



Faulting Prediction Model in Jointed Plain Concrete Pavement and determining the parameters affecting this failure with Artificial Neural Networks

M. Ehsani, F. Moghadas Nejad*, P. Hajikarimi

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

ABSTRACT: Faulting is one of the most common functional failures in concrete pavements. Pavement design and pavement management systems can both benefit from predicting this failure. Therefore, predicting this failure can be very useful. Artificial neural networks, a powerful technique, were utilized in this study to predict this failure. The artificial neural network architecture was first determined by trial and error using 32 input variables such as traffic, weather, and structural data, and then the defined architecture was appropriately trained. New input factors that have not been explored before, such as Poisson's ratio and elastic modulus of concrete slabs, have been considered among these 32 variables, in addition to the variables utilized in earlier studies. After that, 19 input variables were discovered using a new method, and a new neural network model with 19 variables was created. Notably, the feature selection method used in this study has been developed using the metaheuristic optimization algorithm. For the model with 32 variables and 19 variables, the correlation coefficient, mean square error, and mean absolute error are 0.97, 0.45, 0.43, 0.95, 0.54, and 0.6, respectively. Random forest is recognized in data mining as a powerful technique for identifying the importance of input variables. Finally, the importance of 19 variables was assessed using the random forest approach, with the four most important variables being the yearly cumulative number of days with precipitation more than 12.7 mm (24%), elastic modulus (14%), pavement life (12%), and base thickness (10%). It is found that elastic modulus is an essential input factor that has not been considered in prior studies.

Review History:

Received: Dec. 21, 2020

Revised: Feb. 11, 2021

Accepted: Nov. 27, 2021

Available Online: Dec. 20, 2021

Keywords:

Jointed Plain Concrete Pavement (JPCP)

Faulting Failure

Artificial Neural Networks (ANN)

Feature Selection

Machine Learning

1- Introduction

The most popular type of rigid pavement is Jointed Plain Concrete Pavement (JPCP) [1]. Multiple factors such as traffic loading, severe weather conditions, pavement materials qualities, and pavement structure design cause various distress such as faulting in JPCP over time. The variation in height across a transverse joint is known as faulting. One of the most severe structural problems of JPCP is faulting [2]. Pavement maintenance must be done at the right time. In the pavement management system (PMS), timing is crucial since late maintenance may quadruple the entire cost. To avoid a threefold rise in costs, on-time maintenance operations necessitate accurate forecasting of the number of distinct distresses at any given stage [3]. As a result, developing failure prediction models, such as faulting distress, is critical for making Maintenance and Rehabilitation (M&R) technique decisions and estimating pavement life.

Artificial intelligence (machine learning) has been used to solve pavement engineering problems in recent years. Saghafi et al. [4] projected faulting by considering several input factors such as age, base type, base thickness,

erodibility class, percent passing sieve #4 and #200 for base materials, and resilience modulus of the base layer. They employed multivariate linear regression (MLR) and artificial neural networks (ANNs) to anticipate faulting, which yielded R^2 values of 0.51 and 0.94, respectively. Wang and Tsai [5] looked at many factors, including cumulative ESAL, age, etc. They partitioned the variables into four groups and used the ANNs approach to create four models. Their overall model (which included all variables) showed more minor error than the other three, but none of their models were very accurate.

This research aim is to use the ANN approach to forecast faulting failure. Initially, 32 input factors that impact are chosen from the authors' and literature's perspectives, and a general prediction model is built. The feature selection problem was then handled using the metaheuristic optimization approach, and 19 factors causing this failure were found. The 19 variables introduced are used to create a new prediction model. Finally, the Random Forest approach is used to discover crucial factors of this failure.

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



2- Methodology

133 Jointed Plain Concrete Pavement (JPCP) sections were selected from the long-term pavement performance (LTPP), and the amount of faulting failure was extracted over time. The faulting variable is used as the response variable in this study. Input variables have been considered in this study, which includes: Base thickness multiplied by resilient modulus (BM), base and drainage type (BND, DRG, and DRGT), mean transverse joint spacing (JSP), slab, base, and subbase thickness (STH, BTH, and SBTH), dowel (DWL), Poisson’s ratio (PR), elasticity modulus (EM), tensile strength (TS), and compressive strength of concrete slab (CS), cumulative and annual average ESALs (CESAL and ESAL), age (ND), climate zone (WNF, DNF, FT, and DF), cumulative and annual average freeze-thaw (FT and CFT), cumulative and annual average number of days when the temperature is higher than 32 degrees of centigrade (D32 and CD32), cumulative and annual average number of days when the precipitation is more than 12.7 and 0.25 mm (CINT and INT), cumulative and mean freezing index (CFI and FI), and cumulative and annual average precipitation (CPRC and PRC). The data are divided into training (70%), validation (15%), and test (15%) sections to develop the prediction models.

ANNs are one of the most helpful and efficient machine learning technologies accessible. According to the nature of the problem, this tool is known as a machine learning approach for predicting output(s) in regression problems. ANNs inspired by the human brain can accurately model a wide range of very complicated nonlinear problems [6]. The general model is developed with 32 input variables and determines the best architecture for ANN. Variables impacting faulting failure should be discovered to design a basic and forecasting model. For this purpose, a combination of NSGA II optimization method and ANN technique has been used. This study employed two objective functions to choose the attributes that have the greatest influence on faulting failure. The first objective function (F1) seeks to reduce the number of input variables, while the second seeks to reduce the ANN error (F2). This problem was solved using an integer optimization problem. There were 32 decision factors (equal to the total number of input variables). Each choice variable can have a value of zero or one as the solution in this issue. “Zero” indicates that the variable is not chosen, whereas “One” indicates that it is significant. A simple model is designed to predict faulting with selected variables after determining the features affecting faulting. Random Forest (RF) is one of the machine learning ensemble techniques that can determine the importance of input variables [7]. This research determined the importance of the selected variables from the feature selection problem using the RF method.

Finally, the accuracy and inaccuracy of the created models may be assessed using a variety of statistical measures. To evaluate each model constructed in this work, the R-squared (R2) and mean absolute error (MAE) were utilized. Eqs. (1) and (2) show how mean absolute error (MAE) and R-squared (R2) calculate to evaluate models [8].

$$MAE = \frac{1}{n} \sum_{i=1}^n (|T_i - \bar{T}_i|) \tag{1}$$

$$R^2 = \frac{\left(\frac{\sum_{i=1}^n (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \tag{1}$$

Where T is the target value (measured), P is the predicted value, \bar{T} is the average value of the target data, \bar{P} is the average of the data predicted by the model, and n is the number of data examined.

3- Results

After solving the feature selection problem, it was found that ND, FT, WF, WNF, DNF, DF, D32, WT, CINT, CD32, CESAL, DWL, DRG, JSP, SBTH, BTH, STH, PR, and EM variables have a significant effect on faulting failure. The general model with 32 input variables and the simplified model with 19 selected input variables were developed. The results of these models are reported in Table 1.

Also, the importance of the selected variables was determined by the random forest technique. The results show that the yearly cumulative number of days with precipitation more than 12.7 mm (24%), elastic modulus (14%), age (12%), and base thickness (10%) variables have the most significant impact on faulting failure and should be controlled.

4- Conclusions

The following are inferences that can be drawn:

The feature selection method presented in this study selected 19 input variables and constructed a simplified model. The accuracy of the simplified model is very appropriate, which indicates the high accuracy of the feature selection method.

Table 1. Performance evaluation of models

Name	type	MAE	R ²
General	Training	0.15	0.98
General	Testing	0.43	0.94
General	Validation	0.46	0.94
Simplified	Training	0.17	0.98
Simplified	Testing	0.6	0.9
Simplified	Validation	0.3	0.94

Yearly cumulative number of days with precipitation more than 12.7 mm, elastic modulus, age, and base thickness variables have the most role in causing faulting failure, respectively.

Using the LTPP data, the approach outlined in this research may be applied to different pavement distresses.

References

- [1] D.G. Mapa, M. Gunaratne, K.A. Riding, A. Zayed, Evaluating Early-Age Stresses in Jointed Plain Concrete Pavement Repair Slabs, *ACI Materials Journal*, 117(4) (2020).
- [2] Y. Chen, R.L. Lytton, Development of a new faulting model in jointed concrete pavement using LTPP data, *Transportation Research Record*, 2673(5) (2019) 407-417.
- [3] H. Naseri, M. Ehsani, A. Golroo, F. Moghadas Nejad, Sustainable pavement maintenance and rehabilitation planning using differential evolutionary programming and coyote optimisation algorithm, *International Journal of Pavement Engineering*, (2021) 1-18.
- [4] B. Saghafi, A. Hassani, R. Noori, M.G. Bustos, Artificial neural networks and regression analysis for predicting faulting in jointed concrete pavements considering base condition, *International Journal of Pavement Research and Technology*, 2(1) (2009) 20-25.
- [5] W.-N. Wang, Y.-C.J. Tsai, Back-propagation network modeling for concrete pavement faulting using LTPP data, *International Journal of Pavement Research and Technology*, 6(5) (2013) 651.
- [6] S. Ghafari, M. Ehsani, F.M. 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.
- [7] D. Daneshvar, A. Behnood, Estimation of the dynamic modulus of asphalt concretes using random forests algorithm, *International Journal of Pavement Engineering*, (2020) 1-11.
- [8] M. Ehsani, H. Naseri, R. Saeedi Nezhad, M. Etebari Ghasbeh, F. Moghadas Nejad, Compressive strength prediction of ordinary concrete, fly ash concrete, and slag concrete by novel techniques and presenting their optimal mixtures, *Amirkabir Journal of Civil Engineering*, 53(10) (2021) 1-1.

HOW TO CITE THIS ARTICLE

M. Ehsani, F. Moghadas Nejad, P. Hajikarimi, *Faulting Prediction Model in Jointed Plain Concrete Pavement and determining the parameters affecting this failure with Artificial Neural Networks*, *Amirkabir J. Civil Eng.*, 54(7) (2022) 515-518.

DOI: [10.22060/ceej.2021.19406.7161](https://doi.org/10.22060/ceej.2021.19406.7161)





پیش‌بینی خرابی پلکانی شدن در روسازی‌های بتنی غیرمسلح درزدار و تعیین پارامترهای موثر بر این خرابی با استفاده از شبکه‌های عصبی مصنوعی

مهرداد احسانی، فریدون مقدس‌نژاد*، پوریا حاجی‌کریمی

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

تاریخچه داوری:

دریافت: ۱۳۹۹/۱۰/۰۱
بازنگری: ۱۳۹۹/۱۱/۲۳
پذیرش: ۱۴۰۰/۰۹/۰۶
ارائه آنلاین: ۱۴۰۰/۰۹/۲۹

کلمات کلیدی:

پلکانی شدن
روسازی بتنی غیرمسلح درزدار
شبکه عصبی مصنوعی
انتخاب ویژگی
الگوریتم‌های فراابتکاری

خلاصه: یکی از خرابی‌های مهم عملکردی در روسازی‌های بتنی، خرابی پلکانی شدن است. پیش‌بینی مقدار این خرابی می‌تواند در طراحی بهینه روسازی بتنی و نیز استقرار سامانه مدیریت تعمیر و نگهداری روسازی‌ها مورد استفاده قرار گیرد. در این مطالعه از شبکه‌های عصبی مصنوعی برای پیش‌بینی مقدار این خرابی بر اساس داده‌های عملکرد طولانی مدت روسازی (LTPP) استفاده شده است. ابتدا با استفاده از ۳۲ متغیر انتخابی ورودی شامل داده‌های ترافیکی، آب و هوایی و سازه‌ای، معماری شبکه عصبی مصنوعی با روش آزمون و خطا تعیین شده و سپس معماری مشخص شده به درستی آموزش داده شده است. علاوه بر متغیرهای مورد استفاده در مطالعات گذشته، متغیرهای ورودی جدیدی نظیر ضریب پواسون و مدول الاستیسیته دال بتنی که تاکنون بررسی نشده‌اند نیز در بین این ۳۲ متغیر مد نظر قرار گرفته است. سپس با به کارگیری روش جدید MLP-NSGA^۲، ۱۹ متغیر مهم شناسایی شده و یک مدل شبکه عصبی جدید با این تعداد متغیر ساخته شده است. مقدار ضریب همبستگی، میانگین مربعات خطا و میانگین خطای مطلق برای مدل ساخته شده با ۳۲ متغیر و ۱۹ متغیر به ترتیب برابر ۰/۹۷، ۰/۴۵، ۰/۴۳، ۰/۹۵، ۰/۵۴ و ۰/۶ می‌باشد. در انتها با استفاده از روش جنگل تصادفی میزان اهمیت ۱۹ متغیر بر اساس درصد تعیین گردید. چهار متغیری که بیشترین اهمیت را دارند بر اساس سهم درصد اهمیت متغیر از ۱۰۰ به ترتیب عبارتند از تعداد جمعی روزهای بارش بیشتر از ۱۲/۷ میلی‌متر با ۲۴٪، مدول الاستیسیته دال بتنی با ۱۴٪، عمر روسازی با ۱۲٪ و ضخامت اساس با ۱۰٪ اهمیت.

