

پیش‌بینی عمر باقی‌مانده سازه‌های بتن آرمه با Machine Learning

چکیده

سازه‌های بتن آرمه یکی از مهم‌ترین اجزای زیرساخت‌های عمرانی مانند پل‌ها، ساختمان‌ها، پارکینگ‌ها، تونل‌ها و سازه‌های صنعتی هستند. این سازه‌ها در طول زمان تحت تأثیر عوامل مختلف محیطی و مکانیکی قرار می‌گیرند و به تدریج بخشی از عملکرد اولیه خود را از دست می‌دهند. عواملی مانند نفوذ یون‌های کلرید، کربناسیون، خوردگی میلگردها، ترک خوردگی، خستگی، یخ‌زدگی و ذوب‌شدن و تغییرات شرایط بهره‌برداری می‌توانند باعث کاهش دوام و ظرفیت سازه شوند. به همین دلیل، تخمین عمر باقی‌مانده سازه یا Remaining Useful Life (RUL) اهمیت زیادی در مدیریت و نگهداری زیرساخت‌ها دارد.

در سال‌های اخیر، استفاده از Machine Learning برای پیش‌بینی وضعیت آینده سازه‌ها مورد توجه قرار گرفته است. این روش‌ها می‌توانند روابط پیچیده و غیرخطی میان عواملی مانند سن سازه، مقاومت بتن، ضخامت پوشش، شرایط محیطی، میزان کلرید، عمق کربناسیون و شاخص‌های خوردگی را شناسایی کنند. با این حال، پیش‌بینی عمر باقی‌مانده تنها با استفاده از یک مدل داده‌محور همیشه قابل اعتماد نیست؛ زیرا رفتار سازه تابع قوانین فیزیکی و مکانیکی مشخصی است و داده‌های واقعی نیز معمولاً محدود و همراه با عدم قطعیت هستند. بنابراین، استفاده از روش‌های ترکیبی که Machine Learning را با مدل‌های فیزیکی و تحلیل قابلیت اطمینان تلفیق می‌کنند، می‌تواند رویکرد مناسب‌تری باشد.

در این مقاله، مفهوم عمر باقی‌مانده سازه‌های بتن آرمه، عوامل مؤثر بر کاهش عمر، داده‌های مورد نیاز، الگوریتم‌های Machine Learning، روش‌های ترکیبی، نحوه ارزیابی مدل‌ها، محدودیت‌های موجود و مسیرهای آینده این حوزه بررسی می‌شود.

واژگان کلیدی: سازه بتن آرمه، عمر باقی‌مانده، Machine Learning, Remaining Useful Life، دوام بتن، خوردگی میلگرد، پایش سلامت سازه، پیش‌بینی خرابی.

۱. مقدمه

عمر یک سازه بتن آرمه را نمی‌توان فقط بر اساس تعداد سال‌هایی که از زمان ساخت آن گذشته است تعیین کرد. دو سازه با سن یکسان ممکن است شرایط کاملاً متفاوتی داشته باشند. کیفیت بتن، نحوه اجرا، ضخامت پوشش بتن، شرایط محیطی، میزان بارگذاری و کیفیت تعمیرات انجام‌شده در طول عمر سازه، همگی می‌توانند بر وضعیت نهایی آن تأثیر بگذارند.

برای مثال، یک پل بتن آرمه که در یک محیط دریایی قرار دارد، به دلیل تماس با یون‌های کلرید و رطوبت، ممکن است بسیار سریع‌تر از یک سازه مشابه در محیط خشک دچار خوردگی آرماتورها شود. بنابراین نمی‌توان تنها بر اساس سن سازه درباره میزان عمر باقی‌مانده آن قضاوت کرد.

