



Pavement cracks detection and classification using deep convolutional networks

S. Ranjbar¹, F. Moghadas Nejad^{2*}, H. Zakeri³

¹ MSc student, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran

² Professor, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran

³ PhD, Department of Civil & Environmental Engineering, Amirkabir University of Technology, Tehran, Iran

ABSTRACT: Pavement inspection is one of the most important steps in the implementation of the pavement management system and extend efforts have been conducted to increase the efficiency of this system by using new technologies. In recent years, transportation agencies focus on creating automatic and more efficient systems for pavement inspection and a large number of researches have been done for this aim. According to the progress of computer science, data mining and machine learning as computer-based methods are used more in various areas (such as engineering, medical and economy), and significant results have been achieved. In the pavement management area, several researches have been performed to apply the machine learning, especially in pavement distresses evaluation. In this paper, the theoretical concepts have been explained, and several models have been created based on deep convolutional networks using transfer learning to detect and classify pavement cracks as the most prevalent pavement distress, and the performance of these models has been evaluated considering learning and test speed, and accuracy as the most important performance parameters. The results of this research indicate that the speed of models almost depends on the characteristics of pre-trained models that applied in the transfer learning process. Also, the accuracy of models based on various metrics (Sensitivity, F-score, etc.) is in range of 0.94 to 0.99 and indicates that deep learning method can be used to create expert systems for detection, classification, and quantification of pavement distresses such as cracking.

Review History:

Received: 2019-04-13

Revised: 2019-05-12

Accepted: 2019-05-23

Available Online: 2019-06-17

Keywords:

Deep learning
transfer learning
pavement cracking
detection
classification

1. INTRODUCTION

Transportation infrastructures have a deep influence on economic development, urbanization, and globalization [1, 2]. Also, this part of the infrastructure improves the quality of people's life. Roads are one of the most important parts of transportation infrastructure that have an extensive and direct effect on the daily life of humans and provide the possibility to move peoples and goods [3]. The pavement management system plays a very important role in the management of roads and has a direct influence on the quality and safety of roads. An efficient pavement management system creates work planning for pavement maintenance in optimal time, by a correct maintenance technique, and with optimal cost [4]. These aims become possible when the pavement inspection information (such as pavement distresses) is collected correctly.

In recent years, data mining and machine learning approaches have been the most utilized methods for the reorganization of the pavement distresses [5, 6]. Pavement distresses can be divided into cracking and non-cracking distress. Cracking distress in the pavement are the most prevalent pavement distresses, and cracks have a great impact

on reducing the design-life [7, 8]. The pavement cracks can be divided into two general categories that are named surface cracks and linear cracks.

Deep learning is a kind of machine learning technique that is developed based on neural network concepts. The Convolutional Neural Network (CNN) is one of the most popular deep neural networks that have wide applications in processing and extraction of features from data such as pavement images [9-11].

In this research, a machine learning method based on convolutional neural networks has been applied with transfer learning for implementing the detection and classification task on pavement cracks. Also, the performance of the different models has been compared based on speed and accuracy.

2. METHODOLOGY

As can be seen in Fig. 1, the research process contains four main steps, including: data collection, pre-process, training and testing models, and evaluating the performance of the models.

Pavement images have been collected as inputs of the process in three classes, including surface cracking, linear cracking, and non-cracking. Then a pre-processing has been

*Corresponding author's email: moghadas@aut.ac.ir



Fig. 1. Main steps of research




Table 1. Details of datasets

Dataset	Training dataset		Testing dataset
	Training	Validation	
Surface cracking	400	100	250
Linear cracking	400	100	250
Non-cracking	400	100	250
Total	1500		750

Table 2. Time spent in the various process (second)

Pre-trained CNN	Pre-processing for each image (on average)	Train for each image (on average)	Test for each image (on average)
AlexNet		0.482	0.019
SqueezeNet		0.383	0.017
GoogleNet		0.637	0.024
ResNet-18	0.058	0.644	0.021
ResNet-50		1.944	0.041
ResNet-101		3.823	0.054
DenseNet-201		12.908	0.089
Inception-V3		2.951	0.053

Fig. 2. Performance metrics

Models	Accuracy	Sensitivity	Specificity	Precision	Recall	Fscore
AlexNet	0.978	0.967	0.983	0.967	0.967	0.967
SqueezeNet	0.991	0.986	0.993	0.986	0.986	0.986
GoogleNet	0.989	0.984	0.992	0.984	0.984	0.984
ResNet-18	0.979	0.968	0.984	0.969	0.968	0.968
ResNet-50	0.974	0.961	0.981	0.961	0.961	0.961
ResNet-101	0.972	0.957	0.979	0.958	0.957	0.957
DenseNet-202	0.984	0.976	0.988	0.976	0.976	0.976
Inception-V3	0.985	0.977	0.989	0.977	0.977	0.977

conducted on input images to creating more obvious and clear images. Table 1 presents more details on the prepared datasets for training and testing process.

In the training process, eight pre-trained models based on CNN have been applied by using transfer learning technique. AlexNet, GoogleNet, SqueezeNet, ResNet-18, ResNet-50, ResNet-101, DenseNet-201, and Inception-v3 are pre-trained models that applied to retrained based on collected training datasets by using transfer learning. After the training process, the created models were applied to perform crack detection and classification on the testing dataset.

It should be noted that all computations were performed in MATLAB 2018b by using a personal computer with a 64-bit operating system, 8.0 GB memory, and Intel(R) Core i7-4710HQ @ 2.50 GHz processor running a GeForce GTX

850M graphics processing unit (GPU).

3. DISCUSSION AND RESULTS

After performing the experimental work (data preparing, training, and testing), the performance of the models has been evaluated based on two aspects including models speed in training and testing and models accuracy in the detection and classification of the pavement cracks.

The summarized information on time spent in data pre-processing, models training, and testing has been presented in Table 2. It should be noted that the speed of the models depends on the characteristic of pre-trained models applied in the training process.

As can be seen in Table 2, some of the models such as AlexNet, SqueezeNet, GoogleNet, and ResNet-18 are significantly faster than others.

To evaluate the efficiency of the models in crack detection and classification, the confusion matrix was calculated to achieve performance metrics such as accuracy, sensitivity, specificity, precision, and F-score. The average of the performance metrics in three classes has been presented in Fig. 2.

As shown in Fig. 2, the performance metrics of all models are in the range of 0.94 to 0.99. Also, SqueezeNet and GoogleNet have more effective performance than other models, and SqueezeNet has the best performance according to all metrics.

4. CONCLUSIONS

This research tries to apply machine learning techniques for detection and classification of two general types of pavement cracks, including surface cracks and linear cracks. For this aim, eight pre-trained CNNs have been retrained based on pavement images using transfer learning method.

Results of the research indicate that SqueezeNet has the best performance with regard to speed and performance metrics. Finally, according to the performed experiment and presented results, several important points can be concluded as follows:

- By using machine learning techniques, the data mining approaches provide efficient systems to perform pavement inspection tasks such as cracks detection and classification.
- Retraining the pre-trained CNN by utilizing transfer learning is an efficient method to create a classifier model for pavement crack detection and classification, especially when there is a constraint in processing power and available data.
- Prepared data for the training process and the characteristics of pre-trained models have a great influence on the model's performance.
- Determining the best model is a tradeoff between process power, available data and the level of performance required.

REFERENCES

- [1] Y. Shi, S. Guo, P. Sun, The role of infrastructure in China's regional economic growth, *Journal of Asian Economics*, 49 (2017) 26-41.
- [2] E. Ivanova, J. Masarova, Importance of road infrastructure in the economic development and competitiveness, *Economics Management*, 18(2) (2013) 263-274.
- [3] R. Engström, The Roads' Role in the Freight Transport System,


- Transportation Research Procedia, 14 (2016) 1443-1452.
- [4] M.Y. Shahin, Pavement management for airports, roads, and parking lots, 1994.
- [5] K. Gopalakrishnan, Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review, Data, 3(3) (2018) 28.
- [6] G. Zhou, L. Wang, D. Wang, S. Reichle, Integration of GIS and data mining technology to enhance the pavement management decision making, Journal of Transportation Engineering, 136(4) (2009) 332-341.
- [7] H. Zakeri, F.M. Nejad, A. Fahimifar, Rahbin: A quadcopter unmanned aerial vehicle based on a systematic image processing approach toward an automated asphalt pavement inspection, Automation in Construction, 72(Part 2) (2016) 211-235.
- [8] H. Zakeri, F.M. Nejad, A. Fahimifar, Image Based Techniques for Crack Detection, Classification and Quantification in Asphalt Pavement: A Review, Archives of Computational Methods in Engineering, 24(4) (2017) 935-977.
- [9] Y. LeCun, Y. Bengio, G.J.n. Hinton, Deep learning, 521(7553) (2015) 436.
- [10] K. Gopalakrishnan, S.K. Khaitan, A. Choudhary, A. Agrawal, Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection, Construction and Building Materials, 157 (2017) 322-330.
- [11] Z. Tong, J. Gao, Z. Han, Z. Wang, Recognition of asphalt pavement crack length using deep convolutional neural networks, Road Materials and Pavement Design, 19(6) (2018) 1334-1349.

HOW TO CITE THIS ARTICLE

S. Ranjbar, F. Moghadas Nejad, H. Zakeri, Pavement cracks detection and classification using deep convolutional networks, Amirkabir J. Civil Eng., 52(9) (2020) 555-558.

DOI: [10.22060/ceej.2019.16103.6133](https://doi.org/10.22060/ceej.2019.16103.6133)





تشخیص و دسته‌بندی ترک‌های روسازی با استفاده از شبکه‌های پیچشی عمیق

سجاد رنجبر، فریدون مقدس نژاد*، حمزه ذاکری

دانشکده عمران و محیط زیست، دانشگاه صنعتی امیرکبیر، تهران، ایران،

تاریخچه داوری:
دریافت: ۱۳۹۸-۰۱-۲۴
بازنگری: ۱۳۹۸-۰۲-۲۲
پذیرش: ۱۳۹۸-۰۳-۰۲
ارائه آنلاین: ۱۳۹۸-۰۳-۲۷

کلمات کلیدی:

یادگیری عمیق
انتقال یادگیری
ترک خوردگی روسازی
تشخیص
دسته‌بندی

خلاصه: ارزیابی اطلاعات روسازی یکی از مهم‌ترین گام‌های پیاده‌سازی سامانه مدیریت روسازی است و سالانه تلاش‌های گسترده‌ای به منظور افزایش کارایی این سامانه با استفاده از فناوری‌های جدید انجام شده است. در سال‌های اخیر تمرکز سازمان‌ها بر توسعه سامانه‌های خودکار به منظور برداشت و ارزیابی بهتر اطلاعات روسازی بوده و تحقیقات گسترده‌ای در این زمینه انجام شده است. دانش داده‌کاوی و یادگیری ماشین با هدف بهره‌گیری از داده‌های موجود برای ساخت سامانه‌های هوشمند از جمله جدیدترین زمینه‌های تحقیقاتی در علوم مختلف نظیر پزشکی، مهندسی، اقتصادی است و نتایج بسیار خوبی از به‌کارگیری این دانش‌ها بدست آمده است. در زمینه مدیریت روسازی تحقیقات متعددی با هدف به‌کارگیری یادگیری ماشین به ویژه در ارزیابی خرابی‌های روسازی انجام شده است و نتایج این تحقیقات نشان می‌دهد که روش‌های مبتنی بر داده‌کاوی و هوش مصنوعی، ابزارهای قدرتمندی در ساخت سامانه‌های خودکار و هوشمند هستند. در این مقاله ضمن تشریح مفاهیم تئوری، تلاش شده است که مدل‌هایی با هدف تشخیص و دسته‌بندی خرابی ترک خوردگی روسازی با استفاده از شبکه‌های پیچشی عمیق و به‌کارگیری روش انتقال یادگیری ایجاد شود و عملکرد آن‌ها از نظر دقت و سرعت یادگیری و اجرا مورد ارزیابی قرار گیرد. نتایج این پژوهش نشان می‌دهد که سرعت عملکرد مدل‌ها تا حد زیادی به مشخصه‌های مدل‌های از پیش‌تعلیم یافته بستگی دارد و دقت مدل‌ها بر اساس معیارهای مختلف (accuracy, sensitivity, F-score) در بازه ۰/۹۴ تا ۰/۹۹ است که بیانگر عملکرد خوب مدل‌های مبتنی بر شبکه‌های پیچشی عمیق در تشخیص و ارزیابی خرابی‌های روسازی نظیر ترک خوردگی است.

۱- مقدمه

امروزه نقش اساسی زیرساخت‌های حمل‌ونقل در زندگی بشر و توسعه اقتصادی کشورها، بر اهمیت توسعه و مدیریت زیرساخت‌های حمل‌ونقل افزوده است. راه‌ها بخش قابل توجهی از زیرساخت‌های حمل‌ونقل را تشکیل می‌دهند و هر ساله بخش قابل توجهی از نیاز بشر به جابه‌جایی کالا و انسان بر بستر راه‌ها مرتفع می‌گردد. توسعه و مدیریت صحیح شبکه راه‌ها با توجه به مواردی نظیر کاهش زمان سفر و آلودگی ناشی از وسایل نقلیه، کاهش هزینه‌های استهلاکی و مصرفی وسایل نقلیه و افزایش ایمنی، تأثیر مستقیم بر زندگی روزمره

انسان خواهد داشت. [۱-۴]

به منظور بیان اهمیت بالای مدیریت، تعمیر و نگهداری شبکه راه‌ها می‌توان به گزارش انجمن مهندسان آمریکا (ASCE¹) اشاره نمود که بر اساس آن به ازای صرف یک دلار برای بهبود شرایط زیرساخت‌های راه، ۵/۲ دلار بازگشت سرمایه از طریق کاهش مصرف سوخت و آلودگی ناشی از آن، کاهش هزینه‌های نگهداری وسایل نقلیه، افزایش ایمنی و کاهش هزینه نگهداری راه‌ها حاصل می‌شود [۵].

