

روش شناسایی آسیب با استفاده از شاخص‌های انرژی کرنشی و انعطاف‌پذیری مودال و شبکه عصبی عمیق در تیرهای فولادی

سارا زلفی^۱، آرمین عظیمی نژاد^{۲*}، حسین رحامی^۳، عبدالرضا سروقدمقدم^۴، میرحمید حسینی^۵

۱ دانشجوی دکتری مهندسی عمران - زلزله، دانشکده مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی

۲ استادیار، دانشکده مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی

۳ دانشیار، دانشکده فنی، دانشگاه تهران

۴ دانشیار، پژوهشگاه بین‌المللی زلزله‌شناسی و مهندسی زلزله

Email: arminaziminejad@srbiau.ac.ir

پذیرش: ۱۴۰۳/۰۵/۱۳

دریافت: ۱۴۰۲/۱۲/۰۷

چکیده

نظارت بر سلامت پل‌های بزرگراهی امری اساسی برای دستیابی به یک سیستم حمل و نقل قابل اعتماد است. روش شناسایی آسیب مبتنی بر ارتعاش از تغییرات ویژگی‌های ارتعاشی سازه‌ها برای شناسایی آسیب‌ها و اطمینان از وضعیت سلامت سازه‌ها استفاده می‌کند. در این مطالعه، از شاخص‌های آسیب اصلاح‌شده پارامترهای مودال مبتنی بر ترکیب مقدار مطلق انعطاف‌پذیری مودال و انرژی کرنش مودال به عنوان ورودی شبکه‌های عصبی عمیق کانولوشن استفاده شد تا تصمیمات ایمن و ارزیابی آسیب قابل اعتماد در تعیین آسیب‌های تکی در تیرهای فولادی پل‌های بزرگراهی فراهم شود. همچنین شبکه عصبی عمیق ادغام شده برای تخمین شدت آسیب تکی به طور هوشمندانه مورد استفاده قرار گرفت. شبکه عصبی با استفاده از شاخص‌های آسیب حاصل از شبیه‌سازی عددی مدل اعتبارسنجی شده پل آموزش داده شد. شاخص‌های آسیب به عنوان ورودی‌های شبکه عصبی از سناریوهای مختلف آسیب به دست آمد. شبکه عصبی آموزش دیده برای شناسایی، مکان‌یابی و اندازه‌گیری شدت آسیب‌های ناشناخته تکی استفاده شد. روش پیشنهادی پاسخی بر مشکلات شناسایی آسیب در تحقیقات گذشته می‌باشد. نتایج نشان داد که روش ارائه شده بر اساس شاخص‌های آسیب اصلاح شده مبتنی بر ترکیب مقدار مطلق و شبکه عصبی عمیق کانولوشن ادغام شده به صورت عملی و دقیق مکان و شدت آسیب‌های ناشناخته تکی را در تیرهای فلزی پل‌های چند دهانه بزرگراهی شناسایی می‌کند.

کلیدواژه‌ها: پایش سلامت سازه‌ها، شاخص انرژی کرنشی مودال، شاخص انعطاف‌پذیری مودال، تیر فلزی، شبکه عصبی عمیق

۱- مقدمه

بارگذاری و عدم نگهداری مناسب، روبرو می‌شوند. نظارت بر

این سازه‌ها، به ویژه در سازه‌های قدیمی، ضروری است تا زودتر آسیب‌ها را شناسایی کرده و اقدامات تقویتی مناسبی

سازه‌های عمرانی در طول عمر خود با آسیب‌های مختلفی مانند تغییرات محیطی، فرسودگی مصالح، تغییرات در

اجرا شود و به عملکرد ایمن و قابل اطمینان آنها بدون خطر شکستن غیرمنتظره ادامه دهیم. به همین دلیل، تحقیقات قابل توجهی در این زمینه انجام شده است که بر شناسایی آسیب در سازه‌های ساده و پیچیده تمرکز دارد.

تحقیقات نشان می‌دهند که روش‌های شناسایی آسیب مانند روش انعطاف‌پذیری مودال، روش انرژی کرنش مودال و مشتقات داده‌های مودال، به طور مؤثری می‌توانند آسیب را در سازه‌های پیچیده پیش‌بینی کنند. به عنوان نمونه، ونگ و همکاران [1] این روش‌ها را در سکوهایی دریایی، شی و همکاران در پل‌های خرابی [2] و در پل‌های دال روی شاهتیر [3] و ویکراماسینگ [4] به بررسی آسیب در پل‌های معلق پرداخته‌اند.

روش انعطاف‌پذیری مودال (MF)، ابتدا توسط پندی و بیسواس [5] معرفی شد و در مطالعات بسیاری در زمینه شناسایی آسیب به کار گرفته شده است. انتخاب شاخص انعطاف‌پذیری مودال به دقت و سادگی در به کارگیری، و فرآیند محاسباتی ساده‌اش بازمی‌شود [6]. روش‌های مبتنی بر انعطاف‌پذیری مودال در زمینه پایش سلامت سازه و شناسایی آسیب در کاربردهای مختلف با موفقیت به اثبات رسیده است [5, 7].

روش انرژی کرنشی مودال (MSE)، توسط استابس و همکاران [8] پیشنهاد شده است. از این روش در مطالعات متعدد با استفاده از داده‌های اندازه‌گیری شده مختلف برای انواع مختلف سازه‌ها استفاده شد [9]. با این حال، کاربرد این روش‌ها در شناسایی آسیب در پل‌های بزرگراهی با تیرهای فلزی در متون گذشته مورد بررسی قرار نگرفته است.

یادگیری ماشین به عنوان یک ابزار برای انتخاب ویژگی در ارزیابی شرایط سیستم‌های مکانیکی استفاده می‌شود. مزیت اصلی آن قابلیت آموزش از عدم قطعیت‌های گسترده و پیچیده داده‌ها است. شبکه‌های عصبی عمیق به ویژه در مدیریت داده‌های با حجم بالا که از آزمایش‌های تجربی بر روی سازه‌های بزرگ بدست می‌آیند، کاهش زمان آموزش را فراهم می‌کنند. گسترش جامع استفاده از شبکه‌های عصبی

عمیق در پایش سلامت سازه در کار عظیمی و همکاران [10] توضیح داده شده است.