۱- مقدمه

زیرساخت‌های حمل و نقل یکی از مهم‌ترین دارایی‌های هر کشور است که نقش غیرقابل انکاری در توسعه اقتصادی و اجتماعی آن دارد [۱]. راه‌ها به طور میانگین وظیفه جابجایی ۸۰ درصد مسافران در کشورهای مختلف را بر عهده دارند و در کشورهای پیشرفته شبکه‌های جاده‌ای یکی از مهم‌ترین دارایی‌های عمومی به شمار می‌آیند [۲]. روسازی یکی از مهم‌ترین اجزای راه‌ها می‌باشد که سالانه بیش از ۴۰۰ میلیارد دلار در جهان صرف ساخت و نگهداری آن می‌شود [۳]. به طور کلی دو نوع روسازی در حال حاضر در سراسر دنیا مورد بهره‌برداری قرار می‌گیرد: روسازی آسفالتی (انعطاف‌پذیر) و روسازی بتنی (صلب). با وجود این که هزینه ساخت روسازی صلب نسبت به روسازی انعطاف‌پذیر بالاتر است اما روسازی‌های صلب در طول عمر طراحی خود به تعمیر و نگهداری کمتری نیاز دارند و به دوام بالا، طول عمر زیاد، مقاومت بالا در برابر ترافیک عبوری و شرایط بد آب و هوایی معروف هستند

[۴ و ۳]. روسازی بتنی درزدار غیرمسلح^۱ متداول‌ترین نوع روسازی بتنی است که به صورت گسترده مورد استفاده قرار می‌گیرد [۵]. از مجموع ۴/۳ میلیون کیلومتر شبکه بزرگراهی آمریکا، ۶ درصد آن دارای روسازی بتنی است [۶]. با گذشت زمان، در این نوع از روسازی خرابی‌های مختلفی مانند پلکانی شدن^۲، مکش^۳ و خرد شدگی درز^۴ به وجود می‌آید که ناشی از عوامل مختلفی مانند ترافیک، آب و هوا، خصوصیات مواد روسازی و طراحی سازه روسازی می‌باشد. خرابی پلکانی شدن یکی از مهم‌ترین خرابی‌های ساختاری و عملکردی روسازی بتنی درزدار می‌باشد. ناهمواری جاده‌ها که ناشی از این نوع خرابی است باعث نارضایتی استفاده‌کنندگان از راه، افزایش زمان سفر و افزایش هزینه وسایل نقلیه می‌شود. یکی از موضوعات مهم در بحث تعمیر و نگهداری روسازی‌ها، انجام به موقع اقدامات ترمیمی است که لازمه آن

- 1 Jointed Plain Concrete Pavement
- 2 Faulting
- 3 Pumping
- 4 Corner spalling

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

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



دادند. در سال ۱۹۹۶ یو^{۱۱} و همکاران [۱۵] دو مدل مجزا برای پیش‌بینی خرابی پلکانی شدن در روسازی بتنی غیرمسلح درزدار دارای داوول و بدون داوول ارائه دادند با این تفاوت که نسبت به سیمپسون و همکاران از داده‌های بیشتری استفاده کردند و متغیرهای جدیدی مانند ضریب اصلاح زهکشی، فاصله درزها، ضخامت دال و میانگین سالانه تعداد روزهایی که دمای هوا بیشتر از ۳۲ درجه سانتی‌گراد است را نیز به مدل خود اضافه کردند. اضافه کردن متغیرهای جدید باعث افزایش ۰/۰۵ ضریب تعیین مدل شد. در گزارش آشتو [۱۶] از رویکرد افزایش مقدار خرابی در گذر زمان برای مدل‌سازی میانگین پلکانی شدن استفاده شده است. متغیرهای ورودی مختلفی مانند اطلاعات دما، تغییر شکل و عامل فرسایش‌پذیری در این رابطه در نظر گرفته شده است. رابطه ارائه شده بسیار پیچیده بوده و دارای ضریب تعیین ۰/۷۱ می‌باشد. وی‌کر^{۱۲} و همکاران [۱۷] با استفاده از چندین روش رگرسیونی جدید از جمله مدل خطی تعمیم یافته^{۱۳} و مدل تطبیقی تعمیم یافته^{۱۴}، مقدار خرابی پلکانی شدن را پیش‌بینی کردند. آن‌ها متغیرهای مختلفی مانند سن روسازی، بار محوری معادل هم‌ارز، میزان بارندگی سالانه، نوع اساس و زیر اساس و چرخه ذوب و یخ را در مدل پیش‌بینی خود در نظر گرفتند.

علاوه بر روش‌های رگرسیونی، روش‌های دیگری مانند شبکه‌های عصبی مصنوعی که از دقت بالاتری برخوردارند نیز به منظور پیش‌بینی خرابی پلکانی شدن مورد استفاده قرار گرفته است. تقفی^{۱۵} و همکاران [۱۸] در سال ۲۰۰۹ با در نظر گرفتن متغیرهای ورودی مختلف شامل سن روسازی، نوع و جنس اساس، ضخامت، درصد عبوری از الک‌های ۴ و ۲۰۰ برای مصالح اساس و مدول بر جهندگی مقدار پلکانی شدن را با استفاده از دو روش رگرسیون خطی و شبکه عصبی مصنوعی پیش‌بینی کردند. پنج ورودی در روش رگرسیون خطی معنادار شده و مورد استفاده قرار گرفتند. روش شبکه‌های عصبی نسبت به رگرسیون خطی از دقت بالاتری برخوردار بوده است. مولفه‌های متعددی بر شکل‌گیری و گسترش خرابی پلکانی شدن موثر است که تعداد کمی از آن‌ها مورد بررسی قرار گرفته و وارد این مدل شده است. یکی از دلایل به وجود آمدن این خرابی، تغییرات دما و رطوبت است که در پژوهش ایشان متغیرهای آب و هوایی در نظر گرفته نشده است. وانگ^{۱۶} و تسای^{۱۷} [۱۹] در سال ۲۰۱۳ با در نظر گرفتن متغیرهای مختلفی

پیش‌بینی مناسب زمان وقوع خرابی می‌باشد [۸ و ۷]. اگر اقدامات تعمیراتی دیرتر از زمان مطلوب انجام شود، می‌تواند هزینه را تا ۳ برابر افزایش دهد [۱]. بنابراین، توسعه مدل‌های پیش‌بینی میزان خرابی در طول عمر روسازی به منظور تصمیم‌گیری راجع به اقدامات تعمیر و نگهداری و همچنین تخمین عمر مفید روسازی بسیار ضروری است.

محققین از دیدگاه‌های مختلف تحقیقاتی را در زمینه خرابی پلکانی شدن انجام داده‌اند. ویجک^۱ [۹] و جنگ^۲ و زولینگر^۳ [۱۰] با استفاده از روش‌های آزمایشگاهی یک مدل بر اساس بار محوری معادل هم‌ارز ارائه دادند. این مدل نمایی پایه چهار پارامتر ثابت دارد که اساس کار محققین زیادی قرار گرفته است [۱۲ و ۱۱]. جنگ و زولینگر [۱۲] در ادامه کار پیشین خود در سال ۲۰۱۱ از مدل نمایی فوق‌الذکر استفاده کردند و با استفاده از دستگاه ردیاب چرخ هامبورگ^۴ مدلی جدید ارائه کردند. سپس این مدل را با داده‌های موجود مورد آزمایش قرار داده و پارامترهای ثابت آن را با دقت ۰/۹۳ تخمین زدند. نشوادیان‌بخش^۵ و زولینگر [۱۳] در سال ۲۰۱۴ با استفاده از پارامترهای مکانیکی مانند تنش برشی، مقاومت در برابر فرسایش لایه‌های زیرین و تغییر شکل، یک مدل مکانیکی - تجربی با دقت ۰/۸۴ ارائه داده و ادعا کردند که این مدل قابلیت کالیبراسیون با داده‌های میدانی یا آزمایشگاهی را دارد. چن^۶ و لیتون^۷ [۱۱] نیز در سال ۲۰۱۹ از این مدل نمایی پایه استفاده و آن را بر اساس عمر روسازی بازنویسی کردند و یک مدل جدید مکانیکی - تجربی برای برآورد مقدار پلکانی شدن در درزهای روسازی‌های بتنی درزدار که در مسیر چرخ می‌باشد ارائه دادند. ایشان برای چهار پارامتر ثابت مدل خود با استفاده از روش رگرسیونی گام به گام^۸ و داده‌های در دسترس، چهار معادله جداگانه ارائه کردند.

محققین از روش‌های مختلفی مانند رگرسیون خطی و غیرخطی برای پیش‌بینی خرابی پلکانی شدن استفاده می‌کنند. در سال ۱۹۹۴ سیمپسون^۹ و همکاران [۱۴] دو مدل جداگانه برای پیش‌بینی این نوع خرابی در روسازی بتنی غیرمسلح درزدار دارای داوول^۱ و بدون داوول ارائه دادند. آن‌ها با داشتن اطلاعات مربوط به ۲۵ روسازی بتنی، دو مدل مجزا برای این خرابی ارائه

- 1 Wijk
- 2 Jeong
- 3 Zollinger
- 4 Hamburg Wheel Tracking
- 5 Neshvadian Bakhsh
- 6 Chen
- 7 Lytton
- 8 Stepwise regression
- 9 Simpson
- 10 Dowel

- 11 Yu
- 12 Wei Ker
- 13 Generalized Linear Models
- 14 Generalized Additive Model
- 15 Saghafi
- 16 Wang
- 17 Tsai

در این است که با همان روشی (شبکه عصبی مصنوعی) که مدل سازی انجام می شود، انتخاب ویژگی نیز با همان روش صورت پذیرفته است. در ادامه یک مدل جدید با متغیرهای مهم ساخته شده و با مدل اصلی از نظر میزان دقت و خطا مقایسه شده است.

۲- روش تحقیق

۲-۱- جمع آوری داده ها

برنامه عملکرد بلند مدت روسازی^۳ منجر به تشکیل پایگاه داده ای جامع، منسجم و مطمئن در خصوص عملکرد روسازی های انعطاف پذیر و صلب شده است [۲۰]. از داده های این برنامه که به صورت رایگان در اختیار کلیه محققین سراسر دنیا می باشد، می توان به منظور توسعه مدل های پیش بینی مولفه های مختلف روسازی و همچنین کالیبره کردن این مدل ها استفاده نمود. داده های جمع آوری شده در این برنامه شامل اطلاعات مربوط به ۲۵۸۱ مقطع روسازی انعطاف پذیر یا صلب در ایالات متحده آمریکا و کانادا می باشد.

۲-۲- انتخاب داده ها

نظر به اینکه هدف اصلی این پژوهش پیش بینی میزان خرابی پلکانی شدن در روسازی های بتنی است، ابتدا ۱۳۳ مقطع دارای روسازی بتنی غیرمسلح در زردار انتخاب شده است. موقعیت مکانی و تعداد مقاطع مذکور در شکل ۱ قابل مشاهده است. همان طور که در این شکل مشاهده می شود، مقاطع مورد نظر از نظر پراکندگی جغرافیایی در ایالات متحده آمریکا شرایط مناسبی داشته و شرایط آب و هوایی مختلف در داده های جمع آوری شده وجود دارد. داده های مربوط به خرابی پلکانی شدن در کلیه مقاطع مورد مطالعه استخراج شده است. برای هر یک از مقاطع روسازی برداشت خرابی در زمان های مختلف صورت پذیرفته است. داده های تأثیرگذار بر شکل گیری خرابی پلکانی شدن (ورودی های مدل پیش بینی) بر اساس مرور تحقیقات گذشته و همچنین برخی پارامترهایی که از نظر پدیدار شناسی^۴ در بروز این خرابی موثر هستند، انتخاب و با توجه به مقدرات پایگاه داده LTPP استخراج شده اند. به عنوان مثال متغیرهای ضریب پواسون و مدول الاستیسیته دال بتنی از نظر پدیدار شناسی به عنوان متغیرهای ورودی در نظر گرفته شدند. بر اساس مرور ادبیات صورت گرفته، تاکنون این متغیرها در مدل های پیشین مبتنی بر روش های یادگیری ماشین بر اساس علم داده که برای پیش بینی این خرابی توسعه داده شده اند مورد استفاده قرار نگرفته اند

همچون بار محوری معادل هم ارز، سن روسازی، دال دار بودن یا نبودن روسازی، نوع اساس، ضخامت، زهکشی، فاصله درز، نوع شانه راه، میانگین بارندگی سالانه و تعداد سیکل های ذوب و یخ چهار مدل جداگانه با روش شبکه های عصبی مصنوعی ارائه کردند و در هر مدل، تعداد مشخصی از این ورودی ها را در نظر گرفتند. میانگین خطای استاندارد مدلی که همه پارامترها را در نظر گرفته از ۳ مدل دیگر کمتر بوده اما ضریب تعیین آن ۰/۴۶۵۳ بوده است که نشان دهنده دقت پایین این مدل ها است.

