

طراحی یک شبیه‌سازی شبکه‌ی عصبی مصنوعی جهت تعیین فراسنجهای آبخوان آزاد

طاهره آذری^۱، نوذر سامانی^{۲*}

چکیده


در این مقاله، یک شبکه‌ی عصبی مصنوعی جهت تعیین فراسنجهای آبخوان آزاد (قابلیت انتقال آبخوان، ضریب ذخیره، آبدهی ویژه و شاخص تأخیر) طراحی گردیده است. تابع چاه مربوط به آبخوانهای آزاد با روش پس انتشار خطا و به کارگیری الگوریتم بهینه سازی لونیبرگ-مارکوآرت به این شبکه آموزش داده شده است. با اعمال روش تحلیل مولفه‌ی اصلی بر مجموعه داده‌های آموزش، ساختار شبکه با آرایش (۳×۶×۳)، صرف نظر از تعداد داده‌های آزمون آبکشی، ثابت گردید و بازدهی آن بطور قابل ملاحظه‌ای افزایش داده شد. این شبکه با دریافت هر مجموعه داده آزمون آبکشی واقعی، مختصات نقطه انطباق بهینه را تولید می‌کند، سپس مختصات نقطه‌ی انطباق با حل تحلیلی بولتون (۱۹۶۳) ترکیب گردیده، و مقادیر فراسنجهای آبخوان محاسبه می‌شوند. توانایی تعمیم و عملکرد این شبکه با ۱۰۰۰۰۰ مجموعه‌ی داده مصنوعی ارزیابی گردید و دقت آن با استفاده از داده‌های دو آزمون آبکشی واقعی با روش انطباق منحنی نمونه‌ی کامل مقایسه شد. شبکه‌ی پیشنهادی به عنوان یک روش جایگزین ساده‌تر و دقیق‌تر نسبت به روش مرسوم انطباق منحنی نمونه‌ی کامل برای محاسبه فراسنجهای آبخوان آزاد توصیه می‌شود.

واژه‌های کلیدی: فراسنجهای آبخوان، شبکه‌ی عصبی مصنوعی، تحلیل مولفه‌ی اصلی، الگوریتم آموزش لونیبرگ-مارکوآرت، آزمون آبکشی.

^۱ - دانشجوی دکتری زمین شناسی گرایش آبشناسی، بخش علوم زمین، دانشکده علوم، دانشگاه شیراز

^۲ - استاد بخش علوم زمین، دانشکده علوم، دانشگاه شیراز

*- نویسنده مسوول مقاله: samani@susc.ac.ir



شکل ۱- آبخوان آزاد به همراه چاه آبکشی با نفوذ کامل.

معادله‌ی دیفرانسیلی جریان به چاه کامل در آبخوان آزاد در سامانه‌ی مختصات قطبی در حالت ناپایدار به وسیله‌ی بولتون در سال ۱۹۶۳ ارائه شد:

$$T \left(\frac{\partial^2 s}{\partial r^2} + \frac{1}{r} \frac{\partial s}{\partial r} \right) = S \frac{\partial s}{\partial t} + D_i S_y \int_0^t \frac{\partial s}{\partial \tau} e^{-D_i(t-\tau)} d\tau \quad (1)$$

که به ترتیب S مقدار افت اندازه‌گیری شده در زمان t [T] در یک چاه مشاهده‌ای واقع در فاصله r [L] از چاه آبکشی، $[L^2 T^{-1}] T$ قابلیت انتقال آبخوان^۹، ضریب ذخیره‌ی آبخوان^{۱۰}، S_y آبدهی ویژه، و $[T^{-1}] D_i$ و τ معکوس شاخص تأخیر و متغیر ساختگی^{۱۱} می‌باشند. توجه شود که عبارتهای اول و دوم در سمت راست رابطه- ۱ به ترتیب بیان‌کننده‌ی ضریب ذخیره (حجم آبی است که به صورت لحظه‌ای از ذخیره در واحد سطح رها می‌شود)، و آبدهی ویژه (حجم کل زهکشی ثقلی تأخیری در واحد سطح بازاء یک واحد افت) است. بولتون در سال ۱۹۶۳ رابطه‌ی ۱ را با در نظر گرفتن شرایط اولیه و مرزی مناسب حل کرد و یک راه حل تحلیلی را برای افت در چاه مشاهده‌ای ناشی از آبکشی چاهی با نفوذ کامل در آبخوان آزاد به دست آورد:

پریکت در سال ۱۹۶۵ روش تطبیق منحنی نمونه‌ی کامل^{۱۲} در آبخوانهای آزاد را براساس رابطه‌ی ۲ تدوین کرد. نیومن در سال ۱۹۷۵ معادله افت را در آبخوان آزاد به صورت زیر ارائه نمود:

مقدمه

آزمونهای آبکشی بطور وسیعی جهت تعیین فراسنجهای آبخوان استفاده می‌شوند. هنگامی که یک چاه بهره برداری کامل با نرخ ثابت از یک آبخوان آزاد^۱ آبکشی می‌شود، یک مخروط افت در سطح آب زیرزمینی ایجاد می‌گردد (شکل ۱). همان طور که آبکشی ادامه می‌یابد این مخروط بزرگتر و عمیقتر می‌شود و یک مولفه‌ی عمودی جریان به سمت چاه تشکیل می‌گردد. منحنی افت-زمان آبخوانهای آزاد در مقیاس لگاریتمی معمولاً به شکل S بوده و با سه بخش متوالی شناسایی می‌شود. با شروع آبکشی، افت در بخش اول منحنی به سرعت افزایش یافته، در بخش دوم کاستی پذیرفته، و مجدداً در بخش سوم فزونی ناچیزی را نشان می‌دهد. بولتون در سالهای ۱۹۵۴ و ۱۹۶۳ یک راه حل نیمه تحلیلی را برای آبخوانهای آزاد ارائه داد و هر سه بخش منحنی افت-زمان را بر اساس رهاسازی آب از دو مولفه‌ی آبدهی لحظه‌ای^۲ و آبدهی ثقلی^۳ تفسیر کرد. آبدهی لحظه‌ای از فشرده شدن آبخوان^۴ و انبساط آب^۵ حاصل می‌گردد. این مولفه فراسنج اصلی ذخیره‌ی آب در آبخوانهای محبوس و محبوس نشتی به شمار می‌رود، اما در آبخوانهای آزاد نقش محدودی دارد، و اساساً در بخش اول منحنی افت-زمان ظاهر می‌شود. مولفه‌ی دوم، آبدهی ثقلی یا آبدهی تأخیری^۶ می‌باشد که در ابتدا افزایش یافته، سپس به صورت نمایی کاهش می‌یابد. این پدیده با استفاده از دو فراسنج تشریح می‌شود: (۱) آبدهی ویژه^۷ یا آبدهی ثقلی کل (۲) نمایه‌ی تأخیر^۸ یا فراسنج تجربی که توزیع زمان را را تعیین می‌کند. مفهوم پاسخ سطح آب زیرزمینی به زهکشی تأخیری به وسیله‌ی نیومن (۱۹۷۲، ۱۹۷۳ و ۱۹۷۹)، استرلت سوا (۱۹۷۲a، ۱۹۷۲b، ۱۹۷۳ و ۱۹۷۶) و گامبولاتی (۱۹۷۶) با تفصیل بیشتری مورد مطالعه قرار گرفته است.

