

کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه عصبی مصنوعی در پیش‌بینی تغییرات سطح آب زیرزمینی (مطالعه موردی: دشت مرودست)

حسین ملکی نژاد^۱* و ربابه پورشارعیاتی^۲

^۱- نویسنده مسئول، دانشیار دانشکده منابع طبیعی، دانشگاه یزد

^۲- دانش آموخته ارشد آبخیزداری، دانشکده منابع طبیعی، دانشگاه یزد

تاریخ دریافت: ۹۱/۰۲/۲۶ تاریخ پذیرش: ۹۱/۰۲/۲۶

چکیده

پیش‌بینی نوسانات سطح آب زیرزمینی، برای برنامه‌ریزی مناسب‌تر بهویژه در مناطق خشک و نیمه خشک امری ضروری است. در این تحقیق برای پیش‌بینی نوسانات سطح آب زیرزمینی در دشت مرودست از مدل‌های سری زمانی و شبکه عصبی استفاده شد. برای مدل‌سازی، اطلاعات سطح آب زیرزمینی در طی سال‌های ۱۳۶۶-۸۸ استفاده و مدل‌های مختلف سری زمانی تلفیقی و شبکه عصبی مصنوعی بر داده‌ها بازآش داده شد. کارآیی و دقیقت مدل‌های آریما در پیش‌بینی مقادیر آتی توسط معیار اطلاعاتی آکائیک و جذر مربع میانگین خطاهای مورد ارزیابی قرار گرفت. نتایج بررسی حالت‌های مختلف مدل آریما نشان داد که مدل آریما (۱,۱,۰) بهترین بازآش را با داده‌ها دارد. در مدل شبکه عصبی مصنوعی پیش خور با الگوریتم پس انتشار خطا از سه تابع آموزشی لونبرگ مارکوارت، پس انتشار ارجاعی و شبیب توأم مقیاس شده استفاده شد. با توجه به نتایج بدست آمده از بین سه تابع آموزشی، تابع لونبرگ مارکوارت به عنوان بهترین تابع آموزشی برای پیش‌بینی سطح آب زیرزمینی انتخاب گردید. برای ارزیابی و انتخاب روش بهتر، بین مدل سری زمانی تلفیقی آریما (۱,۱,۰) و مدل شبکه عصبی پیش خور با الگوریتم پس انتشار خطا، از آماره‌های میانگین مربع خطاهای میانگین قدر مطلق خطاهای و ضریب بازدهی استفاده شد که مدل شبکه عصبی نسبت به سری زمانی تلفیقی برتری جزئی نشان داد.

کلید واژه‌ها: مدل سری زمانی تلفیقی، شبکه عصبی مصنوعی، دشت مرودست، سطح آب زیرزمینی.

Application and Comparison of Integrated Time Series and Artificial Neural Network Model for Prediction of the Variations of Groundwater Level (Case study: Plain Marvast)

H. Malekinezhad¹ and R. Poorshareiat²

1- Associate Professor, Faculty of Natural Resources, Yazd University.

2- Graduated senior in Watershed Management, Faculty of Natural Resources, Yazd University

Received: 16.May.2012

Accepted: 25.Feb.2013

Abstract

Prediction of groundwater level fluctuations is an essential step for management, appropriate planning and efficient use in arid and semi-arid regions. According to the existing information, the general trend of groundwater hydrograph represents declining trend and continuous falling of groundwater level during the last years in the Marvast plain. In this study, integrated time series and neural network models were used to predict the fluctuations of groundwater levels in the Marvast plain. For this purpose, the groundwater level data of 1987-2009 time period were provided and different integrated time Series models and artificial neural network were fitted to the data. The efficiency and accuracy of ARIMA model for predicting future values was assessed using the Root Mean Square Errors (RMSE) and Akaike information criterion. The results of different ARIMA states showed the ARIMA (1, 1, 0) is the best-fit time series model. Three train functions of Levenberg-Marquardt, Resilient Back Propagation and Scaled Conjugate Gradient were used for the feed-forward back propagation neural network. The results showed Levenberg-Marquardt function is the best train function to predict groundwater level. Comparing the results of ARIMA (1,1,0) and neural network feed-

forward with back propagation algorithm using RMSE, MAE and CE statistics showed neural network model is relatively superior to the Integrated Time Series model.

Keywords: Integrated Time series model, Artificial neural network, , Marvast plain, Groundwater level.

مقدمه

همکاران^۸ (۲۰۰۷) معیاری را جهت تعیین میزان تکرار برای آموزش شبکه‌های عصبی پس انتشار^۹ ارائه دادند. این مطالعه نشان داد که آموزش زیاد و یا کمتر از مقدار می‌تواند منجر به عبور از مقدار مناسب یا نرسیدن به جواب مطلوب برای تعیین ارتباط بین داده‌های ورودی و خروجی شود. جاتپیراکش و ساکر^{۱۰} (۲۰۰۸) در تحقیقی از مدل شبکه عصبی با آموزش الگوریتم پس انتشار استفاده کردند. عملکرد مدل‌ها نشان داد که شبکه عصبی مصنوعی می‌تواند برای پیش‌بینی سطح آب زیرزمینی استفاده شود. بنرجی و همکاران^{۱۱} (۲۰۰۹) در تحقیقی از شبکه عصبی پیش‌خور به عنوان روشنی برای پیش‌بینی سطح آب زیرزمینی استفاده کردند که این شبکه عصبی نتایج مطلوبی را ارائه داد. موهانتی و همکاران^{۱۲} (۲۰۰۹) در تحقیقی از مدل شبکه عصبی مصنوعی با آموزش الگوریتم پس انتشار خطاب رای پیش‌بینی سطح آب زیرزمینی استفاده کردند و مشخص گردید که هرچند دقت پیش‌بینی سطح آب زیرزمینی با افزایش زمان انتظار کاهش پیدا می‌کند ولی پیش‌بینی سطح آب زیرزمینی برای زمان‌های انتظار بیشتر قابل قبول تر است. سریگفت و همکاران^{۱۳} (۲۰۰۹) نشان دادند که استفاده از شبکه عصبی با مدل شبکه پیش‌خور استاندارد و با آموزش الگوریتم لونبرگ مارکوارت با ضریب همبستگی ۰/۹۳ و جذر میانگین مربع خطاهای ۴/۵ متر برای پیش‌بینی سطح آب زیرزمینی مدل مناسب است. رحمانی و سدهی^{۱۴} (۱۳۸۳) در تحقیقی نشان دادند که مقادیر پیش‌بینی شده به وسیله مدل سری زمانی، در ۲۰ سال آینده با کاهش حدود ۱۷/۵ متر نسبت به وضعیت فعلی سطح سفره مواجه خواهد شد.

رضایی و موسوی^{۱۵} (۱۳۸۸) در تحقیقی با استفاده از مدل‌های سری زمانی نوسانات پیزومتری، شبیه‌سازی کردند و نوسانات آینده را پیش‌بینی نمودند. جمالی و همکاران^{۱۶} (۱۳۸۸) در تحقیقی تحت عنوان مقایسه روش خطی (ARIMA) و غیرخطی (ANN) در مدل‌سازی نوسانات سطح آب زیرزمینی در نشان دادند که مدل‌های غیر خطی شبکه عصبی مصنوعی در مقایسه با مدل خطی بسیار دقیق و کارا و قابل اعتماد بوده و

یکی از فاکتورهای مهم در مدیریت صحیح در هر زمینه‌ای داشتن یک دید و نگرش مناسب از اتفاقات آینده در آن زمینه است. در مدیریت منابع آب این امر مستثنی نبوده و آگاهی از وضعیت منابع آب در یک منطقه نقش تعیین کننده‌ای در برنامه ریزی‌های آبی و کشاورزی آن دارد.

