

پیش بینی تراز آب زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی (مطالعه موردی: دشت شبستر)

زینب مفتاری^{۱*}، امیرمسین ناظمی^۲ و عطاله ندیری^۳

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

(۲) استاد گروه آبیاری دانشکده کشاورزی، دانشگاه تبریز

(۳) دانشجوی دکتری هیدروژئولوژی، 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

چکیده

آبهای زیرزمینی، همواره به عنوان یکی از منابع مهم و عمده 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 پراکندگی یکنواختی داشتند استفاده شد. پارامترهای دما، بارش، دبی خروجی دریاں چای و تراز آب زیرزمینی هر یک از پیزومترها با تأخیر زمانی 1-10 (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 محرک TANSIG، قادر به پیش‌بینی سطح آب زیرزمینی ماهانه در بازه زمانی ۳ ساله با دقت بالای $R^2=99.63$ ، $RMSE=1.43$ در مرحله آموزش و $(R^2=99.16, RMSE=1.167)$ در مرحله صحت سنجی در محدوده مورد مطالعه است.

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

۱- مقدمه

هیدروژئولوژی 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 هیدروژئولوژیکی و درک فرایندهای صورت گرفته در یک سیستم می‌باشند، اما دارای محدودیت‌های عملی هستند. مشکل عمده ای که هم‌اکنون کاربران و تهیه‌کنندگان 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 هیدروژئولوژی 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 جبران‌ناپذیری را به سازه‌های مهندسی وارد می‌کند. با پی بردن به این تغییرات می‌توان از نظر بیلان

با استفاده از داده های متوسط ماهانه بارش، تبخیر و سطح آب اندازه گیری شده دریاچه ماگنولیا و بروکلین در مرکز فلوریدا، از شبکه های عصبی مصنوعی استفاده کردند و روابط بین سطح آب دریاچه، سطح آب زیرزمینی، بارندگی و تبخیر و تعرق را با استفاده از مدل شبکه های عصبی مبتنی بر رگرسیون خطی چندگانه و رگرسیون غیرخطی چندگانه مدل سازی کردند. آنها همچنین با استفاده از تابع فعال سازی لونیگ مارکوات که قدرتمندتر از روش های مرسوم گرادیان نزولی است (Alp & Cigizoglu 2007) نتایج قابل قبولی را ارائه کردند. چونگ (Chung 2008) برای پیش بینی نوسانات سفره آب در مرینلد با استفاده از شبکه عصبی، از دو گونه مدل پیش بینی 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 مدل های ساخته شده برای ارزیابی نوسانات سفره از دقت بالایی برخوردار بوده، به گونه ای که میانگین مربعات خطاهای پیش بینی عمق سفره آب در یک دوره ۱۲ ماهه بین ۰/۰۴۳ و ۰/۰۴۷ بوده است. سریکانس و همکاران (Sreekanth et al. 2009) ارزیابی حاصل از مدل های شبکه های عصبی مصنوعی نظیر الگوی لونیگ-مارکوات را در پیش بینی سطح تراز آب زیرزمینی در حوزه آبخیز مهاش ورم (Maheshwarm) در ایالت حیدرآباد هندوستان مورد آزمون قرار دادند. نتایج نشان داد که مدل کاملاً متناسب با واقعیت بوده و داده های حاصل از دقت و قطعیت قابل قبولی ($R^2=0.93$, $RMSE=4.50$) برخوردار می باشند. در نتیجه روش شبکه های عصبی مصنوعی در دهه اخیر با موفقیت برای حل مشکلاتی مربوط به کیفیت آب (Chang et al. 2008, Seyam & Mogheir 2011) بارندگی و مدل سازی رواناب (Chiang et al. 2007) و اصغری مقدم و همکاران (۱۳۸۷) تخمین هدایت هیدرولیکی (Garcia & Shigidi 2006) استفاده شده است. تاکنون، از شبکه عصبی مصنوعی برای پیش بینی رفتار آب زیرزمینی در قالب شبیه سازی و مدل های بهینه سازی، استفاده های بسیاری شده است. این روش می تواند گزینه ای مناسب در مدل سازی کمی منابع آب محسوب شود. لذا این پژوهش به منظور بررسی کاربرد شبکه عصبی مصنوعی برای پیش بینی تراز آب زیرزمینی در آبخوان دشت شبستر انجام شد.

