یازدهمین کنگره ملی سراسری
فناوریهای نوین در حوزه توسعه پایدار ایران
11th National Congress of
the New Technologies in Sustainable Development of Iran
senaconf.ir

تشخیص آسیب در سازه بر اساس الگوریتم هوشمند مبتنی بر شبکه عصبی همگشتی

محمدمهدی کلانتری[۱]، زهرا علی عرب[۲]، علی بیگلری*[۳].

[۱]دانشجوی کارشناسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان

[2]دانش آموخته کارشناسی ارشد عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان

*[۳]استادیار گروه مهندسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، Biglari.a@gmail.com

چکیده

در چند سال گذشته، الگوریتم‌های هوشمند تشخیص آسیب ساختاری بر اساس تکنیک‌های یادگیری ماشینی، توسعه یافته و به دلیل تجزیه و تحلیل قابل اعتماد و کارایی بالا مورد توجه جهانی قرار گرفته است. با این حال، عملکرد روش‌های شناسایی آسیب مبتنی بر یادگیری ماشینی به شدت وابسته به اثر انتخاب شده از سیگنال‌های خام است. این امر باعث می‌شود که روش شناسایی آسیب، در موارد دیگر عملکرد مشابهی را ارائه ندهد. علاوه بر این، استخراج ویژگی‌ها یک کار وقت‌گیر است که ممکن است بر عملکرد زمان واقعی در برنامه‌های کاربردی تأثیر بگذارد. برای مقابله با این مشکلات، این مقاله یک روش جدید مبتنی بر شبکه‌های عصبی همگشتی را برای شناسایی آسیب‌های سازه‌ای ساختمان مجهز به دستگاه‌های کنترل هوشمند پیشنهاد می‌کند. این شبکه عصبی پیشنهادی قادر به استخراج خودکار ویژگی‌های طبقات بالا از سیگنال‌های خام یا ویژگی‌های طبقات پایین است. برای ارزیابی عملکرد روش شبکه عصبی همگشتی پیشنهادی، یک مدل عددی معمولی از یک ساختمان با سناریوی آسیب به منظور شناسایی آسیب برای کد توسعه یافته ASAP با یک سازه مشابه در نرم‌افزار اجزای محدود Abaqus^{TM} شبیه‌سازی شده و فرکانس‌های طبیعی سازه مورد بررسی قرار گرفته است. نتیجه نشان می‌دهد که روش پیشنهادی شبکه‌های عصبی همگشتی عمیق می‌تواند با دقت مناسبی درستی مقادیر مودهای نوسانی سازه را پیش‌بینی نماید.

کلید واژه: پایش سلامت سازه، ساختمان هوشمند، هوش مصنوعی، شبکه عصبی مصنوعی، یادگیری ماشین، توسعه پایدار.

۱- مقدمه

شناسایی آسیب نقش بسزایی در ارزیابی یکپارچگی سازه و حفظ عملکرد ساختمان‌ها دارد، زیرا زیرساخت‌های عمرانی در طول عمر مفید تحت تاثیر آسیب‌های گوناگونی می‌باشند. به طور کلی، ساختار شناسایی آسیب در سازه به چهار سطح تقسیم می شود: شناسایی اولیه آسیب، تشخیص محل آسیب، تشخیص شدت آسیب و برآورد عمر باقی‌مانده سازه. رویکردهای معمولی شناسایی آسیب، از طریق تجزیه و تحلیل پاسخ‌های دینامیکی سازه، به دو دسته تقسیم می‌شود: رویکردهای مبتنی بر آزمایش غیر مخرب[۱] (NDT) و رویکردهای مبتنی بر ارتعاش[۲]. به عنوان شاخه‌ای فعال از شناسایی آسیب، رویکردهای مبتنی بر ارتعاش در چند سال گذشته توجه محققان را در سراسر جهان به خود جلب کرده است. روش‌های شناسایی آسیب موجود بر اساس ارتعاش را می‌توان در سه مرحله خلاصه کرد: استخراج، انتخاب و طبقه‌بندی ویژگی. به طور کلی، واکنش‌های ارتعاشی گرفته شده از ساختمان‌ها سیگنال‌های سری زمانی هستند که حاوی اطلاعات مفید و سیگنال‌های غیر ضروری هستند[1-2]. به عنوان یک نتیجه، بررسی روش استخراج ویژگی‌های مفید که بتواند اطلاعات ذاتی و نمایانگر ساختمان را به تصویر بکشد، بسیار ضروری است. روش‌های معمول پردازش سیگنال برای استخراج ویژگی‌های سیگنال‌های ارتعاشی شامل تبدیل موجک[۳] پیوسته و گسسته، تجزیه حالت تجربی، تجزیه و تحلیل تجربی و مودال است[3]. پس از استخراج ویژگی سیگنال، ما باید ویژگی‌های الگوهای آسیب‌دیده را انتخاب کرده و ویژگی‌های بی فایده را حذف کنیم، بنابراین ابعاد ویژگی‌ها را کاهش می‌دهیم. روش‌های انتخاب ویژگی برای شناسایی آسیب ساختمانی شامل جاسازی خطی محلی تجزیه، تحلیل اجزای مستقل تجزیه، تحلیل اجزای اصلی الگوریتم نقشه برداری ایزومتریک و غیره است. اخیراً، با پیشرفت تکنیک‌های یادگیری ماشین و رایانه، یک روش جدید یادگیری ماشین، به نام یادگیری عمیق، توسعه یافته و در زمینه‌های مختلف کاربردی است. تفاوت این دو ساختار در شکل زیر ارایه شده است. شکل ۱.

