



بکارگیری مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و ماشین بردار پشتیبان در پیش-بینی بار رسوب معلق آجی چای

وحید نورانی، استاد، دانشکده مهندسی عمران دانشگاه تبریز، تبریز، ایران

غلامرضا عندلیب (نویسنده مسئول)، دانشجوی دکتری سازه‌های هیدرولیکی دانشکده مهندسی عمران دانشگاه تبریز، تبریز، ایران

Gholamreza.andalib@gmail.com

چکیده

شبیه‌سازی و ارزیابی رسوب رودخانه و ایجاد ارتباط بین دبی جریان و رسوب از جمله مسائل مهم و کاربردی در مدیریت منابع آب و محیط زیست در استفاده از مخازن سدها، سامان‌دهی رودخانه‌ها و عاملی برای جلوگیری از هزینه اضافی است. در این تحقیق، از تابع موجک به عنوان یکی از ابزارهای محاسبات نرم جهت استخراج ویژگی‌های سری‌های زمانی استفاده گردیده و کارایی مدل‌های موجک-ماشین بردار پشتیبان و موجک- شبکه عصبی مصنوعی برای پیش‌بینی رسوب در رودخانه‌ی آجی چای مورد بررسی قرار گرفته است. برای این منظور، در گام اول مقدار رسوب توسط ماشین بردار پشتیبان و شبکه عصبی مصنوعی پیش‌بینی شده است. سپس سری‌های زمانی دبی و رسوب توسط موجک به زیر سری‌هایی تجزیه شدند و این زیر سری‌ها جهت شبیه‌سازی رابطه دبی-رسوب وارد ماشین بردار پشتیبان و شبکه عصبی مصنوعی شدند. نتایج پیش‌بینی رسوب ماهانه نشان می‌دهند که ماشین بردار پشتیبان با ضریب تبیین $DC=0/65$ خروجی بهتری نسبت به شبکه عصبی مصنوعی $DC=0/61$ دارد. مدل موجک-ماشین بردار پشتیبان نتایج بهتری در مقایسه با مدل موجک- شبکه عصبی مصنوعی نشان می‌دهد و اضافه کردن موجک باعث افزایش دقت مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی می‌شود، برای نمونه $DC_{SVM}=0/65$ به $DC_{WSVM}=0/82$ ارتقاء یافته است.

کلمات کلیدی: پیش‌بینی رسوب، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، تبدیل موجک، آجی چای.



Application of Hybrid Wavelet-SVM and ANN in the Prediction of Suspended Sediment Load of Aji-chay

Vahid Nourani, Department of Water and Hydraulic Structures, Faculty of Civil Engineering, Tabriz University

Gholamreza Andalib (Corresponding Author), Department of Water and Hydraulic Structures, Faculty of Civil Engineering, Tabriz University
Gholamreza.andalib@gmail.com

Abstract

Simulation and evaluation of sediment and extending the relation among streamflow and sediment is an important and applicable issue in the water resource management which is useful in the organizing reservoirs, rivers and avoiding additional costs. In this paper, the efficiency of Wavelet-based Support Vector Machine (WSVM) model was examined for prediction of monthly Suspended Sediment Load (SSL) of the Aji-Chay River. Then for this purpose, at first step, SSL was predicted via ad hoc SVM and Artificial Neural Network (ANN) models. Therefore in the hybrid models, streamflow and SSL time series were decomposed into sub-signals via wavelet transform, and these decomposed subseries were imposed into SVM and ANN to simulate discharge-SSL relationship. The results showed that SVM yield to better outcomes with Determination Coefficient (DC)= 0.65 than ad hoc ANN with DC=0.61. On the other hand, WSVM showed better consequences than wavelet-based ANN (WANN) model in monthly SSL prediction, and wavelet data pre-processing could lead to catch more accurate results, e.g., $DC_{LSSVM}=0.65$ was increased to the $DC_{WLSSVM}=0.82$.

Keywords: Prediction of Sediment, Artificial Neural network, Support Vector Machine, Wavelet, Aji Chay.



۱- مقدمه

عملیاتی به جای مینیمم کردن خطای مدل سازی تبعیت می کند و شامل حل مسأله برنامه ریزی درجه دو است. کاربرد این روش به طور کلی در چند سال اخیر در زمینه های مختلف هیدرولوژیکی دارای پاسخ مناسبی بوده است.

اما در مطالعه ی رسوب حوضه ها، مدل ماشین بردار پشتیبان در چند سال اخیر به طور محدودی مورد استفاده قرار گرفته است. [۵] به منظور پیش بینی غلظت رسوب معلق از مدل ماشین بردار پشتیبان با کرنل گوسی استفاده کرد. نتایج این مطالعه نشان داد مدل ماشین بردار پشتیبان می تواند بار رسوب را بدون ایجاد مقادیر منفی پیش بینی نماید [۶] از مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای پیش بینی بار رسوب معلق رودخانه کائوپینگ تایوان استفاده کردند و نتیجه گرفتند که مدل ماشین بردار پشتیبان از توانایی بیشتری نسبت به مدل شبکه عصبی مصنوعی برخوردار است. [۷] از مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای پیش بینی بار معلق روزانه رسوب بهره بردند.

