



پیش‌بینی تراز آب زیرزمینی دشت شاهرود با استفاده از شبکه عصبی مصنوعی تابع پایه شعاعی

فرزانه اکبرزاده^۱، حمید حسن‌پور^۲ و صمد امامقلی‌زاده^۳

۱ و ۲- دانشجوی دکتری و استاد، دانشگاه صنعتی شاهرود
۳- دانشیار، دانشگاه صنعتی شاهرود، (نویسنده مسوول: s_gholizadeh517@shahroodut.ac.ir)
تاریخ دریافت: ۹۲/۷/۱ تاریخ پذیرش: ۹۲/۱۲/۱۳

چکیده

پیش‌بینی تراز آب زیرزمینی به منظور مدیریت و برنامه‌ریزی منابع آب، بسیار مهم است. برای انجام این پیش‌بینی، از روش‌های متعددی مانند روش‌های استوکستیک، منطق فازی و شبکه عصبی مصنوعی می‌توان استفاده نمود. در تحقیق حاضر، مدل شبکه عصبی مصنوعی RBF هیبرید برای پیش‌بینی تراز آب زیرزمینی دشت شاهرود مورد استفاده قرار گرفته است. این هیبرید بودن شبکه باعث افزایش دقت روش نسبت به شبکه RBF پایه می‌شود. بدین منظور آمار ماهانه تراز ایستابی دشت شاهرود و همچنین داده‌های هواشناسی مانند دما، بارندگی، رطوبت و تبخیر، داده‌های آب‌های سطحی مانند دبی ورودی و خروجی به دشت شاهرود (دبی ورودی مجن آبشار، دبی ورودی تاش فرحزاد و دبی خروجی قلعه نو) طی یک دوره آماری ۱۹۹۴ تا ۲۰۱۰ استفاده شده است. بررسی داده‌ها نشان می‌دهد که برخی از داده‌ها، هم‌بسته بوده و دارای الگوی فصلی هستند، این مسأله، پیش‌بینی داده‌ها را دشوار می‌کند. بر این اساس، روش ارائه شده در این مقاله شامل مراحل غیرفصلی سازی، نرمال‌سازی و حذف داده‌های وابسته است که پیش از این به آن در تحقیقات پرداخته نشده است. سپس از ۸۵ درصد داده‌ها برای آموزش و از ۱۵ درصد آنها، برای تست مدل استفاده شده است. در نهایت، بررسی نتایج نشان می‌دهد که مدل شبکه عصبی ارائه شده، تراز آب دشت شاهرود را برای سه سال پایایی با میانگین مربعات خطای ۰/۰۲۵۷ متر برای سال اول، ۰/۰۲۷۰ متر در سال دوم و ۰/۰۴۵۲ متر در سال سوم می‌تواند پیش‌بینی کند. همچنین در صورتی که بارش منطقه در یک سال، ۳۰ درصد کاهش یابد، نتایج پیش‌بینی مدل مذکور نشان می‌دهد که تراز آب زیرزمینی ۰/۷ کاهش می‌یابد.

واژه‌های کلیدی: تراز آب زیرزمینی، دشت شاهرود، مدل شبکه عصبی مصنوعی RBF، داده فصلی

مقدمه

(Fuzzy Logic) به طور گسترده، در زمینه‌های مختلف برای پیش‌بینی سری زمانی استفاده شده‌اند (۲۲). روش ANN، ابزاری کارآمد محسوب می‌شود که در مدل‌سازی سیستم‌های پیچیده هیدروژئولوژیکی به کار می‌رود. انواع مختلفی از ساختارهای ANN وجود دارد که از میان آنها می‌توان به شبکه‌های عصبی پیشرو (FFN)^۱، شبکه‌های بازگشتی (RN)^۲، شبکه‌های توابع پایه شعاعی (RBF)^۳ و شبکه‌های پرسپترون چند لایه (MLP)^۴ اشاره نمود. محققان زیادی از روش شبکه‌های عصبی در هیدرولوژی، هیدرولیک و هیدروژئولوژی مانند مدل‌سازی فرآیند بارش- رواناب، پیش‌بینی بارندگی، پیش‌بینی ذوب برف - رواناب، پیش‌بینی انتقال رسوب، مدل‌سازی آب‌های زیرزمینی و پاسخ اکولوژیکی تغییرات اقلیمی و عملکرد ذخایر آبی استفاده نمودند (۱، ۴، ۶، ۷، ۸، ۲۲). بررسی‌های انجام شده نشان می‌دهد اغلب پیش‌بینی‌های سیستم‌های هیدروژئولوژیکی از راه شبکه عصبی پیش‌رو با الگوریتم آموزش انتشار بازگشتی خطا انجام شده است (۴). این

در بیش‌تر مناطق ایران، منابع آب‌های سطحی محدود هستند و حتی در بعضی مناطق، این منابع وجود ندارند. بر این اساس در بعضی مناطق با برداشت آب از چاه‌های عمیق و نیمه‌عمیق، نیازهای آبی برآورده می‌شود. احداث بی‌رویه این چاه‌ها طی سال‌های گذشته، سبب تنزل شدید تراز آب‌های زیرزمینی شده است. براین اساس، پیش‌بینی تراز آب زیرزمینی برای مدیریت صحیح و برنامه‌ریزی آینده بسیار مهم و ضروری است. داده‌های مورد بررسی برای انجام پیش‌بینی تراز آب زیرزمینی به صورت سری‌های زمانی با ویژگی فصلی هستند.

تحلیل و پیش‌بینی چنین داده‌هایی با استفاده از روش‌های معمول، امکان‌پذیر نیست. تاکنون روش‌های متعددی برای حل مشکل فصلی بودن داده‌ها معرفی و استفاده شده است (۱۵، ۳).

