

مقایسه شبکه‌های عصبی MLP و RBF در تخمین پارامترهای آبخوان‌های محبوس

طاهره آذری^۱ و دکتر نوذر سامانی^{۲*}

۱. دانشجوی دکترای زمین شناسی گرایش آبشناسی دانشگاه شیراز، دانشکده علوم، بخش علوم زمین، دانشکده علوم، دانشگاه شیراز
۲. استاد دانشگاه شیراز، دانشکده علوم، بخش علوم زمین، دانشکده علوم، دانشگاه شیراز

تاریخ دریافت: ۹۴/۰۳/۱۷

تاریخ پذیرش: ۹۴/۰۴/۰۶

چکیده

در این مقاله، شبکه‌های عصبی مصنوعی پرسپترون چند لایه (MLP) و تابع پایه شعاعی (RBF) جهت تعیین پارامترهای آبخوان محبوس (قابلیت انتقال آبخوان و ضریب ذخیره) طراحی گردیده است. تابع چاه مربوط به آبخوان‌های محبوس به این شبکه‌ها آموزش داده شده است. با اعمال تکنیک آنالیز مولفه اصلی بر مجموعه داده‌های آموزش، ساختار شبکه MLP و RBF به ترتیب با آرایش $(1 \times 12 \times 1)$ و $(1 \times 14 \times 1)$ صرف نظر از تعداد داده‌های آزمون پمپاژ ثابت گردید. این شبکه‌ها با دریافت هر مجموعه داده آزمون پمپاژ واقعی، مختصات نقطه انطباق بهینه را تولید می‌کند. سپس مختصات نقطه انطباق با حل تحلیلی تاپس (۱۹۳۵) ترکیب شده و مقادیر پارامترهای آبخوان محاسبه می‌شود. توانایی تعمیم و عملکرد این شبکه‌ها با ۱۰۰۰۰۰ مجموعه داده سنتز شده ارزیابی گردید و دقت آن‌ها با استفاده از داده‌های دو آزمون پمپاژ واقعی با روش انطباق منحنی تیپ مقایسه شده است. نتایج حاصل از مدلسازی تابع چاه در آبخوان محبوس نشان داد که اگر چه هر دو مدل شبکه عصبی MLP و RBF می‌توانند پارامترهای آبخوان را با دقت بالایی تعیین نمایند و خطاهای گرافیکی حاصل از روش‌های انطباق منحنی تیپ را حذف کنند اما شبکه MLP طراحی شده از دقت بالاتری نسبت به شبکه RBF برخوردار می‌باشد به همین دلیل شبکه MLP پیشنهادی به عنوان یک روش خودکار، دقیق و سریع جهت تعیین پارامترهای آبخوان محبوس توصیه می‌شود.

واژه‌های کلیدی: پارامترهای آبخوان، شبکه عصبی مصنوعی، آنالیز مولفه اصلی، الگوریتم آموزش لونیبرگ-مارکوارت، آزمون پمپاژ.

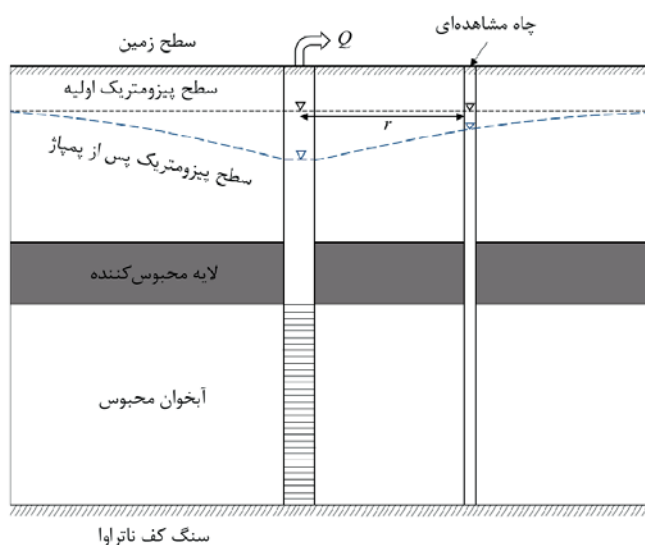
مقدمه

آزمون‌های پمپاژ به طور وسیعی جهت تعیین پارامترهای آبخوان استفاده می‌شود. هنگامی که یک چاه پمپاژ با نرخ ثابت در یک آبخوان محبوس^۱ پمپاژ می‌شود یک مخروط افت

در سطح پیرومتریک آب زیرزمینی ایجاد می‌گردد (شکل ۱). حل تحلیلی تاپس (Theis, 1935) معمولاً جهت محاسبه ضریب ذخیره و قابلیت انتقال آبخوان محبوس

1. Confined aquifer

* نویسنده مرتبط: samani@susc.ac.ir



شکل ۱. نمای شماتیکی آبخوان محبوس به همراه چاه پمپاژ با نفوذ کامل

مقادیر مختصات نقطه انطباق و روابط (۱) و (۳) پارامترهای آبخوان (T) تعیین می‌گردند. پارامترهای آبخوان محاسبه شده با روش گرافیکی منحنی تیپ به دلیل خطاهای فردی و گرافیکی بحث برانگیز هستند. در سال‌های اخیر برخی روش‌های مناسب براساس شبکه‌های عصبی مصنوعی^۵ به عنوان یک روش جایگزین جهت تعیین پارامترهای آبخوان توسعه یافته‌اند تا خطاهای ناشی از روش‌های گرافیکی انطباق منحنی تیپ را حذف کنند (Lin and Chen, 2005, 2006; Samani et al., 2007; Lin et al., 2010). بنابراین هدف این تحقیق طراحی شبکه‌های عصبی پرسپترون چند لایه^۶ (MLP) و تابع پایه شعاعی^۷ (RBF) جهت مدلسازی تابع چاه تاپس (رابطه ۲)، پیش‌بینی مختصات نقطه انطباق و تعیین پارامترهای آبخوان‌های محبوس می‌باشد. این روش در حال حاضر در اکثر مطالعات علمی جهت مدلسازی پروسه‌های فیزیکی پیچیده کنترل‌کننده روابط ورودی-خروجی سیستم‌های مختلف مورد استفاده قرار می‌گیرند. این مقاله به طور مختصر تئوری شبکه عصبی مصنوعی را شرح می‌دهد. علاقه‌مندان می‌توانند جهت کسب اطلاعات

هموژن و ایزوتروپ استفاده می‌شود. بر اساس روش تاپس مقدار افت حاصل از پمپاژ در چاه‌های مشاهده‌ای در حالت ناپایدار با فرمول زیر محاسبه می‌شود:

$$s = \frac{Q}{4\pi T} W(u) \quad (1)$$

$$W(u) = \int_u^\infty \frac{1}{u} \exp(-u) du \quad (2)$$

$$u = \frac{r^2 S}{4Tt} \quad (3)$$

که به ترتیب s مقدار افت اندازه‌گیری شده در زمان t [T] در یک چاه مشاهده‌ای واقع در فاصله r [L] از چاه پمپاژ، T [L²T⁻¹] قابلیت انتقال آبخوان^۱، S ضریب ذخیره آبخوان^۲، Q [L³T⁻¹] دبی چاه پمپاژ و W(u) تابع چاه^۳ تاپس می‌باشد.

