

مکان‌یابی خرابی بر پایه پاسخ‌های دینامیکی در قاب‌های خمشی با استفاده از شبکه

عصبی پیچشی

شاهین قزوینه^۱، غلامرضا نوری^{۱*}، سید حسین حسینی لواسانی^۱

۱- دانشکده فنی مهندسی، دانشگاه خوارزمی، تهران، ایران.

* نویسنده عهده‌دار مکاتبات: r.nouri@khu.ac.ir

چکیده

در الگوریتم‌های تشخیص خرابی سازه مبتنی بر روش‌های سنتی یادگیری ماشین، استخراج ویژگی‌های حساس به خرابی از داده‌های سری زمانی یک مسئله چالش برانگیز است. همچنین این روش‌ها نیازمند به پیش‌پردازش در داده‌های خام هستند که خود فرایند پردازش را کندتر می‌کند. تلاش‌های زیادی برای غلبه بر این محدودیت‌ها با گسترش یادگیری عمیق در زمینه پایش سلامت سازه صورت گرفته است. با این حال، از آنجایی که اکثر این سیستم‌ها دارای معماری‌های عمیق هستند، به رایانه‌هایی با توان محاسباتی بالا و همینطور میزان قابل توجهی داده در طول مرحله آموزش نیاز دارند که در نتیجه برای کاربردهای برخط مناسب نیستند. برای حل چالش‌های بالا، در این مقاله روشی مبتنی بر شبکه‌های عصبی پیچشی دوبعدی (CNN) به منظور ادغام دو مرحله استخراج ویژگی و طبقه‌بندی سریع به طور همزمان، ارائه می‌شود. این روش از یک CNN کم عمق استفاده می‌کند که سیگنال‌های شتاب خام را به عنوان ورودی شبکه دریافت می‌کند. برای بررسی توانایی الگوریتم پیشنهاد شده از داده‌ی به دست آمده از یک سازه آزمایشگاهی مقیاس بزرگ به عنوان ورودی شبکه استفاده شده است. به طور میانگین روش پیشنهادی دارای دقت ۹۹/۸ درصد بر روی داده‌های آموزشی و ۹۹/۶ درصد برای داده‌های اعتبارسنجی رسیده است که نشان از توانایی بالای الگویی آن دارد. همچنین این روش توانسته هر ثانیه از یک سیگنال ورودی را در مدت زمان ۲ میلی ثانیه بررسی کند که در استانداردهای پردازش برخط قرار دارد.

کلمات کلیدی

تشخیص خرابی سازه، یادگیری ماشین، یادگیری عمیق، پایش سلامت سازه، شبکه عصبی پیچشی.

خرابی سازه‌ای در سازه‌های عمرانی به دلیل تأثیرات محیطی، عملیاتی و سایر عوامل انسانی اجتناب ناپذیر است. با توجه به ماهیت پیشرونده آسیب، بازرسی منظم سازه‌های عمرانی برای بهبود قابلیت سرویس‌دهی، جلوگیری از کاهش عمر سازه و فروریزش آن و در نتیجه حفاظت از جان ساکنین ضروری است. بنابراین، تشخیص خرابی به یک موضوع جذاب در زمینه نظارت بر سلامت سازه برای بسیاری از محققان مهندسی عمران تبدیل شده است [۱-۳].

تشخیص خرابی سازه به روش‌های تشخیص محلی و کلی دسته‌بندی می‌شود [۴]. به عنوان یکی از زیر مجموعه‌های روش‌های کلی، تعداد فزاینده‌ای از مطالعات تحقیقاتی بر روی روش‌های تشخیص خرابی مبتنی بر ارتعاش به دلیل قابلیت شناسایی، تعیین کمیت و مکان‌یابی آسیب‌های سازه از طریق پردازش سیگنال‌های شتاب‌سنج انجام شده است [۵-۷]. روش‌های مبتنی بر ارتعاش را می‌توان به دو زیرمجموعه مبتنی بر مدل (پارامتری) و مبتنی بر سیگنال (ناپارامتری) طبقه‌بندی کرد [۸]. در روش‌های پارامتری، آسیب به صورت تغییر در پارامترهایی مانند پارامترهای مدال (مانند فرکانس طبیعی و شکل مد)، میرایی و شاخص‌های سختی ظاهر می‌شود. برعکس، روش‌های ناپارامتری می‌توانند آسیب ناشی از سیگنال‌های اندازه‌گیری شده را بدون دانستن هیچ اطلاعاتی در مورد مدل سازه شناسایی کنند [۹].

در سال‌های اخیر استفاده از رویکردهای بر پایه یادگیری ماشینی به دلیل قابلیت تحلیل خودکار داده‌ها و همین‌طور افزایش حجم داده‌های درد دسترس، در حوزه تشخیص خرابی سازه رایج شده است. یک روش تشخیص خرابی سازه مبتنی بر یادگیری ماشینی شامل سه مرحله است: پیش پردازش داده‌های اندازه‌گیری شده، استخراج ویژگی‌های حساس به خرابی و دسته‌بندی ویژگی‌ها با استفاده از یک طبقه‌بندی برای نشان دادن سالم یا آسیب دیده بودن سازه [۸]. بر این اساس، مشکل اصلی روش‌های سنتی مبتنی بر یادگیری ماشینی، نیاز آن‌ها به استخراج دستی ویژگی‌های حساس به خرابی است که در کارهای عملی چالش برانگیز است. عمدتاً عملکرد روش‌های یادگیری ماشینی به این ویژگی‌های دست‌چین شده بستگی دارد، که برای به دست آوردن آن‌ها نیاز به آزمون و خطا است. از آنجایی که استخراج این ویژگی‌ها ویژگی برای تشخیص آسیب در سازه‌های شهری کلیدی است، توسعه روش‌های استخراج خودکار ویژگی ضروری است [۱۰].

با رشد توان محاسباتی کامپیوترها، یادگیری عمیق، به عنوان یک زیر کلاس از یادگیری ماشینی، به یک راه حل امیدوار کننده در بسیاری از زمینه‌ها مانند بینایی کامپیوتر [۱۱، ۱۲]، تشخیص گفتار [۱۳] و پردازش سیگنال [۱۴-۱۸] تبدیل شده است. به لطف توانایی استخراج خودکار مدل‌های یادگیری عمیق، مشکل نیاز به ویژگی‌های دست‌چین شده حذف شده است [۱۹]. یکی از محبوب‌ترین مدل‌های یادگیری عمیق، شبکه عصبی پیچشی^۱ (CNN) است که می‌تواند ویژگی‌ها را از داده‌های خام استخراج کرده، آن‌ها را یاد گرفته و طبقه‌بندی کند. بر این اساس، روش‌های بسیاری مبتنی بر CNN در زمینه تشخیص خرابی توسط محققان ارائه شده است.

مدرس و همکاران^۲ [۲۰] یک رویکرد جدید برای تشخیص و شناسایی آسیب در تصاویر بر پایه CNN معرفی و عملکرد آن را با چهار الگوریتم دیگر با استفاده از تصاویر نویزدار و بدون نویز مقایسه کردند. نتایج نشان داد که CNN دو بعدی ذکر شده در هر دو سناریو دقیق‌تر از سایر روش‌ها عمل می‌کند. به همین ترتیب، شیهاوالدین و همکاران^۳ [۲۱] روش دیگری بر پایه شبکه‌های عصبی پیچشی دو بعدی ارائه کردند که از تصاویر برای تشخیص آسیب بر روی پره‌های توربین بادی استفاده می‌کند. اگرچه شبکه‌های عصبی پیچشی دو بعدی در ابتدا برای ورودی تصویر توسعه یافته‌اند، این الگوریتم برای پردازش ارتعاش نیز استفاده شده است. این روش‌ها برای استفاده از شبکه‌های عصبی پیچشی دو بعدی به تغییر شکل داده‌های ورودی الگوریتم روی می‌آورند. در برخی روش‌ها سیگنال‌های ارتعاش سازه به تصویر [۹] تبدیل شده، در برخی داده‌های کرنش در آرایش دو بعدی قرار گرفته است [۲۲] و در برخی دیگر با کنار هم قرار دادن پاسخ‌های دینامیکی سازه یک ماتریس دو بعدی تشکیل شده است [۲۳، ۲۴]. از سوی دیگر، استفاده از معماری‌های یک بعدی CNN برای پردازش سیگنال رایج است. بر این اساس، چندین تحقیق در مورد استفاده از این شبکه برای حل مسائل تشخیص خرابی در سازه

¹ Convolutional Neural Network

² Modarres et al

³ Shihavuddin et al.

