



پیش‌بینی تراز آب زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی (مطالعه موادی: دشت شبستر)

زینب مفتاحی^{*}، امیرحسین ناظمی^۲ و عطاء‌الله ندیری^۳

(۱) کارشناس ارشد هیدرولوژی، دانشگاه آزاد اسلامی واحد مراغه، zeynabmokhtari25@yahoo.com

(۲) استاد گروه آبیاری دانشکده کشاورزی، دانشگاه تبریز

(۳) دانشجوی دکترای هیدرولوژی، دانشگاه تبریز

^{*} عهده‌دار مکاتبات

دریافت: ۹۱/۲/۱۳؛ دریافت اصلاح شده: ۹۱/۱۲/۷؛ پذیرش: ۹۱/۱۲/۱۰؛ قابل دسترس در تارنما: ۹۲/۴/۳۰

پکیج

آبهای زیرزمینی، همواره به عنوان یکی از منابع مهم و عملده تأمین آب شرب و کشاورزی به ویژه در مناطق خشک و نیمه خشک مطرح بوده‌اند. شبیه‌سازی سیستم آبهای زیرزمینی به دلیل پیچیدگی این سیستمها به آسانی میسر نیست. هدف از این پژوهش، پیش‌بینی نوسانات تراز آب زیرزمینی دشت شبستر واقع در جنوب استان آذربایجان شرقی با استفاده از شبکه‌های عصبی مصنوعی می‌باشد. به منظور آموزش مدل، از اطلاعات ۱۵ پیزومتر که دارای آمار تراز سطح ایستابی با سری زمانی ۹ ساله (۱۳۸۸-۱۳۸۰) بودند و در کل دشت پراکنده‌ی یکنواختی داشتند استفاده شد. پارامترهای دما، بارش، دبی خروجی دریان چای و تراز آب زیرزمینی هر یک از پیزومترها با تأخیر زمانی $t=1$ (ماه قبل) به صورت ماهانه، چهار ورودی اصلی شبکه‌های عصبی مصنوعی را تشکیل دادند. مقدار تراز آب زیرزمینی نیز تنها خروجی این شبکه را شامل می‌شود. نتایج این تحقیق نشان داد که شبکه عصبی مصنوعی با تابع آموزشی TRAINLM و تابع محرك TANSIG قادر به پیش‌بینی سطح آب زیرزمینی ماهانه در بازه زمانی ۳ ساله با دقت بالای $R^2=99.63$ در مرحله آموزش و $R^2=99.16$ ، RMSE= 1.167 در مرحله صحبت سنجی در محدوده مورد مطالعه است.

واژه‌های کلیدی: دشت شبستر، تابع آموزشی، تراز آب زیرزمینی، شبکه عصبی مصنوعی.

۱- مقدمه

هیدرولوژی و اهداف مدیریتی، تصمیمات مناسب‌تری را ارائه نمود و آبهای زیرزمینی با کیفیت بالاتری را به دست آورد (سلمی ۱۳۸۹). اگرچه مدل‌های فیزیکی و ریاضی ابزار اساسی برای نشان دادن متغیرهای هیدرولوژیکی و درک فرایندهای صورت گرفته در یک سیستم می‌باشند، اما دارای محدودیت‌های عملی هستند. مشکل عملده ای که هم اکنون کاربران و تهیه کنندگان این مدل‌ها با آن مواجه می‌باشند، نیاز این مدل‌ها به اطلاعات دقیق و متنوع ورودی است.

مدل کردن سفره آبهای زیرزمینی، به منظور پیش‌بینی سطح ایستابی از نظر ایجاد سازه‌های مهندسی، مطالعات هیدرولوژی و مدیریتی، مصارف کشاورزی و بدست آوردن آبهای زیرزمینی با کیفیت بالا، از اهمیت بالایی برخوردار است. در بسیاری از موارد تغییرات سطح ایستابی در آبخوان‌ها صدمات جبران ناپذیری را به سازه‌های مهندسی وارد می‌کند. با پی بردن به این تغییرات می‌توان از نظر بیان

با استفاده از داده‌های متوسط ماهانه بارش، تبخیر و سطح آب اندازه‌گیری شده دریاچه ماقنولیا و بروکلین در مرکز فلوریدا، از شبکه‌های عصبی مصنوعی استفاده کردند و روابط بین سطح آب دریاچه، سطح آب زیرزمینی، بارندگی و تبخیر و تعرق را با استفاده از مدل شبکه‌های عصبی مبتنی بر رگرسیون خطی چندگانه و رگرسیون غیرخطی چندگانه مدلسازی کردند. آنها همچنین با استفاده ازتابع فعالسازی لونبرگ مارکوات که قدرتمندتر از روش‌های مرسوم گرادیان نزولی است (Alp & Cigizoglu 2007) نتایج قابل قبولی را ارائه کردند. چونگ (Chung 2008) برای پیش‌بینی نوسانات سفره آب در مریلند با استفاده از شبکه عصبی، از دو گونه مدل پیش‌بینی بر پایه ANN استفاده نمود. در یک مدل از رابطه بین تغییرات رطوبت خاک و عمق سفره و در مدل دیگر از رابطه بین متغیرهای تابش حرارتی گاما و عمق سفره استفاده شد. نتایج نشان داد که مدل‌های ساخته شده برای ارزیابی نوسانات سفره از دقت بالایی برخوردار بوده، به گونه‌ای که میانگین مربعات خطاهای پیش‌بینی عمق سفره آب در یک دوره ۱۲ ماهه بین 0.043 و 0.047 بوده است. سریکانس و همکاران (Sreekanth et al. 2009) ارزیابی حاصل از مدل‌های شبکه‌های عصبی مصنوعی نظیر الگوی لونبرگ-مارکوات را در پیش‌بینی سطح تراز آب زیرزمینی در حوزه آبخیز مهاش ورم (Maheshwaram) در ایالت حیدرآباد هندوستان مورد آزمون قرار دادند. نتایج نشان داد که مدل کاملاً مناسب با واقعیت بوده و داده‌های حاصل از دقت و قطعیت قابل قبولی ($R^2=0.93$, RMSE=4.50) برخوردار می‌باشدند. در نتیجه روش شبکه‌های عصبی مصنوعی در دهه اخیر با موفقیت برای حل مشکلاتی مربوط به کیفیت آب، (Chang et al. 2008, Seyam & Mogheir 2011) بارندگی و مدلسازی رواناب (Chiang et al. 2007) و اصغری مقدم و همکاران (2007) تخمین هدایت هیدرولیکی (Garcia & Shigidi 2006) استفاده شده است. تاکنون، از شبکه عصبی مصنوعی برای پیش‌بینی رفتار آب زیرزمینی در قالب شبیه‌سازی و مدل‌های بهینه‌سازی، استفاده‌های بسیاری شده است. این روش می‌تواند گزینه‌ای مناسب در مدلسازی کمی منابع آب محسوب شود. لذا این پژوهش به منظور بررسی کاربرد شبکه عصبی مصنوعی برای پیش‌بینی تراز آب زیرزمینی در آبخوان دشت شبسیتر انجام شد.

