



Evaluation of the Combination of Optimization Algorithms and adaptive Fuzzy-Neural Inference System Compared to Time Series Models in Groundwater Level Estimation

M. Zeinali¹, M. Ansari Ghojghar¹, Y. Mehri², and S.M. Hosseini^{3*}

Abstract

To optimize the management and use of groundwater resources, the temporal-spatial variation of the stagnant level and its prediction and modelling is essential to better understand the behavior of aquifers in response to the natural and human stimuli. Given the increasing development of metamodelling and their combination with optimization algorithms for modeling and predicting hydrogeological variables, the question remains that to what extent these hybrid models can be effective compared to the individual model. To answer this question, in this study, four algorithms of particle overvoltage optimization (PSO), genetics (GA), ant colony (ACO_R), and demand evolution (DE) were combined with the model of adaptive fuzzy-neural inference system (ANFIS). The performance of the combined models developed with the ANFIS model was evaluated to estimate the average monthly groundwater level of the Sahneh plain aquifer in Kermanshah province over 19 years. The time series model (SARIMA) was used as the reference model. To better compare the results of the models, the same input variables of the groundwater level in different time steps (maximum four months based on the self-correlation function of aquifer level) were considered for them. The results of fitness indicators in the training and test phases showed that there was no significant difference between the SARIMA time series model compared to other combined models used. However, given that SARIMA applies average moving processes, authorization, seasonal changes, and delays in modeling, it can be given more attention in groundwater leveling modeling. The RMSE values of the best hybrid model (ANFIS-GA) and SARIMA were 0.950 and 0.1012, respectively. The results also showed that the combination of optimization algorithms considered with the ANFIS model did not improve the model's results compared to the individual ANFIS model in terms of significance. The results of this research can help researchers in consciously choosing the appropriate model in predicting the time of the stagnant aquifer level according to the criteria of efficiency, time and cost of calculations and data preparation to enter the models.

Keywords: Modeling, Groundwater Level, SARIMA, ANFIS, Evolutionary Algorithms, Sahne Aquifer.

Received: July 10, 2020

Accepted: November 19, 2020

ارزیابی ترکیب الگوریتم‌های بهینه‌سازی و سیستم استنتاج فازی - عصبی تطبیقی در مقایسه با مدل‌های سری‌های زمانی در تخمین سطح آب زیرزمینی

معصومه زینعلی^۱، محمد انصاری قوجقار^۱، یاسر مه‌ری^۲ و سیدموسی حسینی^{۳*}

چکیده

به منظور مدیریت و بهره‌برداری بهینه از منابع آب زیرزمینی آگاهی از تغییرات مکانی - زمانی سطح ایستابی و لزوم پیش‌بینی و مدل‌سازی آنها به منظور شناخت دقیق تر رفتار آبخوان نسبت به محرک‌های طبیعی و انسانی، امری ضروری است. با توجه به توسعه روزافزون فرامدل‌ها و ترکیب آنها با الگوریتم‌های بهینه‌سازی به منظور مدل‌سازی و پیش‌بینی متغیرهای هیدروژئولوژیکی، این سؤال که استفاده از مدل‌های ترکیبی چقدر می‌تواند عملکرد فرامدل‌ها را بهبود بخشد، مطرح می‌شود. به منظور تلاشی در جهت یافتن پاسخ، در این پژوهش، چهار الگوریتم بهینه‌سازی فراکوشی ازدحام ذرات (PSO)، ژنتیک (GA)، کلونی مورچگان (ACO_R) و تکاملی تقاضی (DE) با مدل سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) ترکیب شد. عملکرد چهار مدل ترکیبی توسعه داده شده با مدل ANFIS و مدل سری زمانی (SARIMA) به عنوان مدل مرجع، جهت تخمین سطح آب زیرزمینی متوسط ماهانه آبخوان دشت صحنه در استان کرمانشاه، در بازه زمانی ۱۹ سال آبی ارزیابی شد. به منظور مقایسه بهتر نتایج مدل‌ها، متغیرهای ورودی یکسان از تراز آب زیرزمینی در گام‌های زمانی مختلف (حداکثر ۴ ماه بر اساس تابع خودهمبستگی تراز آبخوان) برای آنها در نظر گرفته شد. نتایج شاخص‌های نکویی برازش در مرحله آموزش و آزمون نشان داد اختلاف معناداری بین مدل سری زمانی SARIMA نسبت به سایر مدل‌های ترکیبی مورد استفاده، وجود ندارد. اما با توجه به اینکه SARIMA فرآیندهای میانگین متحرک، اتورگرسیون، تغییرات فصلی و تأخیر را در مدل‌سازی اعمال می‌کند، در مدل‌سازی سطح آب زیرزمینی می‌تواند بیشتر مورد توجه قرار گیرد. مقادیر RMSE برترین مدل ترکیبی (ANFIS-GA) و SARIMA به ترتیب ۰/۹۵۰ و ۰/۱۰۱۲ متر به دست آمد. همچنین نتایج به دست آمده نشان داد که ترکیب الگوریتم‌های بهینه‌سازی در نظر گرفته شده با مدل ANFIS نتایج مدل را نسبت به مدل انفرادی ANFIS به صورت معنی‌داری بهبود نمی‌بخشد. نتایج این تحقیق می‌تواند محققان را در انتخاب آگاهانه مدل مناسب در پیش‌بینی سطح ایستابی آبخوان با توجه به معیارهای کارایی، زمان و هزینه محاسبات و آماده‌سازی داده‌ها جهت ورود به مدل‌ها کمک نماید.

کلمات کلیدی: مدل‌سازی، سطح آب زیرزمینی، SARIMA، ANFIS، الگوریتم‌های تکاملی، آبخوان صحنه.

تاریخ دریافت مقاله: ۹۹/۴/۲۰

تاریخ پذیرش مقاله: ۹۹/۸/۲۹

1- Ph.D. Candidate in Water Resources, Department of Irrigation & Reclamation Engineering, Faculty of Agricultural Engineering & Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran.

2- Ph.D. Candidate in Hydraulic Structures, Department of Irrigation & Reclamation Engineering, Faculty of Agricultural Engineering & Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Iran.

3- Associate Professor, Department of Physical Geography, College of Geography, University of Tehran, Tehran, Iran. Email: smhosseini@ut.ac.ir

*- Corresponding Author

۱- دانشجوی دکتری منابع آب، گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران، کرج، ایران.

۲- دانشجوی دکتری سازه‌های آبی، گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران، کرج، ایران.

۳- دانشیار، گروه جغرافیای طبیعی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران.

*- نویسنده مسئول

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

استفاده بهینه از منابع آب‌های زیرزمینی، مستلزم مدیریت صحیح در بهره‌برداری و نیازمند سواد علمی و فنی بر سیستم منابع آبی هر منطقه است، از اساسی‌ترین موارد در مدیریت کمی منابع آب زیرزمینی، تخمین سطح آب با استفاده از داده‌های برداشت شده از شبکه چاه‌های مشاهده‌ای می‌باشد (Zarei and Akhund Ali, 2007). در همین راستا طیف وسیعی از مدل‌ها شامل مدل‌های عددی مبتنی بر فیزیک مسئله، مدل‌های سری زمانی و فرامدل‌های هوشمند (جعبه سیاه) و ترکیب آنها با الگوریتم‌های بهینه‌سازی (به ویژه نوع فراکاوشی) کاربرد زیادی در علوم هیدرولوژی و هیدروژئولوژی دارند. به همین دلیل در سال‌های اخیر بهره‌گیری از مدل‌های سری زمانی و هوشمند برای مدل‌سازی و پیش‌بینی سطح ایستابی افزایش یافته است که در ادامه به برخی از این پژوهش‌ها در زمینه هیدروژئولوژی اشاره شده است.

