

هیدروژنومورفولوژی، شماره‌ی ۱۷، زمستان ۱۳۹۷، صص ۶۴-۴۵

وصول مقاله: ۱۳۹۶/۰۸/۰۴ تأیید نهایی مقاله: ۱۳۹۷/۰۲/۱۶

## استفاده از مدل‌های ترکیبی ماشین بردار پشتیبان - موجکی و شبکه‌عصبی - موجکی در پیش‌بینی تراز آب زیرزمینی دشت اردبیل

فرناز دانشور وثوقی<sup>\*۱</sup>

وحید منافیان آذر<sup>۲</sup>

### چکیده

آب‌های زیرزمینی همواره به عنوان یکی از منابع مهم و عمده‌ی تأمین آب شرب و کشاورزی به ویژه در مناطق خشک و نیمه‌خشک مطرح بوده‌اند. به منظور آگاهی از وضعیت این منابع و مدیریت بهینه‌ی آنها، لازم است پیش‌بینی دقیقی از نوسانات سطح آب زیرزمینی صورت گیرد. در این تحقیق اطلاعات ۱۵ پیزومتر موجود در دشت اردبیل مورد استفاده قرار گرفت. از تبدیل موجک و روش خوشه‌بندی به ترتیب برای پیش‌پردازش زمانی و مکانی استفاده گردید. روش مدل‌سازی مورد استفاده در این تحقیق، ماشین بردار پشتیبان و شبکه‌عصبی مصنوعی برای پیش‌بینی یک ماه آینده می‌باشد. در ابتدا پیزومترهای موجود با روش خوشه‌بندی نقشه خود سازمانده کلاس‌بندی شده و برای پیزومترهای مرکزی هر کلاس دو مدل فوق به صورت تکی و در ترکیب با تبدیل موجک به کار رفت. نتایج حاصله ضریب تبیین متوسط ۰/۹۴ برای آموزش و ۰/۸۹ برای صحت‌سنجی را در مرحله‌ی مدل‌سازی با ماشین بردار پشتیبان نشان داد. استفاده از تبدیل موجک باعث افزایش ۳/۵ درصدی دقت مدل گردید. در ضمن مدل‌سازی از طریق شبکه عصبی مصنوعی نیز با ضریب تبیین متوسط ۰/۹۴ برای آموزش و ۰/۸۸ برای صحت‌سنجی از دقت بالایی برخوردار بوده و استفاده از تبدیل موجک باعث افزایش ۵ درصدی دقت مدل شد.

**کلمات کلیدی:** SVM، تبدیل موجک، SOM، تراز آب زیرزمینی، دشت اردبیل.

۱- گروه مهندسی عمران، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران (نویسنده‌ی مسئول).

E-mail: fdaneshvar.vousoughi@gmail.com

۲- کارشناسی ارشد مهندسی عمران-مهندسی و مدیریت منابع آب دانشگاه آزاد اهر.

## مقدمه

در دهه‌های اخیر، شبکه‌های عصبی مصنوعی به عنوان شاخه‌ای از روش هوش مصنوعی توانایی خود را در ارائه‌ی نتایج دقیق مدل‌سازی فرآیندهای هیدرولوژیکی نشان داده است. ANN یک روش موثر برای اداره‌ی مقادیر زیادی از داده‌های پویا، غیرخطی و پر از خطا، به ویژه هنگامی که روابط اساسی فیزیکی آنها به طور کامل شناخته نشده است ارائه می‌دهد. مقالات موفق متعددی از کاربرد شبکه‌عصبی مصنوعی (ANN) در مدل‌سازی فرآیندهای هیدرولوژیکی ارایه شده است. پژوهشگرانی نظیر ASCE Task committee (۲۰۰۰: ۱۳۰)، لالاها و همکاران<sup>۱</sup> (۲۰۰۵: ۱۰۰)، دالیاکوپولوس و همکاران<sup>۲</sup> (۲۰۰۵: ۲۳۵)، نایاک و همکاران<sup>۳</sup> (۲۰۰۹: ۸۴)، چن و همکاران<sup>۴</sup> (۲۰۱۱: ۳۵۸)، تائورمینال و همکاران<sup>۵</sup> (۲۰۱۲: ۱۶۷۳)، ملکی‌نژاد و پورشریعتی (۱۳۹۲: ۸۸) رجایی و ابراهیمی (۱۳۹۳: ۱۰۶) با مطالعه‌ی خود به بررسی امکان استفاده از ANN در تخمین سطح آب زیرزمینی، پرداخته و به نتایجی قابل قبول رسیدند. شبیه‌سازی خوب و منطقی با روش ANN نشان داد که این روش شایستگی بسیار خوبی برای این کار دارد.

ماشین‌های بردار پشتیبان، سیستم‌های یادگیری خاصی هستند که از یک فضای فرضیه به نام فضای مشخصه، شامل توابع خطی با بعد زیاد استفاده کرده و می‌توانند برای پیش‌بینی مورد استفاده قرار گیرند. مدل SVM از اصل مینیمم کردن ریسک عملیاتی به جای مینیمم کردن خطای مدل‌سازی تبعیت می‌کند و شامل حل مسأله برنامه‌ریزی درجه دو است. کاربرد این روش به طور کلی در چند سال اخیر در زمینه‌های مختلف هیدرولوژیکی دارای پاسخ مناسبی بوده است که در ادامه به تعدادی از تحقیقات

1- Lallahema et al.,  
 2- Daliakopoulos et al.,  
 3- Nayak et al.,  
 4- Chen et al.,  
 5- Taorminal et al.,

انجام یافته در این زمینه اشاره می‌شود: محققانی نظیر بهزاد و همکاران<sup>۱</sup> (۲۰۱۰: ۴۱۰)، یون و همکاران<sup>۲</sup> (۲۰۱۱: ۱۴۹)، ژائو و همکاران<sup>۳</sup> (۲۰۱۲: ۱۰۷۵)، شیرری و همکاران<sup>۴</sup> (۲۰۱۳: ۳۸)، ابراهیمی و رجایی<sup>۵</sup> (۲۰۱۷: ۱۸۵) و در ایران نیز، بازرگان لاری و همکاران (۱۳۸۹: ۶۰)، کلتی و غلامی (۱۳۹۱: ۳۷)، نعمت‌الهی و همکاران (۱۳۹۲: ۶۷)، رضانی و ذونعمت کرمانی (۱۳۹۴: ۱۰۰) نتایج حاصل نشان‌دهنده‌ی کارایی بهتر ماشین‌های بردار پشتیبان در پیش‌بینی سطح آب زیرزمینی بوده است.

