

نقش هوش مصنوعی و مدل‌های عددی برای ارزیابی و پیش‌بینی جامع سلامت سازه در

مهندسی سد: مروری جامع و سیستماتیک

میلاد مرادی سارخانلو^{۱*}

۱- دانشجوی دکتری مهندسی عمران - گرایش مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه صنعتی شریف، تهران،

ایران، milad.msh@sharif.edu

خلاصه

ارزیابی سلامت سدها در حفظ پایداری و تعیین طول عمر سازه به موضوعی بسیار مهم تبدیل شده است. مدل‌های ارزیابی سلامت سد با پیشرفت حسگرها و ابزارهای دقیق جمع‌آوری داده، می‌توانند تخمینی از پاسخ‌های سد نسبت به اندازه‌گیری‌های واقعی تحت شرایط بارگذاری استاتیکی و دینامیکی ارائه کنند و نتیجه‌گیری در مورد ایمنی و سلامت سد را ممکن سازند. این مقاله به مروری بر مدل‌های مختلف ارزیابی سلامت سد در چند سال گذشته پرداخته است. در این مقاله، مدل‌های ارزیابی به سه دسته مدل‌های عددی، داده‌محور و مدل‌های ترکیبی طبقه‌بندی شده‌اند. در میان این سه مدل، مدل‌های داده‌محور در سال‌های اخیر به دلیل پیشرفت در هوش مصنوعی و سایر ابزارهای آماری مورد توجه قرار گرفته‌اند. در این مقاله، مروری سیستماتیک از این مدل‌ها به همراه کاربرد، مزایا و محدودیت‌های آن‌ها پوشش داده شده و خلاصه‌ای از دانش موجود در زمینه ارزیابی سلامت سد برای تشخیص و تحلیل آسیب سازه سد بررسی شده است.

کلمات کلیدی: ارزیابی سلامت سد، مدل‌های عددی، مدل‌های داده‌محور، مدل‌های ترکیبی، هوش مصنوعی.

۱. مقدمه

سد بخشی جدایی‌ناپذیر از زیرساخت‌های عمومی هر کشور است که چندین مزیت از جمله کنترل سیل، آبیاری، تولید برق آبی، تأمین آب، گردشگری و تفریح را برای کشور فراهم می‌کند. با این حال، همانند هر زیرساخت دیگری، مصالح سد در طول زمان تخریب می‌شود یا به دلیل افزایش بارهای ناگهانی ممکن است منجر به شکست فاجعه‌بار شود. شکست سد می‌تواند به دلایل مختلفی همچون تخریب مصالح در طول زمان، نواقص در ساخت و ساز، ارتعاشات زلزله، تعمیر و نگهداری ناکافی، شرایط آب و هوایی نامناسب و افزایش فشار هیدرواستاتیکی رخ دهد [۱]. از این رو، ارزیابی سلامت سد به صورت دوره‌ای برای حفاظت از سازه‌های سد قبل از وقوع هرگونه فاجعه بسیار مهم است [۲]. مدل‌های رفتاری جزء اساسی از سیستم‌های ایمنی سد هستند که هم برای عملیات روزانه و هم برای ارزیابی رفتار درازمدت سد کارایی دارند. این روش‌ها برای محاسبه پاسخ سد تحت شرایط ایمن برای یک ترکیب بار معین طراحی شده‌اند که با اندازه‌گیری‌های واقعی عملکرد سد مقایسه می‌شوند [۳].

بنابراین، ارزیابی سلامت سد با استفاده از مدل‌های پیش‌بینی امری ضروری است. به طور عمده می‌توان مدل‌های ارزیابی سلامت سد را در سه دسته مدل‌های عددی، مدل‌های داده‌محور و مدل‌های ترکیبی طبقه‌بندی کرد. مدل‌های عددی که به عنوان مدل‌های قطعی نیز شناخته می‌شوند، معمولاً بر اساس روش اجزای محدود و تکنیک‌های شناسایی سیستم عمل می‌کنند و پاسخ سد را بر اساس قوانین فیزیکی حاکم مدل‌سازی می‌کنند. از سوی دیگر، مدل‌های داده‌محور، رفتار سد را با استفاده از داده‌های جمع‌آوری شده از ابزارهای دقیق و حسگرهای مختلف نصب‌شده در سد مدل‌سازی می‌کنند. تکنیک‌های آماری و هوش مصنوعی به‌طور گسترده‌ای برای مدل‌سازی پاسخ‌های سد در برابر بارهای خارجی و عوامل محیطی به کار می‌روند. اطلاعات بیشتر در مورد روش‌های عددی را می‌توان در [۴،۵] یافت.

ارزیابی ریسک و عدم قطعیت برای اطمینان از ایمنی زیرساخت‌ها و سدها بسیار مهم است [۷،۶]. جمع‌آوری و کمی‌سازی داده‌ها با رویکردهای سنتی برای تجزیه و تحلیل دستی داده‌ها به منظور تصمیم‌گیری آگاهانه در مورد طراحی و ایمنی سدها، می‌تواند با استفاده از هوش مصنوعی بهبود یابد [۸]. با هوش مصنوعی، الگوها و ناهنجاری‌هایی که ممکن است برای مهندسان انسانی آشکار نباشد، به‌طور خودکار شناسایی شده و ارزیابی ایمنی و تصمیم‌گیری‌ها به فرآیندی سیستماتیک و هوشمندانه تبدیل می‌شود. توسعه مدل‌های فیزیکی برای شبیه‌سازی رفتار سدها در شرایط مختلف بسیار دشوار و در بیشتر موارد با تکنیک‌های سنتی غیرممکن است، در حالی که هوش مصنوعی می‌تواند از الگوریتم‌های یادگیری ماشین برای ایجاد مدل‌های پیش‌بینی دقیق‌تر استفاده کند [۹]. اگرچه مدل‌های هوش مصنوعی ممکن است کارآمدتر باشند، اما نتایج ارائه‌شده باید توسط مهندسان انسانی ارزیابی و تایید شوند [۱۰]. از این رو، انجام بازرسی‌های دستی و بصری برای تشخیص خطرات و ارزیابی ایمنی سد ضروری است، اما تجزیه و تحلیل مبتنی بر هوش مصنوعی می‌تواند به کاهش زمان و هزینه‌های مرتبط با تجزیه و تحلیل دستی کمک کرده و آن را کارآمدتر کند.

برای ارزیابی سلامت سازه در مهندسی سد، انواع رویکردهای مبتنی بر داده از جمله تکنیک‌های یادگیری ماشین پیشنهاد شده است. یادگیری ماشین زیرشاخه‌ای از هوش مصنوعی است که بر توسعه الگوریتم‌ها و مدل‌های آماری تمرکز دارد و رایانه‌ها را قادر می‌سازد از مجموعه داده‌های جمع‌آوری شده یاد بگیرند و عملکرد خود را در کارهای خاص در طول زمان بهبود بخشند [۱۱]. پیشرفت‌های تکنولوژی در حسگرها و ابزارهای دقیق در حوزه مهندسی سد، توانایی نظارت طولانی‌مدت سد را فراهم کرده است. از این رو، ارزیابی سلامت سد مستلزم نصب تعداد زیادی ابزار دقیق برای جمع‌آوری اطلاعات ارزشمند از ساختار و رفتار بخش‌های مختلف سد می‌باشد.

بیشتر مسائل ارزیابی سلامت سد، نیازمند جمع‌آوری داده‌های برچسب‌گذاری شده به عنوان مجموعه داده‌های آموزشی و پیش‌بینی است که برای ساخت، ارزیابی و صحت‌سنجی مدل‌های یادگیری ماشین که در تجزیه و تحلیل رفتار سد کاربرد دارد، استفاده می‌شوند. روش‌های مختلفی برای طبقه‌بندی الگوریتم‌های یادگیری ماشین بر اساس رویکرد یادگیری، ساختار مدل و نوع داده‌های به کار گرفته شده وجود دارد. یکی از محبوب‌ترین طبقه‌بندی‌ها شامل، (۱) یادگیری تحت نظارت، که در آن الگوریتم با یادگیری از روی الگوی داده‌های برچسب‌دار، توانایی پیش‌بینی الگوها را پیدا می‌کند. (۲) یادگیری بدون نظارت، که در آن الگوریتم با یادگیری الگوهای داده‌های بدون برچسب، صرفاً بر اساس شباهت و بدون هیچ دسته‌بندی تعریف‌شده‌ای، الگوها را طبقه‌بندی می‌کند. (۳) یادگیری نیمه‌نظارتی، که در آن الگوریتم از داده‌های برچسب‌دار و بدون برچسب برای آموزش استفاده می‌کند و زمانی مفید است که داده‌های برچسب‌دار محدود و داده‌های بدون برچسب زیادی وجود داشته باشد. (۴) یادگیری تقویتی، که در آن الگوریتم با اعمال بازخورد پاداش یا تنبیه از طریق تعامل با شرایط محیطی یاد می‌گیرد که اقداماتی انجام دهد که پاداش را حداکثر و تنبیه را به حداقل برساند. (۵) یادگیری عمیق، زیرمجموعه‌ای از یادگیری ماشین است که از شبکه‌های عصبی با لایه‌های متعدد برای یادگیری الگوها و روابط پیچیده در داده‌ها استفاده می‌کند. (۶) یادگیری آنلاین، که در آن الگوریتم از داده‌ها در جریان پیوسته به جای دسته‌ای یاد می‌گیرد و زمانی مفید است که داده‌ها به طور مداوم در حال تغییر یا تکامل در طول زمان هستند. این رویکردهای

مختلف یادگیری ماشین به مهندسان این امکان را می‌دهند که مدل‌های دقیق‌تر و کارآمدتری برای ارزیابی سلامت سدها ایجاد کنند و بهبود عملکرد و ایمنی سدها را تضمین کنند.

