

## مقاله پژوهشی

# برآورد غلظت رسوب رودخانه گرگانرود با روش‌های هوش مصنوعی

مهسا جوادی علی‌نژاد<sup>۱</sup>، سید مرتضی سیدیان<sup>۲\*</sup>، حامد روحانی<sup>۲</sup>، ابوالحسن فتح‌آبادی<sup>۲</sup>

تاریخ دریافت: ۹۷/۰۸/۲۳

تاریخ پذیرش: ۹۹/۰۲/۳۰

۱-دانش آموخته کارشناسی ارشد آبخیزداری دانشگاه گنبدکاووس

۲-استادیار گروه آبخیزداری دانشگاه گنبد کاووس

\*مسئول مکاتبات، پست الکترونیکی: s.m.seyedian@gmail.com

## چکیده

در سال‌های اخیر، هوش مصنوعی به‌طور گسترده و موفقیت‌آمیز در علوم مختلف استفاده شده است. در این پژوهش، کارایی روش‌های نروفازی، ماشین بردار پشتیبان و کمینه مربعات ماشین بردار پشتیبان به‌منظور تخمین غلظت رسوب در خروجی چهار حوضه آبخیز جنگله، نوده، ارازکوسه و قزاقلی واقع در رودخانه گرگانرود در استان گلستان بررسی شد. برای اجرای مدل‌ها از پنج ترکیب ورودی مختلف با تعداد متفاوت تأخیر جریان و بارش از صفر تا دو روز استفاده شد. نتایج نشان داد مدل کمینه مربعات ماشین بردار پشتیبان با روش جستجوی ساده شبیه‌سازی بهتری نسبت به روش جستجوی شبکه‌ای انجام می‌دهد. ارزیابی شاخص‌های آماری محاسبه شده نشان داد بهترین مدل شبیه‌ساز غلظت رسوب برای هر چهار حوضه مورد مطالعه مدل نروفازی است که مقدار خطای MEF در ایستگاه جنگله، نوده، ارازکوسه و قزاقلی به‌ترتیب برابر ۵/۳، ۱۳/۴، ۴/۸ و ۲/۸ درصد می‌باشد. به‌طور کلی در تمام ایستگاه‌ها به‌جز ایستگاه قزاقلی معرفی دبی جریان دو روز قبل به‌عنوان ورودی مدل باعث افزایش خطای پیش‌بینی می‌شود. علاوه بر آن بارندگی همان روز و روز قبل نیز فقط در ایستگاه ارازکوسه باعث افزایش دقت شده است.

**واژه‌های کلیدی:** انتقال رسوب، رودخانه گرگانرود، منحنی‌سنجه، هوش مصنوعی

## Estimation of Suspended Sediment Concentration in Gorganrood River Using Artificial Intelligence Methods

M Javadi Alinejad<sup>1</sup>, SM Seyedian<sup>2\*</sup>, H Rouhani<sup>2</sup>, Ab Fatabadi<sup>2</sup>

Received: November 14, 2018 Accepted: May 19, 2020

<sup>1</sup>M.Sc. Graduate Student of Watershed Management, Gonbad Kavous University, Gonbad, Iran

<sup>2</sup>Assist. Prof. Watershed Management Department, Gonbad Kavous University, Gonbad, Iran

\*Corresponding Author, Email: s.m.seyedian@gmail.com

### Abstract

Over the last years, artificial intelligence models have been widely and successfully applied in many fields. In the present study, the efficiency of adaptive neuro-fuzzy inference system (ANFIS), SVM (Support Vector Machine) and Least Squares Support Vector Machines (LS-SVM) have been investigated to estimate the sediment concentration in four gauging stations, namely Jangaldehy, Nodeh, Arazkoosh, and Gazaghly along the Gorganrood River in Golestan province, Iran. The models were defined based on the five different combinations of the river flow and precipitation using time lags from 0 to 2 previous days. The results showed that the LS-SVM model with simplex search procedure had a better performance than the grid search method. Meanwhile, the results obtained from ANFIS model which estimated sediment concentration in Jangaldehy, Nodeh, Arazkoose and Ghazaghli stations with MEF Error of 5.3, 13.4, 4.8 and 2.8 percent, respectively, suggested a higher performance than other models. Overall, at all stations except Gazaghly, considering the antecedent flow with two-day time lag as the input data of the model increased the error magnitudes. Furthermore, the rainfall of the same day and one-day time lag could only enhance the efficiency of the model at Arazkooseh station.

**Keywords:** Artificial intelligence, Gorganrood River, Ratig curve, Sediment transport

### مقدمه

کار پیچیده‌ای است (کیسی ۲۰۰۵). عوامل نامشخص زیادی در مدل‌سازی بار رسوب معلق رودخانه مؤثر هستند. به دلیل دشواری و هزینه‌بر بودن اندازه‌گیری مستقیم بار رسوب، استفاده از منحنی‌سنجه رسوب<sup>۲</sup> (SRC) به‌عنوان یک روش ساده و ارزان به‌منظور برآورد بار رسوب بسیار متداول است اما معمولاً منحنی‌سنجه، رسوب را کمتر از مقدار واقعی برآورد می‌کند (وروانی و خلیقی‌سیگارودی ۲۰۰۷، وروانی و همکاران ۲۰۰۸، آسلمن ۲۰۰۰ و تاسن و همکاران ۲۰۰۴). همچنین اعمال فاکتور تصحیح در روش منحنی‌سنجه، بار رسوب را به‌طور قابل توجهی بیشتر از مقدار واقعی برآورد می‌کند (کچ و اسمیلی ۱۹۸۶، والینگ و وب ۱۹۸۸). اثرات غیر خطی و متغیر داده‌های

برآورد حجم رسوبات حمل شده توسط رودخانه‌ها یک مسئله مهم در مهندسی منابع آب است. در اغلب رودخانه‌ها، بخش عمده رسوب انتقال یافته، رسوب معلق است. پیش‌بینی صحیح بار رسوبی به‌ویژه در مناطق سیل‌خیز دارای اهمیت است (یانگ ۱۹۹۶). انتقال رسوب در رودخانه‌ها به‌علت ایجاد آلودگی زیستگاه ماهی‌ها و تغییر کیفیت آب، کاهش قابلیت کشتیرانی، پر کردن مخازن، آسیب به تجهیزات برق‌آبی، مسائل زیبایی‌شناختی و غیره حائز اهمیت است (کوبنر و همکاران ۲۰۰۹). برآورد دقیق رسوبات معلق<sup>۱</sup> (SS) برای عملیات طراحی کانال‌ها، سدها و تأسیسات انحرافی نیز ضروری است. پیش‌بینی رسوبات معلق رودخانه به‌منظور استفاده در مهندسی منابع آب و هیدرولوژی

دادند شبکه عصبی مصنوعی دارای عملکرد بهتری برای پیش‌بینی بار رسوب معلق روزانه نسبت به SVM است. شارما و همکاران (۲۰۱۵) نشان دادند شبکه عصبی یک روش محاسباتی قوی است و SVM می‌تواند یک جایگزین مؤثر برای پیش‌بینی دقیق بار رسوب باشد.

احمدی و همکاران (۲۰۰۸)، رضایی‌بنفشه و همکاران (۲۰۱۳) و سیدیان و روحانی (۲۰۱۵) نشان دادند نروفازی<sup>۳</sup> قابلیت بهتری در تخمین بار رسوب معلق نسبت به مدل‌های رگرسیون خطی چندگانه و منحنی‌سنجه دارد. خورشیددوست و همکاران (۲۰۱۵) و کیسی (۲۰۰۵) نشان دادند مدل نروفازی انعطاف‌پذیری بیشتر و نیز تطابق بیشتری در تخمین بار رسوب نسبت به شبکه عصبی دارد. همچنین تحقیقات لوهانی و همکاران (۲۰۰۷)، (کیسی و همکاران ۲۰۰۶ و ۲۰۰۹)، (کوبنر و همکاران ۲۰۰۹)، اولک و همکاران (۲۰۰۹)، فیرات و گانگور (۲۰۱۰) و دمیرسی و بالتاسی (۲۰۱۳) نشان داد دقت مدل نروفازی نسبت به منحنی‌سنجه، شبکه عصبی و رگرسیون چند متغیره در تخمین بار رسوب معلق بیشتر است.

نورانی و عندلیب (۲۰۱۵) برای پیش‌بینی بار رسوب روزانه و ماهانه از مویک که براساس مدل کمینه مربعات ماشین بردار پشتیبان پایه‌ریزی شده است استفاده کردند. نتایج نشان داد که پیش‌بینی بار رسوبی معلق روزانه توسط LS-SVM نسبت به مدل ترکیبی با شبکه عصبی ارجحیت دارد. کومار و همکاران (۲۰۱۶) دقت چند مدل مختلف را برای پیش‌بینی بار رسوب مقایسه کردند و نشان دادند شبکه عصبی و کمینه مربعات ماشین بردار پشتیبان نتایج بهتری نسبت به مدل‌های دیگر ارائه می‌دهند.

