

پیش بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت بیرجند)

محسن محتشم^۱، امیر احمد دهقانی^{۲*}، ابوالفضل اکبرپور^۳، مهدی مفتاح هلقی^۴ و بهروز اعتباری^۵

چکیده

آبهای زیرزمینی همواره به عنوان یکی از منابع مهم و عمده تامین آب شرب و کشاورزی به ویژه در مناطق خشک و نیمه خشک مطرح بوده است. دشت بیرجند نیز با قرار گرفتن در منطقه خشک، استفاده از آبهای زیرزمینی را به عنوان مهمترین و در عین حال تنهاترین منبع تولید آب شیرین در پیش رو دارد. در همین زمینه پیش بینی نوسانات سطح آب زیرزمینی دشت می تواند کمک شایانی به برنامه ریزی و تصمیم گیری های بعدی، جهت تامین دراز مدت آب شرب، کشاورزی و صنعت نماید. در این تحقیق هدف تخمین سطح آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی مصنوعی می باشد. روش شبکه عصبی مصنوعی یکی از روشهای هوشمند می باشد که با استفاده از ارتباط ذاتی داده ها، روابط غیر خطی بین آنها را یاد گرفته و نتایج را برای بقیه حالتها تعمیم می دهد. بمنظور آموزش مدل، از اطلاعات ۱۶ پیژومتر که اغلب دارای بیش از ۱۵ سال آمار بودند، استفاده گردید. ورودی های مدل، میزان برداشت آب از چاههای آب شرب، صنعت و کشاورزی، میزان آب ورودی به هر پلیگون بر حسب متر مکعب (ناشی از بارندگی منطقه) و تراز سطح آب در هر پیژومتر در گام زمانی قبل و خروجی مدل، تراز سطح آب در گام زمانی فعلی بوده است. بر خلاف تحقیقات گذشته که از اطلاعات تبخیر از سطح گیاه مرجع به عنوان شاخص برداشت آب استفاده شده است، در این تحقیق، حجم آب برداشتی در هر ماه از کنتورهای توربینی، الکترومغناطیس و آلتراسونیک، با دقت بسیار بالا محاسبه گردید. در چاههای آب کشاورزی نیز که طیف وسیعی از چاهها را شامل می شد، با توجه به آزمایش پمپاژ، ساعت کارکرد الکترومپ و دبی سنجی های سالانه حجم آب برداشت شده از آبخوان در هر پلیگون محاسبه شد. همچنین از روش شبکه عصبی مصنوعی در دوحالت (برای هر پیژومتر یک شبکه عصبی و یا یک شبکه عصبی برای کل پیژومترها) استفاده شد. نتایج این تحقیق نشان می دهد که با استفاده از روش شبکه عصبی مصنوعی و تدقیق تخمین میزان آب برداشتی می توان سطح آب زیرزمینی را تا ۱۲ ماه بعد و با دقت بالاتر ($MSE=0.032, R^2=0.99$) نسبت به روشهایی که از اطلاعات تبخیر از سطح گیاه مرجع به عنوان شاخص برداشت آب استفاده می کنند، تخمین زد. همچنین در نظر گرفتن شبکه برای تک تک پیژومترها به طور مجزا نسبت به اجرای شبکه برای کل پیژومترها از دقت بالاتری برخوردار است.

واژه های کلیدی: سطح آب زیرزمینی، شبکه عصبی مصنوعی، الگوریتم آموزش، دشت بیرجند

مقدمه

جریانهای سطحی عموماً به صورت سیلابی و پس از هر بارش مشاهده و قطع می گردد. بنابراین در این مناطق مهار و بهره برداری از آبهای سطحی فقط به شکل پروژه های آبخیزداری و در جهت تغذیه آبهای زیرزمینی انجام می گیرد، لذا کلیه برنامه ریزی های کوتاه مدت و دراز مدت تامین آب در این مناطق، بر مبنای حجم آب زیرزمینی در دسترس می باشد.

