

پیش‌بینی سطح ایستادی با استفاده از شبکه عصبی مصنوعی

(مطالعه موردنی: دشت نیشابور)

عزیزا... ایزدی، کامران داوری، امین علیزاده، بیژن قهرمان، سیدابوالقاسم حقایقی مقدم^۱

اهمیت آبهای زیرزمینی به عنوان یک منبع مهم تأمین آب در مناطق خشک و نیمه خشک بر کسی پوشیده نیست. بطوری که پیش‌بینی نوسانات سطح آب زیرزمینی برای برنامه ریزی بهره‌برداری تلفیقی در چنین مناطقی یک ضرورت اساسی به نظر می‌رسد. دشت نیشابور با داشتن بیش از ۴۵ چاه مشاهده‌های که اکثر آدارای بیش از ۱۲ سال طول آماری هستند، برای این پژوهش انتخاب گردید. بدین منظور ابتدا ویرایش و تولید داده‌های مورد نیاز در مقیاس ماهیانه، برای ۱۵ پیزومتر انتخابی در سطح دشت و در شبکه تیسن معرف آنها با استفاده از اطلاعات خام اولیه و در محیط سامانه اطلاعات جغرافیایی (GIS) صورت گرفت. سپس عملکرد شبکه‌های عصبی مصنوعی (ANN) مختلف مانند شبکه عصبی پرسپترون چند لایه، پیشخور عمومی و بازگشته برای پیش‌بینی سطح آب زیرزمینی به منظور یافتن ساختار مناسب ANN که بتواند روند تغییرات سطح آب زیرزمینی را شبیه سازی کرده و یک پیش‌بینی قابل قبولی نیز در طی ماه‌های آینده فراهم نماید بررسی شده است. نتایج آزمایش‌های مختلف نشان داد که شبکه عصبی پیشخور عمومی آموزش داده شده با الگوریتم مومنتم بهترین نتیجه را برای پیش‌بینی سطح آب زیرزمینی در طی ۶ ماه آینده داشته است به طوریکه معیارهای عملکرد در نظر گرفته شده مانند $R^2 = 0,378$ و $NRMSE = 0,937$ در دوره آزمون نیز حاکی از این مسئله می‌باشد.

واژه‌های کلیدی: آب زیرزمینی، پیش‌بینی، ANNs، دشت نیشابور.

مقدمه

گوناگونی جهت پیش‌بینی سطح آب زیرزمینی توسعه و به کار برده شده است. از جمله این مدل‌ها می‌توان به مدل‌های سری زمانی تجربی و مدل‌های بر مبنای فیزیکی اشاره کرد. از مدل‌های سری زمانی تجربی به طور گسترده‌های برای مدل‌سازی سطح آب استفاده شده است، ولی هنگامی که رفتار دینامیکی یک سیستم هیدرولوژیکی با گذشت زمان تغییر می‌کند مدل‌های یاد شده برای پیش‌بینی پارامترهای منابع آب توانایی کافی نداشته و مدل‌های مناسبی نیستند (Bierkens 1998). از طرف دیگر، مدل‌های بر مبنای فیزیکی نیز در عمل به داده‌های زیادی برای شبیه سازی نوسانات سطح آب زیرزمینی نیاز دارند و از آنجاکه روابط بین متغیرهای مؤثر بر سطح آب در یک سفره آب زیرزمینی احتمالاً غیر خطی می‌باشند مدل‌های فوق در ارائه رابطه بین این متغیرها نیز نمی‌توانند به خوبی عمل کنند (Nayak et al 2006). با توجه به چنین وضعیتی، در سال‌های اخیر شبکه‌های عصبی مصنوعی

آبهای زیرزمینی به عنوان یک منبع مهم برای مصارف آشامیدنی، دام و کشاورزی در مناطق خشک و نیمه خشک محسوب می‌شود. در چنین مناطقی به علت اینکه بارندگی در یک دوره کوتاه مدت رخ می‌دهد و میزان تبخیر و تعرق بالا است، منابع آبهای سطحی منبع قابل اعتمادی برای تأمین آب نمی‌باشند. در نتیجه در این مناطق بیشتر بر روی منابع آبهای زیرزمینی تکیه می‌شود. بنابراین برای تأمین آب در این مناطق لازم است پیش‌بینی دقیقی از نوسانات سطح آب زیرزمینی انجام شود. با پیش‌بینی دقیق نوسانات سطح آب زیرزمینی می‌توان از آن در برنامه ریزی تأمین آب قابل اعتماد و نیز در مدیریت منابع آب استفاده نمود تا با توجه به نوع مصرف آب، برنامه ریزی بر روی منابع و مصارف آب انجام داد تا مدیران و برنامه ریزان منابع آب بتوانند درک بهتری از وضعیت منابع آب موجود داشته باشند. تا به امروز مدل‌های

۱- به ترتیب دانشجوی کارشناسی ارشد آبیاری و زهکشی، استادیار، استاد، دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه فردوسی مشهد و عضو هیأت علمی مرکز تحقیقات کشاورزی و منابع طبیعی استان خراسان

سانتی گراد است. با وجود اختلاف کم دما در ارتفاعات و دشت، آب و هوای حوضه در شمال و جنوب آن به شدت متغیر بوده، به طوریکه در شمال که اقلیم کوهستانی است هوانسبتاً سرد با تابستانی ملایم و به طرف جنوب و غرب هوای آن گرمتر می شود که این امر شاید ناشی از وسعت زیاد حوضه (۷۳۵۰ کیلومتر مربع) باشد. متوسط بارندگی در کل حوضه معادل ۲۳۴ میلی متر است، هر چند میزان بارندگی در نقاط مختلف آن متفاوت بوده، بطوريکه در ارتفاعات بلند بینالود مقدار آن حداقل به ۶۰ میلی متر و در سطح دشت به مراتب کمتر از آن است. میزان تبخیر به علت بالا بودن درجه حرارت هوای زیاد می باشد، بطوريکه متوسط تبخیر برای کل حوضه حدود ۲۳۳۵ میلی متر در سال گزارش شده است water organization(1377).