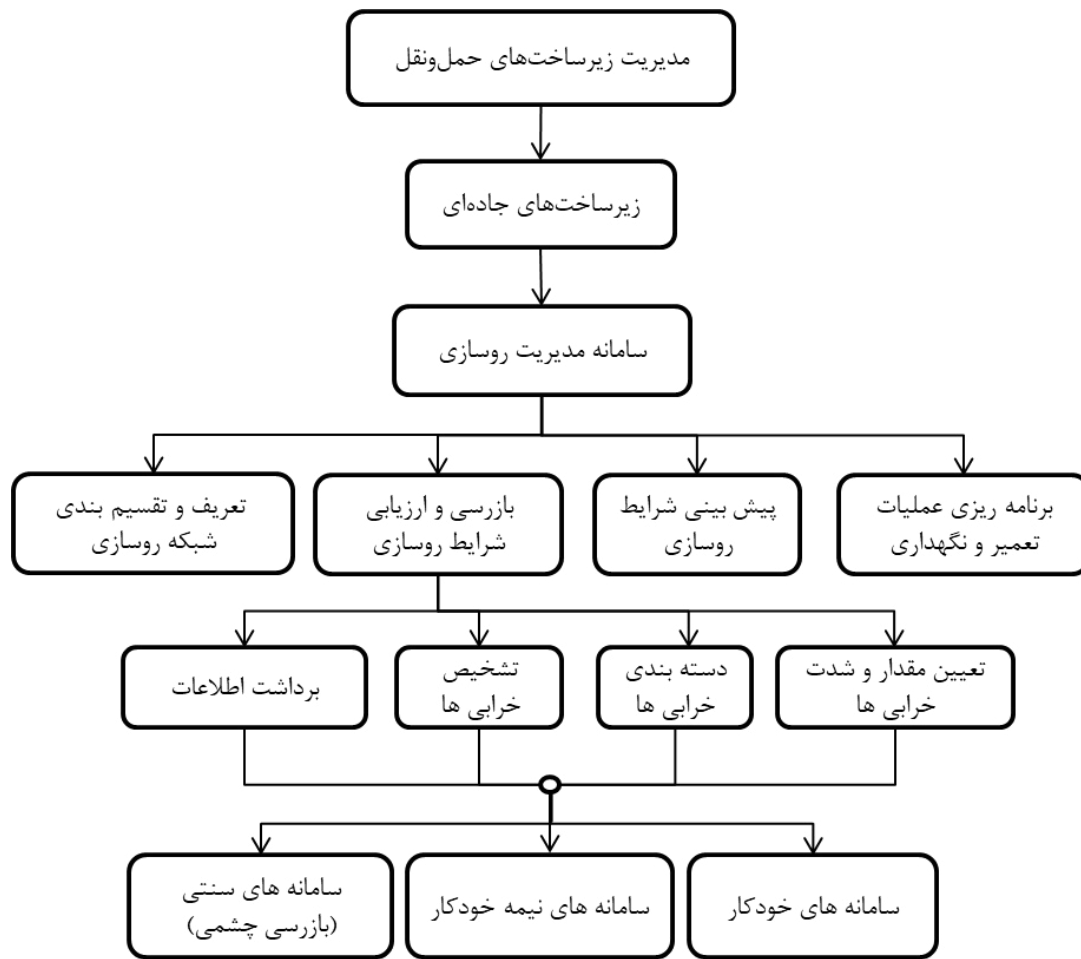
سامانه مدیریت روسازی راه‌ها از بخش‌های بسیار مهم مدیریت و تعمیر و نگهداری راه‌ها بوده و نقش مهمی در بهبود شرایط

* نویسنده عهده‌دار مکاتبات: moghadas@aut.ac.ir@aut.ac.ir

1 American Society of Civil Engineers

حقوق مؤلفین به نویسندگان و حقوق ناشر به انتشارات دانشگاه امیرکبیر داده شده است. این مقاله تحت لایسنس آفرینندگی مردمی (Creative Commons License) در دسترس شما قرار گرفته است. برای جزئیات این لایسنس، از آدرس <https://www.creativecommons.org/licenses/by-nc/4.0/legalcode> دیدن فرمائید.






شکل ۱. بازرسی و ارزیابی شرایط روسازی
Fig. 1. Pavement condition evaluation

روسازی مختلف، بازرسی و ارزیابی اطلاعات روسازی به سه روش سنتی، نیمه خودکار و خودکار انجام می‌شود. اما با توجه به معایب روش‌های سنتی نظیر زمان‌بر بودن، هزینه‌های بالا، غیر قابل اعتماد بودن نتایج، نیاز به حضور کارکنان در جاده، ایجاد اختلال در شرایط ترافیکی مسیر، شرایط کاری پرمخاطره و عدم امکان برداشت اطلاعات در شرایط آب و هوایی نامساعد و همچنین معایب روش‌های نیمه خودکار نظیر غیر قابل اعتماد بودن و متکی به نظر فرد بودن نتایج، زمان‌بر بودن روند برداشت و ارزیابی اطلاعات، اکثریت وزارتخانه‌ها و سازمان‌های مجری سامانه مدیریت روسازی روی توسعه سامانه‌های خودکار برداشت و ارزیابی اطلاعات روسازی متمرکز شده‌اند [۷-۱۰]. در این راستا در سال‌های اخیر، تحقیقات گسترده‌ای به منظور به کارگیری فناوری‌های مختلف برای برداشت و ارزیابی خودکار شرایط روسازی انجام شده است که از پرکاربردترین فناوری‌های به

بهره‌برداری از شبکه راه‌ها دارد. سامانه مدیریت روسازی از پنج بخش اصلی تشکیل شده است که عبارت‌اند از [۶]:

- تعریف شاخه‌ها و قطعات در شبکه روسازی
 - بازرسی و برداشت شرایط روسازی
 - ارزیابی شرایط روسازی
 - پیش‌بینی و آنالیز شرایط روسازی در آینده
 - برنامه‌ریزی برای انجام عملیات تعمیر و نگهداری
- یک سامانه مدیریت روسازی کارا به انجام مناسب‌ترین عملیات تعمیر و نگهداری در بهترین زمان و بهینه‌ترین هزینه اجرایی می‌انجامد که این هدف بدون داشتن اطلاعات کافی از شرایط روسازی میسر نخواهد بود. این موضوع اهمیت بخش بازرسی و برداشت اطلاعات روسازی را مشخص می‌کند [۶]. همانطور که در شکل ۱ مشاهده می‌شود، در سامانه‌های مدیریت



شکل ۲. خرابی های روسازی [۶]
Fig. 2. Pavement distresses

روش های یادگیری ماشین کشف و استخراج مشخصه ها و قوانین از مجموعه داده ها به صورت خودکار انجام می شود [۳۶-۳۸]. روش های یادگیری عمیق بر پایه اصول شبکه عصبی^۴ استوار است و شبکه های عصبی پیچشی یا همگشتی (CNN^۵) از جمله مشهورترین شبکه های مبتنی بر یادگیری عمیق هستند که کاربرد گسترده ای در استخراج خودکار قوانین و مشخصه ها از انواع داده ها نظیر متن، تصویر و فیلم دارد [۳۹، ۴۰]. در سال های اخیر تحقیقات زیادی با هدف تشخیص و ارزیابی خرابی های روسازی با تکیه بر مدل های تهیه شده بر اساس CNN انجام شده است. خرابی های رایج روسازی را مطابق شکل ۲ می توان به دو دسته خرابی های شامل ترک خوردگی و خرابی های غیر ترک خوردگی تقسیم نمود. ترک خوردگی یکی از متداول ترین خرابی های روسازی بوده که حجم قابل توجهی از تلاش های محققان به منظور ایجاد سامانه های خودکار تشخیص خرابی را به خود معطوف کرده است [۴۱-۴۳]. همچنین مطابق شکل ۲ خرابی های شامل ترک خوردگی را می توان به دو دسته ترک های خطی^۶ و ترک های سطحی^۷ یا الگودار تقسیم نمود.

در این مقاله، هشت مدل بر اساس شبکه های عصبی پیچشی عمیق به روش انتقال یادگیری با استفاده از هشت شبکه از پیش

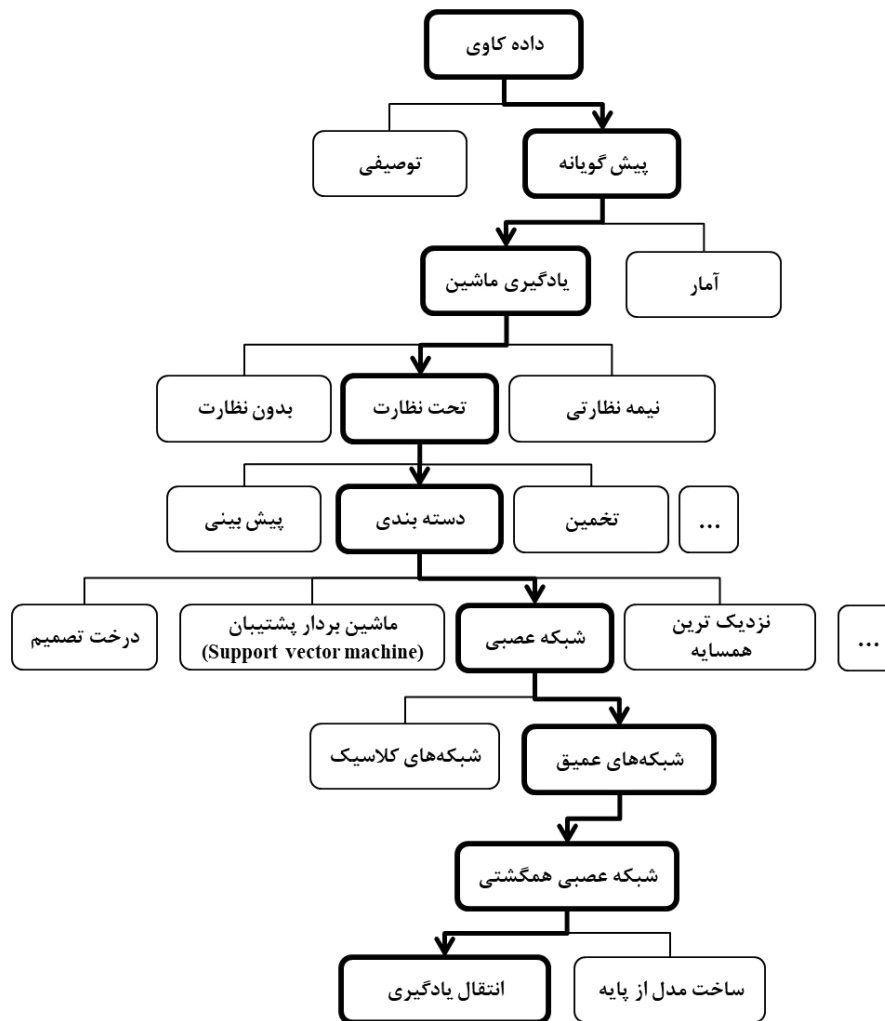
کارگرفته شده می توان به سامانه های مبتنی بر دریافت و پردازش تصاویر دو بعدی [۱۱-۱۴]، سامانه های برداشت و ارزیابی سه بعدی سطح روسازی [۱۵-۱۸]، سامانه های مبتنی بر فناوری رادار [۱۹-۲۱]، سامانه های مبتنی بر سنجش شتاب [۲۲-۲۴]، سامانه های مبتنی بر فناوری مافوق صوت [۲۵-۲۷]، سامانه های ترکیبی [۲۱، ۲۸، ۲۹] اشاره نمود.

از سوی دیگر دانش داده کاوی با توجه به رشد توان پردازشی کامپیوترها، سامانه های ذخیره سازی داده ها و حجم انبوه داده های برداشت شده در سال های گذشته، در بسیاری از زمینه های علوم مهندسی، پزشکی، کسب و کار و ... مورد توجه قرار گرفته است [۳۰، ۳۱] و در این راستا روش های مبتنی بر یادگیری ماشین^۱ به منظور پیاده سازی اهداف مختلف داده کاوی نظیر دسته بندی، تخمین، پیش بینی، خوشه بندی و ... به کار گرفته می شوند و سامانه های ساخته شده بر اساس دانش یادگیری ماشین به دنبال استخراج ویژگی ها و قوانین^۲ از مجموعه داده ها برای استفاده به منظور تصمیم گیری بهتر بر اساس داده های آینده هستند [۳۲-۳۵].

