پیشرفت‌ها در علوم و مهندسی آب
جلد ۱، شماره ۳، پاییز ۱۴۰۳

Advances in Water Sciences and Engineering
Vol.1, Issue 3, Fall 2024

# شبیه‌سازی تراز آب زیرزمینی با مدل‌های هوشمند درخت تصمیم , جنگل تصادفی و سیستم استنتاج فازی (مطالعه موردی: آبخوان دشت تالش)

مریم احمدی[۱]، سامان جوادی[۲*]

**چکیده**

منابع آب زیرزمینی یکی از مهم‌ترین تأمین‌کننده‌های آب در مناطق خشک و نیمه‌خشک هستند. شبیه‌سازی دقیق تراز آب زیرزمینی به دلیل پیچیدگی‌های فیزیکی و وجود عدم قطعیت، چالش‌برانگیز است. این پژوهش سه مدل هوشمند شامل درخت تصمیم، جنگل تصادفی و سامانه استنتاج فازی را برای شبیه‌سازی تراز آب زیرزمینی آبخوان تالش در بازه زمانی ۱۳۸۱-۱۳۹۴ ارزیابی کرده است. داده‌های بارش، دما، برداشت، تبخیر، و سطح آب زیرزمینی یک ماه قبل به‌عنوان ورودی استفاده شد و ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای آزمون مدل‌ها اختصاص یافت. نتایج نشان داد که ترکیب سطح آب زیرزمینی یک ماه قبل، بارش، برداشت، و تبخیر (الگوی C) بهترین عملکرد را دارد. پارامتر سطح آب یک ماه قبل به‌عنوان مؤثرترین ورودی شناسایی شد. جنگل تصادفی با مقادیر خطای RMSE و MAE به ترتیب ۰,۴۴ و ۰,۳۵ متر، دقیق‌ترین مدل بود، درحالی‌که سامانه استنتاج فازی کمترین دقت را نشان داد. این پژوهش رویکردی ارائه می‌دهد که می‌تواند در شبیه‌سازی آبخوان‌های دیگر نیز به‌کار رود.

***کلمات کلیدی:*** آبخوان تالش، سامانه استنتاج فازی، شبیه‌سازی آب زیرزمینی، درخت تصمیم، جنگل تصادفی.

تاریخ دریافت مقاله:۱۴۰۳/۴/۱۳
تاریخ پذیرش مقاله:۱۴۰۳/۵/۲۰

۱- دانش‌آموخته کارشناسی ارشد، دانشکده مهندسی عمران، موسسه آموزش عالی آل طه، تهران، ایران.
۲- استادیار، دانشکده مهندسی عمران، موسسه آموزش عالی آل طه، تهران، ایران.
ایمیل:Saman,javadi@gmail.com
*- نویسنده مسئول

# Simulation of Groundwater Levels Using Intelligent Models: Decision Tree, Random Forest, and Fuzzy Inference System (Case Study: Talesh Plain Aquifer)

M. Ahmadi[1], S. Javadi[2*]

**Abstract**

Groundwater is one of the most critical sources of water supply, particularly in arid and semi-arid regions. Accurate simulation of groundwater levels is challenging due to the complexity of aquifer systems and inherent uncertainties. This study evaluates three intelligent models, decision tree, random forest, and fuzzy inference system for simulating groundwater levels in the Talesh aquifer during the period 2002–2015. Input parameters included precipitation, temperature, groundwater extraction, evaporation, and groundwater level from the previous month. Seventy percent of the data was used for training the models, while the remaining 30% was utilized for testing. The results indicated that the combination of groundwater level from the previous month, precipitation, groundwater extraction, and evaporation (Pattern C) provided the most accurate simulation. Among the input parameters, groundwater level from the previous month was identified as the most influential factor. The random forest model outperformed the others, achieving RMSE and MAE values of 0.44 m and 0.35 m, respectively. In contrast, the fuzzy inference system exhibited the lowest accuracy, with RMSE and MAE values of 0.49 m and 0.389 m, respectively.

***Keywords:*** Groundwater simulation, Intelligent model, Random Forest, Decision tree, Fuzzy inference system.

Received: July 3, 2024
Accepted: August 10, 2024

1- MSc., Civil Engineering Department, Ale-Taha Institute of Higher Education, Tehran, Iran.
2- Assistant Professor, Civil Engineering Department, Ale-Taha Institute of Higher Education, Tehran, Iran.
Email: Saman,javadi@gmail.com
* Corresponding Author

## مقدمه

آب زیرزمینی به‌عنوان یکی از منابع حیاتی در فرآیندهای هیدرولوژیکی و هیدروژئولوژیکی، نقش مهمی در تعادل کلی چرخه آب ایفا می‌کند. این منبع ارزشمند، حدود ۳۰ درصد از آب شیرین جهان را تشکیل می‌دهد و در مناطق خشک و نیمه‌خشک مانند ایران، اهمیت بیشتری می‌یابد. در این مناطق، کمبود آب یکی از بزرگ‌ترین چالش‌های زیست‌محیطی و اجتماعی به شمار می‌رود. بهره‌برداری بی‌رویه و غیرمنطقی از منابع آب زیرزمینی در سال‌های اخیر منجر به تغییرات نگران‌کننده‌ای در تراز طبیعی این منابع شده است، به‌طوری‌که در بسیاری از نقاط کشور، سطح آب زیرزمینی روند نزولی داشته است (نوروزی قوشبلاغ و ندیری، ۱۳۹۷). در کشورهای درحال‌توسعه، کشاورزی به‌عنوان یکی از اصلی‌ترین فعالیت‌های اقتصادی، وابستگی شدیدی به منابع آب زیرزمینی دارد (Kasiviswanathan et al., 2016). بااین‌حال، مدیریت نامناسب در روش‌های آبیاری سنتی و افزایش تعداد چاه‌های کشاورزی برای گسترش سطح زیر کشت، نه‌تنها بهره‌برداری بیش‌ازحد از این منابع را به دنبال داشته، بلکه پیامدهایی چون تخریب زمین، نشست زمین، و کاهش کیفیت آب را به همراه داشته است (Sadeghravesh, 2015).

نشست زمین که در نتیجه برداشت بیش‌ازحد آبخوان‌ها رخ می‌دهد، در برخی مناطق ایران به شش متر نیز رسیده است. این پدیده که اغلب به‌صورت ناهماهنگ رخ می‌دهد، باعث آسیب جدی به ساختمان‌ها، سازه‌ها، و زیرساخت‌های شهری می‌شود (پیش‌نویس دستورالعمل پایش کیفیت آب‌های زیرزمینی، ۱۳۹۰). در چنین شرایطی، مدیریت بهینه منابع آب زیرزمینی از طریق اعمال روش‌های مدیریتی مناسب می‌تواند هزینه‌های توسعه و بهره‌برداری را کاهش داده و استفاده از این منابع را بهینه نماید (فرهمند و همکاران، ۱۳۹۰).

یکی از عوامل مؤثر در کمبود منابع آب زیرزمینی، تأثیرات انسانی ازجمله بهره‌برداری بیش‌ازاندازه است. علاوه بر این، تغییرات اقلیمی و پدیده گرمایش جهانی نیز نقش بسزایی در کاهش منابع آب ایفا می‌کنند. این پدیده‌ها باعث افزایش مصرف آب، تبخیر و تعرق بیشتر، و کاهش بارندگی شده و درنهایت منجر به کاهش میزان آب در دسترس در دوره‌های زمانی مشخص می‌شوند. در چنین شرایطی، فشار بر منابع آب زیرزمینی افزایش یافته و تعادل طبیعی آبخوان‌ها برهم می‌خورد.

کاهش سطح آب زیرزمینی می‌تواند ناشی از برداشت بیش‌ازحد یا کاهش تغذیه منابع باشد. در سال‌های اخیر، رشد روزافزون تقاضا برای کشاورزی، صنعت، و مصارف شرب، وابستگی به آب‌های زیرزمینی را افزایش داده است. در ایران، کشاورزی به‌طور گسترده به آب‌های زیرزمینی متکی است و برداشت‌های بی‌رویه از چاه‌های مجاز و غیرمجاز باعث عدم تعادل میان تغذیه و برداشت از آبخوان‌ها شده است. این شرایط منجر به بیلان منفی آب زیرزمینی و مشکلات جبران‌ناپذیر دیگری می‌شود که مدیریت منابع آب را پیچیده‌تر می‌کند.

برای حفظ تعادل و بهبود شرایط آبخوان‌ها، لازم است تغییرات تراز آب زیرزمینی بررسی و مدل‌سازی شود. مدل‌سازی دقیق و مناسب می‌تواند ابزار ارزشمندی برای پیش‌بینی رفتار منابع آب زیرزمینی و تصمیم‌گیری بهینه در زمینه مدیریت منابع آب باشد.

ازاین‌رو، در این پژوهش تلاش می‌شود با استفاده از روش‌های نوین مدل‌سازی، تغییرات تراز آب زیرزمینی به‌طور دقیق پیش‌بینی شده و ابزارهای لازم برای مدیریت بهینه این منابع فراهم گردد.

درخت تصمیم یکی از ابزارهای پشتیبانی از تصمیم‌گیری است که از درخت‌ها برای مدل‌سازی استفاده می‌کند. این ابزار به‌طور گسترده در تحقیقات و عملیات‌های مختلف کاربرد دارد و به‌ویژه در تحلیل تصمیم برای تعیین استراتژی‌های مؤثر به‌کار می‌رود. درخت‌های تصمیمی به‌صورت قواعد IF-THEN بیان می‌شوند و در مسائلی که پاسخ‌ها به‌صورت دسته‌بندی‌های مشخص هستند، کاربرد دارند (Culter et al., 2007).

جنگل تصادفی یکی از روش‌های مؤثر برای تخمین متغیرهای هدف و طبقه‌بندی الگوها است. این روش گروهی از درخت‌های تصمیم است که به‌طور مکرر پیش‌بینی‌های متعددی از یک پدیده انجام می‌دهد. نتایج پیش‌بینی از ترکیب این درخت‌ها حاصل می‌شود و دقت بالایی در تحلیل‌ها فراهم می‌آورد (Culter et al., 2007).