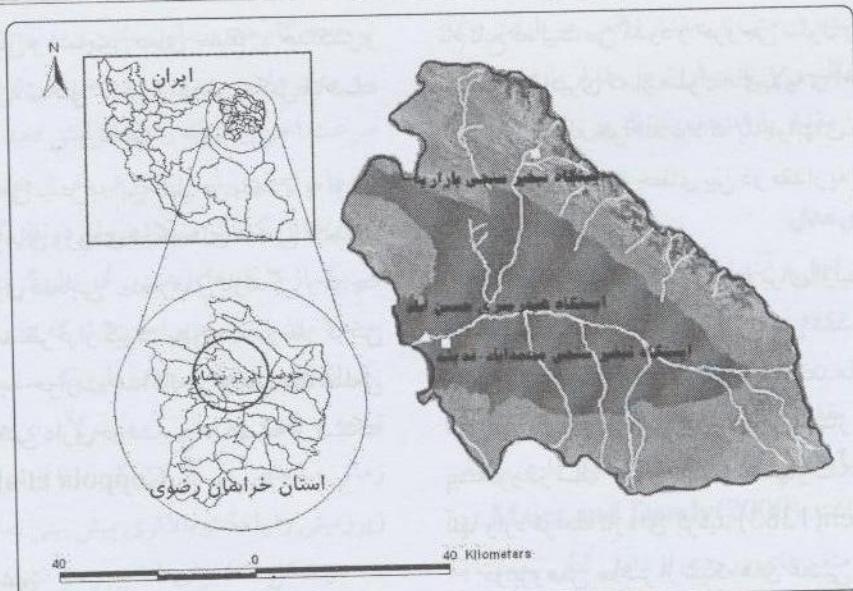
دشت نیشابور در سال های اخیر به علت برداشت زیاد از آبهای زیرزمینی برای مصارف کشاورزی با مشکل افت سطح منابع آب زیرزمینی مواجه شده است. اکثر چاه های موجود در سطح دشت غیر مجاز بوده و پمپاژ از آنها نیز بر مبنای مطالعات صورت گرفته در سطح سفره آب زیرزمینی نمی باشد همچنین به دلیل غالب بودن کشت چغندر قند در منطقه و بالا بودن نیاز آبی آن، متغیر برداشت از سفره آب زیرزمینی بیشترین تأثیر را در افت سطح آب داشته است. هر چند کاهش روند بارندگی و افزایش تبخیر و تعرق نیز در به وجود آمدن چنین شرایطی تأثیر فراوانی داشته است. بنابراین با توجه به چنین وضعیتی، متغیر های در نظر گرفته شده برای پیش بینی سطح آب زیرزمینی متغیر های بارندگی و دمای حداقل، حداقل و متوسط می باشد و به دلیل موجود نبودن اطلاعات مربوط به برداشت از سفره آب زیرزمینی در مقیاس ماهیانه در دوره مطالعه به صورت دقیق، متغیر تبخیر- تعرق گیاه مرجع به عنوان معرفتی برای برداشت از سفره آب زیرزمینی انتخاب گردید. قابل ذکر است که متغیر های در نظر گرفته شده به طور گستره ای در مقالات دیگر نیز به کار برده شده است(Coulibaly et al. 2001), Coppola et.al (2003) و Daliakopoulos et al. (2005) با توجه به متغیر های در نظر گرفته شده، اطلاعات خام اولیه مورد نیاز شامل سطح آب زیرزمینی پیزومترهای موجود در سطح دشت، میزان بارندگی و دمای حداقل، حداقل و متوسط در ایستگاه های موجود در سطح دشت و در مجاورت آن در مقیاس ماهیانه در دوره سری زمانی ۱۲ ساله (از ۷۱-۷۲ تا ۸۳-۸۴) تهیه

به طور فزاینده های برای پیش بینی سطح آب زیرزمینی مورد استفاده قرار گرفته اند. مزیت اصلی این روش بر سایر مدل های قدیمی به ماهیت جعبه سیاه بودن آنها بر می گردد که برای شبیه سازی پارامترهای منابع آب با وجود طبیعت پیچیده و غیر پویای آنها نیاز به شناخت فیزیک مسئله نمی باشد. بدین منظور محققان متعددی از روش فوق برای مدل سازی سطح آب زیرزمینی استفاده کرده اند.

Rizzo(1994) and Daliakopoulos et al., Coulibaly et al., Dougherty Nayak et al.(2005) al. ، و (2006) تحقیق قابلیت کاربرد توأم سامانه اطلاعات جغرافیایی (GIS) و شبکه های عصبی مصنوعی (ANNs) در پیش بینی سطح آب زیرزمینی در دشت نیشابور مورد مطالعه و ارزیابی قرار گرفته است.

منطقه مورد مطالعه و داده ها

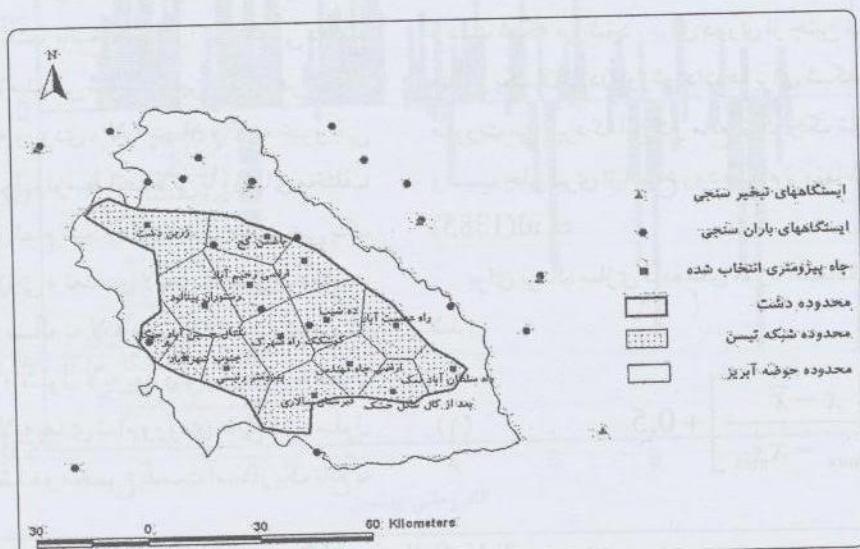
شبکه های عصبی در نظر گرفته شده با استفاده از اطلاعات برداشت شده از دشت نیشابور توسعه و اجرا می شوند. دشت نیشابور جزوی از حوضه آبریز کالشور نیشابور می باشد که در دامنه جنوبی ارتفاعات بینالود و در شمال شرق کویر مرکزی واقع شده است. این حوضه در طول جغرافیایی $۵۸^{\circ} ۳۰' - ۵۹^{\circ} ۳۰'$ و عرض جغرافیایی $۳۵^{\circ} ۴۰' - ۳۶^{\circ} ۳۹'$ واقع شده و از شمال به خط الرأس ارتفاعات بینالود، از شرق به بلندیهای لیلاجوق و یال پلنگ، از جنوب به تپه ماهورهای نیزه بند، سیاه کوه و کوه نمک و از غرب به حوضه آبریز دشت سبزوار محدود می شود(Velayati 1370). شکل (۱) موقعیت منطقه مورد مطالعه را در ایران نشان می دهد. وسعت کل حوضه ۷۳۵۰ کیلومتر مربع است که ۳۱۶۰ کیلومتر مربع آن را ارتفاعات و بقیه آن (عنی ۴۱۹۰ کیلومتر مربع) دشت تشکیل می دهد. بلندترین نقطه منطقه در ارتفاعات بینالود بوده که از سطح دریا ۳۳۰۰ متر ارتفاع دارد. پایین ترین نقطه در محل خروجی دشت (حسین آباد جنگل) قرار دارد که حدود ۱۰۵۰ متر از سطح دریا بلندتر است(Velayati 1370). آب و هوای منطقه بررسی، نیمه خشک تا خشک است. میانگین دمای ماهانه در ایستگاه بار (معرف مناطق کوهستانی) ۱۳ درجه سانتی گراد و در ایستگاه محمدآباد - فدیشه (معرف مناطق دشتی) $۱۳,8$ درجه



شکل(۱) موقعیت منطقه مورد مطالعه

و تعرق معرف هر پیزومتر را جداگانه محاسبه نمود (شکل ۲). لازم به یادآوری است که به علت وجود نداشتن نقشه الگوی کشت منطقه در طول دوره مطالعه، تبخیر و تعرق مرجع به جای تبخیر و تعرق گیاهی در هر چند ضلعی تیسن محاسبه گردید. از روش هارگریوز - سامانی (Hargreaves et al. 1982) به خاطر حداقل اطلاعات لازم برای محاسبه تبخیر و تعرق مرجع که شامل دمای حداقل، حداکثر و متوسط است استفاده شد. برای به

