

مطالعه مقایسه‌ای و ارائه رویکردی دقیق جهت تشخیص آسیب سازه‌های قابی مبتنی بر مدل‌های شبکه عصبی عمیق

اکبر اصغرزاده بناب*

استادیار، گروه مطالعات علم و فناوری، دانشگاه فرماندهی و ستاد آجا، تهران، ایران.
a.asgharzadeh@urmia.ac.ir

غلامرضا نصیرپور

استادیار، گروه مطالعات علم و فناوری، دانشگاه فرماندهی و ستاد آجا، تهران، ایران،
r.nasirpour@casu.ac.ir

امید اللهیاری پرگو

کارشناسی ارشد، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه خوارزمی، تهران، ایران،
omidallahyari@khu.ac.ir

چکیده

در چند دهه اخیر، روش‌های مبتنی بر داده، اثربخشی بالایی در زمینه پایش سلامت سازه‌ها با رویکرد تشخیص آسیب نشان داده‌اند. در گذشته، استفاده از سیگنال‌های خام حسگرهای سری زمانی برای عیب‌یابی سازه‌ها به دلیل ابعاد بالای ذاتی داده‌های اندازه‌گیری شده، تقریباً غیرممکن بود. با این حال، پیشرفت‌های اخیر در شبکه‌های عصبی و مدل‌های یادگیری ماشین، نیاز به پیش‌پردازش پیچیده داده‌های سری زمانی را برطرف کرده است. پایش بر اساس دسترسی به اطلاعات سالم و آسیب‌دیده سازه در شکل دسته‌بندی با رویکرد تشخیص الگو رویکرد غالب پژوهش‌های اخیر بوده است. در این مطالعه، در رویکردی بر مبنای پایش نظارت‌شده، مطالعه‌ای مقایسه‌ای بین چهار الگوریتم یادگیری عمیق نوین، در تشخیص آسیب سازه‌ای با استفاده از داده‌های خام بررسی شده است. این چهار الگوریتم شامل شبکه LSTM، GRU، CNN و شبکه ترکیبی CNNLSTM هستند. و رویکردی دقیق (مدل ترکیبی CNNLSTM با دقت ۹۹/۹٪) بر روی داده‌های سازه مینا آزمایشگاه لس آلاموس ارائه شده است. مدل CNNLSTM بدون پیش‌پردازش به‌خصوص نظیر الگوریتم‌های پردازش سیگنال یا کاهش ابعاد، از نظر دقت، تعداد پارامترها و زمان آموزش، در مقایسه با سه مدل دیگر و پژوهش‌های مشابه پیشین عملکردی ممتاز دارد.

واژه‌های کلیدی: پایش سلامت سازه، تشخیص آسیب سازه‌ای، شناسایی الگو، استخراج ویژگی، شبکه عصبی عمیق، پردازش سیگنال.

A comparative study and the presentation of a precise approach for diagnosing damage in frame structures based on deep neural network models

A. Asgharzadeh-Bonab

Department of Science and Technology Studies, AJA Command and Staff University, Tehran, Iran

GH. Nasirpour

Department of Science and Technology Studies, AJA Command and Staff University, Tehran, Iran

O. Allahyari Pargu

Department of Civil Engineering, Faculty of Engineering, Kharazmi University, Tehran, Iran

Abstract

In recent decades, data-driven methods have shown high effectiveness in structural health monitoring, focusing on damage detection. In the past, using raw time-series sensor signals for diagnosing structures was nearly impossible due to the inherent high dimensions of the measured data. However, recent advances in neural networks and machine learning models have eliminated the need for complex preprocessing of time-series data. Monitoring based on access to healthy and damaged structural information in a classification framework has been the predominant approach in recent research. This study conducts a comparative analysis of four novel deep-learning algorithms for structural damage detection using raw data within a supervised monitoring framework. The four algorithms investigated include LSTM networks, GRU, CNN, and a hybrid CNNLSTM network. A precise approach (the CNNLSTM model with 99.9% accuracy) is proposed based on the Los Alamos Laboratory foundational structure data. Notably, the CNNLSTM model operates without any preprocessing, such as signal processing algorithms or dimensionality reduction, and performs excellently in terms of accuracy, the number of parameters, and training time compared to the other three models and previous studies.

Keywords: Structural Health Monitoring, Structural Damage Diagnosis, Pattern Recognition, Feature Extraction, Deep Neural Networks, Signal Processing.

۱- مقدمه

داشته‌اند. روش‌های مبتنی بر داده در مقایسه با روش‌های مبتنی بر مدل [۱]، فرایند تصمیم‌گیری را با پیچیدگی و بار محاسباتی بالا در عین حال با نتایج کارآمدتر ممکن می‌سازند [۲]. در گذشته، استفاده مستقیم از سیگنال‌های خام حسگرهای سری زمانی برای نظارت بر سلامت سازه‌ها به دلیل ابعاد بالای ذاتی داده‌های اندازه‌گیری شده تقریباً غیرممکن بود. با این حال، پیشرفت‌های اخیر در شبکه‌های عصبی و مدل‌های یادگیری ماشین، نیاز به پیش‌پردازش پیچیده

پایش سلامت سازه فرآیندی است که هنگام رو به آسیب رفتن سازه با هشدار، از آسیب کلی سازه و فروریزش خطرناک آن جلوگیری کند، باعث افزایش عمر مفید سازه شود و هزینه‌های نگهداری را کاهش دهد. در چند دهه اخیر، روش‌های مبتنی بر داده، اثربخشی بالایی در زمینه پایش سلامت سازه‌ها نشان داده‌اند و مزایای چشمگیری

* نویسنده‌ان مکاتبه کننده، آدرس پست الکترونیکی: a.asgharzadeh@urmia.ac.ir

تاریخ دریافت: ۱۳۰۷/۱۱

تاریخ پذیرش: ۱۳۰۹/۱۹

داده‌های سری زمانی را برطرف کرده است [۳]. این راهکارها به‌طور کلی بر اساس سه‌گام اصلی شامل اکتساب داده، مهندسی ویژگی و فرآیند تصمیم‌گیری استوار هستند و سعی دارند فرآیند پایش سلامت سازه را دقیق‌تر، سریع‌تر، ایمن‌تر و حداقل‌امکان در تمامی مراحل به صورت خودکار پیش ببرند. پایش بر اساس دسترسی به اطلاعات سالم و آسیب‌دیده (دسته‌بندی) رویکرد غالب پژوهش‌های اخیر بوده است.


