



A Review of the Applications of Machine Learning in Asphalt Pavement Engineering

Mohammad Mehdi Dadaei, Mohammad Saleh Entezari, Rashid Tanzadeh * , Fereidoon Moghadas Nejad 

Department of Civil and Environmental Engineering, Amirkabir University of Technology, Tehran, Iran.

ABSTRACT: Incorporation of deficient design and construction methods in pavement industry exacerbated with unoptimized maintenance plans has led to unprecedented economic and social costs. Therefore, novel technologies and up-to-date science are most sought for today to respond to the challenges at hand. Artificial Intelligence (AI), one of such new technologies, is currently used to develop machines and algorithms that mimic human's brain. Compared to traditional solutions, AI has proven to be cost- and time-effective in enhancing asphalt pavement design, material production, construction, and maintenance management. The present article delves into the applications of Machine Learning (ML), a subset of AI, in pavement engineering through conducting a review on 150 related scientific articles. According to the results, ML has been employed in 7 various research areas of pavement engineering: Design optimization (11% of the studies), asphalt performance prediction (8%), prediction of asphalt mixture characteristics (33%), detection of surface defects (19%), classification of surface defects (2%), prediction of pavement functional indices (21%), and maintenance plans optimization (6%). Also, aiming to outline the trends in the literature and to represent research gaps and achievements, statistical analysis was presented on: the frequency of published articles in each year, algorithms used for model development, and input features used for predicting the performance of asphalt mixture or pavement sections. It is concluded that ML is an indispensable and necessary tool for improving, optimizing, and conducting the critical processes in pavement design, material production, construction, and management. As a consequence, it is necessary that the applications of ML in pavement engineering be further explored through research. This allows for development of edge-of-science technologies such as Digital Twins (DTs) in the industry.

Review History:

Received: Sep. 05, 2024

Revised: Dec. 08, 2025

Accepted: Jan. 18, 2026

Available Online: Feb. 18, 2026

Keywords:

Asphalt Pavement

Artificial Intelligence

Machine Learning

Artificial Neural Network

Optimization

1- Introduction

Pavements are built to provide a smooth and level surface for driving and also to transfer traffic loads to the subgrade. Accurate engineering design is just as paramount as the right measures and practices for construction of pavement. Subsequently, maintaining the asset in appropriate condition with high serviceability is a vital task. With the ongoing development of road networks, there has been a rise in the demand of high-quality asphalt pavements. To overcome the economic and temporal challenges, it is essential to integrate conventional methods with cutting-edge technologies. Since the beginning of the 21st century, AI solutions have been incorporated in pavement industry to make traditional processes more affordable and time-efficient [1].

Several review articles have already been published in this field, surveying ML algorithms adopted for pavement condition evaluation [2], automated distress detection [3], and pavement performance prediction [4, 5]. However, all the

above-mentioned studies are concentrated on the application of ML in pavement maintenance phase, leaving out material production and construction life-cycle stages. There are also other review articles comprehensively investigating the application of ML in pavement engineering life cycle [6, 7], however, the reviewed models were limited to Artificial Neural Networks (ANNs).

The present study looks into pavement engineering literature and thoroughly investigates the ML models developed for materials selection and production, materials characteristics prediction, analyzing materials effects on test results, optimization of pavement maintenance and rehabilitation, and automated defect detection.

2- AI and its Subsets

AI is turning into the most prominent tool for resolving the issues in industry and academia [8]. ML is a subset of AI which empowers machines to gain knowledge from its own

*Corresponding author's email: RashidTanzadeh@yahoo.com



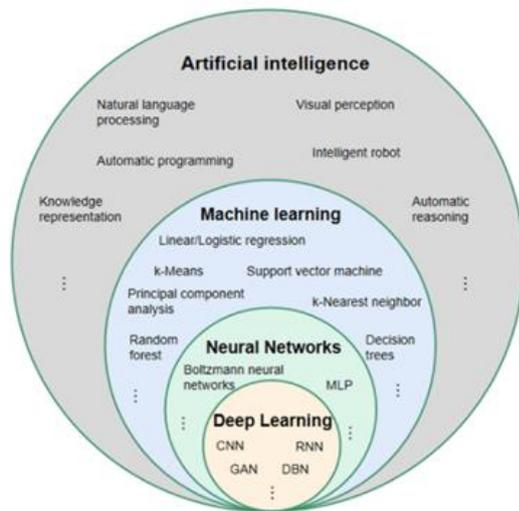


Fig. 1. AI and its subcategories [10].

experience and improve. The principal branch of ML is Deep Learning (DL), composed of Convolutional Neural Networks (CNNs) and more hidden layers than ML algorithms. DL has effectively been used for speech / speaker recognition, object detection, and Natural Language Processing (NLP). Some well-known DL models include Recurrent Neural Networks (RNNs), Generative Adversarial Networks (GANs), and Transformers [9]. AI and its subcategories have been demonstrated in Figure 1 along with exemplary models.

3- Applications of AI in Pavement Engineering

The latest models developed for the prediction of pavement performance indicators have been reviewed in Table 1. It is observed that various models have been used for prediction International Roughness Index (IRI) and Pavement Condition Index (PCI), namely ANN, Random Forest (RF), Support Vector Machine (SVM), Physics-Guided Neural Networks (PG-NN), Gradient Boosting (GB), Light Gradient Boosting Machine (L-GBM), Extreme Gradient Boosting (XGB), K Nearest Neighbor (KNN), and Linear Regression (LR) [11 - 15]. RF has proven to be one of the strongest ML models in predicting IRI and PCI when supplied with enough data and predictor variables, achieving higher than 90% accuracy. Also, the used datasets included Long-Term Pavement Performance (LTPP) and private datasets obtained from data collection using surveyor vehicles.

Using Physics-informed ML has been one of the novel research trends observed in the literature. These models introduce physics rules into the purely data-driven models and thereby resolve shortcomings such as common-sense reasoning, adherence to physical constraints, and limitation in extrapolation beyond training data [16]. PG-NN was trained on LTPP data in order to predict IRI based on a diverse set of input features including climate, traffic, structure, condition,

material, and maintenance data [13]. The model reached an 88.39% accuracy, outperforming the traditional ANN model.

Another research trend spotted in the reviewed articles concerned the “black box nature” of ML models. Explainable AI techniques including calculation of SHAP (SHapely Additive exPlanations) values were implemented to grasp the decision-making process of the model and to recognize the features attended to, in each layer of the model.

Researchers used SHAP analysis to recognize the features that influenced IRI and PCI the most. It was found out that that roughness and pavement age were the most dominant factors in prediction of PCI [15], while aggregate stripping and crack length were the most important features for estimation of IRI [14].

Other subjects covered in the literature included using ML for optimization of mixture and structural design, prediction of asphalt performance and mixture characteristics, detection and classification of surface distresses, prediction of performance indicators, and optimization of the maintenance scenarios. Application of ML in some research areas was barely investigated, including evaluation of environmental phenomena such as albedo and carbonation which are important research topics in pavement Life Cycle Analysis (LCA) [17]. It was also observed that analysis or prediction of the generated energy from pavements was not carried out using ML.

4- Studies in Persian

The articles published in Persian were analyzed separately to better distinguish the approaches taken by researchers with other publications. The efforts of researchers in this section were limited to prediction of Marshall stability using SVM and RF [18], prediction of rutting index for modified asphalt mixture [19], and optimization of the network maintenance plan relying on Fuzzy inference [20].

5- Conclusion

The advances in AI have allowed for accurate analysis and interpretation of data. Nowadays, ML and DL as the subsets of AI are being used to develop systems which are capable of extracting patterns, making decisions, and predicting results without human interference. The article surveyed the applications of ML in asphalt pavement engineering. It was demonstrated that the algorithms have been incorporated in various domains of the industry including design optimization (11% of the studies), prediction of asphalt performance (8%), prediction of asphalt mixture characteristics (33%), detection of surface distresses (19%), classification of surface distresses (2%), prediction of performance indicators (21%), and maintenance plan optimization (6%).

It should be noted that despite the wide application of AI models, there have also been some challenges in implementing them. Dependence on large datasets, lack of generalizability, and the absence of mathematical relationship as the model’s output are some of the faced challenges. In this regard, it is suggested that researchers adopt the following in future studies:

Table 1. Comparison of the latest models developed for predicting pavement performance indicators using AI algorithms

Ref.	Dataset and data volume	ML model	Indicator		Predictor variables						Data splitting share	Model Accuracy
			IRI	PCI	Traffic	Climate	Structure	Material	Condition	Maintenance		
[11]	Data collection at Nablus, Palestine (384 rows)	ANN	-	✓	-	-	-	-	✓	-	70% / 15% / 15%	99.75%
[12]	LTPP (2,708)	RF	✓	-	✓	✓	✓	-	✓	✓	80% / 20%	96%
		SVM										92%
[13]	LTPP (1,287)	PG-NN	✓	-	✓	✓	✓	✓	✓	✓	85% / 15%	88.39%
		ANN										87.89%
[14]	Data collection at Qom, Iran (4,685 rows)	RF									80% / 20%	21.3%
		L-GBM										14.9%
		LR	✓	-	-	-	-	-	✓	-		6.5%
		KNN										15.2%
[15]	LTPP (1,493)	RF	-	✓	✓	✓	✓	✓	✓	-	80% / 20%	91.2%
		XGB										92.3%

- Explainable AI techniques (e.g., SHAP analysis) to recognize how the input features influence the estimated parameter,
- Feature engineering solutions (e.g., recurrent elimination) which avoid entrance of redundant features in the model and thus, improve the model’s accuracy,
- Physics-informed models for which different physical information and information integration methods should be evaluated due to their novelty in the literature.

References

[1] T. Xu, F. Zhu, E.K. Wong, Y. Fang, Dual many-to-one-encoder-based transfer learning for cross-dataset human action recognition, *Image and Vision Computing*, 55(2) (2016) 127–137.

[2] N. Sholevar, A. Golroo, S.R. Esfahani, Machine learning techniques for pavement condition evaluation. *Automation in Construction*, 136 (2021) 104190.

[3] T.B.J. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017) 1374822.

[4] Y. Xu, Z. Zhang, Review of applications of artificial intelligence algorithms in pavement management. *Journal of Transportation Engineering, Part B: Pavements*, 148(3) (2022) 03122001.

[5] S. Cano-Ortiz, P. Pascual-Muñoz, D. Castro-Fresno, Machine learning algorithms for monitoring pavement performance. *Automation in Construction*, 139 (2022) 104309.

[6] M. Abambres, A. Ferreira, Application of ANN in pavement engineering: State-of-Art. *Authorea Preprints*, (2017).

[7] X. Yang, J. Guan, L. Ding, Z. You, V.C. Lee, M.R.M. Hasan, X. Cheng, Research and applications of artificial neural network in pavement engineering: a state-of-

- the-art review, *Journal of Traffic and Transportation Engineering (English Edition)*, 8(6) (2021) 1000-1021.
- [8] K. Kersting, Machine learning and artificial intelligence: two fellow travelers on the quest for intelligent behavior in machines, *Frontiers in big Data*, 1 (2018) 6-10.
- [9] M.H.M., Noor, A.O. Ige, A survey on state-of-the-art deep learning applications and challenges, *Engineering Applications of Artificial Intelligence*, 159 (2025) 111225.
- [10] B.O. Antwi, B.O. Adalakun, A.O. Eziefule. Transforming financial reporting with AI: Enhancing accuracy and timeliness, *International Journal of Advanced Economics*, 6(6) (2024) 205-223.
- [11] A. Issa, H. Samaneh, M. Ghanim, Predicting pavement condition index using artificial neural networks approach, *Ain Shams Engineering Journal*, 13(1) (2022) 101490.
- [12] M. Ghodratabadi, A. Golroo, M.S. Entezari, Machine learning for predicting pavement roughness and optimising maintenance, *Road Materials and Pavement Design*, (2025) 1-20.
- [13] K. Chen, M.E. Torbaghan, N. Thom, A. Faramarzi, Physics-guided neural network for predicting international roughness index on flexible pavements considering accuracy, uncertainty and stability, *Engineering Applications of Artificial Intelligence*, 142 (2025) 109922.
- [14] A. Yazdi, M.H. Dehnad, A Case Study on Predicting Asphalt Pavement Distress Using Advanced Machine Learning Techniques and Road Surface Inspection Data, *Case Studies in Construction Materials*, (2025) e05291.
- [15] M. Shaheen, R.A. Elsayed, H. Ghazoly, W.A. Bekheet, Explainable and economical AI-based approach for PCI assessment, *International Journal of Pavement Engineering*, 26(1) (2025) 2531195.
- [16] Y. Wu, B. Sicard, S.A. Gadsden, Physics-informed machine learning: A comprehensive review on applications in anomaly detection and condition monitoring, *Expert Systems with Applications*, 255 (2024) 124678.
- [17] M.S. Entezari, R. Tanzadeh, F. Moghadas Nejad, Economic, Environmental, and Social Assessment of Concrete Pavement Life Cycle: A Literature Review, *Sharif Journal of Civil Engineering*, 41(1) (2025) 110-129.
- [18] H. Hosseinzadeh, A. Hasani, S. Arman, A.S. Hejazi, Predicting Marshall Asphalt Stability Using Supervised Machine Learning Algorithms, support vector machine and random forest, *Journal of Transportation Research*, 20(3) (2023) 249-262 (in Persian).
- [19] A. Amini, Presenting Predictive Models of Rheological Characteristics of Modified Bitumens Containing SBS and Carbon Nanotubes Using Nonlinear Regression and Neural Network, *Journal of Transportation Research*, 22(3) (2025) 373-384 (in Persian).
- [20] H. Behbahani, N. Nadimi, M. Khaleghi, Introducing a New Method for the Pavements' Maintenance and Rehabilitation Planning, *Amirkabir Journal of Civil Engineering*, 53(7) (2021) 2801-2820 (in Persian).



مروری بر کاربرد یادگیری ماشین در مهندسی روسازی های آسفالتی

محمد مهدی دادایی، محمد صالح انتظاری، رشید تن زاده^{ib}، فریدون مقدس نژاد^{id}

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

تاریخچه داوری:

دریافت: ۱۴۰۳/۰۶/۱۴
بازنگری: ۱۴۰۴/۰۹/۱۷
پذیرش: ۱۴۰۴/۱۰/۲۷
ارائه آنلاین: ۱۴۰۴/۱۱/۲۸

کلمات کلیدی:

روسازی آسفالتی
هوش مصنوعی
یادگیری ماشین
شبکه عصبی مصنوعی
بهینه سازی

خلاصه: نواقص روش های طراحی و اجرای روسازی راهها در کنار برنامه های غیربهینه ترمیم و نگهداری آنها، هزینه های جبران ناپذیر اقتصادی و اجتماعی را به همراه داشته است. در این راستا استفاده از دانش و فن آوری های جدید در مهندسی روسازی اجتناب ناپذیر است. هوش مصنوعی، فن آوری نوینی است که برای توسعه ماشین ها و الگوریتم هایی که همانند هوش انسان عمل می کنند استفاده می شود. هوش مصنوعی، قابلیت های منحصر به فردی در بهبود فرآیندهای طراحی، اجرا، ترمیم و نگهداری روسازی ارائه داده است که نیازمند زمان و هزینه بسیار کمتری نسبت به روش های سنتی هستند. در این تحقیق با بررسی ۱۵۰ مقاله علمی معتبر، کاربرد هوش مصنوعی در دسته یادگیری ماشین در مهندسی روسازی مورد بررسی قرار گرفته است. تحلیل پژوهش های موجود نشان داد الگوریتم های یادگیری ماشین در ۷ حوزه پژوهشی از مهندسی روسازی استفاده شده اند: بهینه سازی طراحی (۱۱٪ از مطالعات)، پیش بینی عملکرد قیر (۸٪)، پیش بینی خصوصیات مخلوط آسفالتی (۳۳٪)، تشخیص خرابی های سطح (۱۹٪)، طبقه بندی خرابی های سطح (۲٪)، پیش بینی شاخص های عملکردی رویه (۲۱٪) و بهینه سازی برنامه عملیات ترمیم و نگهداری (۶٪). همچنین با هدف شناسایی روندهای موجود در ادبیات موضوع و نیز احصاء دستاوردهای محققین، تحلیل های آماری از فراوانی پژوهش های منتشر شده در سال های مختلف، الگوریتم های استفاده شده در مدلسازی و متغیرهای وارد شده جهت پیش بینی عملکرد مخلوط یا روسازی آسفالتی ارائه گردید. این مطالعه نشان داد یادگیری ماشین ابزاری ضروری و جدایی ناپذیر جهت اجرا، بهبود و بهینه سازی فرآیندهای مختلف طراحی، ساخت، نگهداری و مدیریت روسازی است. لذا گسترش تحلیل های مبتنی بر هوش مصنوعی و ارزیابی کاربردهای آن در حوزه مهندسی روسازی ضرورت داشته و پیش نیاز شکل گرفتن فن آوری های لب دانشی از جمله دوقلوهای دیجیتال روسازی است.

۱- مقدمه و تاریخچه تحقیقات

ایده ابتدایی هوش مصنوعی^۱ از زمان اختراع کامپیوتر آغاز شده است. اما از اواسط دهه ۱۹۵۰ به یک دانش چند رشته ای تبدیل شد. جان مک کارتی^۲ پدر دانش هوش مصنوعی، در سال ۱۹۵۶ آن را "علم ساخت ماشین های هوشمند" معرفی کرد. ظهور تکنیک های محاسبات نرم به ویژه آشنایی با شبکه عصبی مصنوعی در میانه دهه ۱۹۸۰ سبب پیشرفت بزرگی در دانش هوش مصنوعی شد و آن را به ابزاری برای حل مسائل بشر تبدیل کرد (۱) و [۲] هوش مصنوعی در حل مسائل مختلف، به ویژگی های انسانی قابل انجام توسط ماشین ها نیازمند است. این ویژگی ها شامل ادراک، یادگیری، حل مسئله و برنامه ریزی است (۳ و ۴). هوش مصنوعی قادر است وظایف پیچیده

و متداول انسان مانند یادگیری، طبقه بندی، تشخیص و تصمیم گیری را بدون از دست دادن زمانی برای کسب تجربه و بدون هیچ گونه خستگی انجام دهد (۵ و ۶). رشته های فرعی هوش مصنوعی، پردازش زبان طبیعی^۳، پردازش تصویر و استخراج داده هستند که این رشته ها با استفاده از الگوریتم های مختلفی مانند یادگیری عمیق^۴ در زمینه های مختلف از جمله مهندسی وارد شده اند (۷ و ۸).

از ابتدای قرن ۲۱م به طور ویژه ای از دانش هوش مصنوعی در مهندسی روسازی استفاده شده است. توسعه راه ها و رشد تقاضا برای ساخت روسازی های آسفالتی با کیفیت در کنار محدودیت های اقتصادی و زمانی، تلفیق روش های سنتی و تکنولوژی های جدید را اجتناب ناپذیر ساخته است (۸ و ۹). روش های منطبق بر هوش مصنوعی، بر خلاف روش های مدلسازی قدیمی، نیازمند

- 1 Artificial Intelligence (AI)
- 2 John MacCarthy

* نویسنده عهده دار مکاتبات: Rashidtanzadeh@yahoo.com



با توجه به این که روسازی‌ها با گذر زمان از احداثشان دچار افت شدید عملکردی می‌شوند، پایش و نظارت پیوسته بر روسازی‌ها زمینه ترمیم و نگهداری مناسب آن‌ها را فراهم ساخته است. بنابراین سرمایه‌گذاری مستمر برای بهبود سطح خدمت یا بازسازی روسازی‌های موجود تاثیر قابل توجهی بر کیفیت راه‌ها داشته است. کمبود منابع مالی در کنار پیچیدگی‌های اجرایی روش‌های متداول ارزیابی عملکرد روسازی‌ها، فرآیند ترمیم‌ونگهداری را به امری پیچیده تبدیل کرده‌است. در این راستا، هوش مصنوعی با پیش‌بینی شاخص‌های عملکردی روسازی، بهینه‌سازی برنامه ترمیم‌ونگهداری و نیز تصمیم‌گیری به‌وسیله مدل‌های هوشمند، مدیریت شبکه گسترده روسازی را تسهیل نموده‌است [۱۷-۱۸].

مطالعات متعددی به مرور کاربردهای الگوریتم‌های هوش مصنوعی در حوزه راه‌ترابری و مهندسی روسازی پرداخته‌اند. شعله‌ور، گل‌رو و همکاران در سال ۲۰۲۲، کاربردهای الگوریتم‌های یادگیری ماشین را در زمینه پایش وضعیت روسازی مورد بررسی قرار دادند [۱۹]. همچنین، کون^۲ و گل‌رو در سال ۲۰۱۷ در پژوهشی با موضوع مشابه، به مرور پیشینه تحقیق در زمینه شناسایی خودکار خرابی‌های روسازی پرداختند [۲۰]. این پژوهش‌ها، علیرغم ارائه تصویری کامل از پیشرفت‌های حاصل‌شده در بهره‌گیری از مدل‌های هوش مصنوعی در پایش سلامت راه‌ها، کاربردهای هوش مصنوعی در زمینه بهینه‌سازی طرح اختلاط آسفالت، بهینه‌سازی هزینه‌های احداث روسازی و پیش‌بینی خواص قیر و مخلوط آسفالتی را مورد بررسی قرار نداده‌اند.

