



An Intelligent Method for Crack Classification in Concrete Structures Based on Deep Neural Networks

N. Bigdeli*, H. Jabbari, M. Shojaei

EE Department, Imam Khomeini International University, Qazvin, Iran

ABSTRACT: Identifying and examining the types of cracks in concrete structures is one of the challenging engineering issues. Detection of crack bifurcation is very important because it detects high-intensity surfaces in concrete structures. In this paper, a new architecture based on convolutional neural networks is presented for crack classification in concrete structures. The proposed architecture detected and classified crack bifurcation in less time and with higher accuracy than other conventional and authentic deep learning architectures. In this paper, the cracks in 12000 images of concrete structures were investigated by the proposed algorithm, which resulted in 99.3% accuracy in categorizing as non-cracked images, images with simple cracks, and bifurcated crack images. Moreover, the analysis of the confusion matrix showed an accuracy of 99.3% and a recall of 99.5%, which confirmed the proper performance of the proposed algorithm. The sensitivity analysis of the proposed algorithm also showed the need for proportionality between the number of data, the number of neurons in the fully connected layer, execution time, and the expected percentage of accuracy according to the application of the problem.

Review History:

Received: Jan. 19, 2020

Revised: Aug. 01, 2020

Accepted: Aug. 14, 2020

Available Online: Sep. 10, 2020

Keywords:

Cracks

Concrete structures

Machine learning

Deep learning

Convolutional neural networks

1. INTRODUCTION

Cracks in concrete structures such as bridges, dams, and skyscrapers are one of the main indicators of durability and possible structural damage [1-6]. Most developed countries carry out regular cracks assessments in concrete structures as part of infrastructure maintenance [6]. These unavoidable issues lead to a great deal of research into the health status of concrete structures [7-9]. Visual inspection is the most common method used to obtain cracking information such as presence, location, thickness, etc. to prepare maintenance programs. Although cracking information can be obtained from a visual inspection, this method is time-consuming and often unreliable; therefore, the results depend on the experience and skills of the relevant expert force. Visual inspection is also not possible in high-rise structures. To overcome the disadvantages of visual inspection, image processing, and machine learning algorithms have been introduced as promising alternative methods for detecting and monitoring cracks [10]. One of the damages that its detection could prevent possible future damage to concrete structures is the crack bifurcation. If the crack splits into two or more new cracks at the change of direction, this point is called the crack bifurcation [11]. In this research, in a classification system, crack bifurcation in concrete structures is detected and classified. The innovation of this research can be mentioned in two cases:

1. The proposed architecture of this paper is a combination of different deep layers that has led to a unique structure.

2. Although some previous studies have examined, detected and classified cracks in concrete structures [6, 12-14], detection of crack bifurcation has received less attention [11]. In some articles, the purpose of which was only to detect cracks (and not to classify some specific types of them), crack bifurcation is also considered, but they have not classified the crack bifurcation as a specific type [14]. Therefore, in this research, crack bifurcation is detected and classified in concrete structures.

The achievements of this research are as follows:


1. Achieving 99.3% accuracy that is high in classifying cracks compared to other methods;

2. Relatively low execution time of the proposed architecture (76 min) compared to other valid architectures in deep learning on the same hardware platform.

2. METHODOLOGY

The proposed method of this paper for detecting and classifying cracks in concrete structures according to the block diagram of Fig. 1 is that first in the data collection stage, a video of the concrete structure is prepared by a quadcopter. The saved video is then converted to a panoramic image of the concrete structure. In the next step, the panoramic image is decomposed into small images with the desired resolution.

*Corresponding author's email: n.bigdeli@eng.ikiu.ac.ir






Fig. 1. Proposed block diagram for crack image classification

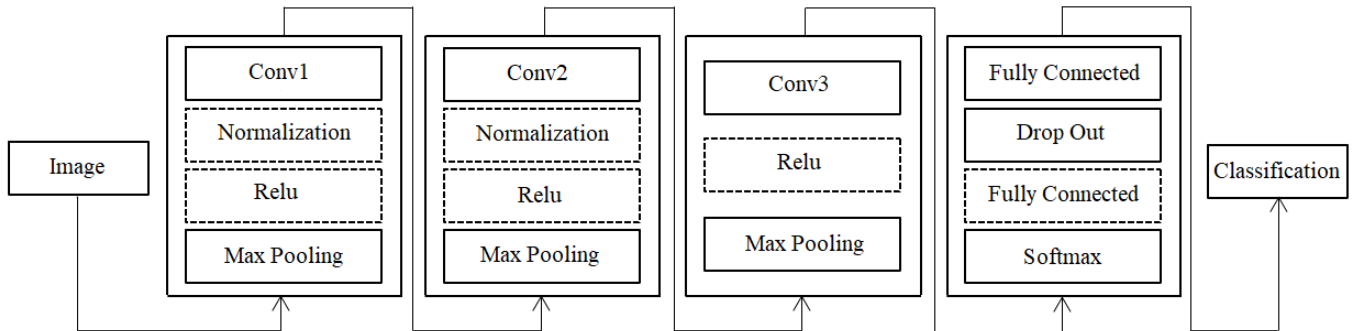


Fig. 2. The proposed architecture

After the data collection step, pre-processing is done to remove possible noise and adjust the color intensity of the images. Finally, by designing a deep learning network, the images extracted from concrete structures are classified into three categories. Fig. 2 also shows the proposed architecture of this research. In this architecture, maximum integration was used across the network to maintain the best features. Moreover, after the convolution layer packet normalization is located in the first and second blocks. There is a Relu nonlinear activator function in the first three blocks of the proposed architecture [15]. At the end of the network and in the fourth block, two fully connected layers have been used. To prevent over-fitting, a random removal layer is used between fully connected layers to reduce parameters. In the last layer, the Softmax function is considered for classification as well [16].

3. RESULTS AND DISCUSSION

The confusion matrix for the proposed algorithm of this research is shown in Table 1. As can be deduced from this Table, the proposed algorithm has been able to detect the presence of bifurcated crack images of concrete structures in 99.5% of cases. Also, according to this Table, the accuracy, precision, and call of the proposed algorithm are 99.3, 99.3, and 99.5%, respectively.

Generally, the convolutional neural networks require large volumes of labeled data. Of course, it is not always possible to provide a lot of labeled data, and in many cases, this has limitations. Although high-tagged data can increase accuracy, it increases computation time and can overshadow the online nature of the learning algorithm. Therefore, the relationship between the number of data and the execution time of the program as well as the desired accuracy is a challenge that can vary depending on the subject under study. Sensitivity analysis of the number of data in the proposed algorithm showed that although the execution time of the algorithm decreases with decreasing the number of data, the percentage of accuracy also decreases, which confirms the challenge of proportionality between the number of data, execution time, and expected percentage of accuracy. However, at least 10,000 data results in a good accuracy of over 90% and an approximate time of 62 minutes.

4. CONCLUSION

According to the intelligent method presented in this paper, the images extracted from the flying robot, which can cover all parts of a concrete structure, were classified by a proposed deep architecture. This classification included categories of non-cracked images, images with simple cracks,

Table 1. The confusion matrix for the proposed algorithm

Actual \ Predicted	Non-Cracked	Simple Crack	Bifurcated Crack
	Non-Cracked	0.993	0.006
Simple Crack	0.003	0.991	0.006
Bifurcated Crack	0.001	0.004	0.995

and bifurcated crack images, which yielded 99.3% accuracy. The strengths of this paper can be summarized in four cases: first, the proposed deep architecture is much less complex than other deep architectures, and secondly, it simply leads to higher accuracy than the other methods introduced in the previous studies and other deep architectures have been validated. The third case involves less execution time than other methods. The fourth and final advantage of this article is the detection of crack bifurcation, which has received less attention in other articles. Although the proposed method may not be suitable for being online due to runtime, the use of a strong hardware system could help to realize this idea. Besides, the use of flying robots, in addition to the advantage of the quadcopter, can be useful and effective in the online investigation of crack bifurcation and other important cracks in concrete structures.

REFERENCES

- [1] L. Qiu, S. Yuan, C. Boller, An adaptive guided wave-Gaussian mixture model for damage monitoring under time-varying conditions: Validation in a full-scale aircraft fatigue test, *Structural health monitoring*, 16(5) (2017) 501-517.
- [2] P. Liu, H.J. Lim, S. Yang, H. Sohn, C.H. Lee, Y. Yi, D. Kim, J. Jung, I.-h. Bae, Development of a "stick-and-detect" wireless sensor node for fatigue crack detection, *Structural Health Monitoring*, 16(2) (2017) 153-163.
- [3] J. Xu, Z. Fu, Q. Han, G. Lacidogna, A. Carpinteri, Micro-cracking monitoring and fracture evaluation for crumb rubber concrete based on acoustic emission techniques, *Structural Health Monitoring*, 17(4) (2018) 946-958.
- [4] D. Reagan, A. Sabato, C. Niezrecki, Feasibility of using digital image correlation for unmanned aerial vehicle structural health monitoring of bridges, *Structural Health Monitoring*, 17(5) (2018) 1056-1072.
- [5] W.-H. Hu, S. Said, R.G. Rohrmann, Á. Cunha, J. Teng, Continuous dynamic monitoring of a prestressed concrete bridge based on strain, inclination and crack measurements over a 14-year span, *Structural Health Monitoring*, 17(5) (2018) 1073-1094.
- [6] H. Kim, E. Ahn, M. Shin, S.-H. Sim, Crack and noncrack classification from concrete surface images using machine learning, *Structural Health Monitoring*, 18(3) (2019) 725-738.
- [7] J. Valença, D. Dias-da-Costa, E. Júlio, H. Araújo, H. Costa, Automatic crack monitoring using photogrammetry and image processing, *Measurement*, 46(1) (2013) 433-441.
- [8] D. Dias-da-Costa, J. Valença, E. Júlio, H. Araújo, Crack propagation monitoring using an image deformation approach, *Structural Control and Health Monitoring*, 24(10) (2017) e1973.
- [9] T.-H. Yi, H.-N. Li, M. Gu, Experimental assessment of high-rate GPS receivers for deformation monitoring of bridge, *Measurement*, 46(1) (2013) 420-432.
- [10] A. Mohan, S. Poobal, Crack detection using image processing: A critical review and analysis, *Alexandria Engineering Journal*, 57(2) (2018) 787-798.
- [11] E.J. Willemse, D.D. Pollard, On the orientation and patterns of wing cracks and solution surfaces at the tips of a sliding flaw or fault, *Journal of Geophysical Research: Solid Earth*, 103(B2) (1998) 2427-2438.
- [12] K. Ohno, M. Ohtsu, Crack classification in concrete based on acoustic emission, *Construction and Building Materials*, 24(12) (2010) 2339-2346.
- [13] A. Cubero-Fernandez, F.J. Rodriguez-Lozano, R. Villatoro, J. Olivares, J.M. Palomares, Efficient pavement crack detection and classification, *EURASIP Journal on Image and Video Processing*, 2017(1) (2017) 39.
- [14] K. Chen, A. Yadav, A. Khan, Y. Meng, K.J.M. Zhu, S.i. Engineering, Improved Crack Detection and Recognition Based on Convolutional Neural Network, 2019 (2019).
- [15] V. Romanuke, Appropriate number and allocation of ReLUs in convolutional neural networks, *Naukovi Visti NTUU KPI*, (1) (2017) 69-78.
- [16] W. Liu, Y. Wen, Z. Yu, M. Yang, Large-margin softmax loss for convolutional neural networks, in: *ICML, 2016*, pp. 7.

HOW TO CITE THIS ARTICLE

N. Bigdeli, H. Jabbari, M. Shojaei, *An Intelligent Method for Crack Classification in Concrete Structures Based on Deep Neural Networks*, *Amirkabir J. Civil Eng.*, 53(8) (2021) 707-710.

