

**Research Paper**

# **Comparison of SVM and ANN models in Simulation the Groundwater level of observation wells in Nahavand Plain - Hamedan Province**

Mehdi Talebi afkham<sup>1</sup>,Abdollah Taheri Tizro<sup>2\*</sup>,Rojin Fasihi<sup>3\*</sup>

<sup>1</sup> Graduated of Water Resource engineering, Department of Water Science and Engineering, Faculty of Agriculture, University of Bu-Ali Sina, Hamedan, Iran. Email: mtalebi94@gmail.com

<sup>2\*</sup> Associate Professor, Department of Water Science and 3. Engineering, Faculty of Agriculture, University of Bu-Ali Sina, Hamedan, Iran. Email: ttizro@yahoo.com, (\*Corresponding Author)

<sup>3</sup> Ph.D Graduated of Water Resource engineering, Department of Water Science and Engineering, Faculty of Agriculture, University of Bu-Ali Sina, Hamedan, Iran. Email: rojin.fasihi@yahoo.com

**10.22125/IWE.2023.418876.1754**

Received:  
**October 29, 2023**  
Accepted:  
**March 2, 2024**  
Available online:  
**May 5, 2024**

**Keywords:**  
**Groundwater level,**  
**Nahavand plain, SVM,**  
**Matlab.**

**Abstract**

Groundwater considered one of the most consequential sources of water supply; therefore, its modeling can be very important. Meanwhile, the study and investigation of Groundwater level fluctuations with respect to management studies, creation of engineering structures, agricultural uses and obtaining high quality of groundwater potentials is of great importance. In this research, support vector machine (SVM) and artificial neural network (ANN) were used to simulate the monthly Groundwater level of Nahavand plain located in Hamedan province. Twenty years data (1997-2017) were used by engaging Matlab software. From these data, 14 years were used for training, 3 years for calibration and finally 3 years used for model validation. The statistical comparison of the results was also attempted with the aid of correlation coefficient ( $r$ ) and standard error (SE). Four observation wells were used along with the variables of Groundwater level, precipitation, evaporation and temperature to simulate the Groundwater level. The highest accuracy among these two models is SVM model, which has  $SE = 0.11$  in the training mode and  $0.03$  in the test mode. Also, the correlation coefficient in the test mode is  $98\%$ . Considering the appropriate accuracy of SVM method in simulating the groundwater level, the results indicate that, the RBF kernel function, with a variance of 6523 and a gamma of 527.23 for the optimal mode. The results of this study showed by using the SVM approach is more realistic in simulation of groundwater level and evaluation of the input parameters. In addition, this could help in reducing the number of input parameters as well as can show appropriate accuracy for the simulation.

\* Corresponding Author: Abdollah Taheri Tizro

Address: Department of Water Science and engineering, Faculty of agriculture, University of Bu Ali Sina, Hamedan, Iran

Email: ttizro@Basu.ac.ir

Tel: 09181190052

## 1. Introduction

Groundwater potentials are one of the most important and valuable water resources. In arid and semi-arid regions, has a significant impact on the sustainable development of many agricultural, social and economic activities. So far, many models have been used to simulate the Groundwater level. Among these models experimental time series models and physical models are well known (izadi et al., 2017). Saeedi Razavi and Arab (2018) used fuzzy logic, neural network and time series models to simulate the Groundwater level of Ajabshir plain. The results showed, that the fuzzy logic model can predict the water level with acceptable accuracy. Zarei et al. (2022) evaluated the flood occurrence potential using data mining models of support vector machine. Based on the results, the algorithm (SVM) and the new random forest algorithm model have found accurate results. Hamidi et al, 2015, used two models of support vector machine and artificial neural network to predict the monthly rainfall of airport and Nojeh synoptic stations in the west of Iran and found that the support vector machine is more efficient than the neural network.

## 2. Materials and Methods

In recent years, climate and hydrological forecasting models have been recommended by various researchers to make long-term forecasts. In the current research, due to the importance of the Groundwater level and its fluctuations over the years, the modeling of the Groundwater level and the comparison of models in water resources management have been investigated. Therefore, in this research, the piezometric wells of the Nahavand Plain aquifer are used as examples for modeling the plains. In this research, SVM and neural network artificial intelligence models have been used to investigate the changes in the Groundwater level of the plain. The existence of many unauthorized wells in these plains has led to a drop in the level of underground water in this region. The purpose of this research is to investigate the difference between artificial intelligence models and to choose the best model in the target area by applying variable temperature, precipitation and evaporation in the effect on the fluctuations of the Groundwater level.

## 3. Results

In this research, the neural network with Levenberg-Marquardt algorithm were used. For this purpose, first normalization was done for all the data used, then the optimal number of middle layer nodes was determined by trial-and-error method. This work was done for all four pizometers and according to the minimum error of the model efficiency; the number of three nodes was obtained for the middle layer of pizometers. The converter function in the middle layer is tangent-sigmoid and in the output layer is linear. Modeling was done with this number of nodes for both pizometers. The lowest test error criterion is related to vasaj piezometer and the highest test error criterion is related to Mohammad abad piezometer. Also, the highest correlation coefficient of the test is related to Milab pizometer.

## 4. Discussion and Conclusion

The results of this research showed that in different models, different input patterns are selected in terms of input parameters to simulate the Groundwater level with appropriate accuracy. Also, the results showed that both used models provided a different approach for simulation. Finally, the most accurate of these two models is the SVM model, which has  $SE = 0.11$  in the training mode and 0.03 in the test mode. Also, the correlation coefficient in the test mode is 98%. According to the appropriate accuracy of SVM method in simulating the Groundwater level, the results indicate the RBF kernel function, with a variance of 6523 and a gamma of 527.23 for the optimal state. The results of this study showed that using the SVM approach to simulate the Groundwater level and evaluate the input parameters for the

simulation can show appropriate accuracy for the simulation in addition to reducing the number of input parameters.

### 5. Six important references

- 1) Adda, A., Hanini, S., Bezari, S., Laidi, M., & Abbas, M. (2022). Modeling and optimization of small-scale NF/RO seawater desalination using the artificial neural network (ANN). *Environmental Engineering Research*, 27(2).
- 2) Hamidi, O., Poorolajal, J., Sadeghifar, M., Abbasi, H., Maryanaji, Z., Faridi, H. R., & Tapak, L. (2015). A comparative study of support vector machines and artificial neural networks for predicting precipitation in Iran. *Theoretical and applied climatology*, 119, 723-731.
- 3) Michalec, B., & Cupak, A. (2022). Assessment of quality of water and sediments in small reservoirs in Southern Poland-A case study. *Environmental Engineering Research*, 27(2).
- 4) Mirarabi, A., Nassery, H. R., Nakhaei, M., Adamowski, J., Akbarzadeh, A. H., & Alijani, F. (2019). Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 78, 1-15.
- 5) Shiri, J., Kisi, O., Yoon, H., Lee, K. K., & Nazemi, A. H. (2013). Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques. *Computers & Geosciences*, 56, 32-44.
- 6) Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O., & Lee, K. K. (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of hydrology*, 396(1-2), 128-138.

### Conflict of Interest

The author(s) of the article declare that in relation to the publication of the presented article, they have completely avoided publishing ethics, including plagiarism, misconduct, falsification of data, or double submission and publication, and commercial interests. In this regard, there is none and the authors have not received any money for presenting their work. The responsible author also declares that this work has not been published elsewhere and has not been submitted to another publication at the same time. Also, all rights to use the content, tables, images, etc. have been assigned to the publisher.

### Acknowledgments

We are grateful to regional water West Company for providing us possible data which were used to carry out this research work.