با وجود قابلیت های شبکه های عصبی مصنوعی و ماشین های بردار پشتیبان در مدل سازی سری های زمانی گاه به دلیل وجود نوسانات فراوان در سری زمانی که موجب ناپایداری آن می گردد و نیز به دلیل تأثیرات مقیاس های زمانی متفاوت از یک روز تا چندین دهه، کاستی ها و مشکلاتی در مدل سازی سری زمانی با روش های یاد شده به وجود می آید. در چنین شرایطی شبکه های عصبی مصنوعی و ماشین های بردار پشتیبان قادر به مدل سازی مناسب سری های زمانی ناپایستا نمی باشند؛ بنابراین بهره گیری از تکنیک پیش پردازش تبدیل موجک موجب دستیابی به مدلی دقیق تر از سری های زمانی ناپایستا همچون سری رواناب- رسوب می گردد [۸].

مدل ترکیبی موجک- شبکه عصبی (WANN) نخستین بار توسط توسط [۹] برای پیش بینی سری زمانی به کار گرفته شد. تحت یک مقاله جامع مروری به بررسی کاربردی انواع مدل های ترکیبی هوش مصنوعی- موجک

نیاز به مدل سازی دقیق میزان رسوب معلق با توجه به اهمیت آن در پر شدن مخازن سدها، تغییر مسیر رودخانه ها، کاهش ظرفیت آبگذری کانال ها و تأسیسات انتقال آب، در طول دهه های گذشته به طور چشمگیری افزایش یافته است. به دلیل ماهیت استوکستیک این فرآیند، مدل های زیادی به منظور تعریف چنین پدیده پیچیده ای توسعه یافته اند. با توجه به وجود روابط غیر خطی و عدم قطعیت در پدیده رسوب رودخانه ها و ویژگی های متغیر زمانی و مکانی، مدل های آماری و مفهومی کلاسیک در الگوسازی رسوب رودخانه ها دارای نواقص و ضعف هایی می باشند. امروزه، مدل های جعبه سیاه، به عنوان یک تابع تخمینگر خودسازمانده، به طور گسترده ای در مدل سازی و پیش بینی سری های زمانی غیر خطی در فرآیندهای هیدرولوژیکی مورد استفاده قرار گرفته است [۱]. [۲] نشان دادند که شبکه های عصبی مصنوعی (ANN) روش بهتری برای تخمین بار معلق رسوب ارائه می دهند. [۳] برای مدل سازی توزیع جزئی بار رسوب معلق، دو مدل شبکه عصبی را گسترش دادند. در مدل اول، یک مدل شبکه عصبی یکپارچه که به وسیله ی داده های چندین ایستگاه درون حوضه آموزش یافته بود، بررسی شد و مدل دوم یک مدل شبکه عصبی مبنی بر ژئومورفولوژی ارائه کردند که در آن پارامترهای ژئومورفولوژی وابسته به مکان زیر حوضه ها و همراه با داده های هواشناسی وابسته به زمان به شبکه عصبی اعمال شدند. نتایج به دست آمده نشان می دادند که اگرچه سری زمانی بار رسوب معلق پیش بینی شده با استفاده از هر دو مدل با داده های مشاهده شده همخوانی خوبی داشته، مدل ژئومورفولوژیکال شبکه عصبی به دلیل استفاده از عوامل متغیر مکانی به عنوان ورودی مدل، عملکرد بهتری دارد. اخیراً علاوه بر روش شبکه عصبی مصنوعی از یک مدل مبتنی بر داده دیگر موسوم به ماشین بردار پشتیبان (SVM) نیز برای مدل سازی فرآیندهای هیدرولوژیکی از جمله در مدل سازی رسوب استفاده می شود. ماشین بردار پشتیبان به عنوان ابزاری قدرتمند برای رگرسیون ابتدا توسط [۴] مطرح گردید. مدل ماشین بردار پشتیبان از اصل مینیمم کردن ریسک



۲- مواد و روش

۲-۱- ماشین بردار پشتیبان

ماشین بردار پشتیبان الگوریتمی است که نوع خاصی از مدل های خطی را می یابد که حداکثر حاشیه ابر صفحه را حاصل می کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین دسته ها می شود. به نزدیک ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می گردد [۴]. تنها از این بردارها برای مشخص کردن مرز بین دسته ها استفاده می شود. قواعد تصمیم گیری که تعریف می شود و توسط یک صفحه بهینه که طبقات تصمیم گیری باینری را تفکیک می کند، به صورت رابطه (۱) است [۴]:

$$y = \text{sign} \left(\sum_{i=1}^N y_i \alpha_i (X X_i) + b \right) \quad (1)$$