تاپس در سال ۱۹۳۵ نمودار W(u) در مقابل مقادیر u را ترسیم نمود و منحنی تیپ^۴ آبخوان‌های محبوس را ایجاد کرد. جهت تعیین مقادیر پارامترهای آبخوان محبوس (T و S) داده‌های افت-زمان مربوط به یک آزمون پمپاژ روی کاغذ لگاریتمی با مقیاس مشابه منحنی تیپ تاپس ترسیم می‌گردد. منحنی افت-زمان روی منحنی تیپ تاپس قرار داده می‌شود به گونه‌ای که محورهای مختصات هر دو منحنی با هم موازی بوده و اکثر نقاط داده‌های مشاهده‌ای روی منحنی تیپ قرار گیرد. در این حالت یک نقطه انطباق انتخاب می‌شود. مختصات نقطه انطباق روی هر دو منحنی $[\frac{1}{u}_m, W(u)_m, s_m, t_m]$ ثبت می‌شود. سپس با استفاده از

1. Transmissibility
- 2 Storage coefficient
3. Well function
4. Type curve
5. Artificial Neural Networks- ANNs
6. Multi-Layer Perceptron - MLP
7. Radial Basis Function - RBF

ارائه دادند. اگر چه این شبکه‌ها، پارامترهای آبخوان را با دقت و سرعت بالایی تعیین می‌کردند اما هنوز این مشکل که با افزایش تعداد داده‌های افت-زمان، ابعاد شبکه بزرگتر می‌شد برطرف نگردید. همچنین این شبکه‌ها باید برای هر مجموعه داده آزمون پمپاژ، آموزش داده و آزمایش شوند. بر این اساس سامانی و همکاران (Samani et al., 2007) یک شبکه عصبی مصنوعی را پیشنهاد دادند که به دلیل جایگزین نمودن الگوریتم لوبنرگ-مارکوآرت^۱ به جای الگوریتم کاهش شیب^۲ و اعمال روش آنالیز مولفه‌های اصلی^۳ بر مجموعه داده‌های آموزش، ابعاد شبکه مستقل از تعداد داده‌های افت-زمان گردید و پارامترهای آبخوان محبوس بدون محدودیت‌های ذکر شده تعیین شد. متعاقباً لین و همکاران (Lin et al., 2010) روش PCA را بر الگوهای آموزش و آزمایش اعمال نمودند تا شبکه‌ای را برای تخمین پارامترهای آبخوان‌های محبوس آنیزوتروپ تدوین کنند.

لین و چن (Lin and Chen, 2006) و سامانی و همکاران (Samani et al., 2007) برای تعیین پارامترهای آبخوان محبوس فرض کردند انطباق کامل بین منحنی تیپ و منحنی افت-زمان از هر آزمون پمپاژ واقعی وجود دارد به همین دلیل خروجی شبکه عصبی آموزش دیده و مختصات نقطه انطباق $[\frac{1}{u_m}, W(u)_m, s_m, t_m]$ مربوط به اولین رکورد از داده‌های افت-زمان را به عنوان ورودی به راه حل تحلیلی تائیس جهت تعیین پارامترهای آبخوان محبوس ایزوتروپ و هموزن در نظر گرفتند. اما از آنجایی که داده‌های افت-زمان اولیه به ویژه رکورد اول به دلیل خطاهای اندازه گیری، دقیق نمی‌باشد انتخاب رکورد اول از داده‌های افت-زمان به عنوان نقطه انطباق جهت تخمین پارامترهای هیدروژئولوژیکی آبخوان دقیق نمی‌باشد. به منظور حل این مسئله، از دو شبکه عصبی پیشخور^۴ MLP و RBF دارای یک لایه پنهان^۵ با ساختارهای ثابت $(1 \times 12 \times 1)$ و $(1 \times 14 \times 1)$ استفاده گردید. فرآیند طراحی مدل شامل یک پروتکل شش

کامل و دقیق تئوری این روش به منابع متعدد از جمله (Fausett, 1994; Haykin, 1999) مراجعه کنند. روش شبکه عصبی مصنوعی مشابه مغز انسان کار می‌کند یعنی از دانش حاصل از تمرین و تجربه جهت حل مسائل جدید استفاده می‌کند. بر این اساس شبکه عصبی مصنوعی به عنوان یک سیستم پردازشگر اطلاعات عمل می‌کند که از تعداد زیادی نورون تشکیل شده که می‌تواند روابط غیرخطی پیچیده بین ورودی‌ها و خروجی‌های مطلوب را از طریق فرآیند آموزش مدلسازی کند تا نتایج دقیقتری را نسبت به روش‌های مرسوم ایجاد کند. به همین دلیل شبکه عصبی مصنوعی با موفقیت در مسائل هیدروژئولوژیکی مختلف استفاده شده‌اند، از جمله در زمینه پاکسازی آب‌های زیرزمینی (Ranjithan et al., 1993; Chang et al., 2012)، پیش‌بینی نوسانات سطح آب زیرزمینی (Coulibaly et al., 2005; Daliakopoulos et al., 2001)، آلودگی و کیفیت آب زیرزمینی (Ray and Klindworth, 2000; Singh and Datta, 2007; Chau, 2007; Chang et al., 2010)، پیش‌بینی جریان سطحی (Cheng et al., 2005; Wu et al., 2009; Maier et al., 2010) انجمن ASCE در سال ۲۰۰۰ در مقاله‌ای با عنوان کاربرد شبکه‌های عصبی مصنوعی در هیدروژئولوژی، جنبه‌های کاربردی مختلف شبکه‌های عصبی را تشریح می‌کند. وو و همکارانش (Wu et al., 2014) در یک مقاله مروری پروتکلی را جهت تدوین مدل‌های شبکه عصبی و کاربرد آنها در مدلسازی کیفی آب آشامیدنی توصیه کردند. علی‌رغم تعداد زیاد مقاله‌های کار شده در زمینه کاربرد شبکه عصبی مصنوعی در هیدروژئولوژی، تحقیقات انجام شده در هیدروژئولوژی آب زیرزمینی به خصوص تخمین پارامترهای آبخوان بسیار محدود می‌باشد. لین و چن (Lin and Chen, 2005) یک روش شبکه عصبی مصنوعی را جهت تخمین پارامترهای آبخوان محبوس نشتی براساس ترکیب شبکه عصبی و حل تحلیلی هانتوش و ژاکوب (Hantush and Jacob, 1955) پیشنهاد دادند. همچنین لین و چن (Lin and Chen, 2006) ترکیبی از روش شبکه عصبی و حل تحلیلی تائیس (Theis, 1935) را برای آبخوان‌های محبوس غیرنشتی

1. Levenberg-Marquardt - LM

2. Gradient descent

3. Principal Component Analysis - PCA

4. Feed-Forward Neural Network - FFNN

5. Single-hidden-layer

پیشنهادی توسط ماير و همکاران (Maier et al., 2010) الهام گرفته شده بود جهت تدوین مدل شبکه عصبی مصنوعی در یک سیستم هیدرولوژی پیشنهاد نمودند. مراحل این پروتکل به ترتیب عبارتند از:

انتخاب ورودی^۴، تقسیم داده^۵، انتخاب ساختار مدل^۶، تعیین ساختار بهینه مدل^۷، کالیبره نمودن/آموزش مدل^۸ (بهینه‌سازی پارامترهای مدل)، صحت‌سنجی مدل^۹. این پروتکل یک راهنمای اصولی و دقیق در مراحل مختلف تدوین مدل شبکه عصبی مصنوعی می‌باشد. با توجه به طبیعت سیستمی که مدل می‌شود و اهداف مدلسازی (از جمله پیش‌بینی^۱، طبقه‌بندی^{۱۱}، تقریب تابع^{۱۲} و غیره) یک یا چند مرحله از فرآیند مدلسازی ممکن است با هم ترکیب و یا حذف شوند. در این تحقیق مدلسازی تابع تاپس و تعیین پارامترهای آبخوان‌های محبوس با تغییراتی در مراحل فوق انجام شده است. در هر مرحله دلیل انتخاب روش‌های اعمال شده و مزایای آنها ارائه شده است. دو شبکه عصبی تدوین شده به ازای هر مجموعه داده آزمون پمپاژ واقعی به عنوان ورودی، مختصات نقطه انطباق $\left[\hat{y} = \log\left(\frac{1}{u}\right)_m \right]$ را به عنوان خروجی تولید می‌کند.

