

طراحی دو شبکه عصبی مصنوعی برای تعیین متغیرهای آبخوان محبوس نشتی

طاهره آذری^۱ و نوذر سامانی^{۲*}

^۱دکتر، گروه علوم زمین، دانشکده علوم، دانشگاه شیراز، شیراز، ایران
^۲استاد، گروه علوم زمین، دانشکده علوم، دانشگاه شیراز، شیراز، ایران

تاریخ دریافت: ۱۳۹۳/۰۳/۲۰ تاریخ پذیرش: ۱۳۹۴/۰۳/۳۰

چکیده

در سال‌های اخیر، شبکه‌های عصبی مصنوعی (Artificial Neural Networks - ANNs) به‌عنوان جایگزین روش‌های انطباق منحنی تیپ (Type curve matching techniques) برای تعیین متغیرهای آبخوان محبوس نشتی (leaky confined aquifer) طراحی شده است. نشی آب به آبخوان یا از لایه نیمه‌تراوا و یا از آب ذخیره شده در لایه نیمه‌تراوا منشأ می‌گیرد. توابع چاه (well functions) مربوط به آبخوان‌های نشتی با این دو سازوکار نشی از لایه نیمه‌تراوا به این دو شبکه آموزش داده شده است. با اعمال روش تجزیه مؤلفه اصلی (Principal Component Analysis - PCA) بر مجموعه داده‌های آموزش، توپولوژی هر دو شبکه کاهش و بازدهی آنها به‌طور قابل ملاحظه‌ای افزایش داده شد. بر خلاف شبکه‌های موجود، توپولوژی شبکه‌های طراحی شده به شمار داده‌های افت-زمان آزمون پمپاژ وابسته نیست و ساختار آن به ترتیب با ۲، ۱۰، ۲ و ۱۰ نرون در لایه‌های ورودی، پنهان و خروجی (۲×۱۰×۲) ثابت است. شبکه‌ها با دریافت داده‌های آزمون پمپاژ، مختصات نقطه انطباق (match point coordinates) را تولید می‌کنند. مختصات نقطه انطباق با حل‌های تحلیلی (Hantush & Jacob (1955) و Hantush (1960) ترکیب می‌شود و مقادیر متغیرهای آبخوان به دست می‌آید. عملکرد دو شبکه با داده‌های سه آزمون پمپاژ واقعی ارزیابی و دقت آنها با روش‌های انطباق منحنی تیپ مقایسه شده است. شبکه‌های پیشنهادی به عنوان یک روش جایگزین دقیق‌تر نسبت به شبکه عصبی مصنوعی پیشین و انطباق منحنی تیپ برای محاسبه متغیرهای آبخوان نشتی توصیه می‌شود.

کلیدواژه‌ها: برآورد متغیر آبخوان، لایه نیمه‌تراوا، شبکه عصبی مصنوعی، تجزیه مؤلفه اصلی (PCA)، الگوریتم آموزش لوبنرگ-مارکوآرت (LM).

E-mail: samani@susc.ac.ir

*نویسنده مسئول: نوذر سامانی

۱- پیش‌نویس

اگر سطح ایستابی و پتانسیومتری در تعادل باشند نشی آب از لایه محبوس کننده نیمه‌تراوا که روی آبخوان محبوس قرار گرفته است، زمانی رخ می‌دهد که آبخوان پمپاژ شود. این نشی ممکن است از راه جریان در عرض لایه محبوس کننده (لایه نیمه‌تراوا)، از آبخوان بالایی و یا از راه رهاسازی آب از ذخیره لایه نیمه‌تراوا صورت بگیرد (شکل ۱). این آبخوان‌ها به ترتیب به عنوان آبخوان‌های "نوع a" و "نوع b" تعریف شده‌اند. جریان آب در چنین آبخوان‌های نشتی از معادلات زیر پیروی می‌کند:

برای آبخوان نوع a (Hantush & Jacob, 1955):

$$\frac{\partial^2 s}{\partial r^2} + \frac{1}{r} \frac{\partial s}{\partial r} - \frac{K's}{Tb'} = \frac{S}{T} \frac{\partial s}{\partial t} \quad (1)$$

برای آبخوان نوع b (Hantush, 1960):

$$\frac{\partial^2 s}{\partial r^2} + \frac{1}{r} \frac{\partial s}{\partial r} + \frac{K'\partial s}{T\partial z} = \frac{S}{T} \frac{\partial s}{\partial t} \quad (2)$$

که $s(L)$ مقدار افت اندازه‌گیری شده در زمان t (T) در یک چاه مشاهده‌ای در فاصله r (L) از چاه پمپاژ، T (L^2T^{-1}) قابلیت انتقال آبخوان (transmissibility)، S ضریب ذخیره آبخوان (storage coefficient)، K' (LT^{-1})، T' (L^2T^{-1}) و b' به ترتیب هدایت هیدرولیکی (hydraulic conductivity)، قابلیت انتقال و ستبرای لایه نیمه‌تراوا هستند. توجه شود که عبارت سوم سمت چپ معادلات ۱ و ۲ بیان‌کننده نشی از لایه نیمه‌تراوا در آبخوان است. Hantush & Jacob (1955) معادله ۱ را با در نظر گرفتن شرایط اولیه و مرزی مناسب حل کردند و یک راه حل تحلیلی برای افت در چاه مشاهده‌ای ناشی از پمپاژ چاهی با نفوذ کامل در آبخوان نوع a به دست آوردند:

$$s = \frac{Q}{4\pi T} W(u, \frac{r}{B}) \quad (3)$$

$$w(u, \frac{r}{B}) = \int_u^\infty \frac{1}{y} \exp(-y - \frac{r^2}{4B^2y}) dy \quad (4)$$

$$u = \frac{r^2 S}{4Tt} \quad (5)$$

$$\frac{r}{B} = \frac{r}{\sqrt{T/(K'/b')}} \quad (6)$$

نرخ پمپاژ (pumping rate) Q (L^3/T) در $W(u, r/B)$ نمودار Walton (1960) برابر I/u را رسم و یک گروه از منحنی‌های تیپ را که هر کدام مقدار r/B مجزایی دارند، ایجاد کرد که در شکل ۲ نشان داده شده است.

Hantush (1960) معادله ۲ مربوط به آبخوان نوع b را حل کرد و تابع چاه این آبخوان را به صورت زیر به دست آورد:

$$S = \frac{Q}{4\pi T} W(u, \psi) \quad (7)$$

که در آن:

$$u = \frac{r^2 S}{4Tt} \quad (8)$$

$$\psi = \frac{r}{4} \sqrt{\frac{S'K'}{TSb'}} \quad (9)$$

$$W(u, \psi) = \int_u^\infty \frac{e^{-y}}{y} \operatorname{erfc} \left(\frac{\psi \sqrt{u}}{\sqrt{y(y-u)}} \right) dy \quad (10)$$

S' ضریب ذخیره لایه نیمه‌تراوا و $\operatorname{erfc}(x)$ تابع خطای مکمل (complementary error function) است که با معادله زیر تعریف می‌شود:

$$\operatorname{erfc}(x) = 1 - \operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_x^\infty \exp(-y^2) dy \quad (11)$$

Hantush (1961) نمودار $W(u, \psi)$ در برابر I/u را رسم کرد و مقادیرشان را به صورت جدولی درآورد. شکل ۳ گروهی از منحنی‌های تیپ آبخوان نوع b را که هر کدام مقدار ψ مجزایی دارند، نشان می‌دهد.

برای تعیین مقادیر متغیرهای آبخوان (T, S, K', S')، داده‌های افت-زمان مربوط به یک آزمون پمپاژ روی کاغذ لگاریتمی با مقیاس همانند منحنی‌های تیپ رسم می‌شود. منحنی افت-زمان روی منحنی تیپ قرار داده می‌شود و به گونه‌ای که محورهای مختصات هر دو منحنی با هم موازی باشد و بیشتر نقاط داده‌های مشاهده‌ای روی یکی از منحنی‌های تیپ قرار گیرد. در این حالت یک نقطه