مرور منابع نشان می‌دهد تحقیقات کمی دقت دو روش LS-SVM و SVM را در برآورد غلظت رسوب ارزیابی کرده‌اند. همچنین تحقیقات زیادی دقت روش

زیست‌محیطی و هیدرولوژیکی در طول دهه گذشته سبب توجه خاص به استفاده از روش‌های مختلف هوش مصنوعی در زمینه مهندسی محیط زیست و مدیریت منابع آب شده است. در تحقیقات زیادی از شبکه عصبی به‌منظور پیش‌بینی بار رسوب استفاده شده است (هالکی و همکاران ۲۰۱۸، سامانتارای و گوس ۲۰۱۸). روشنگر و حکیمی (۲۰۱۷) رسوب رودخانه قطور را با روش برنامه‌ریزی ژنتیک برآورد کردند. مطالعات متعدد سبب گسترش روزافزون روش‌های هوش مصنوعی برای مدل‌سازی فرآیندهایی شده که اطلاعات محدودی از آن‌ها وجود دارد (هی و همکاران ۲۰۱۱، مهسورن و خسا ۲۰۱۲). یکی از این روش‌ها، روش یادگیری ماشین بردار پشتیبان<sup>۱</sup> است که مبتنی بر نظریه یادگیری آماری است و خطاهای طبقه‌بندی داده‌های آموزش و داده‌های مجهول را به کمینه می‌رساند (اب ۲۰۱۰). حمزه‌آبادی و همکاران (۲۰۱۶) برای پیش‌بینی رواناب از ماشین بردار پشتیبان استفاده کردند. سیمن (۲۰۰۸) و نورانی و همکاران (۲۰۱۵) نشان دادند مدل SVM می‌تواند بار رسوب را با دقت قابل قبولی پیش‌بینی کند. ذونعمت و همکاران (۲۰۱۶) از شبکه عصبی و ماشین بردار پشتیبان برای پیش‌بینی بار رسوب معلق استفاده کردند و نشان دادند دقت این دو مدل از روش‌های معمول بیشتر است. همچنین از SVM برای شبیه‌سازی رواناب و بار رسوب روزانه، هفتگی و ماهانه در حوضه آبخیزی در هند استفاده شده است (میسرا و همکاران ۲۰۰۹). جی و یو (۲۰۱۱) نشان دادند ماشین بردار پشتیبان توانایی بیشتری در تخمین بار رسوب معلق نسبت به شبکه عصبی دارد. کیسی (۲۰۱۲) نشان داد که مدل کمینه مربعات ماشین بردار پشتیبان<sup>۲</sup> عملکرد بهتری نسبت به روش شبکه عصبی داشته و دو مدل LS-SVM و شبکه عصبی عملکرد بسیار بهتری نسبت به منحنی‌سنجه رسوب داشته‌اند. کاکائی‌لفدانی و همکاران (۲۰۱۳) نشان

3- Neuro-fuzzy (NF)

1- Support vector machine (SVM)

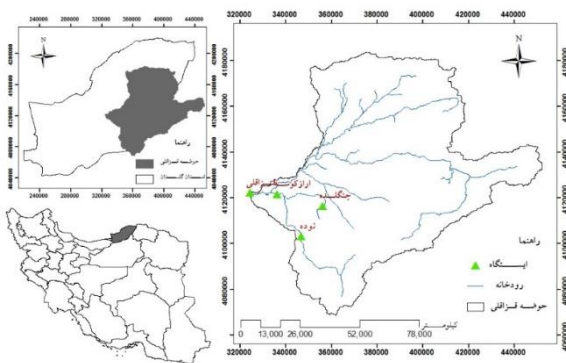
2- Least square support vector machine (LS-SVM)

### منحنی سنج رسوب

منحنی سنج رسوب به طور گسترده‌ای به عنوان یک روش تجربی برای ایجاد ارتباط بین غلظت رسوب معلق با دبی جریان استفاده می‌شود (کلبی ۱۹۵۶). به این ترتیب منحنی سنج سبب ایجاد ارتباط میان دو متغیر می‌شود که (Q) شاخص مستقل است (گلیسون ۱۹۸۷). تحقیقات زیادی در خصوص منحنی سنج صورت گرفته است که ارتباط دو متغیر را به صورت تابع توانی بیان می‌کند (تینیو ۲۰۱۵):

$$C = aQ^b \quad [1]$$

که در این رابطه C: غلظت رسوب ( $\text{mg L}^{-1}$ )، Q: دبی جریان ( $\text{m}^3 \text{s}^{-1}$ )، a و b: ضریب می‌باشند.



شکل ۱- موقعیت قرارگیری ایستگاه‌های مورد مطالعه در استان گلستان.

### سیستم نروفازی (NF)

سیستم نروفازی اولین بار در سال ۱۹۹۳ توسط جنگ معرفی شد. الگوریتم نروفازی، مدل‌های غیرخطی هستند که رابطه ورودی- خروجی یک سیستم واقعی را با استفاده از قوانین اگر-آنگاه فازی توصیف می‌کنند (جاکووین و شمس‌دین ۲۰۰۶). این مدل دارای پنج لایه است (اطلاعات بیشتر در منبع (معیری و همکاران ۲۰۱۰) وجود دارد).

نروفازی را در برآورد غلظت رسوب نشان داده‌اند. بنابراین با توجه به اهمیت هوش مصنوعی و کاربرد آن در زمینه‌های مختلف و استفاده از آن در تکنولوژی‌های آینده، در این تحقیق غلظت رسوب با این سه روش هوش مصنوعی برآورد و بهترین روش انتخاب می‌گردد و نتایج حاصل، با غلظت تخمینی از روش منحنی سنج مقایسه می‌شود.

### مواد و روش‌ها

#### منطقه مورد مطالعه

حوضه آبخیز گرگانرود یکی از سه حوضه اصلی در استان گلستان است که در جنوب شرقی این استان در حد فاصل عرض‌های شمالی ۳۴، ۳۴۵ و ۴۷، ۳۷۵ و طول‌های جغرافیایی ۵۴۵، ۰۲ و ۱۶، ۵۶۵ شرقی جای دارد و با راستای تقریبی غربی- شرقی وارد دشت گرگان می‌شود. این حوضه با مساحت ۱۳۱۷۰ کیلومتر مربع و طول رودخانه اصلی ۳۳۳ کیلومتر در بخش جنوب شرقی دریای خزر قرار دارد. این حوضه از شمال و غرب به حوضه رودخانه اترک، از جنوب به حوضه‌های آبریز شاهرود و دامغان و از جنوب شرقی به حوضه قره‌سو و حوضه رودخانه نکا محدود می‌شود. در این مطالعه چهار ایستگاه هیدرومتری جنگله، نوده، ارازکوسه و قزاقلی بر روی رودخانه گرگانرود برای مدل‌سازی رسوب انتخاب گردید. موقعیت قرارگیری این چهار ایستگاه در شکل ۱ مشخص شده است. کمینه و حداکثر ارتفاع حوضه در ایستگاه‌های جنگله، نوده، ارازکوسه و قزاقلی به ترتیب برابر ۱۶۱ و ۱۸۹۲، ۲۶۴ و ۲۸۷۵، ۲۰ و ۲۸۷۸، ۲ و ۲۸۷۸ و شیب متوسط حوضه به ترتیب برابر ۳۰/۸، ۲۷/۴، ۲۷/۰ و ۱۹/۸ می‌باشد.

جدول ۱ پارامترهای آماری آن‌ها را به تفکیک مراحل آموزش و آزمون نشان می‌دهد.

جدول ۱- پارامترهای آماری ایستگاه‌های مورد مطالعه.

نام ایستگاه سال آماری	نوع داده	مرحله	تعداد داده	کمینه	میانگین	بیشینه	انحراف معیار	ضریب تغییرات	ضریب چولگی
جنگله ۱۳۵۰-۱۳۹۲	دبی ( $m^3 s^{-1}$ )	آموزش	۱۱۵	۰/۰۲	۱/۴۴	۱۳/۰۳	۲/۱۰	۱/۴۶	۳/۳۹
	غلظت رسوب ( $mg L^{-1}$ )			۱/۹۷	۱۶۸/۹۸	۲۸۴۷/۰۰	۳۹۰/۶۳	۲/۳۱	۴/۸۵
	دبی ( $m^3 s^{-1}$ )	آزمون	۳۹	۰/۱۳	۲/۰۶	۱۰/۵۱	۲/۴۸	۱/۲۰	۱/۷۱
نوده ۱۳۵۰-۱۳۹۲	غلظت رسوب ( $mg L^{-1}$ )			۹/۹۸	۱۵۵/۷۳	۱۵۶۹/۳۳	۲۵۳/۲۷	۱/۶۳	۴/۸۱
	دبی ( $m^3 s^{-1}$ )	آموزش	۳۷۰	۰/۰۱	۲/۲۶	۱۵/۲۰	۱/۷۰	۰/۷۵	۲/۷۳
	غلظت رسوب ( $mg L^{-1}$ )			۲/۰۰	۳۸۷/۸۵	۴۰۲۸/۰۰	۵۴۴/۴۲	۱/۴۰	۲/۹۹
ارازکوسه ۱۳۴۷-۱۳۹۳	دبی ( $m^3 s^{-1}$ )	آموزش	۵۳۲	۰/۰۲	۹/۴۵	۱۴۲/۸	۱۵/۶۴	۱/۶۵	۳/۷۰
	غلظت رسوب ( $mg L^{-1}$ )			۸/۰۰	۱۴۳۴/۳۲	۳۶۰۲۶/۷	۲۹۷۵/۸۶	۲/۰۷	۵/۹۲
	دبی ( $m^3 s^{-1}$ )	آزمون	۱۷۷	۰/۰۳	۹/۴۸	۸۲/۰۹	۱۳/۸۶	۱/۴۶	۲/۹۸
قزاقلی ۱۳۵۰-۱۳۹۲	غلظت رسوب ( $mg L^{-1}$ )			۱۶/۰	۱۴۹۵/۷۶	۱۶۳۳۵/۴۰	۲۷۳۵/۵۴	۱/۸۳	۳/۴۷
	دبی ( $m^3 s^{-1}$ )	آموزش	۲۴۲۵	۰/۲۵	۱۹/۱۷	۲۶۵/۳۹	۲۳/۳۲	۱/۲۲	۳/۳۱
	غلظت رسوب ( $mg L^{-1}$ )			۱۴/۷۰	۲۰۶۴/۷۱	۵۴۰۹۶/۶۷	۳۸۷۹/۱۸	۱/۸۸	۵/۰۳
	دبی ( $m^3 s^{-1}$ )	آزمون	۸۰۸	۰/۲۷	۲۰/۴۸	۲۱۹/۳۱	۲۵/۸۳	۱/۲۶	۳/۱۹
	غلظت رسوب ( $mg L^{-1}$ )			۱۸/۰۰	۲۲۴۸/۹۷	۳۷۵۶۶/۱۷	۴۰۵۹/۱۹	۱/۸۰	۴/۴۰

