

صحت‌سنجی مدل‌های یادگیری ماشین برای تفسیر و پیش‌بینی رفتار سازه‌ای سدها با استفاده از داده‌های ابزار دقیق

میلااد مرادی سارخانلو*¹، وهب توفیق²، محسن قائمیان³

1 - فارغ التحصیل کارشناسی ارشد مهندسی عمران - سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه صنعتی شریف،

تهران، ایران، miladmoradi_76@yahoo.com

2 - استاد دانشکده مهندسی عمران، دانشگاه صنعتی شریف، تهران، ایران، toufigh@sharif.edu

3 - استاد دانشکده مهندسی عمران، دانشگاه صنعتی شریف، تهران، ایران، ghaemian@sharif.edu

خلاصه

در سال‌های اخیر، در دسترس بودن تکنیک‌های یادگیری ماشین برای پیش‌بینی و تفسیر رفتار ساختاری سدها مورد استفاده قرار گرفته است. هدف این مقاله نحوه انتخاب یک مدل یادگیری ماشین با دقت و عملکرد مناسب برای پیش‌بینی رفتار سازه‌های سد با در نظر گرفتن داده‌های جمع‌آوری شده به مدت 13 سال از ابزارهای موجود در سازه سد است. این امر مستلزم انتخاب چندین روش یادگیری ماشین مانند جنگل‌های تصادفی (RF)، درختان رگرسیون تقویت‌شده (BRT)، شبکه‌های عصبی مصنوعی (ANN)، رگرسیون برداری پشتیبانی (SVR) و الگوریتم‌های رگرسیون درخت تصمیم (DTR) است. در این مقاله، با در نظر گرفتن 6 متغیر هدف تعریف‌شده از ابزار دقیق پاندول، رفتار سد با استفاده از مدل‌های یادگیری ماشین انتخابی مدل‌سازی می‌شود. ارزیابی مدل‌های ساخته شده با استفاده از سه شاخص اندازه‌گیری خطا (MAE، MSE و R^2) و تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل انجام شده است. بنابراین، در این مقاله کار گسترده‌ای در مورد ارزیابی و صحت‌سنجی شامل صحت‌سنجی داده‌های تاریخی، صحت‌سنجی پیش‌بینی و رفتار باقیمانده‌ها در طول زمان است. بدین ترتیب، مدل درختان رگرسیون تقویت‌شده (BRT) در فرآیند ارزیابی و صحت‌سنجی مدل، بهترین انطباق و دقت را در بخش‌های یادگیری و پیش‌بینی رفتار سد قوسی مورد مطالعه را داشته است.

کلمات کلیدی: پیش‌بینی رفتار سد، ابزار دقیق پاندول، یادگیری ماشین، سد قوسی، جابجایی شعاعی، صحت‌سنجی مدل

1. مقدمه

ایمنی سدها به دلیل نیاز مداوم به کاهش پیامدهای فاجعه‌بار در بخش‌های زیست‌محیطی، اجتماعی و اقتصادی بسیار حیاتی است. نظارت دائمی بر ایمنی سدها مستلزم ارزیابی دقیق جنبه‌های مختلف این سازه است، که شامل نظارت بر بدنه سد، فونداسیون، سازه‌های تکمیلی، شیب‌های کناری و مناطق پایین‌دست می‌شود. این رویکرد نیازمند آگاهی از حوزه‌های مختلف ایمنی سدها است. تا ملاحظات زیست‌محیطی، یکپارچگی ساختاری و عملکرد هیدرولیکی را در بر بگیرد [1]. به طور معمول، روش‌های مورد استفاده برای اطمینان از ایمنی ساختاری سدها، استفاده از مدل‌های شبیه‌سازی



می‌باشد. ارزیابی ایمنی سدها به دلیل ویژگی‌های منحصر به فرد هر سازه و فوندا سیون آن، یک فرآیند پیچیده محسوب می‌شود. به همین دلیل، این فرآیند معمولاً با استفاده از روش‌هایی نظیر بازرسی بصری، تخصص مهندسی و مدل‌های رفتاری ارزیابی می‌گردد. پاسخ واقعی سد با پیش‌بینی‌های مدل با هدف شناسایی ناهنجاری‌ها و جلوگیری از شکست‌های احتمالی مقایسه می‌شود. در واقع، تفاوت بین مقدار پیش‌بینی شده و قرائت واقعی به عنوان معیار واقعی برای ارزیابی رفتار سد مورد استفاده قرار می‌گیرد [2]. این پیش‌بینی‌ها ممکن است بر اساس مدل‌های قطعی مانند مدل‌های اجزای محدود یا مدل‌های مبتنی بر داده‌ها انجام شود.

بسیاری از سدهای بزرگ در حال بهره‌برداری دارای تعداد زیادی ابزار دقیق هستند که هم متغیرهای محیطی (مربوط به بارهای اصلی) و هم پاسخ سد را در طول سال‌ها ثبت کرده‌اند [3]. در میان این ابزارهای دقیق، جابجایی نقش مهمی ایفا می‌کند که اندازه‌گیری و تفسیر آن نسبت به دیگر ابزارها ساده‌تر است. این امر علاقه زیادی به توسعه تکنیک‌هایی ایجاد می‌نماید که قادر به استخراج اطلاعات ارزشمند از پایگاه‌های داده اغلب بزرگ و ناهمگن باشند. در سال‌های اخیر، روند رو به رشدی در پذیرش مدل‌های مبتنی بر داده با استفاده از روش‌های یادگیری ماشین به منظور افزایش قابلیت اطمینان مدل‌های سنتی در توصیف رفتار مشاهده شده یا در برخی موارد، برای مطالعه جنبه‌ای خاص از رفتار سد دیده شده است. برخی از این روش‌ها شامل درختان رگرسیون تقویت شده¹ (BRT) [4]، جنگل‌های تصادفی² (RF) [5]، شبکه‌های عصبی مصنوعی³ (ANN) [6،7]، ماشین‌های بردار پشتیبانی⁴ (SVR) [8،9] و رگرسیون درخت تصمیم⁵ (DTR) [10] می‌باشند. مقایسه عملکرد آنها را می‌توان در کارهای انجام شده توسط سالازار و همکاران [11] یافت. تکنیک‌های یادگیری ماشین معمولاً به عنوان یک حوزه مطالعاتی متمرکز بر الگوریتم‌های رایانه‌ای تعریف می‌شوند که عملکرد خود را به طور خودکار از طریق تجربه افزایش می‌دهند. به همین دلیل، از این تکنیک‌ها می‌توان برای ساخت مدل‌های رفتاری سدها استفاده کرد [12].

مدل‌های مبتنی بر داده، بدون در نظر گرفتن ویژگی‌های فیزیکی سد، امکان ساخت مدل‌های پیش‌بینی را با استفاده از داده‌های ابزار دقیق فراهم می‌کنند [11]. یکی از محبوب‌ترین روش‌های سنتی مبتنی بر داده برای پیش‌بینی رفتار سد، روش هیدرواستاتیک-فصل-زمان⁶ (HST) است. این روش مبتنی بر رگرسیون خطی چندگانه با در نظر گرفتن متغیرهای خارجی مانند بار هیدرواستاتیک، دمای هوا و زمان است. با این حال، روش HST دارای اشکالات اساسی مانند ناتوانی آن در مدیریت روابط غیرخطی متغیرهای ورودی است [8] که می‌تواند بر دقت پیش‌بینی مدل تأثیر منفی گذاشته و به طور بالقوه منجر به ارزیابی نادرست رفتار شود [9]. جزئیات بیشتر در مورد عملکرد و اشکالات این مدل را می‌توان در [13] یافت.

الگوریتم‌های یادگیری ماشین به عنوان ابزاری ارزشمند برای مدل‌سازی سیستم‌های غیرخطی پیچیده شناخته شده‌اند و به طور گسترده برای پیش‌بینی جابجایی اجزاء مختلف سد، از جمله بدنه و فوندا سیون، به کار گرفته می‌شوند. هدف از پیش‌بینی رفتار سد، پایش سلامت سازه و ارزیابی ایمنی برای جلوگیری از آسیب‌ها و حوادث احتمالی در آینده است. بنابراین، شناسایی الگوریتمی مناسب که هم در آموزش و هم در پیش‌بینی رفتار سد عملکرد مناسبی را داشته باشد، مهم‌ترین گام ارزیابی ایمنی سدها می‌باشد.

در یک مطالعه انجام شده توسط ماتا (Mata) [6]، مقایسه‌ای بین مدل‌های شبکه عصبی و رگرسیون خطی چندگانه برای پیش‌بینی جابجایی شعاعی در یک سد قوسی انجام پذیرفت. نتایج نشان داده است که مدل شبکه عصبی نسبت به

¹ Boosted regression trees

² Random forest

³ Artificial neural networks

⁴ Support vector machines

⁵ Decision tree regression

⁶ Hydrostatic-seasonal-time



مدل رگرسیون خطی چندگانه انعطاف‌پذیری و سازگاری بهتری ارائه می‌دهد. سو و همکاران (Su et al) [14]، از ماشین بردار پشتیبان برای ایجاد یک مدل استاتیک و یک مدل به روز شده در زمان واقعی برای پیش‌بینی جابجایی یک سد غلتکی استفاده کردند. در تحقیق انجام‌شده توسط روناکوویچ (Rankovic) [8]، مدل‌های رگرسیون بردار پشتیبان و خودرگرسیون غیرخطی با ورودی‌های برون‌زا برای پیش‌بینی جابجایی مماسی در سدها به کار گرفته شدند. در تحقیق مهم دیگر انجام‌شده توسط سالازار و همکاران (Salazar et al) [15]، مدل‌های مورد استفاده شامل درختان رگرسیون تقویت شده، جنگل‌های تصادفی، شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان و رگرسیون تطبیقی چند متغیره می‌باشند. این مدل‌ها برای تجزیه و تحلیل جابجایی در یک سد قوسی مورد استفاده قرار گرفتند. ارزیابی جامع جابجایی شعاعی و مماسی و همچنین داده‌های نشی نشان می‌دهد که مدل BRT نسبت به مدل‌های دیگر دقت بالاتری در آموزش و پیش‌بینی از طریق ارزیابی جامع جابجایی سدها نشان می‌دهد، هرچند که این نتایج قابل تعمیم به شرایط عمومی نمی‌باشند.