تاکنون مدل های زیادی جهت پیش بینی سطح آب زیرزمینی به کار برده شده است. از جمله این مدلها می توان به مدل های سری زمانی تجربی و مدل های فیزیکی اشاره کرد (ایزدی و همکاران، ۱۳۸۶). از مدل های سری زمانی تجربی، به طور گسترده ای برای مدل سازی سطح آب زیرزمینی استفاده شده است، ولی هنگامی که رفتار دینامیکی یک سیستم هیدرولوژیکی با گذشت زمان تغییر می کند

آبهای زیرزمینی به عنوان تنها منبع مورد اعتماد مصرف آب در زمینه های شرب، کشاورزی و صنعت در مناطق خشک و نیمه خشک محسوب می شوند. با توجه به اینکه ریزشهای جوی در این مناطق عمدتاً به گونه ای است که در زمانهای محدود اتفاق می افتد، لذا

۲، ۱ و ۴ - دانشجوی کارشناسی ارشد منابع آب، استادیاران گروه مهندسی آب، دانشگاه گرگان

* - نویسنده مسئول: (Email: a.dehghani@gau.ac.ir)

۳ - استادیار دانشگاه بیرجند

۵ - کارشناس ارشد ژئوهیدرولوژی شرکت آب منطقه ای خراسان جنوبی

۱۰۴۵ کیلومتر دشت و بقیه را ارتفاعات تشکیل می‌دهد. این دشت از شرق به ارتفاعات مومن آباد و سیستان، از جنوب به کوه‌های باقران و کوه رج، از شمال به ارتفاعات شاه ناصر و اسفدن و بند دره و از غرب به ارتفاعات چنگ در و گرونک محدود می‌شود. دشت بیرجند طبق طبقه‌بندی اقلیمی دومارتن جزء مناطق خشک محسوب می‌شود. از نظر توپوگرافی مرتفع‌ترین نقطه آن مربوط به ارتفاعات شمالی منطقه در کوه بند دره با ارتفاع ۲۷۸۷ متر و پست‌ترین نقطه آن در خروجی دشت در روستای فدشک با ارتفاع ۱۲۴۰ متر بالاتر از سطح دریا‌های آزاد قرار دارد. شیب زمین در قسمتهای شرقی زیاد و هرچه به سمت غرب و قسمتهای انتهایی دشت حرکت می‌کنیم شیب آن کم و سطح زمین تقریباً حالت مسطح دارد.


دشت بیرجند مانند بسیاری از دشتهای دیگر کشور به دلیل خشکسالی‌های ممتد اخیر و نیز به دلیل برداشتهای بی رویه توسط کشاورزان با افت نسبی مواجه شده است. در همین راستا یکی از متغیرهای در نظر گرفته شده برای برآورد سطح آب زیرزمینی، میزان برداشت آب از سطح سفره آب زیرزمینی می‌باشد. در بسیاری از تحقیقات پیشین متغیرهای در نظر گرفته شده برای پیش بینی سطح آب زیرزمینی، متغیرهای بارندگی، دمای حداکثر، دمای حداقل و متوسط می‌باشد و به دلیل موجود نبودن اطلاعات مربوط به برداشت از سفره آب زیر زمینی در مقیاس ماهیانه در طول دوره مطالعه، متغیر تبخیر-تعرق گیاه مرجع به عنوان معرفی برای برداشت از سفره آب زیرزمینی انتخاب شده است (Coulibaly et al. (2001) و (ایزدی و همکاران، ۱۳۸۶) و (Daliakopoulos et al. (2005).

مدلهای یاد شده برای پیش بینی پارامترهای منابع آب توانایی کافی نداشته و مدل‌های مناسبی نیستند (Bierkens, ۱۹۹۸). از طرف دیگر، مدل‌های فیزیکی نیز در عمل به داده‌های زیادی برای شبیه سازی نوسانات سطح آب زیرزمینی نیاز دارند و از آنجا که روابط بین متغیرهای موثر بر سطح آب زیر زمینی احتمالاً پیچیده و غیر خطی می‌باشد، مدل‌های فوق در ارائه رابطه بین این متغیرها نیز نمی‌توانند به خوبی عمل کنند (Nayak et al., ۲۰۰۶).


با توجه به این شرایط، شبکه‌های عصبی مصنوعی می‌توانند در پیش بینی سطح آب زیرزمینی موثر واقع شوند. در دشت چمچال مدل شبکه عصبی پرسپترون برای شبیه سازی سطح آب زیرزمینی در هر چاهک مشاهده ای مورد استفاده قرار گرفت که نتایج مطلوبی را ارائه نمود (تسلطی ۱۳۸۲). ایزدی در سال ۱۳۸۶ نشان داد پیش بینی سطح آب زیرزمینی در طی ۶ ماه آینده نتایج نسبتاً خوبی را ارائه می‌نماید. متغیرهای ورودی شبکه عصبی در دشت نیشابور شامل سطح آب زیرزمینی در زمان $t-1$ ، تبخیر و تعرق گیاه مرجع و بارندگی در هر پلیگون بوده است (ایزدی و همکاران، ۱۳۸۶). در این تحقیق هدف تخمین سطح آب زیرزمینی دشت بیرجند با استفاده از روش شبکه عصبی مصنوعی و تدقیق تخمین میزان آب برداشتی با استفاده از قرائت کنتورهای توریینی، الکترومغناطیس و آلتراسونیک برای کل پیزومترها می‌باشد.