کاربرد شاخص‌های آسیب مبتنی بر داده‌های ارتعاش با استفاده از شبکه‌های عصبی عمیق برای اندازه‌گیری آسیب، به ویژه در سازه‌های بزرگ محدود است. مطالعات موجود روی تشخیص و اندازه‌گیری آسیب در تیرها، قاب‌ها، مدل‌های ساختمان چند طبقه و مدل‌های پل با استفاده از داده‌های ارتعاش و شبکه عصبی تمرکز دارند. درودی و همکاران در سال ۲۰۲۲ مشخصات دینامیکی سازه‌های بلند را با استفاده از روش تجزیه مود تجزیه چند متغیره بدست آوردند [11]. همچنین در سال ۲۰۲۴ به بررسی پل با دهانه بزرگ پرداختند که در این تحقیق از ترکیب تجزیه مودی چند متغیره و تبدیل موجک در ادغام با شبکه‌های عصبی کانولوشن تک بعدی (1D-CNN)، LSTM^۲، MLP^۳ استفاده شد [12]. که از بین آنها شبکه کانولوشن تک بعدی (1D-CNN) بهترین نتیجه را بدست آورد. لواسانی و همکاران از الگوریتم درخت تصمیم در تعیین محدوده و محل آسیب در سال ۲۰۲۳ استفاده کردند [13]. این مطالعات معمولاً پارامترهایی مانند فرکانس و شکل مودی را به عنوان ورودی برای آموزش شبکه‌های عصبی استفاده می‌کنند. به طور کلی در برخی از روش‌های گذشته محدودیت‌هایی از جمله تعیین محدوده آسیب و عدم تعیین محل و شدت دقیق آسیب را دارد. همچنین در روش‌های قدیمی‌تر مبتنی بر شاخص انعطاف‌پذیری مودال یا انرژی کرنشی مودال، پاسخ‌های کاذب مثبت ارائه می‌دهند و یا قابلیت استفاده در موارد خاص آسیب را دارند.

این تحقیق یک رویکرد دو شاخصه را معرفی و به کار می‌برد که همزمان از شاخص‌های خسارت اصلاحی مشتق‌شده از روش‌های مبتنی بر MF و MSE استفاده می‌کند. هدف، ارائه نتایج بدون ابهام برای تشخیص و محلی‌سازی آسیب در اجزای اصلی سازه‌ای مانند تیرهای اصلی پل‌ها است. اثربخشی روش پیشنهادی، پیشی‌گرفتن از رویکردهای مرسوم، از طریق مقایسه نتایج مشهود است. استفاده همزمان

2 - Long short-term memory

3 - Multilayer perceptron

1 - Modal Strain Energy

$$MFDI = \frac{[\sum_{i=1}^m \frac{1}{\omega_i^2} \phi_i \phi_i^T]_d - [\sum_{i=1}^m \frac{1}{\omega_i^2} \phi_i \phi_i^T]_h}{[\sum_{i=1}^m \frac{1}{\omega_i^2} \phi_i \phi_i^T]_h} \quad (2)$$

۲-۲- شاخص آسیب مبتنی بر انرژی کرنش مودال

کیم و استابز [8] ابتدا این روش را به نام شاخص آسیب انرژی کرنش مودال (MSEDI) ابداع کردند. انرژی کرنشی مودال تغییرات انرژی کرنش در تیرهای تغییر شکل یافته، را محاسبه می‌کند و به طور خاص بر روی شکل‌های مودی تمرکز دارد. این تغییرات به عنوان یک شاخص آسیب استفاده شده‌اند.

این شاخص آسیب بر اساس اختلاف بین مدهای سالم و آسیب‌دیده سازه از نظر انرژی کرنش مودال استوار است. شاخص آسیب برای مود i ام‌المان i ام با استفاده از معادله (۳) بیان می‌شود.

$$DI_{ij} = \frac{(\int_j [\phi_i^*(x)]^2 dx + \int_0^L [\phi_i^*(x)]^2 dx) \int_0^L [\phi_i(x)]^2 dx}{(\int_j [\phi_i(x)]^2 dx + \int_0^L [\phi_i(x)]^2 dx) \int_0^L [\phi_i^*(x)]^2 dx} \quad (3)$$

که ϕ_i^* نمایانگر خمش شکل مودی خمشی است و ستاره وضعیت آسیب‌دیده را نشان می‌دهد. برای مشارکت تمام شکل‌های مودی خمشی در پل‌های بزرگراهی، پیشنهاد این است که شاخص آسیب به صورت جداگانه برای هر مود خمشی با استفاده از معادله (۲) و (۳) محاسبه شود. سپس این شاخص‌ها با استفاده از روش ترکیب مقدار مطلق (AV) ترکیب شوند. روش ترکیب مقدار مطلق به علت دقت و محاسبات ساده‌اش، از بین روش‌های ترکیب دیگر ترجیح داده می‌شود. شاخص‌های آسیب ترکیب شده نرمال‌سازی شده، با استفاده از روش ترکیب مقدار مطلق با معادله (۴) بیان می‌شود.

$$DI_{AV} = \frac{\sum_{i=1}^n |DI_i|}{N} \quad (4)$$

در این مطالعه، DI نمایانگر شاخص آسیب است و N تعداد شاخص‌های آسیب محاسبه شده برای هر شاخص آسیب مبتنی بر ارتعاش است.

از دو شاخص به نتایج به دست آمده از هر شاخص اجازه می‌دهد تا نتایج حاصل از دیگری را تقویت و پشتیبانی کند، که منجر به پیش بینی قابل اعتمادتر محل آسیب می‌شود. این مقاله با ترکیب شاخص‌های اصلاحی ذکر شده و چگونگی خاصی از آموزش شبکه عصبی عمیق با هدف هوشمند سازی، شناسایی، مکان یابی و کمی سازی آسیب در تیرهای اصلی پل‌های بزرگراهی، روش شناسایی آسیب را بهبود می‌بخشد. امکان‌پذیری روش پیشنهادی از طریق کاربرد موفق آن در سناریوهای تکی مختلف تشخیص آسیب نشان داده شده است. آموزش شبکه عصبی با داده‌های واقعی چالش برانگیز است بنابراین آموزش با استفاده از شاخص‌های اصلاحی به دست آمده از شبیه‌سازی‌های عددی انجام شد. شاخص‌های آسیب اصلاحی به دست آمده از شبیه‌سازی‌های عددی سناریوهای آسیب مختلف به عنوان ورودی شبکه استفاده شد. روش پیشنهادی روی تیرهای اصلی پل I-40 برای سناریوهای مختلف آسیب تکی مورد بررسی قرار گرفت و در مقایسه با شاخص‌های قدیمی نتایج دقیق و قابل اعتماد شاخص‌های آسیب دوگانه را در ارتباط با شبکه‌های عصبی عمیق نشان می‌دهد.