هدف از این مطالعه پیش بینی مقدار خرابی پلکانی شدن در روسازی بتنی غیرمسلح در زردار می باشد. روش های مبتنی بر رگرسیون نسبت به روش های جدید یادگیری ماشین^۱ مانند شبکه های عصبی مصنوعی در حل این گونه مسائل پیچیده دقت پایین تری دارند. با توجه به پیچیدگی بالا به علت موثر بودن پارامترهای متنوع و مشخص نبودن رابطه بین متغیرهای ورودی و خروجی، روش شبکه های عصبی مصنوعی انتخاب مناسبی برای پیش بینی مقدار این خرابی می باشد. همانطور که در مطالعات گذشته بیان شده است، پارامترهای متنوعی از نوع آب و هوایی، ترافیکی، عمر، سازه روسازی و مشخصات مکانیکی دال بر مقدار این خرابی موثر است. برخلاف مطالعات گذشته که تعدادی متغیر دلخواه برای مدل استفاده شده است، در این مطالعه سعی بر آن است که کلیه متغیرهای بالقوه جهت استفاده در مدل در نظر گرفته شوند. تعداد زیادی از متغیرهای موثر بر این خرابی با توجه به مطالعات گذشته انتخاب شده است و همچنین تعدادی متغیر جدید که از نظر پدیدار شناسی^۲ امکان تأثیرگذاری بر این خرابی را دارند مورد بررسی قرار گرفته است. به عبارت دیگر بر اساس تجربیات افراد خبره و آگاه در خصوص این مسئله متغیرهای ورودی جدیدی در نظر گرفته شد. سپس مدلی با استفاده از تمام متغیرهای بالقوه ساخته شده و با استفاده از شاخص های آماری متنوع، دقت آن مورد بررسی قرار گرفته است. از آنجا که کلیه متغیرهای بالقوه تأثیر یکسانی بر متغیر خروجی مدل ندارند، می بایست متغیرهای ورودی مهم و تأثیرگذار بر خرابی پلکانی شدن شناسایی شوند. از آنجا که روش قطعی برای انتخاب متغیرهای ورودی جهت پیش بینی متغیر خروجی وجود ندارد، می بایست با توجه به نوع داده و مسئله از متغیرهای ورودی مهم و تأثیرگذار استفاده کرد. در این مطالعه با تعریف یک مسئله بهینه سازی با دو تابع هدف، با اجرای روش شبکه عصبی مصنوعی بهترین متغیرهای ورودی (متغیرهای مهم و تأثیرگذار بر خرابی پلکانی شدن) انتخاب شده اند که روش نوآورانه NSGA2-MLP نام گذاری شده است. نوآوری روش به کار گرفته شده

3 Long-Term Pavement Performance (LTPP)

4 Phenomenological

1 Machine learning

2 Phenomenological



شکل ۱. موقعیت مکانی روسازی‌های بتنی غیرمسلح در زردار مورد بررسی [۲۱]

Fig. 1. Locations of investigated jointed plain concrete pavement sections [21]

داده‌هایی در ساخت مدل مورد استفاده قرار گرفته‌اند که عملیات تعمیر و نگهداری روی روسازی انجام نشده باشد زیرا هدف این مطالعه ساخت مدل اضمحلال خرابی پلکانی شدن می‌باشد. بنابراین داده‌های پلکانی شدن از روز اول ساخت روسازی برداشت شده و تا زمانی که عملیات تعمیر و نگهداری موثری بر این خرابی انجام نشده باشد وارد داده‌های مدل‌سازی شده است. چنانچه عملیات تعمیر و نگهداری در زمان خاصی برای یک مقطع وجود داشته باشد، داده‌های پلکانی شدن برای آن مقطع خاص از آن زمان به بعد حذف شده و از داده‌های مقطع بعدی استفاده شده است. آماره توصیفی داده‌های استخراج شده در جدول ۲ گزارش شده است. لازم به ذکر است آماره توصیفی برای متغیرهای ساختگی که تنها دو مقدار صفر یا ۱ را شامل می‌شوند معنایی ندارد.

از آنجا که تعداد متغیرهای در نظر گرفته شده زیاد است و مقادیر متغیرها از یک مرتبه نبوده و اختلاف زیادی با یکدیگر دارند، نرمال کردن داده‌ها جهت توسعه مدل پیش‌بینی مدنظر قرار گرفته است. هر یک از متغیرهای مورد نظر با استفاده از رابطه (۱) بین مقدار صفر و ۱ نرمال شده است [۲۲]:

$$N_i = \frac{i - i_{\min}}{i_{\max} - i_{\min}} \quad (1)$$

و در این مقاله به عنوان دو متغیر جدید معرفی و مورد مطالعه قرار گرفته‌اند. جدول ۱ شرح کامل این متغیرها را ارائه نموده است.

از آنجایی که این خرابی بیشتر در درزهای عرضی اتفاق می‌افتد، داده‌های مورد استفاده در این مطالعه و نیز مطالعات گذشته [۱۹ و ۱۱] مربوط به درزهای عرضی می‌باشد. نظر به اینکه درزهای عرضی توسط داول‌ها به یکدیگر دوخته می‌شوند، این نوع میلگرد در بررسی این خرابی بسیار حائز اهمیت است؛ اما تای بارها چون وظیفه متصل کردن درزهای طولی به یکدیگر را دارند، تاثیر ناچیزی در شکل‌گیری و یا جلوگیری از بروز این خرابی دارند

در جدول ۱ متغیرهای مقاومت کششی، ضریب پواسون و مدول الاستیسیته دال بتنی و ضرب مدول بر جهندگی در ضخامت لایه اساس به عنوان متغیرهای جدید که از نظر پدیدار شناسی خرابی پلکانی شدن مهم به نظر می‌رسند مورد بررسی قرار گرفتند و سایر متغیرها با توجه به مطالعات گذشته انتخاب شده‌اند.

۲-۳- آماده‌سازی داده‌ها

نظر به اینکه هدف اصلی این مطالعه توسعه مدلی برای پیش‌بینی شکل‌گیری و گسترش خرابی پلکانی شدن در روسازی‌های بتنی است،

1 Tie bar

جدول ۱. متغیرهای انتخاب شده به عنوان عوامل تأثیرگذار بر شکل‌گیری خرابی پلکانی شدن

Table 1. Selected variables as influencing factors in the formation of faulting failure

نماد متغیر	نوع متغیر*	واحد	تعریف متغیر	نماد متغیر	نوع متغیر*	واحد	تعریف متغیر
FLT	۱	متر	عمق خرابی پلکانی شدن	FT	۶	تعداد	میانگین سالانه تعداد روزهایی که سیکل ذوب و یخبندان در آن اتفاق می‌افتد
BM	۲	نیوتن بر متر	ضرب مدول بر جهندگی در ضخامت اساس	WF	۶	-	متغیر ساختگی ^۱ (مقدار ۱ برای منطقه با آب و هوای مرطوب همراه با یخبندان و مقدار صفر برای موارد دیگر)
BND	۲	-	نوع اساس (مقدار ۱ برای تثبیت شده و ۰ برای تثبیت نشده)	WNF	۶	-	متغیر ساختگی (مقدار ۱ برای منطقه با آب و هوای مرطوب و بدون یخبندان دارد و مقدار صفر برای موارد دیگر)
DRG	۲	-	متغیر ساختگی (مقدار ۱ برای روسازی‌هایی که زهکشی سطحی دارند و مقدار صفر برای موارد دیگر)	DNF	۶	-	متغیر ساختگی (مقدار ۱ برای منطقه با آب و هوای خشک و بدون یخبندان و مقدار صفر برای موارد دیگر)
JSP	۲	متر	فاصله درزهای روسازی	DF	۶	-	متغیر ساختگی (مقدار ۱ برای منطقه با آب و هوای خشک همراه با یخبندان و مقدار صفر برای موارد دیگر)
STH	۲	متر	ضخامت دال بتنی	D32	۶	تعداد	میانگین سالانه تعداد روزهایی که دمای هوا بیشتر از ۳۲ درجه سانتی‌گراد باشد.
SBTH	۲	متر	ضخامت زیر اساس	INT	۶	تعداد	میانگین سالانه تعداد روزهایی که بارش بیشتر از ۱۲/۷ میلی‌متر باشد
BTH	۲	متر	ضخامت اساس	WT	۶	تعداد	میانگین سالانه تعداد روزهایی که بارش بیشتر از ۰/۲۵ میلی‌متر باشد
DRGT	۲	-	نوع زهکشی (مقدار ۱ برای زهکشی طولی و مقدار صفر برای حالت‌های دیگر)	FI	۶	تعداد	شاخص یخبندان
DWL	۲	-	متغیر ساختگی (مقدار ۱ برای روسازی بتنی دارای داول و مقدار صفر برای روسازی فاقد داول)	PRC	۶	متر	میانگین سالانه بارش
PR	۳	-	ضریب پواسون دال بتنی	CD32	۶	تعداد	مقدار تجمعی تعداد روزهایی که دمای هوا بیشتر از ۳۲ درجه سانتی‌گراد باشد.
EM	۳	پاسکال	مدول الاستیسیته دال بتنی	CFT	۶	تعداد	مقدار تجمعی تعداد روزهایی که سیکل ذوب و یخبندان در آن‌ها اتفاق بیفتد
TS	۳	پاسکال	مقاومت کششی دال بتنی به روش دو نیم کردن	CFI	۶	تعداد	مقدار تجمعی سالانه شاخص یخبندان
CS	۳	پاسکال	مقاومت فشاری بتن	CPRC	۶	متر	مقدار تجمعی سالانه بارش
CESAL	۴	تعداد	تعداد تجمعی بار معادل هم‌ارز	CWT	۶	تعداد	مقدار تجمعی تعداد روزهایی که بارش بیشتر از ۰/۲۵ میلی‌متر باشد
ESAL	۴	تعداد	میانگین سالانه تعداد بار معادل هم‌ارز	CINT	۶	تعداد	مقدار تجمعی تعداد روزهایی که بارش بیشتر از ۱۲/۷ میلی‌متر باشد
ND	۵	تعداد	تعداد روزهایی که از ساخت روسازی می‌گذرد				

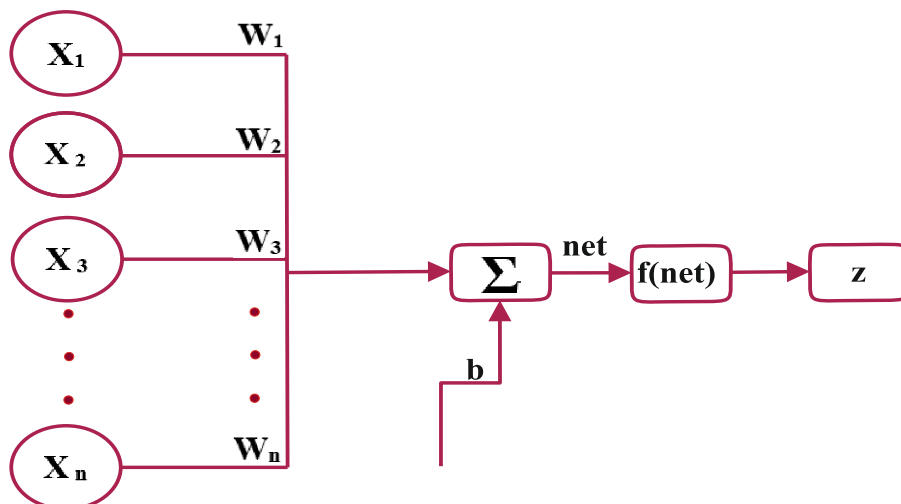
*: ۱=متغیر خروجی، ۲ = سازه روسازی، ۳ = مشخصات مکانیکی دال، ۴ = ترافیکی، ۵ = عمر و ۶ = آب و هوایی

^۱ Dummy

جدول ۲. آماره توصیفی متغیرهای انتخاب شده به عنوان عوامل تأثیرگذار بر شکل‌گیری و گسترش خرابی پلکانی شدن

Table 1. Descriptive statistics of selected variables as influencing factors in the formation and spread of faulting failure

