

پیش‌بینی سطح آب زیرزمینی با استفاده از مدل‌های منطق فازی، شبکه عصبی و سری زمانی

بهزاد سعیدی رضوی^{۱*}، علیرضا عرب^۲

۱- استادیار پژوهشی گروه پژوهشی ساختمانی و معدنی، پژوهشکده فناوری و مهندسی، پژوهشگاه استاندارد، کرج، ایران.

۲- کارشناس ارشد مهندسی منابع آب.

تاریخ پذیرش مقاله: ۱۳۹۶/۱۱/۰۱

تاریخ دریافت مقاله: ۱۳۹۶/۰۳/۰۵

چکیده

در مطالعات آب‌های زیرزمینی، تغییرات سطح ایستابی از اهمیت فراوانی برخوردار است. به همین دلیل، امروزه شبیه‌سازی جریان آب زیرزمینی توسط مدل‌های ریاضی و کامپیوتری که یک روش غیرمستقیم مطالعه آب زیرزمینی می‌باشد، با صرف هزینه کمتر صورت می‌گیرد. پیش‌بینی سطح آب زیرزمینی یک حوضه نقش مهمی را در مدیریت منابع آبی ایفا می‌کند. به‌خصوص در مناطق نیمه‌خشک آب‌های زیرزمینی نقش بسیار مهمی در تعیین آب مورد نیاز، کشاورزی، شهری و امور صنعتی دارد. در این تحقیق کارایی مدل‌های شبکه‌های عصبی مصنوعی، منطق فازی و سری زمانی در تخمین سطح آب زیرزمینی آبخوان دشت عجب‌شیر مورد بررسی قرار گرفت. پارامترهای بارندگی، دما، دبی جریان و تراز سطح ایستابی در دوره زمانی ماه قبل به‌عنوان ورودی و تراز سطح ایستابی در دوره موردنظر به‌عنوان خروجی مدل‌ها در مقیاس زمانی ماهانه در طی دوره آماری (۱۳۸۵-۱۳۹۶) انتخاب گردید. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا برای ارزیابی و نیز مقایسه عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج حاصله نشان داد که مدل منطق فازی می‌تواند تراز سطح ایستابی را با دقت قابل قبولی پیش‌بینی نماید. توابع عضویت استفاده شده برای مدل‌سازی فازی سطح ایستابی، تابع عضویت گوسی بود که به داده‌های دسته‌بندی شده برازش داده شد و نیز تابع عضویت خروجی مدل ساگنو تابعی است خطی که بر اساس ورودی‌ها ساخته می‌شود. در مورد دقت، مدل منطق فازی با بیشترین ضریب همبستگی، کمترین ریشه میانگین مربعات خطا و میانگین قدر مطلق خطا به عنوان بهترین مدل برای پیش‌بینی سطح آب زیرزمینی شناخته شد.

واژه‌های کلیدی: سطح ایستابی، شبکه‌های عصبی، منطق فازی، سری زمانی.

مقدمه

که با استفاده از مدل‌های خطی متداول و کلاسیک به‌خوبی قابل توصیف و مدل‌سازی نیستند. بنابراین به‌منظور مدل‌سازی این پدیده‌های هیدرولوژیکی لازم است از مدل‌های غیرخطی استفاده نمود. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرند (Norouzi et al., 2018). امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد. عدم وجود داده‌های کافی برای توسعه مدل‌های ریاضی به علت محدودیت‌های زمانی و هزینه‌ای و همچنین زمان زیاد لازم جهت اجرای مکرر این مدل‌ها خصوصاً در شرایط ترکیب با مدل‌های بهینه‌سازی

با توجه به رشد روزافزون جمعیت و ضرورت استفاده بهینه از منابع آب، تأمین بیشترین مقدار ممکن آب‌های زیرزمینی برای رفع نیازهای همه انسان‌ها از اهمیت ویژه‌ای برخوردار است. بهره‌برداری بی‌رویه از منابع آب زیرزمینی در مهر و موم‌های اخیر باعث به هم خوردن تعادل طبیعی آن شده و تراز آب زیرزمینی در آبخوان‌های بسیاری از نقاط کشور منفی شده است. به‌منظور آگاهی از وضعیت این منابع و مدیریت بهینه آن‌ها، لازم است پیش‌بینی دقیقی از نوسانات تراز آب زیرزمینی صورت گیرد. بیشتر سری‌های زمانی هیدرولوژیکی نظیر تغییرات سطح آب زیرزمینی همواره شامل فرایندهای نامانا و پیچیده هستند

دما در طی دوره آماری ۲۰۰۹-۲۰۱۰ مورد بررسی قرار دادند و نشان دادند که شبکه عصبی مصنوعی برای پیش‌بینی سطح آب زیرزمینی از دقت قابل توجهی برخوردار است. هاسنا و همکاران (۲۰۱۶) شبکه عصبی مصنوعی را جهت پیش‌بینی سطح آب زیرزمینی دشت چاندپور بنگلادش در طی سال ۱۹۸-۲۰۰۷ بکار بردند و نشان دادند شبکه عصبی مصنوعی خطای ناچیزی در پیش‌بینی سطح آب زیرزمینی دارد. پورمحمدی و همکاران (Pourmohammadi et al., 2013) کارایی تکنیک شبکه عصبی مصنوعی و سری‌های زمانی (آریم) را در پیش‌بینی سطح ایستابی آب زیرزمینی در یکی از زیرحوضه‌های بختگان مورد بررسی قرار دادند. نتایج بیان‌گر کارایی و دقت بالای هر دو تکنیک در پیش‌بینی سطح ایستابی چاه‌های منطقه بود. نتایج پژوهش خاشعی سیوکی و همکاران (Khasheiy et al., 2012) نشان داد که دقت مدل‌های شبکه‌های عصبی مصنوعی و ANFIS در پیش‌بینی سطح آب زیرزمینی دشت نیشابور نسبت به مدل‌های رگرسیونی بالاتر بود. نتایج شبیه‌سازی و پیش‌بینی سطح آب زیرزمینی با دو مدل عددی (مادفلو) و شبکه‌های عصبی مصنوعی در منطقه اودیشا هندوستان نشان داد که پیش‌بینی‌های مدل شبکه‌های عصبی مصنوعی در بازه زمانی کوتاه مدت از مادفلو بهتر بود (Mohanty et al., 2013). ندیری و همکاران (Nadiri et al., 2012) در پژوهشی با کمک مدل‌های منطق فازی، شبکه‌های عصبی مصنوعی و نروفازی مقادیر قابلیت انتقال سفره آب زیرزمینی دشت تسوج را برآورد نمودند. ایشان در ادامه پژوهش با طراحی مدلی ترکیبی از مدل‌های هوش مصنوعی، مقادیر خروجی از هر یک از مدل‌های فوق را با در نظر گرفتن وزن بهینه شده با روش الگوریتم بهینه‌سازی شده با جامعه ذرات وارد مدل ترکیبی نمودند. نتایج نشان داد که مقادیر قابلیت انتقال برآورد شده با مدل ترکیبی دقیق‌تر از تک‌تک مدل‌های اولیه بود. نتایج مقایسه عملکرد سه روش هوش مصنوعی (شبکه‌های عصبی مصنوعی، سامانه استنتاج تطبیقی فازی-عصبی و برنامه‌ریزی بیان ژن) برای


