Automated Damage Diagnosis in Building Slabs and Walls Using Deep Learning-Based Crack Classification

Mahsa AmirAli[1], Mussa Mahmoudi[2], Farid Mahmoudi[3]

1- M.Sc., Shahid Rajaee Teacher Training University, Faculty of Civil Engineering, Tehran, Iran

2- Professor, Shahid Rajaee Teacher Training University, Faculty of Civil Engineering, Structural and Earthquake Engineering Department, Tehran, Iran

3- Ph.D., Amirkabir University of Technology, Faculty of Civil Engineering, Tehran, Iran

1- Introduction

Cracks are among the most common visible indicators of distress in buildings and structural components. Their orientation, geometry, width, distribution, and location can provide useful evidence about stress concentration, local weakness, differential movement, environmental effects, or the initiation of damage. For this reason, crack assessment is an important part of structural health monitoring and of decisions concerning repair, strengthening, or continued use. Conventional visual inspection, however, is strongly dependent on the experience and judgment of the inspector and can become time-consuming and inconsistent when many buildings must be screened within a short period. These limitations are particularly important after moderate earthquakes, in deteriorated urban areas, and in buildings with difficult access.

Recent progress in computer vision and deep learning has created practical opportunities for automated analysis of damage images. Previous studies have used image-processing techniques, unmanned aerial imagery, and convolutional neural networks for crack detection and damage recognition [1], [3]. Other research has combined deep models with regression or image-processing procedures to detect cracks and estimate related characteristics [7], [10]. Nevertheless, a substantial part of the reviewed literature concentrates on binary crack/no-crack detection, on a single surface type, or on one isolated crack characteristic. The present study addresses a different task: multiclass classification of several crack patterns in two building components, slabs and walls, followed by linkage of the predicted class to engineering information.

The objective is therefore to develop a computer-vision framework that can automatically classify ten target crack types and support preliminary damage assessment. Five crack types are considered for slabs and five for walls, and a separate no-crack class is included in each component group. In addition to class prediction, the graphical user interface reports the probable origin of the crack and whether it is considered structural or non-structural. For selected structural cracks, supplementary information about crack width and progression is used to provide preliminary risk guidance. The system is intended for screening and decision support and is not presented as a substitute for professional structural inspection.

2- Materials and Methods

The final dataset contains 1,292 images collected from a combination of photographs of existing cracks and public or Internet sources. Because the images originate from different sources, uniform metadata for camera type, imaging distance, lighting, viewing angle, and original resolution are not available for the entire dataset; this heterogeneity is treated as a limitation when interpreting the results. The slab subset contains 553 images and the wall subset contains 739 images. Each subset is formulated as a six-class classification problem consisting of five target crack patterns and one no-crack reference class.

The slab classes include radial cracks around columns, rectangular cracks around columns, perpendicular/grid-line cracks along reinforcement, horizontal cracks along the slab, crazing cracks, and clear images. Their respective sample counts are 145, 78, 71, 97, 72, and 90.

The wall classes include horizontal cracks at mid-height of retaining walls, vertical cracks, oblique diagonal cracks, diagonal/cross cracks, cracks at the intersection of two walls, and clear images, with 72, 165, 121, 178, 112, and 91 samples, respectively. Thus, the class distribution is not fully balanced.

Image preprocessing was designed to reduce noise, strengthen crack boundaries, and standardize the inputs. First, a 5 x 5 Gaussian filter was applied to smooth the images and suppress unnecessary detail. The filtered image was then processed using Canny edge detection so that regions with large changes in intensity and the boundaries associated with cracks were emphasized. To retain texture and color information while reinforcing edge information, the denoised image and the edge image were combined by weighted fusion using cv2.addWeighted. The original/denoised image contributed with a weight of 0.8 and the edge image with a weight of 0.2. Finally, all processed images were resized to 150 x 150 pixels to match the model input dimensions.

To reduce the risk of overfitting and improve generalization with the available dataset, data augmentation was applied through the Keras ImageDataGenerator. Random horizontal and vertical shifts of up to 10% were used, together with random zooming of up to 20% and horizontal flipping. The nearest-neighbor fill mode was used for pixels introduced near image boundaries after shifting or zooming. These operations increase variation in crack position, scale, and orientation while preserving the class label.

The classification model is based on EfficientNetB0 and transfer learning. A version pretrained on ImageNet was used as the feature-extraction backbone, with its original top layer removed. The EfficientNetB0 weights were frozen during the reported training stage in order to retain general image features learned during pretraining. A Global Average Pooling layer was added to compress the extracted feature maps, followed by a Dropout layer with a rate of 0.4. A fully connected Dense layer with 128 neurons and ReLU activation was then used, and the output Dense layer employed Softmax activation with the number of neurons matched to the six classes in each model. EfficientNetB0 itself uses compound scaling and MBConv blocks with depthwise convolution and skip connections, while batch normalization and nonlinear activation support stable feature extraction.

The model was trained with the Adam optimizer using a learning rate of 0.0005 and categorical cross-entropy as the loss function. Accuracy was used as the reported evaluation metric, and training was performed for 20 epochs. After preprocessing, the data were divided into 80% for training and 20% for validation. The reported quantitative assessment is therefore based on Accuracy and Loss trends for the training and validation sets rather than on an independent external test set. The engineering interpretation connected to the predicted crack classes was developed from the reviewed literature and technical guidance, including ACI documents on cracking and ISO 13822 on assessment of existing structures [14]-[16]. The resulting crack-origin and structural/non-structural labels are used as practical guidance rather than as a claim that every row corresponds directly to a single standard classification.

A simple graphical user interface was implemented in Python using Tkinter so that the trained models can be used without programming knowledge. The user first selects whether the image belongs to the slab or wall group and then loads a crack image. The corresponding model returns the predicted class and a numerical confidence value. The interface also displays the probable cause and the structural or non-structural interpretation associated with that crack type. For selected structural classes such as diagonal, radial, and punching-shear-related cracks, an additional technical window receives information on crack width and whether the crack is progressive, and then provides a preliminary risk-level indication for further review.

3- Results and Discussion

For slab-crack classification, the training accuracy was 34.77% in the first epoch, with a loss of 1.6214. By the second epoch, training accuracy increased to 84.12% and validation accuracy reached 90.91%. The learning trend subsequently stabilized. At the end of the twentieth epoch, training accuracy was 97.23% and validation accuracy was 98.18%. Final training and validation losses were 0.0603 and 0.0750, respectively. The simultaneous reduction in loss and the close training and validation accuracies indicate that no obvious divergence between the two curves was observed in the reported training history.

For the wall model, training accuracy in the first epoch was 34.11% with a loss of 1.6675. In the second epoch, training accuracy rose to 78.95% and validation accuracy to 87.16%. By the eighth epoch, the corresponding accuracies were 96.45% and 96.62%. At the end of the twentieth epoch, training accuracy was 98.13% and validation accuracy remained 96.62%, while training and validation losses decreased to 0.0630 and 0.0891. In both models, the Accuracy and Loss curves show relatively stable convergence, and the final validation loss is below 0.1.

These results show that, within the present dataset and its training/validation split, the proposed EfficientNetB0-based framework can distinguish the defined crack patterns with high validation accuracy. Direct numerical comparison with all earlier studies should nevertheless be made cautiously because the reviewed studies do not all solve the same problem; some focus on binary detection or on narrower surface domains, whereas the present work considers multiclass classification for two building components. The engineering linkage in the interface is a practical feature because the model output is not limited to a class name, but is connected to probable crack origin, structural significance, and preliminary follow-up guidance.

The reported performance must also be interpreted in light of the study limitations. The dataset is relatively limited and not fully balanced, and it combines images obtained under different and incompletely documented acquisition conditions. The quantitative evaluation in the current version is limited to Accuracy and Loss; class-specific Precision, Recall, F1-score, and a confusion matrix were not calculated and recorded in the reported results. In addition, the model has not been evaluated in an independent field study within a real building-inspection workflow. Two-dimensional images do not directly provide crack depth, three-dimensional geometry, internal member condition, or residual structural capacity. Accordingly, the classification output should be treated as supporting information for an engineer rather than as a definitive determination of structural safety.

4- Conclusions

This study developed an integrated computer-vision system for classification of ten target crack types in building slabs and walls. The workflow combines Gaussian filtering, Canny edge detection, weighted image fusion, resizing, data augmentation, and an EfficientNetB0 transfer-learning model. Separate six-class models were trained for slab and wall images. The final validation accuracies were 98.18% for the slab model and 96.62% for the wall model, with validation losses of 0.0750 and 0.0891, respectively. A graphical user interface links the predicted crack class to probable origin and structural/non-structural interpretation and, for selected structural cracks, provides preliminary risk guidance based on additional crack information.

The proposed framework is best viewed as a tool for preliminary screening, visual documentation, and decision support. Future development should increase the volume and diversity of field data, evaluate performance on new independent datasets, incorporate video information to study changes over time, estimate crack width and depth automatically, and combine computer-vision results with structural-analysis information. These steps are necessary before broader field generalization. In its present form, the system can assist inspection activities but does not replace site visits, engineering judgment, or a qualified structural-safety assessment.

