



Influence of Teleconnection Patterns on Prediction of Groundwater Level Fluctuations (Case Study: Garmsar Plain)

Z. Azizi¹, M.R. Yazdani^{2*}, and M.K. Kianian³

Abstract

External source of weather signals is also called teleconnections that can change weather conditions and thus affect groundwater resources. The purpose of this study is to predict the effect of teleconnection patterns on groundwater level fluctuations in Garmsar plain. Data of observation wells, climatic parameters of the study area, as well as 16 teleconnection indices from 1993 to 2016 were used for this study. Gamma test was used to analyze inputs sensitivity and so determine the optimal combination of inputs. Modeling was performed with multiple regression as well as multilayer perceptron artificial neural network (MLP) with two algorithms of Levenberg-Marquardt and Bayesian. Sensitivity analysis results of model inputs with gamma test showed that among the climate parameters of the region, maximum temperature of Firoozkoo station and also teleconnection indices of SOI, EA, NP and WP had the most influence among the selected inputs. Also, the best model is the neural network method with Bayesian learning algorithm, that in the model testing stage in Sardareh well, the MSE and the R² were 0.37 and 0.9 respectively. In well 26, these values were 0.06 and 0.74, respectively. Also, results indicated that the use of teleconnections indices to predict groundwater level fluctuations can have effective role in error rate reduction.

Keywords: Teleconnection Indices, Groundwater, Artificial Neural Network, Gamma Test, Sensitivity Analysis.

Received: December 17, 2019

Accepted: July 14, 2020

تأثیر الگوهای پیوند از دور بر پیش‌بینی نوسانات تراز آب زیرزمینی (مطالعه موردی: دشت گرمسار)

زهرا عزیزی^۱، محمدرضا یزدانی^{۲*} و محمدکیا کیانیان^۳

چکیده

سیگنال‌های آب و هوایی با منشأ خارجی به نام پیوند از دور نیز می‌توانند موجب تغییرات شرایط آب و هوایی شوند و از این طریق بر روی منابع آب زیرزمینی تأثیر بگذارند. هدف از انجام پژوهش حاضر، پیش‌بینی تأثیر الگوهای پیوند از دور بر نوسانات سطح آب زیرزمینی دشت گرمسار می‌باشد. برای انجام این تحقیق از آمار چاه‌های مشاهداتی، پارامترهای آب و هواشناسی منطقه و همچنین ۱۶ شاخص پیوند از دور طی یک دوره‌ی آماری ۱۳۷۲ تا ۱۳۹۵ استفاده گردید. برای آنالیز حساسیت و تعیین ترکیب بهینه ورودی‌ها برای مدل‌سازی از آزمون گاما استفاده گردید. مدل‌سازی با رگرسیون چندگانه و همچنین شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) با دو الگوریتم لونیگ-مارکوآرت و تنظیم بیزین انجام گرفت. نتایج آنالیز حساسیت ورودی‌های مدل با آزمون گاما نشان داد، که از بین پارامترهای آب و هوایی منطقه، پارامتر دمای حداکثر ایستگاه فیروزکوه و شاخص‌های پیوند از دور SOI، EA، NP و WP بیشترین تأثیر را در بین ورودی‌های منتخب داشته‌اند. همچنین بهترین مدل، روش شبکه عصبی با الگوریتم یادگیری تنظیم بیزین می‌باشد، که در مرحله آزمون مدل در چاه سردره، مقدار خطایی برابر ۰/۳۷ و ضریب تبیین ۰/۹ و در چاه شماره ۲۶، این مقدار به ترتیب برابر ۰/۰۶ و ۰/۷۴ می‌باشد. همچنین نتایج بدست آمده نشان داد، که استفاده از شاخص‌های دور پیوندی برای پیش‌بینی نوسانات سطح آب زیرزمینی می‌تواند تأثیر قابل ملاحظه‌ای در کاهش میزان خطا داشته باشد.

کلمات کلیدی: شاخص‌های پیوند از دور، آب‌های زیرزمینی، شبکه عصبی مصنوعی، آزمون گاما، آنالیز حساسیت.

تاریخ دریافت مقاله: ۹۸/۹/۲۶

تاریخ پذیرش مقاله: ۹۹/۴/۲۴

1- M.Sc. Graduate of Water Engineering, Agriculture Meteorology, Faculty of Desert Studies, Semnan University, Semnan, Iran.

2- Associate Professor, Faculty of Desert Studies, Semnan University, Semnan, Iran. Email: m_yazdani@semnan.ac.ir

3- Assistant Professor, Faculty of Desert Studies, Semnan University, Semnan, Iran.

*- Corresponding Author

۱- دانش آموخته کارشناسی ارشد، گروه بیابانزادایی-مهندسی آب، هواشناسی کشاورزی، دانشکده کویرشناسی، دانشگاه سمنان، سمنان، ایران.

۲- دانشیار، گروه بیابانزادایی، دانشکده کویرشناسی، دانشگاه سمنان، سمنان، ایران.

۳- استادیار، گروه بیابانزادایی، دانشکده کویرشناسی، دانشگاه سمنان، سمنان، ایران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان پائیز ۱۳۹۹ امکانپذیر است.

۱- مقدمه

آب‌های زیرزمینی به عنوان مهمترین منبع در دسترس جهت تأمین آب موردنیاز در بخش‌های مختلف خصوصاً در مناطق خشک و نیمه‌خشک می‌باشد. در حال حاضر، کمبود آب و از طرف دیگر افزایش روزافزون مصرف آب در بسیاری از مناطق کشور به دلیل افزایش جمعیت، توسعه صنایع و کشاورزی، به همراه اثرات تغییر اقلیم (Yazdani, 2016) موجب تنزل کمی و کیفی آب‌های زیرزمینی شده است. از جمله عوامل مهم که کمتر مورد بررسی قرار گرفته و می‌تواند در پیش‌بینی نوسان‌های آب زیرزمینی مؤثر باشد، عوامل آب و هوایی با منشأ بیرونی است، که با نام پیوند از دور شناخته می‌شوند (Santo et al., 2014). در بخش‌های خاصی از اقلیم جهانی، فرآیندهای خاصی در تعامل بین هواکره و آب‌کره و سنگ‌کره شکل می‌گیرد، که ویژگی تغییرناپذیر و تکرارناپذیری دارند و چون از نظم خاصی تبعیت می‌کنند، از آن‌ها به عنوان الگو یاد می‌شود. هیچ منطقه‌ای از نظر اقلیمی مستقل نیست، بلکه الگوی اقلیمی غالب در یک منطقه، منطقه دیگر را نیز تحت تأثیر خود قرار می‌دهد. این‌گونه تأثیرگذاری به «پیوند از دور» معروف است. بسیاری از این الگوها ماهیت سیاره‌ای دارند و سراسر اقیانوس‌ها و قاره‌ها را در برمی‌گیرند و بسیاری نیز در ارتباط با همدیگر عمل می‌کنند (Asakereh, 2007). پیوند از دور به بیان ساده، ارتباط عناصر و پدیده‌های اقلیمی مانند دما، فشار سطح دریا و غیره در مناطق دور از هم در سطح کره زمین و در بازه‌های زمانی مشخص می‌باشد (Alijani, 2002). این الگوها، تلفیقی از الگوهای فشار اتمسفری و دمای آب اقیانوس‌ها و دریاها هستند و قلمرو آن‌ها متفاوت است. تأثیر بعضی از آن‌ها سیاره‌ای است، مانند النینو^۱ و النینو-نوسانات جنوبی^۲ و برخی دیگر مانند نوسانات اطلس شمالی^۳ بعد نیمکره‌ای دارند و بعضی مانند شاخص نوسانات مدیترانه^۴، قلمروی منطقه‌ای دارند (NOAA, 2012). الگوهای بزرگ‌مقیاس آب و هوایی مانند النینو-نوسان جنوبی، نوسان‌های فرکانس پایین را نشان می‌دهد. اگر تغییرات آن‌ها مرتبط با تغییرات سفره‌های آب زیرزمینی در یک منطقه مشخص باشد، این نوسان‌ها اطلاعات مفیدی را برای پیش‌بینی نوسان‌های سطح آب زیرزمینی در طول زمان فراهم می‌کنند (Tremblay et al., 2011). علی‌رغم اهمیت آب‌های زیرزمینی و اینکه اقلیم حاکم بر ایران در بیشتر نقاط خشک و نیمه‌خشک است و مسئله آب با بحران جدی روبه‌رو است، مطالعات نسبتاً کمی در ارتباط بین سیستم‌های آب زیرزمینی و گردش جوی بزرگ‌مقیاس مورد بررسی قرار گرفته است. دشت گرمسار در استان سمنان به دلیل وجود آب‌رفت مناسب نقش مهمی در توسعه بخش‌های مختلف خصوصاً کشاورزی و صنعت داشته است، که به دلیل شرایط ذکر شده با چالش کمبود منابع آب مواجه شده است. با

توجه به موارد ذکر شده، لازم است در یک تحقیق مناسب نسبت به بررسی تأثیر این شاخص‌های پیوند از دور بر نوسانات آب زیرزمینی در منطقه اقدام گردد و در صورت تأثیر این شاخص‌ها، در امر پیش‌بینی مورد استفاده قرار گیرند، تا مدیریت بهتری در بخش منابع آب منطقه حاصل گردد.

