

Research Paper

Forecasting the Groundwater Level Decline in the Nahavand Aquifer Using a Combination of Complete Ensemble Empirical Mode Decomposition Preprocessing with LSTM and GMDH Models

Somaye Abdi¹, Hossein Fathian^{2*}, Mehdi Asadi Lour¹, Aslan Igernejad¹, Ali Asareh¹

1- Department of Irrigation and Drainage, Ahv.C., Islamic Azad University, Ahvaz, Iran.

2- Department of Water Resources Engineering, Ahv.C., Islamic Azad University, Ahvaz, Iran. ORCID: 0000-0002-0555-4454



10.22125/iwe.2026.539288.1893

Received:
August 3, 2025

Accepted:
????

Available online:
August 1, 2025

Keywords:
Groundwater level,
Nahavand aquifer,
CEEMD, artificial
intelligence models.

Abstract

Decreasing precipitation and excessive exploitation of groundwater resources have led to a significant decline in groundwater levels in many regions worldwide. One of the aquifers experiencing a noticeable groundwater level decline is the Nahavand aquifer, located in Hamedan Province in western Iran. To model groundwater level fluctuations, the Long Short-Term Memory (LSTM) model and the Group Method of Data Handling (GMDH) were employed. To improve model accuracy, the Complete Ensemble Empirical Mode Decomposition (CEEMD) preprocessing technique was applied, resulting in four models: LSTM, GMDH, CEEMD-LSTM, and CEEMD-GMDH. The results indicated that the GMDH model outperformed the LSTM model. Moreover, integrating both models with the CEEMD preprocessing technique significantly enhanced their performance. Specifically, the coefficient of determination (R^2) of the LSTM model increased from 0.867 to 0.950 in the CEEMD-LSTM model, while the R^2 of the GMDH model improved from 0.885 to 0.945 in the CEEMD-GMDH model. In addition, the evaluation of the Root Mean Square Error (RMSE) and the Akaike Information Criterion (AIC) demonstrated that the use of CEEMD preprocessing effectively reduced model errors. Based on these results, the CEEMD-LSTM hybrid model was identified as the best-performing model and was subsequently used to predict groundwater levels for the next six months (the first six months of the 1403–1404 water year). Overall, the findings suggest that the CEEMD-LSTM hybrid model provides highly satisfactory performance for modeling groundwater level variations in the Nahavand aquifer and has strong potential for application to other aquifers as well.

1. Introduction

In recent years, the decline in groundwater levels across the country's aquifers has intensified due to reduced precipitation, excessive groundwater abstraction, and recurrent droughts. One of the aquifers significantly affected by this phenomenon is the Nahavand aquifer, located in Hamedan Province in western Iran. In this study, monthly data on precipitation, temperature, evaporation, and groundwater levels were collected from available meteorological and observation stations over a 28-year period

(water years 1996–1997 to 2023–2024). Spatial distribution maps of precipitation, isotherms, and isoevaporation were generated. Based on the records of the observation wells in the Nahavand aquifer, 37 wells with sufficiently long and reliable statistical periods were selected. Groundwater level statistics were processed using HEC-4 software, and the period 1996–2024 was adopted for constructing the unit hydrograph. Outliers were identified using the box-plot method; when detected, they were removed and reconstructed using HEC-4. Subsequently, Thiessen polygons were created in a GIS environment to calculate the area of influence of each observation well, and the monthly groundwater unit hydrograph of the Nahavand aquifer was finally developed.

2. Materials and Methods

Inspection of the groundwater unit hydrograph revealed a clear declining trend, which can adversely affect model performance if used directly. To address this issue without altering the original data values, the temporal order of each dataset was randomly rearranged, thereby removing the trend and ensuring data randomness. The Mann–Kendall test was applied to evaluate randomness, and the results confirmed that the complete dataset, as well as the training and testing subsets, satisfied the randomness assumption. Groundwater level modeling was carried out using the Long Short-Term Memory (LSTM) neural network and the Group Method of Data Handling (GMDH). To enhance predictive accuracy, the Complete Ensemble Empirical Mode Decomposition (CEEMD) preprocessing technique was employed. Consequently, four modeling approaches were developed and evaluated: LSTM, GMDH, CEEMD-LSTM, and CEEMD-GMDH.

3. Results

Based on sensitivity analysis of the input variables, five different input combinations were considered for modeling with intelligent techniques. To comprehensively assess model performance and clearly identify the influence of input parameters, several evaluation criteria were employed, including the coefficient of determination (R^2), root mean square error (RMSE), and the Akaike information criterion (AIC).

4. Discussion and Conclusion

Model outputs were compared with observed groundwater levels derived from the unit hydrograph, and the optimal model was selected based on multiple statistical indicators. The results demonstrated that the GMDH model outperformed the LSTM model when used independently. Furthermore, incorporating the CEEMD preprocessing technique substantially improved the performance of both models. Specifically, the coefficient of determination (R^2) of the LSTM model increased from 0.867 to 0.950 in the CEEMD-LSTM framework, while the R^2 of the GMDH model improved from 0.885 to 0.945 in the CEEMD-GMDH model. In addition, reductions in RMSE and AIC values confirmed that the CEEMD preprocessing effectively decreased model errors. Based on these findings, the CEEMD-LSTM hybrid model was identified as the most reliable approach and was subsequently used to forecast groundwater levels for the next six months (the first half of the 2024–2025 water year). Overall, the results indicate that the CEEMD-LSTM model provides robust and accurate performance for groundwater level modeling in the Nahavand aquifer and shows strong potential for application to other aquifer systems.

5. Six important references

- 1) Shahbazi, M., H. Zarei, and A. Solgi. 2023 De-noising groundwater level modeling using data decomposition techniques in combination with artificial intelligence (case study Aspas aquifer). *Applied Water Science*, 13(88):1-18.
- 2) Bahmani, R., A. Solgi, and T.B.M.J. Ouarda. 2020. Groundwater level simulation using gene expression programming and M5 model tree combined with wavelet transform. *Hydrological sciences journal*, 65(8): 1430-1442.
- 3) Wang, Y., Z. Yuan, H. Liu, Z. Xing, Y. Ji, H. Li, Q. Fu, and C. Mo. 2022. A new scheme for probabilistic forecasting with an ensemble model based on CEEMDAN and AM-MCMC and its

- application in precipitation forecasting. *Expert Systems with Applications*, 187 (115872).
- 4) Lin, M.L., C.W. Tsai, and C.K. Chen. 2021. Daily maximum temperature forecasting in changing climate using a hybrid of Multi-dimensional Complementary Ensemble Empirical Mode Decomposition and Radial Basis Function Neural Network. *Journal of Hydrology: Regional Studies*, 38(1000923).
 - 5) Mirarabi, A., H.R. Nassery, M. Nakhaei, J. Adamowski, A.H. Akbarzadeh, and F. Alijani. Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 478 (489).
 - 6) Amirat, Y., M. Benbouzidb, T. Wang, K. Bacha, and G. Feld. 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133: 202-209.

Acknowledgments

The authors gratefully acknowledge the Hamadan Regional Water Company for providing the data required for this research.

پیش‌بینی افت سطح آب زیرزمینی آبخوان نهاوند با ترکیب پیش‌پردازش تجزیه مد

تجربی یکپارچه کامل با مدل‌های LSTM و GMDH

سمیه عبدی^۱، حسین فتحیان^۲، مهدی اسدی لور^۳، اصلا ن اگدرنژاد^۴، علی عصاره^۵

تاریخ ارسال: ۱۳/۰۵/۱۴۰۴

تاریخ پذیرش: ۱۰/۰۹/۱۴۰۴

مقاله پژوهشی

چکیده

کاهش بارندگی و بهره‌برداری بی‌رویه از منابع آب زیرزمینی موجب افت قابل‌توجه تراز سطح آب زیرزمینی در بسیاری از مناطق جهان شده است. یکی از آبخوان‌هایی که دارای افت سطح آب زیرزمینی است، آبخوان نهاوند در استان همدان و غرب ایران می‌باشد. برای مدلسازی تراز سطح آب زیرزمینی، مدل‌های حافظه کوتاه مدت طولانی (LSTM) و روش گروهی مدیریت داده (GMDH) به کار گرفته شد. به منظور افزایش دقت مدل‌ها از ابزار پیش‌پردازش تجزیه مد تجربی یکپارچه کامل (CEEMD) استفاده شد و در نهایت چهار مدل LSTM، GMDH، CEEMD-LSTM و CEEMD-GMDH حاصل شدند. نتایج نشان داد که مدل GMDH عملکرد بهتری نسبت به مدل LSTM داشته است. همچنین ترکیب این دو مدل با ابزارهای پیش‌پردازش CEEMD موجب افزایش عملکرد آنها شده است. به طوری که ضریب تعیین مدل LSTM از ۰/۸۶۷ به ۰/۹۵۰ در مدل CEEMD-LSTM ارتقاء یافته است. ضریب تعیین در مدل GMDH با ۰/۸۸۵ به ۰/۹۴۵ در مدل CEEMD-GMDH رسیده است. همچنین بررسی جذر میانگین مربعات خطا (RMSE) و معیار اطلاعاتی آکائیک (AIC) هم نشان می‌دهد که استفاده از ابزار پیش‌پردازش CEEMD موجب کاهش خطای مدل‌ها شده است. با توجه به این نتایج مدل ترکیبی CEEMD-LSTM بهترین مدل شناخته شده و از آن برای پیش‌بینی تراز سطح آب زیرزمینی برای شش ماه آتی (شش ماه اول سال آبی ۱۴۰۳-۱۴۰۴) استفاده شد. به طور کلی می‌توان گفت که عملکرد مدل ترکیبی CEEMD-LSTM برای مدل‌سازی تراز سطح آب زیرزمینی آبخوان نهاوند بسیار مناسب بوده و قابلیت این را دارد که برای بررسی سطح آب زیرزمینی آبخوان‌های دیگر نیز استفاده شود.

کلیدواژه‌ها: سطح آب زیرزمینی، آبخوان نهاوند، CEEMD، مدل‌های هوش مصنوعی.

^۱ دانشجوی دکترا، گروه آبیاری و زهکشی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران ایمیل: abdi.s202020@gmail.com

^۲ استادیار، گروه مهندسی منابع آب، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران. ایمیل: fathian.h58@gmail.com

^۳ استادیار، گروه آبیاری و زهکشی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران ایمیل: asadi.m@gmail.com

^۴ استادیار، گروه آبیاری و زهکشی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران. ایمیل: igdernejad.e@gmail.com

^۵ استادیار، گروه آبیاری و زهکشی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران. ایمیل: asare.a@gmail.com



مقدمه

و پیش‌بینی سطح آب زیرزمینی باشند تا با استفاده از این برآوردها بتوانند وضعیت آب زیرزمینی را به صورت دقیق-تر و بهتری بررسی نمایند. ضرورت استفاده از تجهیزات و امکانات جدید و به روز، مقوله اجتناب‌ناپذیری است که بشر در بسیاری از علوم پیش روی خود می‌بیند. یکی از مزایای این ابزارهای جدید می‌توان کاهش زمان پیش-بینی‌ها و افزایش دقت مدل‌ها باشد. برای این منظور نیاز است که بتوان نتایج این ابزارها را با مقادیر حاصل از داده-های مشاهداتی مورد بررسی قرار داد. در ادامه به برخی از این مطالعات اشاره می‌گردد:

ستاری و همکاران (۲۰۱۷) برای پیش‌بینی سطح آب زیرزمینی در دشت اردبیل از مدل‌های رگرسیون بردار پشتیبان^۱ (SVR) و مدل درختی M5 استفاده کردند. نتایج آنها نشان داد که عملکرد هر دو مدل خوب بوده ولی استفاده از مدل M5 راحت‌تر و تفسیر آن آسان‌تر می‌باشد. میرعربی و همکاران (۲۰۱۹) ارزیابی مدل‌های SVR و شبکه عصبی مصنوعی^۲ (ANN) را برای پیش‌بینی سطح آب زیرزمینی انجام دادند. نتایج نشان داد که عملکرد مدل SVR بهتر از شبکه عصبی مصنوعی بوده است.

مجاهد و همکاران (۲۰۲۰) با استفاده از مدل شبکه عصبی مصنوعی، ارتباط بین پارامترهای هواشناسی با سطح آب زیرزمینی موجود در محدوده رودخانه راوی و سوتلج را بررسی کردند. در این تحقیق از پارامترهای هواشناسی (داده‌های بارندگی (R)، حداکثر دما (Max.T)، حداقل دما (Min.T)، تابش خورشیدی (S.R)، باد (W)، رطوبت نسبی (R.H)، ارتفاع سطح (E)، ناحیه چند ضلعی (A) و عمق سطح آب (D/W) استفاده شد. براساس نتایج همبستگی بین سطوح آب زیرزمینی با پارامترهای هواشناسی مشاهده شد که میزان بارندگی در مقایسه با هر پارامتر دیگری برای سایت انتخاب شده، تأثیر بیشتری بر تغییرات سطح آب زیرزمینی دارد.

کی همایون و همکاران (۲۰۲۱) رویکرد جدید برای پیش‌بینی تلفات ذخیره‌سازی آب زیرزمینی با استفاده از

کاهش بارندگی و برداشت بیش از حد از منابع آب زیرزمینی در سالیان گذشته، باعث وارد شدن فشار بیش از حد به منابع آب زیرزمینی شده است. این امر موجب افت تراز سطح آب زیرزمینی در آبخوانهای ایران شده است. طی یک دوره خشک، قابلیت تبخیر و تعرق افزایش می‌یابد و پس از یک دوره زمانی کوتاه، مقدار ذخیره رطوبت خاک تحت تأثیر این شرایط شروع به کاهش می‌کند. در نتیجه تغذیه سیستم آب زیرزمینی کم شده و سطح تراز آب چاه‌ها ممکن است یکسال یا بیشتر پس از شروع خشکسالی به کمبود بارندگی واکنش نشان دهد (Moustadraf et al., 2003). این مسئله می‌تواند روی جریان سطحی نیز که وابسته به آب‌های زیرزمینی منطقه است، تأثیرگذار باشد (Havril et al., 2018; Van Loon et al., 2013). آثار تهنی‌شدگی سفره‌های آب زیرزمینی پیچیده و وابسته به آبخوان است، اما مشکلات بسیاری در این شرایط متداول است که مهمترین آنها کاهش سطح ایستابی است که خود باعث افزایش هزینه پمپاژ و خشک شدن چاه‌های آب می‌شود (Mukul Fishman et al., 2011). از دیگر آثار آن می‌توان به کاهش تخلیه آب زیرزمینی به رودخانه‌ها و چشمه‌ها، تأثیر بر اکوسیستم‌های موجود و نیز فرونشست زمین اشاره کرد (Sophocleous, 2000). کاهش سطح آب زیرزمینی همچنین می‌تواند باعث افزایش شوری از طریق نفوذ آب شور دریا به آبخوان‌های ساحلی یا نشت از لایه‌های مجاور حاوی آب شور شود (Konikow & Kendy, 2005).

با توجه به اینکه آب مصرفی برای بخش قابل توجهی از مردم ایران از منابع آب زیرزمینی تأمین می‌شود، بررسی و مطالعه این‌گونه آب‌ها، یکی از چالش‌هایی است که در چند سال گذشته در جهت برطرف نمودن مشکلات تأمین منابع آبی مطرح شده است. افت سطح آب زیرزمینی در سال‌های گذشته، سبب شده است که پژوهشگران مختلف در سراسر جهان به دنبال راهکارهای مختلفی برای برآورد

¹-Support vector regression

²-Artificial neural network

دهنده تأیید و اصلاح کنترل برداشت در تغییرات سطح ایستابی آبخوان می‌باشد. به دلیل کم بودن تغذیه مستقیم آبخوان افزایش یا کاهش بارش‌ها تأثیر زیادی در بیلان دشت و تغییرات سطح ایستابی ندارند. نتایج مدل‌سازی نشان می‌دهد به منظور برقراری تعادل در آبخوان بهاباد، مجموع برداشت از آبخوان بایستی به $58/8$ میلیون متر مکعب در سال کاهش یابد.

ندیری و همکاران (۱۳۹۵) پیش‌بینی زمانی و مکانی سطح آب زیرزمینی آبخوان دوزدوزان را با استفاده از روش‌های هوش مصنوعی و زمین آمار انجام دادند. پس از نرمال‌سازی داده‌ها مدل‌سازی با شبکه‌های عصبی مصنوعی^۵ (ANNs) انجام شد. به منظور بررسی بیشتر شبیه‌سازی با مدل فازی ساگنو (SFL) نیز انجام شد. با توجه به برتری مدل ANNs، مدل کریجینگ و کوکریجینگ عصبی برای پیش‌بینی مکانی سطح ایستابی انتخاب شدند و پیش‌بینی مکانی با هر دو مدل انجام شد. نتایج نشان داد که مدل کوکریجینگ با در نظر گرفتن پارامتر ثانویه توپوگرافی نسبت به مدل کریجینگ پیش‌بینی دقیق‌تری داشته است.

یاری و درزی نفت چالی (۱۳۹۶) به بررسی پیش‌بینی نوسانات سطح آب زیرزمینی با استفاده از مدل MODFLOW پرداختند. مدل به ترتیب به پارامترهای آبدهی ویژه، هدایت هیدرولیکی، تغذیه و تخلیه بیشترین حساسیت را نشان داد. بر اساس نتایج مدل، بهترین سناریو برای تعادل بخشی و احیاء آب زیرزمینی، تغذیه مصنوعی با استفاده از پساب تا افق ۱۴۰۰ می‌باشد.