محققین در سال ۲۰۱۷ به تشخیص آسیب در سازه‌ها با استفاده از شبکه‌های CNN پرداختند. این شبکه‌ها توانایی بالایی در استخراج ویژگی و کلاس‌بندی دارند. برای ارزیابی رویکرد پیشنهادی، از داده‌های سازه فولادی دانشگاه قطر به‌عنوان ورودی به شبکه داده استفاده شد. مدل مطرح‌شده در این پژوهش به‌صورت غیرمتمرکز پیاده‌سازی گردید، بدین معنی که برای هر حسگر یک مدل منحصر به فرد مبتنی بر CNN توسعه یافت [۴]. در پژوهش دیگری در سال ۲۰۱۹ با توسعه CNN مبتنی بر پارامترهای مودال و تبدیل موجک، ویژگی‌های آسیب بر اساس پارامترهای مودال استخراج گردید، کارایی روش پیشنهادشده، بر روی داده‌های یک تیر آزمایشگاهی در وجود شدت‌های مختلفی از نوفه (نویز) سنجیده شد [۵]. در سال ۲۰۲۰ کاربرد CNN در فرآیند پایش سلامت مورد بررسی قرار گرفت. داده مورد نیاز برای آموزش شبکه، بر اساس نتایج حاصل از آنالیز اجزا محدود یک خرپا به دست آمد. ارزیابی شبکه آموزش‌دیده، بر روی داده‌های دیده نشده از مدل عددی نتایجی ایده‌آل داشت. مؤثر بودن فرآیند پایش همچنین به‌وسیله استفاده از داده‌های حاصل آزمایش ارتعاشی خرپا در مقیاس آزمایشگاهی نیز مورد اعتبار سنجی قرار گرفت. تحریک ورودی سازه در مقیاس آزمایشگاهی ضربه حاصل چکش است که صرفاً کاربردی آزمایشگاهی دارد و در بهترین حالت بر روی سازه‌هایی با مقیاس کوچک پاسخگو خواهد بود [۶]. در سال ۲۰۲۰ یک رویکرد بر CNN یک‌بعدی برای استخراج ویژگی و کلاس‌بندی سیگنال‌های سری زمانی یک‌بعدی حاصل از پاسخ سازه توسعه داده شد. این شبکه قادر به تشخیص آسیب در اتصالات سازه است. در این پژوهش، حساسیت پایش آسیب در اتصالات سازه با پاسخ به دست‌آمده از عضو به‌عنوان ورودی شبکه تحت شدت‌های مختلف آسیب و ترکیب سطوح نوفه (نویز) متفاوت، مورد مطالعه قرار گرفت. باهدف کاربرد در سازه‌های با مقیاس واقعی، کاربرد اندازه‌گیری کرنش برای پایش آسیب اتصالات نیز مورد بررسی قرار گرفت [۷]. در پژوهش دیگری در سال ۲۰۲۰ از توابع انتقال حوزه فرکانس حاصل از تبدیل فوری سریع، برای استخراج ویژگی‌های حساس به آسیب، استفاده گردید. توابع انتقال به‌صورت ذاتی مستقل از تداخل با تحریک ایجادشده‌اند. در پژوهش موردنظر سعی شده است با ترکیب CNN و توابع انتقالی، عملیات تشخیص آسیب سازه‌ای با دقت بسیار بالایی انجام شود [۸]. در سال ۲۰۲۰ عملکرد چندین مدل شبکه عصبی عمیق از جمله شبکه‌های پرسپترون چند لایه، CNN یک‌بعدی، CNN دوبعدی و شبکه بازگشتی LSTM روی سازه مینا سه‌طبقه آزمایشگاه لس آلاموس سنجیده شد. نتایج آن‌ها حاکی از برتری مدل CNN دوبعدی بود، با این حال مدت زمان آموزش قابل توجه مدل و تعداد پارامترهای آموزش از نقاط ضعف پژوهش مورد نظر به‌شمار می‌رود [۳]. در سال ۱۴۰۳ اصغرزاده بناب و همکاران با پیش‌پردازش داده‌های سری زمانی با استفاده از تبدیل موجک گسسته و تجزیه حالت تجربی ویژگی‌های حساس به آسیب در دامنه زمان - فرکانس را استخراج

نمودند. سپس از آن‌ها به عنوان ورودی شبکه‌های عصبی مختلف و ماشین بردار پشتیبان بهینه‌شده، جهت تشخیص وضعیت سازه مینا مورد بررسی (سه‌طبقه آزمایشگاه لس آلاموس) استفاده شد. نتایج قابل توجه اما با وجود تلاش محاسباتی گران حاصل گردید [۹].

در این پژوهش، بر مبنای پایش نظارت‌شده، کاربرد چهار الگوریتم یادگیری عمیق در تشخیص آسیب سازه‌ای با استفاده از داده‌های خام بررسی شده است. این چهار الگوریتم شامل شبکه حافظه طولانی کوتاه‌مدت، واحد بازگشتی دروازه‌ای، شبکه عصبی تلفیقی و شبکه ترکیبی تلفیقی - حافظه طولانی کوتاه‌مدت هستند. نوآوری این پژوهش در ارائه معماری‌هایی از مدل‌های شبکه‌های عصبی عمیق است که بدون نیاز به پیش‌پردازش زمان‌بر از جمله الگوریتم‌های پردازش سیگنال، ویژگی‌های حساس به آسیب صرفاً از داده‌های خام حسگرها استخراج شده است. سپس تشخیص وضعیت سازه در دو حالت سالم و دارای آسیب با دقت قابل توجهی حتی با وجود شرایط محیطی و بهره‌برداری متغیر صورت پذیرفته است. معماری این مدل‌ها از دو قسمت استخراج ویژگی و کلاس‌بند تشکیل شده است. در راستای مقایسه مناسب، مدل‌ها در قسمت کلاس‌بند یکسان و در قسمت استخراج ویژگی، حداقل‌امکان یکسان‌اند. در ادامه در بخش دوم، مشخصات سازه مینا مورد بررسی جهت ارزیابی و اعتبارسنجی مدل‌ها، توضیح داده شده است. در بخش سوم مبانی تکنیک‌های رویکرد پیشنهادی و در بخش چهارم معماری مدل‌های پیشنهادی با جزئیات شرح داده شده است. نتایج پژوهش در بخش پنجم تشریح شده و در نهایت در بخش ششم به جمع‌بندی مباحث پرداخته شده است.

۲- اکتساب داده (سازه مینا آزمایشگاه لس آلاموس)

سازه نشان داده‌شده در شکل ۱، یک قاب آلومینیومی در مقیاس آزمایشگاهی است که در آزمایشگاه لوس آلاموس ساخته شده است [۱۰]. این سازه شامل ستون‌ها و صفحات آلومینیومی است که با اتصالات پیچ و مهره‌ای ساخته شده است. این قاب از ستون‌های آلومینیومی به ارتفاع ۱۷۷ میلی‌متر، پهنا ۲۵ میلی‌متر و ضخامت ۶ میلی‌متر و در هر طبقه، شامل چهار ستون آلومینیومی است به صفحه‌های آلومینیومی بالا و پایین با ابعاد ۳۰۵ در ۳۰۵ میلی‌متر و ضخامت ۲۵ میلی‌متر متصل شده‌اند. علاوه بر این، یک ستون مرکزی از طبقه بالا معلق است، که برای ایجاد رفتارهای غیرخطی هنگامی که با ضربه گیر نصب‌شده بر روی طبقه دوم تماس پیدا می‌کند، استفاده می‌شود. موقعیت ضربه‌گیر قابل تنظیم است تا میزان غیرخطی بودن را تغییر دهد. این مکانیسم قابلیت شبیه‌سازی ترک‌های خستگی که در حین بارگذاری باز و بسته می‌شوند را دارا است. بعلاوه از این مکانیسم می‌توان به‌عنوان شبیه‌سازی آسیب در اتصالات سازه و شل شدن پیچ‌ها نیز استفاده کرد. هرچه فاصله ضربه‌گیر و ستون کمتر شود نشان‌دهنده شدت آسیب بالاتری است. این سازه بر روی ریل‌هایی حرکت می‌کند که فقط اجازه حرکت در جهت x را می‌دهند. یک موتور الکتریکی مغناطیسی تحریک را به پایه سازه اعمال می‌کند. چهار شتاب سنج به هر طبقه در سمت مقابل منبع تحریک متصل شده‌اند تا پاسخ هر طبقه را اندازه‌گیری کنند. شتاب‌سنج‌ها در وسط طبقه نصب‌شده‌اند، از این‌رو حالت‌های پیچشی سازه در اندازه‌گیری‌های آن‌ها مؤثر نیستند.