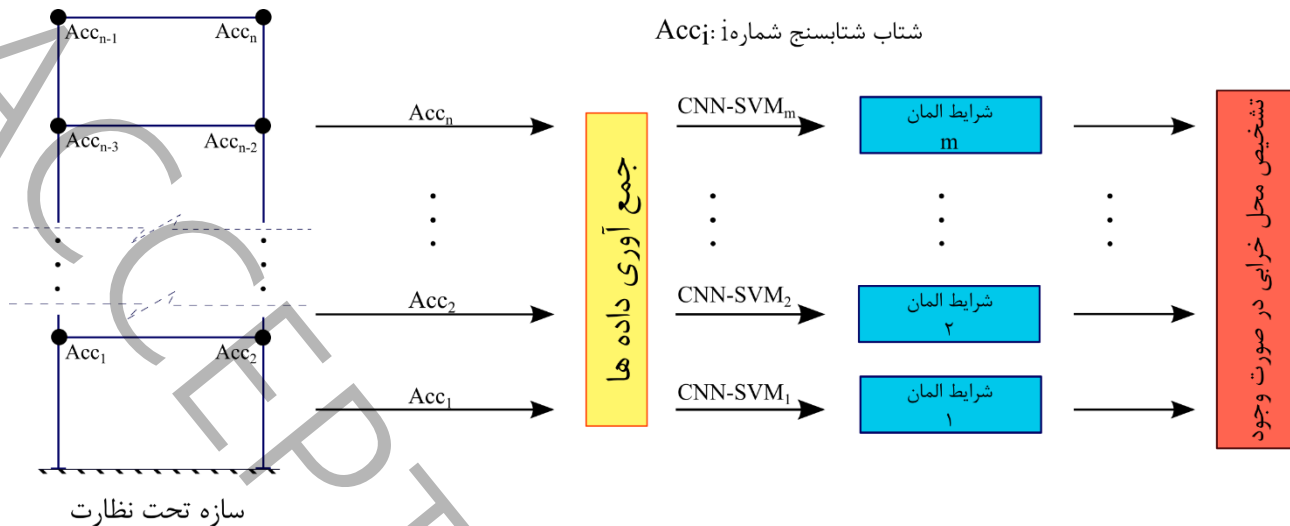
با استفاده از سیگنال‌های شتاب دامنه-زمانی انجام شده است [۲۵-۲۸]. برخی از محققین نیز از انواع دیگری از داده‌های ورودی مانند پاسخ‌های دامنه فرکانس [۲۹] یا شکل مود اول سازه [۳۰] استفاده کرده‌اند. بسیاری از روش‌های ذکر شده قبلی، با افزودن لایه‌های پیچشی بیشتر به مدل‌های خود، از معماری عمیق استفاده می‌کنند که فرایند آموزش را نیازمند حجم زیادی از داده می‌کند و پردازش آن از نظر محاسباتی گران و زمان‌بر است. در یک مطالعه متفاوت، اوچی و همکاران^۱ [۳۱] یک CNN تک بعدی را معرفی کردند که تنها از دو حالت سازه، یعنی کاملاً آسیب دیده و دست نخورده، به عنوان ورودی مرحله آموزش برای تعیین میزان آسیب سازه استفاده می‌کند. همین‌طور روش غیرمتمرکز دیگری بر پایه CNN یک بعدی توسط اوچی و همکاران [۳۲] برای شبکه‌های حسگر بی‌سیم پیشنهاد شد. برای این منظور، یک شبکه مجزا برای هر سنسور آموزش داده شد تا آسیب دیدگی عضو مربوط به همان سنسور را در یک قاب فولادی کنترل کند. این الگوریتم عملکرد قابل قبولی در زمینه سرعت پردازش از خود نشان داد.

بنابراین، نویسندگان این مقاله روش جدید تشخیص خرابی سازه مبتنی بر ارتعاش را بر پایه CNN دو بعدی به منظور تشخیص وجود آسیب و مکان‌یابی آن در صورت وجود، ارائه می‌کنند. این روش غیرمتمرکز در نظر گرفته می‌شود و تنها از داده‌های خام شتاب بدون هیچ گونه آماده‌سازی یا مهندسی ویژگی استفاده می‌کند. هدف ما دستیابی به روشی دقیق است که به زمان کم برای ارزیابی نمونه‌های جدید نیاز دارد و می‌توان آن را با داده‌های کم‌تری نسبت به روش‌های سنتی آموزش داد. تمرکز زدایی اجازه می‌دهد تا با بهینه‌سازی هر شبکه برای هر عضو از سازه، دقت افزایش یابد در حالی که معماری‌ها فشرده و غیر عمیق هستند. از این رو، پیچیدگی محاسباتی کاهش می‌یابد و هر یک از شبکه‌ها را می‌توان در زمان کوتاه‌تری آموزش داد و آزمایش کرد. نویسندگان عملی بودن روش پیشنهادی را با استفاده از داده‌های شتاب مجموعه داده‌های سازه آزمایشگاهی شبیه‌ساز جایگاه تماشاگران دانشگاه قطر [۳۳-۳۵] ارزیابی کردند. این پژوهش به شرح زیر تنظیم شده است: روش پیشنهادی در بخش ۲، شامل شرح مختصری از CNN، روش آموزش و آزمایش آن معرفی شده است. در بخش ۳، سازه معیار توضیح داده شده و اجرای روش پیشنهادی نشان داده شده است. نتایج ارزیابی روش پیشنهادی نیز در این بخش گنجانده شده است. در نهایت، نتیجه‌گیری مورد بحث قرار می‌گیرد.

۲- روش پیشنهادی

هدف از این بخش ارائه یک الگوریتم سریع و کارآمد برای تشخیص خرابی در سازه آزمایشگاهی بزرگ مقیاس است. در روش پیشنهادی ابتدا باید سازه مورد نظر سنسورگذاری شود و پاسخ شتاب سازه برای پردازش توسط شبکه پیشنهادی جمع‌آوری شود. سپس یک CNN به منظور تشخیص خرابی در هر عضو آموزش داده می‌شود. هر کدام از این شبکه‌ها وظیفه نظارت بر سلامت یک عضو را بر عهده دارند. تمام پردازش‌ها بر روی داده‌های خام شتاب‌سنج انجام می‌شود که با حذف مرحله پیش‌پردازش هزینه محاسباتی و در نتیجه زمان محاسبات کاهش می‌یابد. در این پژوهش از داده‌های یک سازه آزمایشگاهی بزرگ مقیاس برای بررسی عملکرد الگوریتم پیشنهادی استفاده خواهد شد و در نهایت دقت الگوریتم با استفاده از معیارهای مختلف بررسی می‌شود. شکل ۱ خلاصه‌ای از روش پیشنهادی ارائه می‌دهد.

¹ Avci



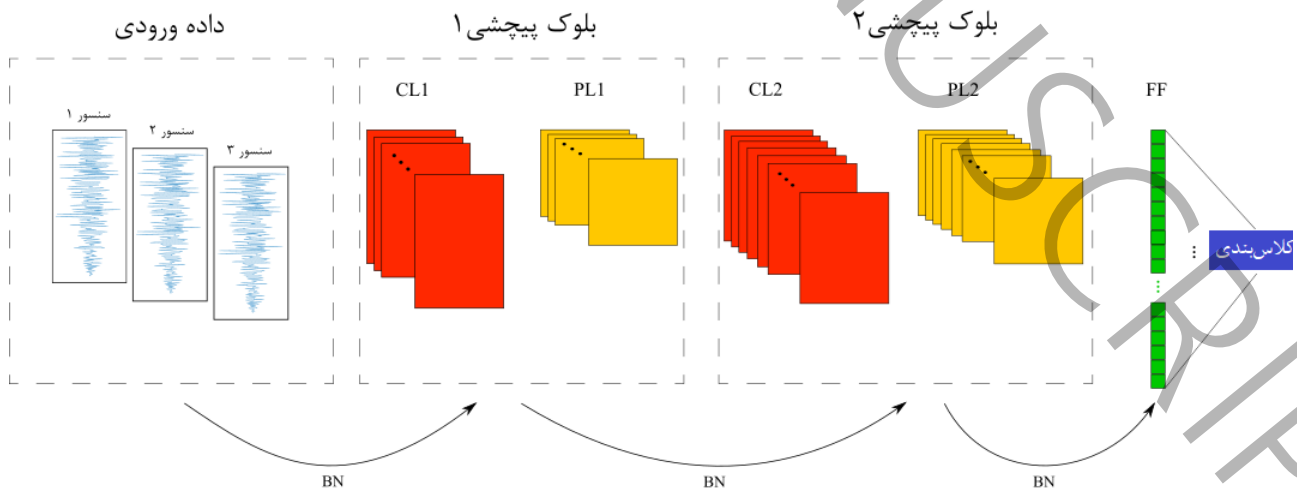
شکل ۱ شماتیک روش پیشنهادی؛ Schematic of the proposed method

حرکت هسته‌های تشخیص الگوی CNN دو بعدی در کنار پارامترهای قابل یادگیری بیشتر، قابلیت یادگیری این الگوریتم را در مقایسه با نوع یک بعدی آن افزایش می‌دهد. استفاده از CNN دو بعدی همچنین به ما اجازه می‌دهد تا داده‌های مورد نیاز برای مرحله آموزش را با تغییر فرم ورودی، همانطور که در بخش آموزش بحث خواهیم کرد، کاهش دهیم. معماری و شرح مختصری از هر لایه از CNNهای آموزش داده شده در بخش‌های بعدی ارائه شده است و سپس مراحل آموزش و آزمایش توضیح داده می‌شود.