برخی محققین دیگر از جمله ژو و ژنگ^۳ در سال ۲۰۲۲ [۲۱] و کانو اورتیز^۴ و همکاران در سال ۲۰۲۲ [۲۲] به مرور روش‌های توسعه مدل‌های عملکردی روسازی با استفاده از الگوریتم‌های هوش مصنوعی پرداخته‌اند. همچنین کنگ^۵ و همکاران در سال ۲۰۲۴ [۲۳] به بررسی کاربردهای هوش مصنوعی در توسعه مدل‌های رفتار روسازی از طریق پیش‌بینی شاخص‌های عملکردی پرداختند. این مطالعات علیرغم مرور دقیق کاربردهای هوش مصنوعی در سیستم‌های مدیریت روسازی، کاربردهای هوش مصنوعی در سایر زمینه‌های مهندسی راه را پوشش نداده‌اند. امبرز و فررا^۶ در سال ۲۰۲۳ [۲۴] و ینگ^۷ و همکاران در سال ۲۰۲۱ [۲۵] به بررسی کاربردهای شبکه‌های عصبی مصنوعی در مهندسی روسازی پرداختند که منجر به

محاسبات گسترده برای اطلاعات ورودی نیستند. زیرا عملکرد این روش‌ها بر مبنای یادگیری داده‌ها و شناخت الگوی ورودی‌ها و خروجی‌های پدیده‌ها است [۶ و ۱۰]. هوش مصنوعی و یادگیری ماشین به خاطر موفقیت‌های اخیر خود به ویژه در بخش یادگیری عمیق، در حال تبدیل‌شدن به اصلی‌ترین ابزار حل مسائل پژوهشی و صنعتی هستند [۱۱]. رشد سریع جهان و افزایش حجم داده‌های جمع‌آوری‌شده، سبب پیشرفت علم داده و ایجاد زمینه‌های جدید برای یادگیری ماشین، به‌ویژه یادگیری عمیق شده‌است [۱۲]. در این مقاله به بیان نقش هوش مصنوعی در مهندسی روسازی به تفکیک مراحل طراحی، ساخت، بهره‌برداری و نهایتاً مدیریت ترمیم‌ونگهداری آن پرداخته شده‌است.

هدف از ایجاد روسازی، ایجاد سطحی صاف و هموار با توان انتقال بارهای ناشی از ترافیک به خاک بستر است. روسازی علاوه بر مقاومت در برابر بارهای واردشده باید در مقابل شرایط مختلف آب‌وهوایی مقاوم باشد. شناخت کافی از عملکرد اجزای مخلوط آسفالتی و طراحی مناسب، ضروری است. پیش‌بینی نتایج تست‌های متداول عملکرد قیر و مخلوط آسفالتی و نیز پیش‌بینی خرابی‌های روسازی‌های آسفالتی، افزایش دقت مطالعات روسازی را به دنبال داشته است. از این رو محققین به استفاده از هوش مصنوعی در طراحی روسازی‌ها پرداخته‌اند.

اما ساخت و اجرای صحیح روسازی‌های آسفالتی نیز به اندازه طراحی آن‌ها دارای اهمیت است. تخمین میزان انرژی مصرف‌شده در زمان تولید مخلوط آسفالتی، دمای مصالح سنگی، مقدار تراکم روسازی و نیز هزینه‌های احداث آن از مواردی هستند که با وجود الگوریتم‌های هوش مصنوعی امکان‌پذیر شده‌است. پس از مرحله ساخت و اجرا، به منظور حفظ روسازی‌های آسفالتی در شرایط مطلوب خدمت‌رسانی، ارزیابی پیوسته آن‌ها ضروری است. زیرا تشخیص خرابی‌ها در مراحل اولیه، امکان ترمیم‌های پیشگیرانه را فراهم ساخته و به افزایش طول عمر قطعات روسازی و کاهش هزینه ترمیم‌ونگهداری آن‌ها منجر شده‌است. ارزیابی شامل نظارت بر سازه روسازی و نیز شناسایی، طبقه‌بندی و ارزیابی شدت خرابی‌ها است. در سال‌های اخیر با استفاده از هوش مصنوعی به‌ویژه شبکه‌های عصبی پیچشی^۱ که نوعی طبقه‌بندی‌کننده غیرخطی محسوب می‌شوند، گام مهمی در سیستم‌های نظارت بر روسازی برداشته شده‌است. این روش مقرون‌به‌صرفه جایگزین روش‌های سنتی ارزیابی روسازی شده‌است که بسیار زمان‌بر و پرهزینه بودند [۱۳-۱۶].

2. Coenen
3. Xu & Zhang
4. Cano-Ortiz
5. Kang
6. Ambres & Ferreira
7. Yang

1. Convolutional Neural Network (CNN)

شناسایی معماری‌های رایج در مدلسازی و نیز چالش‌های موجود گردید. این پژوهش‌ها با اینکه اطلاعات دقیقی از مدلسازی با شبکه‌های عصبی را ارائه نمودند، اما بررسی سایر مدل‌های یادگیری ماشین یا یادگیری عمیق را از قلم انداخته‌اند. از مطالعات مروری دیگری که تنها بر یک مرحله از چرخه عمر روسازی تمرکز داشته‌اند می‌توان به مطالعه ونگ^۱ و همکاران در سال ۲۰۲۴ [۲۶] اشاره نمود که توسعه‌های اخیر در زمینه تراکم هوشمند آسفالت را مورد بررسی قرار دادند.

مطالعه حاضر انواع مدل‌های مختلف موجود در حوزه‌های یادگیری ماشین را در حیطه‌های مختلف مهندسی روسازی از جمله انتخاب مواد و ایجاد مصالح، پیش‌بینی خواص مصالح، تحلیل تاثیر مواد بر نتایج آزمایش‌ها، بهینه‌سازی عملیات نگهداری و تعمیرات و شناسایی خودکار خرابی‌ها را تحلیل نموده‌است. همچنین تلاش شده‌است تا ضمن ارائه آماره‌های توصیفی و فراوانی‌های الگوریتم‌ها، متغیرها و موضوعات انتخاب‌شده، دستاوردها و نواقص تحقیقاتی موجود نیز شناسایی شوند. بر این اساس پیشنهادهایی جهت به‌کارگیری در پژوهش‌های آینده نیز مطرح شده‌است.

ساختار ادامه این مقاله بدین شرح است: بخش دوم دربرگیرنده معرفی هوش مصنوعی و الگوریتم‌های یادگیری ماشین است. بخش سوم، خلاصه مقالات منتشرشده با محوریت استفاده از هوش مصنوعی در زمینه ساخت روسازی را ارائه نموده‌است. خلاصه پژوهش‌های منتشرشده با موضوع کاربرد هوش مصنوعی در بررسی و نظارت روسازی و همچنین تحلیل و مقایسه آن‌ها در بخش سوم ارائه شده‌است. به‌منظور درک تفاوت رویکرد پژوهشگران ایرانی و حجم کار آن‌ها، پژوهش‌های منتشرشده به زبان فارسی به‌صورت مجزا در بخش چهارم ارائه و تحلیل شده‌است. در نهایت، یافته‌های پژوهش، در بخش پایانی مقاله یعنی بخش پنجم جمع‌بندی شده‌است.

۲- هوش مصنوعی

هدف اصلی در دنیای مدرن امروز، انجام سریع و دقیق کارها است و روش‌های متداول و سنتی، زمان‌بر و ناکارآمد هستند. بنابراین ماشین‌ها که فاقد محدودیت‌های انسانی مانند کندی، فراموشی، سرعت کم و نامنظمی هستند می‌توانند انسان‌ها را در انجام وظایف متداول و مواجهه با چالش‌های خود یاری نمایند [۲۷]. دانش هوش مصنوعی در سال ۱۹۴۳ با اختراع رایانه‌های الکترونیکی مطرح شد. اما با کاهش سرعت پیشرفت این دانش، انتظارات محققین برآورده نشد و با کاهش سرمایه‌گذاری‌ها، هوش

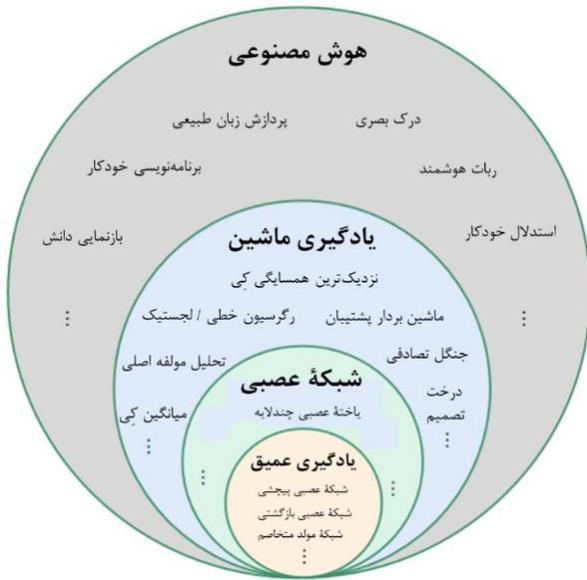
1. Wang

۲-۱- یادگیری ماشین

مصنوعی موقتا به پایان خود رسید [۲۸]. اما مجدداً با گذشت زمان، هوش مصنوعی در دهه‌های اخیر به منظور افزایش بهره‌وری، تسریع خودکارسازی و کاهش هزینه‌ها مورد توجه قرار گرفت [۲۷]. هوش مصنوعی دانش تولید ماشین‌های هوشمند با توانایی تقلید از رفتارهای انسانی مانند تجزیه و تحلیل، طبقه‌بندی و پیش‌بینی است [۲۹]. ماشین‌ها به دلیل عدم توانایی مواجهه با موقعیت‌های جدید، همواره به سطحی از تجربه انسانی نیازمند بوده و آن را با یادگیری از مجموعه داده‌های پیشین بدست می‌آورند [۳۰].

یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که به‌طور خودکار ماشین یا سیستم را قادر می‌سازد تا از تجربه خود یاد بگیرد و پیشرفت کند [۳۱ و ۳۲]. اصلی‌ترین شاخه یادگیری ماشین، یادگیری عمیق است که از شبکه‌های عصبی پیچشی و لایه‌های پنهان بیشتری بهره می‌برد و امکان اجرای تحلیل‌های پیشرفته از جمله تحلیل داده‌های سری زمانی، تصاویر و پایگاه‌های داده متنی را فراهم می‌سازد. شبکه‌های عصبی پیچشی مبنای الگوریتم‌های یادگیری عمیق هستند که مشکل از چندین لایه پنهان بوده و در حوزه‌های مختلفی از جمله شناسایی اشیا، تشخیص گفتار و پردازش زبان طبیعی عملکرد موفقی داشته‌اند. از دیگر الگوریتم‌های یادگیری عمیق می‌توان به شبکه‌های عصبی بازگشتی، شبکه مولد متخاصم و مدل‌ها^۲ اشاره نمود [۳۳ و ۳۴]. در ادامه، تاریخچه و انواع این دو روش آموزش ماشین شرح داده شده‌است.

2. Transformers



شکل ۱. هوش مصنوعی و زیرمجموعه‌های آن [۴۵].

Fig. 1. AI and its subcategories [45].

۳- کاربردهای هوش مصنوعی در روسازی راه

در این بخش به مرور پژوهش‌های مهندسی روسازی با محوریت استفاده از الگوریتم‌های یادگیری ماشین پرداخته شده‌است. شایان ذکر است این پژوهش‌ها در چند موضوع کلی قابل طبقه‌بندی هستند:

- ۱- طراحی روسازی: بهینه‌سازی طرح براساس معیارهای مختلف
- ۲- خصوصیات مواد و عملکرد مخلوط: پیش‌بینی عملکرد قیر و پیش‌بینی خواص مخلوط،
- ۳- ارزیابی وضعیت روسازی: تشخیص وجود خرابی و طبقه‌بندی نوع آن،
- ۴- مدیریت روسازی: پیش‌بینی مقادیر شاخص‌های عملکردی رویه و برنامه‌ریزی عملیات نگهداری.

۳-۱- طراحی روسازی

در یک دهه اخیر، ارائه طرح سازه‌ای روسازی به منظور افزایش دقت و بهینه‌سازی هزینه‌های طراحی با استفاده از هوش مصنوعی مورد توجه محققین بوده‌است. در این راستا، هی^{۱۰} و همکاران در سال ۲۰۱۴ به پیش‌بینی هزینه ساخت یک روسازی آزادراهی با استفاده از شبکه عصبی

یادگیری ماشین عمدتاً شامل چهار بخش جمع‌آوری داده‌ها، نمایش داده‌ها، انتخاب الگوریتم مناسب و بهینه‌سازی مدل است [۳۸]. روش‌های یادگیری ماشین بر اساس نوع داده‌های ورودی غالباً به سه دسته یادگیری نظارت‌شده (مانند رگرسیون و طبقه‌بندی^۱)، یادگیری بدون نظارت (مانند خوشه‌بندی) و یادگیری تقویتی^۲ تقسیم‌بندی می‌شوند. در حال حاضر رایج‌ترین الگوریتم‌های یادگیری ماشین، ماشین بردار پشتیبان^۳، نزدیک‌ترین همسایگی کی^۴، رگرسیون لجستیک^۵، درخت تصمیم‌گیری^۶ و شبکه‌های عصبی مصنوعی هستند [۲۷]. در ادامه شبکه‌های عصبی مصنوعی به اختصار شرح داده می‌شوند.

۲-۲- شبکه‌های عصبی مصنوعی

پرکاربردترین زیر مجموعه روش‌های یادگیری ماشین، شبکه‌های عصبی مصنوعی^۷ است که برخلاف روش‌های متداول آماری می‌توانند مسائل پیچیده را با دقت بالاتر مدل‌سازی نمایند [۳۹]. اولین بار شبکه‌های عصبی در سال ۱۹۴۰ معرفی شدند [۴۰]. اما ویدرو و هاف^۸ در دانشگاه استنفورد در سال ۱۹۶۰ برای اولین بار از یک شبکه عصبی مصنوعی در حل مسائل واقعی استفاده نمودند. آشنایی با این شبکه‌ها در طول سال‌های ۱۹۷۰ تا ۱۹۸۰ زمینه استفاده بیشتر از هوش مصنوعی در مهندسی عمران را فراهم کرد [۴۱]. شبکه عصبی مصنوعی به مجموعه‌ای از یاخته‌های عصبی^۹ (یا نورون‌ها) می‌گویند که در یک معماری ویژه و برای حل مسئله‌ای خاص به هم متصل شده‌اند و هر کدام محاسبات ساده‌ای انجام می‌دهند. هر یاخته عصبی داده ورودی را دریافت نموده و پس از انجام محاسبات، خروجی را به یاخته‌های متصل به خود می‌دهد. شبکه‌های عصبی مصنوعی از سه بخش لایه ورودی، لایه‌های پنهان و لایه خروجی در راستای پردازش داده‌های تجربی و کشف قانون نهفته در ساختار داده‌ها تشکیل شده‌است [۴۲]. این شبکه‌ها در طبقه‌بندی، خوشه‌بندی، شناسایی الگو و پیش‌بینی‌ها در علوم مختلف عملکرد مناسبی نشان داده‌اند [۴۳ و ۴۴]. در شکل ۱، هوش مصنوعی و زیرمجموعه‌های آن مشخص شده‌است.

1. Classification
2. Reinforcement Learning
3. Support Vector Machine (SVM)
4. K Nearest Neighbour (KNN)
5. Logistic Regression
6. Decision Tree
7. Artificial Neural Network (ANN)
8. Widrow & Hoff
9. Neuron

پیش‌بینی سختی خمشی و نیز شبکه عصبی پیش‌رونده^۵ در راستای پیش‌بینی عمق شیارشدگی مناسب بوده‌است [۴۸].

به منظور طراحی روسازی با استفاده از روش‌های مکانیکی-تجربی^۶ به اطلاعات طبقه‌بندی شده خودروها نیاز است. طاحائی و همکاران در سال ۲۰۲۱، به طبقه‌بندی گروه‌های مختلف کامیون از طریق داده‌های توزین در حرکت کامیون‌ها پرداختند. داده‌های این آزمایش از ایستگاه‌های توزین در حال حرکت^۷ کشور گرجستان حاصل شده‌بود. ۱۷ دسته ترافیک کامیونی تعریف شد و با کمک روش‌های نظارت‌شده و بدون نظارت یادگیری ماشین، داده‌ها به طبقات مختلف تقسیم‌بندی شدند. هدف از این تقسیم‌بندی طراحی دقیق‌تر روسازی بود. همچنین الگوریتم میانگین‌گیری^۸ به منظور خوشه‌بندی داده‌های ترافیکی استفاده شد [۴۹].

توحیدی و همکاران در سال ۲۰۲۲ در مطالعه‌ای به کاربرد الگوریتم‌های هوشمند جست‌وجو با هدف طراحی ضخامت روسازی راه‌ها با کمترین هزینه پرداختند. طراحی دستی روسازی فرآیندی آزمون و خطایی، زمان‌بر و خسته‌کننده است. در نتیجه، رسیدن به طرح‌های بهینه نیازمند صرف مدت زمان زیادی است. محققین دو الگوریتم ژنتیک و نیز بهینه‌سازی ازدحام ذرات^۹ را مورد مقایسه قرار دادند. مطابق نتایج، الگوریتم ژنتیک عملکرد بهتری داشته اما هر دو الگوریتم عملکرد مطلوبی داشتند: الگوریتم ژنتیک ۹-۲۶٪ و الگوریتم بهینه‌سازی ازدحام ذرات، ۵-۲۵٪ کاهش هزینه نهایی را به دنبال داشته است. مبنای طراحی در این مطالعه روش نشریه ۲۳۴ آیین‌نامه طراحی روسازی ایران است. الگوریتم ژنتیک، رایج‌ترین الگوریتم مهندسی در بهینه‌سازی مسائل مهندسی است. در این مطالعه نرم‌افزاری توسعه داده شد تا دو الگوریتم بهینه‌سازی را با در نظر گرفتن عوامل مختلف اجرا نماید: روش طراحی آستو ۱۹۹۳، متغیرهای موثر بر طراحی روسازی (مانند عدد سازه‌ای، انحراف معیار استاندارد، مقدار کاهش سطح خدمت روسازی)، موقعیت مکانی مناطق مختلف خوزستان، قیمت مصالح و ضخامت لایه‌های مختلف روسازی [۵۰].

۳-۲- پیش‌بینی عملکرد قیر

یکی از چالش‌های پیش‌روی مهندسیین روسازی، تعیین مقدار افزودنی لازم در راستای بهبود عملکرد قیر مخلوط‌های آسفالتی است. شیائو^{۱۰} و

پرداختند. مطالعه در شهر هنان چین انجام شد و از ۸۸ قطعه آزادراه ساخته‌شده در بین سال‌های ۱۹۹۴ تا ۲۰۰۰، ۸۱ مورد برای آموزش شبکه عصبی به‌طور تصادفی انتخاب شد. در این شبکه از فرآیند پس‌انتشار^۱ استفاده شد که از یک لایه پنهان محاسباتی بهره می‌برد. در این مطالعه بیش از ۹ پارامتر ورودی وجود داشت و پارامترهایی همچون توپوگرافی، اقلیم، زمین‌شناسی، تغییر ارتفاع و هزینه‌های نیروی کار و قیمت تجهیزات و مصالح در نظر گرفته شده‌است [۴۶].

تی‌دمیر^۲ در سال ۲۰۱۴ به ارزیابی مجدد معادله اصلی طراحی روسازی‌های انعطاف‌پذیر آستو ۱۹۹۳ با روش شبکه عصبی مصنوعی پرداخت. این معادله تعداد بار تک‌محور هم‌ارز که قابلیت عبور از روسازی آسفالتی با مشخصات معین را دارد، محاسبه می‌نماید. اهمیت این مطالعه از این جهت بود که فرمول آستو معمولاً این مقدار را بیش از حد واقعی پیش‌بینی کرده‌است. در این مطالعه از پایگاه داده عملکرد بلندمدت روسازی^۳ استفاده شده‌است. از کل ۲۴۴ مقطع روسازی، ۲۳۴ مقطع در مدلسازی به‌کار گرفته شده‌است که علت این کاهش، عدم وجود اطلاعات بارش برای ۱۰ مقطع روسازی بوده‌است. یک لایه پنهان، شش متغیر ورودی و دو متغیر خروجی مرتبط با ترافیک معادل هم‌ارز، مدل شبکه عصبی را تشکیل داده‌است. ضریب همبستگی بین ترافیک واقعی عبوری و ترافیک پیش‌بینی شده با مدل شبکه عصبی برابر ۹۹/۹٪ بوده که بیانگر دقت بالای این مدل است [۴۷].

