مهندسی عمران شریف، (تابستان ۱۴۰۳)
دوره‌ی ۴۰، شماره‌ی ۲، صص. ۷۶-۶۳، (پژوهشی)

Original Article

مطالعه‌ی آزمایشگاهی تشخیص آسیب در پل خرپایی تحت بار متحرک با استفاده از شبکه‌ی عصبی مصنوعی و تبدیل موجک تجربی

سیاوش شاه‌محمدی (کارشناس‌ارشد)
موسی محمودی صاحبی* (استاد)
دانشکده‌ی مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی، تهران

عوامل بسیاری می‌تواند در طول زمان بهره‌برداری از سازه‌ها منجر به ایجاد آسیب‌های موضعی شود، که در پاسخ‌های ارتعاشی سازه‌ها نمود پیدا می‌کنند. با هدف تشخیص وجود و تعیین موقعیت مکانی آسیب با استفاده از شبکه‌ی عصبی مصنوعی و تبدیل موجک تجربی تحت بار متحرک، یک پل خرپایی در مقیاس آزمایشگاهی ساخته شد. پس از اندازه‌گیری پاسخ‌های ارتعاشی پل، ۱۷ ویژگی حوزه‌ی زمانی استخراج شده از سیگنال‌های خام، برای تشخیص وجود آسیب به‌عنوان ورودی به شبکه‌ی عصبی ارائه و وضعیت سلامت پل (سالم یا آسیب دیده) به‌عنوان تارگت‌های آن در نظر گرفته شدند. برای مکانیابی آسیب نیز ۵ ویژگی غیرپارامتریک، شامل: آنتروپی‌های شانون و تی‌سالیس، جذر مجموع مربعات، عامل شکل و کشیدگی، به همراه ویژگی انرژی، از سیگنال‌های پردازش شده‌ی پل به کمک تبدیل موجک تجربی استخراج و استفاده شدند. نتایج نشان می‌دهند که روش پیشنهادی به‌طور مؤثری قادر به تشخیص وجود و مکان آسیب در پل تحت بار متحرک است.

واژگان کلیدی: پایش سلامت سازه، تشخیص آسیب، شبکه‌ی عصبی مصنوعی، تبدیل موجک تجربی، بار متحرک.

siavash.shahmohammadi@ymail.com
m.mahmoudi@sru.ac.ir

۱. مقدمه

ارزشمندی منابع ملی هرکشور، که بخش اعظم آن شامل سازه‌های عمرانی است، بر هیچ کس پوشیده نیست؛ چرا که از اصلی‌ترین شریان‌های حیاتی هستند و کشورها زمان و هزینه‌ی زیادی را برای ساخت آنها صرف می‌کنند. از این رو، دقت و توجه کافی به بحث سلامت سازه‌های عمرانی، به‌منظور پیشگیری از آسیب‌دیدگی و خرابی‌ها، که به بعضاً ممکن است جبران‌ناپذیر نیز باشند، بسیار حائز اهمیت است.

روش‌های تشخیص آسیب عمدتاً به دو دسته‌ی سراسری[۱] و محلی[۲] طبقه‌بندی می‌شوند. روش‌های محلی به تنهایی برای پایش سلامت سازه‌های عمرانی در ابعاد بزرگ کفایت نمی‌کنند. در نتیجه، چنین محدودیتی استفاده از روش‌های تشخیص سراسری را ملزم می‌سازد. روش سراسری را نیز می‌توان در دو گروه استاتیکی و دینامیکی (مبتنی بر ارتعاش) دسته‌بندی کرد.[۱]

روش‌های مبتنی بر ارتعاش، یکی از روش‌های رایج در سیستم‌های پایش سلامت سازه برای تشخیص آسیب هستند، که از شتاب‌سنج‌ها برای اندازه‌گیری پاسخ‌های شتاب سازه استفاده می‌کنند. سپس با استفاده از داده‌های اندازه‌گیری شده، ویژگی‌های ارتعاشی مانند بسامدهای طبیعی و شکل مودها را برای شناسایی تغییراتی که نشان‌دهنده‌ی آسیب سازه‌یی هستند، تجزیه و تحلیل می‌کنند.[۲] استفاده از داده‌های ارتعاشی برای تشخیص آسیب چند مزیت دارد: نخست آنکه، امکان تشخیص زودهنگام آسیب‌ها و امکان تعمیر یا تعویض سریع اجزاء آسیب دیده را فراهم می‌کند. این رویکرد پیشگیرانه می‌تواند از وخامت بیشتر و بلایای انسانی بالقوه جلوگیری کند. علاوه‌بر این، شناسایی زودهنگام آسیب‌ها می‌تواند با کمینه‌سازی هزینه‌های تعمیر و جلوگیری از خرابی‌های سازه‌یی گسترده‌تر به مزایای اقتصادی منجر شود.[۳]

رویکردهای متفاوتی در زمینه‌ی نوع ویژگی استخراج شده در روش‌های مذکور وجود دارد، که آنها را می‌توان به دو دسته‌ی پارامتریک و غیرپارامتریک تقسیم کرد. اساس روش‌های پارامتریک بر وجود رابطه بین آسیب و تغییرات در ویژگی‌های مودال

* نویسنده مسئول

تاریخ: دریافت ۱۴۰۲/۴/۱۷، اصلاحیه ۱۴۰۲/۷/۲۷، پذیرش ۱۴۰۲/۸/۱۷.

استناد به این مقاله:
شاه‌محمدی، سیاوش و محمودی صاحبی، موسی، ۱۴۰۳. مطالعه‌ی آزمایشگاهی تشخیص آسیب در پل خرپایی تحت بار متحرک با استفاده از شبکه‌ی عصبی مصنوعی و تبدیل موجک تجربی. مهندسی عمران شریف، ۴۰(۲)، صص. ۷۶-۶۳. DOI:10.24200/J30.2023.62521.3229

سازه تکیه کرده‌اند. روش‌های پارامتریک بر این فرضیه استوار هستند که آسیب سازه به‌طور قابل توجهی در جرم، سختی و یا میرایی مودال سازه‌ها تأثیر می‌گذارد. البته فرض مذکور به‌طورکلی قابل درک به نظر می‌رسد، اما برای کاربردهای عملی روش مذکور، کاستی‌های شناسایی شده است.[۴] بررسی‌های اخیر نشان داده است که انواع خاصی از آسیب‌های سازه‌یی نمی‌توانند همیشه با تغییرات در ویژگی‌های دینامیکی مرتبط باشند، به‌ویژه آنهایی که مربوط به مودهای پایین ارتعاشی هستند. آسیب سازه‌یی محلی فقط بر مودهای بسامدی بالاتر تأثیر می‌گذارد، که معمولاً شناسایی آنها با استفاده از روش‌هایی که مبتنی بر فقط خروجی[۳] هستند، دشوار است. عواملی مختلفی به غیر از آسیب، مانند: دما، رطوبت و نویز نیز اندازه‌گیری پارامترهای مودال را تحت تأثیر قرار می‌دهند. بنابراین، تغییرات در پارامترهای مودال، لزوماً نشانگر وجود آسیب در سازه نیست.[۵]

برخلاف رویکردهای پارامتریک، که بر شناسایی پارامترهای مودال سیستم تکیه دارند، روش‌های غیرپارامتریک تشخیص آسیب، برای تشخیص آسیب سازه‌یی مستقیماً از ابزارهای آماری بر روی پاسخ‌های ارتعاشی اندازه‌گیری شده استفاده می‌کنند؛ لذا روش‌های اخیر قادر به استخراج ویژگی‌هایی از آسیب هستند که به‌راحتی نمی‌توان آنها را به تغییرات فیزیکی در سازه نسبت داد. در واقع، نکته‌ی قابل توجه در چنین رویکردی امکان استخراج ویژگی‌هایی است که به راحتی در تغییرات رخداده در پارامترهای دینامیکی قابل تشخیص نیستند.[۶]

امروزه با پیشرفت علم، تکنولوژی و ظهور قدرت محاسباتی و همچنین توسعه در زمینه‌ی فنّاوری حسگرها و انتقال داده‌ها، استفاده از هوش مصنوعی[۴] و پردازش سیگنال در تمامی زمینه‌ها در حال فراگیر شدن است. یکی از مهم‌ترین کاربردهای آنها در روش‌های پایش سلامت سازه‌هاست، که می‌تواند مشکلات روش‌های پیشین فرایند اخیر را برطرف سازد.[۷] یادگیری ماشین به‌عنوان یکی از اصلی‌ترین زیرشاخه‌های هوش مصنوعی، پژوهش‌ها و مطالعات زیادی را در زمینه‌ی تشخیص آسیب به خود اختصاص داده است؛ که اساساً سیستم‌ها، توانایی یادگیری و بهبود خودکار عملکرد را از طریق تجربه کردن، بدون آنکه صراحتاً برنامه‌ریزی شوند، ارائه می‌کند.[۸] الگوریتم‌های یادگیری ماشین را به‌طورکلی می‌توان به دو گروه الگوریتم‌های یادگیری بدون نظارت[۵] و یادگیری نظارت شده[۶] طبقه‌بندی کرد.[۹] در دو دهه‌ی اخیر، بیشتر مطالعات در زمینه‌ی پایش سلامت به سوی استفاده از یادگیری ماشین و شبکه‌های عصبی مصنوعی، به‌علت قدرت محاسباتی و سرعت عملی که در اختیار قرار می‌دهند، حرکت کرده است. شبکه‌های عصبی نیز به‌عنوان یکی از روش‌های یادگیری ماشین، امروزه انواع مختلفی دارند. یکی از پایه‌یی‌ترین انواع شبکه‌های عصبی، مدل پرسپترون چندلایه است، که به‌اختصار MLP نامیده می‌شود. پرسپترون اولین نمونه از نورون‌های مصنوعی مطابق با سلول‌های مغز انسان است؛ که عملکرد آن این‌گونه است که با دریافت تعدادی ورودی، بر روی آنها عملیات تجمیع را اعمال می‌کند و سپس خروجی عملیات تجمیع به تابعی با عنوان تابع فعال‌ساز[۷] ارائه می‌شود. در انتها، نیز پس از اعمال فرایند تابع فعال‌ساز، داده‌ها به لایه‌ی نهایی انتقال می‌یابند.[۱۰]

اتصال پرسپترون‌ها به یکدیگر، شبکه‌ی عصبی چندلایه را تشکیل می‌دهد؛ که بیشتر به عملکرد شبکه‌یی مغز و انتشار سیگنال در آن توجه شده است و به همین جهت، شبکه‌های پیش‌خور[۸] یا حرکت رو به جلو نیز خوانده می‌شوند.[۱۱]

شبکه‌های پیش‌خور، از اولین شبکه‌های عصبی محسوب می‌شوند، که در آنها فعال‌سازی از لایه‌ی ورودی به خروجی، بدون هیچ‌گونه فرایند بازگشتی جریان پیدا می‌کند. لایه‌ی میانی با عنوان لایه‌ی مخفی، وظیفه‌ی اصلی انجام محاسبات و تولید خروجی را بر عهده دارد. در شبکه‌های پیش‌خور، حرکت محاسبات کاملاً رو به جلو است و هیچ بازگشتی در محاسبات به‌منظورکاهش خطا یا اصلاح سوگیری (بایاس)[۹] انجام نمی‌شود. تابع هزینه یا اتلاف در هر نوبت از اجرای مجدد آموزش شبکه، میزان خطای آن را اندازه‌گیری می‌کند. در واقع تابع هزینه، معیاری برای ارزیابی مناسب بودن مدل شبکه‌ی عصبی از منظر توانایی در پیش‌بینی مقادیر جدید است.[۱۰]

تابع آنتروپی، پرکاربردترین تابع اتلاف در دسته‌بندی داده‌هاست، که با دور شدن مقادیر پیش‌بینی از مقادیر موردانتظار، افزایش و با کاهش فاصله‌ی مذکور کاهش می‌یابد، که آن را به‌صورت لگاریتمی ارزیابی می‌کند و لذا به آن تابع شبه‌لگاریتمی منفی[۱۰] نیز می‌گویند. در واقع، مزیت تابع آنتروپی آن است که نسبت به هر دو نوع خطا، واکنش مشخصی از خود نشان می‌دهد. معادله‌ی ۱، مربوط به تابع آنتروپی متقاطع دودویی و معادله‌ی ۲، مربوط به تابع آنتروپی متقاطع است، که در آنها y' مقدار پیش‌بینی شده، y مقدار حقیقی و M تعداد کلاس‌هاست.

