



Identifying Apparent Welding Defects using Computer Vision Based on Deep Learning

Research Article

Mussa Mahmoudi¹, Soroush Ghaderi², Faezeh Mahmoudi³

DOI: [10.22067/jfcej.2022.75044.1118](https://doi.org/10.22067/jfcej.2022.75044.1118)

1. Introduction

There are various methods to identify damage in different conditions according to the importance of the structure, severity of damage, and type of damage. In general, structural damage detection methods can be divided into two categories: destructive methods and non-destructive methods. In destructive methods, which are often accompanied by testing or sampling of the original structure, the structure is changed and even in some cases it cannot be used anymore. Therefore, these methods are severely limited and as a result, in the field of damage identification, non-destructive methods will be more suitable option for continuous examination of the structure's condition, identification of possible damages, and safety evaluation.

Recent advances regarding computers, sensors, and other electronic technologies have turned non-destructive methods into effective, easy, and cost-effective methods for damage detection. Non-destructive methods are also divided into two categories: local and general damage detection methods.

Welding quality control (as one of the methods of making connections in steel buildings) has an important position in identifying damage in steel structures. Among the methods for detecting damage in welding, we can refer to objective inspection, magnetic field, ultrasonic, radiography, microwave, eddy current, thermal field, and image processing.

Defects that may appear in the appearance of the welding include the following: 1) Lack of Fusion (LOF); 2) Lack of Penetration (LOP); 3) Porosity; 4) Undercut; 5) Slag Inclusion; 6) Overlap; 7) Spatter; 8) Cracks.

2. Materials and methods

The Internet can be the largest source for providing images as software data, but because the more the number of images in the database the more accurate the software will be, other sources have been used to prepare images. These sources are technical and professional education centers and schools. Defects in these samples are identified by experienced weld inspectors before they are used in

machine learning. For the proper use of captured images, the images that are given as input to the software are pre-processed by the user and modified in terms of framing. In this research, 52 photos of spatter class, 56 slag inclusion impurities, 104 undercuts, and 80 cracks were included for the database which are actually balanced data. Validating the model with usual factors is considered valid. Moreover, pre-processing was done on the images that automatically detects the weld area through deep learning. In addition to the mentioned cases, the data augmentation method can be a suitable approach to generate more training data. In this way, they enhance the samples through a number of random transformations that produce acceptable images. The model deals with more aspects of the data and generalizes better.

This research designs a program using image processing and artificial intelligence methods that can accurately detect and identify welding defects. Python programming language and OpenCV framework are used for image processing, Keras library is used to build and implement deep neural network, and Tensor platform is used for to detect and predict defects.

Convolutional neural networks (CNN) are very similar to artificial neural networks. The neural network takes all the training data in the input layer. It then passes the data through the hidden layers and changes the values based on the weight of each node. Finally, it returns its value in the output layer. Convolutional neural network is a special type of neural network with multiple layers. It processes data that has a grid arrangement and then extracts important features. A big advantage of using CNN is that you don't need to do many processing steps on the images.

3. Results and discussion

Figure 1 and 2 show the accuracy and cost in the training process, where the horizontal axis represents the number of training steps (dimensionless). Moreover, the vertical axis in Figure 1 shows the cost of training and in Figure 2 the accuracy of training. The vertical axes are scaled from zero to one. Examining Figure 1 and 2 shows that the system did not suffer from overfitting in the training phase.

*Manuscript received: January 31, 2022, Revised, September 7, 2022, Accepted, November 29, 2022.

¹.Corresponding Author Professor, Department of structure and earthquake engineering, Shahid Rajaei Teacher Training University, Email: m.mahmoudi@sru.ac.ir

². Master Graduate, Department of structure and earthquake engineering, Shahid Rajaei Teacher Training University.

³. Master Graduate, Department of Artificial intelligence, Azad University, Tehran Gharb Branch.

The input images apply changes so that the program can process it. Then the model is trained to analyze and process the image and by extracting the features of the image, predict the percentage belonging to each of the classes.



Figure 1. The cost of training compared to the increase of training steps

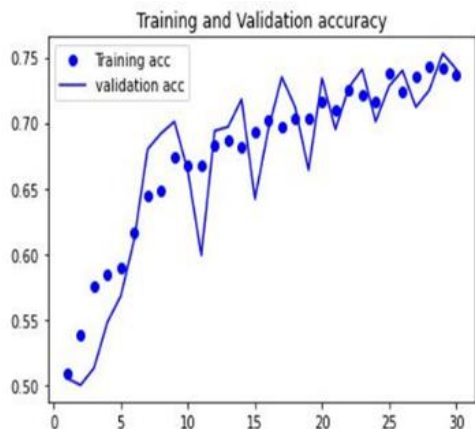


Figure 2. Validation compared to increasing training steps

4. Conclusion

This research proposed a method that can be used for detecting welding defects with the help of a machine and without the need for skilled inspectors. For using this method, it is enough to give the digital image of the tested weld to the software and conclude the health status of the weld. If the weld has several defects at the same time, the software expresses the contribution of each of the defects as a percentage. In order to validate the method and ensure the effectiveness of the software, several samples of defective welding images in which the amount of each type of welding defect was determined by expert welding inspectors were given to the machine, and the machine detected each defect with at least 85% accuracy.

According to the results of this research and the examples that were evaluated by this method, the following advantages can be considered for the proposed method:


- The use of this method and software can greatly reduce the need for skilled welding inspectors to detect external defects;
- The use of machines can significantly reduce human error in detecting external defects and even identify secondary defects;
- By using the proposed method, the time required to check welding defects with a large number is significantly reduced.