۲- منطقه مورد مطالعه و داده ها

۲-۱- معرفی منطقه

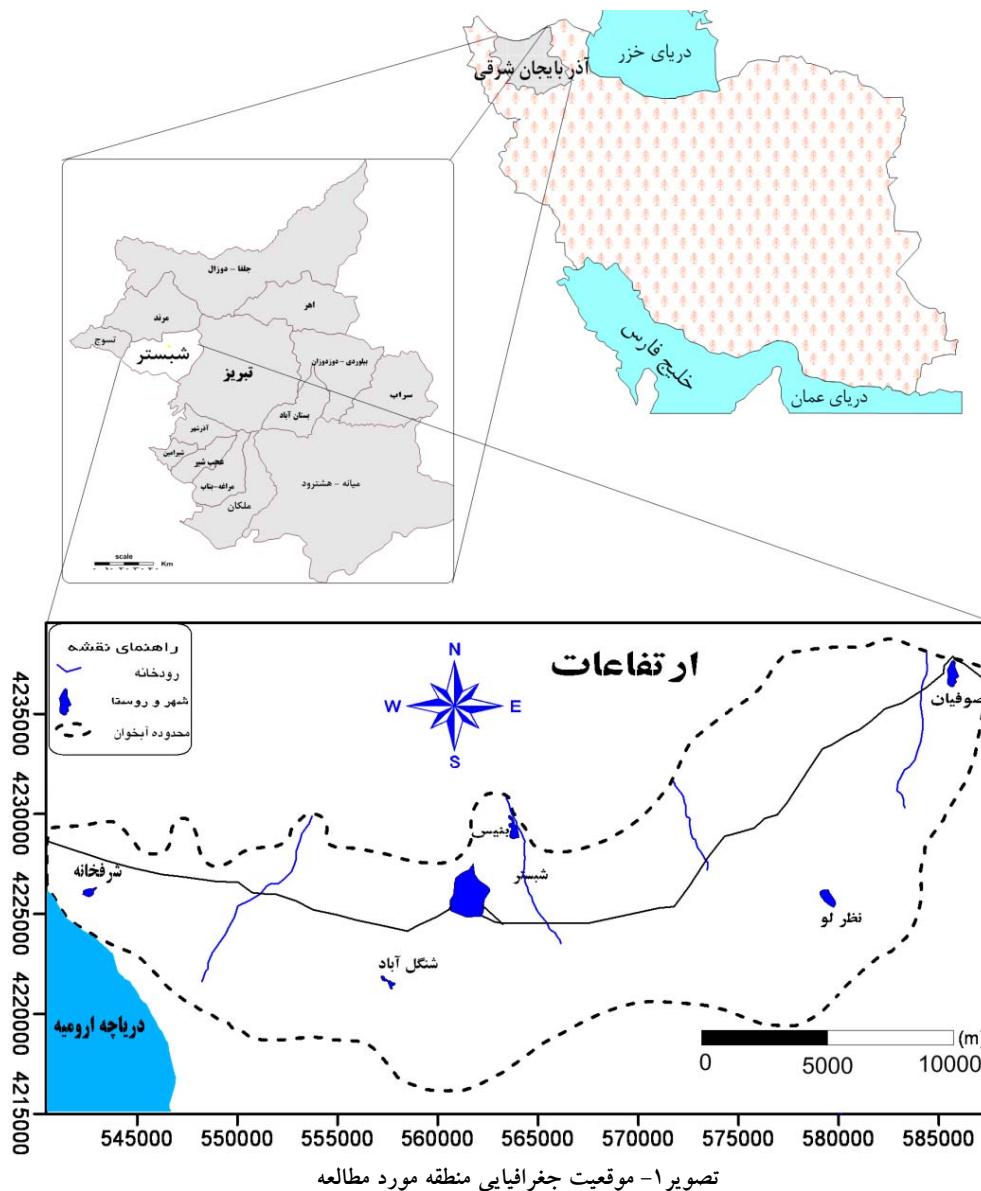
محدوده مطالعاتی شبستر یکی از زیر حوضه های ۲۵ گانه حوضه آبریز دریاچه ارومیه است که در ۶۰ کیلومتری غرب شهرستان تبریز واقع شده است. این محدوده از طرف شمال به حوضه زیلبر چای