پناهی و همکاران (۱۳۹۷) شبیه‌سازی و تخمین نوسانات سطح آب زیرزمینی دشت زنگان را با استفاده از GMS مورد بررسی قرار دادند. مقادیر ریشه مربع میانگین خطا و میانگین خطا به ترتیب با مقادیری برابر با $26/29$ و $8/43$ - نشان‌دهنده دقت نسبتاً خوب مدل است. طبق محاسبه تراز آب برای مدل، جریان آب‌های زیرزمینی از جنوب شرقی به شمال غربی است که این جریان با شیب غالب منطقه مطابقت دارد. مدل با فرض نرخ کاهش آب‌های زیرزمینی و مقدار ثابت تغذیه برای فاصله زمانی

یادگیری ماشین ارائه دادند. از بین متغیرهای مورد بررسی، مصرف آب کشاورزی، سطح آبخوان، نفوذ از رودخانه و زهکش به ترتیب با همبستگی $0/79$ ، $0/70$ و $0/69$ با تلفات ذخیره‌سازی آب زیرزمینی ارتباط زیادی داشتند. سیستم استنتاج عصبی-فازی تطبیقی بهینه‌سازی هریس هاکس^۱ (HHO-ANFIS) و ماشین بردار پشتیبان حداقل مربعات^۲ (LS-SVM) بهترین نتایج را ارائه کردند. به طور کلی، HHO-ANFIS برای پیش‌بینی تلفات ذخیره‌سازی آب زیرزمینی کارآمدتر بود. بنابراین، روش‌های هوش مصنوعی و یادگیری ماشین می‌توانند در زمان و هزینه‌ها برای این محاسبات پیچیده صرفه‌جویی کنند.

آدرمی و همکاران (۲۰۲۳) از مدل‌های یادگیری ماشینی مانند مدل‌های رگرسیون، مدل‌های رگرسیون خودکار عمیق^۳ و شبکه‌های عصبی اتورگرسیو غیرخطی با ورودی خارجی^۴ (NARX) برای پیش‌بینی سطح آب زیرزمینی در کمربند کارست در آفریقای جنوبی استفاده کردند. نتایج نشان داد که NARX و ماشین بردار پشتیبان عملکرد بهتری نسبت به سایر مدل‌های مورد استفاده دارند.

خطیبی‌نیا (۱۳۹۴) پیش‌بینی نوسانات سطح آب زیرزمینی آبخوان بهاباد را با استفاده از مدل عددی مورد بررسی قرار داد. تحلیل حساسیت مدل نشان دهنده بیش‌ترین حساسیت نسبت به تغییرات هدایت هیدرولیکی می‌باشد. پیش‌بینی صورت گرفته بر اساس مدل واسنجی و صحت سنجی شده آبخوان مورد مطالعه برای سال‌های آینده (فروردین ۹۴ تا اسفند ۹۹) نشان می‌دهد که با ادامه روند کنونی برداشت آب، سطح آب زیرزمینی در انتهای دوره مورد پیش‌بینی به ویژه در نواحی با تمرکز زیاد چاه‌های بهره برداری، با افت شدیدی ($3/2$ متر در طول پنج سال) مواجه خواهد شد. بررسی سناریوهای مختلف مرتبط با تغییرات اقلیمی و مدیریتی در آبخوان بهاباد نشان

¹-Harris Hawks optimization adaptive neuro-fuzzy inference system

²-Least-squares support vector machine

³-Deep auto-regressive

⁴-Nonlinear autoregressive neural networks with external input

⁵-Artificial neural network



تخلیه از چاه‌ها در مدل‌سازی‌ها موجب بهبود نتایج در چاه‌های مشاهده‌ای گردید که نشان می‌دهد این داده‌ها بر تراز آب زیرزمینی تأثیرگذار بوده که با توجه به کاهشی بودن روند کلی تغییرات آب زیرزمینی دشت قم می‌توان چنین استنباط کرد، تخلیه از چاه‌ها به‌عنوان مهم‌ترین عامل کاهش تراز آب زیرزمینی این دشت است.

سلیمان‌پور و همکاران (۱۴۰۴) روند تغییرات دوره‌ای سطح آب زیرزمینی حوزه آبخیز بهادران در استان یزد را ارزیابی کردند. مطابق نتایج، بیش‌ترین عمق آب زیرزمینی در آبخوان‌های بهادران و شمس در سال ۱۳۹۷ به ترتیب برابر با ۶۸ و ۴۷/۷ متر است که در نواحی شمالی آبخوان بهادران و جنوبی آبخوان شمس به حداکثر مقدار رسیده و به سمت نواحی جنوبی آبخوان بهادران و بخش‌های شرقی- غربی آبخوان شمس از عمق آب کاسته شده است، به‌طوری‌که کم‌ترین عمق آب زیرزمینی در هر دو آبخوان به حدود ۱۱/۸ متر می‌رسد.

ابزار پیش پردازش تجزیه مدتجربی^۱ (EMD) در رشته‌های مختلف در سال‌های گذشته، مورد توجه قرار گرفته‌اند. به طوری‌که ترکیب این ابزار با مدل‌های مختلف سبب ارائه مدل‌های ترکیبی با دقت بالاتری شده است. روش تجزیه مدتجربی روشی کاملاً موثر برای استخراج سیگنال از داده‌ها می‌باشد و برای تجزیه سیگنال در حوزه زمان-فرکانس کاربرد دارد (Huang et al., 2009). روش تجزیه مدتجربی یکپارچه کامل^۲ (CEEMD) روشی کامل شده EMD می‌باشد. سانگ و همکاران (۲۰۱۲) از روش EMD برای تحلیل داده‌های غیرخطی در هیدرولوژی استفاده کردند.

با توجه به ماهیت غیرخطی، غیرایستا و چندمقیاسی داده‌های تراز سطح آب زیرزمینی، استفاده از روش‌های پیش‌پردازش سیگنال نقش مهمی در افزایش دقت مدل‌های پیش‌بینی دارد. در مطالعات پیشین، روش‌هایی مانند تبدیل موجک^۳ برای تجزیه سری‌های زمانی هیدرولوژیکی به‌کار گرفته شده اند (Torrence &

۱۵ ساله از سال ۲۰۰۷ تا ۲۰۲۲ اجرا شد که نقشه‌های به‌دست‌آمده برای تراز آب‌های زیرزمینی در این سال‌ها نشان‌دهنده افت شدید تراز آب با ادامه برداشت‌های بی‌رویه از ذخیره آب‌های زیرزمینی آبخوان زنجان است. جمالی‌زاده و همکاران (۱۳۹۹) پیش‌بینی نوسانات سطح آب زیرزمینی دشت رفسنجان را با استفاده از مدل- های سری زمانی و GMS مورد بررسی قرار دادند. نتایج شبیه‌سازی افت آب زیرزمینی نیز نشان داد در تمامی منطقه افت سطح آب زیرزمینی در دوره آتی نسبت به دوره پایه رخ داده و بیشترین میزان افت آب زیرزمینی در بخش‌های جنوب غرب دشت صورت گرفته است و سالیانه حدود ۱۳۰ میلیون مترمکعب اضافه برداشت از منابع آب زیرزمینی صورت می‌گیرد.

خیاط و همکاران (۱۴۰۰) پیش‌بینی سطح آب زیرزمینی دشت بیرجند را با استفاده از شبکه عصبی- فازی تحت تأثیر تغییر اقلیم مورد بررسی قرار دادند. در راستای این هدف به منظور ارزیابی اثرات تغییر اقلیم، ۲۶ پارامتر خروجی مدل گردش عمومی جو کانادا (CanESM2 AR5) و سناریوی انتشار RCP4.5 به عنوان پیش‌فرض‌های این تحقیق استفاده شده است. همچنین به منظور ریز مقیاس نمائی داده‌های اقلیمی روزانه جهت تولید سناریوهای اقلیمی منطقه‌ای از مدل SDSM استفاده گردید. برای بررسی تغییرات و پیش‌بینی تراز آب زیرزمینی از شبکه عصبی فازی تطبیقی (ANFIS) بهره گرفته شد. نتایج تحقیق حاکی از سیر نزولی و افت قریب به ۳/۵ متر در سطح آب زیرزمینی دشت بیرجند طی سال‌های آینده تا سال ۲۰۳۷ می‌باشد. همچنین نتایج حاکی از افزایش کمی در تراز آب زیرزمینی طی سال‌های ۲۰۳۹-۲۰۴۰ می‌باشد. با توجه به اهمیت آب زیرزمینی در تأمین مصارف آب در منطقه، مدیریت بهینه و هوشمند منابع آب زیرزمینی و اصلاح الگوی مصرف ضروری بنظر می‌رسد.

سلامتیان و همکاران (۱۴۰۲) تراز آب زیرزمینی دشت قم را با استفاده از مدل سیستم استنتاج فازی عصبی تطبیقی پیش‌بینی کردند. تعداد نه چاه مشاهده‌ای در محدوده دشت قم انتخاب گردید. استفاده از داده‌های

¹-Empirical mode decomposition

²-Complementary ensemble empirical mode decomposition

³-Wavelet Transform

بررسی سطح آب زیرزمینی در آبخوان اسپاس استفاده شد. نتایج نشان داد که مدل‌های هوشمند دارای عملکرد بهتری نسبت به محصولات ماهواره گریس بوده‌اند. جهت پیش‌بینی مقادیر سطح آب زیرزمینی استفاده از مدل هوشمند CEEMD-SVR مناسب‌تر می‌باشد.

با وجود مطالعات متعدد داخلی و خارجی در زمینه پیش‌بینی سطح آب زیرزمینی با استفاده از مدل‌های هوش مصنوعی و ابزارهای تجزیه سیگنال، بررسی منابع نشان می‌دهد که تاکنون پژوهشی که به‌صورت همزمان به ترکیب روش تجزیه مد تجزیه یکپارچه کامل (CEEMD) با دو مدل داده‌محور متفاوت شامل شبکه حافظه کوتاه‌مدت طولانی (LSTM) و روش گروهی مدیریت داده (GMDH) پرداخته باشد، انجام نشده است. نوآوری اصلی این پژوهش در ارائه و مقایسه نظام‌مند چهار چارچوب مدل‌سازی شامل LSTM، GMDH، CEEMD-LSTM و CEEMD-GMDH به‌منظور بررسی نقش ابزار پیش‌پردازش CEEMD در بهبود عملکرد مدل‌ها برای شبیه‌سازی تراز سطح آب زیرزمینی می‌باشد. افزون بر این، برخلاف بسیاری از مطالعات پیشین که بر داده‌های نقطه‌ای یا تک‌چاه متمرکز بوده‌اند، در این تحقیق از هیدروگراف واحد استخراج‌شده از تمامی چاه‌های مشاهده‌ای منطقه استفاده شده است تا نماینده‌ای جامع از رفتار هیدرودینامیکی کل آبخوان نهادند ارائه گردد. همچنین، به‌کارگیری همزمان معیارهای آماری و اطلاعاتی از جمله ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE) و معیار اطلاعاتی آکائیک (AIC) امکان ارزیابی دقیق‌تر و منصفانه‌تر مدل‌ها را فراهم نموده و در نهایت، مدل برتر برای پیش‌بینی تراز سطح آب زیرزمینی در دوره شش‌ماهه آبی به‌کار گرفته شده است. افت شدید سطح آب زیرزمینی آبخوان نهادند در حوضه کرخه در سال‌های گذشته باعث شد که در این تحقیق به بررسی وضعیت سطح آب زیرزمینی این آبخوان پرداخته شود. بدین ترتیب، نتایج این پژوهش می‌تواند به‌عنوان چارچوبی کارآمد برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی در سایر آبخوان‌ها نیز مورد استفاده قرار گیرد.

(Compo, 1998) با این حال، تبدیل موجک نیازمند انتخاب تابع پایه و سطح تجزیه از پیش تعیین‌شده است که این انتخاب‌ها می‌توانند ذهنی بوده و بر نتایج مدل‌سازی اثرگذار باشند. در مقابل، CEEMD توانایی بالاتری در استخراج نوسانات چندمقیاسی و تفکیک مؤلفه‌های نویزی از سیگنال اصلی دارد و در مقایسه با روش‌هایی مانند تبدیل موجک، گزینه‌ای مناسب‌تر برای تحلیل سری‌های زمانی پیچیده و غیرایستای سطح آب زیرزمینی محسوب می‌شود (Yeh et al., 2010). از این‌رو، در پژوهش حاضر از روش CEEMD به‌عنوان ابزار پیش‌پردازش داده‌ها به‌منظور بهبود عملکرد مدل‌های هوش مصنوعی در شبیه‌سازی و پیش‌بینی تراز سطح آب زیرزمینی آبخوان نهادند استفاده شده است.

در ادامه به برخی از مطالعات در زمینه کاربرد این ابزار پیش‌پردازش پرداخته می‌شود:

بهمنی و کوارتا (۲۰۲۰) مدل‌سازی سطح آب زیرزمینی را با ترکیب با تکنیک‌های هوش مصنوعی ارائه دادند. آنها برای این مطالعه از ۴ حلقه چاه مشاهده‌ای در دشت دلفان در ایران استفاده کردند. آنها مدل‌های برنامه ریزی بیان ژن^۱ (GEP) و M5 را با تکنیک‌های تبدیل موجک و CEEMD ترکیب کردند. نتایج نشان داد که مدل ترکیب شده با GEP عملکرد بهتری داشته است.

شهبازی و همکاران (۲۰۲۳) مدل‌سازی سطح آب زیرزمینی آبخوان اسپاس را با استفاده از تکنیک‌های تجزیه داده و ترکیب با مدل‌های هوش مصنوعی انجام دادند. در این مطالعه دو مدل ANN و رگرسیون بردار پشتیبان (SVR)، با دو ابزار پیش‌پردازش، WT و CEEMD مورد استفاده قرار گرفتند. بر اساس نتایج، مدل ترکیبی CEEMD-ANN دقیق‌ترین روش برای پیش‌بینی سطح آب زیرزمینی در سفره‌های آب، به‌ویژه سفره آب زیرزمینی اسپاس، شناخته شده است.

شهبازی و همکاران (۱۴۰۱) عملکرد مدل‌های مبتنی بر تجزیه داده و داده‌های ماهواره گریس را برای مدل‌سازی سطح آب زیرزمینی آبخوان اسپاس مورد ارزیابی قرار دادند. در این پژوهش از ترکیب با مدل SVR برای

¹-Gene Expression Programming (GEP)



مواد و روش‌ها

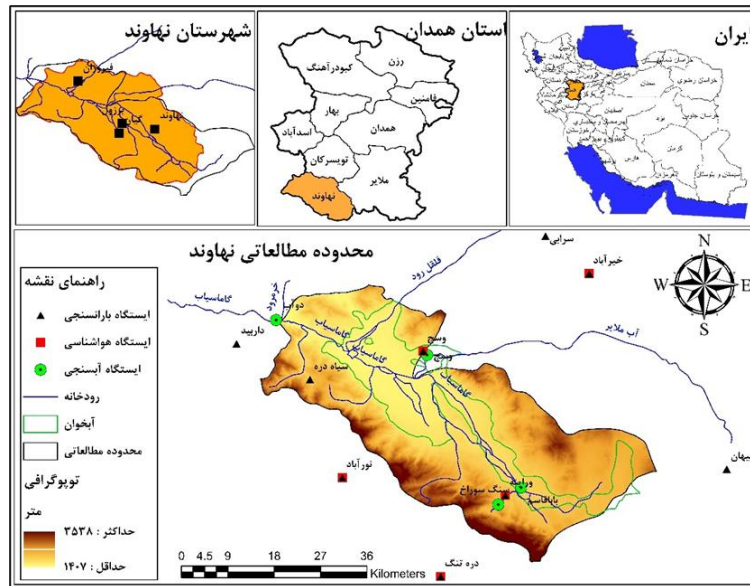
منطقه مورد مطالعه

محدوده مطالعاتی نهاوند با کد ۲۲۳۳ در شمال شرقی حوضه کرخه واقع شده و تحت نظارت شرکت سهامی آب منطقه‌ای همدان است. این محدوده دارای مساحت ۱۷۷۹/۲ کیلومتر مربع بوده و آبخوان اصلی آن از نوع آبرفتی است که بخش عمده آن از رسوبات ماسه‌ای و شن‌های دانه‌درشت تشکیل شده است. مساحت آبخوان آبرفتی نهاوند ۵۰۲/۲ کیلومتر مربع می‌باشد. عمق تراز ایستابی در نقاط مختلف آبخوان متغیر است و حداقل و حداکثر تراز ایستابی به ترتیب در حدود ۵ تا ۳۵ متر می‌رسد. آبخوان نهاوند به صورت نیمه‌متمرکز تغذیه می‌شود؛ تغذیه سطحی از طریق نفوذ آب رودخانه گاماسیاب و بارش‌های منطقه صورت می‌گیرد و تغذیه زیرسطحی محدود به جریان‌های فصلی و آب‌های نفوذی از ارتفاعات اطراف است. هدایت هیدرولیکی آبخوان در محدوده ۱ تا ۳۵ متر در روز قرار دارد. بررسی توپوگرافی و شیب زمین نشان می‌دهد که جریان آب زیرزمینی

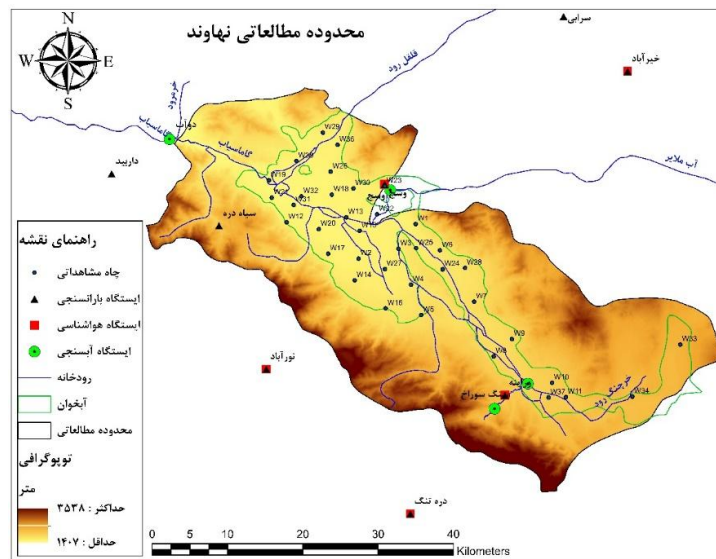
عمدتاً از جنوب غرب به شمال شرق حرکت می‌کند و سطح ایستابی تحت تأثیر تغییرات بارش و برداشت از چاه‌ها نوسانات قابل توجهی دارد. این ویژگی‌ها، ساختار و رفتار دینامیک آبخوان را به‌طور جامع توصیف می‌کند و پایه‌ای برای انتخاب مدل‌های هوش مصنوعی و ابزارهای پیش‌پردازش داده‌ها برای شبیه‌سازی و پیش‌بینی تراز سطح آب زیرزمینی فراهم می‌نماید. حداکثر ارتفاع در این محدوده ۳۵۳۸ متر، در ارتفاعات رشته کوه گرین، در جنوب غربی محدوده و حداقل آن ۱۴۰۷ متر، در قسمت خروجی محدوده، روی رودخانه گاماسیاب می‌باشد. در این محدوده، شهرهای نهاوند، برزول، گیان و فیروزان قرار دارند. در جدول (۱) مشخصات ایستگاه‌های آبسنجی و ایستگاه‌های هواشناسی که در داخل و اطراف محدوده مطالعاتی نهاوند قرار دارند، ارائه شده است. در شکل (۱) موقعیت محدوده مطالعاتی نهاوند در حوضه آبریز کرخه، استان همدان و کشور ایران نشان داده شده است. در شکل (۲) موقعیت چاه‌های مشاهداتی به همراه ایستگاه‌های بارانسنجی، هواشناسی و آبسنجی نشان داده شده است.