## ماشین بردار پشتیبان (SVM)

در سال‌های اخیر، ابزار پیشرفته‌ای که در رابطه با هوش مصنوعی کاربردهای زیادی در روش یادگیری ماشین دارد ماشین بردار پشتیبان می‌باشد (کریستیانینی و همکاران ۱۹۹۹). استفاده از این روش موفقیت‌آمیز بوده است زیرا از آن در طبقه‌بندی اطلاعات و اخیراً در مسائل رگرسیونی استفاده شده است. روابط مربوط به این مدل اولین بار توسط واپنیک (۱۹۹۵) ارائه شد. این مدل اولین بار در مدیریت منابع آب توسط سیوپرگسام و همکاران (۲۰۰۱)، دیبایک و همکاران (۲۰۰۱)، هان و یانگ (۲۰۰۱) به‌کار گرفته شد. ماشین‌های بردار پشتیبان می‌توانند برای مسائل رگرسیونی به‌کار روند (اسملا ۱۹۹۶، کمان ۲۰۰۱). اطلاعات بیشتر در منابع کریستیانینی و شو-تیلور (۲۰۰۰)، کاکائی‌لفدانی و همکاران (۲۰۱۳) و عطارزاده و امینی (۲۰۱۵) وجود دارد.

## کمینه مربعات ماشین بردار پشتیبان (LS-SVM)

کمینه مربعات ماشین بردار پشتیبان برای اولین بار توسط سویکنس و وندوال (۱۹۹۹) پیشنهاد شد. برای اجرای LS-SVM از کرنل تابع پایه شعاعی<sup>۱</sup> RBF استفاده شد. LS-SVM با کرنل تابع پایه شعاعی پارامتر  $\lambda$  و پارامتر تابع کرنل ( $\sigma^2$ ) را به‌گونه‌ای تعیین می‌کند که خطای آموزش کمینه شود و تابع تخمین پارامترها دارای کمترین پیچیدگی باشد. منشأ این روش ماشین بردار پشتیبان است و یک روش قدرتمند برای برآورد تابع می-باشد (کومار و کار، ۲۰۰۲). اطلاعات بیشتر در منابع شو-گنگ و همکاران (۲۰۰۸)، کیسی (۲۰۱۲) و نورانی و عندلیب (۲۰۱۵) وجود دارد.

تابع کرنل پایه شعاعی معمولاً برای مسائل رگرسیونی استفاده می‌شود. در این پژوهش از تابع کرنل RBF استفاده شد.

## روش کار

به‌منظور مدل‌سازی غلظت رسوب با روش‌های منحنی سنجه، نروفازی، SVM و LS-SVM در چهار

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad [۳]$$

$$MEF = \frac{1}{n} \sum_{i=1}^n \left( \frac{|O_i - P_i|}{\max(O_i) - \min(O_i)} \right) \times 100 \quad [۴]$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad [۵]$$

$n$  تعداد داده‌ها،  $O$  مقادیر غلظت رسوب مشاهده شده،  $P$  مقادیر غلظت رسوب برآورد شده است. هر چقدر مقادیر جذر میانگین مربعات خطا، میانگین کارآیی خطا و میانگین اریبی خطا به صفر و ضریب همبستگی به یک یا منفی یک نزدیکتر باشد، مدل شبیه‌سازی را با دقت بیشتری انجام داده است.

### نتایج و بحث

در جدول ۲ مقادیر خطا و ضریب همبستگی غلظت رسوب شبیه‌سازی شده با روش منحنی سنج آورده شده است. در شکل ۲ در هر ایستگاه بهترین توابع عضویت روش نروفازی در هر ترکیب آورده شده است. با توجه به این شکل برای ایستگاه‌های جنگله، نوده، ارازکوسه و قزاقلی به ترتیب ترکیب اول با ورودی  $(Q_i)$ ، ترکیب دوم با ورودی‌های  $(Q_i, Q_{i-1})$ ، ترکیب چهارم با ورودی‌های  $(Q_i, Q_{i-1}, R_i)$  و ترکیب سوم با ورودی‌های  $(Q_i, Q_{i-1}, Q_{i-2})$  به عنوان بهترین ترکیب‌های شبیه‌ساز غلظت رسوب انتخاب شده‌اند. تابع عضویت نروفازی در ایستگاه‌های جنگله، نوده، ارازکوسه و قزاقلی به ترتیب توابع ۳ قانونی نوزنقه‌ای با خروجی عددی، نوزنقه‌ای با خروجی خطی، گوسی با خروجی عددی و گوسی ۲ با خروجی عددی می‌باشند. در سه ایستگاه، غلظت رسوب با خروجی عددی بهتر از خروجی خطی تخمین زده شده است و فقط در ایستگاه نوده خروجی خطی نتایج بهتری ارائه داده است. بررسی نتایج شبیه‌سازی غلظت رسوب با مدل نروفازی در ایستگاه جنگله نشان می‌دهد که پارامتر دبی همان روز از بقیه پارامترها تأثیرگذارتر است

ایستگاه مورد مطالعه، داده‌های دبی و غلظت رسوب متناظر به دو بخش ۷۵٪ داده‌های آموزش و ۲۵٪ داده‌های آزمون تفکیک شدند.

روش SVM با استفاده از ابزار LIBSVM (چانگ و لین ۲۰۱۱) اجرا گردید. در این روش از تابع کرنل RBF استفاده شد زیرا در تحقیقات بسیاری برتری این تابع نشان داده شده است (نونعمت کرمانی و همکاران ۲۰۱۶، سیمین ۲۰۰۸، نورانی و همکاران ۲۰۱۵، میسرا و همکاران ۲۰۰۹، کاکائی لمدانی و همکاران ۲۰۰۹ و کومار و همکاران ۲۰۱۶) و مقادیر پارامترهای  $C$ ،  $\epsilon$  و  $\gamma$  با آزمون و خطا (سیمین ۲۰۰۸، نورانی و همکاران ۲۰۱۵ و کاکائی لمدانی و همکاران ۲۰۰۹) تعیین شدند. مدل LS-SVM در محیط متلب اجرا (برابانتر و همکاران ۲۰۱۱) و از دو روش جستجوی ساده و شبکه‌ای استفاده شد.

برای شبیه‌سازی غلظت رسوب با روش‌های نروفازی، SVM و LS-SVM، ۵ ترکیب با ورودی‌های مختلف تعریف شد. ترکیب ورودی‌ها عبارتند از: ترکیب ۱:  $(Q_i)$ ، ترکیب ۲:  $(Q_i, Q_{i-1})$ ، ترکیب ۳:  $(Q_i, Q_{i-1}, Q_{i-2})$ ، ترکیب ۴:  $(Q_i, Q_{i-1}, R_i)$  و ترکیب ۵:  $(Q_i, Q_{i-1}, R_{i-1})$ . در هر ترکیب نتایج با پارامترهای آماری  $RMSE$ ،  $R$ ،  $MEF^2$  و  $MBE^3$  مقایسه و سپس ترکیب ورودی بعدی انتخاب می‌شود. بارندگی همان روز و بارندگی یک روز قبل، به ترکیبی اضافه گردید که نتایج پیش‌بینی بهبود بیشتری داشته است و برای هر چهار ایستگاه، بارش همان روز به ترکیب چهارم و بارش یک روز قبل به ترکیب پنجم اضافه شد.