با توجه به اینکه روش‌های سنتی طراحی روسازی آسفالتی امکان طراحی روسازی مقاوم در برابر خرابی‌های مختلف را نداشته‌است، در پژوهش‌های اخیر از مواد متنوع و روش‌های نوین برای طراحی استفاده شده‌است. قدیر و همکاران در سال ۲۰۲۰، مدل‌های طراحی عملکردی آسفالت مقاوم‌شده با ژئوسنتتیک‌ها را مورد مطالعه قرار دادند. نتایج نشان داد که افزودن یک لایه ژئوسنتتیک، بیش از ۱۵۰٪ سختی خمشی روسازی را افزایش داده‌است. داده‌های مدلسازی از نمونه‌های آزمایشگاهی تست‌های مارشال و تست عمق شیارشدگی حاصل شده‌است. نمونه‌ها در سه دانه‌بندی میانی، درشت‌دانه و ریزدانه ساخته و مورد آزمایش قرار گرفته‌است. در کنترل سختی خمشی تا ۱۰،۰۰۰ سیکل بارگذاری انجام شده‌است. دانه‌بندی میانی تقویت‌شده، بیشترین استحکام را در بین تمام نمونه‌ها نشان داده‌است. مطابق نتایج برای مجموعه داده‌های کوچک، شبکه‌های عصبی با توابع پایه شعاعی^۴ در راستای

5. Feedforward neural network
6. Mechanistic-Emperical Pavement Design Guide (MEPDG)
7. Weigh-in-Motion (WIM)
8. Particle Swarm Optimization (PSO)
9. Xiao

1. Back-propagation
2. Tigidemir
3. Long-term Pavement Performance (LTPP)
4. Radial Basis Function Networks

نمونه‌ها با استفاده از میکروسکوپ نیروی اتمی اندازه‌گیری شده‌اند. ضریب برازش داده‌های حاصل از مدل ساخته‌شده نسبت به داده‌های واقعی بیش از ۹۰٪ بوده است [۵۳].

ریاض^۸ و همکاران در سال ۲۰۲۴ عملکرد دماهای بالا و متوسط قیر اصلاح‌شده با استایرن-بوتادین-استایرن، پلیمر لیگنین^۹ و خرده لاستیک بازیافتی^{۱۰} را از طریق اجرای الگوریتم‌های یادگیری ماشین و همچنین آزمایش‌های آزمایشگاهی بهینه‌سازی نمودند. در این راستا ابتدا نمونه‌های قیر اصلاح‌شده با افزودنی‌های بیان‌شده (به میزان ۳٪، ۶٪ و ۹٪) از طریق قرارگیری در دستگاه آون دوار لایه نازک^{۱۱} و دستگاه پیرشدگی تحت فشار^{۱۲} به حالت پیرشده منتقل شدند. سپس آزمایش‌های مختلفی با دستگاه‌های رئومتر برشی دینامیکی، ویسکومتر چرخشی^{۱۳}، طیف‌سنج تبدیل فوریه^{۱۴} فرسوخ^{۱۵} و بمب گرماسنج^{۱۶} بر حدود ۵۱ نمونه پیرشده اجرا شد تا خصوصیات پایه آن‌ها ارزیابی شوند. با اضافه‌شدن هر یک از ۳ ماده اصلاح‌کننده، مقاومت قیر نسبت به شیارشدگی افزایش یافت. همچنین با اضافه‌شدن استایرن-بوتادین-استایرن و خرده لاستیک بازیافتی با مقادیر بالا، معیار ترک خستگی سوپرپیو^{۱۷} کاهش یافت که نشان از آسیب‌پذیری کمتر قیر اصلاح‌شده در برابر ترک خستگی بود. در نهایت داده‌های بدست‌آمده از آزمایش‌ها برای توسعه مدل‌های یادگیری ماشین استفاده گردید که متغیرهای پیش‌بینی‌شده عبارت بودند از گرمای سوختن^{۱۷} و دمای شکست^{۱۸}. متغیرهای پیش‌بینی‌کننده دمای شکست عبارت بودند از: قیر پایه، نوع و درصد افزودنی، شرایط پیرشدگی و مقدار نرمال‌شده گرمای سوختن. همچنین متغیرهای پیش‌بینی‌کننده گرمای سوختن شامل قیر پایه، نوع و درصد افزودنی، شرایط پیرشدگی، دمای شکست و همچنین مقادیر زاویه فاز و مدول برشی در دمای شکست بود. از میان مدل‌های ساخته‌شده، رگرسیون لاسو^{۱۹} و رگرسیون تقویت‌گرایان^{۲۰} به ترتیب بهترین عملکرد را در پیش‌بینی گرمای سوختن و دمای شکست داشتند [۵۴].

8. Riyadh
9. Lignin
10. Ground Tire Rubber (GTR)
11. Rolling Thin Film Oven (RTFO)
12. Pressure Aging Vessel (PAV)
13. Rotating Viscometer (RV)
14. Fourier Transform Infrared (FTIR) Spectroscopy
15. Bomb Calorimeter
16. Superpave (Superior Performing Asphalt Pavement)
17. Combustion Heat
18. Failure temperature
19. Lasso Regression
20. Gradient Boosting Regression

همکاران در سال ۲۰۱۱ به پیش‌بینی مقدار ویسکوزیته قیرهای اصلاح‌شده با پودر لاستیک با استفاده از روش شبکه عصبی مصنوعی پرداختند. متغیرهای ورودی این مدل، منبع تهیه قیر، سایز قطعات لاستیک، زمان اختلاط و مقدار لاستیک بود. نتایج نشان داد که طول زمان اختلاط نسبت به سایر پارامترهای ورودی، اهمیت چندانی نداشته‌است ولی حساسیت ویسکوزیته نسبت به منبع قیر و مقدار لاستیک و سایز قطعات لاستیکی زیاد بوده‌است. دو نوع قیر از ونزوئلا و یک نوع از آمریکا مورد بررسی قرار گرفته‌است. یک لایه پنهان نیز در شبکه عصبی توسعه داده‌شده، استفاده شده‌است. دقت مدل ارائه‌شده برای قیرهای لاستیکی مختلف از ۴۶٪ تا ۷۶٪ بوده‌است [۵۱].

حسینی و همکاران در سال ۲۰۲۱، با هدف تعیین مقدار بهینه اصلاح‌کننده‌ها در طرح مخلوط آسفالتی از روش‌های یادگیری ماشین بهینه‌شده استفاده کردند. در این راستا رفتار ویسکوالاستیک قیرهای اصلاح‌شده پیش‌بینی شد. پیش‌بینی تاثیر اصلاح‌کننده‌های مختلف بر قیر با توجه به پارامترهای مدول برشی قیر (G*) و زاویه فاز (δ) حاصل از تست رئومتر برشی دینامیکی^۱ انجام شد. اصلاح‌کننده‌های مورد بررسی عبارت است از پودر لاستیک، استایرن-بوتادین-استایرن^۲ و پلی فسفریک اسید. روش‌های شبکه‌های عصبی مصنوعی، رگرسیون بردار پشتیبانی خطی^۳، رگرسیون درخت تصمیم‌گیری، رگرسیون مرحله‌ای گاوسی^۴ و رگرسیون عملکردی بر داده‌ها توسعه داده شد. با مقایسه خروجی‌های مدل مورد مطالعه از نظر عملکرد از جمله همبستگی ضرایب، انحراف جذر میانگین مربعات^۵ و خطای نسبی، مشخص شد که روش رگرسیون عملکردی بیش‌ترین کارایی را در پیش‌بینی داشته‌است. لازم به ذکر است داده‌های مدلسازی حاصل آزمایش در دماهای -۲۲، -۱۶، -۱۰، ۰، ۱۰، ۱۶ و ۲۲ درجه سانتی‌گراد بوده‌است [۵۲].

آریفوزمان^۶ و همکاران در سال ۲۰۲۱، چسبندگی قیر را مورد بررسی قرار دادند. همواره عوامل متعددی مانند دما، رطوبت و اکسیداسیون بر خواص قیرهای اصلاح‌شده تاثیرگذار است. از این جهت، شناخت تغییرات ویژگی‌های این قیرها به منظور ارائه طرح‌های با دوام ضروری است. این مدل‌سازی با استفاده از یک الگوریتم بهینه‌سازی بیز^۷ و نیز رگرسیون بردار پشتیبان با مجموعه داده‌های حاصل از ۴۰۵ نمونه انجام شده‌است. مقاومت چسبندگی

1. Dynamic Shear Rheometer (DSR)
2. Styrene-Butadiene-Styrene (SBS)
3. Support Vector Regression (SVR)
4. Gaussian Phased Regression
5. Root Mean Squared Error (RMSE)
6. Arifuzzaman
7. Bayesian method

۳-۳- پیش‌بینی خصوصیات مخلوط آسفالتی

تاپکین^۱ و همکاران در سال ۲۰۰۹، نتایج آزمایش خزش نمونه‌های اصلاح‌شده با الیاف پلی پروپیلن را با استفاده از شبکه عصبی مصنوعی پیش‌بینی نمودند. دقت مدل ارائه شده ۹۷٪ بوده است. ورودی این مدل عبارت است از نوع پلی پروپیلن، ارتفاع نمونه، وزن مخصوص نمونه، درصد فضای خالی سنگدانه، درصد فضای پر شده با قیر، درصد فضای خالی مخلوط، زمان آسودگی و تعداد ضربه. در ساخت این مدل یک لایه پنهان استفاده شده است. درصد قیر بهینه مخلوط با آزمایش مارشال با اعمال ۵۰ ضربه برای ترافیک متوسط تعیین شده بوده است. در پایان رابطه‌ای بین کرنش جمعی و متغیرهای ورودی، توسعه داده شده است. افزودن پلی پروپیلن به‌طور قابل ملاحظه‌ای کرنش جمعی را کاهش داده است. به‌طور کلی با افزایش پارامترهای طول دوره آسودگی، درصد فضای خالی سنگدانه‌ها، تعداد ضربه‌های وارده و درصد فضای پر شده با قیر، کرنش جمعی مخلوط نیز افزایش یافته است. همچنین، با افزایش پارامترهای وزن مخصوص و درصد فضای خالی و ارتفاع نمونه، کرنش جمعی کاهش یافته است [۵۵].

صفرزاده و حیدری‌پناه در سال ۲۰۰۹ مطالعه‌ای بر تاثیر درصد قیر بر روی مقاومت مارشال مخلوط آسفالتی با استفاده از شبکه عصبی مصنوعی انجام دادند. پایگاه داده، متشکل از ۱۱۰ نمونه مخلوط آسفالتی بود که در آزمایشگاه استان کرمان مورد آزمایش قرار گرفت. دانه‌بندی، درصد مصالح شکسته و درصد قیر به عنوان پارامترهای ورودی، و مقاومت مارشال به عنوان خروجی مدل در نظر گرفته شده است. بر مبنای مدل توسعه‌یافته و تجربیات آزمایشگاهی، با افزایش درصد قیر، ابتدا مقاومت مارشال افزایش و پس از رسیدن به حداکثر مقدار خود، کاهش یافته است. بیشینه مقاومت مارشال متناظر با درصد بهینه قیر مخلوط بوده است. این شبکه با یک لایه پنهان توسعه داده شده است [۵۶].

غنی‌زاده و فخری در سال ۲۰۱۴ به پیش‌بینی فرکانس در راستای شبیه‌سازی آزمایش‌های خستگی مخلوط آسفالتی با استفاده از روش شبکه عصبی مصنوعی و رگرسیون مارس پرداختند. در این مطالعه، ۵،۰۰۰ مقطع چهار لایه روسازی مورد بررسی تئوری الاستیک لایه‌ای قرار گرفتند. هر دو روش توان پیش‌بینی مناسبی داشته‌اند؛ اما مطابق نتایج، شبکه عصبی از رگرسیون مارس انطباق بهتری داشته است. در توسعه شبکه عصبی از یک لایه پنهان استفاده شده است. با استفاده از این مدل توسعه داده شده می‌توان پاسخ‌های روسازی شامل تنش و کرنش را در فواصل شعاعی مختلف از محل

اعمال بار به دست آورد [۵۷].

خرابی ناشی از خستگی، یکی از خرابی‌های متداول روسازی‌های آسفالتی است و انجام آزمایش‌های گسترده بر روسازی، پرهزینه بوده است. تاپکین در سال ۲۰۱۴ مدلی در راستای تخمین عمر خستگی مخلوط‌های قیری اصلاح‌شده با خاکستر بادی بر اساس شبکه‌های عصبی مصنوعی ارائه کرد. خاکستر بادی نسبت به پلیمرها مزایای اقتصادی و محیط‌زیستی بیشتری داشته است. چهار نوع خاکستر بادی مختلف مورد استفاده قرار گرفت. در طرح اختلاط این مخلوط از روش مارشال استفاده شده است. معیار خستگی در آزمایش، شروع ترک‌های ماکرو بوده است. ورودی‌های مدل عبارت بوده است از درصد قیر، ارتفاع نمونه، وزن مخصوص، وزن مخصوص بیشینه تئوری و کل فضای خالی مخلوط. داده خروجی این آزمایش، تعداد سیکل‌های بارگذاری تا ایجاد ترک‌های ماکروی خستگی (N_f) بوده است. به منظور آموزش مدل از الگوریتم لوبنرگ-مارکوارت^۲ استفاده شده است. مطابق نتایج، یک لایه پنهان کافی است؛ زیرا با افزایش لایه‌های پنهان به دو و سه، دقت برازش کاهش یافته است [۵۸].

پارامترهای درجه نرمی و مقاومت مارشال که از آزمایش مارشال محاسبه شده‌اند به عملکرد روسازی‌های راه‌ها مرتبط هستند. خوتیا^۳ و همکاران در هند در سال ۲۰۱۴ مدلی در راستای پیش‌بینی پارامترهای مارشال مخلوط‌های قیری اصلاح شده با پلی اتیلن با روش‌های هوش مصنوعی ارائه دادند. در این تحقیق، از دو الگوریتم شبکه عصبی مصنوعی و ماشین بردار پشتیبان حداقل مربعات^۴ که یک رگرسیون غیرخطی است استفاده شده است. درصد فضای خالی، درجه نرمی^۵ و مقاومت مارشال پیش‌بینی شدند. در مجموع ۹۰ داده ورودی آزمایشگاهی شامل درصد سنگدانه‌های درشت، ریز دانه‌ها، فیلرها، درصد پلیمر و درصد قیر بوده است. مطابق نتایج، هر دو الگوریتم مناسب بوده اما شبکه عصبی از ماشین بردار پشتیبان نتایج نسبتاً بهتری داشته است. دقت پیش‌بینی پارامترهای مقاومت مارشال، درجه نرمی و درصد فضای خالی توسط مدل شبکه عصبی برابر با ۹۳/۶٪، ۹۶ و ۹۷٪ بوده است [۵۹].

غنی زاده در سال ۲۰۱۷، به پیش‌بینی پاسخ‌های (تنش-کرنش-خیز) روسازی‌های آسفالتی با استفاده از روش رگرسیون ماشین بردار پشتیبان پرداخت. در این مدل‌سازی ۱۰،۰۰۰ مقطع روسازی چهار لایه شامل خاک

2. Lavenberg-Marquardt Algorithm (LMA)
3. Khuntia
4. Least Square Support Vector Machine (LS-SVM)
5. Flow value

1. Tapkin

آسفالتی از نتایج تست مارشال با روش دایره‌وارهای رگرسیونی تطبیقی چند متغیره، معروف به رگرسیون مارس^۶ پرداختند. این مدل به کاهش هزینه و زمان انجام آزمایش‌ها منجر شده‌است. دقت مدل توسعه داده شده بیش از ۹۶ درصد بوده‌است. پارامترهای ورودی این مدل عبارت است از درصد ریزدانه و درشت‌دانه مصالح سنگی، درصد قیر، درصد فضای خالی، درصد فضای خالی مصالح سنگی، مقاومت مارشال. پارامتر خروجی مدنظر، درجه نرمی بوده‌است. مجموعه داده این پژوهش که حاصل نتایج میرزاحسینی در سال ۲۰۱۱ است، شامل ۱۱۸ داده بوده‌است. طبق نتایج ارائه شده در این پژوهش، روش رگرسیون مارس عملکرد دقیق‌تری از الگوریتم‌های مبتنی بر ساختار ژنتیکی^۷، الگوریتم بردار پشتیبان و رگرسیون حداقل مربعات داشته‌است [۶۳].

مقاومت کششی مخلوط آسفالتی، یکی از مهم‌ترین پارامترها در راستای پیش‌بینی ظهور ترک‌ها در مخلوط‌های آسفالتی است [۶۴]. عابد و همکاران در سال ۲۰۲۱ مطالعه‌ای در راستای مدل‌سازی سختی مخلوط‌های آسفالتی اصلاح‌شده با استفاده از آزمایش رئومتر تیر خمشی^۸ انجام دادند. دو دانه‌بندی مختلف در نظر گرفته‌شد. همچنین از قیر با درجه نفوذ ۴۰-۵۰ میلی‌متر استفاده شد. از دو نوع افزودنی اصلاح‌کننده استایرن بوتادین استایرن و نیز از پلی‌وینیل کلراید^۹ استفاده شد. محققین با کمک نرم‌افزار اس‌پی‌اس‌اس^{۱۰} از یک شبکه عصبی مصنوعی به منظور بررسی اثرات پنج عامل دما، زمان بارگذاری، درصد استایرن-بوتادین-استایرن، درصد پلی‌وینیل کلراید و نیز خیز وسط دهانه تیر بر سختی مخلوط استفاده کردند. در ساختار شبکه عصبی از یک لایه پنهان استفاده شد. داده‌ها نرمال سازی شد. دقت مدل، ۸۸/۶٪ است. در این مدل، خروجی شبکه عصبی عمر خستگی بوده‌است [۶۵].

در روش مکانیکی تجربی که به عنوان روش جدید طراحی روسازی‌ها مطرح است، خصوصیات مخلوط آسفالتی وابسته به قیر مانند پیرشدگی در نظر گرفته شده‌است. در این راستا یکی از مهم‌ترین ورودی‌های این روش مدول دینامیکی مخلوط آسفالتی است [۶۶-۶۸]. هوانگ^{۱۱} و همکاران در سال ۲۰۲۱ به کمک روش‌های یادگیری ماشین به پیش‌بینی مدول دینامیکی مخلوط آسفالتی با بهبود رابطه‌ی ویتزک^{۱۲} پرداختند. در آماده سازی مخلوط‌ها

بستر، زیراساس دانه‌ای، اساس دانه‌ای و لایه آسفالتی مورد بررسی قرار گرفته‌است. در این تحلیل از بارگذاری تحت محور استاندارد ۸/۲ تنی و تئوری الاستیک لایه‌ای استفاده شده‌است. هدف مطالعه، محاسبه بیشینه کرنش کششی زیر لایه آسفالتی و بیشینه کرنش فشاری روی لایه بستر بوده‌است [۶۰].

مجیدی فرد و همکاران در سال ۲۰۱۹، مدل‌های پیش‌بینی انرژی شکست مخلوط آسفالتی را با استفاده از روش‌های یادگیری ماشین مورد بررسی قرار دادند. در این مطالعه، دو روش ماشینی برنامه‌ریزی بیان ژنی^۱ و شبکه عصبی مصنوعی ترکیب‌شده با الگوریتم تبرید شبیه‌سازی شده^۲ مورد استفاده قرار گرفت. روش برنامه‌ریزی بیان ژنی که از توسعه الگوریتم ژنتیک بدست آمده، مدل‌های ریاضی را بر مبنای مفاهیم تکامل داروین ارائه داده‌است. مطابق نتایج، مدل برنامه‌ریزی بیان ژنی نتایج بهتری از مدل ترکیبی تبرید شبیه‌سازی شده و شبکه عصبی مصنوعی نشان داده است. ده پارامتر ورودی شامل بیشینه سایز اسمی، درصد قیر، حد پایین درجه عملکردی قیر، نوع دانه‌بندی، درصد پودر لاستیک و همچنین یک لایه پنهان در شبکه عصبی مصنوعی ساخته‌شده تعریف شده‌است تا در نهایت انرژی شکست مخلوط آسفالتی پیش‌بینی شود [۶۱].

لی^۳ و همکاران در سال ۲۰۲۰، به پیش‌بینی مدول دینامیکی مخلوط آسفالتی با استخوان‌بندی سنگدانه‌ای^۴ پرداختند. این مطالعه اولین مقایسه مدول دینامیکی بین مخلوط‌های آسفالتی گرم و استخوان‌بندی سنگدانه‌ای بوده‌است. در این مطالعه از یک الگوریتم جدید یادگیری ماشین استفاده شد. این الگوریتم، ترکیبی از دو الگوریتم شبکه عصبی مصنوعی و یک الگوریتم بهینه‌سازی مبتنی بر آموزش و یادگیری^۵ است. مجموعه داده حاصل شده از نتایج آزمایش‌ها، شامل ۹۶ داده ورودی بوده‌است که هر یک میانگین ۶ نمونه مشابه بوده‌است. دقت مدل ترکیب‌شده از این دو الگوریتم برابر با ۹۸٪ و دقت مدل شبکه عصبی مصنوعی تنها با داده‌های موجود برابر با ۹۴/۸٪ بوده‌است که تاثیر الگوریتم جدید را به خوبی نمایش داده‌است. مطابق نتایج، دمای انجام آزمایش موثرترین عامل در تعیین مدول دینامیکی مخلوط آسفالتی با استخوان‌بندی سنگدانه‌ای است [۶۲].