با وجود انعطاف‌پذیری مدل‌های هوش مصنوعی در پیش‌بینی سری‌های زمانی هیدروژئولوژیکی، گاهی این شبکه‌ها در پیش‌بینی سری‌های زمانی به شدت ناپایدار و ناپایدار با مشکل مواجه می‌شوند. آنالیز موجک امکان استفاده از داده با بازه‌ی زمانی طولانی‌مدت را هنگامی که هدف اطلاعات با فرکانس پایین و دقیق است و بازه‌ی کوچک را وقتی اطلاعات فرکانس بالا نیاز است می‌دهد (نورانی و همکاران، ۲۰۰۹: ۴۶۶-۴۷۲). در سال‌های اخیر، ترکیب تبدیل موجک و شبکه‌عصبی مصنوعی با توجه به توانایی‌اش در زمینه پیش‌بینی و شبیه‌سازی، در علوم مختلف محیطی به وسیله‌ی محققان و تصمیم‌گیرندگان مورد استفاده قرار گرفته است. با توجه به بررسی‌های انجام شده، وانگ و دینگ<sup>۶</sup> (۲۰۰۳: ۶۹) و آداموفسکی و چان<sup>۷</sup> (۲۰۱۱: ۳۵) از نخستین افرادی بودند که از این روش برای پیش‌بینی نوسانات سطح آب زیرزمینی استفاده کردند و ساتیا جیرو و کریشنا<sup>۸</sup> (۲۰۰۹: ۱۰۵)، وانگ و ژائو<sup>۹</sup> (۲۰۱۱: ۱۶۳)، ماهسواران و خوسا<sup>۱۰</sup>

1- Behzad et al.,

2- Yoon et al.,

3- Zhao et al.,

4- Shiri et al.,

5- Ebrahimi and Rajaei

6- Wang and Ding

7- Adamowski and Chan

8- Satyajirao and Krishna

9- Zhao and Gao

10- Maheswaran and Khosa

(۲۰۱۳: ۴۲۷)، موسوی و همکاران (۲۰۱۴: ۱۷۹۰)، سوریانا و همکاران<sup>۱</sup> (۲۰۱۴: ۳۲۷)، نخعی و صابر نصر (۱۳۹۱: ۵۰) و رجایی و زینی‌وند (۱۳۹۳: ۵۵) به بررسی و مقایسه‌ی مدل شبکه عصبی و شبکه عصبی - موجکی در پیش‌بینی نوسانات سطح آب زیرزمینی پرداخته‌اند. نتایج آن‌ها نشان داد که مدل ترکیبی WANN<sup>۲</sup> نسبت به مدل ANN از دقت بهتری برخوردار است. با توجه به تأثیرات مثبتی که استفاده از تبدیل موجک در پیش‌پردازش زمانی مدل‌های هوش مصنوعی در پی داشته است، استفاده از مدل ترکیبی ماشین بردار پشتیبان - موجکی برای پارامترهای هیدرولوژیکی مورد توجه محققان قرار گرفته است. محققانی نظیر سوریانا و همکاران<sup>۳</sup> (۲۰۱۴: ۳۲۷)، یون و همکاران<sup>۴</sup> (۲۰۱۶: ۱۴۸) و ابراهیمی و رجایی<sup>۵</sup> (۲۰۱۷: ۱۸۵) از مدل ترکیبی ماشین بردار پشتیبان - موجکی استفاده کرده‌اند. اما در خصوص استفاده از این روش برای پیش‌بینی تراز آب زیرزمینی دشت اردبیل مطالعه‌ای انجام نشده است که در این تحقیق بدان پرداخته خواهد شد.

تبدیل موجک هرچند قابلیت پیش‌پردازش زمانی را دارا می‌باشد، اما زمانی که در منطقه‌ی مورد مطالعه ایستگاه‌های مختلفی موجود باشد، لازم است از لحاظ مکانی نیز پیش‌پردازش روی داده‌ها صورت گیرد. در این راستا روش خوشه‌بندی نقشه‌های خود سازمانده ابزار برای پیش‌پردازش مکانی می‌باشد که باعث کاهش حجم داده‌های ورودی و افزایش دقت مدل و همچنین دسته‌بندی داده‌ها، ایستگاه‌ها و نواحی به گروه‌های همگن و بهینه‌سازی ساختار مدل با انتخاب داده‌های مؤثر و کارآمد می‌شود (نورانی و همکاران، ۲۰۱۵: ۲۶۰). مقالات موفق متعددی از کاربرد SOM در مورد تراز آب زیرزمینی توسط پژوهشگرانی نظیر چن و لین<sup>۶</sup> (۲۰۰۶: ۷۱)، چن و همکاران (۲۰۱۰:

1- Suryanarayana

2- Wavelet-ANN

3- Suryanarayana et al.,

4- Yoon et al.,

5- Ebrahimi and Rajaei

6- Chen et al.,

۶۲۷)، چن و همکاران<sup>۱</sup> (۲۰۱۱: ۳۵۷)، هان و همکاران<sup>۲</sup> (۲۰۱۶: ۳۱۱) چانگ و همکاران<sup>۳</sup> (۲۰۱۶: ۹۷۰) نورانی و همکاران (۲۰۱۲: ۲۲۵۳)، نورانی و همکاران (۲۰۱۵: ۲۶۰) صورت گرفته است.

هدف از این تحقیق پیش‌بینی سطح آب زیرزمینی دشت اردبیل با استفاده از روش‌های هوش مصنوعی ماشین بردار پشتیبان و شبکه‌عصبی می‌باشد. شبکه‌عصبی تخمین‌گر مورد استفاده برای مدل‌سازی از نوع شبکه‌عصبی پیشرو FFNN می‌باشد. برای پیش‌پردازش داده‌ها، روش خوشه‌بندی SOM برای کاهش حجم داده‌های ورودی همچنین برای دسته‌بندی داده‌ها، ایستگاه‌ها و نواحی به گروه‌های همگن و بهینه‌سازی ساختار مدل با انتخاب داده‌های مؤثر و کارآمد به عبارت بهتر پیش‌پردازش مکانی استفاده شد و تبدیل موجک به علت نیاز سری‌های زمانی تراز آب زیرزمینی به پیش‌پردازش زمانی و غلبه بر پدیده‌ی فصلی بودن سری زمانی و برای بهبود در نتایج استفاده گردید.