باکس و جنکینز^۱ (۱۹۷۶) از تئوری سری‌های زمانی برای پیش‌بینی داده‌های سطح آب زیرزمینی استفاده کردند. یانگ و همکاران^۲ (۲۰۰۹) در تحقیقی نشان دادند که دقت پیش‌بینی شبکه عصبی مصنوعی نسبت به مدل سری زمانی تلفیقی در پیش‌بینی سطح های آب زیرزمینی برتری دارد.

در زمینه استفاده از شبکه‌های عصبی نیز پژوهش‌های متعددی انجام پذیرفته است. کوبولا^۳ و همکاران^۴ (۲۰۰۳) از مدل شبیه‌سازی شبکه عصبی برای پیش‌بینی تراز سطح آب زیرزمینی استفاده نمودند. نتایج این مدل شبیه‌سازی نشان داد که مدل شبکه عصبی با دقت بالایی نسبت به مدل‌های عددی آب زیرزمینی می‌تواند تراز سطح آب را برای افق بلند مدت پیش‌بینی نماید. شیجیدی و گارسیا^۵ (۲۰۰۳) از مدل شبیه‌سازی شبکه‌های عصبی برای تخمین پارامترهای معادله‌ی آب زیرزمینی استفاده کردند. دالیاکوبولوس و همکاران^۶ (۲۰۰۵) برای پیش‌بینی تراز سطح آب زیرزمینی از ساختارهای مختلف شبکه‌های عصبی مصنوعی استفاده نمودند. نتایج نشان داد که مدل لونبرگ-مارکوارت از دقت بالاتری در پیش‌بینی برخوردار است. لالهام و همکاران^۷ (۲۰۰۵) از شبکه عصبی مصنوعی در تشخیص داده‌های زمانی لازم برای برآورد سطح آب زیرزمینی یک پیزومنتر استفاده کردند. نتایج نشان داد که شبکه عصبی پرسپترون چند لایه با حداقل تأخیر و لایه پنهان مناسب‌ترین شبیه‌سازی را انجام داد. نایاک و همکاران^۸ (۲۰۰۶) برای پیش‌بینی سطح آب زیرزمینی در آبخوان ساحلی هند نشان دادند که مدل‌های شبکه عصبی مصنوعی قابلیت پیش‌بینی سطح آب زیرزمینی تا چهار ماه را دارد. چاندرا مولی و

-
- 8- Chandramouli
 - 9 - Back- Propagation ANNs
 - 10- Jothiprakash and Sakhare
 - 11- Banerjee et al.
 - 12- Mohanty
 - 13- Sreekanth et al.

1-Box and Jenkins

2-Yang et al.

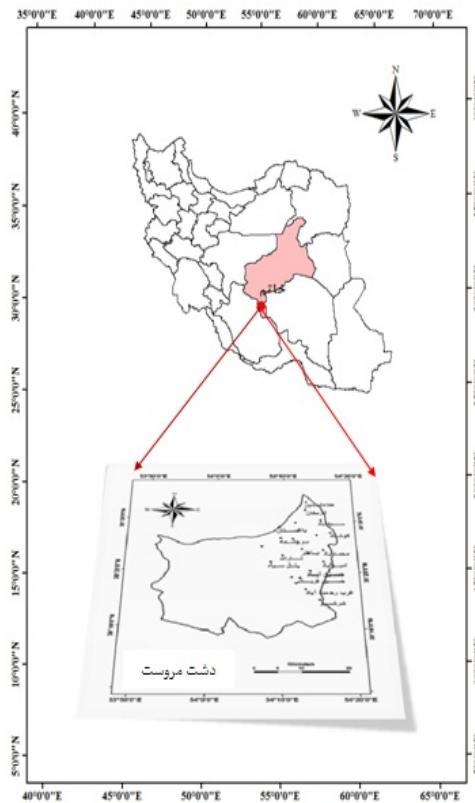
3- Coppola et al.

4- Shigidi and Garcia.

5- Daliakopoulos et al.

6- Lallahem et al.

7- Nayak et al.



شکل ۱- منطقه مورد مطالعه

پیش خور عمومی آموزش داده شده با الگوریتم مومنتوم بهترین راه برای پیش بینی سطح آب زیرزمینی است. میرعربی و نخعی (۱۳۸۷) در تحقیقی نشان دادند که استفاده از شبکه عصبی برای پیش بینی نوسانات سطح آب زیرزمینی موفقیت آمیز است. محتشم و همکاران (۱۳۸۹) در تحقیقی نشان دادند که با استفاده از روش شبکه عصبی مصنوعی و برآورد میزان آب برداشتی می توان سطح آب زیرزمینی را تا ۱۲ ماه بعد پیش بینی کرد.

هدف اصلی تحقیق این است که با پیش بینی نوسانات سطح آب های زیرزمینی، برنامه ریزی بلند مدت و استفاده بهینه از آب منطقه بهویژه در بخش کشاورزی صورت گیرد.

مواد و روش ها

موقعیت منطقه مورد مطالعه

واحد هیدرولوژیک مرغاست که به لحاظ سیاسی جزو استان یزد و شهرستان خاتم محسوب می شود بین طول های جغرافیایی ۵۰°۵۱' تا ۵۴°۱۹' شرقی و عرض های ۳۰° تا ۳۰° شمالي قرار دارد (شکل ۱). منطقه مرغاست دارای اقلیم گرم و خشک، متوسط بارندگی آن در ایستگاه مرغاست (ارتفاع ۱۵۳۰ متر) فقط ۷۵ میلی متر، دمای متوسط سالانه ۱۷/۵ درجه

دارای معیارهای ارزیابی خطای خیلی پایین تری هست. نورانی و همکاران (۲۰۰۸) در تحقیقی تحت عنوان مدل پایه شبکه عصبی مصنوعی برای پیش بینی زمانی و مکانی سطح آب های زیرزمینی نشان دادند که مدل شبکه عصبی مصنوعی پیش بینی دقیقی را در مقایسه با مدل های دیگر ارائه می دهد قدمپور و رخشنده رود (۲۰۱۰) در تحقیقی از شبکه عصبی پیش خور پس انتشار خطا برای پیش بینی سطح آب زیرزمینی استفاده کردند. تسلطی (۱۳۸۲) در تحقیقی در دشت چمچال مدل شبکه عصبی پرسپترون را برای شبیه سازی سطح آب زیرزمینی در چاهک مشاهده ای استفاده نمود و آن را به عنوان مناسب ترین مدل انتخاب کرد. اسماعیلی ورکی و همکاران (۱۳۸۳) در تحقیقی که از سیستم هوشمند شبکه عصبی با ساختار پرسپترون چند لایه برای برآورد تغییرات سطح ایستابی آبخوان یزد گرد استفاده کردند. علیمحمدی و افشار (۱۳۸۵) در تحقیقی نشان دادند که نتایج حاصل حاکی از دقت بالای روش شبکه های عصبی مصنوعی و عملکرد ضعیف روش رگرسیونی در تولید ضرایب پاسخ آبخوان برای مجموعه ای ثابت از داده های موجود است. ایزدی و همکاران (۱۳۸۶) در تحقیقی با استفاده از شبکه های عصبی مصنوعی به پیش بینی سطح ایستابی دشت نیشابور پرداختند. نتایج آزمایش های مختلف نشان داد که شبکه عصبی

متلب^۳ تعیین و $\frac{۲}{۳}$ کل دادهها يعني ۷۰ درصد برای آموزش، ۱۵ درصد برای صحبت سنجی و ۱۵ درصد برای آزمون انتخاب شد. برای آموزش شبکه از بردارهای مختلف استفاده شد. در پایان ، نتایج حاصل از شبکه پیش خور با الگوریتم پس انتشار خطای با نتایج حاصل از سری زمانی تلفیقی مقایسه شد.

