

Research Paper

Estimation of Underground Water Level Using GMDH Method (Case study: Perry and Bondville Wells in the Plains of Illinois, USA)

AmirAbbas Jahanara¹, Saeed Reza Khodashenas^{2*}, Mohammad Najafzadeh³

¹ Department of Water Science and Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

² Department of Water Science and Engineering, Ferdowsi University of Mashhad, Mashhad, Iran

³ Graduate University of Advanced Technology, Kerman, Iran



10.22125/IWE.2022.330987.1604

Received:
March 4, 2022
Accepted:
August 4, 2022
Available online:
August 23, 2023

Keywords:
Water resources
management, time series,
Illinois Plains, soft
computing

Abstract

In this research, the GMDH Method was developed to estimate the groundwater level. For this purpose, the daily data (for the last 21 years) of two observation wells dug in the plains of Illinois, USA, were used. GMDH model development was developed based on two approaches, conventional model and Neuro Fuzzy-GMDH. The training of the mentioned models was done using the least squared error algorithm and also the particle swarm optimization (PSO) algorithm. Time delays (up to five units) of the data related to the underground water level in these wells were used in the design of the pattern of the input variables. The results of this research showed that the GMDH model of the underground water level in the Bondeville well with statistical error indicators including $R^2=0.98$, $RMSE=0.333$ and the $MAPE=9.9\%$ and in Perry well average with $R^2=0.99$, $RMSE=0.64$ and $MAPE=12\%$ in the validation phase. The results of the development of the NF-GMDH model showed that the accuracy of the development of the GMDH model based on the neuro-fuzzy approach also has a suitable accuracy and is equal to the GMDH model. The accuracy of both GMDH and NF-GMDH models increases with the increase of the underground water level, so that the maximum values of the underground water level are accurately predicted, while both models have the property of overprediction in estimating the low values of the underground water level.

1. Introduction

Groundwater is always one of the most important pillars of the development of human societies, industrial and agricultural projects all over the world, especially in arid and semi-arid regions. Forecasting the underground water level in these areas and modeling its fluctuations is very important in the management and exploitation of these resources. Estimating and modeling the underground water level plays an essential role even in determining the irrigation cycle (Cheng Kashani and Hammet, 2016). Due to the importance of modeling and estimating the underground water level, many researchers have studied and investigated the underground water level and its changes and fluctuations. Mohtsham et al. (2016) studied the numerical modeling of the water level in Birjand Plain using artificial neural network model and MODFLOW numerical model. They used GMS software package

* **Corresponding Author:** Saeed Reza Khodashenas

Address: Department of Water Science and Engineering,
Ferdowsi University of Mashhad, Mashhad, Iran

Email: khodashenas@ferdowsi.um.ac.ir

Tel: +9851 38805720

for numerical modeling using MODFLOW software package. The results of their research showed that the MODFLOW model can predict the underground water level up to the next 24 months with acceptable accuracy, and the artificial neural network model can also predict the underground water level up to the next 18 months with reasonable accuracy. The use of numerical models such as GMS software packages require a lot of information about the aquifer (such as hydraulic conductivity coefficient, special storage, etc.). Therefore, this type of numerical modeling needs recalibration because the hydrodynamic parameters and coefficients of the aquifer are changing. The completer and more accurate the information about the aquifer is, the more accurate and reliable the numerical modeling results will be. Nowadays, due to the high cost of calibrating numerical models (such as GMS software), researchers use soft computing models to estimate and predict the hydrodynamic behavior of aquifers.

2. Materials and Methods

In this research, in order to model the fluctuations of the underground water level, the data of the Bondville and Perry observation wells in the Illinois region of the United States were used. The underground water level in these two wells is recorded daily by the regional water organization of this province. The recorded data from these two wells during the years 2001 until now are available. Table 1 shows the location coordinates of this well. In figure (1 and 2) the fluctuations of the underground water level are shown in Bondeville and Perry wells during the used statistical period, respectively. The statistical characteristics of the data recorded in this well are presented in Table (1).

Group method of data Handeling(GMDH)

The GMDH model is one of the types of multilayer neural network models, which has an introduction layer of variables and input parameters, an intermediate layer (s) and an output layer within its structure. Using combinations of optimizer and approximation in the structure of this model creates more accurate results of predicting the physical behavior of phenomena. In this network, the relationship between the input and output parameters of each system can be expressed by the series of Volterra functions, which is similar to the discretized Klomogrov-Gabor polynomial, in the form of equation (1).

3. Results

In this part, the results of modeling and forecasting of the underground water level in the studied areas (Perry and Bondville wells in the plains of Illinois, USA) are presented using soft computing models including the data group classification model. As it was said, for modeling and estimating the level of the water table in each region, the pattern of input variables is designed based on the number of time delays (up to five numbers). The prepared data are divided into training and testing according to the pattern of input variables to be used in the calibration and validation stage of GMDH and NF-GMDH-PSO models. In order to estimate the underground water level in these two wells according to the patterns presented in Tables 5 and 6, in the first scenario, the first and second time delay steps are considered as input and the underground water level at time step t is considered as output. . Considering that there are only two inputs in this scenario, therefore there is only one neuron in this network. The coefficients used in this study of both Bondville and Perry wells are presented in Table 4 for both wells. The performance of GMDH model developed based on this scenario in different stages of development including training and testing is presented in Tables 5 and 6. Next, the effect of increasing input information in the form of increasing time delays was investigated. The results of the effect of increasing the input information on the accuracy of the GMDH model in different stages of development, including training and testing, are given in Tables (5 and 6). Examining this table shows that the statistical indices of the GMDH model developed for the Bondoil well are very suitable, so that in the training stage, the average statistical index of the explanation coefficient is $R^2=0.98$ and the root mean square error $RMSE=0.327m$ and the absolute average error percentage is equal to $MAPE=10\%$. It should be noted that the average performance of the developed models in the test phase is $R^2=0.9$, and the root mean square error is $RMSE=0.333m$ and $MAPE=9.9\%$.

4. Discussion and Conclusion

In this study, the groundwater level in Bondville and Perry wells in Illinois was modeled and predicted using GMDH and NF-GMDH-PSO models. For this purpose, the daily information of the last twenty years of both wells was used. In order to design and determine the pattern of input variables, time delays

(up to five-time delay units) were used. The training and development of GMDH model was done with the help of error square algorithm and the training of NF-GMDH-PSO model, as its name suggests, was done with the help of particle swarm algorithm. The activation function in the GMDH algorithm is a degree polynomial function and, in the NF, -GMDH-PSO model it is a Gaussian function. The results showed that the GMDH model with three units of time delay in the input variables with statistical indicators in the verification stage can predict the underground water level of Bondoil and Perry wells with an accuracy of $[[RMSE]]_P=0.64m$ and $[[RMSE]]_B=0.333m$. NF-GMDH-PSO model with the same input variables can predict the underground water level with an accuracy equal to $[[RMSE]]_P=0.684m$ and $[[RMSE]]_B=0.528$ in the verification stage.

5. Six important references

- 1) Emamgholizadeh, S. Moslemi, K. Karami, G. (2014) Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS), *Water resources management*, 28(15) 5433-5446
- 2) Khalili Naft Chali, A. Shahidi, A. khashei siuki, A. (2017) Comparison of Lazy Algorithms and M5 Model to Estimate Groundwater Level (Case Study: Plain Neyshabur), *Journal of Water and Soil Science*, 21(3) 15-26.
- 3) Kisi, O. Shiri, J. (2012) Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations, *Hydrology Research*, 43(3) 286-300.
- 4) Mohtashami, A., Monfared, S. A. H., Azizyan, G., & Akbarpour, A. (2022). Numerical simulation of groundwater in an unconfined aquifer with a novel hybrid model (case study: Birjand Aquifer, Iran). *Journal of Hydroinformatics*, 24(1), 160-178.
- 5) Najafzadeh, M. Mahmoudi-Rad, M. (2019) Estimation of the Maximum Scour Depth at Bridge Pier under Effects of Debris Accumulations using NF-GMDH Model and Evolutionary Algorithms, *Environment and Water Engineering*, 5(3) 213-225.
- 6) Sahoo, S. Jha, M.K. (2015) On the statistical forecasting of groundwater levels in unconfined aquifer systems, *Environmental Earth Sciences*, 73(7) 3119-3136

Conflict of Interest

Authors declared no conflict of interest.