۲-۱- معماری الگوریتم پیشنهادی

از آنجا که هدف اصلی این پژوهش رسیدن به دقت بالا در عین سریع بودن است روش پیشنهادی از یک معماری متفاوت غیر متمرکز برای تعیین خرابی در سازه استفاده می‌کند. این بدین معنا است که به جای آموزش یک شبکه عمیق برای تمام سازه، وظیفه پایش سلامت بین چندین شبکه تقسیم شده است. اولین مزیت این کار بالا رفتن سرعت عمل و کاهش پیچیدگی محاسباتی خواهد بود. در این معماری هر شبکه CNN مسئول بررسی سلامت تنها یک عضو از سازه است. بدین ترتیب برخلاف روش‌های متمرکز امکان بررسی همزمان خرابی در چند عضو نیز فراهم می‌شود. هر یک از CNNها از یک معماری ساده پیروی می‌کنند که در شکل ۲ مشاهده می‌شود.

بردار ویژگی‌های استخراج شده: FF، لایه ادغام: PL، لایه پیشی: CL، تابع فعالسازی: AF، نرمالسازی دسته ای: BN، ماشین بردار پشتیبان: SVM

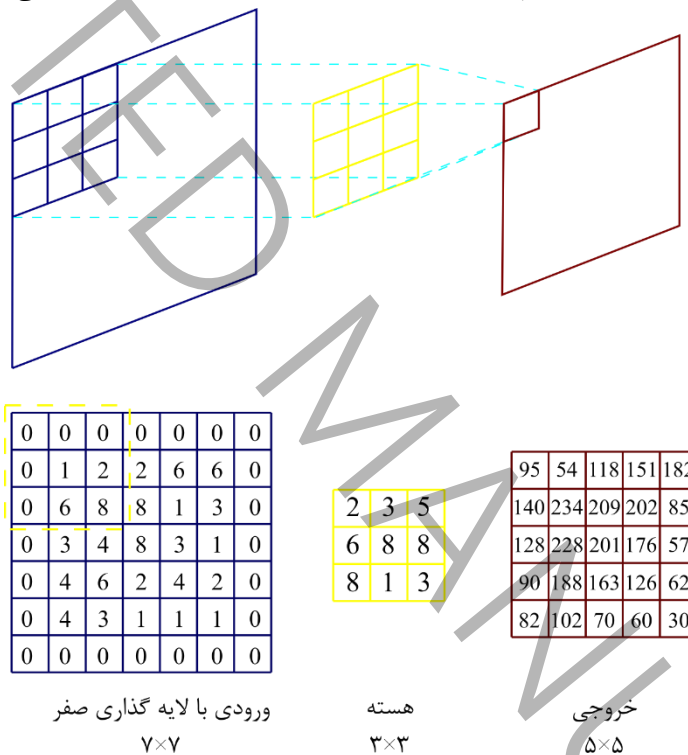


شکل ۲ معماری شبکه پیشنهادی؛ Architecture of the proposed network

هر شبکه CNN شامل دو بلوک پیچشی برای تشخیص الگوهای موجود در داده‌های ورودی و یک لایه طبقه‌بند برای کلاس‌بندی اطلاعات استخراج شده توسط بخش قبلی است. برای بالا بردن راندمان روش پیشنهادی، هر یک از این شبکه‌ها به طور مجزا و برای تشخیص خرابی در یک المان بهینه سازی شده‌اند. در ادامه توضیح مختصری از هر لایه CNN داده می‌شود.

۱-۱-۲- لایه پیچشی

لایه پیچشی جوهر اصلی CNN است که آن را از سیستم‌های یادگیری ماشین قبلی متمایز می‌کند. در این لایه، یک فرآیند ریاضی برای استخراج ویژگی‌ها از ورودی استفاده می‌شود. این عملیات ریاضی ضرب نقطه‌ای بین هسته لغزنده و ورودی لایه پیچشی و سپس جمع حاصل آن با یک عدد ثابت است. یک لایه پیچشی شامل چندین هسته با وزن‌های قابل یادگیری است که یک ماتریس جدید به نام نقشه ویژگی^۱ از ورودی‌ها ایجاد می‌کند که سپس به لایه بعدی داده می‌شود. تعداد کانال‌های ورودی در هسته و داده‌های ورودی باید یکسان باشد. به طور معمول با استفاده از لایه‌گذاری^۲ صفر در این لایه از کوچک شدن نقشه ویژگی جلوگیری می‌شود. شکل ۳ عملکرد یک هسته پیچشی^۳ در ۳ را بر روی یک پنجره داده ۷ در ۷ همراه با لایه‌گذاری صفر نشان می‌دهد.



شکل ۳ هسته پیچشی همراه با لایه‌گذاری صفر؛ Convolutional kernel with zero padding

۱-۲-۲- نرمال‌سازی دسته‌ای

از آنجایی که روند آموزش دسته^۴ به دسته انجام می‌شود، توزیع غیر یکنواخت هر دسته می‌تواند به طور قابل توجهی مانع همگرایی شود. سرچی یافی^۵ و کریستین سزجیدی^۶ [۳۶] یک روش نرمال‌سازی دسته‌ای^۷ (BN) را برای غلبه بر این مشکل ارائه کردند که به نام تغییر متغیر کمکی داخلی شناخته می‌شود. نرمال‌سازی دسته‌ای یک روش قدرتمند برای پارامترسازی مجدد تقریباً هر نوع شبکه عصبی است. این الگوریتم میانگین و واریانس هر دسته ورودی را محاسبه می‌کند و سپس آن‌ها را به ترتیب به ۰ و ۱ تغییر می‌دهد. از آنجایی

¹ Feature Map
² Padding
³ Convolutional Kernel
⁴ Batch
⁵ Sergej Ioffe
⁶ Christian Szegedy
⁷ Batch Normalization


که BN در یک دسته کوچک انجام می‌شود، از نظر محاسباتی کارآمد است و همچنین امکان استفاده از نرخ یادگیری بالاتر را فراهم می‌کند.

۳-۱-۲- تابع فعال‌سازی

یکی از حیاتی‌ترین اجزای یک شبکه عصبی، توابع فعال‌سازی آن است. این توابع به شبکه خاصیت غیرخطی بودن می‌دهند و ورودی را قابل یادگیری‌تر می‌کنند. تابع فعال‌سازی در یک شبکه عصبی نحوه تبدیل مجموع وزنی ورودی به خروجی از یک گره یا گره‌های یک لایه از شبکه را تعریف می‌کند. در سال‌های اخیر تابع فعال‌سازی واحد خطی اصلاح‌شده^۱ (ReLU) [۳۶, ۳۷] به دلیل توانایی آن در حل مؤثر مشکل ناپدید شدن گرادینان، که یک مسئله رایج در توابع فعال‌سازی سیگموئید بود، محبوبیت گسترده‌ای پیدا کرده است [۳۸]. علاوه بر این، ReLU از نظر محاسباتی کارآمد است و روند آموزش شبکه را سریع‌تر می‌کند. این تابع از رابطه $F = \max(0, x)$ پیروی می‌کند.

۴-۱-۲- لایه ادغام

یک لایه‌ی ادغام^۲ در معماری شبکه عصبی در تلاش است با حفظ اطلاعات حیاتی موجود در داده‌ها و کاهش همزمان حجم آن‌ها اندازه نقشه ویژگی را کاهش دهد. علاوه بر این لایه ادغام یادگیری را مستقل‌تر از تغییرات جزئی داده‌های ورودی می‌کند. به عنوان دو نوع متداول آن می‌توان به ادغام حداکثر و ادغام میانگین اشاره کرد. ادغام میانگین یک پنجره را در نقشه ویژگی حرکت می‌دهد و میانگین مقادیر موجود در پنجره را محاسبه می‌کند، در حالی که ادغام حداکثر بیشترین مقدار را گرفته و بقیه را نادیده می‌گیرد. از مزیت‌های ادغام حداکثر افزایش سرعت محاسبات نسبت به ادغام میانگین است. شکل ۴ نحوه عملکرد ادغام حداکثر را نشان می‌دهد.



