



## شناسایی الگوهای ناهنجار داده‌های شتاب‌سنج در پل‌های کابلی خود ایستا به روش یادگیری غیرنظارت شده

رستم رهگذر<sup>ا</sup>، مریم بیطرف<sup>ب\*</sup>

ایران، تهران، خیابان انقلاب، دانشگاه تهران، دانشکده مهندسی عمران، ۱۴۱۷۶۱۳۱۳۱، دانشجوی دکتری<sup>ا</sup>.

ایران، تهران، خیابان انقلاب، دانشگاه تهران، دانشکده مهندسی عمران، ۱۴۱۷۶۱۳۱۳۱، استادیار<sup>ب</sup>.

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

### چکیده

امروزه پایش سلامت سازه‌ها (SHM) به یک حوزه مهم در مهندسی عمران، به منظور ارزیابی و 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 در تشخیص آسیب‌ها است. اما این سنسورها به دلایلی 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 ممکن است خرابی سنسور را بعنوان خرابی یک عضو سازه‌ای تشخیص و گزارش دهد. این ناهنجاری‌ها می‌توانند منجر به تفسیر نادرست داده‌ها و در نتیجه تصمیم‌گیری‌های نادرست شوند. بنابراین، توسعه روش‌های کارآمد برای تشخیص و تصحیح ناهنجاری‌های سنسوری از اهمیت بالایی برخوردار است. در این مقاله انواع ناهنجاری سنسورها برای داده‌های بنچمارک پل واقعی ارزیابی می‌شوند و با بکارگیری روش هوش مصنوعی خودرمزگذار، یک روش غیرنظارت شده برای شناسایی داده با انواع ناهنجاری از داده سالم معرفی می‌شود. در آن از دو متره، خطای بازسازی و تابع برآورد احتمال برای تشخیص ناهنجاری استفاده شد. نتایج نشان می‌دهد روش بکارگیری تابع برآورد احتمال بسیار در افزایش دقت کارآمد است و روش پیشنهادی می‌تواند کارآیی موثری در شناسایی ناهنجاری‌ها باشد. بعنوان یک روش غیرنظارت شده کارآمد بکار گرفته شود.

**کلمات کلیدی:** ناهنجاری سنسور؛ پایش سلامت سازه‌ها؛ پل؛ یادگیری ماشین غیرنظارتی.

### ۱- مقدمه

پایش سلامت سازه‌ها (SHM) به عنوان یکی از حوزه‌های حیاتی در مهندسی عمران، نقش بسزایی در تضمین ایمنی و پایداری سازه‌ها ایفا می‌کند. با توجه به افزایش تعداد سازه‌های بزرگ و پیچیده مانند پل‌ها، ساختمان‌های بلند، سدها، سازه‌های صنعتی و سکوهای دریایی، نیاز به روش‌های پیشرفته برای ارزیابی و نظارت بر وضعیت این سازه‌ها بیش از پیش احساس می‌شود. SHM با استفاده از تکنولوژی‌های نوین و ابزارهای پیشرفته، 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 ابزارهای کلیدی در پایش سلامت سازه‌ها، شتاب‌سنج‌ها هستند که با جمع‌آوری داده‌های دینامیکی سازه، اطلاعات ارزشمندی در مورد رفتار سازه و شرایط کنونی آن در برابر بارهای مختلف محیطی مثل بار ترافیکی یا شرایط محیطی ارائه می‌دهند. این داده‌ها به مهندسان کمک می‌کند تا شرایط سازه و آسیب‌های احتمالی ارزیابی شود. در نهایت مهندسان اقدامات لازم برای بهبود عملکرد و بهسازی سازه انجام دهند. با این حال، شتاب‌سنج‌ها نیز مانند هر ابزار دیگری ممکن است 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. بدین صورت که ممکن است خرابی یک سنسور باعث ایجاد پاسخ‌های با دامنه کم بشود، در نتیجه فرکانس‌های مود اصلی تغییر یابد و در نهایت تصمیم‌گیری‌های نادرستی مبنی بر خرابی احتمالی یک عضو در سازه گرفته بشوند.

