

بررسی عملکرد شبکه عصبی مصنوعی همگشتی در شناسایی آسیب در سازه‌های خرپایی

سعید سبحانی قهرمانلو¹، آلا دهرویه²، علی بیگری³ (نویسنده مسئول)

¹ دانشجوی کارشناسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، saeedsobhani15@gmail.com
² دانشجوی کارشناسی ارشد عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، aladehruye97@gmail.com
³ استادیار گروه مهندسی عمران، دانشکده فنی مهندسی گرگان، دانشگاه گلستان، Biglari.a@gmail.com

چکیده

هدف اصلی تکنیک‌های (ML¹) تولید خودکار دانش برای سیستم‌ها می‌باشد. حجم روزافزون پایگاه‌های اطلاعاتی فرصت‌هایی را برای تکنیک‌های پیشرفته تجزیه و تحلیل داده‌ها از تحقیقات یادگیری ماشین ML فراهم می‌کند. با پیشرفت‌های اخیر در فناوری سنجش غیرتماسی مانند دوربین‌ها، وسایل نقلیه هوایی و زمینی بدون سرنشین، جامعه نظارت بر سلامت سازه (SHM²) شاهد رشد چشمگیری در روش‌های ارزیابی مبتنی بر یادگیری عمیق سیستم‌های ساختاری بوده است. این روش‌های یادگیری عمیق در درجه اول به شبکه‌های عصبی همگشتی (CNN³) متکی هستند. شبکه‌های CNN با استفاده از تعداد زیادی مجموعه داده برای انواع آسیب‌ها و تشخیص ناهنجاری و شناسایی پس از فاجعه آموزش دیده‌اند. سپس از شبکه‌های آموزش دیده به منظور تجزیه و تحلیل داده‌های جدیدتر برای شناسایی نوع و شدت آسیب استفاده می‌شود و قابلیت‌های سنسورهای غیر تماسی در توسعه سیستم‌های SHM مستقل را افزایش می‌دهد. در این مقاله بررسی دقیق ادبیات تکنیک‌های مبتنی بر CNN موجود در زمینه ارزیابی شرایط سازه‌های ارائه شده است.

کلید واژه‌ها

پایش سلامت سازه، ساختمان هوشمند، هوش مصنوعی، شبکه عصبی مصنوعی، یادگیری عمیق.

مقدمه

نظارت بر سلامت سازه SHM ابزارهای تشخیصی نوظهور و قدرتمندی را برای تشخیص آسیب، کاهش هزینه و همچنین مدیریت سریع فاجعه برای سازه‌ها ارائه می‌دهد. بیشتر این تکنیک‌ها به اندازه‌گیری‌های دینامیکی نیاز دارند که نیاز به نصب سنسورهای تماسی مانند شتاب سنج‌ها، فشار سنج‌ها، سنسورهای فیبر نوری و سنسورهای امواج مافوق صوت دارند که هزینه نصب بالایی دارند. با توسعه سنسورهای نسل جدید مانند دوربین‌های دیجیتال و سرعت بالا، وسایل نقلیه زمینی بدون سرنشین (UGV⁴) و حسگرهای متحرک، تغییر اساسی در تکنیک‌های سنجش غیرتماسی در SHM ایجاد شده است. استقرار این سیستم‌های جدید راحت‌تر است، کم‌کارتر و مقرون به صرفه‌تر است و امکان دستیابی به اطلاعات قابل اطمینان‌تر را از ساختارهای دارای اطلاعات مکانی و با وضوح بالا فراهم می‌کند. با این حال، برخلاف سنسورهای تماسی سنتی، سنسورهای غیر تماسی داده و فیلم‌هایی و داده‌هایی را ارائه می‌دهند که به پیشرفت‌های چشمگیر در رباتیک، پردازش تصویر، دید رایانه‌ای و الگوریتم‌های یادگیری عمیق نیاز دارند، که مهندسان سازه هنوز با چالش‌های متعددی روبرو هستند. در سال‌های اخیر، محققان SHM تکنیک‌های هوش مصنوعی را برای حل این چالش‌ها و دستیابی موفقیت آمیز به استراتژی‌های بازرسی