تخمین سطح آب زیرزمینی با استفاده مدل دسته‌بندی گروهی داده‌ها (مطالعه موردی: چاه‌های پری و بوندویل دشت ایلینوی آمریکا)

امیر عباس جهان آرا^۱، سعیدرضا خداشناس^{۲*}، محمد نجف زاده^۳

تاریخ ارسال: ۱۴۰۰/۱۲/۰۳

تاریخ پذیرش: ۱۴۰۱/۰۵/۲۳

مقاله پژوهشی

چکیده

در این تحقیق به توسعه مدل دسته‌بندی گروهی داده‌ها جهت تخمین سطح آب زیرزمینی پرداخته شد. بدین منظور از اطلاعات روزانه (۲۱ سال اخیر) دو چاه مشاهده‌ای حفر شده در دشت ایلینوی آمریکا استفاده گردید. توسعه مدل GMDH بر اساس دو رهیافت مدل مرسوم و مدل دسته‌بندی فازی عصبی گروهی داده‌ها NF-GMDH انجام گرفت. آموزش مدل‌های ذکر شده با استفاده از الگوریتم کمترین مربعات خطا و همچنین الگوریتم بهینه‌سازی ازدحام ذرات (PSO) انجام شد. در طراحی الگوی متغیرهای ورودی از تأخیرهای زمانی (تا پنج واحد) داده‌های مربوط به سطح آب زیرزمینی در این چاه‌ها استفاده شد. نتایج این تحقیق نشان داد که مدل GMDH سطح آب زیرزمینی در چاه بوندویل را با شاخص‌های آماری خطا شامل $R^2 = 0.98$ و ریشه میانگین مربعات خطا $RMSE = 0.333$ و متوسط درصد خطای مطلق $MAPE = 9.9\%$ و در چاه پری متوسط با $R^2 = 0.99$ ، $RMSE = 0.64$ و $MAPE = 12\%$ در مرحله صحت سنجی پیش‌بینی نماید. نتایج توسعه مدل NF-GMDH نشان داد که دقت توسعه مدل GMDH بر مبنای رهیافت عصبی فازی نیز دارای دقتی مناسب و در حد مدل GMDH است. دقت هر دو مدل GMDH و NF-GMDH با افزایش سطح سطح آب زیرزمینی افزایش می‌یابد به طوری که مقادیر حداکثر سطح آب زیرزمینی دقیق پیش‌بینی می‌شود حال آنکه هر دو مدل در تخمین مقادیر کم سطح آب زیرزمینی دارای خاصیت بیش پیش‌بینی هستند.

واژه‌های کلیدی: مدیریت منابع آب، سری‌های زمانی، دشت ایلینوی آمریکا، محاسبات نرم.

^۱ دکتری سازه آبی گروه علوم و مهندسی آب، دانشگاه فردوسی مشهد، amirjahanara20@gmail.com

^{۲*} استاد گروه علوم و مهندسی آب، دانشگاه فردوسی مشهد، khodashenas@ferdowsi.um.ac.ir (نویسنده مسئول)

^۳ دانشیار، دانشگاه تحصیلات تکمیلی و فناوری پیشرفته کرمان، m.najafzadeh@kgut.ac.ir

مقدمه

نیاز به واسنجی دارند چراکه پارامترها و ضرایب هیدرودینامیک آبخوان در حال تغییر هستند. هر قدر که اطلاعات مربوط به آبخوان کامل تر و دقیق تر باشد نتایج مدل سازی عددی هم دقیق تر و قابل اعتمادتر خواهد بود. امروزه با توجه به هزینه زیاد واسنجی مدل های عددی (مانند نرم افزار GMS) محققان از مدل های محاسبات نرم برای تخمین و پیش بینی رفتار هیدرودینامیک آبخوان ها استفاده می کنند. زارع ابیانه و همکاران (۱۳۹۰) به پیش بینی سطح سطح ایستابی در آبخوان دشت ملایر با استفاده از مدل شبکه عصبی مصنوعی پرداختند. آن ها به منظور تخمین سطح آب زیرزمینی در این دشت از اطلاعات هواشناسی ایستگاه های تبخیر سنجی در سطح دشت، حجم آب برداشتی از سفره و مقادیر سطح ایستابی در ماه ها و سال های گذشته استفاده نمودند. اطلاعات هواشناسی شامل میانگین دمای حداکثر، میانگین دمای حداقل، میانگین رطوبت نسبی و میانگین رطوبت نسبی حداقل هوا و میانگین بارش ماهانه و میانگین تبخیر ماهانه بود. نتایج تحقیقات آن ها نشان داد که مدل شبکه عصبی می تواند حداکثر با ۱/۹ درصد خطا سطح سطح ایستابی را مدل سازی و تخمین بزند. رجایی و پوراصلان (۱۳۹۴) به مدل سازی و پیش بینی زمانی و مکانی سطح آب زیرزمینی در دشت داورزن با استفاده از مدل شبکه عصبی مصنوعی و روش زمین آمار کریجینگ پرداختند. متغیرهای ورودی از جنس همان سطح آب زیرزمینی با یک، دو و سه واحد تأخیر زمانی (یک، دو و سه ماه گذشته) در نظر گرفته شدند. نتایج مدل سازی سطح سطح ایستابی با استفاده از مدل شبکه عصبی نشان داد که این مدل دقت مناسبی در تخمین سطح آب زیرزمینی است. دهقانی و همکاران (۱۳۹۵) به پیش بینی و مدل سازی تخمین سطح آب زیرزمینی در دشت نورآباد با استفاده از استفاده از شبکه عصبی مصنوعی چندلایه و شبکه عصبی بیزین پرداختند. نتایج تحقیقات آن ها نشان داد که شبکه بیزین در تخمین اکثر مقادیر عملکرد قبل قبولی داشته به گونه ای که این مقادیر را نزدیک به مقادیر مشاهداتی تخمین زده است. خلیلی نفت چالی و همکاران (۱۳۹۶) به مدل سازی و تخمین سطح سطح

آب های زیرزمینی همواره یکی از مهم ترین ارکان توسعه جوامع بشری، طرح های صنعتی و کشاورزی در سراسر دنیا مخصوصاً مناطق خشک و نیمه خشک است. پیش بینی سطح آب زیرزمینی در این مناطق و مدل سازی نوسانات آن در مدیریت و بهره برداری از این منابع بسیار مهم است. تخمین و مدل سازی سطح آب زیرزمینی حتی در تعیین دور آبیاری نیز نقش اساسی دارد (کاشانی و همت، ۱۳۹۶) با توجه به اهمیت مدل سازی و تخمین سطح آب زیرزمینی محققان زیادی به مطالعه و بررسی سطح آب زیرزمینی و تغییرات و نوسانات آن پرداخته اند (محتشمی و همکاران، ۲۰۲۲). نخعی و صابری نصر (۱۳۹۱) به مدل سازی و تخمین سطح سطح ایستابی در دشت قروه با استفاده از مدل ترکیبی شبکه عصبی-موجک و بسته نرم افزاری MODFLOW پرداختند. آن ها ۷۰ درصد اطلاعات استخراج شده از سیگنال سری زمانی سطح سطح آب به کمک مدل موجک را برای آموزش و ۱۵ برای صحت سنجی و ۱۵ درصد مابقی را برای آزمون اختصاص دادند. نتایج تحقیق آن ها نشان داد که مدل موجک-عصبی دقت بسیار مناسبی در تخمین سطح آب زیرزمینی در این دشت را دارد. مقایسه دقت مدل موجک-عصبی و مدل MODFLOW نشان داد که مدل موجک-عصبی دارای دقت بسیار بیشتری در تخمین سطح سطح ایستابی است. محتشم و همکاران (۱۳۹۶) به مدل سازی عددی سطح سطح ایستابی در دشت بیرجند با استفاده از مدل شبکه عصبی مصنوعی و مدل عددی MODFLOW پرداختند. آن ها برای مدل سازی عددی با استفاده از بسته نرم افزاری MODFLOW بسته نرم افزاری GMS را به کار گرفتند. نتایج تحقیقات آن ها نشان داد که مدل MODFLOW می تواند سطح آب زیرزمینی تا ۲۴ ماه آینده با دقت قابل قبولی و همچنین مدل شبکه عصبی مصنوعی نیز می تواند سطح آب زیرزمینی را تا ۱۸ ماه آینده با دقت مناسبی پیش بینی کند. استفاده از مدل های عددی مانند بسته های نرم افزار GMS نیازمند اطلاعات زیادی از آبخوان (مانند ضریب هدایت هیدرولیکی، ذخیره ویژه و ...) هستند. لذا این نوع از مدل سازی عددی همراه