نماد متغیر	واحد	میانگین	واریانس	انحراف معیار	کمینه	بیشینه	چولگی	کشدگی
FLT	متر	۰/۰۰۲۵	۰	۰/۰۰۲۳	۰/۰۰۰۱	۰/۰۱۱۲	۱/۷۵	۳/۱۵
FT	تعداد	۷۷/۱۴	۱۸۷۳/۵۲	۴۳/۲۸	۱	۱۷۸/۳۳	۰/۲۵	-۰/۲۵۳
BM	نیوتن بر متر	۱۶۹۹۳۷۹۰/۶	۹/۷۵×۱۰ ^{۱۲}	۹۸۷۶۶۸۱/۰۷	۲/۱۳×۱۰ ^۶	۵/۸۳×۱۰ ^۷	۱/۶۶	۴/۱۳
ESAL	تعداد	۳۶۱۴۶۸/۷۶	۱/۱۹×۱۰ ^{۱۱}	۳۴۵۵۳۲/۲۸	۲۰۰۲۹/۴۱	۱/۶۳×۱۰ ^۶	۱/۷۰۴	۲/۴۳۹
CD32	تعداد	۸۳۶/۳۷	۶۱۴۰۴۶/۴۷	۷۸۳/۶۱	۰	۴۱۲۵	۱/۵۲	۲/۸۲
CFT	تعداد	۱۴۷۳/۴۴	۷۷۸۹۹۸/۹۶	۸۸۲/۶۱	۱۵	۳۹۳۵	۰/۳۸۳	-۰/۴۷۹
CFI	تعداد	۵۸۰۲/۲	۵۴۱۵۷۲۸۳/۴۹	۷۳۵۹/۱۶	۰	۳۳۲۴۱	۱/۶	۲/۰۴
CPRC	متر	۱۸/۴۱	۱۴۱/۸۲	۱۱/۹۱	۲/۴۲	۶۳/۳۱	۰/۹۸	۱/۲۲
CWT	تعداد	۲۴۲۸/۹۶	۱۲۹۸۷۲۵/۷۷	۱۱۳۹/۶۲	۴۷۳	۶۱۹۲	۰/۷۹۶	۰/۴۶۱
CINT	تعداد	۴۲۰/۵۶	۱۰۲۱۵۴/۰۷	۳۱۹/۶۱	۹	۱۶۷۲	۱/۰۱	۱/۵۷
ND	تعداد	۶۸۸۹/۲۱	۷۳۹۵۷۶۱/۵۱	۲۷۱۹/۵۱	۲۱۰۱	۱۶۰۴۳	۰/۶۱۵	۰/۴
CESAL	تعداد	۷۴۷۶۵۸۷/۱	۶/۲۲×۱۰ ^{۱۳}	۷۸۹۱۰۵۶/۹	۱۹۳۴۰۱	۴/۵۶×۱۰ ^۷	۲/۰۳	۴/۸۵
JSP	متر	۵/۰۷	۰/۸۶	۰/۹۳	۳/۵۱	۹/۱۴	۰/۹۷	۲/۰۶
PR	-	۰/۱۷	۰/۰۰۲	۰/۰۴	۰/۰۹	۰/۳	۰/۳۸۵	۰/۴۵۸
EM	پاسکال	۲/۹۹×۱۰ ^{۱۰}	۳/۰۱×۱۰ ^{۱۹}	۵۴۸۸۸۸۷۱۷۶	۱/۸۶×۱۰ ^{۱۰}	۴/۸۳×۱۰ ^{۱۰}	۰/۴۷	۰/۶۷
TS	پاسکال	۴۲۵۵۵۷۳/۳	۵/۹۶×۱۰ ^{۱۱}	۷۷۲۰۴۰/۴۶	۳/۰۱×۱۰ ^۶	۶/۴۳×۱۰ ^۶	۰/۶۲۳	-۰/۰۰۴
CS	پاسکال	۵۲۵۹۲۳۴۴/۵۵	۷/۵۲×۱۰ ^{۱۳}	۸۶۷۰۵۰۰/۹۶	۳/۸۶×۱۰ ^۷	۹/۰۳×۱۰ ^۷	۰/۶۱۹	۱/۰۱
STH	متر	۰/۲۵	۰/۰۰۱	۰/۰۴	۰/۱۶	۰/۳۷	۰/۶۹۷	۲/۸۷
SBTH	متر	۰/۱۴	۰/۰۵۵	۰/۲۳۵۴	۰	۰/۹۸	۲/۰۶۳	۳/۸۱
D32	تعداد	۴۰/۶۹	۸۲۰/۳۶	۲۸/۶۴	۰	۱۰۲/۴۲	۰/۴۰۵	-۱/۰۷۸
INT	تعداد	۲۰/۱۱	۱۳۱/۳	۱۱/۴۶	۱/۵	۳۸/۵۷	-۰/۱۰۳	-۱/۲۱۴
WT	تعداد	۱۱۹/۷۱	۸۳۱/۳۸	۲۸/۸۳	۵۵/۱۳	۱۸۲/۸۳	-۰/۰۶۱	-۰/۴۴۲
BTH	متر	۰/۱۴	۰/۰۰۳	۰/۰۵۵	۰/۰۳	۰/۳۹	۱/۷۷	۶/۵۵
FI	تعداد	۳۲۱/۸۱	۱۶۷۱۹۴/۵۴	۴۰۸/۸۹	۰	۱۹۰/۱۹۲	۱/۹۱۵	۴/۲۵
PRC	متر	۰/۸۹۳	۰/۱۶۸	۰/۴۰۹۸	۰/۲۱	۱/۵۴	-۰/۱۱	-۱/۲۶۷



شکل ۲. نحوه عملکرد نورون در شبکه عصبی

Fig. 2. Function of neurons in the neural network

در شکل ۲، X_1 تا X_n متغیرهای ورودی اول تا n ام هستند، W_1 تا W_n وزن‌های مربوط به این متغیرها، b عدد ثابت، f یک تابع انتقال^۲ و z مقدار خروجی نورون می‌باشد. نحوه محاسبه مقدار net و z در روابط ۲ و ۳ بیان شده است [۲۶].

$$net = b + \sum_{i=1}^n W_i X_i \quad (2)$$

$$z = f(net) \quad (3)$$

مقادیر وزن‌ها و عدد ثابت موجود در نورون‌ها با استفاده از روش بهینه‌سازی مورد استفاده در شبکه عصبی تعیین می‌شود. در شبکه‌های عصبی معمولاً از سه نوع تابع انتقال سیگموئید مماسی هذلولی^۳ (TANSIG)، سیگموئید لگاریتمی^۴ (LOGSIG) و تابع انتقال خطی^۵ (PURELIN) استفاده می‌شود. معادلات ۴ تا ۶ معادلات این توابع فعال‌سازی را نشان می‌دهد [۴]. معماری کلی و شماتیک شبکه عصبی نیز در شکل ۳ نمایش داده شده است.


که در آن N_i مقدار نرمال شده داده مربوط به متغیر مورد نظر، i مقدار داده خام متغیر، i_{min} و i_{max} نیز به ترتیب بیشترین و کمترین مقدار موجود در متغیر مورد نظر می‌باشد.

۲-۴- شبکه عصبی پرسپترون چندلایه^۱

شبکه‌های عصبی مصنوعی یکی از مفیدترین و کارآمدترین ابزارهای در دسترس یادگیری ماشین می‌باشند. از این ابزار به عنوان یک روش جدید یادگیری ماشین و پردازش داده برای پیش‌بینی خروجی به صورت رگرسیون و دسته‌بندی با توجه به ماهیت مسئله یاد می‌شود. شبکه‌های عصبی مصنوعی با الهام گرفتن از مغز انسان می‌توانند مسائل غیرخطی مختلف که پیچیدگی بالایی دارند را به خوبی مدل‌سازی کرده و نتایج دقیقی ارائه دهند. هنگامی که داده‌ها از توابع ریاضی شناخته شده‌ای پیروی نمی‌کنند استفاده از این روش قابلیت‌های خود را بیش از پیش آشکار می‌کند. شبکه‌های عصبی مصنوعی از سه لایه مختلف تشکیل می‌شوند: (۱) لایه ورودی شامل متغیر یا متغیرهای ورودی، (۲) تعدادی لایه پنهان، (۳) لایه خروجی که شامل متغیر یا متغیرهای خروجی است. در داخل لایه پنهان تعدادی نورون وجود دارد [۲۳ و ۲۴]. شبکه چند لایه پرسپترون یکی از معمول‌ترین و کاربردی‌ترین شبکه‌های عصبی مصنوعی است که در آن هر نورون به چند همسایه خود متصل است [۲۵]. عملکرد هر نورون مطابق شکل ۲ در نظر گرفته می‌شود.

2 Transfer function
3 Hyperbolic tangent sigmoidal transfer function
4 Logarithmic sigmoidal transfer function
5 Pure linear transfer function

1 Multi Layer Perceptron (MLP)



شکل ۳. معماری شبکه عصبی مصنوعی

Fig. 3. Architecture of artificial neural network

و دو لایه پنهان (HL)، توابع انتقال (TF) TANSIG و LOGSIG، تعداد نورون‌ها (NN) ۱ تا ۳۰ می‌باشد. همچنین دو روش بهینه‌سازی (OM) TRAINLM^۵ و TRAINSCG^۶ [۲۷ و ۲۸] مورد استفاده قرار گرفته است. در مقاله دهایگود^۷ و آجمرا^۸ [۲۹] از دو روش بهینه‌سازی استفاده شده در این مطالعه برای مدل‌سازی استفاده شده است و هر دو روش عملکرد خوبی داشته‌اند اما TRAINLM دقت بالاتری داشته است. از آنجا که تعداد حالات با در نظر گرفتن دو لایه پنهان بسیار زیاد می‌شود، بهترین عملکرد تابع انتقال و روش بهینه‌سازی یک لایه پنهان برای دو لایه پنهان استفاده شده است. همچنین تعداد نورون لایه اول، ضرایبی از پنج در نظر گرفته شده است اما برای لایه دوم، نورون‌ها از ۱ تا ۳۰ مورد آزمایش قرار گرفته‌اند. با توجه به ماهیت تصادفی شبکه عصبی مصنوعی، برای هر معماری خاص n بار شبکه عصبی اجرا شده و شبکه‌ای که کمترین خطا را دارد انتخاب می‌شود. در این مطالعه هر معماری ۳۰ بار و در مجموع ۹۰۰۰ بار شبکه عصبی اجرا شده و بهترین حالت معرفی شده است. فلوجارت مورد استفاده جهت تعیین معماری شبکه عصبی در شکل ۴ ارائه شده است. که در شکل ۴ داریم: HL تعداد لایه پنهان، NN تعداد نورون‌ها، n تعداد اجرای شبکه عصبی، TF تابع انتقال و OM روش بهینه‌سازی می‌باشد.

$$TANSIG(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4)$$

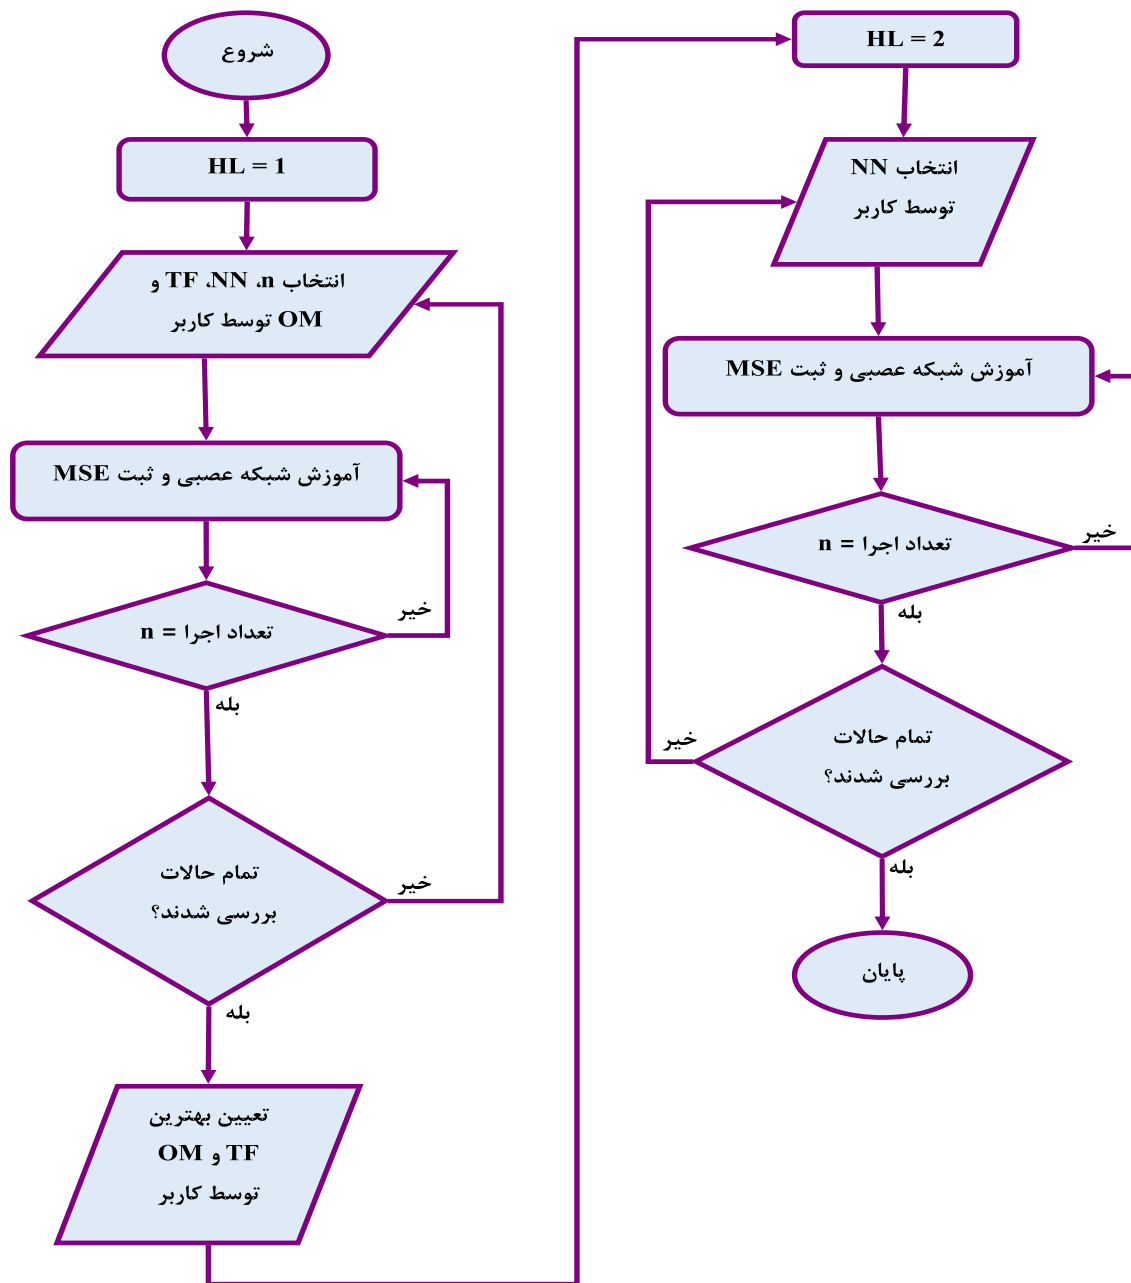
$$LOGSIG(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

