

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

سیاوش شاه محمدی^{۱*}، موسی محمودی صاحبی^۲

^۱ دانش‌آموخته کارشناسی ارشد زلزله، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران
^۲ استاد، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران

پست الکترونیکی نویسندگان:

۱- Siavash.Shahmohammadi@gmail.com

۲- M.Mahmoudi@sru.ac.ir

چکیده:

عوامل بسیاری می‌تواند در طول زمان بهره‌برداری از سازه‌ها منجر به ایجاد آسیب‌های موضعی شود که این آسیب‌ها در پاسخ‌های ارتعاشی آن‌ها نمود پیدا می‌کنند. با هدف تشخیص وجود و تعیین موقعیت مکانی آسیب با استفاده از شبکه 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 حوزه زمانی از سیگنال‌های خام استخراج شدند و برای تشخیص وجود آسیب مورد استفاده قرار گرفتند. این ویژگی‌های حساس به آسیب به عنوان ورودی به شبکه عصبی ارائه گردید و وضعیت سلامت پل (سالم یا آسیب دیده) به عنوان تارگت‌های آن در نظر گرفته شدند. برای مکان‌یابی آسیب نیز پنج ویژگی غیرپارامتریک شامل آنتروپی‌های شانون و تی‌سالیس، جذر مجموع مربعات، فاکتور شکل و کشیدگی، به همراه ویژگی انرژی، از سیگنال‌های پردازش شده پل به کمک تبدیل موجک تجربی، استخراج شدند و مورد استفاده قرار گرفتند. نتایج نشان‌دهنده آن بود که روش پیشنهادی به طور موثری قادر به تشخیص وجود و مکان آسیب در پل تحت بار متحرک می‌باشد.

واژگان کلیدی:

پایش سلامت سازه - تشخیص آسیب - شبکه عصبی مصنوعی - تبدیل موجک تجربی - بار متحرک .

* سیاوش شاه محمدی، دانش‌آموخته کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی
ایمیل: Siavash.Shahmohammadi@gmail.com (نویسنده مسئول مقاله)

Experimental study on damage detection of a truss bridge under moving load using artificial neural network and empirical wavelet transform

S. Shahmohammadi¹, M. Mahmoudi²

¹ M.Sc., Department of Civil Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran.

² Professor, Department of Civil Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran.

Abstract:

Civil structures are always considered one of the most valuable properties of each country. Many factors can lead to local damages in different parts of structures during their operational life. These damages are reflected in the vibration responses of structures. This research aims to detect the existence and determine the location of damage in a truss bridge under moving load using an artificial neural network and experimental wavelet transform. For this purpose, a two-dimensional truss bridge was built in the laboratory to investigate this research's objectives. Earlier experimental studies in damage detection were subjected to excitations such as impact loads and electrodynamic shakers. Since the appearance of damage effects in the vibration responses of the structure mainly depends on the applied location of the impact load, a moving load that crosses the entire length of the bridge can be used as input excitation to detect the presence and location of damages for which there is no available data. After measuring the vibration responses of the bridge, $1\forall$ time-domain features were extracted from the raw signals, which were used to detect the presence of damage. Although feature extraction is applied to raw signals, signal processing stage was not eliminated for damage localization. By processing the response signals of healthy and damaged state of the bridge using experimental wavelet transform, these signals were decomposed into different modes and Δ non-parametric damage-sensitive features such as Shannon and Tsallis entropies, Root Mean Square (RMS), Shape Factor and kurtosis which are all based on statistical parameters in addition to energy, were extracted. Finally, these damage-sensitive features were presented as input to the neural network whereas the state of the bridge (healthy or damaged) was considered as its targets. The obtained results showed that the proposed method is able to effectively detect the presence and the location of the damage in the truss bridge.

Keywords: Structural health monitoring, Damage Detection, ANN, Empirical Wavelet Transform, Moving Load

بین آسیب و تغییرات در ویژگی‌های مودال سازه، تکیه کرده است. روش‌های پارامتریک براساس این فرضیه استوار است که آسیب سازه به طور قابل توجهی بر جرم، سختی و یا میرایی مودال سازه‌ها تأثیر می‌گذارد. در حالی که این فرض به طور کلی قابل درک به نظر می‌رسد، اما برای کاربردهای عملی این روش کاستی‌های شناسایی شده‌اند [۴]. بررسی‌های اخیر نشان داد که انواع خاصی از آسیب‌های سازه‌ای نمی‌توانند همیشه با تغییرات در ویژگی‌های دینامیکی مرتبط باشند، به‌ویژه آنهایی که مربوط به موده‌های پایین ارتعاشی هستند. آسیب سازه‌ای محلی فقط بر موده‌های فرکانسی بالاتر تأثیر می‌گذارد که معمولاً شناسایی آن‌ها با استفاده از روش‌هایی که مبتنی بر خروجی تنها^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 این پارامترها لزوماً نشان دهنده وجود آسیب در سازه نیست [۵].

بر خلاف رویکردهای پارامتریک که بر شناسایی پارامترهای مودال سیستم تکیه دارند، روش‌های غیرپارامتریک تشخیص آسیب، برای تشخیص آسیب سازه‌ای از ابزارهای آماری مستقیماً بر روی پاسخ‌های ارتعاشی اندازه‌گیری شده استفاده می‌کنند. به همین جهت چنین روش‌های غیرپارامتریکی قادر به استخراج ویژگی‌هایی از آسیب هستند که به راحتی نمی‌توان آن‌ها را به تغییرات فیزیکی در سازه نسبت داد. در واقع، نکته قابل توجه در چنین رویکردی امکان استخراج ویژگی‌هایی است که به راحتی در تغییرات رخ داده در پارامترهای دینامیکی قابل تشخیص نیستند [۶].

امروزه با پیشرفت علم، تکنولوژی و ظهور قدرت محاسباتی و همچنین توسعه در زمینه فناوری 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 سازه‌ها می‌باشد که می‌تواند مشکلات روش‌های پیشین این فرایند را برطرف سازد [۷]. یادگیری ماشین به عنوان یکی از اصلی‌ترین زیر شاخه‌های هوش مصنوعی، پژوهش‌ها و مطالعات زیادی را در زمینه تشخیص آسیب به خود اختصاص داده است.

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

روش‌های تشخیص آسیب عمدتاً به دو دسته سراسری^۱ و محلی^۲ طبقه بندی می‌شوند. روش‌های محلی به تنهایی برای پایش سلامت سازه‌های عمرانی در ابعاد بزرگ کفایت نمی‌کند. در نتیجه، چنین محدودیتی استفاده از روش‌های تشخیص سراسری را الزام‌آور 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 فرکانس‌های طبیعی و شکل مودها را برای شناسایی تغییراتی که نشان‌دهنده آسیب سازه‌ای هستند، تجزیه و تحلیل می‌کنند [۲]. استفاده از داده‌های ارتعاشی برای تشخیص آسیب چندین مزیت دارد. نخست آنکه امکان تشخیص زود هنگام آسیب‌ها و امکان تعمیر یا تعویض سریع اجزای آسیب‌دیده را فراهم می‌کند. این رویکرد پیشگیرانه می‌تواند از وخامت بیشتر و بلایای انسانی بالقوه جلوگیری کند. علاوه بر این، شناسایی زود هنگام آسیب‌ها می‌تواند با به حداقل رساندن هزینه‌های تعمیر و جلوگیری از خرابی‌های سازه‌ای گسترده‌تر، به مزایای اقتصادی منجر شود [۳].

رویکردهای متفاوتی در زمینه نوع ویژگی استخراج شده در این روش‌ها وجود دارد که آن‌ها را میتوان به دو دسته پارامتریک و غیرپارامتریک تقسیم کرد. اساس روش‌های پارامتریک بر وجود رابطه

^۱ Output Only

^۲ Artificial Intelligence

^۱ Global

^۲ Local

ارزیابی مناسب بودن مدل شبکه عصبی از منظر توانایی در پیش‌بینی مقادیر جدید است [۱۰].

تابع آنتروپی پرکاربردترین تابع اتلاف در دسته‌بندی داده‌ها است. این تابع با دور شدن مقادیر پیش‌بینی از مقادیر مورد انتظار پیش‌بینی افزایش و با کاهش این فاصله کاهش می‌یابد که آن را به صورت لگاریتمی ارزیابی می‌کند و از این رو به آن تابع شبه لگاریتمی منفی^۹ نیز می‌گویند. در واقع مزیت تابع آنتروپی آن است که نسبت به هر دو نوع خطا واکنش مشخصی از خود نشان می‌دهد. معادله (۱) مربوط به تابع آنتروپی متقاطع دودویی و معادله (۲) مربوط به تابع آنتروپی متقاطع است که در آن‌ها y' مقدار پیش‌بینی شده، y مقدار حقیقی و M تعداد کلاس‌ها می‌باشد.

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

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

حکیم و همکاران^{۱۰} در سال ۲۰۱۵ یک تیر I شکل با شرایط تکیه‌گاهی دو سرگردار تحت یک تحریک نويز را به کمک شبکه عصبی آسیب‌شناسی کردند. با استفاده از فرکانس‌های طبیعی پنج مود اول تیر، عملکرد مطلوبی در تشخیص آسیب از خود به‌جای گذاشت اما در سناریوهای آسیب دوگانه دقت کافی نداشت [۱۲]. در یک مطالعه عددی چون و همکاران^{۱۱} 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 محاسبه مقادیر حداکثر و واریانس سیگنال‌های شتاب اندازه‌گیری شده انجام و سپس این مقادیر توسط شبکه عصبی پردازش شدند که منجر به نتایجی با دقت بالا شد. [۱۳].