---

[1] Non-Distractive Test
[2] Vibration based Methods
[3] Wavelet Transforms

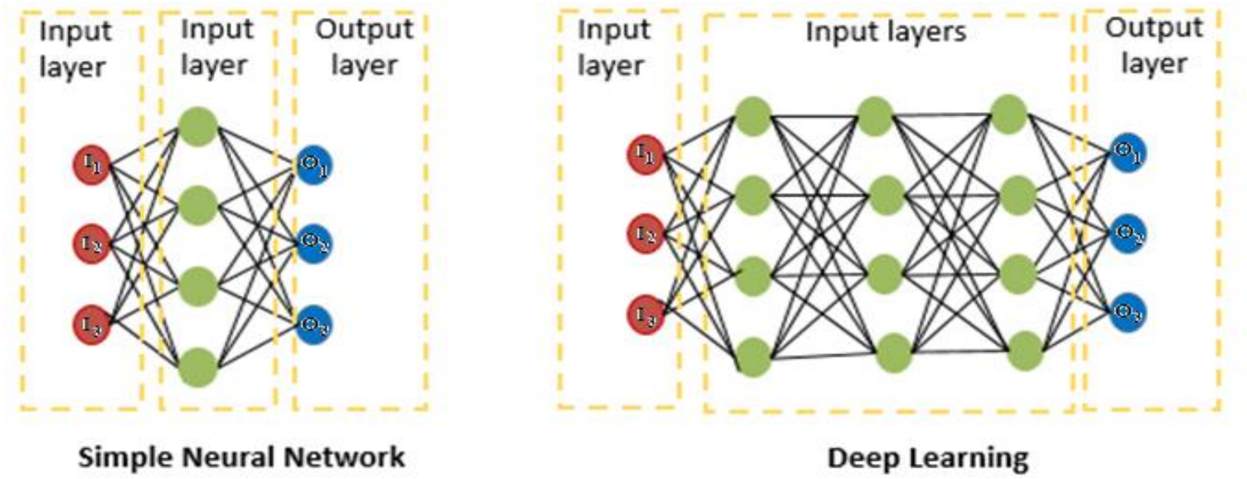

شکل۱. ساختار شبکه عصبی مصنوعی ساده و شبکه عصبی مصنوعی عمیق.

در مقایسه با روش‌های سنتی یادگیری ماشین، یادگیری عمیق دارای مزیت مهم قابلیت یادگیری ویژگی است، که می‌تواند به طور خودکار پیکربندی همگشتی را تشخیص داده و ویژگی‌های طبقات بالای مفید را از سیگنال‌های اصلی یا ویژگی‌های طبقات پایین را لایه به لایه استخراج کند. در یک مدل یادگیری عمیق، ورودی‌های اصلی با هم ادغام می‌شوند و اطلاعات پایه در لایه زیرین استخراج می‌شوند، اطلاعات اساسی در ویژگی نماینده و تصمیم گیری در لایه میانی ترکیب می‌شوند و نتیجه نهایی را در لایه بالاتر تشکیل می دهند. بر این اساس، یادگیری عمیق نه تنها می‌تواند به طور خودکار ویژگی‌های سیگنال را استخراج کند بلکه می‌تواند این ویژگی‌ها را از طریق یک قاب چند لایه ترکیب کند[5-4]. به عنوان یکی از متدهای رایج یادگیری عمیق، شبکه‌های عصبی همگشتی عمیق به طور گسترده در زمینه‌های مختلف از جمله تشخیص چهره، تشخیص گفتار، طبقه بندی سیگنال الکتروکاردیوگرام و تشخیص عیب مکانیکی اعمال شد. با این حال، کاربرد شبکه‌های عصبی همگشتی عمیق در شناسایی آسیب ساختمان‌های عمرانی به ندرت گزارش می شود. شکل ۲.

چا و همکاران یک رویکرد مبتنی بر دید را بر اساس شبکه‌های عصبی همگشتی عمیق برای تشخیص ترک خوردگی سازه بتنی توسعه دادند[6]. تانگ و همکاران از شبکه‌های عصبی همگشتی عمیق برای بومی سازی ترک‌های پنهان در روسازی آسفالت استفاده کردند[7]. هر دو مطالعه عملکرد بهتر شبکه‌های عصبی همگشتی عمیق را از نظر تشخیص ترک نسبت به سایر روش‌های سنتی