$$f(y) = -(y_i \log y'_i + (1 - y_i)\log(1 - y'_i)) \quad (1)$$

$$f(y) = -\sum_{i=1}^{M} y_{j,i} \log(y'_{i,j}) \quad (2)$$

حکیم و همکاران (۲۰۱۵)، یک تیر I شکل با شرایط تکیه‌گاهی دو سرگیردار را تحت یک تحریک نویز به کمک شبکه‌ی عصبی آسیب‌شناسی کردند؛ که با استفاده از بسامدهای طبیعی ۵ مود اول تیر، عملکرد مطلوبی در تشخیص آسیب از خود به‌جای گذاشت، اما در سناریوهای آسیب دوگانه دقت کافی نداشت.[۱۲] در یک مطالعه‌ی عددی، چون[۱۱] و همکاران (۲۰۱۵)، برای پایش کاهش ضخامت ناشی از خوردگی تیرهای اصلی در پل‌ها، روشی مبتنی بر یادگیری ماشین را با رویکردی غیرپارامتریک ارائه کردند. استخراج ویژگی به روش غیرپارامتریک با محاسبه‌ی مقادیر بیشینه و واریانس سیگنال‌های شتاب اندازه‌گیری شده انجام و سپس مقادیر مذکور توسط شبکه‌ی عصبی پردازش شدند، که منجر به نتایجی با دقت بالا شد.[۱۳]

قنادی و کورهلی[۱۲] (۲۰۱۹)،[۱۴] روشی مبتنی بر داده برای تشخیص آسیب با استفاده از حسگرهای پراکنده ارائه کردند؛ که یکی از چالش‌های مهم آن در مشکلات شناسایی آسیب، فقدان درجه‌های آزادی اندازه‌گیری شده و محدودیت حسگرهای نصب شده بر روی سازه بوده است. رویکرد جدید در مطالعه‌ی اخیر، استفاده از داده‌های شکل مودهای توسعه‌یافته برای آموزش شبکه‌ی عصبی مصنوعی بوده است، که شکل‌های مذکور توسط روش SEREPa، که یک روش غیرهموار و محافظ داده است، گسترش یافته‌اند. سپس ANN از طریق داده‌های توسعه‌یافته به‌عنوان ورودی، مکان و شدت آسیب به‌عنوان خروجی آموزش داده شد. نتایج پیش‌بینی خسارت، دقت قابل قبول روش پیشنهادی را نشان داد.

همچنین قنادی و کورهلی (۲۰۲۰)،[۱۵] روشی مؤثر برای ارزیابی آسیب در سازه‌های اسکلتی براساس محدودیت مکان‌های اندازه‌گیری پاسخ با استفاده از مدل تحلیل آزمون مودال و شبکه‌های عصبی مصنوعی پیشنهاد کردند؛ که بر روی یک تیر طره صورت گرفت و در آن از مدل تحلیل آزمون مودال به‌منظور تخمین درجه‌های آزادی اندازه‌گیری نشده استفاده شده بود. در نهایت، نتایج به‌دست آمده نمایانگر دقت بالای مدل تحلیل آزمون مودال و شبکه‌ی عصبی مصنوعی برای تشخیص آسیب سازه‌یی بوده‌اند.

جایاسوندارا[۱۳] و همکاران (۲۰۲۰)، یک روش مبتنی بر ارتعاش را برای پل‌های قوسی که ویژگی‌های ارتعاشی نسبتاً پیچیده‌یی دارند، با هدف تشخیص، مکانیابی و کمّی‌سازی آسیب‌ها در المان‌های سازه بررسی و اعمال کردند. در روش پیشنهادی ایشان، شکل‌های اصلاح شده‌ی شاخص‌های آسیب، که مبتنی بر انعطاف‌پذیری مودال و انرژی کرنش مودال بودند، همراه با فنّاوری شبکه‌ی عصبی مصنوعی برای

ارزیابی کلی آسیب استفاده شده‌اند. روش شناسایی و مکانیابی آسیب به‌صورت تجربی اعتبارسنجی شد و یک پل قوسی با دهانه‌ی بلند در مقیاس واقعی تحت طیف وسیعی از سناریوهای آسیب قرار گرفت. سپس شاخص‌های آسیب به‌دست آمده از داده‌های ارتعاشی آلوده به نویز به‌عنوان داده‌های ورودی برای آموزش و اعتبارسنجی شبکه‌های عصبی استفاده شدند. به همین منظور، دو شبکه‌ی عصبی به‌طور جداگانه با استفاده از شاخص‌های آسیب انعطاف‌پذیری مودال و انرژی کرنش مودال آموزش داده شدند و سپس از رویکرد ادغام شبکه برای به‌دست آوردن نتایج واضح و دقیق برای تشخیص، مکانیابی و کمّی‌سازی آسیب‌ها استفاده شد. در نهایت، سیستم شبکه‌ی عصبی آموزش دیده با موفقیت برای شناسایی آسیب‌های ناشناخته فقط با استفاده از داده‌های ارتعاشی المان‌های سازه‌یی آسیب‌دیده‌ی پل‌های قوسی استفاده شد.[16]

سرمدی و همکاران (۲۰۲۱)،[17] طی پژوهشی به بررسی وضعیت سلامت پل‌ها تحت تغییرات محیطی پرداخته و یک روش یادگیری ماشین جدید برای تشخیص آسیب تحت تغییرات محیطی با استفاده از خوشه‌بندی به‌روش k-medoids، که یک شاخص آسیب جدید و یک رویکرد نوآورانه برای انتخاب تعداد خوشه‌ی مناسب است، را پیشنهاد کردند. برآورد آستانه‌ی هشدار قابل اعتماد، یکی دیگر از چالش‌های مهم برای تشخیص زودهنگام آسیب از طریق بسیاری از روش‌های یادگیری ماشینی است، که بر این اساس، یک رویکرد احتمالی جدید با استفاده از تئوری مقادیر حدی و نیکویی برازش برای برآورد آستانه‌ی هشدار پیشنهاد شده است. نتایج نشان داد که روش‌های ارائه شده، قادر به تشخیص آسیب اولیه تحت تغییرات شدید محیطی و همچنین برآورد آستانه‌ی قابل اعتماد هستند.

نیک و همکاران (۲۰۲۱)، نیز یک روش شناسایی آسیب دو مرحله‌یی برای مکانیابی و برآورد خسارت در پل‌های با شاه‌تیر فولادی پیشنهاد و عملکرد و امکان‌سنجی آن را با اعمال چند سناریوی آسیب منفرد و چندگانه به مدل المان محدود تأیید شده‌ی پل $I-40$ واقع در آمریکا ارزیابی کردند. در ابتدا، محل آسیب با استفاده از روش شاخص آسیب مبتنی بر انرژی کرنش مودال تعیین شد. برای این منظور، شاخص آسیب برای سه مود خمشی اول پل به‌طور جداگانه محاسبه و بردارهای آسیب محاسبه شده در طول تیرها با هم ترکیب شدند. مقدار پیک شاخص آسیب ترکیبی، محل آسیب را در طول تیرورق‌های فولادی حتی در صورت وجود سناریوهای آسیب متعدد در تیرورق‌ها با دقت مناسبی نشان داد. در مرحله‌ی دوم از شبکه‌ی عصبی مصنوعی برای برآورد شدت آسیب استفاده شد. پس از آموزش، شبکه‌ی عصبی توانست شدت آسیب‌های سازه‌یی را پیش‌بینی کند. نتایج حاکی از دقت مناسب ارائه شده توسط شبکه‌ی عصبی مصنوعی برای تخمین میزان آسیب و همچنین عملکرد مناسب روش پیشنهادی بوده است.[18]

همچنین موسوی و همکاران (۲۰۲۱)، با هدف تشخیص آسیب، یک پل خرپایی ۳ بُعدی را در آزمایشگاه، یک بار تحت بار ضربه و بار دیگر تحت تحریکی توسط لرزاننده قرار دادند. فرایند پایش با پردازش سیگنال‌ها به روش تبدیل موجک تجربی و استخراج تعدادی ویژگی مودال، ویژگی آماری و درنهایت استفاده از شبکه‌ی عصبی مصنوعی صورت پذیرفت، که نتایج به‌دست‌آمده دقت بالای روش مذکور را در تشخیص آسیب تأیید کرد.[19]

کوربالی[14] و ملک جعفریان (۲۰۲۲)، استفاده از یک رویکرد داده‌محور جدید را برای نظارت بر وضعیت یک پل بتنی پیشنهاد کردند. در الگوریتم پیشنهادی از یک شبکه‌ی عصبی مصنوعی استفاده می‌شد، که برای پیش‌بینی رفتار پل با استفاده از اندازه‌گیری‌های شتاب از چند گذر، یک وسیله‌ی نقلیه در حال عبور آموزش داده شد. یک فرمول نیز ارائه شده بود که اجازه می‌داد تا پاسخ در نقطه‌ی تماس بین لاستیک و روسازی از سنجش درون خودرو استنتاج شود. سپس محتوای بسامدی پاسخ مربوط به نقطه‌ی تماس، همراه با سرعت خودرو به‌عنوان ورودی‌های اولیه به شبکه‌ی عصبی، که برای تشخیص تأثیر دما در پاسخ سازه آموزش دیده بود، استفاده شدند. یک شاخص آسیب جدید نیز پیشنهاد شده بود که اجازه می‌داد پیشرفت آسیب در طول زمان مشاهده شود. نتایج نشان داده است که استفاده از پاسخ نقطه‌ی تماس در شبکه‌ی عصبی مصنوعی، عملکرد بهبودیافته‌یی را نسبت به پاسخ محوری، که به‌طور سنتی استفاده می‌شود، ارائه می‌دهد. همچنین نتایج به‌دست آمده حاکی از آن است که الگوریتم پیشنهادی قادر به تشخیص ترک‌خوردگی وسط دهانه و یک چهارم دهانه در تمام سرعت‌های در نظر گرفته شده‌ی خودرو و همچنین در حضور روسازی ناهموار و شرایط دمایی متغیر است.[20]

یانگ و همکاران (۲۰۲۲)، از یک وسیله‌ی نقلیه‌ی آزمایشی تک‌محور با دو چرخ برای تشخیص آسیب در یک پل صفحه‌یی استفاده کردند، که در دو انتهای طولی‌اش، دارای تکیه‌گاه ساده و در طرفین جانبی‌اش، آزاد بود. پاسخ وسیله‌ی نقلیه‌ی ثبت شده به‌دلیل تأثیر بسامدهای وسیله‌ی نقلیه، که بسامدهای پل را تحت‌الشعاع قرار می‌دادند، بررسی شد تا در تحلیل طیفی شناسایی شود. در مطالعه‌ی اخیر، بردار پاسخ انتقالی یکنواخت برای مکانیابی آسیب صفحه‌یی ارائه شده است. بردار پاسخ انتقالی یکنواخت برای هر چرخ با درنظر گرفتن چند مود خمشی اولیه‌ی به‌دست آمده از پاسخ نقطه‌ی تماس در طول مسیر حرکت آن محاسبه شد. بر اساس همبستگی بین دو انحنای بردار پاسخ انتقالی یکنواخت ایجاد شده برای چرخ های چپ و راست وسیله‌ی نقلیه‌ی آزمایشی، می‌توان محل هر آسیب را شناسایی کرد. نتایج نشان می‌دهند که روش پیشنهادی در تخمین مکان‌های طولی و وسعت جانبی آسیب‌ها در سازه‌های صفحه‌یی به خوبی کار می‌کند.[21]

خان احمدی و همکاران (۲۰۲۲)،[22] در یک مطالعه‌ی تحلیلی به بررسی آسیب در سازه‌ی تیر فولادی با استفاده از مقایسه‌ی نتایج تحلیلی آنالیز موجک پرداختند و از مدل سازی عددی تیر فولادی در نرم‌افزار اجزاء محدود استفاده و سپس اطلاعات مودال و شکل مودهای سالم و آسیب‌دیده را استخراج کردند. تفاوت‌هایی که در مقادیر بسامدهای وضعیت اولیه در مقایسه با وضعیت ثانویه‌ی تیر مشاهده شد، از وجود آسیب حکایت داشت. همچنین پردازش سیگنال‌های شکل مودهای سالم و معیوب به کمک آنالیز موجک صورت گرفت، که توانست با دقت خوبی تفاوت در منطقه‌ی آسیب را نشان دهد و موقعیت آسیب را با خطای کمتر از ۲٪ شناسایی کند.