به‌منظور یافتن سناریوی بهینه مدیریت آب زیرزمینی، کاربرد مدل‌های ریاضی را با محدودیت مواجه می‌کند (Plumb et al., 2005). مدل‌های مبتنی بر هوش مصنوعی می‌توانند جایگزین مناسبی به شمار آیند. در این نوع شبکه‌ها، با انجام پردازش‌های موازی روی داده‌های تجربی، دانش یا قانون نهفته در داده‌ها به ساختار شبکه منتقل شده و بر اساس محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی آن‌ها فرا گرفته می‌شود (Rani et al., 2010). پژوهش‌های زیادی برای شبیه‌سازی آبخوان به کمک روش‌های هوش مصنوعی صورت گرفته است. آداموسکی و چان (۲۰۱۱) از شبکه عصبی موجک جهت پیش‌بینی سطح آب زیرزمینی حوضه چاتوگای واقع در کانادا در سال ۲۰۰۲-۲۰۰۹ استفاده نمودند و نشان دادند شبکه عصبی موجک پتانسیل بالایی در پیش‌بینی تراز آب زیرزمینی دارد و می‌تواند این مدل در مدیریت آب‌های زیرزمینی مفید باشد. موسوی و همکاران (۲۰۱۳) کارایی چهار مدل شبکه عصبی موجک، شبکه عصبی مصنوعی، سیستم استنتاج فازی و سیستم فازی تلفیقی با شبکه موجک را جهت پیش‌بینی تراز آب زیرزمینی دشت خراسان رضوی با استفاده از پارامترهای بارش، تبخیر و دما در طی سال ۱۹۹۲-۲۰۰۷ مورد بررسی قرار دادند و نشان دادند شبکه عصبی مصنوعی از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار است. دالیاکوپولوس و همکاران (2005)، با استفاده از شبکه‌های عصبی مصنوعی با معماری پیشرو و الگوریتم آموزش لونیبرگ-مارکوارت، مقادیر سطح آب زیرزمینی دره مسارا در جزیره کرت در جنوب یونان را تا ۱۸ ماه آینده پیش‌بینی نمودند. فنگ و همکاران (Feng et al., 2008) با کمک شبکه‌های عصبی مصنوعی پیشرو با الگوریتم پس انتشار گرادیان مزدوج، تغییرات سطح آب زیرزمینی منطقه مین‌کین در شمال غربی چین را شبیه‌سازی و پیش‌بینی نمودند. از سوی دیگر چیت‌سازان و همکاران (۲۰۱۳) در پژوهشی کارایی شبکه عصبی مصنوعی را جهت پیش‌بینی سطح آب زیرزمینی دشت عقیل با استفاده از پارامترهای باران، تبخیر، رطوبت نسبی و

یافت. با توجه به پژوهش‌های انجام‌شده و همچنین اهمیت دشت عجب‌شیر آذربایجان شرقی از لحاظ شرب و کشاورزی، بررسی تغییرات تراز سطح ایستابی به‌منظور پیش‌بینی و اقدامات مدیریتی ضروری است. هدف کلی از این تحقیق بررسی کارایی روش‌های هوش مصنوعی و سری زمانی برای پیش‌بینی سطح آب زیرزمینی دشت عجب‌شیر می‌باشد.

مواد و روش‌ها

دشت عجب‌شیر در شمال غرب ایران و در قسمت شرقی دریاچه ارومیه و در فاصله تقریباً ۹۰ کیلومتری جنوب شهر تبریز و در دامنه‌های غربی رشته‌کوه سهند واقع گردیده است. شکل ۱ موقعیت جغرافیایی منطقه‌ی مورد مطالعه را نشان می‌دهد. وسعت کل محدوده مطالعاتی عجب‌شیر برابر ۵۹۰ کیلومتر مربع است که حدود ۱۳۱ کیلومتر مربع آن را دشت عجب‌شیر تشکیل می‌دهد. ارتفاع بلندترین و پست‌ترین نقاط محدوده به ترتیب برابر ۳۴۰۰ متر و ۱۲۷۵ متر از سطح دریا است. آب‌وهوای منطقه عجب‌شیر از نوع نیمه‌خشک بوده و بر اساس اطلاعات هواشناسی موجود متوسط سالانه میانگین بارش حدود ۳۵۰ میلی‌متر و متوسط بلندمدت تبخیر از سطح تشتک ۱۶۰۰ میلی‌متر است. رودخانه قلعه‌چای، مهم‌ترین رودخانه محدوده است که از بلندی‌های باختری کوه سهند سرچشمه می‌گیرد و در راستای عمومی شمال شرقی- جنوب غربی جریان یافته و پس از گذر از دشت عجب‌شیر به دریاچه ارومیه می‌ریزد. بررسی نوسانات سطح آب زیرزمینی دشت نشان می‌دهد که طی سال‌های ۸۰-۸۹ سطح آب زیرزمینی رو به کاهش است که دلیل آن کاهش ریزش‌های جوی در سال‌های مورد مطالعه و افزایش برداشت از چاه‌های بهره‌برداری است. لیکن از سال ۸۹ شیب روند کاهشی سطح تراز ایستابی کاهش یافته است.