همچنین حجم زیاد محاسبات و نیاز به زمان طولانی در هر بار اجرای مدل، سبب می شود تا استفاده از مدل برای بررسی رویکردهای مختلف بهره برداری زمانبر، دشوار و گاه غیر ممکن باشد. از سوی دیگر، در اغلب مدل های 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 می شود. بر این اساس لازم است تا مدلی هوشمند جایگزین مدل عددی شبیه سازی آبخوان شود (اصغری مقدم و همکاران ۱۳۸۷). کاپالا و همکاران (Copolia et al. 2003) نشان دادند که شبکه های عصبی توانایی بالایی در پیش بینی دقیق سطح ایستابی در حالت غیرماندگار در سیستم در حال پمپاژ و موقعیت های آب و هوایی مختلف دارند. آنها نشان دادند که این مدلها برای مدل سازی آبخوانهای آهکی نشتی و کارستی که مدل های عددی از مدل سازی آنها ناتوان هستند، بسیار مورد تأیید می باشند. لالا هم و همکاران (Lallahem et al. 2005) برای اولین بار از شبکه های عصبی مصنوعی برای ارزیابی سطح ایستابی در سازند سخت استفاده نمودند. آنها از یک پرسپترون چندلایه استفاده کرده و سطح ایستابی را در پیرومتر مرکزی پیش بینی کردند. پس از انجام حساسیت سنجی، آنها توانستند تنها با در دست داشتن سطح ایستابی از دو پیرومتر مجاور پیرومتر مرکزی و میزان بارش موثر، علاوه بر پیرومتر مرکزی سطح ایستابی را در دو پیرومتر دیگر پیش بینی کنند. لالا هم و همکاران (Lallahem et al. 2005) نشان دادند که این مدلها در مدل سازی سطح ایستابی در مناطق کارستی کارایی بیشتری نسبت به مدل های عددی دارند.

میرزایی و ناظمی (۱۳۹۰) از سامانه های هوشمند استنتاج عصبی-فازی تطبیقی، شبکه های عصبی مصنوعی و برنامه ریزی ژنتیک برای تخمین تراز سطح ایستابی دشت شبستر در استان آذربایجان شرقی استفاده نمودند. در این تحقیق از اطلاعات ۲۰ پیرومتر که دارای آمار بالای ۱۷ سال بودند، استفاده شد. بر پایه محاسبات انجام شده، هر سه روش دارای توانایی قابل توجهی در تخمین میزان تراز سطح ایستابی می باشند. دالیاکاپلاس و همکاران (Daliakopoulos et al. 2005) با استفاده از ۶ ساختار مختلف شبکه های عصبی مصنوعی، توانستند مدل حوضه ای در جنوب یونان را که بر اثر برداشت از آبخوان برای مصارف کشاورزی با مشکل مواجه شده بود، تهیه کرده و سطح ایستابی این آبخوان آبرفتی را پیش بینی نمایند. در این مطالعه آنها با استفاده از ساختار شبکه عصبی پیشرو با الگوریتم بهینه سازی لونیگ-مارکوات، پیش بینی ۱۸ ماهه ای از سطح ایستابی در چاه مرکزی این حوضه ارائه کردند. نتایج بدست آمده از این مطالعه از دقت بالایی برخوردار است. داگن و متز (Dogan & Motz 2008) برای برآورد مقدار سطح آب

مرند، از غرب به محدوده مطالعاتی تسوج، از شرق به تبریز و از جنوب به دریاچه ارومیه و پهنه های نمکی - رسی محدود می شود. وسعت کل محدوده مطالعاتی ۱۲۹۳ کیلومتر مربع می باشد که ۸۹۳ کیلومتر مربع آن را پهنه های آبرفتی تشکیل می دهد. مرتفع ترین نقطه حوضه با ۳۱۲۵ متر ارتفاع در قسمت شمالی (در ارتفاعات کوه فالخ) و پست ترین نقطه با ۱۲۷۵ متر ارتفاع در نزدیکی دریاچه ارومیه قرار دارد. شیب عمومی منطقه از شمال و شمال شرق به سمت جنوب می باشد. ارتفاعات شمالی مشرف بر دشت دارای مورفولوژی خشن و پرشیب بوده که از شرق به غرب از درصد شیب ارتفاعات کاسته می شود. نوع اقلیم منطقه مورد مطالعه در ایستگاه شانجان (نماینده ارتفاعات) و شرفخانه (نماینده دشت) به ترتیب نیمه خشک سرد و خشک سرد می باشد. میانگین درجه حرارت سالانه نیز به ترتیب