شکل ۴ عملگر ادغام حداکثر؛ Max pooling operator

۵-۱-۲- حذف تصادفی

برای اولین بار، سریواستاوا و همکاران^۳ [۳۹] این روش را به عنوان راه حلی ساده برای مشکل بیش برآزش پیشنهاد کردند. به طور خلاصه حذف تصادفی برخی از واحدها را به طور موقت در مرحله آموزش غیر فعال کرده و شبکه را مجبور به یادگیری ویژگی‌ها از بین

¹ Rectified Linear Unit

² Pooling

³ Srivastava et al.

ویژگی‌های موجود می‌کند. این کار از حفظ کردن برخی ویژگی‌ها توسط شبکه که معمولاً همراه با مقداری نویز هستند جلوگیری می‌کند. این عملیات علاوه بر مزیت گفته شده باعث کاهش هزینه محاسباتی و در نتیجه افزایش سرعت آموزش شبکه می‌شود. به طور معمول این تابع قبل از لایه کلاس‌بندی قرار می‌گیرد.

۲-۱-۶- طبقه‌بند

پس از استخراج ویژگی‌ها توسط لایه‌های پیچشی، به منظور طبقه‌بندی شدن در یکی از گروه‌های موجود نتایج وارد این لایه می‌شوند. در CNN، طبقه‌بند یک لایه کاملاً متصل^۱ (FC) است که بردار ویژگی‌ها را طبقه‌بندی می‌کند. یک لایه FC در طبقه‌بند دودویی به دنبال ایجاد مرزی بین ویژگی‌ها به منظور ارائه بهترین نتایج طبقه‌بندی ممکن در داده‌های آموزشی است. هر نورون در یک لایه FC به تمام لایه‌های قبلی متصل است. همانطور که در رابطه (۱) نشان داده شده است، هر مقدار ورودی u در وزن w ضرب شده و با بایاس b جمع می‌شود و در نهایت، تمام نتایج جمع می‌شوند. در این روش، وزن w و بایاس b پارامترهای قابل یادگیری هستند. خروجی لایه FC یک بردار N بعدی است که N تعداد کلاس‌های مسئله است و در این حالت N برابر با ۲ است.

$$y = \sum u \times w + b \quad (1)$$

۲-۱-۷- تابع هزینه

برای محاسبه خطای شبکه‌های عصبی مصنوعی از توابعی به نام تابع هزینه^۳ یا تابع هزینه استفاده می‌شود. در فرایند تعیین وزن‌ها و بایاس‌ها در هر مرحله از آموزش، خطای پیش‌بینی شبکه با توجه به برچسب داده‌های ورودی محاسبه می‌شود. در ادامه خطای محاسبه شده معیار به روز رسانی دوباره وزن‌ها و بایاس‌ها قرار گرفته و این چرخه تا رسیدن به نتایج مطلوب ادامه پیدا می‌کند. برای محاسبه خطای پیش‌بینی شبکه‌های CNN به طور معمول از الگوریتم آنتروپی متقاطع [۴۰] به عنوان تابع هزینه استفاده می‌شود. تابع هزینه آنتروپی متقاطع یک روش برای محاسبه تفاوت بین برچسب‌های واقعی و خروجی‌های پیش‌بینی شده است.

۲-۱-۸- بهینه‌ساز

بهینه‌سازها الگوریتم‌هایی هستند که برای تغییر ویژگی‌های شبکه عصبی مانند وزن و نرخ یادگیری^۴ به منظور کاهش هزینه استفاده می‌شوند. نحوه تغییر وزن‌ها یا نرخ یادگیری شبکه عصبی برای کاهش هزینه توسط بهینه‌سازهایی که استفاده می‌شوند تعریف می‌شود. الگوریتم‌های بهینه‌سازی وظیفه کاهش هزینه و ارائه دقیق‌ترین نتایج ممکن را بر عهده دارند. در مرحله آموزش معماری پیشنهادی، الگوریتم بهینه‌ساز آدام^۵ [۴۱] به جای الگوریتم سنتی شیب نزولی تصادفی^۶ (SGD) استفاده می‌شود. این الگوریتم به عنوان محبوب‌ترین روش در یادگیری عمیق برای بهینه‌سازی هزینه شناخته می‌شود.

۲-۲- آموزش مدل پیشنهادی

روش پیشنهادی سلامت هر عضو از سازه را به طور جداگانه و با استفاده از یک CNN دو بعدی خاص ارزیابی می‌کند. این رویکرد غیرمتمرکز امکان تشخیص آسیب‌های متعدد در سازه را به طور همزمان فراهم می‌کند. آموزش CNN‌ها شامل استفاده از سیگنال‌های خام شتاب، هم در شرایط آسیب دیده و هم در شرایط دست نخورده، برای آموزش یک CNN به ازای هر عضو است. در این مرحله به دو دلیل به جای استفاده از سیگنال یک بعدی از ماتریسی شامل سه سیگنال یک بعدی به عنوان ورودی سیستم استفاده شده است. دلیل اول استفاده از CNN دو بعدی است که استفاده از ورودی دو بعدی را می‌طلبد. اما دلیل دوم و مهم‌تر، کاهش نیاز به داده‌های جدید

¹ Fully Connected

² Bias

³ Loss Function

⁴ Learning Rate

⁵ Adam

⁶ Stochastic Gradient Descent

برای آموزش است در حالی که دقت شبکه افت نکند. فرض کنید برای رسیدن به دقت هدف، نیاز به N نقطه داده برای هر عضو وجود دارد. در صورت استفاده از داده‌های مربوط به تنها یک شتاب‌سنج برای هر عضو، در نهایت در سازه ۳۰ مفصلی معیار به $30 \times N$ خط داده برای آموزش هر عضو نیاز است. این بدین معناست که به ازای هر شتاب‌سنج نیاز به ثبت N سطر داده است. اما در صورت استفاده از داده‌های دو شتاب‌سنج دیگر به عنوان داده کمکی برای آموزش شبکه برای هر عضو، این تعداد تقریباً به یک سوم کاهش می‌یابد. بدین ترتیب به منظور فراهم کردن N خط داده مورد نیاز برای هر عضو تنها $N/3$ نقطه داده از هر شتاب‌سنج مورد نیاز است. در نتیجه مقدار داده مورد استفاده در کل فرایند به $10 \times N$ کاهش می‌یابد، در حالی که دقت همچنان بالا است. بدین ترتیب برای پایش سلامت هر عضو سه شتاب‌سنج از نزدیک‌ترین شتاب‌سنج‌ها به آن عضو انتخاب و از داده‌های آن‌ها در فرایند آموزش شبکه مربوطه استفاده شده است. انتظار می‌رود ویژگی‌های خرابی در شتاب‌سنج‌های نزدیک‌تر به عضو مورد نظر بیشتر دیده شود. همین‌طور که در بخش مربوط به نتایج خواهیم دید، استفاده از این روش دقت بسیار بالایی نیز برای الگوریتم به همراه خواهد آورد.

برای هر عضو i داده‌های حالت آسیب دیده و آسیب ندیده به صورت روابط (۲) و (۳) خواهد بود.

$$U_i = [U_{i1} \quad U_{i2} \quad U_{i3}] \quad (۲)$$

$$D_i = [D_{i1} \quad D_{i2} \quad D_{i3}] \quad (۳)$$

که در آن U_i و D_i به ترتیب ماتریس سیگنال حالت سالم و حالت آسیب دیده برای عضو i است. همین‌طور U_{i1} ، U_{i2} و U_{i3} بردار سیگنال ثبت شده از سه شتاب‌سنج نزدیک به عضو i هستند. به طور مشابه D_{i1} ، D_{i2} و D_{i3} بردار سیگنال‌های مربوط به حالت آسیب دیده عضو i هستند.

برای اینکه اثر خرابی در سایر اعضا در تشخیص خرابی عضو i تأثیری نداشته باشد، از داده‌های حالت خراب سایر اعضا نیز در داده‌های آموزشی حالت سالم عضو i استفاده شده است. با این تکنیک شبکه مربوط به عضو i تنها خرابی مربوط به همان عضو را یاد می‌گیرد. همان‌طور که در بخش قبلی نیز اشاره شد، CNN فقط می‌تواند داده‌های با طول معین را دریافت کند؛ در نتیجه ابتدا داده‌ها به طول‌های مساوی S_f تقسیم و برچسب‌گذاری شدند. در این فرایند به حالت سالم برچسب ۰ و حالت آسیب دیده برچسب ۱ اختصاص داده شد.