تحقیقات زیادی بر روی رابطه بین شاخص‌های پیوند از دور با مولفه‌های چرخه آب در دنیا صورت گرفته است، که تمرکز عمده آنها بر روی رابطه شاخص‌ها با بارش (Yar Ahmadi and Azizi, 2007; Kakapour, 2011; Hejazi Zadeh et al., 2013; Allen, 2017) و دما (Alizadeh et al., 2011; Rampelotto et al., 2012) بوده است. تحقیقات صورت گرفته بر روی نوسانات آب‌های زیرزمینی محدودتر بوده، که عمدتاً یک یا دو شاخص پیوند از دور را مورد بررسی قرار داده‌اند. (Memar et al. (2013) در پژوهشی با استفاده از شبکه‌های عصبی مصنوعی پس‌انتشار با الگوریتم آموزشی لونبرگ-مارکوارت، توانستند تراز آب زیرزمینی آبخوان دشت سمنان را با دقت مناسب در بازه زمانی ۴۵ ماهه (از دی ماه ۱۳۸۶ تا مهرماه ۱۳۹۰) پیش‌بینی نمایند. (Bazrafshan and Gorgani (2017). تأثیر شاخص‌های سیگنال النینو-نوسانات جنوبی را بر تغییرات تراز آب‌های زیرزمینی در طی دوره‌ی آماری ۲۰۱۰-۱۹۸۴ در استان هرمزگان بررسی کردند، نتایج نشان داد، که شاخص چند متغیره النینو-نوسانات جنوبی^۵، به عنوان مؤثرترین شاخص می‌باشد. (Dong et al. (2014). تغییرات فصلی و سالانه سطح آب زیرزمینی در دشت کوماتو در ژاپن را مورد بررسی قرار داده و ارتباط احتمالی آن‌ها را با شاخص‌های اقلیمی و ال‌نینو و لائینا مورد تحلیل قرار دادند. بررسی نتایج نشان داد، که سطح آب در آبخوان همبستگی منفی زیادی با دمای هوا و همبستگی مثبت با بارندگی و نوسانات سطح دمای دریا دارد. سری‌های زمانی هیدرولوژیکی بارش و آب زیرزمینی طی سال‌های ۱۹۶۰ تا ۲۰۰۸ در شمال چین برای تحلیل روند و تحلیل طیفی مورد تجزیه و تحلیل قرار گرفتند و نتایج نشان داد، نوسان‌های کوتاه‌مدت در فرکانس ۲-۷ سال، همبستگی قوی با شاخص ال‌نینو-نوسانات جنوبی دارد (Guoliangcao and Zheng, 2015). مطالعه‌ای تأثیر الگوهای پیوند از دور و تغییرات بین دهه‌ای بر سطح آب زیرزمینی و بارندگی و دما را در کانادا مورد بررسی قرار داد و نتایج نشان داد، که بارش محرک اصلی تغییرات سطح آب زیرزمینی بوده و تغییرات سطح آب زیرزمینی عمدتاً تحت تأثیر نوسانات اطلس شمالی و نوسانات قطبی^۶ قرار دارد و این‌که کاهش دما باعث افزایش سطح آب زیرزمینی می‌شود (Tremblay et al., 2011). (Upmanulall and Russo (2017). تغییرات اخیر در آب‌های زیرزمینی در ایالات متحده آمریکا و ارتباط آن‌ها با شاخص‌های تغییرات اقلیمی و بارش سالانه را بررسی کردند،

دارد و همچون دیگر بخش‌های جنوبی استان سمنان، در تابستان، هوای بیابانی و گرم و خشک و در زمستان، هوای سرد دارد. میانگین درجه حرارت سالانه، ۱۷/۸ درجه سانتی‌گراد و متوسط بارش سالانه آن ۱۱۹/۵ میلی‌متر می‌باشد. متوسط تبخیر سالانه بالغ بر ۲۵۳۹ میلی‌متر در سال و متوسط رطوبت نسبی، ۴۵/۷ درصد است.

۲-۲- داده‌های مورد استفاده

با بررسی‌های انجام شده، آمار دما، بارندگی، تبخیر و دبی در مقیاس ماهانه طی سال‌های ۱۳۷۲ تا ۱۳۹۵ از سازمان آب منطقه‌ای و همچنین سازمان هواشناسی اخذ گردید. پیش‌پردازش و کنترل همگنی داده‌ها انجام شد. با بررسی چاه‌های مشاهداتی در منطقه و با توجه به هدف از انجام این تحقیق، دو چاه سردره و شماره ۲۶ انتخاب گردید. در شکل ۱، موقعیت ایستگاه‌های مورد مطالعه و در جدول ۱، مشخصات آنها آورده شده است.

به منظور ارزیابی تأثیر استفاده از شاخص‌ها و الگوهای پیوند از دور بر نوسانات سطح آب زیرزمینی منطقه، از شانزده شاخص پیوند از دور شامل شاخص نوسانات اقیانوس اطلس شمالی، شاخص شمال اقیانوس آرام^۱، شاخص نوسانات شمالی^۲، شاخص غرب اقیانوس آرام^۳، شاخص تغییرات دهه‌ای اقیانوس آرام^۴، الگوی شمال اقیانوس آرام^۱، الگوی

که نتایج نشان می‌دهد، تغییرات سطح آب زیرزمینی مربوط به تغییرات اقلیمی موجود در جهان است. بررسی اثرات شاخص‌های پیوند از دور بر تغییرات سطح آب زیرزمینی در کشور کمتر صورت گرفته است و تحقیق حاضر می‌تواند اطلاعات مفیدی را در این بخش مهیا نماید. هدف از انجام این تحقیق بررسی اثرات شاخص‌های پیوند از دور بر نوسانات سطح آب زیرزمینی در محدوده دشت گرمسار سمنان می‌باشد. که بتواند موجب کاهش عدم قطعیت در پیش‌بینی نوسانات آب‌های زیرزمینی گردد و تقویت برنامه‌ریزی در جهت تأمین آب در منطقه شود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

شهرستان گرمسار در استان سمنان واقع است، که از شمال به شهرستان دماوند، از جنوب به شهرستان‌های اردستان و کاشان، از شرق به شهرستان سمنان و از غرب به شهرستان‌های ورامین و قم محدود می‌شود. دشت گرمسار با مساحتی بالغ بر ۳۷۵۷۰ هکتار مابین طول‌های ۵۲°۱۴' و ۵۲°۳۵' شرقی و عرض‌های ۳۵°۰۷' و ۳۵°۱۶' شمالی واقع شده است (شکل ۱). در شمال منطقه، کوه‌های البرز مرکزی مشاهده می‌شود، که رود حبله‌رود با حفر دره‌ای از آن‌ها خارج شده و مخروط افکنه گرمسار را شکل داده است. این دشت، بخشی از فلات مرکزی ایران است و آب و هوایی مشابه با سایر نقاط این فلات