از پرکاربردترین روش های پیاده سازی یادگیری ماشین می توان به روش یادگیری عمیق^۳ اشاره نمود که در این روش برخلاف سایر

4 Neural Network
5 Convolutional Neural Network
6 Linear Cracking
7 Surface Cracking

1 Machine Learning
2 Rules
3 Deep Learning



شکل ۳. چارچوب بهره‌گیری از مفاهیم تئوری
 Fig. 3. The framework of applying theoretical concepts

دسته خرابی ترک خوردگی خطی و سطحی است. سازمان‌دهی بخش‌های بعدی مقاله به این صورت است که در بخش دوم مفاهیم تئوری به کار گرفته شده در انجام پژوهش تشریح می‌شوند. بخش سوم نحوه انجام پژوهش را توضیح می‌دهد و در بخش چهارم نتایج به دست آمده بررسی خواهد شد. در نهایت جمع بندی مطالب ارائه شده در این پژوهش در بخش پنجم انجام می‌شود و پیشنهاداتی برای انجام مطالعات آینده ارائه می‌گردد.

۲- مفاهیم تئوری

همانطور که در شکل ۳ چارچوب و روند بهره‌گیری از روش‌ها و مفاهیم مورد استفاده در این پژوهش نمایش داده شده است، در این بخش توضیحاتی پیرامون مفاهیم تئوری هر یک از روش‌های به کار

تعلیم یافته^۱ به منظور انجام دسته‌بندی و تشخیص ترک‌های روسازی مورد ارزیابی قرار داده شده است. برای این منظور سه مجموعه داده تصویری از خرابی ترک خوردگی روسازی به منظور تعلیم، اعتبارسنجی و آزمایش مدل‌ها آماده شد که در هر یک از مجموعه‌ها به مقدار مساوی از تصاویر شامل ترک‌های خطی، سطحی و تصاویر بدون ترک خوردگی قرار داده شده است. در این پژوهش از هشت شبکه از پیش تعلیم یافته پر کاربرد به منظور ساخت مدل‌های تشخیص خرابی استفاده شد که عبارتند از: ResNet-18، ResNet-50، ResNet-101، DenseNet-201. هدف این مقاله ارزیابی و مقایسه عملکرد شبکه‌های پیش‌بینی عمیق به دست آمده از شبکه‌های از پیش تعلیم یافته در تشخیص و دسته‌بندی دو

1 Pre-trained Convolutional Neural Network

به سه صورت یادگیری تحت نظارت^۱، بدون نظارت^۲ و نیمه نظارتی^۳ می‌تواند انجام شود [۳۲-۳۴، ۴۷، ۴۸] که در این پژوهش از یادگیری تحت نظارت استفاده شده است. این نوع یادگیری برای انجام برخی از وظایف نظیر دسته بندی، پیش‌بینی و تخمین کاربرد زیادی دارد. در این دسته از روش‌های یادگیری ماشین، عملیات یادگیری روی داده‌های ورودی بر اساس داده‌های خروجی شناخته شده، صورت می‌گیرد [۳۳، ۳۵، ۴۹].

۲-۲- یادگیری عمیق

یادگیری عمیق یکی از پرکاربردترین تکنیک‌های مورد استفاده در یادگیری ماشین است که بر پایه شبکه‌های عصبی استوار است. ساختار مدل‌های یادگیری عمیق متشکل از چند لایه خلاصه‌سازی داده‌ها به منظور استخراج الگوها و ویژگی‌های مورد توجه در داده‌ها است. در این ساختار خلاصه‌ای از داده‌ها در یک لایه به لایه بعد با سطح خلاصه‌سازی بالاتر منتقل می‌شود. ویژگی متمایز کننده یادگیری عمیق از سایر تکنیک‌های یادگیری ماشین، توانایی استخراج خودکار الگوهای مهم از داده‌ها است [۳۲، ۳۷، ۵۰، ۵۱].

شبکه‌های عصبی عمیق مبتنی بر مدل‌های سلسله مراتبی هستند که هر لایه با یک انتقال خطی پس از اعمال تبدیل غیر خطی به لایه بعد مرتبط می‌شود. در یک مثال ساده می‌توان داده‌های ورودی را به صورت $X \in \mathbb{R}^{N \times D}$ فرض نمود که هر ردیف از X یک داده با بعد D مثل تصاویر خاکستری با D پیکسل است و N تعداد نمونه‌ها آموزشی شبکه است. در این شبکه W^k به صورت ماتریسی برای انتقال خطی از لایه $k-1$ به مرحله دیگر خلاصه‌سازی در لایه k تعریف می‌شود [۵۲].

$$X_{k-1} W^k \in \mathbb{R}^{N \times d_k} \quad (1)$$

در مرحله بعد، یک تابع غیر خطی (ψ_k) برای ایجاد لایه k ام مورد استفاده قرار می‌گیرد.

$$X_k = \psi_k(X_{k-1} W^k) \quad (2)$$

این تابع غیر خطی می‌تواند به اشکال مختلفی نظیر تابع $\tanh(x)$ یا $(1+e^{-x})^{-1}$ و غیره تعریف و به کار گرفته شود. با

گرفته شده در مقاله ارائه خواهد شد. همچنین اطلاعاتی در مورد نحوه آماده‌سازی و افزایش میزان وضوح و کیفیت تصاویر ارائه شده است.

همانطور که در شکل ۳ مشاهده می‌شود، در این پژوهش به منظور تشخیص و دسته بندی ترک‌های روسازی از دانش داده کاوی پیش‌گویانه مبتنی بر یادگیری ماشین استفاده شده است و در یادگیری ماشین، روش‌های مبتنی بر شبکه عصبی به عنوان یکی از روش‌های یادگیری تحت نظارت به منظور انجام دسته بندی به کار گرفته شده است. همچنین از شبکه‌های پیچشی عمیق که دسته خاصی از شبکه‌های عصبی هستند به روش انتقال یادگیری بهره‌گیری شده است.

۲-۱- داده کاوی و یادگیری ماشین

به فرایند کشف اطلاعات ارزشمند از داده‌هایی با حجم و پیچیدگی بالا، داده کاوی اطلاق می‌شود که در اکثر زمینه‌ها نظیر کسب و کار و تجارت، علوم مهندسی، آماری و سایر شاخه‌های علم به عنوان یک ضرورت پذیرفته شده است. در سال‌های اخیر، با توجه به پیشرفت چشمگیر علوم کامپیوتری و افزایش توان پردازشی کامپیوترها، پیشرفت فناوری ذخیره‌سازی اطلاعات و افزایش نیاز بشر به استخراج اطلاعات بیشتر از بین داده‌ها، توجه ویژه‌ای به دانش داده‌کاوی در زمینه‌های مختلف علم شده است [۳۵، ۴۳-۴۶]. به طور کلی پیاده‌سازی دانش داده‌کاوی با توجه به هدف انجام داده‌کاوی به دو صورت انجام می‌شود که عبارتند از: (۱) داده‌کاوی پیش‌گویانه و (۲) داده‌کاوی توصیفی. در این پژوهش داده کاوی پیش‌گویانه پیاده‌سازی شده است که در این نوع داده کاوی با بررسی داده‌ها، الگوها و قوانین حاکم بر داده‌ها استخراج شده و یک یا چند مدل از سیستم مورد نظر ایجاد می‌شود که می‌توان از این مدل‌ها برای مقاصد مختلف داده‌کاوی نظیر دسته بندی، پیش‌بینی، تخمین و غیره روی داده‌های جدید استفاده نمود.

به منظور پیاده‌سازی داده‌کاوی می‌توان از علوم مختلف استفاده نمود که یادگیری ماشین و آمار دو مورد از مهمترین علوم هستند که در داده‌کاوی کاربرد گسترده‌ای دارند. روش‌های یادگیری ماشین

1 Supervised
2 Unsupervised
3 Semi-Supervised

هستند که در آنالیز داده‌هایی که دارای ساختار شبکه‌ای هستند، کاربرد گسترده‌ای دارند [۴۰، ۵۵]. این دسته از شبکه‌های عصبی قابلیت آنالیز داده‌هایی با یک بعد (مانند متن و صوت)، دو بعد (مانند تصویر) و سه بعد (مانند فیلم) را دارد [۵۴، ۵۶]. در سال‌های اخیر، با توجه به قابلیت‌های این دسته از تکنیک‌های یادگیری عمیق در استخراج خودکار ویژگی‌ها، تشخیص اشیا، دسته بندی تصاویر و ... تحقیقات گسترده‌ای به منظور بهره‌گیری از این تکنیک برای تشخیص و دسته‌بندی خرابی‌های روسازی انجام شده است که برای نمونه می‌توان مراجع [۳۱، ۳۴، ۴۰، ۵۷-۶۵] مطالعه کرد. به طور کلی ساختار شبکه‌های عصبی پیچشی از سه قسمت اصلی تشکیل شده است که عبارتند از لایه‌های پیچشی^۴، لایه‌های ترکیب^۵ و لایه‌های با اتصال کامل^۶.

لایه‌های پیچشی از چند طرحواره^۷ تشکیل شده اند که هر یک از طرح‌ها از طریق لغزش و جابه‌جایی یک ناحیه کوچک با ابعاد مشخص روی داده ایجاد می‌شود. این ناحیه کوچک به عنوان ناحیه محلی شناخته می‌شود. عملیات تشکیل لایه‌های پیچشی بر اساس ناحیه محلی تعیین شده می‌تواند برای انواع داده‌ها نظیر کارکترهای یک متن، پیکسل‌های یک تصویر و سایر موارد مشابه به کار گرفته شود. با توجه به نحوه تشکیل لایه‌های پیچشی می‌توان گفت که بر خلاف شبکه‌های عصبی معمولی، در شبکه‌های عصبی پیچشی هر نرون در یک لایه به تمامی نرون‌های لایه قبلی متصل نیست بلکه هر نرون فقط به نرون‌های موجود در ناحیه محلی لایه قبل اتصال دارد [۳۱، ۳۶، ۴۰، ۵۵، ۶۱، ۶۶-۶۸]. در شکل ۴ نمایی از نحوه تشکیل لایه‌های پیچشی ارائه شده است.

لایه‌های ترکیب معمولاً بلافاصله بعد از لایه‌های پیچشی قرار می‌گیرند. این لایه‌ها با هدف خلاصه‌سازی، ساده سازی و کاهش ابعاد لایه‌های پیچشی در ساختار شبکه قرار می‌گیرند و به ایجاد طرحواره‌های متراکم‌تر منجر می‌شوند. عملیات ترکیب به شکل‌های مختلفی قابل انجام می‌باشد که روش‌های مبتنی بر میانگین و انتخاب بیشینه، دو مورد از روش‌های پرکاربرد برای پیاده‌سازی عملیات ترکیب به حساب می‌آیند [۳۱، ۳۶، ۴۰، ۶۱، ۶۶-۶۹] و در شکل ۵ نحوه ایجاد لایه‌های ترکیب به دو روش ذکر شده نمایش داده شده است.

توجه به روند شرح داده شده، خروجی شبکه پس از چندین لایه به صورت زیر مشخص می‌شود.

$$\Phi(X, W^1, W^2, \dots, W^k) = \psi_k(\psi_{k-1}(\dots(\psi_2(\psi_1(XW^1)W^2) \dots)W^{k-1})W^k) \quad (3)$$

که در رابطه فوق، Φ یک ماتریس $N \times C$ بوده و C بعد خروجی شبکه است که در یک شبکه با هدف دسته‌بندی تعداد دسته‌ها به عنوان بعد خروجی در نظر گرفته می‌شود.

یادگیری پارامترهای شبکه عمیق با توجه به N داده‌ی آموزشی به صورت یک مسئله بهینه‌سازی مطرح می‌شود. بدین صورت که در یک مسئله با هدف دسته‌بندی، هر ردیف از X یک داده را در \mathbb{R}^D مشخص می‌کند و هر Y یکی از اعضای کلاس‌های خروجی (C) را مشخص می‌کند. بر این اساس فرایند یادگیری به صورت زیر صورت می‌گیرد [۵۲].

$$Y \in \mathbb{R}^{N \times C}, \quad X \in \mathbb{R}^{N \times D}$$

$$\text{Min } \ell(Y, \Phi(X, W^1, W^2, \dots, W^k)) + \lambda \Theta(W^1, W^2, \dots, W^k) \quad (4)$$

در رابطه فوق، یک تابع زیان^۱ ($\ell(Y, \Phi)$) تفاوت بین کلاس‌های از پیش تعیین شده (Y) و کلاس‌های پیش‌بینی شده بر اساس رابطه ۳ را مشخص می‌کند. همچنین یک تابع تنظیم^۲ (Θ) برای جلوگیری از اضافه برازش^۳ مدل و λ به عنوان پارامتر تعدیل با مقدار مثبت در نظر گرفته می‌شود. برای اطلاعات بیشتر در مورد ساختار مدل‌های یادگیری عمیق میتوان به مراجع [۵۲، ۵۳] مراجعه نمود.


یادگیری عمیق به عنوان یکی از تکنیک‌های یادگیری ماشین را می‌توان برای هر سه نوع یادگیری (تحت نظارت، بدون نظارت و نیمه نظارتی) به کار گرفت و کاربرد گسترده‌ای در آنالیز داده‌های عظیم، تشخیص گفتار، تشخیص اجسام، بینایی ماشین، علم رباتیک، خودروهای خودران و ... دارد [۳۲، ۳۷، ۵۴].