۲- منطقه مورد مطالعه و داده‌ها

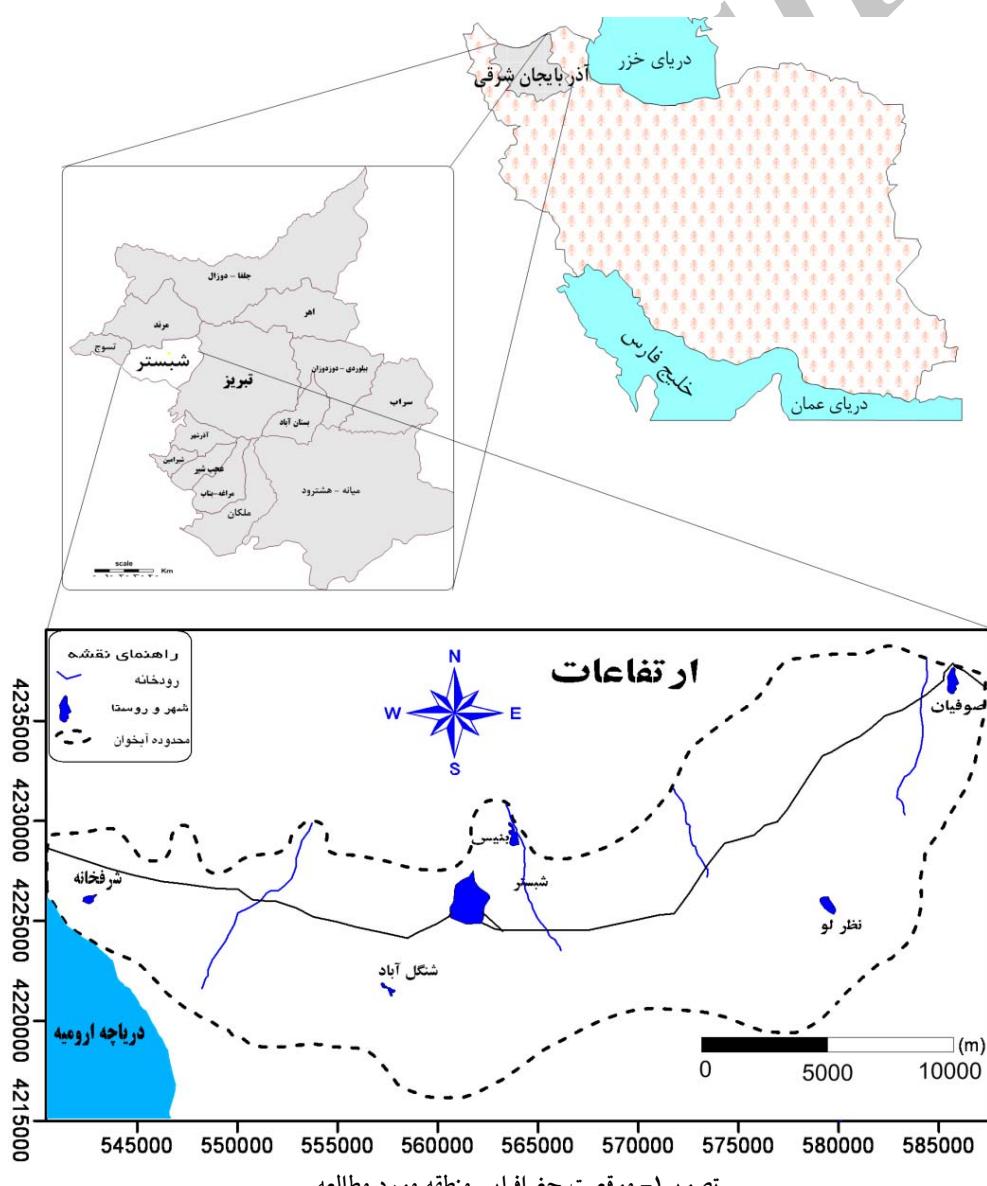
۲-۱- معرفی منطقه

محدوده مطالعاتی شبسیتر یکی از زیر حوضه‌های ۲۵ گانه حوضه آبریز دریاچه ارومیه است که در 60 کیلومتری غرب شهرستان تبریز واقع شده است. این محدوده از طرف شمال به حوضه زیلبر چای