$$PURELIN(x) = x \quad (6)$$

در این تحقیق متغیر FLT (عمق خرابی پلکانی شدن) متغیر خروجی مورد نظر بوده و ۳۲ متغیر باقی‌مانده به عنوان متغیرهای ورودی در نظر گرفته شده‌اند. ابتدا داده‌ها به صورت کاملاً تصادفی به سه دسته آموزش^۱ (۷۰ درصد کل داده‌ها)، آزمایش^۲ (۱۵ درصد کل داده‌ها) و اعتبارسنجی^۳ (۱۵ درصد کل داده‌ها) تقسیم شدند. روش قطعی برای تعیین معماری شبکه عصبی مصنوعی وجود ندارد. بهترین روش برای تعیین تعداد لایه‌های پنهان، تعداد نورون‌ها، نوع تابع انتقال و همچنین نوع روش بهینه‌سازی مورد استفاده در شبکه عصبی، آزمون و خطا می‌باشد [۲۵]. معماری که کمترین مقدار میانگین مربعات خطا^۴ (MSE) را داشته باشد برای حل مسئله انتخاب می‌شود. حالت‌های مورد بررسی در این مطالعه شامل یک

5 Levenberg-Marquardt
6 Scaled Conjugate Gradient
7 Dhaigude
8 Ajmera

1 Train
2 Test
3 Validation
4 Mean Squared Error



شکل ۴. فلوچارت انتخاب معماری شبکه عصبی مصنوعی

Fig. 4. Flowchart of artificial neural network architecture Selection

۲-۵-۲- پیاده‌سازی روش NSGA II-MLP

در این مطالعه به منظور انتخاب متغیرهای ورودی، دو تابع هدف استفاده شده است. همان‌طور که پیشتر عنوان شد تابع هدف اول (F_1) مرتبط با کمینه کردن تعداد متغیرهای ورودی و تابع هدف دوم (F_2) مرتبط با کمینه کردن خطای شبکه عصبی می‌باشد. در اینجا از یک مسئله بهینه‌سازی عدد صحیح^۶ استفاده شده است. تعداد متغیرهای تصمیم در این مسئله ۳۲ می‌باشد (برابر با تعداد کل متغیرهای ورودی) که هر متغیر تصمیم می‌تواند عدد صفر یا ۱ را به عنوان پاسخ داشته باشد. «صفر» به معنی عدم انتخاب متغیر و «۱» به معنی انتخاب متغیر می‌باشد.

پس از ایجاد جمعیت اولیه تصادفی (P)، میزان تابع هدف اول یعنی تعداد متغیرهای انتخاب شده برای هر دسته جواب ثبت می‌شود. از آنجایی که شبکه عصبی ماهیت تصادفی دارد، برای محاسبه مقدار تابع هدف دوم باید برای هر دسته جواب S بار شبکه عصبی اجرا (در این مطالعه ۲۰ بار اجرا شده است) و کمترین مقدار میانگین مربعات خطا ثبت شود. در حقیقت مقدار دو تابع هدف برای جمعیت محاسبه شده است. با استفاده از عملگرهای جهش و ترکیب، جواب‌های تولید شده بهبود پیدا می‌کنند تا جایی که جواب بهینه مشخص شود. در نهایت چندین جواب با شرایط مختلف به عنوان جواب‌های بهینه ارائه می‌شوند که عملاً هیچ جوابی، جواب دیگر را مغلوب نمی‌کند. در شکل ۶ مراحل انجام انتخاب ویژگی به صورت فلوجارت رسم شده است.

که در آن P جمعیت تصادفی، N اندازه جمعیت، F_1 تابع هدف اول (تعداد متغیر)، F_2 تابع هدف دوم (خطای مدل) ND شرط نامغلوب، CD شرط فاصله ازدحامی، C عملگر ترکیب، M عملگر جهش، OP جمعیت فرزندان، MP جمعیت جهش یافتگان و TP جمعیت کل می‌باشد. پس از انتخاب متغیرهای با اهمیت بالا در پیش‌بینی خرابی پلکانی شدن، با این متغیرها نیز یک مدل شبکه عصبی مصنوعی با توجه به روش بیان شده ساخته شده است.

۲-۶- ارزیابی دقت مدل‌ها

شاخص‌های آماری مختلفی برای ارزیابی دقت مدل‌ها وجود دارد. در این مطالعه با استفاده از ضریب همبستگی^۷ (R)، ضریب کارایی نش-ساتکلیف^۸ (NSE)، شاخص پراکندگی^۹ (SI)، میانگین مربعات خطا^{۱۰}

۲-۵- انتخاب متغیرهای تأثیرگذار با استفاده از روش NSGA II-MLP

با توجه به اینکه تعداد متغیرهای مورد استفاده برای پیش‌بینی خرابی پلکانی شدن بسیار زیاد است، می‌بایست متغیرهایی که میزان اهمیت بیشتری در پیش‌بینی دارند مشخص شود. از آنجا که با کاهش دادن تعداد متغیرهای ورودی، مدل ساده‌تر می‌شود باید به این نکته توجه داشت که دقت مدل نیز نسبت به حالت اولیه یعنی مدل‌سازی با ۳۲ متغیر ورودی تفاوت معنادار و تأثیرگذاری نداشته باشد. به این منظور در این مطالعه یک مسئله بهینه‌سازی با دو تابع هدف تعریف شده که تابع هدف اول مربوط به کمینه کردن تعداد متغیرهای ورودی و تابع هدف دوم مربوط به کمینه کردن میزان خطای مدل شبکه عصبی است. سپس بهترین جواب از بین پاسخ‌های به دست آمده از این روش انتخاب شده و با متغیرهای ورودی منتخب، یک مدل ساخته می‌شود.

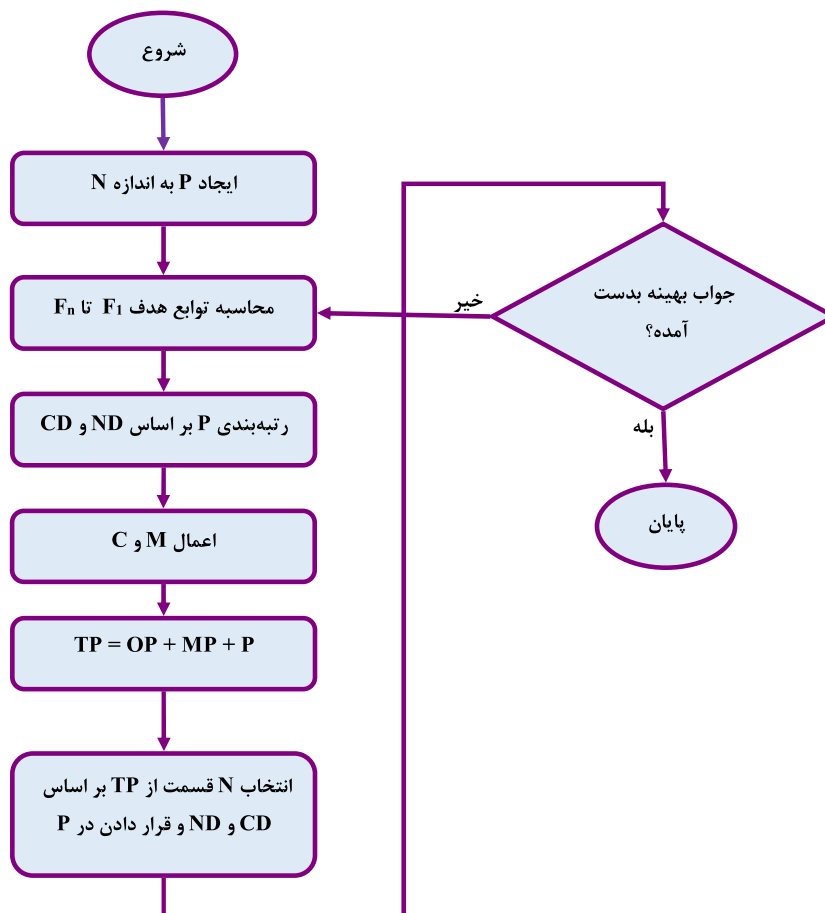
۲-۵-۱- الگوریتم بهینه‌سازی NSGA II^۱

بر خلاف بهینه‌سازی تک هدفه که منجر به یک جواب بهینه می‌شود، بهینه‌سازی چند هدفه بر اساس توابع هدفی که با هم در تناقض هستند چندین جواب بهینه را ارائه می‌دهد. الگوریتم NSGA II یک الگوریتم بهینه‌سازی چند هدفه قدرتمند است [۳۰ و ۳۱]. در ابتدا یک جمعیت اولیه تصادفی (P) به اندازه N ایجاد می‌شود و سپس مقادیر توابع هدف (F_1) تا (F_n) محاسبه می‌گردد. جمعیت موجود بر اساس شروط نامغلوب^۲ (ND) و فاصله ازدحامی^۳ (CD) رتبه‌بندی می‌شوند. برای بهبود پاسخ، با استفاده از عملگرهای جهش^۴ (M) و ترکیب^۵ (C)، جمعیت‌های جهش یافتگان (MP) و فرزندان (OP) ایجاد می‌شوند. از بین جمعیت کل (TP) که مجموع سه جمعیت موجود است، جمعیتی به اندازه N انتخاب می‌شود و این عملیات تکرار می‌شود تا جواب بهینه تعیین گردد [۳۲]. نحوه عملکرد این الگوریتم به صورت فلوجارت در شکل ۵ قابل مشاهده می‌باشد.

در شکل ۵ داریم: P جمعیت تصادفی، N اندازه جمعیت، F تابع هدف، ND شرط نامغلوب، CD شرط فاصله ازدحامی، C عملگر ترکیب، M عملگر جهش، OP جمعیت فرزندان، MP جمعیت جهش یافتگان و TP جمعیت کل می‌باشد.

