

Total Dissolved Solids modeling using machine learning algorithms in periods of low and high water (Case study: Khorramabad, Biranshahr and Alashtar watersheds, Lorestan Province)

Nasrin Beiranvand^{ORCID} | Alireza Sepahvand*^{ORCID} | Ali Haghizadeh^{ORCID}

Department of Range and Watershed Management, Faculty of Natural Resources, Lorestan University, Lorestan, Iran.
E-mail: sepahvand.a@lu.ac.ir

Article Info

Article type:
Research Article

Article history:
Received: 19 Nov. 2022
Revised: 9 Feb. 2023
Accepted: 28 May. 2023
Published online: 21 Nov. 2023

Keywords:
Kashkan Watershed,
Total Dissolved Solids (TDS),
Flow Duration Curve (FDC),
Gaussian process,
Random Forest.

Abstract

In this study, five soft computing techniques, GP-PUK, GP-RBF, M5P, REEP Tree and RF, were used to predict the solute load (SL) in hydrometry stations, namely Cham Anjir, Bahram Joo, Kaka Reza, and Sarab Syed Ali, located in the Khorramabad, Biranshahr, and Alashtar sub-watersheds of Lorestan province. The total dataset consisted of rain, discharge, and SL data from three sub-watersheds. Among these, 70% of the data was used for the training phase, while 30% was allocated for testing. Finally, the accuracy of the models was assessed using three performance evaluation parameters: Correlation Coefficient (C.C.), Root Mean Square Error (RMSE), and Maximum Absolute Error (MAE). The results suggest that the GP-PUK and GP-RBF models outperformed other modeling approaches in estimating the SL during both low and high water periods. Specifically, the GP-RBF model was selected as the optimal model with the highest C.C. and the lowest error for estimating the SL in Cham Anjir, Sarab Said Ali, and Kaka Reza stations during the high-water period, while the GP-PUK model was deemed optimal for the Bahram Joo station. Similarly, during the low-water period, the GP-RBF model was the best choice for Cham Anjir, Sarab Said Ali, and Bahram Joo stations, while the GP-PUK model was found to be the most suitable for the Kaka Reza station. Therefore, these models can be used to estimate the solute load of nearby rivers with or without hydrometry stations, thereby facilitating the management of surface water quantity and quality.

Cite this article: Beiranvand, N., Sepahvand, A., Haghizadeh, A. (2023). Total Dissolved Solids modeling using machine learning algorithms in periods of low and high water (Case study: Khorramabad, Biranshahr and Alashtar watersheds, Lorestan Province). *Journal of Range & Watershed Management*, 76 (3), 215-236.

DOI: <http://doi.org/10.22059/jrwm.2023.351372.1684>



© The Author(s).

Publisher: University of Tehran Press

مدل سازی رسوب انحلالی با استفاده از الگوریتم های یادگیری ماشین در دوره های کم آبی و پربابی (مطالعه موردی: حوضه های آبخیز خرم آباد، بیرانشهر و الشتر، استان لرستان)

نسرین بیرانوند ^{id} | علیرضا سپهوند* ^{id} | علی حقی زاده ^{id}

گروه مهندسی مرتع و آبخیزداری، دانشکده منابع طبیعی، دانشگاه لرستان، لرستان، ایران.
رایانامه: sepahvand.a@lu.ac.ir

چکیده

اطلاعات مقاله

این تحقیق با استفاده از الگوریتم های یادگیری ماشین به بررسی کارایی مدل های RF, RepTree, GP-PUK, GP-RBF, MSP برای مدل سازی بارانحلالی در زیرحوضه های خرم آباد، بیرانشهر و الشتر در استان لرستان پرداخته شد. داده های ورودی شامل بارش، دبی، دبی یک روز قبل، میانگین دبی (دبی همان روز و یک روز قبل) همچنین داده خروجی رسوب انحلالی رودخانه ها می باشد. در این تحقیق برای مدل سازی در مرحله آموزش ۷۰ درصد داده ها و در مرحله آزمایش ۳۰ درصد باقی مانده مورد استفاده قرار گرفتند. در نهایت برای مقایسه نتایج مدل های مختلف و انتخاب بهترین مدل، از معیارهای سنجش خطای ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی (C.C) و میانگین مربعات خطا (MAE) استفاده شد. نتایج نشان داد با توجه به معیارهای ارزیابی مدل GP با دو تابع کرنل PUK و RBF در دوره پربابی و کم آبی عملکرد بهتری را نسبت به سایر مدل ها داشته است. نتایج به دست آمده در دوره پربابی نشان داد که در ایستگاه های چمانجیر، سراب صیدعلی و کاکارضا مدل GP-RBF و در ایستگاه هیدرومتری بهرام جو مدل GP-PUK با بیشترین ضریب همبستگی و کمترین خطا در مرحله آزمایش به عنوان مدل های بهینه برای تخمین بار انحلالی انتخاب شدند. همچنین در ایستگاه های هیدرومتری بهرام جو، چمانجیر و سراب صیدعلی مدل GP-RBF و در ایستگاه هیدرومتری کاکارضا مدل GP-PUK به عنوان مدل بهینه برای تخمین بار انحلالی در دوره کم آبی انتخاب شدند. بنابراین، با توجه به نتایج به دست آمده، می توان برای مدیریت کیفیت و کمیت منابع آب سطحی از مدل های بهینه GP-RBF و GP-PUK برای تخمین بار انحلالی رودخانه های فاقد ایستگاه هیدرومتری در حوضه های کارستی استفاده کرد.

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت: ۱۴۰۱/۰۸/۲۸

تاریخ بازنگری: ۱۴۰۱/۱۱/۲۰

تاریخ پذیرش: ۱۴۰۲/۰۳/۰۷

تاریخ انتشار: ۱۴۰۲/۰۸/۳۰

کلیدواژه ها:

حوزه آبخیز کشکان،

بار انحلالی،

منحنی تلاوم جریان،

فرآیند گوسی،

جنگل تصادفی.

استناد: بیرانوند؛ نسرین، سپهوند؛ علیرضا، حقی زاده؛ علی (۱۴۰۲). مدل سازی رسوب انحلالی با استفاده از الگوریتم های یادگیری ماشین در دوره های کم آبی و پربابی (مطالعه موردی: حوضه های آبخیز خرم آباد، بیرانشهر و الشتر، استان لرستان). نشریه مرتع و آبخیزداری، ۷۶(۳)، ۲۳۶-۲۱۵.

DOI: <http://doi.org/10.22059/jrwm.2023.351372.1684>



© نویسندگان.

ناشر: انتشارات دانشگاه تهران.

۱. مقدمه

برای توصیف نوع خاصی از مناظر روی کره زمین همانند غارها، واژه کارست^۱ مورد استفاده قرار می‌گیرد که این پدیده در اثر تأثیر انحلالی آب زیر زمینی بر روی سنگ بستر انحلال‌پذیر همانند سنگ آهک، سنگ گچ و هالیت توسعه پیدا می‌کند (فورد و ویلیام^۲، ۲۰۰۷؛ سپهوند و همکاران، ۲۰۱۹). بنابراین در مناطق کارستی اشکال بسیار متنوع از ناهمواری‌ها (فرسایش و رسوب‌گذاری از ابعاد میکرو تا ماکرو) دیده می‌شوند که این عوارض طبیعی سه بعدی منحصر به فرد، نتیجه اثر متقابل بین زمین‌شناسی، آب و هوا، توپوگرافی، هیدرولوژی و موجودات زنده در یک مقیاس زمانی طولانی می‌باشد (مه‌دوی، ۲۰۰۷؛ سپهوند و همکاران، ۲۰۱۹). ایجاد و گسترش کارست در سنگ‌های انحلال‌پذیر به مقاومت توده سنگ در برابر هوازدگی شیمیایی وابسته است که با شدت‌های متفاوتی عمل می‌کند که شدت آن به شرایط محیطی و خصوصیات توده سنگ بستگی دارد (سپهوند و همکاران، ۲۰۱۹). مواد انحلالی متفاوت و زیادی در آب وجود دارند که برخی از آن‌ها غیر طبیعی بوده و ناشی از ورود فاضلاب‌های شهری و یا سموم و کودهای کشاورزی می‌باشند. مطالعه این مواد مانند نیترات‌ها و نیتریت‌ها می‌تواند سیکل مواد از نظر اکولوژی آب و یا وضعیت آلودگی آب‌ها را مشخص سازد. علاوه بر این، در ژئوشیمی آب‌ها و فرسایش انحلالی، بررسی این مواد از ملزومات یک مطالعه است. در بعضی از مناطق، ممکن است وزن مواد حمل شده انحلالی حتی بیشتر از وزن مواد حمل شده معلق باشد (مه‌دوی، ۲۰۰۷؛ سپهوند و همکاران، ۲۰۱۹). زمانی که یک سنگ در آب حل می‌شود مواد معدنی مختلف سنگ وارد آب می‌شوند و در نتیجه مطالعه مواد محلول به جای سنگ‌دانه‌ها ضرورت دارد (فورد و ویلیام، ۲۰۰۷). بار انحلالی رودخانه در مناطق کارستی سهم زیادی در کاهش حجم سدها و همچنین کاهش کیفیت آب منطقه دارد. بنابراین، بررسی و پیش‌بینی رسوب انحلالی رودخانه‌ها نقش مهمی در مدیریت کیفیت و کمیت منابع آب سطحی دارد. همچنین تعیین توالی دوره‌های خشک و مرطوب دارای اهمیت زیادی در مطالعات مرتبط با مدیریت منابع آب به‌خصوص در مناطق خشک و نیمه‌خشک می‌باشد. به دلیل پیچیدگی‌های موجود در پدیده‌های هیدرواقلمی، درک آن در مقایسه با سایر بلایای طبیعی دشوارتر بوده (انصاری و داوری، ۲۰۰۸؛ مصطفی‌زاده و قوی‌دل، ۲۰۱۶) و مسلماً به اطلاعات بیشتر و کامل‌تر به منظور مدیریت چالش‌های منابع آبی ناشی از وقوع دوره‌های خشک در یک منطقه نیاز است. از جمله کاربردهای تعیین دوره‌های مرطوب می‌توان به بررسی عوامل آلودگی منابع آب، توصیف کمی خشک‌سالی، سیل‌خیزی و پیش‌بینی و ارزیابی وقوع سیل‌ها اشاره کرد (بازپهیر^۳ و همکاران، ۱۹۹۷). یکی از روش‌هایی که برای تعیین دوره‌های کم آب و پر آبی مور استفاده قرار می‌گیرد، روش منحنی تداوم جریان^۴ (FDC) می‌باشد. نخستین مطالعه جامع بر روی منحنی تداوم جریان را سارسی^۵ در سال ۱۹۵۹ میلادی انجام داد. منحنی تداوم جریان یکی از روش‌های ارزنده است که همه دبی‌های رودخانه اعم از کم و جریان سیلابی را نمایش می‌دهد. این منحنی رابطه بین مقادیر دبی و درصد زمانی را (که این دبی مساوی یا بیش‌تر از آن است)، به نمایش می‌گذارد. به عبارت دیگر، رابطه بین بزرگی و فراوانی دبی رودخانه را نشان می‌دهد (اسمختین^۶، ۲۰۰۱). روش‌های زیادی برای پیش‌بینی بار انحلالی رودخانه در شرایط مختلف کم‌آبی و پرآبی وجود دارند که یکی از این روش‌ها، استفاده از مدل‌های مبتنی بر هوش مصنوعی می‌باشد. الگوریتم‌های یادگیری ماشین از جمله مدل‌های مبتنی بر هوش مصنوعی هستند که در طیف وسیعی از مسائل مرتبط با طبیعت مورد استفاده قرار می‌گیرند. مدل‌های یادگیری از نظر به کارگیری الگوریتم‌های تخمین و توزیع، طبیعت داده محور و تکرار بالای فرآیند مدل‌سازی، توانایی بالایی در شناسایی رفتار وقوع پدیده مورد نظر داشته و در تحقیقات علمی زیادی برتری خود را نسبت به دیگر مدل‌های آماری دو متغیره و چند متغیره اثبات نموده‌اند. همچنین مدل‌های مختلفی مبتنی بر الگوریتم‌های یادگیری ماشین توسعه یافته‌اند که در موارد مختلف مدل‌سازی و پیش‌بینی مورد استفاده قرار می‌گیرند (سان^۷ و همکاران، ۲۰۱۱). در ارتباط با رسوب انحلالی رودخانه، در ایران و سایر نقاط جهان تحقیقاتی انجام شده است که از جمله می‌توان به تحقیقات زیر اشاره کرد.

