

# The Journal of Spatial Planning & Geomatics

Research Paper

## Spatio-Temporal Analysis and Modeling of Groundwater Variability in the Qahavand Plain for Land Subsidence Assessment Using Data Mining and Deep Learning Algorithms

Jalal Karami<sup>1\*</sup>, Fatemeh Babae<sup>2</sup>, Pouya Mahmoudnia<sup>3</sup>, Mohammad  
Sharifi Kia<sup>4</sup>

1. Assistant Professor in Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran.
2. Msc in Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran.
3. Msc in Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran.
4. Associate Professor in Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran.

Received: 2024/09/04  
Accepted: 2024/10/05

### ABSTRACT

The deficiency of surface water in arid and semi-arid territories has exacerbated the dependence on groundwater resources, resulting in considerable reductions in groundwater levels. This phenomenon has been particularly pronounced in numerous plains throughout Iran, where the diminution has exacerbated issues related to land subsidence. A comprehensive understanding of groundwater level variations is imperative for enhancing water management strategies and alleviating the associated hazards. A range of statistical, mathematical, and machine-learning methodologies have been utilized to model the dynamics of groundwater aquifers. Recently, deep neural network algorithms have gained prominence in the investigation of surface and groundwater resources, particularly in light of the spatiotemporal characteristics inherent to groundwater.

In the present investigation, a hybrid spatiotemporal data mining framework, denoted as Wavelet-PCA, was employed to analyze data acquired from 44 piezometric wells situated in the Qahavand plain over a span of three decades (1988-2018) for the purpose of elucidating temporal and spatial patterns associated with fluctuations in groundwater levels. Subsequently, a sophisticated deep recurrent neural network architecture incorporating Long Short-Term Memory (LSTM) was implemented to model the time series data resulting from the data mining procedure. Various degrees of wavelet transformation were applied to effectively capture the intricate trends in groundwater levels. The LSTM model exhibited a coefficient of determination ( $R^2$ ) of 0.85 for the training dataset while achieving an  $R^2$  of 0.62 for the testing dataset.

The research additionally examined regional patterns of land subsidence utilizing radar interferometry data obtained from the Sentinel-1 satellite during the period from 2014 to 2019. The results revealed an average maximum subsidence measurement of 9 centimeters, with the most pronounced subsidence noted in regions that are undergoing the most substantial declines in groundwater levels. This observed relationship between groundwater depletion and land subsidence underscores the necessity for judicious land use planning and the implementation of effective water resource management strategies in analogous regions.

### Keywords:

Spatiotemporal Data Mining, Groundwater Modeling, Land Subsidence, Deep Learning, Qahavand Plain.

\*Corresponding Author: Assistant Professor in Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran.

ORCID: 0000 0003 3831 2942

jl.karami@modares.ac.ir

**T****Extended Abstract  
Introduction**

The phenomenon of groundwater over-extraction constitutes an escalating issue in numerous arid regions, with particular emphasis on the Qahavand Plain of Iran, where the excessive abstraction for agricultural purposes has resulted in marked groundwater depletion and land subsidence. These challenges jeopardize the sustainability of water resources and agricultural viability, thereby posing substantial threats to both ecological integrity and economic stability. The objective of this research is to establish a comprehensive analytical framework to evaluate and forecast groundwater dynamics, employing a synergistic approach that incorporates advanced methodologies: Wavelet Transform, Principal Component Analysis (PCA), and Long Short-Term Memory (LSTM) neural networks. Through the integration of these techniques, the study aspires to yield critical insights that will facilitate sustainable water resource management in the Qahavand Plain, alongside other regions encountering analogous difficulties.

**Data and Method**

This research employs groundwater level data amassed over a protracted duration from wells situated in the Qahavand Plain. In order to process and scrutinize this data, a variety of sophisticated methodologies were utilized:

The Wavelet Transform was employed as a preprocessing mechanism to decompose groundwater level datasets into various frequency constituents. This methodology is advantageous for time-series data analysis, as it effectively distinguishes transient variations from enduring trends, thereby facilitating the recognition of significant patterns over temporal intervals. By mitigating high-frequency noise, this approach enhanced the ability to concentrate on the protracted trends of groundwater depletion, which are imperative for effective sustainable water resource management.

Subsequent to the decomposition of the data utilizing Wavelet Transform, Principal Component Analysis (PCA) was implemented to streamline the spatial data. PCA serves to diminish the intricacy of extensive datasets by converting them into a more compact collection of uncorrelated variables (principal components), which encapsulate the maximum variance within the data. This procedural phase facilitated the discernment of predominant spatial patterns associated with groundwater depletion throughout the Qahavand Plain, thereby elucidating the areas most adversely impacted by excessive extraction.

To forecast prospective groundwater levels, the investigation utilized Long Short-Term Memory (LSTM) neural networks, a specific category of recurrent neural networks (RNN) meticulously crafted for time-series prediction. LSTMs possess the capability to encapsulate both short-term and long-term dependencies, thereby rendering them particularly adept at forecasting groundwater trends utilizing historical data. The LSTM models underwent training on datasets that were processed via Wavelet Transform and Principal Component Analysis (PCA), facilitating both short-term and long-term predictive capabilities. This model of prediction is critical for the formulation of anticipatory water management strategies.

In addition to the examination of groundwater levels, the research also delved into the phenomenon of land subsidence within the Qahavand Plain through the utilization of Interferometric Synthetic Aperture Radar (InSAR) data. InSAR represents an advanced remote sensing methodology that quantifies terrestrial deformation with remarkable accuracy, thereby rendering it a potent instrument for monitoring subsidence resulting from the over-extraction of groundwater resources. Through the comparative analysis of InSAR data and groundwater levels, the investigation discerned regions where pronounced subsidence was intimately associated with elevated rates of groundwater depletion.

---

**Result & Discussion**

The integration of Wavelet Transform, PCA, and LSTM neural networks yielded valuable insights into groundwater dynamics in the Qahavand Plain.

Wavelet Transform effectively decomposed groundwater data, eliminating noise and facilitating the identification of long-term trends. Increased decomposition levels emphasized more substantial patterns of groundwater depletion. This method served as a crucial preprocessing step for illustrating the overall decline in groundwater levels, essential for comprehending the extent of over-extraction in the region.

PCA indicated that the initial two principal components explained the majority of variance in groundwater data, suggesting uniform depletion patterns. The first component represented general groundwater loss, while the second revealed specific variations linked to high agricultural intensity. As data uniformity increased with higher wavelet decomposition, key variations were predominantly represented by one principal component, showcasing PCA's efficacy in detecting significant spatial trends.

The LSTM models excelled in short-term groundwater level prediction, especially for the first principal component indicating significant variance. Nonetheless, they encountered difficulties with long-term forecasting, particularly at elevated wavelet decomposition levels. This indicates that while LSTM is proficient in short-term predictions, enhancing long-term forecasting necessitates additional refinements and the incorporation of factors like climate data, land use, and human activities. Enhancing the model's capacity for long-term groundwater trend prediction is essential for the development of effective water management strategies.

The InSAR data indicated a significant link between groundwater extraction and land subsidence. Areas experiencing the most groundwater depletion exhibited pronounced subsidence, especially in agricultural zones. Field surveys validated that over-extraction for irrigation primarily drives subsidence in the Qahavand Plain, highlighting the critical necessity for sustainable groundwater management to avert additional land degradation and safeguard agricultural output.

**Conclusion**

This research illustrates the efficacy of combining Wavelet Transform, PCA, and LSTM neural networks for groundwater dynamics analysis in the Qahavand Plain. This methodological integration facilitates the discernment of significant temporal and spatial patterns, noise reduction in intricate datasets, and precise short-term groundwater level forecasts. Nonetheless, the difficulties faced in long-term predictions underscore the necessity for model enhancements, including the incorporation of climate change data, land use trends, and anthropogenic factors to improve predictive accuracy.

The research highlights the significant correlation between groundwater withdrawal and land subsidence, as evidenced by InSAR analysis. These results illustrate the necessity of adopting sustainable groundwater management strategies to avert additional ecological harm, preserve agricultural land's sustainability, and reconcile water resource demands with conservation initiatives.

In summation, this investigation presents an extensive framework for tackling the issues of groundwater depletion and land subsidence in arid territories. The methodologies formulated in this research can be utilized in other areas encountering analogous challenges, providing essential instruments for policymakers and water resource administrators to render informed judgments regarding groundwater preservation and sustainable agricultural methodologies.

## تحلیل و مدل سازی تغییرات آب های زیرزمینی دشت قهاوند با استفاده از الگوریتم های داده کاوی مکانی و زمانی و یادگیری عمیق بمنظور ارتباط سنجی آن با مخاطره فرونشست

جلال کرمی<sup>۱\*</sup>، فاطمه بابایی<sup>۲</sup>، پویا محمود نیا<sup>۳</sup>، محمد شریفی کیا<sup>۴</sup>

۱. استادیار سنجش از دور و GIS، دانشگاه تربیت مدرس، تهران، ایران (نویسنده مسئول).
۲. کارشناسی ارشد سنجش از دور و GIS، دانشگاه تربیت مدرس، تهران، ایران.
۳. کارشناسی ارشد سنجش از دور و GIS، دانشگاه تربیت مدرس، تهران، ایران.
۴. دانشیار سنجش از دور و GIS، دانشگاه تربیت مدرس، تهران، ایران.

### چکیده

تاریخ دریافت: ۱۴۰۳/۰۶/۱۴

تاریخ پذیرش: ۱۴۰۳/۰۷/۱۴

در مناطق خشک و نیمه خشک، کمبود آب های سطحی منجر به برداشت بی رویه از آب های زیرزمینی و کاهش شدید سطح آب شده که در بسیاری از دشت های ایران به پدیده فرونشست زمین انجامیده است. درک تغییرات سطح آب زیرزمینی برای مدیریت بهینه منابع آبی و کاهش مخاطرات مرتبط اهمیت زیادی دارد. روش های مختلف آماری، ریاضی و یادگیری ماشین برای مدل سازی این تغییرات استفاده شده اند. اخیراً، شبکه های عصبی عمیق به ویژه برای تحلیل رفتار پیچیده آب های زیرزمینی، به دلیل ماهیت زمانی-مکانی آن ها، مورد توجه قرار گرفته اند. در این تحقیق، از مدل ترکیبی *Wavelet-Principal Component Analysis (PCA)* برای تحلیل داده های ۴۴ چاه پیرومتری دشت قهاوند طی دوره ۳۰ ساله (۱۳۹۷-۱۳۶۷) استفاده شده است. این مدل، الگوهای زمانی و مکانی تغییرات سطح آب زیرزمینی را در مقیاس های مختلف زمانی استخراج کرده و سپس مؤلفه های اصلی به دست آمده از *Wavelet-PCA* به مدل شبکه عصبی بازگشتی *Long Short Term Memory (LSTM)* ارائه شدند تا سری های زمانی سطح آب پیش بینی شود. سطوح مختلف تبدیل موجک برای شناسایی روندهای کوتاه مدت و بلندمدت به کار گرفته شد. مدل *LSTM* با دقت  $R^2 = 0.85$  برای گروه آموزشی و  $R^2 = 0.62$  برای داده های آزمایشی توانست روندهای سطح آب زیرزمینی را مدل سازی کند. همچنین، داده های راداری ماهواره *Sentinel-1* بین سال های ۲۰۱۴ تا ۲۰۱۹ نشان داد که بیشینه فرونشست زمین در مناطقی با افت قابل توجه سطح آب زیرزمینی رخ داده است. همپوشانی این نقشه ها با لایه های کاربری زمین، ارتباطی معنادار بین فعالیت های کشاورزی و افت سطح آب زیرزمینی و فرونشست زمین را نشان داد.

داده کاوی زمانی-مکانی، مدل سازی آب های زیرزمینی، فرونشست، یادگیری عمیق.