(Pour Mohammadi et al. 2013) در تحقیقی به مقایسه کارایی روش شبکه عصبی و مدل سری زمانی در پیش‌بینی سطح آب زیرزمینی در زیرحوضه بختگان استان فارس پرداختند. نتایج این پژوهش کارایی و دقت بالای هر دو تکنیک شبکه عصبی و مدل سری زمانی را در پیش‌بینی سطح ایستابی چاه‌های منطقه نشان داد. (Shirvanyichi et al. 2013) برای شبیه‌سازی و پیش‌بینی وضعیت آب زیرزمینی دشت کرمان، مدل $ARIMA(2,1,0)$ را به‌عنوان بهترین مدل جهت پیش‌بینی سطح آب زیرزمینی منطقه مورد مطالعه، معرفی کردند. (Ghadmapour and Shaghaghian 2011) از دو روش هوش مصنوعی و آنالیز سری‌های زمانی برای تعیین تراز آب زیرزمینی در شهرستان Union در ایالت نیوجرسی آمریکا استفاده کردند. در روش آنالیز سری زمانی با استفاده از مشاهدات و از بین مدل‌های کلاسیک، مدل $ARMA$ بعنوان مدل مناسب جهت برآزش بر مبنای پیش‌بینی‌ها با سطح اعتماد ۹۵٪ انتخاب گردید. (Naseri 2018) افت سطح آب زیرزمینی را به مدت ۴۵ سال با روش الگوبندی، به‌منظور تحلیل تغییرات سطح آب زیرزمینی در یک دشت ارزیابی کرد و الگوی اتورگرسیو تلفیقی میانگین متحرک (ARIMA) مناسب‌ترین الگو تشخیص داده شد.

در کنار مدل‌های سری زمانی، ثابت شده است که مدل سیستم استنتاج عصبی فازی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و همچنین باتوجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، در زمینه پیش‌بینی‌های مؤلفه‌های هیدروژئولوژی ابزار قدرتمندی می‌باشد

(Kişi, 2009; Nayak et al., 2004). در مقایسه با مدل‌های سری زمانی که شرایط ایستایی (در میانگین و واریانس) از جمله الزامات آن‌ها برای داده‌های مورد استفاده است، پیش‌پردازش آماری داده‌ها در این گونه مدل‌ها، الزامی نیست (Hosseini and Mahjouri, 2014). Kholghi and Hosseini, 2009 کارایی روش کریجینگ معمولی (OK) و سیستم استنتاج فازی مبتنی بر شبکه تطبیقی (ANFIS) را در درون‌یابی سطح آب‌های زیرزمینی در یک سفره آب آزاد در شمال ایران، مورد بررسی قرار دادند. نتایج نشان داد که مدل ANFIS در برآورد سطح آب زیرزمینی نسبت به کریجینگ معمولی عملکرد بهتری دارد. (Malekinejad and Pourshareyati 2013) برای پیش‌بینی نوسانات سطح آب زیرزمینی در دشت مروست از مدل‌های سری زمانی و شبکه عصبی استفاده کردند و مدل شبکه عصبی نسبت به مدل سری زمانی تلفیقی، برتری جزئی نشان داد. (Yoon et al. 2016) با استفاده از روش‌های شبکه عصبی و ماشین بردار پشتیبان براساس سری‌های زمانی دراز مدت سطح ایستابی را پیش‌بینی کردند. براساس نتایج مقایسه عملکرد دو مدل، نشان داده شد که پیش‌بینی عملکرد برگشت‌پذیر مدل ماشین بردار پشتیبان برتر از مدل شبکه عصبی می‌باشد.

(Hosseini and Kerachian 2017) یک روش جدید مبتنی بر ترکیب داده‌ها برای طراحی مجدد مکانی - زمانی (S-T) شبکه‌های پایش سطح آب زیرزمینی (GLMNs) ارائه داده‌اند و از یک شبکه عصبی مصنوعی (ANN) و یک مدل کریجینگ S-T برای شبیه‌سازی نوسانات سطح آب زیرزمینی در دشت دهگلان در شمال غربی ایران، استفاده کردند. نتایج نشان داد که برای نمونه‌گیری، یک پیکربندی جدید با ۳۵ و ۷ ایستگاه نظارت و فواصل نمونه برداری ۲۰ و ۳۲ روز، به ترتیب در مناطق فرعی با اولویت‌های نظارت بالا و پایین، به یک شبکه نظارت کارآمدتر از شبکه موجود منجر می‌شود که شامل ۵۲ ایستگاه نظارت و نمونه‌برداری ماهانه است. (Stanley Raj et al. 2017) از شبکه عصبی مصنوعی برای پیش‌بینی تراز آب زیرزمینی در آبخوان کانیاکومری، تامیل نادو، هند استفاده کردند. (Barzegar et al. 2017) با استفاده از مدل‌های ترکیبی موجک و شبکه عصبی، پیش‌بینی نوسانات سطح آب زیرزمینی را انجام دادند. استفاده از شبکه‌های تقویت عصبی WA عملکرد بهتری برای پیش‌بینی سطح آب زیرزمینی در مقایسه با مدل‌های مبتنی بر شبکه عصبی داشته‌اند. (Radmanesh et al. 2020) با استفاده از داده‌های ماهانه پیرومتری آبخوان دشت لور - اندیمشک، به مدت ۵ سال، و محاسبات روی مدل مفهومی آب زیرزمینی (MODFLOW)، برنامه‌نویسی بیان‌ژن (GEP) و سیستم استنتاج فازی عصبی تطبیقی برای مدل‌سازی نوسانات سطح ایستابی آبخوان اجرا کردند. نتایج نشان داد که سرعت

اجرای مدل GEP سریع‌تر از مدل ANFIS بوده و هر دو مدل از نظر کارایی زمانی بهتر از مدل مفهومی عمل کردند. همچنین مدل MODFLOW و GEP در مدل‌سازی هیدروگراف آبخوان تقریباً یکسان عمل کرده‌اند.

در علم هیدروژئولوژی، در زمینه ترکیب فرامدل‌ها با الگوریتم‌های بهینه‌سازی می‌توان به پژوهش‌های زیر اشاره کرد. Jalal Kamali (2015) با استفاده از دو مدل ANFIS-GA و ANFIS-PSO، پارامترهای کیفی آب زیرزمینی دشت کرمان را تخمین زدند. نتایج نشان داد که مدل‌های مورد استفاده، عملکرد مناسبی برای مدل‌سازی کیفیت آب زیرزمینی دارند. Habibi et al. (2016) به منظور پیش‌بینی نوسانات مکانی و زمانی سطح آب زیرزمینی آبخوان دشت هادیشهر، از روش‌های الگوریتم ژنتیک و نروفازی به صورت منفرد و ترکیب بهترین مدل آن‌ها با روش‌های زمین آماری استفاده کردند. نتایج نشان داد دقت مدل برنامه‌ریزی ژنتیک بیشتر از مدل نروفازی است به همین دلیل، مدل برنامه‌ریزی ژنتیک برای ترکیب با مدل زمین آماری (کریجینگ) استفاده شد. در نهایت مدل ترکیبی کریجینگ-ژنتیک برای پیش‌بینی مکانی-زمانی سطح آب زیرزمینی آبخوان موردنظر، انتخاب شد. Nadiri et al. (2017) از مدل‌های هوش مصنوعی شامل شبکه‌های عصبی پیش‌رو (FNN)، شبکه‌های عصبی برگشتی (RNN) و برنامه‌نویسی بیان ژن جهت بررسی تغییرات سطح آب زیرزمینی دشت استفاده کردند. آنها جهت استفاده از کارایی هر سه مدل و دستیابی به نتیجه بهتر، از روش ترکیبی مدل‌های هوش مصنوعی با استفاده از یک شبکه عصبی مصنوعی استفاده کردند. نتایج نشان داد متوسط خطای هر دسته در مدل هوش مصنوعی مرکب، نسبت به مدل‌های منفرد به طور متوسط ۱۷٪ در مقادیر RMSE کاهش می‌یابد.

