

استفاده از خوشه‌بندی مکانی برای پیش‌بینی پارامترهای کیفی آب زیرزمینی با مدل انفیس

محمد تقی اعلمی^۱، وحید نورانی^۱، فرناز دانشور و ثوقی^۲

۱- استاده، گروه مهندسی عمران-آب، دانشکده مهندسی عمران، دانشگاه تبریز
۲- دانشجوی دکترای عمران- سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه تبریز
(نویسنده مسئول) ۰۹۱۴۱۵۳۳۲۹۶، fdaneshvar.vousoughi@gmail.com

(دریافت ۹۳/۱۰/۱۴ پذیرش ۹۴/۳/۲۳)

چکیده

مدل‌سازی پارامترهای کیفی آب‌های زیرزمینی به‌عنوان یکی از منابع تأمین آب شهری، کشاورزی و صنعتی بسیار حائز اهمیت است. همراه با توسعه استفاده از روش‌های نوین مدل‌سازی در سال‌های اخیر، استفاده از ابزارهای پیش‌پردازش زمانی و مکانی داده‌ها در بالا بردن دقت این روش‌ها اهمیت زیادی یافته است. در پژوهش حاضر از ابزارهای زمین‌آمار یا کوکریجینگ و نقشه‌های خود سازمانده به‌ترتیب به‌عنوان تخمین‌گر مکانی و خوشه‌بندی در ترکیب با مدل شبکه عصبی - فازی انفیس برای پیش‌بینی زمانی پارامترهای کیفی هدایت الکتریکی و مقدار کل جامدات محلول در آب زیرزمینی دشت اردبیل استفاده شد. همچنین در این مطالعه، اثر خوشه‌بندی مکانی در پیش‌بینی زمانی هدایت الکتریکی و مقدار کل جامدات محلول بررسی شد. نتایج نشان داد که خوشه‌بندی مکانی با انتخاب ورودی‌های مؤثر، روش مناسبی در جهت بهبود پیش‌بینی پارامترهای کیفی آب زیرزمینی با استفاده از مدل انفیس است.

واژه‌های کلیدی: ابزارهای زمین‌آمار، شبکه عصبی - فازی، پارامترهای کیفی آب زیرزمینی، روش خوشه‌بندی، دشت اردبیل

۱- مقدمه

محوری همچون شبکه عصبی - فازی انفیس^۱ را بهبود ببخشد. روش نقشه‌های خودسازمانده یک روش پیشنهادی برای انجام خوشه‌بندی مکانی داده‌هاست. در مسائل مربوطه به آب‌های زیرزمینی، از آنجا که کیفیت آن‌ها معمولاً در نقاط محدودی اندازه‌گیری می‌شود، لذا به‌منظور تخمین پارامترهای کیفی در سایر نقاط از ابزارهای زمین‌آمار از قبیل کریجینگ و کوکریجینگ استفاده می‌شود [۳]. در زمینه کاربرد ابزارهای زمین‌آمار در تخمین مکانی پارامترهای کیفی آب زیرزمینی می‌توان به پژوهش‌های زیادی از جمله ریزو و موسر در زمینه تحلیل ۱۹ پارامتر شیمیایی آب زیرزمینی و داده‌های میکربی، گاوس و همکاران در پیش‌بینی مکانی پارامتر آرسنیک، بارسا و پاسارللا در مورد شناسایی مکان‌های آلوده از نظر کیفیت آب زیرزمینی، تقی‌زاده و همکاران در تخمین مکانی شش پارامتر کیفی آب زیرزمینی شامل مقدار کل جامدات محلول، هدایت الکتریکی، سختی، کلر، سولفات و نسبت جذب سدیم، ثمین و همکاران برای تخمین داده‌های نسبت جذب سدیم و کلر با استفاده از داده‌های شوری آب زیرزمینی، احمدیان در تخمین مکانی پارامترهای مقدار کل جامدات محلول، هدایت

کاهش ریزش‌های جوی، افزایش جمعیت و نیاز به آب و مواد غذایی و برداشت بی‌رویه آب از چاه‌های مجاز و غیرمجاز موجب شده که در مناطق مختلف کشور سطح آب‌های زیرزمینی و کیفیت این آب‌ها در دشت‌های استان اردبیل به‌ویژه در دشت اردبیل تحت تأثیر قرار گیرد. با توجه به اهمیت کیفیت آب‌های زیرزمینی در تولید محصول و در نتیجه بهره‌وری اقتصادی، مدل‌سازی پارامترهای کیفیت آب زیرزمینی مهم است.

در زمینه مدل‌سازی پدیده‌های هیدرولوژیکی می‌توان به دو دسته پژوهش اشاره کرد: نخست روش‌های کلاسیک شامل مدل‌های تفهیمی و مدل‌های فیزیکی و دوم روش‌های نوین که مبتنی بر استفاده از ابزارهایی همچون شبکه عصبی مصنوعی و منطق فازی است [۱]. با استفاده از روش‌های هوش مصنوعی همچون شبکه عصبی و منطق فازی می‌توان بعضی از کاستی‌ها و مشکلات موجود در روش‌های تفهیمی را تا حدودی از بین برد [۲]. داده‌های موجود در فرایندهای هیدرولوژیکی همان‌طور که به‌صورت زمانی تغییر می‌کنند، ممکن است به‌صورت مکانی نیز متغیر باشند. بنابراین، خوشه‌بندی مکانی داده‌ها می‌تواند قابلیت روش‌های داده

¹ ANFIS

مدل شبکه عصبی را برای پیش‌بینی شوری منابع آب ارائه دادند [۲۰]. بنرج و همکاران قابلیت شبکه عصبی را در تخمین شوری آب زیرزمینی در آبخوان ایسلند بررسی کردند. مدل شبکه عصبی پیشنهادی قابلیت انتخاب پارامترهای مکانی و زمانی بهینه را برای بهبود مدل دارا بود [۲۴]. اورزپوفسکی و همکاران کیفیت آب زیرزمینی و سطحی را تحت شرایط اقلیمی جنوب غرب لهستان با شبکه عصبی مصنوعی مدل‌سازی کردند [۲۵].

در زمینه پیش‌بینی پارامترهای کیفی آب زیرزمینی با استفاده از ابزار انفیس می‌توان به پژوهش‌های زیر اشاره کرد: موسوی و امیری آلودگی نیترا تی آب زیرزمینی را با استفاده از مدل انفیس پیش‌بینی کردند. آن‌ها از داده‌های بیکرنات، سختی، هدایت الکتریکی، کلسیم و منیزیم به‌عنوان ورودی برای مدل‌سازی پارامتر کیفی نیترات استفاده کردند [۲۶]. کیسی و آی نیز از انواع مدل‌های انفیس برای پیش‌بینی پارامتر اکسیژن مورد نیاز شیمیایی استفاده کردند [۲۷]. توتما و همکاران برای مدل‌سازی پارامتر هدایت الکتریکی آب زیرزمینی با استفاده از مدل انفیس از داده‌های مقدار کل جامدات محلول به‌عنوان ورودی بهره‌گرفتند. نتایج نشان دادند مدل انفیس قابلیت بالایی در مدل‌سازی پارامترهای کیفی آب زیرزمینی دارد [۲۸].

در این پژوهش، از سه گام مختلف برای پیش‌بینی پارامترهای کیفی هدایت الکتریکی و مقدار کل جامدات محلول استفاده شد. در گام اول، به دلیل اینکه ایستگاه‌های اندازه‌گیری پارامترهای کیفی و پیرومترهای تراز آب زیرزمینی هم‌مکان نیستند، مقدار متغیرهای کیفی در محل پیرومترها با استفاده از روش کوکریجینگ تخمین زده شد. در گام دوم، پیرومترها با استفاده از روش نقشه‌های خودسازمانده، از نظر مکانی خوشه‌بندی شدند. در گام نهایی با استفاده از ابزار انفیس، مقدار پارامترهای کیفی در پیرومتر مرکزی هر خوشه برای یک گام زمانی جلوتر پیش‌بینی شد. نکته مهم دیگری که در این پژوهش مورد توجه قرار گرفت، پیش‌پردازش مکانی داده‌ها و انتخاب ورودی‌های مؤثر به‌وسیله آنالیز خوشه‌بندی نقشه‌های خودسازمانده قبل از ورود به شبکه عصبی - فازی تطبیقی بود که با این کار می‌توان بازدهی مدل را تا حد مناسبی افزایش داد.