نشان داده‌اند. قابل توجه است که روش‌های موجود مبتنی بر شبکه‌های عصبی همگشتی عمیق برای شناسایی آسیب ساختمانی بر اساس پردازش تصویر است. اینکه آیا هنوز هم در پردازش سیگنال‌های ارتعاش برای اهداف شناسایی آسیب مؤثر است، نیاز به بررسی بیشتر دارد. از سوی دیگر، فناوری‌های کنترلی نیز می‌توانند در شناسایی آسیب زیرساخت‌های عمرانی که تحت تحریکات دینامیکی خارجی (از جمله بادهای شدید، زلزله ها، شوک‌ها و امواج مخرب) قرار دارند، مورد استفاده قرار گیرند[9-8]. اخیراً، با توسعه سریع مواد حساس به میدان مغناطیسی با خواص وابسته به سرعت، دستگاه‌های مبتنی بر مواد حساس به میدان مغناطیسی ، مانند جذب‌کننده مواد حساس به میدان مغناطیسی میراگرهای حساس به میدان مغناطیسی و جداکننده‌های الاستومر مغناطیسی، به عنوان دستگاه‌های کنترل نیمه فعال مورد استفاده در ساختمان‌ها، توسعه یافته است. بر این اساس، ساختمان‌های هوشمند، متشکل از خود ساختمان‌ها و دستگاه‌های مواد حساس به میدان مغناطیسی نصب شده، به دلیل ویژگی منحصر به فرد آنها در ترکیب مزایای هر دو سیستم کنترل فعال و غیرفعال، مورد توجه مهندسان قرار گرفته است. با این وجود، عملکرد سیستم‌های سازه هوشمند هنگامی که سازه‌ها یا محرک‌ها از کار بی‌افتند به طور جدی تحت تأثیر قرار می‌گیرد. تحقیقات فعلی در مورد شناسایی آسیب ساختارهای عمرانی در مقیاس بزرگ که با دستگاه‌های کنترل هوشمند ترکیب شده‌اند محدود است. در پژوهشی دیگر، روشی بر اساس پارامترهای سیستم شناسایی شده مارکوف برای کاهش واکنش‌ها و آسیب‌های ناشی از زلزله در سازه‌های مجهز به میراگرهای مواد حساس به میدان مغناطیسی معرفی کردند. با این وجود تا کنون، روش‌های سیستماتیک برای تشخیص آسیب سازه‌های هوشمند با دستگاه‌های مواد حساس به میدان مغناطیسی تحت بارهای محیطی محدود است. به ویژه، هیچ مطالعه جامعی با استفاده از یادگیری عمیق برای شناسایی آسیب سازه‌های ساختمانی که با جداکننده‌های مواد حساس به میدان مغناطیسی ترکیب شده‌اند، وجود ندارد. در نتیجه، این کار بر طراحی یک مدل شبکه‌های عصبی همگشتی عمیق ابتکاری برای شناسایی آسیب سازه‌های ساختمان با استفاده از دستگاه‌های هوشمند تحت بارهای محیطی متمرکز می‌شود. ادامه مقاله به شرح زیر تنظیم شده است: بخش "شرح مختصر شبکه‌های عصبی همگشتی عمیق "مقدمه‌ای مختصر از شبکه‌های عصبی همگشتی عمیق را ارائه می‌دهد. در بخش "روش مبتنی بر شبکه‌های عصبی همگشتی عمیق برای شناسایی آسیب سازه‌های هوشمند"، الگوریتم شبکه‌های عصبی همگشتی عمیق برای شناسایی آسیب سازه‌های ساختمان هوشمند به تفصیل شرح داده شده است. بخش "اعتبارسنجی عددی" عملکرد روش پیشنهادی را از طریق یک مدل بنایی پنج طبقه با آزمایش در برابر زلزله مجهز به جداکننده‌های مواد حساس به میدان مغناطیسی E

تحت شرایط مختلف بهداشتی مورد تجزیه و تحلیل و بحث قرار می‌دهد. سرانجام، در قسمت آخر نتیجه گیری این پژوهش ارایه می شود.

۲- معماری شبکه‌های عصبی همگشتی عمیق

شبکه‌های عصبی همگشتی عمیق یکی از مدل‌های یادگیری عمیق برای پردازش داده‌ها است که توپولوژی شبکه‌ای دارد. به عنوان مثال، داده‌های زمان سنج را می‌توان به عنوان یک شبکه یک بعدی در نظر گرفت که در فواصل زمانی منظم نمونه می‌گیرد و داده‌های مربوط به یک شبکه دو بعدی پیکسل است. همانطور که در شکل ۲ نشان داده شده است، به طور معمول شبکه‌های عصبی همگشتی عمیق از سه نوع لایه تشکیل شده است: لایه‌های همگشتی، لایه‌های زیر نمونه برداری و طبقه بندی (یا لایه‌ها به طور کامل متصل شده‌اند). لایه‌های همگشتی و زیر نمونه برداری برای استخراج ویژگی‌ها از داده‌های ورودی به صورت لایه‌ای طبقه بندی شده‌اند می باشند در حالیکه لایه‌های طبقه‌بندی برای تصمیم‌گیری نهایی با توجه به ویژگی‌های آموخته شده استفاده می‌شوند.

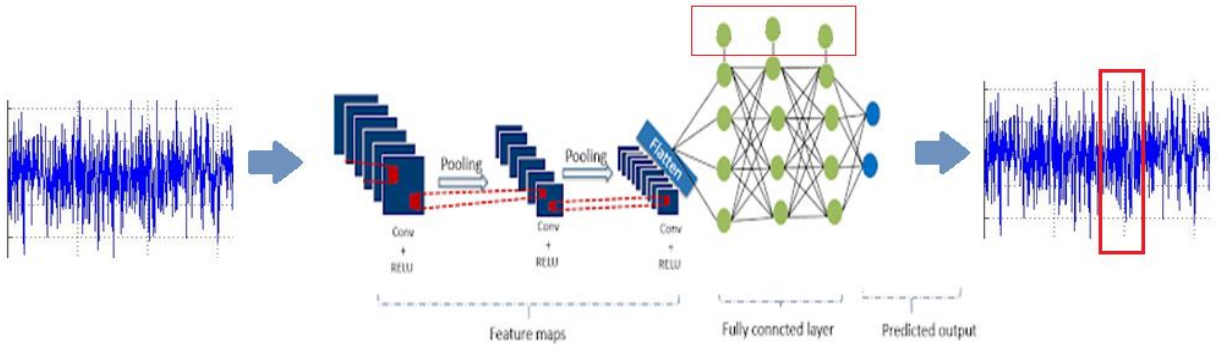

شکل۲. ساختار شبکه عصبی مصنوعی همگشتی عمیق.