گردید. ابتدا اطلاعات مورد نظر با استفاده از روش اسپلاین^۱ از نظر خلاهای آماری مورد بازسازی و ویرایش نهایی قرار گرفت. سپس از بین پیزومترهای موجود در سطح دشت که بالغ بر ۴۵ حلقه بودند، ۱۵ حلقه از آنها به کمک کارشناسان مربوطه و با توجه به کامل بودن اطلاعات آنها در دوره سری زمانی در نظر گرفته شده انتخاب گردید. در نهایت برای پیزومترهای انتخابی، چند ضلعی تیسن رسم گردید تا این طریق بتوان متغیرهای بارندگی و تبخیر



شکل(۲) نمایش پیزومترهای انتخابی و موقعیت ایستگاههای مورد استفاده در تحقیق

نام تابع فعالیت می‌گذرد و خروجی سلول را تشکیل می‌دهد. در نهایت، مقادیری که از سلول‌های لایه‌ی آخر به دست می‌آیند جوابهای مسأله خواهند بود که با جوابهای واقعی مقایسه شده و در صورت کم بودن خطای بین دو مقدار به عنوان جواب اصلی پذیرفته می‌شود.

شبکه‌های عصبی مصنوعی، برای اولین بار در سال ۱۹۴۳ توسط مک‌کولاك و پیتس^۲ معرفی شد، اما این روش برای مدت‌های طولانی بلا استفاده بود که بعداً با توسعه رایانه‌ها و همچنین ظهور الگوریتم آموزش پس انتشار خطای^۳ برای شبکه‌های پیشخور در سال ۱۹۸۶ توسط براملهارت^۴ و همکاران استفاده از آنها وارد مرحله تازه‌ای گردید (Mehdizadeh 1383).

در پژوهش حاضر از شبکه‌های عصبی پرسپترون چند لایه^۵ پیشخور عمومی^۶ و بازگشتی^۷، به همراه الگوریتم های آموزش^۸ و تابع فعالیت^۹ مختلف برای مدل سازی سطح آب زیرزمینی با استفاده از نرم افزار Neuro Solution 5.0 مورد استفاده قرار گرفتند که برای یافتن ساختار بهینه شبکه‌های مختلف، روش آزمون و خطابه کار گرفته شد. البته برای کسب نتایج مناسب، یک سری مراحلی نیز قبل از توسعه و اجرای شبکه‌های عصبی در نظر گرفته شد که در ادامه توضیح آن خواهد آمد.

نرمال سازی داده‌ها

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای دوری از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال سازی صورت می‌گیرد که این کار مانع از کوچک شدن بیش از حد وزنها و سبب جلوگیری از اشباع زود هنگام نزونها می‌گردد (Bahmani et al 1385).

برای نرمال سازی داده‌های مورد استفاده از رابطه زیر استفاده شد:

$$x_n = 0.5 \times \left[\frac{x - \bar{x}}{x_{\max} - x_{\min}} \right] + 0.5 \quad (1)$$

دست آوردن میزان بارندگی و همچنین دمای حداقل، حداکثر و متوسط در هر چند ضلعی (شکل ۲) نیز از روش عکس فاصله استفاده گردید.

به کار گیری چند ضلعی نیسن به این دلیل می‌باشد تا به نوعی فیزیک مسأله نیز در متغیرهای ورودی شبکه‌های عصبی گنجانده شده و همچنین تغییرپذیری فضایی^۱ متغیرهای بارندگی و درجه حرارت در سطح دشت مدنظر قرار گیرد. بطوريکه در نظر گرفتن متغیرهای بارندگی و درجه حرارت جداگانه برای هر چند ضلعی نیسن می‌تواند به طور معنی داری در نتایج حاصله از شبکه تأثیرگذار باشد (Coppola et al 2003).

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی همانند شبکه عصبی طبیعی، از اجزائی به نام سلول عصبی تشکیل شده‌اند. همان طوری که در شبکه‌ی عصبی طبیعی، تعدادی از سلولها وظیفه دریافت اثر محرك خارجی، تعدادی پردازش اطلاعات و تعدادی سلول نیز وظیفه انتقال پاسخ محرك به عضو مورد نظر را بر عهده دارند، در شبکه‌های عصبی مصنوعی نیز تعدادی از سلولها دریافت معلومات مسأله، تعدادی پردازش اطلاعات و تعدادی نیز ارائه پاسخ مسأله را بر عهده دارند. سلول‌هایی که وظیفه آنها دریافت معلومات مسأله می‌باشد، سلول‌های لایه‌ی ورودی، سلول‌هایی که پردازش اطلاعات را بر عهده دارند، سلول‌های لایه پنهان و سلول‌هایی که علاوه بر پردازش اطلاعات، پاسخ محرك را نیز ارائه می‌دهند، سلول‌های لایه خروجی نامیده می‌شوند. بدین ترتیب هر شبکه عصبی به ترتیب شامل لایه ورودی، لایه پنهان و لایه خروجی می‌باشد، بطوريکه این سلولها توسط اتصالاتی با وزنهای مختلف به هم متصل می‌باشند. در تمام شبکه‌های عصبی مصنوعی یک لایه ورودی، یک لایه خروجی و تعدادی لایه‌ی پنهان وجود دارد. زمانی که مقادیر معلوم در مسأله به لایه ورودی داده می‌شود، در وزن اتصال میان آن سلول و سلول لایه بعد ضرب شده و به سلول بعدی منتقل می‌شود. در لایه بعدی تمام ورودی‌هایی که به سلول وارد می‌شوند با هم جمع شده و مجموع بدست آمده از یک تابع به

1) Spatial

4) Ramelhart et al.

7) Recurrent Neural Network

2) McCulloch and Pitts

5) Multi Layer Perceptron

8) Learning Algorithm

3) Back propagation algorithm

6) Generalized Feed Forward

9) Activation Function

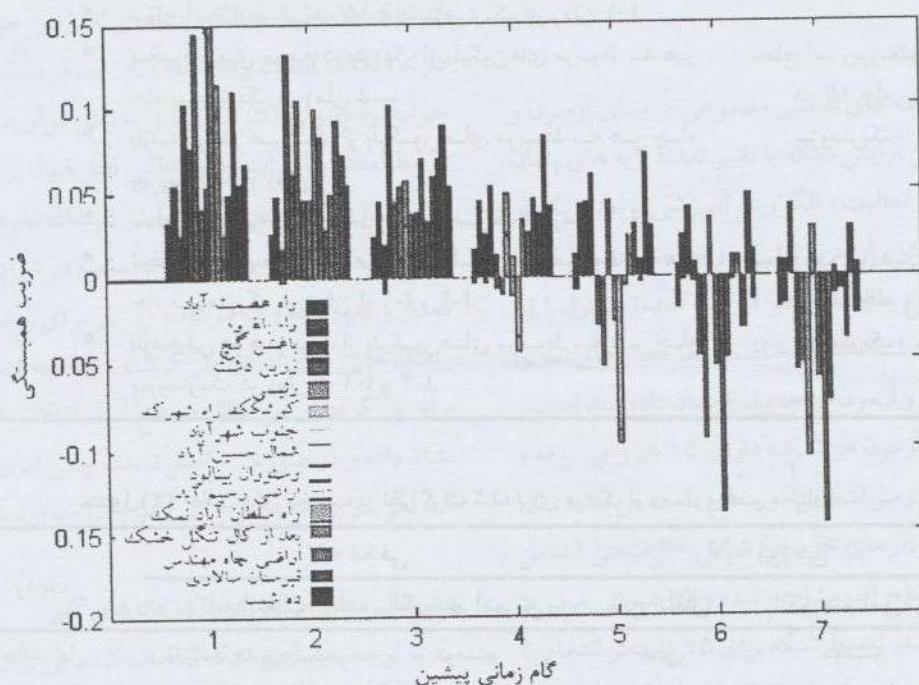
توجه به گام‌های زمانی پیشین، مدل‌های عصبی در تعیین روابط بین متغیرهای ورودی و خروجی می‌تواند سریعتر عمل نموده و سرعت اجرای شبکه را نیز افزایش دهد. البته بدیهی است که گام‌های زمانی پیشین برای هر یک از فصلها و یا حتی ماههای سال متفاوت از یکدیگر می‌باشد ولی در نظر گرفتن چنین شرایطی برای هر یک از شبکه‌های عصبی در نظر گرفته شده مطمئناً کار سختی بوده و نیاز به توسعه و اجرای شبکه‌های مختلف زیادی برای هر یک از فصول و یا ماه‌ها در طی یک سال می‌باشد. بنابراین با توجه به چنین شرایطی، معمولاً برای همه فصول سال یک گام زمانی مشخص در نظر می‌گیرند تا از این طریق بتوانند سطح آب زیرزمینی را با دقت بالاتری پیش‌بینی نمایند.