1 Karst

2 Ford and Williams

3 Bazuhair

4 Flow Duration Curve

5 Searcy

6 Smakhtin

7 Sun

اسدی و همکاران (۲۰۲۱) به پیش‌بینی بار محلول رودخانه با استفاده از مدل‌های ماشین یادگیری و پارامترهای ژئومرفومتری در ۶۸ زیرحوضه استان گیلان و لرستان پرداختند. آنها در تحقیق خود برای تخمین حداقل و متوسط بار انحلالی رودخانه از فاکتورهای ژئومرفومتری و الگوریتم‌های SVM، GP، KNN، ANN، MLR و SVM استفاده کردند. نتایج نشان داد که همه الگوریتم‌ها می‌توانند تخمینی با دقت بالا از حداقل و متوسط بار انحلالی داشته باشند که در نهایت الگوریتم‌های GP و SVM به ترتیب به عنوان الگوریتم‌های بهینه برای تخمین میزان متوسط و حداقل بار انحلالی رودخانه انتخاب شدند.

سپه‌وند و همکاران (۲۱۲۱) به بررسی بارمحلول حوزه‌های کارستی جنوب غرب ایران پرداختند. در این تحقیق از داده‌های نمونه‌برداری شده بارمحلول یک سال آبی مورد بررسی قرار گرفتند. در این تحقیق نمونه برداری بار محلول در یک دوره ۱۲ ماهه انجام شد و سپس داده‌های اندازه‌گیری شده مورد بررسی قرار گرفتند. نتایج نشان داد که املاح Ca ، Mg و HCO_3 نشان دهنده خصوصیات کارستی سازندهای زمین‌شناسی منطقه است. همچنین نتایج نشان داد که میزان فرسایش انحلالی در منطقه بین ۰/۰۱ تا ۰/۰۴ میلی‌متر در سال است. علاوه بر این، مقایسه بین بارمحلول و معلق نشان داد که میزان بار محلول این حوضه‌ها بیشتر از بارمعلق است.

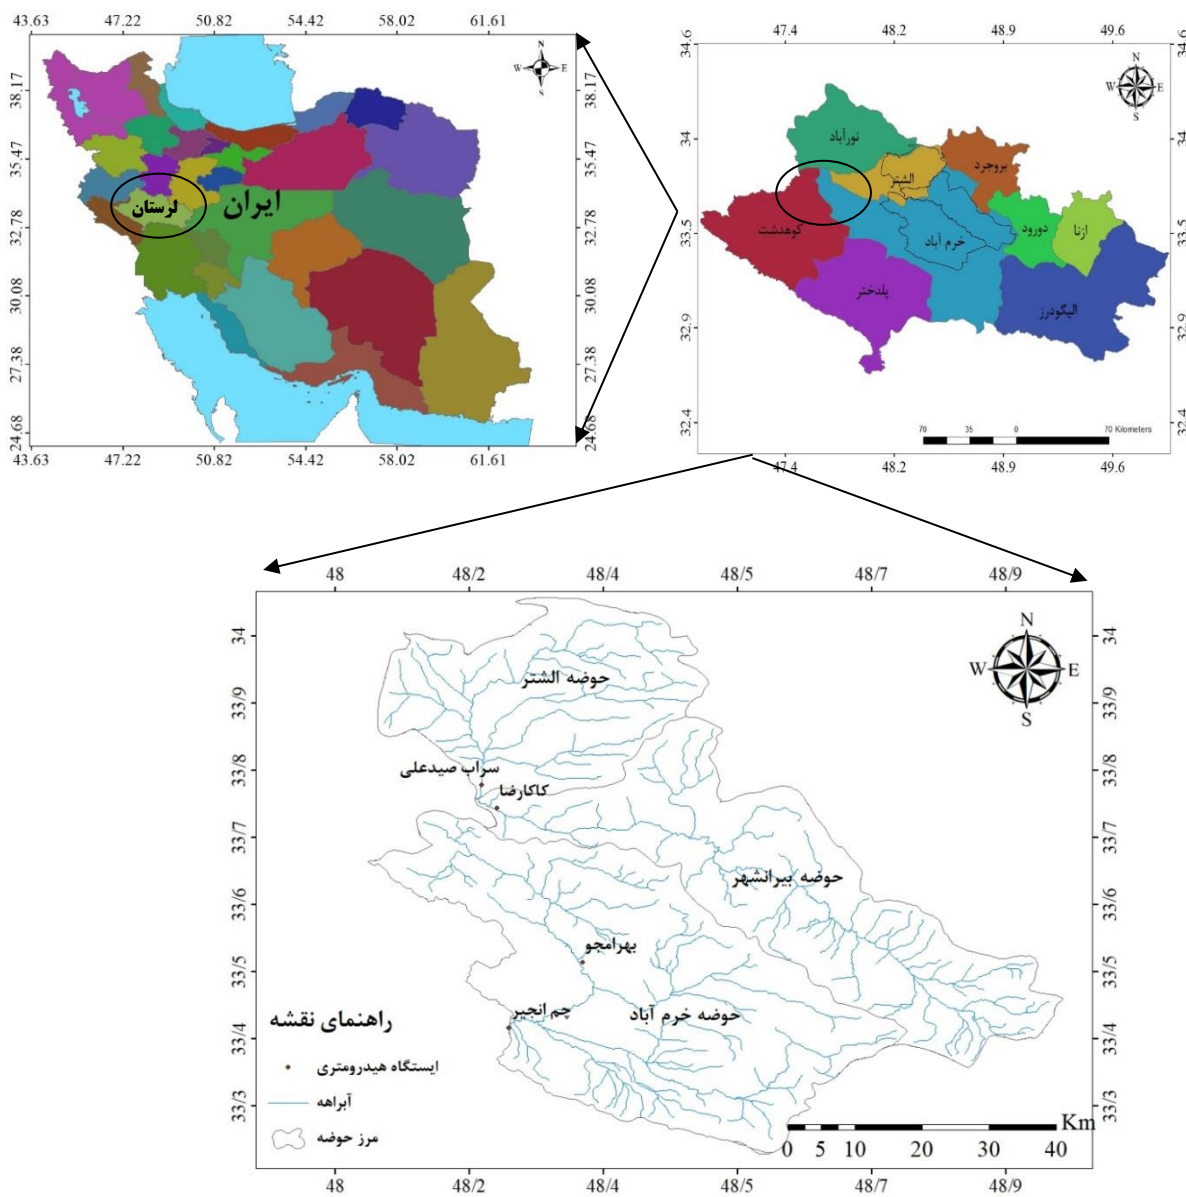
سپه‌وند و همکاران (۲۰۲۰) به مطالعه تغییرات فصلی بار رسوب انحلالی و تعیین سرعت انحلال پذیری سازندهای آهکی در حوزه‌های آبخیز خرم‌آباد، الشتر و بیرانشهر پرداختند. ابتدا با استفاده از دستگاه سیرکوالسیون سرعت انحلال پذیری سازندهای مورد مطالعه تعیین کرده و در ادامه رسوب انحلالی هر حوزه آبخیز و بار محلول خروجی از حوزه‌های آبخیز را تعیین نمودند. نتایج نشان داد که بیشترین کمترین بارانحلالی در عرصه‌های آهکی به ترتیب در حوزه‌های آبخیز خرم‌آباد و بیرانشهر مشاهده شده است که میزان آن در حوزه‌های آبخیز خرم‌آباد، الشتر و بیرانشهر به ترتیب برابر $۷۵/۶۱$ ، $۴۷/۵۶$ و $۴۴/۴۹$ هزار تن در سال بوده است.

لذا با توجه به بررسی تحقیقات انجام شده مشخص شد تاکنون از الگوریتم‌های یادگیری ماشین برای تخمین و پیش‌بینی بار انحلالی در دوره‌های پر آبی و کم‌آبی رودخانه‌های مناطق کارستی زاگرس در استان لرستان انجام نشده است و بر این اساس نوآوری تحقیق استفاده از الگوریتم‌های یادگیری ماشین برای پیش‌بینی بار انحلالی رودخانه می‌باشد. در نتیجه هدف این تحقیق، بررسی کارایی برخی الگوریتم‌های یادگیری ماشین برای مدل‌سازی بار انحلالی رودخانه با تاکید بر دوره‌های خشک و مرطوب در رودخانه‌های کارستی حوضه‌های خرم‌آباد، الشتر و بیرانشهر و الشتر می‌باشد.

۲. مواد و روش‌ها

۲-۱. منطقه مورد مطالعه

حوزه‌های آبخیز خرم‌آباد، الشتر و بیرانشهر از نظر ژئومورفولوژیکی در بخش مرکزی سلسله جبال زاگرس در استان لرستان قرار دارند که خود بخشی از حوزه آبخیز کشکان هستند. حوزه‌های آبخیز خرم‌آباد، الشتر و بیرانشهر در مجموع با مساحت ۳۵۷۶ کیلومتر مربع مطابق شکل ۱ بین طول‌های جغرافیایی $۴۸\ ۰۴\ ۰۲''$ تا $۴۸\ ۵۹\ ۰۷''$ شرقی و عرض‌های $۳۳\ ۱۶\ ۰۵''$ تا $۳۴\ ۰۱\ ۰۷''$ شمالی قرار دارند. بلندترین نقطه در بخش شمالی با ارتفاع ۳۵۷۸ متر و پست‌ترین نقطه در بخش غربی، یعنی خروجی حوزه آبخیز با ارتفاع ۱۱۵۸ متر از سطح دریا قرار دارد. میانگین بارندگی سالانه منطقه بین ۴۰۰ تا ۵۰۰ میلی‌متر بوده و دارای اقلیم نیمه‌خشک و سرد است (سپه‌وند و همکاران، ۲۰۱۹). منطقه مورد مطالعه عمدتاً توسط سازندهای کارستی پوشیده شده است. از مجموع کل مساحت منطقه، آهک و دولومیت ۱۲۶۲ کیلومتر مربع (۳۵/۳ درصد)، دیگر سنگ‌های کربناته از جمله مارن ۷۰۹ کیلومتر مربع (۱۹/۸۲ درصد)، رسوبات کواترنری ۱۴۹۶ کیلومتر مربع (۴۱/۸۳ درصد)، سازندهای تبخیری ۱۴ کیلومتر مربع (۰/۴ درصد) و حدود ۹۵ کیلومتر مربع (۲/۶۵ درصد) توسط سازندهای غیر کارستی و غیر کواترنری پوشیده شده است (سپه‌وند و همکاران، ۲۰۲۱). همچنین منطقه مورد مطالعه دارای کاربری اراضی مسکونی (۱/۴۶ درصد)، کشاورزی (۵۰/۳۱ درصد)، مرتع (۲۲/۹۴ درصد) و اراضی جنگلی (۲۴/۶۳ درصد) می‌باشد. در جدول ۱ مشخصات جغرافیایی ایستگاه‌های مختلف مورد مطالعه نشان داده شده است.