۳-۲- شبکه عصبی پیچشی


شبکه‌های عصبی پیچشی نوع خاصی از مدل‌های یادگیری عمیق

4 Convolution Layers
5 Pooling Layers
6 Fully Connected Layers
7 Feature Map

1 Loss Function
2 Regularization Function
3 Overfitting



شکل ۴. فرایند تشکیل لایه‌های پیچشی
Fig. 4. Process of creating convolutional layers



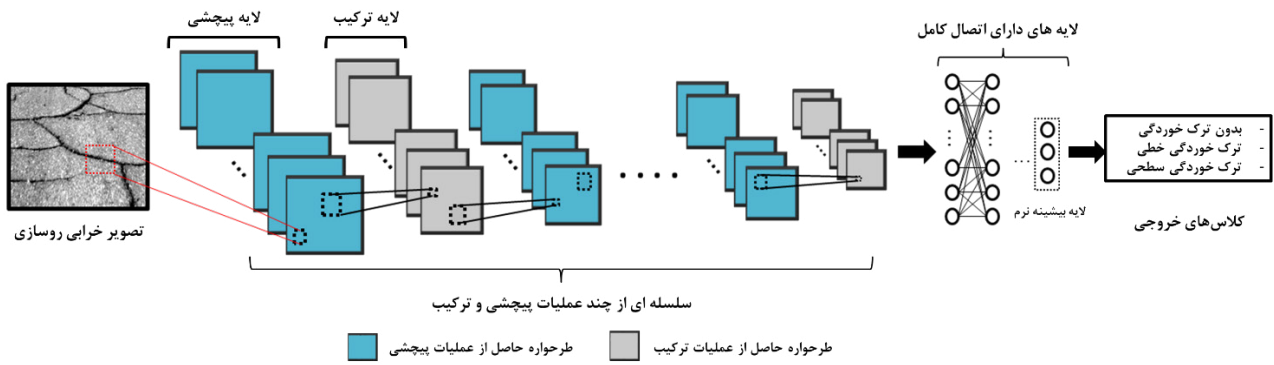
شکل ۵. نحوه ایجاد لایه ترکیب به روش الف: انتخاب بیشینه ب: میانگین
Fig. 5. Creating pooling layers using (a) max-pooling, (b) mean

خوردگی خطی و با ترک خوردگی سطحی در شکل ۶ ارائه شده است. در حالت کلی رایج‌ترین روش‌ها به منظور ایجاد شبکه‌های عصبی پیچشی عبارت‌اند از: (۱) ایجاد شبکه از پایه و انجام تمامی مراحل و الزامات ساخت شبکه و (۲) استفاده از روش انتقال یادگیری با بهره‌گیری از مدل‌های از پیش تعلیم یافته.


در روش اول، برای ایجاد شبکه نیاز است که تمامی اجزا و پارامترهای شبکه توسط افراد متخصص تعیین و طراحی شوند که این امر با توجه به پیچیدگی ساختار شبکه و گستردگی پارامترها نیازمند تخصص بالا و صرف وقت زیاد است. همچنین در این روش به منظور ایجاد شبکه کارآمد نیاز به حجم انبوهی از داده وجود دارد که این امر نیز موجب زمان بردن روند ساخت شبکه و نیاز به سیستم پردازشی قدرتمند خواهد شد. مولفه‌های مهم و تأثیرگذار بر عملکرد

لایه‌های دارای اتصال کامل آخرین لایه‌های قرار گرفته در ساختار شبکه‌های عصبی پیچشی محسوب می‌شوند. این بخش می‌تواند از یک یا چند لایه تشکیل شود. در این لایه‌ها، مهمترین اطلاعات داده‌های ورودی جمع می‌شوند و می‌توان از این اطلاعات برای برخی از وظایف نظیر پیش‌بینی، دسته‌بندی استفاده نمود. آخرین لایه از لایه‌های دارای اتصال کامل، لایه بیشینه نرم است که اغلب در مسائل پیش‌بینی و دسته‌بندی کاربرد دارد و وظیفه تعیین احتمال وقوع هر یک از کلاس‌ها را بر عهده دارد. [۳۱، ۳۶، ۴۰، ۶۱، ۶۶-۶۸]

ساختار کلی شبکه عصبی پیچشی به کار گرفته شده در این پژوهش برای استخراج ویژگی‌ها و تشخیص خرابی ترک خوردگی و دسته‌بندی تصاویر روسازی به سه دسته بدون ترک خوردگی، با ترک



شکل ۶. ساختار شبکه عصبی پیش‌بینی در این مقاله
 Fig. 6. Structure of applied convolutional neural network



شکل ۷. به کارگیری روش انتقال یادگیری
 Fig. 7. Using the transfer learning method

زمان کمتر، با تعداد داده‌های کمتر و با صرف توان پردازشی کمتر را فراهم می‌آورد [۳۶، ۵۷، ۷۵-۷۷]. در شکل ۷ نمایی کلی از نحوه به کارگیری روش انتقال یادگیری در این پژوهش ارائه شده است. همانطور که در این شکل مشخص شده است، در این پژوهش از مدل‌های از پیش‌تعلیم یافته که بر اساس بیش از یک میلیون تصویر و با هدف دسته‌بندی تصاویر در ۱۰۰۰ دسته مختلف ایجاد شده‌اند برای ساخت مدل‌هایی بر اساس ۱۵۰۰ تصویر و با هدف دسته‌بندی تصاویر در سه دسته استفاده شده است.

۴-۲- مدل‌های از پیش‌تعلیم یافته

به منظور بهره‌گیری از تکنیک انتقال یادگیری، از شبکه‌های از

شبکه شامل مولفه‌هایی نظیر عمق شبکه (تعداد لایه‌های پیش‌بینی، ترکیب و اتصال کامل)، تعداد فیلترها، تعداد گام‌ها ناحیه محلی در فرایند ساخت لایه‌های پیش‌بینی، مکان، سایز و نوع عملیات ترکیب، تعداد اجزای لایه دارای اتصال کامل و بسیاری از موارد دیگر است که تعیین حالت بهینه برای عملکرد شبکه نیاز به تخصص بالا دارد و معمولاً در یک روند سعی و خطا انجام می‌شود [۵۵، ۷۰]. لازم به ذکر است که اخیراً تعیین این مولفه‌ها به عنوان یک چالش بهینه‌سازی برای محققان مطرح شده است [۵۵، ۷۱-۷۴].

در روش دوم، از قابلیت یادگیری و استخراج ویژگی‌ها اساسی در شبکه‌های از پیش‌تعلیم یافته برای تعلیم مجدد شبکه بر اساس داده‌های جدید استفاده می‌شود و این امر امکان ساخت مدل در

جدول ۱. مشخصات و اطلاعات مدل‌های از پیش تعلیم یافته
Table 1. More information on pre-trained models

مدل از پیش تعلیم یافته	اندازه تصاویر ورودی	عمق شبکه (تعداد لایه ها)	تعداد پارامترها (میلیون)	اندازه مدل (مگابایت)	تعداد داده مورد استفاده در ساخت شبکه	تعداد دسته‌های خروجی
AlexNet	(۲۲۷×۲۲۷×۳)	۸	۶۱	۲۲۷	بیش از یک میلیون تصویر از پایگاه داده ImageNet	۱۰۰۰
SqueezeNet	(۲۲۷×۲۲۷×۳)	۱۸	۱/۲۴	۴/۶		
GoogleNet	(۲۲۴×۲۲۴×۳)	۲۲	۷	۲۷		
ResNet-18	(۲۲۴×۲۲۴×۳)	۱۸	۱۱/۷	۴۴		
ResNet-50	(۲۲۴×۲۲۴×۳)	۵۰	۲۵/۶	۹۶		
ResNet-101	(۲۲۴×۲۲۴×۳)	۱۰۱	۴۴/۶	۱۶۷		
Inception-V3	(۲۹۹×۲۹۹×۳)	۴۸	۲۳/۹	۸۹		
DenseNet-201	(۲۲۴×۲۲۴×۳)	۲۰۱	۲۰	۷۷		

شده است. در این روش، توزیع مقادیر پیکسل‌های تصویر گسترده‌تر و شدت مقادیر متعادل‌تر می‌شود و در نتیجه تصاویری با روشنی و وضوح بالاتری را ایجاد می‌کند [۱۴، ۸۶-۸۸]. در شکل ۸ نمونه‌هایی از تاثیر این تکنیک بر وضوح تصاویر ارائه شده است.

۳- انجام مدل‌سازی

در این بخش، روند ساخت مدل‌های دسته‌بندی و تشخیص خرابی ترک خوردگی تشریح خواهد شد. روند انجام پژوهش از دو قسمت اصلی تشکیل شده است که شامل آماده‌سازی داده‌های ورودی و تنظیم پارامترهای اصلی و موثر بر فرایند یادگیری است.

۳-۱- آماده‌سازی پایگاه داده

به منظور ساخت مدل‌های تشخیص و دسته‌بندی خرابی ترک خوردگی روسازی، در ابتدا باید مجموعه‌ای از داده‌های با کیفیت برای استفاده به عنوان ورودی در فرایند یادگیری ایجاد شود. با توجه به اینکه در اکثر سازمان‌ها برداشت تصاویر روسازی در شرایط نوری مناسب و در روز انجام می‌شود، در این پژوهش با فرض اینکه تصاویر در شرایط مناسب و در روز برداشت شده باشند، پایگاه داده‌ای متشکل از سه دسته از تصاویر روسازی ساخته شده است که شامل تصاویر بدون ترک خوردگی، تصاویر دارای ترک خطی و تصاویر دارای ترک سطحی می‌شود. لازم به ذکر است که هرچه تنوع و تعداد تصاویر در هر دسته بیشتر باشد، احتمال بروز مشکل اضافه برآزش^۲ کاهش

پیش تعلیم یافته برای ساخت شبکه مورد نظر استفاده می‌شود. این شبکه‌ها توسط متخصصین بر اساس مناسب‌ترین پارامترها و بهترین ساختار شبکه روی تعداد بسیار زیاد داده (۱/۲ میلیون تصویر) برای دسته بندی تصاویر در ۱۰۰۰ دسته ایجاد شده‌اند. در این پژوهش عملکرد مدل‌های ایجاد شده به روش انتقال یادگیری بر اساس هشت شبکه از پیش تعلیم یافته برای تشخیص و دسته بندی ترک‌های روسازی مورد ارزیابی قرار داده شده است. هشت مدل از پیش تعلیم یافته عبارت‌اند از ResNet-18، ResNet-50، ResNet-101، esNet-18. در جدول ۱ مشخصات و اطلاعات تکمیلی مربوط به شبکه‌های از پیش تعلیم یافته که در این مقاله مورد بررسی قرار گرفته‌اند ارائه شده است.

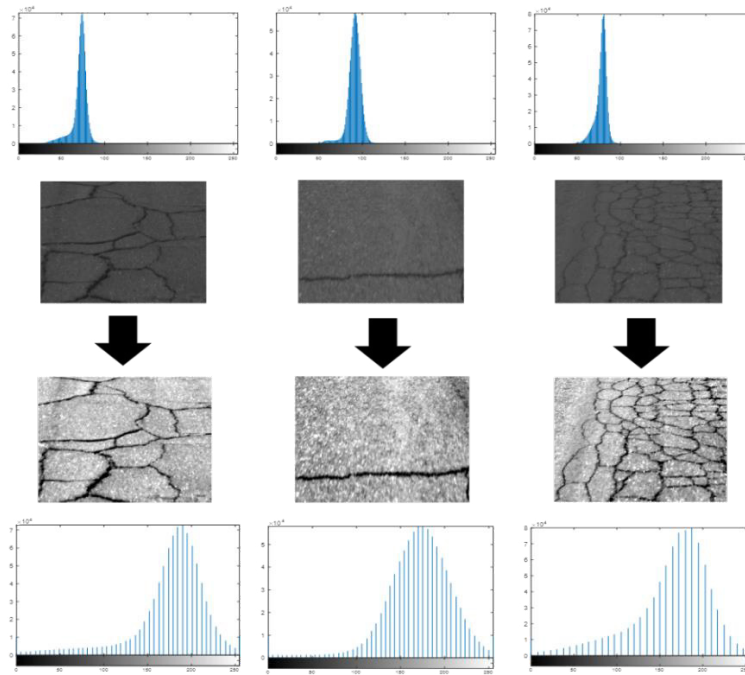
همان‌طور که در جدول ۱ مشاهده می‌شود، با توجه به اختلاف زیاد در ویژگی‌هایی نظیر عمق شبکه و تعداد پارامترها می‌توان انتظار داشت که مدل‌ها عملکرد متفاوتی از نظر سرعت و دقت ارائه دهند.

۵-۲- پیش پردازش تصاویر


به طور معمول تصاویر برداشت شده از سطح روسازی کیفیت لازم برای استفاده به عنوان ورودی فرایند ساخت مدل‌های دسته‌بندی را ندارند. بر همین اساس قبل ورود تصاویر به فرایند ساخت مدل از روش تعدیل هیستوگرام^۱ به منظور افزایش وضوح تصاویر، استفاده

2 Overfitting

1 Histogram Equalization



شکل ۸. تأثیر روش متعادل‌سازی هیستوگرام بر وضوح و کیفیت تصاویر
 Fig. 8. Effect of histogram equalization on clarity and quality of images



شکل ۹. نمونه داده‌های به کار گرفته شده: الف: تصاویر دارای ترک سطحی، ب: تصاویر بدون ترک، ج: تصاویر دارای ترک خطی
 Fig. 9. Samples of image datasets: (a) surface cracking, (b) no-cracking, (c) linear cracking

عملیات یادگیری فراهم شود. با توجه به محدودیت‌های توان پردازش، برای این هدف در هر یک از دسته‌های پایگاه داده ۵۰۰ تصویر با ابعاد 1000×900 در مقیاس خاکستری^۱ برای تعلیم مدل‌ها جمع‌آوری شده است که با توجه به حجم داده‌ها از این مقدار ۸۰ درصد برای عملیات یادگیری و مابقی برای عملیات اعتبارسنجی^۲ در نظر گرفته

می‌باید ولی از سوی دیگر زمان تعلیم مدل‌ها افزایش می‌یابد و توان پردازشی بیشتری را می‌طلبد.