¹ unconfined aquifer

² instantaneous yield

³ gravity yield

⁴ compression of the aquifer

⁵ expansion of the water

⁶ delayed yield

⁷ specific yield

⁸ delay index

⁹ transmissibility

¹⁰ storage coefficient

¹¹ dummy variable

¹² type curve matching

مقادیر β برای تحلیل داده‌های افت-زمان نهایی استفاده می‌شوند. جهت تعیین مقادیر فراسنجهای آبخوان آزاد (T, S, S_y, K_h, K_v) داده‌های افت-زمان مربوط به یک آزمون آبکشی روی کاغذ لگاریتمی با مقیاس مشابه منحنیهای نمونه‌ی کامل نیومن ترسیم می‌گردند. منحنی افت-زمان روی منحنی نمونه‌ی کامل A قرار داده می‌شود به گونه‌ای که محورهای مختصات هر دو منحنی با هم موازی بوده و اکثر نقاط داده‌های مشاهده‌ای اولیه روی یکی از منحنیهای نمونه‌ی کامل A قرار گیرد. مقدار β از منحنی نمونه‌ی کامل A انتخاب شده تعیین می‌گردد. در این حالت یک نقطه انطباق انتخاب می‌شود. سپس مختصات نقطه‌ی انطباق روی هر دو منحنی $[(\frac{1}{u_A})_m, W(u_A, u_B, \beta)_m, S_m, t_m]$ ثبت می‌شود.

استفاده از مقادیر مختصات نقطه‌ی انطباق اول و روابط (۳)، (۵)، (۱۱) و (۱۲) فراسنجهای آبخوان (T, S, K_h, K_v) تعیین می‌گردند. سپس داده‌های مشاهده‌ای نهایی بر روی منحنی نمونه‌ی کامل B با مقدار β تعیین شده قرار داده می‌شوند. در این حالت، نقطه‌ی انطباق دوم انتخاب می‌گردد. سپس با استفاده از مقادیر مختصات نقطه‌ی انطباق دوم $[(\frac{1}{u_B})_m, W(u_A, u_B, \beta)_m, S_m, t_m]$ و روابط (۳) و (۶)، فراسنجهای آبخوان (T, S_y) محاسبه می‌گردند. مقدار T محاسبه شده در این مرحله باید تقریباً برابر با مقدار T تعیین گردیده از داده‌های افت-زمان اولیه باشد. فراسنجهای آبخوان محاسبه شده با روش نموداری منحنی نمونه‌ی کامل به دلیل خطاهای فردی و نموداری بحث برانگیزند. در سالهای اخیر، برخی روشهای مناسب براساس شبکه‌های عصبی مصنوعی به عنوان یک روش جایگزین جهت تعیین فراسنجهای آبخوان توسعه یافته‌اند (لین و چن، ۲۰۰۵؛ لین و چن، ۲۰۰۶؛ سامانی و همکاران، ۲۰۰۷؛ لین و همکاران، ۲۰۱۰).

روش شبکه‌ی عصبی مصنوعی اولین بار به وسیله‌ی مک کلوج و پیت (۱۹۴۳) پیشنهاد گردید. شبکه‌ی عصبی مصنوعی یک سامانه‌ی پردازشگر اطلاعات است که از تعداد زیادی نورون تشکیل شده است که می‌تواند روابط غیرخطی پیچیده‌ی را بین ورودیها و خروجیهای مطلوب

$$s = \frac{Q}{4\pi T} \int_0^\infty \frac{2}{x} \left\{ 1 - e^{-u_A} \left[\cosh u_B + \frac{D_i N(1-x^2)t}{2u_B} \sinh u_B \right] \right\} \quad (2)$$

$$s = \frac{Q}{4\pi T} W(u_A, u_B, \beta) \quad (3)$$

که در آن

$$W(u_A, u_B, \beta) = \int_0^\infty \frac{2}{x} \left\{ 1 - e^{-u_A} \left[\cosh u_B + \frac{D_i N(1-x^2)t}{2u_B} \sinh u_B \right] \right\} J_0 \left(\frac{r}{u_D t} x \right) dx \quad (4)$$

$$u_A = \frac{D_i t N(1-x^2)}{2} = \frac{r^2 S}{4Tt} \quad (5)$$

$$u_B = \frac{D_i t \sqrt{N^2(1+x^2)^2 - 4Nx^2}}{2} = \frac{r^2 S_y}{4Tt} \quad (6)$$

$$N = \frac{S+S_y}{S} \quad (7)$$

$$v = \sqrt{\frac{N-1}{N}} = \sqrt{\frac{S_y}{S+S_y}} \quad (8)$$

$$D_t = \sqrt{\frac{T}{D_i S_y}} = \frac{\beta^2 b / u_B}{4t} \quad (9)$$

$$\beta = \frac{r}{D_t} = \frac{r}{\sqrt{T/D_i S_y}} \quad (10)$$

$$K_h = \frac{T}{b} \quad (11)$$

$$K_v = \frac{\beta^2 b^2 K_h}{r^2} \quad (12)$$

در معادلات بالا J_0 تابع بسل^۱ نوع اول مرتبه صفر، x متغیر انتگرال گیری^۲، D_t عامل زهکشی^۳، $[L]b$ ضخامت ضخامت اشباع اولیه^۴، $[L^3/T]Q$ نرخ آبکشی^۵ و K_h و $[LT^{-1}]K_v$ به ترتیب هدایت آبی^۶ افقی و عمودی می‌باشند.

نیومن در سال ۱۹۷۵ نمودار $W(u_A, u_B, \beta)$ در برابر مقادیر $(\frac{1}{u_B})$ و $(\frac{1}{u_A})$ را ترسیم نمود و یک گروه از منحنیهای نمونه‌ی کامل را، که هر کدام مقدار β مجزایی دارند ایجاد کرد که در شکل ۲ نشان داده شده‌اند. منحنیهای نمونه‌ی کامل A واقع در سمت چپ مقادیر β جهت تحلیل داده‌های افت-زمان اولیه آزمون آبکشی و منحنیهای نمونه‌ی کامل B واقع در سمت راست

¹ Bessel function

² variable of integration


³ drainage factor

⁴ initial saturated thickness

⁵ pumping rate

⁶ hydraulic conductivity

از طریق فرایند آموزش شبیه‌سازی کند تا نتایج دقیقتری را نسبت به روشهای مرسوم ایجاد نماید.



شکل ۲- گروهی از منحنیهای نمونه‌ی کامل نیومن (۱۹۷۵)، $W(u_A, u_B, \beta)$ در مقابل $\frac{1}{u_B}$ و $\frac{1}{u_A}$ برای مقادیر مختلف β .

متعاقبا لین و همکاران (۲۰۱۰) روش PCA^۴ را بر الگوهای آموزش و آزمایش اعمال نمودند تا شبکه‌ای را برای تخمین فراسنجهای آبخوانهای غیرهمورد تدوین کنند. در این تحقیق یک شبکه‌ی عصبی مصنوعی به همراه الگوریتم آموزش LM جهت تعیین فراسنجهای آبخوانهای آزاد طراحی شده است. تابع چاه بولتون (۱۹۶۳) (رابطه‌ی ۴) به این شبکه آموزش داده شد. همچنین، قبل از ساختن شبکه، PCA بر مجموعه‌ی داده‌های آموزش اعمال گردید؛ در نتیجه، ابعاد شبکه کاهش یافته و ساختار آن بدون توجه به تعداد داده‌های افت-زمان با آرایش (۳×۶×۳) ثابت گردید. دقت این شبکه با ۱۰۰/۰۰۰ مجموعه داده‌ی افت-زمان مصنوعی آزمایش شد. درنهایت، عملکرد این شبکه با استفاده از دو مجموعه‌ی داده آبکشی واقعی ارزیابی گردیده و نتایج حاصل از آنها با روش انطباق منحنی نمونه‌ی کامل مورد مقایسه قرار گرفتند. به نظر می‌رسد که این شبکه جایگزین کارآمد، دقیق و مناسبتری جهت تعیین فراسنجهای آبخوانهای آزاد باشد. در این تحقیق، شبکه‌ی طراحی شده در قالب یک برنامه رایانه‌ای (ANN4APE, Artificial Neural Network for Aquifer Parameter Estimation) در محیط نرم‌افزار متلب^۵ تهیه شد که با درخواست از نویسنده مسوول قابل دریافت می‌باشد. این برنامه داده‌های آزمون آبکشی را دریافت

لین و چن (۲۰۰۵) یک روش شبکه‌ی عصبی مصنوعی را جهت تخمین فراسنجهای آبخوان محبوس نشتی براساس ترکیب شبکه تابع پایه شعاعی^۱ و حل تحلیلی هانتوش و ژاکوب (۱۹۵۵) پیشنهاد کردند. همچنین لین و چن (۲۰۰۶) ترکیبی از روش شبکه‌ی عصبی و حل تحلیلی تایس (۱۹۳۵) را برای آبخوانهای محبوس غیرنشستی ارائه دادند. گرچه در مقایسه با شبکه‌های پیشین، فراسنجهای آبخوان با دقت و سرعت بیشتری تعیین گردیدند، 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 آبکشی آموزش داده و آزمایش می‌شد.