در استاندارد ISO ۱۳۸۲۲، ارزیابی سازه‌های موجود بر اساس وضعیت واقعی سازه، قابلیت اطمینان و پیامدهای احتمالی خرابی مطرح می‌شود. همچنین در گزارش ACI ۳۰۸R موضوع پیش‌بینی عمر بهره‌برداری سازه‌های بتنی و روش‌های مختلف مدل‌سازی آن مورد بررسی قرار گرفته است.

در این شرایط، Machine Learning می‌تواند به عنوان یک ابزار تحلیلی در کنار روش‌های سنتی مهندسی استفاده شود. این فناوری قادر است حجم زیادی از داده‌های حاصل از بازرسی‌ها، آزمایش‌های غیرمخرب، حسگرها و اطلاعات محیطی را تحلیل کند و الگوهایی را پیدا کند که شاید با روش‌های معمول به سادگی قابل تشخیص نباشند.

هدف از این کار جایگزین کردن مهندس با یک الگوریتم نیست. هدف اصلی این است که بتوان با استفاده از اطلاعات موجود، وضعیت آینده سازه را بهتر پیش‌بینی کرد و تصمیم‌های مربوط به تعمیر، تقویت و نگهداری را با اطمینان بیشتری گرفت.

۲. مفهوم عمر باقی‌مانده سازه

عمر باقی‌مانده یا RUL را می‌توان به صورت مدت زمانی تعریف کرد که یک سازه از وضعیت فعلی خود تا رسیدن به یک معیار خرابی یا حالت حدی مشخص در اختیار دارد.

اگر زمان فعلی را با t_0 و زمان رسیدن به حالت حدی را با t_{lim} نشان دهیم، می‌توان نوشت:

$$RUL = t_{lim} - t_0$$

اما در عمل، مقدار t_{lim} مشخص و قطعی نیست. برای مثال، نمی‌توان با اطمینان گفت یک پل بتن آرمه دقیقاً در سال دوازدهم آینده دچار خرابی خواهد شد. شرایط محیطی، بارگذاری و عدم قطعیت موجود در خصوصیات مصالح باعث می‌شوند زمان خرابی دارای یک توزیع احتمالی باشد.

بنابراین، در کاربردهای حرفه‌ای بهتر است به جای بیان یک عدد قطعی، احتمال رسیدن سازه به حالت حدی در یک بازه زمانی مشخص ارائه شود.

برای مثال، به جای اینکه گفته شود:

«عمر باقی‌مانده سازه ۱۰ سال است».

می‌توان گفت:

«بر اساس داده‌های موجود، احتمال عبور سازه از معیار عملکرد موردنظر در ۱۰ سال آینده برابر با مقدار مشخصی است».

این نوع بیان از نظر مهندسی منطقی‌تر است، زیرا عدم قطعیت موجود در پیش‌بینی را نیز در نظر می‌گیرد.

۳. عوامل مؤثر بر کاهش عمر سازه‌های بتن آرمه

۳-۱. نفوذ یون‌های کلرید

نفوذ یون‌های کلرید یکی از مهم‌ترین عوامل تخریب سازه‌های بتن‌آرمه، به‌خصوص در محیط‌های دریایی و مناطقی است که از نمک‌های یخ‌زدا استفاده می‌شود.

یون‌های کلرید می‌توانند از طریق منافذ بتن به سمت میلگرد حرکت کنند. هنگامی که غلظت کلرید در نزدیکی میلگرد به یک مقدار بحرانی برسد، لایه محافظ سطح فولاد ممکن است از بین برود و فرایند خوردگی آغاز شود.

خوردگی آرماتور فقط باعث کاهش سطح مقطع فولاد نمی‌شود. محصولات خوردگی حجم بیشتری نسبت به فولاد اولیه دارند و در نتیجه فشار داخلی ایجاد می‌کنند. این فشار می‌تواند باعث ترک خوردن بتن پوشش، جداسازی و پوسته‌شدن بتن شود.

در مراحل پیشرفته‌تر، کاهش سطح مقطع میلگرد و آسیب بتن اطراف آن می‌تواند ظرفیت باربری عضو را کاهش دهد.

