

ارائه روشی مبتنی بر یادگیری ماشین برای تشخیص آسیب‌های خطی و غیرخطی سازه با ترکیب ویژگی‌های عمیق زمانی و زمان - فرکانس

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

اکبر اصغرزاده بناب*

دانشیار، گروه مهندسی برق، دانشگاه صنعتی ارومیه، ارومیه، ایران، h.kalbkhani@uut.ac.ir

هاشم کلبخانی

استادیار، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه امام علی (ع)، تهران، ایران،
s.bijanvand@iamu.ac.ir

سجاد بیژنوند

چکیده

پایش سلامت سازه‌های (SHM) برای تضمین عملکرد ایمن زیرساخت‌ها و تصمیم‌گیری در مورد نگهداری، تعمیر و مقاوم‌سازی سازه استفاده می‌شوند. در این مقاله روش جدیدی مبتنی بر پردازش سیگنال و یادگیری ماشین برای پایش سلامت سازه‌های ارائه شده است. روش پیشنهاد شده، بر مبنای ویژگی‌های عمیق زمانی و زمان - فرکانس است. برای استخراج ویژگی‌های عمیق زمان - فرکانس با استفاده از تبدیل فوری زمان پیوسته (CWT) به دست می‌آید و در ادامه، به شبکه عصبی تلفیقی (CNN) اعمال می‌شود. برای استخراج ویژگی‌های عمیق زمانی، توابع حالت ضمنی (IMF) با استفاده از تجزیه حالت تجربی (EMD) به دست آمده و شبکه حافظه طولانی کوتاه مدت (LSTM)، IMFها را مدل می‌کند. با توجه به تعداد زیاد ویژگی‌های عمیق به دست آمده، با استفاده از الگوریتم کاهش ویژگی، ویژگی‌ها با همبستگی بالا حذف شدند. در نهایت با استفاده از بردار پشتیبان ماشین (SVM) بهینه شده، سلامت سازه یا محل آسیب شناسایی می‌شود. نتایج به دست آمده نشان می‌دهند روش پیشنهادی نسبت به روش‌های مشابه دقت بالایی در سناریوهای خطی و غیرخطی داشته و می‌تواند به عنوان روشی مطمئن در کاربردهای SHM استفاده شود.

واژه‌های کلیدی: آسیب خطی، آسیب غیرخطی، پایش سلامت سازه‌ای، ویژگی زمانی، ویژگی زمان - فرکانس، یادگیری ماشین.

Machine Learning-based Structural Health Monitoring to Detect Linear and Non-linear Damages by Combining Deep Temporal and Time-Frequency Features

A. Asgharzadeh-Bonab

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

H. Kalbkhani

Department of Electrical Engineering, Urmia University of Technology, Urmia, Iran

S. Bijanvand

Department of Civil Engineering, Imam Ali University, Tehran, Iran

Abstract

Structural health monitoring (SHM) systems are used to ensure the safe operation of infrastructure and making decisions about the structure's maintenance, repair, and retrofitting. This paper presents a new method based on signal processing and machine learning for SHM. The proposed method is based on deep temporal and time-frequency features. The time-frequency representation (TFR) is obtained using continuous time Fourier transform (CWT), then TRF is applied to the convolutional neural network (CNN) to extract deep time-frequency features. To extract the deep temporal features, the intrinsic mode functions (IMF) are obtained using the empirical mode decomposition (EMD), and the long short-term memory (LSTM) network models the IMFs. Due to the large number of deep features, the features with high correlation were removed using the feature reduction algorithm. Finally, using the optimized support vector machine (SVM), the structure's health or the damage's location is identified. The results show that the proposed method is more accurate than similar methods in linear and non-linear scenarios and can be used as a reliable method in SHM applications.

Keywords: Linear Damage, Nonlinear Damage, Structural Health Monitoring, Temporal Features, Time-Frequency Features, Machine Learning.

محیطی و تشکیل ترک. بنابراین، پایش سلامت سازه‌ای (SHM¹) از مراحل اولیه تا پایان عمر مفید بسیار مهم است. عمر سرویس دهی سازه را می‌توان از طریق اعمال SHM غیرمخرب بر زیرساخت‌های عمرانی افزایش داد. مکان‌های آسیب‌دیده در مراحل اولیه عمر مفید شناسایی شده و عوامل کنترلی را که ممکن است به آسیب‌های آینده منجر شوند، نظارت می‌شوند. سیستم‌های SHM برای تضمین عملکرد ایمن

۱- مقدمه

نظارت و ارزیابی وضعیت زیرساخت‌های سازه‌ای برای توسعه اقتصادی یک کشور بسیار مهم است، زیرا عمر طولانی و نگهداری مناسب سازه‌ها هزینه‌های بازسازی را به میزان قابل توجهی کاهش می‌دهد. عملکرد سازه‌ای زیرساخت‌ها در طول زمان به دلیل عوامل کوتاه مدت پس از یا در طول ساخت و ساز کاهش می‌یابد، مانند ارتعاش، ترک‌های انقباضی و کارکردی و اثرات بلندمدت، مانند تخریب مواد و هواخوردگی، خوردگی میلگرد، نشست آب، شرایط بارگذاری، تخریب

¹ Structural Health Monitoring (SHM)

زیرساخت به منظور اتخاذ تصمیمات رضایت‌بخش در مورد تعمیر و نگهداری و مقاوم‌سازی سازه استفاده شده است [۵-۱]. در همین راستا، ترکیب داده‌کاوی و هوش مصنوعی نیز راه‌حلی جذاب برای مقابله با مسائل مختلف SHM ارائه شده است [۷-۵].

در [۸]، استفاده از مانده‌های سری زمانی خودبازگشتی (AR^1) پیشنهاد شد که حساسیت پیش‌بینی مدل AR در خصوص خرابی سازه را بهبود بخشید. در نتیجه، نویسندگان در ارزیابی تغییرات جزئی مانند ترک در یک ساختمان بتنی بلندمرتبه که توسط تحریکات واقعی محیط برانگیخته شده‌بود، موفق بودند. مانده‌های مدل AR هم‌چنین می‌توانند با آماره‌های آزمون مانند مقادیر T ، فرضیه آماری آزمون واریانس χ^2 برای تعیین محل خرابی ناشی از ترک در یک آزمایش آزمایشگاهی پیچیده ساختار تیر جعبه‌ای ترکیب شوند. پردازش سری زمانی از ابزارهای پیاده‌سازی شده در برنامه‌های کاربردی تشخیص الگوی آماری برای SHM است [۹]. از آنجایی که این روش مبتنی بر مدل دینامیک ساختاری جزئی است، می‌تواند حتی تعداد کمی از تغییرات را شناسایی کند [۱۰]. به عنوان مثال، در [۱۱] از سری‌های زمانی AR استفاده شد که قادر به انتخاب ویژگی‌های حساس غیرهمبسته بود. پس از آن، الگویی ایجاد و طبقه‌بند ماشین بردار پشتیبان (SVM^2) برای طبقه‌بندی سناریوهای مختلف زوال در یک مدل تحلیلی استفاده شد. با پیروی از این رویکرد، می‌توان خرابی را تحت تأثیر تغییرات محیطی، مانند نویز زیاد و خطاهای عملیاتی، مکان یابی کرد.

طیف فوری، تجزیه و تحلیل طیف، تجزیه و تحلیل فرکانس تفاضلی، و تکنیک تشدید فرکانس بالا ابزارهای مناسبی برای شناسایی آسیب، به ویژه برای خطاهای چرخ دنده و یاتاقان غلنگی، هستند [۱۲]. تبدیل فوری (FT^3) و تبدیل فوری سریع (FFT^4) مفاهیم اصلی تشخیص ناهنجاری در حوزه فرکانس در نظر گرفته می‌شوند. به عنوان نمونه، در مطالعه صورت‌گرفته در [۱۳]، FFT و تبدیل موجک پیوسته (CWT^5) برای تشخیص آسیب در تیرهای بتنی پیش‌تنیده واقعی و دال‌های بتنی مقایسه شدند. نتایج نشان دادند که FFT می‌تواند پیشرفت آسیب را در تیر تشخیص دهد اما نه در دال. برعکس، CWT می‌تواند حالت‌های اولیه و آسیب‌دیده را برای هر دو سازه متمایز کند. در [۱۴] یک رویکرد ضریب همبستگی مبتنی بر FFT برای ارزیابی خسارات روی یک تیر و پل ایجاد شد. نتایج نشان دادند که FFT بار محاسباتی کمتری نسبت به FT دارد و روش پیشنهادی می‌تواند صدمات ساختاری را از طریق ماتریس‌های همبستگی متقابل تعیین کند.

