

ارزیابی روش‌های مختلف SOM-AI برای پیش‌بینی سطح آب زیرزمینی (مطالعه موردی: آبخوان دشت سلماس)

کیوان نادری^۱، عطاله ندیری^{۲*}، اصغر اصغری مقدم^۳ و مهدی کرد^۴

چکیده

تغییرات سطح آب زیرزمینی، یکی از مهم‌ترین متغیرها در مدیریت آبخوان‌هاست که پیش‌بینی دقیق این متغیر می‌تواند در ارائه راهکارهای مدیریتی برای حفظ این مخازن آب شیرین استراتژیک به‌خصوص در مناطق خشک و نیمه‌خشک، مانند حوضه دریاچه ارومیه راهگشا باشد. با وجود توانایی بالای مدل‌های هوش مصنوعی (AI) در پیش‌بینی سطح آب زیرزمینی به دلیل ناهمگنی و ناهمسانی محیط‌های هیدروژئولوژیکی، گه‌گاه از کارایی پایینی برخوردارند؛ از این‌رو، استفاده از روش هوشمند نگاشت خود سازمان‌ده (SOM) برای خوشه‌بندی چاه‌های مشاهده‌ای و ترکیب آن با مدل‌های مختلف هوش مصنوعی می‌تواند باعث بهبود نتایج حاصل از مدل‌سازی شود. در این پژوهش، روش‌های مختلف SOM-AI، شامل ماشین بردار پشتیبان (SOM-SVM) و مدل فازی ساگنو (SOM-SFL) برای پیش‌بینی تغییرات سطح آب زیرزمینی به‌کار گرفته شدند. بدین ترتیب، چاه‌های مشاهده‌ای (OW) در سه گروه G1، G2 و G3 دسته‌بندی و برای هر گروه از چاه‌های مشاهده‌ای مدل‌سازی سطح آب زیرزمینی اجرا شد. ارزیابی نتایج با استفاده از معیارهای RMSE، r^2 و NSE نشان داد که حداقل در سه چاه مشاهده‌ای OW2، OW6 و OW9، مدل ترکیبی SOM-SFL عملکرد بهتری نسبت به بقیه داشت. در بقیه چاه‌های مشاهده‌ای مدل ترکیبی SOM-LSSVM برتری نسبی داشت.

واژه‌های کلیدی: سطح آب زیرزمینی، منطق فازی، ماشین بردار پشتیبان، نگاشت خود سازمان‌ده.

ارجاع: نادری ک. عطاله ندیری ع. اصغری مقدم ا. و مهدی کرد م. ۱۳۹۸. ارزیابی روش‌های مختلف SOM-AI برای پیش‌بینی سطح آب زیرزمینی (مطالعه موردی: آبخوان دشت سلماس). مجله پژوهش آب ایران. ۳۴: ۹۵-۱۰۵.

۱- دکتری هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز.

۲- دانشیار گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز.

۳- استاد گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز.

۴- استادیار گروه زمین‌شناسی، دانشکده علوم پایه، دانشگاه کردستان.

* نویسنده مسئول: nadiri@tabrizu.ac.ir

مقدمه

امروزه به دلیل پیچیدگی و خصوصیات غیرخطی آبخوان‌ها، مدل‌های هوش مصنوعی در کنار مدل‌های کلاسیک برای دستیابی به هدف موردنظر، مورد توجه فراوان قرار گرفته‌اند. از میان مدل‌های هوش مصنوعی مختلف می‌توان به روش‌های ANN^1 ، NF^2 ، GP^3 ، FL^4 و SVM^5 اشاره کرد که محققان زیادی برای پیش‌بینی و تخمین سطح آب‌برزمینی از این روش‌ها استفاده کرده‌اند (ندیری و همکاران، ۱۳۹۵؛ بهزاد و همکاران، ۲۰۱۰؛ شیرمحمدی و همکاران، ۲۰۱۳؛ جها و ساهو، ۲۰۱۵). پیش‌بینی نوسانات سطح آب‌برزمینی با عدم قطعیت همراه است؛ منطق فازی (FL) به‌عنوان ابزاری مناسب برای مقابله با عدم قطعیت‌های موجود از اهمیت خاصی برخوردار است. از طرف دیگر، ماشین بردار پشتیبان (SVM) نیز به موجب دو مشخصه که شامل قابلیت عمومیت‌سازی و کار با داده‌های پراکنده است، به‌عنوان روشی دقیق در پیش‌بینی به شمار می‌رود. بنابراین، در این تحقیق دو روش FL و SVM در ترکیب با روش نگاشت خودسازمان‌ده^۶ برای پیش‌بینی سطح آب‌برزمینی انتخاب شد. ماشین بردار پشتیبان، یک سیستم یادگیری کارآمد است که بر اساس تئوری یادگیری آماری و اصل استقرای کمینه‌سازی خطای ساختاری توسعه یافته است و این توانایی را دارد که داده‌های غیرقابل مشاهده را عمومی‌سازی کند و سازگاری خوبی با داده‌های پراکنده و کم داشته باشد (بهزاد و همکاران، ۲۰۱۰). این روش در کمینه‌های محلی گیر نمی‌افتد، آموزش نسبتاً ساده‌ای دارد و برای داده‌های با ابعاد بالا هم معمولاً نتایج خوبی را ارائه می‌دهد (اعلمی و همکاران، ۱۳۹۲). روش SVM در عمومی‌سازی و قابلیت مدل‌سازی با داده‌های پراکنده و همچنین در پیش‌بینی‌های با دوره بلندمدت، می‌تواند جایگزین خوبی برای ANN باشد (بهزاد و همکاران، ۲۰۱۰). راگاوندا و دکا (۲۰۱۴) مقاله‌ای را با عنوان کاربردهای SVM در زمینه هیدرولوژی ارائه دادند. آنها در این مقاله تئوری SVM، انواع آنها و کاربردهای مختلف آن را در زمینه آب‌های سطحی و زیرزمینی، انتخاب الگوریتم