## مواد و روش‌ها

### - منطقه‌ی مورد پژوهش

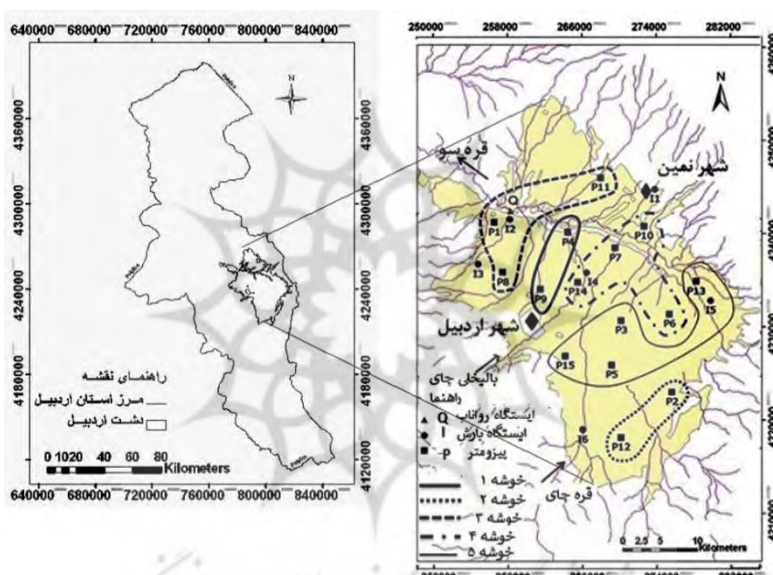
منطقه‌ی مورد مطالعه، دشت اردبیل است که در شمال غربی ایران واقع شده است. این دشت به طور تقریبی، در عرض جغرافیایی ۳۸ درجه و ۳ دقیقه تا ۳۸ درجه و ۲۷ دقیقه‌ی شمالی و طول جغرافیایی ۴۷ درجه و ۵۵ دقیقه تا ۴۸ درجه و ۲۰ دقیقه‌ی شرقی واقع شده است. دشت اردبیل مشرف بر ارتفاعات بخش غربی رشته کوه البرز (ارتفاعات تالش) و در امتداد دامنه‌ی شرقی سبلان قرار دارد. مساحت آن در حدود ۹۹۰ کیلومتر مربع می‌باشد. شکل (۱) موقعیت جغرافیایی دشت اردبیل و موقعیت ایستگاه‌های پیژومتریک، باران‌سنجی و ایستگاه رواناب را نشان می‌دهد. در این پژوهش

1- Chen et al.,

2- Han et al.,

3- Chang et al.,

۱۵ ایستگاه پیزومتري (P) مورد مطالعه قرار گرفته است. طول داده‌های استفاده شده از خرداد سال ۱۳۶۷ تا اسفند ۱۳۹۱ می‌باشد که از سازمان آب منطقه‌ای استان اردبیل تهیه گردیده‌اند. همچنین این حوضه دارای یک ایستگاه رواناب در خروجی حوضه (R) و شش ایستگاه بارش (I) می‌باشد.



شکل (۱) موقعیت جغرافیایی دشت اردبیل و پیزومترهای مورد مطالعه

در این تحقیق برای پیش‌بینی سطح تراز آب زیرزمینی دشت اردبیل، داده‌های بارش و رواناب به همراه داده‌های تراز آب زیرزمینی در زمان (t) و یک ماه قبل (t-1) به عنوان ورودی استفاده شده و سطح تراز آب زیرزمینی ماه آینده به عنوان خروجی مدل در نظر گرفته شده است.

با توجه به اینکه استفاده از اطلاعات ۱۵ ایستگاه پیزومتريک موجود در سطح حوضه دشت اردبیل در قسمت مدل‌سازی می‌تواند باعث بروز خطاهای محاسباتی زیادی گردد.

بدین منظور پیش‌پردازش مکانی با روش SOM انجام شد. در مرحله‌ی اول خوشه‌بندی، مقادیر ۱۵ پیژومتر منتخب به شبکه‌ی خوشه‌بندی SOM دو بعدی برای طبقه‌بندی پیژومترها به خوشه‌هایی با الگوی مشابه، استفاده شد. به منظور اعمال SOM دو بعدی، لایه‌ی Kohonen در مرحله‌ی اول برای اندازه‌های مختلف ( $3 \times 3$  m،  $4 \times 4$ ،  $5 \times 5$ ، الی  $9 \times 9$ ) آزمایش شد. بعد از آزمون و خطا لایه‌های مختلف Kohonen. لایه  $5 \times 5$  به عنوان SOM دو بعدی مناسب انتخاب گردید. در مرحله‌ی بعدی، به منظور اطمینان از تعداد خوشه‌های انتخاب شده در مرحله‌ی اول، SOM یک بعدی برای طبقه‌بندی پیژومترها به تعداد کلاس‌های تعیین شده در مرحله‌ی اول ( $1 \times 5$ ) استفاده شد. در این مرحله، تعداد نرون‌های لایه‌ی Kohonen مساوی تعداد کلاس‌های تعیین شده در مرحله‌ی اول تعیین شد. ضریب سیلوهه برای ارزیابی عملکرد خوشه‌بندی با SOM استفاده گردید. از فاصله اقلیدسی برای انتخاب پیژومتر مرکزی به عنوان بهترین نماینده الگوی آب زیرزمینی هر خوشه استفاده شد.

بعد از انجام خوشه‌بندی پیژومترهای تراز آب زیرزمینی دشت اردبیل به پنج خوشه، با استفاده از مدل ماشین بردار پشتیبان و شبکه‌عصبی پیش‌بینی تراز آب زیرزمینی پیژومترهای مرکزی برای یک ماه آینده انجام گرفت. برای این کار اطلاعات تراز آب زیرزمینی پیژومترهای مرکزی هر خوشه در ماه  $t$  ( $P(t)$ ) و یک ماه قبل ( $P(t-1)$ ) و نیز اطلاعات بارش ( $I$ ) و رواناب ( $R$ ) به عنوان داده‌های ورودی در نظر گرفته شد. با توجه به الگوی مشابه نوسانات تراز آب زیرزمینی پیژومترهای واقع در یک خوشه، پیش‌بینی تراز آب زیرزمینی پیژومترهای مرکزی می‌تواند رفتار پیژومترهای دیگر واقع در خوشه‌ها را در آینده تعیین نماید. در خصوص استفاده از پارامترهای بارش و رواناب با گام تاخیر مناسب، نکته‌ی حایز اهمیت انتخاب پارامترهایی است که بیشترین همبستگی خطی و

