

## Health Monitoring of Bridges by Using the Available Data Based on Deep Learning

Mohammad Sadegh Torabi<sup>1</sup>, Gholamreza Ghodrati Amiri<sup>2\*</sup>, Ehsan Darvishan<sup>3</sup>

1- M.Sc., School of Civil Engineering, Iran University of Science and Technology, Tehran, Iran

2- Professor, School of Civil Engineering, Iran University of Science and Technology, Tehran, Iran

3- Assistant Professor, Civil Engineering Department, Roudehen Branch, Islamic Azad University, Roudehen, Iran

### ABSTRACT

Damage caused by sudden and specific loads such as earthquakes causes undesirable changes in structural performance. Therefore, in recent years need for methods to identify damage in structures feel more than ever. Therefore, finding ways to identify damages and their location is one of the issues that has always been discussed in civil, mechanical, and aerospace engineering. The main idea in most of these methods is to use the responses that the structure gives to external factors based on the assumptions available, in most of these studies structures are considered as a dynamic system with unique mass, stiffness, and damping which in the case of structural damage, these parameters change and reflect changes in the structural responses. This response is often in the form of time signals containing structural properties that can be extracted and used to detect potential damage by examining them. The increasing advancement of machine learning science has not only provided the conditions for the improvement of engineering sciences but it has been such that today it is the computers that often do the most important calculations, One of the most widely used methods today is deep convolutional neural networks to detect the properties mentioned in structural signals. This paper attempts to design a one-dimensional convoluted network to detect a healthy state from unhealthy in which we investigate the effect of the normalizer function on the pre-processing phase is attempted and the effect of Stochastic decreasing gradient and Adam (two optimization functions) on the network learning process is also investigated. To evaluate the capability of the proposed method, data from the Yong cable bridge in China were used. Finally, it can be concluded that the results show satisfactory, accurate, and fast one-dimensional deep neural network (convolution) performance in the diagnosis of an unhealthy state.

### ARTICLE INFO

**Receive Date:** 21 February 2021

**Revise Date:** 12 July 2021

**Accept Date:** 04 August 2021

### Keywords:

Structural health monitoring

Damage detection

Deep neural network

Convolution neural network

ADAM optimization algorithm

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://dx.doi.org/10.22065/jsce.2021.274265.2367>

\*Corresponding author: Gholamreza Ghodrati Amiri

Email address: ghodrati@iust.ac.ir

## پایش سلامت پل ها با استفاده از داده‌های موجود بر مبنای یادگیری عمیق

محمدصادق ترابی<sup>۱</sup>، غلامرضا قدرتی امیری<sup>۲\*</sup>، احسان درویشان<sup>۳</sup>

۱- کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران

۲- استاد، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران، تهران، ایران

۳- استادیار، گروه مهندسی عمران، واحد رودهن، دانشگاه آزاد اسلامی، رودهن، ایران

### چکیده

بروز آسیب‌های ناشی از بارگذاری‌های ناگهانی یا آسیب‌هایی در طول عمر سازه ممکن است باعث ایجاد تغییرات نامطلوبی در عملکرد آن شود لذا در سال‌های اخیر نیاز به روش‌هایی جهت شناسایی آسیب در آن‌ها بیش از پیش احساس می‌شود. از این رو دست‌یابی به روش‌هایی جهت شناسایی رخداد و یافتن محل آسیب یکی از موضوعاتی است که همواره در مهندسی عمران، مکانیک و هوافضا مطرح بوده است. ایده اصلی در اکثر این روش‌ها استفاده از پاسخ‌هایی است که سازه بر اساس پیش‌فرض‌های موجود به عوامل بیرونی می‌دهد. در اغلب این مطالعات سازه به‌عنوان یک سیستم دینامیکی با جرم، سختی و میرایی بکتا در نظر گرفته می‌شود. و در صورت آسیب این پارامترها با تغییر مواجه می‌شوند و این تغییرات خود را در پاسخ‌های سازه نشان می‌دهد. این پاسخ‌ها به‌صورت سیگنال‌های زمانی، حاوی خصوصیات دینامیکی سازه است که با تحلیل سیگنال استخراج می‌شوند و در تشخیص آسیب از آن‌ها بهره گرفته می‌شود. پیشرفت روزافزون علم یادگیری ماشین نه تنها شرایط را برای پیشرفت علوم مهندسی مهیا کرده است بلکه این پیشرفت به گونه‌ای بوده است که امروزه این کامپیوترها هستند که اغلب محاسبات مهم را بر عهده خواهند داشت، یکی از روش‌هایی که امروزه بسیار مورد توجه قرار گرفته است استفاده از شبکه‌های عصبی کانولوشن به‌منظور تشخیص خصوصیات ذکر شده در سیگنال‌های سازه است. در این مقاله سعی شده است تا شبکه‌ی کانولوشن یک‌بعدی جهت تشخیص حالت سالم از ناسالم طراحی شود، علاوه بر آن اثر تابع نرمال‌ساز در فاز پیش‌پردازش داده و اثر دو تابع بهینه‌ساز گرادیان کاهش و آدام در فرآیند آموزش شبکه نیز مورد بررسی قرار گرفته است. در نهایت می‌توان بیان کرد که نتایج حاکی از عملکرد رضایت بخش، دقیق و سریع روش شبکه عصبی عمیق کانولوشن یک‌بعدی در تشخیص حالت سالم از ناسالم است.

کلمات کلیدی: پایش سلامت سازه‌ها، شناسایی آسیب، شبکه عصبی عمیق، شبکه عصبی کانولوشن، الگوریتم بهینه‌سازی آدام، دسته بندی داد

شناسه دیجیتال:		سابقه مقاله:				
doi:	<a href="https://dx.doi.org/10.22065/jsce.2021.274265.2367">https://dx.doi.org/10.22065/jsce.2021.274265.2367</a>	چاپ	انتشار آنلاین	پذیرش	بازنگری	دریافت
	10.22065/jsce.2021.274265.2367	۱۴۰۰/۱۲/۲۹	۱۴۰۰/۰۵/۱۳	۱۴۰۰/۰۵/۱۳	۱۴۰۰/۰۴/۲۱	۱۳۹۹/۱۲/۰۳
				*نویسنده مسئول:		
				پست الکترونیکی:		
				غلامرضا قدرتی godrati@iust.ac.ir		

## ۱- مقدمه

پل، سد، نیروگاه هسته‌ای و... نقش بسزایی در زندگی بشر امروز ایفا می‌کنند، سازه‌هایی که آسیب دیدن هر کدام از آن‌ها می‌تواند منجر به صدمات عمده‌ی جانی و اقتصادی شود. از این رو پایش سلامت این سازه‌ها از اهمیت بسیاری برخوردار است. اما آنچه اهمیت دارد افزایش دقت و سرعت و به طور همزمان کاهش هزینه پایش این سازه‌هاست. چراکه با توجه به ابعاد و پیچیدگی‌های آن‌ها، جزئیات و پارامترهای مختلفی برای پایش باید بررسی شوند. از سوی دیگر بررسی سلامت این سازه‌ها باید به صورت مداوم انجام گیرد در نتیجه نیاز به سیستمی با کارایی و سرعت بالا که دقت بیشتر و هزینه‌ای کمتر از کنترل کننده‌های انسانی دارد بیشتر احساس می‌شود.

تاکنون روشهای متعددی برای پایش سلامت سازه‌ها ارائه شده‌اند. با این حال امروزه روش‌های مبتنی بر ارتعاش سازه<sup>۱</sup> بیشتر مورد توجه محققین قرار گرفته‌اند. این روشها عمدتاً از فرکانس طبیعی ارتعاش، شکل مودی، تقعر مودها، پردازش سیگنال و یا هوش مصنوعی استفاده می‌کنند. از میان روشهای هوش مصنوعی، شبکه‌های عصبی مصنوعی به علت سرعت بالا و قابلیت مدل سازی روابط به صورت غیرخطی تاکنون در بسیاری از تحقیقات مورد استفاده قرار گرفته‌اند [1].

باکاری و همکاران<sup>۲</sup> از شبکه عصبی مصنوعی برای شناسایی خسارت المانهای سازه استفاده کردند. آنها از فرکانس‌ها و شکل مودهای سازه به عنوان ورودی و از مدول یانگ به عنوان خروجی شبکه استفاده کردند [2]. گومز و همکاران<sup>۳</sup> شبکه عصبی و الگوریتمهای بهینه سازی را برای شناسایی خسارت به کار بردند. آنها همچنین با استفاده از تکنیک تصمیم گیری فازی توانستند خسارات را با دقت بالا شناسایی کنند [3]. جین و همکاران<sup>۴</sup> با استفاده از شبکه عصبی توانستند مقدار و محل آسیب را در یک سازه ماهیگیری شناسایی کنند. آنها این شبکه را برای بارگذاری های مختلف امواج دریا و سناریوهای مختلف آسیب آموزش دادند و سپس دقت شبکه آموزش دیده را بر روی یک مدل عددی آزمایش کردند. نتایج نشان داد که روش مذکور قابلیت شناسایی آنالین خسارت را با دقت مطلوب دارا است [4]. سیدارتا و همکاران<sup>۵</sup> بر روی پایش سلامت سازه پهلوگیری سکوه‌های دریایی شناور متمرکز شدند. آنها با استفاده از شبکه عصبی و داده های GPS حرکت سکو و همین طور تغییرات وزن کشتی به عنوان متغیرهای شبکه، توانستند خسارت را شناسایی و طبقه بندی کنند [5].

