



## Asphalt Pavement Bleeding Evaluation using Deep Learning and Wavelet Transform

S. Ranjbar, F. Moghadas Nejad\* , H. Zakeri

<sup>1</sup>Department of Civil & Environmental Engineering, Amirkabir University Of Technology, Tehran, Iran

**ABSTRACT:** Pavement inspection is an important part of pavement management systems because this part provides input and raw material information to the system. If the pavement situation has not been assessed or incorrectly assessed, it will not be possible to carry out optimum maintenance and repair operations. It can also cause higher maintenance costs and the risk of accidents. Pavement distress information is crucial data that should be collected and evaluated in the pavement inspection process. Accordingly, wide research has been conducted to develop more efficient systems for the evaluation of pavement distresses using new technologies. Bleeding is one of the asphalt pavement distresses, which directly affects the skid resistance and vehicle maneuverability. Based on the literature, pavement bleeding received the attention from the research community less than other pavement distress such as cracks, rutting, raveling, and potholes. This research attempts to develop an efficient system for the automatic evaluation of asphalt pavement bleeding. For this aim, the transfer learning method was applied to train a pre-trained convolutional neural network for bleeding detection. Also, various image processing techniques (wavelet transform analysis as the main technique) were used to segment bleeding regions in pavement images. Results indicated that the proposed system has good performance in bleeding detection and segmentation with 98% and 87%, respectively. Accordingly, this system can be applied as an efficient system for pavement bleeding evaluation.

### Review History:

Received: Apr. 19, 2020

Revised: Jul. 04, 2020

Accepted: Aug. 02, 2020

Available Online: Aug. 25, 2020

### Keywords:

Pavement management system

Distress evaluation, Bleeding

Deep learning, Wavelet transform.

### 1- Introduction

In most countries, pavement management systems (PMS) are developed to monitor the pavement condition and planning to improve the safety and serviceability of roads. An efficient PMS leads to work planning for pavement maintenance by a proper maintenance method at the optimum time, and with optimized cost [1]. Pavement inspection is an important step in PMS because most of the input information for evaluating pavement condition is obtained during the pavement inspection procedure and this information has a significant impact on PMS efficiency [2, 3]. Pavement distresses information is the most important information that should be collected in the pavement inspection procedure.

Pavement bleeding is a type of damage to asphalt pavements. This pavement distress leads to create a thin layer of binder on the pavement surface and is usually caused by traffic loads in hot weather [4, 5]. Bleeding directly affects pavement surface characteristics in terms of microtexture and macrotexture which are important factors in pavement skid resistance. Roads safety and vehicle maneuverability are significantly associated with pavement skid resistance [6]. Accordingly, bleeding causes reducing road safety. This impact can intensify with the hydroplaning effect in wet and rainy regions [7].

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

Pavement inspection is conducted traditionally (visual inspection) the past. This approach has some defects, including high labor costs, time-consuming, unreliable results, and unsafe working conditions for staff. Accordingly, the majority of transportation agencies try to apply new technologies for more efficient pavement inspection. According to the literature, 2D image-based, 3D measurement-based, radar-based, optic-based, acceleration-based, sonic-based technologies, and hybrid methods are some of the more prevalent technologies for pavement distress evaluation [3].

In recent years, wide researches have been conducted to develop an automatic system for analyzing skid resistance and detecting various pavement defects such as cracking, rutting, raveling, pothole, etc. However, there is no research with the aim of the automatic inspection of asphalt pavement bleeding as much as other pavement distress such as cracking, rutting, pothole [8].

This research proposes an image-based system for automatic detection and segmentation of asphalt pavement bleeding using deep learning and image processing techniques. In this study, deep convolutional neural networks (CNN) were applied using transfer learning for bleeding detection and applied image processing techniques for segmenting bleeding areas, including histogram



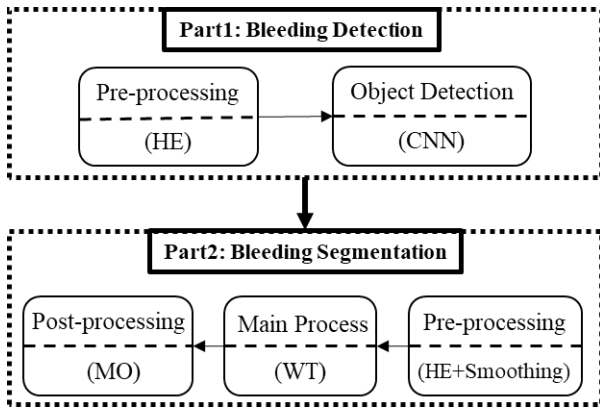


Fig. 1. Research methodology.




Fig. 2. Examples of system outputs.

Table 1. Details of datasets.

Class	Dataset		
	Train	Validation	Test
B (Bleeding)	400	100	270
N (Non-Bleeding)	400	100	270
Total	1000		540

equalization (HE), image smoothing, wavelet transform (WT), thresholding, and morphological operations (MO).

## 2- Methodology

As can be seen in Fig. 1, the research process consists of two main parts, including bleeding detection and segmentation.

For bleeding detection, at first, HE has been used to make the more obvious image as a pre-processing. Then, a CNN model has been used to detect pavement images that there is bleeding distress in them. In this part of the research, a data set of pavement images has been collected for training and testing a pre-trained CNN model (AlexNet) using the transfer learning technique. Details of collected datasets are shown in Table 1.

In the second part of the research (bleeding segmentation), a pre-processing including HE and smoothing was done to prepare pavement images for the main process. Then, a WT module was developed to separate the bleeding areas in pavement images as the main process. Finally, global thresholding and MO were applied as post-processing to improve the quality of output images.

It should be noted that all computations were performed 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- Results and Discussion

After implementing the proposed system, the pavement image with bleeding distress can be detected and bleeding areas can be segmented as presented in Fig. 2

The efficiency of the proposed system has been evaluated based on the processing speed and various performance indices. The time taken for bleeding detection is 0.44 and 0.042 seconds per image in pre-processing and object detection process, respectively. Also, the time taken for bleeding segmentation is 1.55 seconds per image.

To evaluate the efficiency of the models in bleeding detection, the confusion matrix was calculated to achieve performance metrics such as accuracy, sensitivity, precision, and F-score. The average of the performance metrics is almost 98 percent. This result showed that the created CNN model using transfer learning has a good performance in bleeding detection.

The performance of the proposed system for segmenting the bleeding areas was evaluated by comparing the outputs with pixel-level ground-truth labels based on the Dice and recall metrics. The results showed that the proposed system can segment the bleeding areas with 89.94 and 87.47 percent based on the Dice and recall metrics, respectively.

## 4- Conclusion

Bleeding is important pavement distress that has a direct effect on the pavement skid resistance and reduces road safety. This research tried to apply machine learning and image processing techniques for automatic detection and segmentation of bleeding in asphalt pavements.

For bleeding detection, a pre-trained CNN model (AlexNet) was retrained based on the collected dataset using the transfer learning method. Results of applying the model on the test dataset indicated that retraining the pre-trained CNN is an efficient method for bleeding detection with almost 98% based on the various metrics.

For segmenting the bleeding areas, an image processing-based method was developed using WT as the main process and some other techniques such as HE, smoothing, thresholding, and MO. Comparing the similarity of outputs

with ground-truth images showed that the developed method is efficient with 89.94% based on the Dice similarity coefficient.

According to the results, this system can improve PMS performance in various countries by efficiently detecting and segmenting the asphalt pavement bleeding.

## References

- [1] F.M. Nejad, H. Zakeri, The Hybrid Method and its Application to Smart Pavement Management, in: X.-S. Yang, A.H. Gandomi, S. Talatahari, A.H. Alavi (Eds.) *Metaheuristics in Water, Geotechnical and Transport Engineering*, Elsevier, Oxford, 2013, pp. 439-484.
- [2] M.Y. Shahin, *Pavement management for airports, roads, and parking lots*, 1994.
- [3] 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.
- [4] J.S. Miller, W.Y. Bellinger, *Distress identification manual for the long-term pavement performance program*, United States. Federal Highway Administration. Office of Infrastructure Research and Development, 2014.
- [5] A. Designation, D6433 *Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys*, (2007).
- [6] B. Mataei, H. Zakeri, M. Zahedi, F.M. Nejad, Pavement friction and skid resistance measurement methods: a literature review, *Open J. Civ. Eng.*, 6(04) (2016) 537.
- [7] W. Lawson, S. Senadheera, Chip seal maintenance: solutions for bleeding and flushed pavement surfaces, *Transportation Research Record: Journal of the Transportation Research Board*, (2108) (2009) 61-68.
- [8] T.B. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017) 1374822.

### HOW TO CITE THIS ARTICLE

S. Ranjbar, F. Moghadas Nejad, H. Zakeri, *Asphalt Pavement Bleeding Evaluation using Deep Learning and Wavelet Transform*, *Amirkabir J. Civil Eng.*, 53(11) (2022) 1007-1010.

DOI: [10.22060/ceej.2020.18292.6820](https://doi.org/10.22060/ceej.2020.18292.6820)







## ارزیابی خرابی قیرزدگی روسازی آسفالتی با استفاده از یادگیری عمیق و تبدیل موجک

سجاد رنجبر، فریدون مقدس‌نژاد<sup>\*</sup>، حمزه ذاکری

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

### تاریخچه داوری:

دریافت: ۱۳۹۹/۰۱/۳۱  
بازنگری: ۱۳۹۹/۰۴/۱۴  
پذیرش: ۱۳۹۹/۰۵/۱۲  
ارائه آنلاین: ۱۳۹۹/۰۶/۰۴

### کلمات کلیدی:

سامانه مدیریت روسازی  
ارزیابی خرابی  
قیرزدگی  
یادگیری عمیق  
تبدیل موجک

**خلاصه:** اطلاعات مرتبط با وضعیت روسازی نظیر خرابی‌ها، ورودی و مواد اولیه سامانه مدیریت روسازی را تأمین می‌کند. در صورت عدم ارزیابی وضعیت روسازی و یا ارزیابی ناقص و نادرست وضعیت روسازی، امکان انجام عملیات تعمیر و نگهداری مناسب و به موقع وجود نخواهد داشت که این موضوع به افزایش هزینه‌های نگهداری و بهسازی و افزایش احتمال بروز تصادفات منجر خواهد شد. از این رو، تحقیقات گسترده‌ای با هدف بکارگیری فناوری‌های جدید در جهت ارزیابی دقیق و خودکار خرابی‌های روسازی انجام شده است. خرابی قیرزدگی یکی از خرابی‌های روسازی آسفالتی است که مستقیماً بر اصطکاک سطحی و مانورپذیری وسایل نقلیه تأثیر می‌گذارد. علی‌رغم اهمیت خرابی قیرزدگی، ارزیابی خودکار این خرابی نسبت به سایر خرابی‌ها نظیر ترک‌خوردگی، چاله، شیارافتادگی کمتر مورد توجه جامعه تحقیق بوده است. در این پژوهش، سعی شده است که با استفاده از روش‌های جدید نظیر یادگیری عمیق و ابزارهای مختلف پردازش تصویر، یک سامانه کارآمد مبتنی بر تصویر به منظور ارزیابی خودکار خرابی قیرزدگی ارائه شود. برای این منظور، از روش انتقال یادگیری برای ساخت مدل تشخیص خرابی و از یک فرآیند پردازش تصویر مبتنی بر تبدیل موجک برای تفکیک نواحی قیرزده استفاده شد. نتایج به دست آمده نشان می‌دهد که سامانه ارائه شده در این پژوهش، در تشخیص خرابی و تفکیک نواحی قیرزده به ترتیب با متوسط بالای ۹۸ و ۸۷ درصد، عملکرد خوبی در ارزیابی خرابی قیرزدگی دارد و می‌تواند به عنوان ابزاری کارآمد در ارزیابی قیرزدگی بکار گرفته شود.

### ۱- مقدمه

تشخیص خرابی، تفکیک<sup>۲</sup> نواحی خرابی، دست‌بندی بر اساس شدت و نوع خرابی و کمیسازی (ارائه شاخص) خرابی است. موارد ذکر شده در گذشته به روش سنتی (بازرسی چشمی) مورد بررسی قرار می‌گرفت. از جمله معایب روش سنتی ارزیابی شرایط روسازی میتوان به زمان‌بر بودن و هزینه‌های بالا، غیر قابل اعتماد بودن نتایج، قرار دادن کارکنان در شرایط پر خطر و ایجاد اختلال در ترافیک مسیر اشاره کرد [۲]. علاوه بر موارد ذکر شده، گستردگی شبکه راه‌ها در کشورهای مختلف، استفاده از روش‌های مبتنی بر بازرسی چشمی را غیر ممکن کرده است.