شبکه‌های عصبی به عنوان یکی از پرکاربردترین الگوریتم‌های یادگیری ماشین در زمینه سدها شناخته می‌شوند [16، 8، 6]. ماشین بردار پشتیبان (SVM) نیز شباهت‌هایی با شبکه‌های عصبی (NN)، به ویژه در ترکیب تبدیل‌های غیرخطی داده‌های ورودی دارد. محبوبیت این مدل‌ها بدلیل توانایی آن‌ها در آموزش دقیق و پیش‌بینی مجموعه داده‌های بسیار پیچیده ناشی می‌شود که آن‌ها را برای پیچیدگی‌های این رشته مهندسی مناسب می‌کند [17، 15، 11]. سایر الگوریتم‌های یادگیری ماشین که در پیش‌بینی رفتار سدها استفاده می‌شوند، متعلق به گروه مدل‌های درختی می‌باشد که متشکل از درختان رگرسیون تقویت شده (BRT)، رگرسیون درخت تصمیم (DTR) و جنگل‌های تصادفی (RF) هستند. قابل ذکر است که مدل BRT برخلاف شبکه‌های عصبی که معمولاً متغیرها را در طول یک پیش‌پردازش نرمال‌سازی و دسته‌بندی می‌کنند، از چنین تکنیک‌های پیش‌پردازشی روی متغیرهای ورودی استفاده نمی‌کند.

سارجنت (Sargent) [18] یک چارچوب کلی برای صحت‌سنجی و تایید مدل‌های شبیه‌سازی و درک سیستم‌های پیچیده در حوزه‌های مختلف تخصصی پیشنهاد کرده است. ماتا و همکاران (Mata et al) [19] از تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل¹ برای شناسایی مناسب‌ترین مدل پیش‌بینی جابجایی شعاعی برای یک سد قوسی استفاده کردند. براساس چارچوب‌های ارائه شده توسط سارجنت، تمامی مدل‌های جابجایی سد در دو بخش داده‌های آموزشی و پیش‌بینی مورد ارزیابی و صحت‌سنجی قرار گرفتند. نتایج نشان می‌دهد که تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل بکار گرفته شده می‌توانند اطمینان کافی برای تایید دقت و توانایی مدل برای پیش‌بینی جابجایی سد ارائه دهند.

کاربردهای مدل‌های یادگیری ماشین در مهندسی سد به دو حوزه اصلی دسته‌بندی می‌شوند. حوزه اول شامل استفاده از روش‌های مبتنی بر یادگیری ماشین که از نتیجه شبیه‌سازی‌های عددی، برای توسعه مدل‌های یادگیری ماشین استفاده می‌شود [19]. حوزه دوم، نظارت بر سلامت سازه، شامل جمع‌آوری و پس‌پردازش داده‌های ابزار دقیق برای پیش‌بینی رفتار آینده سد است [11]. تمرکز این مقاله بر روی دومین کاربرد مدل‌های یادگیری ماشین در سدها خواهد بود. مدل‌های یادگیری ماشین، با پردازش داده‌های اندازه‌گیری شده توسط ابزارهای دقیق ساخته می‌شوند. بنابراین، مدل‌های یادگیری ماشین با استفاده از معیارهای ارزیابی خطا² و تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل مورد ارزیابی قرار می‌گیرند. تکنیک‌های صحت‌سنجی شامل صحت‌سنجی داده‌های تاریخی³، صحت‌سنجی پیش‌بینی⁴، رفتار باقیمانده‌ها در طول زمان⁵، و مقایسه عملکرد و انتخاب مدل⁶ هستند.

¹ Model Validation and verification


² Error metric indicators

³ Historical data validation

⁴ Predictive validation

⁵ Residual behavior over time

⁶ Performance comparison and model selection



هدف این مطالعه انتخاب یک مدل برتر از میان مدل‌های یادگیری ماشین در نظر گرفته شده با استفاده از داده‌هایی که به مدت ۱۳ سال از طریق ابزار دقیق پاندول جمع‌آوری شده‌اند. این امر مستلزم انتخاب مدلی است که بتواند دقت بالاتری را در هر دو بخش داده‌های آموزشی و پیش‌بینی داشته باشد، که از طریق تفسیر نتایج ارزیابی و صحت‌سنجی به دست می‌آید. به طور خاص، مدل‌های مورد استفاده شامل جنگل‌های تصادفی (RF)، درختان رگرسیون تقویت شده (BRT)، شبکه‌های عصبی مصنوعی (ANN)، رگرسیون بردار پشتیبان (SVR) و رگرسیون درخت تصمیم (DTR) هستند. انتخاب چنین مدلی امکان پیش‌بینی رفتار سازه‌ای سد برای دوره‌هایی که هنوز توسط سد تجربه نشده‌اند را فراهم می‌کند.

2. روش‌های مورد استفاده

در این بخش، توضیحات مختصری از الگوریتم‌های انتخاب شده برای مدل‌های پیش‌بینی ارائه می‌شود. این مقاله از پنج تکنیک یادگیری ماشین برای پیش‌بینی رفتار سد استفاده می‌کند. اگرچه توضیحات دقیق ریاضی فراتر از هدف این مقاله است، اما مرور مختصری از ویژگی‌های کلیدی و مراجع اصلی برای هر الگوریتم ارائه شده است.

1.2. جنگل‌های تصادفی


جنگل تصادفی یک الگوریتم یادگیری ماشین است که به طور گسترده برای کارهای رگرسیون و طبقه‌بندی استفاده می‌شود [20]. این الگوریتم توسط ترکیب هوشمند از مجموعه‌ای از پیش‌بینی‌کننده‌های درخت تصمیم ساخته شده است و در حوزه‌های مختلف استحکام و دقت را ارائه می‌دهد. به دلیل تطبیق‌پذیری و قابلیت‌های با کارایی بالا، این الگوریتم به عنوان یک روش محبوب برای ساخت مدل‌های پیش‌بینی شناخته شده است [21]. برای ساخت یک مدل جنگل تصادفی، از روش راه‌اندازی خودکار¹ الگوریتم استفاده می‌شود. در این روش، مجموعه‌های جدیدی از داده‌های آموزشی به صورت خودکار ایجاد می‌شوند و سپس مدل، به طور تصادفی یک متغیر را برای هر مجموعه (با هدف تنوع بیشتر در نتایج) انتخاب می‌کند. سپس مدل جنگل تصادفی شروع به ایجاد درخت‌های تصمیم برای هر گروه با متغیرهای مربوطه می‌کند. در نهایت، میانگین نتایج پیش‌بینی با ترکیب درختان مجموعه به عنوان نتیجه در نظر گرفته می‌شود [22]. برای ارزیابی عملکرد مدل جنگل تصادفی، معمولاً از آزمون دقت داده‌های خارج از مجموعه² (OOB) استفاده می‌شود که در طول فرآیند راه‌اندازی انتخاب نشده‌اند. یکی از پارامترهای کلیدی در مدل‌سازی، که نشان‌دهنده میانگین خطاهای درختان تصمیم است، پارامتر اهمیت متغیرهای ورودی است که به شرح زیر می‌باشد:

$$VI = \frac{1}{N_{tree}} \sum_{i=1}^B (Err_i - Err_i^*) \quad (1)$$

که در آن N_{tree} تعداد کل درختان را در مدل نشان می‌دهد، Err_i و Err_i^* به ترتیب نشان‌دهنده خطاهای هر درخت پیاده‌سازی شده بر روی داده‌های خارج از مجموعه و داده‌های خارج از مجموعه همراه با نشان را نشان می‌دهند. از مزایای مدل‌های جنگل تصادفی کاهش واریانس است که منجر به کاهش خطر برازش بیش از حد مدل می‌شود. بنابراین، در فرآیند ساخت مدل‌های جنگل تصادفی در این تحقیق، با استفاده از مجموعه‌داده آموزشی، به تنظیم پارامترهای مختلف بیان‌شده در بالا پرداخته شد. این پارامترها شامل پارامترهای پیش‌فرض نظیر $(n_estimators)$ ، (max_depth) و $(min_samples_split)$ بوده‌اند.

