

## شبیه‌سازی آب‌زیرزمینی با استفاده از سیستم هوش مصنوعی (مطالعه موردی: حوزه آبخیز کمه استان اصفهان)

روح اله سمیعی دستجردی<sup>۱</sup>، مهدی حیات زاده<sup>۲\*</sup>، علی فتح زاده<sup>۳</sup>، فرزانه فتوحی فیروزآباد<sup>۴</sup>

۱- دانش آموخته کارشناسی ارشد آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، اردکان، ایران.

۲- استادیار گروه مهندسی طبیعت، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، اردکان، ایران.

۳- دانشیار گروه مهندسی طبیعت، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، اردکان، ایران.

۴- استادیار گروه مهندسی طبیعت، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، اردکان، ایران.

\*نویسنده مسئول: [mhayatzadeh@ardakan.ac.ir](mailto:mhayatzadeh@ardakan.ac.ir)

تاریخ پذیرش مقاله: ۱۴۰۴/۰۱/۲۸

تاریخ دریافت مقاله: ۱۴۰۳/۰۶/۱۸

### چکیده

محدودیت منابع آب سطحی، تقاضای مصرف آب را به سمت استفاده از منابع آب زیرزمینی سوق داده است و برداشت از این منابع و عدم تغذیه آبخوان‌ها باعث افت سطح تراز آب‌های زیرزمینی گردیده است. از طرفی برای ارزیابی و مدیریت منابع آب در شرایط مخاطرات امروز و آینده نیاز به پیش‌بینی تراز آب‌های زیرزمینی می‌باشد. هدف از این پژوهش پیش‌بینی تراز آب زیرزمینی حوزه آبخیز کمه شهرستان سمیرم استان اصفهان با استفاده از سیستم هوش مصنوعی می‌باشد. در این راستا داده‌های مشاهداتی تراز آب زیرزمینی، بارش و دبی در مقیاس ماهانه با سری زمانی ۲۰ ساله (۱۳۹۸-۱۳۷۹) مورد استفاده قرار گرفت. در الگوریتم شبکه پرسپترون چند لایه (MLP) جهت بررسی قدرت پیش‌بینی و تأثیر ورودی‌ها از آرایش مختلف، تغییر وزن‌های ورودی، تغییر لایه‌ها و تعداد نرون‌ها استفاده شد. به منظور بررسی عملکرد مدل‌ها، از دو معیار جذر میانگین مربع خطا (RMSE) و ضریب تعیین ( $R^2$ ) استفاده گردید. به این منظور از ۷۵ درصد داده‌ها (۱۸۰ سری داده) برای آموزش شبکه و از ۲۵ درصد مابقی (۶۰ سری داده) به منظور ارزیابی و تست شبکه استفاده شد. براساس مقایسه جداول RMSE و R آرایش‌های مختلف، در پیش‌بینی تراز آب زیرزمینی حوضه مورد مطالعه، تأثیر بارش بیشتر از دبی می‌باشد و الگوریتم آموزش لونیبرگ مارکوارت با داشتن ضریب همبستگی ۰/۹۹ و جذر میانگین مربع خطا ۰/۰۰۴۷ عملکرد بهتری نسبت به سایرین دارد. نتایج ضمن تایید کارایی مناسب مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی تراز آب زیرزمینی نشان داد که استفاده از پارامترهای اقلیمی نسبت به پارامترهای هیدرولوژیکی جهت مدل‌سازی مقادیر کمی آب زیرزمینی در مدل شبکه عصبی مصنوعی دارای عملکرد بهتری می‌باشد. نتایج حاکی از آن است که در شبیه‌سازی تراز آب زیرزمینی با استفاده از شبکه عصبی مصنوعی، با توجه به وجود عدم قطعیت‌های متعدد در داده‌های ورودی به شبکه، انتخاب نوع و ساختار مدل از اهمیت ویژه‌ای برخوردار می‌باشد.

**کلیدواژه‌ها:** آب زیرزمینی، الگوریتم لونیبرگ مارکوارت، شبکه MLP، هوش مصنوعی.

### مقدمه

می‌روند که شناخت صحیح و بهره‌برداری اصولی از آن‌ها می‌تواند در توسعه پایدار فعالیت‌های اجتماعی و اقتصادی یک منطقه به‌ویژه مناطق خشک و نیمه‌خشک نقش به‌سزایی داشته باشد (یوسفی و همکاران، ۱۴۰۳). کاهش سطح آب زیرزمینی و تخلیه‌ی سفره‌های آب موجب کاهش آبدهی چاه‌ها، شور شدن آب چاه‌ها در اثر افزایش عمق و تجمع املاح، خشک شدن چاه‌های عمیق و نیمه عمیق و

آب به‌عنوان اصلی‌ترین ماده حیاتی برای بشر از اهمیت بالایی برخوردار است و محدودیت منابع آب سطحی مناسب، تقاضای مصرف آب به‌دلیل افزایش جمعیت و توسعه کشاورزی، انسان‌ها را به سمت بهره‌برداری از ذخائر آب زیرزمینی سوق داده است (نیک منش و همکاران، ۱۳۹۰). از طرفی منابع آب زیرزمینی یکی از مهم‌ترین و ارزان‌ترین منابع آب به شمار

تاکنون ضریب همبستگی بالاتری نسبت به روش‌های هوشمند به دست نداده‌اند، مقدار خطا در کل منطقه را به صورت یک مقدار واحد ارائه می‌دهند. از این رو، امروزه استفاده از روش‌های نوین و هوشمند مانند روش شبکه عصبی مصنوعی، مورد نظر قرار گرفته است. شبکه‌های عصبی مصنوعی، سیستم استنتاج فازی-عصبی و برنامه‌ریزی بیان ژن ابزاری قدرتمند جهت شبیه‌سازی فرآیندهای پیچیده و غیرخطی به شمار می‌روند که از جمله کارآمدترین ابزارهای پیش‌بینی پارامترها هستند (سراوانی و همکاران، ۱۴۰۲). شبکه‌های عصبی مصنوعی که از سال ۱۹۴۳ مطرح شده‌اند، از جمله روش‌های بهینه‌سازی هستند که بر مبنای سیستم عصبی موجودات زنده ابداع شده‌اند (Chen et al., 2009). همچنین، مدل شبکه عصبی مصنوعی قادر به درک روابط ضعیف هیدرولوژیک بوده، یک روش قدرتمند در تحلیل داده‌های واقعی است و می‌تواند الگو و رابطه مخفی بین داده‌ها را تشخیص داده، خود را آموزش دهد و با بالا بردن اطلاعات خود پیش‌بینی‌های مناسبی انجام دهد (Bunchingiv et al., 2003)، همچنین به دلیل قابلیت پیش-بینی دقیق می‌تواند، در استراتژی‌های مدیریت آب زیرزمینی به کار رود (Chang et al., 2015). محققان به این نتیجه رسیده‌اند که شبکه‌های عصبی مصنوعی می‌توانند جایگزین مناسبی برای روش‌های دیگر باشند (Emamgholizadeh et al., 2014). در پژوهشی جهت شبیه‌سازی تراز آب زیرزمینی دشت نیریز از ترکیب مدل‌های موجک و فازی عصبی استفاده شد. نتایج این تحقیق نشان داد که مدل تلفیقی Wavlet-ANFIS دقت بالایی در شبیه‌سازی تراز آب زیرزمینی دشت نیریز دارد (مبارکی و همکاران، ۱۳۹۴).