این سامانه‌ها برای تبدیل پایگاه‌های دانش به نگاشت‌های غیرخطی طراحی شده‌اند و در کاربردهای مختلف مهندسی و تصمیم‌گیری به‌ویژه در محیط‌های پیچیده و با عدم قطعیت مورد استفاده قرار می‌گیرند. الگوریتم‌های فازی مبتنی بر منطق فازی است (Zadeh, 1965).

در سال‌های اخیر مدل‌های هوشمند مختلفی برای پیش‌بینی تراز آب زیرزمینی و شبیه‌سازی‌های مرتبط در ایران مورد استفاده قرار گرفته‌اند. در این راستا، عراقی نژاد و کارآموز (۱۳۸۴) از شبکه‌های عصبی مصنوعی و سامانه استنتاج فازی برای پیش‌بینی رواناب زاینده‌رود استفاده کردند. این تحقیق نشان داد که مدل‌های مذکور می‌توانند پیش‌بینی‌هایی با دقت قابل‌قبول ارائه دهند و به‌ویژه در پیش‌بینی بلندمدت، توانایی خوبی از خود نشان دادند.

میرزایی و ناظمی (۱۳۹۰) از روش‌های استنتاج فازی عصبی- تطبیقی و شبکه‌های عصبی برای تخمین تراز سطح ایستابی دشت شبستر استفاده کردند. نتایج تحقیق آن‌ها نشان داد که این روش‌ها در تخمین سطح ایستابی آب زیرزمینی توانایی بالایی دارند.

هاشمی و همکاران (۱۳۹۰) نیز با استفاده از سامانه استنتاج فازی به ارزیابی کیفیت آب زیرزمینی در استان اصفهان پرداختند. نتایج آن‌ها نشان داد که سامانه استنتاج فازی قادر است کیفیت آب را در سطح مطلوب، قابل‌قبول و نامطلوب دسته‌بندی کند.

در تحقیقی دیگر، احمدی و همکاران (۱۳۹۳) با استفاده از برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان (SVM) به پیش‌بینی جریان رودخانه باراندوزچای پرداخته‌اند. نتایج این تحقیق نشان داد که روش SVM ساده‌تر و کارآمدتر از برنامه‌ریزی ژنتیک است.

روزبهانی و ابراهیمی (۱۳۹۵) با تلفیق مدل‌های خوشه‌بندی و شبکه بیزین پیش‌بینی سطح آب زیرزمینی دشت بیرجند را انجام دادند و به این نتیجه رسیدند که این مدل برای مدیریت منابع آب بسیار کارآمد است.

اکبرزاده و همکاران (۱۳۹۵) نیز با استفاده از شبکه عصبی مصنوعی به پیش‌بینی تراز آب زیرزمینی دشت شاهرود پرداختند. این تحقیق نشان داد که شبکه عصبی به‌خوبی قادر به پیش‌بینی تغییرات تراز آب زیرزمینی در این منطقه است.

در تحقیق دیگری، تقی‌زاده و فریدونی (۱۳۹۶) از مدل‌های موجک - سامانه استنتاج فازی عصبی و موجک - شبکه عصبی برای شبیه‌سازی تراز آب زیرزمینی دشت ارسنجان استفاده کردند. نتایج نشان داد که سامانه استنتاج فازی عصبی به‌طور مؤثرتری از شبکه عصبی می‌تواند پیش‌بینی‌هایی دقیق‌تر ارائه دهد.

نوروزی و ندیری (۱۳۹۷) با استفاده از مدل‌های منطق فازی، جنگل تصادفی و شبکه عصبی به پیش‌بینی سطح آب زیرزمینی دشت بوکان پرداخته و دریافتند که مدل جنگل تصادفی دقت بیشتری در پیش‌بینی تراز سطح ایستابی دارد.

دانشوروثوقی و منافیان‌آذر (۱۳۹۷) نیز از مدل‌های ترکیبی ماشین بردار پشتیبان - موجکی و شبکه عصبی - موجکی در پیش‌بینی تراز آب زیرزمینی دشت اردبیل استفاده کردند. نتایج این تحقیق نشان داد که استفاده از تبدیل موجک دقت مدل‌ها را به‌طور قابل‌ملاحظه‌ای افزایش می‌دهد.

با توجه به بحران آب در بسیاری از نقاط دنیا، به‌ویژه در کشورهایی مانند ایران که با کمبود منابع آب شیرین مواجه هستند، اهمیت مدیریت بهینه منابع آب زیرزمینی بیش از پیش احساس می‌شود. آب‌های زیرزمینی به‌عنوان یکی از منابع اصلی تأمین آب برای مصارف مختلف، ازجمله کشاورزی، شرب و صنعت، نقش کلیدی در تأمین نیازهای روزمره جوامع دارند. در همین راستا، استفاده صحیح و پایدار از این منابع نیازمند ارزیابی دقیق و پیش‌بینی وضعیت آن‌ها در آینده است. یکی از چالش‌های اصلی در این زمینه، عدم تعادل میان تغذیه و برداشت منابع آب زیرزمینی است که می‌تواند منجر به مشکلات زیست‌محیطی و اجتماعی مانند نشست زمین، افت کیفیت آب، و بحران‌های آبی گردد. بنابراین، انجام پژوهش‌های جامع برای شبیه‌سازی و مدل‌سازی رفتار منابع آب زیرزمینی، نه‌تنها درک بهتری از وضعیت فعلی آن‌ها ارائه می‌دهد، بلکه ابزارهای مدیریتی مؤثری برای مقابله با چالش‌های آینده فراهم می‌آورد.

هدف اصلی این تحقیق، تحلیل و مدل‌سازی تغییرات تراز آب زیرزمینی در مناطق مختلف ایران است. این مطالعه به بررسی عوامل مؤثر بر کاهش سطح آب‌های زیرزمینی و پیش‌بینی روند آن‌ها در آینده پرداخته و راهکارهایی برای مدیریت بهینه این منابع ارائه می‌دهد. به‌ویژه، مدل‌سازی تغییرات تراز آب با استفاده از داده‌های دقیق و روش‌های نوین می‌تواند به شبیه‌سازی و پیش‌بینی اثرات مختلفی همچون برداشت بی‌رویه، تغییرات اقلیمی، و تغییرات در بارندگی‌ها کمک کند. علاوه بر این، این تحقیق سعی دارد تا ارزیابی‌هایی از نحوه تأثیرگذاری تغییرات ناشی از این عوامل بر روی سطح آب‌های زیرزمینی و نیازهای آبی کشاورزی، صنعت و شرب ارائه دهد.

در مطالعات هیدرولوژیکی و هیدروژئولوژیکی، بسیاری از پژوهش‌ها به تحلیل و مدل‌سازی منابع آب زیرزمینی پرداخته‌اند. یکی از مهم‌ترین مفاهیم در این زمینه، بیلان آب است که تفاوت میان ورودی‌ها و خروجی‌های آب در یک منطقه خاص را مشخص می‌کند. درحالی‌که بیشتر مطالعات به بیلان آب و تغییرات سطح آب در مقیاس‌های زمانی کوتاه‌مدت تمرکز دارند، این تحقیق سعی دارد تا مدل‌های دقیقی برای پیش‌بینی رفتار بلندمدت منابع آب زیرزمینی ایجاد کند. به‌منظور دستیابی به این هدف، از روش‌های عددی و آماری برای شبیه‌سازی تغییرات آبخوان‌ها و

ارزیابی میزان اثرگذاری عوامل مختلف همچون بهره‌برداری بی‌رویه، تغییرات دمایی و بارش استفاده خواهد شد. این پژوهش با ارائه مدل‌های پیشرفته، امکان ارزیابی و پیش‌بینی دقیق‌تر وضعیت منابع آب زیرزمینی در آینده را فراهم می‌آورد و مبنای تصمیم‌گیری‌های بهینه در زمینه مدیریت منابع آب خواهد بود.

## مواد و روش‌ها

این پژوهش شامل معرفی منطقه مطالعاتی و تشریح مراحل انجام تحقیق، همراه با استفاده از مدل‌های هوش مصنوعی برای شبیه‌سازی و پیش‌بینی تراز آب زیرزمینی است. مطابق فلوچارت شکل ۳-۱، ابتدا داده‌های مربوط به پارامترهای مؤثر شامل میانگین تراز آب زیرزمینی، دما، تبخیر، نوسانات سطح آب، برداشت از چاه‌ها، و میزان بارش جمع‌آوری شدند. از این داده‌ها، ۷۰ درصد برای آموزش مدل‌ها و ۳۰ درصد برای آزمون استفاده شد. مدل‌های درخت تصمیم، جنگل تصادفی و سامانه استنتاج فازی با سناریوهای مختلف آموزش و ارزیابی شدند تا مدل برتر با معیارهای مناسب‌تر انتخاب گردد.

### منطقه موردمطالعه

منطقه تالش در شمال غرب استان گیلان قرار دارد و بین رشته‌کوه‌های البرز و دریای مازندران واقع شده است. موقعیت جغرافیایی محدوده در شکل ۱ مشخص شده است. این منطقه شامل دشت‌های جلگه‌ای و کوهستانی است که ارتفاع آن از ۲۶- متر در کرانه دریای خزر تا ۳۲۹۰ متر در ارتفاعات تغییر می‌کند.