جدول (۱): مشخصات ایستگاه‌های مورد استفاده.

نام ایستگاه	متغیر	کد ایستگاه	طول جغرافیایی (متر)	عرض جغرافیایی (متر)	ارتفاع از سطح دریا (متر)
سیاه دره	بارش (میلیمتر)	۲۱-۷۱۲	۷۷۴۹۳۷	۳۷۹۵۹۴۵	۱۷۵۷
سرابی		۲۱-۸۸۲	۲۶۸۲۵۲	۳۸۲۳۷۸۹	۱۹۲۵
پیهان		۲۱-۹۸۱	۳۰۳۴۵۵	۳۷۷۸۶۳۵	۱۸۷۰
داربید		۲۱-۵۴۶	۷۶۰۳۰۲	۳۸۰۲۰۰۳	۱۸۶۰
وراینه	بارش (میلیمتر)، دما	۲۱-۵۳۴	۲۶۰۴۶۲	۳۷۷۳۵۷۵	۱۷۹۵
وسج	(سانتیگراد)، تبخیر	۲۱-۳۷۵	۲۴۴۴۹۵	۳۸۰۱۵۳۱	۱۵۶۶
دره تنگ الشتر	(میلیمتر)	۲۱-۹۵۴	۲۴۷۹۰۷	۳۷۵۷۸۳۷	۱۷۳۰
نورآباد		۲۱-۱۴۵	۲۲۸۷۹۳	۳۷۷۷۰۲۳	۱۸۲۰
خیرآباد		۲۱-۰۳۲	۲۷۶۷۵۳	۳۸۱۶۵۲۰	۱۷۷۰



شکل (۱): موقعیت محدوده مطالعاتی نهاوند در استان همدان، حوضه آبریز کرخه و کشور ایران.



شکل (۲): موقعیت چاه‌های مشاهده‌ای در محدوده مطالعاتی نهاوند

آماده‌سازی داده‌ها

داده‌های این مطالعه، شامل داده‌های بارش و دما، تبخیر ایستگاه‌های هواشناسی و داده‌های چاه‌های مشاهده‌ای از شرکت آب منطقه‌ای استان همدان اخذ گردید. با توجه به داده‌های چاه‌های مشاهده‌ای در آبخوان نهاوند، ۳۷ چاه مشاهده‌ای که دارای دوره آماری بهتری بودند، انتخاب گردید. بعد از تکمیل آمار سطح آب زیرزمینی در چاه‌های مشاهده‌ای با استفاده از نرم افزار

HEC-4، دوره آماری ۲۸ ساله (۱۴۰۳-۱۳۷۵) برای ترسیم هیدروگراف واحد انتخاب شد. به منظور بررسی داده‌های پرت از روش نمودار جعبه‌ای (باکس پلات)^۱ استفاده شد. در صورت مواجهه با داده‌های پرت، آن داده‌ها حذف و دوباره با نرم‌افزار HEC-4 بازسازی شدند. برای

^۱-Box plot

بررسی داده‌های پرت آنها، نقشه‌های هم تبخیر ماهانه برای محدوده مطالعاتی ترسیم شد. سپس مقادیر تبخیر ماهانه برای آبخوان نهانند استخراج شد.

نمودار جعبه‌ای

در روش نمودار جعبه‌ای، چارک‌ها مشخص شده و مقادیر بیشتر و کمتر از رابطه (۱) به عنوان داده پرت شناخته می‌شوند. Q_3 چارک سوم ($x_{0.75}$) و Q_1 چارک اول ($x_{0.25}$) می‌باشد (Asikoglu, 2017). IQR طول جعبه می‌باشد (شکل (۳)).

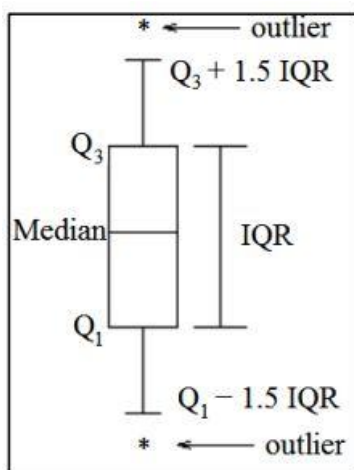
ترسیم نقشه‌ها از نرم‌افزار GIS و روش کریجینگ استفاده شد.

نقشه‌های هم‌بارش ماهانه برای محدوده مطالعاتی نهانند ترسیم شد. سپس مقادیر بارش ماهانه برای محدوده مطالعاتی و آبخوان نهانند استخراج گردید. برای بررسی داده‌های دما و تطویل آنها از روش تفاضلات استفاده شد. بعد از بررسی داده‌های پرت، نقشه‌های هم دمای ماهانه برای محدوده مطالعاتی نهانند ترسیم شد. سپس مقادیر دمای ماهانه برای آبخوان نهانند استخراج گردید. برای بررسی داده‌های تبخیر و تطویل آنها از رابطه بین دما و تبخیر برای هر ایستگاه استفاده شد. بعد از

$$x < Q_1 - 1.5IQR \quad \text{or} \quad (1)$$

$$x > Q_3 + 1.5IQR$$

$$IQR = Q_3 - Q_1 \quad (2)$$



شکل (۳): نمودار جعبه‌ای

معیارهای ارزیابی روش‌ها

با توجه به اینکه در ارزیابی عملکرد روش‌ها بایستی پارامترهای کمی و کیفی مختلفی بررسی گردد تا میزان تأثیرگذاری هر پارامتر ورودی روی نتایج به وضوح مشاهده شود از معیارهای زیر در ارزیابی کارایی روش‌ها استفاده شده است.

R^2 : ضریب تعیین^۱

RMSE: جذر میانگین مربعات خطا^۲

استاندارد سازی داده‌ها

برای استانداردسازی داده‌ها قبل از استفاده، از رابطه

(۳) استفاده شد (سلگی، ۱۳۹۳).

$$y = 0.5 + \left(0.5 \times \frac{x - \bar{x}}{x_{\max} - x_{\min}} \right) \quad (3)$$

که در این رابطه X داده مورد نظر، \bar{X} میانگین داده‌ها، X_{\max} حداکثر داده‌ها، X_{\min} حداقل داده‌ها و y داده استاندارد شده می‌باشد.

¹-Coefficient of determination

²-Root mean square error

افزار با وارد اطلاعات و با کدنویسی در محیط نرم افزار می-
توان مدل های هوشمند، LSTM و GMDH را اجرا نمود.
برای تجزیه داده ها با روش تجزیه مد تجربی یکپارچه
کامل از نرم افزار آماری R استفاده می شود. سپس برای
اجرای مدل های ترکیبی، از نرم افزار MATLAB کمک
گرفته می شود. نرم افزار پر کاربرد دیگر، سیستم اطلاعات
جغرافیایی (GIS)^۲ می باشد که برای ترسیم نقشه های
مختلف مورد استفاده قرار می گیرد.

مدل حافظه کوتاه مدت طولانی (LSTM)

شبکه ی عصبی LSTM یا حافظه ی کوتاه مدت
طولانی^۳، نوعی خاص از شبکه عصبی بازگشتی (RNN)^۴
محسوب می شود. شبکه ی عصبی بازگشتی، نوعی شبکه
عصبی مصنوعی است که حافظه ی داخلی دارد، به عبارت
دیگر، این شبکه یک شبکه ی عصبی معمولی است که در
ساختارش حلقه ای دارد که از طریق آن در هر گام،
خروجی گام قبلی، به همراه ورودی جدید، به شبکه وارد
می شود. این حلقه به شبکه کمک می کند تا اطلاعات قبلی
را در کنار اطلاعات جدید داشته باشد و بتواند براساس این
اطلاعات خروجی مدنظر را به ما بدهد. این ویژگی شبکه ی
عصبی بازگشتی، این امکان را می دهد که بتوان با داده های
ترتیبی^۵، مانند متن، صدا و غیره، کار نمود. شبکه ی
عصبی بازگشتی در مسائلی که نیاز باشد حافظه ی
بلندمدت داشته باشد نمی تواند خیلی خوب عمل کند،
دلیل این موضوع مفهومی به نام محوشدگی گرادیان^۶ است.
این مسئله باعث به وجود آمدن شبکه LSTM شده است.
شبکه ی LSTM نوع خاصی از شبکه ی عصبی
بازگشتی است که مشکل حافظه ی بلندمدت
شبکه ی RNN را حل می کند. شبکه ی LSTM
سازوکارهایی داخلی به اسم گیت^۷ دارد. این گیت ها جریان

AIC: معیار اطلاعاتی آکائیک^۱

$$R^2 = \frac{(\sum_{i=1}^n (G_{i_{obs}} - \bar{G}_{i_{obs}})(G_{i_{pre}} - \bar{G}_{i_{pre}}))^2}{\sum_{i=1}^n (G_{i_{obs}} - \bar{G}_{i_{obs}})^2 \sum_{i=1}^n (G_{i_{pre}} - \bar{G}_{i_{pre}})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (G_{i_{obs}} - G_{i_{pre}})^2}{n}} \quad (5)$$

$$AIC = m \times \ln(RMSE) + 2(Npar) \quad (6)$$

n: تعداد داده ها، $G_{i_{obs}}$: داده های مشاهداتی، $\bar{G}_{i_{obs}}$:
میانگین داده های مشاهداتی، $G_{i_{pre}}$: داده های محاسباتی،
 $\bar{G}_{i_{pre}}$: میانگین داده های محاسباتی، m: تعداد پارامترهای
مدل و Npar: تعداد داده های آموزش دیده میباشند.
ضریب تعیین (R^2) میزان انطباق داده هایی که توسط مدل
به وجود می آید و داده های واقعی را نشان می دهد و هر
چقدر این ضریب به عدد یک نزدیکتر باشد بیانگر این
است که این انطباق بهتر صورت گرفته و میزان خطای
حاصله کمتر می باشد لذا در همه حالات برای بررسی
میزان تأثیرگذاری هر پارامتر بر روی عملکرد مدل ها از این
عامل استفاده شده است. همچنین پارامتر جذر میانگین
مربعات خطا (RMSE) خطای داده های محاسباتی و
مشاهداتی را بیان می کند. واضح است که هر چه مقدار
این عدد کمتر باشد به تبع، آموزش و شبیه سازی داده ها
بهتر صورت گرفته است. در مورد معیار اطلاعاتی آکائیک
(AIC) نیز می توان گفت که هر چه معیار اطلاعاتی
آکائیک مربوط به مدل کمتر باشد آن مدل عملکرد بهتری
دارد. این معیار موقعی که کمتر است ناشی از دو عامل
می باشد یکی خطای مدل و دیگری تعداد پارامترهاست،
پس معیار خوبی برای بررسی مدل ها می باشد.

نرم افزارهای مورد نیاز

در این بخش به معرفی نرم افزارهایی که در این مطالعه
استفاده می شوند، پرداخته می شود، نخستین نرم افزاری که
می توان استفاده کرد مجموعه نرم افزار Office می باشد.
نرم افزار HEC-4 برای بازسازی و تکمیل داده ها مورد
استفاده قرار می گیرد. یکی دیگر از نرم افزارهای پر کاربرد
در این مطالعه، نرم افزار MATLAB می باشد. در این نرم

²-Geographic Information System

³-Long-Short Term Memory

⁴-Recurrent Neural Network

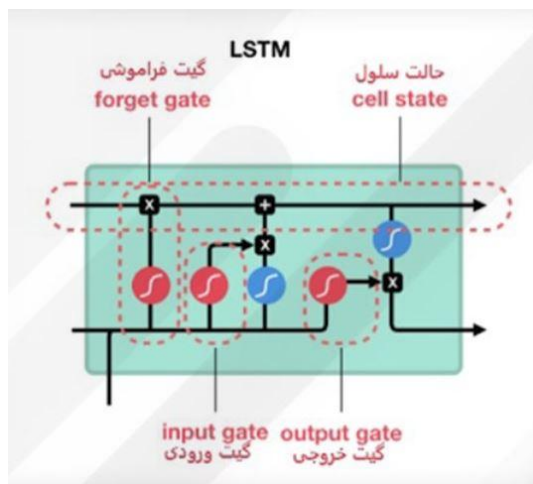
⁵-Sequential Data

⁶-Vanishing Gradient

⁷-Gate

¹- Akaike information criterion

state وارد بشوند. این گیت‌ها در طول آموزش شبکه یاد می‌گیرند چه اطلاعاتی باید حفظ یا فراموش شوند.



شکل (۴): ساختار شماتیکی از مدل LSTM

ورودی است (در هر زیرمجموعه فقط دو تا سه متغیر مستقل قرار دارد)، انجام می‌شود (فارو، ۱۹۸۴). برای فهم این الگوریتم، با فرض وجود داده‌های اولیه که شامل ستونی از مقادیر مشاهده شده y و N ستون از مقادیر مشاهده شده متغیرهای مستقل x_1, x_2, \dots, x_n است، معادلات اولیه به صورت چند جمله‌ای درجه دوم در نظر گرفته می‌شوند:

$$Z = A + B_u + C_v + D_u^2 + E_v^2 + F_u \cdot V \quad (7)$$

در این رابطه، A, B, C, D, E, F ضرایب و u و v زوج مقادیری از x هستند و Z بهترین برازش از متغیر y است. بهترین این برآوردها در مجموعه متغیرهای ورودی وارد و سپس زیرمجموعه‌های کوچکی از این متغیرها برای برآوردهای جدید در هر مرحله از چرخه تکرار شونده و افزایشی^۳ استفاده می‌گردد که شامل تولید و افزوده شدن ساختارهای پایه بسیار ساده (نورون‌های چند جمله‌ای) است و به مرور، با ترکیب این ساختارهای ساده، سیستمی پیچیده شکل می‌گیرد که دارای عملکرد مطلوب است. بر خلاف سایر روش‌های رگرسیون، در این رویکرد، علاوه بر

اطلاعات را کنترل می‌کنند، همین‌طور مشخص می‌کنند چه داده‌هایی در توالی مهم هستند و باید هم‌چنان حفظ بشوند و چه داده‌هایی باید حذف شوند، به این شکل، شبکه‌ی اطلاعات مهم را در طول زنجیره‌ی توالی عبور می‌دهد تا خروجی مدنظر را بدست آید. در شکل (۴) ساختار یک شبکه LSTM مشاهده می‌شود.

مفهوم اصلی شبکه‌ی LSTM همان cell state و گیت‌های همراهش است، گیت‌ها اطلاعات را در cell state به‌روز نگه می‌دارند. این گیت‌ها شبکه‌های عصبی مختلفی هستند که تصمیم می‌گیرند چه اطلاعاتی به cell

روش گروهی مدیریت داده (GMDH)

روش گروهی مدیریت داده‌ها (Group Method of Data Handling) که به اختصار (GMDH) گفته می‌شود، یکی از روش‌های مدل‌سازی و رگرسیون خطی است، که در سال ۱۹۶۸ توسط دانشمند اوکراینی، آلکسی ایواکنکو^۱ معرفی شد. یکی از پایه‌ای‌ترین و مهم‌ترین الگوریتم‌ها برای ساخت مدل GMDH، که به نام شبکه عصبی چند جمله‌ای^۲ که PNN نیز شناخته می‌شود، الگوریتم ارائه شده توسط خود ایواکنکو است که پایه اصلی آن را، مدل چند جمله‌ای درجه دو و الگوریتم کمترین مربعات خطا تشکیل می‌شود.