در [۱۵] داده‌های به‌دست‌آمده از طریق حسگرها را در یک شاخص نرخ انرژی بسته موجک اصلاح‌شده برای تعیین مقدار آسیب در یک پل فولادی تحت یک محیط پرتنش اعمال شد. در [۱۶] از حالت ساختاری استخراج‌شده از مدل المان محدود یک تیر بتن مسلح با تکیه‌گاه ساده استفاده شد که برای شناسایی آسیب با استفاده از انواع مختلف موجک

استفاده می‌شود. نشان داده شد که منحنی بیشینه در یک مقیاس خاص برای یک مورد خاص به یک مقدار اوج می‌رسد که بر اساس آن یک الگوریتم مبتنی بر شکل حالت جدید و شاخص آسیب برای شناسایی آسیب پیشنهاد شد. در [۱۷] استفاده از تبدیل موجک گسسته (DWT^6) و CWT برای تعیین آسیب خستگی و تخمین عمر باقیمانده قاب بررسی شد. در [۱۸]، یک روش محلی و تطبیقی جدید برای تجزیه و تحلیل سیگنال‌های ایستان و غیرایستان به نام تبدیل هیلبرت - هوانگ (HHT^7) ارائه شد. HHT بر تجزیه حالت تجربی (EMD^8) مبتنی است و می‌تواند سیگنال‌های اصلی را به یک سری توابع اساسی و تقریباً تک جزء به نام توابع حالت ضمنی (IMF^9) تجزیه کند. از طریق IMF ها، می‌توان تمام فرکانس‌های آنی را شناسایی کرد، که سپس برای محاسبه طیف هیلبرت استفاده می‌شوند [۱۹]. از تبدیل موجک تجربی و HHT برای محاسبه فرکانس‌های طبیعی و نسبت‌های میرایی سه ساختار استفاده شده‌است [۲۰]. در [۲۱]، EMD اصلاح‌شده برای شناسایی پارامترهای مودال روی یک قاب فولادی چهار طبقه پیشنهاد شده‌است. سیگنال‌های شفت‌های کامپوزیتی بافته‌شده سه-بعدی تحت کشش و پیچش توسط HHT در [۲۲] تجزیه و تحلیل شدند. نشان داده شد که HHT می‌تواند جداسازی مودال سیگنال‌های AE را برای شناسایی انواع آسیب ماتریس در مواد کامپوزیتی انجام دهد. در [۲۳]، پاسخ‌های پل کابلی را تجزیه و تحلیل شده و ویژگی‌ها را با استفاده از $STFT$ استخراج کردند. در [۲۴]، یک روش یادگیری عمیق جدید مبتنی بر CNN ، به نام $R-FPANet$ ، برای تشخیص ترک پیشنهاد شده‌است. $R-FPANet$ تقسیم‌بندی خودکار و کمی‌سازی مورفولوژی ترک را در سطح پیکسل انجام می‌دهد. با توجه به این که خوردگی عملکرد هر سازه عمرانی را کاهش می‌دهد، در [۲۵] یک روش مبتنی بر همبستگی خودکار سیگنال‌های ارتعاشی، یک مرحله پردازش داده، و یک مرحله پردازش مبتنی بر CNN یک‌بعدی برای شناسایی، مکان‌یابی و کمیت آسیب خوردگی پیشنهاد شده است. با توجه به مطالب بیان‌شده، در این مقاله روش جدیدی برای SHM با ترکیب ویژگی‌های عمیق زمانی و زمان - فرکانس برای تشخیص آسیب‌های خطی و غیرخطی ارائه می‌شود. ویژگی‌های عمیق زمانی با استفاده از توابع حالت ضمنی (IMF^10) و شبکه حافظه طولانی کوتاه مدت ($LSTM^11$) به دست می‌آیند. هم‌چنین از تبدیل موجک پیوسته (CWT^12) و شبکه‌های عصبی تلفیقی (CNN^13) برای استخراج ویژگی‌های عمیق زمان - فرکانس استفاده می‌شود. دو دسته ویژگی عمیق بعد از کاهش ویژگی‌های غیرمؤثر با هم ترکیب شده و توسط طبقه‌بند بهینه‌شده، محل خرابی یا سالم‌بودن سازه مشخص می‌شود. نتایج نشان می‌دهند که ترکیب ویژگی‌های نتایج بهتری نسبت به استفاده منفرد از آن‌ها دارد و نسبت به روش‌های مشابه که اخیراً ارائه شده‌اند، دقت تشخیص بالاتری دارد.

⁶ Discrete wavelet transform (DWT)

⁷ Hilbert-Huang transform (HHT)

⁸ Empirical mode decomposition (EMD)

⁹ Intrinsic mode function (IMF)

¹⁰ Intrinsic mode functions (IMF)

¹¹ Long short-term memory (LSTM)

¹² Continuous wavelet transform (CWT)

¹³ Convolutional neural network (CNN)

¹ Autoregressive (AR)




² Support vector machine (SVM)

³ Fourier transform (FT)




⁴ Fast Fourier transform (FFT)

⁵ Continuous wavelet transform (CWT)

سیگنال تنظیم شده است. ده اندازه گیری برای هر حالت ثبت می شود. به همین ترتیب، در نمونه اولیه، این قاب روی ریل هایی که امکان انتقال را در یک جهت با کمک یک محرک فراهم می کند، می نغزد. چهار شتاب سنج با حساسیت 1000 mV/g در طرف مقابل لرزاننده در مرکز طبقات وصل شده است. بنابراین، آن ها به تعیین مدل های پیچشی نمونه کمکی نمی کنند.



شکل ۱- سیگنال های ثبت شده توسط حسگرها در سناریو S1 برای آسیب خطی.



شکل ۲- سیگنال های ثبت شده توسط حسگرها در سناریو S7 برای آسیب خطی.

برای شبیه سازی آسیب غیرخطی، یک ضربه گیر مکانیکی و یک ستون مرکزی بر روی قاب نصب شده است. این عملکرد تقلید از ترک تنفسی است و در شرایطی که ستون نصب شده به سپر که در طبقه دوم قرار دارد برخورد کند، رفتارهای غیرخطی ایجاد خواهد کرد. شکاف قابل تنظیم بین سپر و ستون نصب شده برای تعریف درجات مختلف غیرخطی استفاده می شود. بنابراین، هر چه شکاف بزرگ تر باشد، رفتار غیرخطی کوچک تر می شود. سناریوهای آسیب غیرخطی در جدول ۲ ارائه شده است. برخی از سیگنال های غیرخطی ثبت شده در شکل های ۳ و ۴ آورده شده است، که در آن $y_1(t)$ ، $y_2(t)$ ، $y_3(t)$ و $y_4(t)$ به ترتیب سیگنال ثبت شده توسط حسگر ۱، حسگر ۲، حسگر ۳ و حسگر ۴ هستند. مشابه مورد قبلی، نمایش حوزه زمانی پاسخ ها نمی تواند تغییرات ناشی از آسیب را به درستی نشان دهد.

۳- روش پیشنهادی برای تشخیص آسیب

در این بخش به ارائه روش پیشنهادی برای تشخیص آسیب ها خطی و غیرخطی می پردازیم. در ادامه به بررسی تکنیک ها و ابزارهای استفاده شده می پردازیم و سپس روش پیشنهادی با جزئیات شرح داده می شود.