در سال ۲۰۱۹، قنادی و کورهللی [۱۴] روشی مبتنی بر داده برای تشخیص آسیب با استفاده از سنسورهای پراکنده را ارائه کردند. یکی از چالش‌های مهم در مشکلات شناسایی آسیب، فقدان درجات آزادی

به عنوان یک کاربرد هوش مصنوعی، یادگیری ماشین اساساً به سیستم‌ها، توانایی یادگیری و بهبود خودکار عملکرد را از طریق تجربه کردن، بدون آنکه صراحتاً برنامه ریزی شوند را ارائه می‌کند [۸]. الگوریتم‌های یادگیری ماشین را به طور کلی می‌توان به دو گروه الگوریتم‌های یادگیری بدون نظارت^۵ و یادگیری نظارت شده^۶ طبقه‌بندی کرد [۹]. در دو دهه اخیر اکثریت مطالعات در زمینه پایش سلامت به سوی استفاده از یادگیری ماشین و شبکه‌های عصبی مصنوعی، به علت قدرت محاسباتی و سرعت عملی که در اختیار قرار می‌دهند، حرکت کرده‌است. شبکه‌های عصبی نیز به عنوان یکی از روش‌های یادگیری ماشین، امروزه انواع مختلفی دارند. یکی از پایه‌ای‌ترین انواع شبکه‌های عصبی، مدل پرسپترون چند لایه است که به اختصار MLP نامیده می‌شود. پرسپترون اولین نمونه از نورون‌های مصنوعی مطابق با سلول‌های مغز انسان می‌باشد. عملکرد این نورون مصنوعی اولیه که پرسپترون نامیده می‌شود، این‌گونه است که با دریافت تعدادی ورودی، بر روی آن‌ها عملیات تجمیع را اعمال کرده و سپس خروجی عملیات تجمیع به تابعی تحت عنوان تابع فعال‌ساز^۷ ارائه می‌شود. در انتها نیز پس از اعمال فرایند تابع فعال‌ساز، داده‌ها به لایه نهایی انتقال می‌یابند [۱۰].

اتصال پرسپترون‌ها به یکدیگر شبکه عصبی چندلایه را تشکیل می‌دهد. در این نوع شبکه عصبی، بیشتر عملکرد شبکه‌ای مغز و انتشار سیگنال در آن مورد توجه بوده 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 لایه ورودی به خروجی، بدون هیچ‌گونه فرایند بازگشتی، جریان پیدا می‌کند. لایه میانی با عنوان لایه مخفی وظیفه اصلی انجام محاسبات و تولید خروجی را بر عهده دارد در این مدل از شبکه‌ها حرکت محاسبات کاملاً رو به جلو بوده و هیچ بازگشتی در محاسبات به منظور کاهش خطا یا اصلاح بایاس انجام نمی‌شود. تابع هزینه یا اتلاف در هر نوبت از اجرای مجدد آموزش شبکه میزان خطای آن را اندازه‌گیری می‌کند. در واقع این تابع، معیاری برای

^۹ Negative Logarithm Likelihood

^{۱۰} Hakim et al.

^{۱۱} Chun et al.

^۵ Unsupervised Learning

^۶ Supervised Learning

^۷ Activation function

^۸ Feedforward Networks

آسیب‌های ناشناخته تنها با استفاده از داده‌های ارتعاشی المان‌های سازه‌ای آسیب دیده پل‌های قوسی استفاده شد [۱۶].

سرمدی و همکاران [۱۷]. در سال ۲۰۲۱ طی پژوهشی به بررسی وضعیت سلامت پل‌ها تحت تغییرات محیطی پرداختند. این مقاله یک روش یادگیری ماشین جدید برای تشخیص آسیب تحت تغییرات محیطی با استفاده از خوشه‌بندی به روش k -medoids، که یک شاخص آسیب جدید و یک رویکرد نوآورانه برای انتخاب تعداد خوشه مناسب است را پیشنهاد می‌کند. برآورد آستانه 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 آستانه هشدار پیشنهاد شد. نتایج نشان داد که روش‌های ارائه‌شده، قادر به تشخیص آسیب اولیه تحت تغییرات شدید محیطی و همچنین برآورد آستانه قابل اعتماد هستند.

در مطالعه‌ای دیگر، یک تکنیک شناسایی آسیب دو مرحله‌ای برای مکان‌یابی و برآورد خسارت در پل‌های با شاه تیر فولادی توسط نیک و همکاران در سال ۲۰۲۱ پیشنهاد شد. عملکرد و امکان‌سنجی روش پیشنهادی با اعمال چندین سناریو آسیب منفرد و چندگانه به مدل المان محدود تایید شده پل I-۴۰ واقع در آمریکا، مورد ارزیابی قرار گرفت. 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 به طور جداگانه محاسبه و بردارهای آسیب محاسبه شده در طول تیرها با هم ترکیب شدند. مقدار پیک شاخص آسیب ترکیبی، محل آسیب را در طول تیر ورق‌های فولادی حتی در صورت وجود سناریوهای آسیب متعدد در تیر ورق‌ها با دقت مناسبی نشان داد. در مرحله دوم از شبکه عصبی مصنوعی برای برآورد شدت آسیب استفاده شد. پس از آموزش، شبکه عصبی توانست شدت آسیب‌های سازه‌ای را پیش‌بینی کند. نتایج حاکی از دقت مناسب ارائه شده توسط شبکه عصبی مصنوعی برای تخمین میزان آسیب و همچنین عملکرد مناسب روش پیشنهادی بود [۱۸].

در طی پژوهشی موسوی و همکاران نیز، در سال ۲۰۲۱ با هدف تشخیص آسیب، یک پل خرابی ۳ بعدی را در آزمایشگاه یک بار

اندازه‌گیری شده و محدودیت سنسورهای نصب شده بر روی سازه است. رویکرد جدید این مطالعه استفاده از داده‌های شکل مودهای توسعه‌یافته برای آموزش شبکه عصبی مصنوعی بود که این اشکال توسط SEREPa، یک روش غیر هموار و محافظ داده، گسترش یافتند. سپس ANN از طریق داده‌های توسعه یافته به عنوان ورودی، مکان و شدت آسیب به عنوان خروجی آموزش داده شد. نتایج پیش‌بینی خسارت دقت قابل قبول روش پیشنهادی را نشان داد.

قنادی و کوره‌لی [۱۵] همچنین در سال ۲۰۲۰ روشی موثر برای ارزیابی آسیب در سازه‌های اسکلتی بر اساس محدودیت مکان‌های اندازه‌گیری پاسخ با استفاده از مدل تحلیل آزمون مودال و شبکه‌های عصبی مصنوعی پیشنهاد کردند. این پژوهش بر روی یک تیر طره صورت گرفت که در آن از مدل تحلیل آزمون مودال به منظور تخمین درجات آزادی اندازه‌گیری نشده استفاده شد. در نهایت نتایج نمایانگر دقت بالای مدل تحلیل آزمون مودال و شبکه عصبی مصنوعی برای تشخیص آسیب سازه‌ای بود.

جایاسوندارا و همکاران^{۱۲} در مقاله‌ای در سال ۲۰۲۰، یک روش مبتنی بر ارتعاش را برای پل‌های قوسی که ویژگی‌های ارتعاشی نسبتاً پیچیده‌ای دارند، با هدف تشخیص، مکان‌یابی و کمی‌سازی آسیب‌ها در المان‌های سازه توسعه داده و اعمال کردند. در روش پیشنهادی، اشکال اصلاح‌شده شاخص‌های آسیب که مبتنی بر انعطاف‌پذیری مودال و انرژی کرنش مودال بودند، همراه با فناوری شبکه عصبی مصنوعی برای ارزیابی کلی آسیب استفاده شدند. روش شناسایی و مکان‌یابی آسیب به صورت تجربی اعتبارسنجی شد و یک پل قوسی با دهانه بلند در مقیاس واقعی تحت طیف وسیعی از سناریوهای آسیب قرار گرفت. شاخص‌های آسیب به دست آمده از داده‌های ارتعاشی آلوده به نویز سپس به عنوان داده‌های ورودی برای آموزش و اعتبارسنجی شبکه‌های عصبی استفاده شدند. به همین منظور دو شبکه عصبی به طور جداگانه با استفاده از شاخص‌های آسیب انعطاف‌پذیری مودال و انرژی کرنش مودال آموزش داده شدند و سپس از رویکرد ادغام شبکه برای به دست آوردن نتایج واضح و دقیق برای تشخیص، مکان‌یابی و کمی‌سازی آسیب‌ها استفاده شد. در نهایت سیستم شبکه عصبی آموزش دیده با موفقیت برای شناسایی

^{۱۲} N.Jayasundara

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 در نهایت استفاده از شبکه عصبی مصنوعی صورت پذیرفت که نتایج به دست آمده دقت بالای این روش در تشخیص آسیب را نشان داد [۱۹].