در سال‌های اخیر، تکنیک‌ها و روش‌های مختلفی مانند شبکه‌های عصبی مصنوعی (ANNs)^۱ و منطق فازی

1- Artificial Neural Networks

2- Feed-Forward Neural Networks

3- Recurrent Networks

4- Radial Basis Function Networks

5- Multilayer Perceptron Networks

نشده است. نبود توجه به فصلی بودن داده‌ها، موجب کاهش دقت مدل‌ها در پیش‌بینی داده‌ها می‌شود.

شبکه RBF به وسیله محققین مختلف برای پیش‌بینی تراز آب زیرزمینی استفاده شده است؛ برای مثال، می‌توان به کارهای انجام شده از سوی سلطانی (۱۸) اشاره نمود. وی از این مدل، به منظور پیش‌بینی‌های کوتاه‌مدت و بلندمدت جریان ورودی به سد علویان استفاده نمود.

پیش‌بینی‌های انجام شده شامل میانگین سه روز، یک هفته، ده روز، دو هفته، یک ماه، دو ماه، سه ماه و شش ماه آینده بود که به منظور مدیریت و تدوین سیاست‌های بهینه بهره‌برداری از مخزن سد انجام شد. منتظر و همکاران (۱۰) شبکه RBF را برای پیش‌بینی هوشمند افزایش عمق در بالادست پل مورد بررسی قرار دادند. نتایج تحقیق آن‌ها نشان داد که مدل با دو لایه میانی به خوبی می‌تواند برای تخمین فرا آب ناشی از پایه‌های پل مورد استفاده قرار گیرد. قوسه و همکاران (۱۳) از مدل شبکه عصبی RBF برای تحلیل پیش‌بینی عمق آب زیرزمینی در چهار ایستگاه مختلف در سمبلپور (ناحیه غربی اوریسای هند) استفاده کردند. آموتا و پورچلوان (۱) برای پیش‌بینی سطح زیرزمینی مالاتار در هندوستان از شبکه RBF استفاده کرده و نتایج کار را با نتایج ANFIS مقایسه نموده‌اند. اسرینیواسلو و دکا (۱۹) با استفاده از شبکه RBF در شرایطی که داده‌های در دسترس محدود بود، اقدام به پیش‌بینی سطح آب زیرزمینی در ناحیه‌ای بین موکا و مونجارا در هندوستان نموده‌اند.

نتایج محققین مختلف، نشان‌دهنده قدرت شبکه RBF در پیش‌بینی تراز آب زیرزمینی است. با وجود دقت و توانمندی شبکه RBF، در تحقیقات ذکر شده به فصلی بودن داده‌ها توجهی نشده است.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه، دشت شاهرود و حوزه آبخیز آن مشتمل بر دشت بسطام و مجن در جنوب ارتفاعات البرز، در مسیر جاده اصلی تهران- مشهد قرار گرفته است. از نظر جغرافیایی، این دشت در محدوده ۳۶ درجه و ۱۵ دقیقه تا ۳۶ درجه و ۳۰ دقیقه عرض شمالی و ۵۴ درجه و ۴۵ دقیقه تا ۵۵ درجه و ۱۵ دقیقه طول شرقی قرار گرفته است (شکل ۱). دشت شاهرود، مخزن اصلی آبخوان شاهرود بوده و حجم قابل توجهی از آب مورد نیاز مصارف کشاورزی منطقه را تأمین می‌کند. وسعت این محدوده، ۱۳۱۲/۳ کیلومتر مربع بوده که ۶۵۰/۷ کیلومتر آن، شامل دشت و ۶۶۱/۶ کیلومتر آن، شامل ارتفاعات

شبکه‌ها علی‌رغم سادگی و سرعت بالا، دارای معایبی هستند. استفاده از این الگوریتم، ملزم به تکرار زیاد تعداد دفعات آموزش است، علاوه بر این، خطر اشکال در مینیمم محلی در این روش بسیار زیاد است (۱۷).

تحقیقات گسترده‌ای از سوی محققین داخلی و خارجی در زمینه شبکه‌های عصبی مصنوعی صورت گرفته است که بعضی از آن‌ها به صورت مختصر توضیح داده می‌شود. فتاحی و همکاران (۹) با استفاده از شبکه عصبی مصنوعی پیشرو، جریان رودخانه‌های کارون شمالی را پیش‌بینی نمودند. ایشان در پژوهش خود، از الگوریتم ژنتیک برای تعیین داده‌های مؤثر و نیز انتخاب تعداد نرون‌های لایه مخفی شبکه استفاده نموده‌اند. روش مطرح شده از طرف آن‌ها، رویکردی برای مواجهه با مشکل فصلی بودن داده‌ها ارائه نداده است. این نقصان، نتایج به دست آمده را تحت تأثیر قرار داده است. نیک‌منش و رخشنده‌رو (۱۲)، توانایی شبکه‌های عصبی مصنوعی پیش‌رو، برگشتی و توابع پایه شعاعی را در پیش‌بینی تراز آب زیرزمینی در آبخوان محدوده سعادت‌شهر فارس مورد بررسی قرار دادند. ایشان ادعا نمودند که شبکه عصبی مصنوعی پیشرو با الگوریتم آموزش لونیبرگ-مارکوارت، بهترین نتایج را ارائه می‌دهد. این تحقیق نیز، از نبود انتخاب استراتژی مناسب برای روبرویی با داده‌های فصلی رنج می‌برد، به علاوه در آن تحقیق، نسبت به نحوه انتخاب داده‌های مؤثر در حل مسأله بررسی لازم انجام نشده است.

زارع ایبانه و همکاران (۲۱) براساس داده‌های هواشناسی، تراز ایستابی دشت ملایر را با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه با الگوریتم آموزشی لونیبرگ-مارکوارت شبیه‌سازی کردند.