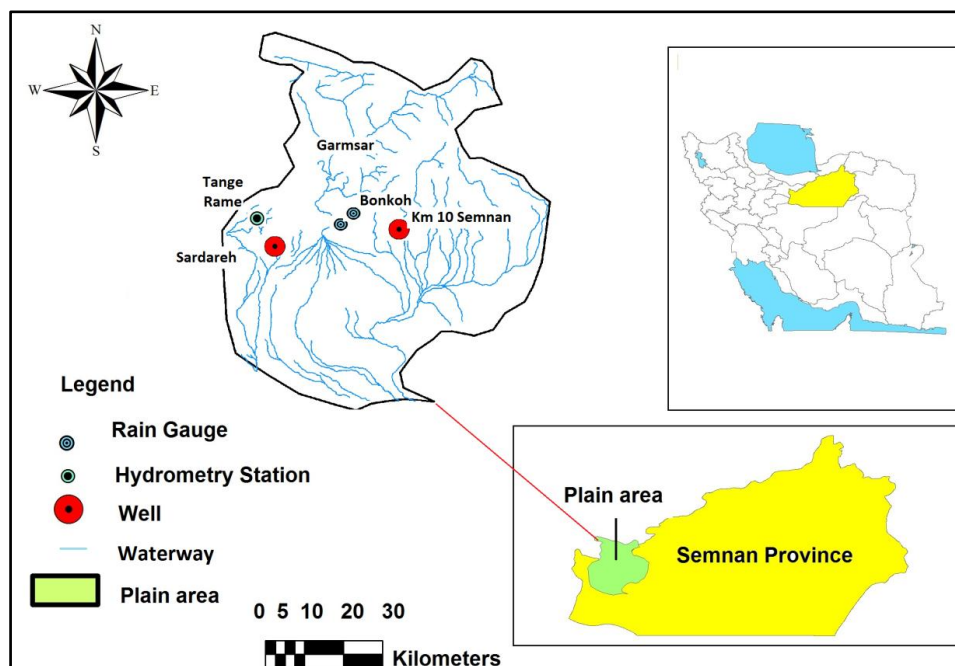


Fig. 1- Location of the study area and selected stations

شکل ۱- موقعیت محدوده مورد مطالعه و ایستگاه‌های منتخب

شرقی-غربی اقیانوس اطلس روسیه^{۱۲}، الگوی حاره‌ای جنوب اقیانوس اطلس^{۱۳}، الگوی قطبی اوراسیا^{۱۴}، شاخص انتقالی نینو^{۱۵}، شاخص چند متغیره النینو- نوسانات جنوبی، الگوی اطلس شرقی^{۱۶}، الگوی حاره‌ای شمال اقیانوس اطلس^{۱۷}، الگوی نوسانات اطلس شمالی جونز^{۱۸}، نوسانات دهه‌ای اقیانوس آرام^{۱۹}، شاخص دوقطبی اقیانوس اطلس^{۲۰} (جدول ۲) استفاده گردید (Yazdani and Zolfaghari, 2016). این داده‌ها از بخش علوم فیزیکی بخش مدیریت اقیانوسی و اتمسفری آمریکا اخذ شده است. این داده‌ها مطابق با سری زمانی داده‌های هواشناسی و هیدرومتری بررسی و استفاده شده است.

که در آن f ، تابع هموار کننده و x متغیر تصادفی است، که بیانگر نوفه می‌باشد. آماره گاما، C ، بیانگر تخمین واریانس خروجی مدل می‌باشد. آماره گاما بر اساس $N[i, K]$ که K امین $(1 \leq k \leq p)$ نزدیکترین همسایه $(1 \leq k \leq p)$ ، $x_n[i, k]$ برای هر بردار $(1 \leq i \leq M)$ می‌باشد (p) تعداد نقاط همسایه، K تعداد همسایگی مطابق با آماره گاما با بعد N و I طول بردار ورودی). بنابراین، می‌توان آماره گاما را بر اساس تابع δ از بردارهای ورودی بدست آورد:

$$\delta_M(k) = \frac{1}{M} \sum_{i=1}^M |x_{N(i,k)} - x_i|^2, \quad (1 \leq K \leq p) \quad (2)$$

در رابطه فوق $|\dots|$ بیانگر فاصله اقلیدسی است و تابع گامای مطابق با مقادیر خروجی عبارتست از:

$$\gamma_M(k) = \frac{1}{2M} \sum_{i=1}^M |y_{N(i,k)} - y_i|^2, \quad (1 \leq K \leq p) \quad (3)$$

که در آن $y_{N(i,k)}$ مقادیر y برای k امین نزدیک‌ترین همسایه برای x_i در معادله (۲) می‌باشد. برای محاسبه C ، خط رگرسیون حداقل مربعات برای نقاط P ، $\gamma_M(k)$ ، $\delta_m(k)$ ایجاد کرد:

$$\gamma = A\delta + \tau \quad (4)$$

۳-۲- آنالیز حساسیت و تعیین ترکیب بهینه ورودی‌ها با آزمون گاما^{۲۱}

آزمون گاما، یک روش غیرمتغیری است و نتایج آن صرف‌نظر از روش‌های خاص برای مدل‌سازی به کار برده می‌شود. با این آزمون، مقدار میانگین مربعات خطای مدل پیش از استفاده محاسبه و ترکیب بهینه متغیرهای ورودی شناسایی می‌شود. بنابراین، آزمون گاما را می‌توان به عنوان ابزاری مناسب برای یافتن بهترین ترکیب از متغیرهای ورودی به مدل غیرخطی در نظر گرفت (Sharifi et al., 2013). اگر مجموعه‌ای از داده‌های مشاهداتی را به شکل

$\{(x_i, y_i, 1 \leq i \leq M)\}$ داشته باشیم و بردارهای ورودی $x_i \in R^m$ بردارهایی با ابعاد m باشند (و با طول M) و مطابق آن خروجی‌ها

Table 1- Characteristics of selected observation stations and wells

جدول ۱- مشخصات ایستگاه‌ها و چاه‌های مشاهداتی منتخب

No.	Station name	Latitude	Longitude	Elevation	Description
1	Sardarreh	35.24	36.52	845/75	Observation well
2	road km 26 Semnan	35.26	52.64	826.59	Observation well
3	Garmsar	35.12	52.16	825	Synoptic
4	Dehnamak	35.15	52.43	800	Evaporation gage
5	Bonkouh	35.18	52.25	1040	Hydrometry
6	Tange rameh	35.20	52.43	2050	Hydrometry
7	Firuzkouh	35.91	52.83	1975	Synoptic

Table 2- The studied teleconnection indices

جدول ۲- شاخص‌های پیوند از دور مورد مطالعه

Index	Sign	Index	Sign
North Atlantic Index	(NAO)	Eurasian Polar Pattern	(POL) یا (P/E)
North Pacific Index	(PNA)	Transitional Nino Index	(TNI)
North Oscillation Index	(NOI)	ENSO Multivariate Index	(MEI)
Western Pacific Index	(WP)	Eastern Atlas Pattern	(EA)
Decadal fluctuations of Pacific ocean	(PDO)	Tropical pattern of the North Atlantic	(TNA)
North Pacific pattern	(NP)	Pattern of North Atlantic Fluctuations	(NAO Jones)
East/West Atlantic pattern of Russian	(EA/WR)	Decadal fluctuations of Pacific ocean	(AMO)
Tropical pattern of the South Atlantic	(TSA)	Atlantic dipole index	(TAD)

در رابطه فوق γ ، متغیر وابسته، δ ، متغیر مستقل، τ ، عرض از مبدا خط رگرسیون و A ، شیب خط رگرسیون می باشد. عرض از مبدا خط رگرسیون فوق برابر مقدار آزمون گاما و شیب بیشتر آن بیانگر پیچیدگی بیشتر مدل می باشد. همچنین مقدار خطای آن هر چه به عدد صفر نزدیک تر باشد، با اطمینان استاندارد بیشتری می توان مقدار گاما را نشان دهنده ی اختلال موجود در داده ها دانست. می توان استاندارد بودن نتایج را با شاخص V به صورت زیر بیان کرد که در آن $\sigma^2(y)$ ، واریانس خروجی y است (Moghaddamnia et al., 2009):

$$V = \frac{\tau}{\sigma^2(y)} \quad (5)$$

در آزمون گاما هر ورودی به ترتیب حذف می گردد، تا اثر آن در ترکیب مشخص شود. ورودی که آماره گامای آن نسبت به گامای کل ترکیب بیشتر شود، ورودی موثر شناخته می گردد. از طرفی هر چقدر شاخص V بزرگتر باشد، بیانگر این است، که تاثیر آن پارامتر بر مدل مؤثرتر بوده و استفاده از آن در مدل باعث ساختار مناسب تری می شود. مقادیر آزمون گاما برای سه سناریوی مختلف از ترکیبات ممکن ورودی ها تعیین گردید. سناریوی اول شامل شاخص های پیوند از دور، سناریوی دوم شامل پارامترهای اقلیمی و سناریوی سوم ترکیبی از سناریوی اول و دوم می باشد.

۲-۴- مدل سازی پیش بینی نوسانات سطح آب زیرزمینی

برای مدل سازی نوسانات سطح آب زیرزمینی در منطقه مورد مطالعه، داده های ورودی های منتخب پس از آزمون گاما به سه بخش آموزش یا کالیبراسیون، آزمایش و آزمون یا صحت سنجی تفکیک گردیدند. با توجه به طول دوره آماری موجود، ۶۰ درصد داده ها برای آموزش و ۲۰ درصد داده ها برای آزمایش و ۲۰ درصد برای بررسی کارایی مدل (آزمون) اختصاص داده شدند. مدل سازی در سه سناریو با سه مدل رگرسیون چندگانه^{۲۲} و شبکه عصبی مصنوعی پرسپترون چندلایه^{۲۳} با دو الگوریتم آموزشی انجام گرفت.

رگرسیون چندگانه: رگرسیون چندگانه در واقع توسعه یافته از رگرسیون خطی ساده است، که برای پیش بینی متغیرهای مد نظر با استفاده از متغیرهای مستقل به کار می رود. در تحقیق حاضر از روش ورود همزمان^{۲۴} (که تمام متغیرها به عنوان ورودی در معادله شرکت می کنند) برای ارائه مدل مناسب رگرسیون چند متغیره استفاده شد.