پیش‌بینی نوسانات تراز آب زیرزمینی در حوضه زیرنگل در استان گلستان نشان داد هر سه روش به‌طور موفقیت‌آمیزی برای پیش‌بینی نوسانات سطح ایستابی مورد استفاده قرار گیرند اما بهترین عملکرد مربوط به مدل برنامه‌ریزی بیان ژن بود (Abarashi et al., 2014). ندیری و همکاران (Nadiri et al., 2014) طی پژوهشی از ۳ مدل هوش مصنوعی شامل منطق فازی تاکاگی-سوگنو، شبکه‌های عصبی مصنوعی و نرو-فازی، برای تخمین هدایت هیدرولیکی آبخوان تسوج-آذربایجان شرقی استفاده کردند. بر اساس نتایج، با وجود مقادیر هدایت هیدرولیکی تخمینی کاملاً متفاوت از طریق دو مدل شبکه عصبی و منطق فازی، ولی این دو مدل اهمیت یکسانی نشان دادند. به‌منظور تخمین مقادیر هدایت هیدرولیکی آبخوان تسوج-آذربایجان شرقی، تایفور و همکاران (Tayfur et al., 2014) از مدل‌های هوش مصنوعی شامل منطق فازی سوگنو، منطق فازی ممدانی، شبکه‌های عصبی پرسپترون چندلایه ترکیبی با تابع لونبرگ-مارکوارت و نرو-فازی، استفاده کردند. بر اساس نتایج، کارایی مدل‌های نرو-فازی و منطق فازی سوگنو قابل قبول بود در حالی که تخمین‌های شبکه‌های عصبی و منطق فازی ممدانی ضعیف بود. ژوروپچ و همکاران در سال ۲۰۱۰ طی پژوهشی جهت پیش‌بینی سطح آب زیرزمینی در ساحل چپ رودخانه دانوب در استان وجودینا در شمال صربستان از دو مدل ANFIS و ANN استفاده کردند. نتایج نشان داد که از هر دو مدل می‌توان به‌عنوان ابزاری مفید برای مدل‌سازی سطح آب زیرزمینی با دقت بالا استفاده کرد. سان و همکاران (Sun et al., 2015) به‌منظور پیش‌بینی سطح آب زیرزمینی جنگل‌های باتلاقی سنگاپور با کمک شبکه عصبی از معماری پرسپترون چندلایه با الگوریتم لونبرگ-مارکوارت و فقط مقادیر سطح آب برکه‌ها و میزان بارندگی استفاده کردند. نتایج حاکی از صحت مقادیر پیش‌بینی شده تا هفت روز آینده بود ولی با طولانی‌تر شدن زمان پیش‌بینی دقت مقادیر کاهش




شکل ۱- موقعیت منطقه مورد مطالعه و تراز آب زیرزمینی

رسوبات آبرفتی، لاگ‌های حفاری و داده‌های ژئوفیزیکی، در قسمت‌های بالایی دشت، ذرات تشکیل دهنده سفره دانه درشت بوده و هر چه به سمت مرکز دشت و نواحی خروجی و به سمت دریاچه ارومیه نزدیک می‌شویم رسوبات دانه‌ریزتر می‌باشند و دارای هدایت هیدرولیکی کمتری می‌باشد. بیشترین ضخامت آبرفت در این قسمت ۹۸ متر می‌باشد. تغییرات هیدروگراف واحد آب زیرزمینی که در شکل ۲ نشان داده شده است، از رأس مخروط‌افکنه‌ها به سمت پای دشت کاهش می‌یابد. بر اساس نقشه‌های هم ضخامت رسوبات آبرفتی، لاگ‌های حفاری و داده‌های ژئوفیزیکی، در قسمت‌های بالایی دشت، ذرات تشکیل دهنده سفره دانه درشت بوده و قابلیت انتقال دشت نیز در این مناطق بالا می‌باشد و هر چه به سمت مرکز دشت و نواحی خروجی و به سمت دریاچه ارومیه نزدیک می‌شویم رسوبات دانه‌ریزتر شده و قابلیت انتقال نیز کاهش می‌یابد. ضریب ذخیره این دشت که با روش بیلان جزء به جزء محاسبه شده است و با استفاده از روش مذکور، مقدار متوسط ضریب ذخیره آبخیز در حدود ۳/۶ درصد می‌باشد. گرادیان هیدرولیکی مطلق که مسئول حرکت آب زیرزمینی و مهاجرت

این منطقه دارای سازندهای زمین‌شناسی مختلفی می‌باشد. سازند لالون که در قسمت شرق و سازند روته در دوره پرمین در جنوب منطقه برون‌زد دارد، سازند شمشک قسمت شرق و شمال‌شرقی منطقه را پوشانده است و سازند لار مربوط به دوره تریاس و ژوراسیک در قسمت شمال و شمال شرق منطقه دیده می‌شود. بخش اعظمی از مساحت منطقه مربوط به رسوبات آبرفتی دوره کواترنر است و بخش کمی از آن‌ها در بخش غربی دارای پهنه‌های رسی-نمکی هستند. در قسمت شمالی و شرقی دشت مجموعه رسوبات آهک و مارن-ژیپس دیده می‌شود که مربوط به دوره کرتاسه و مجموعه سنگ‌های پیروکلاستیک و رس‌سنگ‌ها مربوط به دوره پلیوسن می‌باشند. در قسمت شمال و شمال‌غربی منطقه عجب‌شیر، سنگ‌های آهکی تا توده خاکستری روشن مربوط به دوره تریاس و ژوراسیک و توده آهک‌های کرتاسه به چشم می‌خورد. آبخیز دشت از نوع آزاد می‌باشد که اکثراً از پادگانه‌های آبرفتی قدیمی، پادگانه‌های آبرفتی جدید، مخروط‌افکنه‌ها و رسوبات رودخانه‌ای تشکیل یافته است و مواد اصلی تشکیل دهنده آبخیز رسوبات ماسه، سیلت و رس می‌باشد، که بر اساس نقشه‌های هم ضخامت

کرتاسه یافت می‌شوند که قسمت اعظم منابع آب منطقه را تشکیل می‌دهند. سازندهای با آبدی متوسط به بالا نیز در واحدهای آهکی اربیتولین‌دار، تشکیلات تفکیک‌ناپذیر ژوراسیک و کرتاسه، واحدهای آهکی لار و دلیچای یافت می‌گردند. همچنین گروه سنگ‌های تخریبی - آذرآواری با توان آبدی ضعیف نیز که شامل واحد خاکستر آتشفشانی همراه با سنگ‌های آذرآواری، کنگلومرا و ماسه‌سنگ میوسن، واحد مارن‌های خاکستری با کمی سنگ آهک متعلق به کرتاسه و شیل و آهک دلمیتی متعلق به پرکامبرین می‌باشند، حدود ۳۴ کیلومترمربع از منطقه را تشکیل می‌دهند. سایر سازندها که از وسعت زیادی نیز برخوردار نمی‌باشند، آبدی ضعیفی دارند. این سازندها که در قسمت‌های غربی به‌طور گسترده در حاشیه دریاچه ارومیه قرار گرفته‌اند، دارای سن کواترنری (Qs) و شامل رسوبات رسی هستند که علاوه بر اینکه از نفوذپذیری بسیار کمی برخوردار هستند، به علت داشتن لایه‌های گچ و نمک بر روی کیفیت آب‌ها اثر نامطلوب می‌گذارند.