نتایج تحقیق آن‌ها نشان داد که این مدل، دارای توانایی مناسب برای شبیه‌سازی تراز ایستابی دشت مذکور بوده و لذا این مدل را به عنوان ابزاری با سرعت و دقت مناسب برای تصمیم‌گیری در مدیریت دشت توصیه کردند. این تحقیق نیز دارای مشکلاتی مشابه است. محتشمی و همکاران (۱۱)، تراز ایستابی دشت بیرجند را با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه پیش‌بینی کردند.

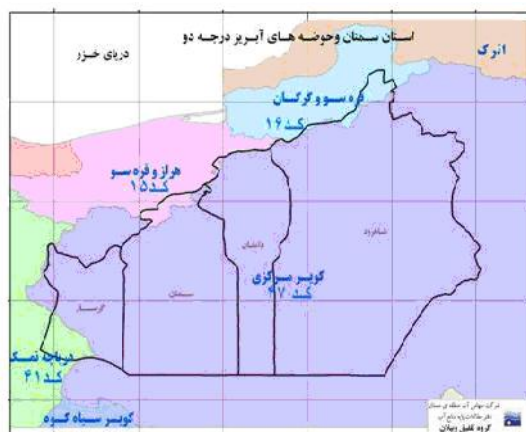
علی‌رغم نتایج اولیه مناسب در این تحقیق، با افزایش تعداد ماه‌های پیش‌بینی شده، دقت پیش‌بینی‌ها کاهش می‌یابد. در تحقیق دیگری نیز از روش‌های شبکه عصبی بازگشتی (RNN)، ANFIS و مدل‌های اتفافی برای پیش‌بینی آب دریاچه Egirdir در ترکیه استفاده شده است (۱۴). در روش‌های مطرح شده در این مقاله نیز، رویکردی برای مواجهه با مشکل فصلی بودن داده‌ها ارائه

پیش‌بینی تراز آب زیرزمینی دشت شاهرود با استفاده از شبکه عصبی مصنوعی تابع پایه شعاعی ۱۰۶

است (شکل ۲). بر اساس داده‌های جمع‌آوری شده از اداره امور آب شاهرود، تعداد ۲۳۸ حلقه چاه عمیق و نیمه‌عمیق فعال در محدوده مطالعاتی وجود دارد که عمدتاً برای مصارف کشاورزی مورد استفاده قرار می‌گیرند.



شکل ۱- تصویر ماهواره‌ای منطقه مورد مطالعه.



شکل ۲- تفکیک زیرحوضه‌های استان سمنان.

شاهرود، چندین متغیر از داده‌های هواشناسی مورد بررسی قرار گرفتند که از آن جمله می‌توان به میزان بارندگی، تبخیر، رطوبت و دمای هوا، دبی ورودی آبشار مچن، دبی ورودی آبشار تاش فرحزاد و دبی خروجی رودخانه قلعه‌نو اشاره نمود. مشخصات آماری داده‌های مورد استفاده با طول آماری هفده سال (۱۹۹۴ تا ۲۰۱۰) در جدول ۱ آمده است. هم‌چنین تغییرات سری زمانی ماز سوی ماهانه هر کدام از این متغیرها در شکل ۳ نشان داده شده است.

روش کار

مراحل انجام پژوهش به شرح زیر است:

- الف- آماده‌سازی و آنالیز داده‌ها شامل بررسی هم‌بستگی داده‌ها، حذف داده‌های افزونه و غیره.
 - ب- پیش‌پردازش داده‌ها شامل غیرفصلی سازی داده‌ها.
 - ج- نرمال‌سازی داده‌ها.
 - د- پیش‌بینی تراز آب زیرزمینی با استفاده از شبکه RBF. آماده‌سازی و آنالیز داده‌ها
- به منظور پیش‌بینی تراز آب زیرزمینی دشت

جدول ۱- مشخصات آماری داده‌های مورد استفاده برای پیش‌بینی سطح آب زیرزمینی دشت شاهرود

بارندگی (mm)	رطوبت (%)	دما (°C)	تبخیر (mm)	دبی ورودی مجن آبشار (MCM)	دبی ورودی تاش فرحزاد (MCM)	دبی خروجی قلعه نو شاهرود (MCM)	سطح آب زیرزمینی (m)
۰	۲۹	-۲/۹	۰	۰/۰۱۴	۰	۰	۱۳۷۲/۵۸
۷۱/۷۰	۷۳/۰۰	۳۰/۰۰	۴۳۵/۱۰	۲/۴۱	۴/۸۵	۵/۷۵	۱۳۸۹/۵۰
۱۱/۷۲	۴۵/۹۲	۱۵/۷۶	۱۵۶/۶۳	۰/۴۲	۰/۸۰	۰/۱۲	۱۳۸۱/۰۴
۱۳/۷۵	۱۰/۷۹	۸/۹۳	۱۳۱/۷۰	۰/۴۱	۰/۷۵	۰/۴۹	۵/۰۶

MCM: ملیون متر مکعب


است. دبی ورودی مجن آبشار، دبی ورودی تاش فرحزاد و دبی خروجی قلعه نو به علت وابستگی به میزان بارش می‌تواند فصلی در نظر گرفته شود. اما همان‌طور که در شکل ۳ نشان داده شد، این داده‌ها رفتاری دقیقاً فصلی از خود نشان نمی‌دهند که علت آن، وجود متغیرهای مؤثر دیگری است که فصلی نیستند.