### موقعیت جغرافیایی

تالش بین طول‌های شرقی ۴۸°۳۰' تا ۴۹°۱۰' و عرض‌های شمالی ۳۷°۳۰' تا ۳۸°۳۰' قرار دارد. ارتفاع متوسط منطقه ۱۰۴۳ متر است (شکل ۱)

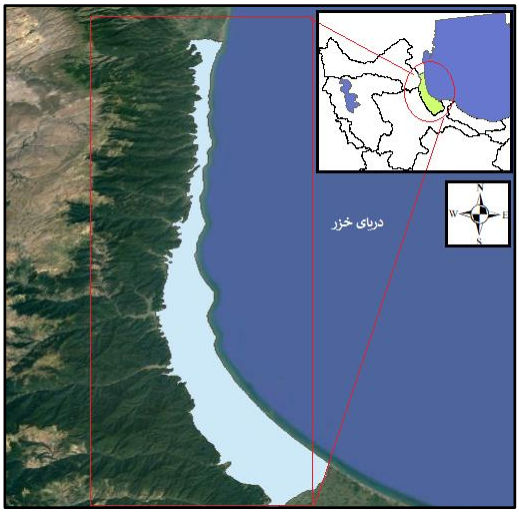


**شکل ۱- موقعیت محدوده مطالعاتی تالش**

### وضعیت آب زیرزمینی

دشت تالش با مساحت ۵۰۵ کیلومترمربع ۱۵,۷ درصد از محدوده را شامل می‌شود. جریان آب زیرزمینی عمدتاً از غرب به شرق است و تغییرات شیب جریان به‌تفصیل در متن بیان شده است.

### چاه‌های مشاهداتی

تراز آب زیرزمینی توسط ۵۴ چاه مشاهداتی بررسی شده است (شکل ۲). از میان این چاه‌ها، دو چاه اردجان و بوره‌سرا برای شبیه‌سازی انتخاب شدند.

### بهره‌برداری از آبخوان

برداشت سالانه از آبخوان تالش حدود ۱۱۸ میلیون مترمکعب است (شکل ۳). با وجود تعداد زیاد چاه‌ها، مقدار برداشت توسط هر چاه محدود است.

### بارش

میانگین بارش ماهانه در منطقه ۷۱ میلی‌متر است که بیشترین مقدار آن در فصول پاییز و بهار رخ می‌دهد. نوسانات بارندگی در شکل ۴ و جدول ۱ ارائه شده است.

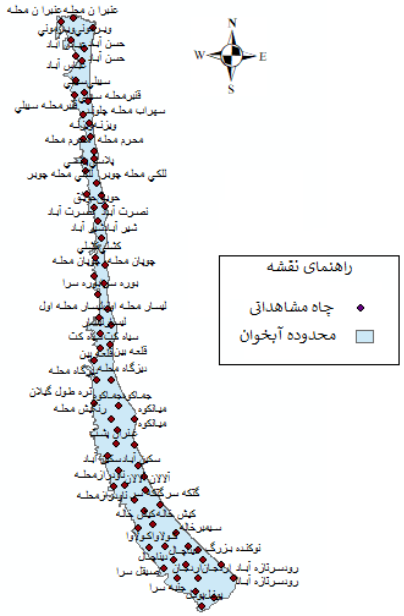


| پارامتر آماری | مقادیر (دما) |
|---|---|
| کمترین | -۲/۴ |
| میانگین | ۱۲/۶۲ |
| بیشترین | ۲۴/۱۵ |
| انحراف معیار | ۶/۶ |

**شکل ۲- موقعیت محدوده مطالعاتی تالش**

**جدول ۱- خلاصه پارامترهای آماری بارش**

**دما**

پارامتر دما مستقیماً بر تراز آب زیرزمینی تأثیر ندارد اما بر نیاز آبی و برداشت از چاه‌ها اثرگذار است. تحلیل دما برای ارزیابی اقلیم منطقه ضروری است. جدول ۲ خلاصه ای از پارامترهای دمای منطقه را ارائه می‌دهد.

شکل ۳ فلوچارت مراحل پژوهش را نشان می‌دهد. داده‌های ۱۴ ساله از شرکت آب منطقه‌ای گیلان تهیه شده و برای تحلیل سناریوها و مدل‌سازی استفاده شده است.

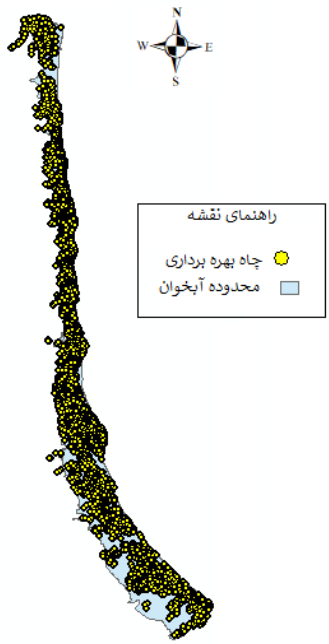


**شکل ۳- موقعیت چاه‌های بهره‌برداری آبخوان تالش**

**جدول ۲- خلاصه پارامترهای آماری دما**

تبخیر از عوامل کلیدی در محاسبات بیلان آبی است که محاسبه آن به دلیل هزینه تجهیزات موردنیاز،

| پارامتر آماری | مقادیر (بارش) |
|---|---|
| کمترین | ۰ |
| میانگین | ۷۱/۱۶ |
| بیشترین | ۲۸۱/۶ |
| انحراف معیار | ۴۶/۷۰ |

اغلب دشوار است. یکی از روش‌های رایج اندازه‌گیری تبخیر، استفاده از تشت تبخیر است که تأثیر عواملی نظیر تشعشع، باد، حرارت، و رطوبت را در شرایط هواشناسی ایستگاه موردنظر اندازه‌گیری می‌کند.

**جدول ۳- خلاصه پارامترهای آماری تبخیر**

در دشت مورد مطالعه، تبخیر از تشت بین ۰ تا ۲۵۱ میلی‌متر در ماه متغیر بوده و میانگین ماهانه آن در طول دوره آماری حدود ۹۰ میلی‌متر است. خلاصه پارامترهای آماری تبخیر در جدول ۳ ارائه شده است. همچنین، سری زمانی داده‌های تبخیر در ماه‌های مختلف طی دوره آماری در ادامه نمایش داده شده است.

## درخت تصمیم

روش درخت تصمیم نخستین بار در سال ۱۹۶۳ توسط مورگان و سانکویست معرفی شد و در سال ۱۹۸۶ با الگوریتم ID3 توسط Ross Quinlan توسعه یافت. نسخه پیشرفته‌تر این روش با نام C4.5 نیز بعدها ارائه شد. درخت تصمیم ابزاری برای پیش‌بینی کلاس اشیا بر اساس ویژگی‌های آن‌هاست که نتیجه آن به‌صورت یک مدل درختی نمایش داده می‌شود. این مدل به

| پارامتر آماری | مقادیر (تبخیر) |
|---|---|
| کمترین | ۰ |
| میانگین | ۹۰ |
| بیشترین | ۲۵۱ |
| انحراف معیار | ۵۵/۷۱ |

دلیل قابلیت تبدیل به قوانین "اگر-آنگاه"، خوانایی بالایی دارد و برای تحلیل داده‌ها بسیار مفید است.

الگوهای بارش، تبخیر و دمای منطقه مورد بررسی در شکل‌های ۴-۶ نشان داده شده است.