ماده حل شونده در آن می‌باشد در دشت عجب‌شیر در نقاط مختلف متفاوت می‌باشد و به‌طور کلی در ورودی‌های دشت میانگین ۰/۰۰۷ و در خروجی‌ها نیز در حدود ۰/۰۰۱ می‌باشد. محاسبات بیلان آب زیرزمینی برای سال آبی ۹۵-۹۶ حاکی از این است که در محدوده بیلان، تغییرات حجم آب آبخوان منفی می‌باشد؛ به‌طوری که در سال مذکور، تخلیه از آن به میزان ۳/۹۳ میلیون مترمکعب بیشتر از میزان تغذیه می‌باشد. با توجه به هیدروگراف واحد دشت عجب‌شیر (شکل ۲)، سطح آب زیرزمینی در طول سال بیلان، ۰/۲۹ متر افت داشته است. بر اساس بررسی‌های هیدروژئولوژیکی، رسوبات کواترنری بیشتر سازندهای آبدار منطقه را در بر گرفته‌اند و آبدی خوبی دارند. این نهشته‌ها شامل رسوبات رودخانه‌ای (Qal)، که در طرفین رودخانه‌های دائمی و فصلی به‌صورت کم شیب گسترش دارند، رسوبات واریزه‌ای Qt2 و Q1 که بیشتر در دامنه‌ها دیده می‌شوند، و رسوبات Qt1 که تراس‌های مرتفع را تشکیل می‌دهند، می‌باشند. سنگ‌های با توان آبدی متوسط نیز بیشتر در سازندهای شمشک، لالون و واحدهای ماسه‌سنگی - شیلی



شکل ۲- هیدروگراف معرف آب زیرزمینی دشت عجب‌شیر.

مصنوعی، می‌توان روش شبکه عصبی مصنوعی و منطق فازی را نام برد که برای چنین داده‌هایی کاربرد دارند. در این مطالعه از

مدل‌های هوش مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد. در بین روش‌های هوش

لونیبرگ-مارکوارت توسط انجمن مهندسين عمران آمريكا (ASCE, 2000) ارائه شده است. در اين تحقيق برای اجرای مدل شبکه‌های عصبی مصنوعی، داده‌های ورودی و هدف به دو دسته آموزش و آزمایش تقسیم گردید. به‌طوری که ۷۵ درصد داده‌ها برای مرحله آموزش و ۲۵ درصد داده‌ها برای مرحله آزمایش در نظر گرفته شده است. روش فازی روشی مناسب جهت کاهش خطای برآوردی و انسانی نسبت به تئوری‌های قابل اعتماد دیگر است (Chiu et al., 1994). در منطق فازی دو بحث مدل‌سازی و دسته‌بندی فازی مطرح است که از مدل‌سازی فازی جهت تخمین پارامترهای عددی مانند تخلخل، هدایت هیدرولیکی، تراوایی و قابلیت انتقال استفاده می‌شود. مدل‌سازی فازی به سه روش فازی ممدانی (MFL)، تاگای سونگو-کانگ که به‌طور خلاصه روش سونگو (SFL) نامیده می‌شود و لارسن (LFL) قابل اجراست. تفاوت روش سونگو با دو روش دیگر در خروجی آن‌ها است، در روش سونگو تابع عضویت داده‌های خروجی سیستم فازی به‌صورت رابطه خطی یا ثابت است که توسط روش دسته‌بندی به دست می‌آید. اولین مرحله در ایجاد یک مدل فازی دسته‌بندی داده‌هاست که بسته به نوع مدل فازی استفاده شده می‌توان از روش‌های دسته‌بندی مختلف استفاده کرد (Norouzi et al., 2018). از روش دسته‌بندی کاهشی^۹ برای مدل ساگو و از روش دسته‌بندی میان مرکز^{۱۰} (FCM) برای روش ممدانی و لارسن استفاده می‌شود. هر مدل فازی شامل سه مرحله اصلی است: الف) فازی کردن داده‌ها: که این عمل با تعریف تابع عضویت انجام می‌شود، ب) ایجاد ارتباط بین ورودی و خروجی: که این کار نیز با یک سری قوانینی مانند اگر آنگاه (if-then) انجام می‌شود و ج) مرحله آخر که مرحله بررسی سیستم، تجميع نتایج و غیرفازی سازی است. در این مطالعه از روش فازی سونگو استفاده شده است.

سری‌های زمانی

مدل‌های هوش مصنوعی مانند فازی^۱ FL و شبکه‌های عصبی مصنوعی (ANN^۲) برای پیش‌بینی سطح آب زیرزمینی استفاده شده است. ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک‌لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است (Demuth et al., 2000).

نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه^۳ انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا^۴ با ساختار شبکه پیش‌خور^۵ و تعداد سه لایه به‌طور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد. از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (Hopfield et al., 1982). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک‌لایه ورودی، یک‌لایه مخفی و یک‌لایه خروجی در شکل ۳ نشان داده شده است. روش‌های آموزش در شبکه‌های پرسپترون چند لایه جهت آموزش شبکه‌های عصبی توسط الگوریتم‌های ریاضی متفاوت صورت می‌گیرد که از جمله مهم‌ترین آن‌ها الگوریتم انتشار خطا به عقب^۶ (BP)، الگوریتم گرادیان مزدوج^۷ (CG)، الگوریتم لونیبرگ-مارکوارت^۸ (LM) و غیره می‌باشند. از این میان الگوریتم لونیبرگ-مارکوارت به‌عنوان کاراترین و سریع‌ترین روش آموزش شبکه‌های عصبی شناخته شده است که جزئیات آموزش و فرایند محاسبه الگوریتم

¹ Fuzzy Logic

² Artificial Neural Network

³ Multi-Layer Perceptron

⁴ Back Propagation (BP)

