

عیب‌یابی سازه جک‌تی فراساحلی با استفاده از پاسخ‌های دینامیکی بر پایه مدل شبیه‌سازی شده، حالت سالم مدل واقعی و شبکه عصبی خود رهنگار عمیق

زهره موسوی^۱، سینا ورهرام^۱، میر محمد اتفاق^{۲*}، مرتضی همایون صادقی^۱، سید ناصر رضوی^۲

۱- دانشکده مهندسی مکانیک، دانشگاه تبریز، تبریز، ایران.

۲- دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۹/۰۳/۱۸

بازنگری: ۱۳۹۹/۰۷/۱۶

پذیرش: ۱۳۹۹/۰۸/۰۴

ارائه آنلاین: ۱۳۹۹/۰۸/۲۸

کلمات کلیدی:

پایش وضعیت
سازه جک‌تی فراساحلی
به‌روزرسانی مدل
شبکه عصبی عمیق

خلاصه: از آنجایی که هزینه نگهداری و تعمیر سیستم‌های مکانیکی اعم از سازه‌ها و ماشین‌های دوار بسیار بالاست، یکی از راه‌های کاهش این هزینه‌ها، در نظر گرفتن تدابیری جهت بررسی عیوب در این سیستم‌ها قبل از هر نوع کار عملی است. در این مطالعه روش جدیدی برای عیب‌یابی سازه جک‌تی فراساحلی در حضور عدم قطعیت‌های مختلف مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری و نویزهای محیطی بر پایه مدل شبیه‌سازی شده و حالت سالم مدل واقعی ارائه شده است. در روش پیشنهادی، داده‌های سازه سالم واقعی برای به‌روزرسانی پارامترهای مدل شبیه‌سازی شده استفاده شده‌اند. برخی از بخش‌های سیگنال که مربوط به ذات سیستم نیستند، با استفاده از روش تجزیه مود تجربی دسته‌ای کامل حذف شده‌اند. داده‌های فرکانسی با استفاده از روش تجزیه حوزه فرکانس از سیگنال‌های ارتعاشی استخراج شده‌اند. یک شبکه عصبی خود رهنگار عمیق، به منظور یادگیری ویژگی‌های حساس به عیب از داده‌های فرکانسی و عیب‌یابی سازه طراحی شده است. به منظور آموزش شبکه عصبی عمیق پیشنهادی، از داده‌های فرکانسی مدل شبیه‌سازی شده و حالت سالم مدل واقعی استفاده شده است. پس از آن، داده‌های فرکانسی سازه واقعی برای ارزیابی شبکه عصبی عمیق پیشنهادی استفاده شده است. نتایج حاصله نشان می‌دهد که استفاده از روش پیشنهادی برای عیب‌یابی سازه جک‌تی فراساحلی صحت بالاتری نسبت به سایر روش‌های مقایسه‌ای دارد.

۱- مقدمه

در صنعت، سیستم‌های مکانیکی و سازه‌ها به‌عنوان تجهیزات اساسی و مهم به شمار می‌روند و به‌طور گسترده مورد استفاده قرار می‌گیرند؛ بنابراین پایش وضعیت^۱ آن‌ها امری ضروری است. علاوه بر این پایش وضعیت سازه‌های فراساحلی که به‌طور مداوم در معرض عیوب مختلف در نتیجه تغییرات نیروهای محیطی هستند، از اهمیت بالاتری برخوردار است. سازه‌های جک‌تی فراساحلی متداول‌ترین نوع سازه‌های دریایی هستند و نقش بسزایی در صنایع نفت و گاز در آب‌های کم‌عمق و متوسط دارند. علاوه بر این، آن‌ها به‌عنوان زیر ساختارهای جک‌تی برای توربین‌های بادی فراساحلی^۲ در آب‌های عمیق (۶۰-۳۰ متر) مورد استفاده قرار می‌گیرند. عیب‌یابی به‌موقع سازه جک‌تی فراساحلی به‌منظور شناسایی عیوب احتمالی و تضمین ایمنی آن امری لازم است، اما انجام تست‌های تعمیر و نگهداری در شرایط عملیاتی

پرهزینه و حتی گاهی غیرممکن است؛ بنابراین، استفاده از روش‌های مناسب و قدرتمند برای شناسایی عیوب سازه در جلوگیری از توقف کامل و بروز خسارات جانی و مالی بسیار کارآمد است.

در سال‌های اخیر یادگیری ماشین به‌عنوان ابزاری مناسب برای انتخاب ویژگی‌ها به‌منظور عیب‌یابی سیستم‌های مکانیکی مورد توجه قرار گرفته است. شبکه‌های عصبی مصنوعی^۳ مجموعه‌ای از الگوریتم‌ها هستند که در یادگیری ماشین برای مدل‌سازی داده‌ها استفاده می‌شوند. استفاده از شبکه‌های عصبی برای تشخیص عیوب، روش‌های جدیدی را برای پایش وضعیت فراهم می‌کند. شبکه‌های عصبی به دو دسته کلی تقسیم می‌شوند؛ شبکه‌های عصبی کم‌عمق^۴ و شبکه‌های عصبی عمیق^۵. شبکه‌های عصبی عمیق به‌طور گسترده و با موفقیت‌های زیادی در پردازش تصویر و سیگنال‌ها در حوزه زمان و فرکانس مورد استفاده قرار گرفته‌اند [۱-۳]. هدف

1 Condition Monitoring

2 Offshore Wind Turbines

* نویسنده عهده‌دار مکاتبات: ettefagh@tabrizu.ac.ir



الگوریتم‌های یادگیری عمیق کشف چندین سطح از بازنمایی توزیع شده از داده‌های ورودی است. برخی از مزایای الگوریتم‌های یادگیری عمیق نسبت به الگوریتم‌های کم‌عمق عبارت‌اند از؛ در این الگوریتم‌ها به صورت خودکار استخراج ویژگی‌ها و کاهش آن‌ها صورت می‌پذیرد، همچنین دقت این الگوریتم‌ها نسبت به الگوریتم‌های کم‌عمق بیشتر است. در مقابل این مزایا، این الگوریتم‌ها معایبی نیز دارند که برخی از این معایب عبارت‌اند از؛ این الگوریتم‌ها نیازمند مجموعه داده‌های آموزشی نسبتاً زیادی هستند که جمع‌آوری داده‌های حجیم امری زمان‌بر است. معماری‌های مختلف یادگیری عمیق، مانند شبکه‌های عصبی عمیق کانولوشنال^۱، شبکه‌های باور عمیق^۲ و شبکه‌های خود رمزنگار^۳ برای کاهش ابعاد داده‌های ورودی و استخراج ویژگی‌های مطلوب استفاده می‌شوند [۴]. یک مرور کلی از کاربرد شبکه‌های عصبی عمیق برای پایش وضعیت سیستم‌های مکانیکی در مرجع [۵] ارائه شده است.

داده‌های سیستم‌های مکانیکی را می‌توان به دو دسته کلی مصنوعی و واقعی که بر پایه الگوریتم‌های داده محور^۴ هستند، تقسیم کرد. داده‌های واقعی را می‌توان از سیستم‌های واقعی یا سیستم‌های آزمایشگاهی به دست آورد که به دست آوردن این داده‌ها به خصوص در حالت‌های معیوب، بسیار پرهزینه است. در مقابل، به دست آوردن داده‌های مصنوعی آسان‌تر و کم‌هزینه‌تر از داده‌های واقعی است، زیرا می‌توان با استفاده از مدل‌های شبیه‌سازی شده این داده‌ها را استخراج کرد. الگوریتم‌های داده محور به طور مؤثر در تشخیص عیوب سیستم مکانیکی موفق بوده‌اند. بسیاری از الگوریتم‌های داده محور مبتنی بر الگوریتم‌های یادگیری ماشین هستند. احمد و همکاران [۵] یک روش عیب‌یابی هوشمند را برای تشخیص عیوب یاتاقان‌ها از اندازه‌گیری‌های فشرده شده بر پایه حسگری فشرده مورد بررسی قرار دادند. در این مطالعه، تأثیرات یک شبکه عصبی خود رمزنگار بر عملکرد عیب‌یابی بررسی شد. نتایج نشان داد که این روش در مقایسه با روش‌های موجود، قادر به دست‌یابی به سطح بالاتری از صحت برای تشخیص عیوب است. ژانگ و همکاران [۶] روش جدیدی را بر اساس یادگیری عمیق برای تشخیص عیوب بیرینگ در محیط نویزی و تحت شرایط بارگذاری مختلف ارائه دادند. در این روش سیگنال‌های زمانی خام بدون هیچ‌گونه پیش‌پردازشی به عنوان ورودی به شبکه عمیق داده شدند. نتایج نشان داد که روش ارائه شده، توانایی

- 1 Convolution Deep Neural Networks (CDNN)
- 2 Deep Belief Networks (DBN)
- 3 Deep Auto-Encoders (DAE)
- 4 Data-driven algorithms

شناسایی عیوب بیرینگ در محیط نویزی و بارگذاری‌های مختلف را دارد. جینگ و همکاران [۷] روشی را برای شناسایی عیوب گیربکس بر پایه یادگیری ویژگی با استفاده از شبکه‌های عمیق ارائه دادند. در این مطالعه یک شبکه کانولوشنال عمیق برای یادگیری ویژگی‌ها به طور مستقیم از داده‌های فرکانسی سیگنال‌های ارتعاشی ارائه شد و عملکرد آن با یادگیری ویژگی‌ها از داده‌های زمانی خام و داده‌های ترکیبی زمان و فرکانس مقایسه شد. نتایج نشان داد که روش ذکر شده قادر به یادگیری ویژگی‌های مطلوب از داده‌های فرکانسی و دستیابی به دقت بالاتر از سایر روش‌های مقایسه‌ای است. از آنجاکه جمع‌آوری داده‌های عیوب واقعی بسیار دشوار و حتی غیرممکن است و به طور کلی فقط داده‌های حالت سالم در اختیار است، جای تعجب ندارد که استفاده از روش‌های مبتنی بر الگوریتم‌های داده محور به سرعت در محیط‌های صنعتی از بین می‌روند. یک راه‌حل برای حل این مسئله، استفاده از داده‌های عیوب مصنوعی به جای واقعی است [۸]. بر این اساس، استفاده از رویکرد مدل شبیه‌سازی شده و حالت سالم مدل واقعی می‌تواند یک راه‌حل مفید باشد.

گو و همکاران [۹] رویکردی را برای تشخیص عیوب سازه‌های جکتی فراساحلی با استفاده از آنالیز مودال و شبکه‌های عصبی پیشنهاد کردند. در این مطالعه، مدل المان محدود^۵ و شاخص‌های تشخیص عیب برای ترکیب ویژگی‌های مودال و فرکانس‌های طبیعی پیشنهاد شدند. در نهایت از این داده‌ها برای آموزش شبکه‌های عصبی و تشخیص عیوب استفاده شد که نتایج حاصل از محاسبات نشان داد که روش ارائه شده کاملاً دقیق است. لیو و همکاران [۱۰] روش جدیدی را مبتنی بر آنالیز مودال برای تشخیص عیوب سازه‌های جکتی فراساحلی ارائه دادند. در پژوهش ارائه شده، مدل المان محدود شبیه‌سازی شده برای حالت‌های مختلف عیب در حضور نویزها و عدم قطعیت‌های مختلف توسعه داده شد. این مطالعه دقت و اثربخشی روش ارائه شده را در حضور نویزها و عدم قطعیت‌های مختلف نشان داد. هنگامی که از داده‌های شبیه‌سازی شده به جای داده‌های واقعی استفاده می‌شود، به علت عدم قطعیت‌های مختلف تفاوت‌هایی بین ویژگی‌های دینامیکی آن‌ها ظاهر می‌شود؛ بنابراین، به روزرسانی مدل شبیه‌سازی شده بر اساس داده‌های حالت سالم واقعی و استخراج ویژگی‌های حساس به عیب و مشترک بین داده‌های شبیه‌سازی شده و واقعی ضروری است. با این حال، استخراج این ویژگی‌ها با روش‌های استخراج ویژگی سنتی به خوبی امکان‌پذیر نیست [۸].

مجتهدی و همکاران [۱۱] یک روش عیب‌یابی را برای سازه جکتی

5 Finite Element (FE) model

انجام می‌شود و سپس طبقه‌بندی با آموزش مجدد^۶ با استفاده از الگوریتم پس انتشار خطا^۷ برای تنظیم دقیق^۸ ابر پارامترهای شبکه عمیق پیشنهادی انجام می‌شود (مرحله دوم). در محیط‌های صنعتی جمع‌آوری داده‌های معیوب دشوار و حتی غیرممکن است و به‌طور کلی فقط داده حالت سالم در اختیار است، بنابراین ارائه‌دادن روشی برای عیب‌یابی سیستم‌های مکانیکی بر پایه عیب‌های شبیه‌سازی شده و داده حالت سالم مدل واقعی، لازم و ضروری است. بر این اساس، سومین هدف این مقاله آموزش‌دادن شبکه عمیق پیشنهادی بر اساس داده‌های فرکانسی مدل شبیه‌سازی شده و حالت سالم واقعی است و سپس ارزیابی شبکه عمیق با داده‌های فرکانسی مدل واقعی است. در روش پیشنهادی، به‌روزرسانی پارامترهای مدل شبیه‌سازی شده بر پایه داده‌های سالم مدل واقعی انجام گرفته است. برخی از بخش‌های سیگنال‌ها که مربوط به ذات سیستم نیستند با استفاده از روش تجزیه مود تجربی دسته‌ای کامل^۹ حذف شده‌اند. داده‌های فرکانسی با استفاده از روش تجزیه حوزه فرکانس^{۱۰} از سیگنال‌های ارتعاشی به‌دست آمده‌اند. برای ارزیابی روش پیشنهادی از سازه جکتی فراساحلی در محیط آزمایشگاهی به‌عنوان یک مطالعه موردی استفاده شده‌است.

