



دانشگاه آزاد اسلامی واحد اهر
فصلنامه‌ی علمی فضای جغرافیایی

سال بیست و دوم، شماره‌ی ۷۸
تابستان ۱۴۰۱، صفحات ۱۴-۱

DOI:10.52547/GeoSpa.22.2.1

مرحمت سبقتی^۱
* هیراد عبقری^۲

پیش‌بینی سطح آبخوان با استفاده از شبکه عصبی تابع بنیادی رگرسیونی و ماشین بردار پشتیبان (دشت آمل- بابل)

تاریخ پذیرش: ۱۳۹۷/۰۸/۰۳

تاریخ دریافت: ۱۳۹۶/۰۷/۲۷

چکیده

تعیین عمق سفره آب و توجه به تغییرات سطح ایستابی آبخوان در مناطق مختلف از جمله مناطق جلگه‌ای و دشتی جهت بهره‌برداری امری ضروری می‌باشد، شناخت رفتار سیستم آب زیرزمینی و پیش‌بینی سطح نوسانات آن یکی از مهم‌ترین اقدامات به منظور دستیابی به مدیریت جامع و پایدار منابع آب زیرزمینی در مناطق مختلف جهان می‌باشد. بنابراین برای استفاده بهینه از منابع آب‌های زیرزمینی باید ابتدا به درستی مورد مطالعه قرار گیرد تا در مواقع بحرانی شرایط تعادل آب‌های زیرزمینی حفظ شود. در این تحقیق برای پیش‌بینی سطح آب زیرزمینی با استفاده از آمار سالانه ۹۵ حلقه چاه مطالعاتی در دشت آمل-بابل در استان مازندران با استفاده از شبکه عصبی تابع شعاعی احتمالی و ماشین بردار پشتیبان مورد استفاده قرار گرفت. در ادامه با روش آزمون و خطا از بین عوامل موثر در پیش‌بینی سطح آبخوان با استفاده از بارندگی، فاصله از منابع آب و قابلیت تشکیل آبخوان شبکه بهینه برای آزمون به دست آمد. نتایج حاصل از پژوهش نشان داد که هر دو مدل می‌توانند سطح آب زیرزمینی را با دقت نسبتاً بالایی پیش‌بینی کنند هرچند مدل تابع شعاعی احتمالی می‌تواند یک ابزار مفید برای شبیه‌سازی و پیش‌بینی آب‌های زیرزمینی باشد، زیرا ضریب همبستگی آن نسبتاً مناسب و برابر ۰/۸۲ و متوسط قدر مطلق خطای آن کوچک‌تر و برابر با ۱/۹۴ می‌باشد.

کلید واژه‌ها: آب زیرزمینی، چاه‌های مطالعاتی، ماشین بردار پشتیبان، منابع آب.

E-mail: sebhghati.marhamat@gmail.com

۱- مهندس مشاور طرح و سازه شفارود، گیلان .

E-mail: h.abghari@urmia.ac.ir

۲- گروه مرتع و آبخیزداری، دانشگاه ارومیه، دانشکده منابع طبیعی. (نویسنده مسئول).