ارتباط را با پارامتر تراز آب زیرزمینی داشته باشد. این عمل به وسیله همبستگی خطی<sup>۱</sup> اشاره شده در فرمول ۱ صورت گرفت:

$$\text{Correl}(X, Y) = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}} \quad (۱) \text{ رابطه‌ی}$$

در رابطه‌ی (۱)،  $x$  و  $y$  همان دو سری داده‌های مورد بررسی برای همبستگی  $\bar{x}$  و  $\bar{y}$  هم میانگین سری‌های زمانی  $X$  و  $Y$  هستند. با استفاده از این فرمول هر چقدر عدد به دست آمده نزدیک ۱ باشد ارتباط بیشتر و هر چقدر به عدد -۱ نزدیک تر باشد ارتباط معکوسی را نشان می‌دهد (پارتال و سیگیزاوغلو<sup>۲</sup>، ۲۰۰۸: ۳۲۳). برای مدل‌سازی حدود ۷۵ درصد داده‌ها برای آموزش و حدود ۲۵ درصد داده‌ها برای صحت‌سنجی انتخاب گردیدند. جهت مدل‌سازی شبکه‌ی SVM و ANN از محیط نرم‌افزار متلب استفاده گردید.

پس از انجام مدل‌سازی از طریق روش ماشین بردار پشتیبان و روش شبکه‌عصبی مصنوعی و بررسی نتایج حاصله و مقایسه این دو روش با یکدیگر، این بار جهت افزایش بهره‌وری و دقت مدل‌سازی‌های انجام شده از روش پیش پردازش موجک بر روی داده‌ها استفاده شد. با توجه به ساختار موجک مادر Daubechies-4 (db4) و شباهت سیگنال تراز آب زیرزمینی به آن، بنابراین موجک مادر db4 می‌تواند ویژگی‌های سیگنال را در بر گیرد و به عنوان موجک مادر تجزیه‌کننده در این پژوهش انتخاب گردید (نورانی و همکاران، ۲۰۱۵: ۲۶۰).

تجزیه‌ی سری زمانی تراز آب زیرزمینی در درجه‌ی  $L$ ، منجر به  $L+1$  زیرسری (یک زیرسری تقریبی  $P_a(t)$  و  $L$  زیرسری جزئی  $Pd_i(t)$  ( $i=1, 2, \dots, L$ ) می‌شود. درجه‌ی تجزیه ۳ به عنوان درجه تجزیه بهینه مطابق رابطه‌ی (۲) در نظر گرفته شد (نورانی و همکاران، ۲۰۰۹: ۴۶۹).

1- Linear Correlation  
2- Partal and Cigizoglu



رابطه‌ی (۲)  $L = \log N$


که در آن  $L$  و  $N$  به ترتیب درجه‌ی تجزیه و طول سری زمانی می‌باشد. در این مطالعه با داشتن  $N=298$ ،  $L=2/5$  به دست می‌آید که درجه‌ی تجزیه ۳ در نظر گرفته شد. در این مرحله پس از انجام پیش پردازش داده‌ها توسط موجک، مدل‌سازی توسط SVM و ANN صورت گرفت.

#### - ماشین بردار پشتیبان

شبکه‌های SVM برخلاف سایر انواع شبکه‌های عصبی بجای اینکه خطای مدل‌سازی یا طبقه‌بندی را کمینه کنند، ریسک عملیاتی را به عنوان تابع هدف در نظر گرفته و مقدار بهینه آن را محاسبه می‌کنند. شبکه‌ی SVM در طبقه‌بندی یک مجموعه داده به دو گروه، ریسک عدم طبقه‌بندی صحیح را به صورت سری کمیت‌های عددی بیان کرده، سپس مقدار کمینه‌ی آن را محاسبه می‌کند؛ اما شبکه‌ی عصبی راه‌حل مسأله را بر مبنای کمینه کردن مقدار خطای تفکیک ارائه می‌کند.

#### - شبکه‌ی عصبی پیشرو (FFNN)

شبکه‌ی عصبی تخمین‌گر مورد استفاده برای مدل‌سازی در تحقیق از نوع شبکه‌ی عصبی پیشرو می‌باشد. شکل (۲) شکل کلی شبکه‌ی عصبی مصنوعی را نشان می‌دهد. در حالت کلی این شبکه از سه لایه تشکیل می‌شود. لایه‌ی اول شامل همه متغیرهای ورودی، لایه‌ی آخر شامل متغیرهای خروجی و لایه‌ی میانی شامل تعدادی از گره‌های مصنوعی می‌باشد. گره‌های لایه‌های مجاور توسط بردارهای وزنی به هم مرتبط‌اند.



شکل (۲) شبکه عصبی مصنوعی سه لایه (نورانی و همکاران، ۲۰۰۹: ۴۷۰)

### – روش دسته‌بندی SOM

عموماً شبکه‌ی SOM شامل دو لایه است، یک لایه‌ی ورودی و یک لایه‌ی KOHONNEN. لایه ورودی کاملاً به لایه‌ی KOHONNEN متصل است. هیچ کدام از المان‌های پردازشی (PE) در لایه‌ی KOHONNEN به هم متصل نیستند. هر کدام از PE ها  $n$  ارزش وزنی دارند. برای هر کدام از المان‌ها مسافت محاسبه شده و PE با کمترین فاصله‌ی انتخاب می‌شود. آموزش با بهره‌گیری از یادگیری رقابتی می‌باشد. هنگامی که یک نمونه از داده‌ها برای آموزش به شبکه داده می‌شود، فاصله‌ی اقلیدسی آن از تمامی بردارهای وزنی محاسبه می‌شود. نرون بردار وزنی که بیشتر شباهت را با نمونه‌ی ورودی دارد با نام (BMU)<sup>۲</sup> بهترین واحد تطبیق نامیده می‌شود. وزن‌های BMU و نرون‌های نزدیک به آن در شبکه‌ی SOM نسبت به بردار ورودی تنظیم می‌شوند. مقدار تغییر با گذشت زمان و با فاصله از BMU کاهش می‌یابد (کوهنن<sup>۳</sup>، ۱۹۹۸: ۴).