شناسایی عیوب ظاهری جوش با استفاده از بینایی ماشین بر اساس یادگیری عمیق*

مقاله پژوهشی

DOI: 10.22067/jfpei.2022.75044.1118

موسی محمودی صاحبی^(۱)  سروش قادری^(۲) فائزه محمودی صاحبی^(۳)

چکیده یکی از کنترل‌های کیفیت جوش، کنترل عیوب ظاهری جوش مانند ترک سطحی، جرقه و پاشش، سر رفتن جوش بر روی فلز و ذوب ناقص است. در حال حاضر بر اساس ضوابط آیین‌نامه‌ها، کیفیت ظاهری جوش توسط یک بازررس به صورت چشمی (تست چشمی) کنترل می‌شود. میزان دقت کار در این روش به میزان مهارت شخص بازررس بستگی دارد. عدم استفاده از تجهیزات و فناوری باعث می‌شود تا خطای شناسایی عیوب ظاهری بالا باشد. در این تحقیق، روشی پیشنهاد می‌گردد تا به کمک تصاویر حاصل از جوش و استفاده از بینایی ماشین بر اساس یادگیری عمیق بتوان با دقت و سرعت مناسب عیوب ظاهری جوش را شناسایی کرد. در یادگیری عمیق از شبکه کونولوشنال برای استخراج ویژگی از تصویر استفاده می‌شود. برای اطمینان از دقت روش پیشنهادی، تصاویر جدیدی از جوش معیوب که قبلاً وضعیت آنها توسط بازرسان مجرب تعیین شده بود انتخاب گردید و وضعیت سلامت آنها به کمک ماشین مورد ارزیابی قرار گرفت. نتایج نشان می‌دهد روش پیشنهادی می‌تواند با دقت قابل قبول (بالای ۸۵ درصد)، عیوب ظاهری جوش را شناسایی کند. همچنین نتایج نشان می‌دهد، با استفاده از روش پیشنهادی، عیوب ظاهری جوش در مقایسه با روش سنتی با سرعت بیشتری مورد ارزیابی قرار می‌گیرد.

واژه‌های کلیدی عیوب ظاهری جوش، شبکه عصبی کانولوشنال، پردازش تصویر، یادگیری عمیق، بینایی ماشین.

Identification of Apparent Welding Defects Using Computer Vision Based on Deep Learning

Mussa Mahmoudi Soroush Ghaderi Faezeh Mahmoudi

Abstract One of the welding controls in health monitoring of structures is to visually control the appearance of welding defects (cracks, Spatter, Overlap, Lack of Fusion). Currently, according to regulations, the appearance quality of welding is controlled by an inspector visually. The accuracy of work in this method depends on the skill level of the inspector. Non using of equipment and technology leads to a high error in identifying visual defects. In this research, a method is proposed to be able to more accurately identify the appearance of welding defects with the help of imaging using machine vision based on deep learning. Convolutional network is used for deep learning to extract features from the image. The results show that the proposed method can identify welding defects with an acceptable accuracy (over 85%). Also, the results show that by using the proposed method, welding defects are evaluated more quickly compared to the traditional method.

Keywords appearance welding defects, Convolutional Neural Network, image processing, deep learning, computer vision.

* تاریخ دریافت مقاله ۱۴۰۰/۱۱/۱۱ و تاریخ پذیرش آن ۱۴۰۱/۹/۸ می‌باشد.


Email: m.mahmoudi@sru.ac.ir

(۱) نویسنده مسئول: استاد گروه سازه و زلزله، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی.

(۲) کارشناسی ارشد سازه، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی.

(۳) کارشناسی ارشد هوش مصنوعی، دانشگاه آزاد واحد تهران غرب

در شکل (۱) تأثیر عوامل مهم بر روی کیفیت ظاهری جوش ارائه شده است.



شکل ۱ تأثیر عوامل مهم روی کیفیت جوش

وقتی آزمایش‌های غیر مخرب (Nondestructive tests) علاوه بر بازرسی عینی (Visual test) مورد نیاز باشد، باید اطلاعاتی از قبیل نوع جوشهایی که باید آزمایش شوند، درصدی از جوشها که باید تحت آزمایش قرار گیرند و روشهای آزمایش در مشخصات فنی ذکر شوند [2,3].

پردازش تصاویر و یادگیری ماشین. بررسی یک تصویر توسط انسان با توجه به کیفیت تصویر و نیز اندازه و موقعیت عیوب جوش می‌تواند باعث خطای انسانی شود، در صورتی که استفاده از کامپیوتر و روشهای جدید پردازش تصویر (Image Processing) و بینایی ماشین (Machine vision) می‌تواند تا حدود زیادی به ایجاد وضوح کیفی در تصاویر و همچنین یافتن عیوب در مدت زمان کمتر و با دقت بیشتری منجر گردد. تعداد زیاد تصاویر و همچنین در دسترس نبودن بازرسان باتجربه باعث ایجاد خستگی مضاعف در فرد مفسر می‌شود و این امر سبب افزایش خطا خواهد شد.

با توجه به موارد ذکر شده، روش بینایی ماشین علاوه بر اینکه از روش‌های غیر مخرب ارزیابی سازه‌ها می‌باشد، از هزینه‌ها و مخاطرات بازرسی انسانی مصون است.

پیشرفتهای گسترده هوش مصنوعی در حوزه یادگیری عمیق، ابزارهای مفیدی در اختیار بینایی ماشین قرار می‌دهد که از آن جمله می‌توان به شبکه‌های عصبی کانولوشنال (CNN) به عنوان مهمترین بخش آن اشاره کرد. از منظر بینایی ماشین سه نوع مسئله قابل حل می‌باشد:

- دسته‌بندی تصاویر که وجود یا عدم وجود شیء را مشخص می‌کند.
- تشخیص اشیا که علاوه بر تشخیص وجود شیء، تقریبی از محل شیء را در اختیار کاربر قرار می‌دهد.

مقدمه

روش‌های متنوعی برای شناسایی آسیب در شرایط مختلف با توجه به اهمیت سازه، شدت خسارت و نوع خسارت وجود دارد. به طور کلی می‌توان روشهای شناسایی خسارت سازه‌ای را به دو دسته روشهای مخرب و روشهای غیر مخرب تقسیم‌بندی کرد. در روشهای مخرب که اغلب همراه با آزمایش یا نمونه‌برداری از سازه اصلی هستند، سازه دچار تغییر شده و حتی در برخی از موارد دیگر قابل استفاده نیست. از این رو این روشها با محدودیت شدیدی مواجه هستند و در نتیجه در حوزه شناسایی خسارت، روشهای غیر مخرب برای بررسی مداوم وضعیت سازه، شناسایی خسارتهای احتمالی و ارزیابی ایمنی، گزینه بسیار مناسبی خواهند بود.

پیشرفتهای اخیر در حوزه کامپیوتر، حسگرها و سایر تکنولوژیهای الکترونیک، روشهای غیر مخرب را به روشهایی مؤثر، آسان و باصرفه برای شناسایی خسارت تبدیل کرده است. روشهای غیر مخرب نیز به دو دسته روشهای شناسایی آسیب محلی و کلی تقسیم‌بندی می‌شوند.