معایب روش‌های سنتی از یک سو و پیشرفت چشمگیر فناوری‌های مبتنی بر علوم کامپیوتری از سوی دیگر، سازمانها و محققان اکثر کشورها را به استفاده از فناوریهای مختلف نظیر پردازش تصویر، یادگیری ماشین برای توسعه سامانه‌های خودکار ارزیابی شرایط روسازی سوق داده است [۲-۴]. مقاومت لغزشی سطح روسازی یکی از مهمترین مشخصه‌های روسازی

روسازی راه‌ها بخش اصلی زیرساخت‌های حمل و نقل جاده‌ای را تشکیل می‌دهند و در اکثر کشورها به منظور کنترل وضعیت روسازی و انجام عملیات تعمیر و نگهداری برای بهبود وضعیت روسازی، سامان‌های مدیریت روسازی<sup>۱</sup> (PMS) ایجاد شده‌اند. مطابق شکل ۱، این سامانه از پنج بخش اصلی تشکیل شده است که بازرسی و ارزیابی شرایط روسازی از مهم‌ترین بخشهای این سامانه است، زیرا اطلاعات جمع‌آوری شده در این بخش، پایه و اساس تمام ارزیابیهای سایر بخشها است و تعیین وضعیت فعلی و آینده روسازی و تصمیم‌گیری در مورد عملیات تعمیر و نگهداری مناسب همگی بر اساس اطلاعات برداشت شده از روسازی انجام می‌شود [۱].

مطابق شکل ۱، ارزیابی خرابیهای روسازی از جمله اطلاعات مهم در بخش ارزیابی شرایط روسازی به شمار می‌رود. این اطلاعات معمولاً شامل


1 Pavement Management System

<sup>\*</sup> نویسنده عهده‌دار مکاتبات: moghadas@aut.ac.ir

2 Segmentation


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. بخش های اصلی سامانه مدیریت روسازی [۱، ۲].

Fig. 1. Main parts of PMS



شکل ۲. اثر خرابی قیرزدگی بر مقاومت لغزشی. الف: روسازی سالم [۱۲]، ب: روسازی دارای خرابی قیرزدگی [۱۳].

Fig. 2. The effect of bleeding on skid resistance; a) intact pavement, b) pavement with bleeding

بیان شده است [۷-۹].

خرابی قیرزدگی از جمله خرابی های روسازی آسفالتی است که به طور مستقیم بر بافت ریز و درشت سطح روسازی اثر می گذارد و مقاومت لغزشی سطح روسازی را کاهش می دهد (شکل ۲-ب) و این امر موجب کاهش مانورپذیری وسایل نقلیه و افزایش احتمال تصادفات می شود. لازم به ذکر است که اثر خرابی قیرزدگی در شرایط آب و هوای بارانی که سطح روسازی خیس و مرطوب است، به علت پدیده هیدروپلنینگ<sup>۲</sup> تا حد زیادی تشدید می شود [۱۰، ۱۱].

در سال های اخیر، تحقیقات گسترده ای با هدف ارزیابی خودکار خرابی

راه ها به شمار می رود که تأثیر بسزایی در سطح ایمنی راه ها دارد؛ زیرا مانورپذیری و کنترل وسایل نقلیه تا حد زیادی به این مشخصه بستگی دارد [۵]. همان طور که در شکل ۲-الف مشاهده می شود، بافت ریز و بافت درشت سطح روسازی دو پارامتر اصلی در تأمین مقاومت لغزشی روسازی هستند. بارهای ناشی از عبور وسایل نقلیه موجب حرکت رو به بالای قیر در مخلوط آسفالتی و رسیدن آن به سطح روسازی می شود که اغلب در هوای گرم به وقوع می پیوندد [۱، ۶]. با توجه به تحقیقات انجام شده، علت اصلی وقوع خرابی قیرزدگی، وجود نقص در طرح اختلاط آسفالت، یعنی کم بودن حجم فضای خالی (Air Void) و بالا بودن حجم پر شده با قیر<sup>۱</sup> (VFA)،

2 Hydroplaning

1 Void Filled with Asphalt



از اطلاعات موجود در تصویر و سیگنال به شمار می رود [۲۲]. در سالهای اخیر، سامانه های مبتنی بر پردازش سیگنال با استفاده از تبدیل موجک ارزیابی وضعیت روسازی بکار گرفته شده است. در این راستا تحقیقاتی با هدف ارزیابی ناهمواری روسازی [۲۳-۲۶]، بررسی اصطکاک سطحی روسازی [۲۷] و تشخیص خرابی روسازی نظیر چاله [۲۸] با استفاده از ابزار تبدیل موجک انجام شده است.

در بخش پردازش تصویر، تبدیل موجک به عنوان یک روش پرکاربرد در جهت کاهش نویز [۲۹، ۳۰]، فشرده سازی [۳۱، ۳۲] و بررسی بافت تصاویر [۳۳، ۳۴] مورد توجه بوده است. در این بخش از تبدیل موجک در سامانه های مبتنی بر پردازش تصویر به منظور ارزیابی خرابیهای روسازی نظیر ترک خوردگی [۲، ۳۵، ۳۶] و چاله [۳۷] استفاده شده است. این ابزار همچنین در بررسی بافت روسازی برای ارزیابی وضعیت زهکشی [۳۸] و مقاومت لغزشی [۳۹] مورد استفاده قرار گرفته است.

بررسی مطالعات نشان می دهد که تبدیل موجک می تواند به عنوان یک روش کارآمد در ارزیابی وضعیت روسازی مورد استفاده قرار گیرد. در پژوهش حاضر از تبدیل موجک به منظور بررسی تصاویر دارای خرابی قیرزدگی و تفکیک نواحی قیرزده بکار گرفته شده است.

### ۲-۳- ارزیابی خودکار خرابی قیرزدگی

تنگ و همکاران [۱۸]، چند مدل بر اساس ترکیب شبکه های عصبی پیچشی<sup>۳</sup> (CNN)، ماشین بردار پشتیبان، چهارچوب عدم قطعیت و زمینه های تصادفی شرطی گوسی برای تشخیص و تفکیک خرابی های روسازی نظیر ترک خوردگی، چاله و قیرزدگی ارائه کرده اند. مدل های پیشنهاد شده، عملیات دسته بندی و شناسایی خرابی را در مقیاس پیکسل های تصویر انجام می دهند. آماده سازی داده های تعلیم و آزمایش این دسته از مدل ها فرآیندی زمان بر است و فرآیند تعلیم و بکارگیری این مدل ها به توان پردازشی بالایی نیاز دارد.

سانگ و وانگ [۲۱]، با استفاده از مدل های Faster R-CNN، سامانه ای به منظور تشخیص خرابی های روسازی نظیر ترک خوردگی، چاله و قیرزدگی ارائه داده اند. در این سامانه نواحی دارای قیرزدگی با یک مستطیل مشخص می شوند. سامانه ارائه شده قادر به تفکیک دقیق نواحی قیرزده نیست و آماده سازی داده های تعلیم مدل ها فرآیند زمانبری است.

کاراساهین و همکاران [۴۰]، با توجه به اینکه پس از وقوع قیرزدگی

های روسازی انجام شده است که در بین این تحقیقات، خرابی قیرزدگی نسبت به سایر خرابی ها نظیر ترک خوردگی، چاله و شیارافتادگی، کمتر مورد توجه جامعه تحقیق قرار گرفته است [۱۴]. در این پژوهش سعی شده است، با استفاده از مدل های مبتنی بر یادگیری عمیق و الگوریتم های پردازش تصویر، سامانه های برای ارزیابی خرابی قیرزدگی ارائه شود تا تشخیص وجود قیرزدگی و تفکیک نواحی قیرزده در تصاویر به صورت خودکار و با دقت قابل قبول انجام دهد.

برای تشخیص خرابی قیرزدگی از مدل های مبتنی بر شبکه عصبی پیچشی عمیق استفاده شده است. در این راستا، روش انتقال یادگیری<sup>۱</sup> برای بازتعلیم مدل های از پیش تعلیم یافته بکار گرفته شده است. همچنین الگوریتم های مختلف پردازش تصویر نظیر تسهیم هیستوگرام، هموارسازی<sup>۲</sup>، تبدیل موجک، آستانه گذاری و عملگرهای مورفولوژیک برای تعیین و تفکیک نواحی قیرزده در تصاویر دارای خرابی قیرزدگی استفاده شده است و در این راستا یک مازول تبدیل موجک نیز برای تعیین نواحی خرابی ارائه شده است.

### ۲- مرور مطالعات گذشته

در این بخش، مرور کلی بر کاربرد شبکه های عصبی پیچشی در ارزیابی خرابی های روسازی و کاربرد تبدیل موجک در سامانه های ارزیابی وضعیت روسازی انجام شده است. همچنین مرور مختصری بر تحقیقات انجام شده با هدف ارزیابی خودکار خرابی قیرزدگی انجام شده است.

#### ۲-۱- کاربرد شبکه های عصبی پیچشی در ارزیابی خرابی های روسازی

مدل های مبتنی بر یادگیری عمیق به ویژه شبکه های عصبی پیچشی با توجه به قابلیت استخراج و یادگیری خودکار قوانین و الگوهای مهم در داده ها، کاربرد گسترده ای در تشخیص اشیاء و بینایی ماشین دارند [۱۵، ۱۶]. در سال های اخیر، جامعه تحقیق توجه ویژه ای به استفاده از این مدل ها در زمینه های مختلف مهندسی داشته است. از این رو، پژوهش های مختلفی با هدف بکارگیری شبکه های عصبی پیچشی در بخش ارزیابی خرابی های روسازی نظیر ترک خوردگی [۱۷-۱۹]، چاله [۱۸، ۲۰، ۲۱]، شن زدگی [۲۱] و قیرزدگی [۱۸، ۲۱] انجام شده است.

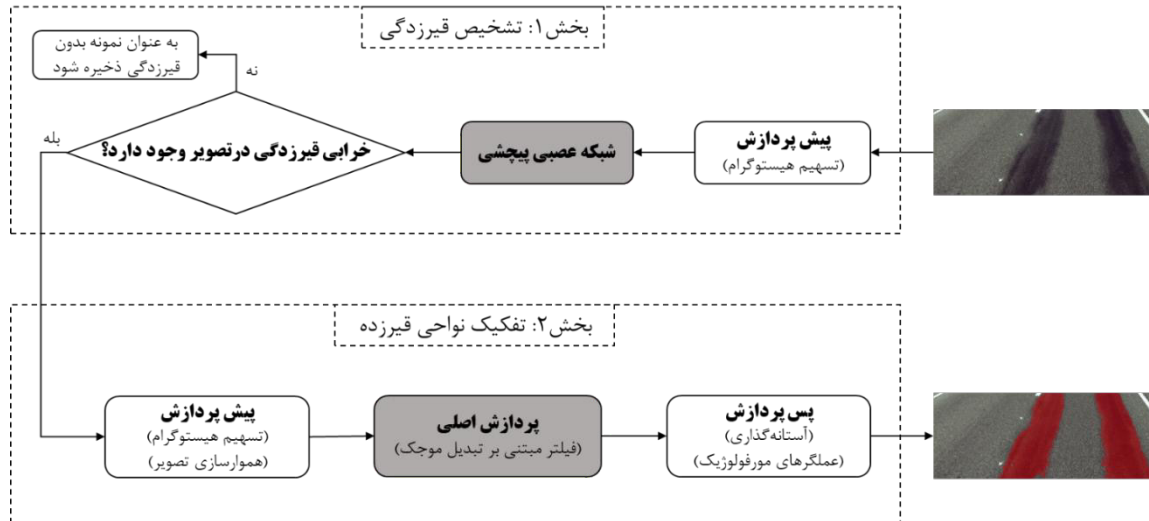
#### ۲-۲- کاربرد تبدیل موجک در ارزیابی وضعیت روسازی

تبدیل موجک یک ابزار ریاضی قدرتمند در استخراج اطلاعات کاربردی

1 Transfer Learning

2 Smoothing

3 Convolutional Neural Network



شکل ۳. سامانه پیشنهادی برای ارزیابی خودکار خرابی قیرزدگی

Fig. 3. Proposed system for automatic evaluation of the pavement bleeding

دارای بافت سطحی ضعیف تری هستند به عنوان نواحی دارای قیرزدگی تشخیص داده می شوند. در این پژوهش، به تفکیک نواحی قیرزده و بررسی گسترده قیرزدگی توجهی نشده است. همچنین بکارگیری سامانه های مبتنی بر فناوری لیزر با توجه به هزینه های بالای این دسته از فناوری ها، چندان توجیه اقتصادی ندارد.

با بررسی پژوهش های گذشته می توان دریافت که تمرکز اصلی محققان بر تشخیص خرابی قیرزدگی بوده است. پژوهش هایی که بر تشخیص و تفکیک نواحی قیرزده متمرکز باشند، سهم بسیار ناچیزی از مطالعات انجام شده را به خود اختصاص داده اند و نیازمند صرف زمان زیاد برای آماده سازی داده ها و توان پردازشی بالا برای تعلیم مدلها هستند. از این رو، در پژوهش حاضر تلاش شده است سامانه ای خودکار و کارآمد به منظور تشخیص خرابی قیرزدگی و تفکیک نواحی قیرزده در تصاویر روستازی ارائه شود.

### ۳- سامانه پیشنهادی و مفاهیم پایه

سامانه پیشنهاد شده در این پژوهش برای ارزیابی خودکار قیرزدگی، از دو بخش اصلی تشکیل شده است که در بخش اول، تشخیص وقوع خرابی قیرزدگی انجام می شود و در بخش دوم، نواحی قیرزده موجود در تصویر روستازی تفکیک و قطعه بندی خواهند شد. همان طور که در شکل ۳ نشان داده شده است، در بخش اول ابتدا یک پیش پردازش، به منظور بهبود وضوح تصاویر، انجام می شود. سپس یک مدل مبتنی بر شبکه های عصبی


سنگدانه ها با لایه ای از قیر پوشانده می شوند، سامانه ای مبتنی بر پردازش تصاویر دیجیتال به منظور تشخیص خرابی قیرزدگی در سیلکت ها، ارائه کردند. در این مطالعه از الگوریتم های تشخیص لبه به منظور بررسی سنگدانه های روی سطح روستازی استفاده شده است و بخشهایی از تصاویر که دارای میزان لبه کمتری هستند به عنوان نواحی دارای قیرزدگی تشخیص داده می شوند. سامانه پیشنهاد شده توانایی تفکیک و بررسی مشخصات هندسی نواحی قیرزده را ندارد و همچنین تصاویر ورودی باید در شرایط نوری کنترل شده برداشت شده باشد.