غیرفصلی ساختن داده‌ها


سری‌های زمانی با رفتار فصلی، یک سری زمانی دنباله‌ای داده‌ها هستند که معمولاً بیانگر مشاهدات اندازه‌گیری شده در فواصل زمانی مساوی هستند. داده‌های سری زمانی، اغلب از روال خاصی پیروی می‌کنند و این روال، بستگی به متغیرهایی دارد که داده‌ها را تشکیل داده‌اند. در بعضی مواقع، داده‌ها روندی صعودی و یا نزولی دارند که شبکه عصبی تا حدودی قابلیت انطباق بر روی آنها را داراست. اما در بعضی از داده‌ها، این روند به صورت دوره‌ای و فصلی است که دلیل آن، ماهیت متغیرهای تشکیل‌دهنده آن است؛ برای مثال، می‌توان داده‌های تغییرات جوی را نام برد که به علل متفاوتی مانند زمان، از یک مسیر تکراری و پریودیک وابسته به فصل (بازه زمانی) تبعیت می‌کنند.

شبکه‌های عصبی به خوبی قادر به پیش‌بینی چنین داده‌هایی نیستند و نتایج کار آنها معمولاً با واقعیت تطابق نخواهد داشت. برای حل این مشکل، باید داده‌ها قبل از اعمال به شبکه پیش‌پردازش شوند. برای پیش‌پردازش کردن، باید ویژگی‌های فصلی را از داده‌ها جدا کرد و داده غیرفصلی شده را به شبکه اعمال نمود (۱۶). با چنین رویکردی پس از انجام پیش‌بینی از راه شبکه عصبی، لازم است که اعمال عکس روی خروجی‌ها به منظور تبعیت از فصل مربوطه انجام شود تا خروجی نهایی به دست آید.



همان‌طوری که در شکل ۳ مشخص است، تغییرات تراز آب زیرزمینی دشت شاهرود روی یک منحنی با رفتار فصلی به صورت نزولی است، اغلب متغیرهای مسأله، رفتاری فصلی و تعدادی نیز رفتاری غیرفصلی دارند. میزان بارندگی در طول سال به شرایط جوی مربوط است و مهم‌ترین عامل آن، ماه‌های سال است؛ برای مثال، در ماه‌های اول، یازدهم و دوازدهم کم‌ترین میزان بارندگی و در ماه‌های ششم، هفتم و هشتم، بیش‌ترین میزان بارندگی را داراست. در شکل ۳- الف، میزان بارندگی برحسب میلی‌متر در ماه برای هفده سال متوالی از منطقه مورد بررسی نشان داده شده است. از روی این شکل به راحتی می‌توان فصلی بودن (تناوبی بودن) رفتار این متغیر را مشاهده نمود. دمای محیط به طور مشخص، وابستگی زیادی به زاویه تابش خورشید و فاصله زمین تا خورشید دارد، با توجه به مدار زمین، این داده کاملاً فصلی بوده و هر ۱۲ ماه به طریق مشابه تکرار می‌شود. البته المان‌های دیگری مانند آلودگی هوا و میزان گازهای گلخانه‌ای محیط نیز در این متغیر مؤثر هستند که ممکن است باعث تغییرات اندکی در رفتار فصلی دما شود. شکل ۳- ب، رفتار متغیر دما در هفده سال متوالی از محیط مورد بررسی را نشان می‌دهد. متغیر رطوبت نیز وابسته به دو پارامتر دما و بارش باران است. با توجه به تناوبی بودن رفتار پارامترهای دما و باران، انتظار می‌رود که این متغیر نیز فصلی باشد که شکل ۳- ج، این موضوع را تأیید می‌نماید. المان‌های اصلی مؤثر بر متغیر تبخیر، میزان درجه حرارت و میزان رطوبت است. با توجه به فصلی بودن این دو متغیر می‌توان نتیجه گرفت که متغیر تبخیر نیز فصلی باشد. با توجه به سری زمانی در شکل ۳- (چ)، این متغیر، رفتاری فصلی دارد و دوره تناوب آن، همان دوره تناوب متغیرهای درجه حرارت و رطوبت (۱۲ ماه در سال)




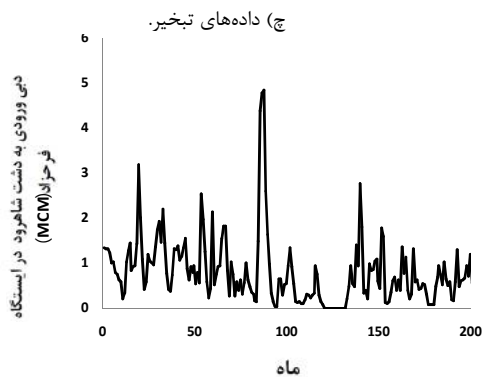
ب) داده‌های دما.





الف) داده‌های بارندگی.



ج) داده‌های رطوبت نسبی.



د) داده‌های ورودی آب مجن آبشار.



ر) داده‌های دبی خروجی قلعه نو.

ز) تراز آب زیرزمینی دشت شاهرود.

شکل ۳- مقادیر داده‌های هواشناسی و تراز آب زیرزمینی دشت شاهرود بر حسب ماه‌های متوالی از سال ۱۹۹۴ تا ۲۰۱۰.

$$X_i' = \frac{X_i}{\sqrt[p]{\sum_{i=1}^N |X_i|^p}} \quad \text{رابطه (۱)}$$

انتخاب متغیرهای مناسب

بررسی میزان وابستگی داده‌های ورودی در انتخاب آنها مهم است، چرا که اگر دو یا چند متغیر نسبت به هم وابستگی خطی داشته باشند، لازم نیست همه آنها به صورت ورودی به شبکه عصبی اعمال شود. وجود ورودی افزونه، باعث کند شدن روند هم‌گرایی شبکه عصبی و حتی کاهش دقت شبکه می‌شود. روش‌های مختلفی برای بررسی مستقل یا وابسته بودن داده‌ها وجود دارد که در این تحقیق از بررسی هم‌بستگی دو داده استفاده می‌شود. چنانچه میزان هم‌بستگی دو داده نزدیک به یک باشد، این دو داده به یکدیگر وابستگی خطی دارند. بررسی هم‌بستگی داده‌های مختلف این تحقیق در جدول ۱ نمایش داده شده است. هر چه این عدد به یک نزدیک‌تر باشد، هم‌بستگی بیش‌تری را نشان می‌دهد. همان‌طور که از این جدول مشخص می‌شود، سه داده رطوبت، دما و تبخیر به یکدیگر وابسته هستند، بنابراین داده تبخیر به صورت نماینده این سه داده استفاده شده و داده‌های رطوبت و دما در آموزش شبکه شرکت داد نمی‌شوند.