علی رغم آن که شبکه‌های عصبی تاکنون در بسیاری از روشهای شناسایی خسارت با موفقیت به کار رفته‌اند با این حال دارای مشکلاتی هستند. اولین مشکل، حساسیت این شبکه‌ها به تغییرات ورودی است. لذا کارایی این شبکه‌ها برای سازه‌های عمرانی که معمولاً با شدت بالای نویز و تغییرات محیطی مواجه هستند ممکن است کاهش پیدا کند. مشکل دوم افت دقت آنها با افزایش حجم داده‌ها است. امروزه سیستم‌های پایش سلامت سازه شامل تعداد زیادی سنسور هستند که حجم بزرگی از داده را ثبت می‌کنند. لذا تحلیل این حجم از داده با شبکه‌های سنتی دارای دشواری‌هایی است [6]. بر این اساس شبکه‌های عصبی عمیق اخیراً مورد توجه محققین قرار گرفته‌اند. این شبکه‌ها شامل شبکه‌های اتوانکودر<sup>۶</sup>، شبکه‌های باور عمیق<sup>۷</sup>، شبکه‌های گن<sup>۸</sup>، شبکه‌های درهم تنیده<sup>۹</sup> و شبکه‌های بازگشتی<sup>۱۰</sup> هستند. با این حال شبکه‌های درهم تنیده به علت کارایی بالا محبوبیت بیشتری پیدا کرده‌اند [7], [8].

1 Vibration-base methods

2 Bakhary et al

3 Gomes et al

4 Jin et al

5 Sidarta et al

6 Auto-Encoder

7 Deep Belief Network

8 Generative Adversarial Networks (GAN)

9 Convolution Neural Network (CNN)

10 Recurrent Neural Networks (RNN)

لین و نی<sup>۱۱</sup> با استفاده از روش‌های نوین یادگیری عمیق کانولوشنال<sup>۱۲</sup> توانستند با استفاده از داده‌های مجموعه سنسورهای با دقت پایین ویژگی‌های سازه را استخراج کرده و محل رخداد خرابی را تعیین کنند [9]. عبدالجابر و همکاران<sup>۱۳</sup> توانستند با توسعه شبکه‌های یک‌بعدی کانولوشنال (1DCNNs)<sup>۱۴</sup> مدلی را جهت ارزیابی سازه معیار IASC\_ASCE توسعه دادند که تنها با استفاده از دودسته داده آسیب موجود در سازه را تشخیص می‌دهد [10]. چا و چوی<sup>۱۵</sup> روشی در حوزه پردازش تصویر بر اساس شبکه عمیق کانولوشن ابداع کردند که براساس آن تشخیص ترک در تصاویر موجود از یک عضو بتنی با دقت بسیار بیشتری نسبت به روش‌های قدیمی تشخیص مرزی امکان پذیر شد [11]. یانگ و همکاران<sup>۱۶</sup> موفق شدند تا با استفاده از شبکه عمیق کانولوشن<sup>۱۷</sup> آسیب ایجاد شده در یک سازه مجهز به ابزار کنترل (سازه هوشمند) را با دقت خوبی تشخیص دهند. در روش آنها شبکه عصبی به صورت خودکار ویژگی‌های سازه آسیب دیده را از سیگنال‌های خام موجود استخراج کرده است [12]. باو و همکاران<sup>۱۸</sup> روشی را براساس تلفیق بینایی کامپیوتر<sup>۱۹</sup> و شبکه عمیق ابداع کردند که به واسطه آن امکان تشخیص رفتار نامتعارف در سیگنال‌های دریافتی از سازه‌های مختلف امکان پذیر بود، آن‌ها این روش را با امتحان بروی داده‌های یک پل موجود در چین ارزیابی کردند [13]. مودرس و همکاران<sup>۲۰</sup> موفق شدند تا با توسعه شبکه عمیق کانولوشن با استفاده از تصاویر یک ساندویچ پنل کامپوزیتی آسیب ایجاد شده در آن را شناسایی کنند. در این تحقیق آنها ابتدا شبکه طراحی شده را بر روی یک تیر لانه زنبوری مدل شده آزمودند و سپس بر روی داده‌های موجود از سناریوهای مختلف آسیب در پل‌ها مختلف که در تمامی آزمون‌ها پاسخ‌های قابل قبولی دریافت شد [7]. لیو و ژانگ<sup>۲۱</sup> موفق شدند تا با توسعه روش پردازش تصویر بر اساس شبکه‌های عمیق کانولوشن آسیب به وجود آمده در اتصالات فلزی بر اساس بارگذاری مداوم لرزه‌ای را تشخیص دهند. آنها در تحقیقات خود این روش را به جهت ارزیابی پس از بحران سازه‌های موجود پیشنهاد کرده اند [14]. گو و همکاران<sup>۲۲</sup> توانستند با توسعه روش شبکه عصبی عمیق کانولوشن ویژگی‌های یک سیگنال آسیب دیده را بر اساس شکل‌ها مودی بدون دخالت هیچ تابع از پیش آموزش داده شده‌ای استخراج نمایند، آن‌ها در تحقیقات خود روش ابداعی را بر روی داده‌های آزمایشگاهی موجود امتحان کردند و پاسخ قابل قبولی دریافت کردند [15]. لیو و ژانگ<sup>۲۳</sup> روشی را با کمک شبکه عصبی عمیق توسعه دادند که براساس آن می‌توان در سازه‌های با قاب‌های مهاربند همگرا<sup>۲۴</sup> بلافاصله پس از وقوع زلزله ارزیابی اولیه‌ای از وضعیت سازه به دست آورد [16].

در بیشتر تحقیقات گذشته شبکه‌های کانولوشن به صورت دو بعدی و برای پردازش تصویر مورد استفاده قرار گرفته اند و تحقیقات انجام شده بر روی این شبکه‌ها جهت پردازش سیگنال‌های یک بعدی بسیار اندک است. ضمناً این شبکه‌ها بزرگ بوده و برای آموزش نیاز به تعداد داده زیادی دارند که همیشه در دسترس نمی‌باشد. آموزش چنین شبکه‌های بزرگی نیز با دشواری‌هایی همراه است.

هدف از این مقاله، شناسایی آسیب در یک سازه واقعی با استفاده از یک شبکه درهم تنیده کوچک با تعداد لایه‌های کم است. بر این اساس تعداد داده‌های ورودی لازم برای تمرین کاهش یافته و آموزش شبکه با سهولت بیشتری انجام خواهد شد. علاوه بر این از هیچ

- 11 Lin and Nie
- 12 Convolutional deep learning
- 13 Abdeljaber et al.
- 14 1D Convolutional Neural Networks
- 15 Cha and Choi
- 16 Yang and et al.
- 17 Convolutional Neural Network
- 18 Bao et al.
- 19 Computer vision
- 20 Modarres et al.
- 21 Liu and Zhang
- 22 Guo et al.
- 23 Liu and Zhang
- 24 Concentrically braced frame

پیش پردازشی استفاده نشده است تا شبکه از داده های خام استفاده کند، (هرچند به عنوان مقایسه یک حالت پیش پردازش ثانویه ساده با استفاده از تابع Zed\_score در نظر گرفته شده است). بدین ترتیب نیاز به پیش پردازش داده ها نیز منتفع شده و سرعت شبکه افزایش پیدا می کند. در انتها عملکرد شبکه تحت دو تابع بهینه یابی ADAM و SGD نیز با یکدیگر مقایسه شده است.

## ۲- شبکه عصبی مصنوعی

شبکه عصبی به عنوان روشی جهت محاسبه روابط بین داده‌ها سال‌هاست که در علوم مختلف مورد استفاده قرار می‌گیرد، پایه اصلی این روش بر اساس روابط ریاضی وزن دار بین داده‌های ورودی و خروجی است. یادگیری عمیق نیز به عنوان مدل پیشرفته‌تر شبکه عصبی توانایی بررسی روابط پیچیده‌تر و متغیرهای بیشتر را داراست. در روش‌های قدیمی تخمین مقادیر همچون تابع بردار پشتیبان (SVM) یک ارتباط خطی بین داده‌ها ترسیم می‌شود. اما در یک شبکه عصبی یک ارتباط خطی یا غیر خطی بین داده ورودی وزن دار شده با کمک تابع فعال‌ساز و مقادیر خروجی ایجاد می‌شود از این رو سرعت و دقت به مراتب بالاتری خواهند داشت [7].

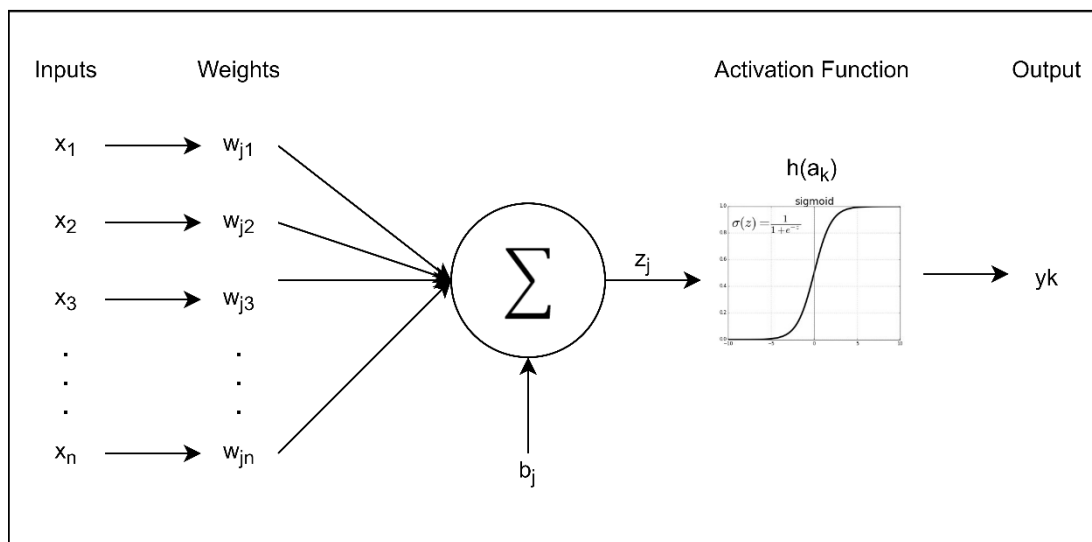
یک شبکه عصبی را می‌توان مجموعه‌ای از نرون‌ها شکل (۱) دانست که به وسیله اتصالات وزن دار به یکدیگر مرتبط شده‌اند. مطابق رابطه (۱)، داده های ورودی  $x_i$  هر نرون پس از عبور از این ارتباط وزن دار  $w_{ji}$  مقدار خروجی  $z_j$  را حاصل می‌شوند.