۳-۲. کربناسیون

کربناسیون نیز یکی دیگر از عوامل مهم تخریب بتن‌آرمه است.

در این فرایند، دی‌اکسیدکربن موجود در هوا وارد بتن شده و با ترکیبات موجود در خمیر سیمان واکنش می‌دهد. در نتیجه pH بتن کاهش پیدا می‌کند و شرایط برای از بین رفتن حالت غیرفعال سطح میلگرد فراهم می‌شود.

سرعت کربناسیون به عواملی مانند نسبت آب به سیمان، رطوبت، دما، شرایط عمل‌آوری، نوع سیمان و کیفیت بتن بستگی دارد.

بنابراین پیش‌بینی عمق کربناسیون نیز یک مسئله مناسب برای استفاده از Machine Learning محسوب می‌شود.

۳-۳. ترک خوردگی

ترک‌های بتن می‌توانند مسیر نفوذ آب، اکسیژن، کلرید و سایر مواد مهاجم را کوتاه‌تر کنند. در نتیجه وجود ترک ممکن است سرعت تخریب را افزایش دهد.

عرض ترک، عمق آن، جهت ترک و موقعیت آن در عضو همگی می‌توانند اطلاعات مهمی برای مدل پیش‌بینی باشند.

۳-۴. خستگی و بارگذاری

در سازه‌هایی مانند پل‌ها، بارگذاری مکرر وسایل نقلیه می‌تواند باعث ایجاد آسیب تجمعی و خستگی شود. در چنین شرایطی، پیش‌بینی عمر باقی‌مانده باید علاوه بر عوامل محیطی، تاریخچه بارگذاری و رفتار مکانیکی سازه را نیز در نظر بگیرد.

۴. چرا پیش‌بینی عمر باقی‌مانده دشوار است؟

یکی از دلایل اصلی دشواری این مسئله، چندعاملی بودن تخریب سازه است.

برای مثال، ممکن است نفوذ کلرید باعث شروع خوردگی شود، خوردگی باعث ترک خوردگی بتن شود و ترک‌ها نیز نفوذ بیشتر کلرید و رطوبت را امکان‌پذیر کنند. بنابراین، عوامل تخریب می‌توانند روی یکدیگر اثر متقابل داشته باشند.

مشکل دیگر، کمبود داده‌های واقعی است. برای آموزش یک مدل کامل RUL، ایده‌آل این است که اطلاعات یک سازه از ابتدای عمر تا زمان رسیدن به حالت حدی در اختیار باشد. چنین مجموعه داده‌ای در مهندسی عمران بسیار کم است.

بسیاری از مطالعات نیز از داده‌های آزمایشگاهی استفاده می‌کنند. اگرچه داده‌های آزمایشگاهی برای توسعه مدل مفید هستند، اما شرایط آزمایشگاه الزاماً با شرایط واقعی یک پل یا ساختمان قدیمی یکسان نیست.

همچنین داده‌های حاصل از بازرسی معمولاً دارای خطا هستند. مثلاً دو مهندس ممکن است عرض یک ترک را کمی متفاوت اندازه‌گیری کنند یا نتایج آزمایش‌های غیرمخرب در نقاط مختلف یک عضو تفاوت داشته باشد.

بنابراین، مدل Machine Learning باید بتواند با داده‌های ناقص، نویزی و نامطمئن نیز کار کند.

۵. داده‌های مورد نیاز برای Machine Learning

یکی از مهم‌ترین مراحل پروژه، تعیین داده‌های ورودی مناسب است.

اطلاعات هندسی و سازه‌ای

از جمله:

- ابعاد مقطع؛
- طول دهانه؛
- ضخامت پوشش بتن؛
- قطر میلگردها؛
- آرایش آرماتورها؛
- نوع عضو؛
- سن سازه؛
- شرایط تکیه‌گاهی.