در شکل (۳) برای ۱۵ پیزومتر انتخابی، تأثیر گام‌های زمانی پیشین از متغیرهای تبخیر- تعرق و بارندگی بطور همزمان بر روی سطح آب زیرزمینی نشان داده شده است. مطابق شکل فوق بدون توجه به نوع پیزومتر گام‌های زمانی ۲ و ۳ که به ترتیب بیان‌گر گام‌های زمانی ۱ و ۲-۱ می‌باشند بیشترین همبستگی را با سطح آب زیرزمینی داشته و می‌توانند به عنوان متغیرهای ورودی در پیش‌بینی سطح آب زیرزمینی در نظر گرفته شوند. بنابراین برای

x_n : مقدار نرمال شده پارامتر، x : مقدار واقعی هر پارامتر، x_{max} : میانگین مقادیر مورد نظر، x_{min} : بیش ترین مقدار پارامتر مورد نظر، x_{min} : کم ترین مقدار پارامتر مورد نظر می‌باشد.

تعیین متغیرهای ورودی مدل

یکی از مهمترین مراحل فرآیند توسعه مدل‌های عصبی، تعیین اهمیت متغیرهای ورودی و تعیین گام‌های زمانی پیشین مؤثر بر متغیر وابسته می‌باشد. معمولاً همه متغیرهای ورودی دارای اهمیت یکسان نبوده و مقادیر بعضی از آنها ممکن است توأم با ناطمنی‌اند (اغتشاش) بوده و یا این که هیچ رابطه معنی‌داری با متغیر خروجی مدل نداشته باشند (Maier and Dandy 2000). در این تحقیق برای تعیین متغیرهای ورودی از دانش قبلی نسبت به متغیرها استفاده شده و برای تعیین گام‌های زمانی مؤثر بر سطح آب زیرزمینی نیز به جای تکیه کامل به خود شبکه و استفاده از آزمون و خطأ، از روش تحلیلی اعتبار سنجی متقاطع^۱ استفاده شده است (شکل ۳). در نظر گرفتن گام‌های زمانی پیشین از متغیرها در فرآیند توسعه مدل‌ها نقش اساسی داشته و فرایندهای مدل‌سازی شبکه‌های عصبی را آسانتر می‌سازد (Nayak et al. 2006). با



شکل (۳) نمایش گام‌های زمانی مؤثر پیشین بر سطح آب زیرزمینی

سیگموئیدی در لایه های مخفی و تابع فعالیت خطی در لایه خروجی استفاده شود عملکرد شبکه افزایش پیدا می کند . Kaustra and Boyd (1995)

شبکه های در نظر گرفته شده، از دو حالت جداگانه یعنی متغیرهای ورودی بدون در نظر گرفتن گام زمانی پیشین و همراه با گام زمانی پیشین به عنوان متغیرهای ورودی استفاده شده است (جدول ۱).

تقسیم بندی داده ها و ارزیابی عملکرد شبکه

در عمل معمولاً داده های موجود را به دو قسم مجموعه آموزشی و مجموعه تأیید مستقل تقسیم می کنند، بطوری که مجموعه های آموزش و تأیید باید معرف جمعیت یکسانی باشند. برای جلوگیری از آموزش زیادی یا بیش برآذش، معمولاً مجموعه داده ها را به جای دو مجموعه به سه مجموعه تقسیم بندی می کنند که مجموعه سوم به نام مجموعه آزمون معروف می باشد. برای شبکه های در نظر گرفته شده از مجموع ۱۲ سال اطلاعات تولید شده، ۸ سال برای آموزش شبکه (۱۳۷۰ تا ۱۳۷۸)، ۲ سال برای اعتبارسنجی (۱۳۷۸ تا ۱۳۸۰) و ۲۱ ماه (مهر ۱۳۸۱ تا خرداد ۱۳۸۳) نیز برای آزمون شبکه در نظر گرفته شد. برای ارزیابی

توبولوزی شبکه

برای تعیین ساختار مطلوب هر یک از مدل های ذکر شده در بالا از شبکه های پرسپترون چند لایه، شبکه پیشخور عمومی و شبکه عصبی بازگشتی استفاده شده است. حالتهای مختلف در نظر گرفته شده برای تعیین بهترین ساختار برای هر یک از شبکه های موردنظر در جدول (۲) ارائه شده است.

دو الگوریتم پس انتشار خطای مومنتم و کاهش گرادیان و دوتابع انتقال تائزانت هایپربولیک و سیگموئیدی در لایه مخفی در تکرارهای مختلف مورد آزمایش قرار گرفتند. البته تابع فعالیت به کار رفته در لایه خروجی برای تمامی تکرارهای مختلف خطی در نظر گرفته شده است. توصیه شده است که اگر از توابع فعالیت

جدول (۱) مدل های مختلف در نظر گرفته شده برای اجرای شبکه های عصبی

متغیرهای خروجی	متغیرهای ورودی	مدل
تبخیر و تعرق مرجع در هر یک از پلیگون های مربوط به هر چاه ۱۵ چاه	سطح آب زیرزمینی در ۱۵ چاه پیزومتریک در زمان ۱-۱	۱
بارندگی در هر یک از پلیگون های مربوط به هر چاه پیزومتریک	تبخیر و تعرق مرجع در هر یک از پلیگون های مربوط به هر چاه پیزومتریک در زمان ۱-۱	۲
تبخیر و تعرق مرجع در هر یک از پلیگون های مربوط به هر چاه ۱۵ چاه	سطح آب زیرزمینی در ۱۵ چاه پیزومتریک در زمان ۱-۱	
بارندگی در هر یک از پلیگون های مربوط به هر چاه پیزومتریک در زمان ۱-۱ و ۱-۲	تبخیر و تعرق مرجع در هر یک از پلیگون های مربوط به هر چاه پیزومتریک در زمان ۱-۱ و ۱-۲	