نرمال‌سازی داده‌ها

هدف از نرمال‌سازی داده‌ها، یکسان‌سازی اهمیت ورودی‌های مختلف به شبکه عصبی است؛ برای مثال، اگر یکی از ورودی‌های شبکه در بازه [۱۰۰۰۰۰ ... ۱] و دیگری در بازه [۱ ... ۱۰۰] قرار گیرد، شبکه باید برای ورودی اول، وزن‌های بسیار کوچک و برای دومی، وزن‌های بسیار بزرگ را انتخاب کند که عملاً یادگیری را دچار مشکل می‌کند. در واقع هنگامی که بازه تغییرات ورودی‌های شبکه مشابه مثال فوق، یکسان نیست، شبکه فرض خواهد کرد که یک ورودی هزاران برابر مهم‌تر از ورودی دیگر است. شبکه شاید بتواند وزن‌های درست را پیدا کند، اما در صورتی که بازه تغییرات یکسان باشد، فرآیند یادگیری به مراتب آسان‌تر خواهد بود. معمولاً برای حل این مشکل تمامی داده‌ها به بازه [۱ ... -۱] نگاشته می‌شوند که به این عمل، نرمال‌سازی گویند.

روش‌های مختلفی برای نرمال‌سازی داده‌ها وجود دارد. در این تحقیق از روش نرمال‌سازی انرژی (۲۱) استفاده شده است. این روش، یک برداری مانند x را با استفاده از رابطه (۱) نرمال می‌سازد:

جدول ۲- هم‌بستگی داده‌ها

بارندگی	رطوبت	دما	تبخیر	آبشار	فرحزاد	قلعه نو
۱	۰/۴۷۱	۰/۴۰۶	۰/۳۸۸	۰/۱۰۹	۰/۲۹۵	۰/۵۰۷
رطوبت	۱	۰/۸۷۴**	۰/۸۳۷**	۰/۳۵۹	۰/۲۳۲	۰/۶۳۸
دما		۱	۰/۹۶۹**	۰/۳۹۵	۰/۲۵۵	۰/۰۳۵
تبخیر			۱	۰/۴۰۵	۰/۲۵۰	۰/۰۳۲
آبشار				۱	۰/۰۶۹	۰/۲۱۹
فرحزاد					۱	۰/۲۳۳
قلعه نو						۱

** همبستگی معنی‌دار در سطح ۵ درصد

در این تحقیق از یک شبکه عصبی RBF هیبرید برای پیش‌بینی داده‌ها استفاده شده است. این شبکه هیبرید از دو طبقه شبکه RBF ساده ساخته شده است که در ادامه شرح داده می‌شود. برای پیش‌بینی تراز آب زیرزمینی دشت شاهرود، داده‌های مربوط به ۱۴ سال برای آموزش شبکه استفاده شده است. هدف از این پژوهش، پیش‌بینی داده‌های مربوط به سال‌های پانزدهم، شانزدهم، هفدهم و مقایسه نتایج آنها با مقادیر واقعی ثبت شده است. هر یک از متغیرهای مورد بحث، به یک شبکه RBF مجزا اعمال

شبکه RBF، یک شبکه دو لایه با معماری تک‌برایه است که در لایه اول، یک نگاشت خطی با تابع گوسی انجام می‌شود و در لایه دوم، طبقه‌بندی انجام می‌گردد. رابطه (۲)، نحوه محاسبه خروجی شبکه RBF را نشان می‌دهد (۲):

$$y = \sum_{i=1}^M W_i w(X) + b = \sum_{i=1}^M W_i e^{-\frac{\|x - \tilde{x}_i\|^2}{u}} + b \quad \text{رابطه (۲)}$$

در رابطه فوق، W بیانگر وزن یال‌ها، b بایاس و w تابع فعال‌ساز گوسی با مرکز \tilde{x} و پراکندگی u است.

چهاردهم که ورودی محسوب می‌شود، به شبکه داده می‌شود. برای انجام پیش‌بینی سال شانزدهم، در شبکه‌های لایه اول از مقادیر پیش‌بینی شده این لایه برای سال پانزدهم به صورت یکی از سال‌های ورودی استفاده می‌شود (مقادیر دو سال قبل‌تر نیز موجود است). برای مثال برای پیش‌بینی بارندگی در اردیبهشت سال شانزدهم، مقادیر بارندگی اردیبهشت سال سیزدهم و چهاردهم به اضافه میزان بارندگی پیش‌بینی شده اردیبهشت سال پانزدهم به گونه‌ای ورودی به شبکه داده می‌شود. در شبکه‌های لایه دوم نیز به طریق مشابه از خروجی شبکه‌های لایه اول و تراز آب پیش‌بینی شده سال پانزدهم برای ورودی استفاده می‌شود. با همین روال می‌توان تراز آب در سال‌های آتی را نیز پیش‌بینی نمود.