¹ bootstrapping

² Out-of-Bag



2.2. ماشین بردار پشتیبان

بر خلاف روش‌های رگرسیون سنتی که به دنبال کمینه‌کردن خطا بین مقادیر پیش‌بینی شده و مقادیر واقعی هستند، رگرسیون بردار پشتیبان به دنبال یافتن یک ابرصفحه¹ متمرکز است که به بهترین شکل با داده‌ها در یک حاشیه مشخص از هماهنگی داشته باشد [23]. همچنین در این الگوریتم، داده‌های ورودی با استفاده از توابع هسته² به یک فضای جدید و بزرگتر تبدیل می‌شوند [9]. این فضا با یک تابع تخمین به صورت زیر تعریف می‌شود:

$$f(x) = w \cdot x + b \quad (2)$$

که در واقع معادله ابرصفحه می‌باشد. بنابراین تابع هزینه \mathcal{E} نیز بصورت زیر تعریف می‌شود:

$$\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \rightarrow \text{where } (x_i, y_i) \quad (3)$$

$$C(\lambda) = \frac{\lambda}{n} \sum_{j=1}^n \mathcal{E}_r(h_j, y_j) + \frac{1}{2} \|\eta\|^2$$

$$\mathcal{E}_r(h_j, y_j) = |h - y| - r |h - y| \geq r \text{ or } 0 \text{ otherwise}$$

که در آن λ پارامتر جریمه است، $\frac{1}{2} \|\eta\|^2$ نشان دهنده پارامتر منظم‌سازی است، Γ نشان دهنده محدوده خطاهای محتمل اندازه‌گیری شده توسط تابع خطای \mathcal{E}_r است، h نشان دهنده مرز خروجی ابرصفحه می‌باشد. در نهایت، معادله ابرصفحه با استفاده از ضریب‌های لاگرانژ (α_i, α_i^*) به همراه با تابع هسته $K(x, x_i)$ دوباره فرموله می‌شود:

$$f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x, x_i) + c \quad (4)$$

در فرایند مدل‌سازی الگوریتم SVR از یک هسته RBF گاوسی به همراه پارامترهای دیگر از جمله پارامتر هزینه C با مقادیر (1, 10, 20, 50, 100)، تابع خطای \mathcal{E} ساس به اپسیلون $\mathcal{E} = 0.01$ ، و پارامتر گامای هسته γ با مقادیر (1, 0.2, 0.1, 0.05, 0.01) در نظر گرفته شده است. جزئیات بیشتر در مورد رگرسیون بردار پشتیبان را می‌توان در [24] یافت.

3.2. شبکه عصبی

از میان انواع مختلف شبکه‌های عصبی موجود در ادبیات [25]، از مدل پرسپترون چندلایه³ (MLP) برای این مطالعه استفاده می‌شود. این شبکه به عنوان یک شبکه عصبی پیش‌خور⁴ عمل می‌کند که شامل چندین لایه به هم پیوسته از نورون‌ها، از جمله یک لایه ورودی، یک یا چند لایه پنهان، و یک لایه خروجی می‌باشد. هر نورون در یک لایه خاص به هر نورون در لایه‌های قبلی و بعدی متصل است. این اتصالات با وزن‌هایی مرتبط هستند که از لایه ورودی ویژگی‌ها را دریافت می‌کنند و لایه خروجی مقادیر پیش‌بینی شده را تولید می‌کند. خروجی شبکه توسط یک تابع فعال‌سازی محاسبه می‌شود که خروجی‌های لایه‌های پنهان را می‌گیرد و خروجی نهایی شبکه را محاسبه می‌کند [26]. توصیف ریاضی یک مدل پرسپترون چندلایه از مدل‌های شبکه عصبی را می‌توان به صورت زیر ارائه کرد [27]:


$$F_t = \beta_0 + \sum_{n=1}^N \beta_n W(\theta_{0i} + \sum_{j=1}^m \theta_{nj} x_j) \quad (5)$$

¹ Hyperplane

² kernel function

³ Multilayer perceptron

⁴ Feed-forward



که در آن N تعداد گره‌های لایه پنهان، m تعداد پارامترهای ورودی β_{n,x_j} و θ_{0i} وزن لایه خروجی را نشان می‌دهند. در این بخش، صفر در ضرایب وزن، نشان دهنده گره‌های بایاس در هر لایه می‌باشد. در نهایت، برای مدل پرسپترون چندلایه، از یک لایه پنهان با تعداد نورون‌های متغیر استفاده شد. با توجه به عدم وجود یک روش استاندارد برای تنظیم تعداد نورون‌ها برای همه مدل‌ها، تعداد نورون‌ها را در بازه 3 تا 30 در نظر گرفته شده که بیشترین دقت را ارائه می‌کنند [22]. تعداد دوره‌های آموزشی نیز به ترتیب 300، 500، 750 و 850 و پارامترهای منظم‌سازی 0.01، 0.001 و 0.0001 در نظر گرفته شدند. برای تابع فعال‌سازی لایه پنهان، هم‌زمان از توابع انتقال Tangent و ReLU [28] استفاده شد. همچنین، حل‌کننده‌های استفاده شده شامل Adam و Lbfgs هستند که به دلیل سرعت بالاتر و همگرایی بهتر در مجموعه داده‌ها انتخاب شدند [29].

4.2. درختان رگرسیون تقویت شده

درختان رگرسیون تقویت شده (BRT)، یک تکنیک یادگیری ماشین قدرتمند است که نقاط قوت درختان تصمیم [30] و الگوریتم‌های تقویت [24] را ترکیب می‌کند. تقویت¹ یک طرح کلی برای ساخت مدل‌های پیش‌بینی است. ایده اصلی در این مدل، این است که به طور متوالی مجموعه‌ای از یادگیرنده‌های ضعیف را با باقیمانده‌های مدل قبلی تطبیق داده شود. از این رو، مدل‌های جدید با تمرکز بر روی اشتباهات مجموعه قبلی ایجاد می‌شوند. این اقدام منجر به تولید یک مدل پیش‌بینی قوی با ترکیب یادگیرنده‌های ضعیف می‌شود. در واقع، هر یادگیرنده با استفاده از جزئیات برازش یادگیرندگان قبلی برازش می‌شود. تابع پیش‌بینی در هر مرحله به صورت زیر فرموله می‌شود:

$$\hat{F}_j^t = \sum_{i=1}^t F^i(x_j) = \hat{F}_j^{t-1} + v \cdot h^{(t)}(x_j) \quad (6)$$

که در آن $F^i(x_j)$ پاسخ مشاهده شده در گام i ، \hat{F}_j^t پاسخ پیش‌بینی شده در گام t ، $h^{(t)}(x_j)$ درخت جدید در گام t ، v نرخ یادگیری و x_j متغیر ورودی است. مدل BRT با استفاده از پارامترهای پیش‌فرض، از جمله تعداد تخمین‌گرها ($n_estimators$)، حداکثر عمق (max_depth) (3، 4، 5)، نرخ‌های یادگیری 0.0001 و 0.001 و پیاده‌سازی شد. برای بهینه‌سازی تابع ضرر، رگرسیون حداقل مربعات (ls) انتخاب شد. جزئیات بیشتر در مورد الگوریتم را می‌توان در [32، 31] یافت.



5.2. رگرسیون درخت تصمیم

رگرسیون درخت تصمیم (DTR) یک تکنیک یادگیری ماشین پارامتریک و غیرخطی است که برای کارهای طبقه‌بندی و رگرسیون استفاده می‌شود. این الگوریتم مهم‌ترین ویژگی‌ها و اطلاعات داده‌ها را برای بهترین پارتیشن‌بندی مجموعه داده شناسایی می‌کند. سپس مجموعه داده براساس ویژگی‌ها و اطلاعات انتخاب شده به زیرمجموعه‌ها تقسیم می‌شود. این فرآیند پارتیشن‌بندی به صورت بازگشتی تکرار می‌شود تا زمانی که یک معیار توقف برآورده شود. پس از رسیدن به یک معیار توقف، یک گره برگ ایجاد می‌شود. این گره برگ حاوی مقدار عددی پیش‌بینی شده است که معمولاً به عنوان میانگین یا میانگین متغیر هدف در آن پارتیشن در نظر گرفته می‌شود [10].

درختان تصمیم اغلب مستعد برازش بیش‌از حد هستند و در نتیجه واریانس بالایی دارند. بنابراین روش‌هایی برای یافتن درخت با اندازه مناسب پیشنهاد شده‌است. معروف‌ترین روش، روش هرس² درختان است [33]. برای دستیابی به یک

¹ Boosting

² Pruning



درخت با کیفیت بالا، ابتدا یک درخت کامل ساخته می‌شود و سپس زیردرخت‌های ناکارآمد که تأثیر قابل توجهی بر تابع هزینه ندارند، حذف می‌شوند [19]. تابع ارزیابی مورد استفاده برای تقسیم درختان رگرسیون، شاخص MSE است که برای وظایف رگرسیون استفاده می‌شود. شاخص MSE را می‌توان به صورت زیر بیان کرد:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

که در آن N اندازه مجموعه آموزشی، y_i خروجی‌های مشاهده‌شده برای داده i ، \hat{y}_i مقدار پیش‌بینی شده برای داده i می‌باشد. مدل رگرسیون درخت تصمیم با استفاده از پارامترهای پیش‌فرض، از جمله حداکثر عمق (max_depth) تنظیم شده به صورت (3، 4، 5) پیاده‌سازی شده است. تابع انتخاب شده برای اندازه‌گیری کیفیت مدل نسبت به داده‌های پیش‌بینی mse می‌باشد.