۲- ابزار و روش

۲-۱- روش انعطاف پذیری مودال

این روش فرکانس طبیعی و شکل مودی سازه را با هم ترکیب می‌کند. انعطاف‌پذیری مودال (F) یک سازه خطی را می‌توان با استفاده از معادله (۱) بیان کرد:

$$F = [\sum_{i=1}^m \frac{1}{\omega_i^2} \phi_i \phi_i^T] \quad (1)$$

در این رابطه، i شماره مود، m تعداد کل مدهای در نظر گرفته شده و ω_i فرکانس طبیعی را نشان می‌دهد. به علاوه، ϕ_i و ϕ_i^T به ترتیب بردار شکل مود i ام و ترانسپوز آن را نشان می‌دهند. (14).

معادله (۲) شاخص آسیب را که با توجه به تغییر در انعطاف‌پذیری مودال نرمال شده تعریف می‌کند.

۳-۲- شبکه عصبی عمیق کانولوشن

شبکه عصبی عمیق کانولوشن یک مدل یادگیری عمیق است. معماری متداول شبکه‌های عصبی کانولوشن که در شکل (۱) توضیح داده شده است، شامل لایه‌های ابتدایی کانولوشنال و پولینگ برای استخراج ویژگی‌ها، به دنبال آن لایه‌های کاملاً متصل شبیه لایه مخفی یک شبکه عصبی چندلایه‌ای (MLP) قرار دارد. طبقه‌بندکننده‌ها با یک لایه سافت مکس به پایان می‌رسند. لایه کانولوشن شامل فیلتر کردن لایه ورودی با استفاده از وزن‌های مختلف، بایاس و تابع فعال‌سازی است، که به صورت معادله (۵) بیان می‌شود.

$$C_{cn} = f(X * W_{cn} + b_{cn}) \quad (5)$$

در این معادله، C_{cn} ویژگی cn ام را نشان می‌دهد، و * نشان دهنده عملگر لایه کانولوشن است که روی ماتریس داده ورودی X اعمال می‌شود. بایاس برای ویژگی cn ام با b_{cn} نشان داده شده است، و تابع فعال‌سازی، به طور متداول ReLU، سیگموئید یا تانژانت هایپربولیک است، که توسط f نمایان داده می‌شود. ReLU در طبقه بندها عملکرد خوبی از خود نشان داده است [15].




Fig. 2. The cross section of the I-40 Bridge. (Adapted from Farrar et al (7, 16)).

شکل ۳. نمای ارتفاعی از بخش مورد بررسی پل I-40 (برگرفته شده از (7, 16)).




Fig. 3. Elevation view of the examined segment of the I-40 Bridge. (Adapted from Farrar et al. (7,16)).




Fig. 1. The typical CNN architecture

۳- کاربرد

۳-۱- پل I-40

۳-۲- اعتبارسنجی مدل‌سازی المان محدود پل I-40
یک مدل المان محدود به اندازه واقعی پل بزرگراهی I-40 با استفاده از نرم‌افزار کامپیوتری [18] اجزا محدود آباکوس ساخته شد که در شکل (۴) نشان داده شده است. مدل‌سازی از عناصر پوسته سه بعدی برای بخش‌هایی مانند تیرها، تیرهای کف و استرینگرها از المان شبکه‌ای چهارگوش منحنی نازک یا ضخیم با کاهش یکپارچه استفاده شد. ویژگیهای عمومی مواد برای فولاد و بتن به شرح زیر مشخص شدند.

عملکرد روش پیشنهادی در شناسایی آسیب‌های سازه با استفاده از یک پل با تیر فولادی ارزیابی شد. این پل شامل سه دهانه بود و دارای ترکیبی از یک دال بتنی، دو تیر فولادی، سه استرینگر و تیرهای فولادی بود. هندسه مقطع عرضی پل و نمای ارتفاعی بخش آزمایش شده از پل در اشکال (۲ و ۳) نشان داده شده است.

مدلی که بهترین هماهنگی را با نتایج اندازه‌گیری شده، با در نظر گرفتن فرکانس‌های طبیعی و شکل مودی، نشان داد،




Fig. 5. The first three bending modes of the FE model of I-40 bridge

شکل ۴. مدل المان محدود پل I-40




Fig. 4. The finite element model of the I-40 bridge.

جدول ۱. مقایسه بین فرکانس‌های طبیعی

Mode	Natural frequency of intact bridge	Natural frequency of FE model	Average difference%
1st	2.48	2.73	5.54
2nd	2.96	2.96	
3rd	3.5	3.56	
4th	4.08	3.63	
5th	4.17	4.083	
6th	4.63	4.24	

Table. 1. Comparison between resonance frequencies

استخراج شده از مدل اجزاء محدود (که در بخش ۲-۳ توضیح داده شده است) اعتبارسنجی شده است.

در دهانه اول و سوم هر کدام نه بخش با عرض ۳۰ میلی‌متر به عنوان موقعیت‌هایی که امکان آسیب در تیر وجود دارد، در نظر گرفته شد. در دهانه میانی، دوازده قسمت دیگر با عرض ۳۰ میلی‌متر به عنوان موقعیت‌های آسیب در نظر گرفته شد.

در این مطالعه پیشنهاد شده است که تنها از سه شکل مودی خمشی اول مدل المان محدود پل‌های سالم و آسیب‌دیده استفاده شود. شاخص‌های آسیب از دو روش مبتنی بر ارتعاش به صورت مستقل با استفاده از داده‌های مودال استخراج شده محاسبه می‌شود. در این مطالعه آسیب در اعضاء سازه با کاهش مدول الاستیسیته شبیه‌سازی شده است. برای محدود کردن محاسبات عددی، سه مورد آسیب متفاوت که دارای درجات مختلف کاهش مدول الاستیسیته است، به صورت خلاصه در جدول (۲) ذکر شده است. امکان تعریف موارد آسیب فراتر از این شدت کاهش سختی وجود دارد، اما مقادیر بیشتر آسیب منجر به افزایش تغییر شکل سازه می‌شود

$$E_{\text{بتن}} = 200 \text{ Gpa } (29000000 \text{ psi}), \quad \nu_{\text{بتن}} = 0.2,$$

$$\mu_{\text{بتن}} = 2320 \text{ Kg m}^{-3} (145 \text{ lbm ft}^{-3})$$

$$E_{\text{فولاد}} = 248 \text{ Gpa } (3600000 \text{ psi}), \quad \nu_{\text{فولاد}} = 0.3$$

$$\mu_{\text{فولاد}} = 38.2 \text{ g cm}^{-3} (0.248 \text{ lbmin}^{-3})$$

برای اعتبارسنجی مدل المان محدود، مقایسه‌ای بین فرکانس‌های طبیعی به دست آمده از آزمایشات تجربی روی پل واقعی و آنچه که توسط تحلیل المان محدود محاسبه شده بود، انجام شد که در جدول (۱) نشان داده شده است. تفاوت میانگین بین دو مجموعه فرکانس حدود ۵.۵۴٪ است که نشانگر همبستگی قابل اعتماد نتایج می‌باشد. شکل (۵) سه شکل مودی اول خمشی پل به دست آمده از مدل المان محدود از طریق تحلیل فرکانسی را نشان می‌دهد.

