



ارزیابی عملکرد ماشین‌های بردار حامی در پیش‌بینی تغییرات شوری آب رودخانه‌ها - مطالعه موردی: رودخانه کارون

مسعود تجریشی^۱، عماد محجوبی^۲

۱- دانشیار دانشکده مهندسی عمران، دانشگاه صنعتی شریف، تهران

۲- دانشجوی کارشناسی ارشد مهندسی محیط زیست، دانشگاه صنعتی شریف، تهران

emad.mahjoobi@gmail.com

خلاصه

در این مقاله، عملکرد روش ماشین‌های بردار حامی در پیش‌بینی تغییرات شوری آب رودخانه کارون در ایستگاه ملائانی مورد بررسی قرار گرفته است. داده‌های استفاده شده مربوط به این ایستگاه در بازه سال‌های ۱۳۴۷ تا ۱۳۸۴، شامل غلظت یون‌های سدیم، کلسیم، منیزیم، کلر، سولفات، بی‌کربنات، pH و دی‌بی به عنوان پارامترهای ورودی مدل‌ها و کل مواد محلول (TDS) به عنوان پارامتر خروجی می‌باشد. همچنین عملکرد مدل با روش شبکه عصبی تابع پایه شعاعی مقایسه گردید. نتایج نشان می‌دهد که هر دو روش با دقت بسیار بالایی قادر به پیش‌بینی میزان TDS هستند، حال آنکه روش ماشین بردار حامی در هر دو مرحله آموزش و ارزیابی دقت بالاتری داشته است. علاوه بر دقت بالاتر، عدم نیاز به استفاده از رویکرد سعی و خطا جهت یافتن ساختار بهینه و در نتیجه سرعت اجرای بیشتر، از دیگر برتری‌های روش ماشین‌های بردار حامی نسبت به روش شبکه عصبی تابع پایه شعاعی شناخته شد.

کلمات کلیدی: ابزار محاسبات نرم، ماشین‌های بردار حامی، شبکه عصبی تابع پایه شعاعی، تغییرات شوری، رودخانه کارون

۱. مقدمه

رودخانه‌ها به عنوان مهم‌ترین منابع تامین و انتقال آب مصرفی بخش‌های صنعت، کشاورزی و شهری از اهمیت خاصی برخوردار بوده و به علت این که از بسترها و مناطق مختلفی می‌گذرند و در ارتباط مستقیم با محیط پیرامون خود هستند، نوسانات کیفی زیادی دارند. توسعه روزافزون فعالیت‌های کشاورزی و صنعتی و افزایش قابل توجه حجم فاضلاب‌های شهری موجب آلودگی منابع آب، خصوصاً رودخانه‌ها گردیده است [۱، ۲]. تغییرات کاربری اراضی و ایجاد تاسیسات ذخیره و نگهداری در یک سیستم رودخانه‌ای می‌تواند میزان شوری آن را تغییر داده و منجر به تأثیرات نامطلوب در سیستم آبی شود. شوری بالای آب رودخانه، باعث افزایش خوردگی لوله‌های انتقال آب و اتصالات و نیز نامطلوبی استفاده برای شرب و مصارف بهداشتی در شهرها شده و همچنین باعث شوری خاک و در نتیجه کاهش عملکرد گیاهان خواهد شد. با پیش‌بینی شوری می‌توان مدیریت استفاده از منابع آب را بهبود بخشید [۳].

در دهه‌های اخیر ابزار محاسبات نرم و سیستم‌های هوشمند (ابزارهای داده‌کاوی) به عنوان روش‌های جدید مدل‌سازی سیستم‌های پیچیده مهندسی معرفی شده‌اند. این روش‌ها در واقع رابطه بین پارامترهای وابسته و مستقل را تعیین نموده و به نوعی مناسب‌ترین تابع را بر روی آن‌ها برازش می‌دهند و قادر به تقریب هر تابع غیرخطی می‌باشند [۴]. در زمینه پیش‌بینی تغییرات شوری با استفاده از ابزارهای داده‌کاوی مطالعات زیادی چه در داخل و چه در خارج از ایران انجام شده است. نمونه‌ای از این مطالعات در جداول ۱ و ۲ آمده است. مشاهده می‌شود که تمرکز اغلب محققین بر روش شبکه عصبی پرسپترون چند لایه بوده و در اکثر حالات نتایج بیانگر عملکرد قابل قبول این روش در پیش‌بینی شوری بوده است. در این مقاله با استفاده از روش ماشین‌های بردار حامی، تغییرات غلظت کل مواد محلول (TDS) رودخانه کارون در ایستگاه ملائانی پیش‌بینی شده و نتایج آن با روش شبکه عصبی تابع پایه شعاعی مقایسه گردیده است.