که در آن γ خروجی معادله، y_i ارزش طبقه نمونه آموزشی X_i و X نشان دهنده ضرب داخلی است. بردارهای $X = (X_1, X_2, \dots, X_n)$ نشان دهنده یک داده ورودی و بردارهای X_i بردارهای پشتیبان هستند. اگر داده ها به صورت خطی قابل تفکیک نباشند، معادله بالا به معادله (۲) تغییر می یابد [۴].

$$y = \text{sign} \left(\sum_{i=1}^N y_i \alpha_i K(X X_i) + b \right) \quad (2)$$

تابع $K(X, X_i)$ تابع کرنلی است که برای ایجاد ماشین های با انواع مختلفی از سطوح تصمیم گیری غیر خطی در فضای داده ها، ضرب های داخلی تولید می کند. در رابطه (۳) مدل ریاضی تابع خطا ارائه شده است [۴]:

$$L(y, f(x)) = |y - f(x)|_{\varepsilon} = \begin{cases} 0 & \text{if } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{otherwise} \end{cases} \quad (3)$$

نهایتاً مسئله کمینه سازی خطای هموار شده پس از تبدیل به یک تابع کمینه ساز و ساخت عبارت لاگرانژی مورد نظر به یک مسئله بهینه سازی مقید محدب تبدیل

در هیدرولوژی پرداخته اند. [۱۰]. [۱۱] برای پیش بینی رسوب رودخانه پوتومک در آمریکا از مدل ترکیبی موجک شبکه عصبی مصنوعی بهره گرفتند. بر اساس تحقیقات موجود، در مورد استفاده از مدل ترکیبی ماشین بردار پشتیبان (WSVM) برای برآورد رسوب هیچ مطالعه ای صورت نگرفته است، اما در چند مطالعه توانایی مدل موجک ماشین بردار پشتیبان برای مدل سازی پدیده های هیدرولوژیکی گزارش شده است. مدل موجک ماشین بردار پشتیبان برای پیش بینی جریان رودخانه های کاناک دره و گوک سو دره استفاده شد و نشان داد که مدل موجک ماشین بردار پشتیبان می تواند دقت مدل ماشین بردار پشتیبان را در پیش بینی جریان ماهانه تقویت کند [۱۲]. هر دو مدل موجک ماشین بردار پشتیبان و موجک شبکه عصبی مصنوعی برای پیش بینی جریان رودخانه به صورت ماهانه به کار گرفته شد [۱۳]، مقایسه نتایج نشان داد که مدل های ترکیبی موجک شبکه عصبی مصنوعی و موجک ماشین بردار پشتیبان پیش بینی های دقیق تری از مدل های ساده شبکه عصبی مصنوعی و ماشین بردار پشتیبان دارند. با این حال، مشخص شد که مدل موجک ماشین بردار پشتیبان نتایج پیش بینی بهتری از مدل موجک شبکه عصبی مصنوعی فراهم می کند. در این تحقیق پیش بینی رسوب با استفاده از مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان و همچنین تأثیر موجک بر روی مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان بررسی شده است. برای رسیدن به این هدف، سری های زمانی رواناب و رسوب رودخانه آجی چای در مقیاس ماهانه توسط موجک های متفاوت در سطوح مختلف به زیر سری های جزء تجزیه شده اند. سپس زیر سری های تجزیه شده توسط مادر موجک ها جهت ارتقای دقت پیش بینی رسوب وارد مدل های شبکه عصبی مصنوعی و ماشین بردار پشتیبان شده اند. مدل های ارائه شده نیز با مدل های ساده شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقایسه شده اند.



این دلیل شبکه پیشرو نامیده می شود که چگونگی ارتباط میان نرون‌ها به گونه‌ای است که از لایه ورودی به لایه مخفی و از این لایه به لایه خروجی اتصال می‌یابند و درون یک لایه نیز نرون‌ها به یکدیگر ارتباط پیدا نمی‌کنند [۱۴].

۲-۳- تبدیل موجک

در اکثر کاربردهای عملی فرآیندهای هیدرولوژی سری زمانی دارای حالت گسسته می‌باشد بنابراین حالت موجک گسسته به صورت رابطه (۶) بیان می‌شود [۱۵]:

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g^* \left(\frac{t - nb_0 a_0^m}{a_0^m} \right) \quad (6)$$

در رابطه فوق m و n اعداد صحیح هستند که به ترتیب میزان مقیاس و انتقال موجک را کنترل می‌نمایند. همچنین a_0 گام مقیاس کوچک ویژه برای پارامتر انتقال $(1 < a_0)$ و $(0 < b_0)$ پارامتر انتقال موقعیت می‌باشند. معمولی‌ترین حالت برای پارامترهای رابطه (۶) مقادیر $a_0 = 2$ و $b_0 = 1$ هستند که این مقیاس لگاریتمی با توان دو برای انتقال و مقیاس تحت عنوان آرایش شبکه دوتایی نامیده می‌شود.