در این راستا، توسعه روش‌های کارآمد برای تشخیص و تصحیح ناهنجاری‌های سنسوری از اهمیت بالایی برخوردار است. یکی از روش‌های نوین که در این زمینه مورد توجه قرار گرفته است، استفاده از روش‌های یادگیری ماشین بر پایه هوش مصنوعی است. بکارگیری شبکه خود رمزگذارها به عنوان یک روش غیرنظارت شده، قادرند داده‌های ناهنجار را از داده‌های سالم تشخیص دهند و به این ترتیب، دقت و کارایی سیستم SHM را بهبود بخشند. در این مقاله، تلاش شده است تا انواع ناهنجاری‌های سنسوری برای داده‌های بنچمارک پل واقعی ارزیابی شوند. با بکارگیری روش هوش مصنوعی خود رمزگذار، یک روش غیرنظارت شده برای شناسایی داده‌های ناهنجار از داده‌های سالم ارائه می‌شود. در آن از دو متره، خطای بازسازی و تابع برآورد احتمال برای تشخیص ناهنجاری استفاده شد. نتایج نشان می‌دهد روش بکارگیری تابع برآورد احتمال بسیار در افزایش دقت کارآمد است.

هدف از پایش سلامت سازه (SHM) ارزیابی و شناسایی وضعیت کنونی سازه برای تصمیم‌گیری در مورد نگهداری، بهسازی یا تخریب آن است. عامل اصلی در این تصمیم‌گیری، وجود آسیب در سازه است که برای ارزیابی آن از سنسورهایی مانند شتاب‌سنج استفاده می‌شوند. پاسخ و ارتعاش سازه تحت شرایط محیطی، بارگذاری ترافیکی و یا بارگذاری ثابت می‌شود. با توجه به اینکه این پاسخ‌ها به صورت بردار هستند، در اکثر تحقیقات این ویژگی‌ها به صورت یک‌بعدی برای شناسایی آسیب استفاده شده‌اند [۱]. در مطالعات جدید، داده‌های یک‌بعدی مانند شتاب به صورت تصویری برای شناسایی آسیب در ورودی شبکه عصبی به کار می‌روند.

روش‌های یادگیری ماشین بر اساس نوع داده به دو دسته اصلی نظارت‌شده و بدون نظارت تقسیم می‌شوند. روش‌های یادگیری ماشین بدون نظارت، نیازی به داده‌های برچسب‌دار ندارند و به همین دلیل مورد توجه محققان قرار گرفته‌اند. سلیمانی و همکاران [۲] یک روش تشخیص خرابی بدون نظارت بر اساس شبکه مولد رقابتی (GAN) پیشنهاد دادند. سرمدی و کرم‌دین [۳] روش بدون نظارت برای تشخیص خرابی را بر اساس فاصله ماهالانوبیس (MSD) و روش k-نزدیکترین همسایه (KNN) با یک طبقه‌بندی پیشنهاد کردند. محققان یک منحنی آستانه مجاز را برای تشخیص خرابی سازه بنچمارک تحت شرایط محیطی استفاده کردند. بابا و کوندوه [۴] یک روش بر پایه روش k-خوشه‌بندی میانگین و یک طبقه‌بندی با استفاده همزمان از SVM برای شناسایی آسیب پیشنهاد دادند. در نهایت به شناسایی خرابی پرداختند. راستین و همکاران [۵] یک روش دو مرحله‌ای بر پایه روش GAN به صورت بدون نظارت برای شناسایی خرابی در سازه ارائه کردند. ابتدا خرابی توسط شبکه عمیق GAN شناسایی می‌شود و سپس مکان خرابی با استفاده از GAN به صورت شرطی پیدا می‌شود. روش را برای بنچمارک آزمایشگاهی و پل تیانجین چین ارزیابی کردند. همچنین راستین و همکاران [۶] یک روش بدون نظارت از ترکیب شبکه عصبی CNN با روش خود رمزگذار برای شناسایی خرابی در سازه‌ها معرفی کردند. در نهایت روش در شناسایی خرابی عملکرد مؤثری داشت. التونی و لیانگ [۷] یک شبکه بدون نظارت با ترکیب شبکه عصبی پیچشی خود رمزگذار و شبکه LSTM را برای ارزیابی خرابی ساختمان‌ها پیشنهاد دادند. روش محققین برای شناسایی مکان خرابی دقت ۸۵٪ را داشت. چن و همکاران [۸] یک روش برای شناسایی تغییرات ناشی از خرابی برای توربین‌های بادی معرفی کردند. این روش با ترکیب دو شبکه LSTM با خود رمزگذار تشکیل شده است و بر اساس روش SVM یک پوش حد مجاز از تغییرات را در نظر گرفتند. در صورتی که تغییرات از آن آستانه فراتر باشد به عنوان تغییرات اساسی گزارش می‌شود. مائو و همکاران [۹] یک روش بدون نظارت برای شناسایی پنج ناهنجاری داده‌ها بر پایه GAN و خود رمزگذار پیشنهاد دادند که در آن پاسخ داده‌های یک پل به صورت تصویر GAF تبدیل شدند و سپس از آن به عنوان ورودی شبکه استفاده کردند. سون و همکاران [۱۰] یک روش بدون نظارت از ترکیب دو روش خود رمزگذار و شبکه بازگشتی LSTM برای شناسایی پنج نوع ناهنجاری در پاسخ‌ها پیشنهاد دادند. روش