مواد و روش‌ها

حوزه آبریز بیرجند دارای وسعت ۳۱۵۵ کیلومتر مربع بوده، که



(شکل ۱) - موقعیت مکانی دشت بیرجند در کشور



(شکل ۲) - دشت بیرجند و پیزومترهای انتخابی همراه با پلیگون بندی

الکترومغناطیس و یا آلتراسونیک بودند میزان برداشت‌ها در هر ماه مشخص بود و در چاههای کشاورزی که عمده برداشت توسط آنها صورت می‌گرفت، بر اساس دبی آزمایش پمپاژ و ساعت کارکرد الکترو پمپ، حجم برداشت از هر پلیگون بر حسب متر مکعب محاسبه گردید.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، برای اولین بار در سال ۱۹۴۳ توسط مک کولاک و پیترس معرفی شد، اما این روش برای مدت‌های طولانی بدون استفاده بود که بعدها با توسعه رایانه‌ها و همچنین ظهور الگوریتم آموزش پس انتشار خطا برای شبکه‌های پیش‌خور در سال ۱۹۸۶ توسط راملهارت و همکاران استفاده از آنها وارد مرحله تازه‌ای گردید (مهدی‌زاده، ۱۳۸۳).

شبکه‌های عصبی مصنوعی ترکیبی از بهره‌برداری موازی از المانهای ساده است. این المانها از سیستم عصبی الهام گرفته شده است. می‌توان شبکه عصبی مصنوعی را برای انجام یک تابع عملی به وسیله تنظیم مقادیر ارتباط (وزنها) بین المانها آموزش داد. معمولاً با استفاده از داده‌های واقعی، خروجی شبکه عصبی مصنوعی به خروجی هدف تعیین شده نزدیک می‌شود و شبکه عصبی مصنوعی آموزش می‌بیند. شبکه‌ها بر اساس مقایسه بین خروجی شبکه و خروجی هدف تعدیل می‌شوند، تا هنگامی که خروجی با هدف مطابقت کند (تسلطی، ۱۳۸۲).

در این تحقیق متغیرهای در نظر گرفته شده برای ورودی شبکه عصبی مصنوعی به ترتیب، تراز سطح آب هر پیزومتر در گام زمانی ۱- t ، میزان آب ورودی به هر پلیگون بر حسب متر مکعب که ناشی از میزان بارندگی در آن منطقه می‌باشد و نهایتاً میزان برداشت آب توسط چاههای آب شرب، صنعت و کشاورزی بر حسب متر مکعب در ماه، از هر پلیگون می‌باشد. تعداد ۱۶ پیزومتر که دارای طول آماری به طور متوسط ۱۳۰ ماهه بودند به پیشنهاد کارشناسان آب منطقه‌ای استان خراسان جنوبی انتخاب و در سامانه اطلاعات جغرافیایی برای هر پیزومتر چند ضلعی تیسن مربوطه ترسیم تا امکان مانور برای هر پیزومتر مقدور باشد. به کارگیری چند ضلعی تیسن به این دلیل می‌باشد تا به نوعی فیزیک مسئله نیز در متغیرهای ورودی شبکه‌های عصبی گنجانده شود و همچنین تغییر پذیری فضایی متغیر بارندگی در سطح دشت مد نظر قرار گیرد، بدین صورت متغیرهای هر تیسن می‌تواند تاثیر معنی داری در ارائه نتایج داشته باشد (Copol et ۲۰۰۳).

با توجه به اینکه حوضه از وسعت بالایی برخوردار نبوده و با استفاده از یک ایستگاه هواشناسی که تقریباً در مرکز حوضه قرار داشته و آمار بارندگی آن در طول دوره مطالعه به طور کامل وجود داشت، آب ورودی به هر پلیگون بر اساس میزان بارندگی ایستگاه و سطح هر پلیگون محاسبه شد. حجم آب برداشت شده از آبخوان در هر پلیگون توسط چاههای حفر شده در آن محدوده محاسبه شد. کل چاههای موجود در دشت مورد مطالعه اعم از شرب، صنعت و کشاورزی ۳۱۱ حلقه چاه می‌باشد. برای محاسبه حجم آب برداشت شده از آبخوان، در چاههای آب شرب که عموماً دارای کنتورهای توربینی،

حالات آموزش

در روابط بالا y_o : مقادیر مشاهده شده، y_f : مقادیر پیش بینی شده، n : تعداد داده ها، P : تعداد متغیرهای خروجی و N : تعداد نمونه‌ها در لایه خروجی می‌باشد.