## مقایسه مدل‌های LS-SVM و ANN در شبیه‌سازی سطح آب زیرزمینی چاه‌های مشاهده‌ای دشت نهاوند – استان همدان

مهدي طالبي افخم<sup>۱</sup>, عبدالله طاهرى تيزرو<sup>۲\*</sup>, روزين فصيحى<sup>۳</sup>

تاریخ ارسال: ۱۴۰۲/۰۸/۰۷

تاریخ پذیرش: ۱۴۰۲/۱۲/۱۲

مقاله پژوهشی - کاربردی

### چکیده

منابع آب زیرزمینی از مهمترین منابع تأمین آب هستند، لذا مدل‌سازی آنها حائز اهمیت می‌باشد. مطالعه و بررسی نوسانات سطح آب زیرزمینی از نظر مطالعات مدیریتی، ایجاد سازه‌های مهندسی، مصارف کشاورزی و حصول آب‌های زیرزمینی با کیفیت بالا حائز اهمیت است. در این تحقیق از مدل ماشین بردار پشتیبان (LS-SVM) و شبکه عصبی مصنوعی (ANN) برای شبیه‌سازی ماهانه سطح آب زیرزمینی دشت نهاوند در استان همدان در یک دوره ۲۰ ساله (۱۳۹۶-۱۳۷۶) در محیط Matlab استفاده شد. در این دوره ۲۰ ساله، ۱۴ سال برای آموزش و ۳ سال برای واسنجی و همچنین ۳ سال برای صحت سنجی مدل تقسیم شد. در این پژوهش مقایسه آماری نتایج به کمک شاخص‌های ضریب تبیین ( $R^2$ ) و خطای استاندارد (SE) صورت گرفت. برای شبیه‌سازی سطح آب زیرزمینی از چهار حلقه چاه مشاهده‌ای به همراه متغیرهای سطح آب زیرزمینی، بارش، تبخیر و دما، استفاده شد. بیشترین دقت از بین این دو مدل در مدل LS-SVM است که دارای  $SE = 0.11$  در حالت Trian و  $0.03$  در حالت Test است. همچنین میزان ضریب تبیین در حالت Test ۹۸٪ است. با توجه به دقت مناسب روش LS-SVM در شبیه‌سازی سطح آب زیرزمینی نتایج حاکی از آن است که تابع کرنل RBF با واریانس  $6523/23$  و گاما  $527/23$  برای حالت بهینه است. نتایج این مطالعه نشان داد که استفاده از رویکرد LS-SVM جهت شبیه‌سازی سطح آب زیرزمینی و ارزیابی پارامترهای ورودی جهت شبیه‌سازی می‌تواند علاوه بر کاهش تعداد پارامترهای ورودی دقت مناسبی را جهت شبیه‌سازی نشان دهد.

واژه‌های کلیدی: مدل‌های هوشمند عصبی، دشت نهاوند، محمدآباد، Matlab.

<sup>۱</sup> گروه علوم و مهندسی آب دانشگاه بوعلي سينا، همدان، ايران، ايميل: mtalebi94@gmail.com

<sup>۲</sup> گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلي سينا ، همدان، ايران، ايميل: ttizro@yahoo.com

<sup>۳</sup> دانشجوی دکترا گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلي سينا ، همدان، ايران، ايميل: rojin.fasihi@yahoo.com

در غرب ایران از دو مدل SVM و ANN استفاده کردند و دریافتند که SVM نسبت به ANN از کارایی بیشتری برخوردار است. Mirarabi (۲۰۱۹) مدل‌های داده محور را برای شبیه‌سازی سطح آب زیرزمینی در سیستم‌های محصور و غیر محصور مورد ارزیابی قرار دادند. در این بین از SVR و ANN در زمان‌های ۱، ۲ و ۳ ماه پیش رو استفاده کردند. برای انتخاب ورودی‌های بهینه مدل، از ترکیب آزمون گاما و الگوریتم ژنتیک استفاده شد. از سوی دیگر، با افزایش ماههای پیش رو از دقت مدل‌ها کاسته شده است. در نتیجه مشخص شد که مدل SVR نسبت به ANN در آبخوان‌های محصور و نامحصور می‌تواند پیش‌بینی آب زیرزمینی را به صورت ماهانه انجام دهد. در پژوهشی دیگر رضایی و همکاران (۱۳۹۳) به شبیه‌سازی سطح ایستابی دشت رامهرمز با استفاده از روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی پرداختند. نتایج چهار ترکیب بیانگر دقت بالای مدل SVM نسبت به ANN می‌باشد. سعیدی، ANFIS، رضوی و عرب (۱۳۹۷) با استفاده از مدل‌های ANN و سری زمانی به شبیه‌سازی سطح آب زیرزمینی دشت عجبشیر پرداختند نتایج حاصل نشان داد که مدل ANFIS می‌تواند سطح ایستابی را با دقت قابل قبولی شبیه‌سازی نماید. پورصالحی و همکاران (۱۴۰۰) عملکرد الگوریتم جنگل تصادفی را در پیش‌بینی نوسانات سطح ایستابی در مقایسه با دو مدل درخت تصمیم و شبکه عصبی مصنوعی در آبخوان آزاد دشت ببرجند مطالعه نمودند. نتایج حاصل از شبیه‌سازی با استفاده از الگوریتم جنگل تصادفی نشان داد که این الگوریتم توانایی نسبتاً زیادی در شبیه‌سازی سطح ایستابی آبخوان دارد. زارعی و همکاران (۱۴۰۱) پتانسیل وقوع سیل با استفاده از مدل‌های داده‌کاوی ماشین بردار پشتیبان، چاید و جنگل تصادفی را در حوزه آبخیز فریزی ارزیابی نمودند. بر اساس نتایج، هم در داده‌های تعلیمی و هم در داده‌های آموزشی، مدل LS-SVM و مدل الگوریتم نوین جنگل تصادفی دارای نتایج دقیق‌تری می‌باشد. در سال‌های اخیر مدل‌های شبیه‌سازی اقلیمی و هیدرولوژیکی برای انجام شبیه‌سازی‌های بلندمدت توسط محققین مختلف توصیه شده است. در تحقیق حاضر نیز با توجه به اهمیت سطح آب زیرزمینی و نوسانات آن طی سال‌های اخیر موجب بررسی مدل‌سازی

## مقدمه

منابع آب‌های زیرزمینی یکی از مهمترین و با ارزش‌ترین منابع آب به‌شمار می‌روند. شناخت صحیح و بهره‌برداری اصولی از آن‌ها به خصوص در مناطق خشک و نیمه خشک در توسعه پایدار بسیاری از فعالیت‌های کشاورزی، اجتماعی و اقتصادی تأثیر بهسزایی دارد. تاکنون مدل‌های زیادی برای شبیه‌سازی سطح آب زیرزمینی به کار برده شده است. از جمله این مدل‌ها می‌توان به مدل‌های سری زمانی تجربی و مدل‌های فیزیکی اشاره کرد (ایزدی و همکاران، ۱۳۸۷). مطالعات متعددی بر توسعه مدل‌های شبیه‌سازی متمرکز شده‌اند برای شناسایی عواملی که در آلودگی آب‌های زیرزمینی نقش دارند ترکیبی از آمار و تکنیک‌های یادگیری ماشین استفاده می‌شود. این مدل‌ها برای شناسایی مناطقی که بیشترین آسیب‌پذیری را در برابر آلودگی دارند پارامترهای مختلفی مانند کاربری زمین، ویژگی‌های هیدرولوژیکی و محیطی را در نظر می‌گیرند (Michalec and Cupak, 2022; Adda et al., 2022).

Yoon و همکاران (۲۰۱۱) به منظور شبیه‌سازی سطح آب زیرزمینی یک آبخوان ساحلی، ANN و LS-SVM را مقایسه کردند. از میان متغیرهای احتمالی، سطح آب زیرزمینی پیشین، بارش و سطح جذر و مد به عنوان ساختار ورودی برگزیده شد و سطح آب زیرزمینی پیشین به عنوان مؤثرترین متغیر ورودی انتخاب شده است. با وجود اینکه عملکرد مدل LS-SVM از نظر ساختارهای ورودی و گام‌های زمانی در نظر گرفته شده شبیه‌سازی، مشابه و حتی در مواردی بهتر از ANN بوده است، اما خطای مدل Train و Test در مراحل LS-SVM از مدل ANN کمتر است. همچنین ANN عدم قطعیت بالاتری را به همراه دارد. Shiri و همکاران (۲۰۱۳) برای شبیه‌سازی نوسانات سطح آب زیرزمینی با بررسی اثرات هواشناسی، از روش‌های مختلف GEP، SVM، ANFIS، ANN و GEP استفاده نمودند. در این بررسی از داده‌های سطح آب زیرزمینی، بارش و مقدار تبخیر در یک دوره هشت ساله استفاده شد. نتایج نشان داد که مدل GEP عملکرد بهتری نسبت به دو روش دیگر دارد. Hamidi و همکاران (۲۰۱۵) به منظور شبیه‌سازی بارش ماهانه ایستگاه‌های سینوپتیک فرودگاه و نوژه

این دشت‌ها افت سطح آب‌های زیرزمینی را در این منطقه در پی داشته است. هدف از مطالعه حاضر بررسی دو روش ANN و LS-SVM در شبیه‌سازی سطح آب زیرزمینی می‌باشد. انتخاب برترین مدل در منطقه مورد نظر با اعمال متغیر دما، بارش، تبخیر و تأثیر آن‌ها روی نوسانات سطح آب زیرزمینی است.