پیشنهادی را برای نیروی کابلی یک پل واقعی ارزیابی کردند. محققان به صورت دقیق تمایز بین ناهنجاری سنسور و خرابی سازه را برآورد نکردند و بلکه روی وجود یک پدیده در سیستم بررسی کردند.

همان‌طور که مشاهده شد، محققان برای شناسایی خرابی در سازه‌ها روش‌های زیادی را پیشنهاد دادند و در این تحقیقات آسیب را با مشاهده وجود تغییرات نسبت به داده سالم ارزیابی کردند. وقوع آسیب در سازه پدیده نادری است و تغییرات در داده لزوماً به معنی وقوع آسیب در سازه نیست. عمده مشکلات در آن است که داده ثبت شده همواره می‌تواند دارای تغییراتی باشد. این تغییرات به دلیل عوامل مختلفی از قبیل نویز محیطی، تغییرات شرایط جوی، خرابی سنسور مانند تغییرات ولتاژ، کاهش ظرفیت باتری، خطاهای ثبتی و ... می‌تواند باشد. وقوع این تغییرات هیچ‌کدام به معنی وقوع آسیب در سازه نیست و این مسئله کار مهندسان در شناسایی خرابی را بسیار دشوار می‌کند. از طرفی وجود این عوامل در داده‌های عملیاتی قابل صرف‌نظر یا حذف نیستند چرا که ضعف سامانه در شناسایی خرابی را به همراه دارد. پایش سلامت سازه به صورت غیرهوشمند و ارزیابی مشاهده‌ای می‌تواند خطای انسانی و هزینه زیادی داشته باشد. در نتیجه وجود سامانه هوشمند که با این تغییرات آشنا و آموزش دیده باشد و بتواند این مشکل مهندسی را با هوشمندی حل کند، ضروری است.

## ۲- روش تحقیق

### ۱-۲ سازه پنج‌مارک پل ساتونگ

پل ساتونگ (Sutong)، با دهانه اصلی ۱۰۸۸ متر، طولانی‌ترین پل کابلی در چین است. این پل همچنین طولانی‌ترین پل کابلی جهان بود که در می ۲۰۰۸ افتتاح شد. با هدف ارزیابی شرایط عملیاتی پل SCB، یک سیستم جامع SHM از زمان تکمیل آن بر روی این پل 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.

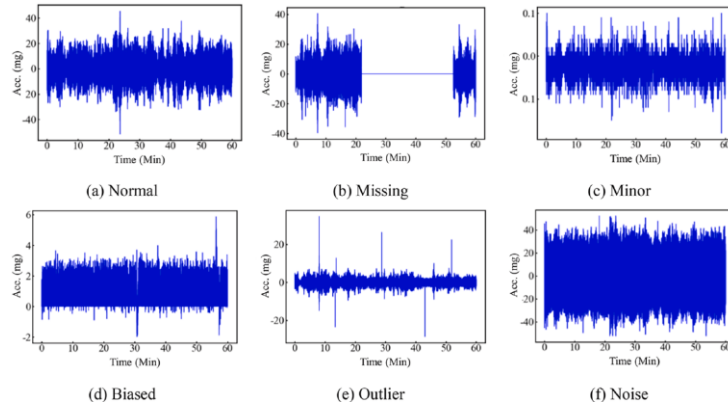


شکل ۱: آرایش سنسورهای شتاب‌سنج در پل ساتونگ [۱۱]

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 برای کاهش حجم محاسباتی و در نظر گرفتن کل گستره داده‌های این پنج‌مارک بصورت رندم نمونه داده ۱۰۷۲۰ در نظر گرفته شدند. هر نمونه داده شامل ۱۲۰ ثانیه می‌باشد.