۲-۴- مطالعه موردی

داده‌های مورد استفاده در آن تحقیق از ایستگاه هیدرومتری ارزق در حوضه‌ی آبی‌چای واقع در استان آذربایجان شرقی ایران می‌باشد (شکل ۱)، که طول داده‌ها ۱۴۴ ماه، از ۱۳۷۹ تا ۱۳۹۱ می‌باشد. این حوضه با وسعتی معادل ۱۰۲۴۶ کیلومتر مربع در محدوده 30° - 45° تا 45° - 47° طول شرقی و 45° - 37° تا 30° - 38° عرض شمالی گسترده شده است و بیش از ۲۵ درصد مساحت کل حوضه آبریز دریاچه ارومیه را می‌پوشاند. به منظور آموزش و صحت‌سنجی مدل، داده‌ها به دو قسمت تقسیم شده‌اند: ۷۵ درصد اول داده‌ها به‌عنوان داده‌های آموزش و ۲۵ درصد باقی داده‌ها به‌عنوان داده‌های آزمایش انتخاب شده‌اند.

می‌گردد که با میل دادن مشتقات جزئی آن نسبت به متغیرهای تصمیم قابل حل است.

$$\text{subject to : } \sum_{i=1}^N (\alpha_i^* - \alpha_i) = 0 \quad (4)$$

$$\max \left\{ \begin{array}{l} -\frac{1}{2} \sum_{j=1}^m (\alpha_i^* - \alpha_i) (\alpha_i^* - \alpha_i) \langle x_i, x_j \rangle \\ -\varepsilon \sum_{i=1}^m (\alpha_i^* - \alpha_i) + \sum_{i=1}^N \nu_i (\alpha_i^* - \alpha_i) \end{array} \right\}$$


با توجه به اینکه در مسائل که دارای رگرسیون عموماً با مسائل غیر خطی مواجه هستیم بایستی روش حل را برای حالت غیر خطی نیز تعمیم دهیم. به این منظور از تابع کرنل گوسی نتایج مناسبی در مسائل مدیریت منابع آب بوده استفاده می‌کنیم. این تابع به صورت رابطه (۵) تعریف می‌شود [۴]:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\delta^2}\right) \quad (5)$$

بنابراین کافی است در مسائل غیر خطی از کرنل مقادیر ورودی به جای خود تابع استفاده کنیم.

۲-۲- شبکه عصبی مصنوعی

شبکه‌های عصبی توانایی شناخت یک سیستم غیرخطی دینامیکی بدون داشتن هیچگونه پیش فرض در فرآیند مدل‌سازی را دارا می‌باشند. معماری شبکه‌های عصبی در اکثر مسائل مهندسی پیش‌بینی کننده از یک سیستم و ساختار سه لایه‌ای تشکیل یافته که شامل لایه ورودی، لایه مخفی و لایه خروجی می‌باشد. در این ساختار لایه ورودی نخست به پردازش داده‌های ورودی برای انتقال به لایه مخفی می‌پردازد، سپس لایه مخفی قبل از ارسال اطلاعات به لایه خروجی با استفاده از توابع انتقال تانژانت هایپربولیک یا تابع منطقی به محاسبه ضرایب وزن مناسب می‌پردازد. ساختار سه لایه شبکه بر پایه ترکیب خطی از متغیرهای ورودی است که با یک تابع محرک غیرخطی تبدیل می‌یابد. این ساختار از شبکه به



شکل ۱: موقعیت حوضه مورد مطالعه در سطح کشور و منطقه

۲-۵- معیار کارایی

نیاز به هماهنگی بین محدوده‌ی داده‌های شبکه با توابع محرکی که مورد استفاده قرار می‌گیرد باعث می‌شود که داده‌ها در محدوده‌ی توابع محرک نرمال شوند. با توجه به اینکه برد این تابع بین منفی یک و یک است، بایستی داده‌های خروجی در این محدوده نرمال‌سازی شوند. برای این کار از رابطه (۷) استفاده شده است [۱۴]:

$$X_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

در این رابطه X_i داده‌ی ورودی و X_{\min} و X_{\max} به ترتیب حداقل و حداکثر داده‌های ورودی می‌باشند. یک مدل مناسب نتایج قابل قبولی از نظر ضریب تبیین DC در مراحل آموزش و صحت‌سنجی نشان می‌دهد؛ بنابراین برای ارزیابی کارایی مدل، رابطه (۸) جهت مقایسه‌ی عملکرد مدل‌های مختلف ارائه شده است [۱۴]:

$$DC = 1 - \frac{\sum_{i=1}^N (O_{obs_i} - O_{com_i})^2}{\sum_{i=1}^N (O_{obs_i} - \bar{O}_{obs})^2} \quad (8)$$

در این روابط N ، O_{obs_i} ، O_{com_i} و \bar{O}_{obs} به ترتیب تعداد مشاهدات، داده‌های مشاهداتی، داده‌های محاسباتی و میانگین داده‌های مشاهداتی است. DC معیاری است که برای تعیین دقت تخمین مدل، با مقایسه‌ی داده‌های مشاهداتی و محاسباتی کاربرد دارد.