۳-۳- فرآیند شناسایی آسیب

برای ارزیابی عملکرد روش‌های شناسایی آسیب مبتنی بر ارتعاش پیشنهاد شده، چندین مورد آسیب تکی به یک مدل اجزاء محدود پل I-40 اعمال شد. مدل اجزاء محدود پل از طریق مقایسه فرکانس‌های طبیعی پل سالم و فرکانس‌های

طولی پل که از تجزیه و تحلیل فرکانسی مدل المان محدود شک ل (۵) به دست آمده است، در محاسبه استفاده شده است.

جدول ۲. سناریوهای آسیب تکی مورد بررسی

Damage Case	Damage location	Stiffness reduction
1	Damage at 101.9 m of G1	10%
2	Damage at 4.5 m of G1	20%
3	Damage at 87.8 m of G1	10%

Table. 2.

با توجه به چالش‌های موجود در به دست آوردن اشکال مودی بالاتر در آزمایش‌های تجربی یا آزمایش‌های مقیاس کامل، پیشنهاد شده است که شاخص‌های آسیب بر اساس فقط سه مود اول خمشی طولی پل محاسبه شود. برای مورد آسیب اول، شاخص‌های آسیب مبتنی بر انرژی کرنشی مودال و انعطاف پذیری مودال با استفاده از سه شکل مودی خمشی اول محاسبه شدند. با این حال، تعیین مکان دقیق آسیب با استفاده از اشکال مودی تکی چالش‌برانگیز است. برای حل این مسئله و بهره‌مندی از تمام اشکال مودی خمشی، پیشنهاد می‌شود که شاخص‌های آسیب با استفاده از روش مقادیر قدر مطلق (AV) ترکیب شوند. شکل (۶)، سناریو آسیب تکی اول واقع در وسط دهانه سوم تیر اصلی پل را نشان می‌دهد. نمودار شاخص مبتنی بر انرژی کرنش مودال مقدار ماکزیمم و نمودار مبتنی بر انعطاف پذیری مودال تغییر شیب ناگهانی در محل آسیب از خود نشان می‌دهند. نتایج هر یک از نمودارها یکدیگر را پشتیبانی و تأیید می‌کند. همانطور که در شکل (۷) نشان داده شده است روش پیشنهادی توانایی تشخیص دقیق محل آسیب در نزدیکی تکیه گاه‌ها را دارد. در سناریو دوم، آسیب در فاصله ۴.۵ متری از تکیه گاه قرار دارد و هر دو شاخص اصلاحی معرفی شده محل آسیب را با دقت بالا و به طور صحیح مشخص کردند. از سناریو سوم آسیب که در شکل (۸-a) نشان داده شده است که شاخص آسیب مبتنی بر انرژی کرنشی مودال می‌تواند در همسایگی خود و در طول

که می‌توان از طریق بازرسی های چشمی تشخیص داد. مطالعات عددی در بخش ۱-۴، جزئیات بیشتری را نشان می‌دهد و عملکرد شاخص‌های آسیب پیشنهادی را ارزیابی می‌کند. برآورد شدت آسیب با استفاده از شبکه عصبی عمیق نیازمند تعداد قابل توجهی داده برای آموزش مناسب شبکه است. در این تحقیق، برای آموزش شبکه عصبی عمیق شاخص‌های آسیب به عنوان پارامترهای ورودی در نظر گرفته شده است. به منظور جمع‌آوری تعداد مناسبی از داده‌های آموزش برای آموزش شبکه عصبی عمیق، روش زیر پیشنهاد می‌شود. شاخص آسیب برای مقادیر مختلف شدت آسیب (۱۰٪ تا ۲۵٪) بر روی تمام مکان‌های آسیب محاسبه شد. برای کاهش حجم محاسبات، شاخص آسیب برای چهار سطح اصلی شدت آسیب (۱۰٪، ۱۵٪، ۲۰٪ و ۲۵٪) محاسبه شد. برای سایر مقادیر میانی آسیب، شاخص آسیب با استفاده از روش تقسیم داده با تابع اسپلاین مکعبی درون‌یابی شد. شاخص‌های آسیب محاسبه شده به عنوان پارامترهای ورودی برای آموزش شبکه عصبی عمیق به کار گرفته شد. هنگامی که شبکه عصبی عمیق به طور مناسب آموزش دید، شاخص آسیب می‌تواند به شبکه عصبی عمیق آموزش دیده وارد شود تا شدت آسیب متناظر به طور دقیق پیش‌بینی شود. علاوه بر این، نتایج تحقیقات شدت آسیب پیشنهاد شده در بخش ۲-۴ به طور کامل توضیح داده شده است.

۴- نتایج

۴-۱- ارزیابی مکان آسیب

کارایی روش تشخیص آسیب مبتنی بر ارتعاش جهت یافتن مکان آسیب توسط سناریوهای مختلف آسیب بر روی مدل المان محدود پل I-40 مورد بررسی قرار گرفت. جدول (۲) سه سناریو آسیب تکی را که در این مطالعه مورد بررسی قرار گرفته است، نشان داده است. در فرآیند تشخیص آسیب، محاسبه شاخص‌های آسیب روش‌های پیشنهادی امری ضروری است. شاخص‌های آسیب مبتنی بر انرژی کرنشی و انعطاف پذیری مودال نسبت به سختی خمشی حساس هستند، که بدین منظور استفاده می‌شوند. سه مود اول خمشی

نشان می‌دهد. با توجه به این نمودارها، مشخص است که مقدار بیشینه شاخص آسیب MSEDI و تغییر شیب ناگهانی شاخص MFDI مکان آسیب را به صورت دقیق و بدون ابهام نشان می‌دهد. در عین حال، قابلیت و دقت روش پیشنهادی تشخیص آسیب با اعمال همزمان شاخص‌های آسیب افزایش خواهد یافت.

