

Comparing the performance of machine learning algorithms in land subsidence rate prediction (case study: Isfahan aquifer)

Bahar Mazarei¹, Massoud Morsali^{2✉}

1. Department of Geology, University of Isfahan, Isfahan, Iran.

2. Department of Geology, University of Isfahan, Isfahan, Iran. E-mail: M.morsali@sci.ui.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 31 May 2026

Accepted 03 September 2026

Keywords:

Land subsidence, Isfahan aquifer, Machine learning, InSAR, XGBoost algorithm.

ABSTRACT

Over the past two decades, land subsidence in the Isfahan-Borkhar aquifer has become a serious hazard as a result of excessive groundwater extraction. This study aimed to predict the land subsidence rate and compare the performance of two machine learning algorithms, Random Forest and XGBoost. The dependent variable was derived from 428 randomly selected points taken from Iran's national InSAR-derived subsidence map (2014-2020). Data from 55 piezometric wells (2014-2020) were also used to compute the annual groundwater-level decline rate via linear regression; this was then converted into a groundwater drawdown (GWD) raster using the inverse distance weighting (IDW) method. Thirteen influential variables — elevation, slope, aspect, curvature, Topographic Wetness Index (TWI), distance to roads, distance to faults, distance to streams, NDVI, lithology, transmissivity, groundwater drawdown and alluvial thickness — were prepared at a spatial resolution of 20 m. The data were split into training (70%) and test (30%) subsets, and the models were evaluated using both random and spatial cross-validation. In a single random 70/30 split, Random Forest performed slightly better ($R^2 = 0.7734$, RMSE = 0.9372 cm, MAE = 0.6720 cm); however, based on the average of 10 independent repetitions of this evaluation, XGBoost showed relatively better performance. Spatial cross-validation revealed a marked decline in the generalisability of both models. Alluvial thickness, distance to fault, transmissivity, elevation, lithology and groundwater drawdown were identified as the most important controlling factors.

Introduction

Land subsidence is a geomorphological and engineering-geological process that may result from natural processes, including sediment compaction and fault displacement, and human activities such as excessive groundwater extraction, mining, and oil and gas extraction. It can damage urban infrastructure, roads, pipelines, buildings, and industrial facilities, and may permanently reduce an aquifer's storage capacity (Galloway and Burbey, 2011; Gambolati and Teatini, 2015). In Iran, particularly in central plains such as Isfahan, declining groundwater levels associated with agricultural development and increasing water demand have contributed to widespread subsidence (Motagh et al., 2008; Foroughnia et al., 2018). Previous work in the Isfahan plain has examined the relationship between subsidence, groundwater-level decline, and sediment characteristics. These studies emphasise that thick alluvial deposits and compressible fine-grained layers can intensify subsidence. Research in other Iranian plains has also reported statistically significant relationships between groundwater-level changes and vertical surface displacement. In parallel, InSAR has become an important tool for monitoring subsidence because it provides broad spatial coverage and can measure ground displacement at millimetre-to-centimetre

scales. Studies using Sentinel-1 imagery have documented subsidence in several Iranian plains, including the Isfahan region. Machine-learning algorithms are increasingly used to model subsidence because they can represent nonlinear relationships between environmental variables and ground deformation. Random Forest (RF) reduces variance by averaging the predictions of multiple decision trees, whereas XGBoost uses gradient-boosted decision trees and regularisation. Given the importance of the Isfahan aquifer as a source of water for domestic, industrial, and agricultural uses, this study aims to predict the land subsidence rate, compare the performance of RF and XGBoost, and identify the most important factors associated with the predicted subsidence rate.

Study Area

The Isfahan aquifer is located in the central Iranian Plateau within the Zayandehrud drainage basin. The groundwater system encompasses the Isfahan and Borkhar plains and covers approximately 700 km². It receives recharge from the Najafabad aquifer to the west and acts as a recharge source for groundwater systems in the northern Borkhar and eastern areas. The region has an arid to semi-arid climate and very low average annual precipitation. Population concentration, large industrial facilities, and extensive

Cite this article: Mazarei, B., Morsali, M. (2026). Comparing the performance of machine learning algorithms in land subsidence rate prediction (case study: Isfahan aquifer). *Journal of Engineering Geology*, 20 (2), 219-236. <https://doi.org/10.22034/jeg.2026.137292.0>

agricultural land have increased groundwater demand and disrupted the hydrogeological balance of the aquifer. The associated decline in groundwater levels has contributed to widespread subsidence in Isfahan's urban area and its northern districts.

Data and Influencing Factors

The dependent variable was obtained from Iran's national InSAR-derived annual vertical ground-displacement-rate map for 2014–2020. A total of 428 points were randomly selected from pixels with valid subsidence-rate values. Areas marked as NoData in the InSAR product were excluded because the actual subsidence rate could not be extracted for those locations.

Thirteen independent variables were selected based on previous research, data availability, and the hydrogeological conditions of the Isfahan plain: elevation, slope, aspect, curvature, Topographic Wetness Index (TWI), distance to roads, distance to faults, distance to streams, Normalised Difference Vegetation Index (NDVI), lithology, transmissivity, groundwater drawdown (GWD), and alluvial thickness. Topographic layers were derived from the ALOS PALSAR digital elevation model at 12.5 m resolution. NDVI was generated from 2020 Sentinel-2 imagery using SNAP. Distance layers were prepared from provincial base maps, while lithology, alluvial thickness, and transmissivity were obtained from geological and regional water-resource datasets. Groundwater-level data from 55 piezometric wells were used to calculate the linear rate of groundwater-level change over 2014–2020, using September observations. September was selected as a critical period associated with high withdrawal and low groundwater levels. The resulting point values were interpolated to a continuous raster using inverse distance weighting (IDW). Kriging was initially tested, but the limited number and irregular distribution of wells did not allow a stable variogram to be fitted and produced unrealistic spatial patterns. IDW parameters, including a power of 2 and a variable search radius, were selected by minimising RMSE in leave-one-out cross-validation.

All raster layers were standardised to WGS 84 / UTM Zone 39N, a common extent, and a 20×20 m cell size. Predictor values and subsidence rates were extracted at the sample points. Where predictor data were missing, values were estimated using the mean or mode. The exclusion of NoData areas reduced the number of usable observations and limited spatial coverage.

Materials and Methods

The modelling workflow comprised preparation of the subsidence samples, generation and harmonisation of the predictor layers, machine-learning model development, and production of continuous prediction

maps. The 428 samples were divided into training (70%) and test (30%) subsets. The test subset was kept independent of model fitting, hyperparameter tuning, and feature selection until final evaluation. To reduce data leakage, StandardScaler was fitted using the training data only and then applied to both subsets. Two regression algorithms were implemented in Python using scikit-learn and XGBoost. RF is an ensemble approach that averages predictions from multiple decision trees, while XGBoost sequentially builds boosted trees and incorporates regularisation. Hyperparameters were tuned using grid search with five-fold cross-validation.

Model performance was evaluated using the coefficient of determination (R^2), root mean square error (RMSE), and mean absolute error (MAE). The study considered a single random 70/30 hold-out split, random five-fold cross-validation, ten independent random 70/30 repetitions, spatial K-means cross-validation, and spatial block cross-validation. The spatial validation schemes were included to examine whether model performance remained reliable when test observations were geographically separated from training observations.

Because the 428 sample points were unevenly distributed and concentrated in zones with observed subsidence, direct point predictions did not provide sufficient spatial continuity for mapping. Kriging was not applied to the model outputs because the stepwise predictions from tree-based models do not necessarily provide the variographic structure required by Kriging. Instead, predicted subsidence values were interpolated using IDW to create continuous raster maps. This interpolation was used to represent the predicted values spatially and should not be interpreted as providing new independent observations.

Results and Discussion

Both machine-learning models showed useful predictive performance under random evaluation, but their relative performance depended on the validation method. The resulting spatial prediction maps indicated that higher predicted subsidence rates were concentrated mainly in the central and southern parts of the study area, where groundwater-level decline and thick fine-grained alluvial deposits coincide. The following subsections detail model performance and the importance of the influencing factors.