اطلاعات مربوط به مصالح

مانند:

- مقاومت فشاری بتن؛
- نسبت آب به سیمان؛
- نوع سیمان؛
- مواد افزودنی؛

- نفوذپذیری؛
- تخلخل؛
- ضریب انتشار کلرید؛
- عمق کرناسیون.

اطلاعات محیطی

مانند:

- دما؛
- رطوبت نسبی؛
- میزان CO_2 ؛
- غلظت کلرید؛
- بارندگی؛
- چرخه‌های تر و خشک؛
- شرایط دریایی؛
- یخ‌زدگی و ذوب.

داده‌های حاصل از بازرسی

بازرسی‌های دوره‌ای می‌توانند اطلاعات بسیار ارزشمندی ایجاد کنند، از جمله:

- عرض ترک؛
- طول ترک؛
- میزان پوسته‌شدن؛
- عمق کرناسیون؛
- میزان کلرید؛
- مقاومت الکتریکی بتن؛
- پتانسیل نیم‌سلول؛
- نرخ خوردگی؛
- مقاومت بتن.

داده‌های حسگرها

در سازه‌هایی که سیستم پایش سلامت دارند، داده‌هایی مانند کرنش، شتاب، تغییر مکان، دما، رطوبت و ارتعاشات نیز قابل استفاده هستند.

ترکیب این داده‌ها می‌تواند تصویر دقیق‌تری از وضعیت واقعی سازه ایجاد کند.

۶. الگوریتم‌های Machine Learning

انتخاب الگوریتم مناسب به نوع داده و هدف پروژه بستگی دارد.

۶-۱. رگرسیون

مدل‌های رگرسیونی ساده‌ترین گزینه‌ها هستند و زمانی که رابطه میان متغیرها نسبتاً ساده باشد می‌توانند عملکرد خوبی داشته باشند.

مزیت اصلی این روش‌ها سادگی و تفسیرپذیری آنهاست.

۶-۲. Random Forest

Random Forest یکی از روش‌های مناسب برای داده‌های جدولی است.

فرض کنید داده‌های زیر را در اختیار داشته باشیم:

سن سازه، مقاومت بتن، پوشش بتن، میزان کلرید، رطوبت، دما و نرخ خوردگی.

Random Forest می‌تواند ارتباط غیرخطی میان این متغیرها و شاخص تخریب را یاد بگیرد.

۶-۳. Gradient Boosting

روش‌هایی مانند Gradient Boosting و XGBoost نیز برای داده‌های جدولی بسیار قدرتمند هستند و می‌توانند روابط پیچیده میان عوامل مختلف را مدل کنند.

۶-۴. Support Vector Regression

SVR برای مجموعه داده‌های نسبتاً کوچک می‌تواند گزینه مناسبی باشد و قابلیت مدل‌سازی روابط غیرخطی را دارد.

۶-۵. شبکه‌های عصبی

شبکه‌های عصبی مصنوعی می‌توانند روابط پیچیده‌ای را یاد بگیرند، اما معمولاً به داده بیشتری نیاز دارند.

مشکل اصلی آنها این است که در مدل‌های پیچیده، توضیح دلیل یک پیش‌بینی دشوارتر می‌شود.

۶-۶. LSTM و GRU

اگر داده‌ها به شکل سری زمانی باشند، مدل‌هایی مانند LSTM و GRU می‌توانند مفید باشند.

برای مثال، اگر وضعیت یک پل در طول ۱۰ سال به صورت دوره‌ای اندازه‌گیری شده باشد، این مدل‌ها می‌توانند روند تغییرات را در طول زمان یاد بگیرند.

۷-۶. CNN و بینایی ماشین

تصاویر سطح بتن نیز می‌توانند وارد فرایند تحلیل شوند.

مدل‌های بینایی ماشین قادرند ترک‌ها، پوسته‌شدن، لکه‌های خوردگی و برخی دیگر از آسیب‌های قابل مشاهده را شناسایی کنند.

