



## Prediction of rutting deterioration in flexible pavements using artificial neural network and genetic algorithm

A. R. Askari, P. Hajikarimi\*, M. Ehsani, F. Moghadas Nejad

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

**ABSTRACT:** Rutting is one of the major deteriorations of asphalt pavement, significantly impacts road safety and service quality. Prediction models are necessary to prevent and control the damage caused by this deterioration in the pavement management system. In this study, using the artificial neural network algorithm, models have been developed to predict the amount of rutting deterioration using the long-term pavement performance (LTPP) database. These models have been developed for wet freeze, dry freeze, and dry no-freeze climates. Since proper accuracy and simplicity are the most important features of a prediction model, using the NSGA II-MLP multi-objective optimization method, the more important variables in predicting rutting deterioration are identified and selected as the model input. Then, using traffic, climatic and structural variables selected from the genetic algorithm, rutting deterioration prediction models were developed. The coefficient of determination and the mean squared error for the model made in the wet freeze zone and the model of dry freeze and dry no freeze zones are equal to 0.96, 2.05, 0.94 and 3.45, respectively. Also, by performing sensitivity analysis, the effect of input data of each model on rutting deterioration was determined. The cumulative maximum and minimum daily temperature difference per year, pavement age, asphalt layer thickness, annual equivalent single axle loads, and bitumen penetration are the most impactful variables that have the greatest impact on rutting deterioration.

### Review History:

Received: Jan. 08, 2022

Revised: Mar. 21, 2022

Accepted: Apr. 16, 2022

Available Online: Apr. 27, 2022

### Keywords:

Rutting

Flexible pavement

Artificial neural network

Multi-objective optimization

Genetic algorithm

### 1- Introduction

Asphalt pavements are part of the national assets of each country, which must be maintained at an acceptable level of service [1]. One of the main deteriorations of asphalt pavements is rutting, which is caused by the accumulation of permanent deformations in the pavement layers [2]. One of the pavement management system (PMS) tasks is to determine the optimal maintenance time by predicting the pavement future condition [3]. Using pavement failure prediction models, the pavement status in the future is determined, and the pavement management system based on the results of these models helps managers choosing the right time to repair the pavement in the appropriate service conditions [4].

In recent studies in this field, Radwan et al. [5] Developed models for predicting rutting failure in dry no freeze and wet no freeze climates. In this study, stepwise regression analysis was performed to obtain the factors affecting the model. In this model, the coefficient of determination is 0.479 for dry no freeze zones and 0.233 for wet no freeze zones. In recent studies, machine learning methods have been used to predict pavement conditions. Zeiada et al. [6] have used various machine learning methods such as support vector machines, regression tree, artificial neural network, etc., to predict the

international pavement roughness index. Comparing the results, it was observed that the artificial neural network had the highest accuracy compared to other methods, including linear regression.

This study aims to develop a model for predicting the rutting depth using an artificial neural network. To find the effective parameters, the NSGA II-MLP algorithm based on the neural network has been used. Due to the lack of coherent and reliable information about the condition of pavements in Iran, in this study, long-term pavement performance (LTPP) data has been used, and the impact of various factors such as weather, traffic, and pavement structures on the rutting failure has been investigated.

### 2- Methodology

In this study, 377 asphalt pavement sections have been selected from asphalt concrete pavement sections on unbound and bound bases. In this research, the rutting depth variable has been used as an output variable, and various climatic, traffic and pavement structure variables have been used as inputs to create a data set. Structural variables and material characteristics include type of base, specific gravity of asphalt and bitumen, percentage of air and bitumen in

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



**Table 1. statistical indices of developed models**

Name	type	MAE	R <sup>2</sup>
First zone	Training	0.84	0.94
First zone	Testing	1.44	0.88
First zone	Validation	1.65	0.88
Second zone	Training	0.62	0.96
Second zone	Testing	2.16	0.84
Second zone	Validation	2.11	0.94

asphalt mixture, material size, bitumen stiffness, thickness of different pavement layers, drainage conditions, resilient modulus, specific gravity and moisture of subgrade, and pavement age. The equivalent single axle load is used as traffic variable. Climatic variables include air temperature, freeze and thaw indices, humidity, shortwave radiation on the surface, cloud cover, and precipitation.

Artificial neural network algorithms are one of the most efficient and popular machine learning tools. Artificial neural networks work based on the physiological structure and mechanism of the human brain and can solve complex problems with high accuracy. This study used a multilayer perceptron neural network to develop a prediction model. The basis of the operation of these methods is that first random values for weights and bias are considered, and by performing the network, modeling error is obtained. Then, with the backward propagation of the error in the network, the weights and the bias are changed to reduce the error in the next prediction cycle [7].

To develop an efficient model that has the features of simplicity and ease of use while being accurate, it is necessary to identify the variables that are more important in predicting rutting failure. For this purpose, an optimization problem is defined with two objective functions: the first objective function is to minimize the number of input variables and the second objective function is to maximize the accuracy of the neural network model. Using NSGA II-MLP method, input data of models related to each of the considered climatic zones were selected. Finally, by using selected input variables and training neural networks with them, the desired models for the wet freeze zone and the model of dry freeze and dry no freeze zones have been developed [8].