روش تحقیق

مدل شبکه عصبي مصنوعی، يك از روش های مورد استفاده در این تحقیق است. مفهوم شبکه های عصبي مصنوعی برای نخستین بار در سال ۱۹۱۱ توسط سگال^۴ بیان گردید. شبکه عصبي مصنوعی جزء آن دسته از سامانه های پویایی است که با پردازش روی داده های تجربی داشت یا قانون نهفته در درون دادهها را به ساختار شبکه منتقل می کند. لذا باور بر این است که با انتخاب پارامترهای نسبتاً مستقل از هر حوزه آبخیز به عنوان متغیرهای ورودی، يك مدل تعیین یافته حاصل می شود. بدین طریق شبکه عصبي مصنوعی آموزش یافته، بیشترین وزن را به متغیری خواهد داد که بیشترین تأثیر را در خروجی داشته باشد (منهاج، ۱۳۷۷؛ دونه و تیروملا: ۲۰۰۰).

شبکه های عصبي در واقع توسط يك سری محدود از داده های واقعی آموزش می بیند و چنانچه پارامترهای مؤثر بر پدیده مورد بررسی به صورت صحیح انتخاب و به شبکه داده شوند، می توان انتظار داشت که جواب های منطقی از شبکه دریافت شود. بدین ترتیب شبکه عصبي احتماجی به تحلیل روابط رگرسیونی متغیرهای وابسته ندارد. البته خود این تحلیل نیازمند داشتن داده های پایه ای است که به دست آوردن آن ها در بسیاری از موارد کار مشکلی است. بنابراین شبکه عصبي می تواند مدل بهتری را با توجه به منابع داده های موجود ارائه دهد. در حال حاضر استفاده از شبکه عصبي کاربرد وسیعی در علوم مختلف از جمله علوم و مهندسي آب و آبخیزداری یافته است. در بیشتر موارد برای مدل سازی از شبکه پرسپترون چند لایه استفاده شده است، چرا که شبکه ها در شناخت الگو و تابع حاکم بر مسائل غیرخطی بسیار متحیرند. همچنین الگوریتم پس انتشار خطای که از مطرح ترین الگوریتم های آموزش این شبکه است، مورد استفاده قرار گرفته است. شبکه عصبي پرسپترون، يك شبکه پیشرو چند لایه، شامل يك ورودی، يك یا چند لایه پنهان و يك لایه خروجي است. گره های ورودی، اطلاعات را از بیرون دریافت می کنند و نتایج از طریق نزون های لایه خروجی شبکه حاصل می گردند. شبکه عصبي پیش رو از مجموعه اطلاعات ورودی، يك پاسخ در مسیر رو به جلو تولید

سیلسیوس و تبخیر پتانسیل آن ۳۷۲۰ میلی متر در سال می باشد. دشت مرودست یکی از مهم ترین دشت های کشاورزی استان یزد می باشد. آبخوان این دشت از طریق نفوذ مستقیم از ریزش های جوی، نفوذ از جریان های سطحی، آب برگشته از مصارف کشاورزی و فضای سبز، شرب و صنعت و از طریق آبدی قنوات بیرون از محدوده بیلان تغذیه و از طریق برداشت از آب زیرزمینی برای مصارف مختلف و همچنین خروجی زیرزمینی تخلیه می گردد (بی نام، ۱۳۷۹).

داده های مورد بررسی

برای بررسی تغییرات سطح آب زیرزمینی از نتایج اندازگیری ماهانه سطح آب ۴۲ حلقه چاه مشاهده ای استفاده شد که از این تعداد، ۲۱ چاه پیزومتری (مشاهده ای) با داشتن آمار نسبتاً طولانی مدت ۲۲ ساله (۱۳۶۶-۸۸) در محدوده مدل سازی قرار گرفتند.

پس از بازسازی داده های ارتفاع مطلق سطح سطح چاه های مشاهده ای، برای هر ماه در سال های مختلف يك میانگین وزنی با استفاده از روش چند ضلعی تیسن در نرم افزار سیستم اطلاعات جغرافیایی^۱ محاسبه شد. این میانگین های وزنی به عنوان معرف دشت انتخاب شدند. سپس داده های میانگین وزنی با استفاده از رابطه (۱) نرم افزاری و برای مدل سازی آماده شدند:

$$T = T_{\min} + \frac{(T_{\max} - T_{\min})(X - X_{\min})}{(X_{\max} - X_{\min})} \quad (1)$$

T: مقادیر نرمال شده داده های واقعی، X : داده های اصلی سطح آب زیرزمینی مشاهده شده، X_{\max} و X_{\min} و بیشینه داده های اصلی، T_{\max} و T_{\min} : بیشینه و کمینه داده های هدف که در اینجا به ترتیب ۰/۹ و ۰/۱ است.

به علت تأثیر متفاوت داده های ورودی بر نزون ها، در ابتدا لازم است داده های ورودی به شبکه نرمال شوند، یعنی بین يك دامنه عددی، که معمولاً (۰/۰) است قرار گیرند. با توجه به اینکه در لایه مخفی از تابع سیگموئید استفاده شد، از رابطه (۱) که باعث می شود داده ها بین ۰/۱ و ۰/۹ قرار گیرند، برای نرم افزار میانی تاب آشده، سپس مدل آزمایشی بر روی داده ها صورت گرفت تا بهترین مدل سری زمانی انتخاب شود. اما برای استفاده از شبکه عصبي ترکیب ورودی، سری داده های ورودی و هدف و بعد از آن داده های آموزشی و آزمایشی در محیط

کاهش شبیب دارد. علاوه بر آن حافظه کمتری برای این الگوریتم نیاز است.

الگوریتم آموزشی شبیب توأم مقیاس شده^۴ (SCG)

الگوریتم مقیاس شده طوری طراحی شده که از جستجوی خطی زمان بر دوری کند. این الگوریتم بسیار پیچیده است و اساس کار آن ترکیب دو روش شبیب توأم و لونبرگ مارکوارت است. رویه الگوریتم آموزشی شبیب توأم مقیاس شده به تکرارهای بیشتر برای هم‌گرایی نسبت به بقیه الگوریتم‌های شبیب توأم نیاز دارد اما از مقدار محاسبات در هر تکرار به طور محسوسی کاسته می‌شود زیرا جستجوی خطی در این روش انجام نمی‌شود.