6 Optimization integer programming
7 correlation coefficient
8 Nash-Sutcliffe coefficient
9 Scatter Index
10 Mean Squared Error

1 Non-dominated Sorting Genetic Algorithm-II
2 Non-Dominated
3 Crowding Distance
4 Mutation
5 Crossover



شکل ۵. فلوجارت بهینه‌سازی چند هدف NSGA II

Fig. 5. Flowchart of NSGA II multi-objective optimization

$$NSE = 1 - \frac{\sum_{i=1}^n (T_i - P_i)^2}{\sum_{i=1}^n (T_i - \bar{P})^2} \quad (۸)$$

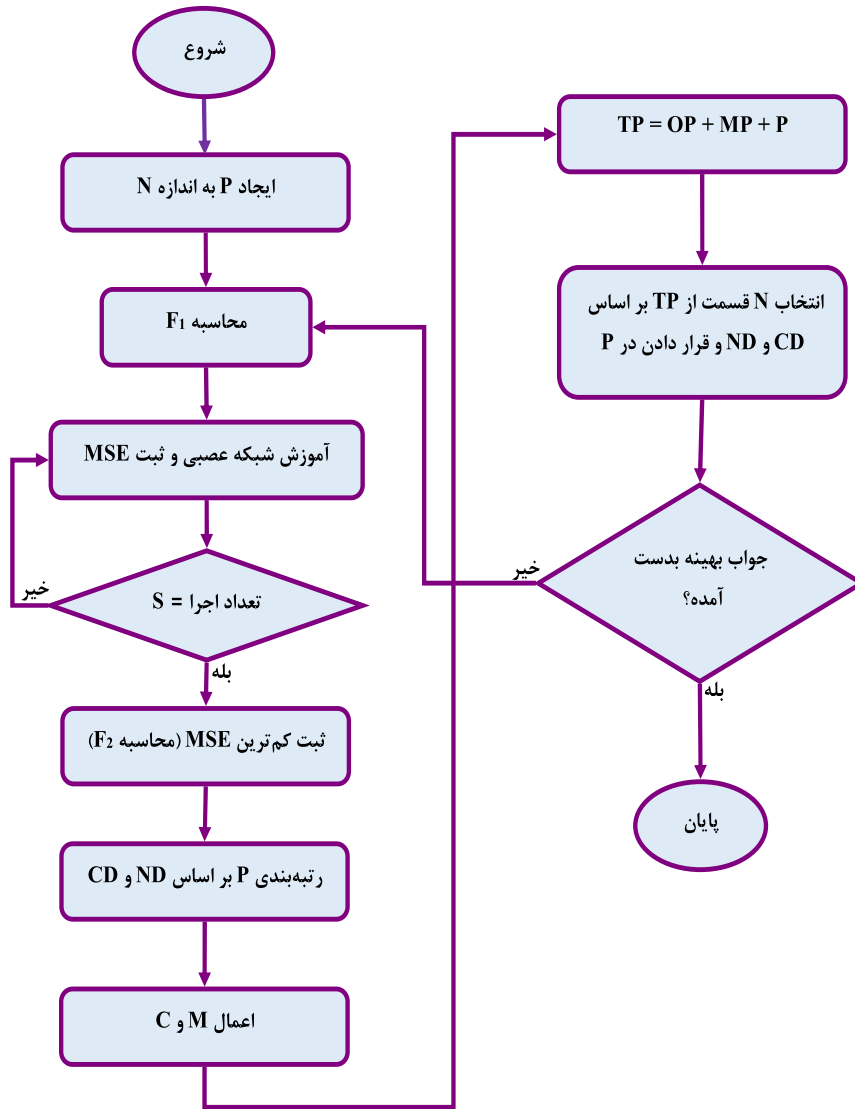
$$SI = \sqrt{\frac{\sum_{i=1}^n [(T_i - \bar{T}) - (P_i - \bar{P})]^2}{\sum_{i=1}^n T_i^2}} \quad (۹)$$

$$MSE = \frac{\sum_{i=1}^n (T_i - P_i)^2}{n} \quad (۱۰)$$

(MSE)، ریشه نسبی میانگین مربعات خطا^۱ (RRMSE)، میانگین خطای مطلق^۲ (MAE) و ریشه میانگین مربعات خطا^۳ (RMSE) دقت مدل‌ها مورد بررسی قرار گرفتند. روابط (۷) تا (۱۳)، معادلات مورد نظر برای به دست آوردن این شاخص‌ها را نشان می‌دهد [۳۳ و ۳۴].

$$R = \frac{\sum_{i=1}^n (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (۷)$$

-
- 1 Relative Root Mean Square Error
 - 2 Mean Absolute Error
 - 3 Root Mean Square Error



شکل ۶. فلوجارت روش NSGA II-MLP

Fig. 6. Flowchart of the NSGA II-MLP method

که در آن‌ها T مقدار هدف (اندازه‌گیری شده)، P مقدار پیش‌بینی شده، \bar{T} مقدار میانگین داده‌های هدف، \bar{P} میانگین داده‌های پیش‌بینی شده توسط مدل و n تعداد داده‌های مورد بررسی می‌باشد. هر یک از شاخص‌های آماری فوق‌الذکر برای داده‌های آموزش، آزمایش و اعتبارسنجی هر مدل به صورت جداگانه محاسبه شده است.

۲-۷- جنگل تصادفی

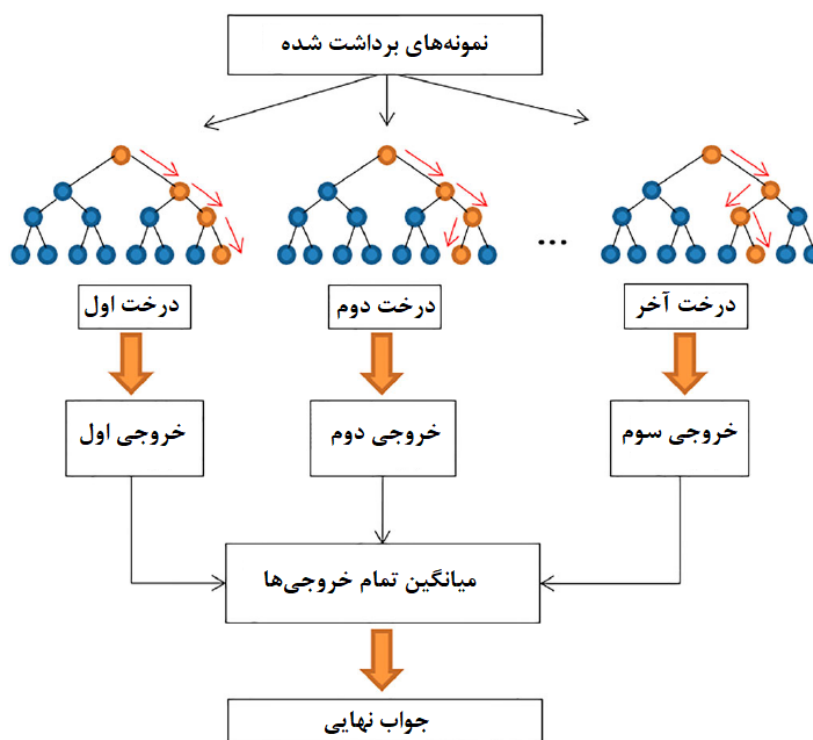
جنگل تصادفی^۱ یک الگوریتم محبوب و کارآمد است که با هدف حل مسائل دسته‌بندی و رگرسیون توسط بریمن^۲ در سال ۲۰۰۱ ارائه شده است

$$RRMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - P_i)}{n \times P_i}} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (|T_i - \bar{T}_i|) \quad (12)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - P_i)^2}{n}} \quad (13)$$

1 Random Forest
2 breiman




شکل ۷. نحوه عملکرد جنگل تصادفی

Fig. 7. Random forest performance diagram

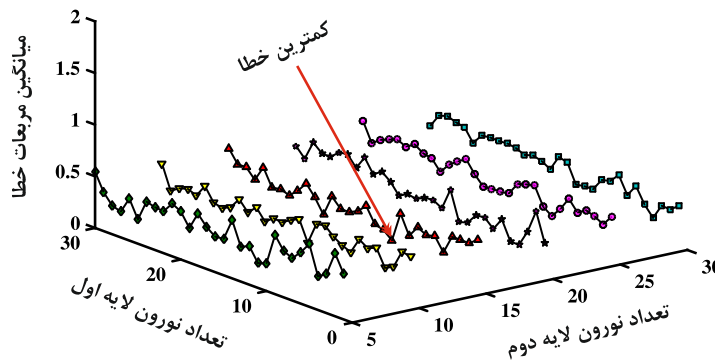
تعیین تعداد از پیش تعیین شده درختان به عنوان جنگل آغاز می‌شود. هر درخت تصمیم مجموعه داده‌های ورودی خود را به زیرمجموعه‌های کوچک‌تر تقسیم می‌کند که شامل گره‌های تصمیم‌گیری و برگ‌ها می‌شود. یک گره تصمیم دارای دو زیرگروه یا شاخه است و برگ‌ها، گره‌های درخت هستند که از آن به بعد داده‌ها را تقسیم نمی‌کند. همانطور که در شکل ۷ قابل مشاهده است، این الگوریتم با آموزش دادن تعداد زیادی از درخت‌های تصمیم که هر کدام با توجه به نمونه برداری تصادفی انجام شده است و خروجی منحصر به فرد خود را دارد مقدار پیش‌بینی را بر اساس میانگین خروجی درخت‌های تصمیم انجام می‌دهد [۴۰]. از آنجایی که متغیرها برای هر درخت به صورت تصادفی انتخاب شده است نتیجه هر درخت به صورت جداگانه ناپایدار بوده و میانگین همه درختان تابعی چند بعدی است که می‌تواند عملکرد بسیار خوبی داشته باشد [۳۶].

در ساخت مدل جنگل تصادفی همه متغیرها به یک اندازه با متغیر خروجی همبستگی ندارند. غالباً تعداد کمی از متغیرها تأثیرات قابل توجهی برای پیش‌بینی متغیر خروجی دارند. در الگوریتم جنگل تصادفی امکان اندازه‌گیری اهمیت نسبی متغیرها نسبت به پیش‌بینی هدف قابل اندازه‌گیری

[۳۵]. این الگوریتم از تعداد زیادی درخت تصمیم تشکیل شده است [۳۶]. درخت تصمیم یک روش یادگیری نظارت شده غیرپارامتریک است که می‌تواند روی مجموعه داده‌ها تصمیم‌گیری انجام داده و از ساختار درخت برای حل مسئله طبقه‌بندی و رگرسیون استفاده کند [۳۷]. الگوریتم‌های درخت‌محور یادگیری ماشین در حل مسائل طبقه‌بندی و رگرسیون به دلیل سهولت در فهم درخت تصمیم، ملموس بودن آن و توانایی کنترل کردن پیچیدگی بالای غیرخطی بین داده‌های پیش‌بینی و اندازه‌گیری شده عملکرد بسیار خوبی از خود نشان داده‌اند [۳۸]. جنگل تصادفی ترکیبی از درخت‌های پیش‌بینی هستند به گونه‌ای که هر درخت بر اساس یک بردار تصادفی به صورت مستقل و با توزیع یکسان نمونه برداری شده است. به عبارت دیگر برای هر یک از درخت‌های تصمیم موجود در جنگل تصادفی تعدادی از متغیرهای ورودی به صورت تصادفی و با جایگذاری مجدد متغیرها انتخاب می‌شوند [۳۹]. یک جنگل تصادفی به دو دلیل تصادفی تلقی می‌شود. اول اینکه هر درخت بر اساس یک زیرمجموعه تصادفی از مشاهدات (متغیرهای ورودی) است و دوم، هر انشعاب در هر درخت بر اساس تعداد متغیرهای انتخاب شده انجام می‌شود [۳۶]. جنگل تصادفی در مسائل رگرسیون با



(الف)



(ب)

شکل ۸. میانگین مربعات خطا برای معماری‌های مختلف با در نظر گرفتن (الف) یک لایه پنهان، و (ب) دو لایه پنهان

Fig. 8. Mean square error for different architectures considering (a) one hidden layer, and (b) two hidden layers

متغیرهای تأثیرگذار بیان گردیده و با استفاده از متغیرهای منتخب، مدل ساده‌تری با تعداد متغیرهای کمتر نسبت به مدل اولیه ساخته شده است. در انتها دقت مدل‌های ساخته شده با استفاده از پارامترهای مختلف مورد بررسی و ارزیابی قرار گرفته است.

۳-۱- شبکه عصبی مصنوعی با استفاده از کلیه متغیرهای موجود (۳۲ متغیر ورودی)

همان‌طور که در بخش ۲ بیان شد، انتخاب معماری شبکه عصبی بر اساس روش آزمون و خطا صورت پذیرفته است. با توجه به ماهیت تصادفی شبکه عصبی، برای هر حالت مختلف ۳۰ بار شبکه اجرا شده و پس از اجرای ۹۰۰۰ حالت مختلف، بهترین حالت انتخاب شده است. در شکل ۸-الف،

است [۳۹]. بریمن برای تعیین اهمیت یک متغیر پیشنهاد داده که پس از آموزش جنگل تصادفی تفاوت در دقت پیش‌بینی قبل و بعد از قرار دادن متغیر مورد بررسی به طور متوسط بر روی همه درختان به عنوان معیاری برای اهمیت متغیر مورد بررسی قرار گیرد و میزان اهمیت آن‌ها به صورت جداگانه و یک عدد بین ۰ و ۱ گزارش شود/مجموع همه‌ی اهمیت متغیرهای ورودی ۱ خواهد بود [۴۱].