در این مرحله برای هر پیژومتر، به طور متوسط دوازده شبکه مختلف اجرا شد که مقادیر R و خطا در هر بار اجرای شبکه برای چهار بخش آزمون، آموزش، اعتبار سنجی و حالت کلی محاسبه شد. پس از آنکه برای هر پیژومتر استراتژی‌های مختلفی بررسی و آزمون شد، برای هر مرحله بهترین تکرار که کمترین میزان خطا را به خود اختصاص داده بود به عنوان شاخص آن استراتژی در نظر گرفته شد. به عنوان مثال توابع TANSIG، LOGSIG، PURLIN با شبکه‌های مختلف و نرونها متفاوت برای هر لایه بررسی شد که در نهایت بهترین شبکه‌ها عمدتاً رو به جلو پس انتشار خطا شناخته و معرفی شدند (feed forward back prop و case cad forward back prop). بهترین توابع تحریک نیز عموماً تانژنت سیگموئید، با الگوریتم آموزش TRAINLM در لایه‌های اول و دوم شناخته شدند.

کرولوگرام

از کرولوگرامها یا همبستگی نگارها برای تعیین میزان همبستگی پارامترها استفاده می‌شود. عموماً به دلیل شباهت رفتار پارامترهای هیدرولوژیکی در ماههای متوالی و یا ماههای مشابه در سالهای متوالی، بالاترین میزان همبستگی بین این پارامترها بدست می‌آید. البته شرایط زمین شناسی منطقه نیز در نوع رفتار کرولوگرام تاثیر دارد. در این تحقیق با ترسیم کرولوگرام پارامتر تراز سطح آب در ماههای مختلف، میزان همبستگی این پارامتر با تراز سطح آب در ماههای قبل مورد بررسی قرار گرفت.

پارامتر دوم برای ورود به شبکه عصبی، میزان آب ورودی به هر پلیگون در نظر گرفته شد. این پارامتر می‌تواند شاخصی برای تغذیه آبخوان باشد. برای این منظور با استفاده از میزان بارندگی در سطح هر پلیگون و مساحت هر پلیگون، میزان آب ورودی به آن پلیگون بر حسب متر مکعب محاسبه شده است.

پارامتر سوم برای ورود به شبکه عصبی، حجم آب برداشت شده از سفره آب زیرزمینی بود. این پارامتر در تحقیقات مشابه گذشته مورد استفاده واقع نشده بود و برای اولین بار در این تحقیق مورد استفاده قرار گرفت. در تحقیقات گذشته عمدتاً از پارامتر تبخیر و تعرق گیاه مرجع به عنوان شاخص برداشت آب از آبخوان استفاده شده بود. این موضوع بیشتر به دلیل عدم وجود اطلاعات مناسب در خصوص میزان برداشت چاههای منطقه صورت گرفته بود. جهت تعیین میزان برداشت آب از هر پلیگون در چاههای آب شرب، اعم از روستایی و شهری، وجود کنتورهای توربینی، الکترومغناطیس و آلتراسونیک، حجم آب برداشتی را با دقت بسیار بالا در هر ماه ارائه می‌نمود. در

به طور کلی دو حالت آموزش توسعه ای و دسته ای وجود دارد که در آموزش توسعه ای، وزنها و بایاس شبکه، پس از معرفی هر ورودی به شبکه اصلاح می‌شود در حالی که در آموزش دسته ای، وزنها و بایاس تنها بعد از معرفی تمام ورودی‌ها به شبکه اصلاح می‌شوند که در این تحقیق از روش آموزش دسته ای استفاده شده است.

الگوریتم پس انتشار خطا

روش پس انتشار خطا یک روش سیستماتیک برای آموزش شبکه‌های چند لایه است. منظور از آموزش یک شبکه انتخابی، بر مبنای اطلاعات موجود، تنظیم مقادیر وزنها و بایاس یا مقادیر ثابت اولیه و به گونه ای است که خطای بین مقادیر خروجی محاسبه شده و مشاهده شده، حداقل گردد. این الگوریتم مبتنی بر قانون یادگیری اصلاح خطا می‌باشد. از قانون یادگیری پس انتشار برای آموزش شبکه‌های عصبی مصنوعی چند لایه پیش خور که عموماً شبکه‌های چند لایه پرسپترون هم نامیده می‌شوند، استفاده می‌شود. پارامترهای شبکه طوری تنظیم می‌شوند که پاسخ واقعی شبکه هر چه بیشتر به سمت پاسخ مطلوب نزدیکتر شود. استفاده از خروجی‌های واقعی در این نوع از شبکه‌ها سبب قرار گرفتن این شبکه‌ها در گروه آموزش با ناظر شده است.