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

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

There are several statistical indicators to evaluate the accuracy of the models. In this study, the accuracy of the models was evaluated using the coefficient of determination (R<sup>2</sup>) and mean absolute error (MAE). Equations (1) and (2) show how to calculate these indicators [9].

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

### 3- Results and discussion

Using NSGA II-MLP algorithm, in wet freeze zones (first zone) with seven input variables and in dry freeze and dry no freeze regions (second zone) with eight variables, the accuracy of the models has reached the maximum value. The variables selected in the first zone include pavement age, freeze and thaw index, equivalent single axle load, maximum and minimum daily temperature difference, asphalt layer thickness, percentage of materials passing through sieve #4 (4.75 mm) and maximum specific gravity of the subgrade. The variables of the second zone also include the first five variables mentioned for the previous zone. In addition, the base type, bitumen penetration, and percentage of materials passing through sieve #4 and residue on sieve #200 in asphalt mixture are among the variables in this zones.

To better evaluate the performance of the neural network, R<sup>2</sup> and MAE of the three categories of training, testing and validation data for each model have been calculated separately. Table 1 shows the values of the statistical indices of the first and second zone models.

Since it is impossible to understand the relationship between input and output variables in the artificial neural network modeling method, by sensitivity analysis, the effect of input variables of each model on the rutting failure was determined. Among the variables that have the greatest impact on rutting deterioration in the first zone are the cumulative maximum and minimum daily temperature difference per year, pavement age, and asphalt layer thickness. Also, in the second zone, important variables include equivalent single axle load, bitumen penetration, and asphalt layer thickness.

### 4- Conclusions

The concluding remarks of this study are as follows:

The important role of NSGA II-MLP method in selecting effective input variables and thus creating a model with less complexity and input variables has been identified. Using this method, optimal models were created by considering more effective variables in each model to predict rutting deterioration in the studied climatic zones.

The coefficient of determination for the models made in the wet freeze and the common model of dry freeze and dry no freeze zones are equal to 0.96 and 0.94, respectively. This indicates that the artificial neural network can predict rutting failure behavior well.

It was concluded that depending on the weather conditions, various factors can affect the rutting performance. The variables of pavement temperature and age in the first zone

and the variables of traffic load and bitumen penetration in the second zone were more important than the other variables.

## References

- [1] T.F. Fwa, The handbook of highway engineering, CRC press, 2005.
- [2] B. Ali, Numerical Model for the Mechanical Behavior of Pavement: Application to the Analysis of Rutting, PhD, University of Science and Technology Lille, France, (2006).
- [3] K.H. McGhee, Automated pavement distress collection techniques, Transportation Research Board, 2004.
- [4] K.A. Abaza, Deterministic performance prediction model for rehabilitation and management of flexible pavement, International Journal of Pavement Engineering, 5(2) (2004) 111-121.
- [5] M. RADWAN, A.-H. Mostafa, M. HASHEM, H. FAHEEM, Modeling pavement performance based on LTPP database for flexible pavements, Teknik Dergi, 31(4) (2020) 10127-10146.
- [6] W. Zeiada, S.A. Dabous, K. Hamad, R. Al-Ruzouq, M.A. Khalil, Machine learning for pavement performance modelling in warm climate regions, Arabian journal for science and engineering, 45(5) (2020) 4091-4109.
- [7] 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.
- [8] 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, (2022) 1-16.
- [9] 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.

### HOW TO CITE THIS ARTICLE

A. R. Askari, P. Hajikarimi, M. Ehsani, F. Moghadas Nejad, Prediction of rutting deterioration in flexible pavements using artificial neural network and genetic algorithm, Amirkabir J. Civil Eng., 54(9) (2022) 725-728.

DOI: 10.22060/ceej.2022.20965.7581







## پیش‌بینی خرابی شیار شدگی در روسازی های انعطاف‌پذیر با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک

علیرضا عسکری، پوریا حاجی‌کریمی\*، مهرداد احسانی، فریدون مقدس‌نژاد

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

### تاریخچه داوری:

دریافت: ۱۴۰۰/۱۰/۱۸  
بازنگری: ۱۴۰۱/۰۱/۰۱  
پذیرش: ۱۴۰۱/۰۱/۲۷  
ارائه آنلاین: ۱۴۰۱/۰۲/۰۷

### کلمات کلیدی:

شیار شدگی  
روسازی انعطاف‌پذیر  
شبکه عصبی مصنوعی  
بهینه‌سازی چند هدفه  
الگوریتم ژنتیک