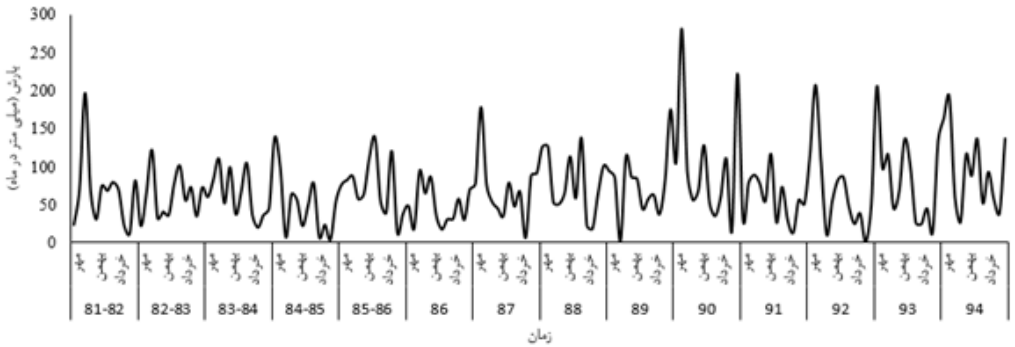


**شکل ۴- الگوی بارش ماهیانه در دشت مورد مطالعه.**

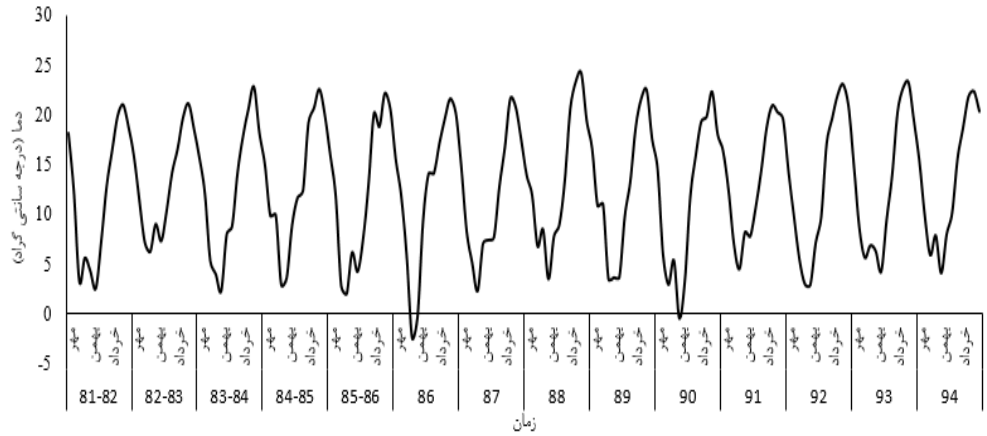


**شکل ۵- الگوی دمای ماهیانه در دشت مورد مطالعه.**

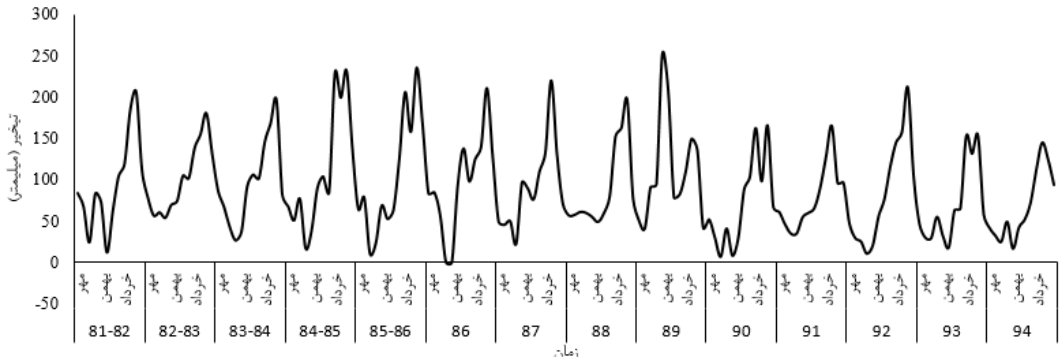


**شکل ۶- الگوی تبخیر ماهیانه در دشت مورد مطالعه.**

**درخت تصمیم**

روش درخت تصمیم نخستین بار در سال ۱۹۶۳ توسط مورگان و سانکویست معرفی شد و در سال ۱۹۸۶ با الگوریتم ID3 توسط Ross Quinlan توسعه یافت. نسخه پیشرفته‌تر این روش با نام C4.5 نیز بعدها ارائه شد. درخت تصمیم ابزاری برای پیش‌بینی کلاس اشیا بر اساس ویژگی‌های آن‌هاست که نتیجه آن به‌صورت یک مدل درختی نمایش داده می‌شود. این مدل به دلیل قابلیت تبدیل به قوانین "اگر-آنگاه"، خوانایی بالایی دارد و برای تحلیل داده‌ها بسیار مفید است.

درخت تصمیم مزایای بسیاری دارد، از جمله اینکه برای تقریب توابع گسسته بسیار مناسب است و در برابر نویز داده‌ها مقاوم عمل می‌کند. همچنین، برای داده‌های حجیم به‌صورت کارآمد عمل کرده و به دلیل ارائه قوانین به‌صورت if-then، درک و تفسیر نتایج را ساده می‌کند. این روش حتی در شرایطی که داده‌ها

ناقص باشند نیز قابل استفاده است. با وجود این مزایا، محدودیت‌هایی نیز دارد. برای مثال، برخی از الگوریتم‌های درخت تصمیم تنها به دسته‌بندی‌های دودویی محدود هستند و امکان استفاده از توابع کرنل در آن‌ها وجود ندارد. همچنین، دقت این روش با افزایش تعداد کلاس‌ها کاهش می‌یابد و در مواردی که نیاز به بررسی همزمان چندین ویژگی باشد، ممکن است عملکرد محدودی داشته باشد.

الگوریتم ID3 برای ساخت درخت تصمیم از رویکردی حریصانه استفاده می‌کند و درخت را به‌صورت چرخشی از بالا به پایین ایجاد می‌کند. این الگوریتم با استفاده از معیارهایی مانند آنتروپی و بهره اطلاعات، بهترین ویژگی‌ها را برای دسته‌بندی انتخاب کرده و داده‌ها را به‌صورت بازگشتی تقسیم می‌کند. روند ساخت درخت تا زمانی ادامه می‌یابد که تمام نمونه‌های موجود در یک گره به یک دسته مشخص تعلق گیرند یا دیگر مشخصه‌ای برای ادامه دسته‌بندی وجود نداشته باشد.

در ادامه توسعه این روش، جنگل تصادفی به‌عنوان یک تکنیک پیشرفته‌تر معرفی شد. جنگل تصادفی که توسط بریمن در سال ۲۰۰۱ معرفی شد، ترکیبی از چند درخت تصمیم مستقل است که هر یک با نمونه‌برداری تصادفی از داده‌ها ساخته می‌شود. استفاده از این روش دقت پیش‌بینی را بهبود می‌بخشد، چرا که انتخاب تصادفی ویژگی‌ها باعث کاهش همبستگی میان درخت‌ها و افزایش دقت می‌شود. این تکنیک از ساختار Bagging بهره می‌برد، به این صورت که هر درخت با استفاده از مجموعه داده‌های آموزشی تصادفی ایجاد می‌شود. این روند تصادفی‌سازی، علاوه بر افزایش دقت، سرعت عملکرد الگوریتم را نیز بهبود می‌بخشد. شکل ۷ مجموعه‌ای از درختان تصمیم‌گیری در یک مدل گروهی را نشان داده است.

الگوریتم مراحل انجام پژوهش نیز در شکل ۸ نمایش داده شده است.

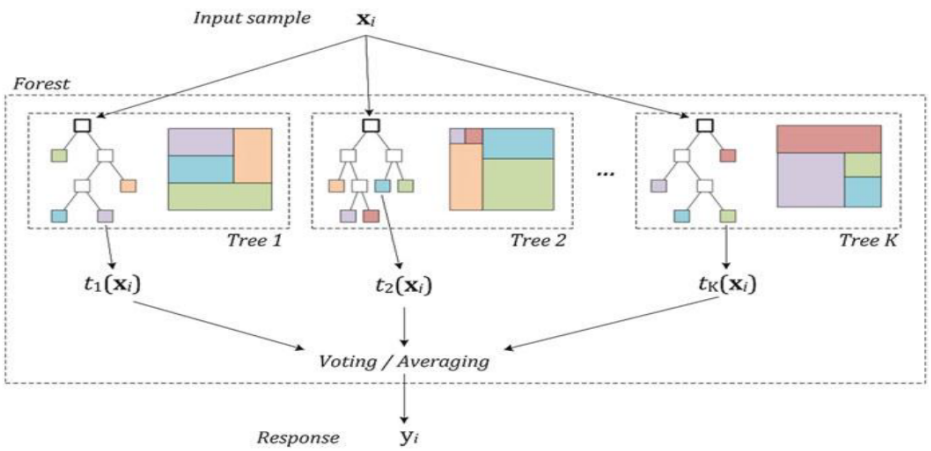


**شکل۷- مجموعه‌ای از درختان تصمیم‌گیری در یک مدل گروهی**

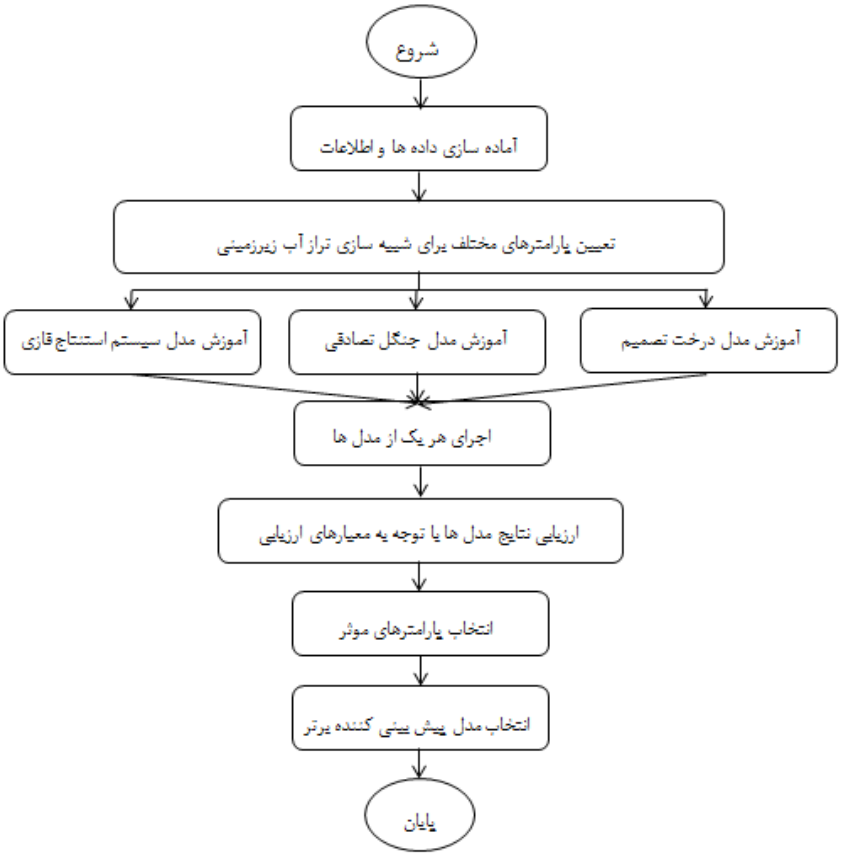


**شکل ۸- الگوریتم مراحل انجام پژوهش**

**سامانه استنتاج فازی**

پدیده‌های دنیای واقعی اغلب با پیچیدگی و عدم قطعیت همراه هستند و نمی‌توان آن‌ها را با عبارات دقیق توصیف کرد. در چنین شرایطی، استفاده از عبارات فازی و تقریبی می‌تواند مفید باشد. منطق فازی، که در سال ۱۹۶۵ توسط پروفسور لطفی زاده معرفی شد، روشی برای فرموله کردن دانش بشری به صورت سیستماتیک و بیان آن در قالب روابط ریاضی ارائه می‌دهد. این روش به‌ویژه در زمینه‌هایی که با عدم قطعیت بالا مواجه هستند، کاربرد گسترده‌ای دارد. سامانه استنتاج فازی، فرآیندی سیستماتیک برای تبدیل یک پایگاه دانش به یک نگاشت غیرخطی فراهم می‌کند و از این رو در تصمیم‌گیری و کاربردهای مهندسی مورد استفاده قرار می‌گیرد. این سامانه با استفاده از مجموعه‌ای از قوانین فازی، ارتباط بین متغیرهای ورودی و خروجی را در نواحی مشخصی از فضای ورودی شرح می‌دهد.