انتخاب بهترین آرایش شبکه

اساس آموزش شبکه‌های عصبی بر مبنای آزمون و خطا می‌باشد تا بهترین آرایش شبکه با تغییر تعداد لایه‌های پنهان و نرونها آنها، تابع فعالیت، الگوریتم آموزش و تعداد تکرار در مرحله آموزش جهت برآورد پارامتر خروجی مورد نظر ارائه شود (Eizadi et al. (1386). مبنای تصمیم گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه، میانگین خطا، پارامتر Error، ضریب همبستگی R^2 ، کمترین میزان مربعات خطا $\min(MSE)$ و RMSE می‌باشد که در زیر ارائه شده است:

$$R^2 = 1 - \frac{\sum (y_o - y_f)}{\sum y_o^2 - \frac{\sum y_f^2}{n}} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{j=0}^p \sum_{i=0}^n (y_o - y_f)^2}{NP}} \quad (2)$$

$$MSE = \frac{\sum (y_o - y_f)^2}{n} \quad (3)$$

پیزومترها، دارای خطای زیاد و غیر قابل قبول بود که تحقیقات گذشته نیز مؤید این موضوع بوده است. در حالت اجرای برنامه برای تک تک پیزومترها که به طور مجزا انجام شد، نتیجه تخمین تراز سطح آب نه تنها به لحاظ تعداد ماههای قابل تخمین افزایش چشمگیری داشت، بلکه برآوردها از دقت بالایی نیز برخوردار بود.

پیش بینی سطح آب زیرزمینی در ماههای آتی

جدول شماره (۱) نشانگر بهترین شبکه‌های طراحی شده از بین شبکه‌هایی است که برای هر پیزومتر اجرا شده است. در این جدول، بهترین شبکه همراه با بهترین تابع انتقال و الگوریتم آموزش در لایه‌های مختلف و همچنین میزان خطا و همبستگی در بخشهای آموزش، آزمون و اعتبار سنجی ارائه شده است. با توجه به بهترین شبکه ارائه شده می‌توان با دقت مناسبی سطح آب زیرزمینی را در دشت مورد مطالعه تخمین زد. البته ماههایی خاص مانند ماههای اول، دوم، سوم، ششم، دوازدهم، هیجدهم و بیست و یکم در نظر گرفته می‌شود تا بتوان بهترین ماه را از نظر عملکرد شبکه انتخاب کرد و از آن برای تخمین سطح آب زیرزمینی تا آن ماه خاص استفاده کرد (Daliakopoulos et al., ۲۰۰۵)

نتایج حاصل از بکارگیری روش شبکه عصبی مصنوعی در شکل‌های شماره ۴ تا ۸ آمده است. با توجه به نمودارهای ارائه شده برای هر پیزومتر، می‌توان در دشت بیرجند برای ۱۶ پیزومتر مورد بررسی سطح آب را تا ۱۲ ماه آینده با دقت مناسبی پیش بینی کرد. ضمن آنکه در برخی از پیزومترها این دقت در تعداد ماههای بیشتری وجود دارد. مبنای مقایسه در این مرحله نیز R^2 و MSE بین سطح آب پیش بینی شده و مشاهده شده بود. همچنین دقت تخمین در پیزومترهای مرکزی دشت یعنی شماره‌های ۴، ۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲ و ۱۳ از دقت بالاتری نسبت به پیزومترهای طرفین دشت با شماره‌های ۱، ۲، ۳، ۱۴، ۱۵ و ۱۶ برخوردار هستند. از دلایل این امر می‌توان به عدم در نظر گرفتن عامل دوری و نزدیکی پیزومترها به ایستگاه هواشناسی و در نتیجه میزان آب ورودی به هر پلیگون بوده است.


نتیجه گیری

نتایج نشان می‌دهد که در دشت بیرجند با ۱۶ پیزومتر مورد بررسی برآورد تراز سطح آب تا یک سال از دقت بسیار بالایی در تمام پیزومترها برخوردار بوده، ضمن آنکه در برخی دیگر از پیزومترها این دقت تا ۱۸ ماه نیز قابل قبول بود. نگاهی به دشت مورد مطالعه و نمودارها نشان می‌دهد که دقت تخمین تراز سطح آب در تمام پیزومترهای میانی در مقایسه با پیزومترهای طرفین دشت بیشتر است.