۷. اهمیت ترکیب Machine Learning با مدل‌های فیزیکی

یکی از مشکلات مدل‌های کاملاً داده‌محور این است که ممکن است یک رابطه آماری را یاد بگیرند که از نظر فیزیکی منطقی نیست.

فرض کنیم یک مدل بر اساس داده‌های آموزشی یاد بگیرد که با افزایش سن سازه، عمق کرناسیون کاهش می‌یابد. ممکن است چنین رابطه‌ای در یک مجموعه داده خاص به دلیل همبستگی میان متغیرها مشاهده شده باشد، اما از نظر فرایند واقعی تخریب قابل قبول نیست.

در اینجا Physics-Informed Machine Learning اهمیت پیدا می‌کند.

در این روش، دانش فیزیکی مربوط به رفتار سازه در مدل وارد می‌شود. برای مثال، می‌توان از روابط مربوط به انتشار کلرید، کرناسیون یا مکانیک شکست به عنوان بخشی از ساختار مدل استفاده کرد.

یک فرم ساده از مدل ترکیبی را می‌توان به صورت زیر نوشت:

$$y_{\text{واقعی}} = y_{\text{فیزیکی}} + y_{\text{مربوط به خطای یادگرفته‌شده توسط Machine Learning}}$$

در این حالت، مدل فیزیکی رفتار اصلی سیستم را توضیح می‌دهد و Machine Learning تلاش می‌کند بخش‌هایی را که مدل فیزیکی قادر به توضیح کامل آن‌ها نیست، اصلاح کند.

این رویکرد می‌تواند نسبت به یک مدل کاملاً Black Box قابل اعتمادتر باشد، زیرا مدل مجبور نیست تمام قوانین فیزیکی را فقط از داده‌ها یاد بگیرد.

۸. چارچوب پیشنهادی برای پیش‌بینی RUL

یک سیستم عملی پیش‌بینی عمر باقی‌مانده می‌تواند شامل مراحل زیر باشد.

مرحله اول: جمع‌آوری داده

اطلاعات طراحی، مصالح، محیط، بازرسی و حسگرها جمع‌آوری می‌شوند.

مرحله دوم: پاک‌سازی داده

داده‌های پرت، مقادیر گم‌شده، خطاهای اندازه‌گیری و داده‌های غیرمنطقی شناسایی می‌شوند.

مرحله سوم: استخراج ویژگی

از داده‌های خام، ویژگی‌های مهم استخراج می‌شوند.

برای مثال، به جای استفاده مستقیم از تمام داده‌های خام محیطی، می‌توان میانگین دما، حداکثر دما، تعداد چرخه‌های تر و خشک یا میانگین رطوبت را استخراج کرد.

مرحله چهارم: تعریف Target

هدف مدل باید دقیقاً مشخص شود.

Target می‌تواند یکی از موارد زیر باشد:

- عمر باقی‌مانده بر حسب سال؛
- احتمال خرابی؛
- عمق کربناسیون آینده؛
- میزان خوردگی؛
- شاخص وضعیت سازه؛
- کاهش ظرفیت باربری.

مرحله پنجم: آموزش مدل

چند الگوریتم مختلف آموزش داده شده و عملکرد آن‌ها مقایسه می‌شود.

مرحله ششم: اعتبارسنجی

داده‌های آزمون باید تا حد امکان مستقل از داده‌های آموزش باشند.

در مسائل زمانی، تقسیم تصادفی داده‌ها می‌تواند باعث نشت اطلاعات شود. برای مثال، اگر داده‌های سال‌های ۱۳۹۸ و ۱۴۰۰ یک سازه هم در آموزش و هم در آزمون باشند، ممکن است مدل به صورت غیرواقعی عملکرد بسیار خوبی نشان دهد.