مرحله ۱- تولید و انتخاب الگوهای ورودی آموزش

جهت تولید الگوهای آموزش شبکه عصبی، ابتدا مقادیر $\log\left(\frac{1}{u}\right)_m$ در محدوده‌ی (۱۵ تا -۱)، مطابق منحنی تپ ارائه شده توسط تاپس (۱۹۳۵) به عنوان خروجی (هدف) شبکه عصبی انتخاب شدند. با در نظر گرفتن بازه‌ی ۰/۰۰۱۶ برای $\log\left(\frac{1}{u}\right)_m$ ۱۰۰۰۰۰ مجموعه بردار ورودی آموزش که هر کدام دارای N-1 عنصر (N تعداد داده‌های افت-زمان) هستند تولید شدند که در شکل (۲) نشان داده شده است.

مرحله‌ای مشابه با روش پیشنهاد شده توسط وو و همکاران (Wu et al., 2014) می‌باشد که روش مورد استفاده در هر مرحله نیز شرح داده شده است. دقت این شبکه‌ها با ۱۰۰۰۰۰ مجموعه داده افت-زمان سنتز شده فاقد خطا^۱ آزمایش شد. در نهایت قابلیت تعمیم و عملکرد این شبکه‌ها با استفاده از دو مجموعه داده پمپاژ واقعی ارزیابی گردید. در این مرحله به منظور انتخاب نقطه بهینه برای تخمین دقیق پارامترهای هیدروژئولوژیکی آبخوان‌های محبوس، خروجی حاصل از شبکه‌های عصبی مربوط به هر کدام از رکوردهای افت-زمان به عنوان نقطه انطباق در نظر گرفته شدند و پارامترهای آبخوان محاسبه گشتند. رکوردی که پارامترهای آبخوان محاسبه شده توسط آن، کمترین ریشه میانگین مربعات خطای نسبی^۲ (RRMSE) را برای افت تخمین زده شده توسط شبکه‌های عصبی ایجاد نمود به عنوان نقطه انطباق بهینه جهت تعیین پارامترهای آبخوان در نظر گرفته شد. سپس نتایج حاصل از شبکه‌های عصبی MLP و RBF با نتایج به دست آمده از روش گرافیکی انطباق منحنی تپ مقایسه گردید. نتایج این تحقیق نشان داد که اگر چه هر دو مدل شبکه عصبی MLP و RBF می‌توانند پارامترهای آبخوان را با دقت و سرعت بیشتری نسبت به روش گرافیکی انطباق منحنی تپ تعیین نمایند اما شبکه MLP طراحی شده از دقت بالاتری نسبت به شبکه RBF برخوردار می‌باشد. لذا شبکه پیشنهادی جهت تعیین پارامترهای آبخوان‌های محبوس، شبکه MLP می‌باشد. شبکه‌های طراحی شده در قالب یک برنامه رایانه‌ای در محیط نرم‌افزار متلب^۳ تهیه شد. این برنامه داده‌های آزمون پمپاژ را دریافت می‌کند و مقادیر پارامترهای آبخوان‌های محبوس [T,S] را برای کاربر محاسبه می‌کند.

روش مدلسازی

اگر چه فرآیند تدوین مدل شبکه عصبی مصنوعی بسیار حائز اهمیت است اما هیچ پروتکل جامعی جهت طراحی و تدوین این مدل‌ها ارائه نشده بود. تا اینکه وو و همکاران (Wu et al., 2014) بیش از ۸۱ مقاله مربوط به سال‌های ۲۰۰۰ تا ۲۰۱۲ را در زمینه کیفیت آب آشامیدنی بررسی نمودند و یک پروتکل شش مرحله‌ای را که از پروتکل ده مرحله‌ای

1. Error-free
2. Relative Root Mean Square Error - RRMSE
3. Matlab program
4. Input selection
5. Data splitting
6. Selection of model architecture
7. Determination of model optimum structure
8. Model calibration/training
9. Model validation
10. Forecasting
11. Classification
12. Function approximation

رابطه (۴) تولید شده نشان می‌دهد. مولفه‌های اصلی با در نظر گرفتن حداقل درصد واریانس ۰/۰۰۱ استخراج شدند. همان‌گونه که مشاهده می‌شود مولفه‌ی اصلی اول ۹۹/۹۰۶٪ از واریانس کل داده‌های آموزش را شامل می‌شود. واریانس محاسبه شده توسط مولفه دوم کوچکتر از حداقل درصد واریانس می‌باشد (۰/۰۰۰۹۳۹ < ۰/۰۰۱) بنابراین می‌توان از آن صرف نظر نمود. این موضوع نشان می‌دهد که عناصر بردار ورودی آموزش به ۱ عنصر کاهش می‌یابد و تعداد نورون‌ها در لایه ورودی شبکه می‌تواند با ۱ نورون به جای تعداد رکوردها در داده‌های افت-زمان که در هر آزمون پیمایشی تغییر می‌کند ثابت شود. کاهش بردار ورودی به یک عنصر کاملاً منطقی است زیرا تابع چاه $W(u)$ تابعی یک متغیره است. بنابراین کاربرد PCA تعداد نورون‌ها در لایه‌های ورودی و پنهان و نیز مدت زمان لازم برای آموزش و آزمایش شبکه عصبی را کاهش می‌دهد و تعداد نورون‌های لایه ورودی را مستقل از تعداد رکوردهای داده‌های افت-زمان ثابت می‌کند.

جدول ۱- پارامترهای مولفه اصلی مجموعه آموزش آبخوان‌های محبوس

مولفه اصلی	مقدار ویژه	واریانس (%)	واریانس تجمعی (%)
PC1	۳۹/۹۶۲۴	۹۹/۹۰۶	۹۹/۹۰۶
PC2	۰/۰۳۷۶	۰/۰۹۳۹	۹۹/۹۹۹۹
PC3	۰/۰۰۰۰۴۲۶	۰/۰۰۰۱	۱۰۰

مرحله ۲- انتخاب ساختار شبکه


یک شبکه عصبی مصنوعی شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشد که هر کدام از لایه‌ها دارای تعدادی نورون می‌باشد. تعداد نورون‌ها در لایه‌های ورودی و خروجی با توجه به تعداد متغیرهای ورودی و خروجی تعیین می‌شوند. تعداد لایه‌های پنهان و نورون‌های آنها در مرحله آموزش مدل (کالیبراسیون) معمولاً از طریق فرآیند سعی و خطا مشخص می‌گردد. الگوی اتصال نورون‌ها، روش تعیین وزن‌های اتصالی و نوع تابع فعالساز^۲، ساختار شبکه عصبی را تعیین می‌کند (Fausett, 1994; ASCE Task Committee on