چاههای آب کشاورزی که طیف وسیعی از چاهها را شامل می‌شد، با توجه به آزمایش پمپاژ، ساعت کارکرد الکتروپمپ و دبی سنجی‌های سالانه حجم آب برداشت شده از آبخوان در هر پلیگون محاسبه شد. این اطلاعات از مهرماه ۷۶ تا تیر ماه ۸۷ یعنی به میزان ۱۳۰ ماه در هر پلیگون، که ۸۰ ماه آن به عنوان آموزش و ۵۰ ماه دیگر به عنوان صحت سنجی و آزمون مورد استفاده قرار گرفت.

نتایج و بحث

یکی از مهمترین مراحل فرآیند توسعه مدل‌های شبکه عصبی تعیین اهمیت متغیرهای ورودی و تعیین گامهای زمانی پیشین موثر بر متغیر وابسته می‌باشد. معمولاً همه متغیرهای ورودی دارای اهمیت یکسان نبوده و مقادیر برخی از آنها ممکن است توأم با عدم قطعیت بوده و یا اینکه هیچ رابطه معنی داری با متغیر خروجی مدل نداشته باشند (Maier and Dandy, ۲۰۰۰). در شکل (۳) کرولوگرام مربوط به چهار پیزومتر به عنوان نمونه رسم شده است. در این کرولوگرامها میزان همبستگی تراز سطح آب در هر پیزومتر با گامهای زمانی قبلی نمایش داده شده است. همانگونه که از شکل مشخص است، بیشترین همبستگی در گام زمانی $t-1$ (یک ماه قبل) وجود دارد، ضمن آنکه در برخی از پیزومترها در تاخیر دوازدهم نیز همبستگی خوبی دیده می‌شود. دلیل افزایش موضعی در گام ۱۲ در پیزومتر ۱ نیز می‌تواند در اثر شباهت رفتار پارامترهای هیدرولوژیکی در ماههای مشابه در سالهای متوالی باشد. بنابراین، در این تحقیق پارامتر تراز سطح آب در ماه قبل به همراه میزان آب ورودی و آب برداشت شده به هر پلیگون به عنوان ورودی‌ها و تراز سطح آب در زمان t بعنوان خروجی شبکه استفاده گردید.



(شکل ۳) - کرولوگرام سطح آب پیزومترها در گامهای زمانی مختلف


اجرای شبکه‌ها که تقریباً ۲۲۰ بار تکرار شد، در دو حالت و به صورت تک تک برای هر پیزومتر و به صورت کلی برای تمام پیزومترها انجام شد، نتایج ارائه شده در حالت کلی برای تمام

(جدول ۱) - بهترین نتیجه ارائه شده برای هر پیژومتر بر اساس کمترین میزان خطا (MSE)