مصنوعی شامل مدل فازی و مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی برگشتی پرداختند. ۸۰ درصد از داده‌های مذکور به صورت نرمال شده به عنوان داده‌های ورودی قسمت آموزش مدل‌های هوش مصنوعی استفاده و ۲۰ درصد مابقی داده‌ها نیز به صورت نرمال شده به عنوان ورودی بخش آزمایش مدل‌ها انتخاب شدند. نتایج نشان می‌دهد که هر سه مدل پیش‌بینی قابل قبول ارائه می‌دهد، لذا روش ترکیبی ارائه شده می‌تواند راهگشای مشکلات موجود در آبخوان‌های پیچیده باشد. چوپان و همکاران (۱۳۹۹) به مدل‌سازی نوسانات و تخمین سطح سطح ایستابی دشت رشتخوار واقع شده در استان خراسان رضوی با استفاده از الگوریتم‌های انتخابات و استعماری و شبکه عصبی مصنوعی پرداختند. آن‌ها جهت طراحی الگوی متغیرهای از داده‌های مربوط به سطح آب زیرزمینی در ماه‌های گذشته (از مهرماه تا شهریورماه) به عنوان ورودی و داده‌های مربوط به سطح آب زیرزمینی در زمان مدنظر (t) به عنوان خروجی مدل شبکه عصبی استفاده کردند. نتایج تحقیقات آن‌ها نشان داد که مدل الگوریتم انتخابات دقت و عملکرد بهتری نسبت به دو مدل شبکه عصبی و الگوریتم رقابت استعماری دارد. ملک‌زاده و همکاران (۱۳۹۹) به پیش‌بینی سطح سطح آب در دشت کبودرآهنگ واقع در استان همدان با استفاده از روش‌های ماشین آموزش نیرومند خود تطبیقی (SAELM¹) و موجک- ماشین آموزش نیرومند خود تطبیقی (WA-SAELM) پرداختند. دشت کبودرآهنگ یکی از محدوده‌های مورد مطالعه حوضه رودخانه قره چای است. برای طراحی متغیرهای ورودی از تأخیرهای زمینی داده‌های سطح آب زیرزمینی استفاده شد. تأخیرهای زمانی یک، دو، سه، شش، نه و دوازده ماهانه است. در ابتدا با استفاده از تابع خودهمبستگی، تأخیرهای مؤثر شناسایی شده و سپس با استفاده از این تأخیرها برای هر یک از روش‌های SAELM و WA-SAELM، ده الگوی متمایز ورودی توسعه داده شد. نتایج تحقیقات آن‌ها نشان داد که هر دو مدل توسعه داده شده دارای دقت مناسبی در تخمین سطح سطح ایستابی هستند. شیرینی و کیسی

ایستابی در آبخوان دشت نیشابور با استفاده از مدل درختی M5 و الگوریتم‌های تنبل با روش‌های (KNN، KSTAR و LWL) پرداختند. آن‌ها برای ارزیابی نتایج از شاخص‌های آماری مانند ریشه متوسط خطای مربعات، ضریب همبستگی و متوسط قدر مطلق خطا استفاده کردند. آن‌ها از داده‌های سطح سطح ایستابی، بارندگی، سطح سطح زمین و تخلیه از سفره، برای پیش‌بینی سطح سطح ایستابی آبخوان استفاده کردند. آن‌ها دریافتند که بیشترین دقت و عملکرد زمانی حاصل می‌شود که دو پارامتر دبی تخلیه و بارندگی به عنوان ورودی مدل‌ها در نظر گرفته شوند. بررسی کلی نتایج منتشر شده توسط این محققین نشان داد که مدل‌های توسعه داده شده دارای دقت مناسبی در تخمین سطح سطح ایستابی در این دشت می‌باشند. نوروزی قشبلاغ و ندیری (۱۳۹۷) به پیش‌بینی سطح آب زیرزمینی در دشت بوکان با استفاده از مدل‌های محاسبات نرم شامل نیرو فازی، جنگل تصادفی و شبکه عصبی مصنوعی پرداختند. آن‌ها از پارامترهای بارندگی، دما و دبی جریان و سطح سطح ایستابی در ماه قبل به عنوان ورودی و سطح سطح ایستابی در دوره مورد نظر به عنوان خروجی مدل‌ها در مقیاس زمانی ماهانه استفاده کردند. نتایج تحقیقات آن‌ها نشان داد که به‌طور کلی نتایج مدل نیرو فازی دقیق‌تر از مدل شبکه عصبی بود و نتایج الگوریتم جنگل تصادفی از هر دو مدل نیرو فازی و شبکه عصبی نیز دقیق‌تر است. جبالبارزی و ملکیان (۱۳۹۸) به مدل‌سازی و پیش‌بینی سطح آب زیرزمینی در دشت جیرفت با استفاده از مدل‌های شبکه عصبی مصنوعی و برنامه‌نویسی بیان ژن پرداختند. بررسی نتایج آن‌ها نشان می‌داد که مدل شبکه عصبی دقت مناسبی بسیار در تخمین سطح آب زیرزمینی دارد. مقایسه عملکرد و دقت مدل شبکه عصبی و مدل برنامه‌نویسی بیان ژن نشان داد که مدل شبکه عصبی بسیار بهتر از مدل برنامه‌نویسی بیان ژن می‌تواند سطح آب زیرزمینی را مدل‌سازی و پیش‌بینی نماید. باقری و همکاران (۱۳۹۸) به پیش‌بینی سطح سطح آب زیرزمینی در آبخوان دشت باروق با استفاده از مدل‌های هوش

¹ Self adaptive Extreme Learning Machine

^۱ANFIS از مدل ANN بهتر است. ساهو و همکاران (۲۰۱۷) به مدل‌سازی و پیش‌بینی سطح آب ایستابی در دو آبخوان دشت‌های مرتفع و آبخوان ابرفتی دره رودخانه می‌سی‌سی‌پی با استفاده از مدل شبکه عصبی چندلایه پرداختند. نتایج تحقیق آن‌ها نشان داد که تقاضای آب آبیاری بیشترین تأثیر را در تغییرات سطح آب‌های زیرزمینی برای اکثر چاه‌ها دارد. آن‌ها همچنین اظهار داشتند که مدل توسعه داده شده توسط آن‌ها می‌تواند به‌عنوان ابزاری جهت شبیه‌سازی دقیق سطح آب زیرزمینی در این دو منطقه مورد استفاده قرار بگیرد. سیفی و همکاران (۲۰۲۰) به مدل‌سازی و تخمین سطح آب زیرزمینی در دشت اردبیل با استفاده از مدل‌های شبکه عصبی مصنوعی، شبکه عصبی تطبیقی فازی و ماشین بردار پشتیبان پرداختند. آن‌ها مدل‌های نامبرده شده را با استفاده از شش الگوریتم بهینه‌سازی مدرن شامل الگوریتم بهینه‌سازی ملخ (GOA^2)، بهینه‌سازی ازدحام گریه (CSO)^۳، الگوریتم علف‌های هرز (WA^4)، الگوریتم ژنتیک (GA^5)، الگوریتم کریل (KA)^۶ و بهینه‌سازی ازدحام ذرات (PSO)^۷ کالیبره کردند. نتایج آن‌ها نشان می‌دهد که همه مدل‌های توسعه داده شده دارای دقت بسیار مناسبی در تخمین سطح سطح ایستابی در این دست هستند. بالین‌وجود دقت مدل ANFIS-GOA از همه بهتر گزارش شده است. بررسی موروی بر منابع نشان می‌دهد که مدل‌سازی و تخمین تراز سطح آب زیرزمینی مخصوصاً در مناطق خشک و نیمه خشک از اهمیت بسیار زیادی در مدیریت منابع آب برخوردار است. با توجه به اهمیت مدل‌سازی و پیش‌بینی سطح آب زیرزمینی در مدیریت منابع آب و توسعه طرح‌های کشاورزی و صنعتی در این تحقیق به توسعه مدل دسته‌بندی گروهی داده‌ها جهت تخمین و مدل‌سازی سطح آب زیرزمینی در دشت‌های ایلینوی آمریکا به‌عنوان مطالعه موردی پرداخته شده است.

(۲۰۱۱) به مدل‌سازی و پیش‌بینی رقوم سطح آب زیرزمینی در دشت ایلینوی (ایالت ایلینوی) آمریکا با استفاده از مدل‌های برنامه برنامه‌نویسی بیان ژن (GEP) و شبکه عصبی فازی تطبیقی (ANFIS) پرداختند. بدین منظور آن‌ها از داده‌های روزانه ثبت‌شده از دو چاه مشاهداتی به نام‌های بوندویل و پری که توسط شرکت آب منطقه‌ای این ایالت ثبت‌شده بود استفاده کردند. آن‌ها الگوی متغیرهای ورودی را با در نظر گرفتن تأخیرهای زمانی (تا چهار روز) از داده‌های خود، سری زمانی داده‌های سطح آب زیرزمینی در این دو چاه تهیه و طراحی کردند. برای ارزیابی دقت مدل ای توسعه داده شده آن‌ها از آماره‌های SI، RMSE و VAF استفاده نمودند. نتایج تحقیقات آن‌ها نشان داد که هر دو مدل دارای دقت مناسبی در تخمین سطح آب زیرزمینی در این دشت هستند ولی مدل GEP به دلیل ارائه فرمول صریح بجای یک شبکه از نرون‌ها ارجحیت دارد. کیسی و شیری (۲۰۱۲) با استفاده از مدل موجک-شبکه عصبی فازی تطبیقی (Wavelet-ANFIS) به پیش‌بینی سطح سطح ایستابی در دشت ایلینوی آمریکا پرداختند. هدف آن‌ها از مدل‌سازی سطح آب زیرزمینی تخمین کوتاه‌مدت آن برای یک، دو سه روز آینده بود؛ چراکه برای مصارف آبیاری حتی یک یا دو روز هم از اهمیت بسزایی برخوردار است. نتیجه تحقیق آن‌ها نشان داد که مدل ترکیبی موجک-عصبی فازی دقت بیشتری نسبت به مدل عصبی فازی دارد. امامقلی زاده و همکاران (۲۰۱۴) به پیش‌بینی سطح آب زیرزمینی در دشت بسطام با استفاده از مدل‌های شبکه عصبی چندلایه (ANN) و شبکه عصبی تطبیقی فازی (ANFIS) پرداختند. طراحی الگوی متغیرهای ورودی بر اساس تأخیرهای زمانی (تا چاه ماه تأخیر زمانی) انجام گرفت. قابل‌ذکر است که داده‌های از معرفی به مدل‌ها استاندارد شدند. نتایج تحقیقات آن‌ها نشان داد که هر دو مدل دقت مناسبی در تخمین سطح سطح ایستابی در دشت بسطام دارند ولی به‌صورت جزئی دقت مدل