همچنین حجم زیاد محاسبات و نیاز به زمان طولانی در هر بار اجرای مدل، سبب می‌شود تا استفاده از مدل برای بررسی رویکردهای مختلف بهره‌برداری زمانبند، دشوار و گاه غیر ممکن باشد. از سوی دیگر، در اغلب مدل‌های مدیریت منابع آب، لازم است آبخوان به صورت پیوسته و زمانمند شبیه سازی شود، لذا استفاده از این مدل‌ها در فرایند بهینه سازی منجر به افزایش زمان اجرا می‌شود. بر این اساس لازم است تا مدلی هوشمند جایگزین مدل عددی شبیه سازی آبخوان شود (اصغری Copola et al. 2003). کاپلا و همکاران (2003) نشان دادند که شبکه‌های عصبی توانایی بالایی در پیش‌بینی دقیق سطح ایستابی در حالت غیرماندگار در سیستم در حال پمپاژ و موقعیت‌های آب و هوایی مختلف دارند. آنها نشان دادند که این مدل‌ها برای مدلسازی آبخوانهای آهکی نشستی و کارستی که مدل‌های عددی از مدلسازی آنها ناتوان هستند، بسیار مورد تأیید می‌باشند. لالاهم و همکاران (Lallahem et al. 2005) برای اولین بار از شبکه‌های عصبی مصنوعی برای ارزیابی سطح ایستابی در سازند سخت استفاده نمودند. آنها از یک پرسپترون چندلایه استفاده کرده و سطح ایستابی را در پیزومتر مرکزی پیش‌بینی کردند. پس از انجام حساسیت‌سنجی، آنها توانستند تنها با در دست داشتن سطح ایستابی از دو پیزومتر مجاور پیزومتر مرکزی و میزان بارش موثر، علاوه بر پیزومتر مرکزی سطح ایستابی را در دو پیزومتر دیگر پیش‌بینی کنند. لالاهم و همکاران (Lallahem et al. 2005) نشان دادند که این مدل‌ها در مدلسازی سطح ایستابی در مناطق کارستی کارایی بیشتری نسبت به مدل‌های عددی دارند.

میرزاei و ناظمی (1390) از سامانه‌های هوشمند استنتاج عصبی-فازی تطبیقی، شبکه‌های عصبی مصنوعی و برنامه ریزی ژنتیک برای تخمین تراز سطح ایستابی دشت شبسیتر در استان آذربایجان شرقی استفاده نمودند. در این تحقیق از اطلاعات 20 پیزومتر که دارای آمار بالای ۱۷ سال بودند، استفاده شد. بر پایه محاسبات انجام شده، هر سه روش دارای تووانایی قابل توجهی در تخمین میزان تراز سطح ایستابی می‌باشند. دالیاکاپلاس و همکاران (Daliakopoulos et al. 2005) با استفاده از 6 ساختار مختلف شبکه‌های عصبی مصنوعی، توانستند مدل حوضه‌ای در جنوب یونان را که براثر برداشت از آبخوان برای مصارف کشاورزی با مشکل مواجه شده بود، تهیه کرده و سطح ایستابی این آبخوان آبرفتی را پیش‌بینی نمایند. در این مطالعه آنها با استفاده از ساختار شبکه عصبی پیش‌رو با الگوریتم بهینه‌سازی لونبرگ-مارکوات، پیش‌بینی 18 ماهه‌ای از سطح ایستابی در چاه مرکزی این حوضه ارائه کردند. نتایج بدست آمده از این مطالعه از دقت بالایی برخوردار است. داگن و متر (Dogan & Motz 2008) برای برآورد مقدار سطح آب

مرند، از غرب به محدوده مطالعاتی سوچ، از شرق به تبریز و از جنوب به دریاچه ارومیه و پهنه‌های نمکی - رسی محدود می‌شود. وسعت کل محدوده مطالعاتی ۱۲۹۳ کیلومترمربع می‌باشد که ۸۹۳ کیلومتر مربع آن را پهنه‌های آبرفتی تشکیل می‌دهد. مرتفع‌ترین نقطه حوضه با ۳۱۲۵ متر ارتفاع در قسمت شمالی (در ارتفاعات کوه فلخ) و پست‌ترین نقطه با ۱۲۷۵ متر ارتفاع در نزدیکی دریاچه ارومیه قرار دارد. شیب عمومی منطقه از شمال و شمال شرق به سمت جنوب می‌باشد. ارتفاعات شمالی مشرف بر دشت دارای مورفلوژی خشن و پرشیب بوده که از شرق به غرب از درصد شیب ارتفاعات کاسته می‌شود. نوع اقلیم منطقه مورد مطالعه در ایستگاه شانجان (نماینده ارتفاعات) و شرفخانه (نماینده دشت) به ترتیب نیمه خشک سرد و خشک سرد می‌باشد. میانگین درجه حرارت سالانه نیز به ترتیب

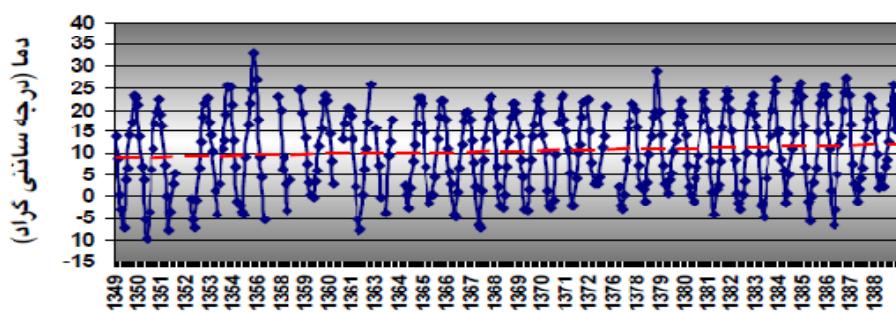


پیزومترها مانند کامل بودن داده ها و پراکندگی یکنواخت در سطح داشت در نظر گرفته شد. داده های این مطالعه برای انجام مدلسازی به دو قسمت کلی تقسیم شدند که هر یک از این دسته ها برای مراحل آموزش و صحبت سنگی به کار می روند. برای هر یک از مراحل فوق تعداد ۷۱ داده آموزشی و تعداد ۳۶ داده برای صحبت سنگی استفاده شد.