### 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 پژوهش ناهنجاری‌هایی بررسی می‌شوند که ناشی از تغییرات به دلیل خرابی خود سنسور باشد.



شکل ۲: انواع ناهنجاری‌های سنسور [۱۲]

### ۳-۲ روش یادگیری ماشین خود رمزگذار

شبکه عصبی عمیق خود رمزگذار (AENN) یک فرآیند یادگیری بدون نظارت است که توانایی یادگیری از داده‌های یک کلاس را دارد. ایده رمزگذار خودکار این است که شبکه را مجبور به یادگیری یک فضای کمتر با ابعاد  $Z$  برای ویژگی‌های ورودی  $X$  کند و سپس سعی کند فضای ویژگی اصلی را بازسازی کند. به عبارت دیگر، مقادیر هدف را تقریباً برابر با ورودی‌های اصلی خود قرار می‌دهد.


فرآیند یادگیری AENN به طور متوالی خروجی هر گره در شبکه را محاسبه می‌کند. برای یک گره  $i$  در لایه  $l$ ، مقدار خروجی  $Z_i^{(l)}$  را با محاسبه مجموع وزنی  $W_j$  مقادیر ورودی به اضافه عبارت بایاس  $b_i$  با استفاده از رابطه (۱) محاسبه می‌شود:

$$z_i^{(l)} = \sum_{j=1}^n W_{ij}^{(l-1)} a_j^{(l-1)} + b_i^{(l)} \quad (1)$$

در این رابطه، پارامتر  $W_j$  وزن ضریب است که ارتباط بین گره  $j$  در لایه  $l-1$  و گره  $i$  در لایه  $l$  مرتبط باشد. پارامتر  $b_i$  عبارت بایاس مربوط به گره  $i$  در لایه  $l$  و  $a_j^{(l-1)}$  مقدار خروجی گره  $j$  در لایه  $l-1$  است. سپس خروجی حاصل از طریق یک تابع فعال سازی پردازش می‌شود. توابع فعال سازی در لایه های پنهان، سیگموئید و هذلولی تانژانت هستند که به ترتیب در روابط (۲) و (۳) تعریف شده اند. خود رمزگذار از دو سیستم معروف به رمزگذار  $g(\theta)$  و رمزگشا  $f(\varphi)$  تشکیل شده است. رمزگذار یک بردار ورودی  $X$  را به بردار نهفته  $Z$  نگاشت می‌کند. سپس رمزگشا  $Z$  را به ویژگی ورودی اصلی  $\hat{X}$  نگاشت می‌کند.

$$f(z) = \frac{1}{1+e^{-z}} \quad (2)$$

$$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3)$$



شکل ۳: شبکه عصبی خود رمزگذار [۱۳]

هنگامی که خود رمزگذار آموزش دید، شبکه قادر خواهد بود یک داده مثبت ورودی جدید را بازسازی کند، در حالی که با داده های غیرعادی از کار می‌افتد. این بر اساس خطای بازسازی<sup>۱</sup> که با اعمال نرم اقلیدسی بین گره‌های ورودی و خروجی مطابق رابطه (۴) اندازه‌گیری می‌شود.

$$RE(x) = \|x^i - \hat{x}^i\|^2 \quad (۴)$$

مقدار اندازه‌گیری شده RE به‌عنوان نمره ناهنجاری برای یک نمونه جدید داده شده استفاده می‌شود. بطور شهودی، نمونه‌هایی از توزیع مشابه با داده‌های آموزشی باید دارای خطای بازسازی کم داشته باشند و ناهنجاری‌ها باید دارای امتیاز ناهنجاری بالایی داشته باشند.