واژگان کلیدی:

### ۱. مقدمه

کمبود آب به ویژه در مناطق خشک و نیمه خشک، جائیکه که آب های سطحی محدود است، یک چالش جهانی است (Gleeson et al. 2012). این کمبود منابع، منجر به افزایش وابستگی به منابع آب زیرزمینی، و بدنبال آن، بهره برداری بیش از حد آن شده است (Wada et al. 2010). در ایران، کشوری که عمدتاً با آب و هوای خشک و نیمه خشک

تعریف می‌شود، کاهش آب‌های زیرزمینی به یک چالش اساسی و مهم تبدیل شده و بسیاری از دشت‌های ایران با کاهش قابل توجهی در سطح آب زیرزمینی و فرونشست زمین مواجه هستند (Motagh et al. 2008). مدیریت پایدار منابع آب زیرزمینی، نیاز به درک کامل رفتار آن و عوامل موثر بر تغییرات آنها در طول زمان و مکان دارد (Elshall et al. 2020b). رویکردهای سنتی مدل‌سازی آب‌های زیرزمینی، به روش‌های فیزیکی و آماری متکی بوده، به همین دلیل، این روش‌ها اغلب در تبیین روابط دینامیک پیچیده و غیرخطی سیستم‌های آب‌های زیرزمینی ناکارآمد هستند (Karami et al. 2014; Moosavi et al. 2013). الگوریتم‌هایی مانند روش‌های فیزیکی (مدل‌های مبتنی بر معادلات)، روش‌های آماری کلاسیک (مدل‌های رگرسیون خطی)، و روش‌های سری زمانی ساده مانند ARIMA، به دلیل محدودیت در تحلیل سیستم‌های غیرخطی و پویایی‌های پیچیده سیستم‌های آب زیرزمینی، نمی‌توانند به خوبی تعاملات پیچیده بین عوامل مختلف (مانند بارندگی، تبخیر، مصرف آب، و تغییرات کاربری زمین) را مدل‌سازی کنند. این روش‌ها عموماً به فرضیات ساده‌سازی شده نیاز دارند که ممکن است با واقعیت‌های پیچیده سیستم آب‌های زیرزمینی تطابق نداشته باشد. به همین دلیل، رویکردهای یادگیری ماشین و شبکه‌های عصبی، که توانایی بیشتری در مدل‌سازی روابط غیرخطی و استخراج الگوهای پیچیده دارند، جایگزین مناسبی برای این روش‌ها به شمار می‌روند. در سال‌های اخیر، الگوریتم‌های یادگیری ماشین و تکنیک‌های داده‌کاوی مکانی، به عنوان ابزاری قدرتمند در تجزیه و تحلیل و پیش‌بینی رفتار آب‌های زیرزمینی ظاهر شده‌اند. شبکه‌های عصبی مصنوعی ( $ANN^1$ ) بعنوان یکی از مولفه‌های یادگیری ماشین، به طور گسترده‌ای در مطالعات هیدرولوژی و مدیریت منابع آب (Maier and Dandy 2000; Rajaei et al. 2019) استفاده شده است. اخیراً، روش‌های یادگیری عمیق، به ویژه شبکه‌های حافظه کوتاه بلندمدت (LSTM)، در مدل‌سازی داده‌های سری زمانی آب‌های زیرزمینی با وابستگی‌های بلندمدت، قابلیت‌های بالایی از خود نشان داده است (Supreetha et al. 2020; Zhang et al. 2018). ادغام تکنیک‌های داده‌کاوی با مدل‌های یادگیری ماشین، توانایی استخراج الگوهای مهم از داده‌ها و اطلاعات پیچیده هیدرولوژیکی را افزایش داده است. به عنوان مثال، تبدیل موجک<sup>۲</sup>، به طور موثری برای تجزیه و تحلیل سری‌های زمانی داده‌های هیدرولوژیکی در مقیاس‌های زمانی مختلف استفاده شده و این تحلیل، امکان درک جامع‌تری از فرآیندهای اساسی پدیده‌های دینامیکی را می‌دهد (Nourani et al. 2014; Sanayei et al. 2021). از طرف دیگر، تجزیه و تحلیل مولفه‌های اصلی ( $PCA^3$ ) برای کاهش ابعاد و شناسایی الگوهای زمانی-مکانی کلیدی و مهم در داده‌های آب‌های زیرزمینی استفاده شده است (Machiwal and Jha 2015). در این بین، فناوری‌های سنسجش از دور بعنوان بخشی از این پازل، و بعنوان ابزاری مهم در پایش و نقشه‌برداری منابع زمینی، قابلیت‌های مهمی را برای مطالعات آب‌های زیرزمینی فراهم کرده‌اند. تکنیک‌های اینترفرومتری (InSAR) به‌ویژه، در اندازه‌گیری فرونشست زمین مرتبط با

<sup>1</sup> . Artificial Neural Networks

<sup>2</sup> . Wavelet Analysis

<sup>3</sup> . Principal Component Analysis

استخراج آب‌های زیرزمینی، نقش مهمی داشته است (Galloway and Burbey 2011). پرتاب ماهواره Sentinel-1، از سری ماهواره‌های Sentinel، با در دسترس قرار دادن داده‌های رادار با وضوح بالا، امکانات فوق‌العاده‌ای را در دسترس محققان علوم زمین قرار داده‌است. این داده‌ها امکان پایش تغییرات دقیق تغییر شکل زمین را امکان‌پذیر می‌کنند (Sowter et al. 2016). در پایان، رابطه بین کاربری زمین، به ویژه فعالیت‌های کشاورزی و کاهش آب‌های زیرزمینی در مطالعات زیادی و در مناطق مناطق مختلف به خوبی اثبات شده‌است (Konikow and Kendy 2005b). با این حال، تعاملات پیچیده بین کاربری زمین، استخراج آب‌های زیرزمینی و فرونشست زمین، به ویژه در محیط‌های خشک و نیمه خشک، نیاز به تحقیقات بیشتر دارد (Alley and Konikow 2015). هدف از این مطالعه رفع این شکاف تحقیقاتی با توسعه یک چارچوب جدید است که تبدیل موجک، PCA، شبکه‌های LSTM، داده‌های InSAR، و تصاویر لندست را برای تجزیه و تحلیل جامع دینامیک آب‌های زیرزمینی در دشت قهاوند ترکیب می‌کند. با ادغام این تکنیک‌های پیشرفته، این تحقیق به دنبال درک دقیق‌تر الگوهای زمانی و فضایی تغییرات آب‌های زیرزمینی، رابطه آنها با فرونشست زمین، و تأثیر کاربری زمین بر آن است. یافته‌های این تحقیق نتایج قابل توجهی برای مدیریت پایدار منابع آب در مناطق خشک و نیمه خشک دارد و نگرشی را ارائه می‌دهد که می‌تواند سیاست‌گذاری‌ها و استراتژی‌های حفاظت از منابع آب را بهینه کند. علاوه بر این، چارچوب روش‌شناسی توسعه یافته در این مطالعه به کاربرد علوم داده‌کاوی مکانی و تکنیک‌های یادگیری ماشین در هیدرولوژی و علوم زیست‌محیطی کمک می‌کند.

## ۲. مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

محدوده مطالعاتی رزن- قهاوند با مساحتی برابر با  $۱۶۵۷۶۰/۴$  هکتار و میانگین ارتفاع  $۱۷۳۱$  متر از سطح دریا در شمال شرقی استان همدان بین طول‌های شرقی  $۴۸^{\circ}۹۲'$  تا  $۴۹^{\circ}۲۷'$  و عرض‌های شمالی  $۳۴^{\circ}۷۴'$  تا  $۳۵^{\circ}۴۹'$  واقع شده است (زبرجدی و همکاران، ۱۳۹۳). این محدوده مطالعاتی یکی از دشت‌های حوزه آبریز قره‌چای است که وسعت حوزه آبریز آن  $۳۰۸۴$  کیلومتر مربع است. سطح گسترش سفره اصلی آب زیرزمینی (آبخوان) در این دشت  $۱۷۰۹$  کیلومتر مربع است. محدوده مطالعاتی مذکور دارای چهار ایستگاه باران‌سنجی خمیگان، زهتران، قهاوند و عمرآباد است که بر اساس متوسط میزان بارندگی در طی دوره‌های آماری مختلف در این ایستگاه‌ها، میزان متوسط بارندگی در این محدوده را می‌توان برابر  $۲۵۳/۸$  میلی‌متر در نظر گرفت. متوسط درجه حرارت منطقه با توجه به آمار سه ایستگاه اندازه‌گیری خمیگان، قهاوند و عمرآباد  $۱۱/۲$  تا  $۱۱/۶$  بوده است. تبخیر سالیانه از تشتک در طول دوره آماری  $۴۰$  ساله در ایستگاه خمیگان برابر  $۱۸۲۰$  میلی‌متر و در طول دوره آماری  $۲۰$  ساله در ایستگاه عمرآباد  $۲۳۴۷$  میلی‌متر و در طول دوره آماری  $۲۶$  ساله در ایستگاه قهاوند  $۱۸۴۶/۶$  میلی‌متر محاسبه شده است. در شکل ۱ موقعیت منطقه مورد مطالعه نشاد داده شده است.

## آمایش فضا و ژئوماتیک



شکل ۱. موقعیت دشت و چاه‌های پیزومتری قهاوند در استان همدان

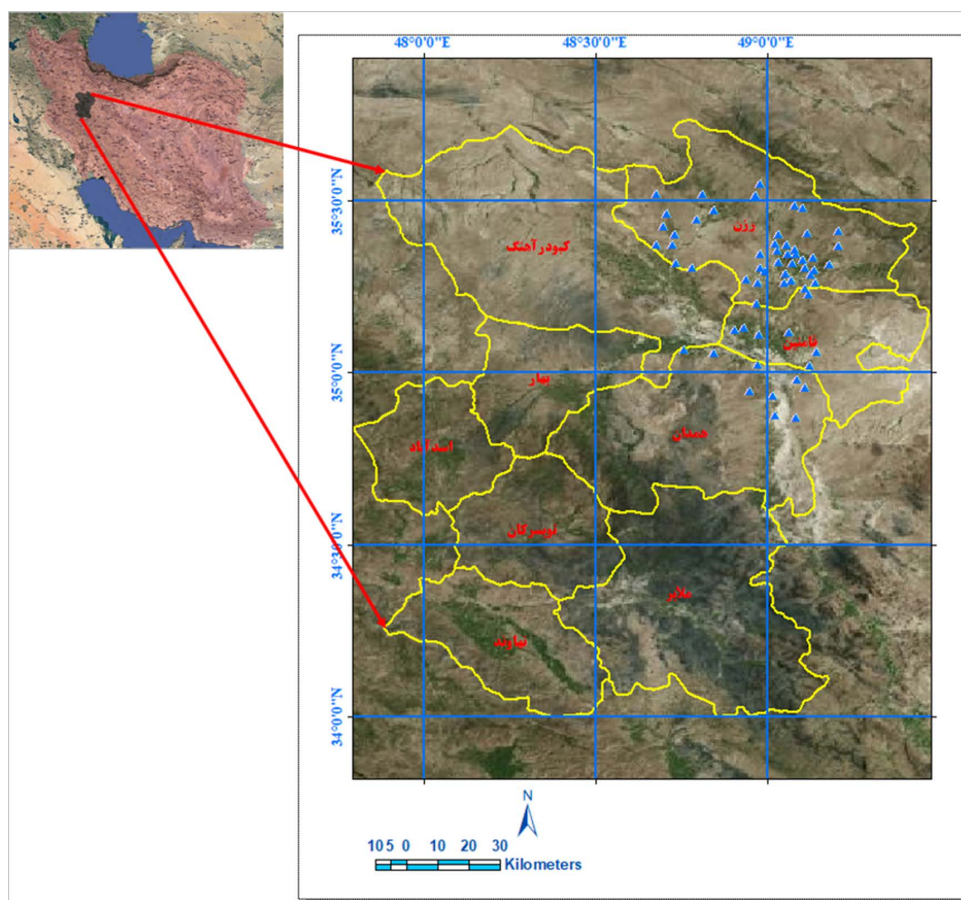


Figure 1. Location of the Qahavand Plain and piezometric wells in Hamadan Province

## ۲-۲- داده‌های مورد استفاده

به منظور تحلیل روند تغییرات زمانی-مکانی سطح آب‌های زیرزمینی دشت رزن-قهاوند، از تعداد ۴۴ چاه پیزومتری در سطح دشت استفاده شده است. چاه‌های پیزومتری را به منظور مطالعه نوسان‌های سطح آب زیرزمینی، تهیه نقشه‌های تراز آب و محاسبه حجم آب ورودی جانبی زیرزمینی و خروجی سفره، حفر می‌کنند. قطر این چاه‌ها جهت پایین آوردن هزینه حفر، کم انتخاب می‌شود (۶-۱۰ اینچ). آنچه که باید در مورد این چاه‌ها توجه داشت این است که می‌بایست آن‌ها را در سفره اصلی حفر کرده و با آزمایش‌های معمول و متداول، از ارتباط هیدرولیکی بین چاه و سفره مطمئن گردید. داده‌ها، متعلق به سازمان آب منطقه‌ای استان همدان است، که در بازه مهر ۱۳۶۷ تا اسفند ۱۳۹۷ (داده‌های بروزتر در دسترس نبودند) به صورت ماهانه برداشت شده‌اند. برای بارزسازی فرانشست منطقه، از تکنیک تداخل‌سنجی راداری با استفاده از داده‌های ماهواره‌ی Sentinel-1 در بازه زمانی دی ۱۳۹۳ تا بهمن ۱۳۹۸ استفاده شده است. در آخر هم نقشه کاربری اراضی به دلیل اینکه یکی از عوامل موثر در تحلیل تغییرات سطح آب زیرزمینی به شمار می‌رود، تهیه شد. در شکل شماره ۲ سری زمانی تغییرات آب‌های زیرزمینی دشت قهاوند از مهرماه ۶۷ تا مهر ۹۷ آورده شده است.