در دانش داده‌کاوی کیفیت مناسب داده‌ها تأثیر بسیار عمیقی بر نتایج بدست آمده دارد. بر همین اساس در روند داده‌کاوی معمولاً ۸۰ درصد زمان پژوهش صرف فراهم کردن داده‌های مناسب خواهد شد و مابقی زمان به مدلسازی و ارزیابی اختصاص می‌یابد. در این مقاله تلاش شده است که داده‌هایی با کیفیت و تنوع کافی برای شروع

1 Gray Scale
 2 Validation

جدول ۲. داده‌های جمع‌آوری شده
Table 2. Collected datasets

عملیات ارزیابی	عملیات یادگیری		دسته بندی
	اعتبارسنجی	تعلیم	
۲۵۰	۱۰۰	۴۰۰	بدون ترک خوردگی
۲۵۰	۱۰۰	۴۰۰	ترک خوردگی خطی
۲۵۰	۱۰۰	۴۰۰	ترک خوردگی سطحی
۷۵۰	۱۵۰۰		مجموع

خواهد شد. در این پژوهش همانطور که در شکل ۱۰ نمایش داده شده است، با بررسی روند تعلیم مدل‌ها می‌توان گفت که نرخ خطا و دقت مدل‌ها تقریباً بعد از ۱۰ تا ۱۲ دوره پایدار گشته و فرایند یادگیری مدل‌ها به بالاترین دقت در هر تکرار می‌رسند. بر این اساس در این پژوهش ۱۵ دوره مناسب به نظر می‌رسد.

پارامتر مهم دیگری که قبل از شروع عملیات تعلیم مدل‌ها باید تعیین شود، تعداد نمونه‌ها (داده‌ها) در هر تکرار است. تعداد نمونه‌ها در هر تکرار می‌تواند بین یک تا تعداد داده‌های تعلیم انتخاب شود. تعداد زیاد نمونه‌ها در هر تکرار نیازمند سیستم پردازشی قدرتمند است. در این مقاله با توجه به توان پردازشی، تعداد ۱۵ نمونه در هر تکرار در نظر گرفته شده است. تعداد تکرار لازم برای انجام یک دوره یادگیری با استفاده از رابطه ۵ تعیین می‌شود.

$$i = \frac{N}{n} \quad (5)$$

که در رابطه فوق N تعداد کل داده‌های تعلیم و n تعداد نمونه در هر تکرار است.

با توجه به در نظر گرفتن ۱۵ نمونه در هر تکرار، ۸۰ تکرار برای انجام یک دوره یادگیری متشکل از ۱۲۰۰ نمونه (داده) نیاز است و در مجموع برای انجام ۱۵ دوره یادگیری، ۱۲۰۰ تکرار باید انجام شود. لازم به ذکر است که اگر تعداد تکرار خیلی زیاد باشد منجر به بروز مشکلاتی نظیر اضافه برآزش و افزایش زمان پردازش خواهد شد. نرخ یادگیری و مقدار تکانه پارامترهای دیگری هستند که در نتیجه

شده است. همچنین برای هر یک از دسته‌ها ۲۵۰ تصویر متفاوت از تصاویر تعلیم، برای ارزیابی مدل در نظر گرفته شده است. در شکل ۹ چند نمونه از تصاویر به کار گرفته شده در این پژوهش به منظور ساخت مدل‌ها نمایش داده شده است.


همانطور که در جدول ۲ مشاهده می‌شود، در مجموع ۱۵۰۰ تصویر در روند یادگیری مدل‌ها استفاده شده است که از این تعداد ۱۲۰۰ تصویر برای تعلیم و ۳۰۰ تصویر برای اعتبارسنجی به کار گرفته شده است. همچنین در مجموع ۷۵۰ تصویر برای ارزیابی مدل‌ها جمع‌آوری و استفاده شده است.

۲-۳- پارامترهای اساسی فرایند یادگیری

پیش از آغاز فرایند ساخت مدل‌ها، باید برخی از پارامترهای موثر در روند یادگیری تعیین شوند که از آن جمله می‌توان به تعداد دوره‌ها^۱، تعداد داده در تکرار^۲، تعداد تکرار^۳، نرخ یادگیری^۴ و مقدار تکانه^۵ اشاره نمود. در این بخش توضیحاتی پیرامون تنظیم این پارامترها ارائه شده است.

تعداد دوره‌های یادگیری به تعداد دفعاتی که تمامی داده‌های تعلیم در روند یادگیری مدل‌ها به کار گرفته می‌شوند، اطلاق می‌شود. در صورتی که تعداد دوره‌ها زیاد در نظر گرفته شوند، سبب بروز مشکلاتی نظیر اضافه برآزش و افزایش زمان پردازش می‌شود. از سوی دیگر، کم بودن تعداد دوره‌ها سبب ناقص انجام شدن فرایند یادگیری

- 1 Epoch
- 2 Batch Size
- 3 Iterations
- 4 Learning Rate
- 5 Momentum



شکل ۱۰. نمونه ای از روند تعلیم مدلها
Fig. 10. Sample of the training process

جدول ۳. زمان طی شده در مراحل مختلف (ثانیه)
Table 3. The Spent time in various stages (second)

مدل	زمان پیش پردازش (برای هر تصویر)	زمان تعلیم مدلها (برای هر تصویر)	زمان ارزیابی مدلها (برای هر تصویر)
AlexNet	۰/۴۸۲	۰/۰۱۹	
SqueezeNet	۰/۳۸۳	۰/۰۱۷	
GoogleNet	۰/۶۳۷	۰/۰۲۴	
ResNet-18	۰/۶۴۴	۰/۰۲۱	۰/۰۵۸
ResNet-50	۱/۹۴۴	۰/۰۴۱	
ResNet-101	۳/۸۲۳	۰/۰۵۴	
DenseNet-201	۱۲/۹۰۸	۰/۰۸۹	
Inception-V3	۲/۹۵۱	۰/۰۵۳	

یادگیری تأثیر داشته و اغلب در مطالعات مختلف به ترتیب ۰/۰۰۱ و ۰/۹ در نظر گرفته می‌شوند.

در این مقاله، پارامترهای تأثیرگذار بر عملیات یادگیری در تمامی مدل‌های از پیش تعلیم یافته به صورت یکسان در نظر گرفته شده اند ولی برای مدل ResNet-101 به علت محدودیت توان پردازشی و بالا بودن عمق و تعداد پارامترهای مدل (مطابق جدول ۱) منجر به عدم کفایت فضای حافظه برای انجام عملیات یادگیری می‌شود. به همین دلیل تعداد نمونه در هر تکرار مدل ResNet-101 برابر ۱۲ در نظر گرفته شده است.

تمامی پردازش‌ها و محاسبات انجام شده در این مقاله با استفاده از یک کامپیوتر شخصی با سیستم اجرایی ۶۴ بیتی، ۸ گیگا بایت فضای حافظه، پردازنده Intel(R) Core i7-4710HQ @ 2.50 GHz و پردازنده گرافیکی GeForce GTX 850M انجام شده اند. همچنین عملیات پردازش تصویر و پیاده‌سازی یادگیری عمیق در نرم افزار MATLAB 2018b اجرا شده است.


سرعت مدل‌ها در یادگیری و اجرا و دقت مدل‌ها در تشخیص و دسته بندی ترک‌ها به عنوان دو پارامتر اصلی عملکرد مدل‌ها در ادامه ارائه شده است.

۴-۱- سرعت یادگیری و دسته بندی داده‌های جدید


همانطور که در جدول ۳ نمایش داده شده است برای ارزیابی سرعت مدل‌ها، زمان طی شده در فرایندهای پیش پردازش تصاویر، یادگیری و ارزیابی مدل‌ها مورد بررسی قرار گرفته است. با توجه به این که عملیات پیش‌پردازش پیش از تعلیم و

۴- نتایج

پس از انجام فرایند یادگیری مدل‌ها بر اساس داده‌های تعلیم و ارزیابی دقت بر اساس داده‌های آزمون، نتایج به دست آمده از ارزیابی



شکل ۱۱. مقایسه سرعت مدلها در عملیات یادگیری
Fig. 11. Speed of models in the training process



شکل ۱۲. مقایسه سرعت مدلها در عملیات ارزیابی
Fig. 12. Speed of models in the testing process

خود اختصاص داده است. مدل‌های AlexNet، GoogleNet، SqueezeNet، ResNet-18 با انجام فرایند یادگیری در کمتر از یک ثانیه و انجام عملیات ارزیابی تصاویر جدید در کمتر از ۰/۱ ثانیه، سرعت بالاتری نسبت به سایر مدل‌ها در عملیات یادگیری و ارزیابی داشته اند.

در بین مدل‌های ارزیابی شده، مدل SqueezeNet با صرف زمان ۰/۴۴۲ ثانیه برای هر تصویر در عملیات یادگیری و ۰/۰۷۶

ارزیابی مدل‌ها انجام می‌شود، در شکل‌های ۱۱ و ۱۲ مقایسه‌ی سرعت عملکرد مدل‌ها در عملیات یادگیری (پیش پردازش و آموزش) و عملیات ارزیابی (پیش پردازش و ارزیابی) ارائه شده است. همانطور که در این شکل‌ها مشاهده می‌شود در عملیات یادگیری بخش ناچیزی از زمان عملیات به پیش پردازش داده‌ها اختصاص یافته است. از سوی دیگر فرایند پیش‌پردازش تصاویر در عملیات ارزیابی عملکرد مدل‌ها، بخش قابل توجهی از زمان را به

جدول ۴. ارزیابی جامع عملکرد مدلها
Table 4. Performance of models

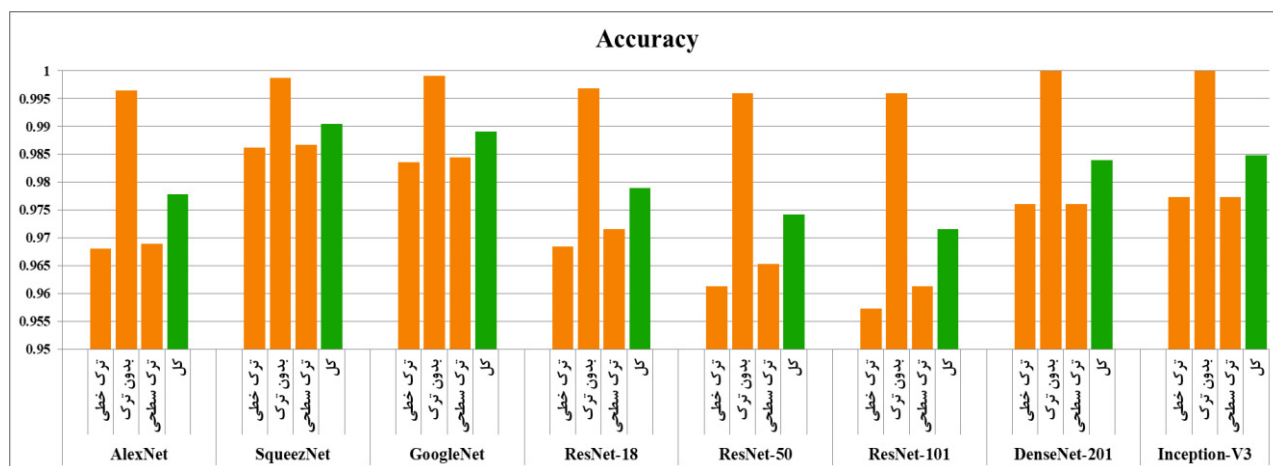
مدل	دسته	Accuracy	Sensitivity	Specificity	Precision	F-score
AlexNet	ترک خطی	0.968	0.951	0.977	0.953	0.952
	بدون ترک	0.996	0.999	0.995	0.991	0.995
	ترک سطحی	0.969	0.951	0.978	0.957	0.953
	کل	0.978	0.967	0.983	0.967	0.967
SqueezeNet	ترک خطی	0.986	0.989	0.985	0.970	0.980
	بدون ترک	0.999	0.999	0.999	0.997	0.998
	ترک سطحی	0.987	0.969	0.995	0.991	0.980
	کل	0.991	0.986	0.993	0.986	0.986
GoogleNet	ترک خطی	0.984	0.980	0.985	0.971	0.975
	بدون ترک	0.999	0.997	1.000	1.000	0.999
	ترک سطحی	0.984	0.973	0.990	0.980	0.977
	کل	0.989	0.984	0.992	0.984	0.984
ResNet-18	ترک خطی	0.968	0.964	0.971	0.943	0.953
	بدون ترک	0.997	0.999	0.996	0.992	0.995
	ترک سطحی	0.972	0.943	0.986	0.971	0.957
	کل	0.979	0.968	0.984	0.969	0.968
ResNet-50	ترک خطی	0.961	0.932	0.976	0.951	0.941
	بدون ترک	0.996	1.000	0.994	0.988	0.994
	ترک سطحی	0.965	0.952	0.972	0.944	0.948
	کل	0.974	0.961	0.981	0.961	0.961
ResNet-101	ترک خطی	0.957	0.948	0.962	0.926	0.937
	بدون ترک	0.996	0.988	1.000	1.000	0.994
	ترک سطحی	0.961	0.936	0.974	0.947	0.942
	کل	0.972	0.957	0.979	0.958	0.957
DenseNet-202	ترک خطی	0.976	0.964	0.982	0.964	0.964
	بدون ترک	1.000	1.000	1.000	1.000	1.000
	ترک سطحی	0.976	0.964	0.982	0.964	0.964
	کل	0.984	0.976	0.988	0.976	0.976
Inception-V3	ترک خطی	0.977	0.972	0.980	0.960	0.966
	بدون ترک	1.000	1.000	1.000	1.000	1.000
	ترک سطحی	0.977	0.960	0.986	0.972	0.966
	کل	0.985	0.977	0.989	0.977	0.977

ثانیه به ازای هر تصویر در عملیات ارزیابی، سریع‌ترین عملکرد و مدل DenseNet-201 با صرف زمان ۱۲/۹۶۶ و ۰/۱۴۸ ثانیه به ترتیب برای یادگیری و ارزیابی، کندترین عملکرد را داشته است.