تابع فعال‌ساز  $h^{25}$  در رابطه (۱) به عنوان آخرین مرحله در پردازش داده‌های ورودی عمل می‌کند. توابع فعال‌ساز به نوعی روابط داخل شبکه را از حالت خطی خارج کرده و گستره محاسبات را افزایش می‌دهند. در رابطه (۲) مقدار  $z_j$  خروجی حاصل از روابط داخلی یک گره از شبکه بوده و مقدار  $a_k$  جمع وزن دار چند گره مجزا است و  $\beta$  ضرایب اصلاحی خطی وزن دار داخل شبکه و  $b$  مقدار بایاس که در نهایت پس از عبور از تابع فعال‌ساز سیگموئید  $\sigma$ ، خروجی  $y$  در رابطه (۳) را حاصل می‌کند [17].

$$z_j = h\left(\sum_{i=1}^D w_{ji}x_i + b_k\right) \quad (۱)$$

$$a_k = \sum_{j=1}^M \beta_{kj}z_j + b_j \quad (۲)$$

$$y_k = \sigma(a_k) = \frac{1}{1 + e^{-a_k}} \quad (۳)$$



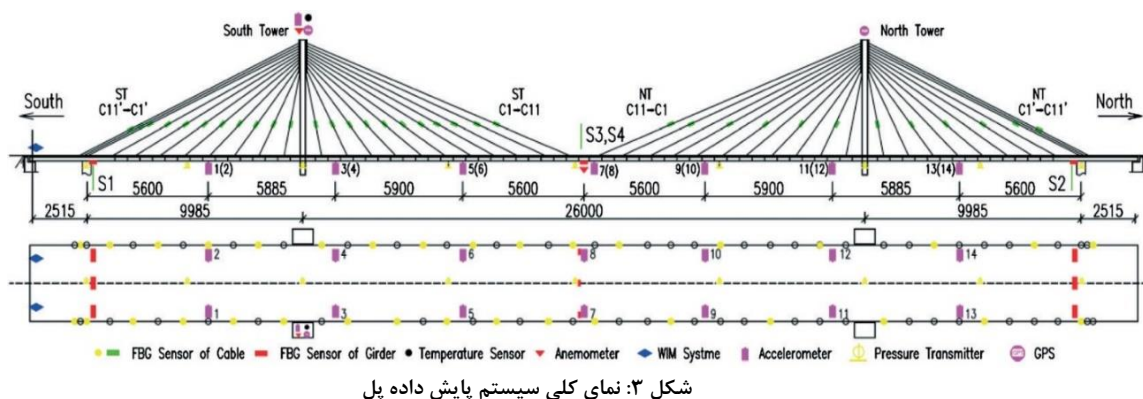
شکل ۱: نمای کلی یک شبکه عصبی و روابط ریاضی بین اجزای آن

### ۳- سازه مورد بررسی

در این پژوهش از سازه پل یانگ برای شناسایی آسیب استفاده شده است [18]. این پل جزو اولین پل‌های کابلی است که در مرکز کشور چین ساخته شده است و در سال‌های اخیر به دلیل مطالعاتی که بر روی آن انجام شده است به عنوان یک سازه پنج‌مارک مورد بررسی قرار گرفته است [19][20]، دارای دهانه مرکزی به طول ۲۶۰ متر و دهانه‌های کناری به طول ۲۵,۱۵+۹۹,۸۵ متر است. طول پل ۵۱۰ متر و عرض آن ۱۱ متر است (۹ متر لاین عبوری وسایل نقلیه و ۲ در ۱ متر پیاده‌رو). برج بتنی پل شامل دو تیر عمودی به ارتفاع ۶۰,۵ متر است. پس از گذشت ۱۹ سال از عمر پل، ترک‌هایی به عرض ۲۵ سانتیمتر در دهانه مرکزی و در زیر شاه‌تیر اصلی مشاهده شد. پس از آسیب به‌عنوان بخشی از سیستم پایش سلامت، بیش از ۱۵۰ سنسور بر روی کابل‌ها، برج و شاه‌تیرها نصب شد. در اتاق کنترل نیز یک سیستم جمع‌آوری داده برقرار شد. ۱۴ سنسور تک‌محوره بر روی عرشه نصب شد و یک سنسور دو‌محوره بر روی برج جنوبی نصب شد تا ارتعاشات افقی را ثبت کند. شکل (۲) و (۳) نمایی از پل و سیستم پایش سلامت آن را نشان می‌دهد. داده‌های شتاب ارتعاش سازه که توسط سنسورها ثبت می‌شود در هر ساعت ذخیره شده است. لذا در کل طول شبانه‌روز ۲۴ داده یک‌ساعته موجود است. نرخ نمونه‌برداری سنسورها ۱۰۰ هرتز است، لذا هر نمونه شامل ۳۶۰۰۰۰ داده برای هر سنسور خواهد بود. برای استفاده در آنالیزها، داده زانویه ۲۰۰۸ به‌عنوان حالت سالم (پس از بهسازی پل) و داده ۳۱ جولای ۲۰۰۸ به‌عنوان حالت آسیب‌دیده پل (کمی قبل از بهسازی) در نظر گرفته شده است. بر این اساس حالت سالم و آسیب‌دیده پل از قبل مشخص بوده و می‌توان از این داده‌ها جهت مقایسه رفتار پل در این دو حالت استفاده کرد، باید به این نکته نیز اشاره کرد، از آنجا که داده‌های مورد استفاده در این پژوهش بر اساس خروجی سنسورهای شتاب‌نگاشت نسب شده بر روی پل بوده‌اند و مطالعه بر روی آن‌ها بدون هیچ فرآیند حذف نویز و اصلاح انجام شده است، در نتیجه اثرگذاری نویز و سایر رخدادها نظیر تغییرات آب و هوایی نیز در عملکرد کلی شبکه مورد توجه بوده است.



شکل ۲: نمای کلی از پل یانگ




شکل ۳: نمای کلی سیستم پایش داده پل

## ۴- پژوهش

### ۴-۱- پیش پردازش

مطابق روش نشان داده شده در شکل (۴) در گام نخست داده‌ها \_ پاسخ فرکانسی شتاب سازه \_ به حالت سالم و حالت آسیب دیده پل انتخاب و برچسب گذاری می‌شود این فرآیند به جهت دسته‌بندی اولیه به عنوان بخشی از مرحله اول آموزش شبکه انجام می‌شود، از آنجا که داده‌های موجود از پیش سالم یا آسیب دیده بودنشان مشخص بوده است، از این امتیاز استفاده شد تا با دسته بندی از پیش بتوان در مرحله ارزیابی عملکرد شبکه از همین برچسب گذاری به عنوان ملاک موفقیت استفاده کرد، به این صورت که در بخش سنجش ابتدا برچسب داده توسط شبکه ذخیره شده و سپس تشخیص شبکه با برچسب مقایسه خواهد شد. سپس از آنجا که شبکه کانولوشن یک بعدی برای داده‌های در دامنه‌های کوتاه پاسخ بهتری به دست می‌دهد [10]، داده‌ها به بخش‌های کوچک‌تر تقسیم شدند. همان طور که پیشتر اشاره شد، برای هر سنسور در هر ۲۴ ساعت ۳۶۰,۰۰۰ داده موجود است. در این مرحله داده‌ها با حالت‌های مختلف تقسیم بندی شده که در نهایت هر ماتریس ورودی به ۲۰ ماتریس مجزا تقسیم می‌شود. پس از بررسی صحت داده‌های سنسورها به منظور افزایش دقت محاسبات در شبکه عمیق نیاز است که تعداد داده‌های ورودی افزایش یابد. به این منظور تانسور اولیه با ابعاد (۷, ۳۶۰,۰۰۰, ۲۴) با تغییر ابعاد به تانسوری با ابعاد (۷, ۱۸,۰۰۰, ۴۸۰) تبدیل می‌شود. در نتیجه تعداد داده‌های ورودی محاسبات ۲۰ برابر افزایش می‌یابد. این امر موجب افزایش دقت شبکه در فرآیند آموزش خواهد شد. به منظور مقایسه توانایی شبکه در این مطالعه، داده‌ها در دو



شکل ۴: نگاه اجمالی به روش پیشنهادی شناسایی خسارت

مرحله یکبار بدون تابع نرمال سازی و بار دیگر با استفاده از تابع نرمال ساز Z-SCORE (نرمال سازی با استفاده از میانگین و انحراف معیار) قبل از ورود به فرایند آموزش شبکه نرمال می شوند [21].