## آمایش فضا و ژئوماتیک

شکل ۲. روند تغییرات چاه‌های پیزومتری قهاوند استان همدان در یک دوره ۳۰ ساله

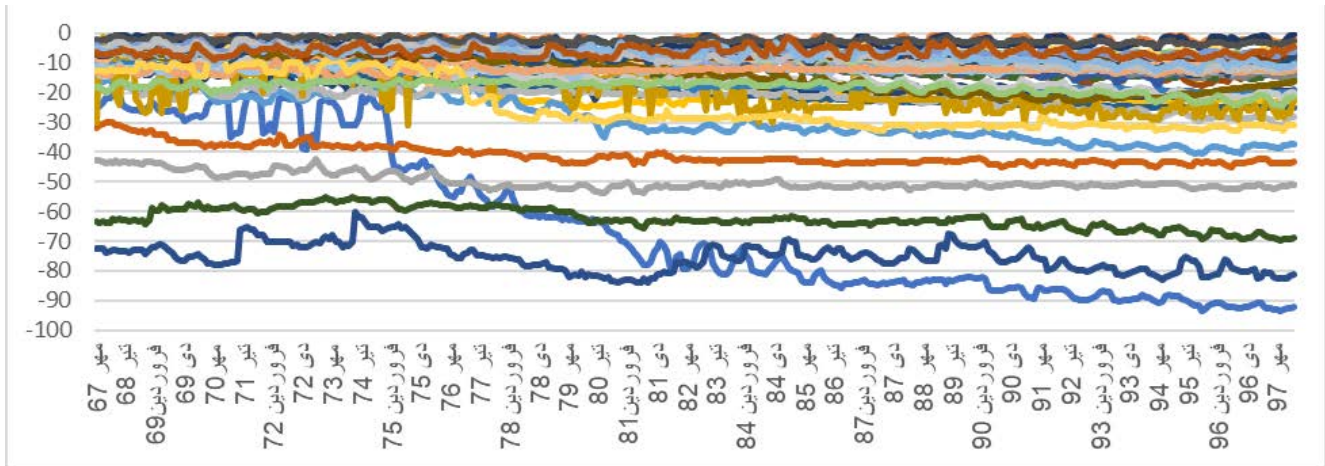


Figure 2. Trends in piezometric well changes in the Qahavand Plain, Hamadan Province, over 30 years

## ۲-۳- روش تحقیق

در این تحقیق، از روش‌های مختلف داده‌کاوی و مدل‌سازی به منظور تبیین روند تغییرات آب‌های زیرزمینی و پیش‌بینی آن‌ها و از تکنیک‌های سنجش‌ازدوری جهت بارزسازی فرونشست استفاده شده است. مدل مفهومی و فرایند اجرای این تحقیق در شکل ۳ آورده شده است.

شکل ۳. مدل مفهومی و فرایند انجام تحقیق

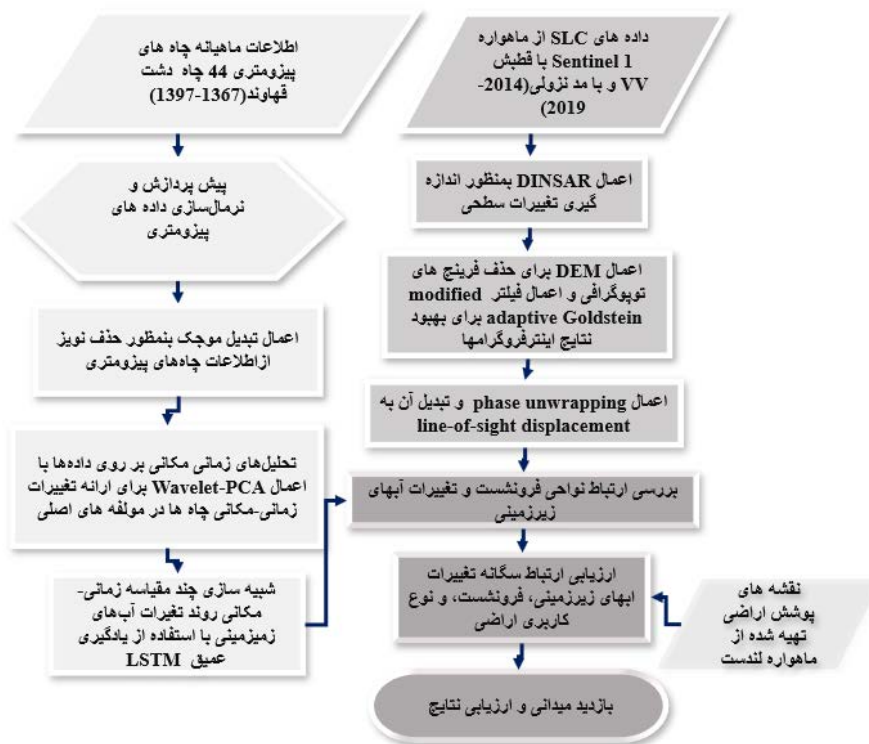


Figure 3. Conceptual Model and Research Process

## آمایش فضا و ژئوماتیک



## ۲-۳-۱- روش تحقیق

در این مطالعه از الگوریتم ترکیبی Wavelet-PCA برای استخراج الگوهای زمانی و مکانی از داده‌های سطح آب زیرزمینی استفاده شده است. این رویکرد، یک ترکیبی از نقاط قوت تبدیل موجک و تجزیه و تحلیل مؤلفه اصلی برای ارائه تجزیه چند مقیاسی سری‌های زمانی آب‌های زیرزمینی و در عین حال شناسایی الگوهای فضایی غالب است.

الف. تبدیل موجک

تبدیل موجک یک تکنیک ریاضی قدرتمند است که برای پردازش سیگنال و تحلیل فرکانسهای زمانی (مکانی) استفاده می‌شود (Daubechies 1992). این الگوریتم، یک سیگنال را به اجزای مقیاس مختلف تجزیه می‌کند و امکان تجزیه و تحلیل اطلاعات زمان و فرکانس را به طور همزمان فراهم می‌کند (Mallat 1989). بر خلاف تبدیل فوریه که فقط اطلاعات فرکانس را ارائه می‌کند، تبدیل موجک تجزیه و تحلیل محلی را در هر دو حوزه زمان و فرکانس ارائه می‌دهد (Torrence 1998). این ویژگی، این الگوریتم را به ویژه برای تجزیه و تحلیل سیگنال‌های غیر ثابت یا سیگنال‌هایی با ویژگی‌های گذرا مفید می‌کند. تبدیل موجک از مجموعه‌ای از توابع پایه به نام موجک استفاده می‌کند که هم در زمان و هم از نظر فرکانس محلی هستند. این موجک‌ها را می‌توان برای مطابقت با ویژگی‌های مختلف سیگنال در مقیاس‌ها و مکان‌های مختلف، مقیاس‌بندی و تغییر داد (Addison 2016). این قابلیت تجزیه و تحلیل با قدرت تفکیک چندگانه به تبدیل موجک اجازه می‌دهد تا هم جزئیات فرکانس بالا و هم تقریب‌های فرکانس پایین یک سیگنال را ثبت کند. در کاربردهایی مانند تجزیه و تحلیل سطح آب زیرزمینی، تبدیل موجک می‌تواند به شناسایی الگوهای دوره‌ای، روندها و ناهنجاری‌ها در مقیاس‌های زمانی مختلف کمک کند و بینش‌هایی را در مورد پویایی پیچیده سیستم‌های هیدرولوژیکی ارائه دهد (Nourani et al. 2014).

تبدیل موجک پیوسته (CWT) یک سیگنال را با هم ترکیب میکند و به شکل یک تابع موجک پیوسته تحلیل می‌کند. فرمول تبدیل موجک پیوسته یک سیگنال  $x(t)$  به صورت زیر است:

$$\text{CWT}x(a, b) = (1/\sqrt{a}) \int x(t) \psi^*(t-b/a) dt \quad (\text{فرمول ۱}) \quad (\text{Qiao et al., 2019})$$

در اینجا  $a$  پارامتر مقیاس که موجک را کشیده (گسترده) می‌کند،  $b$  پارامتر جابه‌جایی که موجک را در زمان منتقل می‌کند، و  $\psi(t)$  موجک مادر یا تابع موجک تحلیل‌گر است.

شکل ۴. طرح نمودار تبدیل موجک: (a) فرایند تجزیه، (b) فرایند بازسازی (Qiao et al. 2019)

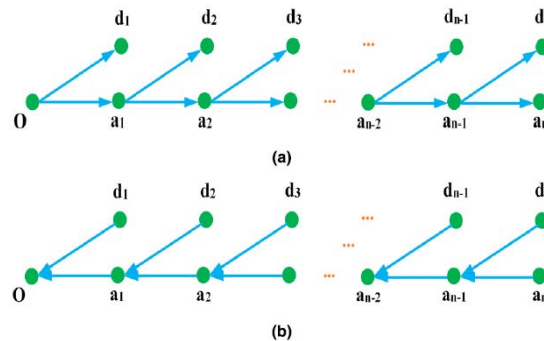


FIGURE 1. Diagrammatic sketch of wavelet transform: (a) decomposition process; (b) reconstruction process.

Figure 4. Wavelet Transform Diagram: (a) Decomposition Process, (b) Reconstruction Process (Qiao et al., 2019)

در این مقاله، از طیف توان موجک<sup>۱</sup> برای شناسایی دوره‌های غالب در نوسانات سطح آب زیرزمینی استفاده شده است. طیف موجک سراسری، که میانگین زمانی طیف توان موجک است، برای خلاصه کردن توزیع انرژی در مقیاس استفاده می‌شود.

برای استخراج مؤلفه‌های معنی‌دار از تجزیه موجک، از آزمون معناداری بر اساس فرضیه صفر نویز قرمز<sup>۲</sup> (فرایند تأخیر ۱ خود همبستگی) استفاده شده است. مولفه‌هایی با توان بالاتر از سطح اطمینان ۹۵ درصد معنی‌دار در نظر گرفته شدند (Torrence 1998). سری‌های زمانی سطح آب زیرزمینی برای هر یک از ۴۴ چاه پیزومتریک به صورت جداگانه تجزیه شد، که منجر به مجموعه‌ای از ضرایب موجک برای هر چاه در مقیاس‌های زمانی متعدد شد.

ب. تبدیل مولفه‌های اصلی

پس از تبدیل موجک، تجزیه و تحلیل مؤلفه اصلی (PCA) برای شناسایی الگوهای فضایی غالب تغییرات آب زیرزمینی استفاده شد. PCA یک تکنیک آماری چند متغیره است که ابعاد یک مجموعه داده را کاهش می‌دهد و در عین حال اطلاعات غالب آن را حفظ می‌کند (Jolliffe 2002; Karami et al. 2012). PCA بر روی ماتریس ضرایب موجک انجام شد، که در آن هر ردیف نشان دهنده یک چاه پیزومتریک و هر ستون نشان دهنده یک مرحله زمانی در مقیاس موجک خاص بود. داده‌ها ابتدا استاندارد شدند تا میانگین و واریانس واحد صفر داشته باشند تا از مقایسه بین چاه‌ها اطمینان حاصل شود. تبدیل PCA توسط  $Y = XW$  انجام شد که در آن  $X$  ماتریس داده استاندارد شده،  $W$  ماتریس بردارهای ویژه ماتریس کوواریانس، و  $Y$  ماتریس نمرات مؤلفه اصلی است (Abdi and Williams 2010). تعداد مؤلفه‌های اصلی مهم با استفاده از معیار کایزر (مقادیر ویژه بزرگتر از ۱) (Cattell 1966) تعیین شد. اجزای اصلی حفظ شده با استفاده از چرخش واریماکس چرخانده شدند تا قابلیت تفسیر را افزایش دهند (Kaiser 1958). وزنهای هر مؤلفه اصلی برای تبیین الگوهای فضایی تغییرپذیری آب‌های زیرزمینی مورد استفاده قرار گرفت.

نتایج حاصل از تجزیه و تحلیل موجک و PCA برای ارائه یک چارچوب جامع مکانی-زمانی دینامیک از آب‌های زیرزمینی ادغام شدند. طیف توان موجک سری‌های زمانی مؤلفه اصلی برای شناسایی تناوب‌های غالب در الگوهای فضایی محاسبه شد.

رویکرد Wavelet-PCA، امکان تجزیه چند مقیاسی سری زمانی آب‌های زیرزمینی را فراهم کرد و به طور همزمان الگوهای فضایی غالب نیز تعیین شد. با ترکیب این دو تکنیک، ویژگی‌های زمانی و مکانی دینامیک آب‌های زیرزمینی در دشت قهاوند استخراج شد و پایه اصلی برای مراحل مدل‌سازی و تحلیل بعدی را فراهم کرد.

در مجموع، ترکیب روش‌های Wavelet و PCA به دلیل توانایی‌های مکمل این دو روش در استخراج الگوهای زمانی و مکانی به کار گرفته شده است. تبدیل موجک (Wavelet) قادر است داده‌های سری زمانی پیچیده مانند سطح آب زیرزمینی را در مقیاس‌های مختلف زمانی تجزیه و تحلیل کند و روندهای پنهان در دوره‌های زمانی کوتاه و بلند را آشکار سازد. از طرفی، تحلیل مؤلفه‌های اصلی (PCA) ابزاری قدرتمند برای کاهش ابعاد داده‌ها و تحلیل وابستگی‌های

<sup>۱</sup> . Wavelet Power Spectrum

<sup>۲</sup> . The Null Hypothesis of Red Noise

مکانی است که با حفظ بیشترین واریانس ممکن، مؤلفه‌های اصلی را استخراج می‌کند. با ترکیب این دو روش، الگوهای چندمقیاسی و مهم داده‌ها به شکلی ساده‌تر و مؤثرتر به دست می‌آید که می‌تواند به دقت بالاتر در مدل‌سازی و تحلیل کمک کند.

### ۲-۳-۲- شبکه‌های عصبی عمیق حافظه کوتاه مدت بلند (LSTM)

در این مقاله شبکه‌های LSTM، بعنوان نوع خاصی از شبکه‌های عصبی بازگشتی ( $RNN^1$ )، برای مدل‌سازی زمانی پیچیده سطح آب‌های زیرزمینی استفاده شدند. LSTM به دلیل توانایی آنها در درک وابستگی‌های بلندمدت در داده‌های سری زمانی، بویژه برای این نوع از مدل‌سازی‌ها مناسب هستند (Hochreiter and Schmidhuber 1997).

معماری LSTM از سلول‌های حافظه با سه نوع گیت تشکیل شده است: ورودی، فراموشی و خروجی. این گیت‌ها جریان اطلاعات را از طریق سلول، کنترل می‌کنند و به شبکه اجازه می‌دهند تا اطلاعات را به‌طور انتخابی در طول توالی‌های طولانی به خاطر بسپارد یا فراموش کند (Gers et al. 2000).