¹ Machine learning

² Structural Health Monitoring

³ Convolutional Neural Network

⁴ Unmanned ground vehicle

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

مستقل و هوشمند با استفاده از دستگاه‌های غیر تماسی و رباتیک کشف کرده‌اند. این تحقیق نه تنها وظایف نظارت و نگهداری را برای صاحبان زیرساخت تسریع می‌کند بلکه امکان تشخیص دقیق نقص در مراحل اولیه را فراهم می‌کند تا از بروز هرگونه خرابی سازه فاجعه بار در آینده جلوگیری کند. علاوه بر این، پیشرفت تحقیقات در این زمینه امکان پیشرفت تعمیر و نگهداری سازه با حداقل خطاهای انسانی، هزینه‌های کمتر و دقت بالاتر، ارائه یک سیستم کاربردی به دارندگان زیرساخت را فراهم می‌کند. در حوزه SHM اخیراً به دلیل کاهش حساسیت به اختلالات خارجی و انتخاب ویژگی‌ها، به منظور غلبه بر این چالش‌ها بر استفاده از تکنیک‌های مختلف هوش مصنوعی (AI^5) متمرکز شده است [1]. مجموعه روشهای مختلف هوش مصنوعی AI را که اخیراً در مهندسی سازه استفاده شده است، مرور کردند. نویسندگان روند اخیر تحقیق با کمک هوش مصنوعی را به سمت شناسایی الگو و روش‌های داده محور خودکار مبتنی بر یادگیری ماشین نشان دادند. محاسن و معایب نسبی روشهای مختلف هوش مصنوعی در زمینه کاربردهای مختلف مهندسی سازه مورد بحث قرار گرفت. در این مقاله تکنیک‌های یادگیری عمیق مبتنی بر CNN با تمرکز ویژه بر اجرای SHM بررسی می‌شود. هوش مصنوعی یک حوزه وسیع تحقیقاتی است که رشته‌های مختلف مهندسی را پوشش می‌دهد تکنیک‌های یادگیری ماشینی ML و یادگیری عمیق (DL^6) دو شاخه مورد توجه هوش مصنوعی هستند که در تحقیقات SHM به شدت مورد توجه قرار گرفته‌اند. الگوریتم‌های ML در مورد طیف گسترده‌ای از داده‌ها آموزش می‌بینند و با استفاده از داده‌های بیشتر، دقت الگوریتم‌ها بهبود می‌یابد. هدف اصلی آموزش بهینه سازی خطا در ابعاد مجموعه داده با استفاده از توابع بهینه سازی مانند تابع از دست دادن یا عملکرد هدف و به دست آوردن بهترین نتایج پیش بینی برای داده‌های آزمون است. با این حال، الگوریتم‌های ML به ویژگی‌هایی نیاز دارند که از روش‌های مختلف پردازش بدست آمده و در طبقه بندی کننده‌های مختلف تغذیه می‌شوند. بسته به نوع کاربرد، انتخاب مناسب ویژگی‌ها و طبقه بندی‌ها برای شناسایی ناهنجاری‌ها ضروری است. بیشتر این روشها براساس الگوریتمهای تطبیق الگو می‌باشد که بر اساس تاریخچه زمان جابجایی استخراج می‌شوند. به طور خاص، [2] با تأکید ویژه بر ساختارهای ترکیبی، یک بررسی جامع از ابزارهای محاسباتی هوشمند موجود برای تشخیص آسیب و شناسایی سیستم را ارائه دادند. اخیراً، پیشرفته ترین روش ارزیابی وضعیت سازه مبتنی بر الگوریتم ML توسط [3] بررسی شده است. بر خلاف ML روش‌های AI مبتنی بر DL به طور خودکار ویژگی‌ها را استخراج می‌کنند و نیازی به استخراج ویژگی‌های دستی ندارند بنابراین، DL می‌تواند بین تعداد زیادی از طبقات تمایز ایجاد کند و این قابلیت اخیراً برای ارزیابی آسیب در سازه‌ها مورد بررسی قرار گرفته است. الگوریتم‌های DL بر اساس مجموعه گسترده‌ای از داده‌های دارای برچسب ساخته شده‌اند و به عملکرد محاسباتی و حافظه بالایی نیاز دارند. اصطلاح "عمیق" به تعداد زیادی لایه که بین ورودی خام و خروجی طبقه بندی نهایی استفاده شده در یک شبکه وجود دارد، گفته می‌شود. شبکه‌های عصبی همگشتی CNN، که یک کلاس محبوب از روش‌های DL هستند، به دلیل توانایی در استخراج خودکار ویژگی‌ها، در چالش (ImageNet 2012) با موفقیت استفاده شده‌اند. این امر امکان استخراج خودکار و بهینه شده ویژگی را برای تبدیل شدن به بخشی از فرایند یادگیری طبقه بندی فراهم کرده است، که با این وجود، بهینه بودن آن یا دقت شناسایی ترک به خطر نمی‌افتد.

شبکه عصبی مصنوعی

[4]، شبکه عصبی مصنوعی را توسعه و بسط داد و یک مدل ANN (کم عمق) که از 3 لایه تشکیل شده است لایه ورودی، لایه پنهان و لایه خروجی به خصوص متغیرهای مدل در لایه ورودی وزن می‌شوند و به لایه مخفی تغذیه شده که لایه مخفی از یک سری روابط غیر خطی مانند توابع (sigmoidal⁷) تشکیل شده است، که برای تهیه یک مدل رگرسیون یا طبقه بندی جلوتر وزن شده و به لایه خروجی وارد می‌شود. وزن اتصال در انتشار رو به جلو آموخته می‌شود و از طریق یک فرآیند آموزشی که خطای پیش بینی را که به طور معمول در جهت عقب منتشر می‌شود، را به حداقل می‌رساند و به روز می‌شود. ANN کلاسیک را می‌توان به صورت یک شبکه عصبی عمیق DNN یا DL که شامل چندین لایه پنهان می‌باشد تعمیم داد. معماری عمیق در یک DNN شامل چندین لایه پردازشی و تبدیل غیر خطی است که عملکرد مدل برتر را بدون نیاز به ویژگی‌های خوب انتخاب شده به عنوان ورودی امکان پذیر می‌کند. ساختار شبکه مصنوعی ANN به ویژه برای

⁵ Artificial intelligence

⁶ Deep learning

⁷ Sigmoid function

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

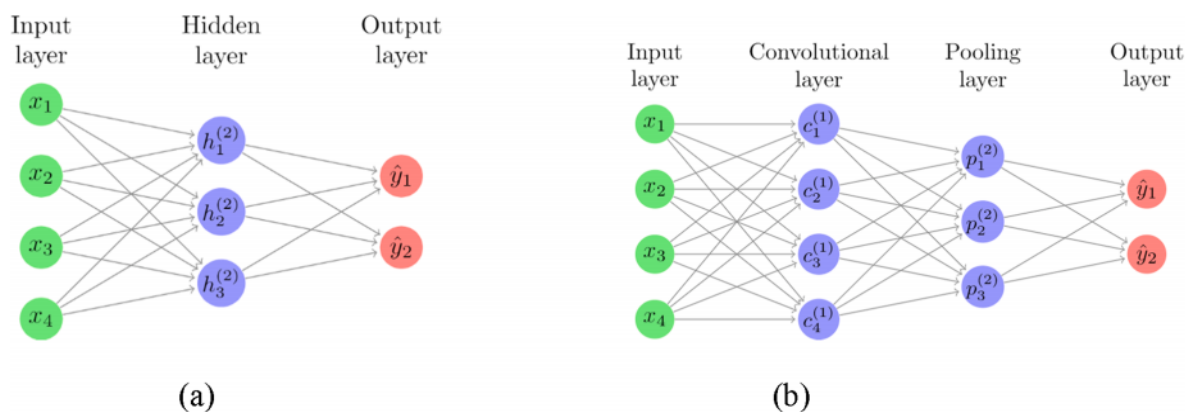
مدل سازی رفتار مشکلات ناشی از الگوهای غیرخطی و پیچیده مناسب است. با این حال، یافتن ساختار بهینه و تنظیم پارامترهای مدل می تواند چالش بر انگیز باشد، اگر با دقت آموزش نبیند، مدل بیش از حد مناسب تولید می شود.