شکل ۳- حسگرگذاری سازه مبنا آزمایشگاه لس آلاموس

جدول ۱- سناریوهای آسیب غیرخطی سازه مبنا LANL [۱۰]

وضعیت (سناریو)	برچسب وضعیت (سناریو)
وضعیت ۱	جرم ۱/۲ کیلوگرم در طبقه اول
وضعیت ۲	جرم ۱/۲ کیلوگرم در طبقه همکف
وضعیت ۳	شکاف ۰/۱۳ میلی‌متری
وضعیت ۴	شکاف ۰/۱۰ میلی‌متری
وضعیت ۵	شکاف ۰/۰۵ میلی‌متری
وضعیت ۶	شکاف ۰/۱۵ میلی‌متری
وضعیت ۷	شکاف ۰/۲۰ میلی‌متری
وضعیت ۸	وضعیت مبنا
وضعیت ۹	جرم ۱/۲ کیلوگرم در طبقه اول + شکاف ۰/۲۰ میلی‌متری
وضعیت ۱۰	جرم ۱/۲ کیلوگرم در طبقه اول + شکاف ۰/۱۰ میلی‌متری
وضعیت ۱۱	جرم ۱/۲ کیلوگرم در طبقه همکف + شکاف ۰/۲۰ میلی‌متری


۳- تکنیک‌های رویکرد پیشنهادی

با توجه به پیچیدگی رفتار سازه‌ها و نیاز به دقت بالا در تشخیص آسیب‌ها، استفاده از روش‌های سنتی مبتنی بر تحلیل ارتعاشی و سیگنال‌ها، اغلب نیازمند زمان و محاسبات زیاد است و ممکن است در تشخیص به‌موقع و دقیق آسیب‌ها ناکافی باشند. مدل‌های مبتنی بر یادگیری ماشین و شبکه‌های عصبی مصنوعی به دلیل توانایی‌شان به‌واسطه قابلیت‌های یادگیری قوی و کارایی بالای محاسباتی، همچنین پردازش حجم زیادی از داده‌ها و یادگیری الگوهای پیچیده، به‌سرعت به یکی از ابزارهای اصلی در پایش سلامت سازه تبدیل شده‌اند [۱۱]. این مدل‌ها قادرند با تحلیل داده‌های حسگرها که از ارتعاشات سازه‌ها به دست می‌آیند، به‌طور خودکار الگوهای آسیب را شناسایی و تشخیص دهند [۱۲]. شبکه‌های عصبی، رفتار غیرخطی سازه‌ها می‌آموزند و سپس با استفاده از دانش فراگرفته‌شده، وضعیت داده‌های ورودی جدید را شناسایی می‌کنند.

۳-۱- شبکه عصبی تلفیقی (درهم تنیده)


شبکه‌های عصبی تلفیقی نوعی شبکه عصبی مصنوعی پیش‌خور با عملکرد نظارت‌شده‌اند. کاربرد اصلی این شبکه‌ها برای وظایف مبتنی بر ورودی از نوع تصویر است اما با ایجاد تغییراتی بر روی سایر انواع داده‌ها از جمله سری‌های زمانی کاربرد می‌یابند. در مقایسه با شبکه‌های عصبی متعارف در این شبکه‌ها پارامترهای موردنیاز برای آموزش مدل کاهش می‌یابد و در مواجهه با پیچیدگی‌های محاسباتی عملکرد بسیار مناسب‌تری دارند [۱۳].

شرایط مختلف داده‌برداری به‌صورت کلی در چهار گروه تقسیم می‌شوند. گروه اول، شرایط پایه است. گروه دوم شامل شرایط پایه‌ای است که در آن سازه تغییراتی در سختی به دلیل تأثیرات عملیاتی و محیطی داشته است. گروه سوم تداعی‌کننده شرایط آسیب غیرخطی که توسط یک ضربه‌گیر ایجاد شده است. گروه چهارم شامل شرایط تلفیق آسیب‌های غیرخطی و تأثیرات بهره‌برداری و محیطی است.




شکل ۴- سازه مبنا آزمایشگاه لس آلاموس [۱۰]

پاسخ شتاب سازه در چندین حالت مختلف در جدول ۱ نشان داده شده است. وضعیت پایه، وضعیت ۸ است. وضعیت‌های ۱ و ۲ وضعیت آسیب‌ندیده سازه به همراه شبیه‌سازی از شرایط محیطی و بهره‌برداری را بیان می‌کنند. در راستای شبیه‌سازی سناریوهای آسیب، برای وضعیت‌های ۳ تا ۷، فاصله ضربه‌گیر و ستون به ترتیب مطابق با جدول ۱ تغییر داده شده است. در وضعیت‌های ۹ تا ۱۱ هم سناریوهای آسیب به همراه تغییرات شرایط بهره‌برداری با افزودن جرم در طبقات پایه و اول در نظر گرفته شده است. داده‌برداری برای هر یک از سناریوهای معرفی شده طی ده تکرار اندازه‌گیری شده است. در هر یک از دفعات اندازه‌گیری پاسخ‌های ارتعاشی، شتاب سنج‌ها در محدوده ۳۲۰ هرتز و به تعداد ۸۱۹۲ اندازه‌گیری شده است [۱۰]. شکل ۲ سری زمانی مربوط به داده‌های برداشت شده هر یک از حسگرها، طی تمامی حالات جدول ۱ نشان داده شده است. پیش از خط عمودی قرمز، داده‌ها مربوط به وضعیت سالم سازه و پس از آن مربوط به حالات دارای آسیب است. شکل ۳ توزیع داده‌های هر یک از حسگرها نمایش داده شده است که همگی از توزیع نرمال (گوسی) برخوردارند.