براساس تحقیقات قبلی (که برخی از آنها در بالا اشاره شده است)، قابلیت فرامدل‌ها و نوع ترکیبی آنها با الگوریتم‌های بهینه‌سازی در کنار مدل‌های سری زمانی در پیش‌بینی مکانی-زمانی تراز آب زیرزمینی به خوبی روشن شده و به اثبات رسیده است؛ و این‌گونه نتیجه می‌شود که مدل‌های خطی سری زمانی با نوع به شدت غیرخطی فرامدل‌های ترکیبی، در این زمینه پژوهشی قابل رقابت هستند.

حال، سؤالات اساسی در این زمینه این است که با توجه به ساختار هریک از این دسته مدل‌ها و الزامات و شرایط مورد نیاز از داده‌های اولیه، ترکیب و تجهیز فرامدل ANFIS با الگوریتم‌های بهینه‌سازی که توسعه هر روزه آنها را شاهد هستیم، تا چه اندازه می‌تواند کارایی این فرامدل را بهبود دهد؟ آیا در مقایسه با مدل‌های سری زمانی

استفاده از این نوع مدل‌های ترکیبی که معمولاً هزینه محاسباتی بالایی هم دارند در پیش‌بینی تراز آب زیرزمینی (به عنوان یک نمونه از کاربردهای آن‌ها در مدل‌سازی سامانه‌های منابع آب) اختلاف معناداری وجود دارد؟ برای پاسخ به این سؤالات، در این پژوهش، فرامدل مرسوم ANFIS با چهار الگوریتم بهینه‌سازی فراکاوشی ژنتیک (GA)، ازدحام ذرات (PSO)، کلونی مورچگان برای محیط‌های پیوسته (ACOR) و تکامل تفاضلی (DE) به منظور مدل‌سازی داده‌های بلند مدت تراز ماهیانه آب زیرزمینی دشت کرمانشاه مورد ارزیابی قرار گرفتند. در این راستا، مدل‌های سری زمانی (SARIMA) به عنوان مدل مینا و جهت ارزیابی عملکرد مدل‌های ترکیبی مورد استفاده قرار گرفته است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

دشت صحنه، در استان کرمانشاه و قسمت جنوبی و شرقی شهرستان صحنه، از اراضی آبرفتی در وسط و اراضی دامنه‌های اطراف تشکیل شده که دارای مساحتی در حدود ۱۷۰ کیلومتر مربع است و بین ۳۴ درجه و ۱۹ دقیقه و ۳۴ درجه و ۴۸ دقیقه عرض شمالی و ۴۷ درجه و ۶ دقیقه تا ۴۷ درجه و ۵۱ دقیقه طول شرقی از نصف‌النهار گرینویچ واقع شده است. این دشت از پای ارتفاعات بید سرخ آغاز و در ارتفاعات نعل‌شکن خاتمه می‌یابد. عرض این دشت در حدود ۹۰ کیلومتر است و دارای آب و هوای معتدل کوهستانی و بیابانی می‌باشد. در شکل (۱-الف) تصویر ماهواره‌ای موقعیت دشت صحنه و محل پیژومترها نشان داده شده است. سپس در محیط اکسل محاسبات لازم برای استخراج هیدروگراف واحد دشت انجام شد. از داده‌های ماهانه مربوط به ۲۱ پیژومتر در ۱۹ سال آبی ۷۱-۷۰ تا ۸۹-۸۸ برای استخراج هیدروگراف آبخوان استفاده شده است. در نهایت مدل‌سازی با ANFIS، ANFIS-GA، ANFIS-PSO، ANFIS-DE و ACOR بر روی داده‌های حاصل از هیدروگراف شکل (۱-ب) صورت گرفته است.

۲-۲- مدل سری زمانی باکس-جنکینز داده‌های تراز آب زیرزمینی

یکی از مدل‌های سری زمانی برای پیش‌بینی، مدل ARMA است که توسط باکس و جنکینز ارائه شده است. این مدل، ترکیبی از مدل‌های خود همبسته (AR) و میانگین متحرک (MA) است. برتری مدل‌های ARMA در مقایسه با مدل‌های AR تعبیرپذیری بالاتر و تعداد پارامترهای کمتر نسبت به مدل‌های خود همبسته مرتبه بالاتر است.

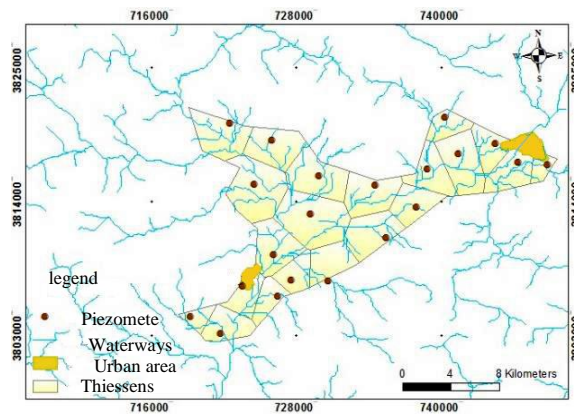
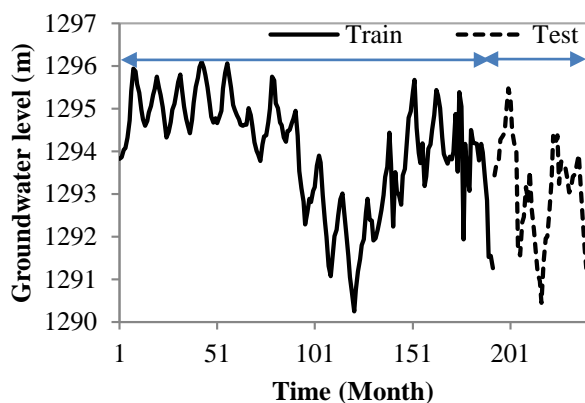


Fig. 1- a) Location of the Sahneh plain and the piezometers, b) Long-term groundwater hydrograph of Sahneh plain aquifer

شکل ۱- الف) موقعیت دشت صحنه و محل پیزومترها، ب) هیدروگراف واحد سطح آب زیرزمینی آبخوان دشت صحنه

به ترتیب مرتبه‌ی مدل‌های میانگین متحرک فصلی و غیر فصلی می‌باشند.