### معیارهای ارزیابی

شاخص‌های آماری  $R$ ،  $RMSE$ ،  $MEF$  و  $MBE$  با روابط ۲، ۳، ۴ و ۵ قابل محاسبه است.

$$R = \frac{n(\sum_{i=1}^n P_i O_i) - (\sum_{i=1}^n P_i)(\sum_{i=1}^n O_i)}{\sqrt{[n(\sum_{i=1}^n P_i^2) - (\sum_{i=1}^n P_i)^2][n(\sum_{i=1}^n O_i^2) - (\sum_{i=1}^n O_i)^2]}} \quad [۲]$$

3- Mean bias error

1- Root mean square error  
2- Mean error function

طوری که خطاهای RMSE و MEF نسبت به ترکیب اول به ترتیب به میزان ۹ و ۸ درصد کاهش و مقدار ضریب همبستگی ۶ درصد افزایش داشته است.

زیرا ترکیب اول این ایستگاه دارای بهترین نتیجه است شکل ۲- الف، ه، ط. نروفازی در ایستگاه نوده با ورودی- های ترکیب دوم توانسته است نتایج بهتری ارائه دهد به

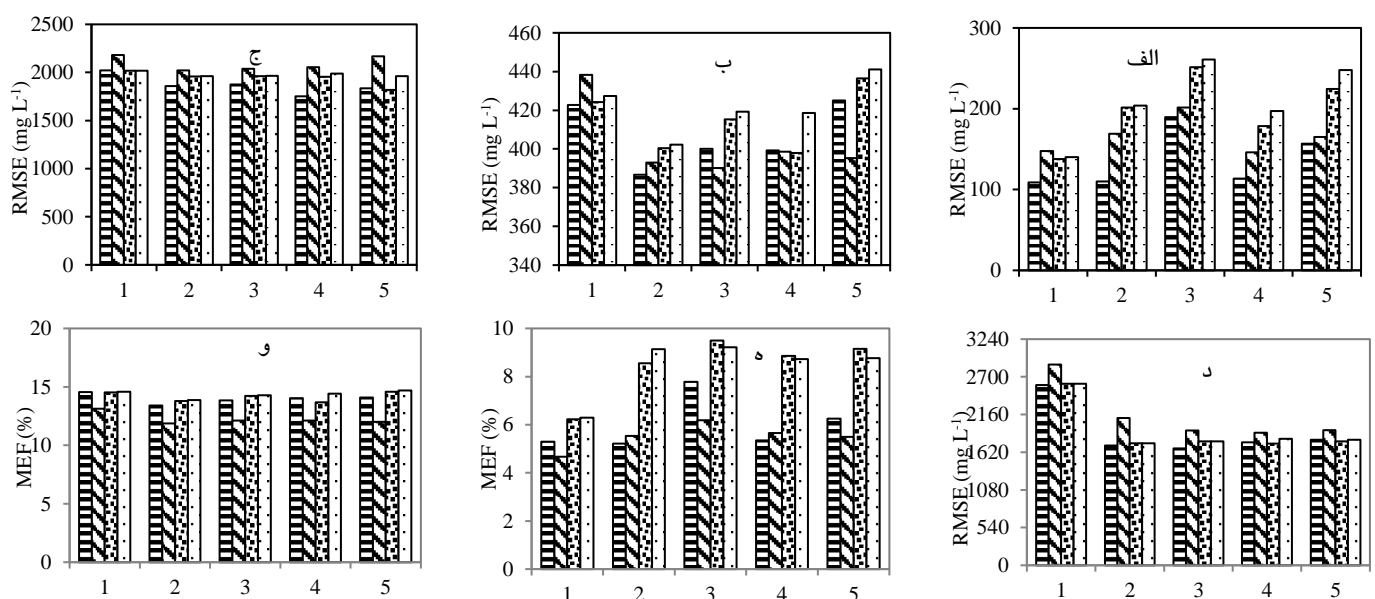
جدول ۲- شاخص‌های آماری غلظت رسوب محاسبه شده با مدل منحنی سنجی برای ایستگاه‌های مورد مطالعه.

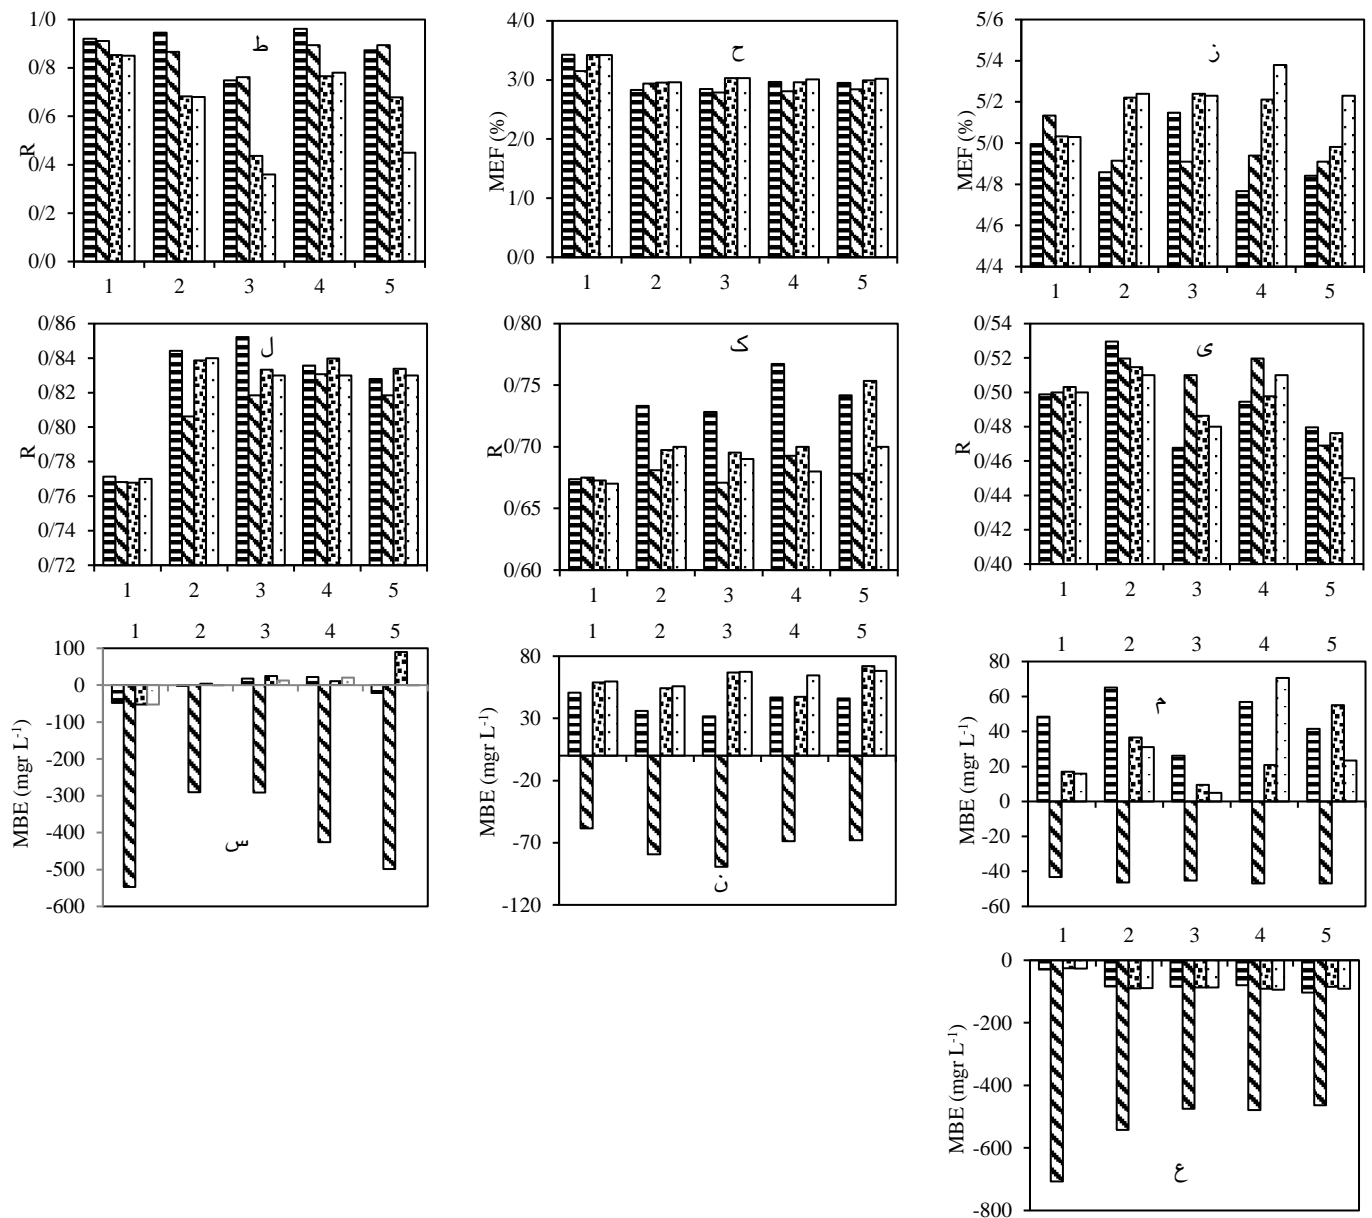
آزمون				آموزش				نام ایستگاه
MBE (mgr L <sup>-1</sup> )	MEF(%)	RMSE (mg L <sup>-1</sup> )	R	MBE (mgr L <sup>-1</sup> )	MEF(%)	RMSE (mg L <sup>-1</sup> )	R	
-۶۵/۹۶	۵/۸۹	۲۳۲	۰/۶۳	-۹۳/۶۰	۴/۵۵	۳۸۲	۰/۴۸	جنگله
-۱۵۴/۴۲	۱۳/۲۶	۴۳۵	۰/۴۲	-۱۷۷/۴۵	۷/۰۴	۵۴۰	۰/۵۱	نوده
-۶۸۹/۱۹	۵/۹۷	۲۴۳۲	۰/۶۸	-۶۴۷/۸۴	۲/۶۲	۲۶۲۸	۰/۶۹	ارازکوسه
-۷۴۲/۹۸	۲/۲۷	۳۰۲۵	۰/۷۵	-۶۵۳/۳۰	۲/۱۳	۲۹۷۷	۰/۷۲	قزاقلی