Lin & Chen (2006) و Samani et al. (2007) شبکه‌های پیشنهادی خود را با فرض انطباق کامل میان منحنی افت-زمان و منحنی تیپ طراحی کردند. بر این اساس آنها از ورودی- خروجی شبکه عصبی آموزش داده شده $[W(u_m), \log(1/u_m)]$ و مختصات نقطه افت-زمان مربوط به رکورد اول (s_1, t_2) به عنوان مختصات نقطه انطباق استفاده کردند. ولی از آنجایی که محیط متخلخل طبیعی معمولاً ناهمگن و آیزوتروپ است و داده‌های افت-زمان اولیه به‌ویژه رکورد اول به دلیل ناهمگنی آبخوان و نوسان نرخ پمپاژ و خطاهای احتمالی در زمان ثبت داده متغیر است. از این نظر، معمولاً انتخاب رکورد اول از داده‌های افت-زمان به‌عنوان نقطه انطباق برای برآورد متغیرهای آبخوان مناسب نیست (Toth, 1966). برای حل این مسئله Lin et al. (2010) یک شبکه عصبی اصلاح شده (modified ANN) و روش (PCA-ANN) را پیشنهاد دادند. آنها شبکه‌ها را به‌ازای هر $\log(1/u_m)$ به همراه همه رکوردهای افت هر مجموعه داده آزمون پمپاژ آموزش دادند و آن شبکه آموزش یافته‌ای که کمترین ریشه میانگین مربع خطای نسبی (Relative Root Mean Square Error - RRMSE) را برای بردار خروجی تولید می‌کند به عنوان شبکه آموزش یافته بهینه، برای تعیین متغیرهای آبخوان در مرحله درستی‌سنجی (verification stage) انتخاب کردند. گر چه خطای ناشی از انتخاب رکورد اول با روش پیشنهادی تصحیح می‌شود، ولی شبکه باید برای هر مجموعه مجزا از داده‌های آزمون پمپاژ آموزش داده شود؛ بنابراین با این روش توپولوژی شبکه به تعداد رکوردها در آزمون پمپاژ بستگی دارد و ثابت نخواهد بود. برای برطرف کردن این مسئله، این روش تنها در مرحله راستی‌آزمایی این پژوهش به کار گرفته شد. در این پژوهش دو شبکه عصبی مصنوعی از نوع پرسپترون چند لایه به همراه الگوریتم آموزش LM طراحی شده است تا متغیرهای آبخوان‌های محبوس نشستی نوع a و b که در بخش قبلی تعریف شده‌اند تعیین شوند. در آبخوان نوع a تابع چاه (Hantush & Jacob, 1955) (معادله ۴) و در آبخوان نوع b تابع چاه (Hantush, 1960) (معادله ۱۰) به شبکه عصبی مصنوعی آموزش داده شد. همچنین پیش از ساخت شبکه‌ها، PCA بر مجموعه داده‌های آموزش اعمال شد تا ابعاد آنها کاهش یابد و ثابت شود. دقت این شبکه‌ها با ۱۰۰۰۰۰ مجموعه داده افت-زمان سنتز شده آزمایش شد. در پایان عملکرد این شبکه‌ها با استفاده از سه مجموعه داده پمپاژ واقعی ارزیابی شد و نتایج حاصل از آنها با روش انطباق منحنی تیپ مورد مقایسه قرار گرفت. به نظر می‌رسد که این شبکه‌ها جایگزین کارآمد، دقیق و مناسب‌تری برای تعیین متغیرهای هر دو نوع آبخوان محبوس نشستی مورد مطالعه باشند.

۲- شبکه‌های پرسپترون چند لایه (MLPNs)

یک MLP عبارت است از یک شبکه عصبی پیشخور (feed-forward neural network) که شامل چند لایه و چند نورون در هر لایه است که مجموعه داده‌های ورودی را به خروجی‌های متناسب مرتبط می‌سازد. MLP شامل یک لایه ورودی (input-layer)، یک یا چند لایه پنهان (hidden-layer) و یک لایه خروجی (output-layer) است که هر لایه به لایه بعدی متصل است (Hsu et al., 1995). هر نورون یک عنصر پردازشگر است که یک تابع فعال‌سازی (activation function) دارد. شکل ۴ ساختار یک شبکه MLP سه لایه را نشان می‌دهد. قانون یادگیری بسیار رایج برای آموزش شبکه‌های MLP الگوریتم پس انتشار (back propagation algorithm) است. این بدین معنی است که سیگنال ورودی در شبکه از یک لایه به لایه بعدی در جهت رو به جلو منتشر می‌شود و یک سیگنال خروجی از ترکیب خطی ورودی‌ها در وزنشان به دست می‌آید. سپس سیگنال خروجی در تابع فعال‌سازی غیرخطی قرار می‌گیرد (Haykin, 1999). تابع فعال‌سازی انواع مختلفی دارد از جمله: تابع سیگموئید (sigmoid)، تابع هیپربولیک تانژانت (hyperbolic tangent)، تابع گاوسی (Gaussian) و خطی (linear).

انطباق انتخاب می‌شود. سپس مختصات نقطه انطباق روی هر دو منحنی $[1/u_m, W(u, \psi)_m, s_m, t_m]$ یا $[1/u_m, W(u, r/B)_m, s_m, t_m]$ ثبت می‌شود. سپس با استفاده از مقادیر مختصات نقطه انطباق و معادلات ۳ تا ۶ یا معادلات ۷ تا ۱۰ متغیرهای آبخوان تعیین می‌شوند.

اگر چه روش انطباق منحنی تیپ از سال ۱۹۳۵ (زمانی که Theis این روش را برای تعیین متغیرهای آبخوان محبوس پیشنهاد داد) توسط هیدروژئولوژیست‌ها استفاده می‌شده است ولی به دلیل خطاهای فردی و گرافیکی روش انطباق بحث‌برانگیز است. در سال‌های اخیر برخی روش‌های مناسب بر پایه شبکه‌های عصبی مصنوعی به‌عنوان یک روش جایگزین برای تعیین متغیرهای آبخوان گسترش یافته‌اند (Aziz & Wong, 1992; Balkhair, 2002; Garcia & Shigidi, 2006; Lin & Chen, 2005, 2006; Samani et al., 2007; Lin et al., 2010; Ch & Mathur, 2012).

روش شبکه عصبی مصنوعی اولین بار توسط McCulloch & Pitts (1943) پیشنهاد شد. شبکه عصبی مصنوعی، گروهی از عناصر پردازشگر ساده (نورون مصنوعی) مرتبط به هم است که قابل قیاس با شبکه نورون‌ها در مغز انسان است. شبکه عصبی مصنوعی یک پردازشگر موازی است که از یک مدل ریاضی برای ارزیابی اطلاعات استفاده می‌کند. این روش می‌تواند از طریق فرایند آموزش، روابط غیرخطی پیچیده میان ورودی‌ها و خروجی‌های مطلوب را که به آسانی با روش‌های مرسوم تجزیه نمی‌شوند مدل‌سازی کند. به دلیل این ویژگی، روش شبکه عصبی مصنوعی با موفقیت در مسائل مختلف آب‌شناسی استفاده شده است برای نمونه: شناسایی ویژگی‌های زیرسطحی (Pezeshk et al., 1996; Gangopadhyay et al., 1999); پیش‌بینی سطح آب زیرزمینی (Coulibaly et al., 2001; Coppola et al., 2003); آلودگی آب زیرزمینی (Dadaser & Cengiz, 2013); پاک‌سازی آب زیرزمینی (Fijani et al., 2013); پاک‌سازی آب زیرزمینی (Ranjithan et al., 1993); (Chang et al., 2012).

Lin & Chen (2005) یک روش شبکه عصبی مصنوعی را برای برآورد متغیرهای آبخوان بر پایه ترکیب شبکه تابع پایه شعاعی (Radial Basis Function Network - RBFN) و حل تحلیلی (Hantush & Jacob (1955) پیشنهاد دادند تا بهترین نقطه انطباق را برای تعیین متغیرهای آبخوان‌های محبوس نشستی حالت a به دست آورند. همچنین Lin & Chen (2006) ترکیبی از روش شبکه عصبی و حل تحلیلی (Theis (1935) را برای آبخوان‌های محبوس غیرنشستی پیشنهاد دادند. گر چه در مقایسه با روش (Aziz & Wong (1992) متغیرهای آبخوان با دقت و سرعت بیشتری تعیین شد، ولی هنوز این مشکل که با افزایش تعداد داده‌های افت-زمان، ابعاد شبکه بزرگ‌تر می‌شد برطرف نشده بود. همچنین این شبکه باید برای هر مجموعه داده آزمون پمپاژ آموزش داده و آزمایش می‌شد. محدودیت‌های بیان شده روش (Lin & Chen (2006) سبب شد (Samani et al. (2007) یک شبکه عصبی مصنوعی ساده را پیشنهاد دهند که در آن الگوریتم لوئرگ-مارکوآرت (LM: Levenberg-Marquardt) جایگزین الگوریتم کاهش شیب (gradient descent algorithm) شده و با اعمال روش تجزیه مؤلفه‌های اصلی بر مجموعه داده‌های آموزش، ابعاد شبکه کاهش و مستقل از تعداد داده‌های افت-زمان شد. در پی آن (Lin et al. (2010) روش PCA را بر الگوهای آموزش و آزمایش اعمال کردند تا شبکه‌ای را برای برآورد متغیرهای آبخوان‌های آیزوتروپ تدوین کنند.

مرحله آموزش و آزمایش، شبکه طراحی شده می‌تواند برای تشخیص الگو، رده‌بندی و تقریب تابع استفاده شود. بنابراین در این پژوهش دو شبکه عصبی از نوع پرسپترون چندلایه (MLPNs) به همراه الگوریتم آموزش LM طراحی شده است تا مختصات نقطه انطباق را برای آبخوان‌های مجبوس نشتی حالت‌های a و b تعیین کند.

۳- تجزیه مؤلفه‌های اصلی (PCA)

PCA که در سال ۱۹۰۱ توسط کارل پیرسون (Chris & Xiaofeng, 2004) پیشنهاد شده بود ابزاری برای گویا کردن و شناسایی همبستگی موجود میان شمار زیادی از متغیرها از راه کاهش ابعاد مجموعه داده‌های حجیم است. PCA از دید ریاضی به عنوان یک تبدیل خطی متعامد (orthogonal linear transformation) تعریف می‌شود که داده‌ها را به سامانه مختصات جدید تبدیل می‌کند؛ به گونه‌ای که بیشترین واریانس داده‌ها را به مختصات اول نسبت می‌دهد و مؤلفه اصلی اول (first PC) را ایجاد می‌کند. همچنین بیشترین واریانس دوم را به مختصات دوم اختصاص می‌دهد و مؤلفه اصلی دوم (second PC) را می‌سازد. بنابراین این روند با همین ترتیب پیش می‌رود تا مؤلفه‌ای که کوچک‌ترین مقدار واریانس را شامل می‌شود ایجاد شود. به عبارت دیگر هر مؤلفه شامل بیشترین مقدار واریانس متغیرهای مشاهده‌ای می‌شود که برای مؤلفه‌های پیشین در نظر گرفته نشده است و با همه مؤلفه‌های پیشین غیرمرتبط است. وقتی تجزیه کامل شد مؤلفه‌های حاصل، درجه متفاوتی از همبستگی با متغیرهای مشاهده‌ای را نشان خواهند داد ولی به‌طور کامل غیر مرتبط با یکدیگر هستند. با در نظر گرفتن یک کمینه درصد واریانس (minimum fraction variance) معین، می‌توان مؤلفه‌های اصلی که سهم کمتری از این مقدار را نسبت به واریانس کل در مجموعه داده‌ها دارند حذف کرد (Samani et al., 2007) و بدین ترتیب ابعاد مجموعه داده‌ها، بدون اینکه هیچ اطلاعاتی از دست برود کاهش داده می‌شود.