۴-۲- آمار و اطلاعات

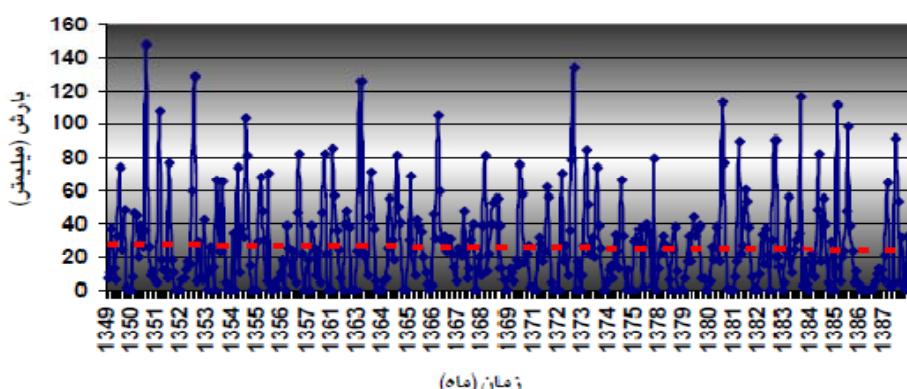
در این تحقیق دما، بارش، دبی رودخانه دریان چای و سطح ایستابی برخی از چاههای موجود در منطقه بصورت ماهانه در بازه زمانی ۹ ساله (۸۰-۸۸) با تأخیر زمانی -10t₀، چهار ورودی اصلی شبکه های عصبی مورد بحث را تشکیل می دهند (تصویر ۲). از بین پیزومترهای موجود در سطح داشت، ۱۵ پیزومتر که دارای آمار تراز سطح ایستابی با سری زمانی ۹ ساله می باشند انتخاب شدند (تصویر ۳). برای انتخاب

نمودار دمای متوسط ماهانه



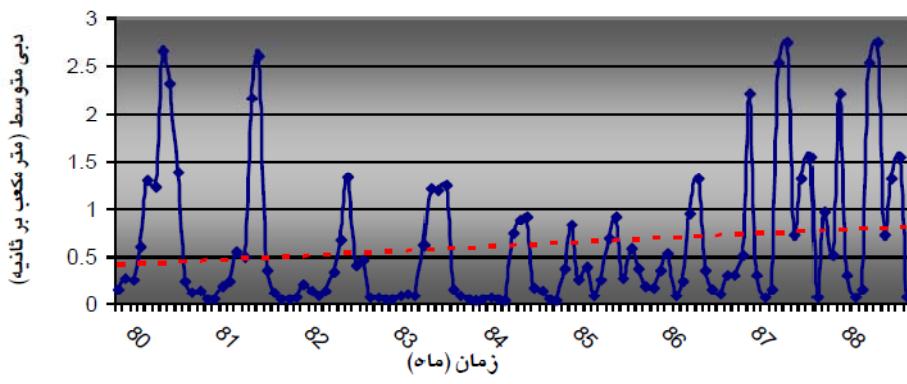
الف

نمودار بارش متوسط ماهانه



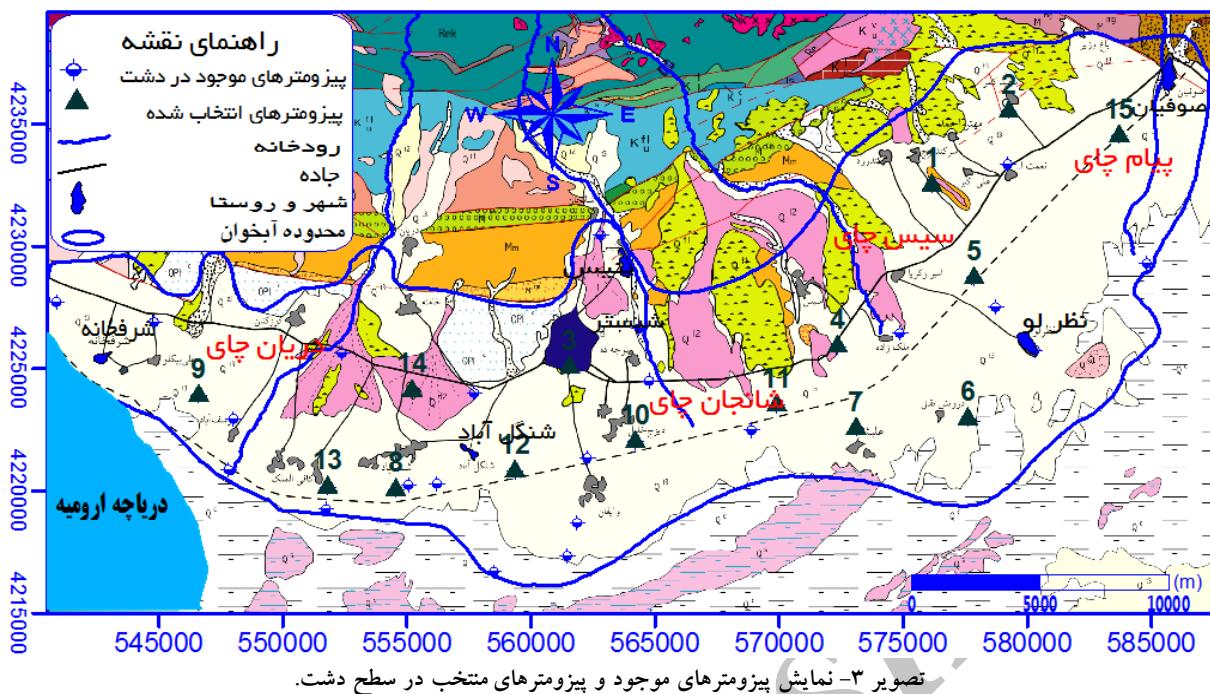
ب

دبی متوسط ماهانه دریان چای



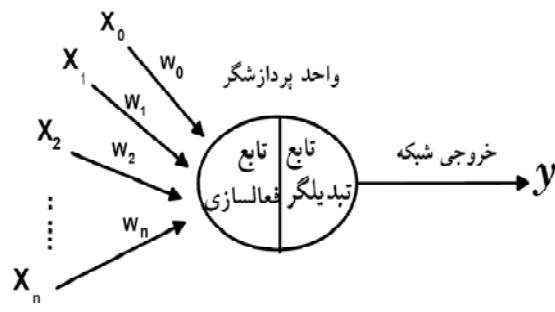
ج

تصویر ۲- الف) نمودار تغییرات دمای متوسط ماهانه، ب) نمودار تغییرات بارش ماهانه، ج) نمودار تغییرات متوسط دبی ماهانه دریان چای