۱۰/۵۵ و ۱۱/۶ درجه سانتی گراد و متوسط بارندگی ۳۰۰/۵۵ و ۲۵۷/۶۶ میلیمتر می باشد. دشت شبستر در سالهای اخیر به علت برداشت زیاد از آب های زیرزمینی برای مصارف کشاورزی، با افت شدید سطح آب زیرزمینی مواجه گردید. در حال حاضر این دشت به عنوان دشت ممنوعه اعلام شده است. اکثر چاه های موجود در سطح دشت در حال برداشت غیر مجاز می باشند، به علاوه پمپاژ از آنها نیز بر مبنای مطالعات آب زیرزمینی صورت نگرفته است. بنابراین برداشت از سفره آب زیرزمینی، بیشترین تأثیر را در افت سطح آب داشته است. البته کاهش روند بارندگی و افزایش تبخیر- تعرق نیز در ایجاد چنین شرایطی تأثیر داشته است. تصویر ۱ موقعیت جغرافیایی محدوده مطالعاتی را نشان می دهد.

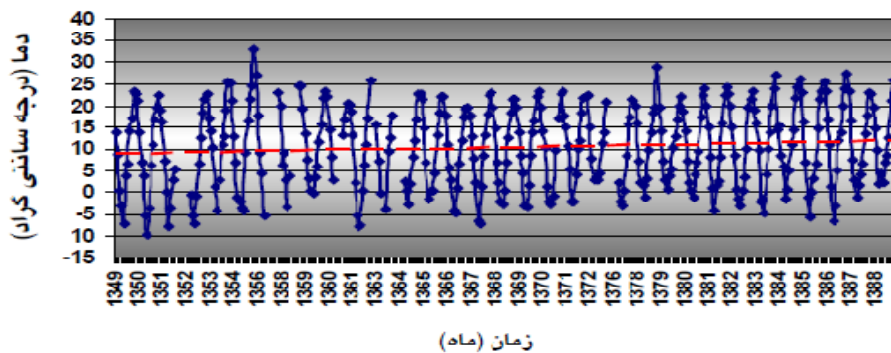


۲-۲- آمار و اطلاعات

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


در این تحقیق دما، بارش، دبی رودخانه دریاں جای و سطح ایستابی برخی از چاه های موجود در منطقه بصورت ماهانه در بازه زمانی ۹ ساله (۸۸-۸۰) با تأخیر زمانی t_0-1 ، چهار ورودی اصلی شبکه های عصبی مورد بحث را تشکیل می دهند (تصویر ۲). از بین پیزومترهای موجود در سطح دشت، 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