۲- مواد و روش‌ها

۲-۱- مدل شبکه عصبی - فازی تطبیقی

سیستم فازی، سیستمی منطبق بر قواعد منطقی اگر - آنگاه است که با تئوری‌های احتمال کلاسیک قابل تحلیل نیست. نقطه شروع ساخت یک سیستم فازی، به‌دست آوردن مجموعه‌ای از قواعد اگر - آنگاه فازی است. بنابراین داشتن روشی که با استفاده از آن بتوان

الکتریکی، یون‌های سدیم و نیترات، طاهری تیزرو و همکاران برای تخمین مکانی پارامترهای نسبت جذب سدیم، هدایت الکتریکی، مقدار کل جامدات محلول، سدیم و خاصیت اسیدی، موسوی فضل و همکاران در تخمین پارامترهای نیترات، سدیم و هدایت الکتریکی، دلبری در تخمین مکانی پارامترهای هدایت الکتریکی، مقدار کل جامدات محلول، سدیم و نسبت جذب سدیم و تقی‌زاده باز در زمینه تخمین مکانی پارامترهای سدیم، سختی، هدایت الکتریکی، کلر، نسبت جذب سدیم و سولفات اشاره کرد [۱۳-۴].

روش خوشه‌بندی خودسازمانده در پژوهش‌های مرتبط با بسیاری از پدیده‌های هیدرولوژیکی کاربرد داشته است که از آن جمله می‌توان به کاربرد آن در زمینه آب زیرزمینی اشاره کرد. در زمینه کاربرد روش خوشه‌بندی نقشه خودسازمانده، پتر و داسارگوس روش‌های آنالیز مؤلفه‌های اصلی و روش نقشه‌های خودسازمانده را به‌منظور تحلیل داده‌های کیفیت آب زیرزمینی به‌کار بردند. آن‌ها خوشه‌بندی را برای دو سفره آب زیرزمینی شامل ۴۷ ایستگاه مشاهداتی برای ۱۴ متغیر کیفی به‌کار بردند. روش نقشه‌های خودسازمانده، خوشه‌بندی درستی را برای حوضه ارائه داد [۱۴]. سانچز و همکاران روش نقشه‌های خودسازمانده را برای طبقه‌بندی داده‌های هیدروشمیایی سفره‌ای واقع در منطقه نیمه خشک در جنوب شرقی اسپانیا اعمال کردند [۱۵]. هونگ و روزان برای تشخیص تأثیر نفوذ جریان سیلابی بر کیفیت آب زیرزمینی و همچنین روابط بین پارامترهای کیفی آب زیرزمینی از ابزار نقشه‌های خودسازمانده بهره‌گرفتند [۱۶]. نتایج، قابلیت این ابزار در تشخیص روابط دینامیکی بین پارامترهای با ابعاد بالا را به‌خوبی نشان داد. پتر و همکاران برای طبقه‌بندی ۱۳۱ نمونه آب زیرزمینی در دو آبخوان از روش‌های نقشه‌های خودسازمانده و GEO3DSOM استفاده کردند [۱۷]. هر دو روش در تشخیص تفاوت بین پارامترهای کیفی نتایج خوبی را ارائه کردند. چویی و همکاران پارامترهای شیمیایی آب زیرزمینی را با استفاده از ابزار نقشه‌های خودسازمانده به دو گروه و شش زیرگروه تقسیم‌بندی کردند [۱۸]. تقوین و همکاران در مطالعه خود هشت پارامتر کیفی آب زیرزمینی را از نظر شوری طبقه‌بندی کردند. آن‌ها داده‌های هیدروژئوشیمیایی را با روش نقشه‌های خودسازمانده در هشت گروه (دو گروه با شوری بالا، سه گروه با شوری کم و سه گروه با آب سالم و تازه) جای دادند [۱۹].

در سال‌های اخیر، شبکه عصبی مصنوعی به‌عنوان یک رویکرد متفاوت برای تخمین کیفیت آب آبخوان استفاده شده است [۲۰]. لین و چن مدل‌های مختلف شبکه عصبی مصنوعی را برای تعیین پارامترهای آبخوان پیشنهاد دادند [۲۱، ۲۲ و ۲۳]. میسر و دندی

بنابراین با توجه به تابع زنگوله‌ای به‌عنوان تابع عضویت خروجی Q_i^1 به صورت زیر محاسبه می‌شود

$$Q_i^1 = \mu_{A_i}(x) = \frac{1}{1 + ((x - c_i) / a_i)^{2b_i}} \quad (1)$$

که در این رابطه


x (یا y) ورودی نرون و A_i یا $B_{i,2}$ سیستم فازی مربوطه و همچنین $\{a_i, b_i, c_i\}$ متغیرهای تطبیقی هستند که به‌عنوان پارامترهای مقدم شناخته می‌شوند.

در لایه دوم تمامی قوانین موجود میان ورودی با به‌کارگیری قاعده تقاطع یا همان اشتراک فازی (AND) فرمول‌بندی می‌شوند. برای هر قانون عملیات ضرب برای برآورد ضریب استفاده می‌شود

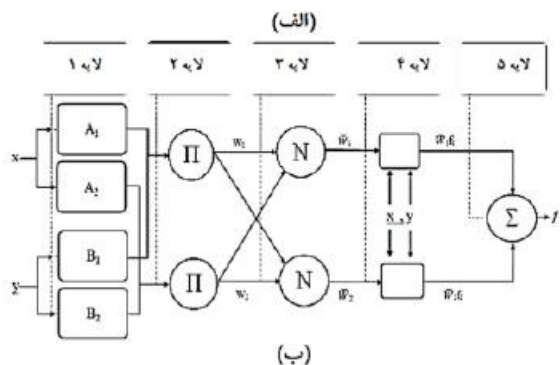
$$Q_i^2 = W_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y) \quad i=1, 2 \quad (2)$$

در لایه سوم نرون i ام، ضریب نرمال شده به صورت زیر محاسبه می‌شود

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1, 2 \quad (3)$$



$$\left. \begin{aligned} f_1 &= p_1x + q_1y + r_1 \\ f_2 &= p_2x + q_2y + r_2 \end{aligned} \right\} f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2}$$



شکل ۱- الف- مکانیسم قوانین سیستم فازی تاکاجی- سوگنو
ب- آرایش معادل ANFIS [۲۹]

اطلاعات موجود برای ساخت این قواعد را تعیین کرد به‌عنوان ابزاری کارآمد به‌شمار می‌رود. در این میان شبکه‌های عصبی- مصنوعی به دلیل قابلیت‌های آموزش‌پذیری و با استفاده از الگوهای مختلف آموزشی می‌توانند ارتباط مناسبی بین متغیرهای ورودی و خروجی ایجاد نمایند. لذا استفاده ترکیبی از سیستم استنتاج فازی و شبکه‌های عصبی- مصنوعی می‌تواند ابزار قدرتمندی با عنوان سیستم استنتاج فازی- عصبی تطبیقی به‌وجود آورد. در این روش ترکیبی، بخش فازی، رابطه بین متغیرهای ورودی و خروجی را ایجاد کرده و پارامترهای مربوط به توابع عضویت بخش فازی به وسیله شبکه عصبی بهینه می‌شود.

در سیستم استنتاج فازی- عصبی تطبیقی ابتدا ساختار یک مدل با پارامترهای مشخص که متناسب با ورودی‌ها، درجه عضویت و قوانین است، انتخاب می‌شود. سپس بخشی از داده‌های موجود که دربرگیرنده تمامی خصوصیات داده‌ها شامل داده‌های بیشینه و کمینه باشد، انتخاب شده و در مرحله آموزش با کمینه کردن میزان خطا، پارامترهای مدل به مقادیر واقعی نزدیک می‌شوند. پس از آموزش سیستم و انتخاب پارامترهای مناسب، نیاز به بررسی صحت‌سنجی مدل است. از این رو بخشی از داده‌ها که در مرحله آموزش به‌کار نرفته است، به‌عنوان ورودی در مرحله صحت‌سنجی مورد استفاده قرار می‌گیرد تا از دقت و اعتبار مدل اطمینان حاصل شود. مدل انفیس غالباً با استفاده از یک سیستم فازی تاکاجی- سوگنو به صورت ساختار شبکه‌ای پیش‌رونده و دارای پنج لایه است. به‌عنوان نمونه یک مدل انفیس مرتبه اول تاکاجی- سوگنو با دو ورودی، یک خروجی و دو تابع عضویت برای هر یک از ورودی‌ها در شکل ۱ نشان داده شده است [۲۹]. مطابق شکل ۱ فرض شد که سیستم فازی دارای ورودی x و y و یک خروجی f است. برای چنین مدلی قوانین معمولی با در نظر گرفتن دو قانون فازی اگر- آنگاه به صورت زیر تعریف می‌شود:

Rule (1): If $\mu(x)$ is A_1 and $\mu(y)$ is B_1 : $f_1 = p_1x + q_1y + r_1$

Rule (2): If $\mu(x)$ is A_2 and $\mu(y)$ is B_2 : $f_2 = p_2x + q_2y + r_2$

که متغیرهای A_1, B_1, A_2, B_2 به ترتیب توابع عضویت برای ورودی x و y های هستند و p_1, q_1, r_1 و p_2, q_2, r_2 پارامترهای تابع خروجی هستند. بنابراین در این حالت فرمول‌بندی انفیس از یک آرایش شبکه عصبی پنج لایه پیشرو پیروی می‌کند.