در پژوهش دیگری با مقایسه مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی در پیش‌بینی سطح آب زیرزمینی نورآباد به نتیجه رسیدند که دو مدل مورد استفاده با دقت قابل قبولی توانسته به تخمین تراز سطح ایستابی پردازد، در مجموع نتایج نشان داد که مدل شبکه عصبی موجک توانایی بالایی در تخمین مقادیر کمینه و بیشینه تراز سطح ایستابی دارد (باباعلی و همکاران، ۱۳۹۶). پژوهش‌های زیادی برای شبیه‌سازی آبخوان به کمک روش‌های هوش مصنوعی صورت گرفته است. حسینی صومعه و همکاران (۱۴۰۰) مدل‌سازی تغییرات سطح آب زیرزمینی براساس روش‌های مبتنی بر هوش مصنوعی را

نشست زمین می‌شود (زاهدی و همکاران، ۱۳۹۳). در دو دهه اخیر و به‌ویژه در سال‌های پایانی قرن بیستم، آب و مدیریت آن به یک دغدغه بزرگ بین‌المللی تبدیل شده است. تشکیل نشست‌های متعدد در سطوح ملی، منطقه‌ای و بین‌المللی در رده‌های مختلف کارشناسی، مدیریتی و سیاستی همه حاکمی از تشدید این نگرانی‌هاست (دلاور و همکاران، ۱۳۸۷). استان اصفهان نیز از این امر مستثنی نبوده و شاهد مشکلات زیادی در این زمینه می‌باشد. بدیهی است برای مدیریت منابع آب، داشتن اطلاعات صحیح و پیش‌بینی سطح تراز آب‌های زیرزمینی امری حیاتی است. در صورتی که هر چه سریع‌تر نسبت به برنامه‌ریزی و مدیریت منابع آب زیرزمینی اقدامی صورت نگیرد، شاهد تخریب بیشتر آبخوان‌ها، عدم تجدید و از دست دادن منابع آب زیرزمینی خواهیم بود (مختاری و همکاران، ۱۳۹۱).

امروزه استفاده از مدل‌های ریاضی نرم‌افزاری برای پیش و مدیریت آب‌های زیرزمینی توسعه چشم‌گیری یافته است و ابزاری برای مدیریت منابع آب فراهم نموده‌اند (چیت‌سازان و کشکویی، ۱۳۸۱)، از جمله این مدل‌ها که برای پیش‌بینی سطح آب زیرزمینی استفاده می‌شود، می‌توان به سری زمانی تجربی، مدل‌های فیزیکی، روش عکس مجذور فاصله و روش‌های زمین‌آماری اشاره کرد (Galavi et al., 2012). از مدل سری زمانی تجربی، به‌طور گسترده‌ای برای مدل‌سازی سطح آب زیرزمینی استفاده شده است، ولی هنگامی که رفتار دینامیکی یک سیستم هیدرولوژیک با گذشت زمان تغییر می‌کند مدل‌های یاد شده برای پیش‌بینی پارامترهای منابع آب توانایی کافی ندارند و مدل‌های مناسبی نیستند. از طرف دیگر، مدل‌های فیزیکی نیز در عمل به اطلاعات زیادی درباره روابط بین متغیرهای مؤثر بر تغییرات سطح آب زیرزمینی نیاز دارند و از آن‌جاکه روابط بین این متغیرها اغلب پیچیده و غیرخطی است و با توجه به فرضیات در نظر گرفته شده در مدل‌های فیزیکی، این مدل‌ها در این گونه موارد نمی‌توانند به خوبی عمل کنند (ملکی‌نژاد و همکاران، ۱۳۹۲). روش زمین‌آمار نیز اگرچه قادر به بیان توزیع مکانی خطای استاندارد تخمین در کل سطح منطقه است، در این روش، پردازش یک مدل ریاضی بر روی کل داده‌ها بسیار مشکل است (زارع ابیانه و همکاران، ۱۳۹۲). روش‌های عکس فاصله وزن‌دار هم علاوه بر این که

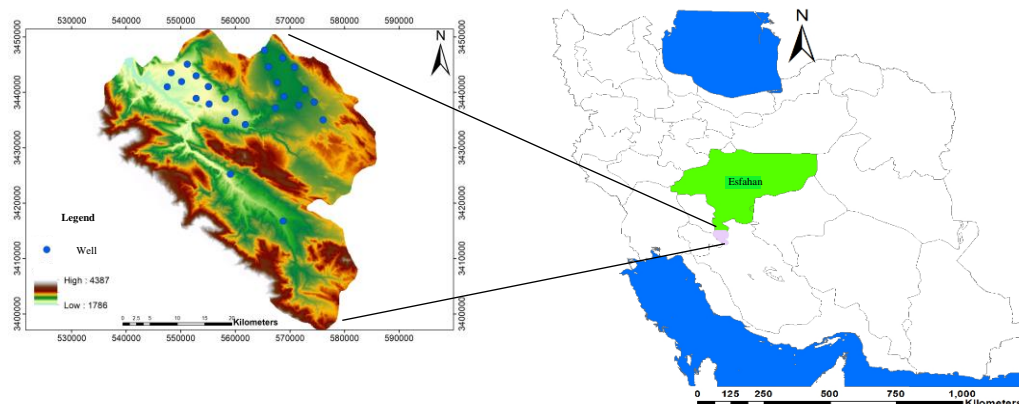
منابع آب زیرزمینی تاکنون در منطقه مورد مطالعه، تحقیقات زیادی به منظور تحلیل آب زیرزمینی انجام نشده است. در این تحقیق به منظور پیش‌بینی تراز آب زیرزمینی دشت کمه با استفاده از مدل شبکه عصبی مصنوعی به بررسی موضوع پرداخته شده است.

### مواد و روش‌ها منطقه مورد مطالعه

حوزه آبخیز کمه در جنوبی‌ترین نقطه استان اصفهان در ارتفاع ۲۵۰۰ متری از سطح دریا و در مختصات طول‌های جغرافیایی ۵۱ درجه ۲۰ دقیقه ۴۶ ثانیه تا ۵۱ درجه ۵۶ دقیقه ۴۱ ثانیه و عرض‌های جغرافیایی ۳۰ درجه ۴۱ دقیقه ۵۳ ثانیه تا ۳۱ درجه ۱۱ دقیقه ۵۰ ثانیه واقع است. این حوزه در کوه پایه‌های خاوری قله دنا (واقع در استان کهگیلویه و بویراحمد) قرار گرفته و منطقه‌ای سردسیر است. فاصله این حوزه از اصفهان ۲۰۰ کیلومتر و از مرکز شهرستان (شهر سمیرم) ۶۳ کیلومتری باشد. منطقه با مساحتی بالغ بر ۱۶۸۰ کیلومتر مربع در مرکز کشور ایران و جنوب استان اصفهان قرار دارد (مطالعات پایه سازمان آب منطقه‌ای اصفهان). متوسط دمای سالانه ۹/۳ درجه سانتی‌گراد، حداکثر مطلق دما در مرداد ماه و معادل ۳۹/۳ درجه سانتی‌گراد و حداقل مطلق دما در بهمن ماه و معادل ۲۳- درجه سانتی‌گراد می‌باشد. میانگین بارندگی سالانه منطقه ۶۲۲ میلی‌متر می‌باشد. در شکل ۱ موقعیت حوزه نشان داده شده است.