جدول ۱ - نمونه‌ای از مطالعات پیشین در زمینه پیش‌بینی تغییرات شوری با استفاده از ابزارهای داده‌کاوی در خارج از ایران

محققین (سال)	هدف	ابزار مورد استفاده	نتایج
Canizares & Pilipovik (2010) [۵]	پیش‌بینی پارامترهای شوری و کل جامدات محلول (TDS) دستگاه‌های نمک‌زدایی و ارزیابی تأثیرات فصلی بر آن‌ها در منطقه کارائیب	شبکه عصبی تابع پایه شعاعی	پارامترهای مذکور در طول سال تا ۳۰ درصد تغییرات داشته و دقت پیش‌بینی مدل حدود ۹۶/۷ درصد است
May & Sivakumar (2009) [۶]	پیش‌بینی کیفیت رواناب شهری در مناطقی از آمریکا	شبکه عصبی پرسپترون چند لایه	مدل توسعه‌یافته در مقایسه با رگرسیون چند متغیره خطی دقت کمتری داشته و زمان برتر است
Palani et al. (2008) [۷]	پیش‌بینی مشخصات کیفی آب‌های ساحلی سنگاپور شامل شوری، دما، اکسیژن محلول و کلروفیل-a	شبکه عصبی پرسپترون چند لایه	توانایی فوق‌العاده مدل توسعه‌یافته در شبیه‌سازی پارامترهای کیفی آب
Huang & Foo (2002) [۳]	پیش‌بینی تغییرات لحظه‌ای شوری در رودخانه Apalachicola در فلوریدا بر مبنای سطح آب، دبی ورودی و باد	شبکه عصبی پرسپترون چند لایه	مدل توسعه‌یافته در مقایسه با رگرسیون چند متغیره توانا تر بوده و زمان کمتر و راحتی بیشتری دارد

جدول ۲ - نمونه‌ای از مطالعات پیشین در زمینه پیش‌بینی تغییرات شوری با استفاده از ابزارهای داده‌کاوی در ایران

محققین (سال)	هدف	ابزار مورد استفاده	نتایج
فردی و همکاران (۱۳۸۸) [۸]	مطالعه شوری در ایستگاه هیدرومتری ونیار در حوضه آبریز رودخانه آچی‌چای (تلخه‌رود)	شبکه عصبی پرسپترون چند لایه	امکان تخمین TDS یک ماه بعد را با استفاده از دبی حال حاضر
بختیاری و همکاران (۱۳۸۶) [۲]	ارزیابی کیفی رودخانه کرخه	شبکه عصبی پرسپترون چند لایه	توانایی بالای مدل توسعه‌یافته در پیش‌بینی کیفیت آب رودخانه کرخه
کرمی و همکاران (۱۳۸۵) [۱]	پیش‌بینی کیفیت آب رودخانه کارون	شبکه عصبی پرسپترون چند لایه	توانایی بالای مدل توسعه‌یافته در پیش‌بینی کیفیت آب رودخانه کارون
نوشادی و همکاران (۱۳۸۵) [۹]	شبیه‌سازی پارامترهای کیفیت آب شامل هدایت الکتریکی، کل جامدات محلول، اسیدیته، بی‌کربنات و کلر در طول رودخانه زاینده‌رود و بررسی تغییرات کیفیت آب در طول رودخانه	شبکه عصبی پرسپترون چند لایه	عملکرد خیلی خوب مدل توسعه‌یافته برای پارامترهای اسیدیته و بی‌کربنات و نسبتاً خوب برای هدایت الکتریکی، کل جامدات محلول و کلر