مقدمه

آب زیرزمینی بخشی از چرخه‌ی آب را تشکیل می‌دهد و منبع قابل اطمینانی برای تأمین آب مورد نیاز انسان محسوب می‌شود و همچنین در ایران، عمده آب مصرفی در بخش‌های شرب، کشاورزی و صنعت از آب زیرزمینی تأمین می‌گردد. با توجه به شرایط کشور ایران به لحاظ کمبود منابع آب سطحی، استفاده از منابع آب زیرزمینی برای تأمین آب مورد توجه قرار گرفته است؛ اما تاکنون مدل‌های زیادی جهت پیش‌بینی سطح آب زیرزمینی به کار برده شده است، از جمله این مدل‌ها می‌توان به مدل‌های سری زمانی تجربی و مدل‌های فیزیکی اشاره کرد (Mohtasham et al., 2010: 14). ولی هنگامی که رفتار دینامیکی یک سیستم هیدرولوژیکی با گذشت زمان تغییر می‌کند مدل‌های یاد شده برای پیش‌بینی پارامترهای منابع آب توانایی کافی نداشته و مدل‌های مناسبی نیستند (Bierkens, 1998: 14). به‌عنوان مثال، Mohammadi (2008: 130) برای پیش‌بینی سطح آب زیرزمینی از مدل‌های فرآیندی (MODFLOW) استفاده نمود و به نتیجه رسید که مدل‌های مبتنی بر هوش مصنوعی (در این حالت شبکه‌های عصبی مصنوعی) در مقایسه با مدل‌های فرآیندی نتیجه دقیق‌تری را ارائه می‌دهند. بررسی منابع اخیر توسط نگارندگان نشان داد که از روش‌های هوش مصنوعی بیش‌تر شبکه‌های عصبی مصنوعی برای پیش‌بینی سطح آب زیرزمینی مورد استفاده قرار گرفته است (ANN) یا (Banerjee., et al., 2009: 7; Sethiet et al., 2010: 7) شبکه‌های عصبی مصنوعی (ANN) یا روش‌های هوش مصنوعی (روش‌های مورد نظر) از جمله یکی از دستاوردهایی هستند که با الگوبرداری از شبکه عصبی مغز انسان، قادرند پدیده‌های پیچیده و ناشناخته را به خوبی بررسی نمایند (Minhaj, 2002: 110). به باور بیش‌تر پژوهشگران شبکه عصبی مصنوعی به دو دلیل عمده در بررسی مسایل ناشناخته و پیچیده، عملکرد خوبی دارد: اول این‌که با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین ورودی و خروجی داده‌ها برقرار می‌کند (Hsu et al., 1995: 13). همچنین در قیاس با دیگر الگوها، حساسیت کم‌تری نسبت به وجود خطا در اطلاعات ورودی نشان می‌دهد (Elshorbagy and Simonovic, 2000: 10; Coulibaly et al., 2000: 13). از سوی دیگر Corrado et al (2008: 686-696) با استفاده از شبکه‌های عصبی برای پیش‌بینی سطح تراز آب در چاه‌های آرتزین پرداختند و نتایج بررسی آن‌ها نشان داد که شبکه نهایی قادر به پیش‌بینی تراز آب در دامنه قابل قبولی است. Anctil et al., (2004: 30) با مقایسه نتایج ANN با شبکه پرسپترون چندلایه و یک مدل مفهومی ترکیبی بارش رواناب در پیش‌بینی سیل دریافتند که شبکه پرسپترون چندلایه ارزیابی بهتری دارد. (Khorshid Doost (2013: 8) با بررسی بازسازی سری‌های زمانی دمای حداکثر و حداقل روزانه با استفاده از روش نزدیک‌ترین همسایه و شبکه عصبی مصنوعی (مطالعه موردی غرب استان تهران) با بررسی کلیه ایستگاه‌های مورد مطالعه روش شبکه عصبی متوسط خطای مطلق کم‌تری را نسبت به روش نزدیک‌ترین همسایه دارد. در روش نزدیک‌ترین همسایه با افزایش فاصله ایستگاه‌ها خطای برآورد افزایش می‌یابد. همچنین دقت هر دو روش در تخمین دمای حداکثر روزانه بیش‌تر از دمای حداقل روزانه می‌باشد

(Kalte & Gholami (2013). تغییرات سطح آب زیرزمینی سواحل جنوبی دریای خزر را با استفاده از ماشین بردار پشتیبان مورد بررسی قرار دادند و از این پژوهش دریافتند که ماشین بردار پشتیبان توانایی نسبتاً بالایی در پیش‌بینی سطح آب زیرزمینی دارد. (Feyzolapor (2017، در تحقیقی با تخمین بار معلق رسوبی رودخانه سنگورچای با استفاده از دو مدل شبکه عصبی مصنوعی دریافت که برای تعیین قابلیت پارامتر RMSE در صحت سنجی هر یک از مدل‌ها، از سیستم اطلاعاتی آکائیک (AIC) استفاده شده و مشاهده شد که مدل RBF با برخورداری از مقادیر آکائیک معادل ۱۰۴۲ از قابلیت بهتری برخوردار است. از سوی دیگر از کاربردهای اخیر شبکه عصبی و ماشین بردار پشتیبان در زمینه آب‌های زیرزمینی می‌توان به تحقیقات (Ramezani Charmahineh & Zunemat Kermani (2017. اشاره کرد که با بررسی کارایی ماشین بردار پشتیبان، شبکه پرسپترون چندلایه و رگرسیون خطی چند متغیره دریافتند ماشین بردار پشتیبان (SVR-RBF) با ترکیب لایه‌های ورودی متشکل از تراز سطح آب زیرزمینی، دما، تبخیر و بارش بر سایر مدل‌ها برتری داشته است و عملکرد کلی مدل‌های پرسپترون چندلایه (MLP)، ماشین بردار پشتیبان (SVR-RBF) و رگرسیون خطی چند متغیره (SVR-Linear) برای معیار ارزیابی نش ساکلیف (NS) به ترتیب برابر ۰/۷۰۳، ۰/۶۵۶ و ۰/۶۵۵ می‌باشد. (Feyzolahpour (2017، برای تخمین بار معلق رسوبی رودخانه سنگورچای با استفاده از دو مدل شبکه عصبی پیش‌خور الگوریتم پس از انتشار خطا و تابع پایه شعاعی بنیادی مصنوعی دریافت که تابع شعاعی بنیادی نتایج مطلوبی را ارائه می‌دهد. (Li et al (2016، برای یک طرح مدیریت منابع آب در شهر لونگیان در استان فوجیان (جنوب چین) به پیش‌بینی سطح آب زیرزمینی با مدل‌های عاملی تابع شعاعی (RBFNN) و مدل کلاسیک GM (1,1) پرداختند که نتایج تحقیقات آن‌ها نشان داد هر دو مدل دقت نسبتاً بالایی در پیش‌بینی سطح آب زیرزمینی دارند.