ورودی‌های هر گره ممکن است از متغیرهای ورودی یا از خروجی

گره‌های دیگر حاصل شود. هر گره دارای یکتابع عملگر است که به آن تابع تبدیلگر گفته می‌شود (تصویر ۵ و رابطه ۱).



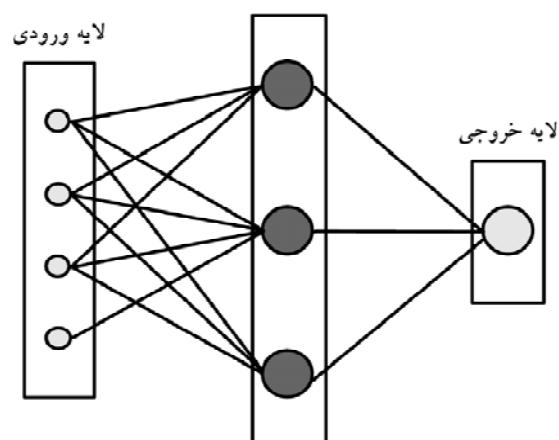
ورودیها به شکل بردار (x_1, \dots, x_n) هستند و هر ورودی توسط یک وزن به گره مربوط می‌شود. در نهایت، گروهی از وزنهای به شکل بردار وزنی (w_1, \dots, w_n) به گره موردنظر مرتبط می‌گردند، w_1 وزن ارتباطی از گره لایه پیشین به لایه مذبور را نشان می‌دهد. خروجی گره که y نامیده می‌شود، طبق رابطه (۱) محاسبه می‌شود.

$$y = f(x \cdot w + b) \quad (1)$$

در این رابطه x داده‌های ورودی، w بردار وزن و b مقدار آستانه یا بایاس می‌باشد. درون هر گره، پردازشگر تابع تبدیلگر تولید کننده

یک شبکه نمونه معمولاً از لایه ورودی، لایه میانی (مخفي) و لایه خروجی تشکیل شده است. تصویر ۴، لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌ها می‌باشد. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه می‌باشد، بنابراین خروجی مدل را معرفی می‌کند. لایه‌های میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها می‌باشند.

لایه میانی (مخفي)



تصویر ۴- یک شبکه سه لایه نمونه (ASCE 2000)

شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به طور معمول به وسیله روش آزمون و خطای مشخص می‌شود. گره‌های هر لایه با لایه‌های مجاور در یک شبکه به طور کامل در ارتباط هستند.

داده‌ها قبل از اعمال شبکه بسیار مهم است. برای پیشگیری از چنین شرایطی و همچنین به لحاظ یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمالسازی داده‌ها مطابق رابطه (۳) انجام شد.

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

در این رابطه، x داده‌های نرمال نشده، x_n داده‌های نرمال شده و x_{\min}, x_{\max} حداقل و حداکثر داده‌های ورودی می‌باشند.

۱۲-۱-۲- تعداد دوره‌ها یا تکرارهای آموزش شبکه

یکی از معیارهای مهم در آموزش شبکه تعداد دوره‌ها یا تکرارهایی است که شبکه در حین آموزش انجام می‌دهد. تعیین تعداد صحیح این تکرارها در آموزش شبکه بسیار مهم است. به طور کلی هرچه تعداد تکرار در آموزش شبکه بیشتر باشد، خطای شبیه‌سازی (پیش‌بینی) در شبکه کمتر می‌شود. اما هنگامی که تعداد تکرار آموزش از یک مقدار تجاوز کند، خطای دسته آزمایشی نیز افزایش می‌یابد.

۱۲-۱-۳- ارزیابی دقیقت مدل

معمولًاً دو معیار مختلف به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیشگوئی دقیق استفاده می‌شود. مجازور خطا (RMSE) و ضریب همبستگی (R^2) که نشانگر میزان بازده شبکه می‌باشد مطابق رابطه (۴) محاسبه می‌شوند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (4)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y - \bar{y})^2} \quad (5)$$

در این رابطه y_i نتایج مشاهداتی، \hat{y}_i نتایج محاسباتی و N تعداد کل مشاهدات است. RMSE اختلاف مقادیر مشاهده شده و مقادیر محاسبه شده را نشان می‌دهد. کمترین مقدار RMSE، بالاترین صحت پیشگویی را نشان می‌دهد. هرچه RMSE به صفر و R^2 به یک نزدیکتر شود، جواب بهتری برای مدل حاصل شده است.