بر این اساس سامانی و همکاران (۲۰۰۷) یک شبکه‌ی عصبی مصنوعی ساده را پیشنهاد کردند که به دلیل جایگزین نمودن الگوریتم لونیبرگ-مارکوآرت^۲ به جای الگوریتم کاهش شیب^۳، و اعمال روش تحلیل مولفه‌های اصلی^۴ بر مجموعه داده‌های آموزش، ابعاد شبکه مستقل از تعداد داده‌های افت-زمان گردید و فراسنجهای آبخوان محبوس بدون محدودیتهای یاد شده تعیین گردید.

^۱ radial basis function network (RBFN)

^۲ Levenberg-Marquardt (LM)

^۳ gradient descent

^۴ principal component analysis (PCA)

^۵ MATLAB

تانژانت $[f(x) = (1 - e^{-2x}) / (1 + e^{-2x})]$ برای لایه‌های ورودی و پنهان، و تابع خطی $[f(x) = x, \text{ for all } x]$ برای لایه‌ی خروجی استفاده شده است (شکل ۴). فرایند تنظیم وزن بین نورونها در لایه‌های مختلف تا آن جا ادامه می‌یابد که خروجی شبکه عصبی محاسبه گردد. هر نورون خروجی، الگوی هدف^۹، یعنی (y_j) را، با الگوی محاسباتی^{۱۰} یعنی (\hat{y}_j) مقایسه نموده و اختلاف بین آنها را محاسبه می‌کند. به عبارت دیگر، فرایند آموزش آن قدر ادامه یافته و مراحل فوق به آن شمار تکرار می‌شود که وزنها و اریبیهای هر نورون تنظیم گردد و تابع هدف^{۱۱} یعنی (F) در معادله زیر به کمترین مقدار قابل قبول برسد: در این صورت، فرایند آموزش متوقف می‌شود (هیگین، ۱۹۹۹):

$$F = \frac{1}{2} \left[\sum_{j=1}^I (y_j(k) - \hat{y}_j(k))^2 \right] \quad (15)$$

I تعداد نورونها در لایه‌ی خروجی می‌باشد؛ بنابراین وزنهاى اولیه به دلخواه انتخاب گشته، سپس طی فرایند آموزش بطور منظم به روز می‌شوند. در این تحقیق، آموزش شبکه و تنظیم وزنها با استفاده از الگوریتم آموزش پس انتشار خطا و روش بهینه‌سازی LM انجام شده است. الگوریتم LM موثرترین روش بهینه‌سازی است و محققان زیادی از این روش در مسائل مختلف آب زیرزمینی با موفقیت استفاده کرده‌اند (مایر و دندی، ۱۹۹۹؛ مایر و دندی، ۲۰۰۰؛ توٹ و همکاران، ۲۰۰۰؛ کولوبالی و همکاران، ۲۰۰۱؛ دالیکوپولوس و همکاران، ۲۰۰۵؛ سامانی و همکاران، ۲۰۰۷).

کرده و مقادیر فراسنجهای آبخوان آزاد (T, S, K_h, K_v, S_y) را برای کاربر محاسبه می‌کند.

مواد و روشها

شبکه‌ی عصبی پیشخور^۱

FNN یک پردازشگر موازی است که شامل چند لایه و چند نورون در هر لایه می‌باشد. در این نوع شبکه‌های عصبی، نورونها در لایه‌های مختلف با وزنهاى سیناپتیکی به هم متصل گردیده و می‌توانند با استفاده از یک شبیه ریاضی هر تابع پیچیده و پیوسته‌ای را با دقت بالا تقریب بزنند (هورنیک و همکاران، ۱۹۸۹). یک شبکه‌ی عصبی پیشخور سه لایه از یک لایه‌ی ورودی، یک لایه‌ی پنهان و یک لایه‌ی خروجی تشکیل شده است (شکل ۳). قانون یادگیری بسیار رایج برای آموزش شبکه‌های عصبی پیشخور، الگوریتم پس انتشار^۲ می‌باشد که می‌تواند هر مساله‌ی خطی و غیر خطی پیچیده‌ای را شبیه‌سازی کند. در این روش علامت ورودی وارد لایه‌ی ورودی گشته، و پس از ضرب در وزنهاى سیناپتیکی به اولین لایه‌ی پنهان فرستاده می‌شود. خروجی ترکیب خطی (Z_1) ، و خروجی لایه‌ی پنهان (h_1) ، می‌توانند با استفاده از روابط زیر تعیین شوند:

$$Z_1 = b_1 + \sum_{i=1}^n X_i w_{i1} \quad (13)$$

$$h_1 = f(Z_1) \quad (14)$$

که X_i عنصر پردازشگر ورودی، b_1 اریبی^۳ بیان‌کننده‌ی حد آستانه واحد انتقال i ، w_{i1} بردار وزن بین نورون i در لایه‌ی ورودی و نورون 1 در لایه‌ی پنهان، n تعداد کل ورودیهای اعمال شده به نورون i در لایه‌ی ورودی، و f تابع فعالسازی^۴ غیرخطی برای تبدیل مجموع مولفه‌های ورودی وزن‌دار شده به بردار خروجی می‌باشد. تابع فعالسازی انواع مختلفی دارند از جمله: سیگموئید^۵، هیپربولیک تانژانت^۶، گاوسی^۷ و خطی^۸.

در شبکه‌ی عصبی طراحی شده، از تابع فعالسازی هیپربولیک:

¹ feed-forward neural network (FNN)

² back propagation

³ bias

⁴ activation function

⁵ sigmoid

⁶ hyperbolic tangent (tansig)


⁷ Gaussian

⁸ linear (purelin)


⁹ target pattern

¹⁰ calculated pattern

¹¹ objective function



شکل ۳- نمای طرح واره‌ای از یک شبکه‌ی عصبی مصنوعی سه لایه.



شکل ۴- توابع فعالسازی هیپربولیک تانژانت و خطی

شبکه‌ی عصبی ارزیابی می‌شود. بهترین نتیجه از عملکرد شبکه زمانی حاصل می‌گردد که شبکه طراحی شده کوچکترین خطای پیش‌بینی را برای مجموعه داده‌های آزمایش، که در مرحله آموزش استفاده نشده‌اند، ایجاد کند. بنابراین جهت جلوگیری از مساله‌ی آموزش بیش از حد^۵، بایستی در مرحله‌ی آموزش معیار خطا در شبکه را به دقت مورد بررسی قرار داد. بعد از مرحله‌ی آموزش و آزمایش، شبکه‌ی طراحی شده می‌تواند برای تشخیص الگو، طبقه‌بندی و تقریب تابع استفاده گردد؛ بنابراین، در مقاله‌ی حاضر یک شبکه‌ی عصبی پیش‌خور سه لایه، به همراه الگوریتم آموزش LM طراحی شده است تا تابع چاه مربوط به آبخوان آزاد را شبیه‌سازی نموده و مختصات

در این الگوریتم تابع تنظیم‌کننده‌ی وزنها $w(k+1)$ با استفاده از رابطه‌ی زیر تخمین زده می‌شود:

$$w(k+1) = w(k) - [J^T \times J + \mu I]^{-1} \times J^T \times e \quad (16)$$

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

پس از آن که فرایند آموزش کامل شده و وزنها و اربیه‌ها بین تمامی اتصالات نورونها و در لایه‌های مختلف تنظیم گردیدند، با استفاده از الگوهای آزمایش^۴ عملکرد