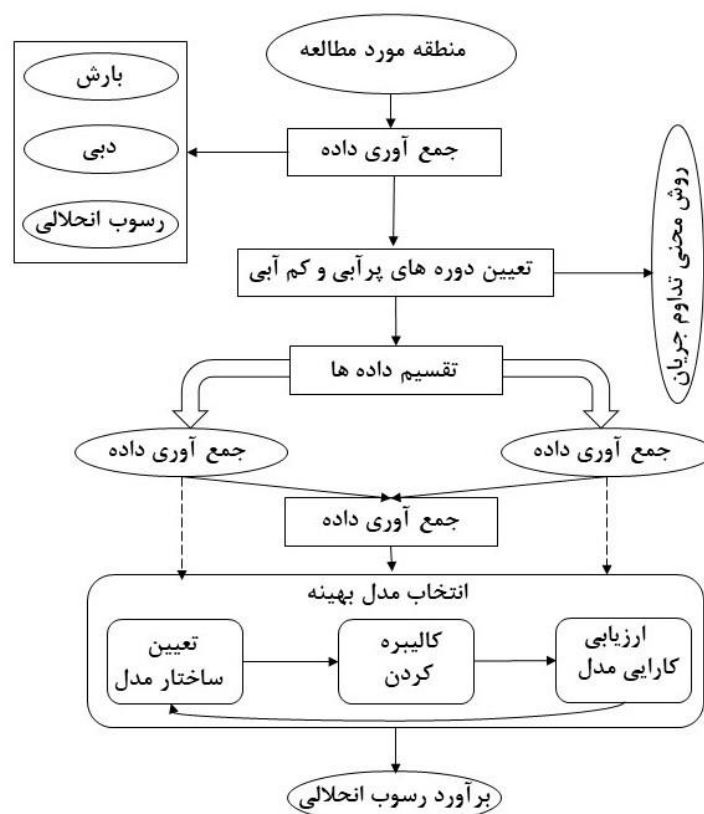
شکل ۱. نقشه موقعیت جغرافیایی منطقه مورد مطالعه در استان لرستان و ایران

جدول ۱. مشخصات جغرافیایی ایستگاه‌های مورد مطالعه

ردیف	نام ایستگاه	طول جغرافیایی	عرض جغرافیایی	محل
۱	بهرام‌جو	۴۸ ۱۷	۳۳ ۳۴	قبل از خروجی
۲	چم‌انجیر	۴۸ ۱۲	۳۳ ۵۲	خروجی
۳	کاکارضا	۴۸ ۱۵	۳۳ ۴۲	خروجی
۴	سراب صیدعلی	۴۸ ۱۵	۳۳ ۳۰	خروجی

۲-۲. روش کار

این تحقیق در چند مرحله، مطابق نمودار جریانی شکل ۲ انجام شده است. ابتدا با مراجعه به اداره کل هواشناسی و شرکت آب منطقه‌ای استان لرستان بانک اطلاعاتی داده‌های مورد نیاز در یک دوره زمانی سال آبی ۱۳۷۹-۱۳۸۰ تا ۱۳۷۰-۱۳۹۶ تهیه شد. در ابتدا داده‌ها جهت استفاده در فرآیند مدل‌سازی بر اساس رابطه ۱ نرمال‌سازی شدند (ملسی^۱ و همکاران، ۲۰۲۰؛ میرهاشمی و همکاران، ۲۰۲۰).



شکل ۲. نمودار جریانی مراحل پژوهش

$$X_{new} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (\text{رابطه ۱})$$

که در آن: X_{new} مقدار داده نرمال شده در محدوده ۰ تا ۱، X مقدار داده مشاهداتی، X_{min} کمترین مقدار داده مشاهداتی و X_{max} بیشترین مقدار داده مشاهداتی است.

۲-۲-۱. منحنی تداوم جریان

در این پژوهش بر اساس مدل‌سازی رسوب انحلالی در دوره‌های پرآبی و کم‌آبی رودخانه‌ها، از منحنی تداوم جریان جهت جدا شدن دوره‌های پرآبی و کم‌آبی استفاده شد. در این تحقیق، مقدار دبی ۵۰ درصدی از منحنی تداوم جریان به عنوان حد آستانه بین کم‌آبی و پرآبی در نظر گرفته شد. به این صورت که دبی‌های بالاتر از این میزان دوره پرآبی و مقدار کمتر از آن دوره کم‌آبی را تشکیل دادند. لازم

به ذکر است که در تحقیقات دیگر حد ۴۰ تا ۶۰ درصدی منحنی تداوم جریان را به عنوان شرایط متوسط در نظر گرفته‌اند که این بخش از منحنی تداوم جریان در برگرفته دبی برای شرایط متوسط می‌باشد (چاهوکی و همکاران، ۲۰۱۳). بر این اساس در این تحقیق از میانگین این حدود، حد آستانه ۵۰ درصدی منحنی تداوم جریان برای تفکیک دوره‌های پربابی و کم‌آبی مد نظر قرار گرفت.

۲-۲-۲. مجموعه داده‌های استفاده شده برای مدل‌سازی

داده‌های استفاده شده برای مدل‌سازی در این پژوهش شامل دو گروه داده‌های ورودی و داده‌های خروجی می‌باشند. داده‌های ورودی در این پژوهش شامل، بارش (R)، دبی همان روز (Q_t)، دبی یک روز قبل (Q_{t-1})، میانگین دبی (دبی همان روز و دبی روز قبل) (AVQ_t) و داده‌های خروجی شامل مقادیر رسوب انحلالی در بازه زمانی ۱۹ ساله (از سال ۷۹-۸۰ تا ۹۶-۹۷) رودخانه است. لازم به ذکر است که این پارامترهای ورودی هر کدام به طریقی بر افزایش بارانحلالی رودخانه تأثیرگذار می‌باشند. به‌طور کلی، وجود محلول برای انحلال و ایجاد رخساره‌های کارستی لازم است که می‌توان بیان کرد که وجود بارانحلالی رودخانه و تشکیل رخساره‌های کارستی نتیجه اثرمتقابل بین زمین‌شناسی، آب و هوا، هیدرولوژی و توپوگرافی است (فورد و ویلیام، ۲۰۰۷). لذا بارش که یکی از پارامترهای آب و هواست با برخورد به سنگ‌های آهکی باعث ایجاد رسوب انحلالی و تشکیل رخساره‌های ریزمقیاس کارستی از جمله کارنها روی سنگ‌های انحلال‌پذیر می‌شود که در منطقه مورد مطالعه این رخساره‌ها به وفور دیده می‌شوند. همچنین در منطقه با افزایش دبی جریان بحث چرخش آب یا سیرکولاسیون آب بر روی سنگ‌های آهکی بیشتر شده و در نتیجه تأثیر معنی‌داری بر روی انحلال سنگ‌های آهکی و افزایش بارانحلالی رودخانه دارد (فورد و ویلیام، ۲۰۰۷؛ سپه‌وند و همکاران، ۲۰۲۰). در نتیجه در منطقه مورد مطالعه، بزرگی دبی همان روز و دبی روز قبل باعث بزرگی میانگین دبی محاسبه شده می‌شود که با افزایش مدت تماس آب با سنگ و افزایش سرعت جریان، باعث افزایش بارانحلالی رودخانه می‌گردد. ابتدا آزمون خود همبستگی (MCT)^۱ برای تعیین همبستگی درونی بین متغیرها از طریق دو فاکتور VIF ^۲ و TOL ^۳ انجام شد. در این پژوهش از ۷۰ درصد کل داده‌ها (دوره ۱۳۹۱-۱۳۷۹) برای آموزش و از ۳۰ درصد باقی‌مانده (دوره ۱۳۹۷-۱۳۹۲) برای آزمایش مدل استفاده شد. در این پژوهش برای مدل‌سازی از مدل‌های GP-PUK، GP-RBF، M5P Tree، REP Tree و RF توسط نرم‌افزار Weka 3.9 استفاده شد. از دلایل انتخاب این الگوریتم‌های برای مدل‌سازی، اجرای سریع و همچنین عدم اجرا در گذشته در منطقه مورد مطالعه برای مدل‌سازی بارانحلالی دوره‌های کم‌آبی و پربابی می‌باشد. در ادامه توضیح مختصری در مورد این مدل‌ها آورده شده است.

۲-۲-۳. الگوریتم درخت تصمیم^۴ REP Tree

مدل REPTree، یک مدل از مجموعه درخت تصمیم (DT^5) است که برای رفع مشکلات طبقه‌بندی و رگرسیون کارآمد است (کوئینلان^۶، ۱۹۹۲). الگوریتم REPTree یک درخت رگرسیون تصمیم است که به‌وسیله تقسیم و هرس کردن درخت رگرسیون، تصمیم را براساس بالاترین اطلاعات مقدار سود (IGR^7)، تشکیل می‌دهد، که مقدار IGR بر اساس تابع آنتروپی (E) و مطابق رابطه^(۲) محاسبه شده است (خسروی و همکاران، ۲۰۱۸).

$$IGR(T, a) = \frac{H(T) - H(T|a)}{-\sum_{i=1}^n \frac{N(t_i)}{N(t)} \log_2 \frac{N(t_i)}{N(t)}} \quad (\text{رابطه } ۲)$$

- 1 Multi-collinearity test
- 2 Variance Inflation Factor
- 3 TOLerance
- 4 Reduced Error Pruning Tree
- 5 Decision Tree
- 6 Quinlan
- 7 Information Gain Ratio

که در آن: T ضریب تصادفی، $H(T|a)$ آنتروپی T برای محاسبه خصوصیات a ، t_i زمان رویداد، $N(t)$ تعداد کل رخدادها و IGR اطلاعات مقدار سود می‌باشد.

۲-۲-۴. الگوریتم درخت تصمیم M5P Tree

یکی از رایج‌ترین الگوریتم‌های مدل درخت تصمیم، الگوریتم M5P است. این الگوریتم اولین بار توسط کوئینلن در سال ۱۹۹۲ پیشنهاد شد (کوئینلن، ۱۹۹۲). سپس الگوریتم M5P که در واقع بازسازی منطقی و توسعه‌یافته از M5 است، توسط ونگ و ویتن در سال ۱۹۹۷ معرفی شد (وانگ و ویتن، ۱۹۹۷). این مدل یکی از روش‌های نسبتاً جدید و قدرتمند هوش مصنوعی است که به علت قابلیت مناسب آن، توسط محققان مختلفی مورد استفاده قرار گرفته است. سادگی محاسبه‌ها و دقت نتایج از مهم‌ترین ویژگی‌های این مدل است (بناکدار و اعتماد شهیدی، ۲۰۱۱). کاهش انحراف معیار (SDR)^۲ مطابق رابطه (۳) محاسبه شده است (میرهاشمی و همکاران، ۲۰۱۹).

$$SDR = sd(T) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (\text{رابطه ۳})$$

که در آن: T بیانگر یکسری نمونه‌هایی است که به گره می‌رسند، T_i بیانگر یکسری نمونه‌هایی است که i امین برآمد تست پتانسیلی را دارند، sd بیانگر انحراف معیار و SDR کاهش انحراف معیار می‌باشد.

۲-۲-۵. الگوریتم تابعی فرآیند گوسی^۳

فرآیند گوسی مجموعه‌ای از متغیرهای تصادفی است که تعداد محدودی از آن‌ها با توزیع‌های گوسی ادغام شده‌اند. توزیع گوسی در واقع توزیع بین متغیرهای تصادفی بوده، در حالی که فرآیند گوسی بیانگر توزیع بین توابع می‌باشد که اولویت‌بندی متغیرها را انجام می‌دهد (صمدیان فرد و همکاران، ۲۰۲۰؛ یانگ^۴ و همکاران، ۲۰۱۸). مدل‌های فرآیند گوسی به دلیل دانش قبلی درباره وابستگی‌های تابعی و داده‌ها، برای تعمیم به هیچ فرآیند اعتبارسنجی نیاز ندارند و قادر به درک توزیع پیش‌بینی متناظر با ورودی آزمون‌ها می‌باشند (پال و دسوال^۵، ۲۰۱۰). تابع فرآیند گوسی $f(x)$ می‌تواند به صورت رابطه (۴) بیان شود (صمدیان فرد و همکاران، ۲۰۲۰).

$$f(x) \sim GP(m(x), k(x, x')) \quad (\text{رابطه ۴})$$

که در آن: GP فرآیند گوسی، $m(x)$ تابع میانگین بوده که معمولاً جهت ساده سازی برابر صفر در نظر گرفته می‌شود، $k(x, x')$ تابع کواریانس در نقاط x و x' و $f(x)$ ، تابع فرآیند گوسی می‌باشد.