ادامه مقاله به‌صورت زیر تدوین شده‌است؛ در بخش ۲ مواد و روش‌ها بررسی خواهند شد. در بخش ۳، الگوریتم پیشنهادی مورد استفاده در این مقاله ارائه داده می‌شود. در بخش ۴ نتایج شبیه‌سازی و مقایسه با روش‌های دیگر مورد بحث قرار می‌گیرد؛ درنهایت، بخش ۵ مربوط به نتیجه‌گیری است.

۲- مواد و روش‌ها

در این بخش در ابتدا مدل‌سازی دینامیکی و آزمایشگاهی سازه جکتی فراساحلی، به‌عنوان یک مطالعه موردی، شرح داده می‌شود. پس از آن روش‌های تجزیه مود تجربی دسته‌ای کامل، تجزیه حوزه فرکانس و شبکه عصبی عمیق ارائه خواهند شد.

۲-۱- مدل‌سازی المان محدود سازه جکتی فراساحلی



با در نظر گرفتن تغییر شکل‌های کوچک و رفتار خطی سیستم، یک مدل سه‌بعدی المان محدود اولیه از سازه فلزی جکتی فراساحلی با استفاده از نرم‌افزار آباکوس ایجاد شده است. اصطلاح "اولیه" نشان می‌دهد که مدل

فراساحلی با استفاده از مدل به‌روزرسانی شده و منطق فازی ارائه دادند. در این مطالعه، یک مدل پایه المان محدود بر اساس مدل آزمایشگاهی سازه جکتی فراساحلی باهدف پایش وضعیت طولانی‌مدت این نوع سازه‌ها ایجاد شد. اثربخشی روش ارائه‌شده برای پایش وضعیت سازه آزمایشگاهی با استفاده از ایجاد سناریوهای عیوب مختلف در مدل المان محدود، مورد بررسی قرار گرفت. دینگ و همکاران [۱۲]، رویکرد جدیدی را بر پایه الگوریتم خوشه‌بندی برای تشخیص عیوب سازه‌ای با خطاهای نامشخص ناشی از عدم قطعیت‌های مختلف ارائه دادند. در این مطالعه، تابع هدف بر اساس داده‌های مودال توسعه یافت. مطالعه عددی بر روی سازه خرپا شکل و همچنین مطالعه تجربی بر روی سازه قاب فلزی آزمایشگاهی به‌منظور ارزیابی بیشتر روش پیشنهادی انجام شد. نتایج تحقیقات عددی و تجربی با نتایج چند الگوریتم تکاملی مقایسه شد که نشان داد که این روش در شناسایی عیوب سازه‌ای نتایج بهتری نسبت به روش‌های مقایسه‌ای دارد. فلاحیان و همکاران [۱۳]، یک روش طبقه‌بندی ترکیبی^۱ بر پایه کدینگ تُنک^۲ و شبکه عصبی عمیق، برای ارزیابی عیوب سازه‌ای در دماهای مختلف ارائه دادند. این روش با استفاده از یک مدل عددی پل و داده‌های تجربی آن تأیید شد. نتایج به‌دست آمده، اثربخشی روش بیان شده در شرایط مختلف دمایی را نشان داد.

در این مقاله روش جدیدی برای پایش وضعیت سیستم‌های مکانیکی ارائه شده‌است. اولین هدف این مقاله ارائه‌دادن روشی برای عیب‌یابی سیستم‌های مکانیکی در حضور عدم قطعیت‌های مختلف مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری و نویزهای محیطی است. همان‌طور که بیان شد یادگیری عمیق به‌طور گسترده و با موفقیت‌های زیادی در پردازش تصویر و سیگنال‌ها در حوزه زمان و فرکانس مورد استفاده قرار گرفته‌است. یکی از مزایای استفاده از یادگیری عمیق این است که در حضور عدم قطعیت‌های مختلف می‌تواند ویژگی‌های حساس به عیب را از داده‌ها بیاموزد. بر این اساس، دومین هدف این مقاله طراحی یک شبکه خود رمزنگار عمیق، به‌منظور یادگیری ویژگی‌های حساس به عیب از داده خام فرکانسی و عیب‌یابی سیستم مکانیکی واقعی در حضور عدم قطعیت‌های مختلف است. در شبکه پیشنهادی، طبقه‌بندی پیش آموزش^۳ با روش بدون نظارت^۴ و با استفاده از خود رمزنگارهای عمیق و لایه سافت مکس^۵ (مرحله اول)

6 Re-training classification
7 Back-Propagation (BP) algorithm
8 Fine tuning
9 Complete Ensemble Empirical Mode Decomposition (CEEMD)
10 Frequency Domain Decomposition (FDD) method

1 Ensemble classification method
2 Sparse coding
3 Pre-training classification
4 Unsupervised
5 Softmax layer



شکل ۲. مدل سازه جکته فراساحلی در مقیاس آزمایشگاهی در حالت سالم

Fig. 2. The laboratory offshore jacket model in intact state.

شکل ۱. مدل المان محدود سازه جکته فراساحلی در حالت سالم.

Fig. 1. Finite element model of the offshore jacket structure in intact state.


(شکل ۲) که در آزمایشگاه آنالیز مودال و ارتعاشات دانشگاه تبریز طراحی و نصب شده است، استفاده می‌شود. تجهیزات آزمایشگاهی شامل یک سیستم پردازشگر داده^۱، یک لرزاننده^۲، ۱۲ شتاب‌سنج^۳ با حساسیت‌های مختلف، یک نیروسنج^۴، یک لپ‌تاپ، یک اسیلوسکوپ^۵، یک آمپلی‌فایر^۶ و کابل‌های انتقال است. ۱۲ شتاب‌سنج که شامل سه مجموعه از چهار شتاب‌سنج هستند برای استخراج پاسخ‌های دینامیکی، بر روی سه طبقه مختلف سازه نصب شده‌اند. دو شتاب‌سنج در جهت x و دو شتاب‌سنج دیگر در جهت y بر روی هر طبقه نصب شده‌اند. شکل ۳ موقعیت ۱۲ شتاب‌سنج نصب شده بر روی ۴ ستون سازه را نشان می‌دهد؛ شتاب‌سنج‌های $b1$ و $b3$ و شتاب‌سنج‌های $b2$ و $b4$ به ترتیب در جهت‌های x و y نصب شده‌اند. شتاب‌سنج‌های مشابه در بالا و پایین آن به همان روش نصب می‌شوند (شکل ۳). در این مطالعه، از لرزاننده برای تولید نیروی تحریک مصنوعی و از مبدل نیرو برای ثبت این نیرو استفاده می‌شود. نیروی تولید شده در لرزاننده، نویز سفید گوسین^۷ با میانگین صفر و انحراف معیار یک در محدوده فرکانسی ۰ هرتز تا ۲۰۰ هرتز

المان محدود به دلیل عدم قطعیت‌های مختلف می‌تواند دقیق نباشد؛ بنابراین، مدل اولیه مبنایی برای به‌روزرسانی پارامترهای مدل در نظر گرفته می‌شود. مدل المان محدود ایجاد شده در حالت سالم در شکل ۱ نشان داده شده است. برای تمامی اعضا، مدول اولیه یانگ (E)، ضریب پواسون (ν)، چگالی (ρ) و ضریب میرایی (ξ) به ترتیب ۲۰۰ گیگا پاسکال، ۰/۳، ۷۸۰۰ کیلوگرم بر مترمکعب و ۰/۰۱ است. اتصالات مشترک، صلب در نظر گرفته شده و شرط مرزی گیردار در قسمت زیرین سازه اعمال شده است. تمامی اعضای این مدل با المان‌های دوبعدی تیر مش‌بندی شده‌اند که امکان تغییر شکل برشی عرضی را فراهم می‌کند [۱۴]. ابعاد مدل المان محدود دقیقاً با توجه به ابعاد سازه واقعی ایجاد می‌شود (شکل ۲). ارتفاع سازه ۲ متر، ابعاد پایینی سازه ۵۷/۰ متر \times ۴۸/۰ متر و ابعاد بالایی سازه ۲/۰ متر \times ۲/۰ متر است. این سازه دارای پنج طبقه است که در تمامی طبقه‌ها از میله‌های برشی افقی و در دو طبقه میانی از میله‌های برشی مورب استفاده شده است. قطر کلیه پایه‌های اصلی ۶/۱ سانتیمتر و قطر میله‌های برشی افقی و مورب ۲/۱ سانتیمتر است.

- 1 National Instrument
- 2 Shaker
- 3 Accelerometer
- 4 Force transducer
- 5 Oscilloscope
- 6 Power amplifier
- 7 White Gaussian noise

۲-۲- مجموعه تجهیزات آزمایشگاهی سازه جکته فراساحلی

در این مطالعه از مدل سازه جکته فراساحلی در مقیاس آزمایشگاهی



شکل ۳. موقعیت و جهت شتابسنج‌های نصب‌شده بر روی ۴ ستون سازه

Fig. 3. Location and direction of mounted accelerometers on the 4 columns of the structure

آزمایش‌ها برای حالت‌های مختلف عیب که با حذف کردن میله‌های برشی مورب مختلف ایجاد می‌شوند، تکرار می‌شوند. به منظور بررسی قابلیت اطمینان‌پذیر بودن نتایج در فرآیند آزمایش‌های تجربی، در هر مرحله، آزمایش‌ها چندین مرتبه تکرار شدند؛ در نهایت به صورت تصادفی برای هر حالت، ۵ تکرار انتخاب شده و میانگین آن‌ها برای آنالیزهای بعدی مورد استفاده قرار گرفته‌است. رویکردی مشابه با مدل آزمایشگاهی، برای مدل المان محدود نیز انجام می‌شود؛ مدل المان محدود دقیقاً از همان مکان تحریک‌شده و پاسخ‌های شتاب‌سنج‌ها از ۱۲ موقعیت مختلف در جهت‌های x و y مانند مدل آزمایشگاهی استخراج می‌شوند.

۲-۳- تجزیه مود تجربی دسته‌ای کامل

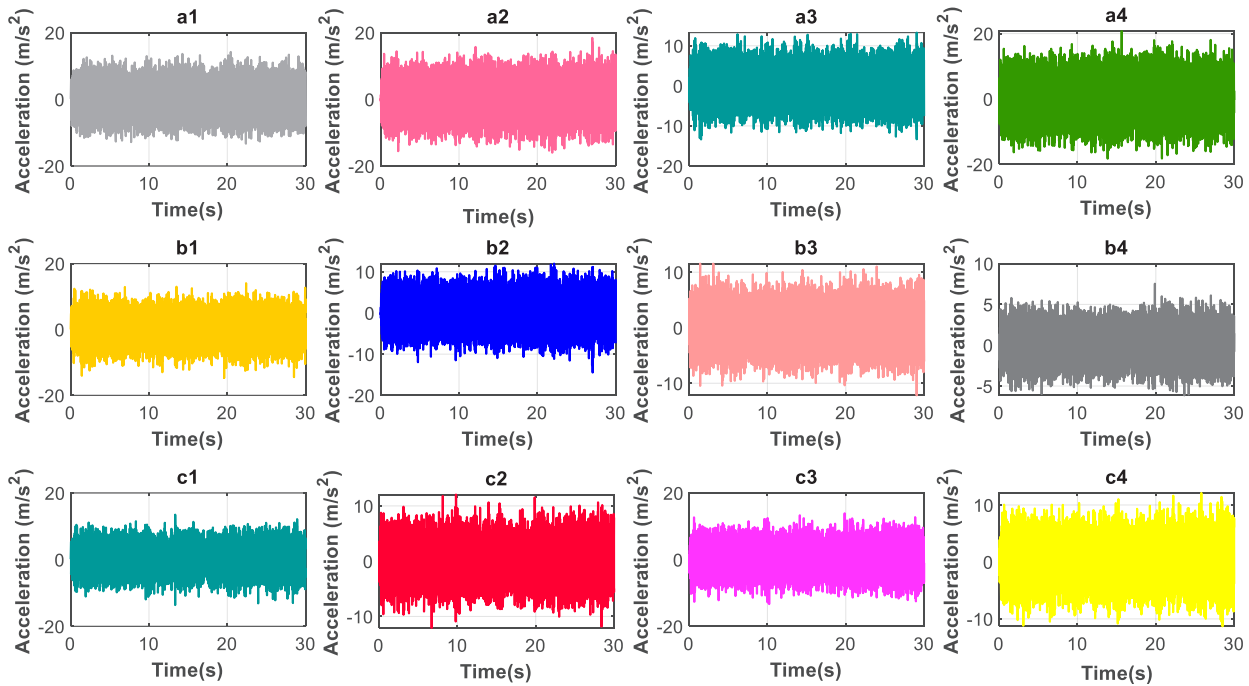
تجزیه مود تجربی دسته‌ای کامل [۱۶] یک ابزار مناسب برای تحلیل سیگنال‌های غیرخطی و غیرثابت مانند سیگنال‌های ارتعاشی است. هر سیگنال با استفاده از روش تجزیه مود تجربی دسته‌ای کامل به مجموعه‌ای از توابع مود ذاتی^۴ خود تجزیه خواهد شد. جزئیات این روش در مرجع [۱۶] ارائه شده‌است.

است که شامل تمامی فرکانس‌ها در این محدوده می‌باشد [۱۱]. لرزاننده به بخش میانی ستون I در طبقه سوم با استفاده از یک فیکسر حلقه‌ای ساخته‌شده از آلیاژ برنج و یک استینگر انعطاف‌پذیر^۱ با سختی محوری بالا^۲ که از انجام هرگونه گشتاور تحریک یا بارگیری پرخشی جلوگیری می‌کند، به سازه متصل شده‌است [۱۵]. فاصله بین نقطه تحریک و انتهای طبقه سوم ۸/۱۱ سانتیمتر است. در شکل ۴ پاسخ‌های دینامیکی استخراج‌شده با استفاده از ۱۲ شتاب‌سنج نصب‌شده بر روی سازه نشان داده شده‌است.