⁵ Genetic Algorithms

⁶ Krill Herd Algorithm

⁷ Particle swarm optimization

¹ Adaptive neuro fuzzy inference system

² Grasshopper Optimization Algorithm

³ Cat Swarm Optimization

⁴ Invasive Weed Optimization Algorithm

مواد و روش‌ها


مطالعه موردی

در این تحقیق به منظور مدل‌سازی نوسانات سطح آب زیرزمینی از داده‌های مربوط به چاه‌های مشاهداتی بوندویل و پری منطقه ایلینوی ایالات متحده استفاده شد. سطح آب زیرزمینی در این دو چاه به صورت روزانه توسط سازمان آب منطقه‌ای این استان ثبت شده است. اطلاعات


ثبت شده از این دو چاه در طول سال‌های ۲۰۰۱ تاکنون در دسترس است. در جدول ۱ مختصات مکانی این چاه آورده شده است. در شکل (۱ و ۲) نوسانات سطح آب زیرزمینی به ترتیب در چاه بوندویل و پری در طی دوره آماری مورد استفاده نشان داده شده است. مشخصات آماری داده‌های ثبت شده در این چاه در جدول (۱) ارائه شده است.

جدول (۱): مشخصات آماری داده‌های سطح آب زیرزمینی در ایالت ایلینوی آمریکا

	Bondville Well		Perry Well	
	عرض	طول	عرض	طول
جغرافیایی	جغرافیایی	جغرافیایی	جغرافیایی	جغرافیایی
	40°05'N	88°37'W	39°80'N	90°83'W
آموزش	Testing	Testing	آموزش	Testing
حداقل (m)	0.06	0.3	0.04	2.25
حداکثر (m)	9.89	9.89	21.38	19.59
میانگین (m)	4.84	5.1	7.87	13.63
انحراف معیار (m)	2.36	2.4	5.41	6.14



شکل (۱): تغییرات سطح آب زیرزمینی در ایالت ایلینوی آمریکا: چاه بوندویل



شکل (۲): تغییرات سطح آب زیرزمینی در ایالت ایلینوی آمریکا: چاه پری

ساختار GMDH هر نرون حداقل دارای دو ورودی است. ارتباط بین متغیرهای ورودی و خروجی در هر نرون با استفاده از تابع محرک که می‌تواند به صورت یک چندجمله‌ای خطی یا غیرخطی باشد بیان گردد. در ساختار پایه مدل GMDH^۱ از چندجمله‌ای درجه دوم همراه با دو متغیر ورودی به صورت رابطه (۲) بیان می‌شود.

$$y = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2 + w_5 x_1 x_2 \quad (2)$$

که در آن w_0, w_1, \dots, w_5 ضرایب چندجمله‌ای هستند. برای ساخت شبکه GMDH ابتدا ترکیب دوتایی از پارامترهای ورودی را باید در نظر گرفت. بعد از آن در هر نرون با استفاده از روش حداقل مربعات ضرایب وزنی هر نرون و مقدار خطای مربوطه محاسبه می‌شود. در هر لایه برای انتخاب نرون‌های برتر از نظر ویژگی طبقه‌بندی از معیار خطا رابطه (۳) استفاده می‌شود.

$$E = \frac{1}{n} \sum_{i=1}^n (y_{obs_i} - y_{prd_i})^2 \quad (3)$$

که در آن y_{prd_i} و y_{obs_i} به ترتیب شامل مقادیر مشاهداتی، مقادیر محاسباتی حاصل از مدل عددی است. n, E معرف تعداد داده‌های مشاهداتی و مقدار خطای

مدل دسته‌بندی گروهی داده‌ها^۱ (GMDH)

مدل GMDH یکی از انواع مدل‌های شبکه عصبی چندلایه است که درون ساختار خود لایه معرفی متغیرها و پارامترهای ورودی، لایه (های) میانی و لایه خروجی دارد. استفاده از ترکیب‌های بهینه‌ساز و تقریب ساز در ساختار این مدل، باعث ایجاد نتایج دقیق‌تری از پیش‌بینی رفتار فیزیکی پدیده‌ها می‌شود. در این شبکه ارتباط بین پارامترهای ورودی و خروجی هر سیستم را می‌توان با سری توابع ولترا که مشابه چندجمله‌ای گسسته شده کلموگروف-گابور است به صورت رابطه (۱) بیان کرد.

$$y = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ijk} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (1)$$

در این رابطه $x_0, x_1, x_2, \dots, x_m$ بردارهای ورودی و $a_0, a_1, a_2, \dots, a_m$ بردار ضرایب وزنی است. در

^۱ Group method of data handling (GMDH)

$$y^{pm} = f(y^{p-1,m-1}, y^{p-1,m}) = \sum_{k=1}^k u_k^{pm} w_k^{pm} \quad (۷)$$

در رابطه (۷) حاصل ضرب توابع عضویت تشکیل شده در هر نرون است که از رابطه (۸) حاصل می‌شود.

$$u_k^{pm} = \exp \left\{ - \frac{(y^{p-1,m-1} - a_{k,1}^{pm})^2}{b_{k,1}^{pm}} - \frac{(y^{p-1,m} - a_{k,2}^{pm})^2}{b_{k,2}^{pm}} \right\} \quad (۸)$$

همچنین بردار خروجی نهایی در مدل NF-GMDH به صورت میانگین لایه برداری‌های خروجی لایه ماقبل، از طریق رابطه (۹) محاسبه می‌شود:

$$y = \frac{1}{M} \sum_{m=1}^M y^{pm} \quad (۹)$$

در شبکه NF-GMDH در هر نرون دو قانون فازی وجود دارد و در مجموع همراه با شش ضریب مجهول که شامل چهار پارامترهای گوسی و دو ضریب وزنی است. شش پارامتر مجهول در هر نرون که با استفاده از الگوریتم‌های بهینه‌ساز به دست می‌آید (پاراسائی و همکاران، ۲۰۱۹)

ترکیب NF-GMDH با الگوریتم PSO

الگوریتم PSO اولین بار توسط کندی و ابرهات (۱۹۹۵) با بهره‌گیری از زندگی دسته‌جمعی پرندگان ارائه شد. در واقع جهت حل مسائل بهینه‌سازی با استفاده از الگوریتم PSO در ابتدا تعداد ذرات مشخص می‌گردند و موقعیت و سرعت ذره در فضای جستجو مسئله بهینه مشخص می‌گردد. تمامی ذرات از نقطه نظر تابع برازش و دست‌یابی به بهترین جواب مسئله ارزیابی می‌گردند و در صورت ارضاء نشدن شرایط مسئله (خطای معیار) موقعیت و سرعت ذره نیز بروز رسانی می‌شوند. روند ترکیب NF-GMDH و PSO به این صورت است که ابتدا در نرون اول لایه اول الگوریتم PSO اجرا می‌شود. بعد تکرارهای مختلف صورت می‌گیرند و در هر تکرار با استفاده از رابطه (۱۱) پارامتر خطای نرون مورد نظر به دست می‌آید. حال در نرون بعدی دوباره الگوریتم PSO اجرا می‌شود. این روند برای کل نرون‌های لایه اول اجرا می‌گردد و خروجی هر نرون محاسبه می‌شود.