۲-۲-۶. الگوریتم درخت تصمیم جنگل تصادفی^۶

الگوریتم RF نخستین بار توسط Breiman ارائه شد و به عنوان روشی دقیق در تهیه نقشه کاربری اراضی و طبقه‌بندی تصاویر ماهواره‌ای استفاده شده است (پال^۷، ۲۰۰۵؛ پراساد^۸ و همکاران، ۲۰۰۶). الگوریتم RF شامل ترکیبی از متغیرها در هر گره برای رشد یک درخت یا

¹ Wang and Witten

² Standard Deviation Reduction

³ Gaussian Processes

⁴ Yang

⁵ Pal and Deswal

⁶ Random Forest

⁷ Pal

⁸ Prasad

استفاده از متغیر ورودی تصادفی انتخاب شده است (بریمان^۱، ۱۹۹۶). برای الگوریتم RF دو پارامتر لازم توسط کاربر تعریف شود: تعداد متغیرهای ورودی استفاده شده در هر گره برای تولید یک درخت و تعداد درختان قابل رشد در هر گره، فقط متغیرهای انتخاب شده برای بهترین تقسیم جستجو می‌شوند (سپهوند و همکاران، ۲۰۱۹؛ سپهوند و عزیززی، ۲۰۱۹).

۲-۲-۷. معیارهای ارزیابی کارایی مدل

در این پژوهش از پارامترهای ریشه میانگین مربعات خطا^۲ (RMSE)، میانگین خطای مطلق^۳ (MAE) و ضریب همبستگی^۴ (R)، برای ارزیابی دقت مدل‌ها استفاده شدند. از بین الگوریتم‌های استفاده شده، الگوریتمی که از ضریب همبستگی بالاتر، ریشه میانگین مربعات خطا و میانگین خطای مطلق نزدیک به صفر برخوردار باشد (سپهوند و همکاران، ۲۰۲۰)، به عنوان مناسب‌ترین مدل برای تعیین رسوب انحلالی رودخانه‌های مورد مطالعه انتخاب شد (رابطه‌های ۵ تا ۷). در این تحقیق برای بهینه کردن پارامترهای مدل (جدول ۳) و افزایش دقت آن از روش سعی و خطا استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O - P)^2} \quad (\text{رابطه ۵})$$

$$MAE = \frac{\sum_{i=1}^n |O_i - P_i|}{n} \quad (\text{رابطه ۶})$$

$$R = \frac{n \sum OP - (\sum O)(\sum P)}{\sqrt{n(\sum O^2) - (\sum O)^2} \sqrt{n(\sum P^2) - (\sum P)^2}} \quad (\text{رابطه ۷})$$

در روابط فوق، P مقدار برآورد شده، O مقدار مشاهده شده و n تعداد داده‌های اندازه‌گیری رسوب انحلالی است.

۳. نتایج

۳-۱. مدل‌سازی رسوب انحلالی دوره کم‌آبی و پرآبی

نتایج حاصل از منحنی تداوم جریان برای تعیین حد کم‌آبی و پرآبی هیدرولوژیکی نشان داد که در ایستگاه‌های بهرام‌جو، چمنجیر، سراب صیدعلی و کاکارضا حدود پرآبی و کم‌آبی به ترتیب برابر با ۶/۴۴، ۴/۷، ۵/۴۱ و ۴/۱۳ مترمکعب بر ثانیه بود که در ادامه تفکیک و تقسیم‌بندی داده‌های دبی جریان برای تعیین رسوب انحلالی دوره‌های پرآبی و کم‌آبی بر اساس این حدود انجام شد. نتایج کلی مدل‌سازی در این پژوهش به دو بخش، نتایج بخش رسوب انحلالی دوره کم‌آبی و رسوب انحلالی دوره پرآبی تقسیم شدند. تقسیم‌بندی به این صورت است که با توجه به داده‌های دبی برای هر سال در هر یک از ایستگاه یک دبی حد مطابق منحنی تداوم جریان تعیین شد که بعضی ماه‌های سال کم‌تر و بعضی بیش‌تر از دبی حد بودند که دبی‌های کم‌تر از دبی حد دوره کم‌آبی و دبی‌های بیش‌تر از آن در دوره پرآبی قرار می‌گیرند.

۳-۲. مدل‌سازی رسوب انحلالی دوره پرآبی

جدول ۲ خصوصیات آماری داده‌های رسوب انحلالی دوره پرآبی مربوط به مرحله آموزش و آزمایش ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد.

¹ Breiman

² Root Mean Square Error

³ Mean absolute error

⁴ Correlation Coefficient

جدول ۲. خصوصیات آماری داده‌های آموزش و آزمایش ایستگاه‌های هیدرومتری مورد مطالعه

داده‌ها	آموزش			آزمایش		
	کمترین	بیشترین	میانگین	انحراف معیار	کمترین	بیشترین
بارش	۰	۲۰۴/۵۰	۴۰/۶۲	۱۰/۲۷	۰/۰۰	۲۳۰/۰۰
دبی	۳/۴۴	۱۴۴/۳۹	۱۰/۷۶	۱۱/۸۵	۳/۵۱	۲۷/۶۱
دبی یک روز قبل	۰/۹۳	۳۵/۵۴	۸/۸۴	۲/۳۱	۰/۰۰	۴۳/۴۵
میانگین دبی (دبی همان روز و دبی روز قبل)	۲/۱۸	۷۸/۲۹	۹/۸۰	۵/۶۲	۲/۲۵	۳۴/۴۰
رسوب انحلالی	۲/۳۰	۷۹۲	۳۹۴/۰۴	۵۱/۴۷	۱۹۹۰/۰۰	۶۲۵/۰۰

* واحدها: بارش به میلی متر، دبی به متر مکعب بر ثانیه و رسوب انحلالی به میلی گرم بر لیتر

مطابق نتایج جدول ۲ مشخص شد که به ترتیب بیشترین و کمترین رسوب انحلالی در مرحله آموزش برابر ۷۹۲ و ۲۰۳ میلی گرم بر لیتر و در مرحله آزمایش به ترتیب برابر ۶۲۵ و ۱۹۹ میلی گرم بر لیتر است. نتایج آزمون خود همبستگی برای تعیین همبستگی درونی بین متغیرها نشان داد که مقدار TOL و VIF به ترتیب بین ۰/۰۶-۰/۴۲ و ۱۸/۴-۲/۳۳ متغیر بود. جدول ۳ پارامترهای بهینه برای مدل‌های مختلف در ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد. همچنین جدول ۴ نتایج عملکرد برای مدل‌های مختلف در ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد.

مطابق این جدول مشخص شد که در تمام ایستگاه‌ها، الگوریتم‌ها در بخش آموزش دارای نتایج نسبتاً مطلوبی بودند، اما در بخش آزمایش نتایج تغییرات زیادی را نشان دادند. بر این اساس، در ایستگاه بهرام‌جو نتایج مرحله آزمایش نشان داد که مدل GP-PUK با ضریب همبستگی ۰/۹۳۸، ریشه میانگین مربعات خطا ۰/۰۲ و میانگین خطای مطلق ۰/۱۳۶ در مرحله آموزش دارای بهترین عملکرد می‌باشد.

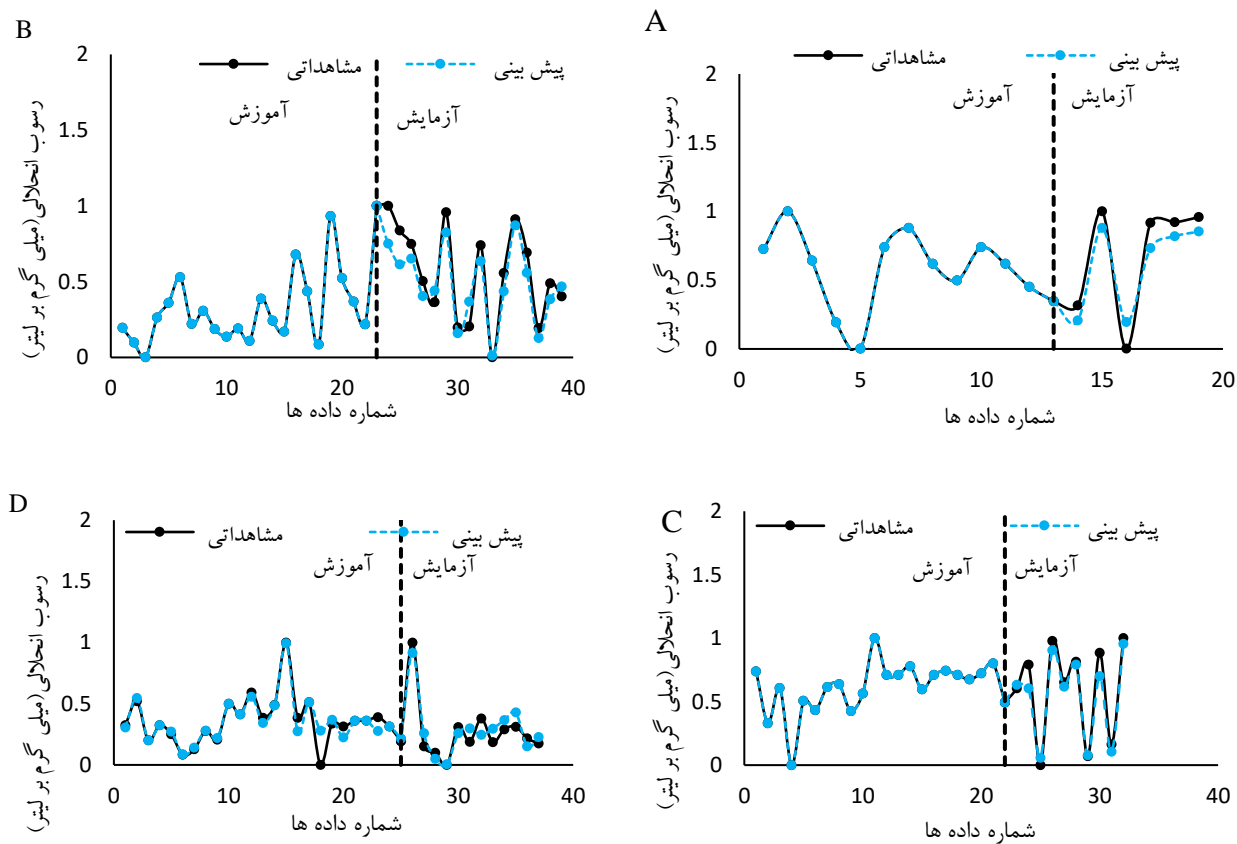
جدول ۳. پارامترهای بهینه الگوریتم‌های مختلف در دوره پرآبی

چم انجیر		بهرام‌جو	
پارامترهای بهینه	مدل	پارامترهای بهینه	مدل
Gaussian noise = 0.001, $\omega=0.9$, $\sigma=0.9$	GP-PUK	Gaussian noise = 0.001, $\omega=5$, $\sigma=3$	GP-PUK
Gaussian noise = 0.001, $\gamma=0.9$	GP-RBF	Gaussian noise = 0.1, $\gamma=1$	GP-RBF
num-decimal-places= 0, M=4	M5P	num-decimal-places= 0, M=4	M5P
M=0, V=0.001, N=3, S=1	REPTREE	M=2, V=0.001, N=3, S=1, L=1	REPTREE
K=0, M=1, V=0.001, S=1	RF	K=0, M=1, V=0.001, S=1-	RF
کاکارضا		سراب صیدعلی	
Gaussian noise = 0.01, $\omega=52.2$, $\sigma=1.5$	GP-PUK	Gaussian noise = 0.001, $\omega=0.001$, $\sigma=0.001$	GP-PUK
Gaussian noise = 0.001, $\gamma=0.5$	GP-RBF	Gaussian noise = 0.001, $\gamma=0.5$	GP-RBF
num-decimal-places= 0, M=4	M5P	num-decimal-places= 2, M=4	M5P
M=2, V=0.001, N=3, S=1	REPTREE	M=2, V=0.001, N=3, S=1	REPTREE


جدول ۴. پارامترهای ارزیابی عملکرد الگوریتم های GP-RBF, GP-PUK, M5p, RepTree و RF در دوره پرابی