جدول (۲) حالت های مختلف در نظر گرفته شده برای هر یک از معماری های مختلف

ردیف	تابع انتقال	الگوریتم آموزش	لایه مخفی	لایه خروجی
حالت اول	تائزانت هایپربولیک	مومنتم	خطی	مومنتم
حالت دوم	سیگنید	مومنتم	خطی	مومنتم
حالت سوم	تائزانت هایپربولیک	گرادیان نزولی	خطی	گرادیان نزولی
حالت چهارم	سیگنید	گرادیان نزولی	خطی	گرادیان نزولی

2) Normalized Root Mean Square Error

4) Underestimate

1) Coefficient of Determination
3) Overestimate

3) Overestimate: $\sum_{i=1}^N (y_{acti} - y_{esti})^2$
 $\sum_{i=1}^N y_{acti}^2$ $\geq \sum_{i=1}^N y_{acti} y_{esti}$
 $\Rightarrow \sum_{i=1}^N (y_{acti} - y_{esti})^2 > 0$

4) Underestimate:

$y_{acti} \geq y_{esti}$ $\Rightarrow \sum_{i=1}^N (y_{acti} - y_{esti})^2 < 0$
 $\sum_{i=1}^N y_{acti}^2 < \sum_{i=1}^N y_{acti} y_{esti}$

$$RMSE = \sqrt{\frac{P \times N \times RMSE}{\sum_{i=1}^N (y_{acti} - y_{esti})^2}}$$

$$RMSE = \sqrt{\frac{NP}{\sum_{i=1}^N (y_{acti} - y_{esti})^2}}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{acti} - y_{esti})^2}{\sum_{i=1}^n y_{acti}^2 - \sum_{i=1}^n y_{esti}^2}$$

• R^2 $\in [0, 1]$
 $R^2 = 1 - \frac{\text{Sum of squared residuals}}{\text{Sum of squares of differences from mean}}$

• $R^2 = 1 - \frac{\sum_{i=1}^N (y_{acti} - y_{esti})^2}{\sum_{i=1}^N (y_{acti} - \bar{y}_{act})^2}$

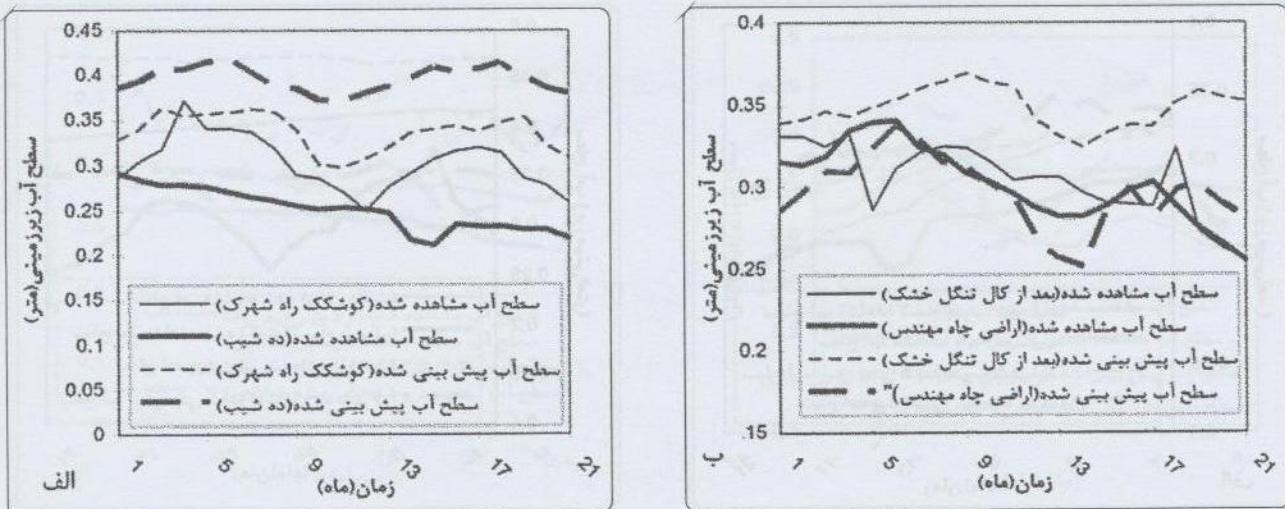
• $\bar{y}_{act} = \frac{1}{N} \sum_{i=1}^N y_{acti}$
 $\sum_{i=1}^N (y_{acti} - \bar{y}_{act})^2 = \sum_{i=1}^N (y_{acti}^2 - 2\bar{y}_{act}y_{acti} + \bar{y}_{act}^2)$
 $= \sum_{i=1}^N y_{acti}^2 - 2\bar{y}_{act} \sum_{i=1}^N y_{acti} + N\bar{y}_{act}^2$
 $= \sum_{i=1}^N y_{acti}^2 - 2\bar{y}_{act} \cdot N \bar{y}_{act} + N \bar{y}_{act}^2$
 $= \sum_{i=1}^N y_{acti}^2 - N \bar{y}_{act}^2$
 $\Rightarrow R^2 = 1 - \frac{\sum_{i=1}^N (y_{acti} - y_{esti})^2}{\sum_{i=1}^N y_{acti}^2 - N \bar{y}_{act}^2}$

• $\bar{y}_{act} = \frac{1}{N} \sum_{i=1}^N y_{acti}$
 $\sum_{i=1}^N (y_{acti} - \bar{y}_{act})^2 = \sum_{i=1}^N (y_{acti}^2 - 2\bar{y}_{act}y_{acti} + \bar{y}_{act}^2)$
 $= \sum_{i=1}^N y_{acti}^2 - 2\bar{y}_{act} \sum_{i=1}^N y_{acti} + N\bar{y}_{act}^2$
 $= \sum_{i=1}^N y_{acti}^2 - N \bar{y}_{act}^2$
 $\Rightarrow R^2 = 1 - \frac{\sum_{i=1}^N (y_{acti} - y_{esti})^2}{\sum_{i=1}^N y_{acti}^2 - N \bar{y}_{act}^2}$

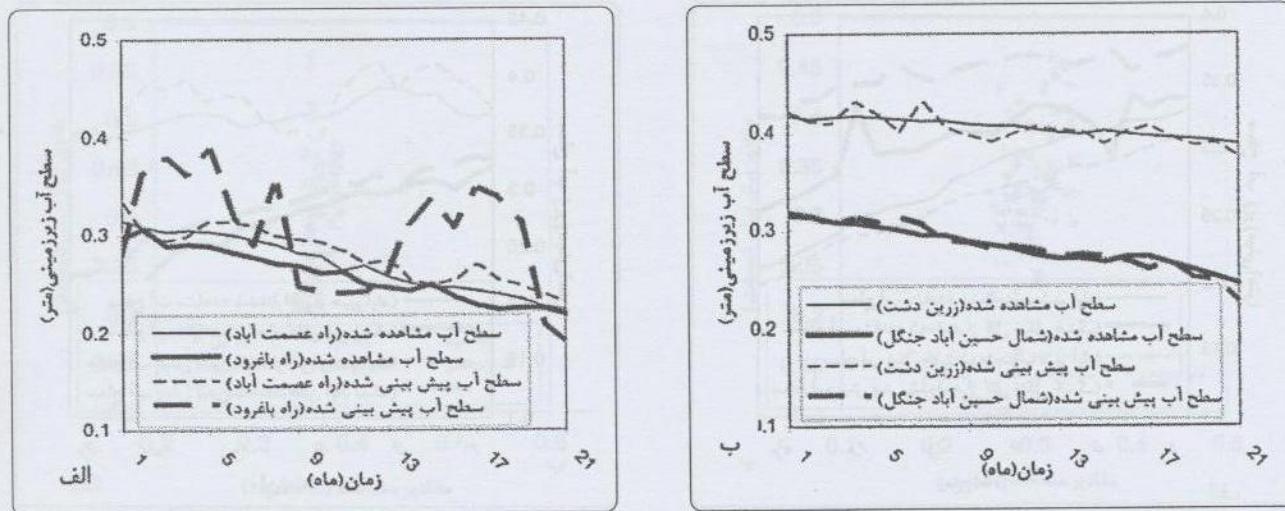
جدول (۳) نتایج حاصل از اجرای شبکه‌های مختلف در دوره آموزش، تأیید و آزمون (با ۱۵ نمون خروجی و تابع فعالیت خطی در لایه خروجی)