در لایه نخست، هر نرون درجه عضویت متغیر را تعیین می‌کند. اگر خروجی نرون- i ام در لایه k -ام به صورت Q_i^k نشان داده شود،

شده سپس به حد ثابتی می‌رسد که این فاصله را شعاع تأثیر و مقدار نیم‌تغییر نما که ثابت شده را حد آستانه گویند.

اگر برای تخمین یک متغیر اصلی از یک یا چند متغیر کمکی دارای همبستگی بالا با متغیر اصلی استفاده شود در این صورت روش تخمین کوکریجینگ نامیده می‌شود. سیستم معادلاتی کوکریجینگ را می‌توان به هر تعداد متغیر ثانویه تعمیم داد. با فرض وجود فقط یک متغیر مکانی کمکی $Z_2(x_i)$ در کنار متغیر مکانی اصلی $Z_1(x_j)$ مقدار نامعلوم متغیر در نقطه x_0 برابر $Z^*(x_0)$ است که در تخمین گر کوکریجینگ به صورت زیر تعریف می‌شود

$$Z^*(x_0) = \sum_{i=1}^n \lambda_{1i} Z_1(x_i) + \sum_{j=1}^m \lambda_{2j} Z_2(x_j) \quad (7)$$

که در آن

m و n به ترتیب تعداد جفت مقایسه‌ها برای پارامترهای اصلی و کمکی و λ_{1i} و λ_{2j} عبارت‌اند از وزن‌های آماری اختصاص داده شده به این متغیرهای کمکی و ثانویه.

برای ارزیابی تخمین‌گرهای استفاده شده از روش ارزیابی متقابل استفاده می‌شود. در این روش برای کلیه نقاط مشاهده‌ای در هر مرحله یک نقطه مشاهده‌ای حذف و با استفاده از بقیه نقاط مشاهده‌ای آن نقطه برآورد می‌شود.

۲-۳- روش خوشه‌بندی خودسازمانده

نقشه خودسازمانده به عنوان ابزاری مؤثر برای تبدیل روابط استاتیکی، غیرخطی و پیچیده موجود در داده‌های چندبعدی به روابط هندسی، ساده و با ابعاد کم اجازه می‌دهد تعداد خوشه‌ها با بازرسی دقیق مشخص شود [۳۲]. از آنجای که فشرده‌سازی اطلاعات در حین ساخت و حفظ روابط توپولوژیک و متریک داده‌های اولیه بر روی صفحه نمایش انجام می‌شود، می‌توان تصور کرد که نوعی انتزاع یا چکیده‌سازی نیز روی داده‌ها انجام می‌گیرد.

نقشه خودسازمانده یک نوع شبکه عصبی مصنوعی است که با استفاده از یادگیری بدون نظارت برای تولید داده‌هایی با بعد کم (معمولاً دو بعدی) آموزش داده می‌شوند. نمایش گسسته از فضای ورودی نمونه‌های آموزش یافته، یک نقشه نامیده می‌شود. نقشه متشکل از اجزایی به نام گره‌ها یا نرون‌ها هست. یک بردار وزن مرتبط با هر گره وجود دارد که ابعاد آن بردار وزن، به اندازه همان بردار داده‌های ورودی است و موقعیت آن در فضای نقشه موجود است.

هدف از یادگیری در نقشه خودسازمانده این است که بخش‌های مختلف این شبکه پاسخگویی مشابه به الگوهای ورودی

در لایه چهارم نرون i -ام چگونگی مشارکت و یا به عبارتی تأثیر قانون i -ام را در خروجی مدل محاسبه می‌کند

$$Q_i^4 = \bar{w}_i(p_i x + q_i y + r_i) = \bar{w}_i f_i \quad (4)$$

که در این رابطه

\bar{w}_i خروجی لایه سوم و $\{p_i, q_i, r_i\}$ پارامترهای تنظیمی هستند که در حقیقت به عنوان پارامترهای تالی یا نتیجه مطرح هستند. در لایه آخر نیز خروجی نهایی و کلی انفیس به صورت زیر محاسبه می‌شود [۲۹]

$$Q_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (5)$$

پارامترهایی که باید در روند مدل انفیس بهینه‌سازی شوند عبارت‌اند از پارامترهای مقدم $\{a_i, b_i, c_i\}$ و پارامترهای تالی $\{p_i, q_i, r_i\}$. جانگ و همکاران یک الگوریتم حل ترکیبی برای یافتن مقادیر دقیق پارامترهای مدل انفیس ارائه نموده‌اند که دارای قابلیت بیشتری نسبت به روش کلاسیک بازگشتی است [۳۰].

۲-۲- ابزارهای زمین آمار (روش کوکریجینگ)

توسعه این روش بیشتر به واسطه شرایطی بود که در آن از یک متغیر تعداد نمونه کمی در دست بود. محل‌هایی که در آنها کمبود نمونه وجود دارد، به کمک متغیرهای ثانوی و با استفاده از همبستگی متقابل بین متغیرهای اصلی و ثانوی، تخمین زده می‌شوند. برای تحلیل و بررسی پیوستگی مکانی متغیر محیطی مورد نظر، از یک تابع واریوگرام کریجینگ و کوکریجینگ استفاده شده است [۳۱]


$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} (Z(x_i + h) - Z(x_i))^2 \quad (6)$$

که در آن

$\gamma(h)$ مقدار نیم‌تغییر نما در فاصله h ، مقدار اندازه‌گیری شده متغیر در موقعیت (x_i, x_i+h) ، مقدار اندازه‌گیری شده متغیر مکانی در موقعیت (x_i) و $N(h)$ تعداد جفت مقایسه‌ها به فاصله h در محدوده مورد مطالعه، نیم‌تغییر نماها از سه پارامتر اثر قطعه‌ای، شعاع تأثیر و حد آستانه تشکیل شده‌اند. مقدار نیم‌تغییر نما به ازای $h=0$ را اثر قطعه‌ای می‌گویند که معمولاً ناشی از وجود مولفه‌های تصادفی در توزیع متغیر است که در واقع به تصادفی بودن فرایندها برمی‌گردد و خطاهای نمونه برداری، آماده‌سازی، مقدار نیم‌تغییر نما، آزمایشگاهی و آنالیز است و با افزایش h تا فاصله معینی اضافه

۲-۴- معیار ارزیابی موفقیت

در مرحله خوشه‌بندی مکانی، از ضریب سیلوه می‌توان به‌عنوان معیاری برای اندازه‌گیری اعتبار خوشه استفاده نمود. این ضریب برای یک خوشه درجه شباهت ایستگاه‌های داخل یک خوشه را بیان می‌کند که به‌صورت زیر بیان می‌شود [۳۳]



شکل ۲- ساختار شبکه نقشه خودسازمانده با دو سطح [۳۳]

$$S(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (10)$$

که در آن

$S(i)$ مقدار سیلوه پیزومتر i است. مقادیر کوچک $S(i)$ بیانگر کمی شباهت ایستگاه‌ها در همان خوشه است. کیفیت خوشه‌بندی می‌تواند با استفاده از متوسط سیلوه برای مجموعه کل داده‌ها اندازه‌گیری شود. $a(i)$ فاصله اقلیدسی است که متوسط نامشابهتی خوشه i را از تمام ایستگاه‌های دیگر در خوشه A اندازه می‌گیرد. $b(i)$ فاصله اقلیدسی است که کمینه نامشابهتی متوسط ایستگاه i را از ایستگاه‌های دیگر در غیر از خوشه A بیان می‌کند [۳۳].