آزمایش			آموزش			ایستگاه	مدل
MAE	RMSE	CC	MAE	RMSE	CC		
۰/۱۳۶	۰/۰۲	۰/۹۳۸	۰/۰۰۰۱	۰/۰۰۰۱	۰/۹۹۹	GP-PUK	
۰/۳۱۶	۰/۳۶۷	۰/۸۸۰	۰/۰۱۸	۰/۰۲۶	۰/۹۹۵	GP-RBF	
۰/۳۳۶	۰/۳۷۵	۰/۴۹۳	۰/۱۹۲	۰/۲۳۳	۰/۴۶۴	M5P	بهرام جو
۰/۴۳۳	۰/۴۸۹	۰/۱۲۲	۰/۱۳۵	۰/۱۶۸	۰/۷۶۸	REPTREE	
۰/۳۷۰	۰/۴۰۶	۰/۴۳۶	۰/۰۸۰	۰/۰۹۹	۰/۹۶۴	RF	
۰/۵۹۳	۰/۷۲۶	۰/۴۹۶	۰/۰۰۰۱	۰/۰۰۰۳	۰/۹۹۹	GP-PUK	
۰/۱۰۷	۰/۰۱۵	۰/۹۰۰	۰/۰۰۰۱	۰/۰۰۰۱	۰/۹۹۹	GP-RBF	
۰/۳۰۹	۰/۳۶۸	۰/۰۰۰	۰/۱۹۳	۰/۲۵۱	۰/۰۰۰	M5P	چم انجیر
۰/۳۳۹	۰/۴۱۱	۰/۰۳۸	۰/۱۲۰	۰/۱۷۹	۰/۷۰۱	REPTREE	
۰/۳۰۲	۰/۳۶۲	۰/۱۵۴	۰/۰۷۸	۰/۱۰۷	۰/۹۶۱	RF	
۰/۳۰۱	۰/۳۶۵	۰/۴۳۴	۰/۰۰۰۱	۰/۰۰۰۱	۰/۹۹۹	GP-PUK	
۰/۰۶۹	۰/۰۰۸	۰/۹۶۱	۰/۰۰۰۱	۰/۰۰۰۱	۰/۹۹۹	GP-RBF	
۰/۳۴۱	۰/۴۰۶	۰/۳۷۱	۰/۰۹۵	۰/۱۵۱	۰/۶۴۵	M5P	سراب صیدعلی
۰/۳۰۵	۰/۳۶۰	۰/۰۰۰	۰/۱۴۲	۰/۱۹۶	۰/۰۰۰	REPTREE	
۰/۲۹۰	۰/۳۶۳	۰/۱۲۷	۰/۰۵۷	۰/۰۸۹	۰/۹۵۶	RF	
۰/۵۴۵	۰/۷۶۹	۰/۰۸۰	۰/۰۳۵	۰/۰۷۱	۰/۹۲۸	GP-PUK	
۰/۰۸	۰/۰۰۷	۰/۸۷۰	۰/۰۳۳	۰/۰۶۸	۰/۹۳۳	GP-RBF	
۰/۱۹۰	۰/۲۵۲	۰/۰۰۰	۰/۱۳۲	۰/۱۹۱	۰/۰۰۰	M5P	کاکارضا
۰/۲۲۴	۰/۲۶۶	۰/۳۵۴	۰/۱۰۴	۰/۱۳۰	۰/۷۳۰	REPTREE	
۰/۲۰۶	۰/۲۴۱	۰/۵۵۴	۰/۰۴۹	۰/۰۷۱	۰/۹۶۵	RF	


همچنین در ایستگاه چم انجیر با توجه به نتایج بخش آزمایش، مدل GP-RBF با ضریب کارایی ۰/۹۰۰، ریشه میانگین مربعات خطا ۰/۰۱۵ و میانگین خطای مطلق ۰/۱۰۷ به عنوان بهترین مدل انتخاب شد. در ایستگاه سراب صیدعلی با توجه به نتایج مرحله آزمایش، مدل GP-RBF با ضریب کارایی ۰/۹۶۱، ریشه میانگین مربعات خطا ۰/۰۰۸ و میانگین خطای مطلق ۰/۰۶۹ دارای بهترین کارایی بود و بر اساس نتایج جدول ۴ برای ایستگاه کاکارضا مدل GP-RBF با ضریب کارایی ۰/۸۷، ریشه میانگین مربعات خطا ۰/۰۰۷ و میانگین خطای مطلق ۰/۰۸ در مرحله آزمایش دارای بهترین کارایی است. شکل ۳ نمودار تغییرات داده های مشاهداتی و پیش بینی بخش آموزش و آزمایش ایستگاه های بهرام جو، چم انجیر، سراب صیدعلی و کاکارضا را نشان می دهد. همچنین شکل ۴ نمودار تغییرات خطا (اختلاف بین مشاهداتی و تخمینی) بخش آموزش و آزمایش و شکل ۵ کارایی مدل های بهینه برای تخمین بار انحلالی ایستگاه های مورد مطالعه در مرحله آزمایش را نشان می دهد.



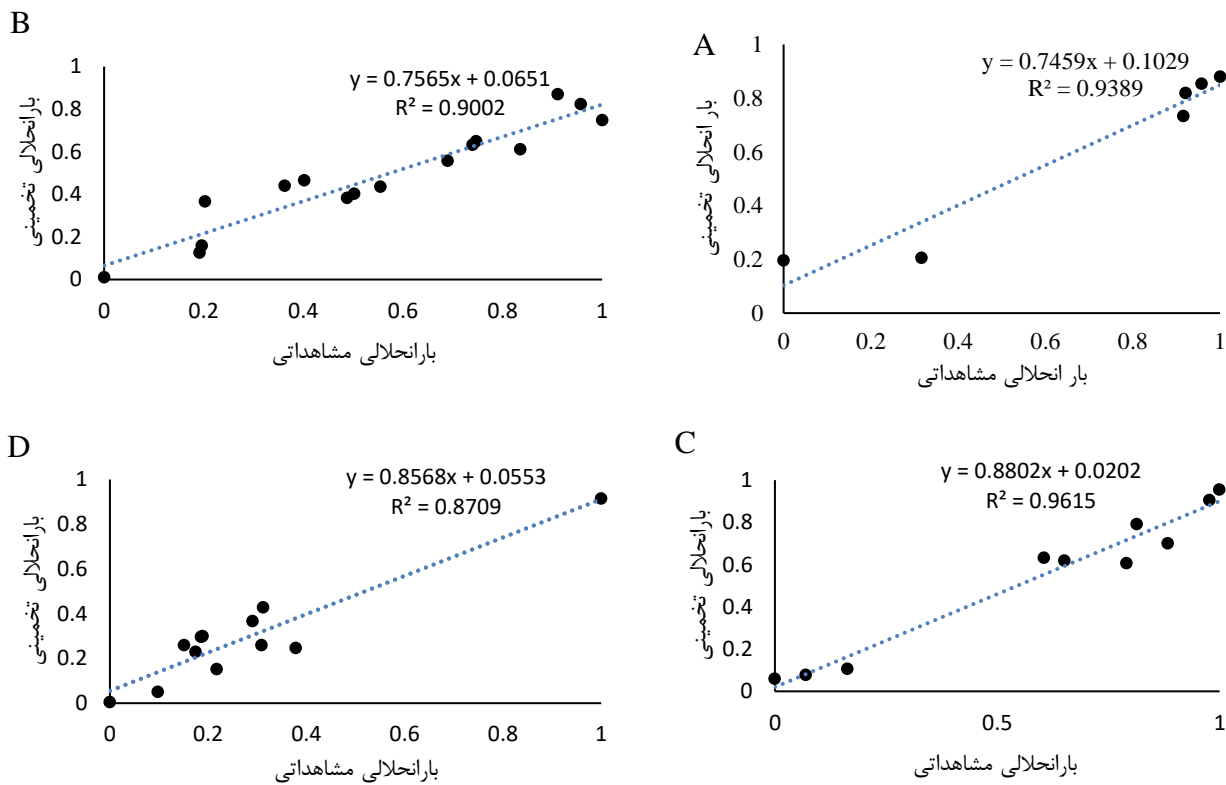
شکل ۳. نمودار تغییرات داده‌های مشاهده‌ای و پیش‌بینی در مرحله آموزش و آزمایش، (A) بهرام‌جو، (B) چمانچیر، (C) سراب صیدعلی و (D) کاکارضا



شکل ۴. نمودار تغییرات خطا در مرحله آموزش و آزمایش، (A) بهرام‌جو، (B) چمانچیر، (C) سراب صیدعلی و (D) کاکارضا



ادامه شکل ۴



شکل ۵. کارایی مدل بهینه برای تخمین بار انحلالی در مرحله آزمایش دوره پرآبی (A) بهرام‌جو، (B) چم‌انجیر، (C) سراب‌صیدعلی و (D) کاکارضا

۳-۳. مدل سازی رسوب انحلالی دوره کم آبی

جدول ۵ خصوصیات آماری داده‌های رسوب انحلالی دوره خشک‌سالی مربوط به مرحله آموزش و آزمایش ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد. مطابق نتایج جدول ۵ مشخص شد که به ترتیب بیش‌ترین و کم‌ترین رسوب انحلالی در مرحله آموزش برابر ۶۶۳ و ۱۹۹ میلی‌گرم بر لیتر و در محله آزمایش به ترتیب برابر ۷۹۵ و ۰ میلی‌گرم بر لیتر است. نتایج آزمون خود همبستگی برای تعیین همبستگی درونی بین متغیرها نشان داد که مقدار TOL و VIF به ترتیب بین ۰/۰۹۷-۰/۰۵۱ و ۱/۰۳-۱/۹۳ متغیر بود. جدول ۶ پارامترهای بهینه برای مدل‌های مختلف در ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد و جدول ۷ نتایج عملکرد مدل‌های مختلف در ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد.

جدول ۵. خصوصیات آماری داده‌های آموزش و آزمایش در دوره کم آبی

داده‌ها	آموزش			آزمایش		
	کمترین	بیشترین	میانگین	انحراف معیار	کمترین	بیشترین
بارش	۰/۰۰	۲۵۷	۴۸/۹۸	۲۱/۳۷۰	۰/۰۰	۲۸۴
دبی	۰/۳۳	۸/۵۶	۳/۱۷	۰/۵۵	۰/۱۸	۸/۷۰
دبی یک روز قبل	۰/۷۸	۲۷/۴۰	۳/۹۸	۱/۹۲	۰/۰۰	۱۸/۸۱
میانگین دبی (دبی همان روز و دبی روز قبل)	۰/۹۹	۱۷/۹۸	۳/۵۷	۱/۱۲	۱/۰۵	۱۳/۷۵
رسوب انحلالی	۱۹۹	۶۶۳	۳۸۰/۱۰	۵۶/۰۰	۰/۰۰	۷۹۵

* واحدها: بارش به میلی متر، دبی به متر مکعب بر ثانیه و رسوب انحلالی به میلی گرم بر لیتر