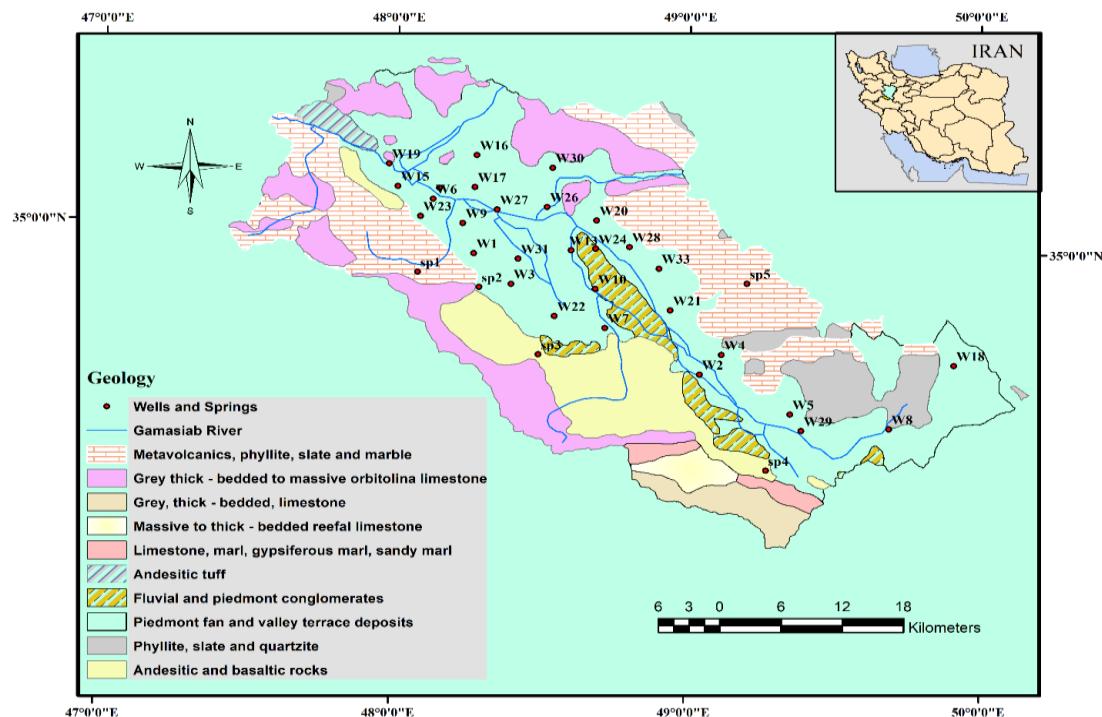
ایستگاه هیدرومتری دوآب در خروجی حوزه) و ارتفاع متوسط حوزه آبریز ۱۸۹۰ متر از سطح دریا می‌باشد. شهر نهاوند دارای مختصات جغرافیایی،  $48^{\circ}22' 48''$  طول شرقی و  $34^{\circ}12'$  عرض شمالی از مرکز شهرستان بوده و به فاصله ۱۵۰ کیلومتری از مرکز استان (شهر همدان) قرار گرفته است (بی‌نام، ۱۴۰۲). در شکل (۱) موقعیت جغرافیایی محدوده مطالعاتی نهاوند، نشان داده شده است.

سطح آب زیرزمینی و مقایسه مدل‌ها در مدیریت منابع آب شده است. از این‌رو در این تحقیق برای مدل‌سازی دشت‌ها از چاه‌های پیزومتری محدوده آبخوان دشت نهاوند به عنوان LS-نمونه استفاده شده است. در این تحقیق از مدل‌های LS-ANN و SVM جهت بررسی تغییرات سطح آب زیرزمینی دشت استفاده شده است. وجود چاه‌های غیرمجاز فراوان در

## مواد و روش‌ها

### معرفی محدوده مورد مطالعه

دشت نهاوند با وسعت حوزه آبریز ۱۹۰۲ کیلومترمربع یکی از دشت‌های حوزه علیای رودخانه کرخه محسب می‌گردد و در شمال شرق کوه‌های گرین از سلسله ارتفاعات زاگرس قرار گرفته است. وسعت اراضی مسطح (دشت) نهاوند ۶۴۴ کیلومترمربع و بقیه اراضی که ۱۰۴۶ کیلومترمربع (۶۲ درصد) گسترش دارند شامل ارتفاعات حاشیه دشت می‌باشد. شبیه‌سازی دشت از جنوب شرق به طرف شمال غرب بوده، مرتفع‌ترین نقطه حوزه بیش از ۳۴۰۰ متر ارتفاع و پست‌ترین نقطه ۱۴۰۲ متر (منطبق با



شکل (۱): ترسیم موقعیت جغرافیایی محدوده مطالعاتی آبخوان دشت نهاوند

شکل ۱ موقعیت تمامی چاه‌های مشاهداتی منطقه مورد مطالعه را نشان می‌دهد و در این پژوهش از ۴ چاه انتخابی

بر اساس بالاتر بودن سطح آب زیرزمینی در این چاهها و کامل بودن اطلاعات مورد استفاده طبق جدول ۱ استفاده شده است.

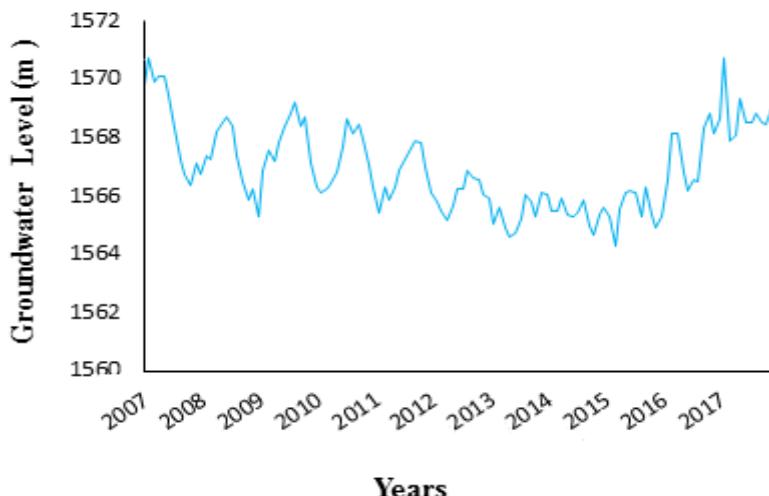
جدول (۱): مشخصات چاههای مورد استفاده

چاه مشاهده‌ای	Utm(x)	Utm(y)	سطح ایستابی (متر)
ازنهوری (W <sub>1</sub> )	۲۳۶۷۵۵	۳۷۹۲۶۰۰	۱۵۲۳/۵۹
محمدآباد (W <sub>28</sub> )	۲۵۲۰۰۰	۳۷۹۳۲۵۰	۱۵۵۷/۶
میلاب (W <sub>29</sub> )	۲۶۸۸۰۰	۳۷۷۲۳۲۰۰	۱۷۸۰/۵۲
ووج (W <sub>30</sub> )	۲۴۴۵۰۰	۳۸۰۱۹۰۰	۱۵۴۲/۹۷

سطح آب زیرزمینی را داریم و این افزایش به دلیل بارندگی خوب در این دو سال است. علت تغذیه مناسب منابع آب زیرزمینی این دشت از تشکیلات کارستی حاشیه دشت می‌باشد. تقریباً برداشت از سطح آبخوان و الگوی کشت نسبت به سال‌های گذشته تغییری نداشته است.