## ۴-۲- معماری شبکه عصبی عمیق کانولوشن

تفاوت عمده شبکه های کانولوشن با شبکه عصبی معمولی در این است که در حداقل در یکی از لایه های آن از کانولوشن به جای ضرب معمولی استفاده می شود. در نتیجه این شبکه ها از تحلیل داده های با مکان شناسی شبکه ای مانند تصاویر و داده های زمانی دو بعدی بسیار کارآمد هستند.

در این مطالعه یک شبکه عمیق کانولوشن با چندین لایه مختلف طراحی شده است تا با استفاده از آنها داده های سالم و ناسالم یک کابلی از یکدیگر تشخیص داده شوند. یک شبکه کانولوشن به طور معمول از سه مرحله تشکیل می شود: کانولوشن، فعال سازی غیرخطی، و انتخاب. علاوه بر این از توابع بهینه ساز  $ADAM^{26}$  و  $SGD^{27}$  به صورت جداگانه جهت مقایسه عملکرد شبکه استفاده شده است. همان طور که در شکل ۵ نمایش داده شده است جزئیات معماری شبکه به این صورت خواهد بود: (۱) یک لایه کانولوشن به همراه لایه انتخاب (۲) دو لایه کانولوشن یکسان شامل لایه انتخاب و تابع فعال سازی (۳) در نهایت خروجی جهت تبدیل به داده یک بعدی از یک لایه تماما متصل (FC) عبور خواهد کرد [9].

## ۴-۳- لایه کانولوشن و انتخاب

کانولوشن و انتخاب هسته اصلی ترین بخش شبکه ی CNN است [22]. به طور کلی رابطه کانولوشن بین دو تابع اصلی مطابق رابطه ۴ نمایش داده می شود [23].

$$f(i) = \int_{-\infty}^{\infty} s(n)k(i-n)dn \quad (4)$$

در رابطه فوق  $n$  شمارنده عضو ورودی، مقدار  $s$  ورودی تابع و مقدار  $k$  تحت عنوان کرنل  $^{28}$  شناخته می شود. خروجی تابع فوق نقشه ویژگی  $^{29}$  تابع ورودی خواهد بود. در حالت کلی در محاسبات کامپیوتری توابع به صورت پیوسته و همانند تابع فوق عمل خواهند کرد، اما در حالت کلی می توان شکل رابطه ۵ را برای داده های حوزه اعداد حقیقی در نظر گرفت. در این رابطه، مقادیر  $v_s$  و  $v_k$  (حدود نهایی مقادیر ورودی و کرنل) تعریف می شوند.

$$F(i) = \sum_{n=1}^{v_k} S(i-n)K(n) = \sum_{n=1}^{v_s} S(n)K(i-n) \quad (5)$$

هر دو سمت رابطه فوق در تعریف یکسان عمل می کنند. اما اولین رابطه که در محدوده کرنل حرکت می کند در الگوریتم های یادگیری ماشین پاسخ بهتری خواهد داد، چرا که مقدار کرنل در یک مجموعه چند بعدی داده بازه کوچکتری دارد و عملکرد بهتری خواهد داشت. در رابطه فوق با افزایش  $n$  مقدار کرنل رو به جلو حرکت کرده اما داده ورودی عقب رفت خواهد کرد و این ویژگی اشتراک را در کانولوشن ایجاد می کند. معمولا از رابطه ۶ به عنوان نتیجه نهایی در کاربرد عملگر کانولوشن استفاده می شود [24].

26 ADaptive Moment estimation(ADAM)

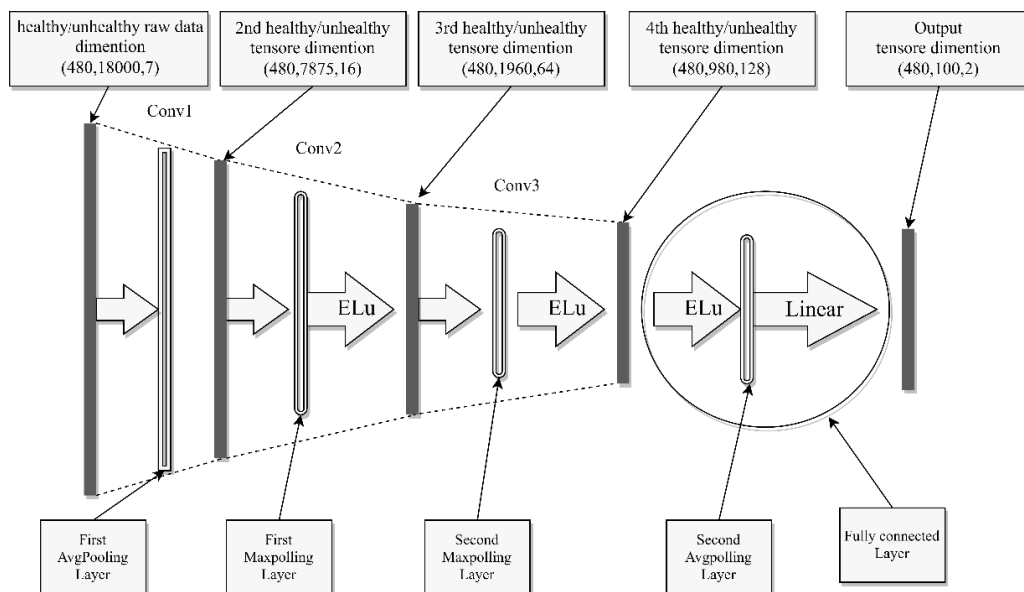
27 Stochastic Gradient Descent (SGD)

28 Kernel

29 Feature map

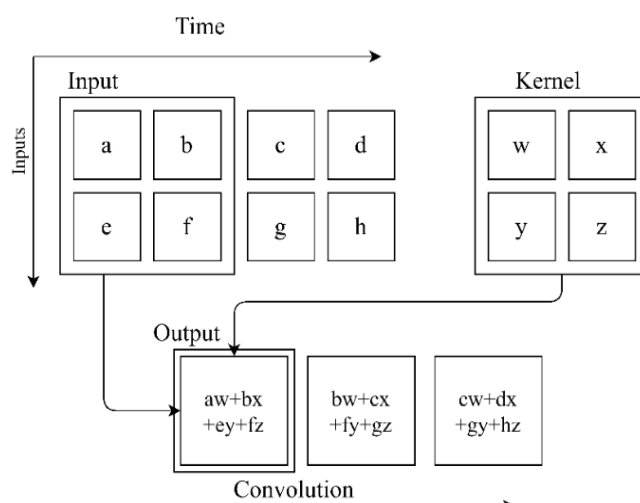


$$F(i) = \sum_{n=1}^{u_k} S(i+n)K(n) \quad (6)$$



شکل ۵: معماری شبکه کانولوشن


در نهایت این رابطه نشان دهنده یک رابطه یک بعدی کانولوشن با یک کانال ورودی است. به طور کلی می توان با استفاده موازی از چند شبکه تک بعدی برای حالت های با چند داده ورودی نیز استفاده کرد. شکل (۶) تصویر کلی یک شبکه کانولوشن تک بعدی با دو کانال ورودی در راستای زمان را نشان می دهد. در این مثال ورودی یک تنسور از مجموعه بردارهایی با طول ۲ است که کرنلی با بعد ۲ به آن اعمال می شود. خروجی نتیجه جمع ضرب درایه به درایه تنسور کرنل در تنسور ورودی و سپس تکرار این عمل بعد از حرکت به مقدار گام در راستای زمان خواهد بود. در سوی دیگر لایه های انتخاب به عنوان یکی از مهمترین بخش های شبکه کانولوشن وظیفه اعمال عملگرهای عددی/آماری بر روی خروجی را برعهده دارند. لایه های انتخاب انواع مختلفی دارند. در این مطالعه از لایه های انتخاب میانگین و حداکثر استفاده شده است. این لایه ها همانند عملگر کرنل در راستای محور بر روی داده حرکت کرده و در عوض اعمال عملگر کانولوشن، میانگین داده های داخل کرنل و یا بزرگترین عدد داخل مجموعه را انتخاب می کنند. لایه های انتخاب از دو منظر باعث بهبود عملکرد شبکه می شوند (۱) با کاهش سایز داده در مراحل مختلف محاسبات را آسان تر می کنند. (۲) این لایه ها با کاهش پراکندگی داده ها سعی می کنند همخوانی بیشتر بین آن ها ایجاد کنند در نتیجه شبکه عصبی عملکرد بهتری خواهد داشت [25].



شکل ۶: نمای کلی یک شبکه کانولوشن

## ۴-۴- تابع فعال ساز

توابع فعال ساز عنصر جدانشدنی از یک شبکه عصبی هستند که با تغییر عملکرد خطی شبکه به مدل غیرخطی ظرفیت پاسخگویی شبکه را افزایش می‌دهند. به طور معمول تابع سیگموئید به فرم  $\sigma(x) = 1/(1 + e^{-x})$  تعریف شده است به دلیل عملکرد خود به عنوان تابع فعال ساز مورد استفاده قرار می‌گیرد. این تابع به دلیل آن که در فرآیند پس انتشار<sup>۳۰</sup>، شبکه خروجی را در بازه‌ی بین صفر و یک مقیاس می‌کند، باعث سهولت در محاسبات می‌شود. از سوی دیگر همین امر باعث می‌شود که اگر داده‌ها در فرآیند پس انتشار از مقدار صفر و یک کمتر یا بیشتر باشند خروجی صحیح نباشد. در نتیجه در سالهای اخیر استفاده از این رابطه کاهش یافته است. اخیراً تابع نمایی خطی یا  $eLU^{31}$  (شکل (۷) الف) و مدل نمایی تابع اصلاح شده خطی یا  $ReLU^{32}$  (شکل (۷) ب) رابطه (۸))



شکل ۷: نمودار توابع فعال سازی (الف) تابع eLU (ب) تابع ReLU

(۸) بیشتر مورد استفاده قرار می‌گیرد [26], [10], [9].