همچنین فلاح و همکاران (۲۰۲۳)،[23] طی پژوهشی یک روش جدید برای شناسایی آسیب سازه‌ها با استفاده از به‌روزرسانی مدل بر پایه‌ی تحلیل مؤلفه‌های اصلی و داده‌های چگالی طیفی توان کرنش -محور ارائه کردند. عیب‌یابی نیز توسط یک معادله‌ی حساسیت ابداعی حل شد. با هدف ارزیابی روش پیشنهادی اخیر، دو سازه‌ی فلزی، شامل یک خرپا و یک قاب دوبُعدی دو طبقه‌با دو دهانه انتخاب شدند، که نتایج آنها نشان‌دهنده‌ی عملکرد خوب روش ارائه شده، حتی با وجود خطای اندازه‌گیری بود. همچنین، مقایسه‌ی روش ارائه شده با روش‌های دیگر نشان داد که نتایج معادله‌ی حساسیت ابداعی، حساسیت مناسب‌تری نسبت به دیگر روش‌های کرنش ـ محور دارد.

هدف پژوهش حاضر، تشخیص وجود و مکانیابی آسیب در یک پل خرپایی با استفاده از شبکه‌ی عصبی مصنوعی و تبدیل موجک تجربی بوده است. عمده‌ی پژوهش‌های آزمایشگاهی پیشین صورت گرفته در زمینه‌ی تشخیص آسیب، تحت تحریک‌های ورودی، نظیر بارهای ضربه‌یی قرار داشتند. همچنین پژوهش‌های اخیری که از نتایج گذر وسیله‌ی نقلیه بهره برده‌اند، بر روی پل‌های صفحه‌یی و بتنی صورت گرفته‌اند. تشخیص وجود آسیب‌هایی که از موقعیت مکانی آنها داده‌یی در دسترس

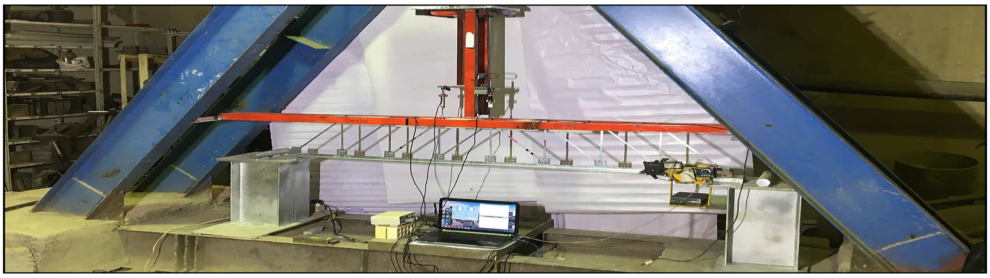

شکل ۱. پل خرپایی دو بُعدی ساخته شده در آزمایشگاه سازه.

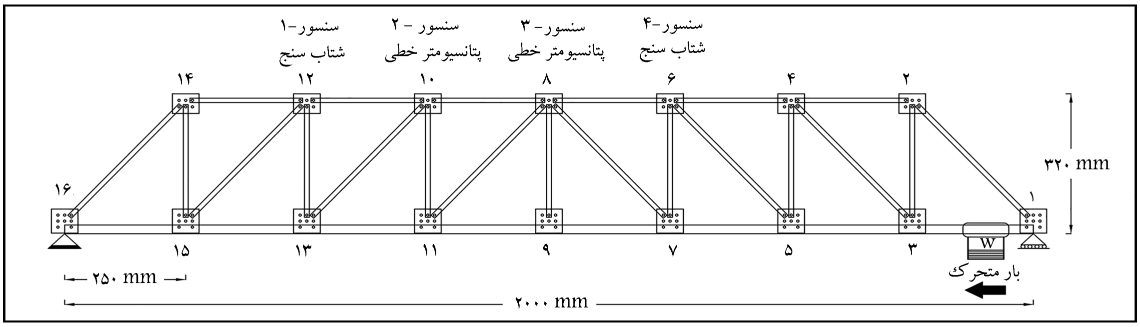

شکل ۲. شماتیک پل خرپایی.

نیست، می‌تواند با استفاده از یک بار متحرک که طول پل را به‌طورکامل طی می‌کند، ممکن شود. از این رو، به دلیل وابستگی نمود آسیب‌ها در پاسخ سازه به محل اعمال بارهای ضربه‌یی و به‌منظور نوآوری، در پژوهش حاضر از یک بار متحرک به‌عنوان تحریک ورودی استفاده شده است.

۲. روش پژوهش

۱.۲. مطالعه‌ی آزمایشگاهی

برای بررسی روش پیشنهادی در پژوهش حاضر، یک پل خرپایی در مقیاس آزمایشگاهی در آزمایشگاه سازه‌ی دانشکده‌ی عمران در دانشگاه تربیت دبیر شهید رجایی تهران ساخته شد (شکل ۱)؛ که المان‌های خرپایی آن با استفاده از ورقه‌هایی از جنس نزدیک به فولاد گالوانیزه با ضخامت ۱ میلی‌متر تهیه شدند. طول خالص اعضاء خرپایی برای المان‌های افقی برابر ۲۲۵ و برای المان‌های عمودی برابر ۲۴۰ میلی‌متر اندازه‌گیری شد. تیر زیرین پل یک تیر پیوسته بود، که در سمت راست که نقطه‌ی شروع حرکت بار متحرک است، بر روی یک تکیه‌گاه غلتکی و در سمت چپ بر روی یک تکیه‌گاه مفصلی قرار داشت. فاصله‌ی بین دو تکیه‌گاه پل برابر ۲۰۰۰ میلی‌متر و طول خالص آن برای حرکت بار متحرک ۱۹۰۰ میلی‌متر اندازه‌گیری شده است. برای اندازه‌گیری پاسخ‌های ارتعاشی پل خرپایی مذکور، بر روی آن ۴ عدد حسگر نصب شد (شکل ۲). همچنین به‌منظور جلوگیری و کاهش تغییرمکان‌های عمود بر صفحه، یال‌های بالایی خرپا با استفاده از یونولیت فشرده مهار شدند.

اتصال‌های المان‌های خرپایی پل خرپایی، تماماً از نوع پیچی متصل به ورق گاست بود. از این رو تمامی المان‌های آن، به غیر از تیر پیوسته‌ی زیرین پل، عملکردی مفصلی از خود نشان داده‌اند.

در شکل ۳، جزئیات هندسی مربوط به اتصال المان‌ها به صفحه‌های گاست و همچنین گاست‌ها به تیر اصلی مشاهده می‌شود.

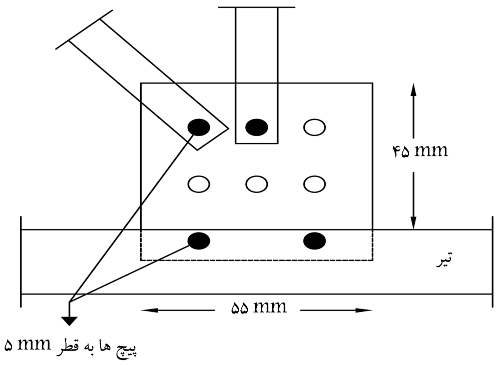

الف) گره ۷؛

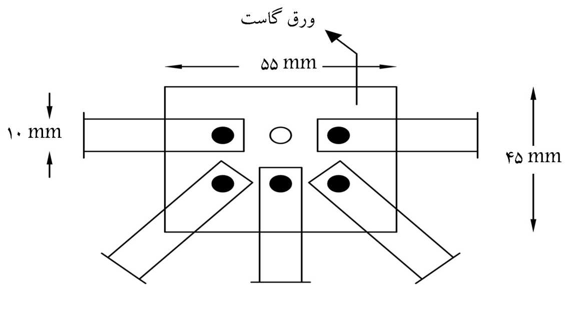

ب) گره ۸

شکل ۳. جزئیات اتصال‌های پل خرپایی.

سطح مقطع تمامی المان‌های خرپایی از اتصال دو ورق مستطیلی شکل، که هرکدام ۱ میلی‌متر ضخامت داشتند، تشکیل شده است. همچنین تیر زیرین پل نیز از اتصال دو سطح مقطع L شکل تشکیل شده است، که جزئیات آنها در شکل ۴ مشاهده می‌شود.

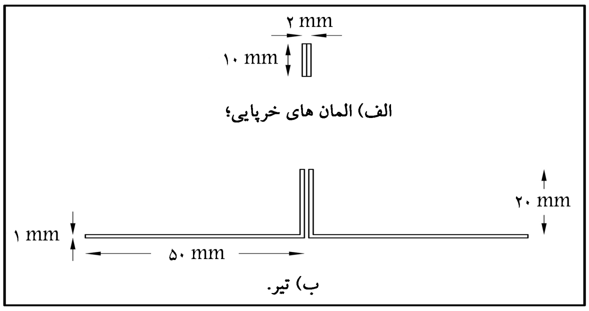

شکل ۴. جزئیات سطح مقطع.

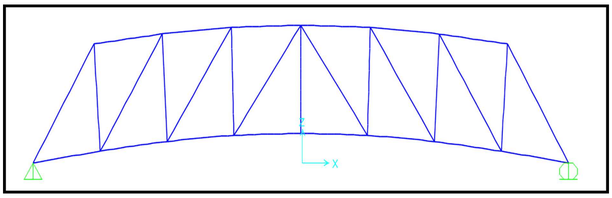

شکل ۵. مدل عددی پل خرپایی ـ مود اول.

جدول ۱. مقایسه‌ی بسامدهای طبیعی (Hz).

شماره‌ی بسامد	مدل آزمایشگاهی	مدل عددی
۱	۱۹٫۹	۲۱٫۷
۲	۵۱٫۲	۵۶٫۷
۳	۷۵٫۴	۷۰٫۳

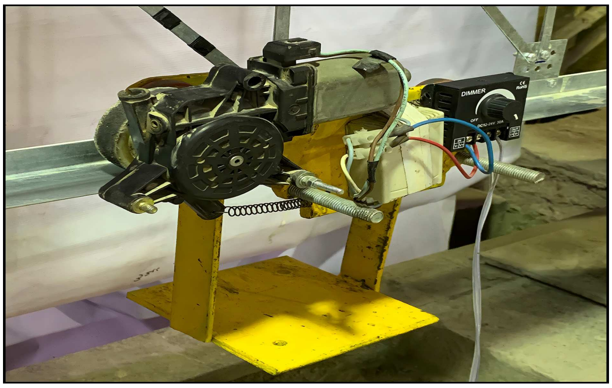

شکل ۶. ارابه‌ی بار متحرک.

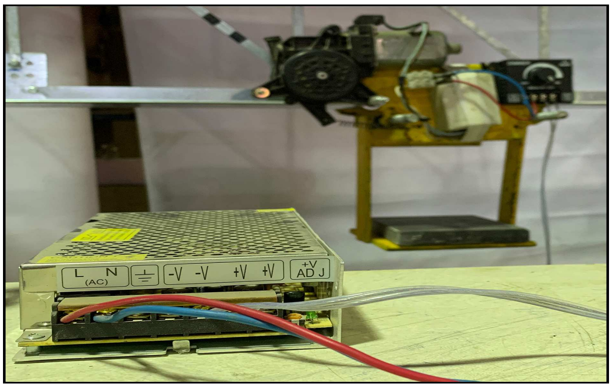

شکل ۷. گیرنده‌ی بسامدی.

۲.۲. مدل‌سازی عددی

با هدف راستی‌آزمایی نتایج حاصل از سیگنال‌های ثبت شده در آزمایشگاه، مدل‌سازی عددی برای پل خرپایی در نرم‌افزار SAP ۲۰۰۰، با توجه به مشخصات هندسی و مکانیکی آن انجام شده است (شکل ۵). سپس مدل مذکور تحت تحلیل مودال قرارگرفت و بسامدهای طبیعی آن به‌دست آمدند.

برای به‌دست آوردن بسامدهای طبیعی پل آزمایشگاهی در وضعیت سالم پل نیز داده‌های شتاب ـ زمان حاصل از حسگرها، در نرم‌افزار متلب[۱۵] با استفاده از تبدیل فوریه به حوزه‌ی بسامد انتقال یافتند و با روش انتخاب مقادیر بیشینه، بسامدهای طبیعی سازه مشخص شدند. نتایج بسامدهای طبیعی حاصل از مدل عددی با پل آزمایشگاهی در جدول ۱ مقایسه شده‌اند. نتایج نشان داد که بسامدهای طبیعی به‌دست آمده از مدل‌سازی عددی با توجه به محدودیت‌های مدل‌سازی، از قبیل نوع اتصال‌ها و ضخامت ورق‌های گاست، به‌طور قابل قبولی با بسامدهای طبیعی سازه‌ی آزمایشگاهی هم‌خوانی دارند.