Model Performance Evaluation

In the single random 70/30 hold-out evaluation, RF performed slightly better than XGBoost. RF achieved $R^2 = 0.7734$, RMSE = 0.9372 cm, and MAE = 0.6720 cm, compared with $R^2 = 0.7564$, RMSE = 0.9717 cm, and MAE = 0.6795 cm for XGBoost. Across ten independent random 70/30 repetitions, XGBoost showed better average performance than RF.

XGBoost achieved mean $R^2 = 0.7444 \pm 0.0319$, RMSE = 0.9759 ± 0.0816 cm, and MAE = 0.6825 ± 0.0432 cm. The corresponding RF results were $R^2 = 0.7153 \pm 0.0282$, RMSE = 1.0349 ± 0.1259 cm, and MAE = 0.7250 ± 0.0596 cm. Random five-fold cross-validation also produced a slightly higher mean R^2 for XGBoost (0.7049 ± 0.0952) than for RF (0.6979 ± 0.0674).

Performance declined substantially under spatial validation. Spatial K-means cross-validation produced negative mean R^2 values for RF (-1.1281 ± 2.8631) and XGBoost (-1.3282 ± 3.2260). Under spatial block cross-validation, mean R^2 was -3.5120 ± 7.6668 for RF and -6.2168 ± 12.8742 for XGBoost. Negative R^2 indicates that, for these spatially separated test samples, predictions were worse than a baseline prediction based on the training mean. These results indicate that the apparent ranking of the algorithms depends on the validation design. RF was marginally better in one random hold-out split, whereas XGBoost performed better on average across the ten repeated random splits. However, neither model generalised well under spatial validation. Spatial autocorrelation, the limited number of observations within spatial blocks, and the possibility that the models learned local rather than transferable patterns may help explain this deterioration. Accordingly, random-split metrics alone may overstate the models' ability to predict subsidence in spatially independent locations.

Feature Importance

Feature importance was calculated using Gini impurity reduction for RF and the Gain criterion for XGBoost. In XGBoost, the most important variables were alluvial thickness, transmissivity, distance to fault, elevation, and lithology, while groundwater drawdown ranked sixth. These results suggest that the predicted subsidence pattern is associated with a combination of subsurface sediment characteristics, aquifer hydraulic properties, geological setting, and groundwater-level decline.

The importance of alluvial thickness is consistent with the role of thick, compressible fine-grained sediments in consolidation and subsidence. Groundwater-level decline is also hydrogeologically relevant because reduced groundwater pressure can promote compaction of susceptible sediments. Transmissivity was highly ranked by XGBoost, but feature importance describes the contribution of a predictor to the model's predictions and does not by itself establish a causal relationship. SHAP analysis was conducted for RF; stable SHAP computation for XGBoost was not feasible because of computational constraints. The mean SHAP contributions were negative for distance to fault, alluvial thickness, elevation, and transmissivity, and positive for GWD, distance to road, distance to stream,

slope, TWI, NDVI, aspect, and lithology. The SHAP beeswarm plot showed a relatively wide range of contributions for distance to fault, alluvial thickness, and elevation, indicating substantial influence on individual model outputs, whereas curvature and TWI showed more limited influence. The sign of a mean SHAP value should not be interpreted alone as evidence that an increase in the variable causes subsidence to increase or decrease. SHAP dependence plots for key predictors would be needed to investigate the direction and possible nonlinearity of these relationships more directly.

Spatial Pattern of Predicted Subsidence

The final maps generated by IDW interpolation showed that the highest predicted subsidence rates were concentrated in the central and southern parts of the aquifer. These areas corresponded with pronounced groundwater-level decline and thicker fine-grained alluvial deposits, including clay-rich materials, which may increase compressibility and the potential for consolidation. In contrast, marginal parts of the plain generally showed lower predicted rates, consistent with thinner alluvial deposits and proximity to bedrock.

The distribution of sample points was constrained by the valid-data coverage of the original InSAR product. Consequently, areas marked as NoData were not represented by observed subsidence values and could not contribute equivalent ground-truth samples to model development. The interpolated maps should therefore be interpreted in light of these data-coverage limitations and the weak spatial generalisability identified by spatial cross-validation.

Conclusions

This study combined InSAR-derived subsidence rates, piezometric observations, satellite imagery, geological information, and machine-learning algorithms to predict land subsidence in the Isfahan aquifer. RF and XGBoost both performed reasonably under random evaluation, although their relative ranking varied by validation method. RF performed slightly better in the single random 70/30 hold-out split, whereas XGBoost showed better average results across ten independent random 70/30 repetitions, with $R^2 = 0.7444 \pm 0.0319$, RMSE = 0.9759 ± 0.0816 cm, and MAE = 0.6825 ± 0.0432 cm.

The negative R^2 values obtained through spatial validation revealed a substantial limitation in the ability of both models to predict subsidence at spatially independent locations. This finding highlights the importance of spatial cross-validation when assessing the generalisability of subsidence models. XGBoost identified alluvial thickness, transmissivity, distance to fault, elevation, lithology, and groundwater drawdown as the leading predictors. The prediction maps

indicated higher subsidence rates mainly in the central and southern parts of the study area, where groundwater decline coincides with thick, compressible alluvium. The XGBoost prediction map may support preliminary decisions related to groundwater-extraction management, artificial-recharge planning, and infrastructure protection. Nevertheless, practical use should account for incomplete InSAR coverage, the limited and uneven distribution of piezometric wells,

and the weak spatial generalisability indicated by spatial validation. Future studies should improve spatial and temporal data coverage, incorporate dynamic variables such as groundwater levels and climatic factors, and prioritise spatially appropriate validation methods. Further investigation of predictor effects using interpretability tools such as SHAP dependence plots may also help clarify nonlinear relationships between environmental and hydrogeological variables and subsidence.

مقایسه عملکرد الگوریتم‌های یادگیری ماشین در پیش‌بینی نرخ فرونشست زمین (مطالعه موردی: آبخوان اصفهان)

بهار مزارعی^۱، مسعود مرسلی^۲ ✉

۱. گروه زمین‌شناسی، دانشگاه اصفهان، اصفهان، ایران.

۲. گروه زمین‌شناسی، دانشگاه اصفهان، اصفهان، ایران. رایانامه: M.morsali@sci.ui.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	فرونشست زمین در آبخوان اصفهان-برخوار طی دو دهه اخیر، در پی برداشت بی‌رویه از منابع آب زیرزمینی، به مخاطره‌ای جدی تبدیل شده است. این پژوهش با هدف پیش‌بینی نرخ فرونشست و مقایسه عملکرد دو الگوریتم یادگیری ماشین Random Forest و XGBoost انجام شد. متغیر وابسته از ۴۲۸ نقطه تصادفی برگرفته از نقشه InSAR ملی ایران (۲۰۱۴-۲۰۲۰) استخراج گردید. داده‌های ۵۵ پیزومتر (۱۳۹۹-۱۳۹۳) نیز برای محاسبه نرخ سالانه افت سطح آب از طریق رگرسیون خطی به کار رفت و با روش IDW به نقشه رستری افت آب (GWD) تبدیل شد. سیزده متغیر مؤثر شامل ارتفاع، شیب، جهت شیب، انحنای TWI، فاصله از جاده‌ها، فاصله از گسل‌ها، فاصله از آبراهه‌ها، NDVI، لیتولوژی، قابلیت انتقال، افت سطح آب زیرزمینی و ضخامت آبرفت با تفکیک مکانی ۲۰ متر آماده‌سازی شدند. داده‌ها به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم و مدل‌ها با اعتبارسنجی متقابل تصادفی و مکانی ارزیابی شدند. در ارزیابی تقسیم تصادفی Random Forest با $MAE = 0.6720$ و $RMSE = 0.9372$ و $R^2 = 0.7734$ عملکرد بهتری داشته‌است، اما بر مبنای میانگین ۱۰ تکرار مستقل این ارزیابی، XGBoost عملکرد نسبتاً بهتری داشت. در مقابل اعتبارسنجی مکانی، کاهش قابل توجه تعمیم‌پذیری هر دو مدل را نشان می‌دهد. ضخامت آبرفت، فاصله از گسل، قابلیت انتقال، ارتفاع، لیتولوژی و افت سطح آب نیز از مهم‌ترین عوامل بودند.
تاریخ دریافت: ۱۴۰۵/۰۳/۱۰	
تاریخ پذیرش: ۱۴۰۵/۰۶/۱۲	
کلیدواژه‌ها:	
فرونشست زمین، آبخوان اصفهان، یادگیری ماشین، InSAR، الگوریتم XGBoost.	