سازه به یک صفحه فولادی با ضخامت ۱ سانتیمتر جوش داده شده و پس از آن با یک پایه بتنی به زمین وصل شده‌است. شکل ۵ بخش‌های مختلف تجهیزات آزمایشگاهی را نشان می‌دهد. شتاب‌سنج‌ها و مبدل نیرو با کابل‌های انتقال سیگنال به سیستم پردازشگر داده وصل می‌شوند. سیگنال‌های ارتعاشی به مدت ۳۰ ثانیه با استفاده از نرم‌افزار لب ویو^۳ با فرکانس نمونه‌برداری ۲۰۰۰ هرتز ثبت می‌شوند و سپس این سیگنال‌ها وارد نرم‌افزار متلب می‌شوند تا فرآیند پردازش روی آن‌ها صورت بگیرد. در این مطالعه آزمایش‌های اولیه بر روی سازه سالم انجام می‌گیرد، پس از آن،

- 1 Flexible stingers
- 2 High axial stiffness
- 3 LabVIEW Signal Express software

4 Intrinsic Mode Functions (IMF)



شکل ۴. پاسخ‌های دینامیکی استخراج‌شده با استفاده از ۱۲ شتاب‌سنج نصب‌شده بر روی سازه

Fig. 4. Extracted dynamic responses using 12 accelerometers mounted on the structure.

مبتنی بر خود رمزنگارها، ابتدا الگوریتم خود رمزنگار [۴] چندین بار استفاده می‌شود که به آن شبکه عمیق پیش آموزش گفته می‌شود؛ در این مرحله، خروجی هر لایه ورودی لایه بعدی است. سپس شبکه عمیق به منظور نظارت^۴ بر طبقه‌بندی با الگوریتم پس انتشار خطا [۱۸] دوباره آموزش داده می‌شود. الگوریتم خود رمزنگار یک الگوریتم یادگیری بدون نظارت است که هدف خروجی آن، داده ورودی است و از الگوریتم پس انتشار خطا استفاده می‌کند [۴]. همان‌طور که در شکل ۶ نشان داده شده است، شبکه خود رمزنگار شامل دو بخش، یعنی بخش رمزنگاری^۵ و بخش رمزگشایی^۶ است که بخش رمزنگاری یک بردار ویژگی را از داده‌های ورودی تولید می‌کند و بخش رمزگشایی داده‌های ورودی را از این بردار ویژگی بازیابی می‌کند. بخش رمزنگاری یک عملگر استخراج ویژگی است که یک بردار ویژگی را از ورودی x_i محاسبه می‌کند و می‌تواند به صورت زیر محاسبه شود:

$$h(x_i) = f_{\theta}(x_i) \quad (1)$$

- 4 Supervised
- 5 Encoder
- 6 Decoder

۲-۴- روش تجزیه حوزه فرکانس

روش تجزیه حوزه فرکانس، یک روش آنالیز مودال بر مبنای فقط خروجی^۱ است که برای شناسایی پارامترهای مودال سازه‌ها و سیستم‌های مکانیکی استفاده می‌شود [۱۷]. در این روش، فقط پاسخ‌های خروجی اندازه‌گیری شده از سیستم‌های مکانیکی برای تجزیه و تحلیل مورد نیاز است؛ بنابراین، نیازی به استفاده از نیروهای تحریک در این روش نیست. در این روش ابتدا ماتریس چگالی طیفی توان^۲ پاسخ‌های دینامیکی محاسبه شده و سپس روش تجزیه مقادیر تکین^۳ بر روی آن‌ها اعمال می‌شود و به کمک آن، مقادیر فرکانس‌های طبیعی و شکل مودها به دست می‌آیند. با استخراج پیک‌های نمودار مقادیر تکین، فرکانس‌های طبیعی مرتبط با سیستم مکانیکی حاصل می‌شوند [۱۷]. جزئیات این روش در مرجع [۱۷] ارائه شده است.

۲-۵- شبکه عصبی عمیق

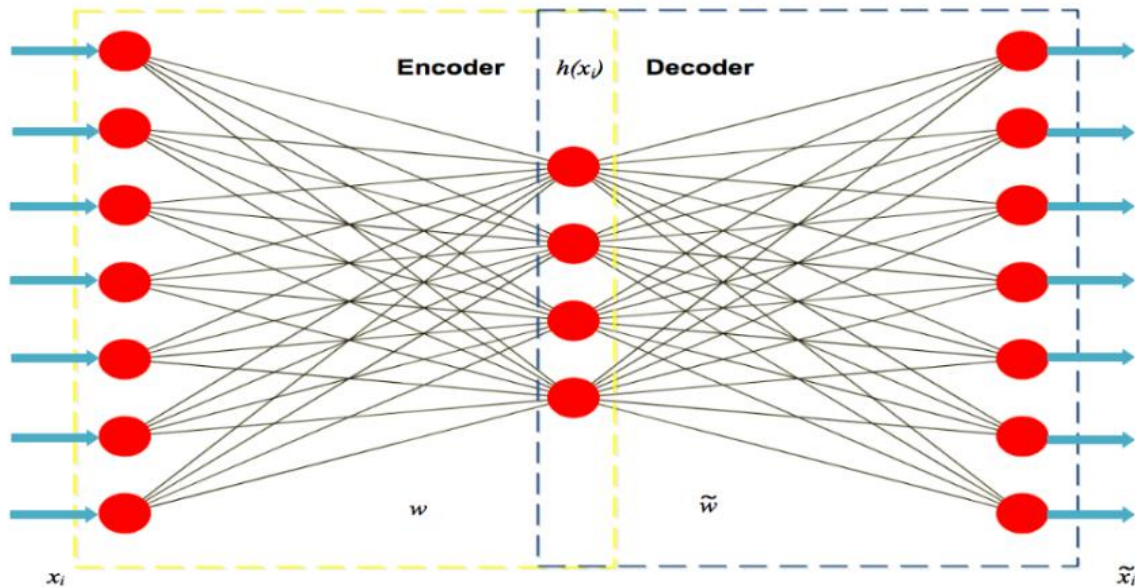
در سال‌های اخیر، شبکه‌های عصبی عمیق نسبت به سایر روش‌های یادگیری ماشین، توجه بیشتری را به خود جلب کرده‌اند. در شبکه‌های عمیق

- 1 Output-only Modal Analysis (OMA) method
- 2 Power Spectral Density (PSD) matrix
- 3 Singular-value decomposition (SVD)



شکل ۵. بخش‌های مختلف تجهیزات آزمایشگاهی.

Fig. 5. Different parts of experimental equipment.



شکل ۶. معماری شبکه خود رمزنگار.

Fig. 6. Auto-Encoder network architecture.

$$R(d) = \begin{cases} d & \text{if } d > 0 \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

با در نظر گرفتن مجموعه آموزشی $\{x^{(1)}, c^{(1)}, \dots, x^{(m)}, c^{(m)}\}$ از نمونه‌های برچسب‌خورده m و ویژگی‌های ورودی $x^{(i)} \in R^n$ ، تخمین احتمال $P(c = k | x)$ برای هر مقدار از $k = 1$ تا K ، می‌تواند با استفاده از رگرسیون سافت مکس محاسبه شود. رگرسیون سافت مکس با چند لیبیل از $c^{(i)} \in \{1, \dots, K\}$ به صورت زیر تعریف می‌شود [۴]:

$$\sigma_{\theta}(x) = \frac{e^{(\theta^{(j)})^T x}}{\sum_{j=1}^K e^{(\theta^{(j)})^T x}} = \begin{bmatrix} P(c=1|x;\theta) \\ P(c=2|x;\theta) \\ \vdots \\ P(c=K|x;\theta) \end{bmatrix} \quad (6)$$

for $j = 1, \dots, K$; $\theta^{(j)} \in R^n$

که $\theta^{(i)}$ و K به ترتیب پارامترهای مدل رگرسیون سافت مکس و تعداد کلاس‌ها هستند. مقادیر خروجی $\sigma_{\theta}(x)$ بین صفر تا یک و جمع آن‌ها برابر یک است.

۳- الگوریتم عیب‌یابی پیشنهادی

در این بخش، روش پیشنهادی برای تشخیص عیوب سازه جکتی فراساحلی توضیح داده شده است. شکل ۷ بلوک دیاگرام روش پیشنهادی را نشان می‌دهد. جزئیات هر مرحله در بخش‌های بعدی توضیح داده شده است.

۳-۱- داده‌ها

به‌طور کلی، به منظور بررسی عملکرد روش‌های عیب‌یابی، می‌توان سناریوهای عیوب فرضی در سازه ایجاد کرد. در این مطالعه، همان‌طور که قبلاً بیان شد، سناریوهای مختلف عیب با حذف کردن میله‌های برشی مورب در سازه ایجاد می‌شوند، به گونه‌ای که سختی سازه در یک جهت خاص کاهش یابد. حذف کردن میله‌های مختلف برشی از سازه، باعث جابه‌جایی فرکانس‌ها و تغییر شکل مودها می‌شود. مطالعه حاضر بر پایه ۵ حالت مختلف

که $h(x_i)$ بردار ویژگی و f_{θ} عملگر استخراج ویژگی است. بخش رمزگشایی یک تابع بازتابی g_{θ} است که فضای ورودی را از بردار ویژگی بازسازی می‌کند به گونه‌ای که:

$$\bar{x}_i = g_{\theta}(h(x_i)) \quad (2)$$

شبکه خود رمزنگار تلاش می‌کند تقریبی را یاد بگیرد که \bar{x}_i شبیه به x_i باشد، به این معنی که سعی می‌کند به کمترین خطای بازسازی $E(x_i, \bar{x}_i)$ که اختلاف بین x_i و \bar{x}_i را اندازه‌گیری می‌کند، برسد. در واقع، شبکه خود رمزنگار به عنوان یک شبکه چند لایه پرسپترون توسعه داده شده است که انسجام و به دنبال آن غیرخطینگی را در بخش‌های رمزنگاری و رمزگشایی حفظ می‌کند:

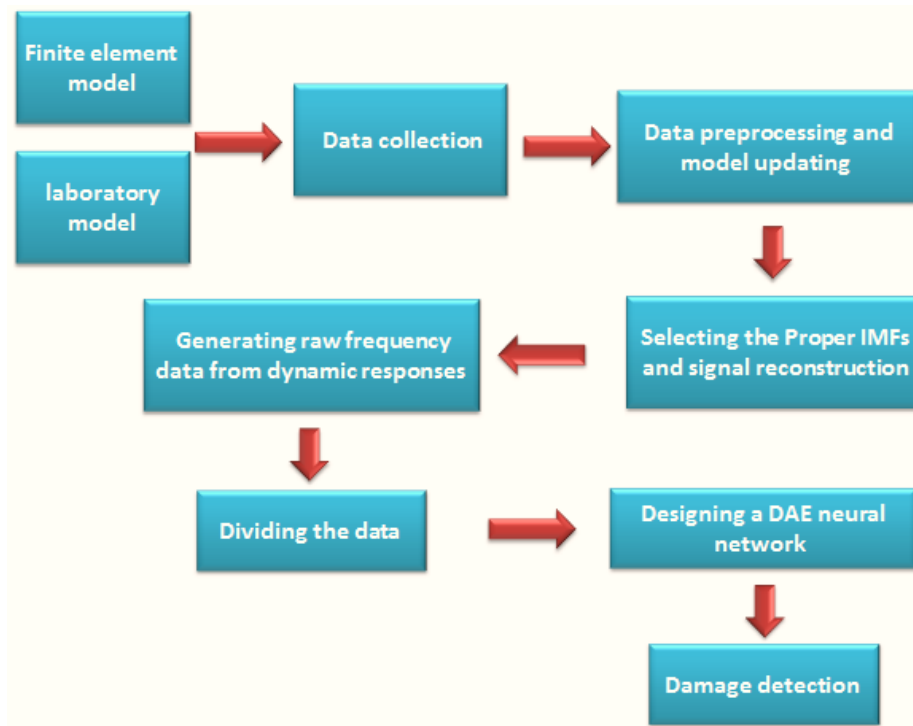
$$h(x_i) = s_f(W + b^*) \quad (3)$$

$$g_{\theta}(h(x_i)) = s_g(\bar{W} + c^*) \quad (4)$$

که s_f و s_g به ترتیب توابع فعالیت بخش‌های رمزنگاری و رمزگشایی هستند، مانند سیگموئید^۱ و رلو^۲، b^* و c^* بردارهای بایاس، \bar{W} و W ماتریس‌های وزن بخش‌های رمزنگاری و رمزگشایی هستند. به‌طور کلی، در شبکه‌های عصبی پس از هر لایه، یک تابع فعال‌سازی قرار می‌گیرد. تابع فعال‌سازی یک عملگر است که خروجی را به مجموعه‌ای از ورودی‌ها نگاشت می‌کند و برای غیرخطی کردن ساختار شبکه استفاده می‌شود [۱۹]. در این مطالعه از تابع رلو به عنوان تابع فعال‌سازی در بخش‌های رمزنگاری و رمزگشایی استفاده شده است و این ویژگی را دارد که غیرخطی بودن را به ساختار شبکه اعمال کند؛ بنابراین در برابر تغییرات جزئی در ورودی مقاوم است. رابطه (۵) تابع رلو را نشان می‌دهد. در این تابع، اگر مقدار d بزرگ‌تر از صفر باشد، خروجی d است و اگر مقدار d کوچک‌تر یا مساوی صفر باشد، خروجی صفر است.

1 Sigmoid

2 Relu



شکل ۷. بلوک دیاگرام روش پیشنهادی.

Fig. 7. The block diagram of the proposed method.