۸۸.۸ متری پیک کاذبی نشان دهد که با استفاده از ترکیب این دو شاخص می‌توان محل آسیب را به طور دقیق مشخص کرد. همانطور که در شکل (۸-ب) نشان داده می‌شود محل آسیب فقط در طول ۸۷.۸ متری از تکیه گاه وجود دارد. به طور کلی اشکال (۶) الی (۸) نمودارهای شاخص‌های آسیب ترکیبی با استفاده از روش AV هر سه مورد آسیب را با دقت

شکل ۶. شاخص‌های اصلاحی مبتنی بر MSE و MF برای سناریو آسیب تکی اول




Fig. 6. The modified damage index based on MSE and MF for the first single damage scenario.

شکل ۷. شاخص‌های اصلاحی مبتنی بر MSE و MF برای سناریو آسیب تکی دوم




Fig. 7. The modified damage index based on MSE and MF for the second single damage scenario.

شکل ۸: شاخص‌های اصلاحی مبتنی بر MSE و MF برای سناریو آسیب تکی سوم




Fig. 8. The modified damage index based on MSE and MF for the third single damage scenario.

۲-۴- تعیین شدت آسیب

این مقاله به بررسی تعیین شدت آسیب در تیر فولادی پل‌های بزرگراهی می‌پردازد. همچنین عملکرد شاخص‌های آسیب اصلاح‌شده در مکان‌ها و شدت‌های مختلف آسیب در تیر پل‌های بزرگراهی ارزیابی می‌شود. برای تعیین شدت‌های نامعلوم، یک شبکه عصبی کانولوشن آموزش داده شده است تا مکان و شدت آسیب را به صورت دقیق پیش‌بینی کند. شاخص‌های آسیب اصلاح‌شده به عنوان داده‌های ورودی استفاده می‌شوند، که اطلاعات فشرده و حساس درباره الگوهای تغییرات آسیب را ارائه می‌دهند. رویکرد فیوژن^۴ (ادغام) شبکه برای افزایش قابلیت اعتماد پیشنهاد شده است، که نتایج دو شبکه عصبی جداگانه را ترکیب کرده و نتایج دقیق‌تر در موارد آسیب نامعلوم فراهم می‌کند. شبکه فیوژن برای دستیابی به نتایج قطعی برای آسیب‌های نامعلوم آموزش داده شد و مورد آزمایش قرار گرفت.

در این مقاله، شبکه‌های عصبی کانولوشن برای تعیین شدت آسیب و بازیابی مجدد مکان آسیب با استفاده از داده‌های یک مدل المان محدود توسعه یافت. داده‌های ورودی شامل شاخص‌های آسیب بدست آمده از سناریوهای مختلف آسیب بود. هر تیر پل به شش بخش تقسیم شد، که شامل ۲۳ مورد آسیب در امتداد تیرها می‌باشد، و در هر مورد چهار سطح شدت آسیب مختلف (۱۰٪، ۱۵٪، ۲۰٪، ۲۵٪) در نظر گرفته شده است. شاخص‌های آسیب دیگر با استفاده از روش اسپیلاین مکعبی به داده‌ها اضافه شده و دقت آموزش شبکه را افزایش می‌دهد. شش بخش تیر پل I-40 در شکل (۹) نشان داده شده است.

شبکه دارای تعداد گره‌های ورودی و خروجی متناسب با متغیرهای موجود در مجموعه داده است. گره‌های ورودی به تعداد ۲۳ عدد تنظیم شدند که با شاخص آسیب اصلاح شده مبتنی بر انرژی کرنشی و انعطاف پذیری مودال اصلاح شده در امتداد تیر هماهنگی داشته باشد. تعداد لایه‌های مخفی در پیکربندی شبکه از طریق آزمون و خطا تعیین شد تا خطای میانگین مربعات را کمینه کند، و همچنین نیاز به سعی و

خطای بیشتر برای تعیین پیکربندی نهایی به منظور دستیابی به همگرایی بهینه وجود دارد. این شبکه دارای شش گره خروجی می‌باشد که با شش بخش مختلف پل متناظر است، که فرآیند آموزش را ساده‌تر می‌کند. زیرشبکه‌های ویژه ابتدایی برای هر بخش آموزش داده شدند تا مقدار زیاد داده‌ها را مدیریت کنند. پس از شناسایی کلاس هر سناریوی آسیب، دو شبکه عصبی همگرایی پیشرو با استفاده از رگرسیون آموزش داده شدند تا مکان و شدت دقیق آسیب در تیر تعیین شود. شبکه اصلی و زیرکدها به صورت مداوم ساختارهای زیرمجموعه مرتبط را برای پردازش انتخاب می‌کند تا خروجی نهایی به دست آید.

فضای داده ورودی به داده‌های آموزش (۷۰٪)، داده‌های اعتبارسنجی (۱۵٪) و داده‌های آزمون (۱۵٪) تقسیم شد. تابع (ReLU) به عنوان تابع فعال‌ساز استفاده شد. پس از اتمام فرآیند آموزش، آسیب‌های ناشناخته به شبکه وارد شدند تا مکان و شدت آن‌ها تعیین شود. شبکه اصلی منطقه آسیب را تشخیص داد و زیرشبکه‌های فرعی مکان دقیق و شدت را مشخص کردند.

شکل ۹. تقسیم بندی پل I-40




Fig. 9. The segmentations of the I-40 bridge

۳-۴- طراحی شبکه

تنظیمات هر شبکه، از جمله شبکه اصلی و زیرشبکه‌های فرعی، توسط پارامترهای کلیدی مانند تعداد گره‌های داده‌های ورودی، اندازه داده‌های تقسیم‌بندی شده و الگوریتم بهینه‌سازی تعیین می‌شود. جدول‌های (۳ الی ۵) لایه‌های هر شبکه را نشان می‌دهد. دقت شناسایی زیرسازه آسیب‌دیده در شکل (۱۰) از طریق استفاده از این شبکه‌های طبقه‌بند نشان داده شده است. شبکه اصلی با دقت بیش از ۹۸٪ در تشخیص آسیب، عملکرد برتری از خود نشان می‌دهد. با تکمیل

دو لایه پنهان کاملاً متصل، یک تابع فعال‌سازی (ReLU) و یک لایه خروجی کاملاً متصل با یک لایه رگرسیون هستند.