۴- طراحی شبکه (Network design)

طراحی شبکه شامل چهار مرحله است: تولید الگوهای آموزش، ساخت شبکه، آزمایش شبکه با مجموعه داده‌های سنتز شده و راستی‌آزمایی شبکه با داده‌های واقعی.

۴-۱. تولید الگوهای ورودی آموزش

برای تولید الگوهای آموزش برای شبکه، ابتدا مقادیر $\log(1/u_m)$ در محدوده $7/10 - 0/5$ ، مقادیر $(r/B)_m$ در محدوده $2/5 - 0/0$ و مقادیر $(\psi)_m$ در محدوده $10/10 - 0/0$ همان‌گونه که در شکل‌های ۲ و ۳ دیده می‌شود به‌عنوان اهداف خروجی شبکه عصبی انتخاب شدند. برای هر دو نوع آبخوان ۵۱۲۰۰ مجموعه بردار ورودی آموزش با انتخاب بازه‌های $0/0073$ ، $0/0052$ و $0/0241$ به ترتیب برای $\log(1/u_m)$ ، $(r/B)_m$ و $(\psi)_m$ تولید شدند. سپس برای همه مجموعه‌های $[\log(1/u_m), (r/B)_m]$ و $[\log(1/u_m), (\psi)_m]$ توابع چاه $W(u, r/B)$ و $W(u, \psi)$ به ترتیب با استفاده از معادلات ۴ و ۱۰ به دست آمد. در مرحله بعد الگوهای آموزش Z_i با معادلات زیر با روش همانند روش Lin & Chen (2005) و Samani et al. (2007) تولید شد (شکل‌های ۶ و ۷):

$$Z_i = \log \left[\frac{W(u_m t_1 / t_{i+1}, (r/B)_m)}{W(u_m, (r/B)_m)} \right] \quad (18)$$

برای آبخوان نوع a که در آن $(S' = 0.0, K' > 0.0)$ و

$$Z_i = \log \left[\frac{W(u_m t_1 / t_{i+1}, (\psi)_m)}{W(u_m, (\psi)_m)} \right] \quad (19)$$

برای آبخوان نوع b که در آن $(S' > 0.0, K' > 0.0)$.

اندیس m به نقطه انطباق اشاره می‌کند و $i = 1, 2, \dots, N-1$ که N تعداد داده‌های ایت-زمان است.

بنابراین Z_i مؤلفه‌های ورودی و $[\log(1/u_m), (r/B)_m]$ و $[\log(1/u_m), (\psi)_m]$ به ترتیب مؤلفه‌های خروجی شبکه آبخوان‌های نشتی نوع a و

در شبکه‌های عصبی طراحی شده، از تابع هیپربولیک تانژانت یا (tansig) $[f(x) = (1 - e^{-2x}) / (1 + e^{-2x})]$ برای لایه‌های ورودی و پنهان و تابع خطی (purelin) $[f(x) = x, \text{ for all } x]$ برای لایه خروجی استفاده شده است (شکل ۵).

رابطه میان الگوهای ورودی و خروجی در یک شبکه MLP به همراه الگوریتم پس انتشار می‌تواند به‌صورت زیر بیان شود (Ajmera & Rastogi, 2008):

هر نورون ورودی در لایه ورودی، سیگنال ورودی $[Z_i (i = 1, 2, \dots, n)]$ را دریافت می‌کند و این سیگنال را به همه نورون‌ها در لایه بعدی (نورون‌های پنهان) انتقال می‌دهد. هر نورون پنهان $[h_j (j = 1, 2, \dots, m)]$ مجموعه‌ای از سیگنال‌های ورودی وزن‌دار را به‌عنوان ورودی خالص (net input) دریافت می‌کند.

$$net_1(k) = b_1(k) + \sum_{i=1}^n Z_i(k) w_{1i}(k) \quad (12)$$

با استفاده از تابع فعال‌سازی (e.g., tansig) خروجی لایه پنهان تعیین می‌شود و به همه نورون‌ها در لایه خروجی منتقل می‌شود. k در فرمول‌ها تعداد تکرار (iteration number) است.

$$h_j(k) = f_h(net_1(k)) \quad (13)$$

هر نورون خروجی $[y_j (j = 1, 2, \dots, r)]$ ورودی‌های وزن‌دار شده را با هم جمع می‌کند.

$$net_j(k) = b_j(k) + \sum_{i=1}^m h_i(k) w_{ji}(k) \quad (14)$$

و با اعمال تابع فعال‌سازی خطی (purelin) سیگنال‌های خروجی را محاسبه می‌کند. $\hat{y}_j(k) = f_o(net_j(k))$ (15)

هر نورون خروجی، الگوی هدف (target pattern) یعنی (y_j) را با الگوی محاسباتی (calculated pattern) یعنی (\hat{y}_j) مقایسه و اختلاف میان آنها را محاسبه می‌کند. یک شبکه عصبی مصنوعی باید تا جایی آموزش داده شود که وزن‌ها (weights) و بایاس‌های (biases) هر نورون تنظیم شود و تابع هدف (objective function - F) به کمترین میزان قابل قبول برسد:

$$F = \frac{1}{2} \left[\sum_{j=1}^r (y_j(k) - \hat{y}_j(k))^2 \right] \quad (16)$$

به بیان دیگر، فرایند آموزش آن قدر ادامه می‌یابد و مراحل بالا آن قدر تکرار می‌شود تا F به کمترین مقدار قابل قبول برسد؛ در این صورت فرایند آموزش متوقف می‌شود. در این پژوهش آموزش شبکه به وسیله الگوریتم آموزش پس انتشار خطا و روش بهینه‌سازی لونیبرگ-مارکوارت (LM) انجام شده است. الگوریتم LM الگوریتم بهینه‌سازی بسیار مؤثری است و بسیاری از پژوهشگران از این الگوریتم در مسائل مختلف آب زیرزمینی با موفقیت استفاده کرده‌اند (Toth et al., 2000; Coulibaly et al., 2001; Daliakopoulos et al., 2005; Samani et al., 2007). در این الگوریتم تابع تنظیم‌کننده وزن‌ها $w(k+1)$ با استفاده از فرمول زیر برآورد می‌شود (ASCE Task Committee on Application of Artificial Neural Networks, 2000):

$$w(k+1) = w(k) - [J^T \times J + \mu I]^{-1} \times J^T \times e \quad (17)$$

که در این معادله w عبارت است از وزن شبکه عصبی، J ماتریس ژاکوبی (Jacobin matrix) معیار عملکرد (performance criteria) شبکه است که باید کمینه شود، μ نرخ یادگیری (learning rate)، k شمار تکرار در طول فرایند بهینه‌سازی، e بردار مقدار باقیمانده و I ماتریس همانی (unit matrix) است. از دید تجربی تعداد بهینه نورون‌ها و لایه‌های پنهان بر پایه پیچیدگی مسئله مدل‌سازی و اهداف پژوهشگر از جمله معیار همگرایی (convergence criterion)، با روش سعی و خطا تعیین می‌شوند. پس از اینکه فرایند آموزش کامل شد و وزن‌ها و بایاس‌ها میان همه اتصالات نورون‌ها در لایه‌های مختلف تنظیم شد، با استفاده از الگوهای آزمایش (test patterns) عملکرد شبکه عصبی ارزیابی می‌شود. بهترین نتیجه از عملکرد شبکه زمانی حاصل می‌شود که شبکه طراحی شده کوچک‌ترین خطای پیش‌بینی را روی مجموعه داده‌های آزمایش که در مرحله آموزش استفاده نشده‌اند ایجاد کند. پس از