شکل ۵- حسگرگذاری سازه مبنا آزمایشگاه لس آلاموس



شکل ۴- ساختار شبکه CNN [۱۳]


هدف اصلی در طراحی شبکه‌های درهم‌تنیده تشخیص وابستگی‌های محلی در داده‌های ورودی است. این ویژگی به شبکه‌های تلفیقی کمک می‌کند اثر همسایگی و ارتباط داده‌ها با یکدیگر را بیابد. این مزیت این امکان را به این شبکه‌ها می‌دهد که الگوهای پیچیده‌تر را به یک روش سلسله‌مراتبی، با ترکیب ویژگی‌های سطح پایین ابتدایی و ویژگی‌های سطح بالا، بازنمایی کنند. این ویژگی نیز ترکیب‌پذیری نام دارد. چهار ایده کلیدی در شبکه‌های تلفیقی وجود دارد: اتصالات محلی، به‌اشتراک‌گذاری وزن‌ها، مفهوم انتخاب (رأی‌گیری) و استفاده از لایه‌های بسیار [۱۴]. شبکه‌های عصبی تلفیقی دو نوع می‌باشند: شبکه‌های یک‌بعدی و شبکه‌های دوبعدی. در شبکه‌های عصبی تلفیقی یک‌بعدی، داده‌های ورودی یک‌بعدی هستند و نیاز به پیش‌پردازش ندارند. مزیت اصلی این است که به دلیل پیچیدگی ساده و فشرده آن‌ها نسبت به نوع دوبعدی، پیاده‌سازی سخت‌افزاری آن‌ها در زمان واقعی و با هزینه کم امکان‌پذیر است. این شبکه‌ها به‌ویژه زمانی که داده‌های آموزشی کم هستند، عملکرد قابل قبولی دارند. همچنین به دلیل ساده‌تر بودن ساختار شبکه‌های تلفیقی یک‌بعدی، امکان آموزش با تعداد داده‌های کمتر فراهم بوده و زمان کمتری جهت آموزش نیاز است [۱۵]. در شکل ۴ ساختار اجزای سازنده شبکه‌های عصبی تلفیقی نشان داده شده است. این شبکه‌ها از لایه‌های ورودی، لایه تلفیقی (شامل ناحیه دریافت، فیلتر (هسته)، طول گام، تابع فعال‌ساز، لایه سازی (پدینگ))، لایه انتخاب (رأی‌گیری یا تجمیع‌کننده) و لایه تماماً متصل (لایه تماماً متصل از نورون‌های شبکه‌های عصبی متعارف (شبکه پرسپترون چندلایه)) تشکیل شده است [۱۳].

۲-۳- شبکه عصبی بازگشتی (شبکه حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای)

شبکه‌های عصبی بازگشتی، از انواع معماری‌های شبکه‌های عصبی هستند که عمدتاً برای شناسایی الگوها در یک توالی داده استفاده می‌شوند. توانایی شبکه‌های بازگشتی ثبت ویژگی‌های وابسته به زمان سیستم‌های پیچیده و غیرخطی است. این شبکه‌ها برخلاف شبکه‌های تلفیقی که بر استخراج ویژگی‌های محلی تمرکز دارند، نسبت به ویژگی‌های کلی داده ورودی حساس‌اند و سعی در کشف الگو و استخراج ویژگی با توجه به خصوصیات کلی داده ورودی دارند [۱۶]. سه شبکه عصبی بازگشتی، شبکه عصبی حافظه طولانی کوتاه‌مدت و شبکه عصبی دروازه‌ای از انواع مختلف این شبکه‌اند. مسئله ذخیره کردن اطلاعات گذشته یکی از بارزترین مزیت‌های این گونه از شبکه‌ها است ولی نکته قابل تأمل اینجاست که تا چه میزان اطلاعات پیشین

مورد نیاز است. اینجا اولین مشکل این شبکه‌ها نمود پیدا می‌کند که هر چه فاصله میان داده‌ها افزایش پیدا می‌کند، شبکه‌های عصبی بازگشتی متعارف توانایی‌شان را در استفاده از اطلاعاتی که در گذشته دورتر جمع‌آوری کرده‌اند از دست می‌دهند. از این رو شبکه‌های عصبی بازگشتی متعارف RNN مشکل ضعف حافظه بلندمدت دارند.

مدل LSTM می‌تواند در انجام وظایف مختلف، از RNN‌های سنتی بهتر عمل کند. واحدهای حافظه بلندمدت-کوتاه‌مدت به‌طور خاص برای مدیریت صحیح مشکل گرادیان ناپدید شونده طراحی شده‌اند. شبکه‌های مبتنی بر این واحدها، موجب آموزش بر روی تعداد بیشتری از مراحل زمانی (بیش از ۱۰۰۰) می‌گردد [۱۶]. شبکه LSTM می‌تواند وابستگی بلندمدت داده‌ها را به کمک سلول حافظه در خود نگه دارد و ارتباط بلندمدت داده‌ها را حفظ نماید. یک واحد LSTM ساده شامل یک سلول، یک دروازه ورودی، یک دروازه خروجی و یک دروازه فراموشی است [۱۷]. واحد بازگشتی دروازه‌ای GRU به‌عنوان مدل دیگری برای ساخت شبکه عصبی بازگشتی معرفی شده است. این مدل برخلاف LSTM تنها شامل دو دروازه است. دروازه‌ی به‌روزرسانی، کنترل می‌کند که چه اطلاعاتی به حافظه وارد شود، درحالی‌که دروازه‌ی تنظیم مجدد کنترل می‌کند که چه اطلاعاتی از حافظه خارج شود. مشابه واحد LSTM، GRU نیز دارای واحدهای دروازه‌ای است که جریان اطلاعات را درون واحد تنظیم می‌کنند، اما در معماری آن برخلاف LSTM یک سلول حافظه‌ی جداگانه وجود ندارد. شکل ۵ در قسمت (الف) معماری سلول‌های واحد بازگشتی دروازه‌ای و در قسمت (ب) معماری سلول حافظه طولانی کوتاه‌مدت را نشان می‌دهد. در قسمت (الف) f و o به ترتیب دروازه ورودی، فراموشی و خروجی هستند. c و $\tilde{c}$ به ترتیب سلول حافظه و سلول حافظه جدید هستند. در قسمت (ب) r و z دروازه‌های تنظیم مجدد و به‌روزرسانی هستند. $\tilde{h}$ و h فعال‌ساز و فعال‌ساز جدید هستند [۱۷]. با توجه به شباهت‌ها و تفاوت‌های LSTM و GRU، به‌سختی می‌توان نتیجه گرفت که کدامیک از شبکه‌های LSTM یا GRU عملکرد دقیق‌تری خواهد داشت و بسته به ماهیت داده مورد بررسی، هر دو باید مورد بررسی قرار گیرند [۱۸].



شکل ۵- معماری (الف) واحد بازگشتی دروازه‌ای (ب) حافظه طولانی کوتاه‌مدت [۱۷]

۳-۳- شبکه پرسپترون چندلایه

ساختار شبکه‌های عصبی مصنوعی (ANN) از عملکرد مغز الهام گرفته شده‌است. این شبکه‌ها می‌توانند روابط خطی و غیرخطی داده‌ها را بیاموزند و به شرایط دیده نشده تعمیم دهند. از شبکه‌های عصبی مصنوعی معروف، پرسپترون چندلایه (MLP) است. در این شبکه محاسبات توسط عنصری به نام پرسپترون انجام می‌پذیرد، هر پرسپترون در ساختار معین خود با سایر پرسپترون‌ها مرتبط بوده و نتایج محاسبات را به آن‌ها منتقل می‌کند. ساختار یک پرسپترون ساده

۴- رویکرد پیشنهادی تشخیص آسیب

روش پیشنهادی این پژوهش بر مبنای استفاده از اطلاعات تمامی داده‌های جمع‌آوری شده است. در سازه مبنای مورد بررسی، ۴ حسگر داده‌های حالت‌های مختلف را جمع‌آوری می‌کنند، از این‌رو یک سری زمانی چهار کاناله باید تحلیل شود. در راستای بهبود پژوهش‌های پیشین و ارائه مدل‌هایی دقیق و با تلاش محاسباتی کم، مدل‌های LSTM، GRU، CNN و CNNLSTM در این پژوهش ارائه شده‌اند. یک پنجره به طول ۱۰۲۴ با گام‌های ۳۲ تایی، بر روی سری زمانی ۴ کاناله مورد بررسی، لغزنده شده است. نتیجتاً ماتریس ورودی به هر یک از مدل‌های فوق‌الذکر ابعاد (۱۰۲۴×۴) دارد.