در مرحله پیش‌بینی، دو معیار مختلف ضریب تبیین (R^2) و جذر میانگین مربع خطاها به‌منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیشگویی دقیق استفاده شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{\sum_{i=1}^N (G_{obs_i} - \bar{G}_{obs_i})^2} \quad (11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{N}} \quad (12)$$

خاص داشته باشد. هنگامی که یک نمونه از داده‌ها برای آموزش به شبکه داده می‌شود، فاصله اقلیدسی آن از تمامی بردارهای وزنی محاسبه می‌شود. نرون بردار وزنی که بیشترین شباهت را با نمونه ورودی دارد با نام (BMU) بهترین واحد تطبیق نامیده می‌شود. در حین نگاشت، تنها یک نرون برنده وجود خواهد داشت و آن نرونی است که بردار وزنی آن نزدیک‌ترین فاصله به بردار ورودی را داشته باشد، که به سادگی با محاسبه فاصله اقلیدسی بین بردار ورودی و بردار وزنی تعیین می‌شود

$$d_{jk}^p = \sqrt{\sum_i (x_i^p - w_{jk,i})^2} \quad (8)$$

که در این رابطه

x_i^p i امین جز از p امین بردار ورودی x^p است و $w_{jk,i}$ پیوند وزنی x_i^p در نرون واقع در (j,k) لایه کوهن^۱ است. نرون‌ها برای پیروز شدن (رسیدن به بهترین واحد تطابق BMU) در لایه با یکدیگر رقابت می‌کنند، این نرون‌ها با حرف c مشخص شده‌اند. پس از یافتن BMU، بردارهای اولیه نقشه خودسازمانده، به‌روزرسانی می‌شوند. تابع همسایگی گوسین که به‌صورت زیر است، رایج‌ترین تابع مورد استفاده در این زمینه است

$$h_{ci}(r_{jk}(t)) = \exp\left(-\frac{1}{2} \frac{\|r_{jk}\|^2}{R^2(t)}\right) \quad (9)$$

که در این رابطه

$h_{ci}(r_{jk}(t))$ هسته همسایگی، پیرامون واحد برنده c با یک فاصله همسایگی $r_{jk}(t)$ است. $R(t)$ شعاع همسایگی است که معمولاً با زمان کاهش می‌یابد. گام‌های آموزش تا رسیدن به حداکثر تکرار تعیین شده تکرار می‌شود. یک شبکه اساسی نقشه خودسازمانده از یک لایه ورودی و یک لایه کوهن (لایه خروجی) تشکیل شده است. لایه ورودی شامل واحدهای ورودی است که داده‌ها با ابعاد بالا را دریافت می‌کنند. لایه کوهن متشکل از واحدهای خروجی است که بر روی یک شبکه دو بعدی منظم قرار دارد. ساختار شبکه نقشه خودسازمانده با دو سطح در شکل ۲ نشان داده شده است که در آن یک مجموعه بزرگ از نمونه‌های اولیه (بسیار بزرگ‌تر از تعداد خوشه‌های مورد انتظار) با استفاده از نقشه خودسازمانده ساخته شده است [۳۳]. در لایه دوم کوهن داده‌های دسته‌بندی شده در لایه اول درون خوشه‌های خود قرار می‌گیرند.

¹ Kohonen

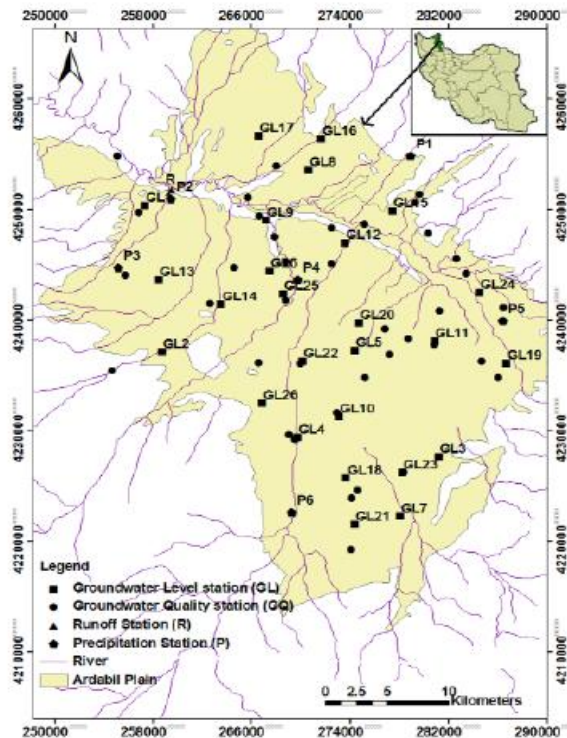
که در آن

N تعداد داده‌های مشاهداتی، G_{com_i} داده‌های محاسباتی (مقدار پیش‌بینی شده)، G_{obs_i} داده‌های مشاهداتی و \bar{G}_{obs} میانگین داده‌های مشاهداتی است. هر چه $RMSE$ به صفر و R^2 به یک نزدیک شود، جواب بهتری برای مدل حاصل شده است.

۲-۵- منطقه مورد پژوهش

منطقه مورد پژوهش دشت اردبیل بود که در شمال غربی ایران در عرض جغرافیایی ۳۸ درجه و ۳ دقیقه تا ۳۸ درجه و ۲۷ دقیقه شمالی و طول جغرافیایی ۴۷ درجه و ۵۵ دقیقه تا ۴۸ درجه و ۲۰ دقیقه شرقی واقع شده است. دشت اردبیل مشرف بر ارتفاعات بخش غربی رشته کوه البرز (ارتفاعات تالش) و در امتداد دامنه شرقی سبلان قرار دارد. مساحت آن حدود ۹۹۰ کیلومتر مربع است. متوسط بارش سالانه در ایستگاه سینوپتیک اردبیل حدود ۳۰۴ میلی‌متر است. در این دشت اردیبهشت پر باران‌ترین ماه سال است. داده‌های کیفی آب زیرزمینی برای پارامترهای هدایت الکتریکی و مقدار کل جامدات محلول در ۳۸ حلقه چاه در دشت اردبیل در دو ماه از سال از سال ۱۳۷۴ تا ۱۳۹۱ از سازمان آب استان اردبیل اخذ شدند. پارامترهای مذکور معمولاً دو بار در سال اندازه‌گیری می‌شوند که یک بار آن در یکی از ماه‌های اردیبهشت یا خرداد است که تراز آب زیرزمینی به بالاترین سطح خود می‌رسد و

یک بار آن در یکی از ماه‌های شهریور یا مهر است که تراز آب زیرزمینی به پایین‌ترین سطح خود می‌رسد. داده‌های تراز آب زیرزمینی در مقیاس ماهانه برداشت شده و در این پژوهش ۲۶ ایستگاه پیزومتری مورد مطالعه قرار گرفت (شکل ۳). دو مورد از مهم‌ترین شاخص‌های کیفی آب زیرزمینی، پارامترهای هدایت و مقدار کل جامدات محلول است. پارامتر هدایت الکتریکی بیانگر مقدار نمک موجود در آب است که یون‌های موجود در آن توانایی هدایت الکتریکی را دارد. همچنین این پارامتر معیار مهمی در تعیین مناسب بودن آب برای مصارف شرب و کشاورزی است و نقش مهمی در کنترل سلامتی آب برای مصارف مختلف دارد. مقدار کل جامدات محلول یک اندازه‌گیری از مقدار مواد حل شده در آب و تازگی آب است. با توجه به گزارش‌های آب منطقه‌ای اردبیل، بیشترین مقدار کل جامدات محلول و هدایت الکتریکی در قسمت شمال و جنوب غربی دشت اردبیل مشاهده می‌شود. علت این مورد می‌تواند به دلیل حلالیت سازند مارنی در قسمت جنوب غربی دشت و وجود سنگ‌های آهکی، فاضلاب شهری و کارخانه سیمان در قسمت شمال دشت اردبیل باشد. افزایش مقدار این پارامتر در آب زیرزمینی بیانگر آلودگی آبخوان است. خلاصه‌ای از داده‌های کیفیت، تراز و داده‌های هیدرولوژیکی (بارش و رواناب) در جدول ۱ آورده شده است.