چندین مقاله مروری در مورد کاربرد یادگیری ماشین در زمینه‌های مختلف مهندسی سد منتشر شده است که در جدول (۱) ارائه شده است. به عنوان مثال، سالازار و همکاران [۳] مروری بر مدل‌های هوش مصنوعی همراه با ملاحظات ریاضی برای تحلیل ایمنی سد با در نظر گرفتن جنبه‌های مختلفی همچون انتخاب متغیرهای ورودی، تقسیم‌بندی مجموعه داده‌های آموزشی و اعتبارسنجی، و تحلیل خطای مدل انجام دادند. بوکنیا و همکاران [۱۲] مروری بر روش‌های استاتیکی و دینامیکی برای پایش سلامت سدهای بتنی ارائه کردند. در مقاله مروری دیگری، لی و همکاران [۱۳] مروری بر مدل‌های داده‌محور برای ارزیابی سلامت سد ارائه کردند. آنها چنین مدل‌هایی را در سه دسته، مدل نظارتی، مدل شاخص نظارتی، و ارزیابی و تشخیص رفتارهای غیرعادی تقسیم‌بندی کردند. مدل نظارتی، یک مدل ورودی-خروجی است که متغیرهای محیطی را به عنوان ورودی و پاسخ سد را به عنوان خروجی در نظر می‌گیرد. مدل شاخص نظارتی، برای ایجاد هشدارهایی درباره ایمن یا نایمن بودن سد با توجه به پاسخ سد نسبت به تغییرات قبلی طراحی شده است. بطور مشابه، ارزیابی و تشخیص رفتارهای غیرعادی، برای تشخیص تغییرات غیرعادی در وضعیت سد استفاده می‌شود. حریری اردبیلی و همکاران [۱۴] نیز مروری بر نقش مدل‌های هوش مصنوعی و فناوری‌های دیجیتال در مهندسی سد، برای مدل‌های پیش‌بینی‌کننده، نظارت در زمان واقعی، بهینه‌سازی و تأثیرات فناوری‌های نوظهور در ارزیابی ایمنی سد داشتند. با این حال، این مقاله مروری به بررسی کاربرد انواع روش‌های مختلف همچون روش‌های عددی، هوش مصنوعی و مدل‌های ترکیبی در زمینه‌های مختلف ایمنی و سلامت در مهندسی سدها پرداخته است. به همین دلیل، مرور ادبیات موجود در این حوزه می‌تواند به شناسایی شکاف‌های تحقیقاتی و تسهیل توسعه مطالعات جدید کمک کند.


جدول ۱ - مقالات مروری اخیر در مورد مدل‌های ارزیابی سلامت سد

مراجعه	ویژگی‌ها و روش‌های مورد استفاده در مقاله
سالازار و همکاران [۳]	مدل‌های آماری، مدل‌های یادگیری ماشین، مدل‌های اجزای محدود، مروری و روش‌شناسی، ارزیابی ایمنی سدها
بوکنیا و همکاران [۱۲]	مدل‌های استاتیکی، مدل‌های دینامیکی، ارزیابی سلامت سدهای بتنی
لی و همکاران [۱۳]	مروری بر مدل‌های داده‌محور برای ارزیابی سلامت سد
حریری اردبیلی و همکاران [۱۴]	هوش مصنوعی، فناوری‌های دیجیتال و نوظهور، روش‌های عددی، ارزیابی ایمنی و سلامت سد
سیواسوریان و همکاران [۱۵]	شکست سدها به دلایل فرسایش خاک، فرسایش پاشنه سد، فرسایش آبکندی و آبستگي
زامارون و همکاران [۱۶]	مروری سیستماتیک بر تجزیه و تحلیل تصمیمات چندمعیاره در مدیریت سدهای قدیمی
مرادی و همکاران [۱۷]	تجزیه و تحلیل و مقایسه مدل‌های هوش مصنوعی همچون RF، SVR، BRT، ANN و DTR برای ارزیابی ایمنی و سلامت سدها

۲. سیستم‌های ارزیابی سلامت سد

پاسخ‌های سد مانند جابه‌جایی، ترک، خزش، تنش بتن و پارامترهایی با فرکانس‌های طبیعی سازه‌ای همچون فشار هیدرواستاتیکی، دما، سن و خواص مکانیکی بتن وابسته هستند. رابطه بین بارهای وارده بر سد و پاسخ‌های سازه‌ای، همانطور که در شکل (۱) نشان داده شده است، عمدتاً بر مبنای دو رویکرد (الف) نوع اندازه‌گیری‌های بکار گرفته شده و

(ب) تکنیک‌های مدل‌سازی، برای طبقه‌بندی مدل‌های ارزیابی سلامت سد استفاده می‌شود. از این رو، مدل‌های ارزیابی بر اساس نوع اندازه‌گیری‌های بکار گرفته شده به دو دسته (۱) مدل استاتیکی و (۲) مدل دینامیکی طبقه‌بندی می‌شوند.

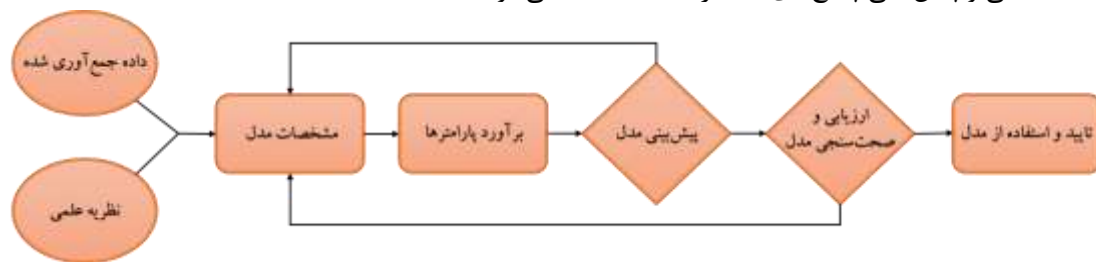


شکل ۱ - انواع بارهای خارجی وارده بر سد به همراه پاسخ‌های سد

مدل‌های استاتیکی با اندازه‌گیری‌های استاتیکی همچون جابه‌جایی بدنه سد، تنش بتن، جابه‌جایی درزها و غیره، با در نظر گرفتن پارامترهای محیطی مانند فشار هیدرواستاتیک و دما فرمول‌بندی می‌شوند [۱۸]. فرض اصلی چنین مدلی این است که پاسخ‌های مدل نسبت به پاسخ‌های سد در شرایط تخریب و شکست سد مورد ارزیابی قرار می‌گیرد تا وضعیت سلامت سد بررسی شود. مدل‌های آماری و هوش مصنوعی عمده مدل‌هایی هستند که با استفاده از اندازه‌گیری‌های استاتیکی توسعه داده شده‌اند. برخی از این مدل‌ها عبارتند از: مدل هیدرواستاتیک-فصل-زمان (HST)، هیدرواستاتیک-دما-زمان (HTT)، هیدرواستاتیک-فصل-دما-زمان (HSTT)، شبکه عصبی (NN)، مجموعه مدل‌های درختان تصمیم، مدل حافظه کوتاه مدت-بلند مدت (LSTM) [۱۹-۲۴]. از طرفی، مدل‌های دینامیکی براساس اندازه‌گیری‌هایی همچون ارتعاشات ناشی از زلزله، باد و یا امواج آب می‌باشند. در این روش، سلامت سد به‌طور غیرمستقیم و از طریق پارامترهای دینامیکی مانند فرکانس‌های طبیعی، نسبت میرایی و شکل‌های مد ارزیابی می‌شود. غالباً از دو آزمایش میدانی ارتعاشات اجباری (FVT) و ارتعاشات محیطی (AVT) برای این منظور استفاده می‌شود که با توجه به اندازه و جرم بزرگ سدها، آزمایش AVT ترجیح داده می‌شود. اخیراً پیرا و همکاران [۲۵] مطالعه‌ای برای ارزیابی دینامیکی یک سد با در نظر گرفتن تأثیرات تراز آب مخزن بر فرکانس‌های طبیعی در حالت اولین پرشدگی مخزن سد انجام دادند. برای این سد، سیستم‌های اندازه‌گیری دینامیکی به گونه‌ای تنظیم شدند که سری‌های زمانی شتاب را با نرخ نمونه‌برداری ۵۰ هرتز در مدت زمان ۳۰ دقیقه ثبت کنند. بر اساس تکنیک‌های مدل‌سازی، همان‌طوری که در بخش مقدمه به آن اشاره شد، مدل‌های ارزیابی سلامت سد به سه دسته (۱) مدل‌های عددی، (۲) مدل‌های داده‌محور و (۳) مدل‌های ترکیبی طبقه‌بندی شده‌اند.