برای دشت زاوه انجام دادند. نتایج این تحقیق نشان داد که شبکه عصبی مصنوعی با دقت بالایی ( $R^2 = 0.99$ ) قادر به پیش‌بینی تراز سطح ایستابی می‌باشد. Adamowski et al., (2011) از شبکه عصبی موجک جهت پیش‌بینی سطح آب زیرزمینی حوزه چاتوگای واقع در کانادا در سال ۲۰۰۹-۲۰۰۲ استفاده نمودند و نشان دادند شبکه عصبی موجک پتانسیل بالایی در پیش‌بینی تراز آب زیرزمینی دارد و می‌تواند در مدیریت آب‌های زیرزمینی مفید باشد. همچنین روش‌های یادگیری ماشین به دلیل سرعت عمل بالا و نیاز به حجم داده‌های کم برای پیش‌بینی پارامترهای هیدروکلیماتولوژی، دبی رودخانه‌ها و نوسانات تراز آب زیرزمینی توسط محققین زیادی توصیه شده‌اند (نورمحمدی‌ده‌بالایی و همکاران، ۱۴۰۱. Paul et al., 2023، مرادی و همکاران، ۱۴۰۱. سامانی و همکاران، ۱۴۰۰ و پناهی و همکاران، ۱۴۰۰). نتایج تحقیقات انجام شده نشان می‌دهد اکثریت مدل‌های ریاضی به کار گرفته شده در هر آبخوان نیازمند تعریف شرایط مرزی جدید و اطلاعات و نقشه‌های مربوط به آن منطقه است و عملاً کاربردی نمودن مدل مستلزم انطباق آن با شرایط خاص منطقه مورد مطالعه است.

Lie et al., (2019) پیش‌بینی سطح آب زیرزمینی را در یک مجتمع گلخانه‌ای تحت تأثیر عوامل داخلی و انفعالی با استفاده از شبکه عصبی مصنوعی مورد بررسی قرار دادند. نتایج بررسی حاکی از دقت مناسب ضرایب آماری در پیش‌بینی می‌باشد. علی‌رغم وابستگی بسیاری از کاربری‌های موجود در منطقه به




شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه.  
Figure 1. Geographical location of the study area.

### ساختار شبکه

لذا در این تحقیق از شبکه عصبی پایه شعاعی استفاده شده است. شبکه‌های با تابع مدار شعاعی تقریب‌سازهای بسیار قدرتمندی هستند به طوری که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب‌سازی هر تابع پیوسته و با هر درجه دقت می‌باشند که از جمله آن‌ها شبکه‌های پیشرو همراه با سه لایه می‌باشد. نرون‌های خروجی ترکیبی خطی از تابع-های پایه‌ای را به وجود می‌آورد، که به وسیله نرون‌های لایه پنهان محاسبه شده‌اند (Fang et al., 2008). زمانی که ورودی در ناحیه تعیین شده کوچکی از فضای ورودی قرار می‌گیرد، توابع اساسی (غیرخطی) در لایه پنهان، پاسخ غیر صفری به محرک می‌دهند. معمول‌ترین تابع غیرخطی استفاده شده در این مدل تابع گوسی هستند.

شبکه به کار گرفته شده در این تحقیق، یک شبکه پرسپترون چندلایه (MLP) است که به صورت پیش‌خور عمل می‌کند. تعداد نرون‌های لایه ورودی متغیر می‌باشد که متعاقب آن‌ها ورودی‌های متغیری به شبکه القا خواهد شد و خروجی شامل یک نرون است که همان جریان مصنوعی تولید شده در روز می‌باشد، در لایه میانی نیز ۲۰ نرون وجود دارد (مهدوی زاده، ۱۳۸۳). نرون‌های لایه‌های میانی از توابع تبدیل تانژانت سیگموئید استفاده می‌کنند در لایه خروجی نیز از تابع تبدیل خطی استفاده شده است. روش به کار گرفته شده جهت آموزش شبکه، پس انتشار خطا می‌باشد. لازم به ذکر است که این روش آموزشی نیز در الگوریتم‌ها و فرم‌های متعددی ارائه شده است



شکل ۲- شبکه پرسپترون چند لایه (MLP).  
Figure 2. Multilayer Perceptron Network (MLP).

حوضه کمه به عنوان خروجی مدل در نظر گرفته شد. داده‌های موجود که شامل ۲۴۰ سری داده از اطلاعات بارندگی، دبی و سطح تراز آب چاه‌های دشت مورد مطالعه می‌باشند بدین صورت تفکیک گردیدند که دسته مربوط به آموزش شبکه که با آن وزن‌های شبکه تعیین می‌گردند. نکته‌ای که در انتخاب داده‌ها در مرحله آموزش مد نظر قرار گرفت، آن است که توزیع متوازنی از داده‌ها به مدل معرفی گردد و تا حد ممکن مقادیر ماکزیمم و مینیمم آنها در این گروه قرار گیرند. در این تحقیق تعداد ۱۸۰ سری داده در مرحله آموزش به کار گرفته شد. گروه دوم جهت تست شبکه و در واقع ارزیابی مدل شامل ۶۰ سری

### شبیه‌سازی تراز آب زیرزمینی با استفاده از شبکه عصبی مصنوعی

به منظور شبیه‌سازی تراز آب زیرزمینی دشت کمه سمیرم استان اصفهان با استفاده از شبکه‌های عصبی مصنوعی از ۴ سری نمونه داده‌های بارش و دبی استفاده گردید. طول داده-های آماری بین سال‌های ۱۳۷۹-۱۳۹۸ می‌باشد، در مرحله آموزش توابع محرک و الگوریتم‌های یادگیری مختلف مورد بررسی قرار گرفته و سپس شبکه آموزش دیده شده، صحت سنجی و تست گردید. اطلاعات به کار گرفته شده در کلیه مراحل آموزش، صحت‌سنجی و تست شبکه‌های عصبی شامل اطلاعات بارش و دبی به عنوان ورودی مدل و تراز آب چاه‌های

$$X_n \frac{x - x_{min}}{x_{man} - x_{min}} \quad (1)$$

که در آن:

$X_n$ : معرف داده‌های نرمال شده

$X$ : معرف داده‌های مشاهده ای خام

$X_{man}$ : معرف حداکثر داده‌های مشاهده‌ای خام

$X_{min}$ : معرف حداقل داده‌های مشاهده‌ای خام

### تست شبکه

در مدل‌های شبکه تحقیقات نشان داده است که یک شبکه ممکن است دچار آموزش اضافه شود. اگر فرایند آموزش خیلی طولانی باشد، ممکن است شبکه به سمت به حافظه سپردن برخی زوج‌های ورودی- خروجی برود. هنگامی که یک مجموعه از مقادیر ورودی جدید اعمال شود، شبکه زیاد آموزش دیده، متمایل به یادآوری یکی از بردارهای ذخیره شده می‌شود، در حالی که شبکه می‌بایستی قادر به تعمیم بردار خروجی و هر بردار ورودی داده شده را داشته باشد (Khaled et al., 2013). برای پرهیز از این حالت می‌توان قبل از اینکه شبکه شروع به بخاطر سپردن کند، آموزش را قطع کرد. فرایند تعمیم را می‌توان با اضافه کردن داده‌هایی با دقت کمتر به هر یک از بردارهای ورودی-خروجی در هر نوبت آموزش، ساده تر کرد. با استفاده از این روش، هیچگاه شبکه با زوج بردارهای دقیقاً مثل هم برای ورودی-خروجی آموزش نمی‌بیند و لذا شبکه نمی‌تواند الگوهای خاصی را به حافظه بسپارد.

### ارزیابی مدل

در شروع فرآیندهای ساخت مدل، تعریف معیارهای که عملکرد مدل با آنها سنجیده می‌شود از اهمیت خاصی برخوردار است، به طوری که این معیارها می‌توانند اثر معنی‌داری در معماری مدل و انتخاب تکنیک‌های وزن بهینه شبکه داشته باشند (نادری و همکاران، ۱۳۹۵). برای این منظور معیارهای ضریب کارایی و مجذور میانگین مربعات خطا برای صحت سنجی شبکه‌های طراحی شده مورد استفاده قرار گرفتند.

$$R^2 = 1 - \frac{\sum_{i=1}^n (Q - Q_p)^2}{\sum_{i=1}^n (Q - \bar{Q}_p)^2} \quad (2)$$

داده در نظر گرفته شد. در مدل شبکه‌های عصبی مصنوعی به‌منظور شبیه‌سازی، از سه تابع محرکه استفاده شد. تابع محرکه خطی (همانی)، تابع محرکه لگاریتم سیگموئید، تابع محرکه تانژانت هیپربولیک.

### آماده‌سازی و پیش‌پردازش داده‌ها

در این تحقیق اطلاعات تراز آب زیرزمینی حوضه مورد مطالعه از ۲۳ چاه پیژومتر آب منطقه‌ای جمع‌آوری گردید. اطلاعات هیدرولوژیکی از ایستگاه‌های هیدرومتری سرباز رودخانه ماربر و بند قدیمی رودخانه تنگ سحری و اطلاعات اقلیمی از دو ایستگاه باران‌سنجی سرباز و تنگ سحری و ایستگاه تبخیرسنجی حنا استفاده شد. در ابتدا از سطح تراز چاه‌های پیژومتر، سطح تراز آب زیرزمینی حوضه به صورت ماهیانه استخراج گردید. سپس جهت رفع نقص داده‌های بارش با استفاده از داده‌های دو ایستگاه بارانسنجی خارج از حوضه از روش تفاضل‌ها و نسبت‌ها داده‌های مفقودی یا گم تکمیل شد. کلیه داده‌های آماری بین سال‌های ۱۳۷۹-۱۳۹۸ به صورت ماهیانه مرتب شدند. این داده‌ها که شامل ۲۴۰ سری داده از اطلاعات بارندگی، دبی و سطح تراز آب چاه‌های دشت مورد مطالعه بود، نرمال شدند. ۷۵ درصد داده‌ها برای آموزش مدل و ۲۵ درصد برای صحت‌یابی و ارزیابی مدل مورد استفاده قرار گرفت. جدول ۱ مشخصات آماری داده‌های ورودی مدل را نشان می‌دهد.

جدول ۱- مشخصات آماری داده‌های ورودی مدل.

Table 1- Statistical characteristics of model input data.

Annual average	Maximum 24 hours	Length of statistical period (years)	Parameter
352	96	20	(mm) Rain
9.8	163	20	Discharge (m <sup>3</sup> /s)

### نرمال سازی داده‌ها

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای دوری از چنین شرایطی و همچنین به‌منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی صورت می‌گیرد که این کار مانع از کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌گردد (بروجردی و همکاران، ۱۳۹۴). در این تحقیق برای نرمال کردن از رابطه ۱ استفاده شده است.

صفر نزدیک‌تر باشد، نمایانگر اختلاف کمتری بین آن‌ها خواهد بود. RMSE به صورت رابطه ۳ تعریف می‌شود.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q - Q_p)^2}{n}} \quad (3)$$

که در آن؛ n: تعداد داده‌ها می‌باشد.

### نتایج و بحث

#### نتایج آرایش‌ها

در این مطالعه به منظور دستیابی به الگوریتم و ساختار مناسب شبکه سناریوهای مختلفی در نظر گرفته شده که در جدول ۲ نشان داده شده است.

جدول ۲- سناریوهای مختلف مدل.

Table 2- Different model scenarios.

Model output	Model input structure	Scenario
Groundwater level	Precipitation and water level data with a one-month delay	Structure 1
Groundwater level	Water level data with a one-month delay	Structure 2
Groundwater level	Precipitation data with one- and two-month lags, balance data with one- and two-month lags	Structure 3
Groundwater level	Precipitation and streamflow data with a one-month delay	Structure 4

در آرایش ۳ داده‌های بارش (P) و تراز آب (W)، با تأخیر یک ماهه (P-1) (W-1) و تأخیر دو ماهه (P-2) (W-2) به عنوان ورودی (Input) و داده‌های تراز آب به عنوان Target در نظر گرفته شدند.

در آرایش ۴ نیز داده‌های بارش (P) و دبی (Q)، با تأخیر یک ماهه (P-1) (Q-1) به عنوان ورودی (Input) و داده‌های تراز آب به عنوان Target در نظر گرفته شدند.