غنی زاده و همکاران در سال ۲۰۲۰ به پیش‌بینی درجه نرمی مخلوط

6. Multivariate Adaptive Regression Spline (MARS)
7. Gene Expression Programming – Multi Expression Programming (GEP-MEP)
8. Bending Beam Rheometer (BBR)
9. PolyVinyl Chloride (PVC)
10. SPSS
11. Huang
12. Witczak

1. Gene Expression Programming (GEP)
2. Artificial Neural Network with Simulated Annealing (ANN/SA)
3. Le
4. Stone Mastic Asphalt (SMA)
5. Teaching Learning Based Optimization (TLBO)

مخلوط آسفالتی با استفاده از روش‌های یادگیری ماشین پرداختند. دو مدل با استفاده از داده‌های حاصل از ۴۰۲۲ نمونه مخلوط آسفالتی ساخته شده‌است. مدل اول شامل پارامترهای دما، فرکانس، درصد فضای خالی مصالح سنگی، درجه عملکردی قیر و مدل دوم شامل پارامترهای دما، فرکانس، درصد فضای خالی مصالح سنگی، درجه عملکردی قیر، درصد قیر مخلوط، دمای بالای درجه عملکردی قیر، حجم قیر موثر، درصد روسازی آسفالتی بازیافتی بوده‌است. در این پژوهش از الگوریتم بهینه‌سازی جغرافیای زیستی^۶ مبتنی بر توزیع طبیعی جانوران در زیست‌بوم استفاده شده‌است. هر دو مدل توسعه داده شده با دقت بالای ۹۷٪ با داده‌های تجربی انطباق داشته‌است [۷۱].

رحمان و همکاران در سال ۲۰۲۱، به پیش‌بینی عمق شیارشدگی و نیز مقاومت کششی غیرمستقیم مخلوط آسفالتی به وسیله روش‌های یادگیری ماشین پرداختند. پیش‌بینی عمق شیارشدگی با استفاده از داده‌های آزمایش شیارشدگی هامبورگ انجام شده‌است. از الگوریتم‌های رگرسیون بردار پشتیبان، گرادیان تقویتی^۷، درخت اضافی^۸، جنگل تصادفی و طبقه بندی ترکیبی برای پیش‌بینی عمق شیارشدگی و مقاومت کششی غیرمستقیم استفاده شده‌است. بر اساس معیار ضریب تعیین R^2 ، روش درخت اضافی بهترین مدل را ایجاد کرد [۷۲].

گسترش و توسعه ساختار ترک مخلوط‌های آسفالتی با استفاده از منحنی‌های شکست قابل درک است. آزمایش‌های تعیین رفتار شکست مخلوط‌های آسفالتی با پیچیدگی‌هایی همراه بوده، در نتیجه استفاده از روش‌های جدیدتر بررسی شده‌است. غفاری و همکاران در سال ۲۰۲۲ با استفاده از روش‌های یادگیری ماشین به پیش‌بینی منحنی‌های مقاومت شکست مخلوط‌های آسفالتی اصلاح‌نشده و اصلاح‌شده با پودر لاستیک پرداختند. نمونه‌ها با دو نوع قیر دارای درجه عملکردی مختلف، مصالح سنگی آهکی و سیلیسی با دو دانه‌بندی، محدوده دمایی +۵ تا -۲۰- درجه سانتی‌گراد برای انجام آزمایش، درصد‌های مختلف پودر لاستیک ۰، ۵، ۱۰، ۱۵ و ۲۰٪، درصد‌های مختلف قیر ۴، ۵/۴ و ۵٪ در نظر گرفته شده‌است. آزمایش تیر با ترک لبه‌ای تحت خمش سه نقطه‌ای^۹ در راستای استخراج داده‌ها انجام شده‌است. دقت مدل‌های ساخته‌شده با روش‌های شبکه عصبی مصنوعی و ژنتیک به ترتیب ۹۶/۵٪ و ۸۷٪ بود. داده‌های ورودی شامل محدوده عملکردی دمایی قیر، حداقل دمای عملکردی قیر، درصد قیر

از چهار دانه‌بندی با بیشینه سائز اسمی ۱۹ میلی‌متر و چهار دانه‌بندی ۱۲/۵ میلی‌متر، دو نوع قیر و مجموعاً ۱۶ مخلوط آسفالتی استفاده شده‌است. طرح اختلاط مخلوط‌ها به روش سوپریو انجام شد. مقادیر مدول برشی قیر (G^*) و زاویه فاز (δ) به طور تجربی در دماهای مختلف و فرکانس‌های مختلف با استفاده از تست رنومتر دینامیکی برشی حاصل شده‌است. آزمایش مدول دینامیکی آسفالت انجام شد. در این مطالعه از روش‌های درخت رگرسیون منفرد، جنگل تصادفی^۱ و الگوریتم جستجوی بهبودیافته حسگر سوسک^۲ برای پیش‌بینی هوشمند مدول دینامیکی استفاده شده‌است. بر اساس نتایج، دانه‌بندی تاثیر چندانی بر مدول دینامیکی نداشته‌است، اما مدول برشی قیر، زاویه فاز و خصوصیات حجمی قیر، به ترتیب دارای بیشترین اثرگذاری بر مقدار مدول دینامیکی بوده‌اند [۶۹].

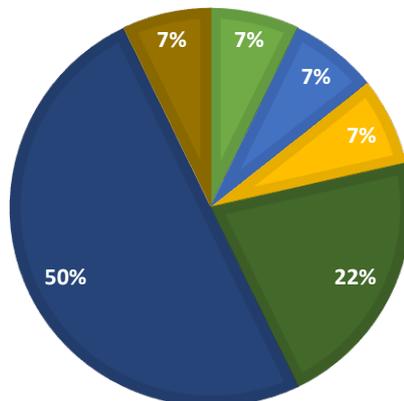
ارزیابی سازه‌های روسازی‌ها همواره از دو طریق آزمایش‌های مخرب یا غیرمخرب صورت گرفته‌است. محاسبه مدول لایه‌های روسازی آسفالتی، به طور سنتی از طریق محاسبات معکوس خیز اندازه‌گیری‌شده رویه روسازی انجام شده‌است. اما روش‌های مبتنی بر شبکه عصبی، روش‌های دقیق‌تری برای این منظور هستند. ژنگ^۳ و همکاران در سال ۲۰۲۱ به محاسبه مدول روسازی با محاسبات معکوس بوسیله شبکه عصبی مصنوعی بهینه‌شده با الگوریتم ژنتیک برای یک روسازی آسفالتی پرداختند. ورودی‌های این شبکه عصبی عبارت است از: مقادیر خیز اندازه گرفته‌شده از دستگاه نشست‌سنج وزنه‌ای^۴، مقدار بارگذاری، ضخامت لایه‌ها، دمای سطح روسازی و دمای هوا و شاخص حلقه پسماند (منحنی نیرو-جابجایی). همچنین پیشنهاد شده‌است که مطالعات آتی دارای متغیرهای ورودی بیشتری اعم از بار چرخ، سرعت، ساختار روسازی و مصالح باشد. یک لایه پنهان برای مدل ایجاد شده‌است. در انجام آزمایش، سه میلیون بار عبور صورت گرفته‌است. آزمایش در یک فضای $۹/۵۲۵ \times ۳/۷۵$ متری انجام شده‌است. در هر یک از لایه‌های روسازی با افزایش سیکل‌های بارگذاری یا با افزایش دما، مدول کاهش یافته‌است [۷۰].

همواره مدول دینامیکی به عنوان یکی از پارامترهای مهم در طراحی روسازی بوده‌است. پیش‌بینی غیرمستقیم مقادیر مدول دینامیکی به جای انجام مستقیم آزمایش‌ها، مزایای اقتصادی و زمانی زیادی به همراه داشته‌است. بهنود و گلفشانی^۵ در سال ۲۰۲۱، به پیش‌بینی مدول دینامیکی

6. Biogeography-Based Optimization (BBO)
7. Gradient Boosting
8. Extra tree
9. Single-Edge Notched Beam (SENB)

1. Random Forest (RF)
2. Beetle Antenna Search (BAS)
3. Zhang
4. Falling weight Deflectometer (FWD)
5. Behnood & Golafshani

■ حجم قیر موثر ■ خصوصیات حجمی قیر ■ مدول برشی قیر
■ درجه عملکردی قیر ■ درصد قیر ■ درصد فضای پر شده با قیر



شکل ۲. سهم پارامترهای مرتبط با قیر که به مدل‌های هوش مصنوعی وارد شده‌اند. (مقایسه میان ۱۶ مطالعه علمی با هدف پیش‌بینی خصوصیات مخلوط آسفالتی)

Fig. 2. The share of parameters characterizing asphalt in the performed AI-assisted analyses (analyzing 16 different studies aimed at predicting asphalt mixture characteristics)

شامل دوربین‌های مادون قرمز و چند حسگر اندازه‌گیری دما با طراحی اختصاصی بودند. بخش نرم‌افزاری که مدل‌های مختلف رگرسیون، ماشین بردار پشتیبان و تقویت گرادیان شدید^۲ را در بر می‌گرفت، دماهای میان نقطه تماس مخلوط با محفظه کامیون و نقاط مرکزی مخلوط را پیش‌بینی می‌نمودند. نتایج نشان داد که روش توسعه داده‌شده در شرایط توقف کامیون، در صورتی که سرعت باد در نظر گرفته‌شود، عملکرد قابل قبولی داشته‌است. همچنین در شرایط حرکت کامیون، عوامل مختلفی از جمله سرعت رانندگی، دمای محیط، موقعیت قرارگیری حسگرها و لایه‌های عایق‌بندی باید در روابط اعمال شود [۷۴].

آن دسته از ورودی‌های مدل‌های هوش مصنوعی که مربوط به قیر بوده‌است در شکل ۲ نشان داده‌شده و فراوانی آن‌ها با یکدیگر مقایسه شده‌است. بر این اساس پارامترهای درصد قیر و درجه عملکردی قیر که داده‌های آن‌ها به ترتیب در ۷ و ۳ پژوهش مورد استفاده قرار گرفته، بیشترین فراوانی را نسبت به سایر پارامترها یعنی مدول برشی قیر، حجم موثر قیر، خصوصیات حجمی قیر و درصد فضای پر شده با قیر داشته‌اند. آن دسته از پارامترهای مربوط به مخلوط یا نمونه آسفالتی ساخته‌شده

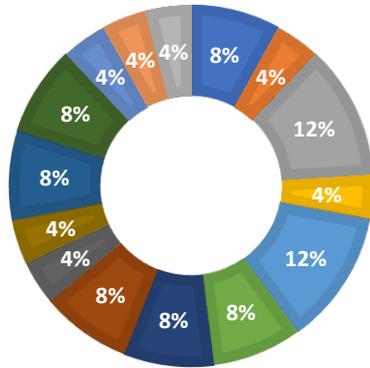
مخلوط، درصد پودر لاستیک، دمای انجام آزمایش، زمان بارگذاری، بیشینه سایز اسمی مصالح سنگی و نوع مصالح سنگی (آهکی یا سیلیسی) است. خروجی مدل شامل انرژی تجمعی شکست و میزان گسترش طول ترک بوده‌است. داده‌ها از ۲۵۹ آزمایش تیر با ترک لبه تحت خمش سه نقطه‌ای حاصل شده‌است. اگر چه مدل ساخته‌شده با روش شبکه عصبی از روش ژنتیک بهتر بوده، ولی هر دو دقت بالایی داشته و قابل استفاده بودند. نتایج نشان داد که درصد قیر بیشتر منجر به اتلاف بیشتر انرژی شده‌است و مقاومت بالاتری در هنگام ترک‌خوردگی پدید آمده‌است. مخلوط‌های دارای ۲۰٪ پودر لاستیک حتی در دماهای پایین ۲۰- درجه سانتی‌گراد خصوصیات خوبی از خود نشان داده‌است [۷۳].

یکی از دلایل بروز خرابی‌های زود هنگام در رویه‌های اجراشده، بوجود آمدن تغییرات دمایی در مخلوط آسفالتی حین حمل و انتقال به موقعیت پروژه است. ونگ^۱ و همکاران در سال ۲۰۲۳ به ارزیابی تغییرات دمایی مخلوط آسفالتی حمل‌شده توسط کامیون پرداخته و دقت روش‌های توسعه داده‌شده را در مقابل آزمایش‌های میدانی صحت‌سنجی نمودند. روش نوین پیشنهادشده از دو بخش سخت‌افزار و نرم‌افزار تشکیل شده‌بود. سخت‌افزارها

2. Extreme Gradient Boosting (XGboost)

1. Wang

- | | | | |
|--------------------------|--------------------|---------------------------|--------------------------|
| ■ درصد فضای پرشده با قیر | ■ درصد مصالح شکسته | ■ درصد فضای خالی مخلوط | ■ درصد پودر لاستیک |
| ■ پارامترهای مارشال | ■ وزن مخصوص نمونه | ■ ماکزیمم سایز اسمی | ■ درصد فضای خالی سنگدانه |
| ■ درصد سنگدانه‌های درشت | ■ درصد فیلرها | ■ درصد ریزدانه‌ها | ■ درصد پلیمر |
| ■ درصد SBS | ■ درصد PVC | ■ وزن مخصوص تئوری ماکزیمم | |



شکل ۳. مقایسه سهم پارامترهای واردشده به مدل‌های هوش مصنوعی در ارتباط با خصوصیات نمونه یا مخلوط آسفالتی (مقایسه میان ۱۶ مطالعه علمی با هدف پیش‌بینی خصوصیات مخلوط آسفالتی)

Fig. 3. Comparing the share of parameters characterizing asphalt mixture or pavement sample in the performed AI-assisted analyses (analyzing 16 different studies aimed at predicting asphalt mixture characteristics)

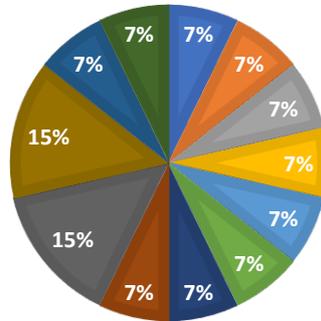
طبق روش مارشال آماده‌سازی و سپس بر اساس آزمون کشش غیرمستقیم آزمایش شده‌اند و در مطالعه دوم، نمونه‌ها با استفاده از رتومتر تیر خمشی مورد آزمایش قرار گرفته‌اند. باتوجه به تفاوت آزمایش‌های به‌کارگرفته‌شده، ورودی‌های مدل‌های ساخته نیز متفاوت بوده‌است. دقت پیش‌بینی در مطالعه تاپکین در سال ۲۰۱۴ [۵۸] برابر با ۹۲/۵٪ بود که نسبت به مطالعه عابد و همکاران در سال ۲۰۲۱ [۶۵] حد ۴٪ بالاتر بوده‌است. پیشنهاد می‌شود در مطالعات آینده، دیگر روش‌های پیش‌بینی عمر خستگی نیز مورد مطالعه قرار گرفته و عملکرد سایر مدل‌های یادگیری ماشین در پیش‌بینی این متغیر بررسی شود. همچنین باتوجه به اینکه در ۲ مطالعه اشاره‌شده از نرم‌افزارهای متلب و اس‌پی‌اس‌اس برای مدلسازی استفاده شده‌است، پیشنهاد می‌شود در مطالعات آینده، مدلسازی با به‌کارگیری زبان پایتون و کتابخانه‌های مورد نیاز هر مدل ارتقاء داده شود.

مدول دینامیکی متغیر دیگری است که در مطالعات مختلف مورد بررسی قرار گرفته‌است. لی و همکاران در سال ۲۰۲۰ [۶۲] و هوانگ و همکاران در سال ۲۰۲۱ [۶۹] مدول دینامیکی را برای مخلوط‌های آسفالتی متفاوتی بر مبنای روش آشتو تعیین و سپس با استفاده از مدل‌های یادگیری ماشین بهینه‌سازی شده پیش‌بینی نمودند. در مطالعه اول مخلوط آسفالتی

که به‌عنوان ورودی به مدل داده شده‌اند، از نظر فراوانی در شکل ۳ مقایسه شده‌اند. بر این اساس، درصد فضای خالی سنگدانه و درصد فضای خالی مخلوط که در ۳ مطالعه به‌عنوان ورودی مدل استفاده شده‌اند، بیشترین فراوانی را داشته‌اند.

در نهایت، پارامترهای مربوط به شرایط آزمایش و برخی مشخصات نمونه در شکل ۴ از نظر سهم آن‌ها در ادبیات موضوع با یکدیگر مقایسه شده‌اند. بر این اساس، دما و زمان بارگذاری بیشترین سهم را داشته‌اند.

تحلیل مطالعات این بخش نشان می‌دهد که پارامترهای عمر خستگی، مدول دینامیکی و نیز پارامترهای تست مارشال در مطالعات مختلفی تحلیل شده و نتایج آن‌ها با یکدیگر قابل مقایسه است. هدف از مدل‌های ساخته‌شده در این پژوهش‌ها، جایگزین نمودن مدلسازی کامپیوتری بر آزمایش‌های زمان‌بر و هزینه‌بر بوده‌است. مطالعات تاپکین در سال ۲۰۱۴ [۵۸] و عابد و همکاران در سال ۲۰۲۱ [۶۵] هر دو بر پیش‌بینی عمر خستگی مخلوط آسفالتی با استفاده از شبکه عصبی متمرکز بوده‌است که در مطالعه اول از خاکستر بادی و در مطالعه دوم از استایرن-بوتادین-استایرن و همچنین پلی‌وینیل کلراید به‌عنوان افزودنی استفاده شده‌است. بعلاوه، در این دو مطالعه از روش‌های متفاوتی برای تخمین عمر خستگی استفاده شده‌است: در مطالعه اول نمونه‌ها



شکل ۴. مقایسه سهم پارامترهای واردشده به مدل‌های هوش مصنوعی در ارتباط با شرایط اجرای آزمایش و نمونه آزمایش شده (مقایسه میان ۱۶ مطالعه علمی با هدف پیش‌بینی خصوصیات مخلوط آسفالتی)

Fig. 4. Comparing the share of parameters related to the experiment or sample conditions in the performed AI-assisted analyses (analyzing 16 different studies aimed at predicting asphalt mixture characteristics)

حاوی ۹۶ و ۱۴۰ ردیف داده) به‌طور قابل توجهی افزایش یافته است. در این مدل، شاخص انحراف جذر میانگین مربعات برای پیش‌بینی مدول به حدود ۰/۰۱ مگاپاسکال کاهش یافته است. بهبود قابل توجه خطای مدل نسبت به مطالعات قبل نشان از اهمیت به‌کارگیری داده‌های کافی برای آموزش مدل و همچنین استفاده از ورودی‌های موثر جهت پیش‌بینی است. با توجه به تفاوت داده‌های استفاده‌شده در مطالعات، پیشنهاد می‌شود در مطالعات پیش رو مدل‌های مختلف یادگیری ماشین بر مجموعه داده‌های مشترک و متغیرهای ورودی یکسان توسعه داده شود تا امکان ارزیابی عملکرد مدل‌ها در شرایط یکسان فراهم گردد.

در نهایت، چندین مطالعه جهت پیش‌بینی پارامترهای مارشال منتشر شده است [۵۶، ۶۹، ۶۳]. با توجه به محدودیت داده‌ها (حدود ۱۰۰ ردیف داده) و مدل‌های استفاده‌شده (شبکه عصبی مصنوعی و رگرسیون مارس) برای پیش‌بینی مقاومت مارشال، پیشنهاد می‌شود در مطالعات پیش رو از مجموعه داده‌های بزرگ‌تر و دیگر مدل‌های یادگیری ماشین برای پیش‌بینی مقاومت مارشال استفاده شود.

۳-۴- تشخیص خرابی‌های سطح روسازی

ترک‌های پنهان به دلیل پتانسیل ایجاد ترک‌های انعکاسی در آینده

با استخوان‌بندی سنگدانه‌ای به همراه افزودنی‌هایی از جمله پلیمر، الیاف سلولزی و ساسوبیت مورد آزمایش قرار گرفته و سپس از الگوریتم شبکه عصبی مصنوعی بهینه‌شده برای مدلسازی استفاده شده است. در مطالعه دوم مخلوطی با قیر حاوی استایرن-بوتادین-استایرن با طرح اختلاط حاصل از سوپریو در نظر گرفته شده و سپس مدل جنگل تصادفی بهینه‌شده با الگوریتم جستجوی حسگر سوسک برای مدلسازی به‌کار گرفته شده است. از تمایزات دیگر این دو مطالعه می‌توان به متغیرهای پیش‌بینی‌کننده واردشده به مدل اشاره نمود که در مطالعه اول محدود به دما و فرکانس بوده و در مطالعه دوم شامل مدول برشی قیر، زاویه فاز، خصوصیات حجمی قیر و مشخصات مصالح سنگی بوده است. جالب توجه است که شاخص انحراف جذر میانگین مربعات برای هر دو مدل برابر با ۱۸۰ مگاپاسکال بوده است. مطالعه دیگری نیز جهت پیش‌بینی مدول دینامیکی توسط بهنود و گلشنای در سال ۲۰۲۱ [۷۱] انجام شده که در آن، متغیرهای ورودی مدل ترکیبی از دو مطالعه قبلی [۶۲] و [۶۹] به جز مقدار زاویه فاز بوده است. در این مطالعه که بر مبنای یک مجموعه داده از مشخصه‌های مخلوط آسفالتی حاوی تراشه آسفالتی انجام شده، از الگوریتم بهینه‌سازی جغرافیای زیستی برای مدلسازی بهره گرفته شده است. تعداد داده‌های استفاده‌شده در این مطالعه برابر با حدود ۴ هزار ردیف بوده که در قیاس با دو مطالعه اشاره‌شده

در راستای هوشمندسازی سیستم حمل‌ونقل، مطالعه‌ای با موضوع نظارت خودکار بر ترک‌های روسازی انجام دادند. داده‌های این مطالعه شامل تصاویر برداشت‌شده از سطح راه به‌وسیله یک دوربین ورزشی تجاری گوپرو^۶ بود که پشت یک خودرو نصب گردیده بود. تصویربرداری در سرعت ۴۰ تا ۸۰ کیلومتر بر ساعت و با نرخ ۲۴۰ فریم بر ثانیه انجام شده‌است. در این مطالعه از یک شبکه عصبی دارای ۱۲۱ لایه واپیچش^۷ به عنوان مولد و نیز از یک شبکه ۵ لایه کاملاً پیچشی به عنوان تفکیک‌کننده استفاده شده‌است. مدل توسعه داده‌شده با عنوان کان‌کرک^۸ نام‌گذاری گردید که نتایج بهتری نسبت به روش‌های موجود داشته‌است. در این مطالعه فقط به تشخیص ترک پرداخته شده‌است و راه حلی برای تعیین ابعاد ترک‌ها توسعه داده نشده‌است [۷۶].