به‌طور کلی، یک مدل ارزیابی سلامت سد را می‌توان با طی مراحل مختلف، همان‌طور که در شکل (۲) نشان داده شده است، توسعه داد. اولین گام در مدل‌سازی، جمع‌آوری داده‌ها و انتخاب یک نظریه علمی یا تکنیک ریاضی مرتبط با سیستم سد مورد مطالعه است. مجموعه داده‌های ورودی برای ساخت مدل عمدتاً متشکل از پاسخ‌های اندازه‌گیری‌شده با استفاده از ابزارهای دقیق، حسگرهای مختلف، خواص بتن، نقشه‌های ساختاری، بازرسی‌های بصری و سایر موارد می‌باشد. برخی از ابزارهای دقیق مورد استفاده در ارزیابی ایمنی سد در شکل (۳) نشان داده شده‌اند. کیفیت مجموعه داده‌های جمع‌آوری شده برای ساخت، پیش‌بینی و صحت‌سنجی مدل بسیار مهم است. طبق نظر ارائه‌شده توسط لیونگرن و همکاران [۲۶].

ارزیابی کیفیت داده‌ها نه تنها در مدیریت داده‌ها بلکه در مرحله نصب و راه‌اندازی ابزارهای دقیق و حسگرها بسیار حائز اهمیت می‌باشد. از این رو، ابزارهای مورد استفاده بایستی محکم، بادوام، و غیرحساس به دما و رطوبت باشند. به‌طور مشابه، در گام مدیریت داده‌ها نیز، داده‌های جمع‌آوری شده قبل از پردازش و تجزیه و تحلیل باید حداقل خطا را داشته باشند. زمانی که نظریه علمی متناسب با سیستم و الگوهای مجموعه داده‌ها مشخص شد، تصمیم‌گیری در مورد نوع مدل و پارامترهای مورد نیاز برای ساخت مدل‌های مربوطه اتخاذ می‌شود. در گام بعدی، از مدل‌های توسعه داده شده برای صحت‌سنجی و پیش‌بینی پاسخ‌های سد در آینده استفاده می‌شود [۲۷-۲۹].



شکل ۲ - چارچوب کلی توسعه، صحت‌سنجی و استفاده از یک مدل ارزیابی سلامت سد



شکل ۳ - ابزارهای دقیق مورد استفاده در ارزیابی سلامت سد

۳. مدل‌های عددی

مدل‌های عددی با استفاده از اصول فیزیکی و ریاضی همچون روش‌های اجزای محدود و شناسایی سیستم مورد مطالعه ساخته می‌شوند. در مدل اجزای محدود، سازه به تعدادی المان محدود با ویژگی‌های از قبل تعریف شده تقسیم‌بندی می‌شود تا جابه‌جایی آنها توسط معادلات حاکم بر فیزیک توصیف و فرمول‌بندی شود. از شرایط معادلات تغییر شکل‌های سازگار و معادلات تعادل برای ایجاد ارتباط بین تک المان با مدل کلی استفاده شده و رابطه بین نیرو و جابه‌جایی توسط قوانین مشخصه ارائه می‌شود [۳۰]. استفاده از چنین مدل‌هایی دو مزیت عمده دارد. اولاً، توانایی شناسایی تغییر شکل‌های برگشت‌ناپذیر طولانی‌مدت از طریق مقایسه پاسخ‌های پیش‌بینی‌شده توسط مدل و پاسخ‌های اندازه‌گیری‌شده وجود دارد. ثانیاً، توانایی ارزیابی رفتار سد در اولین پرشدگی مخزن که بحرانی‌ترین دوره در طول عمر یک سد محسوب می‌شود را دارا

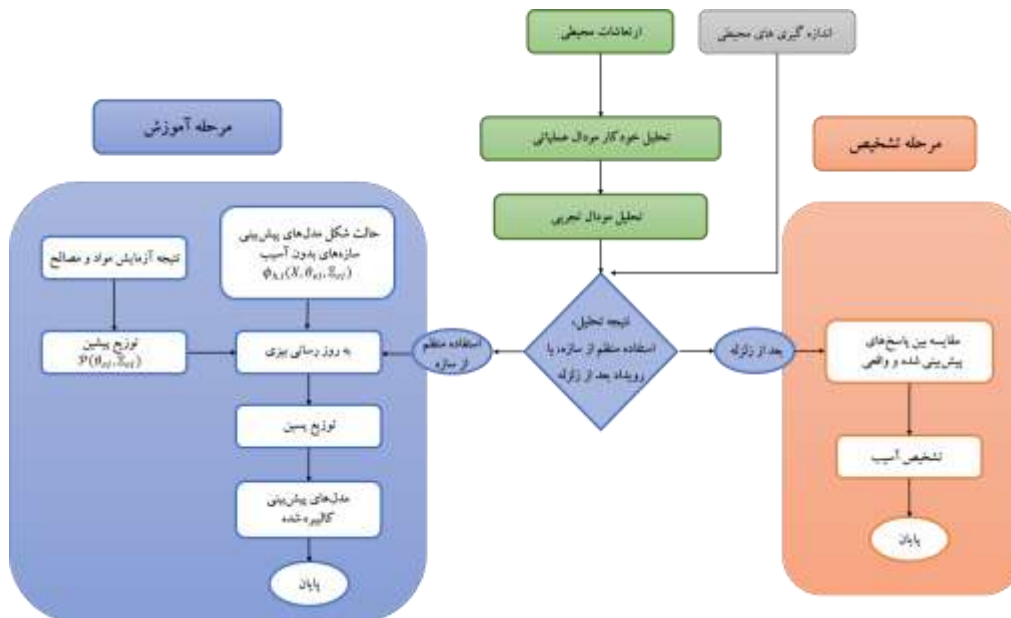
می‌باشد. آندونوف و همکاران [۳۱] مدلی را برای ارزیابی ایمنی سد Tsankov Kamak در بلغارستان در برابر خطرات ناشی از زلزله استفاده کردند. آنها از تحلیل استاتیکی غیرخطی برای ارزیابی ظرفیت سازه‌ای سد و از تحلیل دینامیکی غیرخطی برای به دست آوردن حداکثر پاسخ لرزه‌ای استفاده کردند تا ایمنی سد را با دو شاخص آسیب مبتنی بر جابه‌جایی SFS و DIIs ارزیابی کنند. همچنین، با استفاده از تکنیک‌های مبتنی بر اجزای محدود، پارامترهای فیزیکی مانند مدول یانگ الاستیک معادل برای درک رفتار کلی سازه سد تعیین شد. با نظارت بر تغییرات مدول یانگ در گذر زمان، می‌توان عیوب و پیری سد را شناسایی کرد. دی و همکاران [۳۲] نیز با استفاده از این روش، یک سد بتنی در ایتالیا را ارزیابی کردند.

به طور کلی، یک مدل عددی سعی در مدل‌سازی فرآیند تخریب فیزیکی واقعی با استفاده از معادلات مختلف دارد. از این رو، برخی محققان مطالعاتی را بر روی نمونه‌های اولیه سد انجام داده و رفتار آنها را در شرایط مختلف بارگذاری بررسی کرده‌اند. سویم و همکاران [۳۳] نمونه اولیه یک سد قوسی به ارتفاع ۶۰ سانتی‌متر را ساخته و اثر افزایش تراز مخزن آب را بر پارامترهای دینامیکی سد مانند فرکانس‌های طبیعی، شکل‌های مود و نسبت میرایی تجزیه و تحلیل کردند. آزمایش ارتعاشات محیطی بر روی مخازن خالی، مخازن پر و مخازنی با پرشدگی جزئی انجام شد. برای هر آزمایش، داده‌ها با استفاده از یازده شتاب‌سنج نصب‌شده در تاج سد جمع‌آوری شد. به‌طور مشابه، باری و همکاران [۳۴] یک مدل اولیه از یک سد وزنی با تراز ارتفاعی ۹۶ متری با در نظر گرفتن ترک‌های قبلی ساختند و رفتار سد را تحت شرایط وزن معادل بار هیدرواستاتیکی بررسی و آزمایش کردند. بار هیدرواستاتیک به طور غیرمستقیم با استفاده از یک سروو موتور محرک کنترل‌شده، با اعمال چهار بار متمرکز به سمت بالادست سد شبیه‌سازی شد. چن و همکاران [۳۵] با استفاده از قوانین تشابه، یک مدل مقیاس کوچک از یک سد وزنی طراحی کردند و نمونه اولیه را بر روی میز لرزه‌مورد آزمایش و تحلیل قرار دادند. نتایج الگوهای آسیب نشان داد که مدل مبتنی بر اجزای محدود مطابقت خوبی با رفتارهای فیزیکی واقعی به دست آمده از آزمایش میز لرزه دارد. وانگ و همکاران [۳۶] نیز آزمایش‌هایی را بر روی یک مدل مقیاس کوچک سد وزنی با ارتفاع ۲۰۳ متری در آزمایشگاه میز لرزه انجام دادند. مدل مقیاس‌شده با دو نوع امواج لرزه‌ای مورد آزمایش قرار گرفت: (۱) امواج لرزه‌ای طبق کد استاندارد چین و (۲) امواج لرزه‌ای ونچوان^۱ به عنوان یک رکورد زلزله طبیعی. نتایج نشان داد که حداکثر شتاب زلزله (PGA) که ترک اولیه را در مدل ایجاد می‌کند، می‌تواند به عنوان یک شاخص مهم در اندازه‌گیری ایمنی بخش سرریز سد تحت زلزله‌های قوی استفاده شود. مقادیر PGA برای ایجاد ترک‌های اولیه در کد استاندارد چین و رکورد زلزله ونچوان به ترتیب ۰.۳۷۱g و ۰.۳۴۵g بود. سویری و همکاران [۳۷] یک چارچوب برای ارزیابی دینامیکی سلامت سدهای وزنی در محیط بیزی نشان داده شده در شکل (۴) ارائه کردند. در این روش، آنها از داده‌های حاصل از ارتعاشات محیطی و تحلیل مودال عملیاتی برای به‌روزرسانی پارامترهای مدل پیش‌بینی سد استفاده کردند.