شکل ۵. ساختار شبکه LSTM

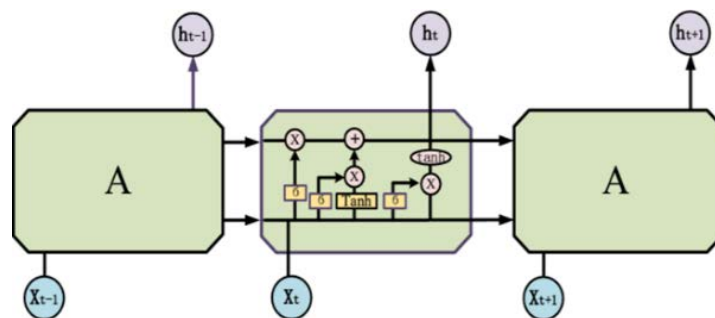


Figure 5. Structure of the LSTM Network

معماری مدل LSTM مورد استفاده در این مقاله، از چندین لایه LSTM متراکم تشکیل شده است. معماری خاص به شرح زیر است:

۱. لایه ورودی، ۲. لایه LSTM (۶۴ نرون)، ۳. لایه حذفی (نرخ = ۰.۲)، ۴. لایه LSTM (۳۲ نرون)، ۵. لایه حذفی (نرخ = ۰.۲)، ۶. لایه متراکم (۱۶ نرون)، ۷. لایه متراکم. این معماری بر اساس آزمایش‌های گسترده انتخاب شد و شبیه معماری‌هایی بود که در پیش‌بینی سری‌های زمانی هیدرولوژیکی موفق بوده‌اند (Kratzert et al. 2018).

قبل از انجام مدل‌سازی، داده‌ها در محدوده ۰ تا ۱ نرمال شده‌اند، چون شبکه‌های LSTM به مقیاس داده‌های ورودی حساس هستند؛ به ویژه زمانی که از توابع فعال‌سازی sigmoid یا tanh استفاده می‌شود. به‌طور پیش‌فرض تابع فعال‌سازی سیگموئید برای بلوک‌های LSTM استفاده شده است. این شبکه برای ۱۰۰ دوره تکرار، آموزش داده شد و بعد از پایداری نسبی آن، ارزیابی مدل در مجموعه داده‌های آموزش و تست محاسبه شد. ورودی مدل برآیند نتیجه Wavelet-PCA برای مؤلفه‌های اول و دوم و با چهار تاخیر زمانی و خروجی مدل هم داده‌های زمان حال بود. جهت

<sup>1</sup> Recurrent Neural Networks

ارزیابی مدل LSTM، ابتدا داده‌ها به دو مجموعه داده آموزشی و آزمایشی تقسیم شدند. به دلیل اهمیت ترتیب مقادیر، در داده‌های سری زمانی، به ترتیب ۶۷٪ از مشاهدات برای آموزش مدل و ۳۳٪ باقی مانده برای چک و ارزیابی مدل استفاده شده است. در این پژوهش از دو معیار ریشه میانگین مربع خطا (RMSE) و ضریب تعیین (R2) به منظور بررسی کمی دقت مدل بهره برده شده است. مدل LSTM با استفاده از کتابخانه Keras با هسته TensorFlow اجرا شد. این مدل با استفاده از بهینه‌ساز آدام با نرخ یادگیری اولیه ۰.۰۰۱ تعریف شد. از سنجه میانگین مربعات خطا (MSE) به عنوان تابع هزینه و از ضریب تعیین (R<sup>2</sup>) بعنوان کارآمدی مدل استفاده شد (Xiang et al. 2020). این معیارها برای مجموعه داده‌های آموزشی و آزمایشی برای ارزیابی قابلیت تعمیم مدل محاسبه شدند (Kratzert et al. 2018).

### ۲-۳-۲- تداخل سنجشی راداری

رادار روزنه مصنوعی تداخل سنج (DInSAR) یک ابزار قدرتمند برای ایجاد مدل‌های رقومی ارتفاع در سطح زمین و تصویربرداری از جابه‌جایی‌های مرتبط با تغییر ساختارهای پوسته‌ای در مقیاس سانتی‌متر در طول زمان است (درویشی و احمدی توانا، ۱۳۹۲). در این روش، با استفاده از زوج تصویر راداری، یک ایتترفروگرام تهیه می‌شود و پس از طی یک سری مراحل که شامل رفع ابهام است، مدل ارتفاعی متناظر با Interferogram ایجاد می‌شود (شاه حسین و همکاران، ۱۳۸۸).

در این تحقیق، از داده‌های SAR از ماهواره Sentinel-1 وابسته به آژانس فضایی اروپا (ESA) استفاده شده است. Sentinel-1 داده‌های SAR باند C (طول موج ۵.۶ سانتی‌متر) را با یک بازه زمانی ۱۲ روزه برداشت می‌کند و قدرت تفکیک زمانی بالایی را برای نظارت بر تغییر شکل زمین ارائه می‌دهد (Schmidt et al. 2018). از تصاویر Single Look Complex (SLC) منطقه مورد مطالعه برای سال‌های ۲۰۱۴ تا ۲۰۱۹ استفاده شده است (جدول ۱). در این پژوهش، جهت بررسی نرخ و دامنه فرونشست، از تکنیک تداخل سنجی تفاضلی راداری استفاده شده و از ابزار DInSAR در نرم افزار SARscape 5.4.1 برای پردازش داده‌ها در این بخش استفاده شده است. در جدول شماره ۱، داده‌های رادار به‌مراه تاریخ مربوطه آورده شده است

جدول ۱. جفت‌های تداخل سنجی برای داده‌های Sentinel-1A و پارامترهای مرتبط با آنها، از جمله Bn (خط مبنای عمود)، Bcr (زاویه بحرانی)، Bt

(خط مبنای زمانی)،  $\theta$  (زاویه بروز)

Pairs	Master Date (Y/mm/dd)	Slave Date (Y/mm/dd)	Bn (Meter)	Bcr (Meter)	Bt Day	$\theta$
۱	۲۵/۱۰/۲۰۱۴	۱۳/۱۱/۲۰۱۵	۱۰۵.۶۶	۵۴۱۷.۳۹	۳۸۴	۳۹.۱۹
۲	۱۳/۱۱/۲۰۱۵	۱۴/۱۰/۲۰۱۶	۶.۰۲	۵۴۲۵.۴۴	۳۳۶	۳۹.۲۲
۳	۱۴/۱۰/۲۰۱۶	۰۲/۱۱/۲۰۱۷	۳۳.۸۳	۵۴۲۵.۷۳	۳۸۴	۳۹.۲۲
۴	۰۲/۱۱/۲۰۱۷	۲۱/۱۱/۲۰۱۸	۲۷.۰۴	۵۴۲۵.۶۳	۳۸۴	۳۹.۲۲
۵	۲۱/۱۱/۲۰۱۸	۱۶/۱۱/۲۰۱۹	۴۷.۸۰	۵۴۲۵.۴۴	۳۶۰	۳۹.۲۲

**Table 1.** Interferometric Pairs for Sentinel-1A Data and Related Parameters, Including Bn (perpendicular baseline), Bcr (Critical Angle), Bt (Temporal Baseline),  $\theta$  (Incidence Angle)

## ۳. نتایج

## ۳-۱- تبدیل موجک

نمودارهای ارائه شده در شکل ۶، یک تجزیه چند سطحی موجک از داده‌های پیزومتریک را نشان می‌دهد که سیگنال اصلی و تقریب‌های آن در مقیاس‌های مختلف (سطح‌های ۲، ۴، ۶ و ۸) را به تصویر می‌کشد. پنل بالایی، داده‌های اصلی را به رنگ قرمز نشان می‌دهد که با نوسانات پیچیده و تنوع در چاه‌های مختلف در طول زمان مشخص می‌شود. با حرکت به پایین از سطوح تقریب، شاهد یک نرم‌سازی تدریجی از سیگنال هستیم، که اجزای فرکانس بالاتر فیلتر می‌شوند.

شکل ۶. مقایسه تقریب‌ها از سیگنال‌های اصلی در سطوح ۲ تا ۸




Figure 6. Comparison of Approximations from Original Signals at Levels 2 to 8



در سطح ۲، بخش زیادی از جزئیات اصلی حفظ شده است، اما کاهش نويز نیز مشهود است. سطوح ۴ و ۶ نمایش‌های نرم‌تر را نشان می‌دهند که روندهای متوسط تا بلندمدت را برجسته می‌کنند، در حالی که نوسانات کوتاه‌مدت را کاهش می‌دهد. تقریب سطح ۸، اصلی‌ترین روندهای فرکانس پایین در داده‌ها را آشکار می‌کند، که به وضوح الگوهای کلی نزولی در برخی چاه‌ها را نشان می‌دهد.

این تحلیل چندمقیاسی، سیگنال پیزومتریک را به مقیاس‌های زمانی مختلف تقسیم می‌کند، که امکان شناسایی روندهای اصلی، الگوهای فصلی و رفتارهای بلندمدت در سطح آب زیرزمینی را فراهم می‌کند. چنین تجزیه‌ای به ویژه برای درک عوامل مختلف مؤثر بر دینامیک آب زیرزمینی، از تأثیرات کوتاه‌مدت مانند رویدادهای بارندگی تا اثرات بلندمدت مانند تغییرات آب و هوا یا استخراج پایدار آب زیرزمینی مفید است.

### ۳-۱-۱- حذف نويز

نمودارهای ارائه شده در شکل ۷ یک تحلیل حذف نويز چند سطحی موجک از داده‌های پیزومتریک از مهر ۶۷ تا اسفند ۹۷ را نشان می‌دهد. ستون سمت چپ، داده‌های حذف نويز شده در سطوح مختلف (اصلی، سطح ۲، ۴، ۶ و ۸) را نشان داده، در حالی که ستون سمت راست، باقی مانده (نويز) مربوطه را نمایش می‌دهد. نمودارهای داده‌های حذف نويز شده (سمت چپ)، یک اثر هموارسازی تدریجی را با افزایش سطح تجزیه نشان می‌دهند. داده‌های اصلی و سطوح پایین‌تر، نوسانات فرکانس بالاتر بیشتری را حفظ می‌کنند، در حالیکه سطوح بالاتر (۶ و ۸) روندهای بلندمدت واضح‌تری را نشان می‌دهند. این هموارسازی در شناسایی الگوهای زیربنایی و روندهای کلی در سطح آب زیرزمینی در طول زمان کمک می‌کند.

نمودارهای باقیمانده (سمت راست)، تفاوت بین سیگنال اصلی و تقریب حذف نويز شده در هر سطح را نشان می‌دهند. با افزایش سطح تجزیه، اطلاعات پیزومتری، ساختارمندتر و کمتر تصادفی می‌شوند، که نشان می‌دهد سطوح بالاتر کلیات بنیادی بیشتری از سیگنال را دربر می‌گیرند.

این رویکرد حذف نويز موجک، یک تحلیل چند مقیاسی از داده‌های پیزومتریک را امکان‌پذیر می‌کند، که محققان را قادر می‌سازد مقیاس‌های زمانی مختلف تغییرات سطح آب زیرزمینی را جدا کنند. این می‌تواند در تمایز بین نوسانات کوتاه‌مدت (احتمالاً به دلیل اثرات فصلی یا اختلالات محلی) و روندهای بلندمدت (که ممکن است نشان دهنده تغییرات پایدارتر در شرایط آب زیرزمینی، مانند کاهش کلی یا الگوهای شارژ مجدد) کمک کند.

شکل ۷. نمودارهای سمت چپ (آبی) داده‌های نویز زدایی شده را نشان می‌دهد درحالی‌که نمودارهای سمت راست (سیاه) باقیمانده نویزها را برای داده‌های دشت قهاوند نشان می‌دهد.