کنترل کیفیت جوش (به عنوان یکی از روشهای ایجاد اتصال در ساختمانهای فولادی) از جایگاه مهمی در شناسایی آسیب در سازه‌های فولادی برخوردار است. از روشهای تشخیص آسیب در جوش می‌توان به بازبینی عینی، میدان مغناطیسی، التراسونیک، رادیوگرافی، ماکروویو، جریان گردابی، میدان حرارتی و پردازش تصویر اشاره کرد. در حال حاضر بر اساس ضوابط آیین‌نامه‌ها، کیفیت ظاهری جوش توسط یک بازرس به صورت چشمی (تست چشمی) کنترل می‌شود.

عیوب ظاهری جوش. عیوبی که ممکن است در ظاهر جوش به‌وجود آید شامل موارد زیر است [1]:

- ذوب ناقص (Lack of Fusion (LOF))
- نفوذ ناقص (Lack of Penetration (LOP))
- تخلخل (Porosity)
- بریدگی کناره جوش (Undercut)
- ناخالصیهای حبس شده (Slag Inclusion)
- سر رفتن جوش روی فلز پایه (Overlap)
- جرقه و پاشش (Spatter)
- ترکها (cracks)

و تشخیص محل آسیب نمودند. در این مطالعه، آنها از یک شبکه عصبی کانولوشنال استفاده کردند که علاوه بر دسته‌بندی تصاویر آسیبها، محل قرارگیری آنها را نیز به واسطه چهار مختصات از یک مستطیل محصور کننده ارائه داد. محتشم خانی و همکاران [10] با استفاده از یک مدل کانولوشنال و با بهره‌گیری از یادگیری انتقالی، اقدام به دسته‌بندی تصاویر برای داده‌های مربوط به توربینهای گازی کردند. Feng و همکاران [11] در مطالعه‌های دیگر اقدام به دسته‌بندی تصاویر برای شناسایی آسیبهای ایجاد شده در سطح سازه‌های آبی کردند که از فرایند یادگیری انتقالی استفاده شد. تمامی مطالعات اخیر از دقت بسیار بالای شبکه‌های عصبی کانولوشن و یادگیری عمیق در حوزه دسته‌بندی تصاویر مربوط به آسیبهای سازه‌ای حکایت دارند.

در حوزه یادگیری عمیق در سال ۲۰۱۵ با ارائه شبکه‌های عصبی تماماً کانولوشنال [12] مسیر جدیدی گشوده شد. Yang و همکاران [13] از شبکه‌های عصبی تماماً کانولوشنال استفاده کردند و فرایند دسته‌بندی تصاویر بتنی را به انجام رساندند. Zhang و همکاران [14] با پیچیدگی بسیار کمی این کار را به سرانجام رساندند. مطالعه‌ای دیگر [15] شبکه‌ای ارائه داد تا به کمک آن بتوان مسائل آسیبهای موجود برای سطوح مختلف را تشخیص داد و فرایند بخش‌بندی را برای تصاویر آنها به انجام رسانید. مدل مورد استفاده در این پژوهش نیز از نوع تماماً کانولوشنال بوده است که دقت آن نسبت به مدل‌های جدیدتر کمی پایین می‌باشد. از دیگر مطالعات جدید در حوزه دسته‌بندی تصاویر می‌توان به U-NET [16] که مشابه شبکه‌های عصبی تماماً کانولوشنال است اشاره کرد، با این تفاوت که علاوه بر آموزش رمزگذار و رمزگشا، رابطه بین عناصر این دو نیز به مدل آموزش داده می‌شود. Liv و همکاران [17] با استفاده از مدل اصلی پیشنهادی U-NET مدلی ارائه کردند. آنها نشان دادند که این مدل نسبت به مدل‌های پیشین نیاز به داده آموزشی بسیار کمتری خواهد داشت. از دیگر مدل‌هایی که اخیراً در بخش‌بندی تصاویر به موفقیت‌های زیادی دست یافته است می‌توان به DeepLab [18] و زیرمجموعه‌های آن [19,20] اشاره کرد. این مدل به واسطه بهره‌گیری از لایه‌های کانولوشن تفکیک‌پذیر توانسته است به بهترین نتایج دست یابد.

در تمامی تحقیقات ارائه شده، تصاویر مورد استفاده برای شناسایی آسیب از نوع تصاویر رادیوگرافی بود و از تصاویر دیجیتالی استفاده نشد. همچنین در هیچ یک از تحقیقات ارائه

- بخش‌بندی و تقسیم‌بندی معنایی که پیکسل‌های موجود در تصویر را دسته‌بندی کرده و برای آن برچسب مخصوص اختصاص می‌دهد. در این پژوهش هدف اول یا همان دسته‌بندی تصاویر مورد بررسی قرار می‌گیرد.

تاریخچه تحقیق. قطعه‌قطعه‌سازی تصاویر، روشی است که در سال ۲۰۰۹ توسط F.Regragui و A.Mahmoudi مطرح شد. روال کار در الگوریتم پیشنهادی آنها، تمرکز بر مناطقی بود که عیوب موجود هنگام فرایند جو شکاری را شامل می‌شود و این مناطق را به قطعات کوچکتر تقسیم‌بندی می‌کند. اساس کار این روش، تجزیه و تحلیل هیستوگرام (analysis Histogram) و بهبود کنتراست می‌باشد [4].

در سال ۲۰۰۵ روشی توسط Hong-Peng Bai, Yi Sun و Ping Zhou ارائه شد که در آن، عیوب سرباره، سوراخهای کرمی و ذوب ناقص، با استفاده از تشخیص الگوی فازی، به طور اتوماتیک شناسایی می‌شوند و در شرایطی که هر کدام از این نقایص از مقدار مجاز خود بی‌شتر باشند، به اپراتور اطلاع داده می‌شود [5].

یکی دیگر از روشهایی که در سال ۲۰۰۹ توسط Juan Ramon Ruiz و Rafael Vilar Zapata ارائه شد، با هدف شناسایی خودکار عیوب جوش در تصاویر رادیوگرافی بود. با توجه به اینکه تصاویر رادیوگرافی، دارای نویز می‌باشند، ابتدا با بهره‌گیری از فیلتر میانه (Median filter)، تکنیک بهبود کنتراست و حد آستانه (Threshold)، وضوح تصاویر را بالا می‌برند. در گام بعدی، تعدادی از ویژگیهای هندسی انتخاب می‌شوند. سپس با بهره‌گیری از یک شبکه عصبی مصنوعی عیوب جوش دسته‌بندی می‌شوند [6].