وو و همکاران [۳۸] از روش اجزای محدود و تحلیل‌های نظارتی برای بررسی تغییر شکل، تنش و تراوش سد در طول آبیگری اولیه سد قوسی Jinping-I در چین استفاده کردند. نتایج نشان داد که تغییر شکل بدنه و فونداسیون سد در محدوده طراحی قرار داشته است. توزیع تنش سد نرمال بوده و کمتر از معیارهای کنترل طراحی بوده است. همچنین مجموع جریان‌های تراوش سد کمتر از ظرفیت زهکشی طراحی شده بود. بنابراین، دو رویکرد تحلیل نظارتی و روش‌های عددی مبتنی بر اجزای محدود برای پیش‌بینی پاسخ سدهای مختلف مکمل یکدیگر هستند. با وجود کاربردهای متعدد، مدل‌های عددی محدودیت‌های خاص خود از جمله، نیاز به تلاش قابل توجهی در مدل‌سازی و کالیبراسیون مدل دارند [۳۹،۴۰]. با این حال، اعمال تغییر شکل‌های مرتبط با گذر زمان مانند نشست یا خزش در این مدل‌ها دشوار است، در حالی که می‌توان این تغییرات را در مدل‌های داده‌محور متناسب با اندازه‌گیری‌های دقیق ابزارها در نظر گرفت. همچنین، به دلیل اعمال فرضیات و ساده‌سازی‌ها در خصوصیات مواد، هندسه و شرایط مرزی، درجه قابل توجهی از عدم قطعیت

¹ Wenchuan

وجود دارد. به طور کلی، مدل‌های عددی ابزاری بسیار مهم در عمر اولیه سد هستند زیرا داده‌های کافی برای ساخت مدل‌های داده‌محور وجود ندارد. از سوی دیگر، مدل‌های داده‌محور برای مواردی مناسب هستند که داده‌های ابزار دقیق به صورت بلندمدت در دسترس بوده و آسیب‌ها و مکانیزم‌های تخریب سد به خوبی شناسایی نشده باشند.



شکل ۴ - مراحل آموزش و آزمایش یک مدل آماری

۴. مدل‌های داده‌محور

نوع دیگری از مدل که به‌طور گسترده برای ارزیابی سلامت سد استفاده می‌شود، مدل‌های داده‌محور هستند. پیشرفت‌های اخیر در فناوری‌های مختلف سنجش، مانند حسگرها و ابزارهای دقیق، ارزیابی ایمنی و تشخیص خطرات احتمالی را از طریق جمع‌آوری مجموعه داده‌های برگرفته از رفتار بخش‌های مختلف سد، افزایش داده است. این امر به‌ویژه با توجه به ادغام مهندسی سازه و علم داده اهمیت پیدا می‌کند. برخلاف مدل‌های عددی، این نوع مدل‌ها را می‌توان با صرف زمان و هزینه کمتری توسعه داد و پارامترهای آن‌ها را با داده‌های موجود برآورد و به‌روزرسانی کرد. این مدل‌ها عمدتاً مبتنی بر مدل‌های آماری و مدل‌های هوش مصنوعی هستند.

۱.۴. مدل‌های آماری

به منظور پیش‌بینی رفتار ساختاری، روش‌های سنتی به شدت بر تکنیک‌های آماری وابسته هستند [۱۹،۲۰]. این روش‌ها معمولاً شامل استفاده از متغیرهای مستقل همچون عوامل محیطی (مانند تغییرات تراز مخزن، تغییرات دمایی و میزان بارندگی) و متغیرهای وابسته (مانند جابه‌جایی، ترک‌خوردگی یا تراوش) برای ساخت مدل‌های رگرسیونی است. از این رو، مدل‌های آماری مورد استفاده در مهندسی سد شامل مدل‌های هیدرواستاتیک-فصل-زمان (HST)، هیدرواستاتیک-دما-زمان (HTT)، هیدرواستاتیک-فصل-زمان-دما (HSTT)، و هیدرواستاتیک-هیستریک-فصل-دما (HHST) می‌باشد [۴۱،۴۲].

رایج‌ترین رویکرد مبتنی بر داده برای پیش‌بینی و تجزیه و تحلیل رفتار سدهای بتنی، استفاده از مدل HST می‌باشد. این روش متشکل از فرضیات تعریف‌شده در متغیرهای ورودی مدل نسبت به پاسخ سد است که به‌طور کلی احتمال برآورده شدن این فرضیات وجود ندارد. به‌طور خاص، به دلیل همبستگی بین تغییرات تراز مخزن و تغییرات دمای هوا در سدها، فرض مستقل بودن متغیرهای تعریف‌شده می‌تواند منجر به ایجاد خطا در پیش‌بینی این مدل شود [۴۲]. از طرفی، با توجه به اینکه این مدل تعاملات خطی را مدل‌سازی می‌کند، ممکن است منجر به تفسیر نادرستی در پیش‌بینی رفتارهای غیرخطی در پاسخ سد شود [۴۳]. برخلاف مدل HST که شامل تغییرات دمایی به طور غیرمستقیم با استفاده از تابع فصلی است، مدل HTT مستقیماً از دماهای اندازه‌گیری شده استفاده می‌کند. با توجه به اینکه انواع مختلف سدهای بتنی، به ویژه سدهای قوسی، تحت تغییرات دمایی رفتار متفاوتی دارند، اعمال متغیرهای دمایی در مدل‌سازی‌ها از اهمیت ویژه‌ای برخوردار است [۴۴، ۴۵].

ماتا و همکاران [۲۰] دو مدل HTT را بر اساس تجزیه و تحلیل اجزای اصلی (PCA) داده‌های دما، برای تجزیه و تحلیل رفتار یک سد بتنی ساختند. در یک روش، از PCA برای انتخاب مناسب‌ترین دماسنج‌ها در ساخت مدل HTT استفاده کردند، در حالی که در روش دیگر، تأثیرات حرارتی توسط داده‌های دمایی تبدیل‌شده با PCA نشان داده شده است. نتایج نشان می‌دهد که با افزایش ارتفاع سد، مدل HTT نسبت به مدل HST مؤثرتر است. لو و همکاران [۴۶] یک مدل برای تجزیه و تحلیل تغییر شکل سد با تمرکز بر اثرات سطح آب و دما ایجاد کردند. با ادغام تکنیک‌های حداقل مربعات خطی و غیرخطی، این مدل خطای باقیمانده را به حداقل رسانده و از باقیمانده‌ها برای تشخیص آسیب بر اساس آستانه‌های آماری استفاده می‌نماید. این مدل برای ارزیابی ایمنی سد با استفاده از داده‌های تغییر شکل استاتیکی جمع‌آوری شده از ابزار دقیق سد Feu-Tsui در چین مورد استفاده قرار گرفت. مدل‌های دیگری نیز برای بهبود عملکرد و اعمال بیشتر تأثیرات دمایی، برگرفته از مدل‌های HST و HTT ایجاد شدند. وانگ و همکاران [۴۷] یک مدل هیدرواستاتیک-هیستریک-فصل-زمان (HHST) را برای مدل‌سازی و درک رفتار تغییر شکل سد قوسی Jinping I ایجاد کردند. یافته‌های آنها نشان داد که تغییر شکل غیرعادی در سد عمدتاً به دلیل اثرات ترکیبی تغییر شکل‌های نمایی هیدرواستاتیک و افت دمای محیط ایجاد می‌شود. یکی از معایب عمده مدل‌های آماری سنتی، عدم اتخاذ پارامترها و عدم قطعیت در مدل‌سازی می‌باشد. عدم قطعیت در مدل ارزیابی سلامت سد به دلیل عدم شناخت از داده‌های فیزیکی مانند هندسه سد، خصوصیات مواد و مصالح، مشخصات توده سنگ بستر و حالت‌های شکست سد ایجاد می‌شود. از این رو، محققان برای حل این موضوع یک مدل احتمالاتی بیزی [۴۸، ۴۹] ایجاد کرده‌اند که با دریافت تمام اطلاعات سد مورد مطالعه، عدم قطعیت را کاهش می‌دهد.

۲.۴. مدل‌های هوش مصنوعی

یکی از اشکالات عمده مدل‌های آماری این است که نمی‌توانند روابط غیرخطی و همبستگی بین متغیرها را بازتولید کنند. مدل‌های هوش مصنوعی توانایی غلبه بر این مشکلات را دارند، زیرا این مدل‌ها انعطاف‌پذیرتر بوده و توانایی دارند که روابط درونی پیچیده غیرخطی بین متغیرهای ورودی و خروجی را یاد بگیرند و عدم قطعیت‌های مختلف را در پیش‌بینی‌های خود بگنجانند. ایده اصلی تکنیک‌های هوش مصنوعی، آموزش یک مدل با داده‌های پاسخ سد و استفاده از آن برای پیش‌بینی رفتار آینده سد است. در گذشته، مدل‌های مختلف هوش مصنوعی مانند شبکه‌های عصبی (ANN)، ماشین بردار پشتیبان (SVM)، درخت رگرسیون تقویت‌شده (BRT)، یادگیری عمیق و غیره برای ارزیابی سلامت سد استفاده شده‌اند.