شبکه های عصبی همگشتی

CNN محبوب ترین نوع شبکه DL است. ساختار اساسی CNN از سه لایه تشکیل شده است: 1- همگشتی (استخراج ویژگی)، 2- جمع شدن (کاهش ابعاد) و 3- لایه کاملاً متصل. لایه همگشتی شامل تعداد محدودی فیلتر (تعریف شده توسط هسته یا اندازه فیلتر) است که با داده های ورودی ترکیب می شود و تعداد زیادی از ویژگی های مربوطه را از داده های ورودی شناسایی می کند. لایه میانی جمع کننده با استفاده از یک عملیات نمونه برداری پایین، ابعاد ویژگی های حاصل را کاهش می دهد، در نتیجه تلاش کلی محاسباتی شبکه را به حداقل می رساند. بسته به داده ها و دقت مورد نظر، سیستم با تکرار متوالی جمع شدن همگشتی دقت بیشتری پیدا می کند. به این ترتیب، از داده های ورودی و به دنبال آن یک یا چند لایه کاملاً متصل که برای طبقه بندی استفاده می شوند، ویژگی های بعدی با ابعاد بیشتر استخراج می شوند. به این ترتیب بیشتر ویژگی های بعدی از داده های ورودی و به دنبال آن یک یا چند لایه کاملاً متصل که برای طبقه بندی استفاده می شوند، استخراج می شوند. لایه های همگشتی یک مجموعه داده ورودی را با یک فیلتر یا هسته ترکیب می کنند. هنگامی که اندازه ماتریس هسته بسیار کوچکتر از اندازه ماتریس ورودی است. ضرب ماتریس لایه های همگشتی تعداد وزنه ها را کاهش می دهد که باعث کاهش واریانس مدل می شود. همگرایی ها ویژگی های محلی بی تغییر ایجاد می کنند. در سطح پایین تر، از فیلترها می توان برای تشخیص لبه های تصویر استفاده کرد، در حالی که در سطح بالاتر، می توانند اشکال و اشیاء پیچیده تری را که برای طبقه بندی تصویر حیاتی هستند، شناسایی کنند. یک لایه همگشتی مجموعه ای از فیلترهای تصویر با وزن قابل یادگیری است و به عنوان یک استخراج کننده ویژگی نقش مهمی در CNN بازی می کند. از طرف دیگر، لایه های جمع کننده اندازه لایه را کاهش می دهند در حالی که کاهش تعداد سلول های عصبی در شبکه ها و استخراج مهمترین ویژگی ها با طول ثابت روی پنجره های کشویی داده های ورودی خام. کاهش تعداد سلول های عصبی با کشیدن یک پنجره ثابت در عرض یک لایه و انتخاب یک مقدار که به طور موثر تمام واحدهای گرفته شده توسط پنجره را نشان می دهد، انجام می شود. حداکثر و میانگین جمع شدگی دو پیاده سازی متداول در (pooling) هستند.

ویژگی های شبکه های عصبی همگشتی

تفاوت اصلی بین NN و CNN تفاوت لایه هایی است که برای طبقه بندی داده استفاده می کنند. شکل 1 نمودارهای معماری معمولی NN و CNN را نشان می دهد. NN از لایه های مخفی استفاده می کند (با h مشخص می شود)، در حالی که CNN به همراه لایه های ورودی و خروجی از لایه های همگشتی (با c نشان داده می شود) و استخر (با p نشان داده می شود) استفاده می کند. تعداد لایه ها به تاریخچه، داده ها و عملکرد مورد نیاز مدل بستگی دارد. یکی از مهمترین مسائل در مورد NN ها، مجهز بودن بیش از حد است. شبکه های عصبی بزرگ که روی مجموعه داده های نسبتاً کوچک آموزش دیده اند، می توانند بیش از حد در داده های آموزش جای بگیرند.



شکل 1. شماتیک (الف) یک NN معمولی و (ب) CNN معمولی با لایه های همگشتی pooling [5]

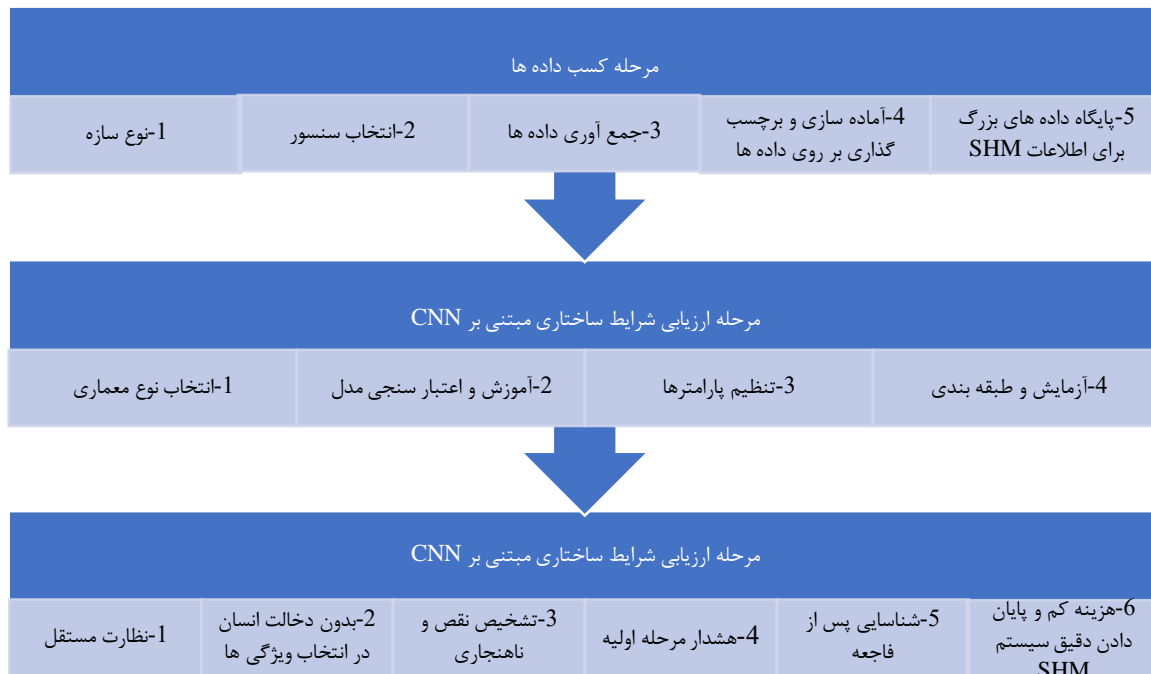
یازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