گائو^۹ و همکاران در سال ۲۰۲۰، مطالعه‌ای در راستای تشخیص خودکار خرابی‌های روسازی با استفاده از رادار نفوذی زیرزمینی با بهره‌گیری از الگوریتم یادگیری عمیق انجام دادند. الگوریتم یادگیری عمیق به کار گرفته شده در این مطالعه، یک شبکه عصبی پیچشی مبتنی بر ناحیه سریع‌تر^{۱۰} بوده‌است. مجموعه داده^{۱۱} این مطالعه ۳،۷۸۵ تصویر رادار نفوذی زیر زمینی با وضوح ۵۱۲ × ۵۱۲ پیکسل بوده‌است. در این مجموعه داده سه نوع معضل ترک‌های انعکاسی، جمع‌شدگی آب روی سطح زمین و نیز نشست‌های ناگهانی مورد بررسی قرار گرفت. شبکه عصبی این مطالعه دارای دو خروجی است. خروجی لایه^{۱۲} تابع بیشینه هموار برای تشخیص و پیش‌بینی طبقه‌بندی خرابی مورد استفاده قرار گرفته‌است و خروجی لایه رگرسیونی برای مکان‌یابی محل خرابی به وسیله تصاویر رادار نفوذی مورد استفاده قرار گرفته‌است [۷۷].

یکی از عوامل موثر بر عملکرد و دوام روسازی‌ها نحوه توزیع سنگدانه‌ها درون روسازی است. تشخیص غیرمخرب این پارامتر ارزش بسیار بالایی در حفظ زمان و هزینه به دنبال خواهد داشت. دان^{۱۱} و همکاران در سال ۲۰۲۱ به بررسی این موضوع با استفاده از یادگیری عمیق پرداختند. در این مطالعه نمونه‌های گرفته‌شده از سطح روسازی‌ها تحت آزمایش قرار گرفت. همچنین اطلاعات جانبی سطح نمونه‌ها به وسیله یک شبکه عصبی مصنوعی تجزیه و تحلیل شد. مدل‌های شناسایی‌کننده^{۱۲} ایجادشده در این مطالعه مبتنی بر

و مشاهده‌نشدن در حین عملیات نگهداری، از معضلات ویژه در مدیریت روسازی راه محسوب می‌شود. همواره یکی از چالش‌های محققین، تشخیص این نوع از خرابی‌ها بوده‌است اما با استفاده از هوش مصنوعی این امکان بیش از پیش فراهم شده‌است. تانگ^۱ و همکاران در سال ۲۰۱۷، به مطالعه بر کاربرد شبکه‌های عصبی در پردازش تصاویر رادار نفوذی زیرزمینی^۲ پرداختند. این مطالعه در کشور چین انجام شده‌است و برای تصویربرداری از سطح روسازی‌ها از دستگاه رادار نفوذی زیرزمینی ساخت چین استفاده شده‌است. مشکل تصاویر رادار نفوذی زیرزمینی آن است که عرض ترک‌های پنهان به درستی قابل تشخیص نبوده‌است و باید برای محاسبه مقدار واقعی از روابط تجربی استفاده کرد. در این مطالعه از شبکه عصبی پیچشی که جزء شبکه‌های عصبی عمیق است، استفاده شده‌است. برای ساخت مجموعه داده تشخیص ترک، مجموعه ای شامل ۲،۲۰۰ تصویر از کل ۶،۸۴۲ تصویر موجود انتخاب شده و برای آموزش مدل به‌کار گرفته شده‌است. ساختار شبکه تشخیص ترک در این مطالعه از ۲ لایه پیچشی، ۲ لایه نمونه‌گیری فرعی، ۲ لایه ارتباطی و نهایتاً لایه خروجی تشکیل شده است [۱۵].

تشخیص خرابی توسط کاربران متخصص، زمان‌بر، گران و غیرمنطقی است. به‌منظور برداشت داده‌های تمامی شبکه راه در زمان مطلوب، نیاز به سامانه‌ای جهت تشخیص خرابی‌ها به صورت خودکار وجود دارد که افراد غیرمتخصص نیز امکان اجرای آن را داشته باشند. تانگ و همکاران در سال ۲۰۲۰، با استفاده از رادار نفوذی زیرزمینی که روشی غیرمخرب به‌شمار می‌رود، به تشخیص خرابی‌های روسازی پرداختند. در این روش، داده‌های رادار نفوذی به عنوان ورودی به دو شبکه داده شده‌است. شبکه‌ها مدل‌های یادگیری عمیق به شمار می‌روند. به منظور آموزش شبکه‌ها از پایگاه داده‌ای حاصل از ارزیابی یک چهارراه استفاده شده‌است. در انتخاب داده‌ها، فرکانس‌های ۳۰۰، ۶۰۰ و ۹۰۰ مگاهرتز بررسی شدند و تعداد ۲۵۶، ۳۸۴ و ۵۱۲ نمونه از چهارراه مورد مطالعه برداشت شد. روش تشخیص خرابی‌ها بر رفتار غیرمعمول سیگنال‌های ارسالی نهفته‌است. در این مدل چندین لایه مختلف از نوع یاخته عصبی چندلایه، لایه ادغام متوسط جامع^۳ و تابع بیشینه هموار^۴ وجود داشته و تشخیص خرابی مبتنی بر خروجی لایه تابع بیشینه هموار و سه لایه رگرسیونی بوده‌است. نتایج نشان داده‌است دقت این روش معادل ۸۵/۱۷٪ بوده‌است [۷۵]. می و گل^۵ در سال ۲۰۲۰،

6. GoPro
7. Deconvolution
8. ConCrack
9. Gao
10. Faster R-CNN
11. Dan

1. Tong
2. Ground Penetrating Radar (GPR)
3. Global Average Pooling (GAP)
4. Softmax
5. Mei & Gul

گرفته‌است. در این مطالعه از تکنیک‌های ساختار از حرکت^۵، فن‌آوری تبدیل تصاویر دوبعدی برداشت‌شده به تصاویر دارای عمق و سه‌بعدی، استفاده گردید. به منظور سهولت محاسبات از یک شبکه ساده یونت استفاده شد. این شبکه با ۱۸۰ تکرار آموزش داده شده‌است. خرابی‌های تشخیص داده‌شده توسط این روش شامل چاله‌ها و ترک‌ها بود. عمق ترک‌ها و نیز عمق چاله‌های محاسبه‌شده توسط این مدل دقت بسیار خوبی نسبت به مقادیر واقعی داشته‌است. همچنین حجم چاله‌های تشخیص داده‌شده نیز محاسبه شده‌است [۸۱].

احسانی و همکاران در سال ۲۰۲۲ از الگوریتم‌های شبکه عصبی مصنوعی و جنگل تصادفی برای پیش‌بینی بروز اختلاف ارتفاع میان دال‌های روسازی بتنی استفاده کردند. در این پژوهش از برنامه‌نویسی عدصیح دوهدفه جهت کاهش تعداد ورودی‌های مدل شبکه عصبی استفاده گردید که منجر به کاهش ۳۲ ورودی مدل به ۱۹ ورودی شد. از مقایسه مدل‌های توسعه داده‌شده دریافت شد که عملکرد شبکه عصبی بهتر از مدل‌های جنگل تصادفی بوده‌است. در نهایت تحلیل حساسیت بر پارامترهای مختلف اجرا شد. مهم‌ترین پارامترهای ورودی مدل جنگل تصادفی عبارت بودند از ضخامت اساس، ترافیک عبوری، عمر روسازی، متوسط روزهایی در سال که دمای هوا بالاتر از ۳۲ درجه سانتی‌گراد بوده و تعداد روزهایی که میزان بارش بیشتر از ۱۲/۷ میلی‌متر بوده‌است [۸۲].

۳-۵- طبقه‌بندی خرابی‌های سطحی

بررسی میدانی و چشمی روسازی در راستای تشخیص و دسته‌بندی انواع خرابی‌ها، زمان‌بر و پرهزینه است و با پیشرفت تجهیزات در علوم مختلف می‌توان این کار را به‌صورت نیمه‌خودکار یا خودکار انجام داد. لی^۶ و همکاران در سال ۲۰۱۹، به شناسایی و طبقه‌بندی خودکار ترک‌های روسازی بر اساس تصاویر سه‌بعدی روسازی پرداختند. پس از ساخت مدل شناسایی، با استفاده از اطلاعات ۲۰۰ روسازی، دقت و بهره‌وری مدل مورد بررسی قرار گرفت. نتایج این روش با استفاده از آزمون‌های تی و اف^۷ نسبت به مقادیر واقعی مقایسه شد که دقت‌های حاصل‌شده به ترتیب برابر با ۸۸/۳۸٪ و ۹۰/۶۸٪ بودند؛ پس بهره‌وری این روش اثبات شده‌است [۸۳].

تصاویر بدست آمده از تلفن‌های همراه و کامپیوترهای شخصی بوده‌است. در این مطالعه ابتدا به تشخیص سنگدانه‌ها از تصاویر با استفاده از شبکه عصبی پرداخته شده‌است، سپس ابعاد حفرات و سنگدانه‌ها محاسبه شده و در نتیجه پارامترهایی مانند نسبت ابعاد، گردی و نیز تحلیل ضعف مخلوط بدست آمده‌است. برای داشتن تصویری از سطح جانبی مخلوط، تصویربرداری از زوایای مختلف صورت گرفته‌است. همچنین الگوریتم یونت پلاس پلاس^۱ از حوزه تشخیص تصاویر پزشکی به این مبحث وارد شده‌است [۷۸].

آریا و همکاران در سال ۲۰۲۱، با هدف تشخیص خرابی‌های راه، مطالعه‌ای بر تصاویر گرفته شده توسط تلفن‌های همراه هوشمند انجام دادند. این مطالعه با استفاده از یادگیری عمیق صورت گرفته‌است. در این تحقیق، اطلاعاتی پیرامون مجموعه تصاویر آریدی^۲ ۲۰۲ با بیش از ۳۱،۰۰۰ نمونه خرابی از کشورهای ژاپن، هند و جمهوری چک، بیان شده‌است. ترک‌های خستگی (پوست‌سوسماری)، ترک‌های طولی، ترک‌های عرضی و چاله‌ها خرابی‌های مد نظر در این مجموعه بوده‌است. تصاویر به‌وسیله تلفن همراه متصل به یک خودرو و با ظرفیت ثبت تصاویر در حرکت با سرعت ۴۰ کیلومتر بر ساعت و ثبت تصویر در هر ثانیه جمع‌آوری شده‌اند [۷۹].

ژنگ^۳ و همکاران در سال ۲۰۲۱، با استفاده از شبکه عصبی پیش‌بینی به تشخیص خرابی‌های روسازی در مونترال کانادا پرداختند. هدف از این مطالعه، تشخیص خرابی‌های روسازی راه به وسیله یک روش داده‌برداری کم‌هزینه ویدئویی بوده‌است. در این مطالعه، خرابی‌ها به ترک‌های طولی یا خطی، ترک‌های شبکه‌ای، ترک‌های خستگی، چاله‌ها، خرابی‌های محل وصله و علامت‌گذاری روی سطح روسازی تقسیم‌بندی شده‌اند. مجموعه تصاویر در دسترس شامل ۲،۱۰۵ تصویر از دوربین ارزان‌قیمت نصب‌شده بر خودروی در حال حرکت بوده‌است. دقت تشخیص مدل ارائه شده با توجه به تصاویر برداشت‌شده از سطح روسازی‌های مونترال، ۸۳/۸٪ است [۸۰].

گوآن^۴ و همکاران در سال ۲۰۲۱، مطالعه‌ای در راستای تشخیص خودکار خرابی‌های سطح روسازی انجام دادند که خرابی‌ها در سطح پیکسل شناسایی می‌شدند. در این راستا از تصاویر رنگی و الگوریتم‌های یادگیری عمیق، استفاده شد. محیط دانشگاه چانگ آ برای برداشت تصاویر به دلیل جاده‌های آسفالتی و عاری از آلودگی، مناسب تشخیص داده شده‌است. در این مطالعه برداشت تصاویر توسط دوربین نصب‌شده روی خودرو صورت

1. Unet++
2. RDD20
3. Zhang
4. Guan

5. Structure from Movement (SFM)

6. Li

7. T and f tests

۳-۶- پیش‌بینی مقادیر شاخص‌های عملکردی رویه

ترک‌های خستگی، ترک‌های بلوکی، شیار افتادگی، عمر روسازی و بارندگی سالانه، تاثیر زیادی بر شاخص بین‌المللی ناهمواری داشته است. همچنین ترک‌های طولی، ترک‌های لبه و چاله‌ها و صیقلی بودن مصالح تاثیر کمی بر شاخص بین‌المللی ناهمواری داشته است. مدل توسعه داده شده می‌تواند در روش طراحی مکانیکی-تجربی روسازی برای پیش‌بینی غیرخطی شاخص بین‌المللی ناهمواری مورد استفاده قرار گیرد [۸۶].

صولتی‌فر و لواسانی در سال ۲۰۲۰، به پیش‌بینی مدل خرابی روسازی آسفالتی با استفاده از الگوریتم شبکه عصبی مصنوعی پرداختند. معیار مورد نظر شاخص بین‌المللی ناهمواری بوده است. آن‌ها در این مطالعه از پایگاه داده عملکرد بلندمدت روسازی استفاده کردند. اطلاعات برداشت شده متعلق به قطعات GPS-1 و GPS-2 بود. در این مطالعه از الگوریتم شبکه عصبی پس‌انتشار استفاده شده است. در شبکه عصبی توسعه داده شده در راستای پیش‌بینی شاخص بین‌المللی ناهمواری از یک لایه پنهان استفاده شده است. همچنین نتایج حاصل از شبکه عصبی مصنوعی با نتایج مدلسازی رگرسیونی مقایسه شده و مشخص گردید شبکه عصبی دقت بالاتری ارائه داده است [۸۷].

بشار و همکارش در سال ۲۰۲۱، به بررسی روش‌های یادگیری ماشین در راستای پیش‌بینی شاخص ناهمواری سطح راه پرداختند. در این تحقیق، مدل‌های ساخته شده به وسیله الگوریتم‌های شبکه عصبی مصنوعی، جنگل تصادفی و ماشین بردار پشتیبان مورد بررسی قرار گرفت. ۲۰ مطالعه از سال‌های ۲۰۰۱ تا ۲۰۲۰ انتخاب شده و تحلیل جزئیات روی آنها انجام شده است. در نتیجه این مطالعه، روش جنگل تصادفی با دقت ۹۹/۵٪ به عنوان دقیق‌ترین روش شناخته شده است. شبکه‌های عصبی نیز با دقت ۹۳٪ برای طیف وسیعی از نمونه‌ها مناسب بوده است. شبکه عصبی توسعه داده شده در این مطالعه دارای یک لایه پنهان است. دقت مدل بردار پشتیبان در پیش‌بینی ۹۱/۶٪ است. تعداد حداقل نمونه در راستای توسعه مدل پیش‌بینی با دقت مناسب، ۵۰ برابر تعداد متغیر ورودی توصیه شده است [۸۸].

عیسی و همکاران در سال ۲۰۲۱، به پیش‌بینی شاخص وضعیت روسازی با استفاده از شبکه عصبی مصنوعی پرداختند. مدل‌سازی با داده‌های مرتبط با شاخص وضعیت روسازی برای ۳۴۸ قطعه از ۱۰ راه در شهر نابلس فلسطین انجام شده است. در این شبکه عصبی از یک لایه پنهان برای محاسبات استفاده شده است. متغیرهای ورودی این شبکه عصبی، خرابی‌های متعددی مانند انواع ترک خوردگی‌ها، لکه‌گیری‌ها، تغییرات سطحی، شن‌زدگی، قیرزدگی و خرابی‌های مقطعی مانند افتادگی شانه راه هستند. نتایج نشان داد

کاربرد هوش مصنوعی در ارزیابی، پیش‌بینی و برنامه‌ریزی نگهداری و تعمیرات روسازی مورد بررسی قرار گرفته است. ارزیابی وضعیت روسازی و محاسبه شاخص‌های عملکردی آن در راستای اجرای بهسازی اجتناب ناپذیر است. در این راستا استفاده از هوش مصنوعی و روش‌های عددی با هدف کاهش زمان و هزینه لازم مورد توجه محققین بوده است.

فخری و دزفولیان در سال ۲۰۱۹، به ارزیابی سازه روسازی بر اساس شاخص ناهمواری و خرابی سطحی با استفاده از شبکه عصبی پرداخت. در این مطالعه تلاش شد تا بین شاخص بین‌المللی ناهمواری^۱ و شاخص ارزیابی و رتبه‌بندی سطح^۲ با حوضچه خیز حاصل از آزمون نشست‌سنج وزنه‌ای ارتباط معناداری برقرار شود. پایگاه داده این مطالعه از ۳۱۸ قطعه راه از شهرهای کرمانشاه و ایلام در کشور ایران برداشت شده است [۸۴].

کایا^۳ و همکاران در سال ۲۰۲۰، عملکرد روسازی و پیش‌بینی عمر باقی‌مانده سیستم‌های روسازی مرکب و انعطاف‌پذیر را مورد بررسی قرار دادند. در این مطالعه روش‌های آماری و روش‌های مبتنی بر هوش مصنوعی، مقایسه شد. عملکرد روش‌های هوش مصنوعی (شبکه عصبی مصنوعی) در بهترین حالت تا دقت برازش ۹۹/۱٪ و روش‌های آماری تا دقت برازش ۹۶/۶٪ مشاهده شده است. ورودی مدل‌های آماری و شبکه عصبی ساخته شده عبارت است از ضخامت لایه آسفالتی، ترافیک، سن روسازی، شاخص ناهمواری یک و دو ساله روسازی. شاخص بین‌المللی ناهمواری به عنوان خروجی در هر سال مطلوب بوده است. شبکه عصبی ساخته شده دارای یک لایه پنهان در نظر گرفته شده است. در این مطالعه پنج شبکه عصبی برای پیش‌بینی پارامترهای شیارشدگی، ترک‌های طولی، ترک‌های عرضی و شاخص ناهمواری به دو روش ایجاد شده است [۸۵].

گانگ^۴ و همکاران در سال ۲۰۱۸، با استفاده از الگوریتم جنگل تصادفی به پیش‌بینی شاخص بین‌المللی ناهمواری پرداختند. متغیرهای ورودی این مدل شامل خرابی‌های اندازه‌گیری شده، ترافیک، شرایط آب‌وهوایی، شرایط نگهداری و داده‌های سازه روسازی است. مدل جنگل تصادفی به وسیله اطلاعات ۱۱،۰۰۰ نمونه برداشت شده از مجموعه داده عملکرد بلندمدت روسازی توسعه داده شده است. دقت تعیین شاخص بین‌المللی ناهمواری برابر با ۹۵٪ بوده است. نتایج نشان داد که ترک‌های عرضی،

1. International Roughness Index (IRI)
2. Pavement Surface Evaluation and Rating (PASER)
- 3 Kaya
- 4 Gong

می‌تواند منجر به افزایش دقت پیش‌بینی به میزان ۴٪ و ۲۶/۰۸٪، به ترتیب در پیش‌بینی‌های ۱ و ۱۲ ساله بشود [۹۱].

یزدی و دهناد در سال ۲۰۲۵ داده‌های مرتبط با ۶ شاخص و خرابی روسازی شامل متوسط عمق بافت درشت، مساحت ترک خطی، طول ترک خطی، میزان برهنگی سنگدانه، عمق شیارشدگی و همچنین متوسط شاخص بین‌المللی ناهمواری را از مسیر مشخصی در استان قم برداشت نموده و هر شاخص یا متغیر را براساس مجموعه شاخص‌ها یا متغیرهای دیگر پیش‌بینی نمودند. روش حذف بازگشتی ویژگی‌ها^۴ به‌عنوان یکی از تکنیک‌های کاهش ابعاد با هدف حذف ورودی‌های اضافی مدل استفاده شد. به‌کارگیری این روش باعث کاهش پیچیدگی مدل، بهبود تعمیم‌پذیری و جلوگیری از بیش‌برازش^۵ می‌شود. در این راستا از طیف گسترده‌ای از مدل‌های یادگیری ماشین شامل جنگل تصادفی، تقویت گرادیان، رگرسیون بردار پشتیبان، نزدیک‌ترین همسایگی^۶، تقویت شدید گرادیان، ماشین سبک تقویت گرادیان و رگرسیون خطی استفاده شده‌است. بهترین عملکرد توسط مدل جنگل تصادفی به اجرا گذاشته شد مساحت و طول ترک را به ترتیب با ضرایب تعیین ۸۲/۴٪ و ۸۱٪ پیش‌بینی نمود. از نوآوری‌های این پژوهش استفاده از توضیحات افزودنی شپلی (تحلیل شپ) به‌عنوان یکی از تکنیک‌های هوش مصنوعی توضیح‌پذیر^۷ بود. به‌عنوان نمونه تحلیل شپ نشان داد که برهنگی سنگدانه بیشترین تاثیر را از مقادیر متوسط عمق بافت درشت پذیرفته‌است. همچنین نشان داده شد که موثرترین متغیرها در پیش‌بینی متوسط شاخص بین‌المللی ناهمواری، برهنگی سنگدانه‌ها و طول ترک خطی بودند [۹۲].