۳.۲. بار متحرک

در بیشتر پژوهش‌هایی که تاکنون در زمینه‌ی شناسایی آسیب در پل‌ها صورت گرفته‌اند، عمدتاً از دو نوع تحریک استفاده شده است. گروه اول، پاسخ‌های خود را تحت تحریک یک بار ضربه‌یی، که با استفاده از یک چکش یا هر وسیله‌ی مشابه دیگر ایجاد می‌شود، ثبت می‌کنند. گروه دوم، نیز با استفاده از ابزارهایی نظیر دستگاه‌های لرزاننده، در پل ارتعاش ایجاد می‌کنند. سپس، با استفاده از حسگرها، مقادیر پاسخ سازه را اندازه‌گیری می‌کنند.

در پژوهش حاضر، در تلاش برای رفع وابستگی نمود آسیب‌ها در پاسخ سازه به محل اعمال بارهای ضربه‌یی، پل خرپایی تحت اثر یک بار متحرک قرار گرفت؛ که شامل یک محل نگه‌دارنده‌ی وزنه، گیرنده‌ی بسامدی و چهار عدد چرخ بود و اجزاء تشکیل‌دهنده‌ی آن، بدون اعمال بار اضافه، مجموعاً جرمی برابر با ۶۲۳۰ گرم داشتند. هر چهار چرخ بار متحرک بر روی تیر پایینی پل قرارگرفتند، که در شکل ۶ مشاهده می‌شود. فرایند شروع و پایان حرکت ارابه نیز با کمک یک کشنده، که توسط یک ریموت کنترل از راه دورکنترل می‌شد، صورت پذیرفته است (شکل ۷).

۴.۲. مشخصات حسگرها و دستگاه رویداد نگار داده

بر روی پل، چهار عدد حسگر شامل، دو عدد شتاب‌سنج تک‌جهته، که شتاب را فقط در یک راستا اندازه‌گیری می‌کردند و همچنین دو عدد حسگر پتانسیومتر خطی (LP)[۱۶] جهت اندازه‌گیری میزان جابه‌جایی عمودی، استفاده شده‌اند. با توجه به ساختار و نحوه‌ی عملکرد بار متحرک در هنگام آزمایش و به دلیل محدودیت‌های آزمایشگاهی، تمامی حسگرها بر روی گره‌های بالایی خرپا قرارگرفتند (شکل ۸). در جدول ۲، نیز مشخصات فنی آنها ارائه شده است. اطلاعات و خروجی‌های حسگرها، از طریق یک کابل به دستگاه رویدادنگار داده، محصول شرکت آترون انتقال یافتند و داده‌ها با نرخ نمونه‌برداری ۵۰۰ هرتز ثبت و ذخیره شدند.

آماده‌سازی اولیه‌ی پل خرپایی جهت اجرای آزمون‌ها انجام شد. به‌منظور تشخیص آسیب در پل، ابتدا در شرایطی که سازه در حالت سالم قرارگرفته بود، بار متحرک با ۳ نوع سناریوی بارگذاری، که شامل حالت‌های بدون بار (فقط جرم اجزاء تشکیل‌دهنده‌ی بار متحرک بدون بار اضافه)، نیمه‌ی بار و بیشینه‌ی بار که به ترتیب جرم آنها برابر با ۶۲۳۰، ۱۳۸۰۰ و ۱۹۶۵۶ گرم بود، به پل اعمال و پاسخ‌های پل برداشت شدند. مدت زمان تقریبی هر برداشت بین ۶ تا ۸ ثانیه بود. داده‌های حسگرهای

جدول ۲. مشخصات حسگرها.

نوع حسگر	شرکت سازنده	مدل	محدوده‌ی اندازه‌گیری (mm)	دقت اندازه‌گیری (mm)
	نوع حسگر	تعداد محورها	نرخ پاسخ (HZ)	
	شتاب‌سنج	تک محوره	۵۰۰	
پتانسیومتر	اپکون	SLPS۵۰	۱۰-۱۰۰	۰/۰۱

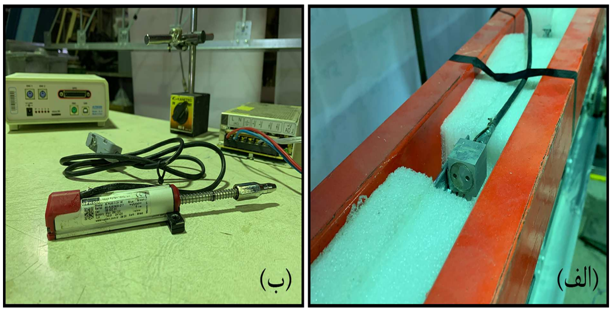

شکل ۸. الف) شتاب‌سنج، ب) پتانسیومتر خطی.

جدول ۳. سناریوهای آسیب.

شماره‌ی سناریو	المان آسیب‌دیده	موقعیت المان
DS − ۱	M ۶ − ۷	عضو قائم سوم از سمت راست
DS − ۲	M ۱۰ − ۱۳	عضو مایل ششم از سمت راست
DS − ۳	M ۴ − ۶	عضو افقی دوم از سمت راست
DS − ۴	M ۱۲ − ۱۳	عضو قائم ششم از سمت راست
DS − ۵	M ۷ − ۸	عضو مایل چهارم از سمت راست
DS − ۶	M ۱۲ − ۱۴	عضو افقی ششم از سمت راست
DS − ۷	M ۷ − ۸ and M۱۲ − ۱۳	همزمانی سناریوهای ۴ و ۵
DS − ۸	N ۱۳	اتصال گره هفتم از سمت راست

LP پس از انجگسیختگی۱ام آزمون به نرم‌افزار متلب ارائه شد و با ۲ بار مشتق‌گیری از آنها، به داده‌های شتاب تبدیل شدند. پس از جمع‌آوری و ثبت سیگنال‌های پل در حالت سالم، پاسخ‌های سازه در حالت آسیب‌دیده نیز اندازه‌گیری شدند.

با همین هدف، ۸ سناریوی آسیب مختلف تحت هر سه سناریوی بارگذاری تعریف و به انواع المان‌های خرپا، که تحت فشار و یا کشش بودند، اعمال شد (جدول ۳). در تمامی سناریوها، آسیب با خارج کردن کامل المان از سیستم باربری صورت پذیرفته است.

۵.۲. استخراج ویژگی

روش پیشنهادی در پژوهش حاضر، رویکردی غیرپارامتریک را در فرایند استخراج ویژگی در نظر گرفته است. در روش‌های استخراج ویژگی با رویکرد غیرپارامتریک، برخلاف رویکرد پارامتریک، که از ویژگی‌های مودال و پارامترهای دینامیکی سازه استفاده می‌کند، ویژگی‌های حساس به آسیب با استفاده از ابزارهای آماری استخراج می‌شوند. از این جهت برای انجام فرایند استخراج ویژگی، ۱۷ ویژگی آماری انتخاب شدند تا از سیگنال‌های ثبت شده از پاسخ پل در حوزه‌ی زمان استخراج شوند. سعی شد ویژگی‌های آماری مذکور به گونه‌یی انتخاب شوند تا ویژگی‌هایی از آسیب را که به راحتی نمی‌توان آنها را به تغییرات فیزیکی نسبت داد، استخراج کنند.

در جدول ۴، p_n برابر با تابع چگالی احتمال است، که مقادیر آن با توجه به نوع توزیع داده‌ها تعیین شده است. مقادیر با عنوان N بر تعداد داده‌های ثبت شده با توجه به نرخ نمونه‌برداری حسگرها در طول یک سیگنال دلالت دارند، که در آزمایش اخیر با توجه به نرخ نمونه‌برداری حسگرهای استفاده شده، برابر ۵۰۰ در نظر گرفته شد. آنتروپی، مقادیر اطلاعاتی از مشاهده‌های سیستم‌های بی‌نظم و اختلال در سیستم‌های فیزیکی را اندازه‌گیری می‌کند.[۲۴] هر چه احتمال تصادفی بودن یک اتفاق بیشتر باشد، آنتروپی مقادیر بیشتری را گزارش می‌کند، که به معنای وجود اختلال در سیستم است. آنتروپی و کشیدگی هر دو با استفاده از تابع چگالی احتمال سیگنال محاسبه می‌شوند، از این رو مقدار آنها با هر تغییری درتابع چگالی احتمال پاسخ‌های ارتعاشی ناشی از بروز آسیب، افزایش می‌یابد.[۲۵]

آنتروپی شانون، متداول‌ترین نوع آنتروپی است. در فرمول هر سه نوع آنتروپی، مقادیر پایه‌ی لگاریتم‌ها باعث تغییر واحد اندازه‌گیری می‌شود. در پژوهش حاضر، برای شانون از لگاریتم مبنای ۲ و برای سایرین از لگاریتم طبیعی استفاده شده است، که به ترتیب برای آنها واحدهای بیت و نات را می‌سازد.[۲۶] مقدار α در فرمول شانون برابر با ۱ در نظر گرفته می‌شود، ولی برای آنتروپی‌های تی‌سالیس و رنی با استفاده از روش سعی و خطا، به ترتیب مقادیر ۴ و ۱۲ محاسبه شده است.

پس از استخراج ویژگی‌های حساس به آسیب، آنها در فرم یک ماتریس جهت ارائه به شبکه‌ی عصبی آماده شدند. در آزمایش حالت‌های سالم و آسیب‌دیده، همان‌طورکه پیشتر بیان شد، پل تحت ۳ نوع بارگذاری با ۵ برداشت برای هرکدام از آنها قرارگرفت. با گزینش سیگنال‌های ثبت شده و حذف برداشت‌های دارای خطا، ۲۸ برداشت برای حالت‌های سالم و ۶۹ برداشت برای حالت‌های آسیب‌دیده با هدف آموزش شبکه انتخاب شدند؛ که از آنها فقط جهت آموزش شبکه‌ی عصبی استفاده شده است.

کلاً با توجه به گزینش ۹۷ سیگنال در مجموع حالت‌های سالم و آسیب‌دیده، ماتریس مذکور دارای ۹۷ سطر بوده است. همچنین با استخراج ۱۷ ویژگی آماری از هر یک از ۴ حسگر، مجموعاً ۶۸ ویژگی از هر سیگنال در اختیار بود، که ستون‌های ماتریس را تشکیل می‌دادند. یک ستون در آخر نیز به تعیین وضعیت پل که در حالت سالم یا آسیب‌دیده است، اختصاص داده شد و داده‌ها از این طریق برچسب‌گذاری شدند. در نهایت، ماتریس ویژگی‌ها با ابعاد (۶۹×۹۷) به‌عنوان ماتریس ورودی به شبکه‌ی عصبی ارئه شد. پیش از آنکه شبکه‌ی عصبی پیشنهادی با داده‌های موجود در ماتریس ویژگی‌ها آموزش ببیند، نرمال‌سازی نیز که یکی از فرایندهای پیش‌پردازشی است، با هدف مقایسه‌ی منصفانه‌ی داده‌ها با یکدیگر صورت پذیرفت.

۶.۲. پردازش سیگنال‌ها با استفاده از تبدیل موجک تجربی

به‌منظور تعیین موقعیت مکانی آسیب در پل خرپایی، این بار پیش از انجام فرایند استخراج ویژگی، سیگنال‌ها با استفاده از تبدیل موجک تجربی پردازش و به مودهای

جدول ۴. ویژگی‌های آماری استخراج شده.