30 Back propagation

31 Exponential Linear Unit

32 Rectified Linear Unit

$$ReLU(z) = \max(0, a_k) \quad (7)$$

$$eLU(z) = \begin{cases} a_k & a_k > 0 \\ \alpha \cdot (e^{a_k} - 1) & a_k < 0 \end{cases} \quad (8)$$

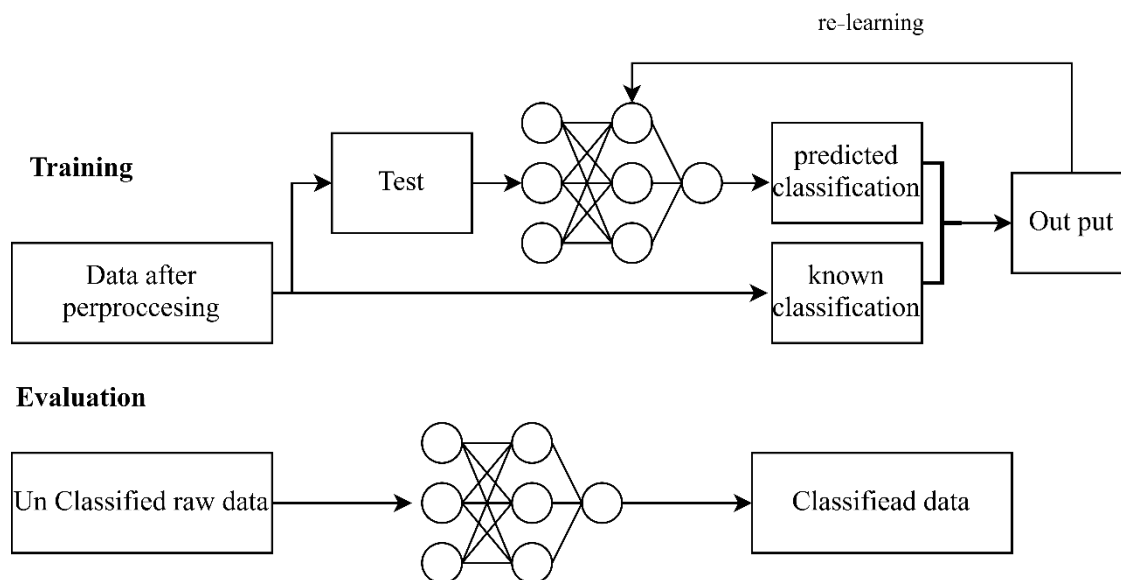
تابع ReLU از لحاظ عملکرد در مرحله پس انتشار باعث می شود تا گرادبان تابع به صورت بهینه تری توزیع شود و مانند تابع سیگموئید در محدوده صفر و یک محدودیت نداشته باشد اما این تابع نیز برای حالت های کمتر از صفر محدودیت عملکرد دارد. به همین دلیل در این پژوهش از تابع نمایی خطی eLU استفاده شده است تا در نواحی کمتر از صفر نیز عملکرد بهبود پیدا کند. این عمل باعث بهبود سرعت و عملکرد آموزش نسبت به تابع سیگموئید و ReLU می شود.

#### ۵-۴- تشخیص آسیب

در این بخش با معرفی شبکه عصبی CNN پیشنهادی عملکرد آن در تشخیص سیگنال های ساده و آسیب دیده را بررسی خواهیم کرد. همان طور که در شکل (۵) قبلا نشان داده شد، شبکه حاضر از دو بخش اصلی لایه های کانولوشن (CNN) و لایه تماما متصل (FC) تشکیل شده است. هدف لایه های کانولوشن شناسایی ویژگی های نهفته در داده ها به منظور تشخیص آسیب دیده یا سالم بودن و در نهایت جداسازی آن ها از یکدیگر است. بدین این منظور ابتدا یک لایه انتخاب، (میانگین) داده ها را از لحاظ آماری کمی اصلاح خواهد کرد و سپس یک لایه کانولوشن وارد عمل شده و سپس یک لایه کانولوشن و یک لایه انتخاب (حداکثر) در دو مرحله پشت سر هم فرایند آموزش را انجام خواهند داد. در نهایت لایه تماما متصل با هدف دسته بندی نتایج نهایی وارد عمل خواهد شد. این لایه با دریافت داده های خروجی نهایی از آخرین لایه کانولوشن احتمال صحت آنها را بررسی کرده و دسته بندی درست را برای هر کدام انتخاب خواهد کرد.

همان طور که در شکل (۸) نمایش داده شده است شبکه در دو مرحله مجزا عمل می کند، در مرحله نخست شبکه طراحی شده سعی می کند با بررسی داده و سنجش آنها یک پیش بینی اولیه از دسته بندی داده شده ارائه می کند و آنها را با داده های در اختیار مقایسه می کند و سپس آموزش را تکرار خواهد کرد تا شبکه به بهترین حالت خود دست یابد. سپس در مرحله سنجش مجددا داده های خامی که تاکنون به شبکه معرفی نشده اند وارد جریان شده و پس از خروج از شبکه با دسته بندی منتصب از سوی شبکه خارج خواهد شد. داده های ورودی مجموعه رکوردهای شتاب برداشت شده از پل هستند که همان طور که در بخش ۲-۲-۱ اشاره شد کل سنسور خواهد بود، به جهت دستیابی به بهترین حالت آموزش توسط شبکه عصبی ترکیبات مختلف دسته بندی اعداد جهت آموزش و و سنجش مورد بررسی قرار گرفت و در نهایت ۷۰ درصد آن به عنوان داده آموزش شبکه استخراج شده و ۳۰ درصد جداگانه برای بررسی و سنجش استفاده شده است [27], [23]. به عنوان یک شبکه آموزش با از داده های ورودی می باشد که در حقیقت همان برچسب سالم یا آسیب داده است. به این منظور داده های سالم با برچسب ۱ و داده های آسیب دیده با برچسب ۰ به شبکه معرفی شده اند. داده های موجود در هر مرحله ۱۸۰۰۰ ورودی برای هر شبکه در مرحله آموزش و تمرین خود سعی خواهد کرد تا برای هر کدام از مجموعه داده ها برچسبی پیش بینی کند. این پیش بینی ها به صورت احتمالاتی از سوی شبکه معرفی خواهند شد به این صورت که پیش بینی شبکه در مورد نشانه گذاری داده ها بین ۰ تا ۱۰۰ به صورت احتمالاتی اعلام خواهد شد، این خروجی ها در ادامه به عنوان ورودی به لایه بیشینه هموار<sup>۳۳</sup> معرفی خواهند شد [28]، این تابع خروجی ها را در بازه بین صفر و یک تقسیم خواهد کرد تا به عنوان احتمال آسیب که توسط شبکه CNN حاصل شده اند در نظر گرفته شوند. به عبارت دیگر شبکه در مقابل هر ورودی یک احتمال آسیب تولید خواهد کرد.

تابع کراس آنترپپی<sup>۳۴</sup> با هدف محاسبه و بررسی نتایج حاصل از هر دور آموزش شبکه توزیع های احتمالاتی خروجی را به صورت یک تابع قابل ارزیابی ارائه می دهد [29].



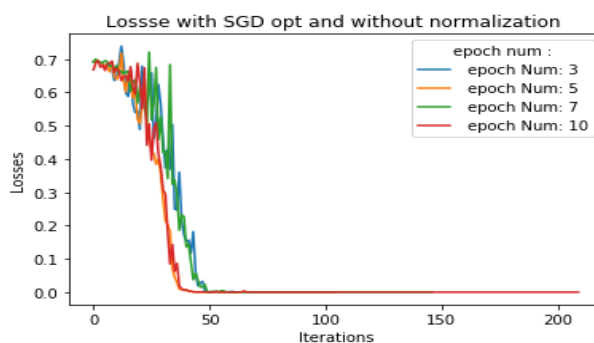
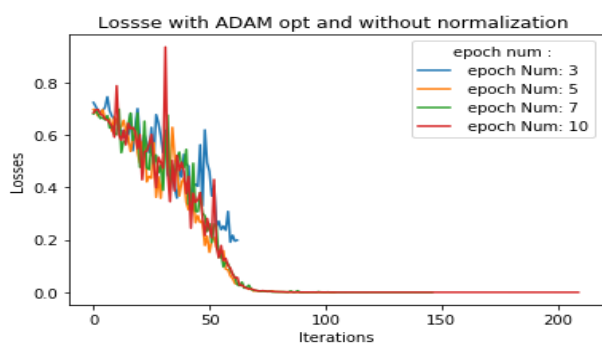
شکل ۸: نمای کلی عملکرد شبکه در تشخیص و دسته بندی داده ها

$$H(p, q) = - \sum_x p(x) \log(q(x)) \quad (9)$$





در رابطه (۹)،  $H$  خروجی تابع کراس آنترپپی و  $x$  مقدار مجاز توزیع احتمالاتی مورد نظر در خروجی شبکه خواهد بود که در این پژوهش شماره اعضای ماتریس احتمالاتی آسیب خروجی از شبکه است. مقدار  $p(x)$  نمایش دهنده مقدار متناظر برچسب دسته بندی درست معرفی شده به شبکه است که نمایش دهنده احتمال صحیح آسیب دیده یا سالم بودن عضو مورد نظر است.  $q(x)$  نیز مقدار متناظر با عضو در مجموعه احتمالاتی خروجی از شبکه است. در نهایت نیز به جهت بهبود عملکرد تابع اتلاف از توابع بهینه سازی استفاده می شود: توابع ADAM و SGD که هر کدام در سناریوهای مجزا عمل کرده و محاسبات خروجی را اصلاح می کنند [30].