شناسایی آسیب در ساختمان‌ها با استفاده از ترک‌های ایجاد شده در دال و دیوار به کمک بینایی ماشین

مهسا امیرعلی[۱]، موسی محمودی صاحبی*[۲]، فرید محمودی صاحبی[۳]

۱- کارشناسی ارشد، دانشگاه تربیت دبیر شهید رجایی، دانشکده مهندسی عمران، تهران، ایران
*۲- استاد، دانشگاه تربیت دبیر شهید رجایی، دانشکده مهندسی عمران، گروه سازه و زلزله، تهران، ایران
۳- دکتری، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی عمران، تهران، ایران

چکیده

شناسایی و ارزیابی اولیه آسیب در ساختمان‌ها برای برنامه‌ریزی تعمیر و نگهداری اهمیت زیادی دارد و الگوهای ترک می‌توانند اطلاعات مفیدی درباره منشأ احتمالی آسیب فراهم کنند. در این پژوهش، یک چارچوب مبتنی بر بینایی ماشین و یادگیری عمیق برای طبقه‌بندی خودکار ترک‌های دال و دیوار و پشتیبانی از ارزیابی اولیه آسیب ارائه شده است. مجموعه‌داده شامل ۱۲۹۲ تصویر است که ده نوع ترک هدف، شامل پنج نوع ترک در دال و پنج نوع ترک در دیوار، را به همراه یک کلاس «بدون ترک» برای هر یک از دو گروه پوشش می‌دهد. توزیع تصاویر در کلاس‌ها کاملا متوازن نیست و تعداد نمونه‌ها در کلاس‌های دال بین ۷۱ تا ۱۴۵ تصویر و در کلاس‌های دیوار بین ۷۲ تا ۱۷۸ تصویر متغیر است. در مرحله پیش‌پردازش از فیلتر گوسی، لبه‌یابی Canny، ترکیب وزنی تصاویر و تغییر اندازه ورودی‌ها استفاده شد و مدل EfficientNetB۰ با یادگیری انتقالی آموزش داده شد. ارزیابی مدل در این پژوهش بر اساس معیار Accuracy و روند Loss در داده‌های آموزش و اعتبارسنجی انجام شد. دقت اعتبارسنجی نهایی برای مدل دال ٪۹۸،۱۸ و برای مدل دیوار ٪۹۶،۶۲ به‌دست آمد. وجه تمایز پژوهش، طبقه‌بندی چند الگوی ترک در دو عضو دال و دیوار و پیوند دادن خروجی مدل با اطلاعات مهندسی شامل منشأ احتمالی ترک، سازه‌ای یا غیرسازه‌ای بودن آن و، برای برخی ترک‌های سازه‌ای، ارائه راهنمای اولیه سطح خطر در یک رابط کاربری است. سامانه پیشنهادی به‌عنوان ابزار کمکی برای غربالگری و ارزیابی اولیه طراحی شده است و جایگزین بازرسی تخصصی سازه نیست.

کلمات کلیدی: پایش سلامت سازه، پردازش تصویر، یادگیری عمیق، شناسایی ترک، شبکه عصبی کانولوشنال

نسخه پیش انتشار

Automated Damage Diagnosis in Building Slabs and Walls Using Deep Learning-Based Crack Classification

Mahsa AmirAli[1], Mussa Mahmoudi[2], Farid Mahmoudi[3]

1- M.Sc., Shahid Rajaee Teacher Training University, Faculty of Civil Engineering, Tehran, Iran
2- Professor, Shahid Rajaee Teacher Training University, Faculty of Civil Engineering, Structural and Earthquake Engineering Department, Tehran, Iran
3- Ph.D., Amirkabir University of Technology, Faculty of Civil Engineering, Tehran, Iran

Abstract

Structural health monitoring and timely maintenance are important for building safety, and crack patterns can provide useful information about the probable origin of damage. This study presents a computer-vision and deep-learning framework for automated classification of slab and wall cracks to support preliminary building-damage assessment. The dataset contains 1,292 images representing ten target crack types, including five slab-crack types and five wall-crack types, together with one no-crack reference class for each group. The class distribution is not fully balanced, ranging from 71 to 145 images per slab class and from 72 to 178 images per wall class. Preprocessing includes Gaussian filtering, Canny edge detection, weighted image fusion, and image resizing, and an EfficientNetB0 backbone is trained using transfer learning. Model evaluation in this study is based on Accuracy and Loss trends for the training and validation data. The final validation accuracies are 98.18% for the slab model and 96.62% for the wall model. The main contribution is the multiclass classification of crack patterns in two building components and the linkage of model outputs to engineering information, including probable crack origin, structural/non-structural classification, and preliminary risk guidance for selected structural cracks through a graphical user interface. The proposed system is intended as a support tool for preliminary screening rather than a replacement for professional structural inspection.

Keywords: Structural Health Monitoring, Image Processing, Deep Learning, Crack Detection, Convolutional Neural Networks

۱- مقدمه

ترک‌ها یکی از متداول‌ترین نشانه‌های آسیب در اجزای ساختمانی و سازه‌ای به شمار می‌روند و می‌توانند بیانگر تمرکز تنش، ضعف موضعی، تغییرشکل‌های غیرمجاز یا آغاز فرایندهای خرابی باشند. الگو، جهت، عرض و محل وقوع ترک‌ها اغلب اطلاعات ارزشمندی درباره نوع رفتار سازه و منشأ احتمالی آسیب فراهم می‌کند. از این رو، ارزیابی ترک‌ها یکی از مراحل کلیدی در پایش سلامت سازه و تصمیم‌گیری درباره تعمیر، مقاوم‌سازی یا ادامه بهره‌برداری از ساختمان است.

با وجود اهمیت این موضوع، روش‌های متداول بازرسی چشمی عمدتا به تجربه و قضاوت کارشناسان وابسته‌اند و در شرایطی مانند ارزیابی سریع ساختمان‌ها پس از زلزله، با محدودیت‌هایی نظیر زمان‌بر بودن، احتمال خطای انسانی، وابستگی به شرایط محیطی و ناهماهنگی در تفسیر نتایج مواجه هستند. این محدودیت‌ها به‌ویژه زمانی آشکارتر می‌شوند که تعداد زیادی ساختمان باید در مدت‌زمان کوتاه مورد بررسی قرار گیرند. بنابراین، توسعه روش‌های خودکار، سریع و قابل‌اعتماد برای شناسایی و طبقه‌بندی ترک‌ها می‌تواند نقش مهمی در بهبود فرآیند ارزیابی اولیه آسیب ایفا کند.

در سال‌های اخیر، پیشرفت‌های حاصل‌شده در حوزه بینایی ماشین و یادگیری عمیق، زمینه مناسبی برای تحلیل خودکار تصاویر آسیب‌های ساختمانی فراهم کرده است. این روش‌ها قادرند با یادگیری الگوهای بصری موجود در تصاویر، ویژگی‌هایی مانند جهت، امتداد، پراکندگی، شکل و شدت ترک‌ها را استخراج کرده و فرآیند تشخیص یا طبقه‌بندی را با دقت و سرعت بیشتری پشتیبانی کنند. بر این اساس، پژوهش حاضر با تمرکز بر ترک‌های دال و دیوار، به ارائه روشی مبتنی بر یادگیری عمیق برای شناسایی و طبقه‌بندی خودکار انواع ترک در تصاویر ساختمانی می‌پردازد.

در این پژوهش، ترک‌های مورد بررسی در دو گروه اصلی شامل ترک‌های دال و ترک‌های دیوار دسته‌بندی شده‌اند و هدف اصلی، طبقه‌بندی خودکار ۱۰ نوع ترک با استفاده از روش‌های پردازش تصویر و شبکه عصبی کانولوشنی است. نتایج چنین رویکردی می‌تواند به‌عنوان ابزاری کمکی برای کارشناسان در پایش سلامت سازه، ارزیابی اولیه آسیب و تصمیم‌گیری درباره اقدامات تعمیراتی مورد استفاده قرار گیرد.

ترک‌ها می‌توانند تحت تأثیر عوامل مختلفی مانند بارگذاری‌های سازه‌ای، نشست نامتقارن پی، تغییرات دمایی، جمع‌شدگی بتن و یا ضعف در اجرای اجزای سازه‌ای ایجاد شوند. نوع، جهت و الگوی انتشار ترک‌ها اغلب می‌تواند نشانه‌ای از منشأ ایجاد آن‌ها باشد. مهم‌ترین عوامل و منشأهای ایجاد انواع ترک به‌صورت خلاصه در جدول ۱ ارائه شده است.

جدول ۱: عوامل و منشا ایجاد انواع ترک

عوامل ایجاد ترک	توضیحات
عوامل سازه‌ای	بارگذاری بیش از حد
	نشست نامتقارن پی
	طراحی ضعیف یا کمبود آرماتور
	اتصال نامناسب اجزای سازه
عوامل اجرایی	استفاده از مصالح بی‌کیفیت
	نسبت نامناسب آب به سیمان
	عمل‌آوری نامناسب بتن
	عدم اجرای درزهای انبساطی
عوامل محیطی	تغییرات شدید دمایی
	خشک‌شدگی سریع بتن یا گچ
	یخ‌زدگی و ذوب آب
	محیط‌های خورنده مانند مناطق مرطوب یا صنعتی
عوامل لرزه‌ای و ارتعاشی	زلزله و تنش‌های ناگهانی
	ارتعاش مداوم ناشی از ترافیک یا راه‌آهن
عوامل فیزیکی و شیمیایی	خوردگی آرماتورها در بتن
	واکنش قلیایی-سیلیسی بین سنگدانه و سیمان

یکی از موقعیت‌هایی که نیاز به ارزیابی سریع وضعیت سازه وجود دارد، پس از وقوع زلزله‌هایی با شدت متوسط است. در چنین شرایطی ممکن است ساختمان‌ها دچار خرابی‌های شدید و قابل مشاهده نشده باشند، اما وجود ترک‌هایی با ابعاد قابل توجه در بخش‌های مختلف سازه می‌تواند موجب ایجاد نگرانی در میان ساکنان و کاهش اطمینان نسبت به ایمنی و قابلیت بهره‌برداری ساختمان شود. از این رو، بررسی دقیق وضعیت سازه و ارزیابی نوع، الگو و پراکندگی ترک‌ها نقش مهمی در تشخیص میزان آسیب و تصمیم‌گیری درباره ادامه بهره‌برداری از ساختمان ایفا می‌کند. علاوه بر این، در فرآیند ارزیابی ساختمان‌های واقع در بافت‌های فرسوده در طرح‌های توسعه و نوسازی شهری، تحلیل ترک‌های موجود در اجزای سازه‌ای می‌تواند به عنوان شاخصی مؤثر برای تشخیص قابلیت بهره‌برداری، نیاز به تعمیر، یا ضرورت مقاوم‌سازی سازه مورد استفاده قرار گیرد.