در سال ۲۰۱۲ Krizhevsky و همکاران [7] با استفاده از یک شبکه عصبی کانولوشنال عمیق توانستند به بیشترین دقت در زمینه دسته‌بندی تصاویر دست پیدا کنند. این موضوع آغازی جدید در مبحث بینایی کامپیوتر بود. البته موضوع شبکه‌های عصبی کانولوشن توسط LeCun و همکاران [8] ارائه شده بود، اما پیدایش نسل‌های جدید پردازنده‌های گرافیکی، آنها را به راه حلی قابل استفاده در مسائل روزمره تبدیل کرد. Cha و همکاران [9] از یک شبکه عصبی کانولوشن برای دسته‌بندی تصاویر بتنی استفاده کردند. پس از آن و در مطالعه‌های دیگر اقدام به شناسایی

در این تحقیق، ۵۲ عکس از کلاس جرقه و پاشش، ۵۶ مورد از ناخالصیهای حبس شده، ۱۰۴ مورد از تخلخل و ۸۰ مورد از ترک برای پایگاه داده لحاظ گردید که در واقع داده‌های متعادلی هستند و صحت‌سنجی مدل با فاکتورهای معمول، معتبر محسوب می‌شوند. ضمناً برای اینکه اشکالات غیر از عیوب جوش مشکلی برای این روش به وجود نیارد یک پیش‌پردازش روی تصاویر انجام شد که از طریق یادگیری عمیق، ناحیه جوش را به صورت خودکار تشخیص می‌دهد.

علاوه بر موارد ذکر شده، روش تقویت داده‌ها می‌تواند رویکرد مناسبی برای تولید داده آموزشی بیشتر باشد. به این ترتیب که از طریق تعدادی از تبدیلات تصادفی که تصاویر قابل قبول تولید می‌کنند، اقدام به تقویت نمونه‌ها می‌کنند. هدف این است که در زمان آموزش مدل، یک تصویر را دو بار پردازش نکند. این کار کمک می‌کند تا مدل با جنبه‌های بیشتری از داده‌ها روبه‌رو شود و بهتر تعمیم یابد. این موارد تنها تعدادی از گزینه‌های انتخابی موجود هستند:

range Rotation: یک مقدار برحسب درجه است (۰-۱۸۰)، بازه‌ای که در آن می‌توان تصاویر را به صورت تصادفی چرخش داد.

zoom_range: برای انجام بزرگنمایی تصادفی درون تصویر انجام می‌شود.

horizontal_flip: برای وارونه کردن تصادفی نیمی از تصاویر به صورت افقی قرار می‌گیرد.

fill_mode: استراتژی به کار رفته برای پر کردن پیکسلهایی است که به تازگی ایجاد شدند و ممکن است پس از یک عمل چرخش یا تغییر عرض یا ارتفاع آنها آشکار شوند. همچنین یک تصویر جوش شامل چند عیب به صورت همزمان می‌باشد، با توجه به این موضوع اغلب برای یک اپراتور تمایز قائل شدن بین عیوب ممکن است با خطا همراه باشد، که این تحقیق کمک بزرگی به رفع این مشکل می‌کند.

در این تحقیق سعی شده است با استفاده از روش‌های پردازش تصویر و هوش مصنوعی (Intelligence Artificial) برنامه‌ای طراحی شود که بتواند با دقت بالا کار تشخیص و شناسایی عیوب ظاهری جوش را انجام دهد. در این مقاله از زبان برنامه‌نویسی پایتون (Python) و با چارچوب Opencv برای پردازش تصاویر، از کتابخانه Keras به منظور ساخت و اجرای

شده شناسایی عیوب ظاهری مد نظر قرار نگرفت. در این تحقیق از تصاویر دیجیتالی حاصل از گوشی تلفن همراه و همچنین دوربینهای عکس‌برداری برای شناسایی عیوب ظاهری جوش مورد استفاده قرار می‌گیرد.

همچنین در این تحقیق، روش شناسایی عیوب ظاهری جوش بر اساس یادگیری عمیق مورد بررسی قرار می‌گیرد و دقت آن مورد بررسی قرار می‌گیرد. برای این منظور قطعاتی که عیوب ظاهری آنها از قبل توسط بازرسان مجرب جوش مشخص گردیده است به کمک یادگیری عمیق هم مورد ارزیابی قرار می‌گیرند تا کارایی روش پیشنهادی در شناسایی آسیب ارزیابی گردد. در حقیقت نوآوری این تحقیق استفاده از یادگیری عمیق در شناسایی عیوب ظاهری جوش با استفاده از تصاویر دیجیتالی است.

روش تحقیق

در این تحقیق به تصاویر زیادی که در آنها عیوب جوش نمایان باشد احتیاج است. اینترنت می‌تواند بزرگترین منبع برای تهیه تصاویر به عنوان داده‌های نرم‌افزار باشد. اما از آنجا که هر چه تعداد تصاویر پایگاه داده بیشتر باشد، دقت نرم‌افزار بالا می‌رود، از منابع دیگری نیز برای تهیه تصاویر استفاده شده است. این منابع، مراکز آموزش فنی و حرفه‌ای، هنرستانها و مدارس می‌باشند. در این مراکز دوره‌های صلاحیت جوشکاری برای کارآموزان برگزار می‌شود که نمونه جوشهای تهیه شده توسط این افراد، دارای عیوب مختلف می‌باشند. عیوب این نمونه‌ها قبل از اینکه در یادگیری ماشین مورد استفاده قرار گیرند توسط بازرسان مجرب جوش مورد شناسایی قرار می‌گیرند. برای استفاده مناسب از تصاویر برداشت شده نخست تصاویری که به عنوان ورودی به نرم‌افزار داده می‌شود توسط کاربر پیش‌پردازش شده و از نظر کادربندی اصلاح می‌گردند به نحوی که خط جوش مورد نظر به صورت تقریبی در وسط تصویر قرار بگیرد. با توجه به اینکه نرم‌افزار با استفاده از تعداد زیادی از تصاویر مختلف آموزش دیده است، تمامی حالات و اشکالاتی که ممکن است وجود داشته باشد، پوشش داده می‌شود. همچنین از آنجا که خروجی نرم‌افزار همواره شامل ۴ کلاس مختلف می‌باشد، اشکالات غیر مرتبط در صد کمی را به خود اختصاص می‌دهند و در اولویتهای انتهایی قرار می‌گیرند.