### هیدروگراف واحد آبخوان

با استفاده از ARCGIS 10.4 و همچنین داده‌های ۲۹ چاه مشاهده‌ای شکل (۱)، هیدروگراف واحد دشت به روش تیسن ترسیم شد. با توجه به نمودار هیدروگراف واحد آبخوان، اگر چه از سال ۲۰۰۷ تا ۲۰۱۶ سطح آب زیرزمینی کاهش پیدا می‌کند اما از سال ۲۰۱۶ تا ۲۰۱۷ افزایش



شکل (۲): تهیه هیدروگراف واحد، ده ساله آبخوان دشت نهادن با استفاده از روش تیسن

چاه مشاهده‌ای طبق شکل (۲) به دست آمده، ملاحظه می‌شود که میزان افت متوسط آبخوان در طی ۱۰ سال ۱/۴ متر است.

طبق جدول زیر، بیشترین سطح آب زیرزمینی در سال ۲۰۰۷، به میزان ۱۵۷۰ /۰۱ متر می‌باشد. کمترین سطح آب زیرزمینی در سال ۲۰۱۳، به میزان ۱۵۶۵ /۴۹ متر است. با توجه به نمودار هیدروگراف واحد آبخوان، که از ۲۹

جدول (۲): بررسی افت ۱۰ ساله سطح آب زیرزمینی آبخوان

سال آبی	سطح آب زیرزمینی (متر)	سال آبی	سطح آب زیرزمینی (متر)
۲۰۱۳	۱۵۷۰/۰۱	۲۰۰۷	۱۵۶۵/۴۹
۲۰۱۴	۱۵۶۷/۸۱	۲۰۰۸	۱۵۶۵/۵۱
۲۰۱۵	۱۵۶۷/۲۰	۲۰۰۹	۱۵۶۵/۵۳
۲۰۱۶	۱۵۶۷/۵۵	۲۰۱۰	۱۵۶۷/۸۱
۲۰۱۷	۱۵۶۶/۹۷	۲۰۱۱	۱۵۶۸/۵۸
۱/۴ = افت	۱۵۶۶/۴۱	۲۰۱۲	

تغذیه آبرفت دشت نهادن علاوه بر تغذیه مستقیم از ریزش-های جوی و منابع سرشار و تقریباً دائمی آب‌های سطحی از تشکیلات زمین شناسی حاشیه نیز تغذیه می‌نماید. ارتفاعات حاشیه دشت نهادن از آهک‌های مرمری شده و سنگ‌های آذرین و آهک تشکیل شده است. از بین این تشکیلات آهک‌های کریستالی و آهک‌های توده‌ای مهمترین عامل تغذیه سفره آبدار می‌باشند. این تشکیلات از نظر زمانی متعلق به کرتاسه بالایی بوده و دارای درز و شکاف‌های متعددی می‌باشد به طوریکه قسمت‌های عمده‌ای از ریزش‌های جوی در داخل این درز و شکاف‌ها به صورت چشممه‌های متعددی در دامنه ارتفاعات ظاهر گشته‌اند. در دشت نهادن قابلیت انتقال رسوبات آبرفتی بین ۱۰۰ تا ۳۰۰ متر مربع در روز متغیر است که در حاشیه دشت کمتر از ۱۰۰ متر مربع در روز است (لشکری پور و همکاران، ۲۰۰۳).

منبع اصلی ریزش‌های جوی منطقه، توده هوای مدیترانه‌ای است که با برخورد به ارتفاعات منطقه ایجاد ریزش می‌کنند. در این حوضه سه ایستگاه باران‌سنگی (وراینه، وسج و آران) وجود دارد. میزان بارندگی سالانه در محدوده دشت ۳۶۶/۵ میلی‌متر برآورد شده است. میزان تبخیر از سطح آب آزاد از ۱۰۴۷ میلی‌متر تا ۱۲۱۱ میلی‌متر در سال برآورد گردیده.

جهت حرکت آب زیرزمینی از پتانسیل بالاتر به پتانسیل پایین تر است (شکل ۳). مسلم است که هر جا خطوط پتانسیل به هم نزدیکتر باشند، گرادیان هیدرولیکی زیاد است، بنابراین در مناطقی که این خطوط به هم نزدیکتر هستند، حرکت آب زیرزمینی سریعتر است (Todd، ۲۰۰۴).

### هیدرولوژی و هیدروژئولوژی دشت نهادن

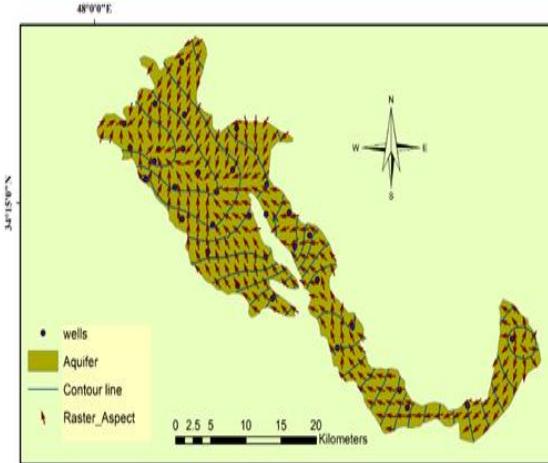
دشت نهادن به سه منطقه کوچک: دشت کوچک شرقی، دره نهادن و دشت اصلی نهادن یا دشت گیان تقسیم شده است. آبرفت دشت نهادن مجموعه‌ای از اجزاء تخریبی شامل شن، ماسه و رس است. ضخامت آبرفت در نقاط مختلف دشت متفاوت است. در مورد دشت کوچک شرقی از حاشیه بطرف محور مرکزی دشت بر مقدار آن افزوده شده و به ۷۰ تا ۸۰ متر نیز می‌رسد. در مورد دره نهادن آبرفت دارای اجزاء تخریبی درشت‌تری بوده و ضخامت آن به طرف محور مرکزی افزایش می‌یابد. این قسمت از دشت نهادن در مقایسه با دشت شرقی از پتانسیل آبی بالاتر برخوردار است. سنگ کف در دره دارای توپوگرافی شدیدتری بوده و از جنس شیست، آهک و کنگلومرا مترکم می‌باشد. آبرفت این منطقه به علت تغذیه مداوم از منابع آب‌های سطحی و چشممه‌سارهای متعدد و دارای قابلیت آبدهی بالاتری است. ضخامت آبرفت از ۶۰ تا ۹۰ متر به طرف محور دره متغیر می‌باشد. بیشترین محدوده گسترش سفره آبداره دشت اصلی نهادن یا دشت گیان می‌باشد. آبرفت این قسمت از دشت نهادن دارای درصد بیشتری از ذرات رس و سیلت بوده و شن و ماسه و قلوه آن کمتر است. ضخامت لایه آبرفت این دشت در مقایسه با مناطق دیگر بیشتر بوده و با توجه به تغذیه کاملاً مناسب از محل آب‌های سطحی و به خصوص آهک‌های کارستیکی حاشیه دارای پتانسیل قابل توجهی است. ضخامت آبرفت در این منطقه به بیش از یک صد متر نیز می‌رسد.

### بیلان آب زیرزمینی

در جدول زیر بیلان آب زیرزمینی سال ۱۳۸۹ آبخوان آبرفتی دشت نهادن نشان داده شده است. ارقام به میلیون مترمکعب در سال است. و همچنین متوسط ضریب ذخیره در دشت نهادن برابر با ۵ درصد برآورد شده است (گزارش بیلان منابع آب محدوده مطالعاتی حوضه آبریز کرخه، ۱۳۹۰). با توجه به حجم ذخیره ۱۶/۶ در جدول زیر، بیلان آب زیرزمینی منفی است. شبیه‌سازی دقیق آینده به وسیله مدل‌های مختلف کمک می‌کند که از وضعیت منابع آب منطقه آگاه باشیم و سناریوهای مدیریتی بهتری را اعمال کنیم و کمتر از سطح دشت و آبخوان برداشت کنیم.