۲-۳- سیستم استنتاج فازی- عصبی تطبیقی (ANFIS)

سیستم استنتاج عصبی فازی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و همچنین با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، در مدل‌سازی فرایندهایی همچون هیدرولوژی، هیدروژئولوژی، مدیریت مخازن و برآورد بار رسوب معلق بسیار قدرتمند می‌باشد (Nayak et al., 2004; Kişi, 2009). به‌منظور ساده‌سازی، فرض می‌شود که سیستم استنتاجی مورد نظر دو ورودی x و y و یک خروجی z دارد. برای یک مدل فازی تاکاگی سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر- آنگاه فازی به صورت زیر بیان کرد:

قانون اول: اگر x برابر A_1 و y برابر B_1 باشد آنگاه $z_1 = p_1x + q_1y + r_1$ ؛

قانون دوم: اگر x برابر A_2 و y برابر B_2 باشد آنگاه $z_2 = p_2x + q_2y + r_2$ ؛ که p_i و q_i که $i=1, 2$ پارامترهای خطی در بخش تالی مدل فازی تاکاگی- سوگنو درجه اول هستند (Nourani and Salehi, 2008). ویژگی متمایزکننده ANFIS، فراهم کردن الگوریتم یادگیری پیوندی روش شیب پس انتشار و روش حداقل مربعات، به منظور اصلاح پارامترها می‌باشد. جزییات بیشتر این روش در منبع (Jang et al., 1997) در دسترس می‌باشد.

اگر در سری زمانی مورد بررسی مانند سری‌های زمانی هیدرولوژیک تغییرات فصلی وجود داشته باشد از مدل‌های SARIMA استفاده می‌شود که این مدل، توسعه یافته مدل ARMA است. این مدل متشکل از دو مدل ARIMA فصلی و غیر فصلی است که به شکل $SARIMA(p,d,q)(P,D,Q)_s$ نشان داده می‌شود و در آن P مرتبه‌ی مدل خود همبسته فصلی، D تعداد دفعات تفاضل‌های فصلی انجام شده و Q مرتبه‌ی مدل میانگین متحرک و s طول فصل می‌باشد (Wang et al., 2013 and Safavi, 2011). در این مدل روابطی به کار برده می‌شود که در ادامه به آنها اشاره شده است:

$$\Phi_p(B)\Phi_p(B^s)^d(1-B^s)^D Y_t = \theta_q(B)\Theta_q(B^s)\varepsilon_t \quad (1)$$

در رابطه بالا؛ B^s عملگر تفاضل است که به صورت $B^k Y_t = Y_{t-k}$ تعریف می‌شود. $\Phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ ، عملگر خود همبسته، $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ ، عملگر میانگین متحرک، $\Phi_p(B^s) = 1 - \phi_s B^s - \dots - \phi_{ps} B^{ps}$ ، عملگر خود همبسته فصلی و $\Theta_q(B^s) = 1 - \theta_s B^s - \dots - \theta_{qs} B^{qs}$ ، عملگر میانگین متحرک فصلی هستند. طبق رابطه بالا Φ پارامتر مدل همبسته غیر فصلی، θ پارامتر مدل میانگین متحرک غیر فصلی، Φ پارامتر مدل خود همبسته فصلی و Θ پارامتر مدل میانگین متحرک فصلی است. برای انتخاب بهترین مدل از معیاری به نام آکائیکه اصلاح شده استفاده می‌شود. هرچه این معیار کوچک‌تر باشد مدل موردنظر مناسب‌تر خواهد بود:

$$AIC = n \left(\ln \left(\frac{2\pi RSS}{n} \right) + 1 \right) + 2(p + q + P + Q) \quad (2)$$

که در این رابطه n تعداد مشاهدات و RSS مجموع مربعات باقیمانده‌ها و P و Q به ترتیب مرتبه مدل خود همبسته فصلی و غیر فصلی Q و p

۴-۲- الگوریتم‌های فراکاوشی بهینه‌سازی

در مرحله آموزش، با اصلاح پارامترهای درجه عضویت بر اساس میزان خطای قابل قبول، مقادیر ورودی به مقادیر حقیقی نزدیک‌تر می‌شوند. روش آموزش اصلی در این سامانه، روش پس‌انتشار خطا است. در این روش با استفاده از الگوریتم شیب نزولی خطا، مقدار خطا به سمت ورودی‌ها پخش می‌گردد و پارامترها تصحیح می‌شوند. در این پژوهش برای دستیابی به پارامترهای بهینه توابع عضویت، از الگوریتم‌های بهینه‌سازی ازدحام ذرات، ژنتیک، کلونی مورچگان در محیط‌های پیوسته و تکامل تقاضی، استفاده شده است. مطابق با روندنمای ارائه شده در شکل ۲ روند تعیین پارامترهای بهینه توابع عضویت، با تابع هدف حداقل کردن مقدار خطا، با استفاده از چهار الگوریتم بهینه‌سازی GA، PSO، ACO_R و DE به منظور ترکیب با مدل ANFIS در مدل‌سازی زمانی سطح آب زیرزمینی مورد استفاده قرار گرفته است. در ادامه روابط تابع هدف ارائه شده است:

$$OF = \text{Minimum}(\text{RMSE}) \quad (۳)$$

$$w_i = \prod_i \mu_{A_i}(x_i) \quad (۴)$$

$$\bar{w}_i = \frac{w_i}{\sum_{i=1}^{\text{NumRule}} w_i} \quad (۵)$$

$$E_k = \sum_{i=1}^{\text{NumRule}} \bar{w}_i (p_i x + q_i y + r_i) \quad (۶)$$

$$E_{k'} = \sum_{i=1}^{\text{NumRule}} \bar{w}_i (p_i x + q_i y + r_i) \quad (۷)$$

$$\text{RMSE}_{\text{Test}} = \sqrt{\frac{1}{N_{\text{Test}}} \sum_{k'=1}^{N_{\text{chek}}} (O^{k'} - E^{k'})^2} \quad (۸)$$

$$\text{RMSE}_{\text{Train}} = \sqrt{\frac{1}{N_{\text{Train}}} \sum_{k=1}^{N_{\text{chek}}} (O^k - E^k)^2} \quad (۹)$$

در روابط بالا x و y ورودی‌های غیرفازی به گره i و A_1 و B_1 برچسب‌های زبانی هستند که به ترتیب با توابع عضویت مناسب μ_{A_i} و μ_{B_i} مشخص می‌شوند. خروجی i امین گره از لایه قبلی است. (p_i, q_i, r_i) ضرایب این ترکیب خطی بوده، همچنین مجموعه پارامترهای بخش تالی مدل فازی تاکاگی- سوگنو نیز می‌باشند. N تعداد داده‌ها، O مقدار مشاهداتی تراز متوسط ماهانه سطح آب زیرزمینی و E مقدار تخمینی تراز متوسط ماهانه سطح آب زیرزمینی می‌باشد و اندیس k و k' به ترتیب نشان‌دهنده مرحله آموزش و آزمایش هستند.