۲-۴- دقت مدلها

تشکیل ماتریس درهم ریختگی^۱ یکی از بهترین روش‌های ارزیابی

1 Confusion Matrix



شکل ۱۳. ارزیابی عملکرد مدلها بر اساس معیار Accuracy
Fig. 13. Performance of models based on the accuracy index

می‌دهد.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

ارزیابی دقت و مقایسه عملکرد مدل‌ها برای دسته بندی تصاویر در دسته های تعریف شده و همچنین عملکرد کلی مدل‌ها بر اساس معیار accuracy در شکل ۱۳ ارائه شده است. همانطور که در این شکل مشاهده می‌شود، بر اساس این معیار تمامی مدل‌ها بهترین عملکرد را دسته بندی و تشخیص تصاویر بدون ترک خوردگی دارند و پس از آن بیشترین پاسخ صحیح در تشخیص خرابی ترک خوردگی سطحی ارائه شده است. همچنین بر اساس این معیار، مدل‌های GoogleNet و SqueezeNet عملکرد بهتری نسبت به سایر مدل‌ها در تشخیص و دسته بندی تصاویر دارای ترک خوردگی سطحی و خطی دارند. به طور کلی تمامی مدل‌ها عملکرد مناسبی ارائه داده اند و عملکرد کلی مدل‌ها بر اساس این معیار در محدوده ۰/۹۷۲ تا ۰/۹۹۱ قرار دارد که بهترین عملکرد مربوط به مدل SqueezeNet است و ضعیف ترین عملکرد را مدل ResNet-101 دارد.

۴-۲-۲-۲ معیار Sensitivity

این معیار میزان توانایی و حساسیت مدل‌ها را در انجام دسته‌بندی صحیح مشخص می‌کند. مطابق رابطه ۷ این امر با محاسبه نسبت پاسخ‌های مثبت صحیح به مجموع پاسخ‌های مثبت صحیح و پاسخ‌های منفی غلط انجام می‌شود. این معیار همچنین با نام‌های نرخ


دقت مدل‌های ایجاد شده برای انجام پیش‌بینی و دسته‌بندی به ویژه در مسائلی با بیش از دو دسته است [۸]. این ماتریس با مقایسه‌ی نتایج حاصل از مدل با واقعیت، پاسخ‌های به دست آمده از مدل‌ها در هر یک از دسته‌ها را با چهار حالت ممکن پاسخ مثبت صحیح (TP^1), پاسخ منفی صحیح (TN^2), پاسخ مثبت غلط (FP^3) و پاسخ منفی غلط (FN^4) بررسی می‌کند.

پس از تعیین اجزای ماتریس درهم ریختگی می‌توان کارایی و عملکرد مدل‌ها در دسته‌بندی و تشخیص صحیح ترک‌ها را با استفاده از چند معیار اساسی ارزیابی نمود. $sensitivity$, $accuracy$, $precision$, $specificity$ و F -score از جمله پرکاربردترین معیارها در ارزیابی عملکرد و دقت مدل‌ها در مسائل دسته‌بندی و پیش‌بینی هستند. در جدول ۴ مقادیر این معیارها برای هر یک از مدل‌ها ارائه شده است و این بخش از مقاله به مقایسه عملکرد مدل‌ها بر اساس معیارهای ذکر شده می‌پردازد.


۴-۲-۱-۱ معیار Accuracy

این معیار یکی از رایج‌ترین معیارهای ارزیابی مدل‌ها به شمار می‌رود و بر اساس رابطه ۶ یک نمای کلی از میزان دقت مدل‌ها با تعیین نسبت پاسخ‌های صحیح (TP و TN) به کل پاسخ‌ها ارائه

- 1 True Positive
- 2 True Negative
- 3 False Positive
- 4 False Negative



شکل ۱۴. ارزیابی عملکرد مدلها بر اساس معیار Sensitivity
Fig. 14. Performance of models based on the sensitivity index



شکل ۱۵. ارزیابی عملکرد مدلها بر اساس معیار Specificity
Fig. 15. Performance of models based on the specificity index

و در مواقع وقوع ترک خوردگی، عملکرد اغلب مدل ها (به غیر از ResNet-50) در تشخیص ترک خوردگی خطی بهتر از ترک خوردگی سطحی است.


ارزیابی متوسط حساسیت مدل ها در تمامی دسته ها و قرارگیری مقادیر در محدوده ۰/۹۵۷ تا ۰/۹۸۶، بیانگر عملکرد خوب مدل های ایجاد شده با تکنیک یادگیری عمیق است و مدل SqueezeNet با حساسیت ۰/۹۸۶ بهترین عملکرد را دارد و به عبارت دیگر در مواقعی که باید جواب مثبت بدهد به طور متوسط در ۹۸/۶ درصد موارد به درستی عمل کرده است. همچنین مدل GoogleNet با متوسط حساسیت ۰/۹۸۴ در جایگاه بعدی قرار دارد و در تشخیص تصاویر ترک خوردگی سطحی عملکرد بهتری نسبت به مدل SqueezeNet دارد.

پاسخ مثبت صحیح^۱ و میزان صحت^۲ مدل نیز شناخته می شود.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (7)$$

به عبارت دیگر معیار Sensitivity، حساسیت و صحت عملکرد مدل ها در مواقعی که باید پاسخ مثبت داشته باشند را ارزیابی می کند. مقایسه حساسیت مدل ها در دسته بندی صحیح تصاویر در شکل ۱۴ ارائه شده است. همانطور که در این شکل مشاهده می شود، مدل های ارزیابی شده در این پژوهش بیشترین حساسیت و صحت را در تشخیص و دسته بندی تصاویر بدون ترک خوردگی دارند

- 1 True Positive Rate
- 2 Recall



شکل ۱۶. ارزیابی عملکرد مدلها بر اساس معیار Precision
 Fig. 16. Performance of models based on the precision index

۴-۲-۴- معیار Precision

این معیار یکی از پارامترهای مهم در ارزیابی مدلها است که میزان دقت و اعتماد پذیری پاسخهای مثبت مدلها را مشخص می‌کند یا به عبارت دیگر احتمال صحیح بودن پاسخهای مثبت مدلها را تعیین می‌کند. این معیار با نام ارزش پیش‌بینی مثبت^۲ نیز شناخته می‌شود و مطابق رابطه ۹ محاسبه می‌شود.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (9)$$

مطابق جدول ۴ عملکرد کلی مدلها با بررسی متوسط این معیار در تمامی دسته‌ها در محدوده ۰/۹۵۸ تا ۰/۹۸۶ قرار دارد که بیانگر عملکرد مناسب مدلها است. به عبارت دیگر با توجه به ارزیابی این معیار می‌توان با سطح اعتماد بالایی به پاسخهای مثبت مدلها ایجاد شده اعتماد کرد. همانطور که در شکل ۱۶ مشاهده می‌شود، پاسخ مثبت مدلها در تشخیص و دسته‌بندی تصاویر بدون ترک دارای بیشترین ارزش (سطح اعتماد) در تمام مدلها است و پس از آن، پاسخهای مثبت مدلها (به غیر از ResNet-50) در دسته ترک سطحی ارزش بالاتری نسبت به دسته ترک خطی دارد. همچنین با توجه به این معیار پاسخهای مثبت مدل SqueezeNet با متوسط ۰/۹۸۶ دارای بالاترین ارزش در بین مدلها است.

2 Positive Predictive Value

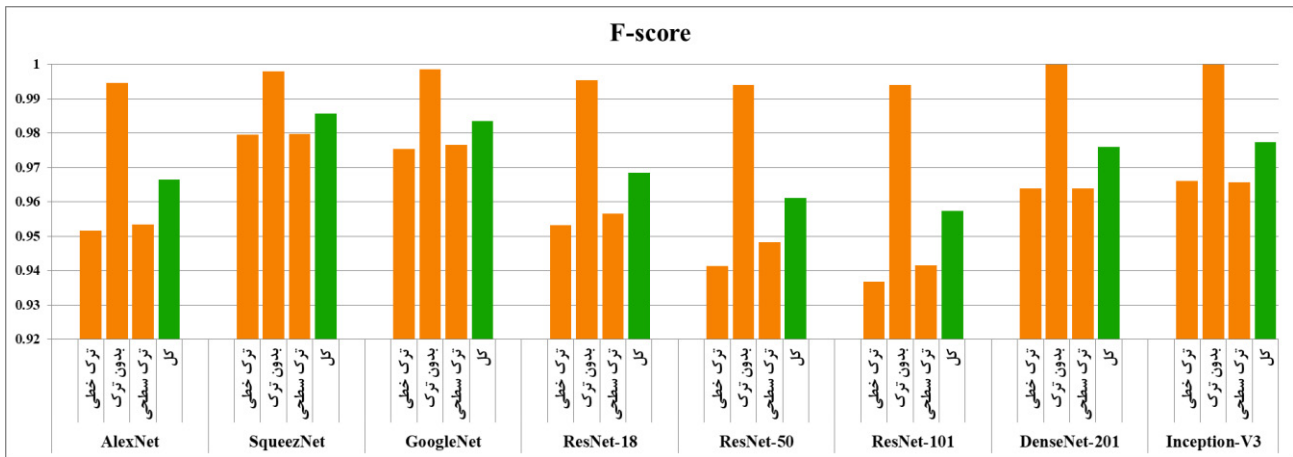
۴-۲-۳- معیار Specificity

مطابق رابطه ۸، این معیار میزان توانایی مدلها در ایجاد تمایز بین دسته‌ها را با تعیین نسبت پاسخهای منفی صحیح به مجموع پاسخهای مثبت غلط و پاسخهای منفی صحیح مشخص می‌کند. این معیار مفهومی مشابه sensitivity را برای پاسخهای منفی ارائه می‌کند و با نام نرخ پاسخهای منفی صحیح^۱ نیز شناخته می‌شود.

$$\text{Specificity} = \frac{TN}{FP + TN} \quad (8)$$

در شکل ۱۵ عملکرد مدلها در مواقعی که باید پاسخ منفی بدهند، مقایسه و ارزیابی شده است و همانطور که مشاهده می‌شود در این معیار نیز مشابه سایر معیارها بهترین عملکرد مدلها در دسته‌بندی تصاویر بدون ترک است و اغلب مدلها (به غیر از ResNet-50) در ارائه پاسخ منفی صحیح برای تصاویر ترک خوردگی سطحی عملکرد بهتری نسبت به ترک خوردگی خطی دارند. با ارزیابی متوسط این معیار در همه دسته‌ها برای هر مدل مشخص می‌شود که مدلهای SqueezeNet و GoogleNet به ترتیب با متوسط ۰/۹۹۳ و ۰/۹۹۲ عملکرد بهتری نسبت به سایر مدلها دارند. همچنین قرارگیری مقادیر این معیار در محدوده ۰/۹۷۹ تا ۰/۹۹۳ و مقایسه آن با معیار Sensitivity می‌تواند بیانگر عملکرد بهتر مدلها در ارائه پاسخ منفی نسبت به پاسخ مثبت باشد.

1 True Negative Rate



شکل ۱۷. ارزیابی عملکرد مدلها بر اساس معیار F-score
Fig. 17. Performance of models based on the F-score index

۵-۲-۴- معیار F-score

یکی از جامع‌ترین معیارهای ارزیابی دقت و عملکرد مدل‌های دسته‌بندی و پیش‌بینی، معیار F-score است که مطابق رابطه ۱۰ با محاسبه میانگین همساز وزنی^۱ دو معیار Precision و Sensitivity تعیین می‌شود.

$$F\text{-score} = \frac{2}{\left(\frac{1}{\text{Precision}} + \frac{1}{\text{Sensitivity}}\right)} \quad (10)$$

با توجه به شکل ۱۷، بر اساس این معیار که یک دید جامع از عملکرد مدل‌ها ارائه می‌دهد، عملکرد اغلب مدل‌ها در تشخیص و دسته‌بندی تصاویر ترک خوردگی خطی و سطحی یکسان است و بهترین عملکرد مدل‌ها در دسته‌بندی تصاویر بدون ترک است. همچنین متوسط عملکرد مدل‌ها برای دسته‌های مختلف در محدوده ۰/۹۵۷ تا ۰/۹۸۶ قرار گرفته است که بیانگر توانایی بالای مدل‌های ایجاد شده با تکنیک یادگیری عمیق در تشخیص خرابی ترک خوردگی روسازی است.

بر اساس این معیار مشابه سایر معیارها، مدل‌های مدل‌های SqueezeNet و GoogleNet به ترتیب با متوسط ۰/۹۸۶ و ۰/۹۸۴ عملیات تشخیص و دسته‌بندی خرابی ترک خوردگی را با دقت بالاتری نسبت به سایر مدل‌ها انجام داده‌اند.