هدف از این تحقیق پیش‌بینی سطح تراز آبخوان با استفاده از شبکه عصبی تابع بنیادی (رگرسیون تعمیم یافته/احتمالی^۳) و ماشین بردار پشتیبان^۴ که روش‌های هوش مصنوعی می‌باشد یکی از فواید این شبکه‌ها یادگیری سریع آن‌ها نسبت به سایر روش‌های عصبی مصنوعی می‌باشد؛ بنابراین در این پژوهش از دو روش استفاده شد تا بر اساس نتایج حاصل از آن در تحقیقات آتی روش‌هایی که برای پیش‌بینی دقیق‌ترند استفاده گردد.

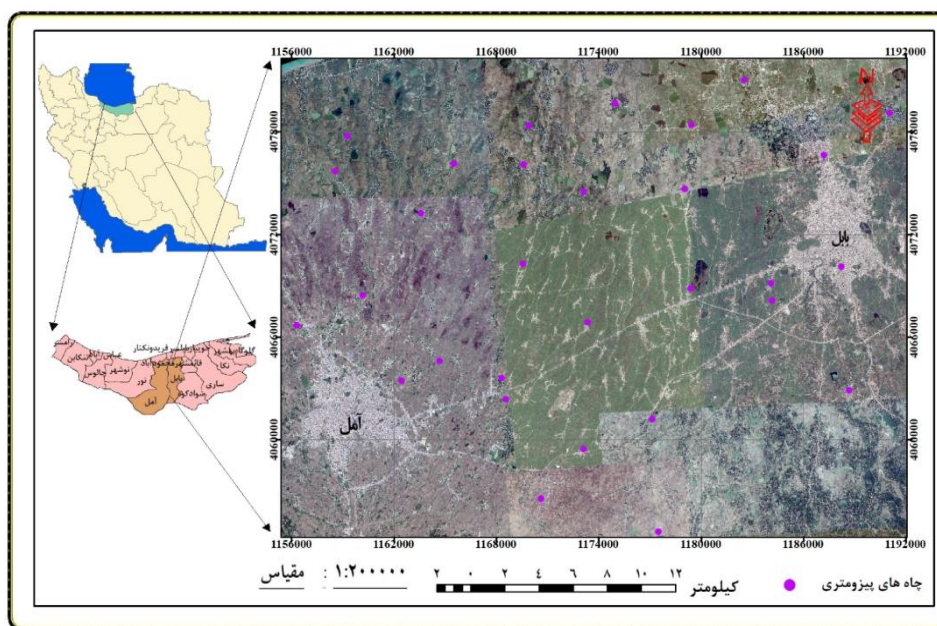
منطقه مورد مطالعه

دشت آمل-بابل در مرکز (وسط) استان مازندران (شکل ۱) قرار دارد که از شمال به دریای خزر و از جنوب به سلسله کوه‌های البرز و از شرق و غرب به ترتیب قائم‌شهر و نور منتهی می‌شود، ارتفاع دشت از شمال تا ده کیلومتری جنوب آن، از سطح دریا‌های آزاد پایین‌تر است. دشت آمل-بابل بین ۳۶ درجه و ۳۴ دقیقه و ۱۵ ثانیه عرض شمالی و ۵۲ درجه و ۴۴ دقیقه و ۲۰ ثانیه طول شرقی از نصف‌النهار گرینویچ واقع شده است. از طرفی ۹۵ حلقه چاه مطالعاتی در محدوده مطالعاتی وجود دارد که اندازه‌گیری سفره آب که در ۱۰ سال اخیر در ۱۲ ماه سال

3- Radial basis function (RBF) Generalized regression (GRNN) / Probabilistic (PNN)

4- Support Vector Machine

اندازه‌گیری و عمق متوسط آن به‌طور متوسط برآورد شده است. عوامل موثر در سطح آب زیرزمینی از جمله داده‌های آماری فاصله از منابع آب، ارتفاع از سطح دریا، قابلیت تشکیل آبخوان، تبخیر و تعرق و بارندگی با طول دوره آماری ۳۰ ساله استفاده شد.



شکل ۱: موقعیت منطقه مورد مطالعه
Figure 1: Location of the study area

مواد و روش‌ها


مفاهیم و مکانیسم شبکه‌های مورد استفاده

در این تحقیق برای پیش‌بینی سطح آب زیرزمینی از پردازش موازی استفاده شد، پردازش موازی، باعث افزایش سرعت پردازش شده و احتمال خطا را تا حد امکان کاهش می‌دهد به‌طوری که تعداد زیادی نرون ساده به‌صورت مشترک پردازش را بر عهده می‌گیرند و وظیفه کلی پردازش بین پردازنده‌های کوچک‌تر مستقل از هم توزیع می‌گردد. از محاسن این روش این است که اگر یکی از نرون‌ها نتواند به سمت پاسخ درست حرکت کند سهم آن در کل سیستم چندان حائز اهمیت نیست.