۳- نتایج و بحث

در این مطالعه مقدار خرابی پلکانی شدن با استفاده از ابزار شبکه عصبی مصنوعی پیش‌بینی شده است. در این بخش ابتدا نتایج مدل حاصل از در نظر گرفتن ۳۲ متغیر ورودی ارائه شده است. سپس نتایج روش جدید انتخاب

موثر معرفی نشده است اما روش NSGA II-MLP این متغیرها را موثر شناسایی کرده است. منطق رفتاری حاکم بر روسازی بتنی و شکل‌گیری خرابی پلکانی شدن نیز موید این مطلب است که مشخصات مکانیکی اصلی دال بتنی شامل مدول الاستیسیته و ضریب پواسون نقش پر رنگی در این خرابی دارند زیرا اگر دو نوع روسازی با شرایط آب و هوایی، ترافیکی، سازه‌ای و با عمر یکسان داشته باشیم اما دال یکی از روسازی‌ها از نظر ویژگی‌های مکانیکی ضعیف‌تر از روسازی دیگر باشد احتمال به وجود آمدن اختلاف ارتفاع یا خرابی پلکانی شدن در محل درز زیادتر است.

همانطور که در قسمت روش تحقیق بیان شد میزان اهمیت ۱۹ متغیر انتخاب شده با استفاده از روش جنگل تصادفی تعیین می‌شود که مقدار اهمیت آن‌ها به درصد در جدول شماره ۳ قابل مشاهده است. با توجه به نتایج جنگل تصادفی متغیرهای مهم برای پیش‌بینی این خرابی به ترتیب اهمیت شامل تعداد تجمعی تعداد روزهایی که بارش بیشتر از ۱۲/۷ میلی‌متر است، مدول الاستیسیته دال، عمر روسازی، ضخامت اساس، تعداد تجمعی بار معادل هم‌ارز، میانگین سالانه تعداد روزهایی که دما بیشتر از ۳۲ درجه سلسیوس است، میانگین سالانه تعداد روزهایی که بارش بیشتر از ۰/۲۵ میلی‌متر است، ضخامت دال، ضریب پواسون، میانگین سالانه تعداد روزهایی که سبک‌دوب و یخ اتفاق می‌افتد، داول‌دار بودن یا نبودن روسازی، ضخامت زیر اساس، تعداد تجمعی روزهایی که دما بیشتر از ۳۲ درجه است، میانگین فاصله درزها از یکدیگر، متغیر ساختگی زهکشی و در انتها چهار نوع آب و هوایی که روسازی در آنجا قرار دارد. دو پارامتر پر اهمیت مدول الاستیسیته دال و ضخامت اساس در دست طراح روسازی بوده و با کنترل این دو پارامتر می‌توان از این خرابی مهم جلوگیری نمود.

با استفاده از متغیرهای انتخاب شده و با توجه به روش بیان شده در روش تحقیق، مدل شبکه عصبی مصنوعی ساخته شده است. همانطور که در شکل ۱۱ نشان داده شده است، سه دسته داده‌های آموزش، آزمایش و اعتبارسنجی دقت قابل قبولی دارند.

با مقایسه شکل‌های ۹ و ۱۱ می‌توان نتیجه‌گیری نمود که دقت دو مدل ساخته شده تقریباً با یکدیگر برابر بوده و می‌توان از اختلاف ناچیز آن‌ها صرف نظر نمود. در بخش بعد مدل‌ها با استفاده از شاخص‌های آماری به صورت دقیق با یکدیگر مقایسه شده‌اند.

۳-۳- ارزیابی و مقایسه دقت مدل‌ها


با توجه به معادلات ۷ تا ۱۳ میزان خطا و دقت مدل‌ها برای داده‌های

حالت‌های مختلف تابع انتقال و روش بهینه‌سازی برای یک لایه پنهان نشان داده شده است که تابع انتقال LOGSIG به همراه روش بهینه‌سازی TRAINLM کمترین میزان خطا را نسبت به سه حالت دیگر داشته است. در شکل ۸-ب، با استفاده از بهترین تابع انتقال و روش بهینه‌سازی در نمودار مربوط به یک لایه پنهان، تعداد نورون‌های مختلف برای دو لایه پنهان مورد بررسی قرار گرفته است. با توجه به دو نمودار شکل ۸ کمترین خطا مربوط به دو لایه پنهان با تعداد نورون لایه اول ۵ و لایه دوم ۱۱ و همچنین تابع انتقال LOGSIG و روش بهینه‌سازی TRAINLM می‌باشد که میانگین مربعات خطا برابر ۰/۱۷ برای این نوع معماری به دست آمده است.

پس از مشخص شدن معماری شبکه عصبی مصنوعی، می‌بایست یک شبکه با مشخصات بیان شده ساخته شود. در شکل ۹ نتایج مدل‌سازی برای سه دسته داده‌های آموزش، آزمایش و اعتبارسنجی قابل مشاهده است. هر چه نقاط به خط $y = x$ نزدیک‌تر باشند، به این معناست که مقادیر پیش‌بینی و هدف به یکدیگر نزدیک‌تر بوده و مدل از دقت بالاتری برخوردار است. همان‌طور که در این شکل مشاهده می‌شود در هر سه دسته داده، نقاط به خط $y = x$ نزدیک بوده و با ثبت مقادیر R برابر ۰/۹۹، ۰/۹۷ و ۰/۹۷ به ترتیب برای داده‌های آموزش، آزمایش و اعتبارسنجی مدل از دقت بالایی برخوردار است.


۳-۲- شبکه عصبی مصنوعی با متغیرهای انتخاب شده

در روش NSGA II-MLP هدف کمینه کردن تعداد متغیرهای ورودی و میانگین مربعات خطا می‌باشد. در شکل ۱۰ خروجی انتخاب متغیرهای تأثیرگذار قابل مشاهده است. محور افقی در این شکل مربوط به تابع هدف اول و تعداد متغیرهای ورودی و محور عمودی مقدار میانگین مربعات خطا می‌باشد. هر چه تعداد متغیرهای ورودی زیاد می‌شود، مطابق انتظار خطای مدل کاهش یافته است. از آنجا که در مسئله اولیه با استفاده از ۳۲ متغیر ورودی مدل‌سازی انجام شد و مقدار میانگین مربعات خطای آن برابر ۰/۱۷ بود، مشاهده می‌شود که با انتخاب ۱۹ متغیر ورودی می‌توان به همان مقدار میانگین مربعات خطا رسید. در حقیقت با حذف ۱۳ متغیر که بر خرابی پلکانی شدن تأثیر کمتری داشته‌اند، مدلی با دقتی بسیار نزدیک به دقت مدل اولیه قابل ساخت است. در جدول ۳ متغیرهای انتخاب شده برای ساخت مدل ساده‌تر ارائه شده است. متغیرهای ضریب پواسون و مدول الاستیسیته دال بتنی روسازی تاکنون در مدل‌های گذشته به عنوان متغیر



شکل ۹. نتایج شبکه عصبی مصنوعی ساخته شده با ۳۲ متغیر ورودی برای داده‌های (الف) آموزش، (ب) اعتبارسنجی و (ج) آزمایش

Fig. 9. Results of an artificial neural network constructed with 32 input variables for (a) training data, (b) validation, and (c) testing




شکل ۱۰. مجموعه جواب بهینه به دست آمده از روش NSGA II-MLP

Fig. 10. The optimal answer set obtained from the NSGA II-MLP method

جدول ۳. متغیرهای انتخاب شده به عنوان عوامل تأثیرگذار بر شکل‌گیری خرابی پلکانی شدن

Table 3. Selected variables as influencing factors in the formation of faulting failure

شماره	نماد متغیر انتخاب شده	درصد اهمیت	شماره	نماد متغیر انتخاب شده	درصد اهمیت
۱	FT	۴/۱۷	۱۱	EM	۱۴/۳۷
۲	WF	۰/۳۷	۱۲	SBTH	۲/۴۳
۳	WNF	۰/۲	۱۳	STH	۴/۴۹
۴	DNF	۰/۰۱	۱۴	BTH	۱۰/۲۱
۵	DF	۰/۰۵	۱۵	D32	۵/۷۲
۶	DRG	۰/۴۴	۱۶	WT	۴/۴۹
۷	ND	۱۱/۷۵	۱۷	DWL	۲/۷۸
۸	CESAL	۵/۹۴	۱۸	CINT	۲۴/۱۲
۹	JSP	۱/۶۴	۱۹	CD32	۲/۴۲
۱۰	PR	۴/۴۰			



شکل ۱۱. نتایج شبکه عصبی مصنوعی ساخته شده با متغیرهای انتخاب شده برای داده‌های (الف) آموزش، (ب) اعتبارسنجی و (ج) آزمایش

Fig. 11. Results of artificial neural network constructed with selected variables for (a) training, (b) validation and (c) testing data

جدول ۴. شاخص‌های آماری محاسبه شده برای دو مدل ساخته شده با ۳۲ متغیر و ۱۹ متغیر

Table 4. Statistical indices calculated for two models made with 32 variables and 19 variables

شاخص‌های آماری	مدل اول			مدل دوم		
	آموزش	آزمایش	اعتبارسنجی	آموزش	آزمایش	اعتبارسنجی
R	۰/۹۹	۰/۹۷	۰/۹۷	۰/۹۹	۰/۹۵	۰/۹۷
NSE	۰/۹۸	۰/۹۴	۰/۹۳	۰/۹۸	۰/۹۱	۰/۹۳
SI	۰/۰۹	۰/۱۸	۰/۱۸	۰/۰۹	۰/۱۹	۰/۱۷
MSE	۰/۰۸	۰/۴۵	۰/۳۴	۰/۱۱	۰/۵۴	۰/۱۵
RRMSE	۰/۲۸	۰/۶۷	۰/۵۹	۰/۳۲	۰/۷۴	۰/۳۸
MAE	۰/۱۵	۰/۴۳	۰/۴۶	۰/۱۷	۰/۰۶	۰/۰۳
RMSE	۰/۲۸	۰/۶۷	۰/۵۹	۰/۳۲	۰/۷۴	۰/۳۸

۴- نتیجه‌گیری

در این مطالعه تأثیر ۳۲ متغیر شامل متغیرهای آب و هوایی، ترافیکی و سازه‌ای بر مقدار خرابی پلکانی شدن مورد بررسی قرار گرفته است. همچنین با استفاده از شبکه‌های عصبی مصنوعی دو مدل مجزا جهت پیش‌بینی مقدار این خرابی توسعه داده شده است. مدل اول با استفاده از ۳۲ متغیر ورودی ساخته شده است. از آنجا که تعداد متغیرهای ورودی زیاد است و کلیه متغیرهای ورودی بر مقدار خرابی پلکانی شدن تأثیر یکسانی ندارند، روش جدید NSGA II-MLP به منظور انتخاب متغیرهای تأثیرگذار ارائه شده است. با استفاده از این روش تعدادی از متغیرهای مهم شناسایی شده و با استفاده از این متغیرها یک شبکه عصبی مصنوعی دیگر آموزش داده شده است. در نهایت با استفاده از شاخص‌های آماری R، NSE، SI، MAE، MSE، RMSE و RRMSE میزان دقت دو مدل توسعه داده شده با یکدیگر مقایسه شدند. نتایج این تحقیق به شرح زیر است:

- مقدار R برای داده‌های آموزش، اعتبارسنجی و آزمایش مدل ساخته شده با ۳۲ متغیر ورودی به ترتیب برابر ۰/۹۹، ۰/۹۷ و ۰/۹۷ می‌باشد. دقت گزارش شده بسیار بالا بوده که نشان از آموزش صحیح شبکه عصبی مصنوعی، استفاده از متغیرهای ورودی صحیح و معتبر بودن مدل ساخته شده می‌باشد.
- روش توسعه داده شده NSGA II-MLP این توانایی را دارد

آموزش، آزمایش و اعتبارسنجی هر مدل به صورت جداگانه محاسبه شده است. جدول ۴ مقدار شاخص‌های آماری برای مدل اول (۳۲ متغیر ورودی) و مدل دوم (۱۹ متغیر ورودی) را نشان داده است.

ضرایب همبستگی هر دو مدل برای داده‌های مختلف مناسب و نشان دهنده توانمندی شبکه عصبی مصنوعی در پیش‌بینی خرابی پلکانی شدن در روسازی‌های بتنی است. دقت مدل‌های ارائه شده نسبت به کارهای پیشین [۱۷-۱۵] بالاتر بوده که دلایل مختلفی می‌تواند داشته باشد. بررسی طیف وسیعی از متغیرهای موثر بر این خرابی به صورت همزمان، استفاده از یک روش قدرتمند و جدید جهت انتخاب متغیرهای تأثیرگذار و تعیین معماری درست و آموزش صحیح شبکه عصبی مصنوعی از جمله این دلایل است. به صورت کلی برای داده‌های آزمایش، شاخص‌های R، NSE و SI در هر دو مدل تقریباً مقداری ثابت دارند اما از نظر ۴ پارامتر دیگر، میزان خطای مدل اول کمتر از مدل دوم است. همچنین نتایج حاصل از ۷ شاخص آماری نشان می‌دهد که میزان دقت داده‌های آزمایش مدل اول برتری جزئی در هر ۷ شاخص نسبت به مدل دوم دارد. اما در داده‌های اعتبارسنجی، مدل دوم نسبت به مدل اول عملکرد بهتری از خود نشان داده است. این نتایج نشان دهنده عملکرد مطلوب روش مورد استفاده جهت انتخاب متغیرهای تأثیرگذار می‌باشد که با حذف ۱۳ متغیر ورودی توانسته تقریباً به همان دقت اولیه مدل‌سازی برسد.