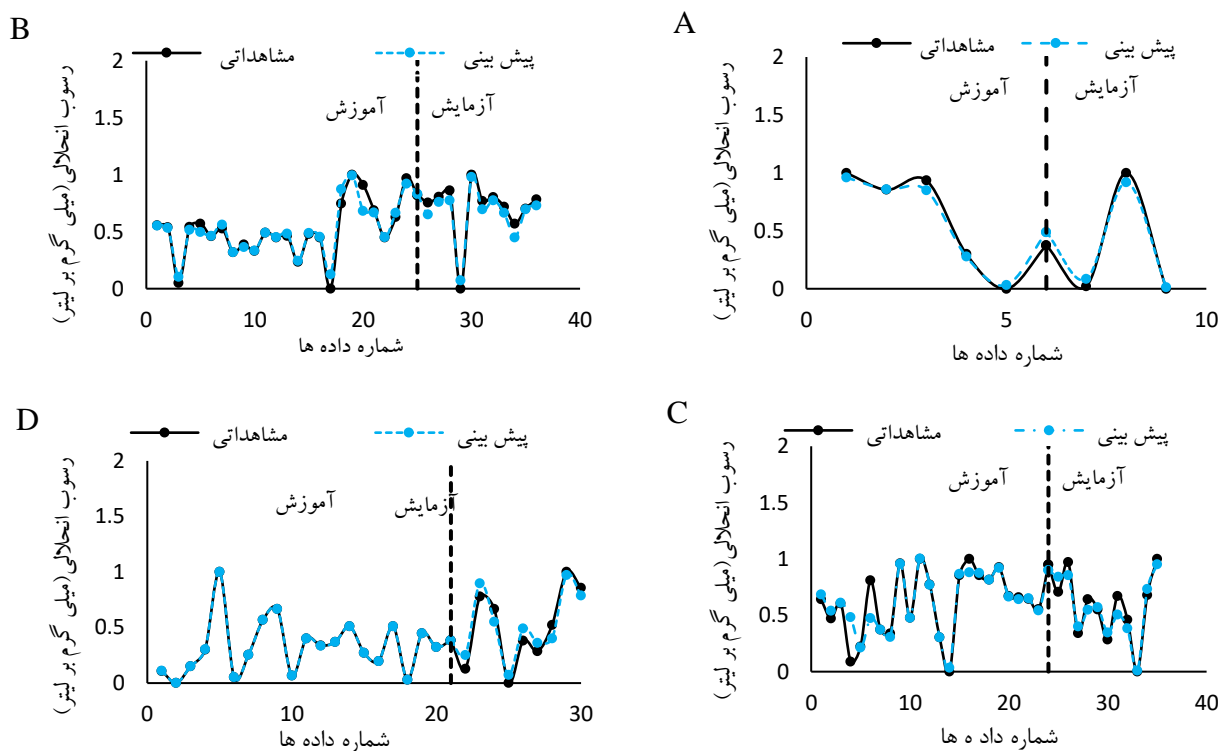
جدول ۶. پارامترهای بهینه الگوریتم‌های مختلف در دوره کم آبی

چم انجیر		بهرام‌جو	
پارامترهای بهینه	مدل	پارامترهای بهینه	مدل
Gaussian noise = 0. 1, $\omega=1$, $\sigma=1$	GP-PUK	Gaussian noise = 0.001, $\omega=0.001$ $\sigma=0.001$	GP-PUK
Gaussian noise = 0.1, $\gamma=9.9$	GP-RBF	Gaussian noise = 0.01, $\gamma=0.001$	GP-RBF
num-decimal-places= 0, M=4	M5P	num-decimal-places= 0, M=4	M5P
M=0, V=0.001, N=3, S=1	REPTREE	M=0, V=0.001, N=3, S=1	REPTREE
K=0, M=1, V=0.001, S=1	RF	K=0, M=1, V=0.001, S=1	RF
کاکارضا		سراب صیدعلی	
Gaussian noise = 0.001, $\omega=2.1$, $\sigma=1$	GP-PUK	Gaussian noise = 0.1, $\omega=0.8$, $\sigma=1$	GP-PUK
Gaussian noise = 0.1, $\gamma=0.5$	GP-RBF	Gaussian noise = 0.05, $\gamma=0.4$	GP-RBF
num-decimal-places= 0, M=4	M5P	num-decimal-places= 0, M=4	M5P
M=2, V=0.001, N=3, S=1	REPTREE	M=2, V=0.001, N=3, S=1	REPTREE
K=0, M=1, V=0.001, S=1	RF	K=0, M=1, V=0.001, S=1	RF

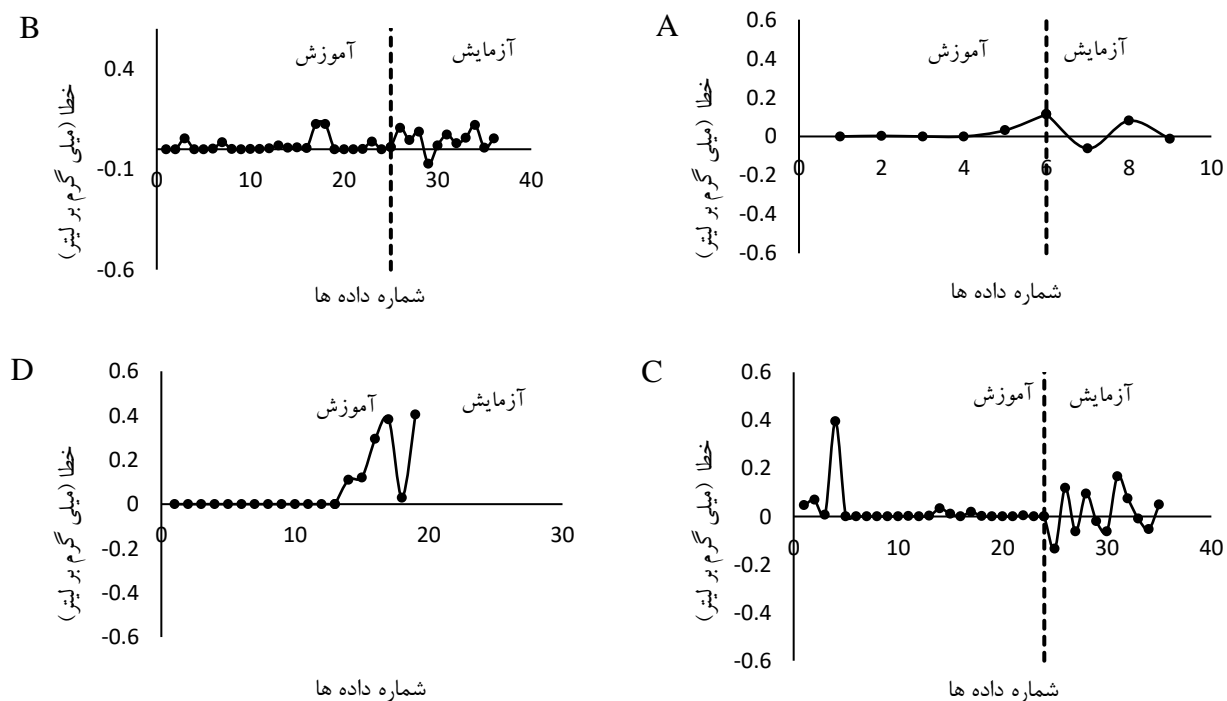
جدول ۷. پارامترهای ارزیابی عملکرد الگوریتم‌های GP-RBF, GP-PUK, RepTree, M5p, RF در دوره کم آبی

آزمایش			آموزش			مدل	ایستگاه
MAE	RMSE	CC	MAE	RMSE	CC		
-/۲۳۰	۰/۳۴۲	-/۸۴۰	۰/۰۰۰۱	۰/۰۰۰۱	-/۹۹۹	GP-PUK	
۰/۰۵۱	۰/۰۰۳	۰/۹۹۵	۰/۰۴۹	۰/۰۶۲	۰/۹۸۸	GP-RBF	
-/۵۱۸	۰/۵۲۳	-/۰۰۰	۰/۳۵۲	۰/۳۷۲	-/۰۰۰	M5P	بهرام‌جو
-/۵۱۸	۰/۵۲۳	-/۰۰۰	۰/۳۵۲	۰/۳۷۲	-/۰۰۰	REPTREE	
-/۵۴۸	۰/۵۹۶	-/۲۹۸	۰/۱۷۰	۰/۲۰۶	-/۸۷۶	RF	
-/۳۶۹	۰/۴۲۵	۰/۴۶۰	۰/۰۴۷	۰/۰۸۰	-/۹۴۸	GP-PUK	
۰/۰۶۱	۰/۰۰۵	۰/۹۶۳	۰/۰۳۴	۰/۰۶۲	۰/۹۶۷	GP-RBF	
-/۲۱۳	۰/۲۹۷	-/۰۵۶	۰/۱۷۰	۰/۲۲۷	-/۳۳۱	M5P	چمنجیر
-/۳۴۵	۰/۴۱۹	-/۲۳۴	۰/۱۶۰	۰/۱۹۶	-/۵۷۹	REPTREE	
-/۲۷۱	۰/۳۷۱	-/۲۲۶	۰/۰۶۸	۰/۰۸۷	-/۹۵۱	RF	
-/۲۰۸	۰/۲۴۴	-/۶۸۴	۰/۰۵۹	۰/۱۲۰	-/۹۰۹	GP-PUK	
۰/۰۷۷	۰/۰۰۸	۰/۹۰۱	۰/۰۴۹	۰/۱۱۰	۰/۹۲۱	GP-RBF	
-/۲۱۷	۰/۲۶۹	-/۳۳۲	۰/۲۲۰	۰/۲۶۴	-/۳۶۶	M5P	سراب صیدعلی
-/۲۴۷	۰/۳۰۲	-/۱۵۰	۰/۲۰۶	۰/۲۵۴	-/۵۰۴	REPTREE	
-/۲۱۲	۰/۲۵۹	۰/۴۰۲	۰/۱۰۰	۰/۱۲۶	-/۹۴۵	RF	
۰/۰۹۳	۰/۰۱۰	۰/۹۱۴	۰/۰۰۰۴	۰/۰۰۰۸	۰/۹۹۹	GP-PUK	
-/۴۲۸	۰/۴۹۰	-/۳۴۳	۰/۰۵	۰/۰۷۱	-/۹۵۵	GP-RBF	
-/۳۱۱	۰/۳۶۹	-/۰۰۰	۰/۱۷۹	۰/۲۳۵	-/۰۰۰	M5P	کاکارضا
-/۳۳۸	۰/۳۹۹	-/۲۶۱	۰/۱۵۸	۰/۲۰۰	-/۵۲۳	REPTREE	
-/۳۵۳	۰/۴۱۲	-/۵۷۴	۰/۰۷۸	۰/۰۹۸	-/۹۴۵	RF	

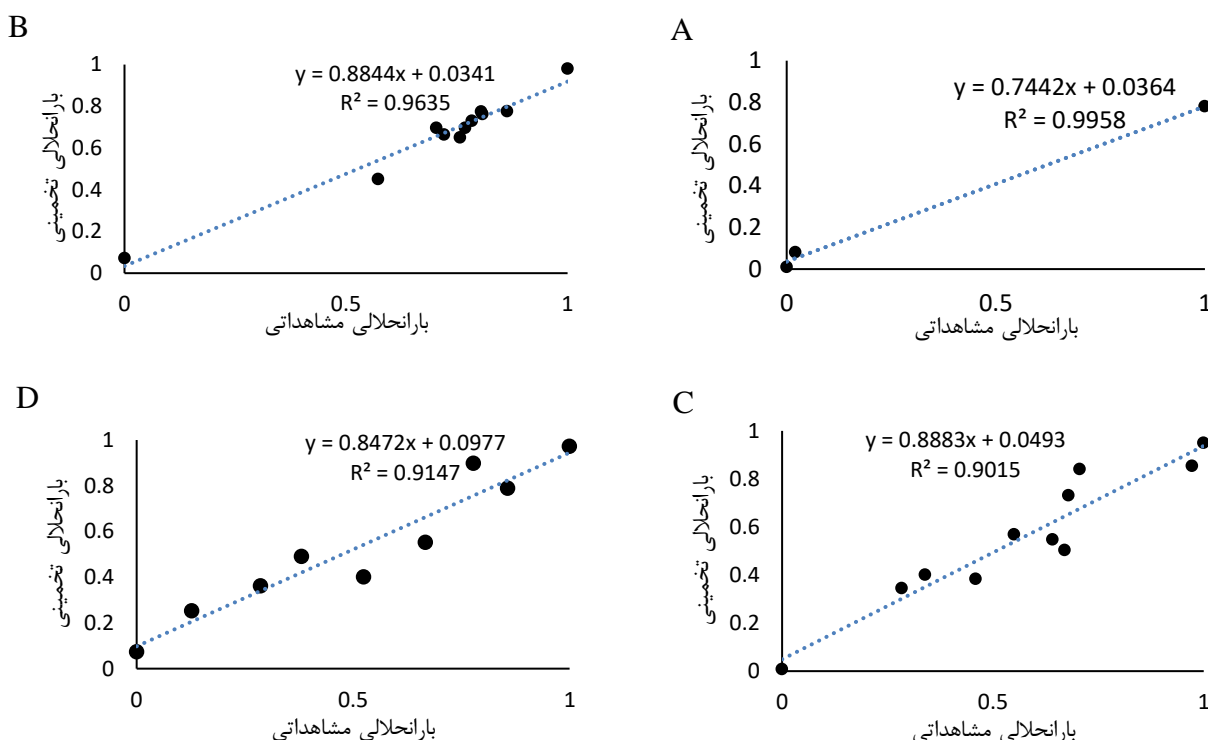
مطابق نتایج این جدول مشخص شد که در ایستگاه بهرام‌جو مدل GP-RBF با ضریب همبستگی ۰/۹۹۷، ریشه میانگین مربعات خطا ۰/۰۰۳ و میانگین خطای مطلق ۰/۰۵۱ در مرحله آزمایش دارای بهترین کارایی است. همچنین در ایستگاه چمنجیر مدل GP-RBF با ضریب کارایی ۰/۹۶۳، ریشه میانگین مربعات خطا ۰/۰۰۵ و میانگین خطای مطلق ۰/۰۶۱ در مرحله آزمایش دارای بهترین کارایی است. در ایستگاه سراب صیدعلی مدل GP-RBF با ضریب کارایی ۰/۹۰۱، ریشه میانگین مربعات خطا ۰/۰۰۸ و میانگین خطای مطلق ۰/۰۷۷ در مرحله آزمایش دارای بهترین کارایی است. و نهایت در ایستگاه کاکارضا مدل GP-PUK با ضریب کارایی ۰/۹۱۵، ریشه میانگین مربعات خطا ۰/۰۱ و میانگین خطای مطلق ۰/۰۹۳ در مرحله آزمایش دارای بهترین کارایی است. شکل ۶ نمودار تغییرات داده‌های مشاهداتی و پیش‌بینی بخش آموزش و آزمایش در ایستگاه‌های بهرام‌جو، چمنجیر، سراب صیدعلی و کاکارضا را نشان می‌دهند. همچنین شکل ۷ نمودار تغییرات داده‌های خطای بخش آموزش و آزمایش و شکل ۸ کارایی مدل‌های بهینه برای تخمین بارانحلالی ایستگاه‌های مورد مطالعه در مرحله آزمایش را نشان می‌دهد.