6.2. ارزیابی عملکرد با معیارهای اندازه‌گیری خطا

شاخص‌های مختلفی در ارزیابی و صحت‌سنجی عملکرد مدل‌های پیش‌بینی در نظر گرفته می‌شود. در این مقاله از سه تابع ارزیابی مهم و پرکاربرد استفاده شده است که به ترتیب شامل میانگین خطای مطلق (MAE)، میانگین مربعات خطا (MSE) و ضریب تعیین (R^2) هستند. این توابع به صورت زیر فرموله می‌شوند:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (8)$$

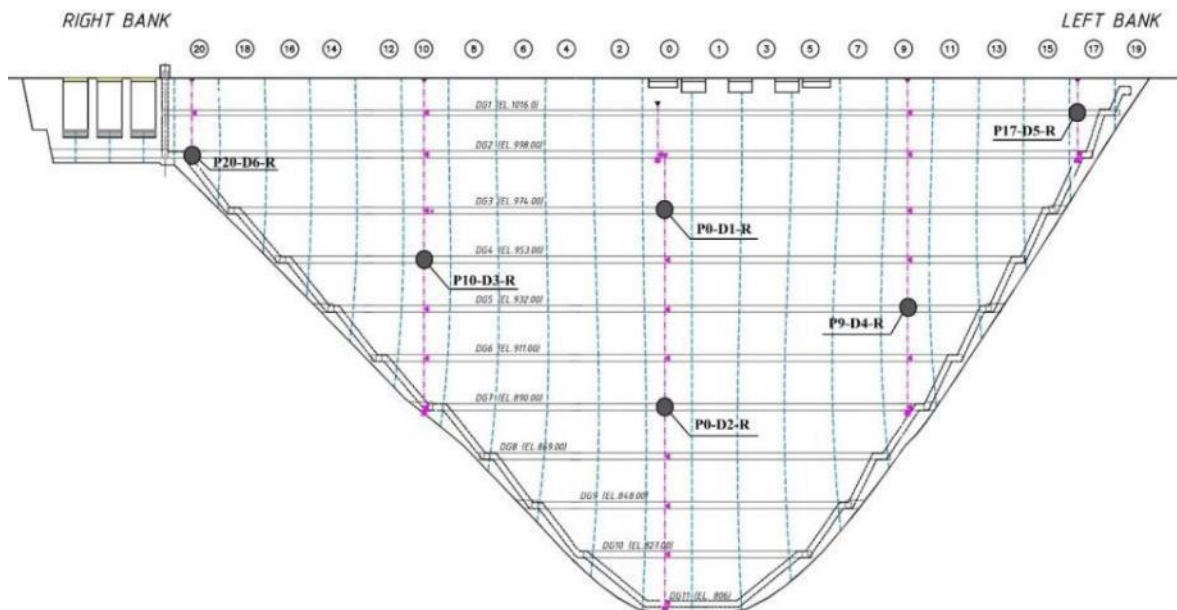
$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (10)$$

که در این فرمول، N اندازه مجموعه آموزشی (یا صحت‌سنجی)، y_i خروجی‌های مشاهده‌شده، \hat{y}_i مقدار پیش‌بینی شده و \bar{y} میانگین خروجی می‌باشد. تمامی الگوریتم‌ها در محیط پایتون پیاده‌سازی شده‌اند.

3. مطالعه موردی

مجموعه داده‌های مورد مطالعه مربوط به یک سد بتنی دو قوسی در ایران به ارتفاع 230 متر و طول کل تاج آن 350 متر می‌باشد. این سد عمدتاً برای تولید برق آبی طراحی شده که در سال 2010 به بهره‌برداری رسیده و در حال حاضر در حال استفاده می‌باشد. این سد با حداکثر تراز آب مخزن 1032.50 متر و ظرفیت ذخیره‌سازی حداکثر 3700 میلیون مترمکعب، به ابزارهای دقیق مختلفی مجهز است. این ابزارها، شاخص‌های اصلی عملکرد سد، از جمله دمای بتن و هوا، سطح آب مخزن، تنش، کرنش، نشت، جابجایی‌ها و تغییرات در بدنه سد، فوندا سیون، و نواحی دیگر سد را به طور مداوم ثبت می‌نمایند. جابجایی‌های بدنه سد با استفاده از پنج پاندول اندازه‌گیری و ثبت می‌شود. در این مقاله، مطالعه بر روی مجموعه داده‌های 6 متغیر هدف از میان تمامی متغیرهای ثبت شده از ابزار دقیق پاندول می‌باشد. این متغیرها جابجایی‌های اندازه‌گیری شده توسط ابزار دقیق را در بلوک‌ها و ترازهای ارتفاعی مختلف ثبت می‌نماید که سعی در پوشش تمامی بخش‌های سد برای یک ارزیابی دقیق و جامع از کل رفتار سد انتخاب شده است. شکل 1 مکان جانمایی ابزار دقیق پاندول و متغیرهای هدف را برای این مطالعه نشان می‌دهد.






شکل 1 - نمای بالادست سد و محل قرارگیری پاندول ها در بلوک ها به همراه شش متغیر هدف جابه‌جایی شعاعی

مجموعه مدل‌های پیش‌بینی شامل 22 متغیر است که شامل متغیرهای محیطی مانند تغییرات تراز مخزن آب، دمای هوا و بارندگی روزانه است که در شکل 2 نشان داده شده است. علاوه بر این، این مجموعه شامل متغیرهای مشتق شده¹ و متغیرهای مرتبط با زمان است. جدول 1 فهرستی جامع از این متغیرهای مشتق شده و توضیحاتی برای سایر متغیرها ارائه می‌کند. با توجه به بدنه نازک سد، ارتفاع زیاد و حساسیت سدهای قوسی به تغییرات دما، در نظر گرفتن میانگین دمای هوا برای کل بدنه سد ممکن است منجر به اثرات حرارتی غیر واقعی در مدل‌ها شود. به همین دلیل و با وجود تعداد زیادی دما سنج در سراسر بدنه سد و دسترس به دماهای بخش‌های مختلف سد، این مطالعه از دماهای مستقل تعیین شده در محدوده هر هدف در بدنه سد استفاده می‌کند.

مجموعه داده‌های تجزیه و تحلیل شده مربوط به دوره زمانی بین مه 2010 تا دسامبر 2022 است. در این مجموعه، از داده‌های بین مه 2010 تا دسامبر 2019 برای آموزش مدل‌های یادگیری ماشین استفاده شده است. در همه مدل‌های ساخته‌شده، تقریباً 70 درصد از داده‌ها به عنوان مجموعه داده‌های آموزشی و 30 درصد باقی‌مانده به عنوان مجموعه داده‌های آزمایشی مورد استفاده قرار گرفته است. این تصمیم بر اساس [15] گرفته شده، جایی که با در نظر گرفتن یک مجموعه آزمایشی بزرگتر منجر به افزایش قابلیت اطمینان و دقت نتایج مدل‌ها در مقایسه با مطالعات قبلی شده است [34,6]. هدف اصلی این است که مدل‌های یادگیری ماشین تولیدشده، قادر به بهترین نمایش الگوهای رفتاری مشاهده‌شده در مجموعه داده‌های آموزش باشند و همچنین قابلیت تعمیم‌پذیری بسیار قوی را نیز داشته باشند. مدل‌های یادگیری ماشین ایجاد شده، برای نظارت و فعالیت‌های ایمنی روزانه سد به کار گرفته خواهند شد. به همین دلیل، مجموعه داده‌های بازه زمانی بین ژانویه 2020 تا دسامبر 2022 به عنوان یک مجموعه پیش‌بینی در نظر گرفته شده تا توانایی مدل‌های ساخته‌شده را در بررسی دقت پیش‌بینی و مقایسه با نتایج داده‌های واقعی سنجیده شود. در نهایت، پس از اجرای دو مرحله فوق‌الذکر در تولید و صحت‌سنجی مدل‌های یادگیری ماشین، که به انتخاب یک الگوریتم مناسب از میان الگوریتم‌های مورد استفاده، که بیشترین دقت را در پیش‌بینی هر دو مجموعه داده‌ی مورد بررسی به دست آوردند، منجر می‌شود.


¹ Derived variables



شکل 2 - سری زمانی عوامل محیطی سد مورد مطالعه. از بالا به پایین: تغییرات تراز آب مخزن، تغییرات دمای هوا و بارندگی روزانه

جدول 1 - متغیرهای پیش‌بینی تعریف شده برای مدل‌های یادگیری ماشین

Target	Group	Type	Period (days)	
W-Level	Hydrostatic load	Original	-	
W-Level-7			7	
W-level-14			14	
W-Level-30			Average	30
W-Level-60				60
W-Level-90				90
W-Level-180				180
TA	Air temperature	Original	1	
TA-7			7	
TA-14			14	
TA-30			Average	30
TA-60				60
TA-90				90
TA-180				180
Rain	Rainfall	Collected	1	
Rain-30			30	
Rain-60			60	
Rain-90			90	
Rain-180			180	
Year	Time	Original	-	
Month			-	
Day			-	



4. نتایج و بحث

این بخش نتایج ارزیابی دقت مدل‌های یادگیری ماشین را در هر دو مجموعه داده‌های آموزشی و پیش‌بینی ارزیابی می‌کند. این ارزیابی با در نظر گرفتن معیارهای اندازه‌گیری خطا و تکنیک‌های صحت‌سنجی و راستی‌آزمایی صورت می‌پذیرد. این نوع ارزیابی امکان انتخاب بهترین مدل با اطمینان کافی برای پیش‌بینی رفتار سد را فراهم می‌کند.

1.4. ارزیابی عملکرد با معیارهای اندازه‌گیری خطا


در این بخش، دقت پیش‌بینی مدل‌های ساخته شده مورد ارزیابی قرار می‌گیرد. این مقایسه برای هر متغیر هدف، به صورت مستقل بر روی مجموعه داده‌های آموزشی و آزمایشی اجرا شده است. لازم به ذکر است که انتخاب مجموعه داده‌های آموزشی و آزمایشی در این مطالعه به صورت کاملاً تصادفی انجام شده است، که این کار منجر به ارزیابی بی‌طرفانه‌تر عملکرد مدل‌های یادگیری ماشین می‌گردد. جدول 2 خلاصه‌ای جامع از نتایج سه تابع ارزیابی خطا بر اساس معیارهای اندازه‌گیری خطا می‌باشد.