در روابط (۴) و (۵) به ترتیب ماتریس‌های با طول ثابت حالت سالم و حالت آسیب دیده عضو i نشان داده شده است.

$$U_i = \begin{bmatrix} U_{i1,1} & U_{i2,1} & U_{i3,1} \\ U_{i1,2} & U_{i2,2} & U_{i3,2} \\ \vdots & \vdots & \vdots \\ U_{i1,N_u} & U_{i2,N_u} & U_{i3,N_u} \end{bmatrix}$$

Error!

No text of specified style in document. (۴)

$$D_i = \begin{bmatrix} D_{i1,1} & D_{i2,1} & D_{i3,1} \\ D_{i1,2} & D_{i2,2} & D_{i3,2} \\ \vdots & \vdots & \vdots \\ D_{i1,N_u} & D_{i2,N_u} & D_{i3,N_u} \end{bmatrix} \quad (۵)$$

در این روابط N_u و N_d به ترتیب تعداد فریم‌های حالت خراب و سالم عضو i هستند. همین‌طور در روابط (۶) و (۷)، λ زمین فریم سیگنال حالت آسیب دیده و سالم نشان داده شده است که هر فریم دارای ابعاد $3 \times S_f$ می‌باشد.

$$UF_{i,j} = [U_{i1,j} \quad U_{i2,j} \quad U_{i3,j}] \quad (۶)$$

$$DF_{i,j} = [D_{i1,j} \quad D_{i2,j} \quad D_{i3,j}] \quad (۷)$$

با فرض اینکه سیگنال هر شتاب‌سنج شامل S_u و S_d نمونه به ترتیب برای حالت‌های آسیب‌دیده و سالم یک عنصر معین است، تعداد کل فریم‌ها در موارد آسیب‌دیده و سالم به صورت زیر تعیین می‌شود (روابط (۸) و (۹)).

$$N_u = \frac{S_u}{S_f} \quad (۸)$$

$$N_d = \frac{S_d}{S_f} \quad (۹)$$

با توجه به اینکه آسیب در سایر اعضای سازه به عنوان شرایط سالم برای یک عضو در نظر گرفته می‌شود، مقادیر N_u و N_d به طور قابل توجهی متفاوت هستند و در نتیجه یک مجموعه داده نامتعادل برای آموزش ایجاد می‌شود. برای غلبه بر این مشکل، در مرحله تکه‌تکه کردن سیگنال اصلی، به تعداد مساوی داده از هر سناریویی که عضو i در آن سالم است انتخاب شد، داده‌ها به تکه‌هایی با طول مساوی تقسیم و مجموعه داده ساخته شده به صورت تصادفی مرتب شد. سپس تعداد N_d داده اول به عنوان فریم‌های سالم برای آموزش انتخاب و استفاده شد. با انجام این عملیات ساختمان داده‌های آموزشی برای هر دو حالت آسیب دیده و سالم متعادل شد.

۳-۲- آزمایش مدل پیشنهادی

پس از آماده سازی داده‌های آموزشی هر CNN باید به طور مجزا به ازای تعداد حلقه‌های مشخصی^۱ بر روی داده‌های مربوط به عضو خود آموزش ببیند. الگوریتم پس‌انتشار^۲ به منظور آموزش شبکه در این بخش استفاده شده است. به منظور جلوگیری از مشکل بیش‌برازش در فاز آموزش شبکه‌ها، بهینه‌ترین وزن‌های شبکه با توجه به عملکرد آن‌ها بر روی داده‌های آزمایشی ذخیره شد. در آخرین مرحله نیز باید عملکرد شبکه مورد نظر بر روی داده‌هایی که شبکه آن‌ها را ندیده ارزیابی شود. برای پیش‌بینی داده‌های جدید از سه مرحله‌ی زیر استفاده می‌کنیم.

- داده‌های جدید را به طول‌های مساوی S_f تقسیم می‌شوند.
 - برای هر فریم داده ورودی حالت خراب به عنوان ۱ و حالت سالم با ۰ طبقه‌بندی می‌شود.
- درصد احتمال خراب بودن^۳ عضو i ، DP_i ، را از رابطه (۱۰) به دست می‌آید.

$$DP_i = \frac{\sum_{j=1}^{n_i} L_{i,j}}{n_i} \times 100 \quad (۱۰)$$

^۱ Epoch

^۲ Backpropagation

^۳ Damage Possibility


که در آن L_i, z_i ، زامین فریم پردازش شده توسط شبکه نام است. انتظار می‌رود برای اعضای آسیب دیده مقدار DP_i به ۱۰۰ و برای حالت‌های سالم به ۰ نزدیک‌تر باشد.

۳- اعتبارسنجی روش پیشنهادی

در این بخش، روش پیشنهادی این مطالعه با استفاده از داده‌های یک سازه معیار در زمینه پایش سلامت ارزیابی می‌شود. برای این منظور، در زیربخش‌های بعدی، ابتدا سازه معیار معرفی می‌گردد. سپس اعتبار روش پیشنهادی در این مطالعه مورد بررسی قرار می‌گیرد. در نهایت در بخش آخر، سرعت CNNها مورد بحث قرار می‌گیرد.

۳-۱- سازه معیار

در این مطالعه به منظور بررسی عملیاتی الگوریتم پیشنهادی، از داده‌های مربوط به یک سازه آزمایشگاهی بزرگ مقیاس استفاده شده است. این سازه آزمایشگاهی^۱ (QUGS) که توسط محققین دانشگاه قطر ساخته شده است، یک شبیه‌سازی از جایگاه تماشاگران در ورزشگاه است. سازه QUGS در شکل ۵ نشان داده شده است. QUGS یک سازه فولادی آزمایشگاهی با هشت شاه‌تیر و ۲۵ تیر پرکننده که بر روی چهار ستون قرار دارند، است. شبیه‌ساز جایگاه تماشاگران برای میزبانی از ۳۰ تماشاگر با ابعاد ۴/۲ متر × ۴/۲ متر طراحی شده است [۳۵]. به منظور ثبت پاسخ‌های دینامیکی سازه ۳۰ شتاب‌سنج بر روی تیرهای اصلی و در محل مفصل‌ها تعبیه شده است. خرابی در سازه مورد بررسی از طریق شل کردن پیچ‌ها در اتصالات تیر به تیر شبیه‌سازی شده است. همچنین نیروی محرکه لرزاننده مورد استفاده نویز سفید بوده و داده‌ها در فرکانس نمونه‌برداری ۱۰۲۴ هرتز از تمامی شتاب‌سنج‌ها به طور همزمان جمع‌آوری شده‌اند. این روش برای هر مورد دو بار تکرار شده و نتایج به صورت دو مجموعه داده ارائه شده است.



شکل ۵ چیدمان شتاب‌سنج‌ها در اتصالات (محل سناریوهای خرابی): (Arrangement of accelerometers at joints (locations of damage scenarios))

¹ Qatar University Grandstand Simulator

۳-۲- نتایج سناریوهای اصلی

در این مرحله، برای اعتبارسنجی روش پیشنهادی، برای ده مفصل از سازه ذکر شده عملیات پایش سلامت انجام شده است. مجموعه داده مورد استفاده شامل داده‌های به دست آمده از این ده مفصل است، که در مجموع ۱۳ سناریو متفاوت را تشکیل می‌دهد. این سناریوها شامل ده مورد آسیب منفرد در هر یک از مفصل‌ها، دو مورد آسیب دو عضوی و حالت سالم سازه است. هر مجموعه داده شامل ۲۶۲۱۴۴ نمونه شتاب ثبت شده در ۲۵۶ ثانیه است. بدین منظور، ۵۰ درصد از مجموعه داده الف به سیگنال‌هایی با طول ثابت ۲۵۶ نمونه تقسیم شدند تا ده CNN دوبعدی را با استفاده از روش توضیح داده شده آموزش دهند. همینطور 12/5 درصد از داده‌های همین مجموعه برای آزمایش CNNها استفاده شد. علاوه بر این، ۵۰ درصد از مجموعه داده ب نیز به عنوان مجموعه داده اعتبارسنجی مورد بررسی قرار گرفت.

جدول ۱ انتخاب شتابسنج‌ها را نشان می‌دهد. معماری پایه هر CNN از معماری بیان شده در شکل ۲ پیروی می‌کند اما انتخاب ابرپارامترها در هر CNN با استفاده از جستجوی حریصانه برای هر عضو به صورت جداگانه بهینه‌سازی شده است. CNNها با زبان برنامه‌نویسی پایتون نوشته شده‌اند و رایانه مورد استفاده در این پژوهش دارای سی‌پی‌یو^۱ Intel Core i7-4720HQ و کارت گرافیک^۲ NVIDIA GTX 950m بوده است.