پژوهش‌های آینده

از آنجا که مدل توسعه داده شده در این تحقیق مبتنی بر داده‌های عملکرد بلند مدت روسازی (LTPP) برای قطعات روسازی کشورهای آمریکا و کانادا می‌باشد، به منظور استفاده از این مدل جهت پیش‌بینی خرابی پلکانی شدن در کشور ایران پیشنهاد می‌شود در پژوهش‌های آتی قطعاتی از روسازی‌های فوق‌الذکر که شرایط آب و هوایی (دما، بارش و رطوبت)، سازه‌ای و ترافیکی مشابه با روسازی‌های بتنی مورد نظر در کشور ایران دارند مورد نظر و مبنای مقایسه قرار گیرند.

منابع

- [1] V. Yepes, C. Torres-Machi, A. Chamorro, E. Pellicer, Optimal pavement maintenance programs based on a hybrid greedy randomized adaptive search procedure algorithm, *Journal of Civil Engineering and Management*, 22(4) (2016) 540-550.
- [2] M.G. Augeri, S. Greco, V. Nicolosi, Planning urban pavement maintenance by a new interactive multiobjective optimization approach, *European Transport Research Review*, 11(1) (2019) 1-14.
- [3] Z. Mao, Life-Cycle Assessment of Highway Pavement Alternatives in Aspects of Economic, Environmental, and Social Performance, Texas A & M University, 2012.
- [4] M. Hossain, L.S.P. Gopiseti, M.S. Miah, Artificial neural network modelling to predict international roughness index of rigid pavements, *International Journal of Pavement Research and Technology*, (2020) 1-11.
- [5] D.G. Mapa, M. Gunaratne, K.A. Riding, A. Zayed, Evaluating Early-Age Stresses in Jointed Plain Concrete Pavement Repair Slabs, *ACI Materials Journal*, 117(4) (2020).
- [6] L.F. Facts, National Asphalt Pavement Association (NAPA), Landham, MD, no date, in, 2007.
- [7] M.Y. Shahin, Pavement management for airports, roads, and parking lots, 1994.
- [8] X. Yang, Z. You, J.E. Hiller, M.R. Mohd Hasan, A. Diab, S. Luo, Sensitivity of Rigid Pavement Performance Predictions to Individual Climate Variables using Pavement ME Design, *Journal of Transportation*

که برای هر روش یادگیری ماشین مورد استفاده قرار گیرد. با استفاده از این روش می‌توان متغیرهای ورودی موثر را شناسایی و یک مدل ساده‌تر با استفاده از متغیرهای مهم ساخت. در این مطالعه متغیرهای آب و هوایی که در خرابی پلکانی شدن موثر بوده‌اند عبارت‌اند از میانگین سالانه تعداد روزهایی که سیکل ذوب و یخ در آن اتفاق می‌افتد (FT)، ۴ متغیر مربوط به نوع آب و هوایی که روسازی در آن وجود دارد (DNF، WNF، WF)، میانگین سالانه تعداد روزهایی که دمای هوا بیشتر از ۳۲ درجه سانتی‌گراد باشد و همچنین مقدار تجمعی آن (D32 و CD32)، میانگین سالانه تعداد روزهایی که بارش بیشتر از ۰/۲۵ میلی‌متر باشد (WT) و مقدار تجمعی تعداد روزهایی که بارش بیشتر از ۱۲/۷ میلی‌متر باشد (CINT). متغیرهای سازه‌ای نیز شامل سیستم زهکشی روسازی (DRG)، فاصله درزهای روسازی (JSP)، ضریب پواسون و مدول الاستیسیته دال بتنی (EM و PR)، ضخامت زیر اساس، دال و اساس (SBTH، STH و BTH) و دال داشتن یا نداشتن روسازی (DWL). همچنین عمر روسازی (ND) و تعداد تجمعی بار معادل هم‌ارز (CESAL) از متغیرهای مهم برای پیش‌بینی این خرابی معرفی شدند.

- مدل دوم ساخته شده با متغیرهای منتخب از روش NSGA II-MLP دارای ضریب همبستگی ۰/۹۹، ۰/۹۵ و ۰/۹۷ به ترتیب برای داده‌های آموزش، اعتبارسنجی و آزمایش می‌باشد. دقت این مدل نیز مانند مدل اول قابل قبول بوده است. ضریب تعیین مدل دوم با توجه به این نکته که با ۱۳ متغیر ورودی کمتر نسبت به مدل اول ساخته شده است فقط ۰/۰۲ در داده‌های اعتبارسنجی پایین‌تر بوده و در داده‌های آموزش و آزمایش دقت برابر داشته‌اند. این اختلاف دقت ناچیز نشانگر این واقعیت است که متغیرها به درستی انتخاب شده و ۱۳ متغیر انتخاب نشده تأثیر قابل توجهی بر پیش‌بینی مقادیر خرابی پلکانی شدن ندارند.

- پنج متغیری که بیشترین تأثیرگذاری بر مقدار خرابی پلکانی شدن را دارند به همراه درصد تأثیر آن‌ها عبارتند از تعداد تجمعی تعداد روزهای بارش بیشتر از ۱۲/۷ میلی‌متر (CINT)، ۲۴٪، مدول الاستیسیته دال بتنی (EM)، ۱۴٪، عمر روسازی (ND)، ۱۲٪، ضخامت لایه اساس (BTH)، ۱۰٪ و تعداد تجمعی بار معادل هم‌ارز (CESAL)، ۶٪. دو متغیر مدول الاستیسیته دال بتنی و ضخامت لایه اساس، پارامترهایی هستند که طراح روسازی می‌تواند با کنترل آن‌ها از شدت خرابی در طول عمر روسازی بکاهد.

- [19] W.-N. Wang, Y.-C.J. Tsai, Back-propagation network modeling for concrete pavement faulting using LTPP data, *International Journal of Pavement Research and Technology*, 6(5) (2013) 651.
- [20] P. Lu, D. Tolliver, Pavement treatment short-term effectiveness in IRI change using long-term pavement program data, *Journal of transportation engineering*, 138(11) (2012) 1297-1302.
- [21] <https://infopave.fhwa.dot.gov/>.
- [22] V. Safak, Min-Mid-Max Scaling, Limits of Agreement, and Agreement Score, arXiv preprint arXiv:2006.12904, (2020).
- [23] A. Moniri, H. Ziari, A. Amini, M. Hajiloo, Investigating the ANN model for cracking of HMA in terms of temperature, RAP and fibre content, *International Journal of Pavement Engineering*, (2020) 1-13.
- [24] M. Younos, R. Abd El-Hakim, S. El-Badawy, H. Afify, Multi-input performance prediction models for flexible pavements using LTPP database, *Innovative Infrastructure Solutions*, 5(1) (2020) 1-11.
- [25] E. Heidari, M.A. Sobati, S. Movahedirad, Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN), *Chemometrics and intelligent laboratory systems*, 155 (2016) 73-85.
- [26] G. Sollazzo, T. Fwa, G. Bosurgi, An ANN model to correlate roughness and structural performance in asphalt pavements, *Construction and Building Materials*, 134 (2017) 684-693.
- [27] A. Kostopoulos, T. Grapsa, Self-scaled conjugate gradient training algorithms, *Neurocomputing*, 72(13-15) (2009) 3000-3019.
- [28] A.A. Suratgar, M.B. Tavakoli, A. Hoseinabadi, Modified Levenberg-Marquardt method for neural networks training, *World Acad Sci Eng Technol*, 6(1) (2005) 46-48.
- [29] R. Dhaigude, S. Ajmera, Modelling of Groundwater Level Using Artificial Neural Network.
- [30] M.H. Esfe, H. Hajmohammad, R. Moradi, A.A.A. Arani, Multi-objective optimization of cost and thermal Engineering, Part B: Pavements, 146(3) (2020) 04020028.
- [9] W.A. Van, Rigid pavement pumping:(1) subbase erosion and (2) economic modeling: informational report, (1985).
- [10] J.-H. Jeong, D.G. Zollinger, Characterization of stiffness parameters in design of continuously reinforced and jointed pavements, *Transportation Research Record*, 1778(1) (2001) 54-63.
- [11] Y. Chen, R.L. Lytton, Development of a new faulting model in jointed concrete pavement using LTPP data, *Transportation Research Record*, 2673(5) (2019) 407-417.
- [12] Y.S. Jung, D.G. Zollinger, New Laboratory-Based Mechanistic-Empirical Model for Faulting in Jointed Concrete Pavement, *Transportation research record*, 2226(1) (2011) 60-70.
- [13] K.N. Bakhsh, D. Zollinger, Faulting prediction model for design of concrete pavement structures, in: *Pavement Materials, Structures, and Performance*, 2014, pp. 327-342.
- [14] A. Simpson, J. Rauhut, P. Jordahl, E. Owusu-Antwi, M. Darter, R. Ahmad, O. Pendleton, Y. Lee, Early analyses of LTPP general pavement studies data, *Sensitivity Analyses for Selected Pavement Distresses*, (1993).
- [15] H. Yu, K. Smith, M. Darter, J. Jiang, L. Khazanovich, Performance of concrete pavements. Volume III: Improving concrete pavement performance, 1998.
- [16] Aashto, Guide for the local calibration of the mechanistic-empirical pavement design guide, in, *American Association of State Highway and Transportation Officials ...*, 2010.
- [17] H.-W. Ker, Y.-H. Lee, C.-H. Lin, Development of faulting prediction models for rigid pavements using LTPP database, *Statistics*, 218(0037.0) (2008) 0037.0030.
- [18] B. Saghafi, A. Hassani, R. Noori, M.G. Bustos, Artificial neural networks and regression analysis for predicting faulting in jointed concrete pavements considering base condition, *International Journal of Pavement Research and Technology*, 2(1) (2009) 20-25.

- [36] U. Grömping, Variable importance assessment in regression: linear regression versus random forest, *The American Statistician*, 63(4) (2009) 308-319.
- [37] W. Zhang, C. Wu, Y. Li, L. Wang, P. Samui, Assessment of pile drivability using random forest regression and multivariate adaptive regression splines, *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 15(1) (2021) 27-40.
- [38] 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.
- [39] H. Gong, Y. Sun, W. Hu, P.A. Polaczyk, B. Huang, Investigating impacts of asphalt mixture properties on pavement performance using LTPP data through random forests, *Construction and Building Materials*, 204 (2019) 203-212.
- [40] D. Daneshvar, A. Behnood, Estimation of the dynamic modulus of asphalt concretes using random forests algorithm, *International Journal of Pavement Engineering*, (2020) 1-11.
- [41] C. Strobl, A.-L. Boulesteix, T. Kneib, T. Augustin, A. Zeileis, Conditional variable importance for random forests, *BMC bioinformatics*, 9(1) (2008) 1-11.
- performance of double walled carbon nanotubes/water nanofluids by NSGA-II using response surface method, *Applied Thermal Engineering*, 112 (2017) 1648-1657.
- [31] T. Vo-Duy, D. Duong-Gia, V. Ho-Huu, H.C. Vu-Do, T. Nguyen-Thoi, Multi-objective optimization of laminated composite beam structures using NSGA-II algorithm, *Composite Structures*, 168 (2017) 498-509.
- [32] A. Kumar, H. Majumder, K. Vivekananda, K. Maity, NSGA-II approach for multi-objective optimization of wire electrical discharge machining process parameter on inconel 718, *Materials Today: Proceedings*, 4(2) (2017) 2194-2202.
- [33] J.-L. Chen, H.-B. Liu, W. Wu, D.-T. Xie, Estimation of monthly solar radiation from measured temperatures using support vector machines—a case study, *Renewable Energy*, 36(1) (2011) 413-420.
- [34] Z. He, X. Wen, H. Liu, J. Du, A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region, *Journal of Hydrology*, 509 (2014) 379-386.
- [35] R. Genuer, J.-M. Poggi, C. Tuleau-Malot, Variable selection using random forests, *Pattern recognition letters*, 31(14) (2010) 2225-2236.

چگونه به این مقاله ارجاع دهیم

M. Ehsani, F. Moghadas Nejad, P. Hajikarimi, *Faulting Prediction Model in Jointed Plain Concrete Pavement and determining the parameters affecting this failure with Artificial Neural Networks*, *Amirkabir J. Civil Eng.*, 54(7) (2022) 2547-2568.

DOI: [10.22060/ceej.2021.19406.7161](https://doi.org/10.22060/ceej.2021.19406.7161)