جدول (۳): بررسی بیلان آب زیرزمینی دشت نهادن در سال ۱۳۸۹

عوامل خروجی	عوامل ورودی									
	آبیان زیرزمینی و دودی	نفوذ از زمین‌های سطحی	نفوذ از زمین‌های بردگی	نفوذ از پساب کشاورزی	نفوذ از پستانه و معدن	نفوذ از براحتی	نفوذ از آبادان و چشمه، قنات	برآیند بروادشتن (پدان و چشمه، قنات)	برآیند زیرزمینی	آبیان آبخوان
-	۱۳/۶	۲۰/۳	۳۰/۴	۴۰/۵	۵۱/۵	۵۱/۵	۵۱/۵	۵۱/۵	۵۱/۵	۵۱/۵



شکل (۳): نقشه ترسیم شده جهت حرکت آب‌های زیرزمینی

آبخوان نهادن با استفاده از ARCGIS10.4

شد. به علت اینکه وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت می‌شود از روش استانداردسازی داده‌ها استفاده شده است. با روش استانداردسازی هر عدد تبدیل به عددی بین صفر تا یک می‌شود (Riad et al., 2004). برای نرمال‌سازی (استانداردسازی) از رابطه زیر استفاده می‌کنیم که در این روابط  $X$  داده مورد نظر،  $\bar{X}$  میانگین داده‌ها،  $X_{\max}$  حداقل داده‌ها،  $X_{\min}$  حداقل داده‌ها و  $y$  داده استاندارد شده می‌باشد. در این تحقیق از ۸۰ درصد

### آماده‌سازی داده‌ها

داده‌ها در یک دوره ۲۰ ساله (۱۳۷۶-۱۳۹۶) از سازمان آب منطقه‌ای همدان جمع آوری گردید سپس از محیط نرم‌افزار Matlab2016 برای شبیه‌سازی ماهانه سطح آب زیرزمینی دشت نهادن استفاده شد. در این دوره ۲۰ ساله، ۱۴ سال برای آموزش و ۳ سال برای واسنجی و همچنین ۳ سال برای صحت سنجی مدل در نظر گرفته شد. در این پژوهش نواقص آماری داده‌ها به روش فرگمنت بازسازی شد، داده‌های پرت حذف گردید و مجدد بازسازی

از: الف) گره‌ها واحدهایی هستند که وظیفه پردازش داده‌ها را بر عهده دارند؛ ب) بردارهای ارتباطی سیگنال بین گره را انتقال می‌دهند؛ ج) با توجه به اهمیت داده ورودی وزن هر کدام از خطوط ارتباطی تعیین می‌شود؛ د) گره‌ها دارای توابع فعالسازی و تبدیل‌گر برای تعیین سیگنال‌های خروجی از داده‌های ورودی شبکه هستند. یک شبکه معمولاً از سه لایه ورودی، میانی، خروجی تشکیل شده که لایه ورودی وسیله‌ای برای ورود داده‌ها بوده و هرگره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر به دست بیاید و لایه میانی به عنوان پردازشگر سیستم عمل می‌کند که شمار گره‌ها به وسیله روش آزمون و خطا تعیین می‌شود. در نهایت لایه خروجی شامل مقادیر شبیه‌سازی شده است. از مهمترین کاربردهای شبکه عصبی مصنوعی می‌توان به موارد زیر اشاره کرد: ۱) تقسیم بندی الگوها (داده‌ها، اشکال و غیره)؛ ۲) شبیه‌سازی در زمینه‌های مختلف؛ ۳) بهینه‌سازی؛ ۴) حافظه در دسترس برای ذخیره‌سازی؛ ۵) کنترل سیستم‌های مختلف. یک شبکه عصبی مصنوعی چند لایه، شامل گره‌های پردازش (شبیه نورون مغز) در لایه‌های مختلف و اتصال‌هایی (شبیه سینپس مغز) است که بین گره‌ها ایجاد می‌شود (Coppola et al., 2003). در شبکه عصبی برگشتی اطلاعات بین گره‌ها در دو جهت، از ورودی به سمت خروجی و برعکس جریان می‌باید. این نوع از شبکه، از خروجی‌ها به عنوان ورودی‌های جدید استفاده می‌کند، بنابراین به داده‌ها اجازه برگشت به ورودی را می‌دهد (ASCE, 2000). شکل (۳) تصویر شماتیکی از یک شبکه عصبی مصنوعی را برای پژوهش حاضر نشان می‌دهد.

داده‌های سطح آب زیرزمینی برای آموزش و ۲۰ درصد برای شبیه‌سازی استفاده شده است.

$$y = 0.5 + \left( 0.5 * \left( \frac{X - \bar{X}}{X_{max} - X_{min}} \right) \right) \quad (1)$$

### ماشین بردار پشتیبان (LS-SVM)

ماشین بردار پشتیبان، یکی از روش‌های یادگیری با نظارت (Supervised learning) است. ماشین بردار پشتیبان، دسته‌بندی کننده‌ای است که جزء شاخه روش‌های کرنلی (Kernel Methods) در یادگیری ماشین محسوب می‌شود. این نوع سیستم یادگیری هم برای دسته‌بندی و هم برای تخمین و برآورد تابع برآذش داده‌ها به کار می‌رود. به طوری که کمترین خطأ در دسته‌بندی داده‌ها و یا تابع برآذش رخ دهد. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون، داشته است. مبنای کاری دسته‌بندی کننده ماشین بردار پشتیبان، دسته‌بندی خطی داده‌ها است. در دسته‌بندی خطی داده‌ها سعی می‌شود خطی انتخاب گردد که حاشیه اطمینان بیشتری داشته باشد. حل معادله پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های QP که روش‌های شناخته شده‌ای در حل مسائل محدودیت‌دار هستند صورت می‌گیرد. قبل از تقسیم خطی، برای اینکه ماشین بتواند داده‌های با پیچیدگی بالا را دسته‌بندی کند.

هدف ماشین بردار پشتیبان، تشخیص تابع  $f(x)$  برای الگوهای آموزشی  $x$  است، به طوریکه حداقل حاشیه را از مقادیر آموزشی  $y$  داشته باشد. به عبارت دیگر، ماشین بردار پشتیبان مدلی است که یک منحنی با ضخامت مشخص به داده‌ها برآذش می‌دهد، به طوریکه کمترین خطأ در داده‌های آزمایشی صورت گیرد (Cortes and Vapnik, 1995).

### شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند (Hopfield, 1982). اساس کار شبکه‌های عصبی عبارتند

به ترتیب تبخیر، دما، سطح ایستابی و بارش در دوره‌های زمانی گذشته و سطح ایستابی  $GWL_{(n+1)}$  در دوره آتی می‌باشد.

جدول (۴): الگوهای مختلف ورودی برای تخمین تراز سطح آب زیرزمینی

متغیر خروجی	متغیرهای ورودی	الگو
$GWL_{(n+1)}$	$GWL_{(n)}, R_n, E_n, T_n$	A
$GWL_{(n+1)}$	$GWL_{(n)}, GWL_{(n-1)}, R_n, R_{(n-1)}, E_n, E_{(n-1)}, T_n, T_{(n-1)}$	B
$GWL_{(n+1)}$	$GWL_{(n)}, GWL_{(n-1)}, GWL_{(n-2)}, R_n, R_{(n-1)}, R_{(n-2)}, E_n, E_{(n-1)}, E_{(n-2)}, T_n, T_{(n-1)}$	C
$GWL_{(n+1)}$	$GWL_{(n)}, GWL_{(n-1)}, GWL_{(n-2)}, R_n, R_{(n-1)}, R_{(n-2)}, E_n, E_{(n-1)}, E_{(n-2)}, T_n, T_{(n-1)}, T_{(n-2)}$	D

برای شبیه‌سازی سطح آب زیرزمینی با مدل‌های مذکور نیاز به اطلاعات مشاهداتی مستقل بود که مقدار سطح آب زیرزمینی برای هریک از ماههای مورد بررسی را شبیه‌سازی بزند. بنابراین با توجه به تحقیقات گذشته از متغیرهای سطح آب زیرزمینی ماه قبل ( $GWL_{(n-1)}$ ، بارش ( $R_{(n)}$ )، دما ( $T_{(n)}$ ) و تبخیر ( $E_{(n)}$ ) به صورت ماهانه به عنوان ورودی انتخاب گردید. با مشخص بودن پارامترهای ورودی و گام زمانی ماهانه، آمار و اطلاعات داده‌های مشاهداتی استخراج گردید. از مهر سال ۱۳۷۶ تا شهریور سال ۱۳۹۶ دوره شبیه‌سازی استفاده گردید. حدود ۸۰ درصد داده‌ها برای آموزش و مابقی برای صحت سنجی مدل در نظر گرفته شد.