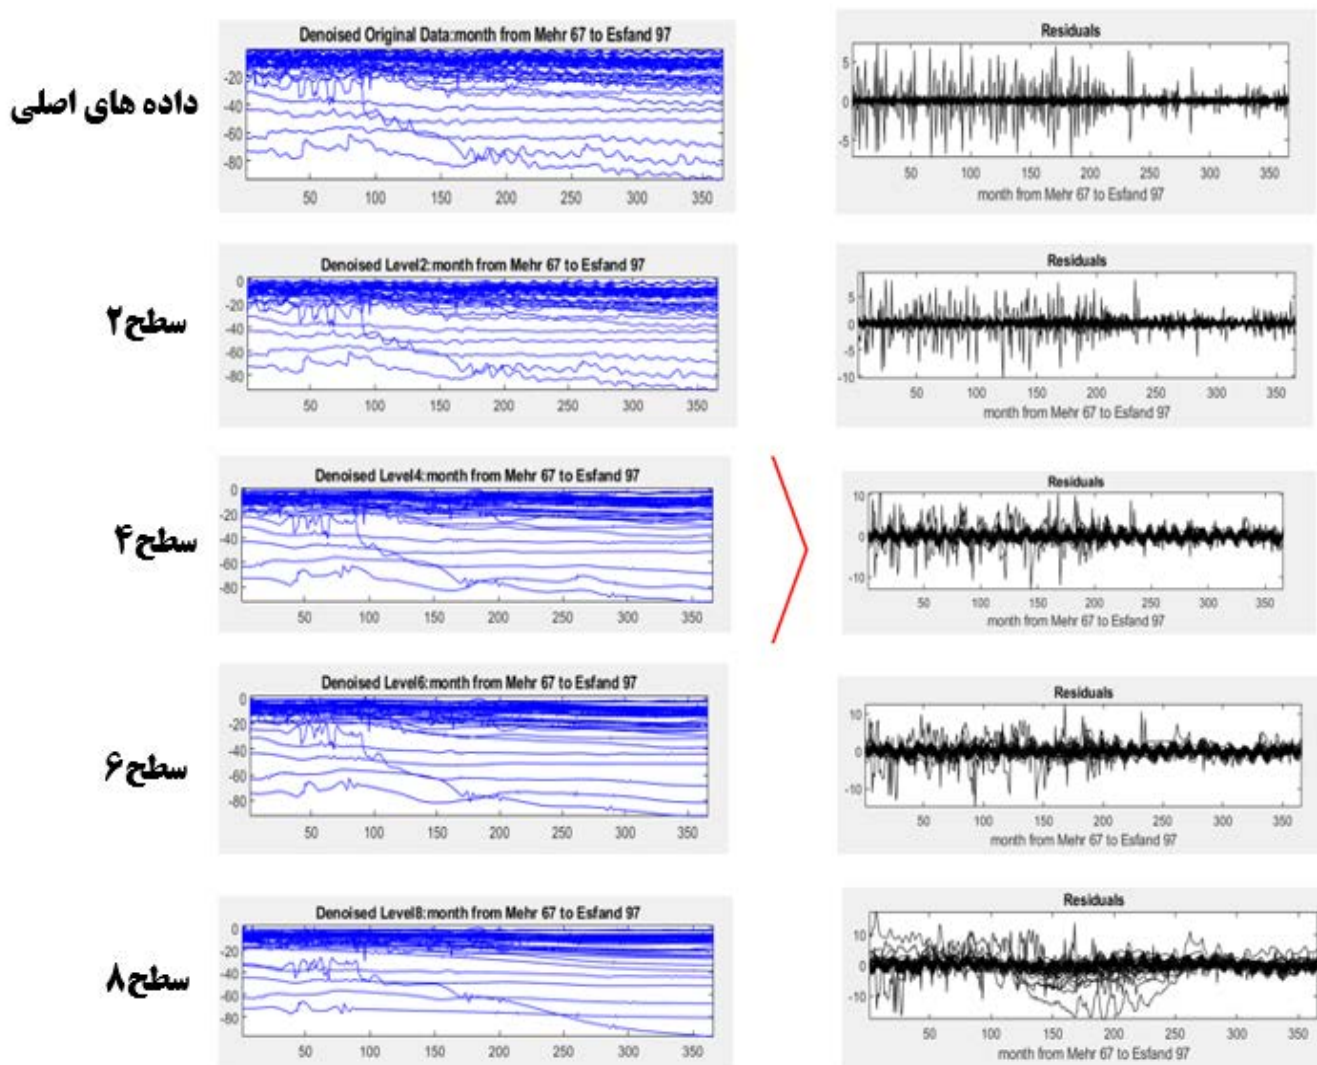


Figure 7. The Left Graphs (Blue) Show Denoised Data, While the Right Graphs (Black) Represent Noise Residuals for the Qahavand Plain Data

### ۲-۳- تحلیل مولفه‌های اصلی

در شکل ۸، نتایج کمی حاصل از اعمال الگوریتم PCA به همراه چرخش Varimax بر سطوح معین تبدیل موجک جهت به دست آوردن میزان همبستگی داده‌ها در سطوح مختلف قابل مشاهده است. در تمامی سطوح، بیشترین مقدار واریانس در دو مؤلفه اول قرار گرفته است، از این رو دو مؤلفه اول در هر سطح به عنوان نماینده تمام داده‌های دشت در آن سطح است.

### آمایش فضا و ژئوماتیک

در تمامی سطوح، روند داده‌ها بسیار شبیه به یکدیگر بوده و اکثر چاه‌ها در هر دو مؤلفه قرار دارند، اما در نهایت هر چاه متعلق به مؤلفه‌ای است که همبستگی بیشتری با آن داشته باشد. هر چه سطوح بالاتر می‌رود شباهت داده‌ها نیز به دلیل حذف جزئیات بیشتر می‌شود، در نتیجه واریانس در مؤلفه اول افزایش پیدا می‌کند. در نهایت در سطح ۸ تمامی چاه‌ها یا همان سیگنال‌ها در یک مؤلفه قرار گرفته‌اند. قابل ذکر است که بیشتر سیگنال‌ها در اکثر سطوح در یک مؤلفه ثابت هستند.

شکل ۸. مقدار واریانس در مؤلفه اول بر اساس سطوح موجک




Figure 8. Variance in the First Component Based on Wavelet Levels

با توجه به نمودارهای اشکال ۹، ۱۰، ۱۱، و ۱۲، دیده می‌شود که هرچه به سمت سطوح بالاتر از تبدیل موجک می‌رویم، روند سراسری تغییرات آب زیرزمینی بهتر و گویاتر می‌شود. همچنین مقدار واریانس (اطلاعات) به سمت مؤلفه اول متمرکزتر می‌شود.

شکل ۹. دو مؤلفه اول در سطح دو




Figure 9. First Two Components at Level Two

شکل ۱۰. دو مولفه اول در سطح چهار



Figure 10. First Two Components at Level Four

شکل ۱۱. دو مولفه اول در سطح شش




Figure 11. First Two Components at Level Sixth

شکل ۱۲. دو مولفه اول در سطح هشت




Figure 12. First Two Components at Level twelve

آمایش فضا و ژئوماتیک

درونیابی روند افت سطح آب‌ها در داده‌های تمامی سطوح تبدیل موجک (۲، ۴، ۶ و ۸) در نقشه‌های شکل ۱۳ آورده شده است. در فرایند درونیابی، مقادیر مؤلفه اول و دوم استخراج شده از تحلیل Wavelet-PCA برای هر یک از چاه‌های پیژومتری در سطوح مختلف زمانی استفاده شدند. هدف از درونیابی این بود که توزیع مکانی دقیق‌تری از تغییرات سطح آب زیرزمینی در دشت قهاوند به دست آید. با استفاده از مقادیر مولفه‌های اصلی، الگوهای زمانی و مکانی که بیشترین واریانس داده‌ها را توضیح می‌دهند، در فضا و زمان منتشر شده و نواحی فاقد داده با استفاده از اطلاعات چاه‌های موجود به صورت پیوسته مدل‌سازی شدند. این فرآیند به شبیه‌سازی و درک بهتر از الگوهای افت سطح آب زیرزمینی در کل دشت کمک می‌کند و نتایج دقیق‌تری برای تحلیل روندهای تغییرات سطح آب زیرزمینی ارائه می‌دهد.

شکل ۱۳-۵ میانگین افت سطح آب‌های زیرزمینی دشت رزن-قهاوند را نشان می‌دهد؛ به عبارتی این نقشه میانگینی از نقشه‌های ۱، ۲، ۳، ۴ در شکل ۱۳ است که نشان دهنده مقدار افت بر اساس داده‌های سطوح مختلف است. در تمامی خروجی‌ها بیشترین مقدار افت در بخش مرکزی و جنوب شرق دشت رخ داده است. همچنین افت سطح آب‌های زیرزمینی در قسمت‌های شرق، شمال شرق و شمال غرب با شدت کم‌تری ادامه پیدا کرده است.

شکل ۱۳-۱، ۲، ۳ و ۴ به ترتیب نشان‌دهنده میانگین افت سطح آب زیرزمینی در سطوح ۲، ۴، ۶ و ۸ از تبدیل موجک بوده و نقشه شماره ۵ میانگین افت سطح آب زیرزمینی چهار نقشه اول است

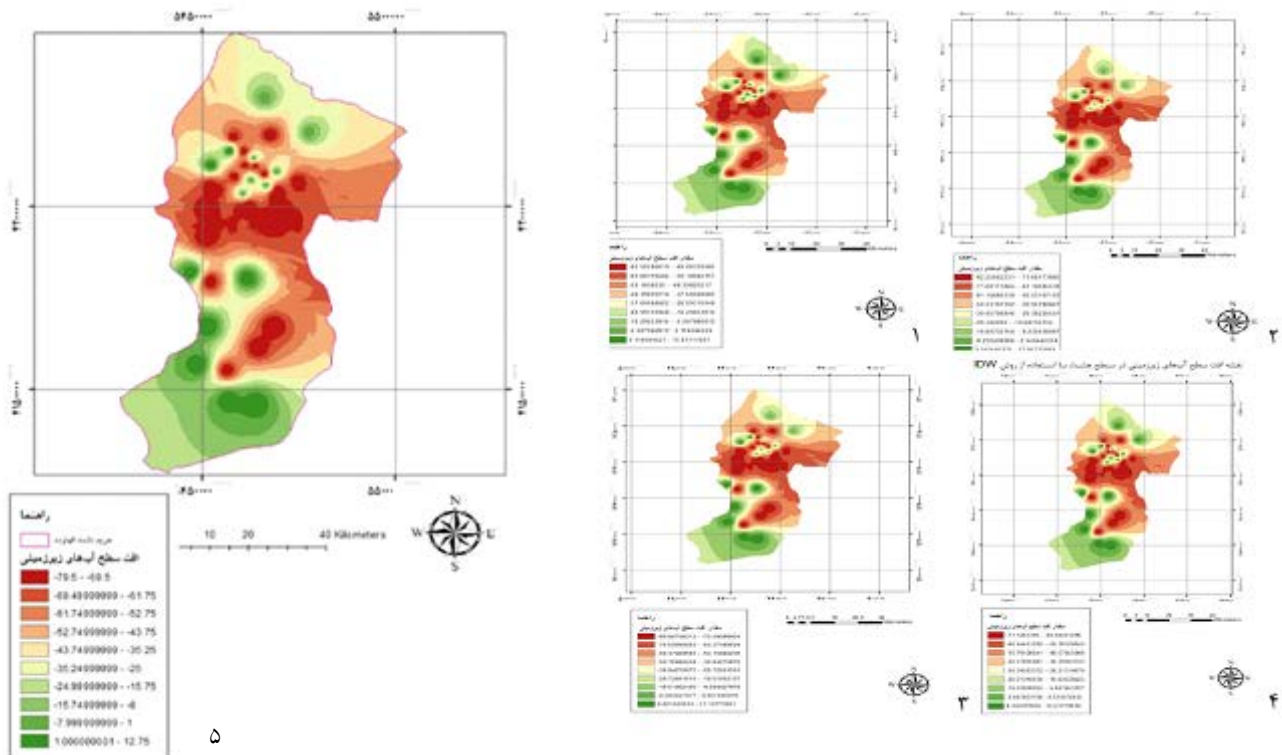


Figure 13. 1, 2, 3, and 4 Represent the Average Groundwater Level Decline at Levels 2, 4, 6, and 8 from the Wavelet Transform, While Figure 5 Shows the Average Groundwater Level Decline of the First Four Maps



### ۳-۳- خود همبستگی جزئی

به دست آوردن گام‌های زمانی بعنوان ورودی مدل، یکی از مراحل آماده‌سازی داده‌ها برای مدل‌سازی است. در مسائل وابسته به زمان، هر رخدادی، نمونه‌ای از مشاهدات است که وابستگی زمانی به مراحل زمانی قبلی خواهد داشت؛ به عبارتی، متغیرهای مشاهده شده همان ویژگی‌ها هستند. در این پژوهش، جهت به دست آوردن گام‌های زمانی، از نرم افزار متلب و تابع خود همبستگی جزئی<sup>۱</sup> با انحراف معیار ۴ و تا ۲۰ گام استفاده شد. در برخی از مسائل دنباله‌دار ممکن است هر نمونه به تعداد گام‌های زمانی متفاوتی از خود وابسته باشد (شکل ۱۴)؛ از این رو تابع خود همبستگی برای دو مؤلفه‌ی اول در تمامی سطوح محاسبه و نتایج کمی آن در جدول ۲ ارائه شد.

شکل ۱۴. پنجره سری زمانی برای پیش‌بینی روند آینده




Figure 14. Time Series Window for Forecasting Future Trends

جدول ۲. گام‌های زمانی موثر در داده‌های سطوح مختلف

مؤلفه دوم	مؤلفه اول	PC/Level
2 Lag	3 Lag	سطح اول
3 Lag	2 Lag	سطح دوم
3 Lag	2 Lag	سطح سوم
2 Lag	3 Lag	سطح چهارم


Table 2. Effective Time Steps in Data at Different Level

<sup>1</sup>. Partial Autocorrelation

### ۳-۴ LSTM برای رگرسیون با گام‌های زمانی


در سری‌های زمانی می‌توان مراحل زمانی قبلی ( $X_{t-1}, X_{t-2}, \dots$ ) را به عنوان ورودی برای پیش‌بینی خروجی در مرحله بعدی ( $x_t$ ) استفاده کرد. در اینجا نیز ورودی‌های مدل، سطح آب زیرزمینی در ماه‌های قبل یا همان گام‌های زمانی هستند که تعداد گام‌ها برای هر سطح و هر مؤلفه متفاوت است.