۴-۳. آزمایش شبکه‌ها

دقت شبکه‌های آموزش دیده با ۱۰۰۰۰۰ مجموعه داده افت- زمان سنتز شده آزمایش شد. این داده‌های سنتز شده برای آبخوان نوع a از ترکیب مقادیر ایده‌آل و منطقی $S, T, r/B$ به ترتیب در محدوده 10^{-2} تا 10^6 متر مربع در روز، 10^{-6} تا 10^0 و 10^0 تا 10^5 با استفاده از معادلات ۳ تا ۶ ساخته شدند. به طور مشابه الگوهای آزمایش برای آبخوان نوع b هم از ترکیب مقادیر ایده‌آل $S, T, r/B$ به ترتیب در محدوده 10^2 تا 10^6 متر مربع در روز، 10^{-2} تا 10^6 و 10^0 تا 10^0 با استفاده از معادلات ۷ تا ۱۰ تولید شدند. اندازه Q در معادلات ۳ و ۷ می‌تواند هر مقدار منطقی مانند ۵ لیتر در ثانیه (۴۳۲ متر مکعب در روز) باشد. این داده‌های سنتز شده پس از اینکه به نسبت‌های افت تبدیل شدند (Lin & Chen, 2006) و تجزیه مؤلفه اصلی بر آنها اعمال شد به‌عنوان بردار ورودی شبکه‌ها استفاده می‌شوند:

$$PCA[\log(\frac{s_i+1}{s_i})] \quad (22)$$

که s_i افت ثبت شده در زمان t_i است. دقت شود که معادله ۲۲ اکنون متناسب با معادله ۱۸ یا ۱۹ است که ورودی شبکه در مرحله آزمایش را تشکیل می‌دهد. شکل ۹ 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 شد) را دریافت می‌کنند و مقادیر $\log(I/u)$ و r/B و ψ را به دست می‌دهند که به K', S, T و $K'S'$ تبدیل می‌شوند. نمودارهای سمت چپ در شکل ۱۰ نمودارهای پراکنش (scatter plots) و بهترین خط تناسب (best-fitted line) میان متغیرهای هدف و محاسبه شده $(T, S, r/B)$ توسط شبکه آموزش داده شده آبخوان نوع a و نمودارهای سمت راست نمودارهای پراکنش و بهترین خط تناسب میان متغیرهای هدف و محاسبه شده (T, S, ψ) توسط شبکه آموزش داده شده آبخوان نوع b را نشان می‌دهد. همان‌گونه که در این شکل‌ها نشان داده شده است این شبکه‌های پیشنهادی می‌توانند متغیرهای آبخوان را با دقت بالایی در محدوده گسترده‌ای از مقادیر محاسبه کنند. در همه نمودارها مقدار R^2 مساوی یک و مقدار RRMSE بسیار نزدیک به صفر است (جدول ۶) که این موضوع نشان‌دهنده دقت بالای پیش‌بینی شبکه‌های طراحی شده است.

۴-۴. راستی آزمایشی شبکه‌ها

در مرحله راستی آزمایشی از روش همانند مرحله آزمایش شبکه استفاده می‌شود؛ با این تفاوت که در این مرحله بردار ورودی یک مجموعه داده افت- زمان آزمون پمپاژ واقعی است. در این پژوهش، سه مجموعه داده آزمون پمپاژ استفاده شده است. مجموعه اول داده‌ها از Todd & Mays (2005)، مجموعه دوم از Walton (1960) و مجموعه سوم از Neuman & Witherspoon (1972) گرفته شده است (جدول‌های ۹ و ۱۰). روش PCA بر هر سه مجموعه داده اعمال شد و مجموعه داده‌های کاهش یافته به‌عنوان بردارهای ورودی به هر یک از شبکه‌های طراحی شده وارد شد تا مقادیر مختصات نقطه انطباق $[1/u_m, W(u, r/B)_m]$ یا $[1/u_m, W(u, \psi)_m]$ تعیین شوند. با جایگزین کردن این مقادیر در توابع چاه مربوطه (معادلات ۳، ۵ و ۶ یا معادلات ۷ تا ۹) و در نظر گرفتن داده افت- زمان اول ($s_m = s_j, t_m = t_j$) که توسط Lin & Chen (2005) پیشنهاد شده بود مقادیر متغیرهای آبخوان تعیین شد. برای برطرف کردن خطای ناشی از در نظر گرفتن رکورد اول از داده‌های افت- زمان، نقطه انطباق برای همه رکوردهای افت- زمان به شرح زیر تنظیم شد.

$$\hat{y}_1 = \log(\frac{1}{u_j}) = \log(\frac{1}{u_m} \frac{t_j}{t_1}), j = 1, 2, \dots, N \quad (23)$$

$$(\frac{1}{u_j}) = (\frac{1}{u_m} \frac{t_j}{t_1}) = 10^{\hat{y}_1} \quad (24)$$

$$W[u_j, (r/B)_m] = W(\frac{1}{10^{\hat{y}_1}}, \hat{y}_2) \quad (25) \text{ آبخوان نوع a}$$

b خواهند بود. پیش از اینکه مجموعه الگوهای ورودی آموزش تولید شده Z_j که دارای $[(N-1) \times (51200)]$ عنصر است به‌عنوان بردار ورودی به شبکه عصبی مصنوعی استفاده شوند، باید بهنجارسازی شوند و سپس روش PCA (همان‌گونه که توسط Samani et al. (2007) پیشنهاد شده است) بر آنها اعمال شود. جدول ۱ و ۲ متغیرهای PCA الگوهای آموزش دو نوع آبخوان نشستی را نشان می‌دهد. مؤلفه‌های اصلی با در نظر گرفتن کمترین درصد واریانس 0.005 (0.5%) استخراج شدند. همان‌گونه که دیده می‌شود، مؤلفه‌های اصلی اول و دوم در مجموع به ترتیب $99/997$ درصد و $99/996$ درصد از واریانس کل داده‌های آموزش آبخوان‌های نوع a و b را شامل می‌شوند. واریانس محاسبه شده توسط مؤلفه سوم کوچک‌تر از کمترین درصد واریانس است (برای نمونه در آبخوان نوع a $0.033/0.033$ درصد > 0.5 درصد) بنابراین می‌توان از آن صرف نظر کرد. این موضوع نشان می‌دهد که عناصر بردار ورودی آموزش به ۲ عنصر کاهش می‌یابد؛ به این ترتیب Z_j دارای $[(2) \times (51200)]$ عنصر است. تعداد نورون‌ها در لایه ورودی شبکه‌ها می‌تواند به ۲ نورون (به جای $N-1$ نورون در شبکه (Lin & Chen (2006) کاهش و ثابت شود.

۴-۲. ساخت شبکه‌ها

دو شبکه MLP سه لایه طراحی شدند تا مختصات نقطه انطباق را تولید کنند $\hat{y}_2 = (\frac{r}{B})_m$ و $\hat{y}_1 = \log(\frac{1}{u_m})$ و $\hat{y}_1 = \log(\frac{1}{u_m})$ برای آبخوان نوع a و $\hat{y}_2 = (\frac{r}{B})_m$ و $\hat{y}_1 = \log(\frac{1}{u_m})$ برای آبخوان نوع b. ابتدا الگوهای ورودی آموزش مطابق با معادلات ۱۸ و ۱۹ تولید و سپس تجزیه مؤلفه‌های اصلی بر آنها اعمال شد. آنگاه طبق روش شرح داده شده در بخش ۲ شبکه‌ها آموزش داده شد. شبکه آموزش دیده برای هر دو نوع آبخوان با توپولوژی بهینه $(2 \times 10 \times 2)$ تثبیت شد. 10^2 و 10^0 به ترتیب به تعداد نورون در لایه ورودی، پنهان و خروجی اشاره می‌کند. متغیرهای به کار گرفته شده در هنگام فرایند آموزش در جدول ۳ نشان داده شده‌اند.

دو معیار زیر برای ارزیابی دقت مختصات نقطه انطباق (هدف شبکه) به کار گرفته شد:

الف) ریشه میانگین مربع خطای نسبی (RRMSE) هدف برآورد شده:

$$RRMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (\frac{\hat{y}_j - y_j}{y_j})^2} \quad (20)$$

که \hat{y}_j هدف شبیه‌سازی شده یا محاسبه شده توسط شبکه، y_j هدف واقعی و n تعداد الگوهاست. کمترین مقدار RRMSE بیشترین دقت پیش‌بینی را نشان می‌دهد. $RRSME=0$ نشان‌دهنده دقت ۱۰۰ درصد است.


ب) ضریب تشخیص (R^2) (determination coefficient):

$$R^2 = 1 - \frac{\sum (y_j - \hat{y}_j)^2}{\sum y_j^2 - \frac{(\sum y_j)^2}{n}} \quad (21)$$

$R^2=1$ نشان‌دهنده ۱۰۰ درصد تناسب میان مقادیر خروجی شبکه و مقادیر هدف است. شکل ۸ ساختار شبکه (Lin & Chen (2005) و شبکه‌های پیشنهادی را نشان می‌دهد. به دلیل کاربرد PCA، ابعاد الگوهای ورودی شبکه‌های پیشنهادی به ۲ کاهش داده شد (برخلاف شبکه عصبی Lin & Chen که $N-1$ نورون دارد). همچنین این شبکه‌ها تنها با ۱۰ نورون در لایه پنهان آموزش داده شدند. جدول ۴ مقادیر هر دو معیار بیان شده به‌همراه ساختار شبکه و زمان مورد نیاز برای آموزش شبکه طراحی شده آبخوان نوع a را نشان می‌دهد و نتایج را با شبکه تابع پایه شعاعی (Lin & Chen (2005) برای مدل‌سازی مختصات نقطه انطباق آبخوان نوع a مقایسه می‌کند. مقایسه مقادیر R^2 و RRMSE و بازدهی بالاتر شبکه پیشنهادی را نسبت به شبکه (Lin & Chen (2005) نشان می‌دهد. این مزایا در بخش‌های بعدی با تفصیل بیشتری اثبات خواهند شد. جدول ۵ متغیرهای همانند شبکه مربوط به آبخوان نوع b را نشان می‌دهد که برای مقایسه نتایج آن شبکه همانندی وجود ندارد.