مطالعه و بررسی انواع ترک‌ها در ساختمان‌ها از گذشته مورد توجه پژوهشگران قرار داشته است. در این زمینه، روش‌های متعددی با دقت‌ها و رویکردهای متفاوت مورد بررسی و آزمایش قرار گرفته‌اند و نتایج حاصل از آن‌ها در جهت بهبود فرآیند ارزیابی و بهره‌برداری ایمن از سازه‌ها مورد استفاده قرار می‌گیرد. در میان این روش‌ها، روش‌های غیرمخرب به دلیل عدم ایجاد آسیب در سازه از اهمیت ویژه‌ای برخوردار هستند. یکی از متداول‌ترین روش‌های غیرمخرب، بازرسی

نسخه پیش انتشار

بصری است که دقت و صحت نتایج آن تا حد زیادی به مهارت، تجربه و دقت نیروی متخصص وابسته است. با این حال، در برخی شرایط مانند سازه‌های با ارتفاع زیاد یا دسترسی دشوار، امکان انجام بازرسی توسط نیروی متخصص به سادگی فراهم نیست. در این راستا، چن و همکاران در سال ۲۰۲۱ مطالعه‌ای ارائه کردند که در آن یک روش دومرحله‌ای مبتنی بر تکنیک‌های پیشرفته پردازش تصویر برای شناسایی خودکار ترک‌های موجود در دیوارهای ساختمان از تصاویر ثبت‌شده توسط هواپیماهای بدون سرنشین پیشنهاد شده است. [۱]

الگوریتم‌های پردازش تصویر به‌عنوان یک روش جایگزین امیدوارکننده برای بررسی و نظارت بر ترک‌ها معرفی شده‌اند در یک مطالعه ماناوار و همکاران در سال ۲۰۲۱ از وسایل نقلیه هوایی بدون سرنشین برای تصویربرداری هوایی از آسیب‌ها خودکار استفاده کردند. ترک‌های موجود در تصاویر با کمک شبکه‌های عصبی کانولوشنال و کاربرد روش یادگیری عمیق که پتانسیل قابل‌توجهی برای تشخیص خودکار ویژگی‌های تصویر مانند آسیب‌ها نشان می‌دهند و حساسیت کمتری به نویز تصویر دارند، به تشخیص ترک‌ها کمک کرد. [۲]

در سال ۲۰۲۰ بیگدلی و همکاران یک روش هوشمند برای طبقه‌بندی ترک در سازه های بتنی بر اساس شبکه های عصبی عمیق پیشنهاد کردند که یک معماری جدید بر مبنای شبکه های عصبی کانولوشنی برای طبقه‌بندی ترک در سازه های بتنی ارائه گردید. معماری پیشنهادی در زمان کمتر و صحت بالاتر نسبت به سایر معماری های مرسوم و معتبر در یادگیری عمیق، چندشاخگی در ترک را شناسایی و طبقه‌بندی کرد.[۳]

یکی دیگر از روش‌های پایش سلامت سازه و نظارت بر عملکرد آن در طول دوره بهره‌برداری با استفاده از تبدیلات موجک است. در یک تحقیق که در سال ۲۰۱۸ توسط کاشانی انجام گرفت، یک عضو بتن مسلح انتخاب و در آنها عیوبی مانند ترک بتنی و خوردگی میلگرد ایجاد شد. این اعضا تحت بارگذاری قرار گرفتند و از تغییر شکل آنها، عکس با کیفیت بالا تهیه شد و به کمک پردازش تصاویر این عکس‌ها به سیگنال خیز پیوسته تبدیل شدند و از آنها تبدیل موجک گرفته شد. نتایج نشان می‌دهد این روش به‌خوبی می‌تواند آسیب‌های داخلی موجود در تیر را شناسایی کند. [۴]

در یک پژوهش توسط میربد و همکاران در سال ۲۰۲۳ یک مدل هوشمند تشخیص ترک سطح بتن را با استفاده از بینایی ماشین، تشخیص الگو، شبکه‌های عصبی مصنوعی و هیستوگرام گرادیان‌های جهت‌یافته برای استخراج ویژگی ارائه شد. برای این منظور، از بیش از ۵۶۰۰۰ داده تصویری از عرشه، دیوارها و روسازی‌های پل بتنی ترک خورده و بدون ترک استفاده شد. ANN ارائه شده در این مطالعه توانست تصاویر ترک خورده را از تصاویر بدون ترک تشخیص دهد. راندمان این شبکه ۸۴/۸۸ درصد بود و خطای شبکه را از ۰/۶۳۱ به ۰/۱۹۹ و شاخص گرادیان را از ۲۵/۵ به ۰/۰۸۰۱ کاهش داد. [۵] در پژوهشی در حوزه مهندسی عمران، محمودی و همکاران با استفاده از بینایی ماشین و شبکه عصبی کانولوشنال، روشی برای شناسایی خودکار عیوب ظاهری جوش ارائه کردند. نتایج این مطالعه نیز قابلیت روش‌های یادگیری عمیق را در کاهش وابستگی ارزیابی‌های بصری به قضاوت انسانی نشان داد. [۶]

در سال ۲۰۲۳ یک روش توسط لاکسمن و همکاران توسعه داده شد که یک چارچوب خودکار جامع تشخیص ترک و ارزیابی عمق ترک برای سازه‌های بتنی با استفاده از تصاویر گرفته شده از دستگاه‌های قابل بود. ابتدا، یک مدل شبکه عصبی کانولوشنال کلاس دودویی CNN برای تشخیص خودکار ترک‌ها روی سطح بتنی توسعه داده شد. در

نسخه پیش انتشار

مرحله دوم، یک مدل CNN یکپارچه ترکیبی از لایه‌های استخراج ویژگی کانولوشن و مدل‌های رگرسیون (RF و XGBoost) برای پیش‌بینی خودکار عمق ترک‌ها ایجاد شد. نتایج نشان می‌دهد که مدل‌ها برای بازرسی خودکار ترک‌ها دقیق و قابل اعتماد هستند که می‌تواند به ارزیابی وضعیت سازه بتنی و انتخاب روش‌های تعمیر مناسب کمک کند. [۷]

تشخیص ترک بتن بر اساس پردازش تصویر و هوش مصنوعی شامل استفاده از تکنیک‌های بینایی کامپیوتری برای شناسایی و طبقه‌بندی خودکار ترک‌ها در سازه‌های بتنی است. تشخیص و طبقه‌بندی این ترک‌ها را می‌توان با استفاده از ترکیبی از الگوریتم‌های مختلف یادگیری ماشین و تکنیک‌های پردازش تصویر انجام داد. در همین راستا تحلیل مقایسه‌ای برای تشخیص ترک بتن با استفاده از پردازش تصویر و هوش مصنوعی در سال ۲۰۲۳ توسط سمیه و همکاران صورت گرفت. در این مطالعه شناسایی محل ترک‌ها بر روی سازه‌ها با استفاده از تکنیک‌های مختلف پردازش مانند تغییر اندازه، مقیاس‌بندی خاکستری، دوتایی‌سازی، تقسیم‌بندی، افزایش و فیلتر کردن نویز بررسی شد. طبقه‌بندی بعدی این ترک‌های شناسایی شده با استفاده از تکنیک های یادگیری عمیق در مورد پارامترهای مختلف تصمیم گیری مانند طول، عرض و سطح مقطع ترک شناسایی شده مورد بررسی قرار گرفت. همچنین نشان داده شد که ترک‌ها را می توان بر اساس اندازه آنها طبقه‌بندی کرد که می توانند ترک‌های نازک، متوسط یا گسترده باشند. [۸]

در مطالعه‌ای دیگر از یادگیری ماشین بر اساس مدل VGG۱۶-Net برای تشخیص ترک در سازه‌های بتنی استفاده شد. در این تحقیق مدل پیشنهادی CNN + معماری مبتنی بر شبکه عصبی VGG بود و از الگوریتم تقویت گرادیان برای تقسیم‌بندی تصویر استفاده شد. مدل پیشنهادی به میزان دقت اعتبارسنجی ۹۸ درصد با کاهش ۰,۳ درصد دست یافت. [۹]

در یک مطالعه مبتنی بر داده‌های SDNET که در سال ۲۰۲۴ توسط شالابی و همکاران انجام شد، یک مدل هوشمند تشخیص ترک بر روی سطوح مختلف بتنی شامل دال‌های پل، دیوارهای بتنی و نمونه‌های مکعبی بتن توسعه داده شد که توانست بادقت بالایی ترک‌ها را حتی در حضور ناهمواری سطح، نویز، تغییرات رنگ و لکه‌های سطحی شناسایی کند. نتایج این پژوهش نشان داد که روش‌های مبتنی بر پردازش تصویر، ضمن برخورداری از دقت مناسب در کاربردهای واقعی سازه‌ای، از شفافیت فرایند و هزینه محاسباتی کمتری نسبت به چارچوب‌های پیچیده یادگیری عمیق برخوردار بوده و قابلیت بالایی برای استفاده در پایش سلامت سازه‌ها دارند. [۱۰]

در مجموع، بخش قابل‌توجهی از مطالعات مرورشده بر تشخیص دودویی ترک/بدون ترک، شناسایی ترک در یک نوع سطح مشخص یا استخراج یک ویژگی منفرد از ترک تمرکز داشته‌اند. در مقابل، پژوهش حاضر مسئله طبقه‌بندی چندکلاسه الگوهای متفاوت ترک در دو عضو دال و دیوار را دنبال می‌کند و نتیجه طبقه‌بندی را به تفسیر مهندسی مرتبط می‌سازد. در میان مطالعات بررسی‌شده در این پژوهش، ارائه هم‌زمان طبقه‌بندی ده نوع ترک هدف، تعیین منشأ احتمالی و سازه‌ای/غیرسازه‌ای بودن ترک و ارائه راهنمای اولیه سطح خطر برای برخی ترک‌های سازه‌ای در یک چارچوب کاربردی کمتر مورد توجه قرار گرفته است. همچنین، کمبود مجموعه‌داده‌های استاندارد و برچسب‌گذاری‌شده برای طبقه‌بندی مهندسی انواع ترک در ساختمان از محدودیت‌های این حوزه است؛ ازاین‌رو، در این پژوهش مجموعه‌ای از تصاویر گردآوری‌شده از منابع مختلف برای آموزش و ارزیابی مدل تهیه شده است.