DOI: [10.22060/ceej.2020.17738.6660](https://doi.org/10.22060/ceej.2020.17738.6660)





یک روش هوشمند برای طبقه‌بندی ترک در سازه‌های بتنی بر اساس شبکه‌های عصبی عمیق

نوشین بیگدلی^{*}، حامد جباری، مهدی شجاعی

دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران

تاریخچه داوری:

دریافت: ۱۳۹۸/۱۰/۲۹

بازنگری: ۱۳۹۹/۰۵/۱۱

پذیرش: ۱۳۹۹/۰۵/۲۴

ارائه آنلاین: ۱۳۹۹/۰۶/۲۰

کلمات کلیدی:

ترک

سازه‌های بتنی

یادگیری ماشین

یادگیری عمیق

شبکه‌های عصبی کانولوشنی

خلاصه: شناسایی و بررسی انواع ترک‌ها در سازه‌های بتنی یکی از موضوعات چالش‌برانگیز در حوزه مهندسی به شمار می‌رود. تشخیص چندشاخگی در ترک به دلیل اینکه موجب شناسایی سطوح شدت بالا در سازه‌های بتنی می‌شود، از اهمیت بسزایی برخوردار است. در این مقاله یک معماری جدید بر مبنای شبکه‌های عصبی کانولوشنی برای طبقه‌بندی ترک در سازه‌های بتنی ارائه گردید. معماری پیشنهادی در زمان کمتر و صحت بالاتر نسبت به سایر معماری‌های مرسوم و معتبر در یادگیری عمیق، چندشاخگی در ترک را شناسایی و طبقه‌بندی کرد. در این مقاله ترک‌های موجود در ۱۲۰۰۰ تصویر سازه‌های بتنی توسط الگوریتم پیشنهادی بررسی شدند که در نتیجه این تصاویر با صحت ۹۹/۳ درصد در دسته‌های تصاویر بدون ترک، تصاویر دارای ترک ساده و تصاویر دارای چندشاخگی در ترک طبقه‌بندی شدند. همچنین تحلیل ماتریس درهم‌ریختگی نشان از دقت ۹۹/۳ درصد و فراخوانی ۹۹/۵ درصد داشت که تأییدی بر عملکرد مناسب الگوریتم پیشنهادی بود. آنالیز حساسیت الگوریتم پیشنهادی نیز الزام وجود تناسب میان تعداد داده، تعداد نورون‌های لایه تماماً متصل، زمان اجرا و درصد صحت مورد انتظار با توجه به کاربرد مسأله را نشان داد.

۱- مقدمه

اطمینان است، چرا که نتایج به تجربه و مهارت نیروی متخصص مربوطه بستگی دارد. همچنین بازرسی بصری در سازه‌های دارای ارتفاع نیز امکان‌پذیر نیست. برای غلبه بر معایب بازرسی بصری، الگوریتم‌های پردازش تصویر به عنوان یک روش جایگزین امیدوار کننده برای بررسی و نظارت بر ترک‌ها معرفی شده‌اند [۱۰]. بطور کلی در این الگوریتم‌ها از تصاویر سطح سازه‌های بتنی برای پردازش و آنالیز ترک‌ها استفاده می‌شود که منجر به حصول اطلاعاتی نظیر وجود یا عدم وجود ترک در بتن، موقعیت و ضخامت ترک‌ها می‌گردد. اگرچه کارایی مناسب این الگوریتم‌ها منجر به کاربرد بالای آن‌ها در زمینه شناسایی ترک‌های بتنی شده است، اما وجود لکه‌های تیره، سایه‌ها، گردوغبار، کلوخگی‌ها و سوراخ‌های احتمالی موجود در تصاویر سطحی بتن‌ها می‌تواند منجر به تشخیص نادرست ترک‌ها گردد. بنابراین،

ترک‌ها در سازه‌های بتنی از جمله پل‌ها، سدها و آسمان‌خراش‌ها یکی از شاخص‌های اصلی دوام و آسیب‌های ساختاری احتمالی به شمار می‌روند [۱-۶]. بیشتر کشورهای توسعه‌یافته ارزیابی منظم ترک در سازه‌های بتنی را به عنوان بخشی از نگهداری زیرساخت‌ها انجام می‌دهند [۶]. این مسائل اجتناب‌ناپذیر موجب تحقیقات زیادی در زمینه مشاهده وضعیت سلامتی سازه‌های بتنی شده است [۷-۹]. بازرسی بصری متداول‌ترین روش استفاده شده برای به دست آوردن اطلاعات ترک مانند وجود، موقعیت، ضخامت و غیره به منظور تهیه برنامه‌های نگهداری است. اگرچه می‌توان اطلاعات ترک را از یک بازرسی بصری به دست آورد، اما این روش وقت‌گیر و معمولاً غیرقابل

^{*} نویسنده عهده‌دار مکاتبات: n.bigdeli@eng.ikiu.ac.ir



جدول ۱. مقایسه‌ای از انواع کلی روش‌های تشخیص و طبقه‌بندی ترک در سازه‌های بتنی

Table 1. The comparison of general types of crack detection and classification methods in concrete structures

روش	مزایا	معایب
آزمایش بصری	ساده سریع	الزام در دسترس بودن محدوده آزمایش الزام تمیز بودن سطح آزمایش عدم تشخیص عمق ترک نیازمند نیروی متخصص غیر قابل اطمینان
روش‌های غیرهوشمند	امکان اظهار نظر در مورد شکل، نوع و بزرگی ترک بسیار حساس برای آزمایش ترک‌های سطحی چندمنظوره و انعطاف‌پذیر	نیازمند تجهیزات بسیار گران‌قیمت الزام معلوم بودن نوع آسیب و جهت آن الزام در دسترس بودن محدوده آزمایش نیازمند تجربه
روش‌های تشخیص و طبقه‌بندی ترک	آزمایش چکش اشمیت [۱۵] ساده سریع	نیازمند تجهیزات خاص و نیروی متخصص الزام در دسترس بودن محدوده آزمایش
روش‌های هوشمند	پردازش تصاویر لیزر [۱۸] امکان اظهار نظر در مورد شکل و نوع ترک عدم الزام در دسترس بودن محدوده آزمایش	نیازمند زمان و تجهیزات بسیار گران‌قیمت وابستگی بالا به تصاویر آموزش
روش‌های هوشمند	پردازش تصاویر فراصوت [۱۷] امکان اظهار نظر در مورد شکل و نوع ترک عدم الزام در دسترس بودن محدوده آزمایش	نیازمند زمان و تجهیزات بسیار گران‌قیمت وابستگی بالا به تصاویر آموزش
روش‌های هوشمند	پردازش تصاویر دیجیتال امکان اظهار نظر در مورد شکل و نوع ترک عدم الزام در دسترس بودن محدوده آزمایش	نیازمند زمان و تجهیزات بسیار گران‌قیمت وابستگی بالا به تصاویر آموزش

و ترک‌های واقعی، به سختی قابل تشخیص است. برای طبقه‌بندی مؤثر و به منظور تولید یک مدل طبقه‌بندی قوی نیاز به استخراج ویژگی‌های پیشرفته از تصاویر سطوح ترک‌ها در سازه‌های بتنی است. در دهه اخیر یادگیری عمیق^۱ که دسته‌ای از الگوریتم‌های یادگیری ماشین و هوش مصنوعی است و تلاش می‌کند مفاهیم انتزاعی سطح بالا را با استفاده از یادگیری در سطوح و لایه‌های مختلف مدل کند، به عنوان روشی قدرتمند در موضوعات تشخیص و طبقه‌بندی معرفی شده است [۱۳]. ایده یادگیری عمیق با الهام از ساختار طبیعی مغز انسان و به کمک امکانات و فن‌آوری‌های جدید توانسته است در بسیاری از حوزه‌های مربوط به هوش مصنوعی و یادگیری ماشین موفقیت‌های چشم‌گیری را کسب کند. از جمله مزایای یادگیری عمیق می‌توان به یادگیری خودکار و چندلایه ویژگی‌ها، دقت بالا در نتایج، قدرت تعمیم بالا و شناسایی داده‌های جدید، پشتیبانی گسترده سخت‌افزاری و نرم‌افزاری اشاره کرد [۱۴].

تشخیص ترک‌های واقعی از تصاویر سطحی سازه‌های بتنی فرآیندی مهم در تشخیص و طبقه‌بندی ترک‌ها محسوب می‌شود. امروزه یادگیری ماشین به عنوان ابزاری ترکیبی و نوآورانه در برنامه‌های مختلف مهندسی به خصوص شناسایی ترک‌ها در سازه‌های بتنی شناخته شده است [۱۱، ۱۲]. روش‌های یادگیری ماشین بطور معمول شامل شناسایی ویژگی‌های متمایز کننده از تصاویر آموزش است که منجر به ایجاد یک مدل طبقه‌بندی می‌شود. سپس مدل طبقه‌بندی آموزش دیده بر روی تصاویر جدید (تصاویر آزمایش) اعمال می‌شود تا در آن‌ها ترک‌های سطحی شناسایی شوند. معمولاً الگوهای هندسی (مانند تراکم و تعداد پیکسل‌ها در هر گروه پیکسلی) و خصوصیات آماری شدت پیکسل‌ها (مانند میانگین و انحراف معیار) به عنوان ویژگی‌هایی جهت تمایز تصاویر حاوی ترک و تصاویر بدون ترک انتخاب می‌شوند که منجر به تولید یک مدل طبقه‌بندی می‌شوند. قابل ذکر است که در اکثر این روش‌ها تمایز میان خطوط شبیه به ترک (که دارای شکل هندسی و رنگ‌های مشابه با ترک‌های واقعی هستند)

تصاویر ترک به منظور طبقه‌بندی در ۵ دسته مختلف، میانگین صحت ۹۲ درصد را در پی داشت. مطالعه‌ای دیگر در سال ۲۰۰۲ ابتدا با تبدیل تصاویر ترک به تصاویر باینری و تعیین دو حد آستانه برای تشخیص لبه، با پیاده‌سازی الگوریتم ماشین بردار پشتیبانی و آنالیز شدت توانست تصاویر ترک را در سه دسته با صحت میانگین ۸۶/۴ درصد طبقه‌بندی کند [۲۰]. در ادامه و در سال ۲۰۱۱ یک سیستم تشخیص و طبقه‌بندی خودکار بر اساس شبکه‌های عصبی معرفی شد که توانست با آنالیز مناسب تصاویر سطوح بتنی، ترک‌های موجود در آن‌ها را به دو دسته تصاویر ترک و تصاویر بدون ترک با میانگین صحت ۹۱ درصد طبقه‌بندی کند [۲۱]. همچنین دو الگوریتم هوشمند تشخیص ترک (تشخیص لبه و تنظیم آستانه‌ها، یادگیری عمیق و شبکه‌های عصبی) در مطالعه‌ای در سال ۲۰۱۸ با یکدیگر مقایسه شدند [۲۲]. در مطالعه مذکور طبقه‌بندی تصاویر به دو دسته تصاویر دارای ترک و تصاویر بدون ترک توسط دو الگوریتم تشخیص لبه و یادگیری عمیق انجام شد که به ترتیب صحتی معادل ۷۹/۹ و ۹۲/۰۸ درصد در پی داشتند. خلاصه‌ای از الگوریتم‌های استفاده شده برای طبقه‌بندی ترک‌ها در تصاویر سطحی سازه‌های بتنی در جدول ۲ مشاهده می‌گردد.