#### معیارهای ارزیابی

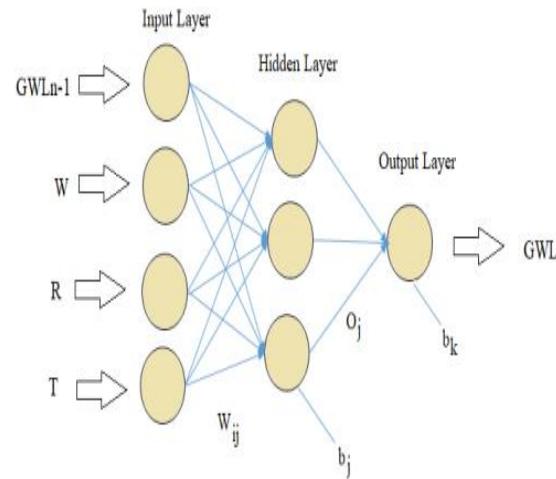
به منظور ارزیابی مدل‌ها از سه شاخص آماری ضریب تبیین ( $R^2$ )، خطای استاندارد (SE) و ریشه مربع میانگین خطای (RMSE) به صورت زیر استفاده شد.

$$R^2 = \frac{\sum_{i=1}^n [Q_i^p - \bar{Q}_i^p] (Q_i^o - \bar{Q}_i^o)^2}{\sum_{i=1}^n (Q_i^p - \bar{Q}_i^p)^2 \sum_{i=1}^n (Q_i^o - \bar{Q}_i^o)^2} \quad (2)$$

$$SE = \frac{RMSE}{\bar{Q}_i^o} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [Q_i^o - Q_i^p]^2}{n}} \quad (4)$$

در این روابط،  $Q_i^o$  سطح ایستابی مشاهداتی،  $Q_i^p$  سطح ایستابی شبیه‌سازی،  $\bar{Q}_i^o$  میانگین سطح ایستابی



شکل (۴): تصویر شماتیکی از یک شبکه عصبی مصنوعی

در توضیح شکل ۴ باید مذکور شد که این شبکه دارای چهار ورودی مختلف، یک لایه میانی و یک لایه خروجی تشکیل شده است. هر ورودی وزنی به خود می‌گیرد و سپس با بایاس جمع می‌گردد و درنهایت توسط تابع در لایه میانی به لایه خروجی منتقل می‌گردد. لایه خروجی بعد از اعمال و وزن و بایاس درنهایت نیز توسط تابع دیگر به مقدار خروجی منتقل می‌گردد. مدل شبکه عصبی نیز توسط الگوریتم‌های مختلفی آموزش می‌بیند تا مقدادر خطا بین مشاهداتی و خروجی را به حداقل برساند. در قسمت نتایج تعداد نورون مطلوب برای لایه میانی و الگوریتم مناسب جهت آموزش شبکه عصبی آورده شده است. درنهایت نیز همه الگوهای تدوین شده توسط شبکه عصبی شبیه‌سازی می‌شوند و با معیارهای مختلف مورد ارزیابی قرار می‌گیرند.

#### ساختارهای مختلف مدل‌سازی

برای اجرای مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی، با توجه به تعداد پارامترهای ورودی، ۴ نوع ترکیب مختلف مطابق جدول (۴) مورد بررسی قرار گرفت. هدف از بررسی تا ۴ الگو این است که آیا مدل‌های استفاده شده با توجه به تاخیرهای زمانی ایجاد شده نتایج بهتری می‌دهند یا خیر که در بخش نتایج بررسی گردیده است. پارامترهای  $GWL_{(n)}, R_n, E_n, T_n$  به ترتیب دما، تبخیر، بارش و سطح ایستابی در دوره زمانی ماهانه هستند و پارامترهای  $GWL_{(n-1)}, T_{(n-2)}, T_{(n-1)}, E_{(n-2)}, E_{(n-1)}$  سطح ایستابی

جدول (۵): نتایج ارزیابی الگوهای مختلف برای مدل LS-SVM

RMSE		$R^2$		SE		شماره الگو	جاه مشاهداتی
Train	Test	Train	Test	Train	Test		
۰/۸۳	۰/۷۲	۰/۶۸	۰/۷۳	۰/۱۰	۰/۰۸	C	ازنه روی
۰/۹۷	۰/۳۲	۰/۷۶	۰/۹۸	۰/۱۱	۰/۰۳	C	محمد آباد
۰/۸۶	۱/۱۶	۰/۷۸	۰/۸۴	۰/۰۷	۰/۱۰	D	پلاد
۱/۴۹	۱/۶۲	۰/۷۸	۰/۸۲	۰/۰۴	۰/۰۴	B	وسج

#### نتایج حاصل از مدل شبکه عصبی مصنوعی

در این پژوهش از شبکه عصبی با الگوریتم لونبرگ - مارکوارت استفاده شده است. بدین منظور ابتدا نرمال سازی برای کل داده های مورد استفاده انجام گرفت سپس به روش آزمون و خطا تعداد بهینه گره های لایه میانی تعیین شدند. این کار برای هر چهار چاه انجام شد و با توجه به کمترین خطای بازده مدل، تعداد سه گره برای لایه میانی تعیین شدند. این کار برای هر چهار چاه انجام شد و با توجه به کمترین خطای بازده مدل، تعداد سه گره برای لایه میانی تعیین چاهها به دست آمد. تابع تبدیل گر در لایه میانی از نوع سیگموئید تائزانت و در لایه خروجی خطی می باشد. مدل - سازی با این تعداد گره ها برای هر دو چاه انجام شد. همانطور که از جدول ۶ و شکل ۴ مشاهده می کنیم مدل ANN کمترین معیار خطای Test را برای چاه وسج، طبق الگوی B با  $R^2 = ۰/۱۶$  و  $SE = ۰/۱۶$  و بیشترین ضریب تبیین در مرحله Test را برای چاه میلاب، طبق الگوی D با  $R^2 = ۰/۲۷$  و  $SE = ۰/۰۴$  داشته است.

مشاهداتی،  $\overline{Q_i^p}$  میانگین سطح ایستابی شبیه سازی و  $n$  تعداد داده ها می باشد.

#### بحث و نتایج

هدف از مطالعه حاضر، بررسی دو روش LS-ANN و SVM در شبیه سازی سطح آب زیرزمینی می باشد. از سوی دیگر، از داده های آماری مربوط به چهار چاه مشاهداتی منتخب (پیزومتر های ازنه روی، محمد آباد، وسج و میلاب)، که اطلاعات مربوط به سطح آب زیرزمینی آن در دوره زمانی (۱۳۹۶-۱۳۷۶) کامل بوده است، استفاده شد. در ابتدا با بررسی بیشترین همبستگی میان متغیر های ورودی هواشناسی و تأثیر آنها بر سطح آب زیرزمینی مشخص شد که متغیر های دما، بارش و تبخیر تعرق با سطح آب زیرزمینی بیشترین وابستگی را دارند. داده های مورد نظر با سه دوره تأخیر به عنوان ورودی انتخاب شده اند که در جدول ۴ نمایش داده شده است و خروجی تمام مدل سازی - های سطح آب زیرزمینی در زمان ( $t^{+0/1}$ ) می باشد.

#### نتایج حاصل از مدل ماشین بردار پشتیبان

در این پژوهش از مدل SVM استفاده شده که توسط Suykens و همکاران (۲۰۰۲) پیشنهاد شده است. برای اجرای SVM انتخاب بهترینتابع کرنل و مقادیر مناسب برای پارامتر های بهینه آن که شامل پارامتر  $\gamma$  نیز است بر اساس کمینه خطای ایجاد شده ضروری می باشد. در این تحقیق از کرنل RBF استفاده شده. بر اساس مطالعات انجام گرفته کارایی بهتر تابع کرنل RBF نسبت به تابع کرنل های Asefa et al., 2005; Asefa et al., 2006 نیز است. همانطور که از جدول زیر و شکل ۴ مشاهده می کنیم مدل LS-SVM بهترین برازش را برای چاه محمد آباد، طبق الگوی C و با  $RMSE = ۰/۰۳$  و  $R^2 = ۰/۹۸$  در مرحله Test داشته است.