هادجی مترو و کرسودولو [۴۱]، یک سامانه مبتنی بر آنتروپی تصاویر برای تشخیص خرابی های روستازی نظیر ترک خوردگی، شن زدگی، شیارافتادگی، موج زدگی و قیرزدگی پیشنهاد داده اند. سامانه ارائه شده عملکرد قابل قبولی در تشخیص خرابیهای قیرزدگی و شیارافتادگی نداشته است. همچنین قادر به تفکیک نواحی قیرزده و ارزیابی مشخصات نواحی قیرزده نیست.

لارنت و همکاران [۴۲]، در پژوهش خود تلاش کردند تا با استفاده از داده های برداشت شده توسط سامانه LCMS<sup>۱</sup> مبتنی بر فناوری لیزر که اغلب به منظور برداشت اطلاعات ترک خوردگی روستازی استفاده می شود، برای ارزیابی سایر خرابیها نظیر شن زدگی و قیرزدگی بکار گیرند. در پژوهش انجام شده، با محاسبه متوسط عمق بافت روستازی<sup>۲</sup> (MTD) نواحی که

1 Laser Crack Measurement System  
2 Mean Texture Depth





شکل ۴. ساختار کلی شبکه‌های عصبی پیچشی

Fig. 4. The structure of the convolutional neural network

کننده ویژگی‌ها و (۲) دسته بندی کننده تشکیل شده است. بخش استخراج ویژگی از چندین لایه تشکیل شده است که وظیفه استخراج و خلاصه سازی اطلاعات موجود در تصویر را بر عهده دارند. لایه های پیچشی<sup>۱</sup> و ترکیب<sup>۲</sup> از اصلی ترین لایه های تشکیل دهنده این بخش به شمار می روند [۴۳، ۴۴]. هر لایه پیچشی معمولاً دارای چند طرح‌واره است که از اعمال فیلترهای مختلف روی داده ورودی به دست آمده است. با انجام عملیات پیچش (convolution) مطابق رابطه (۱)، هر یک از طرح‌واره‌ها<sup>۳</sup> به وسیله حرکت یک کرنل یا فیلتر روی ورودی لایه ایجاد می شود و برای استخراج یک ویژگی مشخص از ورودی به وجود آمده است. یکسان بودن کرنل اعمال شده برای ایجاد یک طرح‌واره موجب اشتراک گذاری وزنها و کاهش قابل توجه تعداد پارامترهای یادگیری مدل خواهد شد [۴۳، ۴۴].

$$(F * I)(i, j) = \sum_m \sum_n I(i-m, j-n)F(m, n) \quad (1)$$

که در رابطه (۱)؛  $F$  و  $I$  به ترتیب بیانگر فیلتر و تصویر هستند.  $i$  و  $j$  مختصات پیکسل تصویر و  $m$  و  $n$  ابعاد کرنل یا فیلتری هستند که بر روی تصویر اعمال می شود.

لایه ترکیب تنها با هدف فشرده سازی و کاهش ابعاد طرح‌واره‌ها در ساختار شبکه های عصبی پیچشی قرار می گیرند. این فشرده سازی با حرکت یک ناحیه محلی با ابعاد مشخص روی طرح‌واره‌ها و اعمال یک تابع

پیچشی برای تشخیص وقوع خرابی قیرزدگی در تصاویر روسازی بکار گرفته می شود.

در بخش دوم، تصاویری که در بخش اول دارای قیرزدگی تشخیص داده شده اند وارد یک فرآیند پردازش تصویر مبتنی بر تبدیل موجک می شوند. هدف این فرآیند، تفکیک نواحی خرابی است که برای این منظور، ابتدا یک پیش پردازش متشکل از عملیات تسهیم هیستوگرام و هموارسازی روی تصویر اعمال می شود. سپس با استفاده از یک فیلتر مبتنی تبدیل موجک نواحی دارای خرابی مشخص می شوند و در آخر یک فرآیند پس‌پردازش متشکل از آستانه گذاری و عملگرهای مورفولوژیک به منظور بهبود کیفیت نتایج استفاده می شود.


در سامانه پیشنهاد شده، مدل مبتنی بر شبکه های عصبی پیچشی و روش تبدیل موجک به عنوان دو ابزار اصلی در سامانه ارائه شده مورد استفاده قرار گرفته اند. در ادامه توضیحات مختصری پیرامون مفاهیم تئوری این ابزارها ارائه شده است.

### ۳-۱- شبکه های عصبی پیچشی

شبکه‌های عصبی پیچشی نوع خاصی از مدل‌های یادگیری عمیق هستند. قابلیت استخراج و خلاصه سازی خودکار الگوها از ویژگیهای متمایزکننده این دسته از مدلها در بین سایر مدل‌های یادگیری ماشین در کار با داده‌ها (به ویژه تصاویر) به شمار میرود. این ویژگی شبکه های عصبی پیچشی را به یک ابزار قدرتمند برای ساخت مدل‌های تشخیص اشیاء و استخراج الگوها تبدیل کرده است [۴۳].

مطابق شکل ۴، ساختار این مدلها به طور کلی از دو بخش (۱) استخراج

- 1 Convolutional
- 2 Pooling
- 3 Feature Map



شکل ۵. ساختار مدل از پیش‌تعلیم یافته AlexNet [۴۹، ۵۰]

Fig. 5. The structure of AlexNet model [49, 50].

بر طرف کرده است [۱۵، ۴۶-۴۸].

در روش انتقال یادگیری، تنها بخشی از ساختار شبکه‌های از پیش‌تعلیم یافته بر اساس داده‌های جدید مورد بازتعلیم قرار می‌گیرند و این امر امکان ساخت مدل در زمان کمتر و با تعداد داده‌های کمتر و با صرف توان پردازشی کمتر فراهم می‌آورد. به عبارت دیگر در انتقال یادگیری از قابلیت یادگیری و استخراج ویژگی‌ها اساسی در شبکه‌های از پیش‌تعلیم یافته برای تعلیم مجدد شبکه بر اساس داده‌های جدید استفاده می‌شود [۱۵، ۴۵-۴۸].

در این پژوهش، از قابلیت استخراج ویژگی شبکه از پیش‌تعلیم یافته AlexNet که یکی از شبکه‌های پرکاربرد در استخراج ویژگی از تصاویر و تشخیص اشیا است، استفاده شده است و با بکارگیری روش انتقال یادگیری، بخش دسته‌بندی‌کننده شبکه بر اساس ویژگی‌های استخراج شده از تصاویر روسازی، مورد تعلیم مجدد قرار می‌گیرد.

مدل از پیش‌تعلیم یافته AlexNet یکی از مدل‌های مبتنی بر شبکه‌های عصبی پیچشی است. همان‌طور که در شکل ۵ نمایش داده شده است، ورودی این مدل یک تصویر سه کاناله ( $RGB^3$ ) با ابعاد ۲۲۷ در ۲۲۷ پیکسل است. معماری این شبکه شامل ۸ لایه است که ۵ لایه در بخش استخراج ویژگی و از نوع لایه‌های پیچشی هستند. هر یک از این لایه‌ها در بردارنده تعدادی طرح‌واره بوده که بر اساس فیلترهای مختلف ایجاد می‌شوند. ۳ لایه دیگر از نوع اتصال کامل هستند که عملیات ساخت مدل دسته

بر اطلاعات قرار گرفته در ناحیه محلی صورت می‌گیرد. توابع میانگین‌گیری و انتخاب بیشینه از جمله توابع پرکاربرد در عملیات ترکیب هستند. انجام این عملیات موجب کاهش پارامترهای یادگیری مدل می‌شود و با توجه به اینکه پیچیدگی مدل کاهش می‌یابد، احتمال بروز اضافه‌برازش نیز کاهش می‌یابد [۴۳، ۴۴].

تعداد و ترتیب قرارگیری این لایه‌ها به ساختار مدل بستگی دارد و پس از قرارگیری چندین لایه پیچشی و ترکیب در بخش اول، امکان استخراج و خلاصه‌سازی خودکار الگوهای مهم فراهم می‌شود. در بخش دوم با اعمال یک مدل دسته‌بندی‌کننده نظیر ماشین بردار پشتیبان، شبکه عصبی، درخت تصمیم بر روی اطلاعات استخراج شده، امکان تشخیص و دسته‌بندی اشیاء در تصاویر فراهم می‌شود. مطابق شکل ۴، در شبکه‌های عصبی پیچشی اغلب از شبکه عصبی معمولی دو یا سه لایه در بخش دوم استفاده می‌شود که تحت عنوان لایه‌های دارای اتصال کامل<sup>۱</sup> شناخته می‌شوند [۴۳-۴۵].

با توجه به پیچیدگی ساختار مدل و زیاد بودن تعداد پارامترهای یادگیری، دستیابی به یک ساختار بهینه کار دشوار و زمان‌بری است. علاوه بر این، فرآیند تعلیم پارامترهای یادگیری چنین مدل‌هایی نیازمند حجم انبوهی از داده است که معمولاً در مسائل پیشرو در شاخه مهندسی، جمع‌آوری حجم عظیمی از داده، هزینه و زمان زیادی نیاز دارد. روش انتقال یادگیری یکی از روش‌های پرکاربرد در یادگیری ماشین است که این مشکل را تا حد زیادی

$$\begin{aligned} LL_k(i, j) &= \sum_{m,n} l(m-2i)l(n-2j)LL_{k-1}(m, n) \\ HL_k(i, j) &= \sum_{m,n} h(m-2i)l(n-2j)LL_{k-1}(m, n) \\ LH_k(i, j) &= \sum_{m,n} l(m-2i)h(n-2j)LL_{k-1}(m, n) \\ HH_k(i, j) &= \sum_{m,n} h(m-2i)h(n-2j)LL_{k-1}(m, n) \end{aligned} \quad (۴)$$

در مجموعه روابط (۳)،  $LL_k, HL_k, LH_k$  و  $HH_k$  طرح های نرمال شده و متعامد در فضاهای  $V_k, W_k^H, W_k^V$  و  $W_k^D$  هستند که مطابق مجموعه روابط (۴) تعیین می شوند.

در مجموعه روابط (۴)،  $l$  و  $h$  به ترتیب مشخص کننده فیلترهای پایین گذر<sup>۱</sup> و بالاگذر<sup>۲</sup> هستند و  $LL_0$  بیانگر تصویر اصلی قبل شروع فرآیند تجزیه است.

همان طور که پیشتر گفته شد، با انجام فرآیند تجزیه به کمک تبدیل ویولت، زیرگروه های فرکانس بالا و فرکانس پایین از تصویر استخراج خواهد شد. با توجه به مجموعه روابط (۴)،  $HL_k, LH_k$  و  $HH_k$  زیرگروه های فرکانس بالا به ترتیب در جهت های افقی، قائم و قطری هستند و  $LL_k$  زیرگروه فرکانس پایین را مشخص می کند [۳۶، ۵۲].

در تحقیقات مختلف مشخص شده است که زیرگروه های فرکانس بالا اغلب بیانگر جزئیات موجود در تصویر برداشت شده از روسازی مانند خرابیها هستند و زیر گروه فرکانس پایین مربوط به اجزای پیش زمینه تصویر است. بر این اساس می توان با طراحی ماژول هایی با هدف اعمال تغییرات بر روی زیرگروه های فرکانس بالا، اجزای مورد نظر را از تصویر استخراج نمود و سپس در فرآیند ترکیب که معکوس فرآیند تجزیه است، تصویر پردازش شده را بازسازی کرد [۳، ۳۹، ۵۳].

#### ۴- پیاده سازی سامانه

در این بخش، روند پیاده سازی سامانه پیشنهادی در دو بخش اصلی تشریح خواهد شد. در ابتدا توضیحات مرتبط با فرآیند ساخت مدل تشخیص خرابی قیرزدگی ارائه می شود و سپس روند ایجاد یک روش پردازش تصویر مبتنی بر تبدیل موجک برای تفکیک نواحی قیرزده در تصاویر روسازی توضیح داده خواهد شد.

بندی بر اساس الگوهای استخراج شده را انجام می دهد. ساختار مدل در مجموع دارای حدود ۶۱ میلیون پارامتر است که بر اساس یک پایگاه داده عظیم متشکل از ۱/۲ میلیون تصویر در پایگاه ImageNet، به منظور تشخیص و دسته بندی تصاویر در ۱۰۰۰ دسته، تعلیم یافته است [۴۹، ۵۰].