11th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

کاربرد شبکه‌های عصبی همگشتی در تشخیص ویژگیها

در اصل برای شناسایی شی الگوریتم‌های CNN 2D بیشتر برای داده 2D در برنامه‌های مختلف SHM برای شناسایی نقص و ناهنجاری به طور خودمختار مورد بررسی قرار گرفتند. علاوه بر این، برای SHM مبتنی بر ارتعاش، محققان سعی کردند با تبدیل سیگنال در دامنه فرکانس و فرکانس زمان TF سیگنال ارتعاش را به داده تغییر شکل دهند و از نقشه‌های TF حاصل به عنوان داده در CNN 2D استفاده کنند. با این حال، داده در انتخاب تعداد زیادی از داده‌ها و لایه‌های دارای برچسب پیچیدگی قابل توجهی دارند و برای برنامه‌های SHM در زمان واقعی با استفاده از دستگاه‌های تلفن همراه یا دستی مناسب نیستند. برای حل این مشکل، CNN 1D اخیراً به گونه‌ای معرفی شده است که می‌توان مستقیماً یک سیگنال تجویز همزمان در CNN تغذیه کرد، که به عملیات ساده آرایی نیاز دارد، بنابراین یک معماری کم عمق با تعداد کمتری از لایه‌های پنهان نیاز است شکل 2 نمودار جریان پیشرفته ترین SHM مبتنی بر CNN را نشان می‌دهد ادبیاتی که منجر به پیشرفت قابل توجهی در این مبحث در چند سال گذشته شده است. شماتیک دو مرحله را ارائه می‌دهد که شامل جمع آوری داده‌ها و مرحله ارزیابی شرایط می‌باشد. مرحله کسب اطلاعات برای درک اینکه کدام نوع داده برای یک ساختار خاص مناسب است، امری اساسی است. بسته به طبقه بندی یا وظیفه پیش بینی مورد نیاز از یک برنامه خاص، آماده سازی داده‌ها قبل از مرحله جمع آوری داده‌ها است. معماری خاص CNN در مرحله بعدی انتخاب می‌شود و به دنبال آن بهبود بیشتر آنها با استفاده از تنظیم hyperparameter انجام می‌شود. پس از انجام این مرحله، وظایف مختلف نظارت بر زیرساخت‌ها در آخرین مرحله به دست می‌آیند، و نشان دهنده سهم جدیدی از پیشرفته ترین روش‌های SHM مبتنی بر CNN است. یک بررسی منظم از SHM مبتنی بر CNN با طبقه بندی ادبیات فعلی در چندین کلاس سازمان یافته است، همانطور که در زیر نشان داده شده است.



شکل 2. نمودار جریان پیشرفته ترین SHM مبتنی بر CNN [6]