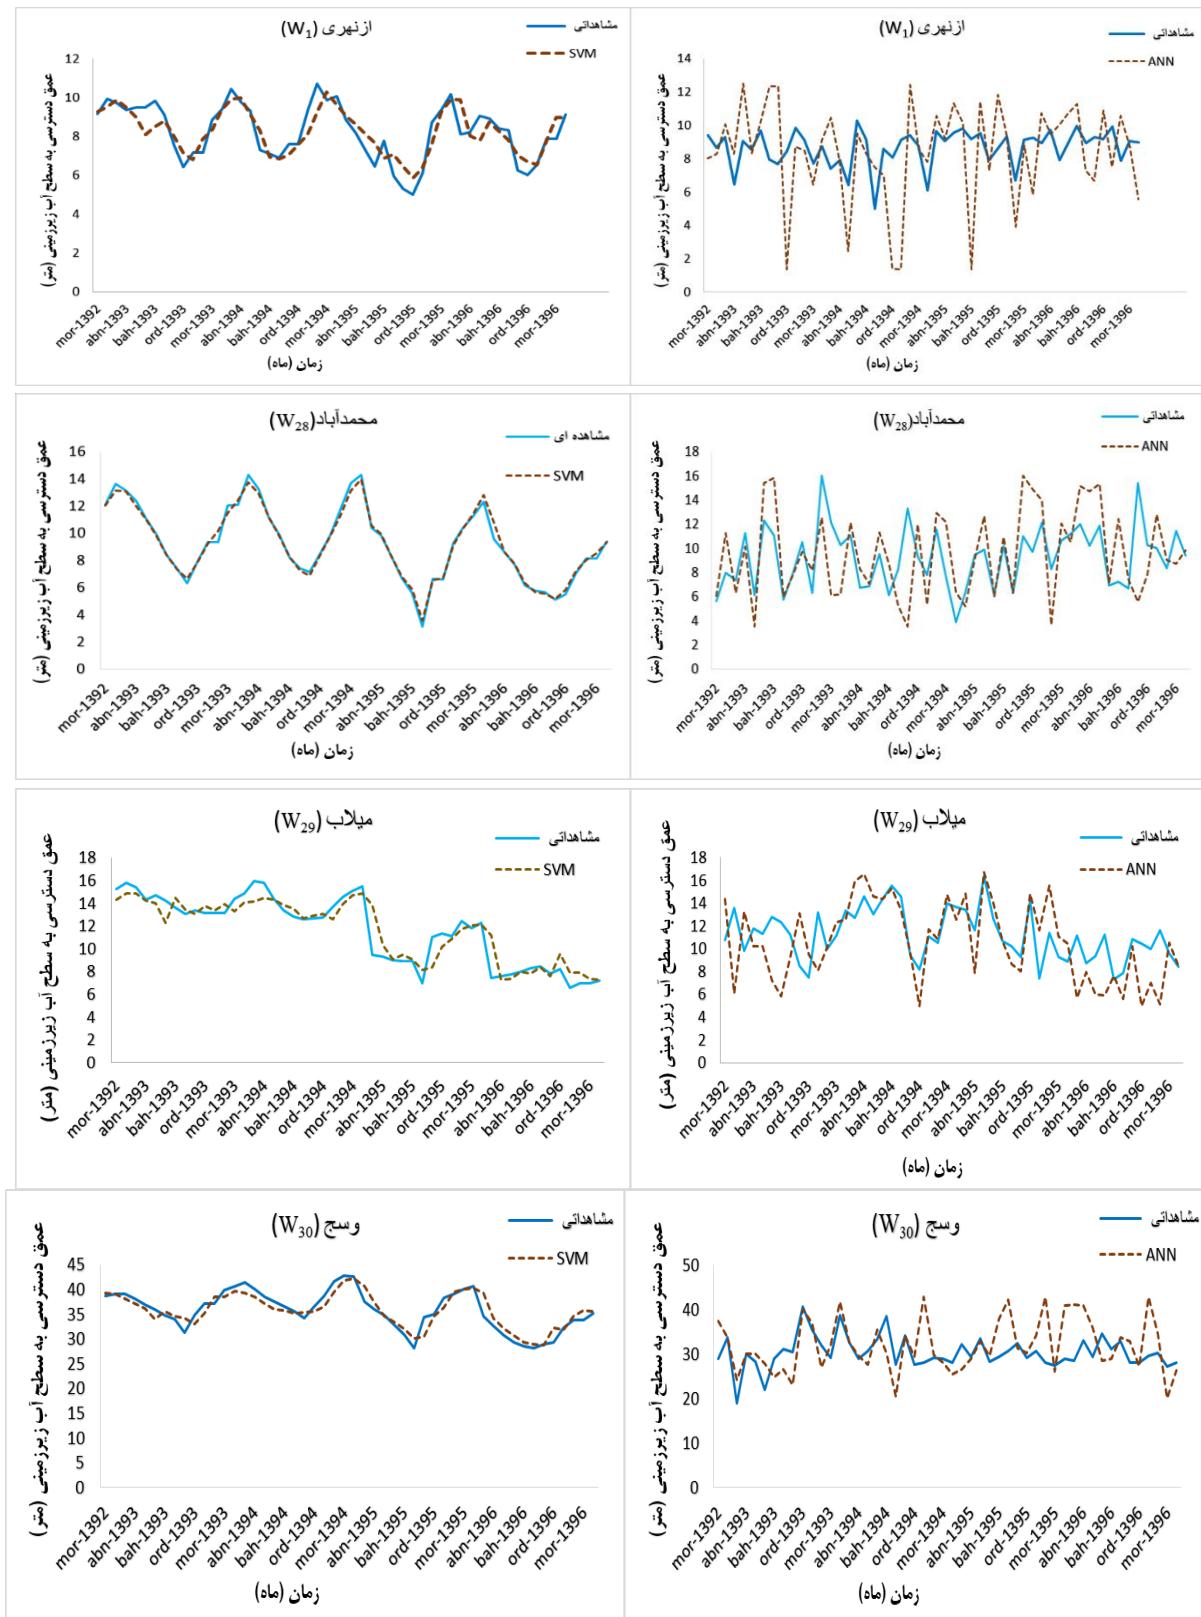
ضریب تبیین مدل LS-SVM از  $0.73 / 0.98$  تا  $0.73 / 0.98$  متغیر می-باشد در حالی که مقدار این ضریب در مدل ANN در بازه  $0.10 / 0.27$  است که نشان دهنده برتری مدل LS-SVM نسبت به ANN است. مقابلاً بر اساس شاخص SE این نتیجه دریافت می‌گردد. همچنین طبق شکل (۵)، صحت سنجی که در مرحله Test مدل‌ها انجام شده است برتری مدل LS-SVM را نشان می‌دهد. نتایج این پژوهش با یافته‌های قوردی میلان و همکاران (۱۳۹۹) و عیسی زاده و همکاران (۱۳۹۸) مطابقت دارد. براساس نتایج شالودگی و بازیزدی (۱۴۰۱) مدل ماشین بردار پشتیبان دارای بیشترین بازده، کمترین درصد خطأ و توانایی بالایی در شبیه‌سازی سطح آب زیرزمینی نسبت به مدل شبکه عصبی مصنوعی می‌باشد که همسو با نتایج این پژوهش است. یافته‌های نوذری و توکلی (۱۳۹۷) بیانگر آن بود که مدل ماشین بردار پشتیبان به علت نداشتن محدودیت در تعداد سری‌های ورودی، مدلی مناسب جهت شبیه‌سازی می‌باشد. علیرغم نتایج قابل قبول ارائه شده از شبیه‌سازی سطح آب زیرزمینی توسط شبکه عصبی مصنوعی در پژوهش‌های پیشین، این امر ناشی از خطأ در انجام مراحل یا عدم توانایی مدل مذکور در شبیه‌سازی نبوده، شرایط اقلیمی و عوامل طبیعی مانند خشکسالی چاههای مورد مطالعه به عنوان یک پارامتر مهم می‌تواند این موضوع را تحت الشاعع قرار دهد.