ردیف	ویژگی	فرمول ریاضی	ردیف	ویژگی	فرمول ریاضی
۱	آنتروپی شنون	$SE = -\sum_{n=1}^{N} p_n \log_2 p_n^{\alpha}$	۱۰	فاصله قله تا قله	$PPV = \max(x(n)) - \min(x(n))$
۲	آنتروپی تی سالیس	$TE = \frac{-1}{\alpha-1}\ln(1-\sum_{n=1}^{N} p_n^{\alpha})$	۱۱	میانگین	$M = \frac{1}{N}\sum_{n=1}^{N} x(n)$
۳	آنتروپی رنی	$RE = \frac{1}{1-\alpha}\ln\sum_{n=1}^{N} p_n^{\alpha}$	۱۲	واریانس	$\sigma^2 = \frac{1}{N}\sum_{n=1}^{N}(x(n)-M)^2$
۴	ضریب چولگی	$Sk = \frac{1}{N}\sum_{n=1}^{N}(\frac{x(n)-M}{\sigma})^3$	۱۳	انحراف معیار	$\sigma = \sqrt{\frac{\sum_{n=1}^{N}(x(n)-M)^2}{N}}$
۵	کشیدگی	$Kurt = \frac{1}{N}\sum_{n=1}^{N}(\frac{x(n)-M}{\sigma})^4$	۱۴	عامل ایمپالس	$Im_f = \frac{PV}{MA}$
۶	دامنه مجذور ریشه‌ها	$SRA = (\frac{1}{N}\sum_{n=1}^{N}\sqrt{\lvert x(n)\rvert})^2$	۱۵	عامل حاشیه	$Ma_f = \frac{PV}{SRA}$
۷	دامنه میانگین	$MA = \frac{1}{N}\sum_{n=1}^{N}\lvert x(n)\rvert$	۱۶	عامل شکل	$Sh_f = \frac{RMS}{MA}$
۸	جذر مجموع مربعات	$RMS = \sqrt{(\frac{1}{N}\sum_{n=1}^{N}(x(n))^2)}$	۱۷	عامل کرست	$Cr_f = \frac{PV}{RMS}$
۹	بیشینه مقدار	$PV = \max(\lvert x(n)\rvert)$			

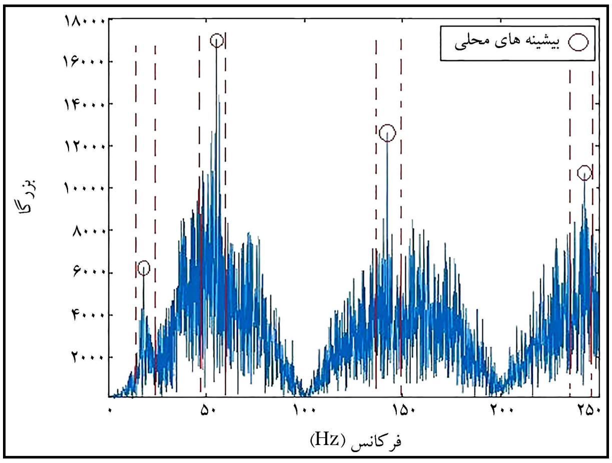

شکل ۹. مرزهای شناسایی شده با استفاده از بیشینه‌های محلی طیف سیگنال حاصل از تبدیل فوریه‌ی سریع.

معنی‌دار تشکیل‌دهنده‌ی خود تجزیه شدند. این تبدیل با استفاده از جعبه‌ی ابزار متلب صورت پذیرفت. در این فرایند، ابتدا با استفاده از تبدیل فوریه‌ی سریع، سیگنال‌های حوزه‌ی زمان به حوزه‌ی بسامد انتقال داده شدند و تعداد بیشینه‌های محلی آنها تعیین شد. مرزهای تقسیم‌بندی و ۴ بیشینه‌ی محلی در طیف فوریه‌ی حاصل از پاسخ شتاب پل در شکل ۹ مشاهده می‌شود. در ادامه، پاسخ‌های ارتعاشی پل با استفاده از روش تبدیل موجک تجربی تجزیه شدند، که خروجی آنها را تابع مقیاس ذاتی و N عدد موجک تشکیل داده است، که تعداد موجک‌های مذکور با استفاده از تعداد مهم‌ترین بیشینه‌های محلی در بزرگای تبدیل فوریه سیگنال تعیین شده است.

رویکرد تعیین تعداد مودها توسط تبدیل موجک تجربی، تعداد مودها را به نسبت بیشینه‌های محلی، بیش از حد برآورد می‌کند، تا تمامی بیشینه‌های محلی را مطابق پژوهش گیلس[17] (۲۰۱۳)،[27] بتواند حفظ کند. بنابراین، تعداد مودهای پاسخ پل توسط EWT، ۵ عدد برآورد شده است. در نهایت، با استفاده از تبدیل موجک تجربی سیگنال‌ها به تعداد سطوحی که معنادار بودند، تجزیه شدند (شکل ۱۰).

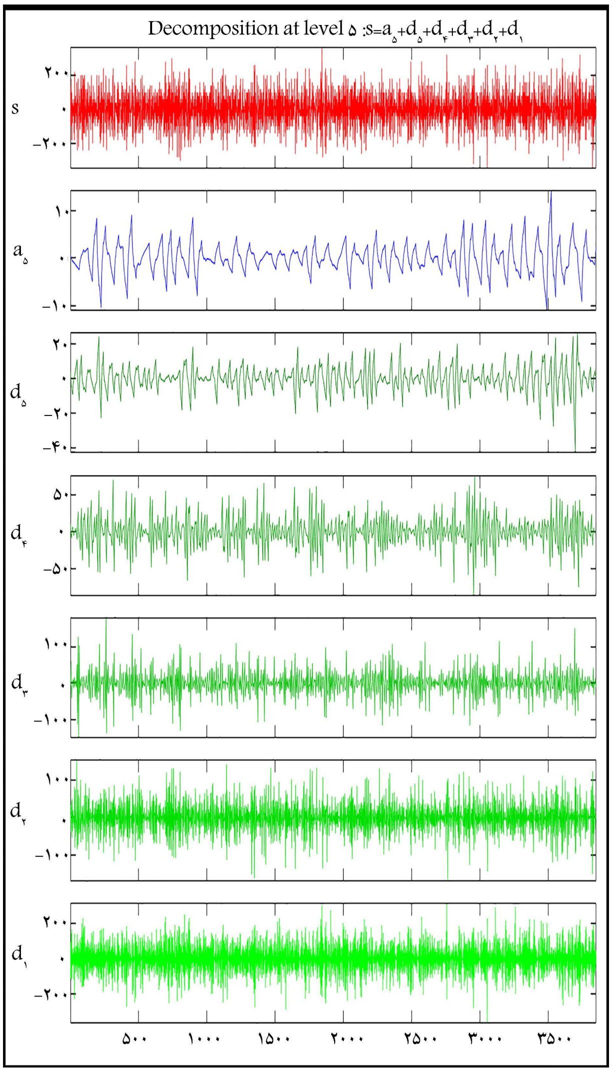

شکل ۱۰. مودهای تجزیه شده‌ی سیگنال توسط تبدیل موجک تجربی.

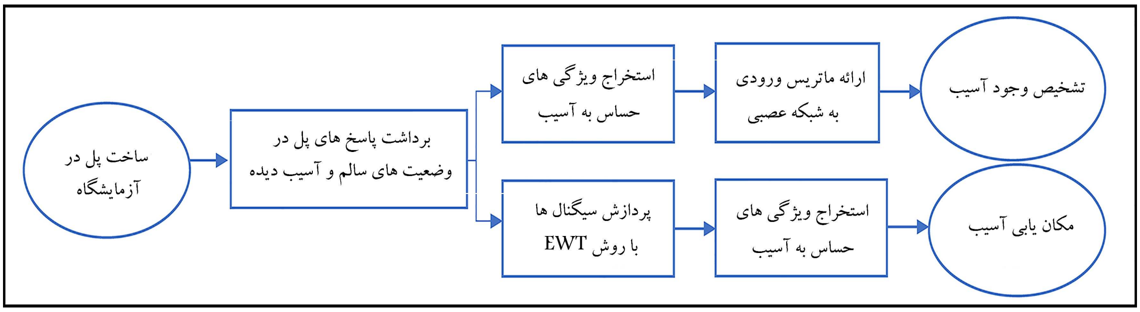

شکل ۱۱. فلوچارت روش پیشنهادی.

پس از پردازش، فرایند استخراج ویژگی از مودهای معنی‌دار حاصل از تجزیه‌ی سیگنال‌ها آغاز شد. ۵ ویژگی آماری، شامل: آنتروپی‌شانون، آنتروپی تی‌سالیس، کشیدگی، جذر مجموع مربعات و عامل شکل در کنار یک ویژگی دیگر با عنوان انرژی سیگنال، استخراج شدند. رابطه‌ی انرژی سیگنال در رابطه‌ی ۳ و فرمول‌های مربوط به پنج ویژگی دیگر در جدول ۳، که مربوط به ویژگی‌هاست، ارائه شده است.

$$E = \int_{0}^{t} x^{2}(t)dt \qquad (۳)$$

با توجه به پژوهش‌های پیشین صورت گرفته، با هرگونه تغییر ناگهانی در شدت سیگنال ارتعاش متناسب با پیشرفت یک خطا یا آسیب در سیستم، مقادیر انرژی، جذر مجموع مربعات و به سبب آن عامل شکل سیگنال افزایش می‌یابند.

۷.۲. طراحی شبکه‌ی عصبی مصنوعی

در پژوهش حاضر، یک شبکه‌ی عصبی از نوع پرسپترون چندلایه در نرم‌افزار متلب تهیه شد، که با هدف بهبود توانایی آن در تعیین پارامترهای مربوط به وزن توابع خود، با الگوریتم ژنتیک که یک الگوریتم بهینه‌سازی تکاملی است، ترکیب شد. در الگوریتم ژنتیک با روش سعی و خطا، جمعیت اولیه برابر با ۱۵۰ و تعداد نسل‌ها برابر با ۵۰ نسل در نظر گرفته شد. همچنین نرخ‌های انتخاب طبیعی، تقاطع یا ترکیب نسل و جهش به ترتیب برابر با ۲۰، ۵۰ و ۳۰ درصد تعیین شدند.

برای تعلیم شبکه‌ی عصبی از الگوریتم گرادیان مزدوج مقیاس شده[18] استفاده شد. بهینه‌ترین تعداد لایه‌ها و نورون‌ها توسط روش سعی و خطا تعیین شدند، که بر این اساس شبکه، دو لایه‌ی پنهان و در هر لایه به ترتیب ۵ و ۳ نورون داشت. همچنین تابع فعال‌ساز در هر لایه‌ی آن، تابع Tan-sigmoid (تانژانت هیپربولیک) بوده است. ابعاد ماتریس ورودی (۹۷ × ۶۹) و ماتریس تارگت (۲ × ۱) بود، که وضعیت سلامت پل را مشخص می‌کند. پس از طراحی ساختار اصلی شبکه، ۷۰٪ داده‌ها جهت آموزش، ۱۵٪ جهت اعتبارسنجی و ۱۵٪ نیز جهت آزمایش شبکه اختصاص یافتند، که این مقادیر به‌صورت تصادفی انتخاب شده‌اند.

در فلوچارت شکل ۱۱، روش پیشنهادی در پژوهش حاضر برای رسیدن به اهداف تشخیص وجود آسیب و مکانیابی آن مشاهده می‌شود.

۳. نتایج

۱.۳. تشخیص وجود آسیب

در شکل ۱۲، نمودار وضعیت نحوه‌ی کاهش خطا در عملکرد شبکه در هر یک

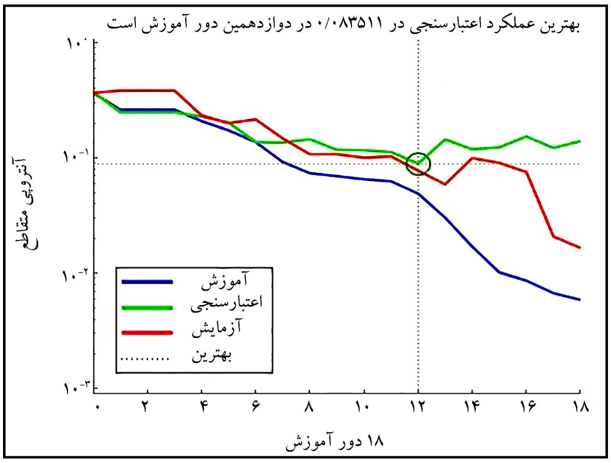

شکل ۱۲. نمودار وضعیت عملکرد شبکه‌ی عصبی.

از فرایندهای خود مشاهده می‌شود. نتایج حاکی از آن است که شبکه در مرحله‌ی دوازدهم از فرایند آموزش خود، بهترین عملکرد اعتبارسنجی را از خود نشان داده است. محور قائم میزان آنتروپی را نشان می‌دهد. عملکرد تابع آنتروپی بدین گونه است که حدس‌های اشتباه شبکه را به شدت مجازات می‌کند، در حالی که برای حدس‌های نسبتاً صحیح، جریمه‌ی اندکی را در نظر می‌گیرد. لذا کمینه‌سازی آنتروپی منجر به یک طبقه‌بندی با دقت زیاد خواهد شد. مقدار ایده‌آل آنتروپی متقاطع صفر بوده و مقادیر کمتر از ۰/۲، از نظر کیفی، خوب تلقی شده‌اند. نتایج به دست آمده از اعتبارسنجی، دقت خوب ۰/۰۸ را نشان می‌دهد.

منحنی برازندگی در شکل ۱۳، بیانگر نحوه‌ی عملکرد الگوریتم ژنتیک در بهینه‌سازی وزن‌های شبکه‌ی عصبی است. با جمعیت آغازین ۱۵۰ نفر و ۵۰ نسل و با نرخ‌های انتخاب طبیعی، ترکیب نسل و جهش به ترتیب برابر با ۲۰، ۵۰ و ۳۰ درصد توانست برای آموزش شبکه با استفاده از داده‌های آموزشی، خطا را به مقدار ۰/۰۷۴۹ نزدیک سازد، که عملکرد مناسبی را در این زمینه از خود ارائه داده است. در قسمت پایین تصویر مشاهده می‌شود که وضعیت تمامی داده‌ها در آخرین حالت وزن‌دهی به چه مقدار از خطای صفر فاصله دارند.