روش گروهی مدیریت داده‌ها، الگوریتمی است که در آن متغیرهای اصلی ورودی در یک شبکه قابل انعطاف از معادلات رگرسیونی نگهداری می‌شوند که می‌توان از آنها برای ارتباط بین متغیرهای ورودی (مستقل) و متغیرهای خروجی (وابسته) استفاده کرد. در این الگوریتم برآورد اولیه از متغیرهای خروجی با استفاده از معادلات رگرسیونی که شامل زیرمجموعه‌های کوچک از متغیرهای

³-Iteration cycle

¹-Alexey Ivakhnenko

²-Polynomial Neural Network

Wu 2004) روشی متفاوت با عنوان روش تجزیه مد تجربی یکپارچه^۴ (EEMD) را پیشنهاد کردند. در روند تجزیه‌سازی EEMD، حجم محدودی از نویز سفید وارد سیگنال اصلی می‌شود. با استفاده از جنبه‌های مثبت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌شود. در روش تجزیه مد تجربی یکپارچه کامل^۵ (CEEMD) نوفه سفید به صورت دوتایی (یکی مثبت و دیگری منفی) به داده اصلی اضافه می‌شود تا دو سری IMF مجموع ساخته شود. بنابراین ترکیبی متشکل از داده اصلی و نوفه اضافی بدست می‌آید که مجموع IMFها برابر سیگنال اصلی می‌شود.

مدل‌های ترکیبی

زمانی که سیگنال اولیه با استفاده از روش تجزیه مد تجربی یکپارچه کامل (CEEMD) تجزیه شده و از زیرسیگنال‌های حاصل به عنوان ورودی به مدل‌های هوشمند LSTM و GMDH استفاده شود، به ترتیب مدل‌های ترکیبی CEEMD-LSTM و CEEMD-GMDH تشکیل می‌شود. در شکل (۵) زیر سیگنال‌های Pr, Tr, GWLr و Er (Residual) در سطح پایانی و سایر زیرسیگنال‌ها مربوط به توابع مد ذاتی (IMF) در سطوح یک تا سطح پایانی می‌باشند.

ساخت تدریجی مدل، از الگوی انتخاب طبیعی^۱، همانند آنچه که در الگوریتم‌های تکاملی است، استفاده شده است. برای آشنایی بیشتر با این مباحث می‌توان به منابع فارو (۱۹۸۴)، پاچپسکی و همکاران (۱۹۹۸) مراجعه نمود.

روش تجزیه مد تجربی یکپارچه کامل (CEEMD)

روش تجزیه مد تجربی^۲ (EMD) روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرآیندی تحت عنوان غربال کردن صورت می‌گیرد. طی این فرایند سیگنال اصلی به تعدادی مولفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه (۸) سیگنال اصلی $x(n)$ را به تعدادی مد ذاتی^۳ (IMF) تجزیه می‌کند (Amirat et al., 2018).

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (8)$$

در رابطه فوق، $r_n(x)$ همان مولفه باقی مانده، بعد از n تعداد IMFها و $c_i(x)$ است. $C(x)$ تابع موج شکل استخراج شده از سیگنال اصلی است که شرایط تابع مد ذاتی را ندارد. یک داده ممکن است در یک زمان دارای چندین مد ذاتی باشد.

این مدهای نوسانی، تابع‌های مد ذاتی (IMF) نام دارند و دارای دو شرط هستند: (۱) در کل داده‌ها، تعداد نقاط اکسترمم و نقاط صفر با هم برابر و یا حداکثر دارای یک واحد اختلاف هستند. (۲) در هر نقطه میانگین پوش برازش داده شده بر نقاط بیشینه محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد.

به علت وجود تناوب و نویز در سیگنال‌ها، در برخی از موارد به علت اختلاف مدها، توزیع حوزه زمان-فرکانس دچار انقطاع می‌شود و عملکرد EMD دچار نقض می‌گردد. جهت رفع این ایراد، وو و هوانگ (Wu and Huang, 2009)

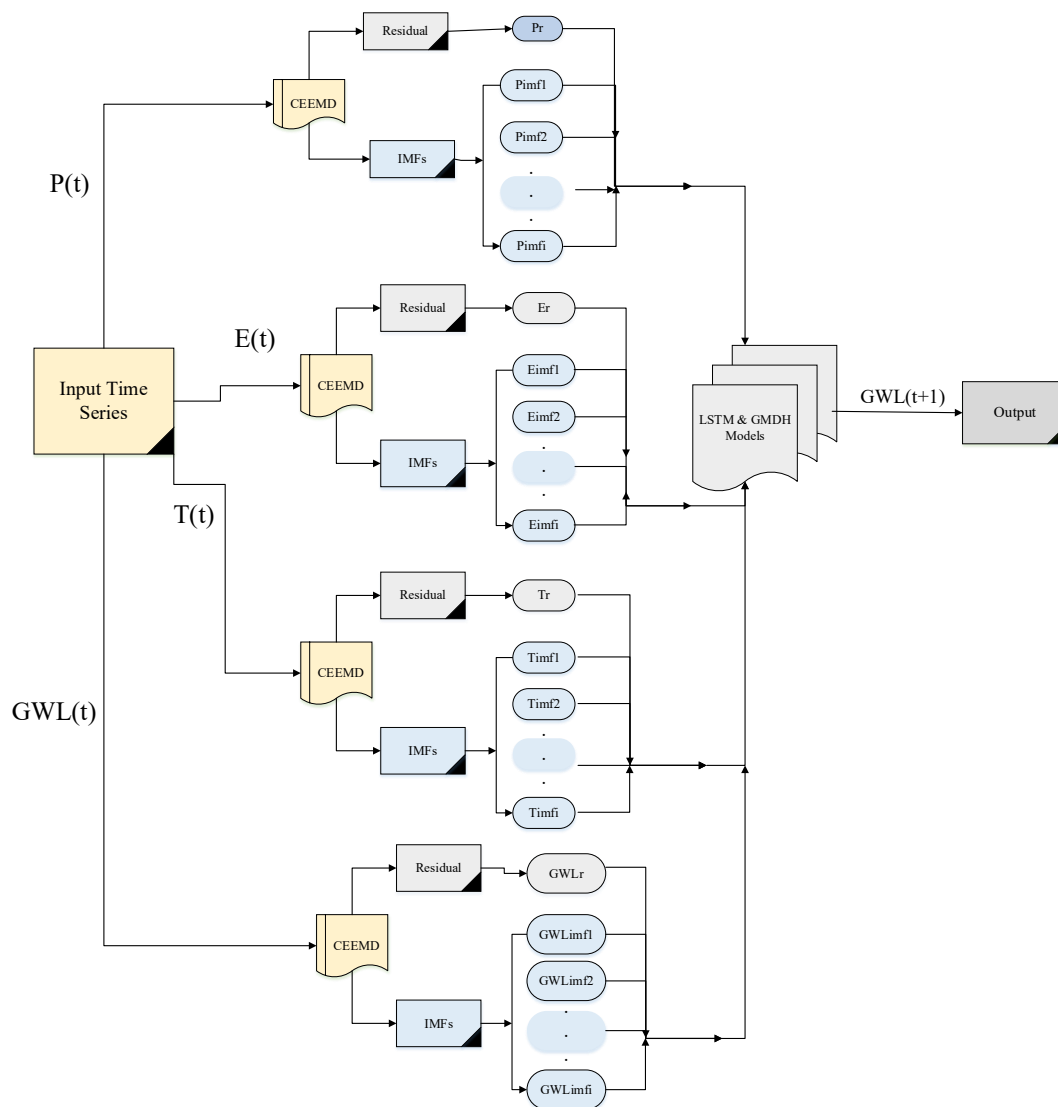
⁴-Ensemble empirical mode decomposition

⁵-Complementary ensemble empirical mode decomposition

¹-Natural Selection

²-Empirical mode decomposition

³-Intrinsic mode functions



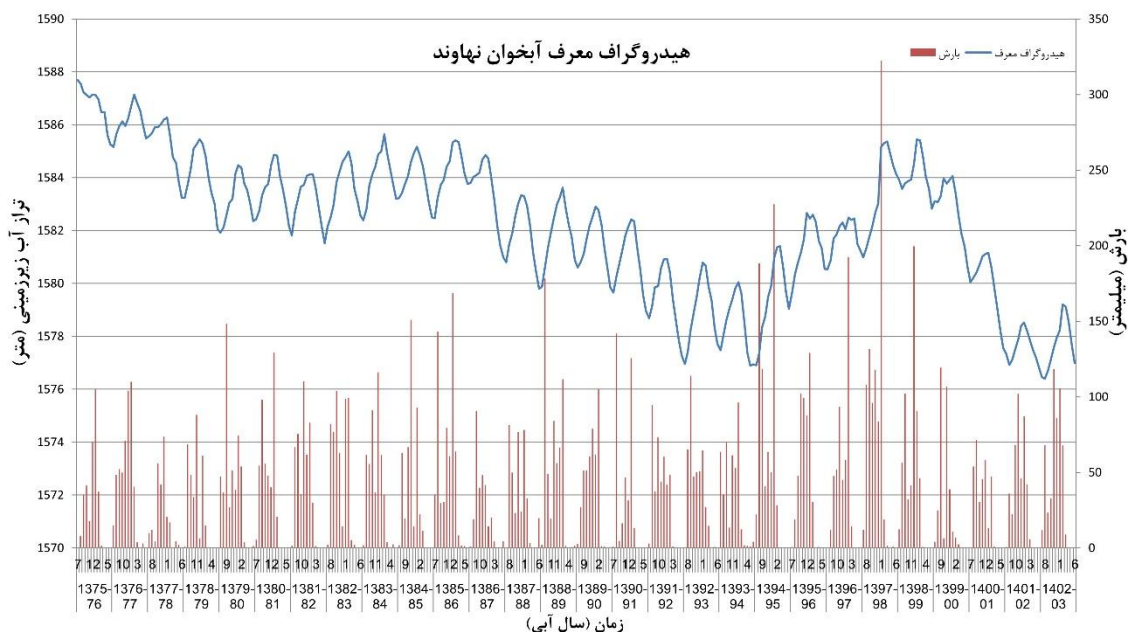
شکل (۵): دیاگرام شماتیکی از مدل‌های ترکیبی CEEMD-LSTM و CEEMD-GMDH

نتایج و بحث

ترسیم هیدروگراف واحد آب زیرزمینی

با توجه به داده‌های چاه‌های مشاهده‌ای در آبخوان نهاوند، ۳۷ چاه مشاهده‌ای که دارای دوره آماری بهتری بودند، انتخاب گردید. بعد از تکمیل آمار سطح آب زیرزمینی در چاه‌های مشاهده‌ای با استفاده از نرم افزار HEC-4، دوره آماری (۱۴۰۳-۱۳۷۵) برای ترسیم هیدروگراف واحد انتخاب شد. به منظور بررسی داده‌های پرت از روش نمودار جعبه‌ای استفاده شد. در صورت

مواجهه با داده‌های پرت، آن داده‌ها حذف و دوباره با نرم-افزار HEC-4 بازسازی شدند. بعد از ترسیم چندضلعی-های تیسن برای چاه‌های مشاهده‌ای در محیط نرم‌افزار GIS و محاسبه مساحت هر چاه مشاهده‌ای، در نهایت نمودار هیدروگراف واحد آب زیرزمینی در مقیاس ماهانه برای آبخوان نهاوند مطابق شکل (۶) ترسیم شد. بعد از ترسیم هیدروگراف واحد آب زیرزمینی آبخوان نهاوند، مقادیر تراز سطح آب زیرزمینی برای مدل سازی مورد استفاده قرار می‌گیرند



شکل (۶): هیدروگراف واحد آبخوان نهاوند به همراه مقادیر بارش.

با توجه به ضریب همبستگی بدست آمده و تعداد ایستگاه‌های مورد استفاده برای تعیین گرادیان بارش معادله گرادیان بارندگی محاسبه شده در سطح ۹۵ درصد معنی‌دار می‌باشد. در جدول (۲) مقایسه بین نتایج روش گرادیان با مقادیر مشاهداتی صورت گرفته است. همانطوری که مشاهده می‌شود، مقدار خطای این روش خوب می‌باشد.

با استفاده از روش درونیابی کریجینگ نیز مقدار بارش بلندمدت برای محدوده مطالعاتی نهاوند ترسیم شد. سپس مقدار بارش برای هر یک از ایستگاه‌های منطقه محاسبه شد تا مقدار خطای این روش بدست آید. در جدول (۲) مقایسه بین نتایج این روش با مقادیر مشاهداتی صورت گرفته است. همانطوری که مشاهده می‌شود، مقدار خطای این روش خیلی خوب می‌باشد. لذا برای ترسیم نقشه‌های بارش و دیگر داده‌های مطالعه از این روش استفاده شد

ترسیم نقشه بارش بلندمدت منطقه

برای بررسی و ترسیم نقشه بارش منطقه از دو روش مختلف استفاده شد و نتایج حاصل از ترسیم میانگین بلند مدت بارندگی سالانه آنها با مقادیر مشاهداتی میانگین بلند مدت بارندگی سالانه هر ایستگاه مقایسه شد تا بهترین روش برای ترسیم نقشه‌های بارش در زمان‌های مختلف انتخاب شود. ابتدا با استفاده از ایستگاه‌های داخل محدوده مطالعاتی، استخراج شد، که نتایج مناسب نبود، سپس با استفاده از ایستگاه‌های داخل و بیرون محدوده مطالعاتی، گرادیان استخراج شد که نتایج کمی بهتر شد، در مرحله بعد با استفاده از متغیرهای بارش، ارتفاع، طول و عرض جغرافیایی اقدام به استخراج گرادیان شد. لذا معادله استخراج شده با استفاده از این متغیرها به صورت رابطه (۹) می‌باشد.

$$P = 0.0000738X + 0.000053Y - 0.0259715H \quad R^2 = 0.9518 \quad n = 9 \quad (9)$$

جدول (۲): بررسی دقت روش‌های تخمین بارش.

نام ایستگاه	بارش محاسباتی		بارش مشاهداتی	تفاضل		درصد مقدار خطا		متوسط مقدار خطای ایستگاه‌ها	
	گراد یا کریجینگ	گراد یا کریجینگ		گراد یا کریجینگ	گراد یا کریجینگ	گراد یا کریجینگ	گراد یا کریجینگ	گراد یا کریجینگ	گراد یا کریجینگ
وراینه	۴۹ ن	۹۸۲۳	۲۱۲/۲۶۹۲	۳۷/۷۸ ن	-۰/۲۸۷۰ گ	-۱۷/۸۰ ن	-۰/۱۳۵۲ ینگ		
وسج	۱۸۰/۷۶	۵۸۴۷ ۱۴۸	۱۴۸/۲۱۵۴	۳۲/۵۴	۰/۳۶۹۳	۲۱/۹۶	۲۴۹ ۰/۲		
نورآباد	۱۷۱/۶۹	۱۰۳۹۸ ۲۱۷	۲۱۷/۰۵۳۷	-۴۵/۳۶	-۰/۰۱۳۹	-۲۰/۹۰	۰۰۶۴ -۰/		
دره تنگ	۴۱ ۱۷۴	۸۱۶۸ ۲۴۰	۲۴۰/۸۵۹۳	-۶۶/۴۵	-۰/۰۴۲۵	-۲۷/۵۹	۰۱۷ -۰/۷		
خیرآباد	۱۷۸/۶۴	۱۸۱۹ ۱۲۹	۱۲۹/۱۹۲۳	۴۹/۴۵	-۰/۰۱۰۴	۳۸/۲۷	۰۰۸ -۰/۰	۵/۷۰	-۰/۰۰۳۴
سرابی	۳۸ ۱۷۴	۵۲۷۶ ۱۵۷	۱۵۷/۵۵۰۰	۱۶/۸۳	-۰/۰۲۳۳	۱۰/۶۸	۰۱۴ -۰/۸		
پیهان	۹۹ ۱۷۵	۳۰۰۲ ۱۱۷	۱۱۷/۲۹۴۸	۵۸/۷۰	۰/۰۰۵۴	۵۰/۰۴	۰۰۴۶ ۰/		
سیاه دره	۲۱۴/۶۶	۳۹۲۱ ۲۳۲	۲۳۲/۶۱۹۲	-۱۷/۹۶	-۰/۲۲۷۲	-۷/۷۲	۰۹۷ -۰/۷		
داربید	۲۳ ۲۱۱	۴۸۹۶ ۲۰۲	۲۰۲/۴۹۹۸	۸/۷۳	-۰/۰۱۰۲	۴/۳۱	۰۰۵ -۰/۰		

همبارش برای ماه‌های مختلف در سال‌های آماری ارائه شده است.