#### ۳-۲- تبدیل موجک

تبدیل موجک یک ابزار ریاضی کاربردی در پردازش های یک بعدی (سیگنال) و دو بعدی (تصاویر) است. از آنجایی که ابزار تبدیل موجک، پردازش تصاویر را با توجه به خصوصیات تصویر در حوزه فرکانس انجام می دهد، با بهره گیری از این ابزار می توان تصویر را به چند زیر بخش فرکانسی تجزیه نمود. سپس با استفاده فیلترهای پایین گذر و بالا گذر می توان دو دسته از مقادیر (فرکانس بالا و پایین) را استخراج نمود که هر یک می توانند به ترتیب بیانگر بخش های پیش زمینه و پس زمینه در تصویر باشند. در آخر پس از اعمال تغییرات بر اجزای تجزیه شده، میتوان اطلاعات مورد نظر در تصویر را استخراج و بازسازی نمود.

در فرآیند تبدیل موجک، تصویر مطابق رابطه (۲) به زیر چند زیر بخش در فضاهای  $V_k, W_k^H, W_k^V$  و  $W_k^D$  تجزیه کرد که  $k$ ، سطح تجزیه یا تعداد تجزیه ها را بیان میکند [۲۲، ۳۹، ۵۱].

$$f_{k-1}(x, y) = V_k + W_k^H + W_k^V + W_k^D \quad (۲)$$

در رابطه (۲)،  $f_{k-1}(x, y)$  بیانگر مقدار پیکسل موجود در مختصات  $(x, y)$  در سطح تجزیه  $k$  ام است و مقادیر  $f_0(x, y)$  بیانگر مقادیر پیکسل های تصویر اصلی هستند. هر یک از مولفه های رابطه (۲) بر اساس هسته های موجک ( $\psi$  و  $\varphi$ ) به صورت زیر تعیین می شوند.

$$\begin{aligned} V_k &= 2^{-k} \sum_{m,n} LL_k(m, n) \varphi(2^{-k}x-m) \varphi(2^{-k}y-n) \\ W_k^H &= 2^{-k} \sum_{m,n} HL_k(m, n) \varphi(2^{-k}x-m) \psi(2^{-k}y-n) \\ W_k^V &= 2^{-k} \sum_{m,n} LH_k(m, n) \psi(2^{-k}x-m) \varphi(2^{-k}y-n) \\ W_k^D &= 2^{-k} \sum_{m,n} HH_k(m, n) \psi(2^{-k}x-m) \psi(2^{-k}y-n) \end{aligned} \quad (۳)$$

1 Low-Pass filter  
2 High-Pass filter

#### ۴-۱- تشخیص قیرزدگی

در این پژوهش، به منظور ارائه یک سامانه مبتنی بر تصویر برای تشخیص خرابی قیرزدگی از مدل‌های مبتنی بر یادگیری عمیق استفاده شده است. اولین گام برای ایجاد این مدل‌ها، جمع آوری و آماده سازی یک پایگاه داده غنی است. داده های بکار گرفته شده برای ساخت یک مدل، تأثیر زیادی بر عملکرد مدل دارند. از این رو به منظور کاهش احتمال بروز مشکلاتی نظیر اضافه برآزش و تعلیم ناقص مدل‌ها، سعی شده است که یک پایگاه داده متشکل از تصاویر روسازی با تنوع بالا و تعداد مناسب جمع آوری شود.

لازم به ذکر است که تعداد داده مورد نیاز برای بازتعلیم شبکه به روش پیاده سازی تکنیک انتقال یادگیری بستگی دارد. به طوری که هرچه نسبت بخش هایی از مدل که در فرآیند بازتعلیم شرکت داده می شوند افزایش یابد، به تعداد داده بیشتری برای فرآیند بازتعلیم نیاز خواهد بود.

در این پژوهش تمامی لایه های مربوط به بخش استخراج ویژگی مدل بدون تغییر بکار گرفته شده اند و در عملیات بازتعلیم شرکت داده نشده اند و فقط بخش دسته بندی کننده مدل در فرآیند بازتعلیم شرکت داده است. از این رو، تعداد داده های مورد نیاز برای عملیات بازتعلیم مدل تا حد زیادی کاهش می یابد.

با بررسی مطالعات گذشته می توان دریافت، در مواردی که شیوه بکارگیری تکنیک انتقال یادگیری مشابه با شیوه بکار گرفته شده در پژوهش حاضر است، تعداد داده های استفاده شده در محدوده ۱۰۰۰ تا ۲۰۰۰ تصویر بوده است، به طوری که گااً و مسالام [۵۴] در پژوهش خود از تکنیک یادگیری عمیق با بکارگیری ۲۰۰۰ تصویر، مدلی جهت تشخیص خرابی های ساختمان ارائه کرده اند. همچنین گپالاکریشنان و همکاران [۴۵] در پژوهش خود به منظور ایجاد مدل تشخیص ترک های روسازی، از تکنیک انتقال یادگیری بر اساس ۱۰۵۶ تصویر استفاده کرده اند.

در این پژوهش یک پایگاه داده متشکل از ۱۵۴۰ تصویر با رزولوشن  $970 \times 2480$  پیکسل از روسازی های دارای خرابی قیرزدگی و بدون خرابی قیرزدگی جمع آوری شده است. لازم به توضیح است که با توجه به ماهیت خرابی قیرزدگی، احتمال وقوع آن در مناطق گرمسیری بیشتر از سایر مناطق است. به همین دلیل در این پژوهش، عملیات جمع آوری داده از جاده های اصلی در محورهای موجود در مناطق گرم نظیر محورهای ایرانشهر-چابهار، رستم آباد-چابهار و اردکان-نابین انجام شده است و به طور متوسط در هر ۱۰ یک تصویر از روسازی برداشت شده است.


در مدل‌های یادگیری عمیق، استخراج الگو از داده‌ها به صورت خودکار

انجام می شود. از این رو برای بهبود عملکرد مدل‌ها، وضوح و کیفیت تصاویر از اهمیت بالایی برخوردار است و با بکارگیری یک فرآیند پیش پردازش ارتقاء داده شده است. همان طور که در شکل ۶ نشان داده شده است، ابتدا باید بخشی از تصاویر که جزئیات روسازی در آن به خوبی ثبت شده است (این ناحیه با توجه به یکسان بودن کیفیت برداشت تصویر و ارتفاع نصب دوربین، تا حد زیادی ثابت است) برش داده شود. برای این منظور ناحیه مشخص شده در شکل ۶ بخش ۱، به صورت خودکار از تصاویر برش داده می شود. در ادامه ناحیه برش داده شده به مقیاس خاکستری تبدیل می شود (شکل ۶ بخش ۳).

سپس با بکارگیری تسهیم هیستوگرام (شکل ۶ بخش ۴)، مقادیر روشنایی پیکسل ها محدوده گسترده تری از مقادیر را پوشش خواهد داد که نتیجه این امر، ایجاد تصاویری با کنتراست و وضوح بالاتر خواهد بود. در این عملیات، مقدار پیکسل های تصویر در بازه صفر تا یک نرمال می شوند و تابع چگالی احتمال مقدار پیکسلها تعیین میگردد و سپس با اعمال یک تابع انتقال روی مقدار پیکسل ها، مقدار جدید پیکسل های تصویر مشخص می شود. لازم به ذکر است که در این فرآیند، تابع توزیع تجمعی مقدار پیکسل ها به عنوان تابع انتقال مورد استفاده قرار می گیرد [۵۱]. در شکل ۷ جزئیات فرآیند تسهیم هیستوگرام تصاویر نمایش داده شده است.

پس از انجام فرآیند آماده سازی پایگاه داده، بخشی از تصاویر باید به عملیات تعلیم و اعتبارسنجی و بخش دیگر به عملیات ارزیابی مدل اختصاص داده شوند. در مسائل یادگیری ماشین، فرآیند تقسیم پایگاه داده برای عملیات تعلیم و ارزیابی مدل باید به گونه ای باشد که از یک سو تعداد داده مناسب برای عملیات تعلیم مدل فراهم شود و از سوی دیگر تعداد داده های ارزیابی مدل به میزانی باشد که بتوان با سطح اطمینان مناسب عملکرد مدل را مورد بررسی قرار داد. میزان محدودیت در پایگاه داده از جمله مهمترین عوامل اثرگذار بر فرآیند تقسیم پایگاه داده به شمار میرود؛ به طوری که هرچه محدودیت در جمع آوری داده کمتر باشد، نسبت داده های اختصاص داده شده به فرآیند تعلیم و ارزیابی مدل، یکسان (۵۰-۵۰) در نظر گرفته خواهد شد.

از سوی دیگر هرچه محدودیت در جمع آوری داده بیشتر باشد، بخش عمده داده ها باید به فرآیند تعلیم اختصاص پیدا کند؛ زیرا فرآیند تعلیم مدل باید تعداد داده مناسب انجام شود و در غیر این صورت مدل به مشکل تعلیم ناقص دچار خواهد شد. از سوی دیگر باید به این نکته توجه شود که اگر تعداد داده های تست خیلی کم باشد، نمی توان با اطمینان کافی عملکرد



شکل ۶. فرآیند آماده سازی پایگاه داده. (۱) تصویر اولیه، (۲) ناحیه مورد بررسی، (۳) تصویر در مقیاس خاکستری، (۴) نتیجه تسهیم هیستوگرام.

**Fig. 6. Dataset preparation process; 1) initial image, 2) region of interest, 3) gray scale image, 4) histogram equalization**

بر اساس پایگاه داده جمع آوری شده مورد تعلیم قرار خواهد گرفت و بخش استخراج کننده ویژگیها بدون تغییر باقی خواهد ماند. در این پژوهش با استفاده از روش انتقال یادگیری، بخش اعظم شبکه AlexNet که مربوط به استخراج ویژگی است در فرآیند تعلیم تغییر نخواهد کرد (شکل ۹) و تعداد پارامترهای یادگیری به طور قابل توجهی کاهش خواهد یافت. این موضوع موجب می شود تا بتوان با تعداد داده و زمان کمتر و همچنین توان پردازشی پایینتر، مدل را بر اساس تصاویر جدید بکار گرفت.

پیش از آغاز فرآیند بازتعلیم مدل به کمک تکنیک انتقال یادگیری، باید برخی از پارامترهای مؤثر در روند یادگیری تعیین شوند که از آن جمله می توان به تعداد دوره ها، تعداد داده در هر تکرار، تعداد تکرار، نرخ یادگیری و مقدار تکانه اشاره نمود. در ادامه توضیحاتی پیرامون تنظیم این پارامترها ارائه شده است.

تعداد دوره های یادگیری به تعداد دفعاتی که تمامی داده های تعلیم در روند یادگیری مدل ها بکار گرفته می شوند، اطلاق می شود. در صورتی که تعداد دوره ها زیاد در نظر گرفته شوند، سبب بروز مشکلاتی نظیر اضافه برآزش و افزایش زمان پردازش می شود. از سوی دیگر، کم بودن تعداد دوره ها سبب ناقص انجام شدن فرآیند یادگیری خواهد شد. در این پژوهش


مدل را بررسی نمود.

در پژوهش حاضر، با توجه به اینکه پایگاه داده بسیار گسترده ای از تصاویر روسازی دارای قیرزدگی در دسترس نبود، تلاش شد که تعداد داده مناسب برای عملیات تعلیم و تست فراهم شود؛ به طوری که هم عملیات تعلیم بدون نقص انجام شود و هم داده های تست به مقداری باشد که بتوان با سطح اطمینان مناسبی عملکرد مدل را بررسی نمود. بر این اساس، همان طور که در جدول ۱ نشان داده شده است، ۱۰۰۰ داده از ۱۵۴۰ داده (۶۵ درصد) به عملیات تعلیم و اعتبارسنجی اختصاص داده شد که با توجه به تکنیک انتقال یادگیری بکار گرفته شده و مطالعات گذشته، مقدار مناسبی به نظر می رسد. همچنین ۵۴۰ داده از ۱۵۴۰ داده (۳۵ درصد) به فرآیند تست مدلها اختصاص داده شد و می توان با سطح اطمینان مناسبی عملکرد مدل را بررسی نمود.

نمونه هایی از تصاویر آماده سازی شده برای انجام فرآیند تعلیم و ارزیابی مدل در شکل ۸ ارائه شده است.

به منظور ساخت مدل تشخیص قیرزدگی از روش انتقال یادگیری استفاده شده است. در این روش شبکه عصبی پیچشی از پیش تعلیم یافته AlexNet مورد باز تعلیم قرار گرفته است. در این پژوهش مطابق شکل ۹، بخش دسته بندی کننده (لایه های با اتصال کامل) مدل از پیش تعلیم یافته






شکل ۷. جزئیات فرآیند تسهیم هیستوگرام. (۱) هیستوگرام تصویر اولیه، (۲) تابع توزیع تجمعی مقدار پیکسل ها، (۳) هیستوگرام تصویر نهایی.