۳- بحث و نتایج

پیش از انجام پیش‌پردازش داده‌ها، ابتدا پیش‌بینی رسوب ماهانه‌ی با استفاده از ماشین بردار پشتیبان و شبکه عصبی مصنوعی ساده صورت گرفته است. تمامی مدل‌ها با استفاده از داده‌های کالیبراسیون، آموزش داده شده و با استفاده از داده‌های آزمایش، صحت‌سنجی می‌شوند. در این تحقیق از الگوریتم ماشین بردار پشتیبان از نوع حاشیه نرم که برای حالت غیرخطی تعمیم‌یافته است و قابلیت استفاده در بسیاری از فرآیندهای مهندسی آب از جمله پدیده رسوب را دارد، استفاده شده است. ماشین‌های بردار پشتیبان به‌جای اینکه خطای مدل‌سازی یا طبقه‌بندی را کمینه کند، در مقابل ریسک عملیاتی را به‌عنوان تابع هدف در نظر می‌گیرد و مقدار بهینه آن را محاسبه می‌کند. برای انتخاب بهترین ورودی برای ماشین بردار پشتیبان و شبکه عصبی مصنوعی، ۴ ترکیب ورودی انتخاب گردیده است و این امر برای پیدا کردن میزان وابستگی رسوب یک ماه آینده‌ی ایستگاه ارزقنق به چند ماه قبل با استفاده از داده‌های بدون پیش‌پردازش انجام گردیده است. ترکیب ورودی‌ها به‌صورت زیر است:

Comb. 1: SSL_{t-1}

Comb. 2: Q_{t-1}

Comb. 3: SSL_{t-1}, Q_{t-1}

البته برای پیش‌بینی رسوب ماهانه، یک ترکیب اضافی نیز به‌عنوان ورودی در نظر گرفته شده است که در این



ترکیب رسوب یک ماه آینده به یک و دوازده ماه قبل ربط داده شده است زیرا معمولاً در پدیده‌ی رسوب ماهانه برای مثال رسوب فروردین ماه امسال وابستگی بیشتری به رسوب همین ماه در سال قبل دارد تا ماه‌های دیگر:

ترکیب رسوب یک ماه آینده به یک و دوازده ماه قبل ربط داده شده است زیرا معمولاً در پدیده‌ی رسوب ماهانه برای مثال رسوب فروردین ماه امسال وابستگی بیشتری به رسوب همین ماه در سال قبل دارد تا ماه‌های دیگر:

Comb. 4: SSL_{t-1} , SSL_{t-12} , Q_{t-1} , Q_{t-12}

$$DL = \text{int}[\text{Log}(N)] \quad (9)$$

برای پیش‌بینی رسوب ماهانه، نتایج مندرج در جدول ۱ نشان می‌دهد که بهترین DC در قسمت داده‌های آزمایش، در مدل ماشین بردار پشتیبان، ۰/۶۵ می‌باشد که مربوط به حالتی است که رسوب این ماه، به یک و ۱۲ ماه قبل وابسته است. در مدل شبکه عصبی مصنوعی این حوضه نیز، بهترین DC در قسمت داده‌های آزمایش، ۰/۶۱ می‌باشد. Comb. 4 به خاطر در نظر گرفتن خاصیت فصلی بودن داده‌ها علاوه بر خاصیت خودهمبستگی نتایج بهتری نسبت به دیگر ورودی‌ها از خود نشان داد.

نتایج نشان می‌دهد که بر اساس معیار سنجه DC، مادر موجک db2 با سطح تفکیک‌پذیری ۲ عملکرد بهتری نسبت به db های دیگر در سطوح متفاوت دارد (شکل ۲). عملکرد بهتر موجک db2 شاید ناشی از فرم موجک آن باشد که تطابق خوبی به ترتیب با سری‌های زمانی ماهانه رودخانه آجی چای دارد. در مدل‌های ترکیبی موجک ماشین بردار پشتیبان و موجک شبکه عصبی مصنوعی نتایج حاکی از آن است که در پیش‌بینی رسوب ماهانه نوع مادر موجک و سطح تفکیک نقش بسزایی دارند به‌طوری‌که دامنه تغییر معیار سنجه DC در آجی چای با تغییر این پارامترها در موجک ماشین بردار پشتیبان از ۰/۵ تا ۰/۸۲ و در موجک شبکه عصبی مصنوعی از ۰/۴۵ تا ۰/۸۱ می‌باشد. ضمناً مدل موجک ماشین بردار پشتیبان عملکرد بهتری نسبت به موجک شبکه عصبی مصنوعی دارد (شکل ۲). سری‌های زمانی مشاهداتی و محاسباتی پیش‌بینی رسوب حوضه آجی-چای برای مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان، موجک شبکه عصبی مصنوعی و موجک ماشین بردار پشتیبان در شکل ۳ مشاهده می‌گردد.