جدول 2 - دقت مدل‌ها در هر یک از هدف‌های تعریف‌شده در جابه‌جایی شعاعی ابزار دقیق پاندول در دو بخش

مجموعه داده‌های آموزشی و آزمایشی

Target	Data Type	BRT			RF			NN			SVR			DTR		
		MAE	MSE	R ²	MAE	MSE	R ²	MAE	MSE	R ²	MAE	MSE	R ²	MAE	MSE	R ²
P ₀ -D ₁ -R	Training	0.49	0.35	0.99	0.52	0.49	0.98	0.47	0.37	0.99	0.51	0.62	0.99	0.70	0.92	0.98
	Testing	0.57	0.51	0.99	0.60	0.64	0.98	0.58	0.72	0.99	0.61	1.12	0.98	0.79	1.18	0.98
P ₀ -D ₂ -R	Training	0.36	0.21	0.98	0.50	0.46	0.96	0.43	0.30	0.98	0.51	0.66	0.95	0.67	0.77	0.94
	Testing	0.37	0.26	0.98	0.51	0.44	0.96	0.45	0.44	0.96	0.56	0.78	0.94	0.65	0.69	0.94
P ₁₀ -D ₃ -R	Training	0.36	0.19	0.99	0.44	0.38	0.98	0.40	0.30	0.98	0.44	0.39	0.98	0.59	0.57	0.97
	Testing	0.41	0.26	0.99	0.46	0.34	0.98	0.44	0.49	0.98	0.58	0.89	0.95	0.62	0.65	0.96
P ₉ -D ₄ -R	Training	0.25	0.10	0.98	0.28	0.15	0.97	0.29	0.15	0.97	0.36	0.31	0.94	0.34	0.21	0.96
	Testing	0.30	0.15	0.97	0.29	0.16	0.97	0.31	0.17	0.97	0.39	0.29	0.94	0.37	0.25	0.95
P ₁₇ -D ₅ -R	Training	0.12	0.02	0.98	0.14	0.03	0.97	0.14	0.03	0.97	0.12	0.04	0.97	0.16	0.05	0.96
	Testing	0.15	0.03	0.97	0.16	0.04	0.97	0.17	0.06	0.96	0.16	0.06	0.96	0.19	0.06	0.96
P ₂₀ -D ₆ -R	Training	0.10	0.01	0.99	0.12	0.03	0.98	0.06	0.01	0.99	0.10	0.07	0.95	0.15	0.04	0.97
	Testing	0.15	0.06	0.97	0.15	0.09	0.95	0.11	0.08	0.98	0.18	0.18	0.87	0.16	0.05	0.97

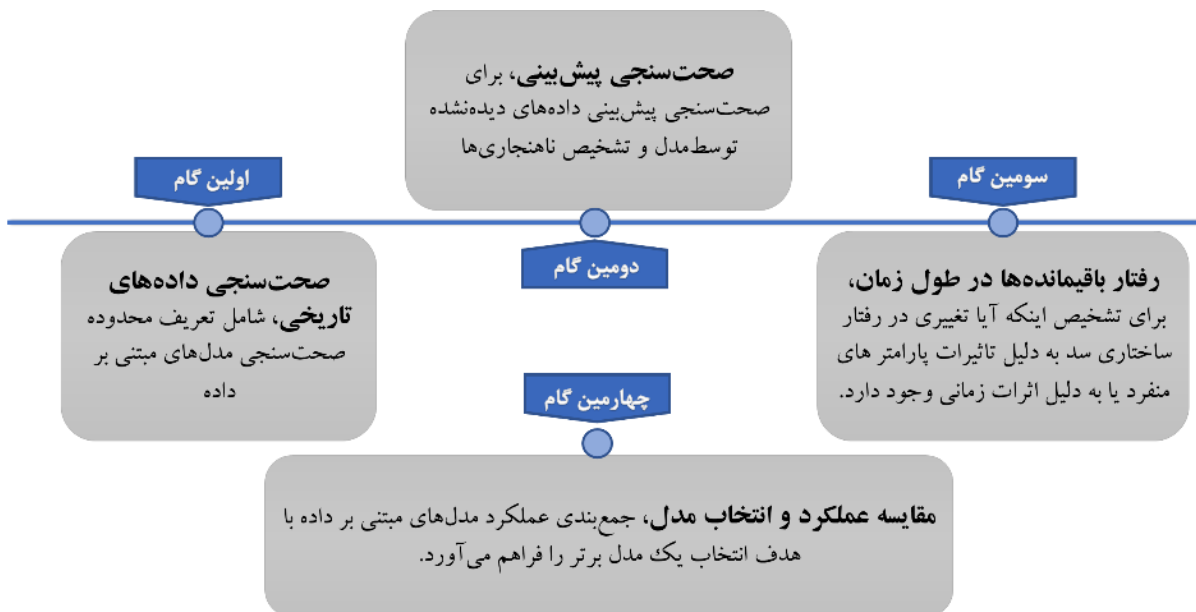
مشاهدات اولیه نتایج مدل‌های یادگیری ماشین در خصوص جابه‌جایی شعاعی نشان می‌دهد که برای مجموعه داده آموزشی، مدل‌ها به ترتیب BRT, NN, RF, SVR و DTR، از کمترین تا بالاترین میزان خطا را برای هر سه تابع خطای (MAE, MSE, R²) دارند. علاوه بر این، برای مجموعه داده آزمایشی نیز، مدل‌ها به ترتیب BRT, RF, NN, SVR و DTR



DTR بر اساس توابع خطا از کمترین به بالاترین طبقه‌بندی می‌شوند. با این حال، می‌توان ادعا کرد که برای هر دو مجموعه داده (آموزشی و آزمایشی)، مدل DTR بدترین پیش‌بینی را ارائه می‌دهد. مدل BRT برای مجموعه داده آموزشی بالاترین دقت را دارد و به دنبال آن، مدل NN در رتبه دوم قرار دارد. به طور مشابه، برای مجموعه داده آزمایشی، مدل BRT به عنوان دقیق‌ترین مدل حفظ می‌شود و مدل RF در رتبه دوم قرار می‌گیرد. به طور کلی می‌توان ادعا کرد که مدل BRT به عنوان بهترین مدل از لحاظ عملکرد در بین مجموعه داده‌های آموزشی و آزمایشی دارد. از این رو، مدل NN نیز دقت نسبتاً بالایی را هم در هر دو بخش داده‌های آموزش و آزمایش نشان داده است، که نشان‌دهنده توانایی این مدل برای ارزیابی پیش‌بینی‌های رضایت بخش است.

2.4. تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل

نتایج به دست آمده از تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل پیشنهادی در چهار مرحله مجزا، در بخش‌های زیر ارائه و مورد بحث قرار می‌گیرند. شکل 3 گام‌های صحت‌سنجی را نمایش می‌دهد.



شکل 3 - تکنیک‌های پیشنهادی برای اعتبارسنجی و تایید مدل‌های یادگیری ماشین برای تفسیر رفتار سد و انتخاب مدل برتر

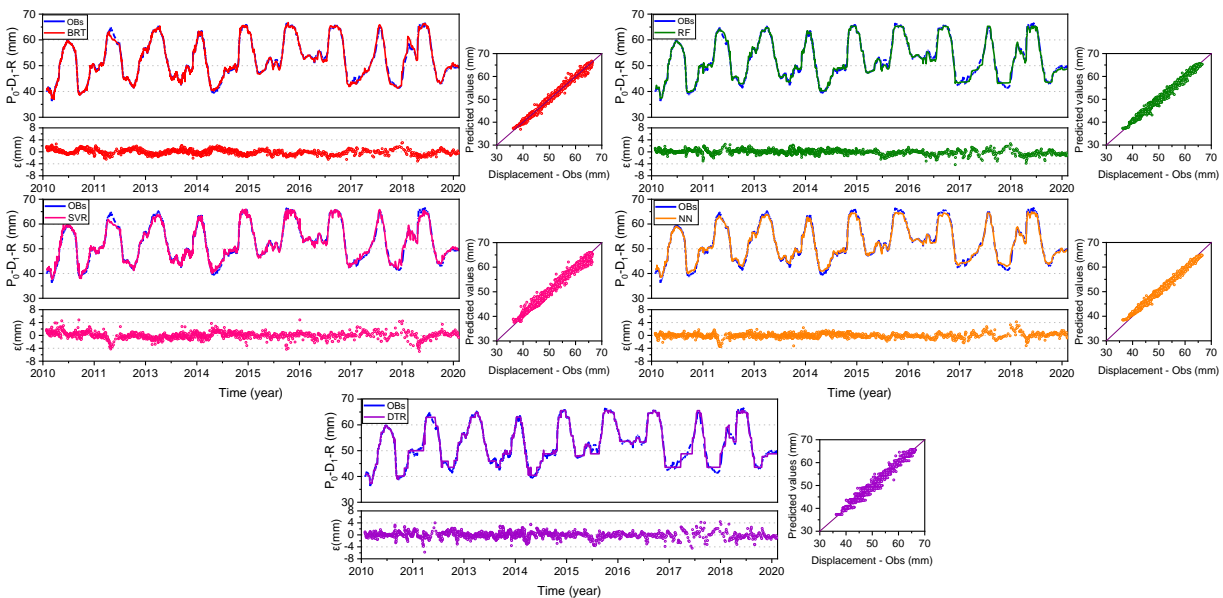
2.4. مرحله 1 صحت‌سنجی داده‌های تاریخی

صحت‌سنجی داده‌های تاریخی فرآیندی است که برای ارزیابی کیفیت داده‌های تاریخی برای آموزش یک مدل یادگیری ماشین استفاده می‌شود. این فرآیند، اولین مرحله از صحت‌سنجی مدل است و در واقع به معنای یک آزمون دقیق از توانایی یک مدل برای تعمیم بهتر از داده‌های آموزشی عمل می‌کند. اگر یک مدل با داده‌های تاریخی به خوبی عمل کند، این نشان‌دهنده این است که الگوها و ارتباطات اساسی را به خوبی فهمیده و اصولاً توانایی مدل را برای تعمیم به داده‌های

خارج از مجموعه داده‌های آموزش نشان می‌دهد. بنابراین، گام اولیه در صحت‌سنجی مدل، مقایسه بین پیش‌بینی‌های مدل و خروجی‌های مشاهده‌شده در طول دوره آموزشی مدل است.