شبکه عصبی مصنوعی: برای انجام این تحقیق از روش شبکه عصبی مصنوعی پرسپترون چندلایه مبتنی بر دو ساختار آموزشی با الگوریتم لوبنرگ-مارکوارت^{۲۵} و تنظیم بیزین^{۲۶} استفاده شده است.

الگوریتم لوبنرگ-مارکوارت (LM): این روش تغییر یافته الگوریتم کلاسیک نیوتن است، که به علت سرعت بالای آن برای پیدا کردن راه حلی مناسب برای مسائلی که نیاز به کمینه سازی دارند، به کار می رود و نتایج آن عموماً بسیار نزدیک به مینیمم خطا می باشد و به دلیل ساختارهایی که در این الگو استفاده می شود، نتایج قابل قبول تری ارائه کردند. این روش یک تقریب برای ماتریس هیزن در تغییر وزن ها مانند روش نیوتن در نظر می گیرد:

$$x_{k-1} = x_k - [J^T + \mu I]^{-1} J^T + e \quad (6)$$

در رابطه فوق، X ، وزن های شبکه عصبی، K ، تعداد تکرار، T ، نشانگر ماتریس، L ، ترانهاده ژاکوبین در x_k می باشد، μ ، عددی است که فرآیند آموزش را کنترل می کند و e ، بردار خطای باقیمانده است (Pradhan et al., 2019).

الگوریتم تنظیم بیزین (BN): تنظیم بیزین الگوریتمی است، که به طور اتوماتیک مقادیری مناسب برای پارامترهای تابع قرار می دهد. در این روش، وزن ها و بایاس های شبکه، متغیرهایی تصادفی با توزیع هایی ویژه فرض می شوند. مزیت این الگوریتم در این است، که اندازه شبکه بر روی نتایج آن تأثیر کمی خواهد داشت. ساختار یک شبکه بیزین در واقع یک نمایش نموداری از اثرات متقابل متغیرهایی است، که باید الگوبندی شوند و علاوه بر اینکه کیفیت رابطه بین متغیرهای مسأله را نشان می دهد. روش تنظیم بیزین می تواند جهت بهبود توانایی شبکه عصبی و آموزش تابع که بصورت زیر نشان داده شده است، استفاده شود. E_W ، مجموع مربعات وزن های شبکه و E_D ، مجموع مربعات باقیمانده بین پاسخ شبکه و تابع هدف می باشد. α و β ، متغیرهای تنظیم تابع هدف می باشند. نکته اساسی روش تنظیم این است، که متغیرهای تابع هدف را چگونه از طریق داده های آماری بیزین انتخاب و بهینه نماید (Guzman et al., 2019):

$$F = \alpha E_W + \beta E_D \quad (7)$$

اگر α و β به عنوان متغیرهای تصادفی در نظر گرفته شوند، رابطه بیزین به صورت زیر در خواهد آمد:

$$P(\alpha, \beta | D, M) = \frac{P(D | \alpha, \beta, M) P(\alpha, \beta | M)}{P(D | M)} \quad (8)$$

که در آن D ، بیانگر داده های آموزش، M ، مدل شبکه و W ، نیز وزن شبکه می باشد. با توجه به قانون بیزین، اگر α و β از توزیع یکنواخت تبعیت کنند، در این صورت احتمال زمانی $P(D | \alpha, \beta, M)$ بیشترین مقدار خواهد شد و احتمال توزیع اولیه α و β در معادله نیز به بالاترین مقدار خود خواهد رسید. مقادیر α و β تغییر خواهند کرد، تا مقادیر بهینه توزیع اولیه به دست آید و مقدار F (رابطه ۴) نیز به روز می گردد. در نهایت آموزش شبکه آنقدر تکرار خواهد شد، تا به همگرایی مطلوب برسد.

۲-۵- معیار ارزیابی خطا و کارایی مدل: در این تحقیق دو معیار به منظور کارایی و خطای هر شبکه و توانایی آن برای پیشگویی دقیق و برای تعیین بهترین ساختار مدل و مقایسه آن در جهت انتخاب بهترین روش و ساختار استفاده شد، که شامل ریشه متوسط مربع خطا^{۲۷} و ضریب تبیین^{۲۸} می باشد.

۳- نتایج و بحث

۳-۱- تعیین ترکیب بهینه متغیرها با استفاده از آزمون گاما

تعیین ترکیب بهینه ورودی‌ها برای مدل‌سازی با استفاده از روش آزمون گاما انجام شد. در این روش، هر چه مقدار گامای متغیر ورودی بیشتر باشد، آن متغیر سهم بیشتری در توضیح متغیر وابسته خواهد داشت. در جدول ۳، نتایج آزمون گاما برای دو چاه ۲۶ و سردره در منطقه مورد

مطالعه آورده شده است. با توجه به نتایج به دست آمده برای چاه سردره آماره گاما برای کل ترکیب، ۰/۱۰۴ به دست آمده است. متغیرهای مؤثر در این روش متغیرهایی هستند، که با حذف آنها از ترکیب آماره گاما نسبت به گامای کل بیشتر می‌شود. از بین پارامترهای اقلیمی و هیدرومتری منتخب، پارامترهای دبی ماهانه ایستگاه‌های بنکوه و تنگ رامه و دمای حداکثر ایستگاه‌های فیروزکوه و ده نمک تأثیرگذار بوده‌اند و دمای حداکثر ایستگاه فیروزکوه با گامای ۰/۱۳۵ مؤثرترین ورودی می‌باشد. از بین شاخص‌های پیوند از دور مورد استفاده، شاخص‌های SOI، TNI، MEI، PNA، EA، WP و NP اثرگذار بوده و شاخص‌های SOI و EA با گامای ۰/۱۲۹ بیشترین تأثیر را داشته‌اند. حداقل دمای فیروزکوه با گامای ۰/۰۳۳، کمترین تأثیر را در بین پارامترهای اقلیمی و شاخص دور پیوندی EA/WR با گامای ۰/۰۶۸، کمترین تأثیر را از بین شاخص‌های پیوند از دور داشته است.

Table 3- Results of the Gamma test for determination of effective input compounds for Sardarreh and Kilometer 26 Wells

جدول ۳- نتایج آزمون گاما در تعیین ترکیب‌های ورودی مؤثر برای چاه سردره و چاه کیلومتر ۲۶

Combination number	omitted variable of the Combination	Gamma amount	
		Sardarreh well	Well No. 26
1	-	0.104	0.0386
2	baransanjibonekoh	0.07	0.0297
3	baransanjigarmsar	0.095	0.033
4	hydrometribonekoh	0.14	0.0329
5	hydrometritangerameh	0.124	0.0431
6	TMAXfir	0.135	0.0464
7	TMinfir	0.033	0.0392
8	Tmeandehnamak	0.0684	0.0167
9	Tmaxdehnamak	0.1184	0.0261
10	Tmindehnamak	0.076	0.0196
11	ETdehnamak	0.104	0.032
12	NAO	0.088	0.0248
13	PDO	0.096	0.0149
14	TNI	0.118	0.0294
15	NOI	0.099	0.0386
16	SOI	0.129	0.027
17	MEI	0.12	0.0437
18	EA/WR	0.0687	0.0167
19	NAO (Jones)	0.099	0.0386
20	POL	0.088	0.0248
21	TAD	0.096	0.0149
22	PNA	0.118	0.0294
23	EA	0.129	0.027
24	WP	0.12	0.0437
25	NP	0.1184	0.0261
26	AMO	0.076	0.0196
27	TNA	0.104	0.032

از دور، بیشترین نسبت V مربوط به شاخص‌های SOI و EA برابر $0/556$ می‌باشد.

۳-۲- مدل‌سازی نوسانات آب‌های زیرزمینی

برای مدل‌سازی نوسانات سطح آب زیرزمینی در چاه‌های مورد مطالعه از ۳ سناریو برای متغیرهای ورودی منتخب برگرفته از نتایج آزمون گاما در مدل استفاده شد. در سناریوی اول، پارامترهای ورودی مدل شامل پارامترهای اقلیمی و هیدرومتری، در سناریوی دوم، پارامترهای ورودی شامل شاخص‌های پیوند از دور و در سناریوی سوم یا ترکیبی، ورودی‌های مدل شامل پارامترهای اقلیمی، هیدرومتری و شاخص‌های پیوند از دور بودند. برای پیش‌بینی نوسانات سطح آب زیرزمینی از مدل رگرسیون خطی چندگانه و دو روش شبکه عصبی یکی با الگوریتم آموزشی لونیبرگ-مارکوات و دیگری الگوریتم آموزشی تنظیم بیزین استفاده گردید. برای آموزش شبکه عصبی برای دو الگوریتم استفاده شده، تعداد تکرار ۱۰۰۰۰ و حداکثر تعداد عناصر پردازشگر در لایه‌های مخفی ۱۲ عدد تعیین شد. تعداد بهینه لایه مخفی در هر ساختار با استفاده از روش سعی و خطا و از یک تا ۱۲ لایه مورد بررسی قرار گرفت و با توجه به معیار خطا، بهترین تعداد لایه‌های مخفی مشخص گردید.