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

کاربرد شبکه‌های عصبی همگشتی در تشخیص خطا

موضوع شناسایی سیستم، شاخه‌ای گسترده از مطالعات را توسعه می‌دهد مدل‌های مبتنی بر ML برای تقلید از یک سیستم سازه و پیش بینی پاسخ زمین لرزه پایین دست آن استفاده می‌شود. سازه‌ها انواع مختلفی از آسیب را تجربه می‌کنند و شناسایی همه آنها به یک باره رویکرد سریع تری برای تعمیر و نگهداری است. شبکه CNN عمیق پیکسلی چند مقیاس مبتنی بر دید توسط [7] ارائه شد، برای شناسایی شش نوع آسیب سازه. روش پیشنهادی شامل دو مرحله موازی است: 1- طبقه بندی آسیب برای جدا کردن هر پیکسل به کلاسهای از پیش تعریف شده و 2- یک تقسیم کننده آسیب که پیکسل‌های آسیب دیده را از موارد آسیب دیده متمایز می‌کند. نظارت بر ساختارهای در مقیاس بزرگ و مبتنی بر تصویر چالش برانگیز است تکنیک‌های نظارت ابزاری قدرتمند برای نظارت موثر سازه را فراهم می‌کنند. تنظیم منابع مختلف نور در زوایای مورب مختلف در میدان تاریکی، محل حفره‌ها را از طریق پراکندگی نور اعمال شده مشخص کرد. با مقایسه رویکردهای مبتنی بر مدل سنتی به CNN آموزش دیده، نویسندگان کاهش قابل توجهی در یک خطای تشخیص پیدا کردند علاوه بر این، روش‌های نظم بخشی مانند افزایش داده‌های آموزش و پیش از آموزش لایه‌های بدون نظارت نیز وجود داشت نشان داده شده است که احتمال تعدیل بیش از حد به دلیل اندازه را کاهش می‌دهد. تعداد انگشت شماری از مطالعات بر پیش بینی حالت‌های خرابی و مقاومت برشی برای اتصالات تیر ستون متمرکز بودند [8]. گروهی از ابزارهای ML، یعنی LR،⁸ (LASSO)، تجزیه و تحلیل تفکیک، همسایه ترین همسایگان، طبقه بندی ساده بیز،⁹ (SVM)،¹⁰ (DT)،¹¹ (RF) و ماشین یادگیری شدید ELM برای طبقه بندی، و به صورت گام به گام LASSO، شبکه الاستیک و RF برای رگرسیون، به طبقه بندی حالت شکست و پیش بینی مقاومت برشی با هم تحقق ببخشند. زیرساخت پل برای حمل و نقل بسیار مهم است نیاز به نظارت مستمر دارد. از مولفه‌های مهم هر پلی که مستعد آسیب هستند، برای بدست آوردن داده‌ها به صورت تاریخ شتاب، داده یا جریان‌های مداوم ویدیویی استفاده می‌شود. گروه مشابهی از ابزارهای ML توسط [9] برای پیش بینی حالت‌های خمشی، خمشی برشی و شکست برشی ستون‌های پل استفاده شده است. یک مطالعه توسط [10] برای پیش بینی ظرفیت رانش ستون‌های RC با استفاده از روش SVR حداقل مربع وزن محلی انجام شده است. 14 نتیجه آزمایش از نمونه قاب‌ها بررسی شده است. ابتدا آزمایشات آزمایشگاهی بر روی سازه‌های بتن آرمه (RC) یکی از منابع داده را فراهم کرده است که روش‌های ML را قادر می‌سازد تا حالت‌های خرابی را شناسایی کند، در این راستا تعداد انگشت شماری از مطالعات بر پیش بینی حالت شکست متمرکز بودند. گروه دوم مطالعات در شناسایی سیستم با مجموعه داده‌های شبیه سازی عددی سروکار دارد، جایی که ورودی داده‌ها (پارامترهای سازه و حرکات زمینی) و خروجی‌ها (پاسخ‌های سازه) روش‌های ML را برای ایجاد یک نقشه برداری رابطه‌ای که از یک سازه تقلید می‌کند، فعال می‌کند. برای این منظور، روش‌های ML، به ویژه ANN، تأیید شده است که به دلیل سازگاری آنها با ساختارهای پیچیده تقریبی بدون محدود شدن به اشکال خاص، در جایگزینی مدل‌های اجزای محدود از ساختارهای مدنی موثر است. شروع از [11] که از ANN برای یادگیری و شبیه سازی رفتار کششی خطی ساختمانهای چند طبقه استفاده کرده است، شبکه‌های ANN در شناسایی انواع سازه‌ها و اتصالات ستون در قاب‌های لحظه‌ای فولادی کوتاه، متوسط و بلند [12]. علاوه بر این ANN‌ها با الگوریتم‌های محاسبات نرم دیگری ترکیب شده‌اند تا خطای پیش بینی را به حداقل برسانند و سرعت آموزش را افزایش دهند و قابلیت تعمیم را بهبود بخشند به عنوان مثال یک مدل موجک Fuzzy تاخیر در زمان دینامیکی پویا توسعه یافته شده است 1- ایجاد یک مدل روابط عمومی که داده‌های سری زمانی را به طور دقیق و کارآمد ضبط می‌کند و 2- مدیریت دو نوع عدم دقت در داده‌های اندازه گیری شده: اطلاعات فازی و عدم قطعیت اندازه گیری [13]. منطقه موضوع شناسایی آسیب به طور کلی به عنوان یک گروه از مطالعات که مدل‌های ML برای شناسایی، طبقه بندی و ارزیابی آسیب‌های لرزه‌ای سازه‌های عمرانی ایجاد می‌کند، تعریف شده است. اول چندین مطالعه برای پیش بینی آسیب لرزه‌ای به سوابق زبانی و عکاسی‌ها پس از زلزله متکی بود، یک چالش اساسی در این زمینه در رسیدگی به اطلاعات آسیب در سوابق زبانی است. روش‌های ML در برخورد با داده ماهواره‌ای برای شناسایی و طبقه بندی خسارت ساختمان به کار رفته است [14]. در یک زمینه گسترده، مدل‌های ANN برای پیش بینی پاسخ لرزه‌ای برای انواع سازه‌ها

⁸ least absolute shrinkage and selection operator

⁹ support vector machine

¹⁰ decision tree

¹¹ random forest

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

ساخته شده‌اند تا شرایط آسیب آنها را استنباط کنند. مطالعات مرتبط شامل 1- تخمین سریع خسارت زمین لرزه در خانه‌های چوبی در ژاپن است [15] 2- پیش بینی شاخص آسیب قاب‌های دیوار برشی بتنی و سازه‌های کنسولی 3- ارزیابی آسیب لرزه ای [16] برای پیوند دادن الگوهای آسیب لرزه‌ای ساختمان‌ها به شاخص‌های ظرفیت سازه باقی مانده از آن استفاده می‌شود (یعنی نسبت ظرفیت متوسط بین ساختمانهای سالم و آسیب دیده). چارچوب پیشنهادی آنها تجزیه و تحلیل تقاضای لرزه‌ای، شبیه سازی خسارت مولفه‌ها و برآورد ظرفیت سقوط باقیمانده را در ساختارهای سالم و آسیب دیده ادغام می‌کند. الگوریتم‌های ML اعمال شده شامل CART و RF برای طبقه بندی ایمنی و LASSO و SVM برای پیش بینی شاخص ظرفیت هستند. منطقه شناسایی سیستم و تشخیص آسیب شامل یک مجموعه گسترده‌ای از مطالعات است که به حل مجموعه‌ای از مشکلات می‌پردازد، که از طبقه بندی حالت‌های خرابی مولفه‌ها با استفاده از آزمایش‌های آزمایشگاهی، تا کشف آسیب سازه در سطح منطقه با استفاده از داده ماهواره‌ای می‌باشد. به همین ترتیب، از جدول ماتریس ویژگی فوق الذکر در اینجا استفاده می‌شود تا ساختار ادبیات کلی و ارتباطات متقابل را در بین تمام مطالعات مربوطه افشا کند. توجه داشته باشید که ادبیات در این زمینه موضوعی انتخاب شده است که تا توسط کلمات کلیدی " یادگیری ماشین " و " مهندسی زلزله " محدود شود. ارزیابی وضعیت سازه شامل وظایف اصلی مانند شناسایی سیستم، شناسایی آسیب، ترک و تشخیص ناهنجاری است. دقت این وظایف به شدت بر روی قرارگیری سنسور و وجود خطاهای سنسور، نوسانات در شرایط محیطی و عملیاتی، مناسب بودن ویژگیهای مناسب و روشهای استخراج ویژگی مانند روشهای زمان، فرکانس، زمان - فرکانس تأکید دارد دقت این وظایف به شدت به قرارگیری سنسور و وجود خطاهای سنسور، نوسانات در شرایط محیطی و عملیاتی، روشهای استخراج ویژگی مانند روشهای زمان، فرکانس، فرکانس_ زمان بستگی دارد [17]. بنابراین، استراتژی‌های متداول ML مبتنی بر ML به شدت به دانش متخصص برای طراحی مناسب ترین ویژگی‌ها برای داده‌های داده شده از زیرساخت‌های مهم اعتماد می‌کنند. برخلاف رویکردهای سنتی، CNN بدون نیاز به مرحله انتخاب ویژگی، کارهای مشابهی را انجام می‌دهد. این متکی به یک پایگاه داده بزرگ از داده‌های آموزش است و یک شبکه عمیق با مجموعه‌ای از پارامترهای شبکه و آموزش ایجاد می‌کند، به طور ضمنی هر دو ویژگی استخراج و طبقه بندی الگوها را انجام می‌دهد.