جدول ۱: سناریوهای مختلف تحلیل داده در شبکه طراحی شده

شرایط پیش پردازش	تابع بهینه سازی	تعداد دوره های تکرار
بدون تابع نرمال سازی	ADAM	3,5,7,10 epochs
	SGD	
با استفاده از تابع نرمال سازی Z-Score	ADAM	
	SGD	




شکل ۹: نمودار تابع اتلاف شبکه بدون نرمال سازی با تعداد دوره های برداشت مختلف از دسته داده ها (الف) تابع اتلاف / SGD (ب) تابع اتلاف ADAM



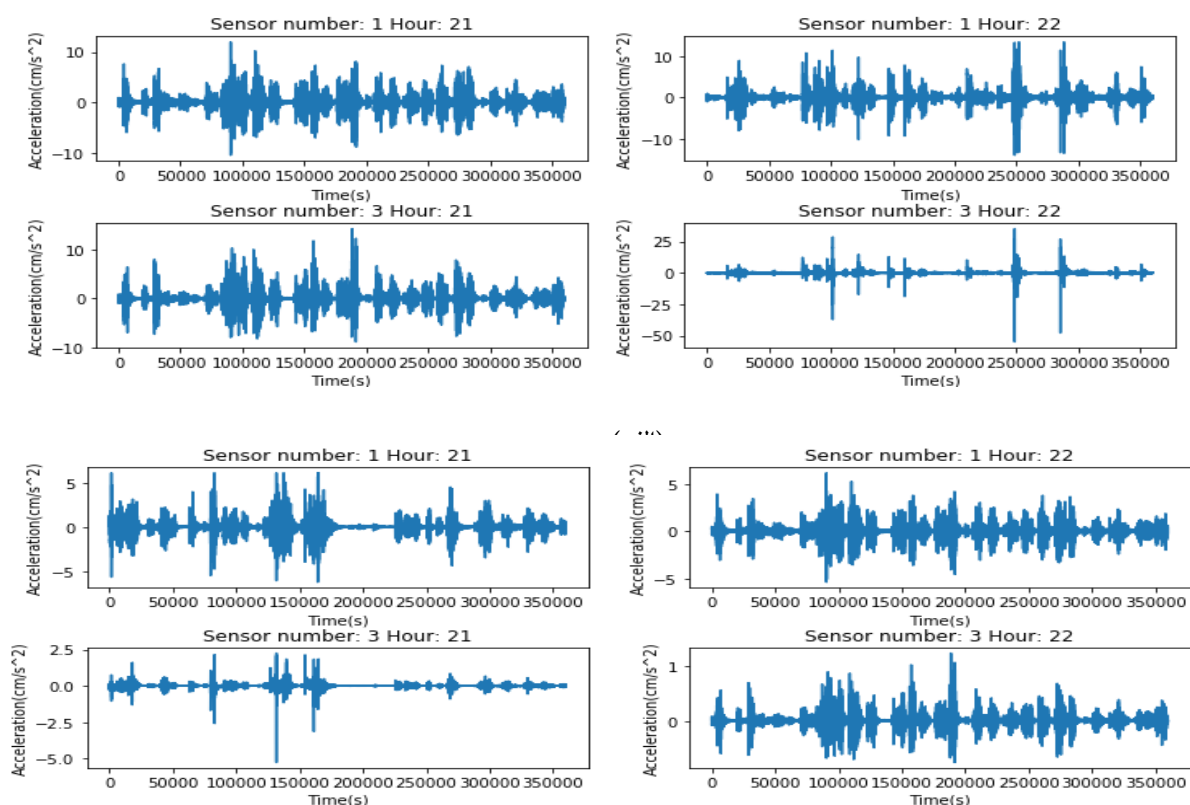
شکل ۱۰: مقایسه فرایند آموزش شبکه و کاهش میزان اتلاف با استفاده از دو تابع آدام و گرادینان کاهش می دهد در دوره های مختلف برداشت داده (الف) ۳ (ب) ۵ (ج) ۷ (د) ۱۰

## ۵- نتایج

قبلاً بیان شد که در این پژوهش هدف سنجش کارایی شبکه آموزش عمیق به هم تنیده یک‌بعدی است و در این مسیر حالت‌های مختلف داده‌های ورودی، تکرارهای مختلف و توابع بهینه‌سازی متفاوت کنترل خواهد شد. بدین منظور در این بخش ۴ سناریوی جدول (۱) مورد بررسی قرار گرفته‌اند.




شکل ۱۱: مقایسه عملکرد دو تابع بهینه ساز در میزان اتلاف و دقت محاسبه / (الف) نمودار مقایسه دقت / (ب) نمودار مقایسه اتلاف



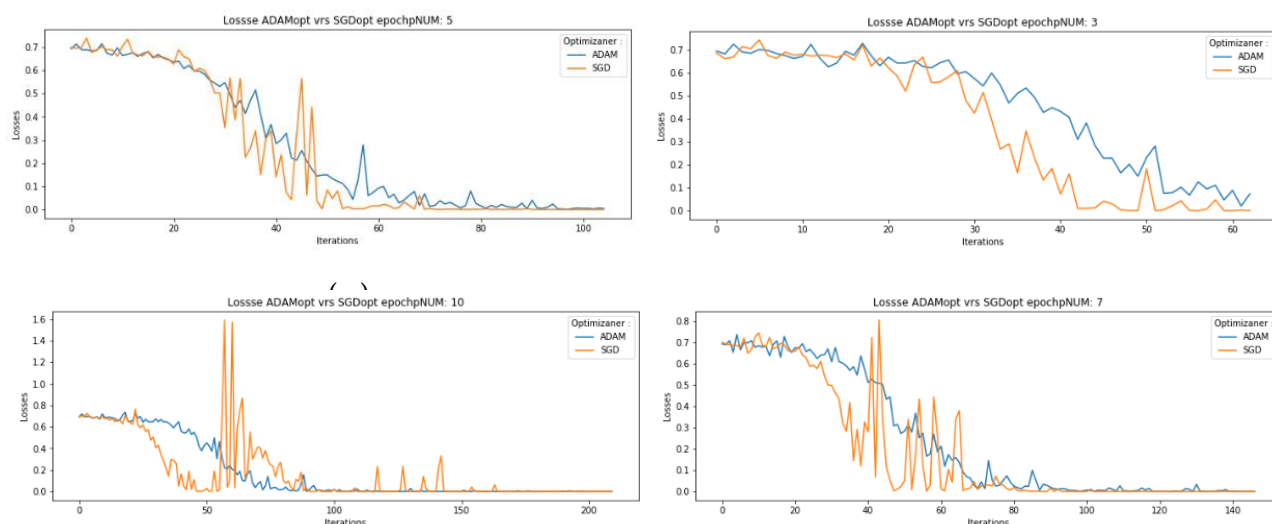
شکل ۱۲: نمونه داده های شتاب نگاشت حالت آسیب دیده ساعت ۲۱ و ۲۲ (۲۱ جولای) (الف) حالت عادی / (ب) تحت اثر تابع Z-Score

## ۵-۱- آموزش بدون نرمال سازی :

در گام نخست، داده‌ها در فاز پیش‌پردازش تنها جداسازی شده و افزایش می‌یابد و هیچ‌گونه فرایند نرمال‌سازی بر روی آن‌ها انجام نمی‌شود، هدف اصلی در نرمال‌سازی داده‌ها اصلاح مقادیر داده‌های ورودی نسبت به یکدیگر است و بررسی می‌شود که شبکه طراحی شده تا چه اندازه می‌تواند داده‌های نامتوازن ورودی را دسته‌بندی کرده و پاسخ مناسب را بیابد. به این منظور داده‌ها تنها دسته‌بندی شده و به شبکه وارد می‌شوند. در گام بعدی به جهت مقایسه عملکرد دو تابع بهینه‌سازی آدام و گرادیان کاهشی، شبکه تحت اثر هر دو به صورت مجزا در دوره‌های<sup>۳۵</sup> مختلف اجرا شده و نتایج آن مورد بررسی قرار خواهد گرفت. شکل (۹) به ترتیب نمایانگر نتایج حاصل از شبکه با استفاده از تابع نرمال‌سازی آدام و گرادیان کاهشی است. مشاهده می‌شود که در هر ۴ دوره انتخاب شده، شبکه هرچند با افت و خیز بسیار ولی در نهایت به شرایط نرمال خود می‌رسد و پاسخ مناسبی با دقت ۱ در اختیار قرار می‌دهد. هرچند میزان اتلاف نهایی با تابع آدام در ۳ دوره انتخابی از سایر حالت‌ها بیشتر است، اما در نهایت تفاوت چندانی بین آن‌ها مشاهده نمی‌شود. تابع گرادیان کاهشی نیز بهترین پاسخ را برای برداشت ۵ دوره انتخابی می‌یابد و در سایر حالت‌ها مانند حالت پیشین افت و خیز نسبتاً زیادی مشاهده می‌شود.