معماری معمول شبکه‌های عصبی مصنوعی متشکل از سه لایه است. لایه ورودی که داده‌ها را در شبکه توزیع می‌کند، لایه پنهان داده‌ها را پردازش می‌نماید و لایه خروجی نتایج را به ازای ورودی‌های مشخص، استخراج می‌نماید. یک شبکه می‌تواند چندین لایه پنهان داشته باشد. در تحقیق حاضر شبکه پرسپترون چندلایه برای شبیه‌سازی شوری آب زیرزمینی استفاده شده است. شبکه پرسپترون چند لایه با افزودن یک یا چند لایه پنهان به شبکه پرسپترون تک لایه ساخته می‌شود و این توپولوژی توانایی حل مسائل پیچیده را دارد (Tokar & Markus, 2000: 5).

(۱) استفاده از شبکه عصبی تابع بنیادی شعاعی

اگر از یک تابع رگرسیون تعمیم یافته شبکه عصبی، GRNN/احتمالی PNN انتخاب شود، تمامی وزن‌های شبکه می‌توانند به صورت احتمالی محاسبه شوند. در RBF از یک تابع سریع انتقال گوسین^۵ که شکلی شبیه به زنگوله که همان (GRNN) است (شکل ۲) استفاده می‌گردد. یکی از فواید این شبکه‌ها یادگیری سریع آن نسبت به سایر شبکه‌ها از جمله شبکه پرسپترون چند لایه^۶ MLPs می‌باشد مراکز و عرض‌های گوسین شبکه تابع انتقالی از نوع یادگیری نظارت نشده^۷ می‌باشند اما خروجی آن از نوع یادگیری نظارت شده^۸ می‌باشد این شبکه به واسطه آموزش سریع، قابلیت تعمیم بخشی و سادگی، در شبیه‌سازی مسائل هیدرولوژیکی و هیدرژئولوژیکی بسیار کاربردی است. در (رابطه ۱) معادله آن بیان شده است.



شکل ۲: ساختار تابع شعاعی بنیادی عصبی

Figure 2: Structure of the neural stem radial function

$$y = \frac{\sum_{n=1}^N d(n) \text{Exp} \left[-\frac{[x_0 - x(n)]^2}{2\sigma^2} \right]}{\sum_{n=1}^N \text{Exp} \left[-\frac{[x_0 - x(n)]^2}{2\sigma^2} \right]} \quad \text{معادله (۱)}$$

که $x_0 =$ داده‌های جدید ورودی مدل، $x(n) =$ داده‌های ورودی آموزش^۹ مدل، $d(n) =$ داده‌های خروجی و $\sigma =$ واریانس معادله است که از رابطه زیر به دست می‌آید:

$$\sigma = cN^{-E/a} \quad 0 \leq E \leq 1 \quad \text{رابطه (۲)}$$


که در آن c و E محرک‌های ثابت و a اندازه داده‌های ورودی می‌باشد.

(۲) استفاده از ماشین بردار پشتیبان

ماشین بردار پشتیبان بر اساس اصل کمینه‌سازی خطای ساختاری پیشنهاد شده است. Vapnik (1995). بیان دارد که ماشین بردار پشتیبان می‌تواند هم در مسائل مربوط به طبقه‌بندی و هم در تخمین توابع مورد استفاده قرار گیرد و

- 5- Gaussians
- 6- Multi layer Prespetron
- 7- Unsupervised
- 8- Supervised
- 9- Train

برای کاربرد ماشین بردار پشتیبان در مسائل رگرسیون از تابع خطای جدید به نام ϵ -insensitive استفاده کرد به گونه‌ای که این تابع خطاهایی که در یک فاصله معین از مقادیر واقعی می‌باشند نادیده می‌گیرد. این تابع به صورت شکل (۳) و رابطه (۳) تعریف می‌گردد:



شکل ۳: ساختار تابع ماشین بردار پشتیبان
Figure 3: Structure of the support vector machine function

$$L_{\epsilon}(f(x) - y) = \begin{cases} |f(x) - y| - \epsilon & \text{if } |f(x) - y| \geq \epsilon \\ 0 & \text{otherwise} \end{cases} \quad \text{رابطه (۳)}$$

این تابع مقادیر خطای کم‌تر از ϵ را نادیده می‌گیرد ولی برای داده‌هایی که با مقادیر برآوردی اختلاف بیش از ϵ دارند مقدار خطایی مطابق با آنچه که فرمول (۳) ذکر گردیده در نظر می‌گیرد. با جایگزینی تابع فوق به عنوان خطای تجربی و با استفاده از اصل کمینه‌سازی خطای ساختاری و حل مساله بهینه‌سازی حاصل در فرم دوگانه با استفاده از ضرایب لاگرانژ، روش ماشین بردار پشتیبان منجر به حل مساله بهینه‌سازی زیر می‌شود.