باشد، CNN بهتر تنظیم می‌شود. فقط باید به خاطر داشت که این نقاط داده باید تمیز و دارای برجسب باشند تا CNN بتواند از آنها استفاده کند. همین امر باعث گران شدن کار با آنها می‌شود. شبکه‌های عصبی کانولوشنال، شبکه‌های عصبی چند لایه هستند که واقعاً در استخراج ویژگیها از داده‌ها مهارت دارند. آنها به خوبی با تصاویر کار می‌کنند و نیاز به پردازش زیادی ندارند. با استفاده از کانولوشنال و تجمیع تصاویر برای کاهش ویژگیهای اصلی آن، می‌توان تصاویر را به درستی شناسایی کنید. آموزش مدل‌های CNN با پارامترهای اولیه کمتر، از سایر شبکه‌های عصبی آسانتر است. در این حالت به تعداد زیادی از لایه‌های پنهان نیاز نیست زیرا کانولوشنالها قادر خواهند بود بسیاری از کشف لایه‌های پنهان را کنترل کنند.

آخرین لایه CNN لایه طبقه‌بندی است که مقدار پیش‌بینی شده را بر اساس نقشه فعال‌سازی تعیین می‌کند. آموزش CNN مشابه آموزش بسیاری از الگوریتمهای یادگیری ماشین است. ابتدا با برخی از داده‌های آموزشی که جدا از داده‌های آزمون است شروع خواهد کرد و وزن خود را بر اساس دقت مقادیر پیش‌بینی شده تنظیم خواهد کرد. البته باید به پیش‌برازشی هم توجه کرد.

یکی از مراحل کانولوشن ادغام یا pooling است. لایه ادغام اندازه نقشه‌های ویژگی را کاهش می‌دهد که این خود از تعداد پارامترهای یادگیری و همچنین میزان محاسبات شبکه می‌کاهد. لایه ادغام ویژگیهای موجود در هر ناحیه از نقشه ویژگی (Feature Maps) را که لایه کانولوشن تولید کرده است خلاصه می‌کند؛ در واقع مهمترین آنها را انتخاب می‌کند و به مرحله بعد منتقل می‌کند. این باعث می‌شود مدل در برابر تغییرات موقعیت ویژگیهای موجود در تصویر ورودی مقاومت بیشتری داشته باشد (شکل ۳).

به‌طور کلی سه نوع ادغام وجود دارد:

Max Pooling - در این نوع ادغام (Pooling)، بزرگترین مقدار در ناحیه‌ای که فیلتر پوشانده است انتخاب می‌شود؛ بنابراین در این حالت خروجی یک نقشه ویژگی است که برجسته‌ترین ویژگی‌های نقشه ویژگی قبلی را دارد.

Average Pooling - در این نوع ادغام، مقدار میانگین ناحیه‌ای که فیلتر روی آن قرار می‌گیرد محاسبه می‌شود؛ بنابراین میانگین ویژگیهای نقشه ویژگی قبلی را در خروجی ارائه می‌کند.

شبکه عصبی عمیق و از بستر Tensor برای قسمت شناسایی و پیش‌بینی عیوب استفاده شده است.

معماری شبکه عصبی کانولوشنال. شبکه‌های عصبی کانولوشن تا حد بسیار زیادی شبیه شبکه‌های عصبی مصنوعی هستند. شبکه عصبی تمام داده‌های آموزش را در لایه ورودی می‌گیرد. سپس داده‌ها را از میان لایه‌های پنهان عبور داده و مقادیر را بر اساس وزن هر گره تغییر می‌دهد. در آخر مقدار آن را در لایه خروجی برمی‌گرداند. شبکه عصبی کانولوشن نوع خاصی از شبکه عصبی با چندین لایه است. داده‌هایی را که دارای آرایش شبکه‌ای هستند پردازش می‌کند و سپس ویژگیهای مهم را استخراج می‌کند. یک مزیت بزرگ استفاده از CNN این است که نیازی به انجام بسیاری از مراحل پردازش روی تصاویر ندارید. یک تفاوت بزرگ بین CNN و یک شبکه عصبی منظم این است که CNNها از پیچیدگی برای مدیریت ریاضیات پشت صحنه استفاده می‌کنند. حداقل در یک لایه CNN به جای ضرب ماتریس از ترکیب استفاده می‌شود. کانولوشن‌ها در دو تابع محاسبه می‌شوند و یک تابع را برمی‌گردانند.

CNNها زیر مجموعه‌ای از شبکه‌های عصبی عمیق هستند. شبکه‌های عصبی عمیق به شبکه‌های عصبی‌ای گفته می‌شود که تعداد لایه‌های مخفی شبکه آنها بیش از سه لایه می‌باشد. در واقع یادگیری عمیق محاسبات پیچیده‌ای دارد که روی CPU سیستم‌های معمولی یا ممکن نیست یا بسیار زمانبر است. در اصل، CNN با استفاده از فیلترها که روی داده‌های ورودی می‌لغزاند کار می‌کند و یک استخراج ویژگی از تصویر دریافت می‌کند. آنچه آنها را بسیار خاص می‌کند این است که CNNها می‌توانند فیلترها را در صورت آموزش تنظیم کنند. به این ترتیب نتایج در زمان واقعی تنظیم می‌شوند. این باعث صرفه‌جویی زیادی در وقت و آزمایش و خطا می‌شود زیرا به پارامترهای زیادی احتیاج ندارند [21].

از آنجا که می‌توان فیلترها را برای آموزش بهتر CNN به‌روز کرد، این امر نیاز به فیلترهای دستی را از بین می‌برد. این موضوع امکان انعطاف‌پذیری بیشتری در تعداد فیلترها می‌دهد. یکی از مواردی که جلوی بسیاری از مشکلات استفاده از CNN را می‌گیرد، کمبود داده است، در حالی که می‌توان شبکه‌ها را با نقاط داده نسبتاً کمی آموزش داد، هر چه اطلاعات بیشتری در دسترس

مناسبی برای سنجش میزان موفقیت خواهد بود، در واقع از این مدل آماده با دیتاست غنی به منظور آموزش شبکه استفاده می شود [23,24] و سپس دیتاست مخصوص، وظیفه جدید به سیستم اضافه می شود تا تشخیص تصاویر مورد نظر را آموزش ببینند [25].

در اینجا شبکه مورد استفاده متشکل از دنباله‌ای از ۱۶ لایه متراکم (Dens) و انبوهی از لایه‌های عصبی تماماً متصل هستند. لایه آخر یک لایه بیشینه هموار (Soft max) می باشد که به تعداد شماره کلاسها، مسیر دارد. به این معنی که آرایه‌ای از ۴ امتیاز احتمالی را باز خواهد گرداند (که مجموع آنها برابر با ۱ است). هر امتیاز برابر است با احتمال آنکه تصویر کنونی متعلق به یکی از کلاسهای مربوط به عیوب می باشد. برای آماده ساختن شبکه برای فرایند آموزش، لازم است به عنوان بخشی از مرحله گردآوری و تلفیق سه مورد دیگر نیز مشخص شوند [26] که عبارتند از:

یک تابع هزینه (Loss) یا زیان: شبکه چگونه می تواند عملکرد و کارایی خود را در داده‌های آموزشی بسنجد و بنابراین چگونه می تواند خود را در مسیر صحیح هدایت کند.