الگوریتم لونبرگ مارکوارت^۵ (LM)

همانند روش‌های شبه نوتن این روش نیز سعی در کاهش محاسبات با استفاده از عدم محاسبه ماتریس هیسین دارد و بسیار سریع‌تر از بقیه الگوریتم‌ها عمل می‌کند. اشکال عمده روش لونبرگ مارکوارت نیاز آن به نگهداری ماتریس‌های پرحجم در حافظه است و این مسئله نیاز به فضای زیادی دارد (کیا، ۱۳۸۹).

سری زمانی

روش دیگر مورد استفاده در این پژوهش، سری زمانی تلفیقی است. یک سری زمانی مجموعه مشاهداتی است که بر اساس زمان مرتب شده‌اند و می‌تواند ایستا و پویا باشد. پویایی در سری‌های زمانی در میانگین و واریانس است، بدین معنی که در طول زمان میانگین و واریانس مشاهدات ثابت نیست. پویایی میانگین ناشی از روند و پویایی واریانس ناشی از تناوب داده‌ها است. هر سری زمانی دارای چهار مؤلفه که شامل روند، تناوب فصلی، تناوب دوره‌ای و مؤلفه تصادفی غیر قابل پیش‌بینی است. هدف اصلی از مدل‌سازی سری زمانی را می‌توان پیش‌بینی آینده سری زمانی و تولید داده‌های مصنوعی دانست. سری‌های زمانی را معمولاً به صورت گستته یا پیوسته بررسی می‌کنند. اگر مشاهدات به طور پیوسته بر حسب زمان در نظر گرفته شوند سری زمانی حاصل را پیوسته می‌نمایند. اگر مشاهدات را به طور منظم در فاصله‌های مساوی ثبت شوند یک سری زمانی گستته به دست می‌آید (بزرگیا، ۱۳۶۶).

می‌کند. به عبارت دیگر هیچ پس‌خوری ندارد. همچنین اتصالات این شبکه کامل است یعنی هر نرون به تمام نرون‌های لایه بعدی اتصال دارد (منهاج، ۱۳۷۷).

شبکه‌های پس‌انتشار

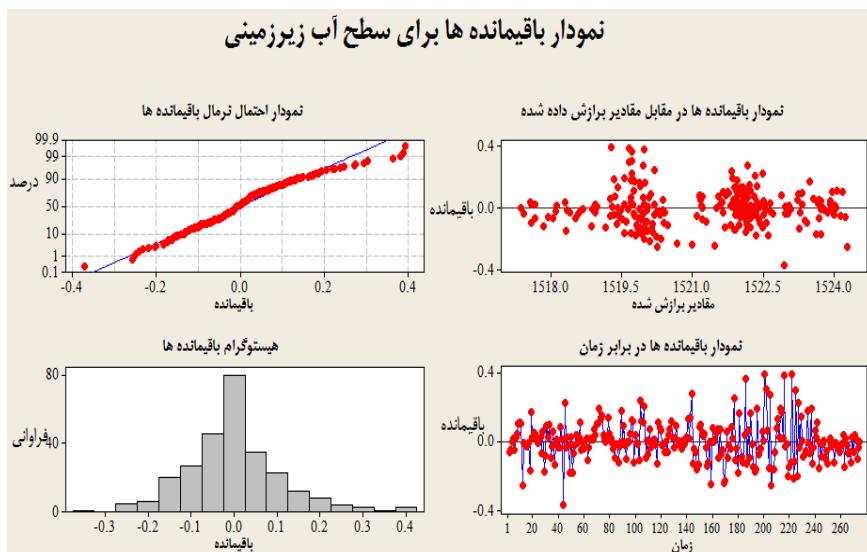
یک شبکه پس‌انتشار دارای بایاس، یک لایه سیگموئید و یک لایه خروجی خطی توانایی تخمین زدن هر تابعی با نقاط ناپیوستگی محدود را دارد. پس‌انتشار استاندارد، یک الگوریتم با شبیب تزویلی است که در آن وزن‌های شبکه در جهت تابع کارایی^۱ حرکت می‌کنند. لغت پس‌انتشار به رفتار شبکه پس‌انتشار در محاسبه شبیب در شبکه‌های غیر خطی چند لایه اشاره دارد. شبکه‌های چند لایه اغلب از تابع انتقال لوگ سیگموئید استفاده می‌کنند. این تابع به ازای ورودی ($+∞$ ، $-∞$) خروجی بین یک و صفر تولید می‌کند. گاهی اوقات تابع انتقال تائزانت سیگموئید در شبکه‌های چند لایه مورد استفاده قرار می‌گیرد. در بعضی موارد نیز تابع انتقال خطی در شبکه‌های پس‌انتشار استفاده می‌شود (کیا، ۱۳۸۹).

شبکه‌های پیش‌خود^۲

شبکه‌های پیش‌خود اغلب یک یا چند لایه مخفی از نرون‌های سیگموئید هستند و از یک لایه پایانی خطی استفاده می‌کنند. شبکه‌های چند لایه از نرون‌ها با یک تابع انتقال غیر خطی به شبکه اجازه می‌دهد که توانایی یادگیری رابطه خطی و غیر خطی را بین ورودی‌ها و خروجی‌ها داشته باشد. لایه خروجی خطی به شبکه این امکان را می‌دهد که خروجی خارج از محدوده $+1$ و -1 داشته باشد. البته اگر به خروجی مثلاً در محدوده یک و صفر نیاز باشد می‌توان از تابع لوگ سیگموئید در لایه خطی استفاده کرد. در این شبکه تمامی توابع از شبیب تابع کارایی برای تنظیم وزن‌ها و بایاس‌ها از تکنیک پس‌انتشار استفاده می‌کنند (کیا، ۱۳۸۹).

تابع آموزشی پس‌انتشار برگشتی^۳ (RP)

الگوریتم آموزش پس‌انتشار برگشتی باعث از بین بردن تأثیر مضر بر روی اندازه مشتقات جزئی است. تنها علامت مشتق برای بهنگام رسانی وزن‌ها استفاده می‌شود و اندازه مشتق اثری بر بهنگام رسانی وزن‌ها ندارد. مقدار تغییرات وزن با استفاده از یک مقدار بهنگام رسیده جداگانه تعیین می‌شود. این الگوریتم کارایی بسیار بالاتری نسبت به الگوریتم استاندارد



شکل ۲- نمودارهای مربوط به باقیمانده‌های حاصل از برآذش مدل آریما(۱،۱،۱)

بررسی و تجزیه و تحلیل مدل‌هایی که پارامتر بیشتری انجام می‌گردد، یعنی مدلی که کمتر از مدل مشخص شده است و این مدل را به عنوان یک حالت خاص در بر می‌گیرد، استفاده می‌شود. از روی نمودارهای توابع خود همبستگی و همبستگی جزی، دو مدل آریما(۱,۱,۰) و آریما(۲,۱,۰) تشخیص داده شد. مناسب بودن مدل از تجزیه و تحلیل باقیمانده مدل برآذش شده بررسی شد که مناسب بودن آن‌ها مورد تأیید قرار گرفت (شکل ۲).

برای اینکه مدل مناسب بین دو مدل انتخاب شده تعیین شود از معیار اطلاعاتی آکائیک^۱ استفاده شد. مدلی که معیار اطلاعاتی آکائیک آن کمتر باشد مدل مناسب است. معیار اطلاعاتی آکائیک مدل آریما(۱,۱,۰) نسبت به مدل آریما(۲,۱,۰) کمتر است و مناسب‌ترین مدل برای پیش‌بینی سطح آب زیرزمینی انتخاب شد.