شهبین^۸ و همکاران در سال ۲۰۲۵ از الگوریتم‌های جنگل تصادفی و تقویت شدید گرادیان برای پیش‌بینی شاخص وضعیت روسازی براساس متغیرهایی از جمله متغیرهای اقلیمی (مانند شاخص انجماد)، زمان (عمر روسازی)، سازه (ضخامت لایه‌ها)، مواد (شاخص پلاستیک و همچنین عبوری از الک ۲۰۰)، ترافیک و وضعیت (متوسط شاخص بین‌المللی ناهمواری و همچنین خرابی‌ها) استفاده کردند. توسعه مدل‌ها مستلزم بهینه‌سازی ابرپارامترهای آن‌ها (مانند بیشینه عمق و تعداد درختان) بود که مقادیر آن‌ها از طریق

که شبکه عصبی مصنوعی توان پیش‌بینی شاخص عملکرد روسازی با دقت بیش از ۹۹٪ را دارد. همچنین مشخص شد که همبستگی کمی بین خرابی و شاخص وضعیت روسازی وجود دارد [۸۹].

قدرت‌آبادی و همکاران در سال ۲۰۲۵، به پیش‌بینی شاخص بین‌المللی ناهمواری با استفاده از مدل‌های جنگل تصادفی و همچنین ماشین بردار پشتیبان با توابع مرکزی خطی، شعاعی و چندجمله‌ای پرداختند. از نوآوری‌های این پژوهش اجرای پیش‌بینی برای مقادیر شاخص در طولانی‌مدت یا همان تغییرات شاخص در طول بازه چندساله و نیز در کوتاه‌مدت یا همان تغییر دفعی شاخص به سبب اجرای عملیات نگهداری بود. ورودی‌های مدل‌های توسعه داده‌شده جهت پیش‌بینی مقدار شاخص بین‌المللی ناهمواری شامل متغیرهای مختلفی بوده‌است، از جمله: عمر روسازی، ترافیک سنگین متوسط سالیانه روزانه، میزان بار هم‌ارز محور منفرد، مقدار اولیه شاخص، میزان بارندگی، دما، رطوبت، شاخص انجماد، ضخامت رویه، ضخامت اساس و ضخامت زیراساس. علاوه، ضخامت روکش‌های نازک و ضخیم و اسلاری سیل نیز در کنار ضخامت تراش رویه به‌عنوان مشخصه‌های واردشده به مدل در نظر گرفته شدند تا مقدار شاخص پس از این عملیات پیش‌بینی شود. از دیگر نوآوری‌های این پژوهش، پس‌بینی تغییرات متغیرهای آب‌وهوایی ورودی مدل با استفاده از روش خودرگرسیونی میانگین متحرک ادغام‌شده فصلی (ساریم) بود. مدل‌های جنگل تصادفی به بالاترین دقت (۸۰٪ - ۹۶٪) دست یافتند [۹۰].

چن^۲ و همکاران در سال ۲۰۲۵ به پیش‌بینی مقدار شاخص بین‌المللی ناهمواری بر اساس مدل شبکه عصبی فیزیک‌آگاه یا مبتنی بر فیزیک^۳ پرداختند. در این نوع شبکه عصبی، از مفاهیم اولیه یا قوانین فیزیک برای آموزش شبکه عصبی استفاده می‌شود. به‌منظور توسعه مدل، ۱،۲۸۷ ردیف داده از پایگاه داده عملکرد بلندمدت روسازی انتخاب گردید که شامل داده‌های ۹۹ قطعه روسازی از ۲۰ ایالت مختلف آمریکا در طی سال‌های ۱۹۹۵ الی ۲۰۰۷ بود. اطلاعات مربوط به سازه، وضعیت رویه، اقلیم، ترافیک، مصالح و پیشینه نگهداری برای توسعه دو مدل شبکه عصبی مصنوعی و شبکه عصبی فیزیک‌آگاه استفاده شد. داده‌های ۸۴ قطعه برای آموزش و صحت‌سنجی و داده‌های ۱۵ قطعه برای تست مدل‌ها انتخاب گردید. مقایسه عملکرد دو مدل نشان داد که بهره‌گیری از مدل ارتقاء‌یافته شبکه عصبی

4. Recursive Feature Elimination (RFE)
5. Overfitting
6. SHapely Additive exPlanations (SHAP)
7. Explainable AI
8. Shaheen
9. Hyperparameter

1. Seasonal AutoRegressive Integrated Moving Average (SARIMA)
2. Chen
3. Physics-Informed or Physics-Guided Neural Network (PINN or PGNN)

رویکردهای مختلف توسعه مدل‌های یادگیری فیزیک‌محور ماشین و نیز با به‌کارگیری قوانین فیزیکی و مدل‌های متنوع انجام شود. بعلاوه نیاز است تاثیر به‌کارگیری قوانین فیزیکی بر میزان عدم قطعیت پیش‌بینی در بازه‌های بلند و کوتاه‌مدت تحلیل شود.

از نوآوری‌های دیگر پژوهش‌های این بخش، استفاده از تکنیک‌های هوش مصنوعی توضیح‌پذیر جهت درک شیوه تصمیم‌گیری مدل یادگیری ماشین و مشخصه‌های مورد توجه قرارگرفته در لایه‌های مختلف آن است. یزدی و دهناد در سال ۲۰۲۵ [۹۲] و شهین و همکاران در سال ۲۰۲۵ [۹۳] از تحلیل شپ به‌ترتیب برای شناسایی عوامل تعیین‌کننده در تخمین شاخص‌های ناهمواری و وضعیت استفاده نمودند که در مورد اول، برهنگی سنگدانه و طول ترک بیشترین تاثیر را داشتند و در مورد دوم، میزان ناهمواری و عمر رویه موثرترین عوامل بودند.

۳-۷- برنامه‌ریزی عملیات نگهداری و بهینه‌سازی آن

مدیریت و نگهداری بهینه‌سازی‌های موجود، یکی از مهم‌ترین مراحل مدیریت روسازی راه است. برنامه‌ریزی و مدیریت نگهداری روسازی به دلیل پارامترهای متعدد و گاه متضاد با هم، در میان ارائه‌دهندگان خدمت و ادارات راهداری امر پیچیده‌ای محسوب می‌شود. الحدیدی و همکاران در سال ۲۰۱۵، در یک مطالعه موردی به بهینه‌سازی عملیات نگهداری و تعمیرات راه‌های کشور مصر با استفاده از الگوریتم ژنتیک دو هدفه پرداختند. هدف اول از توسعه این مدل، حداقل‌سازی هزینه نگهداری و تعمیرات و هدف دوم بهینه‌سازی شرایط خدمت‌رسانی به کاربران راه بوده‌است. در این مطالعه برای پیش‌بینی شرایط آتی روسازی در هر قطعه مورد نظر، از روش زنجیره مارکوف^۴ استفاده شده‌است. بر این اساس شاخص وضعیت روسازی به ۵ گروه در گستره‌های ۱۰-، ۱۰-۴۰، ۴۰-۵۵، ۵۵-۷۰ و ۷۰-۱۰۰ تقسیم‌بندی شده‌است. با هدف سهولت استفاده برای کلیه کاربران، مدل با استفاده از زبان ویژوال بیسیک^۵ کدگذاری شده‌است [۹۵].

باروآ و زو^۶ در سال ۲۰۲۱، برنامه‌ریزی نگهداری و تعمیرات روسازی‌های فرودگاهی با استفاده از روش‌های یادگیری ماشین را مورد مطالعه قرار دادند. معیار نگهداری در نظر گرفته‌شده در این مطالعه شاخص وضعیت روسازی بوده‌است. در این مطالعه، ساخت مدل بر اساس داده‌های واقعی فرودگاه شیکاگو انجام شده‌است. ۱۶۳ قطعه باند پرواز و ۳۷۷ قطعه باند خزش،

روش‌های جستجوی تصادفی^۱، جستجوی شبکه‌ای^۲ و روش بیز حاصل شد. نتایج تست مدل‌ها بر داده‌های پایگاه داده عملکرد بلندمدت روسازی نشان داد که دو مدل تقویت شدید گرادیان و جنگل تصادفی به ترتیب با دقت‌های بالای ۹۲/۳٪ و ۹۱/۲٪ قادر به پیش‌بینی شاخص وضعیت هستند. از آنجایی که ماتریس همبستگی ایجادشده در قالب نقشه حرارتی، نشان‌دهنده وجود همبستگی میان متغیرهای پیش‌بینی‌کننده بود، در این پژوهش نیز از تحلیل شپ با هدف شناسایی و حذف متغیرهای اضافی استفاده شد. برجسته‌ترین متغیرها در پیش‌بینی شاخص عبارت بودند از متوسط شاخص بین‌المللی ناهمواری و عمر روسازی [۹۳].

مطالعات اخیر که دربرگیرنده توسعه مدل‌های پیش‌بینی شاخص‌های عملکردی روسازی بوده‌اند در جدول ۱ با یکدیگر مقایسه شده‌اند. این مقایسه از منظر الگوریتم انتخاب‌شده، متغیرهای پیش‌بینی‌شده و پیش‌بینی‌کننده، تقسیم‌بندی داده‌ها در مدل‌سازی و همچنین دقت مدل انجام گرفته‌است.

تحلیل دقیق‌تر مطالعات این بخش نشان می‌دهد که استفاده از شبکه عصبی فیزیک‌آگاه برای پیش‌بینی عملکرد رویه، از نوآوری‌های تحقیقاتی اعمال‌شده در زمینه مدل‌سازی بوده‌است. به‌طور کلی، یادگیری فیزیک‌محور ماشین^۳ با واردنمودن قوانین فیزیکی به مدل‌های داده‌محور محض، برخی مشکلات مدل از جمله استدلال بر مبنای درک عام و پیروی از محدودیت‌های فیزیکی را مرتفع می‌نماید. بعلاوه، این قوانین باعث می‌شود که مدل قدرت استقراء فراتر از داده‌های ورودی را نیز داشته باشد [۹۴]. روش‌های مختلفی جهت توسعه مدل‌های فیزیک‌آگاه وجود دارد: ۱- تعریف خروجی مدل مبتنی بر فیزیک به‌عنوان ورودی مدل یادگیری ماشین، ۲- اجرای همزمان مدل‌های یادگیری ماشین و فیزیک‌مبنا و متعاقباً اصلاح خطاهای مدل فیزیک‌مبنا، ۳- ایجاد توابع زیان مبتنی بر قوانین فیزیکی، ۴- استفاده از قوانین فیزیکی در تعیین مقادیر اولیه پارامترهای مدل یادگیری ماشین و ۵- طراحی معماری مدل یادگیری ماشین بر مبنای اطلاعات بدست‌آمده از فیزیک. در مطالعه چن و همکاران در سال ۲۰۲۵ [۹۱]، روش‌های ۱ و ۳ جهت توسعه مدل شبکه عصبی پیش‌بینی‌کننده شاخص ناهمواری بین‌المللی استفاده شده‌است. همچنین، قوانین فیزیکی محدود به اطلاعات شبیه‌سازی‌های اجزا محدود و مدل انتخابی نیز محدود به شبکه عصبی بوده‌است. در نتیجه پیشنهاد می‌شود در مطالعات پیش‌رو، پیش‌بینی شاخص‌های عملکردی روسازی با

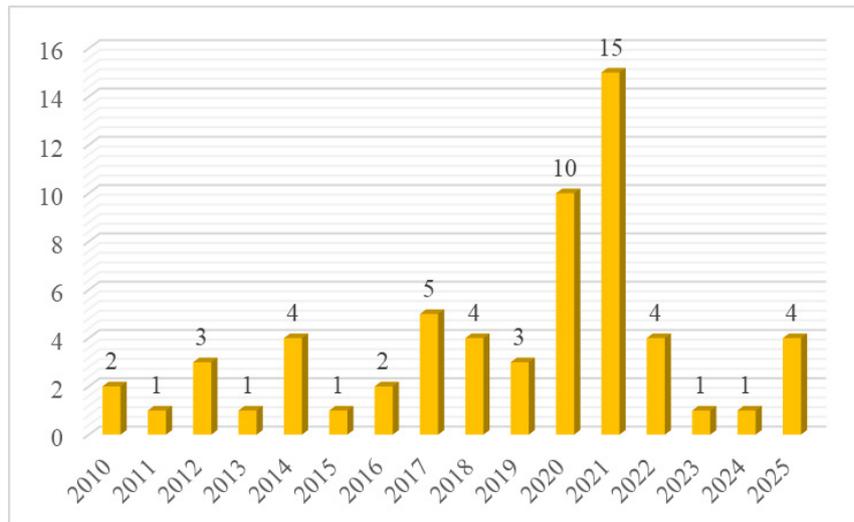
4. Markov Chain
5. Visual basics
6. Barua & Zou

1. Random Search
2. Grid Search
3. Physics-informed Machine Learning

جدول ۱. مقایسه پژوهش‌های اخیر با موضوع پیش‌بینی شاخص‌های عملکرد روسازی با استفاده از الگوریتم‌های یادگیری ماشین.

Table 1. Comparison of the latest models developed for predicting pavement performance indicators using ML algorithms.

مرجع	پایگاه و تعداد داده	مدل یادگیری ماشین	شاخص		متغیرهای پیش‌بینی‌کننده					تقسیم‌بندی داده‌ها	دقت مدل (R^2)	
			IRI	PCI	ترافیک	اقلیم	سازه	مواد	وضعیت و خرابی			تاریخچه نگهداری
[۸۹]	داده‌برداری در نابلس (فلسطین) (۳۸۴ ردیف)	شبکه عصبی مصنوعی	-	✓	-	-	-	-	-	✓	-	۹۹٪/۷۵
[۹۰]	LTPP (۲،۷۰۸)	جنگل تصادفی ماشین بردار پشتیبان	✓	-	✓	✓	✓	✓	-	✓	✓	۹۶٪ ۹۲٪
[۹۱]	LTPP (۱،۲۸۷ ردیف)	شبکه عصبی فیزیک‌آگاه شبکه عصبی مصنوعی	✓	-	✓	✓	✓	✓	✓	✓	✓	۸۸٪/۳۹ ۸۷٪/۸۹
[۹۲]	داده‌برداری در قم (ایران) (۴،۶۸۵ ردیف)	جنگل تصادفی ماشین سبک تقویت گرادیان رگرسیون خطی نزدیک‌ترین همسایگی کی تقویت گرادیان	✓	-	-	-	-	-	-	✓	-	۲۱٪/۳ ۱۴٪/۹ ۶٪/۱۵ ۱۵٪/۲ ۱۹٪/۱۶
[۹۳]	LTPP (۱،۴۹۳ ردیف)	جنگل تصادفی تقویت شدید گرادیان	-	✓	✓	✓	✓	✓	✓	✓	✓	۹۱٪/۲ ۹۲٪/۳



شکل ۵. فراوانی مقالات خارجی منتشرشده در سال‌های مختلف با هدف بهبود راه‌حل‌ها در حوزه مهندسی روسازی با استفاده از هوش مصنوعی.

Fig. 5. The frequency of international articles published annually with the aim of improving pavement engineering solutions using AI

عمق شیارشدگی^۴، شاخص کیفیت رانندگی^۵ و شاخص بازتاب خورشیدی سطح^۶ بوده‌است. در این مطالعه انتخاب روش نگهداری و تعمیرات متناسب با مقایسه هزینه روش‌های مختلف انجام شده‌است. هزینه‌ها با استفاده از الگوریتم بهینه‌سازی سیاست تقریبی^۷ محاسبه شده‌است. روش توسعه داده‌شده در این مطالعه با موفقیت با ۲،۵۰۰ نمونه برداشت‌شده از راه‌های استان جیانگسو کنترل شده‌است [۹۷].

در ادامه، مقالات مرور شده در دسته‌های مختلف به صورت یک‌جا با یکدیگر مقایسه شده‌است تا درک عمیق‌تری از ادبیات موضوع حاصل شود. به منظور ارزیابی میزان رشد استفاده از الگوریتم‌های یادگیری ماشین و شبکه عصبی در ارزیابی یا بهبود عملکرد مخلوط یا رویه آسفالتی، تعداد پژوهش‌هایی که در این زمینه در سال‌های مختلف منتشر شده‌اند، در شکل ۵ نشان داده شده‌است.

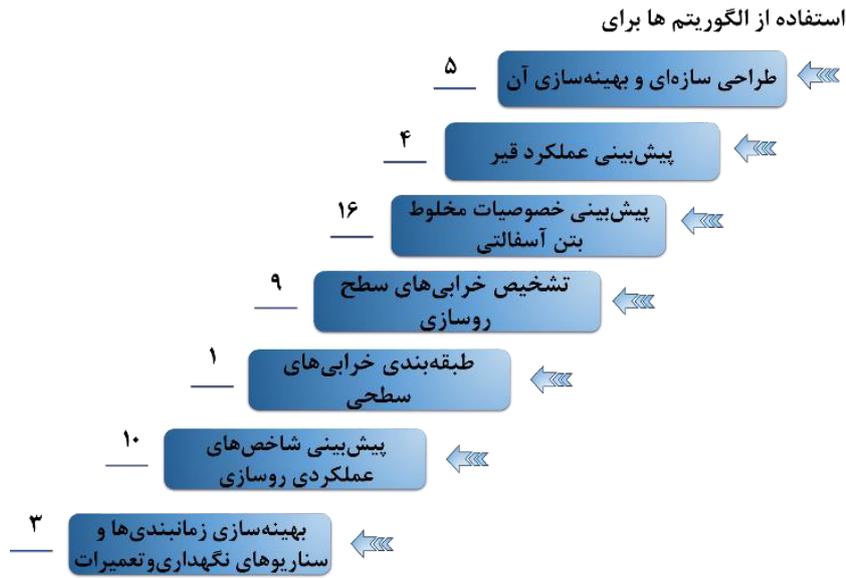
موضوعات کلی پژوهش‌هایی که بهره‌گیری از الگوریتم‌های هوش مصنوعی در مهندسی روسازی را مورد توجه قرار داده‌اند، به همراه فراوانی مطالعات تحلیل‌شده در آن زمینه، در شکل ۶ آورده شده‌است. موضوعات کلی پژوهش‌ها که در شکل ۶ نشان داده شد، با جزئیات

مرجع برداشت مجموعه داده این مطالعه است. در این مدل‌سازی از الگوریتم ماشین تقویت گرادیان^۱ استفاده شده‌است و برای باند خزش و باند پرواز مدل‌های جداگانه‌ای ایجاد شده‌است. پارامترهای ورودی در این مدل، عمر، نوع روسازی، ترافیک، سیکل‌های یخبندان و اقدامات ترمیمی انجام‌شده قبلی در نظر گرفته شده‌است. به منظور آموزش مدل‌ها از روش یادگیری کبوی^۲ استفاده شده‌است. نتایج نشان داد که دقت پیش‌بینی مدل توسعه داده‌شده بیش از ۹۰٪ بوده‌است. روش ارائه‌شده در این پژوهش می‌تواند با دریافت داده‌های ورودی مورد نیاز، یعنی مقادیر شاخص وضعیت روسازی و نیز هزینه واحد عملیات بهسازی، تحلیل‌های اقتصادی را برای برنامه‌های نگهداری و تعمیرات اجرا نماید [۹۶].

هان^۳ و همکاران در سال ۲۰۲۱، به توسعه مدل هوشمند برنامه‌ریزی نگهداری و تعمیرات روسازی‌های آسفالتی پرداختند. دقت مدل یادگیری تقویتی توسعه داده‌شده برابر با ۸۲/۲٪، یعنی ۱۷/۲٪ بالاتر از مدل شبکه عصبی بوده‌است. شبکه عصبی مذکور دارای یک لایه پنهان بوده‌است. ورودی‌های شبکه عصبی توسعه داده‌شده، شاخص وضعیت روسازی، شاخص

4. Rutting Depth Index (RDI)
5. Ride Quality Index (RQI)
6. Solar Reflectance Index (SRI)
7. Proximal Policy Optimization (PPO)

1. Gradient Boosting Machine (GBM)
2. Q-learning
3. Han



شکل ۶. کاربردهای تحلیل‌شده در ادبیات موضوع بهره‌گیری از هوش مصنوعی در مهندسی روسازی و فراوانی آن‌ها.

Fig. 5. Analyzed applications and the associated frequency reviewed in the AI-assisted pavement engineering literature.