یک بهینه‌ساز (Optimizer): ساز و کاری که شبکه از طریق آن براساس داده‌هایی که مشاهده می کند، تابع هزینه خود را به‌روزرسانی می کند.

معیارهایی برای پایش در حین آموزش و آزمودن (Metrics): در اینجا تنها به دقت و صحت توجه خواهد شد (نسبتی از تصاویر که به درستی طبقه‌بندی شدند) [27].

در جدول (۱) پارامترهای مربوط به معماری شبکه کانولوشنال ارائه شده است. همچنین در شکل (۲) معماری شبکه عصبی کانولوشنال که توضیحات آن در بخش جاری ارائه گردید نشان داده شده است.

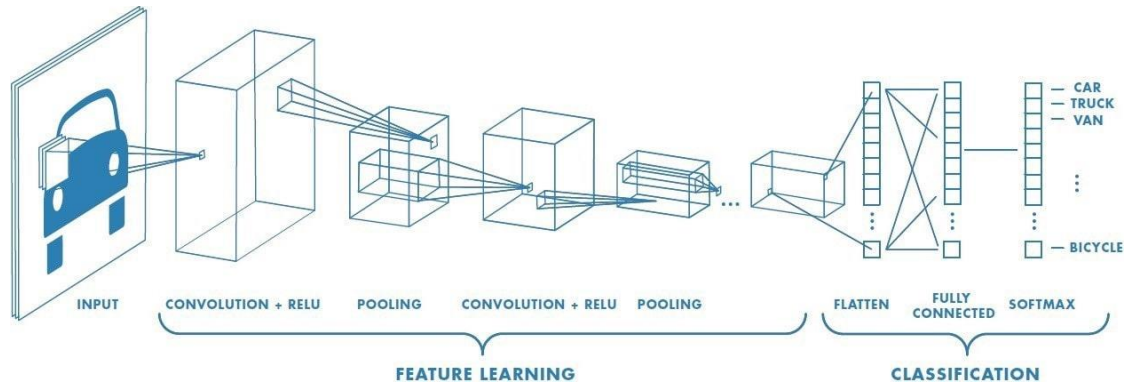
جدول ۱ پارامترهای مربوط به معماری شبکه کانولوشنال

نوع مسئله	تابع فعالسازی لایه آخر	تابع هزینه
طبقه‌بندی دودویی	relu یا sigmoid	binary_crossentropy
طبقه‌بندی تک برچسبی چندکلاسی	relu یا sigmoid	binary_crossentropy
طبقه‌بندی چند برچسبی چندکلاسی	softmax	categorical_crossentropy
رگرسیون برای مقادیر اختیاری	None	mse
رگرسیون برای مقادیر بین ۰ و ۱	relu یا sigmoid	mse or binary_crossentropy

Sum Pooling - ر این نوع ادغام، جمع کل ناحیه‌ای که فیلتر پوشانده است محاسبه می شود و یک نقشه ویژگی جدید را ایجاد می کند.

بعد از فیلتر کردن یک ماتریس، سایز خروجی کمتر از ماتریس ورودی می شود. با لایه‌گذاری یا padding می توان به صورت جعلی اندازه ورودی را افزایش داد تا ماتریس خروجی هم‌اندازه ماتریس ورودی بشود. در مورد لایه‌گذاری صحبت بسیار است و معمولاً در پردازش تصویر بررسی می شود؛ اما یک راه ساده و رایج آن اضافه کردن سطر و ستون صفر به صورت متقارن به دور ماتریس ورودی است [22].


مجموعه داده imagenet که از آن در این روش استفاده می شود به صورت یک بسته همراه با Keras ارائه نمی شود. این مجموعه داده توسط Kaggle به عنوان بخشی از یک مسابقه بینایی کامپیوتری در اواخر سال ۲۰۱۳ زمانی که شبکه‌های عصبی کانولوشنی هنوز به عنوان یک جریان اصلی به شمار نمی رفتند، در دسترس قرار گرفت. این تصاویر، عکسهای JPEG با رزولوشن متوسط هستند. این مجموعه داده حاوی ۲۵۰۰۰ تصویر از سگها و گربه‌ها (۱۲۵۰۰ نمونه از هر کلاس) و حجم آن ۵۴۳ مگابایت است (به صورت فشرده). پس از دانلود و خارج کردن آن از حالت فشرده، باید مجموعه داده‌ای ایجاد شود که حاوی سه زیرمجموعه است: یک مجموعه آموزشی با ۱۰۰۰ نمونه از هر کلاس، یک مجموعه اعتبارسنجی با ۵۰۰ نمونه از هر کلاس و یک مجموعه آزمایشی با ۵۰۰ نمونه از هر کلاس. بنابراین در واقع تعداد ۲۰۰۰ تصویر آموزشی، ۱۰۰۰ تصویر اعتبارسنجی و ۱۰۰۰ تصویر آزمایشی در اختیار قرار خواهد داد. هر بخش شامل تعداد یکسانی از نمونه‌های مربوط به هر کلاس است و یک مسئله طبقه‌بندی دودویی متوازن است به این معنی که دقت طبقه‌بندی، معیار



شکل ۲ معماری شبکه عصبی کانولوشنال



شکل ۳ بررسی هزینه آموزش در مقایسه با افزایش مراحل آموزش




شکل ۴ بررسی صحت‌سنجی در مقایسه با افزایش مراحل آموزش

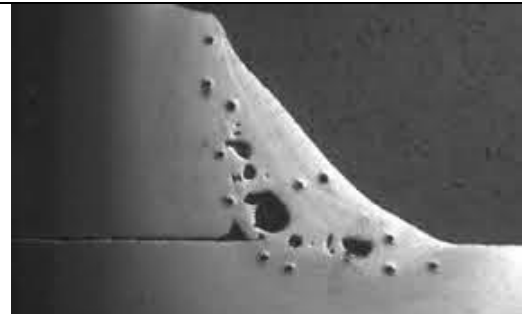
نتایج

است. بیش‌برازشی به این معناست که شبکه، داده‌های آموزشی را بیش از حد یاد گرفته و روی آن نتایج خوبی دارد ولی روی داده‌های جدید یا همان تست، نتایج قابل قبولی نخواهد داشت. برای این منظور یک دیتاست کمکی یا همان اعتبارسنجی به شبکه اضافه می‌شود تا نتایج شبکه بر روی آن بررسی گردد، در نتیجه با مشاهده نتایج که نشان‌دهنده نزدیک و همسو بودن نتایج داده‌های آموزش و اعتبارسنجی است می‌توان مطمئن بود نتایج روی داده‌های تست قابل قبول هستند.