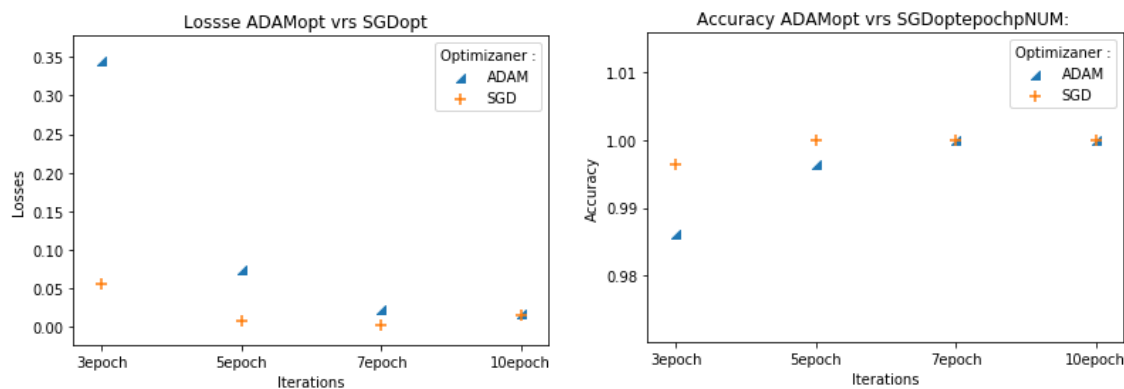


شکل ۱۳: نمودار تابع اتلاف شبکه تحت اثر تابع Z-score و بهینه‌ساز گرادیان کاهشی با تعداد دوره‌های برداشت مختلف از دسته داده‌ها (الف) با تابع اتلاف SGD / (ب) با تابع اتلاف ADAM



شکل ۱۴: مقایسه فرایند آموزش شبکه و کاهش میزان اتلاف با استفاده از دو تابع آدام و گرادیان کاهشی در دوره‌های مختلف برداشت داده تحت اثر تابع نرمال‌سازی Z-score (الف) ۳ (ب) ۵ (ج) ۷ (د) ۱۰

پس از انجام محاسبات مجدد داده‌های حاصل از هر دوره برداشت شبکه در دو حالت با یکدیگر مقایسه می‌شوند تا مدل بهینه به دست آید. شکل (۱۰) (الف) تا (د) مقایسه‌ای است بین عملکرد دو تابع در نحوه آموزش شبکه، چنانکه پیش از این گفته شد هر دو تابع در نهایت به همگرایی خوبی می‌رسند اما شبکه با تابع گرادیان کاهشی سرعت و عملکرد بهتری در مقایسه با تابع آدام دارد. در شکل (۱۱) (الف) تا (ب) مشاهده می‌شود که در نهایت هر دو تابع با دقت نزدیک به ۱، اتلاف بسیار کم پاسخ نهایی را به دست می‌آورند و چنانچه بیان شد در اینجا نیز مشاهده می‌شود که تابع گرادیان کاهشی در میزان اتلاف و دقت نیز عملکرد بهتری داشته است.



شکل ۱۵: مقایسه عملکرد دو تابع بهینه ساز تحت اثر تابع نرمال ساز Z-score در میزان اتلاف و دقت محاسبه (الف) نمودار مقایسه دقت (ب) نمودار مقایسه اتلاف

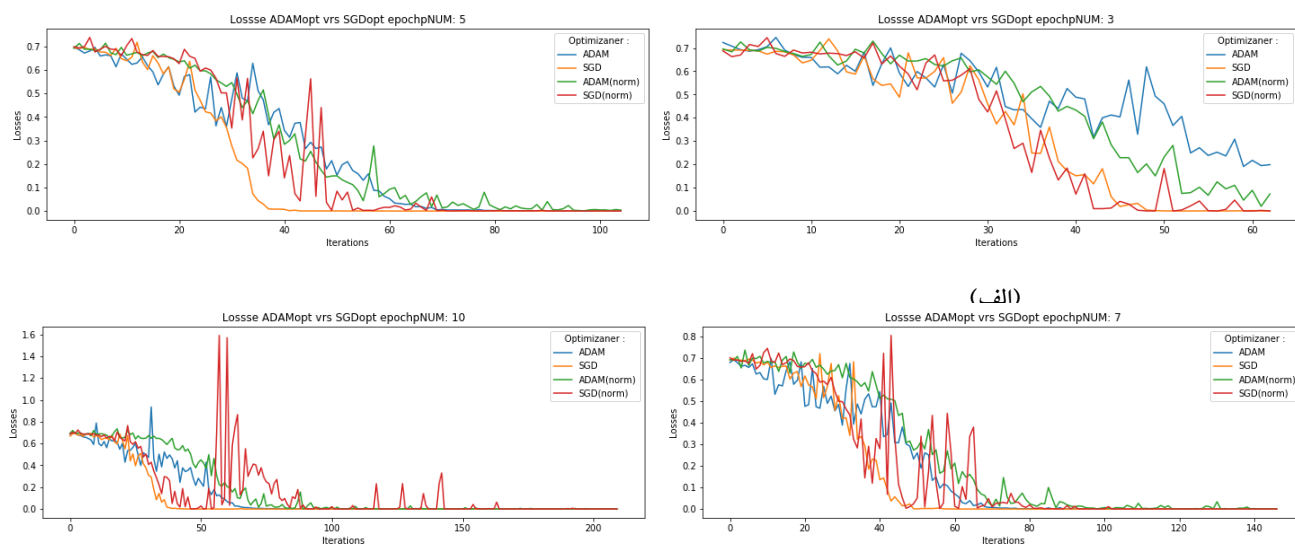
## ۲-۵- آموزش با نرمال سازی

به جهت مقایسه روش بهینه استفاده از شبکه عمیق در گام بعدی مجدداً داده‌های موجود وارد فرآیند پیش‌پردازش می‌شوند. با این تفاوت که این بار داده‌ها با استفاده از تابع نرمال‌سازی Z-SCORE (نرمال‌سازی با استفاده از میانگین و انحراف معیار) قبل از ورود به فرآیند آموزش شبکه نرمال می‌شوند. سایر مراحل همانند فاز اول کنترل شبکه خواهد بود. در ادامه نتایج حاصل ارائه خواهد شد. شکل (۱۲) شتاب‌نگاشت پل در حالت آسیب‌دیده پیش و پس از اعمال تابع نرمال‌سازی را نمایش می‌دهد. مشاهده می‌شود که پس از اعمال نرمال‌سازی دامنه داده‌های موجود تغییر کرده و همبستگی داده‌ها نسبت به حالت قبل بیشتر شده است. با بررسی داده‌های حاصل از آموزش شبکه و مقایسه نتایج نمایش داده‌شده در شکل‌های (۱۳) تا (۱۵) مشخص است که تابع بهینه‌ساز آدام در شرایط بهره‌برداری از نرمال‌سازی، عملکرد به مراتب بهتری از خود نشان می‌دهد و تابع گرادیان کاهشی نیز افت محسوسی در عملکرد خود نسبت به حالت بدون نرمال‌سازی نشان داده است. این تفاوت می‌تواند به دلیل نوع داده‌های حاصل از شتاب‌نگاشت باشد و اختلاف دامنه‌های داده‌ها در هر بازه شرایط را برای تابع بهینه‌ساز دشوار کرده است.

## ۳-۵- جمع‌بندی نتایج

مشاهده می‌شود که با توجه به نتایج نشان داده‌شده در شکل (۱۶)، می‌توان به این جمع‌بندی رسید که اولاً شبکه عصبی عمیق کانولوشن به خوبی قابلیت پاسخ‌دهی به مسئله مطرح‌شده را دارا است و با دقت مناسب توانایی تشخیص حالت سالم از خراب را دارا است به طوری که در هر ۴ سناریوی مطرح‌شده توانایی تشخیص با دقت بالای ۹۰ درصد را از خود نشان داده است. از سوی دیگر به منظور یافتن شبکه‌ای در جهت بهبود فرآیند آموزش داده‌های شتاب‌نگاشت، مقایسه‌ای بین دو روش بهینه‌سازی آدام و گرادیان کاهشی در دو حالت با و بدون نرمال‌سازی انجام شد که در نهایت می‌توان بیان کرد که روش بهینه‌ساز آدام در حالت استفاده از تابع نرمال‌سازی عملکرد بهتری برای آموزش از خود نشان می‌دهد و نمودار همگرایی تابع اتلاف با گام‌های منطقی کاهش می‌یابد. از سوی دیگر عکس این عملکرد برای تابع گرادیان کاهشی اتفاق می‌افتد و این تابع در شرایطی که تابع نرمال‌سازی استفاده نشده است عملکرد بهتری دارد. این تفاوت می‌تواند ریشه در ماهیت اصلی این دو روش داشته باشد. به طور کلی می‌توان گفت از آنجا که دامنه فرکانسی سیگنال‌های پل‌ها و ساختمان‌ها در حالت





شکل ۱۶: مقایسه فرایند آموزش شبکه و کاهش میزان اتلاف با استفاده از دو تابع آدام و گرادیان کاهشی در دوره های مختلف برای هر ۴ سناریوی مورد بررسی الف ۳/ ب ۵/ ج ۷/ د ۱۰

سالم و آسیب متفاوت و این تابع در شرایطی که تابع نرمال سازی استفاده نشده است عملکرد بهتری دارد. این تفاوت می تواند ریشه در ماهیت اصلی این دو روش داشته باشد. پل ها و ساختمان ها در حالت سالم و آسیب متفاوت است، سیگنال خام پاسخ بهتری را خواهد داشت و سیگنال نرمال شده ممکن است سیگنال را دستخورده کرده و روند آموزش را با اختلال مواجه کند. به همین دلیل تابع آدام پاسخ بهتری را نسبت به روش ساده تر گرادیان کاهشی نتیجه داد. به طور کلی می توان گفت از آنجا که دامنه فرکانسی سیگنال های پل ها و ساختمان ها در حالت سالم و آسیب متفاوت و این تابع در شرایطی که تابع نرمال سازی استفاده نشده است عملکرد بهتری دارد. این تفاوت می تواند ریشه در ماهیت اصلی این دو روش داشته باشد. به طور کلی می توان گفت از آنجا که دامنه فرکانسی سیگنال های پل ها و ساختمان ها در حالت سالم و آسیب متفاوت است، سیگنال خام پاسخ بهتری را خواهد داشت و سیگنال نرمال شده ممکن است سیگنال را دستخورده کرده و روند آموزش را با اختلال مواجه کند. به همین دلیل تابع آدام پاسخ بهتری را نسبت به روش ساده تر گرادیان کاهشی نتیجه داد.