⁵ over training

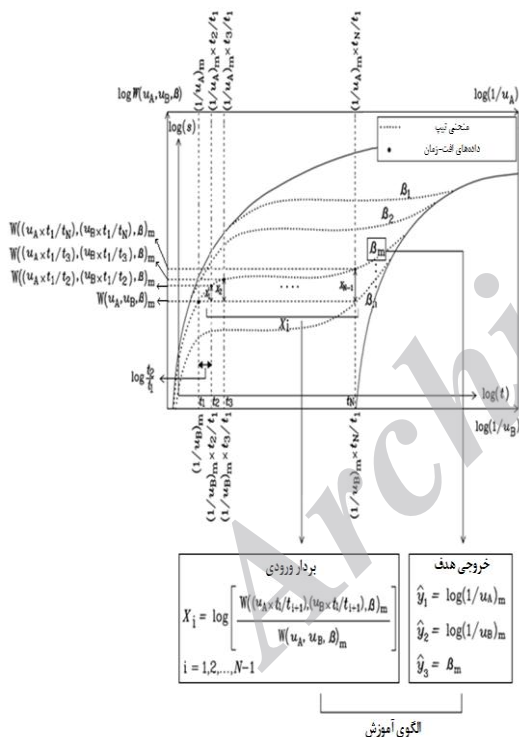
¹ Jacobin matrix
² performance criteria
³ learning rate
⁴ test patterns

ابعاد بردارهای ورودی در طول فرایند آموزش و آزمایش استفاده گردیده است.

نتایج و بحث

طراحی شبکه^۶

در این مقاله، با ترکیبی از شبکه‌ی عصبی و حل تحلیلی بولتون (۱۹۶۳)، و نیز اعمال روش PCA بر الگوهای آموزش تولید شده بر اساس شکل ۵، فرانسجهای آبخوان آزاد تعیین می‌شوند. این شبکه مختصات نقاط انطباقی را $[\text{Log}(\frac{1}{u_A})_m, \text{Log}(\frac{1}{u_B})_m, (\beta)_m]$ برای هر مجموعه داده آزمون آبکشی تولید می‌کند. طراحی شبکه شامل چهار مرحله می‌باشد: تولید الگوهای آموزش، ساخت شبکه، آزمایش شبکه با مجموعه داده‌های مصنوعی و صحت سنجی شبکه با داده‌های واقعی.



شکل ۵- نحوه‌ی تولید بردارهای ورودی و خروجی

(هدف) شبکه‌ی عصبی مصنوعی.

نقاط انطباق هر مجموعه داده‌ی آزمون آبکشی را تعیین کند.

تحلیل مولفه‌ی اصلی

PCA روشی موثر برای کاهش ابعاد مجموعه داده‌های حجیم به همراه حذف حداقل اطلاعات می‌باشد (کریس و زیوفنگ، ۲۰۰۴). این روش داده‌ها را به سامانه‌ی مختصات جدید تبدیل می‌کند، به گونه‌ای که بیشترین واریانس داده‌ها را به مختصات اول نسبت داده و مولفه‌ی اصلی اول^۱ را ایجاد می‌نماید. همچنین بیشترین واریانس دوم را به مختصات دوم اختصاص داده و مولفه‌ی اصلی دوم^۲ را می‌سازد؛ بنابراین، روند مزبور با همان ترتیب پیش می‌رود تا مولفه‌ای که کوچکترین مقدار واریانس را شامل می‌شود ایجاد گردد. وقتی تحلیل کامل شد، مولفه‌های حاصل، درجه‌ی متفاوتی از همبستگی را با متغیرهای مشاهده‌ای نشان خواهند داد، اما بطور کامل غیر مرتبط با یکدیگر می‌باشند. یکی از فرانسجهای در روش PCA، حداقل درصد واریانس^۳ است. با در نظر گرفتن یک حداقل درصد واریانس معین، می‌توان مولفه‌های اصلی را که سهم کمتری از این مقدار را نسبت به واریانس کل در مجموعه داده‌ها دارند، حذف کرد و بدین ترتیب، ابعاد مجموعه داده‌ها، بدون آن که اطلاعاتی از دست برود کاهش داده می‌شوند (سامانی و همکاران، ۲۰۰۷).

همچنین، جهت تعیین تعداد مولفه‌های اصلی از آزمون خرده سنگ^۴ هم می‌توان استفاده کرد. در این آزمون مقادیر ویژه^۵ یا درصد واریانس در مقابل مولفه‌ها رسم شده، و مؤلفه‌هایی که در محل تغییر شیب نمودار قرار گرفته و مقدار درصد واریانس به صفر میل می‌کند، در نظر گرفته نمی‌شوند (کتل، ۱۹۶۶). سامانی و همکاران (۲۰۰۷) با موفقیت روش PCA را برای کاهش ابعاد بردارهای ورودی استفاده کرده، و یک شبکه را با ساختار ثابت جهت تعیین دقیق فرانسجهای آبخوان محبوس طراحی نمودند. در این مقاله نیز از PCA جهت کاهش

¹ first PC

² second PC

³ minimum fraction variance

⁴ scree test

⁵ eigen values

⁶ network design

مرحله‌ی ۱- تولید الگوهای ورودی آموزش

جهت تولید الگوهای آموزش برای شبکه، ابتدا مقادیر $\text{Log}(\frac{1}{u_A})_m$ در محدوده‌ی $(-1/0 - 8/0)$ ، مقادیر $\text{Log}(\frac{1}{u_B})_m$ در محدوده‌ی $(-5/0 - 4/0)$ و مقادیر $(\beta)_m$ در محدوده‌ی $(0/0 - 7/0)$ مطابق منحنی نمونه‌ی کامل ارائه گردیده به وسیله‌ی نیومن (۱۹۷۵) که در شکل (۲) نشان داده شده است، به عنوان خروجی (هدف) شبکه عصبی انتخاب گردیدند. بنابراین $100/000$ مجموعه‌ی بردار ورودی آموزش با انتخاب بازه‌های $0/0045$ ، $0/0045$ و $0/1429$ به ترتیب برای $\text{Log}(\frac{1}{u_A})_m$ ، $\text{Log}(\frac{1}{u_B})_m$ و $(\beta)_m$ تولید شدند. سپس برای همه‌ی مجموعه‌های $[\text{Log}(\frac{1}{u_A})_m, (\beta)_m]$ با استفاده از رابطه‌ی ۴ محاسبه گردید. در مرحله‌ی بعد، الگوهای آموزش X_i با معادله زیر تولید شد:


$$X_i = \log \left[\frac{W(u_A \times t_1 / t_1 + 1), (u_B \times t_1 / t_1 + 1), \beta)_m}{W(u_A, u_B, \beta)_m} \right] \quad (17)$$

نمایه‌ی m به نقطه انطباق اشاره کرده و $i=1, 2, \dots, N$ که N تعداد داده‌های افت-زمان می‌باشد. شکل ۵ مراحل تولید مجموعه‌ی الگوهای آموزش شبکه را نشان می‌دهد. قبل از آن که مجموعه‌ی الگوهای ورودی آموزش

تولید شده به عنوان بردار ورودی به شبکه‌ی عصبی مصنوعی مورد استفاده قرار گیرند، باید بهنجار سازی گردیده سپس روش PCA (همان گونه که به وسیله‌ی سامانی و همکاران (۲۰۰۷) پیشنهاد شده) بر آنها اعمال گردد. جدول ۱ فراسنجهای PCA الگوهای آموزش آبخوان آزاد را نشان می‌دهد. مولفه‌های اصلی با در نظر گرفتن حداقل درصد واریانس $0/001$ استخراج شدند. همان گونه که مشاهده می‌شود، سه مولفه‌ی اصلی اول با هم $99/9999\%$ از واریانس کل داده‌های آموزش آبخوان آزاد را شامل می‌شوند. واریانس محاسبه شده به وسیله‌ی مولفه‌ی چهارم کوچکتر از حداقل درصد واریانس می‌باشد ($0/0000323 < 0/001$)؛ بنابراین، می‌توان از آن صرف نظر کرد. همچنین، نتایج آزمون اسکری (همان گونه که در شکل ۶ نشان داده شده است) تأیید می‌کند که سه مولفه‌ی اصلی اول باید به عنوان بردارهای ورودی منظور گردند. این موضوع نشان می‌دهد که عناصر بردار ورودی آموزش به ۳ عنصر کاهش یافته و تعداد نورونها در لایه‌ی ورودی شبکه می‌تواند با ۳ نورون به جای تعداد داده‌ها در داده‌های افت-زمان ثابت شود.