۲- انواع ترک‌ها در سازه

دسته‌بندی ترک‌ها به روش‌های مختلفی انجام می‌شود. مطالعات مختلفی با روش‌های متفاوت با تمرکز بر ترک‌های خاص انجام شده است. در همین راستا مطالعه‌ای در سال ۲۰۲۳ توسط گولسکی با مروری جامع بر مکانیسم‌های ایجاد و گسترش ترک در بتن‌های کامپوزیتی انجام شد که انواع ترک‌ها را بر اساس ۸ معیار اصلی دسته‌بندی کرده و به بررسی دلایل شکل‌گیری آن‌ها پرداخته است. همچنین روش‌های تشخیص، تحلیل شکل و مسیر انتشار ترک‌های میکروسکوپی مورد ارزیابی قرار گرفته است. این آسیب‌ها می‌توانند منجر به کاهش ظرفیت باربری، نفوذپذیری، و دوام سازه شوند. [۱۱]

همچنین در پژوهشی دیگر در سال ۲۰۲۳ که توسط عسکر و همکاران انجام شد، به بررسی علل، پیشگیری و ترمیم انواع ترک‌های سازه‌ای و غیرسازه‌ای در ساختمان می‌پردازد. ترک‌های سازه‌ای معمولا ناشی از طراحی یا اجرای ضعیف و بارگذاری زیاد هستند، در حالی‌که ترک‌های غیرسازه‌ای بیشتر از تنش‌های داخلی ناشی از عوامل محیطی ایجاد می‌شوند. مدیریت صحیح طراحی و اجرا نقش مهمی در کنترل این ترک‌ها دارد. [۱۲]

در مطالعه‌ای دیگر که در سال ۲۰۲۳ توسط نیکیلا و همکاران انجام شد، ترک‌ها در سازه‌های بنایی بر اساس ماهیت به دو دسته سازه‌ای و غیرسازه‌ای، از نظر هندسی به صورت عمودی، افقی، مورب، پلکانی، نقشه‌ای یا تصادفی، و از نظر ابعاد به ترک‌های سطحی، مویین و عمیق تقسیم می‌شوند. هر نوع ترک می‌تواند نشان‌دهنده نوع خاصی از ضعف یا تنش در سازه باشد. شناخت این دسته‌بندی‌ها برای تحلیل دقیق‌تر آسیب و انتخاب روش تقویت مناسب ضروری است. [۱۳]

برای تکمیل مبنای مهندسی دسته‌بندی ترک‌ها، علاوه بر مطالعات مروری فوق، از راهنماهای فنی معتبر نیز استفاده شد. گزارش ACI ۲۲۴R-۰۱ علل اصلی ترک‌خوردگی و راهکارهای کنترل ترک در سازه‌های بتنی را تشریح می‌کند و ACI ۲۲۴,۱R-۰۷ به علل، ارزیابی و تعمیر ترک‌های بتن می‌پردازد [۱۴،۱۵]. همچنین ISO ۱۳۸۲۲:۲۰۱۰ چارچوب عمومی ارزیابی سازه‌های موجود را ارائه می‌کند [۱۶]. در این مقاله، این اسناد به‌عنوان پشتوانه فنی برای تفسیر منشأ و اهمیت ترک‌ها به‌کار رفته‌اند و جداول ۲ و ۳ بازتولید مستقیم یک طبقه‌بندی استاندارد واحد نیستند، بلکه حاصل تلفیق منابع علمی و راهنماهای فنی هستند.

کاربرد روش‌های پردازش سیگنال در مسائل مهندسی عمران نیز در مطالعات پژوهشگران ایرانی گزارش شده است. شکوهی و همکاران با استفاده از تبدیل موجک و تحلیل چندتفکیکی، پروفیل روسازی را برای شناسایی مؤلفه‌ها و ناهنجاری‌های موضعی تحلیل کردند [۱۷]. در مطالعات منتشرشده در زمینه پایش سلامت سازه نیز، از پردازش سیگنال و تبدیل موجک برای تشخیص خرابی [۱۸] و از روش‌های شناسایی سیستم و پارامترهای مودال برای ارزیابی وضعیت سازه استفاده شده است [۱۹]. همچنین داوودی، جعفری و عامل‌سخی از روش‌های تحلیل زمان–فرکانس برای بررسی رکوردهای انفجار سد سنگریزه‌ای مسجدسلیمان استفاده کردند [۲۰] و عامل‌سخی و داوودی نیز کاربرد پردازش زمان–فرکانس رکوردهای زلزله را در تحلیل دینامیکی این سد بررسی کردند [۲۱]. این مطالعات ظرفیت روش‌های پردازش

سیگنال و استخراج ویژگی را در پایش و ارزیابی سامانه‌های عمرانی نشان می‌دهند؛ در حالی که مسئله پژوهش حاضر بر طبقه‌بندی تصویری چندکلاسه ترک و تفسیر مهندسی آن متمرکز است.

در این مطالعه تلاش شده است با بررسی ۱۰ نوع ترک و ویژگی های آن‌ها در دسته های مختلف بتوان به نتیجه کلی در خصوص وضعیت سازه دارای ترک دست پیدا کنیم. انواع دسته‌بندی ترک به شرح زیر است.

- ترک‌های ساختمانی بر اساس محل تشکیل ترک
- ترک‌های ساختمانی از لحاظ شکل و الگوی انتشار
- ترک‌های ساختمانی از لحاظ منشأ ترک
- ترک‌های ساختمانی از لحاظ اندازه
- ترک‌های ساختمانی از لحاظ فعال بودن
- ترک‌های ساختمانی از لحاظ سن (بتن)

در این مقاله، ترک‌های ایجادشده در دال و دیوار بر اساس محل تشکیل، شکل و الگوی انتشار و منشأ احتمالی مورد بررسی قرار می‌گیرند. دسته‌بندی ارائه‌شده در جداول ۲ و ۳ با تلفیق مطالعات مرورشده [۱۰، ۱۱ و ۱۲] و راهنماهای فنی ACI [۱۳ و ۱۴] تدوین شده است؛ ISO ۱۳۸۲۲ [۱۵] نیز به‌عنوان چارچوب کلی ارزیابی سازه‌های موجود مورد توجه قرار گرفته است. بنابراین، هدف جداول ارائه یک مرجع کاربردی برای ارتباط میان الگوی بصری ترک و تفسیر اولیه مهندسی آن است، نه ادعای انطباق کامل هر ردیف با یک استاندارد منفرد.

جدول ۲: دسته‌بندی انواع ترک در دال‌ها

منشأ سازه‌ای یا غیرسازه‌ای	منشأ ایجاد ترک	الگوی انتشار ترک	محل تشکیل ترک
سازه‌ای	ضعف خمشی دال	شعاعی اطراف ستون	دال
سازه‌ای	برش پانچ (ضعف برشی دال)	مستطیلی اطراف ستون	
سازه‌ای	نشست تکیه گاه و ضعف برش یک‌طرفه	افقی در طول دال	
غیرسازه‌ای	جمع‌شدگی پلاستیک قبل از گیرش بتن	ترک‌های موازی	
غیرسازه‌ای	ترک‌های ناشی از نشست پلاستیک	ترک‌های عمود برهم و شبکه‌ای (در طول میلگردها)	
غیرسازه‌ای	ترک‌های ناشی از خوردگی میلگردها در اثر حملات کلریدی بعد از ماه‌ها و سال‌ها		
غیرسازه‌ای	ترک‌های ناشی از جمع شدگی بعد از گیرش بتن	پوست ماری	
غیرسازه‌ای	ترک‌های حاصل از آسیب‌های شیمیائی		
غیرسازه‌ای	ترک‌های حاصل از آسیب‌های فیزیکی		

جدول ۳: دسته‌بندی انواع ترک در دیوارها

ماهیت ترک	منشأ ایجاد ترک	دسته‌بندی ترک	الگوی انتشار	محل تشکیل ترک
سازه‌ای	خیز تیرها در دهانه‌های کوتاه	ترک‌های افقی کمی بالاتر از تیر	افقی	دیوار
سازه‌ای	زلزله ضعیف	ترک‌های افقی در تراز بالای تیر	افقی	دیوار
غیرسازه‌ای	ناشی از خمش دال مجاور دیوار	ترک‌های افقی در تراز زیر دال	افقی	دیوار
غیرسازه‌ای	ناشی از انبساط دال در اثر گرما	ترک‌های افقی کمی پائین‌تر از تراز دال	افقی	دیوار
سازه‌ای	بار خاک در پشت دیوار حائل	ترک‌های افقی در وسط دیوار حائل	افقی	دیوار
غیرسازه‌ای	ناشی از ضربه یا حرارت	ترک‌های افقی در محل درز سرد طاقچه	افقی	دیوار
سازه‌ای	نشست غیریکنواخت فونداسیون	ترک‌های عمودی در دیوار	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار

نسخه پیش انتشار

ماهیت ترک	منشأ ایجاد ترک	دسته‌بندی ترک	الگوی انتشار	محل تشکیل ترک
غیرسازه‌ای	کاهش طول نامساوی دیوارهای متقاطع ناشی از حرارت و عدم مهار صحیح	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
غیرسازه‌ای	ناشی از حرارت یا ضربه	ترک‌های عمودی در مجاورت المان‌های غیرسازه‌ای	قائم	دیوار
سازه‌ای	خیز تیر در دهانه‌های بلند	ترک‌های مورب ذوزنقه‌ای	مورب	دیوار
سازه‌ای	نشست تکیه گاه	ترک‌های مورب قطری با گسترش به سمت پائین	مورب	دیوار
سازه‌ای	تورم خاک زیر پی	ترک‌های مورب قطری با گسترش به سمت بالا	مورب	دیوار
سازه‌ای	زلزله شدید	ترک ضربدری	ضربدری	دیوار
غیرسازه‌ای	خوردگی میلگردها	ترک‌های شبکه‌ای	افقی و عمودی در طول میلگردها	دیوار
غیرسازه‌ای	آسیب‌های فیزیکی و شیمیائی	ترک‌های پوست ماری	پوست ماری	دیوار

نسخه پیش انتشار

۱-۲- نوآوری و وجه تمایز پژوهش

نوآوری پژوهش حاضر در توسعه یک چارچوب یکپارچه برای طبقه‌بندی ده نوع ترک هدف در دو عضو دال و دیوار با استفاده از EfficientNetB۰ و یادگیری انتقالی و پیوند دادن خروجی طبقه‌بندی به تفسیر مهندسی است. در این سامانه، پنج نوع ترک دال و پنج نوع ترک دیوار به‌صورت جداگانه و همراه با کلاس «بدون ترک» بررسی می‌شوند. افزون بر تعیین نوع ترک، رابط کاربری منشأ احتمالی و سازه‌ای یا غیرسازه‌ای بودن آن را نمایش می‌دهد و برای برخی ترک‌های سازه‌ای، با دریافت اطلاعات تکمیلی نظیر عرض و پیش‌روندگی، راهنمای اولیه سطح خطر ارائه می‌کند. این خروجی صرفا برای غربالگری و پشتیبانی از تصمیم مهندس طراحی شده است و جایگزین ارزیابی تخصصی سازه نیست.