**خلاصه:** شیار شدگی یکی از خرابی‌های مهم عملکردی در روسازی‌های آسفالتی است. توسعه مدل‌های پیش‌بینی به منظور جلوگیری و کنترل آسیب‌های ناشی از این خرابی در سیستم مدیریت روسازی ضروری است. در این مطالعه با کمک الگوریتم شبکه عصبی مصنوعی، مدل‌هایی برای پیش‌بینی مقدار خرابی شیار شدگی با استفاده از پایگاه داده برنامه بلند مدت روسازی (LTPP) توسعه داده شده است. این مدل‌ها برای اقلیم‌های آب و هوایی سرد و مرطوب، گرم و خشک و سرد و خشک ارائه شده‌اند. از آنجا که دقت مناسب در عین سادگی جزء مهم‌ترین ویژگی‌های یک مدل پیش‌بینی به شمار می‌رود، با استفاده از روش بهینه‌سازی چندهدفه NSGA II-MLP متغیرهایی که میزان اهمیت بیشتری در پیش‌بینی خرابی شیار شدگی دارند، مشخص و به عنوان ورودی مدل در نظر گرفته شدند. سپس با استفاده از متغیرهای ترافیکی، آب و هوایی و سازه‌ای انتخاب شده توسط الگوریتم ژنتیک، مدل‌های پیش‌بینی خرابی شیار شدگی ساخته شده‌اند. مقدار ضریب تعیین و میانگین مربعات خطا برای مدل ساخته شده در مناطق سرد و مرطوب و مدل مشترک مناطق گرم و خشک و سرد و خشک به ترتیب برابر ۰/۹۶، ۰/۰۵، ۲/۰۵ و ۰/۹۴ می‌باشد. همچنین با انجام تحلیل حساسیت، متغیرهایی که بیشترین اثرگذاری را بر خرابی شیار شدگی در اقلیم سرد و مرطوب دارند، به ترتیب اهمیت سن و اختلاف دمای حداکثر و حداقل روزانه با تاثیر مستقیم و ضخامت روسازی با تاثیر معکوس مشخص گردید. همچنین در اقلیم گرم و سرد خشک به ترتیب متغیرهای بار ترافیکی و نفوذپذیری قیر با تاثیر مستقیم و ضخامت روسازی با تاثیر معکوس بر خرابی از بیش‌ترین اهمیت برخوردارند.

### ۱- مقدمه

آن کمک می‌کند [۴ و ۳]. مدل‌های پیش‌بینی وضعیت روسازی در دو سطح شبکه و پروژه برای تحلیل وضعیت روسازی و تصمیم‌گیری درباره فعالیت‌های تعمیر و نگهداری استفاده می‌شوند. در سطح شبکه از مدل‌های پیش‌بینی وضعیت روسازی برای تشخیص زمان استفاده از برنامه تعمیر و نگهداری استفاده می‌شود، در صورتی که در سطح پروژه با جزئیات بیشتر، نوع تعمیر و نگهداری نیز برای آن پروژه خاص تعیین می‌گردد [۵ و ۴]. یکی از خرابی‌های اصلی روسازی‌های آسفالتی، شیار شدگی می‌باشد. شیار شدگی از جمله خرابی‌های سازه‌ای روسازی است که بر ایمنی و کیفیت سرویس‌دهی جاده اثر می‌گذارد. خرابی شیار شدگی از تجمیع تغییر شکل‌های ماندگار در لایه رویه یا سایر لایه‌ها ایجاد می‌شود و دلایل مختلفی برای به وجود آمدن این خرابی وجود دارد [۷ و ۶]. علی [۸] این عوامل را به دو دسته داخلی مانند خصوصیات مواد و ساختار روسازی و عوامل خارجی شامل بار

امروزه روسازی راه‌ها بخشی از سرمایه‌های ملی هر کشور محسوب می‌شوند و حفظ و نگهداری آن‌ها در سطح خدمت‌رسانی قابل قبول ضروری است. برای نگه داشتن روسازی در سطح کیفیت قابل قبول، داشتن برنامه زمان‌بندی بهینه برای انجام عملیات تعمیر و نگهداری از اهمیت زیادی برخوردار است [۱]. وظیفه یک سیستم مدیریت روسازی تعیین روش مناسب تعمیر و نگهداری، تعیین اولویت میان قطعه‌های مختلف روسازی و تشخیص زمان بهینه اجرای تعمیر و نگهداری از طریق پیش‌بینی وضعیت روسازی در آینده است [۲]. با استفاده از مدل‌های پیش‌بینی روسازی، وضعیت روسازی در آینده تعیین شده و سیستم مدیریت روسازی بر مبنای نتایج این مدل‌ها به مدیران در تصمیم‌گیری برای انتخاب زمان مناسب برای تعمیر و نگهداشتن روسازی در شرایط عملکردی و خدمت‌پذیری مناسب در طول چرخه عمر



بلند مدت سوئد، توانستند تاثیر عوامل بار ترافیکی، شرایط آب و هوایی، خصوصیات خاک بستر و ساختار روسازی را بر روی خرابی شیار شدگی مورد بررسی قرار دهند. در نزدیک ترین مطالعات انجام گرفته در این زمینه، رادوان<sup>۸</sup> و همکاران [۱۵] با بررسی مناطق گرم و خشک و گرم و مرطوب که شرایط آب و هوایی بیشتر مناطق خاورمیانه را تشکیل می‌دهد، مدلی را توسعه دادند. در این مطالعه تحلیل رگرسیون گام به گام<sup>۹</sup> برای دست‌یابی به عوامل موثر بر روی مدل انجام شد. در این مدل ضریب تعیین برای منطقه گرم و خشک ۰/۴۷۹ و برای منطقه گرم و مرطوب ۰/۲۳۳ است.