⁵ Feed Forward

⁶ Back Propagation Algorithm

⁷ Conjugate Gradient Algorithm

⁸ Levenberg-Marquard

⁹ Subtractive

¹⁰ Fuzzy C-Means

اساس بسیاری از تصمیم‌گیری‌ها در فرایندهای هیدرولوژیکی، تصمیمات بهره‌برداری از منابع آب بر پایه‌ی پیش‌بینی و تحلیل سری‌های زمانی می‌باشد. امروزه تجزیه و تحلیل سری‌های زمانی به طور وسیعی در بسیاری از شاخه‌های مهندسی، علوم فیزیک و اقتصاد استفاده واقع می‌شود و می‌توان گفت که بیشتر شاخه‌های علوم منجر به مطالعه داده‌هایی می‌شوند که به شکل سری‌های زمانی رخ می‌دهند (نیرومند و بزرگنیا، ۱۳۷۲). یک سری زمانی مجموعه مشاهداتی است که بر حسب زمان مرتب شده باشند. داده‌هایی که از مشاهدات یک پدیده در طول زمان به دست می‌آیند بسیار متداول هستند. سری‌های زمانی یکی از شاخه‌های آمار و احتمال است که در سایر رشته‌های علوم مانند ژئوفیزیک، اقتصاد، مهندسی ارتباطات، هواشناسی و ... کاربرد فراوانی دارد. می‌توان گفت که بیشتر شاخه‌های علوم منجر به مطالعه داده‌هایی که به شکل سری‌های زمانی رخ می‌دهند، می‌شود. هر سری زمانی دارای ۴ مؤلفه می‌باشد که شامل روند، تناوب فصلی، تناوب دوره‌ای و مؤلفه تصادفی (یا گوس محض که غیرقابل پیش‌بینی است) می‌باشد. هدف تجزیه و تحلیل سری‌های زمانی معمولاً دو مورد است: درک یا به مدل درآوردن مکانیسم تصادفی که منجر به مشاهده سری می‌شود و همچنین پیش‌بینی آینده سری زمانی و تولید داده‌های مصنوعی دانست. روش‌های پیش‌بینی در دو دسته کلی روش‌های ساختاری و سری زمانی طبقه‌بندی می‌گردد (Capilla, 2008). در روش‌های ساختاری مقدار یک متغیر (متغیر وابسته) با توجه به سایر متغیرها (متغیرهای مستقل) تعیین می‌گردد در حالی که در مدل‌های سری زمانی، وقفه‌های زمانی متغیر وابسته به عنوان متغیر مستقل محسوب می‌گردد. در روش‌های ساختاری علاوه بر پیش‌بینی متغیر وابسته، نیاز به پیش‌بینی مقدار متغیر یا متغیرهای مستقل نیز می‌باشد در حالی که در روش‌های سری زمانی، وقفه‌های یک متغیر جهت پیش‌بینی مقدار آتی همان متغیر به کار می‌رود. تجزیه و تحلیل سری‌های زمانی به‌طور نظری و عملی از زمان شروع کار اصلی جورج.ای.پی. باکس و ام.جنکینس در سال ۱۹۷۰ تحت عنوان تجزیه و تحلیل

سری‌های زمانی، پیش‌بینی و کنترل به سرعت توسعه پیدا نمود. ویژگی‌های تصادفی بودن پدیده‌های هیدرولوژیکی سبب شده هیدرولوژیست‌ها از مفاهیم متغیرهای تصادفی و سری‌های زمانی در مدل‌سازی و پیش‌بینی متغیرهای هیدرولوژیکی کمک بگیرند (میان‌آبادی و افشار، ۱۳۷۸). کاربرد سری‌های زمانی در هیدرولوژی از چهار دهه پیش آغاز شده و با ارائه مدل‌های باکس و جنکینز به اوج خود رسید (عزیزی، ۱۳۸۴). دو کاربرد مهم مدل‌های آماری، پیش‌بینی و ساخت اطلاعات می‌باشد. منظور از پیش‌بینی سری‌های زمانی تخمین مقدار یک متغیر در افق زمانی آینده یا در زمانی است که اطلاعات آن ثبت نشده است. هر چند توصیف رفتار یک سری زمانی از لحاظ تغییرات موضعی و دراز مدت در آن یا مطالعه وابستگی‌های موجود بین عناصر سری از بررسی‌های متداولی است که روی سری‌های زمانی انجام می‌شود، اما می‌توان گفت مهم‌ترین هدف از تحلیل سری زمانی پیش‌بینی مقادیر آینده آن است. ساخت اطلاعات یک سری زمانی عبارت است از تولید تعداد مشخصی از متغیرهای آن سری، به‌طوری که اطلاعات تولید شده به لحاظ خواص آماری مشابه با سری زمانی مورد نظر باشد. تفاوت اساسی بین عملیات پیش‌بینی و ساخت اطلاعات در این است که در انجام پیش‌بینی، افق زمانی مشخص و محدود می‌باشد. در حالی که در تولید و ساخت اطلاعات، افق زمانی خاص را نمی‌توان در نظر داشت اما انتظار این است که رفتار و تغییرات خاص یک سری زمانی در سری بلند مدت ساخته شده، آشکار شده باشد. در مسائل عملی افق پیش‌بینی‌های سری‌های زمانی هیدرولوژیکی حداکثر چندین ماه می‌باشد، در حالی که با توجه به نیاز می‌توان یک سری زمانی را تا چند صد سال تولید نمود. به طور کلی مدل‌سازی سری زمانی در مراحل زیر صورت می‌پذیرد.

انتخاب مدل: مشخصات آماری یک سری زمانی در مقایسه با خواص مدل‌های مختلف تعیین می‌کند که چه نوع مدلی برای بیان رفتار یکی سری زمانی مفید می‌باشد. مدل‌های مختلف

دومین یا به‌طور کلی d امین تفاضل سری و مدل‌سازی آن با $ARMA(p, q)$ منجر به پیدایش سری جدیدی از مدل‌های آماری موسوم به مدل‌های آریما غیر فصلی گردید. اگر سری مورد نظر پریودیک یا فصلی باشد (مانند یک سری ماهانه با اختلاف ۱۲ ماه)، مدل پریودیک (آریما (p, d, q)) تعریف می‌شود. ترکیب دو مدل پریودیک و غیرپریودیک آریما، مدل مرکب یا پیچیده آریما را به وجود می‌آورد. مدل‌های آریما سری‌ها را با استفاده از عملگر تفاضل ایستا می‌کنند، حصول به اطلاعات اصلی نیازمند انتگرال‌گیری از (برای یک سری پیوسته) و یا محاسبه مجموع (برای یک سری گسسته) سری‌ها تفاضل شده می‌باشند. ضرایب مدل آریما همانند مدل $ARMA$ تعیین می‌شود با این تفاوت که سری موردنظر به صورت تفاضل آماده شده است. جهت تعیین مرتبه مدل یعنی مقادیر p, d, q همان طوری که گفته شد، مینیمم درجه تفاضل که باعث از بین رفتن نا ایستایی می‌شود، به عنوان درجه تفاضل (d) انتخاب می‌شود، برای یافتن مقادیر p و q نیز مانند مدل $ARMA$ از تست آکایکه (AIC) مناسب به نظر می‌رسد (Salas et al., 1980).

تخمین پارامترهای مدل آریما

در مدل آریما تفاضل سری اصلی با هر مرتبه و تناوبی که لازم باشد انجام می‌گیرد تا سری حاصل ایستا شود. پارامترهای ساده مدل آریما در این حالت همان پارامترهای مدل $ARMA$ می‌باشد. که از مدل‌سازی سری ایستا شده حاصل می‌گردد. بنابراین محاسبه این پارامترها نیز همانند مدل‌ها $ARMA$ انجام می‌گیرد.