۳- روش تحقیق

در این مطالعه، ده نوع ترک هدف که در جداول ۲ و ۳ ارائه شده‌اند بررسی شدند. این ترک‌ها در دو گروه اصلی دال و دیوار قرار دارند. ترک‌های دال شامل ترک شعاعی اطراف ستون، ترک مستطیلی اطراف ستون، ترک‌های عمود برهم و شبکه‌ای در امتداد میلگردها، ترک افقی در طول دال و ترک پوست‌ماری هستند. ترک‌های دیوار نیز شامل ترک افقی در وسط دیوار حائل، ترک عمودی، ترک مورب قطری با گسترش به سمت پایین، ترک ضربدری و ترک در محل اتصال دو دیوار متقاطع هستند. علاوه بر این ده نوع ترک، یک کلاس «بدون ترک» برای تصاویر دال و یک کلاس «بدون ترک» برای تصاویر دیوار در نظر گرفته شد؛ بنابراین هر یک از دو مدل دال و دیوار یک مسئله طبقه‌بندی شش‌کلاسه را حل می‌کند.

برای تشکیل مجموعه‌داده، تصاویر مربوط به پنج نوع ترک دال و پنج نوع ترک دیوار به همراه تصاویر بدون ترک گردآوری شدند. در مجموع، ۹۰ تصویر بدون ترک برای دال و ۹۱ تصویر بدون ترک برای دیوار وجود دارد. تصاویر از ترکیبی از برداشت‌های انجام‌شده از ترک‌های موجود در سازه‌ها و منابع عمومی و اینترنتی گردآوری شده‌اند. با توجه به تنوع منابع، مشخصات یکسانی از نوع دوربین، فاصله تصویربرداری، شرایط روشنایی و رزولوشن اولیه برای کل مجموعه‌داده در دسترس نیست و یک پایگاه داده استاندارد واحد نیز منبع همه تصاویر نبوده است. این ناهمگونی در شرایط و منشأ تصاویر به‌عنوان یکی از محدودیت‌های مجموعه‌داده در تفسیر نتایج در نظر گرفته شده است.

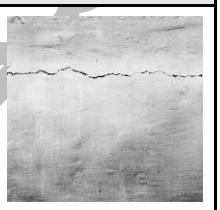
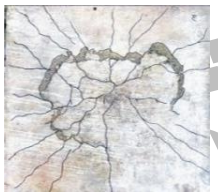
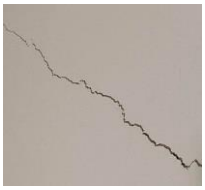
پس از گردآوری، تصاویر از نظر محتوای نامرتبط بررسی و برای ورود به فرایند پیش‌پردازش آماده شدند. در مجموع، ۱۲۹۲ تصویر در مجموعه‌داده نهایی استفاده شد. توزیع داده‌ها کاملا متوازن نیست؛ تعداد نمونه‌های کلاس‌های دال بین ۷۱ تا ۱۴۵ تصویر و کلاس‌های دیوار بین ۷۲ تا ۱۷۸ تصویر متغیر است. برای کاهش خطر بیش‌برازش ناشی از محدود بودن حجم داده، در فرایند آموزش از یادگیری انتقالی، Dropout و افزایش داده استفاده شد.

نسخه پیش انتشار

۱-۳- مشخصات گردآوری و منشأ تصاویر

مجموعه‌داده این پژوهش از منابع متنوع تشکیل شده است و برای همه تصاویر، فراداده یکسان و کاملی درباره دوربین، فاصله، نور، زاویه و رزولوشن اولیه ثبت نشده است. ازاین‌رو، در نسخه حاضر از ذکر مشخصات حدسی یا غیرقابل مستند خودداری شده و این موضوع به‌عنوان محدودیت قابلیت بازتولید مجموعه‌داده گزارش شده است.

جدول ۴: توزیع تعداد تصاویر در کلاس‌های دال و دیوار

ترک در دیوارها			ترک در دال‌ها		
نمونه تصاویر ترک	تعداد تصاویر	نوع ترک	نمونه تصاویر ترک	تعداد تصاویر	نوع ترک
	۷۲	افقی در وسط ارتفاع دیوار حائل (Horizontal-retaining-wall)		۱۴۵	شعاعی اطراف ستون (Radial)
	۱۶۵	ترک‌های عمودی در دیوار (Vertical)		۷۸	مستطیلی اطراف ستون (Rectangular)
	۱۲۱	ترک‌های مورب قطری Oblique		۷۱	ترک‌های عمود برهم و شبکه‌ای (در طول میلگردها) (Grid_Line)

	۱۷۸	ضربدری (Diagonal)		۹۷	افقی در طول دال (Horizontal)
	۱۱۲	محل اتصال دو دیوار متقاطع Two Walls		۷۲	پوست‌ماری (Crazing)
	۹۱	بدون ترک (Clear)		۹۰	بدون ترک (Clear)
	۷۳۹	مجموع		۵۵۳	مجموع
۱۲۹۲					جمع کل تصاویر

به منظور آغاز فرآیند تحلیل در نرم‌افزار، با توجه به اینکه تصاویر ترک‌ها در دو گروه کلی شامل دال (Slab) و دیوار (Wall) دسته‌بندی شده‌اند و در برخی موارد شباهت‌های ظاهری میان ترک‌های این دو گروه ممکن است منجر به بروز خطا در تشخیص شود، در ابتدای اجرای برنامه از کاربر خواسته می‌شود نوع ترک مورد نظر برای بررسی را مشخص کند. بدین منظور، کاربر با وارد کردن شماره ۱ یا ۲ به ترتیب دسته ترک‌های مربوط به دال (Slab) یا دیوار (Wall) را انتخاب می‌کند و نرم‌افزار مراحل تحلیل را بر اساس دسته انتخاب‌شده آغاز می‌کند.

به منظور آماده‌سازی داده‌ها و انجام پیش‌پردازش، داده‌های خام شامل تصاویر رنگی ترک‌ها از دو مجموعه مجزای مربوط به دیوارها و دال‌ها جمع‌آوری شدند. هر یک از این مجموعه‌ها شامل پنج دسته از ترک‌ها هستند که پیش‌تر در جداول ۲ و ۳ معرفی شده‌اند. به منظور افزایش کیفیت داده‌های ورودی به مدل و بهبود فرآیند استخراج ویژگی‌های مرتبط با ترک‌ها، یک فرآیند چندمرحله‌ای پیش‌پردازش بر روی این تصاویر اعمال شد که در ادامه مراحل آن تشریح می‌شود:

۳-۱- مراحل پیش‌پردازش

به منظور آماده‌سازی تصاویر برای استفاده در مدل یادگیری عمیق، مجموعه‌ای از مراحل پیش‌پردازش بر روی داده‌های ورودی اعمال شد. هدف از این مراحل، کاهش نویز، برجسته‌سازی مرز ترک‌ها و استانداردسازی تصاویر برای ورود به مدل بود. در مرحله نخست، به منظور کاهش نویز و حذف جزئیات غیرضروری، از فیلتر گوسی با ابعاد ۵×۵ بر روی

تصاویر استفاده شد. اعمال این فیلتر موجب هموارسازی تصویر شده و شرایط مناسب‌تری برای انجام عملیات لبه‌یابی فراهم می‌کند.

در مرحله بعد، تصویر حاصل با استفاده از الگوریتم Canny مورد لبه‌یابی قرار گرفت. این الگوریتم با شناسایی نقاط دارای بیشترین تغییر در شدت روشنایی، لبه‌ها و نواحی ترک را برجسته کرده و مرز ترک‌ها را به‌صورت واضح مشخص می‌کند.

به منظور حفظ اطلاعات بافت و رنگ تصویر اصلی و در عین حال تقویت ویژگی‌های مرتبط با ترک‌ها، تصویر نویززدایی‌شده و تصویر لبه‌یابی‌شده به‌صورت وزنی با یکدیگر ترکیب شدند. برای این منظور از تابع cv۲,addWeighted استفاده شد، به‌طوری که تصویر اصلی با وزن ۰٫۸ و تصویر لبه‌ها با وزن ۰٫۲ در تصویر نهایی مشارکت داشتند. این ترکیب باعث می‌شود ویژگی‌های مهم مرتبط با ترک‌ها در تصویر تقویت شوند، به‌ویژه در مواردی که تشخیص ترک در تصویر خام دشوار است.

در نهایت، به منظور استانداردسازی ابعاد تصاویر و سازگاری با ورودی مدل EfficientNetB۰، تصاویر نهایی به ابعاد ۱۵۰×۱۵۰ پیکسل تغییر اندازه داده شدند. با انجام این مراحل، تصاویر حاصل علاوه بر حفظ اطلاعات بافتی و رنگی، دارای لبه‌های برجسته‌تری از ترک‌ها هستند که می‌تواند به بهبود عملکرد مدل در مراحل آموزش و پیش‌بینی کمک کند.

۱-۱-۳- افزایش داده[1]

یکی از چالش‌های اساسی در یادگیری عمیق، محدودیت حجم داده‌های متنوع و پدیده بیش‌برازش (Overfitting) است؛ حالتی که در آن مدل به‌جای یادگیری الگوهای ساختاری کلی، داده‌های آموزشی را حفظ می‌کند و در نتیجه، در مواجهه با داده‌های جدید عملکرد قابل‌قبولی ارائه نمی‌دهد. برای مقابله با این مشکل و افزایش تعمیم‌پذیری (Generalization) مدل، از تکنیک افزایش داده استفاده شد.

به‌منظور اجرای این فرآیند، از کلاس Image Data Generator در کتابخانه Keras استفاده گردید تا مجموعه‌ای از تغییرات تصادفی بر روی تصاویر اعمال شود. این تغییرات شامل موارد زیر است:

- انتقال افقی (Width Shift): انتقال تصویر تا ۱۰٪ از عرض آن به سمت چپ یا راست برای ایجاد تنوع در مکان افقی ترک‌ها؛
- انتقال عمودی (Height Shift): انتقال تصویر تا ۱۰٪ از ارتفاع آن به سمت بالا یا پایین؛
- بزرگ‌نمایی(Zooming)): اعمال زوم تصادفی تا ۲۰٪ از تصویر به‌منظور شبیه‌سازی تغییر مقیاس در فواصل مختلف و زوایای دید متفاوت دوربین؛
- بازتاب افقی (Horizontal Flip): معکوس‌سازی تصویر از راست به چپ برای رفع سوگیری احتمالی ناشی از جهت‌گیری یکسان ترک‌ها در مجموعه داده؛

[1] Data Augmentation

- نحوه پر کردن حاشیه(Fill Mode): استفاده از پارامتر 'fill_mode = 'nearest برای پر کردن پیکسل‌های خالی ایجادشده در نواحی حاشیه پس از اعمال جابه‌جایی یا بزرگ‌نمایی، با استفاده از مقادیر نزدیک‌ترین پیکسل‌ها.