شماره پیژومتر	نوع شبکه	لایه پنهان			لایه خروجی		epoch	R		MSE			
		الگوریتم آموزش	تابع انتقال	تعداد نرون	تابع انتقال	الگوریتم آموزش		Validation	All	test	train	test	All
۱	Casacad forward backprop Feed	TRAINLM	tandig	۵	tandig	۱۲	TRAINLM	tandig	۰/۹۸۲	۰/۹۵۶	۰/۹۹۳	۰/۰۰۴۸	۰/۰۰۲۶۵
۲	forward back prop Feed	TRAINLM	tandig	۱۰	tandig	۲۴	TRAINLM	tandig	۰/۹۲۸	۰/۹۶۵	۰/۹۹۱	۰/۰۱۳۸	۰/۰۰۸۹
۳	forward back prop Feed	TRAINLM	Purlin	۱۰	Purlin	۳	TRAINLM		۰/۹۶۸	۰/۹۱۲	۰/۹۹۷	۰/۰۰۴۸	۰/۰۰۴۴
۴	Casacad forward backprop	TRAINLM	tandig	۶	tandig	۱۵	TRAINLM	tandig	۰/۹۹۹	۰/۹۸۹	۰/۹۹۹	۰/۰۱۹۵	۰/۰۰۵۵
۵	Casacad forward backprop	TRAINLM	tandig	۱۰	tandig	۸	TRAINLM	tandig	۰/۹۹۵	۰/۹۹۷	۰/۹۹۹	۰/۰۱۴۸	۰/۰۱۳۲
۶	forward back prop Feed	TRAINLM	tandig	۶	tandig	۶	TRAINLM	tandig	۰/۹۹۱	۰/۹۹۶	۰/۹۹۷	۰/۰۰۴۶۱	۰/۰۰۲۸۳
۷	Casacad forward backprop	TRAINLM	tandig	۱۰	tandig	۸	TRAINLM	tandig	۰/۹۹۸	۰/۹۹۸	۰/۹۹۹	۰/۰۱۱۶	۰/۰۰۹۵
۸	forward back prop Feed	TRAINLM	tandig	۶	tandig	۶	TRAINLM	tandig	۰/۹۹۷	۰/۹۹۷	۰/۹۹۹	۰/۰۰۸۳	۰/۰۰۱۴۳
۹	forward back prop Feed	TRAINLM	tandig	۱۰	tandig	۶	TRAINLM	tandig	۰/۹۹۷	۰/۹۹۸	۰/۹۹۹	۰/۰۰۶۷	۰/۰۰۶۸
۱۰	forward back prop Feed	TRAINLM	tandig	۱۰	tandig	۱۰	TRAINLM	tandig	۰/۹۹۶	۰/۹۹۸	۰/۹۹۷	۰/۰۰۶۱	۰/۰۰۳۹
۱۱	forward back prop Feed	TRAINLM	tandig	۱۰	tandig	۳۲	TRAINLM	tandig	۰/۹۹۷	۰/۹۹۷	۰/۹۹۹	۰/۰۰۸۴	۰/۰۰۳۹
۱۲	forward back prop Feed	TRAINLM	tandig	۱۰	tandig	۸	TRAINLM	tandig	۰/۹۸۴	۰/۹۰۸	۰/۹۹۹	۰/۰۰۹۸	۰/۰۱۴۹
۱۳	forward back prop	TRAINLM	tandig	۱۰	tandig	۱۱۲	TRAINLM	tandig	۰/۹۹۷	۰/۹۳۸	۰/۹۹۹	۰/۰۰۲۱۶	۰/۰۰۰۴
۱۴	Casacad forward backprop	TRAINLM	tandig	۱۰	tandig	۱۷	TRAINLM	tandig	۰/۹۹۱	۰/۹۹۵	۰/۹۹۲	۰/۰۰۲۵۹	۰/۰۰۷۷
۱۵	Casacad forward backprop	TRAINLM	tandig	۱۰	tandig	۱۶	TRAINLM	tandig	۰/۹۷	۰/۹۷۹	۰/۹۹	۰/۰۰۱۳	۰/۰۰۰۹
۱۶	forward back prop Feed	TRAINLM	tandig	۸	tandig	۲۴	TRAINLM	tandig	۰/۹۸۷۲	۰/۹۲۴	۰/۹۸۹۲	۰/۰۰۰۷	۰/۰۰۰۳
کل پیژومترها	forward back prop	TRAINLM	tandig	۶	tandig	۱۰۲	TRAINLM	tandig	۰/۹۹۹۹	۰/۹۹۹۸۷	۰/۹۹۹۸	۰/۰۰۶۱۱	۰/۰۰۱۴۱

ولی در چاههایی که فاقد کنتور می باشند، حجم آب برداشتی حاصل ضرب دبی آزمایش پمپاژ یا دبی سنجی های ادواری در زمان برداشت می باشد که با توجه به متغیر بودن دبی در طول زمان حجم آب استحصالی از دقت پایین تری برخوردار می باشد. لیکن دقت تخمین نسبت به حالتی که از اطلاعات تبخیر از سطح گیاه مرجع به عنوان شاخص برداشت آب استفاده می کنند، بالاتر است. همچنین نتایج نشان می دهد اجرای شبکه های مجزا برای تک تک پیزومترها از اجرای یک شبکه برای همه پیزومترها، نتایج دقیق تری ارائه می دهد.


می توان از دلایل این امر به نزدیکی پیزومترهای میانی به ایستگاه هواشناسی و دوری پیزومترهای طرفین دشت به آن نام برد که بالتبع در میزان آب ورودی به هر پلیگون تاثیر گذار بوده است. از دیگر عوامل موثر در دقت تخمین نحوه محاسبه حجم آب برداشت شده می باشد. در مواردی که چاه مجهز به کنتور خروجی باشد حجم آب استحصال شده از دقت بیشتری نسبت به زمانی که بر اساس ساعت کارکرد الکتروپمپ همراه با دبی آزمایش پمپاژ حجم آب برآورد شده است برخوردار خواهد بود، چرا که در این حالت حجم آب برداشتی حاصل ضرب دبی لحظه ای چاه در زمان برداشت خواهد بود




شکل ۴- مقایسه سطح آب مشاهده شده و محاسبه شده با روش شبکه عصبی مصنوعی در پیزومتر شماره ۱۴