$$\text{Max } \frac{1}{2} \sum_i^N \sum_j^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) - \epsilon \sum_i^N (\alpha_i + \alpha_i^*) + \sum_i^N y_i (\alpha_i - \alpha_i^*) \quad \text{رابطه (۴)}$$

$$\text{Max } \frac{1}{2} \sum_i^N \sum_j^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) - \epsilon \sum_i^N (\alpha_i + \alpha_i^*) + \sum_i^N y_i (\alpha_i - \alpha_i^*) \quad \text{رابطه (۵)}$$

در روابط فوق α_i و α_i^* ضرایب لاگرانژ $K(x_i, x_j)$ تابع کرنلی است. برای حل مساله باید مقادیر پارامترهای C ، ϵ و همچنین پارامترهای مربوط به تابع کرنل انتخابی مشخص شوند.

اجرای مدل
استانداردسازی داده‌ها

قبل از مراحل آموزش و تست شبکه، باید فرآیند استانداردسازی روی داده‌ها انجام شود تا داده‌ها در دامنه خاصی وارد شبکه گردند. با استفاده از دستور استانداردسازی داده‌ها نرمال می‌شوند. هر چند در این روش خطر از دست رفتن برخی داده‌ها وجود دارد، ولی داده‌ها فرم همگنی پیدا کرده و با سایر داده‌ها قابل مقایسه می‌گردند. به طوری در هنگام فرآیند آموزش و در صورت متفاوت بودن رنج داده‌ها تأثیر داده‌های بزرگ‌تر بیش‌تر می‌شود بعد از این فرایند، آموزش داده‌ها همان‌طور که در شکل‌های (۴ و ۵) و جدول‌های (۱ و ۲) مشاهده می‌گردد با استفاده از عوامل موثر در سطح آبخوان انجام می‌شود.




شکل ۴: نتایج آموزش با استفاده از مدل ماشین بردار پشتیبان

Figure 4: Training results by using of the support vector machine model

جدول ۱- پیش‌بینی عملکرد و نتایج آموزش برای مدل ماشین بردار پشتیبان با بهترین شبکه

Table 1- Predict performance and training results for the best vector support machine model

کم‌ترین مقدار آموزش	انحراف استاندارد آموزش	کل اجرا
۰/۰۳۳۱	۰/۰۰۴۸	میانگین کم‌ترین مقدار MSEs
۰/۰۳۳۰	۰/۰۰۴۶	میانگین نهایی MSEs
آموزش		بهترین شبکه‌ها
۲		اجرا
۱۰۰۰		دور



شکل ۵: نتایج آموزش با تابع شعاعی بنیادی احتمالی / رگرسیونی

Figure 5: Training results with probabilistic fundamental / regression radial function

جدول ۲- پیش‌بینی عملکرد و نتایج آموزش با تابع شعاعی بنیادی احتمالی / رگرسیونی

Table 2- Prediction of performance and training results with probabilistic fundamental / regression radial function

کم‌ترین مقدار آموزش	انحراف استاندارد آموزش	کل اجرا
۰/۰۳۰۴	۰/۰۰۰۶	میانگین کم‌ترین مقدار MSEs
۰/۰۳۰۴	۰/۰۰۰۶	میانگین نهایی MSEs
آموزش		بهترین شبکه‌ها
۱		اجرا
۹۹۹		دور

ارزیابی عملکرد شبکه

مبنای تصمیم‌گیری برای انتخاب بهترین شبکه در هر بار اجرای برنامه، ضریب تعیین R^2 متوسط قدر مطلق (MAE^1)، ریشه مربعات خطا (MSE^1)، میانگین مربعات خطای نرمال شده ($NMSE^1$) و ضریب همبستگی برای مرحله تست می‌باشد که در زیر رابطه MAE و R^2 را مشاهده می‌گردد.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad \text{رابطه (۶)}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y}_i)^2} \quad \text{رابطه (۷)}$$

که Y_i داده‌های مشاهداتی، \hat{Y}_i داده‌های تخمینی، \bar{Y}_i میانگین داده‌های مشاهداتی می‌باشد.