ادامه این مقاله به صورت زیر تنظیم شده است. در بخش دوم، پایگاه داده استفاده شده توضیح داده شده است. روش پیشنهادی با جزئیات در بخش سوم شرح داده شده است. نتایج روش پیشنهادی در بخش چهارم گزارش شده و در نهایت بخش پنجم به جمع بندی این مقاله می پردازد.

۲- پایگاه داده

۲-۱- پایگاه داده آسیب خطی

اولین پایگاه داده شامل مطالعه موردی یک قاب فلزی سه طبقه با ستون ها و کف های آلومینیومی است که در شبیه سازی آسیب خطی مورد بررسی قرار گرفته است [۲۶]. یک غلتک در پایه از سازه پشتیبانی می کند و می تواند با استفاده از جک هیدرولیک به صورت افقی حرکت کند. شتاب سنج های تک محوری پیزوالکتریک در هر طبقه نصب شده اند. نه سناریو آسیب خطی با استفاده از کاهش سختی ستون ها و جایگزینی یک جرم $1/2$ کیلوگرمی شبیه سازی شده است. از این رو، ۵۰ سیگنال برای هر سناریو با نرخ نمونه 320 هرتز ثبت می شود. سناریوها به شرح مقابل هستند: وضعیت سالم (S1) که ساختارهای دست نخورده را بدون هیچ تغییری در اجزا نشان می دهد، دو سناریو (S2 و S3)، تغییر اثرات عملیاتی و محیطی را با تغییر جرم طبقات و شش سناریو (S4-S9) آسیب را با تغییر سفتی ستون ها شبیه سازی می کنند.

جدول ۱- سناریوهای آسیب در مطالعه آسیب های خطی

سناریو	توضیحات
S1	حالت سالم
S2	جرم = $1/2$ کیلوگرم در پایه
S3	وزن = $1/2$ کیلوگرم در سطح ۱
S4	$87/5$ کاهش سفتی در ستون 1BD
S5	$87/5$ کاهش سفتی در ستون 1AD و 1BD
S6	$87/5$ کاهش سفتی در ستون 2BD
S7	$87/5$ کاهش سفتی در ستون 2AD و 2BD
S8	$87/5$ کاهش سفتی در ستون 3BD
S9	$87/5$ کاهش سفتی در ستون 3AD و 3BD

شکل های ۱ و ۲ به ترتیب نمونه سیگنال های ثبت شده را در سناریو سالم و سناریوی خرابی S7 مختلف نشان می دهد، که در آن $y_1(t)$ ، $y_2(t)$ و $y_3(t)$ به ترتیب نشان دهنده داده ثبت شده توسط حسگر ۱، حسگر ۲ و حسگر ۳ است. بدیهی است که پاسخ های ثبت شده برای همه سناریوهای آسیب از الگوی تصادفی پیروی می کنند. بنابراین، نیاز به مدل سازی پاسخ های خروجی از طریق تکنیک های پردازش سیگنال برای یافتن ویژگی های مناسب که نشان دهنده تغییرات در سیگنال ها هستند، وجود دارد.


۲-۲- پایگاه داده آسیب غیرخطی

این پایگاه داده، مدل تعدیل شده اولین مطالعه موردی است و برای بررسی تأثیر آسیب غیرخطی استفاده می شود. نرخ نمونه برداری مشابه مدل خطی است و روی $322/58$ هرتز با 8192 نمونه داده برای هر

۳-۱- تکنیک‌های استفاده شده

۳-۱-۱- شبکه عصبی تلفیقی (CNN)

CNN یک شبکه عصبی پیشخور با ساختار عمیق مبتنی بر محاسبات تلفیق است. در قرن بیست و یکم، با معرفی نظریه یادگیری عمیق و بهبود الگوریتم‌های محاسبات عددی، CNN به سرعت توسعه یافته و در بینایی کامپیوتر، پردازش زبان طبیعی و سایر زمینه‌ها به کار گرفته شده است. CNN ساختار ادراک بصری موجودات زنده را تقلید می‌کند و می‌تواند یادگیری تحت نظارت و بدون نظارت را انجام دهد. اشتراک پارامترهای هسته تلفیق در لایه پنهان و پراکندگی اتصالات بین لایه‌ای، شبکه عصبی تلفیق را قادر می‌سازد تا ویژگی‌های توپولوژیکی شبکه مانند را با محاسبات کمتر، مانند پیکسل‌ها و صدا، یاد بگیرد.



شکل ۴- سیگنال‌های ثبت‌شده توسط حسگرها در سناریو S15 برای آسیب غیرخطی

جدول ۲- سناریوهای آسیب در مطالعه آسیب‌های غیرخطی

سناریو	توضیحات
S1	وزن = ۱/۲ کیلوگرم در طبقه ۱
S2	جرم = ۱/۲ کیلوگرم در پایه
S3	شکاف = ۰/۱۳ میلی‌متر
S4	شکاف = ۰/۱۰ میلی‌متر
S5	شکاف = ۰/۰۵ میلی‌متر
S6	شکاف = ۰/۱۵ میلی‌متر
S7	شکاف = ۰/۲۰ میلی‌متر
S8	حالت سالم
S9	شکاف = ۰/۲۰ میلی‌متر و جرم = ۱/۲ کیلوگرم در طبقه اول
S10	شکاف = ۰/۱۰ میلی‌متر و جرم = ۱/۲ کیلوگرم در طبقه اول
S11	شکاف = ۰/۲۰ میلی‌متر و جرم = ۱/۲ کیلوگرم در پایه
S12	۵۰٪ کاهش سفتی در ستون 1BD
S13	۵۰٪ کاهش سفتی در ستون 1BD + 1AD
S14	۵۰٪ کاهش سفتی در ستون 3BD
S15	۵۰٪ کاهش سفتی در ستون 3BD + 3AD
S16	۵۰٪ کاهش سفتی در ستون 2BD + 2AD
S17	۵۰٪ کاهش سفتی در ستون 2BD


یک CNN کامل معمولاً شامل لایه‌های تلفیق، ادغام^۱، لایه‌های اتصال کامل^۲ است. لایه‌های تلفیق با انجام محاسبات تلفیق روی ورودی، ویژگی‌ها را استخراج می‌کنند. لایه‌های تلفیق حاوی هسته‌های محاسباتی و بایاس^۳ هستند. اندازه و عمق هسته‌های تلفیق به ترتیب به طول پنجره فیلتر و تعداد کانال‌های ورودی بستگی دارد. فرآیند تلفیق را می‌توان به صورت زیر نشان داد:

$$y_j^l = \sum_{i=1}^k \omega_{i,j}^l \otimes y_i^{l-1} + b_j^l \quad (1)$$

که در آن y_j^l خروجی لایه l را نشان می‌دهد، $\omega_{i,j}^l$ پارامترهای وزن لایه تلفیق l را نشان می‌دهد، y_i^{l-1} مقدار خروجی لایه قبلی را نشان می‌دهد و b_j^l نشان‌دهنده مقدار بایاس است.

پس از تلفیق، از تابع فعال‌ساز^۴ برای افزودن برخی عوامل غیرخطی برای بهبود بیان و توانایی طبقه‌بندی مدل استفاده می‌شود. هنگامی که یک نورون اطلاعات مرتبط را پردازش می‌کند، سیگنال ارسال شده توسط دندریت نورون قبلی وزن‌دار می‌شود. هنگامی که نتیجه وزنی از آستانه خاص فراتر رفت، نورون‌های بعدی می‌توانند برای درگیر شدن در پاسخ‌های بعدی تحریک شوند. به طور کلی، تابع فعال‌سازی برای تعیین اینکه آیا خروجی یک نورون از یک آستانه خاص فراتر می‌رود یا خیر استفاده می‌شود. سه تابع فعال‌ساز متداول عبارتند از: sigmoid، tanh و ReLU^۵.