بهینه‌سازی، کرنل^۷ و پارامترهای مربوطه بیان کردند. منطق فازی اولین بار توسط زاده (۱۹۶۵) معرفی شد و از آن زمان تاکنون در مطالعات زمین‌شناسی و هیدروژئولوژیکی کاربرد فراوانی داشته است (فانگ و چن، ۱۹۹۷؛ یو و همکاران، ۲۰۰۰؛ الویسی و همکاران، ۲۰۰۶). نتایج تحقیقات نشان می‌دهد منطق فازی، روشی مناسب برای کاهش خطای برآوردی و انسانی نسبت به تئوری‌های قابل اعتماد دیگر ارائه کرده است (نیک‌روش و امین‌زاده، ۲۰۰۳). ندیری و همکاران (۱۳۹۵)، ترکیبی از مدل‌های فازی و زمین‌آمار را برای پیش‌بینی زمانی و مکانی سطح آب‌برزمینی به‌کار بردند. آن‌ها در این تحقیق از روش خوشه‌بندی سلسه‌مراتبی برای خوشه‌بندی پیرومترها استفاده کردند و نتایج قابل قبولی را به‌دست آوردند. روش‌های مختلفی برای تقسیم‌بندی داده‌های هیدرولوژیکی توسط محققان استفاده شده است (نورانی و پرهیزکار، ۲۰۱۳؛ ندیری و همکاران، ۱۳۹۵). برخلاف روش‌های آماری که حالت خطی دارند و حجم زیادی از داده‌ها برای دسته‌بندی نیاز است، روش‌های دسته‌بندی هوش مصنوعی می‌توانند برای حالت‌های غیرخطی و پیچیده نتایج قابل قبولی را ارائه دهند (نورانی و همکاران، ۲۰۱۶). در سال‌های اخیر، روش SOM در ترکیب با روش‌های مختلف هوش مصنوعی برای پیش‌بینی‌های هیدروژئولوژیکی کاربردهای فراوانی داشته است (نورانی و همکاران، ۲۰۱۶). در این تحقیق، برای اولین بار روش SOM در ترکیب با مدل‌های هوش مصنوعی برای پیش‌بینی سطح آب‌برزمینی استفاده شد. به‌دلیل ناهمگنی‌های مورفولوژیکی و هیدروژئولوژیکی آبخوان، به‌کارگیری مدل‌های ترکیبی SOM-AI می‌تواند از مشکل ناهمگنی آبخوان بکاهد و دقت پیش‌بینی را تا حد زیادی بالا ببرد. به‌کارگیری روشی مناسب برای پیش‌بینی سطح آب‌برزمینی می‌تواند برای آگاهی از وضعیت پیش روی آبخوان بسیار مفید و کارآمد باشد. از طرفی دیگر، با توجه به ناهمگنی و ناهمسانی بیشتر آبخوان‌ها، دسته‌بندی چاه‌های مشاهده‌ای قبل از انجام مدل‌سازی می‌تواند باعث بهبود نتایج شود. بنابراین، در این پژوهش برای پیش‌بینی سطح آب‌برزمینی در آبخوان دشت سلماس از مدل‌های ترکیبی SOM-SVM و SOM-FL استفاده شد.

1- Artificial neural network
2- Neuro fuzzy
3- Genetic programing
4- Fuzzy logic
5- Support vector Machine (SVM)
6- Self-Organization Map (SOM)

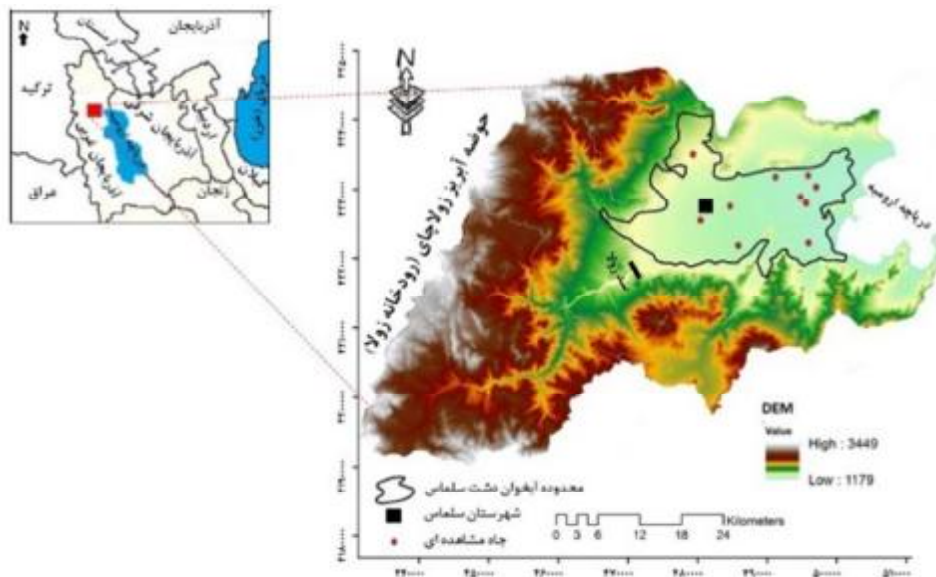
برای بررسی نوسانات سطح آب زیرزمینی حفر شده است (نادری و همکاران، ۱۳۹۷). ۱۰ چاه مشاهده‌ای داده سطح آب ۱۵ ساله و یا بیشتر دارند؛ بنابراین، برای مدل‌سازی سطح آب زیرزمینی انتخاب شدند (شکل ۳). در این تحقیق، داده‌های سطح آب زیرزمینی ماهانه با یک تأخیر زمانی (GWL_{t_0-1}) ، میزان متوسط بارندگی در هر ماه (P_{t_0}) ، متوسط دمای ماهانه (T_{t_0}) و دبی خروجی ماهانه رودخانه زولاچای (Q_{t_0}) ، طی دوره زمانی ۱۵ ساله (۱۳۹۵ - ۱۳۸۱) به‌عنوان ورودی‌های مدل و سطح آب زیرزمینی در زمان t_0 (GWL_{t_0}) به‌عنوان خروجی مدل تعیین شدند. از ۸۰ درصد داده‌ها برای مرحله آموزش و ۲۰ درصد آنها برای مرحله آزمون استفاده شد.

بدین ترتیب، چاه‌های مشاهده‌ای که بیشتر شباهت را با هم دارند، در یک گروه قرار می‌گیرند.

مواد و روش‌ها

منطقه مطالعاتی و بررسی داده‌ها

دشت سلماس با حدود ۵۵۰ کیلومترمربع مساحت، در قسمت شمال‌غرب ایران و شمال استان آذربایجان‌غربی قرار گرفته است (شکل ۱). مهم‌ترین منبع آب سطحی دشت سلماس، رودخانه زولاچای است که در نهایت به دریاچه ارومیه ختم می‌شود. بر اساس نتایج به‌دست آمده از لوگ چاه‌های اکتشافی، دو نوع آبخوان آزاد و تحت فشار در دشت سلماس وجود دارد که روی همدیگر قرار گرفته‌اند. در دشت سلماس تعداد ۲۷ حلقه چاه مشاهده‌ای



شکل ۱- موقعیت منطقه مورد مطالعه و چاه‌های مشاهده‌ای

هستند، تخمین‌گر SVM $(f(x))$ به‌صورت معادله (۱) بیان می‌گردد (شیری و همکاران، ۲۰۱۳).

$$f(x) = w \cdot \varphi(x) + b \quad (1)$$

که w بردار وزن؛ b بایاس؛ و φ تابع تبدیل گر خطی (به نام کرنل) است که بردارهای ورودی را به شکل فضای بالاتر ترسیم می‌کند. تابع هدف بهینه‌سازی محدب با استفاده از تابع تلفات غیرحساس^۱ برای حل معادله (۱) توسط وپنیک به‌صورت زیر معرفی شده است (وپنیک، ۱۹۹۵).