جدول ۱ نحوه انتخاب شتابسنج برای هر مفصل؛ Selection of accelerometers for each joint

شماره مفصل									
۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰
۶-۲-۱	۳-۲-۱	۴-۳-۲	۵-۴-۳	۶-۵-۴	۷-۶-۵	۸-۷-۶	۹-۸-۷	۱۰-۹-۸	۱۰-۹-۵

پس از آموزش، روش پیشنهادی به طور متوسط دقت 99/8 درصد بر روی مجموعه داده‌های آموزشی و 99/6 درصد را بر روی مجموعه داده‌های اعتبارسنجی نشان داد. جزئیات دقت هر CNN در مجموعه داده‌های ذکر شده در جدول ۲ ارائه شده است. همانطور که مشاهده می‌شود روش پیشنهادی علاوه بر دقت میانگین بالا، در هر یک از اعضا نیز حداقل 99/7 درصد دقت را حفظ کرده که نشان دهنده قدرت بالای شبکه در تشخیص خرابی در تمامی حالت‌ها است.

جدول ۲ نتایج الگوریتم پیشنهادی بر روی داده‌های آموزش، آزمایش و اعتبارسنجی؛ Results of the proposed algorithm on training, testing, and validation data

شماره شبکه	مجموعه داده آموزش	مجموعه داده آزمایش	مجموعه داده اعتبارسنجی
	دقت	دقت	دقت
۱	1/000	0/998	0/998
۲	0/998	0/998	0/981
۳	0/999	0/996	0/994
۴	1/000	0/999	1/000
۵	0/989	0/996	0/996
۶	1/000	0/999	0/999
۷	1/000	1/000	1/000
۸	0/999	0/997	0/997

¹ Central Processing Unit (CPU)

² Graphics Processing Unit (GPU)

۹	1/000	0/997	0/999
۱۰	0/997	0/998	0/993

در ادامه مجموعه داده‌های آزمایش برای نشان دادن نحوه مکان‌یابی خرابی استفاده شده است. جدول ۳ مقدار DP محاسبه شده توسط شبکه CNNها را برای هر مفصل در سازه نشان می‌دهد. در تمام ۱۳ سناریو، مقدار DP محاسبه شده مفصل‌های آسیب دیده بیش از 98/4 درصد بوده است، در حالی که این مقدار برای مفصل‌های سالم از 3/1 درصد عبور نکرده است. اختلاف واضح در مقدار DP محاسبه شده برای مفصل‌ها در دو حالت سالم و خراب نشان دهنده عملکرد تقریباً بی‌نقص روش معرفی شده در این پژوهش است.

جدول ۳ نتایج روش پیشنهادی در سناریوهای مختلف خرابی؛ Results of the proposed method in various damage scenarios

سناریوی خرابی	شماره اتصال									
	1	2	3	4	5	6	7	8	9	10
۱	99/2	0/0	0/0	0/0	0/0	0/0	0/0	0/0	0/8	0/0
۲	0/0	100/0	0/0	0/0	0/0	0/0	0/0	0/0	0/0	0/0
۳	0/0	0/0	99/2	0/0	3/1	0/0	0/0	0/8	0/0	0/0
۴	0/0	0/0	1/6	100/0	0/0	0/0	0/0	0/0	1/6	0/0
۵	0/0	0/0	0/0	0/0	99/2	0/0	0/0	0/0	0/0	0/0
۶	0/0	0/0	0/0	0/0	0/0	100/0	0/0	0/0	0/0	0/0
۷	0/0	0/8	0/8	0/0	0/0	0/0	100/0	0/0	0/0	0/0
۸	0/0	1/6	0/0	0/0	0/0	0/0	0/0	99/2	0/0	0/0
۹	0/0	0/0	0/0	0/0	0/0	0/0	0/0	0/0	99/2	0/8
۱۰	0/8	0/0	0/0	0/0	0/0	0/8	0/0	0/0	0/0	100/0
۵-۱	98/4	0/0	0/0	0/0	98/4	0/0	0/0	0/0	0/0	0/0
۴-۳	0/0	0/0	98/4	99/2	0/0	0/0	0/0	2/3	0/0	0/8
بدون خرابی	0/0	0/0	0/0	0/0	0/0	0/0	0/0	0/0	0/8	1/6
دقت بر اساس هر اتصال	99/76	99/82	99/64	99/94	99/58	99/94	100/00	99/70	99/70	99/76

تحلیل داده‌های جدول ۳ نشان می‌دهد که روش پیشنهادی در شناسایی و تشخیص خرابی‌ها در سناریوهای مختلف بسیار موفق عمل کرده است. به طور مثال، در سناریوی خرابی شماره ۱، مقدار DP محاسبه شده برای اتصال شماره ۱ به 99/2 رسیده است که نشان‌دهنده قابلیت بالای روش در تشخیص دقیق خرابی‌هاست. همچنین، در سناریوی خرابی شماره ۷، تنها اتصالات شماره ۲ و ۳ دچار خطای اندکی شده‌اند (DP=0/8) که با توجه به احتمال خرابی محاسبه شده برای مفصل آسیب دیده (۱۰۰) و اختلاف واضح بین این دو مقدار، خطای پیش‌آمده قابل چشم‌پوشی است. از سوی دیگر، سناریوی بدون خرابی نیز نشان می‌دهد که روش پیشنهادی در شرایط عادی و بدون وجود خرابی نیز می‌تواند با دقت بالایی عمل کند، که این امر اهمیت توانایی روش در تشخیص عدم وجود خرابی را مورد تأکید قرار می‌دهد. نتایج همچنین نشان می‌دهند که روش پیشنهادی قادر به تمایز بین سناریوهای خرابی همزمان است. در سناریوی ۵-۱، خرابی اتصالات ۱ و ۵، خرابی در هر دو مفصل با دقت بالایی، احتمال خرابی 98/4 درصد، تشخیص داده شده است؛ این در حالی است که احتمال خرابی برای سایر اتصالات به درستی عدد صفر محاسبه شده است. در مجموع، نتایج حاکی از آن است که روش

پیشنهادی می‌تواند به عنوان یک راهکار موثر و قابل اعتماد در تشخیص خرابی‌ها در سناریوهای مختلف مورد استفاده قرار گیرد. در شکل ۶ نحوه مکان‌یابی خرابی برای ۴ سناریوی مشخص خرابی از طریق نمودار نشان داده شده است.



شکل ۶ محاسبه احتمال آسیب‌دیدگی در سناریوهای خرابی در مفصل الف) شماره ۹ ب) شماره ۱۰ ج) شماره ۱ و ۵ به طور همزمان د) شماره ۳ و ۴ به طور همزمان؛

Damage probability estimation in damage scenarios for joint: a) number 9 b) number 10 c) numbers 1 and 5 simultaneously d) numbers 3 and 4 simultaneously

۳-۳- بررسی خرابی با استفاده از سنسورهای دور از محل خرابی

همانطور که پیش‌تر اشاره شد، فرض این پژوهش بر این بوده که سنسورهای نزدیک‌تر به محل خرابی داده‌های با ارزش‌تری به منظور تشخیص و مکان‌یابی خرابی در سازه ارائه می‌دهند. از این رو به منظور بررسی این فرضیه، در این بخش دو سناریوی دیگر خرابی اینبار با استفاده از داده‌های مربوط به دورترین سنسورها بررسی شده و نتایج با سناریوهای اصلی مقایسه می‌شود.

دو مفصل انتخاب شده برای این بخش مفصل‌های شماره ۱ و ۱۰ هستند که بیشترین فاصله مکانی را نسبت به یکدیگر دارند. برای بررسی خرابی در مفصل شماره ۱ از سه سنسور نزدیک به مفصل ۱۰ (سنسورهای شماره ۵، ۹ و ۱۰) و برای تشخیص خرابی مفصل ۱۰ از دورترین سنسورهای ممکن نسبت به همان مفصل (سنسورهای شماره ۱، ۲ و ۶) استفاده شده است. در ادامه به همان نسبت‌های

قبلی داده‌های آموزشی و اعتبارسنجی انتخاب شده و برای تشخیص خرابی در این دو مفصل، دو شبکه عصبی پیچشی به شرحی که در بخش ۲ آمده آموزش داده شده است. جدول ۴ نتایج این دو سناریو را با حالت اصلی آن‌ها مقایسه می‌کند.