کوربالی و ملک جعفریان در سال ۲۰۲۲ در مقاله‌ای استفاده از یک رویکرد داده محور جدید را برای نظارت بر وضعیت یک پل بتنی پیشنهاد کردند. الگوریتم پیشنهادی از یک شبکه عصبی مصنوعی استفاده می‌کند که برای پیش‌بینی رفتار پل با استفاده از اندازه‌گیری‌های شتاب از چندین گذر یک وسیله نقلیه در حال عبور آموزش داده شده است. یک فرمول ارائه شده بود که اجازه می‌داد تا پاسخ در نقطه تماس بین لاستیک و روسازی از سنجش درون خودرو استنتاج شود. سپس محتوای فرکانسی پاسخ مربوط به نقطه تماس، همراه با سرعت خودرو به عنوان ورودی‌های اولیه به شبکه عصبی استفاده شدند. این شبکه عصبی همچنین برای تشخیص تأثیر دما بر پاسخ سازه آموزش دیده بود. یک شاخص آسیب جدید نیز پیشنهاد شده بود که اجازه می‌داد پیشرفت آسیب در طول زمان قابل مشاهده باشد. نتایج نشان می‌دهد که استفاده از پاسخ نقطه تماس در شبکه عصبی مصنوعی عملکرد بهبود یافته‌ای را نسبت به پاسخ محوری که به طور سنتی مورد استفاده قرار می‌گیرد، ارائه می‌دهد. همچنین نتایج به دست آمده حاکی از آن است که الگوریتم پیشنهادی قادر به تشخیص ترک خوردگی وسط دهانه و یک چهارم دهانه در تمام سرعت‌های در نظر گرفته شده خودرو و همچنین در حضور روسازی ناهموار و شرایط دمایی متغیر است [۲۰].

یانگ و همکاران در سال ۲۰۲۲، از یک وسیله نقلیه آزمایشی تک محور دارای دو چرخ برای تشخیص آسیب در یک پل صفحه‌ای استفاده کردند که این پل در دو انتهای طولی دارای تکیه‌گاه ساده، اما در طرفین جانبی آن آزاد بود. پاسخ وسیله نقلیه ثبت شده به دلیل تأثیر فرکانس‌های وسیله نقلیه که فرکانس‌های پل را تحت الشعاع قرار می‌دادند مورد بررسی قرار گرفت تا در تحلیل طیفی شناسایی شود. در این مطالعه بردار پاسخ انتقالی یکنواخت برای مکان‌یابی آسیب صفحه‌ای ارائه شده است. بردار پاسخ انتقالی یکنواخت برای هر چرخ با در نظر گرفتن چند مود خمشی اولیه به دست آمده از پاسخ نقطه تماس در طول مسیر حرکت آن محاسبه

می‌شود. بر اساس همبستگی بین دو انحنای بردار پاسخ انتقالی یکنواخت ایجاد شده برای چرخ‌های چپ و راست وسیله نقلیه آزمایشی، می‌توان محل هر آسیب را شناسایی کرد. نتایج نشان می‌دهند که روش پیشنهادی در تخمین مکان‌های طولی و وسعت جانبی آسیب‌ها در سازه‌های صفحه‌ای به خوبی کار می‌کند [۲۱].

خان احمدی و همکاران در سال ۲۰۲۲ [۲۲] در یک مطالعه تحلیلی به بررسی آسیب در سازه تیر فولادی با استفاده از مقایسه نتایج تحلیلی آنالیز موجک پرداختند. در این پژوهش مدل سازی عددی تیر فولادی در نرم‌افزار اجزا محدود صورت گرفت و سپس اطلاعات مودال و شکل مودهای سالم و آسیب‌دیده استخراج شدند. تفاوت‌هایی که در مقادیر فرکانس‌های وضعیت اولیه در مقایسه با وضعیت ثانویه 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 منطقه آسیب را نشان دهد و موقعیت آسیب را با خطای کمتر از ۲ درصد شناسایی کند.

فلاح و همکاران نیز در سال ۲۰۲۳ [۲۳] طی پژوهشی یک روش جدید برای شناسایی آسیب سازه‌ها با استفاده از به‌روز رسانی 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، دو سازه‌ی فلزی، شامل یک خرپا و یک قاب دوتبعی دو طبقه‌ی با دو دهانه انتخاب کردند که نتایج آن‌ها نشان‌دهنده عملکرد خوب روش ارائه شده، حتی با وجود خطای اندازه‌گیری، بود. همچنین، مقایسه‌ی روش ارائه شده با روش‌های دیگر نشان داد که نتایج معادله‌ی اشاره شده، حساسیت مناسب‌تری نسبت به دیگر روش‌های کرنش-محور دارد.

هدف پژوهش حاضر تشخیص وجود و مکان‌یابی آسیب در یک پل خرپایی با استفاده از شبکه عصبی مصنوعی و تبدیل موجک تجربی می‌باشد. عمده پژوهش‌های آزمایشگاهی پیشین صورت گرفته در زمینه تشخیص آسیب، تحت تحریکات ورودی نظیر بارهای ضربه‌ای قرار داشتند. همچنین پژوهش‌های اخیر نیز که از نتایج گذر وسیله نقلیه بهره بردند، بر روی پل‌های صفحه‌ای و بتنی صورت گرفته‌اند. تشخیص وجود آسیب‌هایی که از موقعیت مکانی آن‌ها داده‌ای در دسترس نیست می‌تواند با استفاده از یک بار متحرک که طول پل را


به طور کامل طی می‌کند، ممکن گردد. از این رو، به دلیل وابستگی نمود آسیب‌ها در پاسخ سازه به محل اعمال بارهای ضربه‌ای و به منظور نوآوری، در این پژوهش از یک بار متحرک به عنوان تحریک ورودی استفاده شد.

۲- روش تحقیق


۲-۱- مطالعه آزمایشگاهی

برای بررسی روش پیشنهادی در این پژوهش یک پل خرپایی در مقیاس آزمایشگاهی در آزمایشگاه سازه دانشکده عمران در دانشگاه تربیت دبیر شهید رجایی تهران ساخته شد (شکل ۱). المان‌های

خرپایی این پل با استفاده از ورقه‌هایی از جنس نزدیک به فولاد گالوانیزه با ضخامت یک میلی‌متر تهیه شدند. طول خالص اعضای خرپایی برای المان‌های افقی برابر ۲۲۵ و برای المان‌های عمودی برابر ۲۴۰ میلی‌متر اندازه‌گیری شد. تیر زیرین پل یک تیر پیوسته می‌باشد که در سمت راست که نقطه شروع حرکت بار متحرک است، بر روی یک تکیه‌گاه غلتکی و در سمت چپ بر روی یک تکیه‌گاه مفصلی قرار دارد. فاصله بین دو تکیه‌گاه پل برابر ۲۰۰۰ میلی‌متر و طول خالص آن برای حرکت بار متحرک ۱۹۰۰ میلی‌متر اندازه‌گیری شده است. برای اندازه‌گیری پاسخ‌های ارتعاشی این پل خرپایی، بر روی آن ۴ عدد سنسور نصب شد (شکل ۲). همچنین به منظور جلوگیری و کاهش تغییر مکان‌های عمود بر صفحه، یال‌های بالایی خرپا با استفاده از یونولیت فشرده، مهار شدند.




شکل ۱: پل خرپایی دو بعدی ساخته شده در آزمایشگاه سازه



شکل ۲: شماتیک پل خرابایی

اتصالات المان‌های خرابایی این پل تماماً از نوع پیچی متصل به ورق گاست می‌باشد. از این رو تمامی این المان‌ها، به غیر از تیر پیوسته زیرین پل، عملکردی مفصلی از خود نشان می‌دهند.


در شکل ۳، جزئیات هندسی مربوط به اتصال المان‌ها به صفحات گاست و همچنین گاست‌ها به تیر اصلی نشان داده شده است.



شکل ۴: جزئیات سطح مقطع (الف) المان‌های خرپایی (ب) تیر


۲-۲- مدل‌سازی عددی

با هدف صحت‌سنجی نتایج حاصل از سیگنال‌های ثبت شده در آزمایشگاه، مدل‌سازی عددی برای پل خرپایی در نرم‌افزار SAP2000، با توجه به مشخصات هندسی و مکانیکی آن صورت پذیرفت (شکل ۵). سپس این مدل تحت تحلیل مودال قرار گرفت و فرکانس‌های طبیعی آن به دست آمدند.



شکل ۵: مدل عددی پل خرپایی - مود اول

برای به دست آوردن فرکانس‌های طبیعی پل آزمایشگاهی نیز در وضعیت سالم پل، داده‌های شتاب-زمان حاصل از سنسورها، در نرم‌افزار متلب، با استفاده از تبدیل فوریه به حوزه فرکانس انتقال یافتند و با روش انتخاب مقادیر بیشینه، فرکانس‌های طبیعی سازه مشخص شدند. نتایج فرکانس‌های طبیعی حاصل از مدل عددی با پل آزمایشگاهی در جدول ۱ مقایسه شدند. نتایج نشان داد که فرکانس‌های طبیعی به دست آمده از مدل‌سازی عددی با توجه به محدودیت‌های مدل‌سازی، از قبیل نوع اتصالات و ضخامت ورق‌های



شکل ۳: جزئیات اتصالات پل خرپایی (الف) گره ۷ (ب) گره ۸

سطح مقطع تمامی المان‌های خرپایی از اتصال دو ورق مستطیلی شکل، که هرکدام یک میلی‌متر ضخامت دارند تشکیل شده است. همچنین تیر زیرین پل نیز از اتصال دو سطح مقطع L شکل تشکیل شده است که در شکل ۴ به جزئیات آن‌ها اشاره شده است.