برای چاه ۲۶، آماره گاما برای کل ترکیب برابر $0/386$ به دست آمده است و از بین پارامترهای اقلیمی و هیدرومتری منتخب، پارامترهای دبی ماهانه ایستگاه تنگ رامه، دمای حداکثر و دمای حداقل ایستگاه فیروزکوه تأثیرگذار بوده‌اند، بطوری که دمای حداکثر دمای ایستگاه فیروزکوه با گامای $0/464$ ، مؤثرترین پارامتر ترکیب می‌باشد. از بین شاخص‌های پیوند از دور، شاخص‌های MEI و WP اثرگذاری بیشتری داشته‌اند و گامای آنها برابر $0/437$ می‌باشد. متوسط دمای دهنمک با گامای $0/167$ کمترین تأثیر را در بین پارامترهای اقلیمی و شاخص‌های دور پیوندی PDO و TAD با گامای $0/149$ ، کمترین تأثیر را بین شاخص‌های پیوند از دور داشته است. در شکل‌های ۲ و ۳، مقادیر نسبت V برای ورودی‌های منتخب دو چاه مورد بررسی ارائه شده است. بر اساس نتایج بدست آمده، با استفاده از تمام متغیرها به عنوان ورودی، نسبت V برای چاه سردره برابر $0/417$ خواهد شد. در این ایستگاه، بیشترین میزان این نسبت مربوط به پارامتر دبی ماهانه ایستگاه بنکوه به میزان $0/563$ می‌باشد. شاخص‌های SOI و EA از بین شاخص‌های پیوند از دور مورد بررسی، دارای بیشترین میزان نسبت V برابر $0/518$ می‌باشند. در چاه ۲۶، نسبت کل V برابر با $0/444$ محاسبه شده است. در این ایستگاه نیز بیشترین مقدار V متعلق به دبی ماهانه ایستگاه بنکوه به میزان $0/598$ و سپس دبی ماهانه ایستگاه تنگ رامه به میزان $0/528$ می‌باشد. از بین شاخص‌های پیوند




Fig. 2- V ratio changes for selected entrances in well Sardarreh

شکل ۲- تغییرات نسبت V برای ورودی‌های منتخب در چاه سردره

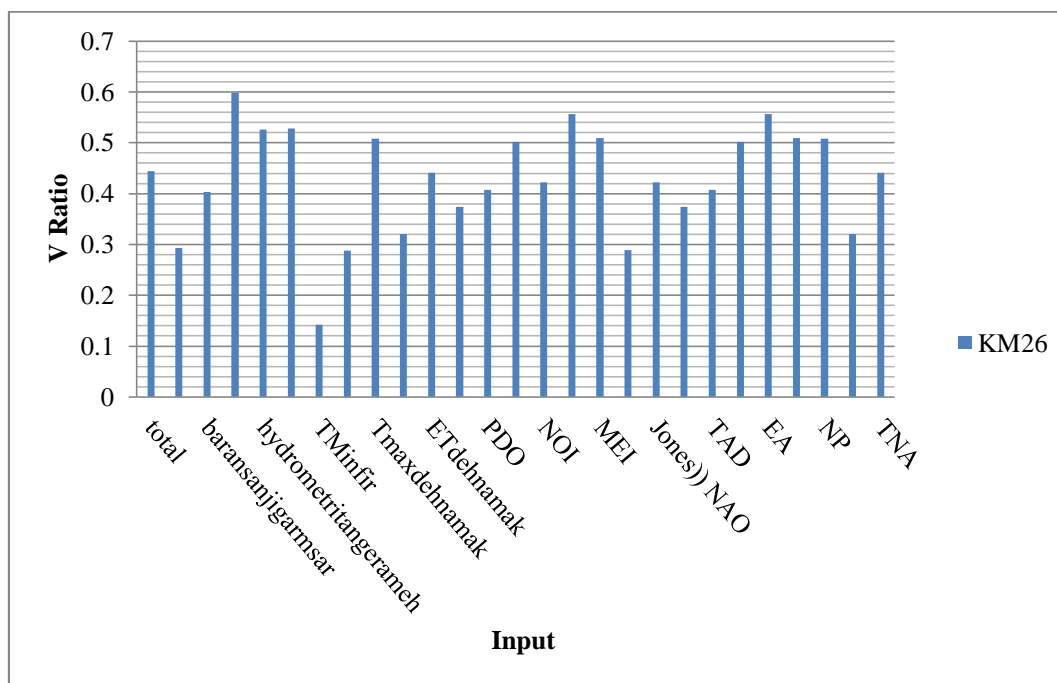


Fig. 3- V ratio changes for selected inputs in well 26

شکل ۳- تغییرات نسبت V برای ورودی‌های منتخب در چاه ۲۶

آزمون، $0/09$ با ضریب تبیین $0/76$ می‌باشد. با الگوریتم تنظیم بیزین، مقدار خطا $0/06$ با ضریب تبیین $0/74$ در مرحله آزمون بدست آمد، که بیانگر بهترین مدل در این سناریو می‌باشد.

در جدول ۵، مقدار خطا و ضریب تبیین مدل‌های منتخب برای پیش‌بینی نوسانات سطح آب زیرزمینی در چاه سردره آورده شده است. براساس نتایج به‌دست آمده در سناریوی اول و روش ورود همزمان رگرسیون چند متغیره، مقدار خطا در مرحله آزمون برابر $6/2$ و ضریب تبیین $0/7$ به‌دست آمد. استفاده از شبکه عصبی با الگوریتم لونیبرگ-مارکوات، میزان خطا را تا $3/13$ در مرحله آزمون کاهش داد، در حالی که در الگوریتم آموزشی تنظیم بیزین، میزان خطا برابر $2/1$ و ضریب تبیین، $0/55$ محاسبه گردید. در سناریوی دوم، نتایج مدل‌سازی با رگرسیون چندمتغیره، خطایی برابر $6/8$ در محله آزمون با روش ورود همزمان داده‌ها ایجاد کرد.

در شکل ۴، مقادیر تخمینی و مشاهداتی سطح آب زیرزمینی در چاه کیلومتر ۲۶ و چاه سردره با استفاده از رگرسیون چندگانه در دو مرحله آموزش و آزمون ارائه شده است. با استفاده از روش شبکه عصبی مصنوعی در دو الگوریتم لونیبرگ-مارکوات و تنظیم بیزین مقدار خطا برابر با $0/93$ و $0/82$ به ترتیب می‌باشد، که نسبت به سناریوی اول خطای کمتر و ضریب تبیین بیشتری دارد.

در جدول ۴، مقدار خطا و ضریب تبیین مدل‌ها در چاه ۲۶ آورده شده است. در سناریوی اول، رگرسیون چندگانه با روش ورود همزمان داده‌ها در دو مرحله و آموزش انجام گرفت. بر اساس نتایج به‌دست آمده، مقدار خطا در مرحله آزمون برابر $3/9$ و ضریب تبیین، $0/35$ به‌دست آمد. استفاده از شبکه عصبی با الگوریتم لونیبرگ-مارکوات، میزان خطا را تا $0/11$ در مرحله آزمون کاهش داد. در شبکه عصبی با الگوریتم آموزشی تنظیم بیزین میزان خطا برابر $0/1$ و ضریب تبیین $0/39$ در مرحله آزمون و میزان خطا در مرحله صحت‌سنجی $0/1$ محاسبه گردید. بنابراین، در سناریوی اول بهترین مدل محسوب می‌شود. در سناریوی دوم، که تنها از شاخص‌های پیوند از دور مؤثر در مدل استفاده گردید، استفاده از رگرسیون چندمتغیره با روش ورود همزمان متغیرها، خطایی (ریشه متوسط مربع خطا) برابر $3/5$ در مرحله آزمون تولید می‌کند. با استفاده از روش شبکه عصبی مصنوعی در دو الگوریتم لونیبرگ-مارکوات و تنظیم بیزین، مقدار خطا به ترتیب برابر با $0/14$ و $0/2$ می‌باشد، که نسبت به سناریوی اول خطای بیشتر و ضریب تبیین کمتری دارد. در این سناریو، الگوریتم لونیبرگ-مارکوات کمترین خطا را دارد. در سناریوی سوم، که کلیه پارامترهای مؤثر در مرحله مدل‌سازی استفاده شدند، در روش رگرسیون چندگانه مقدار خطا در مرحله آزمون به $4/2$ می‌رسد، که البته ضریب تبیین بیشتری ($0/53$) نسبت به دو سناریوی اول در این روش دارد. در روش شبکه عصبی با الگوریتم لونیبرگ-مارکوات، مقدار خطا (ریشه متوسط مربع خطا) برای دو مرحله آموزش و صحت‌سنجی برابر $0/04$ و $0/08$ بوده و در مرحله