هدف از آموزش و پیاده‌سازی مدل‌های مزبور تشخیص وضعیت سازه در دو حالت سالم و آسیب‌دیده است. خاطر نشان می‌گردد وجود سناریوهای سالم آلوده به شرایط متغیر محیطی و عملیاتی و آسیب‌دیده آلوده به شرایط متغیر محیطی و عملیاتی و درهم‌تنیدگی شدید بین داده‌های وضعیت‌های مختلف در سازه مبنای مورد بررسی، کشف الگو مابین وضعیت‌های مختلف سازه را دشوار و چالش‌برانگیز می‌سازد. به منظور اثبات درهم‌تنیدگی داده مرتبط با حالات مختلف سازه، در شکل ۸ داده‌های تمام وضعیت مندرج در جدول ۱ با استفاده از (الف) تکنیک مصورسازی T-SNE، (ب) تکنیک PCA و (پ) تکنیک UMAP نمایش داده شده است. در جدول ۲ جزئیات مدل‌های LSTM، GRU، CNN و CNNLSTM پیشنهادی، نشان داده شده است. همچنین شکل‌های ۹ تا ۱۲ به ترتیب معماری مدل‌های پیشنهادی LSTM، GRU، CNN و CNNLSTM جهت کلاس‌بندی دوگانه، به نمایش درآمده‌اند. نکته مهم در توسعه مدل‌های فوق این است که بخش‌های مشابه در مدل‌ها، از معماری کاملاً یکسانی برخوردارند تا نتایج حاصله از مقایسه آن‌ها در شرایط برابر صورت گیرد. اما این بدین معنا نیست که در صورت مشابه بودن معماری‌ها تحت انتخاب هر مقداری از پارامترها، نتایج مشابه‌ای به دست‌آید.

از مهمترین پارامترهای طراحی شبکه‌های عصبی، تابع هزینه است، که در هر نوبت از اجرای آموزش شبکه، میزان خطای پیش‌بینی را اندازه‌گیری می‌کند. شبکه عصبی در مسیر یادگیری خود هر بار وزن‌ها و بایاس اصلاح می‌کند تا در نهایت به بهترین خروجی ممکن برسد و در این مسیر بررسی میزان تغییر و خطای ایجادشده توسط تابع هزینه محاسبه می‌گردد [۲۰]. در این پژوهش از تابع هزینه آنتروپی متقاطع L_{CE} ، برای ارزیابی عملکرد مدل‌های توسعه داده‌شده استفاده شده است. نوع خاص این تابع برای طبقه‌بندی فقط دو کلاس که به آن تابع آنتروپی متقاطع باینری گفته می‌شود [۲۰]، بکار گرفته‌شد. مقدار تابع از رابطه (۲) محاسبه می‌شود، که در این رابطه، جزء $x_{j,i}^{th}$ ام از نمونه i^{th} ام و M تعداد کل مشاهدات در مجموعه داده‌های آموزشی است:


$$L_{CE} = -\frac{1}{M} \sum_{i=1}^M \sum_{j=1}^n [x_{j,i} \log \hat{x}_{j,i} + (1 - x_{j,i}) \log (1 - \hat{x}_{j,i})] \quad (2)$$

پارامتر مهم دیگر توابع بهینه‌سازی هستند که باعث بهبود محاسبات و افزایش کارایی شبکه عصبی می‌شوند و به‌صورت مکرر الگوریتم‌های مشخصی را اعمال کرده تا به بهترین پاسخ ممکن برسند. این توابع در شبکه‌های عصبی باهدف بهبود فرآیند آموزش و


در شکل ۶ نمایش داده شده است. اتصال پرسپترون‌ها به یکدیگر تشکیل‌دهنده شبکه عصبی چندلایه است که در متداول‌ترین معماری این شبکه‌ها سه لایه اصلی، لایه ورودی، لایه مخفی و لایه خروجی بکار گرفته می‌شود [۱۹]. قسمت (الف) شکل ۷، ساختار MLP و در قسمت (ب) پرسپترون تک‌لایه نمایش داده شده است. این شبکه ابزار قدرتمندی است که از آموزش نظارت‌شده با استفاده از نمونه‌های داده با خروجی‌های معلوم بهره می‌برد. در این شبکه عصبی، پس از فعال شدن نورون‌های ورودی، سایر نورون‌ها، از طریق اتصالات وزنی فعال می‌شوند. این کار ادامه پیدا می‌کند و پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه نهان به‌عنوان ورودی‌های لایه خروجی مورد استفاده قرار می‌گیرد. این فرایند رفتار غیرخطی را شناسایی و پیش‌بینی داده‌های خروجی را از داده‌های ورودی امکان‌پذیر می‌سازد [۱۹]. هر اتصال بین نورون‌ها وزن خاص خود را دارد. پرسپترون‌ها در یک لایه از تابع فعال‌سازی یکسانی برخوردارند. در رابطه (۱) عملیات هر پرسپترون بیان شده است. در این رابطه حاصل جمع مقادیر ورودی در وزن مربوطه با بایاس به ورودی تابع انتقال می‌رود و خروجی تابع انتقال، خروجی پرسپترون است.

$$y = f(z) \text{ and } z = \sum_{i=0}^n [w_i x_i] \quad (1)$$

در میان بسیاری از الگوریتم‌های یادگیری، الگوریتم پس انتشار در راستای آموزش MLP شناخته‌شده‌تر است. وزن‌ها می‌توانند با پس انتشار خطا، از لایه خروجی به سمت عقب، از لایه‌ای به لایه دیگر حرکت کرده و اصلاح شوند. عملکرد مدل MLP به انتخاب متغیرها، تعداد لایه‌های پنهان، گره‌ها و داده‌های آموزشی وابسته است. به دلیل عملکرد مناسب در مواجهه با داده‌های ناقص، ازدست‌رفته یا نویز دار، عدم نیاز به فرضیات قبلی در مورد توزیع داده و توانایی در نگاشت توابع و الگوهای پیچیده، MLP در حل مسائل گوناگون مورد استفاده گسترده‌ای شده است [۱۹].




شکل ۶- معماری پرسپترون. x_1 تا x_n ورودی، عملگر $\times$ مقدار ثابت بایاس، $\sum$ تجمیع مقادیر ورودی و بایاس، f تابع فعال‌سازی روی $\sum$ و y خروجی پرسپترون هستند [۱۹].