هر لایه تلفیق مقدار زیادی اطلاعات اضافی را در طول آموزش مدل تولید می‌کند که تأثیر کمی بر استخراج ویژگی و آموزش مدل دارد و حتی ممکن است روند آموزش مدل را آهسته کند. هنگام طراحی ساختار شبکه عصبی، لازم است لایه‌های ادغام در برخی مکان‌ها لحاظ شوند تا اطلاعات اضافی حذف شوند. ادغام عمدتاً تعداد عناصر را با در نظر گرفتن حداکثر مقدار یا مقدار متوسط کاهش می‌دهد تا نتایج خروجی لایه قبلی را کاهش دهد. پس از چندین لایه تلفیق و



شکل ۳- سیگنال‌های ثبت‌شده توسط حسگرها در سناریو S1 برای آسیب غیرخطی.

¹ Pooling
² Fully-connected
³ Bias
⁴ Activation function
⁵ Rectified linear unit (ReLU)

می‌کنیم. اجزای سوم، چهارم و پنجم IMF را می‌توان با قیاس به دست آورد، یعنی $c_3(t)$ ، $c_4(t)$ و $c_2(t)$ و $r_n(t)$ باقی‌مانده سیگنال اصلی نامیده می‌شود.

به این ترتیب، سیگنال اصلی $y(t)$ را می‌توان به مجموع چندین مؤلفه IMF و یک باقی‌مانده تجزیه کرد که می‌تواند به صورت زیر بیان شود:

$$y(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (4)$$

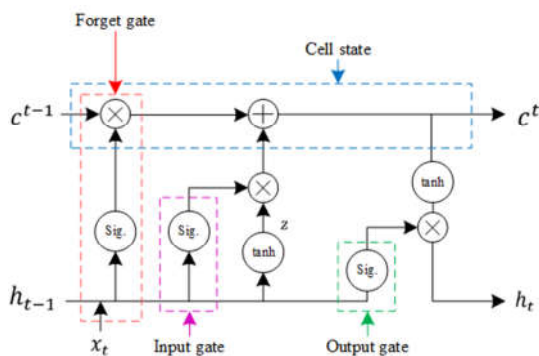
۳-۱-۳- شبکه حافظه طولانی کوتاه مدت (LSTM)

ساختار یک واحد LSTM در شکل ۵ نشان داده شده است. سه دروازه^۲ در بلوک LSTM وجود دارد که شامل یک دروازه فراموشی^۳، یک دروازه ورودی^۴ و یک دروازه خروجی^۵ است. حالت سلولی اطلاعات را در طول زمان به خاطر می‌آورد، دروازه فراموشی مقادیر نگهداری‌شده در سلول را کنترل می‌کند، دروازه ورودی مقادیر موجود در سلول را برای جریان کنترل می‌کند، و دروازه خروجی مقادیر موجود در سلول را کنترل می‌کند. خروجی محاسبات فرمول‌های ریاضی واحدهای LSTM به صورت زیر تعریف می‌شوند:

$$z = \tanh(W[x_t, h_{t-1}]) \quad (5)$$

$$c^t = \sigma(W^f[x_t, h_{t-1}]) \times c^{t-1} + \sigma(W^i[x_t, h_{t-1}]) \times z \quad (6)$$

$$h(t) = \sigma(W^o[x_t, h_{t-1}]) \times \tanh(c^t) \quad (7)$$



شکل ۵- نمایش ساختار یک واحد LSTM.

۳-۱-۴- کاهش ویژگی

تجزیه و تحلیل مؤلفه اصلی (PCA)^۶، یک روش کاهش ابعاد است که اغلب برای کاهش ابعاد مجموعه داده بزرگ، با تبدیل مجموعه بزرگی از متغیرها به یک مجموعه کوچک‌تر که هم‌چنان حاوی بیشتر اطلاعات در مجموعه بزرگ است، استفاده می‌شود.

PCA با هسته (KPCA)^۷ یک تکنیک کاهش ابعاد غیرخطی است که الگوریتم PCA محبوب را با اضافه کردن هسته گسترش می‌دهد تا

لایه‌های ادغام، لایه خروجی مدل CNN به طور کلی لایه کاملاً متصل است و رگرسیون softmax اغلب برای ارائه نتایج چندین کلاس به صورت احتمالی استفاده می‌شود.

۳-۱-۲- تجزیه حالت تجربی (EMD)

الگوریتم تجزیه حالت تجربی (EMD)^۱ توسط هوانگ در سال ۱۹۹۸ پیشنهاد شد که می‌تواند سیگنال‌های غیرثابت و غیرخطی را به صورت تطبیقی تجزیه کند. الگوریتم EMD می‌تواند سیگنال را با توجه به ویژگی‌های سیگنال به چندین توابع حالت ضمنی (IMF) تجزیه کند، که پایه خوبی برای پردازش موثر کاهش نویز فراهم می‌کند. بر اساس اطلاعات مشخصه محلی خود سیگنال، روش EMD تجزیه تطبیقی را برای به دست آوردن یک سری از اجزای IMF با مقیاس‌های زمانی مختلف انجام می‌دهد. مؤلفه IMF باید دو شرط را برآورده کند: (۱) در کل سری زمانی، تعداد نقاط اکسترمم و تعداد عبور از صفر باید یکسان باشد، یا تفاوت نباید از یک تجاوز کند. (۲) در هر زمان، مقدار متوسط پوش بالایی و پایینی که به ترتیب توسط نقاط بیشینه محلی و کمینه محلی تشکیل شده است، صفر است. فرآیند EMD به شرح زیر است:

(۱) تمام اکسترمم‌های محلی سیگنال اصلی $y(t)$ تعیین شده و سپس تمام آن نقاط توسط یک منحنی spline مکعبی به هم وصل می‌شوند تا پوش بالایی تشکیل شود.

(۲) تمام نقاط کمینه محلی توسط یک منحنی spline مکعبی به هم وصل می‌شوند تا پوش پایینی را تشکیل دهند. پوش بالا و پایین باید تمام نقاط داده را در بر گیرد.

در ادامه میانگین پوش بالایی و پایینی محاسبه شده و با $m_1(t)$ نشان داده می‌شود و داریم:

$$y(t) - m_1(t) = h_1(t) \quad (2)$$

در شرایط ایده‌آل، $h_1(t)$ اولین مؤلفه IMF از $y(t)$ است اگر $h_1(t)$ دو شرط اساسی مؤلفه IMF را برآورده کند.

(۳) اگر $h_1(t)$ دو شرط اساسی مؤلفه IMF را برآورده نکند، به عنوان سیگنال اصلی در نظر گرفته می‌شود و مراحل (۱)-(۳) برای بدست آوردن مقدار میانگین $m_2(t)$ از خطوط پوش بالا و پایین تکرار می‌شود و سپس بررسی می‌شود که آیا

$h_2(t) = h_1(t) - m_2(t)$ دو شرط اساسی مؤلفه IMF را برآورده می‌کند یا خیر. اگر نه، چرخه را برای k بار تکرار می‌شود تا

$h_k(t) = h_{k-1}(t) - m_2(t)$ به دست آید. بنابراین $h_k(t) = h_k(t)$ ، $c_1(t) = h_k(t)$ ، اولین مؤلفه IMF را برآورده می‌کند. بنابراین، $c_1(t) = h_k(t)$ ، اولین مؤلفه IMF سیگنال اصلی $y(t)$ است.

(۴) پس از این‌که اولین مؤلفه IMF، $c_1(t)$ ، از سیگنال اصلی $y(t)$ تجزیه شد، $c_1(t)$ از $y(t)$ کم می‌شود تا دنباله مقادیر باقیمانده $r_1(t)$ بدست آید:

$$r_1(t) = y(t) - c_1(t) \quad (3)$$

$r_1(t)$ به عنوان سیگنال اصلی گرفته می‌شود و مراحل (۱)-(۴) را برای بدست آوردن دومین مؤلفه IMF، $c_2(t)$ ، سیگنال اصلی $y(t)$ تکرار

^۱ Empirical mode decomposition (EMD)

^۲ Gate

^۳ Forgotten

^۴ Input

^۵ Output

^۶ Principal component analysis (PCA)

^۷ Kernel PCA (KPCA)

داده‌ها را در فضایی با ابعاد بالاتر نشان دهد که در آن داده‌ها به صورت خطی قابل تفکیک می‌شوند. این امکان ثبت روابط غیرخطی در داده را فراهم می‌کند و آن را به ابزاری قدرتمند برای کارهایی مانند تشخیص الگو و استخراج ویژگی تبدیل می‌کند. KPCA اغلب در کاربردهای یادگیری ماشین و تجزیه و تحلیل داده استفاده می‌شود که در آن داده‌ها به صورت خطی در فضای اصلی قابل تفکیک نیستند. با اعمال یک تابع هسته، مانند هسته تابع پایه شعاعی (RBF)، داده‌ها را می‌توان در یک فضای ابعادی بالاتر ترسیم کرد، جایی که به صورت خطی قابل تفکیک می‌شود و امکان کاهش ابعاد موثرتر را فراهم می‌کند.