ورودی داده‌ها مورد بررسی قرار گرفت. برای انتخاب پارامترهای ورودی مؤثر مدل از روش آزمون گاما استفاده گردید. بر اساس نتایج به‌دست آمده در چاه‌های منتخب، پارامترهای دمای حداکثر و دبی ایستگاه بنگوه، متغیرهای آب و هوایی مؤثری در مدل می‌باشند. همچنین مشخص شد برخی از شاخص‌های پیوند نیز مؤثر بوده‌اند، که از مهمترین آنها می‌توان به SOI، MEI، EA و WP اشاره نمود. بررسی مقادیر نسبت V در بین پارامترهای ورودی منتخب نیز حاکی از تأیید اثرگذاری مثبت این ورودی‌ها می‌باشد. باید در نظر داشت، که نسبت V با واریانس تابع هدف (رابطه ۵) نسبت معکوس دارد، هرچه واریانس تابع هدف بیشتر باشد، نسبت V کوچکتر است و مفهوم آن این است، که ورودی مد نظر در ترکیب تأثیر کمتری دارد. در واقع ورودی‌هایی مانند SOI باعث کاهش واریانس پیش‌بینی نوسانات سطح آب زیرزمینی در چاه سردره می‌شوند، در نتیجه نسبت V افزایش می‌یابد. از طرفی استفاده از شاخص دور پیوندی NAO در این چاه، واریانس پیش‌بینی افزایش و نسبت V کاهش می‌یابد و اثرگذاری آن در مدل کمرنگ خواهد بود.

در سناریوی سوم، استفاده از تمام متغیرهای مؤثر ورودی به مدل رگرسیون چندگانه، تغییری در کاهش میزان خطا در مرحله آزمون نداشته است، اما با الگوریتم لونبرگ-مارکوات، مقدار خطا (ریشه متوسط مربع خطا) در دو مرحله آموزش و صحت‌سنجی به ترتیب برابر با ۰/۲۹ و ۰/۶۶ و در مرحله آزمون برابر با ۱/۰۷ با ضریب تبیین ۰/۶۶ در بهترین حالت اجرای مدل به‌دست آمد. استفاده از الگوریتم آموزشی تنظیم بیزین، میزان خطا را کاهش داده است، بطوری‌که میزان خطا در مرحله آموزش و صحت‌سنجی به ۰/۱۱ و ۰/۶۳ رسیده است و در مرحله آزمون برابر ۰/۳۷ با ضریب تبیین ۰/۹ می‌باشد. بنابراین در سه سناریوی مورد بررسی در چاه سردره، مدل شبکه عصبی با الگوریتم آموزشی تنظیم بیزین کارایی بهتری نشان داده است (شکل‌های ۵ و ۶).

۴- نتیجه‌گیری

در این تحقیق پیش‌بینی نوسانات سطح آب زیرزمینی در دو چاه در محدوده‌ی جنوب شهر سمنان با استفاده از سه مدل و سه سناریوی

Table 4- Error rate and coefficient of determination of selected models from the top parameters in well 26

جدول ۴- میزان خطا و ضریب تعیین مدل‌های منتخب حاصل از پارامترهای برتر در چاه ۲۶

Input variables	model	method	stage	R ²	RMSE	
Climatic and hydrometric parameters	Multivariate regression	Enter	training	0.47	3.5	
			test	0.35	3.9	
	neural network	The Levenberg-Marquardt algorithm	training	0.74	0.042	
			validation	0.25	0.171	
			test	0.30	0.106	
			training	0.54	0.078	
			validation	0.47	0.082	
			test	0.39	0.095	
	teleconnection	Multivariate regression	Enter	training	0.5	3.8
				test	0.4	4.2
neural network		The Levenberg-Marquardt algorithm	training	0.97	0.014	
			validation	0.89	0.061	
			test	0.75	0.141	
			training	0.99	0.005	
			validation	0.56	0.079	
			test	0.69	0.201	
Hybrid	Multivariate regression	Enter	training	0.58	3.4	
			test	0.53	3.3	
	neural network	The Levenberg-Marquardt algorithm	training	0.80	0.038	
			validation	0.72	0.082	
			test	0.69	0.074	
			training	0.98	0.003	
			validation	0.88	0.06	
			test	0.69	0.059	

Table 5- Error rate and coefficient of determination of selected models from top parameters in well Sardarreh

جدول ۵- میزان خطا و ضریب تعیین مدل‌های منتخب حاصل از پارامترهای برتر در چاه سردره

Input variables	Model	Method	Stage	R ²	RMSE	
Climatic and hydrometric parameters	Multivariate regression	Enter	Training	0.84	6	
			test	0.7	6.2	
	neural network	The Levenberg-Marquardt algorithm	training	0.72	0.95	
			validation	0.33	2.51	
Bayesian regulation algorithm		test	0.21	3.132		
		training	0.77	0.661		
teleconnection	Multivariate regression	Enter	validation	0.75	1.238	
			test	0.55	2.1	
	neural network	The Levenberg-Marquardt algorithm	training	0.31	6.6	
			test	0.3	6.8	
		Bayesian regulation algorithm	training	0.90	0.429	
			validation	0.77	1.238	
	hybrid	Multivariate regression	Enter	test	0.79	0.929
				training	0.88	0.338
		neural network	The Levenberg-Marquardt algorithm	validation	0.74	0.779
				test	0.75	0.82
	neural network	Bayesian regulation algorithm	training	0.89	6	
			test	0.75	6.3	
The Levenberg-Marquardt algorithm		training	0.91	0.285		
		validation	0.77	0.633		
Bayesian regulation algorithm	test	0.66	1.072			
	training	0.96	0.105			
neural network	The Levenberg-Marquardt algorithm	validation	0.81	0.633		
		test	0.90	0.368		

گفت شاخص‌های پیوند از دور می‌توانند باعث کاهش خطای پیش‌بینی مدل شوند. در چاه سردره، استفاده از پارامترهای اقلیمی در بهترین مدل، خطایی برابر ۲/۱ دارد، اما استفاده از شاخص‌های پیوند از دور به تنهایی در مدل می‌تواند خطا را نسبت به سناریوی اول کاهش دهد. چنانچه به متغیرهای سناریوی اول شاخص‌های دور پیوندی اضافه شود، مقدار خطا به مقدار ۰/۳۷ کاهش و ضریب تبیین به ۰/۹ افزایش می‌یابد و میزان خطا نسبت به سناریوی اول بیشتر از ۴/۶ برابر کاهش می‌یابد. بنابراین، می‌توان گفت استفاده از شاخص‌های پیوند از دور برای پیش‌بینی نوسانات سطح آب زیرزمینی در منطقه مورد مطالعه می‌تواند میزان خطا را کاهش دهد و کارایی مدل را ارتقاء دهد. البته نتایج بدست آمده از تحقیقات دیگر در این زمینه بیانگر تأثیر این شاخص‌ها بر افزایش کارایی پیش‌بینی سطح آب زیرزمینی می‌باشد (Tremblay et al., 2011; Dong et al., 2014; Bazrafshan et al., 2017; Holman et al., 2018).

بنابراین با استفاده از آماره گاما و نسبت V می‌توان خطای پیش‌بینی مدل را مشخص و ترکیب بهینه را برای پیش‌بینی نوسانات سطح آب زیرزمینی تعیین نمود. با بررسی مدل‌های منتخب مشخص گردید، که مدل شبکه عصبی با توجه به توانایی آن در تبیین روابط غیرخطی از کارایی بهتری در پیش‌بینی نوسانات سطح آب زیرزمینی در چاه‌های منتخب برخوردار است. همچنین الگوریتم یادگیری تنظیم بیزین نسبت به الگوریتم یادگیری لوبنرگ-مارکوات در کلیه سناریوها (به جز سناریوی دوم در چاه ۲۶) از دقت بیشتر و خطای کمتری برخوردار بود. بررسی نتایج بدست آمده حاکی از این است، که در چاه ۲۶، استفاده از سناریوی دوم که تنها از شاخص‌های پیوند از دور به عنوان ورودی استفاده می‌کند، میزان خطا را نسبت به سناریوی اول در هر دو الگوریتم شبکه عصبی بیشتر می‌کند. این درحالی است، که اگر به سناریوی اول، شاخص‌های پیوند از دور اضافه گردد، میزان خطا با بهترین مدل از ۰/۱ به ۰/۰۶ کاهش و ضریب تبیین به ۰/۷۴ افزایش می‌یابد. در واقع، میزان خطا ۰/۴ کاهش می‌یابد. بنابراین، می‌توان