قطعیت‌های مختلف مانند خطاهای مدل‌سازی، کمی اختلاف وجود دارد که ممکن است باعث هشدارهای کاذب در فرآیند عیب‌یابی شود؛ بنابراین، تنظیم پارامترهای مدل المان محدود اولیه و به‌روزرسانی آن‌ها برای به‌حداقل رساندن خطای مدل‌سازی بر پایه داده‌های مدل واقعی ضروری است. در مطالعه حاضر، مدل المان محدود سازه جکته فراساحلی بر پایه فرکانس‌های طبیعی مدل سالم آزمایشگاهی به‌روزرسانی شده است. در مراحل بعدی، اطلاعات استخراج‌شده از مدل به‌روزرسانی شده و مدل سالم آزمایشگاهی به‌عنوان داده‌های آموزش برای تشخیص عیوب مدل آزمایشگاهی استفاده می‌شوند. به‌روزرسانی مدل المان محدود با تغییر چگالی و مدول یانگ به‌گونه‌ای انجام می‌شود که فرکانس‌های طبیعی مدل سالم المان محدود با فرکانس‌های طبیعی مدل سالم آزمایشگاهی مطابقت داشته باشند. استفاده از مدل المان محدود برای تولید داده‌های شبیه‌سازی شده، به صحت مدل بستگی دارد. مدل المان محدود با استفاده از یک الگوریتم بهینه‌سازی استاندارد برای حل یک مسئله مقید به‌روزرسانی می‌شود. تابع هدف به‌منظور کم کردن خطا می‌تواند به‌صورت زیر بیان شود [۱۱-۱۲، ۲۱-۲۲]:

در ۳ سناریو برای هر دو مدل المان محدود و آزمایشگاهی انجام شده است که شامل؛ حالت سالم، حذف میله برشی مورب طبقه چهارم از وجه دوم (D1)، حذف میله برشی مورب طبقه سوم از وجه دوم (D2)، حذف میله برشی مورب طبقه چهارم از وجه سوم (D3) و حذف میله برشی مورب طبقه سوم از وجه سوم (D4) می‌باشد. سناریوهای مختلف عیب در جدول ۱ ارائه شده است. علاوه بر این، مدل‌های المان محدود برای حالت‌های مختلف عیب، در شکل ۸ نشان داده شده است که میله‌های برشی مشخص شده با رنگ قرمز، در هر حالت عیب از سازه حذف می‌شوند. در روش پیشنهادی در این مقاله، از مدل المان محدود سازه و حالت سالم آزمایشگاهی برای داده‌های آموزش و از مدل آزمایشگاهی برای داده‌های ارزیابی استفاده می‌شود.

۳-۲- به‌روزرسانی مدل المان محدود و پیش‌پردازش داده‌ها


در روش پیشنهادی، هر سیگنال ارتعاشی برای هر یک از حالت‌های عیب توسط نرمالیزاسیون Z-score^۱ نرمالیزه شده است [۲۰]. به‌طور کلی، بین ویژگی‌های دینامیکی مدل‌های المان محدود و واقعی به دلیل عدم

1 Normalization of Z-score

جدول ۱. سناریوهای مختلف عیب.

Table 1. Different scenarios of damage.

سناریوهای مختلف	حالت‌های در نظر گرفته شده
۲-کلاس	سالم، معیوب (D1 & D2 & D3 & D4)
۳-کلاس	سالم، معیوب (D1 & D3)، معیوب (D2 & D4)
۵-کلاس	سالم، معیوب (D1)، معیوب (D2)، معیوب (D3)، معیوب (D4)



شکل ۸. مدل‌های المان محدود برای حالت‌های مختلف عیب.

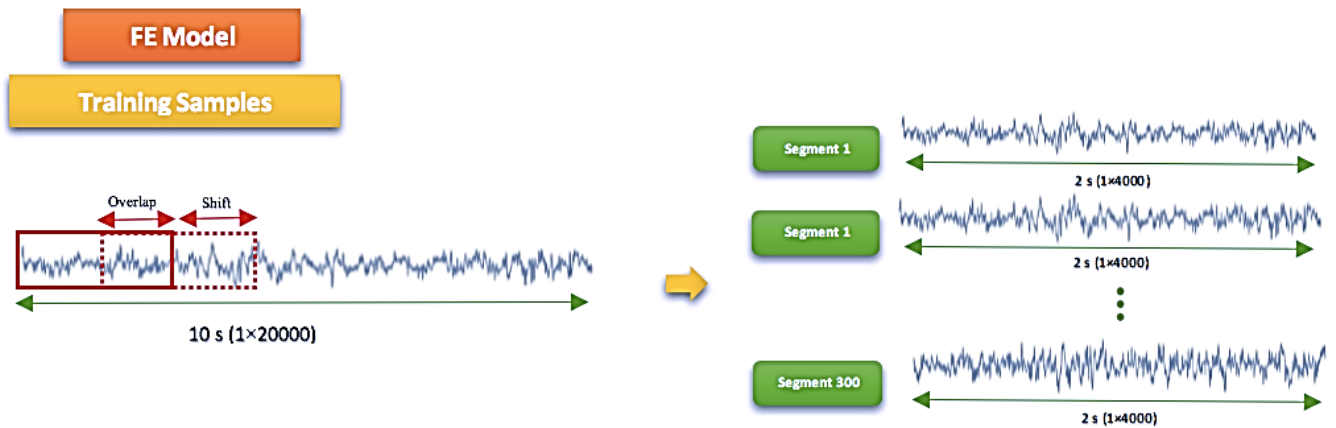
Fig. 8. The FE models for different damage states.

در روش پیشنهادی این مطالعه، از تکنیک هم‌پوشانی برای داده‌افزایی^۱ استفاده می‌شود [۶، ۲۳]. افزایش تعداد داده‌ها باعث افزایش صحت و جلوگیری از پدیده بیش برآزش می‌شود. در این مطالعه پاسخ‌های دینامیکی شتاب‌سنج‌های $a1$ ، $b1$ و $c1$ که بر روی ستون I نصب شده‌اند، برای استخراج ویژگی‌های مختلف و تشخیص عیوب سازه مورد استفاده قرار می‌گیرند. تعداد نمونه‌ها و طول آن‌ها با دقت انتخاب شده‌اند تا به حداکثر نرخ صحت و سرعت در عیب‌یابی سازه برسند. در هر حالت از مدل المان محدود، ۱۰ ثانیه (طول سیگنال 20000) از پاسخ‌های دینامیکی ثبت می‌شوند؛ در این صورت ۵ نوع داده با ابعاد 3×20000 خواهیم داشت که در آن ۵ تعداد حالت‌های مختلف، ۳ تعداد پاسخ‌های دینامیکی و 20000 طول هر پاسخ دینامیکی (10×2000) یا نقاط نمونه‌برداری است. پس از آن، هر پاسخ دینامیکی با استفاده از تکنیک هم‌پوشانی با شیف‌ت زمانی مشخصی،

$$F = \sum_{i=1}^n \left(\frac{|f_{Exp(i)} - f_{FE(i)}(\rho, E)|}{f_{Exp(i)}} \right)^2 \quad (7)$$

که $f_{Exp(i)}$ فرکانس‌های طبیعی به دست آمده از مدل آزمایشگاهی، ρ چگالی، E مدول یانگ، n تعداد فرکانس‌های طبیعی و $f_{FE(i)}$ فرکانس‌های طبیعی محاسبه شده از مدل المان محدود با پارامترهای بین $7700 \text{ kg/m}^3 < \rho < 8050 \text{ kg/m}^3$ و $190 \text{ GPa} < E < 215 \text{ GPa}$ است. در مطالعه حاضر، فقط فرکانس‌های طبیعی به دست آمده در محدوده فرکانس کاری از صفر هرتز تا ۱۲۰ هرتز در فرایند به‌روزرسانی مدل استفاده می‌شوند [۱۱]. اگر فرکانس‌های طبیعی مدل سالم المان محدود با فرکانس‌های طبیعی مدل سالم آزمایشگاهی مطابقت داشته باشند، مقدار تابع هدف به حداقل مقدار خود می‌رسد.

1 Sigmoid



شکل ۹. داده‌افزایی با استفاده از تکنیک هم‌پوشانی برای داده‌های آموزش.

Fig. 9. Data augmentation using overlap technique for training data.

به بازه‌های ۲ ثانیه‌ای (طول سیگنال ۴۰۰۰) تقسیم می‌شود که روند این هم‌پوشانی در شکل ۹ نشان داده شده است. در واقع هر پاسخ دینامیکی به ۳۰۰ نمونه ۲ ثانیه‌ای تقسیم خواهد شد؛ بنابراین تعداد نمونه‌ها برای هر حالت از مدل المان محدود $(3 \times 4000) \times 300$ و برای مجموع حالت‌های مختلف این مدل $(3 \times 4000) \times 1500$ خواهد شد. رویکردی مشابه با مدل المان محدود، برای مدل آزمایشگاهی نیز انجام می‌شود؛ در هر حالت از مدل آزمایشگاهی، ۳۰ ثانیه (طول سیگنال ۶۰۰۰۰) از پاسخ‌های دینامیکی ثبت می‌شوند؛ در این صورت ۵ نوع داده با ابعاد 3×60000 خواهیم داشت که در آن ۵ تعداد حالت‌های مختلف، ۳ تعداد پاسخ‌های دینامیکی و ۶۰۰۰۰ طول هر پاسخ دینامیکی (30×2000) یا نقاط نمونه‌برداری است. پس از آن، هر پاسخ دینامیکی با استفاده از تکنیک هم‌پوشانی با شیفت زمانی مشخصی، به بازه‌های ۲ ثانیه‌ای تقسیم می‌شود. در واقع هر پاسخ دینامیکی به ۱۰۰ نمونه ۲ ثانیه‌ای تقسیم خواهد شد؛ بنابراین تعداد نمونه‌ها برای هر حالت از مدل آزمایشگاهی $(3 \times 4000) \times 100$ و برای مجموع حالت‌های مختلف این مدل $(3 \times 4000) \times 500$ خواهد شد.

می‌توان به تعریف ساده، سرعت بالا محاسبات آن اشاره کرد. در این مطالعه، به منظور انتخاب توابع مود ذاتی مناسب، پاسخ‌های دینامیکی مدل المان محدود سازه و حالت سالم آزمایشگاهی با استفاده از روش تجزیه مود تجربی دسته‌ای کامل به توابع مود ذاتی خود تجزیه می‌شوند. پس از آن، توابع مود ذاتی که بالاترین مقدار آنتروپی جایگشتی را دارند انتخاب می‌شوند [۲۶-۲۵]. بر اساس آنتروپی شانون، آنتروپی جایگشتی یک سری زمانی را می‌توان به صورت زیر تعریف کرد:

۳-۳- انتخاب توابع مود ذاتی مناسب و بازسازی سیگنال‌ها

سیگنال‌های ارتعاشی استخراج شده از سیستم‌های مکانیکی همیشه در معرض اطلاعات اضافی و نامربوط به ذات اصلی سیستم هستند که ممکن است باعث ایجاد خطا یا کاهش دقت در یادگیری ویژگی‌ها و فرآیند تشخیص عیب شود. این امر مستلزم حذف اطلاعات اضافی و انتخاب مؤلفه‌های اصلی

1 Permutation Entropy (PE)

۳-۴- شبکه عمیق پیشنهادی

هدف اصلی این مطالعه، ارائه دادن الگوریتمی برای یادگیری ویژگی‌های زیر کامل^۴ حساس به عیب از داده‌های ورودی به منظور عیب‌یابی سیستم‌های مکانیکی است. روش پیشنهادی، یک الگوریتم یادگیری چند مرحله‌ای از ویژگی‌های غیرخطی بوده که هر مرحله یک نوع تغییر ویژگی محسوب می‌شود. در این الگوریتم از شبکه عصبی عمیق با چندلایه پنهان که هر لایه به لایه‌های بعدی با یک ترکیب غیرخطی متصل شده است، استفاده می‌شود. برای پیاده‌سازی شبکه عمیق پیشنهادی از کتابخانه کراس در زبان برنامه‌نویسی پایتون استفاده شده است.

رویکرد پیشنهادی برای آموزش شبکه عمیق (شکل ۱۰) شامل دو مرحله آموزش است؛ یعنی، مرحله پیش آموزش با استفاده از الگوریتم یادگیری بدون نظارت بر اساس خود رمزنگارها و لایه رگرسیون سافت مکس که به آن مرحله عمیق^۵ گفته می‌شود (مرحله اول) و آموزش مجدد با استفاده از الگوریتم پس انتشار خطا که مرحله تنظیم دقیق^۶ (مرحله دوم) نامیده می‌شود. شکل ۱۰ نحوه آموزش شبکه عصبی عمیق پیشنهادی را نشان می‌دهد. در مرحله پیش آموزش، داده‌های ورودی بدون برچسب‌گذاری^۷ برای استخراج ویژگی‌های زیر کامل، مورد استفاده قرار می‌گیرند. در شبکه پیشنهادی تعداد نورون‌های لایه‌های پنهان (d_i) کمتر از تعداد ویژگی‌های ورودی (m) است؛ یعنی $d_i < m$ در هر لایه مخفی (i) که $d_i < d_{i-1}$ برای $i=1, 2, 3, \dots, n$ و d_n تعداد لایه‌های پنهان در رمزگذار (n) است.