این تکنیک‌ها منجر به بهبود پایداری مدل نسبت به تغییر موقعیت، ابعاد و زاویه ترک‌ها می‌گردد. این تنوع‌بخشی مصنوعی به داده‌ها، مدل را قادر می‌سازد تا در مواجهه با تصاویر واقعی (تحت شرایط گوناگون نور، فاصله و زاویه دوربین) عملکردی بهینه‌تر و دقیق‌تر داشته باشد.

۲-۳- معماری مدل و تکنیک یادگیری انتقالی[1]

در این پژوهش، برای شناسایی و طبقه‌بندی ترک‌های موجود در سازه‌های بتنی از رویکرد یادگیری انتقالی (Transfer Learning) استفاده شده است. در این رویکرد، به جای آموزش کامل یک شبکه عصبی عمیق از ابتدا، از یک مدل از پیش آموزش‌دیده به عنوان پایه مدل استفاده می‌شود. در این تحقیق، معماری EfficientNetB۰ به عنوان ستون فقرات شبکه مورد استفاده قرار گرفته است.

EfficientNetB۰ یکی از نسخه‌های اولیه خانواده EfficientNet محسوب می‌شود که طراحی آن با استفاده از الگوریتم جست‌وجوی معماری شبکه (Neural Architecture Search – NAS) به صورت خودکار انجام شده است. هدف اصلی در طراحی این معماری، دستیابی به تعادل مناسب میان دقت مدل و کارایی محاسباتی بوده است. در بسیاری از شبکه‌های عصبی کانولوشنی سنتی، افزایش دقت معمولا با افزایش یکی از ابعاد شبکه شامل عمق (Depth)، عرض (Width) یا وضوح ورودی (Resolution) انجام می‌شود. در مقابل، معماری EfficientNet این سه بعد را به‌صورت هم‌زمان و متعادل با استفاده از راهبرد مقیاس‌دهی مرکب (Compound Scaling) توسعه می‌دهد. نسخه B۰ به عنوان مدل پایه این خانواده معرفی شده و سایر نسخه‌ها بر اساس آن مقیاس‌بندی می‌شوند.

در ساختار داخلی EfficientNetB۰ از بلوک‌های MBConv (Mobile Inverted Bottleneck Convolution) استفاده شده است. این بلوک‌ها با بهره‌گیری از کانولوشن‌های عمق‌گرا (Depthwise Convolution) و اتصالات میان‌بری (Skip Connections)، امکان استخراج مؤثر ویژگی‌ها را با تعداد پارامتر کمتر فراهم می‌کنند. این ویژگی موجب می‌شود مدل در عین سبک بودن، توانایی بالایی در یادگیری الگوهای پیچیده داشته باشد.

علاوه بر این، در بسیاری از لایه‌های شبکه از تکنیک Batch Normalization برای پایدارسازی فرآیند آموزش و تسریع همگرایی مدل استفاده شده است. همچنین در این معماری، تابع فعال‌سازی غیرخطی Swish به جای تابع ReLU به کار گرفته شده است که در شبکه‌های عمیق عملکرد بهتری در انتقال گرادیان و بهبود دقت مدل نشان می‌دهد.

[1] Model Architecture and Transfer Learning

۳-۲-۱- پیاده‌سازی مدل سفارشی‌شده

برای به‌کارگیری معماری EfficientNetB۰ در مسئله طبقه‌بندی ترک‌های سازه‌ای، از نسخه از پیش آموزش‌دیده این شبکه بر روی مجموعه‌داده ImageNet استفاده شد. در این مرحله، لایه بالایی (Top Layer) مدل حذف گردید تا امکان افزودن لایه‌های سفارشی متناسب با مسئله طبقه‌بندی ترک‌ها فراهم شود. همچنین ابعاد ورودی شبکه به صورت (۱۵۰, ۱۵۰, ۳) تعریف شد تا با تصاویر پیش‌پردازش‌شده در این پژوهش سازگاری داشته باشد.

به منظور بهره‌گیری از ویژگی‌های عمومی آموخته‌شده در مرحله پیش‌آموزش، وزن‌های لایه‌های EfficientNetB۰ فریز (Freeze) شدند تا در طول فرآیند آموزش تغییری نکنند. این کار باعث می‌شود دانش استخراج ویژگی‌های پایه‌ای تصاویر که در مرحله آموزش اولیه مدل کسب شده است حفظ شود.

در ادامه، یک لایه Global Average Pooling به خروجی شبکه افزوده شد تا نقشه‌های ویژگی استخراج‌شده توسط EfficientNetB۰ به یک بردار ویژگی فشرده تبدیل شوند. این لایه با محاسبه میانگین مقادیر هر فیلتر، ابعاد داده را کاهش داده و در مقایسه با روش Flatten موجب کاهش تعداد پارامترهای قابل آموزش می‌شود.

به منظور کاهش احتمال بیش‌برازش (Overfitting)، از لایه Dropout با نرخ ۰٫۴ استفاده شد. این لایه با حذف تصادفی بخشی از نورون‌ها در طول آموزش، از وابستگی بیش از حد مدل به ویژگی‌های خاص جلوگیری کرده و موجب بهبود تعمیم‌پذیری مدل می‌شود.

پس از آن، یک لایه Fully Connected از نوع Dense با ۱۲۸ نورون و تابع فعال‌سازی ReLU به شبکه افزوده شد تا فرآیند یادگیری و ترکیب ویژگی‌های استخراج‌شده تقویت شود. در نهایت، برای انجام طبقه‌بندی، یک لایه Dense خروجی با تعداد نورون برابر با تعداد کلاس‌های مورد نظر در نظر گرفته شد و از تابع فعال‌سازی Softmax برای تولید احتمال تعلق هر تصویر به کلاس‌های مختلف استفاده گردید.

مشخصات فنی آموزش مدل به شرح زیر است:

- بهینه‌ساز (Optimizer): Adam (با نرخ یادگیری ۰٫۰۰۰۰۵)
- تابع هزینه (Loss Function): Categorical Crossentropy
- معیار ارزیابی (Evaluation Metric): Accuracy
- تعداد دوره‌های آموزش (Epochs): ۲۰

۳-۳- تقسیم داده‌ها به مجموعه‌های آموزش و اعتبارسنجی

پس از انجام مراحل پیش‌پردازش و آماده‌سازی داده‌ها، مجموعه تصاویر به دو بخش تقسیم شد؛ ۸۰٪ داده‌ها برای آموزش مدل و ۲۰٪ برای اعتبارسنجی در نظر گرفته شد. داده‌های آموزشی برای یادگیری پارامترهای مدل و داده‌های اعتبارسنجی برای پایش عملکرد مدل در طول دوره‌های آموزش و بررسی روند دقت و تابع زیان مورد استفاده قرار گرفتند.

۳–۴– ارزیابی عملکرد مدل و طراحی رابط کاربری

پس از پایان فرایند آموزش، عملکرد مدل پیشنهادی با استفاده از داده‌های آموزش و اعتبارسنجی ارزیابی شد. در این پژوهش دو شاخص گزارش‌شده برای پایش عملکرد عبارت‌اند از Accuracy و Loss. نمودار Accuracy روند تغییر نسبت پیش‌بینی‌های صحیح و نمودار Loss روند تغییر خطای مدل را در طول دوره‌های آموزش نشان می‌دهند.

۱. نمودار Accuracy Curve که میزان پیشرفت مدل در تشخیص صحیح نمونه‌ها در طول دوره‌های آموزش را نشان می‌دهد.

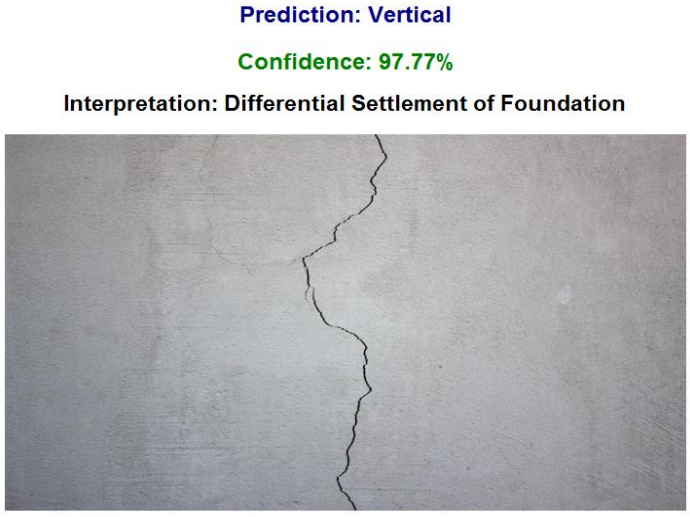
۲. نمودار Loss Curve که روند کاهش خطای پیش‌بینی در هر دوره‌ی آموزشی را نشان می‌دهد.

این نمودارها کمک کردند تا بتوان بررسی کرد آیا مدل دچار بیش‌آموزی یا کم‌آموزی[1] شده است یا خیر.

۳–۵– طراحی رابط کاربری گرافیکی[2]

به‌منظور بهره‌برداری آسان از مدل توسط کاربران نهایی همچون مهندسین، ناظران پروژه، اپراتورها، یک رابط گرافیکی ساده و کاربردی با استفاده از کتابخانه‌ی Tkinter در پایتون طراحی شد. این رابط کاربری امکان تعامل با مدل آموزش‌دیده را بدون نیاز به دانش برنامه‌نویسی فراهم می‌کند.