10- Mean Absolute Error

11- Root Square Error

12- Normal Root Square Error

چگونگی طراحی و بهینه‌سازی شبکه

برای شبیه‌سازی عمق سفره آب زیرزمینی عوامل موثر آن از جمله بارندگی سالانه، قابلیت سازندهای زمین‌شناسی، فاصله از منابع آب و ارتفاع از سطح دریا دخالت داده شد. برای طراحی شبکه هر دو مدل نیاز به ۲ دسته داده آموزشی و آزمایش (تست) می‌باشد. در این پژوهش حدود ۷۴ درصد از داده‌ها برای آموزش و ۲۶ درصد از داده‌ها برای تست در نظر گرفته می‌شود. یکی از معیارهای مهم در آموزش شبکه تعداد تکرار^۳ یا دور در حین آموزش می‌باشد هر چقدر تعداد تکرار افزایش داده شود خطا رو به کاهش می‌رود تا آموزش داده‌ها به همگرایی^۴ نائل شود که در این موقع افزایش تعداد تکرار بی‌نتیجه خواهد بود. از سوی دیگر برای بهینه‌سازی شبکه هدف از آموزش شبکه کاهش خطا و دست‌یابی به شبکه‌ای است که بتواند روابط بین ورودی و خروجی مدل را بهبود بخشد. به علت این‌که قوانین خاصی جهت طراحی شبکه‌های عصبی مصنوعی (ANN)، موجود نیست، ساختارهای مختلفی مورد بررسی قرار گرفت تا بهینه‌سازی به درستی صورت گیرد انتخاب تعداد و نوع پارامترهای ورودی به مدل از اهمیت بسیاری برخوردار است. به همین دلیل هفت الگوی ورودی طراحی، در زیر آورده شده است؛ که در محیط نرم‌افزار نروسولیشن^۵ انجام گرفت.


$G_w = f(P, T, L_s, E, E_{Sea})$	۱
$G_w = f(P, T, L_s, E)$	۲
$G_w = f(P, T, E_{Sea})$	۳
$G_w = f(P, T, E, L_s)$	۴
$G_w = f(E, T, L_s)$	۵
$G_w = f(P, T, E)$	۶
$G_w = f(P, T, L_s)$	۷

در روابط بالا G_w سطح آب زیرزمینی، P بارندگی سالانه به میلی‌متر، T ترنس‌میسویته (قابلیت تشکیل آبخوان)، E تبخیر سالانه به (متر)، E_{Sea} ارتفاع از سطح دریا (متر) و L_s = فاصله از منابع آب می‌باشد؛ و همچنین نتایج حاصل از تست با ساختار بهینه از جمله منابع آب، بارندگی و قابلیت تشکیل آبخوان در جدول‌های (۳ و ۴) و شکل‌های (۶ و ۷) برای هر دو مدل ارایه شده است.

جدول ۳- نتایج تست با مقایسه دو مدل تابع شعاعی بنیادی / احتمالی و ماشین بردار پشتیبان


Table 3- Test results by comparing the two models of fundamental / probabilistic radial function and support vector machine

ماشین بردار پشتیبان		تابع شعاعی بنیادی / احتمالی	
عملکرد	سطح آبخوان	عملکرد	سطح آبخوان
میانگین مربعات خطا	۱۵/۳۴	میانگین مربعات خطا	۱۴/۲۴
میانگین مربعات خطای نرمال شده	۰/۴۹۴	میانگین مربعات خطای نرمال شد	۰/۴۵۸
متوسط قدر مطلق	۱/۹۱۲	متوسط قدر مطلق	۱/۹۴۲
مینیمم خطای مشاهده شده	۰/۲۵۹	مینیمم خطای مشاهده شده	۰/۰۹۲
ماکسیمم خطای مشاهده شده	۱۷/۴۳	ماکسیمم خطای مشاهده شده	۱۶/۵۱۹
R^2	۰/۷۴	R^2	۰/۸۲



شکل ۶: برازش داده‌های مشاهداتی و برآوردی با مدل ماشین بردار پشتیبان

Figure 6: Fitting of observational and estimation data with the support vector machine model



شکل ۷: برازش داده‌های مشاهداتی و برآوردی با مدل تابع شعاعی بنیادی / احتمالی

Figure 7: Fitting of observational and estimation data with the probabilistic radial function model

نتایج به دست آمده با تابع شعاعی بنیادی و ماشین بردار پشتیبان بیانگر این نقطه است که ماشین بردار پشتیبان و تابع شعاعی بنیادی توانایی تقریباً یکسان در پیش‌بینی و مدل‌سازی دارند هر چند به‌طور کلی نتایج حاصل از تابع شعاعی بنیادی قابل قبول‌تر می‌باشد. نتایج حاصل از تست مدل در جدول (۴) نیز مشاهده می‌گردد.