نتایج و بحث

شبکه‌های عصبی مصنوعی

یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است شناخت بهترین ساختار شبکه‌های عصبی مصنوعی و طراحی شبکه جهت تخمین سطح ایستابی یا تراز آب زیرزمینی در منطقه مطالعاتی مرحله اول مدل‌سازی توسط شبکه‌های عصبی مصنوعی می‌باشد. به این منظور ساختارهای شبکه‌های عصبی مصنوعی که متشکل از

آماری مانند مدل‌های خود همبسته¹¹ (AR)، میانگین متحرک¹² ($ARMA$)، آریما¹³ ($ARIMA$) و... هر کدام در کارایی‌های خاص خود را دارند. هریک شامل مجموعه‌ای از مدل‌ها با پارامترهای گوناگون می‌باشند و می‌توانند به عنوان متغیرهای ممکن برای مدل‌سازی استفاده شوند.

تعیین نوع مدل: در این قسمت هریک از مدل‌های منتخب با توجه به رفتار و حافظه بلند مدت یا کوتاه مدت سری زمانی تعیین می‌گردد. به عنوان مثال انتخاب مدل $ARMA(1,1)$ از بین انواع مدل‌های آریما تصمیمی است که در مورد انتخاب نوع مدل در این گام انجام می‌گیرد.

تخمین پارامترهای مدل: در این مرحله پارامترهای مدل‌های تعیین شده در گام قبلی محاسبه می‌شوند. روش‌های مختلف آماری برای تعیین پارامترها نظیر روش گشتاورها، کمترین مربعات و ماکزیمم درست‌نمایی در این مرحله مورد استفاده قرار می‌گیرند.

صحت‌سنجی مدل‌ها: در این قسمت توانایی مدل منتخب در مدل‌سازی سری زمانی با استفاده از معیارهای مختلف سنجیده می‌شود. از جمله معیارهای مختلف می‌توان آزمون نرمال بودن و استقلال باقیمانده‌ها در زمان را نام برد. آزمون‌های ذکر شده می‌توانند جهت تعیین بهترین مدل آماری برای یک سری زمانی مورد استفاده قرار بگیرند، بنابراین ممکن است گام‌های عملیاتی ذکر شده در مدل‌سازی به‌طور متناوب برای انتخاب و آزمون مدل‌های مختلف و در نهایت انتخاب برترین گزینه به عنوان مدل منتخب کار گرفته شوند.

مدل میانگین متحرک تجمعی خود همبسته آریما:

اگر یک سری زمانی دارای میانگین ثابت نبوده اما تغییرات یا تفاضل تغییرات این پارامتر ایستا باشد، می‌توان با استفاده از عملگر تفاضل آن سری زمانی را ایستا نمود. استفاده از اولین،

¹¹ Auto Regressive

¹² Auto Regressive Moving Average


¹³ Auto Regressive Integrated Moving Average

نرون‌های پردازشگر در لایه دوم و تابع خطی (Purlin) در لایه سوم مورد استفاده قرار گرفت (Nadiri et al., 2014). توابع انتقال با آزمون و خطا به گونه‌ای انتخاب شد که میانگین مربعات خطا (MSE) در دو مجموعه‌ی آموزش و آزمایش کمینه گردید، مقادیر ضریب همبستگی و میانگین مربعات خطا برای مرحله آموزش و آزمایش در جدول (۱) ارائه شده است. به منظور پیش‌بینی سطح آب زیرزمینی به کمک شبکه‌های عصبی مصنوعی، شبکه چندلایه پرسپترون با الگوریتم آموزشی لوببرگ-مارکوارت به عنوان کاراترین شبکه شناخته شد. به طوری که با کمترین MSE و بیشترین مقدار R^2 به عنوان بهترین مدل شبکه عصبی مصنوعی شناخته شده است.

جدول ۱. مقدار خطای شبکه عصبی مصنوعی با ساختارهای مختلف.

نوع شبکه	FFN						RNN					
	LM		GC		BP		LM		GC		BP	
الگوریتم آموزش												
معیار ارزیابی	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE
مرحله آموزش	۰/۷۸	۰/۰۶۷	۰/۶۸	۰/۱۲۳	۰/۷۲	۰/۷۹	۰/۷۵۳	۰/۴۳۴	۰/۷۱۱	۰/۷۱	۰/۶۶۲	۰/۵۶
مرحله آزمایش	۰/۸۰	۰/۰۶۱	۰/۶۱۲	۰/۰۷۳	۰/۷۴۵	۰/۴۹۸	۰/۶۹۴	۰/۵۴۹	۰/۶۶۹	۰/۷۹	۰/۶۳	۰/۶۱


ایستایی مدل شبکه عصبی مصنوعی با مقادیر مشاهداتی در برخی نقاط وجود دارد. به گونه‌ای که در شکل (۳-ب) این امر مشهود است که مدل مذکور در تخمین نقاط بیشینه و کمینه ضعیف عمل کرده است.



(ب)

شبکه‌های (FFN) و (RNN) است با الگوریتم‌های مختلف از جمله الگوریتم‌های انتشار خطا به عقب (BP)، الگوریتم گرادیان مزدوج (CG) و الگوریتم لوببرگ-مارکوارت (LM) مورد بررسی و مطالعه قرار گرفتند. پارامترهای سطح ایستایی در دوره زمانی ماه قبل، دبی جریان، دما و بارش در دوره زمانی t به عنوان لایه‌های ورودی شبکه استفاده شدند. با توجه به اینکه تعداد نرون‌ها در لایه مخفی در راستای کمینه کردن خطا و بیشینه کردن دقت مدل، بهینه‌سازی می‌شوند بنابراین با استفاده از روش آزمون و خطا، تعداد نرون‌ها در لایه میانی سه به دست آمد. تابع تانژانت هیپربولیک که به عنوان بهترین تابع برای مدل‌سازی سیستم‌های طبیعی غیرخطی تشخیص داده شده‌اند، به عنوان تابع تبدیلگر

نمودار مقادیر مشاهداتی و محاسباتی در شکل ۳ نشان داده شده است که داده‌های مشاهداتی مربوط به ۱۴۴ داده از چاه‌های مشاهداتی مربوط به است. همان‌طور که در شکل (۳-الف) مشخص است تطابق مقادیر محاسباتی میزان سطح



(الف)