محاسباتی در هر نرون (توصیف گر جزئی) است (نجف زاده و همکاران، ۲۰۱۹)

توسعه مدل NF-GMDH1

به منظور توسعه مدل GMDH تبدیل آن به مدل NF-GMDH از قاعده استدلال فازی ساده شده زیر استفاده می‌شود

«اگر x_1 برابر با F_{x_1} و x_2 برابر با F_{x_2} باشد آنگاه خروجی y برابر با W_k است. در قاعده استدلال فازی بالا، x_1 و x_2 متغیرهای ورودی بوده و تابع گوسی بکار رفته بر حسب F_{x_j} است؛ که به قانون فازی k ام مقادیر ورودی x ام مربوط می‌شود و به شکل رابطه (۴) نوشته می‌شود.

$$F_{kj}(x_j) = \exp \left(- \frac{(x_j - a_{kj})^2}{b_{kj}} \right) \quad (۴)$$

در رابطه (۴) a_{kj} و b_{kj} مقادیر ثلثت برای هر قانون فازی هستند. همچنین بردار خروجی هر نرون از مدل NF-GMDH به صورت رابطه (۵) تعریف می‌شود.

$$y = \sum_{k=1}^k u_k w_k \quad (۵)$$

در رابطه بالا w_k مقدار واقعی برای قانون فازی k ام و u_k تابع گوسی است که به شکل رابطه (۶) تعریف می‌شود:

$$u_k = \prod_j F_{kj}(x_j) \quad (۶)$$

در این مدل هر توصیفگر جزئی (نرون) دارای دو متغیر ورودی و یک متغیر خروجی است و خروجی هر نرون به عنوان متغیر ورودی در لایه بعدی در نظر گرفته می‌شود. در آخر خروجی نهایی با استفاده از میانگین خروجی‌های لایه آخر به دست می‌آید. شکل (۱) ساختار کلی شبکه جلو رونده NF-GMDH را نشان می‌دهد. به طوری که ورودی‌ها مدل m ام (نرون lm) در لایه p ام، متغیرهای خروجی مدل $m-1$ ام و lm ام در لایه p ام هستند. در ادامه ارتباط بین نرون‌های لایه جاری (کنونی) با نرون‌های لایه پیشین به صورت رابطه (۷) بیان می‌شود:

¹ Neuro Fuzzy Group method of data handling (NF-GMDH)

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (11)$$

$$MAPE = 100 \times \left| \frac{P-O}{O} \right| \quad (12)$$

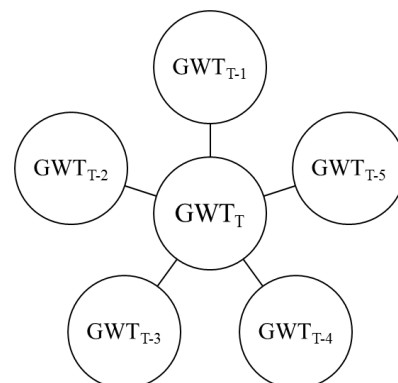
در این فرمول‌ها و \bar{O} و \bar{P} به ترتیب نشان‌دهنده داده‌های مشاهداتی و میانگین آن‌ها، P و \bar{P} به ترتیب نماینده و میانگین نتایج حاصل از واسنجی و صحت سنجی مدل‌های توسعه داده شده است.

نتایج و بحث

در این قسمت نتایج حاصل از مدل‌سازی و پیش‌بینی سطح آب زیرزمینی در مناطق مورد مطالعه (چاه‌های پری و بوندویل در دشت ایلینوی آمریکا) را با استفاده از مدل‌های محاسبات نرم شامل مدل دسته‌بندی گروهی داده‌ها ارائه می‌شود. همان‌طور که گفته شد برای مدل‌سازی و تخمین سطح سطح ایستابی در هر منطقه الگوی متغیرهای ورودی بر اساس تعداد تأخیرهای زمانی (تا پنج عدد) طراحی می‌شود. داده‌ها تهیه شده بر طبق الگوی متغیرهای ورودی به دودسته آموزش و آزمایش تقسیم می‌شوند تا در مرحله واسنجی و صحت سنجی مدل‌های GMDH، NF-GMDH و NF-GMDH-PSO استفاده شوند. در ادامه میزان همبستگی پارامترهای ورودی با پارامتر خروجی بررسی می‌شود. در جدول ۲ و ۳ همبستگی تأخیرهای زمانی با پارامتر خروجی آورده شده است. همان‌طور که از این جدول مشخص است همبستگی بسیار بالایی بین تأخیرهای زمانی مخصوصاً تأخیرهای زمانی با یک تا دو واحد تأخیر زمانی وجود دارد.

توسعه مدل‌ها

به منظور توسعه مدل‌های GMDH و NF-GMDH داده‌های جمع‌آوری شده به دودسته آموزش و آزمایش تقسیم می‌شوند. داده‌های آموزش برای توسعه و واسنجی مدل‌ها و داده‌های آزمایش برای صحت سنجی آن‌ها بکار گرفته می‌شوند. در این تحقیق با توجه به این که داده‌های مشاهداتی هر ۲ چاه از جنس سری زمانی هستند لذا برای مدل‌سازی و تخمین سطح آب زیرزمینی از اطلاعات زمان‌های قبلی استفاده می‌شود (شکل ۱). به منظور توسعه مدل‌ها، ۸۰ درصد داده‌های جمع‌آوری شده به منظور توسعه و واسنجی مدل‌ها و مابقی آن‌ها (۲۰ درصد است) برای صحت سنجی مدل‌ها بکار استفاده شده است. مشخصات آماری داده‌های اختصاص داده شده به هریک از این گروه‌های آموزش و آزمایش شامل کمترین، بیشترین، میانگین و انحراف معیار داده‌ها در جدول ۱ ارائه شده است. به منظور بررسی دقت مدل‌های توسعه داده شده در مراحل مختلف توسعه و صحت سنجی از شاخص‌های خطا شامل ضریب تبیین (R^2) و میانگین مربع خطا (RMSE) و درصد مطلق خطای نسبی (MAPE) استفاده شده است. فرمول این سه شاخص در رابطه‌های (۱۰ تا ۱۲) ارائه شده است.



شکل (۳): متغیرهای ورودی و خروجی ر توسعه مدل‌های NF-GMDH و GMHD



شامل آموزش و آزمایش در جدول (۵ و ۶) آورده شده است. بررسی این جدول نشان می‌دهد که شاخص‌های آماری مدل GMDH توسعه داده شده برای چاه بوندویل بسیار مناسب است به طوری که در مرحله آموزش متوسط شاخص آماری ضریب تبیین عبارت از $R^2 = 0.98$ و ریشه میانگین مربعات خطا $RMSE = 0.327m$ و متوسط مطلق درصد خطای آن برابر با $MAPE = 10\%$ است. قاب ذکر است که متوسط عملکرد مدل‌های توسعه داده شده در مرحله آزمایش عبارت از $R^2 = 0.9$ و ریشه میانگین مربعات خطا $RMSE = 0.333m$ و $MAPE = 9.9\%$ است. عملکرد مدل GMDH توسعه داده شده برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی چاه پری نیز بسیار مناسب است. همان‌طور که در جدول (۶) ارائه شده است در مرحله آموزش متوسط شاخص آماری ضریب تبیین عبارت از $R^2 = 0.99$ ، $RMSE = 0.540m$ و متوسط مطلق درصد خطای آن برابر با $MAPE = 18\%$ است. قابل ذکر است که متوسط عملکرد مدل‌های توسعه داده شده در مرحله آزمایش عبارت از $R^2 = 0.99$ ، $RMSE = 0.64m$ و $MAPE = 12\%$ است. در شکل ۳ مدل GMDH توسعه داده شده با سه ورودی (سه واحد تأخیر زمانی) نشان داده شده است. عملکرد مدل GMDH توسعه داده شده در مرحله آموزش و آزمایش برای سه واحد تأخیر زمانی به عنوان ورودی در شکل (۴) نشان داده شده است. مدل GMDH با سه واحد تأخیر زمانی به عنوان مدل منتخب برای مدل‌سازی سطح آب زیرزمینی چاه‌های بوندویل و پری دشت ایلینوی آمریکا انتخاب می‌شود. عملکرد مدل توسعه داده شده در شکل‌های ۴ تا ۷ نشان داده شده است. در شکل ۴ و ۶ مقادیر مشاهداتی با خروجی‌های مدل در کنار یکدیگر، در شکل (۷ و ۵) مقادیر مشاهداتی و خرجی مدل توسعه داده شده در مقابل یکدیگر ترسیم شده‌اند.