با توجه به بررسی مقالات و مطالعات پیشین در زمینه شناسایی و طبقه‌بندی ترک‌ها این نکته دریافت می‌شود که اگرچه شناسایی ترک‌ها در سازه‌های بتنی از لحاظ مهندسی و نگهداری زیرساخت‌ها از اهمیت بالایی برخوردار است، اما تشخیص نوع ترک‌ها نیز به نوبه خود می‌تواند مهم و ضروری باشد. این امر بدون درک درست از آسیب‌ها و نارسایی‌های موجود در ترک‌ها امکان‌پذیر نیست. یکی از آسیب‌هایی که شناسایی آن می‌تواند از بروز خسارات احتمالی آتی در سازه‌های بتنی جلوگیری کند، چندشاخگی در ترک‌هاست. در قسمت‌هایی از سازه‌های بتنی که دارای نقص سازه هستند، امکان تشکیل ترک‌های کششی وجود دارد. رشد ترک در امتداد محل نقص سازه امکان تغییر جهت را دارد که این تغییر زاویه در مکانیک شکست الاستیک خطی خیلی مهم و قابل بررسی جهت وضعیت سازه و دلایل ایجاد ترک است. در صورتی که در محل تغییر جهت، ترک به دو یا چند ترک جدید انشعاب یابد، این نقطه با نام چندشاخگی در ترک نام‌گذاری می‌شود [۲۳]. به بیان دیگر، در صورت بالا بودن سطح شدت ایجاد

در حالت کلی روش‌های تشخیص و طبقه‌بندی ترک در سازه‌های بتنی را می‌توان به دو دسته هوشمند و غیرهوشمند تقسیم کرد. در روش‌های غیرهوشمند مانند چکش اشمیت [۱۵] و دستگاه‌های تولید امواج فراصوت [۱۶]، نیروی متخصص نتایج حاصل از آزمایش بر روی نمونه بتن از منطقه تحت بررسی را ثبت و بررسی می‌کند. در روش‌های هوشمند، الگوریتم‌های پردازش تصویر و یادگیری ماشین بر روی انواع مجموعه داده تصاویر دیجیتال (تصاویر دیجیتالی، تصاویر فراصوت [۱۷] و تصاویر لیزر [۱۸]) اعمال می‌شود. این روش‌ها مزایایی از جمله عدم نیاز به نیروی متخصص بتن، عدم الزام در دسترس بودن محدوده مورد آزمایش و امکان دسترسی به دقت‌های بالاتر نسبت به روش‌های غیرهوشمند دارند. همچنین وقت‌گیر بودن جمع‌آوری تصویر در این روش‌ها و الزام وجود تجهیزات خاص نیز می‌تواند از معایب آن‌ها به شمار رود. اکثر الگوریتم‌های پردازش تصویر موجود در روش‌های هوشمند بر اساس یکی از روش‌های باینری‌سازی، تشخیص لبه و مورفولوژی ریاضی است. باینری‌سازی تصویر که منجر به تبدیل پیکسل‌های تصویر خاکستری به پیکسل‌های سیاه یا سفید می‌شود، می‌تواند برای تشخیص ترک استفاده شود. به این دلیل که ترک‌ها در تصاویر سطحی بتن به صورت یک بخش تیره دیده و در حالت کلی در تصاویر باینری شده به صورت پیکسل‌های سیاه تبدیل می‌شوند، درحالی‌که زمینه‌های نسبتاً روشن‌تر به صورت پیکسل‌های سفید تبدیل می‌گردند. در تشخیص لبه، ترک‌های بتنی با محلی‌سازی مرزهای پیکسل‌های ترک شناسایی می‌شوند. همچنین، مورفولوژی ریاضی به عنوان یک فرآیند اضافی برای اصلاح شکل‌های ترک‌ها و در نتیجه بهبود عملکرد شناسایی آن‌ها استفاده می‌شود. البته در میان این روش اصلی، برخی از مطالعات نیز به بررسی انواع الگوریتم‌های پردازش تصویر استفاده شده برای تشخیص ترک در سازه‌های بتنی پرداخته‌اند. جدول ۱ خلاصه‌ای از مزایا و معایب روش‌های هوشمند و غیرهوشمند تشخیص و طبقه‌بندی ترک در سازه‌های بتنی را نشان می‌دهد.

تشخیص و طبقه‌بندی ترک با استفاده از روش‌های هوشمند از دهه آخر قرن نوزدهم به بعد محبوبیت یافت. بطوری‌که در سال ۱۹۹۳ میلادی روشی برای طبقه‌بندی خودکار تصاویر ترک توسط شبکه عصبی مصنوعی معرفی شد [۱۹]. این روش تلفیق مدل شبکه عصبی مصنوعی با تکنیک‌های معمول پردازش تصویر بود که اعمال آن روی

جدول ۲. خلاصه‌ای از الگوریتم‌های استفاده شده در طبقه‌بندی ترک در سازه‌های بتنی

Table 2. The summary of the used algorithms in the crack classification in concrete structures

روش	سال	تعداد دسته	نام دسته‌ها	صحت (درصد)
ماشین بردار پشتیبانی [۱۹]	۱۹۹۳	۵	بدون ترک	۹۲
			ترک عرضی	
			ترک طولی	
			ترک مورب ترک مرکب	
ماشین بردار پشتیبانی [۲۰]	۲۰۰۲	۳	بدون ترک	۸۶/۴
			ترک ترکیبی	
شبکه‌های عصبی مصنوعی [۲۱]	۲۰۱۱	۲	بدون ترک	۹۱
			ترک	
یادگیری عمیق [۲۲]	۲۰۱۸	۲	بدون ترک ترک	۹۲

چندشاخگی در ترک نیز لحاظ شده است؛ ولی به طور مشخص به طبقه‌بندی چندشاخگی در ترک به عنوان یک نوع و آسیب خاص در ترک نپرداخته‌اند [۲۶]. لذا در این پژوهش به طور مشخص و در یک سیستم طبقه‌بندی، چندشاخگی در ترک در سازه‌های بتنی شناسایی و طبقه‌بندی می‌گردد.

همچنین دستاوردهای این پژوهش نیز عبارتند از:

- ۱- دست‌یابی به صحت ۹۹/۳ درصد که در طبقه‌بندی ترک‌ها و در مقایسه با سایر روش‌ها، صحت بالایی به شمار می‌رود.
- ۲- زمان اجرای نسبتاً پایین معماری پیشنهادی (۷۶ دقیقه) در مقایسه با سایر معماری‌های معتبر در یادگیری عمیق در یک بستر سخت‌افزاری یکسان.


به این ترتیب و در ادامه بخش ۲ ساختار پیشنهادی شامل جمع‌آوری داده، پیش‌پردازش، طراحی شبکه کانولوشنی عمیق معرفی می‌شود. بخش ۳ به بررسی نتایج و بحث می‌پردازد. سپس، آنالیز حساسیت در بخش ۴ و نتیجه‌گیری در بخش ۵ صورت می‌گیرد.

۲- ساختار پیشنهادی

روش پیشنهادی این مقاله برای شناسایی و طبقه‌بندی ترک‌ها در سازه‌های بتنی مطابق بلوک دیاگرام شکل ۱ به این صورت است

ترک‌ها، آن‌ها می‌توانند شکسته شده و تبدیل به دو یا چند ترک شوند که طول ترک‌های جدید بسته به میزان شدت، متغیر است. لازم به ذکر است که در اینجا منظور از سطح شدت، سطح شدت حرکت زمین است که توسط شتاب طیفی الاستیک مشخص می‌گردد. بنابراین شناسایی چندشاخگی در ترک‌های موجود در سازه‌های بتنی به دلیل آنکه می‌تواند منجر به شناسایی سطوح شدت بالا شود، از اهمیت بسزایی برخوردار است. به همین منظور در این پژوهش یک روش هوشمند بر اساس یادگیری عمیق برای شناسایی و طبقه‌بندی ترک‌ها در سازه‌های بتنی ارائه می‌شود. این روش هوشمند که مبنای آن شبکه‌های عصبی کانولوشنی است، منجر به طبقه‌بندی ترک‌ها به سه دسته بدون ترک، ترک ساده و چندشاخگی در ترک می‌شود. از همین رو، نوآوری این پژوهش را می‌توان در دو مورد ذکر کرد:

- ۱- معماری پیشنهادی این مقاله ترکیبی از لایه‌های عمیق مختلف است که منجر به یک ساختار منحصربه‌فرد شده است.
- ۲- با وجود اینکه برخی از پژوهش‌های پیشین به بررسی، تشخیص و طبقه‌بندی ترک در سازه‌های بتنی پرداخته‌اند [۶، ۲۴-۲۶]، اما تشخیص چندشاخگی در ترک‌ها مورد توجه کمتری قرار گرفته است [۲۳]. همچنین در برخی از مقالاتی که هدف آنها صرفاً تشخیص ترک (و نه طبقه‌بندی چند نوع خاص از آن) بوده است،



شکل ۱. بلوک دیاگرام روش پیشنهادی این مقاله برای طبقه‌بندی تصاویر مستخرج از سازه‌های بتنی

Fig. 1. The block diagram of proposed method of this paper for classification of extracted image from concrete structures

جدول ۳. خلاصه‌ای از مهم‌ترین مشخصات فنی پهپاد Phantom4 Pro

Table 3. The summary of the most important technical specifications of the Phantom^۴ Pro


ابعاد	۶/۴×۱۶/۸×۱۸/۴ سانتی‌متر
وزن	۱۳۸۸ گرم
موتور	براش
سرعت	۷۲ کیلومتر بر ساعت
زمان پرواز	بیش از ۳۰ دقیقه
باتری	لیتیومی چهار سلولی با ظرفیت ۵۸۷۰ میلی‌آمپر
برد مسافتی ارتفاع	۵۰۰ متر
دوربین	۲۰ مگا پیکسل Full HD
حافظه ذخیره‌سازی	۱۲۸ گیگابایت
گیمبال	سه محوره

ترک در سازه‌های بتنی، استفاده از پردازش تصاویر دیجیتالی است که نسبت به سایر روش‌ها دارای دقت بالاتر است. برای این منظور می‌بایست تصاویر دیجیتالی از سازه بتنی موردنظر تهیه گردد. روش‌های معمول تهیه تصویر (مانند عکاسی با تلفن همراه، دوربین‌های دیجیتالی) که توسط نیروی انسانی گرفته می‌شود، نمی‌توانند کل سازه بتنی به‌خصوص بخش‌های دارای ارتفاع را پوشش دهند. همچنین وجود عوامل انسانی نیز می‌تواند منجر به بروز اشتباهات سهوی گردد. به همین دلیل در این پژوهش به جای استفاده از نیروی انسانی، از یک ربات پرنده Phantom4 Pro که خلاصه‌ای از مهم‌ترین مشخصات فنی آن در جدول ۳ ذکر شده است، استفاده شد [۲۷]. در این پژوهش سازه‌های بتنی اعم از برج‌ها، ساختمان‌ها و سوله‌های صنعتی با بتن از جنس سیمان نوع ۲ و عیار ۲۵۰ تا ۳۰۰ برای تهیه اطلاعات و جمع‌آوری داده در نظر گرفته شدند. اطلاعات تهیه شده توسط این ربات پرنده به صورت تصاویر و ویدیوهای رنگی با کیفیت 4K

که ابتدا در مرحله جمع‌آوری داده، ویدیویی از سازه بتنی موردنظر توسط یک پهپاد (پرنده هدایت پذیر از دور) تهیه می‌گردد. سپس ویدیوی ذخیره شده به یک تصویر سراسرنما^۱ از سازه بتنی تبدیل می‌شود. در مرحله بعد تصویر سراسرنما به تصاویر با ابعاد کوچک و با رزولوشن مطلوب تجزیه می‌شود. پس از مرحله جمع‌آوری داده، پیش‌پردازشی جهت حذف نویزهای احتمالی و تنظیم شدت رنگ تصاویر صورت می‌گیرد. در انتها با طراحی یک شبکه یادگیری عمیق، تصاویر مستخرج از سازه‌های بتنی به سه دسته تصاویر بدون ترک، تصاویر دارای ترک و تصاویر دارای چندشاخگی در ترک طبقه‌بندی می‌شوند.