پدیده‌هایی مانند آلودگی و کرناسیون مورد توجه قرار نگرفته‌است. سایر موضوعاتی که در ادبیات موضوع بررسی نشده‌است و پیشنهاد می‌شود در مطالعات پیش رو تحلیل شوند عبارتند از: تحلیل یا پیش‌بینی میزان انرژی تولیدشده از روسازی، پیش‌بینی خواص آسفالت‌های رنگی، تحلیل پایگاه‌های داده‌ی متن‌ی جهت تعیین پرمخاطره‌ترین انواع خرابی با استفاده از تکنیک‌های پردازش زبان طبیعی و شناسایی خرابی‌های تبیین‌شده، شناسایی خرابی‌های رویه با رویکرد ترکیب نمودن داده‌ها از حسگرهای مختلف یا ترکیب نمودن نتایج مدل‌های مختلف (که با عنوان هم‌جوشی در سطح داده یا تصمیم‌شناخته می‌شود) و نهایتاً به‌کارگیری الگوریتم‌های یادگیری ماشین جهت توسعه‌ی دوقلوی دیجیتال^۲ روسازی آسفالتی.

۴- مطالعات منتشرشده توسط پژوهشگران ایرانی

در این بخش مطالعات منتشرشده به زبان فارسی به‌صورت مجزا مورد بررسی و ارزیابی قرار گرفته‌است تا رویکردها و دستاوردهایشان با دیگر محققین مشخص شود. مرور آثار پژوهشگران ایرانی با محور استفاده از الگوریتم‌های یادگیری ماشین، علاوه بر روسازی آسفالتی، برای دیگر سازه‌ها و مصالح از جمله بتن یا فولاد نیز انجام شده‌است تا تحلیل جامع‌تری ارائه شود.

1. Data-level or Decision-level Fusion
2. Digital Twin (DT)

دقیق‌تری از هدف آن پژوهش در جدول ۲ آورده شده‌است. مدل‌های مختلف هوش مصنوعی بر اساس فراوانی به‌کارگیری‌شان در جدول ۳ آورده شده‌است. بر این اساس، مدل شبکه‌ی عصبی مصنوعی بیشترین تعداد دفعات استفاده در تحلیل‌ها را داشته‌است (۳۱ مرتبه) که این بیانگر توجه بیشتر به مدل در ادبیات موضوع است و نه عملکرد قوی‌تر. در مراتب بعدی، الگوریتم‌های جنگل تصادفی ماشین بردار پشتیبان مجموعه‌ی مدل‌های مبتنی بر تقویت گرادیان به ترتیب دارای بیشترین فراوانی در تحلیل‌ها بوده‌اند. همچنین مدل‌هایی که کمترین تعداد استفاده در ادبیات موضوع را داشته‌اند، عبارتند از خوشه‌بندی میانگین‌کی، بهینه‌سازی ازدحام ذرات، رگرسیون گاوسی، بهینه‌سازی بیز، ماشین بردار پشتیبان حداقل مربعات، رگرسیون لاسو، گرادیان افزایشی بسته‌بندی، بهینه‌سازی سیاست تقریبی، تقویت شدید گرادیان و رگرسیون (کرنل) ریج (۱ مرتبه).

برخی حوزه‌های پژوهشی که در ادبیات موضوع مورد بررسی قرار نگرفته‌اند در شکل ۷ بیان شده‌اند. تاثیرات زیست‌محیطی روسازی‌های آسفالتی در چرخه‌ی عمر از مهم‌ترین موضوعات پژوهشی روز هستند [۹۸] و [۹۹]. در این زمینه، استفاده از الگوریتم‌های یادگیری ماشین برای ارزیابی

جدول ۲. اهداف جزئی شناسایی شده ذیل موضوعات کلی در پژوهش‌های مبتنی بر یادگیری ماشین در مهندسی روسازی.

Table 2. The detailed goals detected under the general topics in the ML-based analyses in pavement engineering research.

موضوع کلی	موضوع دقیق	موضوع کلی	موضوع دقیق
طراحی سازه ای	پیش‌بینی هزینه ساخت روسازی	موضوع دقیق	پیش‌بینی کرنش تجمعی
	پیش‌بینی بار معادل هم ارز		رابطه بین درصد قیر و مقاومت مارشال
	پیش‌بینی عمر باقی مانده روسازی		پیش‌بینی فرکانس آزمایش‌های خستگی
	طبقه‌بندی ترافیک کامیون‌ها		تخمین عمر خستگی
پیش‌بینی عملکرد قیر	بهینه‌سازی ضخامت از منظر اقتصادی روسازی	خصوصیات نمونه آسفالتی	پیش‌بینی نتایج تست مارشال
	پیش‌بینی ویسکوزیته قیر		پیش‌بینی پاسخ‌های بحرانی روسازی آسفالتی
	تعیین درصد بهینه افزودنی به قیر		توسعه مدل‌های انرژی شکست
خصوصیات مخلوط آسفالتی	چسبندگی قیر		پیش‌بینی عدد روانی مخلوط آسفالتی
	بهینه‌سازی طرح اختلاط آسفالت		پیش‌بینی عمر باقی مانده روسازی
پیش‌بینی با شناسایی خرابی روسازی	مدلسازی خواص آسفالت‌های جاذب صوت		پیش‌بینی مدول سختی
	مدلسازی ترک‌های عرضی روکش روسازی	پیش‌بینی مدول دینامیکی آسفالت و آسفالت ماستیکی	
	پیش‌بینی خستگی روسازی	پیش‌بینی مدول دینامیکی آسفالت و آسفالت ماستیکی	
پیش‌بینی عملکرد روسازی	مدلسازی شیارشدگی و پیش‌بینی عمق شیارشدگی	برنامه‌ریزی نگهداری و تعمیرات	کمیته‌سازی هزینه نگهداری و تعمیرات راه
	شناسایی ترک‌های انعکاسی		برنامه‌ریزی نگهداری و تعمیرات فرودگاهی
پیش‌بینی عملکرد روسازی	پیش‌بینی شاخص بین‌المللی ناهمواری	برنامه‌ریزی نگهداری و تعمیرات	برنامه‌ریزی نگهداری و تعمیرات هوشمند راه
	پیش‌بینی شاخص وضعیت راه		

باتوجه به زمان‌بر بودن و هزینه‌بر بودن فرآیند تولید و کنترل کیفیت مخلوط آسفالتی، حسین‌زاده و همکاران ۱۴۰۲ به توسعه مدل‌های یادگیری ماشین جهت پیش‌بینی مقاومت مارشال پرداختند. در این راستا از نتایج آزمایش ۲،۰۰۰ نمونه آسفالتی در سازمان عمران شهرداری مشهد برای توسعه مدل‌های ماشین بردار پشتیبان و جنگل تصادفی استفاده شد. متغیرهای ورودی مدل شامل دانه‌بندی مصالح، درصد شکستگی مصالح، درصد جذب قیر، وزن مخصوص قیر، وزن مخصوص حقیقی مصالح، درصد قیر مصرفی، نسبت درصد وزنی فیلر به قیر موثر و مقاومت مارشال نمونه بوده‌است. مقادیر ضریب تعیین بدست‌آمده برای مدل‌های ماشین بردار پشتیبان و جنگل تصادفی به ترتیب برابر با ۸۷/۵٪ و ۸۲/۷٪ بوده‌است [۱۰۰].

امینی ۱۴۰۴ تاثیر هم‌افزایی استایرن-بوتادین-استایرن و نانو لوله‌های کربنی را بر رفتار رئولوژیکی قیر بررسی نموده و سپس به توسعه دو مدل یادگیری ماشین جهت پیش‌بینی شاخص شیارشدگی پرداخت. اولین مدلی که بر اساس داده‌های آزمایشگاهی ساخته شد، مدل رگرسیون چندجمله‌ای بود که متغیر وابسته آن مقاومت شیارشدگی بر حسب سوپرپیو و متغیرهای مستقل آن درصد هر یک از افزودنی‌ها و دمای آزمایش بود. در ادامه یک مدل شبکه عصبی با بهره‌گیری از الگوریتم لوبنبرگ-مارکوارت به‌عنوان بهینه‌ساز ساخته شد. به‌منظور دست‌یابی به بالاترین دقت پیش‌بینی، ۲۰ ساختار مختلف برای معماری شبکه عصبی مورد بررسی قرار گرفت که بهترین عملکرد مربوط به ساختاری با ۳ لایه مخفی و به ترتیب ۵، ۱۰ و ۱۵ یاخته عصبی در لایه‌های مخفی اول، دوم و سوم بود. هر دو مدل رگرسیون و شبکه عصبی، به ترتیب با ضرایب تعیین ۹۱/۵٪ و ۹۷/۶٪ با دقت مطلوبی برای پیش‌بینی عملکرد شیارشدگی قیر اصلاح‌شده مورد استفاده قرار گرفتند [۱۰۱].

بهبهانی و همکاران ۱۴۰۰ به بهینه‌سازی برنامه نگهداری و تعمیرات شبکه روسازی با بهره‌گیری از ابزارهای اولویت‌بندی و هوش مصنوعی پرداختند. روش پیشنهادی شامل استفاده از فرآیند سلسله‌مراتبی تحلیل جهت تعیین قطعات روسازی پراهمیت‌تر، برنامه‌ریزی خطی^۱ ریاضی جهت اعمال قیود (محدودیت بودجه، هزینه عملیات نگهداری و تعداد قطعه قابل تعمیر در سال برای متولی راه) و روش استنتاج فازی^۲ جهت تعیین احتمال انتخاب گزینه‌های ترمیم و نگهداری بوده‌است. مطالعه موردی بر اساس داده‌های شبکه‌ای از راه‌های شهر ماهان در استان کرمان انجام شد. عملیات نگهداری

1. Analytical Heirarchical Process (AHP)
2. Linear Programming
3. Fuzzy Inference System (FIS)

جدول ۳. فراوانی استفاده از مدل‌های یادگیری ماشین در تحلیل یا پیش‌بینی عملکرد و وضعیت روسازی.

Table 3. The frequency of ML-based models in prediction or analysis of pavement performance or condition.

فراوانی	الگوریتم	فراوانی	الگوریتم
۱۱	جنگل تصادفی	۳۱	شبکه عصبی مصنوعی
۷	انواع مدل‌های تقویت گرادیان	۸	ماشین بردار پشتیبان
۴	رگرسیون خطی	۷	الگوریتم ژنتیک
۲	نزدیک‌ترین همسایگی کی	۲	رگرسیون مارس
۱	بهینه‌سازی ازدحام ذرات	۱	خوشه بندی میانگین کی
۱	بهینه ساز بیز	۱	رگرسیون گاوسی
۱	الگوریتم جستجوی بهبود یافته حسگر سوسک	۱	ماشین بردار پشتیبان حداقل مربعات
۱	گرادیان افزایشی - بسته بندی	۱	الگوریتم بهینه سازی جغرافیای زیستی
۱	شبکه عصبی فیزیک‌آگاه	۱	بهینه سازی سیاست تقریبی
۱	درخت تصمیم	۱	رگرسیون لاسو
۱	رگرسیون کرنل ریج ^۱	۱	رگرسیون ریج

^۱ Kernel Ridge Regression



شکل ۷. برخی حوزه‌های مهندسی روسازی که از الگوریتم‌های یادگیری ماشین در بهبود آن‌ها استفاده نشده‌است.

Fig. 7. Research topics in pavement engineering for which ML-based models have seldom been used.

زمینه‌های مختلف مهندسی روسازی از جمله بهینه‌سازی طراحی (۱۱٪) از مطالعات)، پیش‌بینی عملکرد قیر (۸٪)، پیش‌بینی خصوصیات مخلوط آسفالتی (۳۳٪)، تشخیص خرابی‌های سطح روسازی (۱۹٪)، طبقه‌بندی خرابی‌های سطح روسازی (۲٪)، پیش‌بینی شاخص‌های عملکردی رویه (۲۱٪) و بهینه‌سازی برنامه عملیات ترمیم‌ونگهداری (۶٪) استفاده شده‌است. یافته‌های این پژوهش نشان می‌دهد ابزارهای سنتی مانند منحنی‌های تجربی و معادلات رگرسیونی ساده که برای ارزیابی و پیش‌بینی خصوصیات و عملکرد روسازی آسفالتی استفاده می‌شدند جای خود را به مدل‌های پیشرفته یادگیری ماشین داده‌اند که دارای قابلیت استخراج الگوهای پیچیده و غیرخطی در فرآیندهای مختلف صنعت قیر و آسفالت هستند. همچنین میتوان گفت در آینده‌ای نزدیک، با تجمع بیشتر داده‌های گردآوری شده و همچنین پیشرفت و توسعه مدل‌های هوش مصنوعی، مسائل پیچیده مرتبط با روسازی راه‌ها با سرعت و دقت بالاتری تجزیه و تحلیل خواهد شد.

با این حال استفاده از الگوریتم‌های یادگیری ماشین چالش‌هایی را نیز به همراه داشته‌است که از جمله آن‌ها می‌توان به نیاز به پایگاه‌های داده گسترده، عدم تعمیم‌پذیری و عدم ارائه معادلات و روابط ریاضی اشاره نمود. لذا پیشنهاد می‌شود در مطالعات آینده، کاربرد الگوریتم‌های هوش مصنوعی در حوزه مهندسی روسازی با رویکردهایی نوین و به‌روز انجام شود. از جمله این رویکردها، استفاده از هوش مصنوعی توضیح‌پذیر است که امکان تفسیر و ادراک تصمیم‌گیری‌های مدل‌ها را فراهم می‌سازد. تحلیل شپ از جمله تکنیک‌های هوش مصنوعی توضیح‌پذیر بود که کاربرد آن در مطالعاتی که اخیراً انتشار یافته‌اند دیده‌شد. به‌خدمت‌گرفتن این تکنیک‌ها کمبودها و خلأهای مدل‌های یادگیری ماشین از جمله عدم ارائه معادلات ریاضی و عملکرد به مثابه جعبه سیاه را پوشش می‌دهد.

از دیگر رویکردهایی که در مطالعات آینده ضروری به نظر می‌رسد، مهندسی و بهینه‌سازی مشخصه‌های ورودی مدل‌هاست. این رویکرد باعث افزایش دقت مدل و جلوگیری از ورود مشخصه‌های اضافی به مدل می‌شود. روش حذف بازگشتی ویژگی‌ها از جمله روش‌های بهینه‌سازی ورودی‌های مدل است که کاربرد آن در پژوهش‌های اخیر در ادبیات موضوع مورد توجه قرار گرفته‌است.

همچنین پیش‌بینی و تحلیل عملکرد روسازی با رویکرد به‌کارگیری دانش و قوانین فیزیک که امروزه در حال تبدیل شدن به یک الگواره نوین جهت ارتقاء مدل‌های یادگیری ماشین است، ضرورت دارد. مطابق با مرور ادبیات، راهبردهای پیشنهادی جهت استفاده از ظرفیت‌های یادگیری

در نظر گرفته‌شده در تحلیل شامل پرکردن ترک، فاگ‌سیل، اسلاری سیل، چپ‌سیل، بازیافت، روکش و بازسازی بود. اولویت‌بندی قطعات روسازی و شاخه‌های موجود در شبکه نیز بر اساس ۴ معیار طبقه‌بندی عملکردی، ترافیک، دسترسی و اهمیت تجاری انجام شد. بهینه‌سازی عملیات نگهداری با استفاده از روش پیشنهادی منجر به استفاده بیشتر از گزینه‌های پیشگیرانه از جمله میکروسرفسینگ در سناریوی بودجه نامحدود و نیز انتخاب گزینه‌های مقرون‌به‌صرفه‌تر مانند فاگ‌سیل در سناریوی بودجه محدود شد [۱۰۲].

قادری و عبدالمالکی ۱۴۰۰ از روش یادگیری بدون نظارت برای شناسایی خودکار آسیب‌های سازه‌های عمرانی بهره گرفتند. الگوریتم به‌کار گرفته‌شده یک شبکه عصبی بدون ناظر متشکل از چند لایه ماشین بولتزمن^۱ بوده‌است. در مطالعه موردی، یک ساختمان ۳۵ طبقه فولادی طراحی گردیده و در برابر دو نوع بار طبیعی، شامل زلزله‌هایی با دامنه کوچک و نیز بار دینامیکی باد قرار داده‌شد. پاسخ‌های سازه سالم (سازه ۱) برای آموزش مدل پیشنهادی مورد استفاده قرار گرفت تا الگوهای معنادار موجود در پاسخ‌ها استخراج شوند. سپس یک زلزله خفیف در مدلسازی کامپیوتری به ساختمان اعمال گردید تا سازه در وضعیت نامعلوم و آسیب‌دیده قرار بگیرد. در ادامه بارهای محیطی اولیه مجدد به ساختمان وارد شد تا پاسخ‌ها ثبت شده و به‌منظور تشخیص آسیب‌دیدگی به مدل شبکه عصبی وارد شود. تفاضل خروجی‌های مدل در حالت آسیب‌دیده و حالت سالم (شاخص سلامت) نشان‌دهنده آسیب‌های وارده به ساختمان بود که حاکی از دقت مطلوب مدل در تعیین آسیب‌دیدگی (حدود ۹۵٪) بود [۱۰۳].

۵- نتیجه‌گیری

هوش مصنوعی، هوشی است که با الگوگرفتن از رفتار انسانی توسط ماشین‌ها، ظهور یافته‌است. با کاربرد دسته‌های مختلف هوش مصنوعی، فرآیندهای تجزیه، تحلیل و تفسیر داده‌ها با دقت بسیار بالایی امکان‌پذیر شده‌است؛ به‌گونه‌ای که امروزه از دو زیرمجموعه هوش مصنوعی، یعنی یادگیری ماشین و یادگیری عمیق، برای خلق سامانه‌هایی استفاده می‌شود که قابلیت استخراج الگوها، تصمیم‌گیری و پیش‌بینی نتایج را بدون دخالت انسان فراهم می‌نمایند. در این تحقیق، کاربردهای هوش مصنوعی در دسته یادگیری ماشین در مهندسی روسازی آسفالتی مورد بررسی قرار گرفته‌است. در این راستا مقالات معتبر منتشرشده با محوریت به‌کارگیری الگوریتم‌های یادگیری ماشین مورد توجه بوده‌است. الگوریتم‌های یادگیری ماشین در

- [5] V. Dignum, Responsible Artificial Intelligence: Designing AI for human values, *ITU Journal: ICT Discoveries*, 1 (2017).
- [6] P. Lu, S. Chen, Y. Zheng, Artificial intelligence in civil engineering, *Mathematical Problems in Engineering*, 1 (2012) 145974.
- [7] Y. Zhang, S. Balochian, P. Agarwal, V. Bhatnagar, O.J. Housheya, Artificial intelligence and its applications, *Mathematical problems in Engineering*, 1 (2014) 840491.
- [8] R. Cioffi, M. Travaglioni, G. Piscitelli, A. Petrillo, F. De Felice, Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions, *Sustainability*, 12(2) (2020) 492.
- [9] M. Abambres, A. Ferreira, Application of ANN in Pavement Engineering: State-of-Art, (2017).
- [10] B. Ghorbania, A. Arulrajaha, G. Narsiliob, S. Horpibulsuk, Experimental and ANN analysis of temperature effects on the permanent deformation properties of demolition wastes, *Transportation Geotechnics*, 24 (2020) 100365.
- [11] K. Kersting, Machine learning and artificial intelligence: two fellow travelers on the quest for intelligent behavior in machines, *Frontiers in big Data*, 1 (2018) 6-10.
- [12] M.I. Jordan, T.M. Mitchell, Machine learning: trends, perspectives, and prospects, *Science*, 349 (2015) 255–260.
- [13] T. Xu, F. Zhu, E.K. Wong, Y. Fang, Dual many-to-one-encoder-based transfer learning for cross-dataset human action recognition, *Image and Vision Computing*, 55(2) (2016) 127–137.
- [14] E.P. Ijjina, K.M. Chalavadi, Human action recognition using genetic algorithms and convolutional neural networks, *Pattern Recognition*, 59 (2016) 199–212.
- [15] 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.
- [16] Z. Du, J. Yuan, F. Xiao, C. Hettiarachchi, Application of image technology on pavement distress detection: A review, *Measurement*, 184 (2021) 109900.
- [17] J. Bryce, S. Brodie, T. Parry, D.L. Presti, A systematic

فیزیک‌محور ماشین عبارتند از: ارزیابی قوانین فیزیکی مختلف و روش‌های ادغام آن‌ها با مدل‌های یادگیری ماشین و نیز تحلیل تاثیر آن بر دقت و میزان عدم قطعیت پیش‌بینی، توسعه مدل‌های یادگیری فیزیک‌محور ماشین با الگوریتم‌های بررسی‌نشده در این زمینه، از جمله ماشین بردار پشتیبان و جنگل تصادفی و همچنین پیش‌بینی سایر شاخص‌های عملکردی روسازی از جمله شاخص وضعیت و شیارشدگی.

در نهایت به‌منظور افزایش دقت پیش‌بینی مدل‌های مورد نیاز در صنعت روسازی، پیشنهاد می‌شود الگوریتم‌های پیشرفته یادگیری عمیق برای اهدافی که در مرور ادبیات شناسایی شدند استفاده شوند. شایان ذکر است مدل‌های یادگیری عمیق با بهره‌گیری از تعداد لایه‌های بیشتر و لایه‌های کاملاً پیچشی در انجام محاسبات، دقت‌های بالاتری را نسبت به الگوریتم‌های یادگیری ماشین ارائه نموده و همچنین تحلیل انواع دیگری از داده از جمله داده‌های تصویری و سری زمانی را نیز ممکن می‌سازند.