مرحله هفتم: برآورد عدم قطعیت

بهتر است مدل علاوه بر مقدار پیش‌بینی‌شده، میزان عدم قطعیت را نیز ارائه کند.

مرحله هشتم: تصمیم‌گیری مهندسی

در نهایت، خروجی مدل باید به تصمیم عملی تبدیل شود؛ مانند تعمیر، تقویت، افزایش دفعات بازرسی یا محدودیت بارگذاری.

۹. ارزیابی مدل

برای ارزیابی مدل‌های پیش‌بینی می‌توان از معیارهایی مانند MAE و RMSE استفاده کرد.

MAE نشان می‌دهد پیش‌بینی مدل به طور متوسط چقدر با مقدار واقعی اختلاف دارد.

RMSE نیز خطاهای بزرگ را بیشتر مورد توجه قرار می‌دهد.

با این حال، برای RUL تنها بررسی MAE یا RMSE کافی نیست.

فرض کنیم دو مدل داشته باشیم. مدل اول RUL را با خطای کمی پیش‌بینی می‌کند، اما هیچ اطلاعاتی درباره عدم قطعیت ارائه نمی‌دهد. مدل دوم کمی خطای بیشتری دارد ولی می‌تواند یک بازه پیش‌بینی قابل اعتماد ارائه کند.

برای تصمیم‌گیری مهندسی، مدل دوم ممکن است ارزش بیشتری داشته باشد.

به همین دلیل، **کالیبراسیون، قابلیت تعمیم و عدم قطعیت** باید در کنار دقت مدل بررسی شوند.

۱۰. نمونه فرضی از کاربرد روش

فرض کنیم یک پل بتن‌آرمه ۲۵ ساله در محیطی مرطوب قرار دارد.

اطلاعات موجود شامل موارد زیر است:

- سن سازه؛
- مقاومت بتن؛
- ضخامت پوشش؛
- میزان کلرید؛
- عمق کریناسیون؛
- مقاومت الکتریکی بتن؛
- نتایج پتانسیل نیم‌سلول؛
- عرض ترک‌ها؛

- دما؛
- رطوبت؛
- شدت ترافیک؛
- نتایج بازرسی‌های سال‌های گذشته.

در مرحله اول، Machine Learning می‌تواند روند تغییر شاخص‌های تخریب را پیش‌بینی کند.

سپس نتایج مدل با یک مدل فیزیکی خوردگی یا دوام ترکیب می‌شود.

در مرحله بعد، تحلیل قابلیت اطمینان انجام می‌شود تا مشخص شود احتمال رسیدن سازه به حالت حدی در پنج، ده یا پانزده سال آینده چقدر است.

در این شرایط، خروجی نهایی بهتر است شامل مواردی مانند RUL تخمینی، بازه عدم قطعیت و مهم‌ترین عوامل مؤثر بر تخریب باشد.

البته اعداد دقیق در این مثال وجود ندارند و این مثال صرفاً برای نشان دادن فرایند کلی استفاده شده است.

۱۱. تفسیرپذیری مدل

در پروژه‌های مهندسی، دانستن نتیجه مدل به تنهایی کافی نیست. مهندس باید بتواند تا حدی بفهمد چه عواملی باعث ایجاد آن نتیجه شده‌اند.

یکی از روش‌های رایج برای این کار SHAP است.

با استفاده از چنین روش‌هایی می‌توان مشخص کرد کدام متغیرها بیشترین تأثیر را بر پیش‌بینی دارند.

برای مثال، ممکن است مدل نشان دهد که در یک سازه خاص، مهم‌ترین عوامل عبارت‌اند از:

۱. میزان کلرید؛

۲. ضخامت پوشش بتن؛

۳. رطوبت؛

۴. سن سازه؛

۵. مقاومت بتن.

این اطلاعات می‌تواند در انتخاب روش تعمیر نیز مفید باشد.