۲. معرفی روش‌ها


۲.۱. شبکه عصبی تابع پایه شعاعی

ساختار شبکه عصبی تابع پایه شعاعی (Radial Basis Function Network, RBFN) مشابه شبکه پرسپترون چند لایه شامل سه لایه ورودی، میانی و خروجی است. با این تفاوت که گره‌های لایه میانی با توابع پایه شعاعی مشخص می‌شوند و گره‌های لایه خروجی نیز لزوماً از تابع فعالیت خطی استفاده می‌کنند. ساختار لایه میانی یا گیرنده، شامل گره‌هایی برای بیان خوشه‌های الگوهای ورودی می‌باشد. این خوشه‌ها براساس توابع پایه شعاعی یا توابع فاصله میان مرکز تابع پایه شعاعی و بردار مقادیر ورودی تعریف می‌شوند. در این روش، فضا توسط دایره یا ابرگره‌هایی با مرکز و شعاع مشخص تقسیم می‌گردد. گره‌ها به فاصله نقاط از مرکز، حساسیت نشان می‌دهند. سطح پاسخ یک گره شعاعی منفرد، به صورت یک تابع گوسی است که بیشینه آن در مرکز بوده و به اطراف نزول می‌یابد. شبکه تابع پایه شعاعی، یک لایه میانی با گره‌های شعاعی دارد که هر کدام یک سطح پاسخ گوسی را مدل می‌کنند. از آنجا که این توابع غیر خطی‌اند، نیازی به بیش از یک لایه میانی نبوده و تعداد مناسب گره‌های شعاعی اغلب برای مدل کردن هر تابعی کافی خواهد بود. آموزش این شبکه معمولاً در دو مرحله شامل توسعه توابع پایه در لایه میانی و سپس تعیین وزن‌های ارتباطی میان گره‌های لایه میانی و خروجی

انجام می‌گردد [۳]. ارتباطات بین گره‌های ورودی و میانی مشابه مدل K-means آموزش می‌بینند. به ویژه وزن‌های میانی تنها با لایه ورودی آموزش می‌بینند و لایه خروجی برای اولین فاز آموزش نادیده گرفته می‌شود. تنها پس از این که وزن‌های میانی برای یافتن خوشه‌ها در داده‌های ورودی بهینه شدند، ارتباطات میان لایه میانی و خروجی جهت تولید پیش‌بینی‌ها آموزش داده می‌شوند. در طول آموزش، رکوردها مانند پرسپترون چند لایه به شبکه معرفی می‌شوند. گره‌های میانی، میزان فعال‌سازی خود را براساس اندازه تابع پایه شعاعی خود و میزان همپوشانی که توسط کاربر مشخص می‌شود، محاسبه می‌کنند. گره‌های خروجی نیز با استفاده از تابع مجموع وزنی براساس مقادیر گره‌های میانی مشخص می‌گردند. وزن‌های خروجی مشابه یک شبکه دو لایه پس انتشار آموزش می‌بینند [۵].

۲.۲. ماشین‌های بردار حامی

مدل ماشین‌های بردار حامی (Support Vector Machines, SVMs)، توسط Vapnik بنا نهاده شد. وی در سال‌های ۱۹۹۲، ۱۹۹۵ و ۱۹۹۸ مدل را مطرح و تکامل داد. مانند شبکه‌های عصبی پرسپترون چند لایه و توابع پایه شعاعی، SVMs نیز می‌تواند برای کلاس‌بندی الگوها و برازش غیرخطی مورد استفاده قرار گیرد [۱۰]. SVMs، روش‌های رگرسیونی و طبقه‌بندی هستند که از تئوری یادگیری آماری مشتق شده‌اند. روش‌های طبقه‌بندی بر مبنای اصل جداسازی بهینه کلاس‌هاست. اگر دو کلاس تفکیک پذیر باشند، این الگوریتم از میان بیشمار دسته‌کننده خطی، آن دسته‌کننده‌ای که خطای تعمیم‌پذیری را حداقل می‌کند یا دسته کم یک حد بالایی بر روی این خطا می‌گذارد را از طریق کمینه‌سازی ریسک ساختاری انتخاب می‌کند. لذا ابرصفحه (Hyper plane) انتخابی، تنها موردی خواهد بود که بیشترین حاشیه میان دو کلاس را ایجاد می‌کند. منظور از حاشیه، مجموع فواصل ابر صفحه از نزدیک‌ترین نقطه دو کلاس است [۱۱]. شکل ۱ یک ابرصفحه بهینه را در فضای دو بعدی نشان می‌دهد.