جدول ۱- فراسنجهای مولفه‌ی اصلی مجموعه آموزش آبخوان آزاد.

مولفه اصلی	مقدار ویژه	واریانس (%)	واریانس تجمعی (%)
PC1	۲۷/۸۳۴۰۴	۹۹/۴۰۷۳	۹۹/۴۰۷۳
PC2	۰/۱۶۵۴۸	۰/۵۹۱	۹۹/۹۹۸۳
PC3	۰/۰۰۰۴۴۸	۰/۰۰۱۶	۹۹/۹۹۹۹
PC4	$9/044 \times 10^{-7}$	$3/23 \times 10^{-6}$	۱۰۰
PC5	$1/10 \times 10^{-9}$.	۱۰۰



شکل ۶- نمودار خرده سنگ واریزه الگوهای آموزش حاصل از تحلیل مولفه‌های اصلی.

مرحله‌ی ۲- ساختن شبکه

یک شبکه‌ی عصبی سه لایه‌ی طراحی شد تا مختصات نقطه انطباق را $\hat{y}_1 = \log\left(\frac{1}{u_A}\right)_m$ ، $\hat{y}_2 = \log\left(\frac{1}{u_B}\right)_m$ و $\hat{y}_3 = (\beta)_m$ را تولید کند.

ابتدا الگوهای ورودی آموزش، مطابق با رابطه‌ی ۱۷ تولید، سپس تحلیل مولفه‌های اصلی بر آن اعمال گردید؛ آن گاه یک شبکه‌ی عصبی سه لایه با استفاده از الگوریتم LM آموزش داده شد تا مختصات نقطه‌ی انطباق را تولید کند. شبکه‌ی آموزش دیده برای آبخوان آزاد با ساختار بهینه‌ی (۳×۶×۳) تثبیت گردید. ۳، ۶ و ۳ به ترتیب به تعداد نورون در لایه‌ی ورودی، پنهان و خروجی اشاره می‌کند. فراسنجهای اعمال گردیده در طول فرایند آموزش در جدول ۲ نشان داده شده اند.

دو معیار زیر جهت ارزیابی دقت مختصات نقطه‌ی انطباق (هدف شبکه) به کار گرفته شدند:
الف) ریشه‌ی میانگین مربع خطای نسبی^۱ هدف تخمین زده شده:

$$RRMSE = 100 \times \sqrt{\frac{1}{n} \sum_{j=1}^n \left(\frac{y_j - \hat{y}_j}{y_j}\right)^2} \quad (18)$$

که \hat{y}_j هدف شبیه‌سازی شده یا محاسبه شده به وسیله‌ی شبکه، y_j هدف واقعی و n تعداد الگوها می‌باشد. کمترین مقدار RRMSE بیشترین دقت پیش‌بینی را نشان می‌دهد. $RRSME=0$ نشان‌دهنده‌ی دقت ۱۰۰٪ می‌باشد.
ب) ضریب تعیین^۲:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_j - \hat{y}_j)^2}{\sum_{i=1}^n (y_j - \bar{y})^2} \quad (19)$$


$R^2=1$ نشان دهنده‌ی ۱۰۰٪ تناسب بین مقادیر خروجی شبکه و مقادیر هدف می‌باشد. شکل ۷ ساختار شبکه‌ی پیشنهادی را نشان می‌دهد. به دلیل کاربرد PCA ابعاد الگوهای ورودی شبکه پیشنهادی به ۳ کاهش یافت؛ همچنین، این شبکه تنها با ۶ نورون در لایه‌ی پنهان آموزش داده شد. جدول ۳ مقادیر هر دو معیار ذکر شد را برای آموزش شبکه‌ی طراحی گردیده‌ی آبخوان آزاد عرضه می‌نماید. مقایسه‌ی مقادیر R^2 و RRMSE دقت و بازدهی بالای شبکه پیشنهادی را نشان می‌دهد.

جدول ۲- فراسنجهای به کار رفته در آموزش شبکه‌ی عصبی آبخوان آزاد.

مقدار	فراسنج
۰/۵	نرخ یادگیری
10^{-6}	معیار همگرایی
۱۰۰۰۰	حداکثر چرخه آموزش
۱۰۰۰۰۰	تعداد الگوهای آموزش


^۱relative root mean square error (RRMSE)

^۲Determination coefficient (R^2)



شکل ۷- ساختار شبکه‌ی عصبی آبخوان آزاد در مرحله‌ی آموزش.

RRMSE بسیار نزدیک به صفر می‌باشند (جدول ۴). این مقادیر نشان‌دهنده‌ی دقت بالای پیش‌بینی شبکه‌ی طراحی شده می‌باشد.



شکل ۸- ساختار شبکه‌ی عصبی آبخوان آزاد در مرحله-ی آزمایش.

مرحله‌ی ۴- صحت‌سنجی شبکه

در مرحله‌ی صحت‌سنجی از دو مجموعه‌ی داده‌ی آزمون آیکشی استفاده شده است تا دقت و عملکرد شبکه پیشنهادی ارزیابی گردد. مجموعه‌ی اول داده‌ها از تاد و میز (۲۰۰۵) و مجموعه‌ی دوم از دریدر (۱۹۶۶) اقتباس شده است. هر مجموعه داده‌ی افت-زمان به نسبت‌های افت تبدیل شده، سپس روش PCA بر آنها اعمال گردید. مجموعه‌ی داده‌های کاهش‌یافته به عنوان بردارهای ورودی به شبکه‌ی طراحی شده وارد گردید تا مقادیر مختصات نقطه انطباق اول $[\log(\frac{1}{u_A})_m, \log(\frac{1}{u_B})_m, \beta_m]$ تعیین شوند. با جایگزین کردن این مقادیر در توابع چاه مربوطه روابط (۳)، (۴)، (۵)، (۱۱) و (۱۲) و در نظر گرفتن داده‌ی افت-زمان اول $(s_m = s_1, t_m = t_1)$ که به وسیله‌ی لین و چن (۲۰۰۵) پیشنهاد شده بود، مقادیر فراسنجهای آبخوان تعیین گردیدند. جهت برطرف کردن خطای ناشی از در نظر گرفتن داده‌ی اول از داده‌های افت-زمان، نقطه-ی انطباق برای تمامی داده‌های افت-زمان به شرح زیر تنظیم گردید:

مرحله‌ی ۳- آزمایش شبکه

عملکرد شبکه‌ی آموزش دیده با ۱۰۰/۰۰۰ مجموعه-ی داده‌ی افت-زمان مصنوعی آزمایش گردید. این داده‌های مصنوعی برای آبخوان آزاد از ترکیب مقادیر مطلوب T, S, S_y, β به ترتیب در محدوده‌ی 10^2 تا 10^6 متر مربع در روز، 10^{-6} تا 10^{-3} ، 10^{-3} تا 10^{-1} و ۰ تا ۷ با استفاده از روابط ۳ تا ۶ تولید گشتند. داده‌های مصنوعی با استفاده از رابطه‌ی ۲۰ به نسبت‌های افت تبدیل شدند (لین و چن، ۲۰۰۵) که به عنوان بردارهای ورودی شبکه آموزش دیده (X_i) استفاده شدند:

$$X_i = \log(s_{i+1}) - \log(s_i) = \log\left(\frac{s_{i+1}}{s_i}\right) \quad (20)$$

s_i افت ثبت شده در زمان t_i می‌باشد. با اعمال PCA بر بردارهای ورودی (X_i) ، نسبت‌های افت کاهش‌یافته $\text{PCA}\left[\log\left(\frac{s_{i+1}}{s_i}\right)\right]$ تولید شدند. شکل ۸ ساختار شبکه‌ی طراحی شده را در مرحله‌ی آزمایش نشان می‌دهد. شبکه‌ی آموزش داده شده، نسبت‌های افت کاهش‌یافته (نسبت‌های افتی که PCA بر آنها اعمال گردید) را دریافت کرده و مقادیر $\log(\frac{1}{u_A})_m, \log(\frac{1}{u_B})_m$ و β_m را محاسبه می‌کند که به T, S, S_y تبدیل می‌شوند. شکل ۹ نمودارهای پراکنش^۱ و بهترین خط تناسب^۲ را بین فراسنجهای هدف و محاسبه شده (T, S, S_y, β) به وسیله‌ی شبکه‌ی آموزش داده شده آبخوان آزاد را عرضه می‌نماید. همان طور که در این شکلها نشان داده شده است، این شبکه پیشنهادی می‌تواند فراسنجهای آبخوان را با دقت بالایی در محدوده‌ی وسیعی از مقادیر محاسبه کند. در تمامی نمودارها مقدار R^2 مساوی یک و مقدار