شکل ۱۱ تصویری از روند پیش آموزش شبکه عمیق پیشنهادی با ۴ لایه پنهان را برای تشخیص عیوب سازه جکته فراساحلی نشان می‌دهد. با تعیین تعداد نورون‌ها در هر لایه پنهان کوچک‌تر از ویژگی‌های ورودی، هر خود رمزنگار ویژگی‌های مفیدی را از داده‌های ورودی بدون برچسب‌گذاری، می‌آموزد. در مرحله اول یادگیری، از یک رمزنگار با تابع فعال‌سازی رلو برای یادگیری ویژگی‌های زیر کامل از داده‌های ورودی استفاده می‌گردد که در آن $d_1 < m$ و ویژگی‌های زیر کامل استخراجی به عنوان داده‌های ورودی، برای مرحله دوم یادگیری استفاده می‌شوند. پس از آن رمزنگارهای ۲، ۳ و ۴ از خود رمزنگارهای دوم، سوم و چهارم با تعداد واحدهای پنهان d_3 ، d_2 و d_4 برای استخراج ویژگی‌های زیر کامل حساس‌تر به عیب مورد استفاده قرار می‌گیرند. در نهایت، لایه رگرسیون سافت مکس با استفاده از بردار

$$PE = H_p(D) = - \sum_{\pi_j \in A_D} p(\pi_j) \ln(p(\pi_j)) \quad (8)$$

برای هر سری زمانی دلخواه $\{s(t), t=1, 2, \dots, N\}$ با توجه به تئوری جاسازی، بردار جاسازی در زمان i به صورت زیر تعریف می‌شود:

$$S_i^D = [s(i), s(i+\tau), s(i+2\tau), \dots, s(i+(D-1)\tau)] \quad (9)$$

$$i=1, 2, \dots, N$$

که در آن τ و D به ترتیب پارامتر تأخیر زمانی^۱ و بعد جاسازی^۲ هستند. برای هر جایابی π_j فرکانس نسبی^۳ $p(\pi_j)$ می‌تواند به صورت زیر تعریف شود:

$$p(\pi_j) = \frac{\#\{S_i^D \text{ has type } \pi_j | 1 \leq j \leq N - (D-1)\tau\}}{N - (D-1)\tau} \quad (10)$$

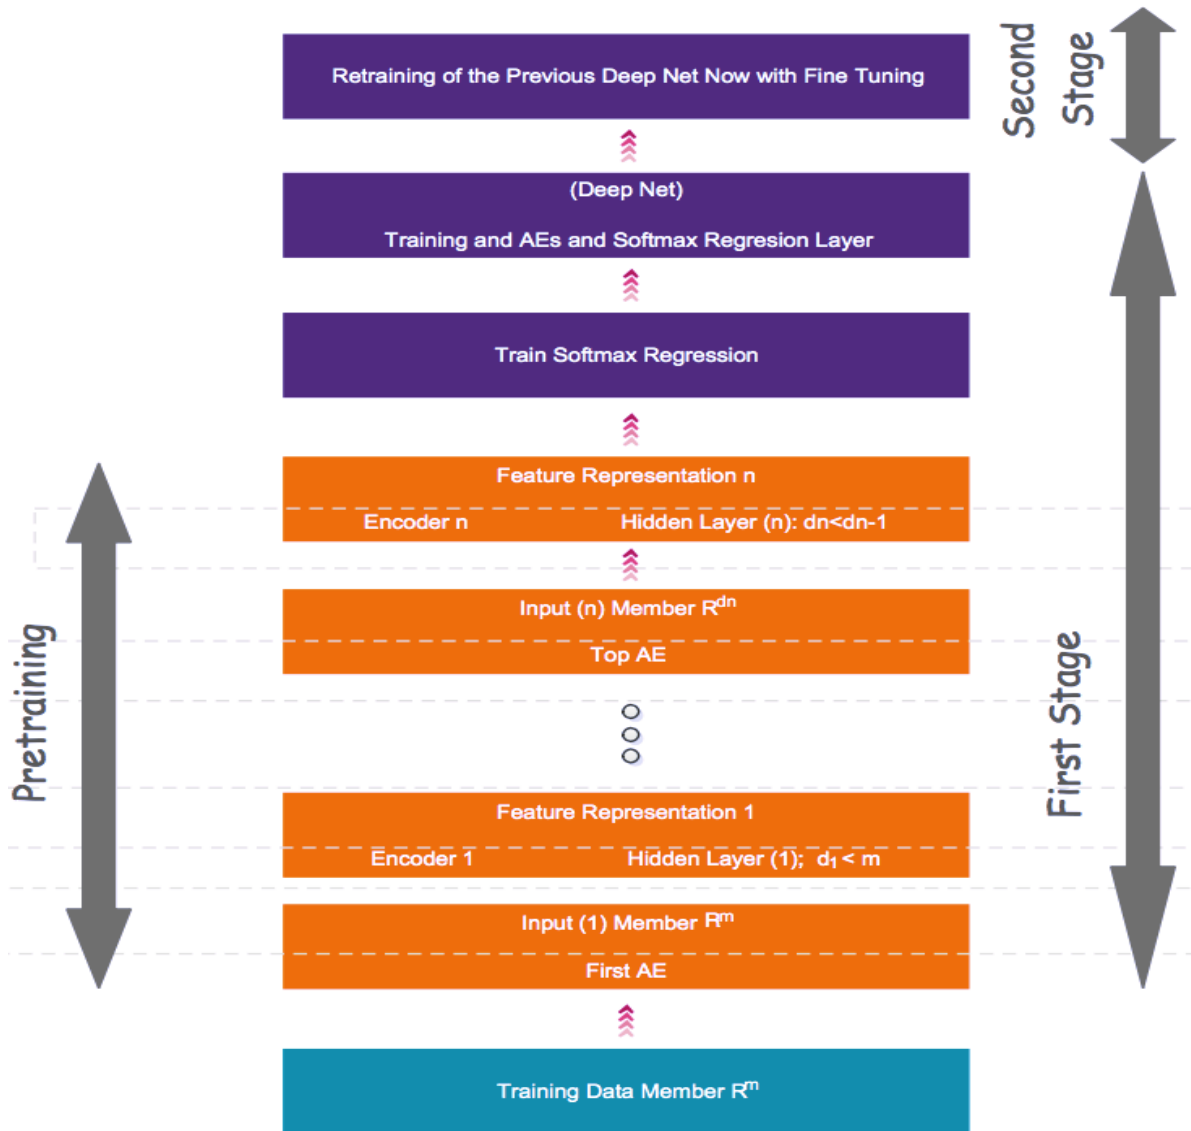
که در آن $\#\#$ تعداد را ارائه می‌دهد. مطابق مرجع [۲۶] مقادیر منطقی برای پارامترهای تأخیر زمانی و بعد فضای جاسازی به ترتیب ۱ تا ۴ و ۳ تا ۹ است. در این مطالعه تخصیص $D=3$ و $\tau=1$ برای استخراج جایگشت سری‌های زمانی به کار گرفته شده است. همچنین، می‌توان آنتروپی جایگشتی را در فاصله ۰ تا ۱ به صورت زیر نرمالایز کرد:

$$H_p = \frac{H_p(D)}{\ln(D!)} = - \frac{1}{\ln(D!)} \sum_{i=1}^k p(\pi_j) \ln(p(\pi_j)) \quad (11)$$

پس از انتخاب توابع مود ذاتی مناسب در مدل‌های المان محدود و آزمایشگاهی، سیگنال‌های اصلی با استفاده از این توابع مود ذاتی بازسازی می‌شوند. سیگنال‌های ارتعاشی که بر اساس توابع مود ذاتی مناسب و مؤثر بازسازی شده‌اند می‌توانند در فرآیندهای یادگیری و تشخیص عیب عملکرد بهتری داشته باشند [۲۴-۲۶].

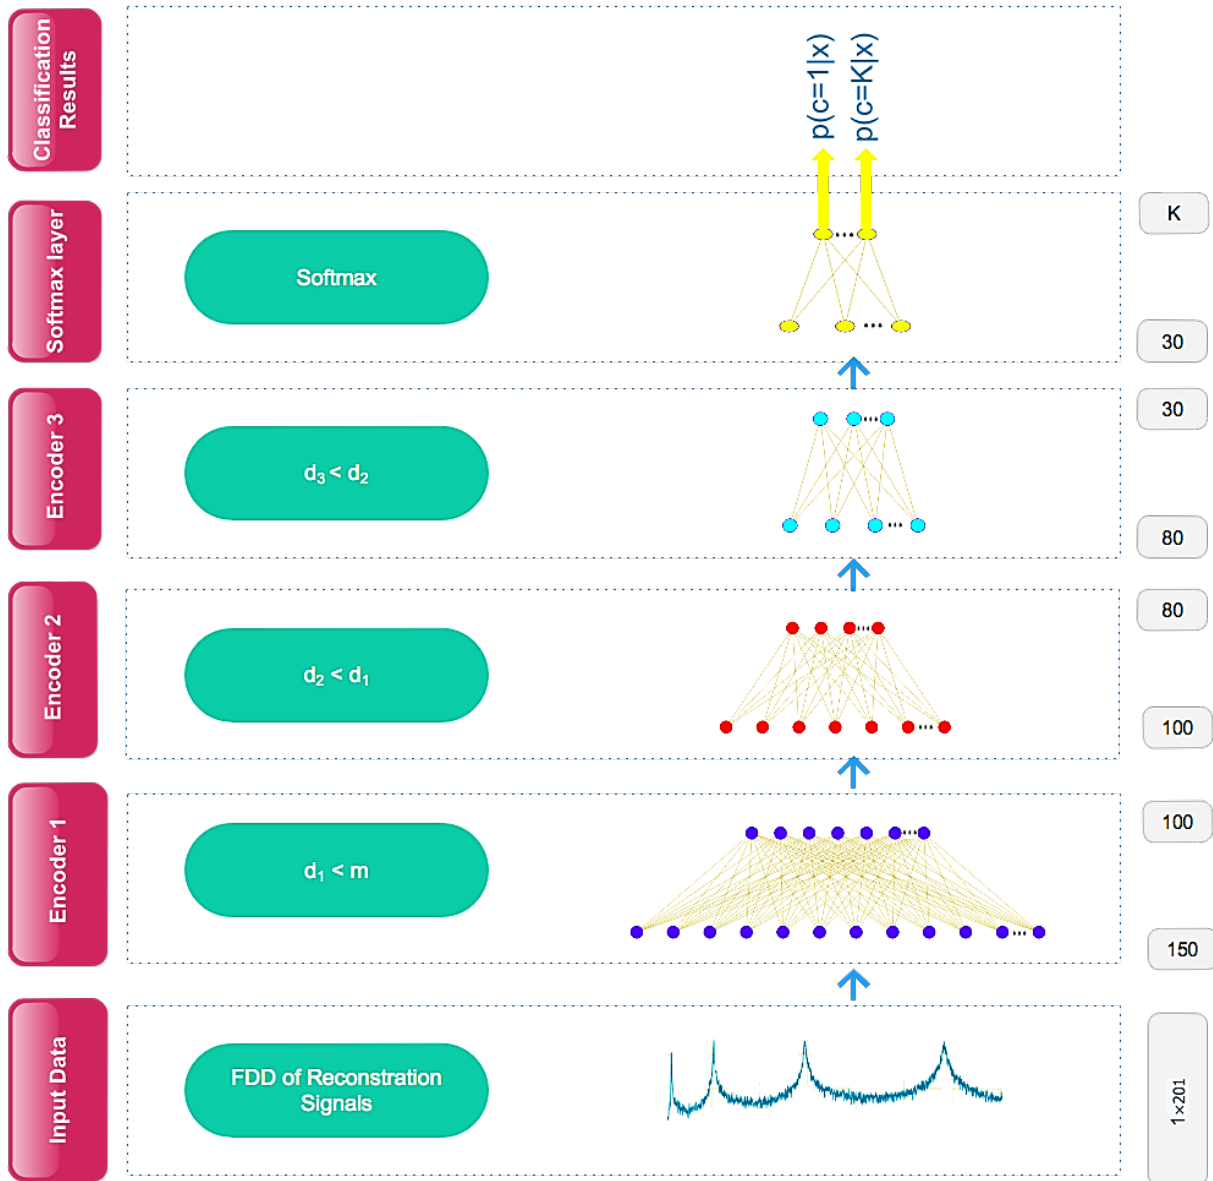
4 Under-complete features
5 Deep stage
6 Fine-tuning stage
7 Unlabelled

1 Time lag parameter
2 Embedding dimension
3 Relative frequency



شکل ۱۰. نحوه آموزش شبکه عصبی عمیق پیشنهادی.

Fig. 10. Training process of the proposed deep neural network.



شکل ۱۱. نحوه پیش آموزش شبکه عمیق پیشنهادی با ۴ لایه پنهان.

Fig. 11. The pre-training process of the proposed deep network with 4 hidden layers

۴-۱-۱- آنالیز مودال تجربی

در روش آنالیز مودال تجربی، سازه توسط نیروهای خاصی (به‌عنوان ورودی) تحریک می‌شود و سیگنال‌های ارتعاشی پاسخ، ثبت می‌شوند (به‌عنوان خروجی)؛ بنابراین، پارامترهای مودال بر پایه ورودی و خروجی با استفاده از تابع پاسخ فرکانسی^۶ استخراج می‌شوند. تابع پاسخ فرکانس را می‌توان به‌صورت زیر بیان کرد [۲۷]:

$$H(\omega) = \frac{S_{xx}(\omega)}{S_{yy}(\omega)} \quad (12)$$

که $S_{xx}(\omega)$ و $S_{yy}(\omega)$ به‌ترتیب چگالی طیفی توان و چگالی طیفی مقاطع^۷ سیگنال‌های خروجی و ورودی هستند. زیرنویس‌های x و f به‌ترتیب سیگنال‌های خروجی و ورودی را نشان می‌دهند. شکل ۱۲ توابع پاسخ فرکانسی را برای ۱۲ شتاب‌سنج نصب‌شده بر روی ۴ ستون مدل سالم آزمایشگاهی را در محدوده فرکانس ۰ هرتز تا ۲۰۰ هرتز نشان می‌دهد (شکل ۳ را ببینید). همان‌طور که ملاحظه می‌گردد، شتاب‌سنج‌های مشابه نصب‌شده بر روی هر ستون سازه دارای فرکانس‌های طبیعی تقریباً یکسانی هستند.

در شکل ۱۳، توابع پاسخ فرکانسی به‌دست‌آمده با استفاده از شتاب‌سنج $a1$ برای حالت‌های مختلف نشان داده‌شده‌است. همان‌طور که مشاهده می‌شود، حالت‌های مختلف عیب، نمودارهای تابع پاسخ فرکانسی خاص خود را ارائه می‌دهند که با تابع پاسخ فرکانسی حالت سالم متفاوت است.