۵-۱-۳- بردار پشتیبان ماشین (SVM)

برای طبقه‌بندی بردار ویژگی تولید شده، در این پژوهش از ماشین بردار پشتیبان (SVM) استفاده می‌شود. SVMها طبقه‌بندهای باینری بهینه هستند که با ایجاد ابرصفحه^۲ بهینه که داده‌ها را به دو کلاس جدا می‌کند، طبقه‌بندی را انجام می‌دهند. برای طبقه‌بندی باینری، ماشین بردار پشتیبان حاشیه نرم^۳، که به عنوان C-SVM شناخته می‌شود، با هسته RBF می‌تواند برای طبقه‌بندی ویژگی‌ها استفاده شود. اگرچه SVMها در اصل به عنوان طبقه‌بندهای باینری طراحی شده‌اند، اما کاربردهای مختلفی وجود دارد که آن‌ها را قادر می‌سازد تا بیش از دو کلاس را طبقه‌بندی کنند. طبقه‌بندهای SVM چندکلاسه را می‌توان تقریباً به دو گروه تقسیم کرد، روش‌های همه با هم^۴ و روش‌های مبتنی بر طبقه‌بندی‌کننده‌های باینری [۲۷].

۲-۳- روش پیشنهادی

بلوک دیاگرام روش پیشنهادی در این پژوهش برای شناسایی آسیب‌های خطی و غیرخطی در شکل ۶ نشان داده شده‌است. روش ارائه‌شده بر مبنای ترکیب ویژگی‌های عمیق زمانی و زمان - فرکانسی است که می‌تواند رفتارهای خطی و غیرخطی سیگنال را به صورت مناسبی توصیف کنند. برای استخراج ویژگی‌های عمیق زمان - فرکانسی، ابتدا تبدیل CWT برای هر کدام سیگنال ذخیره‌شده توسط حسگرهای مختلف محاسبه می‌شود. با در نظر گرفتن n_s نمونه برای هر سیگنال، خروجی CWT برای استخراج ویژگی‌های عمیق مورد استفاده قرار خواهد گرفت. چون خروجی CWT مختلط است، از قدرمطلق آن استفاده خواهد شد. برای استخراج ویژگی‌های عمیق، قدرمطلق CWT از یک CNN عبور داده می‌شود و ویژگی‌های به دست‌آمده در لایه flatten به عنوان ویژگی‌های عمیق زمان - فرکانسی در نظر گرفته می‌شوند. با توجه به این‌که طراحی ساختار جدید برای CNN به دلیل پارامترهای زیاد دشوار است، از ساختارهای از پیش طراحی‌شده و یادگیری انتقالی استفاده خواهد شد. شایان ذکر است در این حالت،

ابعاد خروجی CWT باید با روش‌های درون‌یابی به ابعاد لایه ورودی CNN تغییر کند.

فرض کنید بردارهای $\mathbf{x}_1, \dots, \mathbf{x}_N$ بیانگر ویژگی‌های عمیق زمان - فرکانس استخراج‌شده از حسگرهای ۱ تا N باشند که هر کدام شامل n_{tf} ویژگی هستند. بردار ویژگی‌های زمان - فرکانس به صورت زیر به دست می‌آید که شامل $N \times n_{tf}$ ویژگی است:

$$\mathbf{x}_{tf} = [\mathbf{x}_1^T, \dots, \mathbf{x}_N^T]^T \quad (V)$$

در نهایت، روش KPCA به بردار \mathbf{x}_{tf} اعمال می‌شود و بردار ویژگی‌های زمان - فرکانس نهایی، $\mathbf{x}_{tf,F}$ ، با ابعاد $1 \times n_{tf,F}$ به دست می‌آید.

بر اساس بلوک دیاگرام نشان داده‌شده در شکل ۶ برای استخراج ویژگی‌های عمیق زمانی، ابتدا با استفاده از تجزیه حالت تجربی، توابع حالت ضمنی به دست می‌آیند و در ادامه رفتار زمانی این توابع با استفاده از شبکه LSTM مدل می‌شود. فرض کنید تعداد توابع حالت ضمنی برابر n_{IMF} باشد. با در نظر N حسگر و برای هر حسگر، تعداد توابع حالت ضمنی به دست‌آمده برابر $N \times n_{IMF}$ است. اگر مدل‌سازی هر تابع حالت ضمنی با LSTM، به تعداد n_t ویژگی عمیق زمانی تولید کند، تعداد ویژگی‌های عمیق زمانی برابر $N \times n_{IMF} \times n_t$ است. با توجه به تعداد بالای ویژگی‌های عمیق زمانی، ویژگی‌های استخراج‌شده با استفاده از KPCA کاهش می‌یابند و ویژگی‌های زمانی نهایی، $\mathbf{x}_{t,F}$ ، با ابعاد $1 \times n_{t,F}$ به دست می‌آیند.

بردار ویژگی نهایی با ادغام بردارهای $\mathbf{x}_{t,F}$ و $\mathbf{x}_{t,F,F}$ به صورت $\mathbf{x}_F = [\mathbf{x}_{t,F,F}^T, \mathbf{x}_{t,F}^T]^T$ به دست می‌آید که شامل $n_{t,F,F} + n_{t,F}$ ویژگی است. این بردار ویژگی به طبقه‌بند SVM با کرنل RBF اعمال می‌شود تا شناسایی محل خرابی یا سالم بودن سازه مشخص شود. با توجه به این‌که عملکرد این طبقه‌بند به انحراف معیار کرنل وابسته است، از بهینه‌سازی Bayesian برای یافتن مقدار بهینه آن و بیشینه کردن دقت طبقه‌بندی استفاده می‌شود.

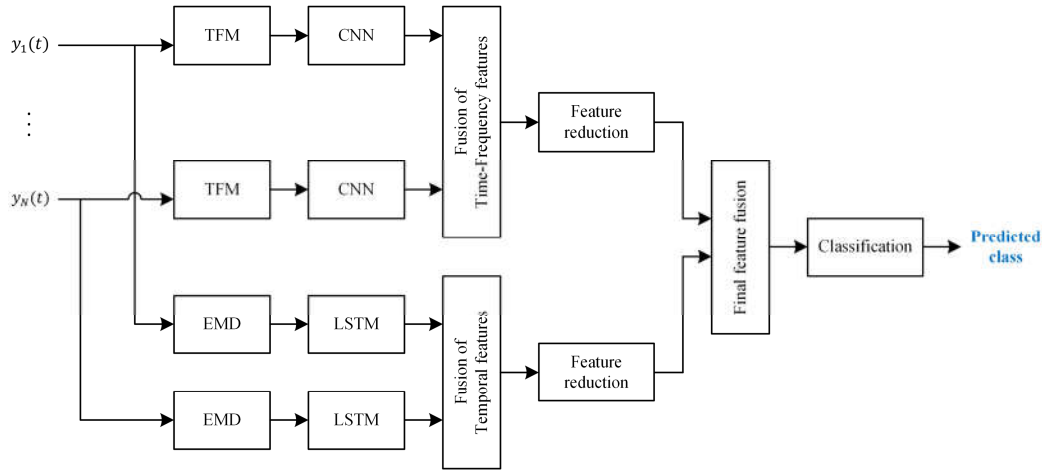
شایان ذکر است علاوه بر ساختار ارائه‌شده در شکل ۶، ساختارهای مبتنی بر ترکیب اولیه (شکل ۷) و ترکیب نهایی (شکل ۸) نیز مورد ارزیابی قرار گرفتند. نتایج به دست آمده نشان دادند که ساختار پیشنهادی در شکل ۶ عملکرد بهتری دارد، به همین دلیل این ساختار با جزئیات بیشتر شرح داده شد. ساختار ترکیب اولیه، ویژگی‌های عمیق زمان - فرکانس و زمانی را به ترتیب از مقدار میانگین TFM و توابع حالت ضمنی استخراج می‌کند که به دلیل میانگین‌گیری انجام‌شده، ویژگی‌های متعددی حذف می‌شوند و دقت تشخیص کاهش می‌یابد. در ساختار ترکیب نهایی، ویژگی‌های زمانی و زمان - فرکانس مرتبط با هر کانال به صورت جداگانه طبقه‌بندی می‌شوند و تصمیم‌گیری نهایی بر کلاسی تعلق می‌یابد که بیشترین تعداد تکرار را در بین کلاس‌ها داشته باشد.