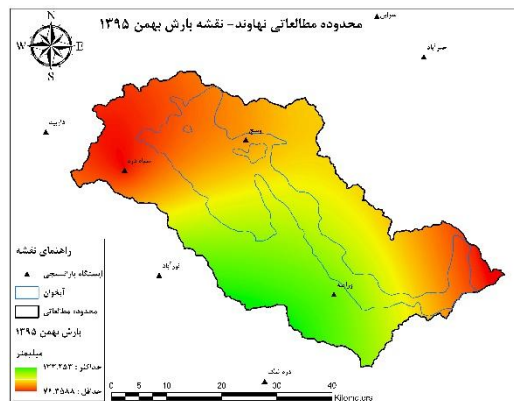
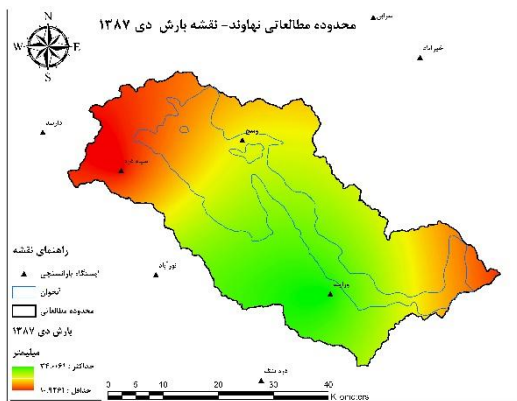
براساس نقشه‌های هم‌دمای ماهانه ترسیم شده برای محدوده مطالعاتی نهاوند متوسط دمای سالانه آبخوان نهاوند در دوره ۲۸ ساله برابر ۱۳/۰۴ درجه سانتیگراد، در دوره ده ساله (۱۴۰۳-۱۳۹۳) برابر ۱۴/۱۰ درجه سانتیگراد و در سال آبی (۱۴۰۲-۱۴۰۳) برابر ۱۴/۵۴ درجه سانتیگراد بدست آمد. نتایج نشان از افزایش دمای آبخوان نهاوند در طی چند سال اخیر نسبت به دوره بلندمدت دارد. در شکل (۸) نقشه هم‌دمای ماه‌های مختلف در سال‌های آماری ارائه شده است. براساس نقشه‌های هم‌تبخیر ترسیم شده برای محدوده مطالعاتی نهاوند، متوسط مقدار سالانه تبخیر آبخوان نهاوند در دوره ۲۸ ساله (۱۴۰۳-۱۳۷۵) برابر ۲۰۴۷ میلیمتر، در دوره ده

ترسیم نقشه‌های پارامترهای مختلف

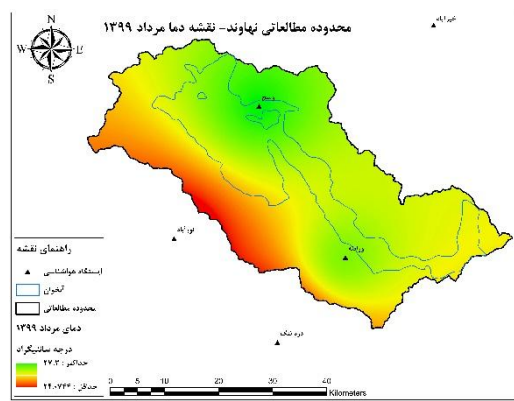
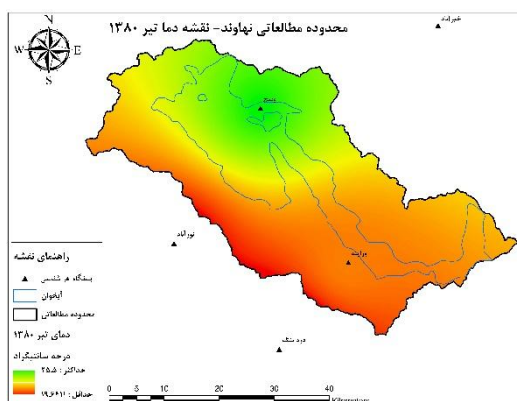
برای ترسیم نقشه‌ها از نرم‌افزار GIS و روش کریجینگ استفاده شد. نقشه‌های هم‌بارش ماهانه در سال‌های مختلف برای محدوده مطالعاتی نهاوند ترسیم شد. سپس مقادیر بارش ماهانه برای آبخوان نهاوند استخراج گردید. با توجه به این نقشه‌ها، مقدار متوسط بارش روی آبخوان در طی دوره آماری ۲۸ ساله (۱۴۰۳-۱۳۷۵) برابر ۴۶۳ میلیمتر، در دوره ده ساله (۱۴۰۳-۱۳۹۳) برابر ۵۲۱ میلیمتر و در سال آبی (۱۴۰۲-۱۴۰۳) برابر ۵۳۵ میلیمتر می‌باشد. دلیل افزایش بارش در دهه اخیر مربوط به افزایش میزان بارش در سال‌های ۱۳۹۷ و ۱۳۹۸ نسبت به دیگر سال‌ها می‌باشد. در ادامه برخی از نقشه‌ها به عنوان نمونه ارائه می‌شوند. در شکل (۷) نقشه

(۹) نقشه هم‌تبخیر برای ماه‌های مختلف در سال‌های آماری ارائه شده است.

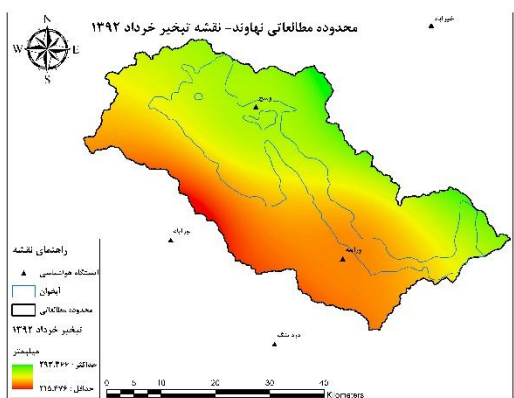
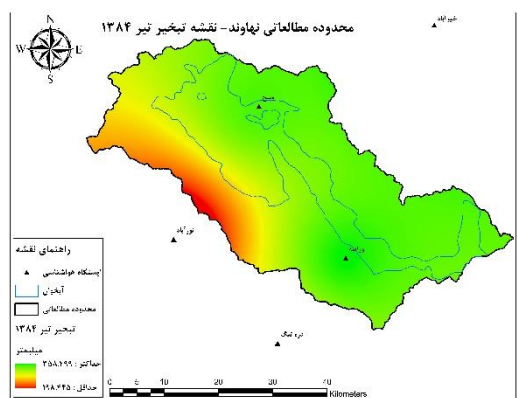
ساله (۱۴۰۳-۱۳۹۳) برابر ۲۰۱۳ میلیمتر و در سال آبی (۱۴۰۲-۱۴۰۳) برابر ۲۰۳۶ میلیمتر می‌باشد. در شکل



شکل (۷): نقشه‌های هم‌بارش در محدوده مطالعاتی و آبخوان نهاوند.



شکل (۸): نقشه‌های هم‌دما در محدوده مطالعاتی و آبخوان نهاوند.



شکل (۹): نقشه‌های هم‌تبخیر در محدوده مطالعاتی و آبخوان نهاوند.

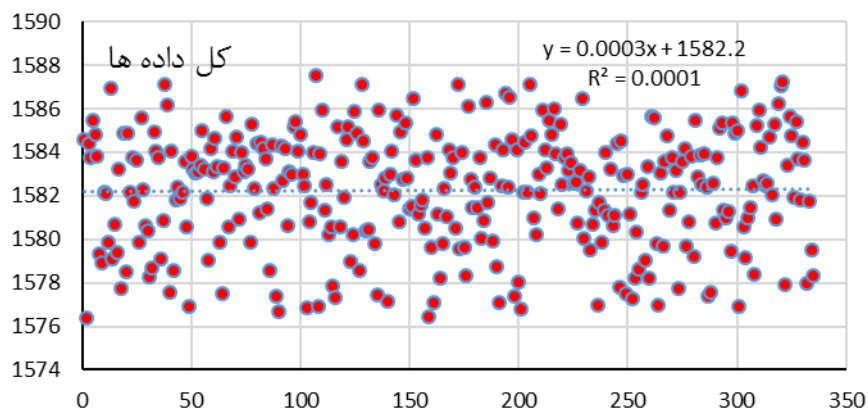
با مشاهده هیدروگراف واحد آبخوان نهاوند متوجه می

بررسی روند در داده‌ها

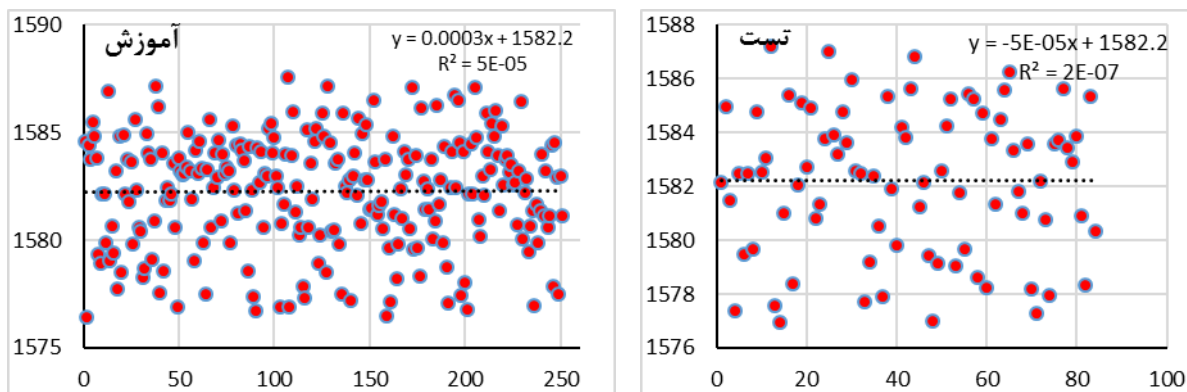


در سال ۱۹۷۵ بر پایه رتبه داده‌ها در یک سری زمانی بسط و توسعه یافت. مقدار Z در آزمون من-کندال با توجه به سطح اطمینان ۹۵٪ معادل ۱/۹۶، بر اساس سطح اطمینان ۹۰٪ برابر با ۱/۶۴ و بر اساس سطح اطمینان ۹۹٪ برابر با ۲/۵۷۶ است. اگر مقدار Z کمتر از ۱/۹۶، بر اساس سطح اطمینان ۹۰ درصد، اگر کمتر از ۱/۶۴، و بر اساس سطح اطمینان ۹۹ درصد اگر کمتر از ۲/۵۷۶ باشد، فرض صفر پذیرفته شده و سری زمانی مورد مطالعه دارای روند نیست. در شکل (۱۰) داده‌ها از نظر بررسی روند در آنها مورد بررسی قرار گرفت تا از تصادفی بودن آنها اطمینان حاصل شود. ۷۵ درصد کل داده‌ها برای مرحله آموزش و ۲۵ درصد آنها برای مرحله تست به صورت رندومی انتخاب شدند. با مشاهده این شکل، متوجه می‌شویم که داده‌ها دارای روند نیستند ولی برای اطمینان بیشتر، داده‌های مراحل آموزش و تست هم در شکل (۱۱) بررسی شدند. همچنین نتایج روش من کندال برای بررسی تصادفی بودن کل داده‌ها، داده‌های مرحله آموزش و مرحله تست در جدول (۳) ارائه شده است. نتایج این جدول نشان از تصادفی بودن کل داده‌ها، داده‌های مراحل آموزش و تست دارند

شویم که داده‌ها دارای روند کاهشی می‌باشند، لذا استفاده کردن از داده‌های دارای روند در مدل‌سازی باعث ایجاد خطا می‌شود برای این منظور بدون اینکه داده‌ای تغییر پیدا کند، ردیف‌های هر داده را به صورت رندومی تغییر داده (یعنی بدون توجه به زمان رویداد آنها پشت سر هم قرار گرفته‌اند) تا داده‌ها به صورت تصادفی شده و روندی در آنها مشاهده نشود، برای بررسی تصادفی بودن این داده‌ها، از روش من-کندال استفاده شد. چنانچه سری زمانی داده‌ها دارای سیر صعودی یا نزولی باشند، گفته می‌شود که داده‌ها دارای روند (trend) هستند. به عبارت دیگر، در آزمون روند هدف بررسی وضعیت تغییرات متغیر با تغییر پارامتر زمان (T) می‌باشد. آزمون‌های بررسی روند داده‌ها به دو دسته پارامتری و غیرپارامتری تقسیم می‌شوند. روش‌های پارامتری عموماً مبتنی بر فرضیات خطی بودن روند و نرمال بودن توزیع باقیمانده‌ها هستند. اما روش‌های ناپارامتری از این دیدگاه دارای محدودیت‌های کمتری بوده و به همین دلیل کاربرد آنها در سال‌های اخیر به طور وسیعی افزایش داشته است. از مهمترین روش‌های ناپارامتری می‌توان به آزمون‌های من-کندال اشاره نمود. آزمون ناپارامتری من-کندال ابتدا توسط Mann در سال ۱۹۴۵ ارائه و سپس توسط Kendall



شکل (۱۰): بررسی روند داده‌های تراز سطح آب زیرزمینی استفاده شده-کل داده‌ها.



شکل (۱۱): بررسی روند داده‌های تراز سطح آب زیرزمینی استفاده شده-مراحل آموزش و تست.

جدول (۳): نتایج بررسی روند داده‌های تراز سطح آب زیرزمینی آبخوان نهاوند

Runs Test			
	Total	Train	Test
Test Value ^a	۱۵۸۲/۵۲۷۶	۱۵۸۲/۵۸۱۸	۱۵۸۲/۴۹۳۵
Cases < Test Value	۱۶۷	۱۲۵	۴۲
Cases >= Test Value	۱۶۸	۱۲۶	۴۲
Total Cases	۳۳۵	۲۵۱	۸۴
Number of Runs	۱۷۰	۱۲۸	۳۳
Z	۰/۱۶۴	۰/۱۹۰	-۲/۱۹۵
Asymp. Sig. (2-tailed)	۰/۸۶۹	۰/۸۴۹	۰/۰۲۸

a. Median

بارش ماهانه (P) به عنوان منبع اصلی تأمین آب سطحی و زیرزمینی در آبخوان در نظر گرفته شده است. افزایش بارش موجب افزایش ذخیره آب در خاک و بالا رفتن سطح آب زیرزمینی می‌شود، در حالی که کاهش بارش باعث افت تراز آبخوان خواهد شد. واحد این پارامتر میلیمتر در ماه است.

دمای متوسط ماهانه (T) بر میزان تبخیر از سطح خاک و آبخوان تأثیر مستقیم دارد. افزایش دما باعث افزایش تبخیر و کاهش سطح آب زیرزمینی می‌شود. بنابراین این پارامتر نقش تعیین‌کننده‌ای در تغییرات تراز آبخوان دارد و واحد آن درجه سانتی‌گراد است.

تبخیر ماهانه (E) به عنوان یکی از عوامل اصلی کاهش ذخیره آب زیرزمینی در نظر گرفته شده است. تبخیر مستقیم از سطح خاک و آب موجب کاهش سطح آب زیرزمینی می‌شود. مقادیر این پارامتر با استفاده از

نتایج مدل‌های هوشمند

در این بخش نتایج اجرای مدل‌های هوشمند برای برآورد تراز سطح آب زیرزمینی با استفاده از داده‌های حاصل از ترسیم نقشه‌های هم‌بارش، هم‌دما، هم‌تبخیر و ترسیم هیدروگراف واحد آب زیرزمینی صورت گرفت. در این مطالعه مدل‌سازی برای محاسبه تراز سطح آب زیرزمینی آبخوان نهاوند صورت گرفت. برای بهبود مدل‌سازی با استفاده از رابطه (۳) داده‌های ورودی به صورت استاندارد شده مورد استفاده قرار گرفت. در این مطالعه، برای پیش‌بینی تراز سطح آب زیرزمینی آبخوان نهاوند، چندین پارامتر هیدرولوژیکی و اقلیمی به‌عنوان ورودی مدل‌های هوشمند انتخاب شده‌اند. انتخاب این پارامترها بر اساس تأثیر فیزیکی مستقیم یا غیرمستقیم آن‌ها بر نوسانات سطح آب زیرزمینی صورت گرفته است.

مشاهده می‌شود بر اساس نتایج آنالیز حساسیت، بارش تأثیر زیادی را بر تغییرات تراز سطح آب زیرزمینی دارد. این اثر به دلیل نفوذ مستقیم آب بارش به لایه‌های نفوذپذیر خاک و تأمین ذخیره آبخوان است که با تأخیر زمانی مشخصی خود را در تراز آب زیرزمینی نشان می‌دهد. همچنین، تبخیر و دمای محیط نیز نقش قابل توجهی دارند؛ افزایش دما سبب افزایش نرخ تبخیر و کاهش ذخیره آب سطحی و زیرسطحی می‌شود، در حالی که کاهش دما روند عکس آن را ایجاد می‌کند. تراز سطح آب زیرزمینی نیز با یک یا دو ماه تأخیر نسبت به تغییرات بارش و تبخیر واکنش نشان می‌دهد که بیانگر زمان نفوذ و جریان در داخل آبخوان است. به علاوه، نتایج نشان می‌دهد که برخی متغیرها مانند تراز آب زیرزمینی ماه‌های قبل، با وجود تأخیر زمانی، حساسیت بالایی نسبت به خروجی مدل دارند. این امر ناشی از ماهیت حافظه‌دار سیستم آبخوان است که سطح فعلی آبخوان تحت تأثیر ذخیره قبلی و تعادل هیدرولیکی آن قرار دارد. بنابراین، ترکیب این تحلیل فیزیکی با نتایج کمی مدل‌ها توضیح می‌دهد چرا برخی پارامترها بر پیش‌بینی تراز آب زیرزمینی تأثیر بیشتری دارند و عملکرد مدل‌های هوشمند را بهبود می‌بخشد.