مقدمه

تحلیل هیدروژئولوژی فرونشست در دشت اصفهان پرداخته و ارتباط نزدیک آن را با افت سطح آب زیرزمینی و ویژگی‌های رسوبات بررسی کرده‌اند. یافته‌های ایشان بر نقش کلیدی ضخامت آبرفت و تراکم‌پذیری لایه‌های ریزدانه در تشدید نرخ فرونشست تأکید دارد که با نتایج پژوهش حاضر همسو می‌باشد. همچنین اطهری و همکاران (Athari et al., 2022) با استفاده از تصاویر سنتینل-۱ و مدل‌های رگرسیونی، رابطه آماری معنی‌داری میان تغییرات تراز آب‌زیرزمینی و نرخ جابه‌جایی قائم سطح زمین در دشت ورامین یافتند که همسو با نتایج پژوهش حاضر مبنی بر نقش کلیدی افت سطح آب‌زیرزمینی در فرونشست آب می‌باشد. تاکنون روش‌های مختلفی برای پایش فرونشست به‌کاررفته است: روش‌های زیرسطحی (نصب سنسور در چاه‌ها)، ترازبایی دقیق، سامانه موقعیت‌یاب جهانی (GPS/ GNSS) و روش‌های زمینی و

فرونشست زمین به‌عنوان یک پدیده ژئومورفولوژیکی و زمین‌شناسی مهندسی، در نتیجه عوامل طبیعی (مانند تراکم رسوبات، جابه‌جایی گسل‌ها) و فعالیت‌های انسانی (از جمله برداشت بیش از حد آب‌های زیرزمینی، معدن‌کاری، استخراج نفت و گاز) رخ می‌دهد. (Galloway and Burbey, 2011) این پدیده می‌تواند آسیب‌های جدی به زیرساخت‌های شهری، جاده‌ها، خطوط لوله، ساختمان‌ها و تأسیسات صنعتی وارد سازد و همچنین ظرفیت ذخیره‌سازی آبخوان را به طور دائمی کاهش دهد (Gambolati and Teatini, 2015). در ایران، به‌ویژه در دشت‌های مرکزی مانند اصفهان، افت شدید سطح آب زیرزمینی ناشی از توسعه کشاورزی و افزایش تقاضای آب، منجر به بروز فرونشست گسترده شده است (Motagh et al., 2008; Foroughnia et al., 2018). در راستای مطالعات پیشین، مرسلی و فتاحیان (Morsali and Fattahian, 2024) به

استناد: مزارعی، ب.، مرسلی، م. (۱۴۰۵). مقایسه عملکرد الگوریتم‌های یادگیری ماشین در پیش‌بینی نرخ فرونشست زمین (مطالعه موردی: آبخوان اصفهان). مجله زمین


شناسی مهندسی، ۲۰ (۲)، ۲۳۶-۲۱۹. <https://doi.org/10.22034/jeg.2026.137292.0>

مطالعه‌ای جدید در شهر شیان چین با موفقیت داده‌های تداخل‌سنجی راداری را با مدل‌های ترکیبی یادگیری ماشین از جمله جنگل تصادفی برای پهنه‌بندی خطر فرونشست تلفیق کرده است. از جمله این الگوریتم‌ها می‌توان به Random Forest و XGBoost اشاره کرد. الگوریتم جنگل تصادفی با ساخت تعداد زیادی درخت تصمیم و میانگین‌گیری از نتایج، از بیش‌برازش جلوگیری می‌کند (Breiman, 2001). الگوریتم تقویت‌گرایان (Gradient Boosting) نیز با بهینه‌سازی گرایان و اعمال جریمه‌های L1 و L2، مدلی مقاوم و دقیق ارائه می‌دهد (Chen and Guestrin, 2016). در مطالعه اقراری و همکاران (Eghrari et al., 2023) در دشت کاشان، XGBoost با $R^2=0.9032$ عملکرد بهتری نسبت به RF نشان داد. باتوجه‌به اهمیت آبخوان اصفهان به‌عنوان تأمین‌کننده اصلی آب شرب، صنعت و کشاورزی منطقه، هدف از این پژوهش (۱) تهیه نقشه پیش‌بینی نرخ فرونشست، (۲) مقایسه عملکرد دو الگوریتم Random Forest و XGBoost و (۳) شناسایی مهم‌ترین عوامل کنترل‌کننده فرونشست در آبخوان اصفهان می‌باشد.

منطقه مورد مطالعه

آبخوان اصفهان در مرکز فلات ایران و در حوضه آبریز زاینده‌رود واقع شده است (شکل ۱). این سفره آب زیرزمینی که دشت‌های اصفهان و برخوار را در بر می‌گیرد، مساحتی در حدود ۷۰۰ کیلومتر مربع دارد. آبخوان اصفهان از سمت غرب توسط آبخوان نجف‌آباد تغذیه شده و خود به عنوان منبع تغذیه‌کننده سفره‌های آب زیرزمینی بخش‌های شمالی (برخوار) و شرقی عمل می‌کند (Management of Exploitation of Groundwater Resources, 2019). اقلیم منطقه بر اساس شاخص‌های اقلیمی، خشک و نیمه‌خشک بوده و متوسط بارندگی سالانه در آن بسیار ناچیز است. در سال‌های اخیر، به دلیل تمرکز شدید جمعیت، صنایع بزرگ و اراضی گسترده کشاورزی، تعادل هیدروژئولوژیکی آبخوان به‌هم‌خورده و افت تراز آب منجر به وقوع فرونشست‌های گسترده در بافت شهری اصفهان و مناطق شمالی آن شده است.

روش‌های سنجش‌ازدور، در میان روش‌های سنجش‌ازدور، تکنیک تداخل‌سنجی راداری با روزه مصنوعی (InSAR) به دلیل توانایی در اندازه‌گیری جابه‌جایی سطح زمین بادقت سانتی‌متری و حتی میلی‌متری، پوشش وسیع و کاهش نسبی وابستگی به شرایط زمینی، بسیار موردتوجه قرار گرفته است (Bokhari et al., 2023). مطالعات اخیر نشان داده‌اند که ترکیب تکنیک‌های سنجش‌ازدور، به‌ویژه داده‌های InSAR و تصاویر ماهواره‌ای چندزمانه، نقش مؤثری در پایش دقیق و بلندمدت فرونشست زمین دارد (Asgari et al., 2024). به طور مشابه، پایش فرونشست دشت کازرون با استفاده از تصاویر سنتینل و تکنیک تداخل‌سنجی راداری نشان داد که برداشت بی‌رویه از آب‌های زیرزمینی، به‌ویژه در بخش‌های مرکزی دشت، نرخ فرونشستی تا ۹ سانتی‌متر در سال ایجاد کرده است (Khalooei and Elmizadeh, 2023). در همین راستا، شیرانی و پسندی (Shirani and Pasandi, 2026) با استفاده از تکنیک تداخل‌سنجی راداری پراکنشگرهای پایدار (PSInSAR)، به ارزیابی و پهنه‌بندی مخاطره فرونشست در حوضه‌های آبخیز استان اصفهان پرداختند که یافته‌های آن با نتایج پژوهش حاضر در محدوده مطالعاتی مشابه، همسویی دارد. در این پژوهش از نقشه فرونشست ملی ایران مبتنی بر داده‌های سنتینل ۱ در بازه ۲۰۱۴ تا ۲۰۲۰ استفاده گردید (Haghshenas Haghighi and Motagh, 2024). در سال‌های اخیر، الگوریتم‌های یادگیری ماشین به دلیل توانایی در مدل‌سازی روابط غیرخطی و پیچیده میان عوامل محیطی و پدیده فرونشست، به طور گسترده در مدل‌سازی و پیش‌بینی نرخ فرونشست به کار رفته‌اند (Arabameri et al., 2021; Eghrari et al., 2023). محمدی و همکاران (Mohammady et al., 2019) نیز با استفاده از الگوریتم جنگل تصادفی، نقشه حساسیت فرونشست دشت سمنان را تهیه کردند و نشان دادند این روش در تشخیص عوامل کنترل‌کننده فرونشست از دقت بالایی برخوردار است. همچنین رویکردهای تلفیقی مبتنی بر سری‌های زمانی تداخل‌سنجی راداری و الگوریتم‌های یادگیری ماشین با موفقیت برای پیش‌بینی و پایش فرونشست توسعه یافته‌اند (Yang et al., 2025). به‌عنوان نمونه چن و همکاران (Chen et al., 2024) در