نشان می‌دهد خطاهای RMSE و MEF به ترتیب ۲ و ۱ درصد کاهش و ضریب همبستگی ۱ درصد افزایش داشته است. بیشترین کاهش خطا مربوط به ترکیب سوم است که تأثیر دو پارامتر دبی یک روز قبل و دبی دو روز قبل بر دقت شبیه‌سازی را نشان می‌دهد شکل ۲- د، ح، ل. مدل نروفازی در ایستگاه قزاقلی با ورودی‌های ترکیب سوم (با میانگین کارایی خطای ۲/۸۵ درصد و ضریب همبستگی ۰/۸۵، دقیق‌ترین تخمین غلظت رسوب را در بین ایستگاه‌های مورد مطالعه انجام داده است شکل ۲- ح، ل.

در ترکیب چهارم مقدار خطا نسبت به ترکیب اول به مقدار قابل توجهی کاهش یافته است که نشان می‌دهد دبی یک روز قبل و بارش همان روز باعث افزایش دقت تخمین غلظت رسوب می‌شود شکل ۲- ج، ز، ک. در ایستگاه قزاقلی مقایسه بهترین برآورد غلظت رسوب (ترکیب سوم) با ترکیب اول نشان می‌دهد که خطاهای RMSE و MEF به ترتیب به مقدار ۵۴ و ۲۰

درصد کاهش و ضریب همبستگی ۱۰ درصد افزایش داشته است. مقایسه این ترکیب با ترکیب دوم نیز





شکل ۲- مقایسه شاخص خطای RMSE در ایستگاه‌های الف (جنگله، ب) نوده، ج) ارازکوسه و د) قزاقلی، MEF در ایستگاه‌های ه) جنگله، و) نوده، ز) ارازکوسه و ح) قزاقلی، ضریب همبستگی خطی در ایستگاه‌های ط) جنگله، ی) نوده، ک) ارازکوسه و ل) قزاقلی، MBE در ایستگاه‌های م) جنگله، ن) نوده، س) ارازکوسه و ع) قزاقلی با مدل‌های روش جستجوی ساده با مدل LS-SVM ، SVM ، NF و روش جستجوی شبکه با مدل LS-SVM . محور افقی شماره ترکیب می‌باشد.



ترکیب‌ها نتایج بسیار نزدیکی با الگوریتم ساده داشته است اما در مجموع روش جستجوی ساده به دلیل مدل‌سازی غلظت رسوب با میزان خطای کمتر و ضریب همبستگی بیشتر، برآورد بهتری را ارائه داده است. مدل LS-SVM شبیه‌سازی غلظت رسوب را با روش جستجوی ساده در ایستگاه جنگله با ترکیب اول  $(Q_t)$ ، در ایستگاه نوده با ترکیب چهارم  $(Q_t, Q_{t-1}, R_t)$ ، در ایستگاه ارازکوسه با ترکیب پنجم  $(Q_t, Q_{t-1}, R_{t-1})$  و در ایستگاه قزاقلی با ترکیب چهارم  $(Q_t, Q_{t-1}, R_t)$  دقیق‌تر انجام داده است.

در ایستگاه جنگله با اضافه شدن دبی یک روز قبل به ترکیب اول خطاهای RMSE و MEF به مقدار ۴۷ و ۳۷ درصد شکل ۲-الف، ه افزایش و ضریب همبستگی ۲۵ درصد شکل ۲-ط کاهش می‌یابد اما در سه ایستگاه دیگر با اضافه شدن این ورودی مقادیر خطا کاهش و ضریب همبستگی افزایش می‌یابد. در ترکیب سوم در هر چهار ایستگاه هنگامی که دبی دو روز قبل به ورودی‌های ترکیب دوم اضافه می‌گردد شاخص‌های آماری افزایش خطا و کاهش ضریب همبستگی را نشان می‌دهند اما مقدار این تغییرات در آن‌ها یکسان نیست. در ترکیب چهارم افزودن بارش در هر چهار ایستگاه باعث کاهش میزان خطا و افزایش دقت تخمین غلظت رسوب با مدل LS-SVM می‌شود. در ترکیب پنجم در سه ایستگاه جنگله، نوده و قزاقلی با افزودن بارش یک روز قبل به ورودی‌های ترکیب دوم، افزایش خطا و کاهش مقدار ضریب همبستگی مشاهده می‌شود.

مقادیر خطای MBE (شکل ۲-م، ن، س و ع) نشان می‌دهد در هر چهار ایستگاه مدل SVM کم‌برآوردی دارد و مقادیر غلظت رسوب را به مقدار قابل توجهی کمتر از مقدار واقعی پیش‌بینی می‌کند. کم‌برآوردی در ایستگاه ارازکوسه و قزاقلی بیشتر از دو ایستگاه دیگر است. در ایستگاه جنگله و نوده مدل‌های نروفازی و LS-SVM در تمام ترکیب‌ها بیش‌برآوردی دارند. در ایستگاه ارازکوسه به جز مدل SVM بیش و یا کم‌برآوردی مدل‌ها بسیار کم


از بین ۵ ترکیب اجرا شده با مدل SVM، مقادیر آماری خطا در مرحله آزمون نشان می‌دهد بهترین شبیه‌سازی در ایستگاه‌های جنگله در ترکیب چهارم  $(Q_t, Q_{t-1}, R_t)$  شکل ۲-الف، ه، نوده در ترکیب سوم  $(Q_t, Q_{t-1}, R_t)$  شکل ۱،  $(Q_t, Q_{t-1})$  شکل ۲-ب، و، ارازکوسه در ترکیب دوم  $(Q_t, Q_{t-1})$  شکل ۲-ج، ز و قزاقلی در ترکیب چهارم  $(Q_t, Q_{t-1}, R_t)$  شکل ۲-د، ح صورت گرفته است.

در ترکیب دوم ایستگاه جنگله با اضافه شدن دبی یک روز قبل، مقادیر خطا افزایش یافته است. در ترکیب سوم نیز دبی دو روز قبل باعث افزایش خطا می‌شود اما در ترکیب چهارم خطا کاهش و در ترکیب پنجم خطا ۱۳ درصد افزایش می‌یابد. در این ایستگاه بارندگی همان روز باعث بهبود نتایج و دبی دو روز قبل و بارندگی روز قبل باعث افزایش خطا می‌شود. ترکیب دوم مدل SVM در ایستگاه‌های نوده، ارازکوسه و قزاقلی باعث کاهش خطای RMSE به ترتیب ۱۲، ۸ و ۳۶ درصد شکل ۲-ب، ج، د و MEF به ترتیب ۱۱، ۴ و ۷ درصد شکل ۲-و، ز، ح شده است و ضریب همبستگی دو ایستگاه نوده و قزاقلی ۴ و ۵ درصد شکل ۲-ی، ل افزایش یافته است. در ایستگاه نوده با اضافه شدن دبی دو روز قبل نتایج اندکی بهتر می‌شود. در ایستگاه‌های نوده و ارازکوسه در ترکیب چهارم با افزودن بارش همان روز به ترکیب دوم، تخمین غلظت رسوب با مدل SVM با افزایش خطا همراه بوده است. همچنین با افزایش بارندگی روز قبل نیز در ایستگاه‌های ارازکوسه و قزاقلی، خطای RMSE به ترتیب به اندازه ۶ و ۲ درصد افزایش پیدا می‌کند (شکل ۲-ج و د).

در شکل ۲ شاخص‌های آماری برای روش جستجوی ساده و شبکه‌ای در ترکیب‌های (۱ تا ۵) با روش کمینه مربعات ماشین بردار پشتیبان آورده شده است. با توجه به این شکل، مناسب‌ترین الگوریتم بهینه‌سازی در هر ۵ ترکیب و برای هر ۴ ایستگاه، روش جستجوی ساده است. هر چند که مقادیر غلظت رسوب برآورد شده با روش جستجوی شبکه‌ای در بعضی از

۳ و ۱۲)، ایستگاه ارازکوسه (۱۵، ۴ و ۳۹) و ایستگاه قزاقلی (۱۳، ۴ و ۸۱) درصد کمتر می‌باشد (شکل ۲- الف، ب، ج، د و جدول ۲). این موضوع بیانگر توانایی و قابلیت نروفازی در مدل‌سازی پدیده‌های غیر خطی و پیچیده است.