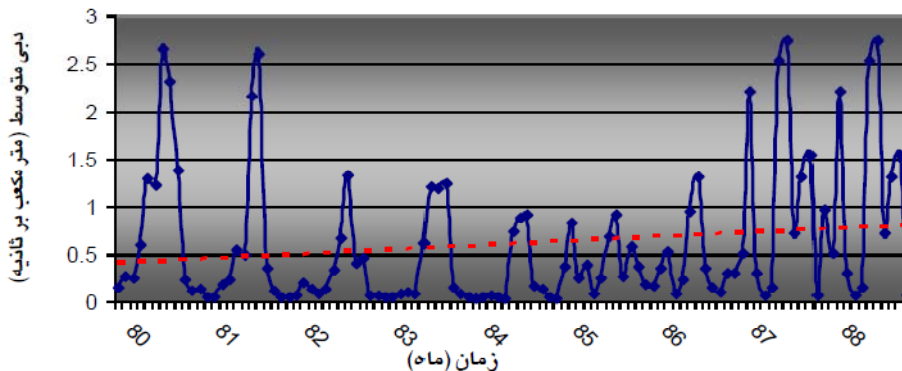
الف

نمودار بارش متوسط ماهانه



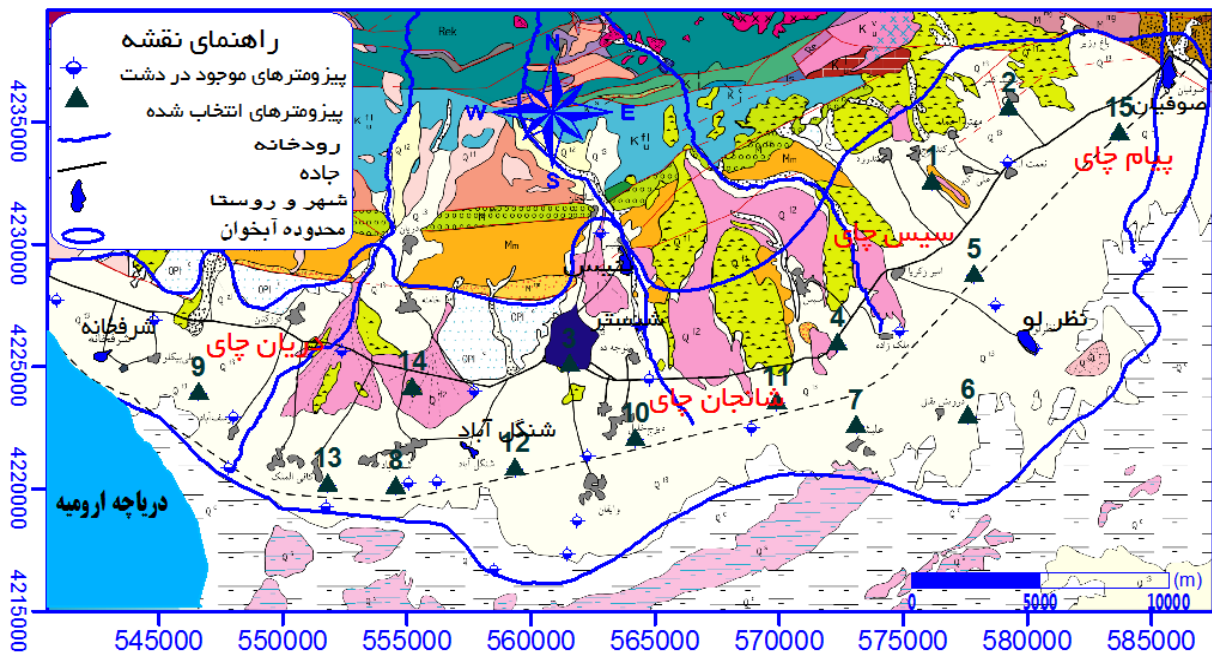
ب

دبی متوسط ماهانه دریاں جای



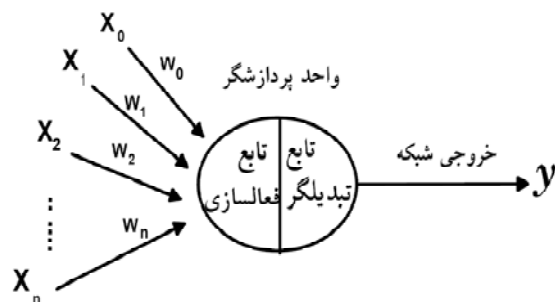
ج

تصویر ۲- الف) نمودار تغییرات دمای متوسط ماهانه، ب) نمودار تغییرات بارش ماهانه، ج) نمودار تغییرات متوسط دبی ماهانه دریاں جای



تصویر ۳- نمایش پیزومترهای موجود و پیزومترهای منتخب در سطح دشت.

ورودی های هر گره ممکن است از متغیرهای ورودی یا از خروجی گره های دیگر حاصل شود. هر گره دارای یک تابع عملگر است که به آن تابع تبدیلگر گفته می شود (تصویر ۵ و رابطه ۱).