برای مثال، اگر کلرید عامل اصلی تخریب باشد، کنترل خوردگی و جلوگیری از ورود بیشتر کلرید ممکن است اهمیت بیشتری از یک تعمیر سطحی ساده داشته باشد.

۱۲. محدودیت‌های استفاده از Machine Learning

با وجود مزایای زیاد، استفاده از Machine Learning در پیش‌بینی عمر سازه محدودیت‌هایی دارد.

کمبود داده‌های واقعی

داده‌های بلندمدت مربوط به سازه‌های واقعی بسیار محدود هستند.

تفاوت اقلیمی

مدلی که در یک منطقه آب‌وهوایی آموزش داده شده، ممکن است در منطقه‌ای با شرایط متفاوت عملکرد مشابهی نداشته باشد.

تفاوت بین سازه‌ها

حتی دو پل مشابه ممکن است به دلیل تفاوت در اجرا، مصالح یا نگهداری رفتار متفاوتی داشته باشند.

تغییر شرایط بهره‌برداری

ترافیک، بارگذاری، رطوبت و شرایط محیطی در طول زمان ثابت نیستند.

تعمیر و تقویت

پس از تعمیر یک عضو، روند تخریب ممکن است تغییر کند و مدل باید بتواند این تغییر را در نظر بگیرد.

مشکل Black Box

مدل‌های Deep Learning ممکن است بسیار پیچیده باشند و توضیح نتایج آن‌ها دشوار باشد.

عدم قطعیت

هیچ مدلی نمی‌تواند تمام عوامل مؤثر بر عمر سازه را با قطعیت کامل پیش‌بینی کند.

بنابراین، نتیجه Machine Learning نباید بدون بررسی مهندسی مستقیماً مبنای تصمیم‌های ایمنی قرار گیرد.

۱۳. آینده پیش‌بینی عمر باقی‌مانده

یکی از مسیرهای مهم آینده، ترکیب Machine Learning با Digital Twin است.

در یک Digital Twin، یک مدل دیجیتال از سازه ایجاد می‌شود و با دریافت اطلاعات جدید از حسگرها و بازرسی‌ها به‌روزرسانی می‌شود.

در نتیجه، وضعیت سازه به صورت پویا دنبال می‌شود.

برای مثال، ممکن است مدل در یک مقطع RUL را ۱۵ سال تخمین بزند، اما پس از دریافت اطلاعات جدید و مشاهده افزایش نرخ خوردگی، این مقدار اصلاح شود.

مسیر مهم دیگر، استفاده از داده‌های مختلف به صورت هم‌زمان است. به جای اینکه فقط تصاویر ترک یا فقط داده‌های حسگر استفاده شوند، می‌توان تصاویر، اطلاعات محیطی، داده‌های سازه‌ای و نتایج بازرسی را با یکدیگر ترکیب کرد.

همچنین استفاده از مدل‌های احتمالاتی و Bayesian می‌تواند امکان بیان بهتر عدم قطعیت را فراهم کند.

در آینده، احتمالاً مدل‌های موفق‌تر مدلهایی خواهند بود که سه ویژگی را هم‌زمان داشته باشند:

- استفاده از داده‌های واقعی؛
- رعایت قوانین فیزیکی؛
- ارائه عدم قطعیت قابل اندازه‌گیری.

۱۴. نتیجه‌گیری

پیش‌بینی عمر باقی‌مانده سازه‌های بتن‌آرمه یک مسئله پیچیده و چندعاملی است. سن سازه به تنهایی نمی‌تواند معیار مناسبی برای تعیین وضعیت آینده آن باشد، زیرا عوامل مختلفی مانند کیفیت بتن، ضخامت پوشش، شرایط محیطی، نفوذ کلرید، کربناسیون، خوردگی، ترک خوردگی و بارگذاری بر عملکرد سازه تأثیر می‌گذارند.