شکلهای (۳ و ۴) دقت و هزینه را در فرایند آموزش نشان می‌دهند که در آنها محور افقی بیانگر تعداد مراحل آموزش (بدون بعد) است. همچنین محور عمودی در شکل (۳) هزینه آموزش و در شکل (۴) دقت آموزش را نشان می‌دهد. محورهای عمودی از صفر تا یک مقیاس شده است. بررسی شکلهای (۳ و ۴) نشان می‌دهد که سیستم در مرحله آموزش دچار بیش‌برازشی نشده

	الویت کلاس	نوع عیب	احتمال وجود (%)
	احتمال اول	ترک	۸۵/۱
	احتمال دوم	تخلخل	۱۱/۶
	احتمال سوم	سرباره	۱/۹۳
	احتمال چهارم	پاشش	۱/۳۲

الف

	الویت کلاس	نوع عیب	احتمال وجود (%)
	احتمال اول	تخلخل	۹۹/۹۹
	احتمال دوم	پاشش	۰/۰۰۷
	احتمال سوم	سرباره	۰/۰۰۲
	احتمال چهارم	ترک	۰/۰۰۱

ب

	الویت کلاس	نوع عیب	احتمال وجود (%)
	احتمال اول	پاشش	۸۶/۴
	احتمال دوم	تخلخل	۱۲/۷۳
	احتمال سوم	سرباره	۰/۸۳
	احتمال چهارم	ترک	۰/۰۲

ج

	الویت کلاس	نوع عیب	احتمال وجود (%)
	احتمال اول	سرباره	۸۶/۴
	احتمال دوم	پاشش	۱۲/۷۳
	احتمال سوم	تخلخل	۰/۸۳
	احتمال چهارم	ترک	۰/۰۲

د

شکل ۵ شناسایی عیوب ظاهری در جوش توسط ماشین: الف) ترک، ب) تخلخل، ج) جرقه و پاشش، د) ناخالصیهای حبس شده

در شکل (۵) چند مثال برای صحت‌سنجی این روش و میزان دقت آن ارائه شده است. این تصاویر توسط نویسندگان این تحقیق تهیه شد. تصاویر در اختیار بازرسان ماهر جوش قرار گرفت تا نظر خود را در مورد عیوب ظاهری آنها اعلام کنند و فقط عیب اصلی را برای هر یک از تصاویر بیان کنند. بازرسان عیوب زیر را برای هر یک از تصاویر مشخص کردند:

شکل الف: جوش دارای ترک

در عمل، نیاز است که برنامه دیگری نوشته شود که بتواند تصویر مورد نظر کاربر را به عنوان ورودی دریافت و تغییراتی را بر آن اعمال کند تا برنامه بتواند آن را پردازش کند. سپس با استفاده از مدلی که از قبل آموزش دیده است اقدام به تحلیل و پردازش تصویر کند و با استخراج ویژگیهای تصویر، درصد تعلق به هر کدام از کلاسها را پیش‌بینی نماید. در آخر نیز به ترتیب تعلق به کلاسها، نتایج را در کنار تصویر وارد شده نمایش دهد.

شکل ب: جوش دارای تخلخل

شکل ج: جوش دارای جرقه و پاشش

شکل د: جوش دارای ناخالصیهای حبس شده

در ادامه، تصاویر فوق به نرم‌افزار پیشنهادی داده شده و نوع عیوب ظاهری به کمک ماشین تعیین شد. به دلیل اینکه ممکن است هر تصویر دارای چند عیب به صورت همزمان باشد، ماشین این توانایی را دارد تا چند عیب به‌طور همزمان را نیز شناسایی کند. بنابراین، هر کدام از عیوب، با توجه به میزان آن عیب در جوش مورد نظر، درصد مشخصی را به خود اختصاص می‌دهند و اولویت‌بندی می‌شوند. نتایج به صورت زیر توسط ماشین بر حسب درصد اعلام گردید:

شکل الف: ماشین، عیب ترک در جوش را با احتمال ۸۵ درصد و عیب تخلخل را با احتمال ۱۱ درصد پیش‌بینی کرده است.

شکل ب: ماشین عیب تخلخل را با احتمال ۹۹ درصد پیش‌بینی کرده است.

شکل ج: سیستم عیب جرقه و پاشش را با احتمال ۸۶ درصد و تخلخل را با احتمال ۱۲ درصد شناسایی کرد.

شکل د: سیستم عیب ناخالصی حبس شده را با احتمال ۸۶ درصد و جرقه و پاشش را با احتمال ۱۲ درصد تشخیص داده است.

درصدهای اعلام شده، خروجیهای حاصل از پیش‌بینی توسط نرم‌افزار است و تطابق خوبی با درصدهای پیش‌بینی شده توسط بازرسان داشته است. ماشین توانسته است عیوب جوش را حداقل با ۸۵ درصد دقت تعیین نماید.

نتیجه‌گیری

در این تحقیق، روشی پیشنهاد شده است که با استفاده از آن

می‌توان عیوب ظاهری جوش را به کمک ماشین و بدون نیاز به بازرسان ماهر تشخیص داد. برای این منظور یک بسته نرم‌افزاری بر اساس یادگیری ماشین تهیه شد. در استفاده از این روش کافی است تصویر دیجیتالی جوش مورد آزمایش را به نرم‌افزار داد و وضعیت سلامت جوش را نتیجه گرفت. اگر جوش دارای چند عیب همزمان باشد نرم‌افزار میزان مشارکت هر یک از عیوب ظاهری را به صورت درصد بیان می‌کند. برای صحت‌سنجی روش و اطمینان از کارایی نرم‌افزار، چند نمونه از تصاویر جوش معیوب که میزان هر یک از انواع عیوب جوش در آن توسط بازرسان ماهر جوش تعیین شده بود به ماشین داده شد و ماشین با دقت حداقل ۸۵ درصد هر یک از معایب را شناسایی کرد.