شکل ۱. منطقه مورد مطالعه و مکان نقاط نمونه فرونشست

Fig. 1. Study area and location of subsidence sample points (DEM) ماهواره ALOS PALSAR با تفکیک مکانی ۱۲/۵ متر استخراج شدند. لایه‌های هندسی فاصله تا جاده، فاصله تا گسل و فاصله تا آبراهه از نقشه‌های پایه استان تهیه گردیدند. شاخص پوشش گیاهی (NDVI) با استفاده از تصاویر ماهواره‌ای Sentinel-2 متعلق به سال ۱۳۹۹ و از طریق پردازش رادیومتریک در نرم‌افزار SNAP تولید شد. لایه‌های زمین‌شناسی و هیدروژئولوژیکی شامل لیتولوژی، ضخامت آبرفت و قابلیت انتقال (Transmissivity) نیز از نقشه‌های سازمان زمین‌شناسی و داده‌های شرکت آب منطقه‌ای اصفهان استخراج و یکپارچه‌سازی شدند.

داده‌های مورد استفاده و عوامل مؤثر

در این تحقیق، بر اساس پیشینه پژوهش (Arabameri et al., 2021; Eghrari et al., 2023) و باتوجه به در دسترس بودن داده‌ها و بررسی شرایط هیدروژئولوژیکی دشت اصفهان، ۱۳ عامل محیطی و زمین‌شناسی به عنوان متغیرهای مستقل مؤثر بر وقوع فرونشست زمین انتخاب شدند (جدول ۱). همچنین ۴۲۸ نقطه فرونشست به عنوان متغیر وابسته از نقشه InSAR ایران استخراج گردید. داده‌های توپوگرافی شامل ارتفاع، شیب، جهت شیب، انحنای زمین و شاخص رطوبت توپوگرافی (TWI) از مدل رقومی ارتفاعی

جدول ۱. مشخصات عوامل مؤثر بر فرونشست در این پژوهش

Table 1. Characteristics of factors affecting subsidence in this study

Effective factor	Data source	Spatial scale / resolution
Elevation	DEM ALOS PALSAR	12.5 m
Slope	Extracted from DEM	12.5 m
Aspect	Extracted from DEM	12.5 m
Curvature	Extracted from DEM	12.5 m
TWI	Extracted from DEM	12.5 m
Distance to Road	Provincial Road map	1:100000
Distance to Stream	Provincial Stream map	1:100000
Distance to Fault	Provincial Fault map	1:100000

GroundWater Drawdown	Piezometric data from Isfahan Regional Water Company	Calculating the annual rate of 93-99 for the month of September, Interpolation with IDW, 20x20 raster
NDVI	Sentinel-2 images	Calculate it in NDVI software, 20x20 raster
Lithology	Geological Survey	1:100000
Transmissivity	Isfahan regional water	Hydrogeological maps
Alluvial thickness	Isfahan regional water	Subsurface maps

در این بخش از نقشه DEM، لایه‌های ارتفاعی، شیب، جهت شیب و انحنا با استفاده از جعبه‌ابزار Spatial Analyst نرم‌افزار ArcGIS و از روی DEM ماهواره ALOS PALSAR استخراج شدند. شاخص NDVI با پردازش رادیومتریک تصاویر Sentinel-2 در نرم‌افزار SNAP تولید و سپس به ArcGIS منتقل شد. TWI نیز مخفف شاخص رطوبت توپوگرافی (Topographic Wetness Index) است که میزان تجمع رطوبت در یک نقطه از سطح زمین را نشان می‌دهد که فرمول آن به‌صورت زیر می‌باشد.

$$TWI = \ln\left(\frac{a}{\tan b}\right) \quad (1)$$

در این فرمول a نشان‌دهنده مساحت ویژه آبخیز (Specific Catchment Area) یعنی مساحت حوضه بالادست تقسیم بر طول خط جریان واحد (معمولاً بر حسب متر)، و b نشان‌دهنده زاویه شیب محلی زمین (بر حسب درجه یا رادیان) است که $\tan b$ همان تانژانت آن زاویه می‌باشد. برای محاسبه این شاخص، ابتدا لایه DEM با ابزار Fill جعبه‌ابزار Hydrology در ArcGIS از حفره‌های کاذب پالایش شده و سپس با ابزارهای Flow Direction و Flow Accumulation، جهت و میزان تجمع جریان سطحی در هر سلول محاسبه گردید. مساحت ویژه آبخیز (a) نیز از حاصل ضرب مقدار Flow Accumulation در اندازه سلول به دست آمد. زاویه شیب زمین هم بر حسب رادیان از لایه Slope استخراج و در نهایت، با استفاده از ابزار Raster Calculator و بر اساس رابطه ارائه شده، نقشه نهایی شاخص رطوبت توپوگرافی تولید شد.

محاسبه افت سطح آب زیرزمینی و درونیابی

افت تراز سفره آب زیرزمینی، اصلی‌ترین محرک تحکیم رسوبات دانهریز و وقوع فرونشست است. در این پژوهش، اطلاعات هیدرولوژیکی ۵۵ چاه پیزومتری توزیع‌شده در سطح آبخوان اصفهان برای یک دوره ۷ ساله (۱۳۹۳-۱۳۹۹) مورد تحلیل قرار گرفت. داده ورودی اعمال‌شده برای هر ایستگاه پیزومتری، شیب یا

روش‌شناسی

در این پژوهش فرآیند تحقیق در چهار مرحله اصلی اجرا می‌شود که در ادامه به توضیح هر مرحله پرداخته شده است.

گام اول: آماده‌سازی لایه فرونشست و انتخاب نقاط فرونشست

در این پژوهش، به منظور تهیه متغیر وابسته مدل‌های یادگیری ماشین، از نقشه نرخ سالانه جابه‌جایی عمودی سطح‌زمین (با واحد سانتی‌متر بر سال) حاصل از پردازش داده‌های InSAR در بازه زمانی ۱۳۹۳ تا ۱۳۹۹ (۲۰۲۰-۲۰۱۴) استفاده شد. با توجه به اینکه بخشی از محدوده مورد مطالعه در این محصول دارای مقادیر NoData (فاقد داده معتبر) بود، نمونه‌برداری تنها از پیکسل‌هایی انجام شد که دارای مقادیر معتبر نرخ فرونشست بودند. در نهایت، ۴۲۸ نقطه به صورت تصادفی از نواحی دارای داده معتبر انتخاب و به عنوان نقاط آموزشی و آزمون مورد استفاده قرار گرفتند. نقاط نمونه‌برداری‌شده به‌صورت تصادفی از تمامی پیکسل‌های دارای داده معتبر در نقشه InSAR استخراج شدند. این نقاط طیف کاملی از مقادیر نرخ فرونشست (از مقادیر نزدیک به صفر تا بیشینه نشست) را پوشش می‌دهند تا مدل قادر به یادگیری رفتار آبخوان در تمامی شرایط باشد. به دلیل وجود نواحی فاقد داده (NoData) در نقشه مرجع، این نواحی از فرآیند نمونه‌برداری حذف شدند که این موضوع در بخش محدودیت‌های پژوهش تشریح شده است.


گام دوم: ایجاد ۱۳ لایه از عوامل مستقل


در این قسمت تمامی لایه‌های رستری با استفاده از نرم‌افزار ArcGIS و SNAP تهیه و همسان‌سازی شدند. در ادامه توضیح مختصری در مورد روش ایجاد برخی لایه‌ها ارائه می‌شود (شکل ۲).