جدول (۴): ضرایب مدل GMDH مدل توسعه داده شده بر اساس دو واحد تأخیر زمانی: چاه بوندویل

نورون	W5	W4	W3	W2	W1	W0
بوندویل	-0.143	0.084	0.062	1.074	-0.129	0.134
پری	-0.065	0.060	0.006	0.912	0.073	0.061


جدول (۲): همبستگی تأخیرهای زمانی در چاه بوندویل

	GW _t	GW _{t-1}	GW _{t-2}	GW _{t-3}	GW _{t-4}	GW _{t-5}
GW _t	1.0	0.99	0.98	0.97	0.96	0.95
GW _{t-1}	0.9	1.00	0.99	0.98	0.97	0.96
GW _{t-2}	0.9	0.99	1.00	0.99	0.98	0.97
GW _{t-3}	0.9	0.98	0.99	1.00	0.99	0.98
GW _{t-4}	0.9	0.97	0.98	0.99	1.00	0.99
GW _{t-5}	0.9	0.96	0.97	0.98	0.99	1.00

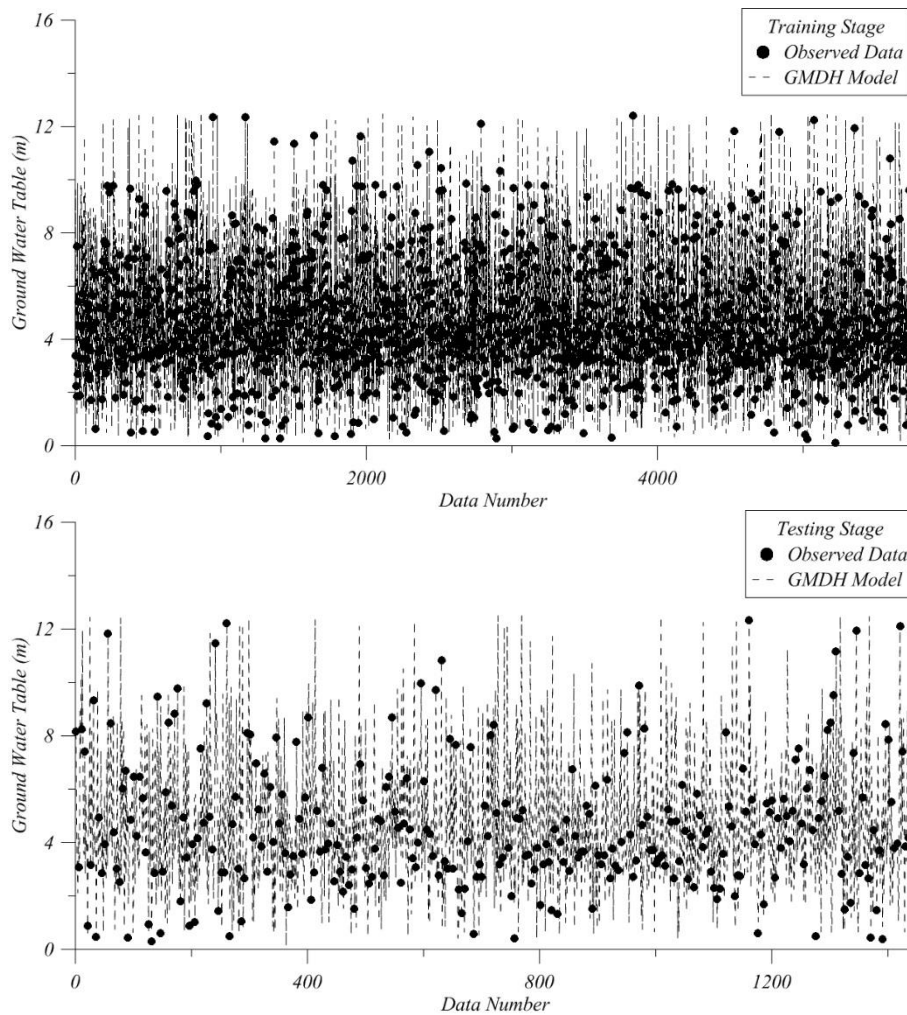
جدول (۳): همبستگی تأخیرهای زمانی در چاه پری

	GW _t	GW _{t-1}	GW _{t-2}	GW _{t-3}	GW _{t-4}
GW _t	1.000	0.995	0.990	0.984	0.979
GW _{t-1}	0.995	1.000	0.995	0.990	0.984
GW _{t-2}	0.990	0.995	1.000	0.995	0.990
GW _{t-3}	0.984	0.990	0.995	1.000	0.995
GW _{t-4}	0.979	0.984	0.990	0.995	1.000
GW _{t-5}	0.973	0.979	0.984	0.990	0.995


به منظور تخمین سطح آب زیرزمینی در این دو چاه طبق الگوهای ارائه شده در جداول ۵ و ۶ در اولین سناریو دو گام تأخیر زمانی اول و دوم (GW_{t-2}, GW_{t-1}) به عنوان ورودی و سطح آب زیرزمینی در گام زمانی t (GW_t) به عنوان خروجی در نظر گرفته می‌شود. با توجه به اینکه تنها دو ورودی در این سناریو وجود دارد لذا تنها یک نرون در این شبکه وجود دارد. ضرایب بکار رفته در این نرون برای هر دو چاه بوندویل و پری در جدول ۴ برای هر دو چاه ارائه شده است. عملکرد مدل GMDH توسعه داده شده بر اساس این سناریو در مراحل مختلف توسعه شامل آموزش و آزمایش در جدول ۵ و ۶ ارائه شده است. در ادامه تأثیر افزایش اطلاعات ورودی در قالب افزایش تأخیرهای زمانی بررسی شد. نتایج تأثیر افزایش اطلاعات ورودی بر دقت مدل GMDH در مراحل مختلف توسعه



شکل (۴): ساختار مدل GMDH مدل توسعه داده شده بر اساس سه واحد تأخیر زمانی: چاه بوندویل

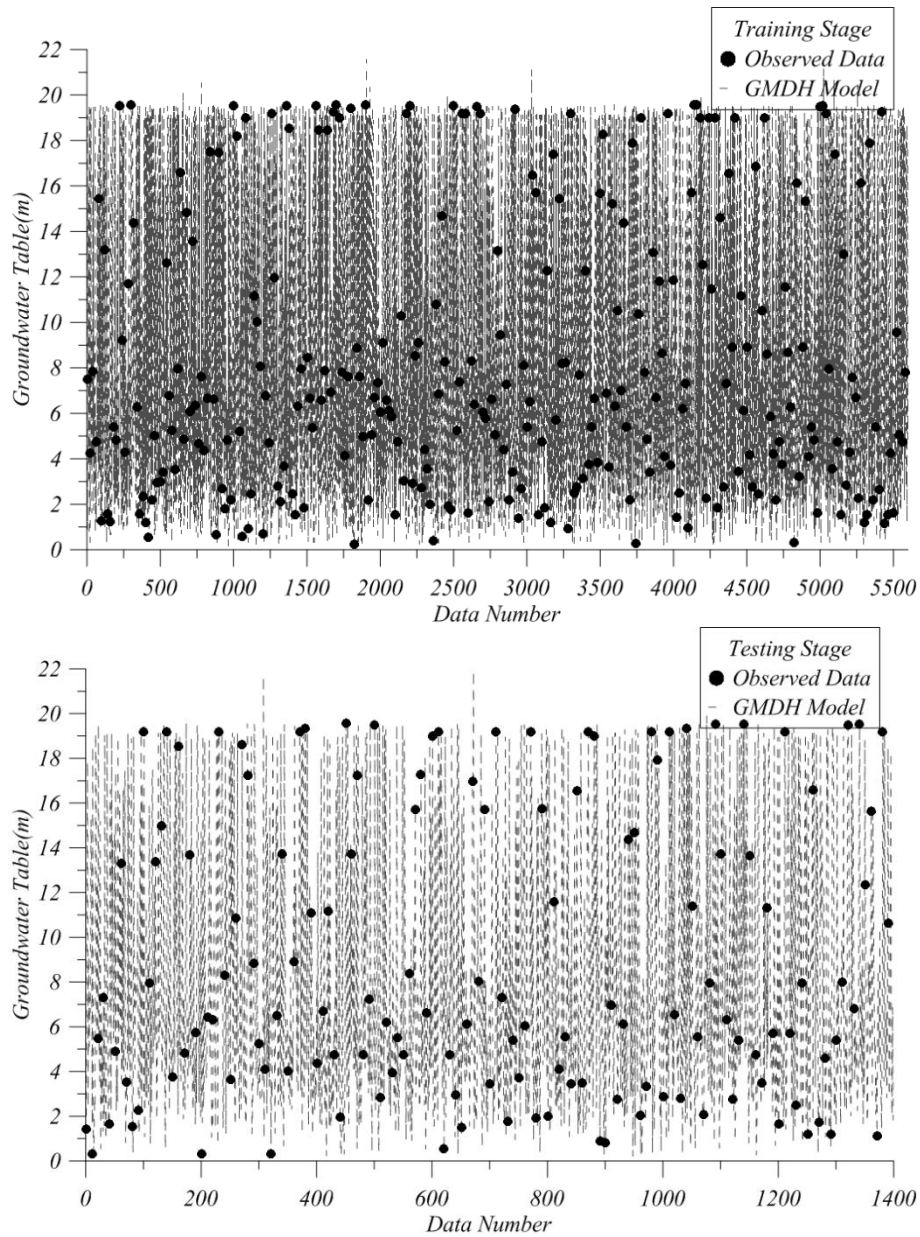


شکل (۵): عملکرد مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه بوندویل: سه واحد تأخیر زمانی)