1. Dimensionality reduction
2. Minimum fraction variance
3. Activation function

بر این اساس اندازه ماتریس داده ورودی $[(N-1) \times 100000]$ می‌باشد. سپس برای همه مجموعه‌های $[\log(\frac{1}{u})_m]$ تابع چاه $W(u)$ با استفاده از رابطه (۲) محاسبه گردید. در مرحله بعد الگوهای آموزش X_i با معادله زیر و مطابق با شکل (۲) تولید شد:

$$X_i = \log \left[\frac{W(u_m \times t_1/t_{i+1})}{W(u_m)} \right] \quad (4)$$

اندیس m به نقطه انطباق اشاره می‌کند و $i=1, 2, \dots, N-1$ می‌باشد. قبل از اینکه مجموعه الگوهای ورودی آموزش تولید شده به عنوان بردار ورودی به شبکه‌های عصبی استفاده گردند، باید مستقل بودن داده‌ها با استفاده از روش کاهش ابعاد داده بررسی شود (Maier et al., 2010). کاهش ابعاد داده‌ها معمولاً با استفاده از روش PCA انجام می‌شود (Wu et al., 2014). بنابراین با اعمال تکنیک PCA، ابعاد داده‌های ورودی کاهش داده می‌شوند. PCA داده‌ها را به سیستم مختصات جدید تبدیل می‌کند به گونه‌ای که بیشترین واریانس داده‌ها را به مختصات اول نسبت می‌دهد و مولفه اصلی اول را ایجاد می‌نماید. همچنین بیشترین واریانس دوم را به مختصات دوم اختصاص داده و مولفه اصلی دوم را می‌سازد بنابراین این روند با همین ترتیب پیش می‌رود تا مولفه‌ای که کوچکترین مقدار واریانس را شامل می‌شود ایجاد گردد. وقتی آنالیز کامل شد مولفه‌های حاصل، درجه متفاوتی از همبستگی با هم نشان خواهند داد. یکی از پارامترهای مهم در روش PCA، حداقل درصد واریانس^۲ است. با در نظر گرفتن یک حداقل درصد واریانس معین، می‌توان مولفه‌های اصلی که سهم کمتری از این مقدار را نسبت به واریانس کل در مجموعه داده‌ها دارند حذف نمود و بدین ترتیب ابعاد مجموعه داده‌ها، بدون اینکه هیچ اطلاعاتی از دست برود کاهش داده می‌شود (Davis, 2002). سامانی و همکاران (Samani et al., 2007) و متعاقباً لین و همکاران (Lin et al., 2010) با موفقیت روش PCA را جهت کاهش ابعاد بردارهای ورودی استفاده نمودند و یک شبکه با ساختار ثابت جهت تعیین دقیق پارامترهای آبخوان‌های محبوس ایزوتروپ و آنیزوتروپ طراحی نمودند. جدول (۱) پارامترهای PCA الگوهای آموزش X_i را که با استفاده از



شکل ۲. نمایش گرافیکی تولید بردارهای ورودی و خروجی (هدف) شبکه‌های MLP و RBF

MLP سیگنال‌های ورودی وارد لایه ورودی گشته و پس از ضرب در وزن‌های سیناپتیکی به اولین لایه پنهان فرستاده می‌شود. در لایه‌های پنهان و خروجی یک تابع فعالسازی مانند آستانه‌ای^۲، سیگموئید تک قطبی^۳، سیگموئید دو قطبی^۴، هیپربولیک تانژانت^۵، گاوسی^۶، و خطی^۷ برای تبدیل مجموع مولفه‌های ورودی وزن‌دار شده به بردار خروجی به کار می‌رود (Haykin, 1999). در این تحقیق بر اساس تجارب قبلی (Samani et al., 2007) تابع هیپربولیک تانژانت (tansig): $f(x) = (1 - e^{-2x}) / (1 + e^{-2x})$; برای لایه پنهان و تابع خطی (purelin): $[f(x) = x, \text{ for all } x]$ برای لایه خروجی شبکه MLP استفاده شده است.


همچنین در این تحقیق از یک شبکه عصبی مصنوعی پیشخور RBF دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی استفاده گردید. در شبکه RBF سیگنال‌های ورودی وارد لایه ورودی گشته و پس از اینکه تفاضل بین

Application of Artificial Neural Networks in Hydrology, 2000a). همچنین شبکه‌های عصبی مصنوعی بر اساس نوع پردازش (پیشخور و برگشتی) اطلاعات طبقه‌بندی می‌شوند (Maier et al., 2010). به عنوان مثال در یک شبکه عصبی مصنوعی پیشخور MLP اطلاعات تنها از نورون‌های ورودی به نورون‌های خروجی انتقال داده می‌شوند. این نوع شبکه‌ها برعکس شبکه‌های عصبی برگشتی هستند که اطلاعات را در هر دو جهت (از نورون‌های ورودی به نورون‌های خروجی و بالعکس) انتقال می‌دهند. ساختار شبکه عصبی رایجی که معمولاً استفاده می‌شود شبکه‌های عصبی پیشخور می‌باشند (ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a; Maier et al., 2010; Razavi and Tolson, 2011; Wu et al., 2014). بنا به پیشنهاد رضوی و تولسون (Razavi and Tolson, 2011) شبکه عصبی مصنوعی پیشخور MLP با یک لایه پنهان، جهت تقریب هر رابطه پیوسته بین الگوهای ورودی و خروجی مناسب می‌باشد. بنابراین در این تحقیق در شروع کار جهت تدوین شبکه عصبی MLP از شبکه پیشخور دارای یک لایه پنهان استفاده گردید. در شبکه

1. Recurrent neural networks
2. Threshold
3. Uni-polar sigmoid
4. Bi-polar sigmoid
5. Hyperbolic tangent
6. Gaussian
7. linear

شکل (۳) ساختار شبکه‌های عصبی با یک لایه پنهان را قبل و بعد از اعمال تکنیک PCA بر مجموعه داده‌های ورودی نشان می‌دهد. تعداد بهینه نورون‌ها در لایه پنهان و ساختار بهینه شبکه در بخش بعدی در فرآیند آموزش شبکه (کالیبراسیون) تعیین می‌گردد.

این سیگنال‌ها با وزن بین لایه ورودی و پنهان، به عنوان ورودی خام به لایه پنهان فرستاده شد، جذر مجموع مربعات آنها به عنوان ورودی مؤثر جهت قرار دادن در تابع فعالسازی نورون‌های لایه پنهان محاسبه می‌گردد. تابع فعالسازی لایه پنهان شبکه RBF، تابع گاوسی $f(x) = e^{-\frac{\|x-c_j\|^2}{\tau\sigma^2}}$ می‌باشد. خروجی حاصل از لایه پنهان به لایه خروجی فرستاده می‌شود تا خروجی شبکه RBF محاسبه گردد (Haykin, 1999).



شکل ۳. ساختار شبکه‌های عصبی دارای یک لایه پنهان قبل و بعد از اعمال PCA بر مجموعه داده‌های ورودی آموزش

PCA بر آنها اعمال شد)، b_1 بایاس^۲ بیان‌کننده حد آستانه نورون 1، w_{i1} بردار وزن بین نورون i در لایه ورودی و نورون 1 در لایه پنهان برای شبیه‌سازی سیناپس‌های بیولوژیکی، n تعداد کل ورودی‌های اعمال شده به نورون i در لایه ورودی و f تابع فعالسازی برای تبدیل مجموع مولفه‌های ورودی وزن‌دار شده به بردار خروجی می‌باشد.