### تبدیل موجک

تبدیل موجک با مقیاس زمانی یک سیگنال زمانی پیوسته،  $x(t)$ ، به صورت زیر تعریف

- 
- 1- Processing Elements
  - 2- Best Matching Unit
  - 3- Kohonen

می‌شود:

$$(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} g^* \left( \frac{t-b}{a} \right) x(t) \cdot dt \quad \text{رابطه‌ی (۳)}$$

که تابع مزدوج را نشان می‌دهد.  $g(t)$  تابع موجک یا موجک مادر است. پارامتر  $a$  فاکتور بزرگنمایی و  $b$  نشان‌دهنده‌ی تبدیل موقت تابع  $g$  است که امکان مطالعه  $d$  سیگنال در پیرامون  $b$  را می‌دهد (نورانی و همکاران، ۲۰۰۹: ۴۶۸).

### - معیار ارزیابی موفقیت

در مرحله‌ی خوشه‌بندی مکانی، از ضریب سیلووه می‌توان به عنوان معیاری برای اندازه‌گیری اعتبار خوشه استفاده نمود. این ضریب برای یک خوشه درجه‌ی شباهت ایستگاه‌های داخل یک خوشه را بیان می‌کند که در آن  $S(i)$  مقدار سیلووه پیرومتر  $i$  است. مقادیر کوچک  $S(i)$  بیانگر کمی شباهت ایستگاه‌ها در همان خوشه است. کیفیت خوشه‌بندی می‌تواند با استفاده از متوسط سیلووه برای مجموعه‌ی کل داده‌ها اندازه‌گیری شود.  $a(i)$  فاصله‌ی اقلیدسی است که متوسط نامشابه‌ی خوشه‌ی  $i$  را از تمام ایستگاه‌های دیگر در خوشه‌ی  $A$  اندازه می‌گیرد.  $b(i)$  فاصله‌ی اقلیدسی است که کمینه‌ی نامشابه‌ی متوسط ایستگاه  $i$  را از ایستگاه‌های دیگر در غیر از خوشه  $A$  بیان می‌کند. ضریب سیلووه در زیر ارائه شده است (هسیو و لی، ۲۰۱۰: ۱۹۵)

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad \text{رابطه‌ی (۴)}$$

در مرحله‌ی پیش‌بینی، دو معیار مختلف ضریب تبیین (DC) (رابطه‌ی ۵) و جذر میانگین مربع خطاها (رابطه‌ی ۶) به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیشگویی دقیق‌تر استفاده شده است.

$$DC = 1 - \frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{\sum_{i=1}^N (G_{obs_i} - \bar{G}_{obs_i})^2} \quad \text{رابطه‌ی (۵)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (G_{comi} - G_{obsi})^2}{N}} \quad \text{رابطه ی (۶)}$$

که در این روابط N تعداد داده‌های مشاهداتی،  $G_{comi}$  داده‌های محاسباتی (مقدار پیش‌بینی شده)،  $G_{obsi}$  داده‌های مشاهداتی  $\overline{G_{obsi}}$  میانگین داده‌های مشاهداتی است. هرچه RMSE به صفر و DC به یک نزدیک شود، جواب بهتری برای مدل حاصل شده است.

## نتایج و بحث

### – خوشه‌بندی

نتایج خوشه‌بندی پیژومترها به ۵ خوشه در جدول (۱) نشان داده شده‌است. مطابق مقادیر سیلوئه ارایه شده در جدول پیژومترهای مرکزی دارای بالاترین مقدار این ضریب می‌باشند. در خوشه‌هایی با دو پیژومتر، پیژومتر با مقدار ضریب سیلوئه بالا به عنوان پیژومتر مرکزی انتخاب شد. پیژومترهای مرکزی در ستون چهارم جدول زیر آورده شده است. مطابق جدول (۱)، پیژومترهای خوشه پنجم با داشتن بالاترین مقادیر این ضریب، بهترین خوشه‌بندی و همچنین خوشه‌های دوم و چهارم دارای ضعیف‌ترین خوشه‌بندی هستند.

جدول (۱) نتایج خوشه‌بندی تراز آب زیرزمینی دشت اردبیل (P نمایشگر پیژومترهای دشت می‌باشد)

شماره کلاس	پیژومترها	ضریب سیلوئه	پیژومتر مرکزی
کلاس ۱	P2, P12	۰/۴۸ _ ۰/۷۲	P12
کلاس ۲	P1, P8, P11	۰/۴۷ _ ۰/۶ _ ۰/۱۱	P8
کلاس ۳	P3, P5, P13, P15	۰/۱۸۶ _ ۰/۱۸۸ _ ۰/۷۶ _ ۰/۷۹	P5
کلاس ۴	P4, P6, P9, P10	۰/۱۶۶ _ ۰/۱۰۴ _ ۰/۶۳ _ ۰/۴۴	P4
کلاس ۵	P7, P14	۰/۹۴ _ ۰/۹۶	P7

## - نتایج مدل‌سازی با مدل SVM و ANN

جدول (۲) نتایج مدل‌سازی با روش‌های ماشین بردار پشتیبان و شبکه عصبی را نشان می‌دهد. شبکه عصبی استفاده شده در مدل ANN به منظور پیش‌بینی سطح تراز آب زیرزمینی، شبکه عصبی پیشرو FFNN می‌باشد. شکل بهینه‌ی شبکه‌های عصبی به صورت آزمون و خطا به دست می‌آید. هدف از این آزمون و خطا، یافتن تعداد نرون‌های لایه‌ی پنهان و تعداد تکرار الگوریتم می‌باشد تا به واسطه‌ی آن‌ها مدل تعریف گردد.