لایه‌های توپوگرافی

(Zone 39N، اندازه سلول‌ها (20×20) و محدوده‌های آن‌ها با ابزار Project Raster و Resample همسان‌سازی شدند. در صورت متفاوت بودن مشخصات لایه‌ها با استفاده از ابزارهای نام‌برده، لایه به شرایط مطلوب خود تبدیل می‌شود. در انتها؛ با استفاده از ابزار Extract Multi Values to Points در ArcGIS، به استخراج مقادیر ۱۳ لایه (متغیرهای مستقل) و لایه فرونشست (متغیر وابسته) برای ۴۲۸ نقطه نمونه به صورت تصادفی پرداخته شد. در طی فرآیند استخراج داده‌ها، نقاطی که در نقشه نرخ فرونشست دارای مقدار NoData بودند، از مجموعه داده حذف شدند، زیرا مقدار واقعی متغیر وابسته در این نقاط در دسترس نبود. استفاده از این نقاط مستلزم اختصاص مقادیر فرضی به نرخ فرونشست بود که می‌توانست موجب کاهش اعتبار مدل‌های یادگیری ماشین و افزایش خطای پیش‌بینی شود. در ادامه با بررسی جدول داده‌ای هر یک از نقطه‌ها، از Null نبودن سلول‌ها اطمینان حاصل می‌شود. همچنین در صورت نداشتن مقدار، توسط میانگین یا مد مقدار آن به دست می‌آید.

نرخ خطی اختلاف سطح آب آن چاه در ماه شهریور (به عنوان بحرانی‌ترین ماه از نظر برداشت و کمترین تراز آبی) در طول سال‌های ۹۳ تا ۹۹ بود. جهت تبدیل این نقاط شاخص به یک لایه رستری پیوسته، ابتدا روش کریجینگ (Kriging) اعمال شد؛ اما به دلیل تعداد محدود پیزومترها (۵۵ حلقه) و توزیع نامنظم مکانی آن‌ها، برازش یک مدل واریوگرام پایدار و قابل اعتماد میسر نبود و نقشه‌های حاصل، ناپیوستگی و ساختار غیرواقعی (مغایر با خطوط هم‌پتانسیل آبخوان) نشان می‌دادند. از این رو، از روش قطعی عکس فاصله‌ی وزنی (IDW) که فاقد پیش‌فرض آماری صریح دربارهٔ ساختار همبستگی مکانی داده است، استفاده گردید. پارامترهای بهینه روش IDW (از جمله توان ۲ و شعاع جستجوی متغیر) بر اساس کمینه‌سازی خطای ریشه میانگین مربعات (RMSE) حاصل از آزمون اعتبارسنجی متقاطع حذفی (Leave-one-out Cross Validation) تعیین و اعمال گردیدند. بقیه لایه‌ها نیز در نرم‌افزار ArcGIS ایجاد و سپس سیستم مختصات (WGS84 UTM







شکل ۲. نقشه عوامل مؤثر بر فرونشست جهت شیب a=، ضخامت آبرفت b=، فاصله از گسل c=، انحنا d=، فاصله از جاده e=، فاصله از آبراهه f=، ارتفاع شیب g=، سنگشناسی i=، افت سطح آب j=، شاخص پوشش گیاهی k=، شاخص رطوبت توپوگرافی l=، قابلیت انتقال m=

Fig. 2. Map of factors influencing land subsidence a= Aspect, b= Alluvial Thickness, c= Distance to Fault, d= Curvature, e= Distance to Road, f= Distance to Stream, g= Elevation, h= Slope, i= Lithology, j= GWD, k= NDVI, l= TWI, m= Transmissivity

جدول ۲- لیتولوژی منطقه مورد مطالعه

Table 2. Lithology of the study area

Geo unit	Description	Age
Qft2	Low level piedment fan and vally terrace deposits	Quaternary
Qal	Stream channel, braided channel and flood plain deposits	Quaternary
Qcf	Clay flat	Quaternary
Klsol	Grey thick - bedded to massive orbitolina limestone	Early.Cretaceous
K1c	Red conglomerate and sandstone	Cretaceous
TRn	Sandstone, quartz arenite, shale and fossiliferous limestone (NAIBAND FOR)	Mesozoic

گام سوم: مدل‌سازی با الگوریتم‌های یادگیری ماشین

داده‌های استخراج‌شده از ۴۲۸ نقطه فرونشست به همراه مقادیر متناظر ۱۳ عامل مؤثر محیطی، وارد الگوریتم‌های یادگیری ماشین شدند. داده‌های آزمون (۳۰٪) در هیچ‌یک از مراحل آموزش، تنظیم ابرپارامترها و انتخاب ویژگی‌ها مشارکتی نداشته و تا پایان فرآیند مدل‌سازی جهت ارزیابی نهایی مدل‌ها کاملاً مستقل باقی ماندند. این نسبت تقسیم (۷۰ به ۳۰) به‌عنوان رویه‌ای استاندارد و به‌عنوان تصمیم طراحی پژوهش برای مدل‌سازی یادگیری ماشین با حجم داده‌های متوسط (۴۲۸ نمونه) انتخاب شد (Roberts et al., 2017). به‌گونه‌ای که با تخصیص حجم کافی داده (۱۲۸ نمونه) به مجموعه آزمون، امکان سنجش پایدار و بدون سوگیری توانایی تعمیم مدل‌ها فراهم گردد. این نسبت همسو با رویه رایج در مطالعات معتبر پیشین در حوزه فرونشست توسط عرب عامری و همکاران و اقراری و همکاران (Arabameri et al., 2021; Eghrari et al., 2023) انتخاب شده است. به‌منظور پیشگیری از نشت داده (Data Leakage)، فرآیند استانداردسازی ویژگی‌ها (StandardScaler) صرفاً براساس آمار داده‌های آموزش برازش (fit) و سپس بر هر دو مجموعه آموزش و آزمون اعمال (transform) گردید.

الگوریتم جنگل تصادفی (Random Forest Regression)؛ یک مدل یادگیری گروهی مبتنی بر درخت‌های تصمیم‌گیری متعدد است که با میانگین‌گیری از درخت‌ها، واریانس مدل را کاهش می‌دهد (Breiman, 2001).

الگوریتم XGBoost Regression؛ یک پیاده‌سازی بهینه‌شده از درخت‌های تقویت‌کننده گرادیان (Gradient Boosting) است که با بهره‌گیری از محاسبات موازی و توابع جریمه لایه منظم‌سازی (Regularization)، سرعت بسیار بالا و قدرت فوق‌العاده‌ای در کنترل بیش‌برازش دارد (Chen and Guestrin, 2016).

مدل‌ها در محیط پایتون (کتابخانه‌های Scikit-learn و XGBoost) پیاده‌سازی شدند. ابتدا ویژگی‌ها با StandardScaler استانداردسازی گردیدند. سپس تنظیم ابرپارامترهای هر دو مدل، با استفاده از روش جستجوی شبکه‌ای (Grid Search) و اعتبارسنجی متقابل ۵ لایه انجام پذیرفت.

گام چهارم: درون‌یابی و ترسیم نقشه‌های نهایی فرونشست

پس از اجرای مدل‌ها در پایتون، به‌دلیل پراکندگی غیریکنواخت ۴۲۸ نقطه نمونه در سطح آبخوان (تمرکز در پهنه‌های دارای فرونشست) و عدم پوشش نواحی فاقد نمونه، نقشه‌های پیکسلی

خروجی مستقیم فاقد پیوستگی مکانی کافی برای کاربردهای مدیریتی بودند. با توجه به اینکه خروجی الگوریتم‌های درختی (Random Forest و XGBoost) ماهیتی ناپیوسته و پله‌ای دارد و فاقد ساختار واریوگرافی موردنیاز روش کریجینگ است، از اعمال کریجینگ بر خروجی مدل‌ها صرف‌نظر شد. به‌جای آن، مقادیر عددی نرخ فرونشست پیش‌بینی‌شده توسط هر دو مدل به محیط نرم‌افزار ArcGIS منتقل و با استفاده از روش عکس فاصله وزنی (IDW) به سطح رستری پیوسته تبدیل شد. روش IDW به‌دلیل فقدان فرض آماری صریح درباره ساختار مکانی داده، گزینه‌ای سازگارتر با ماهیت خروجی مدل‌های یادگیری ماشین محسوب می‌شود.