#### ۴-۲ برآورد تابع چگالی احتمال

در آمار و احتمال، برآورد چگالی به فرایند تخمین تابع چگالی احتمال یک متغیر تصادفی با استفاده از نمونه‌های مشاهده شده از آن متغیر گفته می‌شود. معمولاً فرض می‌شود نمونه‌های مشاهده شده به‌طور تصادفی و مستقل براساس تابع توزیع احتمال، توزیع شده‌اند. تابع توزیع بصورت رابطه (۵) در نظر گرفته می‌شود. در این رابطه،  $x$  نمونه‌های مشاهده شده،  $h$  طول پنجره،  $n$  تعداد نمونه می‌باشد.  $K$  تابع کرنل است که بصورت رابطه (۶) حاصل می‌شود.


$$\hat{f}(x; h) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x_i - x}{h}\right) \quad (۵)$$

$$K(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \quad (۶)$$

#### ۵-۲ روش پیشنهادی تحقیق

در این تحقیق با بکارگیری دو سیستم هوش مصنوعی، شبکه عصبی پیچشی با خود رمزگذار، به شناسایی ناهنجاری سنسوری پرداخته می‌شود. برای اینکار ابتدا تصویر سری زمانی شتاب‌های سنسوری برای هر ساعت بصورت عکس تبدیل و ذخیره می‌شوند. سپس عکس‌ها بعنوان ورودی لایه پیچشی داده می‌شوند و با توجه به معماری پیشنهادی تحقیق (شکل ۴)، برای رسیدن به لایه وسط، کاهش ابعاد صورت می‌گیرد.

<sup>1</sup> Reconstruction Error



شکل ۴: معماری شبکه عصبی پیچشی خودرمزگذار

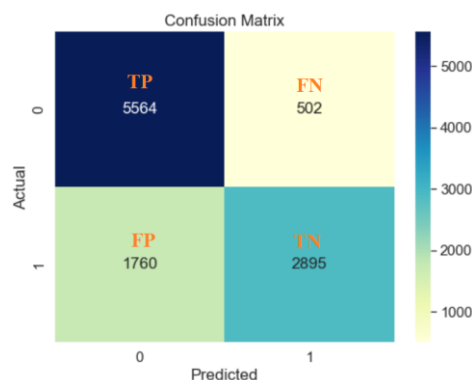
شبکه تعلیم داده می‌شود و در نهایت با کمک گرفتن از دو متره، تصویر داده سالم با تصویر دارای ناهنجاری شناسایی می‌شود. (۱) تابع بازسازی خطا: مربوط به تابع خطا می‌باشد که میزان اختلاف تصویر تولید شده را با تصویر ورودی مقایسه می‌دهد و اختلاف را محاسبه می‌کند. (۲) تابع برآورد احتمال: بکارگیری تابع توزیع احتمالاتی در شناسایی اختلاف بین تصویر سالم با ناهنجار است. بدین صورت که داده‌های سالم از یک توزیع خاص پیروی می‌کنند، حال اگر داده نامعلومی به شبکه داده شود، توزیع آماری به خوبی معرف آن داده‌ها نخواهد بود در نتیجه می‌توان نتیجه گرفت داده ناهنجار می‌باشد.

### ۳- نتایج و دستاوردها

در این مقاله برای شناسایی ناهنجاری‌های ناشی از سنسور ابتدا شبکه عصبی پیچشی با معماری خود رمزگذار برای داده‌های شتاب‌سنج پل ساتونگ، تعلیم داده شد. بدین نحو که تنها داده‌های شتاب سالم به شبکه داده می‌شود. سپس با استفاده از شبکه با دو معیار سنج به شناسایی ناهنجاری می‌پردازیم.

#### ۳-۱- تابع بازسازی خطا

همانطور که گفته شد تابع بازسازی خطا مربوط به تابع خطا می‌باشد که میزان اختلاف تصویر تولید شده را با تصویر ورودی مقایسه می‌دهد و اختلاف را محاسبه می‌کند. ابتدا تنها این معیار برای شناسایی ناهنجاری بکار گرفته شد که نتایج ماتریس درهم ریختگی آن در شکل (۵) دیده می‌شود.