نوع مدل (بر اساس جدول ۱)	نوع شبکه	آزمون					
		لایه پنهان	لایه خروجی	لایه تأیید	آموزش	تعداد نمون	لایه پنهان
NRMSE	R ²	RMSE	RMSE	الگوریتم آموزش	تعداد نمون	لایه دوم	لایه پنهان
بدترین	بدترین	بدترین	بدترین	بفترین آباق	تعداد نمون	لایه اول	لایه دوم
۰/۹۹۵۳	۰/۰۳۷	۰/۰۵۵	۰/۱۲۱	Mom	۰	۰/۶	Tanh
۰/۹۴۴۶	۰/۰۱۶	۰/۰۵۴	۰/۰۵۰	C.G.	*	۰/۱	Sig.
۰/۸۸۸۳	۰/۰۰۰	۰/۰۵۴	۰/۰۵۰	Mom	*	۰/۰	Sig.
۰/۸۵۱۳	۰/۰۴۸	۰/۰۸۹	۰/۰۵۱	C.G.	*	۰/۰	Sig.
۰/۸۲۴	۰/۰۵۹	۰/۰۷۸	۰/۰۳۹	Mom	*	۰/۰	Sig.
۰/۷۲۶۱	۰/۰۳۰	۰/۰۱۴	۰/۰۱۱	C.G.	*	۰/۰	Sig.
۰/۷۲۳۷	۰/۰۴۳	۰/۰۴۹	۰/۰۳۳	Mom	*	۰/۰	Sig.
۰/۷۳۹۶	۰/۰۰۹	۰/۰۳۴	۰/۰۳۴	C.G.	*	۰/۰	Tanh
۰/۷۳۱۶	۰/۰۰۹	۰/۰۴۷	۰/۰۴۷	Mom	*	۰/۰	C.G.
۰/۷۴۴۶	۰/۰۱۹	۰/۰۳۰	۰/۰۱۲	C.G.	*	۰/۰	MLP

الگوریتم آموزشی: Mom
تابع فعالیت تابع تازهات هیبریوپلک: Tanh
Sig.: شبکه عصبی پیچیده
GFF: شبکه عصبی پیچیده عدومی
MLP: شبکه عصبی پیچیده لایه



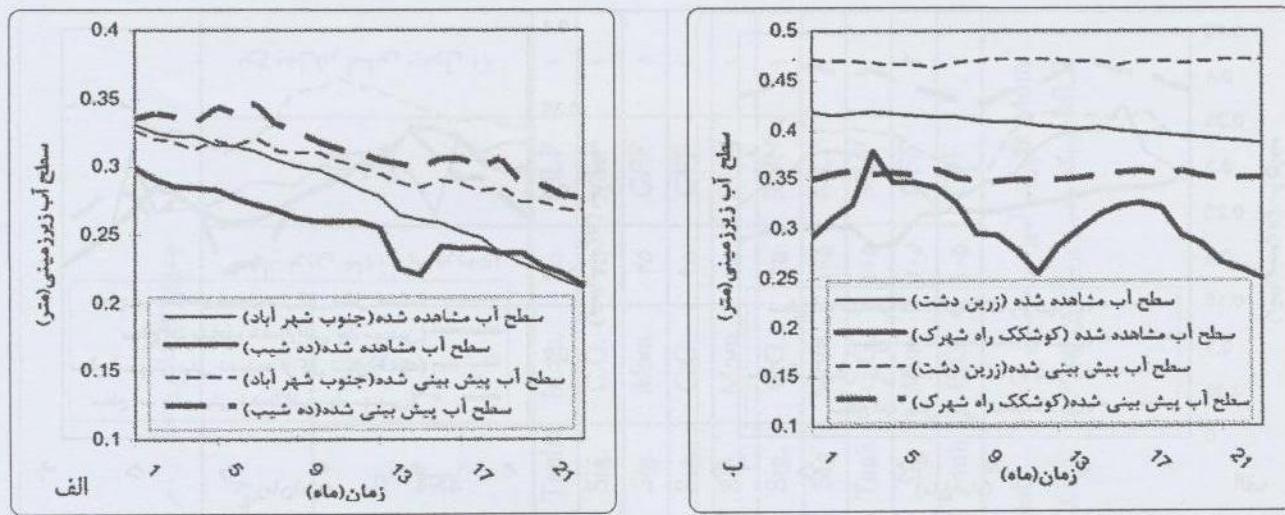
شکل(۴) مقایسه مقادیر پیش‌بینی شده و مشاهده شده برای دوره آزمون همراه با گام زمانی پیشین (مدل ۲) برای شبکه MLP با الگوریتم (الف) Mom و (ب) CG



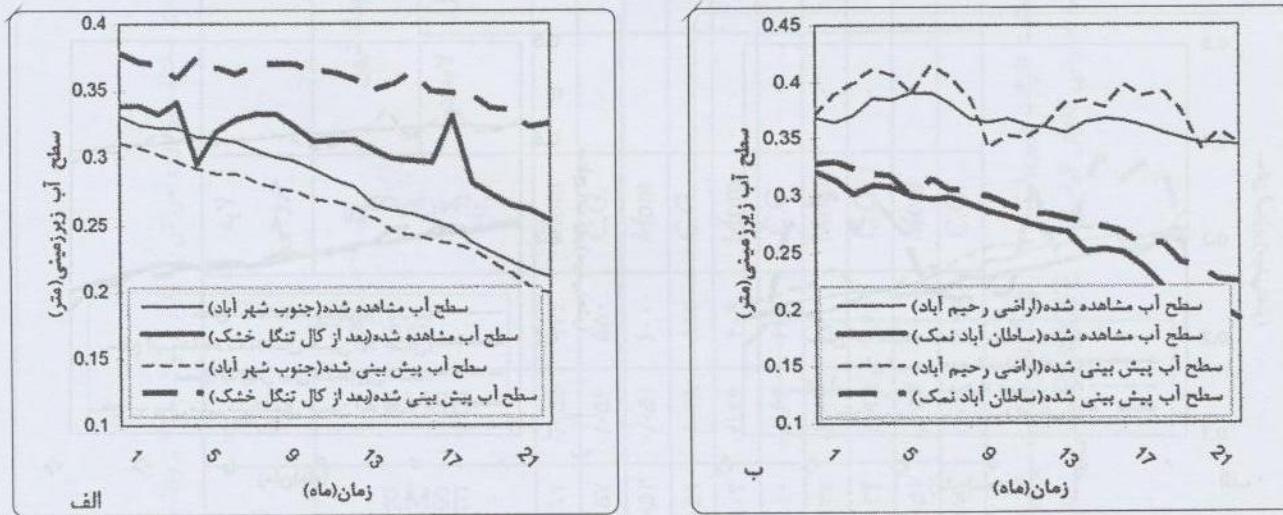
شکل(۵) مقایسه مقادیر پیش‌بینی شده و مشاهده شده برای دوره آزمون همراه با گام زمانی پیشین (مدل ۲) برای شبکه GFF با الگوریتم (الف) Mom و (ب) CG