جدول (۲) نتایج و آماره‌های مدل‌های SVM و ANN برای یک ماه آینده

شماره کلاس	متغیرهای ورودی به شبکه	متغیر خروجی	نوع مدل	DC		RMSE	
				آموزش	آزمایش	آموزش	آزمایش
۱	P12(t), P12(t-1), Q(t)	P12(t+1)	ANN	۰/۹۷۷	۰/۹۵۱	۰/۰۰۵	۰/۰۰۶
			SVM	۰/۹۷۷	۰/۹۵۸	۰/۰۰۵	۰/۰۰۶
			ARIMAX	۰/۶۲	۰/۶۱	۰/۱۲۳	۰/۰۹۶
۲	P8(t), P8(t-1), I3(t-1), Q(t-2)	P8(t+1)	ANN	۰/۹۴۴	۰/۸۶	۰/۰۳۵	۰/۰۴۱
			SVM	۰/۹۳۵	۰/۸۶۹	۰/۰۳۴	۰/۰۴۴
			ARIMAX	۰/۷۶	۰/۶۵	۰/۱۱۲	۰/۰۸۹
۳	P5(t), P5(t-1), Q(t-1)	P5(t+1)	ANN	۰/۹۹۶	۰/۹۹۲	۰/۰۱۴	۰/۰۱۵
			SVM	۰/۹۹	۰/۹۹	۰/۰۱۵	۰/۰۲۳
			ARIMAX	۰/۶۸	۰/۵۷	۰/۱۰۹	۰/۰۷۹
۴	P4(t), P4(t-1), I4(t),Q(t)	P4(t+1)	ANN	۰/۸۳۲	۰/۶۷۷	۰/۰۲۲	۰/۰۳۷
			SVM	۰/۸۱۹	۰/۶۶۷	۰/۰۲۳	۰/۰۳۸
			ARIMAX	۰/۷۷	۰/۵۴	۰/۱۲۵	۰/۱
۵	P7(t), P7(t-1), I4(t-1), Q(t-1)	P7(t+1)	ANN	۰/۹۷	۰/۹۴	۰/۰۰۴	۰/۰۰۵
			SVM	۰/۹۵۵	۰/۹۴	۰/۰۰۴	۰/۰۰۶
			ARIMAX	۰/۷۴	۰/۶۵	۰/۱۰۶	۰/۰۸۸

P نمایشگر پیزومترهای مرکزی هر خوشه، I نماینده ایستگاه باران‌سنجی و Q رواناب در خوجی حوضه می‌باشد (t زمان فعلی را در هر پارامتر نمایش می‌دهد).

نتایج حاکی از دقت بالای مدل‌سازی توسط شبکه‌ی SVM و ANN در اکثر پیزومترها است. براساس نتایج مندرج در جدول (۲) بهترین  $R^2$  در بخش آموزش و صحت‌سنجی با مقادیر مشابه ۰/۹۹ برای آموزش و صحت‌سنجی مربوط به خوشه‌ی ۳ و پیزومتر مرکزی P5 می‌باشد. بر این اساس خوشه‌ی شماره‌ی ۴ نسبت به سایر خوشه‌ها از دقت کمتری برخوردار بوده که دلیل آن را می‌توان در مواردی نظیر مقدار ضریب سیلوهه پایین، قرارگیری در مناطق دارای کشت دیمی واقع بین دو شهر بزرگ اردبیل و نمین، وجود چاه‌های متعدد غیرمجاز، برداشت بی‌رویه از سفره‌های آب زیرزمینی و نیز احداث سد یامچی روی رودخانه‌ی بالیخلی جای جستجو کرد. با نگاهی به نتایج حاصله ناشی از دو روش مدل‌سازی SVM و ANN می‌توان نتیجه گرفت که هر دو مدل از دقت بالایی در اکثر خوشه‌ها برخوردار می‌باشد. همچنین در جدول (۲) نتایج روش خطی ARIMAX به منظور مقایسه‌ی بهتر با روش‌های پیشنهادی ارائه گردید. با توجه به عدم توانایی مدل خطی ARIMAX در مدل‌سازی پدیده‌های پیچیده‌ی غیرخطی، این روش از دقت کمتری نسبت به مدل‌های غیرخطی SVM و ANN برخوردار است. اما با این وجود هنوز روش مفید و پرکاربردی برای مقایسه می‌باشد.

#### نتایج مدل‌سازی با مدل WSVM و WANN

جدول (۳) نتایج حاصل از مدل‌سازی توسط شبکه‌ی ماشین بردار پشتیبان و شبکه عصبی مصنوعی و مدل ترکیبی این دو با موجک را نشان می‌دهد.

نتایج به دست آمده برای مدل‌سازی به روش WSVM بیانگر ضریب تبیین متوسط ۰/۹۷ برای آموزش و ۰/۹۳ برای آزمایش و در مدل‌سازی به روش WANN ضریب

تبیین ۰/۹۷ برای آموزش و ۰/۹۴ برای آزمایش می‌باشد و تأثیر مثبت استفاده از پیش پردازش داده‌ها توسط موجک را نشان می‌دهد. با بررسی نتایج دو روش مدل‌سازی پشتیبان - موجکی با عصبی - موجکی می‌توان نتیجه‌گیری کرد که هر دو مدل در اکثر خوشه‌ها از دقت بسیار بالایی در امر پیش‌بینی مقادیر تراز آب زیرزمینی برای یک ماه آینده برخوردار هستند. در خوشه‌ی شماره‌ی ۳ به عنوان بهترین خوشه، نتایج به دست آمده برای هر دو مدل برابری می‌کند. در خوشه‌های شماره ۱ و ۵ مدل‌سازی از طریق مدل هیبریدی پشتیبان - موجکی به طور میانگین ۰/۷ درصد در قسمت آموزش و ۰/۳ درصد در قسمت صحت‌سنجی دارای برتری نسبت به مدل عصبی - موجکی است. در خوشه‌های شماره ۲ و ۴ مدل ترکیبی عصبی - موجکی با میانگین نتایج ۱/۷ درصد برای آموزش و ۳/۲ درصد برای صحت‌سنجی نسبت به مدل ترکیبی ماشین بردار پشتیبان - موجکی دارای برتری می‌باشد. در پایان می‌توان اینطور نتیجه گرفت که ترکیب تبدیل موجک با مدل‌های هوش مصنوعی باعث افزایش دقت مدل‌سازی می‌شود.

جدول (۳) نتایج و آماره‌های مدل‌سازی با مدل ترکیبی WSVM و WANN

شماره کلاس	متغیرهای ورودی به شبکه *		متغیر خروجی	نوع مدل‌سازی	DC		RMSE	
	Pi	Q			آموزش	آزمایش	آموزش	آزمایش
۱	Pi12(t), Q(t)	P12(t+1)	موجکی	WSVM	۰/۹۹۳	۰/۹۷۳	۰/۰۰۳	۰/۰۰۴
				WANN	۰/۹۸۸	۰/۹۷۵	۰/۰۰۵	۰/۰۰۴
۲	Pi8(t), I3(t-1), Q(t-2)	P8(t+1)	موجکی	WSVM	۰/۹۶۲	۰/۹۰۱	۰/۰۳۳	۰/۰۲۹
				WANN	۰/۹۶۸	۰/۹۱۶	۰/۰۳۱	۰/۰۲۷
۳	Pi5(t), Q(t-1)	P5(t+1)	موجکی	WSVM	۰/۹۹۷	۰/۹۹۵	۰/۰۱۳	۰/۰۱۱
				WANN	۰/۹۹۷	۰/۹۹۵	۰/۰۱۳	۰/۰۱۱
۴	Pi4(t), I4(t), Q(t)	P4(t+1)	موجکی	WSVM	۰/۸۹۸	۰/۸۲۲	۰/۰۲۸	۰/۰۱۷
				WANN	۰/۹۲۲	۰/۸۶۱	۰/۰۲۵	۰/۰۱۵
۵	Pi7(t), I4(t-1), Q(t-1)	P7(t+1)	موجکی	WSVM	۰/۹۷۹	۰/۹۶۷	۰/۰۰۴	۰/۰۰۳
				WANN	۰/۹۷۱	۰/۹۶۳	۰/۰۰۵	۰/۰۰۳