شکل ۳- نقشه مورد مطالعه و موقعیت ایستگاه‌های کیفی و تراز آب زیرزمینی دشت اردبیل

جدول ۱- اطلاعات آماری داده‌ها

پارامتر	واحد	مقدار بیشینه	مقدار کمینه	میانگین	انحراف معیار
بارش	mm	۱۵۶	۰	۱۷/۵۲	۲۲/۸۹
رواناب	m ³ /s	۳۰۷۶/۶	۰	۱۷۶/۹۴	۲۹۷/۷۲۴
تراز آب زیرزمینی	m	۱۴۵۸/۴۵	۱۲۹۹/۳۱	۱۳۳۹/۴۱۶	۳۹/۰۵
EC	μzimens / cm	۵۴۸۰	۱۴۸	۱۱۱۵/۷۶۳	۸۰۰/۶۶
TDS	mg/L	۲۸۳۶	۲۲/۶	۶۹۱/۹۱	-۵۴۱/۱۵۳

۳- نتایج و بحث

در گام اول این پژوهش، از آنجا که پارامترهای کیفی دو بار در سال اندازه‌گیری می‌شوند و با توجه به دوره زمانی مورد مطالعه که ۱۷ سال است، روش تخمین‌گر کوکریجینگ ۳۴ بار به پارامترهای کیفی اعمال می‌شود. کمترین مقدار RMSE و بالاترین مقدار ضریب تبیین (R²) در مرحله صحت‌سنجی^۱ معیار انتخاب مدل شد. در روش کوکریجینگ، در میان سه نوع تابع واریوگرام شامل کروی، گوسین و نمایی، تابع گوسین برای پارامتر هدایت الکتریکی، پارامتر کل جامدات محلول و پارامتر تراز آب زیرزمینی از دقت بالایی برخوردار بود. جدول ۲ کمترین مقادیر RMSE را برای پارامترهای هدایت الکتریکی و کل جامدات محلول در مدل گوسین نمایش می‌دهد. در این جدول اعداد ارائه شده میانگین ۳۴ بار استفاده از مدل‌های کوکریجینگ است.

شکل ۴ نمودار یک واریوگرام را برای مدل گوسین نشان می‌دهد که در آن پارامترهای sill(A), range(r), nugget(C₀) مشخص شده‌اند. مدل تنوری واریوگرام گوسین برازش شده توسط رابطه زیر با فواصل تأخیر h ارائه شده است [۳۴].

¹ Cross-Validation

$$\lambda(h) = C_0 + A \left(1 - e^{-\left(\frac{h}{r}\right)^2} \right) \quad \text{for } h > 0 \quad (13)$$

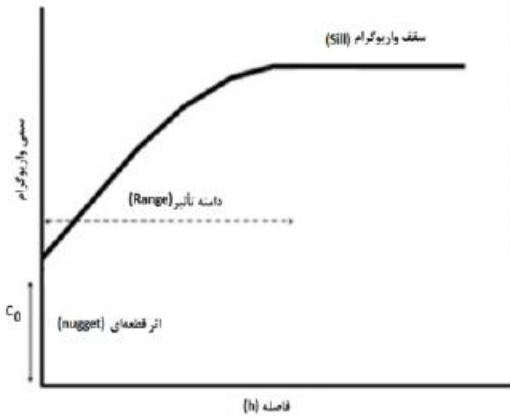
جدول ۲- انتخاب مدل مناسب برای واریوگرام تجربی بر اساس معیار RMSE

پارامترهای کیفی	جذر مربع خطاها		
	نمایی	گوسین	کروی
آب زیرزمینی	۱/۱۶E-۳	۱/۰۵E-۳	۱/۱۲E-۳
هدایت الکتریکی	۰/۹E-۳	۰/۴۲E-۳	۰/۷۵E-۳
کل جامدات محلول	۰/۹E-۳	۰/۴۲E-۳	۰/۷۵E-۳

جدول ۳ محدوده پارامترهای واریوگرام را که به پارامترهای هدایت الکتریکی و کل جامدات محلول اعمال شده است، نشان می‌دهد. محدوده نتایج صحت‌سنجی برای مدل‌های گوسین اعمالی به پارامترهای کیفی در جدول ۴ آورده شده است. شکل ۵ مثالی از واریوگرام و نمودار صحت‌سنجی را برای پارامتر TDS نشان می‌دهد. شکل ۶ نقشه‌های حاصل از کوکریجینگ را برای ماه کم‌آب سال ۱۳۸۴، برای هر دو پارامتر نمایش می‌دهد. نتایج بیانگر این است که در مناطق شمالی و جنوبی دشت، مقدار پارامترهای هدایت الکتریکی و کل جامدات محلول بیشتر از سایر قسمت‌های دشت است.

جدول ۳- محدوده پارامترهای واریوگرام روش کوکریجینگ برای پارامترهای هدایت الکتریکی و کل جامدات محلول


کراس واریوگرام				سمیواروگرام			
پارامترها	مدل	Nugget	Sill	Range (Km)	مدل	Nugget	Sill
EC	گوسین	۰/۱۵۴-۰/۲۱	۰/۱۷-۰/۴	۱۹۱۵-۲۴۶۰۰	گوسین	-	۰/۰۰۰۵-۰/۰۰۳
TDS	گوسین	۰/۰۵۵-۰/۱۹۳	۰/۳۵۷-۰/۴۷۷	۱۷۲۴۲/۹-۲۱۸۷۹/۴	گوسین	-	۰/۰۰۰۷-۰/۰۰۳
تراز آب زیرزمینی	گوسین	۰/۰۰۰۱-۰/۰۰۰۴	۰/۰۰۰۶-۰/۰۰۰۹	۱۸۳۳۳/۵-۲۳۱۵۱/۵	گوسین	-	۰/۰۰۰۵-۰/۰۰۳




شکل ۴- مدل واریوگرام گوسین

جدول ۴- محدوده نتایج صحت‌سنجی مدل‌های مختلف واریوگرام

پارامتر	R	RMSE
هدایت الکتریکی	۰/۵۸-۰/۷۵	۵۵۵/۹-۶۹۲/۴
کل جامدات محلول	۰/۵۹-۰/۷۳	۲۰۹/۸-۶۸۸



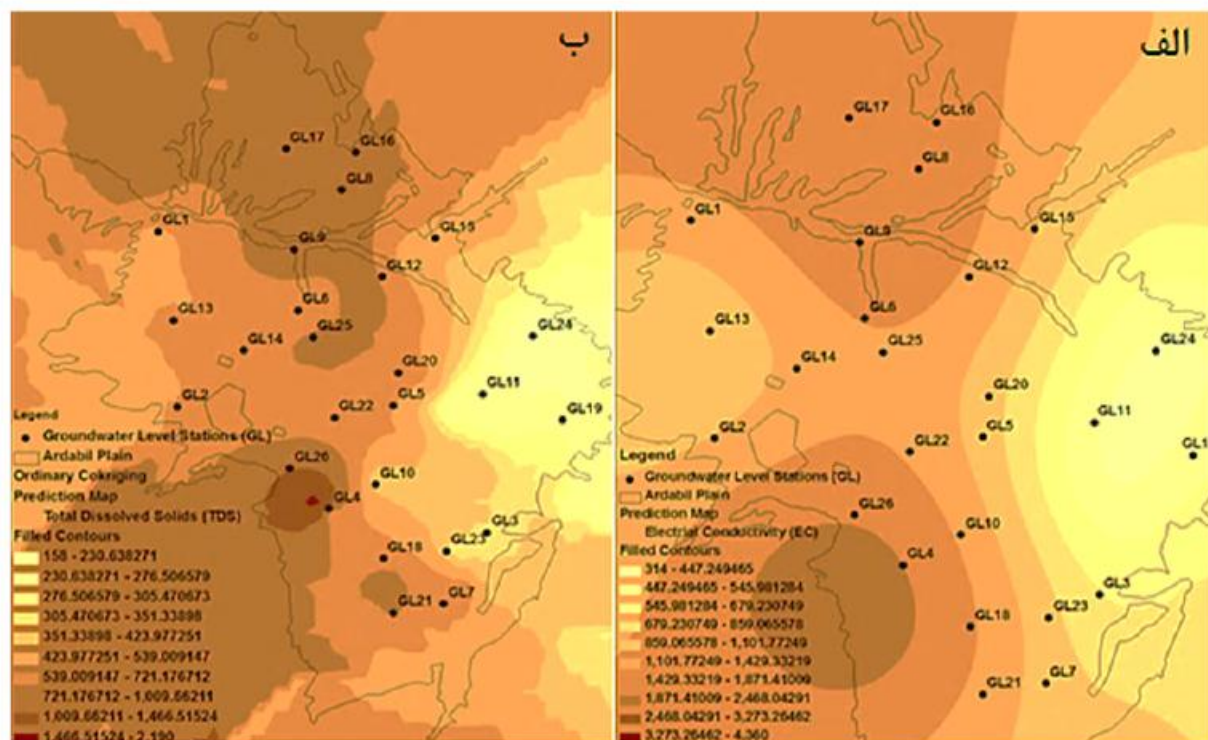
(الف)



شکل ۵- الف- نمونه‌ای از واریوگرام گوسین ب- نمونه‌ای از نتایج صحت‌سنجی برای پارامتر کل جامدات محلول

در گام دوم، بعد از تخمین مقدار پارامترهای کیفی در مکان پیزومترهای تراز آب زیرزمینی، برای دسته‌بندی داده‌ها از آنالیز خوشه‌بندی نقشه خودسازمانده استفاده شد. نکته مهم در آنالیز خوشه‌بندی، انتخاب تعداد دسته‌های خوشه‌بندی بود که در آن، چهار خوشه انتخاب شد. نتایج خوشه‌بندی در جدول‌های ۵ و ۶ آورده شده است. مطابق این جداول، خوشه‌بندی پارامترهای EC و TDS تا حدودی مشابه یکدیگراند. شکل ۷ نتایج خوشه‌بندی را برای دو متغیر EC و TDS نمایش می‌دهد. مطابق شکل‌های ۶ و ۷ و جدول‌های ۵ و ۶ و آنچه در مورد ژئولوژی حوضه مورد مطالعه گفته شد، مناطق شمالی و جنوبی دشت که دارای آلودگی‌های بیشتری نسبت به سایر مناطق می‌باشند، در دو کلاس مجزا قرار گرفته‌اند. قسمت‌های شرقی و مرکزی با کمترین آلودگی در گروه‌های مجزای دیگر قرار گرفته‌اند.