۱-۲- جمع‌آوری داده

همان‌گونه که پیشتر ذکر شد یکی از راه‌های مدرن برای تشخیص



شکل ۲. سخت‌افزار و پهپاد مورد استفاده در این پژوهش

Fig. 2. The used hardware and quad copter in this study

تصویر (دارای ترک، بدون ترک و ترک دارای چندشاخگی)، ۴۰۰۰ تصویر برای هر دسته انتخاب شد و ۱۲۰۰۰ تصویر برای مرحله بعد آماده شدند. شکل ۳ (ج) خروجی مرحله پیش‌پردازش و همین‌طور تصاویر کوچک ایجاد شده از شکل ۳ (ب) را نشان می‌دهد. همان‌طور که از این شکل مشاهده می‌شود در یک تصویر سراسرنما ممکن است ترک‌های مختلفی وجود داشته باشد که هدف این مقاله نیز شناسایی و طبقه‌بندی آن‌هاست.

۳-۲- طراحی شبکه عصبی کانولوشنی

۳-۲-۱- اصول عملکرد شبکه‌های عصبی کانولوشنی

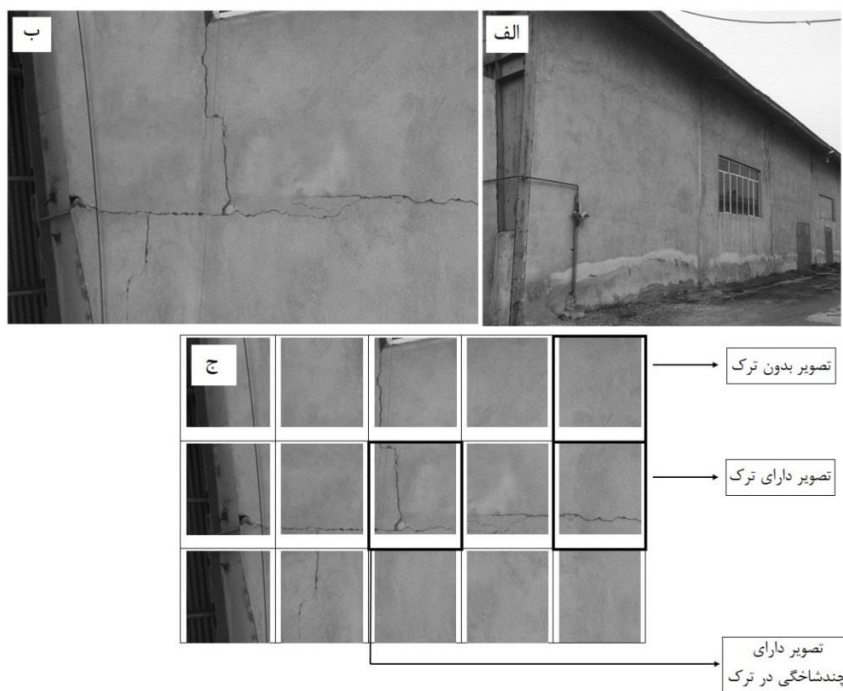
شبکه‌های عصبی مصنوعی که از شیوه عملکرد سیستم عصبی زیستی الهام گرفته‌اند، نوع خاصی از مدل‌های یادگیری برای پردازش اطلاعات هستند. ساده‌ترین نوع شبکه‌های عصبی مصنوعی، شبکه‌های عصبی پیش‌خور هستند که جهت حرکت اطلاعات در آن‌ها فقط رو به جلو است [۲۹]. مجموعه‌ای از شبکه‌های عصبی مصنوعی پیش‌خور که حداقل شامل سه لایه (لایه ورودی، لایه پنهان و لایه خروجی) باشند و از الگوریتم پس‌انتشار برای آموزش لایه‌ها استفاده کنند، تشکیل شبکه‌های پرسپترون چندلایه می‌دهند [۲۹]. در این مقاله به منظور طبقه‌بندی ترک در سازه‌های بتنی، از شبکه‌های عصبی عمیق استفاده می‌شود. شبکه‌های عصبی کانولوشنی^۱ (CNN) نوع خاصی از شبکه‌های عصبی عمیق پیش‌خور هستند که با اعمال تغییراتی بر شبکه‌های کلاسیک پرسپترون چندلایه طراحی شده‌اند و انتخابی مناسب برای پردازش داده‌های دوبعدی مانند تصاویر هستند [۳۰].

ذخیره می‌شوند. به منظور پوشش کامل سازه‌های بتنی، ویدیویی از تمام قسمت‌های سازه‌های بتنی مختلف تهیه شد. سپس این ویدیوها به تصاویر رنگی سراسرنما تبدیل شدند. شکل ۲ تصویری از مرحله جمع‌آوری داده شامل سخت‌افزار و پهپاد مورد استفاده را نشان می‌دهد. همچنین سخت‌افزار مورد استفاده در این مطالعه یک سیستم کامپیوتری با پردازنده Quad Intel(R) Core(TM)2 Q9400 و حافظه داخلی ۸ گیگابایت است

۲-۲- پیش‌پردازش

تصاویر سراسرنمای حاصل از مرحله قبل، رنگی و دارای نویزهای است که در اثر تغییرات شدت نور محیط و لرزش احتمالی به وجود آمده‌اند. البته این نویزها در فیلم‌برداری حین پرواز پهپاد شایع هستند و موجب تغییر رنگ و محو شدن بعضی از قسمت‌های سطح بتن می‌شوند. در این مرحله ابتدا تصاویر سراسرنمای رنگی به تصاویر خاکستری تبدیل می‌شوند و سپس با استفاده از متعادل‌سازی هیستوگرام، تصویر بهبود می‌یابد [۲۸]. در نهایت و پس از متعادل‌سازی هیستوگرام در تصاویر سراسرنما، هر کدام از آن‌ها به تصاویر کوچک با ابعاد 330×330 تقسیم می‌شوند. علت انتخاب عدد ۳۳۰ در تقسیم‌بندی تصاویر سراسرنما، ویژگی‌های تصویربرداری از سازه مانند فاصله دوربین از سطح سازه و انتخاب نزدیک‌ترین رزولوشن برای حداقل کردن اضافات تصاویر سراسرنما بوده است. با این شیوه ۹۰۰ تصویر سراسرنما ایجاد شد که هر کدام از آن‌ها به ۱۵ تصویر کوچک تقسیم شدند. در واقع تعداد تصاویر کوچک به ۱۳۵۰۰ رسید که از بین آن‌ها به منظور ایجاد تراز بین سه دسته

1 Convolutional Neural Network



شکل ۳. نمونه‌ای از تصاویر مورد استفاده در این پژوهش، (الف) یک سازه نمونه، (ب) تصویر اولیه سراسرنمای خروجی از یک قسمت سازه نمونه، (ج) تصاویر کوچک ایجاد شده از تصویر پیش‌پردازش شده قسمت (ب)

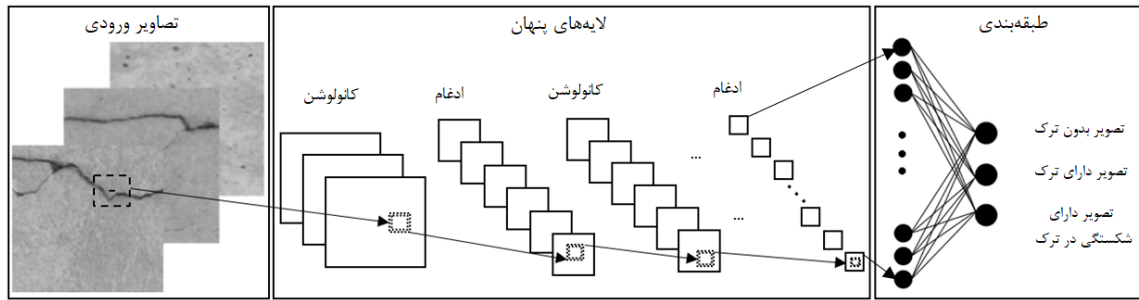
Fig. 3. The sample of used images in this study, (a) the sample structure, (b) the preliminary extracted panorama image from the sample structure, (c) The created small images from the pre-processed image of part (b)

هر فیلتر در یک صفحه با نام نگاشت ویژگی ذخیره می‌شود. لایه‌های کانولوشن وظیفه استخراج ویژگی‌ها از ورودی شبکه را به عهده دارند و ویژگی اصلی آن‌ها استخراج ویژگی‌های محلی و پیوستگی بین این ویژگی‌هاست [۳۲]. لایه‌های ادغام یا جمع‌آوری نیز با هدف کاهش تعداد پارامترها (کاهش ابعاد مسأله) و تجمیع ویژگی‌های مشترک در لایه‌های پنهان استفاده می‌شوند. ادغام بیشینه و میانگین از مهم‌ترین روش‌های ادغام هستند که به ترتیب با انتخاب بیشینه و میانگین مقادیر در یک همسایگی، منجر به کاهش اندازه نگاشت‌های ویژگی و در عین حال، ثابت ماندن تعداد آن‌ها می‌شوند [۳۳]. ذکر این نکته ضروری است که در لایه‌های کانولوشن و ادغام، اندازه و گام فیلتر و همچنین نوع لایه‌سازی^۱ در اندازه نگاشت ویژگی تأثیرگذار است. لایه‌سازی به معنای اضافه کردن لایه‌های اضافی با مقدار صفر دور تصویر ورودی جهت کانولوشن با فیلتر است که می‌تواند به سه روش لایه‌سازی صحیح^۲، لایه‌سازی یکسان^۳ و لایه‌سازی کامل^۴ انجام

ساختار کلی طبقه‌بندی ترک در تصاویر سازه‌های بتنی با استفاده از شبکه‌های عصبی کانولوشنی که از سه بخش کلی تصاویر ورودی، لایه‌های پنهان و طبقه‌بندی تشکیل می‌شود، در شکل ۴ نشان داده شده است [۳۱]. طبق این شکل تصاویر سازه‌های بتنی به عنوان تصاویر ورودی در نظر گرفته و به لایه‌های پنهان فرستاده می‌شوند. خروجی این لایه‌ها به عنوان ورودی قسمت طبقه‌بندی که حاوی لایه‌های تماماً متصل هستند، در نظر گرفته می‌شود و خروجی نهایی شبکه منجر به طبقه‌بندی تصاویر سازه‌های بتنی به سه دسته تصاویر بدون ترک، تصاویر دارای ترک و تصاویر دارای چندشاخگی در ترک می‌شود.

لایه‌های پنهان از دو نوع لایه اصلی کانولوشن و ادغام تشکیل می‌شوند که وظیفه انتخاب و استخراج خودکار ویژگی‌ها را بر عهده دارند. در لایه‌های کانولوشن، فیلترهایی که عمقی برابر با عمق تصویر ورودی دارند، با تصویر ورودی کانولوشن می‌شوند. هرکدام از این فیلترها همانند وزن‌های ماتریسی قابل آموزش هستند و در طول آموزش شبکه مدام بروزرسانی می‌شوند. کانولوشن ایجاد شده به ازای

1 Padding
2 Valid Padding
3 Same Padding
4 Full Padding



شکل ۴. یک نمونه از ساختار شبکه‌های عصبی کانولوشنی
Fig. 4. A sample of convolutional neural networks structure


همانند شبکه‌های عصبی مصنوعی سنتی عمل می‌کنند. به این صورت که این لایه‌ها نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه می‌دهند. شکل ۵ و معادله (۲) جزئیات یک نورون نمونه در شبکه‌های عصبی سنتی را نشان می‌دهند [۳۵]:

$$y_k = f\left(\sum_{i=1}^n x_i \omega_{ki} + b_k\right) \quad (2)$$

بنابراین در حالت کلی در هر شبکه عصبی کانولوشنی تعدادی از لایه‌های ادغام و کانولوشن به همراه توابع غیرخطی موسوم به تابع فعال‌سازی نظیر واحد خطی اصلاح کننده (Relu) [۳۶]، در کنار تعدادی لایه تماماً متصل، کار استخراج ویژگی و طبقه‌بندی را انجام می‌دهند. تابع Relu بر اساس معادله (۳) بدست می‌آید [۳۶]:

$$Relu(x) = \max(0, x) \quad (3)$$

در شبکه‌های عصبی کانولوشنی دو مرحله آموزش وجود دارد: مرحله روبه‌جلو^۲ و مرحله پس انتشار^۳ یا رو به عقب. در مرحله اول پس از اعمال تصویر ورودی به شبکه، ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و نهایتاً اعمال عملیات کانولوشن در هر لایه صورت می‌گیرد و خروجی شبکه محاسبه می‌شود. به منظور تنظیم وزن‌ها و پارامترهای شبکه (آموزش شبکه) از نتیجه خروجی با استفاده از یک تابع خطا جهت محاسبه میزان خطای شبکه استفاده می‌گردد. در این مقاله از تابع Softmax به عنوان تابع هزینه استفاده شده است و وزن‌ها و پارامترهای شبکه طوری انتخاب می‌شوند که این تابع کمینه گردد [۳۷]. این تابع هزینه توسط معادله (۴) محاسبه می‌گردد [۳۷]:



شکل ۵. یک نورون در شبکه‌های عصبی سنتی
Fig. 5. A neuron in traditional neural networks


شود [۳۴]. در حالت کلی اعمال K فیلتر به اندازه $F \times F$ به یک تصویر به اندازه $I \times I \times C$ منتج به یک نگاشت ویژگی خروجی به اندازه $O \times O \times K$ می‌شود که O از معادله (۱) به دست می‌آید [۳۴]:

$$O = \frac{I - F + P_{start} + P_{end}}{S} + 1 \quad (1)$$

که P_{start} به ترتیب میزان حاشیه صفر از سمت چپ و بالا، P_{end} میزان حاشیه صفر از سمت راست و پایین و S گام حرکت فیلتر بر روی تصویر است.