جدول ۴ مقایسه نتایج روش پیشنهادی در سناریوهای تشخیص خرابی با سنسورهای نزدیک و دور از محل خرابی؛ Comparison of the proposed method results in damage detection scenarios with sensors near and far from the damage location

	مجموعه داده آموزش	مجموعه داده اعتبارسنجی
سناریو	دقت	دقت
مفصل ۱- سنسورهای نزدیک	1/000	0/998
مفصل ۱- سنسورهای دور	0/974	0/948
مفصل ۱۰- سنسورهای نزدیک	0/998	0/981
مفصل ۱۰- سنسورهای دور	0/961	0/939

همانطور که از جدول ۴ مشخص است، در هر دو سناریوی بررسی شده دقت تشخیص خرابی در روش پیشنهاد شده (انتخاب سنسورهای نزدیک) بالاتر است. در سناریوهای مربوط به مفصل‌های ۱ و ۱۰، دقت در استفاده از سنسورهای نزدیک به ترتیب 0/998 و 0/981 در مجموعه داده اعتبارسنجی بدست آمده است، در حالی که در سناریوهای مربوط به سنسورهای دور، دقت به ترتیب به 0/948 و 0/939 کاهش می‌یابد. این نتایج نشان می‌دهد که روش پیشنهاد شده با استفاده از سنسورهای نزدیک به محل خرابی مؤثرتر است و فرض اولیه این پژوهش را تایید می‌کند. از آنجا که سنسورهای نزدیک اطلاعات بیشتری در مورد خرابی جمع‌آوری می‌کنند، پیشنهاد می‌شود که این سنسورها در اولویت انتخاب برای تشخیص خرابی قرار بگیرند.

با این حال، حتی با استفاده از سنسورهای دور، دقت تشخیص خرابی در محدوده قابل قبول قرار دارد. در هر دو سناریو بررسی شده با سنسورهای دور، دقت بالاتر از 0/939 برای مجموعه داده‌های آموزش و اعتبارسنجی نشان می‌دهد که این روش حتی زمانی که سنسورها در فاصله بیشتری از محل خرابی قرار دارند قابل اطمینان است. بنابراین اگرچه استفاده از سنسورهای نزدیک ترجیح داده می‌شود، اما سنسورهای دور نیز می‌توانند به عنوان یک گزینه مناسب جایگزین در سناریوهای مختلف عمل کنند.

۴-۳- سرعت پردازش شبکه‌ها

به منظور محاسبه سرعت عملکرد شبکه CNN پیشنهادی، ۳۲ ثانیه از پاسخ شتاب سازه توسط هر یک از شبکه‌های آموزش داده شده بر روی CPU و GPU پردازش و زمان متوسط برای هر دسته سیگنال محاسبه شد. این عملیات ۳۰ بار تکرار و میانگین‌گیری شد تا نتایج قابل اعتماد به دست آید. همانطور که در جدول ۴ نشان داده شده است، میانگین زمان برای پردازش یک سیگنال ۳۲ ثانیه‌ای حدود ۶۸ میلی‌ثانیه بر روی GPU و ۷۳ میلی‌ثانیه با استفاده از CPU بوده است. همانطور که مشاهده می‌شود زمان مورد نیاز برای پردازش یک فریم در هنگام استفاده از CPU یا GPU تفاوت قابل توجهی نداشته است که دلیل آن معماری نسبتاً فشرده شبکه است. با این حال، زمان مورد نیاز برای طبقه‌بندی یک سیگنال یک ثانیه‌ای برای هر CNN تقریباً ۲ میلی‌ثانیه است که نشان می‌دهد این روش نه تنها دقت بسیار بالایی دارد بلکه سرعت پردازش آن نیز بالا بوده و استانداردهای مورد نیاز برای پردازش برخط را دارا می‌باشد.

جدول ۵ زمان مورد نیاز روش پیشنهادی برای پردازش سیگنال ورودی بر حسب میلی ثانیه؛ Processing time required by the proposed method for the input signal (in milliseconds)

		شماره شبکه										
		۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	میانگین
۳۲ ثانیه پاسخ شتاب		۶۹	۷۳	۶۹	۶۹	۶۹	۶۹	۹	۹	۷۳	۴۹	67/8
GPU	یک فریم شامل ۱۲۸ نمونه شتاب	0/5	0/6	0/5	0/5	0/5	0/5	0/5	0/5	0/6	0/4	0/5
۳۲ ثانیه پاسخ شتاب		۷۸	۸۲	۸۲	۷۱	۷۸	۷۴	۸۰	۷۶	۸۲	۴۹	75/3
CPU	یک فریم شامل ۱۲۸ نمونه شتاب	0/6	0/6	0/6	0/6	0/6	0/6	0/6	0/6	0/6	0/4	0/6

۴- نتیجه گیری

یکی از چالش‌های اصلی در تشخیص خرابی سازه، تشخیص ویژگی‌های حساس به خرابی در سازه است [42]. این مقاله با ارائه یک چارچوب تشخیص و محل‌یابی سریع و دقیق خرابی در سازه بر اساس شبکه عصبی پیچشی دوبعدی، به این مشکل پرداخته است. روش پیشنهادی شامل یک فرایند غیرمتمرکز است که در آن به هر عضو از سازه یک شبکه عصبی پیچشی اختصاص داده می‌شود. از آنجا که ابر پارامترهای هر یک از این شبکه‌های عصبی پیچشی برای یک عضو خاص بهینه‌سازی شده است، این روش توانست دقت تشخیص خرابی را به 99/6 درصد برساند. همین‌طور از پاسخ شتاب یک سازه بزرگ مقیاس آزمایشگاهی برای اعتبارسنجی روش پیشنهاد شده استفاده شد که نتایج زیر به دست آمد.

- یافته‌های اعتبارسنجی نشان می‌دهند که روش پیشنهادی در شناسایی آسیب‌های سازه‌ای در هر دو حالت تک‌آسیب و دوآسیب، کارآمدی قابل توجهی دارد.
- الگوریتم پیشنهادی قابلیت استخراج ویژگی‌های خرابی را به طور مستقیم از سیگنال‌های شتاب خام را داشته و نیازی به هیچ پیش‌پردازش یا استخراج ویژگی ندارد.
- استفاده از سیگنال‌های دو شتاب‌سنج اضافی در داده ورودی، منجر به کاهش مقدار اطلاعات مورد نیاز برای آموزش شبکه‌های عصبی پیچشی می‌شود. علاوه بر این، این رویکرد امکان پیاده‌سازی یک شبکه عصبی پیچشی دوبعدی را فراهم می‌کند که همگرایی سریعتر و قابلیت یادگیری بیشتری نسبت به یک شبکه عصبی پیچشی یک بعدی دارد.
- بر خلاف روش‌های سنتی، این تکنیک غیرمتمرکز است و هر شبکه عصبی پیچشی از یک ساختار ساده پیروی می‌کند. بنابراین، الگوریتم پیشنهادی به توان محاسباتی کمتری نیازمند است و می‌توان آن را بر روی رایانه‌های متوسط نیز اجرا کرد.
- همان‌طور که در بخش اعتبارسنجی نشان داده شده است، زمان لازم برای ارزیابی داده‌های جدید در این الگوریتم بسیار پایین بوده و استانداردهای پردازش برخط را دارا می‌باشد.

۵- منابع و مراجع

[1] J.M. Ko, Y.Q. Ni, Technology developments in structural health monitoring of large-scale bridges, Engineering Structures, 2005, pp. 1715-1725.