شکل ۳- الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی

نتایج مدل فازی


روش کاهشی برای دسته‌بندی داده‌ها در روش فازی استفاده گردید. پارامتر اصلی در این روش دسته‌بندی برای تعیین دسته‌ها و قوانین اگر آنگاه شعاع دسته‌بندی است. توابع عضویت با استفاده از دسته‌بندی کاهشی توسط دستور $\text{genfis2}(\text{datin}, \text{datout}, r)$ تعیین گردید که در آن، datin داده‌های ورودی، datout داده‌های خروجی و r شعاع دسته‌بندی است که بین صفر تا یک متغیر است. تعریف مقدار بزرگ شعاع دسته‌بندی منجر به تولید تعداد کمی دسته می‌شود و تعریف مقادیر کوچک، تعداد زیادی دسته کوچک تولید خواهد کرد. هر یک از دسته‌ها، نماینده یک تابع عضویت می‌باشد و هر تابع عضویت نیز نشانگر یک مجموعه فازی در داده‌ها می‌باشد که برای استخراج قوانین به کار می‌رود. کاهش این پارامتر باعث افزایش دسته‌ها و قوانین می‌شود و افزایش آن به سمت یک باعث کاهش دسته‌ها و قوانین خواهد بود. بازده مدل فازی بستگی به تعیین شعاع بهینه دسته‌بندی دارد که در برآورد سطح ایستابی مقدار بهینه آن به روش آزمون و خطا ۰/۷ تعیین شد. توابع عضویت استفاده شده برای مدل‌سازی فازی سطح ایستابی، تابع عضویت گوسی بود که به داده‌های دسته‌بندی شده برازش داده شد و نیز تابع عضویت خروجی مدل سوگنو تابعی است خطی که بر اساس ورودی‌ها ساخته می‌شود. جدول (۲) نتایج ارزیابی عملکرد مدل‌سازی فازی در مراحل آموزش و آزمایش را نشان می‌دهد.

جدول ۲. نتایج ارزیابی عملکرد مدل منطق فازی در مراحل آموزش و آزمایش

معیار ارزیابی	R^2	MSE
مرحله آموزش	۰/۸۹	۰/۰۵۸
مرحله آزمایش	۰/۸۶	۰/۰۴۷



(ب)



(الف)


شکل ۴- الف (مقادیر محاسباتی و مشاهداتی نسبت به زمان ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی برای داده‌ها

نتایج سری‌های زمانی


برای مدل‌سازی سطح آب زیرزمینی توسط سری زمانی که روش‌های متفاوتی مثل مدل خودهمبستگی (AR)، مدل میانگین خود همبسته (ARMA) و مدل میانگین متحرک (MA) وجود دارد. برای این منظور از بین نرم‌افزارهای مختلف، نرم‌افزار برای مدل‌سازی استفاده گردید. مدل آریما توسط نرم‌افزار SPSS به عنوان بهترین مدل در پیش‌بینی سطح آب زیرزمینی برای هر کدام از پیرومترها

استاندارد کردن داده‌های ورودی نیز در این مدل‌سازی صورت گرفته است. در صورت ناهمگن بودن سفره و استرس‌های وارده به آن مثل برداشت زیاد از آبخوان، می‌توانند دقت پیش‌بینی مدل را پایین بیاورند و باعث ضعیف بودن نتایج گردند که در این‌گونه موارد استفاده از مدل‌های غیر خطی می‌تواند نتایج قابل قبول‌تری داشته باشد. شکل ۵ مدل سری زمانی اجرا شده برای پیش‌بینی سطح آب زیرزمینی دشت عجب‌شیر با استفاده از مدل آریمای نشان می‌دهد بر اساس پیش‌بینی مدل آریمای سطح آب زیرزمینی پیش‌بینی شده روندی تقریباً برابر با روند سال‌های ۱۳۸۵ تا ۱۳۹۶ را نشان می‌دهد که به عدم وجود تغییرات زیاد در تراز آب زیرزمینی می‌باشد. پیش‌بینی انجام شده برای این دشت دارای R^2 برابر با ۰/۸۳ و مقدار RMSE برابر با ۰/۵۸ می‌باشد که دلیل دقت پیش‌بینی بالا به خاطر نبود نوسانات زیاد در سطح ایستابی می‌باشد.

انتخاب شد. در مرحله اول از مدل‌سازی روند سری‌ها مورد بررسی قرار گرفت و سری‌هایی که دارای روند بودند، روند آن‌ها حذف گردید و با برازش مدل‌های مناسب به داده‌های مورد نظر مقدار پارامترها برای ماه‌های آینده پیش‌بینی گردید. برای بررسی صحت مدل‌های برازش داده شده به داده‌ها باقیمانده‌های مدل از نظر نرمال بودن و خودهمبستگی مورد بررسی قرار گرفت. همچنین ضرایب همبستگی (R^2)، جذر میانگین مربعات خطا (RMSE)، برای بررسی ارتباط داده‌های مشاهداتی و پیش‌بینی شده مورد بررسی قرار گرفت. تعیین تابع خود همبستگی و خود همبستگی جزئی سری زمانی نیز پس از نرمال و استاندارد کردن داده‌های سطح آب زیرزمینی انجام گرفت. با استفاده از تابع‌های خود همبستگی و خود همبستگی جزئی می‌توان ضرایب مدل‌های سری زمانی و مرتبه مدل را به دست آورد. همچنین ایستا و



الف)



شکل ۵. الف) پیش‌بینی سطح آب زیرزمینی دشت عجب‌شیر توسط مدل سری زمانی (ب) توابع خودهمبستگی و خودهمبستگی جزئی

نتیجه‌گیری

برخی مقادیر کمینه، بیشینه و میانی نسبت به سایر مدل‌ها دارد. به‌منظور پیش‌بینی سطح آب زیرزمینی به کمک شبکه‌های عصبی مصنوعی، شبکه چندلایه پرسپترون با الگوریتم آموزشی لوبز-مارکوارت به‌عنوان کاراترین شبکه شناخته شد. به‌طوری که با کمترین MSE و بیشترین مقدار R^2 به‌عنوان بهترین مدل شبکه عصبی مصنوعی شناخته شده در صورتی که سایر ساختارهای شبکه عصبی مصنوعی به‌طور میانگین از MSE و R^2 بالاتری برخوردار بودند. نتایج این مدل نشان می‌دهد که در تخمین نقاط بیشینه و کمینه ضعیف عمل کرده است و این نقاط را نزدیک به مقداری واقعی‌شان تخمین زده است. بر اساس نتایج مدل منطق فازی ساگو دارای بیشترین بازده، کمترین درصد خطا و توانایی بالایی در پیش‌بینی سطح ایستابی این دشت نسبت به شبکه عصبی می‌باشند. در مجموع بیان می‌گردد که استفاده از مدل منطق فازی می‌تواند در زمینه تخمین سطح آب زیرزمینی مؤثر باشد و می‌تواند به نوبه خود برای تسهیل، توسعه و پیاده‌سازی استراتژی‌های مدیریت آب‌های زیرزمینی مفید باشد. با توجه به