که در آن Q مقادیر بر مشاهده ای و Qp مقادیر پیش بینی شده توسط شبکه و  $\bar{Q}_p$  میانگین مقادیر پیش‌بینی شده و n تعداد داده‌ها در مرحله صحت‌سنجی می‌باشند. هر چه ضریب کارایی R<sup>2</sup> به یک نزدیک باشد؛ نشان‌دهنده نزدیک‌تر بودن مقادیر مشاهده و محاسبه شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است. مجذور میانگین مربعات خطا یک شاخص کمی مناسب که می‌توان از آن در برآورد میزان دقت مدل استفاده کرد، مجذور میانگین مربعات خطا (RMSE) می‌باشد. این معیار، دقت مدل را براساس تفاضل بین مقادیر واقعی و مقادیر پیش‌بینی شده، ارزیابی می‌کند و طبیعتاً هر چه به

#### آرایش ۱: (Input=W-1, P-1), (Target=W)

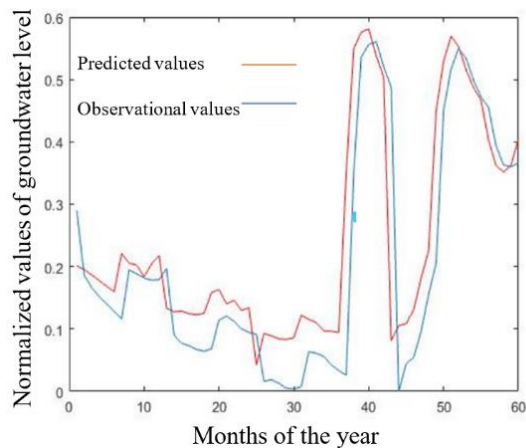
در آرایش ۱ داده‌های بارش (P) و داده‌های تراز آب (W)، با تأخیر یک ماهه (P-1) و (W-1) به عنوان ورودی (Input) و داده‌های تراز آب به عنوان Target در نظر گرفته شدند (جدول ۳). شکل ۳ مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی موجود در مدت ۶۰ ماه (صحت‌سنجی) را نشان می‌دهد. شکل ۴ نیز خطوط برازشی مدل را در شرایط مختلف آموزش و آزمون شبکه را در اولین مدل از آرایش اول را نشان می‌دهد. در آرایش ۲ داده‌های تراز آب (W)، با تأخیر یک ماهه (W-1) به عنوان ورودی (Input) و داده‌های تراز آب به عنوان Target در نظر گرفته شدند.

جدول ۳- نتایج آرایش ۱.

Table 3. Results of arrangement 1.

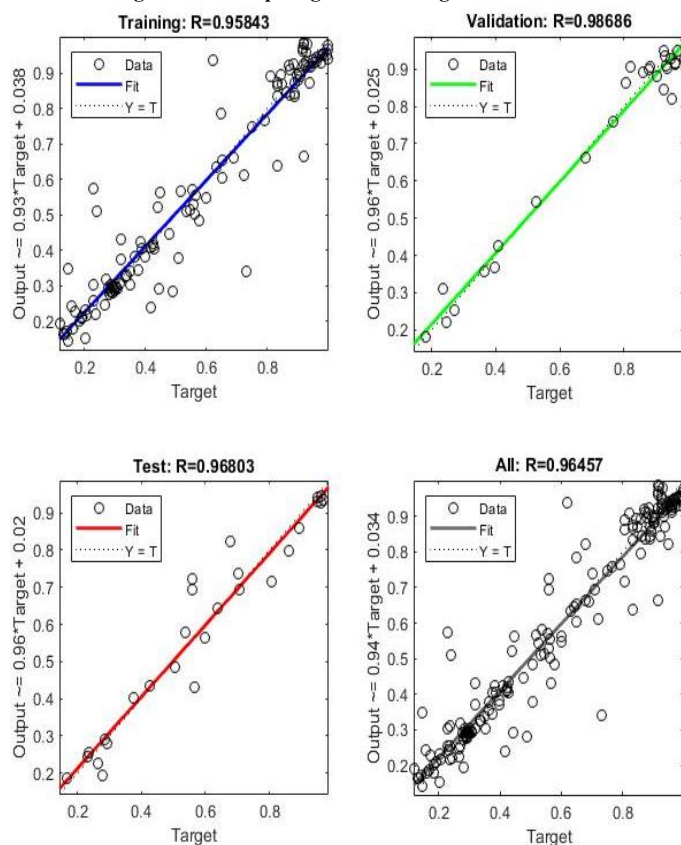
Test	Transfer function		Number of neurons	Number of layers	Training functions	Network type	Input model number	
	Layer2	Layer1						
0.0089	0.8780	PURLINE	LOGSIG	1	2	TRAINLM	MLP	1
0.0081	0.8725	PURLINE	LOGSIG	2	2	TRAINLM	MLP	2
0.0132	0.8760	PURLINE	LOGSIG	3	2	TRAINLM	MLP	3
0.0124	0.8712	PURLINE	LOGSIG	1	2	TRAINGD X	MLP	4
0.0158	0.8447	PURLINE	LOGSIG	1	2	TRAINGD A	MLP	5





شکل ۳- نمودار هم پوشانی آرایش ۱ از مدل ۱.

Figure 3. Overlap diagram of arrangement 1 of model 1.



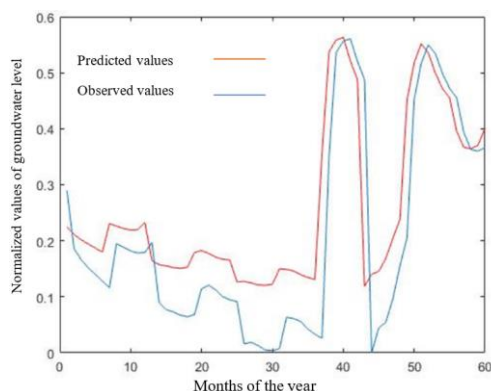
شکل ۴- نمودار رگرسیون آرایش ۱ از مدل ۱.

Figure 4. Regression diagram of arrangement 1 of model 1.

جدول ۴- نتایج آرایش ۲.

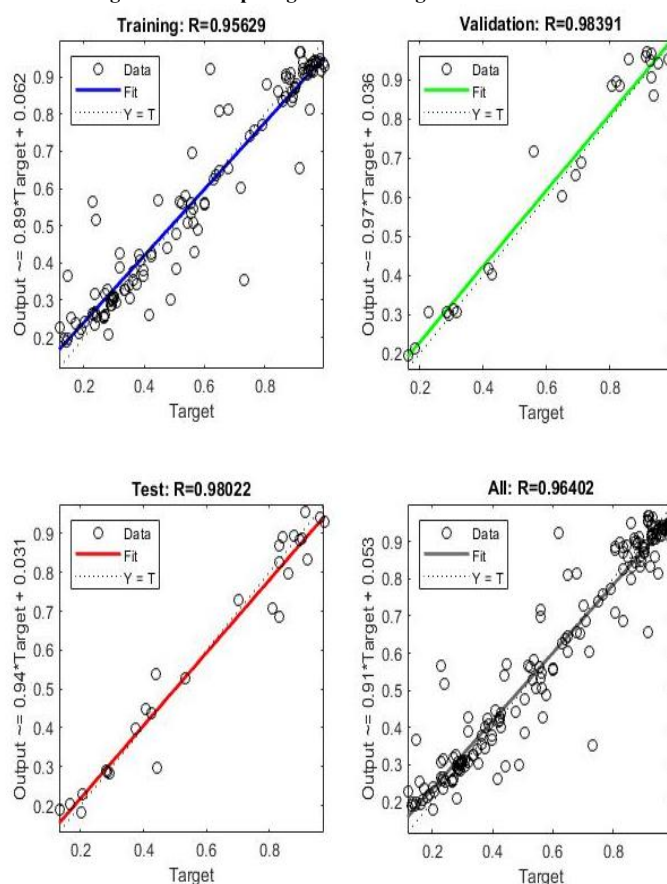
Table 4. Results of arrangement 2.