نتایج و بحث

ارزیابی و مقایسه عملکرد مدل‌ها


کارایی و قدرت پیش‌بینی مدل‌های یادگیری ماشین با استفاده از سه معیار آماری: ضریب تبیین (R^2)، ریشه میانگین مربع خطا (RMSE) و میانگین قدر مطلق خطا (MAE) مورد ارزیابی قرار گرفت. نتایج نشان داد که هر دو مدل با مقادیر ضریب تبیین بالای ۷۵٪ و خطاهای بسیار کم (RMSE کمتر از ۱ سانتی‌متر، توانایی بالایی در مدل‌سازی نرخ فرونشست دارند (شکل ۳).

نتایج اعتبارسنجی مکانی (Spatial Block Cross-Validation) کاهش شدید توان تعمیم‌پذیری هر دو مدل را آشکار ساخت؛ به‌طوری‌که مقادیر R^2 منفی (Random Forest: $R^2 = -3.51 \pm 7.67$ ؛ XGBoost: $R^2 = -6.22 \pm 12.87$) به‌دست آمد. R^2 منفی بدین معناست که در پیش‌بینی نقاط جدید و مستقل از نظر مکانی، عملکرد مدل‌ها حتی از یک برآورد ساده بر مبنای میانگین داده‌های آموزش نیز ضعیف‌تر بوده است. این افت شدید عملکرد ناشی از خودهمبستگی مکانی قوی در متغیر وابسته (نرخ فرونشست) و حجم محدود داده‌ی آموزشی درون هر بلوک مکانی می‌باشد که نشان می‌دهد مدل‌های حاضر عمدتاً الگوهای محلی را به‌جای روابط علی قابل تعمیم یاد گرفته‌اند.

جدول ۳- مقایسه عملکرد مدل‌ها تحت روش‌های مختلف اعتبارسنجی

Table.3. Comparing the performance of models under different validation methods

Model	Evaluation method	$R^2(\text{mean} \pm \text{std})$	RMSE(cm)	MAE(cm)
Random Forest	Random 5-Fold CV	0.6979 ± 0.0674	1.0495 ± 0.1514	0.7486 ± 0.0767
XGBoost	Random 5-Fold CV	0.7049 ± 0.0952	1.0294 ± 0.1815	0.7200 ± 0.1039
Random Forest	10 random repetitions of 70 / 30	0.7153 ± 0.0282	1.0349 ± 0.1259	0.7250 ± 0.0596
XGBoost	10 random repetitions of 70 / 30	0.7444 ± 0.0319	0.9759 ± 0.0816	0.6825 ± 0.0432
Random Forest	Spatial KMeans CV	-1.1281 ± 2.8631	1.7627 ± 0.9325	1.3804 ± 0.7238
XGBoost	Spatial KMeans CV	-1.3282 ± 3.2260	1.7983 ± 1.0859	1.3678 ± 0.7987
Random Forest	Spatial Block CV	-3.5120 ± 7.6668	2.0051 ± 1.1960	1.6219 ± 1.1178
XGBoost	Spatial Block CV	-6.2168 ± 12.8742	2.3109 ± 1.5789	1.8521 ± 1.5001
Random Forest	Random Hold-out 70/30	0.7734	0.9372	0.6720
XGBoost	Random Hold-out 70/30	0.7564	0.9717	0.6795



شکل ۳- سازگاری بین داده‌های اندازه‌گیری شده و داده‌های پیش‌بینی‌شده در مدل‌ها

Fig. 3. Compatibility between measured data and predicted data in models

نتایج نشان داد رتبه‌بندی برتری دو مدل به روش ارزیابی آن‌ها بستگی دارد. در یکبار تقسیم تصادفی ۳۰/۷۰ Random Forest عملکرد اندکی بهتری نشان داد ($R^2=0.7734$) در برابر $R^2=0.7564$ برای XGBoost). اما در میانگین ۱۰ تکرار اعتبارسنجی متقاطع ۵ لایه‌ای (دارای برآورد پایدارتر و کمتر مستعد نوسان تصادفی از توان تعمیم مدل) الگوریتم XGBoost با $R^2 = 0.744 \pm 0.032$ نسبت به Random Forest ($R^2 = 0.7153 \pm 0.028$) پایدارتری از خود نشان داد.

به‌منظور ارزیابی اعتبار و قابلیت تعمیم نتایج، عملکرد مدل‌ها علاوه بر اعتبارسنجی متقاطع ۵ لایه‌ای، توسط ۱۰ تکرار مستقل تقسیم‌بندی تصادفی ۳۰/۷۰ (با تقسیم‌بندی مجدد داده‌ها در هر تکرار) ارزیابی شد. نتایج این روش نیز نشان داد که هر دو مدل توانایی بالایی در شبیه‌سازی دارند، با این حال الگوریتم XGBoost با میانگین $R^2 = 0.7444 \pm 0.0319$ نسبت به Random Forest با $R^2 = 0.7153 \pm 0.0282$ ، عملکرد نسبتاً بهتر و پایدارتری از خود نشان داد (جدول ۳).


اهمیت عوامل مؤثر بر فرونشست

اهمیت ویژگی‌ها در مدل جنگل تصادفی براساس معیار کاهش ناخالص گینی (Gini Impurity Reduction) و در مدل XGBoost براساس معیار Gain (افزایش دقت حاصل از انشعابات هر ویژگی) محاسبه گردید.

تحلیل اهمیت ویژگی‌ها در مدل XGBoost نشان داد که ضخامت آبرفت، قابلیت انتقال (T)، فاصله از گسل (DtF)، ارتفاع و لیتولوژی به ترتیب بیشترین تأثیر را در پیش‌بینی نرخ فرونشست دارند، و افت سطح آب زیرزمینی (GWD) در رتبه‌ی ششم اهمیت قرار می‌گیرد. این یافته منطبق با واقعیت هیدروژئولوژیکی آبخوان

اصفهان است: مناطق با ضخامت آبرفت بیشتر (رسوبات ریزدانه تراکم‌پذیر) و افت شدید سطح آب، بیشترین نرخ فرونشست را تجربه می‌کنند (شکل ۴).

همچنین همسو با یافته‌های پژوهش حاضر که افت سطح آب زیرزمینی و ضخامت آبرفت را به‌عنوان مهم‌ترین عوامل کنترل‌کننده فرونشست معرفی می‌کند، مطالعه صالحی متعهد و همکاران (Salehi Moteahd et al., 2019) نیز در دشت مشهد و نشان داد که بیش‌ترین نرخ فرونشست در مناطقی با تناوب رسوبات ریزدانه و درشت‌دانه، ضخامت زیاد آبرفت و افت شدید سطح آب زیرزمینی رخ داده است.




شکل ۴- اهمیت ویژگی‌ها در مدل‌ها a= Random Forest, b= XGBoost

Fig. 4. Feature importance of models a= Random Forest, b= XGBoost

Beeswarm (شکل ۵-b) نیز پراکندگی مقادیر SHAP را در سطح نمونه‌های منفرد نشان می‌دهد که فاصله از گسل، ضخامت آبرفت و ارتفاع، بیشترین دامنه‌ی تغییرات و در نتیجه بیشترین تأثیرگذاری را بر خروجی مدل داشته‌اند؛ درحالی‌که عواملی مانند انحنا و TWI تأثیر محدودی نشان دادند. تفسیر دقیق‌تر جهت اثر هر متغیر (مثبت/منفی بودن رابطه با افزایش مقدار متغیر) نیازمند بررسی تکمیلی با نمودارهای SHAP Dependence برای متغیرهای کلیدی است که در مطالعات آتی پیشنهاد می‌شود. در ادامه پارامترهای بهینه مدل‌ها که در این پژوهش استفاده شده، در جدول ۴ ارائه شده است.

