

## تشخیص آسیب سازه‌ای با استفاده از شبکه عصبی عمیق و تحلیل زمان-فرکانس سیگنال‌های ارتعاشی

معصومه روحی<sup>۱</sup>، مریم صفاری<sup>۱</sup>، ساغر آقابابایی<sup>۱</sup>، مریم بیطرف<sup>۲\*</sup>

آیران، تهران، خیابان انقلاب، دانشگاه تهران، پردیس دانشکدگان فنی، دانشکده مهندسی عمران، ۴۱۷۶۱۳۱۳۱۱، دانشجوی کارشناسی ارشد.

آیران، تهران، خیابان انقلاب، دانشگاه تهران، پردیس دانشکدگان فنی، دانشکده مهندسی عمران، ۴۱۷۶۱۳۱۳۱۱، دانشیار.

\*پست الکترونیکی نویسنده مسئول: [maryam.bitaraf@ut.ac.ir](mailto:maryam.bitaraf@ut.ac.ir)

### چکیده

در سال‌های اخیر، یادگیری ماشین و به‌ویژه یادگیری عمیق به‌عنوان ابزارهایی توانمند در تشخیص آسیب‌های سازه‌ای و ارتقای ایمنی سازه‌ها مورد توجه گسترده قرار گرفته‌اند. در این پژوهش، رویکردی مبتنی بر یادگیری عمیق برای تشخیص آسیب در سازه‌ها ارائه می‌شود. داده‌های ارتعاشی دکل فولادی LUMO در آلمان در دو وضعیت سالم و آسیب‌دیده به‌عنوان داده‌های ورودی این مطالعه مورد استفاده قرار گرفتند. داده‌ها با استفاده از تبدیل موجک پیوسته<sup>۱</sup> به نگاشت‌های زمان-فرکانس (اسکالوگرام)<sup>۲</sup> تبدیل شدند و تصاویر حاصل به‌عنوان ورودی شبکه‌ی عصبی کانولوشنی<sup>۳</sup> عمیق با معماری ResNet-18 مورد استفاده قرار گرفتند. نتایج نشان داد که مدل ResNet-18 با بهره‌گیری از اتصالات باقیمانده<sup>۴</sup> و قابلیت یادگیری عمیق، عملکرد دقیقی در استخراج ویژگی‌های مرتبط با آسیب دارد، به‌گونه‌ای که دقت مدل برابر با ۹۷.۵٪، شاخص F1 برابر با ۹۴.۷٪ و معیار فراخوانی برابر با ۹۰٪ به‌دست آمد. همچنین به‌کارگیری Grad-CAM تفسیرپذیری مدل را افزایش داده و امکان شناسایی نواحی حساس به آسیب در اسکالوگرام‌ها را فراهم ساخت. یافته‌های این پژوهش نشان می‌دهد که چهارچوب پیشنهادی می‌تواند با دقت و اطمینان بالا آسیب‌های سازه‌ای را شناسایی کرده و به‌عنوان پایه‌ای برای توسعه سامانه‌های بلادرنگ پایش ارتعاشات در سازه‌های مهندسی به‌کار رود.

**کلمات کلیدی:** پایش سلامت سازه؛ یادگیری عمیق؛ اسکالوگرام؛ ResNet-18

<sup>۱</sup> Continuous Wavelet Transform (CWT)

<sup>۲</sup> Scalogram

<sup>۳</sup> Convolutional

<sup>۴</sup> Residual Connections


## ۱- مقدمه

پایش سلامت سازه به‌عنوان رویکردی نوین در مهندسی عمران، با هدف شناسایی زود هنگام آسیب‌ها، افزایش ایمنی و کاهش هزینه‌های نگهداری توسعه یافته است. با توجه به افزایش عمر سازه‌های زیرساختی و خطرات طبیعی مکرر، به‌کارگیری سامانه‌های پایش هوشمند به‌جای روش‌های سنتی ضرورتی اساسی در مدیریت چرخه عمر سازه‌هاست [۱]. روش‌های متداول بازرسی اگرچه کاربرد دارند، اما زمان‌بر، پرهزینه و وابسته به تجربه انسانی‌اند و توان نظارت پیوسته ندارند [۲]. از این‌رو، توسعه‌ی روش‌های خودکار و داده‌محور گامی کلیدی در ارتقای ایمنی و پایداری سازه‌ها به‌شمار می‌رود.

در سال‌های اخیر، رویکردهای داده‌محور مبتنی بر یادگیری ماشین و یادگیری عمیق تحولی چشمگیر در حوزه‌ی پایش سلامت سازه (SHM) ایجاد کرده‌اند [۳]. داده‌های ارتعاشی به‌دلیل حساسیت بالا به تغییرات سختی، جرم و میرایی، شاخصی مؤثر برای ارزیابی سلامت سازه محسوب می‌شوند. با این‌حال، تحلیل صرف در حوزه‌ی زمان یا فرکانس برای توصیف کامل رفتار دینامیکی یک سیستم کافی نیست؛ زیرا آسیب‌ها معمولاً در بازه‌های محدود زمانی- فرکانسی رخ می‌دهند. در این راستا، تحلیل‌های زمان- فرکانس، مانند تبدیل موجک پیوسته (CWT)، ابزارهایی کارآمد برای آشکارسازی تغییرات سیگنال و تولید نمایش تصویری (اسکالوگرام) انرژی آن به‌شمار می‌روند [۴،۵].

در میان مدل‌های یادگیری عمیق، شبکه‌های عصبی کانولوشنی (CNN) به‌دلیل توانایی بالا در استخراج ویژگی‌های محلی از داده‌های تصویری، ابزار مؤثری در تشخیص آسیب سازه‌ای هستند [۶]. با این‌حال، مدل‌های کم‌عمق در مواجهه با داده‌های نویزی یا محدود دچار بیش‌برازش می‌شوند. استفاده از معماری‌های عمیق‌تر نظیر ResNet با اتصالات میان‌بر، ضمن رفع مشکل افت گرادیان، امکان استخراج ویژگی‌های پیچیده‌تر را فراهم می‌سازد [۷]. همچنین، انتقال یادگیری از مدل‌های از پیش‌آموزش‌دیده موجب بهبود عملکرد در مجموعه‌داده‌های کوچک می‌شود [۸].

در این پژوهش، چهارچوبی مبتنی بر تبدیل موجک پیوسته (CWT) و مدل ResNet-18 برای تشخیص آسیب سازه‌ای توسعه داده شد. سیگنال‌های شتاب به نگاشت‌های زمان- فرکانس (اسکالوگرام) تبدیل و به‌عنوان ورودی مدل استفاده گردیدند. عملکرد و تفسیرپذیری مدل با استفاده از روش Grad-CAM ارزیابی شد تا نواحی حساس به آسیب به‌صورت بصری مشخص شوند. در این پژوهش از داده‌های ارتعاشی دکل فولادی LUMO با ارتفاع ۹ متر و وزن ۹۰ کیلوگرم استفاده شده است. این دکل شامل ۱۸ مکانیزم خرابی برگشت‌پذیر در شش تراز بوده و به ۹ شتاب‌سنج پیزوالکتریک، سه کرنش‌سنج و یک دماسنج مجهز است (شکل ۱). داده‌ها با نرخ ۱۶۵۱.۶ Hz ثبت شده و پارامترهای محیطی نظیر دما نیز به‌طور هم‌زمان پایش شدند [۹].



شکل ۱. دکل فولادی LUMO (سمت چپ) و نمای شماتیکی شامل ترازهای اندازه‌گیری (ML) و محل‌های ایجاد آسیب (DAM) (سمت راست) [۹].

## ۲- مرور تحقیقات پیشین

در سال‌های اخیر، استفاده از شبکه‌های عصبی کانولوشنی (CNN) برای شناسایی آسیب‌های سازه‌ای رشد چشمگیری یافته است. چا و همکاران [۶]، با به‌کارگیری معماری CNN توانستند ترک‌های سطحی بتن را بدون نیاز به استخراج ویژگی‌های دستی شناسایی کنند. با این حال، شبکه‌های کم‌عمق به دلیل ظرفیت محدود در استخراج الگوهای پیچیده‌ی زمان-فرکانس و حساسیت بالا به نویز، با پدیده‌ی بیش‌برازش در داده‌های محدود مواجه‌اند [۱۰].

به‌منظور رفع این محدودیت‌ها، پژوهش‌ها به سمت معماری‌های عمیق‌تر مانند Residual Network (ResNet) گرایش یافته‌اند که با بهره‌گیری از اتصالات باقیمانده، مشکل افت گرادیان را برطرف کرده و امکان استخراج ویژگی‌های سطح بالا از داده‌های ارتعاشی را فراهم می‌سازد [۷]. این معماری ضمن افزایش پایداری در برابر نویز، کارایی بالایی در کاربردهای پایش سلامت سازه (SHM) دارد [۸].

افزون بر این، استفاده از نمایش‌های زمان-فرکانس نظیر اسکالوگرام مبتنی بر تبدیل موجک پیوسته (CWT) به‌عنوان ورودی شبکه، موجب بهبود محسوس دقت مدل‌ها در شناسایی آسیب‌های موضعی شده است. در پژوهش سونگ و همکاران [۱۱]، ترکیب CWT و شبکه‌های CNN به همراه انتقال یادگیری از مدل‌های از پیش آموزش‌دیده مانند ResNet و AlexNet، امکان شناسایی مکان و شدت آسیب را با دقتی بیش از ۹۰٪ فراهم کرد. در مجموع، مرور پژوهش‌های اخیر بیانگر آن است که ترکیب نمایش‌های زمان-فرکانس (نظیر اسکالوگرام) با معماری‌های عمیق CNN به‌ویژه ResNet، موجب افزایش چشمگیر دقت، پایداری و قابلیت تعمیم مدل‌های SHM نسبت به روش‌های سنتی یا شبکه‌های کم‌عمق می‌شود.

## ۳- روش تحقیق

### ۳-۱ افزایش حجم داده‌ها برای آموزش مدل عمیق

داده‌های ارتعاشی سازه در قالب ماتریس‌های  $19 \times 165100$  جمع‌آوری شدند که شامل شتاب در دو راستای X و Y و دمای هم‌زمان بود. برای افزایش حجم و تنوع داده‌ها، هر سیگنال به ده بخش زمانی تقسیم شد تا تعداد نمونه‌ها از ۹۵۴ به ۹۵۴۰ افزایش یابد. به‌منظور جلوگیری از نشت داده، تمام ده بخش زمانی حاصل از یک سیگنال اولیه در یک ساختار چندنمونه‌ای (Bag) واحد قرار گرفتند و این‌ها بر اساس آزمایش‌های مستقل) با استفاده از شناسه‌های منحصر به فرد و Seed ثابت ۴۲ (بین مجموعه‌های آموزشی، اعتبارسنجی و آزمون تقسیم‌بندی شدند تا هیچ هم‌پوشانی بین مجموعه‌ها رخ ندهد. ساختار bag، که بر پایه رویکرد یادگیری چندنمونه‌ای (Multiple Instance Learning - MIL) طراحی شده، شامل مجموعه‌ای از اسکالوگرام‌های مرتبط با یک آزمایش است و اگر حداقل یکی از نمونه‌ها آسیب‌دیده باشد، کل bag به عنوان آسیب‌دیده برچسب‌گذاری می‌شود؛ این روش هم‌بستگی‌های مکانی-زمانی میان حسگرها را حفظ کرده و پایداری مدل در برابر بیش‌برازش را بهبود می‌بخشد.

### ۳-۲ استخراج ویژگی‌های زمان-فرکانس با تبدیل موجک پیوسته

سیگنال‌های ارتعاشی با تبدیل موجک پیوسته (CWT) و موجک Morlet [۴] در مقیاس ۱ تا ۱۲۷ تحلیل شدند تا تغییرات انرژی در زمان و فرکانس استخراج گردد؛ این محدوده مقیاس بر اساس نرخ نمونه‌برداری  $1651.6 \text{ Hz}$  و پوشش فرکانس‌های طبیعی سازه (از فرکانس‌های بالا تا پایین) انتخاب شده است [۹]. برای هر حسگر، اسکالوگرام دوبعدی انرژی تولید شد. تمام پردازش‌ها به صورت چندرسمانی انجام و حداقل و حداکثر انرژی محاسبه‌شده در کل مجموعه‌داده برای نرمال‌سازی استفاده شد تا مقیاس تمام اسکالوگرام‌ها یکنواخت شود.

### ۳-۳ تولید اسکالوگرام‌های زمان-فرکانس و آماده‌سازی ورودی شبکه‌ی ResNet-18

اسکالوگرام‌ها به تصاویر  $224 \times 224$  پیکسلی با نقشه‌ی رنگی Jet تبدیل شدند. ابتدا با نرمال‌سازی خطی و سپس با اصلاح گاما ( $\gamma=0.3$ )، محدوده‌ی انرژی تنظیم شد تا الگوهای ظریف‌تر نمایان شوند. برای هر تصویر، متادیتای حسگر، راستا و وضعیت سازه (سالم یا آسیب‌دیده) ذخیره شد تا در آموزش مدل استفاده گردد. این داده‌ها ورودی نهایی شبکه ResNet-18 محسوب شدند.

#### ۳-۳-۱ نرمال‌سازی خطی<sup>۵</sup>:

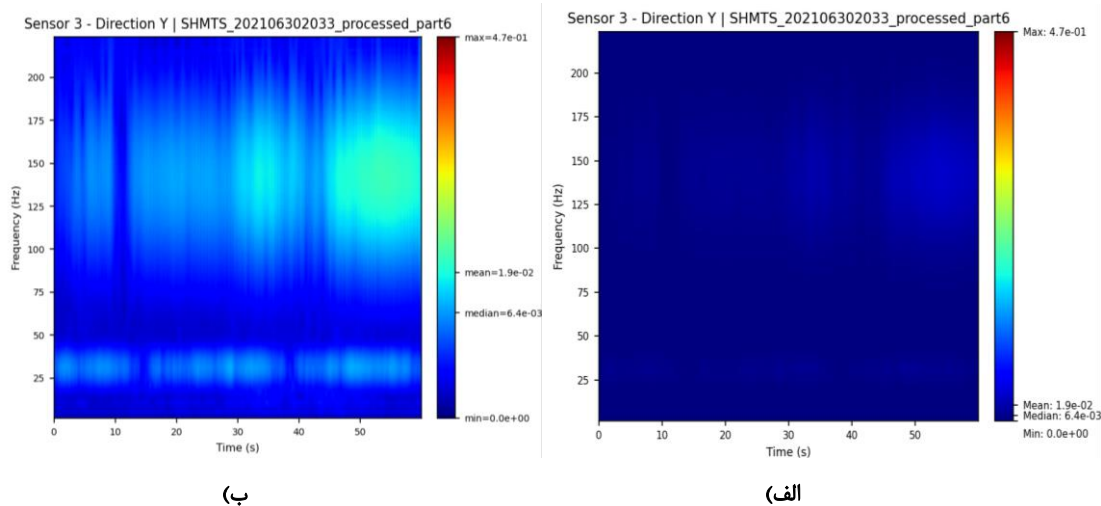
در این گام، مقادیر انرژی موجک با استفاده از حداقل و حداکثر انرژی محاسبه‌شده در کل مجموعه‌داده برای تمام مجموعه‌داده بازمقیاس شدند تا یکنواختی بصری بین اسکالوگرام‌ها حفظ شود. رابطه‌ی نرمال‌سازی به‌صورت زیر است:

$$E_{norm} = \frac{E - E_{min}^{global}}{E_{max}^{global} - E_{min}^{global}} \quad (1)$$


که در آن:

- $E$  انرژی موجک در هر نقطه‌ی زمان-فرکانس است،
- $E_{min}$  و  $E_{max}$  به ترتیب کمینه و بیشینه‌ی انرژی در کل مجموعه‌ی داده هستند.

مطابق شکل ۲، سه حالت متفاوت از پردازش اسکالوگرام ارائه شده است، در حالت (الف) نرمال‌سازی خطی موجب یکنواختی شدت انرژی در کل محدوده‌ی زمان-فرکانس شده است، در حالی که در حالت (ب) نرمال‌سازی غیرخطی، جزئیات نواحی با انرژی پایین برجسته‌تر شده‌اند. حالت (ج) نیز اسکالوگرام بدون نرمال‌سازی را نشان می‌دهد.



<sup>۵</sup>Linear Normalization



ج

شکل ۲. نمونه تصاویر اسکالوگرام در حالت‌های الف) نرمال خطی، ب) نرمال غیرخطی، ج) غیرنرمال

### ۳-۲ اصلاح گاما

به‌منظور افزایش دیدپذیری نواحی با انرژی پایین، مقدار نرمال‌شده با یک توان گاما کوچکتر از ۱ (در اینجا  $\gamma=0.3$ ) تغییر شکل داده شد. این تبدیل باعث افزایش روشنایی نواحی کم‌انرژی و تأکید بر جزئیات ضعیف اما مؤثر در تشخیص آسیب گردید.

$$E_{fainal} = (E_{norm})^\gamma \quad (2)$$

پس از نرمال‌سازی، اسکالوگرام‌ها با نقشه‌ی رنگی Jet ترسیم و به ابعاد  $224 \times 224$  پیکسل بازنمونه‌برداری شدند تا با ورودی شبکه‌ی ResNet-18 سازگار شوند. برای هر تصویر، فایل فراداده (Metadata) شامل شماره حسگر، راستا و برچسب سلامت سازه ایجاد و در قالب جدول CSV ذخیره شد. در نتیجه، داده‌های خام به مجموعه‌ای از اسکالوگرام‌های استاندارد و قابل پردازش توسط مدل‌های یادگیری عمیق مبتنی بر بینایی تبدیل گردیدند.

### ۳-۴ تقسیم داده‌ها و ساختاردهی در سطح

تصاویر به ساختارهای Bag در سطح آزمایش سازمان‌دهی و شناسه‌ی یکتا (Bag\_ID) برای هر مجموعه تعریف شد. برچسب سلامت هر Bag بر اساس وجود هر تصویر آسیب‌دیده تعیین گردید. داده‌ها با نسبت‌های ۷۰٪ آموزش، ۱۵٪ اعتبارسنجی و ۱۵٪ آزمون و بذر تصادفی ثابت (Seed=۴۲) تقسیم شدند تا نشت داده رخ ندهد.

### ۳-۵ بررسی نهایی تقسیم داده‌ها و کنترل نشت اطلاعات

به‌منظور اطمینان از صحت تقسیم‌بندی، فایل متادیتای مرحله‌ی قبل تحلیل شد تا از عدم وجود نمونه‌ی مشترک بین مجموعه‌های آموزشی، اعتباری و آزمایشی اطمینان حاصل گردد. نتایج تأیید کردند که هیچ نشت اطلاعاتی میان مجموعه‌ها وجود ندارد و توزیع داده‌ها متعادل و مستقل است.

### ۳-۶ طراحی معماری مدل MIL-ResNet-18

معماری مدل پیشنهادی بر پایه‌ی ResNet-18 و در قالب رویکرد یادگیری چندنمونه‌ای (MIL) توسعه یافت. در این ساختار، لایه‌های Fully Connected حذف و خروجی لایه‌های کانولوشنی به ماژول توجه شامل توابع tanh و softmax منتقل شد

تا ضرایب توجه ( $\alpha$ ) برای هر اسکالوگرام محاسبه شود. مؤلفه‌ی منفی واریانس ضرایب توجه ( $-\text{Var}(\alpha)$ ) نیز به تابع زیان افزوده شد تا تمرکز مدل بر نمونه‌های کلیدی تقویت گردد.

### ۷-۳ آماده‌سازی داده‌ها برای مدل MIL-ResNet-18

داده‌های اسکالوگرام در قالب کلاس BagDataset سازمان‌دهی و به تنسورهای ( $N \times 3 \times 224 \times 224$ ) تبدیل شدند. تصاویر با پارامترهای میانگین و انحراف معیار مجموعه‌ی ImageNet نرمال‌سازی و برای سه مجموعه‌ی آموزش، اعتبارسنجی و آزمون به مدل وارد گردیدند. تابع زیان وزن‌دهی شده بر اساس نسبت داده‌های سالم و آسیب‌دیده تعریف شد تا اثر عدم‌توازن داده‌ها کاهش یابد.

### ۸-۳ آموزش مدل بر روی مجموعه‌ی آزمون

فرآیند آموزش مدل با استفاده از الگوریتم Adam Optimizer با نرخ یادگیری اولیه ( $0.0001$ ) انجام گرفت و به‌منظور جلوگیری از نوسانات و افت ناگهانی در همگرایی، از راهبرد تنظیم پویا نرخ یادگیری بهره گرفته شد. ضریب منظم‌ساز  $\lambda_{reg}$  در بازه‌ی  $[0.1-0]$  از طریق جستجوی شبکه‌ای<sup>۷</sup> تعیین گردید و مقدار بهینه بر اساس بیشینه‌ی شاخص F1 انتخاب شد. مدل در طول ۵۰ دوره‌ی آموزشی<sup>۸</sup> آموزش داده شد و از مکانیزم توقف زودهنگام<sup>۹</sup> با آستانه‌ی ۷ دوره بدون بهبود در عملکرد اعتبارسنجی برای جلوگیری از بیش‌برازش استفاده گردید. در هر مرحله، معیارهای Accuracy، Recall، Precision و شاخص F1 به‌صورت پویا محاسبه و پایش شدند. در نهایت، مدل نهایی بر پایه‌ی بیشترین مقدار F1 در مجموعه‌ی اعتبارسنجی انتخاب گردید؛ معیاری که به دلیل حساسیت آن نسبت به عدم‌توازن داده‌ها، تصویر دقیق‌تری از توازن میان دقت و شناسایی آسیب ارائه می‌دهد. این رویکرد موجب بهبود قابل‌توجه در پایداری، تعمیم‌پذیری و تفسیرپذیری مدل در فرآیند تشخیص آسیب گردید.

### ۹-۳ تحلیل نتایج و ترسیم نمودارهای عملکرد

پس از تکمیل فرآیند آموزش، مدل ResNet-18 بر روی مجموعه‌ی آزمون نهایی ارزیابی شد تا عملکرد آن در تشخیص آسیب سازه‌ای مورد سنجش قرار گیرد. برای تضمین اعتبار نتایج و پرهیز از سوگیری‌های ناخواسته، تابع زیان با وزن‌دهی کلاس‌ها تنظیم شد و ضریب منظم‌ساز بهینه‌ی  $\lambda_{reg}$  اعمال گردید؛ این تدابیر روش‌شناختی برای ارائه خروجی‌های غیرمغرضانه، به‌ویژه در شرایط عدم توازن ذاتی در داده‌های آسیب، حیاتی بودند. معیارهای اصلی عملکرد شامل دقت، معیار فراخوانی (Recall) و شاخص گزارش شده‌اند.

مطابق شکل ۳، ماتریس آشفتگی عملکرد مدل را در تفکیک سازه‌های سالم و آسیب‌دیده منعکس می‌کند. از میان ۸۰ نمونه‌ی آزمون، مدل با موفقیت تمامی ۶۰ نمونه‌ی سالم و ۱۸ نمونه از ۲۰ نمونه‌ی آسیب‌دیده را به درستی طبقه‌بندی کرده است. این عملکرد، دقت بالای ۹۷.۵٪ را در تشخیص کلی وضعیت سازه تأیید می‌کند.

شکل ۴، این نتایج را به صورت بصری در قالب توزیع احتمال پیش‌بینی شده (نمودار چگالی KDE و هیستوگرام فراوانی) نمایش می‌دهد. توزیع کاملاً دوجبه‌ی احتمالات، حاکی از قاطعیت و ثبات تصمیم‌گیری مدل است. عدم وجود هرگونه داده در نزدیکی مرز تصمیم‌گیری (آستانه ۰.۵)، یک شکاف واضح میان دو کلاس ایجاد می‌کند. این ثبات بالا در تفکیک، نشان‌دهنده استحکام و ثبات آماری نتایج (که پاسخی جایگزین برای گزارش بازه اطمینان است) و توانایی قوی مدل در تعمیم‌پذیری به داده‌های ندیده‌شده

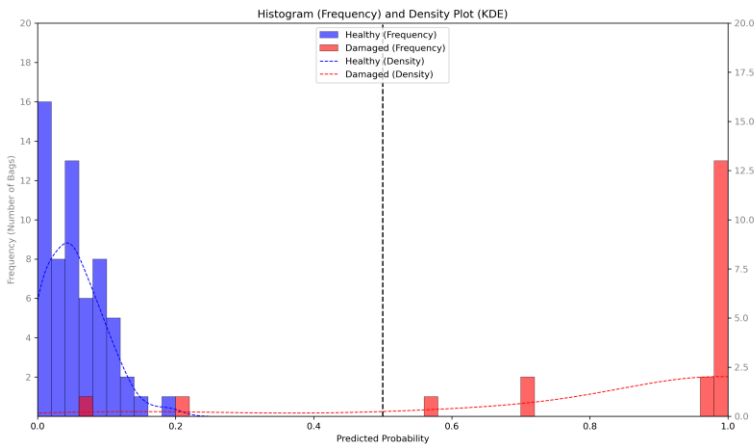
<sup>۷</sup>Gamma Correction

<sup>۸</sup>Grid Search


<sup>۹</sup>epochs

<sup>۱۰</sup>Early Stopping

است و فرضیه حفظ کردن (Memorization) را رد می‌کند. علاوه بر این، مقدار بالای AUC-ROC مدل نیز به‌عنوان یک شاخص کمی استاندارد و مقاوم در برابر سوگیری، عملکرد تفکیکی برتر مدل را در آستانه‌های مختلف تأیید می‌کند.



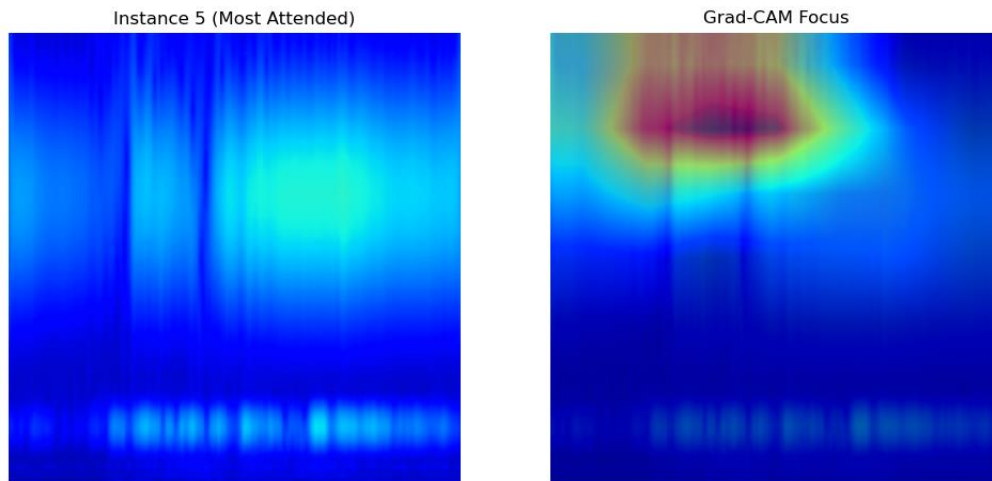
شکل ۴. نمودار هیستوگرام



شکل ۳. ماتریس آشفتگی

### ۳-۱۰ تحلیل نقشه‌های گرادیان فعال‌سازی

برای ارزیابی تفسیرپذیری مدل، از روش Grad-CAM جهت استخراج نقشه‌های گرادیان فعال‌سازی لایه‌های کانولوشنی استفاده شد. در این روش، گرادیان‌های خروجی نسبت به ویژگی‌های آخرین لایه کانولوشن محاسبه و با میانگین‌گیری وزنی، نواحی مؤثر بر تصمیم مدل شناسایی شدند. نقشه‌های حاصل به‌صورت Heatmap Overlay روی اسکالوگرام‌های ورودی نمایش داده شدند تا سهم هر ناحیه از تصویر در فرآیند تشخیص آسیب مشخص شود. نتایج نشان داد که مدل ResNet-18 پیشنهادی قادر است نواحی بحرانی مرتبط با آسیب را به‌دقت برجسته کرده و به درک بصری از الگوهای زمانی-فرکانسی مؤثر در تصمیم‌گیری مدل کمک کند.



شکل ۵. نمونه ای از Grad-CAM حالت آسیب دیده

#### ۴- نتیجه‌گیری

با تحلیل اسکالوگرام‌های زمان-فرکانس و ضرایب توجه مدل ResNet-18 مشخص شد که چارچوب پیشنهادی توانایی تفکیک میان وضعیت‌های سالم و آسیب‌دیده را با دقت قابل‌قبولی داراست. نقشه‌های گرادیان فعال‌سازی (GradCAM) نشان دادند که مدل در محدوده‌های خاصی از حوزه‌ی زمان و فرکانس تمرکز بیشتری دارد؛ این نواحی با الگوهای کلی پاسخ ارتعاشی سازه در شرایط آسیب‌دیده هم‌راستایی نسبی نشان می‌دهند. در حالت سالم، ضرایب توجه میان حسگرها توزیع یکنواختی داشتند، در حالی که در سناریوهای آسیب، مدل الگوهای غیریکنواخت و تغییرپذیری انرژی را ثبت نمود که بیانگر حساسیت آن نسبت به تغییر رفتار دینامیکی سازه است.

اگرچه در این مرحله مدل به‌صورت مستقیم مکان آسیب را تعیین نمی‌کند، اما نتایج حاکی از آن است که شبکه قادر است اثرات آسیب را از منظر تغییرات انرژی و توزیع فرکانسی به‌درستی تشخیص دهد. در سناریوهای با شدت آسیب بالاتر، مدل افزایش محسوس انرژی را شناسایی کرد.

به‌طور کلی، استفاده از تبدیل موجک پیوسته برای استخراج ویژگی‌های زمان-فرکانس و ترکیب آن با ساختار یادگیری چندمنونه‌ای مجهز به ماژول توجه، موجب بهبود تفسیرپذیری و پایداری مدل در فرآیند تشخیص آسیب گردید. مدل پیش‌ساخته ResNet-18 توانست با Accuracy حدود ۹۷.۵٪ و میانگین شاخص F1 برابر با ۹۴.۷٪، تمایز بین حالات سالم و آسیب‌دیده را در سطح آماری به‌درستی انجام دهد. در آینده، با بهینه‌سازی معماری و استفاده از داده‌های متنوع‌تر، انتظار می‌رود عملکرد مدل در زمینه‌ی شناسایی دقیق‌تر و مکانی آسیب نیز به‌طور چشمگیری ارتقا یابد.

#### ۵- محدودیت‌ها و مسیر پژوهش‌های آتی

پژوهش حاضر، با وجود دستیابی به دقت بالا در تشخیص کلی آسیب، زمینه‌های مهمی را برای تعمیق و توسعه در مطالعات آتی برجای می‌گذارد. برای تثبیت اعتبار و تعمیم‌پذیری نتایج، لازم است تحلیل‌های آماری دقیق‌تر (نظیر محاسبه‌ی بازه اطمینان) انجام گیرد. همچنین، به منظور توجیه قاطع برتری روش، انجام یک مقایسه‌ی سیستماتیک با روش‌های سنتی‌تر (SVM) و سایر معماری‌های عمیق (ResNet-50) ضروری است. در نهایت، لازم است برای پیشرفت به سمت مکان‌یابی آسیب، تحلیل کمی عمیق بر روی نقشه‌های تفسیرپذیری (Grad-CAM) و مقایسه‌ی آن‌ها با مکانیسم‌های آسیب واقعی (DAM) انجام شود. علاوه بر این، بررسی استفاده از نقشه‌های رنگی جایگزین به جای Jet، برای ارزیابی حساسیت مدل به الگوهای رنگی مصنوعی، موضوع مهمی برای تحقیقات آینده خواهد بود.

## مراجع

- [1] Farrar CR, Worden K. An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2007 Feb 15;365(1851):303-15.
- [2] Lynch JP, Loh KJ. A summary review of wireless sensors and sensor networks for structural health monitoring. *Shock and vibration digest*. 2006 Mar 1;38(2):91-130.
- [3] Gul M, Catbas FN. Statistical pattern recognition for Structural Health Monitoring using time series modeling: Theory and experimental verifications. *Mechanical Systems and Signal Processing*. 2009 Oct 1;23(7):2192-204.
- [4] Daubechies I. The wavelet transform, time-frequency localization and signal analysis. *IEEE transactions on information theory*. 2002 Aug 6;36(5):961-1005.
- [5] Rautela M, Chaturvedi S, Samantaray AK, Sharma A. Deep learning-based damage detection using continuous wavelet transform of vibration signals. *Structural Health Monitoring*. 2021;20(5):2164–2178.
- [6] Cha YJ, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*. 2017 May;32(5):361-78.
- [7] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition 2016* (pp. 770-778).
- [8] Fan G, Li J, Hao H. Vibration signal denoising for structural health monitoring by residual convolutional neural networks. *Measurement*. 2020 Jun 1;157:107651.
- [9] Wernitz S, Hofmeister B, Jonscher C, Griebmann T, Rolfes R. A new open-database benchmark structure for vibrationbased structural health monitoring. *Struct Control Health Monit [Internet]*. 2022
- [10] Xia H, Huang X. Research on Structural Damage Identification Based on Multiple Model Deep ResNet. In *3rd International Conference on Green Building, Civil Engineering and Smart City (GBCESC 2024)* 2025 May 19 (pp. 868-887). Atlantis Press.
- [11] Song X, Li D, Cho C. Image-based machine learning approach for structural damage detection through wavelet transforms. *Urban Lifeline*. 2024 May 6;2(1):4.