جدول (۶): نتایج ارزیابی الگوهای مختلف برای مدل ANN

شماره الگو	RMSE		$R^2$		SE		ماه مشاهده‌ای
	Train	Test	Train	Test	Train	Test	
C	۰/۰۲	۲/۸۷	۰/۹۸	۰/۱۰	۰/۰۰۲	۰/۳۴	ازبهنگی
C	۰/۰۴	۳/۳۳	۰/۹۹	۰/۲۰	۰/۰۰۵	۰/۳۶	محمدآباد
D	۰/۰۴	۳/۰۴	۰/۹۹	۰/۲۷	۰/۲۵	۰/۲۶	پلار
B	۰/۰۴	۶/۰۵	۱	۰/۱۲	۰/۰۰۱	۰/۱۶	وسع

#### نتایج حاصل از شبیه‌سازی سطح آب زیرزمینی دشت نهادوند

مقایسه شاخص‌های آماری طبق جدول (۵) و (۶)، نشان می‌دهد که مدل LS-SVM نسبت به مدل ANN عملکرد بهتری داشته است. زیرا در مرحله Test مقدار



شکل (۵): مقایسه مدل‌های ANN و LS-SVM در شبیه‌سازی سطح آب زیرزمینی دشت نهادوند

## نتیجه‌گیری

با توجه به اهمیت فراوان و نقش مهم سطح آب زیرزمینی در ارزیابی وضعیت کمی آبخوان، شبیه‌سازی این پارامتر جهت ارزیابی وضعیت منابع آب زیرزمینی یک منطقه حائز اهمیت است. بررسی و شبیه‌سازی سطح آب زیرزمینی در تصمیم‌گیری مدیران منابع آب جهت مدیریت بهتر آبخوان کمک شایانی می‌نماید. بدین منظور در این تحقیق از دو مدل شبکه عصبی مصنوعی و روش حداقل مربعات ماشین بردار پشتیبان جهت شبیه‌سازی سطح آب زیرزمینی استفاده گردید. با توجه به نقش پارامترهای مختلف در بررسی سطح آب زیرزمینی، در این پژوهش پارامترهای مختلف آبخوان ارزیابی گردید و بر اساس مطالعات انجام شده پارامترهایی از جمله: عمق دسترسی به سطح آب زیرزمینی، بارش، دما، تبخیر به عنوان ورودی مدل جهت شبیه‌سازی انتخاب گردید. بهمنظور تعیین بهترین الگوی جهت ورود پارامترهای شبیه‌سازی سطح آب زیرزمینی، الگوهای مختلف شبیه‌سازی کننده‌ها در هر دو مدل مورد ارزیابی قرار گرفت. نتایج این تحقیق نشان داد

## منابع

- ایزدی، ع. ا، داوری، ک، علیزاده، ا، و قهرمان، ب. (۱۳۸۷). کاربرد مدل داده‌های ترکیبی در پیش‌بینی سطح آب زیرزمینی. مجله آبیاری و زهکشی ایران، ۲(۲): ۱۴۴-۱۳۳.
- پورصالحی، ف، خاشعی سیوکی، ع، و هاشمی س. ر. (۱۴۰۰). بررسی عملکرد الگوریتم جنگل تصادفی در پیش‌بینی نوسانات سطح ایستابی در مقایسه با دو مدل درخت تصمیم و شبکه عصبی مصنوعی (مطالعه موردی: آبخوان آزاد دشت بیرجنده). اکوهیدرولوژی، ۸(۴): ۹۶۱-۹۷۴.
- رضایی، ا، خاشعی سیوکی، ع، و شهیدی ع. (۱۳۹۳). طراحی شبکه پایش سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM). تحقیقات آب و خاک ایران، ۴۵(۴): ۳۸۹-۳۹۶.
- زارعی، م، زندی، ر، و ناعمی تبار، م. (۱۴۰۱). ارزیابی پتانسیل وقوع سیل با استفاده از مدل‌های داده‌کاوی ماشین بردار پشتیبان، چاید و جنگل تصادفی (مطالعه موردی: حوزه آبخیز فربیز). پژوهشنامه مدیریت حوزه آبخیز، ۲۵(۲۵): ۱۳۳-۱۴۴.
- سعیدی رضوی، ب، و عرب، ع. ر. (۱۳۹۷). پیش‌بینی سطح آب زیرزمینی با استفاده از مدل‌های منطق فازی، شبکه عصبی و سری زمانی. مجله هیدرولوژی، ۲(۳): ۶۱-۸۳.
- شالودگی، ا، و بایزیدی، م. (۱۴۰۱). پیش‌بینی سطح ایستابی آب زیرزمینی آبخوان چهاردولی در شهرستان قروه با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان. یافته‌های نوین زمین‌شناسی کاربردی، ۱۶(۳۱): ۱۶۳-۱۷۵.
- عیسی زاده، م، بی آزار، س. م، اشرف زاده، ا، و خانجانی، ر. (۱۳۹۸). تخمین پارامترهای کیفی آبخوان دشت گیلان با استفاده از آزمون گاما و مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی. فصلنامه علوم و تکنولوژی محیط زیست، ۲۱(۲): ۲۱-۱.

قدرویی میلان، س.، آریآذر، ن.، جوادی، س.، و رازدار، ب. (۱۳۹۹). شبیه‌سازی تراز سطح آب زیرزمینی با استفاده از مدل حداقل مربعات ماشین بردار پشتیبان و مقایسه آن با شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره، مجله هیدرولوژی، ۵(۱): ۱۱۸-۱۳۳.

لشکری پور، غ.، کولیوند، د.، ساکی، م.، و شکیبی نیا، م. (۲۰۰۳). بررسی اجمالی آب‌های زیرزمینی دشت نهاوند. بیست و یکمین گردهمایی علوم زمین. ۲-۱۵.

مهندسين مشاور آب و توسعه پايدار (۱۳۸۹). مطالعات بهنگام‌سازی بیلان منابع آب محدوده‌های مطالعاتی حوزه آبريز رودخانه کرخه، گزارش بیلان منابع آب، پیوست شماره ۳۳: گزارش بیلان آب محدوده مطالعاتی نهاوند. ۵۸ صفحه.

نودری، ح.، توکلی، ف. (۱۳۹۷). پیش‌بینی جریان با استفاده از مدل ماشین بردار پشتیبان بر مبنای سری‌های زمانی دبی و بارش در ایستگاه‌های بالادست (مطالعه موردی: ایستگاه هیدرومتری تله زنگ). مدل سازی در مهندسی. ۱۶(۵۴): ۹۵-۱۰۴.

Adda, A., Hanini, S., Bezari, S., Laidi, M., & Abbas, M. (2022). Modeling and optimization of small-scale NF/RO seawater desalination using the artificial neural network (ANN). Environmental Engineering Research, 27(2).

ASCE Task Committee. (2000). The ASCE Task Committee on application of artificial neural networks in hydrology. J. Hydrol. Eng., American Society of Civil Engineers, 5(2), 115-136.

Asefa, T., Kembowski, M., Urroz, G., & McKee, M. (2005). Support vector machines (SVMs) for monitoring network design. Groundwater, 43(3), 413-422.

Asefa, T., Kembowski, M., McKee, M., & Khalil, A. (2006). Multi-time scale stream flow predictions: The support vector machines approach. Journal of hydrology, 318(1-4), 7-16.

Coppola Jr, E., Szidarovszky, F., Poulton, M., & Charles, E. (2003). Artificial neural network approach for predicting transient water levels in a multilayered groundwater system under variable state, pumping, and climate conditions. Journal of Hydrologic Engineering, 8(6), 348-360.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning, 20, 273-297.

Hamidi, O., Poorolajal, J., Sadeghfari, M., Abbasi, H., Maryanaji, Z., Faridi, H. R., & Tapak, L. (2015). A comparative study of support vector machines and artificial neural networks for predicting precipitation in Iran. Theoretical and applied climatology, 119, 723-731.

Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. Proceedings of the national academy of sciences, 79(8), 2554-2558.

Michalec, B., & Cupak, A. (2022). Assessment of quality of water and sediments in small reservoirs in Southern Poland-A case study. Environmental Engineering Research, 27(2).

Mirarabi, A., Nassery, H. R., Nakhaei, M., Adamowski, J., Akbarzadeh, A. H., & Aljani, F. (2019). Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. Environmental Earth Sciences, 78, 1-15.

Shiri, J., Kisi, O., Yoon, H., Lee, K. K., & Nazemi, A. H. (2013). Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques. Computers & Geosciences, 56, 32-44.

Suykens, J. A. K., Van Gestel, T., De Brabanter, J., De Moor, B., & Vandewalle, J. (2002). Least squares support vector machines, World Scientific Publishing, Singapore.

Todd, D.K. and Mays, L.W., (2004). Groundwater hydrology. John Wiley & Sons.

Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O., & Lee, K. K. (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. Journal of hydrology, 396(1-2), 128-138.