(ب) پرسپترون تک‌لایه

(الف) پرسپترون چندلایه

شکل ۷- معماری مدل (الف) پرسپترون چندلایه (ب) پرسپترون تک‌لایه [۱۹]



شکل ۸- مصورسازی داده خام سازه مبنا با استفاده از الف) T-SNE، ب) PCA و پ) UMAP (قرمز: حالات دارای آسیب، آبی: حالات سالم)

۵- نتایج



نتایج ارزیابی مدل‌های آموزش‌دیده، روی داده‌های آزمون (تست) در جدول ۳ نشان داده شده است. به منظور مصورسازی بهتر نتایج شکل ۱۴ پیشنهاد شده است. داده‌های آزمون قسمتی از کل داده‌ها هستند که مدل در فرآیند آموزش با آن‌ها برخورد نداشته و آن‌ها را ندیده است. میانگین نتایج معیارهای دقت متوازن، صحت، بازخوانی، $F1$ -score و AUC-ROC در جدول ۳ و شکل ۱۴ برای ۱۰ تکرار برای مدل‌های LSTM و GRU و ۲۰ تکرار برای مدل‌های CNN و CNNLSTM گزارش شده‌اند. زمان آموزش مدل‌ها در شکل ۱۳ و تعداد پارامترهای قابل آموزش هر یک از مدل‌ها در شکل ۱۵ نشان داده شده است.


جدول ۲- هایپر پارامترهای مدل‌های پیشنهادی

CNNLSTM	CNN	GRU	LSTM	هایپر پارامترهای مدل
۲	۲	۲	۲	تعداد کلاسی‌ها
۹	۷	۵	۵	تعداد کل لایه‌ها
RMSprop	RMSprop	RMSprop	RMSprop	تابع بهینه یابی
Relu - Tanh - Sigmoid	Relu - Sigmoid	Tanh - Sigmoid	Tanh - Sigmoid	تابع فعال‌سازی لایه‌ها
BCE	BCE	BCE	BCE*	تابع هزینه
۱۲۸	۱۲۸	۱۲۸	۱۲۸	اندازه دسته آموزش
۵۰	۵۰	۱۰۰	۱۰۰	تعداد دفعات آموزش
۰/۴	۰/۴	۰/۴۵	۰/۴۵	نرخ متوسط لایه بیرون انداز
۱۳۸۱۷	۱۳۰۳۵۳	۱۳۲۹۰۵	۱۳۳۳۸۵	کل پارامترهای قابل آموزش


* Binary Cross-Entropy Loss

پارامترهای شبکه، مقادیر وزن‌ها و بایاس‌ها در لایه‌های مختلف را در راستای هدف موردنظر تنظیم می‌کنند. نرخ یادگیری، اندازه گام‌ها در الگوریتم بهینه‌سازی را مشخص می‌کند. در نوع خاصی از این توابع، با کاهش یا افزایش نرخ یادگیری آموزش شبکه بهبود می‌یابد. اثر این توابع در هنگام حرکت رو به عقب شبکه، حین یادگیری بر اساس قاعده پس انتشار خطا اعمال می‌شود. طی آموزش شبکه‌های مزبور از تابع بهینه یاب RMSprop استفاده شده است. تعداد دفعات آموزش، تعداد دفعاتی است که داده‌های آموزش در اختیار شبکه گذاشته می‌شود و شبکه داده‌ها را می‌بیند. معمولاً در تعیین آن قانون مشخصی وجود ندارد اما به عنوان یک معیار کلی، پیش از ثابت ماندن یا کاهش دقت آموزش، آموزش شبکه متوقف خواهد شد. در روند آموزش شبکه‌های عصبی عمیق به دلیل محدودیت‌های پردازشی، امکان پردازش کل داده در هر دوره جود ندارد. لذا در فرآیند آموزش، زیرمونه‌هایی (دسته) از کل داده در هر دوره، به صورت قطعه به قطعه به شبکه داده می‌شود. سائز دسته‌ها در هر دوره معمولاً ۳۲، ۶۴ و ۱۲۸ انتخاب می‌شود.





شکل ۱۴- نتایج مدل‌ها با ارائه معیارهای ارزیابی مختلف



شکل ۱۵- تعداد پارامترهای قابل آموزش مدل‌ها

۵-۱- مقایسه بین مدل‌ها برای استخراج ویژگی‌ها

نتایج نشان‌دهنده یک سلسله‌مراتب واضح در عملکرد شبکه‌ها است. LSTM به گونه‌ای طراحی شده‌است که وابستگی‌های بلندمدت در داده‌های دنباله‌ای کشف کند. این ویژگی برای کاربردهای SHM که روابط زمانی بسیار مهم هستند، بسیار مناسب است. GRU معماری ساده‌تری نسبت به LSTM دارند و با ترکیب دروازه‌های فراموشی و ورودی به یک دروازه به‌روزرسانی، کارایی را افزایش می‌دهند. با این حال، درحالی‌که GRU می‌تواند وابستگی‌ها را به خوبی مدیریت کنند، ممکن است در مدل‌سازی داده‌های چندمتغیره پیچیده در SHM نتوانند به عمق یادگیری مشابه LSTM‌ها دست یابند. مدل‌های CNN عملیات تلفیقی را بر روی داده‌های دنباله‌ای یک‌بعدی اعمال می‌کنند و به این ترتیب می‌توانند ویژگی‌ها و الگوهای محلی را با کارایی استخراج کنند. مدل ترکیبی CNNLSTM، می‌تواند با بهره‌گیری از قابلیت‌های استخراج ویژگی CNN و توانایی مدل‌سازی زمانی LSTM، به شناسایی بهترین الگوها در پایش سلامت سازه کمک کند. این معماری به‌ویژه برای SHM مناسب است زیرا می‌تواند ابتدا ویژگی‌های محلی را از حسگرها استخراج کرده و سپس وابستگی‌های زمانی بین این ویژگی‌ها را مدل‌سازی کند. عملکرد کلی مدل‌ها از نظر معیارهای ارزیابی مندرج در شکل ۱۴:


$$CNNLSTM > CNN > LSTM >> GRU$$

از نظر تلاش محاسباتی در فرآیند آموزش مدل‌ها که در شکل ۱۳


به نمایش گذاشته شده است به صورت:

$$CNNLSTM \cong CNN > LSTM \cong GRU$$


و از نظر معیار مهم تعداد پارامترهای قابل آموزش که در شکل ۱۵




شکل ۹- معماری مدل LSTM



شکل ۱۰- معماری مدل GRU




شکل ۱۱- معماری مدل CNN



شکل ۱۲- معماری مدل CNNLSTM

جدول ۳- نتایج ارزیابی مدل‌ها بر روی داده آزمون (برحسب درصد)

	F1-score	دقت متوازن	صحت	بازخوانی	ROC AUC
LSTM	۹۸/۰۱	۹۷/۰۹	۹۹/۳۰	۹۶/۷۶	۹۹/۶۴
GRU	۹۲/۲۱	۸۸/۴۷	۹۲/۳۷	۹۲/۰۶	۹۵/۸۳
CNN	۹۸/۹۸	۹۸/۴۶	۹۸/۶۲	۹۹/۳۳	۹۹/۸۷
CNN LSTM	۹۹/۹۳	۹۹/۸۹	۹۹/۹۵	۹۹/۹۰	۹۹/۹۸