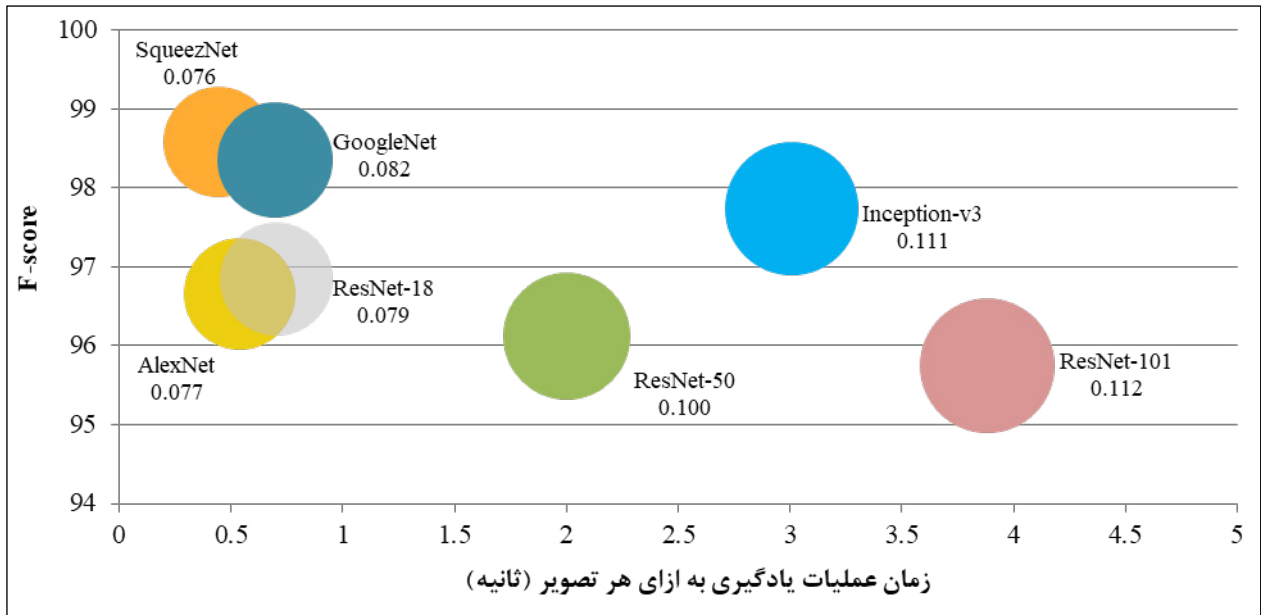
۵- جمع‌بندی

جاده‌ها به عنوان بخش اصلی زیرساخت‌های حمل و نقل جاده‌ای، نقش بسیار پر رنگی در رفع نیازهای بشر به جابه‌جایی و ارسال کالا ایفا می‌کند و توسعه کشورها تا حد زیادی به توسعه و مدیریت مناسب شبکه جاده‌ای گره خورده است. از سوی دیگر کیفیت و سلامت جاده‌ها تاثیر مستقیم بر ایمنی و راحتی این شیوه حمل و نقلی دارد و روسازی راه‌ها به عنوان بخش اصلی زیرساخت‌های جاده‌ای تاثیر زیادی بر کیفیت، راحتی و ایمنی حمل و نقل جاده‌ای دارد.

سالانه وقت و هزینه هنگفتی به منظور توسعه و تعمیر و نگهداری شبکه روسازی صرف می‌شود و تحقیقات زیادی برای بهبود عملکرد سامانه مدیریت روسازی انجام شده است که برداشت اطلاعات روسازی یکی از بخش‌های مهم این سامانه است و با توجه رشد روزافزون فناوری‌های مختلف، تلاش‌های گسترده‌ای به منظور پیاده‌سازی سامانه‌های خودکار برای برداشت دقیق اطلاعات روسازی انجام شده است.

دانش داده‌کاوی و یادگیری ماشین در سال‌های اخیر به علت پیشرفت علوم کامپیوتری و افزایش توان سامانه‌های ذخیره‌سازی داده به طور چشمگیری در علوم مختلف نظیر مهندسی، پزشکی، علوم مرتبط با تجارت و ... مورد توجه قرار گرفته است. همچنین در سال‌های اخیر پژوهش‌های متعددی به منظور بهره‌گیری از این علوم در مدیریت روسازی انجام شده است که بخش قابل

1 Weighted Harmonic Mean



شکل ۱۸. ارزیابی و مقایسه جامع عملکرد مدلها
 Fig. 18. A comprehensive comparison of models' performance

هر تصویر در عملیات یادگیری و ۰/۰۷۶ ثانیه بر تصویر در عملیات ارزیابی و همچنین متوسط ۹۸/۶ درصد در معیار F-score بهترین عملکرد را در بین مدل ها داشته است. همچنین لازم به ذکر است که در شکل ۱۸ مدل DenseNet-201 به علت عملکرد ضعیف در سرعت یادگیری (۱۲/۹۶۶ ثانیه به ازای هر تصویر) مورد ارزیابی قرار نگرفته است.

نتایج و خروجی این پژوهش را می توان در چند نکته مهم جمع بندی نمود که عبارت اند از:

- به کارگیری روش های مبتنی بر دانش داده کاوی و یادگیری ماشین در زمینه تشخیص و دسته بندی خرابی های روسازی نظیر ترک خوردگی، نتایج بسیار خوبی داشته و علیرغم هزینه اجرایی کم، دقت قابل توجهی ارائه کرده است.

- تکنیک یادگیری عمیق به عنوان یکی از مهمترین تکنیک های یادگیری ماشین نتایج قابل توجهی در به کارگیری هوش مصنوعی برای تشخیص خرابی ترک خوردگی روسازی دارد.

- روش بازتعلیم مدل های از پیش تعلیم یافته (انتقال یادگیری) به عنوان یکی از روش های پیاده سازی یادگیری عمیق نتایج قابل قبولی در ارزیابی تصاویر و خرابی ترک خوردگی روسازی دارد. به ویژه در مواقعی که داده های زیادی به منظور تعلیم مدل ها در دسترس

توجهی از آن ها در زمینه تشخیص خودکار خرابی های روسازی با توجه به داده های برداشت شده از شبکه روسازی بوده است. در بین خرابی های روسازی، خرابی ترک خوردگی یکی از رایج ترین خرابی ها است و اثرات مخرب زیادی در سطح کیفی روسازی دارد.

در این مقاله ضمن تشریح مباحث تئوری با به کارگیری داده کاوی و یادگیری ماشین، هشت مدل مبتنی بر شبکه های پیچشی عمیق به روش انتقال یادگیری برای تشخیص و دسته بندی ترک های روسازی ایجاد شد و عملکرد هر یک از مدل ها از جنبه های مختلف نظیر سرعت یادگیری، سرعت اجرا (ارزیابی) و دقت مورد ارزیابی و مقایسه قرار گرفت. ارزیابی جامع مدل های تولید شده در این پژوهش با در نظر گرفتن تمامی پارامتر های عملکردی (سرعت یادگیری، سرعت ارزیابی و دقت) در شکل ۱۸ ارائه شده است که در این شکل مساحت حباب ها و محور افقی به ترتیب بیانگر سرعت ارزیابی و یادگیری مدل به ازای هر تصویر است و محور قائم بیانگر معیار F-score به عنوان معیار جامع ارزیابی دقت و صحت مدل است.

بدیهی است که در شکل ۱۸ هرچه حباب ها کوچکتر باشند و مکان آن ها بالاتر و به سمت چپ متمایل تر باشد بیانگر عملکرد بهتر مدل ها خواهد بود. بر همین اساس در این پژوهش مدل SqueezeNet بهترین عملکرد را با سرعت ۰/۴۴۲ ثانیه به ازای

ساده یا روش های مبتنی بر پردازش تصویر می تواند موضوع مناسبی
برای مطالعات آینده باشد.

مراجع

- [1] Y. Shi, S. Guo, P. Sun, The role of infrastructure in China's regional economic growth, *Journal of Asian Economics*, 49 (2017) 26-41.
- [2] E. Ivanova, J. Masarova, Importance of road infrastructure in the economic development and competitiveness, *Economics Management*, 18(2) (2013) 263-274.
- [3] R. Engström, The Roads' Role in the Freight Transport System, *Transportation Research Procedia*, 14 (2016) 1443-1452.
- [4] C.Y. Chan, B. Huang, X. Yan, S. Richards, Investigating effects of asphalt pavement conditions on traffic accidents in Tennessee based on the pavement management system (PMS), *Journal of advanced transportation*, 44(3) (2010) 150-161.
- [5] ASCE, 2017 infrastructure report card, Roads, ASCE Reston, VA, 2017.
- [6] M.Y. Shahin, Pavement management for airports, roads, and parking lots, 1994.
- [7] H. Zakeri, F.M. Nejad, A. Fahimifar, Image Based Techniques for Crack Detection, Classification and Quantification in Asphalt Pavement: A Review, *Archives of Computational Methods in Engineering*, 24(4) (2017) 935-977.
- [8] H. Zakeri, F.M. Nejad, A. Fahimifar, Rahbin: A quadcopter unmanned aerial vehicle based on a systematic image processing approach toward an automated asphalt pavement inspection, *Automation in Construction*, 72(Part 2) (2016) 211-235.
- [9] C. Koch, K. Georgieva, V. Kasireddy, B. Akinici, P. Fieguth, A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure, *Advanced Engineering Informatics*, 29(2) (2015) 196-210.
- [10] T.B. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017) 1374822.

نباشد.

- مشخصه های مدل های از پیش تعلیم یافته (عمق، تعداد پارامترها و ...) تاثیر زیادی در عملکرد مدل های ایجاد شده به روش انتقال یادگیری خواهد داشت.

- آماده سازی داده ها مهمترین گام در به کارگیری دانش داده کاوی و یادگیری ماشین است و تاثیر مستقیم در نتایج بدست آمده خواهد داشت. به عبارت دیگر هرچه داده های غنی تر و متنوع تر برای عملیات یادگیری استفاده شود نتایج بهتری از مدل های ساخته شده به دست خواهد آمد.

- به طور کلی تصمیم گیری در مورد استفاده از مدل ها و روش یادگیری مدل ها به عواملی نظیر توان سیستم پردازشی، میزان و کیفیت داده های موجود و میزان سطح عملکرد (سرعت و دقت) مورد نیاز بستگی دارد.

۱-۵- مطالعات آینده

در این بخش با توجه به انجام پژوهش حاضر، ضرورت انجام پژوهش های بیشتر احساس می شود و بر همین اساس چند پیشنهاد ارائه می گردد.

- پارامترهای اساسی یادگیری نظیر تعداد دوره ها، نرخ یادگیری، تعداد تکرار و ... تاثیر بسیار زیادی در زمان و کیفیت یادگیری مدل ها دارند و در اغلب مطالعات به صورت تجربی و با سعی و خطا تعیین می شوند و این نیاز احساس می شود که تحقیقاتی با هدف بهینه سازی این پارامترها صورت گیرد.

- تعداد داده های مورد استفاده برای تعلیم مدل ها از جمله پارامترهای تاثیرگذار در زمان یادگیری و عملکرد مدل ها است و نیاز است که پژوهش هایی با هدف تعیین بهینه ترین تعداد داده برای انجام عملیات یادگیری در کمترین زمان و با بهترین عملکرد انجام شود.

- با توجه به عملکرد مناسب مدل های ایجاد شده با استفاده از شبکه های پیچشی عمیق، انجام پژوهش هایی به منظور ساخت مدل های بهینه شده برای تشخیص، دسته بندی و ارزیابی شدت انواع خرابی های روسازی ضروری به نظر می رسد.