خروجی = y وزن ها = X ورودی ها
تصویر ۵- یک نود (گره) نمونه (ASCE 2000)

ورودیها به شکل بردار (x_1, x_2, \dots, x_n) هستند و هر ورودی توسط یک وزن به گره مربوط می شود. در نهایت، گروهی از وزنها به شکل بردار وزنی (w_1, w_2, \dots, w_n) به گره مورد نظر مرتبط می گردند، w_1 وزن ارتباطی از گره لایه پیشین به لایه مزبور را نشان می دهد. خروجی گره که y نامیده می شود، طبق رابطه (۱) محاسبه می شود.


$$y = f(x.w + b) \quad (۱) \text{ رابطه}$$

در این رابطه x داده های ورودی، w بردار وزن و b مقدار آستانه یا بایاس می باشند. درون هر گره، پردازشگر تابع تبدیل گر تولید کننده

۳- شبکه عصبی مصنوعی

یک شبکه نمونه معمولاً از لایه ورودی، لایه میانی (مخفی) و لایه خروجی تشکیل شده است. تصویر ۴، لایه ورودی یک لایه انتقال دهنده و وسیله ای برای تهیه کردن داده ها می باشد. آخرین لایه یا لایه خروجی شامل مقادیر پیش بینی شده به وسیله شبکه می باشد، بنابراین خروجی مدل را معرفی می کند. لایه های میانی یا مخفی که از گره های پردازشگر تشکیل شده اند، محل پردازش داده ها می باشند.

لایه میانی (مخفی)



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

شمار لایه های مخفی و شمار گره ها در هر لایه مخفی به طور معمول به وسیله روش آزمون و خطا مشخص می شود. گره های هر لایه با لایه های مجاور در یک شبکه به طور کامل در ارتباط هستند.

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

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه (۳)}$$

در این رابطه، X داده های نرمال نشده، X_n داده های نرمال شده و X_{\min} ، X_{\max} حداقل و حداکثر داده های ورودی می باشند.

۳-۱-۲- تصداده دوره ها یا تکرارهای آموزش شبکه

یکی از معیارهای مهم در آموزش شبکه تعداد دوره ها یا تکرارهایی است که شبکه در حین آموزش انجام می دهد. تعیین تعداد صحیح این تکرارها در آموزش شبکه بسیار مهم است. به طور کلی هرچه تعداد تکرار در آموزش شبکه بیشتر باشد، خطای شبیه سازی (پیش بینی) در شبکه کمتر می شود. اما هنگامی که تعداد تکرار آموزش از یک مقدار تجاوز کند، خطای دسته آزمایشی نیز افزایش می یابد.

۳-۱-۳- ارزیابی دقت مدل

معمولاً دو معیار مختلف به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیشگویی دقیق استفاده می شود. مجذور خطا (RMSE) و ضریب همبستگی (R^2) که نشانگر میزان بازده شبکه می باشند مطابق رابطه (۴) محاسبه می شوند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad \text{رابطه (۴)}$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y - \bar{y})^2} \quad \text{رابطه (۵)}$$

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 می دهد. کمترین مقدار RMSE، بالاترین صحت پیشگویی را نشان می دهد. هر چه RMSE به صفر و R^2 به یک نزدیکتر شود، جواب بهتری برای مدل حاصل شده است.

۴- بهت

در این پژوهش، برای پیش بینی 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 دریاں جای و تراز آب زیرزمینی هر یک از پیزومترها با تأخیر زمانی t_0-1 (ماه قبل) در بازه زمانی ۹ ساله (۱۳۸۸-۱۳۸۰) می باشد. مقدار تراز آب زیرزمینی نیز تنها خروجی شبکه را شامل

خروجی های آن گره به شمار می رود. یکی از مهم ترین و پرکاربردترین توابع تبدیگر، تابع سیگموئید می باشد، که به صورت رابطه (۲) بیان می شود.

$$f(t) = \frac{1}{1 + \exp(-tn)} \quad \text{رابطه (۲)}$$

در این رابطه $f(t)$ تابع تبدیگر، n ورودی خالص نرون و t تقریبی است که بیانگر طول قسمت خطی نمودار تابع تبدیگر می باشد، بطوری که اگر t بزرگ باشد قسمت خطی تابع بصورت عمودی درآمده و در واقع تابع به شکل یک تابع حدی دو مقداره درمی آید 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 می کند. این تابع یک تابع کران دار، یکنواخت و غیر کاهنده است و به علت سادگی و کارایی بالای آن، در فرآیند آموزش (Training Process) مورد استفاده قرار می گیرد.