شکل ۱۵، ۱۷، ۱۶، ۱۸ و ۱۹، خروجی‌های شبکه LSTM در غالب نمودار را ارائه کرده‌اند. نمودار آبی بعنوان داده واقعی، قسمت نارنجی بخش آموزشی، و قسمت سبز بخش ارزیابی مدل را نمایش می‌دهند. می‌توان پیش‌بینی‌هایی که با استفاده از مدل برای مجموعه داده‌های آموزش و ارزیابی ایجاد شده را در نمودارهای اشکال ۱۵، ۱۶، ۱۷، و ۱۸ دید. شکل ۱۵. خروجی مدل‌سازی الگوریتم LSTM برای دو مؤلفه اول PCA در سطح دو (نمودار آبی بعنوان داده واقعی، قسمت نارنجی بخش آموزشی و قسمت سبز بخش ارزیابی مدل را نمایش می‌دهند)



**Figure 15.** Output of the LSTM Algorithm Modeling for the First Two PCA Components at Level Two (The Blue Curve Represents Actual Data, the Orange Section Represents Training Data and the Green Section Represents Model Evaluation)


شکل ۱۶. خروجی مدل‌سازی الگوریتم LSTM برای دو مؤلفه اول PCA در سطح چهار (نمودار آبی بعنوان داده واقعی، قسمت نارنجی بخش آموزشی و قسمت سبز بخش ارزیابی مدل را نمایش می‌دهند)



**Figure 16.** Output of the LSTM Algorithm Modeling for the First Two PCA Components at Level Four (The Blue Curve Represents Actual Data, the Orange Section Represents Training Data and the Green Section Represents Model Evaluation)


## آمایش فضا و ژئوماتیک

شکل ۱۷. خروجی مدل‌سازی الگوریتم LSTM برای دو مؤلفه اول PCA در سطح شش (نمودار آبی بعنوان داده واقعی، قسمت نارنجی بخش آموزشی و قسمت سبز بخش ارزیابی مدل را نمایش می‌دهند)



**Figure 17.** Output of the LSTM Algorithm Modeling for the First Two PCA Components at Level Six (The Blue Curve Represents Actual Data, the Orange Section Represents Training Data, and the Green Section Represents Model Evaluation)

شکل ۱۸. خروجی مدل‌سازی الگوریتم LSTM برای دو مؤلفه اول PCA در سطح هشت (نمودار آبی بعنوان داده واقعی، قسمت نارنجی بخش آموزشی و قسمت سبز بخش ارزیابی مدل را نمایش می‌دهند)



**Figure 18.** Output of the LSTM Algorithm Modeling for the First Two PCA Components at Level Eight (The Blue Curve Represents Actual Data, the Orange Section Represents Training Data, and the Green Section Represents Model Evaluation)

در جدول ۳ نتایج کمی حاصل از عملکرد مدل آموزش دیده شده بر روی مجموعه داده‌های آموزشی و ارزیابی آورده شده است.

جدول ۳- ضریب تعیین و خطای مدل‌سازی برای سطوح مختلف و مؤلفه‌های ۱ و ۲

PC2				PC1				
RMSE		R <sup>2</sup>		RMSE		R <sup>2</sup>		
آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش	
۲,۸۶	۱,۱۶	۰,۸۲	۰,۹۱	۲,۴۲	۱,۹۴	۰,۹۹	۰,۸۶	سطح ۲
۲,۵۶	۰,۳۳	۰,۸۵	۰,۹۸	۲,۵۲	۳,۱۳	۰,۹۹	۰,۵۸	سطح ۴
۲,۳	۰,۲۳	۰,۸۶	۰,۹۹	۲,۵۴	۳,۲	۰,۹۹	۰,۴۷	سطح ۶
۳,۳۹	۰,۴۰	۰,۲۰	-۰,۰۸	۲,۴۶	۴,۱۵	۰,۹۸	۰,۵۷	سطح ۸

**Table 3.** Coefficient of Determination and Modeling Error for Different Levels and Components 1 and 2

با توجه به جدول ۳، این مدل قابلیت پیش‌بینی کوتاه مدت قوی را به خصوص برای PC1 نشان می‌دهد. عملکرد آن برای پیش‌بینی‌های بلندمدت کاهش می‌یابد، به ویژه برای سطح ۸، تفاوت قابل توجهی بین نتایج آموزش و تست وجود دارد که این اختلاف، به خصوص در سطوح بالاتر بیشتر است. در سطح ۸، نتایج مدل‌سازی برای PC2 با کاهش شدید دقت مواجه شده است، به طوری که مقدار  $R^2$  به  $-0.08$  رسیده است. این افت می‌تواند به دلیل افزایش پیچیدگی و نویز در مقیاس‌های زمانی بزرگ‌تر باشد که در سطح ۸ توسط تبدیل موجک استخراج شده‌اند. در سطوح بالاتر، مولفه‌های اصلی (PC2) ممکن است الگوهای کم‌اهمیت‌تر یا نویزی را در داده‌ها نشان دهند که تأثیر کمتری بر رفتار کلی سیستم دارند. به همین دلیل، مدل LSTM توانایی کمتری در یادگیری و پیش‌بینی دقیق این مولفه‌ها در سطوح زمانی بالاتر پیدا می‌کند، زیرا داده‌ها کمتر قابل پیش‌بینی و بیشتر تحت تأثیر نوسانات تصادفی و عوامل غیرقابل توضیح هستند. در یک جمع بندی، مدل LSTM پتانسیل خوبی را برای پیش‌بینی کوتاه‌مدت سطح آب زیرزمینی، به ویژه برای مؤلفه اول (PC1) نشان می‌دهد. با این حال، دقت آن برای پیش‌بینی‌های بلندمدت کاهش می‌یابد، و شرایط برای بهبود تعمیم داده‌های آزمایشی، به ویژه برای افق‌های پیش‌بینی گسترده، وجود دارد. اصلاح مدل یا مهندسی ویژگی‌ها برای افزایش قابلیت‌های پیش‌بینی بلندمدت ضروری است.

### ۳-۳- تداخل سنجی تفاضلی راداری

خروجی‌های تداخل سنجی تفاضلی راداری بیانگر این مسئله است که طی زمان‌های ۲۰۱۴/۱۰/۲۵ تا ۲۰۱۹/۱۱/۱۶ بیشترین مقدار فرونشست با مقدار ۱۴ سانتی‌متر متعلق به سال ۲۰۱۴-۲۰۱۵ است. در این سال (شکل ۱۹-۱) بیشترین نشست در قسمت غرب دشت اتفاق افتاده و به سمت جنوب مقدار آن کاهش پیدا می‌کند. در سال ۲۰۱۵-۲۰۱۶ (شکل ۱۹-۲) مقدار نشست در غرب نسبت به سال قبل کمتر شده اما همچنان مقدار آن بالا است. به مرور فرونشست در کل قسمت جنوبی دشت با شدت‌های مختلف گسترش پیدا کرده است، به گونه‌ای که در سال ۲۰۱۶-۲۰۱۷ (شکل ۱۹-۳) یک نقطه مشخص با افت شدید وجود ندارد. لازم به ذکر است که در این سال، قسمت غربی دشت کمترین مقدار فرونشست را دارد. مجدداً در سال ۲۰۱۷-۲۰۱۸ (شکل ۱۹-۴) نقطه غربی دشت، بیشترین میزان نشست را به خود اختصاص داده است. در این سال، بیشترین مقدار نشست در بخش مرکزی دشت ایجاد و تا جنوب غرب کشیده شده اما در قسمت جنوب و جنوب شرق، میزان نشست نسبت به سال‌های قبل کمتر بوده است. در سال ۲۰۱۸-۲۰۱۹ (شکل ۱۹-۵) بیشترین مقدار نشست در قسمت جنوبی دشت اتفاق افتاده و در قسمت جنوب شرق مقدار نشست نسبت به سال‌های قبل افزایش یافته است. بخش مرکزی در این سال، جز در چند نقطه، کمترین مقدار نشست طی سال‌های مورد بررسی را داشته است. به عبارتی نشست در بخش غربی دشت اتفاق افتاده و طی سال‌های بعد در بقیه بخش‌های دشت گسترش پیدا کرده است.

شکل ۱۹- نقشه‌های فرونشست به دست آمده از تکنیک تداخل‌سنجی راداری در سال‌های ۱ (۲۰۱۴-۲۰۱۵)، ۲ (۲۰۱۵-۲۰۱۶)، ۳ (۲۰۱۶-۲۰۱۷)، ۴ (۲۰۱۷-۲۰۱۸)، ۵ (۲۰۱۸-۲۰۱۹)

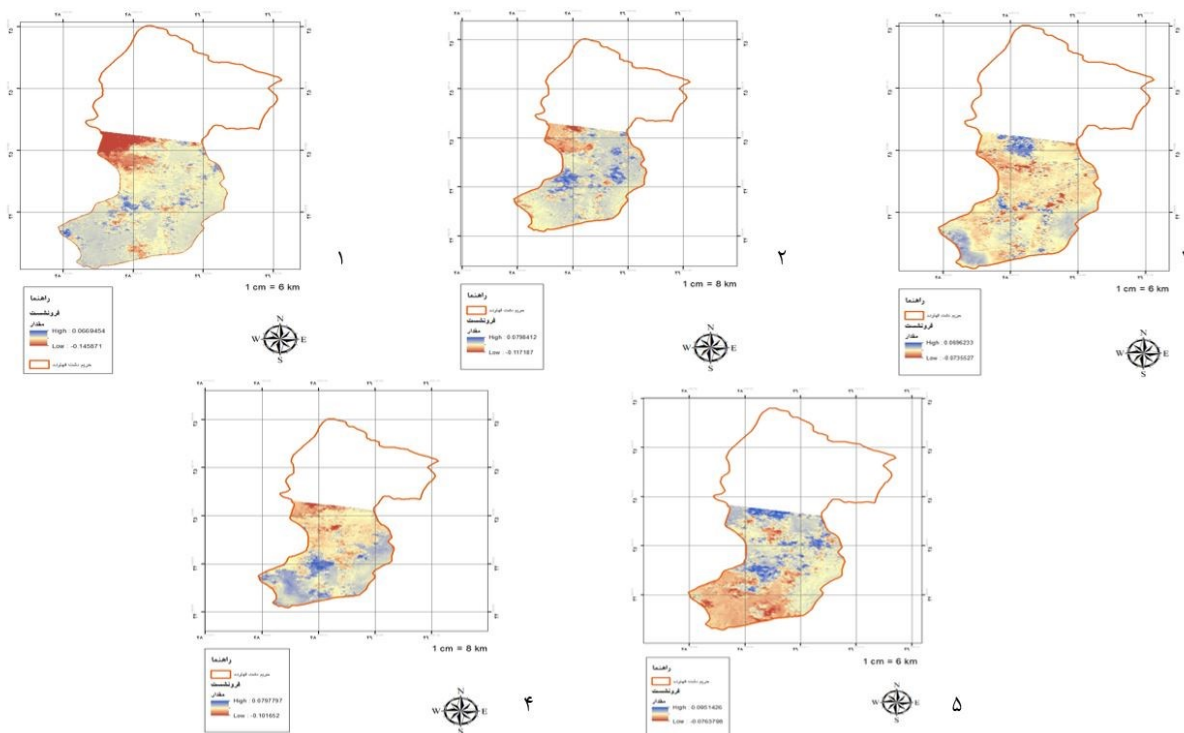


Figure 19. Subsidence Maps Obtained from Radar Interferometry Technique for Years 1 (2014-2015), 2 (2015-2016), 3 (2016-2017), 4 (2017-2018), and 5 (2018-2019)


در جدول شماره ۴، مقدار حداکثر فرونشست برای سال‌های ۲۰۱۴ تا ۲۰۱۹ به تفکیک و در مجموع آورده شده است. همچنانکه دیده میشود، بیشترین مقدار مربوط به دوره زمانی ۲۰۱۵-۲۰۱۶ است. جدول ۴: حداکثر نشست در سال‌های مورد مطالعه

سال	فرونشست سالیانه (cm)
۲۰۱۵-۲۰۱۴	۱۴
۲۰۱۶-۲۰۱۵	۱۱
۲۰۱۷-۲۰۱۶	۷
۲۰۱۸-۲۰۱۷	۱۰
۲۰۱۹-۲۰۱۸	۷
مجموع	۴۹

Table 4. Maximum Subsidence in the Study Years



شکل ۲۰. نقطه پیمایشی ۱



شکل ۲۱. نقطه پیمایشی ۲



Figure 21. Survey Point 2

پس از تکمیل فرایند پردازش داده‌ها، بررسی‌های میدانی نتایج انجام شد. در نقطه پیمایشی ۱ (شکل ۲۰) ایجاد فروچاله با توجه به نوع خاک (رسی ماسه‌ای) تا حدودی امری طبیعی است اما عامل تشدید کننده این رخداد عظیم چاه‌های عمیق اطراف آن است. جنس خاک در نقطه پیمایشی ۲ (شکل ۲۱) لومی ماسه‌ای است. عامل این رخداد، متلاشی شدن ناشی از فرسودگی، تحت تاثیر چاه‌های عمیق بوده است. بر خلاف نقطه ۱ که چاه‌های عمیق عامل اصلی نبوده بلکه تشدید کننده بوده است، در این رخداد چاه‌های عمیق عامل اصلی هستند. اطراف فروچاله گیاه خارشتر روئیده که به دلیل ریشه عمیق آن، نشانه وجود آب زیرزمینی در گذشته است. هر دو نقطه متعلق به غرب دشت قهاوند هستند، بخشی که بیشترین فرونشست و افت آب در آن اتفاق افتاده است.

### ۳-۶- بررسی فرونشست و افت سطح آب‌های زیرزمینی با نوع کاربری‌های اراضی

هدف از بررسی نوع کاربری‌ها در دشت قهاوند، یافتن ارتباط بین آن‌ها با روند افت سطح آب‌های زیرزمینی و نشست زمین است. ۷۲ درصد از اراضی دشت قهاوند برای کشاورزی استفاده می‌شود؛ به عبارتی عمده کاربری این دشت در بخش کشاورزی است. در جدول ۵، و شکل شماره ۲۲، مساحت هر کاربری به همراه درصد تحت پوشش آن، در این دشت آمده است.