۱) الگوریتم ازدحام ذرات: الگوریتم بهینه‌ساز ازدحام ذرات یکی از روش‌های بهینه‌سازی تکاملی الهام گرفته شده از طبیعت می‌باشد، چارچوب این الگوریتم شامل تعدادی ذره است که بصورت تصادفی منتشر می‌شوند و در فضای جستجوی تابع هدف مسئله باید کمینه شوند. مقدار تابع هدف توسط هر ذره در موقعیت فعلی خود محاسبه می‌گردد، سپس بهترین موقعیت قبلی و اطلاعات یک یا چند عدد از

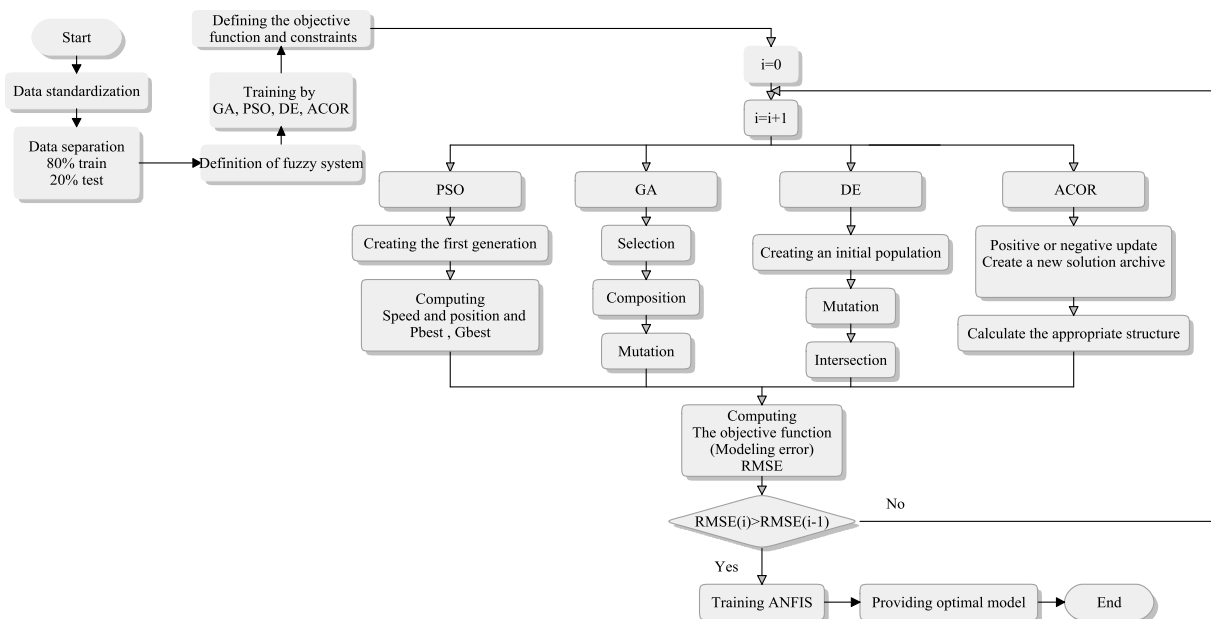


Fig. 2- ANFIS model and ANFIS-GA, ANFIS-PSO, ANFIS-ACOR and ANFIS-DE combined models flowchart

شکل ۲- روندنمای مدل ANFIS و مدل‌های ترکیبی ANFIS-GA، ANFIS-PSO، ANFIS-ACOR و ANFIS-DE

بهترین ذرات با استفاده از ترکیب اطلاعاتی که در اختیار قرار گرفته مشخص شده و در نهایت جهتی برای حرکت انتخاب می‌گردد. هر ذره جهتی را برای حرکت انتخاب می‌کند و بعد از حرکت یک مرحله از الگوریتم تمام می‌شود که تکرار این مراحل تا کسب پاسخ مطلوب ادامه خواهد یافت (Araghinejad, 2013).

۲-۵- پیش‌پردازش و آماده‌سازی داده‌های ورودی مدل‌ها

در مدل‌سازی سری زمانی SARIMA اولین مرحله این است که سری زمانی داده‌ها در میانگین و واریانس ایستا باشند. برای تشخیص ایستایی سری زمانی ابتدا با استفاده از آزمون نرمالیت در محیط نرم‌افزار Minitab 17، ایستایی در میانگین و واریانس توسط آزمون‌های آماری کلموگروف-اسمیرنوف (K-S) بررسی شد. نتایج آزمون‌های آماری حاکی از عدم ایستایی داده‌ها در سطح معنی‌داری ۹۵٪ بوده است. برای ایستا کردن سری زمانی از تبدیلات یوجانسون استفاده شده است. بعد از ایستا کردن در مرحله بعد، وجود یا عدم وجود روند در سری زمانی بررسی شد که داده‌ها دارای روند نزولی بودند و با یک مرحله تفاضل‌گیری از سری زمانی روند داده‌ها از بین رفت و سری زمانی جهت مدل‌سازی آماده شد. در فرامدل ANFIS و مدل‌های ترکیبی ANFIS-GA، ANFIS-PSO، ANFIS-ACOR و ANFIS-DE، برای به‌دست آوردن مجموعه مناسب از داده‌های ورودی، از نمودارهای توابع خود همبستگی (ACF) و خود همبستگی جزئی (PACF) داده‌های تراز متوسط ماهیانه سطح آب زیرزمینی دشت مورد مطالعه، مطابق شکل ۳ استفاده شد و طبق آن سری داده‌های تراز آب زیرزمینی بین یک تا چهار ماه تأخیر زمانی به‌عنوان ورودی مدل‌ها معرفی شدند.

سپس به منظور مدل‌سازی بهتر با فرامدل‌ها، سری داده‌ها توسط رابطه (۱۰) استاندارد شدند و کلیه داده‌ها بین صفر و یک قرار گرفتند و در نهایت ۸۰ درصد داده‌ها از ابتدای بازه، برای آموزش و ۲۰ درصد داده‌های باقیمانده برای آزمایش براساس ترتیب زمانی از ابتدا تا انتها استفاده شده است.

$$GWL = \frac{GWL_0 - GWL_{\min}}{GWL_{\max} - GWL_{\min}} \quad (10)$$

که در این رابطه GWL_0 داده نرمال شده سطح آب زیرزمینی، GWL_{\max} داده مورد نظر، حداکثر داده‌ها، GWL_{\min} حداقل داده‌ها می‌باشند. در مرحله بعد بایستی سیستم فازی پایه ایجاد شود. در این تحقیق برای ایجاد سیستم فازی پایه از روش $genfis3$ استفاده می‌شود برای این منظور پارامترهای ورودی ANFIS شامل: ۱- الگوریتم سوگنو (sugeno)؛ ۲- پارامترهای ورودی برای الگوریتم FCM و ۳- تعداد توابع عضویت (cluster) است که بعد از آزمون و خطا ۱۰ در نظر گرفته شد.

۲) الگوریتم ژنتیک: الگوریتم وراثتی یک مدل محاسباتی بر مبنای تکامل طبیعی است. سیستمی که بایستی بهینه گردد، به صورت رشته دودویی که پارامترهای سیستم را رمزگذاری کرده، نشان داده می‌شود. جمعیتی از رشته‌ها با پارامترهای تصادفی اولیه مورد استفاده قرار می‌گیرند. تعدادی از نسل‌ها با عملگرهایی که نشان‌دهنده اجزاء مهم تکامل مانند رقابت، انتخاب بر مبنای برازش، ترکیب و جهش هستند، شبیه‌سازی می‌شوند. با این وجود، روند تکاملی منجر به فیلتر شدن عناصر جمعیت که به تابع هدف مسأله بهینه‌سازی نزدیک‌ترند، می‌شود. اگر نقطه بهینه یکتا باشد، روند از طریق بهبود مدام برازش به آن نزدیک می‌شود و اگر این نقطه‌ی بهینه یکتا نباشد، روش به یکی از جواب‌های بهینه نزدیک می‌شود (Zahraei and Hosseini, 2014).