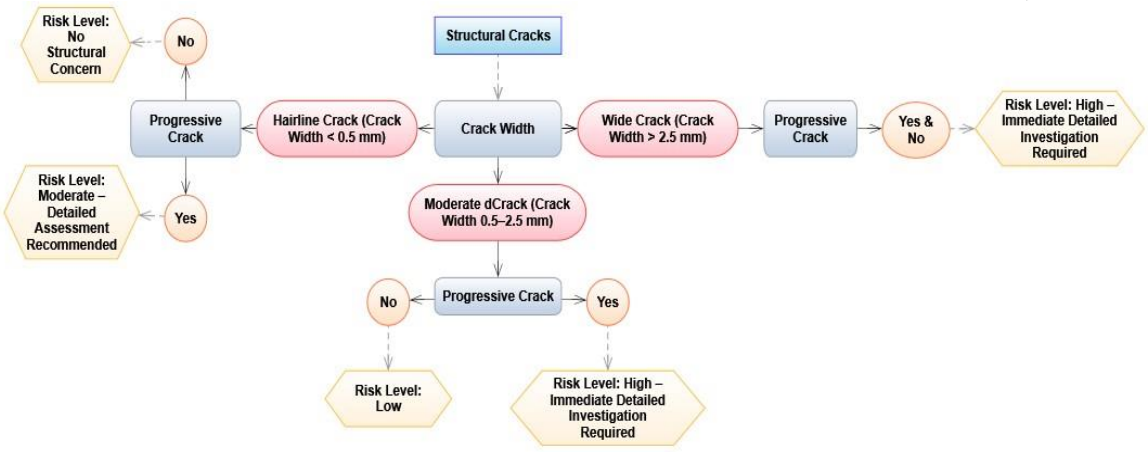
رابط گرافیکی طراحی‌شده امکانات جامعی را برای شناسایی، دسته‌بندی و تحلیل و تفسیر ترک‌های سازه‌ای فراهم می‌کند. کاربر می‌تواند با استفاده از دکمه‌ی "Browse"، یک تصویر ترک را از سیستم خود بارگذاری کند. با این کار تصویر به مدل داده می‌شود و کلاس پیش‌بینی‌شده‌ی ترک همراه با میزان درصد اطمینان به‌صورت عددی نمایش داده می‌شود.



شکل :۱نمونه پاسخ نرم‌افزار به تصویر انتخابی و شناسایی و دسته‌بندی ترک و بیان منشأ آن

[1] Underfitting
[2] GUI

همچنین درصورتی‌که نوع ترک از انواع سازه‌ای مانند ترک‌های مورب قطری (Diagonal)، شعاعی (Radial) یا پانچ (Punching Shear) باشد، یک پنجره تفسیر فنی نیز نمایش داده می‌شود تا با بررسی و وضعیت عرض ترک و پیش‌رونده یا عدم پیش‌رونده بودن سطح خطر را به کاربر گزارش دهد تا در جهت تصمیم‌گیری در خصوص فرایند بررسی و تصمیم‌گیری در خصوص ترک، اطلاعات واضحی در اختیار داشته باشد.



شکل :۲فلوچارت ارزیابی ترک شناسایی‌شده توسط نرم‌افزار با توجه به عرض و پیش‌روندگی آن، به‌منظور تصمیم‌گیری در خصوص ضرورت بررسی بیشتر و انجام اقدامات ترمیمی

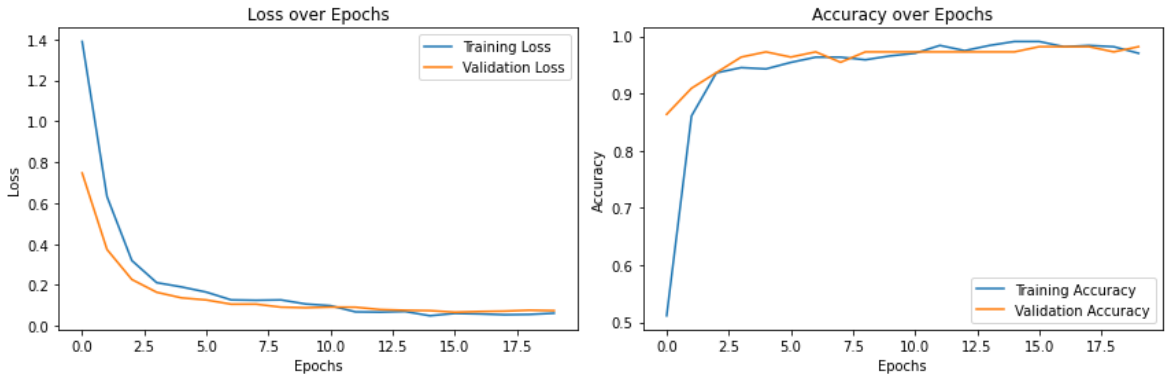
۴- نتایج و تفسیر

برای تحلیل عملکرد مدل پیشنهادی، دو زیرمجموعه مجزا شامل تصاویر دال و دیوار مورد استفاده قرار گرفتند. هر زیرمجموعه شامل پنج نوع ترک به همراه یک کلاس «بدون ترک» است و بنابراین هر مدل شش کلاس خروجی دارد. نتایج ارائه‌شده در این بخش بر اساس روند آموزش و اعتبارسنجی و معیارهای Accuracy و Loss گزارش می‌شوند.

۴–۱– عملکرد مدل در طبقه‌بندی ترک‌های دال

در مدل دال، دقت آموزش در دوره نخست ۳۴٫۷۷٪ و مقدار زیان ۱٫۶۲۱۴ بود. در دوره دوم، دقت آموزش به ۸۴٫۱۲٪ و دقت اعتبارسنجی به ۹۰٫۹۱٪ رسید. روند یادگیری در ادامه پایدار شد و در پایان دوره بیستم، دقت آموزش ۹۷٫۲۳٪ و دقت اعتبارسنجی ۹۸٫۱۸٪ گزارش شد.

مقدار تابع زیان در پایان آموزش به ۰٫۰۶۰۳ برای داده‌های آموزش و ۰٫۰۷۵۰ برای داده‌های اعتبارسنجی رسید. کاهش هم‌زمان زیان و نزدیک بودن دقت آموزش و اعتبارسنجی نشان می‌دهد در منحنی‌های گزارش‌شده واگرایی آشکاری میان دو مجموعه مشاهده نشده است.



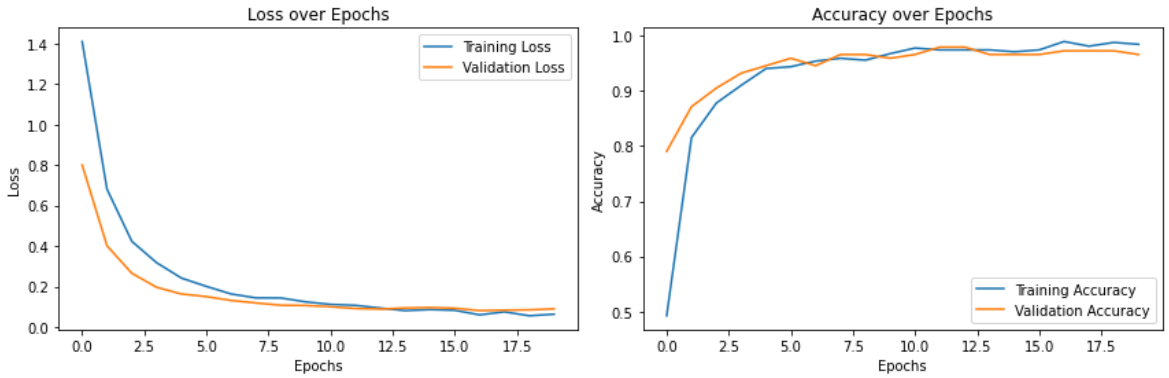
شکل ۳:تحلیل عملکرد مدل با بررسی روند تغییر دقت و خطای آموزش و اعتبارسنجی در طول دوره‌ها بر روی تصاویر Sl ab

۴-۲- عملکرد مدل در طبقه‌بندی ترک‌های دیوار

در مدل دیوار، دقت آموزش در دوره نخست ۳۴٫۱۱٪ و مقدار زیان ۱٫۶۶۷۵ بود. در دوره دوم، دقت آموزش به ۷۸٫۹۵٪ و دقت اعتبارسنجی به ۸۷٫۱۶٪ رسید. این روند نشان می‌دهد مدل در دوره‌های ابتدایی به‌سرعت الگوهای تفکیک‌کننده میان کلاس‌ها را فرا گرفته است.

در دوره هشتم، دقت آموزش به ۹۶٫۴۵٪ و دقت اعتبارسنجی به ۹۶٫۶۲٪ رسید. این مقادیر نشان‌دهنده همگرایی مناسب فرایند آموزش و نزدیک بودن عملکرد دو مجموعه در این مرحله است.

در پایان دوره بیستم، دقت آموزش ۹۸٫۱۳٪ و دقت اعتبارسنجی ۹۶٫۶۲٪ بود. مقدار زیان نیز به ۰٫۰۶۳۰ برای آموزش و ۰٫۰۸۹۱ برای اعتبارسنجی کاهش یافت. منحنی‌های Accuracy و Loss روند همگرایی نسبتا پایداری را در داده‌های آموزش و اعتبارسنجی نشان می‌دهند.



شکل ۴:تحلیل عملکرد مدل با بررسی روند تغییر دقت و خطای آموزش و اعتبارسنجی در طول دوره‌ها بر روی تصاویر Wal l

منحنی‌های یادگیری در هر دو مدل، کاهش زیان و تثبیت دقت آموزش و اعتبارسنجی را نشان می‌دهند. بر اساس نتایج اعتبارسنجی، هر دو مدل به دقت بیش از ۹۵٪ دست یافته‌اند و مقدار زیان اعتبارسنجی در انتهای آموزش کمتر از ۰،۱ بوده است.

دقت اعتبارسنجی مدل دال برابر ۹۸،۱۸٪ و دقت اعتبارسنجی مدل دیوار برابر ۹۶،۶۲٪ است. این مقادیر عملکرد مدل را در چارچوب مجموعه‌داده و تقسیم آموزش/اعتبارسنجی این پژوهش نشان می‌دهند و تعمیم آن‌ها به شرایط میدانی گسترده‌تر نیازمند ارزیابی مستقل در داده‌های جدید است.

۵- بحث

نتایج اعتبارسنجی نشان می‌دهد چارچوب مبتنی بر EfficientNetB۰ و یادگیری انتقالی در مجموعه‌داده این پژوهش توانسته است الگوهای مختلف ترک در دال و دیوار را با دقت بالایی طبقه‌بندی کند. با این حال، مقایسه مستقیم درصد دقت این پژوهش با همه مطالعات پیشین باید با احتیاط انجام شود؛ زیرا بخشی از مطالعات مرورشده بر تشخیص دودویی ترک/بدون ترک یا بر سطوح و دامنه‌های محدودتر متمرکز بوده‌اند [۵،۹،۱۰]، در حالی که پژوهش حاضر یک مسئله چندکلاسه را در دو عضو ساختمانی بررسی می‌کند.