در این مقاله، آموزش شبکه و تنظیم وزن‌ها با استفاده از روش لونیگ-مارکوارت^۳ که موثرترین روش بهینه‌سازی شبکه‌های عصبی می‌باشد انجام شده است (Razavi and Tolson, 2011). محققان زیادی از این روش در مسائل مختلف آب زیرزمینی با موفقیت استفاده نموده‌اند (Maier and Dandy, 1999, 2000; Toth et al., 2000; Coulibaly et al., 2001; Daliakopoulos

مرحله ۳- آموزش شبکه (کالیبراسیون)

الگوریتم پس انتشار^۱ رایج‌ترین روش برای آموزش شبکه‌های عصبی MLP می‌باشد (Rumelhart et al., 1986) که می‌تواند هر مسئله خطی و غیر خطی پیچیده بین ورودی‌ها و خروجی‌ها را از طریق یافتن وزن‌های بهینه، مدل‌سازی کند (ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a; Maier and Dandy, 1999, 2000). در این روش ورودی‌ها پس از ضرب در وزن‌های سیناپتیکی وارد لایه پنهان می‌شوند. خروجی لایه پنهان (h_1) می‌تواند با استفاده از روابط زیر تعیین شوند:

$$Z_1 = b_1 + \sum_{i=1}^n X_i w_{i1} \quad (5)$$

$$h_1 = f(Z_1) \quad (6)$$

که X_i ورودی به نورون‌های پردازشگر (بردارهای ورودی که با استفاده از رابطه (۴) تولید شدند و سپس تکنیک

1. Back-Propagation - BP
2. Bias
3. Levenberg-Marquardt - LM

شبیه‌سازی شده) با استفاده از دو معیار زیر انجام شد:
الف) ریشه میانگین مربع خطای نسبی (RRMSE):

$$RRMSE = 100 \times \sqrt{\frac{1}{n} \sum_{j=1}^n \left(\frac{\hat{y}_j - y_j}{y_j}\right)^2} \quad (8)$$

که \hat{y}_j هدف شبیه‌سازی شده یا محاسبه شده توسط شبکه، y_j هدف واقعی و n تعداد الگوها می‌باشد. کمترین مقدار RRMSE بیشترین دقت پیش‌بینی را نشان می‌دهد. RRSME = ۰ نشان‌دهنده دقت ۱۰۰٪ می‌باشد.

ب) ضریب تشخیص R^2 :

$$R^2 = 1 - \frac{\sum (y_j - \hat{y}_j)^2}{\sum y_j^2 - \frac{(\sum \hat{y}_j)^2}{n}} \quad (9)$$

R^2 میزان تناسب بین خروجی شبکه و خروجی مطلوب را نشان می‌دهد. $R^2 = 1$ نشان‌دهنده ۱۰۰٪ تناسب بین مقادیر خروجی شبکه و مقادیر هدف می‌باشد. مزیت استفاده از معیارهای RRMSE و R^2 این است که مقادیر آنها به ترتیب بین دو حد بالا و پایین ۰ تا ۱۰۰ و ۰ تا ۱ تغییر می‌کند و بنابراین این معیارها به وضوح، اندازه مشخصی از مقدار خطای میانگین را نشان می‌دهند. شکل (۴) تغییرات (RRMSE, R^2) را نسبت به تعداد نورون‌های لایه پنهان برای مقدار مطلوب هدف شبکه‌های عصبی نشان می‌دهد. به طور کلی نمودارهای شکل (۴) نشان می‌دهد که بهترین ساختارهای شبکه عصبی مصنوعی که به طور کارآمد و موثر تابع چاه آبخوان‌های محبوس را مدل‌سازی و مختصات نقطه انطباق را با دقت پیش‌بینی می‌کنند شبکه عصبی پیشخور MLP با یک لایه پنهان و ساختار (۱×۱۲×۱) و شبکه RBF با ساختار (۱×۱۴×۱) می‌باشند.

مرحله ۵- آزمایش شبکه‌های طراحی شده

به منظور ارزیابی عملکرد شبکه‌های طراحی شده با ساختار بهینه در تعیین مختصات نقطه انطباق و پارامترهای آبخوان از الگوهای آزمایش استفاده می‌شود. بهترین نتیجه از عملکرد شبکه، زمانی حاصل می‌شود که شبکه آموزش دیده کوچکترین خطای پیش‌بینی را برای مجموعه

1. Jacobin matrix
2. Performance criteria - error
3. Learning rate
4. Structural validity
5. Determination coefficient

(et al., 2005; Samani et al., 2007). در این الگوریتم تابع تنظیم‌کننده وزن‌ها $w(k+1)$ با استفاده از فرمول زیر تخمین زده می‌شود:

$$w(k+1) = w(k) - [J^T \times J + \mu I]^{-1} \times J^T \times e \quad (7)$$

در این رابطه J ماتریس ژاکوبی^۱ معیار عملکرد-خطا^۲ شبکه می‌باشد که باید کمینه گردد، μ نرخ یادگیری^۳، k تعداد تکرار در طول فرآیند بهینه‌سازی، e بردار مقدار باقیمانده و I ماتریس همانی می‌باشد.

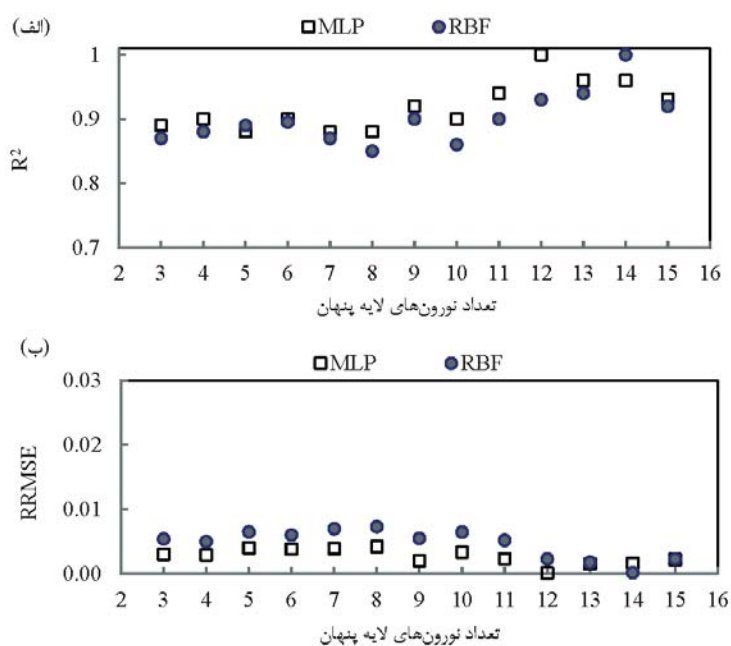
پس از اینکه وزن‌ها و بایاس‌ها بین تمامی اتصالات نورون‌ها در لایه‌های مختلف تنظیم گردید و معیار همگرایی به حد مطلوب (مثلاً 10^{-6}) رسید فرآیند آموزش شبکه کامل شده است. در این تحقیق شبکه عصبی MLP با یک لایه پنهان و دوازده نورون و شبکه RBF با چهارده نورون در لایه پنهان از طریق روش سعی و خطا کالیبره گردید. بنابراین ساختار شبکه‌های آموزش داده شده، با آرایش بهینه (۱×۱۲×۱) و (۱×۱۴×۱) تثبیت گردید. ۱، ۱۲ و ۱ و نیز ۱، ۱۴ و ۱ به ترتیب به تعداد نورون در لایه ورودی، پنهان و خروجی اشاره می‌کند. پارامترهای به کار رفته در طول فرآیند آموزش در جدول (۲) نشان داده شده است.