می‌دهند. در نتیجه با حفظ معیار همگرایی مورد نظر (دقت مطلوب آموزش شبکه) در حد 10^{-6} ابعاد لایه‌های ورودی و پنهان در هر دو شبکه به ترتیب به ۲ و ۱۰ کاهش یافت. بنابراین ساختار شبکه‌های طراحی شده برای هر دو نوع آبخوان محبوس نشتی صرف نظر از شمار رکوردهای داده‌های افت-زمان با توپولوژی $2 \times 10 \times 2$ ثابت شد. دقت شبکه‌های طراحی شده با 100000 مجموعه داده افت-زمان سنتز شده آزمایش شد. سرانجام عملکرد این شبکه‌ها با استفاده از سه مجموعه داده آزمون پمپاژ واقعی با روش انطباق منحنی تیپ مقایسه شد. به‌طور خلاصه، این شبکه‌های پیشنهادی نسبت‌های افت کاهش یافته را به‌عنوان ورودی دریافت کرده و مختصات نقطه انطباق مربوط به رکورد اول را به عنوان خروجی تولید می‌کنند. این خروجی با هر کدام از رکوردهای افت-زمان ترکیب می‌شود و متغیرهای آبخوان به دست می‌آیند. با استفاده از رکوردهای افت-زمان و هر مجموعه از متغیرهای آبخوان، رکوردهای افت تولید و با رکوردهای افت واقعی مقایسه می‌شوند و مقدار RRMSE افت برآورد شده، به دست می‌آید. متغیرهایی که کمترین مقدار RRMSE را ایجاد می‌کنند به‌عنوان دقیق‌ترین برآورد از مقادیر متغیرهای آبخوان انتخاب می‌شوند. شبکه‌های طراحی شده به عنوان یک روش جایگزین سریع، دقیق و با کاربرد آسان نسبت به روش‌های گرافیکی انطباق منحنی تیپ و شبکه‌های عصبی مصنوعی پیشین توصیه می‌شود که متغیرهای آبخوان محبوس نشتی با یا بدون ذخیره در لایه نیمه‌تراوا را به همراه مزایای زیر تعیین می‌کند:

- این شبکه‌ها از الگوریتم آموزش LM به‌جای الگوریتم کاهش شیب استفاده می‌کنند که دقت شبکه (Lin & Chen, 2005) را از 10^{-3} به 10^{-6} بهبود می‌دهد و همچنین مدت زمان لازم برای آموزش در هر دو نوع آبخوان محبوس نشتی را کاهش می‌دهد.
- با اعمال PCA، ساختار شبکه‌های طراحی شده با توپولوژی $2 \times 10 \times 2$ به‌جای $2 \times 1 \times N-1 \times N-1 \times 2$ در شبکه RBF (Lin & Chen, 2005) کاهش یافت و ثابت شد. این مسئله سبب کاهش بیشتر زمان آموزش می‌شود و ساختار شبکه‌های طراحی شده وابسته به تعداد داده‌های افت-زمان نخواهد بود.
- همچنین آزمایش شبکه‌های طراحی شده با 100000 داده سنتز شده و بررسی عملکرد شبکه با استفاده از سه مجموعه داده پمپاژ واقعی، توانایی تعمیم و قابلیت اطمینان بیشتر شبکه‌های پیشنهادی را اثبات می‌کند.
- در شبکه‌های طراحی شده خطای احتمالی ناشی از انتخاب نامناسب رکورد اول از داده‌های افت-زمان به‌عنوان نقطه انطباق وجود ندارد.



شکل ۱- آبخوان محبوس نشتی به همراه چاه پمپاژ کامل. در آبخوان محبوس نشتی نوع a، $S' = 0$ است.

$$W [u_j, (\psi)_m] = W \left(\frac{1}{10^{\hat{a}_1}}, \hat{y}_2 \right) \quad (26) \text{ آبخوان نوع b:}$$

$$s_m = s_1 \quad (27)$$

$$t_m = t_j \quad (28)$$

با جایگزین کردن این مقادیر در توابع چاه مربوطه (معادلات ۳، ۵، ۶ یا معادلات ۷ تا ۹) مقادیر متغیرهای آبخوان تعیین شدند. این داده افت $[I/u_j, W_j, S_j, t_j]$ که کمترین مقدار RRMSE را به دست می‌دهد به‌عنوان نقطه انطباق بهینه انتخاب می‌شود. این داده مقادیر متغیرهای آبخوان را با بیشترین دقت ممکن تعیین می‌کند.


آزمایش پمپاژ اول: این آزمایش در یک آبخوان محبوس نشتی با ستبرای ۱۴ فوت انجام شد که در آن یک چاه پمپاژ کامل با نرخ ثابت ۶۰۰ فوت مکعب بر دقیقه پمپاژ می‌شد. داده‌های افت-زمان در یک چاه مشاهده‌ای در فاصله ۴۰ فوتی از چاه پمپاژ ثبت شد. در این آبخوان، لایه نیمه‌تراوا محبوس‌کننده هیچ آبی را از ذخیره رها نمی‌کند ($S' = 0.0$). مقادیر متغیرهای آبخوان (T, S, K') با استفاده از شبکه طراحی شده تعیین و نتایج در جدول ۷ ارائه و با مقادیر حاصل از روش انطباق منحنی تیپ مقایسه شده است. مقادیر RRMSE دقت بیشتر مدل پیشنهادی را نشان می‌دهد (خطای حاصل از روش انطباق منحنی تیپ معادل ۲۶/۳٪ است در حالی که خطای شبکه پیشنهادی ۰/۰۱ درصد است). در این آزمون پمپاژ، رکورد هشتم از داده‌های افت-زمان که کمترین مقدار RRMSE را ایجاد کرد به‌عنوان نقطه انطباق بهینه انتخاب شد (شکل ۱۱).

آزمایش پمپاژ دوم: این آزمون پمپاژ در یک آبخوان محبوس نشتی انجام شد که در آن یک چاه کامل با نرخ ثابت ۳/۳۴۲ فوت مکعب بر دقیقه پمپاژ می‌شد. میزان ذخیره لایه نیمه‌تراوا مساوی صفر است ($S' = 0.0$). مقادیر متغیرهای آبخوان با استفاده از شبکه طراحی شده تعیین و نتایج آن در جدول ۷ ارائه و با مقادیر محاسبه شده با روش انطباق منحنی تیپ مقایسه شده است. همان‌گونه که دیده می‌شود، دقت مدل پیشنهادی بسیار بیشتر است؛ چرا که مقدار RRMSE حاصل از آن خیلی کوچک‌تر است (۰/۰۱ درصد در مقایسه با ۴۱/۴٪). در این آزمون پمپاژ رکورد سوم از داده افت-زمان به‌عنوان نقطه انطباق بهینه انتخاب شد (شکل ۱۱).


آزمایش پمپاژ سوم: در این آزمایش یک چاه کامل با نرخ ثابت پمپاژ ۱۰۰۰ گالن بر دقیقه، آبخوان محبوس نشتی را تخلیه می‌کند. داده‌های افت-زمان در یک پیژومتر که در فاصله ۱۰۰ فوتی از این چاه پمپاژ قرار گرفته اندازه‌گیری شده است. لایه نیمه‌تراوا آب را از ذخیره آزاد می‌کند ($S' > 0.0$). مقادیر متغیرهای آبخوان (T, S, K', S') با شبکه طراحی شده تعیین و با نتایج حاصل از روش انطباق منحنی تیپ در جدول ۸ مقایسه شده است که مقدار RRMSE بسیار کوچک‌تری را نشان می‌دهد (۰/۰۵ درصد در مقایسه با ۹/۴ درصد). در این آزمون پمپاژ رکورد سی و یکم از داده‌های افت-زمان به‌عنوان نقطه انطباق بهینه انتخاب شد (شکل ۱۱).

۵- نتیجه‌گیری


در این پژوهش دو شبکه عصبی پرسپترون چند لایه (MLPNs) با الگوریتم آموزش لوبرگ-مارکوآرت (LM) برای تعیین متغیرهای آبخوان محبوس نشتی با لایه نیمه‌تراوا بدون ذخیره (نوع a) و آبخوان‌های محبوس نشتی با لایه نیمه‌تراوا دارای ذخیره (نوع b) طراحی شد. شبکه اول برای تابع چاه Hantush & Jacob (1955) و شبکه دوم برای تابع چاه Hantush (1960) آموزش داده شد. همچنین پیش از ساخت شبکه‌ها PCA بر مجموعه داده‌های آموزش اعمال شد تا ابعاد الگوهای ورودی آموزش با در نظر گرفتن کمترین درصد واریانس ۰/۰۰۵ کاهش یابد. نتایج نشان داد که مؤلفه‌های اصلی اول و دوم در مجموع به ترتیب ۹۹/۹۹۷ درصد و ۹۹/۹۹۶ درصد از واریانس کل داده‌های آموزش آبخوان‌های نوع a و b را به خود اختصاص




شکل ۲- گروهی از منحنی‌های تیب (Walton (1960)، $W(u, r/B)$ در برابر $1/u$ برای مقادیر مختلف r/B .