هیجدهم و در نهایت بیست و یکم می‌باشدند تا بتوان نحوه تغییرات عملکرد شبکه را در ماه‌های مختلف بررسی و بهترین ماه را از نظر عملکرد شبکه انتخاب کرد تا از این طریق بتوان از عملکرد خوب شبکه تا ماه خاصی اطلاع پیدا کرده و از آن برای پیش‌بینی سطح آب زیرزمینی تا آن ماه خاص استفاده نمود *e.g. Daliakopoulos et al. (2005)*. با توجه به نتایج حاصله می‌توان گفت که بهترین شبکه در نظر گرفته شده برای پیش‌بینی سطح آب زیرزمینی برای پیزومترهای مختلف، عملکرد متفاوتی داشته است. کسب چنین نتایجی را می‌توان به موقعیت قرارگیری پیزومترها در سطح دشت نسبت داد که در بعضی از نقاط دشت مانند نقاط نزدیک به کوهها

که شرایط هیدرولوژیکی در ۲۱ ماه آینده دقیقاً از ۲۱ ماه گذشته (دوره در نظر گرفته شده برای آزمون شبکه‌ها) تبعیت کند. در نظر گرفتن چنین فرضی فقط برای پیش‌بینی سطح آب زیرزمینی احتمالی در آینده بوده و فقط یک نگرش کلی از وضعیت تراز سطح آب زیرزمینی در آینده به ما خواهد داد و قطعاً به منزله صحیح بودن کامل مقادیر پیش‌بینی شده در آینده نمی‌باشد. بنابراین با توجه به شبکه فوق، سطح آب زیرزمینی برای هر یک از ۱۵ پیزومتر انتخاب شده در سطح دشت از یک تا ۲۱ ماه (دوره زمانی در نظر گرفته شده برای آزمون) پیش‌بینی گردید. البته ماه‌های خاص در نظر گرفته شده، ماه‌های اول، دوم، سوم، ششم، دوازدهم،



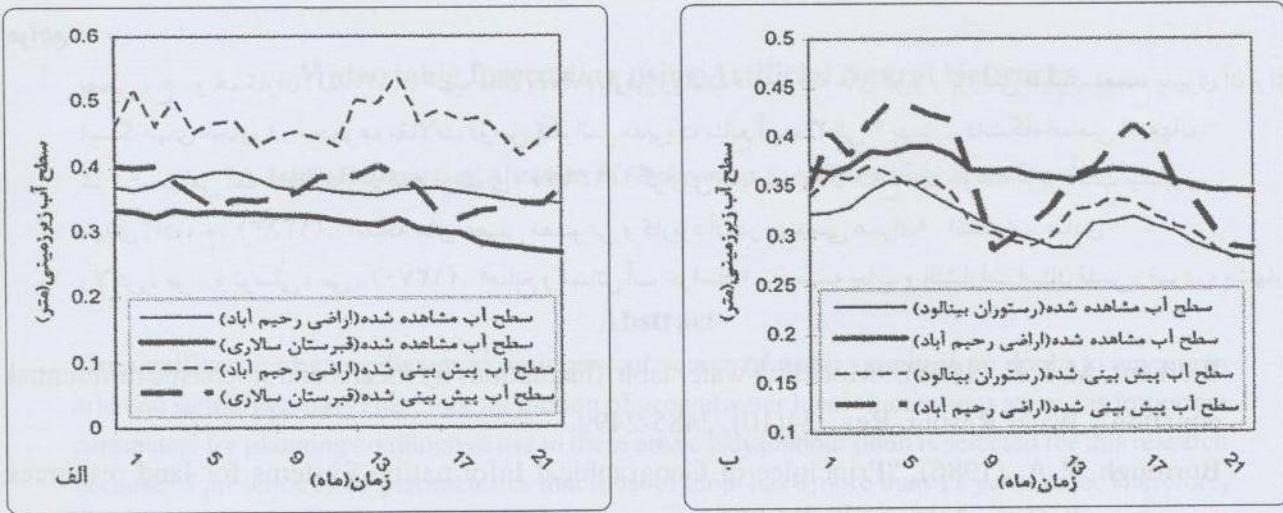
شکل (۶) مقایسه مقادیر پیش‌بینی شده و مشاهده شده برای دوره آزمون همراه بدون در نظر گرفتن گام زمانی پیشین (مدل ۲) برای شبکه MLP با الگوریتم (الف) CG و (ب) Mom



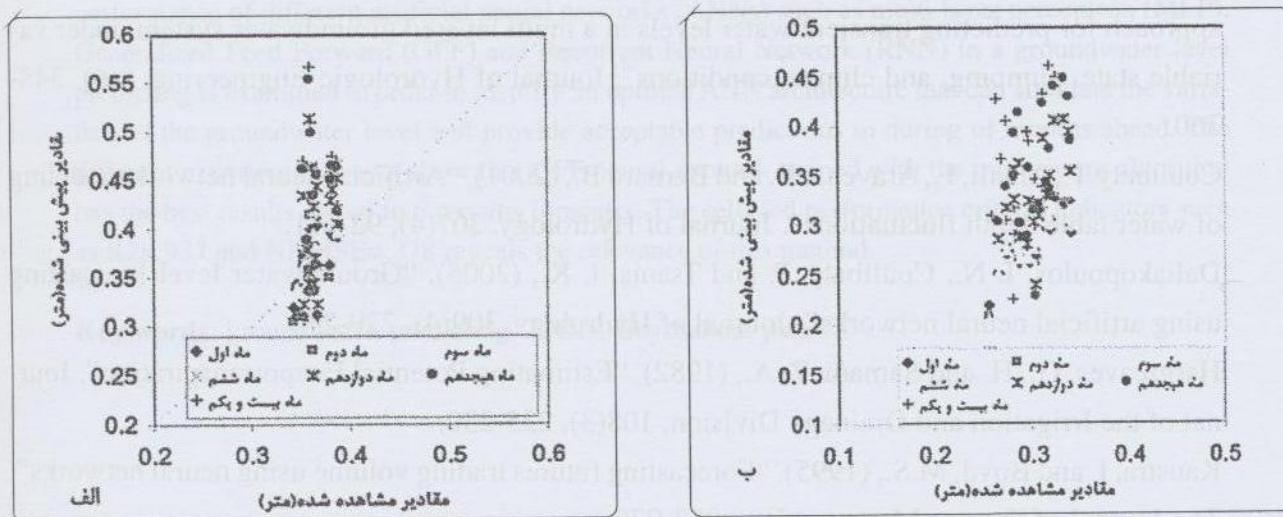
شکل (۷) مقایسه مقادیر پیش‌بینی شده و مشاهده شده برای دوره آزمون بدون در نظر گرفتن گام زمانی پیشین (مدل ۱) برای شبکه GFF با الگوریتم Mom (الف) CG و (ب) Mom

شبکه دچار کم برآورد گشته و مثل حالت بالاتر ۶ ماه بعدی عملکرد خوبی داشته است. برای بقیه پیزومترها نیز شبکه دارای عملکرد خوبی خوبی بوده به طوریکه در اکثر این پیزومترها به جز پیزومترهای کوشک راه شهرک و اراضی رحیم آباد که به ترتیب برای ۱۲ و ۳ ماه بعدی عملکرد خوبی داشته اند، شبکه برای بقیه پیزومترها تا ۶ ماه آینده عملکرد خوبی خوبی از خود نشان داده است به طوری که نتایج حاصله، یافته های محققان دیگر را نیز تأیید می نماید (Daliakopoulos et al. 2005) و (Nayak et al. 2006). در شکل ۹ نمونه ای از پیزومترهایی که عملکرد خوبی داشته اند ارائه شده است.