ماشین بردار پشتیبان

ماشین بردار پشتیبان، نوعی روش یادگیری است که اولین بار توسط وپنیک (۱۹۹۵) معرفی شد. مهم‌ترین ویژگی SVM، به‌کارگیری اصل استقرای کمینه‌سازی خطای ساختاری است که منجر به یک جواب بهینه کلی می‌شود. SVM با قابلیت عمومی‌سازی بالا و سازگاری با داده‌های پراکنده و کم نتایج بسیار دقیقی را ارائه می‌دهد (بهراد و همکاران، ۲۰۱۰). انتخاب بردارهای پشتیبان و تعیین وزن آن‌ها، فرایند اصلی در مدل SVM است. با در نظر گرفتن مجموعه‌ای با N نمونه $\{(X_k, Y_k)\}_{k=1}^N$ ، $x \in R^m$ ، $y \in R$ که در آن: x بردار ورودی R^m جزئی؛ و y بردار خروجی

1- Insensitivity loss function (ϵ)

مدل فازی ساگنو و روش دسته‌بندی کاهشی^۴ برای مدل‌سازی سطح آب زیرزمینی به‌کار برده شده است. در روش ساگنو، تابع عضویت خروجی سیستم فازی یک رابطه خطی و ثابت است که با استفاده از روش دسته‌بندی به‌دست می‌آید (ندیری و همکاران، ۲۰۱۷). b و c : ندیری و همکاران، ۲۰۱۸). b ، گام نخست در اجرای یک مدل فازی، دسته‌بندی داده‌هاست که انتخاب روش دسته‌بندی بستگی به نوع روش اجرای مدل فازی دارد.

نگاشت خودسازمان‌ده

طبقه‌بندی داده‌ها، ساخت داده‌های همگن و بهینه‌سازی ساختار مدل با انتخاب ورودی‌های غالب و مرتبط از اهداف اصلی خوشه‌بندی است (کوهنن و همکاران، ۱۹۹۷). SOM، یکی از انواع روش‌های هوش مصنوعی برای خوشه‌بندی داده است که توسط کوهنن (۱۹۸۲) توسعه داده شد. این روش نسبت به سایر روش‌های دسته‌بندی برتری‌هایی دارد که عبارت‌اند از: ۱- نبود یک تابع هدف خروجی برای بهینه‌سازی یا پیش‌بینی (الگوریتم یادگیری بدون نظارت)؛ و ۲- هیچ برچسبی برای داده‌ها اختصاص نمی‌یابد و ورودی‌ها بر اساس بیشتر میزان تشابه دسته‌بندی می‌گردند (کوهنن، ۱۹۸۲). چگونگی کار در SOM بدین صورت است که ورودی‌ها با یک وزن تصادفی بین صفر و یک وارد سیستم می‌شوند. سپس، فاصله بین هر پارامتر ورودی با مرکز لایه پنهان بر اساس فاز رقابت و تابع مینیمم به‌دست می‌آید. فرایند آموزش SOM در سه مرحله انجام می‌گیرد (رقابت، همکاری و تطبیق). در فاز رقابت، با معرفی داده به شبکه، کمترین فاصله این داده نسبت به نورون‌های لایه خروجی محاسبه می‌شود و هر نورون از لایه خروجی که فاصله کمتری را داشته باشد، به‌عنوان نورون برنده انتخاب می‌شود. مقدار فاصله اقلیدسی (D_j) در شبکه SOM مطابق با معادله (۴) به‌دست می‌آید (کوهنن و همکاران، ۱۹۹۷). در این معادله بردار ورودی نورون برنده \mathbf{i} و \mathbf{w}_j وزن نورون همسایه است.

$$D_j = |\mathbf{x} - \mathbf{w}_j| \sqrt{\sum_{i=1}^M (x_i - w_{ij})^2} \quad (4)$$

$$j = 1, 2, 3, \dots, M$$

$$\begin{aligned} \text{minimize } & \mathbf{w}^T \mathbf{b} + \sum_{k=1}^N \xi_k^* \\ & = \frac{1}{2} \|\mathbf{w}\|^2 \\ & + \mathbf{C} \sum_{k=1}^N (\xi_k + \xi_k^*) \quad (2) \\ \text{Subject to } & \begin{cases} y_k - \mathbf{w}^T \boldsymbol{\varphi}(x_k) - b \leq \varepsilon + \xi_k \\ \mathbf{w}^T \boldsymbol{\varphi}(x_k) + b - y_k \leq \varepsilon + \xi_k^* \\ \xi_k, \xi_k^* \geq 0 \\ k = 1, 2, 3, \dots, N \end{cases} \end{aligned}$$

در این معادله، ξ_k و ξ_k^* ، متغیرهای کمبود هستند که خطای آموزش را به‌وسیله تابع تلفات غیرحساس (ε) جریمه می‌کنند و پارامتر مثبت \mathbf{C} ضریب موازنه برای تعیین درجه خطای تجربی در مسئله بهینه‌سازی است. در این تحقیق، کرنل تابع پایه شعاعی^۱ (RBF-kernel) به‌کار برده شده است. معادله مربوط به RBF-kernel در زیر آمده است (معادله (۳))، که در آن پارامتر σ مربوط به تابع کرنل است.

$$K(\mathbf{x}_k, \mathbf{x}_l) = \exp\left(-\frac{\|\mathbf{x}_k - \mathbf{x}_l\|^2}{2\sigma^2}\right) \quad (3)$$

حل مسائل در ابعاد بزرگ با استفاده از مدل SVM هزینه محاسباتی را به‌شدت افزایش می‌دهد. برای رفع این مشکل، سوپکنز و همکاران (۲۰۰۲) روش کمترین مربعات ماشین بردار پشتیبان^۲ (LSSVM) را ارائه کردند.

منطق فازی

منطق فازی که در برابر منطق کلاسیک قرار دارد، ابزاری است برای درک عدم قطعیت‌ها و عدم صراحت‌ها که بیان عبارت‌های بشر را در قالب مفاهیم ریاضی ممکن می‌سازد. سیستم فازی، سه بخش اصلی را شامل می‌شود: ۱- تعریف تابع عضویت یا فازی‌کردن داده‌ها؛ ۲- تعیین قوانین فازی؛ ایجاد ارتباط بین ورودی و خروجی با استفاده از مجموعه‌ای از قوانین، مثل اگر-آنگاه (if → then)؛ و ۳- جمع‌کردن نتایج سیستم و غیرفازی‌سازی، که توسط عملگرهای فازی (not, or, and) انجام می‌گیرد (لی، ۲۰۰۴). بر اساس تابع عضویت خروجی و عملگر به‌کار رفته، سه نوع روش ساگنو (ناکاگی و ساگنو، ۱۹۸۵)، ممدانی (ممدانی و اسیلین، ۱۹۷۵) و لارسن (لارسن، ۱۹۸۰) برای اجرای مدل فازی وجود دارد. روش فازی ساگنو^۳ با روش‌های بهینه‌سازی به خوبی سازگار است و در علوم مهندسی کاربرد بیشتری دارد. در این پژوهش،