Test		Transfer function		Number of neurons	Number of layers	Training functions	Network type	Input model number
RMSE	R <sup>2</sup>	Layer2	Layer1					
0.0107	0.8772	PURLINE	LOGSIG	1	2	TRAINLM	MLP	1
0.0099	0.8686	PURLINE	LOGSIG	2	2	TRAINLM	MLP	2
0.0095	0.8749	PURLINE	LOGSIG	3	2	TRAINLM	MLP	3
0.0137	0.8674	PURLINE	LOGSIG	1	2	TRAINIDX	MLP	4
0.0198	0.8661	PURLINE	LOGSIG	1	2	TRAINGDA	MLP	5



شکل ۵- نمودار هم‌پوشانی آرایش ۲ مدل ۱.

Figure 5. Overlap diagram of arrangement 2 of model 1.



شکل ۶- نمودار رگرسیون آرایش ۲ مدل ۱

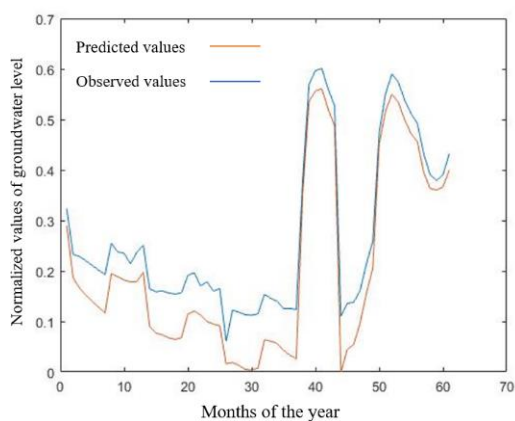
Figure 6. Regression diagram of arrangement 2 of model 1

جدول ۵- نتایج آرایش ۳

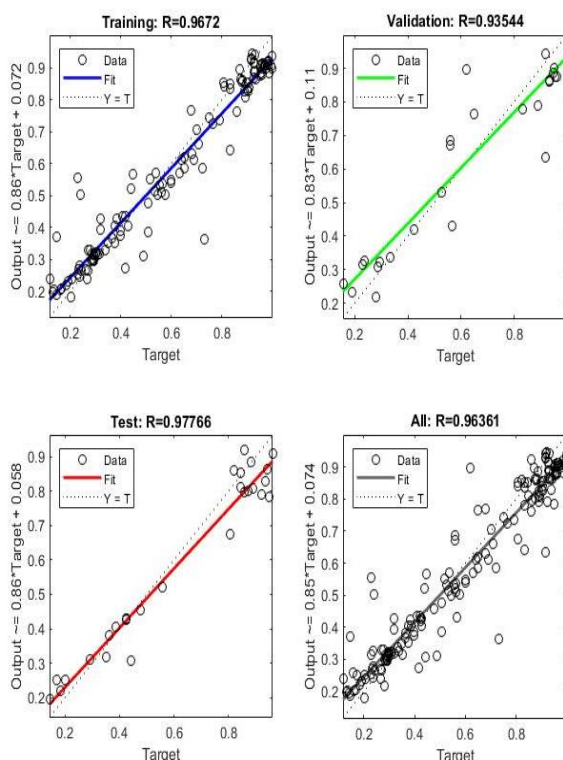
Table 5- Results of arrangement 3

Test		Transfer function		Number of neurons	Number of layers	Training functions	Network type	Input model number
RMSE	R <sup>2</sup>	Layer2	Layer1					
0.0047	0.9962	PURLINE	LOGSIG	1	2	TRAINLM	MLP	1
0.0048	0.9853	PURLINE	LOGSIG	2	2	TRAINLM	MLP	2
0.0078	0.9634	PURLINE	LOGSIG	3	2	TRAINLM	MLP	3
0.0199	0.9544	PURLINE	LOGSIG	1	2	TRAINIDX	MLP	4
0.0273	0.8518	PURLINE	LOGSIG	1	2	TRAINXDA	MLP	5





شکل ۷- نمودار هم‌پوشانی آرایش ۳ مدل ۱.  
Figure 7. Overlap diagram of arrangement 3 of model 1.

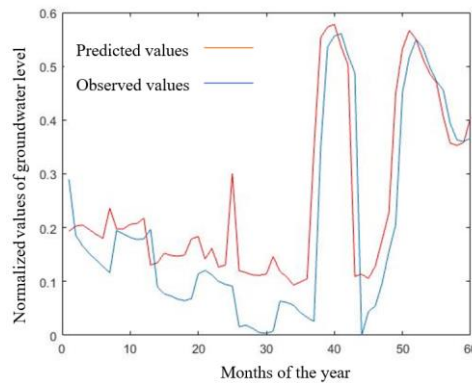


شکل ۸- نمودار رگرسیون آرایش ۳ مدل ۱.  
Figure 8. Regression diagram of arrangement 3 of model 1.

جدول ۶- نتایج آرایش ۴

Table 6. Results of arrangement 4

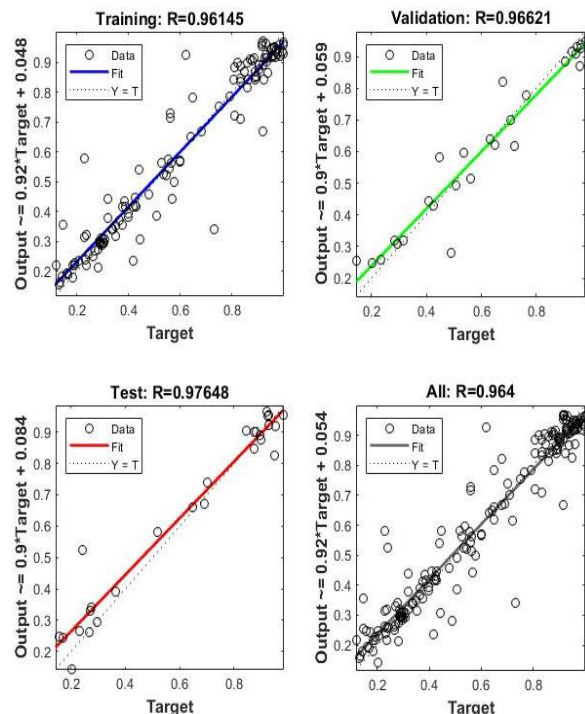
Test		Transfer function		Number of neurons	Number of layers	Training functions	Network type	Input model number
RMSE	R <sup>2</sup>	Layer2	Layer1					
0.0104	0.8746	PURLINE	LOGSIG	1	2	TRAINLM	MLP	1
0.0106	0.8846	PURLINE	LOGSIG	2	2	TRAINLM	MLP	2
0.0096	0.8802	PURLINE	LOGSIG	3	2	TRAINLM	MLP	3
0.0260	0.7666	PURLINE	LOGSIG	1	2	TRAINLGD	MLP	4
0.0277	0.7992	PURLINE	LOGSIG	1	2	TRAINLGD	MLP	5



شکل ۹- نمودار هم‌پوشانی آرایش ۴ مدل ۳.  
Figure 9. Overlap diagram of arrangement 4 of model 3.