جدول ۵. مساحت کاربری‌های مختلف در دشت قهاوند

پوشش زمین	مساحت (Km2)	درصد مساحت (%)
کشاورزی	۳۲۷۴	۷۲,۶
گیاهان علفی	۹۳۷	۲۰,۷
پوشش گیاهی تنک	۲۳۸	۵,۳
نواحی شهری/روستایی	۴۰	۰,۸۸
درختچه	۲۳	۰,۵۱
پهنه های آبی	۰,۲۶	۰,۰۰۵۹
نواحی جنگلی تنک	۰,۰۳۹	۰,۰۰۰۹

Table 5. Area of Various Land Uses in the Qahavand Plain

شکل ۲۲. سهم کاربری‌های مختلف در دشت قهاوند




Figure 22. Percent of Various Land Uses in the Qahavand Plain

در نقشه میانگین افت سطح ایستابی (شکل ۲۳-۲) چندین نقطه داغ<sup>۱</sup> وجود دارد که اکثر آنها متناظر با کاربری کشاورزی است و تعدادی نیز بر روی کاربری گیاهان علفی واقع شده‌اند. همچنین با هم‌نهادسازی نقشه میانگین فرونشست (شکل ۲۳-۳) و کاربری (شکل ۲۳-۱) این مهم حاصل شد که اکثر نقاط با نشست زیاد در کاربری کشاورزی و مقداری در کاربری گیاهان علفی واقع شده‌اند.

شکل ۲۳. نقشه ۱ (کاربری اراضی)، نقشه ۲ (میانگین افت سطح آب زیرزمینی از سال ۶۷ الی ۹۷)، نقشه ۳ (میانگین فرونشست از سال ۹۳ الی ۹۸)

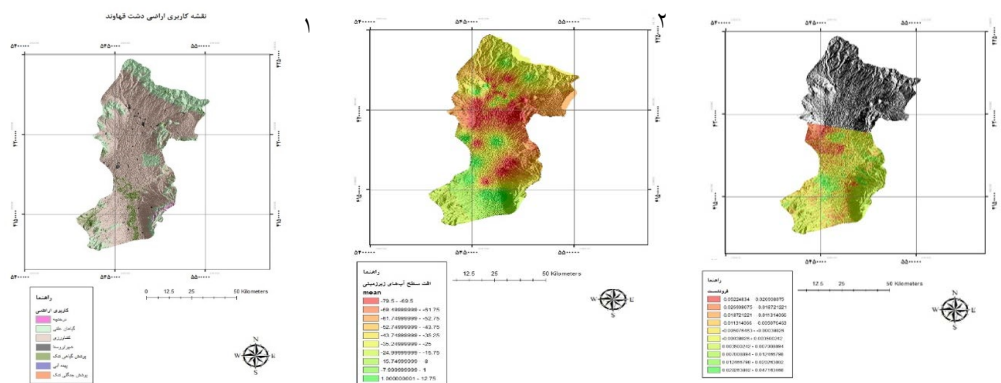


Figure 23. Map 1 (Land Use), Map 2 (Average Groundwater Level Decline from 1988 to 2018), Map 3 (Average Subsidence from 2014 to 2019)

<sup>1</sup> . Hot Spot

## ۴. بحث

در این مطالعه تلفیق آنالیز Wavelet-PCA با مدل‌سازی LSTM، چارچوبی جامع برای درک و پیش‌بینی دینامیک آب‌های زیرزمینی در دشت قهاوند فراهم کرده است. این رویکرد به ماهیت پیچیده و غیرخطی سیستم‌های آب زیرزمینی اشاره دارد و در عین حال الگوهای مکانی و زمانی را تبیین می‌کند.

در الگوریتم داده‌کاوی Wavelet-PCA، ابتدا داده‌های سری زمانی سطح آب زیرزمینی چاه‌های پیژومتری با استفاده از تبدیل موجک (Wavelet) در مقیاس‌های مختلف زمانی تجزیه و تحلیل شدند. این فرآیند امکان شناسایی روندهای مختلف در بازه‌های زمانی کوتاه و بلندمدت را فراهم کرد. تبدیل موجک کمک کرد تا نوسانات و تغییرات سطح آب زیرزمینی در سطوح مختلف زمانی به صورت جداگانه بررسی و درک شود. برای مثال، روندهای کوتاه‌مدت می‌توانند تغییرات فصلی یا سالانه ناشی از بارندگی و مصرف آب را نشان دهند، در حالی که روندهای بلندمدت ممکن است منعکس‌کننده تأثیرات طولانی‌مدت مانند تغییرات آب و هوایی یا افت تدریجی سطح آب زیرزمینی در طول سال‌ها باشند.

پس از تبدیل موجک، از تحلیل مؤلفه‌های اصلی (PCA) برای کاهش ابعاد داده‌ها و استخراج مؤلفه‌های اصلی استفاده شد. هدف از این کار، کاهش پیچیدگی داده‌ها و حفظ بیشترین واریانس موجود در سیستم بود. دو مؤلفه اصلی اول (PC1 و PC2) که بیشترین سهم از واریانس را توضیح می‌دادند، استخراج شدند. این مؤلفه‌ها نشان‌دهنده الگوهای اصلی و پنهان تغییرات آب زیرزمینی در دشت قهاوند بودند. PC1 عمدتاً نمایانگر روندهای کلی و جامع‌تر بود که بر روی مقیاس‌های زمانی طولانی‌تر تأثیرگذار است، در حالی که PC2 تغییرات جزئی‌تر و نوسانات محلی‌تر را در بازه‌های کوتاه‌تر زمانی به تصویر می‌کشد. این نتایج به ما امکان داد تا تغییرات سطح آب زیرزمینی را در مقیاس‌های مختلف زمانی به طور دقیق‌تر شناسایی کنیم و سپس این مؤلفه‌های اصلی به‌عنوان ورودی مدل LSTM برای پیش‌بینی سری‌های زمانی سطح آب زیرزمینی استفاده شدند. نتایج حاصل از این تحلیل نشان داد که روش Wavelet-PCA به خوبی توانسته است الگوهای زمانی و مکانی پیچیده را از داده‌های سطح آب زیرزمینی استخراج کند، که منجر به بهبود دقت مدل‌سازی و پیش‌بینی رفتار سیستم آب زیرزمینی در دشت قهاوند شد.

تجزیه و تحلیل Wavelet-PCA الگوهای زمانی چند مقیاسی را در نوسانات آب زیرزمینی نشان داد و نتایج این مطالعه مشابه یافته‌های نورانی و همکاران در بررسی نوسانات سطح آب زیرزمینی در اتیوبی بود. با این حال، روش مورد استفاده در این تحقیق، ادغام الگوهای فضایی از طریق PCA بود و درک جامع‌تری از پویایی سیستم ارائه داد (Nourani et al. 2013). شناسایی الگوهای فضایی از طریق PCA می‌تواند تلاش‌های حفاظتی هدفمند با تمرکز بر مناطقی که بیشترین روند کاهش را نشان می‌دهند، ارائه دهد. این روش با توصیه‌های الشال و همکاران برای مدیریت پایدار آب‌های زیرزمینی که تنوع فضایی را در نظر می‌گیرد مطابقت دارد (Elshall et al. 2020a).

کارآمدی مدل LSTM در نتایج پیش‌بینی سطح آب‌های زیرزمینی با  $R^2$  0.99 برای مجموعه آموزشی و ۰.۶۲ برای مجموعه آزمایشی ارائه شد. این نتایج با نتایج مطالعات مشابه قابل مقایسه است و در برخی موارد از آنها نیز بهتر بود.

این نتایج همانند نتایجی است که توسط فرمانی فرد و همکاران به دست آمده است (Farmanifard et al. 2023). همچنین نتایج حاصل از مدل‌سازی با LSTM نشان داد که این نوع شبکه‌ها ضریب همبستگی بالایی را ارائه می‌دهند که این نتیجه با تحقیق چو و همکاران تطابق دارد (Chu et al. 2022). همچنین، ژانگ و همکاران (Zhang et al. 2018) به  $R^2 0.97$  برای پیش‌بینی سطح آب زیرزمینی نیز با استفاده از LSTM در مناطق کشاورزی دست یافتند (Zhang et al. 2018). دقت بالای مدل LSTM در این مطالعه، پتانسیل آن را به عنوان یک ابزار ارزشمند برای مدیران منابع آب در پیش‌بینی تغییرات کوتاه‌مدت سطح آب زیرزمینی نشان می‌دهد. این می‌تواند به توسعه استراتژی‌های مدیریت فعال، به ویژه در مناطق کشاورزی که تقاضا برای آب‌های زیرزمینی بالا است، کمک کند.

تجزیه و تحلیل ما از فرونشست زمین با استفاده از داده‌های InSAR، که میانگین حداکثر فرونشست ۹ سانتی‌متر را نشان می‌دهد، با یافته‌های سایر مناطق خشک سازگار است. متق و همکاران (Motagh et al. 2008) نرخ فرونشست مشابهی را در بخش‌هایی از ایران مرکزی به دلیل بهره‌برداری بیش از حد از آب‌های زیرزمینی گزارش کردند (Motagh et al. 2008). این امر بر نیاز فوری به استفاده پایدار از آب‌های زیرزمینی برای کاهش خطرات فرونشست زمین تأکید می‌کند. همچنین دهقان سورکی برای تعیین نرخ دامنه و فرونشست زمین در دشت مرند (Mohammad et al. 2011) و پاپی جهت تحلیل سری زمانی فرونشست زمین برای دشت شهریار (رامین و همکاران، ۱۳۹۹) از تکنیک تداخل‌سنجی راداری استفاده کرده‌اند. این نتایج با نتایج به دست آمده از پژوهش‌های قربانی محمدآبادی (Sedigheh et al. 2023) و احمدی (Ahmadi 2018) برای دشت قهاوند تطابق دارد. بررسی پژوهش‌های انجام شده در دیگر دشت‌های استان بیانگر شرایط مشابه آن‌ها با دشت قهاوند است. به طور مثال، امینی و مستوفی در سال ۱۴۰۱ طی پژوهشی که برای دشت کبودرآهنگ انجام دادند، به این نتیجه رسیدند که افت سطح آب‌های زیرزمینی ناشی از چاه‌های کشاورزی از دلایل مهم ایجاد فرونشست در این دشت بوده است (امینی و مستوفی، ۱۴۰۱). رجبی و همکاران در سال ۱۴۰۱ پژوهشی جهت ارزیابی و پتانسیل‌سنجی فرونشست در دشت بهار انجام داده‌اند و در آن افت سطح آب‌های زیرزمینی و کشاورزی را مهم‌ترین عامل فرونشست در نظر گرفته‌اند (رجبی و همکاران، ۱۴۰۱).

رابطه مشاهده شده بین فعالیت‌های کشاورزی و کاهش آب زیرزمینی با روندهای جهانی شناسایی شده توسط کونیکو و کندی (Konikow and Kendy 2005a) مطابقت دارد. با این حال، مطالعه حاضر، تجزیه و تحلیل دقیق‌تر و محلی‌شده‌تری از این رابطه ارائه کرد و اهمیت استراتژی‌های مدیریتی محلی را برجسته کرد. در پایش میدانی طی مصاحبه با کشاورزان منطقه، این مهم حاصل شد که تمامی کشاورزان از چاه‌های اطراف زمین کشاورزی جهت آبیاری استفاده می‌کنند. از سویی با برهم‌نهاد نقشه افت سطح آب‌های زیرزمینی با کاربری اراضی و فرونشست، این نتیجه حاصل شد که بیشترین میزان فرونشست و افت آب در منطقه، منطبق بر اراضی کشاورزی بوده است. به عبارتی عامل اصلی فرونشست منطقه، افت شدید منابع آب زیرزمینی بر اثر توسعه اراضی کشاورزی بوده است. بنابراین می‌توان گفت که توسعه اراضی کشاورزی و استفاده بیش از حد از منابع آب زیرزمینی، دلیل اصلی وقوع فرونشست در منطقه بوده است.

## ۵. نتیجه‌گیری

در حالیکه مدل این تحقیق، عملکرد بالایی را نشان می‌دهد، مهم است که توجه داشته باشیم که  $R^2$  پایین‌تر برای مجموعه آزمایشی (۰,۶۲) در مقایسه با مجموعه آموزشی (۰,۸۵) نشان‌دهنده درجه‌ای از برازش پایین است. تحقیقات آینده می‌تواند تکنیک‌های مهندسی داده پیشرفته‌تر، یا معماری‌های بهینه جایگزین را برای بهبود تعمیم مدل، بررسی کند.

اتکای این مطالعه به داده‌های تاریخی ثبت شده آب زیرزمینی، به این معنی است که ممکن است به طور کامل تأثیرات تغییرات آب و هوایی بر دینامیک آب‌های زیرزمینی را نشان داده نشده باشد. منظور کردن اطلاعات آب و هوایی در مدل، می‌تواند قابلیت‌های پیش‌بینی بلندمدت خود را افزایش دهد. علاوه بر این، در حالیکه این مطالعه، نگرش‌های ارزشمندی را در مورد دشت قهاوند ارائه داد، قابلیت انتقال مدل به مناطق دیگر نیاز به آزمایش دارد و عملکرد مدل‌های یادگیری عمیق در هیدرولوژی می‌تواند به شدت به شرایط محلی وابسته باشد.