شکل ۵: نتایج ماتریس درهم ریختگی برای معیار اول

برای ماتریس درهم ریختگی قطر اصلی ملاک است که معرف تشخیص صحیح داده‌ها و عملکرد شبکه عصبی را نشان می‌دهد. مشاهده می‌شود تعداد ۵۵۶۴ داده سالم به درستی سالم تشخیص داده، تعداد ۲۸۹۵ داده ناهنجار را نیز درست تشخیص داده، اما سایر مقادیر خطای شبکه می‌باشد. برای ارزیابی دقیق می‌توان معیارهای سنجش و ارزیابی شبکه در جدول مشاهده شود.


جدول ۱. مقایسه نتایج برای بکارگیری معیار بازسازی خطا

| نوع داده                | دقت ( Precision ) | یادآوری ( Recall ) | معیار ( f1-score ) |
|-------------------------|-------------------|--------------------|--------------------|
| سالم                    | ۰.۷۶              | ۰.۹۲               | ۰.۸۳               |
| آسیب                    | ۰.۸۵              | ۰.۶۲               | ۰.۷۲               |
| <b>صحت ( Accuracy )</b> |                   |                    | ۰.۷۹               |

مشاهده می‌شود، برای معیار یادآوری، ۶۲ درصد از داده‌های ناهنجار را شناسایی کرده و برای داده‌های سالم ۹۲ درصد را به درستی شناسایی کرده است.

### ۲-۳ تابع برآورد احتمال

با بکارگیری تابع توزیع احتمالاتی در شناسایی اختلاف بین تصویر سالم با ناهنجار بدین صورت که داده‌های سالم از یک توزیع خاص پیروی می‌کنند، حال اگر داده نامعلومی به شبکه داده شود، توزیع آماری به خوبی معرف آن داده‌ها نخواهد بود در نتیجه می‌توان نتیجه گرفت داده ناهنجار می‌باشد. این ایده در کنار معیار اول، روی داده‌ها پیاده سازی شد، ماتریس درهم ریختگی داده‌ها در ادامه ارائه شده است.



شکل ۶: نتایج ماتریس درهم ریختگی برای معیار اول به‌همراه معیار دوم

مشاهده می‌شود تعداد ۵۶۶۶ داده که به درستی سالم تشخیص داده شد. تعداد ۴۰۱۵ داده ناهنجار را نیز درست تشخیص داده شد. اما سایر مقادیر خطای شبکه می‌باشد. برای ارزیابی دقیق می‌توان معیارهای سنجش و ارزیابی شبکه در جدول مشاهده شود.

جدول ۲. مقایسه نتایج برای بکارگیری معیار بازسازی خطا

| نوع داده                | دقت ( Precision ) | یادآوری ( Recall ) | معیار ( f1-score ) |
|-------------------------|-------------------|--------------------|--------------------|
| سالم                    | ۰.۹۲              | ۰.۹۱               | ۰.۹۲               |
| آسیب                    | ۰.۸۸              | ۰.۸۹               | ۰.۸۹               |
| <b>صحت ( Accuracy )</b> |                   |                    | ۰.۹۰               |

مطابق جدول (۲)، برای معیار یادآوری، از ۶۲ درصد برای داده‌های ناهنجار به ۸۹ درصد و برای داده‌های سالم از ۹۲ درصد به ۹۱ درصد رسید. دلیل کاهش درصد داده سالم، انتخاب تصادفی نمونه داده‌ها از کل داده‌های موجود بود نتایج افزایش دقت را نشان می‌دهد. برای مثال معیار یادآوری ۳۰ درصد، معیار ( f1-score ) ۱۷ درصد افزایش داشتند. دلیل افزایش دقت در شناسایی ناهنجاری، بکارگیری معیار شباهت توزیع احتمالاتی بوده و همچنین این افزایش نشان از حساس بودن نتایج ناهنجاری به شاخص‌ها (feature) است. لازم به ذکر است در این تحقیق نشان داده می‌شود که با توجه به اینکه از سیستم شبکه عصبی پیچشی با رویکرد معماری خود رمزگذار استفاده شد. شبکه قادر است الگوهای مهم و متمایز بین داده سالم با داده‌های ناهنجاری را تشخیص بدهد. نتایج پژوهش در سه محور قابل بررسی هستند.

۱. معیار خطای بازسازی برای تشخیص داده‌های سالم کارایی مناسبی دارد.
۲. معیار تابع توزیع احتمال برای تشخیص داده‌های ناهنجار کارایی مناسبی دارد.