نمودار هیستوگرام در شکل ۱۴، خطاهای موجود میان مقادیر هدف و مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی را پس از طی کردن فرایند آموزش نشان می‌دهد. از آنجا که این مقادیر خطا، اختلاف مقادیر پیش‌بینی شده با مقادیر هدف را نشان می‌دهند، می‌توانند منفی نیز باشند. همان‌طور که مشاهده می‌شود، بیشتر خطاها در نزدیکی خطای صفر قرار گرفته‌اند، که نشان‌دهنده‌ی خطای کم شبکه‌ی عصبی در پیش‌بینی مقادیر است.

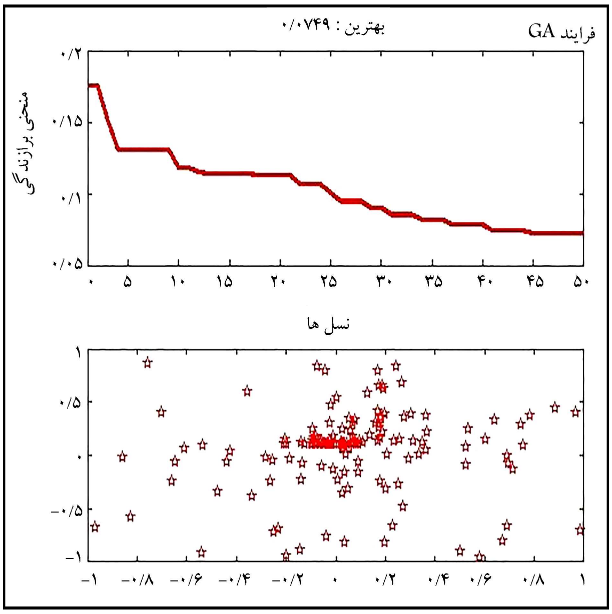

شکل ۱۳. منحنی برازندگی مربوط به عملکرد الگوریتم ژنتیک.

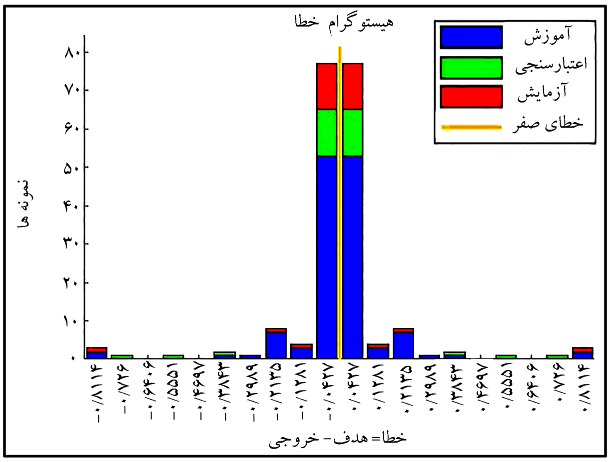

شکل ۱۴. هیستوگرام خطا.

منحنی مشخصه‌ی عملکرد یا ROC، رابطه‌ی بین نرخ مثبت واقعی (TPR) و نرخ مثبت کاذب (FPR) را برای مدل نشان می‌دهد. TPR نرخی است که شبکه‌ی عصبی برای داده‌های وضعیت سالم پل، به درستی سالم پیش‌بینی کرده است، ولی FPR در واقع نرخی است که در آن شبکه‌ی عصبی برای داده‌های وضعیت آسیب‌دیده، به اشتباه، شرایط سالم را پیش‌بینی کرده است. مقادیر نرخ مثبت واقعی و مثبت کاذب مطابق روابط ۴ و ۵ محاسبه شده‌اند:

$$TPR = \frac{TP}{TP+FN} \qquad (۴)$$

$$\mathrm{FPR} = \frac{FP}{TN+FP} \qquad (۵)$$

وضعیت منحنی ROC، که در شکل ۱۵ مشاهده می‌شود، حاکی از آن است که عملکرد شبکه در تعیین کلاس‌های هر داده، با هدف طبقه‌بندی در دو گروه سالم و آسیب‌دیده، دقت بسیار خوبی دارد و نمودارها نرخ مثبت کاذب اندکی را گزارش کرده‌اند.

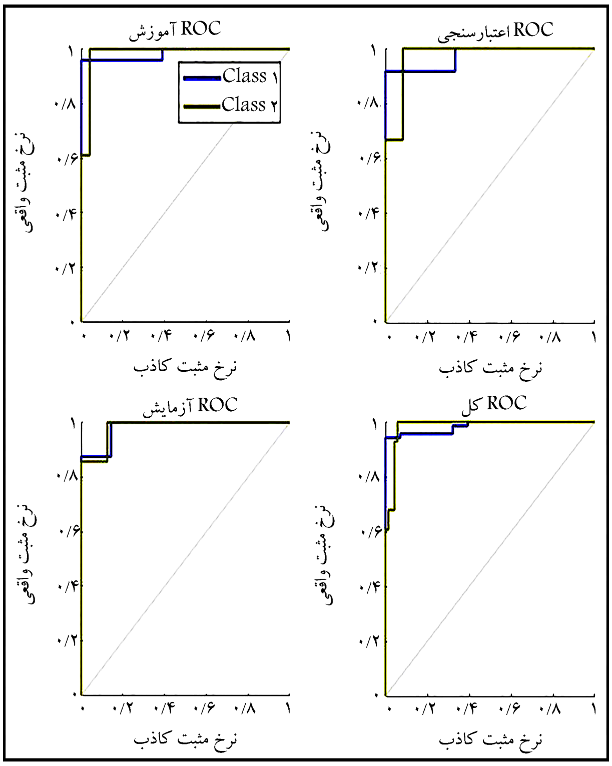

شکل ۱۵. منحنی مشخصه‌ی عملکرد.

در شکل ۱۶، ماتریس درهم‌ریختگی[۱۹] عملکرد الگوریتم طبقه‌بندی مشاهده می‌شود، که در هر سلول تعداد کل مشاهده‌ها نمایش داده شده است.

ردیف‌های ماتریس درهم‌ریختگی، با کلاس واقعی داده‌ها و ستون‌ها با کلاس پیش‌بینی شده مطابقت دارند. هر چقدر این ماتریس قطری باشد، دقت روش نیز بیشتر خواهد بود. برای ارزیابی معیارهای حساسیت، خاصیت، دقت و صحت در ماتریس درهم‌ریختگی به ترتیب از روابط ۶ الی ۹ استفاده شده است.

$$Sensitivity = \frac{TP}{TP+FN} \qquad (۶)$$

$$Specificity = \frac{TN}{TN+FP} \qquad (۷)$$

$$Precision = \frac{TP}{TP+FP} \qquad (۸)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \qquad (۹)$$

در پژوهش حاضر، پیش‌بینی صحیح حالت سالم، مثبت واقعی (TP) و پیش‌بینی صحیح حالت آسیب‌دیده، منفی واقعی (TN) است. پیش‌بینی نادرست حالت سالم پل، مثبت کاذب (FP) و پیش‌بینی نادرست حالت آسیب‌دیده، منفی کاذب (FN) است.

عملکرد شبکه در تمامی حالت‌های ممکن ارزیابی شد، که نتایج نهایی در بررسی داده‌ها، نشان‌دهنده‌ی دقت بسیار خوب ۹۴٫۸ درصدی این روش در تشخیص آسیب است.

بررسی نتایج مربوط به ماتریس‌های درهم‌ریختگی در شکل ۱۷ حاکی از آن است که در شرایطی که شبکه بدون استفاده از الگوریتم ژنتیک و با الگوریتم پیش‌فرض خود، یعنی گرادیان کاهشی، فرایند آموزش را طی کرده است، دقت شبکه‌ی عصبی در تشخیص وضعیت سلامت پل کاهش یافته است.

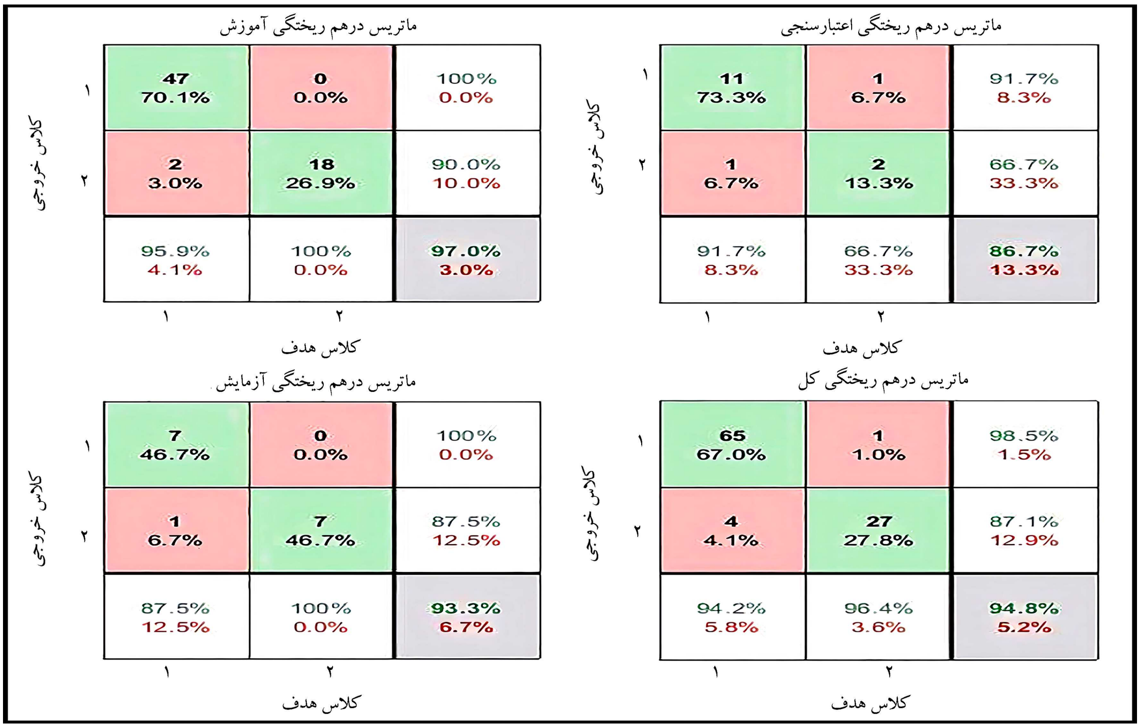

شکل ۱۶. ماتریس درهم‌ریختگی شبکه عصبی.

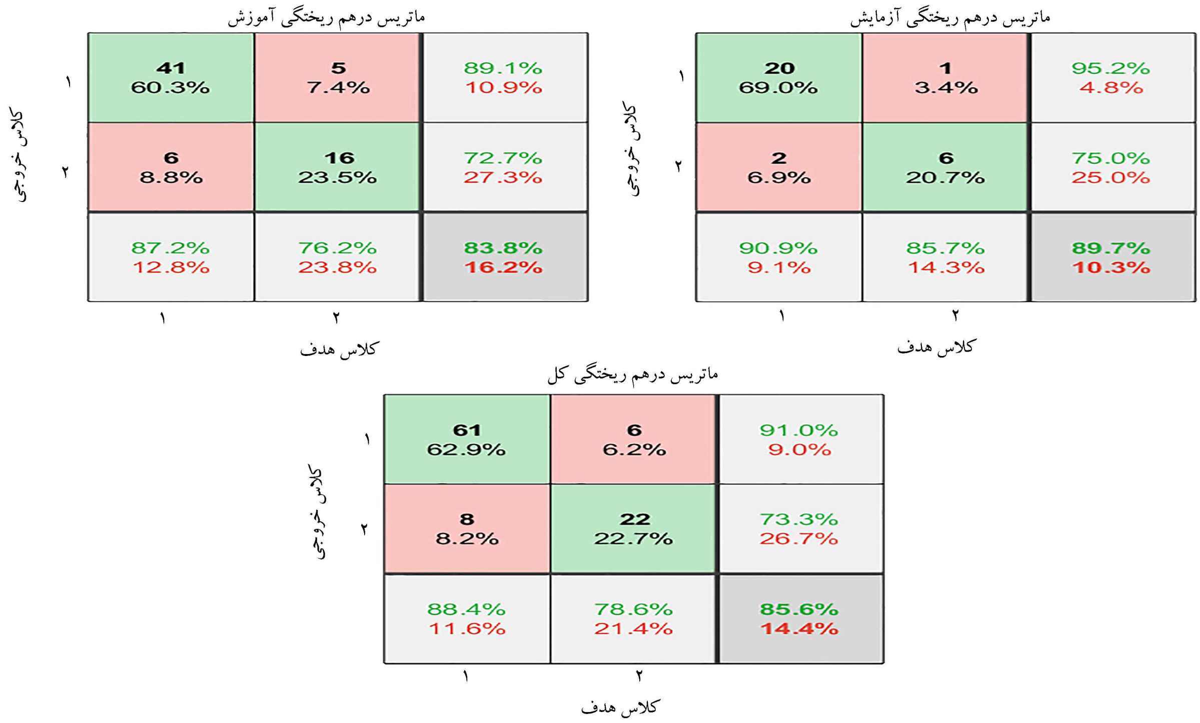

شکل ۱۷. ماتریس درهم‌ریختگی شبکه‌ی عصبی بدون الگوریتم ژنتیک.