شکل ۶. نمودار تغییرات داده‌های مشاهده‌ای و پیش‌بینی در مرحله آموزش و آزمایش، (A) بهرام‌جو، (B) چمنجیر، (C) سراب صیدعلی و (D) کاکارضا



شکل ۷. نمودار تغییرات خطا در مرحله آموزش و آزمایش، (A) بهرام‌جو، (B) چمنجیر، (C) سراب صیدعلی و (D) کاکارضا



شکل ۸. کارایی مدل بهینه برای تخمین بار انحلالی در مرحله آزمایش دوره کم‌آبی (A) بهرام‌جو، (B) چمن‌انجیر، (C) سراب صیدعلی و (D) کاکارضا

۳-۴. تحلیل حساسیت

جدول ۸ آنالیز حساسیت بهترین الگوریتم در بخش آزمایش رسوب انحلالی پرآبی و کم‌آبی ایستگاه‌های هیدرومتری مورد مطالعه را نشان می‌دهد. مطابق نتایج این جدول مشخص شد که الگوریتم‌های بهینه انتخاب شده برای دوره پرآبی در ایستگاه‌های هیدرومتری بهرام‌جو، چمن‌انجیر، سراب صیدعلی و کاکارضا به ترتیب به پارامترهای بارش، دبی همان روز، دبی همان روز و دبی یک روز قبل حساسیت بیشتری داشته‌اند و همچنین در دوره کم‌آبی، نتایج مدل‌سازی به ترتیب در ایستگاه‌های هیدرومتری بهرام‌جو، چمن‌انجیر، سراب صیدعلی و کاکارضا نسبت به پارامترهای بارش، دبی همان روز، بارش و دبی همان روز دارای بیشترین حساسیت بوده‌اند. زیرا با حذف این پارامترهای حساس، نتایج مدل‌سازی بیشترین تغییر را در جهت کاهش دقت مدل شده است.

۴. بحث و نتیجه‌گیری

انحلال‌پذیری در مفهوم دقیق آن به مقدار ماده‌ای اطلاق می‌شود که می‌تواند تحت شرایط تعادلی خاصی از درجه حرارت و فشار در یک حلال، حل شود که نتیجه آن بار انحلالی رودخانه می‌باشد. نتیجه بار انحلالی رودخانه، کاهش کیفیت آب و حجم سدهای پایین دست منطقه دارد. لذا پیش‌بینی و تخمین بار انحلالی رودخانه در مدیریت حوضه‌ها بسیار حائز اهمیت است. بر این اساس، با توجه به اینکه منطقه مورد مطالعه در سرشاخه‌های حوضه آبخیز کرخه و بالادست سد کرخه می‌باشد، در این پژوهش به مدل‌سازی بارانحلالی رودخانه با استفاده از الگوریتم‌های یادگیری ماشین و به کارگیری مدل‌های GP-PUK, GP-RBF, RepTree, M5P, RF در ایستگاه‌های هیدرومتری حوضه آبخیز کشکان شامل بهرام‌جو، چمن‌انجیر، سراب صیدعلی و کاکارضا پرداخته شد.

جدول ۸. تحلیل حساسیت بهترین مدل ایستگاه‌های هیدرومتری مورد مطالعه

دوره کم‌آبی			دوره پرآبی			حذف	تحلیل حساسیت
MAE	RMSE	CC	MAE	RMSE	CC		
بهرام‌جو							
۰/۹۵	۰/۹۵	۰/۹۹	۰/۶۲	۰/۶۵	۰/۹۰	-	R, Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۲۷	۰/۳۷	۰/۷۰	۰/۴۴	۰/۵۵	۰/۵۹	R	Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۹۵	۰/۹۶	۰/۹۹	۰/۵۰	۰/۶۱	۰/۹۱	Q _t	R, Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۸۹	۰/۹۰	۰/۹۹	۰/۷۳	۰/۷۹	۰/۷۱	Q _{t-1}	R, Q _t , AvQ _t Q _{t-1} , TDS
۰/۹۳	۰/۹۴	۰/۹۹	۰/۵۸	۰/۶۲	۰/۹۱	AvQ _t -Q _{t-1}	R, Q _t , Q _{t-1} , TDS
چمانجیر							
۰/۳۰	۰/۳۵	۰/۹۰	۰/۵۹	۰/۷۳	۰/۸۷	-	R, Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۲۸	۰/۳۳	۰/۷۲	۰/۹۹	۲/۰۶	۰/۲۷	R	Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۲۸	۰/۳۰	۰/۱۷	۱/۳۴	۲/۴۱	۰/۲۷	Q _t	R, Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۳۶	۰/۴۴	۰/۴۹	۰/۷۰	۰/۸۷	۰/۴۳	Q _{t-1}	R, Q _t , AvQ _t Q _{t-1} , TDS
۰/۳۱	۰/۳۸	۰/۵۴	۰/۷۱	۰/۹۴	۰/۵۰	AvQ _t -Q _{t-1}	R, Q _t , Q _{t-1} , TDS
سراب صیدعلی							
۰/۳۹	۰/۳۶	۰/۸۹	۰/۲۱	۰/۲۶	۰/۹۱	-	R, Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۲۰	۰/۲۵	۰/۴۵	۱/۴۳	۲/۸۱	۰/۳۲	R	Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۳۴	۰/۴۲	۰/۶۱	۰/۴۰	۰/۴۵	۰/۱۵	Q _t	R, Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۲۶	۰/۳۰	۰/۶۸	۰/۲۳	۰/۲۸	۰/۶۸	Q _{t-1}	R, Q _t , AvQ _t Q _{t-1} , TDS
۰/۳۷	۰/۴۷	۰/۶۷	۰/۲۲	۰/۲۹	۰/۶۴	AvQ _t -Q _{t-1}	R, Q _t , Q _{t-1} , TDS
کاکارضا							
۰/۷۰	۰/۹۱	۰/۹۱	۰/۱۴	۰/۱۹	۰/۹۲	-	R, Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۳۸	۰/۴۷	۰/۴۰	۱/۶۳	۲/۵۴	۰/۶۰	R	Q _t , Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۵۳	۰/۷۵	۰/۳۲	۱/۴۰	۲/۴۶	۰/۸۰	Q _t	R, Q _{t-1} , AvQ _t Q _{t-1} , TDS
۰/۸۴	۱/۰۱	۰/۴۶	۱/۳۹	۲/۰۹	۰/۴۶	Q _{t-1}	R, Q _t , AvQ _t Q _{t-1} , TDS
۰/۳۴	۰/۴۲	۰/۳۳	۱/۱۷	۲/۴۰	۰/۸۵	AvQ _t -Q _{t-1}	R, Q _t , Q _{t-1} , TDS

نتایج حاصل از مدل‌سازی با استفاده از مدل‌های GP-PUK, GP-RBF, REP Tree, M5P Tree, RF برای رسوب انحلالی در دوره کم‌آبی و پرآبی در ایستگاه‌های مختلف (بهرام‌جو، چمانجیر، سراب صیدعلی و کاکارضا) نشان داد که در دوره پرآبی در ایستگاه بهرام‌جو، تمامی الگوریتم‌های استفاده شده توسط داده‌های آموزشی و آزمایشی نتایج نسبتاً نتایج خوبی به همراه داشته است. اما مدل GP با دو کرنل RBF و PUK نتایج بهتری نسبت به سایر مدل‌ها داشته است؛ اگرچه، کرنل PUK نسبت به کرنل RBF برتر بوده است. در ایستگاه‌های چمانجیر، سراب صیدعلی و کاکارضا تمام الگوریتم‌ها غیر از M5P Tree توسط داده‌های آموزشی نتایج عالی از خود نشان داده‌اند و همچنین بر اساس داده‌های آزمایشی نتایج آن‌ها نسبتاً خوب بوده‌اند. در این خصوص، مدل GP با دو کرنل RBF و PUK نتایج بهتری نسبت به سایر مدل‌ها داشته است؛ اگرچه، کرنل RBF نسبت به PUK برتری داشته است. همچنین در دوره کم‌آبی در ایستگاه

کاکارضا همانند بخش پرآبی در هر دو بخش پرآبی و کم آبی نتایج همه الگوریتم‌ها نسبتاً نتایج خوبی بوده است و مدل GP با کرنل PUK نسبت به کرنل RBF برتری داشته است. همچنین نتایج مدل‌سازی در ایستگاه‌های چمانجیر، سراب صیدعلی و بهرام‌جو همانند دوره پرآبی بوده است و الگوریتم GP با کرنل RBF نسبت به PUK برتری داشته است. در حالت کلی در دوره کم‌آبی و پرآبی الگوریتم M5P Tree نتایج خوبی نشان نداده است اما الگوریتم‌های RF و REP Tree در بعضی ایستگاه‌ها نتایج خوبی به همراه داشته‌اند در حالی که در بعضی از ایستگاه‌های هیدرومتری نتایج ضعیفی داشته‌اند و الگوریتم GP توانست در بعضی ایستگاه‌های هیدرومتری با کرنل RBF و در بعضی دیگر از ایستگاه‌های هیدرومتری با کرنل PUK به خوبی عمل کند. این امر بیانگر پتانسیل بالای این الگوریتم‌ها در تشخیص ارتباط بین پارامترهای موثر بر کیفیت آب و تخمین رسوب انحلالی رودخانه در دوره پرآبی و کم‌آبی می‌باشد. تحقیقات زیادی در مورد بارانحلالی به تفکیک دوره‌های پرآبی و کم‌آبی انجام نگرفته است و تعداد کمی از محققان تاکنون به بررسی این موضوع در رودخانه‌های حوضه‌های کارستی پرداخته‌اند.