## ۶- نتیجه گیری

در این پژوهش یک روش کارآمد مبتنی بر شبکه های عصبی در هم تنیده برای شناسایی خسارت در یک پل کابلی واقعی ارائه شد. برخلاف تحقیقات گذشته، از یک شبکه کوچک با تعداد لایه های کم استفاده شد که نیاز به داده کمتر داشته و آموزش آن بسیار ساده تر است. داده های ورودی بر خلاف روش های پیشین بدون هیچ تغییر اولیه وارد شبکه شدند، در این پژوهش از داده های شتاب نگاشتی برداشت شده از حالت های سالم و ناسالم پل استفاده شد و بر خلاف روش های مودال و انرژی فرآیند استخراج ویژگی از داده ها تماماً توسط خود شبکه انجام شده است ضمناً این شبکه با دو پیش فرض استفاده از تابع آدام و گرادیان کاهشی مورد استفاده قرار گرفت. نتایج نشان داد که سالم از ناسالم را دارا است. ضمناً این روش توانایی کاربرد به صورت بلادرنگ را دارا است. از سوی دیگر روش بهینه سازی آدام در صورت استفاده از تابع نرمال کننده عملکرد بهتری داشته و تابع گرادیان کاهشی نیز در محاسبات داده های خام پاسخ بهتری می دهد. در نهایت می توان گفت روش شبکه عصبی عمیق کانولوشن یک روش کارآمد جهت شناسایی خسارت پل ها است، هرچند اختلافاتی در فرآیند آموزش شبکه برای حالت های مختلف مشاهده شد.

## مراجع

- [1] J. Peng, S. Zhang, D. Peng, and K. Liang, "Application of machine learning method in bridge health monitoring," 2017 2nd Int. Conf. Reliab. Syst. Eng. ICRSE 2017, no. Icrse, 2017, doi: 10.1109/ICRSE.2017.8030793.

- [2] K. H. Padil, N. Bakhary, and H. Hao, "The use of a non-probabilistic artificial neural network to consider uncertainties in vibration-based-damage detection," *Mech. Syst. Signal Process.*, vol. 83, pp. 194–209, Jan. 2017, doi: 10.1016/j.ymsp.2016.06.007.
- [3] P. da S. L. Alexandrino, G. F. Gomes, and S. S. Cunha, "A robust optimization for damage detection using multiobjective genetic algorithm, neural network and fuzzy decision making," *Inverse Probl. Sci. Eng.*, vol. 28, no. 1, pp. 21–46, Jan. 2020, doi: 10.1080/17415977.2019.1583225.
- [4] H. S. Kim, C. Jin, M. H. Kim, and K. Kim, "Damage detection of bottom-set gillnet using Artificial Neural Network," *Ocean Eng.*, vol. 208, p. 107423, Jul. 2020, doi: 10.1016/J.OCEANENG.2020.107423.
- [5] D. E. Sidarta, J. O'Sullivan, and H. J. Lim, "Damage detection of offshore platform mooring line using artificial neural network," in *Proceedings of the International Conference on Offshore Mechanics and Arctic Engineering - OMAE*, Sep. 2018, vol. 1, doi: 10.1115/OMAE2018-77084.
- [6] A. Santos, E. Figueiredo, M. F. M. Silva, C. S. Sales, and J. C. W. A. Costa, "Machine learning algorithms for damage detection: Kernel-based approaches," Elsevier, 2016.
- [7] C. Modarres, N. Astorga, E. L. Droguett, and V. Meruane, "Convolutional neural networks for automated damage recognition and damage type identification," *Struct. Control Heal. Monit.*, vol. 25, no. 10, pp. 1–17, 2018, doi: 10.1002/stc.2230.
- [8] M. Azimi, A. D. Eslamlou, and G. Pekcan, "Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review," *Sensors (Switzerland)*, vol. 20, no. 10, 2020, doi: 10.3390/s20102778.
- [9] Y. Z. Lin, Z. H. Nie, and H. W. Ma, "Structural Damage Detection with Automatic Feature-Extraction through Deep Learning," *Comput. Civ. Infrastruct. Eng.*, vol. 32, no. 12, pp. 1025–1046, 2017, doi: 10.1111/mice.12313.
- [10] O. Abdeljaber, O. Avci, M. S. Kiranyaz, B. Boashash, H. Sodano, and D. J. Inman, "1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data," *Neurocomputing*, vol. 275, pp. 1308–1317, 2018, doi: 10.1016/j.neucom.2017.09.069.
- [11] Y. J. Cha, W. Choi, and O. Büyüköztürk, "Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks," *Comput. Civ. Infrastruct. Eng.*, vol. 32, no. 5, pp. 361–378, 2017, doi: 10.1111/mice.12263.
- [12] Y. Yu, C. Wang, X. Gu, and J. Li, "A novel deep learning-based method for damage identification of smart building structures," *Struct. Heal. Monit.*, vol. 18, no. 1, pp. 143–163, 2019, doi: 10.1177/1475921718804132.
- [13] Y. Bao, Z. Tang, H. Li, and Y. Zhang, "Computer vision and deep learning-based data anomaly detection method for structural health monitoring," *Struct. Heal. Monit.*, vol. 18, no. 2, pp. 401–421, 2019, doi: 10.1177/1475921718757405.
- [14] H. Liu and Y. Zhang, "Image-driven structural steel damage condition assessment method using deep learning algorithm," *Meas. J. Int. Meas. Confed.*, vol. 133, pp. 168–181, 2019, doi: 10.1016/j.measurement.2018.09.081.
- [15] T. Guo, L. Wu, C. Wang, and Z. Xu, "Damage detection in a novel deep-learning framework: a robust method for feature extraction," *Struct. Heal. Monit.*, no. 28, 2019, doi: 10.1177/1475921719846051.
- [16] H. Liu and Y. Zhang, "Deep learning-based brace damage detection for concentrically braced frame structures under seismic loadings," *Adv. Struct. Eng.*, 2019, doi: 10.1177/1369433219859389.
- [17] C. Modarres, N. Astorga, E. L. Droguett, and V. Meruane, "Convolutional neural networks for automated damage recognition and damage type identification," *Struct. Control Heal. Monit.*, vol. 25, no. 10, 2018, doi: 10.1002/stc.2230.
- [18] H. Li, J. Zhang, W. Li, and H. Jiang, "Study on the technology of replacement of closure segment for strengthening existing prestressed concrete cable stayed bridges," *Tumu Gongcheng Xuebao/China Civ. Eng. J.*, vol. 44, no. 7, pp. 83–89, 2011.
- [19] M. R. Kaloop and J. W. Hu, "Stayed-Cable Bridge Damage Detection and Localization Based on Accelerometer Health Monitoring Measurements," *Shock Vib.*, 2015, doi: 10.1155/2015/102680.
- [20] S. Arangio and F. Bontempi, "Structural health monitoring of a cable-stayed bridge with Bayesian neural networks," *Struct. Infrastruct. Eng.*, vol. 11, no. 4, pp. 575–587, 2015, doi: 10.1080/15732479.2014.951867.
- [21] J. DeLaughter, B. Meltz, S. Smith, J. Yun, and M. Murat, "Use of z-score to rescale amplitudes," *Lead. Edge*, vol. 24, no. 7, pp. 698–701, 2005, doi: 10.1190/1.1993260.

- [22] Y. LeCun and others, "Generalization and network design strategies," in *Connectionism in perspective*, 1989, pp. 143–155.
- [23] Y. LeCun *et al.*, "Backpropagation Applied to Handwritten Zip Code Recognition," *Neural Comput.*, vol. 1, no. 4, pp. 541–551, 1989, doi: 10.1162/neco.1989.1.4.541.
- [24] E. R. Ziegel, "The Elements of Statistical Learning," *Technometrics*, vol. 45, no. 3, pp. 267–268, 2003, doi: 10.1198/tech.2003.s770.
- [25] Y. T. Zhou and R. Chellappa, "Computation of optical flow using a neural network," 1988, pp. 71–78, doi: 10.1109/icnn.1988.23914.
- [26] M. Heusel *et al.*, "Fast and Accurate CNN Learning on ImageNet," *Iccv*, p. 2015, 2015.
- [27] L. Bull, K. Worden, G. Manson, and N. Dervilis, "Active learning for semi-supervised structural health monitoring," *J. Sound Vib.*, vol. 437, pp. 373–388, 2018, doi: 10.1016/j.jsv.2018.08.040.
- [28] Y. Liu and Q. Liu, "Convolutional neural networks with large-margin softmax loss function for cognitive load recognition," in *Chinese Control Conference, CCC*, 2017, pp. 4045–4049, doi: 10.23919/ChiCC.2017.8027991.
- [29] Z. Zhang and M. R. Sabuncu, "Generalized cross entropy loss for training deep neural networks with noisy labels," in *Advances in Neural Information Processing Systems*, 2018, vol. 2018-Decem, pp. 8778–8788.
- [30] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," pp. 1–15, 2014, [Online]. Available: <http://arxiv.org/abs/1412.6980>.