۲.۳. مکانیابی آسیب

برای ارزیابی عملکرد روش پیشنهادی در تشخیص موقعیت مکانی آسیب، از سناریوهای خرابی شماره‌های ۲، ۵ و ۶ استفاده شده است. همچنین به جهت بررسی توانایی روش پیشنهادی در تشخیص مکان دو آسیب به‌صورت هم‌زمان، از سناریوی ۷ استفاده و نتایج سناریوها بررسی شده‌اند. داده‌های مربوط به سناریوهای آسیب ذکر شده، در آموزش شبکه حضور نداشتند و فقط از آنها جهت بررسی و آزمایش عملکرد شبکه استفاده شده است. شماتیک سناریوهای خرابی در شکل ۱۸ مشاهده می‌شود.

بررسی نتایج و ویژگی‌های حاصل از حسگرها این موضوع را نشان می‌دهد

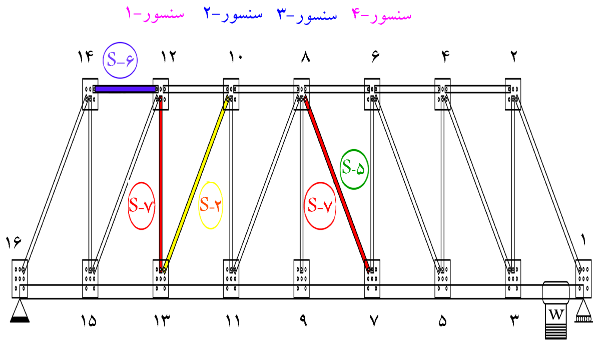

شکل ۱۸. نمایش شماتیک المان‌های آسیب‌دیده در سناریوهای خرابی.

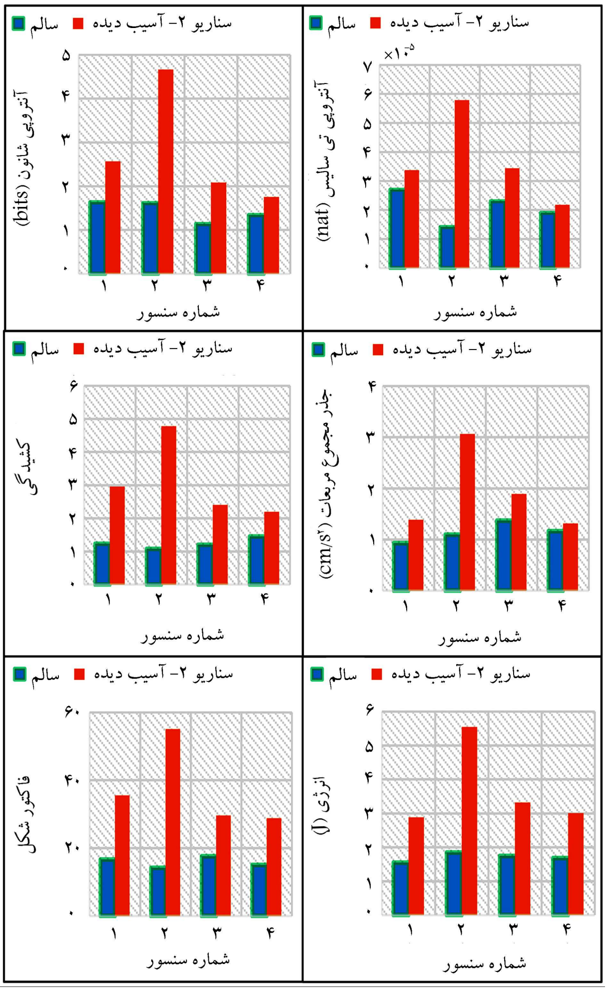

شکل ۱۹. سناریوی آسیب شماره‌ی ۲.

که ویژگی‌های استخراج شده نظیر آنتروپی‌های شانون، تی‌سالیس، کشیدگی، جذر مجموع مربعات، عامل شکل و انرژی هر چقدرکه به محل آسیب نزدیک‌تر می‌شوند، مقادیر آنها افزایش می‌یابد. در سناریو خرابی شماره‌ی ۲، که عضو ۱۳-۱۰ آسیب دیده بود، نزدیک‌ترین حسگرها به آن به ترتیب حسگرهای ۲، ۱، ۳ و ۴ بودند، که با همین ترتیب در شکل ۱۹ تقریباً در تمامی ویژگی‌ها بیشترین مقادیر را داشتند. از ارزیابی ۶ ویژگی برای حالت آسیب‌دیده‌ی پل، مشخص شد که بزرگای همه‌ی ویژگی‌ها در محل آسیب (حسگر ۲) در مقایسه با آنهایی که در دورترین مکان از آسیب (حسگر ۴) بودند، حدود ۱۰۰٪ افزایش یافته است. این رخداد بیشینه در

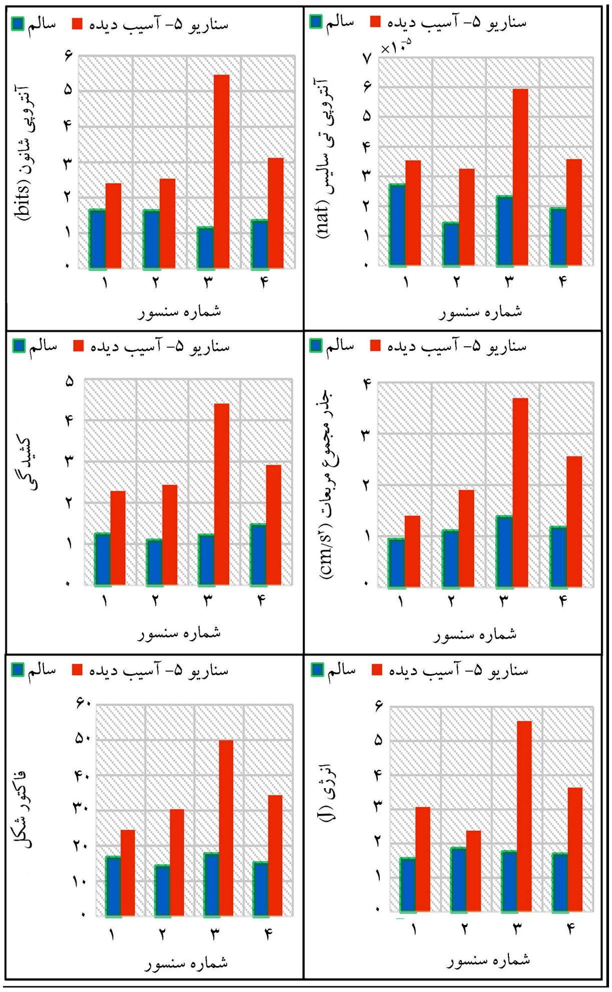

شکل ۲۰. سناریوی آسیب شماره‌ی ۵.

هر حسگر، مکان وقوع آسیب را نمایش می‌دهد.

برای بررسی دقیق‌تر، دو سناریوی دیگر، که شبکه با آنها آموزش ندیده بود، نیز ارزیابی شدند. نتایج تمامی سناریوها حاکی از آن است که ویژگی‌های بررسی شده در نزدیکی محل آسیب به بیشینه‌ی مقدار خود می‌رسند.

در شکل ۲۰، نتایج مربوط به سناریوی ۵ مشاهده می‌شود. مطابق انتظار، با توجه به محل آسیب که عضو ۸-۷ است، در نزدیک‌ترین حسگر، یعنی حسگر شماره‌ی ۳، بزرگای تمامی ویژگی‌ها در حالت آسیب‌دیده به بیشینه‌ی مقدار خود رسیده است. در حسگر شماره‌ی ۱ نیز که دورترین حسگر نسبت به محل آسیب است، بیشتر ویژگی‌ها، کمترین مقدار را نسبت به سایرین داشته‌اند.

در شکل ۲۱، سناریوی شماره‌ی ۶ نیز که مربوط به آسیب عضو فشاری ۱۴-۱۲ است، مشاهده می‌شود؛ که مطابق آن، نزدیک‌ترین حسگر به محل آسیب در پل (حسگر ۱)، بیشترین مقادیر را به خود اختصاص داده است. در نهایت، به‌منظور بررسی توانایی روش پیشنهادی در مکانیابی دو آسیب هم‌زمان، سناریوی شماره‌ی ۷ بررسی شده است. با توجه به المان‌های آسیب‌دیده‌ی ۸-۷ و ۱۳-۱۲ در سناریوی فعلی، رخداد مقادیر بیشینه در حسگرهای شماره‌ی ۱ و ۳، مورد انتظار بود که برآورده نیز شد. با توجه به شکل ۲۲، نتایج حاصل از ویژگی‌های استخراج شده توانستند با دقت بسیار خوبی مکان دو آسیب هم‌زمان در پل را تشخیص دهند.

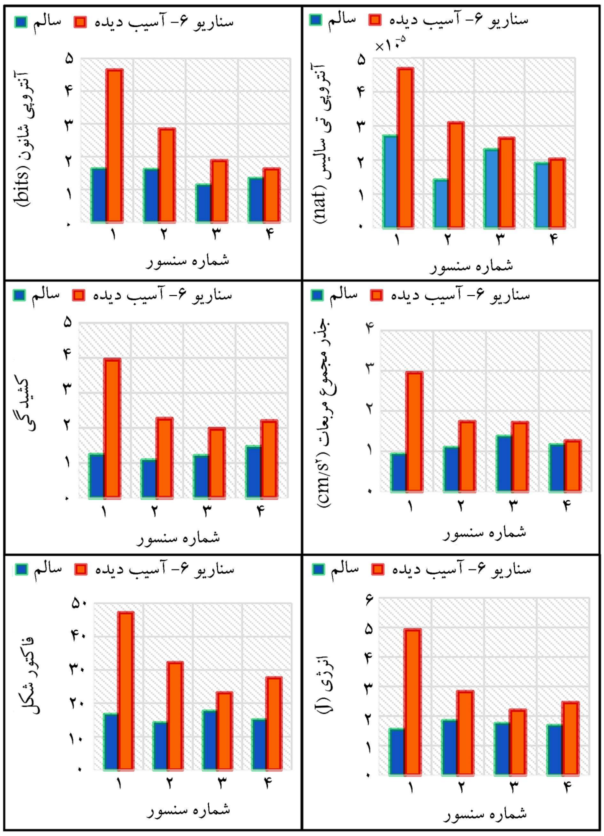

شکل ۲۱. سناریوی آسیب شماره‌ی ۶.

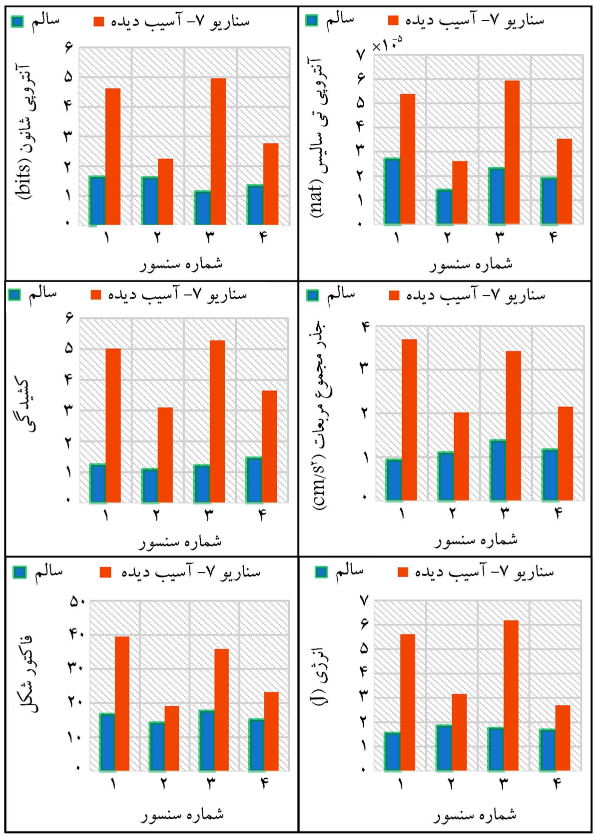

شکل ۲۲. سناریوی آسیب شماره‌ی ۷.