۳) الگوریتم کلونی مورچه‌ها: بهینه‌سازی کلونی مورچه‌ها برای دامنه‌های پیوسته از طریق مطالعه کلونی مورچه‌ها اختراع شد. این الگوریتم برای نخستین بار توسط دوریگو در سال ۱۹۹۲ به عنوان ابزاری برای حل مشکل بهینه‌یابی ارائه شد (Dorigo, 1992). این الگوریتم از رفتارهای جستجوی مواد غذایی برخی از گونه‌های مورچه‌ها در طبیعت الهام گرفته شده است (Socha and Dorigo, 2008). روش کلونی مورچه‌گان پیوسته با استفاده از یک تابع توزیع احتمال پیوسته توسط یک تابع چگالی احتمال، به جای استفاده از یک توزیع احتمال گسسته عمل می‌کند و الگوریتم تابع گوسی را بکار می‌گیرد. جزییات بیشتر این الگوریتم در منبع (Araghinejad, 2013) در دسترس می‌باشد.

۴) الگوریتم تکامل تفاضلی: الگوریتم تکامل تفاضلی روشی در حوزه محاسبات تکاملی است که در مسائل بهینه‌سازی کاربرد دارد. این الگوریتم برای غلبه بر مشکل الگوریتم‌های ژنتیکی که قادر به جستجوی محلی نیستند، توسط استورن و پرایس در سال ۱۹۹۷ ارائه شده است (Storn and Price, 1997). این الگوریتم با استفاده از تعدادی پاسخ اولیه فرایند را آغاز می‌کند و با یک سری تکرارهای پشت‌سرهم، بهترین پاسخ را برای مسئله بهینه‌سازی پیدا می‌کند. مهم‌ترین ویژگی الگوریتم تکامل تفاضلی، قدرت زیاد، سادگی و توانایی زیاد آن است و با تنظیم سه پارامتر اندازه جمعیت (NP)، وزن




Fig. 3- (a) Correlation diagrams (ACF) and (b) partial self-correlation (PACF) of the groundwater level data

شکل ۳- الف) نمودارهای خود همبستگی (ACF) و ب) خود همبستگی جزئی (PACF) داده‌های تراز آب زیرزمینی

۳- نتایج و بحث

۳-۱- نتایج مدل SARIMA

به منظور مدل‌سازی با SARIMA، اگر داده‌ها از مدل AR(P) تبعیت کنند نمودار ACF بصورت نامحدود بوده و حالت نمایی یا موجی میرا می‌شود و خط حدود اطمینان در نمودار PACF در فاصله p قطع می‌شود. اما اگر سری زمانی مورد بررسی از مدل MA(q) پیروی کند نمودار ACF در فاصله p قطع می‌شود و نمودار PACF به صورت نامحدود بوده و به حالت نمایی یا موجی میرا نمایان می‌شود. و زمانی که توابع PACF و ACF بصورت نامحدود گسترش پیدا کنند و در تأخیرهای p-q عملکرد منظم داشته باشند و به شکل نمایی میرا شوند مدل ARMA(p,q) است. در این مرحله ابتدا شش مدل پذیرفته شده با مقادیر آکائیک (۱۷۶/۳۲، ۱۸۲/۱۹، ۱۸۳/۴۳، ۱۸۵/۵۳، ۱۹۰/۷۰، ۲۱۱/۴۳)، مورد صحت‌سنجی قرار گرفتند و دو معیار ارزیابی شد. ابتدا مطابق شکل (۴-الف) باقیمانده‌های مدل مورد بررسی قرار گرفت، که اگر سری باقیمانده‌ها نرمال باشند به این معنی است که مدل انتخابی مناسب است. سپس مطابق شکل (۴-ب) نمودار خودهمبستگی باقیمانده‌های مدل رسم شد، و اگر تمام گام‌های تأخیر در محدوده اطمینان قرار گیرد به معنای مناسب بودن مدل می‌باشد. در نهایت مدل SARIMA(1,1,4)(3,1,0)₁₂ با مقدار آکائیک ۲۱۱/۴۳ به عنوان مدل برتر انتخاب شد.

معیار دیگر برای بررسی صحت مدل انتخابی آزمون لجانگ-باکس بر روی باقیمانده‌های مدل است که مقادیر حاصل از این آزمون در جدول ۱ آورده شده است در این جدول باید مقادیر p-value بزرگتر از ۰/۰۵ باشد تا آزمون پذیرفته شود. همانطور که در جدول نمایان است مقادیر p-value در تمام تأخیرها بزرگتر از ۰/۰۵ است، و این آزمون هم صحت مدل را تأیید می‌کند.

بعد از این قسمت که سیستم پایه فازی ایجاد شد، می‌توان از الگوریتم مرسوم ANFIS استفاده کرد یا سیستم بهینه‌سازی GA، PSO، ACO_R یا DE را برای آموزش ANFIS استفاده کرد. در نهایت در مرحله آخر بعد از ایجاد کمترین مقدار تابع خطا، داده‌ها را از محیط فازی به محیط مورد نظر انتقال داده (غیر فازی‌سازی) و نتایج مقادیر تخمینی با مقادیر مشاهداتی مقایسه می‌شود.

۲-۶- معیارهای نکویی برازش مدل‌ها

برای ارزیابی مدل‌های مورد استفاده از دو معیار، ضریب همبستگی (r) و جذرمیانگین مربعات خطا (RMSE) استفاده شد. در ادامه روابط این معیارها ارائه شده است:

$$r = \frac{\sum_{i=1}^n (O_i - O_m)(E_i - E_m)}{\sqrt{\sum_{i=1}^n (O_i - O_m)^2 \sum_{i=1}^n (E_i - E_m)^2}} \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (12)$$

به طوری که در روابط ۱۱ و ۱۲، E_i مقدار تخمینی تراز متوسط ماهانه سطح آب، O_i مقدار مشاهداتی تراز متوسط ماهانه سطح آب زیرزمینی، O_m متوسط مقادیر مشاهداتی، E_m متوسط مقادیر تخمینی و n تعداد کل داده‌ها است. یکی از کاربردی‌ترین روش‌های آماری در تجزیه و تحلیل داده‌ها، تکنیک تحلیل واریانس یا آنالیز واریانس (ANOVA) (Analysis of Variance) است که بطور خلاصه آنوا (ANOVA) نامیده می‌شود و برای انجام آزمون مقایسه میانگین بین دو یا چند جامعه آماری مستقل، می‌توان از این روش استفاده کرد.