کاربرد شبکه‌های عصبی همگشتی در تشخیص سلامت سازه

ساختارهای عمرانی از چندین نوع ماده تشکیل شده است و غالباً، در معرض طیف گسترده‌ای از دسته‌های آسیب قرار می‌گیرند. چنین تنوعی نه تنها در بیشتر ساختارهای عمرانی بلکه در زیرساخت‌های راه آهن، خطوط لوله، نیروگاه‌های تولید برق، خطوط انتقال و برج‌ها نیز اعمال می‌شود علاوه بر این، یک شیوع در بین این ساختارها وجود دارد که به دلیل پیری یا شرایط عملیاتی عادی، در معرض خسارات ناشی از بلایای طبیعی و مصارف حیاتی است. همچنین، بازرسی‌های پس از فاجعه اغلب وقت گیر، ناامن و پرمشغله هستند انجام موثر این وظایف را برای بشر دشوار می‌کند مدرن ترین معماری‌های مبتنی بر CNN و فناوری‌های جدیدتر SHM به دارندگان زیرساخت این امکان را داده است که با استفاده از سنسورهای نسل جدید مانند دوربین‌ها، هواپیماهای بدون سرنشین و روبات‌ها، انواع آسیب را در ساختارهای مختلف به طور دقیق و مستقل شناسایی و محلی سازی کنند در نتیجه، تحقیقات آینده بر توسعه واقعی تمرکز خواهد کرد. این مقاله به بررسی اهمیت تکنیک‌های ML برای کاربردهای مهندسی زلزله می‌پردازد 2 زمینه موردی برای اجرای ML شناسایی سیستم و شناسایی آسیب برای کاهش زلزله می‌پردازد. اگر چه در برخی موارد تعداد داده‌ها محدود است اما مجموعه داده‌های جمع آوری شده از آزمایش‌های آزمایشگاهی و میدانی وقایع قبلی زلزله و شبیه سازی‌های عددی محققان را قادر می‌سازد مجموعه از ابزارهای پیشرفته ML را به کار گیرند. پیشینه فنی برخی از روش‌های ML که معمولاً مورد استفاده قرار می‌گیرند ارائه شد در حالی که سازگاری و کاربرد این ابزارها در هر یک از 2 موضوع به طور مفصل مورد بحث قرار گرفت این مطالعه نشان می‌دهد که تکنیک‌های ML توانایی یادگیری و استنتاج روابط متقابل پیچیده را در بین پارامترهای کمک کننده دارند و بنابراین اجازه می‌دهد تا با استفاده از روش‌های سنتی حل مشکلات مختلف مهندسی زلزله که حل آن‌ها چالش بر انگیز است و یا حتی غیر ممکن می‌باشد بپردازد. همانطور که در طی روند بررسی مشاهده شد رشته متقابل مهندسی ML و زلزله یک منطقه جدید اما به طور فزاینده پویا برای تحقیقات با تاثیر بالا است که در آن می‌توان گستره و عمق گسترده موضوعات را بررسی کرد و به منظور ارتقاء ترویج بیشتر کاربردهای ML در مهندسی زلزله چالش‌های بالقوه و نیازهای تحقیقاتی مرتبط را مورد بحث قرار داد.