شکل ۱ - نمایش ایده ابرصفحه بهینه برای الگوهای تفکیک پذیر خطی در فضای دو بعدی

تکنیک‌های مدل‌سازی نظیر ماشین‌های بردار حامی، توانایی باز تولید روابط مجهول موجود میان مجموعه متغیرهای ورودی و خروجی سیستم را دارا هستند. عملکرد ماشین‌های بردار حامی به دلیل استفاده از اصل کمینه‌سازی ریسک ساختاری (Structural Risk Minimization, SRM) در فرمول‌بندی کردن توابع هزینه و برنامه‌ریزی غیرخطی در طول بهینه‌سازی بهتر است. این ویژگی منجر می‌شود که SVMs در مقایسه با روش‌های معمول شبکه عصبی که از اصل کمینه‌سازی ریسک تجربی (Empirical Risk Minimization, ERM) بهره می‌گیرند، بهینه‌تر باشد [۱۲]. اگر دو کلاس تفکیک‌پذیر نباشند، SVMs سعی می‌کند تا ابر صفحه‌ای را که حاشیه را بیشینه و در عین حال احتمال خطای کلاس‌بندی میانگین گرفته شده روی مجموعه داده آموزش را کمینه می‌کند، بیابد. انتخاب میان حاشیه و خطای دسته‌بندی نادرست، توسط یک مقدار ثابت مثبت که قبلاً مشخص شده کنترل می‌گردد. این روش طراحی SVMs می‌تواند به سطوح تصمیم غیرخطی تعمیم یابد. این امر با طرح‌ریزی مجموعه‌ای از متغیرها به داخل یک فضای مشخصه با ابعاد بالاتر و فرمول‌بندی یک مسئله دسته‌بندی خطی در آن فضا، ممکن می‌شود.

Vapnik (۱۹۹۵)، بردار پشتیبان رگرسیونی را با معرفی یک تابع اتلاف غیر حساس پیشنهاد داد. پیشنهاد این بردار، یافتن یک تابع تا حد امکان مسطح دارای انحراف بسیار زیاد از بردار هدف واقعی برای کلیه داده‌های آموزشی داده شده است [۱۱]. به بیان دیگر باید خطای هر داده آموزشی از \mathcal{E} کمتر باشد. برای یک داده آموزشی با تعداد k نمونه به صورت $(x_1, y_1), \dots, (x_k, y_k)$ و یک تابع خطی داریم:



$$f(x) = \langle w, x \rangle + d \quad (1)$$

که در آن $w \in R^N$ و $d \in R$ ، $\langle w, x \rangle$ بیانگر ضرب نقطه‌ای در فضای R^N ، و N بعد فضای ورودی است. هر چه مقدار w کوچکتر باشد، رابطه (۱) مسطح‌تر است. این امر با کمینه‌سازی فاصله اقلیدسی، $\|w\|^2$ ، میسر می‌گردد [۱۳]. بنابراین مسئله بهینه‌سازی به صورت زیر تعریف می‌شود:

$$\begin{aligned} & \text{Minimize} \quad \frac{1}{2} \|w\|^2 \\ & \text{s.t.} \quad \begin{cases} y_i - \langle w, x_i \rangle - d \leq \varepsilon \\ \langle w, x_i \rangle + d - y_i \leq \varepsilon \end{cases} \end{aligned} \quad (2)$$

مسئله بهینه‌سازی فوق بر مبنای فرض وجود یک تابع است که خطایی بر روی کلیه زوج‌های آموزشی مشخص می‌کند که از ε کمتر است. با تعریف ξ_i به عنوان متغیر کمکی خطا یا متغیر کمبود که معیاری برای انحراف یک نقطه داده از شرایط ایده‌آل جداسازی الگو می‌باشد، مسئله بهینه‌سازی در رابطه (۲) به صورت زیر در می‌آید:

$$\begin{aligned} & \text{Minimize} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k (\xi_i + \xi'_i) \\ & \text{s.t.} \quad \begin{cases} y_i - \langle w, x_i \rangle - d \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + d - y_i \leq \varepsilon + \xi'_i \end{cases} \\ & \xi_i, \xi'_i \geq 0 \quad \text{for all } i = 1, 2, \dots, k \end{aligned} \quad (3)$$