در بخش انتهایی لایه‌های پنهان در شبکه‌های کانولوشن تعداد زیادی از صفحات ویژگی با ابعاد بسیار کوچک وجود دارند که به عنوان ورودی‌های لایه‌های تماماً متصل در قسمت طبقه‌بندی به کار می‌روند. خروجی این لایه‌ها برداری یک‌بعدی است، در صورتی که ورودی آن‌ها نگاشت‌های ویژگی دوبعدی است. لایه‌های تماماً متصل که حاوی بخش زیادی از پارامترهای یک شبکه کانولوشنی هستند،

1 Rectified Linear Unit
 2 Feed Forward
 3 Backpropagation



شکل ۶. معماری پیشنهادی شبکه های کانولوشنی مورد استفاده در این پژوهش
 Fig. 6. The proposed architecture of used convolutional networks in this study

جدول ۴. جزئیات لایه ها در معماری پیشنهادی

Table 4. The details of layers in the proposed architecture

توضیحات	نوع لایه	بلوک
۸ فیلتر ۳×۳ با گام ۱ و لایه سازی صحیح	کانولوشن	بلوک ۱
اندازه ۴×۴ با گام ۲	ادغام بیشینه	
۱۶ فیلتر ۵×۵ با گام ۲ و لایه سازی صحیح	کانولوشن	بلوک ۲
اندازه ۴×۴ با گام ۲	ادغام بیشینه	
۳۲ فیلتر ۵×۵ با گام ۲ و لایه سازی صحیح	کانولوشن	بلوک ۳
اندازه ۲×۲ با گام ۲	ادغام بیشینه	
نورون هایی با ابعاد ۵۰×۳	تماماً متصل	بلوک ۴

گاهی در شبکه های عصبی کانولوشنی، نرمال سازی بسته ها^۲ مورد استفاده قرار می گیرد. هنگام آموزش یک شبکه عصبی، ورودی ها به بسته های کوچک با اندازه یکسان تقسیم و به مدل ارسال می شوند. این کار باعث می شود مدل نسبت به مدلی که تمام اطلاعات را یکجا دریافت کرده است، جامع تر باشد. اگر $B = \{x_{1...m}\}$ یک بسته حاوی ورودی های x_1 تا x_m باشد، آنگاه طبق معادلات (۵) تا (۸)، y_i خروجی نرمال شده است [۳۸]:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (5)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (6)$$


$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (7)$$

$$L_i = -\log\left(\frac{e^{s_{y_i}}}{\sum_j e^{s_j}}\right) \quad (4)$$

با توجه به فرمول (۴) اگر به تصویر x_i برچسب y_i داده شود و تابع $s = f(x_i, w)$ امتیازهای هر طبقه را با وزن w محاسبه کند، آن گاه $s_j = f(x_i, w)_j$ امتیاز طبقه j را نشان می دهد. در نهایت L_i مقدار تابع هزینه مربوط به i امین تصویر است. سپس بر اساس میزان خطای محاسبه شده، مرحله پس انتشار شروع می شود. در این مرحله گرادینان هر وزن و پارامتر با توجه به قاعده زنجیری^۱ محاسبه می شود و تمامی وزن ها و پارامترها با توجه به تأثیری که بر خطای ایجاد شده در شبکه دارند، تغییر پیدا می کنند و بروزرسانی می شوند. بعد از بروزرسانی وزن ها و پارامترها مرحله روبه جلو شروع می شود. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه پایان می یابد.

2 Batch

1 Chain Rule



شکل ۷. نتیجه اعمال معماری پیشنهادی روی مجموعه تصاویر آموزش، (الف) تغییرات درصد اعتبارسنجی، (ب) تغییرات مقدار تابع هزینه
Fig. 7. The result of applying the proposed architecture in the training image set, (a) validation percentage changes, (b) cost function value changes

ویژگی، هنگام نمونه برداری کاهشی از لایه‌های ادغام استفاده می‌شود. در مورد بهتر بودن هر کدام از تکنیک‌های ادغام بیشینه و میانگین نیز بحث زیادی در میان محققان وجود دارد. در حالت کلی ادغام بیشینه به دلیل حفظ بهتر ویژگی‌های شناسایی شده در لایه‌های ابتدایی نسبت به ادغام میانگین، می‌تواند باعث همگرایی سریع‌تر و تعمیم بهتر گردد. در این میان نیز الگوریتم‌های مختلف منظم‌سازی^۲ مانند حذف تصادفی^۳، افزایش داده^۴ و غیره می‌توانند از بروز بیش‌برازش^۵ جلوگیری کنند. این الگوریتم‌ها در معماری‌هایی نظیر AlexNet و ZF مشاهده می‌شود. با این وجود، رسیدن به یک معماری مطلوب بر مبنای یک فرمول واحد امکان‌پذیر نیست و معماری‌های CNN بر اساس یک سری از اصول اولیه و مبتنی بر سعی و خطا بدست می‌آیند.

شکل ۶ و جدول ۴ به ترتیب معماری پیشنهادی این پژوهش و جزئیات هر لایه از آن را نشان می‌دهد. در این معماری در سراسر شبکه برای نگهداری بهترین ویژگی‌ها از ادغام بیشینه استفاده شد. همچنین در بلوک‌های اول و دوم پس از لایه کانولوشن، نرمال‌سازی، بسته‌ها قرار گرفته است. در سه بلوک ابتدایی معماری پیشنهادی،

$$y_i = \gamma \hat{x}_i + \beta \quad (۸)$$

که μ_B و σ_B به ترتیب میانگین و واریانس B, \hat{x}_i نرمال شده ورودی $x_i, (i=1, \dots, m)$ تغییر مقیاس و منتقل شده \hat{x}_i و در حالت کلی خروجی نرمال شده است [۳۸]. همچنین β و γ پارامترهای قابل یادگیری هستند [۳۸].

۲-۳-۲- ساختار CNN پیشنهادی

عملیات کانولوشن ایده اصلی تشکیل‌دهنده شبکه‌های CNN است و شیوه استفاده از آن یک عامل تعیین‌کننده بزرگ برای عملکرد شبکه است. اینکه ابعاد لایه‌های کانولوشن چه اندازه باشد بستگی به نوع داده، محدودیت‌های سخت‌افزاری، برخط بودن یا نبودن عملیات و غیره دارد. با این حال کانولوشن‌های 3×3 که به طور متوالی پشت سرهم قرار می‌گیرند، می‌توانند به همان میدان تأثیر^۱ که کانولوشن‌های بزرگ‌تر ارائه می‌دهند، دست یابند. ساختاری که در معماری‌های مشتق شده CNN مانند VGGNet و ResNet دیده می‌شود. هر چند که ممکن است این ساختار نیاز به سخت‌افزار قوی و زمان بالای محاسبات داشته باشد. بعد از هر لایه کانولوشن و به منظور جمع‌بندی

2 Regularization
 3 Drop Out
 4 Data Augmentation
 5 Overfitting

1 Receptive Field



شکل ۸. خروجی لایه‌های مختلف معماری پیشنهادی روی یک تصویر نمونه (الف) یک تصویر نمونه دارای چندشاخگی در ترک، (ب) بهترین خروجی در بلوک اول، (ج) بهترین خروجی در بلوک دوم، (د) بهترین خروجی در بلوک سوم

Fig. 8. The output of different layers of proposed architecture in the sample image, (a) the sample of bifurcated crack image, (b) the best of output in block 1, (c) the best of output in block 2, (d) the best of output in block 3

درصد از مجموعه داده‌های آموزش (۱۸۰۰ تصویر) برای اعتبارسنجی^۳ در نظر گرفته شده است. پس از طراحی معماری شبکه عصبی عمیق با CNN، هر تصویر ۳۳۰×۳۳۰ با ۸ فیلتر ۳×۳ با مقاردهی اولیه گاوسی کانولوشن می‌شود که حاصل آن ۸ صفحه ویژگی با ابعاد ۳۲۸×۳۲۸ است. بعد از این مرحله، تابع فعال‌ساز و پس از آن ادغام بیشینه با اندازه ۴×۴ در این صفحات ویژگی اعمال می‌شود که خروجی آن ۸ صفحه ویژگی با ابعاد ۱۶۳×۱۶۳ است. همان‌طور که مشخص است پس از اعمال لایه ادغام، ابعاد صفحات ویژگی کاهش پیدا کرده است. در مرحله بعد، هر کدام از این صفحات ویژگی از یک لایه کانولوشن با ۱۶ فیلتر ۵×۵ و یک لایه ادغام بیشینه با اندازه ۴×۴ عبور می‌کنند که منجر به ایجاد ۱۶ صفحه ویژگی با ابعاد ۳۹×۳۹ می‌گردد. سپس این صفحات ویژگی مطابق با شکل ۶ و جدول ۴ از دو لایه کانولوشن و یک لایه ادغام بیشینه عبور می‌کنند که منجر به ایجاد ۳۲ صفحات ویژگی با ابعاد ۷×۷ می‌شود. در این طراحی از دو لایه تماماً متصل استفاده شده است که لایه اول آن شامل ۵۰۰ نرون است. همچنین لایه بعدی نیز به دلیل وجود سه دسته تصویر خروجی (تصاویر بدون ترک، تصاویر دارای ترک و تصاویر دارای ترک چندشاخه) دارای سه نرون می‌باشد. طی کردن ورودی در کل شبکه در یک مسیر رفت و برگشت به یک دوره^۴ اشاره دارد. تعداد دوره‌هایی که برای یادگیری شبکه استفاده می‌شود در هر شبکه متفاوت است. درست است که داشتن دوره‌های بیشتر منجر به صحت بیشتر در شبکه می‌شود، ولی زمان یادگیری شبکه را هم افزایش می‌دهد. به علاوه، باید توجه داشت که اگر تعداد دوره‌ها بیش از حد زیاد باشد، ممکن است منجر به بیش‌برازش شود. لازم به ذکر است که

تابع فعال‌ساز غیرخطی Relu وجود دارد. این تابع در کنار تسریع فرآیند همگرایی، به دلیل محاسبات ساده‌تر در مقایسه با توابعی مثل سیگموئید، حجم محاسبات لازم را نیز کاهش می‌دهد. در انتهای شبکه و در بلوک چهارم نیز از دو لایه تماماً متصل استفاده شده است. از آنجا که تعداد زیادی از پارامترها در دو لایه انتهایی تماماً متصل قرار دارند، در حین آموزش احتمال بیش‌برازش زیادتر می‌شود. به همین دلیل و برای جلوگیری از آن، در بین لایه‌های تماماً متصل از لایه حذف تصادفی برای کاهش پارامترها استفاده می‌شود. حذف تصادفی از جمله روش‌های منظم‌سازی است که در هر تکرار از آموزش، تعدادی از نرون‌ها را به صورت تصادفی از شبکه حذف می‌کند و در مرحله بعد، با وزن قبلی به شبکه بازمی‌گرداند. همچنین در لایه آخر نیز تابع Softmax به منظور طبقه‌بندی در نظر گرفته شده است.