Fig. 7. The process of histogram equalization; 1) histogram of initial image, 2) cumulative distribution of pixel values, 3) histogram of final image

جدول ۱. داده های آماده سازی شده

Table 1. Preprade data

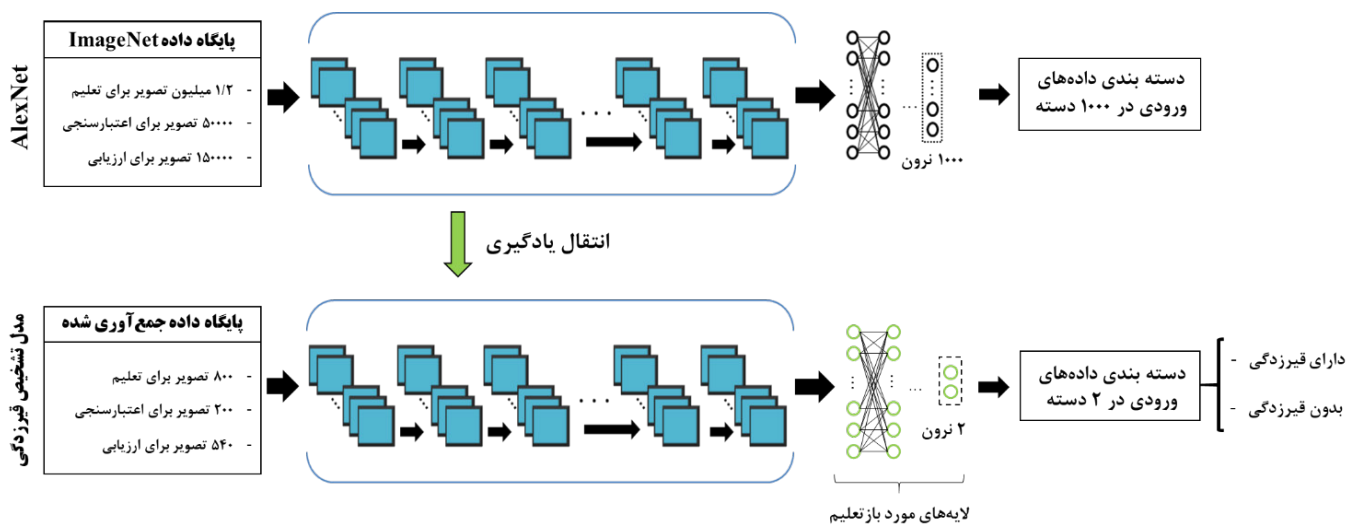
عملیات ارزیابی مدل‌ها	عملیات یادگیری مدل‌ها		دسته بندی
	اعتبارسنجی	تعلیم	
۲۷۰	۱۰۰	۴۰۰	B (دارای قیرزدگی)
۲۷۰	۱۰۰	۴۰۰	N (بدون قیرزدگی)
۵۴۰	۱۰۰۰		مجموع



شکل ۸. نمونه هایی از تصاویر مورد استفاده در فرآیند تعلیم و ارزیابی مدل، (الف) بدون خرابی قیرزدگی (ب) دارای خرابی قیرزدگی.

Fig. 8. Examples of train and test image; a) image without bleeding, b) image with bleeding





شکل ۹. فرآیند انتقال یادگیری

Fig. 9. Transfer learning process

دوره یادگیری، در کل فرآیند یادگیری ۸۰۰ تکرار باید انجام شود. لازم به ذکر است که اگر تعداد تکرار خیلی زیاد باشد، منجر به اضافه برآزش و افزایش زمان پردازش خواهد شد.

نرخ یادگیری<sup>۱</sup> و مقدار تکانه<sup>۲</sup> پارامترهای دیگری هستند که در نتیجه یادگیری و سرعت همگرایی مدل تأثیر زیادی دارند. در صورتی که مقدار نرخ یادگیری زیاد باشد موجب عدم همگرایی مدل خواهد شد و در صورتی که خیلی کم باشد، سرعت همگرایی مدل تا حد زیادی کاهش پیدا میکند و احتمال یادگیری نادرست مدل افزایش می یابد. مقدار نرخ یادگیری به و صورت ثابت و متغیر قابل تعیین است و مقدار پایه معمولاً به صورت تجربی بین ۰/۰۰۱ تا ۱ و مقدار مومنتوم بین ۰ تا ۱ در نظر گرفته میشود. در این پژوهش، مقدار نرخ یادگیری و تکانه به ترتیب ۰/۰۰۱ و ۰/۹ در نظر گرفته شده‌اند که در برخی از مطالعات گذشته نیز استفاده شده‌اند [۱۸، ۴۶، ۵۵]. مقدار پارامترهای مؤثر در فرآیند یادگیری مدلها به طور خلاصه در جدول ۲ ارائه شده است.

#### ۴-۲- تفکیک نواحی قیرزده

در سامانه پیشنهاد شده، تصاویری که توسط مدل ساخته شده در مرحله

همان‌طور با بررسی روند تعلیم مدل‌ها می‌توان گفت که نرخ خطا و دقت مدل‌ها تقریباً بعد از ۱۰ دوره پایدار گشته و فرآیند 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 کل داده‌های تعلیم انتخاب شود. تعداد زیاد نمونه‌ها در هر تکرار نیازمند سیستم پردازشی قدرتمند است. در این مقاله با توجه به توان پردازشی رایانه، تعداد ۲۰ 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 (۵)،  $N$  تعداد کل داده‌های تعلیم و  $n$  تعداد نمونه در هر تکرار است.

با توجه به در نظر گرفتن ۲۰ نمونه در هر تکرار، ۴۰ تکرار برای انجام یک دوره یادگیری متشکل از ۸۰۰ نمونه (داده) نیاز است و با احتساب ۱۵

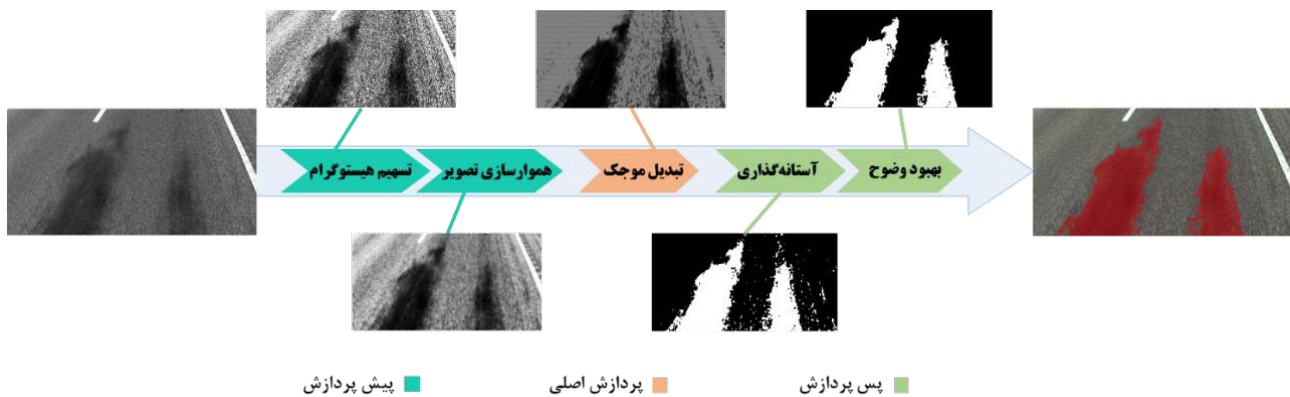
1 Learning Rate

2 Momentum

جدول ۲. پارامترهای مؤثر در فرآیند یادگیری

Table 2. The value of the effective factors in learning process

مقدار به کار گرفته شده	پارامتر
۱۵	تعداد دوره یادگیری
۴۰	تعداد تکرار در هر دوره یادگیری
۲۰	تعداد نمونه در هر تکرار
۰/۰۰۱	نرخ یادگیری
۰/۹	تکانه



شکل ۱۰. فرآیند تفکیک نواحی قیرزده

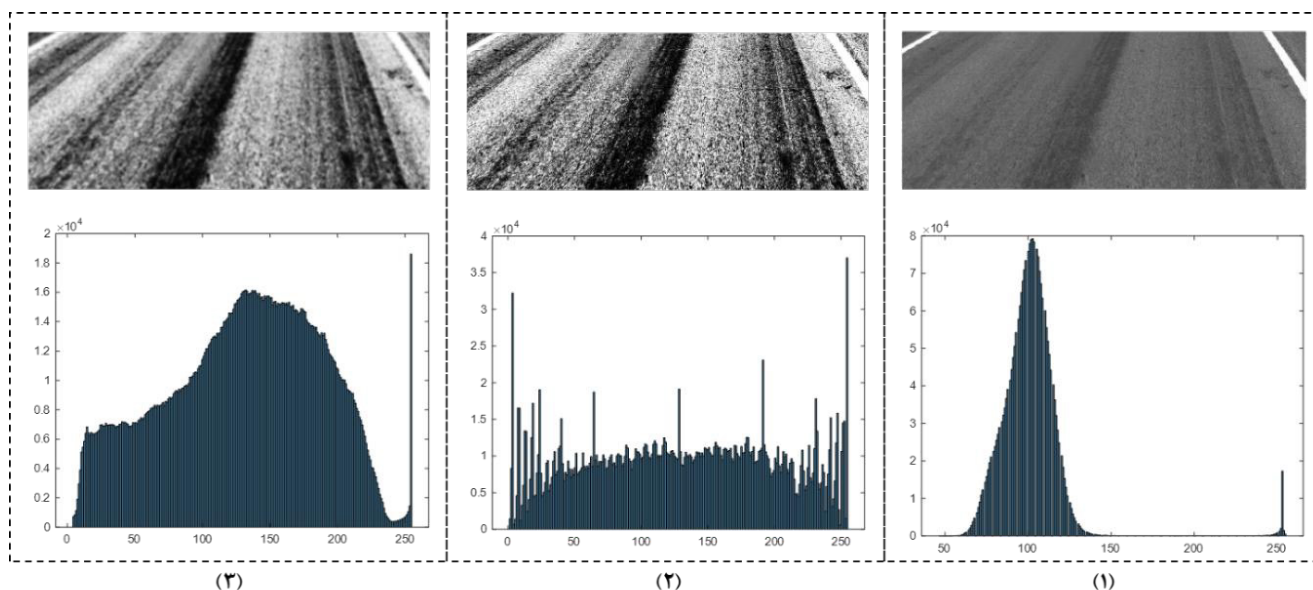
Fig. 10. Process of segmenting bleeding areas

نکته اساسی در تعیین فیلتر مناسب برای انجام فرآیند هموارسازی، توانایی فیلتر در حفظ لبه اشیاء و کاهش نویزهای موجود در تصویر است. فیلتری که بیشترین نویز را حذف کند و علی‌رغم ایجاد تارشدگی تا حد امکان لبه اشیاء را حفظ کند، فیلتر مناسبی برای انجام فرآیند خواهد بود. با بررسی فیلترهای مختلف، فیلتر مبتنی بر تابع گوسی برای این منظور بکار گرفته شده است.

در فیلتر گوسی مورد استفاده، میزان هموارسازی تصویر در راستای افقی و عمودی با پارامتر  $\sigma$  قابل تنظیم است. در نظر گرفتن مقادیر خیلی بزرگ موجب از بین رفتن جزئیات تصویر می شود و از طرف دیگر در نظر گرفتن مقادیر کوچک در حذف نویزهای تصویر اختلال ایجاد می کند. در این پژوهش پس از بررسی اثر مقادیر مختلف بر نتیجه نهایی، مقدار پارامتر فیلتر گوسی برابر ۵ در نظر گرفته شده است.

قبل دارای خرابی قیرزدگی تشخیص داده می شوند، در گام بعدی وارد یک فرآیند پردازش تصویر خواهند شد تا نواحی قیرزده در تصاویر تعیین و تفکیک شوند (شکل ۳). اجزای اصلی فرآیند طراحی شده در این پژوهش و نحوه کارکرد هر یک از بخش ها در شکل ۱۰ ارائه شده است.

همان‌طور که در شکل ۱۰ نمایش داده شده است، بخش ابتدایی این فرآیند به منظور انجام پیش‌پردازش تصاویر در نظر گرفته شده است. در این بخش، به منظور بهبود توزیع مقدار پیکسلها و افزایش وضوح تصویر از روش تسمیم هیستوگرام استفاده شده است. همچنین برای دستیابی به خروجی های بهتر و دقیقتر، عملیات هموارسازی تصویر برای کاهش نویزهای موجود در تصویر و ایجاد تصویری همگن تر بکار گرفته شده است. در شکل ۱۱، نمایی از فرآیند پیش پردازش و هیستوگرام مقدار روشنایی پیکسلها نمایش داده شده است.



شکل ۱۱. هیستوگرام تصویر در فرآیند پیش پردازش؛ (۱) تصویر اولیه، (۲) تسهیم هیستوگرام، (۳) هموارسازی تصویر.

Fig. 11. Histogram of the image in pre-processing; 1) initial image, 2) histogram equalization, 3) image smoothing

هریک از پارامترها مورد ارزیابی قرار گرفته است.

سطح  $K$ ، تعداد مرتبه های تجزیه تصویر را مشخص می کند. اگر مقدار این پارامتر کم در نظر گرفته شود ممکن است جزئیات مد نظر به خوبی از تصویر استخراج نشود و اگر مقدار آن زیاد باشد، اغلب عملیات تجزیه بیش از اندازه انجام شده و موجب بروز ناهنجاری و تشخیص نادرست اجزای مورد نظر می شود. در این پژوهش، اطلاعات به دست آمده از مرتبه سوم تجزیه تصویر به نتایج قابل قبولی منجر شده است.