گاست، به طور قابل قبولی با فرکانس های طبیعی سازه آزمایشگاهی همخوانی دارند.

جدول ۱: مقایسه فرکانس های طبیعی (Hz)


شماره فرکانس	مدل آزمایشگاهی	مدل عددی
۱	۱۹/۹	۲۱/۷
۲	۵۱/۲	۵۶/۷
۳	۷۵/۴	۷۰/۳

۲-۳- بار متحرک


اکثر پژوهش هایی که تا کنون در زمینه شناسایی آسیب در پل ها صورت گرفته است عمدتاً از دو نوع تحریک استفاده می کنند. گروه اول پاسخ های خود را تحت تحریک یک بار ضربه ای، که با استفاده از یک چکش یا هر وسیله مشابه دیگر ایجاد می شود، ثبت می کنند. گروه دوم نیز با استفاده از ابزارهایی نظیر دستگاه های لرزاننده در پل ارتعاش ایجاد کرده و با استفاده از سنسورها مقادیر پاسخ سازه را اندازه گیری می کنند.

در پژوهش حاضر در تلاش برای رفع وابستگی نمود آسیب ها در پاسخ سازه به محل اعمال بارهای ضربه ای، پل خریایی تحت اثر یک بار متحرک قرار گرفت.

این بار متحرک از یک محل نگه دارنده وزنه، گیرنده فرکانسی و چهار عدد چرخ تشکیل شده است و اجزای تشکیل دهنده آن بدون اعمال بار اضافه مجموعاً جرمی برابر با ۶۲۳۰ گرم را دارا می باشد. هر چهار چرخ بار متحرک بر روی تیر پایینی پل قرار گرفتند که در شکل ۶ قابل مشاهده است. فرایند شروع و پایان حرکت اربه نیز با کمک یک کشنده که توسط یک ریموت کنترل از راه دور، کنترل می شود، صورت پذیرفت (شکل ۷).



شکل ۷: گیرنده فرکانسی



شکل ۶: اربه بار متحرک

۲-۴- مشخصات سنسورها و دستگاه رویداد نگار داده

بر روی پل چهار عدد سنسور شامل، دو عدد شتاب سنج تک جهته که شتاب را تنها در یک راستا اندازه گیری می کردند و همچنین دو عدد سنسور پتانسیومتر خطی^{۱۳} جهت اندازه گیری میزان جابه جایی عمودی، مورد استفاده قرار گرفتند. با توجه به ساختار و نحوه عملکرد بار متحرک در هنگام آزمایش و به دلیل محدودیت های آزمایشگاهی تمامی سنسورها بر روی گره های بالایی خریا قرار گرفتند (شکل ۸).

^{۱۳} Linear Potentiometer (LP)

بودند، اعمال شد (جدول ۳). در تمامی سناریوها، آسیب با خارج کردن کامل المان از سیستم باریری صورت پذیرفت.

جدول ۳: سناریوهای آسیب


شماره سناریو	المان آسیب دیده	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 M ۱۲-۱۳	همزمانی سناریوهای ۴ و ۵
DS-۸	N ۱۳	اتصال گره هفتم از سمت راست

۲-۵- 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 تعداد ۱۷ ویژگی آماری انتخاب شدند تا از سیگنال‌های ثبت شده از پاسخ پل در حوزه زمان استخراج شوند. سعی شد این ویژگی‌های آماری به گونه‌ای 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 می‌شود. مقادیر تحت عنوان N بر تعداد داده‌های ثبت شده با توجه به نرخ نمونه‌برداری سنسورها در طول یک سیگنال دلالت دارد که در این آزمایش با توجه به نرخ نمونه‌برداری سنسورهای مورد استفاده، برابر ۵۰۰ در نظر گرفته شد. آنتروپی مقادیر اطلاعاتی از مشاهدات 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

در جدول ۲ به مشخصات فنی آن‌ها پرداخته شده است. اطلاعات و خروجی‌های سنسورها، از طریق یک کابل به دستگاه رویدادنگار داده، محصول شرکت آترون، انتقال یافتند و داده‌ها با نرخ نمونه‌برداری ۵۰۰ هرتز ثبت و ذخیره شدند.



شکل ۸: (الف) شتاب‌سنج (ب) پتانسیومتر خطی

جدول ۲: مشخصات سنسورها

نوع سنسور	تعداد محورها	نرخ پاسخ (Hz)
شتاب‌سنج	تک محوره	۵۰۰

(ب)

نوع سنسور	شرکت سازنده	مدل	محدوده اندازه‌گیری (mm)	دقت اندازه‌گیری (mm)
پتانسیومتر	اپکون	SLPS۵۰	۱۰ - ۱۰۰	۰/۰۱

آماده‌سازی اولیه پل خرابی جهت اجرای تست‌ها انجام شد. به منظور تشخیص آسیب در پل، ابتدا در شرایطی که سازه در حالت سالم قرار گرفته بود، بار متحرک با ۳ نوع سناریو بارگذاری که شامل حالات بدون بار (فقط جرم اجزای تشکیل دهنده بار متحرک بدون بار اضافه)، نیمه بار و حداکثر بار که به ترتیب جرم آن‌ها برابر با ۶۲۳۰ گرم، ۱۳۸۰۰ گرم و ۱۹۶۵۶ گرم بود، به پل اعمال و پاسخ‌های پل برداشت شد. مدت زمان تقریبی هر برداشت بین ۶ تا ۸ ثانیه بود. داده‌های سنسورهای LP پس از انجام تست به نرم افزار متلب ارائه شد و با دو 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 شد.

با همین هدف، ۸ سناریوی آسیب مختلف تحت هر سه سناریوی بارگذاری تعریف و به انواع المان‌های خرابی که تحت فشار و یا کشش

می‌شوند، از این رو مقدار آن‌ها با هر تغییری در تابع چگالی احتمال پاسخ‌های ارتعاشی، ناشی از بروز آسیب، افزایش می‌یابد [۲۵].

آنتروپی شانون متداول‌ترین نوع آنتروپی است. در فرمول هر سه نوع آنتروپی مقادیر پایه لگاریتم‌ها باعث تغییر واحد اندازه‌گیری می‌گردد.

در این پژوهش برای شانون از لگاریتم مبنای دو 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 یک 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.

جدول ۴: ویژگی‌های آماری استخراج شده

ردیف	ویژگی	فرمول ریاضی	ردیف	ویژگی	فرمول ریاضی
۱	آنتروپی شانون	$SE = -\sum_{n=1}^N p_n \log_{\alpha} p_n$	۱۰	فاصله قله تا قله	$PPV = \max(x(n)) - \min(x(n))$
۲	آنتروپی تی‌سالیس	$TE = \frac{-1}{\alpha-1} \ln(1 - \sum_{n=1}^N p_n^{\alpha})$	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	$Sk = \frac{1}{N} \sum_{n=1}^N \left(\frac{x(n) - M}{\sigma} \right)^3$	۱۳	انحراف معیار	$\sigma = \sqrt{\frac{\sum_{n=1}^N (x(n) - M)^2}{N}}$
۵	کشیدگی	$Kurt = \frac{1}{N} \sum_{n=1}^N \left(\frac{x(n) - M}{\sigma} \right)^4$	۱۴	فاکتور ایمپالس	$Im_f = \frac{PV}{MA}$
۶	دامنه مجذور ریشه‌ها	$SRA = \left(\frac{1}{N} \sum_{n=1}^N \sqrt{ x(n) } \right)^2$	۱۵	فاکتور حاشیه	$Ma_f = \frac{PV}{SRA}$
۷	دامنه میانگین	$MA = \frac{1}{N} \sum_{n=1}^N x(n) $	۱۶	فاکتور شکل	$Sh_f = \frac{RMS}{MA}$
۸	جذر مجموع مربعات	$RMS = \sqrt{\left(\frac{1}{N} \sum_{n=1}^N (x(n))^2 \right)}$	۱۷	فاکتور کرس	$Cr_f = \frac{PV}{RMS}$
۹	بیشینه مقدار	$PV = \max(x(n))$			

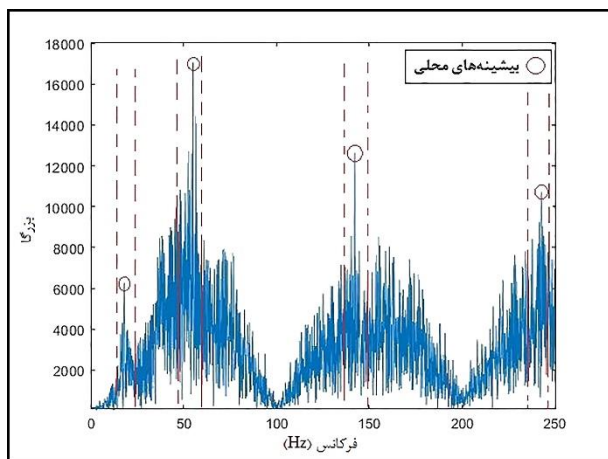
می‌دهند. یک ستون در آخر نیز به تعیین وضعیت پل که در حالت سالم یا آسیب‌دیده است، اختصاص داده شد و داده‌ها از این طریق برچسب‌گذاری شدند. در نهایت ماتریس ویژگی‌ها با ابعاد (۹۷*۶۹) به عنوان ماتریس ورودی به شبکه عصبی ارائه شد. پیش از آن که شبکه عصبی پیشنهادی با داده‌های موجود در ماتریس ویژگی‌ها آموزش ببیند، نرمال‌سازی نیز که یکی از فرایندهای پیش‌پردازشی است، با هدف مقایسه منصفانه داده‌ها با یکدیگر، صورت پذیرفت.