۳- نتایج و بحث

همان‌گونه که پیش‌تر ذکر شد هدف از این مطالعه طبقه‌بندی ترک‌های موجود در تصاویر مستخرج از سازه‌های بتنی است. به همین منظور ابتدا پس از تبدیل ویدیوی ضبط شده از سازه‌های بتنی به تصاویر سراسرنما و متعادل‌سازی هیستوگرام آن‌ها، تعداد ۱۲۰۰۰ تصویر ۳۳۰×۳۳۰ شامل سه دسته تصاویر بدون ترک، تصاویر دارای ترک و تصاویر دارای چندشاخگی در ترک (هر دسته ۳۰۰۰ تصویر) ایجاد شدند. از این تعداد تصویر، تعداد ۹۰۰۰ تصویر (۷۵ درصد مجموعه داده) برای آموزش^۱ و ۳۰۰۰ تصویر (۲۵ درصد مجموعه داده) برای آزمایش^۲ به صورت تصادفی انتخاب شدند. همچنین ۲۰

3 Validation
4 Epoch

1 Train
2 Test

جدول ۵. ماتریس درهم‌ریختگی الگوریتم پیشنهادی

Table 5. The confusion matrix for the proposed algorithm

دسته واقعی	دسته پیش‌بینی شده		
	بدون ترک	ترک ساده	چندشاخگی در ترک
بدون ترک	۰/۹۹۳	۰/۰۰۶	۰/۰۰۱
ترک ساده	۰/۰۰۳	۰/۹۹۱	۰/۰۰۶
چندشاخگی در ترک	۰/۰۰۱	۰/۰۰۴	۰/۹۹۵

استفاده شد. همان‌طور که پیشتر ذکر شد، صحت به این معناست که مدل آموزش دیده تا چه اندازه خروجی را درست پیش‌بینی می‌کند. دقت نشان‌دهنده میزان اعتماد به خروجی طبقه‌بند و فراخوانی نیز کارایی طبقه‌بند را با توجه به تعداد رخداد یک طبقه خاص نشان می‌دهد. این معیارها عبارتند از [۳۹]:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$Pr = \frac{TP}{TP + FP} \quad (10)$$

$$Re = \frac{TP}{TP + FN} \quad (11)$$

که TP تعداد تصاویری است که به درستی توسط الگوریتم به یک طبقه انتساب یافته، TN تعداد تصاویری است که با وجود اینکه متعلق به یک طبقه نبوده‌اند به درستی در آن طبقه نیز پیش‌بینی نشدند، FN تعداد تصاویری است که با وجود اینکه متعلق به یک طبقه نبوده‌اند به سایر طبقه‌ها تعلق گرفته‌اند و در نهایت FP تعداد تصاویری است که با وجود اینکه متعلق به یک طبقه نبوده‌اند، ولی در آن طبقه پیش‌بینی شدند. Acc ، Pr و Re نیز به ترتیب صحت، دقت و فراخوانی را نشان می‌دهند. ماتریس درهم‌ریختگی^۴ نیز با تکیه بر این مفاهیم چگونگی عملکرد الگوریتم طبقه‌بندی را با توجه به مجموعه داده ورودی به تفکیک انواع طبقه‌های مسأله نمایش می‌دهد. ماتریس درهم‌ریختگی برای الگوریتم پیشنهادی این پژوهش در جدول ۵ نشان داده شده است. همان‌طور که از این جدول استنتاج می‌شود، الگوریتم پیشنهادی توانسته است در ۹۹/۵ درصد موارد وجود

در این پژوهش از ۲۰ دوره استفاده شد. در نهایت و پس از مرحله اعتبارسنجی یک مدل یادگیری عمیق، کارایی آن روی مجموعه داده‌های آزمایش ارزیابی می‌شود. در واقع هنگامی که یک شبکه عمیق آموزش می‌بیند و برازش می‌شود، این شبکه سعی می‌کند خروجی را روی داده‌های آزمایش هرچه دقیق‌تر پیش‌بینی کند که میزان درستی پیش‌بینی بدست آمده روی داده‌های آزمایش، درصد صحت^۱ را تشکیل می‌دهد. شکل ۷ تغییرات درصد اعتبارسنجی و تغییرات مقدار تابع هزینه را نشان می‌دهد که اعمال این شبکه روی داده‌های آزمایش درصد صحت ۹۹/۳ را به دنبال داشت که نشان از عملکرد مناسب معماری پیشنهادی است. به عنوان نمونه، شکل ۸ (الف) یک تصویر دارای چندشاخگی در ترک را نشان می‌دهد و قسمت‌های (ب)، (ج) و (د) این شکل نیز به ترتیب مربوط به بهترین خروجی لایه‌های کانولوشن در بلوک اول، دوم و سوم است. لازم به ذکر است که تصویر ورودی در طی مسیرش در لایه‌های کانولوشن و ادغام، دستخوش تبدیلات مختلفی می‌شود و صفحات و ویژگی موجود در لایه‌های انتهایی شبکه متفاوت با تصویر ورودی ارائه شده به شبکه است. در واقع یک سطح انتزاع به سطح دیگری تبدیل شده است و صفحات و ویژگی در شبکه‌های عصبی عمیق خصوصاً در لایه‌های بالاتر به صورت تصاویر با وضوح نسبتاً پایین دیده می‌شوند. به همین دلیل و برای پرهیز از نمایش تصاویر صفحات و ویژگی با وضوح پایین و همچنین برای نمایش مناسب تغییرات هر لایه، بهترین خروجی هر بلوک در شکل ۸ به تصویر کشیده شده است.

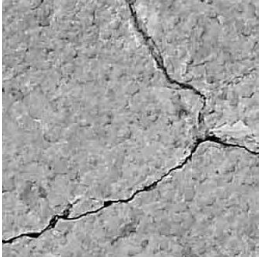
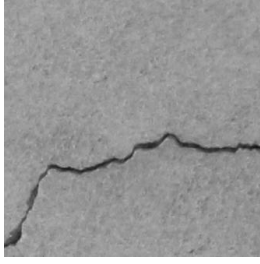

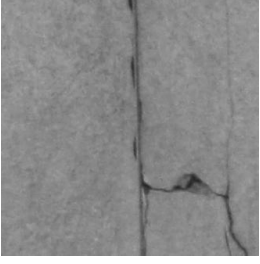
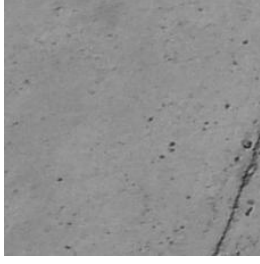
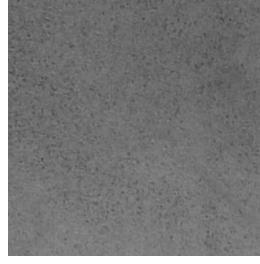
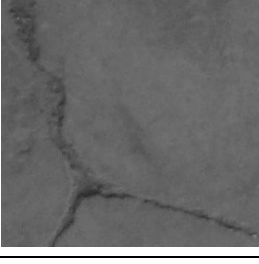
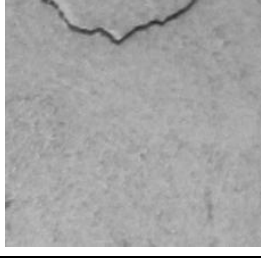

برای نشان دادن عملکرد الگوریتم پیشنهادی در طبقه‌بندی ترک در سازه‌های بتنی از معیارهای کمی صحت، دقت^۲ و فراخوانی^۳

- 1 Accuracy
- 2 Precision
- 3 Recall

4 Confusion Matrix

جدول ۶. نمونه‌هایی از تصاویر ترک با پیش‌بینی درست توسط الگوریتم پیشنهادی

Table 6. The examples of crack images with correct predictions by the proposed algorithm

چندشاخگی در ترک	ترک ساده	بدون ترک
		
		
		

سرعت تحت قاعده بازده نزولی است، یعنی هر چه لایه‌های بیشتری به شبکه اضافه شود، صحت کمتری در هر لایه منفرد ایجاد می‌گردد. در حالت کلی تعیین هایپر پارامترهای یک شبکه کار سخت و زمان‌بری است. یکی از هایپر پارامترهای مهم در طراحی شبکه‌های عصبی کانولوشنی تعداد لایه و نورون‌های لایه‌های تماماً متصل است. برای تعیین تعداد آن‌ها باید به این نکته توجه کرد که در یک شبکه عصبی کانولوشنی، بایاس‌ها و وزن‌های این لایه‌ها به دلیل اتصال کامل بین نورون‌ها، بیش از ۹۰ درصد پارامترهای شبکه را تشکیل می‌دهند. این مسئله، جلوگیری از بیش‌برازش شبکه را به یکی از چالش‌های اصلی طراحی شبکه‌های عصبی کانولوشنی تبدیل می‌کند. هرچند روش حذف تصادفی نیز می‌تواند جهت افزایش سرعت و همگرایی بهتر در این لایه‌ها مورد استفاده قرار گیرند. شکل ۹ تغییرات درصد صحت و زمان تقریبی اجرای شبکه پیشنهادی را نسبت به تغییرات تعداد


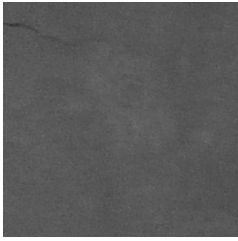
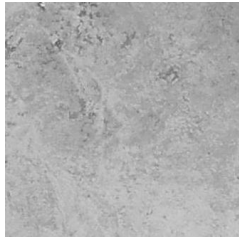
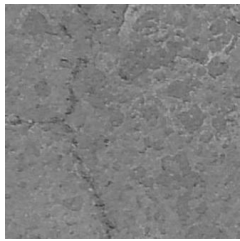
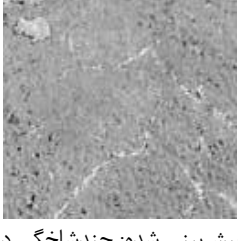
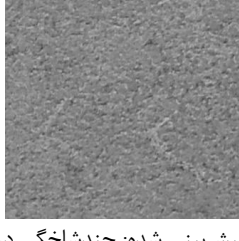
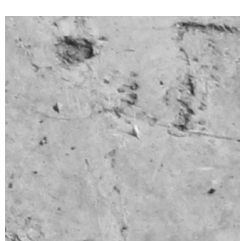
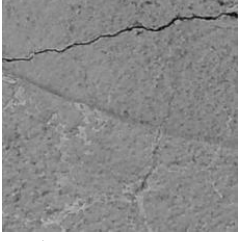
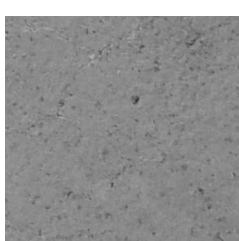
چندشاخگی در ترک در تصاویر سازه‌های بتنی را درست تشخیص دهد. همچنین بر اساس جدول ۵ صحت، دقت و فراخوانی الگوریتم پیشنهادی نیز به ترتیب ۹۹/۳، ۹۹/۳ و ۹۹/۵ می‌باشد. همچنین جدول ۶ و ۷ به ترتیب نمونه تصاویری را با پیش‌بینی درست و غلط توسط الگوریتم پیشنهادی نشان می‌دهد.