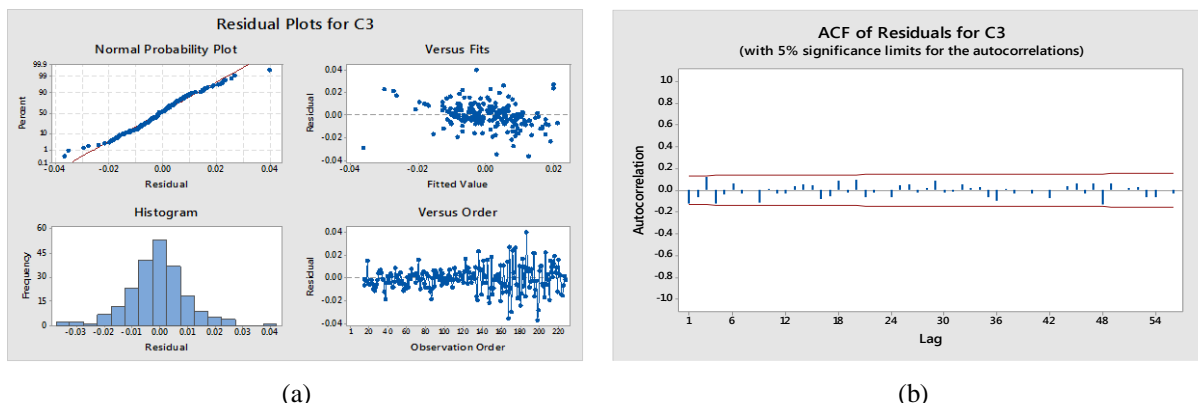


Fig. 4- a) Checking the normality and b) the self-correlation function of the residuals of the selected model

شکل ۴- الف) بررسی نرمال بودن و ب) تابع خود همبستگی باقیمانده‌های مدل انتخابی

تکرار، حداقل مقدار رشد و تابع داخلی مدل هستند که به ترتیب برابر ۲، ۱۰۰۰، 10^{-9} و صفر می‌باشند. سپس با ثابت نگه داشتن پارامترهای داخلی که در جدول ۲ نیز ارائه شده است، اقدام به بهینه‌سازی توابع عضویت برای تعیین کمترین مقدار خطا با روش‌های مختلف شد. پارامترهای ورودی مشترک در هر ۴ مدل بهینه‌شده، یکسان در نظر گرفته شد ولی پارامترهای داخلی مرتبط با هر روش بهینه‌سازی، با سعی و خطا و بر حسب تجربه مدل‌سازی تعیین شد. با توجه به اینکه تابع هدف وابسته به مقدار خطای مدل تخمینی است، با استفاده از پارامترهایی که در FIS پایه هستند مقادیر خطا تعیین شده است و اگر خطای مدل از مقدار خطایی که تعیین شده است کمتر شود، مدل‌سازی متوقف می‌شود و در غیر این صورت مراحل مدل‌سازی ادامه می‌یابد تا زمانی که شرط توقف را ارضاء کند. در نهایت در جدول ۲ مقادیر ثبت گردید.

Table 1- Log-Box test confirmation on the remaining of the selected model
جدول ۱- تأییدآزمون لجانگ- باکس بر روی باقیمانده‌های مدل انتخابی

Lag	12	24	36	48
Chi-Square	9.4	19.9	29.1	40.9
DE	4	16	28	40
P-Value	0.052	0.226	0.406	0.430

۳-۲- نتایج مدل عصبی- فازی و مدل‌های ترکیبی

در این تحقیق به منظور مدل‌سازی، ابتدا مدل ANFIS مورد آنالیز قرار گرفته است. پارامترهای ورودی مدل ANFIS بصورت سعی و خطا بدست آمده‌اند که با تأکید بر ایجاد کمترین خطا، جستجو و تعیین شده‌اند. این پارامترها شامل، تعداد نماینده ماتریس پارتیشن، تعداد

Table 2- The values of ANFIS model parameters and optimization algorithms
جدول ۲- مقادیر پارامترهای مدل ANFIS و الگوریتم‌های بهینه‌سازی

Row	Model	Optimization algorithm /Model parameters
1	ANFIS	(ROPM,MNOR,MGR,MIF)* (2,1000,10 ⁻⁹ ,0)
2	ANFIS-GA	(MNOR,PS,POC,NOFPOM,NOM,MR,SP)** (1000,25,0.4,0.9,0.9,11,0.9,8)
3	ANFIS-PSO	(MNOR,PS,IW,IWLR,PLC,CLC)*** (1000,25,1,0.99,1,2)
4	ANFIS-ACOR	(MNOR,PS,SP,DRAD)**** (1000,25,0.45,1)
5	ANFIS-DE	(PS,LROSF,HSFF,POI)***** (25,0.3,0.85,0.1)

* Representative of the partition matrix, Maximum number of repetitions, Minimum growth rate, Model internal function.

** Maximum number of repetitions, Population size, Percentage of composition, Number of parents, Percentage of mutations, Number of mutations, Mutation rate, Select pressure.

*** Maximum number of repetitions, Population size, Inertial weight, Inertia weight loss ratio, Personal learning coefficient, Collective learning coefficient.

**** Maximum number of repetitions, Population size, Select pressure, Deviation rate and distance.

***** Population size, Low range of scale factor, High scope factor factor, Probability of intersection.

۴- نتیجه گیری

هدف از این مطالعه ارزیابی عملکرد مدل‌های سری زمانی (SARIMA) و فرامدل‌های ترکیبی با الگوریتم‌های بهینه‌سازی ANFIS-ACOR, ANFIS-PSO, ANFIS-GA, ANFIS و ANFIS-DE در مدل‌سازی نوسانات سطح ایستابی آبخوان می‌باشد. در این تحقیق از داده‌های تراز متوسط آب زیرزمینی ۲۱ پیرومتر واقع در دشت صحنه در استان کرمانشاه به عنوان مطالعه موردی استفاده شده است. ورودی‌های مدل شامل مقادیر متوسط ماهانه تراز آب زیرزمینی در تأخیرهای قبل (حداکثر تا ۴ ماه) و متغیر خروجی شامل مقادیر تراز متوسط ماهانه سطح آب زیرزمینی می‌باشد. تجزیه واریانس نتایج مدل‌های نشان داد که اختلاف معناداری بین نتایج مدل‌های شش‌گانه مورد بررسی، وجود ندارد. اما با توجه به اینکه که مدل SARIMA فرآیندهای خاصی مانند میانگین متحرک، اتورگرسیون، تغییرات فصلی و تأخیر را در مدل‌سازی اعمال می‌کند و مدت زمان کمتری برای اجرای مدل نیاز دارد، می‌تواند در مورد مدل‌سازی تراز آب زیرزمینی بیشتر مورد توجه قرار گیرد. هرچند پیش‌پردازش آماری داده‌ها (بررسی ایستایی) و تبدیل داده‌ها در صورت نیاز، خود می‌تواند از جمله چالش‌های توأم با این دسته مدل‌ها باشد. همچنین نتایج بدست آمده از تجزیه واریانس، نشان داد که استفاده از الگوریتم‌های بهینه‌سازی فراکاوشی GA, PSO, ACO_R و DE و ترکیب آنها با مدل ANFIS، نتایج را به صورت معناداری نسبت به مدل ANFIS بهبود نمی‌بخشد و گویای آن است که مدل ANFIS خود به تنهایی ابزار قدرتمندی برای مدل‌سازی در این پژوهش به منظور تخمین سطح آب زیرزمینی می‌باشد. قابل ذکر است که الگوریتم‌های ترکیبی در جست‌وجوی کامل فضای جست‌جوی مسأله بهینه‌سازی، عدم نیاز به پیش‌پردازش و فرضیات آماری بر روی داده‌ها و همچنین یافتن ساختار بهینه ارتباط بین متغیرهای ورودی و خروجی به ویژه در فرآیندهای غیرخطی توانایی زیادی دارند؛ اما از جمله معایب آنها می‌توان به هزینه محاسبات اشاره نمود. لازم به ذکر می‌باشد که نتایج بدست آمده در این پژوهش و عدم معنی‌داری عملکرد مدل‌های ترکیبی در مقایسه با مدل ANFIS تنها برای آبخوان مورد مطالعه و مجموعه داده‌های استفاده شده کاربرد دارد و قابل تعمیم برای سایر آبخوان‌ها با شرایط هیدروژئولوژیکی متفاوت نیست و ممکن است ایجاد خطا نماید؛ اما می‌تواند محققین را در انتخاب آگاهانه مدل مناسب در پیش‌بینی زمانی سطح ایستابی آبخوان با توجه به کارایی مورد انتظار، زمان و هزینه محاسبات و شرایط لازم برای آماده‌سازی داده‌ها کمک نماید. بدون شک به منظور اعتبارسنجی نتایج بدست آمده از این پژوهش، تحقیقات بیشتر در کاربرد فرامدل‌های ترکیبی در مدل‌سازی و

پیش‌بینی زمانی- مکانی سطح آب زیرزمینی/پیرومتری در آبخوان‌های آبرفتی/تحت فشار لازم است، انجام شود.