۲-۶- پردازش سیگنال‌ها با استفاده از تبدیل موجک تجربی


به منظور 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 معنی‌دار تشکیل دهنده خود، تجزیه

پس از استخراج ویژگی‌های حساس به آسیب، آن‌ها در فرم یک ماتریس جهت ارائه به شبکه عصبی آماده شدند. در آزمایش حالت‌های سالم و آسیب‌دیده، همان‌طور که پیشتر بیان شد، پل تحت ۳ نوع بارگذاری متفاوت قرار گرفت و از هر نوع بارگذاری آن نیز ۵ برداشت انجام پذیرفت. با گزینش سیگنال‌های ثبت شده و حذف برداشتهای دارای خطا، ۲۸ برداشت برای حالات سالم و ۶۹ برداشت برای حالت‌های آسیب‌دیده با هدف آموزش شبکه، انتخاب شدند. از این برداشتهای صرفاً جهت آموزش شبکه عصبی استفاده شد.

با توجه به گزینش به طور کلی ۹۷ سیگنال در مجموع حالات سالم و آسیب‌دیده، این ماتریس دارای ۹۷ سطر است. همچنین با استخراج ۱۷ ویژگی آماری از هر یک از ۴ سنسور، مجموعاً ۶۸ ویژگی از هر سیگنال در اختیار خواهد بود که ستون‌های ماتریس را تشکیل



شکل ۹: مرزهای شناسایی شده با استفاده از بیشینه‌های محلی طیف سیگنال حاصل از تبدیل فوریه سریع



شکل ۱۰: مدهای تجزیه شده سیگنال توسط تبدیل موجک تجربی

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 فاکتور شکل سیگنال افزایش می‌یابند.

۲-۶- طراحی شبکه عصبی مصنوعی

در این پژوهش یک شبکه 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

شدند. این تبدیل با استفاده از جعبه ابزار متلب صورت پذیرفت. در این فرایند ابتدا با استفاده از تبدیل فوریه سریع، سیگنال‌های حوزه زمان به حوزه فرکانس انتقال داده شدند و تعداد بیشینه‌های محلی این سیگنال‌ها تعیین گردید. مرزهای تقسیم‌بندی و ۴ بیشینه محلی در طیف فوریه حاصل از پاسخ شتاب پل در شکل ۹ مشخص است. در ادامه، پاسخ‌های ارتعاشی پل با استفاده از روش تبدیل موجک تجربی تجزیه خواهند شد. خروجی آن‌ها را تابع مقیاس ذاتی و N عدد موجک تشکیل خواهند داد که تعداد این موجک‌ها با استفاده از تعداد مهمترین بیشینه‌های محلی در بزرگای تبدیل فوریه سیگنال تعیین می‌شود.

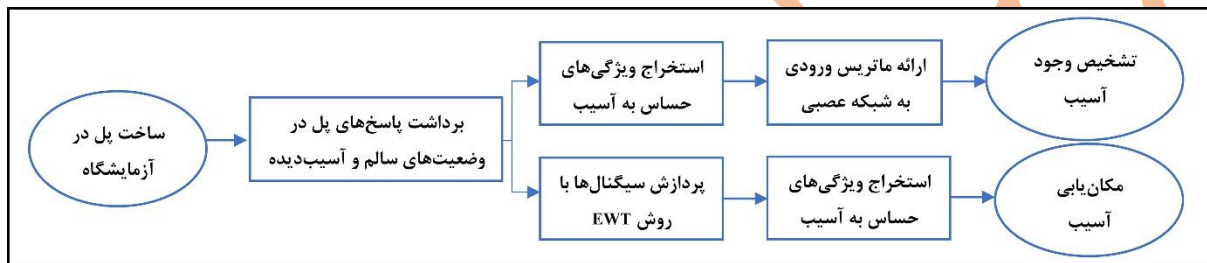
رویکرد تعیین تعداد مدها توسط تبدیل موجک تجربی، تعداد مدها را به نسبت بیشینه‌های محلی، بیش از حد برآورد کرده تا تمامی بیشینه‌های محلی را مطابق پژوهش گیلز [۲۷]، بتواند حفظ کند. بنابراین تعداد مدهای پاسخ پل توسط EWT، ۵ عدد برآورد شده است. در نهایت با استفاده از تبدیل موجک تجربی سیگنال‌ها به تعداد سطوحی که معنادار بودند، تجزیه شدند (شکل ۱۰).

پس از پردازش، فرایند استخراج ویژگی از مدهای معنی‌دار حاصل از تجزیه سیگنال‌ها آغاز شد. ۵ ویژگی آماری شامل آنتروپی شانون، آنتروپی تی‌سالیس، کشیدگی، جذر مجموع مربعات و فاکتور شکل در کنار یک ویژگی دیگر تحت عنوان انرژی سیگنال، استخراج شدند. رابطه انرژی سیگنال در زیر و فرمول‌های مربوط به پنج ویژگی دیگر در جدول ۳ که مربوط به ویژگی‌ها می‌باشد، بیان شده است.

$$E = \int x^2(t) dt \quad (3)$$

(تائزانت هیپرولیک) است. ابعاد ماتریس ورودی (۶۹*۹۷) و ماتریس تارگت (۲*۱) می‌باشد که وضعیت سلامت پل را مشخص می‌کند. پس از طراحی ساختار اصلی شبکه، ۷۰ درصد داده‌ها جهت آموزش، ۱۵ درصد جهت اعتبارسنجی و ۱۵ درصد نیز جهت آزمایش شبکه اختصاص یافتند که این مقادیر به صورت تصادفی انتخاب شدند.

فلوچارت شکل ۱۱ روش پیشنهادی در این پژوهش را برای رسیدن به اهداف تشخیص وجود آسیب و مکان‌یابی آن، نشان می‌دهد.




شکل ۱۱: فلوچارت روش پیشنهادی

نفر و ۵۰ نسل و با نرخ‌های انتخاب طبیعی، ترکیب نسل و جهش به ترتیب برابر با ۵۰،۲۰ و ۳۰ درصد توانست برای آموزش شبکه با استفاده از داده‌های آموزشی، خطا را به مقدار ۰۰۰۷۴۹ نزدیک سازد که عملکرد مناسبی را در این زمینه از خود ارائه داده است. در قسمت پایین تصویر وضعیت تمامی داده‌ها در آخرین حالت وزن‌دهی قابل مشاهده است که به چه مقدار از خطای صفر فاصله دارند.

۳- نتایج

۳-۱- تشخیص وجود آسیب

شکل ۱۲ نمودار وضعیت نحوه کاهش خطا در عملکرد شبکه را در هر یک از فرایندهای خود نشان می‌دهد. نتایج حاکی از آن است که شبکه در مرحله دوازدهم از فرایند آموزش خود بهترین عملکرد اعتبارسنجی را از خود نشان داده است.



شکل ۱۲: نمودار وضعیت عملکرد شبکه عصبی

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 جریمه اندکی را در نظر می‌گیرد. از این رو به حداقل رساندن آنتروپی منجر به یک طبقه‌بندی با دقت زیاد خواهد شد. مقدار ایده‌آل آنتروپی متقاطع صفر است و مقادیر کمتر از ۰،۲، از نظر کیفی، خوب تلقی می‌شوند. نتایج به دست آمده از اعتبارسنجی، دقت خوب ۰،۰۸ را نشان می‌دهد.

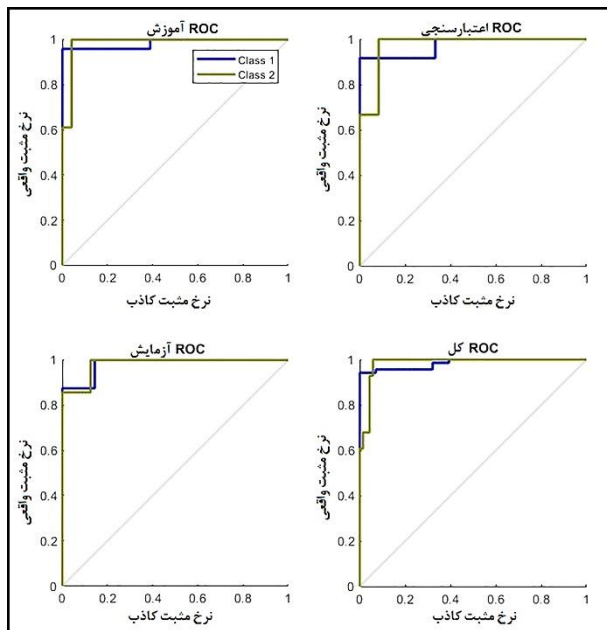
منحنی برازندگی در شکل ۱۳ بیانگر نحوه عملکرد الگوریتم ژنتیک در بهینه‌سازی وزن‌های شبکه عصبی است. با جمعیت آغازین ۱۵۰

است که شبکه عصبی برای داده‌های وضعیت سالم پل، به درستی سالم پیش بینی کرده ولی FPR در واقع نرخ است که در آن شبکه عصبی برای داده‌های وضعیت آسیب‌دیده، به اشتباه، شرایط سالم را پیش‌بینی کرده است. مقادیر نرخ مثبت واقعی و مثبت کاذب از روابط زیر محاسبه شده است.

$$TPR = \frac{TP}{TP + FN} \quad (4)$$


$$FPR = \frac{FP}{TN + FP} \quad (5)$$

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




شکل ۱۵: منحنی مشخصه عملکرد

شکل ۱۶، ماتریس درهم‌ریختگی^{۱۴} عملکرد الگوریتم طبقه‌بندی را به تصویر می‌کشد. در هر سلول تعداد کل مشاهدات نمایش داده شده است. ردیف‌های ماتریس درهم‌ریختگی، با کلاس واقعی داده‌ها و



شکل ۱۳: منحنی برازندگی مربوط به عملکرد الگوریتم ژنتیک

نمودار هیستوگرام در شکل ۱۴، خطاهای موجود میان مقادیر هدف و مقادیر پیش‌بینی شده توسط شبکه 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 قابل مشاهده است اکثر خطاها در نزدیکی خطای صفر قرار گرفته‌اند که نشان دهنده خطای کم شبکه عصبی در پیش‌بینی مقادیر است.