Machine Learning این امکان را فراهم می‌کند که حجم زیادی از داده‌های مربوط به سازه تحلیل شود و روابط پیچیده میان عوامل مختلف شناسایی گردد. روش‌هایی مانند Random Forest، Gradient Boosting، SVR، شبکه‌های عصبی و مدل‌های LSTM می‌توانند بسته به نوع داده برای پیش‌بینی روند تخریب مورد استفاده قرار گیرند.

با این حال، استفاده صرف از مدل‌های داده‌محور کافی نیست. مهم‌ترین مسئله این است که پیش‌بینی Machine Learning با اصول فیزیکی و مهندسی سازه سازگار باشد. به همین دلیل، روش‌های Hybrid و Physics-Informed Machine Learning اهمیت زیادی پیدا کرده‌اند.

همچنین بهتر است RUL به صورت یک عدد قطعی ارائه نشود، بلکه همراه با بازه پیش‌بینی و احتمال رسیدن به حالت حدی بیان شود. این کار باعث می‌شود تصمیم‌گیری درباره تعمیر و نگهداری واقع‌بینانه‌تر باشد.

در نهایت، ترکیب داده‌های حاصل از بازرسی و حسگرها، مدل‌های فیزیکی، Machine Learning و تحلیل قابلیت اطمینان می‌تواند زمینه را برای ایجاد سیستم‌های هوشمند مدیریت زیرساخت فراهم کند. چنین سیستم‌هایی می‌توانند مهندسان را قادر سازند تا قبل از وقوع خرابی جدی، روند تخریب را شناسایی کرده و اقدامات لازم برای تعمیر یا تقویت سازه را انجام دهند.

به عبارت دیگر، هدف اصلی استفاده از Machine Learning در این حوزه پیش‌بینی یک «عدد جادویی» برای عمر سازه نیست؛ بلکه ایجاد یک ابزار تصمیم‌گیری است که بتواند وضعیت فعلی سازه، روند تخریب، عوامل مؤثر و میزان ریسک آینده را با دقت و شفافیت بیشتری در اختیار مهندس قرار دهد.

منابع

ACI Committee ۳۶۵. (۲۰۱۷). *ACI 365.1R-17: Report on service life prediction*. American Concrete Institute.

International Organization for Standardization. (۲۰۱۰). *ISO 13822:2010: Bases for design of structures—Assessment of existing structures*. ISO.

Jia, H., Qiao, G., & Han, P. (۲۰۲۲). Machine learning algorithms in the environmental corrosion evaluation of reinforced concrete structures: A review. *Cement and Concrete Composites*, 133, ۱۰۴۷۲۵.

Jayawickrema, U. M. N., Herath, H. M. C. M., Hettiarachchi, N. K., Sooriyaarachchi, H. P., & Epaarachchi, J. A. (۲۰۲۲). Fibre-optic sensor and deep learning-based structural health monitoring systems for civil structures: A review. *Measurement*, 199, ۱۱۱۵۴۳.

Taffese, W. Z., Hilloulouin, B., Villagran Zaccardi, Y., Marani, A., Nehdi, M. L., Hanif, M. U., et al. (۲۰۲۵). Machine learning in concrete durability: Challenges and pathways identified by RILEM TC ۳۱۵-DCS towards enhanced predictive models. *Materials and Structures*, 58, ۱۴۵.

Taffese, W. Z., & Sistonen, E. (۲۰۱۷). Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions. *Automation in Construction*.

Shahrivar, F., Mahmoodian, M., Sidiq, A., Jayasinghe, S., Sun, Z., Alavi, A., et al. (۲۰۲۶). AI-based remaining useful life prediction for civil infrastructure: Methods, challenges, and future research directions. *Artificial Intelligence Review*.

Rai, A., Sharma, U. K., & Ball, R. J. (۲۰۲۶). Physics-informed hybrid machine learning model for carbonation depth prediction in concrete through residual correction and variogram analysis of response surfaces. *Journal of Materials in Civil Engineering*, 38(۱۱).