یکی از محدودیت‌های این پژوهش آن است که ارزیابی کمی مدل در نسخه حاضر بر Accuracy و Loss متمرکز است و معیارهای کلاس‌محور مانند Precision، Recall، F۱-Score و ماتریس درهم‌ریختگی در فرایند گزارش نتایج محاسبه و ثبت نشده‌اند. همچنین، حجم مجموعه‌داده نسبتا محدود و توزیع کلاس‌ها کاملا متوازن نیست و تصاویر از منابع و شرایط تصویربرداری متنوع گردآوری شده‌اند. بنابراین، نتایج باید در محدوده داده‌های این پژوهش تفسیر شوند و برای تعمیم گسترده‌تر، ارزیابی بر داده‌های جدید و مستقل ضروری است.

از دیدگاه کاربردی، سامانه پیشنهادی می‌تواند برای غربالگری اولیه، مستندسازی تصویری و کمک به تشخیص نوع ترک مورد استفاده قرار گیرد. با این حال، تصاویر دوبعدی اطلاعات مستقیم درباره عمق ترک، هندسه سه‌بعدی، وضعیت داخلی عضو یا ظرفیت باقیمانده سازه فراهم نمی‌کنند و عملکرد سامانه نیز در یک مطالعه میدانی مستقل در چرخه واقعی بازرسی ساختمان ارزیابی نشده است. ازاین‌رو، خروجی سامانه باید به‌عنوان اطلاعات پشتیبان برای مهندس در نظر گرفته شود و نمی‌تواند جایگزین بازدید میدانی و ارزیابی تخصصی ایمنی سازه باشد.

۶- نتیجه‌گیری

- **جمع‌بندی یافته‌های اصلی**

هدف این تحقیق شناسایی آسیب در ساختمان‌ها با استفاده از ترک‌های ایجاد شده در دال و دیوار به کمک بینایی ماشین است. برای این منظور یک سامانه مبتنی بر EfficientNetB۰ و یادگیری انتقالی برای طبقه‌بندی ده نوع ترک هدف در دال و دیوار توسعه داده شد. در آماده‌سازی تصاویر از فیلتر گوسی، لبه‌یابی Canny، ترکیب وزنی تصویر و افزایش داده استفاده شد. دقت اعتبارسنجی نهایی برای مدل دال ۹۸،۱۸٪ و برای مدل دیوار ۹۶،۶۲٪ به‌دست آمد.

رابط کاربری توسعه‌یافته نیز خروجی طبقه‌بندی را به اطلاعات مهندسی مربوط به منشأ احتمالی و سازه‌ای یا غیرسازه‌ای بودن ترک مرتبط می‌کند.

- **محدودیت‌های پژوهش**

مهم‌ترین محدودیت‌های پژوهش شامل حجم نسبتا محدود و نامتوازن مجموعه‌داده، تنوع منابع و شرایط تصویربرداری، محدود بودن ارزیابی کمی به Accuracy و Loss، نبود ارزیابی میدانی مستقل و استفاده از تصاویر دوبعدی است. ازاین‌رو، نتیجه طبقه‌بندی تصویری نباید معادل تشخیص قطعی وضعیت ایمنی سازه تلقی شود.

- **پیشنهادات آینده و جایگاه کاربردی سامانه**

در ادامه این پژوهش، افزایش حجم و تنوع داده‌های میدانی، استفاده از داده‌های ویدئویی برای بررسی تغییرات زمانی، تخمین خودکار عرض و عمق ترک و ادغام نتایج بینایی ماشین با اطلاعات تحلیل سازه‌ای پیشنهاد می‌شود. سامانه حاضر به‌عنوان یک ابزار کمکی برای غربالگری، مستندسازی و ارزیابی اولیه طراحی شده است و جایگزین بازدید میدانی، قضاوت مهندسی و ارزیابی تخصصی ایمنی سازه توسط مهندس ذی‌صلاح نیست.

۷- مراجع

[1] K. Chen, G. Reichard, X. Xu, and A. Akanmu, "Automated crack segmentation in close-range building façade inspection images using deep learning techniques," *Journal of Building Engineering*, vol. 43, p. 102913, 2021.

[2] H. S. Munawar, F. Ullah, A. Heravi, M. J. Thaheem, and A. Maqsoom, "Inspecting buildings using drones and computer vision: A machine learning approach to detect cracks and damages," *Drones*, vol. 6, no. 1, p. 5, 2021.

[3] N. Bigdeli, H. Jabbari, and M. Shojaei, "An intelligent method for crack classification in concrete structures based on deep neural networks," *Amirkabir Journal of Civil Engineering*, vol. 53, no. 8, pp. 3201-3220, 2021.

[4] A. Kouchak Kashani, "Detection of internal damages in reinforced concrete beams using image processing and wavelet transform," M.Sc. thesis, Department of Civil Engineering (Structural Engineering), 2018.

[5] M. Mirbod and M. Shoar, "Intelligent concrete surface cracks detection using computer vision, pattern recognition, and artificial neural networks," *Procedia Computer Science*, vol. 217, pp. 52-61, 2023.

[6] M. Mahmoudi, S. Ghaderi, and F. Mahmoudi Sahebi, "Identification of apparent welding defects using computer vision based on deep learning," *Ferdowsi Civil Engineering*, vol. 35, no. 4, pp. 73-86, 2023, doi: 10.22067/jfcei.2022.75044.1118.

[7] K. C. Laxman, N. Tabassum, L. Ai, C. Cole, and P. Ziehl, "Automated crack detection and crack depth prediction for reinforced concrete structures using deep learning," *Construction and Building Materials*, vol. 370, p. 130709, 2023.

[8] M. N. Sumaiya, K. Prajwal, R. S. Vasudev, K. A. Shreya, R. Thrishul, and R. M. Prasad, "Comparative analysis of concrete crack detection using image processing and artificial intelligence," *Journal of Image Processing and Artificial Intelligence*, vol. 9, no. 1, pp. 8-15, 2023.

[9] P. Padmapoorani and S. Senthilkumar, "Application of machine learning for crack detection on concrete structures using CNN architecture," *Matéria (Rio de Janeiro)*, vol. 28, p. e20230010, 2023.

[10] Y. M. Shalaby, M. Badawy, G. A. Ebrahim, and A. M. Abdelalim, "Condition assessment of concrete structures using automated crack detection method for different concrete surface types based on image processing," *Discover Civil Engineering*, vol. 1, no. 1, p. 81, 2024.

نسخه پیش انتشار

[11] G. L. Golewski, "The phenomenon of cracking in cement concretes and reinforced concrete structures: The mechanism of cracks formation, causes of their initiation, types and places of occurrence, and methods of detection-a review," *Buildings*, vol. 13, no. 3, p. 765, 2023.

[12] M. K. Askar, Y. A. M. A. N. Al-Kamaki, R. Ferhadi, and H. K. Majeed, "Cracks in concrete structures causes and treatments: A review," *Journal of Duhok University*, vol. 26, no. 2, pp. 148-165, 2023.

[13] G. Nikila and P. A. Prabakaran, "Study of structural cracks on residential buildings," *International Journal of Advanced Research in Science, Communication and Technology*, vol. 3, no. 2, pp. 1-6, 2023.

[14] ACI Committee 224, "Control of cracking in concrete structures," ACI 224R-01, American Concrete Institute, Farmington Hills, MI, 2001, reapproved 2008.

[15] ACI Committee 224, "Causes, evaluation, and repair of cracks in concrete structures," ACI 224.1R-07, American Concrete Institute, Farmington Hills, MI, 2007.

[16] International Organization for Standardization, *Bases for Design of Structures-Assessment of Existing Structures*, ISO 13822:2010, Geneva, Switzerland, 2010.

[17] P. Shokouhi, N. Gucunski, A. Maher, and S. M. Zaghloul, "Wavelet-based multiresolution analysis of pavement profiles as a diagnostic tool," *Transportation Research Record*, vol. 1940, pp. 79-88, 2005, doi: 10.3141/1940-10.

[18] A. Abbasi, S. R. Hosseini Vae'z, and G. Ghodrati Amiri, "Damage detection of steel shear wall using wavelet algorithm," *Ferdowsi Civil Engineering*, vol. 29, no. 2, pp. 61-74, 2017, doi: 10.22067/civil.v29i2.50565.

[19] N. Kowsari, Z. Rezaie, M. Golriz, and A. Shooshtari, "Comparison of system identification methods for extracting modal parameters (Case study: 22 Bahman Bridge, Ferdowsi University of Mashhad)," *Ferdowsi Civil Engineering*, 2025, doi: 10.22067/jfcei.2025.91585.1336.

[20] M. Davoodi, M. K. Jafari, and M. Amel Sakhi, "Using new signal processing techniques in analyzing Masjed Soleyman Embankment Dam's explosion records," in *Proc. 6th International Conference on Case Histories in Geotechnical Engineering*, Paper 33, 2008.

[21] M. Amel Sakhi and M. J. Davoodi, "Using recorded earthquake signals for dynamic analysis of Masjed Soleiman Embankment Dam," in *Proc. 5th International Conference on Recent Advances in Geotechnical Earthquake Engineering and Soil Dynamics*, Paper 41, 2010.

واژه‌نامه

English Equivalent	واژه فارسی
Slab	دال
Wall	دیوار
Overfitting	بیش‌برازش
Generalization	تعمیم‌پذیری
Width Shift	انتقال افقی
Height Shift	انتقال عمودی
Horizontal Flip	بازتاب افقی
Transfer Learning	یادگیری انتقالی
Neural Architecture Search – NAS	جست‌وجوی معماری شبکه
Depth	عمق

نسخه پیش انتشار

English Equivalent	واژه فارسی
Width	عرض
Resolution	وضوح ورودی
Compound Scaling	مقیاس‌دهی مرکب
Depthwise Convolution	کانولوشن‌های عمق‌گرا
Skip Connections	اتصالات میان‌بری
Top Layer	لایه بالایی
Freeze	فریز
Optimizer	بهینه‌ساز
Loss Function	تابع هزینه
Evaluation Metric	معیار ارزیابی
Epochs	تعداد دوره‌های آموزش
Diagonal	ترک‌های مورب قطری
Radial	شعاعی
Punching Shear	پانچ
Zooming	بزرگ‌نمایی
Fill Mode	نحوه پر کردن حاشیه
Canny Edge Detection	لبه‌یابی کنی
Accuracy	دقت
Loss	زیان
Data Augmentation	افزایش داده
Convolutional Neural Network (CNN)	شبکه عصبی کانولوشنال
Underfitting	کم‌آموزی
Graphical User Interface (GUI)	رابط کاربری گرافیکی

نسخه پیش انتشار