با توجه به مرور ادبیات فنی، ملاحظه می‌شود که اکثر مدل‌های توسعه داده شده به منظور پیش‌بینی خرابی شیار شدگی از نوع رگرسیون خطی بوده است. در مطالعات جدید صورت گرفته برای پیش‌بینی وضعیت روسازی، مانند شاخص خرابی ترک خستگی<sup>۱۰</sup>، رتبه‌بندی وضعیت ترک<sup>۱۱</sup>، شاخص بین‌المللی ناهمواری روسازی<sup>۱۲</sup> و غیره از روش‌های یادگیری ماشین استفاده شده است. از جمله این پژوهش‌ها می‌توان به مطالعه فتحي و همکاران [۱۶] اشاره نمود. در این مطالعه برای تهیه داده‌ها، از داده‌های LTPP استفاده شده است. روش یادگیری ماشین، ترکیبی از روش جنگل تصادفی<sup>۱۳</sup> و شبکه عصبی مصنوعی<sup>۱۴</sup> برای پیش‌بینی شاخص خرابی ترک خستگی توسعه داده شده است. ضریب تعیین به دست آمده با این روش ۰/۹۲ بوده است. اینکوم<sup>۱۵</sup> و همکاران [۱۷] با استفاده از داده‌های مدیریت روسازی حمل و نقل فلوریدا<sup>۱۶</sup>، مدلی برای پیش‌بینی وضعیت ترک‌های طولی و عرضی توسعه دادند. در این پژوهش از تقسیم‌بندی بازگشتی<sup>۱۷</sup> شامل درختان رگرسیون و طبقه‌بندی<sup>۱۸</sup> و همچنین از شبکه عصبی مصنوعی استفاده شد. مدل شبکه عصبی توسعه داده شده در این مطالعه دارای ضریب تعیین ۰/۸۹۴ است. در مطالعه‌ی زیادا<sup>۱۹</sup> و همکاران [۱۸] روش‌های مختلف یادگیری ماشین از جمله ماشین‌های بردار پشتیبان<sup>۲۰</sup>، درخت رگرسیون، شبکه عصبی مصنوعی و غیره برای پیش‌بینی شاخص بین‌المللی ناهمواری روسازی استفاده شده است.

8 Radwan

9 Stepwise Regression Analysis (SRA)

10 Alligator Deterioration Index (ADI)

11 Rating Crack Condition (RCC)

12 International Roughness Index (IRI)

13 Random Forest (RF)

14 Artificial Neural Network (ANN)

15 Inkoom

16 FDOT's PMS DATA

17 Recursive Partitioning (RP)

18 Regression And Classification Tree (RACT)

19 Zeiada

20 Support Vector Machine (SVM)

ترافیکی و شرایط محیطی تقسیم نموده است. شیار شدگی روسازی معمولاً در راه‌های پر رفت و آمد مانند تقاطع‌ها و محل عبور و مرور وسایل نقلیه سنگین مشاهده می‌شود [۶].

دو رویکرد قطعی و تصادفی می‌تواند به منظور مدل‌سازی عملکرد روسازی مورد استفاده قرار گیرد. تفاوت عمده بین مدل‌های پیش‌بینی عملکرد قطعی و تصادفی، مفاهیم توسعه مدل، فرمول‌بندی پردازشگر مدل و قالب خروجی مدل‌ها است. انواع مختلفی از مدل‌های قطعی، شامل مدل‌های مکانیکی<sup>۱</sup>، مدل‌های مکانیکی تجربی<sup>۲</sup> و مدل‌های رگرسیونی وجود دارد. مدل‌های مکانیکی رابطه بین پارامترهای پاسخ مانند تنش، کرنش و تغییر شکل را به دست می‌دهد [۹]. مدل‌های مکانیکی تجربی اغلب در ارتباط با سیستم‌های طراحی توسعه می‌یابند؛ بنابراین به طور گسترده در سیستم مدیریت روسازی استفاده نشده‌اند، اما ظرفیت استفاده در سطح شبکه را دارند. از سوی دیگر، مدل‌های رگرسیونی رابطه بین یک پارامتر عملکردی، به عنوان مثال خرابی‌های روسازی و پارامترهای پیش‌بینی کننده مانند ضخامت روسازی، خواص مواد روسازی، بار ترافیکی و سن روسازی را به دست می‌دهد [۱۰ و ۹].

مطالعات مختلفی برای ارائه مدل پیش‌بینی خرابی شیار شدگی انجام شده است. به عنوان مثال، آرا<sup>۳</sup> و همکاران [۱۱] مدلی از نوع مکانیکی تجربی ارائه کردند که عمق شیار شدگی را به کمک کرنش پلاستیک و ضخامت لایه‌های روسازی پیش‌بینی کرده است. عیسی<sup>۴</sup> و همکاران [۱۲] طی مطالعه‌ای در کشور مالزی به توسعه مدلی برای پیش‌بینی عمق شیار شدگی پرداختند. در این پژوهش از متغیرهای سازه‌ای و ترافیکی و روش رگرسیون خطی در تدوین مدل استفاده شده است و ضریب تعیین ( $R^2$ ) مدل نهایی ۰/۷۲۳ می‌باشد. در مطالعه‌ای دیگر نایل<sup>۵</sup> و همکاران [۱۳] با استفاده از داده‌های برنامه بلند مدت روسازی<sup>۶</sup> (LTPP) مدلی برای چهار منطقه آب و هوایی توسعه دادند. ضریب تعیین مدل‌های رگرسیونی خطی ارائه شده برای مناطق سرد و خشک و همچنین گرم و خشک به ترتیب ۰/۷۳۳ و ۰/۵۶۹ است. همچنین دقت مدل برای مناطق سرد و مرطوب و گرم و مرطوب به ترتیب ۰/۶ و ۰/۵۴۱ است و متغیرهای آب و هوایی نیز در این مدل گنجانده شده است. اسونسون<sup>۷</sup> و همکاران [۱۴] با مدل‌سازی آماری داده‌های برنامه