شکل ۳ نمودار پراکندگی بهترین ترکیب و مدل شبیه‌سازی غلظت رسوب را در هر ایستگاه در مرحله آزمون نشان می‌دهد. خط وسط نمودار ۱:۱ و خط چین-های کناری  $\pm 25\%$  را نشان می‌دهند. در ایستگاه جنگله نقاط زیادی در بالای خط  $+25\%$  وجود دارد که بیانگر بیش‌برآوردی می‌باشد و با منحنی‌های MBE شکل ۲- م، ن، س و ع تطابق دارد. در ایستگاه نوده مقادیر کمتر از ۴۰۰ میلی‌گرم بر لیتر بیشتر از مقدار واقعی پیش‌بینی شده‌اند اما برای مقادیر بیشتر از این مقدار پراکندگی نقاط زیاد می‌باشد اما به‌طور کلی مدل کم‌برآوردی بیشتری برای این محدوده نشان می‌دهد. در ایستگاه ارازکوسه در محدوده ۴۵۰۰-۱۵۰۰۰ میلی‌گرم بر لیتر مدل مقداری بیش‌برآوردی دارد اما برای غلظت‌های بیشتر، کم-برآوردی مشاهده می‌شود. در ایستگاه قزاقلی غلظت‌های ۶۰۰۰-۲۰۰۰۰ میلی‌گرم بر لیتر کمتر از مقدار واقعی پیش‌بینی شده است اما برای خارج از این محدوده توزیع نقاط حول خط ۱:۱ یکنواخت است. حداکثر بار رسوبی در مرحله آزمون در ایستگاه‌های جنگله، نوده، ارازکوسه و قزاقلی به‌ترتیب برابر ۱۴۲۴، ۲۰۱۵، ۲۹۸۸۰ و ۳۱۹۷۰ تن بر روز می‌باشد که توسط بهترین مدل به‌ترتیب ۱۳۲۷، ۱۴۴۱، ۲۸۷۷۵ و ۲۹۲۸۴۰ تن بر روز تخمین زده شده است.



است. در ایستگاه قزاقلی تمام مدل‌ها کم‌برآوردی دارند و مقدار آن در ترکیب‌های ۲ تا ۵ تقریباً یکسان است.

ارزیابی بهترین ترکیب مدل SVM با مدل منحنی سنج نشان می‌دهد مقادیر خطاهای RMSE و MEF در ایستگاه جنگله به‌ترتیب ۵۹ و ۴ درصد، در ایستگاه نوده ۱۲ و ۹ درصد، در ایستگاه ارازکوسه ۲۰ و ۲۲ درصد و در ایستگاه قزاقلی ۵۹ و ۱۶ درصد کمتر از مدل منحنی‌سنج است و ضریب همبستگی نیز نسبت به روش منحنی‌سنج در ایستگاه‌های جنگله، نوده و قزاقلی به‌ترتیب به اندازه ۶۱، ۲۱ و ۱۱ درصد افزایش داشته است. نتایج نشان می‌دهد مدل SVM نسبت به مدل منحنی‌سنج تخمین غلظت رسوب را دقیق‌تر انجام داده است (جدول ۲ و شکل ۲). همچنین مقایسه غلظت رسوب تخمین زده شده توسط بهترین ترکیب مدل کمینه مربعات ماشین بردار پشتیبان با روش منحنی‌سنج رسوب نیز نشان می‌دهد که مدل LS-SVM در ایستگاه‌های جنگله، نوده، ارازکوسه و قزاقلی به‌ترتیب با معیارهای خطای RMSE و MEF برابر (۱۳۸، ۳۹۸، ۱۸۱۸ و ۱۷۴۳) میلی‌گرم بر لیتر و (۶/۲۳، ۱۳/۶۸، ۴/۹۸ و ۲/۹۶) درصد و ضریب همبستگی (۰/۸۵، ۰/۵۰، ۰/۷۵ و ۰/۸۴) برآورد مناسب‌تری نسبت به روش منحنی‌سنج با مقادیر خطای RMSE و MEF به‌ترتیب برابر (۲۳۲، ۴۳۵، ۲۴۳۲ و ۳۰۲۵) میلی‌گرم بر لیتر و (۵/۸۹، ۱۳/۲۶، ۵/۹۷ و ۳/۲۷) درصد و ضریب همبستگی (۰/۶۳، ۰/۴۲، ۰/۶۸ و ۰/۷۵) داشته است (جدول ۲ و شکل ۲).

مقدار خطای RMSE بهترین ترکیب مدل نروفازی نسبت به مدل‌های SVM، LS-SVM و روش منحنی‌سنج برای ایستگاه جنگله (۳۴، ۲۷ و ۱۱۳)، ایستگاه نوده (۰/۸،



### شکل ۳- نمودار پراکندگی غلظت رسوب پیش‌بینی شده توسط بهترین مدل در مرحله آزمون در ایستگاه‌های الف)

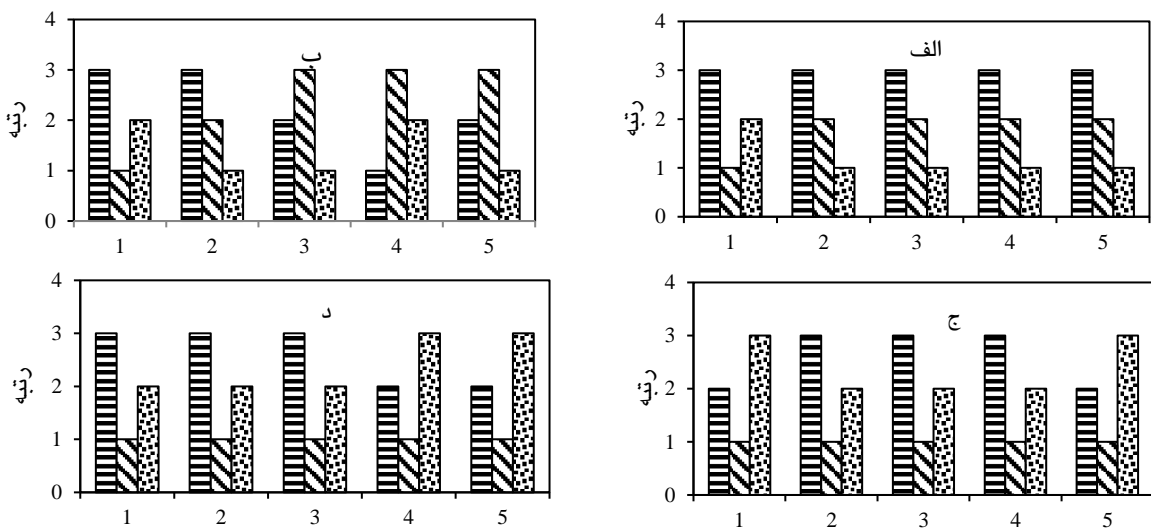
جنگله، ب) نوده، ج) ارازکوسه و د) قزاقلی. محور افقی غلظت واقعی ( $\text{mgr L}^{-1}$ ) و محور عمودی ( $\text{mgr L}^{-1}$ ) غلظت پیش‌بینی شده می‌باشد.

از مدل نروفازی جای می‌گیرد (شکل ۴- الف). نتایج مدل LS-SVM با تغییر ساختار ورودی‌ها در ترکیب‌های دوم تا پنجم مناسب نبوده و در ترکیب سوم عملکرد ضعیفی داشته است (شکل ۲- الف و ه).

در ایستگاه نوده در دو ترکیب اول و دوم مدل نروفازی غلظت رسوب را با دقت بیشتری تخمین زده است و در ترکیب دوم با اضافه شدن دبی روز قبل، مقدار خطا کاهش می‌یابد. در ترکیب‌های سوم، چهارم و پنجم مدل SVM نتایج بهتری داشته است. مدل LS-SVM در ترکیب‌های دوم، سوم و پنجم، غلظت رسوب را با دقت کمی تخمین زده است که در ترکیب پنجم کاملاً مشخص است (شکل ۲- ب، و و شکل ۴- ب).

در شکل ۴ با توجه به شاخص‌های خطای RMSE و MEF، مناسب‌ترین غلظت‌های رسوب شبیه‌سازی شده از مدل‌های نروفازی، SVM و LS-SVM مورد ارزیابی قرار گرفتند و امتیازبندی شدند. بر این اساس به دقیق‌ترین تخمین غلظت رسوب امتیاز ۳، تخمین متوسط امتیاز ۲ و نامناسب‌ترین برآورد امتیاز ۱ تعلق گرفت.

بررسی نتایج سه مدل نروفازی، ماشین بردار پشتیبان و کمینه مربعات ماشین بردار پشتیبان نشان می‌دهد که در ایستگاه جنگله بهترین تخمین غلظت رسوب در ترکیب‌های دوم تا پنجم مربوط به مدل نروفازی، در رده دوم مدل SVM و در آخرین رده مدل LS-SVM است. فقط در ترکیب اول، مدل LS-SVM تخمین دقیق‌تری نسبت به SVM داشته است و در رده دوم پس



شکل ۴- رتبه‌بندی مدل‌های NF، SVM و LS-SVM در ایستگاه‌های الف) جنگله، ب) نوده، ج) ارازکوسه و د) قزاقلی. محور افقی شماره ترکیب می‌باشد.