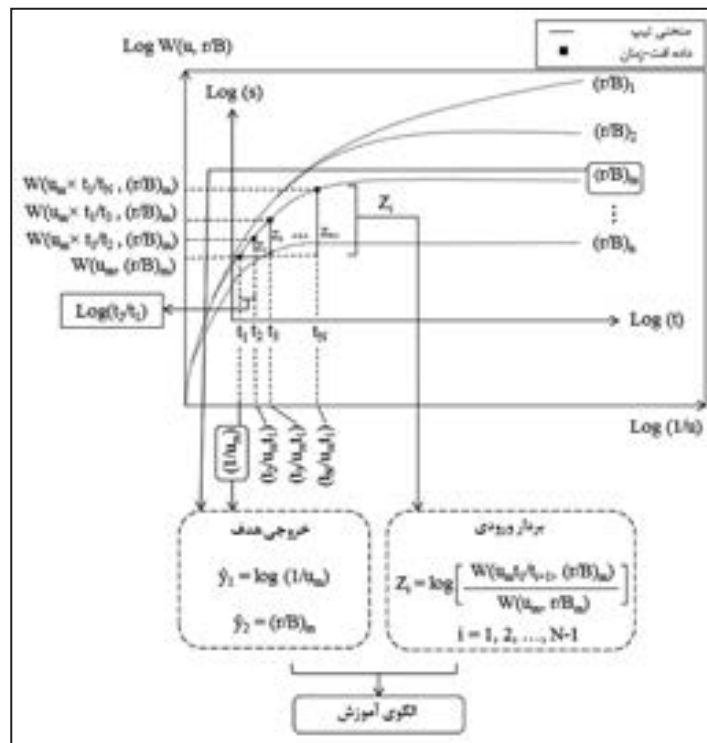
شکل ۳- گروهی از منحنی‌های تیب (Hantush (1961)، $W(u, \psi)$ در برابر $1/u$ برای مقادیر مختلف ψ .



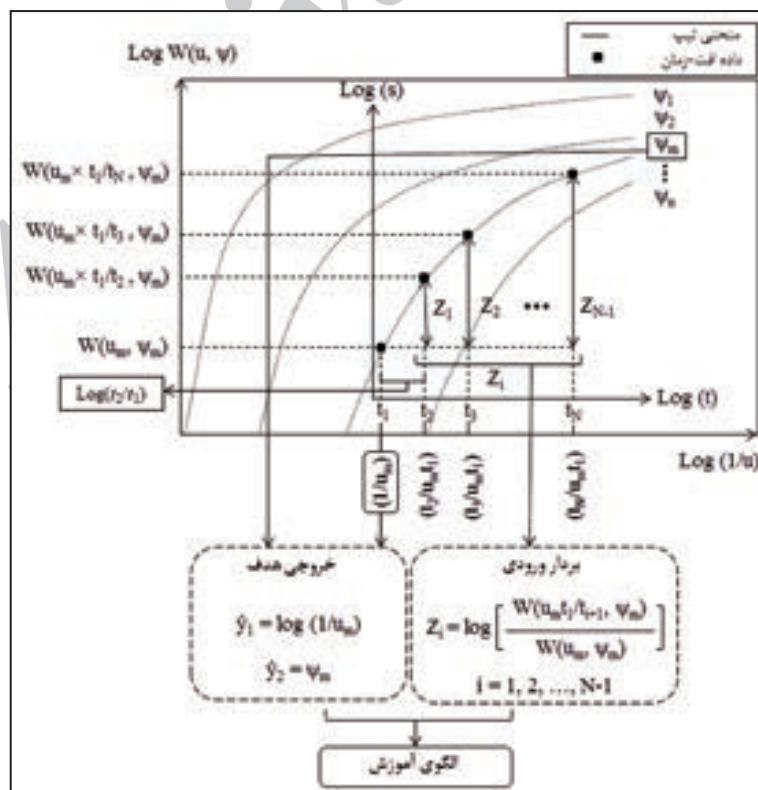
شکل ۵- توابع فعال‌سازی هیپربولیک تانژانت و خطی.



شکل ۴- نمای نمادین از یک MLPN سه لایه.




شکل ۶- چگونگی تولید بردارهای ورودی و خروجی شبکه عصبی آبخوان نشتی نوع a




شکل ۷- چگونگی تولید بردارهای ورودی و خروجی شبکه عصبی آبخوان نشتی نوع b

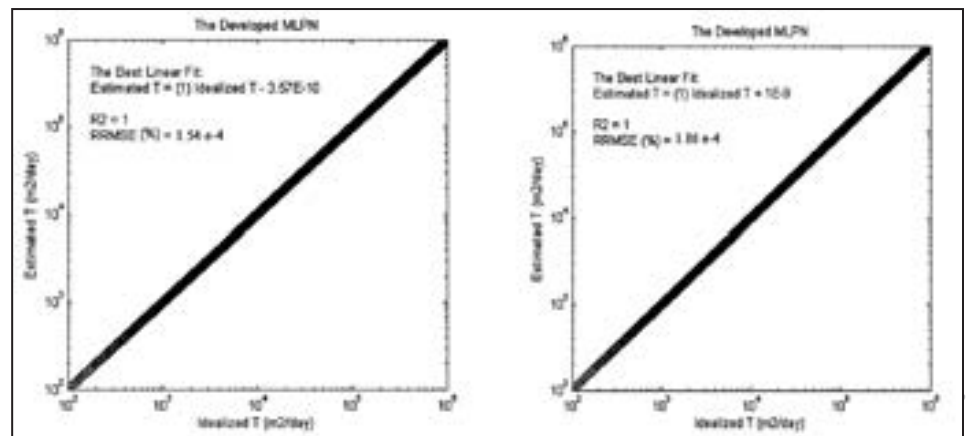
شکل ۸- ساختار شبکه عصبی در مرحله آموزش:
الف) آبخوان نوع a؛ ب) آبخوان نوع b؛ ج) شبکه
Lin & Chen (2006)




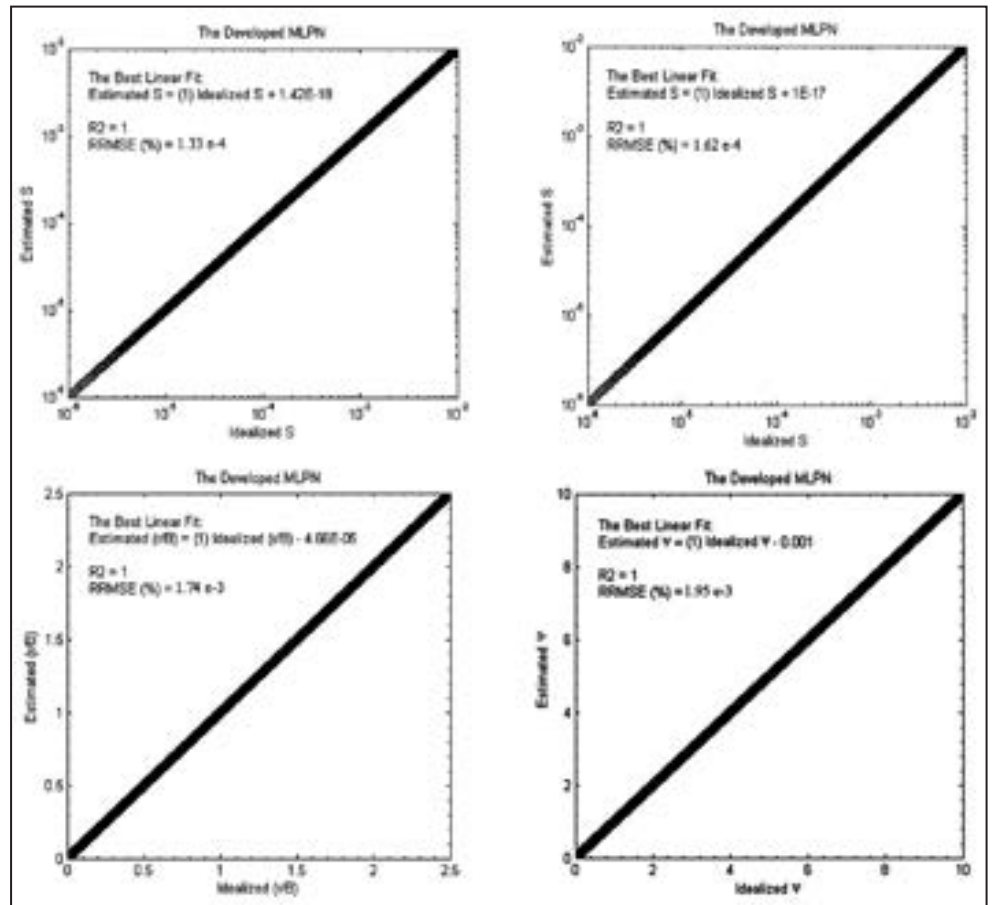
شکل ۹- ساختار MLPN طراحی شده در مرحله
آزمایش: الف) آبخوان نوع a؛ ب) آبخوان نوع b.



شکل ۱۰- مقادیر متغیرهای هدف در برابر مقادیر
محاسبه شده توسط شبکه‌های MLP طراحی
شده. نمودارهای سمت چپ و راست به ترتیب
برای آبخوان نوع a و b هستند.



ادامه شکل ۱۰- مقادیر متغیرهای هدف در برابر مقادیر محاسبه شده توسط شبکه‌های MLP طراحی شده. نمودارهای سمت چپ و راست به ترتیب برای آبخوان نوع a و b هستند.



شکل ۱۱- نمودار RRMSE رکورد‌های مختلف آفت ۳ مجموعه داده آزمون پمپاژ واقعی.

جدول ۲- متغیرهای مؤلفه اصلی مجموعه آموزش آبخوان نوع b.