اما در شبکه عصبی پیش‌خور پس انتشار خطای بردارهای ورودی مختلفی به شبکه عصبی داده شد. این ورودی‌ها شامل بارندگی ماهانه، دی متوسط ماهانه، برداشت و تغذیه ماهانه، سطح آب زیرزمینی با یک ماه، دو ماه و سه ماه تأخیر بود که از بین ترکیب ورودی داده‌هایی که به شبکه عصبی داده شد ورودی سطح آب زیرزمینی با یک ماه تأخیر مناسب‌ترین ورودی با ضریب همبستگی بالا و جذر مربع میانگین خطای پایین انتخاب شد. در این شبکه عصبی سه الگوریتم آموزشی لونبرگ مارکوارت، پس انتشار ارجاعی و شبیب توازن مقیاس شده استفاده شد. هر یک از این سه الگوریتم آموزشی به داده‌های ورودی برآذش داده شدند.

تئوری مدل‌های سری زمانی

برای مدل‌سازی سری‌های غیر فصلی ایستا مدل‌های خودهمبسته^۲، مدل میانگین متحرک^۳ و مدل مرکب خودهمبسته میانگین متحرک^۳ استفاده می‌شود.

مدل خودهمبسته بر پایه زنجیره مارکوف در زنجیره زمانی بنا شده است. یک سری زمانی از زنجیره مارکوف تعیین می‌کند، اگر هر داده ثبت شده سری زمانی در زمان t با زمان قبل و یا زمان بعد از خود مرتبط باشد. در مدل میانگین متحرک متغیر t از روی مقدار تصادفی در همان لحظه به علاوه q برایر مقدار تصادفی مربوط به زمان‌های قبل از t برآورد می‌شود. فرایندهای خود همبسته-میانگین متحرک که فرایندهای مرکب نامیده می‌شوند از ترکیب دو فرایند پیشین به دست می‌آید. این فرایند شامل p جمله AR و q جمله MA است. مدل آریما یک مدل کمی که توانایی نمایندگی طبقه گسترده‌ای از سری‌های زمانی نایستا را دارد، فرایند تلفیقی خود همبسته-میانگین متحرک با درجه (p,d,q) است. با توجه به اینکه در عمل بیشتر سری‌های زمانی نایستا هستند، لذا این رده از فرایندها کاربرد گسترده‌ای دارند (خرمی و بزرگنیا، ۱۳۸۶).

نتایج و بحث

پس از تشخیص یک مدل و برآورد پارامترهای آن، مناسب بودن مدل با استفاده از تجزیه و تحلیل باقیمانده‌های مدل برآذش

جدول ۱- مقادیر آماره‌های برازش در ورودی‌های مختلف با توابع آموزشی

تابع انتقال	ارزیابی	*دبی متوسط(م)	دبی متوسط(م کث)	سطح آب زیرزمینی با سه ماه تأخیر(متر)	سطح آب زیرزمینی با دو ماه تأخیر(متر)	سطح آب زیرزمینی با یک ماه تأخیر(متر)	سطح آب زیرزمینی با یک ماه تأخیر(م)	تابع انتقال
لوبرگ	مریع میانگین خطاهای آزمایش(متر)	.۰/۰۱	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	لوبرگ
مارکوت	مریع میانگین خطاهای آموزش(متر)	.۰/۰۲	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	مارکوت
ضریب همبستگی آزمایش		.۰/۲۳	.۰/۹۹	.۰/۹۹	.۰/۹۸	.۰/۹۸	.۰/۹۸	
ضریب همبستگی آموزش		.۰/۰۵	.۰/۹۹	.۰/۹۹	.۰/۹۸	.۰/۹۸	.۰/۹۸	
پس	مریع میانگین خطاهای آزمایش(متر)	.۰/۱۱	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	پس
انتشار	مریع میانگین خطاهای آموزش(متر)	.۰/۰۱	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	انتشار
برگشتی	ضریب همبستگی آزمایش	.۰/۰۸	.۰/۹۹	.۰/۹۹	.۰/۹۸	.۰/۹۸	.۰/۹۸	برگشتی
ضریب همبستگی آموزش		.۰/۰۴	.۰/۹۹	.۰/۹۹	.۰/۹۹	.۰/۹۹	.۰/۹۹	
شب	مریع میانگین خطاهی آزمایش(متر)	.۰/۱۱	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	شب
توأم	مریع میانگین خطاهای آموزش(متر)	.۰/۰۱	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	توأم
مقیاس	ضریب همبستگی آزمایش	.۰/۰۷	.۰/۹۹	.۰/۹۹	.۰/۹۸	.۰/۹۸	.۰/۹۸	مقیاس
شده	ضریب همبستگی آموزش	-.۰/۰۵	.۰/۹۹	.۰/۹۹	.۰/۹۸	.۰/۹۸	.۰/۹۸	شده

* متر مکعب : م مک، متر مکعب بر ثانیه: م مکث، میلی‌متر: م

جدول ۲- مقادیر آماره‌های برازش در ورودی‌های مختلف با توابع آموزشی

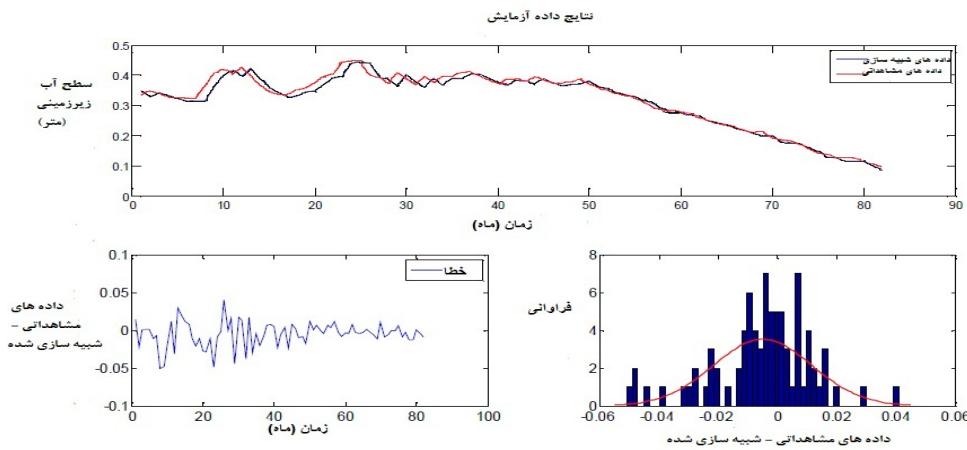
تابع انتقال	ارزیابی	*دبی متوسط(م)	دبی متوسط(م کث)	بارندگی، بارندگی با یک ماه تأخیر(م) و تغذیه(متر)، برداشت(م مک)، سطح آب زیرزمینی با تغذیه(متر)، برداشت(م مک) و یک ماه تأخیر(م)	دبی متوسط(م)	دبی متوسط(م کث)	بارندگی، بارندگی با یک ماه تأخیر(م)	تابع انتقال
لوبرگ	مریع میانگین خطاهای آزمایش(متر)	.۰/۰۱	.۰/۰	.۰/۰۳	.۰/۰۳	.۰/۰۲	.۰/۰	لوبرگ
مارکوت	مریع میانگین خطاهای آموزش(متر)	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	مارکوت
ضریب همبستگی آزمایش		.۰/۹۴	.۰/۹۶	.۰/۵۴	.۰/۶۳	.۰/۷۸	.۰/۰	
ضریب همبستگی آموزش		.۰/۷۴	.۰/۷۲	.۰/۸۷	.۰/۰۹	.۰/۵۰	.۰/۰	
پس	مریع میانگین خطاهای آزمایش(متر)	.۰/۰۱	.۰/۰۱	.۰/۰۱	.۰/۰۳	.۰/۰۳	.۰/۰	پس
انتشار		.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	انتشار
برگشتی	مریع میانگین خطاهای آموزش(متر)	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	برگشتی
ضریب همبستگی آزمایش		.۰/۸۹	.۰/۸۵	.۰/۹۲	.۰/۴۹	.۰/۳۳	.۰/۰	
ضریب همبستگی آموزش		.۰/۶۸	.۰/۷۳	.۰/۶۹	.۰/۱۱	-.۰/۳۲	.۰/۰	
شب	مریع میانگین خطاهی آزمایش(متر)	.۰/۰	.۰/۰۱	.۰/۰۱	.۰/۰۳	.۰/۰۳	.۰/۰	شب
توأم		.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	توأم
مقیاس	مریع میانگین خطاهای آموزش(متر)	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	.۰/۰	مقیاس
شده		.۰/۷۸	.۰/۸۱	.۰/۸۰	.۰/۳۶	.۰/۳۹	.۰/۴۱	شده
ضریب همبستگی آزمایش		.۰/۸۴	.۰/۸۰	.۰/۲۴	.۰/۵۲	.۰/۳۶	.۰/۴۱	
ضریب همبستگی آموزش		.۰/۷۸	.۰/۸۱	-.۰/۴۳	-.۰/۱۲	.۰/۴۳	.۰/۴۱	