در گام سوم این پژوهش، با توجه به مرکزیت پیزومتر مرکزی در منطقه مطالعاتی، این پیزومتر برای ارزیابی کیفیت آب زیرزمینی و برای به‌دست آوردن تخمینی کلی از تغییرات کیفیت آب زیرزمینی در هر خوشه انتخاب شد. در این پژوهش، فاصله اقلیدسی مابین میانگین پیزومترهای واقع در یک خوشه و تک تک پیزومترهای واقع در خوشه مطابق رابطه ۸ محاسبه شد و در نتیجه معیار کمترین فاصله اقلیدسی برای انتخاب پیزومتر مرکزی استفاده شد [۳۰]. همچنین از داده‌های تراز آب زیرزمینی، داده‌های بارش و رواناب در زمان‌های قبل و پارامتر کیفی در سال قبل برای همان ماه در پیزومتر مرکزی برای مدل‌سازی زمانی پارامترهای کیفی هدایت الکتریکی و مقدار کل جامدات محلول پیزومتر مرکزی استفاده شد. همانطور که قبلاً نیز گفته شد، در دشت اردبیل داده‌های کیفی آب زیرزمینی در بازه‌های زمانی شش ماه (T) برای همه پیزومترها و داده‌های بارش (P)، رواناب (R) و تراز آب زیرزمینی (GL) در مقیاس ماهانه (t) اندازه‌گیری می‌شوند. همچنین برای تعیین میزان تأخیر زمانی پارامترهای ورودی با پارامترهای کیفی پیزومتر مرکزی از آنالیز حساسیت بهره گرفته شد. در این میان یکی از نکات مهم و اساسی در مورد مدل عصبی-فازی، تنظیم پارامترهای شبکه است. بنابراین برای یافتن ساختاری مناسب که انطباق بهتری با داده‌های سری زمانی پارامترهای کیفی داشته باشد، می‌توان از آنالیز حساسیت استفاده نمود. به این معنی که ساختارهای متفاوتی از تعداد ورودی‌ها و تعداد و شکل تابع عضویت باید مورد بررسی قرار گیرد. برای هر خوشه، مدل انفیسی برای هر یک از پارامترها آموزش داده شد و معیارهای ارزیابی مدل برای تعیین بهترین مدل استفاده شد. نتایج پیش‌بینی زمانی



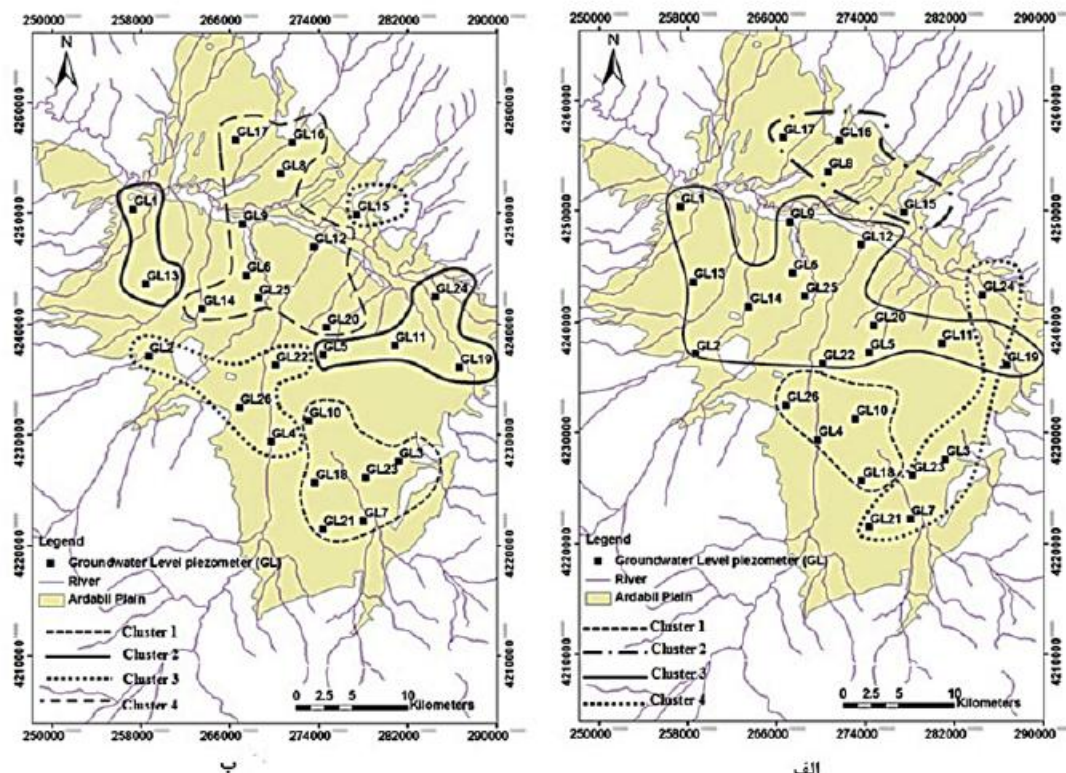
شکل ۶- پهنه‌بندی مکانی در ماه کم آب سال ۱۳۸۴ در دشت اردبیل، الف- مقدار کل جامدات محلول، ب- هدایت الکتریکی

جدول ۵- نتایج حاصل از خوشه‌بندی نقشه خود سازمان ده برای پارامتر هدایت الکتریکی

شماره کلاس	پیزومترها	ضریب سیلوئه	پیزومتر مرکزی
کلاس ۱	GL۳, GL۷, GL۲۱, GL۲۳, GL۲۴	۰/۶۷۸۳, ۰/۷۹۰۹, ۰/۵۲۶۵, ۰/۷۷۷۹, ۰/۵۰۳۳	GL۷
کلاس ۲	GL۸, GL۱۵, GL۱۶, GL۱۷	۰/۲۸۹۲, ۰/۲۰۵۴, ۰/۵۹۴۲, ۰/۰۹۸	GL۱۶
کلاس ۳	GL۴, GL۱۰, GL۱۸, GL۲۶	۰/۳۶۹۶, ۰/۲۱۹۱, ۰/۲۱۸۱, ۰/۱۶۷	GL۴
کلاس ۴	GL۱, GL۲, GL۵, GL۶, GL۹, GL۱۱, GL۱۲, GL۱۳, GL۱۴, GL۱۹, GL۲۰, GL۲۲, GL۲۵	۰/۲۱۳۹, ۰/۰۹۸۵, ۰/۴۶۵۸, ۰/۲۹۸۶, ۰/۳۵۶۹, ۰/۴۰۳۵, ۰/۳۹۴۳, ۰/۴۱۱۳, ۰/۲۸۵, ۰/۰۴۵۶, ۰/۴۳۰۲, ۰/۱۳۷۱, ۰/۳۱۹۳	GL۵

جدول ۶- نتایج حاصل از خوشه‌بندی نقشه خود سازمان ده برای پارامتر کل جامدات محلول

شماره کلاس	پیزومترها	ضریب سیلوئه	پیزومتر مرکزی
کلاس ۱	GL۳, GL۷, GL۱۰, GL۱۸, GL۲۱, GL۲۳	۰/۳۹۸, ۰/۶۲۲۶, ۰/۰۶۱۳, ۰/۲۹۶۹, ۰/۶۳۹۳, ۰/۵۸۲۷	GL۲۱
کلاس ۲	GL۱, GL۵, GL۱۱, GL۱۳, GL۱۹, GL۲۴	۰/۵۰۱۹, ۰/۳۵۴۷, ۰/۲۹۶۴, ۰/۱۸۰۴, ۰/۰۹۹۲, ۰/۵۱۰۷	GL۲۴
کلاس ۳	GL۲, GL۴, GL۱۵, GL۲۲, GL۲۶	-۰/۰۸۹۳, -۰/۰۱۳۶, ۰/۱۱۸۱, ۰/۲۳۷۲, ۰/۳۲۸۲	GL۲۶
کلاس ۴	GL۶, GL۸, GL۹, GL۱۲, GL۱۴, GL۱۶, GL۱۷, GL۲۰, GL۲۵	۰/۴۸۷۷, ۰/۳۵۶۰, ۰/۵۴۸۵, ۰/۳۸۹۲, ۰/۱۱۴۸, ۰/۲۷۶۳, ۰/۰۳۳۱, ۰/۰۴, ۰/۴۴۶۵	GL۹