جدول ۲- پارامترهای به کار رفته در آموزش شبکه عصبی مصنوعی MLP

پارامتر	مقدار
نرخ یادگیری	۰/۵
معیار همگرایی	۱۰-۶
حداکثر چرخه آموزش	۱۰۰۰۰
تعداد الگوهای آموزش	۱۰۰۰۰۰

مرحله ۴- تعیین ساختار بهینه شبکه

جهت حصول اطمینان در مورد بهینه‌بودن ساختار شبکه‌های عصبی تعیین شده لازم است که آنالیز حساسیت جهت تعیین تعداد بهینه لایه‌ها و نورون‌های پنهان انجام شود. این آنالیز اعتبار بیشتری را به شبکه آموزش دیده در پیش‌بینی مختصات نقطه انطباق (هدف شبکه) خواهد داد که به این آنالیز، صحت‌سنجی ساختاری^۴ گفته می‌شود (Wu et al., 2014). در این مقاله، آنالیز حساسیت و تعیین میزان خطا (اختلاف بین هدف مطلوب و هدف



شکل ۴. نمودارهای آنالیز حساسیت ساختار شبکه‌های عصبی MLP و RBF

به T و S تبدیل می‌شوند. شکل (۶) نمودارهای پراکنش^۱ و بهترین خط تناسب^۲ بین پارامترهای هدف و محاسبه شده (T, S) توسط شبکه‌های دو شبکه طراحی شده آبخوان محبوس را نشان می‌دهد. همانطور که در این شکل‌ها نشان داده شده است هر دو شبکه می‌توانند پارامترهای آبخوان را با دقت بالایی در محدوده‌ی وسیعی از مقادیر آزمایشی محاسبه کنند. در تمامی نمودارها مقدار R^۲ مساوی یک و مقدار RRMSE بسیار نزدیک به صفر می‌باشند (جدول ۳). این مقادیر نشان‌دهنده دقت بالای پیش‌بینی شبکه‌های طراحی شده در شبیه‌سازی دقیق سیستم واقعی (رابطه ۱) می‌باشند (Wu et al., 2014).

جدول ۳. RRMSE (%) و R^۲ پارامترهای محاسبه شده آبخوان محبوس با استفاده از شبکه‌های طراحی شده در مرحله آزمایش

نوع شبکه عصبی	پارامترها	RRMSE (%)
MLP	T	$1/74 \times 10^{-3}$
	S	$3/85 \times 10^{-3}$
RBF	T	$2/55 \times 10^{-3}$
	S	$6/23 \times 10^{-3}$

هر دو پارامتر فوق در هر دو شبکه عصبی برابر ۱ محاسبه شد R^۲


1. Scatter plots
2. Best-fitted line

داده‌های آزمایش که متفاوت از مجموعه داده‌های آموزش هستند تولید کند.

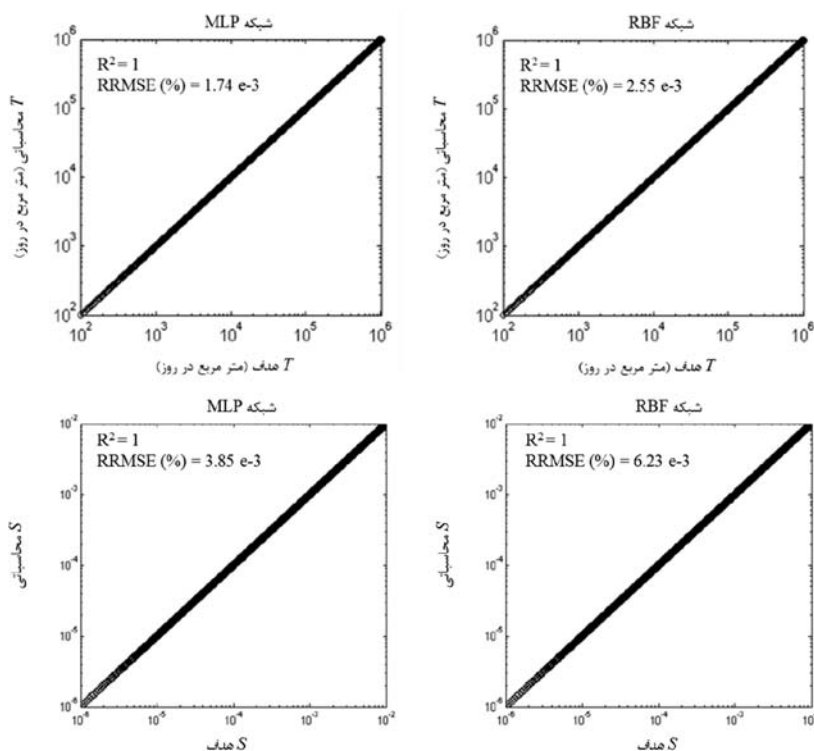
عملکرد شبکه‌های آموزش دیده با ۱۰۰۰۰۰ مجموعه داده افت-زمان سنتز شده فاقد خطا آزمایش گردید. این داده‌های سنتز شده با استفاده از حل تحلیلی تاپس (روابط ۱-۳) برای آبخوان محبوس و از ترکیب مقادیر ایده‌آل T و S به ترتیب در محدوده‌ی ۱۰^۲ تا ۱۰^۶ متر مربع در روز و ۱۰^{-۶} تا ۱۰^{-۲} با انتخاب تعدادی گام‌های زمانی مطابق شکل (۲) تولید گشتند. داده‌های سنتز شده با استفاده از رابطه (۱۰) به نسبت‌های افت تبدیل شدند (Lin and Chen, 2005) که به عنوان بردارهای ورودی (X_i) در شبکه‌های آموزش دیده استفاده شدند:

$$X_i = \log(s_{i+1}) - \log(s_i) = \log\left(\frac{s_{i+1}}{s_i}\right) \quad (10)$$

s_i افت ثبت شده در زمان t_i می‌باشد. با اعمال PCA بر بردارهای ورودی، نسبت‌های افت کاهش‌یافته $\left[\log\left(\frac{s_{i+1}}{s_i}\right)\right]$ تولید شدند. شکل (۵) ساختار شبکه‌های طراحی شده در مرحله آزمایش را نشان می‌دهد. شبکه‌های آموزش داده شده، نسبت‌های افت کاهش یافته (نسبت‌های افتی که PCA بر آنها اعمال گردید) را دریافت و مقدار $\log\left(\frac{1}{u}\right)_m$ را محاسبه می‌کنند که با استفاده از روابط (۱-۳)



شکل ۵- ساختار شبکه‌های عصبی طراحی شده در مرحله آزمایش



شکل ۶. نمودار پراکنش پارامترهای محاسباتی آبخوان محبوس در مقابل هدف با استفاده از شبکه‌های عصبی MLP و RBF

پمپاژ و داده‌های افت-زمان یک چاه مشاهده‌ای در فاصله ۶۰ متری از چاه پمپاژ ثبت گردید. هر مجموعه داده‌ی افت-زمان به نسبت‌های افت تبدیل شدند و سپس تکنیک PCA بر آنها اعمال گردید. مجموعه داده‌های کاهش‌یافته به عنوان بردارهای ورودی به شبکه‌های طراحی شده وارد گردید تا مقدار مختصات نقطه انطباق $\log(\frac{1}{u})_m$ توسط شبکه‌ها تعیین شوند.

تعیین پارامترهای آبخوان

مختصات نقطه انطباق تعیین شده توسط شبکه‌های عصبی طراحی شده مربوط به هر دو آزمون پمپاژ برای تمامی رکوردهای افت-زمان مطابق شکل (۲) به شرح زیر تنظیم گردید:

مرحله ۶- صحت‌سنجی شبکه‌های طراحی شده

در این مرحله از دو مجموعه داده آزمون پمپاژ واقعی (داده افت - زمان) استفاده شده است تا دقت و عملکرد دو شبکه پیشنهادی برای تعیین مختصات نقطه انطباق ارزیابی شود. مجموعه اول داده‌ها از والتون (Walton, 1962) و مجموعه دوم داده‌ها از تاد و میز (Todd and Mays, 2005) اقتباس شده است.

الف) آزمایش پمپاژ اول: این آزمایش در آبخوانی محبوس انجام شد که در آن یک چاه پمپاژ با نرخ ثابت ۱۱۹۹ متر مکعب در روز پمپاژ می‌شد. داده‌های افت-زمان در یک چاه مشاهده‌ای در فاصله ۵۲ متری از چاه پمپاژ ثبت گردید. ب) آزمایش پمپاژ دوم: در این آزمون پمپاژ یک چاه با نرخ ثابت ۲۵۰۰ متر مکعب در روز در آبخوانی محبوس

مدل پیشنهادی MLP را نشان می‌دهد. در آزمون پمپاژ اول و دوم رکورد هشتم و دهم از داده‌های افت-زمان که کمترین مقدار RRMSE را ایجاد نمودند به عنوان نقاط انطباق بهینه شبکه‌های MLP و RBF انتخاب گردیدند (شکل ۷).