مؤلفه اصلی	مقدار ویژه	واریانس (%)	واریانس تجمعی (%)
PC1	۳۵/۵۷۴۶	۹۸/۸۱۸۳۳	۹۸/۸۱۸۳۳
PC2	۰/۴۲۳۸	۱/۱۷۷۲۲۲	۹۹/۹۹۵۵۶
PC3	۰/۰۰۱۶	۰/۰۰۴۴۴۴	۱۰۰
PC4	۲/۴۵۰۶ × ۱۰ ^{-۶}	۰	۱۰۰

جدول ۱- متغیرهای مؤلفه اصلی مجموعه آموزش آبخوان نوع a.

مؤلفه اصلی	مقدار ویژه	واریانس (%)	واریانس تجمعی (%)
PC1	۲۴/۲۵۸۹۲۵	۹۷/۰۳۵۷	۹۷/۰۳۵۷
PC2	۰/۷۴۰۲۵	۲/۹۶۱	۹۹/۹۹۶۷
PC3	۸/۲۵ × ۱۰ ^{-۴}	۰/۰۰۳۳	۱۰۰
PC4	۵/۰۳۴ × ۱۰ ^{-۷}	۰	۱۰۰

جدول ۳- متغیرهای به کار رفته در آموزش شبکه عصبی مصنوعی در هر دو نوع آبخوان محبوس نشستی.

مقدار	متغیر
۰/۵	نرخ یادگیری
۱۰ ^{-۶}	معیار همگرایی
۱۰۰۰۰	بیشینه چرخه آموزش
۵۱۲۰۰	تعداد الگوهای آموزش

جدول ۴- تعداد نورون‌ها، زمان مورد نیاز آموزش، R^2 و RRMSE (%) مربوط به مقادیر $(r/B)_m$ و $\text{Log}(I/u_m)$ شبکه عصبی RBFN (Lin & Chen, 2005) و MLPN طراحی شده در مرحله آموزش برای آبخوان نوع a.

R^2	RRMSE		زمان مورد نیاز آموزش (ثانیه)	تعداد نورون‌ها			شبکه عصبی مصنوعی
	$(r/B)_m$	$\text{Log}(I/u_m)$		لایه ورودی	لایه مخفی	لایه خروجی	
۰/۷	۰/۷۵	۱	۱۲۰	۲	N-۱	N-۱	RBFN (Lin & Chen)
۱	۱	$1/8 \times 10^{-۴}$	۷۲	۲	۱۰	۲	MLPN

جدول ۵- تعداد نورون‌ها، زمان مورد نیاز آموزش، R^2 و RRMSE (%) مربوط به مقادیر $(\psi)_m$ و $\text{Log}(I/u_m)$ شبکه MLPN طراحی شده در مرحله آموزش برای آبخوان نوع b.

R^2	RRMSE		زمان مورد نیاز آموزش (ثانیه)	تعداد نورون‌ها			شبکه عصبی مصنوعی
	$(\psi)_m$	$\text{Log}(I/u_m)$		لایه ورودی	لایه مخفی	لایه خروجی	
۱	۱	$1/94 \times 10^{-۴}$	۷۸	۲	۱۰	۲	MLPN

جدول ۶- مقادیر R^2 و RRMSE (%) متغیرهای محاسبه شده با استفاده از شبکه‌های MLP طراحی شده در مرحله آزمایش در آبخوان‌های نشستی نوع a و b.

()	RRMSE			شبکه عصبی مصنوعی
	(r/B)	S	T	
-	$1/74 \times 10^{-۳}$	$1/33 \times 10^{-۴}$	$1/54 \times 10^{-۴}$	MLPN طراحی شده برای آبخوان نوع a
$1/95 \times 10^{-۳}$	-	$1/62 \times 10^{-۴}$	$1/86 \times 10^{-۴}$	MLPN طراحی شده برای آبخوان نوع b

R^2 برای هر چهار متغیر بالا برابر ۱ محاسبه شد.

جدول ۷- متغیرهای محاسبه شده با استفاده از شبکه MLP طراحی شده و روش انطباق منحنی تیپ در آبخوان نوع a و مقادیر RRMSE (%) (آزمون‌های پمپاژ اول و دوم).

RRMSE	متغیرهای آبخوان				روش	آزمون پمپاژ
	K' (ft/day)	r/B	S	T (ft ² /day)		
۲۶/۳	۰/۲۸	۰/۰۳	۰/۰۰۳۶۵	۳۵۶۲۴	روش گرافیکی انطباق منحنی تیپ (Todd & Mays, 2005)	اول
۰/۰۰۱	۳/۱۲۵۲	۰/۰۹۹	۰/۰۰۳۶	۳۶۳۳۷	طراحی شده MLPN	
۴۱/۴	۰/۰۱۴۸	۰/۲۲	۰/۰۰۰۲	۲۰۱/۵۶۰۹	روش گرافیکی انطباق منحنی تیپ (Walton, 1960)	دوم
۰/۰۰۱	۰/۰۱۰۱	۰/۱۷۳	۰/۰۰۰۲۰۶	۲۲۲/۸۷۷۵	طراحی شده MLPN	

جدول ۸- متغیرهای محاسبه شده با استفاده از شبکه MLP طراحی شده و روش انطباق منحنی تیپ در آبخوان نوع b و مقادیر RRMSE (%) (آزمون پمپاژ سوم).

RRMSE	متغیرهای آبخوان				روش
	$K'S'$ (gpd/ft ²)	ψ	S	T (gpd/ft)	
۹/۴	$1/73 \times 10^{-۵}$	۰/۰۰۵	$1/11 \times 10^{-۴}$	۱۳۰۰۰	روش گرافیکی انطباق منحنی تیپ (Neuman & Witherspoon, 1972)
۰/۰۰۵	$1/۰۹ \times 10^{-۵}$	۰/۰۰۶	$۴/۸۵ \times 10^{-۵}$	۱۳۰۶۲۰	طراحی شده MLPN

جدول ۹- داده‌های افت- زمان آزمون‌های پمپاژ اول و دوم.

آزمون پمپاژ اول (Todd & Mays, 2005)				آزمون پمپاژ دوم (Walton, 1960)	
زمان (دقیقه)	افت (فوت)	زمان (دقیقه)	افت (فوت)	زمان (دقیقه)	افت (فوت)
۲	۵/۶۵	۸۰	۱۲/۰۲	۵	۰/۷۶
۴	۶/۹۶	۹۰	۱۲/۲۶	۲۸	۳/۳
۶	۷/۷۲	۱۰۰	۱۲/۳۳	۴۱	۳/۵۹
۸	۸	۱۱۰	۱۲/۳۷	۶۰	۴/۰۸
۱۰	۸/۷۱	۱۲۰	۱۲/۴۱	۷۵	۴/۳۹
۱۵	۹/۴۷	۱۵۰	۱۲/۶۹	۲۴۴	۵/۴۷
۲۰	۹/۹۹	۱۸۰	۱۲/۸۵	۴۹۳	۵/۹۶
۲۵	۱۰/۳۵	۲۱۰	۱۳/۰۹	۶۶۹	۶/۱۱
۳۰	۱۰/۷	۲۴۰	۱۳/۱۳	۹۵۸	۶/۲۷
۴۰	۱۱/۱۴	۲۷۰	۱۳/۲۵	۱۱۲۹	۶/۴۰
۵۰	۱۱/۴۶	۳۰۰	۱۳/۳۳	۱۱۸۵	۶/۴۲
۶۰	۱۱/۶۲	۳۶۰	۱۳/۳۷		
۷۰	۱۱/۸۶	۴۲۰	۱۳/۴۱		

جدول ۱۰- داده‌های افت- زمان آزمون پمپاژ سوم (Neuman & Witherspoon, 1972).

افت (فوت)	زمان (دقیقه)	افت (فوت)	زمان (دقیقه)	افت (فوت)	زمان (دقیقه)
۱۰/۶۸	۱۸۰۰	۸/۵۳	۱۳۰	۶/۳۰	۱۰
۱۰/۸۰	۲۰۰۰	۸/۶۶	۱۸۰	۶/۵۱	۱۳
۱۰/۹۷	۲۴۰۰	۸/۸۴	۲۲۰	۶/۷۲	۱۸
۱۱/۱۴	۲۹۰۰	۸/۹۷	۲۵۰	۶/۸۳	۲۲
۱۱/۲۷	۳۵۰۰	۹/۱۳	۳۰۰	۷/۰۱	۲۶
۱۱/۴۱	۴۰۰۰	۹/۳۳	۳۵۰	۷/۱۶	۳۰
۱۱/۶۰	۴۹۰۰	۹/۴۷	۴۳۰	۷/۲۹	۳۸
۱۱/۷۸	۵۹۰۰	۹/۶۷	۵۰۰	۷/۴۰	۴۳
۱۱/۹۶	۶۹۰۰	۹/۸۸	۶۰۰	۷/۶۵	۵۳
۱۲/۱۴	۸۱۰۰	۱۰/۱۰	۷۵۰	۷/۷۹	۶۳
۱۲/۳۲	۱۰۰۰۰	۱۰/۱۹	۸۸۰	۸/۰۸	۷۳
		۱۰/۳۵	۱۱۰۰	۸/۲۶	۸۳
		۱۰/۵۱	۱۴۰۰	۸/۳۷	۱۱۰