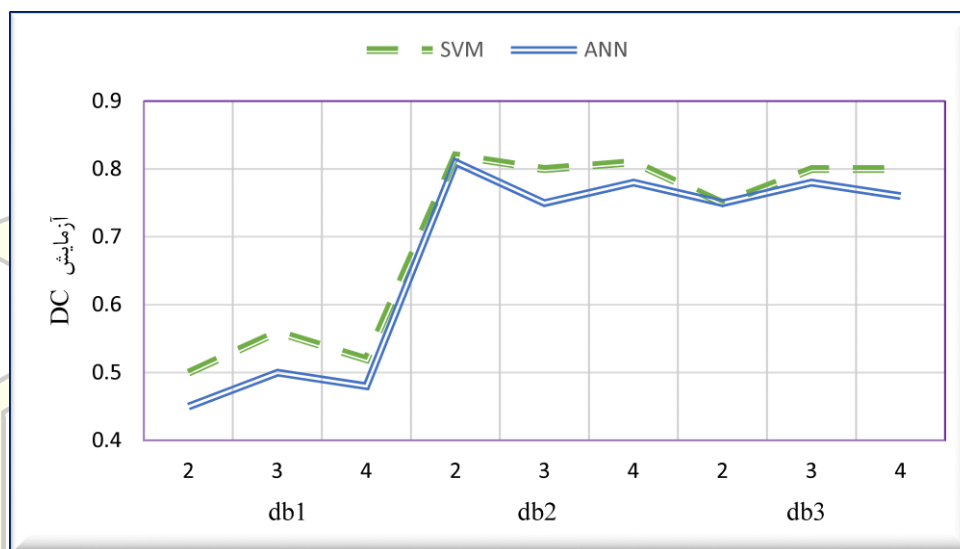
مدل ترکیبی هوش مصنوعی موجکی برای ترکیب همزمان توانایی‌های مدل‌های هوش مصنوعی (همچون ماشین بردار پشتیبان، شبکه عصبی مصنوعی) و آنالیز موجک در یک ساختار واحد برای پیش‌بینی رسوب طراحی گردیده است. در این مدل پیش‌پردازش داده‌ها توسط تبدیل موجک انجام گرفته و سپس نتایج این پردازش به‌عنوان ورودی در مدل‌های هوش مصنوعی استفاده می‌گردد. گزینش مادر موجک منطقی چالشی مهم در مسئله مدل ترکیبی هوش مصنوعی موجکی است که می‌تواند تأثیر قابل توجهی در نتایج مدل‌سازی داشته باشد. ماهیت مادر موجک، کشف شباهت میان سری زمانی تحلیل شده و نمونه موجک مستعمل می‌باشد. بدین منظور، موجک‌های خانواده‌ی دوپچی

مدل ترکیبی هوش مصنوعی موجکی برای ترکیب همزمان توانایی‌های مدل‌های هوش مصنوعی (همچون ماشین بردار پشتیبان، شبکه عصبی مصنوعی) و آنالیز موجک در یک ساختار واحد برای پیش‌بینی رسوب طراحی گردیده است. در این مدل پیش‌پردازش داده‌ها توسط تبدیل موجک انجام گرفته و سپس نتایج این پردازش به‌عنوان ورودی در مدل‌های هوش مصنوعی استفاده می‌گردد. گزینش مادر موجک منطقی چالشی مهم در مسئله مدل ترکیبی هوش مصنوعی موجکی است که می‌تواند تأثیر قابل توجهی در نتایج مدل‌سازی داشته باشد. ماهیت مادر موجک، کشف شباهت میان سری زمانی تحلیل شده و نمونه موجک مستعمل می‌باشد. بدین منظور، موجک‌های خانواده‌ی دوپچی