داده‌های دما و روابط تبخیر-دما برای هر ایستگاه محاسبه شده است و واحد آن نیز میلی‌متر در ماه می‌باشد.

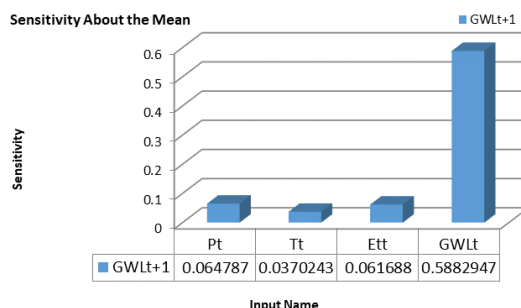
تراز سطح آب زیرزمینی در ماه‌های گذشته (GW) نشان‌دهنده ذخیره و جریان آب در آبخوان است و اثر مستقیم بر سطح آب زیرزمینی ماه جاری دارد. این پارامتر با توجه به داده‌های مشاهداتی چاه‌های نمونه استخراج شده و واحد آن متر از سطح زمین می‌باشد.

علاوه بر این، برای در نظر گرفتن تأثیرات زمانی پارامترها، گام‌های زمانی تأخیر، نیز در مدل لحاظ شده‌اند. اثرات هیدرولوژیکی بارش، تبخیر و تغییرات تراز سطح آب زیرزمینی معمولاً با تأخیر زمانی ظاهر می‌شوند؛ بنابراین استفاده از داده‌های یک یا دو ماه قبل، به مدل کمک می‌کند تا اثرات گذشته بر پیش‌بینی ماه جاری به درستی لحاظ شود. واحد این ورودی‌ها همان واحد پارامتر اصلی مربوطه است.

با در نظر گرفتن این مجموعه پارامترها و توجیه فیزیکی هر کدام، مدل‌های هوشمند قادر هستند تغییرات سطح آب زیرزمینی را با دقت بالاتری پیش‌بینی کنند و ارتباط پارامترهای ورودی با نوسانات آبخوان به‌طور شفاف مشخص می‌شود.

آنالیز حساسیت پارامترهای ورودی

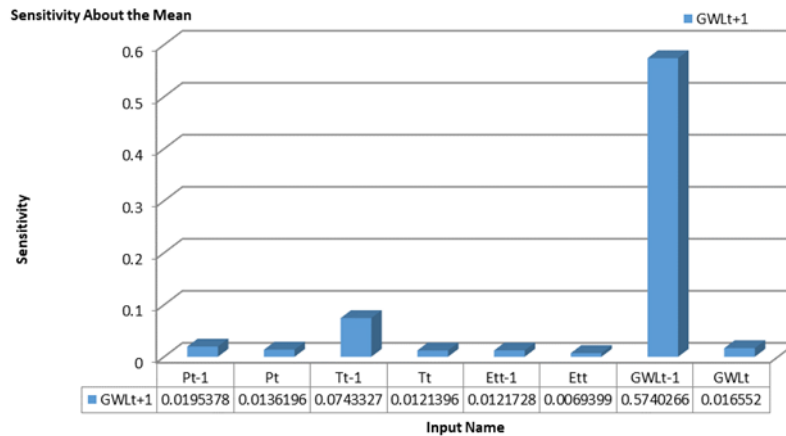
در شکل (۱۲) نمودار آنالیز حساسیت پارامترهای ورودی ارائه شده است، همانطوری که در این شکل




شکل (۱۲): نمودار آنالیز حساسیت پارامترهای ورودی

در شکل‌های (۱۳) و (۱۴) آنالیز حساسیت برای پارامترهای ورودی با یک و دو گام زمانی تأخیر در نظر گرفته شد.

به دلیل اینکه بتوان از همه ظرفیت مربوطه استفاده نمود و مدل‌سازی با دقت بیشتری صورت گیرد، داده‌های ورودی را با گام‌های زمانی مختلف نیز در نظر گرفته شد.



شکل (۱۳): نمودار آنالیز حساسیت پارامترهای ورودی با یک گام زمانی تأخیر



شکل (۱۴): نمودار آنالیز حساسیت پارامترهای ورودی با دو گام زمانی تأخیر

شده، استفاده شد. در این جدول $Tave_{t-1}$ ، $Tave_{t-2}$ به ترتیب دمای متوسط با دو، یک گام تأخیر زمانی و T_t مقدار دمای متوسط در ماه جاری را نشان می‌دهد. ET_{t-1} ، ET_{t-2} به ترتیب تبخیر با دو، یک گام تأخیر زمانی و ET_t مقدار تبخیر در ماه جاری را نشان می‌دهد. GWL_{t-1} ، GWL_{t-2} به ترتیب تراز سطح آب زیرزمینی با دو، یک گام تأخیر زمانی و GWL_t مقدار تراز سطح آب زیرزمینی در ماه جاری را نشان می‌دهد. P_{t-1} ، P_{t-2} به ترتیب بارش با دو، یک گام تأخیر زمانی و P_t مقدار بارش در ماه جاری را نشان می‌دهد. GWL_{t+1} پارامتر خروجی و مقدار تراز سطح آب زیرزمینی در ماه آتی می‌باشد

براساس نتایج آنالیز حساسیت پارامترهای ورودی، ۵ ترکیب برای مدل‌سازی با مدل‌های هوشمند مطابق جدول (۴) در نظر گرفته شد. ابتدا از همه پارامترهای ورودی استفاده شد (ترکیب شماره یک)، در ترکیب شماره دو، داده‌های ورودی با یک گام زمانی تأخیر استفاده شد، در ترکیب شماره سه، داده‌های ورودی با دو گام زمانی تأخیر در نظر گرفته شد، به دلیل اینکه در آنالیز حساسیت مولفه‌های دارای دو گام زمانی تأخیر، عملکرد خوبی نداشته‌اند، از افزایش تأخیر به داده‌های ورودی خودداری شد. در ترکیب‌های شماره چهار و پنج، از بین پارامترهای موثر در پارامتر خروجی، مطابق آنالیز حساسیت انجام

جدول (۴): جزئیات ترکیب‌های مختلف مدل LSTM و GMDH

ترکیب	ورودی	خروجی
۱	T_t, ET_t, GWL_t, P_t	GWL_{t+1}
۲	$T_{t-1}, T_t, ET_{t-1}, ET_t, GWL_{t-1}, GWL_t, P_{t-1}, P_t$	GWL_{t+1}
۳	$T_{t-2}, T_{t-1}, T_t, ET_{t-2}, ET_{t-1}, ET_t, GWL_{t-2}, GWL_{t-1}, GWL_t, P_{t-2}, P_{t-1}, P_t$	GWL_{t+1}
۴	$T_{t-1}, P_t, P_{t-1}, GWL_t, GWL_{t-1}$	GWL_{t+1}
۵	$T_t, ET_{t-1}, ET_t, GWL_{t-1}, P_{t-1}, P_t$	GWL_{t+1}


ضریب تعیین آن ۰/۸۶۷۱ و خطای آن ۰/۰۴۳۵ بدست آمد. در این ترکیب برتر حداکثر تکرار برابر ۱۰۰۰، Mini Batch RMSE برابر ۰/۰۳، و Base Learning rate برابر ۰/۰۰۰۳۳ بوده است. در شکل (۱۵) مقایسه بین عملکرد این مدل با مقادیر مشاهداتی در مرحله تست صورت گرفته است. همانطوری که در این شکل دیده می‌شود، مدل LSTM در برخی از نقاط حداکثری و حداقلی عملکرد مناسبی نداشته است

نتایج مدل حافظه‌ی کوتاه‌مدت طولانی (LSTM)

در این مطالعه، ۵ ترکیب، برای اجرای مدل LSTM مطابق جدول (۴) در نظر گرفته شد. برای اجرای مدل LSTM، با کدنویسی در محیط نرم افزار MATLAB و استفاده از تمامی پارامترهای موثر در اجرای مدل، اقدام به مدل‌سازی شد. برای این منظور در هر ترکیب، ساختارهای مختلفی مورد بررسی قرار گرفت. نتایج بهترین ساختار در هر ترکیب در جدول (۵) ارائه شده است. همانطوری که در این جدول مشاهده می‌شود ترکیب شماره سه با ۱۲ پارامتر ورودی بهترین عملکرد را داشته است. به طوری که

جدول (۵): بهترین عملکرد در ترکیب‌های مختلف مدل LSTM در مقیاس ماهانه.

ترکیب	input size	max Epochs	پارامترهای مدل			R ²		RMSE	
			Mini Batch RMSE	Mini Batch Loss	Base Learning rate	آموزش	تست	آموزش	تست
۱	۴	۱۰۰۰	۰/۰۳	۰/۰۰۰۶۱	۰/۰۰۰۱	۰/۹۱۸۹	۰/۸۱۱۷	۰/۰۳۴۸	۰/۰۵۲۹
۲	۸	۱۰۰۰	۰/۰۴	۰/۰۰۰۸۴	۰/۰۰۰۱	۰/۸۷۵۷	۰/۸۰۷۵	۰/۰۴۰۷	۰/۰۵۳۲
۳	۱۲	۱۰۰۰	۰/۰۳	۰/۰۰۰۳۳	۰/۰۰۰۱	۰/۹۵۰۱	۰/۸۶۷۱	۰/۰۲۵۷	۰/۰۴۳۵
۴	۵	۱۰۰۰	۰/۰۳	۰/۰۰۰۵۷	۰/۰۰۰۱	۰/۹۱۱۲	۰/۸۴۷۶	۰/۰۳۳۹	۰/۰۴۶۹
۵	۶	۱۰۰۰	۰/۰۳	۰/۰۰۰۳۸	۰/۰۰۰۱	۰/۹۵۷۲	۰/۸۶۳۱	۰/۰۲۷۶	۰/۰۴۶۲



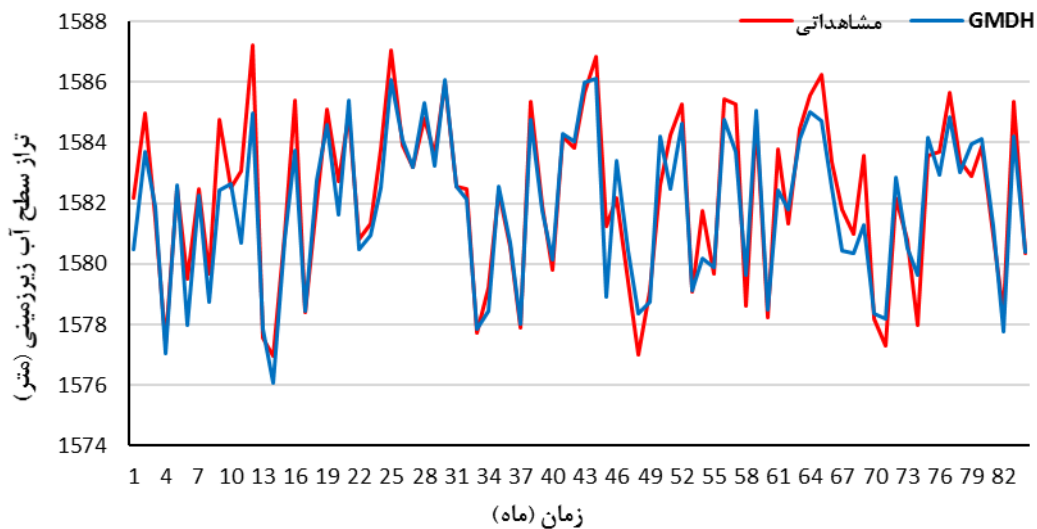
شکل (۱۵): مقایسه نتایج مدل LSTM با مقادیر مشاهداتی - مرحله تست.

ورودی هر ترکیب می باشد، تعداد نرون لایه خروجی هم که فقط یک خروجی داشته و یک می باشد، تعداد نرون - های لایه های میانی متفاوت بوده و بسته به تعداد لایه های میانی متفاوت می باشد. در این ترکیب برتر سه لایه میانی به ترتیب با تعداد ۱۱، ۱۵ و ۱۵ نرون وجود دارند. ضریب تعیین این ترکیب برتر ۰/۸۸۴۵ و خطای آن ۰/۰۴۳۲ بدست آمد. در شکل (۱۶) مقایسه بین عملکرد این مدل با مقادیر مشاهداتی در مرحله تست صورت گرفته است. همانطوری که در این شکل دیده می شود، مدل GMDH در نقاط حداکلی عملکرد بهتری نسبت به نقاط حداکثری، داشته است.

نتایج مدل روش گروهی مدیریت داده (GMDH)
برای اجرای مدل GMDH، با کدنویسی در محیط نرم افزار MATLAB و استفاده از تمامی پارامترهای موثر در اجرای مدل، اقدام به مدل سازی شد. برای این منظور مطابق جدول (۴)، پنج ترکیب مختلف مورد بررسی قرار گرفت. در هر ترکیب، ساختارهای مختلفی بررسی شد. نتایج بهترین ساختار در هر ترکیب در جدول (۶) ارائه شده است. همانطوری که در این جدول مشاهده می شود ترکیب شماره سه با ۱۲ پارامتر بهترین عملکرد را داشته است. بهترین ساختار در این جدول نشان دهنده تعداد نرون های لایه ورودی، لایه های میانی و لایه خروجی می - باشد. نرون های لایه ورودی همان تعداد پارامترهای

جدول (۶): بهترین عملکرد در ترکیب های مختلف مدل GMDH در مقیاس ماهانه.

RMSE		R ²		بهترین ساختار	ترکیب
تست	آموزش	تست	آموزش		
۰/۰۴۸۳	۰/۰۲۷۹	۰/۸۵۶۹	۰/۹۵۵۷	۴-۱۳-۱۱-۱	۱
۰/۰۴۸۸	۰/۰۳۳۸	۰/۸۴۰۵	۰/۹۱۹۲	۸-۷-۱۱-۱۵-۱	۲
۰/۰۴۳۲	۰/۰۲۴۱	۰/۸۸۴۵	۰/۹۵۵۴	۱۲-۱۱-۱۵-۱۵-۱	۳
۰/۰۴۸۱	۰/۰۲۶۵	۰/۸۶۴۴	۰/۹۶۲۶	۵-۴-۵-۹-۱	۴
۰/۰۴۳۸	۰/۰۳۲۶	۰/۸۷۵۶	۰/۹۲۶۵	۶-۱۵-۱۲-۱۲-۱	۵



شکل (۱۶): مقایسه نتایج مدل GMDH با مقادیر مشاهداتی - مرحله تست.

ارائه شده است. براساس این جدول، بهترین عملکرد در IMF برابر سه و مقدار ϵ برابر $0/2$ بدست آمد. همانطوری که در این جدول مشاهده می شود این ترکیب دارای ۱۶ پارامتر ورودی با ضریب تعیین آن $0/9496$ و خطای $0/0283$ می باشد. در این ترکیب برتر حداکثر تکرار برابر 1000 ، Mini Batch RMSE برابر $0/04$ ، Base Learning rate برابر $0/0065$ و Batch Loss برابر $0/0001$ بوده است. در شکل (۱۷) مقایسه بین عملکرد این مدل با مقادیر مشاهداتی در مرحله تست صورت گرفته است. همانطوری که در این شکل دیده می شود، عملکرد مدل مناسب بوده ولی نقاط اکسترمم را نتوانسته با دقت بالایی برآورد کند.

نتایج مدل های ترکیبی

در این بخش با استفاده از روش پیش پردازش CEEMD و مدل های هوشمند، مدل های ترکیبی حاصل شده و نتایج اجرای آنها ارائه شد. برای اجرای روش CEEMD از نرم افزار R استفاده شد. ابتدا باید در نرم افزار R پکیج "hht" را نصب نمود. سپس با استفاده از کدنویسی در محیط نرم افزار R اقدام به استخراج زیرسیگنال ها با روش CEEMD نمود.