آموزش شش زیرشبکه طبقه‌بند، دو شبکه عصبی عمیق جداگانه برای اندازه‌گیری محل دقیق و شدت آسیب در هر زیرشبکه استفاده می‌شود. این شبکه‌ها دارای یک لایه ورودی،

جدول ۳. لایه‌های سیستم شبکه عصبی مبتنی بر MSEDI

Classification network	Main network	featureInputLayer(23)+FL*(50)+FL(10)+reluLayer+FL(6)+softmaxLayer+classificationLayer
Regression networks	Secondary sub-network for Location	featureInputLayer(23)+FL(30)+FL(10)+reluLayer+FL(1)+regressionLayer
	Secondary sub-network for intensity	featureInputLayer(23)+FL(20)+FL(10)+reluLayer+FL(1)+regressionLayer

FL*: Fully Connected Layer

Table 3. Layers of MSEDI neural network system

جدول ۴. لایه‌های سیستم شبکه عصبی مبتنی بر MFDI

Classification network	Main network	featureInputLayer(23)+FL*(50)+FL(10)+reluLayer+FL(6)+softmaxLayer+classificationLayer
Regression networks	Secondary sub-network for Location	featureInputLayer(23)+FL(40)+FL(10)+reluLayer+FL(1)+regressionLayer
	Secondary sub-network for intensity	featureInputLayer(23)+FL(20)+FL(10)+reluLayer+FL(1)+regressionLayer

Table 4. Layers of MFDI neural network system

جدول ۵. لایه‌های سیستم شبکه عصبی فیوژن

Fusion network of damage location	featureInputLayer (2) + FL(5)+ reluLayer+FL (1) + regressionLayer
Fusion network of damage intensity	featureInputLayer (2) + FL(7)+ reluLayer+FL (1) + regressionLayer

Table 5. Layers of fusion neural network system

شکل ۱۰. ماتریس کانفیوژن داده‌های آموزش و تست شاخص آسیب مبتنی بر انرژی کرنشی مودال



Fig. 10. The training and test confusion matrix of MSE damage index.

شکل ۱۱. نمودار رگرسیون شبکه عصبی ثانویه تعیین شدت آسیب در زیر کلاس S2




Fig. 11. The regression plots of secondary sub-network for severity

جدول (۶) نتایج مورد انتظار و پیش‌بینی شده برای موارد درستی آزمایی را نشان می‌دهد و مشخص است که شبکه عصبی عمیق کانولوشن با خطا کمتر از ۱٪ مکان و شدت آسیب را پیش‌بینی می‌کند. این نتایج عملکرد دقیق شبکه عصبی عمیق کانولوشن را در تشخیص، تعیین مکان و اندازه‌گیری آسیب تأیید می‌کند.

۵-۴- گام‌های الگوریتم پیشنهادی

- ۱- استخراج پارامترهای مودال برای محاسبه شاخص‌های آسیب دوگانه اصلاحی مبتنی بر انرژی کرنشی (MSE) و انعطاف پذیری (MF).
- ایجاد مدل المان محدود پل سالم با استفاده از روش شناسایی سیستم.
- استخراج سیگنال‌های ارتعاشی از سازه واقعی آسیب دیده و مدل اجزا محدود سازه سالم (هنگامی که به طور مداوم تحت پایش سلامت قرار داشته باشد، سیگنال‌های ارتعاشی می‌توانند از سازه واقعی سالم و آسیب دیده بدست آید).
- تعداد کافی شکل مودی خمشی را از سیگنال ارتعاشی پل آسیب دیده واقعی و مدل المان محدود پل سالم استخراج شود تا اطمینان حاصل شود که ارتعاشات آنها کل طول تیر اصلی پل را پوشش می‌دهد.
- محاسبه شاخص‌های اصلاح شده بر اساس معادله (۴) با استفاده از اشکال مودی خمشی استخراج شده در امتداد تیر اصلی که از مرحله قبل بدست آمده‌اند.

شکل (۱۱) نمودارهای رگرسیون برای زیر شبکه‌های شدت آسیب در زیرکلاس S2 را نشان می‌دهند. در این شکل همگرایی کامل و یک شبکه آموزش دیده خوب با مقادیر R بالای ۰.۹۹ کاملاً مشهود است. هنگامی که سیستم شبکه مبتنی بر شاخص‌های دوگانه به طور کامل آموزش دیده می‌شود، ماتریس فیوژن می‌تواند به طور مؤثر سناریوهای آسیب ناشناخته را تست کند و موقعیت و شدت آسیب را به صورت دقیق توسط هر یک از شبکه‌ها تعیین کند.

۴-۴- درستی آزمایی روش پیشنهادی

برای ارزیابی کارایی شبکه عصبی عمیق کانولوشن آموزش دیده در تعیین دقیق مکان و شدت آسیب، سه سناریو تصادفی آسیب تکی به تیرهای اصلی مدل عددی پل I-40 اعمال شد. پارامترهای مودال قبل و بعد از آسیب استخراج شدند و شاخص‌های آسیب اصلاح شده مبتنی بر مقادیر مطلق انعطاف پذیری و انحنای مودال محاسبه شدند. این شاخص‌ها به عنوان ورودی برای شبکه عصبی عمیق کانولوشن آموزش دیده، برای پیش‌بینی هر یک از سناریوهای آسیب استفاده شد. شبکه طبقه‌بند اصلی کلاس محل آسیب را شناسایی کرد و سپس به زیر شبکه‌های مرتبط به خود اختصاص یافت و زیرکلاس‌ها تعیین شد. سپس، شبکه‌های عمیق رگرسیون مرتبط با زیرکلاس‌ها، مکان و شدت آسیب را پیش‌بینی کردند.