در این مطالعه، از سه روش مختلف برای انجام صحت‌سنجی استفاده شده است. در مرحله اول، پیش‌بینی‌های مدل را می‌توان در کنار خروجی‌های مشاهده‌شده به‌عنوان سری‌های زمانی ترسیم کرد. زمان بر روی محور افقی قرار می‌گیرد، در حالی که هر دو جابجایی پیش‌بینی و مشاهده‌شده در محور عمودی نمایش داده می‌شوند. این رویکرد امکان تجزیه و تحلیل دقیق، دقت مدل‌ها را فراهم می‌کند و بینش دقیقی از عملکرد مدل‌های ساخته‌شده را ارائه می‌دهد، به‌عنوان مثال، قابلیت شناسایی دوره‌هایی با خطاهای قابل‌توجه را ممکن می‌سازد. در مرحله دوم، بررسی سری‌های زمانی باقیمانده‌ها نشان‌دهنده اختلاف بین جابجایی‌های پیش‌بینی شده و مشاهده‌شده می‌باشد. در مرحله سوم، بررسی نمودار جابجایی پیش‌بینی شده در مقابل جابجایی‌های مشاهده‌شده، با افزودن یک خط مستقیم از مبدا با شیب ۱/۱ برای اعمال تناسب کامل هر دو خروجی انجام شده است.

با توجه به محدودیت فضا، تنها یکی از متغیرهای هدف تعریف شده ارائه شده است. شکل 4 به‌عنوان نمونه، صحت داده‌های تاریخی برای متغیر هدف P_0-D_1-R را نشان می‌دهد. با ارزیابی و انجام یک تجزیه و تحلیل گرافیکی از مقایسه بین پیش‌بینی‌های مدل و پاسخ‌های مشاهده‌شده برای همه مدل‌های جابجایی شعاعی سد در هر شش هدف، آشکار می‌شود که میزان تطابق بین پیش‌بینی‌های مدل و پاسخ‌های مشاهده‌شده توسط ابزار پاندول، کاملاً با نتایج بیان شده در بخش 1.4 مطابقت دارد. بنابراین، مدل‌های BRT و NN سطح بالاتری از تطابق را نشان می‌دهند و پیش‌بینی‌هایی با نوسان بسیار کمتری نسبت به مدل‌های دیگر (DTR, SVR, RF) تولید می‌کنند. علاوه بر این، بررسی باقیمانده‌ها (تفاوت بین پیش‌بینی‌ها و مشاهدات) نیز تأیید می‌کند که این مدل‌ها کمترین باقی‌مانده را در بین سایر مدل‌های به‌کار گرفته شده دارند.



شکل 4 - اندازه‌گیری مجموعه داده‌های آموزشی مدل‌های یادگیری ماشین و پاسخ‌های قرائت شده توسط ابزار دقیق پاندول برای جابجایی شعاعی سد - P_0-D_1-R در بلوک 0.

بطور کلی، دستیابی به خطای آموزشی کم، به‌عنوان یکی از شروط لازم برای اثربخشی یک مدل یادگیری ماشین تلقی می‌شود. با این حال، باید تأکید نمود که این نوع ارزیابی، فقط یکی از شاخص‌های ارزیابی عملکرد مدل است و به‌تنهایی

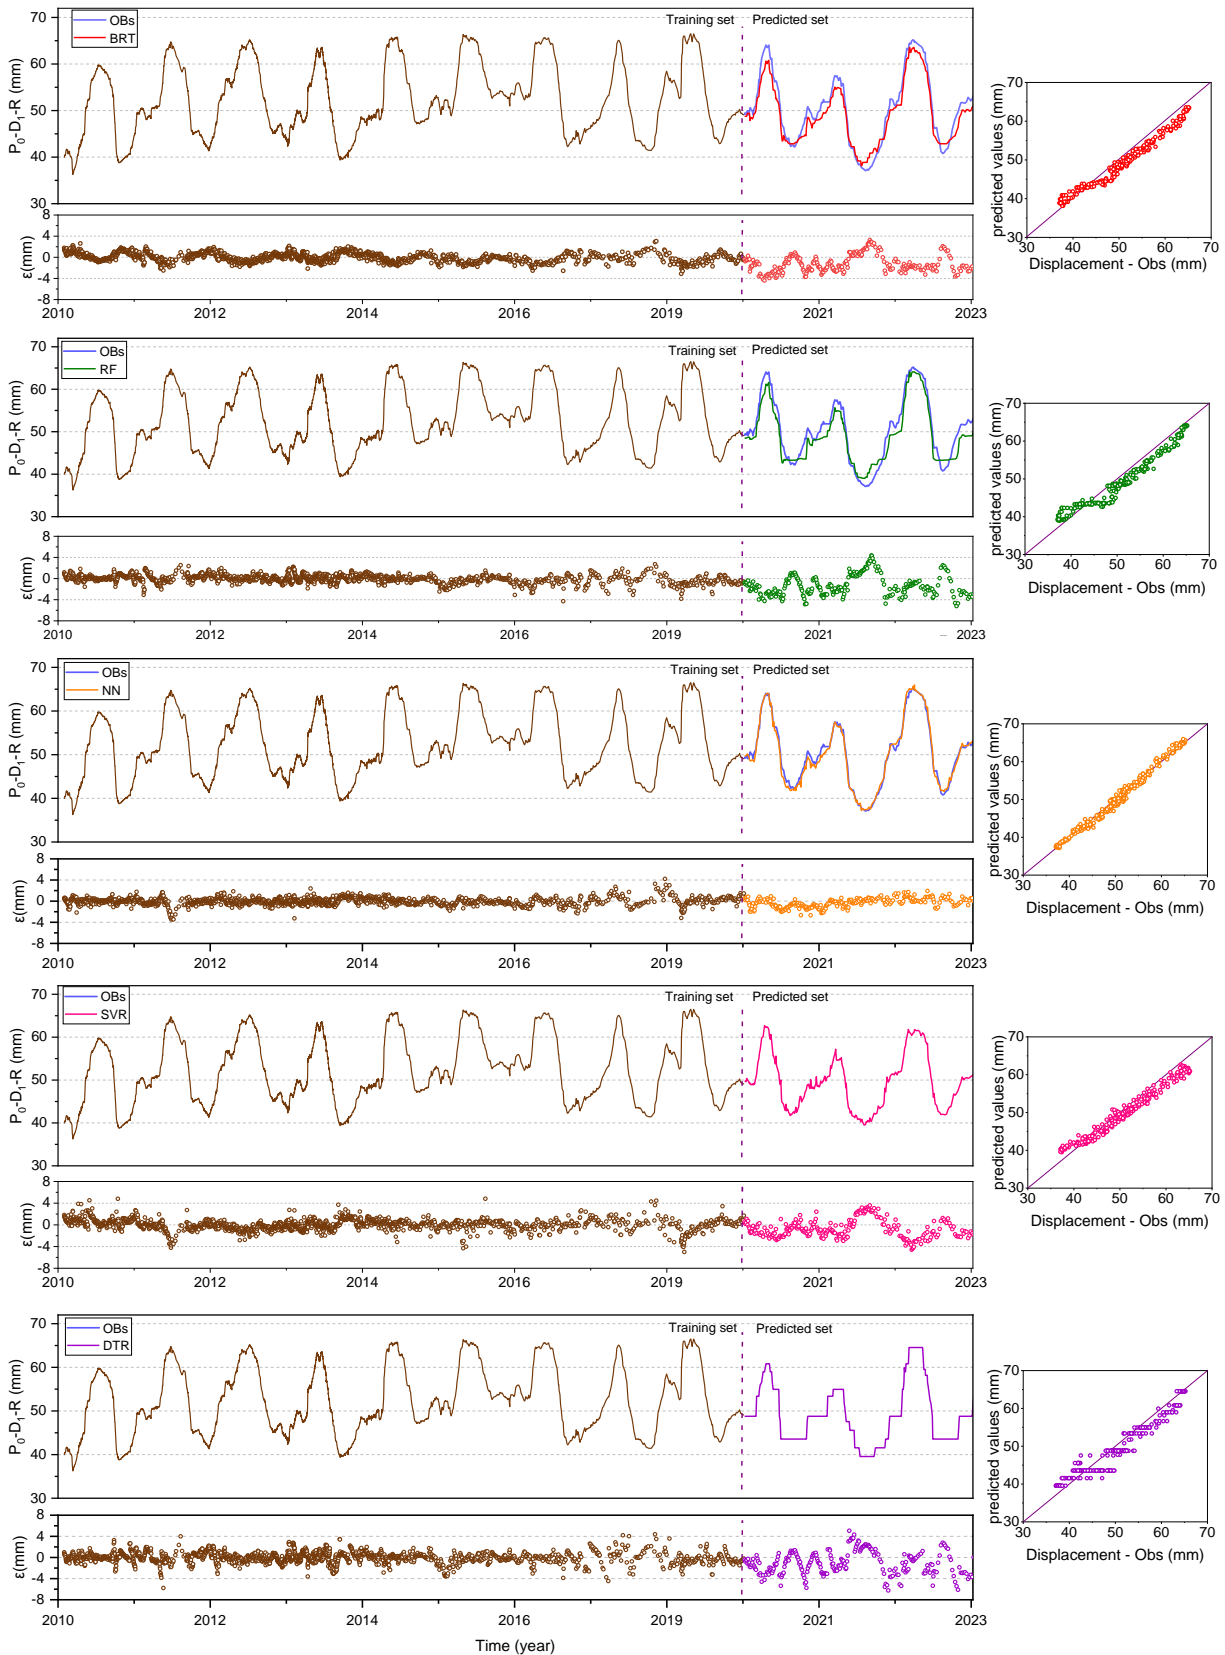



تضمین دقت بالا در کاربردهای عملی مدل‌ها را نمی‌دهد. این به دلیل آن است که مدل‌های یادگیری ماشین ممکن است بیش از حد نسبت به داده‌های آموزشی برازش شوند و در نتیجه، در مواجهه با داده‌های جدید، دقت پیش‌بینی واقعی بسیار پایین‌تری داشته باشد.