1- Radial Basis Function kernel (RBF-kernel)

2- Least Squares Support Vector Machine (LSSVM)

3- Sugeno Fuzzy Logic (SFL)

4- Subtractive Clustering

انحراف معیار تراز سطح آب زیرزمینی در هر چاه مشاهده‌ای، UTMx و UTMy مربوط به چاه‌ها به‌عنوان ورودی شبکه SOM انتخاب شدند. شکل ۲-الف، ساختار نهایی شبکه SOM را نشان می‌دهد. بر این اساس، چاه‌های مشاهده‌ای (OW) در سه گروه دسته‌بندی می‌شوند. شکل ۲-ب، میزان تحرک‌پذیری نورون‌های همسایه نسبت به پارامترهای ورودی را نشان می‌دهد. چاه‌های مشاهده‌ای دسته‌بندی شده در سه گروه G1، G2 و G3 در شکل ۳-الف نشان داده شده‌اند. با استفاده از این روش، چاه‌های مشاهده‌ای که روند نوسانات سطح آب مشابه دارند، در یک گروه قرار می‌گیرند؛ به طوری که در چاه‌های مشاهده‌ای گروه اول (G1)، نوسانات فصلی نسبت به گروه دوم (G2) و سوم (G3) بسیار کمتر دیده می‌شود. در شکل ۳-ب، تغییرات ماهانه سطح آب زیرزمینی در یک دوره ۱۸۰ ماهه (۱۳۸۰-۱۳۹۵) نشان داده شده است.

نتایج حاصل از مدل ترکیبی SOM-SVM

در این پژوهش از مدل حداقل مربعات ماشین بردار پشتیبان (LSSVM) که توسط سویکنز و همکاران (۲۰۰۲) پیشنهاد شده است، استفاده گردید. در این مدل، انتخاب بهترین تابع کرنل و مقادیر مناسب برای پارامترهای بهینه آن بر اساس کمینه خطای ایجاد شده ضروری است. در این تحقیق، از کرنل RBF که کارایی بهتری نسبت به تابع کرنل‌های دیگر دارد (اسفا و همکاران، ۲۰۰۶)، استفاده شده است. برای هر گروه از چاه‌های مشاهده‌ای (G1، G2 و G3) مدل LSSVM اجرا شد. مقادیر بهینه به دست آمده برای پارامتر گاما و پارامتر کرنل در چاه‌های مشاهده‌ای مختلف در جدول ۱ ارائه شده است. ارزیابی نتایج مدل ترکیبی SOM-LSSVM با استفاده از r^2 ، RMSE و NSE توانایی بالای مدل ترکیبی SOM-LSSVM را برای پیش‌بینی تغییرات سطح آب زیرزمینی نشان می‌دهد (شکل ۴-الف و ب).

در فاز همکاری، وزن نورون‌های همسایه برحسب مقدار فاصله با نورون برنده به‌هنگام‌سازی می‌شوند (کوهنن و همکاران، ۱۹۹۷):

$$h_{ij}(x) = (FD_{ij}) \quad (5)$$

در این معادله، تابع h_{ij} تأثیری را که بر اثر برنده شدن نورون i روی نورون j به‌هنگام به‌کارگیری ورودی x به‌وجود می‌آید، نشان می‌دهد به‌طور مستقیم از فاصله بین نورون i و j شکل می‌گیرد (FD_{ij}) .

معیارهای ارزیابی مدل

در این پژوهش، برای ارزیابی کارایی و توانایی مدل‌های ترکیبی پیشنهادی از سه معیار ضریب تبیین r^2 ، جذر میانگین مربع خطا $RMSE$ و ضریب نش-سانکلیف NSE استفاده شده است که به‌صورت معادلات زیر تعریف می‌شوند:

$$NSE = 1 - \frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{\sum_{i=1}^N (x_i - \bar{x}_i)^2} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{n}} \quad (7)$$

$$r^2 = \left[\frac{\sum_{i=1}^N [(x_i - \bar{x}_i)(\hat{x}_i - \bar{\hat{x}}_i)]}{\sqrt{[\sum_{i=1}^N (x_i - \bar{x}_i)^2][\sum_{i=1}^N (\hat{x}_i - \bar{\hat{x}}_i)^2]}} \right]^2 \quad (8)$$

در معادلات بالا: x_i و \hat{x}_i به ترتیب مقادیر مشاهداتی و محاسباتی؛ \bar{x}_i میانگین مقادیر مشاهداتی؛ $\bar{\hat{x}}_i$ میانگین مقادیر محاسباتی؛ و N ، تعداد کل داده است. بهترین مقدار برای معیارهای یادشده به ترتیب یک، صفر و یک است. برای طراحی و کدنویسی مدل‌های ترکیبی SOM-SVM و FL-SOM، اجرایی کردن الگوریتم‌های خوشه‌بندی و تعیین تعداد بهینه خوشه‌ها از نرم‌افزار MATLAB استفاده شد.

نتایج و بحث

دسته‌بندی چاه‌های مشاهده‌ای با استفاده از روش


خوشه‌بندی SOM

در این مرحله، چاه‌های مشاهده‌ای انتخاب شده (شکل ۵-الف) بر اساس پارامترهای سطح آب، موقعیت چاه‌ها و ارتفاع از سطح آب‌های آزاد با استفاده از روش SOM دسته‌بندی شدند. مناسب‌ترین تعداد گروه، برای دسته‌بندی چاه‌ها، سه گروه و پارامترهای میانگین و

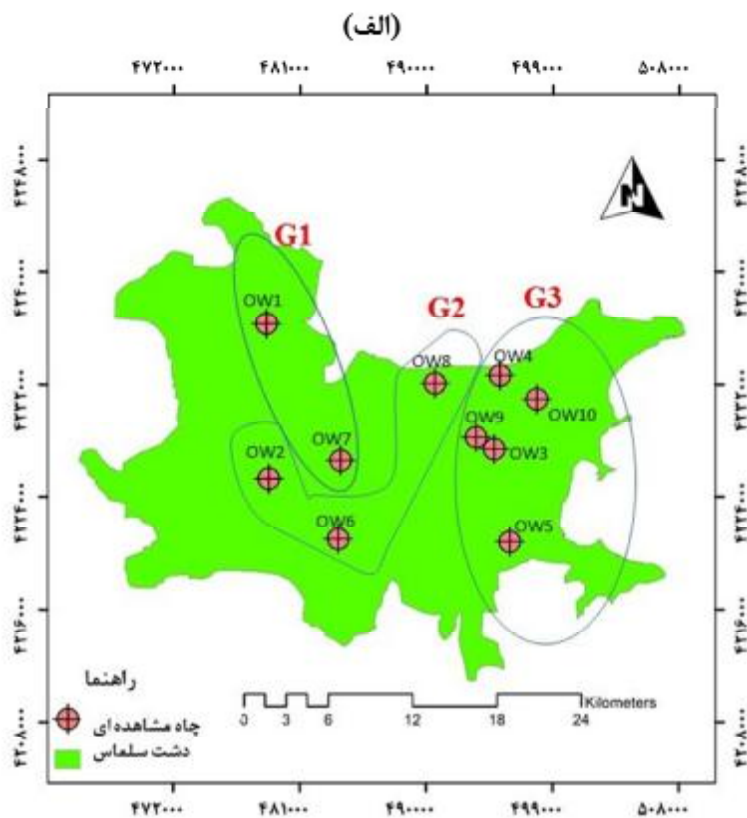
1- Coefficient of determination (r^2)