شکل ۵- مقایسه سطح آب مشاهده شده و محاسبه شده با روش شبکه عصبی مصنوعی در پیزومتر شماره ۱۶



(شکل ۶) - مقایسه سطح آب مشاهده شده و محاسبه شده با روش شبکه عصبی مصنوعی در پیزومتر شماره ۹



(شکل ۷) - مقایسه سطح آب مشاهده شده و محاسبه شده با روش شبکه عصبی مصنوعی در پیزومتر شماره ۸



(شکل ۸) - مقایسه سطح آب مشاهده شده و محاسبه شده با روش شبکه عصبی مصنوعی در پیزومتر شماره ۵

مراجع

- ایزدی، ع، ا. داوری، ک. علیزاده، ا. قهرمان، ب. و حقایقی مقدم، س، ۱۳۸۶. پیش بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی مجله آبیاری و زهکشی ایران، سال اول، شماره ۲، صفحه ۵۹-۷۱.
- تسلطی، ب. ۱۳۸۲. برآورد سطح آب زیر زمینی با استفاده از modflow و شبکه عصبی مصنوعی. پایان نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه تربیت مدرس، ۱۰۵ صفحه.
- مهدیزاده، م. ۱۳۸۳. شبکه‌های عصبی مصنوعی و کاربرد آن در مهندسی عمران. انتشارات عبادی، ۱۳۰ صفحه.
- Bierkens, M. F. P., 1998. Modeling water table fluctuations by means of a stochastic differential equation. *Journal of Water Resource Research*, 34(10), 2485-2499.
- Copola, J. M., Szidarovszky, F., Poulton, M. and Charles, E., 2003. Artificial neural network approach for predicting transient water levels in a multi layered ground water system under variable state, pumping, and climate conditions. *Journal of hydrologic Engineering*. 8(6), 348-360.
- Coulibaly, P., Anclil, F., Aravena, R. and Brnard B., 2001. Artificial neural network modeling of water table depth fluctuations. *Journal of Hydrology*. 309(4), 219-228.
- Daliakopoulos, I. N., Coulibaly, P. and Tsanis, I. K., 2005. Ground water level forecasting using artificial neural networks. *Journal of Hydrology*. 309(4), 229-240.
- Maier, H. R. and Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: A review of modeling issues and application. *Environmental Modeling and Software*, 15:101-124.
- Nayak, P., Satyaji Rao, Y. R., and Sudheer, K. P., 2006. Ground water level forecasting in a Shallow aquifer using artificial neural network approach. *Water Resources Management*, 2(1), 77-99.

تاریخ دریافت: ۸۸/۳/۱۱

تاریخ پذیرش: ۸۸/۱۲/۹

Archive of SID

Groundwater Level Determination by Using Artificial Neural Network (Case study: Birjand Aquifer)

M. Mohtasham¹, A. A. Dehghani^{2*}, A. Akbarpour³, M. Meftah⁴ and B. Etebari⁵

Abstract

The use of groundwater always in one of the main sources of the drinking water and agricultural demands in the arid and semiarid areas. Birjand aquifer is located in the arid region and ground water is the main sources of fresh water. The aim of this research study is the prediction of groundwater level by using of artificial neural networks. To reach such goal, the Birjand plain is divided to sixteen polygons (according to sixteen piezometric wells) by using Tisen's polygon approach. Then in each polygon the amount of recharge (due to precipitation) and discharge (due to pumping wells) were calculated and selected as input parameters in addition to groundwater level of previous month. The groundwater level in present time was selected as output parameter in artificial neural network. The innovation of this study is to account the precise value of discharge of each polygon by considering the volumetric flow meter and duration of pumping form wells. It must be noted that in previous studies, the evapotranspiration from the leaf area of reference plant was selected as an index of discharge from each polygon. From 130 months measuring data of each piezometric well, the 80 months were selected as a training data and the rest of them for verification and test of artificial neural network. The various artificial neural networks such as feed forward back propagation, cascade forward back propagation were tested and the best architectures of artificial neural networks for each piezometric well were found by trial and errors. The results show that artificial neural networks can simulate the decreasing trend of the groundwater level and provide acceptable predictions up to 12 months ahead ($R^2=0.99$, $MSE=0.032$). The results also show that the accuracy of estimation for closer piezometric wells to weather station is more than the piezometric wells located far from it.

Keywords: ground water table neural net work, Birjand plain algorithm education

1,2,4- Graduate Student, and assistant professor, Gorgan Univ-respectively
(* - Corresponding author Email: a.dehghani@gau.ac.ir)
5- Geohydrologist, South Khorasan Water Quthorety