شکل ۱۳- زمان آموزش مدل‌ها

گزارش شده است، به صورت:

$$CNNLSTM \gg CNN \cong LSTM \cong GRU$$

در شکل ۱۶ نمودار عنکبوتی به منظور مقایسه دقیق تر نتایج جدول ۳ ارائه شده است. عملکرد برتر مدل CNNLSTM به توانایی آن در مدلسازی هم زمان ویژگی های محلی و وابستگی های بلندمدت بازمی گردد. این معماری ترکیبی به خوبی اطلاعات را در طول زمان ترکیب می کند و در نتیجه در شناسایی الگوهای پیچیده که نشان دهنده مشکلات سازه های هستند، بسیار مؤثر است. عملکرد CNN اگرچه کمی کمتر از CNNLSTM است، به دلیل کارایی آن در استخراج ویژگی های محلی اما هنوز هم قوی است. در حالی که شبکه های LSTM برای کشف وابستگی های بلندمدت بسیار قدرتمند هستند، ممکن است در مقایسه با معماری های مبتنی بر CNN در زمینه SHM که استخراج ویژگی های محلی را ضروری می داند، عملکرد کمتری داشته باشند. اگرچه GRUها از نظر محاسباتی کارآمد هستند، اما در این پژوهش کمترین عملکرد را داشتند. ساختار ساده آن ها ممکن است به اندازه کافی پیچیدگی های موجود در داده های چندمتغیره زمانی سیستم های SHM را به خوبی درک نکند. در سناریوهایی که نیاز به مدلسازی دقیق زمانی وجود دارد، GRUها ممکن است نتوانند به اندازه LSTMها و مدل های مبتنی بر CNN مؤثر باشند. به طور کلی توانایی شبکه های عصبی عمیق در مدلسازی روابط و الگوهای سری زمانی اثبات شده است. اخیراً مطالعات در جهت بهینه سازی این مدل ها با هدف ثابت نگه داشتن دقت پیشین و از طرفی کاهش تلاش محاسباتی و تعداد پارامترهای قابل آموزش در فرآیند توسعه این مدل هاست. از این رو تلاش بر این بوده است، معماری های مدل های پیشنهادی برقرار کننده شروط فوق باشند.

CNNLSTM پژوهش حاضر و ۲،۵ برابر سایر مدل های پژوهش حاضر است. در جهت مقایسه زمان آموزش، مدل های CNNLSTM و CNN پژوهش حاضر با دو دقیقه آموزش بسیار بهینه تر از مدل های پژوهش [۳] عمل کرده اند.

جدول ۵ نتایج پژوهش اصغرزاده و همکاران را نمایش می دهد [۹]. در پژوهش مورد نظر دقت تشخیص آسیب صرفاً بر اساس ویژگی های دامنه زمان موجود است. از نظر مقایسه نتایج مدل های پژوهش مورد نظر با نتایج پژوهش حاضر در دامنه زمان، کارایی مدل های پژوهش حاضر مشهود است. از طرفی از نظر مقایسه نتایج کلی پژوهش مورد نظر با پژوهش حاضر، شاید در نگاه اول هر دو پژوهش به نتایج یکسان رسیده اند، اما با توجه به استفاده از دو نوع الگوریتم پردازش سیگنال در کنار استفاده از شبکه های عصبی عمیق به صورت موازی، پژوهش مورد نظر از نظر تلاش محاسباتی بسیار گران است. از طرفی بکارگیری الگوریتم های پردازش سیگنال نیاز به دانش تخصصی انسانی دارد. از این رو مدل های پیشنهادی پژوهش حاضر از نظر تلاش محاسباتی بهینه تر از پژوهش مورد نظر عمل می کنند.

قره باغی و همکاران در پژوهش های [۲۲ و ۲۱] رویکرد پیشنهادی شان را روی سازه مبنا پژوهش حاضر اعتبار سنجی نمودند. نتایج پژوهش آن ها در جدول ۶ و ۷ ارائه شده است. آن ها با ارائه رویکردی جهت انتخاب ویژگی های حساس به آسیب و فرآیند قابل توجه پیش پردازش آسیب را در سازه مبنا سه طبقه لوس آلاموس تشخیص دادند. مقایسه نتایج تشخیص آسیب در پژوهش حاضر گزارش شده در جدول ۳ و نتایج پژوهش آن ها، حاکی از دقت بالاتر کلاس بندی های LSTM، CNN و CNNLSTM نسبت به مدل های پیشنهادی آن هاست.

جدول ۴- نتایج تشخیص آسیب پژوهش دانگ و همکاران [۳]


Task	MLP of trucks	1DCNN (m/s)	LSTM loss (%)	2DCNN location
Detection accuracy (%)	97	97	99	99
Localization accuracy (%)	87	93	93.5	95
Severity accuracy (%)	85	91	92.6	94.6
Training time (s)	350	470	930	1250
Number of trainable parameters	389806	342670	326606	540550
Storage (Mb)	1010	1010	1010	1945

جدول ۵- نتایج تشخیص آسیب پژوهش اصغرزاده و همکاران [۹]

نوع ویژگی	زمان - فرکانس	ترکیب ویژگی ها
آسیب خطی	۸۸/۷۷	۹۲/۶۷
آسیب غیرخطی	۷۹/۲۹	۹۱/۷۲

جدول ۶- نتایج تشخیص آسیب پژوهش قره باغی و همکاران [۲۱]

Overall accuracy (%)	ANN	SVM	KNN	Average
Story 1	92.2	92.0	86.6	92.2
Story 2	90.9	87.5	85.7	88.1
Story 3	90.9	83.9	78.6	84.4
Average	91.3	87.8	83.6	-



شکل ۱۶- نتایج مدل های مختلف (بر حسب درصد)

۲-۵- تحلیل مقایسه ای با پژوهش های پیشین

دانگ و همکاران در پژوهشی در سال ۲۰۲۰ به توسعه مدل های مشابه روی سازه مبنا سه طبقه LANL پرداختند [۳]. مقادیر دقت تشخیص آسیب توسط مدل های پژوهش مورد نظر در جدول ۴ گزارش شده است. با مقایسه نتایج جدول مورد نظر با جدول ۳ حاصل پژوهش حاضر، تمامی معیارهای ارزیابی مشابه در هر دو پژوهش، برای مدل های LSTM، GRU، CNN و CNNLSTM مقادیر بالاتری گزارش شده است. نکته دیگر مقادیر پارامترهای قابل آموزش مدل ها پیشنهاد شده پژوهش [۳] در جدول ۴ است، جایی که مقادیر پارامترهای مدل های پیشنهادی آن پژوهش، تقریباً ۲۵ برابر مدل

[۲] نظامیوند چگینی س، باقری الف، رضانی دشتیمان م، احمدی ب. طبقه‌بندی چند عصبی برای چرخ‌دنده‌ها بر پایه‌ی تبدیل موجک گسسته، انتخاب مناسب‌ترین ویژگی و ماشین بردار پشتیبان بهبود یافته. مهندسی مکانیک دانشگاه تبریز. ۱۴۰۱؛ ۵۲(۲): ۳۶۱-۳۷۰. doi: 10.22034/jmeut.2020.11607

[3] Dang HV, Raza M, Nguyen TV, Bui-Tien T, Nguyen HX. Deep learning-based detection of structural damage using time-series data. *Structure and Infrastructure Engineering*. 2021 Oct 11;17(11):1474-93.

[4] Abdeljaber O, Avci O, Kiranyaz S, Gabbouj M, Inman DJ. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks. *Journal of sound and vibration*. 2017 Feb 3;388:154-70.