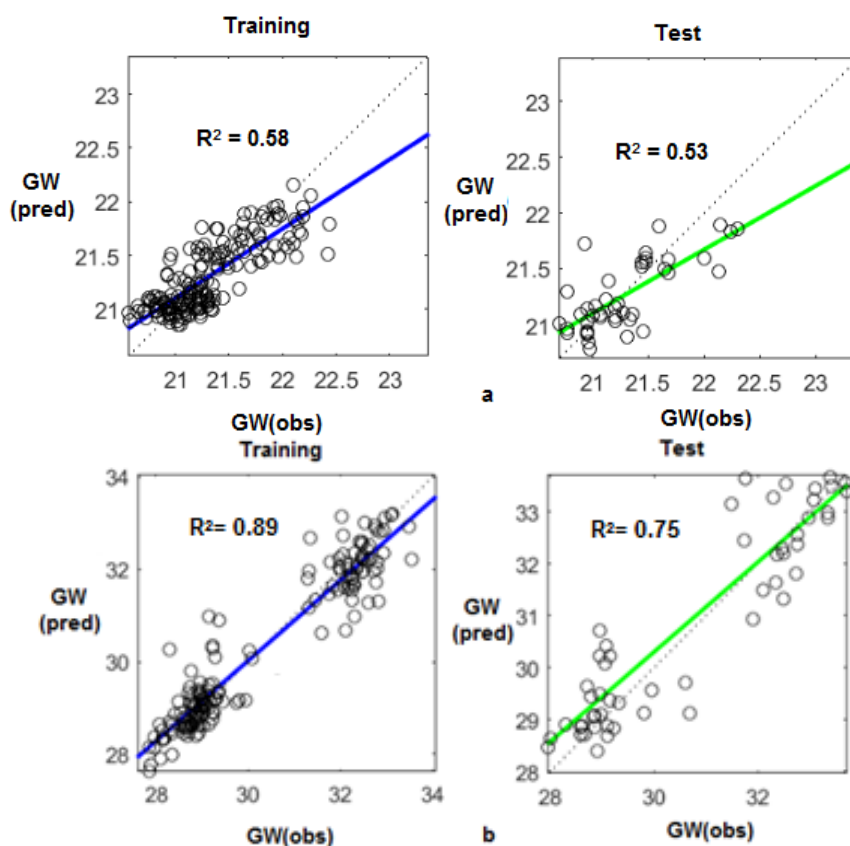


Fig. 4- Estimated and observed ground water level in 26 (a) and Sardareh Well (b) using multiple regression in the training and test stages

شکل ۴- مقادیر تخمینی و مشاهداتی سطح آب زیرزمینی در چاه کیلومتر ۲۶ (a) و چاه سردره (b) با استفاده از رگرسیون چندگانه در دو مرحله آموزش و آزمون

- 10- Decadal fluctuations of Pacific Ocean (PDO)
- 11- North Pacific pattern (NP)
- 12- East/West Atlantic Pattern of Russian (EA/WR)
- 13- Tropical Pattern of the South Atlantic (TSA)
- 14- Eurasian Polar Pattern (PE)
- 15- Transitional Nino Index (TNI)
- 16- Eastern Atlas Pattern (EA)
- 17- Tropical Pattern of the North Atlantic (TNA)
- 18- Pattern of North Atlantic Fluctuations (NAO Jones)
- 19- Decadal fluctuations of Pacific Ocean (AMO)
- 20- Atlantic Dipole Index (TAD)
- 21- Gamma Test
- 22- Multiple Regression
- 23- Multilayer Perceptron of Artificial Intelligent Networks
- 24- Enter Method
- 25- Levenberg-Marquardt Algorithm
- 26- Bayesian Regulation Algorithm
- 27- Root Mean Square Error (RMSE)
- 28- Coefficient of Determination

بنابراین، استفاده از این شاخص‌ها پس از بررسی‌های اولیه می‌تواند باعث کاهش خطای پیش‌بینی شود و بهتر است از آنها در مدل‌سازی استفاده شود. افزایش کارایی پیش‌بینی نوسانات آب زیرزمینی می‌تواند کمک شایانی به مدیران و بهره‌برداران منابع آب خصوصاً آبهای زیرزمینی نماید و تصمیم‌گیری‌ها در بخش آب از پشتوانه قوی‌تری برخوردار گردد. استفاده از سایر شاخص‌های پیوند از دور همراه با روش‌های دیگر مدل‌سازی می‌تواند در تحقیقات آتی مدنظر قرار گیرد.

پی‌نوشت‌ها

- 1- El Nino
- 2- El Nino-Sothern Oscillation (ENSO)
- 3- North Atlantic Oscillation (NAO)
- 4- Mediterranean Oscillation Index (MOI)
- 5- ENSO Multivariate Index (EMI)
- 6- Arctic Oscillation (AO)
- 7- North Pacific Index (PNA)
- 8- North Oscillation Index (NOI)
- 9- Western Pacific Index (WP)

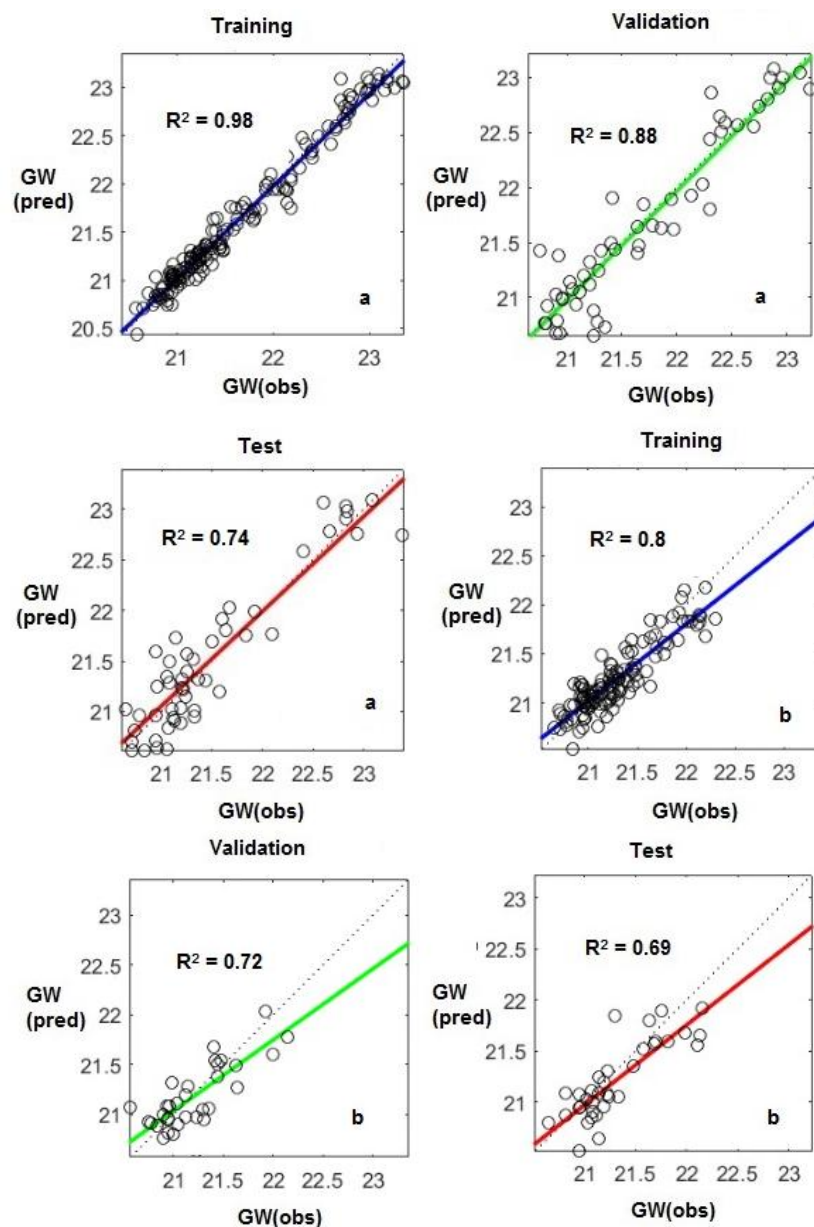


Fig. 5- Estimated and observed ground water level in Well 26 using two algorithms of Bayesian Regulation (a) and Levenberg-Marquardt (b) in the training, validation and test stages

شکل ۵- مقادیر تخمینی و مشاهداتی سطح آب زیرزمینی در چاه ۲۶ با دو الگوریتم تنظیم بیزین (a) و لونبرگ-مارکوآرت (b) در سه مرحله آموزش، آزمایش و آزمون