شکل (۶) عملکرد مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه بوندویل: سه واحد تأخیر زمانی)
جدول (۵): شاخص‌های آماری مدل GMDH توسعه داده شده جهت مدل‌سازی و تخمین سطح آب زیرزمینی: چاه بوندویل

ورودی‌ها	خروجی	آموزش			آزمایش		
		RMS E	R ²	MAP E	RMS E	R ²	MAP E
GWT_{T-2}, GWT_{T-1}		0.327	0.98 1	9.99	0.333	0.98 0	9.91
$GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.326	0.98 1	10.10	0.332	0.98 1	9.92
$GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$	GWT_T	0.328	0.98 1	10.06	0.325	0.98 1	9.64
$GWT_{T-5}, GWT_{T-4}, GWT_{T-3},$ GWT_{T-2}, GWT_{T-1}		0.328	0.98 1	10.07	0.323	0.98 2	9.40



شکل (۷): عملکرد مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه پری: سه واحد تأخیر زمانی)



شکل (۸): عملکرد مدل GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه پری: سه واحد تأخیر زمانی)
جدول (۶): شاخص‌های آماری مدل GMDH توسعه داده شده جهت مدل‌سازی و تخمین سطح آب زیرزمینی: چاه پری

ورودی‌ها	خروجی	آموزش			آزمون		
		RMS E	R ²	MAP E	RMS E	R ²	MAP E
GWT_{T-2}, GWT_{T-1}		0.544	0.992	18.70	0.641	0.989	12.14
$GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.552	0.991	18.75	0.625	0.989	13.19
$GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$	GWT_T	0.572	0.991	17.45	0.543	0.991	17.11
$GWT_{T-5}, GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.600	0.990	18.76	0.380	0.996	12.06

از جداول مشخص است که افزایش اطلاعات ورودی در قالب افزایش تأخیرهای زمانی تأثیری برافزایش دقت مدل‌سازی ندارد. بررسی شکل‌های ۴ و ۶ نشان می‌دهد که مدل توسعه داده شده دارای دقت مناسب در تخمین مقادیر حداکثر سطح آب زیرزمینی در این چاه‌ها چه در

بررسی نتایج توسعه مدل GMDH بر اساس سناریوهای مختلف و همچنین شاخص‌های آماری ارائه شده در جداول ۵ و ۶ نشان می‌دهد دقت مدل GMDH در همه سناریوها برای پیش‌بینی سطح آب زیرزمینی در هر دو این چاه‌ها مناسب است. علاوه بر این



شکل (۸) نشان داده شده است. ضرایب نرون‌های بکار رفته در این شبکه در جدول (۹) آورده شده است. برای آموزش مدل NF-GMDH از الگوریتم PSO استفاده شد که در شکل (۱۰) نشان داده شده است. همان‌طور که از این شکل مشخص است برای این نرون الگوریتم PSO دو بار اجرا شده که جواب‌های به دست آمده در هر دو اجرا نزدیک به هم است. قابل ذکر است که پارامترهای تنظیم شده در الگوریتم PSO در جدول (۱۰) آورده شده است. عملکرد مدل NF-GMDH-PSO در هر دو مرحله آموزش و آزمایش برای هر دو چاه در شکل‌های ۹ و ۱۱ نشان داده شده است. بررسی این شکل‌ها نشان می‌دهد که NF-GMDH هم مثل GMDH در تخمین مقادیر ماکزیمم سطح آب زیرزمینی در هر دو چاه دقت بسیار مناسبی دارد ولی این مدل نیز در تخمین مقادیر کمینه سطح آب زیرزمینی دارای دقت مناسب نیست. مقایسه عملکرد مدل NF-GMDH با GMDH نشان می‌دهد که این دقت مدل GMDH به صورت جزئی بهتر از مدل NF-GMDH است.

مرحله آموزش و چه در مرحله آزمایش است. بررسی شکل‌های ۵ و ۶ نشان می‌دهد که مدل‌های GMDH توسعه داده شده در پیش‌بینی مقادیر کم سطح آب زیرزمینی دارای دقت کافی نمی‌باشند و این مقادیر را بیش از مقدار واقعی‌شان تخمین می‌زنند. به عبارت دیگر برای مقادیر کم سطح آب زیرزمینی مدل خاصیت بیش پیش‌بینی آشکار دارد.


در این پژوهش علاوه بر مدل GMDH، مدل NF-GMDH-PSO نیز توسعه داده شد. ساختار مدل NF-GMDH-PSO در حالتی که فقط دو ورودی وجود دارد شبیه مدل GMDH است. از همان داده‌های استفاده شده برای مدل NF-GMDH نیز برای توسعه مدل NF-GMDH-PSO نیز استفاده شد. نتایج مدل NF-GMDH در این سناریو در جدول (۷ و ۸) آورده شده است. در ادامه برای بررسی اثر افزایش اطلاعات ورودی بر دقت مدل‌سازی تأخیرهای زمانی دیگر نیز به ورودی‌های مدل اضافه شد. ساختار مدل NF-GMDH بر اساس سه واحد تأخیر زمانی در

جدول (۷): شاخص‌های آماری مدل NF-GMDH توسعه داده شده جهت مدل‌سازی و تخمین سطح آب زیرزمینی: چاه بوندویل


ورودی‌ها	خروجی	آموزش			آزمون		
		RMSE	R ²	MAPE	RMSE	R ²	MAPE
GWT_{T-2}, GWT_{T-1}		0.414	0.970	17.62	0.472	0.964	16.36
$GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.510	0.955	20.78	0.373	0.977	13.385
$GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$	GWT_T	0.546	0.952	17.622	0.528	0.955	16.361
$GWT_{T-5}, GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.335	0.981	10.229	0.285	0.986	9.192

جدول (۸): شاخص‌های آماری مدل NF-GMDH توسعه داده شده جهت مدل‌سازی و تخمین سطح آب زیرزمینی: چاه پری

ورودی‌ها	خروجی	آموزش			آزمون		
		RMSE	R ²	MAPE	RMSE	R ²	MAPE
GWT_{T-2}, GWT_{T-1}		0.464	0.965	15.548	0.472	0.964	15.855
$GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.812	0.983	23.598	0.863	0.980	24.615
$GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$	GWT_T	0.531	0.972	15.193	0.684	0.967	26.323
$GWT_{T-5}, GWT_{T-4}, GWT_{T-3}, GWT_{T-2}, GWT_{T-1}$		0.543	0.977	15.643	0.649	0.973	23.672



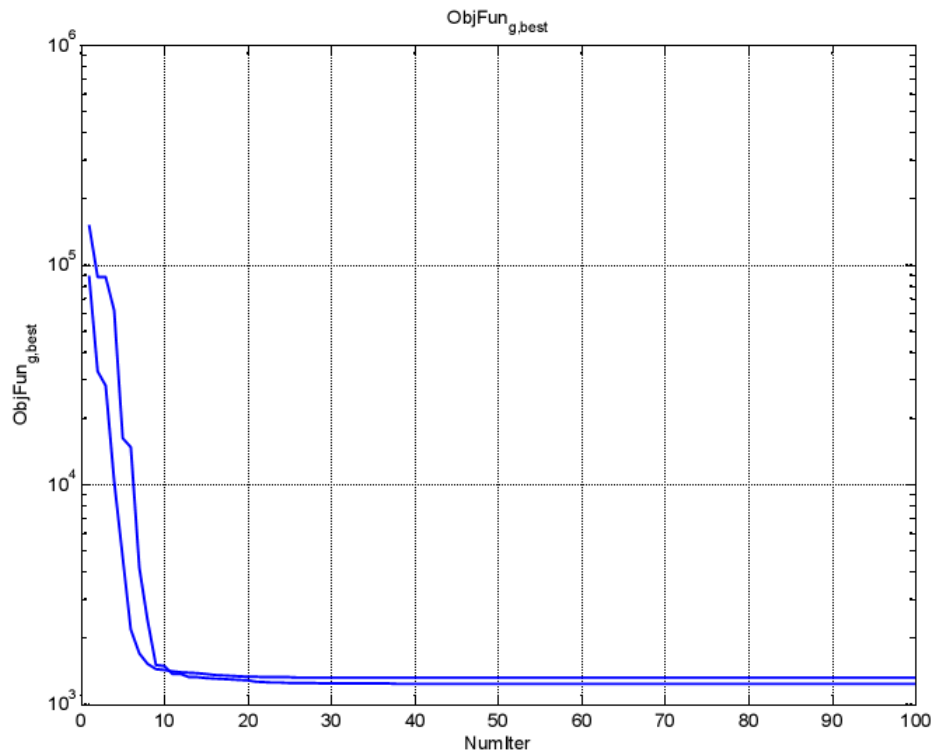
شکل (۹): ساختار مدل NF-GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه بوندویل و پری: سه واحد تأخیر زمانی)



شکل (۱۰): عملکرد مدل NF-GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه بوندویل: سه واحد تأخیر زمانی)