^۱ scatter plots

^۲ best-fitted line

جدول ۳- RRMSE (%) و R² مربوط به مقادیر $\text{Log}(\frac{1}{u_A})_m$ ، $\text{Log}(\frac{1}{u_B})_m$ و $(\beta)_m$ شبکه‌ی عصبی طراحی شده در مرحله‌ی آموزش آبخوان آزاد.

RRMSE (%)	فراسنجه‌ها
$1/45 \times 10^{-4}$	$\text{Log}(1/u_A)_m$
$1/45 \times 10^{-4}$	$\text{Log}(1/u_B)_m$
$1/72 \times 10^{-3}$	$(\beta)_m$

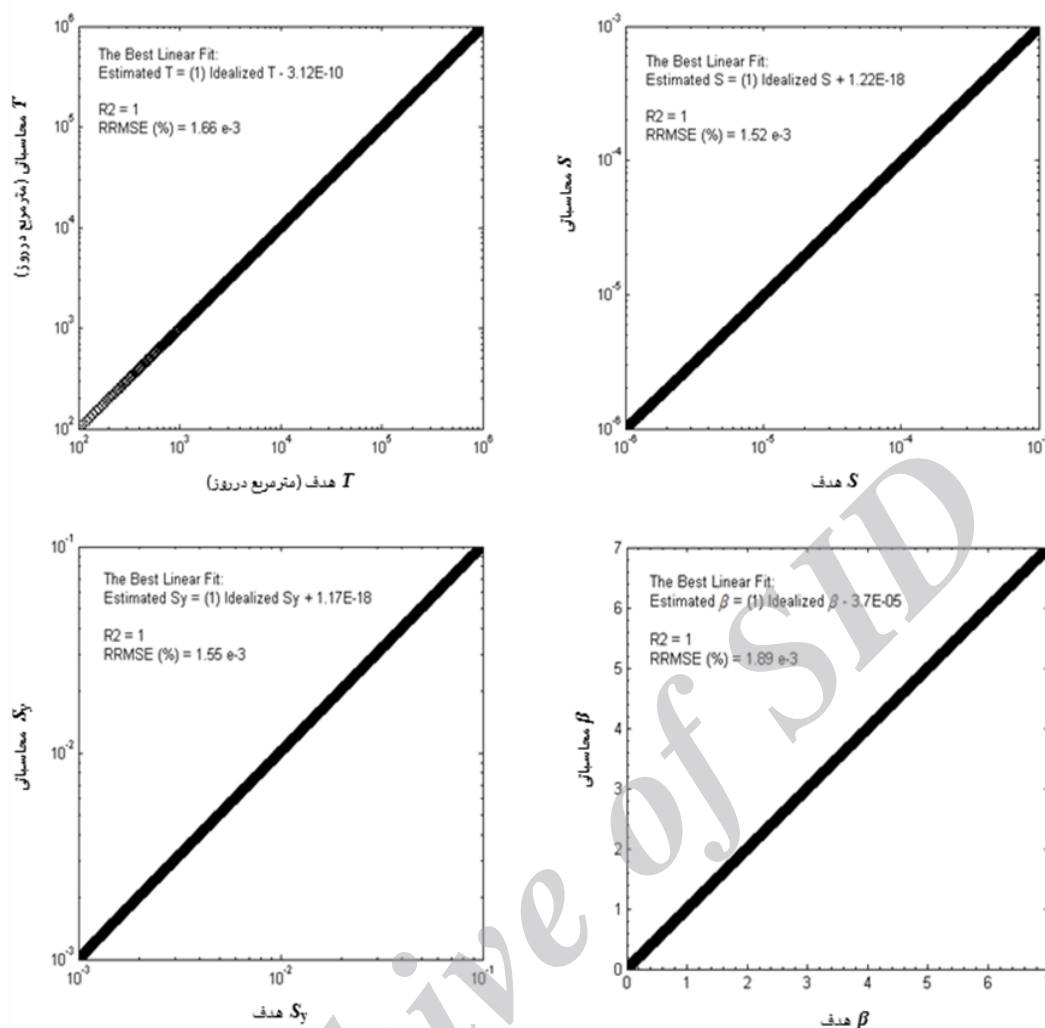
R² برای هر سه فراسنجه فوق برابر با ۱ محاسبه شد.

جدول ۴- RRMSE (%) و R² فراسنجه‌های محاسبه شده‌ی آبخوان آزاد با استفاده از شبکه‌ی طراحی گردیده در مرحله آزمایش.


RRMSE (%)	فراسنجه‌ها
$1/66 \times 10^{-3}$	T
$1/52 \times 10^{-3}$	S
$1/55 \times 10^{-3}$	S _y
$1/89 \times 10^{-3}$	β

R² برای هر چهار فراسنجه فوق برابر ۱ محاسبه شد.

Archive of SID



شکل ۹- مقادیر فراسنجهای هدف در مقابل مقادیر محاسبه شده‌ی آبخوان آزاد با کاربرد شبکه‌ی عصبی طراحی گردیده.



شکل ۱۰- نمودار $RRMSE$ داده‌های مختلف افت دو مجموعه داده آزمون آبکشی واقعی.

جدول ۵- داده‌های افت- زمان آزمون پمپاژ اول (تاد و میز، ۲۰۰۵).

زمان (دقیقه)	افت (فوت)	زمان (دقیقه)	افت (فوت)	زمان (دقیقه)	افت (فوت)	زمان (دقیقه)	افت (فوت)
۰/۱۶۵	۰/۱۲	۱/۶۸	۰/۸۲	۱۰	۱/۰۲	۲۰۰	۱/۵۲
۰/۲۵	۰/۱۹۵	۱/۸۵	۰/۸۴	۱۲	۱/۰۳	۲۵۰	۱/۵۹
۰/۳۴	۰/۲۵۵	۲	۰/۸۶	۱۵	۱/۰۴	۳۰۰	۱/۶۵
۰/۴۲	۰/۳۳	۲/۱۵	۰/۸۷	۱۸	۱/۰۵	۳۵۰	۱/۷
۰/۵	۰/۳۹	۲/۳۵	۰/۹	۲۰	۱/۰۶	۴۰۰	۱/۷۵
۰/۵۸	۰/۴۳	۲/۵	۰/۹۱	۲۵	۱/۰۸	۵۰۰	۱/۸۵
۰/۶۶	۰/۴۹	۲/۶۵	۰/۹۲	۳۰	۱/۱۳	۶۰۰	۱/۹۵
۰/۷۵	۰/۵۳	۲/۸	۰/۹۳	۳۵	۱/۱۵	۷۰۰	۲/۰۱
۰/۸۳	۰/۵۷	۳	۰/۹۴	۴۰	۱/۱۷	۸۰۰	۲/۰۹
۰/۹۲	۰/۶۱	۳/۵	۰/۹۵	۵۰	۱/۱۹	۹۰۰	۲/۱۵
۱	۰/۶۴	۴	۰/۹۷	۶۰	۱/۲۲	۱۰۰۰	۲/۲
۱/۰۸	۰/۶۷	۴/۵	۰/۹۷۵	۷۰	۱/۲۵	۱۲۰۰	۲/۲۷
۱/۱۶	۰/۷	۵	۰/۹۸	۸۰	۱/۲۸	۱۵۰۰	۲/۳۵
۱/۲۴	۰/۷۲	۶	۰/۹۹	۹۰	۱/۲۹	۲۰۰۰	۲/۴۹
۱/۳۳	۰/۷۴	۷	۱	۱۰۰	۱/۳۱	۲۵۰۰	۲/۵۹
۱/۴۲	۰/۷۶	۸	۱/۰۱	۱۲۰	۱/۳۶	۳۰۰۰	۲/۶۶
۱/۵	۰/۷۸	۹	۱/۰۱۵	۱۵۰	۱/۴۵		