**تابع عضویت**

تابع عضویت، میزان فازی بودن یک پارامتر و درجه تعلق آن به یک مجموعه را تعیین می‌کند. این تابع مقادیری بین صفر (عدم تعلق) و یک (تعلق کامل) دارد و به مجموعه‌های فازی ارزش می‌دهد. مفهوم تابع عضویت در نظریه مجموعه‌های فازی اهمیت ویژه‌ای دارد، زیرا تمام اطلاعات مربوط به یک مجموعه فازی از طریق این تابع ارائه می‌شود. تابع عضویت هر عضو از مجموعه را به درجه‌ای بین ۰ و ۱ نگاشت می‌کند و معمولاً عناصر با درجه عضویت صفر نشان داده نمی‌شوند.

**مراحل و اجزای سامانه استنتاج فازی**

سامانه استنتاج فازی بر مبنای قواعد "اگر-آنگاه" طراحی شده و به‌عنوان ابزاری برای مدل‌سازی شرایط دارای عدم قطعیت بالا استفاده می‌شود، جایی که روش‌های کلاسیک مانند رگرسیون قادر به مدیریت مناسب این عدم قطعیت‌ها نیستند. این سامانه شامل سه بخش اصلی است:

فازی‌سازی: در این مرحله، مقادیر ورودی عددی با استفاده از توابع عضویت به مقادیر فازی تبدیل می‌شوند. این فرآیند اولین گام در سامانه‌های فازی است و میزان فازی بودن متغیرها را تعیین می‌کند.

پایگاه داده‌ها: این بخش شامل پایگاه قواعد و موتور استنتاج فازی است. قواعد مرتبط با گزاره‌های فازی در پایگاه قواعد تعریف شده و تحلیل پارامترها توسط موتور استنتاج فازی انجام می‌شود. برای استنتاج از روش‌هایی مانند ممدانی یا سوگنو استفاده می‌شود. در شکل ۹ اجزای تشکیل‌دهنده سامانه استنتاج فازی نشان داده شده است.

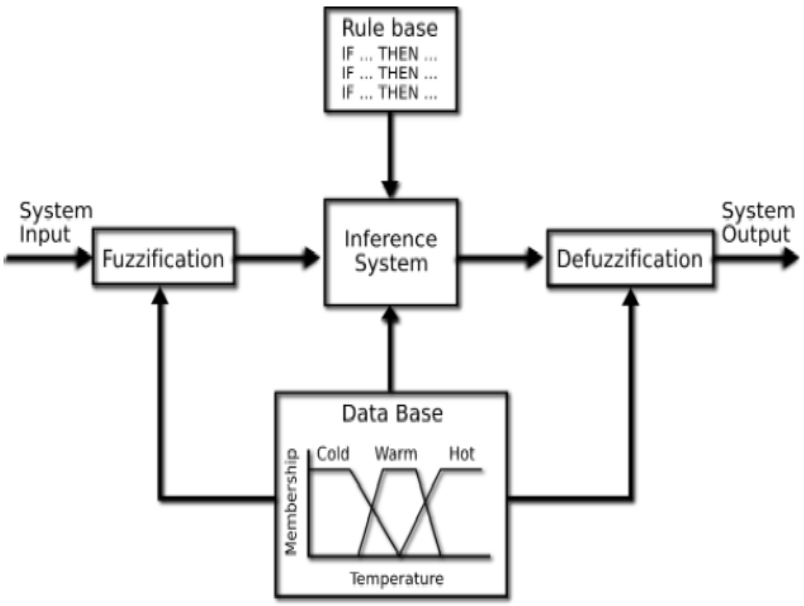


**شکل ۹- اجزای تشکیل‌دهنده سامانه استنتاج فازی.**

غیرفازی‌سازی: خروجی فازی سامانه به یک مقدار عددی تبدیل می‌شود. این مرحله با استفاده از الگوریتم‌های غیرفازی‌سازی صورت می‌گیرد.

این سه بخش به‌صورت هماهنگ برای تولید خروجی نهایی در سامانه‌های استنتاج فازی عمل می‌کنند.

**روش‌های فازی‌سازی**

در بسیاری از کاربردها، ورودی و خروجی سامانه‌های فازی به صورت اعداد حقیقی تعریف می‌شوند. به همین دلیل، لازم است واسطه‌هایی بین محیط و موتور استنتاج فازی وجود داشته باشند که این نقش را فازی‌سازها و غیرفازی‌سازها ایفا می‌کنند. فازی‌سازها وظیفه تبدیل مجموعه‌های ورودی حقیقی به مجموعه‌های فازی را بر عهده دارند. یکی از روش‌های دقیق تعریف تابع عضویت، استفاده از فرمول‌های ریاضی است که توسط فازی‌سازها انجام می‌شود. انواع مختلف این روش‌ها بسته به نیاز سامانه و ویژگی‌های مورد نظر، انتخاب و اعمال می‌شوند.

## نتایج و بحث

در این تحقیق، عملکرد مدل‌های یادگیری ماشین برای پیش‌بینی سطح آب زیرزمینی با استفاده از متغیرهای ورودی شامل سطح آب ماه قبل، برداشت از آب زیرزمینی، بارش، دما، و تبخیر مقایسه شد. این متغیرها به توابع عضویت فازی مثلثی تقسیم‌بندی شده و قوانین فازی برای تعیین خروجی تدوین گردیدند (شکل‌های ۱۰-۱۲). ترکیب قوانین، مقادیر خروجی را مشخص کرد و معیارهای خطا (RMSE و MAE) برای ارزیابی دقت مدل‌ها استفاده شد.

### نتایج الگوی A

برای الگوی A، متغیرهای ورودی شامل تمام پارامترهای اصلی بود. مدل فازی توانست برای چاه اردجان RMSE معادل ۰,۷۱۵ متر و MAE معادل ۰,۴۰۵ متر را ارائه دهد (جدول ۴). سری‌های زمانی داده‌های مشاهداتی و شبیه‌سازی‌شده برای داده‌های آموزش تطابق خوبی داشتند، اما در داده‌های آزمون تخمین‌ها در برخی ماه‌ها به‌ویژه برای چاه بوسرا ضعیف‌تر بود.

نتایج ترسیم سری زمانی داده‌های آموزش و آزمون برای الگوی A در شکل ۱۳ و ۱۴ نشان داده شده است.

**جدول ۴- تدوین الگوهای مختلف ورودی جهت انتخاب بهترین ترکیب از بین پارامترهای ورودی**

| نام الگو | سطح آب ماه قبل | برداشت از آب زیرزمینی | بارش | دما | تبخیر | پارامتر خروجی |
|---|---|---|---|---|---|---|
| A | ✓ | ✓ | ✓ | ✓ | ✗ | سطح آب انتهای ماه موجود |
| **B** | ✓ | ✓ | ✗ | ✓ | ✓ | |
| C | ✓ | ✓ | ✓ | ✗ | ✓ | |
| D | ✓ | ✗ | ✓ | ✓ | ✓ | |
| E | ✗ | ✓ | ✓ | ✓ | ✓ | |
| F | ✓ | ✓ | ✓ | ✓ | ✓ | |

**نتایج الگوی B**

در الگوی B، دما حذف و پارامتر تبخیر اضافه شد. این تغییر تأثیر اندکی بر دقت مدل داشت اما نتایج بهبود یافت. برای چاه اردجان RMSE برابر ۰,۴۱۹ متر و MAE برابر ۰,۲۷۲ متر به دست آمد (جدول ۵). سری‌های زمانی شبیه‌سازی‌شده و مشاهداتی تطابق بهتری نسبت به الگوی A داشتند، اما همچنان تفاوت‌هایی در برخی ماه‌ها مشاهده شد. نتایج ترسیم سری زمانی داده‌های آموزش و آزمون برای الگوی B در شکل ۱۵ و ۱۶ نشان داده شده است.

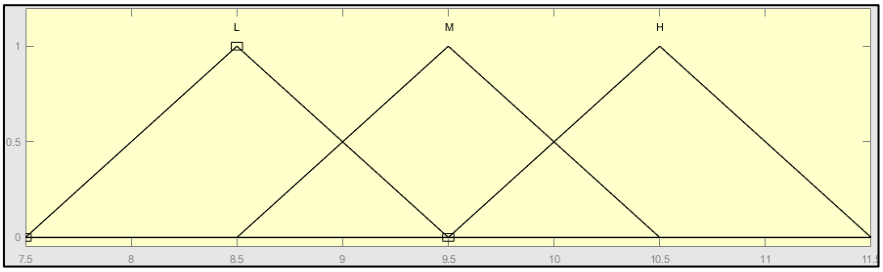


**شکل ۱۰- تابع عضویت مثلثی سطح آب زیرزمینی ماهانه**

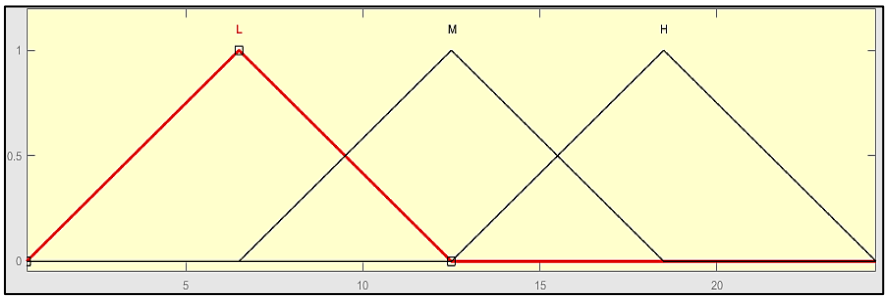


**شکل ۱۱- تابع عضویت مثلثی برداشت از آب زیرزمینی ماهانه**

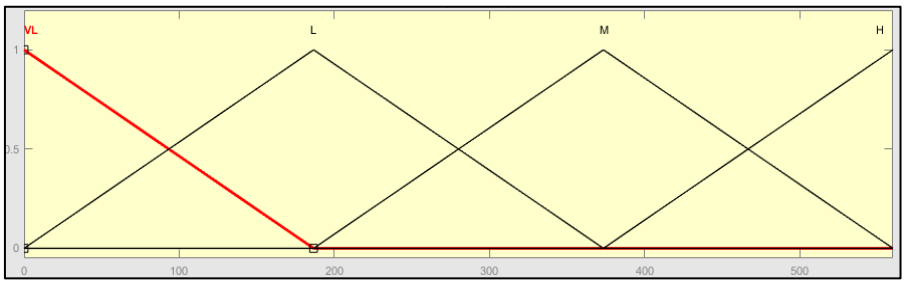


**شکل ۱۲- تابع عضویت مثلثی بارش ماهانه**

**نتایج الگوی C**

در الگوی C، دما حذف شد تا تأثیر این متغیر بررسی شود. RMSE برای چاه اردجان برابر با ۰,۳۸۹ متر و

برای چاه بوسرا برابر با ۰,۴۵۷ متر بود که نشان‌دهنده کاهش نسبی خطا بود (جدول 5). سری‌های زمانی این الگو نشان داد که حذف دما تأثیر محسوسی بر پیش‌بینی مدل نداشته است (شکل‌های ۱۷ و۱۸).