جدول (۹): ضرایب مدل NF-GMDH مدل توسعه داده شده بر اساس سه واحد تأخیر زمانی: چاه بوندویل

نورون	W1	A1	B1	W2	A2	B2
1,1	68.322	14.575	12.234	54.905	6.925	4.730
1,2	72.385	13.542	12.242	39.448	5.770	3.490
1,3	68.303	13.455	12.133	40.042	5.822	3.646
2,1	148.153	13.009	5.752	148.153	13.009	5.752
2,2	136.173	13.343	5.553	140.342	13.234	5.454
2,3	141.343	12.789	5.442	142.873	13.229	5.335
خروجی	140.775	12.443	5.543	140.335	13.556	5.657




شکل (۱۱): مقادیر تابع هدف خطای آموزشی نرون در مدل NF-GMDH

نتیجه‌گیری

در این مطالعه سطح آب زیرزمینی در چاه‌های بوندویل و پری ایالات ایلینوی آمریکا با استفاده از مدل‌های GMDH و NF-GMDH-PSO مدل‌سازی و پیش‌بینی شد. بدین منظور از اطلاعات روزانه بیست سال اخیر هر دو چاه استفاده شد. به منظور طراحی و تعیین الگوی متغیرهای ورودی از تأخیرهای زمانی (تا پنج واحد تأخیر زمانی) استفاده گردید. آموزش و توسعه مدل GMDH به کمک الگوریتم مربعات خطا و آموزش مدل NF-GMDH-PSO همان‌طور که از نام آن برمی‌آید به کمک الگوریتم ازدحام ذرات انجام شد. تابع فعال‌سازی در الگوریتم GMDH یک تابع چندجمله‌ای درجه و در مدل NF-GMDH-PSO یک تابع گوسی است. نتایج نشان داده که مدل GMDH با سه واحد تأخیر زمانی در متغیرهای ورودی با شاخص‌های آماری در مرحله صحت‌سنجی می‌تواند سطح آب زیرزمینی را چاه بوندویل و پری با دقتی در حدود $RMSE_B = 0.64m$ و $RMSE_P = 0.333m$ پیش‌بینی نماید. مدل NF-GMDH-PSO نیز با همین متغیرهای ورودی می‌تواند سطح آب زیرزمینی را با دقتی برابر با $RMSE_B = 0.684m$ و $RMSE_P = 0.528$ در مرحله صحت‌سنجی پیش‌بینی نماید. بررسی کلی دقت مدل‌سازی و تخمین سطح آب زیرزمینی در هر دو چاه این ایالت مناسب است. بررسی دقیق‌تر عملکرد مدل‌های توسعه داده نشان می‌دهد که برای مقادیر کمتر از یک متر سطح آب زیرزمین آن‌ها دارای خطای قابل توجه است حال آنکه با افزایش سطح آب زیرزمینی دقت مدل‌های توسعه داده شده به سرعت و به‌طور چشمگیری افزایش می‌یابد. تقریباً همه مدل‌های توسعه داده شده برای مقادیر کمتر از یک متر سطح آب زیرزمینی دارای خاصیت بیش پیش‌بینی فاحش هستند.

جدول (۱۰): مقادیر پارامترهای در الگوریتم بهینه‌ساز PSO

پارامتر	مقدار
ω	۰/۰۸۸۵
تعداد ذرات	۵۰
تعداد متغیرها	۶
خطا	۰/۰۰۰۰۱
C_1, C_2	۲
پارامترهای گوسی و ضرایب وزنی	۰-۱/۰۵



شکل (۱۲): عملکرد مدل NF-GMDH توسعه داده شده در مراحل آموزش و آزمایش (چاه پری: سه واحد تأخیر زمانی)

منابع

باقری، ی. عباس نوین پور، ا. ندیری، ع. نادری، ک. پیش‌بینی نوسانات سطح آب زیرزمینی در آبخوان باروق با استفاده از مدل SOM-AI، علوم زمین، ۲۸ (۲۰۱۷)



جبالبارزی، ب. ملکیان، آ. (۱۳۹۸) مقایسه کارایی روش‌های شبکه عصبی مصنوعی و برنامه ریزی بیان ژن برای پیش‌بینی سطح ایستابی در مناطق خشک و نیمه‌خشک (مطالعه موردی: دشت جیرفت)، تحقیقات مرتع و بیابان ایران، ۲۶-۲، ۲۹۲-۳۰۱

جنگ‌چی کاشانی، س. حکمت، م. (۱۳۹۶) مدیریت منابع آب در توسعه پایدار کشاورزی، مرکز نشر آکادمیک.
چوپان، ی. امامی، س. خیری قوجه بیگلر، م. (۱۳۹۹) ارزیابی الگوریتم‌های انتخابات، رقابت استعماری و روش شبکه عصبی مصنوعی در بررسی روند افت سطح ایستابی دشت رشتخوار، نشریه مهندسی عمران امیرکبیر، ۵۲(۶) ۱-۱.
دهقانی، ر. پورحقی، ا. ترابی، ح. (۱۳۹۵) پیش‌بینی نوسانات سطح آب زیرزمینی با استفاده از شبکه‌های بیزین (مطالعه موردی: دشت نورآباد-لرستان)، فضای جغرافیایی، ۱۶(۵۶) -
رجائی، ط. پوراصلان، ف. (۱۳۹۴) پیش‌بینی زمانی و مکانی سطح آب زیرزمینی دشت داورزن، هیدروژئومورفولوژی، ۲(۴) ۱-۱۹.

زارع ابیانه، ح. بیات ورکشی، م. معروفی، ص. ایلدرومی، ع. (۱۳۹۰) شبیه‌سازی سطح ایستابی دشت ملایر براساس داده‌های هواشناسی با استفاده از شبکه‌ی عصبی مصنوعی، پژوهش‌های جغرافیای طبیعی، ۴۳(۷۸) ۱۷-۲۸.
محتشم، م. دهقانی، ا. اکبرپور، ا. مفتاح هلقی، م. (۱۳۹۶) ارزیابی شبکه عصبی مصنوعی و مدل عددی MODFLOW در پیش‌بینی سطح ایستابی (مطالعه موردی: خراسان جنوبی - دشت بیرجند)، نشریه آبیاری و زهکشی ایران، ۱۱(۱) ۱-۱۰.
ملکزاده، م. کاردار، س. شعبانلو، س. (۱۴۰۰) شبیه‌سازی سطح آب زیرزمینی با استفاده از مدل ترکیبی موجک-ماشین آموزش نیرومند خودتطبیقی، تحقیقات آب و خاک ایران، ۵۱(۴) ۹۷۵-۹۸۶.
نخعی، م. صابری نصر، ا. (۱۳۹۱) پیش‌بینی نوسانات سطح آب زیرزمینی دشت قروه با استفاده از شبکه عصبی- موجکی و مقایسه آن با مدل عددی MODFLOW، زمین‌شناسی کاربردی پیشرفته، ۱(۴).
نوروزی قوشبلاغ، ح. ندیری، ع. (۱۳۹۶) پیش‌بینی سطح آب زیرزمینی دشت بوکان با استفاده از مدل‌های منطق فازی، جنگل تصادفی و شبکه‌ی عصبی، مرتع و آبخیزداری، ۷۱(۳) ۸۲۹-۸۴۵.

Emamgholizadeh, S. Moslemi, K. Karami, G. (2014) Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS), Water resources management, 28(15) 5433-5446

Khalili Naft Chali, A. Shahidi, A. khashei siuki, A. (2017) Comparison of Lazy Algorithms and M5 Model to Estimate Groundwater Level (Case Study: Plain Neyshabur), Journal of Water and Soil Science, 21(3) 15-26.

Kisi, O. Shiri, J. (2012) Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations, Hydrology Research, 43(3) 286-300.

Mohtashami, A., Monfared, S. A. H., Azizyan, G., & Akbarpour, A. (2022). Numerical simulation of groundwater in an unconfined aquifer with a novel hybrid model (case study: Birjand Aquifer, Iran). Journal of Hydroinformatics, 24(1), 160-178.

Najafzadeh, M. Mahmoudi-Rad, M. (2019) Estimation of the Maximum Scour Depth at Bridge Pier under Effects of Debris Accumulations using NF-GMDH Model and Evolutionary Algorithms, Environment and Water Engineering, 5(3) 213-225.

Sahoo, S. Jha, M.K. (2015) On the statistical forecasting of groundwater levels in unconfined aquifer systems, Environmental Earth Sciences, 73(7) 3119-3136

Seifi, A. Ehteram, M. Singh, V.P. Mosavi, A. (2020) Modeling and uncertainty analysis of groundwater level using six evolutionary optimization algorithms hybridized with ANFIS, SVM, and ANN, Sustainability, 12(10) 4023

Shiri, J. Kişi, Ö. (2011) Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations, Computers & Geosciences, 37(10) 16