۳-۱-۱- آموزش شبکه

هدف از این پژوهش، استفاده از ساختار شبکه های عصبی مصنوعی برای پیش بینی زمانی سطح ایستابی در تخمین تغییرات بار هیدرولیکی در منطقه مطالعاتی می باشد. ساختار کلی شبکه های عصبی مصنوعی بصورت آزمون و خطا بدست می آید. 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 می آید. براساس نظرات دالیکوپوس و همکاران (Daliakopoulos et al. 2005) ساختار FNN-LM به عنوان بهترین ساختار برای پیش بینی سطح آب شناخته شده است که در این مدل سازی از این ساختار استفاده شده است. تعداد ورودی و لایه مخفی شبکه متغیر است و تنها به افق پیش بینی بستگی دارد. تعداد گره ها در لایه مخفی در راستای کمینه کردن خطا و بیشینه کردن دقت مدل بهینه سازی می شوند. در نهایت تابع سیگموئید تانژانتی هیپربولیک از بین توابع دیگر، به علت اینکه با استفاده از روش آزمون و خطا بهترین تابع برای مدل سازی سیستم های طبیعی غیرخطی تشخیص داده شده است (Nourani et al. 2006a, 2008b, Nadiri et al. 2006)، به عنوان تابع تبدیگر گره های پردازشگر لایه مخفی مورد استفاده قرار گرفت.

۳-۱-۱-۱- نرمالسازی داده ها

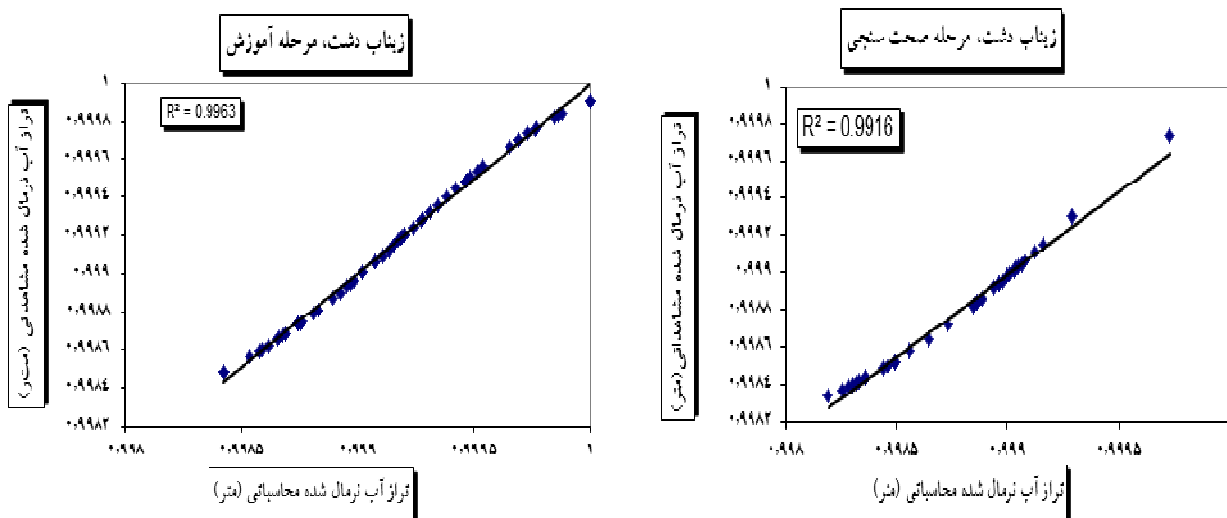
با توجه به آنکه وارد کردن داده ها به صورت خام باعث کاهش سرعت و دقت شبکه می شود، لذا در آموزش شبکه، نرمالیزه کردن

نتایج، بهترین شبکه طراحی شده مربوط به پیژومترهای شماره ۱، ۴، ۶ و ۷ است. این پیژومترها دارای بیشترین بازده مدل و کمترین درصد خطا می باشند نتایج به صورت اسکاتر پلات در تصویر ۶ برای پیژومتر 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 مجذور خطای $RMSE=1.43$ در مرحله آموزش و $R^2=99.16$ و $RMSE=1.167$ در مرحله صحت سنجی وجود دارد.