شکل ۷- خوشه‌بندی مکانی SOM، الف) متغیر EC، ب) متغیر TDS

معیارهای ارزیابی مدل‌سازی برای هر دو مرحله آموزش و صحت‌سنجی، نتایج منطقی را در پیش‌بینی پارامترهای هدایت الکتریکی و کل جامدات محلول نشان داد. نتایج قابل قبول مدل انفیس برای هر دو پارامتر، شناسایی صحیح الگوی کیفی پیرومترهای نماینده هر خوشه را تأیید می‌نماید. در حالت کلی، مدل انفیس به خوبی توانسته تغییرات پارامترهای کیفی آب زیرزمینی را

پارامترهای کیفی هدایت الکتریکی و کل جامدات محلول به ترتیب در جدول‌های ۷ و ۸ آورده شده است. تعداد و شکل تابع عضویت با دو سه تابع عضویت مورد آزمایش قرار گرفتند که نتایج آن برای هر یک از خوشه‌ها به صورت ضریب تبیین و جذر میانگین مربع خطاها در مرحله صحت‌سنجی و واسنجی در جدول‌های ۷ و ۸ آورده شده است.

جدول ۷- نتایج و آماره‌های مدل‌سازی پارامتر EC با روش شبکه عصبی-فازی

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	تابع عضویت	R ²		RMSE ²	
				صحت سنجی	واسنجی	صحت سنجی	واسنجی
کلاس ۱	ECV(T-1) GLV(t) R(t-3)	ECV(T+1)	Gaussmf-3	۰/۹۷	۰/۹۱۹	۰/۰۵۲	۰/۰۴
کلاس ۲	GL۱۶(t) R(t-۲)	EC۱۶(T+1)	Timf-3	۰/۹۷۷	۰/۹۰۱	۰/۰۵۷	۰/۰۳۵
کلاس ۳	EC۴(T-1) GL۴(t)	EC۴(T+1)	Gaussmf-3	۰/۷۸	۰/۷۷۳	۰/۱۳۴	۰/۱۱۴
کلاس ۴	EC۵(T-1) R(t-۲)	EC۵(T+1)	Timf-3	۰/۷۸۷	۰/۷۳۱	۰/۱۳۵	۰/۱۲۵

* بر اساس داده‌های نرمال شده است.


جدول ۸- نتایج و آماره‌های مدل‌سازی پارامتر TDS با روش شبکه عصبی-فازی

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	تابع عضویت	R ²		RMSE ⁺	
				واسنجی	صحت سنجی	واسنجی	صحت سنجی
کلاس ۱	TDS ₂₁ (T-1) GL ₂₁ (t) R(t-3)	TDS ₂₁ (T+1)	Pimf-3	۰/۹۰۵	۰/۷۶۴	۰/۰۹۲	۰/۱۴
کلاس ۲	TDS ₂₄ (T-1) GL ₂₄ (t) R(t-2) P5(t)	TDS ₂₄ (T+1)	Pimf-3	۰/۹۶۵	۰/۹۱۵	۰/۰۱۳۴	۰/۰۹۲
کلاس ۳	TDS ₂₆ (T-1) GL ₂₆ (t)	TDS ₂₆ (T+1)	Pimf-3	۰/۷۸۹	۰/۶۹۱	۰/۱۲۳	۰/۱۵۹
کلاس ۴	TDS ₉ (T-1) P4(t-1)	TDS ₉ (T+1)	Gaussmf-3	۰/۸۶	۰/۷۹۹	۰/۱۱۶	۰/۱۴۱

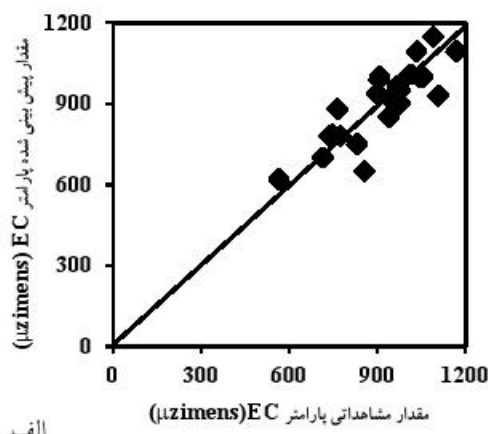
* بر اساس داده‌های نرمال شده است.

ارتباط بین ورودی‌ها در زمان‌های گذشته و کیفیت آب زیرزمینی دیده می‌شود. نمودار داده‌های محاسباتی و مشاهداتی برای مراحل واسنجی و صحت‌سنجی در پیزومتر ۵ خوشه ۳ برای متغیر هدایت الکتریکی و پیزومتر ۲۴ خوشه ۲ برای متغیر کل جامدات محلول در شکل‌های ۸ و ۹ نشان داده شده‌اند.

در دشت اردبیل نمایش دهد. بنابراین می‌توان نتیجه گرفت که کاربرد روش عصبی-فازی به همراه آنالیز خوشه‌بندی می‌تواند به‌عنوان یک ابزار مناسب برای پیش‌بینی پارامترهای کیفی آب زیرزمینی به‌کار گرفته شود. در مورد خوشه‌هایی که در آن‌ها پیش‌بینی با دقت بالایی صورت گرفته می‌توان پی برد که بیشترین

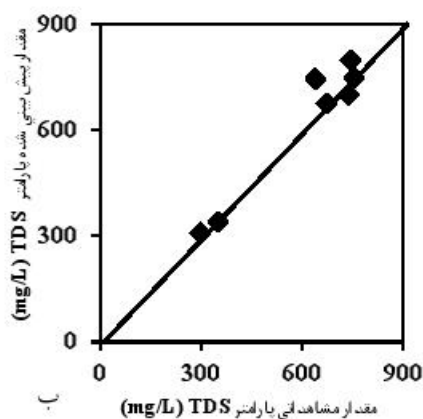


ب

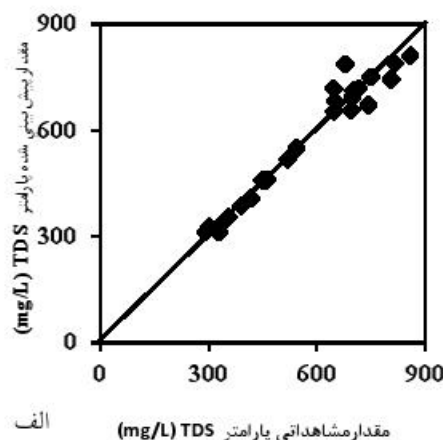


الف

شکل ۸- نمودار سری زمانی داده‌های محاسباتی و مشاهداتی برای الف) مرحله واسنجی و ب) مرحله صحت‌سنجی در پیزومتر ۵ برای پارامتر EC



ب



الف

شکل ۹- نمودار سری زمانی داده‌های محاسباتی و مشاهداتی برای الف) مرحله واسنجی و ب) صحت‌سنجی در پیزومتر ۲۴ برای پارامتر TDS

۴- نتیجه‌گیری

ترتیب یک شبکه آموزش‌دیده برای آن حوضه داشت. بهره‌گیری از دیگر روش‌های دانش هوش مصنوعی و یا مدل‌سازی پارامترهای کیفی دیگر آب زیرزمینی در کنار پارامترهای هدایت الکتریکی و کل جامدات محلول می‌تواند اعتبار و عدم اعتبار این نوع مدل‌سازی را بهتر نمایان سازد. همچنین، به دلیل فقدان داده‌های ماهانه پارامترهای هدایت الکتریکی و کل جامدات محلول برای دشت اردبیل و انجام مدل‌سازی با استفاده از داده‌های شش ماهه آن‌ها، کاربرد روش پیشنهادی این پژوهش برای آبخوان‌های دیگر با مدت زمان داده‌های بیشتر و در مقیاس ماهانه می‌تواند یک رهیافت مناسب در زمینه مدل‌سازی پارامترهای کیفی آب زیرزمینی باشد.