همبستگی بالا و میانگین قدر مطلق خطاهای نسبت به دیگر ورودی‌ها، مناسب‌ترین ورودی برای مدل سازی شبکه عصبی است. این ورودی بیشترین ضریب همبستگی و کمترین میانگین قدر مطلق خطاهای را در الگوریتم لونبرگ مارکوآت دارد هر چند که مقادیر این ورودی نسبت به دیگر ورودی‌ها در دو الگوریتم دیگر نیز مناسب‌تر است.

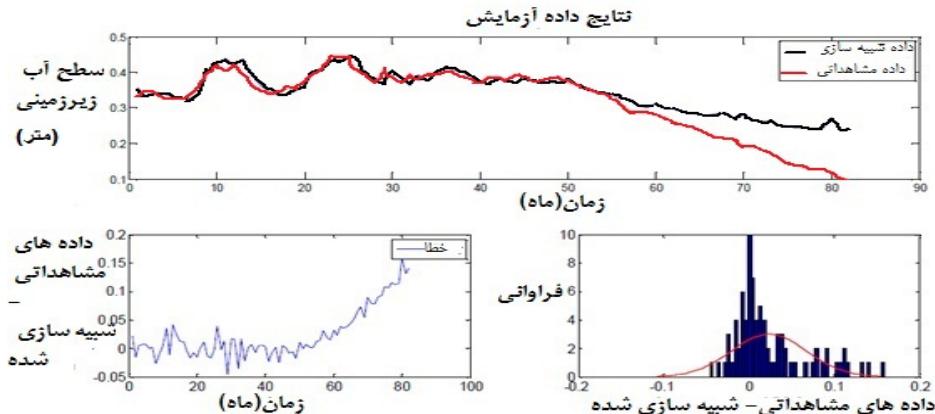
با توجه به اینکه مقادیر شبیه‌سازی شده سطح آب زیرزمینی در هر سه الگوریتم به مقادیر واقعی نزدیک‌تر بود و مناسب‌ترین ورودی انتخاب شد. بنابراین نمودارهای مربوط به این ورودی در سه الگوریتم آموزشی در شکل‌های (۳) و (۵) ترسیم شد.

مقادیر ضریب همبستگی و جذر مربع خطاهای در سه الگوریتم آموزشی برای ورودی‌های مختلف محاسبه شد (جدول‌های ۱ و ۲).

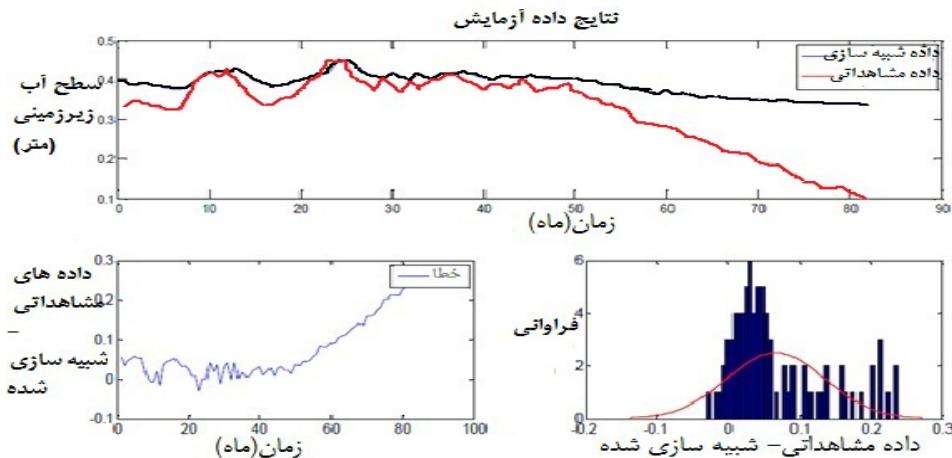
جدول‌های (۱) و (۲) نشان‌دهنده سناریوهای مختلف در سه الگوریتم آموزشی استفاده شده به همراه مقادیر آمارهای ضریب همبستگی و مربع میانگین خطاهای برای هر یک از آنها در دو مرحله آموزش و آزمایش هستند. در این جدول‌ها همان‌گونه که دیده می‌شود برای تمامی ورودی‌ها الگوریتم لونبرگ مارکوآرت مناسب‌ترین الگوریتم آموزشی با ضریب همبستگی بالا و جذر مربع میانگین خطای پایین است. همچنین استنباط شد که ورودی سطح آب زیرزمینی با یک ماه تأخیر با توجه به میزان ضریب



شکل ۳- شبیه‌سازی ورودی ارتفاع سطح مطلق آب زیرزمینی با یک ماه تأخیر با تابع Train(LM)



شکل (۴): شبیه‌سازی ورودی ارتفاع سطح مطلق آب زیرزمینی با یک ماه تأخیر با تابع Train(RP)



شکل ۵- شبیه‌سازی ورودی ارتفاع سطح مطلق آب زیر زمینی با یک ماه تأخیر باتابع Train(SCG)

جدول (۳): مقادیر آماره‌های برازش در مرحله آزمایش

روش	آماره
شبکه عصبی مصنوعی	CE
سری زمانی تجمعی(۱،۰)	RMSE
۰/۰۱۰	MAE
۰/۰۲۰	

$$RMSE = \sqrt{\frac{1}{n} \sum_t^n (H_t - \hat{H}_t)^2} \quad (۲)$$

$$CE = 1 - \frac{\sum_{t=1}^n (H_t - \hat{H}_t)^2}{\sum_{t=1}^n (H_t - \bar{H})^2} \quad (۳)$$