شکل ۱۴: هیستوگرام خطا

منحنی مشخصه عملکرد یا ROC رابطه بین نرخ مثبت واقعی (TPR) و نرخ مثبت کاذب (FPR) را برای مدل نشان می‌دهد. TPR نرخ

^{۱۴} Confusion Matrix

ماتریس درهم‌ریختگی آموزش			ماتریس درهم‌ریختگی آزمایش						
کلاس خروجی	1	41 60.3%	5 7.4%	89.1% 10.9%	کلاس خروجی	1	20 69.0%	1 3.4%	95.2% 4.8%
	2	6 8.8%	16 23.5%	72.7% 27.3%		2 6.9%	6 20.7%	75.0% 25.0%	
		87.2% 12.8%	76.2% 23.8%	83.8% 16.2%			90.9% 9.1%	85.7% 14.3%	89.7% 10.3%
		کلاس هدف				کلاس هدف			

ماتریس درهم‌ریختگی کل				
کلاس خروجی	1	61 62.9%	6 6.2%	91.0% 9.0%
	2	8 8.2%	22 22.7%	73.3% 26.7%
		88.4% 11.6%	78.6% 21.4%	85.6% 14.4%
		کلاس هدف		

شکل ۱۷: ماتریس درهم‌ریختگی شبکه عصبی بدون الگوریتم ژنتیک

عملکرد شبکه در تمامی حالات ممکن مورد ارزیابی قرار گرفت که نتایج نهایی در بررسی داده‌ها، نشان دهنده دقت بسیار خوب ۹۴.۸٪ درصدی این روش در تشخیص آسیب می‌باشد.

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 پیش فرض خود، یعنی گرادیان کاهشی، فرایند آموزش را طی کرده، دقت شبکه عصبی در تشخیص وضعیت سلامت پل کاهش یافته است.

۲-۲- مکان‌یابی آسیب

برای ارزیابی عملکرد روش پیشنهادی در تشخیص موقعیت مکانی آسیب، از سناریوهای خرابی شماره ۲، ۵ و ۶ استفاده گردید. همچنین به جهت بررسی توانایی روش پیشنهادی در تشخیص مکان دو آسیب به صورت همزمان، از سناریوی شماره ۷ استفاده شد و نتایج سناریوها مورد بررسی قرار گرفت. داده‌های مربوط به سناریوهای آسیب ذکرشده، در آموزش شبکه حضور نداشتند و صرفاً از آن‌ها جهت بررسی و آزمایش عملکرد شبکه استفاده شده است. شماتیک سناریوهای خرابی در شکل ۱۸ قابل مشاهده است.

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 زیر بهره برده شده است.

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

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

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

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

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

ماتریس درهم‌ریختگی آموزش			ماتریس درهم‌ریختگی اعتبارسنجی						
کلاس خروجی	1	47 70.1%	0 0.0%	100% 0.0%	کلاس خروجی	1	11 73.3%	1 6.7%	91.7% 8.3%
	2	2 3.0%	18 26.9%	90.0% 10.0%		1 6.7%	2 13.3%	66.7% 33.3%	
		95.9% 4.1%	100% 0.0%	97.0% 3.0%			91.7% 8.3%	66.7% 33.3%	86.7% 13.3%
		کلاس هدف				کلاس هدف			


ماتریس درهم‌ریختگی آموزش			ماتریس درهم‌ریختگی کل						
کلاس خروجی	1	7 46.7%	0 0.0%	100% 0.0%	کلاس خروجی	1	65 67.0%	1 1.0%	98.5% 1.5%
	2	1 6.7%	7 46.7%	87.5% 12.5%		4 4.1%	27 27.8%	87.1% 12.9%	
		87.5% 12.5%	100% 0.0%	93.3% 6.7%			94.2% 5.8%	96.4% 3.6%	94.8% 5.2%
		کلاس هدف				کلاس هدف			

شکل ۱۶: ماتریس درهم‌ریختگی شبکه عصبی

آسیب (سنسور-۲) در مقایسه با آنهایی که در دورترین مکان از آسیب (سنسور-۴) هستند، حدود ۱۰۰ درصد افزایش یافته است. این رخداد بیشینه در هر سنسور، مکان وقوع آسیب را نمایش می‌دهد.

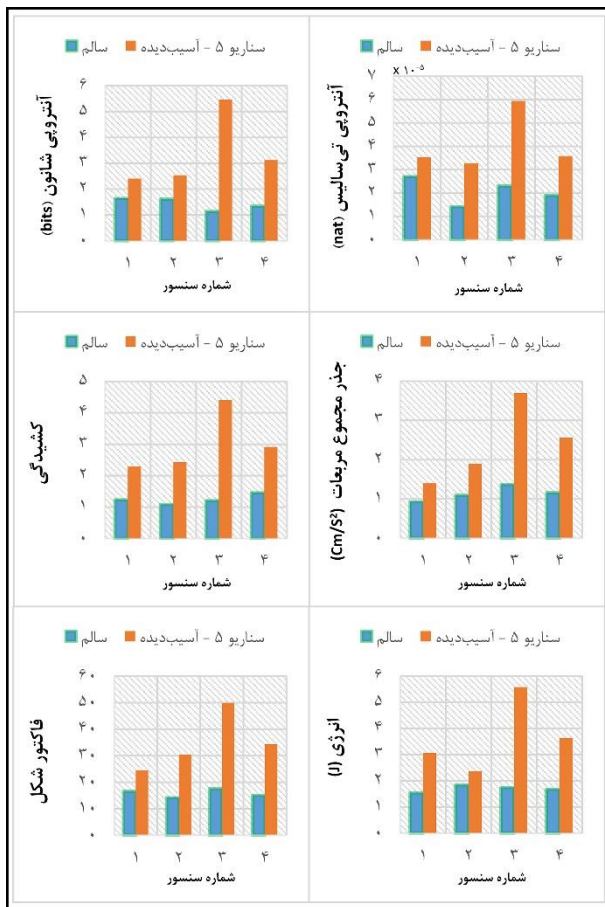
برای بررسی دقیق‌تر، دو سناریو دیگر، که شبکه با آن‌ها آموزش ندیده بود، نیز مورد ارزیابی قرار گرفتند. نتایج تمامی سناریوها حاکی از آن است که ویژگی‌های مورد بررسی در نزدیکی محل آسیب به بیشینه مقدار خود می‌رسند.

بررسی نتایج و ویژگی‌های حاصل از سنسورها این موضوع را نشان می‌دهد که ویژگی‌های استخراج شده نظیر آنتروپی‌های شانون، تی‌سالیس، کشیدگی، جذر مجموع مربعات، فاکتور شکل و انرژی هرچقدر که به محل آسیب نزدیک‌تر می‌شوند، مقادیر آن‌ها افزایش می‌یابد. در سناریو خرابی شماره ۲ که عضو ۱۰-۱۳ آسیب دیده است، نزدیک‌ترین سنسورها به آن به ترتیب سنسورهای شماره دو، یک، سه و چهار هستند که با همین ترتیب در شکل ۱۹ تقریباً در تمامی ویژگی‌ها بیشترین مقادیر را دارا می‌باشند. از ارزیابی ۶ ویژگی برای حالت آسیب دیده پل، مشخص شد که بزرگای همه ویژگی‌ها در محل