ترکیب مدل شبکه عصبی- فازی با آنالیز خوشه‌بندی یک ایده نو برای به‌وجود آمدن شبکه‌ای توانمندتر است. نتایج حاصل از این مدل‌سازی نشان می‌دهد که بهره‌گیری از داده‌های هیدرولوژیکی پیرومترهای مرکزی خوشه‌های مختلف و مدل‌سازی کیفی آن توسط شبکه عصبی- فازی توانسته تا حدودی الگوی سری زمانی داده‌های کیفی در دشت اردبیل را تشخیص دهد و به نتایج نسبتاً مطلوبی منجر شود. همچنین خوشه‌بندی داده‌ها سبب بهبود هر چه بهتر فرایند مدل‌سازی و در نتیجه افزایش کارایی مدل شد. با توجه به این که مدل شبکه عصبی- فازی بر نگرش هوش مصنوعی بر پایه روش داده‌کاوی استوار است، این مدل را می‌توان برای هر دشت در داخل ایران مورد آموزش قرار داد و به این

۵- مراجع

1. Nourani, V., Monadjemi, P., and Singh, V. P. (2007). "Liquid analog model for laboratory simulation of rainfall-runoff process." *J. Hydrol. Eng.*, 12(3), 246-255.
2. Hsu, K., Gupta, H. V., and Sorooshian, S. (1995). "Artificial neural network modeling of the rainfall-runoff process." *J. Hydrol.*, 31(10), 2517-2330.
3. Ma, T.S., Sophocleous, M., and Yu, Y.S. (1999). "Geostatistical applications in groundwater modeling in South-central Kansas." *J. Hydrol. Eng.*, 4(1), 57-64.
4. Mouser, D., and Rizzo, P. (2000). "Evaluation of geostatistics for combined hydrochemistry and microbial community fingerprinting at a waste disposal site." *Critical Trasntions in Water and Environmental Resourcess Management*, doi: 10.1061/40737 (2004) 106.
5. Gaus, I., Kinniburgh, D.G., Talbot, J.C., and Webster, R. (2003). "Geostatistical analysis of arsenic concentration in groundwater in Bangladesh using disjunctive kriging." *Environ. Geo.*, 44, 939-948.
6. Barca, E., and Passarella, G. (2008). "Spatial evaluation of the risk of groundwater quality degradation. A comparison between disjunctive kriging and geostatistical simulation." *Environ. Monit. and Assess*, 137, 261-273.
7. Taghizadeh Mehrjardi, R., Zareian Jahromi, M., Mahmodi, S., and Heidari, A. (2008). "Spatial distribution of groundwater quality with geostatistics (case study: Yazd-Ardakan plain)." *World Appl. Sci. J.*, 4(1), 9-17.
8. Samin, M., Soltani, J., Zeraatcar, Z., Moasheri, A., and Sarani, N. (2012). "Spatial estimation of groundwater quality parameters based on water salinity data using Kriging and Cokriging Methods." *International Conference on Transport, Environment and Civil Engineering (ICTECE'2012)*, Kuala Lumpur, Malaysia.
9. Ahmadian, S. (2013). "Geostatistical based modelling of variations of groundwater quality during 2006 to 2009 (in Tehran-Karaj Plain)." *J. Basic Appl. Sci. Res.*, 3(2), 264-272.
10. Taheri Tizro, A, Voudouris, K., and Vahedi, S. (2014). "Spatial variation of groundwater quality parameters: A case study from a semiarid region of Iran." *Int. B. Water Resour. Develop.*, 1(3), 1-11.
11. Mousavifazl, H., Alizadh, A., and Ghahraman, B. (2013). "Application of geostatistical methods for determining nitrate concentrations in groundwater (case study of Mashhad plain, Iran)." *Int. J. Agri. Crop Sci.*, 5(4), 318-328.
12. Delbari, M., Bahraini Motlagh, M., Kiani, M., and Amiri, M. (2013). "Investigating spatio-temporal variability of groundwater quality parameters using geostatistics and GIS." *Intl. Res. J. Appl. Basic. Sci.*, 4(10), 3623-3632.

13. Taghizadeh-Mehrjardi, R. (2014). "Mapping the spatial variability of groundwater quality in Urmia, Iran." *J. Mater. Environ. Sci.*, 5(2), 530-539.
14. Peeters, L., and Dassargues, A. (2006). "Classification of groundwater samples in wetlands using self-organizing maps." *International Association for Mathematical Geology 6th International Congress*, Belgium, 3-8.
15. Snchez-Martos, F., Aguilera, P.A., Garrido-Frenich, A., Torres, J., and Pulido-Bosch, A. (2002). "Assessment of groundwater quality by means of self-organizing maps: Application in a semiarid area." *Environ. Manage.*, 30(5), 716-726.
16. Hong, Y-S., and Rosen, M.R. (2001). "Intelligent characterization and diagnosis of groundwater quality in an urban fractured-rock aquifer using an artificial neural network." *Urban Water*, 3, 193-204.
17. Peeters, L., Bacao, F., Lobo, V., and Dassargues, A. (2007). "Exploratory data analysis and clustering of multivariate spatial hydrogeological data by means of GEO3DSOM, a variant of Kohonen's self-organizing map." *Hydrol. Earth Sys. Sci.*, 11, 1309-1321.
18. Choi, B.Y., Yun, S.T., Kim, K.H., Kim, J.W., Kim, H.M., and Koh, Y.K. (2014). "Hydrogeochemical interpretation of South Korean groundwater monitoring data using self-organizing maps." *J. Geochem. Explor.*, 137, 73-84.
19. Nguyen, T.T., Kawamura, A., Tong, T.N., Nakagawa, N., Amaguchi, H., and Gilbuena, R. (2015). "Clustering spatio-seasonal hydrogeochemical data using self-organizing maps for groundwater quality assessment in the Red River Delta, Vietnam." *J. Hydro.*, 522, 661-673.
20. Maier, H.R., and Dandy, G.C. (1996). "The use of artificial neural networks for the prediction of water quality parameters." *Water Resour. Res.*, 32 (4), 1013-1022.
21. Lin, G.F., and Chen, G.R. (2005a). "Determination of aquifer parameters using radial basis function network approach." *J. Chinese Inst. Engineers*, 28 (2), 241-249.
22. Lin, G.F., and Chen, L.H. (2005b). "Time series forecasting by combining the radial basis function network and the self-organizing map." *Hydrol. Process*, 19 (10), 1925-1937.
23. Lin, G.F., and Chen, G.R. (2006). "An improved neural network approach to the determination of aquifer parameters." *J. Hydrol.*, 316 (1-4), 281-289.
24. Banerjee, P., Singh, V.S., Chattopadhyay, K., Chandra, P.C., and Singh, B. (2011). "Artificial neural network model as a potential alternative for groundwater salinity forecasting." *J. Hydrol.*, 398, 212-220.
25. Orzepowski, W., Paruch, A.M., Pulikowski, K., Kowalczyk, T., and Pokladek, R. (2014). "Quantitative and qualitative assessment of agricultural water resources under variable climatic conditions of Silesian Lowlands (Southwest Poland)." *Agric. Water Manage.*, 138, 45-54.
26. Mousavi, F., and Amiri, M. J. (2012). "Modelling nitrate concentration of groundwater using adaptive neural-based fuzzy inference system." *Soil Water Resour.*, 7(2), 73-83.
27. Kisi, O., and Ay, M. (2012). "Modelling COD concentration by using three different ANFIS techniques." *Sixteenth International Water Technology Conference*, Istanbul, Turkey, IWTC-16.
28. Tutmez, B., Hatipoglu, Z., and Kaymak, U. (2006). "Modelling electrical conductivity of groundwater using an adaptive neuro-fuzzy inference system." *Comput. Geosci.*, 32, 421-433.
29. Aqil, M., Kita, I., Yano, A., and Nishiyama, S. (2007). "Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool." *J. Environ. Manage.*, 85, 215-223.
30. Jang, J.S.R., Sun, C.T., and Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*, 3rd Ed., Prentice Hall, New Jersey.
31. Mohammadi, J. (2000). *Pedonmeter*, Pelk Pub., Tehran. (In Persian)
32. Kohonen, T. (1998). "The self-organizing map." *Neurocomputing*, 21, 1-6.
33. Hsu, K., and Li, S. (2010). "Clustering spatial-temporal precipitation data using wavelet transform and self-organizing map neural network." *Adv. Water Resour.*, 33, 190-200.
34. Myers, D.E. (1982). "Matrix formulation of cokriging." *Math. Geol.*, 14, 249-257.