متغیر  $R$  با هدف تنظیم حساسیت تبدیل موجک برای استخراج اجزای مورد نظر استفاده می شود. در محدوده یک تا ده، مقدار این پارامتر با میزان حساسیت رابطه مستقیم دارد. اگر مقدار این پارامتر زیاد باشد، میزان جزئیات استخراج شده بیش از اندازه خواهد بود و سبب ایجاد نویز در نتایج خروجی خواهد شد و اگر مقدار آن کم باشد ممکن است جزئیات مد نظر به طور کامل استخراج نشوند. متغیر  $N$  نیز در محدوده بین صفر تا یک، اثر معکوس بر حساسیت دارد و اثر این متغیر شدیدتر از متغیر  $R$  است. متغیر  $S$  تأثیر یکنواختی بر میزان حساسیت ندارد و مقدار ۲ برای این پارامتر مناسبترین عملکرد را داشته است.

در این پروژه با سعی و خطا و بررسی اثر مقادیر مختلف بر کیفیت نتایج خروجی، مشخص شد که مقدار سه برای متغیر  $K$ ، مقادیر بین ۰/۰۰۸ و ۰/۰۰۹ برای متغیر  $N$  و مقادیر بین ۲ و ۴ برای متغیر  $R$  نتایج قابل قبولی

مطابق شکل ۱۰، پس از انجام پیش پردازش، تصاویر وارد فرآیند پردازش مبتنی بر تبدیل موجک خواهند شد. در این فرآیند، از ابزار تبدیل موجک به منظور استخراج زیر بخشهای فرکانسی تصویر و اعمال یک فیلتر بر فرکانسهای بالا استفاده شده است. فرکانس های بالا در تصاویر روسازی بیانگر جزئیات خرابی های موجود در تصویر روسازی است.

در این مرحله ابتدا به کمک تبدیل موجک زیر گروه های فرکانس بالا و فرکانس پایین از تصویر استخراج می شود و سپس یک مازول که از ترکیب زیرگروه های فرکانس بالا است به منظور استخراج اشیا موجود در تصویر تعریف می شود. با بررسی مطالعات گذشته و ارزیابی اثر ترکیب های مختلف، در این پژوهش به منظور استخراج اجزای مربوط به نواحی قیرزده یک مازول مطابق رابطه (۶) ارائه شده است.


$$M_{s,k}(p,q) = \left[ (HL_k^s(p,q) + LH_k^s(p,q) + HH_k^s(p,q)) \times N \right]^{\frac{1}{R}} \quad (6)$$

در رابطه (۶)، پارامترهای  $HL_k(p,q)$ ،  $LH_k(p,q)$  و  $HH_k(p,q)$  به ترتیب زیرگروه های فرکانس بالا در راستای افقی، قائم و قطری مناظر با پیکسل موجود در موقعیت  $(p,q)$  در سطح  $k$  ام تبدیل موجک هستند.  $S$ ،  $N$  و  $R$  پارامترهایی هستند که برای تنظیم حساسیت مازول در استخراج اجزاء بکار گرفته می شوند. در ادامه نحوه اثرگذاری

جدول ۳. مقدار مناسب پارامترهای مازول تبدیل موجک

Table 3. The best value for wavelet module parameters

پارامتر	مقدار (محدوده) مناسب
k	۳
S	۲
N	[۰/۰۰۸, ۰/۰۰۹]
R	[۲, ۴]



شکل ۱۲. استخراج نواحی قیرزده، (۱) خروجی عملیات پیش پردازش (۲) خروجی فیلتر مبتنی بر تبدیل موجک

Fig. 12. Extracting bleeding regions; 1) pre-processing output, 2) output of the wavelet-based filter

گذاری در نتایج به دست آمده، اشیاء کوچک یا نویزهایی وجود دارد که که این امر موجب کاهش کیفیت و وضوح خروجی فرآیند شده است. برای رفع این مشکل از عملگرهای مورفولوژیکی به منظور حذف این عناصر استفاده شده است. در شکل ۱۳، عملکرد فرآیند بکار گرفته شده برای بهبود نتایج، نمایش داده شده است.

در پایان این بخش، لازم به ذکر است که تمامی عملیات انجام شده در این پژوهش با استفاده از یک رایانه شخصی با سیستم اجرایی ۶۴ بیتی، ۸ گیگابایت فضای حافظه، پردازنده Intel(R) Core i7-4710HQ 2.50 GHz و پردازنده گرافیکی GeForce GTX 850M انجام شده‌اند.

#### ۵- نتایج و بحث

در این بخش نتایج به دست آمده از پیاده سازی سامانه با بررسی سرعت و دقت بخش های مختلف سامانه به عنوان دو پارامتر مهم در سامانه های مدیریت روسازی، ارائه شده است.

را به منظور استخراج نواحی قیرزده دارند. همچنین به منظور انجام تبدیل موجک از فیلتر coif1 استفاده شده است. در جدول ۳ مقدار مناسب برای پارامترهای مازول تبدیل موجک، ارائه شده است.

در شکل ۱۲، نتیجه بکارگیری مازول تبدیل موجک طراحی شده برای استخراج نواحی قیرزده روی یک نمونه از تصاویر دارای خرابی قیرزدگی نشان داده شده است.

همان طور که در شکل ۱۲ مشاهده می شود، فیلتر مبتنی بر تبدیل موجک طراحی شده در این پژوهش تا حد زیادی نواحی دارای خرابی قیرزدگی را از تصاویر استخراج کرده است. در گام بعد فرآیندی به منظور بهبود نتایج به دست آمده استفاده شده است. این فرآیند از عملیات آستانه گذاری سراسری و عملیات مورفولوژیکی تشکیل شده است.

با انجام عملیات آستانه گذاری سراسری روی تصاویر به دست آمده از تبدیل موجک، تصویر باینری از نواحی دارای خرابی و بدون خرابی ایجاد می شود. این پردازش موجب تفکیک بهتر نواحی قیرزدگی و فراهم شدن امکان بررسی مشخصات هندسی نواحی خرابی می شود. پس از انجام آستانه



شکل ۱۳. فرآیند پس پردازش. ۱) آستانه گذاری سراسری، ۲) عملیات مورفولوژیک حذف اشیاء کوچک

Fig. 13. Post-processing; 1) global thresholding, 2) morphological operations

در جدول ۴، اطلاعات به دست آمده از ماتریس درهم ریختگی و معیارهای عملکردی محاسبه شده ارائه شده است.

در ادامه توضیحات بیشتری در مورد معیارهای ذکر شده و ارزیابی عملکرد مدل بر اساس هر یک از معیارها ارائه خواهد شد.

معیار صحت: این معیار یکی از رایج ترین معیارهای ارزیابی مدل ها به شمار می رود و بر اساس رابطه (۷) یک نمای کلی از میزان دقت مدل ها با تعیین نسبت پاسخ های صحیح (TP و TN) به کل پاسخ ها ارائه می دهد.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

مطابق جدول ۴، عملکرد مدل ایجاد شده بر اساس این معیار ۹۸/۱۴ درصد بوده است که بیانگر عملکرد خوب مدل در تشخیص خرابی قیرزدگی است. لازم به ذکر است که در مسائلی که داده ها در دو دسته قرار می گیرند، عملکرد مدل برای هر یک از دسته ها برابر عملکرد کلی مدل خواهد بود.

معیار حساسیت: این معیار میزان توانایی و حساسیت مدل ها را در انجام دسته بندی صحیح مشخص می کند. به عبارت دیگر حساسیت و صحت عملکرد مدلها در مواقعی که باید پاسخ مثبت داشته باشند را ارزیابی میکند. مطابق رابطه (۸)، این امر با محاسبه نسبت پاسخ های مثبت صحیح به مجموع پاسخ های مثبت صحیح و پاسخ های منفی غلط انجام می شود. این معیار همچنین با نام های نرخ پاسخ مثبت صحیح<sup>۶</sup> و میزان فراخوانی<sup>۷</sup> مدل نیز شناخته می شود.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (8)$$

6 True Positive Rate  
7 Recall

#### ۵-۱- عملکرد سامانه در تشخیص قیرزدگی

همان طور که در بخش ۴ توضیح داده شد، بخش مرتبط با تشخیص خرابی قیرزدگی شامل عملیات پیش پردازش و عملیات ساخت مدل با استفاده از روش انتقال یادگیری است. زمان مورد نیاز برای انجام این فرآیند از جمله پارامترهای عملکردی سامانه است. با توجه به سیستم پردازشی استفاده شده در این مطالعه، زمان سپری شده به منظور انجام پیش پردازش و آماده سازی تصاویر ۰/۴۴ ثانیه به ازای هر تصویر بوده است. همچنین زمان سپری شده در فرآیند ارزیابی مدل به ترتیب ۰/۰۴۲ ثانیه به ازای هر تصویر بوده است. دقت و کارایی مدل ایجاد شده، از دیگر مولفه های عملکرد مدل به شمار می رود. برای بررسی دقت و کارایی مدل در تشخیص خرابی قیرزدگی، مدل ایجاد شده با استفاده از داده های ارزیابی که مستقل از داده های تعلیم هستند مورد بررسی قرار گرفت. تشکیل ماتریس درهم ریختگی<sup>۱</sup> یکی از بهترین روش های ارزیابی دقت مدل های ایجاد شده برای انجام تشخیص و دسته بندی است.

این ماتریس با مقایسه ی نتایج حاصل از مدل با واقعیت، پاسخ های به دست آمده از مدل ها در هر یک از دسته ها (دارای قیرزدگی و بدون قیرزدگی) را با چهار حالت بررسی می کند که عبارتند از: پاسخ مثبت صحیح (TP<sup>۲</sup>)، پاسخ منفی صحیح (TN<sup>۳</sup>)، پاسخ مثبت غلط (FP<sup>۴</sup>) و پاسخ منفی غلط (FN<sup>۵</sup>).


با استفاده از اطلاعات به دست آمده از ماتریس درهم ریختگی، معیارهای عملکردی نظیر صحت (accuracy)، حساسیت (sensitivity)، دقت (precision) و معیار امتیاز F (F-score) محاسبه و ارزیابی شده اند.

- |   |                  |
|---|------------------|
| 1 | Confusion Matrix |
| 2 | True Positive    |
| 3 | True Negative    |
| 4 | False Positive   |
| 5 | False Negative   |

جدول ۴. ارزیابی عملکرد مدل تشخیص قیرزدگی

Table 3. Evaluating the performance of the bleeding detection model

معیارهای عملکرد				اجزای ماتریس درهم ریختگی				دسته‌ها
F-score	Precision	Sensitivity	Accuracy	TP	TN	FP	FN	
۰/۹۸۱۲	۰/۹۹۴۹	۰/۹۶۷۹	۰/۹۸۱۴	۲۶۱	۲۶۹	۱	۹	B (دارای قیرزدگی)
۰/۹۸۱۷	۰/۹۶۸۷	۰/۹۹۵۱		۲۶۹	۲۶۱	۹	۱	N (بدون قیرزدگی)
۰/۹۸۱۵	۰/۹۸۱۸	۰/۹۸۱۵						مجموع



شکل ۱۴. عملکرد مدل ارائه شده بر اساس معیارهای مختلف

Fig. 14. The model performance based on the various metrics

بدون قیرزدگی (۹۶/۸۷ درصد) بوده است (شکل ۱۴). این بدان معناست که اگر جواب مدلها برای یک تصویر، وجود قیرزدگی باشد بیشتر می توان به پاسخ اعتماد کرد. در مجموع مدل ارائه شده با متوسط ۹۸/۱۸ دارای ارزش پیشبینی مثبت بالایی است و با سطح اطمینان بالایی می توان به پاسخ های مدل اعتماد کرد.

معیار امتیاز F: این معیار یکی از جامع ترین معیارهای ارزیابی دقت و عملکرد مدل های دسته بندی و پیش بینی است که مطابق رابطه (۱۰) با محاسبه میانگین همساز وزنی<sup>۲</sup> دو معیار دقت و حساسیت تعیین می شود.

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

با ارزیابی این معیار می توان به طور هم زمان با توجه به ارزش پیشبینی مثبت و حساسیت، عملکرد مدلها را بررسی نمود. همان طور که در شکل ۱۴ نشان داده شده است، عملکرد مدل بر اساس این معیار بالای ۹۸/۱۵ درصد

مطابق شکل ۱۴، بررسی عملکرد مدل بر اساس این معیار نشان می دهد که مدل به تصاویر بدون قیرزدگی حساستر است. زیرا میزان صحت مدل در تشخیص تصاویر بدون خرابی قیرزدگی ۹۹/۵۱ درصد و در تشخیص تصاویر دارای خرابی ۹۶/۷۹ بوده است. مدل ایجاد شده در مجموع با عملکرد ۹۸/۱۵ درصدی، حساسیت قابل قبولی در تشخیص قیرزدگی داشته است.

معیار دقت: این معیار یکی از پارامترهای مهم در ارزیابی مدلها است که میزان دقت و اعتمادپذیری پاسخ های مثبت مدلها را مشخص می کند یا به عبارت دیگر احتمال صحیح بودن پاسخ های مثبت مدلها را تعیین می کند. این معیار با نام ارزش پیش بینی مثبت<sup>۱</sup> نیز شناخته می شود و مطابق رابطه (۹) محاسبه می شود.

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

بر اساس این معیار می توان گفت که در مدل ساخته شده، ارزش پاسخ مثبت در دسته بندی تصاویر دارای قیرزدگی (۹۹/۴۹ درصد) بیشتر از تصاویر

2 Weighted Harmonic Mean

1 Positive Predictive Value



با تصویر حقیقت مبنا است. FP، تعداد پیکسل هایی از خروجی مدل که با تصویر مبنا همپوشانی ندارد را مشخص می کند. پارامتر FN بیانگر تعداد پیکسل هایی از تصویر مبنا است که با خروجی مدل همپوشانی ندارد.