- به کارگیری هر دو شاخص آسیب اصلاح شده به طور جداگانه به عنوان داده ورودی و همچنین مکان و شدت را به عنوان داده‌های خروجی برای آموزش شبکه عصبی عمیق در نظر گرفته شود.
- دو نمودار جداگانه بر اساس تغییر مقادیر شاخص آسیب اصلاح شده دو گانه در امتداد تیر در مکان‌های مختلف آسیب انتخاب شده با شدت آسیب ثابت رسم شود.
- تیر اصلی پل را بر اساس رفتار مشابه مشاهده شده در دو نمودار به دست آمده از مرحله قبل به تعداد قطعات مناسب تقسیم شود.
- سیستم شبکه عصبی عمیق شامل یک زیرشبکه طبقه‌بندی کننده است. همچنین از دو زیرشبکه رگرسیون تشکیل شده است که با نام‌های زیرشبکه موقعیت مکانی و زیرشبکه شدت شناخته می‌شوند.
- فضای داده ورودی شبکه های عصبی عمیق را به سه مجموعه: ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمایش تقسیم شود.
- برای پردازش خودکار داده‌ها و انتخاب زیرشبکه مربوطه، تمامی کدهای فرعی در برنامه اصلی فراخوانی شود.
- از زیر شبکه فرعی رگرسیونر موقعیت مکانی و شدت برای تعیین مکان دقیق و شدت آسیب به ترتیب در هر زیر کلاس استفاده شود.
- پاسخ‌های زیر شبکه هر شاخص اصلاحی به طور جداگانه با یکدیگر ادغام شود تا محل و شدت دقیق آسیب به دست آید.

۲- تعیین محل دقیق و بدون ابهام آسیب

- نتایج هر دو شاخص اصلاح شده در امتداد تیرها ترسیم شود تا مکان‌های دقیق و بدون ابهام آسیب به دست آید.
- محل آسیب را با شناسایی مقدار پیک جداگانه شاخص مبتنی بر انرژی کرنشی و تغییرات ناگهانی در شیب شاخص انعطاف پذیری مودال مشخص شود.
- ۳- شبکه عصبی عمیق آموزش دیده را برای تعیین خودکار و سریع محل و شدت آسیب استفاده شود.
- نقاط آسیب برای آموزش شبکه به طور مناسب روی تیر پل انتخاب شود.
- سناریوهای آسیب را با شدت‌های مختلف بر اساس سطوح آسیب به دست آمده از بازرسی بصری (کاهش سختی کم، متوسط، شدید) در تمام نقاط آسیب انتخاب شده با استفاده از مدل المان محدود شبیه سازی شود. این شبیه‌سازی را می‌توان با استفاده از نرم‌افزار متلب یا یک برنامه کامپیوتری مناسب انجام داد.
- تعداد کافی سناریوهای مختلف آسیب تکی ایجاد شود تا زمانی که نتایج داده‌های آزمون طبقه بند بالاتر از ۹۹٪ باشد و مقادیر R داده‌های آزمون رگرسیون به عدد یک نزدیک شود.
- تعداد کافی شکل مودی خمشی از مرحله قبل در تمام سناریوهای آسیب شبیه‌سازی شده استخراج شود.
- محاسبه شاخص‌های خسارت اصلاح شده بر اساس معادله (۴).
- پیش پردازش و نرمالسازی روی هر دو شاخص اعمال شود.

جدول ۶. نتایج شبکه عصبی عمیق کانولوشن برای سناریوهای آسیب تصادفی

Damage case	Expected result		Neural network outcome		The percentage error of intensity
	Location (m)	intensity (%)	Location (m)	(%) intensity	
1	8	6.5	8	6	-%0.5
2	114	12	114	12.02	+%0.02
3	56.5	15	56.5	14.96	-%0.04

Table 6. Results of deep convolutional neural network for random damage scenarios

۵- نتیجه گیری

ورودی می‌پذیرد که به تشخیص دقیق و بدون ابهام آسیب در تیرهای فولادی پل‌های بزرگراهی کمک می‌کند.

۶- سپاسگذاری

این پژوهش هیچ کمک‌هزینه خاصی از هیچ مؤسسه سرمایه‌گذار در بخش عمومی، تجاری یا غیرانتفاعی دریافت نکرده است.

۷- تعارض منافع

نویسندگان اعلام می‌کنند که هیچ نوع تعارض منافع وجود ندارد.

منابع

1. Wang FL, Chan TH, Thambiratnam DP, Tan AC, Cowled CJ. Correlation-based damage detection for complicated truss bridges using multi-layer genetic algorithm. *Advances in Structural engineering*. 2012;15(5):693-706.
2. Shih W, Thambiratnam D, Chan T. Damage detection in truss bridges using vibration based multi-criteria approach. *Structural Engineering and Mechanics*. 2011;39(2):187-206.
3. Shih HW, Thambiratnam D, Chan T. Damage detection in slab-on-girder bridges using vibration characteristics. *Structural Control and Health Monitoring*. 2013;20(10):1271-90.
4. Wickramasinghe WR, Thambiratnam DP, Chan TH, Nguyen T. Vibration characteristics and damage detection in a suspension bridge. *Journal of Sound and Vibration*. 2016;74-375:254;
5. Pandey A, Biswas M. Experimental verification of flexibility difference method for locating damage in structures. *Journal of sound and vibration*. 1995;184(2):311-28.
6. Moragaspitiya HP, Thambiratnam DP, Perera NJ, Chan TH. Development of a vibration based method to update axial shortening of vertical load bearing elements in reinforced concrete buildings. *Engineering Structures*. 2013;46:49-61.
7. Farrar CR, Jauregui DA. Comparative study of damage identification algorithms applied to a bridge: II. Numerical study. *Smart materials and structures*. 1998;7(5):720.
8. Stubbs N, Kim J-T, Farrar C, editors. Field verification of a nondestructive damage localization and severity estimation algorithm. *Proceedings-SPIE the international society for optical engineering*; 1995: SPIE International Society for Optical.

این مطالعه یک روش نوآورانه با استفاده از ترکیب مقدار مطلق شاخص دو معیاره و یک شبکه عصبی عمیق برای تشخیص، تعیین مکان و اندازه‌گیری شدت آسیب‌های تکی در تیرهای پل‌های بزرگراهی ارائه می‌دهد. اثربخشی این روش بر تیرهای مدل المان محدود پل I-40 به عنوان نمونه موردی نشان داده شده است که در آن سناریوهای مختلف آسیب تکی بر تیرهای فولادی پل مورد بررسی قرار گرفته است.

این روش از شاخص‌های اصلاح شده مبتنی بر انرژی کرنشی مودال و انعطاف پذیری مودال و سه مود اول خمشی استفاده می‌کند. با استفاده از این شاخص‌ها روش به طور هوشمند مکان‌های آسیب ناشناخته، را بدون نیاز به آموزش گسترده بر روی داده‌های واقعی با استفاده از مدل المان محدود پل، پیش‌بینی می‌کند. دو معماری متفاوت شبکه عصبی عمیق کانولوشن، براساس ترکیب مقدار مطلق شاخص‌های آسیب مبتنی بر انعطاف پذیری مودال و انحنای مودال، استفاده شده و نتایج آن‌ها برای افزایش دقت در شبکه عصبی کانولوشن ادغام شد.