پارامتر C ، توسط کاربر مشخص شده و انتخاب میان مسطح‌بودن تابع و مقدار مجاز انحراف از خطای بیش از ε را کنترل می‌کند. مسئله بهینه‌سازی در رابطه (۳) از طریق جایگزین کردن نابرابری‌ها با یک فرم ساده‌تر به روش انتقال مسئله به یک فضای دوتایی که با ضرایب لاگرانژی $\lambda_i, \eta_i, \lambda'_i, \eta'_i$ تعریف می‌شود، قابل حل است [۱۴]. بالاخره مسئله پیش‌بینی به صورت زیر مشخص می‌گردد:

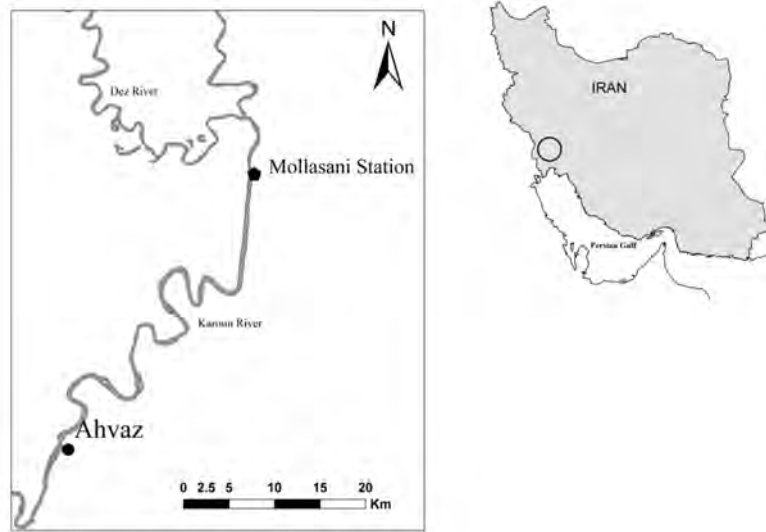
$$f(x, \alpha) = \sum_{i=1}^k (\lambda'_i - \lambda_i) \langle x_i, x \rangle + d \quad (4)$$

این روش قابلیت تعمیم به بردار رگرسیون حامی غیرخطی از طریق معرفی مفهوم تابع Kernel را دارد. این امر با نگاشت داده به یک فضای مشخصه با ابعاد بالاتر و اعمال رگرسیون خطی در فضای مشخصه، ممکن می‌شود. مسئله رگرسیون در فضای مشخصه توسط جایگزینی $x_i \cdot x_j$ با $\Phi(x_i) \cdot \Phi(x_j)$ حاصل می‌شود؛ به طوری که $K(x_i, x_j) \equiv \Phi(x_i) \cdot \Phi(x_j)$. تابع رگرسیون به صورت زیر خواهد بود [۱۱]:

$$f(x, \alpha) = \sum_{i=1}^k (\lambda'_i - \lambda_i) K(x_i, x) + d \quad (5)$$

۳. آماده‌سازی داده‌ها

داده‌های مورد مطالعه در این تحقیق مربوط به ایستگاه ملائانی بر روی رودخانه کارون با مختصات جغرافیایی ۳۱ درجه و ۳۶ دقیقه شمالی و ۴۸ درجه و ۵۳ دقیقه شرقی، در بازه سال‌های ۱۳۴۷ تا ۱۳۸۴ است. موقعیت جغرافیایی این ایستگاه و شهر اهواز در شکل ۲ نشان داده شده است. داده‌های کیفی شامل غلظت‌های سدیم، کلسیم، منیزیم، کلر، سولفات، بی‌کربنات، pH، کل مواد محلول و دی‌اکسید است. مشخصات آماری داده‌ها در جدول ۳ آمده است. بدون ارزیابی صحیح داده‌ها، انجام تحلیل‌های پیچیده آماری نتایج قابل اعتمادی را به دست نخواهد داد. هر چند استاندارد بودن قرائت و ثبت داده‌ها، تا حد زیادی از ایجاد اشتباه در آن‌ها می‌کاهد ولی معمولاً داده‌ها تا حدی به کنترل یا اصلاح نیاز دارند. در این مطالعه با استفاده از روش منحنی جرم مضاعف (Double Mass Curve)، همگنی داده‌های ایستگاه ملائانی مورد بررسی قرار گرفت و نتایج قابل قبولی به دست آمد.