- مقایسه عملکرد شبکه های پیچشی عمیق به کار گرفته شده در این مقاله با روش های دیگر نظیر روش های مبتنی بر شبکه عصبی

- Journal of computing in civil engineering, 30(6) (2016) 04016015.
- [21] M. Solla, S. Lagüela, H. González-Jorge, P. Arias, Approach to identify cracking in asphalt pavement using GPR and infrared thermographic methods: Preliminary findings, *NDT & E International*, 62 (2014) 55-65.
- [22] H. Song, K. Baek, Y. Byun, Pothole detection using machine learning, *Advanced science and technology letters*, 150 (2018) 151-155.
- [23] M.R. Carlos, M.E. Aragón, L.C. González, H.J. Escalante, F. Martínez, Evaluation of Detection Approaches for Road Anomalies Based on Accelerometer Readings--Addressing Who's Who, *IEEE Transactions on Intelligent Transportation Systems*, (2018).
- [24] A. Fox, B.V. Kumar, J. Chen, F. Bai, Multi-lane pothole detection from crowdsourced undersampled vehicle sensor data, *IEEE Transactions on Mobile Computing*, 16(12) (2017) 3417-3430.
- [25] S. Nakashima, S. Aramaki, Y. Kitazono, S. Mu, K. Tanaka, S. Serikawa, Application of ultrasonic sensors in road surface condition distinction methods, *Sensors*, 16(10) (2016) 1678.
- [26] A. Bystrov, E. Hoare, T.-Y. Tran, N. Clarke, M. Gashinova, M. Cherniakov, Road surface classification using automotive ultrasonic sensor, *Procedia Engineering*, 168 (2016) 19-22.
- [27] R. Madli, S. Hebbar, P. Pattar, V. Golla, Automatic detection and notification of potholes and humps on roads to aid drivers, *IEEE Sensors Journal*, 15(8) (2015) 4313-4318.
- [28] J. Mehta, V. Mathur, D. Agarwal, A. Sharma, K. Prakasha, Pothole Detection and Analysis System (Pol) AS for Real Time Data Using Sensor Networks, *Journal of Engineering and Applied Sciences*, 12(12) (2017) 3090-3097.
- [29] J. Huang, W. Liu, X. Sun, A pavement crack detection method combining 2D with 3D information based on Dempster-Shafer theory, *Computer-Aided Civil Infrastructure Engineering*, 29(4) (2014) 299-313.
- [30] G. Zhou, L. Wang, D. Wang, S. Reichle, Integration of GIS and data mining technology to enhance the pavement
- [11] N.-D. Hoang, An Artificial Intelligence Method for Asphalt Pavement Pothole Detection Using Least Squares Support Vector Machine and Neural Network with Steerable Filter-Based Feature Extraction, *Advances in Civil Engineering*, 2018 (2018) 12.
- [12] P. Wang, Y. Hu, Y. Dai, M. Tian, Asphalt Pavement Pothole Detection and Segmentation Based on Wavelet Energy Field, *Mathematical Problems in Engineering*, 2017 (2017) 13.
- [13] B. Mataei, F. Moghadas Nejad, M. Zahedi, H. Zakeri, Evaluation of pavement surface drainage using an automated image acquisition and processing system, *Automation in Construction*, 86 (2018) 240-255.
- [14] F.M. Nejad, N. Karimi, H. Zakeri, Automatic image acquisition with knowledge-based approach for multi-directional determination of skid resistance of pavements, *Automation in Construction*, 71(Part 2) (2016) 414-429.
- [15] K. Kamal, S. Mathavan, T. Zafar, I. Moazzam, A. Ali, S.U. Ahmad, M. Rahman, Performance assessment of Kinect as a sensor for pothole imaging and metrology, *International Journal of Pavement Engineering*, 19(7) (2018) 565-576.
- [16] Y.-C. Tsai, A. Chatterjee, Pothole Detection and Classification Using 3D Technology and Watershed Method, *Journal of Computing in Civil Engineering*, 32(2) (2017) 04017078.
- [17] J.Y.-C. Tsai, Z.-H. Wang, F. Li, Assessment of rut depth measurement accuracy of point-based rut bar systems using emerging 3d line laser imaging technology, *Journal of Marine Science and Technology*, 23(3) (2015) 322-330.
- [18] J.Y.-C. Tsai, F. Li, Y.-C. Wu, A new rutting measurement method using emerging 3D line-laser-imaging system, *International Journal of Pavement Research and Technology*, 6(5) (2013) 667-672.
- [19] S. Dai, K. Hoegh, 3D step frequency GPR Asphalt pavement stripping detection: Case study evaluating filtering approaches, in: *Advanced Ground Penetrating Radar (IWAGPR)*, 2017 9th International Workshop on, IEEE, 2017, pp. 1-7.
- [20] S. Li, C. Yuan, D. Liu, H. Cai, Integrated processing of image and GPR data for automated pothole detection,

- Radon transform, *Advanced Engineering Informatics*, 30(3) (2016) 481-499.
- [43] V. Ananth, P. Ananthi, V. Elakkiya, J. Priyadharshini, R. Shiyamili, Automatic Pavement Crack Detection Algorithm, *International Innovative Research Journal of Engineering and Technology*, 2 (2017).
- [44] I.H. Witten, E. Frank, M.A. Hall, C.J. Pal, *Data Mining: Practical machine learning tools and techniques*, Morgan Kaufmann, 2016.
- [45] J. Han, J. Pei, M. Kamber, *Data mining: concepts and techniques*, Elsevier, 2011.
- [46] F. Gorunescu, *Data Mining: Concepts, models and techniques*, Springer Science & Business Media, 2011.
- [47] E. Alpaydin, *Introduction to machine learning*, MIT press, 2009.
- [48] A.T. Azar, S. Vaidyanathan, *Computational intelligence applications in modeling and control*, Springer, 2015.
- [49] S.B. Kotsiantis, I. Zaharakis, P. Pintelas, Supervised machine learning: A review of classification techniques, 160 (2007) 3-24.
- [50] I. Goodfellow, Y. Bengio, A. Courville, Y. Bengio, *Deep learning*, MIT press Cambridge, 2016.
- [51] M.M. Najafabadi, F. Villanustre, T.M. Khoshgoftaar, N. Seliya, R. Wald, E. Muharemagic, Deep learning applications and challenges in big data analytics, *Journal of Big Data*, 2(1) (2015) 1.
- [52] R. Vidal, J. Bruna, R. Giryes, S. Soatto, *Mathematics of deep learning*, arXiv preprint arXiv:04741, (2017).
- [53] T. Wiatowski, H. Bölcskei, A mathematical theory of deep convolutional neural networks for feature extraction, *IEEE Transactions on Information Theory*, 64(3) (2018) 1845-1866.
- [54] A. Bhandare, M. Bhide, P. Gokhale, R. Chandavarkar, Applications of Convolutional Neural Networks, *International Journal of Computer Science Information Technologies*, (2016) 2206-2215.
- [55] S. Albelwi, A. Mahmood, A framework for designing the architectures of deep convolutional neural networks, *Entropy*, 19(6) (2017) 242.
- [56] Y. LeCun, Y. Bengio, Convolutional networks for management decision making, *Journal of Transportation Engineering*, 136(4) (2009) 332-341.
- [31] K. Gopalakrishnan, Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review, *Data*, 3(3) (2018) 28.
- [32] Y. LeCun, Y. Bengio, G. Hinton, Deep learning, *Nature*, 521 (2015) 436.
- [33] C. Robert, *Machine Learning, a Probabilistic Perspective*, CHANCE, 27(2) (2014) 62-63.
- [34] N.K. Warriar, K. Sathish, Object Detection on Roads using Deep Learning and Neural Networks, *Journal of Network Communications Emerging Technologies* 8(4) (2018).
- [35] M. Kantardzic, *Data mining: concepts, models, methods, and algorithms*, John Wiley & Sons, 2011.
- [36] K. Gopalakrishnan, S.K. Khaitan, A. Choudhary, A. Agrawal, Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection, *Construction and Building Materials*, 157 (2017) 322-330.
- [37] L. Deng, D. Yu, *Deep learning: methods and applications*, Foundations Trends® in Signal Processing, 7(3-4) (2014) 197-387.
- [38] Y. LeCun, Y. Bengio, G.J.n. Hinton, Deep learning, 521(7553) (2015) 436.
- [39] S. Dorafshan, R.J. Thomas, M. Maguire, Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete, *Construction and Building Materials*, 186 (2018) 1031-1045.
- [40] Z. Tong, J. Gao, Z. Han, Z. Wang, Recognition of asphalt pavement crack length using deep convolutional neural networks, *Road Materials and Pavement Design*, 19(6) (2018) 1334-1349.
- [41] Q. Zhu, Pavement crack detection algorithm Based on image processing analysis, in: *Proceedings - 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2016*, 2016, pp. 15-18.
- [42] Y.O. Ouma, M. Hahn, Wavelet-morphology based detection of incipient linear cracks in asphalt pavements from RGB camera imagery and classification using circular

- [67] Z. Tong, J. Gao, H. Zhang, Innovation for evaluating aggregate angularity based upon 3D convolutional neural network, *Construction and Building Materials*, 155 (2017) 919-929.
- [68] M.A. Nielsen, *Neural networks and deep learning*, Determination press USA, 2015.
- [69] H. Eom, H. Choi, Alpha-Pooling for Convolutional Neural Networks, arXiv preprint arXiv:03436, (2018).
- [70] D.C. Ciresan, U. Meier, J. Masci, L. Maria Gambardella, J. Schmidhuber, Flexible, high performance convolutional neural networks for image classification, in: *IJCAI Proceedings-International Joint Conference on Artificial Intelligence*, Barcelona, Spain, 2011, pp. 1237.
- [71] L. Li, K. Jamieson, G. DeSalvo, A. Rostamizadeh, A. Talwalkar, Hyperband: A novel bandit-based approach to hyperparameter optimization, *The Journal of Machine Learning Research*, 18(1) (2017) 6765-6816.
- [72] S.R. Young, D.C. Rose, T.P. Karnowski, S.-H. Lim, R.M. Patton, Optimizing deep learning hyper-parameters through an evolutionary algorithm, in: *Proceedings of the Workshop on Machine Learning in High-Performance Computing Environments*, ACM, 2015, pp. 4.
- [73] T. Domhan, J.T. Springenberg, F. Hutter, Speeding Up Automatic Hyperparameter Optimization of Deep Neural Networks by Extrapolation of Learning Curves, in: *IJCAI*, 2015, pp. 3460-3468.
- [74] J. Snoek, H. Larochelle, R.P. Adams, Practical bayesian optimization of machine learning algorithms, in: *Advances in neural information processing systems*, 2012, pp. 2951-2959.
- [75] Y. Gao, K.M. Mosalam, Deep Transfer Learning for Image-Based Structural Damage Recognition, 33(9) (2018) 748-768.
- [76] K. Zhang, H. Cheng, A Novel Pavement Crack Detection Approach Using Pre-selection Based on Transfer Learning, in: Y. Zhao, X. Kong, D. Taubman (Eds.) *Image and Graphics*, Springer International Publishing, Cham, 2017, pp. 273-283.
- [77] S.J. Pan, Q. Yang, A survey on transfer learning, *IEEE Transactions on knowledge data engineering*, 22(10) images, speech, and time series, *The handbook of brain theory neural networks*, 3361(10) (1995) 1995.
- [57] K. Zhang, H. Cheng, B. Zhang, Unified Approach to Pavement Crack and Sealed Crack Detection Using Preclassification Based on Transfer Learning, *Journal of Computing in Civil Engineering*, 32(2) (2018) 04018001.
- [58] T. Wang, K. Gopalakrishnan, O. Smadi, A.K.J.T. Somani, Automated shape-based pavement crack detection approach, 33(3) (2018) 598-608.
- [59] D. Seichter, M. Eisenbach, R. Stricker, G. H-M, How to Improve Deep Learning based Pavement Distress Detection while Minimizing Human Effort, in: *Proc. Int. Conf. on*, 2018, pp. 63-70.
- [60] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiya, H. Omata, Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone, arXiv preprint arXiv:1801.09454, (2018).
- [61] B. Li, K.C. Wang, A. Zhang, E. Yang, G. Wang, Automatic classification of pavement crack using deep convolutional neural network, *International Journal of Pavement Engineering*, (2018) 1-7.
- [62] G. Ciaparrone, A. Serra, V. Covito, P. Finelli, C.A. Scarpato, R. Tagliaferri, A Deep Learning Approach for Road Damage Classification, in: *Advanced Multimedia and Ubiquitous Engineering*, Springer, 2018, pp. 655-661.
- [63] Z. Tong, J. Gao, H. Zhang, Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks, *Construction and Building Materials*, 146 (2017) 775-787.
- [64] Y. Liu, J. Yao, X. Lu, R. Xie, L. Li, DeepCrack: A Deep Hierarchical Feature Learning Architecture for Crack Segmentation, *Neurocomputing*, (2019).
- [65] J. Singh, S. Shekhar, Road Damage Detection And Classification In Smartphone Captured Images Using Mask R-CNN, arXiv, (2018).
- [66] K. Gopalakrishnan, H. Gholami, A. Vidyadharan, A. Choudhary, A. Agrawal, Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model, *International Journal for Traffic Transport Engineering*, 8 (2018) 1.

- size, (2016).
- [83] K. He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 770-778.
- [84] G. Huang, Z. Liu, L. Van Der Maaten, K.Q. Weinberger, Densely connected convolutional networks, in: CVPR, 2017, pp. 3.
- [85] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna, Rethinking the inception architecture for computer vision, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2016, pp. 2818-2826.
- [86] F.M. Nejad, H. Zakeri, An optimum feature extraction method based on Wavelet-Radon Transform and Dynamic Neural Network for pavement distress classification, Expert Systems with Applications, 38(8) (2011) 9442-9460.
- [87] F. Moghadas Nejad, H. Zakeri, An expert system based on wavelet transform and radon neural network for pavement distress classification, Expert Systems with Applications, 38(6) (2011) 7088-7101.
- [88] R.C. Gonzalez, R.E. Woods, Digital image processing, 2 (2007).
- (2010) 1345-1359.
- [78] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, Imagenet large scale visual recognition challenge, International Journal of Computer Vision, 115(3) (2015) 211-252.
- [79] A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, in: Advances in neural information processing systems, 2012, pp. 1097-1105.
- [80] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, in: Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9.
- [81] K. He, X. Zhang, S. Ren, J. Sun, Delving deep into rectifiers: Surpassing human-level performance on imagenet classification, in: Proceedings of the IEEE international conference on computer vision, 2015, pp. 1026-1034.
- [82] F.N. Iandola, S. Han, M.W. Moskewicz, K. Ashraf, W.J. Dally, K.J.a.p.a. Keutzer, Squeezenet: Alexnet-level accuracy with 50x fewer parameters and < 0.5 mb model

چگونه به این مقاله ارجاع دهیم

S. Ranjbar, F. Moghadas Nejad, H. Zakeri, Pavement cracks detection and classification using deep convolutional networks, Amirkabir J. Civil Eng., 52(9) (2020) 2255-2278.

DOI: [10.22060/ceej.2019.16103.6133](https://doi.org/10.22060/ceej.2019.16103.6133)