2- Root mean squared error (RMSE)

3- Nash-Sutcliffe efficiency (NSE)

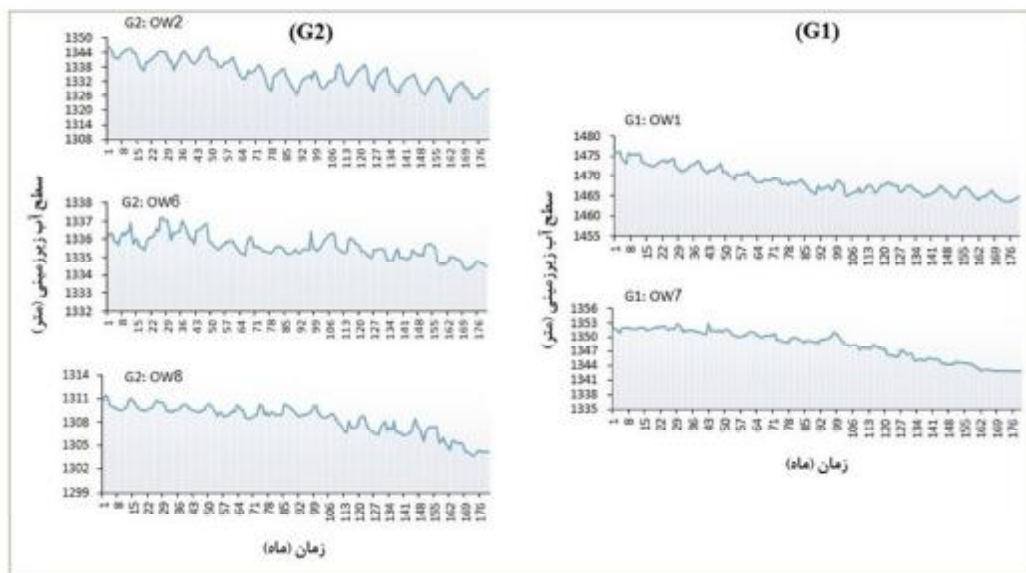


شکل ۲- الف) ساختار نهایی شبکه SOM؛ ب) نمودار صفحات وزنی SOM به ازای هر عضو از بردار ورودی



شکل ۳- الف) دسته‌بندی چاه‌های مشاهده‌ای در سه گروه (G1 و G2 و G3)

(ب)



ادامه شکل ۳- ب) نوسانات سطح آب زیرزمینی در چاه‌های مشاهده‌ای گروه اول (G1) و دوم (G2)

جدول ۱- مقادیر بهینه پارامترهای SVM

تابع کرنل	پارامتر کرنل	گاما	چاه مشاهده‌ای
RBF	۴۸/۰۸	۱۸/۷۳	چاه مشاهده‌ای ۱
RBF	۱۶/۶۴	۱۵/۱۷	چاه مشاهده‌ای ۲
RBF	۲۲/۸۱	۱۲/۸۳	چاه مشاهده‌ای ۳
RBF	۵/۹۷	۱۶/۳۰	چاه مشاهده‌ای ۴
RBF	۲۳/۸۹	۴/۹۵	چاه مشاهده‌ای ۵
RBF	۱۷/۳۶	۳/۵۶	چاه مشاهده‌ای ۶
RBF	۷۰/۰۳	۹۲/۶۹	چاه مشاهده‌ای ۷
RBF	۷/۲۵	۱۲/۰۵	چاه مشاهده‌ای ۸
RBF	۹/۸۳	۱۱/۵	چاه مشاهده‌ای ۹
RBF	۱۹/۱۳	۴۵/۵۳	چاه مشاهده‌ای ۱۰

قوانین فازی برای هر گروه از چاه‌های مشاهده‌ای در شکل ۵ نشان داده شده است. تابع عضویت استفاده شده برای داده‌های ورودی تابع گوسی و تابع عضویت خروجی مدل تابع خطی است. شکل ۶، توابع عضویت ورودی‌های مختلف مدل فازی و قوانین فازی ایجادشده توسط مدل SFL را در گروه G2 نشان می‌دهد.

مدل SFL برای گروه G1، G2 و G3 اجرا و مقادیر r^2 ، RMSE و NSE مربوط به مراحل آموزش و آزمون در هر کدام از چاه‌های مشاهده‌ای محاسبه شد (شکل ۴- الف و ب). در شکل ۷، نمودارهای پراکنش حول محور یک به یک ($y = x$) در مرحله آزمون برای دو مدل SOM-SFL و SOM-LSSVM در تعدادی از چاه‌های مشاهده‌ای نمایش

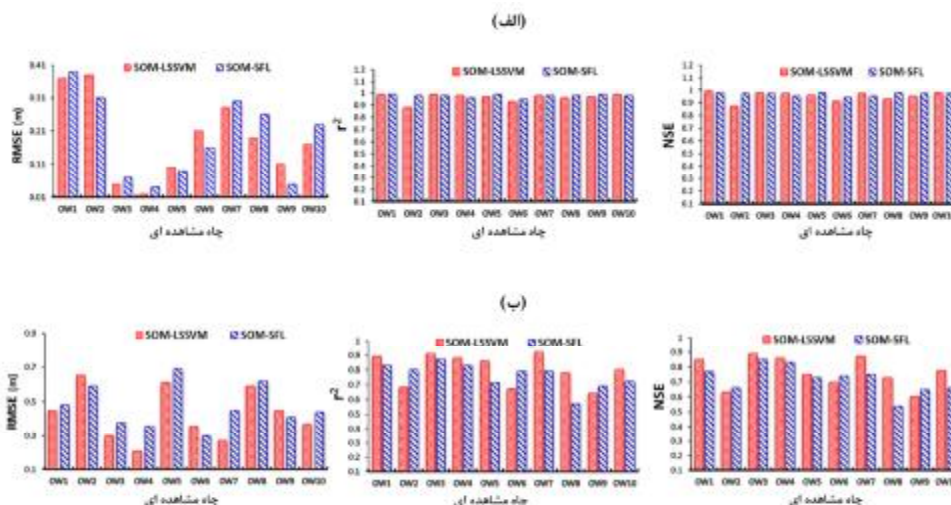
نتایج حاصل از مدل ترکیبی SOM-FL

برای مقایسه بهتر نتایج از مدل فازی ساگنو (SFL) نیز در ترکیب با روش دسته‌بندی SOM برای پیش‌بینی سطح آب زیرزمینی استفاده شد. اولین مرحله در اجرای مدل فازی، دسته‌بندی داده‌ها و تعیین توابع عضویت است که در این پژوهش از روش خوشه‌بندی کاهشی استفاده شده است. در خوشه‌بندی کاهشی، شعاع دسته^۱ (CR) پارامتر مهمی است که تعداد دسته‌ها و قوانین فازی را تعیین می‌کند که مقدار آن بین صفر و یک متغیر است. بنابراین، تعیین مقدار بهینه CR بر اساس کمینه خطای ایجادشده امر مهمی است. مقادیر بهینه CR به دست آمده و تعداد