1 Mechanistic

2 Mechanistic Empirical

3 ARA

4 Isa

5 Naiel

6 Long Term Pavement Performance

7 Svensson

است [۲۰]. ارزیابی روش‌های طراحی موجود، بهبود و توسعه روش‌های طراحی روسازی و بررسی تأثیر ویژگی‌های مختلف روسازی بر عملکرد آن از اهداف اصلی این برنامه است [۲۱]. LTPP به دو دسته کلی تقسیم می‌شود که شامل مطالعات عمومی روسازی<sup>۱</sup> و مطالعات خاص روسازی<sup>۲</sup> می‌شود. مطالعات عمومی شامل مجموعه مطالعاتی در ۸۰۰ قطعه راه در حال خدمت‌دهی در ایالات متحده آمریکا و کانادا می‌باشد. از طرف دیگر مطالعات خاص شامل ۱۷۰۰ قطعه روسازی است که با اهداف مشخصی ساخته شده و مورد مطالعه قرار می‌گیرند [۲۲]. LTPP برای همه‌ی محققان در سراسر جهان قابل دسترسی است و می‌تواند به منظور توسعه مدل‌های پیش‌بینی برای اجزای مختلف روسازی و کالیبره کردن مدل‌های موجود استفاده شود.

## ۲-۲- انتخاب داده‌ها

نظر به اینکه هدف اصلی این پژوهش پیش‌بینی میزان خرابی شیار شدگی در روسازی‌های آسفالتی است، مقاطع روسازی از بخش‌های روسازی بتن آسفالتی بر روی اساس دانه‌ای<sup>۳</sup> و روسازی بتن آسفالتی بر روی اساس تثبیت شده<sup>۴</sup> انتخاب شده است. با توجه به دو نوع مقطع ذکر شده در بالا، در مجموع ۳۷۷ مقطع روسازی آسفالتی از ایالت‌های مختلف آمریکا و کانادا برای تهیه داده‌ها انتخاب شد. موقعیت مکانی و تعداد مقاطع مذکور در شکل ۲ قابل مشاهده است. همان‌طور که در این شکل مشاهده می‌شود، مقاطع مورد نظر پراکندگی جغرافیایی مناسبی داشته و شرایط آب و هوایی مختلف را نیز در بر می‌گیرد.

داده‌های مربوط به خرابی شیار شدگی در کلیه مقاطع مورد مطالعه در زمان‌های مختلف استخراج شده است. در انتخاب داده‌های تأثیرگذار بر شکل‌گیری خرابی شیار شدگی (ورودی‌های مدل پیش‌بینی) علاوه بر مرور تحقیقات گذشته، سعی شده است تا اکثر متغیرهای موجود در پایگاه داده عملکرد بلند مدت روسازی مورد بررسی قرار گیرد. لذا متغیرهای مختلف آب و هوایی، ترافیکی و سازه روسازی که از نظر پدیدارشناسی<sup>۵</sup> در بروز این خرابی موثر هستند، انتخاب و استخراج شدند. در جدول ۱ متغیرهای مورد استفاده در این مطالعه به صورت کامل شرح داده شده‌اند.

بالاترین دقت به دست آمده در میان تمامی روش‌ها، روش شبکه عصبی مصنوعی با ضریب تعیین ۰/۸۷ بوده است. از مقایسه این نتایج می‌توان نتیجه‌گیری نمود که دقت روش‌های یادگیری ماشین در تشخیص الگو و مدل‌سازی نسبت به روش‌هایی از جمله روش رگرسیون خطی بالاتر است. با این حال پیچیدگی استفاده از مدل‌های توسعه داده شده بر مبنای روش‌های یادگیری ماشین و عدم ارائه یک رابطه مشخص برای پیش‌بینی شاخص مورد نظر از نقاط ضعف این دسته از مدل‌های پیش‌بینی است.

با توجه به مرور ادبیات انجام شده برای پیش‌بینی خرابی شیار شدگی، ملاحظه می‌شود که انتخاب پارامترهای موثر بر خرابی شیار شدگی با روش‌های ساده انجام شده است که می‌تواند یکی از دلایل دقت پایین مدل‌های توسعه داده شده باشد. هدف از این مطالعه، توسعه مدل پیش‌بینی عمق خرابی شیار شدگی با استفاده از شبکه عصبی مصنوعی است. در راستای پیدا کردن پارامترهای موثر، از الگوریتم فراابتکاری -NSGA II MLP بر مبنای شبکه عصبی و قضاوت مهندسی پدیدار شناسانه استفاده شده است. کشور ایران همانند آمریکا و کانادا دارای اقلیم‌های مختلف آب و هوایی است. با توجه به کمبود اطلاعات منسجم و قابل استناد از وضعیت روسازی‌ها در ایران، در این تحقیق از داده‌های LTPP استفاده شده است و تاثیر عوامل مختلف اعم از شرایط آب و هوایی، ترافیکی و سازه‌ای روسازی بر روی خرابی شیار شدگی مورد بررسی قرار گرفته است.