- [2] F. Magalhães, A. Cunha, E. Caetano, Vibration based structural health monitoring of an arch bridge: From automated OMA to damage detection, *Mechanical Systems and Signal Processing*, 2012, pp. 212-228.
- [3] A.B. Noel, A. Abdaoui, T. Elfouly, M.H. Ahmed, A. Badawy, M.S. Shehata, *Structural Health Monitoring Using Wireless Sensor Networks: A Comprehensive Survey*, IEEE Communications Surveys and Tutorials, 2017, pp. 1403-1423.
- [4] S. Teng, G. Chen, P. Gong, G. Liu, F. Cui, Structural damage detection using convolutional neural networks combining strain energy and dynamic response, *Meccanica*, Springer Netherlands, 2020, pp. 945-959.
- [5] C.R. Farrar, S.W. Doebling, D.A. Nix, Vibration-based structural damage identification, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2001, pp. 131-149.
- [6] W. Fan, P. Qiao, *Vibration-based damage identification methods: A review and comparative study*, Structural Health Monitoring, SAGE PublicationsSage UK: London, England, 2011, pp. 83-111.
- [7] S. Das, P. Saha, S.K. Patro, Vibration-based damage detection techniques used for health monitoring of structures: a review, *Journal of Civil Structural Health Monitoring*, 6(3) (2016) 477-507.
- [8] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, D.J. Inman, Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks, *Journal of Sound and Vibration*, Elsevier, 2017, pp. 154-170.
- [9] H. Liu, Y. Zhang, Deep learning-based brace damage detection for concentrically braced frame structures under seismic loadings, *Advances in Structural Engineering*, 2019, pp. 3473-3486.
- [10] L. Jing, M. Zhao, P. Li, X. Xu, A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox, *Measurement: Journal of the International Measurement Confederation*, Elsevier B.V., 2017, pp. 1-10.
- [11] K. He, X. Zhang, S. Ren, J. Sun, Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2016, pp. 770-778.
- [12] J. Han, H. Chen, N. Liu, C. Yan, X. Li, CNNs-Based RGB-D Saliency Detection via Cross-View Transfer and Multiview Fusion, *IEEE Transactions on Cybernetics*, 2018, pp. 3171-3183.
- [13] T.N. Sainath, B. Kingsbury, G. Saon, H. Soltau, A.-r. Mohamed, G. Dahl, B. Ramabhadran, Deep Convolutional Neural Networks for Large-scale Speech Tasks, *Neural Networks*, 64 (2015) 39-48.
- [14] F. Ordóñez, D. Roggen, Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition, *Sensors*, 2016, pp. 115.
- [15] S. Kiranyaz, T. Ince, M. Gabbouj, Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks, *IEEE Transactions on Biomedical Engineering*, 2016, pp. 664-675.

- [16] W. Zhang, C. Li, G. Peng, Y. Chen, Z. Zhang, A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load, *Mechanical Systems and Signal Processing*, 2018, pp. 439-453.
- [17] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, D.J. Inman, 1D convolutional neural networks and applications: A survey, *Mechanical Systems and Signal Processing*, The Author(s), 2021, pp. 107398.
- [18] S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci, M. Gabbouj, 1-D Convolutional Neural Networks for Signal Processing Applications, *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 2019, pp. 8360-8364.
- [19] S. Sony, K. Dunphy, A. Sadhu, M. Capretz, A systematic review of convolutional neural network-based structural condition assessment techniques, *Engineering Structures*, Elsevier Ltd, 2021.
- [20] C. Modarres, N. Astorga, E.L. Droguett, V. Meruane, Convolutional neural networks for automated damage recognition and damage type identification, *Structural Control and Health Monitoring*, John Wiley and Sons Ltd, 2018, pp. e2230.
- [21] A.S.M. Shihavuddin, X. Chen, V. Fedorov, A.N. Christensen, N.A.B. Riis, K. Branner, A.B. Dahl, R.R. Paulsen, Wind turbine surface damage detection by deep learning aided drone inspection analysis, *Energies*, MDPI AG, 2019, pp. 676.
- [22] K. Lee, N. Byun, D.H. Shin, A Damage Localization Approach for Rahmen Bridge Based on Convolutional Neural Network, *KSCE Journal of Civil Engineering*, 2020.
- [23] Y. Yu, C. Wang, X. Gu, J. Li, A novel deep learning-based method for damage identification of smart building structures, *Structural Health Monitoring*, 2019, pp. 143-163.
- [24] B.K. Oh, S.H. Lee, H.S. Park, Damage localization method for building structures based on the interrelation of dynamic displacement measurements using convolutional neural network, *Structural Control and Health Monitoring*, 2020, pp. 1-16.
- [25] Y.-z. Lin, Z.-h. Nie, H.-w. Ma, Structural Damage Detection with Automatic Feature-Extraction through Deep Learning, *Computer-Aided Civil and Infrastructure Engineering*, 32(12) (2017) 1025-1046.
- [26] T. Zhang, S. Biswal, Y. Wang, SHMnet: Condition assessment of bolted connection with beyond human-level performance, *Structural Health Monitoring*, 2020, pp. 1188-1201.
- [27] M. Azimi, G. Pekcan, Structural health monitoring using extremely compressed data through deep learning, *Computer-Aided Civil and Infrastructure Engineering*, 2020, pp. 597-614.
- [28] H.V. Dang, M. Raza, T.V. Nguyen, T. Bui-Tien, H.X. Nguyen, Deep learning-based detection of structural damage using time-series data, *Structure and Infrastructure Engineering*, Taylor & Francis, 2020, pp. 1-20.
- [29] Z. Mousavi, M.M. Etefagh, M.H. Sadeghi, S.N. Razavi, Developing deep neural network for damage detection of beam-like structures using dynamic response based on FE model and real healthy state, *Applied Acoustics*, Elsevier Ltd, 2020, pp. 107402.

- [30] T. Guo, L. Wu, C. Wang, Z. Xu, Damage detection in a novel deep-learning framework: a robust method for feature extraction, *Structural Health Monitoring*, 2020, pp. 424-442.
- [31] O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Structural damage detection in real time: Implementation of 1D convolutional neural networks for SHM applications, *Conference Proceedings of the Society for Experimental Mechanics Series*, 2017, pp. 49-54.
- [32] O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, D.J. Inman, Wireless and real-time structural damage detection: A novel decentralized method for wireless sensor networks, *Journal of Sound and Vibration*, Elsevier Ltd, 2018, pp. 158-172.
- [33] O. Abdeljaber, O. Avci, M.S. Kiranyaz, B. Boashash, H. Sodano, D.J. Inman, 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data, *Neurocomputing*, Elsevier B.V., 2018, pp. 1308-1317.
- [34] O. Avci, O. Abdeljaber, S. Kiranyaz, D. Inman, Convolutional Neural Networks for Real-Time and Wireless Damage Detection, in, 2020, pp. 129-136.
- [35] O. Abdeljaber, A. Younis, O. Avci, N. Catbas, M. Gul, O. Celik, H. Zhang, Dynamic Testing of a Laboratory Stadium Structure, *Geotechnical and Structural Engineering Congress 2016*, American Society of Civil Engineers, Reston, VA, 2016, pp. 1719-1728.
- [36] X. Glorot, A. Bordes, Y. Bengio, Deep Sparse Rectifier Neural Networks, in, *JMLR Workshop and Conference Proceedings*, 2011, pp. 315-323.
- [37] V. Nair, G.E. Hinton, Rectified linear units improve Restricted Boltzmann machines, *ICML 2010 - Proceedings, 27th International Conference on Machine Learning*, 2010, pp. 807-814.
- [38] A. Krizhevsky, I. Sutskever, G.E. Hinton, ImageNet classification with deep convolutional neural networks, *Communications of the ACM*, 2017, pp. 84-90.
- [39] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, Dropout: A simple way to prevent neural networks from overfitting, *Journal of Machine Learning Research*, 2014, pp. 1929-1958.
- [40] B.Y. Goodfellow Ian, Courville Aaron, *Deep Learning - Ian Goodfellow, Yoshua Bengio, Aaron Courville - Google Books*, MIT Press, 2016, pp. 800.
- [41] D.P. Kingma, J.L. Ba, Adam: A method for stochastic optimization, *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, International Conference on Learning Representations, ICLR, 2015*.
- [42] R. Doroudi, S.H.H. Lavassani, M. Shahrouzi, Damage detection for long-span bridges through support vector machine, wavelet transform, and multivariate empirical mode decomposition, *Int. J. Struct. Eng.*, 14(2) (2024) 164-185.

Vibrational-based damage localization of bending frames using CNNs

ABSTRACT

The challenge of identifying damage-indicative features that are robust to noise in time-series data has long hindered the effectiveness of traditional machine learning-based structural damage detection methods. The time-consuming preprocessing procedures required by these methods also contributed to reduced accuracy and performance. However, the advent of deep learning has led to an increased exploration of the use of deep architectures in structural health monitoring. Despite these advancements, many deep learning approaches are resource-intensive and require significant data for training, making them less feasible for real-time applications. As a solution, we propose using 2-D convolutional neural networks (2-D CNNs) that integrate feature extraction and classification into a single entity. Our method employs a network of lighted CNNs instead of deep ones and utilizes raw acceleration signals as input, overcoming the limitations of previous approaches. Using lighted CNNs, in which everyone is optimized for a specific element, increases the accuracy and makes the network faster to perform. Also, a new framework is proposed for decreasing the data required in the training phase. We verified our method on Qatar University Grandstand Simulator (QUGS) benchmark data provided by Structural Dynamics Team. The results showed an improvement in accuracy over other methods, and the running time was adequate for real-time applications.

KEYWORDS

Structural Damage Detection, Machine Learning, Deep Learning, Structural Health Monitoring, Convolutional Neural Networks