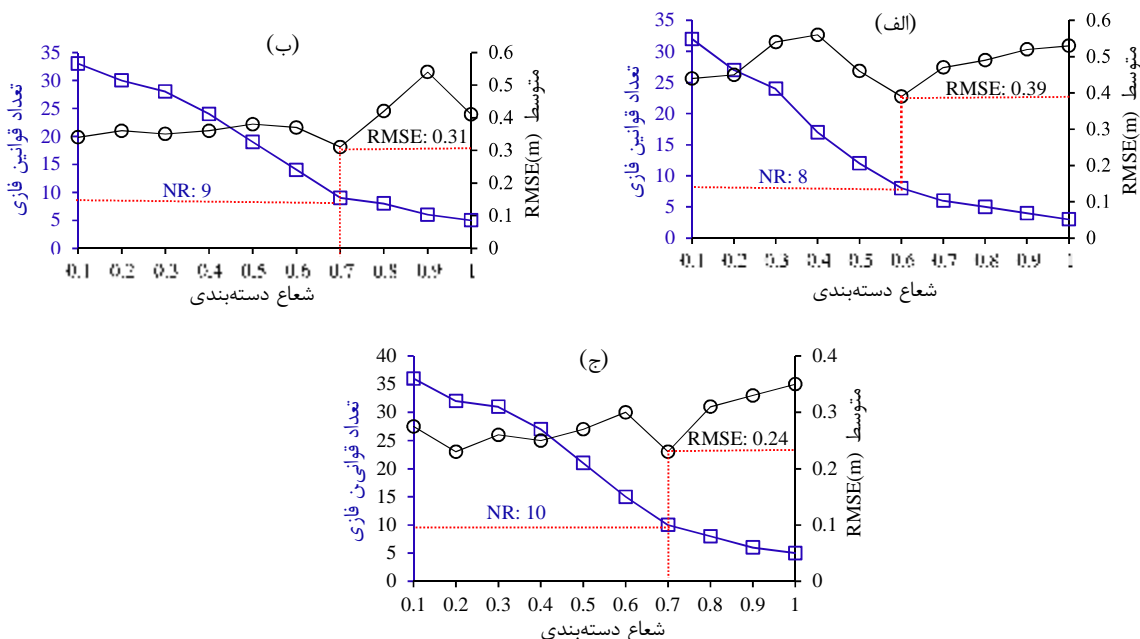
1- Clustering radius (CR)

همان‌طور که در شکل ۴-ب نشان داده شده است، در چاه‌های مشاهده‌ای OW2، OW5 و OW8 (گروه G2 و G3) خطای پیش‌بینی نسبت به سایر چاه‌ها بالاتر است. این امر می‌تواند به دلیل نوسانات فصلی زیاد سطح آب زیرزمینی باشد؛ به طوری که در تعدادی از این چاه‌های مشاهده‌ای نوسانات از روند خاصی نیز پیروی نمی‌کنند.

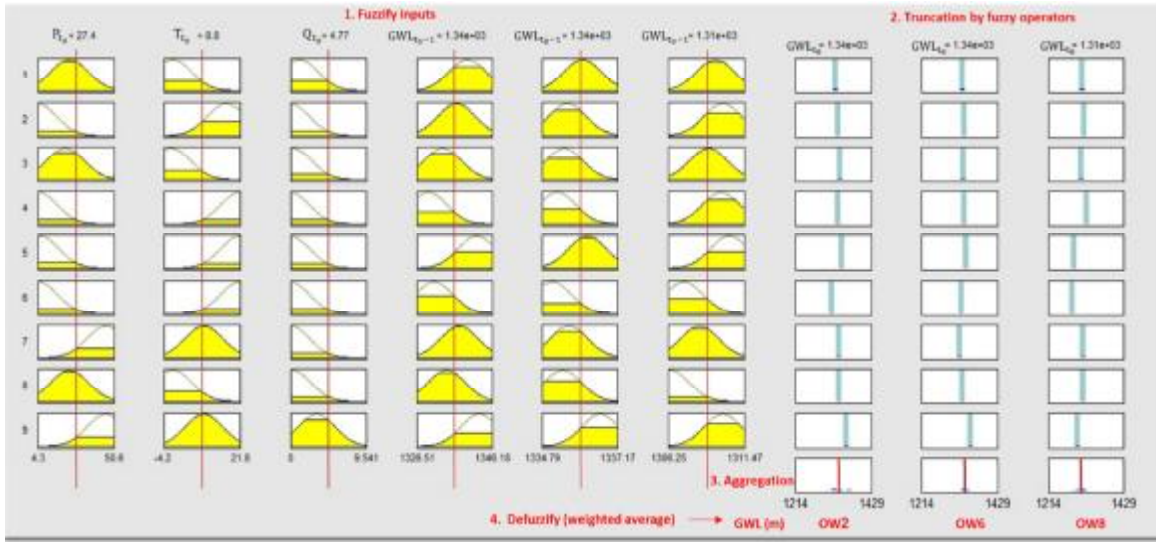
داده شده است. همان‌طور که ملاحظه می‌شود، همبستگی قابل قبولی بین مقادیر مشاهداتی و پیش‌بینی‌شده وجود دارد. برای مقایسه بهتر نتایج مقادیر پیش‌بینی‌شده توسط مدل‌ها و مقادیر مشاهداتی در دو چاه مشاهده‌ای OW1 و OW2 در شکل ۸ نمایش داده شده است.