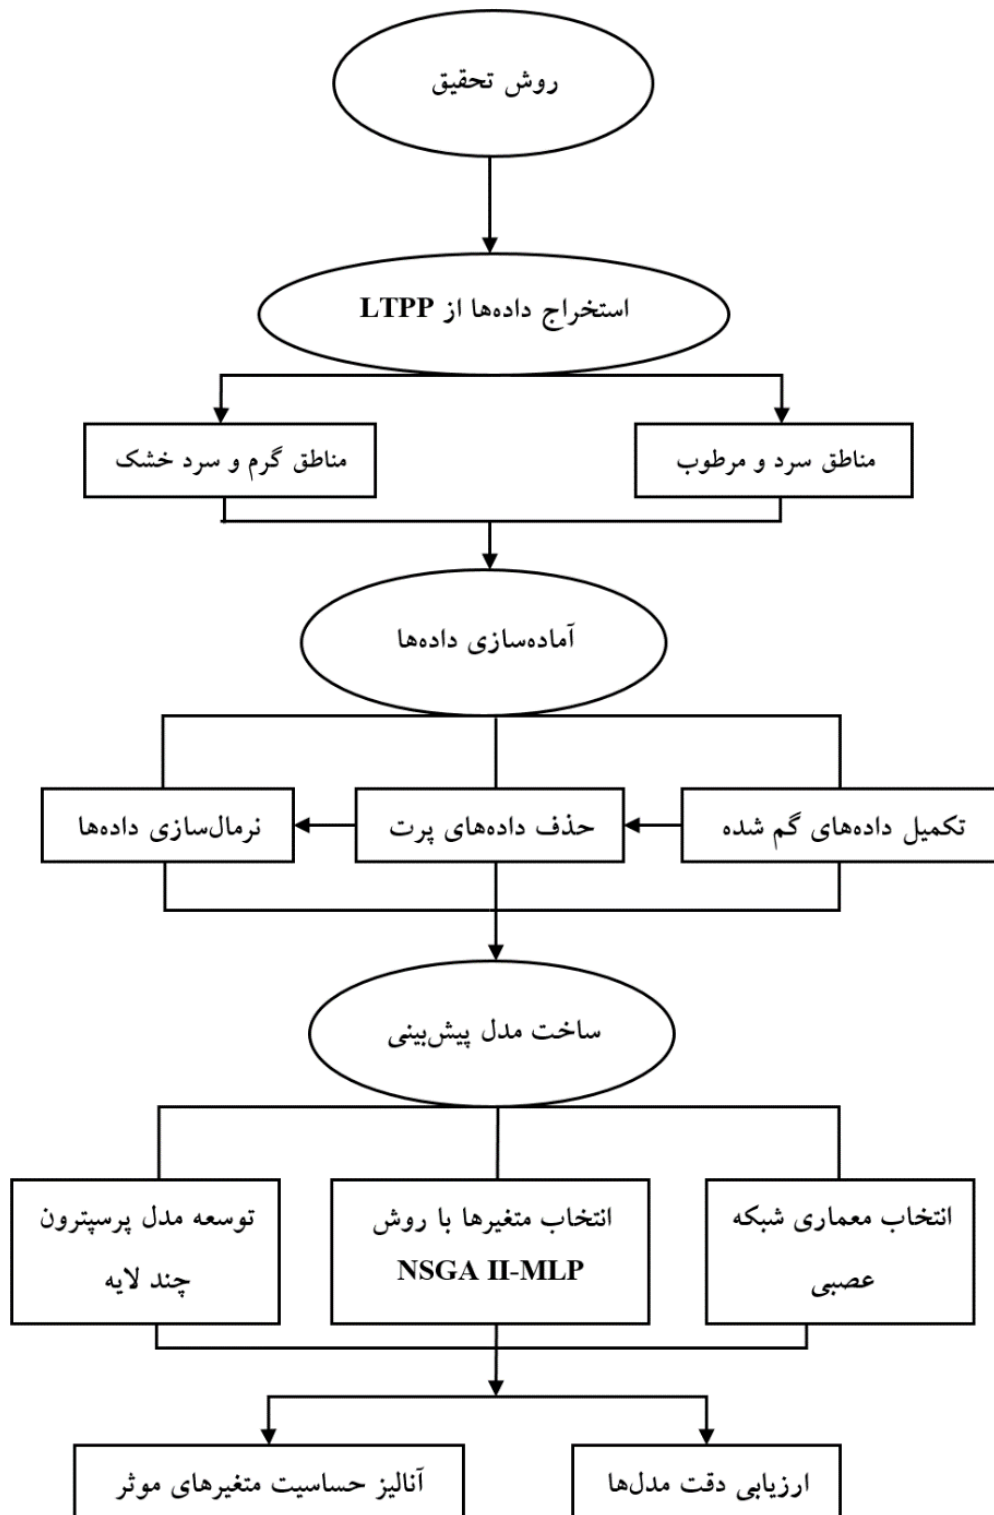
## ۲- روش تحقیق

در این پژوهش داده‌های لازم برای فرآیند مدل‌سازی از LTPP استخراج و سعی شده است در حد امکان از کلیه داده‌های موجود استفاده و داده‌های گم شده و پرت شناسایی، تکمیل یا حذف شود. سپس فرآیند انتخاب متغیرهای موثر ورودی برای توسعه مدل، با روش فراابتکاری -NSGA II MLP انجام گرفت [۱۹]. در ادامه مدل‌سازی به روش پرسپترون چند لایه انجام شده و عملکرد مدل‌های ساخته شده با تحلیل‌های آماری مورد ارزیابی قرار گرفته است. در نهایت با انجام آنالیز حساسیت، تاثیر متغیرهای موثر انتخابی بر روی خرابی شیار شدگی بررسی شده است. فلوچارت روش تحقیق مورد استفاده در این مطالعه در شکل ۱ قابل مشاهده است.