به عنوان مثال، مدل شبکه عصبی مصنوعی توسط وی و همکاران [۵۰]، کائو و همکاران [۵۱]، و لوه و همکاران [۱۸] به ترتیب برای پیش‌بینی جابه‌جایی افقی سد، تغییر شکل‌های استاتیکی سد، و ارزیابی روندهای بلندمدت در تغییر شکل‌های استاتیکی سد استفاده شده‌اند. لیو و همکاران [۵۲] با ارائه یک مدل ریاضی بهبود یافته برگرفته از الگوریتم شبکه عصبی و با استفاده از مجموعه داده‌های اندازه‌گیری شده از ابزار دقیق، منجر به افزایش دقت پیش‌بینی جابه‌جایی یک سد بتنی وزنی شدند. هان و همکاران [۵۳] یک مدل پیش‌بینی جدید ترکیبی از یک مدل آماری و یک شبکه عصبی پس انتشار (BPNN) برای سد Deze در چین توسعه دادند. نتایج نشان می‌دهد که مدل ترکیبی، دقت بالاتر، پیش‌بینی غیرخطی قوی، مقاومت در برابر بیش‌برازش، و قابلیت تعمیم قوی با اندازه‌های نمونه آموزشی متفاوت را ارائه می‌دهد. اسد و الاداوی [۵۴] یک شبکه عصبی مصنوعی را به عنوان یک ابزار پشتیبانی برای پیش‌بینی سطوح خطرات بالقوه سدها در ایالات متحده توسعه دادند تا از شکست‌هایی که می‌تواند منجر به عواقب شدید شود جلوگیری کنند. نتایج نشان داد که مدل توسعه داده شده علاوه بر افزایش دقت پیش‌بینی و ارائه ارزیابی با قابلیت اعتماد بالا، نیاز به بازرسی‌های مکرر و پرهزینه را نیز کاهش داده است. لی و همکاران [۵۵] یک روش پیشرفته را با ترکیب شبکه‌های عصبی باقیمانده عمیق و انتقال یادگیری برای طبقه‌بندی و مکان‌یابی خودکار ترک‌های ساختاری در سدهای بتنی ارائه دادند. این روش شامل ایجاد یک مجموعه داده تخصصی و استفاده از یک استراتژی یادگیری انتقال دو مرحله‌ای است که منجر به شناسایی دقیق ترک‌ها در شرایط مختلف محیطی سد می‌شود.

یکی دیگر از تکنیک‌های هوش مصنوعی مدل SVM یا SVR است که برای مدل‌سازی رفتار و تشخیص خطرات و آسیب‌های احتمالی در پاسخ‌های سد مورد استفاده قرار می‌گیرد. چنگ و همکاران [۵۶] از SVM برای ارزیابی ایمنی سد با تجزیه و تحلیل جابه‌جایی افقی و فشار بالارونده استفاده کردند. رانکوویچ و همکاران [۵۷] از یک مدل خودرگرسیون غیرخطی با ورودی‌های برون‌زا (NARX) برگرفته از الگوریتم SVR برای ارزیابی ایمنی یک سد بتنی با پیش‌بینی جابه‌جایی مماسی استفاده کردند. طبری و سنایی [۵۸] مدل SVR را همراه با شبکه عصبی مصنوعی برای ارزیابی ایمنی سد با پیش‌بینی جابه‌جایی تاج با استفاده از مجموعه داده‌های جمع‌آوری شده از شبیه‌سازی‌های صورت گرفته در ABAQUS انجام دادند. نتایج نشان داد که مدل SVR به‌طور قابل توجهی نسبت به مدل شبکه عصبی عملکرد بهتری داشته، خطا را تا ۳۲٪ کاهش داده و دقت و قابلیت اطمینان بالاتری را به نمایش گذاشته است.

محققان نتایج مدل‌های مختلف هوش مصنوعی را برای ارزیابی اثربخشی آن‌ها در ارزیابی سلامت سد مقایسه کرده و مناسب‌ترین مدل را برای یک سد خاص انتخاب می‌کنند. به عنوان مثال، هو و همکاران [۲۹] از مقایسه نتایج پیش‌بینی تغییر شکل یک سد بتنی با استفاده از تکنیک‌های مدل‌های جنگل تصادفی (RF)، ماشین‌های بردار پشتیبان حداقل مربعات (LS-SVM) و درخت رگرسیون تقویت شده ساده (SBRT)، برای ارزیابی ایمنی و سلامت سد استفاده کردند. به‌طور مشابه، چنگ و همکاران [۵۹] نتایج به‌دست آمده از مدل‌های مختلف هوش مصنوعی، از جمله ماشین‌های بردار پشتیبان، شبکه عصبی و مدل‌های ترکیبی را برای پیش‌بینی جابه‌جایی سد مقایسه کردند. نتایج نشان داد که مدل‌های هوش مصنوعی ترکیبی می‌توانند به‌طور مؤثر و دقیق جابجایی سدها را پیش‌بینی کنند و هشدارهای اولیه را برای افزایش ایمنی سد ارائه دهند. در یک تحقیق دیگر انجام شده توسط مرادی و همکاران [۱۷]، با مدل‌سازی رفتار جابه‌جایی شعاعی یک سد بتنی دو قوسی با استفاده از مدل‌های یادگیری ماشین شامل ANN، SVR، RF، BRT و DTR، و با ارزیابی و اعتبارسنجی جامع مدل‌ها، نشان داده شد که مدل درخت رگرسیون تقویت شده (BRT) نسبت به مدل‌های دیگر بهترین عملکرد را در یادگیری و پیش‌بینی رفتار سد دارد. هدف از این تحقیق، ارزیابی ایمنی و سلامت سد با پیش‌بینی رفتار آینده سد با استفاده از مدل برتر BRT همراه با مدل LSTM به عنوان مدل مکمل برای دوره‌ای که سد هنوز آن را تجربه نکرده است، می‌باشد. نتایج نشان می‌دهد که مدل برتر توانایی خوبی در پیش‌بینی رفتار احتمالی آینده سد داشته و قابلیت‌های قوی در ارزیابی سلامت سد و جلوگیری از خسارات احتمالی آینده ارائه می‌نماید [۶۰].

مدل‌های یادگیری عمیق نیز در چند سال اخیر در ارزیابی سلامت سد مورد توجه قرار گرفته‌اند. مزیت اصلی استفاده از یک مدل یادگیری عمیق این است که می‌تواند وابستگی‌های طولانی‌مدت بین متغیرهای ورودی و پاسخ سد را یاد بگیرد. یانگ و همکاران [۶۱] یک مدل یادگیری عمیق مبتنی بر LSTM را برای ارزیابی رفتار سد تحت عوامل مختلف محیطی معرفی کردند. بطور مشابه، فنگ و همکاران [۶۲] از شبکه عصبی کانولوشنی (CNN) برای تشخیص ترک‌های سد با استفاده از تصاویر جمع‌آوری شده توسط پهباد و تکنیک پردازش تصویر استفاده کردند. نتایج نشان داد که این شبکه در ارزیابی دقیق ترک‌ها موثر است و ابزاری کارآمد برای نظارت بر ایمنی و سلامت سد فراهم می‌کند. مائو و همکاران [۶۳] یک رویکرد نوآورانه با استفاده از شبکه عصبی عمیق برای ارزیابی ایمنی سد ارائه کردند. کانگ و همکاران [۶۴] شبکه تابع پایه شعاعی (RBFN) را به عنوان یک مدل بهبود یافته معرفی کردند. این مدل با شبیه‌سازی اثرات حرارتی بر سازه سد و استفاده از مجموعه داده‌های متغیرهای دمایی، توانست ایمنی و سلامت سد را ارزیابی کند. رن و همکاران [۶۵] یک مدل حافظه کوتاه‌مدت بلند مدت (LSTM) بهبود یافته را برای پیش‌بینی جابه‌جایی یک سد معرفی کردند. نتایج نشان داد که این مدل بهبود یافته در مقایسه با مدل‌های کلاسیک، عملکرد بهتری دارد و دقت پیش‌بینی بالاتری ارائه می‌کند. همچنین، تفسیرپذیری فیزیکی واضح‌تری دارد که می‌تواند در تحلیل و ارزیابی دقیق‌تر سلامت سدها مفید باشد. به طور خلاصه، مدل‌های هوش مصنوعی در چند سال اخیر به مهندسان سد کمک کرده‌اند تا دید مناسبی نسبت به پاسخ‌های ساختاری سدها تحت سناریوهای مختلف بارگذاری داشته باشند. این مدل‌ها امکان مدل‌سازی دقیق و پیش‌بینی رفتار سد را فراهم می‌کنند، که به شناسایی نقاط بحرانی و ارزیابی ایمنی و سلامت سد کمک می‌کند. از طرفی، این مدل‌ها مزایا و محدودیت‌های خاص خود را دارند و انتخاب یک الگوریتم خاص به عوامل مختلفی بستگی دارد. از جمله این عوامل می‌توان به اندازه و نوع مجموعه داده‌های جمع‌آوری شده، نوع سد، تعداد و دقت ابزارهای دقیق و حسگرهای نصب شده در مجموعه مورد مطالعه اشاره کرد. برای دستیابی به بهترین نتایج، مهندسان باید با توجه به ویژگی‌های خاص هر سد و داده‌های موجود، مدل مناسب را انتخاب کنند.