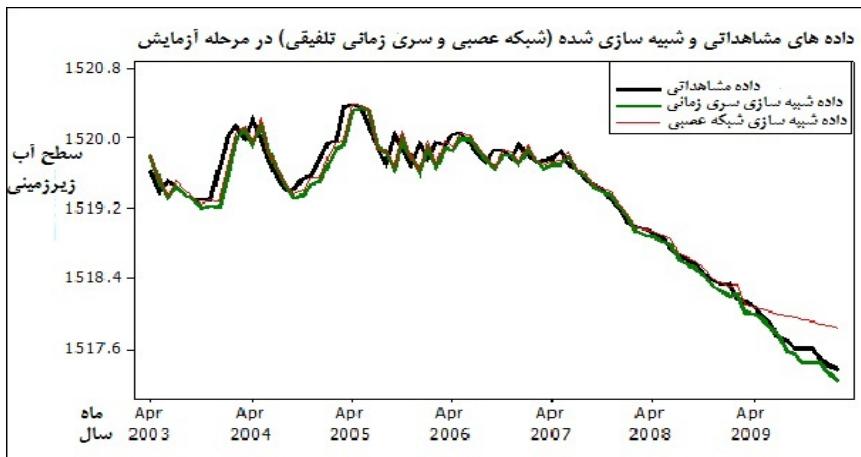
$$MAE = \frac{1}{n} \sum_{t=1}^n |H_t - \hat{H}_t| \quad (۴)$$

MAE: میانگین قدر مطلق خطاهای (متر)، CE: ضریب بازدهی، RMSE: جذر میانگین مربع خطاهای (متر)، H_t : مقادیر مشاهداتی، \hat{H}_t : مقادیر پیش‌بینی شده، \bar{H} : میانگین مشاهداتی، n : تعداد مشاهدات است. با توجه به آماره‌های جدول (۳)، دیده شد که هر چند مقادیر آماره‌ها برای هر دو مدل نزدیک بهم است ولی نتایج مدل شبکه عصبی مصنوعی مناسب‌تر از سری زمانی تجمعی است.

در شکل ۳ که مربوط به شبیه‌سازی داده‌ها با الگوریتم لونبرگ مارکوآت است، این داده‌ها به داده‌های واقعی نزدیکتر و تطابق و هم خوانی بیشتری نسبت به دو شکل (۴) و (۵) دارند. این نشان دهنده مناسیت بودن این الگوریتم نسبت به دو الگوریتم دیگر است.

شکل (۴) نیز مقادیر شبیه‌سازی را با الگوریتم پس انتشار برگشتی نشان می‌دهد. داده‌های شبیه‌سازی شده نسبت به شکل (۳) هم خوانی و تطابق کمتری به داده‌های واقعی دارند ولی نسبت به شکل (۵) که مقادیر شبیه‌سازی با الگوریتم شب تأم مقياس شده است، به خصوص در قسمت انتهایی نمودار، هم خوانی و تطابق بیشتری دارد.

در پایان، برای انتخاب بهترین روش از بین دو روش سری زمانی تلفیقی و شبکه عصبی مصنوعی پیش‌خور پس انتشار خطای از معیارهای ارزیابی میانگین قدر مطلق خطاهای، جذر میانگین مربع خطاهای و ضریب بازدهی استفاده شد که در رابطه (۲) تا (۴) تعریف شده‌اند.



شکل ۶- داده های مشاهداتی و شبیه سازی شده با روشن شکه عصبی مصنوعی و سری زمانی تلفیقی در مرحله آزمایش

جزئی دو مدل آریما (۱،۱،۰) و آریما (۲،۱،۰) تشخیص داده شد. مناسب بودن مدل از تجزیه و تحلیل باقیمانده مدل برآش شده بررسی شد که مناسب بودن آن مورد تأیید قرار گرفت. ازین این دو مدل آریما با توجه به معیار اطلاعاتی آکائیک مدل آریما (۱،۱،۰) مناسب‌ترین مدل برای پیش‌بینی سطح آب زیرزمینی انتخاب شد. در تکنیک شبکه عصبی، از شبکه‌های عصبی پیش‌خور پس انتشار خطا استفاده شد. برای انتخاب بهترین روش از سه تابع آموزشی پس انتشار ارجاعی، شبیه تأمین مقیاس شده و تابع لونبرگ-مارکوارت استفاده شد. بردارهای ورودی مختلف، بارندگی، دبی متوسط، برداشت، تغذیه و سطح آب زیرزمینی با تأخیر یک ماهه، دو و سه ماهه به مدل داده شد. ازین تمام ورودی‌ها و توابع آموزشی مورد استفاده در شبکه، بهترین ورودی سطح آب زیرزمینی با یک ماه تأخیر و توابع آموزشی لونبرگ-مارکوارت بود. سپس اعتبار مدل‌ها با استفاده از آماره‌های میانگین قدر مطلق خطاهای، ضرب باردهی و جذر میانگین مربع خطاهای مورد بررسی قرار گرفتند. مقادیر آماره‌های میانگین قدر مطلق خطاهای و جذر میانگین مربع خطاهای در مدل شبکه عصبی مصنوعی پیش‌خور پس انتشار خطا کمتر از مدل سری زمانی آریما (۱،۱،۰) بود، که به عنوان بهترین روش برای پیش‌بینی سطح آب زیرزمینی انتخاب شد.

همان‌گونه که در شکل (۶) مشاهده می‌شود هر دو مدل با داده‌ها تطابق زیادی دارند ولی داده‌های شبیه سازی سری زمانی تجمعی در انتهای نمودار که مربوط به سال‌های اخیر است، تطابق کمتری نسبت به داده‌های شبیه سازی شبکه عصبی دارد و این نقطه قوتی برای انتخاب مدل شبکه عصبی مصنوعی به عنوان مناسب‌ترین روش برای شبیه سازی داده‌های سطح آب زیرزمینی منطقه است.

نتایج تحقیقاتی که تاکنون انجام شده (در مقدمه نیز به آنها اشاره شده است) نشان دهنده این است که شبکه عصبی پیش‌خور پس انتشار خطا برای پیش‌بینی سطح آب زیرزمینی روشی مناسب است که دقت بالایی دارد و مناسب‌ترین الگوریتم آموزشی آن، الگوریتم لونبرگ مارکوارت است. در این پژوهش نیز شبکه عصبی مصنوعی پیش‌خور پس انتشار خطا با الگوریتم آموزشی لونبرگ مارکوارت نسبت به روش سری زمانی تجمعی، به عنوان مناسب‌ترین روش با دقت بالا برای پیش‌بینی سطح آب زیرزمینی داشت مروضت انتخاب شد.