پیش‌بینی سطح تراز آب‌های زیرزمینی در بهینه‌سازی مدیریت منابع آب بسیار موثر می‌باشند. اما فاکتورها و عوامل مختلفی بر روی این پدیده تأثیر گذارند که تحلیل آن‌ها را مشکل می‌سازد. عواملی از قبیل میزان بهره‌برداری از چاه‌ها در مقیاس زمانی و مکانی، میزان آب برگشتی، میزان ضریب ذخیره و مواردی از این قبیل تأثیر به‌سزایی در تغییرات تراز آب زیرزمینی و به‌تبع آن در عدم‌قطبیت پیش‌بینی‌ها دارند. با این وجود مدل‌های شبکه عصبی مصنوعی از جمله مدل‌هایی هستند که از نظر ساختاری به‌صورت جعبه سیاه هستند. یعنی این مدل‌ها با ساختارهای مختلف ورودی‌ها را طی یک سیستم پردازشی پیچیده به خروجی (تغییرات تراز آب زیرزمینی) متصل می‌کنند. به‌عبارتی مدل از طریق آموزش الگوهای مشاهده‌ای فرآیند شبیه‌سازی را انجام می‌دهد و به نوعی عوامل یاد شده در نتیجه شبیه‌سازی‌ها مستتر می‌باشند. مدل‌های آماری و رگرسیون از معمول‌ترین روش‌های تحلیلی می‌باشند که غالباً با توجه به حل خطی این پدیده نتایجی همراه با خطا ارائه داده و نمی‌توانند تغییرات زمانی پدیده موردنظر را با دقت قابل قبول مدل‌سازی کنند. امروزه سیستم‌های فازی و عصبی با توجه به توانایی در حل پدیده‌های غیر خطی و پیچیده کاربردهای فراوانی در مسائل مختلف مهندسی آب از جمله هیدرولوژی پیدا کرده‌اند. از آن‌جا که تغییرات سطح آب زیرزمینی به مؤلفه‌های زیادی بستگی دارد لذا پیش‌بینی سطح تراز آب زیرزمینی با ورودی‌های متعدد به مدل‌های شبکه عصبی مصنوعی با عدم‌قطبیت‌هایی روبرو خواهد بود. کما اینکه با اضافه شدن ورودی‌ها علاوه بر پیچیدگی بیشتر ساختار شبکه ممکن است پیش‌بینی‌ها را با عدم‌قطبیت بیشتری مواجه سازد. از این رو

براساس نتایج در آرایش سوم که داده‌های بارش (P) و تراز آب (W)، با تأخیر یک ماهه (P-1) (W-1) و تأخیر دو ماهه (P-2) (W-2) به‌عنوان ورودی (Input) و داده‌های تراز آب به‌عنوان Target در نظر گرفته شده بودند، با الگوریتم آموزش لونیبرگ مارکوات بهترین کارایی را دارا می‌باشند ( $R^2=0.9962$  و  $RMSE=0.0047$ ). با مقایسه جداول  $R^2$  و آرایش سوم (ورودی بارش و تراز آب زیرزمینی) و آرایش چهارم (ورودی دبی و بارش)، مشاهده می‌گردد که آرایش سوم نتایج بهتری را نشان می‌دهد.



شکل ۱۰- نمودار رگرسیون آرایش ۴ مدل ۳.  
Figure 10. Regression diagram of arrangement 4 of model 3.

## نتیجه‌گیری

بروردی، آ.، فریدونی، م.، ۱۳۹۴. شبیه‌سازی تراز آب زیرزمینی دشت شیراز با استفاده از مدل‌های بردار پشتیبان و مقایسه آن با مدل‌های عصبی فازی و موجک عصبی (مطالعه موردی: دشت شیراز)، کنفرانس و نمایشگاه مهندسی آب، ۱-۱۳.

جندقی، ن.، ۱۴۰۰. مدل‌سازی تراز آب زیرزمینی ماهانه با استفاده از مدل شبکه عصبی مصنوعی، چهلمین گردهمایی ملی علوم زمین، تهران.

حسینی، م.، روشنی، ع.، ذباح، ا.، ۱۳۹۹. مدل‌سازی تغییرات سطح آب زیرزمینی براساس روش‌های مبتنی بر هوش مصنوعی (مطالعه موردی: دشت زاوه تربت حیدریه). پژوهشنامه مدیریت حوزه آبخیز، ۱۱ (۲۱): ۲۳۵-۲۲۳.

دلاور، م.، مرید، س.، شفيعی، فر. م.، ۱۳۸۷. شبیه‌سازی و تحلیل حساسیت و عدم قطعیت تغییرات تراز آب دریاچه ارومیه نسبت به مؤلفه‌های بیلان آبی آن. مجله هیدرولیک، ۳(۱): ۵۵-۴۵.

زارع ابیانه، ح.، بیات ورکشی، م.، ۱۳۹۲. توسعه و کاربرد مدل‌های عصبی فازی، الگوریتم ژنتیک و زمین‌آمار در برآورد توزیع مکانی سطح ایستابی دشت همدان. نشریه پژوهش‌های حفاظت و آب و خاک، ۲۰(۴): ۲۵-۱.

زاهدی، ا.، فریدونی، م.، ۱۳۹۳. مقایسه شبکه عصبی مصنوعی با سیستم استنتاج فازی عصبی تطبیقی در پیش‌بینی تراز آب زیرزمینی توابع دشت ارسنجان. همایش ملی راهکارهای پیش‌روی بحران آب در ایران و خاور میانه، ۱-۶.

مبارکی، م.، فریدونی، م.، ۱۳۹۴. شبیه‌سازی تراز آب زیرزمینی با استفاده از ترکیب مدل‌های موجک، فازی عصبی و مقایسه آن با مدل فازی عصبی. کنفرانس بین‌المللی دستاوردهای نوین پژوهشی در مهندسی عمران معماری شهرسازی، ۱-۱۰.

مختاری، ز.، ناظمی، ا.، ندیری، ع.، ۱۳۹۱. پیش‌بینی تراز آب زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی (مطالعه موردی: دشت شبستر)، فصلنامه زمین‌شناسی کاربردی، ۸(۴): ۳۴۵-۳۵۳.

ملکی نژاد، ح.، پور شرعیاتی، ر.، ۱۳۹۲. کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه عصبی مصنوعی در پیش‌بینی تغییرات سطح آب زیرزمینی (مطالعه موردی: دشت مروست). علوم و مهندسی آبیاری، ۳۶ (۳): ۹۲-۸۱.

مهدوی‌زاده، م.، ۱۳۸۳. شبکه‌های عصبی مصنوعی و کاربردهای آن در مهندسی عمران. انتشارات عبادی. ۱۹۲ ص.