شبکه‌های عصبی همگشتی عمیق برای پردازش داده‌های ورودی از عملیات ریاضی همگشتی استفاده می‌کند. به طور خاص، لایه همگشتی شامل گروهی از فیلترها (یا هسته‌ها) قابل آموزش است. سپس، فیلترها را روی هر عنصر داده‌های ورودی می‌کشیم، ورودی‌های مربوط به فیلتر و داده‌ها را ضرب می‌کنیم و سپس آنها را جمع می‌کنیم. هر فیلتر یک فریم (یا کانال) از نقشه ویژگی در لایه زیر نمونه برداری بعدی ایجاد می‌کند و عمق لایه همگشتی برابر با تعداد فریم‌ها (یعنی تعداد هسته‌ها) است. فرض کنید w_k^i

و b_k^i وزن دهی اولیه هسته k در لایه i هستند و عملیات متقابل را می‌توان به صورت زیر بیان کرد که $y_k^{i+1}(j)$ ورودی های نورون j قاب k در لایه $(i + 1)$ را نشان می‌دهد. $x^i(j)$ منطقه j در لایه i است. نماد * نشان دهنده عملکرد محصول اسکالر بین منطقه محیطی و هسته فیلتر است. با معرفی تابع فعال‌سازی، واحد خطی اصلاح‌شده خروجی لایه همگشتی توصیف می‌شود که در آن می‌توان از تابع سیگموئید یا تابع مماس هذلولی در مدل‌های معمولی شبکه‌های عصبی همگشتی عمیق استفاده نمود. در شبکه‌های عصبی همگشتی عمیق، لایه‌های زیر نمونه برداری معمولاً پس از لایه‌های همگشتی متصل می‌شوند، که برای کاهش ابعاد داده‌های ورودی و افزایش کارایی ویژگی‌های استخراج شده استفاده می‌شود. لایه زیر نمونه برداری مرسوم، حداکثر زیرنمونه برداری است که حداکثر کار را بر روی داده‌های ورودی انجام می‌دهد تا چرخش نقشه ویژگی‌ها را از لایه پیچشی قبلی کاهش دهد. در نهایت در لایه طبقه‌بندی در شبکه‌های عصبی همگشتی عمیق، لایه طبقه‌بندی یک لایه کاملاً متصل است که به دنبال ترکیبی از لایه‌های همگشتی و زیر نمونه‌گیری، طبقه‌بندی ویژگی‌های سطح بالا را که از لایه‌های سابولوژیکی و زیر نمونه‌برداری قبلی تغییر یافته است، طبقه‌بندی می‌کند.

$$y_k^{i+1}(j)=w_k^i*x^i(j)+b_k^i$$

۳- آموزشی شبکه‌های عصبی همگشتی عمیق

در مدل شبکه‌های عصبی همگشتی عمیق، پارامترهای b_k^i و w_k^i متغیر هستند و باید در طی تمرین با استفاده از برخی الگوریتم‌های بهینه‌سازی شیب گرادیان، بهینه شوند. این تکنیک‌های بهینه‌سازی شامل اعتبار سنجی متقابل، الگوریتم مناسب شیب تصادفی و میزان یادگیری خود تطبیقی است. استراتژی اعتبارسنجی متقابل می‌تواند با انتخاب گروهی از نمونه‌های اعتبارسنجی از نمونه‌های آموزشی برای ارزیابی ظرفیت پارامترهای مدل، از برازش بیش از حد مدل آموزش‌دیده جلوگیری کند. الگوریتم شیب مناسب تصادفی برای بهبود قابلیت اطمینان آموزش مدل و تسریع روند آموزش استفاده می‌شود. علاوه بر این، میزان یادگیری عامل مهمی است که در ارتباط با عملکرد آموزش است. نرخ یادگیری پایین منجر به همگرایی آهسته می‌شود در حالی که مقدار نرخ بالا ممکن است باعث نوسان همگرایی شود. در نتیجه، ارزش نرخ یادگیری باید به طور مناسب از قبل تعیین شود تا به همگرایی سریع و نتیجه‌ای مطمئن برسیم. شکل ۳.