در بخش پایانی این مقاله، پژوهش‌های منتشرشده به زبان فارسی نیز ارزیابی شدند تا رویکردها و فراوانی مطالعات محققین با مطالعات بین‌المللی مقایسه شود. باتوجه به گستره محدود مطالعات موجود، پیشنهاد می‌شود مدل‌های بیشتر و دقیق‌تری با بهره‌گیری از داده‌های آزمایشگاهی معتبر جهت پیش‌بینی خصوصیات قیر و مخلوط آسفالتی توسعه داده شود. همچنین پیشنهاد می‌شود از داده‌های برداشت‌شده از شبکه گسترده راه‌های کشور، شامل شدت و وسعت خرابی‌ها، مقادیر شاخص‌های بین‌المللی ناهمواری، وضعیت روسازی و نیز دیگر مشخصه‌های خدمت‌دهی روسازی برای توسعه مدل‌های پیش‌بینی سطح خدمت‌دهی روسازی و مدل‌های تشخیص خودکار خرابی استفاده شود.

منابع

- [1] D. Berrar, N. Sato, A. Schuster, Quo vadis, artificial intelligence?, *Advances in Artificial Intelligence*, 2010(1) (2010) 629869.
- [2] L. Morgenstern, and S.A. McIlraith, John McCarthy's legacy, *Artificial Intelligence*, 175(1) (2011) 1-24.
- [3] Y. Xu, X. Liu, X. Cao, C. Huang, E. Liu, S. Qian, X. Liu, Y. Wu, F. Dong, C.-W. Qiu, J. Qiu, K. Hua, W. Su, J. Wu, H. Xu, Artificial intelligence: A powerful paradigm for scientific research, *The Innovation*, 2(4) (2021).
- [4]- G. Tecuci, Artificial Intelligence, *WIREs Computational Statistics*, 4(2) (2012) 168-180.

- Guo, Y.-C. Cao, and S. Cheng. Artificial Intelligence to Power the Future of Materials Science and Engineering. Published by WILEY-VCH Verlag GmbH & Co. KGaA, Weinheim.
- [28] Y. Duan, J.S. Edwards, Y.K. Dwivedi, Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda, *International Journal of Information Management*, 48 (2019) 63-71.
- [29] S. Moulodi, H. Rahmanpanah, S. Gohari, C. Burvill, K.M. Tse, H.M.S. Davies, What can artificial intelligence and machine learning tell us? A review of applications to equine biomechanical research, *Journal of the Mechanical Behavior of Biomedical Materials*, 123 (2021) 104728.
- [30] F. Yang, X. Zhang, Z. Yu, Human-machine collaborative learning for streaming data-driven scenarios. *Sensors*, 25(21) (2025) 6505.
- [31] K. Razzaq, and M. Shah, Machine learning and deep learning paradigms: From techniques to practical applications and research frontiers, *Computers*, 14(3) (2025) 93.
- [32] M.H.M., Noor, A.O. Ige, A survey on state-of-the-art deep learning applications and challenges, *Engineering Applications of Artificial Intelligence*, 159 (2025) 111225.
- [33] I.H. Sarker, Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions, *SN computer science*, 2(6) (2021) 1-20.
- [34] M. Soori, B. Arezoo, R. Dastres, Artificial intelligence, machine learning and deep learning in advanced robotics, a review, *Cognitive Robotics*, 3 (2023) 54-70.
- [35] A.L. Fradkov, Early history of machine learning, *IFAC-Papers OnLine*, 53(2) (2020) 1385-1390.
- [36] H.S. Greenwald, C.K. Oertel, Future directions in machine learning, *Frontiers in Robotics and AI*, 3 (2017) 79.
- [37] K. Rajan, Materials informatics, *Materials Today*, 8(10) (2005) 38-45.
- [38] D. Wang, H. He, D. Liu, Adaptive critic nonlinear robust control: a survey, *IEEE transactions on cybernetics*, 47(10) (2017) 3429-3451.
- assessment of road pavement sustainability through a review of rating tools, *Resources, Conservation and Recycling*, 120 (2017) 108-118.
- [18] X. Yang, J. Guan, L. Ding, Z. You, V.C. Lee, M.R.M. Hasan, X. Cheng, Research and applications of artificial neural network in pavement engineering: A state-of-the-art review, *Journal of Traffic and Transportation Engineering (English Edition)*, 8(6) (2021) 1000-1021.
- [19] N. Sholevar, A. Golroo, S.R. Esfahani, Machine learning techniques for pavement condition evaluation. *Automation in Construction*, 136 (2021) 104190.
- [20] T.B.J. Coenen, A. Golroo, A review on automated pavement distress detection methods, *Cogent Engineering*, 4(1) (2017) 1374822.
- [21] Y. Xu, Z. Zhang, Review of applications of artificial intelligence algorithms in pavement management. *Journal of Transportation Engineering, Part B: Pavements*, 148(3) (2022) 03122001.
- [22] S. Cano-Ortiz, P. Pascual-Muñoz, D. Castro-Fresno, Machine learning algorithms for monitoring pavement performance. *Automation in Construction*, 139 (2022) 104309.
- [23] J. Kang, P. Tavassoti, M.N.A.R. Chaudhry, H. Baaj, M. Ghafurian, Artificial intelligence techniques for pavement performance prediction: a systematic review, *Road Materials and Pavement Design*, 26(3) (2025) 497-522.
- [24] M. Abambres, A. Ferreira, Application of ANN in pavement engineering: State-of-Art. *Authorea Preprints*, (2017).
- [25] X. Yang, J. Guan, L. Ding, Z. You, V.C. Lee, M.R.M. Hasan, X. Cheng, Research and applications of artificial neural network in pavement engineering: a state-of-the-art review, *Journal of Traffic and Transportation Engineering (English Edition)*, 8(6) (2021) 1000-1021.
- [26] Y. Wang, J. Li, X. Zhang, Y. Yao, Y. Peng, Recent Development in Intelligent Compaction for Asphalt Pavement Construction: Leveraging Smart Sensors and Machine Learning, *Sensors*, 24(9) (2024) 2777.
- [27] W. Sha, Y. Guo, Q. Yuan, S. Tang, X. Zhang, S. Lu, X.

- Durham. Machine learning of Truck Traffic Classification groups from Weigh-in-Motion data, *Machine Learning with Applications*, 6 (2021) 100178.
- [50] M. Tohidi, N. Khayat, A. Telvari, The use of intelligent search algorithms in the cost optimization of road pavement thickness design, *Ain Shams Engineering Journal*, 13 (2022) 101596.
- [51] F. Xiao, B.J. Putman, S.N. Amirkhani, Viscosity prediction of CRM binders using artificial neural network approach, *International Journal of Pavement Engineering*, 12(5) (2011) 485–495.
- [52] A.S. Hosseini, P. Hajikarimi, M. Gandomi, F. Moghadas Nejad, A.H. Gandomi, Optimized machine learning approaches for the prediction of viscoelastic behavior of modified asphalt binders, *Construction and Building Materials*, 299 (2021) 124264.
- [53] M. Arifuzzaman, M.A. Gul, K. Khan and S.M.Z. Hossain, Application of Artificial Intelligence (AI) for Sustainable Highway and Road System, *Symmetry*, 13(60) 2021.
- [54] R.H. Riyad, R. Jaiswal, I.B. Muhit, J. Shen, Optimizing modified asphalt binder performance at high and intermediate temperatures using experimental and machine learning approaches, *Construction and Building Materials*, 449 (2024) 138350.
- [55] S. Tapkın, A. Cevik, Ü. Usar. Accumulated strain prediction of polypropylene modified marshall specimens in repeated creep test using artificial neural networks, *Expert Systems with Applications*, 36 (2009) 11186–11197.
- [56] M. Saffarzadeh, A. Heidaripناه. Effect of Asphalt Content on the Marshall Stability of Asphalt Concrete Using Artificial Neural Networks, *Scientia Iranica*, 16(1) (2009).
- [57] A.R. Ghanizadeh and M. Fakhri, Prediction of Frequency for Simulation of Asphalt Mix Fatigue Tests Using MARS and ANN, *The Scientific World Journal*, 1 (2014) 515467.
- [58] S. Tapkın, Estimation of Fatigue Lives of Fly Ash Modified Dense Bituminous Mixtures Based on Artificial
- [39] M. Nikzad, K. Movagharnejad, F. Talebnia, Comparative study between neural network model and mathematical models for prediction of glucose concentration during enzymatic hydrolysis, *International Journal of Computer Applications*, 56(1) (2012).
- [40] M. Lazarevska, M. Knezevic, M. Cvetkovska, A. Trombeva-Gavriloska, Application of artificial neural networks in civil engineering, *Tehnički vjesnik*, 21(6) (2014) 1353-1359.
- [41] A.M. Mosa, R.A.O.K Rahmat, A. Ismail, M.R. Taha. Expert system to control construction problems in flexible pavements, *Computer-Aided Civil and Infrastructure Engineering*, 28(4) (2013) 307-323.
- [42] A. Kurian, E. Sunildutt, Artificial Neural Networks in Pavement Engineering: A Recent Review, *AIJR Proceedings*, (2021) 553-558.
- [43] V.S. Dave, K. Dutta, Neural network-based models for software effort estimation: a review, *Artificial Intelligence Review*, 42(2) (2014) 295-307.
- [44] R. Bala, D.D. Kumar, Classification using ANN: A review, *International Journal of Computational Intelligence Research*, 13(7) (2017) 1811–1820.
- [45] B.O. Antwi, B.O. Adelokun, A.O. Eziefula. Transforming financial reporting with AI: Enhancing accuracy and timeliness, *International Journal of Advanced Economics*, 6(6) (2024) 205-223.
- [46] J. He, Z. Qi, W. Hang, C. Zhao, M. King, Predicting freeway pavement construction cost using a back-propagation neural network: A case study in Henan, China, *The Baltic Journal of Road and Bridge Engineering*, 9(1) (2014) 66-76.
- [47] M. Tiğdemir, Re-evaluation of the AASHTO-flexible pavement design equation with neural network modeling, *PloS one*, 9(11) (2014) e113226.
- [48] A. Qadir, U. Gazder, K.U.N Choudhary, Artificial neural network models for performance design of asphalt pavements reinforced with geosynthetics, *Transportation Research Record*, 2674(8) (2020) 319-326.
- [49] N. Tahaei, J.J. Yang, M.G. Chorzepa, S.S. Kim, S.A.

- A bird's-eye view, *Journal of Modern Transportation*, 19(2) (2011) 114-133.
- [68] J. Huang, G.S. Kumar, Y. Sun, Evaluation of workability and mechanical properties of asphalt binder and mixture modified with waste toner, *Construction and Building Materials*, 276 (2021) 122230.
- [69] J. Huang, G.S. Kumar, J. Ren, J. Zhang, Y. Sun, Accurately predicting dynamic modulus of asphalt mixtures in low temperature regions using hybrid artificial intelligence model, *Construction and Building Materials*, 297 (2021) 123655.
- [70] X. Zhang, F. Otto, M. Oeser, Pavement moduli back-calculation using artificial neural network and genetic algorithms, *Construction and Building Materials*, 287 (2021) 123026.
- [71] A. Behnood, E.M. Golafshani, Predicting the dynamic modulus of asphalt mixture using machine learning techniques: An application of multi biogeography-based programming, *Construction and Building Materials*, 266 (2021) 120983.
- [72] S. Rahman, A. Bhasin, A. Smit. Exploring the use of machine learning to predict metrics related to asphalt mixture performance, *Construction and Building Materials*, 295 (2021) 123585.
- [73] S. Ghafari, M. Ehsani, F. Moghadas Nejad, Prediction of low-temperature fracture resistance curves of unmodified and crumb rubber modified hot mix asphalt mixtures using a machine learning approach, *Construction and Building Materials*, 314 (2022) 125332.
- [74] X. Wang, P. Pan, J. Li, Real-time measurement on dynamic temperature variation of asphalt pavement using machine learning, *Measurement*, 207 112413.
- [75] Z. Tong, D. Yuan, J. Gao, Y. Wei, H. Dou, Pavement-distress detection using ground-penetrating radar and network in networks, *Construction and Building Materials*, 233 (2020) 117352.
- [76] Q. Mei, M. Gül. A cost-effective solution for pavement crack inspection using cameras and deep neural networks, *Construction and Building Materials*, 256 (2020) 119397.
- Neural Networks, *Materials Research*, 17(2) (2014) 316-325.
- [59] S. Khuntia, A.K. Das, M. Mohanty, M. Panda, Prediction of Marshall Parameters of Modified Bituminous Mixtures Using Artificial Intelligence Techniques, *Transportation Science and Technology*, 3(3) (2014) 211-227.
- [60] A.R. Ghanizadeh, Application of Support Vector Machine Regression for Predicting Critical Responses of Flexible Pavements, *International Journal of Transportation Engineering*, 4(4) (2017) 305-315.
- [61] H. Majidifard, B. Jahangiri, W.G. Buttlar, A.H. Alavi, New machine learning-based prediction models for fracture energy of asphalt mixtures, *Measurement*, 135 (2019) 438–451.
- [62] T.-H. Le, H.-L. Nguyen, B.T. Pham, M.H. Nguyen, C.-T. Pham, N.-L. Nguyen, T.-T. Le, H.-B. Ly, Artificial Intelligence-Based Model for the Prediction of Dynamic Modulus of Stone Mastic Asphalt, *Applied Sciences*, 10(15) (2020) 5242.
- [63] A.R. Ghanizadeh, F.S. Jahanshahi, V. Khalifeh, F. Jalali, Predicting Flow Number of Asphalt Mixtures Based on the Marshall Mix design Parameters Using Multivariate Adaptive Regression Spline (MARS), *International Journal of Transportation Engineering*, 7(4) (2020) 433-448.
- [64] N.T. Tran, O. Takahashi, Evaluating the rutting resistance of wearing course mixtures with different fine aggregate sources using the indirect tensile strength test, *Journal of Testing and Evaluation*, 48(4) (2020) 2865-2879.
- [65] M.A. Abed, Z.N.M. Taki, A.H. Abed, Artificial neural network modeling of the modified hot mix asphalt stiffness using Bending Beam Rheometer. *Materials Today: Proceedings*, 42 (2021) 2584–258.
- [66] L.T. Glover, J. Mallela, Guidelines for Implementing NCHRP 1-37A ME Design Procedures in Ohio: Volume 4—MEPDG Models Validation & Recalibration, No. FHWA/OH-2009/9D, Ohio Department of Transportation, 2009.
- [67] Q. Li, D.X. Xiao, K.C. Wang, K.D. Hall, Y. Qiu, Mechanistic-empirical pavement design guide (mepdg):

- [86] H. Gong, Y. Sun, X. Shu, B. Huang, Use of random forests regression for predicting IRI of asphalt pavements, *Construction and Building Materials*, 189 (2018) 890–897.
- [87] N. Solatifar, S.M. Lavasani, Development of An Artificial Neural Network Model for Asphalt Pavement Deterioration Using LTPP Data, *Journal of Rehabilitation in Civil Engineering*, 8(1) (2020) 121-132.
- [88] M.Z. Bashar, C. Torres-Machi, Performance of Machine Learning Algorithms in Predicting the Pavement International Roughness Index, *Transportation Research Record*, 2675(5) (2021) 226-237.
- [89] A. Issa, H. Samaneh, M. Ghanim, Predicting pavement condition index using artificial neural networks approach, *Ain Shams Engineering Journal*, 13(1) (2022) 101490.
- [90] M. Ghodratabadi, A. Golroo, M.S. Entezari, Machine learning for predicting pavement roughness and optimising maintenance, *Road Materials and Pavement Design*, (2025) 1-20.
- [91] K. Chen, M.E. Torbaghan, N. Thom, A. Faramarzi, Physics-guided neural network for predicting international roughness index on flexible pavements considering accuracy, uncertainty and stability, *Engineering Applications of Artificial Intelligence*, 142 (2025) 109922.
- [92] A. Yazdi, M.H. Dehnad, A Case Study on Predicting Asphalt Pavement Distress Using Advanced Machine Learning Techniques and Road Surface Inspection Data, *Case Studies in Construction Materials*, (2025) e05291.
- [93] M. Shaheen, R.A. Elsayed, H. Ghazoly, W.A. Bekheet, Explainable and economical AI-based approach for PCI assessment, *International Journal of Pavement Engineering*, 26(1) (2025) 2531195.
- [94] Y. Wu, B. Sicard, S.A. Gadsden, Physics-informed machine learning: A comprehensive review on applications in anomaly detection and condition monitoring, *Expert Systems with Applications*, 255 (2024) 124678.
- [95] A.A. Elhadidy, E.E. Elbeltagi, M.A. Ammar, Optimum analysis of pavement maintenance using multi-objective
- [77] J. Gao, D. Yuan, Z. Tong, J. Yang, D. Yu, Autonomous pavement distress detection using ground penetrating radar and region-based deep learning, *Measurement* 164 (2020) 108077.
- [78] H.-C., Dan, G.-W. Bai, Z.-H. Zhu, Application of deep learning-based image recognition technology to asphalt–aggregate mixtures: Methodology, *Construction and Building Materials*, 297 (2021) 123770.
- [79] D. Arya, H. Maeda, S.K. Ghosh, D. Toshniwal, Y. Sekimoto, An annotated image dataset for automatic road damage detection using deep learning, *Data in Brief*, 36 (2021) 107133.
- [80] C. Zhang, E. Nateghinia, L.F. Miranda-Moreno, L. Sun, Pavement distress detection using convolutional neural network (CNN): A case study in Montreal, Canada, *International Journal of Transportation Science and Technology*, 11(2) (2022) 298-309.
- [81] J. Guan, X. Yang, L. Ding, X. Cheng, V.C.S. Lee, C. Jin, Automated pixel-level pavement distress detection based on stereo vision and deep learning, *Automation in Construction*, 129 (2021) 103788.
- [82] M. Ehsani, F. Moghadas Nejad, P. Hajikarimi, Developing an optimized faulting prediction model in Jointed Plain Concrete Pavement using artificial neural networks and random forest methods, *International journal of pavement engineering*, 24(2) (2023) 2057975.
- [83] B. Li, K.C.P. Wang, A. Zhang, Y. Fei, Automatic Segmentation and Enhancement of Pavement Cracks Based on 3D Pavement Images. *Journal of Advanced Transportation*, 1 (2019) 1813763.
- [84] M. Fakhri, R.S. Dezfoulian, Pavement structural evaluation based on roughness and surface distress survey using neural network model, *Construction and Building Materials*, 204 (2019) 768–780.
- [85] O. Kaya, H. Ceylan, S. Kim, D. Waid, and B.P. Moore, Statistics and Artificial Intelligence-Based Pavement Performance and Remaining Service Life Prediction Models for Flexible and Composite Pavement Systems, *Transportation Research Record*, 2674(10) (2020) 448-460.

- [100] H. Hosseinzadeh, A. Hasani, S. Arman, A.S. Hejazi, Predicting Marshall Asphalt Stability Using Supervised Machine Learning Algorithms, support vector machine and random forest, *Journal of Transportation Research*, 20(3) (2023) 249-262 (in Persian).
- [101] A. Amini, Presenting Predictive Models of Rheological Characteristics of Modified Bitumens Containing SBS and Carbon Nanotubes Using Nonlinear Regression and Neural Network, *Journal of Transportation Research*, 22(3) (2025) 373-384 (in Persian).
- [102] H. Behbahani, N. Nadimi, M. Khaleghi, Introducing a New Method for the Pavements' Maintenance and Rehabilitation Planning, *Amirkabir Journal of Civil Engineering*, 53(7) (2021) 2801-2820 (in Persian).
- [103] P. Ghaderi, A. Abdolmaaleki, A novel unsupervised deep neural network-based method for damage detection in civil structures, *Modarres Civil Engineering Journal*, 22(1) (2022) 143-159 (in Persian).
- genetic algorithms, *HBRC Journal*, 11(1) (2015) 107–113.
- [96] L. Barua, B. Zou, Planning maintenance and rehabilitation activities for airport pavements: A combined supervised machine learning and reinforcement learning approach, *International Journal of Transportation Science and Technology*, 11(2) (2022) 423-435.
- [97] C. Han, T. Ma, S. Chen, Asphalt pavement maintenance plans intelligent decision model based on reinforcement learning algorithm, *Construction and Building Materials*, 299 (2021) 124278.
- [98] M.S. Entezari, R. Tanzadeh, F. Moghadas Nejad, Economic, Environmental, and Social Assessment of Concrete Pavement Life Cycle: A Literature Review, *Sharif Journal of Civil Engineering*, 41(1) (2025) 110-129.
- [99] M.M. Dadaei, P. Hajikarimi, F. Moghadas Nejad, Sustainable prospective proposals for utilizing modifiers in bitumen industry to address global warming, *Scientific Reports*, 15(1) (2025) 17042.

چگونه به این مقاله ارجاع دهیم

M. M. Dadaei, M. S. Entezari, R. Tanzadeh, F. Moghadas Nejad, A Review of the Applications of Machine Learning in Asphalt Pavement Engineering, Amirkabir J. Civil Eng., 57(10) (2026) 1839-1872.

DOI: [10.22060/ceej.2026.23492.8175](https://doi.org/10.22060/ceej.2026.23492.8175)