به‌منظور تبیین جهت و میزان تأثیر هر یک از عوامل ورودی بر خروجی مدل، تحلیل SHAP برای مدل Random Forest انجام شد؛ محاسبه‌ی پایدار مقادیر SHAP برای مدل XGBoost با محدودیت محاسباتی مواجه شد و در این پژوهش میسر نگردید. همان‌طور که در شکل ۵ مشاهده می‌شود، فاصله از گسل (DtF)، ضخامت آبرفت، ارتفاع و قابلیت انتقال (T) دارای میانگین سهم منفی، و افت سطح آب زیرزمینی (GWD)، فاصله از جاده، فاصله از آبراهه، شیب، TWI، NDVI، جهت شیب و لیتولوژی دارای میانگین سهم مثبت در پیش‌بینی نرخ فرونشست می‌باشند. نمودار



شکل ۵- نمودار SHAP a: میانگین تأثیر عوامل بر خروجی مدل جنگل تصادفی براساس SHAP، b: پراکندگی مقادیر SHAP برای هر عامل در سطح نمونه‌های منفرد در مدل جنگل تصادفی

Fig.5. SHAP graph a: Average effect of the feature on the Random Forest model output, b: Distribution of SHAP values for each feature across individual in the Random Forest model

جدول ۴- پارامترهای بهینه مدل‌ها

Table 4. Optimal hyperparameters of the models

Model	Parameter	Optimal Value
Random Forest	n_estimators	1000
Random Forest	min_samples_split	2
Random Forest	min_samples_leaf	1
Random Forest	max_features	0.4
Random Forest	max_depth	None
XGBoost	n_estimators	1000
XGBoost	subsample	0.8
XGBoost	reg_lambda	0.5
XGBoost	reg_alpha	0.0
XGBoost	max_depth	6
XGBoost	learning_rate	0.1
XGBoost	colsample_bytree	0.9

منطقه مورد مطالعه متمرکز شده است. در این حالت درون‌یابی IDW عمدتاً نقش پرکردن شکاف مکانی میان نقاط نمونه را ایفا کرده، بدون آنکه ساختار اصلی الگوی پیش‌بینی شده توسط مدل را تغییر دهد.

همچنین بررسی لایه‌های جانبی نشان داد که در این مناطق علاوه بر افت شدید تراز آب به دلیل چاه‌های مجاز و غیرمجاز کشاورزی


تحلیل نقشه نرخ فرونشست

نقشه‌های نهایی حاصل از درون‌یابی IDW بر روی داده‌های پیش‌بینی شده مدل‌ها (شکل ۶)، انطباق مکانی بسیار شدیدی را میان نرخ فرونشست و افت سطح تراز آب نشان می‌دهند. بیشترین میزان نرخ فرونشست پیش‌بینی شده در مناطق مرکز و جنوب

در محصول InSAR دارای مقادیر NoData بودند، امکان استخراج نرخ واقعی فرونشست در این نواحی وجود نداشت. بنابراین، حذف این مناطق از فرآیند نمونه‌برداری ناشی از محدودیت داده‌های ورودی می‌باشد. این رویکرد از ورود مقادیر نامعتبر به مجموعه داده آموزشی جلوگیری کرده و قابلیت اعتماد نتایج مدل را افزایش داده است.

و صنعتی، ضخامت آبرفت ریزدانه (شیل و رس) در بالاترین حد خود قرار دارد که پتانسیل تراکم‌پذیری و نشست مخزن آبخوان را به شدت تشدید کرده است. در مقابل، مناطق حاشیه‌ای دشت به دلیل کاهش ضخامت آبرفت و نزدیکی به سنگ کف، نرخ کمتری از فرونشست نشان داده‌اند.

لازم به ذکر است که توزیع نقاط نمونه تابع پوشش مکانی داده‌های معتبر InSAR بوده است. از آنجا که بخش‌هایی از محدوده مطالعه



شکل ۴ - نقشه نرخ پیش‌بینی شده فرونشست زمین a= Random Forest, b= XGBoost
Fig. 4. Predicted Land Subsidence rate map a= Random Forest, b= XGBoost

تصمیم‌گیری برای مدیریت برداشت از چاه‌ها، برنامه‌ریزی تغذیه مصنوعی و حفاظت از زیرساخت‌های حیاتی اصفهان مورد استفاده قرار گیرد.

محدودیت‌های پژوهش

این مطالعه دارای محدودیت‌هایی است که در تفسیر نتایج باید مدنظر قرار گیرد:

یکی از مهم‌ترین محدودیت‌های این پژوهش، وجود نواحی فاقد داده (NoData) در نقشه نرخ فرونشست حاصل از InSAR بود که امکان استخراج مقدار واقعی نرخ فرونشست را در این نواحی فراهم نمی‌کرد. در نتیجه، تعداد نمونه‌های قابل استفاده برای آموزش و ارزیابی مدل‌های یادگیری ماشین کاهش می‌یابد. این مسئله می‌تواند بر توانایی مدل‌ها در یادگیری الگوهای مکانی فرونشست، به‌ویژه در مناطق کم‌پوشش، تأثیرگذار باشد. در پژوهش‌های آینده، استفاده از محصولات InSAR با پوشش مکانی کامل‌تر یا ترکیب داده‌های چندمنبعی می‌تواند موجب افزایش تعداد نمونه‌های قابل استفاده و بهبود عملکرد مدل‌های پیش‌بینی شود.

نتیجه‌گیری

در این پژوهش، پیش‌بینی نرخ فرونشست در آبخوان اصفهان با استفاده از تلفیق داده‌های هیدروژئولوژیکی، تصاویر ماهواره‌ای InSAR و Sentinel-2 و الگوریتم‌های هوشمند یادگیری ماشین انجام شد. نتایج این تحقیق نشان داد که استفاده از روش IDW برای لایه هیدروژئولوژیکی افت تراز آب و استفاده از همین روش (IDW) بر روی خروجی پیش‌بینی مدل‌های پایتون، راهکاری کارآمد برای غلبه بر خطاهای پردازشی نرم‌افزاری و ارتقای کیفیت بصری و فنی نقشه‌ها می‌باشد. مدل XGBoost بر مبنای میانگین

۱۰ تکرار اعتبارسنجی متقاطع ۵ لایه‌ای با

$$R^2 = 0.7444 \pm 0.032, RMSE(cm) = 0.976 \pm 0.082, MAE(cm) = 0.683 \pm 0.043$$

عملکرد نسبتاً پایدارتری نسبت به Random Forest نشان داد. مهم‌ترین عوامل مؤثر در فرونشست به ترتیب شامل ضخامت آبرفت، قابلیت انتقال، فاصله از گسل، ارتفاع، لیتولوژی و افت سطح آب‌زیرزمینی می‌باشند. نقشه نهایی پیش‌بین نرخ فرونشست حاصل از مدل XGBoost می‌تواند به‌عنوان یک ابزار پشتیبان

هیدروژئولوژیکی در قالب داده‌های مکانی ثابت وارد مدل شده‌اند و تغییرات زمانی آن‌ها در طول دوره مطالعه به‌طور کامل لحاظ نشده است. در حالی که فرونشست زمین یک پدیده پیچیده و وابسته به برهم‌کنش فرآیندهای مکانی و زمانی است، استفاده همزمان از متغیرهای پویا مانند تغییرات ماهانه سطح آب زیرزمینی، بارش، تبخیر-تعرق، رطوبت خاک و سایر عوامل اقلیمی می‌تواند تصویر دقیق‌تری از فرآیندهای مؤثر بر فرونشست ارائه دهد.

در نهایت، پیشنهاد می‌شود در مطالعات آتی علاوه بر الگوریتم‌های مورد استفاده در این پژوهش، عملکرد سایر روش‌های یادگیری ماشین و یادگیری عمیق نیز بررسی و با یکدیگر مقایسه شود. استفاده از روش‌های تفسیرپذیری مدل مانند SHAP نیز می‌تواند در شناسایی سهم نسبی هر یک از عوامل مؤثر بر فرونشست و درک بهتر روابط غیرخطی میان متغیرهای هیدروژئولوژیکی، محیطی و فرونشست مؤثر باشد. بدین ترتیب، توسعه یک چارچوب جامع مکانی-زمانی با داده‌های باکیفیت‌تر، پوشش مکانی و زمانی کامل‌تر و اعتبارسنجی مکانی مناسب می‌تواند زمینه را برای پیش‌بینی دقیق‌تر و کاربردی‌تر فرونشست زمین در منطقه مورد مطالعه فراهم سازد.