## ۲-۱- برنامه عملکرد بلندمدت روسازی (LTPP)

برنامه عملکرد بلند مدت روسازی یک پایگاه داده قابل اعتماد برای بررسی روسازی‌های انعطاف‌پذیر و صلب در ایالات متحده آمریکا و کانادا


- 1 General Pavement Studies (GPS)
- 2 Specific Pavement Studies (SPS)
- 3 Asphalt concrete pavement on granular base (GPS-1)
- 4 Asphalt concrete pavement on bound base (GPS-2)
- 5 Phenomenological



شکل ۱. نمودار شماتیک روش تحقیق

Fig. 1. Schematic diagram of methodology





شکل ۲. موقعیت مکانی و تعداد مقاطع روسازی انعطاف‌پذیر مورد مطالعه [۲۳]

Fig. 2. Location and number of flexible pavement sections [23]

در این مطالعه سه منطقه آب و هوایی شامل مناطق «سرد و مرطوب»، «گرم و خشک» و «سرد و خشک» مورد بررسی قرار گرفته است. به دلیل کمبود اطلاعات در مناطق گرم و خشک و سرد و خشک، داده‌های این مناطق با یکدیگر ترکیب شده است. در مجموع ۲۲۵ ردیف داده برای مناطق سرد و مرطوب و ۹۵ ردیف داده برای مناطق گرم و سرد خشک حاصل شده است. آماره توصیفی داده‌های استخراج شده در جداول ۲ و ۳ گزارش شده است. با توجه به اینکه مقادیر متغیرها از یک مرتبه نمی‌باشد، یکی از راهکارهای افزایش دقت مدل، نرمال کردن داده‌ها است. تحقیقات صورت گرفته در ادبیات گذشته نشان داده است که استفاده از محدوده ۰/۱ تا ۰/۹ برای نرمال کردن داده‌ها نسبت به بازه صفر تا ۱ نتایج بهتری خواهد داشت [۲۶]. در نتیجه، هر یک از متغیرهای مورد نظر با استفاده از رابطه (۱) بین مقدار ۰/۱ و ۰/۹ نرمال شده‌اند [۲۷].

$$N_i = 0.1 + 0.8 \times \left( \frac{i - i_{\min}}{i_{\max} - i_{\min}} \right) \quad (1)$$

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

## ۲-۳- کمیل داده‌های گمشده و شناسایی داده‌های پرت

در بسیاری از مطالعات وجود داده‌های گمشده اجتناب‌ناپذیر است. محققین همواره سعی می‌کنند با داده‌های گمشده به درستی برخورد کرده و یا از آن اجتناب کنند [۲۴]. با توجه به الگوهای معرفی شده برای مقادیر گمشده توسط لیتل<sup>۱</sup> و روبین<sup>۲</sup> [۲۵]، در این مطالعه می‌توان الگوی کلی را برای این مقادیر در نظر گرفت. به همین منظور از روش جایگزینی مقادیر گمشده با میانگین آن‌ها استفاده شده است. همچنین برای شناسایی داده‌های دور افتاده از ترسیم نمودار جعبه‌ای<sup>۳</sup> استفاده شده است و این مقادیر از داده‌های متغیرهای مستقل حذف گردید.

## ۲-۴- آماده‌سازی داده‌ها

نظر به اینکه هدف اصلی این مطالعه توسعه مدلی به منظور پیش‌بینی شکل‌گیری و گسترش خرابی شیار شدگی در روسازی‌های آسفالتی است، از منظر زمانی از داده‌هایی در ساخت مدل استفاده شده است که عملیات تعمیر و نگهداری روی آن روسازی انجام نشده باشد. بنابراین داده‌ها از روز اول ساخت روسازی برداشت شده و تا زمانی که عملیات تعمیر و نگهداری موثری بر خرابی شیار شدگی انجام نشده باشد، وارد داده‌های مدل‌سازی شده است.