در مجموع، تغییر ترکیب متغیرهای ورودی تأثیر محدودی بر دقت پیش‌بینی‌ها داشت. الگوی C کمترین خطا را ارائه داد و در عین حال قوانین ساده‌تری برای پیش‌بینی‌ها تدوین شد، که به کاهش پیچیدگی مدل کمک کرد

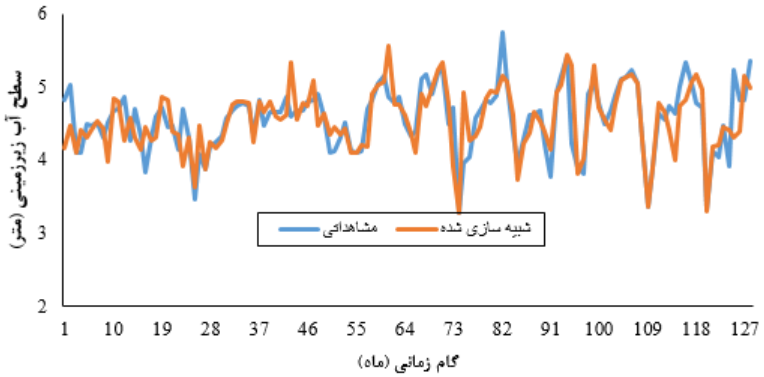


(الف)

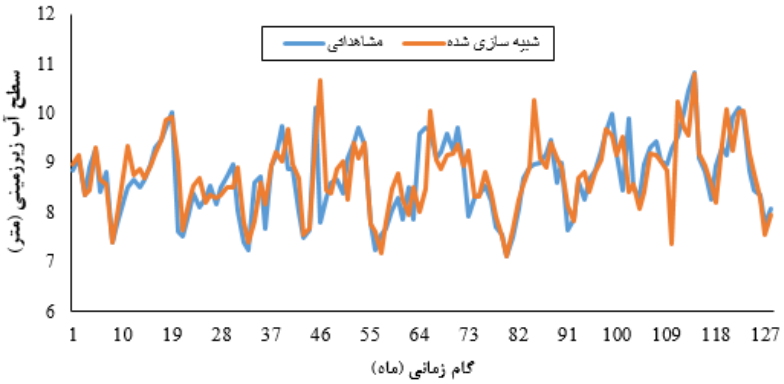


(ب)

**شکل ۱۳- سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آموزش، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

(الف)

(ب)

**شکل۱۴-سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آزمون، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

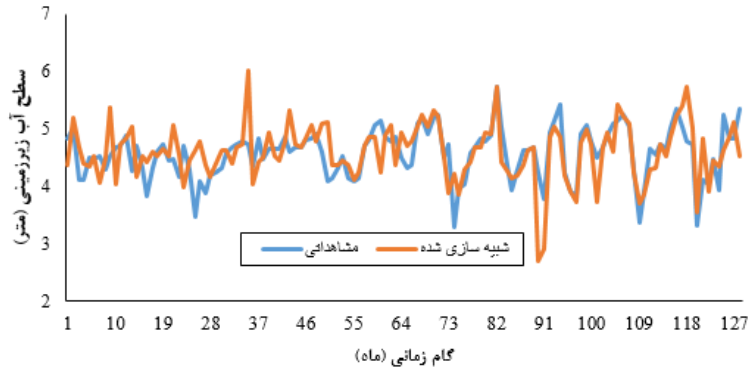


(الف)

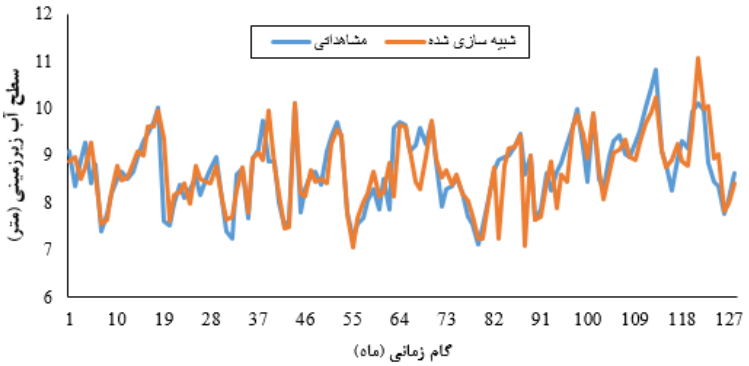


(ب)

**شکل ۱۵- سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آموزش، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

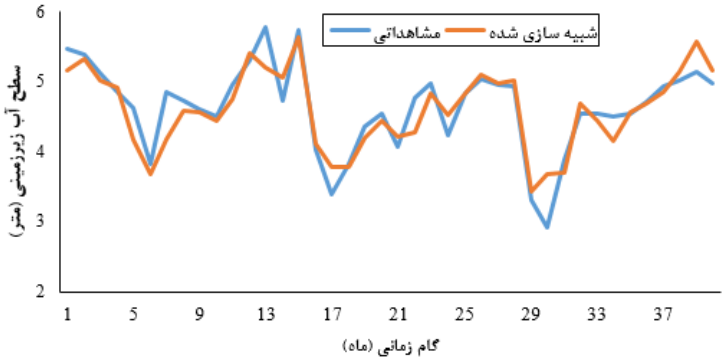


(الف)

(ب)

**شکل 16-سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آزمون، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

## نتایج الگوی D

در این الگو پارامترهای ورودی سطح آب ماه قبل، بارش، دما و تبخیر به عنوان پارامترهای ورودی در نظر گرفته‌شده است. به‌مانند سایر الگوهای موردبررسی شده نیز دو نمونه چاه مشاهداتی که به‌صورت تصادفی انتخاب گردیده بود به عنوان چاه‌های مشاهداتی هدف جهت شبیه‌سازی سطح آب آن‌ها استفاده گردید. ازآنجایی‌که سامانه استنتاج فازی از قوانین اگر-آنگاه برای پیش بینی مقادیر خروجی استفاده می‌کند لذا نمونه قوانینی که به‌کاررفته شده به شرح زیر می‌باشد اگر سطح آب ماه قبل کم، بارش کم، دما و تبخیر نیز کم باشد آنگاه سطح آب زیرزمینی انتهای ماه کم باشد. اگر سطح آب ماه قبل بیشتر، بارش متوسط، دما و تبخیر نیز کم باشد آنگاه سطح آب زیرزمینی انتهای ماه متوسط باشد. اگر سطح آب ماه قبل متوسط، بارش کم، دما و تبخیرنیز بیشتر باشد آنگاه سطح آب زیرزمینی انتهای ماه بیشتر باشد. نتایج ترسیم سری زمانی داده‌های آموزش و آزمون برای الگوی D در شکل ۱۹ و ۲۰ نشان داده شده است.

(الف)

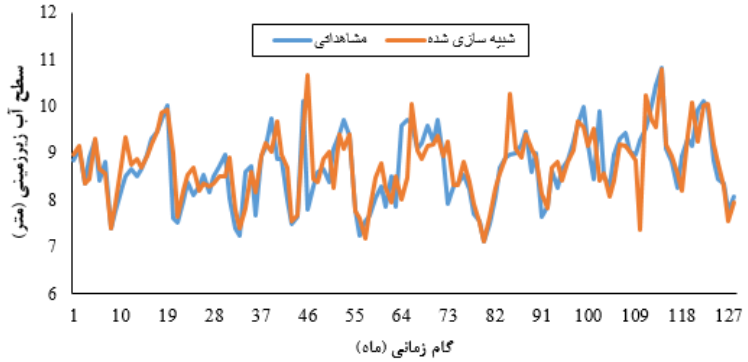


(ب)

**شکل 17- سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آموزش، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

(الف)

(ب)

**شکل 18-سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آزمون، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

این قوانین باهم ترکیب می‌شوند و از ترکیب آن‌ها مقدار خروجی نمایش داده می‌شود.

نتایج معیارهای ارزیابی خطا برای هر دو چاه و برای مدل سامانه استنتاج فازی مطابق جدول ۴-۶ می‌باشد. معیارهای ارزیابی نشان می‌دهد که مدل سامانه استنتاج فازی در الگوی D قادر به پیش‌بینی سطح آب با مقدار RMSE برابر ۰/۴۸۹ متر و MAE برابر ۰/۳۳۰ متر برای داده‌های آزمون چاه مشاهداتی اردجان می‌باشد. به‌طور مشابه و برای چاه مشاهداتی بوره سرا نیز معیارهای ارزیابی خطا به ترتیب برابر ۰/۴۱ و ۰/۲۹۸ متر به دست آمد. درنتیجه می‌توان گفت دقت این الگو برای چاه مشاهداتی بوره سرا بیشتر از چاه مشاهداتی اردجان بوده است. جمع بندی نتایج مدل‌های به کار رفته در جدول ۵ نشان داده شده است.