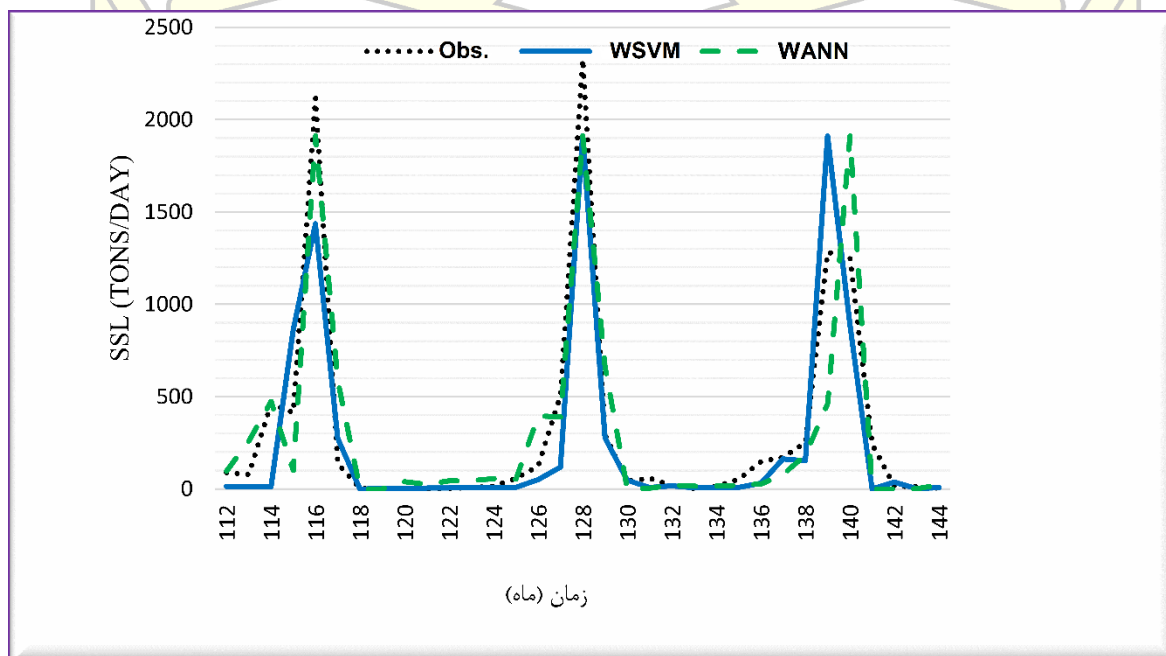


جدول ۱: نتایج مدل‌ها برای پیش‌بینی رسوب

مدل		SVM(Comb. 4)	ANN (Comb. 4)	WSVM(db2, DL2)	WANN (db2, DL2)
DC	آموزش	0.7	0.68	0.82	0.82
	آزمایش	0.65	0.61	0.82	0.81



شکل ۲: ارزیابی موجک های مادر با درجات تجزیه متفاوت در مدل هوش مصنوعی- موجکی حوضه آبی چای (مرحله آزمایش)



شکل ۳: مقادیر محاسباتی و مشاهداتی برای بخش صحت سنجی رسوب ماهانه آبی چای



۴- جمع بندی و نتیجه گیری

رسوب یکی از مهم ترین پارامترهای کیفیت آب است که به طور مستقیم شفافیت آب، کدورت و رنگ آب و غیره را تحت تأثیر قرار می دهد و همچنین طراحی و مدیریت سیستم های منابع آب و سازه های آبی را تحت تأثیر قرار می دهد. با توجه به اهمیت رسوب به عنوان یک پدیده پیچیده، استفاده از مدل های هوشمند جعبه سیاه مانند ماشین بردار پشتیبان می تواند به برآورد دقیق تر رسوب منجر شود. مدل ماشین بردار پشتیبان برای پیش بینی رسوب رودخانه آجی چای در مقیاس زمانی ماهانه استفاده شده است. همچنین، توانایی مدل ماشین بردار پشتیبان در مقایسه با مدل شبکه عصبی مصنوعی مورد سنجش قرار گرفت و در نهایت اثر تبدیل موجک به عنوان مدل پیشنهادی ترکیبی موجک ماشین بردار پشتیبان مورد بررسی قرار گرفت. ورودی های بهینه از طریق آنالیز حساسیت برای مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی بر اساس خاصیت مارکوفین مقیاس ماهانه تعیین گردیدند. نتایج نشان می دهند که در سری های زمانی ماهانه ماشین بردار پشتیبان نتایج کمی بهتر نسبت به شبکه عصبی مصنوعی دارد. به منظور ارتقاء کارایی مدل و در نظر گرفتن اثرات فصلی بودن تبدیل موجک که دارای توانایی تشخیص ویژگی های چندگانه مقیاسی سری های زمانی می باشد جهت تفکیک سری های زمانی روناب-رسوب به زیر سری های متفاوت استفاده شده است. سپس زیر سری ها به عنوان ورودی برای پیش بینی رسوب ماهانه در مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی استفاده شده اند. مدل های ترکیبی موجک شبکه عصبی مصنوعی و موجک ماشین بردار پشتیبان منجر به بهبود مدل سازی روناب-رسوب در مقایسه با مدل های ماشین بردار پشتیبان و شبکه عصبی مصنوعی ساده شدند برای نمونه میزان پیشرفت موجک ماشین بردار پشتیبان و موجک شبکه عصبی مصنوعی در ایستگاه ارزنق آجی چای برترتیب ۲۶٪ و ۳۲٪ می باشد. همچنین ذکر این نکته

ضروری است که تعویض مادر موجک و سطح تجزیه در پیش بینی رسوب ماهانه در هر دو مدل موجک شبکه عصبی مصنوعی و موجک ماشین بردار پشتیبان تأثیر بسزایی داشت.