۴. نتیجه‌گیری

هدف پژوهش حاضر، تشخیص آسیب در پل خرپایی با استفاده از شبکه‌ی عصبی مصنوعی و تبدیل موجک تجربی تحت یک بار متحرک بوده است. از این رو یک پل خرپایی دو بُعدی در مقیاس آزمایشگاهی در آزمایشگاه دانشگاه شهید رجایی تهران ساخته شد و پاسخ‌های ارتعاشی پل، توسط ۴ حسگر متصل به آن، تحت بار متحرک اندازه‌گیری شدند. با توجه به رویکرد غیرپارامتریک روش پیشنهادی، به کمک ابزارهای آماری، ۱۷ ویژگی حساس به آسیب در حوزه‌ی زمان از سیگنال‌های خام شتاب ـ زمان پل خرپایی استخراج و در فرم یک ماتریس جهت ارائه به شبکه‌ی عصبی آماده شدند. در نرم‌افزار متلب، یک شبکه‌ی عصبی مصنوعی متشکل از دو لایه‌ی پنهان، به ترتیب با ۵ و ۳ نورون تشکیل‌دهنده طراحی شد و به هر یک از فرایندهای آموزش، اعتبارسنجی و آزمایش آن، تعداد مشخصی داده به‌صورت تصادفی اختصاص داده شد، تا شبکه بتواند مراحل آموزش خود را به درستی طی کند.

ویژگی‌های استخراج شده از پاسخ پل خرپایی مسطح در آزمایشگاه تحت تحریک بار متحرک، به‌عنوان ورودی به شبکه‌ی عصبی ارائه شدند و شبکه‌ی عصبی توانست با دقت ۹۴٫۸٪ وجود آسیب در پل را تشخیص دهد. پس از بررسی نتایج حاصل از عملکرد روش پیشنهادی در پژوهش حاضر، می‌توان این‌گونه نتیجه گرفت که این روش قادر است در صورتی که تعداد داده‌های ورودی به اندازه‌ی معقولی باشد، تشخیص آسیب را تحت بار متحرک با دقت خوبی انجام دهد. این عملکرد خوب شبکه را می‌توان به عنوان تأییدی بر کیفیت ویژگی‌های استخراج شده از سیگنال‌ها نیز تلقی کرد. ویژگی‌های غیرپارامتریک ضمن برخورداری از دقت بالا، کاستی‌های مرتبط با رویکردهای پارامتریک، نظیر آثار دما در پارامترهای مودال و عدم تأثیرگذاری قابل توجه آسیب‌های محلی در جرم، سختی و میرایی مودال سازه را نیز برطرف می‌کنند. برای مکانیابی آسیب، ابتدا به کمک تبدیل موجک تجربی فرایند پردازش سیگنال بر روی پاسخ‌های ارتعاشی پل صورت گرفت. سپس ۵ ویژگی غیرپارامتریک شامل آنتروپی‌های شانون و تی‌سالیس، جذر مجموع مربعات، عامل شکل وکشیدگی به همراه ویژگی انرژی استخراج شدند. این ویژگی‌ها در اثر هر تغییری در تابع چگالی احتمال پاسخ‌های ارتعاشی، ناشی از بروز آسیب و یا هرگونه تغییر ناگهانی در شدت سیگنال ارتعاشی، متناسب با پیشرفت آسیب در سیستم افزایش می‌یابند.

نتایج آزمایش‌های صورت‌گرفته نشان‌دهنده‌ی آن است که به‌طورکلی، مقادیر ویژگی‌ها در حالت‌های آسیب‌دیده به نسبت حالت‌های سالم افزایش یافته و همچنین در نزدیکی محل‌های آسیب نیز تمامی ویژگی‌ها به مقدار بیشینه‌ی خود رسیده‌اند. با در نظر گرفتن مقادیر ویژگی‌ها در حالت آسیب‌دیده‌ی پل، هر چقدر حسگرها از محل آسیب دورتر باشند، این مقادیر متعاقباً برای آن حسگر کاهش می‌یابند. از این‌رو، حسگر دارای بیشترین بزرگا در ویژگی‌های موردنظر، موقعیت مکانی آسیب را تعیین می‌کند. به‌طورکلی، روش پیشنهادی توانست تحت یک بار متحرک با دقت خوبی موقعیت آسیب را شناسایی کند. همچنین در پیش‌بینی آسیب‌های هم‌زمان دوگانه نیز توانست عملکرد خوبی را از خود نشان دهد.

تقدیر و تشکر

بدین‌وسیله از آقای دکتر عابد کردی، که ما را در ساخت پل خرپایی یاری کردند، تشکر و قدردانی می‌شود. همچنین از کمک‌های آقای مهندس هومن شیرده در انجام پژوهش حاضر صمیمانه سپاسگزاری می‌شود.

پانوشت‌ها

1. Global
2. Local
3. Output Only
4. Artificial Intelligence
5. Unsupervised Learning
6. Supervised Learning
7. Activation Function
8. Feedforward Networks
9. Bias
10. Negative Logarithm Likelihood
11. Chun
12. Kourehli
13. N.Jayasundara
14. Corbally
15. MATLAB
16. Linear Potentiometer
17. Gilles
18. Scaled Conjugate Gradient
19. Confusion Matrix

منابع (References)

1. Farrar, C.R., Doebling, S.W. and Nix, D.A., 2001. Vibration-based structural damage identification. *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, *359*(1778), pp.131-149. https://doi.org/10.1098/rsta.2000.0717.

2. Ghannadi, P., Kourehli, S.S. and Mirjalili, S., 2022. The application of PSO in structural damage detection: An analysis of the previously released publications (2005-2020). *Frattura ed Integrità Strutturale*, *16*(62), pp.460-489. https://doi.org/10.3221/IGF-ESIS.62.32.

3. Ghannadi, P., Kourehli, S.S. and Mirjalili, S., 2023. A review of the application of the simulated annealing algorithm in structural health monitoring (1995-2021). *Frattura e Integrita Strutturale*, *64*. https://doi.org/10.3221/IGF-ESIS.64.04.

4. Farrar, C.R. and Worden, K., 2007. An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, *365*(1851), pp.303-315. https://doi.org/10.1098/rsta.2006.1928.

5. Gul, M. and Catbas, F.N., 2008. Ambient vibration data analysis for structural identification and global condition assessment. *Journal of Engineering Mechanics*, *134*(8), pp.650-662. https://doi.org/10.1061/(ASCE)0733-9399(2008)134:8(650).

6. Tseng, K.K. and Naidu, A.S., 2002. Non-parametric damage detection and characterization using smart piezoceramic material. *Smart Materials and Structures*, *11*(3), p.317. https://doi.org/10.1088/0964-1726/11/3/301.

7. Wu, R.T. and Jahanshahi, M.R., 2020. Data fusion approaches for structural health monitoring and system identification: Past, present, and future. *Structural Health Monitoring*, *19*(2), pp.552-586. https://doi.org/10.1177/1475921718798769.

8. Dietterich, T.G., 2000, June. Ensemble methods in machine learning. In International Workshop on Multiple Classifier Systems pp.1-15. Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/3-540-45014-9_1.

9. Santos, A., Figueiredo, E., Silva, M.F.M., Sales, C.S. and Costa, J.C.W.A., 2016. Machine learning algorithms for damage detection: Kernel-based approaches. *Journal of Sound and Vibration*, *363*, pp.584-599. https://doi.org/10.1016/j.jsv.2015.11.008.

10. Bengio, Y., 2013. July. Deep learning of representations: Looking forward. *In International Conference on Statistical Language and Speech Processing*, pp.1-37. Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-39593-2_1.

11. Hastie, T., Tibshirani, R., Friedman, J.H. and Friedman, J.H., 2009. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, *2*, pp.1-758. New York: springer. https://doi.org/10.1007/978-0-387-21606-5.

12. Hakim, S.J.S., Razak, H.A. and Ravanfar, S.A., 2015. Fault diagnosis on beam-like structures from modal parameters using artificial neural networks. *Measurement*, *76*, pp.45-61. https://doi.org/10.1016/j.measurement.2015.08.021.

13. Chun, P.J., Yamashita, H. and Furukawa, S., 2015. Bridge damage severity quantification using multipoint acceleration measurement and artificial neural networks. *Shock and Vibration*, *2015*, pp.1-11. https://doi.org/10.1155/2015/789384.

14. Ghannadi, P. and Kourehli, S.S., 2019. Data-driven method of damage detection using sparse sensors installation by SEREPa. *Journal of Civil Structural Health Monitoring*, *9*, pp.459-475. https://doi.org/10.1007/s13349-019-00345-8.

15. Ghannadi, P. and Kourehli, S.S., 2021. An effective method for damage assessment based on limited measured locations in skeletal structures. *Advances in Structural Engineering*, *24*(1), pp.183-195. https://doi.org/10.1177/1369433220947193.

16. Jayasundara, N., Thambiratnam, D.P., Chan, T.H.T. and Nguyen, A., 2020. Damage detection and quantification in deck type arch bridges using vibration based methods and artificial neural networks. *Engineering Failure Analysis*, *109*, p.104265. https://doi.org/10.1016/j.engfailanal.2019.104265.

17. Sarmadi, H., Entezami, A., Salar, M. and De Michele, C., 2021. Bridge health monitoring in environmental variability by new clustering and threshold estimation methods. *Journal of Civil Structural Health Monitoring*, *11*, pp.629-644. https://doi.org/10.1007/s13349-021-00472-1.

18. Nick, H., Aziminejad, A., Hosseini, M.H. and Laknejadi, K., 2021. Damage identification in steel girder bridges using modal strain energy-based damage index method and artificial neural network. *Engineering Failure Analysis*, *119*, p.105010. https://doi.org/10.1016/j.engfailanal.2020.105010.

19. Mousavi, A.A., Zhang, C., Masri, S.F. and Gholipour, G., 2021. Damage detection and localization of a steel

truss bridge model subjected to impact and white noise excitations using empirical wavelet transform neural network approach. *Measurement*, *185*, p.110060. https://doi.org/10.1016/j.measurement.2021.110060.

20. Corbally, R. and Malekjafarian, A., 2022. A data-driven approach for drive-by damage detection in bridges considering the influence of temperature change. *Engineering Structures*, *253*, p.113783. https://doi.org/10.1016/j.engstruct.2021.113783.
21. Yang, Y.B. and He, Y., 2022. Damage detection of plate-type bridges using uniform translational response generated by single-axle moving vehicle. *Engineering Structures*, *266*, p.114530. https://doi.org/10.1016/j.engstruct.2022.114530.
22. Khanahmadi, M., Gholhaki, M., Rezaifar, O. and Dejkam, B., 2023. Damage identification in steel beam structures based on the comparison of analytical results of wavelet analysis. *Civil Infrastructure Researches*, *8*(2), pp.173-183. [In Persian]. https://doi.org/10.22091/cer.2022.8340.1407.
23. Fallah, N., Hoseini Vaez, S.R. and Esfandiari, A., 2023. Damage detection of steel structures by FEM updating based on strain data. *Sharif Journal of Civil Engineering. Sharif Journal of Civil Engineering*, *39.2*(2), pp.39-49. [In Persian]. https://doi.org/10.24200/j30.2023.61055.3144.
24. Maszczyk, T. and Duch, W., 2008. Comparison of shannon, renyi and tsallis entropy used in decision trees. *In Artificial Intelligence and Soft Computing-ICAISC 2008: 9th International Conference Zakopane*, Poland, June 22-26, 2008 Proceedings 9 (pp. 643-651). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-69731-2_62.
25. Xu, Y. and Zhang, H., 2009. Recent mathematical developments on empirical mode decomposition. *Advances in Adaptive Data Analysis*, *1*(04), pp.681-702. https://doi.org/10.1142/S1793536909000242.
26. Tsallis, C., Mendes, R. and Plastino, A.R., 1998. The role of constraints within generalized nonextensive statistics. *Physica A: Statistical Mechanics and its Applications*, *261*(3-4), pp.534-554. https://doi.org/10.1016/S0378-4371(98)00437-3.
27. Gilles, J., 2013. Empirical wavelet transform. *IEEE Transactions on Signal Processing*, *61*(16), pp.3999-4010. https://doi.org/10.1109/TSP.2013.2265222.