¹ Radial basis function (RBF)

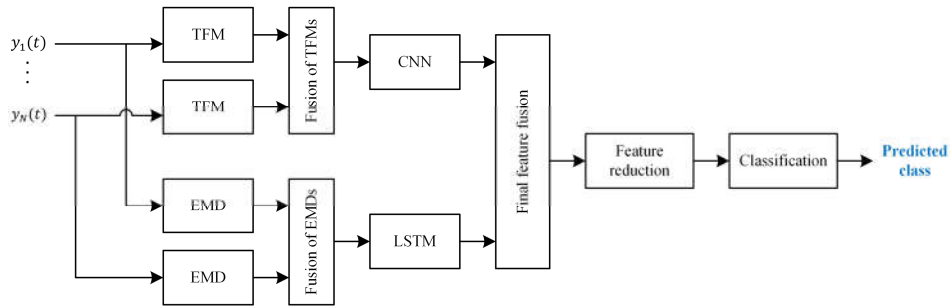
² Hyperplane

³ Soft margin

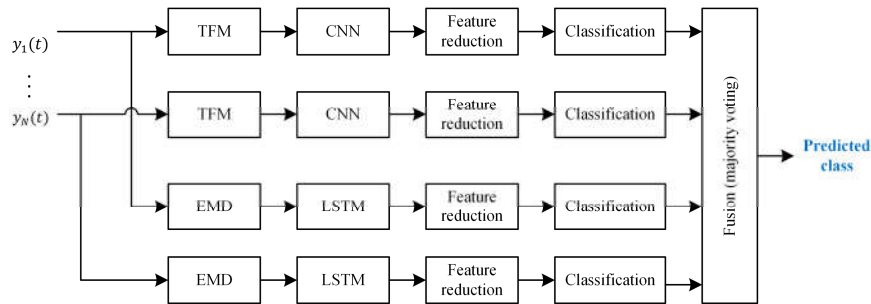
⁴ All-together



شکل ۶- بلوک دیاگرام روش پیشنهادی برای تشخیص آسیب‌های خطی و غیرخطی.



شکل ۷- بلوک دیاگرام ساختار ترکیب اولیه برای تشخیص آسیب‌های خطی و غیرخطی.



شکل ۸- بلوک دیاگرام ساختار ترکیب نهایی برای تشخیص آسیب‌های خطی و غیرخطی.

۴- نتایج

در این بخش نتایج به ارائه نتایج به دست آمده از شبیه‌سازی‌ها و تحلیل آن‌ها می‌پردازیم. برای ارزیابی عملکرد روش پیشنهادی، اعتبارسنجی متقابل پنج‌گانه^۱ را در نظر گرفتیم. بدین منظور، داده‌ها به طور تصادفی به پنج گروه هم‌اندازه تقسیم شدند و سپس مراحل

آموزش و آزمون برای پنج کارآزمایی تکرار شد. یک گروه از داده‌ها به عنوان آزمون در هر کارآزمایی در نظر گرفته شد و گروه‌های دیگر برای آموزش طبقه‌بند استفاده شدند. در نهایت، متوسط نتایج محاسبه شد. دقت طبقه‌بندی به صورت زیر محاسبه می‌شود:

$$Acc. = \frac{TP + FP}{TP + TN + FP + FN} \quad (A)$$

که در آن TP، TN، FP و FN به ترتیب نشان‌دهنده مثبت واقعی، منفی واقعی، مثبت کاذب و منفی کاذب هستند.

با توجه به پیچیدگی‌های طراحی شبکه CNN، از شبکه‌های پیش‌طراحی شده MobileNet و یادگیری انتقالی برای استخراج ویژگی‌های

^۱ Five-fold cross-validation

عمیق زمان - فرکانس استفاده می‌کنیم. هم‌چنین شبکه LSTM با ۵۰ واحد مخفی برای استخراج ویژگی‌های عمیق زمانی مورد استفاده قرار می‌گیرد.

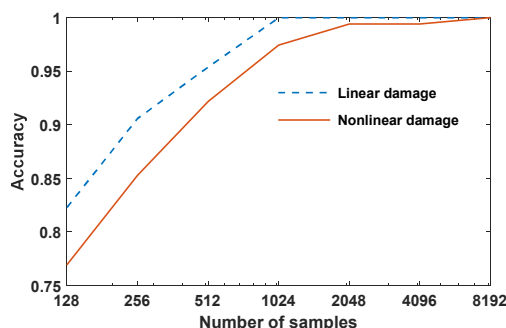
۴-۱- تاثیر ساختار ترکیب و طول سیگنال

در این قسمت ابتدا، دقت ساختارهای پیشنهاد شده در شکل‌های ۶-۸ را ارائه می‌کنیم تا مشخص شود کدام ساختار دقت طبقه‌بندی بالاتری دارد. نتایج در جدول ۳، با در نظر گرفتن استفاده از کل طول سیگنال‌های ذخیره شده، گزارش شده است. همانطور که مشاهده می‌شود روش پیشنهادی برای ترکیب ویژگی‌های مختلف دقت بالاتری نسبت به روش‌های ترکیب اولیه و ترکیب نهایی دارد. هم‌چنین روش ترکیب نهایی، دقت بالاتری نسبت به روش ترکیب اولیه ارائه می‌کند. هم‌چنین ساختارهای ترکیب اولیه و ترکیب نهایی، آسیب خطی را با دقت بیشتری نسبت به آسیب غیرخطی تشخیص می‌دهند.

جدول ۳- تاثیر ساختار ترکیب ویژگی‌ها بر دقت طبقه‌بندی

نوع ترکیب	ساختار پیشنهادی	ترکیب اولیه	ترکیب نهایی
آسیب خطی	٪۱۰۰	۹۶٪/۴۴	۹۸٪/۲۲
آسیب غیرخطی	٪۱۰۰	۹۵٪/۲۷	۹۷٪/۰۴

در ادامه، اثر طول سیگنال بر دقت طبقه‌بندی بررسی می‌شود. در بخش ۲ بیان شد که سیگنال‌های ذخیره شده دارای ۸۱۹۲ نمونه هستند. چون افزایش طول سیگنال باعث افزایش بار محاسباتی می‌شود، می‌خواهیم بررسی کنیم که آیا با تعداد نمونه‌های کمتری می‌توان به دقت مطلوب دست یافت یا نه. برای این منظور دقت طبقه‌بندی برای طول مختلف به دست آمد که در شکل ۹ نشان داده شده است. مشاهده می‌شود که با افزایش تعداد نمونه‌ها، دقت طبقه‌بندی در حالا کلی افزایش پیدا می‌کند. در حالت آسیب خطی، با افزایش تعداد نمونه‌ها از ۱۲۸ تا ۱۰۲۴ دقت طبقه‌بندی از ۸۲٪/۲۲٪ به ۱۰۰٪ رسیده و بعد از آن ثابت باقی می‌ماند. در حالت غیرخطی نیز، دقت طبقه‌بندی از ۷۷٪/۰۹٪ برای ۱۲۸ نمونه به ۹۹٪/۴۱٪ برای ۲۰۴۸ نمونه رسیده و به ازای ۸۰۹۲ نمونه به دقت ۱۰۰٪ می‌رسد.