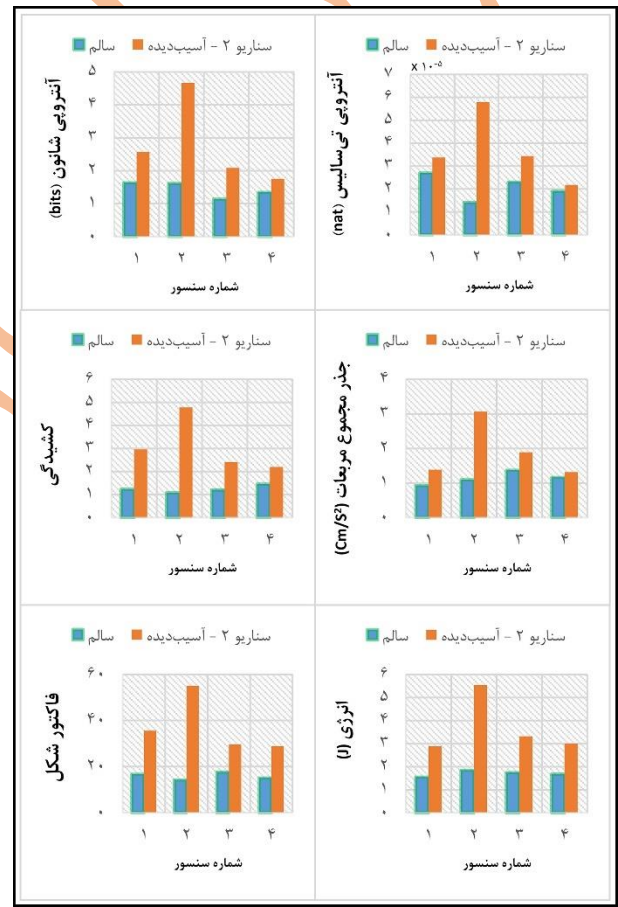


شکل ۱۸: نمایش شماتیک المان‌های آسیب دیده در سناریوهای خرابی

نمونه



شکل ۲۰: سناریو آسیب شماره ۵



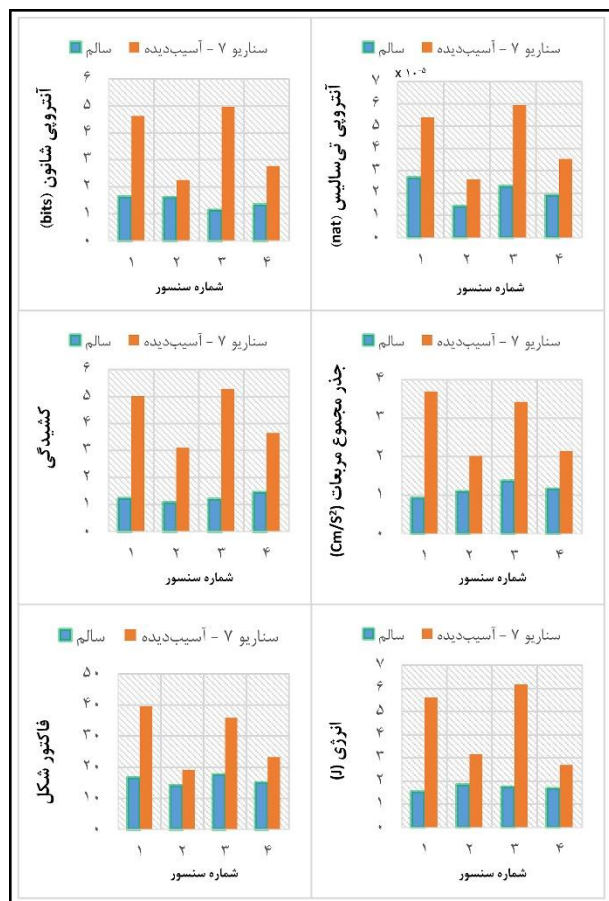
شکل ۱۹: سناریو آسیب شماره ۲

نیز که دورترین سنسور نسبت به محل آسیب است، اکثر ویژگی‌ها کمترین مقدار را نسبت به سایرین دارند. در شکل ۲۱ سناریوی شماره ۶ نیز که مربوط به آسیب عضو فشاری ۱۲-۱۴ می‌باشد، مورد بررسی قرار گرفته است. قابل مشاهده است که نزدیک‌ترین سنسور به

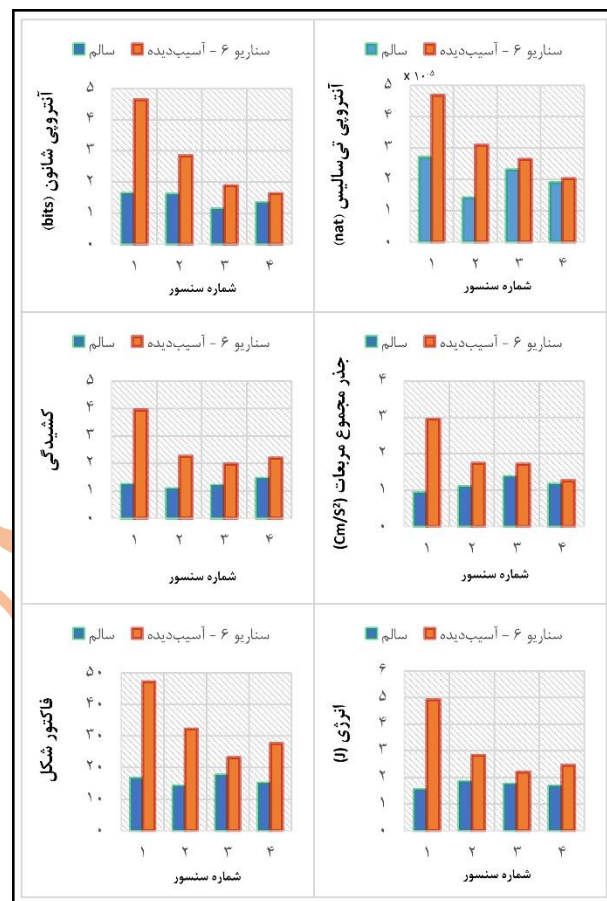
در شکل ۲۰ نتایج مربوط به سناریو ۵ نمایش داده شده است. مطابق انتظار، با توجه به محل آسیب که عضو ۷-۸ می‌باشد، در نزدیک‌ترین سنسور، یعنی سنسور شماره ۳، بزرگای تمامی ویژگی‌ها در حالت آسیب‌دیده به حداکثر مقدار خود رسیده است. در سنسور شماره ۱

سناریو، رخداد مقادیر حداکثر در سنسورهای شماره 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.

محل آسیب در پل (سنسور-۱)، بیشترین مقادیر را به خود اختصاص داده است. در نهایت، به منظور بررسی توانایی روش پیشنهادی در مکان‌یابی دو آسیب همزمان، سناریو شماره ۷ مورد بررسی قرار گرفت. با توجه به المان‌های آسیب دیده ۷-۸ و ۱۲-۱۳ در این



شکل ۲۲: سناریوی آسیب شماره ۷



شکل ۲۱: سناریوی آسیب شماره ۶

به کمک ابزارهای آماری، ۱۷ ویژگی حساس به آسیب در حوزه زمان از سیگنال‌های خام شتاب - زمان پل خرابایی استخراج و در فرم یک ماتریس جهت ارائه به شبکه عصبی آماده شدند. در نرم‌افزار متلب یک شبکه عصبی مصنوعی متشکل از دو لایه پنهان، به ترتیب با ۵ و ۳ نورون تشکیل‌دهنده، طراحی گردید و به هر یک از فرایندهای آموزش، اعتبارسنجی و آزمایش آن، تعداد مشخصی داده به صورت تصادفی اختصاص داده شد تا شبکه بتواند مراحل آموزش خود را به درستی طی کند.

۴- نتیجه‌گیری

هدف این پژوهش تشخیص آسیب در پل خرابایی با استفاده از شبکه عصبی مصنوعی و تبدیل موجک تجربی تحت یک بار متحرک بود. از این رو یک پل خرابایی دو بعدی در مقیاس آزمایشگاهی در آزمایشگاه دانشگاه شهید رجایی تهران ساخته شد و پاسخ‌های ارتعاشی پل، توسط ۴ سنسور متصل به آن، تحت بار متحرک اندازه‌گیری شدند. با توجه به رویکرد غیرپارامتریک روش پیشنهادی،

تشکر و قدردانی

بدین وسیله از آقای دکتر عابد کردی که ما را در ساخت پل خرپایی یاری کردند، کمال تشکر و قدردانی را داریم. همچنین از کمک‌های آقای مهندس هومن شیردره در انجام این پژوهش صمیمانه سپاسگزاریم.

مراجع

- [۱] Farrar, C.R., Doebling, S.W. and Nix, D.A., ۲۰۰۱. Vibration-based structural damage identification. *Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, ۳۵۹(۱۷۷۸), pp.۱۳۱-۱۴۹. <https://doi.org/10.1098/rsta.2000.0717>.
- [۲] Ghannadi, P., Kourehli, S.S. and Mirjalili, S., ۲۰۲۲. The application of PSO in structural damage detection: An analysis of the previously released publications (۲۰۰۵-۲۰۲۰). *Frattura ed Integrità Strutturale*, ۱۶(۶۲), pp.۴۶۰-۴۸۹. <https://doi.org/10.3221/IGF-ESIS.۶۲.۳۲>.
- [۳] Ghannadi, P., Kourehli, S.S. and Mirjalili, S., ۲۰۲۳. A review of the application of the simulated annealing algorithm in structural health monitoring (۱۹۹۵-۲۰۲۱). *Frattura e Integrità Strutturale*, (۶۴). <https://doi.org/10.3221/IGF-ESIS.۶۴.۰۴>.
- [۴] Farrar, C.R. and Worden, K., ۲۰۰۷. An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, ۳۶۵(۱۸۵۱), pp.۳۰۳-۳۱۵. <https://doi.org/10.1098/rsta.2006.1928>.
- [۵] Gul, M. and Catbas, F.N., ۲۰۰۸. Ambient vibration data analysis for structural identification and global condition assessment. *Journal of Engineering Mechanics*, ۱۳۴(۸), pp.۶۵۰-۶۶۲. [https://doi.org/10.1061/\(ASCE\)0733-9399\(2008\)134:8\(650\)](https://doi.org/10.1061/(ASCE)0733-9399(2008)134:8(650)).
- [۶] Tseng, K.K. and Naidu, A.S., ۲۰۰۲. Non-parametric damage detection and characterization using smart piezoceramic material. *Smart Materials and Structures*, ۱۱(۳), p.۳۱۷. <https://doi.org/10.1088/0964-1726/11/3/301>.