نتیجه‌گیری

در این تحقیق برای پیش‌بینی سطح آب زیرزمینی از دو مدل شبکه عصبی مصنوعی و سری زمانی تلفیقی استفاده شد. در مدل سری زمانی از روی تابع خود همبستگی و خود همبستگی

منابع

- اسماعیلی ورکی، م، خیاط خلقی، م. و. شفیعی. ۱۳۸۳. ارائه یک مدل هوشمند برای برآورد نوسانات سطح آب زیرزمینی یک آبخوان آبرفتی با استفاده از شبکه عصبی مصنوعی. اولین کنفرانس سالانه مدیریت منابع آب ایران، تهران - انجمن علوم و مهندسی منابع آب ایران، دانشکده فنی دانشگاه تهران.
- اصغری مقدم، ا، ندیری، ع، و. نورانی. ۱۳۸۵. ارزیابی توانانی‌های شبکه‌های عصبی مصنوعی در مدل‌سازی آبخوانهای کمپلکس. بیست و پنجمین گردهمایی علوم زمین‌شناسی، سازمان زمین‌شناسی کشور

- ۳- ایزدی، ع.، داوری، ک.، علیزاده، ا.، قهرمان، ب. و س.ا. حقایقی مقدم. ۱۳۸۶. پیش‌بینی سطح ایستابی با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی: دشت نیشابور). مجله آبیاری و زهکشی ایران، ۱(۲): ۵۹-۷۱.
- ۴- بزرگنیا، ا. ۱۳۶۶، تجزیه و تحلیل سریهای زمانی و پیش‌بینی، انتشارات استان قدس رضوی، ۱۹۰ صفحه.
- ۵- تسلیطی، ب. ۱۳۸۲. برآورد سطح آب زیر زمینی با استفاده از modflow و شبکه عصبی مصنوعی. پایان نامه کارشناسی ارشد، رشته دانشکده کشاورزی، دانشگاه تربیت مدرس، صفحه ۱۰۵.
- ۶- جمالی، م.، میرعربی، ع. و م. نخعی. ۱۳۸۸. مقایسه روش خطی (ARIMA) و غیرخطی (ANN) در مدلسازی نوسانات سطح آب زیرزمینی منطقه مورد مطالعه دشت قاین. نخستین کنفرانس سراسری آبهای زیرزمینی، بهبهان (دانشگاه آزاد اسلامی واحد بهبهان)، چکیده مقالات.
- ۷- خرمی، م. و ا. بزرگنیا. ۱۳۸۶. تجزیه و تحلیل سری‌های زمانی با نرم‌افزار Minitab14. انتشارات سخن‌گستر، مشهد، ۳۳۶ صفحه.
- ۸- رحمانی، ع.ر. و م. سدهی. ۱۳۸۳. پیش‌بینی تغییرات سطح آب‌های زیرزمینی دشت همدان- بهار با مدل سری زمانی. مجله علمی مهندسین طرح و تحقیقات آب و فاضلاب اصفهان، ۱۵(۱۰): ۴۲-۴۹.
- ۹- رضایی، ع. و س. ن. موسوی. ۱۳۸۸. پیش‌بینی تغییرات سطح آب زیرزمینی دشت سیدان - فاروق شهرستان مروdest با مدل سری‌های زمانی. ششمین کنفرانس اقتصاد کشاورزی ایران، کرج، چکیده مقاله.
- ۱۰- علیمحمدی، س. و ع. افشار. ۱۳۸۵. کاربرد شبکه‌های عصبی مصنوعی در شبیه سازی آبهای زیرزمینی. دومین کنفرانس مدیریت منابع آب، اصفهان، چکیده مقاله.
- ۱۱- کیا، م. ۱۳۸۹. شبکه‌های عصبی در MATLAB. چاپ سوم، نشر کیان رایانه سیز، ۲۲۹ صفحه.
- ۱۲- بی‌نام. ۱۳۷۹. گزارش مطالعات آب زیرزمینی منطقه سروست. شرکت آب منطقه‌ای استان یزد.
- ۱۳- منهاج، م. ۱۳۷۷. مبانی شبکه‌های عصبی (هوش محاسباتی). مرکز نشر پروفسور حسابی، جلد اول، صفحات ۱۷-۴۹.
- ۱۴- محتشم، م.، دهقانی، ا.، اکبرپور، ا.، مفتاح هلقی، ا. و ب. اعتباری. ۱۳۸۹. پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت بیرون). مجله آبیاری و زهکشی، ۱۰(۱-۱۰).
- ۱۵- میر عربی، ع. و م. نخعی. ۱۳۸۷. پیش‌بینی نوسانات سطح آب زیرزمینی دشت بیرون با استفاده از شبکه عصبی. مجموعه مقالات دوازدهمین همایش انجمن زمین‌شناسی ایران، اهواز، چکیده مقاله.
- 16- Banerjee, P., Prasad, P. K. and V.S Singh, 2009. Forecasting of groundwater level in hard rock region using artificial neural network, Environmental Geology, 58(6): 1239–1246.
- 17- Box, G. E. P. and G.W. Jenkins, G.W. 1976. Time Series analysis: Forecasting and control. Revised ed., Holden-Day, San Francisco, CA.
- 18- Chandramouli, V., Lingireddy, S. and G. M.Brion, 2007. Robust training termination criterion for back propagation ANNs applicable to small data sets. Journal of Computing in Civil Engineering, 21(1): 39- 46.
- 19- Coppola, J. M., Szidarovszky, F., Poulton, M. and E. Charles. 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.
- 20- Daliakopoulos, I. N., Coulibaly, P. and I. K. Tsanis. 2005. Groundwater level forecasting using artificial neural networks. Journal of Hydrology, 309(4): 229-240.

- 21- Doe, M. C. and C.Thirumalayah. 2000. Real time forecasting using neural networks. Artificial Neural Networks in Hydrology, edited by R.S. Govindarajue and A. Ramachandra Rao, Chapter 3.
- 22- Ghadampour, Z. and Gh. Rakhsandehroo, 2010. Using artificial neural network to forecast groundwater depth in union county Well. World Academy of Science, Engineering and Technology, 62.
- 23- Jothiprakash, V. and S. Sakhare, 2008. Ground water level fluctuations using artificial neural network. The 12th International Conference of International Association for Computer Methods and Advances in Geomechanics (IACMAG), Goa, India.
- 24- Lallahem, S., Mania, J., Hani A and Y.Najjar. 2005. On the use of neural networks to evaluate ground water levels in fractured media. Journal of Hydrology, 307: 92–111.
- 25- Mohanty, S. K., Jha, M., Kumar, A. and k. p. Sudhee. 2009. Artificial neural network modeling for groundwater level forecasting in a river island of Eastern India.Water Resour Manage,
- 26- Nayak , Satyaji Rao, Y. R. and K. P. Sudheer. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. Water Resources Management, 2(1):77-99.
- 27- Nourani, V. Asghari Mogaddam, A. and A.O. Nadiri. 2008. An ANN-based model for spatiotemporal groundwater level forecasting, Wiley Inter Science, 22: 5045- 5066.
- 28- Shigidi, A. and L.A. Garcia. 2003. Parameter estimation in groundwater hydrology using artificial neural networks. J.of Computing in Civil Engineering, 17(4): 281- 289.
- 29- Sreekanth, P. D. Geethanjali, N., Sreedevi, P. D. Ahmed, Sh., Ravi Kumar, N. and P. D. Kamala Jayanthi. 2009. Forecasting groundwater level using artificial neural networks, Current Science, 96: 1-7.
- 30- Yang Z.P, W.X. Lu , Long Y. Q. and P. Li. 2009. Application and comparison of two prediction models for groundwater levels: A case study in Western Jilin Province, China, Journal of Arid Environments, 73:487-492.