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


ارزیابی عددی

ML معمولاً برای تأثیرگذار بودن به مقدار زیادی داده با کیفیت بالا نیاز دارد. در دسترس بودن داده‌ها در زمینه GMPE، که در آن ده‌ها هزار مجموعه داده حرکت حرکت در پایگاه داده حرکت قوی (NGA-West2) که به تازگی توسعه یافته است، وجود دارد، مسئله‌ای کمتر شده است [18]. با این حال، برای برخی از مناطق که نیاز به تجزیه و تحلیل محاسباتی با راستی آزمایشی بالا یا آزمایش‌های میدانی در مقیاس بزرگ دارند، نقاط داده با کیفیت بالا اغلب به صدها یا تعداد کمتری محدود می‌شوند. همانطور که انتظار می‌رود، ML در این مناطق با یک چالش جدی روبرو است. به عنوان مثال، قبل از اجرای مقررات طراحی لرزه‌ای مدرن، تعداد زیادی ساختمان و پل موجود با قاب‌های RC و پل‌های موجود در مناطق فعال لرزه‌ای ساخته شده است، و ستون‌های RC مستعد ابتلا به شکست‌های برشی شکننده در این سازه‌ها هستند. اخیراً از ML برای پیش‌بینی ظرفیت جابجایی ستون‌های RC استفاده شده است، جایی که داده‌های ورودی که برای ستون‌های برشی مهم وجود دارد بسیار کمتر از ستون‌های مهم خمشی است. در نتیجه، مدل‌های ML برای ستون‌های مهم برشی مانند مدل‌های خرابی خمشی عملکرد خوبی ندارند [10]. برای پرداختن به این مسئله داده‌ها، تلاش‌های تحقیق در جهت‌های زیر پیشنهاد می‌شود. ابتدا داده‌های شفاف‌تر، قابل دسترسی و با کیفیت بالا برای جمع‌آوری در فرم قابل خواندن توسط کامپیوتر لازم است. در برنامه‌های ML، اگرچه تخصص قابل توجهی لازم است و تلاش برای تنظیم، آموزش، اعتبار سنجی و تفسیر مدل است. در این زمینه، بسیار مهم است که در مهندسی زلزله، یک زیرساخت سایبری مبتنی بر جامعه که توسط جامعه پذیرفته شده است وجود داشته باشد که به محققان این امکان را دهد که داده‌ها را به طور موثرتری به اشتراک بگذارند و تجزیه و تحلیل کنند، مجموعه داده‌های متنوعی را ادغام کنند و ابزارهای ML را تمرین و توسعه دهند. یکی از چنین بسترهای زیرساخت سایبری (DesignSafe) نام دارد که از تحقیقات مهندسی خطرات طبیعی پشتیبانی می‌کند و از طریق آن مجموعه داده‌های مختلفی که اخیراً ایجاد شده بارگذاری و به اشتراک گذاشته شده‌اند همچنین، از آنجا که پایگاه داده‌های آزمایشی آزمایشگاهی یا میدانی محدود است و شروع فعالیت‌های جدید در مقیاس بزرگ می‌تواند زمانبر و هزینه‌بردار باشد، باید محققان را برای ارائه داده‌های مبتنی بر شبیه‌سازی بیشتر تشویق کرد، در حالی که سایر جوامع عملی از مدل‌های اشتراکی استقبال می‌کنند و از شبیه‌سازی‌ها نتیجه می‌گیرند، این فرهنگ هنوز در جامعه مهندسی زلزله در مراحل ابتدایی است. با این حال، بسیاری از این مدل‌های با کیفیت بالا همچنین در ارائه داده‌های آموزشی برای برنامه‌های ML شایستگی زیادی دارند. علاوه بر این، انتظار می‌رود محققان انجام ML در مهندسی زلزله به طور فزاینده‌ای با منابع جدید داده تولید شده از سایر فناوری‌های پیشرفته مانند سنسور بی‌سیم، بینایی رایانه، اینترنت اشیا (IoT)، شهرهای هوشمند، سیستم اطلاعات جغرافیایی (GIS)، محاسبات کوانتومی و غیره سر و کار داشته باشند. پس از وقوع زلزله، این فناوری‌ها می‌توانند اشکال جدیدی از داده‌ها را در مقیاس کاملاً متفاوت ارائه دهند. به عنوان مثال، اینترنت اشیا برای شهرهای هوشمند می‌تواند از حسگرهای متصل در زمان واقعی برای تولید مقدار زیادی داده مکانی - زمانی در مورد شبکه‌های پل یا سیستم‌های خط لوله برای کل منطقه استفاده کند [1]. برای این منظور، با ادغام ML با این فناوری‌های جدید می‌توان مشکلات بلند پروازانه تری را در مهندسی زلزله برطرف کرد. چنین مشکلاتی می‌تواند پیش‌بینی عملکرد لرزه‌ای بالا بودن یک مولفه سازه در سطح دانه‌ای یا ارزیابی انعطاف پذیری لرزه‌ای سیستم‌های زیرساختی متصل به هم در منطقه باشد. در این پژوهش، محاسبات دقیق با استفاده از یک نرم افزار مبتنی بر روش المان محدود (SAP2000) انجام شده است و تعداد زیادی از نتایج نمونه به عنوان ورودی برای روش شبکه‌های عصبی با یادگیری عمیق استفاده شده است. بمنظور ارزیابی روش پیشنهادی در تشخیص آسیب خرابی 31 المان Huang شکل 3 مورد ارزیابی و مقایسه قرار گرفته است [19].

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



شکل 3. خرپای 31 المانی Huang [19]

با توجه به وقت گیر بودن محاسبات با استفاده از نرم افزار SAP، از روش شبکه‌های عصبی با یادگیری عمیق برای تعمیم نتایج به دست آمده با استفاده از نرم افزار SAP استفاده می‌شود. 10 درصد از نتایج به دست آمده با استفاده از نرم افزار SAP برای آزمایش استفاده می‌شود. 10 درصد از آن‌ها برای تأیید شبکه استفاده می‌شود و از داده‌های باقی مانده برای آموزش شبکه استفاده می‌شود. بعد از آموزش و آزمایش شبکه‌های عصبی، روش شبکه‌های عصبی با یادگیری عمیق مدل مورد نظر را برای پیکربندی شکل 3 و بر اساس دو سناریوی متفاوت مورد ارزیابی قرار گرفت و نتایج به همراه نتایج روش‌های دیگر محاسباتی در شکل 4 و 5 مورد مقایسه قرار می‌گیرد.

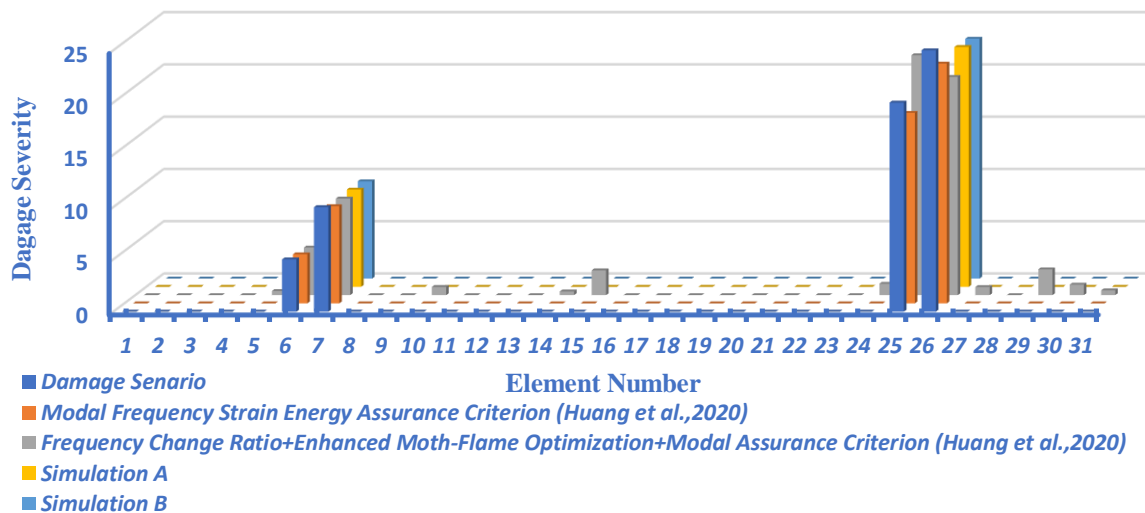


شکل 4. نتایج ارزیابی عددی در تشخیص آسیب در مقایسه با نتایج مبنای خرپای 31 المانی Huang