این مطالعه قدرت ترکیب تکنیک‌های داده‌کاوی پیشرفته با یادگیری عمیق برای تجزیه و تحلیل آب‌های زیرزمینی را نشان داد. ادغام تجزیه و تحلیل Wavelet-PCA با مدل سازی LSTM یک چارچوب قوی برای درک و پیش‌بینی دینامیک آب‌های زیرزمینی پیچیده فراهم کرد.

یافته‌های این تحقیق، رابطه مهم بین کاربری زمین، به‌ویژه فعالیت‌های کشاورزی، و کاهش آب‌های زیرزمینی را برجسته کرد. این امر بر نیاز به شیوه‌های مدیریت آب پایدار تأکید می‌کند که نیازهای کشاورزی را با حفظ بلندمدت منابع آب متعادل می‌کند. روش توسعه یافته در این مطالعه کاربردهای بالقوه‌ای فراتر از دشت قهاوند دارد و الگویی برای تجزیه و تحلیل جامع آب‌های زیرزمینی در سایر مناطق خشک و نیمه خشک را ارائه می‌دهد. با این حال، تحقیقات بیشتری برای اصلاح مدل، بهبود قابلیت‌های تعمیم آن، و ترکیب سناریوهای آب و هوایی آینده مورد نیاز است. از آنجایی که کمبود جهانی آب همچنان یک موضوع مبرم است، مطالعات مشابه، نگرش‌های ارزشمندی برای تصمیم‌گیری آگاهانه در مدیریت منابع آب ارائه می‌دهد. ادغام تکنیک‌های تحلیلی پیشرفته با دانش محلی و شیوه‌های پایدار در پرداختن به چالش‌های پیچیده حفاظت از آب‌های زیرزمینی در قرن بیست و یکم بسیار مهم خواهد بود.

## منابع

- امینی، آ.، و مستوفی، ن. (۱۴۰۱). پایش فروچاله‌های شهر کبودرآهنگ همدان با استفاده از تکنیک تداخل سنجی راداری. جغرافیا و روابط انسانی، (۱) ۵، ۱۵۷-۱۳۹.
- درویشی، م.، و احمدی توانا، غ. (۱۳۹۲). کاربرد تکنیک راداری تداخل سنجی (DInSAR) در آشکارسازی تغییرات جابجایی سطحی در حوزه مخاطرات زمین ساختی، دومین کنفرانس بین‌المللی مخاطرات محیطی.



- رامین، پ.، سارا، ع.، و مسعود، س. (۱۳۹۹). تحلیل سری زمانی فرونشست زمین در غرب استان تهران (دشت شهریار) و ارتباط آن با برداشت آب‌های زیرزمینی با تکنیک تداخل سنجی راداری. *جغرافیا و پایداری محیط*، سال ۱۰، ۱۰۹-۱۲۸.
- رجبی، م.، روستایی، ش.، و جوادی، س. (۱۴۰۱). ارزیابی میزان فرونشست در شهرهای غربی استان همدان با استفاده از تصاویر راداری. *جغرافیا و برنامه‌ریزی*، ۲۶، ۹۶-۸۱.
- زبرجدی، ح.، قضاوی، ر.، و طاهری، ع. (۱۳۹۳). پهنه بندی میزان کل املاح محلول (TDS) آب‌های زیرزمینی دشت رزن- قهاوند با استفاده از مناسب‌ترین روش زمین‌آماری، اولین کنگره ملی زیست‌شناسی و علوم طبیعی ایران.
- شاه‌حسینی، ر.، اسمعیلی، م.، و امینی، ج. (۱۳۸۸). شبیه‌سازی ایتترفروگرام مدل رقومی زمین، همایش ژئوماتیک ۸۸.
- صدیقه، گ.، رقیه، ن.ح.، و حمید، گ. (۱۴۰۲). تحلیل عوامل مؤثر در وقوع فرونشست دشت قهاوند با استفاده از تصاویر راداری و ماهواره‌ای. *جغرافیا و روابط انسانی*، ۵، ۵۵۳-۵۴۲.
- محمد، س.ک.، رضا، س.م.، و سورکی، ی.د. (۱۳۹۰). بکارگیری تکنیک تداخل‌سنجی تفاضلی راداری (D-InSAR) در تعیین نرخ و دامنه فرونشست زمین در دشت مرند. وزارت علوم، تحقیقات و فناوری - دانشگاه تربیت مدرس - دانشکده علوم انسانی.
- Abdi, H., & Williams, L. (2010). Principal Component Analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2, 433-459
- Addison, P.S. (2016). *The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance*. CRC Press
- Ahmadi, T. (2018). The effect of meteorological and hydrological drouth on land use changes using remote sensing (Case study: Qahavand Plain, Hamedan province). In, Faculty of Natural Resources and Environment: Malayer University
- Alley, W.M., & Konikow, L.F. (2015). Bringing GRACE Down to Earth. *Ground Water*, 53, 826-829.
- Amini, A., & Mostofi, N. (2022). Monitoring sinkholes in Kabudarhang city of Hamadan using radar interferometry technique. *Geography and Human Relations*, (1) 5, 157-139. (In Persian).
- Cattell, R.B. (1966). The Scree Test for The Number of Factors. *Multivariate Behavioral Research*, 1, 245-276.
- Chu, H., Bian, J., Lang, Q., Sun, X., & Wang, Z. (2022). Daily groundwater level prediction and uncertainty using lstm coupled with pmi and bootstrap incorporating teleconnection patterns information. *Sustainability*, 14, 11598. <https://doi.org/10.3390/su141811598>
- Darvishi, M., & Ahmadi-Tavana, G. (2013). Application of interferometric radar technique (DInSAR) in detecting surface displacement changes in the field of tectonic hazards, Second *International Conference on Environmental Hazards*. (In Persian).
- Daubechies, I. (1992). *Ten lectures on wavelets*. SIAM Publication.
- Elshall, A., Arik, A., El-Kadi, A., Pierce, S., Ye, M., Burnett, K., Wada, C., Bremer, L., & Chun, G. (2020a). Groundwater sustainability: A review of the interactions between science and policy. *Environmental Research Letters*, 15.
- Elshall, A.S., Arik, A.D., El-Kadi, A.I., Pierce, S., Ye, M., Burnett, K.M., Wada, C.A., Bremer, L.L., & Chun, G. (2020b). Groundwater sustainability: a review of the interactions between science and policy. *Environmental Research Letters*, 15.

- Farmanifard, S., Alesheikh, A.A., Sharif, M., & Alizadeh, D. (2023). Tropical Storm Path Prediction Using Long Short-Term Memory Model, Similarity Measurement of Trajectories and Contextual Information. *Journal of Geospatial Information Technology*, 11, 1-16.
- Galloway, D.L., & Burbey, T.J. (2011). Review: Regional land subsidence accompanying groundwater extraction. *Hydrogeology Journal*, 19, 1459-1486.
- Gers, F., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural computation*, 12, 2451-2471.
- Gleeson, T., Wada, Y., Bierkens, M.F.P., & van Beek, L.P.H. (2012). Water balance of global aquifers revealed by groundwater footprint. *Nature*, 488, 197-200.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-term Memory. *Neural computation*, 9, 1735-1780.
- Jolliffe, I. (2002). *Principal Component Analysis*, Springer.
- Kaiser, H.F. (1958). The varimax criterion for analytic rotation in factor analysis. *Psychometrika*, 23, 187-200.
- Karami, J., Alimohammadi, A., & Modabberi, S. (2012). Analysis of the Spatio-Temporal Patterns of Water Pollution and Source Contribution Using the MODIS Sensor Products and Multivariate Statistical Techniques. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5, 1243-1255.
- Karami, J., Alimohammadi, A., & Seifouri, T. (2014). Water quality analysis using a variable consistency dominance-based rough set approach. *Computers, Environment and Urban Systems*, 43, 25-33.
- Konikow, L., & Kendy, E. (2005a). Groundwater Depletion: A Global Problem. *Hydrogeology Journal*, 13, 317-320.
- Konikow, L.F., & Kendy, E. (2005b). Groundwater depletion: A global problem. *Hydrogeology Journal*, 13, 317-320.
- Kratzert, F., Klotz, D., Brenner, C., Schulz, K., & Herrnegger, M. (2018). Rainfall-runoff modelling using Long Short-Term Memory (LSTM) networks. *Hydrol. Earth Syst. Sci.*, 22, 6005-6022.
- Machiwal, D., & Jha, M.K. (2015). Identifying sources of groundwater contamination in a hard-rock aquifer system using multivariate statistical analyses and GIS-based geostatistical modeling techniques. *Journal of Hydrology: Regional Studies*, 4, 80-110.
- Maier, H.R., & Dandy, G.C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software*, 15, 101-124.
- Mallat, S. (1989). Mallat, S.G.: A Theory of Multiresolution Signal Decomposition: The Wavelet Representation. *IEEE Trans. Pattern Anal. Machine Intell.* 11, 674-693.
- Mohammad, S.K., Reza, S.M., & Soraki, Y.D. (2011). Application of Differential Interferometry Radar (D-InSAR) Technique in Determining the Rate and Range of Land Subsidence in the Marand Plain. Ministry of Science, Research and Technology - Tarbiat Modares University - Faculty of Humanities. (In Persian).
- Moosavi, V., Vafakhah, M., Shirmohammadi, B., & Behnia, N. (2013). A Wavelet-ANFIS Hybrid Model for Groundwater Level Forecasting for Different Prediction Periods. *Water Resources Management*, 27.
- 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.

- Nourani, V., Hosseini Baghanam, A., Adamowski, J., & Gebremichael (2013). Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network-based rainfall-runoff modeling. *Journal of Hydrology*, 476, 228-243.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J., & Kisi, O. (2014). Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514, 358-377
- Qiao, W., Tian, W., Tian, Y., Yang, Q., Wang, Y., & Zhang, J. (2019). The forecasting of PM<sub>2.5</sub> using a hybrid model based on wavelet transform and an improved deep learning algorithm. *IEEE Access*, 7, 142814-142825.
- Rajabi, M., Roustaei, Sh., and Javadi, S. (2022). Evaluating the rate of subsidence in the western cities of Hamadan province using radar images. *Geography and Planning*, 26, 81-96. (In Persian).
- Rajaei, T., Ebrahimi, H., & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology*, 572, 336-351.
- Ramin, P., Sara, A., & Masoud, S. (2019). Time series analysis of land subsidence in the west of Tehran province (Shahriyar plain) and its relationship with groundwater withdrawal using radar interferometry technique. *Geography and Environmental Sustainability*, 10, 109-128. (In Persian).
- Sanayei, R., Vafaeinejad, A., Karami, J., & Aghamohammadi Zanjabadi, H. (2021). A model development on GIS-driven data to predict temporal daily collision through integrating Discrete Wavelet Transform (DWT) and Artificial Neural Network (ANN) algorithms; case study: Tehran-Qazvin freeway. *Geocarto International*, 37, 4141-4157.
- Schmidt, K., Tous Ramon, N., & Schwerdt, M. (2018). Radiometric Accuracy and Stability of Sentinel-1A Determined using Point Targets. *International Journal of Microwave and Wireless Technologies*, 10.
- Sedighe, G., Roqiyeh, N.H., and Hamid, G. (2023). Analysis of factors affecting the occurrence of subsidence of the Qahavand plain using radar and satellite images. *Geography and Human Relations*, 5, 553-542. (In Persian).
- Shah Hosseini, R., Esmaeili, M., & Amini, J. (2009). Simulation of Digital Earth Model Interferograms, *88th Geomatics Conference*. (In Persian).
- Shen, C. (2018). A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*, 54, 8558-8593.
- Sowter, A., Che Amat, A., Cigna, F., Marsh, S., Athab, A., & Alshammari, L. (2016). Mexico City land subsidence in 2014-2015 with Sentinel-1 IW TOPS: results using the Intermittent SBAS (ISBAS) technique. *International Journal of Applied Earth Observation and Geoinformation*, 52.
- Supreetha, B.S., Shenoy, N., & Nayak, P. (2020). Lion Algorithm-Optimized Long Short-Term Memory Network for Groundwater Level Forecasting in Udipi District, India. *Applied Computational Intelligence and Soft Computing*, 2020, 1-8.
- Taylor, R., Scanlon, B., Doell, P., Rodell, M., Beek, R., Wada, Y., Longuevergne, L., Leblanc, M., Famiglietti, J., Edmunds, M., Konikow, L., Green, T., Chen, J., Taniguchi, M., Bierkens, M.F.P., Macdonald, A., Fan, Y., Maxwell, R., Yechieli, Y., & Treidel, H. (2013). Ground water and climate change. *Nature Climate Change*, 3, 322-329.
- Torrence, C., & Compo, G. P. (1998). <bams-1520-0477\_1998\_079\_0061\_apgtwa\_2\_0\_co\_2.pdf>. *Bulletin of the American Meteorological society* 79, 61-78

- Wada, Y., Beek, L., van Kempen, C., Reckman, J., & Bierkens, M.F.P. (2010). Global Depletion of Groundwater Resources. *Geophysical Research Letters*, 37.
- Xiang, Z., Yan, J., & Demir, I. (2020). A Rainfall- Runoff Model With LSTM- Based Sequence- to- Sequence Learning. *Water Resources Research*, 56.
- Zabarjadi, H., Ghazawi, R., & Taheri, A. (2014). Zoning of total dissolved solids (TDS) in groundwater of Razan-Qahavand plain using the most appropriate geostatistical method, *First National Congress of Biology and Natural Sciences of Iran*. (In Persian).
- Zhang, J., Zhu, Y., Zhang, X., Ye, M., & Yang, J. (2018). Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas. *Journal of Hydrology*, 561, 918-929.