۳. پژوهش نشان داد که مسئله شناسایی ناهنجاری سنسوری یک مسئله حساس به نوع شاخص‌ها (feature) می‌باشد و در نتیجه انتخاب شاخص‌ها در افزایش دقت تشخیص موثر است.

#### ۴- جمع بندی

در این مقاله، تلاش شده است تا انواع ناهنجاری‌های سنسوری برای داده‌های بنچمارک پل واقعی ارزیابی شوند و با بکارگیری روش هوش مصنوعی خودمزمگذار، یک روش غیرنظارت شده برای شناسایی داده‌های ناهنجار از داده‌های سالم ارائه شود. نتایج این تحقیق نشان می‌دهد که روش پیشنهادی بعنوان یک روش غیرنظارتی می‌تواند به طور موثری ناهنجاری‌ها را شناسایی کند. همچنین بکارگیری دو معیار تابع خطای بازسازی به‌مراه تابع توزیع احتمالی در افزایش دقت تشخیص کارآمد است. با توجه به اهمیت موضوع و نتایج به دست آمده، می‌توان نتیجه گرفت که استفاده از روش‌های هوش مصنوعی و به ویژه خودمزمگذارها در پایش سلامت سازه‌ها، می‌تواند به عنوان یک راهکار موثر و کارآمد در تشخیص و تصحیح ناهنجاری‌های سنسوری بصورت غیرنظارتی مورد استفاده قرار گیرد. 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. Zhang Y, Yuen KV. Review of artificial intelligence-based bridge damage detection. *Adv. Mech. Eng.* [Internet] 2022 [cited 2023 Aug 2];14. Available from: <https://journals.sagepub.com/doi/full/10.1177/16878132221122770>
2. Soleimani-Babakamali MH, Sepasdar R, Nasrollahzadeh K, Sarlo R. A system reliability approach to real-time unsupervised structural health monitoring without prior information. *Mech. Syst. Signal Process.* 2022;171:108913.
3. Sarmadi H, Karamodin A. A novel anomaly detection method based on adaptive Mahalanobis-squared distance and one-class kNN rule for structural health monitoring under environmental effects. *Mech. Syst. Signal Process.* 2020;140:106495.
4. Baba S, Kondoh J. Damage evaluation of fixed beams at both ends for bridge health monitoring using a combination of a vibration sensor and a surface acoustic wave device. *Eng. Struct.* 2022;262:114323.
5. Rastin Z, Ghodrati Amiri G, Darvishan E. Generative Adversarial Network for Damage Identification in Civil Structures. *Shock Vib.* 2021;2021.
6. Rastin Z, Ghodrati Amiri G, Darvishan E. Unsupervised Structural Damage Detection Technique Based on a Deep Convolutional Autoencoder. *Shock Vib.* 2021;2021.
7. Eltouny KA, Liang X. Large-scale structural health monitoring using composite recurrent neural networks and grid environments. *Comput. Civ. Infrastruct. Eng.* [Internet] 2023 [cited 2023 Jul 31];38:271–87. Available from: <https://onlinelibrary.wiley.com/doi/full/10.1111/mice.12845>
8. Chen H, Liu H, Chu X, Liu Q, Xue D. Anomaly detection and critical SCADA parameters identification for wind turbines based on LSTM-AE neural network. *Renew. Energy* 2021;172:829–40.
9. Mao J, Wang H, Spencer BF. Toward data anomaly detection for automated structural health monitoring: Exploiting generative adversarial nets and autoencoders. *Struct. Heal. Monit.* [Internet] 2020 [cited 2023 Jul 31];20:1609–26. Available from: <https://journals.sagepub.com/doi/abs/10.1177/1475921720924601>
10. Son H, Jang Y, Kim SE, Kim D, Park JW. Deep Learning-Based Anomaly Detection to Classify Inaccurate Data and Damaged Condition of a Cable-Stayed Bridge. *IEEE Access*



- 2021;9:124549–59.
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.
  12. 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.
  13. Anaissi A, Zandavi SM, Suleiman B, Naji M, Braytee A. Multi-objective variational autoencoder: an application for smart infrastructure maintenance. *Appl. Intell.* [Internet] 2023 [cited 2023 Aug 4];53:12047–62. Available from: <https://link.springer.com/article/10.1007/s10489-022-04163-2>