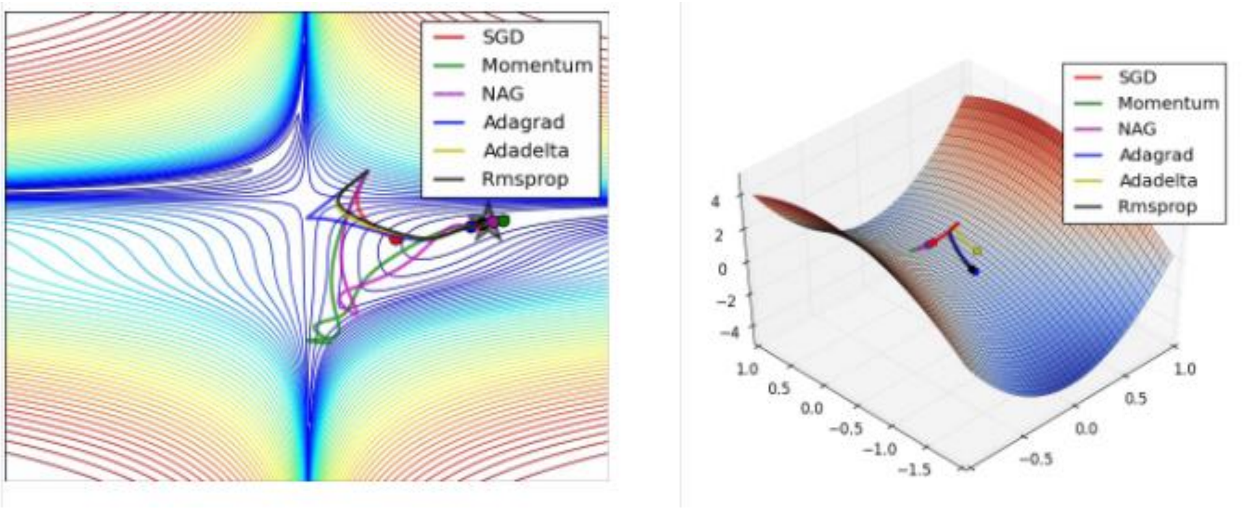

شکل۳. فرایند همگرایی آموزش ساختار شبکه عصبی مصنوعی همگشتی عمیق.

۴- کاربرد شبکه‌های عصبی همگشتی عمیق در شناسایی آسیب

در این مقاله توسعه روش شناسایی آسیب جدید در سازه‌ها بر اثر ارتعاشات خارجی از جمله تحریکات محیطی ناشی از وسایل نقلیه یا زمین‌لرزه‌ها و همچنین کنترل سیگنال های فعلی اعمال شده به دستگاه های کنترل در سازه‌های هوشمند می باشد. بر اساس دو نوع ورودی تحریک، می‌توان پاسخ‌های دینامیکی سازه‌های هوشمند را اندازه‌گیری کرد، که برای توصیف تغییرات خواص مکانیکی سازه (سختی یا میرایی) ناشی از آسیب استفاده می‌شود و معماری ساختمان هوشمند پیشنهادی تحت تحریکات خارجی و سیگنال-های کنترلی را به تصویر می کشد. در این کار، شبکه‌های عصبی همگشتی عمیق برای توسعه الگوریتم شناسایی آسیب از طریق پردازش پاسخ‌های پویا (سیگنال ها) استفاده می‌شود. شکل ۳.

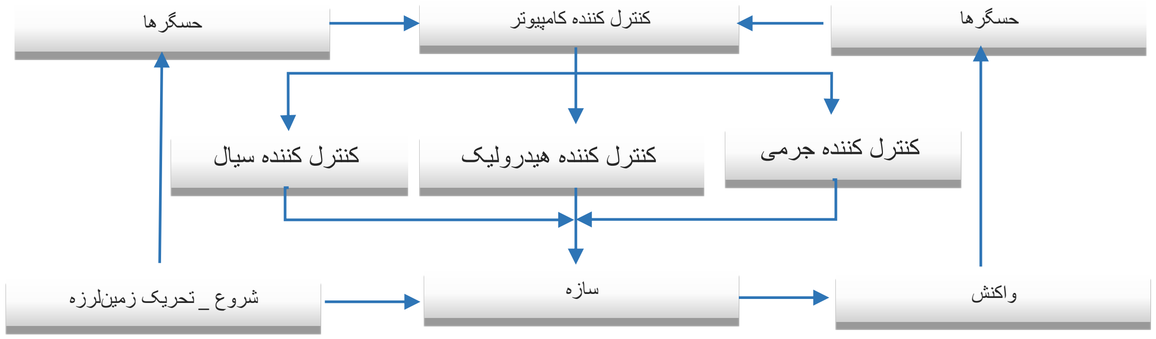

شکل۳. معماری کنترل فعال در ساختمان‌های هوشمند به منظور کنترل فعال ارتعاشات.

یافتن اطلاعات ارزشمندی که در پشت تناوب‌ها و روابط سیگنال‌ها با استفاده از روابط هسته کوچک پنهان می‌شوند، دشوار است. علاوه بر این، سیگنال‌های ارتعاش ضبط شده همیشه با صداهای فرکانس بالا آلوده می‌شوند، که بر عملکرد هسته کوچک در اولین لایه پیچشی تأثیر می‌گذارد. در نتیجه، برای استخراج مؤثر اطلاعات مفید سیگنال در فرکانس‌های پایین و متوسط، مدل پیشنهادی ابتدا یک هسته بزرگ و سپس از هسته‌های کوچک برای بدست آوردن نمای بهتر استفاده می‌شود. از سوی دیگر، برای بدست آوردن بهتر ویژگی‌های ساختمان و بهبود دقت شناسایی آسیب، قبل از استفاده از داده‌ها برای آموزش مدل، یک روش پیش پردازش داده برای سیگنال‌های ارتعاش خام ضروری است. به طور کلی، ویژگی‌های سیگنال در حوزه فرکانس کم‌تر و راحت‌تر از آن در حوزه زمان است. پس از پیش پردازش داده‌ها، ویژگی سیگنال بسیار واضح‌تر خواهد بود و طول سیگنال نیز به میزان قابل توجهی کاهش می‌یابد، که برای طراحی مدل شناسایی آسیب مبتنی بر شبکه‌های عصبی همگشتی عمیق مفید است. در این بخش، تبدیل سریع فوریه برای تبدیل سیگنال‌های توالی زمان به ویژگی‌های حوزه فرکانس انتخاب می‌شود. اهداف اصلی این عملیات استخراج اطلاعات مفید سیگنال حساس به آسیب و کاهش آن است ابعاد سیگنال‌های خام که برای مدل‌سازی آموزش برای مرحله بعدی مفید است. سپس، اجزای برآورد شده برای ساخت یک ماتریس ویژگی دو بعدی، که به عنوان ورودی شبکه‌های عصبی همگشتی عمیق طراحی شده است، انتخاب می‌شوند.