[5] Guo T, Wu L, Wang C, Xu Z. Damage detection in a novel deep-learning framework: a robust method for feature extraction. *Structural Health Monitoring*. 2020 Mar;19(2):424-42.

[6] Teng Z, Teng S, Zhang J, Chen G, Cui F. Structural damage detection based on real-time vibration signal and convolutional neural network. *Applied Sciences*. 2020 Jul 9;10(14):4720.

[7] Sharma S, Sen S. One-dimensional convolutional neural network-based damage detection in structural joints. *Journal of Civil Structural Health Monitoring*. 2020 Nov;10(5):1057-72.

[8] Liu T, Xu H, Ragulskis M, Cao M, Ostachowicz W. A data-driven damage identification framework based on transmissibility function datasets and one-dimensional convolutional neural networks: Verification on a structural health monitoring benchmark structure. *Sensors*. 2020 Feb 15;20(4):1059.

[۹] اصغرزاده بناب الف، کلب خانی ه، بیژنوند س. ارائه روشی مبتنی بر یادگیری ماشین برای تشخیص آسیب‌های خطی و غیرخطی سازه با ترکیب ویژگی‌های عمیق زمانی و زمان - فرکانس. مهندسی مکانیک دانشگاه تبریز. ۱۴۰۳؛ ۵۴(۱): ۷۱-۸۰. doi: 10.22034/jmeut.2024.60099.3368

[10] Figueiredo E, Park G, Figueiras J, Farrar C, Worden K. Structural health monitoring algorithm comparisons using standard data sets. *Los Alamos National Lab (LANL), Los Alamos, NM (United States)*; 2009 Mar 1.

[11] Cha YJ, Ali R, Lewis J, Büyüköztürk O. Deep learning-based structural health monitoring. *Automation in Construction*. 2024 May 1;161:105328.

[12] Avci O, Abdeljaber O, Kiranyaz S, Hussein M, Gabbouj M, Inman DJ. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical systems and signal processing*. 2021 Jan 15;147:107077.

[13] O'Shea K. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*. 2015.

[14] Marcus G. Deep Learning: A Critical Appraisal. *arXiv preprint arXiv:1801.00631*. 2018.

[15] Dong S, Wang P, Abbas K. A survey on deep learning and its applications. *Computer Science Review*. 2021 May 1;40:100379.

[16] Schmidt RM. Recurrent neural networks (rnns): A gentle introduction and overview. *arXiv preprint arXiv:1912.05911*. 2019 Nov 23.

[17] Van Houdt G, Mosquera C, Nápoles G. A review on the long short-term memory model. *Artificial Intelligence Review*. 2020 Dec;53(8):5929-55.

جدول ۷- نتایج تشخیص آسیب پژوهش قره‌باغی و همکاران [۲۲]
Accuracy of classification in models.

Story	Deterioration		Damage
1	Scenario #1	91.7%	97.3%
	Scenario #2	83.3%	
	Scenario #3	83.3%	
2	Scenario #1	91.7%	100.0%
	Scenario #2	91.7%	
	Scenario #3	83.3%	
3	Scenario #1	100.0%	100.0%
	Scenario #2	91.7%	
	Scenario #3	91.7%	

۶- نتیجه‌گیری و پیشنهادات

در این پژوهش، روش‌های استخراج ویژگی توسط شبکه‌های عصبی عمیق و تصمیم‌گیری مبتنی بر آن‌ها، ساختاری مطمئن و توانمند برای تشخیص آسیب سازه‌ای کشف شدند. از این رو استخراج ویژگی حساس به آسیب از پاسخ‌های ارتعاشی حاصل از تحریک محیطی، فارغ از محتوای غیرخطی و غیرایستا آن‌ها، صرفاً بر اساس داده‌های خام، با در نظر گرفتن عدم قطعیت‌های متعدد موجود و بدون مبادرت به پیش‌پردازش پیچیده نظیر استفاده از روش‌های پردازش سیگنال یا الگوریتم‌های کاهش ابعاد صورت گرفت. در مدل‌های پیشنهادی وضعیت‌های مختلف سازه تشخیص داده شد و با تحلیل مقایسه‌ای از مدل‌های LSTM، GRU، CNN و CNNLSTM برای داده‌های سری زمانی چندمتغیره سازه موردبررسی، نتایج هریک طی نمودارها و جداول متنوع مورد ارزیابی قرار گرفت. در این بین اثربخشی مدل ترکیبی CNNLSTM در شناسایی دقیق وضعیت سازه، با وجود درهم‌تنیدگی و وابستگی پیچیده بین حالات مختلف سازه مشهود است. یکی از نقاط مثبت پژوهش، ایجاد معماری‌های کارا درعین حال مشابه به‌منظور اطمینان از درستی مقایسه نتایج آن‌هاست. درحالی‌که هر یک از مدل‌ها نقاط قوت خاص خود را دارد، یافته‌ها نشان می‌دهد که استفاده از ترکیب شبکه‌های تلفیقی و بازگشتی CNNLSTM، با دقت ۹۹/۹٪ نتایج دقیقی در تشخیص آسیب سناریوهای مختلف به همراه دارد، همچنین مدل موردنظر از نظر تعداد پارامترهای آموزش (۱۳۸۱۷ پارامتر) و تلاش محاسباتی (نیاز به ۲ دقیقه جهت آموزش روی داده‌های سازه مورد بررسی) عملکرد مطلوبی دارد. جهت اثبات کارایی مدل پیشنهادی، نتایج با مدل‌های پژوهش مشابه بر روی سازه مینا یکسان مقایسه گردیده که حاکی نتایجی دقیق‌تر در قیاس با آن‌ها است.

۷- سپاسگزاری

با سپاس و تقدیر ویژه از جناب آقای مهندس امید خلف بیگی، دانشجوی کارشناسی ارشد مهندسی کامپیوتر دانشگاه خوارزمی که در مراحل مختلف این پژوهش راهنمایی‌های ارزنده‌ای داشته و از هیچ کوششی دریغ ننموده است.

۸- مراجع

[۱] نظری بیگدیلو ر، ایران‌دوست پاکچین ص. تشخیص وجود ترک در تیر یکسرگیردار با استفاده از روش حسگری فشرده (CS). مهندسی مکانیک دانشگاه تبریز. ۱۴۰۱؛ ۵۲(۴): ۱۴۵-۱۵۲. doi: 10.22034/jmeut.2022.49808.3041

- [18] Chung J, Gulcehre C, Cho K, Bengio Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint arXiv:1412.3555. 2014 Dec 11.
- [19] Taud H, Mas JF. Multilayer perceptron (MLP). Geomatic approaches for modeling land change scenarios. 2018:451-5.
- [20] Michelucci U. An introduction to autoencoders. arXiv preprint arXiv:2201.03898. 2022 Jan 11.
- [21] Gharehbaghi VR, Noroozinejad Farsangi E, Yang TY, Hajirasouliha I. Deterioration and damage identification in building structures using a novel feature selection method. Structures. 2020 Dec 9;29:458–70.
- [22] Gharehbaghi VR, Nguyen A, Noroozinejad Farsangi E, Yang TY. Supervised damage and deterioration detection in building structures using an enhanced autoregressive time-series approach. Journal of Building Engineering. 2020 Feb 20;30:101292.