همچنین مقادیر میانگین^۸ و انحراف معیار^۹ فرکانس‌های طبیعی [۲۸-۲۹] برای حالت‌های مختلف با استفاده از توابع پاسخ فرکانسی همه شتاب‌سنج‌ها، در محدوده فرکانس کاری صفر هرتز تا ۱۲۰ هرتز در جدول ۲ ارائه‌شده‌است. انتظار می‌رود که ایجاد یک عیب سازه‌ای منجر به کاهش فرکانس‌های طبیعی شود؛ با این حال، بررسی فرکانس‌های طبیعی برای عیب D4، نشان می‌دهد که در فرکانس طبیعی اول افزایش مقدار وجود دارد که می‌تواند ناشی از عدم قطعیت‌های مختلف مانند خطاهای اندازه‌گیری و نویزهای محیطی در فرآیند آزمایش باشد [۱۳].

ویژگی‌های زیر کامل آخرین لایه پنهان، عیوب سازه را تشخیص می‌دهد. تعداد کل داده‌های آموزش و آزمون به‌ترتیب ۱۵۰۰ و ۵۰۰ است که ۵۰ نمونه از داده‌های آزمون برای اعتبارسنجی استفاده می‌شود. تمامی ابر پارامترهای شبکه پیشنهادی برای رسیدن به بهترین نرخ همگرایی با استفاده از روش سعی و خطا به‌دقت تنظیم شده‌اند. در نهایت تابع خطا آنتروپی متقابل^۱، بهینه‌کننده آدام^۲ [۶] با نرخ یادگیری ۰/۰۰۰۱ و اندازه دسته ۱۰ برای آموزش شبکه پیشنهادی مورد استفاده قرار گرفته‌است. بعد از آموزش شبکه پیشنهادی، ارزیابی با استفاده از ۴۵۰ نمونه از داده‌های آزمون صورت می‌گیرد.

۴- کاربرد روش پیشنهادی برای عیب‌یابی سازه جک‌تی فراساحلی

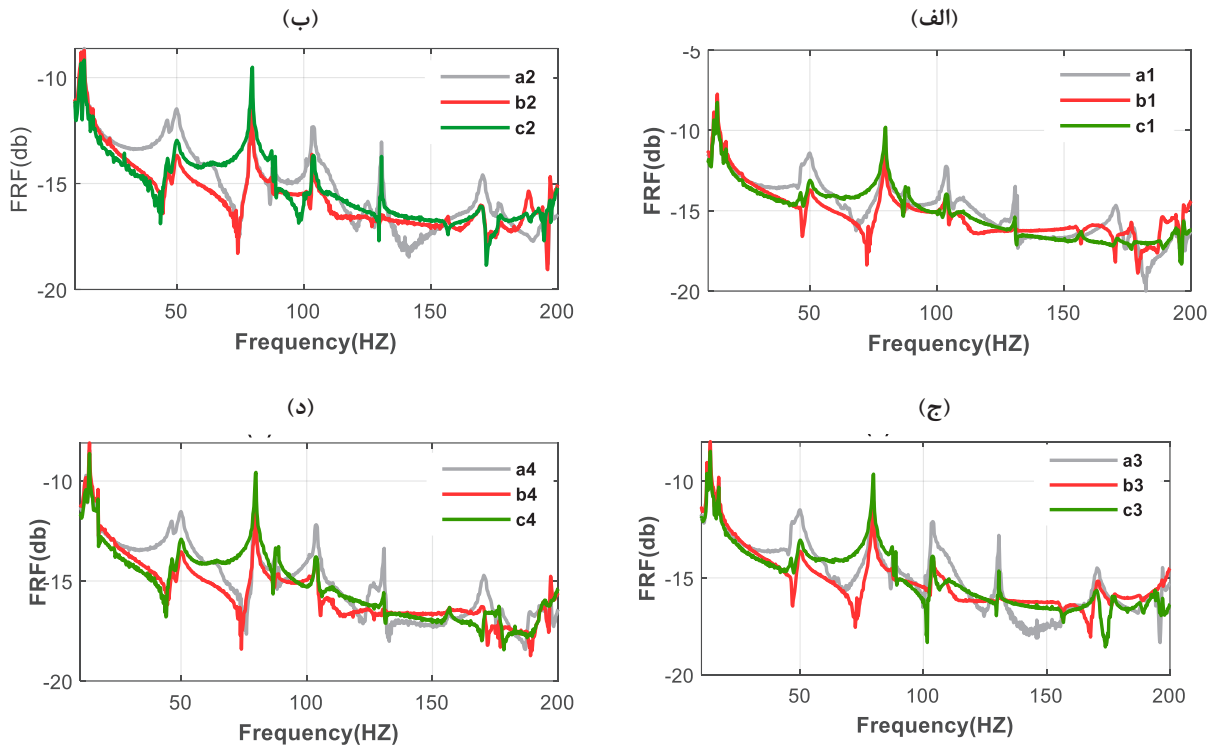
در این قسمت، نتایج روش پیشنهادی برای عیب‌یابی سازه جک‌تی فراساحلی ارائه‌شده‌است. این بخش به چندین زیر بخش تقسیم شده است: (۱) ارزیابی مدل المان محدود شبیه‌سازی شده بر پایه داده‌های آزمایشگاهی. (۲) انتخاب توابع مود ذاتی مناسب و بازسازی سیگنال‌های ارتعاشی. (۳) عیب‌یابی سازه جک‌تی فراساحلی.

۴-۱- ارزیابی مدل المان محدود شبیه‌سازی شده بر پایه داده‌های آزمایشگاهی

به‌منظور ارزیابی صحت مدل المان محدود، فرکانس‌های طبیعی سازه جک‌تی فراساحلی با استفاده از روش‌های مختلف به‌دست آمده و با یکدیگر مقایسه می‌شوند. به‌منظور ساماندهی اطلاعات ارائه‌شده، این زیر بخش به زیر بخش‌های زیر تقسیم می‌شود: (۱) به‌دست‌آوردن پارامترهای مودال با استفاده از آنالیز مودال تجربی^۳. (۲) به‌دست‌آوردن پارامترهای مودال با استفاده از آنالیز مودال عددی^۴ بر پایه مدل المان محدود و روش مقادیر ویژه^۵. (۳) به‌دست‌آوردن پارامترهای مودال با استفاده از روش آنالیز مودال بر مبنای فقط خروجی به‌صورت تجربی و عددی. (۴) مقایسه پارامترهای مودال به‌دست‌آمده با استفاده از روش‌های بیان‌شده.


6 Frequency Response Function (FRF)
7 Cross Spectral Density (CSD)
8 Mean
9 Standard deviations (Std)

1 Cross-entropy loss function
2 Adam optimizer
3 Experimental Modal Analysis (EMA) method
4 Numerical Modal Analysis (NMA)
5 Eigenvalues method



شکل ۱۲. توابع پاسخ فرکانسی برای ۱۲ شتاب سنج نصب شده بر روی ۴ ستون مدل سالم آزمایشگاهی. الف) ستون I. ب) ستون II. ج) ستون III. د) ستون IV.

Fig. 12. Frequency response functions for 12 accelerometers mounted on the 4 columns of the lab-scale intact model. a) Column I. b) Column II. c) Column III. d) Column IV.



شکل ۱۳. توابع پاسخ فرکانسی برای حالت‌های مختلف عیب.

Fig. 13. Frequency response functions for different damage states.

جدول ۲. مقادیر میانگین و انحراف معیار فرکانس‌های طبیعی برای حالت‌های مختلف با استفاده از توابع پاسخ فرکانسی همه شتاب‌سنج‌ها.

Table 2. Mean values and standard deviations of the natural frequencies for different states using frequency response functions of all accelerometers.

شماره مود	سالم		عیب (D1)		عیب (D2)		عیب (D3)		عیب (D4)	
	انحراف معیار	میانگین	انحراف معیار	میانگین	انحراف معیار	میانگین	انحراف معیار	میانگین	انحراف معیار	میانگین
۱	۰/۳۴	۱۲/۸۲	۰/۳۱	۱۴/۱۲	۰/۳۰	۱۳/۹۸	۰/۳۰	۱۴/۵۳	۰/۳۲	۱۴/۴۱
۲	۰/۲۷	۲۱/۱۱	۰/۲۴	۲۰/۸۲	۰/۲۸	۲۰/۱۳	۰/۲۲	۱۸/۸۱	۰/۲۱	۲۱/۵۰
۳	۰/۳۶	۵۰/۶۲	۰/۳۵	۵۰/۸۸	۰/۳۷	۴۹/۶۲	۰/۳۶	۵۰/۴۲	۰/۳۴	۵۱/۵۲
۴	۰/۱۷	۷۹/۱۳	۰/۱۱	۷۶/۱۰	۰/۱۴	۷۹/۰۲	۰/۱۳	۷۸/۳۵	۰/۱۲	۷۹/۴۴
۵	۰/۳۴	۸۸/۲۱	۰/۳۳	۸۷/۶۴	۰/۳۱	۸۷/۸۹	۰/۳۲	۸۵/۲۴	۰/۳۰	۸۸/۳۳
۶	۰/۲۳	۹۷/۸۸	۰/۲۳	۱۰۳/۲۲	۰/۲۲	۹۸/۳۳	۰/۲۱	۱۰۲/۵۷	۰/۲۲	۱۰۳/۶۵

جدول ۳. فرکانس‌های طبیعی به دست آمده از آنالیز مودال عددی بر پایه روش مقادیر ویژه.

Table 3. The obtained natural frequencies from numerical modal analysis based on eigenvalues method.

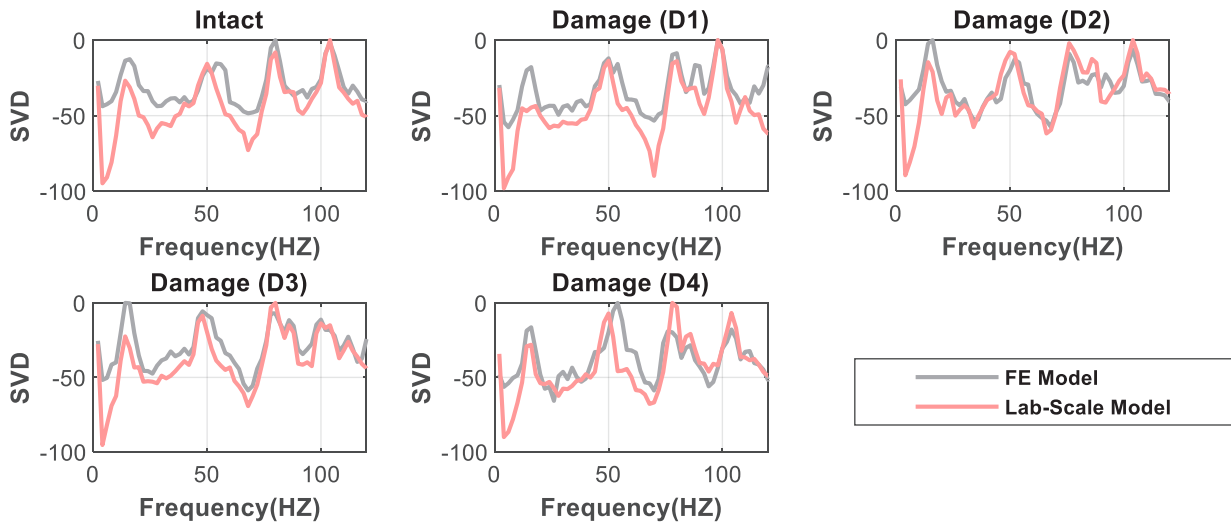
شماره مود	نوع مود	سالم	عیب (D1)	عیب (D2)	عیب (D3)	عیب (D4)
۱	خمشی	۱۵/۲۶۳	۱۵/۳۶۱	۱۵/۴۱۹	۱۵/۳۳۹	۱۵/۱۵۳
۲	پیچشی	۲۰/۷۶۹	۲۰/۶۶۸	۲۰/۴۱۳	۲۰/۸۳۰	۲۰/۹۲۱
۳	خمشی	۵۴/۳۶۰	۵۳/۶۹۷	۵۴/۴۰۱	۵۱/۲۱۳	۵۴/۱۰۲
۴	خمشی	۷۹/۵۳۴	۷۹/۵۹۱	۷۸/۷۷۵	۷۹/۶۱۷	۷۹/۶۹۸
۵	پیچشی	۹۰/۹۱۷	۸۸/۶۲۹	۸۹/۳۵۲	۸۹/۲۹۱	۸۹/۲۷۷
۶	پیچشی	۱۰۳/۴۱	۹۹/۹۳۳	۱۰۳/۴۷	۹۸/۹۴۹	۱۰۳/۴۰

۴-۱-۲ آنالیز مودال عددی

در آنالیز مودال عددی سازه جکته فراساحلی بر پایه مدل المان محدود، فرکانس‌های طبیعی و شکل مودهای سازه با استفاده از روش مقادیر ویژه [۳۰] و با استفاده از تکنیک Block Lanczos استخراج می‌شوند [۳۱]. فرکانس‌های طبیعی به دست آمده قبل از به‌روزرسانی مدل، در محدوده فرکانس کاری ۰ هرتز تا ۱۲۰ هرتز با استفاده از آنالیز مودال عددی در جدول ۳ ارائه شده است. همان‌طور که ملاحظه می‌گردد، حالت‌های مختلف عیب بر روی فرکانس‌های طبیعی سازه اثر می‌گذارند.

۴-۱-۳ آنالیز مودال عددی و تجربی بر مبنای فقط خروجی

همان‌طور که در بخش ۴-۲ بیان شد، روش تجزیه حوزه فرکانس فقط به پاسخ‌های خروجی اندازه‌گیری شده نیاز دارد. در این بخش از روش تجزیه حوزه فرکانس برای استخراج داده‌های فرکانسی سازه استفاده می‌شود. شکل ۱۴ نمونه‌ای از سیگنال ارتعاشی نرمال شده مدل‌های المان محدود و آزمایشگاهی سازه جکته فراساحلی برای حالت‌های مختلف عیب با استفاده از روش تجزیه حوزه فرکانس در محدوده فرکانس کاری صفر هرتز تا ۱۲۰ هرتز را نشان می‌دهد. با توجه به نتایج شکل ۱۴، ملاحظه می‌گردد که نمودارهای مقادیر تکین هر دو مدل تقریباً رفتار مشابهی دارند، اما عدم



شکل ۱۴. نمونه‌ای از سیگنال ارتعاشی نرمال‌شده مدل‌های المان محدود و آزمایشگاهی سازه جکته فراساحلی برای حالت‌های مختلف عیب با استفاده از روش تجزیه حوزه فرکانس

Fig. 14. sample of normalized vibration signal of finite element and Lab-Scale offshore jacket model for different damage states using frequency domain decomposition method.