۵- ارزیابی عددی شبکه‌های عصبی همگشتی در شناسایی آسیب

در این بخش، یک مطالعه عددی برای ارزیابی عملکرد روش پیشنهادی شناسایی آسیب مبتنی بر شبکه‌های عصبی همگشتی عمیق انجام می‌شود، یک مدل عددی معمولی از یک ساختمان با سناریوی آسیب به منظور شناسایی آسیب برای کد توسعه یافته ASAP در یک سازه مشابه در نرم‌افزار اجزای محدود Abaqus™ شبیه سازی شده و فرکانس‌های طبیعی سازه در هر دو حالت با یکدیگر مقایسه می‌شود. برای این منظور یک قاب ۳ بعدی ساده با ۸ المان دارای سطح مقطع دایره تو خالی در نرم افزار Abaqus™ مدلسازی شده‌است و روی آن تحلیل فرکانسی انجام می‌شود.

در شکل۴، شکل مودی و فرکانس‌های طبیعی اول برای سازه مدل شده در نرم‌افزار Abaqus™ ارائه گردیده که تحلیل فرکانسی آن انجام شده است و در ادامه نتایج مدل‌سازی در کد توسعه یافته ASAP ارائه می‌شود. این نکته حائز اهمیت است که در مشبندی این سازه در نرم‌افزار Abaqus™ در تعریف هر عضو سازه از ۳ المان استفاده می‌شود، که هر عضو دارای ۷ گره و ۴۲ درجه آزادی است. اما برای رسیدن به همگرایی نتایج در فرکانس‌های طبیعی برابر با نرم‌افزار Abaqus™ در کد توسعه یافته ASAP هر عضو سازه با ۳ المان و با تعداد گره ۴ و تعداد درجه آزادی ۱۲ مدل‌سازی شده است.

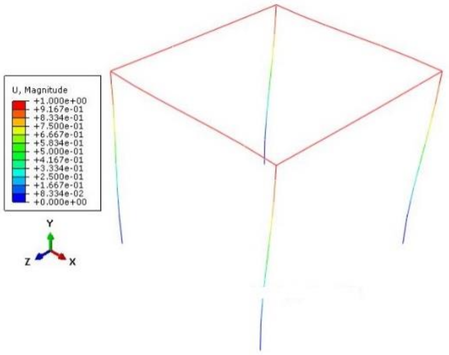
U, Magnitude
+1.000e+00
+9.167e-01
+8.334e-01
+7.500e-01
+6.667e-01
+5.834e-01
+5.000e-01
+4.167e-01
+3.334e-01
+2.500e-01
+1.667e-01
+8.334e-02
+0.000e+00
Y
Z
X

۱) مد ۱ نرم‌افزار Abaqus™ فرکانس ۱,۲۸۵۲

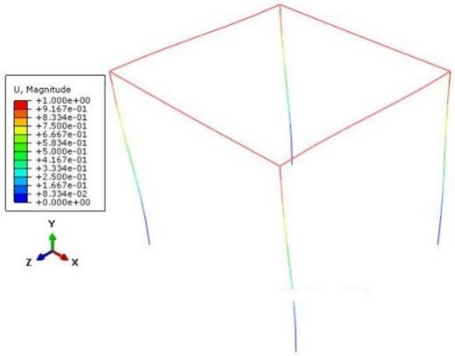
U, Magnitude
+1.000e+00
+9.167e-01
+8.334e-01
+7.500e-01
+6.667e-01
+5.834e-01
+5.000e-01
+4.167e-01
+3.334e-01
+2.500e-01
+1.667e-01
+8.334e-02
+0.000e+00
Y
Z
X