۱۲-۲- بحث

در این پژوهش، برای پیش‌بینی زمانی تراز آب زیرزمینی در دشت شبستر، ساختار FNN-LM مورد ارزیابی قرار گرفت. این ساختار دارای ۴ گره ورودی شامل پارامترهای همبسته با تراز آب زیرزمینی دما، بارش، دبی دریان چای و تراز آب زیرزمینی هر یک از پیزومترها با تأخیر زمانی t_{0-1} (ماه قبل) در بازه زمانی ۹ ساله (۱۳۸۰-۱۳۸۸) می‌باشد. مقدار تراز آب زیرزمینی نیز تنها خروجی شبکه را شامل

خرجی‌های آن گره به شمار می‌رود. یکی از مهم‌ترین و پرکاربردترین توابع تبدیلگر،تابع سیگموئید می‌باشد، که به صورت رابطه (۲) بیان می‌شود.

$$f_{(t)} = \frac{1}{1 + \exp(-tn)} \quad (2)$$

در این رابطه $f(t)$ تابع تبدیلگر، n ورودی خالص نرون و t تغیری است که بیانگر طول قسمت خطی نمودار تابع تبدیل گر می‌باشد، بطوری که اگر t بزرگ باشد قسمت خطی تابع بصورت عمودی درآمده و در واقع تابع به شکل یک تابع حدی دو مقداره درمی‌آید و اگر t کوچک باشد، تابع به شکل یک s کشیده در امتداد محور افقی در خواهد آمد. شکل تابع $f(t)$ تعیین کننده جواب یک گره به سیگنال ورودی کلی است، که آن را دریافت می‌کند. این تابع یک تابع کراندار، یکنواخت و غیر کاهنده است و به علت سادگی و کارایی بالای آن، در فرآیند آموزش (Training Process) مورد استفاده قرار می‌گیرد.

۱۳-۱- آموزش شبکه

هدف از این پژوهش، استفاده از ساختار شبکه‌های عصبی مصنوعی برای پیش‌بینی زمانی سطح ایستابی در تخمین تغییرات بار ھیدرولیکی در منطقه مطالعاتی می‌باشد. ساختار کلی شبکه‌های عصبی مصنوعی بصورت آزمون و خطا بدست می‌آید. بدین ترتیب با استفاده از منوی Start نرم افزار Matlab، قسمت nntool شبکه عصبی مصنوعی ایجاد و با تغییر تعداد نرونها لایه میانی و تعداد تکرارهای آموزش، ساختار بهینه بدست می‌آید. براساس نظرات دالیکوپوس و همکاران FNN-LM (Daliakopoulos et al. 2005) ساختار بهترین ساختار برای پیش‌بینی سطح آب شناخته شده است که در این مدل‌سازی از این ساختار استفاده شده است. تعداد ورودی و لایه مخفی شبکه متغیر است و تنها به افق پیش‌بینی بستگی دارد. تعداد گره‌ها در لایه مخفی در راستای کمینه کردن خطأ و بیشینه کردن دقیقت مدل بهینه‌سازی می‌شوند. در نهایت تابع سیگموئید تانژانتی هیپربولیک از بین توابع دیگر، به علت اینکه با استفاده از روش آزمون و خطا بهترین تابع برای مدل‌سازی سیستمهای طبیعی غیرخطی تشخیص داده شده است (Nourani et al. 2008a, 2008b, Nadiri et al. 2006)، به عنوان تابع تبدیلگر گره‌های پردازشگر لایه مخفی مورد استفاده قرار گرفت.

۱۳-۱-۱- نرمالسازی داده‌ها

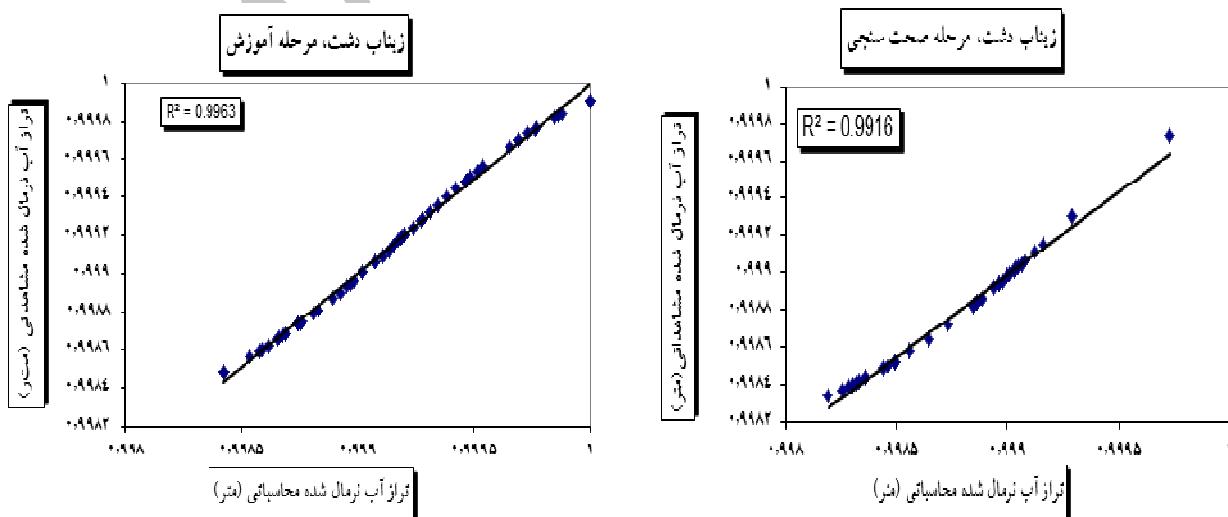
با توجه به آنکه وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقیقت شبکه می‌شود، لذا در آموزش شبکه، نرمالیزه کردن

نتایج، بهترین شبکه طراحی شده مربوط به پیزومترهای شماره ۱، ۴، ۶ و ۷ است. این پیزومترها دارای بیشترین بازده مدل و کمترین درصد خطای می‌باشند نتایج به صورت اسکاتر پلات در تصویر ۶ برای پیزومتر زیناب دشت نشان داده شده است. بر اساس نمودار پلات شده، بین نتایج مشاهداتی و نتایج محاسباتی یک رابطه کاملاً خطی با ضریب همبستگی بالای $R^2=99.63$ و مجدول خطای RMSE=1.43 در مرحله آموزش و $R^2=99.16$ و RMSE= 1.167 در مرحله صحت سنجی وجود دارد.