ویژگی‌های استخراج شده از پاسخ پل خرپایی مسطح در آزمایشگاه تحت تحریک بار متحرک، به عنوان ورودی به شبکه عصبی ارائه شدند و شبکه عصبی توانست با دقت ۹۴.۸ درصد وجود آسیب در پل را تشخیص دهد.

پس از بررسی نتایج حاصل از عملکرد روش پیشنهادی در پژوهش حاضر، می‌توان این گونه نتیجه گرفت که این روش، قادر است در صورتی که تعداد داده‌های ورودی به اندازه معقولی باشد، تشخیص آسیب را تحت بار متحرک با دقت خوبی انجام دهد. این عملکرد خوب شبکه را می‌توان به عنوان تاییدی بر کیفیت ویژگی‌های استخراج شده از سیگنال‌ها نیز تلقی کرد. ویژگی‌های غیر پارامتریک ضمن برخورداری از دقت بالا، کاستی‌های مرتبط با رویکردهای پارامتریک، نظیر تاثیرات دما بر پارامترهای مودال و عدم تاثیرگذاری قابل توجه آسیب‌های محلی بر جرم، سختی و میرایی مودال سازه را نیز برطرف می‌نمایند.

برای مکان‌یابی آسیب، ابتدا به کمک تبدیل موجک تجربی فرایند پردازش سیگنال بر روی پاسخ‌های ارتعاشی پل صورت گرفت. سپس ۵ ویژگی غیر پارامتریک شامل آنترپی‌های شانون و تی‌سالیس، جذر مجموع مربعات، فاکتور شکل و کشیدگی به همراه ویژگی انرژی استخراج شدند. این ویژگی‌ها بر 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 آزمایشات صورت گرفته نشان‌دهنده آن است که به‌طور کلی، مقادیر ویژگی‌ها در حالت‌های آسیب‌دیده به نسبت حالات سالم افزایش یافته‌اند و همچنین در نزدیکی محل‌های آسیب نیز تمامی ویژگی‌ها به مقدار بیشینه خود رسیده‌اند. با در نظر گرفتن مقادیر ویژگی‌ها در حالت آسیب‌دیده پل، هرچقدر سنسورها از محل آسیب دورتر باشند، این مقادیر متعاقباً برای آن سنسور کاهش می‌یابد. از این‌رو، سنسور دارای بیشترین بزرگای در ویژگی‌های مورد نظر، موقعیت مکانی آسیب را تعیین می‌کند. به‌طور کلی، 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.

- Structural Engineering, ٢٤(١), pp.١٨٣-١٩٥.
<https://doi.org/10.1177/1369943222.947193>.
- [١٧] Jayasundara, N., Thambiratnam, D.P., Chan, T.H.T. and Nguyen, A., ٢٠٢٠. Damage detection and quantification in deck type arch bridges using vibration based methods and artificial neural networks. Engineering Failure Analysis, ١٠٩, p.١٠٤٢٤٥.
<https://doi.org/10.1016/j.engfailanal.2019.104245>.
- [١٨] Sarmadi, H., Entezami, A., Salar, M. and De Michele, C., ٢٠٢١. Bridge health monitoring in environmental variability by new clustering and threshold estimation methods. Journal of Civil Structural Health Monitoring, ١١, pp.٤٢٩-٤٤٤.
<https://doi.org/10.1007/s13349-021-00472-1>.
- [١٩] Nick, H., Aziminejad, A., Hosseini, M.H. and Laknejadi, K., ٢٠٢١. Damage identification in steel girder bridges using modal strain energy-based damage index method and artificial neural network. Engineering Failure Analysis, ١١٩, p.١٠٥٠١٠.
<https://doi.org/10.1016/j.engfailanal.2020.105010>.
- [٢٠] Mousavi, A.A., Zhang, C., Masri, S.F. and Gholipour, G., ٢٠٢١. 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, ١٨٥, p.١١٠٠٤٠.
<https://doi.org/10.1016/j.measurement.2021.110040>.
- [٢١] Corbally, R. and Malekjafarian, A., ٢٠٢٢. A data-driven approach for drive-by damage detection in bridges considering the influence of temperature change. Engineering Structures, ٢٥٣, p.١١٣٧٨٣.
<https://doi.org/10.1016/j.engstruct.2021.113783>.
- [٢٢] Yang, Y.B. and He, Y., ٢٠٢٢. Damage detection of plate-type bridges using uniform translational response generated by single-axle moving vehicle. Engineering Structures, ٢٤٤, p.١١٤٥٣٠.
<https://doi.org/10.1016/j.engstruct.2022.114530>.
- [٢٣] Khanahmadi, M., Gholhaki, M., Rezaifar, O. and Dejkam, B., ٢٠٢٣. Damage identification in steel beam structures based on the comparison of analytical results of wavelet analysis. Civil Infrastructure Researches, ٨(٢), pp.١٧٣-١٨٣. [In Persian].
<https://doi.org/10.22091/cer.2022.8340.14.7>.
- [٢٤] Wu, R.T. and Jahanshahi, M.R., ٢٠٢٠. Data fusion approaches for structural health monitoring and system identification: past, present, and future. Structural Health Monitoring, ١٩(٢), pp.٥٥٢-٥٨٤.
<https://doi.org/10.1177/1475921718798769>.
- [٢٥] Dietterich, T.G., ٢٠٠٠, June. Ensemble methods in machine learning. In International workshop on multiple classifier systems (pp. ١-١٥). Berlin, Heidelberg: Springer Berlin Heidelberg.
https://doi.org/10.1007/3-540-4514-9_1.
- [٢٦] Santos, A., Figueiredo, E., Silva, M.F.M., Sales, C.S. and Costa, J.C.W.A., ٢٠١٤. Machine learning algorithms for damage detection: Kernel-based approaches. Journal of Sound and Vibration, ٣٤٣, pp.٥٨٤-٥٩٩.
<https://doi.org/10.1016/j.jsv.2015.11.008>.
- [٢٧] Bengio, Y., ٢٠١٣, July. Deep learning of representations: Looking forward. In International conference on statistical language and speech processing (pp. ١-٣٧). Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-39593-2_1.
- [٢٨] Hastie, T., Tibshirani, R., Friedman, J.H. and Friedman, J.H., ٢٠٠٩. The elements of statistical learning: data mining, inference, and prediction (Vol. ٢, pp. ١-٧٥٨). New York: springer.
<https://doi.org/10.1007/978-0-387-21676-5>.
- [٢٩] Hakim, S.J.S., Razak, H.A. and Ravanfar, S.A., ٢٠١٥. Fault diagnosis on beam-like structures from modal parameters using artificial neural networks. Measurement, ٧٤, pp.٤٥-٤١.
<https://doi.org/10.1016/j.measurement.2015.08.021>.
- [٣٠] Chun, P.J., Yamashita, H. and Furukawa, S., ٢٠١٥. Bridge damage severity quantification using multipoint acceleration measurement and artificial neural networks. Shock and Vibration, ٢٠١٥, pp.١-١١.
<https://doi.org/10.1155/2015/789384>.
- [٣١] Ghannadi, P. and Kourehli, S.S., ٢٠١٩. Data-driven method of damage detection using sparse sensors installation by SEREPa. Journal of Civil Structural Health Monitoring, ٩, pp.٤٥٩-٤٧٥.
<https://doi.org/10.1007/s13349-019-00345-8>.
- [٣٢] Ghannadi, P. and Kourehli, S.S., ٢٠٢١. An effective method for damage assessment based on limited measured locations in skeletal structures. Advances in

- [۲۳] Fallah, N., Hoseini Vaez, S.R. and Esfandiari, A., ۲۰۲۳. Damage detection of steel structures by FEM updating based on strain data. Sharif Journal of Civil Engineering. Sharif Journal of Civil Engineering, ۳۹,۲(۲), pp. ۳۹-۴۹. [In Persian]. <https://doi.org/10.24200/j30.2023.61055.3144>.
- [۲۴] Maszczyk, T. and Duch, W., ۲۰۰۸. Comparison of Shannon, Renyi and Tsallis entropy used in decision trees. In Artificial Intelligence and Soft Computing–ICAISC ۲۰۰۸: ۹th International Conference Zakopane, Poland, June ۲۲-۲۶, ۲۰۰۸ Proceedings ۹ (pp. ۶۴۳-۶۵۱). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-69731-2_62.
- [۲۵] Xu, Y. and Zhang, H., ۲۰۰۹. Recent mathematical developments on empirical mode decomposition. Advances in Adaptive Data Analysis, ۱(۰۴), pp.۶۸۱-۷۰۲. <https://doi.org/10.1142/S179353690900244>.
- [۲۶] Tsallis, C., Mendes, R. and Plastino, A.R., ۱۹۹۸. The role of constraints within generalized nonextensive statistics. Physica A: Statistical Mechanics and its Applications, ۲۶۱(۳-۴), pp.۵۳۴-۵۵۴. [https://doi.org/10.1016/S0378-4371\(98\)00437-3](https://doi.org/10.1016/S0378-4371(98)00437-3).
- [۲۷] Gilles, J., ۲۰۱۳. Empirical wavelet transform. IEEE transactions on signal processing, ۶۱(۱۶), pp.۳۹۹۹-۴۰۱۰. <https://doi.org/10.1109/TSP.2013.2265222>.