۲) مد ۲ نرم‌افزار Abaqus™ فرکانس ۱,۲۸۵۲

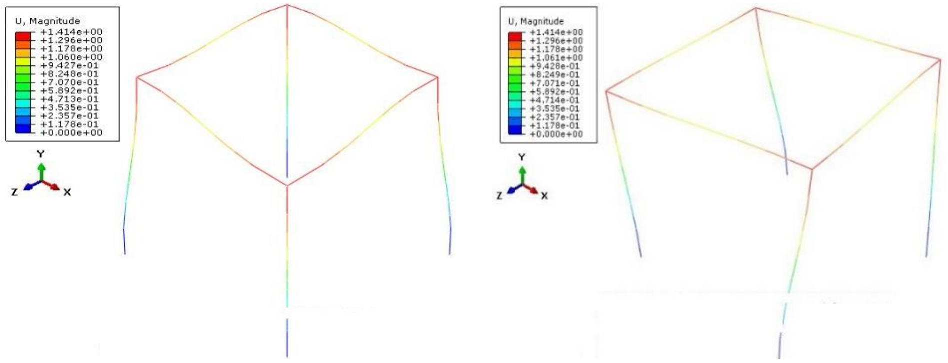
U, Magnitude
+1.414e+00
+1.296e+00
+1.178e+00
+1.060e+00
+9.427e-01
+8.248e-01
+7.070e-01
+5.892e-01
+4.713e-01
+3.535e-01
+2.357e-01
+1.178e-01
+0.000e+00
Y
Z
X
U, Magnitude
+1.414e+00
+1.296e+00
+1.178e+00
+1.061e+00
+9.428e-01
+8.249e-01
+7.071e-01
+5.892e-01
+4.714e-01
+3.535e-01
+2.357e-01
+1.178e-01
+0.000e+00
Y
Z
X

۳) مد ۳ نرم‌افزار Abaqus^{TM} فرکانس ۱٫۶۴۳۸   ۴) مد ۴ نرم‌افزار Abaqus^{TM} فرکانس ۲٫۸۱۸۸

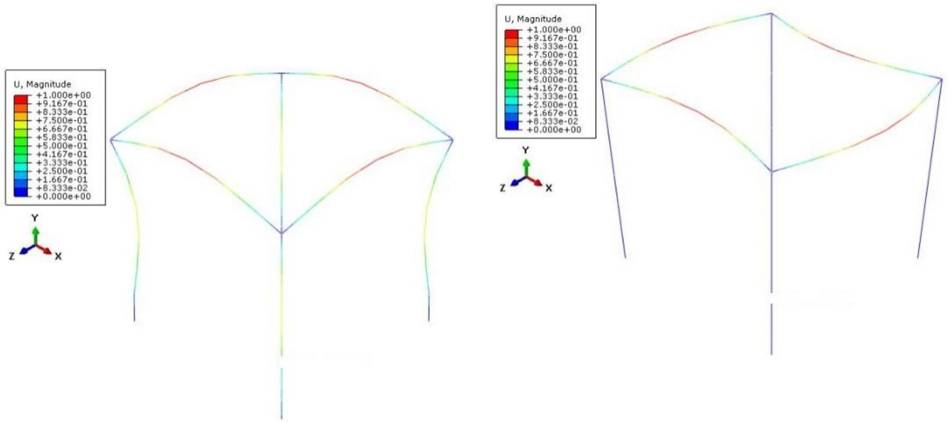
U, Magnitude
+1.000e+00
+9.167e-01
+8.333e-01
+7.500e-01
+6.667e-01
+5.833e-01
+5.000e-01
+4.167e-01
+3.333e-01
+2.500e-01
+1.667e-01
+8.333e-02
+0.000e+00
Y
Z
X
U, Magnitude
+1.000e+00
+9.167e-01
+8.333e-01
+7.500e-01
+6.667e-01
+5.833e-01
+5.000e-01
+4.167e-01
+3.333e-01
+2.500e-01
+1.667e-01
+8.333e-02
+0.000e+00
Y
Z
X

۵) مد ۵ نرم‌افزار Abaqus^{TM} فرکانس ۵٫۴۱۴۴   ۶) مد ۶ نرم‌افزار Abaqus^{TM} فرکانس ۶٫۴۶۲۹

شکل ۴. شکل‌های مدی به همراه فرکانس‌های طبیعی حاصل از نرم افزار Abaqus^{TM}

در جدول ۱ فرکانس‌های طبیعی به همراه درصد خطا نسبت به مدل Abaqus^{TM} ارائه شده‌است. همان‌گونه که مشاهده می‌شود درصد خطا به صفر میل می‌کند در نتیجه مدل‌سازی انجام شده در کد توسعه یافته ASAP با درصد خطای بسیار کم قابل پذیرش می‌باشد.

جدول ۱. مقایسه فرکانس‌های طبیعی مدل ساخته‌شده در شبیه سازی شده و Abaqus^{TM} به همراه درصد خطا.

	Mod1	***Mod2***	***Mod3***	***Mod4***	***Mod5***	***Mod6***
Abaqus^{TM}	١,٢٨٥٢	١,٢٨٥٢	١,٦٤٣٨	٢,٨١٨٨	٥,٤١٤٤	٦,٤٦٢٩
Simulation	١,٢٨٨٣	١,٢٨٨٦	١,٦٤٨٣	٢,٨٢٥٢	٥,٤٢١٣	٦,٤٧١٥
Eror%	٠,٢٧٨٦	٠,٢٧٨٥	٠,٢٦٢٣	٠,٢٤١٣	٠,١٢٧٠	٠,١٢٦٥

خطای میانگین ریشه میانگین مربع (RMS) اعتبارسنجی مدل شبکه‌های عصبی همگشتی عمیق در جدول ۱ برای مودهای مختلف نشان داده شده است.