به عبارت دیگر در این پژوهش، TP بیانگر نواحی است که در خروجی مدل و تصویر مبنا به صورت یکسان برچسب گذاری شده اند. FP بیانگر پیکسل هایی است که مدل به اشتباه به عنوان ناحیه قیرزده برچسب گذاری کرده است و FN مواردی را مشخص میکند که در تصویر مبنا به عنوان ناحیه قیرزده برچسب گذاری شده، ولی در خروجی مدل به عنوان ناحیه قیرزده مشخص نشده است. در شکل ۱۵، چند نمونه از موارد بررسی تطابق و شباهت تصاویر خروجی مدل با تصاویر مبنا با استفاده از معیارهای صحت و ضریب تشابه دایس، ارائه شده است.

سامانه پیشنهاد شده به منظور تفکیک و قطعه بندی نواحی قیرزده، با متوسط ۸۹/۹۴ و ۸۷/۴۷ درصدی به ترتیب بر اساس معیار صحت و ضریب تشابه دایس، عملکرد قابل قبولی داشته است. همچنین در شکل ۱۶، جزئیات بیشتری از توزیع مقادیر به دست آمده در بررسی عملکرد مدل بر اساس معیارهای ذکر شده، با استفاده از نمودار جعبه ای ارائه شده است.

بررسی نمودارهای جعبه ای ارائه شده در شکل ۱۶ نشان می دهد که پراکندگی مقادیر محاسبه شده برای معیارها، به ویژه برای معیار ضریب تشابه دایس، کم بوده است و میتوان گفت که مدل روی تصاویر عملکرد خوبی داشته است. به طوری که بخش عمده نتایج برای معیار صحت در محدوده ۸۵ تا ۹۶ درصد و برای معیار ضریب تشابه دایس در محدوده ۸۵ تا ۹۰ درصد بوده است. لازم به ذکر است که عملیات تفکیک نواحی قیرزده در سامانه ارائه شده، به طور متوسط با سرعت ۱/۵۵ ثانیه به ازای هر تصویر انجام می شود.

در پایان این بخش، به مقایسه عملکرد سامانه های ارائه شده در مطالعات گذشته به منظور ارزیابی خودکار قیرزدگی با عملکرد بخش های مختلف سامانه ارائه در این پژوهش پرداخته خواهد شد. سامانه مبتنی بر آنتروپی تصاویر که توسط هادجی متریو و کرسودولو [۴۱] ارائه شده است، بر اساس نتایج گزارش شده قادر است وجود خرابی قیرزدگی را با حساسیت ۶۵/۵ درصدی تشخیص دهد. این سامانه تنها به منظور تشخیص خرابی ارائه شده و امکان تفکیک نواحی خرابی وجود ندارد.

سامانه ی مبتنی بر مدل های Faster R-CNN که توسط سانگ و وانگ [۲۱] ارائه شده است، امکان تشخیص وجود خرابی و تعیین موقعیت کلی نواحی خرابی را با صحت ۸۷/۲ درصدی و حساسیت ۸۵/۵ درصدی

است و تفاوت چندانی بین عملکرد مدل برای تشخیص تصاویر دارای خرابی و بدون خرابی قیرزدگی وجود ندارد.

بر اساس ارزیابی عملکرد مدل با معیارهای مبتنی بر ماتریس درهم ریختگی، میتوان شبکه های پیشی عمیق را به عنوان یک ابزار قدرتمند در تشخیص و دسته بندی خرابی قیرزدگی به حساب آورد.

## ۵-۲- عملکرد سامانه در تفکیک نواحی قیرزده

بررسی عملکرد فرآیند طراحی شده در این پژوهش به منظور تفکیک و قطعه بندی نواحی قیرزده، بر اساس میزان تطابق نتایج به دست آمده از مدل پیشنهادی با واقعیت موجود در تصاویر انجام شده است. به منظور انجام این ارزیابی، بخشی از تصاویر جمع آوری شده بر مبنای واقعیت موجود در تصاویر بررسی شده و نواحی قیرزده در تصاویر به صورت دستی برچسب گذاری شده اند. این تصاویر به عنوان حقیقت مبنا<sup>۲</sup> در بررسی عملکرد مدل پیشنهادی بکار گرفته شده اند.

در این پژوهش، از ضریب تشابه دایس<sup>۳</sup> و معیار فراخوانی<sup>۴</sup> یا حساسیت برای بررسی میزان شباهت و تطابق تصاویر به دست آمده از مدل با تصاویر حاصل از بررسی دستی و دقیق نواحی قیرزده، استفاده شده است. معیار فراخوانی (حساسیت) به منظور بررسی حساسیت مدل در مواردی که باید نواحی قیرزده را تفکیک کند، استفاده شده است که نحوه محاسبه آن در رابطه (۸) ارائه شده است.

ضریب تشابه دایس از جمله معیارهای پر کاربرد در بررسی عملکردهای قطعه بندی تصاویر به شمار میرود. این معیار نسبت اشتراک به اجتماع دو مجموعه را مطابق رابطه (۱۱)، به عنوان معیار شباهت دو مجموعه تعیین می کند.

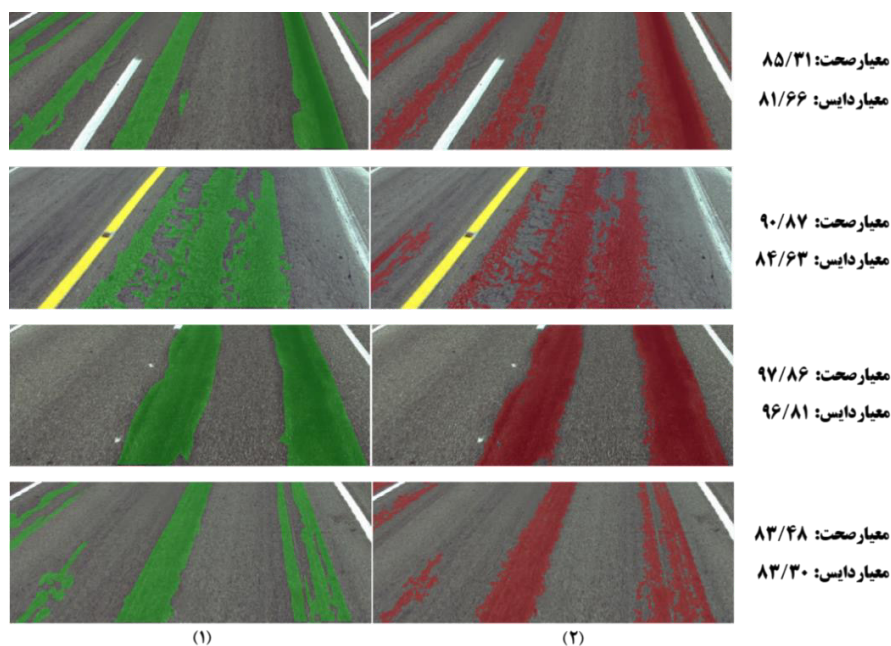
$$Dice(A, B) = \left[ \frac{2 \times |A \cap B|}{|A \cup B|} \right] \quad (11)$$

معیار دایس در بررسی تشابه دو تصویر قطعه بندی شده مطابق رابطه (۱۲) محاسبه می شود.

$$Dice(A, B) = \left[ \frac{2 \times TP}{2 \times TP + FP + FN} \right] \quad (12)$$


که در رابطه (۱۲)، A و B تصاویر خروجی مدل و تصویر مبنا (واقعیت) هستند. TP بیانگر تعداد پیکسل های خروجی مدل که دارای برچسب مشابه

- 1 Label
- 2 Ground Truth
- 3 Dice similarity coefficient
- 4 Recall



شکل ۱۵. نمونه هایی از بررسی عملکرد مدل تفکیک نواحی قیرزده. (۱) نواحی تفکیک شده به صورت دستی، (۲) خروجی مدل

Fig. 15. Examples of the bleeding segmentation model; 1) ground truth image, 2) model output



شکل ۱۶. نمودار جعبه ای مقادیر به دست آمده از ارزیابی مدل تفکیک نواحی قیرزده

Fig. 16. Box plot for the metrics in evaluating bleeding segmentation

سطح پیکسل های تصویر را انجام می دهد. لازم به ذکر است که تعلیم این دسته از مدلها نیازمند تصاویری است که تمامی پیکسل ها به طور دستی برچسب گذاری شده باشند و این موضوع فرآیند آماده سازی داده ها را بسیار زمانبر خواهد کرد. همچنین تعلیم این دسته از مدلها نیازمند سیستم پردازشی به مرتب قوی تری هستند.

لازم به توضیح است که در پژوهش ذکر شده، عملکرد مدل به تنهایی برای خرابی قیرزدگی ارائه نشده است و عملکرد کلی بهترین مدل ارائه شده

فراهم کرده است. لازم به ذکر است که این سامانه قابلیت بررسی موقعیت و هندسه دقیق نواحی خرابی را نداشته و تنها موقعیت کلی خرابی را با کادرهای مستطیلی مشخص می کند.

سامانه دیگری توسط تنگ و همکاران [۱۸] بر اساس چند مدل مبتنی بر ترکیب شبکه های عصبی پیچشی، ماشین بردار پشتیبان، چهارچوب عدم قطعیت و زمینه های تصادفی شرطی گوسی ارائه شده است. این سامانه قابلیت تشخیص و تفکیک نواحی خرابی را دارد و عملیات دسته بندی در

موجب کاهش هزینه های برداشت اطلاعات نسبت به روشهای مبتنی بر فناوری لیزر شده است. ارزیابی که توسط سامانه پیشنهاد شده روی خرابی قیرزدگی انجام می دهد، علاوه بر تشخیص خرابی، تفکیک و قطعه بندی نواحی قیرزده را نیز در بر می گیرد.

به منظور تشخیص خرابی قیرزدگی از مدل‌های یادگیری عمیق استفاده شد. این مدل‌ها از جمله جدیدترین مدل‌های ارائه شده در زمینه یادگیری ماشین هستند که با توجه به قابلیت استخراج خودکار ویژگی‌ها، بسیار مورد توجه قرار گرفته اند. در این پژوهش، عملیات ساخت مدل تشخیص خرابی با بکارگیری روش انتقال یادگیری و بازتعلیم شبکه پیچشی از پیش تعلیم یافته AlexNet صورت گرفت.

به منظور تفکیک نواحی قیرزده در تصاویر دارای قیرزدگی، یک فرآیند پردازش تصویر ارائه شده که از بخش‌های مختلفی نظیر تسهیم هیستوگرام، هموارسازی، تبدیل موجک و عملیات مورفولوژیک تشکیل شده است. بخش اصلی این فرآیند را تبدیل موجک تشکیل داده است که از روشهای قدرتمند و پرکاربرد در زمینه طراحی فیلترهایی برای فرکانس و تصویر به شمار میرود. در این پژوهش یک فیلتر مبتنی بر تبدیل موجک با پارامترهای تنظیم مختلف توسعه داده شد که نواحی دارای خرابی قیرزدگی را در تصویر مشخص می کند.

عملکرد بخش‌های مختلف سامانه پیشنهادی به استفاده از معیارهای مختلفی مورد ارزیابی قرار گرفت. در این راستا، عملکرد مدل ایجاد شده به منظور تشخیص تصاویر دارای خرابی به کمک اطلاعات استخراج شده از ماتریس درهم‌ریختگی انجام شد. با استفاده از این اطلاعات، معیارهای عملکردی مختلفی نظیر accuracy، sensitivity، precision و F-score تعیین شدند که مدل این ایجاد شده با متوسط بالای ۹۸ درصد عملکرد خوبی داشته است.

همچنین عملکرد فرآیند تفکیک و قطعه بندی نواحی قیرزده با بررسی میزان مشابهت با تصاویر واقعی، مورد ارزیابی قرار گرفت. برای این منظور ابتدا بخشی از تصاویر روسازی دارای قیرزدگی به صورت دستی و با دقت بالا برچسب گذاری شدند تا به عنوان مبنای ارزیابی مورد استفاده قرار گیرند. عملکرد مدل ارائه شده با تعیین میزان شباهت تصاویر خروجی مدل با تصاویر مبنای استفاده از معیارهای صحت و ضریب تشابه دایس انجام شد که متوسط ۸۹/۹۴ درصد بر اساس معیار صحت و متوسط ۸۷/۴۷ بر اساس معیار دایس، بیانگر عملکرد قابل قبول این مدل است.

با توجه به اینکه در استانداردهای معتبر نظیر ASTM D6433،

در ارزیابی خرابی‌های مختلف، بر اساس معیارهای متوسط صحت پیکسلی<sup>۱</sup> (MPA)، متوسط نسبت اشتراک به اجتماع تصاویر<sup>۲</sup> (MIoU) و نسبت وزنی اشتراک به اجتماع تصاویر<sup>۳</sup> (FWIoU) به ترتیب ۸۲/۲، ۷۵/۸ و ۹۲/۱ گزارش شده است.