ارزیابی


قدرت روش، از راه معیار میانگین مربعات خطا (MSE) سنجیده می‌شود. در این معیار مربع تفاوت مقدار پیش‌بینی شده و مقدار اندازه‌گیری شده سطح آب در دوازده ماه سال سنجیده می‌شود و نهایتاً میانگین این مقادیر، مانند معیار برازش پیش‌بینی انجام شده استفاده می‌شود. رابطه (۳) نحوه محاسبه مقدار میانگین مربعات خطا را نشان می‌دهد.

$$MSE = \frac{\sum (Y - T)^2}{n} \quad \text{رابطه (۳)}$$


که در آن، Y: مقدار پیش‌بینی شده، T: مقدار خروجی مورد انتظار و n: تعداد داده‌هاست که در این مسأله برابر ۱۲ (تعداد ماه‌های سال) است.

می‌شود تا بتواند به طور مستقل و مجزا، هر یک از آنها را پیش‌بینی نماید. این شبکه خود از یک دسته دوازده‌تایی از شبکه‌های RBF ساده، هر کدام برای یک ماه مشخص، تشکیل می‌شود (شکل ۶). هر کدام از این شبکه‌های RBF ساده، دارای پنج نرون مخفی با پراکندگی پنج و تابع مولد گوسی هستند (شکل ۷). مقادیر اولیه وزن‌های شبکه به صورت تصادفی بین صفر تا یک انتخاب می‌شوند. این مقادیر با آزمون و خطا با توجه به سرعت و دقت شبکه به دست آمده است.

برای آموزش شبکه‌های لایه اول (بارندگی، تبخیر، دبی ورودی مجن، دبی ورودی تاش فرحزاد و دبی خروجی قلعه‌نو) به ازای داده مربوط به سه سال گذشته، داده یک سال آینده پیش‌بینی می‌شود؛ برای مثال، داده‌های مربوط به بارندگی اردیبهشت ماه سال اول، دوم و سوم به شبکه اعمال شده و این شبکه، بارندگی سال چهارم را پیش‌بینی می‌کند. لایه اول جمعاً دارای ۶۰ شبکه موازی به ازای دوازده ماه سال برای پنج ورودی بارندگی، تبخیر، دبی ورودی مجن، دبی ورودی تاش فرحزاد و دبی خروجی قلعه‌نو است. حال برای پیش‌بینی تراز آب زیرزمینی (شبکه لایه دوم)، نیاز به ۱۲ شبکه RBF موازی (از نوعی که در شکل ۷ نشان داده شد) برای پیش‌بینی تراز آب در دوازده ماه مختلف سال است. برای این پیش‌بینی علاوه بر خروجی‌های لایه اول، از تراز آب سال گذشته نیز استفاده می‌شود؛ به عنوان مثال، برای پیش‌بینی تراز آب در اردیبهشت سال پانزدهم، میزان بارندگی، تبخیر، دبی ورودی مجن، دبی ورودی تاش فرحزاد و دبی خروجی قلعه‌نو در اردیبهشت سال پانزدهم (خروجی شبکه‌های اردیبهشت لایه اول) همراه با تراز آب اردیبهشت سال



شکل ۶- شبکه RBF پیشنهادی برای پیش‌بینی تراز آب دشت شاهرود.




شکل ۷- یک نمونه از شبکه RBF لایه اول.


نتایج و بحث

همان‌گونه که پیش‌تر گفته شد هر کدام از شبکه‌های RBF ساده، دارای پنج نرون مخفی با پراکندگی پنج و تابع مولد گوسی هستند. پس از این‌که شبکه‌ها آموزش دیدند و مقدار وزن‌های مناسب برای آن‌ها پیدا شد، از آن‌ها برای پیش‌بینی سطح آب سال‌های آتی استفاده می‌شود. برای ارزیابی روش پیشنهادی در پیش‌بینی تراز آب زیرزمینی،


پس از آموزش شبکه‌های لایه اول و دوم، داده‌های هواشناسی سال دوازدهم، سیزدهم و چهاردهم و نیز تراز آب سال چهاردهم به صورت ورودی به شبکه داده شده و تراز آب سال پانزدهم پیش‌بینی می‌شود. شکل‌ها و جداول زیر، مقادیر نتایج پیش‌بینی آب زیرزمینی سال پانزدهم را نشان می‌دهند.



(ب)



(الف)



(ج)


شکل ۸- الف) مقایسه خروجی پیش‌بینی شده و خروجی واقعی سال پانزدهم تراز آب، ب) خطای پیش‌بینی، ج) پراکندگی مقادیر پیش‌بینی شده نسبت به مقادیر واقعی.

مربوط به دو سال آینده یعنی سال شانزدهم نیز پیش‌بینی می‌شود. در این پیش‌بینی از داده‌های پیش‌بینی شده سال پانزدهم به صورت ورودی برای پیش‌بینی سال شانزدهم استفاده می‌شود.


مجموع مربعات خطای پیش‌بینی تراز آب زیرزمینی دشت شاهرود در سال پانزدهم، ۰/۰۲۵۷ است. این میزان خطا به علت وجود خطای اندازه‌گیری و خطای ذاتی شبکه‌های عصبی است. پس از سال پانزدهم، داده‌های

۰/۰۲۷۰ است. به روش مشابه سال شانزدهم، داده‌های مربوط به سال هفدهم نیز پیش‌بینی می‌شود. شکل ۱۰ نتایج به دست آمده را نشان می‌دهد.


شکل ۹ مقادیر پیش‌بینی واقعی تراز آب در سال شانزدهم و هم‌چنین خطای پراکندگی و مقادیر پیش‌بینی شده را نسبت به مقادیر واقعی نشان می‌دهد. مجموع مربع خطای پیش‌بینی در دوازده ماه سال شانزدهم، برابر



(ب)





(الف)




(ج)

شکل ۹- الف) پیش‌بینی واقعی تراز آب سال شانزدهم، ب) خطای پیش‌بینی، ج) پراکندگی مقادیر پیش‌بینی شده نسبت به مقادیر واقعی.