References

- Arabameri, A., Lee, S., Rezaie, F., Pal, S. C., Asadi Nalivan, O., Saha, A., Chowdhuri, I., & Moayedi, H. (2021). Performance evaluation of GIS-based novel ensemble approaches for land subsidence susceptibility mapping. *Frontiers in Earth Science*, 9, 663678. DOI: [10.3389/feart.2021.663678](https://doi.org/10.3389/feart.2021.663678)
- Asgari, S., Shirani, K., & Soleimani, F. (2024). Monitoring and detection of land subsidence. In *Remote Sensing of Soil and Land Surface Processes* (pp. 281-302). Elsevier. DOI: [10.1016/B978-0-443-15341-9.00021-6](https://doi.org/10.1016/B978-0-443-15341-9.00021-6)
- Athari, M., Azizi, H. R., Hashemi, S. S., & Honari, H. (2022). Investigation of the relationship between land surface changes due to subsidence and groundwater using sentinel-1 satellite images and statistical models (case study: Varamin plain). *Journal of Water and Wastewater Science and Engineering*, 7(1), 34-43. DOI: [10.22112/jwwse.2021.261650.1232](https://doi.org/10.22112/jwwse.2021.261650.1232)
- Bokhari, R., Shu, H., Tariq, A., Al-Ansari, N., Guluzade, R., Chen, T., Jamil, A., & Aslam, M. (2023). RETRACTED: Land subsidence analysis using synthetic aperture radar data. *Heliyon*, 9(3). DOI: [10.1016/j.heliyon.2023.e14690](https://doi.org/10.1016/j.heliyon.2023.e14690)
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32. DOI: [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324)
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794). DOI: [10.1145/2939672.2939785](https://doi.org/10.1145/2939672.2939785)
- از دیگر محدودیت‌های پژوهش، محدود بودن داده‌های اندازه‌گیری مستقیم سطح آب زیرزمینی و وابستگی به داده‌های موجود چاه‌های پیزومتری می‌باشد. پراکندگی نامتوازن چاه‌ها در منطقه مورد مطالعه و فقدان داده در برخی نواحی می‌تواند بر دقت نمایش تغییرات مکانی افت سطح آب زیرزمینی و ارتباط آن با فرونشست تأثیرگذار باشد. بنابراین، نصب و توسعه شبکه پیزومترهای جدید، به‌ویژه در نواحی فاقد داده، و ثبت منظم و بلندمدت تغییرات سطح آب زیرزمینی می‌تواند در مطالعات آینده به افزایش کیفیت داده‌های ورودی و بهبود قابلیت پیش‌بینی مدل‌ها کمک کند.
- همچنین نتایج اعتبارسنجی مکانی (جدول ۳) نشان داد که استفاده از تقسیم‌بندی تصادفی استاندارد، عملکرد واقعی مدل‌ها در پیش‌بینی نقاط جدید و مستقل از نظر مکانی را به‌طور قابل‌توجهی خوش‌بینانه برآورد کرده است. مقادیر R^2 منفی حاصل از Spatial Block CV محدودیت مهمی در تعمیم‌پذیری مکانی نتایج ایجاد می‌کند و به‌کارگیری روش‌های Spatial/Block Cross-Validation به‌عنوان معیار اصلی (نه صرفاً مکمل) ارزیابی در مطالعات آتی این حوزه توصیه می‌شود.
- محدودیت دیگر به ماهیت ایستای بخشی از متغیرهای مورد استفاده در مدل مربوط می‌شود. برخی پارامترهای محیطی و 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. DOI: [10.5194/isprs-annals-X-4-W1-2022-129-2023](https://doi.org/10.5194/isprs-annals-X-4-W1-2022-129-2023)
- Yang, J., Kou, P., Dong, X., Xia, Y., Gu, Q., Tao, Y., Feng, J., Ji, Q., Wang, W., & Avtar, R. (2025). Reservoir water level decline accelerates ground subsidence: InSAR monitoring and machine learning prediction of surface deformation in the Three Gorges Reservoir area. *Frontiers in Earth Science*, 12, 1503634. DOI: [10.3389/feart.2024.1503634](https://doi.org/10.3389/feart.2024.1503634)
- Foroughnia, F., Nemati, S., Maghsoudi, Y., & Perissin, D. (2019). An iterative PS-InSAR method for the analysis of large spatio-temporal baseline data stacks for land subsidence estimation. *International Journal of Applied Earth Observation and Geoinformation*, 74, 248-258. <https://agris.fao.org/search/en/providers/122535/records/65dfdd6c0f3e94b9e5dd0621>
- Galloway, D. L., & Burbey, T. J. (2011). Regional land subsidence accompanying groundwater extraction. *Hydrogeology Journal*, 19(8), 1459-1486. DOI: [10.1007/s10040-011-0775-5](https://doi.org/10.1007/s10040-011-0775-5)
- Gambolati, G., & Teatini, P. (2015). Geomechanics of subsurface water withdrawal and injection. *Water Resources Research*, 51(6), 3922-3955. DOI: [10.1002/2014WR016841](https://doi.org/10.1002/2014WR016841)
- Haghshenas Haghighi, M., & Motagh, M. (2024). Uncovering the impacts of depleting aquifers: A remote sensing analysis of land subsidence in Iran. *Science*

- Advances, 10(19), eadk3039. <https://doi.org/10.1126/sciadv.adk3039>
- Chen, C., Peng, M., Motagh, M., Guo, X., Xing, M., & Quan, Y. (2024). Mapping Susceptibility and Risk of Land Subsidence by Integrating InSAR and Hybrid Machine Learning Models: A Case Study in Xi'an, China. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18, 3625-3639. DOI: [10.1109/JSTARS.2024.3522995](https://doi.org/10.1109/JSTARS.2024.3522995)
- Khalooei, F., & Elmizadeh, H. (2023). Monitoring the Subsidence of Kazerun Plain Using SENTINEL Images and Radar Interferometric Technique (DInSAR). *Engineering Geology*, 17(2), 169-186. DOI: [10.22034/JEG.2023.17.2.1019172](https://doi.org/10.22034/JEG.2023.17.2.1019172) (In Persian)
- Management of Exploitation of Groundwater Resources. (2019). Hydrogeological and balance report of Isfahan-Barkhar plain. Isfahan Municipality Parks and Green Space Organization. (In Persian)
- Mohammady, M., Pourghasemi, H. R., & Amiri, M. (2019). Land subsidence susceptibility assessment using random forest machine learning algorithm. *Environmental Earth Sciences*, 78(16), 503. DOI: [10.1007/s12665-019-8518-3](https://doi.org/10.1007/s12665-019-8518-3)
- Morsali, M., & Fattahian, Z. (2024). Hydrogeological analysis of land subsidence in Isfahan plain. In *Proceedings of the 5th Congress of Water and Wastewater Engineering Science*, Iran. <https://civilica.com/doc/2163380> (In Persian)
- Motagh, M., Walter, T. R., Sharifi, M. A., Fielding, E., Schenk, A., Anderssohn, J., & Zschau, J. (2008). Land subsidence in Iran caused by widespread water reservoir overexploitation. *Geophysical Research Letters*, 35(16). DOI: [10.1029/2008GL033814](https://doi.org/10.1029/2008GL033814)
- Roberts, D. R., Bahn, V., Ciuti, S., Boyce, M. S., Elith, J., Guillerá-Arroita, G., Hauenstein, S., Lahoz-Monfort, J. J., Schröder, B., Thuiller, W., Warton, D. I., Wintle, B. A., Hartig, F., & Dormann, C. F. (2017). Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, 40(8), 913-929. DOI: [10.1111/ecog.02881](https://doi.org/10.1111/ecog.02881)
- Salehi Moteahd, F., Hafezi Moghaddas, N., Lashkaripour, G., & Dehghani, M. (2019). Land Subsidence and its Consequences in Mashhad City by Integrating Radar Interferometry and Field Measurements. *Journal of Engineering Geology*, 13(3), 435-462. DOI: [10.18869/acadpub.jeg.13.3.435](https://doi.org/10.18869/acadpub.jeg.13.3.435) (In Persian)
- Shi, L., Gong, H., Chen, B., Shao, Z., & Zhou, C. (2025). Land subsidence simulation considering groundwater and compressible layers based on an improved machine learning method. *Journal of Hydrology*, 656, 133008. DOI: [10.1016/j.jhydrol.2025.133008](https://doi.org/10.1016/j.jhydrol.2025.133008)
- Shirani, K., & Pasandi, M. (2025). Land subsidence risk assessment and zoning in the watersheds of Isfahan Province using Persistent Scatterer InSAR (PSInSAR). *Watershed Engineering and Management*, 17(4), 534-552. DOI: [10.22092/ijwmse.2025.367922.2091](https://doi.org/10.22092/ijwmse.2025.367922.2091)