جدول ۴. پارامترهای محاسبه شده آبخوان با استفاده از شبکه‌های طراحی شده و روش انطباق منحنی تیپ و مقادیر RRMSE (%) (آزمون پمپاژ اول (Walton, 1962)

پارامترهای آبخوان	روش‌ها		
	انطباق منحنی تیپ	MLP	RBF
T (m ² /day)	۱۲۵	۱۱۷	۱۲۱
S (10 ⁻⁵)	۲	۲/۲۴	۲/۲۲
RRMSE (%)	۱۰	۰/۰۲	۱/۱۵

جدول ۵. پارامترهای محاسبه شده آبخوان با استفاده از شبکه‌های طراحی شده و روش انطباق منحنی تیپ و مقادیر RRMSE (%) (آزمون پمپاژ دوم (Todd and Mays, 2005)

پارامترهای آبخوان	روش‌ها		
	انطباق منحنی تیپ	MLP	RBF
T (m ² /day)	۱۱۱۰	۱۱۲۹/۹	۱۱۲۵
S (10 ⁻⁴)	۲/۰۶	۱/۹۴	۲
RRMSE (%)	۵/۷۵	۰/۰۲۸	۱/۰۲

$$\hat{y} = \log\left(\frac{1}{u}\right) = \log\left[\left(\frac{1}{u}\right)_m \times \left(\frac{t_j}{t_1}\right)\right], j = 1, 2, \dots, N \quad (11)$$

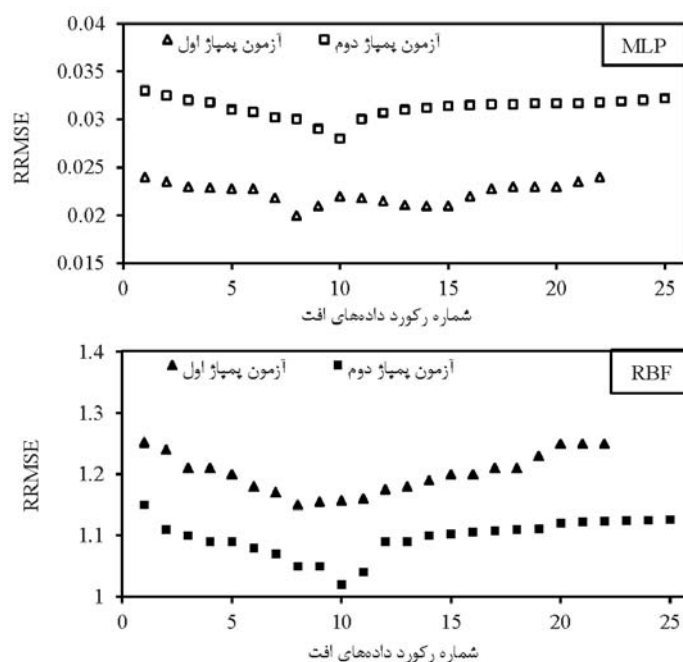
$$\left(\frac{1}{u}\right)_j = \left[\left(\frac{1}{u}\right)_m \times \left(\frac{t_j}{t_1}\right)\right] = 10^{\hat{y}} \quad (12)$$

$$W_m = W(u_j) = W\left(\frac{1}{10^{\hat{y}}}\right) \quad (13)$$

$$s_m = s_j \quad (14)$$

$$t_m = t_j \quad (15)$$

با جایگزین نمودن مقادیر مختصات نقطه انطباق در معادلات (۱-۳) مقادیر پارامترهای آبخوان محبوس (T, S) تعیین شدند. آن داده افت [t_j, W_j, s_j, t₁] که حداقل مقدار RRMSE را تولید می‌کند به عنوان مختصات نقطه انطباق بهینه انتخاب می‌شود. این داده مقادیر پارامترهای آبخوان را با بیشترین دقت ممکن تعیین می‌کند. مقادیر پارامترهای آبخوان (T, S) با استفاده از شبکه‌های طراحی شده تعیین و نتایج در جدول‌های (۴) و (۵) به ترتیب برای آزمون‌های پمپاژ اول و دوم آورده شده و با مقادیر حاصل از روش انطباق منحنی تیپ مقایسه گردیده است. همان‌گونه که در جدول‌های (۴) و (۵) نشان داده شده است مقدار RRSME با روش انطباق منحنی تیپ ۱۰٪ و ۵/۷۵٪، با شبکه RBF ۱/۱۵ و ۱/۰۲ و با شبکه MLP ۰/۰۲٪ و ۰/۰۲۸٪ برای آزمون‌های پمپاژ اول و دوم می‌باشد که دقت بیشتر



شکل ۷. نمودار RRMSE نشان‌دهنده رکورد افت-زمان بهینه دو مجموعه داده آزمون پمپاژ با شبکه‌های MLP و RBF

نتیجه‌گیری

دقت شبکه‌های طراحی شده با ۱۰۰۰۰۰ مجموعه داده افت-زمان سنتز شده فاقد خطا آزمایش گردید. نمودار پراکنش اهداف خروجی (مقادیر هدف تخمین‌زده شده نسبت به مقادیر هدف واقعی)، دقت بسیار خوب عملکرد این شبکه‌ها را نشان داد. در مرحله ششم (صحت‌سنجی شبکه)، عملکرد این شبکه‌ها در تولید مختصات نقطه انطباق دو مجموعه داده آزمون پمپاژ واقعی با روش انطباق منحنی تیپ مقایسه گشت. مقایسه مقادیر RRMSE، توانایی شبکه‌های طراحی شده در تعیین پارامترهای آبخوان را نشان داد. به طور خلاصه، شبکه‌های طراحی شده نسبت‌های افت کاهش یافته را به عنوان ورودی دریافت نموده و مختصات نقطه انطباق مربوط به رکورد اول را به عنوان خروجی تولید می‌کنند. خروجی شبکه‌ها با هر کدام از رکوردهای افت-زمان ترکیب شده و پارامترهای آبخوان به ازای هر رکورد محاسبه می‌گردند. با استفاده از هر مجموعه از پارامترهای آبخوان، رکوردهای افت تولید می‌شوند و با رکوردهای افت واقعی مقایسه می‌گردند و مقدار RRMSE محاسبه می‌شود. پارامترهایی که کمترین مقدار RRMSE را ایجاد می‌کنند به عنوان دقیق‌ترین تخمین از مقادیر پارامترهای آبخوان انتخاب می‌گردند. نتایج نشان داد که اگر چه هر دو شبکه‌ی MLP و RBF، می‌توانند پارامترهای آبخوان‌های محبوس را با دقت و سرعت بالایی تعیین کنند و خطاهای گرافیکی روش انطباق منحنی تیپ را حذف نمایند اما شبکه عصبی MLP از دقت و سرعت بالاتری برخوردار بوده بنابراین این روش به عنوان یک روش جایگزین دقیق، کارآمد و با کاربرد آسان نسبت به شبکه RBF و روش‌های گرافیکی انطباق منحنی تیپ جهت تعیین پارامترهای آبخوان‌های محبوس توصیه می‌گردد.