پی‌نوشت‌ها

- 1- Ordinary Kriging
- 2- Adaptive Neuro Fuzzy Inference System
- 3- Spatio-Temporal
- 4- Groundwater Level Monitoring Network Design
- 5- Artificial Neural Network
- 6- Gene Expression Programming
- 7- Feedforward Neural Network
- 8- Recurrent Neural Network
- 9- Genetic Algorithm
- 10- Particle Swarm Optimization
- 11- Ant Colony Optimization for Continuous Domains
- 12- Differential Evolution
- 13- Autoregressive
- 14- Moving-Average

۵- مراجع

- Araghinejad Sh (2013) Data-driven modeling: Using MATLAB® in water resources and environmental engineering (Vol. 67). Springer Science & Business Media
- Barzegar R, Fijani E, Asghari Moghaddama A, Tziritis E (2017) Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of the Total Environment* 599(60):20-31
- Dashti R, Sattari M T, and Nourani V (2017) Performance evaluation of differential evolution algorithm in optimum operating of Elevisyan single-reservoir dam system. *Journal of Water and Soil Resources Conservation* 6(3):61-75
- Deb K A P, Agarwal S, Meyarivan T (2000) A fast elitist multi-objective genetic algorithm: NSGA II. *IEEE Transactions on Evolutionary Computation* 6:182-197
- Dorigo M (1992) Optimization, learning and natural algorithms. Ph.D. Thesis, Dipartimento di Elettronica, Politecnico di Milano, Italy
- Ghadmapour Z and Shaghaghian M (2011) Comparison of classical models of time series and artificial intelligence in determining groundwater levels. 6th National Congress of Civil Engineering, Semnan, Semnan University, https://www.civilica.com/Paper-NCCE06-NCCE06_0809.html
- Habibi M H, Nadiri A, and Asghari Moghadam A (2016) Providing a combined genetic-kriging model for temporal and spatial prediction of groundwater level.

- modeling hydrological time series. *Journal of Hydrology* 291(1–2):52-66
- Nourani V, Salehi K (2008) Rainfall-runoff modeling using adaptive fuzzy neural network method and comparing it with neural network and fuzzy inference method, Case study: (Lighvan Chay catchment area in East Aegean province). Fourth National Congress on Civil Engineering, University of Tehran (In Persian)
- Pour Mohammadi S, Malekinejad A, Pourshareiani R (2013) Comparison of the efficiency of neural and serial time network method in predicting groundwater level Case study: Under Bakhtegan basin of Fars province. *Journal of Water and Soil Research* 20(4):251:262 (In Persian)
- Radmanesh F, Golabi M R, Khodabakhshi F, Farzi S, and Zeinali M (2020) Modeling aquifer hydrograph: Performance review of conceptual MODFLOW and simulator models. *Arabian Journal of Geosciences* 13(5):1-9
- Safavid H (2011) *Engineering hydrology*. Arkan Danesh Publications, Third Edition, 724 pages
- Shirvanyichi H, Rashkolia H, Zonamat Kermani M (2013) Simulation and prediction of the groundwater status of Kerman plain using return and time series models of Kerman stochastic using return models and time series of stochastic time. The First National Conference on Hydrology in Arid Regions, 3 to 5 May, Kurdistan University Jihad
- Socha K, Dorigo M (2008) Ant colony optimization for continuous domains. *European Journal of Operational Research* 185(3):1155-1173
- Stanley Raj A, Hudson Oliver D, Srinivas Y, Viswanath J (2017) Wavelet based analysis on rainfall and water table depth forecasting using Neural Networks in Kanyakumari district, Tamil Nadu, India. *Groundwater for Sustainable Development* 5:178–186
- Storn R, Price K (1997) Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces. *Journal of Global Optimization* 11:341-359
- Wang Sh, Feng J, Liu G (2013) Application of seasonal time series model in the precipitation forecast. *Mathematical and Computer Modelling* 58(3-4):677-683
- Yoona H, Hyunb Y, Ha K, Leec K K, Kimd G B (2016) A method to improve the stability and accuracy of ANN- and SVM-based time series models for long-term groundwater level predictions. *Computers and Geosciences* 90:144-155
- Iran-Water Resources Research 11(3):85-99 (In Persian)
- Hosseini M and Kerachian R (2017) A data fusion-based methodology for optimal redesign of groundwater monitoring networks. *Journal of Hydrology* 552:267-282
- Hosseini S M & Mahjouri N (2014) Developing a fuzzy neural network-based support vector regression (FNN-SVR) for regionalizing nitrate concentration in groundwater. *Environmental Monitoring and Assessment* 186(6):3685-3699
- Hosseinipoor A, and Abdollahi A (1991) Predicting the short-term load of Kerman region using ANFIS-PSO combined method. Second National Conference on New and Clean Energy Management, Shahid Ba Honar University of Kerman
- Jalalkamali A (2015) Using of hybrid fuzzy models to predict spatiotemporal groundwater quality parameters. *Earth Science Informatics* 8(4):885-894
- Jang J S R, Sun C T, and Mizutani E (1997) *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. Prentice-Hall International, New Jersey
- Kholghi M and Hosseini S M (2009) Comparison of groundwater level estimation using neuro-fuzzy and ordinary kriging. *Environmental Modeling and Assessment* 14(6):729
- Kişi Ö (2009) Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology* 372(1–4):68-79
- Ljung G M and Box G E P (1978) On a measure of lack affect in time series models. *Biometrika* 65(2):297-303
- Malekinezhad H and Pourshareyati R (2013) Application and comparison of cumulative time series model and artificial neural network model in prediction of groundwater level variation (Case study: Marvast plain). *Irrigation Science & Engineering (Scientific Journal of Agriculture)* 36(3):81-92 (In Persian)
- Nadiri A, Taherkhani Z, and Sadeghi Aghdam F (2017) Groundwater level prediction of Bostanabad plain using supervised combination of artificial intelligence models. *Iranian Water Resources Research* 13(3):43-55 (In Persian)
- Nasari A (2018) Comparison of the application of fourteen temporal series patterns to analyze and predict changes in groundwater level in Marand plain (northern margin of Urmia Lake). *Irrigation and Drainage* 13(1):58-68
- Nayak P C, Sudheer K P, Rangan D M, and Ramasastry K S (2004) A neuro-fuzzy computing technique for

hydrograph drawings of groundwater unit. Research Project of Khuzestan Water and Power Organization P. 71 (In Persian)

Zahraei B, Hosseini S M (2014) Genetic algorithm and engineering optimization. Publications: Gutenberg, Second Edition, 298 pages

Zareie H, Akhondali A M (2007) Comparison of ground-statistical methods and classical statistics in