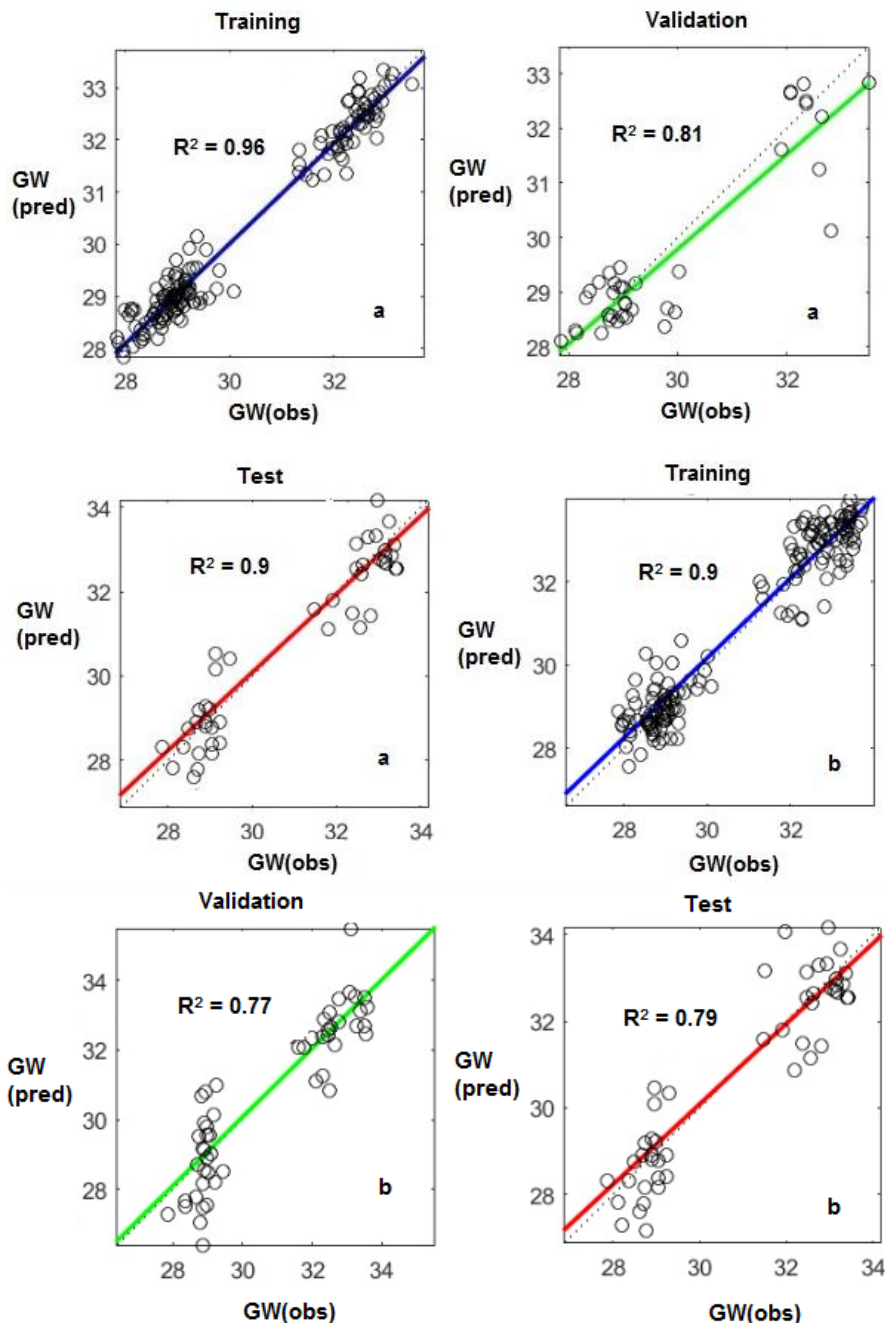


Fig. 6- Estimated and observed ground water level in Sardareh Well using two algorithms of Bayesian Regulation (a) and Levenberg-Marquardt(b) in the training, validation and test stages
 شکل ۶- مقادیر تخمینی و مشاهداتی سطح آب زیرزمینی در چاه سردره با دو الگوریتم تنظیم بیزین (a) و لونبرگ- مارکوآرت (b) در سه مرحله آموزش، آزمایش و آزمون

Alizadeh A, Erfanian M, Ansari H (2011) Investigation of teleconnection patterns affecting precipitation and temperature parameters, Case study: Synoptic Station, Mashhad. Iranian Journal of Irrigation and Drainage 5(2):176-185 (In Persian)

۶- مراجع

Alijani B (2002) Synoptic climatology. Samt Publications Press (In Persian)

Allen J (2017) El Niño-like teleconnection increases California precipitation in response to warming. Nature Communications 8:1-15

- with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics* 71:975-982
- NOAA (2012) Climate diagnostic center climate indices. Available from: <http://www.cdc.noaa.gov/ClimateIndices>
- Pradhan S, Kumar SH, Kumar Y, Sharma HC (2019) Assessment of groundwater utilization status and prediction of water table depth using different heuristic models in an Indian inter-basin. *Soft Computing* 23(20):10261-10285
- Rampelotto PH, Rigozo NR, Da Rosa MB, Prestes A, Frigo E, Souza Echer, MP, Nordemann DJR (2012) Variability of rainfall and temperature (1912–2008) parameters measured from Rust Santa Maria (29°41'S, 53°48'W) and their connections with ENSO and solar activity. *Journal of Atmospheric and Solar- Terrestrial Physics* 77:152-160
- Santo FE, Lima MI, Ramos AM, Trigo RM (2014) Trends in seasonal surface air temperature in mainland Portugal since 1941. *International Journal of Climatology* 34(6):1814-1837
- Sharifi AR, Din Pajouh Y, Fakhri Fard A, Moghadamnia AR (2013) Optimal combination of variables for simulation of runoff in Imamah watershed using Gamma test. *Soil and Water Journal* 23(4):59-72 (In Persian)
- Tremblay L, Larocque M, Anctil F, Rivard C (2011) Teleconnections and interannual variability in Canadian groundwater levels. *Journal of Hydrology* 410(3):178-188
- Upmanullal T, Russo A (2017) Depletion and response of deep groundwater to climate induced pumping variability. *Nature Geoscience* 10:105-108
- Yar Ahmadi D, Azizi Q (2007) Multivariate analysis of relationship between seasonal precipitation of Iran and climate indicators. *Journal of Geographical Research* 62:161-174 (In Persian)
- Yazdani MR, Zolfaghari AA (2016) Investigation of the effect of teleconnection indicators on river flow prediction performance (Case study: Hable-rood River Basin). *Journal of Rangeland and Watershed Management* 62(2):515-528 (In Persian)
- Yazdani MR (2016) Climate change and water resources. Semnan University Press (In Persian)
- Asakereh H (2007) Statistical study of Tabriz annual temperature trends. *Journal of Geographical Thought* 1:9-21 (In Persian)
- Bazrafshan A, Gorgani Z (2017) Influence of teleconnection indices on groundwater fluctuations in Hormozgan province. 11th National Conference on Iranian Watershed Management and Science, Yasouj, Iran (In Persian)
- Dong L, Shimada J, Kagabu M, Fu C (2014) Teleconnection and climatic oscillation in aquifer water level in Kumamoto plain, Japan. *Water Resources Management* 32(7):2421-2465
- Guoliangcao P, Zheng R (2015) Signals of short-term climatic periodities detected in the groundwater of North china plain. *Hydrological Processes* 30(4):515-533
- Guzman SM, Paz J, Tagert M, Mercer M (2019) Evaluation of seasonally classified inputs for the prediction of daily groundwater levels: NARX networks Vs support vector machines. *Environmental Modeling and Assessment* 24(2):223-234
- Hejazi Zadeh Z, Fatahi A, Saliegh M (2013) Investigating the impact of climate signals on precipitation in central Iran using artificial neural network. *Applied Research Journal of Geographical Sciences* 13(29):120-129 (In Persian)
- Holman W, Corstanje I, Bloomfield R, Cuthbert M (2018) A conceptual model for climatic teleconnection signal control on groundwater variability in Europe. *Earth-Science Reviews* 177:164-174
- Kakapour SA (2011) Analysis of the Caspian transplanted pattern effects on precipitation fluctuations in northwest and west of the country. M.Sc. Thesis, Department of Natural Geography, Faculty of Humanities, Tarbiat Modares University, Tehran (In Persian)
- Memar M, Hosseini KH, Karami H (2013) Predicting groundwater level using neural networks, Case study: Semnan Plain. 1st National Conference on Water Crisis, 22 May, Islamic Azad University, Khorasgan Branch (In Persian)
- Moghaddamnia A, Remesan R, Hassanpour Kashani M, Mohammadi M, Han D, Piri J (2009) Comparison of LLR, MLP, Elman, NNARX and ANFIS models-