جدول ۴- عوامل موثر در سطح تراز آبخوان و نتایج خروجی حاصل از مدل‌های SVM* و RBF / GRNN / PNN**

Table 4- Factors affecting aquifer level and output results from SVM * and RBF / GRNN / PNN models

بارندگی (میلی‌متر)	فاصله از منابع آب	قابلیت انتقال (متر مربع/روز)	سطح تراز آبخوان (متر) مقدار واقعی	سطح تراز* آبخوان (متر) برآوردی	سطح تراز** آبخوان (متر) برآوردی
۷۰۰	۲۰۸۰	۱۰۰	۳/۱۸	۲/۶۲	۲/۹۲
۸۰۰	۲۵۵۹	۱۵۰۰	۷/۱۳	۶/۱۹	۱۲/۸
۷۰۰	۱۷۱۱۲	۵۰۰	۳/۲۴	۲/۲۷	۲/۸۰
۷۰۰	۱۳۴۴۰	۳۷۵	۲/۲۵	۲/۳۴	۲/۸۰
۷۵۰	۲۴۸۴۵	۱۵۰۰	۸/۳۵	۶/۵۵	۷/۰۷
۷۵۰	۱۹۲۷۵	۷۵۰	۲/۸۱	۲/۷۱	۳/۰۸
۷۰۰	۱۳۴۱۶	۵۰۰	۴/۳۳	۲/۳۲	۲/۷۹
۷۰۰	۹۲۲۲	۱۷۵	۳/۱۷	۲/۵۵	۲/۸۵
۶۵۰	۵۰۲۶	۱۷۵	۲/۴۳	۲/۸۰	۲/۹۴
۸۰۰	۲۴۸۸۲	۱۵۰۰	۸/۳۵	۵/۸۶	۷/۳۰
۷۵۰	۱۹۳۴۴	۷۵۰	۲/۸۱	۲/۷۱	۳/۰۸
۷۰۰	۵۰۳۹	۱۷۵	۳/۲۷	۲/۶۳	۲/۸۶
۷۰۰	۳۸۰۹	۱۰۰	۳/۲۸	۲/۷۶	۲/۹۰
۷۵۰	۲۲۵۹۷	۱۵۰۰	۷/۰۴	۶/۶۹	۷/۷۱
۶۴۵	۲۰۴۸۵	۲۰۰۰	۳۰/۱	۱۳/۵۸	۱۲/۶۶
۷۰۰	۱۶۵۹۶	۱۵۰۰	۴/۸۴	۵/۸۷	۴/۱۳
۷۰۰	۱۱۷۰۳	۷۵۰	۶/۶۷	۲/۵۷	۲/۸۳
۷۰۰	۷۶۰۰	۳۷۵	۶/۱۴	۲/۴۱	۲/۷۹
۷۰۰	۱۹۹۲۵	۱۵۰۰	۱۱/۴۹	۶/۶۹	۵/۸۲
۷۰۰	۱۵۶۱۵	۱۵۰۰	۶/۷۸	۶/۱۶	۵/۲۵
۷۰۰	۱۳۲۳۴	۷۵۰	۵/۶۵	۲/۸۳	۲/۹۶
۶۵۰	۸۵۳۷	۳۷۵	۲/۳۵	۲/۷۲	۲/۸۷
۷۰۱	۲۱۰۷	۱۰۰	۱/۷۳	۲/۸۳	۲/۹۰
۷۰۱	۲۳۹۸	۱۰۰	۱/۶۹	۲/۸۳	۲/۹۰
۶۵۰	۸۵۱۹	۱۰۰	۲/۲۲	۳/۰۱	۲/۹۶

برای پیش‌بینی سطح آب زیرزمینی نیاز به مدلی است که ارزیابی را در مرحله آموزش با خطای کم‌تر و ضریب همبستگی بالایی در مرحله اعتبارسنجی داشته باشد، با توجه به جدول ارایه شده ۲۰ درصد از داده‌هایی در مرحله اعتبارسنجی به‌کار گرفته شد که در مرحله آموزش از آن‌ها استفاده نشده است و از آنجایی که ساختار بهینه مدل‌سازی مبتنی بر تمامی پارامترها و تهیه تمامی داده‌های ورودی خود مستلزم صرف زمان و هزینه‌ی زیادی خواهد بود از این‌رو روشی مبتنی بر اصلی‌ترین پارامترهای ورودی (ورودی‌های بهینه) مدل‌سازی و اعتبارسنجی شد و در

(جدول ۴) مشاهده گردید که سطح آبخوان پیش‌بینی شده برای هر دو مدل تقریباً نزدیک به مقدار واقعی آن می‌باشد.