2.4. مرحله 2 صحت‌سنجی پیش‌بینی

صحت‌سنجی پیش‌بینی‌کننده در زمینه یادگیری ماشین، فرآیندی است که برای ارزیابی عملکرد یک مدل پیش‌بینی‌کننده بر روی داده‌های جدید و دیده نشده استفاده می‌شود. این شامل ارزیابی توانایی مدل برای پیش‌بینی دقیق داده‌هایی است که روی آن‌ها آموزش ندیده است. در این مرحله از صحت‌سنجی، از همان روش‌های مشابه به کار گرفته شده در تجزیه و تحلیل داده‌های تاریخی نسبت به مجموعه داده‌هایی که در طول فرایند برازش مدل، مورد استفاده قرار نگرفته است، استفاده می‌شود. تجزیه و تحلیل پیش‌بینی‌ها برای این دوره باید بر تشخیص وجود بیش از حد برازش در مدل‌های یادگیری ماشین متمرکز شود.

با توجه به محدودیت فضا، تنها یکی از متغیرهای هدف تعریف شده ارائه شده است. شکل 5 به عنوان نمونه، پیش‌بینی‌های مدل و خروجی‌های مشاهده شده را در کنار باقیمانده‌های آنها برای هدف $P0-D1-R$ نشان می‌دهد. ارزیابی اولیه برای همه مدل‌های جابجایی شعاعی سد در هر شش هدف، نشان می‌دهد که در سری‌های زمانی، همه مدل‌های یادگیری ماشین تمایل به پیش‌بینی جابجایی‌های کمتری نسبت به جابجایی‌های مشاهده شده توسط ابزار پاندول دارند. توجه به این نکته ضروری است که به دلیل تغییرات در سطح مخزن، فرکانس خواندن سطح آب در طول دوره پیش‌بینی کمتر از دوره آموزشی است. با در نظر گرفتن این عامل، جابجایی‌های پایین در پیش‌بینی‌ها منطقی به نظر می‌رسند. در واقع، ارزیابی ارقام با انتظارات تعیین شده در مراحل قبلی مطابقت دارد. با توجه به نتایج ارائه شده در مراحل قبل، دوباره مدل‌های BRT و NN دقت بالاتری از پیش‌بینی‌ها را نشان می‌دهند و پیش‌بینی‌های جابجایی شعاعی را با نوسان کمتری نسبت به جابجایی‌های قرائت شده نسبت به مدل‌های دیگر (DTR, SVR, RF) تولید می‌کنند. علاوه بر این، بررسی باقیمانده‌ها (تفاوت بین پیش‌بینی‌ها و مشاهدات) و نمودار $1/1$ (نمودار جابجایی پیش‌بینی شده در مقابل مشاهدات) مجدداً تأیید می‌کند که این مدل‌ها کمترین مقدار باقی‌مانده و کمترین پراکندگی را در مقایسه با سایر مدل‌های بکار گرفته شده نشان می‌دهند. از این رو، می‌توان اظهار نمود که مدل‌های BRT و RF توانایی قابل قبولی را برای پیش‌بینی جابجایی‌های شعاعی ابزار دقیق پاندول دارا می‌باشند.

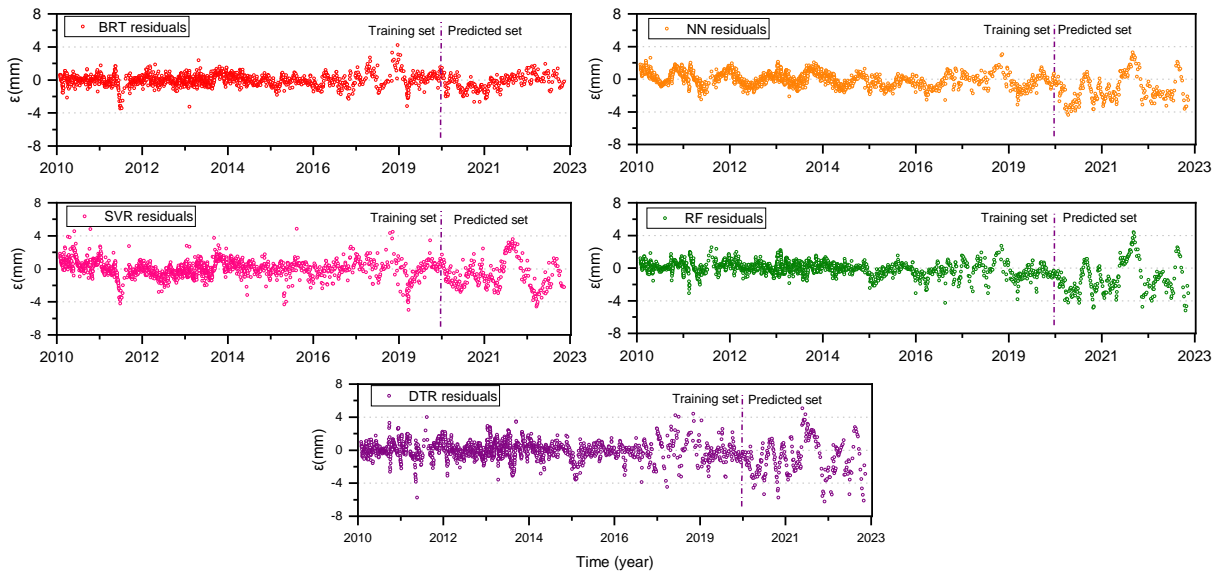


شکل 5 - اندازه‌گیری مجموعه داده پیش‌بینی با مدل‌های یادگیری ماشین و پاسخ قرائت شده توسط ابزار دقیق پاندول برای جابه‌جایی شعاعی - P0-D1-R در بلوک 0.


2.4. مرحله 3 رفتار باقیمانده در طول زمان

رفتار باقیمانده جابه‌جایی‌ها، یک تکنیک در زمینه یادگیری ماشین است که برای نظارت و تجزیه و تحلیل عملکرد یک مدل در طول زمان استفاده می‌شود. این روش به ما این امکان را می‌دهد تا تفاوت بین پیش‌بینی جابه‌جایی‌های مدل و جابه‌جایی‌های مشاهده شده واقعی متغیر هدف را برای مجموعه داده‌های جدید و دیده‌نشده برای تمامی متغیرهای هدف مورد بررسی و ارزیابی قرار دهیم. اثر زمان اغلب به عنوان بخشی از تغییر شکل‌های غیرقابل بازگشت در جابه‌جایی‌ها تفسیر می‌شود. این به این دلیل است که استفاده از اصطلاح زمان می‌تواند تمام اثراتی که در هر لحظه بر سد وارد شده‌اند، اما در مدل‌ها در نظر گرفته نشده‌اند، را در بر بگیرد.

با توجه به محدودیت فضا، تنها یکی از متغیرهای هدف تعریف شده ارائه شده است. شکل 6 به عنوان نمونه، ارزیابی رفتار باقیمانده در طول زمان را نشان می‌دهد که شامل مجموعه داده‌های آموزشی در کنار مجموعه داده‌های پیش‌بینی برای هدف P_0-D_1-R است. ارزیابی سیر تکاملی سری‌زمانی باقیمانده جابه‌جایی‌های شعاعی برای هر یک از شش هدف انتخابی نشان می‌دهد که باقیمانده‌ها در بخش پیش‌بینی، زمانی که داده‌های جدید به مدل‌ها ارائه می‌شوند، افزایش محسوس‌تری در باقیمانده‌ها مشاهده می‌شود. با این حال، در کل دوره زمانی (شامل هر دو مجموعه آموزش و پیش‌بینی)، باقیمانده‌ها همچنان روند خطی را نشان می‌دهند و تقریباً از یک مدل خطی پیروی می‌کنند. این رفتار با یافته‌های بیان شده توسط گوا [35] (GUO) همخوانی دارد. اگرچه همه مدل‌ها رفتار یکنواختی را از خود نشان نداده‌اند، اما مشاهده می‌شود که مدل‌های BRT و NN، در مقایسه با سایر مدل‌ها، دارای باقیمانده‌های مشابه با رفتار دوره آموزشی می‌باشند. این نشان‌دهنده رفتار یکنواخت این مدل‌ها در مواجهه با داده‌های جدید و دیده‌نشده می‌باشد.



شکل 6 - باقیمانده جابه‌جایی‌های شعاعی در هر دو مجموعه داده‌های آموزشی و پیش‌بینی شده - P_0-D_1-R در بلوک 0.



2.4. مرحله 4 مقایسه عملکرد و انتخاب مدل

این مرحله امکان انتخاب بهترین مدل با تکیه بر نتایج سه مرحله قبلی تکنیک‌های صحت‌سنجی و راستی‌آزمایی مدل را فراهم می‌کند، و می‌توان تایید کرد که کدام یک از مدل‌های یادگیری ماشین عملکرد رضایت‌بخشی را در آموزش و پیش‌بینی جابجایی‌های شعاعی از خود نشان می‌دهد. با این حال، می‌توان ادعا کرد که مدل‌های BRT و NN نسبت به سایر مدل‌ها (DTR, RF, SVR) در آموزش و پیش‌بینی جابجایی سد عملکرد بهتری داشتند. از طرفی، مدل‌های DTR و SVR پایین‌ترین رضایت را در آموزش و پیش‌بینی نشان داده و در اکثر موارد همراه با نوسان و خطا بیشتری نسبت به سایر مدل‌ها بوده‌اند. علاوه بر این، بر اساس نتایج ارائه شده در بخش 5.6 مرحله 2، در ارتباط با پیش‌بینی‌های انجام شده توسط مدل BRT، مشاهده شد که این مدل‌ها استحکام بیشتری را نشان می‌دهند (وابستگی کمتری به پارامترهای ورودی) و تمایل کمتری به بیش‌برازش از خود نشان می‌دهند. همچنین، مدل BRT انسجام بهتری نسبت به مدل NN و RF نشان داده و نوسان کمتری را در پیش‌بینی جابجایی سد ارائه کرده‌است. در نهایت، مدل BRT به عنوان بهترین مدل یادگیری ماشین در آموزش و پیش‌بینی رفتار جابجایی شعاعی سد مورد مطالعه انتخاب گردید.