با افزایش اندازه گروه آموزش و میزان یادگیری، خطای RMS اعتبار مدل شبکه‌های عصبی همگشتی عمیق به تدریج کاهش می‌یابد و سپس ثابت می‌ماند یا پس از رسیدن خطا به حداقل مقدار، کمی افزایش می‌یابد. به وضوح مشاهده می‌شود که روش پیشنهادی قادر است مقادیر را با دقت مناسبی پیش‌بینی نماید حتی اگر با استفاده از داده‌ها با نویز سفید گاوسی با نسبت S/N پایین بهتر باشد. شبکه‌های عصبی همگشتی عمیق می‌تواند با دقت مناسب درستی مقادیر مودهای نوسانی سازه را پیش‌بینی نماید. به طور کلی، روش شناسایی آسیب مبتنی بر شبکه‌های عصبی همگشتی عمیق هنوز می تواند عملکرد بالایی را در پیش‌بینی شدت خسارت تحت اختلال نویز زیاد حفظ کند.

۶- نتیجه

این مقاله یک روش جدید مبتنی بر شبکه‌های عصبی همگشتی عمیق را برای ارزیابی و متمرکز کردن آسیب‌های سازه‌های هوشمند ساختمان در معرض تحریکات مضرخارجی ارائه می‌دهد. متفاوت از الگوریتم‌های شناسایی آسیب سنتی، روش پیشنهادی مستقیماً بر روی سیگنال‌های ارتعاشی گرفته شده از ساختمان‌های شناسایی شده اجرا می‌شود و از کارهای اضافی وقت‌گیر و روش انتخاب ویژگی‌های دستی جلوگیری می‌کند. اول، یک هسته بزرگ در اولین لایه همگشتی برای کاهش تأثیر نویز با فرکانس بالا و سپس، چندین هسته کوچک برای توصیف نمایش سیگنال از طریق نگاشت غیرخطی چند لایه استفاده می‌گردد. در نهایت، عملکرد روش پیشنهادی بر روی یک مدل عددی معمولی از یک ساختمان با سناریوی آسیب در نرم‌افزار اجزای محدود Abaqus^{TM} شبیه‌سازی و

ارزیابی می‌شود که برای این منظور یک قاب ۳ بعدی ساده با ۸ المان دارای سطح مقطع دایره تو خالی در نرم‌افزار Abaqus$^{\text{TM}}$ مدلسازی شده است. نتیجه ارزیابی نشان می‌دهد که روش شبکه‌های عصبی همگشتی عمیق مقادیر را با دقت مناسبی پیش‌بینی می‌کند و از سایر روش‌های متداول مبتنی بر یادگیری ماشین از نظر RMSE، IA، SCC، AAD و ESR نیز بهتر عمل می‌کند. از آنجا که فقط تحقیقات عددی در این کار انجام می‌شود، باید مطالعات تجربی و میدانی برای تأیید روش نیز در نظر گرفته و انجام شود. در کاربرد عملی، به دلیل کمیاب بودن اطلاعات آسیب در ساختمان‌های واقعی، مدل پیشنهادی مبتنی بر شبکه‌های عصبی همگشتی عمیق را باید با استفاده از داده‌های مدل عددی توسعه داده و سپس از مدل آموزش‌دیده برای پیش‌بینی وضعیت سلامت سازه‌های هوشمند واقعی استفاده شود. مشکلی وجود خواهد داشت که توزیع داده‌های آموزشی از مدل عددی کاملاً متفاوت از توزیع داده‌های آزمایش از ساختمان واقعی است. در این مورد، دقت شناسایی روش پیشنهادی تحت تأثیر قرار می‌گیرد. بر این اساس، در کارهای آینده، تکنیک یادگیری انتقال نیز برای رفع این مشکل جهت استفاده از روش شبکه‌های عصبی همگشتی عمیق پیشنهادی در شناسایی آسیب سازه‌های هوشمند در دنیای واقعی مورد بررسی قرار خواهد گرفت.

۷- منابع

[1] Avci O and Abdeljaber O. Self-organizing maps for structural damage detection: a novel unsupervised vibration-based algorithm. J Perform Constr Fac 2016; 30: 04015043.

[2] Yang Y and Nagarajaiah S. Blind identification of damage in time-varying systems using independent component analysis with wavelet transform. Mech Syst Signal Pr 2014; 47: 3–20.

[3] Ruiz M, Mujica LE, Sierra J, et al. Multiway principal component analysis contributions for structural damage localization. Struct Health Monit 2017; 17: 1151–1165.

[4] Shu J, Zhang Z, Gonzalez I, et al. The application of a damage detection method using artificial neural network and train-induced vibrations on a simplified railway bridge model. Eng Struct 2013; 52: 408–421.

[5] Zhou Q, Zhou H, Zhou Q, et al. Structural damage detection based on posteriori probability support vector machine and Dempster–Shafer evidence theory. Appl Soft Comput 2015; 36: 368–374.

[6] Cha YJ, Choi W and Bu¨ yu¨ ko¨ ztu¨ rk O. Deep learningbased crack damage detection using convolutional neural networks. Comput-Aided Civ Inf 2017; 32: 361–378.

[7] Tong Z, Gao J and Zhang H. Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks. Constr Build Mater 2017; 146: 775–787.

[8] Sohn JW, Oh JS and Choi SB. Design and novel type of a magnetorheological damper featuring piston bypass hole. Smart Mater Struct 2015; 24: 035013.

[9] Ha SH, Seong MS and Choi SB. Design and vibration control of military vehicle suspension system using magnetorheological damper and disc spring. Smart Mater Struct 2013; 22: 065006.