۴- آنالیز حساسیت

تعداد بین تعداد لایه‌ها، اندازه و گام فیلترها، نرمال‌سازی یا عدم نرمال‌سازی بسته‌ها، نوع تابع فعال‌ساز، صحت و سرعت شبکه و در حالت کلی تعیین هایپر پارامترهای یک شبکه عصبی کانولوشنی نیازمند تجربه است. بطور کلی، می‌توان تعداد لایه‌ها و فیلترهای مختلف را بررسی کرد و بهترین معماری از نظر سرعت و صحت را یافت. البته باید آگاه بود که در برخی از موارد تعادل بین صحت و

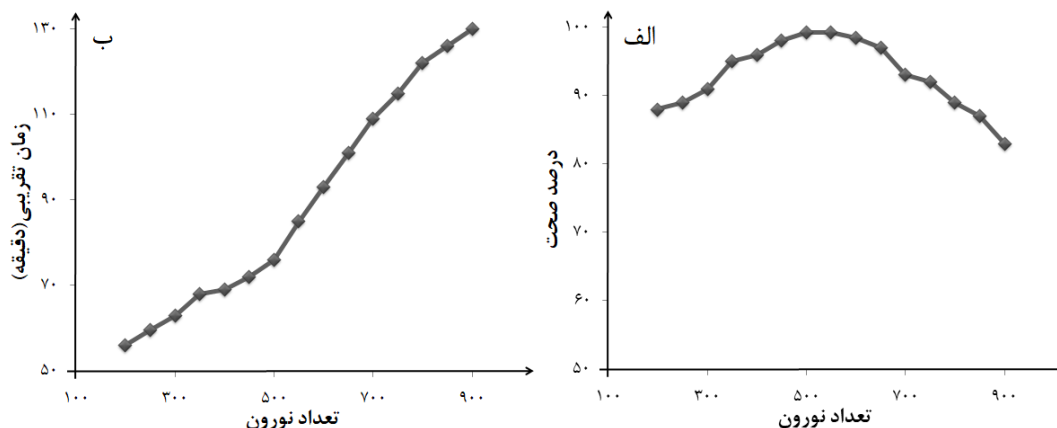
جدول ۷. نمونه‌هایی از تصاویر ترک با پیش‌بینی غلط توسط الگوریتم پیشنهادی

Table 7. The examples of crack images with incorrect predictions by the proposed algorithm

چندشاخگی در ترک	ترک ساده	بدون ترک
 (پیش‌بینی شده: بدون ترک)	 (پیش‌بینی شده: بدون ترک)	 (پیش‌بینی شده: ترک ساده)
 (پیش‌بینی شده: ترک ساده)	 (پیش‌بینی شده: چندشاخگی در ترک)	 (پیش‌بینی شده: چندشاخگی در ترک)
 (پیش‌بینی شده: ترک ساده)	 (پیش‌بینی شده: چندشاخگی در ترک)	 (پیش‌بینی شده: ترک ساده)

در کنار تعیین مناسب‌های پارامترها، استفاده از برخی از روش‌ها همانند نرمال‌سازی لایه‌ها می‌تواند در سرعت و صحت شبکه تأثیرگذار باشد. از نظر مفهومی، می‌توان به نرمال‌سازی بسته‌ها به عنوان سدی نگاه کرد که در بخش‌های مختلفی از یک رود قرار گرفته است. این کار باعث می‌شود که لایه‌ی بعدی همان‌گونه داده‌ها را دریافت کند که انتظارش را دارد. هنگام یادگیری شبکه‌ی عصبی، تغییرات وزن‌ها در هر لایه، شکل داده‌ای که به لایه‌ی بعدی می‌رود را تغییر می‌دهند. هر لایه انتظار دارد که داده‌هایی مشابه داده‌های قبلی خود دریافت کند و به همین دلیل قبل از ارسال، داده‌ها نرمال‌سازی می‌شوند. جدول ۱۰ تغییرات صحت شبکه عصبی کانولوشنی پیشنهادی را بر اساس نرمال‌سازی در لایه‌های مختلف نشان می‌دهد. در حالت کلی

نورون‌های لایه تماماً متصل نشان می‌دهد. همان‌طور که از این شکل ۹ (الف) پیداست افزایش تعداد نورون‌های لایه تماماً متصل تا محدوده ۵۰۰ الی ۶۰۰ نورون موجب افزایش درصد صحت شبکه شده است و از این مقدار به بعد با توجه به افزایش پارامترهای شبکه و امکان بیش‌برازش موجب کاهش درصد صحت شبکه شده است. همچنین افزایش زمان اجرای شبکه در طول این پروسه نیز به دلیل افزایش پارامترها و به تبع آن افزایش محاسبات در شکل ۹ (ب) مشهود است. پیشتر با سعی و خطای انجام شده تعداد ۵۰۰ نورون برای لایه تماماً متصل در نظر گرفته شده بود که با توجه به محدوده مناسب ۵۰۰ الی ۶۰۰ نورون در لایه تماماً متصل و همچنین در نظر گرفتن زمان اجرای این محدوده، تعداد ۵۰۰ نورون انتخابی معقول به نظر می‌رسد.



شکل ۹. آنالیز حساسیت الگوریتم پیشنهادی روی تعداد نورون‌های لایه تماماً متصل، (الف) تغییرات درصد صحت و (ب) تغییرات زمان تقریبی اجرای الگوریتم نسبت به تعداد نورون‌های لایه تماماً متصل

Fig. 9. Sensitivity analysis of the proposed algorithm in the number of fully connected layer neurons, (a) accuracy percentage changes and, (b) the changes of algorithm run time into the number of fully connected layer neurons

جدول ۹. مقایسه صحت شبکه کانولوشنی پیشنهادی با سایر روش‌های معرفی شده توسط مقالات

Table 9. The comparison of the accuracy of the proposed convolution network with other introduced methods by the articles

صحت (درصد)	نوع
۹۲	ماشین بردار پشتیبانی (۱۹۹۳) [۱۹]
۸۶/۴	ماشین بردار پشتیبانی (۲۰۰۲) [۲۰]
۹۱	شبکه‌های عصبی مصنوعی (۲۰۱۱) [۲۱]
۹۲	یادگیری عمیق (۲۰۱۸) [۲۲]
۹۹/۳	شبکه کانولوشنی پیشنهادی

جدول ۸. مقایسه صحت و زمان اجرای شبکه کانولوشنی پیشنهادی با برخی از مهم‌ترین شبکه‌های کانولوشنی معتبر و مرسوم

Table 8. The comparison of the accuracy and run time of the proposed convolution network with some of the most important valid and standard convolution networks

نوع	صحت (درصد)	زمان تقریبی (دقیقه)
Alex Net [۴۰]	۷۹	۱۷۳۰
VGG Net [۴۱]	۸۶/۴	۱۵۵۱
GoogLe Net [۴۲]	۹۴/۲	۴۵۷
شبکه کانولوشنی پیشنهادی	۹۹/۳	۷۶

مبتنی بر آزمون و خطا استفاده کرد.

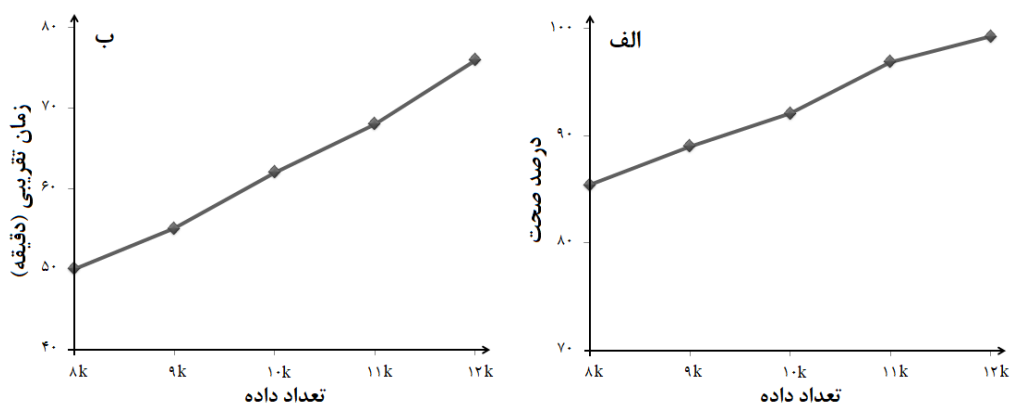
در حالت کلی شبکه‌های عصبی کانولوشنی نیاز به حجم بالایی از داده‌های برچسب خورده دارند. به عبارت دیگر در حالت کلی در یادگیری عمیق کافی است تعداد زیادی داده و زمان کافی در اختیار الگوریتم یادگیری قرار داد تا الگوریتم بتواند بهترین ویژگی‌های مناسب به منظور طبقه‌بندی با حداقل خطا را یاد بگیرد. البته همیشه نمی‌توان داده‌های برچسب خورده زیادی فراهم کرد و در بسیاری از موارد این موضوع با محدودیت‌هایی همراه است. هرچند داده‌های برچسب خورده زیاد می‌تواند افزایش صحت را به دنبال داشته باشد، ولی منجر به افزایش زمان محاسبات شده و می‌تواند برخط شدن الگوریتم یادگیری را تحت‌الشعاع قرار دهد. از این رو تناسب میان

نرمال‌سازی لایه‌ها باعث صفر شدن میانگین و واحد شدن انحراف از معیار توزیع داده‌های ورودی می‌شود که موجب کاهش وابستگی سیستم به مقداردهی اولیه ضرایب خواهد شد. طبق این جدول نرمال‌سازی در لایه‌های ابتدایی منجر به بالاترین دقت ممکن شده و هر چه نرمال‌سازی در لایه‌های بالاتر صورت گرفته است، درصد صحت کاهش یافته است. هر چند که این اختلاف صحت کمتر از ۴ درصد است، اما می‌توان این کاهش درصد صحت را به دلیل تأثیر بیشتر لایه‌های ابتدایی به دلیل ارتباط مستقیم با توزیع اصلی داده‌ها دانست. با تمام این اوصاف می‌بایست عنوان کرد که همانند بسیاری از مسائل یادگیری ماشین، بهینه‌سازی کامل اکثر هایپر پارامترها با روش‌های تحلیلی عملاً امکان‌پذیر نیست و می‌بایست از روش‌های

جدول ۱۰. مقایسه صحت شبکه عصبی کانولوشنی پیشنهادی بر اساس نرمال سازی لایه ها

Table 10. The comparison of the accuracy of the proposed convolutional neural network based on layer normalization of layers

نوع	صحت (درصد)	میانگین صحت (درصد)
نرمال سازی	۹۸/۷۶	۹۹/۰۳
در لایه های ابتدایی	۹۹/۳	
نرمال سازی	۹۵/۰۸	۹۵/۱۴
در لایه های انتهایی	۹۵/۲	
نرمال سازی در کل شبکه	۹۸/۸۳	۹۸/۸۳



شکل ۱۰. آنالیز حساسیت الگوریتم پیشنهادی روی تعداد داده ها، (الف) تغییرات درصد صحت و (ب) تغییرات زمان تقریبی اجرای الگوریتم نسبت به تعداد داده ها

Fig. 10. Sensitivity analysis of the proposed algorithm in the number data, (a) accuracy percentage changes, (b) the changes of algorithm run time into the number data

تعداد داده ها و زمان اجرای برنامه و همین طور صحت مورد نظر خود چالشی است که با توجه به موضوع مورد بررسی می تواند متفاوت باشد. از این رو در این پژوهش با توجه به صحت مطلوب به دست آمده (بالای ۹۹ درصد)، افزایش تعداد داده ها توجیه زمانی ندارد و امکان

برخط شدن الگوریتم یادگیری را حتی در سیستم های سخت افزاری قوی تر کم رنگ خواهد کرد. با این حال یک آنالیز حساسیت نسبت به تعداد داده ها در الگوریتم پیشنهادی انجام شد که نتایج آن به صورت نمودارهای موجود در شکل ۱۰ به تصویر کشیده شده است. همان طور که از این شکل دریافت می شود با کاهش تعداد داده ها گرچه زمان اجرای الگوریتم کاهش می یابد، اما درصد صحت نیز کاهش پیدا می کند که خود تأییدی بر چالش تناسب میان تعداد داده، زمان اجرا و درصد صحت مورد انتظار است. با این وجود، حداقل تعداد ۱۰۰۰۰

داده منجر به دقت مناسب بالای ۹۰ درصد و زمان تقریبی ۶۲ دقیقه شده است.