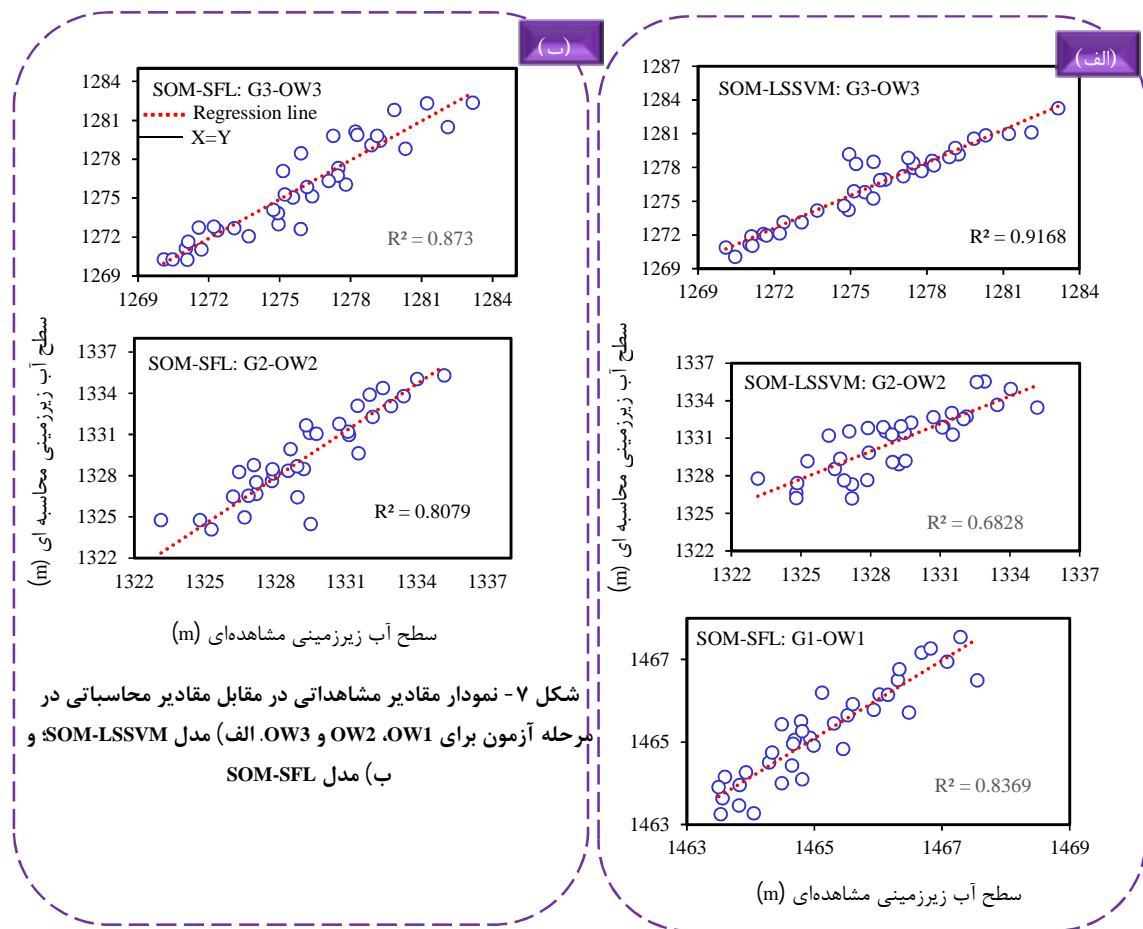
شکل ۴- مقادیر RMSE، r^2 و NSE در چاه‌های مشاهده‌ای مختلف. الف: مرحله آموزش؛ ب: مرحله آزمون

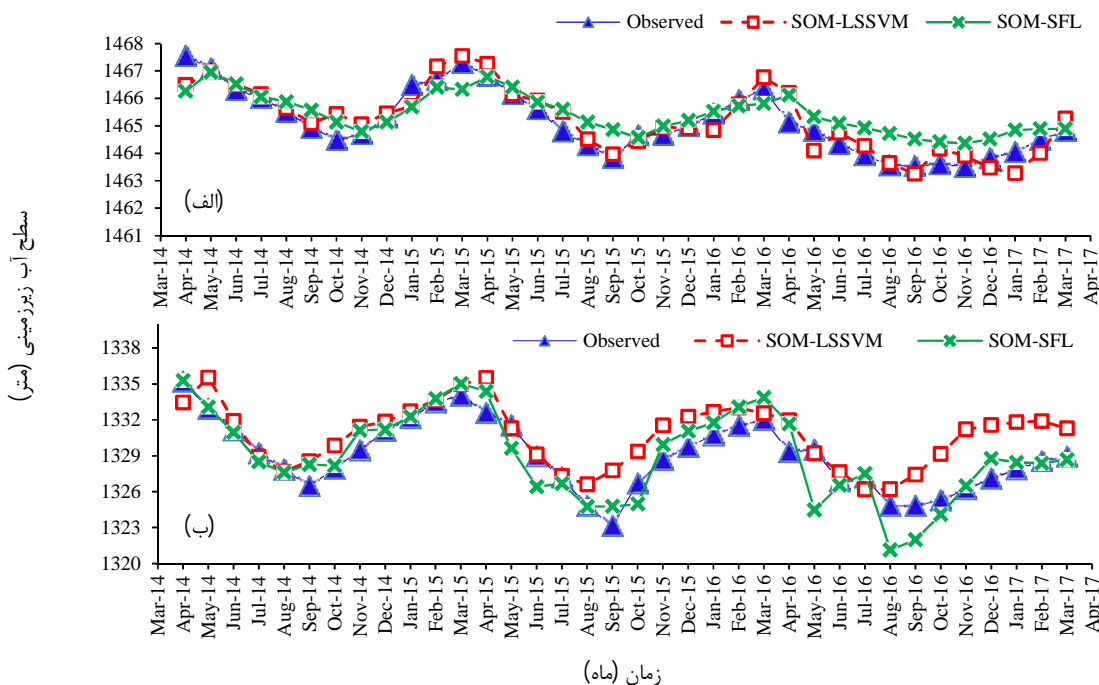


شکل ۵- مقادیر شعاع دسته‌بندی در مقابل تعداد قوانین فازی (NR) و متوسط خطای (RMSE) چاه‌های مشاهده‌ای در هر گروه. الف) گروه اول (G1)؛ ب) گروه دوم (G2)؛ ج) گروه سوم (G3)



شکل ۶- شکل گرافیکی از توابع عضویت ورودی‌های مختلف، قوانین فازی و مراحل مختلف اجرای مدل فازی در گروه دوم (G2) از چاه‌های مشاهده‌ای





شکل ۸- مقایسه بین مقادیر پیش‌بینی شده و مقادیر مشاهداتی در مرحله آزمون. (الف) چاه مشاهده‌ای ۱؛ و (ب) چاه مشاهده‌ای ۲

نتیجه‌گیری

هدف از این پژوهش، پیش‌بینی سطح آب زیرزمینی در آبخوان دشت سلماس است. برای کسب نتایج بهتر و دقیق‌تر، از روش SOM برای خوشه‌بندی چاه‌های مشاهده‌ای استفاده شد. مدل‌های ترکیبی SOM-SFL و SOM-LSSVM برای پیش‌بینی سطح آب زیرزمینی انتخاب شدند. با استفاده از روش SOM، مشکل ناهمگنی و ناهمسانی محیط آبخوان تا حد زیادی برطرف شده و چاه‌های مشاهده‌ای که تراز سطح آب زیرزمینی و نوسانات فصلی مشابه دارند، در یک گروه قرار می‌گیرند. ارزیابی نتایج مدل‌سازی در مرحله آموزش و آزمون، توانایی بالای مدل‌های ترکیبی پیشنهادی را نشان می‌دهد. به دلیل آنکه نمی‌توان به‌طور قطعی تعیین کرد که کدام یک از مدل‌های ترکیبی نتایج دقیق‌تری ارائه داده‌اند، پیشنهاد می‌شود از ترکیب نتایج دو مدل پیشنهادی با استفاده از مدل‌های مرکب برای دستیابی به نتایج دقیق‌تر استفاده شود.