References

- Ajmera, T. K. & Rastogi, A. K., 2008- Artificial neural network application on estimation of aquifer transmissivity. *Journal of Spatial Hydrology* 8(2): 15-31.
- Almasari, M. N. & Kalurachi, J. J., 2005- Modular neural networks to predict the nitrate distribution in ground water using the on-ground nitrogen loading and recharge data. *Environmental Modeling and Software* 20: 851-871.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000- Artificial Neural Networks in hydrology. I: preliminary concepts. *Journal of Hydrologic Engineering* 5(2): 115-123.
- Aziz, A. R. A. & Wong, K. V., 1992- A neural-network approach to the determination of aquifer parameters. *Ground Water* 30(2): 164-166.
- Balkhair, K. S., 2002- Aquifer parameters determination for large diameter wells using neural network approach. *Journal of Hydrology* 265(1-4): 118-128.
- Banerjee, P., Singh, V. S., Chattopadhyay, K., Chandra, P. C. & Singh, B., 2011- Artificial neural network model as a potential alternative for groundwater salinity forecasting. *Journal of Hydrology* 398: 212-220.
- Ch, S. & Mathur, Sh., 2012- Particle swarm optimization trained neural network for aquifer parameter estimation. *KSCE Journal of Civil Engineering* 16(3): 298-307.
- Chang, F. J., Kao, L. S., Kuo, Y. M. & Liu, Cw., 2010- Artificial neural networks for estimating regional arsenic concentrations in a black foot disease area in Taiwan. *Journal of Hydrology* 388: 65-76.
- Chang, L. Ch., Chu, H. J. & Hsiao, Ch. T., 2012- Integration of optimal dynamic control and neural network for groundwater quality management. *Water Resource Management* 26: 1253-1269.
- Chris, D. & Xiaofeng, H., 2004- K-Means clustering via principal component analysis. In proceedings of the 21st International Conference on Machine Learning, Banff, Canada.
- Coppola, E., Szidarovszky, F., Poulton, M. & Charles, E., 2003- Artificial neural networks approach for predicting transient water levels in a multilayered groundwater system under variable state, pumping and climate conditions. *Journal of Hydrologic Engineering, ASCE* 8(6): 348-360.
- Coulibaly, P., Anctil, F., Aravena, R. & Bobee, B., 2001- Artificial neural network modeling of water table depth fluctuations. *Water Resource Research* 37(4): 885-896.
- Dadaser, F. & Cengiz, E., 2013- A neural network model for simulation of water levels at the Sultan Marshes wetland in Turkey. *Wetlands Ecology and Management* 21(5): 297-306.
- Daliakopoulos, I. N., Coulibaly, P. & Tsanis, I. K., 2005- Groundwater level forecasting using artificial neural networks. *Journal of Hydrology* 309(1-4): 229-240.
- Fijani, E., Nadiri, A., Asghari-Moghaddam, A., Tsai, F. & Dixon, B., 2013- Optimization of DRASTIC method by supervised committee machine artificial intelligence to assess groundwater vulnerability for Maragheh-Bonab plain aquifer, Iran. *Journal of Hydrology* 503: 89-100.

- Gangopadhyay, S., Gautam, T. R. & Gupta, A. D., 1999- Subsurface characterization using neural networks and GIS. *Journal of Computing in Civil Engineering* 13(3): 153-161.
- Garcia, L. A. & Shigidi, A., 2006- Using neural networks for parameter estimation in ground water. *Journal of Hydrology* 318(1-4): 215-231.
- Hantush, M. S. & Jacob, C. E., 1955- Non-steady radialflow in an infinite leaky aquifer. *Transactions American Geophysical Union* 36(1): 95-100.
- Hantush, M. S., 1960- Modification of the theory of leaky aquifers. *Journal of Geophysical Research* 66(11): 3713-3726.
- Hantush, M. S., 1961- Tables of the function $H(u, \beta) = \int_u^{\infty} \frac{e^{-y}}{y} \operatorname{erfc}\left(\frac{\beta\sqrt{u}}{\sqrt{y(y-u)}}\right) dy$. *New Mexico Institute of Mining and Technology* 103: 12 PP.
- Haykin, S., 1999- *Neural networks: A comprehensive foundation*. Prentice-Hall: Englewood Cliffs, NJ.
- Hsu, K. L., Gupta, H. V. & Sorooshian, S., 1995- Artificial neural network modeling of the rainfall-runoff process. *Water Resource Research* 31(10): 2517-2530.
- Lin, G. F. & Chen, G. R., 2005- Determination of aquifer parameters using radial basis function network approach. *Journal of the Chinese Institute of Engineers* 28(2): 241-249.
- Lin, G. F. & Chen, G. R., 2006- An improved neural network approach to the determination of aquifer parameters. *Journal of Hydrology* 316(1-4): 281-289.
- Lin, H. T., Ke, K. Y., Chen, Ch. H., Wu, Sh. Ch. & Tan, Y. Ch., 2010- Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrological Processes* 24: 3237-3250.
- Mahallawi, Kh., Mania, J., Hani, A. & Shahrour, I., 2012- Using of neural networks for the prediction of nitrate groundwater contamination in rural and agricultural areas. *Environmental Earth Sciences* 65: 917-928.
- McCulloch, W. & Pitts, W., 1943- A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics* 5: 113-115.
- Mohanty, S., Jha, M. K., Kumar, A. & Sudheer, K. P., 2010- Artificial neural network modeling for groundwater level forecasting in a river island of eastern india. *Water Resource Management* 24(9): 1845-1865.
- Nadiri, A., Chitsazan, N., Tsai, F. & Asghari-Moghaddam, A., 2014- Bayesian Artificial Intelligence Model Averaging for Hydraulic Conductivity Estimation. *Journal of Hydrologic Engineering* 19(3): 520-532.
- Nadiri, A., Fijani, E., Tsai, F. & Asghari-Moghaddam, A., 2013- Supervised committee machine with artificial intelligence for prediction of fluoride concentration. *Journal of Hydroinformatics* 15(4): 1474-1490.
- Neuman, Sh. P. & Witherspoon, P. A., 1972- Field determination of the hydraulic properties of leaky multiple aquifer systems. *Water Resource Research* 8(5): 1284-1298.
- Nourani, V., Asghari-Moghaddam, A. & Nadiri, A., 2008- An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrological Processes* 22(26): 5054-5066.
- Parkin, G., Birkinshaw, S. J., Younger, P. L., Rao, Z. & Kirk, S., 2007- A numerical modeling and neural network approach to estimate the impact of groundwater abstractions on river flows. *Journal of Hydrology* 339: 15-28.
- Pezeshk, S., Camp, C. V. & Karprapu, S., 1996- Geophysical log interpretation using neural network. *Journal of Computing Civil Engineering, ASCE* 10(2): 136-143.
- Ranjithan, S., Eheart, J. W. & Garrett, J. H., 1993- Neural network-based screening for groundwater reclamation under uncertainty. *Water Resource Research* 29(3): 563-574.
- Samani, N., Gohari-Moghadam, M. & Safavi, A. A., 2007- A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology* 340(1-2): 1-11.
- Singh, R. M. & Datta, B., 2007- Artificial neural network modeling for identification of unknown pollution sources in groundwater with partially missing concentration observation data. *Water Resource Management* 21: 557-572.
- Tayfur, G., Nadiri, A. & Asghari-Moghaddam, A., 2014- Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resources Management* 28(4): 1173-1184.
- Theis, C. V., 1935- The relationship between the lowering of the piezometric surface and the rate and duration of discharge of a well using groundwater storage. *Transactions American Geophysical Union* 16: 519-524.
- Todd, D. K. & Mays, L. W., 2005- *Groundwater hydrology*. Wiley, New York.
- Toth, E., Brath, A. & Montanari, A., 2000- Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of Hydrology* 239: 132-147.
- Toth, J., 1966- Groundwater, geology, movement, chemistry and resources, near Olds, Alberta. *Res Council Alberta Bull* 17: Edmonton:126.
- Walton, W. C., 1960- Leaky artesian aquifer conditions in Illinois. *Illinois State Water Surv, Rept of Invest* 39.

Two Multilayer Perceptron Networks for the Determination of Leaky Confined Aquifer Parameters

T. Azari¹ & N. Samani^{2*}

¹Ph.D., Department of Earth Sciences, Sciences College, Shiraz University, Shiraz, Iran

²Professor, Department of Earth Sciences, Sciences College, Shiraz University, Shiraz, Iran

Received: 2014 June 10

Accepted: 2015 June 20

Abstract

In recent years, the artificial neural networks (ANNs) are used as an alternative to the conventional type curve matching techniques for the determination of aquifer parameters. In this paper two multilayer perceptron networks (MLPNs) are developed for the determination of leaky confined aquifers parameters. Leakage into the aquifer takes place from either the upper aquifer through the confining aquitard or the storage in the confining aquitard. The first and second networks are trained for the well functions of leaky aquifers (a) without and (b) with storage in the confining aquitard, respectively. By applying the principal component analysis (PCA) on the adopted training data sets the topology of both networks are reduced and their efficiency increased considerably. In contrast to the existing networks the topology of developed networks is fixed to $(2 \times 10 \times 2)$ regardless of number of records in the pumping test data. The networks generate the match point coordinates for any individual pumping test data set. The match point coordinates are incorporated with Hantush-Jacob (1955) and Hantush (1960) analytical solutions and the aquifer parameter values are determined. The performance of the MLPNs is evaluated by three sets of real field data and their accuracy is compared with that of type curve matching techniques. The proposed MLPNs are recommended as simple and reliable alternatives to previous ANN methods and the type-curve matching techniques.

Keywords: Aquifer parameter estimation, Aquitard, Artificial neural network, Principal component analysis (PCA), Levenberg–Marquardt (LM) training algorithm.

For Persian Version see pages 375 to 386

*Corresponding author: N. Samani; E-mail: samani@susc.ac.ir