۵- پیشنهادات

با توجه به اینکه در این پژوهش مجال پرداختن به تمامی مسائل مربوطه به هوش مصنوعی وجود ندارد پیشنهاد می شود در تحقیقات آتی، قابلیت و کارایی انواع دیگر ساختارهای موجک-هوش مصنوعی در مقایسه با مدل موجک ماشین بردار پشتیبان در مدل سازی روناب-رسوب و همچنین بخاطر وجود نویز در داده ها، تأثیر دینویز در مدل ماشین بردار پشتیبان مورد ارزیابی قرار گیرد. همچنین جهت توسعه و کامل شدن مدل ها می توان اثر اضافه شدن سایر متغیرهای هیدرولوژیکی همچون تبخیر، دما و ... در کنار متغیرهای مطرح شده در این پژوهش را مورد مطالعه و بررسی قرار داد. کاربرد مدل های ترکیبی طراحی شده و ارزیابی کارایی آن ها برای پیش بینی های چند ایستگاهی و همچنین سایر سری های زمانی در مهندسی عمران نیز می تواند به عنوان یک پژوهش مناسب مطرح گردد. در این راستا پیشنهاد می شود که از مدل های یاد شده در زمینه مدل سازی سایر پدیده های هیدرولوژیکی همانند خشکسالی، آب های زیرزمینی و ... استفاده نمود.

۶- تقدیر و تشکر

نگارندگان از سازمان آب منطقه ای آذربایجان شرقی که ما را در تهیه این مقاله یاری نمودند، کمال تقدیر و تشکر را دارند.



۷-مراجع

1. Hart, R.J., Anctil, F., Coulibaly, P., Dawson, C.W., Mount, N.J., See, L.M., Shamseldin, A.Y., Solomatine, D.P., Toth, E. and Wilby, R.L. (2012), "Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting," *Progress in Physical Geography*, 36, pp 480-513.
2. Jain, A.K., Murty, M.N. and Flynn, P.J. (1999), "Data clustering: a review," *ACM Computing Surveys*, 31(3), pp 264-323.
3. Nourani, V., Kalantari, O., Baghanam, A.H. 2012. Two semi-distributed ANN-based models for estimation of suspended sediment load. *Journal of Hydrologic Engineering*, 17(12): 1368-1380.
4. Vapnik, V. and Cortes, C. (1995), "Support Vector Networks. *Machine Learning*, 20," pp 1-25.
5. Cimen, M. (2008), "Estimation of daily suspended sediments using support vector machines," *Hydrological Sciences Journal*, 53, pp 656-666.
6. Jie, L.C., Yu, S.T. (2011), "Suspended sediment load estimate using support vector machines in Kaoping River basin," *International Conference on Consumer Electronics, Communications and Networks (IEEE)*, XianNing, China, 16-18 April.
7. Kakaei, E., Moghddammia, A. and Ahmadi, A. (2013), "Daily suspended sediment load prediction using artificial neural networks and support vector machines," *Journal of Hydrology*, 478, pp 50-62.
8. Nason, G.P. and Von Sachs, R., (1999), "Wavelets in time series analysis," *Philosophical Transactions of the Royal Society*, 357, pp 2511-2526.
9. Aussem, A. and Murtagh, F. (1997), "Combining neural network forecasts on wavelet-transformed time series," *Connection Science*, 9, pp 113-121.
10. Nourani, V., Baghanam, A.H., Adamowski, J. and Kisi, O. (2014), "Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review," *Journal of Hydrology*, 514, pp 358-377.
11. Nourani, V., Baghanam, A.H., Yahyavi Rahimi, A. and Nejad, F.H., (2014), "Evaluation of wavelet-based de-noising approach in hydrological models linked to artificial neural networks," *Computational Intelligence Techniques in Earth and Environmental Sciences*. Springer Dordrecht Heidelberg NewYork London, pp 209-241.
12. Kisi, O. and Cimen, M. (2011), "A wavelet-support vector machine conjunction model for monthly streamflow forecasting," *Journal of Hydrology*, 399, pp 132-140.
13. Kalteh, A.M. (2013), "Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform," *Computers and Geosciences*, 54, pp 1-8.
14. Nourani, V. and Andalib, G. (2015), "Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches," *Journal of Mountain Science*, 12:85-100.
15. Nourani, V. and Andalib, G. (2015), "Wavelet based artificial intelligence approaches for prediction of hydrological time Series," In: Chalup, S.K., Blair A.D., Randall, M., (Eds.), *Artificial life and computational intelligence*. Springer International Publishing. Switzerland, 8955, 422-435.