\* مقادیر Pi: زیرسری‌های تجزیه شده سری زمانی تراز آب زیرزمینی توسط تبدیل موجک در ورودی شبکه

### نتیجه‌گیری و پیشنهادات

در این مطالعه با استفاده از روش خوشه‌بندی SOM برای پیش‌پردازش مکانی، مدل‌سازی تراز آب زیرزمینی دشت اردبیل با روش‌های ANN و SVM انجام گرفت. برای افزایش دقت مدل‌سازی از ابزار موجک برای پیش‌پردازش زمانی داده‌ها، استفاده گردید. در بین مدل‌های تکی ANN و SVM، مدل ANN در همه‌ی خوشه‌ها بجز خوشه ۱ دقت بهتری داشت. مدل‌های ترکیبی WANN و WSVM نسبت به مدل‌های تکی پیش‌بینی خوبی از تراز آب زیرزمینی دشت اردبیل ارائه دادند. در مطالعات بازرگان لاری و همکاران (۱۳۸۹: ۶۰) در آبخوان تهران، کلته و غلامی در سواحل جنوبی دریای خزر (۱۳۹۱: ۳۷)، نعمت‌الهی و همکاران در دشت کرمان (۱۳۹۲: ۶۷)، رضانی و ذونعمت کرمانی در دشت شهرکرد (۱۳۹۴: ۱۰۰) صورت گرفت، مدل SVM از دقت بالایی در پیش‌بینی تراز آب زیرزمینی نسبت به مدل شبکه‌عصبی برخوردار بوده است. سوریانا و همکاران ۱ (۲۰۱۴: ۳۲۷)، یون و همکاران ۲ (۲۰۱۶: ۱۴۸) و ابراهیمی و رجایی (۲۰۱۷: ۱۸۵) نیز همانند دشت اردبیل قابلیت بالای مدل ترکیبی WSVM را در مدل‌سازی پژوهش‌های خود اذعان داشتند. در حالت کلی مدل ترکیبی بردار پشتیبان - موجکی که در دشت اردبیل برای اولین بار اجرا می‌شود به عنوان ابزاری مطمئن و کارا، دارای قابلیت پیش‌بینی تراز آب زیرزمینی دشت اردبیل با دقت بالا می‌باشد. در این تحقیق تنها از پارامترهای هیدرولوژیکی بارش و رواناب استفاده شده است. برای بررسی و مطالعه‌ی بیشتر می‌توان از پارامترهای ورودی دیگری چون تبخیر، دمای روزانه برای مدل‌سازی استفاده کرد. همچنین می‌توان پیش‌بینی تراز آب زیرزمینی برای ماه‌های آتی را با این روش انجام داد. در ضمن سایر روش‌های هوش مصنوعی در ترکیب با موجک را نیز می‌توان مورد مطالعه قرار داده و دقت آن‌ها را سنجید. با توجه به توانمندی‌های مدل WSVM می‌توان از این نوع مدل‌سازی برای پیش‌بینی سایر پدیده‌های هیدرولوژیکی نظیر بارش، رسوب، رودخانه و ... استفاده کرد.

1- Suryanarayana et al.,

2- Yoon et al.



## منابع

- بازرگان لاری، محمدرضا؛ کراچیان، رضا؛ صدقی، حسین؛ فلاح نیا، مهسا؛ علم‌دوست، ارمان و محمدرضا نیکو (۱۳۸۹)، تدوین قوانین احتمالاتی برای بهره‌برداری بهینه تلفیقی کمی - کیفی از منابع آب سطحی و زیرزمینی در زمان واقعی: کاربرد ماشین بردار پشتیبان، مجله‌ی آب و فاضلاب، شماره‌ی ۴، صص ۶۹-۵۴.
- رجایی، طاهر و هادی ابراهیمی (۱۳۹۳)، مدل‌سازی نوسان‌های ماهانه‌ی آب زیرزمینی به وسیله‌ی تبدیل موجک و شبکه‌عصبی پویا، مدیریت آب و آبیاری، شماره‌ی ۴(۱)، صص ۹۹-۱۱۵.
- رجایی، طاهر و اکرم زینی‌وند (۱۳۹۳)، مدل‌سازی تراز آب زیرزمینی با بهره‌گیری از مدل هیبریک موجک- شبکه‌عصبی مصنوعی، نشریه‌ی مهندسی عمران و محیط زیست، شماره‌ی ۴۴(۴)، صص ۶۳-۵۱.
- رضانی چرمهینه، عبدالله و محمد ذونعمت کرمانی (۱۳۹۴)، ارزیابی روش‌های ماشین بردار پشتیبان، تحلیل تفکیک خطی و درجه دوم در شبیه‌سازی نوسانات سطح آب زیرزمینی دشت شهر کرد، تحقیقات منابع آب ایران، شماره‌ی ۲، صص ۱۰۵-۹۷.
- کلتی، امان محمد و وحید غلامی (۱۳۹۱)، پیش‌بینی سطح آب زیرزمینی با استفاده از ماشین بردار پشتیبان، مطالعه موردی سواحل جنوبی خزر، سومین همایش ملی مدیریت جامع منابع آب، دانشگاه علوم کشاورزی و منابع طبیعی، ساری، ۲۱-۲۰ شهریور، صص ۳۰-۴۶.
- ملکی‌نژاد، حسین و ربابه پورشریعتی (۱۳۹۲)، کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه‌عصبی مصنوعی در پیش‌بینی تغییرات سطح آب زیرزمینی (مطالعه‌ی موردی: دشت مروست)، علوم مهندسی آبیاری (مجله‌ی کشاورزی)، شماره‌ی ۳(۳)، صص ۹۲-۸۱.
- نخعی، محمد و امیر صابری نصر (۱۳۹۱)، پیش‌بینی نوسانات سطح آب زیرزمینی دشت قروه با استفاده از شبکه‌عصبی - موجکی و مقایسه‌ی آن با مدل عددی MODFLOW، مجله‌ی زمین‌شناسی کاربردی پیشرفته، شماره‌ی ۴(۱)، صص ۵۸-۴۷.