می شود. بر اساس روش آزمون و خطا، یک و دو گره میانی برای ساختار مورد بحث تعیین گردید. همچنین در این مدل سازی از تعداد تکرارهای ۱۰۰ که دارای عملکرد مناسب و خطای کم برای شبکه می باشد، استفاده شد. پس از نرمالیزه کردن داده ها مراحل آموزش و صحت سنجی برای هر یک از پیژومترها اجرا گردید. در جدول ۱ میزان R^2 (ضریب همبستگی) و $RMSE$ (مجذور خطا) در مراحل آموزش و صحت سنجی ارائه شده است. این جدول نشان دهنده ی بهترین شبکه طراحی شده برای ساختار اجرا شده می باشد. با توجه به

جدول ۱- نتایج ساختار شبکه عصبی برای ۱۵ پیژومتر.



شماره و نام پیژومتر	ضریب تبیین (آموزش)	ضریب تبیین (صحت سنجی)	مجذور خطا (آموزش)	مجذور خطا (صحت سنجی)
۱، جاده سر کند دیزج	۰/۹۹۷۹	۰/۹۶۹۵	۱/۱۶۱	۰/۰۰۱
۲، سفید کمر میدان ورزش	۰/۹۲۵۵	۰/۹۵۵۵	۲/۳۵۴	۱/۱۷۲
۳، وایقان بعد از آبیاری	۰/۹۳۲۶	۰/۹۲۳۵	۲/۷۰	۴/۳۲
۴، بیگجه خاتون	۰/۹۹۱۲	۰/۹۶۷۹	۲/۰۳۱	۲/۰۰۳
۵، نظرلو کنار راه آهن	۰/۹۴۴	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	۱/۸۵۳
۸، شندآباد راه ناچریولی	۰/۹۳۳۵	۰/۸۶۴۷	۱/۰۱۴	۳/۱۰۸
۹، علی بیگلو دشت	۰/۹۸۴۳	۰/۹۶۱۸	۲/۳۱۵	۰/۰۰۲
۱۰، دیزج خلیل کنار راه آهن	۰/۹۳۰۹	۰/۹۴۴۸	۲/۴۷۶	۰/۰۳۶
۱۱، آق کهریز کنار راه آهن	۰/۹۰۶۸	۰/۹۰۸۷	۲/۱۶۱	۰/۰۰۲
۱۲، شنگل 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، شند آباد 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 متقابل خروجی شبکه و داده های مشاهداتی با روش شبکه عصبی مصنوعی (ساختار FNN-LM) در پیژومتر زیناب دشت.

مشاهده نمود و علت اصلی این پیش بینی دقیق را از روی رفتارسنجی پیزومترها تشخیص داد. علت آن را می تواند دوری از دریاچه ارومیه، کمی چاههای بهره برداری 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 مشاهداتی با نتایج محاسباتی است. با توجه به نمودارهای ارائه شده، می توان 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.
میرزایی، ع.ا. و ناظمی، ا.ح.، ۱۳۹۰، "پیش بینی تراز سطح ایستابی با استفاده از سامانه های هوشمند (مطالعه موردی دشت شبستر)"، 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 artificial 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- نتیجه گیری

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 پیش بینی و مدلسازی مسائل پیچیده هیدروژئولوژیکی و هیدرولوژیکی می باشند. نتایج این مقاله نشان داد که مدل شبکه های عصبی مصنوعی با الگوریتم پس انتشار خطا، تابع آموزشی (TRAINLM)، تابع محرک (TANSIG) و تعداد یک و دو لایه پنهان، دارای بیشترین بازده شبکه، کمترین درصد خطا و توانایی بالا در پیش بینی زمانی پدیده های هیدروژئولوژیکی است. در نتیجه، این مدل قادر است با دقت بالایی تراز آب زیرزمینی را در محدوده مورد مطالعه پیش بینی نموده و از صرف زمان و هزینه های مالی بیشتر جهت حفر پیزومترهای زیادتر جلوگیری نماید. این پژوهش از نظر روش شناسی می تواند راهگشای بسیاری از مشکلات موجود در پیش بینی زمانی تراز آبهای زیرزمینی در آبخوانها باشد. نتایج حاصل از مدل شبکه های 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 شبکه های عصبی مصنوعی"، *مجله دانش کشاورزی دانشگاه تبریز*، جلد ۱۸ (۱): ۱-۱۵.

"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.

Lallahem, 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 artificial 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 artificial neural networks", *Current Science*, Vol. 96 (7): 933-939.