۳.۴. مدل‌های ترکیبی

مدل‌های ترکیبی از داده‌های ابزارهای دقیق و حسگرها همراه با دانش و قوانین فیزیکی حاکم بر سد برای ارزیابی ایمنی و سلامت سد استفاده می‌کنند. این مدل‌ها برای مواقعی مفید هستند که یک مدل عددی یا داده‌محور به تنهایی نمی‌تواند وضعیت واقعی را تفسیر کند. برای مثال، پدیده‌هایی مانند ایجاد ترک در بتن تحت خستگی، کاهش سختی ناشی از تغییرات عملیاتی، اثرات بارهای دینامیکی خارجی مانند زلزله و طوفان و غیره، به طور کامل توسط مدل‌های مبتنی بر فیزیک یا داده قابل توصیف نیستند. در چنین مواردی، استفاده از مدل‌های ترکیبی ضروری است تا با ترکیب مکانیزم‌های مدل فیزیکی و مدل داده‌محور، ارزیابی قوی‌تری از ایمنی و سلامت سازه انجام گیرد.

وانگ و همکاران [۴۰] به بررسی تشخیص ترک‌ها در سدهای قوسی بتنی از طریق شبیه‌سازی عددی و آزمایش‌های مدل، با تمرکز بر کاهش فرکانس‌های طبیعی پرداخته‌اند. آنها یک شبکه عصبی آماری را برای تشخیص ترک‌ها با کاهش فرکانس‌های طبیعی پیشنهاد کرده‌اند. یافته‌ها نشان می‌دهد که وجود ترک‌ها فرکانس‌های طبیعی را کاهش می‌دهد و این کاهش می‌تواند به طور موثر توسط شبکه عصبی برای تشخیص ترک استفاده شود. به همین ترتیب، کریمی و همکاران [۶۶] یک روش مبتنی بر شبکه عصبی مصنوعی را برای شناسایی ترک‌ها در سدهای گرانشی بتنی، با استفاده از تجزیه و تحلیل ترکیبی المان محدود-المان مرزی (FE-BE) برای پیش‌بینی ویژگی‌های دینامیکی پیشنهاد می‌کنند. نتایج نشان می‌دهد که روش پیشنهادی دقت و کارایی بیشتری نسبت به راه‌حل‌های صرفاً مبتنی بر اجزای محدود دارد. لین و همکاران [۶۷] یک روش شبیه‌سازی ساده‌شده را برای فونداسیون‌های سد وزنی پیشنهاد می‌کنند که تغییر شکل محدود

فونداسیون را در حالی که خواص مکانیکی آن را در نظر می‌گیرد، توضیح می‌دهد. این روش تغییر شکل الاستیک بدنه سد را از تغییر شکل محدود فونداسیون، با استفاده از پارتیشن‌بندی ترکیبی المان محدود-المان مرزی جدا می‌کند. در این روش، از داده‌های استاتیکی جمع‌آوری شده از یک سد بتنی برای کالیبره کردن مدل پارتیشن‌بندی شده استفاده شد. سویری و همکاران [۶۸] یک مدل ترکیبی احتمالاتی جدید در چارچوب بیزی برای پیش‌بینی جابه‌جایی‌های یک سد بتنی وزنی پیشنهاد کردند. در این مدل، جابه‌جایی‌های ناشی از تغییرات فصلی تراز مخزن با استفاده از روش اجزای محدود و جابه‌جایی‌های ناشی از تغییرات حرارتی سد از طریق سری فوریه شبیه‌سازی می‌شود. نتایج نشان می‌دهد که مدل ترکیبی پیش‌بینی‌کننده جدید، بار محاسباتی را به مقدار قابل توجهی کاهش می‌دهد. در مطالعه‌ای دیگر، وی و همکاران [۶۹] یک مدل ترکیبی مکانی - زمانی با نظارت تغییر شکل چند نقطه‌ای برای یک سد بتنی قوسی پیشنهاد کردند. این مدل مختصات فضایی و محاسبات هیدرولیکی سد را با استفاده از روش اجزای محدود ادغام کرده و از مدل ماشین بردار پشتیبان برای تجزیه و تحلیل و پیش‌بینی استفاده می‌نماید. نتایج نشان می‌دهد که این مدل دقت برازش و پیش‌بینی بهتری را در مقایسه با روش‌های مرسوم داشته و می‌تواند به طور همزمان تغییر شکل‌ها را در چندین نقطه تجزیه و تحلیل و پیش‌بینی کند. مدل‌های ترکیبی متشکل از مدل‌های مختلف همراه با تکنیک‌های مورد استفاده و کاربرد آن‌ها برای ارزیابی دقیق‌تر و کامل‌تر سلامت یک سد بتنی می‌باشند.

۵. نتیجه‌گیری

توسعه مدل‌های ارزیابی سلامت سد برای تفسیر دقیق رفتار سدها بسیار مهم است و باید برای هر سد به‌طور مستقل انجام شود. دلیل این نیاز، منحصر به فرد بودن فونداسیون سد، شرایط محیطی، بارگذاری، و مواد و مصالح مصرفی در ساخت سد است. یک مدل ارزیابی سلامت سد باید داده‌های جامع و متنوعی را شامل شود و پارامترهای آن بر اساس پاسخ‌های سد مشاهده شده در طول زمان به‌روزرسانی شوند تا ارزیابی دقیقی از رفتار سد صورت گیرد. هدف اصلی از این مدل‌ها، شناسایی تغییرات بین رفتارهای پیش‌بینی شده و مشاهده شده برای تسهیل تعمیر و نگهداری فعال و تضمین ایمنی سد است. مدل‌های مبتنی بر رگرسیون خطی چندگانه به عنوان مطلوب‌ترین رویکرد مبتنی بر داده در میان متخصصان سد برای ارزیابی سلامت سد شناخته می‌شوند. این مدل‌ها بر اساس اصل عمل می‌کنند که پاسخ‌های سد تحت تأثیر عواملی مانند فشار هیدرواستاتیک، تغییرات دما و پدیده‌های برگشت‌ناپذیر قرار دارند. محققان با انتخاب فاکتورهای تأثیرگذار مختلف، مدل‌های رگرسیون متعددی از جمله HST, HTT, HSTT و HHST را ایجاد کرده‌اند. پیشرفت‌های اخیر در هوش مصنوعی و یادگیری عمیق، انقلابی در زمینه مهندسی سد ایجاد کرده است. داده‌های ابزارهای دقیق و حسگرهای مدرن همراه با تکنیک‌های جدید امکان ارزیابی ایمنی و سلامت سد را برای مهندسان فراهم کرده‌اند. با این حال، چالش‌هایی مانند کیفیت و در دسترس بودن داده‌ها، شفافیت، و انتخاب الگوریتم مناسب باید مورد توجه قرار گیرند تا هوش مصنوعی به‌طور کامل در این زمینه یکپارچه شود. هوش مصنوعی و یادگیری ماشین، به ویژه یادگیری عمیق، پتانسیل بهبود قابل توجه عملیات سد را با امکان پیش‌بینی بهتر رفتار سد، بهینه‌سازی عملیات، و تصمیم‌گیری آگاهانه دارند. این موضوع در تحقیقات رو به رشد کاربرد این فناوری‌ها در مهندسی سد در سال‌های اخیر برای ارزیابی ایمنی و سلامت سد مشهود است.

از سوی دیگر، مدل‌های عددی به دلیل دقت بالای خود در شبیه‌سازی فرآیندهای فیزیکی، ابزارهای قدرتمندی برای ارزیابی سلامت سدها هستند، اما ساخت و استفاده از آنها نیازمند درک دقیق و جامع از فرآیندهای فیزیکی و همچنین داده‌های ورودی مناسب است. با این حال، استفاده از مدل‌های عددی و مدل‌های مبتنی بر داده به تنهایی ممکن است برای ارزیابی ایمنی و سلامت سازه کافی نباشد. در این شرایط، استفاده از مدل‌های ترکیبی که از هر دو نوع مدل بهره

می‌برند، ضروری است. به طور کلی، تمرکز جامعه مهندسی سد به سمت بهینه‌سازی سازه‌های موجود و توسعه تکنیک‌های نوآورانه برای نگهداری و نظارت است. این مقاله مروری بر شناخت چالش‌ها و تأکید بر فرصت‌های هر یک از روش‌ها، تحقیق و نوآوری‌های بیشتر در زمینه مهندسی سد را تشویق می‌کند. تحقیقات آینده باید بر توسعه مدل‌های ترکیبی، بهبود دقت و کیفیت داده‌های جمع‌آوری شده، و استفاده از تکنیک‌های نوآورانه برای ارزیابی و نظارت بر سدها متمرکز شوند.