شکل ۲ - موقعیت ایستگاه ملاسانی در حوضه رودخانه کارون در جنوب غرب ایران

جدول ۳ - مشخصات آماری پارامترهای مختلف اندازه‌گیری شده در ایستگاه ملاسانی در بازه سال‌های ۱۳۴۷ تا ۱۳۸۴

Na, mg/L	Mg, mg/L	Ca, mg/L	SO ₄ , mg/L	Cl, mg/L	HCO ₃ , mg/L	pH	Q, m ³ /s	TDS, mg/L	
۳۴/۶	۴/۹	۱۱/۴۵	۱۱/۲۵	۳۵/۳۵	۳/۹۵	۸/۹	۴۵۳۵/۵	۲۴۹۰	حداکثر
۱/۹	۰/۱۵	۱/۴۷	۰/۹	۱/۸	۱/۱۵	۷/۲	۱۴۱	۲۷۸	حداقل
۶/۳۹	۲/۲۴	۴/۱۲	۳/۶۲	۶/۴	۲/۸	۷/۹۹	۶۹۶/۳۳	۸۱۵/۵۸	میانگین
۳/۲۸	۰/۸۷	۱/۲۲	۱/۷۳	۳/۳۹	۰/۴۴	۰/۲۴	۶۲۹/۵۵	۲۹۹/۹۴	انحراف از معیار

۴. نتایج مدل‌سازی

پارامترهای غلظت سدیم، کلسیم، منیزیم، کلر، سولفات، بی‌کربنات، pH و دبی به عنوان ورودی و کل مواد محلول به عنوان خروجی مدل‌ها تعریف شدند. داده‌ها به دو بخش آموزش و ارزیابی تقسیم شدند؛ به این ترتیب که داده‌های در بازه سال‌های ۱۳۴۷ تا ۱۳۷۶ شامل ۳۱۴ مورد ثبتی در مجموعه آموزش و داده‌های در بازه سال‌های ۱۳۷۶ تا ۱۳۸۴ شامل ۱۰۷ داده ثبتی در مجموعه ارزیابی قرار گرفتند. در مرحله اول مدل‌ها، بر روی مجموعه آموزش کالیبره شده و سپس با استفاده از مجموعه ارزیابی، مورد صحت‌سنجی قرار گرفتند.

برای یافتن تعداد بهینه گره‌های لایه میانی در روش شبکه عصبی تابع پایه شعاعی از رویکرد سعی و خطا استفاده شد. به این منظور ۱۰ شبکه مختلف با تعداد گره‌های لایه میانی از ۵ تا ۵۰ توسعه یافته و عملکرد آن‌ها بر روی مجموعه ارزیابی با استفاده از میانگین مربعات خطاها بررسی شد. با توجه به شکل ۳، ساختار ۱-۲۰-۸ به عنوان شبکه بهینه مشخص گردید.

به منظور محاسبه میزان خطا در پیش‌بینی پارامتر مورد نظر و ارزیابی عملکرد مدل‌ها، از ضریب تعیین (R^2)، جذر میانگین مربعات خطاها (RMSE) و میانگین خطای مطلق (MAE) استفاده شده است. این پارامترها مطابق روابط زیر محاسبه می‌شوند:


$$R^2 = \frac{\left(\sum (x_i - \bar{x})(y_i - \bar{y}) \right)^2}{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2} \quad (6)$$



$$RMSE = \sqrt{\frac{1}{n} \sum (y_i - x_i)^2} \quad (7)$$

$$MAE = \frac{1}{n} \sum |x_i - y_i| \quad (8)$$

در همه روابط فوق، x_i داده‌های اندازه‌گیری شده، y_i داده‌های پیش‌بینی شده، \bar{x} میانگین داده‌های اندازه‌گیری شده و \bar{y} میانگین داده‌های پیش‌بینی شده می‌باشند.




شکل ۳ - تغییرات میانگین مربعات خطاها در شبکه‌های با تعداد گره‌های لایه میانی مختلف

مقادیر پارامترهای مختلف خطا در مراحل آموزش و ارزیابی مدل‌ها در جدول ۴ آمده است. مقایسه مقادیر واقعی و پیش‌بینی شده کل مواد محلول (TDS) و همچنین عملکرد مدل‌ها در مرحله ارزیابی در شکل ۴ نشان داده شده است. مشاهده می‌شود که هر دو روش با دقت بالایی قادر به پیش‌بینی میزان TDS هستند. در مرحله ارزیابی دقت روش‌ها در مقادیر پایین TDS بیشتر از مقادیر بالای آن است. همچنین هر دو روش مقادیر اوج را اندکی دست‌پایین تخمین زده‌اند.