نتیجه‌گیری

آب زیرزمینی به عنوان یک منبع مهم تامین آب شیرین جایگاه ویژه‌ای در مطالعات منابع آب دارد با این حال برای پیش‌بینی سطح آبخوان نیاز به اکتشافات و صرف هزینه زیاد می‌باشد، اما امروزه با استفاده از مدل مفهومی شبکه عصبی مصنوعی با انتخاب نوع و تعداد مناسب عوامل ورودی به‌عنوان ابزار مناسب برای شبیه‌سازی و پیش‌بینی به کار گرفته می‌شود که با تحقیقات (Ramezani Charmahineh & Zunemat Kermani (2017) هم‌خوانی دارد. براساس تحقیقات مختلف انجام شده در خصوص کارایی شبکه‌های عصبی مصنوعی، در مدل‌سازی پارامترهای هیدرولوژیک، واضح است که توانایی‌های این روش با توجه به ساختارهای مختلف آن و نیز طبیعت مسئله‌ای که باید حل شود، متفاوت می‌باشد. با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز استفاده از نوع مناسب و سازگار شبکه عصبی مصنوعی و نیز واسنجی کردن مناسب آن می‌توان گفت که این روش ابزاری بسیار کارا و مناسب برای برآورد سطح آب زیرزمینی می‌باشد (Li et al., 2017: 8). همان‌طور که از بررسی نتایج برمی‌آید با استفاده از ساختار بهینه مدل یعنی فاصله از منابع آب، بارندگی و قابلیت تشکیل آبخوان برای پیش‌بینی سطح آب زیرزمینی مورد استفاده قرار گرفت. نتایج حاصل از تست نشان داد که هر دو مدل نتایج قابل قبولی ارائه می‌دهند هرچند تابع شعاعی بنیادی نسبت به ماشین بردار پشتیبان با ضریب همبستگی $0/82$ و متوسط قدر مطلق خطای $1/94$ ابزار مناسب‌تری برای پیش‌بینی در برنامه‌های مدیریت منابع آب می‌باشد.

References

- Anctil, F., Perrin, C. H., Andreassian, V., (2004), "Impact of the length of observed records on the performance of ANN and conceptual parsimonious rainfall-runoff forecasting models", *Environmental Modeling and Software*, 19 (4): 357-368
- Banerjee, P. R., Prasad, K., Singh, V. S., (2009), "Forecasting of groundwater level in hard rock region using artificial neural network", *Environmental Geology*, 58 (6): 1239-1246.
- Bierkens, M. F. P., (1998), "Modeling water table fluctuations by means of a stochastic differential equation", *Journal of Water Resource Research*, 34 (10): 2485-2499.
- Corrado, M., Fanelli, A. M., Chieco, M., (2008), "A neural network for water level prediction in artesian wells," *2008 International Conference on Computational Intelligence for Modelling Control & Automation. Web Technologies and Internet Commerce- Cover. IEEE*, pp 686-691
- Coulibaly, P., Anctil, F., Bobee, B., (2000), "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach", *Journal of Hydrology*, 30 (2): 244-257.
- Elshorbagy, A., Simonovic, S. P., (2000), "Performance evaluation of artificial neural networks for runoff prediction", *Journal of Hydrologic Engineering*, 3 (3): 203-209.
- Feyzolapor. M., (2017), "Estimation of suspended sediment load of Sangurchai River using two artificial neural network models", *Journal of Geographical Space*, 16 (56): 115-131. [In Persian].
- Hsu, K., Gupta, H. V., Sorooshian, S., (1995), "Artificial neural network modeling of the rainfall-runoff process", *Water Resources Research*, 31 (10): 2517-2530.
- Kalte, A. M., Gholami, V., (2012), "Groundwater level forecasting using support vector machine on the southern shores of the Caspian Sea", *The third national conference on water resources management in Iran in 21-22 September 2012*, Sari Faculty of Agricultural Sciences and Natural Resources. [In Persian].
- Khursheeddoost, A. M., Nasajizavareh, B., Ghermezcheshme, B., (2012), "Reconstruction of daily maximum and minimum temperature time series using the nearest neighbor method and artificial neural network (case study of West Tehran province)" , *Journal of Geographical Space*, 38 (12): 197-204. [In Persian].
- Li, Z., Yang, Q., Wang, L., Delgado, J. M., (2016), "Application of RBFN network and GM (1, 1) for groundwater level simulation", *Journal of Water Resource Research*, 7: 3345-3353
- Minhaj, M. B., (2002), *Fundamentals of Neural Networks*, Tehran: Amir Kabir University of Technology. [In Persian].
- Mohammadi, K., (2008), "Groundwater table estimation using modflow and artificial neural networks", *Water Science and Technology Library*, 68 (2): 127-138.
- Mohtasham, M., Dehghani, A. A., Akbarpour, A., Mafta Halaghi, M., Etebari, B., (2010), "Water level prediction using artificial neural network (Case study: Birjand plain)", *Iranian Journal of Irrigation and Drainage*, (4) 2: 1-14. [In Persian].
- Ramezani Charmahineh, A., Zunemat Kermani, M., (2017), "Every time there is a method of running water, the study of water and water every day from the watershed, *Iranian: Water*, 15 (4): 1-12. [In Persian].
- Sethi, R. R., Kumar, A., Sharma, S. P., Verma, H. C., (2010), "Prediction of water table depth in a hard rock basin by using artificial neural network", *International Journal of Water Resources and Environmental Engineering*, 4 (2): 95-102.

- Tokar, A. S., Markus, M., (2000), "Precipitation-runoff modeling using artificial neural networks and conceptual models", *Journal of Hydrologic Engineering*, 5 (2): 156-161.
- Vapnik, V., (1995), "*The nature of statistical learning theory*", Springer: New York.