می‌شود. بر اساس روش آزمون و خطای یک و دو گره میانی برای ساختار مورد بحث تعیین گردید. همچنین در این مدل‌سازی از تعداد تکرارهای ۱۰۰ که دارای عملکرد مناسب و خطای کم برای شبکه می‌باشد، استفاده شد. پس از نرم‌الیزه کردن داده‌ها مراحل آموزش و صحت سنجی برای هر یک از پیزومترها اجرا گردید. در جدول ۱ میزان R^2 (ضریب همبستگی) و RMSE (مجدول خطای) در مراحل آموزش و صحت سنجی ارائه شده است. این جدول نشان‌دهنده‌ی بهترین شبکه طراحی شده برای ساختار اجرا شده می‌باشد. با توجه به

جدول ۱- نتایج ساختار شبکه عصبی برای ۱۵ پیزومتر.

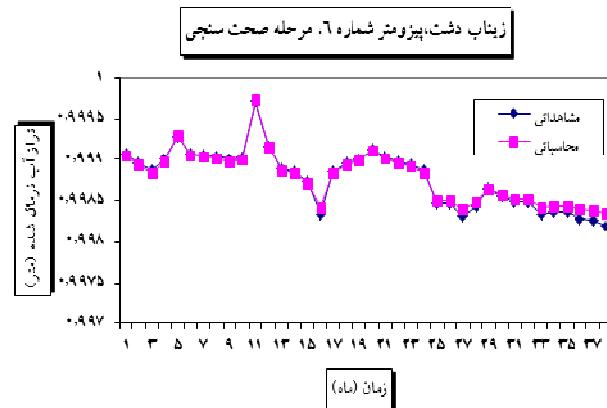
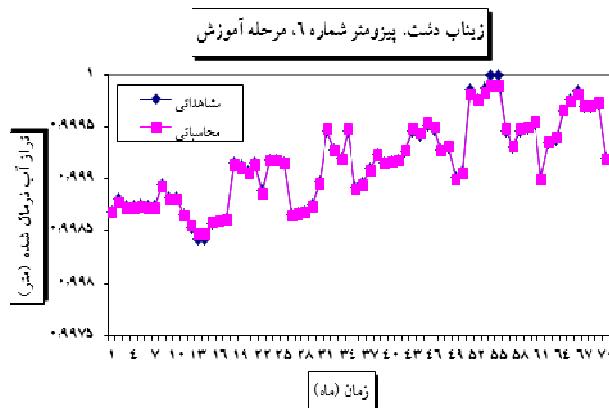
شماره و نام پیزومتر	ضریب تبیین (صحبت آموزش)	ضریب تبیین (صحبت سنجی)	مجدول خطای (آموزش)	مجدول خطای (صحبت سنجی)
۱، جاده سر کند دیزج	۰/۹۹۷۹	۰/۹۶۹۵	۱/۱۶۱	۰/۰۰۱
۲، سفید کمر میدان ورزش	۰/۹۲۰۵	۰/۹۵۵۵	۲/۳۵۶	۱/۱۷۲
۳، وايقان بعد از آبياري	۰/۹۳۲۶	۰/۹۲۳۵	۲/۷۰	۴/۳۲
۴، بیکجه خاتون	۰/۹۹۱۲	۰/۹۶۷۹	۲/۰۳۱	۲/۰۰۳
۵، نظرلو کنار راه آهن	۰/۹۴۶	۰/۸۱۲۵	۱/۴۷۵	۶/۹۱۴
۶، زیناب دشت	۰/۹۹۶۳	۰/۹۹۱۶	۱/۴۳۴	۱/۱۶۷
۷، علیشاه	۰/۹۶۹	۰/۹۸۴۸	۱/۱۶۲	۱/۸۰۳
۸، شندآباد راه ناصرپولی	۰/۹۲۳۵	۰/۸۶۴۷	۱/۰۱۴	۳/۱۰۸
۹، علی بیکلو دشت	۰/۹۸۴۳	۰/۹۶۱۸	۲/۳۱۵	۰/۰۰۲
۱۰، دیزج خلیل کنار راه آهن	۰/۹۳۰۹	۰/۹۴۴۸	۲/۴۷۶	۰/۰۳۶
۱۱، آقی کهریز کنار راه آهن	۰/۹۰۶۸	۰/۹۰۸۷	۲/۱۶۱	۰/۰۰۲
۱۲، ششگل آباد کنار راه آهن	۰/۹۳۲۸	۰/۸۶۷۵	۲/۱۰۳	۲/۴۵۳
۱۳، کوشک کنار راه آهن	۰/۹۶۴۷	۰/۸۵۱۳	۷/۰۸۹	۴/۱۴۶
۱۴، شندآباد شمال روستا	۰/۹۸۱۴	۰/۸۶۳۸	۹/۲۹۷	۲/۲۲۸
۱۵، صوفیان کنار راه آهن	۰/۹۲۴۴	۰/۸۶۰۳	۱/۹۷۴	۱/۳۴۴



تصویر ۶- نمودارهای مقابل خروجی شبکه و داده‌های مشاهداتی با روش شبکه عصبی مصنوعی (ساختار LM-FNN) در پیزومتر زیناب دشت.

مشاهده نمود و علت اصلی این پیش‌بینی دقیق را از روی رفتار سنجی پیزومترها تشخیص داد. علت آن را می‌تواند دوری از دریاچه ارومیه، کمی چاهه‌های بهره‌برداری و صحت بیشتر نتایج آمار برداری دانست.