ندیری، ع.، صدقی، ز.، کاظمیان، ن.، ۱۳۹۶. بهینه‌سازی روش DRATIC با استفاده از هوش مصنوعی برای ارزیابی آسیب‌پذیری

انتخاب بهترین شبکه و مؤثرترین عوامل در تغییرات متغیر مورد نظر گام مؤثری در کاهش عدم قطعیت‌ها در پیش‌بینی آن متغیر می‌باشد. در این تحقیق برای پیش‌بینی تراز آب زیرزمینی حوزه آبخیز کمه شهرستان سمیرم از مدل شبکه عصبی مصنوعی با آرایش‌های مختلف استفاده شد. نتایج ضمن تایید کارایی مناسب مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی تراز آب زیرزمینی نشان داد که استفاده از پارامترهای اقلیمی با میزان ضریب تعیین ۰/۹۹ و مجذور میانگین مربعات خطای ۰/۰۰۴۷ نسبت به پارامترهای هیدرولوژیکی با میزان ضریب تعیین ۰/۸۸ و مجذور میانگین مربعات خطای ۰/۰۱ جهت مدل‌سازی مقادیر کمی آب- زیرزمینی در مدل شبکه عصبی مصنوعی دارای عملکرد بهتری می‌باشد. مقایسه آرایش اول و چهارم نشان می‌دهد که با اضافه‌شدن دبی جریان سطحی به‌عنوان ورودی مدل‌های شبکه از کارایی آن کاسته می‌شود. همچنین با افزایش زمان تأخیر در داده‌های اقلیمی و آب زیرزمینی کارایی مدل‌سازی بهتر گردیده است و این نشان از اثرگذاری میزان بارش‌ها حتی در حوزه‌های کوهستانی، با بازه‌های یک ماهه و دو ماهه بر تغییرات سفره زیرزمینی می‌باشد. با مقایسه نتایج آزمون‌های آماری چهار آرایش مختلف در مدل شبکه عصبی می‌توان نتیجه گرفت که مدل‌هایی که با الگوریتم آموزش لونیگ مارکوارت آموزش داده شده‌اند، بهترین کارایی را داشته‌اند که با نتایج تحقیق حسینی در منطقه دشت زاوه خراسان مطابقت دارد (حسینی و همکاران، ۱۳۹۹). همچنین مطابق نتایج این تحقیق و با توجه به پیچیدگی مدل‌سازی تراز آب زیرزمینی در اثر عوامل مختلف اقلیمی، زمینی و مدیریتی پیشنهاد می‌گردد تا جهت پیش‌بینی کوتاه مدت تراز آب زیرزمینی با دقت قابل‌قبولی از مدل‌های شبکه عصبی مصنوعی استفاده نمود که نتایج تحقیق جندقی نیز در منطقه گرگانرود مؤید این موضوع می‌باشد (جندقی، ۱۴۰۰).

## منابع

باباعلی، ح.، دهقانی، ر.، ۱۳۹۶. پیش‌بینی دبی سیلابی با استفاده از شبکه عصبی موجک. مجله هیدروژئومورفولوژی، ۳(۱): ۱۴۹-۱۶۸.

- Academic Journals, Scientific Research and Essays, 7(24),2112-2121.
- Khaled, A., Abdolmajid, A., hadad, B. O., Heydari, N., 2013. Estimation Of Virtual Water Using Support Vector Machine, K-nearest Neighbour and Radial Basis Function Neural Network Models, International Journal of Agronomy and Plant Production, 4(11), 2926-2936.
- Moradi, A., Akhtari, A., Azari, A., 2023. Prediction of groundwater level fluctuation using methods based on machine learning and numerical model. Journal of Applied Research in Water and Wastewater, 10 (1), 20-28.
- Nourmohammadi Dehbalaei, F., Azari, A., Akhtari, A. A., 2023. Development of a linear-nonlinear hybrid special model to predict monthly runoff in a catchment area and evaluate its performance with novel machine learning methods. Applied Water Science, 13 (5), 1-23.
- Panahi, J., Mastouri, R., Shabanlou, S., 2022. Insights into enhanced machine learning techniques for surface water quantity and quality prediction based on data pre-processing algorithms. Journal of Hydro informatics, 24 (4), 875-897.
- Paul, A., Afroosa, M., Baduru, B., Paul, B. (2023). Showcasing model performance across space and time using single diagrams. Ocean Modelling, 181, 102150.
- Samani, S., Vadiati, M., Delkash, M., Bonakdari, H. (2022). A hybrid wavelet-machine learning model for qanat water flow prediction. Acta Geophysica, 1-19.
- آبخوان چندگانه دشت ورزقان. مجله اکوهیدرولوژی، ۴(۴): ۱۰۸۹-۱۱۰۳.
- نیک منش، م، رخشنده‌رو، غ، ۱۳۹۰. ارزیابی توانایی شبکه‌های مختلف عصبی‌مصنوعی در پیش‌بینی تراز آب زیرزمینی در آبخوان محدوده سعادت شهر فارس. تحقیقات منابع آب ایران، ۷(۱): ۸۶-۸۲.
- سراوانی، ز، محمدرضایپور، ا، سیاسر، هادی، ۱۴۰۲. پیش‌بینی پارامترهای کیفی آب‌های زیرزمینی استان گلستان با مدل‌های هوش‌مصنوعی. هیدروژئولوژی ۸(۲): ۱۵-۲۸.
- یوسفی مبرهن، ا، صابر چناری، ک، زندی فر، س، ۱۴۰۳. تحلیل تغییرات زمانی خشک‌سالی بر منابع آب زیرزمینی دشت قروه-دهگلان با استفاده از شاخص‌های خشک‌سالی آب زیرزمینی و بارش استاندارد. هیدروژئولوژی، ۹(۲): ۱-۱۴.
- Adamowski, J., Chan, H. F., 2011. A wavelet neural network conjunction model for groundwater level forecasting. Journal of Hydrology, 407, 28-40.
- Bunchingiv, B., Gerald, H., Holz, K.P., 2003. Short Term Water Level Prediction Using Neural Network and Neuro-Fuzzy Approach, ELSEVIER, page 439-450.
- Chang, J., Wang, G., Mao, T., 2015. Simulation and prediction of supra permafrost groundwater level variation in response to climate change using a neural network model. Journal of Hydrology, 529, pp.1211-1220.
- Chen, L. H., Chen, C. T., Pan, Y. G., 2009. Groundwater level prediction using SOM RBFN multisite model. Journal of Hydrologic Engineering, 15(8), 624-631.
- Chitsazan, M., Rahmani, G., Neyamandpour, A., 2013. Ground Water Level Simulation Using Artificial Neural Network: A Case Study from Aghili Plain, Urban Area of Gotvand, Soth-West Iran, Jgeope, 3(1), P.35-46.
- Emamgholizadeh, S., Moslemi, K. and Karami, G., 2014. Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS). Water resources management, 28(15), 5433-5446.
- Feng, Sh., Kang, Sh., Hou, Z., Chen, S and Mao, X., 2008. Neural Networks to Simulate Regional Ground Water Levels Affected by Human Activities, Ground Water, 46, page 80-90.
- Galavi, H and Lee Teang, Shui., 2012. Neuro-Fuzzy-Modeling and Fore Casting in Water Resources,