الف)




ج)

شکل ۱۰- الف) پیش‌بینی واقعی تراز آب سال هفدهم، ب) خطای پیش‌بینی، ج) پراکندگی مقادیر پیش‌بینی شده نسبت به مقادیر واقعی.

زیرزمینی نیز بررسی شد. برای این مهم در مرحله آزمایش داده، بارندگی به میزان ۳۰ درصد کاهش داده شد (خشکسالی). سپس تراز آب سال پانزدهم با این تغییرات پیش‌بینی شد. در شکل ۱۱ نتایج کار را نشان داده شده است.

مجموع مربع خطای پیش‌بینی در دوازده ماه سال شانزدهم، برابر ۰/۰۴۵۲ است. خطای پیش‌بینی سال شانزدهم بیش از سال پانزدهم است. علت این امر تأثیر خطای پیش‌بینی سال پانزدهم و انتشار آن می‌باشد. با استفاده از این شبکه، تأثیر میزان بارندگی در تراز آب



شکل ۱۱- پیش‌بینی واقعی تراز آب سال پانزدهم با ۳۰ درصد کاهش بارندگی.

ابتدا داده‌های هواشناسی سال شانزدهم به کمک شبکه‌های RBF جداگانه پیش‌بینی می‌شود. سپس به کمک این داده‌ها و داده‌های پیش‌بینی شده تراز آب سال پانزدهم، پیش‌بینی برای سال شانزدهم نیز انجام می‌شود. به طریق مشابه پیش‌بینی‌ها برای سال هفدهم نیز تکرار می‌شود. نتایج به دست‌آمده، میانگین مربعات خطای ۰/۰۲۵۷ متر برای یک سال آینده و ۰/۰۲۷۰ متر را برای دو سال متوالی و ۰/۰۴۵۲ متر برای سال سوم از پیش‌بینی نشان می‌دهد. بنابراین می‌توان برای پیش‌بینی سال‌های بعد نیز از روش مشابه استفاده نمود. جدول ۳ میزان مجموع مربعات خطای به دست آمده برای یک سال را با نتایج حاصل شده از سوی سایر محققان که همگی از شبکه RBF استفاده نموده‌اند، مقایسه می‌کند.

لازم به ذکر است در صورتی که بارش منطقه ۳۰ درصد کاهش یابد، تراز آب زیرزمینی به مقدار ۰/۷ متر کاهش می‌یابد. در تحقیق به عمل آمده تلاش شد تا با کمک شبکه‌های RBF، داده‌های مربوط به تراز آب زیرزمینی دشت شاهرود برای دو سال آینده پیش‌بینی شود. برای انجام پیش‌بینی، ابتدا روی داده‌ها پردازش‌هایی شامل حذف ورودی‌های افزونه، حذف فصلی بودن داده‌ها و نرمال‌سازی داده‌ها انجام شد. سپس داده‌های هواشناسی همان سال پانزدهم (بارندگی، تبخیر، دبی ورودی مجن، دبی ورودی تاش فرحزاد و دبی خروجی قلعه نو) و داده‌های مربوط به تراز آب در سال چهاردهم، به صورت ورودی برای انجام این پیش‌بینی به شبکه RBF داده شد. برای پیش‌بینی تراز آب در سال بعد نیز

جدول ۳- مقایسه مجموع مربعات خطای به دست آمده با نتایج به دست آمده از سوی سایر محققان

محققین خطا	اموتا در مالاتار (۱)	اسرینیواسلو و دکا (۱۹)	دهقانی و همکاران (۵)	روش پیشنهادی در دشت شاهرود
MSE	۱۸/۷۸۶۱	۰/۶۳۵۲	۱۱/۰۱۳	۰/۰۲۵۷

مانع از استفاده از ظرفیت‌های شبکه RBF در پیش‌بینی شده است.

تشکر و قدردانی

این تحقیق با حمایت مالی شرکت سهامی آب منطقه‌ای سمنان با کد پروژه SEW89003 و دانشگاه شاهرود انجام شده است. بدین وسیله نویسندگان مقاله مراتب تشکر و قدردانی را دارند.

اسرینیواسلو و دکا (۱۹) در تحقیقات خود پیش‌بینی را برای یک هفته آینده انجام داده‌اند. همان‌گونه که از جدول ۳ مشاهده می‌شود میزان خطای روش پیشنهادی تحقیق حاضر بسیار کمتر از سایر مطالعات است. علت این امر غیرفصلی‌سازی داده‌ها، استفاده از چندین عامل مؤثر در تراز آب برای پیش‌بینی و استفاده از شبکه هیبرید در انجام پیش‌بینی است. عدم توجه به فصلی بودن داده‌ها در سایر مطالعات