با توجه به نتایج حاصل از این تحقیق و مثالهایی که با این روش مورد ارزیابی قرار گرفت می‌توان مزایای زیر را برای روش پیشنهادی در نظر گرفت:

- استفاده از این روش و نرم‌افزار می‌تواند نیاز به بازرسان ماهر جوش را برای تشخیص عیوب ظاهری تا حد زیادی کاهش دهد.

- استفاده از ماشین می‌تواند به طور چشمگیری خطای انسانی را در تشخیص عیوب ظاهری کاهش دهد و حتی عیوب ثانویه را نیز شناسایی کند.

- با بهره‌گیری از روش پیشنهادی، مدت زمان مورد نیاز برای بررسی معایب جوش با تعداد زیاد به طور چشمگیری کاهش می‌یابد.

در پایان یادآور می‌شود هرچه تعداد تصاویر برای آموزش ماشین بیشتر باشد، نرم‌افزار با دقت بیشتری تصاویر جدید را ارزیابی می‌کند.

مراجع

- [1] Iranian Office of the Deputy for Technical Affairs Bureau of Technical Affairs and Standards, *Iranian structural welding code No. 228*, Tehran, Center for scientific documents and publications, (2001), (In Persian).
- [2] Iranian Office of National Regulations and Building Control, *Guide to welding and welded joints in steel buildings*, Tehran, Tosseh publisher, (2015), (In Persian).
- [3] Fatemi S.M., *Visual inspection of welding*, Tehran, Keyfiat publisher, (2018), (In Persian).
- [4] Mahmoudi, A., & Rezagui, F., "Welding defect detection by segmentation of radiographic images". *2009 WRI World Congress on Computer Science and Information Engineering*, Vol. 7, pp. 111-115. IEEE. (2009, March).

- [5] Sun, Y., Bai, P., Sun, H. Y., & Zhou, P., "Real-time automatic detection of weld defects in steel pipe", *Ndt & E International*, 38(7), 522-528, (2005).
- [6] Y.J. Cha, W. Choi, G. Suh, S. Mahmoudkhani, O. Büyüköztürk, "Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types", *Computer-Aided Civil and Infrastructure Engineering*, 33(9), pp. 731-747, (2018).
- [7] A. Krizhevsky, I. Sutskever, G.E. Hinton, "Imagenet classification with deep convolutional neural networks", *Advances in neural information processing systems*, 25, pp. 1097-1105, (2012).
- [8] Y. LeCun, Y. Bengio, "Convolutional networks for images, speech and time series", *The handbook of brain theory and neural networks*, 3361(10), 1995, (1995).
- [9] Y.J. Cha, W. Choi, O. Büyüköztürk, "Deep learning-based crack damage detection using convolutional neural networks", *Computer-Aided Civil and Infrastructure Engineering*, 32(5), pp. 361-378, (2017).
- [10] M. Mohtasham Khani, S. Vahidnia, L. Ghasemzadeh, Y.E. Ozturk, M. Yuvalaklioglu, S. Akin, N.K. Ure, "Deep-learning-based crack detection with applications for the structural health monitoring of gas turbines", *Structural Health Monitoring*, 19(5), pp. 1440-1452, (2020).
- [11] C. Feng, H. Zhang, S. Wang, Y. Li, H. Wang, F. Yan, "Structural damage detection using deep convolutional neural network and transfer learning", *KSCE Journal of Civil Engineering*, 23(10), pp. 4493-4502, (2019).
- [12] J. Long, E. Shelhamer, T. Darrell, "Fully convolutional networks for semantic segmentation", *IEEE conference on computer vision and pattern recognition*, pp. 3431-3440, (2015).
- [13] X. Yang, H. Li, Y. Yu, X. Luo, T. Huang, X. Yang, "Automatic pixel-level crack detection and measurement using fully convolutional network", *Computer-Aided Civil and Infrastructure Engineering*, 33(12), 1090, (2018).
- [14] L. Zhang, F. Yang, Y.D. Zhang, Y.J. Zhu, "Road crack detection using deep convolutional neural network", *2016 IEEE international conference on image processing (ICIP)*, IEEE, 2016, pp. 3708-3712.
- [15] V. Hoskere, Y. Narazaki, T.A. Hoang, B. Spencer Jr, "MaDnet: multi-task semantic segmentation of multiple types of structural materials and damage in images of civil infrastructure", *Journal of Civil Structural Health Monitoring*, 10, 757-773, (2020).
- [16] O. Ronneberger, P. Fischer, T. Brox, "Unet: Convolutional networks for biomedical image segmentation", *International Conference on Medical image computing and computerassisted intervention*, Springer, pp. 234, (2015).
- [17] Z. Liu, Y. Cao, Y. Wang, W. Wang, "Computer vision-based concrete crack detection using U-net fully convolutional networks", *Automation in Construction*, 104, pp. 129-139, (2019).
- [18] L.C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, A.L. Yuille, "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution and fully connected crfs", *IEEE transactions on pattern analysis and machine intelligence*, 40(4), pp. 834-848, (2017).
- [19] L.-C. Chen, G. Papandreou, F. Schroff, H. Adam, "Rethinking atrous convolution for semantic image segmentation", *arXiv preprint arXiv,1706.05587*, (2017).
- [20] L.C. Chen, Y. Zhu, G. Papandreou, F. Schroff, H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation", *the European conference on computer vision (ECCV)*, pp. 801-818, (2018).

- [21] Zhang, Z., Wen, G., & Chen, S., "Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding", *Journal of Manufacturing Processes*, 45, 208-216, (2019).
- [22] Feng, S., Zhou, H., & Dong, H., "Using deep neural network with small dataset to predict material defects", *Materials & Design*, 162, 300-310, (2019).
- [23] B. Zoph, V. Vasudevan, J. Shlens, Q.V. Le, "Learning transferable architectures for scalable image recognition", *IEEE conference on computer vision and pattern recognition*, pp. 8697-8710, (2018).
- [24] Zhang, Y., You, D., Gao, X., Zhang, N., & Gao, P. P., "Welding defects detection based on deep learning with multiple optical sensors during disk laser welding of thick plates", *Journal of Manufacturing Systems*, 51, 87-94, (2019).
- [25] Chollet, F., "Deep Learning with Python", *United States: Manning Publications*, (2018).
- [26] Hou, W., Wei, Y., Guo, J., & Jin, Y., "Automatic detection of welding defects using deep neural network" *Journal of Physics: Conference Series*, Vol. 933, No. 1, p. 012006, IOP Publishing, (2017, December).
- [27] Deng, L., "A tutorial survey of architectures, algorithms, and applications for deep learning", *APSIPA Transactions on Signal and Information Processing*, (2014).