منابع

- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology., 2000a. Artificial Neural Networks in hydrology. I: preliminary concepts. J Hydrol Eng, 5,2, 115-123.
- Chang, F.J., Kao, L.S., Kuo, Y.M., and Liu, C.W., 2010. Artificial neural networks for

در این مقاله دو شبکه عصبی مصنوعی پیشخور MLP و RBF دارای یک لایه پنهان جهت مدلسازی تابع چاه تاپس و تعیین پارامترهای آبخوان‌های محبوس طراحی گردید. طراحی این شبکه‌های عصبی طی یک پروتکل شش مرحله‌ای انجام شد. در مرحله اول (تولید و انتخاب داده ورودی)، با استفاده از حل تحلیلی تاپس و با در نظر گرفتن محدوده وسیعی از مقادیر $\log\left(\frac{1}{u}\right)_m$ ، داده‌های ورودی تولید شد (شکل ۲ و رابطه ۴). قبل از طراحی ساختار شبکه، با در نظر گرفتن واریانس ۰/۰۰۱ PCA بر مجموعه داده‌های ورودی اعمال گردید تا ابعاد آن کاهش یابد. نتایج نشان داد که تنها مولفه‌ی اصلی اول در مجموع ۹۹/۹۰۶٪ از واریانس کل داده‌ها را به خود اختصاص می‌دهند. در نتیجه بعد الگوهای ورودی و تعداد نورون‌ها در لایه ورودی به ۱ نورون کاهش یافته و ثابت گردید. در مرحله دوم (انتخاب ساختار شبکه)، طراحی ساختار شبکه با یک لایه پنهان که مرسوم‌ترین شبکه عصبی استفاده شده در کاربردهای مهندسی می‌باشد آغاز گشت. در این مرحله توابع فعالسازی انتخاب شدند و تعدادی نورون‌های اختیاری برای لایه پنهان در نظر گرفته شد. در مرحله سوم (کالیبره‌نمودن شبکه)، آموزش شبکه و تنظیم وزن‌ها با اعمال روش آموزش BP و الگوریتم بهینه‌سازی LM اجرا گردید. شبکه MLP با ۱۲ نورون و شبکه RBF با ۱۴ نورون در لایه پنهان با استفاده از روش سعی و خطا آموزش داده شدند و در نتیجه ساختار $(1 \times 12 \times 1)$ و $(1 \times 14 \times 1)$ با حفظ معیار همگرایی 10^{-6} حاصل گردید. در مرحله چهارم (تعیین ساختار بهینه شبکه)، آنالیز حساسیت انجام شد تا ساختار بهینه شبکه‌های آموزش دیده با ارزیابی توانایی شبکه‌ها جهت تولید خروجی مطلوب بر اساس دو معیار موثر RRMSE و R^2 تعیین شود. نتایج این آنالیز نشان داد که افزایش و کاهش تعداد نورون‌ها در لایه پنهان و همچنین افزایش تعداد لایه پنهان دقت شبکه را جهت محاسبه هدف مطلوب کاهش می‌دهد. به این ترتیب ساختار بهینه شبکه‌های طراحی شده صرف نظر از تعداد رکوردهای داده‌های افت-زمان با آرایش $(1 \times 12 \times 1)$ و $(1 \times 14 \times 1)$ ثابت شدند. در مرحله پنجم (آزمایش شبکه)،

- estimating regional arsenic concentrations in a black foot disease area in Taiwan. *J Hydrol*, 388, 65-76.
- Chang, L.Ch., Chu, H.J., and Hsiao, Ch.T., 2012. Integration of optimal dynamic control and neural network for groundwater quality management. *Water Resour Manage*, 26, 1253-1269.
 - Chau, K.W., 2007. An ontology-based knowledge management system for flow and water quality modeling. *Adv Eng Softw*, 38,3, 172-181.
 - Cheng, Ch., Chau, K., Sun, Y., and Lin, J., 2005. Long-term prediction of discharges in Manwan Reservoir using artificial neural network models. *LNCS 3498*, 1040-1045.
 - Coulibaly, P., Anctil, F., Aravena, R., and Bobee, B., 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resour Res*, 37,4, 885-896.
 - Daliakopoulos, I.N., Coulibaly, P., and Tsanis, I.K., 2005. Groundwater level forecasting using artificial neural networks. *J Hydrol*, 309,1-4, 229-240.
 - Davis, J.C., 2002. *Statistics and data analysis in geology*. 3rd edn. Wiley, New York.
 - Fausett, L., 1994. *Fundamentals of neural networks*. Prentice Hall, Englewood Cliffs, N.J.
 - Hantush, M.S., Jacob, C.E., 1955. Non-steady radial flow in an infinite leaky aquifer. *Trans Am Geophys Union*, 36,1, 95-100.
 - Haykin, S., 1999. *Neural networks: a comprehensive foundation*. Prentice-Hall: Englewood Cliffs, NJ.
 - Lin, G.F., and Chen, G.R., 2005. Determination of aquifer parameters using radial basis function network approach. *J Chinese Inst Engrs*, 28,2, 241-249.
 - Lin, G.F., and Chen, G.R. 2006. An improved neural network approach to the determination of aquifer parameters. *J Hydrol*, 316,1-4, 281-289.
 - Lin, H.T., Ke, K.Y., Chen, Ch.H., Wu, Sh.Ch., and Tan, Y.Ch., 2010. Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrol Process*, 24, 3237-3250.
 - Maier, H.R., and Dandy, G.C., 1999. Empirical comparison of various methods for training feed-forward neural networks for salinity forecasting. *Water Resour Res*, 32,8, 2591-2596.
 - 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 applications. *Environ Modell Softw*, 15, 101-124.
 - Maier, H.R., Jain, A., Dandy, G.C., and Sudheer, K.P., 2010. Methods used for the development of neural networks for the prediction of water resource variables in river systems: current status and future directions. *Environ Model Softw*, 25,8, 891-909.
 - Ranjithan, S., Eheart, J.W., and Garrett, J.H., 1993. Neural network-based screening for groundwater reclamation under uncertainty. *Water Resour Res*, 29,3, 563-574.
 - Ray, C., and Klindworth, K.K., 2000. Neural networks for agricultural vulnerability assessment of rural private wells. *J Hydrol Eng*, 5,2, 162-171.
 - Razavi, S., and Tolson, B.A., 2011. A new formulation for feed forward neural networks. *Neural Netw IEEE Trans*, 22,10, 1588-1598.
 - Rumelhart, D.E., Hinton, G.R., and Williams, R.J., 1986. Learning internal representations by error propagation. In: Rumelhart, D.E., David, E., (Eds.), *Parallel Distributed Processing*. MIT Press, Massachusetts, 318-362.
 - Samani, N., Gohari-Moghadam, M., and

- Safavi, A.A., 2007. A simple neural network model for the determination of aquifer parameters. *J Hydrol*, 340,1-2, 1-11.
- Singh, R.M., and Datta, B., 2007. Artificial neural network modeling for identification of unknown pollution sources in groundwater with partially missing concentration observation data. *Water Resour Manage*, 21, 557-572.
 - Theis, C.V., 1935. The relationship between the lowering of the piezometric surface and the rate and duration of discharge of a well using ground-water storage. *Trans Am Geophys Union*, 16, 519-524.
 - Todd, D.K., and Mays, L.W., 2005. *Groundwater Hydrology*. Wiley, New York.
 - Walton, W.C., 1962. Leaky artesian aquifer conditions in Illinois. *Illinois State Water Survey, Illinois*.
 - Wu, C.L., Chau, K.W., and Li, Y.S., 2009. Predicting monthly streamflow using data-driven models coupled with data-preprocessing techniques. *Water Resour Res*, 45, W08432.
 - Wu, W., Dandy, G.C., and Maier, H.R., 2014. Protocol for developing ANN models and its application to the assessment of the quality of the ANN model development process in drinking water quality modeling. *Environ Modell Softw*, 54, 108-127.