جدول ۶- فراسنجهای محاسبه شده با استفاده از شبکه عصبی طراحی گردیده و روش انطباق منحنی نمونه‌ی کامل در آبخوان آزاد و مقادیر $RRMSE$ (%) (آزمون آبکشی اول (تاد و میز، ۲۰۰۵)).

فراسنجهای آبخوان	روشها	
	روش نموداری انطباق منحنی نمونه‌ی کامل	شبکه عصبی طراحی شده
T (ft ² /day)	۲۹۹۰۰	۳۶۹۵۲
S (10 ⁻³)	۲/۵۷	۳
S_y	۰/۰۲	۰/۳
K_h (ft/day)	۱۱۶۰	۱۴۷۸
K_v (ft/day)	۸/۲۰	۱۲/۱
β	۰/۰۶	۰/۰۷
$RRMSE$ (%)	۱۹/۷	۰/۰۲۵

جدول ۷- داده‌های افت-زمان آزمون آبکشی دوم (دریدر، ۱۹۶۶).

زمان (دقیقه)	افت (متر)	زمان (دقیقه)	افت (متر)
۰	۰	۴۱	۰/۱۲۸
۱/۱۷	۰/۰۰۴	۵۱	۰/۱۳۳
۱/۳۴	۰/۰۰۹	۶۵	۰/۱۴۱
۱/۷	۰/۰۱۵	۸۵	۰/۱۴۶
۲/۵	۰/۰۳۰	۱۱۵	۰/۱۶۱
۴	۰/۰۴۷	۱۷۵	۰/۱۶۱
۵	۰/۰۵۴	۲۶۰	۰/۱۷۲
۶	۰/۰۶۱	۳۰۰	۰/۱۷۳
۷/۵	۰/۰۶۸	۳۷۰	۰/۱۷۳
۹	۰/۰۶۴	۴۳۰	۰/۱۷۹
۱۴	۰/۰۹۰	۴۸۵	۰/۱۸۳
۱۸	۰/۰۹۸	۶۶۵	۰/۱۸۲
۲۱	۰/۱۰۳	۱۳۴۰	۰/۲۰۰
۲۶	۰/۱۱۰	۱۴۹۰	۰/۲۰۳
۳۱	۰/۱۱۵	۱۵۲۰	۰/۲۰۴

جدول ۸- فراسنجهای محاسبه شده با استفاده از شبکه‌ی عصبی طراحی شده و روش انطباق منحنی نمونه‌ی کامل در آبخوان آزاد و مقادیر RRMSE (%) (آزمون آبکشی دوم (دریدر، ۱۹۶۶)).

فراسنجهای آبخوان	روشها	
	روش نموداری انطباق منحنی نمونه‌ی کامل	روش عصبی طراحی شده
T (m ² /day)	۱۴۴۷	۲۷۲۴
S (10 ⁻⁴)	۵/۲	۱/۱
S_y	۰/۰۰۴۹	۰/۰۱
K_h (m/day)	۷۳	۱۲۹/۷۳
K_v (m/day)	۰/۰۴	۰/۱۴
β	۰/۰۱	۰/۰۲
RRMSE (%)	۱۷/۸۴	۰/۰۶۲۲

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

با جایگزین کردن این مقادیر در معادلات (۳)، (۴)، (۵)، (۱۱) و (۱۲) مقادیر فراسنجهای آبخوان آزاد (T , S , K_h and K_v) تعیین شدند. آن داده‌ی افت $\left[\left(\frac{1}{u_A} \right)_j, \left(\frac{1}{u_B} \right)_j, W_j, s_j, t_j \right]$ که حداقل مقدار RRMSE را به دست می‌دهد، به عنوان نقطه‌ی انطباق بهینه انتخاب می‌شود. این داده مقادیر فراسنجهای آبخوان را با بیشترین دقت ممکن تعیین می‌کند.

$$\hat{f}_1 = \log \left(\frac{1}{u_A} \right)_j = \log \left[\left(\frac{1}{u_A} \right)_m \times \left(\frac{t_j}{t_1} \right) \right], j = 1, 2, \dots, N \quad (22)$$

$$\left(\frac{1}{u_A} \right)_j = \left[\left(\frac{1}{u_A} \right)_m \times \left(\frac{t_j}{t_1} \right) \right] = 10^{\hat{f}_1} \quad (23)$$

$$\hat{f}_2 = \log \left(\frac{1}{u_B} \right)_j = \log \left[\left(\frac{1}{u_B} \right)_m \times \left(\frac{t_j}{t_1} \right) \right], j = 1, 2, \dots, N \quad (24)$$

$$\left(\frac{1}{u_B} \right)_j = \left[\left(\frac{1}{u_B} \right)_m \times \left(\frac{t_j}{t_1} \right) \right] = 10^{\hat{f}_2} \quad (25)$$

$$W[(u_A)_j, (u_B)_j, (\beta)_m] = W \left(\frac{1}{10^{\hat{f}_1}}, \frac{1}{10^{\hat{f}_2}}, \hat{f}_2 \right) \quad (26)$$

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

نتیجه‌گیری

در این مقاله یک شبکه‌ی عصبی مصنوعی با الگوریتم آموزش LM برای تعیین فراسنجهای آبخوانهای آزاد طراحی شد. تابع چاه بولتون به شبکه‌ی طراحی گردیده آموزش داده شد. همچنین، قبل از ساختن شبکه، PCA بر مجموعه داده‌های آموزش اعمال گردید تا ابعاد الگوهای ورودی آموزش با در نظر گرفتن حداقل درصد واریانس ۰/۰۱٪ کاهش یابد. نتایج نشان دادند که سه مولفه‌ی اصلی اول در مجموع ۹۹/۹۹۹۹٪ از واریانس کل داده‌های آموزش آبخوانهای آزاد را به خود اختصاص می‌دهند؛ در نتیجه، با حفظ معیار همگرایی مورد نظر (دقت مطلوب آموزش شبکه) در حد 10^{-6} ، ابعاد لایه‌های ورودی و پنهان در شبکه طراحی شده به ترتیب به ۳ و ۶ کاهش یافت، بنابراین، ساختار شبکه‌ی طراحی شده برای آبخوان آزاد صرف نظر از تعداد داده‌های افت-زمان با آرایش (۳×۶×۳) ثابت گردید. دقت شبکه‌ی طراحی شده با ۱۰۰/۰۰۰ مجموعه‌ی داده افت-زمان مصنوعی آزمایش گردید. سرانجام، عملکرد این شبکه با استفاده از دو مجموعه داده آزمون آبکشی واقعی با روش انطباق منحنی نمونه‌ی کامل مقایسه شد. بطور خلاصه، این شبکه‌ی پیشنهادی نسبتهای افت کاهش یافته را به عنوان ورودی دریافت نموده و مختصات نقطه انطباق مربوط به داده اول را به عنوان خروجیها تولید می‌کند. این خروجیها با هر کدام از داده‌های افت-زمان ترکیب شده و فراسنجهای آبخوان محاسبه می‌گردند. با استفاده از داده‌های افت-زمان، و هر مجموعه از فراسنجهای آبخوان، داده‌های افت تولید شده، با داده‌های افت واقعی مقایسه می‌گردند و مقدار RRMSE محاسبه می‌شود. فراسنجهایی که کمترین مقدار RRMSE را ایجاد می‌کنند به عنوان دقیقترین تخمین از مقادیر فراسنجهای آبخوان انتخاب می‌گردند. شبکه‌ی طراحی شده به عنوان یک روش جایگزین سریع، دقیق و با کاربرد آسان نسبت به روشهای نموداری انطباق منحنی نمونه‌ی کامل توصیه می‌گردد که فراسنجهای آبخوانهای آزاد را تعیین می‌کند.