فقط خروجی پس از به‌روزرسانی با توجه به فرکانس‌های طبیعی به‌دست‌آمده از مدل آزمایشگاهی مبتنی بر روش آنالیز مودال بر مبنای فقط خروجی به ترتیب تقریباً ۱/۵، ۱/۴، ۰/۲۹ و ۰/۱۷ درصد است. این مقایسه‌ها نشان می‌دهد که مدل المان محدود به‌روز شده به‌اندازه کافی دقیق است تا نمایانگر رفتار دینامیکی سازه باشد [۱۱، ۲۱].

۴-۲- انتخاب توابع مود ذاتی و بازسازی سیگنال‌های ارتعاشی

بر اساس بخش ۳-۳، مقادیر میانگین آن‌تروپی جایگشتی توابع مود ذاتی ۱ تا ۱۲ برای همه نمونه‌های مدل المان محدود جکته فراساحلی و حالت سالم آزمایشگاهی در شکل ۱۵ ارائه شده و با یکدیگر مقایسه شده‌اند.

با توجه به شکل ۱۵ می‌توان بیان کرد که مقادیر آن‌تروپی جایگشتی اولین توابع مود ذاتی برای عیوب مختلف، تقریباً بالاتر از حالت‌های سالم هستند [۲۶]. علاوه بر این، ملاحظه می‌گردد که حالت‌های مختلف عیب و سالم روند مشابهی دارند حتی اگر مقادیر آن‌تروپی جایگشتی توابع مود ذاتی مربوط به آن‌ها با یکدیگر متفاوت باشد. ملاحظه می‌گردد که با افزایش شماره توابع مود ذاتی، مقادیر آن‌تروپی جایگشتی کاهش می‌یابد و ۸ تابع مود ذاتی اول دارای مقادیر آن‌تروپی جایگشتی بالاتری از سایر توابع مود ذاتی هستند. با این دیدگاه و با توجه به بخش ۳-۳، اطلاعات عیب به‌طور کلی در محدوده فرکانس نسبتاً بالا متمرکز هستند [۲۵-۲۶]؛ می‌توان نتیجه گرفت که ۸ تابع مود ذاتی اول شامل اطلاعات عیب بیشتری نسبت به سایر توابع

قطعیت‌های مختلف در سیستم باعث ایجاد اختلاف در دامنه پیک‌ها در فرکانس‌های مربوطه می‌شود. پیک نمودار مقادیر تکین، فرکانس‌های طبیعی سازه را نشان می‌دهد که مقادیر میانگین آن‌ها برای همه نمونه‌ها در بخش بعدی آورده شده‌است. لازم به ذکر است از آنجاکه تحریک ورودی لرزاننده در محاسبات آنالیز مودال بر مبنای فقط خروجی وارد نمی‌شود، برخی فرکانس‌های طبیعی در محدوده فرکانس موردنظر به‌خوبی در نمودارهای مقادیر تکین ظاهر نمی‌شوند.

۴-۱-۴- مقایسه پارامترهای مودال

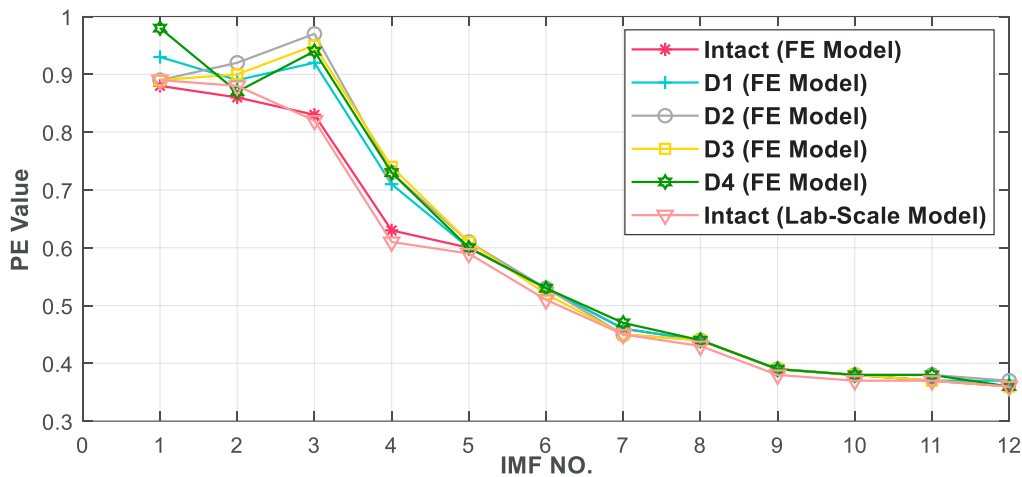
به‌منظور بررسی بهتر نتایج، خطاهای به‌دست‌آمده از مقادیر میانگین فرکانس‌های طبیعی برای سازه سالم در محدوده فرکانس کاری صفر هرتز تا ۱۲۰ هرتز با استفاده از روش‌های عددی (قبل و بعد از به‌روزرسانی) و تجربی در جدول ۴ نشان داده شده‌است. همان‌طور که از جدول ۴ ملاحظه می‌گردد، خطاهای به‌دست‌آمده از مقادیر میانگین فرکانس‌های طبیعی ۱، ۲، ۳، ۴، ۵ و ۶ مدل المان محدود بر پایه روش مقادیر ویژه پس از به‌روزرسانی با توجه به فرکانس‌های طبیعی به‌دست‌آمده از مدل آزمایشگاهی مبتنی بر روش آنالیز مودال تجربی به‌ترتیب تقریباً ۱/۴، ۱/۷، ۱/۱، ۱/۰۶، ۰/۸۸ و ۰/۱۳ درصد است. همچنین خطاهای به‌دست‌آمده از مقادیر میانگین فرکانس‌های طبیعی ۱، ۳، ۴ و ۶ مدل المان محدود بر پایه روش آنالیز مودال بر مبنای

جدول ۴. مقایسه مقادیر میانگین فرکانس‌های طبیعی برای سازه سالم با استفاده از روش‌های مختلف قبل و بعد از به‌روزرسانی.

Table 4. Comparison of the mean values of the natural frequencies for the intact structure using different methods before and after updating.

شماره مود	خطا (%)		فرکانس طبیعی (هرتز)		
	مقایسه مدل المان محدود و آزمایشگاهی		مدل المان محدود		مدل آزمایشگاهی
	قبل از به‌روزرسانی	بعد از به‌روزرسانی	آنالیز مودال عددی-آنالیز مودال تجربی	آنالیز مودال تجربی	آنالیز مودال تجربی
۱	۵/۹	۱/۴	۱۴/۶۲	۱۵/۲۶	۱۴/۴۱
۲	۳/۴	۱/۷	۲۱/۱۲	۲۰/۷۷	۲۱/۵۰
۳	۵/۵	۱/۱	۵۲/۱۰	۵۴/۳۶	۵۱/۵۲
۴	۰/۱۱	۰/۰۶	۷۹/۴۹	۷۹/۵۳	۷۹/۴۴
۵	۲/۹	۰/۸۸	۸۹/۱۱	۹۰/۹۲	۸۸/۳۳
۶	۰/۲۳	۰/۱۳	۱۰۳/۵۱	۱۰۳/۴۱	۱۰۳/۶۵

شماره مود	خطا (%)		فرکانس طبیعی (هرتز)		
	مقایسه مدل المان محدود و آزمایشگاهی		مدل المان محدود		مدل آزمایشگاهی
	قبل از به‌روزرسانی	بعد از به‌روزرسانی	آنالیز مودال عددی-آنالیز مودال تجربی	آنالیز مودال تجربی	آنالیز مودال تجربی
۱	۵/۱	۱/۵	۱۴/۴۶	۱۴/۹۸	۱۴/۲۵
۲	-	-	-	-	-
۳	۵/۰	۱/۴	۵۲/۱۰	۵۳/۹۳	۵۱/۳۶
۴	۰/۸۸	۰/۲۹	۸۰/۳۶	۸۰/۸۴	۸۰/۱۳
۵	-	-	-	-	-
۶	۰/۷۳	۰/۱۷	۱۰۴/۱۵	۱۰۳/۵۶	۱۰۴/۳۳



شکل ۱۵. مقایسه مقادیر میانگین آنترپوی جایگشتی توابع مود ذاتی ۱ تا ۱۲ همه نمونه‌های مدل المان محدود جکتی فراساحلی و حالت سالم آزمایشگاهی.

Fig. 15. Comparisons of permutation entropy mean values of all samples for IMF1 to IMF12 of the FE offshore jacket model and lab-scale intact state.

جدول ۵. صحت روش پیشنهادی برای عیب‌یابی با استفاده از مرحله اول و دوم.

Table 5. The accuracy of the proposed method for damage detection using the first and second stages.

مرحله طبقه‌بندی	صحت %		
	۵-کلاس	۳-کلاس	۲-کلاس
مرحله اول	۴۱/۵ ± ۳/۱	۵۳/۴ ± ۲/۳	۷۸/۱ ± ۲/۸
مرحله دوم	۷۱/۳۳ ± ۲/۵	۸۸/۶۷ ± ۲/۱	۱۰۰ ± ۳/۲

مدل المان محدود، برای آموزش شبکه عمیق پیشنهادی استفاده می‌شوند و داده‌های فرکانسی سیگنال‌های بازسازی شده همه نمونه‌های حالت‌های مختلف آزمایشگاهی، برای ارزیابی شبکه عمیق پیشنهادی استفاده می‌شوند.

۴-۳- عیب‌یابی سازه جکتی فراساحلی

در مرحله آخر، همان‌طور که قبلاً بیان شد، از داده‌های مدل المان محدود شبیه‌سازی شده و داده‌های سالم آزمایشگاهی برای آموزش شبکه عمیق پیشنهادی و از داده‌های مدل آزمایشگاهی برای ارزیابی توانایی تشخیص عیوب مختلف شبکه پیشنهادی استفاده می‌گردد. در همین راستا، نمونه‌های مشابه نیز در شبکه عصبی پس انتشار خطا [۳۲-۳۴، ۷] استفاده شده و نتایج

مود ذاتی هستند [۲۴-۲۶]. علاوه بر این، هنگامی که شماره توابع مود ذاتی از ۸ بزرگ‌تر می‌شود، مقادیر آنترپوی جایگشتی توابع مود ذاتی برای حالت‌های مختلف مدل المان محدود و حالت سالم آزمایشگاهی تقریباً یکسان می‌شوند و به حالت پایدار خود می‌رسند. از این دیدگاه، می‌توان بیان کرد که توابع مود ذاتی ۹ تا ۱۲ سهم کمی در تشخیص حالت‌های مختلف دارند [۲۶]. بنابراین، ۸ تابع مود ذاتی اول که حاوی اطلاعات اصلی عیوب هستند به‌عنوان توابع مود ذاتی مؤثر در هر دو مدل انتخاب می‌شوند. پس از انتخاب توابع مود ذاتی مناسب، سیگنال‌های اصلی همه نمونه‌ها با استفاده از این توابع مود ذاتی بازسازی می‌شوند؛ این کار باعث می‌شود که اطلاعات اضافی و غیر مربوط به ذات سیستم حذف شوند. پس از آن، داده‌های فرکانسی سیگنال‌های بازسازی شده همه نمونه‌های مدل سالم آزمایشگاهی و حالت‌های مختلف

1 BackProagation Neural Network (BPNN)

جدول ۶. صحت روش پیشنهادی برای عیب‌یابی با استفاده از مرحله اول و دوم.

Table 6. The accuracy of the proposed method for damage detection using the first and second stages.

روش‌ها	نوع شبکه	داده ورودی	مرحله طبقه‌بندی	صحت %	
				۲-کلاس	۳-کلاس
روش ۱	شبکه پس انتشار خطا	داده‌های فرکانسی سیگنال‌های ارتعاشی	-	۹۵/۳ ± ۲/۹	۵۱/۶ ± ۲/۳
روش ۲	شبکه پس انتشار خطا	داده‌های فرکانسی سیگنال‌های ارتعاشی بازسازی شده	-	۱۰۰ ± ۳/۸	۵۵/۷۸ ± ۳/۶
روش ۳	شبکه عمیق پیشنهادی	داده‌های فرکانسی سیگنال‌های ارتعاشی	مرحله دوم	۹۶/۲ ± ۴/۳	۷۹/۱ ± ۳/۴
روش پیشنهادی	شبکه عمیق پیشنهادی	داده‌های فرکانسی سیگنال‌های ارتعاشی بازسازی شده	مرحله دوم	۱۰۰ ± ۳/۲	۸۸/۶۷ ± ۲/۱

۱) برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس به ترتیب تقریباً ۹۵٪، ۵۱٪ و ۳۹٪ است. مطابق این جدول، برای سناریو ۲-کلاس، صحت کلیه روش‌ها بالاتر از ۹۰٪ است. همچنین مشاهده می‌شود که صحت طبقه‌بندی روش پیشنهادی برای سناریوی ۳-کلاس حدوداً ۸۸٪ است، درحالی‌که صحت روش ۳، روش ۲ و روش ۱ برای سناریوی مشابه به ترتیب حدوداً ۷۹٪، ۵۵٪ و ۵۱٪ است. همچنین، صحت طبقه‌بندی روش پیشنهادی برای سناریوی ۵-کلاس حدوداً ۷۱٪ است، درحالی‌که صحت روش ۳، روش ۲ و روش ۱ به ترتیب حدوداً ۶۴٪، ۴۲٪ و ۳۹٪ برای سناریوی مشابه است. این نشان می‌دهد که روش پیشنهادی نسبت به روش‌های دیگر در تشخیص عیوب سازه (برای همه سناریوها) عملکرد بهتری از خود نشان می‌دهد. شبکه پس انتشار خطا می‌تواند سناریوی ۲-کلاس را به درستی تشخیص دهد. باین‌حال، تشخیص عیوب با این شبکه برای سناریوهای ۳-کلاس و ۵-کلاس با شکست مواجه شده است. برای بررسی بیشتر عملکرد روش پیشنهادی، ماتریس‌های درهم‌ریختگی^۱ برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس در شکل ۱۶ نشان داده شده است.

۵- نتیجه‌گیری

در این مقاله، یک روش جدید تشخیص عیب برپایه مدل المان محدود و حالت سالم مدل واقعی در حضور عدم قطعیت‌های مختلف با استفاده از یادگیری عمیق ارائه شده است. در کاربردهای عملی معمولاً اندازه‌گیری

آن با روش پیشنهادی مقایسه شده است. شبکه عصبی پس انتشار خطا از دو لایه پنهان (۵۰ و ۱۰۰) تشکیل شده و در آن تابع فعال‌سازی سیگموئید و نرخ یادگیری ۰/۰۰۰۱ در نظر گرفته شده است. برای ارزیابی عملکرد روش پیشنهادی از معیار ارزیابی صحت استفاده شده است [۳۵]. جدول ۵ صحت شبکه پیشنهادی با داده‌های فرکانسی سیگنال‌های ارتعاشی بازسازی شده به‌عنوان داده‌های ورودی (روش پیشنهادی) را برای تشخیص عیوب سازه با استفاده از مرحله‌های اول و دوم نشان می‌دهد. همان‌طور که از این جدول ملاحظه می‌گردد، روش پیشنهادی با استفاده از مرحله دوم آموزش به نتایج بهتری دست می‌یابد.

به‌منظور بهتر نشان‌دادن عملکرد روش پیشنهادی، صحت طبقه‌بندی با استفاده از روش‌های دیگر نیز به‌دست آمده و با روش پیشنهادی مقایسه شده است. جدول ۶ صحت روش پیشنهادی را در مقایسه با روش‌های دیگر، برای تشخیص عیوب سازه جکتی فراساحلی آزمایشگاهی نشان می‌دهد.

مطابق این جدول، صحت گزارش شده روش پیشنهادی برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس تقریباً ۱۰۰٪، ۸۸٪ و ۷۱٪ است، درحالی‌که صحت شبکه پیشنهادی با داده‌های فرکانسی سیگنال‌های ارتعاشی (روش ۳) برای سناریوهای ۲-کلاس، ۳-کلاس و ۵-کلاس به ترتیب تقریباً ۹۶٪، ۷۹٪ و ۶۴٪ است. صحت شبکه پس انتشار خطا با داده‌های فرکانسی سیگنال‌های ارتعاشی بازسازی شده (روش ۲) برای سناریوهای ۲-کلاس، ۳-طبقه و ۵-کلاس حدوداً ۱۰۰٪، ۵۵٪ و ۴۲٪ است، درحالی‌که صحت شبکه پس انتشار خطا با داده‌های فرکانسی سیگنال‌های ارتعاشی (روش

1 Confusion matrix



شکل ۱۶. ماتریس درهم‌ریختگی روش پیشنهادی؛ (الف) سناریوی ۲-کلاس، (ب) سناریوی ۳-کلاس، (ج) سناریوی ۵-کلاس.

Fig. 16. Confusion matrices of the proposed algorithm (a) Scenario of 2-Class; (b) Scenario of 3-Class; (c) Scenario of 5-Class.

دارد؛ برای به حداقل رساندن این تفاوت‌ها، در روش پیشنهادی پارامترهای مدل شبیه‌سازی شده با توجه به داده‌های سالم واقعی به‌روزرسانی شده‌اند. به‌منظور اعتبارسنجی روش پیشنهادی، از یک مدل سازه جکتی فراساحلی به‌عنوان یک مطالعه موردی در محیط آزمایشگاهی و یک شبکه عمیق مؤثر با الگوریتم یادگیری ویژگی بدون نظارت برای استخراج ویژگی‌های حساس به عیب استفاده شده است. برخی از بخش‌های سیگنال‌های ارتعاشی که

داده‌های عیب سازه‌های واقعی دشوار است و به‌طور کلی فقط داده‌های حالت سالم در اختیار است؛ این محدودیت از استفاده از الگوریتم‌های داده محور در محیط‌های صنعتی جلوگیری می‌کند. یک روش ممکن برای حل این مشکل، استفاده از داده‌های عیب شبیه‌سازی شده به‌جای داده‌های واقعی است. با این حال، همیشه بین ویژگی‌های دینامیکی سیستم‌های شبیه‌سازی شده و واقعی به دلیل عدم قطعیت‌های مختلف تفاوت‌هایی وجود

health monitoring, *Mechanical Systems and Signal Processing*, 115 (2019) 213-237.

- [6] W. Zhang, C. Li, G. Peng, Y. Chen, Z. Zhang, A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load, *Mechanical Systems and Signal Processing*, 100 (2018) 439-453.
- [7] L. Jing, M. Zhao, P. Li, X. Xu, A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox, *Measurement*, 111 (2017) 1-10.
- [8] Y. Chen, G. Peng, C. Xie, W. Zhang, C. Li, S. Liu, ACDIN: Bridging the gap between artificial and real bearing damages for bearing fault diagnosis, *Neurocomputing*, 294 (2018) 61-71.
- [9] J. Guo, J. Wu, J. Guo, Z. Jiang, A damage identification approach for offshore jacket platforms using partial modal results and artificial neural networks, *Applied Sciences*, 8(11) (2018) 2173.
- [10] K. Liu, R.-J. Yan, C.G. Soares, Damage identification in offshore jacket structures based on modal flexibility, *Ocean Engineering*, 170 (2018) 171-185.
- [11] A. Mojtahedi, M.L. Yaghin, Y. Hassanzadeh, M. Etefagh, M. Aminfar, A. Aghdam, Developing a robust SHM method for offshore jacket platform using model updating and fuzzy logic system, *Applied Ocean Research*, 33(4) (2011) 398-411.
- [12] Z. Ding, J. Li, H. Hao, Z.-R. Lu, Structural damage identification with uncertain modelling error and measurement noise by clustering based tree seeds algorithm, *Engineering Structures*, 185 (2019) 301-314.
- [13] M. Fallahian, F. Khoshnoudian, V. Meruane, Ensemble classification method for structural damage assessment under varying temperature, *Structural Health Monitoring*, 17(4) (2018) 747-762.

مربوط به ذات اصلی سیستم نیستند با استفاده از روش تجزیه مود تجربی دسته‌ای کامل حذف شده‌اند. روش تجزیه حوزه فرکانس برای استخراج داده‌های فرکانسی استفاده شده‌است. پس‌از آن، ویژگی‌های حساس به عیب توسط شبکه پیشنهادی استخراج می‌شوند. داده‌های فرکانسی مدل المان محدود و حالت سالم واقعی برای آموزش شبکه عمیق پیشنهادی و داده‌های فرکانسی سازه واقعی برای ارزیابی شبکه عمیق پیشنهادی استفاده شده‌است. شبکه پیشنهادی با استفاده از دو مرحله، یعنی طبقه‌بندی پیش آموزش با روش بدون نظارت بر پایه شبکه عمیق خود رمزنگار و لایه سافت مکس (مرحله اول) و طبقه‌بندی با آموزش مجدد برپایه الگوریتم پس انتشار خطا برای تنظیم دقیق پارامترهای شبکه پیشنهادی (مرحله دوم) طراحی شده‌است. مطالعه حاضر نشان می‌دهد که روش پیشنهادی می‌تواند ویژگی‌های حساس به عیب را از داده‌های فرکانسی مدل المان محدود و حالت سالم مدل واقعی بیاموزد و صحت قابل قبولی برای تشخیص عیوب سازه واقعی در حضور عدم قطعیت‌های مختلف مانند خطاهای مدل‌سازی، خطاهای اندازه‌گیری و نویزهای محیطی به‌دست‌آورد.

منابع

- [1][1] S. Cofre-Martel, P. Kobrich, E. Lopez Droguett, V. Meruane, Deep convolutional neural network-based structural damage localization and quantification using transmissibility data, *Shock and Vibration*, 2019 (2019).
- [2] X. Wang, J. Jiao, J. Yin, W. Zhao, X. Han, B. Sun, Underwater sonar image classification using adaptive weights convolutional neural network, *Applied Acoustics*, 146 (2019) 145-154.
- [3] Y. Bao, Z. Tang, H. Li, Y. Zhang, Computer vision and deep learning-based data anomaly detection method for structural health monitoring, *Structural Health Monitoring*, 18(2) (2019) 401-421.
- [4] H. Ahmed, M.L.D. Wong, A.K. Nandi, Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse over-complete features, *Mechanical Systems and Signal Processing*, 99 (2018) 459-477.
- [5] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, R.X. Gao, Deep learning and its applications to machine

- response based on FE model and real healthy state, *Applied Acoustics*, 168 (2020) 107402.
- [23] Z. Mousavi, T.Y. Rezaei, S. Sheykhivand, A. Farzamnia, S. Razavi, Deep convolutional neural network for classification of sleep stages from single-channel EEG signals, *Journal of neuroscience methods*, 324 (2019) 108312.
- [24] M. Li, H. Wang, G. Tang, H. Yuan, Y. Yang, An improved method based on CEEMD for fault diagnosis of rolling bearing, *Advances in Mechanical Engineering*, 6 (2014) 676205.
- [25] M. Kuai, G. Cheng, Y. Pang, Y. Li, Research of planetary gear fault diagnosis based on permutation entropy of CEEMDAN and ANFIS, *Sensors*, 18(3) (2018) 782.
- [26] X. Zhang, Y. Liang, J. Zhou, A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM, *Measurement*, 69 (2015) 164-179.
- [27] D. Formenti, M. Richardson, Parameter estimation from frequency response measurements using rational fraction polynomials (twenty years of progress), in: *Proceedings of International Modal Analysis Conference XX*, Citeseer, 2002.
- [28] B. Song, D. Casem, J. Kimberley, *Dynamic Behavior of Materials, Volume 1: Proceedings of the 2013 Annual Conference on Experimental and Applied Mechanics*, Springer Science & Business Media, 2013.
- [29] G. Deodatis, B.R. Ellingwood, D.M. Frangopol, *Safety, reliability, risk and life-cycle performance of structures and infrastructures*, CRC Press, 2014.
- [30] L. Meirovitch, *Analytical methods in vibrations*, (1967).
- [31] C. Rajakumar, C. Rogers, The Lanczos algorithm applied to unsymmetric generalized eigenvalue problem, *International Journal for Numerical Methods in Engineering*, 32(5) (1991) 1009-1026.
- [32] H.D. Beale, H.B. Demuth, M. Hagan, Neural [14] S. Teng, G. Chen, G. Liu, J. Lv, F. Cui, Modal Strain Energy-Based Structural Damage Detection Using Convolutional Neural Networks, *Applied Sciences*, 9(16) (2019) 3376.
- [15] S. Varahram, P. Jalali, M.H. Sadeghi, S. Lotfan, Experimental Study on the Effect of Excitation Type on the Output-Only Modal Analysis Results, *Transactions of FAMENA*, 43(3) (2019) 37-52.
- [16] M.E. Torres, M.A. Colominas, G. Schlotthauer, P. Flandrin, A complete ensemble empirical mode decomposition with adaptive noise, in: *2011 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, IEEE, 2011, pp. 4144-4147.
- [17] J.-H. Yi, J.-S. Park, S.-H. Han, K.-S. Lee, Modal identification of a jacket-type offshore structure using dynamic tilt responses and investigation of tidal effects on modal properties, *Engineering Structures*, 49 (2013) 767-781.
- [18] S.-L. Hung, H. Adeli, Parallel backpropagation learning algorithms on Cray Y-MP8/864 supercomputer, *Neurocomputing*, 5(6) (1993) 287-302.
- [19] I. Goodfellow, Y. Bengio, A. Courville, *Deep learning*, MIT press, 2016.
- [20] U.R. Acharya, S.L. Oh, Y. Hagiwara, J.H. Tan, H. Adeli, Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals, *Computers in biology and medicine*, 100 (2018) 270-278.
- [21] E. Barton, C. Middleton, K. Koo, L. Crocker, J. Brownjohn, Structural finite element model updating using vibration tests and modal analysis for NPL Footbridge-SHM demonstrator, in: *Journal of Physics: Conference Series*, IOP Publishing, 2011, pp. 012105.
- [22] Z. Mousavi, M.M. Etefagh, M.H. Sadeghi, S.N. Razavi, Developing deep neural network for damage detection of beam-like structures using dynamic

- [34] Z. Mousavi, M. M. Etefagh, S. M. H. Sadeghi, S. N Razavi, Identification and Damage Detection of beam-like structure Using Vibration Signals Based on Simulated Model, Real Healthy State and Deep Convolutional Neural Network, AUT Journal of Mechanical Engineering, 2020, (in Persian).
- [35] S. Kim, J.-H. Choi, Convolutional neural network for gear fault diagnosis based on signal segmentation approach, Structural Health Monitoring, 18(5-6) (2019) 1401-1415.
- network design, Pws, Boston, (1996).
- [33] S. Sheykhivand, T.Y. Rezaii, A. Farzamia, M. Vazifekkhahi, Sleep Stage Scoring of Single-Channel EEG Signal based on RUSBoost Classifier, in: 2018 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET), IEEE, 2018, pp. 1-6.

چگونه به این مقاله ارجاع دهیم

Z. Mousavi, S. Varahram, M. M. Etefagh, M. Ho. Sadeghi, S. Na. Razavi, Damage detection of offshore jacket structure using dynamic responses based on simulated model, intact state of real model and deep auto-encoder neural network, *Amirkabir J. Mech Eng.*, 53(Special Issue 6)(2021) 3783-3808.

DOI: 10.22060/mej.2020.18553.6843