جدول ۴ - مقادیر پارامترهای مختلف خطا در پیش‌بینی TDS در مراحل آموزش و ارزیابی مدل‌ها

RBFN		SVM		پارامترهای خطا
ارزیابی	آموزش	ارزیابی	آموزش	
۰/۹۵۶	۰/۹۴۳	۰/۹۷۵	۰/۹۵۶	R ²
۷۰/۱۴	۶۴/۰۲	۵۹/۲۷	۵۶/۶۷	RMSE
۵۰/۹۸	۴۸/۲۸	۴۵/۲۷	۴۲/۲۳	MAE

جهت تعیین میزان حساسیت TDS به پارامترهای مختلف مسئله، در هر روش مدل‌هایی با تنها یک پارامتر ورودی تعریف و توانایی آن‌ها در پیش‌بینی با استفاده از پارامترهای خطای تعریف شده بررسی گردید. نتایج تحلیل حساسیت در جدول ۵ آورده شده است. نتایج تحلیل حساسیت نشان می‌دهد که غلظت یون‌های سدیم و کلر، تشکیل‌دهنده کلرید سدیم موجود در آب، بیشترین تاثیر را در میزان TDS داشته و پس از آن‌ها به ترتیب غلظت یون‌های سولفات، کلسیم و منیزیم، تشکیل‌دهنده سولفات کلسیم و سولفات منیزیم موجود در آب، قرار دارند. پارامتر دبی در مرحله بعد قرار داشته و تاثیر غلظت یون بی‌کربنات و pH بسیار ناچیز و قابل صرف نظر کردن است.



شکل ۴ - مقایسه مقادیر واقعی و پیش‌بینی شده TDS در مرحله ارزیابی مدل‌ها

جدول ۵ - نتایج تحلیل حساسیت پارامترهای مختلف مسئله در هر دو روش

روش	پارامترهای خطا	Na	Cl	SO ₄	Ca	Mg	Q	HCO ₃	pH
SVM	R ²	۰/۹۰۹	۰/۸۹۵	۰/۵۶۵	۰/۳۲۶	۰/۴۵۷	۰/۲۵۹	۰/۰۰۰	۰/۰۰۰
	RMSE	۹۹/۷۱	۱۱۹/۱۸	۲۴۳/۵۹	۲۸۰/۷۹	۳۱۳/۰۷	۴۰۸/۵۶	۴۳۴/۸۶	۴۳۷/۷۴
	MAE	۷۰/۸۶	۸۷/۴۶	۱۸۲/۸۰	۲۱۵/۷۲	۲۴۸/۶۸	۳۲۷/۵۹	۳۵۲/۳	۳۵۵/۴
RBFN	R ²	۰/۸۸۸	۰/۸۸۸	۰/۵۶	۰/۳۱۷	۰/۳۳۸	۰/۳۵۸	۰/۰۲۷	۰/۰۰۶
	RMSE	۱۰۲/۸۴	۱۱۲/۰۹	۲۲۸/۱۷	۲۷۲/۱۶	۲۹۵/۹۶	۳۴۴/۴۱	۳۷۷/۲۲	۳۹۸/۵۷
	MAE	۷۵/۱۴	۸۱/۲	۱۶۸/۹۷	۲۰۷/۵۸	۲۳۰/۷۷	۲۶۵/۳۹	۲۹۳/۰۳	۳۱۸/۸۵

۵. نتیجه‌گیری

در این مقاله، عملکرد روش ماشین بردار حامی در پیش‌بینی تغییرات شوری (کل مواد محلول) آب رودخانه کارون در محل ایستگاه ملاثانی مورد بررسی قرار گرفت و نتایج به دست آمده با روش شبکه عصبی تابع پایه شعاعی مقایسه شد. داده‌های استفاده شده در بازه سال‌های ۱۳۴۷ تا ۱۳۸۴، شامل غلظت‌های سدیم، کلسیم، منیزیم، کلر، سولفات، بی‌کربنات، pH، و دبی به عنوان پارامترهای ورودی مدل‌ها و کل مواد محلول (TDS) به عنوان پارامتر خروجی بود.