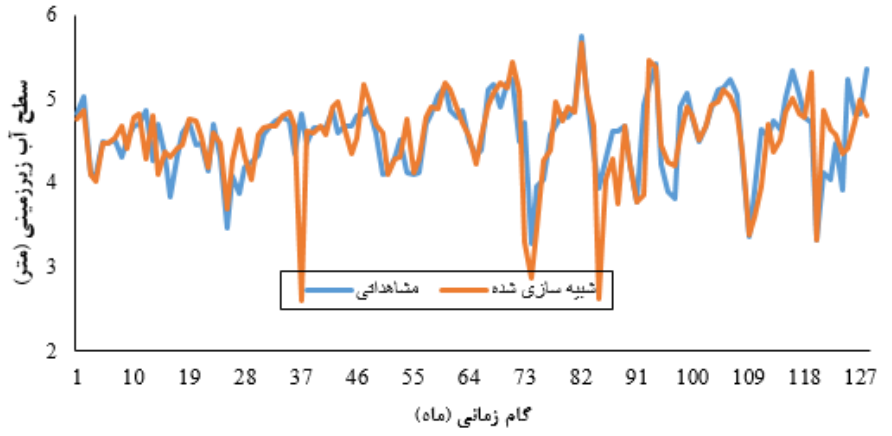


(الف)

(ب)

**شکل 19- سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آموزش، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

(الف)

(ب)

**شکل 20-سری زمانی مشاهداتی و شبیه‌سازی‌شده برای داده‌های آزمون، الف: چاه مشاهداتی اردجان، ب: چاه مشاهداتی بوره سرا**

**جدول ۵- جمع بندی نتایج مدل‌های به کار رفته**

| مدل | الگوی ورودی | چاه مشاهداتی | RMSE (متر) | | MAE (متر) | |
|---|---|---|---|---|---|---|
| | | | آموزش | آزمون | آموزش | آزمون |
| DT | C | اردجان | ۰/۲۳۹ | ۰/۴۵۷ | ۰/۱۸۵ | ۰/۳۷۲ |
| | B | بوره سرا | ۰/۵۰۱ | ۰/۵۱۱ | ۰/۳۷۸ | ۰/۴۱۰ |
| FR | C | اردجان | ۰/۱۲۷ | ۰/۴۴ | ۰/۰۹ | ۰/۳۵ |
| | C | بوره سرا | ۰/۲۶ | ۰/۴۴ | ۰/۱۹ | ۰/۳۵ |
| FIS | C | اردجان | ۰/۳۳۴ | ۰/۴۹۰ | ۰/۱۹۷ | ۰/۳۸۹ |

| | | | | | |
|---|---|---|---|---|---|
| C | بوره سرا | ۰/۳۶۴ | ۰/۵۱۳ | ۰/۲۴ | ۰/۴۱۴ |

مطابق جدول ۵ در مدل درخت تصمیم الگوهای C و B به عنوان مناسب ترین الگو انتخاب شدند. الگوی C برای چاه مشاهداتی اردجان و الگوی B برای چاه مشاهداتی بوره سرا مناسب ارزیابی شد. چنانچه در سایر مدل‌های به کار رفته در این تحقیق برای هر دو چاه مشاهداتی مذکور الگوهای وردی C مناسب ارزیابی شدند. در نتیجه می‌توان الگوی C را به عنوان مناسب‌ترین الگو انتخاب کرد.

## جمع‌بندی

این پژوهش با هدف ارائه یک مدل هوشمند برتر برای شبیه‌سازی تراز آب زیرزمینی از بین سه مدل مختلف شامل درخت تصمیم، جنگل تصادفی، و سامانه استنتاج فازی انجام شد. رویکرد تحقیق بر ترکیب متغیرهای ورودی متنوع و مؤثر متمرکز بود تا بهترین ترکیب شناسایی شود. متغیرهای ورودی شامل سطح آب زیرزمینی در این ماه، بارش ماهانه، برداشت آب از آبخوان، تبخیر ماهانه، و دمای ماه موردنظر بود، درحالی‌که متغیر خروجی، تراز آب زیرزمینی انتهای ماه بود. این مدل‌ها بر روی آبخوان تالش و دو چاه مشاهداتی آزمایش شدند و نتایج زیر حاصل شد:

هر سه مدل مورد بررسی توانستند رفتار تغییرات تراز آب زیرزمینی را با دقت قابل قبولی شبیه‌سازی کنند. در این میان، مدل جنگل تصادفی به‌عنوان بهترین مدل انتخاب شد، زیرا با کمترین میزان خطا قادر بود تغییرات تراز آب زیرزمینی را پیش‌بینی کند. همچنین، شش الگوی طراحی‌شده برای هر مدل نشان دادند که قابلیت شبیه‌سازی تغییرات تراز آب زیرزمینی را به‌خوبی دارند. در مدل سامانه استنتاج فازی، افزایش تعداد متغیرهای ورودی باعث افزایش تعداد قوانین فازی و در نتیجه پیچیدگی مدل شد. با این حال، تابع عضویت مثلثی توانست تغییرات تراز آب زیرزمینی را با توجه به متغیرهای ورودی با دقت خوبی شبیه‌سازی کند.

مدل‌های توسعه‌یافته در این پژوهش نه‌تنها توانایی شبیه‌سازی تراز آب زیرزمینی در آبخوان تالش را داشتند، بلکه می‌توانند برای سایر آبخوان‌ها نیز به‌کار گرفته شوند. همچنین، مدل نهایی تدوین‌شده می‌تواند جایگزینی مناسب برای مدل‌های مفهومی در شبیه‌سازی تراز آب زیرزمینی باشد. با توجه به یافته‌های این پژوهش، موارد ذیل برای تحقیقات آتی پیشنهاد می‌شود. اضافه‌کردن متغیرهای دیگری مانند دبی رودخانه به‌عنوان ورودی برای بهبود شبیه‌سازی تراز آب زیرزمینی. استفاده از توابع عضویت متنوع مانند ذوزنقه‌ای، گوسی، و زنگوله‌ای برای افزایش دقت مدل‌های فازی. و بهره‌گیری از مدل‌های هوشمند دیگر مانند شبکه بیزین و شبکه‌های عصبی موجک برای شبیه‌سازی تراز آب زیرزمینی و مقایسه نتایج آن‌ها با یافته‌های این پژوهش.

در این تحقیق هدف جمع‌بندی نتایج مدل‌های مختلف و الگوی انتخاب شده توسط هر مدل است تا بتوان به یک مدل برتر به همران مناسب ترین الگوی که حاکی از ترکیب مناسب الگوهای ورودی است، دست یافت. با این توصیف و مطابق جدول ۵ در مدل درخت

تصمیم الگوهای C و B به عنوان مناسب ترین الگو انتخاب شدند که الگوی C برای چاه مشاهداتی اردجان و الگوی B برای چاه مشاهداتی بوره سرا مناسب ارزیابی شد. در حالی که در سایر مدل های به کار رفته در این تحقیق برای هر دو چاه مشاهداتی مذکور الگوهای وردی C مناسب ارزیابی شدند. در نتیجه می توان الگوی C را به عنوان مناسب‌ترین الگو انتخاب کرد که این الگو شامل مشارکت تمام پارامترهای ورودی به جز دما بود. در بین مدل‌ها نیز مدل جنگل تصادفی برای هر دو چاه مشاهداتی دارای بیشترین دقت از بین مدل‌ها بود به طوری که مقادیر RMSE، MAE برای چاه مشاهداتی اردجاه به ترتیب برابر ۰/۴۴ و ۰/۳۵ متر و برای چاه مشاهداتی بوره سرا به ترتیب ۰/۴۳ و ۰/۳۲ بدست آمد. در نتیجه با در اختیار داشتن مقادیر پارامترهای موجود در الگوی C و با توجه به مدل جنگل تصادفی می توان به پیش‌بینی تراز آب زیرزمینی پرداخت. در حالت کلی و با توجه به نتایج مدل ها می توان به عنوان نتیجه کلی به ترتیب مدل های جنگل تصادفی، درخت تصمیم و سامانه استنتاج مناسب این تحقیق رتبه بندی شدند. مدل‌های توسعه‌یافته در این پژوهش نه‌تنها توانایی شبیه‌سازی تراز آب زیرزمینی در آبخوان تالش را داشتند، بلکه می‌توانند برای سایر آبخوان‌ها نیز به‌کار گرفته شوند. همچنین، مدل نهایی تدوین‌شده می‌تواند جایگزینی مناسب برای مدل‌های مفهومی در شبیه‌سازی تراز آب زیرزمینی باشد. با توجه به یافته‌های این پژوهش، موارد ذیل برای تحقیقات آتی پیشنهاد می‌شود. اضافه‌کردن متغیرهای دیگری مانند دبی رودخانه به‌عنوان ورودی برای بهبود شبیه‌سازی تراز آب زیرزمینی. استفاده از توابع عضویت متنوع مانند ذوزنقه‌ای، گوسی، و زنگوله‌ای برای افزایش دقت مدل‌های فازی. و بهره‌گیری از مدل‌های هوشمند دیگر مانند شبکه بیزین و شبکه‌های عصبی موجک برای شبیه‌سازی تراز آب زیرزمینی و مقایسه نتایج آن‌ها با یافته‌های این پژوهش.

## مراجع

اکبرزاده، ف، حسن پور، ح.، امامقلی زاده. (۱۳۹۵). پیش‌بینی تراز آب زیرزمینی دشت شاهرود استفاده از شبکه عصبی مصنوعی تابع پایه شعاعی. (پژوهشنامه مدیریت حوزه آبخیز (علمی-پژوهشی، ۷(۱۳)، ۱۱۸-۱۰۴.

بانژاد، ح، محب زاده، ح، قبادی، م، حیدری، م. (۱۳۹۲). شبیه‌سازی عددی جریان و انتقال آلودگی در آبهای زیرزمینی مطالعه موردی: آبخوان دشت نهاوند. دانش آب و خاک،(۲)۲۳،۴۳-۵۷.

پوستی زاده ن،نجفی ن. (۱۳۹۰). مقایسه کاربرد شبکه عصبی مصنوعی باسیستم استنتاج فازی در پیش‌بینی جریان رودخانه زاینده‌رود. تحقیقات منابع آب ایران. سال هفتم،شماره۲. ص ۹۲-۹۷.