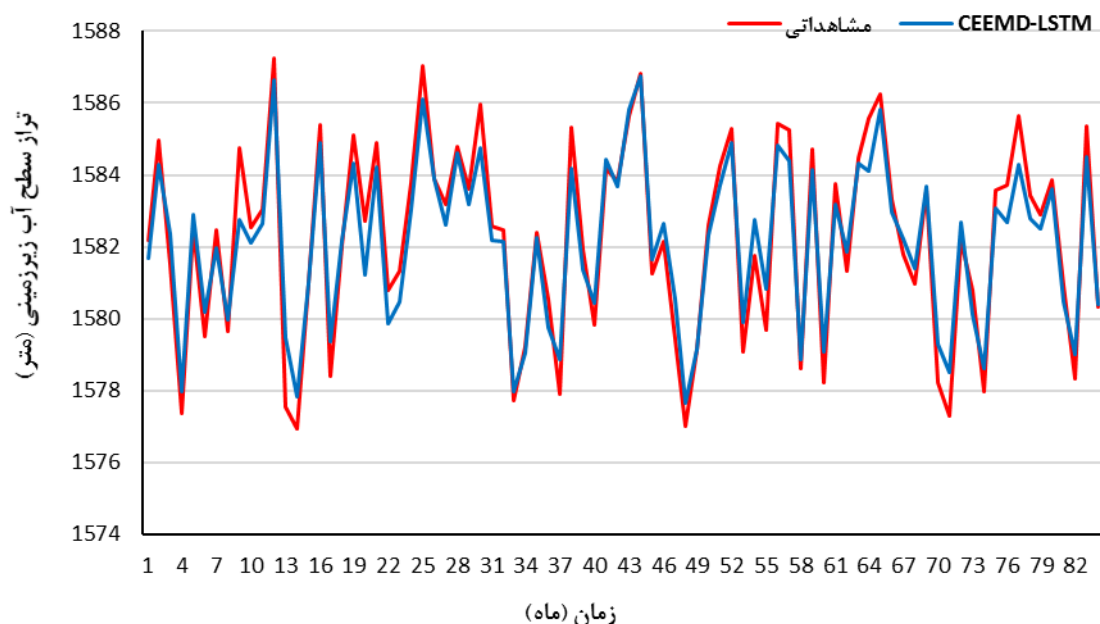
نتایج مدل CEEMD-LSTM

برنامه برای تعداد حداکثر IMF برابر ۱۰ اجرا شد که نتایج نشان داد که حداکثر تعداد زیرسیگنال ها ۶ می تواند باشد. بنابراین کد برنامه برای تعداد IMF های یک تا ۶ اجرا گردید. سپس زیرسیگنال های حاصل به عنوان ورودی به مدل LSTM وارد شد. نتایج این بررسی در جدول (۷)

جدول (۷): بهترین عملکرد در ترکیب های مختلف مدل CEEMD-LSTM در مقیاس ماهانه.

RMSE		R ²		پارامترهای مدل					ϵ	تعداد IMF
تست	آموزش	تست	آموزش	Base Learning rate	Mini Batch Loss	Mini Batch RMSE	max Epochs	input size		
$0/0380$	$0/0242$	$0/9020$	$0/9572$	$0/0001$	$0/00045$	$0/03$	۱۰۰۰	۸	$0/1$	۱
$0/0361$	$0/0283$	$0/9211$	$0/9483$	$0/0001$	$0/00067$	$0/03$	۱۰۰۰	۸	$0/2$	۱
$0/0389$	$0/0285$	$0/9059$	$0/9418$	$0/0001$	$0/00069$	$0/04$	۱۰۰۰	۸	$0/3$	۱
$0/0383$	$0/0288$	$0/9157$	$0/9511$	$0/0001$	$0/00068$	$0/04$	۱۰۰۰	۱۲	$0/1$	۲

RMSE		R ²		پارامترهای مدل					تعداد IMF	
تست	آموزش	تست	آموزش	Base Learning rate	Mini Batch Loss	Mini Batch RMSE	max Epochs	input size		
۰/۰۳۱۹	۰/۰۲۴۸	۰/۹۳۳۶	۰/۹۵۶۹	۰/۰۰۰۱	۰/۰۰۰۶۱	۰/۰۳	۱۰۰۰	۱۲	۰/۲	۲
۰/۰۴۵۵	۰/۰۳۹۱	۰/۹۰۷۴	۰/۹۱۸۳	۰/۰۰۰۱	۰/۰۰۱۱	۰/۰۴	۱۰۰۰	۱۲	۰/۳	۲
۰/۰۴۰۸	۰/۰۳۳۴	۰/۹۲۲۲	۰/۹۳۵۰	۰/۰۰۰۱	۰/۰۰۰۸۲	۰/۰۴	۱۰۰۰	۱۶	۰/۱	۳
۰/۰۲۸۳	۰/۰۲۳۲	۰/۹۴۹۶	۰/۹۶۱۱	۰/۰۰۰۱	۰/۰۰۰۶۵	۰/۰۴	۱۰۰۰	۱۶	۰/۲	۳
۰/۰۳۶۸	۰/۰۳۰۷	۰/۹۲۵۸	۰/۹۳۴۹	۰/۰۰۰۱	۰/۰۰۰۷۴	۰/۰۴	۱۰۰۰	۱۶	۰/۳	۳
۰/۰۳۶۱	۰/۰۳۰۵	۰/۹۲۵۰	۰/۹۴۳۲	۰/۰۰۰۱	۰/۰۰۰۸۳	۰/۰۴	۱۰۰۰	۲۰	۰/۱	۴
۰/۰۳۴۳	۰/۰۲۶۶	۰/۹۳۳۹	۰/۹۴۹۶	۰/۰۰۰۱	۰/۰۰۱۲	۰/۰۵	۱۰۰۰	۲۰	۰/۲	۴
۰/۰۳۸۵	۰/۰۲۹۳	۰/۹۲۶۷	۰/۹۴۳۷	۰/۰۰۰۱	۰/۰۰۰۸۴	۰/۰۴	۱۰۰۰	۲۰	۰/۳	۴
۰/۰۴۵۱	۰/۰۳۸۵	۰/۹۰۸۰	۰/۹۱۵۴	۰/۰۰۰۱	۰/۰۰۱۲	۰/۰۵	۱۰۰۰	۲۴	۰/۱	۵
۰/۰۴۱۰	۰/۰۳۵۴	۰/۹۱۱۱	۰/۹۲۴۳	۰/۰۰۰۱	۰/۰۰۰۹۴	۰/۰۴	۱۰۰۰	۲۴	۰/۲	۵
۰/۰۴۳۱	۰/۰۳۴۵	۰/۸۹۸۷	۰/۹۱۹۴	۰/۰۰۰۱	۰/۰۰۱۴	۰/۰۵	۱۰۰۰	۲۴	۰/۳	۵
۰/۰۴۴۶	۰/۰۳۰۸	۰/۸۹۳۷	۰/۹۴۲۲	۰/۰۰۰۱	۰/۰۰۰۸۳	۰/۰۴	۱۰۰۰	۲۸	۰/۱	۶
۰/۰۴۰۱	۰/۰۳۰۳	۰/۹۰۳۹	۰/۹۴۵۸	۰/۰۰۰۱	۰/۰۰۰۶۵	۰/۰۴	۱۰۰۰	۲۸	۰/۲	۶
۰/۰۵۱۴	۰/۰۳۸۹	۰/۸۸۷۰	۰/۹۲۴۷	۰/۰۰۰۱	۰/۰۰۱۱	۰/۰۵	۱۰۰۰	۲۸	۰/۳	۶



شکل (۱۷): مقایسه نتایج مدل CEEMD-LSTM با مقادیر مشاهداتی-مرحله تست.

روش گروهی مدیریت داده وارد شد تا مدل ترکیبی CEEMD-GMDH حاصل گردید. نتایج استفاده از این مدل ترکیبی در جدول (۸) ارائه شده است. براساس این

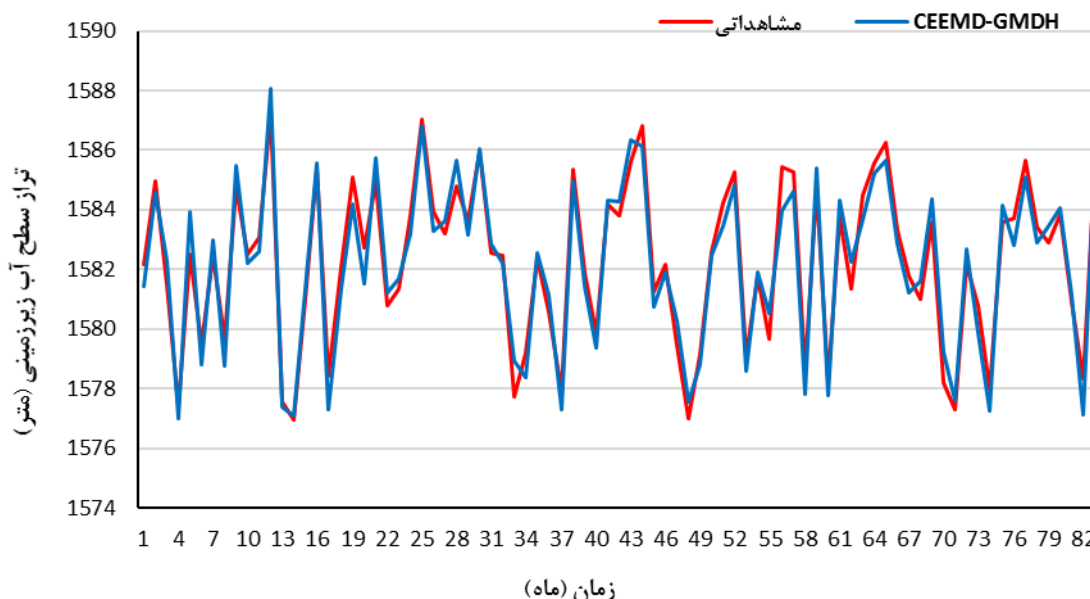
نتایج مدل CEEMD-GMDH
برنامه برای تعداد IMF های یک تا ۶ اجرا گردید. سپس زیرسیگنال‌های حاصل به عنوان ورودی به مدل

(۱۸) مقایسه بین عملکرد این مدل با مقادیر مشاهداتی در مرحله تست صورت گرفته است. همانطوری که در این شکل دیده می‌شود، مقادیر برآوردی مدل CEEMD-GMDH به مقادیر مشاهداتی نزدیک می‌باشد. این مدل در برآورد نقاط حداقلی عملکرد مناسب‌تری داشته است.

جدول، بهترین عملکرد در IMF برابر ۲ و مقدار ϵ برابر ۰/۳ بدست آمد. این ترکیب دارای ۱۲ پارامتر ورودی می‌باشد. این ترکیب برتر، سه لایه میانی به ترتیب با تعداد ۱۱، ۹ و ۶ نرون وجود دارند. ضریب تعیین این ترکیب برتر ۰/۹۴۵۰ و خطای آن ۰/۰۲۹۲ بدست آمد. در شکل

جدول (۸): بهترین عملکرد در ترکیب‌های مختلف مدل CEEMD-GMDH در مقیاس ماهانه.

تعداد IMF	ϵ	بهترین ساختار	آموزش	تست	R^2	آموزش	تست	RMSE
۱	۰/۱	۸-۱۵-۱۵-۸-۱	۰/۹۵۸۱	۰/۹۳۳۹	۰/۹۳۳۹	۰/۲۳۳	۰/۰۳۱۵	
۱	۰/۲	۸-۱۵-۱۵-۱۰-۱	۰/۹۵۹۵	۰/۹۴۱۹	۰/۹۴۱۹	۰/۰۲۲۹	۰/۰۲۹۶	
۱	۰/۳	۸-۱۴-۱۰-۳-۱	۰/۹۶۴۱	۰/۹۴۳۰	۰/۹۴۳۰	۰/۰۲۱۶	۰/۰۲۸۹	
۲	۰/۱	۱۲-۱۱-۱۰-۱۸-۱	۰/۹۵۹۲	۰/۹۳۹۷	۰/۹۳۹۷	۰/۰۲۲۹	۰/۰۳۰۶	
۲	۰/۲	۱۲-۱۳-۱۱-۱۰-۱	۰/۹۵۶۰	۰/۹۴۴۲	۰/۹۴۴۲	۰/۰۲۳۸	۰/۰۲۹۲	
۲	۰/۳	۱۲-۱۱-۹-۶-۱	۰/۹۵۱۸	۰/۹۴۵۰	۰/۹۴۵۰	۰/۰۲۵۱	۰/۰۲۹۲	
۳	۰/۱	۱۶-۱۵-۱۶-۲۰-۱	۰/۹۳۸۷	۰/۹۲۸۱	۰/۹۲۸۱	۰/۰۲۸۳	۰/۰۳۳۹	
۳	۰/۲	۱۶-۱۵-۱۴-۱۳-۱	۰/۹۴۷۸	۰/۹۳۸۹	۰/۹۳۸۹	۰/۰۲۶۰	۰/۰۲۹۷	
۳	۰/۳	۱۶-۱۵-۲۰-۲۰-۱	۰/۹۴۷۷	۰/۹۳۰۳	۰/۹۳۰۳	۰/۰۲۵۹	۰/۰۳۲۲	
۴	۰/۱	۲۰-۱۹-۲۰-۲۰-۱	۰/۹۴۲۱	۰/۹۲۳۴	۰/۹۲۳۴	۰/۰۲۷۵	۰/۰۳۴۰	
۴	۰/۲	۲۰-۱۹-۲۰-۲۰-۱	۰/۹۴۴۹	۰/۹۳۰۱	۰/۹۳۰۱	۰/۰۲۶۷	۰/۰۳۱۶	
۴	۰/۳	۲۰-۱۲-۱۱-۱۰-۱	۰/۹۲۸۴	۰/۹۱۳۷	۰/۹۱۳۷	۰/۰۳۰۶	۰/۰۳۵۳	
۵	۰/۱	۲۴-۲۰-۲۰-۲۰-۱	۰/۹۱۳۵	۰/۸۹۷۲	۰/۸۹۷۲	۰/۰۳۳۴	۰/۰۳۸۹	
۵	۰/۲	۲۴-۲۰-۱۷-۲۰-۱	۰/۹۱۶۳	۰/۹۰۹۸	۰/۹۰۹۸	۰/۰۳۲۹	۰/۰۳۷۴	
۵	۰/۳	۲۴-۲۰-۲۰-۲۰-۱	۰/۹۲۰۴	۰/۸۹۱۵	۰/۸۹۱۵	۰/۰۳۲۱	۰/۰۳۹۸	
۶	۰/۱	۲۸-۲۰-۲۰-۲۰-۱	۰/۹۰۶۴	۰/۸۹۹۹	۰/۸۹۹۹	۰/۰۳۴۹	۰/۰۳۷۹	
۶	۰/۲	۲۸-۲۰-۲۰-۲۰-۱	۰/۹۲۴۱	۰/۹۰۲۷	۰/۹۰۲۷	۰/۰۳۱۴	۰/۰۳۷۴	
۶	۰/۳	۲۸-۲۰-۲۰-۲۰-۱	۰/۹۱۳۴	۰/۸۹۲۴	۰/۸۹۲۴	۰/۰۳۳۶	۰/۰۳۹۴	



شکل (۱۸): مقایسه نتایج مدل CEEMD-GMDH با مقادیر مشاهداتی - مرحله تست.

پیش‌بینی تراز آب می‌تواند منجر به تصمیم‌گیری دقیق‌تر در بهره‌برداری و کنترل افت آبخوان شود.

همچنین معیار AIC به‌عنوان شاخصی برای ارزیابی تعادل بین دقت مدل و پیچیدگی آن استفاده شد. مقادیر کمتر AIC در مدل‌های ترکیبی نشان‌دهنده برتری این مدل‌ها در ارائه پیش‌بینی دقیق‌تر بدون افزایش بیش‌ازحد پیچیدگی ساختاری است. این موضوع از نظر هیدرولوژیکی بیانگر توان مدل‌های ترکیبی در شبیه‌سازی رفتار واقعی آبخوان با ساختاری بهینه و قابل اعتماد می‌باشد.

در جدول (۹) بهترین عملکرد هر یک از مدل‌های استفاده شده در این مطالعه ارائه شده است. همانطوری که در این جدول قابل مشاهده است، استفاده از ابزار پیش‌پردازش باعث بهبود عملکرد مدل‌های LSTM و GMDH شده است به طوری که استفاده از CEEMD باعث بهبود ۹/۵ درصدی ضریب تعیین در مدل LSTM و ۶/۸ درصدی ضریب تعیین در مدل GMDH شده است. با مقایسه نتایج مشاهده می‌شود که مدل ترکیبی CEEMD-LSTM با ضریب تعیین ۰/۹۵ و خطای

مقایسه نتایج مدل‌های هوشمند

در این بخش به مقایسه نتایج حاصل از اجرای مدل‌های مختلف در حالت‌های مختلف آنها پرداخته می‌شود. به‌منظور ارزیابی عملکرد مدل‌ها، از شاخص‌های آماری ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE) و معیار اطلاعاتی آکائیک (AIC) استفاده شد. ضریب تعیین بیانگر میزان توان مدل در بازتولید تغییرات زمانی تراز سطح آب زیرزمینی بوده و مقادیر بالاتر آن نشان‌دهنده تطابق بهتر الگوی تغییرات شبیه‌سازی‌شده با داده‌های مشاهداتی است. از دیدگاه هیدرولوژیکی، افزایش R^2 به‌ویژه در مدل‌های ترکیبی CEEMD-LSTM و CEEMD-GMDH نشان می‌دهد که این مدل‌ها قادر به استخراج بهتر مؤلفه‌های روند و نوسانات دوره‌ای سیستم آبخوان هستند.


شاخص RMSE نمایانگر میانگین خطای مطلق پیش‌بینی تراز سطح آب زیرزمینی بوده و کاهش آن بیانگر افزایش دقت مدل در تخمین مقدار واقعی سطح آب است. از منظر کاربردی، کاهش RMSE اهمیت بالایی در مدیریت منابع آب زیرزمینی دارد، زیرا خطای کمتر در

مشاهده می‌شود مدل‌های ترکیبی عملکرد بهتری داشته و از بین آنها مقادیر مدل ترکیبی CEEMD-LSTM به مقادیر مشاهداتی نزدیک‌تر می‌باشد. لذا می‌توان از این مدل برای پیش‌بینی تراز سطح آب زیرزمینی آبخوان نهاوند استفاده نمود.

۰/۰۲۸۳ دارای بهترین عملکرد بوده است. این مدل دارای معیار اطلاعاتی آکائیک ۱۵۷/۳۱ می‌باشد که نسبت به دیگر مدل‌ها کمتر می‌باشد. در شکل (۱۹) مدل‌های مختلف در دوره تست براساس هیدروگراف‌های واحد آبخوان نهاوند مورد مقایسه قرار گرفتند. همانطوری‌که

جدول (۹): مقایسه مدل‌های هوشمند استفاده شده در این مطالعه.