عدم وجود داده‌های کافی برای توسعه مدل‌های ریاضی به علت محدودیت‌های زمانی و هزینه‌ای و همچنین زمان زیاد لازم جهت اجرای مکرر این مدل‌ها خصوصاً در شرایط ترکیب با مدل‌های بهینه‌سازی به‌منظور یافتن سناریوی بهینه مدیریت آب زیرزمینی، کاربرد مدل‌های ریاضی را با محدودیت مواجه می‌کند. در چنین شرایطی، مدل‌های مبتنی بر هوش مصنوعی، ماشین‌های یادگیری و سری زمانی می‌توانند جایگزین مناسبی به شمار آیند. در پژوهش حاضر عملکرد مدل‌های شبکه عصبی، منطق فازی و سری زمانی برای مدل‌سازی سطح آب زیرزمینی دشت عجب‌شیر با استفاده از پارامترهای بارش، دما، دبی جریان و تراز سطح ایستابی در طی دوره آماری (۱۳۹۶-۱۳۸۵) مورد ارزیابی قرار گرفت و مقادیر سطح آب زیرزمینی مشاهداتی با سطح آب زیرزمینی تخمین زده‌شده این مدل با استفاده معیارهای ارزیابی بررسی گردید. نتایج تحقیق نشان داد که مدل منطق فازی دقت بالا و خطای ناچیزی در تخمین سطح آب زیرزمینی داشته و قابلیت بسیار بالایی در تخمین

- Nadiri, A., Asgharimghdam, A., Abghari, H., Fijani, A. 2012. Development of composite artificial intelligence models in the estimation of aquifer transferability, Case study: Tasuj plain. Iranian Water Resources Research. 9: 1-14.
- ASCE. 2000. Task Committee on Application of Artificial Neural Networks in Hydrology, Part I and II. Journal of Hydrology. 5(2): 115-137.
- Daliakopoulos, I.N., Coulibaly, P., Tsanis, I.K. 2005. Groundwater level forecasting using artificial neural networks. Journal of Hydrology. 309(4): 229-240.
- Demuth, H., Beale, M. 2000. Neural Network Toolbox User, s Guide, By the Math Works. Inc Version. 4: 840pp.
- Dixon, B.A. 2010. Case study using support vector machines, neural networks and logistic regression in a GIS to identify wells contaminated with nitrate-N. Journal of Hydrogeology. 17(6): 1507-20.
- Feng, S., Kang, S., Huo, Z., Chen, S., Mao, X. 2008. Neural networks to simulate regional groundwater levels affected by human activities. Groundwater. 46(1): 80-90.
- Hopfield, J.J. 1982. Neural network and physical systems with emergent collective computational abilities. Proc. Nat, Academy of scientists. 79: 2554-2558.
- Nadiri, A., Chitsazan, N., Tsai, F.T.-C., Asghari Moghaddam, A. 2014. Bayesian artificial intelligence model averaging for hydraulic conductivity estimation. Journal of Hydrologic Engineering. 19(3): 520-532.
- Norouzi, H., Asghari Mogaddam, A. and Nadiri, A.A. 2016. Determining vulnerable areas of Malikan Plain Aquifer for Nitrate, Using Random Forest method. Journal of Environmental Studies. 41(4): 923-94.
- Norouzi, H., Nadiri, A.A., Moghaddam, A.A., Gharekhani, M. 2018. Comparing Performans of Fuzzy Logic, Artificial Neural Network and Random Forest Models in Transmissivity Estimation of Malekan Plain Aquifer, Journal of ecohydrology. 5(3): 739-751. doi.org/10.22059/ije.2018.239914.707
- Philip Plumb, A., Rowe, R.C., York, P., Brown, M. 2005. Optimisation of the predictive ability of artificial neural network (ANN) models: A comparison of three ANN programs and four classes of training algorithm. European Journal of Pharmaceutical Sciences. 25(5): 395-405.
- Rani Sethi, R., Kumar, A., Sharma, S.P., Verma, H.C. 2010. Prediction of water table depth in a hard rock basin by using artificial neural network. International Journal of Water Resources and Environmental Engineering. 2(4): 95-102.
- Sun, Y., Wendi, D., Kim, D.E., Liong, S.Y. 2015. Application of artificial neural networks in groundwater table forecasting—a case study in
- نتایج مشاهده شده در این پژوهش و صرف وقت زیاد برای دستیابی به مقادیر دقیق تر، می توان با ترکیب چند روش هوش مصنوعی با یکدیگر در زمان انجام محاسبات صرفه جویی نموده و سریع تر به مقادیر دقیق تر دست یافت.
- منابع
- عزیزی، ق. ۱۳۸۴. بررسی خشک سالی ها، ترسالی ها و امکان پیش بینی آن ها با استفاده از مدل سری زمانی در استان هرمزگان. فصلنامه تحقیقات جغرافیایی. شماره ۶۳-۴.
- نیرومند، ح.، بزرگ نیا، ا. ۱۳۷۲. مقدمه ای بر سری های زمانی (ترجمه). انتشارات دانشگاه فردوسی مشهد. ۲۸۹ص.
- میان آبادی، ح.، افشار، ع. ۱۳۷۸. کاربرد سری های زمانی ماهانه پربودیک در تولید رواناب ماهانه و مدیریت یکپارچه منابع آب حوضه کشف رود. سومین کنفرانس مدیریت منابع آب ایران، تبریز، ایران.
- Abarashi, F., Moftah Heghi, M., Sani Khani, H., Dehghani, A.A. 2014. Comparison of performance of three intelligent methods in order to predict static level fluctuations (Case study: Zerling plain). Water and Soil Conservation Studies. 21(1): 163-180.
- Adamowski, J., Chan, H., 2011. A wavelet neural network conjunction model for groundwater level forecasting. Water Resources Management journal. 407(1-4): 28-40.
- Chitsazan, M., Rahmani, G., Neyamadpour, A., 2013. Groundwater level simulation using artificial neural network: a case study from Aghili plain, urban area of Gotvand, south-west Iran. Journal of Geope. 3(1): 35-46.
- Moosavi, V., Vafakhah, M., Shirmohammadi, B., Behnia, N., 2013. A Wavelet-ANFIS Hybrid Model for Groundwater Level Forecasting for Different Prediction Periods. Water Resources Management journal. 27(5): 1301-1321.
- Pourmohammadi, S., Malekinejad, H., Pourshriyati, R. 2013. Comparison of the Efficiency of Neural Network Techniques and Time Series in Groundwater Forecasting (Case Study: Bakhtegan Basin of Fars Province). Water and Soil Conservation. 20(4): 251-262.
- Khasheiy Siyuki, A., Ghahreman, B., Koochakzade, M. 2012. Comparison of Artificial Neural Network Models, ANFIS and Regression in Estimating the Staging Level of the Aquifer in Neishabour Plain. Irrigation and drainage of Iran. =7: 10-22.

- Singapore swamp forest. *Hydrology and Earth System Science*. 12: 9317–9336.
- Tayfur, G., Nadiri, A., Asghari Moghaddam, A. 2014. Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resources Management*. 28: 1173–1184.
- Capilla, C. 2008. Time series analysis and identification of trends in a Mediterranean urban area, *Global and Planetary Change*. 63: 275–281