منابع

1. Amutha, R. and P. Porchelvan. 2011. Seasonal Prediction of Groundwater Levels Using Anfis and Radial Basis Neural Network, *International Journal of Geology, Earth and Environmental Sciences*, 1: 98-108.
2. Bortman, M. and M.A. Aladjem. 2009. Growing and Pruning Method for Radial Basis Function Networks, *IEEE Transactions on Neural Networks*. 20: 1039-1045.
3. Constantinos, S., M. Hilas, K. Sotirios, J. Goudos and N. Sahalos. 2006. Seasonal Decomposition and Forecasting of Telecommunication Data: A Comparative Case Study, *Technological Forecasting & Social Change*, Elsevier. 73: 495-509.
4. Coulibaly, P., F. Anctil and B. Bobee. 2000. Daily Reservoir Inflow Forecasting Using Artificial Neural Networks with Stopped Training Approach. *Journal of Hydrology*, 230: 244-257.
5. Dehghani, A., A. Asgari and M. Mosaedi. 2009. Comparison of Geostatistics, Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System Approaches in Groundwater Level Interpolation (Case Study: Ghazvin Aquifer), *Journal of Agricultural Sciences and Natural Resources*, 16 (special issue 1-b): 517-536 (In Persian).
6. Emamgholizadeh, S., S.M. Bateni and D.S. Jeng. 2013. Artificial Intelligence-Based Estimation of Flushing Half-Cone Geometry. *Engineering Application Artificial Inteligence*, 26: 2551-2558.
7. Emamgholizadeh, S., H. Kashi, I. Marofpoor and E. Zalaghi. 2013. Prediction of Water Quality Parameters of Karoon River (Iran) by Artificial Intelligence-Based Models. *International Journal of Environmental Science Technology*. 11: 645-656, DOI: 10.1007/s13762-013-0378-x.
8. Emamgholizadeh S; K. Moslemi, G. Karami. 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: 5433-5446. DOI: 10.1007/s11269-014-0810-0.
9. Fatahi, E., M. Delavar and K. Noohi. 2012. Prediction River Flow of North Karoon Using Artificial Neural Networks. *Geography Research*, 104: 51-78 (In Persian).
10. Montazer, G., M. Ghodsi, F. Nasiri, M. Javan and A. Eghbalzadeh. 2003. Intelligent Prediction of Water Using Artificial Neural Network Based on Radial Basis Functions, *Modares Technical and Engineering*. 14: 49-62 (In Persian).
11. Mohtashami, M., A. Dehghani, A. Akbarpour, M. Mefta Halghi and B. Ehtebari. 2010. Groundwater Level Determination by Using Artificial Neural Network (Case Study: Birjand Aquifer). *Iranian Journal of Irrigation and Drainage*, 1: 1-10 (In Persian).
12. Nikmanesh, M.R. and G.R. Rakhshandehroo. 2011. Forecasting Groundwater Level in Saadat Shahr Plain, Iran, Using Artificial Neural Networks. *Water Resource*, 7: 82-86 (In Persian).
13. Ghose, D.K., P.S. Sudhansu and P.C. Swain. 2010. Prediction of Water Table Depth in Western Region, Orissa Using BPNN and RBFN Neural Networks. *Journal of Hydrology*. 394: 296-304.
14. GÜldal, V. and T. Hakan. 2010. Comparison of Recurrent Neural Network, Adaptive Neuro-Fuzzy Inference System and Stochastic Models in Egirdir Lake Level Forecasting. *Water Resource Management*. 24: 105-128.
15. Livera, A.M., R.J. Hyndman and R.D. Snyder. 2011. Forecasting Time Series with Complex Seasonal Patterns Using Exponential Smoothing. *Journal of American Statistical Association*. 106: 1513-1527.
16. Tseng, F.M., H.C. Yu and G.H. Tzeng. 2002. Combining Neural Network Model with Seasonal Time Series ARIMA model. *Technological Forecasting and Social Change*, 9: 71-87.
17. Slowik, A. and M. Bialko. 2008. Training of Artificial Neural Networks Using Differential Evolution Algorithm, Krakow, Poland, pp: 25-27, pp: 60-65.
18. Soltani, S. 2002. Evaluation of Artificial Neural Network in Predicting Short-term Stream Flow. M.Sc. Thesis, Tarbiat Modarres University, 157 pp (In Persian).
19. Sreenivasulu, D. and P.C. Deka. 2011. Groundwater Level Forecasting Using Radial Basis Function with Limited Data, *International Journal of Earth Sciences and Engineering*, 4: 1064-1067.
20. Yu, Z., S. Mason and G. Birch. 2003. Impact of Energy Normalization Transform on the Performance of the LF-ASD Brain Computer Interface, *Advances in Neural Information Processing Systems* 16: 1-8.
21. Zare Abyaneh, H., M. Bayat Varkeshi, S. Marofi and A.R. Ildromi. 2011. Simulation of Malayer Plain Groundwater Level Based on Weather Data Using Artificial Neural Network. *Physical geography. Res*. 78: 17-28 (In Persian).
22. Zhang, G.P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, *Neurocomputing*, 50: 159-175.

Groundwater Level Prediction of Shahrood Plain using RBF Neural Networks

Farzaneh Akbarzadeh¹, Hamid Hasanpour² and Samad Emamgholizadeh³

1 and 2- PhD. Student and Professor, Shahrood University of Technology

3- Associate Professor, Shahrood University of Technology

(Corresponding Author: s_gholizadeh517@shahroodut.ac.ir)

Received: September 23, 2013

Accepted: March 4, 2014

Abstract

Groundwater level prediction is an important issue in scheduling and managing water resources. A number of approaches such as stochastic, fuzzy networks and artificial neural network have been used for such prediction. A neural network model has been employed in this research for Shahrood plain groundwater level prediction. For this reason, statistical parameters of groundwater level fluctuations for 16 successive years 1994 to 2010, have been used and also, weather forecasting parameters for 16 successive years from 1994 to 2010 have used. This study indicates that some of the data are correlated and possessed a seasonal pattern. This issue makes difficult the forecasting process. Hence, the proposed method employed policies for non season analyzing, normalizing, and ignoring the correlated date. 85% of the data for train and the rest for testing the proposed neural networks model have used. Results indicate that the proposed method can predict groundwater level of Shahrood Plain for three successive years with the mean square errors of 0.0257m, 0.0270m and 0.0452m. Also, the prediction shows that if the precipitation decreases 30 percent in a year, the groundwater level will decrease 0.7 m.

Keywords: Groundwater level, RBF Neural Networks, Seasonal Data, Shahrood Plain