منابع

۱. اعلمی م. ت. صادق فام س. فاضلی فرد م. ح. و تقی‌پور ل. ۱۳۹۲. مدل‌سازی سری داده‌ها. انتشارات دانشگاه تبریز. تبریز. ۲۹۹ ص.
۲. نادری ک. ندیری. ع. ا. اصغری مقدم ا. و کرد م. ۱۳۹۷. روشی جدید برای شناسایی و تعیین مناطق در معرض خطر فرونشست (مطالعه موردی: آبخوان دشت سلماس). اکوهیدرولوژی. ۵(۱): ۸۵-۹۷.
۳. ندیری ع. ا. نادری ک. اصغری مقدم ا. و حبیبی م. ح. ۱۳۹۵. پیش‌بینی زمانی و مکانی سطح آب‌زیرزمینی با استفاده از روش‌های هوش مصنوعی و زمین آمار (مطالعه موردی: دشت دوزدان). مجله جغرافیا و برنامه‌ریزی. ۲۰(۵۸): ۲۸۱-۳۰۱.
4. Alvisi S. Mascellani G. Franchini M. and Bardossy A. 2006. Water level forecasting through fuzzy logic and artificial neural network approaches. Hydrology Earth System Science. 10(1): 1-17.
5. Asefa T. Kemblowski M. McKee M. and Khalil A. 2006. Multi-time scale stream

- parameters of a wastewater treatment plant using a supervised committee fuzzy logic model. *Journal of Cleaner Production*. 180: 539-549.
19. Nikravesh M. and Aminzadeh F. 2003. *Soft computing and intelligent data analysis in oil exploration*. Elsevier. Berkeley, USA. 744 p.
 20. Nourani V. Aalami M. T. and Vousoghi F. D. 2016. Wavelet-ANFIS approach to model and infill missing groundwater level data. *Journal of Hydrologic Engineering*. 21(9): p. 05016018.
 21. Nourani V. and Parhizkar M. 2013. Conjunction of SOM-based feature extraction method and hybrid wavelet-ANN approach for rainfall-runoff modeling. *Journal of Hydroinformatics*. 15(3): 829-848.
 22. Raghavendra S. N. and Deka P. C. 2014. Support vector machine application in the field of hydrology: A review. *Applied soft Computing*. 19: 372-386.
 23. Shiri J. Kisi O. Yoon H. Lee K. K. and Nazemi A. H. 2013. Prediction groundwater level fluctuations with meteorological effect implications, A comparative study among soft computing techniques. *Computer & Geoscience*. 56: 32-44.
 24. Shirmohammadi B. Vafakhah M. Moosavi V. and Moghaddamnia A. 2013. Application of several data-driven techniques for prediction groundwater level. *Water Resource Manage*. 27: 419-432.
 25. Suykens J. A. De Brabanter j. Lukas L. and Vandewalle J. 2002. Weighted least squares support vector machines: robustness and spare approximation. *Neurocomputing*. 48(1): 85-105.
 26. Takagi T. and Sugeno M. 1985. Identification of systems and its application to modelling and control. *IEEE Transaction on system, Man and Cybernetics*. 15: 116-132.
 27. Vapnik V. N. 1995. *The nature of statistical learning theory*. Springer. New York. 150 p.
 28. Yu P. S. Chen C. J. and Chen S. J. 2000. Application of gray and fuzzy method for rainfall forecasting. *Journal of Hydrologic Engineering*, ASCE. 5(1): 339-345.
 29. Zadeh L. A. 1965. Fuzzy Sets. *Information and Control*. 8: 338-353.
 - flow prediction, the support vector machine approach. *Journal of Hydrology*. 318: 7-16.
 6. Behzad M. Asghari K. and Coppola E. A. 2010. Comparative study of SVMs and ANNs in aquifer water level prediction. *Journal of Computer in Civil Engineering*. 5: 408-413.
 7. Fang J. H. and Chen H. C. 1997. Fuzzy modeling and the prediction of porosity and permeability from the compositional and textural attributes of sandstone. *Journal of Petroleum Geology*. 20(2): 185-204.
 8. Jha M. K. and Sahoo S. 2015. Efficacy of neural network and genetic algorithm techniques in simulating spatio-temporal fluctuation of groundwater. *Hydrological Processes*. 29: 671-691.
 9. Kohonen T. Kaski S. and Lappalainen H. 1997. Self-organized formation of various invariant-feature filters in the adaptive subspace SOM. *Neural Computation*. 9(6): 1321-1344.
 10. Kohonen T. 1982. Self-organized formation of topologically correct feature maps. *Biological cybernetics*. 43(1): 59-69.
 11. Larsen P. M. 1980. Industrial application of fuzzy logic control. *International journal of Man-Machine Studies*. 12: 3-10.
 12. Lee K. H. 2004. *First course on fuzzy theory and application*. Springer. Berlin. 335 p.
 13. Mamdani E. H. and Assilian S. 1975. An experimental in linguistic synthesis with a fuzzy logic control. *International journal of Man-Machine Studies*. 7:1-13.
 14. Nadiri A. A. Asadi S. Babaizadeh H. and Naderi K. 2018b. Hybrid fuzzy model to predict strength and optimum compositions of natural Alumina-Silica-based geopolymers. *Computers and Concrete*. 21: 103-110.
 15. Nadiri A. A. Gharekhani M. Khatibi R. Sadeghfam S. and Asgari Moghaddam A. 2017a. Groundwater vulnerability indices conditioned by supervised intelligence committee machine (SICM). *Sci. Total Environ*. 574: 691-706.
 16. Nadiri A. A. Gharekhani M. Khatibi R. and Asgari Moghaddam A. 2017b. Assessment of groundwater vulnerability using supervised committee to combine fuzzy logic models. *Environ. Sci. Pollut. Res*. 24(9): 8562-8577.
 17. Nadiri A. A. Sedghi Z. Khatibi R. and Gharekhani M. 2017c. Mapping vulnerability of multiple aquifers using multiple models and fuzzy logic to objectively derive model structures. *Sci. Total Environ*. 593: 75-90.
 18. Nadiri A. A. Shokri S. and Tsai F. T. C. 2018a. Prediction of effluent quality