نروفازی و در ترکیب‌های سوم و چهارم مدل LS-SVM عملکرد بهتری را نشان داده است.

در ایستگاه‌های ارازکوسه و قزاقلی، مقایسه دو مدل SVM و LS-SVM نشان می‌دهد که LS-SVM عملکرد قویتری نسبت به SVM داشته است (شکل ۲- ج، د و ضعیف‌ترین عملکرد مدل SVM در هر دو ایستگاه در

در ایستگاه ارازکوسه در ترکیب‌های دوم تا چهارم مدل نروفازی نتایج بهتری ارائه کرده است (شکل ۴- ج و در ترکیب چهارم با افزودن پارامتر بارش به ترکیب دوم بهترین نتیجه حاصل شده است (شکل ۲- ج) و (ز)). در ایستگاه قزاقلی در سه ترکیب اول مدل

تحقیقات (کیسی ۲۰۰۵، کیسی و همکاران ۲۰۰۶ و کیسی و همکاران ۲۰۰۹) همسو است. مطالعات دیگری (کوبنر و همکاران ۲۰۰۹، خورشید دوست و همکاران ۲۰۱۵، اولک و همکاران ۲۰۰۹ و فیرات و گانگور ۲۰۱۰) به ارزیابی دقت مدل نروفازی با سایر مدل‌ها (روش‌های شبکه عصبی مصنوعی، شبکه عصبی رگرسیون تعمیم‌یافته، پرسپترون چندلایه، شبکه عصبی پایه شعاعی، رگرسیون چند متغیره، رگرسیون خطی چندگانه و منحنی‌سنجه رسوب) پرداخته‌اند که نتایج این مطالعات نشان داد مدل نروفازی تخمین‌گر مناسبی برای مدل‌سازی بار یا غلظت رسوب بوده است و با یافته‌های پژوهش حاضر هم‌خوانی دارد. همچنین بررسی نتایج شبیه‌سازی غلظت رسوب با توجه به شاخص‌های ارزیابی نشان داد که مدل نروفازی دقت برآورد بیشتری نسبت به روش منحنی‌سنجه نیز داشته است و این یافته‌ها مشابه نتیجه‌ی تحقیقات (جعفری‌میانی و کشاورزی ۲۰۰۸، احمدی و همکاران ۲۰۰۸، رضایی‌بنفشه و همکاران ۲۰۱۳، لوهانی و همکاران ۲۰۰۷ و دمیرسی و بالتاسی ۲۰۱۳) است.

### نتیجه‌گیری کلی

تعیین میزان دقیق غلظت رسوب منتقل شده توسط رودخانه‌ها برای دامنه وسیعی از پروژه‌های آبی حائز اهمیت است. فرسایش و رسوبگذاری منجر به اعمال آثار منفی بر شاخص‌های کیفی آب، کاهش ظرفیت مخازن سدها و وارد شدن خسارت به تأسیسات رودخانه‌ای می‌شود. بنابراین برآورد صحیح و دقیق غلظت رسوب معلق بسیار ضروری است. لذا در این پژوهش به منظور تخمین غلظت رسوب رودخانه گرگانرود از داده‌های دبی-غلظت رسوب متناظر چهار ایستگاه جنگله، نوده، ارازکوسه و قزاقلی استفاده شده است. برای مدل‌سازی غلظت رسوب از روش متداول و ساده منحنی‌سنجه و از سه روش هوشمند نروفازی، ماشین بردار پشتیبان و کمینه مربعات ماشین بردار پشتیبان استفاده گردید.

ترکیب اول حاصل شده است. خطای SVM در هر ترکیب نوساناتی داشته است و دارای یک روند کاهشی بوده اما مقدار کاهش در هر ترکیب یکسان نمی‌باشد. دلیل این امر ساختارهای متفاوت هر ترکیب می‌باشد که سبب ایجاد مقدار خطاهای مختلف در هر ترکیب است. به‌عنوان مثال بیشترین مقدار کاهش خطای RMSE در ایستگاه ارازکوسه با مدل SVM در ترکیب دوم و به میزان ۸ درصد بوده است (شکل ۲-ج و شکل ۴-ج). در ایستگاه قزاقلی برخلاف ایستگاه ارازکوسه بیشترین درصد کاهش خطا در ترکیب چهارم و به مقدار ۵۱ درصد بوده است که نشان می‌دهد با اضافه شدن دبی یک روز قبل و بارش مقدار خطا به مقدار قابل توجهی کاهش می‌یابد (شکل ۲-د و شکل ۴-د).

در دو ایستگاه جنگله و نوده، ارزیابی مقادیر غلظت خروجی در ۵ ترکیب اجرا شده با مدل‌های کمینه مربعات ماشین بردار پشتیبان و ماشین بردار پشتیبان نشان داد که در همه ترکیب‌ها به‌جز ترکیب اول، LS-SVM نتایج ضعیف‌تری ارائه کرده است در حالی که در ایستگاه‌های ارازکوسه و قزاقلی در همه ترکیب‌ها مدل SVM عملکرد ضعیف‌تری دارد که این نتیجه با تحقیق کاکائی‌لفدانی و همکاران (۲۰۱۳) سازگار است اما با نتایج مطالعات (سیمن ۲۰۰۸، جی و یو ۲۰۱۱، نورانی و همکاران ۲۰۱۵ و شامارا و همکاران ۲۰۱۵) مغایرت دارد. مقایسه ۵ ترکیب اجرا شده در هر ایستگاه نشان می‌دهد مدل نروفازی دارای کمترین میزان خطا به‌منظور تخمین غلظت رسوب رودخانه گرگانرود بوده است و می‌تواند به‌عنوان یک روش مناسب و دقیق مورد استفاده قرار گیرد. مدل نروفازی به سبب اینکه شبکه‌های عصبی را با مفاهیم منطق فازی تلفیق می‌کند از امکانات هر دو روش در قالب یک روش بهره‌مند می‌شود. از این رو نروفازی به‌عنوان یک برآورد کننده جهانی<sup>۱</sup> مطرح است (جنگ و همکاران ۱۹۹۷) و قادر به شبیه‌سازی دقیق از پدیده مورد بررسی می‌باشد. این نتیجه‌گیری با نتایج

دهد. دقت مدل‌سازی غلظت رسوب مدل‌های ماشین بردار پشتیبان و کمینه مربعات ماشین بردار پشتیبان کمتر از نروفازی است اما این دو روش، سرعت بسیار بالاتری در شبیه‌سازی دارند. تنظیم قوانین نروفازی که براساس روش آزمون و خطا به‌منظور افزایش دقت شبیه‌سازی صورت می‌گیرد ممکن است ساعت‌ها به طول انجامد. ترکیب روش‌های بهینه‌سازی با نروفازی می‌تواند سرعت اجرای کار را افزایش دهد و در کارهای آتی مورد استفاده قرار گیرد و دقت و زمان اجرا مدل با روش معمول مقایسه شود. همچنین آنالیز حساسیت مدل‌های مختلف به پارامترهای ورودی بررسی شود و مهم‌ترین پارامترها تعیین شود.

مقایسه بهترین شبیه‌سازی مدل‌های SVM و LS-SVM با روش منحنی‌سنجه نشان داد که این دو مدل هوشمند، برآورد دقیق‌تری از غلظت رسوب نسبت به روش منحنی‌سنجه داشته‌اند و این نتیجه‌گیری مشابه پژوهش کیسی و شیرینی (۲۰۱۲) است. به طور کلی در هر چهار ایستگاه مورد مطالعه، مدل نروفازی نسبت به دو مدل SVM و LS-SVM ارتباط مناسب‌تری میان دبی و غلظت رسوب برقرار کرده است. مدل نروفازی علی‌رغم وقت‌گیر بودن تنظیم قوانین با روش آزمون و خطا، قادر است با قابلیت جعبه سیاه خود، بین داده‌های ورودی و خروجی ارتباط منطقی برقرار سازد و مدل‌سازی پدیده مورد بررسی (غلظت رسوب معلق) را با دقت بالایی انجام

#### منابع مورد استفاده

- Abe S, 2010. Support Vector Machine for Pattern Classification. Springer, London.
- Ahmadi H, Tahmoore M and Mohammad Asgari H, 2008. Estimating suspended sediment using fuzzy inference system case study: taleghan watershed. Iranian Journal of Watershed Management Sciences and Engineering 2(1): 5-14.
- Asselman NEM, 2000. Fitting and interpretation of sediment rating curves. Journal of Hydrology 23(4): 228-248.
- Attarzadeh R and Amini J, 2015. Optimization of backup vector machine classifier using genetic algorithm for classification of polarimetric radar images. Scientific-Research Journal of Science and Technology of Surveying 5(1): 127-138.
- Brabanter K, Karsmakers P, Ojeda F, Alzate C, Brabanter J, Pelckmans K, De Moor B, Vandewalle J and Suykens JAK, 2011. LS-SVMlab Toolbox User's Guide version 1.8, Internal Report 10-146, ESAT-SISTA, K.U. Leuven (Leuven, Belgium).
- Chang CC and Lin CJ, 2011. LIBSVM: a library for support vector machines. ACM Transactions on Intelligent Systems and Technology 2(3): 1-27.
- Cimen M, 2008. Estimation of daily suspended sediment using support vector machines. Hydrological Sciences Journal 53(3): 656-666.
- Cobaner M, Unal B, and Kisi O, 2009. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydrometeorological data. Journal of Hydrology 367(1-2): 52-61.
- Colby BR, 1956. Relationship of Sediment Discharge to Streamflow, U.S. Department of the Interior, Geological Survey, Water Resources Division, USA.
- Cristianini N, and Shawe-Taylor J, 2000. An Introduction to Support Vector Machines. Cambridge University Press, Cambridge.
- Cristianini N, Campbell C and Taylor JS, 1999. Dynamically Adapting Kernels in Support Vector Machines. Cambridge, MA: The MIT Press.
- Demirci M and Baltaci A, 2013. Prediction of suspended sediment in river using fuzzy logic and multilinear regression approaches. Neural Computing and Applications 23(1): 145-151.
- Dibike YB, Velickov S, Solomatine DP and Abbott M, 2001. Model induction with support vector machines: introduction and applications. Journal of Computing Civil Engineering 15(3): 208-216.
- Firat M and Gungor M, 2010. Monthly total sediment forecasting using adaptive neuro fuzzy inference system. Stochastic Environmental Research Risk Assessment 24: 259-270.
- Glysson GD, 1987. Sediment-Transport Curves. U.S. Geology Survey Open File Report. Microfiche, Denver.