با بررسی و مقایسه نحوه پیاده‌سازی و اجرا، قابلیت‌ها و عملکرد سامانه ارائه شده در این پژوهش نسبت به مطالعات گذشته میتوان دریافت که سامانه ارائه شده در این پژوهش، فرآیند پیاده‌سازی راحتتری داشته و با توان پردازشی معمول امکان تشخیص خرابی قیرزدگی و تفکیک نواحی قیرزده را فراهم کرده است. به طوری که با استفاده از مدل‌های ساده‌تر یادگیری عمیق قادر به تشخیص خرابی قیرزدگی با متوسط دقت بالای ۹۸ درصد است و با بکارگیری روش‌های پردازش تصویر قادر به تفکیک نواحی قیرزده با عملکرد متوسط ۸۹/۹۴ و ۸۷/۴۷ درصدی به ترتیب بر اساس معیار صحت و ضریب تشابه دایس است.

## ۶- جمع بندی و نتیجه گیری

در سال‌های اخیر با توجه به پیشرفت فناوریهای مختلف، تلاشهای گسترده‌ای در جهت بکارگیری این فناوریها در برداشت و ارزیابی اطلاعات خرابیهای روسازی انجام شده است. خرابی قیرزدگی یکی از خرابیهای روسازی آسفالتی است که به طور مستقیم بر مقاومت لغزشی سطح روسازی اثر میگذارد و مانورپذیری وسایل نقلیه را کاهش میدهد که این اثر در شرایط بارانی تا حد زیادی تشدید می شود.

بررسی مطالعات گذشته در زمینه ارائه سامانه‌های کارآمد به منظور برداشت و ارزیابی خودکار خرابی‌ها، نشان می دهد که جامعه تحقیق به خرابی‌هایی نظیر ترک خوردگی، چاله، شیارافتادگی و شن زدگی توجه بیشتری نسبت به سایر خرابی‌ها نظیر قیرزدگی داشته است. همچنین با بررسی تحقیقاتی که تاکنون در زمینه ارزیابی قیرزدگی انجام شده اند، مشخص شد که توجه اکثر محققان بر تشخیص این خرابی بوده است و تحقیقاتی که ارزیابی جامع تری از خرابی قیرزدگی ارائه دهند بسیار محدود بوده است.

در این تحقیق تلاش شد تا سامانه‌ای خودکار با بکارگیری فناوری‌ها و روش‌های جدید به منظور ارزیابی خرابی قیرزدگی ارائه شود. این سامانه مبتنی بر تصاویر دو بعدی برداشت شده از سطح روسازی است و این امر

- 1 Mean Pixel Accuracy
- 2 Mean Intersection over Union
- 3 Frequency weighted Intersection over Union

- [4] C. Koch, K. Georgieva, V. Kasireddy, B. Akinci, P. Fieguth, A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure, *Advanced Engineering Informatics*, 292 (2015) 196-210.
- [5] B. Mataei, H. Zakeri, M. Zahedi, F.M. Nejad, Pavement friction and skid resistance measurement methods: a literature review, *Open J. Civ. Eng.*, 6(04) (2016) 537.
- [6] J.S. Miller, W.Y. Bellinger, Distress identification manual for the long-term pavement performance program, United States. Federal Highway Administration. Office of Infrastructure Research and Development, 2014.
- [7] S. Kodippily, T.F.P. Henning, J.M. Ingham, G. Holleran, Quantifying the effects of chip seal volumetrics on the occurrence of pavement flushing, *Journal of Materials in Civil Engineering*, 26(8) (2014).
- [8] T. Bennert, Determining Binder Flushing Causes in New York State Final Report, (2014).
- [9] H. Khosravi, S.M. Abtahi, B. Koosha, M. Manian, An analytical-empirical investigation of the bleeding mechanism of asphalt mixes, *Construction and Building Materials*, 45(Supplement C) (2013) 138-144.
- [10] W. Lawson, S. Senadheera, Chip seal maintenance: solutions for bleeding and flushed pavement surfaces, *Transportation Research Record: Journal of the Transportation Research Board*, (2108) (2009) 61-68.
- [11] R. Henderson, P. Cenek, N. Jamieson, D. Wilson, The influence of binder rise in reducing tyre-road friction June 2011, (2011).
- [12] M. Arbabpour Bidgoli, A. Golroo, H. Sheikhzadeh Nadjar, A. Ghelmani Rashidabad, M.R. Ganji, Road roughness measurement using a cost-effective sensor-based monitoring system, *Automation in Construction*, 104 (2019) 140-152.
- [13] A. Designation, D6433 Standard Practice for Roads and Parking Lots Pavement Condition Index Surveys, (2007).
- [14] T.B.J. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017).
- [15] Y. LeCun, Y. Bengio, G. Hinton, Deep learning, *Nature*, 521 (2015) 436.
- [16] Goodfellow, Y. Bengio, A. Courville, Y. Bengio, Deep

ارزیابی و ارائه شاخص خرابی قیرزدگی بر اساس دو معیار شدت و گستردگی خرابی انجام می شود، در سامانه ارائه شده با تعیین نسبت نواحی قیرزده به نواحی سالم و یا با محاسبه مساحت نواحی قیرزده، امکان تعیین خودکار میزان گستردگی خرابی فراهم شده است. همچنین تفکیک خودکار نواحی قیرزده، زمینه انجام ارزیابی های بیشتر برای تعیین نوع (محلی یا طولی) و شدت قیرزدگی را در پژوهش های آینده فراهم میکند.

علاوه بر این، می توان از سامانه ارائه شده به منظور ایجاد داده های مورد نیاز برای ساخت انواع دیگری از مدل های مبتنی بر شبکه عصبی پیچشی (YOLO، U-Net و غیره) استفاده نمود. زیرا داده های مورد نیاز برای تعلیم مدل های ذکر شده باید تمامی پیکسل های تصویر دسته بندی و برچسب گذاری شده باشند که این عملیات در حالت عادی به صورت دستی انجام می شود و بسیار وقت گیر خواهد بود.

در مجموع عملکرد سامانه ارائه شده در این پژوهش در ارزیابی خودکار خرابی قیرزدگی روسازی آسفالتی نشان می دهد که این سامانه می تواند به عنوان ابزاری کارآمد در جهت تشخیص و ارزیابی این خرابی مورد استفاده قرار گیرد و عملکرد سامانه های مدیریت روسازی در کشورهای مختلف را بهبود بخشد.

در آخر می توان به این نکته اشاره کرد که در بخش های مختلف سامانه پیشنهاد شده، امکان استفاده از ابزارها و روش های دیگر به منظور بهبود عملکرد سامانه وجود دارد. به عنوان نمونه در بخش تفکیک نواحی قیرزده میتوان از فیلترهای دیگر نظیر فیلترهای فازی استفاده نمود یا در بخش تشخیص خرابی می توان از سایر مدل های از پیش تعلیم یافته استفاده نمود و میزان بهبود یا عدم بهبود سامانه را بررسی کرد.

## منابع

- [1] M.Y. Shahin, Pavement management for airports, roads, and parking lots, 1994.
- [2] 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.
- [3] 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.



- to Threshold Computation Based on the Haar Wavelet Transform, in: 2019 IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC), IEEE, 2019, pp. 306-315.
- [29] P. Luo, X. Qu, X. Qing, J. Gu, CT Image Denoising Using Double Density Dual Tree Complex Wavelet with Modified Thresholding, in: 2018 2nd International Conference on Data Science and Business Analytics (ICDSBA), IEEE, 2018, pp. 287-290.
- [30] A.S. Yaseen, O.N. Pavlova, A.N. Pavlov, A.E. Hramov, Image denoising with the dual-tree complex wavelet transform, in: Saratov Fall Meeting 2015: Third International Symposium on Optics and Biophotonics and Seventh Finnish-Russian Photonics and Laser Symposium (PALS), International Society for Optics and Photonics, 2016.
- [31] P. Prasad, G. Umamadhuri, Biorthogonal Wavelet-based Image Compression, in: Artificial Intelligence and Evolutionary Computations in Engineering Systems, Springer, 2018, pp. 391-404.
- [32] C. Karthikeyan, C. Palanisamy, An Efficient Image Compression Method by Using Optimized Discrete Wavelet Transform and Huffman Encoder, Journal of Computational Theoretical Nanoscience, 15(1) (2018) 289-298.
- [33] A. Bakhshipour, A. Jafari, S.M. Nassiri, D. Zare, Weed segmentation using texture features extracted from wavelet sub-images, Biosystems Engineering, 157 (2017) 1-12.
- [34] A.M. Atto, Y. Berthoumieu, P. Bolon, 2-d wavelet packet spectrum for texture analysis, IEEE Transactions on Image Processing, 22(6) (2013) 2495-2500.
- [35] Y.O. Ouma, M. Hahn, Wavelet-morphology based detection of incipient linear cracks in asphalt pavements from RGB camera imagery and classification using circular Radon transform, Advanced Engineering Informatics, 30(3) (2016) 481-499.
- [36] 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.
- [37] P. Wang, Y. Hu, Y. Dai, M. Tian, Asphalt Pavement Pothole Detection and Segmentation Based on Wavelet learning, MIT press Cambridge, 2016.
- [17] 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.
- [18] Z. Tong, D. Yuan, J. Gao, Z. Wang, Pavement defect detection with fully convolutional network and an uncertainty framework, Computer-Aided Civil and Infrastructure Engineering, (2020).
- [19] Y. Liu, J. Yao, X. Lu, R. Xie, L. Li, DeepCrack: A Deep Hierarchical Feature Learning Architecture for Crack Segmentation, Neurocomputing, (2019).
- [20] W. Ye, W. Jiang, Z. Tong, D. Yuan, J. Xiao, Convolutional neural network for pothole detection in asphalt pavement, Road Materials and Pavement Design, (2019) 1-17.
- [21] L. Song, X. Wang, Faster region convolutional neural network for automated pavement distress detection, Road Materials and Pavement Design, (2019) 1-19.
- [22] P.S. Addison, The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance, CRC press, 2017.
- [23] S. Yang, A. Alhasan, Y. Zhang, H. Ceylan, S. Kim, Pavement curling and warping analysis using wavelet techniques, International Journal of Pavement Engineering, (2020) 1-16.
- [24] Z. Zhang, C. Sun, R. Bridgelall, M. Sun, Road profile reconstruction using connected vehicle responses and wavelet analysis, Journal of Terramechanics, 80 (2018) 21-30.
- [25] M. Khan, F. Qiao, L. Yu, Wavelet analysis to characterize the dependency of vehicular emissions on road roughness, Transportation Research Record, 2641(1) (2017) 111-125
- [26] A. Alhasan, D.J. White, K. De Brabanter, Wavelet filter design for pavement roughness analysis, Computer-Aided Civil and Infrastructure Engineering, 31(12) (2016) 907-920.
- [27] G. Yang, Q.J. Li, Y.J. Zhan, K.C. Wang, C. Wang, Wavelet based macrotexture analysis for pavement friction prediction, KSCE Journal of Civil Engineering, 22(1) (2018) 117-124.
- [28] R.S. Rodrigues, M. Pasin, A. Kozakevicius, V. Monego, Pothole Detection in Asphalt: An Automated Approach

- [47] S.J. Pan, Q. Yang, A survey on transfer learning, IEEE Transactions on knowledge data engineering, 22(10) (2010) 1345-1359.
- [48] Y. Gao, K.M. Mosalam, Deep Transfer Learning for Image-Based Structural Damage Recognition, Computer-Aided Civil and Infrastructure Engineering, 33(9) (2018) 748-768.
- [49] 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.
- [50] 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.
- [51] R.C. Gonzalez, R.E. Woods, Digital image processing, (2007).
- [52] 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.
- [53] F.M. Nejad, H. Zakeri, The Hybrid Method and its Application to Smart Pavement Management, in: X.-S. Yang, A.H. Gandomi, S. Talatahari, A.H. Alavi (Eds.) Metaheuristics in Water, Geotechnical and Transport Engineering, Elsevier, Oxford, 2013, pp. 439-484.
- [54] Y. Gao, K.M. Mosalam, Deep Transfer Learning for Image-Based Structural Damage Recognition, 33(9) (2018) 748-768.
- [55] 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.
- Energy Field, Mathematical Problems in Engineering, 2017 (2017) 13.
- [38] 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.
- [39] 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.
- [40] M. Kardeşahin, M. Saltan, S. Çetin, Determination of seal coat deterioration using image processing methods, Construction and Building Materials, 53(Supplement C) (2014) 273-283.
- [41] G.M. Hadjidemetriou, S.E. Christodoulou, Vision- and Entropy-Based Detection of Distressed Areas for Integrated Pavement Condition Assessment, Journal of Computing in Civil Engineering, 33(3) (2019).
- [42] J. Laurent, J. Hébert, M. Talbot, Using full lane 3D road texture data for the automated detection of sealed cracks, bleeding and ravelling, in: Proceedings of the World Conference on Pavement and Asset Management, Milan, Italy, 2017, pp. 12-16.
- [43] Goodfellow, Y. Bengio, A. Courville, Deep learning, MIT press, 2016.
- [44] M.A. Nielsen, Neural networks and deep learning, Determination press USA, 2015.
- [45] 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.
- [46] 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.

چگونه به این مقاله ارجاع دهیم

S. Ranjbar, F. Moghadas Nejad, H. Zakeri, Asphalt Pavement Bleeding Evaluation using Deep Learning and Wavelet Transform, Amirkabir J. Civil Eng., 53(11) (2022) 4577-4598.

DOI: 10.22060/ceej.2020.18292.6820