تغذیه پیزومترها زیاد بوده و یا اینکه در میانه های دشت تغذیه کم بوده ولی برداشت زیاد می باشد و یا حتی می توان به قرارگیری بعضی از پیزومترهای در اطراف رودخانه مرتبط دانست. بدیهی است که شبکه های عصبی قادر به درک کامل فیزیک مسئله نبوده و وجود چنین شرایطی می تواند در نتایج حاصله تأثیر زیادی داشته باشد. با توجه به چنین شرایطی شبکه فوق در پیش‌بینی تراز سطح آب زیرزمینی در پیزومترهای راه عصمت آباد، راه باگرود، رستوران بینالود و راه سلطان آباد نمک شبکه تا حدودی دچار بیش برآورد گشته، ولی با این وجود شبکه تا ۶ ماه بعدی پیش‌بینی خوبی داشته است. برای پیزومترهای راه باگشن گچ و قبرستان سالاری نیز



شکل(۸) مقایسه مقادیر پیش‌بینی شده و مشاهده شده دوره آزمون بدون در نظر گرفتن گام زمانی پیشین (مدل ۱) برای شبکه RNN با الگوریتم Mom (الف) و (ب) CG



شکل(۹) مقایسه سطح آب زیرزمینی مشاهده شده و پیش‌بینی شده برای ماه‌های مختلف برای پیزومترهای (الف) اراضی رحیم آباد و (ب) اراضی چاه مهندس

فوق دارای دقت بالایی در پیش‌بینی سطح آب زیرزمینی بوده و در اکثر پیزومترهای انتخابی تا ۶ ماه بعدی عملکرد خوبی از خود نشان داده است. هر چند دقت پیش‌بینی مدل در اکثر پیزومترها به طور معنی داری با افزایش افق زمانی کاهش یافته است. از دیگر نتایج این مطالعه می‌توان به مناسب بودن الگوریتم آموزش مومنتم و ترکیب تابع فعالیت سیگموئید در لایه مخفی و خطی در لایه خروجی اشاره کرد که عملکرد خیلی خوبی در پیش‌بینی سطح آب زیرزمینی داشته است و از آن می‌توان برای این امور استفاده نمود.

نتیجه گیری

در این تحقیق توانایی شبکه‌های عصبی مصنوعی به عنوان یک روش سودمند و مؤثر در پیش‌بینی سطح آب زیرزمینی برای دشت نیشابور مورد ارزیابی قرار گرفته و اثبات گردیده است. عملکرد شبکه‌هایی که در آنها از گام‌های زمانی پیشین به عنوان متغیر ورودی استفاده شده است نسبت به سایر شبکه‌ها عملکرد به مراتب بهتری داشته‌اند، بطوریکه در این حالت شبکه‌های GFF در مقایسه با شبکه‌های MLP و RNN عملکرد خیلی بهتری داشته و بهترین ساختار حاصله نیز مربوط به شبکه GFF آموزش دیده با الگوریتم مومنتم با ترکیب ۱۵-۲-۱۰۵ می‌باشد. شبکه

مراجع

بهمنی، ع. و همکاران. (۱۳۸۵). «تهیه مدل ANN بارش رواناب در حوضه های آبریز و بررسی قابلیت تعمیم پذیری آن برای استگاههای مجاور». مجموعه مقالات دومین کنفرانس مدیریت منابع آب، ۳ الی ۴ بهمن. دانشگاه صنعتی اصفهان.

شرکت سهامی آب منطقه ای خراسان رضوی، (۱۳۷۷). گزارش محاسبه بیلان منابع آب حوضه آبریز دشت نیشابور.

مهدی زاده، م. (۱۳۸۳). «شبکه های عصبی مصنوعی و کاربرد آن در مهندسی عمران». انتشارات عبادی.

ولایتی، س. و توسلی، س. (۱۳۷۰). «منابع و مسائل آب خراسان». موسسه چاپ و انتشارات آستان قدس رضوی، مشهد.

Bierkens, M. F. P., (1998). "Modeling water table fluctuations by means of a stochastic differential equation". Water Resour. Res., 34(10), 2485-2499.

Burrough, P. A. (1986), "Principles of Geographical Information Systems for land resources assessment". Oxford, Claredon Press.

Coppola, J. M., Szidarovszky, F., Poulton, M. and Charles, E., (2003). "Artificial neural network approach for predicting transient water levels in a multi layered groundwater system under variable state, pumping, and climate conditions". Journal of Hydrologic Engineering. 8(6), 348-360.

Coulibaly, P., Anctil, F., Aravena, R. and Bernard B., (2001). "Artificial neural network modeling of water table depth fluctuations". Journal of Hydrology. 307(4), 92-111.

Daliakopoulos, I. N., Coulibaly, P. and Tsanis, I. K., (2005). "Groundwater level forecasting using artificial neural networks". Journal of Hydrology. 309(4), 229-240.

Hargreaves, G., H. and Samani, Z. A., (1982). "Estimating Potential Evapotranspiration". Journal of the Irrigation and Drainage Division, 108(3), 225-230.

Kaustra, I. and Boyd, M.S., (1995). "Forecasting futures trading volume using neural networks". The Journal of Futures Markets 15(8), 953-970.

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). "Groundwater level forecasting in a shallow aquifer using artificial neural network approach". Water Resources Management, 2(1), 77-99.

Rizzo, D. M. and Dougherty, D.E., (1994). "Characterization of aquifer properties using artificial neural networks: Neural kriging". Water Resources Research 30(2), 483-497.

Water table forecasting using Artificial Neural Networks

A. Izadi , K. Davari , A. Alizadeh , B. Ghahreman , S. A. Haghayeghi Moghadam¹

Abstract

The significance of groundwater as an important source of water supply is no doubt to anyone in arid and semiarid areas. Therefore prediction of groundwater level fluctuations seems as important parameters for planning conjunctive use in these areas. Neyshabour plain is selected for this research because of presence of 45 piezometers that most of them have more than 12 years data. Therefore, at first preprocessing job is done on the raw data using GIS for editing and generating requirement of data in month scale in 15 selective piezometric wells and in its thiessen polygon. Then, the performance of different artificial neural networks (ANNs) such as multi layer perceptron (MLP), Generalized Feed Forward (GFF) and Recurrent Neural Network (RNN) in a groundwater level predicting is examined in order to identify an optimal ANN architecture that can simulate the variation of the groundwater level and provide acceptable predictions in during of months ahead. The different experiment results show that GFF neural network trained with the momentum algorithm has the best results for up to 6 months forecasts. The selected performance criteria indicators such as $R^2=0.937$ and $NRMSE=0.378$ reveals the relevance of this method.

Key words: groundwater, predicting, ANNs, Neyshabour plain.

1- Contribution from Water Engineering Department, College of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran.