



شناسایی الگوهای ناهنجار داده‌های شتاب‌سنج در پل‌های کابلی خودایستا به روش یادگیری نظارت شده و با استفاده از تصویر میدان زاویه‌ای گرمیان

رستم رهگذر^۱، مریم بیطرف^{۲*}

^۱ ایران، تهران، خیابان انقلاب، دانشگاه تهران، دانشکده مهندسی عمران، ۱۴۱۷۶۱۳۱۳۱، دانشجوی دکتری.

^۲ ایران، تهران، خیابان انقلاب، دانشگاه تهران، دانشکده مهندسی عمران، ۱۴۱۷۶۱۳۱۳۱، استادیار.

*پست الکترونیکی نویسنده مسئول: maryam.bitarf@ut.ac.ir

چکیده

شناسایی آسیب سازه قبل از وقوع حادثه ضرورت دارد که در پایش سلامت سازه‌ها (SHM) این امر با نظارت بر وضعیت سازه‌ها و تشخیص ناهنجاری‌ها و آسیب‌های احتمالی در آن‌ها به کار می‌رود. یکی از ابزارهای کلیدی در SHM، استفاده از شتاب‌سنج‌ها برای جمع‌آوری داده‌های سازه است. اما این سنسورهای به دلایل مختلف از قبیل، نویز، خرابی سنسور، یا تغییرات شرایط محیطی و ... می‌توانند دچار ناهنجاری خارج از خرابی سازه بشوند. این ناهنجاری‌ها اگر شناسایی نشوند کل عملکرد SHM را با مشکل مواجه می‌کند و سیستم خرابی سنسور را بعنوان خرابی یک عضو سازه‌ای تشخیص دهد. این ناهنجاری‌ها می‌توانند منجر به تفسیر نادرست داده‌ها شود بنابراین این توسعه روش‌های کارآمد برای تشخیص و تصحیح ناهنجاری‌های سنسوری از اهمیت بالایی برخوردار است. در این مقاله انواع ناهنجاری سنسوری برای داده‌های پنج‌مارک پل واقعی ارزیابی می‌شوند. روش پیشنهادی بکارگیری یادگیری ماشین بصورت نظارت شده با شبکه عصبی پیچشی به همراه تصویر میدان زاویه‌ای گرمیان (GAF^1) در شناسایی ناهنجاری است. نتایج کارآمدگی و روش با دقت ۹۳ درصد را نشان می‌دهد. حاصل پژوهش، ارزیابی عملکرد روش پیشنهادی برای داده نرمال و ناهنجاری‌های مختلف است این روش برای داده نرمال و برخی ناهنجاری‌ها مثل، ناهنجاری روند^۲، عملکرد بسیار خوبی دارد. بکارگیری روش پیشنهادی می‌تواند در ارتقا دقت شبکه در شناسایی ناهنجاری موثر باشد.

کلمات کلیدی: ناهنجاری سنسور؛ پایش سلامت سازه‌ها؛ یادگیری ماشین نظارتی؛ شبکه عصبی پیچشی.

۱- مقدمه

امروزه بکارگیری پایش سلامت سازه‌ها (SHM) در سازه‌های عمرانی مانند پل‌ها، ساختمان‌های بلند، سدها و سازه‌های صنعتی و سکوه‌های دریایی، به یکی از حوزه‌های مهم مطالعاتی تبدیل شده است. SHM امکان تشخیص ناهنجاری‌ها و آسیب‌های احتمالی در سازه‌ها را فراهم می‌آورد و به این ترتیب، از وقوع حوادث ناگوار و هزینه‌های سنگین تعمیرات جلوگیری می‌کند. یکی از

¹ Gramian angular fields

² Trend

ابزارهای کلیدی در پایش سلامت سازه‌ها، شتاب‌سنج‌ها هستند. با جمع‌آوری داده‌های دینامیکی سازه می‌توان شرایط سازه و آسیب‌های احتمالی را شناسایی کرد و اقدامات لازم برای بهبود عملکرد سازه انجام داد. با این حال، شتاب‌سنج‌ها می‌توانند دچار ناهنجاری‌هایی شوند که ناشی از نویز، خرابی سنسور، یا تغییرات شرایط محیطی باشند. این ناهنجاری‌ها اگر به درستی شناسایی و تصحیح نشوند، می‌توانند کل عملکرد سیستم SHM را تحت تأثیر قرار دهند و منجر به تفسیر نادرست داده‌ها شود.

در این راستا، توسعه روش‌های کارآمد برای تشخیص ناهنجاری‌های سنسوری از اهمیت بالایی برخوردار است. روش پیشنهادی برای تشخیص این ناهنجاری‌ها بکارگیری یادگیری نظارت شده با کمک شبکه عصبی پیچشی است که در آن از تصاویر استفاده شوند که خود حاصل تبدیل شتاب به تصویر گرامیان است. به این ترتیب، دقت و کارایی نسبت به بکارگیری تنها تصویر شتاب در شبکه عصبی پیچشی بهبود بخشیده شد.

روش‌های یادگیری ماشین بر اساس نوع داده به دو دسته اصلی نظارت شده و بدون نظارت تقسیم می‌شوند. روش‌های یادگیری ماشین نظارت شده، نیازی به داده‌های برچسب‌دار است به این معنی که باید برای مرحله تعلیم شبکه، عنوان داده مشخص باشد. پریسی و همکاران^۳ [۱] با استفاده از مدل اجزای محدودی پل فولادی خرابی به شناسایی خرابی در سناریوهای مختلف پرداختند که از داده‌های کرنش به‌عنوان ورودی در شبکه عصبی پیچشی (CNN) استفاده کردند. دنگ و همکاران^۴ [۲] از مدل ماشین بردار پشتیبان (SVM)^۵ نظارت شده برای توسعه یک مدل رگرسیون بین خرابی ناشی از خستگی و بار ترافیک برای آویزهای پل معلق پرداختند. دنگ و همکاران [۸] به معرفی روش نظارت شده بر اساس ترکیب شبکه عصبی پیچشی و حافظه طولانی کوتاه مدت (LSTM) برای شناسایی خرابی در سازه‌ها برای SHM پرداختند. شبکه پیشنهادی بر اساس ظرفیت CNN در گرفتن اطلاعات محلی و توانایی برجسته شبکه LSTM برای یادگیری وابستگی‌های طولانی مدت زمانی طراحی شده است. لی‌یو و همکاران^۶ [۳] روشی برای شناسایی خرابی در سازه را پیشنهاد دادند. در آن از تابع انتقال^۷ به‌عنوان ورودی شبکه CNN یک بعدی استفاده شد. این روش را برای ورودی شبکه با ویژگی‌های دیگری مثل شتاب یا فرکانس پاسخ ارتعاش مقایسه کردند که در نهایت تابع انتقال کارایی بهتری داشت. مشابه این پژوهش، پارزیال و همکاران^۸ [۴] روشی برای شناسایی خرابی بصورت ترکیب شبکه CNN و روش خود رمزگذار با ورودی تابع انتقال برای آموزش شبکه پیشنهاد دادند. این روش را برای یک مدل عددی تیر تحت تغییرات دمایی ارزیابی کردند. روش پیشنهاد کارایی موثری در تشخیص خرابی داشته است. ورودی‌های شبکه می‌تواند غیر از داده شتاب باشد.

محققین پژوهش‌هایی برای بررسی ناهنجاری در پاسخ را به روش یادگیری نظارت شده ارائه کردند. زی‌اومینگ و همکاران^۹ [۵] با استفاده از روش نظارت شده به شناسایی شش نوع از ناهنجاری‌های مختلف در سنسور پرداختند. آن‌ها یک شبکه مراقبت باقیمانده^{۱۰} را پیشنهاد می‌کنند که از مکانیسم یادگیری باقیمانده برای بهبود کارایی و دقت طبقه‌بندی استفاده کردند. روش پیشنهادی را برای دو بنچمارک از داده‌های واقعی پل ارزیابی کردند که نتایج عملکرد خوب روش را نشان دادند.

بو و همکاران^{۱۱} [۶] یک شبکه عصبی بازگشتی بصورت نظارت شده برای شناسایی چهار نوع ناهنجاری در پاسخ سنسورها معرفی کردند و روش پیشنهادی را برای یک مدل آزمایشگاهی صحت‌سنجی کردند. رویکرد پیشنهادی محققین بدین نحو بود که ابتدا شبکه آموزش را دادند و سپس یک آستانه‌ای را به‌عنوان حد مجاز ناهنجاری بصورت توزیع نرمال احتمالاتی در نظر گرفتند. زنگ و لی^{۱۲} [۷] به شناسایی پنج نوع ناهنجاری در پاسخ شتاب به کمک روش نظارت شده پیشنهادی بر پایه CNN پرداختند. روش پیشنهادی را برای داده‌های پل واقعی ارزیابی کردند که روش عملکرد مطلوبی داشته است. تانگ و همکاران^{۱۳} [۸] به طور مستقیم حوزه‌های زمان و فرکانس شتاب خام را در یک تصویر به‌عنوان ورودی شبکه CNN استفاده کردند. یک شبکه با پنج لایه طراحی

³ Parisi et al.

⁴ Deng et al.

⁵ Support Vector Machine

⁶ Liu et al.

⁷ Transmissibility functions

⁸ Parziale et al.

⁹ Xiaoming et al.

¹⁰ Residual attention

¹¹ Bo et al.

¹² Zhang and Lei

¹³ Tang et al.


کردند که می‌تواند به طور دقیق شش الگوی ناهنجاری داده‌ها را از پل‌های کابلی با دهانه بزرگ طبقه بندی کند. چو و همکاران^{۱۴} [۹] به شناسایی شش نوع ناهنجاری در پاسخ شتاب با روش‌های نظارت شده، پرداختند. روش‌ها شامل: شبکه عصبی کانولوشن مبتنی بر طیف، فرکانس زمان، تاریخچه زمانی بصورت جداگانه، شبکه تشخیص الگوی مبتنی بر آمار و یک مدل پیشنهادی مبتنی بر شبکه عصبی آموزش گروهی^{۱۵} می‌باشند. روش‌ها را برای داده‌های شتاب پل واقعی واقع در چین ارزیابی کردند که در نهایت نتایج مطلوبی گرفتند. بائو و همکاران^{۱۶} [۱۰] ویژگی، نقشه مقیاس خاکستری^{۱۷} در دامنه زمانی شتاب خام را به‌عنوان ورودی شبکه یک بعدی CNN برای شناسایی شش نوع ناهنجاری داده یک پل کابلی استفاده کردند. آزمایشات نشان دادند که روش پیشنهادی می‌تواند به دقت ۸۷ درصد دست یابد. با مشاهده اکثر پژوهش‌های در شناسایی ناهنجاری‌ها، ضرورت پژوهش بیشتر برای ارائه راهکار در افزایش دقت مطلوب در کنار کاهش هزینه محاسباتی، دیده می‌شود. برای مثال معماری ساده VGG در CNN مقدار ۱۳۸ میلیون پارامتر برای تعلیم دارد و این مقاله هدف دارد که با انتخاب ویژگی حساس مناسب بعنوان ورودی بتواند دقت در کنار کاهش حجم محاسباتی در تعلیم شبکه عصبی، ارائه نماید.

۲- روش تحقیق

در این فصل روش‌ها و موضوعات، داده‌های بنچمارک پل واقعی، انواع ناهنجاری سنسور و روش یادگیری ماشین بررسی می‌شوند که می‌تواند به کمک آن‌ها مسئله تحقیق را حل کرد.

۲-۱ بنچمارک پل ساتونگ (Sutong)

در این مقاله برای ارزیابی ناهنجاری‌ها از داده‌های پل ساتونگ SCB استفاده می‌شود. این پل با دهانه اصلی ۱۰۸۸ متر، طولانی‌ترین پل کابلی در چین است. همچنین این پل طولانی‌ترین پل کابلی جهان بود که در می ۲۰۰۸ افتتاح شد. یک سیستم جامع SHM از زمان تکمیل آن بر روی این پل با هدف ارزیابی شرایط عملیاتی پل SCB، نصب شده است. در سیستم حسگرها، هفت جفت شتاب‌سنج دو محوره در عرشه پل نصب شده‌اند که در میان آنها پنج جفت به‌طور یکنواخت در دهانه اصلی و دو جفت دیگر به ترتیب در بخش‌های میانی دو دهانه جانبی توزیع شده‌اند. در مجموع ۳۸ کانال داده شتاب در پل قرار گرفته که مکان شتاب‌سنج‌ها به تفصیل در شکل (۱) نشان داده شده است. فرکانس نمونه برداری از شتاب‌سنج‌ها ۲۰ هرتز است. داده‌های شتاب برای دو ماه در اختیار می‌باشد، این داده‌ها دارای ۶ نوع ناهنجاری سنسوری هستند، که در این مقاله ناهنجاری داده‌ها ارزیابی می‌شوند. لازم به ذکر است.



شکل ۱: آرایش سنسورهای شتاب‌سنج در پل ساتونگ [۱۱]

¹⁴ Chou et al.

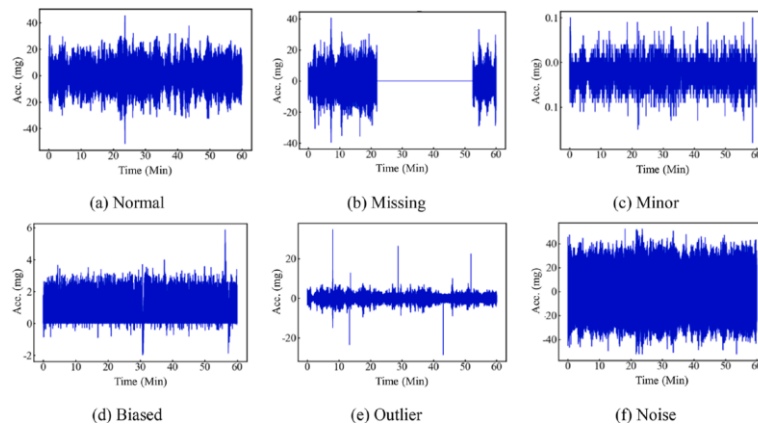
¹⁵ Ensemble neural network

¹⁶ Bao et al.

¹⁷ Greyscale map

۲-۲ انواع ناهنجاری‌های سنسوری

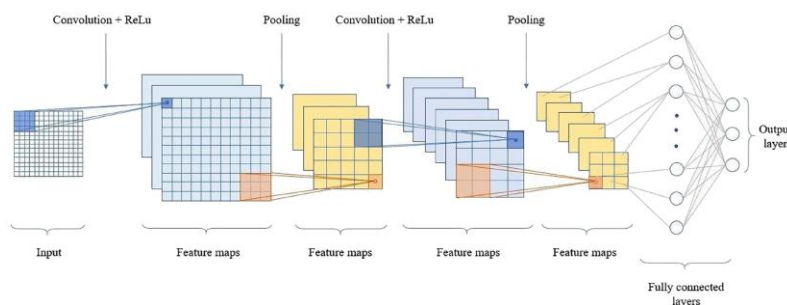
ناهنجاری در داده را می‌توان بدین نحو تعریف کرد که اگر داده با حالت سازه سالم تفاوت داشته باشد یا فاصله بگیرد که ناشی از خرابی نباشد، داده ناهنجار است. در این رساله ناهنجاری‌هایی بررسی می‌شوند که ناشی از تغییرات به دلیل خرابی خود سنسور باشد. ناهنجاری داده می‌تواند دلایل مختلفی از تغییر ولتاژ در سنسور تا تغییرات شرایط محیطی داشته باشد. وقوع هر تغییراتی در داده‌ها به معنای آن نیست که لزوماً خرابی در سازه رخ داده است بلکه همانطور که گفته شد می‌تواند دلایل دیگری داشته باشد. ناهنجاری می‌تواند خطا در ثبت و بروز علائمی که مانع در تشخیص خرابی سازه از پاسخ سنسور باشد. برخی از انواع ناهنجاری‌های سنسور در شکل (۲) نشان داده شده است. همانطور که مشاهده می‌شود هر کدام از ناهنجاری‌ها رفتار مختص خود را دارند.



شکل ۲: انواع ناهنجاری‌های سنسور [۵]

۲-۳ شبکه عصبی پیچشی

شبکه عصبی پیچشی (CNN)، شبکه‌های عصبی عمیق (DNN) هستند که از لایه‌های ناهمگن تشکیل شده‌اند که در اصل برای پردازش داده‌ها، در قالب آرایه‌های متعدد طراحی شده‌اند. معماری یک CNN استاندارد از سه زیر گروه اصلی تشکیل شده است: لایه ورودی، لایه‌های پنهان و لایه خروجی (شکل ۳). در معماری CNN، چند لایه اول معمولاً بین لایه‌های کانولوشن و لایه‌های ادغام متناوب می‌شوند و چند لایه آخر نزدیک به لایه خروجی از لایه‌های مترابست تشکیل می‌شوند. همانطور که در شکل ۲ نشان داده شده است، معمولاً دو یا سه مرحله کانولوشن، غیرخطی بودن و ادغام روی هم قرار می‌گیرند و به دنبال آن لایه‌های کانولوشن پیچیده تر و کاملاً متصل قرار دارند. مقادیر وزن‌ها در تمام بانک‌های فیلتر نتیجه یک فرآیند آموزشی است که به CNN اجازه می‌دهد تا رابطه ورودی و خروجی را یاد بگیرد. گرادیان پس انتشار از طریق CNN یک تکنیک آموزشی رایج است. بسیاری از معماری‌های موثر CNN در طول سال‌های گذشته با اهداف مختلف (تشخیص تصویر، تشخیص اشیا و غیره) ارائه شده‌اند.



شکل ۳: نمونه‌ای از معماری شبکه عصبی پیچشی [۴]

۲-۳-۱ لایه کانولوشن

در لایه کانولوشن، داده‌ها در نقشه‌های ویژگی سازمان‌دهی می‌شوند که عناصر آن حاصل جمع وزنی محلی لایه هستند. هر کدام از آن‌ها از طریق مجموعه‌ای از وزن‌ها به نام فیلتر بانک (یا کرنل) به وصله‌های محلی در نقشه‌های ویژگی لایه قبلی متصل

می‌شوند. برای هر نقشه ویژگی یک فیلتر وجود دارد و بنابراین، نقشه ویژگی‌های مختلف فیلتر متفاوتی دارند. یک ماتریس بایاس به نقشه ویژگی جمع می‌شود و یک عملیات غیرخطی مانند ReLU دنبال می‌شود. بنابراین، نقش لایه کانولوشن استخراج ویژگی‌های سطح بالا و به طور همزمان کاهش ابعاد ورودی ارائه شده به شکلی است که پردازش توسط لایه‌های زیر آسان تر باشد [۴]. در یک لایه کانولوشن، ابتدا لایه ورودی با فیلترهای قابل یادگیری، ترکیب می‌شود تا نقشه‌های ویژگی میانی را به صورت رابطه (۱) تشکیل دهد:

$$x_j^l = f\left(\sum_{i=1}^I x_i^{l-1} * F_{ij}^l + b_j^l\right), j \in [1, j] \quad (1)$$

که در آن x_j^l - j -امین کانال لایه l است. F_{ij}^l - i -امین کانال فیلتر j در لایه l است. b_j^l یک بایاس برای فیلتر j برای لایه l است. I و J به ترتیب مقادیر کانال لایه $l-1$ و l هستند.

۲-۳-۲ لایه ادغام

همانند لایه کانولوشن، لایه ادغام مسئول کاهش اندازه فضای داده‌های کانولوشن است. لایه ادغام ممکن است برای استخراج ویژگی‌های غالب مورد استفاده قرار گیرد. هدف اصلی برای یک لایه ادغام، کاهش اندازه درون صفحه نقشه‌های ویژگی با کاهش نمونه سازی این پیکسل‌ها با استفاده از یک استراتژی خاص است. این رویکرد به نمایش عمیق‌تر در لایه‌های متوالی کمک می‌کند و از برازش بیش از حد جلوگیری می‌کند. نقشه‌های ویژگی به طور مستقل در هر کانال با انتخاب مقادیر نماینده در فیله‌های پذیرنده زیر نمونه برداری می‌شوند.

$$x_j^l = x_i^{l-1} * P_i^l, i \in [1, I] \quad (2)$$

که در آن x_j^l کانال j -امین لایه l است. P_i^l کانال i -ا پراتور ادغام در لایه l است. I مقدار کانال هر دو لایه $l-1$ و l است. اندازه درون صفحه نقشه‌های ویژگی خروجی بصورت زیر محاسبه می‌شود.

$$D_{out} = (D_{in} - P_{pool}) / S_{pool} + 1 \quad (3)$$

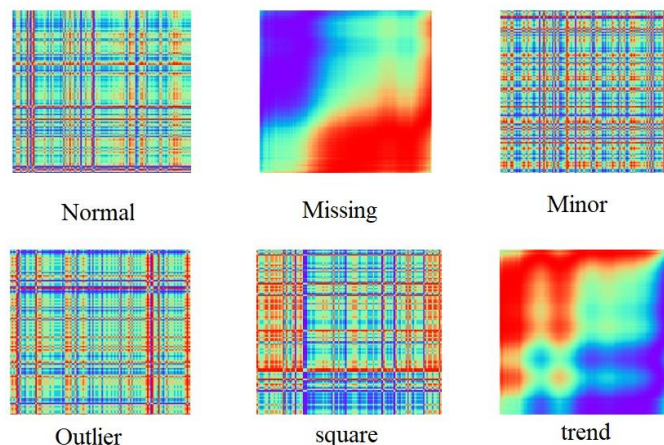
که در آن P_{pool} طول ضلع عملگر ادغام است (فرض کنید اپراتور مربعی به اندازه $P_{pool} \times P_{pool}$ باشد) و S_{pool} گام ارتفاع و عرض است.

۲-۴ ماتریس گرمیان^{۱۸}

در جبر خطی، ماتریس گرمیان میزان وابستگی دو بردار را بررسی می‌کند. برای دو بردار مشابه مقادیر نزدیک به یک می‌شود که معرف وابستگی است و اگر مقادیر نزدیک به صفر داشته باشد به معنای استقلال خطی دو بردار است. بصورت رابطه (۴) ماتریس قابل تشکیل است.

$$GAF = \begin{bmatrix} \cos(\varphi_1 - \varphi_1) & \cos(\varphi_1 - \varphi_2) & \dots & \cos(\varphi_1 - \varphi_n) \\ \cos(\varphi_2 - \varphi_1) & \cos(\varphi_2 - \varphi_2) & \vdots & \cos(\varphi_2 - \varphi_n) \\ \dots & \dots & \dots & \dots \\ \cos(\varphi_n - \varphi_1) & \cos(\varphi_n - \varphi_1) & \dots & \cos(\varphi_n - \varphi_n) \end{bmatrix} \quad (4)$$


در این رابطه، φ_i مقدار زاویه حاصل ضرب داخلی دو بردار برای هر مولفه است. در نهایت می‌توان ماتریس GAF را با توجه به اینکه مقداری بین صفر تا یک است بصورت تصویر رنگی در نظر گرفت. در شکل زیر نمونه‌هایی از تصویر برای هر ناهنجاری نشان داده شده است، این تصاویر تولید شده بعنوان ورودی شبکه عصبی خواهد بود.



شکل ۴: نمونه هایی از تصویر برای هر ناهنجاری

۲-۵ روش پیشنهادی تحقیق

باتوجه به مرور ادبیات فنی ضرورت افزایش دقت در کنار کاهش حجم محاسبات دیده شد. روش پیشنهادی در این مقاله شامل دو بخش می‌شود. در بخش اول برای داده‌های شتاب ماتریس گرمیان (GAF) محاسبه می‌شود. سپس در گام دوم تصویر GAF بعنوان ورودی شبکه عصبی پیچشی داده می‌شود و شبکه باتوجه به برجسب‌هایی که از هر داده دارد شروع به تعلیم شدن می‌کند تا در نهایت به دقت نهایی خود برسد. یک معماری ساده برای شبکه پیچشی مطابق شکل زیر در نظر گرفته شده است. این معماری دارای، ۱۵ میلیون پارامتر برای تعلیم است در حالیکه معماری‌های شبکه عصبی پیچشی از نوع ساده مثل VGG دارای ۱۳۵ میلیون پارامتر است.

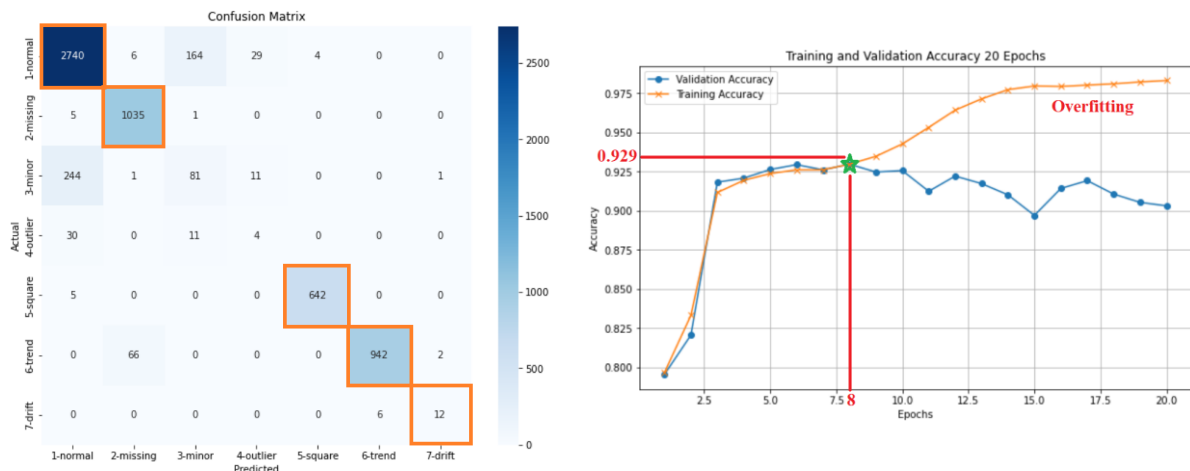


شکل ۵: معماری مورد استفاده در این مقاله

۳- نتایج و دستاوردها

در مقاله برای شناسایی ناهنجاری‌های ناشی از سنسور ابتدا داده‌ها بصورت تصویر GAF تبدیل شدند و در شبکه عصبی پیچشی با معماری خود بسیار ساده برای داده‌های شتاب‌سنج پل ساتونگ، تعلیم داده شد. بدین نحو که داده‌ها به‌همراه برجسب مربوطه به شبکه داده می‌شود. سپس بعد از تعلیم شبکه قادر است ناهنجاری‌ها را شناسایی کند. در شکل (۶)، تاریخچه عملکرد شبکه برای داده‌های تست و داده‌های تعلیم ارائه شده است. مشاهده می‌شود از دوره ۸ دقت داده‌های تست کاهش می‌یابد در حالیکه دقت داده‌های تعلیم افزایش می‌یابد، در نتیجه بیش برآزش رخ می‌دهد و ملاک دقت ۹۸ درصد تعلیم نیست. ملاک نهایی دقت شبکه ۹۲,۹ درصد است، این دقت در مقایسه با دقت پژوهش‌های انجام شده که به حداکثر دقت ۸۷ درصد، دقت قابل قبولی می‌باشد. نکته قابل

ذکر دیگر همگرایی با سرعت بالا بود که شبکه با ۸ دوره به نتیجه نهایی، در حالیکه در عمده پژوهش‌ها حداقل ۵۰ دوره انجام می‌شود که به معنی افزایش هزینه محاسباتی است.



شکل ۶: (۱) نمودار تاریخچه دقت تعلیم به تست. (۲) ماتریس درهم ریختگی

برای بررسی دقیق عملکرد در ناهنجاری مختلف، نتایج در ماتریس درهم ریختگی رسم شدند. در شکل ماتریس درهم ریختگی، ناهنجاری‌هایی که روی قطر ماتریس بیشترین مقدار را دارند به معنای عملکرد خوب شبکه برای آن ناهنجاری است. روش پیشنهادی برای داده‌های نرمال، فقدان، مربعی، روند و انحراف می‌تواند بکار گرفته شود اما ناهنجاری شماره سه و چهار را به خوبی تشخیص نداده است.

جدول ۱. ارزیابی عملکرد شبکه در ناهنجاری‌های مختلف

شماره	نوع داده	دقت (Precision)	یادآوری (Recall)	معیار (f1-score)
۱	نرمال	۰٫۹۱	۰٫۹۳	۰٫۹۲
۲	فقدان	۰٫۹۳	۰٫۹۹	۰٫۹۶
۳	ناچیز	۰٫۳۲	۰٫۲۴	۰٫۲۷
۴	برون داده	۰٫۰۹	۰٫۰۹	۰٫۰۹
۵	مربع	۰٫۹۹	۰٫۹۹	۰٫۹۹
۶	روند	۰٫۹۹	۰٫۹۳	۰٫۹۶
۷	انحراف	۰٫۸۰	۰٫۶۷	۰٫۷۳
		صحت (Accuracy)		
		۰٫۹۳		

مطابق جدول، برای معیار دقت، یادآوری و معیار f1، ۴ نوع داده به خوبی درصد بالای ۹۰ درصد را دارند. آنچه از نتایج به خوبی مشاهده می‌شود آن است نوع ناهنجاری روی عملکرد شبکه نتیجه بسیاری دارد. راهکار کاهش خطا، افزایش داده برای ناهنجاری‌هایی که عمل کرد پایین دارند. ارزیابی مشابهی می‌توان برای سنجش اهمیت داده در تعیین الویت افزایش داده (Data Augmentation) داشت. دقت شبکه علاوه بر آنکه معماری بسیار ساده و سبکی دارد توانست با دقت قابل قبول ۹۳ درصد، ناهنجاری‌ها را شناسایی کند. شبکه قادر است الگوهای مهم و متمایز بین داده سالم با داده‌های ناهنجاری را تشخیص بدهد. نتایج پژوهش در چهار محور قابل بررسی هستند.

۱. لزوماً بکارگیری معماری پیچیده و پر هزینه منجر به افزایش دقت بیشتر از معماری ساده نمی‌شود.
۲. بکارگیری GAF می‌تواند یک شاخص مناسب بعنوان ورودی شبکه عصبی پیش‌بینی برای شناسایی ناهنجاری باشد.
۳. نوع ناهنجاری در عملکرد شبکه بسیار مهم است. از بین انواع ناهنجاری داده جزئی، بدلیل شباهت با داده نرمال، دشوارترین نوع ناهنجاری در شناسایی است.

۴. شبکه به نوع ورودی و ویژگی (feature) بستگی دارد و بکارگیری GAF می‌تواند در کنار افزایش سرعت همگرایی دقت نهایی را نیز افزایش دهد.

۴- جمع بندی

در این مقاله، تلاش شده است تا انواع ناهنجاری‌های سنسوری برای داده‌های بنچمارک پل واقعی ارزیابی شوند و با بکارگیری روش CNN، یک روش نظارت شده برای شناسایی داده‌های ناهنجر از داده‌های سالم ارائه شد. نتایج این تحقیق نشان می‌دهد که بکارگیری GAF می‌تواند سرعت همگرایی به دقت نهایی را افزایش دهد. نوع ناهنجاری روی عملکرد شاخص ورودی موثر است. شبکه توانست به دقت ۹۳ درصد برسد. این روش‌ها نه تنها دقت و کارایی سیستم‌های SHM را افزایش می‌دهند، بلکه هزینه‌های نظارت و تعمیرات را نیز به طور قابل توجهی کاهش می‌دهند. بنابراین، پژوهش‌های بیشتر در این زمینه می‌تواند به توسعه و بهبود روش‌های موجود کمک کرده و به مهندسان عمران ابزارهای جدید و موثری برای پایش سلامت سازه‌ها ارائه دهد.

مراجع

1. Parisi F, Mangini AM, Fanti MP, Adam JM. Automated location of steel truss bridge damage using machine learning and raw strain sensor data. *Autom. Constr.* 2022;138:104249.
2. Deng Y, Zhang M, Feng DM, Li AQ. Predicting fatigue damage of highway suspension bridge hangers using weigh-in-motion data and machine learning. *Struct. Infrastruct. Eng.* [Internet] 2020 [cited 2023 Jul 30];17:233–48. Available from: <https://www.tandfonline.com/doi/abs/10.1080/15732479.2020.1734632>
3. Liu T, Xu H, Ragulskis M, Cao M, Ostachowicz W. A Data-Driven Damage Identification Framework Based on Transmissibility Function Datasets and One-Dimensional Convolutional Neural Networks: Verification on a Structural Health Monitoring Benchmark Structure. *Sensors* [Internet] 2020 [cited 2023 Jul 31];20:1059. Available from: <https://www.mdpi.com/1424-8220/20/4/1059/htm>
4. Parziale M, Lomazzi L, Giglio M, Cadini F. Vibration-based structural health monitoring exploiting a combination of convolutional neural networks and autoencoders for temperature effects neutralization. *Struct. Control Heal. Monit.* [Internet] 2022 [cited 2023 Jul 31];29:e3076. Available from: <https://onlinelibrary.wiley.com/doi/full/10.1002/stc.3076>
5. Lei X, Xia Y, Wang A, Jian X, Zhong H, Sun L. Mutual information based anomaly detection of monitoring data with attention mechanism and residual learning. *Mech. Syst. Signal Process.* 2023;182:109607.
6. Liu B, Xu Q, Chen J, Li J, Wang M. A New Framework for Isolating Sensor Failures and Structural Damage in Noisy Environments Based on Stacked Gated Recurrent Unit Neural Networks. *Buildings* [Internet] 2022 [cited 2023 Jul 31];12:1286. Available from: <https://www.mdpi.com/2075-5309/12/8/1286/htm>
7. Zhang Y, Lei Y. Data Anomaly Detection of Bridge Structures Using Convolutional Neural Network Based on Structural Vibration Signals. *Symmetry (Basel)*. [Internet] 2021 [cited 2023 Jul 31];13:1186. Available from: <https://www.mdpi.com/2073-8994/13/7/1186/htm>
8. Tang Z, Chen Z, Bao Y, Li H. Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring. *Struct. Control Heal. Monit.* [Internet] 2018 [cited 2023 Jul 30];26:e2296. Available from: <https://onlinelibrary.wiley.com/doi/full/10.1002/stc.2296>
9. Chou JY, Fu Y, Huang SK, Chang CM, Chou JY, Fu Y, et al. SHM data anomaly classification using machine learning strategies: A comparative study. *Smart Struct. Syst.* [Internet] 2022 [cited 2023 Jul 31];29:77. Available from: <http://techno-press.org/content/?page=article&journal=sss&volume=29&num=1&ordernum=8>
10. Bao Y, Tang Z, Li H, Zhang Y. Computer vision and deep learning-based data anomaly detection method for structural health monitoring. *Struct. Heal. Monit.* [Internet] 2018 [cited 2023 Jul 30];18:401–21. Available from: <https://journals.sagepub.com/doi/abs/10.1177/1475921718757405?journalCode=shma>
11. Mao JX, Wang H, Fu YG, Spencer BF. Automated modal identification using principal component and cluster analysis: Application to a long-span cable-stayed bridge. *Struct. Control Heal. Monit.* 2019;26:1–20.