- Halecki W, Kruk E and Ryczek M, 2018. Estimations of nitrate nitrogen, total phosphorus flux and suspended sediment concentration (SSC) as indicators of surface-erosion processes using an ANN (Artificial Neural Network) based on geomorphological parameters in mountainous catchments. *Ecological Indicators* 91: 461-469.
- Hamzeabad AJ, Khadkhodahosseini M, Akhavan S and Nozari H, 2016. Evaluation of SWAT and SVM Models to Simulate the Runoff of Lighvanchay River. *Water and Soil Science- University of Tabriz* 26(4.1): 137-150.
- Han D and Yang Z, 2001. River flow modeling using support vector machines. Pp. 494-499. *Proceeding of 29th IAHR*. 17-21 September, Beijing, China.
- He J, Valeo C, Chu A and Neumann NF, 2011. Prediction of event-based stormwater runoff quantity and quality by ANNs developed using PMI-based input selection. *Journal of Hydrology* 400: 10-23.
- Jacquin AP and Shamseldin AY, 2006. Development of rainfall- runoff models using takagi-sugeno fuzzy Inference System. *Journal of Hydrology* 329: 154-173.
- Jafari Miyanaei S and Keshavarzi A, 2008. Comparison of Fuzzy Method and Statistical Regression to Estimate Sediment Load in Rivers. Pp. 41-53. *Fourth National Congress on Civil Engineering*, Tehran University, Tehran.
- Jang JSR, Sun CT and Mizutani E, 1997. *Neuro-Fuzzy and Soft Computing, a Computational Approach to Learning and Machine Intelligence*. Prentice Hall, London.
- Jie LC and Yu ST, 2011. Suspended sediment load estimate using support vector machines in Kaoping River basin. Pp. 494-499. *Proceeding of International Conference on Consumer Electronics, Communications and Networks*. 16-18 April, XianNing, China.
- Kakaei Lafdani E, Moghaddam Nia A and Ahmadi A, 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology* 478: 50-62.
- Kecman V, 2001. *Learning and Soft Computing: Support Vector Machines*. Neural Networks and Fuzzy Logic Models. MIT Press, Cambridge, Massachusetts, London, England.
- Khorshiddoost AM, Feyzallohpour M and Sadrafshari S, 2015. Evaluation of the functionality of the neural fuzzy inference system model (anfis) in estimating sediment load and comparison with two types of artificial neural network models case study: Zarinéhroud river, southeast basin, Urmia lake. *Geography and Development Quarterly* 13(41): 185-200.
- Kisi O and Shiri J, 2012. River suspended sediment estimation by climatic variables implication comparative study among soft computing techniques. *Computers & Geosciences* 43: 73-82.
- Kisi O, 2005. Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrological Sciences Journal* 50(4): 683-696.
- Kisi O, 2012. Modelling discharge-suspended sediment relationship using least square support vector machine. *Journal of Hydrology* 456: 110-120.
- Kisi O, Haktanir T, Ardicioglu M, Ozturk O, Yalcin E and Uludag S, 2009. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Advances in Engineering Software* 40(6): 438-444.
- Kisi O, Karahan ME and Sen Z, 2006. River suspended sediment modeling using fuzzy logic approach. *Hydrological Processes* 20(20): 4351-4362.
- Koch RW and Smillie GM, 1986. Comment on "River loads underestimated by rating curves" by R. I. Ferguson. *Water Resource Research* 22: 2121-2122.
- Kumar D, Pandey A, Sharma N and Flugel WA, 2016. Daily suspended sediment simulation using machine learning approach. *Catena* 138: 77-90.
- Kumar M and Kar IN, 2002. Non-linear HVAC computations using least square support vector machines. *Energy Conversion Management* 50: 1411-1418.
- Lohani A K, Goel NK and Bhatia KKS, 2007. Deriving Stage- discharge- sediment concentration relationships using fuzzy logic. *Hydrological Sciences Journal* 52(4): 793-807.
- Maheswaran R and Khosa R, 2012. Wavelet-Volterra coupled model for monthly stream flow forecasting. *Journal of Hydrology* 450: 320-335.
- Misra D, Oommen T, Agarwal A, Mishra SK and Thompson AM, 2009. Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering* 103: 527-535.
- Moayeri MM, Nikpoor MR, Hoseinzadehdalir A and Farsadizadeh D, 2010. Comparison of artificial neural networks, adaptive neuro-fuzzy and sediment rating curve models for estimating suspended sediment load of Ajichay river. *Water and Soil Science- University of Tabriz* 20:1(2): 71-82.

- Nourani V and Andalib G, 2015. Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches. *Journal of Mountain Science* 12(1): 85-100.
- Nourani V, Alizadeh F and Roushangar K, 2015. Evaluation of a two-Stage SVM and spatial statistics methods for modeling monthly river suspended sediment load. *Water Resource Management* 30(1): 393-407.
- Rezaeibanafshe M, Feyzallohpour M and Sadrafshari S, 2013. Estimating sediment load using of neural fuzzy inference system and comparing with MLR and SRC models in the area of the Qaranko River. *Natural Geography Research* 45(2): 77-90.
- Roshangar K and Hakimi D, 2017. Estimation of bed load rate of a gravel bed river using evolutionary systems and classic methods. *Water and Soil Science- University of Tabriz* 27(1): 187-197.
- Samantaray S and Ghose D, 2018. Evaluation of suspended sediment concentration using descent neural networks. *Procedia Computer Science* 132: 1824-1831.
- Seyedian M and Rouhani H, 2015. Assessing ANFIS accuracy in estimation of suspended sediments. *Gradevinar* 67(12): 1165-1176.
- Sharma N, Zakaullah MD, Tiwari H and Kumar D, 2015. Runoff and sediment yield modeling using ANN and support vector machines: a case study from Nepal watershed. *Modeling Earth Systems and Environment* 1(23): 1-8.
- Shu-gang C, Yan-bao L and Yan-ping W, 2008. A forecasting and forewarning model for methane hazard in working face of coal mine based on LS-SVM. *Journal of China University Mining Technology* 18: 0172–0176.
- Sivapragasam C, Liong SY and Pasha MFK, 2001. Rainfall and runoff forecasting with SSA–SVM approach. *Journal of Hydroinformatics* 3(3): 141–152.
- Smola A, 1996. Regression Estimation with Support Vector Learning Machines. Technics Universitat Munchen: Munich, Germany.
- Suykens JAK and Vandewalle J, 1999. Least square support vector machine classifiers. *Neural Processing Letters* 9(3): 293–300.
- Tananaev N, 2015. Fitting sediment rating curves using regression analysis: a case study of Russian arctic rivers. Pp. 213-224. *Proceedings of Sediment Dynamics from the Summit to the Sea*. 3-5 December, Louisiana, USA.
- Ulke A, Tayfur G and Ozkul S, 2009. Predicting suspended sediment loads and missing data for Gediz river, Turkey. *Journal of Hydrologic Engineering* 14(9): 954-965.
- Vapnik VN, 1995. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York.
- Varvani J and Khalighisigaroodi Sh, 2007. Investigating the error rate of sediment gauge curves for estimating sediment load of flood events in Gharacheh. *New Agricultural Findings* 1(3): 201-214.
- Varvani J, Najafinejad A and Mirmoeinikarheroodi A, 2008. Modification of sediment scale curve using minor variance unbiased method. *Journal of Agricultural Science and Natural Resources* 15(1): 27-41.
- Walling DE and Webb BW, 1988. The reliability of rating curve estimates of suspended sediment yield: some further comments. Pp. 337-350. *Proceedings of the Sediment Budgets (Proceedings of the Porto Alegre Symposium)*. 5-7 December, Devon, UK.
- Yang CT, 1996. *Sediment Transport: Theory and Practice*. McGraw-hill, New York.
- Zounemat-Kermani M, Kisi O, Adamowski J and Ramezani A, 2016. Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology* 535: 457-472.