مدل	R ²		RMSE		AIC	
	آموزش	تست	آموزش	تست	آموزش	تست
LSTM	۰/۹۵۰۱	۰/۸۶۷۱	۰/۰۲۵۷	۰/۰۴۳۵	۴۹۱/۰۱۶۷	۱۵۸/۵۹۳۸
GMDH	۰/۹۵۵۴	۰/۸۸۴۵	۰/۰۲۴۱	۰/۰۴۳۲	۴۹۰/۸۲۷۴	۱۵۸/۵۷۱۲
CEEMD-LSTM	۰/۹۶۱۱	۰/۹۴۹۶	۰/۰۲۳۲	۰/۰۲۸۳	۴۹۰/۷۰۵۷	۱۵۷/۳۰۷۱
CEEMD-GMDH	۰/۹۵۱۸	۰/۹۴۵۰	۰/۰۲۵۱	۰/۰۲۹۲	۴۹۰/۹۴۳۸	۱۵۷/۳۹۵۰




شکل (۱۹): مقایسه مدل‌های استفاده شده در این مطالعه - مرحله تست.

مقدار تراز سطح آب زیرزمینی برای شش ماه اول سال آبی ۱۴۰۳-۱۴۰۴ صورت گرفت. در شکل (۲۰) مقادیر برآوردی مقدار تراز سطح آب زیرزمینی با مدل CEEMD-LSTM برای سال آبی ۴۰۱-۱۴۰۰ به بعد به همراه دوره پیش‌بینی ارائه شده است.

پیش‌بینی تراز سطح آب زیرزمینی

با مقایسه نتایج قسمت‌های قبل مشخص شد که مدل ترکیبی CEEMD-LSTM دارای بهترین عملکرد بوده و به عنوان بهترین مدل در این مطالعه شناخته شد. لذا از این مدل برای پیش‌بینی مقدار تراز سطح آب زیرزمینی آبخوان نهاوند در دوره‌های آتی استفاده شد. پیش‌بینی



شکل (۲۰): نتایج کاربرد مدل CEEMD-LSTM برای سال آبی ۱۴۰۱-۱۴۰۰ به بعد و دوره پیش‌بینی.

نتیجه‌گیری

در این تحقیق با استفاده از اطلاعات ایستگاه‌های هواشناسی موجود در داخل و خارج از محدوده نهالوند، و بهره‌گرفتن از نرم‌افزار HEC-4 و روش‌های آماری بین‌دما و تبخیر هر ایستگاه، بازسازی آمار صورت‌گرفت و در محیط نرم‌افزار GIS، نقشه‌های ماهانه، هم‌بارش، هم‌دما و هم‌تبخیر در دوره آماری (سال آبی ۱۳۷۶-۱۳۷۵ تا ۱۴۰۳-۱۴۰۲) ترسیم شد. با استفاده از اطلاعات چاه‌های مشاهداتی و تکمیل آمار چاه‌های موجود، هیدروگراف واحد آبخوان نهالوند ترسیم شد. مدل‌های هوش مصنوعی شامل حافظه کوتاه مدت طولانی (LSTM) و روش گروهی مدیریت داده (GMDH) برای مدل‌سازی تراز سطح آب زیرزمینی آبخوان نهالوند استفاده شد. سپس از ابزار پیش‌پردازش داده، تجزیه مدتجربی یکپارچه کامل (CEEMD) استفاده نموده و مدل‌های ترکیبی تشکیل شد. مقایسه بین نتایج مدل‌های هوشمند بر پایه داده‌های مشاهداتی صورت پذیرفت، تا مدل برتر مشخص شود. در مرحله بعد، برای پیش‌بینی تراز سطح آب زیرزمینی در دوره‌های آبی، از مدل برتر استفاده شد. به‌طور کلی نتایج این مطالعه به صورت زیر می‌باشد:

نتایج نشان داد که مدل GMDH عملکرد بهتری نسبت به مدل LSTM داشته است. در مدل LSTM، ضریب تعیین ۰/۸۶۷، جذر میانگین مربعات خطای ۰/۴۳۵ و معیار اطلاعاتی آکائیک ۱۵۸/۵۹ بدست آمد. این مدل ترکیب برتر دارای ۱۲ پارامتر ورودی بوده است. در مدل GMDH، ضریب تعیین ۰/۸۸۵، خطای آن ۰/۴۳۲ و معیار آکائیک ۱۵۸/۵۷ محاسبه شد. این مدل ترکیب برتر دارای ساختار ۱-۱۵-۱۱-۱۲ نرون در لایه‌های مختلف بوده است.

مدل ترکیبی CEEMD-LSTM عملکرد بهتری نسبت به مدل ترکیبی CEEMD-GMDH داشته است. در مدل ترکیبی CEEMD-LSTM، بهترین عملکرد در IMF برابر سه و مقدار ϵ برابر ۰/۲ بدست آمد. مدل ترکیبی CEEMD-LSTM، دارای ضریب تعیین ۰/۹۴۹۶، خطای ۰/۰۲۸۳ و معیار اطلاعاتی آکائیک ۱۵۷/۳۰۷۱ بود. در مدل ترکیبی CEEMD-GMDH، بهترین عملکرد در IMF برابر دو و مقدار ϵ برابر ۰/۳ بدست آمد. مدل ترکیبی CEEMD-GMDH، دارای ضریب تعیین ۰/۹۴۵، مقدار خطای ۰/۰۲۹۲ و معیار اطلاعاتی آکائیک ۱۵۷/۴۰ بوده است.



زیرزمینی یا ویژگی‌های هیدروژئولوژیکی آبخوان می‌تواند بر دقت پیش‌بینی مدل‌ها تأثیرگذار باشد.

علاوه بر این، مدل‌های ارائه‌شده روابط فیزیکی حاکم بر جریان آب زیرزمینی را به صورت صریح شبیه‌سازی نمی‌کنند و رفتار سیستم را از طریق الگوهای آماری و یادگیری داده‌ها بازنمایی می‌نمایند. بنابراین، تعمیم نتایج این مطالعه به سایر آبخوان‌ها یا دوره‌های زمانی متفاوت نیازمند واسنجی مجدد مدل‌ها و استفاده از داده‌های محلی می‌باشد. همچنین عدم بررسی صریح عدم قطعیت پیش‌بینی‌ها از دیگر محدودیت‌های این پژوهش محسوب می‌شود که می‌تواند در مطالعات آینده مورد توجه قرار گیرد.

پیامدهای کاربردی پیش‌بینی تراز سطح آب زیرزمینی شامل بهینه‌سازی برداشت آب، کاهش خطر افت سطح ایستابی، افزایش بهره‌وری کشاورزی، پایش خشکسالی و تغییر اقلیم و پشتیبانی از تصمیم‌گیری علمی می‌باشد. پیامدهای مدیریتی پیش‌بینی تراز سطح آب زیرزمینی شامل مدیریت پایدار آبخوان، کاهش تعارضات اجتماعی، پشتیبانی از سیاست‌های دولتی، مدیریت بحران و کاهش هزینه‌های پایش سنتی می‌باشد.

مقایسه نتایج مدل‌های هوشمند نشان داد که مدل ترکیبی CEEMD-LSTM دارای بهترین عملکرد بوده است. با استفاده از مدل برتر در این مطالعه، مقادیر تراز سطح آب زیرزمینی آبخوان نهاوند از مهر ۱۴۰۳ تا اسفند ۱۴۰۳ (زمان تدوین این مطالعه) برآورد شد. به طور کلی می‌توان گفت که عملکرد مدل ترکیبی CEEMD-LSTM برای مدل‌سازی تراز سطح آب زیرزمینی آبخوان نهاوند بسیار مناسب بوده و قابلیت این را دارد که از این مدل برای پیش‌بینی مقادیر تراز سطح آب زیرزمینی این آبخوان در دوره‌های آتی استفاده نمود. با وجود نتایج قابل قبول به دست آمده در این مطالعه، لازم است محدودیت‌های مدل‌های مورد استفاده نیز مورد توجه قرار گیرد. نتایج این مدل‌ها دارای محدودیت‌هایی است که باید در تفسیر و تعمیم نتایج مدنظر قرار گیرد. مدل‌های مبتنی بر هوش مصنوعی از جمله LSTM و GMDH ماهیتی داده‌محور دارند و وابستگی زیادی به کیفیت، طول دوره آماری و توزیع زمانی داده‌های ورودی دارند. از این رو، تغییر در شرایط اقلیمی، الگوی بهره‌برداری از آب

تقدیر و تشکر

نویسندگان این تحقیق، از شرکت آب منطقه‌ای همدان به دلیل در اختیار قرار دادن اطلاعات مورد نیاز این مطالعه، کمال تقدیر و تشکر را بعمل می‌آورند.

منابع

- پناهی، م.، ف. میثاقی، و پ. عسگری. ۱۳۹۷. شبیه‌سازی و تخمین نوسانات سطح آب زیرزمینی با استفاده از GMS. فصلنامه علوم محیطی، دوره ۱۶، شماره ۱، ص ۱۴-۱.
- جمالی‌زاده، م.ع.، ا. بذرافشان، ر. مهدوی نجف‌آبادی، ع. آذره، و ا. رفیعی ساردوئی. ۱۳۹۹. پیش‌بینی نوسانات سطح آب زیرزمینی با استفاده از مدل‌های سری زمانی و GMS (مطالعه موردی: دشت رفسنجان). اکوهیدرولوژی، دوره ۷، شماره ۱، ص ۹۷-۱۰۹.
- خطیبی‌نیا، ک. ۱۳۹۴. پیش‌بینی نوسانات سطح آب زیرزمینی در آبخوان بهاباد با استفاده از مدل عددی. پایان‌نامه کارشناسی ارشد، گروه علوم زمین، دانشگاه صنعتی شاهرود.
- خیاط، ا.، م. امیرآبادی‌زاده، م. پوررضا بیلندی، و ح. خزیمه‌نژاد. ۱۴۰۰. پیش‌بینی سطح آب زیرزمینی دشت بیرجند با

استفاده از شبکه عصبی-فازی تحت تأثیر تغییر اقلیم. مجله آبخوان و قنات، دوره ۳، شماره ۱، پیاپی ۲، ص ۳۸-۵۱.

سلامتیان، س.ا.، ح. ابراری، و ع. نظری. ۱۴۰۲. پیش‌بینی تراز آب زیرزمینی با استفاده از مدل استنتاج تطبیقی عصبی فازی (مطالعه موردی: دشت قم). نشریه مهندسی آبیاری و آب ایران، دوره ۱۳، شماره ۵۱، ص ۳۰۴-۲۸۵.

سلگی، ا. ۱۳۹۳. پیش‌بینی جریان رودخانه با مدل ترکیبی شبکه عصبی مصنوعی-موجک و مقایسه آن با روش‌های سیستم استنتاج فازی عصبی تطبیقی و شبکه عصبی مصنوعی (مطالعه موردی: رودخانه گاماسیاب نهانوند)، پایان‌نامه کارشناسی ارشد رشته مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز.

سلیمان‌پور، س.م.، س. زندی‌فر، ا. رحمتی، و م. معتمدنیا. ۱۴۰۴. ارزیابی روند تغییرات دوره‌ای سطح آب زیرزمینی حوزه آبخیز بهادران استان یزد. مدل‌سازی و مدیریت آب و خاک، دوره ۵، شماره ۱، ص ۴۴-۲۹.

شهبازی، م.، ح. زارعی، و ا. سلگی. ۱۴۰۱. ارزیابی عملکرد مدل‌های مبتنی بر تجزیه داده و داده‌های ماهواره گریس برای مدل‌سازی سطح آب زیرزمینی (مطالعه موردی: آبخوان آسپاس). نشریه پژوهش‌های حفاظت آب و خاک، دوره ۲۹، شماره ۴، ص ۵۰-۲۷.

ندیری، ع.ا.، ک. نادری، ا. اصغری‌مقدم، و م.ح. حبیبی. ۱۳۹۵. پیش‌بینی زمانی و مکانی سطح آب زیرزمینی با استفاده از روش‌های هوش مصنوعی و زمین‌آمار (مطالعه موردی: آبخوان دشت دوزدوزان). جغرافیا و برنامه‌ریزی، دوره ۲۰، شماره ۵۸، پیاپی ۲، ص ۳۰۱-۲۸۱.

یاری، ر.ا.، و ع. درزی‌نفت‌چالی. ۱۳۹۶. پیش‌بینی نوسانات سطح آب زیرزمینی تحت سناریوهای مختلف مدیریتی با استفاده از مدل MODFLOW. آبیاری و آب ایران، دوره ۸، شماره ۲، پیاپی ۳۰، ص ۱۱۵-۱۰۳.

Aderemi, B.A., T.O. Olwal, M. Julius, J.M. Ndambuki, and S.S. Rwanga. 2023. Groundwater levels forecasting using machine learning models: A case study of the groundwater region 10 at Karst Belt, South Africa. *Systems and Soft Computing*, 5(200049).

Amirat, Y., M. Benbouzidb, T. Wang, K. Bacha, and G. Feld. 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133: 202-209.

Asikoglu, O.L. 2017. Outlier Detection in Extreme Value Series. *Journal of Multidisciplinary Engineering Science and Technology (JMEST)*, 4(5): 7314-7318.

Bahmani, R., and T.B.M.J. Ouarda. 2020. Groundwater level modeling with hybrid artificial intelligence techniques. *Journal of Hydrology*, **595:1-12**.

Bahmani, R., A. Solgi, and T.B.M.J. Ouarda. 2020. Groundwater level simulation using gene expression programming and M5 model tree combined with wavelet transform. *Hydrological sciences journal*, 65(8): 1430-1442.

Farrow, S.J. 1984. The GMDH algorithm. In S.J. Farrow (ed.), *Self-organizing Methods in Modeling: GMDH type Algorithms*. Marcel Dekker. New York, pp 1-27.

Havril, T., Á. Tóth, J.W. Molson, A. Galsa, and J. Mádl-Szőnyi. 2018. Impacts of predicted climate change on groundwater flow systems: Can wetlands disappear due to recharge reduction? *Journal of Hydrology*, 563: 1169-1180.

Huang, Y., F.G. Schmitt, Z. Lu, and Y. Liu. 2009. Analysis of daily river flow fluctuations using empirical mode decomposition and arbitrary order Hilbert spectral analysis. *Hydrology*, 373(1-2):103-111.

Kayhomayoon, Z., N. Arya Azar, S. Ghordoyee Milan, H. Kardan Moghaddam, and R. Berndtsson. 2021. Novel approach for predicting groundwater storage loss using machine learning. *Journal of Environmental Management*, 296 (15)113237.

Konikow, L.F. and E. Kendy. 2005. Groundwater Depletion: A Global Problem. *Hydrogeology Journal*, 13: 317-320.

Mirarabi, A., H.R. Nassery, M. Nakhaei, J. Adamowski, A.H. Akbarzadeh, and F. Alijani. Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*, 478 (489).

Moustadraf, J., M. Razack, and M. Sinan. 2003. Evaluation of the impacts of climate changes on the coastal Chaouia aquifer, Morocco, using numerical modeling. *Hydrogeology Journal*, 16(7):1411-1426.

Mujahid, I., A.N. Usman, A. Afaq, R. Habib-ur, G. Usman, and F. Tallat. 2020. Relating



groundwater levels with meteorological parameters using ANN technique. *Measurement*, 166 (108163).

Mukul Fishman, R. T. Siegfried, P. Raj, V. Modi, and U. Lall. 2011. Over-extraction from shallow bedrock versus deep alluvial aquifers: Reliability versus sustainability considerations for India's groundwater irrigation. *Water Resources Research*, 47(6).

Pachepsky, Ya., W. Rawls, D. Gimenez, and J.P.C. Watt. 1998. Use of soil penetration resistance and group method of data handling to improve soil water retention estimates. *Soil Tillage Research*, 49:117-128.

Sang, Y.F., Z. Wang, and C. Liu. 2012. Period identification in hydrologic time series using empirical mode decomposition and maximum entropy spectral analysis. *Hydrology*, 424-425:154-164.

Sattari, M.T., R. Mirabbasi, R. Shamsi Sushab, and J. Abraham. 2017. Prediction of Groundwater Level in Ardebil Plain Using Support Vector Regression and M5 Tree Model. *National GroundWater Association*, 56(4): 636-646.

Shahbazi, M., H. Zarei, and A. Solgi. 2023 De-noising groundwater level modeling using data decomposition techniques in combination with artificial intelligence (case study Aspas aquifer). *Applied Water Science*, 13(88):1-18.

Sophocleous, M. 2000. From Safe Yield to Sustainable Development of Water Resources-The Kansas Experience. *Journal of Hydrology*, 235: 27-43.

Van Loon, A.F. and H.A.J. Van Lanen. 2013. Making the distinction between water scarcity and drought using an observation-modeling framework. *Water Resources Research*, 49: 1483-1502.

Wu, Z. and N.F Huang. 2004. A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of the Royal Society of London, Series A: Mathematical, Physical and Engineering Sciences*, 460(2046):1197-1611.

Yeh, J.R., Shieh, J.S., & Huang, N.E. (2010). Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method. *Advances in Adaptive Data Analysis*, 2(2), 135–156.

Torrence, C., & Compo, G.P. (1998). A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*, 79(1), 61–78.