5. نتیجه‌گیری


مدل‌های مبتنی بر داده نقش مهمی در کنترل ایمنی سدها، تجزیه و تحلیل و پیش‌بینی رفتار سازه‌ای با ارزیابی جابجایی‌های پیش‌بینی‌شده، با در نظر گرفتن تأثیرات بارهای اصلی مانند هیدرواستاتیک، دما، و زمان ایفا می‌کنند. گام اساسی در پیش‌بینی رفتار سازه‌ای سدها، انتخاب مدل برتر و مناسب ساخته‌شده با استفاده از داده‌های جمع‌آوری‌شده توسط ابزار دقیق در بخش‌های مختلف سد است.

در این مقاله، صحت‌سنجی و ارزیابی دقت مدل در دو بخش با استفاده از شاخص‌های ارزیابی خطا و تکنیک‌های صحت‌سنجی و راستی‌آزمایی برای تعیین بهترین مدل یادگیری ماشین با اطمینان کافی انجام شده است. مدل‌های مورد استفاده در این مطالعه شامل درختان رگرسیون تقویت‌شده، جنگل‌های تصادفی، رگرسیون بردار پشتیبان، شبکه‌های عصبی و رگرسیون درخت تصمیم می‌باشد. برای مرحله اولیه، از سه شاخص ارزیابی خطای مدل، شامل میانگین خطای مطلق (MAE)، میانگین مربعات خطا (MSE)، و ضریب تعیین (R^2) برای ارزیابی دقت مدل‌ها با در نظر گرفتن دو مجموعه داده آموزشی و آزمایشی استفاده شد. در مرحله دوم، بر اساس ویژگی‌های کنترل ایمنی، چهار تکنیک برای صحت‌سنجی و راستی‌آزمایی مدل به کار گرفته شده است. این تکنیک‌ها شامل صحت‌سنجی داده‌های تاریخی، صحت‌سنجی پیش‌بینی‌کننده، رفتار باقی‌مانده در طول زمان و مقایسه عملکرد و انتخاب مدل است. در این بخش با در نظر گرفتن یک مجموعه داده 13 ساله از جابجایی‌های شعاعی متشکل از داده‌های مه 2010 تا دسامبر 2019 برای صحت‌سنجی داده‌های تاریخی و از داده‌های ژانویه 2020 تا دسامبر 2022 برای صحت‌سنجی داده‌های پیش‌بینی استفاده شد.



نتایج به‌دست‌آمده نشان می‌دهد که مدل BRT در آموزش و پیش‌بینی جابجایی‌های شعاعی در شش هدف مشخص شده در کل بدنه سد، نسبت به سایر مدل‌ها (DTR, RF, NN, SVR) برتری دارد. این نتیجه نشان می‌دهد که پیاده‌سازی مدل BRT به سادگی انجام می‌شود و دقت قابل توجهی در پیش‌بینی ارائه می‌دهد. این مدل با اندازه مناسب مجموعه آموزشی عمل می‌کند و حساسیت کمی به پیش‌بینی‌های مرتبط با نوسانات از خود نشان می‌دهد.

6. مراجع

[1] RSB. Regulation for the Safety of Dams; Decree-Law number 21/2018 of March 28; RSB: Porto, Portugal, 2018.



- [2] Lombardi G. Advanced data interpretation for diagnosis of concrete dams. CISM Udine, Italy. 2004 Dec.
- [3] International Commission on Large Dams, Dam surveillance guide, tech. rep. B- 158, ICOLD; 2012.
- [4] Salazar F, Toledo MÁ, Oñate E, Suárez B. Interpretation of dam deformation and leakage with boosted regression trees. *Engineering Structures*. 2016 Jul 15;119:230-51.
- [5] Dai B, Gu C, Zhao E, Qin X. Statistical model optimized random forest regression model for concrete dam deformation monitoring. *Structural Control and Health Monitoring*. 2018 Jun;25(6):e2170.
- [6] Mata J. Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. *Engineering structures*. 2011 Mar 1;33(3):903-10.
- [7] Ren Q, Li M, Li H, Shen Y. A novel deep learning prediction model for concrete dam displacements using interpretable mixed attention mechanism. *Advanced Engineering Informatics*. 2021 Oct 1;50:101407.
- [8] Ranković V, Grujović N, Divac D, Milivojević N. Development of support vector regression identification model for prediction of dam structural behaviour. *Structural Safety*. 2014 May 1;48:33-9.
- [9] Hariri-Ardebili MA, Pourkamali-Anaraki F. Support vector machine based reliability analysis of concrete dams. *Soil Dynamics and Earthquake Engineering*. 2018 Jan 1;104:276-95.
- [10] Murthy SK. Automatic construction of decision trees from data: A multi-disciplinary survey. *Data mining and knowledge discovery*. 1998 Dec;2:345-89.
- [11] Salazar F, Morán R, Toledo MÁ, Oñate E. Data-based models for the prediction of dam behaviour: a review and some methodological considerations. *Archives of computational methods in engineering*. 2017 Jan;24:1-21.
- [12] Hochreiter S, Schmidhuber J. Long short-term memory. *Neural computation*. 1997 Nov 15;9(8):1735-80.
- [13] Tatin M, Briffaut M, Dufour F, Simon A, Fabre J-P. Thermal displacements of concrete dams: accounting for water temperature in statistical models. *Eng Struct* 2015;91:26–39.
- [14] Su H, Chen Z, Wen Z. Performance improvement method of support vector machine-based model monitoring dam safety. *Structural Control and Health Monitoring*. 2016 Feb;23(2):252-66.
- [15] Salazar F, Toledo MA, Oñate E, Morán R. An empirical comparison of machine learning techniques for dam behaviour modelling. *Structural Safety*. 2015 Sep 1;56:917.
- [16] De Granrut M, Simon A, Dias D. Artificial neural networks for the interpretation of piezometric levels at the rock-concrete interface of arch dams. *Engineering Structures*. 2019 Jan 1;178:616-34.
- [17] Rico J, Barateiro J, Mata J, Antunes A, Cardoso E. Applying advanced data analytics and machine learning to enhance the safety control of dams. *Machine Learning Paradigms: Applications of Learning and Analytics in Intelligent Systems*. 2019:315-50.
- [18] Sargent, R. Verification and validation of simulation models. In *Proceedings of the 2010 Winter Simulation Conference, Baltimore, MD, USA, 5–8 December 2010*.
- [19] Mata J, Salazar F, Barateiro J, Antunes A. Validation of machine learning models for structural dam behaviour interpretation and prediction. *Water*. 2021 Oct 1;13(19):2717.
- [19] Hariri-Ardebili MA, Barak S. A series of forecasting models for seismic evaluation of dams based on ground motion meta-features. *Engineering Structures*. 2020 Jan 15;203:109657.



- [20] Breiman L. Random forests. *Mach Learning* 2001;45(1):05–32.
- [21] Genuer R, Poggi JM, Tuleau-Malot C. Variable selection using random forests. *Pattern recognition letters*. 2010 Oct 15;31(14):2225-36.
- [22] Thakur M, Kumar D. A hybrid financial trading support system using multi-category classifiers and random forest. *Applied Soft Computing*. 2018 Jun 1;67:337-49.
- [23] Vapnik V. The support vector method of function estimation. In *Nonlinear modeling: Advanced black-box techniques* 1998 Jan (pp. 55-85). Boston, MA: springer us.
- [24] Vapnik V. *The nature of statistical learning theory*. Springer science & business media; 2013.
- [25] Bishop CM. *Neural networks for pattern recognition*. Oxford university press; 1995 Nov 23.
- [26] Gershenfeld NA. *The nature of mathematical modeling*. Cambridge university press; 1999.
- [27] Zhang G, Patuwo BE, Hu MY. Forecasting with artificial neural networks:: The state of the art. *International journal of forecasting*. 1998 Mar 1;14(1):35-62.
- [28] Appleyard J, Kocisky T, Blunsom P. Optimizing performance of recurrent neural networks on gpus. *arXiv preprint arXiv:1604.01946*. 2016 Apr 7.
- [29] Nair V, Hinton GE. Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* 2010 (pp. 807-814).
- [30] Breiman L, Friedman JH, Olshen RA, Stone CJ. *Classification and regression trees*. Monterrey, CA: Wadsworth & Brooks; 1984.
- [31] Elith J, Leathwick JR, Hastie T. A working guide to boosted regression trees. *Journal of animal ecology*. 2008 Jul;77(4):802-13.
- [32] Auret L, Aldrich C. Empirical comparison of tree ensemble variable importance measures. *Chemometrics and Intelligent Laboratory Systems*. 2011 Feb 15;105(2):157-70.
- [33] Rizzo G, d'Amato C, Fanizzi N, Esposito F. Tree-based models for inductive classification on the web of data. *Journal of Web Semantics*. 2017 Aug 1;45:1-22.
- [34] Ranković V, Grujović N, Divac D, Milivojević N, Novaković A. Modelling of dam behaviour based on neuro-fuzzy identification. *Engineering Structures*. 2012 Feb 1;35:107-13.
- [35] Guo X, Baroth J, Dias D, Simon A. An analytical model for the monitoring of pore water pressure inside embankment dams. *Engineering Structures*. 2018 Apr 1;160:356-65.