تقی زاده، سید عبدالرسول و مهرداد فریدونی، ۱۳۹۶، شبیه‌سازی تراز سطح آب زیرزمینی با بکارگیری دو روش موجک - سیستم استنتاج فازی عصبی (ANFIS) و موجک - شبکه عصبی (MPL) و مقایسه آن‌ها با یکدیگر. (مطالعه موردی دشت ارسنجان)، کنفرانس بین المللی عمران،معماری و شهرسازی ایران معاصر، تهران، دانشگاه اسوه - تهران - دانشگاه شهید

بهشتی، https://www.civilica.com/Paper-CICEAUD01-CICEAUD01_0259.html

حسامی رستمی، ر،افشارع، موسوی ج. (۱۳۸۴). مدل پیش‌بینی سیلاب بااستفاده ازسیستم استنتاج فازی-عصبی تطبیقی ومقایسه آن باروش رگرسیونه مثال موردی رودخانه کرخه. مجموعه مقالات اولین کنفرانس سالانه مدیریت منابع آب ایران. تهران

زارع، د، (۱۳۹۸)، استفاده از روش شبکه عصبی مصنوعی در پیش‌بینی تراز آب زیرزمینی(مطالعه موردی: دشت مرودشت-خرامه)، پایان نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد مرودشت.

صداقت،م. (۱۳۸۷). زمین ومنابع آب (آبهایزیرزمینی). چاپاول. انتشارات دانشگاه پیام نور.۲۸۸

صفوی،ح ر. (۱۳۹۰). هیدرولوژی مهندسی.چاپ سوم.انتشارات ارکان دانش.۷۲۴ ص.

کوره‌پزان دزفولی الف. (۱۳۹۴). اصول تئوری مجموعه‌های فازی و کاربرد های آن در مدل‌سازی مسائل مهندسی آب. جهاد دانشگاهی واحد صنعتی امیرکبیر. ۱-۲۰۹

معینی ح،بنکداری و عبداللهی ص. ۱۳۹۵. ارزیابی عملکردبرخی مدل های آماری و محاسبات نرم در پیش بینی جریان رودخانه. تحقیقات منابع آب ایران. سال ۱۲، شماره ۳، ص: ۲۰۶-۲۰۱.

ناشاد، مجید. ۱۳۹۶. بررسی روش بیان ژن در برآورد سطح آب زیرزمینی با استفاده از نرم افزار GENE XPRO TOOLS، پایان نامه کارشناسی ارشد، دانشگاه بیرجند.

هاشمی الف،موسوی ف. (۱۳۸۹). ارزیابی کیفیت آب زیرزمینی ۹ شهراستان اصفهان برای مصارف شرب با استفاده ازسیستم استنتاج فازی. تحقیقات منابع آب ایران. سال ششم،شماره ۳. ص ۲۵-۳۴.

Aguilera, P. A., Fernández, A., Fernández, R., Rumí, R., & Salmerón, A. (2011). Bayesian networks in environmental modelling. Environmental Modelling & Software, 26(12), 1376-1388.

Amaranto, A., Corzo Perez, G., Solomatine, D., Meyer, G., & Munoz-Arriola, F. (2017). Data Driven Models to Forecast Groundwater Level in Response to Hydro-climatological Conditions and Agricultural Water Demand. EGUGA, 13155.

ASANO, A., Support vector machine and kernel method, Pattern information processing (2004 Autumn Semester) Session 12 (۲۱ .۱ .۰۵)

ASCE Task Committee on Application of the Artificial Neural Networks in Hydrology, “Artificial Neural Networks in Hydrology, II: Hydrologic Applications”, Journal of Hydrological Engineering, Vol. 5, No. 2, pp. 124-137, 2000b

BERWICK, An Idiot's guide to Support vector machines (SVMs)

Bierkens MFP (1998) Modeling water table fluctuations by means ofa stochastic differential equation. Water Resour Re34:2485–2499.

Birgani, Y. T. and Yazdandoost, F. 2015. Resilience in urban drainage risk management

Karimi, S; Kisi, O; Shiri, J and Makarynskyy, O. 2013. Nwuro- Fuzzy and neural network techniques for forecasting sea level in Darwin Harbor, Australia Computers & Geosciences. 52: 50-59.

Kasiviswanathan, K. S., Saravanan, S., Balamurugan, M., & Saravanan, K. (2016). Genetic programming based monthly groundwater level forecast models with uncertainty quantification. Modeling Earth Systems and Environment, 2(1), 27.

Kaya, Y. Z., Üneş, F., Demirci, M., Taşar, B., & Varçin, H. (2018). Groundwater level prediction using artificial neural network and M5 tree models. Aerul si Apa. Componente ale Mediului, 195-201.

Kisi, O; Shiri, J and Nikoofar, B. 2012. Forecasting daily lake level using artificial intelligence approaches Computers & Geosciences. 41: 169-180.

Knotters M, Bierkens MFP (2000) Physical basis of time seriesmodels for water table depths. Water Resour Res 36:181–188.

Konikow, L. F. and Kendy, E. "Groundwater depletion: a globalproblem". Hydrogeology Journal, 131(2005): 317–320.

Langeroudi M.R, Kerachian R. 2014. Developing Operating Rules for Conjunctive Use of Surface and Groundwater Considering the Water Quality Issues. KSCE Journal of Civil Engineering (2014) 18(2):454-461.

Lawrence, G., Pieters, R., Zaremba, L., Tedford, T., Gu, L., Greco, S., & Hamblin, P. (2004). Summer exchange between Hamilton harbour and Lake Ontario. Deep Sea Research systems. Proceedings of the Institution of Civil Engineers-Water Management. pp. 3-16. Thomas Telford Ltd.

BURGES, Christopher J. C., A Tutorial on Support Vector Machines for Pattern Recognition, 1998.

C.Huang and C. Wang, "A GA-based feature selection and parameters optimizationfor support vectormachines,"Expert systems with applications, vol. 31, pp. 231-240, 2006.

Chang, L.-C., Chu, H.-J. and Chen, Y.-W. 2013. A fuzzy inference system for the conjunctive use of surface and subsurface water. Advances in Fuzzy Systems, 2013: 2.

Cheng, J., Bell, D., & Liu, W. (1998). Learning Bayesian networks from data: An efficient approach based on information theory. On World Wide Web at http://www. cs. ualberta. ca/~ jcheng/bnpc. htm.

Coppola, E; Szidarovszky, F; Poulton, M and Charles, E. 2003. Artificial Neural Network Approach for Predicting Transient Water Levels in a Multi Layered Groundwater System under Variable State. Pumping, and Climate Conditions, Hydrologic Engineering. 8 (6): 348-360.

Coulibaly, P; Anctil, F; Aravena, R and Bobée, B. 2001. Artificial Neural Network Modeling of Water Table Depth Fluctuations. Water Resources Research, 37(4): 885-896.

Gehreles, JC; Van Geer, FC and de Vries, JJ. 1994. Decomposition of groundwater level fluctuation using transfer modeling in an area with shallow to deep unsaturated zones. Journal of Hydrology: 157:105-138.

Part II: Topical Studies in Oceanography, 51(4-5), 475-48.

Li, H., Lu, Y., Zheng, C., Yang, M., & Li, S. (2019). Groundwater level prediction for the arid oasis of northwest China based on the artificial bee colony algorithm and a back-propagation neural network with double hidden layers. Water, 11(4), 860.

Lohani, A. K., Goel, N. and Bhatia, K. 2014. Improving real time flood forecasting using fuzzy inference system. Journal of Hydrology, 509: 25-41.

Lohani, A. K., Goel, N. and Bhatia, K. 2014. Improving real time flood forecasting using fuzzy inference system. Journal of Hydrology, 509: 25-41.

Mahapatra, S. S., Nanda, S. K. and Panigrahy, B. K. 2011. A cascaded fuzzy inference system for indian river water quality prediction. Advances in Engineering Software, 42: 787-796.

Milan, S. G., Roozbahani, A., & Banihabib, M. E. (2018). Fuzzy optimization model and fuzzy inference system for conjunctive use of surface and groundwater resources. Journal of Hydrology, 566, 421-434.

Sadat-Noori, M., Glamore, W., & Khojasteh, D. (2020). Groundwater level prediction using genetic programming: the importance of precipitation data and weather station location on model accuracy. Environmental Earth Sciences, 79(1), 37.

Sadeghravesh, M. H., Khosravi, H. and Ghasemian, S. (2015). Application of fuzzy analytical hierarchy process for assessment of combating-desertification alternatives in central Iran. Natural Hazards, 75(1), 653-667.

Sattari, M. T., Mirabbasi, R., Sushab, R. S., & Abraham, J. (2018). Prediction of groundwater level in Ardebil plain using support vector regression and M5 tree model. Groundwater, 56(4), 636-646.

Shiri J, Kisi O (2011) Comparison of genetic programming withneuro-fuzzy systems for predicting short-term water table depthfluctuations. Comput Geosci 37:1692–1701.

Shiri, J and Kisi, O. 2013. Comparison of Genetic Programing with neure- fuzzy systems for predicting short- Term water table depth fluctuations. Computer & Geoscience, 59: 216-220.

Shiri, J and Kisi, O. 2013. Comparison of Genetic Programing with neure- fuzzy systems for predicting short- Term water table depth fluctuations. Computer & Geoscience, 59: 216-220.

Srivastav RK, Sudheer KP, Chaubey I (2007) A simplified approachto quantifying predictive and parametric uncertainty in artificialneural network hydrologic models. Water Resour Res43:W10407. doi:10.1029/2006WR005352.

Wang, W.; Jin, J.; Li, Y. “Prediction of inflow at Three Gorges Damin Yangtze Riverwith wavelet network model”. Water Resources Management 23, 13(2009): 2791–2803.

Zahmatkesh, G.A; Alavi Panah, K and Zehtabian, G.R. 2001. Study of shallow groundwater table fluctuations of Playa margin, case study of Semnan. J. Des. 6: 2. 15-30.