۶. مراجع

- [1] Lane, N., 2007. Aging infrastructure: Dam safety. *Congressional Research Service*.
- [2] Sivasuriyan, A., Vijayan, D.S., Górski, W., Wodzyński, Ł., Vaverková, M.D. and Koda, E., 2021. Practical implementation of structural health monitoring in multi-story buildings. *Buildings*, 11(6), p.263. <https://doi.org/10.3390/buildings11060263>.
- [3] Salazar, F., Morán, R., Toledo, M.Á. and Oñate, E., 2017. Data-based models for the prediction of dam behaviour: a review and some methodological considerations. *Archives of computational methods in engineering*, 24, pp.1-21. <https://doi.org/10.1007/s11831-015-9157-9>.
- [4] Huebner, K.H., Dewhurst, D.L., Smith, D.E. and Byrom, T.G., 2001. The finite element method for engineers. *John Wiley & Sons*.
- [5] Reddy, J.N., 1993. An introduction to the finite element method. *New York*, 27, p.14.
- [6] Hariri-Ardebili, M.A., 2018. Risk, Reliability, Resilience (R3) and beyond in dam engineering: A state-of-the-art review. *International journal of disaster risk reduction*, 31, pp.806-831. <https://doi.org/10.1016/j.ijdrr.2018.07.024>.
- [7] Kalinina, A., Spada, M., Marelli, S., Burgherr, P. and Sudret, B., 2016. *Uncertainties in the risk assessment of hydropower dams: state-of-the-art and outlook* (Doctoral dissertation, Paul Scherrer Institute, 5232 Villigen, Switzerland; ETH Zurich, Chair of Risk, Safety and Uncertainty Quantification, Stefano-Franscini-Platz 5, 8093 Zurich, Switzerland).
- [8] Chen, Y.W., Stanley, K. and Att, W., 2020. Artificial intelligence in dentistry: current applications and future perspectives. *Quintessence Int*, 51(3), pp.248-57.
- [9] Himeur, Y., Ghanem, K., Alsalemi, A., Bensaali, F. and Amira, A., 2021. Artificial intelligence based anomaly detection of energy consumption in buildings: A review, current trends and new perspectives. *Applied Energy*, 287, p.116601. <https://doi.org/10.1016/j.apenergy.2021.116601>.
- [10] O'Keefe, R.M. and O'Leary, D.E., 1993. Expert system verification and validation: a survey and tutorial. *Artificial Intelligence Review*, 7, pp.3-42. <https://doi.org/10.1007/BF00849196>.
- [11] Jeong, S., Zhang, Y., O'Connor, S., Lynch, J.P., Sohn, H. and Law, K.H., 2016. A NoSQL data management infrastructure for bridge monitoring. *Smart structures and systems*, 17(4), pp.669-690.
- [12] Bukenya, P., Moyo, P., Beushausen, H. and Oosthuizen, C., 2014. Health monitoring of concrete dams: a literature review. *Journal of Civil Structural Health Monitoring*, 4, pp.235-244. <https://doi.org/10.1007/s13349-014-0079-2>.
- [13] Li, B., Yang, J. and Hu, D., 2020. Dam monitoring data analysis methods: A literature review. *Structural Control and Health Monitoring*, 27(3), p.e2501. <https://doi.org/10.1002/stc.2501>.
- [14] Hariri-Ardebili, M.A., Mahdavi, G., Nuss, L.K. and Lall, U., 2023. The role of artificial intelligence and digital technologies in dam engineering: Narrative review and outlook.

Engineering Applications of Artificial Intelligence, 126, p.106813. <https://doi.org/10.1016/j.engappai.2023.106813>.

[15] Sivasuriyan, A., Vijayan, D.S., Munusami, R. and Devarajan, P., 2021. Health assessment of dams under various environmental conditions using structural health monitoring techniques: a state-of-art review. *Environmental Science and Pollution Research*, pp.1-12. <https://doi.org/10.1007/s11356-021-16749-3>.

[16] Zamarrón-Mieza, I., Yepes, V. and Moreno-Jiménez, J.M., 2017. A systematic review of application of multi-criteria decision analysis for aging-dam management. *Journal of Cleaner Production*, 147, pp.217-230. <https://doi.org/10.1016/j.jclepro.2017.01.092>.

[17] Moradi Sarkhanlou, M., Toufigh, V. and Ghaemian, M., 2024. Integrated analysis of instrumentation data for structural health assessment and behavior prediction of arch dams. *Journal of Civil Structural Health Monitoring*, pp.1-25. <https://doi.org/10.1007/s13349-024-00819-4>.

[18] Loh, C.H., Chen, C.H. and Hsu, T.Y., 2011. Application of advanced statistical methods for extracting long-term trends in static monitoring data from an arch dam. *Structural Health Monitoring*, 10(6), pp.587-601. <https://doi.org/10.1177/1475921710395807>.

[19] Léger, P. and Leclerc, M., 2007. Hydrostatic, temperature, time-displacement model for concrete dams. *Journal of engineering mechanics*, 133(3), pp.267-277. [https://doi.org/10.1061/\(ASCE\)07339399\(2007\)133:3\(267\)](https://doi.org/10.1061/(ASCE)07339399(2007)133:3(267)).

[20] Mata, J., Tavares de Castro, A. and Sá da Costa, J., 2014. Constructing statistical models for arch dam deformation. *Structural Control and Health Monitoring*, 21(3), pp.423-437. <https://doi.org/10.1002/stc.1575>.

[21] Prakash, G., Sadhu, A., Narasimhan, S. and Brehe, J.M., 2018. Initial service life data towards structural health monitoring of a concrete arch dam. *Structural Control and Health Monitoring*, 25(1), p.e2036. <https://doi.org/10.1002/stc.2036>.

[22] Mata, J., 2011. Interpretation of concrete dam behaviour with artificial neural network and multiple linear regression models. *Engineering structures*, 33(3), pp.903-910. <https://doi.org/10.1016/j.engstruct.2010.12.011>.

[23] Elith, J., Leathwick, J.R. and Hastie, T., 2008. A working guide to boosted regression trees. *Journal of animal ecology*, 77(4), pp.802-813. <https://doi.org/10.1111/j.13652656.2008.01390.x>.

[24] Hochreiter, S. and Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), pp.1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.

[25] Pereira, S., Magalhães, F., Gomes, J.P., Cunha, Á. and Lemos, J.V., 2018. Dynamic monitoring of a concrete arch dam during the first filling of the reservoir. *Engineering Structures*, 174, pp.548-560. <https://doi.org/10.1016/j.engstruct.2018.07.076>.

[26] Ljunggren, M., Logan, T. and Campbell, P., 2013. Is your dam as safe as your data suggest. In *Proceedings of the NZSOLD/ANCOLD conference* (Vol. 1).

[27] Xu, Y., Huang, H., Li, Y., Zhou, J., Lu, X. and Wang, Y., 2022. A three-stage online anomaly identification model for monitoring data in dams. *Structural Health Monitoring*, 21(3), pp.1183-1206. <https://doi.org/10.1177/14759217211025766>.

[28] Li, X., Li, Y., Lu, X., Wang, Y., Zhang, H. and Zhang, P., 2020. An online anomaly recognition and early warning model for dam safety monitoring data. *Structural Health Monitoring*, 19(3), pp.796-809. <https://doi.org/10.1177/1475921719864265>.

- [29] Hu, J. and Ma, F., 2021. Comparison of hierarchical clustering based deformation prediction models for high arch dams during the initial operation period. *Journal of Civil Structural Health Monitoring*, 11(4), pp.897-914. <https://doi.org/10.1007/s13349-021-00487-8>.
- [30] Quecedo, M., Pastor, M., Herreros, M.I., Merodo, J.F. and Zhang, Q., 2005. Comparison of two mathematical models for solving the dam break problem using the FEM method. *Computer Methods in Applied Mechanics and Engineering*, 194(36-38), pp.3984-4005. <https://doi.org/10.1016/j.cma.2004.09.011>.
- [31] Andonov, A.G., Iliev, A. and Apostolov, K.S., 2013. Towards Displacement-based seismic assessment of concrete dams using non-linear static and dynamic procedures. *Structural Engineering International*, 23(2), pp.132-140. <https://doi.org/10.2749/101686613X13439149157074>.
- [32] De Sortis, A. and Paoliani, P., 2007. Statistical analysis and structural identification in concrete dam monitoring. *Engineering structures*, 29(1), pp.110-120. <https://doi.org/10.1016/j.engstruct.2006.04.022>.
- [33] Sevim, B., Bayraktar, A., Altunışık, A.C., Adanur, S. and Akköse, M., 2012. Determination of water level effects on the dynamic characteristics of a prototype arch dam model using ambient vibration testing. *Experimental Techniques*, 36, pp.72-82. <https://doi.org/10.1111/j.1747-1567.2010.00671.x>.
- [34] Barpi, F. and Valente, S., 2000. Numerical simulation of prenotched gravity dam models. *Journal of Engineering Mechanics*, 126(6), pp.611-619. [https://doi.org/10.1061/\(ASCE\)0733-9399\(2000\)126:6\(611\)](https://doi.org/10.1061/(ASCE)0733-9399(2000)126:6(611)).
- [35] Chen, J., Wang, M. and Fan, S., 2013. Experimental investigation of small-scaled model for powerhouse dam section on shaking table. *Structural Control and Health Monitoring*, 20(5), pp.740-752. <https://doi.org/10.1002/stc.1489>.
- [36] Wang, M., Chen, J., Wei, H. and Song, B., 2019. Experimental investigation of a small-scaled model for overflow section of a high gravity dam on shaking table. *Advances in Mechanical Engineering*, 11(2), p.1687814019829959. <https://doi.org/10.1177/1687814019829959>.
- [37] Sevieri, G. and De Falco, A., 2020. Dynamic structural health monitoring for concrete gravity dams based on the Bayesian inference. *Journal of Civil Structural Health Monitoring*, 10(2), pp.235-250. <https://doi.org/10.1007/s13349-020-00380-w>.
- [38] Wu, S.Y., Cao, W. and Zheng, J., 2016. Analysis of working behavior of Jinping-I Arch Dam during initial impoundment. *Water Science and Engineering*, 9(3), pp.240-248. <https://doi.org/10.1016/j.wse.2016.11.001>.
- [39] Chouinard, L. and Roy, V., 2006, June. Performance of statistical models for dam monitoring data. In *Joint international conference on computing and decision making in civil and building engineering, Montreal* (pp. 14-16).
- [40] Wang, B.S. and He, Z.C., 2007. Crack detection of arch dam using statistical neural network based on the reductions of natural frequencies. *Journal of Sound and Vibration*, 302(4-5), pp.1037-1047. <https://doi.org/10.1016/j.jsv.2007.01.008>.
- [41] Mata, J., de Castro, A.T. and da Costa, J.S., 2013. Time–frequency analysis for concrete dam safety control: Correlation between the daily variation of structural response and air temperature. *Engineering structures*, 48, pp.658-665. <https://doi.org/10.1016/j.engstruct.2012.12.013>.