در تصویر ۷، نتایج حاصل از به کارگیری روش شبکه عصبی مصنوعی با ساختار FNN-LM در پیزومتر ذکر شده ارائه شده که نشان دهنده مقایسه نتایج مشاهده‌ای با نتایج محاسباتی است. با توجه به نمودارهای ارائه شده، می‌توان تطبیق بسیار خوب این نتایج را



تصویر ۷- مقایسه تراز آب مشاهده شده و محاسبه شده با روش شبکه عصبی مصنوعی (ساختار FNN-LM) در پیزومتر زیناب دشت

سلمی، ک..، ۱۳۸۹، "بررسی تغییرات سطح ایستابی در خاک با استفاده از مدل DRAINMOD و مدل شبکه عصبی مصنوعی در منطقه خوزستان"، سایت سازمان هماهنگی مناطق استان تهران. میرزاچی، ع.ا. و ناظمی، ا.ح.، ۱۳۹۰، "پیش‌بینی تراز سطح ایستابی با استفاده از سامانه‌های هوشمند (مطالعه موردی دشت شبسیتر)", مجله مهندسی منابع آب، سال چهارم.

ASCE - Task Committee on Application of Artificial Neural Networks in Hydrology, 2000, "Artificial neural network in hydrology", *Journal of Hydrologic Engineering*, Vol. 5 (2): 115-137.

Alp, M. & Cigizoglu, H. K. 2007, "Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data", *Environmental Modelling & Software*, Vol. 22 (1): 2-13.

Chang, F. J. Chang, K. Y. & Chang, L. C., 2008, "Counterpropagation fuzzy-neural network for city flood control system", *Journal of Hydrology*, Vol. 358 (1-2): 24-34.

Chiang, Y. M. Hsu, K. L. Chang, F. J. Yang, H. & Soroosh, S., 2007, "Merging multiple precipitation sources for flash flood forecasting", *Journal of Hydrology*, Vol. 340 (3-4): 183-196.

Chung, Y. W., 2008, "Prediction water table fluctuation using artifical neural network, in partial fulfillment of the requirements for the degree of doctor of philosophy", *University of Maryland*, 185 pp.

Copola, E., Szidarovszky, F., Poulton, M. & Charles, E., 2003, "Artificial Neural Network Approach for Predicting Transient Water Levels in a Multilayered Groundwater System under Variable State, Pumping, and Climate Conditions", *Journal of Hydrologic Engineering*, Vol. 8 (6): 348-380.

Daliakopoulos, N. I. Coulibaly, P. & Tsanis, I. K. 2005,

۵-نتیجه‌گیری

مدل کردن و شبیه سازی تراز آب زیرزمینی از طریق شبکه عصبی مصنوعی با عدم وجود محدودیتهای ذکر شده و همچنین دارا بودن قابلیت توانایی یادگیری از طریق ارائه مثال بدون نیازمندی به معادلات حاکم بر پدیده، جایگاه ویژه ای دارد. در واقع شبکه های عصبی مصنوعی یکی از پر کاربردترین مدلها در پیش‌بینی و مدلسازی مسائل پیچیده هیدرولوژیکی و هیدرولوژیکی می‌باشند. نتایج این مقاله نشان داد که مدل شبکه های عصبی مصنوعی با الگوریتم پس انتشار خط، تابع آموختشی (TRAINLM)، تابع محرک (TANSIG) و تعداد یک و دو لایه پنهان، دارای بیشترین بازده شبکه، کمترین درصد خطأ و توانایی بالا در پیش‌بینی زمانی پدیده‌های هیدرولوژیکی است. در نتیجه، این مدل قادر است با دقت بالایی تراز آب زیرزمینی را در محدوده مورد مطالعه پیش‌بینی نموده و از صرف زمان و هزینه‌های مالی بیشتر جهت حفر پیزومترها زیادتر جلوگیری نماید. این پژوهش از نظر روش‌شناسی می‌تواند راهگشای بسیاری از مشکلات موجود در پیش‌بینی زمانی تراز آبهای زیرزمینی در آبخوانها باشد. نتایج حاصل از مدل شبکه‌های عصبی مصنوعی بیانگر قدرت بالای این روش غیرخطی در تخمین پارامتر مورد نظر بود.

مراجع

اصغری مقدم، ا..، نورانی، و..، ندیری، ع..، ۱۳۸۷، "مدل سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی"، *مجله دانش کشاورزی دانشگاه تبریز*, جلد ۱۱ (۱): ۱۵-۱=۱.

"Ground water level forecasting using artificial neural networks", *Journal of Hydrology*, Vol. 309 (1-4): 229-240.

Dogan, A. & Motz, L. H., 2008, "Saturated-unsaturated 3D groundwater Model, I: development", *Journal of Hydrologic Engineering*, Vol. 10 (6): 492-504.

Garcia, L. A. & Shigidi, A., 2006, "Using neural networks for parameter estimation in ground water", *Journal of Hydrology*, Vol. 318 (1-4): 215-231.

Lallaheem, S., Mania, J., Hani, A. & Najjar, Y., 2005, "On the use of neural networks to evaluate groundwater levels in fractured media", *Journal of Hydrology*, Vol. 307 (1-4): 92-111.

Nadiri, A. O. A. Asghari Moghaddam. & Nourani, V., 2006, "Basic of artifical neural networks model (ANNs) and its application in hydrogeology", *Proceeding of the 24th Symposium of Geosciences, Geological Survey of Iran, Tehran, Iran*.

Nourani, V., Asghari Moghaddam, A. & Nadiri, A. O., 2008a, "An ANN-based model for spatiotemporal groundwater level forecasting ", *Hydrological Processes*. Vol. 22 (26):5054-5066.

Nourani, V., Asghari Moghaddam, A., Nadiri, A. O. & Singh, V. P., 2008b, "Forecasting spatiotemporal water levels of Tabriz aquifer", *Trends in Applied Sciences Research*, Vol. 3 (4): 319-329.

Seyam, M. & Mogheir, Y., 2011, "Application of Artificial Neural Networks Model as Analytical Tool for Groundwater Salinity", *Journal of Environmental Protection*, Vol. 2: 56-71.

Sreekanth, P. D., Geethanjali, N., Sreedevi, P. D., Ahmed, S., Ravi Kumar, N. & Kamala Jayanthi, P. D., 2009, "Forecasting groundwater level using artifical neural networks", *Current Science*, Vol. 96 (7): 933-939.