بر خلاف یافته‌های تحقیقات گذشته در مورد روش‌های مبتنی بر ارتعاش که در سازه‌های با ساختار پیچیده غیرقابل اعتماد تلقی شده بودند، روش پیشنهادی عملکرد برتر در تشخیص، تعیین مکان و اندازه‌گیری آسیب تکی دارد. در حقیقت در روش پیشنهادی محل آسیب به طور ۱۰۰٪ دقیق و شدت آسیب با خطایی کمتر از ۰.۵ درصد شناسایی شده است. استفاده همزمان از ترکیب مقدار مطلق هر دو شاخص پیشنهادی کارآمدی روش را افزایش می‌دهد، و از نشانه‌های نادرست، و تصمیمات ناایمن جلوگیری می‌کند و منجر به پیش‌بینی‌های آسیب قابل اعتمادتر می‌شود.

علاوه بر این، شبکه عصبی کانولوشن همراه با ترکیب مقدار مطلق دو شاخص آسیب اصلاحی پیشنهاد شده نتایج قابل اعتماد و قطعی در تشخیص آسیب‌های تکی فراهم می‌کند. شبکه ترکیبی از شاخص‌های آسیب پیش‌پردازش شده مبتنی بر انعطاف پذیری مودال و انحنای مودال را به عنوان

- buildings by support vector regression. *The Structural Design of Tall and Special Buildings*. 2023;32(16):e2049.
14. Pandey A, Biswas M. Damage detection in structures using changes in flexibility. *Journal of sound and vibration*. 1994;169(1):3-17.
 15. Khodabandehlou H, Pekcan G, Fadali MS. Vibration-based structural condition assessment using convolution neural networks. *Structural Control and Health Monitoring*. 2019;26(2):e2308.
 16. Farrar CR, Jauregui DA. Comparative study of damage identification algorithms applied to a bridge: I. Experiment. *Smart materials and structures*. 1998;7(5):704.
 17. Farrar C, Jauregui D. Damage detection algorithms applied to experimental modal data from the I-40 bridge. Los Alamos National Lab.(LANL), Los Alamos, NM (United States); 1996.
 18. ABAQUS. 6.14-4 ed: SIMULIA; 2014.
 9. Shi Z, Law S, Zhang L. Damage localization by directly using incomplete mode shapes. *Journal of engineering mechanics*. 2000;126(6):656-60.
 10. Azimi M, Eslamlou AD, Pekcan G. Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review. *Sensors*. 2020;20(10):2778.
 11. Doroudi R, Hosseini Lavassani SH, Shahrouzi M, Dadgostar M. Identifying the dynamic characteristics of super tall buildings by multivariate empirical mode decomposition. *Structural Control and Health Monitoring*. 2022;29(11):e3075.
 12. Doroudi R, Lavassani SHH, Shahrouzi M. Optimal tuning of three deep learning methods with signal processing and anomaly detection for multi-class damage detection of a large-scale bridge. *Structural Health Monitoring*. 2024;14759217231216694.
 13. Doroudi R, Hosseini Lavassani SH, Shahrouzi M. Predicting acceleration response of super-tall

Damage detection method utilizing modal strain energy and modal flexibility damage indexes and deep neural network in steel beams

Sara Zalaghi¹, Armin Aziminejad^{2*}, Hossein Rahami³, Abdolreza S. Moghadam⁴, Mir Hamid Hosseini²

1. Ph.D Candidate, Department of civil engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Ph.D, Department of civil engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

3. Ph.D, School of Engineering Science, College of Engineering, University of Tehran, Tehran, Iran

4. Ph.D, International Institute of Earthquake Engineering and Seismology (IIEES), Tehran, Iran

Corresponding author email address: Arminaziminejad@srbiau.ac.ir

Abstract:

Civil structures inevitably undergo damage over time due to various reasons such as environmental changes, material aging, load variations, and insufficient maintenance. Monitoring these structures, especially aging ones, is crucial to detect damage early on and implement suitable retrofitting measures, ensuring their continued safe and reliable operation without unexpected failures. Consequently, there has been significant research in this field, focusing on damage detection in both simple and complex structures. Health monitoring of highway bridges is essential for achieving a reliable transportation system. The vibration-based damage detection method uses changes in the vibrational properties of structures to detect damages and ensure a healthy state. In this study, the absolute value of the modal flexibility damage index and the modal strain energy damage index simultaneously are utilized to prevent unsafe decisions.

These absolute values of modal strain energy and flexibility damage indexes are utilized as the bases for training deep neural networks (DNNs). These indexes are applied to provide safe decisions and reliable damage evaluation in steel girder of the highway bridges. The convolution neural network (CNN) is utilized for damage quantification estimation. The CNN is one of the deep learning models that can currently be applied in 2D dominant approaches, such as pattern recognition and speech recognition. In addition, these networks can utilize the 1D time domain and vibrational signal data via the convolutional layer. The initial stage of CNN model comprises combined convolutional and pooling layers that apply different filters to extract features. Following this, fully connected layers, similar to a hidden layer of a multilayer perceptron are incorporated. Ultimately, these layers are classified together with a softmax layer. The convolution layer acts as a filter that convolutes the input layer with a set of weights, adding bias and applying an activation function to the outcome. Gradient descent momentum methods (SGDM) can be employed to optimize the parameters in CNN network architecture. SGDM estimates the gradient with high velocity in any dimension. This method mitigates issues such as jittering and saddle points by utilizing high-velocity inconsistent gradient dimensions and the SGD gradients, respectively. Additionally, when the Current gradient approaches zero, the SGDM provides some momentum.

The convolution neural network is trained to utilize damage indexes obtained from numerical simulation of the validated finite element model of the bridge. The damage indexes as the inputs for the neural network, which are achieved from different damage scenarios. Once network training and validation are completed, a well-trained neural network is used to detect, localize, and quantify the intensity of unknown damages. The proposed method overcomes previous damage detection problems such as false positive indications, the unreliability of a single damage index, and insufficient precision in determining the intensity. The results revealed that the presented method, based on the dual updated damage indexes and CNN, practically and accurately identified unspecified single damages' location and severity in multi-span beams. The new training method of deep neural network systems overcomes some shortcomings in ANN. Moreover, this deep neural network training scheme can reduce the need for huge amounts of input data and enhance the accuracy of network training. The method is capable in predicting single damage scenarios in steel beam.

Keywords: Structural health monitoring, modal strain energy damage index, modal flexibility damage index, steel beam, deep learning.