- [42] Tatin, M., Briffaut, M., Dufour, F., Simon, A. and Fabre, J.P., 2015. Thermal displacements of concrete dams: Accounting for water temperature in statistical models. *Engineering Structures*, 91, pp.26-39. <https://doi.org/10.1016/j.engstruct.2015.01.047>.
- [43] Amberg, F., 2009, May. Interpretative models for concrete dam displacements. In *23th ICOLD congress*, q91-R43.
- [44] Tatin, M., Briffaut, M., Dufour, F., Simon, A. and Fabre, J.P., 2018. Statistical modelling of thermal displacements for concrete dams: Influence of water temperature profile and dam thickness profile. *Engineering Structures*, 165, pp.63-75. <https://doi.org/10.1016/j.engstruct.2018.03.010>.
- [45] Perner, F. and Obernhuber, P., 2010. Analysis of arch dam deformations. *Frontiers of Architecture and Civil Engineering in China*, 4, pp.102-108. <https://doi.org/10.1007/s11709-010-0012-7>.
- [46] Lew, J.S. and Loh, C.H., 2014. Structural health monitoring of an arch dam from static deformation. *Journal of Civil Structural Health Monitoring*, 4, pp.245-253. <https://doi.org/10.1007/s13349-014-0084-5>.
- [47] Wang, S., Xu, Y., Gu, C., Bao, T., Xia, Q. and Hu, K., 2019. Hysteretic effect considered monitoring model for interpreting abnormal deformation behavior of arch dams: a case study. *Structural Control and Health Monitoring*, 26(10), p.e2417. <https://doi.org/10.1002/stc.2417>.
- [48] Prakash, G. and Balomenos, G.P., 2021, October. A Bayesian approach to model selection and averaging of hydrostatic-season-temperature-time model. In *Structures* (Vol. 33, pp. 4359-4370). Elsevier. <https://doi.org/10.1016/j.istruc.2021.06.109>.
- [49] Gamse, S., Zhou, W.H., Tan, F., Yuen, K.V. and Oberguggenberger, M., 2018. Hydrostatic-season-time model updating using Bayesian model class selection. *Reliability Engineering & System Safety*, 169, pp.40-50. <https://doi.org/10.1016/j.ress.2017.07.018>.
- [50] Wei, B., Yuan, D., Li, H. and Xu, Z., 2019. Combination forecast model for concrete dam displacement considering residual correction. *Structural Health Monitoring*, 18(1), pp.232-244. <https://doi.org/10.1177/1475921717748608>.
- [51] Kao, C.Y. and Loh, C.H., 2013. Monitoring of long-term static deformation data of Fei-Tsui arch dam using artificial neural network-based approaches. *Structural Control and Health Monitoring*, 20(3), pp.282-303. <https://doi.org/10.1002/stc.492>.
- [52] Liu, X., Kang, F., Ma, C. and Li, H., 2021. Concrete arch dam behavior prediction using kernel-extreme learning machines considering thermal effect. *Journal of Civil Structural Health Monitoring*, 11(2), pp.283-299. <https://doi.org/10.1007/s13349-020-00452-x>.
- [53] Han, B., Geng, F., Dai, S., Gan, G., Liu, S. and Yao, L., 2020. Statistically optimized back-propagation neural-network model and its application for deformation monitoring and prediction of concrete-face rockfill dams. *Journal of Performance of Constructed Facilities*, 34(4), p.04020071. [https://doi.org/10.1061/\(ASCE\)CF.19435509.0001485](https://doi.org/10.1061/(ASCE)CF.19435509.0001485).
- [54] Assaad, R. and El-Adaway, I.H., 2020. Evaluation and prediction of the hazard potential level of dam infrastructures using computational artificial intelligence algorithms. *Journal of Management in Engineering*, 36(5), p.04020051. [https://doi.org/10.1061/\(ASCE\)ME.1943-5479.0000810](https://doi.org/10.1061/(ASCE)ME.1943-5479.0000810).
- [55] Li, Y., Bao, T., Xu, B., Shu, X., Zhou, Y., Du, Y., Wang, R. and Zhang, K., 2022. A deep residual neural network framework with transfer learning for concrete dams patch-level crack classification and weakly-supervised localization. *Measurement*, 188, p.110641. <https://doi.org/10.1016/j.measurement.2021.110641>.

[56] Cheng, L. and Zheng, D., 2013. Two online dam safety monitoring models based on the process of extracting environmental effect. *Advances in Engineering Software*, 57, pp.48-56. <https://doi.org/10.1016/j.advengsoft.2012.11.015>.

[57] Ranković, V., Grujović, N., Divac, D. and Milivojević, N., 2014. Development of support vector regression identification model for prediction of dam structural behaviour. *Structural Safety*, 48, pp.33-39. <https://doi.org/10.1016/j.strusafe.2014.02.004>.

[58] Tabari, M.M.R. and Sanayei, H.R.Z., 2019. Prediction of the intermediate block displacement of the dam crest using artificial neural network and support vector regression models. *Soft Computing*, 23, pp.9629-9645. <https://doi.org/10.1007/s00500-018-3528-8>.

[59] Cheng, M.Y., Cao, M.T. and Huang, I.F., 2022. Hybrid artificial intelligence-based inference models for accurately predicting dam body displacements: A case study of the Fei Tsui dam. *Structural Health Monitoring*, 21(4), pp.1738-1756. <https://doi.org/10.1177/14759217211044116>.

[۶۰] میلاد مرادی سارخانلو، وهب توفیق، محسن قائمیان. صحت‌سنجی مدل‌های یادگیری ماشین برای تفسیر و پیش‌بینی رفتار سازه‌های سدها با استفاده از داده‌های ابزار دقیق. InDevelopment Engineering Conferences Center Articles Database 2024 Jun 20 (Vol. 1, No. 2).

[61] Yang, D., Gu, C., Zhu, Y., Dai, B., Zhang, K., Zhang, Z. and Li, B., 2020. A concrete dam deformation prediction method based on LSTM with attention mechanism. *Ieee Access*, 8, pp.185177-185186. <https://doi.org/10.1109/ACCESS.2020.3029562>.

[62] Feng, C., Zhang, H., Wang, H., Wang, S. and Li, Y., 2020. Automatic pixel-level crack detection on dam surface using deep convolutional network. *Sensors*, 20(7), p.2069. <https://doi.org/10.3390/s20072069>.

[63] Mao, Y., Zhang, J., Qi, H. and Wang, L., 2019. DNN-MVL: DNN-multi-view-learning-based recover block missing data in a dam safety monitoring system. *Sensors*, 19(13), p.2895. <https://doi.org/10.3390/s19132895>.

[64] Kang, F., Li, J., Zhao, S. and Wang, Y., 2019. Structural health monitoring of concrete dams using long-term air temperature for thermal effect simulation. *Engineering Structures*, 180, pp.642-653. <https://doi.org/10.1016/j.engstruct.2018.11.065>.

[65] Ren, Q., Li, M., Li, H. and Shen, Y., 2021. A novel deep learning prediction model for concrete dam displacements using interpretable mixed attention mechanism. *Advanced Engineering Informatics*, 50, p.101407. <https://doi.org/10.1016/j.aei.2021.101407>.

[66] Karimi, I., Khaji, N., Ahmadi, M.T. and Mirzayee, M., 2010. System identification of concrete gravity dams using artificial neural networks based on a hybrid finite element–boundary element approach. *Engineering structures*, 32(11), pp.3583-3591. <https://doi.org/10.1016/j.engstruct.2010.08.002>.

[67] Lin, C., Li, T., Liu, X., Zhao, L., Chen, S. and Qi, H., 2019. A deformation separation method for gravity dam body and foundation based on the observed displacements. *Structural Control and Health Monitoring*, 26(2), p.e2304. <https://doi.org/10.1002/stc.2304>.

[68] Sevieri, G., Andreini, M., De Falco, A. and Matthies, H.G., 2019. Concrete gravity dam model parameters updating using static measurements. *Engineering Structures*, 196, p.109231. <https://doi.org/10.1016/j.engstruct.2019.05.072>.

[69] Wei, B., Liu, B., Yuan, D., Mao, Y. and Yao, S., 2021. Spatiotemporal hybrid model for concrete arch dam deformation monitoring considering chaotic effect of residual series. *Engineering Structures*, 228, p.111488. <https://doi.org/10.1016/j.engstruct.2020.111488>.