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



شکل 5. نتایج ارزیابی عددی در تشخیص آسیب در مقایسه با نتایج مبنای خرابی 31 المانی Huang

نتیجه گیری

در این پژوهش با کار بردی شبکه‌های عصبی همگشتی به ارزیابی آسیب در سازه‌ها پرداخته شد و ارزیابی عددی بکار گیری این روش بر قابلیت این روش تاکید می‌نماید. بر اساس نتایج مثالهای عددی و تجربی، برخی از نکات کلیدی را می‌توان به شرح زیر خلاصه کرد. در مقایسه با سایر الگوریتم‌های تشخیص آسیب مکانیسم به تشخیص و شناسایی آسیب بر اساس بکار گیری شبکه‌های عصبی مصنوعی می‌تواند به راه حل بهینه سازی بهتری منجر شود و نرخ همگرایی نتایج محاسبه را افزایش دهد. این در حالیست که احتمال تشخیص نادرست خطا به شدت کاهش می‌یابد. از دیگر سو امکان تعیین نسبی خسارت با خطای بیشینه 8.54٪ می‌باشد. آموزش شبکه بر اساس داده‌های یک سازه و در فرایند طولانی تر مبتنی بر طول عمر سازه، می‌تواند باعث کاهش خطای محاسبات بصورت قابل توجهی گردد. همچنین اثر نویزهای ناخواسته در تشخیص آسیب بر اساس این روش به خوبی قابل کنترل می‌باشد.

منابع

- [1] Salehi H, Burgueno ~ R. Emerging artificial intelligence methods in structural engineering. Eng Struct 2018;171(May): 170–89
- [2] Gomes GF, Mend´ez YAD, da Silva Lopes Alexandrino P, da Cunha SS, Ancelotti AC. The use of intelligent computational tools for damage detection and identification with an emphasis on composites – A review. Compos Struct 2018.
- [3] Spencer BF, Hoskere V, Narazaki Y. Advances in Computer Vision-Based Civil Infrastructure Inspection and Monitoring. Engineering 2019;5(2): 199–222.
- [4] Perlovsky L (2000) Neural Networks and Intellect: Using Model-Based Concepts. 1st ed. Oxford: Oxford University Press
- [5] Gu, et al. Recent advances in convolutional neural networks. Pattern Recogn 2017.

- [6] Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman DJ. 1D convolutional neural networks and applications – a survey. *Mechanical Systems and Signal processing*. 2020.
- [7] Hoskere V, Eick B, Spencer BF, Smith MD, Foltz SD. Deep Bayesian neural networks for damage quantification in miter gates of navigation locks. *Struct Health Monit* 2019: 1–30.
- [8] Naderpour H and Mirrashid M (2019) Shear failure capacity prediction of concrete beam–column joints in terms of ANFIS and GMDH. *Practice Periodical on Structural Design and Construction* 24(2): 04019006.
- [9] Mangalathu S and Jeon J-S (2019a) Machine learning–based failure mode recognition of circular reinforced concrete bridge columns: Comparative study. *Journal of Structural Engineering* 145(10): 04019104.
- [10] Luo H and Paal SG (2019) A locally weighted machine learning model for generalized prediction of drift capacity in seismic vulnerability assessments. *Computer-Aided Civil and Infrastructure Engineering* 34: 935–950.
- [11] Conte JP, Durrani AJ and Shelton RO (1994) Seismic response modeling of multi-story buildings using neural networks. *Journal of Intelligent Material Systems and Structures* 5(3): 392–402.
- [12] Akbas B, Shen J and Sabol TA (2011) Estimation of seismic-induced demands on column splices with a neural network model. *Applied Soft Computing* 11(8): 4820–4829.
- [13] Jiang X, Mahadevan S and Yuan Y (2017) Fuzzy stochastic neural network model for structural system identification. *Mechanical Systems and Signal Processing* 82: 394–411.
- [14] Gong L, Wang C, Wu F, Zhang J, Zhang H and Li Q (2016) Earthquake-induced building damage detection with post-event sub-meter VHR TerraSAR-X staring spotlight imagery. *Remote Sensing* 8(11): 1–21.
- [15] Molas GL and Yamazaki F (1995) Neural networks for quick earthquake damage estimation. *Earthquake Engineering & Structural Dynamics* 24(4): 505–516.
- [16] Vafaei M, Adnan AB and Rahman ABA (2013) Real-time seismic damage detection of concrete shear walls using artificial neural networks. *Journal of Earthquake Engineering* 17(1): 137–154.
- [17] Kankanamge Y, Hu Y, Shao X. Application of wavelet transform in structural health monitoring. *Earthq Eng Eng Vibr* 2020;19: 515–32.
- [18] Ancheta TD, Darragh RB, Stewart JP, Seyhan E, Silva WJ, Chiou BSJ, Wooddell KE, Graves RW, Kottke A, Boore DM, Kishida T and Donahue J (2014) NGA-West2 database. *Earthquake Spectra* 30(3): 989–1005.
- [19] Huang M. , Li X, and Lei, Y. , Jianfeng Gu, Structural damage identification based on modal frequency strain energy assurance criterion and flexibility using enhanced Moth-Flame optimization, *Structures*, Volume 28, 2020, Pages 1119-1136, ISSN 2352-0124.