نتایج به‌دست آمده در این تحقیق با نتایج تحقیق سپه‌وند و عزیزی (۲۰۱۹) همخوانی دارد. زیرا آن‌ها در پژوهش خود به این نتیجه رسیدند که مدل GP با کرنل RBF نسبت به کرنل PUK برتری دارد. علاوه بر این، نتایج این تحقیق با نتایج اسدی و همکاران (۲۰۲۱) همخوانی دارد. زیرا آن‌ها در تحقیق خود دریافتند که مدل GP نسبت به دیگر مدل‌ها در تخمین رسوب معلق رودخانه برتری دارد. اما نتیجه به دست آمده با تحقیق سلیمانی و همکاران (۲۰۲۱) همخوانی ندارد. زیرا آن‌ها به این نتیجه رسیدند که مدل RF دارای بهترین عملکرد و مدل GP با کرنل PUK دارای کمترین عملکرد در بحث مدل‌سازی نفوذ می‌باشد. علاوه بر این، نتایج با نتایج تحقیق کوهستانی و همکاران (۲۰۱۶) نیز مطابقت ندارد. زیرا آن‌ها در تحقیق خود به این نتیجه رسیدند که مدل M5P دارای بیشترین کارایی است. همچنین، نتایج این تحقیق با نتایج عشقی و همکاران (۲۰۱۵)، مغایرت داشت. از دلایل مغایرت نتایج این تحقیق با تحقیقات دیگران، تفکیک دوره‌های پرآبی و کم‌آبی، وجود سازندهای کارستی بالا و همچنین شرایط بارشی منطقه می‌باشد. لذا می‌توان از پارامترهای بیشتری که موثر بر بارانحلالی رودخانه باشند در مدل‌سازی استفاده کرد.

نتایج نشان داد که عملکرد الگوریتم‌ها در دوره پرآبی دارای دقت بیشتری نسبت به دوره کم‌آبی بوده که این نتایج نشان از حساسیت بالاتر داده‌های دوره کم‌آبی به عوامل طبیعی و خطاهای انسانی همچون اندازه‌گیری است که این نتیجه با نتایج منتصری و زمان زاده قویدل (۲۰۱۷) همخوانی داشت. در بخش تحلیل حساسیت مشخص شد که حساس‌ترین پارامتر بر روی نتایج مدل‌سازی در دوره پرآبی و کم‌آبی ایستگاه بهرام‌جو، بارش، دوره پرآبی و کم‌آبی ایستگاه چمانجیر، دبی همان روز، دوره پرآبی و کم‌آبی ایستگاه سراب صیدعلی به ترتیب دبی همان روز و بارش و دوره پرآبی و کم‌آبی ایستگاه کاکارضا به ترتیب دبی یک روز قبل و دبی همان روز به عنوان حساس‌ترین پارامتر مشخص شدند. با توجه به اینکه منطقه کارستی می‌باشد، لذا بارش با برخورد به سنگ‌های آهکی باعث ایجاد رسوب انحلالی و تشکیل رخساره‌های ریزمقیاس کارستی از جمله کارن‌ها می‌شود. همچنین در منطقه مورد مطالعه با افزایش دبی جریان بحث چرخش آب یا سیرکولاسیون آب بر روی سنگ‌های آهکی بیشتر شده و در نتیجه تأثیر معنی‌داری بر روی تشکیل بارانحلالی دارد (سپه‌وند و همکاران، ۲۰۲۰).

با توجه به نتایج به دست آمده از این تحقیق می‌توان از این الگوریتم‌ها برای صرفه‌جویی در هزینه و زمان در راستای توسعه پایدار منابع آب و خاک و تخمین رسوب انحلالی خروجی از حوضه‌ها استفاده کرد. زیرا علاوه بر نتایج این تحقیق، نتایج تحقیقات دیگران نیز برتری الگوریتم‌های داده‌کاوی را نسبت به سایر مدل‌های پیش‌بینی‌کننده برای پیش‌بینی پارامترهای کیفی رودخانه‌ها اثبات شده است (کبانز، ۲۰۱۱؛ اووسی^۲ و همکاران، ۲۰۲۱؛ گولدال و تونگال^۳، ۲۰۱۰؛ منتصری و زمان‌زاده قویدل، ۲۰۱۷؛ سنگورور^۴ و همکاران، ۲۰۰۶؛

¹ Cobaner

² Ewusi

³ Guldai and Tnngal

⁴ Sengorur

سپهوند و عزیزی، ۲۰۱۹؛ ساین^۱ و همکاران، ۲۰۰۹؛ سیهاگ و ساین^۲، ۲۰۱۹). همچنین برای مدیریت بهینه کیفیت و کمیت منابع آب سطحی می‌توان مدل‌های انتخاب شده را با قابلیت اعتماد بیشتر برای تخمین رسوبات انحلالی و سایر پارامترهای کیفیت آب ایستگاه‌های مجاور فاقد آمار دارای شریط زمین‌ساختی و هیدرولوژیکی یکسان در سطح منطقه مورد استفاده قرار گیرند و نتایج قابل اعتمادی در رابطه با رسوب انحلالی ارائه دهند.

References

- Ansari, H., and Davari, K. (2008). Classification of dry period using standard precipitation index in GIS environment. *Geographical Research*, 39(60), 98-108 (In Persian).
- Asadi, M., Fathzadeh, A., Kerry, R., Ebrahimi Khusfi, R. and Taghizadeh Mehrjardi, R. (2021). Prediction of river suspended sediment load using machine learning models and geo-morphometric parameters. *Arabian Journal of Geoscience*, 14(1926), <https://doi.org/10.1007/s12517-021-07922-6>. (In Persian).
- Baghdar dokht, Z., Hidari, M., Ghobadi, M.H. and Shafei, A. (2006). Study of karst formations solubility in Kangir Dam site, 4th Iranian Conference on Geology Engineering and Environment, 621-637. (In Persian).
- Bazuhair, S.A., Gohani, A. and Sen, Z. (1997). Determination of monthly wet and dry periods in Saudi Arabia. *International Journal of Climatology*, (17), 303-311.
- Bonakdar, L. and Etemad Shahidi, A. (2011). Predicting wave run-up on rubble-mound structures using M5 model tree. *Ocean Engineering*, (38), 111-118. (In Persian).
- Breiman, L. (1996). Bagging predictors. *Machin Learning*, 24(2), 123-140.
- Chahouki, Z., Salajegheh, A., Mahdavi, M., Khalighi, Sh. And Asadi, S. (2013). Regional duration curve in Arid regions for ungauged basins. *Journal of Range and Watershed management*, 66(2), 251.265(In Persian).
- Cobaner M. 2011. Evapotranspiration estimation by two different neuro-fuzzy inference systems. *Journal of Hydrology*, 398: 292-302.
- Eshghi, P., Farzad Mehr, J., Dasturani, M.T. and Arabasadi, Z. (2015). Investigating the efficiency of intelligent models in estimating river suspended sediments. *Watershed Management Research Journal*, 7(14), 88-96. (In Persian).
- Ewusi, A., Ahenkorah, I. and Aikins, D. 2021. Modelling of total dissolved solids in water supply systems using regression and supervised machine learning approaches. *Appl Water Science*, 11(13), <https://doi.org/10.1007/s13201-020-01352-7>
- Ford, D.C. and Williams, P. (2007) *Karst Hydrogeology and Geomorphology*. John Wiley, Chichester, 562. <https://doi.org/10.1002/9781118684986>.
- Güldal V. and Tongal, H. 2010. Comparison of recurrent neural network, adaptive neuro-fuzzy inference system and stochastic models in Egirdir Lake level forecasting. *Water Resources Management*, 24(1): 105-128.
- Khosravi, K., Pham, B.T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., Prakash, I. and Bui, D.T. (2018). A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Science of the Total Environment*, 627, 744-755.
- Kohestani, V.R., Hasanlorad, M. and Bazargan Lari, M. (2016). Prediction of the ultimate bearing capacity of surface foundations located on granular soils using the M5P tree model. *Ferdowsi Civil Engineering*, 2(27), 99-110 (In Persian).
- Mahdavi, M. (2007). *Applied hydrology*. Tehran University Press, 357 pp. (In Persian).

¹ Sighn

² Sihag and Sighn

- Melesse, A.M., Khosravi, K., Tiefenbacher, J.P., Heddam, S., Kim, S., Mosavi, A. and Pham, B.T. (2020). River Water Salinity Prediction Using Hybrid Machine Learning Models. *Water*, 12(10), 2951. <https://doi.org/10.3390/w12102951>
- Mirhashemi, S.H., Panahi, M. and Zareei, L. (2020). Evaluation of M5P Algorithm for Estimation of Potential Evapotranspiration, Minimum and Maximum Temperature. *Journal of Meteorology and Atmospheric Sciences*, 2(4), 287-295 (In Persian).
- Montaseri, M. and Zaman Zad Ghavidel, S. (2017). Comparing the Performance of Artificial Intelligence Models in Estimating Water Quality Parameters in Periods of Low and High Water Flow, *Journal of Water and Soil*, 30(6), 1733-1747 (In Persian).
- Mostafazadeh, R. and Zabihi, M. (2016). Comparison of SPI, SPEI indices in meteorological drought assessment using R programming (study area: Kurdistan province). *Journal of Earth and Space Physics*, 42, 633-643 (In Persian).
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.
- Pal, M. and Deswal, S. (2010). Modelling pile capacity using Gaussian process regression. *Computer. Geotechnical*, 37, 942-947.
- Prasad, A.M., Iverson, L.R. and Liaw, A. (2006). Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. *Ecosystems*, 9(2), 181-199.
- Quinlan, J.R. (1992). Learning with continuous classes. in Proceedings of the 5th Australian joint Conference on Artificial Intelligence. Hobart 16-18 November, 343-348.
- Samadianfard, S., Salarifar, M., Javidan, S. and Mikaeili, F. (2020). Estimation of Daily Reference Evapotranspiration in Humid Climates Using Data-Driven Methods of Gaussian Process Regression, Support Vector Regression and Random Forest. *Environment and Water Engineering*, 6(4), 360-373 (In Persian).
- Sengorur B., Dogan E., Koklu R. and Samandar A. 2006. Dissolved oxygen estimation using artificial neural network for water quality control. *Fresenius Environmental Bulletin*, 15: 1064-1067.
- Sepahvand A., Nazari Samani, A.A., Mohammadian, H., Ahmadi, H. and Feiz Nia, S. (2020). Seasonal variation of the solute and determine the solubility of limestone formations. *Iranian Journal of Watershed Management Science and Engineering*, 14(48), 21-32. (In Persian).
- Sepahvand, A., Prelovsek, M., Nazari Samani, A. and Wasson, R.J. (2021). Solute transport and solutional denudation rate of carbonate karst in the semi-arid Zagros region (southwestern Iran). *Journal of Cave and Karst Studies*, 83(3), 93-108.
- Sepahvand, A., Singh, B., Sihag, P., Nazari, A., Hasan Ahmadi, S. and Fiz Nia, S. (2019). Assessment of the various soft computing techniques to predict sodium absorption ratio (SAR). *ISH Journal of Hydraulic Engineering*, 27, 124-135.
- Sepehvand, A. and Azizi Najafkali, Z. (2019). Suspended sediment modeling using Gaussian process and multi-layer perceptron models 15th National conference on Watershed Management Sciences and Engineering of Iran, 15, 1-6. (In Persian).
- Sighn K.P., Basant A., Malik A. and Jain G. 2009. Artificial neural network modeling of the river water quality-A case study. *Ecological Modelling*, 220: 888-895
- Sihag P., Singh V.P., Angelaki A., Kumar V., Sepahvand A. and Golia E. (2019). Modelling of infiltration using artificial intelligence techniques in semi-arid Iran, 64(13): 1647-1658.
- Smakhtin, V.U. (2001). Low-flow hydrology: a review. *Journal of Hydrology*. 240, 147-186.
- Soleimani, L., Derikund, B. and Sepehvand, A. (2021). Permeability modeling in different classes of soil texture using learning algorithms. *Watershed Researches*, 35(4), 1-150 (In Persian).
- Sun, Z., Guo, H., Li, X., Lu, L. and Du, X. (2011). Estimating urban impervious surfaces from Landsat-5 TM imagery using multilayer perceptron neural network and support vector machine. *Journal of Applied Remote Sensing*, 5(1), 053501.

Wang, Y. and Witten, I.H. (1997). Inducing model trees for continuous classes. Proceedings of the Ninth European Conference on Machine Learning. Prague, Czech Republic: Springer. 13 pp.

Yang, D., Zhang, X., Pan R., Wang, Y. and Chen, Z. (2018). A novel Gaussian process regression model for state-of-health estimation of lithium-ion battery using charging curve. Journal of Power Sources, 384, 387-39.