- نعمت‌الهی، بیتا؛ کمالی، امیرجلال و محمد علیخانی‌نژاد (۱۳۹۱)، پیش‌بینی سطح آب زیرزمینی با مدل محاسباتی ماشین بردار پشتیبان (مطالعه‌ی موردی: دشت کرمان)، دومین کنفرانس بین‌المللی گیاه، آب، خاک و هوا، صص ۶۲-۷۸.
- Adamowski. J., Chan. H.F., (2011), **A Wavelet neural network conjunction model for groundwater level forecasting**, Journal of Hydrology, Vol. 407, PP28-40.
- Behzad, M., Asghari, K., Coppola, EJR., (2010), **Comparative study of SVMs and ANNs in aquifer water level prediction**, Journal of computing in Civil Engineering, Vol. 24, No. 5, PP. 408-413.
- Chang, F.J., Chang, L.C., Huang, C.W., Kao, I.F., (2016), **Prediction of monthly regional groundwater levels through hybrid soft-computing techniques**, Journal of Hydrology, Vol. 541, PP. 965-976.
- Chen, L.H., Chen, C.T., Pan, Y.G., (2010), **Groundwater level prediction using SOM-RBFN multisite model**, Journal of Hydrologic Engineering, Vol. 15, PP. 624-631.
- Chen, L.H., Chen, C.T., Li, D.W., (2011), **Application of integrated back-propagation network and self-organizing map for groundwater level forecasting**, Water Resources Management, Vol.137, No.4, PP. 352-365.
- Chen, ST. Yu, PS., (2007), **Pruning of support vector networks on flood forecasting**, Journal of Hydrology, Vol. 347, No. 1-2, PP. 67-78.
- Daliakopoulos, I.N., Coulibaly, P., Tsanis, I.K., (2005), **Groundwater level forecasting using artificial neural networks**, Journal of Hydrology, Vol. 309, PP. 229-240.
- Han, J.C., Huang, Y., Li, Z., Zhao, C., Cheng, G., Huang, P., (2016), **Groundwater level prediction using a SOM-aided stepwise cluster inference model**, Journal of Environmental Management, Vol. 182, PP. 308-321.
- Hsu, K.C., Li, S.T., (2010), **Clustering spatial-temporal precipitation data using wavelet transform and self-organizing map neural network**, Advances in Water Resources, Vol. 33, PP. 190-200.

- Lallahema, S., Maniaa, J., Hania, A., Najjarb, Y., (2005), **On the use of neural networks to evaluate groundwater levels in fractured media**, Journal of Hydrology., Vol. 307, PP. 92-111.
- Lin, G.F., Chen, G.R., (2006), **An improved neural network approach to the determination of aquifer parameters**, Journal of Hydrology, Vol. 316, No.1-4, PP. 281-289.
- Maheswaran, R., Khosa, R., (2013), **Long term forecasting of groundwater levels with evidence of non- stationary and nonlinear characteristics**, Computers Geosciences, Vol. 52, PP. 422- 436.
- Moosavi, V., Vafakhah, M., Shirmohammadi, B., Ranjbar, M., (2014), **Optimization of wavelet- ANFIS and wavelet- ANN hybrid models by Taguchi method for groundwater level forecasting**, Arabian Journal for Science and Engineering, Vol. 39, No. 3, PP. 1785-1796.
- Nayak, P. C., Satyajirao, Y. P., Sudheer, P. K., (2006), **Groundwater Level Forecasting in a Shallow Aquifer Using Artificial Neural Network Approach**, Water Resources Management, Vol. 20, PP. 77-90.
- Nourani, V., Alami, M., T., Aminfar, MH., (2009), **Combined neural - wavelet model for prediction of Ligvanchayi watershed precipitation**, Engineering Applications of Artificial Intelligence, Vol. 22, PP. 466 - 472.
- Nourani, V., Hosseini Baghanam, A., Daneshvar Vousoughi, F., Alami, M.T., (2012), **Classification of Groundwater Level Data Using SOM to Develop ANN-Based Forecasting Model**, International Journal of Soft Computing and Engineering., Vol. 2, PP. 2231-2307.
- Nourani, V., Taghi Alami, M., Daneshvar Vousoughi, F., (2015), **Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling**, Journal of Hydrology, Vol. 524, PP. 255-269.
- Partal, T. and Cigizoglu, H.K., (2008), **Estimation and forecasting of daily suspended sediment data using wavelet-neural networks**, Journal of Hydrology, Vol. 358, No. 3-4, PP. 317-331.
- Satyajirao, Y. R., Krishna, B., (2009), **Modelling hydrological time series data using wavelet neural network analysis**, New Approaches to

**Hydrological Prediction in in Datasparse Regions, Proc. of Symposium HS.2 at the Joint IAHS IAH Convention, Hydreabad, India, IAHS Publications, Vol. 333, PP. 101-111.**

- Shiri, J., Kisi, O., Yoon, H., Lee, KK., Nazemi, AD., (2013), **Predicting groundwater level fluctuations with meteorological effect implications – A comparative study among soft computing techniques**, Computers & Geosciences, Vol. 56, PP. 32-44.
- Taorminal, R., Chau, K.W., Sethi, R., (2012), **Groundwater levels in a coastal aquifer system of the 4 Venice lagoons**, Engineering Applications of Artificial Intelligence, Vol. 25, No. 8, PP.1670-1676.
- Vapnik, V., Cortes, C., (1995), **Support Vector Networks, Machine Learning**, Vol. 20, PP. 1-25.
- Wang. W., Ding. S., (2003), **Wavelet network model and its application to the predication of hydrology**, Nature and Science, Vol. 1, No. 1, PP. 67-71.
- Yoon, H., Jun, SC., Hyun, Y., Bae, GO., Lee, KK., (2011), **A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer**, Journal of Hydrology, Vol. 396, No. 1-2, PP. 128-138.
- Yoon, H., Hyun, Y., Ha, K., Lee, K.K., Kim, G.B., (2016), **A method to improve the stability and accuracy of ANN- and SVM-based time series models for long-term groundwater level predictions**, Computers & Geosciences, Vol. 90, PP. 144-155.
- Zhao, W., Gao, Y., LI, C., (2012), **RVM based on PSO for groundwater level forecasting**, Journal of computers, Vol. 7, No. 5, PP. 1073-1079.