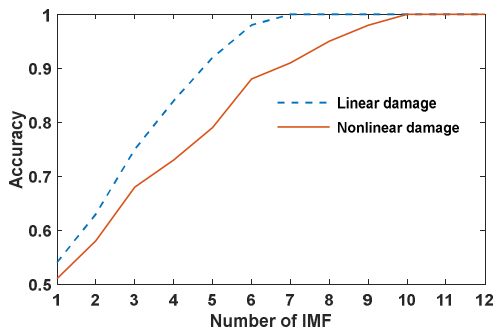


شکل ۹- تاثیر تعداد نمونه‌های سیگنال بر دقت طبقه‌بندی.

۴-۲- تاثیر تعداد توابع حالت ضمنی

شکل ۱۰ تاثیر تعداد توابع ضمنی استفاده شده برای استخراج ویژگی‌های عمیق زمانی با در نظر گرفتن ۱۰۲۴ نمونه برای

سیگنال‌های آسیب خطی و ۲۰۴۸ نمونه برای سیگنال‌های آسیب غیرخطی بر دقت طبقه‌بندی را نشان می‌دهد. در حالت با افزایش تعداد توابع حالت ضمنی، دقت طبقه‌بندی نیز بهبود می‌یابد. برای سیگنال‌های خطی به ازای هفت تابع و برای سیگنال‌های غیرخطی به ازای ده تابع حالت ضمنی، بیشینه دقت طبقه‌بندی به دست می‌آید.



شکل ۱۰- تاثیر تعداد توابع حالت ضمنی بر دقت طبقه‌بندی.

۴-۳- تاثیر نویز و کاهش ویژگی

در این بخش پایداری روش پیشنهادی در برابر نویز و خطاهای اندازه‌گیری ارائه می‌شود. جدول ۴ دقت روش پیشنهادی را به ازای مقادیر مختلف نسبت سیگنال به نویز (SNR^۱) نشان می‌دهد. نویز اضافه شده به سیگنال‌ها به صورت نویز گوسی سفید جمع‌شونده (AWGN^۲) با میانگین صفر و واریانس مشخص است که در این حالت توان نویز برابر با مقدار واریانس آن است. واریانس نویز به صورتی تنظیم می‌شود که نسبت سیگنال به نویز مورد نظر تامین شود که در حقیقت برابر نسبت توان سیگنال به توان نویز می‌باشد. نتایج به دست آمده نشان می‌دهند که روش پیشنهادی تا SNR معادل ۱۵ dB دقت شناسایی بالای ۹۰٪ را ارائه می‌دهد که قابل قبول است. هم‌چنین بدون استفاده از کاهش ویژگی KPCA به ترتیب به دقت ۹۵٪/۱۱٪ و ۹۴٪/۶۷٪ برای آسیب‌های خطی و غیرخطی می‌رسد. نتایج نشان می‌دهند استفاده از کاهش ویژگی برای کاهش بار محاسباتی و افزایش دقت طبقه‌بندی ضروری است.

جدول ۴- دقت طبقه‌بندی برای مقادیر مختلف SNR

SNR (dB)	فاقد نویز	۲۵	۲۰	۱۵	۱۰
آسیب خطی	٪۱۰۰	۹۶٪/۸۹	۹۵٪/۵۶	۹۲٪/۲۲	۸۶٪/۸۹
آسیب غیرخطی	٪۱۰۰	۹۶٪/۴۵	۹۴٪/۶۷	۹۲٪/۳۱	۸۵٪/۸۰

۴-۴- بررسی دقت انواع ویژگی

در این بخش به بررسی دقت انواع ویژگی‌های استخراج شده بر دقت تشخیص انواع آسیب سازه‌ای می‌پردازیم. جدول ۵ دقت هر مجموعه از ویژگی‌های زمان - فرکانس و زمانی را در تشخیص آسیب‌های سازه‌ای نمایش می‌دهد. مشاهده می‌شود که ویژگی‌های زمان - فرکانس به تنهایی دقت بالاتری نسبت به ویژگی‌های زمانی در

¹ Signal-to-noise ratio (SNR)

² Additive white Gaussian noise (AWGN)

۱۲۸ تا ۲۰۴۸، دقت طبقه‌بندی افزایش قابل ملاحظه‌ای دارد ولی با افزایش تعداد نمونه‌ها از ۲۰۴۸ به ۸۱۹۲ تاثیر ملموسی بر دقت طبقه‌بندی ندارد. همچنین افزایش تعداد توابع حالت ضمنی از ۱ تا ۸، دقت تشخیص را به صورت چشم‌گیری افزایش می‌دهد ولی بعد از آن، افزایش ملموسی مشاهده نمی‌شود. نتایج نشان دادند که روش پیشنهادی مقاومت خوبی در برابر نویز از خود نشان می‌دهد و استفاده از KPCA برای کاهش ویژگی، باعث بهبود دقت طبقه‌بندی می‌شود.

۶- مراجع

- [1] Amezquita-Sanchez JP, Adeli H. Nonlinear Measurements for Feature Extraction in Structural Health Monitoring. Scientia Iranica. 2019; 26:3051-3059.
- [2] GFSirca Jr, Adeli H. Infrared Thermography for Detecting Defects in Concrete Structures. Journal of Civil Engineering and Management. 2018; 24:508-515, 2018.
- [3] Perez-Ramirez CA, Amezquita-Sanchez JP, Adeli H, Valtierra-Rodriguez M, Camarena-Martinez D, Romero-Troncoso RJ. New Methodology For Modal Parameters Identification of Smart Civil Structures Using Ambient Vibrations and Synchrosqueezed Wavelet Transform. Engineering Applications of Artificial Intelligence. 2016; 48:1-12.
- [4] Ghaedi K, Gordan M, Ismail Z, Hashim H, Talebkah M. A Literature Review on the Development of Remote Sensing in Damage Detection of Civil Structures. Journal of Engineering Research and Reports. 2021; 20:39-56.
- [5] Jauhiainen J, Pour-Ghaz M, Valkonen T, Seppänen A. Nonplanar Sensing Skins for Structural Health Monitoring Based on Electrical Resistance Tomography. Computer-Aided Civil and Infrastructure Engineering. 2021; 36:1488-1507.
- [6] Hou Z, Hera A, Noori M. Health Assessment of Engineered Structures: Bridges, Buildings and Other Infrastructures. World Scientific; 2013.
- [7] Gharehbaghi VR, Kalbkhani H, Noroozinejad Farsangi E, Yang T, Mirjalili S. A Data-Driven Approach for Linear and Nonlinear Damage Detection Using Variational Mode Decomposition and GARCH Model. Engineering With Computers. 2023; 39:2017-2034.
- [8] Monavari B, Chan TH, Nguyen A, Thambiratnam DP. Structural Deterioration Detection Using Enhanced Autoregressive Residuals. International Journal of Structural Stability and Dynamics. 2018; 18:1850160.
- [9] Gul M, Catbas FN, Georgiopoulos M. Application of pattern recognition techniques to identify structural change in a laboratory specimen. In Conference of Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems, 2007.
- [10] Das S, Saha P, Patro S. Vibration-Based Damage Detection Techniques Used For Health Monitoring of Structures: a Review. Journal of Civil Structural Health Monitoring. 2016; 6:477-507.
- [11] Gharehbaghi VR, Nguyen A, Farsangi EN, Yang T. Supervised Damage and Deterioration Detection in Building Structures Using An Enhanced Autoregressive Time-Series Approach. Journal of Building Engineering. 2020; 30:101292.
- [12] Farrar CR, Duffey TA, Doebling SW, Nix DA. A Statistical Pattern Recognition Paradigm For Vibration-Based Structural Health Monitoring. Structural Health Monitoring. 1999; 2000:764-773.
- [13] Melhem H, Kim H. Damage Detection in Concrete by Fourier and Wavelet Analyses. Journal of Engineering Mechanics. 2003; 129:571-577.
- [14] Ngo NK, Nguyen TQ, Vu TV, Nguyen-Xuan H. A Fast Fourier Transform-Based Correlation Coefficient Approach for Structural Damage Diagnosis. Structural Health Monitoring. 2021, 20:2360-2375.
- [15] Noori M, Wang H, Altabay WA, Silik AI. A Modified Wavelet Energy Rate-Based Damage Identification

تشخیص آسیب‌های سازه‌ای دارند، ولی همانطور که در بخش‌های قبل بیان شد، ترکیب هر دو دسته ویژگی به دقت طبقه‌بندی بالاتری می‌رسد.