۵- نتیجه گیری

تشخیص چندشاخگی در ترک های بتنی که عمدتاً از سطوح شدت بالا ایجاد می شوند می توانند نقش بسزایی در طول عمر و نظارت بر سازه های بتنی ایفا کنند. به همین دلیل در این مقاله یک روش هوشمند برای شناسایی آنها بر اساس شبکه های عصبی کانولوشنی ارائه شد. بر طبق این روش هوشمند، تصاویر مستخرج از ربات پرنده Phantom4 Pro که می تواند تمام بخش های یک سازه بتنی را تحت پوشش هوایی خود قرار دهد، توسط یک معماری عمیق پیشنهادی طبقه بندی شدند. این طبقه بندی شامل دسته های تصاویر

- measurements over a 14-year span, *Structural Health Monitoring*, 5(17) (2018) 1094-1073.
- [6] H. Kim, E. Ahn, M. Shin, S.-H. Sim, Crack and noncrack classification from concrete surface images using machine learning, *Structural Health Monitoring*, 3(18) (2019) 725-738.
- [7] J. Valença, D. Dias-da-Costa, E. Júlio, H. Araújo, H. Costa, Automatic crack monitoring using photogrammetry and image processing, *Measurement*, 1(46) (2013) 441-433.
- [8] D. Dias-da-Costa, J. Valença, E. Júlio, H. Araújo, Crack propagation monitoring using an image deformation approach, *Structural Control and Health Monitoring*, 10(24) (2017) e1973.
- [9] T.-H. Yi, H.-N. Li, M. Gu, Experimental assessment of high-rate GPS receivers for deformation monitoring of bridge, *Measurement*, 1(46) (2013) 432-420.
- [10] A. Mohan, S. Poobal, Crack detection using image processing: A critical review and analysis, *Alexandria Engineering Journal*, 2(57) (2018) 798-787.
- [11] J.-K. Oh, G. Jang, S. Oh, J.H. Lee, B.-J. Yi, Y.S. Moon, J.S. Lee, Y. Choi, Bridge inspection robot system with machine vision, *Automation in Construction*, 7(18) (2009) 929-941.
- [12] N.-D. Hoang, Q.-L. Nguyen, A novel method for asphalt pavement crack classification based on image processing and machine learning, *Engineering with Computers*, 2(35) (2019) 498-487
- [13] Goodfellow, Y. Bengio, A. Courville, *Deep learning*, MIT press, 2016.
- [14] N. Dwivedi, D.K. Singh, Review of Deep Learning Techniques for Gender Classification in Images, in: *Harmony Search and Nature Inspired Optimization Algorithms*, Springer, 2019, pp. 1099-1089.
- [15] M. Shariati, N.H. Ramli-Sulong, M.M.A. KH, P. Shafigh, H. Sinaei, Assessing the strength of reinforced concrete structures through Ultrasonic Pulse Velocity and Schmidt Rebound Hammer tests, *Scientific Research and Essays*, 1(6) (2011) 220-213.
- [16] M. Hamidian, A. Shariati, M.A. Khanouki, H. Sinaei, A. Togholi, K. Nouri, Application of Schmidt rebound
- بدون ترک، تصاویر دارای ترک ساده و تصاویر دارای چندشاخگی در ترک بود که صحت ۹۹/۳ درصد را به همراه داشت. نقاط قوت این مقاله را می‌توان در چهار مورد برشمرد: اول اینکه معماری عمیق پیشنهادی در مقایسه با سایر معماری‌های عمیق از پیچیدگی بسیار کمتری برخوردار است و دوماً در عین سادگی منجر به صحت بالاتری نسبت به سایر روش‌های معرفی شده در مطالعات پیشین و سایر معماری‌های عمیق معتبر شده است. مورد سوم به زمان اجرای کمتر نسبت به سایر روش‌ها مربوط می‌شود. چهارمین و آخرین نقطه قوت این مقاله تشخیص چندشاخگی در ترک می‌باشد که در سایر مقالات کمتر مورد توجه قرار گرفته است. اگرچه با توجه به زمان اجراء، روش پیشنهادی نمی‌تواند برای برخط بودن مناسب باشد، اما این انتظار می‌رود که استفاده از سیستم سخت‌افزاری قوی می‌تواند به تحقق آن کمک کند. همچنین استفاده از ربات پرنده علاوه بر مزیت پوشش هوایی، می‌تواند در بررسی برخط ترک‌های دارای چندشاخگی و سایر ترک‌های مهم در سازه‌های بتنی مفید و مؤثر باشد.

مراجع

- [1] L. Qiu, S. Yuan, C. Boller, An adaptive guided wave-Gaussian mixture model for damage monitoring under time-varying conditions: Validation in a full-scale aircraft fatigue test, *Structural health monitoring*, 5(16) (2017) 517-501.
- [2] P. Liu, H.J. Lim, S. Yang, H. Sohn, C.H. Lee, Y. Yi, D. Kim, J. Jung, I.-h. Bae, Development of a "stick-and-detect" wireless sensor node for fatigue crack detection, *Structural Health Monitoring*, 2(16) (2017) 163-153.
- [3] J. Xu, Z. Fu, Q. Han, G. Lacidogna, A. Carpinteri, Micro-cracking monitoring and fracture evaluation for crumb rubber concrete based on acoustic emission techniques, *Structural Health Monitoring*, 4(17) (2018) 958-946.
- [4] D. Reagan, A. Sabato, C. Niezrecki, Feasibility of using digital image correlation for unmanned aerial vehicle structural health monitoring of bridges, *Structural Health Monitoring*, 5(17) (2018) 1072-1056.
- [5] W.-H. Hu, S. Said, R.G. Rohrmann, Á. Cunha, J. Teng, Continuous dynamic monitoring of a prestressed concrete bridge based on strain, inclination and crack

- [26] K. Chen, A. Yadav, A. Khan, Y. Meng, K.J.M. Zhu, S.i. Engineering, Improved Crack Detection and Recognition Based on Convolutional Neural Network, 2019 (2019).
- [27] M. Peppas, J. Hall, J. Goodyear, J. Mills, Photogrammetric assessment and comparison of DJI Phantom 4 pro and phantom 4 RTK small unmanned aircraft systems, ISPRS Geospatial Week 2019, (2019).
- [28] Y. Xie, L. Ning, M. Wang, C. Li, Image enhancement based on histogram equalization, in: Journal of Physics: Conference Series, IOP Publishing, 2019, pp. 012161.
- [29] M.W. Gardner, S. Dorling, Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences, *Atmospheric environment*, 15-14(32) (1998) 2636-2627.
- [30] A.A.M. Al-Saffar, H. Tao, M.A. Talab, Review of deep convolution neural network in image classification, in: 2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET), IEEE, 2017, pp. 31-26.
- [31] T. Suzuki, H. Kudo, Image Correction in Emission Tomography Using Deep Convolution Neural Network, in: ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 2019, pp. 3671-3667.
- [32] M.T. McCann, K.H. Jin, M. Unser, Convolutional neural networks for inverse problems in imaging: A review, *IEEE Signal Processing Magazine*, 6(34) (2017) 95-85.
- [33] D. Scherer, A. Müller, S. Behnke, Evaluation of pooling operations in convolutional architectures for object recognition, in: International conference on artificial neural networks, Springer, 2010, pp. 101-92.
- [34] K. He, X. Zhang, S. Ren, J. Sun, Spatial pyramid pooling in deep convolutional networks for visual recognition, *IEEE transactions on pattern analysis and machine intelligence*, 9(37) (2015) 1916-1904.
- [35] A. Santoro, D. Raposo, D.G. Barrett, M. Malinowski, R. Pascanu, P. Battaglia, T. Lillicrap, A simple neural network module for relational reasoning, in: Advances in neural information processing systems, 2017, pp. 4976-4967.
- [36] V. Romanuke, Appropriate number and allocation of hammer and ultrasonic pulse velocity techniques for structural health monitoring, *Scientific Research and Essays*, 21(7) (2012) 2001-1997.
- [17] S. Alam, A. Loukili, F. Grondin, E. Rozière, Use of the digital image correlation and acoustic emission technique to study the effect of structural size on cracking of reinforced concrete, *Engineering Fracture Mechanics*, 143 (2015) 31-17.
- [18] J. Valença, I. Puente, E. Júlio, H. González-Jorge, P. Arias-Sánchez, Assessment of cracks on concrete bridges using image processing supported by laser scanning survey, *Construction and Building Materials*, 146 (2017) 678-668.
- [19] M.S. Kaseko, S.G. Ritchie, A neural network-based methodology for pavement crack detection and classification, *Transportation Research Part C: Emerging Technologies*, 4(1) (1993) 291-275.
- [20] Z. Liu, S.A. Suandi, T. Ohashi, T. Ejima, Tunnel crack detection and classification system based on image processing, in: Machine Vision Applications in Industrial Inspection X, International Society for Optics and Photonics, 2002, pp. 152-145.
- [21] H. Moon, J. Kim, Intelligent crack detecting algorithm on the concrete crack image using neural network, *Proceedings of the 28th ISARC*, (2011) 1467-1461.
- [22] H. Nhat-Duc, Q.-L. Nguyen, V.-D. Tran, Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network, *Automation in Construction*, 94 (2018) 213-203.
- [23] E.J. Willemsse, D.D. Pollard, On the orientation and patterns of wing cracks and solution surfaces at the tips of a sliding flaw or fault, *Journal of Geophysical Research: Solid Earth*, 103(B2) (1998) 2438-2427.
- [24] K. Ohno, M. Ohtsu, Crack classification in concrete based on acoustic emission, *Construction and Building Materials*, 12(24) (2010) 2346-2339.
- [25] A. Cubero-Fernandez, F.J. Rodriguez-Lozano, R. Villatoro, J. Olivares, J.M. Palomares, Efficient pavement crack detection and classification, *EURASIP Journal on Image and Video Processing*, 1(2017) (2017) 39.

- [40] W. Nawaz, S. Ahmed, A. Tahir, H.A. Khan, Classification of breast cancer histology images using alexnet, in: International Conference Image Analysis and Recognition, Springer, 2018, pp. 876-869.
- [41] M.-K. Kim, Contactless Palmprint Identification Using the Pretrained VGGNet Model, Journal of Korea Multimedia Society, 12(21) (2018) 1447-1439.
- [42] M. Al-Qizwini, I. Barjasteh, H. Al-Qassab, H. Radha, Deep learning algorithm for autonomous driving using googlenet, in: 2017 IEEE Intelligent Vehicles Symposium (IV), IEEE, 2017, pp. 96-89.
- ReLU in convolutional neural networks, Naukovi Visti NTUU KPI, (1) (2017) 78-69.
- [37] W. Liu, Y. Wen, Z. Yu, M. Yang, Large-margin softmax loss for convolutional neural networks, in: ICML, 2016, pp. 7.
- [38] S. Ioffe, C. Szegedy, Batch normalization: Accelerating deep network training by reducing internal covariate shift, arXiv preprint arXiv:1502.03167, (2015).
- [39] Y.D. Chun, N.C. Kim, I.H. Jang, Content-based image retrieval using multiresolution color and texture features, IEEE Transactions on Multimedia, 6(10) (2008) -1073 1084.

چگونه به این مقاله ارجاع دهیم

N. Bigdeli, H. Jabbari, M. Shojaei, An Intelligent Method for Crack Classification in Concrete Structures Based on Deep Neural Networks, Amirkabir J. Civil Eng., 53(8) (2021) 3201-3220.

DOI: [10.22060/ceej.2020.17738.6660](https://doi.org/10.22060/ceej.2020.17738.6660)