جهت تعیین آبدهی ویژه (S_y) در روش انطباق منحنی نمونه‌ی کامل، مختصات نقطه‌ی انطباق دوم لازم می‌باشد. از آن جا که بین منحنیهای نمونه‌ی کامل نیومن A و B تقریباً سه دوره‌ی لگاریتمی فاصله وجود دارد، با جایگزین کردن قابلیت انتقال محاسبه شده (T) و $\left[\left(\frac{1}{u_B} \right) \times 10^3 \right]$ در رابطه‌ی مربوطه (رابطه ۶) و محاسبه‌ی داده افت-زمان مربوطه $[(s_j), (t_j \times 10^3)]$ مقدار آبدهی ویژه تعیین می‌گردد.

آزمایش آبکشی اول: این آزمایش در یک آبخوان آزاد با ضخامت اشباع ۲۵ فوت انجام شد که در آن یک چاه آبکشی کامل با نرخ ثابت ۱۴۴/۴ فوت مکعب بر دقیقه آبکشی می‌شد. داده‌های افت-زمان در یک چاه مشاهده‌ای در فاصله‌ی ۷۳ فوتی از چاه آبکشی ثبت گردیدند (جدول ۵). مقادیر فراسنجهای آبخوان (T, S, S_y, K_h, K_v) با استفاده از شبکه‌ی طراحی گردیده تعیین، و نتایج در جدول ۶ ارائه شده و با مقادیر حاصل از روش انطباق منحنی نمونه‌ی کامل مقایسه گردیده اند. مقادیر RRSME و R^2 دقت زیاد شبیه پیشنهادی را نشان می‌دهد. در این آزمون آبکشی، داده‌ی هفتم از داده‌های افت-زمان، که کمترین مقدار RRMSE را ایجاد نمود، به عنوان نقطه انطباق بهینه انتخاب گردید (شکل ۱۰).

آزمایش آبکشی دوم: این آزمون آبکشی در آبخوان آزاد ونولتن^۱ واقع در هلند با ضخامت اشباع ۲۱ متر انجام گرفت، که در آن یک چاه کامل با نرخ ثابت ۸۷۳ متر مکعب بر روز آبکشی می‌شد. داده‌های افت-زمان در یک چاه مشاهده‌ای در فاصله ۹۰ متری از چاه آبکشی ثبت گردیدند (جدول ۷). مقادیر فراسنجهای آبخوان (T, S, S_y, K_h, K_v) با استفاده از شبکه‌ی طراحی شده تعیین و با مقادیر محاسبه گردیده با روش انطباق منحنی نمونه‌ی کامل مقایسه شد، نتایج آن در جدول ۸ ارائه گردیده‌اند که مقدار RRMSE بسیار کوچکی را نشان می‌دهد. در این آزمون آبکشی داده‌ی نوزدهم از داده افت-زمان به عنوان نقطه‌ی انطباق بهینه انتخاب گردید (شکل ۱۰).

¹ Vennebulden

- using radial basis function network approach. *J Chinese Inst. Eng.* 28: 241-249.
13. Lin, G.F., and G.R. Chen. 2006. An improved neural network approach to the determination of aquifer parameters. *J. Hydrol.* 316: 281-289.
 14. Lin, H.T., K.Y. Ke, Ch.H. Chen, Sh.Ch. Wu, and Y.Ch. Tan. 2010. Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrol. Process.* 24: 3237-3250.
 15. McCulloch, W., and W. Pitts. 1943. A logical calculus of the ideas immanent in nervous activity. *Bull Math Biophys.* 5: 113-115.
 16. Maier, H.R., and G.C. Dandy. 1999. Empirical comparison of various methods for training feed-forward neural networks for salinity forecasting. *Water Resour Res.* 32: 2591-2596.
 17. Maier, H.R., and G.C. Dandy. 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.
 18. Neuman, S.P. 1972. Theory of flow in unconfined aquifers considering delayed response of the water table. *Water Resour Res.* 8: 1031-1045.
 19. Neuman, S.P. 1973. Supplementary comments on theory of flow in unconfined aquifers considering delayed response of the water table. *Water Resour. Res.* 9: 1102-1103.
 20. Neuman, S.P. 1975. Analysis of pumping test data from anisotropic unconfined aquifers considering delayed gravity response. *Water Resour Res.* 11: 329-342.
 21. Neuman, S.P. 1979. Perspective on delayed yield. *Water Resour Res* 15: 899-908.
- منابع
1. Boulton, N.S. 1954. The drawdown of the water table under non-steady conditions near a pumped well in an unconfined formation. *Proc, Instn. Civ. Eng.* 3: 574.
 2. Boulton, N.S. 1963. Unsteady radial flow to a pumped well allowing for delayed yield from storage. 472-477.
 3. Cattell, R.B. 1966. The scree test for the number of factors. *Multivar. Behav. Res.* 1: 245-276.
 4. Chris, D., and H. Xiaofeng. 2004. K-Means clustering via principal component analysis. In proceedings of the 21st Int. Conf. Machine Learning, Banff, Canada.
 5. Coulibaly, P., F. Anctil, R. Aravena, and B. Bobee. 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resour. Res.* 37: 885-896.
 6. Daliakopoulos, I.N., P. Coulibaly, and I.K. Tsanis. 2005. Groundwater level forecasting using artificial neural networks. *J Hydrol.* 309: 229-240.
 7. De Ridder, N.A. 1966. Analysis of the pumping test De Vennebulten near Varsseveld (in Dutch). *Inst. Land and Water Manag. Res, Wageningen*, Report no. 335, 5 pp.
 8. Gambolati, G. 1976. Transient free surface flow to a well: An analysis of theoretical solutions. *Water Resour. Res.* 12: 27-39.
 9. Hantush, M.S., and C.E. Jacob. 1955. Non-steady radial flow in an infinite leaky aquifer. *Trans Am Geophys Union.* 36: 95-100.
 10. Haykin, S. 1999. *Neural networks: a comprehensive foundation.* Prentice-Hall: Englewood Cliffs, N.J.
 11. Hornik, K., M. Stinchcombe, and H. White. 1989. Multilayer feed forward networks are universal approximators. *Neural Networks.* 2: 359-366.
 12. Lin, G.F., and G.R. Chen. 2005. Determination of aquifer parameters

22. Prickett, T.A. 1965. Type curve solution to aquifer tests under water table conditions. *Ground Water*. 3.
23. Samani, N., M. Gohari-Moghadam, and A.A. Safavi. 2007. A simple neural network model for the determination of aquifer parameters. *J Hydrol*. 340: 1–11.
24. Streltsova, T.D. 1972a. Unconfined aquifer and slow drainage. *J Hydrol*. 16: 117-124.
25. 7. Streltsova, T.D. 1972b. Unsteady radial flow in an unconfined aquifer. *Water Resour. Res.* 8: 1059-1066.
26. Streltsova, T.D. 1973. On the leakage assumption applied to equations of groundwater flow. *J. Hydrol.* 20: 237-253.
27. Streltsova, T. D. 1976. Progress in research on well hydraulics. *Advances in groundwater hydrology*, Am. Water Resour. Assoc. 15-28.
28. 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.
29. Todd, D. K., and L. W. Mays. 2005. *Groundwater hydrology*. John Wiley & Sons, Inc., N.Y, USA.
30. Toth, E., A. Brath, and A. Montanari. 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *J. Hydrol.* 239: 132–147.

Archive