جدول ۵- تاثیر انواع ویژگی‌ها بر دقت طبقه‌بندی

نوع ویژگی	زمانی	زمان - فرکانس	ترکیب ویژگی‌ها
آسیب خطی	۸۱٪/۷۷	۹۲٪/۶۷	٪۱۰۰
آسیب غیرخطی	۷۹٪/۷۲	۹۱٪/۷۲	٪۱۰۰

۵-۴- تاثیر ساختار شبکه‌های عمیق

جدول ۶ دقت تشخیص آسیب‌های خطی و غیرخطی را به ازای ساختارهای متفاوت شبکه‌های CNN و LSTM را نشان می‌دهد. برای شبکه CNN، ساختارهای AlexNet, LeNet, VGG-16, VGG-19 و MobileNet در نظر گرفته شد. همچنین برای شبکه LSTM یک لایه مخفی در نظر گرفته شد و تعداد گره‌های لایه مخفی برابر ۱۰، ۲۵، ۵۰ و ۷۵ در نظر گرفته شد. نتایج به دست آمده نشان دادند که شبکه MobileNet به همراه شبکه LSTM با ۵۰ و ۷۵ گره به بیشترین دقت طبقه‌بندی می‌رسد. چون شبکه LSTM با ۵۰ گره پیچیدگی محاسباتی کمتری دارد، شبکه‌های MobileNet و LSTM با ۵۰ گره برای استخراج ویژگی‌های عمیق استفاده شدند.

جدول ۶- تاثیر ساختار شبکه‌های عمیق بر دقت طبقه‌بندی. اعداد داخل پرانتز بیانگر دقت تشخیص آسیب غیرخطی هستند.

ساختار CNN	تعداد گره‌های لایه مخفی LSTM			
	۷۵	۵۰	۲۵	۱۰
LeNet	۸۲٪/۶۷ (۸۰٪/۴۷)	۷۹٪/۱۱ (۷۸٪/۶۹)	۷۶٪/۶۷ (۷۵٪/۷۴)	۷۵٪/۷۸ (۷۳٪/۹۶)
AlexNet	۸۶٪/۲۲ (۸۴٪/۰۲)	۸۲٪/۴۴ (۸۳٪/۲۵)	۸۱٪/۷۸ (۸۱٪/۰۷)	۷۹٪/۷۸ (۷۸٪/۱۱)
VGG-16	۹۲٪/۸۹ (۸۹٪/۹۴)	۸۹٪/۵۶ (۸۸٪/۱۶)	۸۹٪/۱۱ (۸۶٪/۹۸)	۸۵٪/۳۳ (۸۴٪/۰۲)
VGG-19	۹۶٪/۶۷ (۹۵٪/۲۷)	۹۴٪/۸۹ (۹۳٪/۴۹)	۹۳٪/۳۳ (۹۲٪/۳۱)	۹۱٪/۳۳ (۸۹٪/۹۴)
MobileNet	٪۱۰۰ (٪۱۰۰)	٪۱۰۰ (٪۱۰۰)	۹۷٪/۳۳ (۹۷٪/۰۴)	۹۴٪/۸۸ (۹۴٪/۰۸)

۵- جمع‌بندی

با توجه به ضرورت بررسی سلامت و استحکام سازه‌ها، در این مقاله روش جدیدی بر مبنای یادگیری ماشین برای SHM ارائه شد. با توجه به ماهیت غیرخطی و غیرایستایی، سیگنال‌های ذخیره‌شده، از تبدیل موجک گسسته برای استخراج محتوای زمان - فرکانس و از تجزیه حالت تجربی برای استخراج توابع حالت ضمنی استفاده شد. در ادامه با توجه به پیچیدگی سیگنال‌ها در خرابی‌ها، به‌ویژه خرابی غیرخطی، ویژگی‌های عمیق از محتوای زمان - فرکانس و توابع حالت ضمنی به ترتیب با استفاده از شبکه عصبی تلفیقی و شبکه حافظه طولانی کوتاه مدت استخراج شدند. تعداد ویژگی‌های عمیق زیاد بوده و همبستگی بالایی با یکدیگر دارند، این رو با استفاده از KPCA تعداد ویژگی‌ها کاهش یافت و در نهایت با استفاده از SVM بهینه‌شده، طبقه‌بندی انجام شد. نتایج به دست آمده نشان دادند که با افزایش تعداد نمونه‌ها از

- Method for Steel Bridges. *Scientia Iranica*. 2018; 25:3210-3230.
- [16] Zhao Y, Noori M, Altabey WA, Beheshti-Aval SB. Mode Shape-Based Damage Identification for a Reinforced Concrete Beam Using Wavelet Coefficient Differences and Multiresolution Analysis. *Structural Control and Health Monitoring*. 2018; 25:e2041.
- [17] Haq M, Bhalla S, Naqvi T. Fatigue Damage Monitoring of Reinforced Concrete Frames Using Wavelet Transform Energy of PZT-Based Admittance Signals. *Measurement*. 2020; 164:108033.
- [18] Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng Q, Yen NC, Tung CC, Liu HH. The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-stationary Time Series Analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*. 1998; 454:903-995.
- [19] Roveri N, Carcaterra A. Damage Detection in Structures Under Traveling Loads by Hilbert-Huang Transform. *Mechanical Systems and Signal Processing*. 2012; 28:128-144.
- [20] Amezcuita-Sanchez JP, Park HS, Adeli H. A Novel Methodology for Modal Parameters Identification of Large Smart Structures Using MUSIC, Empirical Wavelet Transform, and Hilbert Transform. *Engineering Structures*. 2017; 147:148-159.
- [21] Yang J, Li P, Yang Y, Xu D. An Improved EMD Method for Modal Identification and a Combined Static-Dynamic Method for Damage Detection. *Journal of Sound and Vibration*. 2018; 420:242-260.
- [22] Zhao, G., Zhang, L., Wang, B., Hao, W., and Luo, Y., "HHT-based AE characteristics of 3D braiding composite shafts," *Polymer Testing*, vol. 79, p. 106019, 2019.
- [23] Babajanian Bisheh, H., Ghodrati Amiri, G., Nekooei, M., and Darvishan, E., "Damage detection of a cable-stayed bridge using feature extraction and selection methods," *Structure and Infrastructure Engineering*, vol. 15, no. 9, pp. 1165-1177, 2019.
- [24] Yuan J, Ren Q, Jia C, Zhang J, Fu J, Li M. Automated Pixel-Level Crack Detection and Quantification Using Deep Convolutional Neural Networks for Structural Condition Assessment. *Structures*. 2014; 59:105780.
- [25] Yanez-Borjas JJ, Valtierra-Rodriguez M, Machorro-Lopez JM, Camarena-Martinez D, Amezcuita-Sanchez JP. Convolutional Neural Network-Based Methodology for Detecting, Locating and Quantifying Corrosion Damage in a Truss-Type Bridge Through the Autocorrelation of Vibration Signals. *Arabian Journal for Science and Engineering*. 2023; 48:1119-1141.
- [26] Figueiredo E, Park G, Figueiras J, Farrar C, Worden K. Structural Health Monitoring Algorithm Comparisons Using Standard Data Sets. Los Alamos National Lab. (LANL), United States, 2009.
- [27] Burges CJ. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*. 1998; 2:121-167.