با استفاده از رویکرد سعی و خطا، شبکه با ساختار ۱-۲۰-۸ به عنوان شبکه بهینه در روش RBFN مشخص گردید. مقایسه پارامترهای مختلف



خطا، بیانگر عملکرد بسیار مطلوب هر دو روش در پیش‌بینی تغییرات شوری می‌باشد. همچنین روش SVM در هر دو مرحله آموزش و ارزیابی دقت بالاتری داشته است. برای مثال میزان پارامتر جذر میانگین مربعات خطاها (RMSE) در مراحل آموزش و ارزیابی در روش SVM به ترتیب برابر ۵۶/۷ و ۵۹/۳ میلی‌گرم بر لیتر و در روش RBFN به ترتیب ۶۴ و ۷۰/۱ میلی‌گرم بر لیتر می‌باشد.

باتوجه به شکل ۴ روش SVM، مقادیر بالای TDS را اندکی دست پایین پیش‌بینی می‌کند. البته عملکرد روش RBFN در مقادیر بالای TDS ضعیف تر بوده و انحراف بیشتری از مقدار واقعی پیدا می‌کند. تحلیل حساسیت روش‌ها نشان داد که به ترتیب پارامترهای غلظت یون سدیم، کلر، سولفات، کلسیم و منیزیم و میزان دبی بر مقدار شوری تاثیرگذار بوده و اثر غلظت یون بی‌کربنات و pH قابل صرف نظر کردن است. علاوه بر دقت بالاتر، عدم نیاز به استفاده از رویکرد سعی و خطا جهت یافتن ساختار بهینه و در نتیجه سرعت اجرای بیشتر، از دیگر برتری‌های روش SVM نسبت به روش RBFN می‌باشد.

۶. مراجع

۱. کرمی م.، کاشفی پور م.، معاضد ه.، فروغی ح.، (۱۳۸۵)، "پیش‌بینی کیفیت آب رودخانه کارون با استفاده از شبکه‌های عصبی مصنوعی"، هفتمین سمینار بین‌المللی مهندسی رودخانه‌ها
۲. بختیاری م.، کاشفی پور م.، عزیزی مبصر ج.، (۱۳۸۶)، "استفاده از شبکه‌های عصبی در ارزیابی کیفی رودخانه کرخه"، ششمین کنفرانس هیدرولیک ایران
3. Huang W., Foo S., (2002), "Neural Network Modelling of Salinity Variation in Apalachicola River", Water Research, 36:356-362
4. Mitchell T. M., (1997), "Machine Learning", McGraw-Hill
5. Riverol-Canizares C., Pilipovik V., (2010), "The Use of Radial Basis Function Networks (RBFN) to Predict Critical Water Parameters in Desalination Plants", Expert Systems with Applications
6. May D. B., Sivakumar M., (2009), "Prediction of Urban Storm water Quality Using Artificial Neural Networks", Environmental Modelling & Software, 24:296-302
7. Palani S., Liong S. Y., Tkalich P., (2008), "An ANN Application for Water Quality Forecasting", Journal of Marine Pollution Bulletin
۸. فردی غ. ا.، تکلیفی ا.، قنبری ع.، (۱۳۸۸)، "استفاده از روش شبکه عصبی مصنوعی در پیش‌بینی مقادیر TDS در رودخانه تلخه‌رود"، سومین همایش تخصصی مهندسی محیط زیست
۹. نوشادی م.، احمدزاده م.، سالمی ح. ر.، (۱۳۸۵)، "شبیه‌سازی و پیش‌بینی برخی از پارامترهای کیفیت آب رودخانه زاینده‌رود با استفاده از شبکه‌های عصبی مصنوعی"، اولین همایش منطقه‌ای بهره‌برداری از منابع آب حوضه‌های کارون و زاینده‌رود (فرصت‌ها و چالش‌ها)
10. Haykin S., (1999), "Neural Networks, A Comprehensive Foundation", Second Edition, Prentice Hall
11. Vapnik V. N., (1995), "The Nature of Statistical Learning Theory", NY:Springer-Verlag
12. Goel A., (2009), "Application of SVMs Algorithms for Prediction of Evaporation in Reservoirs", World Environmental and Water Resources Congress 2009: Great Rivers
13. Smola A. J., (1996), "Regression Estimation with Support Vector Learning Machines", Master's Thesis, Technische Universitat Munchen, Germany
14. Leunberger D., (1984), "Linear and Nonlinear Programming", Addison-Wesley