- 1 Little
- 2 Rubin
- 3 Box Plot

جدول ۱. متغیرهای تأثیرگذار مورد بررسی در این مطالعه بر شکل گیری خرابی شیار شدگی

Table 1. The influential variables on the formation of rutting failure studied in this research

نماد متغیر	تعریف متغیر	واحد	نماد متغیر	تعریف متغیر	واحد
MMD	عمق خرابی شیار شدگی	میلی متر	MLDD	حداکثر وزن مخصوص خشک خاک بستر	کیلونیوتن بر متر مربع
UOBB	نوع اساس (صفر: تثبیت نشده ، ۱: تثبیت شده)		OLM	درصد رطوبت بهینه آزمایشگاهی	
MSGA	ماکزیمم وزن مخصوص آسفالت	کیلوگرم بر متر مکعب	MR	مدول برجهندگی خاک بستر	مگاپاسکال
BSGA	میانگین وزن مخصوص توده‌ای آسفالت	کیلوگرم بر متر مکعب	HYD02S	درصد مصالح کوچک‌تر از ۰/۰۲ میلی متر در خاک بستر	
AC	درصد قیر در مخلوط آسفالتی		AGE	تعداد روزهای گذشته از ساخت روسازی	
AV	درصد هوا در مخلوط آسفالتی		CKESAL	مقدار تجمعی تعداد محور استاندارد معادل	
NO4A	درصد عبوری سنگدانه از الک ۴ در مخلوط آسفالتی		AAT	میانگین سالانه دمای هوا	درجه سانتی‌گراد
NO200A	درصد عبوری سنگدانه از الک ۲۰۰ در مخلوط آسفالتی		CTR	مقدار تجمعی اختلاف دمای حداکثر و حداقل روزانه در سال	درجه سانتی‌گراد
SGB	وزن مخصوص قیر خالص	کیلوگرم بر متر مکعب	AAFI	میانگین شاخص یخبندان سالانه	درجه سلسیوس-روز
VIS140	گرانروی قیر خالص در دمای ۶۰ درجه سانتی‌گراد	پاسکال ثانیه	NDT32	تعداد روزهایی از سال با دمای هوای بیشتر از ۳۲ درجه سانتی‌گراد	
PEN77	نفوذپذیری قیر خالص در دمای ۲۵ درجه سانتی‌گراد	میلی متر	C7DHT	مقدار تجمعی دمای ۷ روز گرم سال	درجه سانتی‌گراد
ALT	ضخامت لایه آسفالتی	سانتی متر	LAT	میانگین کمترین دمای سال	درجه سانتی‌گراد
BLT	ضخامت لایه اساس	سانتی متر	CAFT	مقدار تجمعی سالانه تعداد روزهایی که سیکل ذوب و یخبندان در آن اتفاق می‌افتد.	
SLT	ضخامت لایه زیر اساس	سانتی متر	CMAH	مقدار تجمعی حداکثر رطوبت نسبی روزانه در سال	
DRG	متغیر ساختگی (صفر: عدم وجود زهکشی زیرسطحی، ۱: دارای زهکشی زیرسطحی)		ACC	میانگین سالیانه کسر ساعتی پوشش ابر	
NO4S	درصد عبوری سنگدانه از الک شماره ۴ (۴/۷۵ میلی متر) در مصالح خاک بستر		SSA	میانگین تابش موج کوتاه خورشید به سطح برای دوره زمانی مشخص	وات بر متر مربع
NO200S	درصد عبوری سنگدانه از الک شماره ۲۰۰ (۰/۰۷۵ میلی متر) در مصالح خاک بستر		TAP	میانگین سالانه بارش	میلی متر

جدول ۲. آماره توصیفی متغیرهای تأثیرگذار بر خرابی شیار شدگی در مناطق سرد و مرطوب

Table 2. Descriptive statistics of variables affecting rutting failure in wet freeze zones

نماد متغیر	میانگین	انحراف معیار	کمینه	بیشینه	نماد متغیر	میانگین	انحراف معیار	کمینه	بیشینه
MMD	۹/۱۶	۵/۲۷	۱/۰۰	۲۷/۰۰	MLDD	۱۹/۱۷	۱/۶۷	۱۴/۱۴	۲۲/۷۸
UOBB	متغیر dummy				OLM	۱۱/۰۶	۳/۳۰	۶/۰۰	۲۸/۰۰
MSGGA	۲/۴۴	-۰/۱۹	۱/۴۰	۲/۷۴	MR	۹۳/۰۱	۳۰/۱۵	۲۴/۲۰	۲۰۵/۹۷
BSGA	۲/۳۴	-۰/۱۷	۱/۳۱	۲/۵۹	HYD02S	۲۰/۲۹	۱۵/۷۱	۰/۷۰	۷۳/۲۵
AC	۵/۷۱	-۰/۷۶	۳/۳۵	۷/۱۰	AGE	۴۰۹۲/۳۰	۲۳۸۸/۰۵	۲۸۹/۰۰	۱۰۱۳۷/۰۰
AV	۴/۷۳	۲/۱۱	۰/۲۰	۹/۵۰	CKESAL	۱۲۳۸۴۸۳/۷۹	۱۲۲۹۷۶۱/۳۸	۱۶۶۲۷/۰۰	۷۷۵۴۹۲۴/۰۰
NO4A	۵۷/۶۰	۱۵/۷۱	۰/۰۰	۹۹/۰۰	AAT	۷/۰۲	۳/۱۱	۱/۰۰	۱۴/۰۰
NO200A	۴/۹۱	۲/۱۲	۰/۰۰	۱۱/۰۰	CTR	۳۲۴/۲۲	۲۱۵/۷۲	۷۸/۹۱	۱۰۶۲/۳۶
SGB	-۰/۷۸	-۰/۳۵	۰/۰۸	۱/۰۴	AAFI	۷۴۳/۳۴	۴۱۱/۲۱	۱۲۱/۰۰	۱۹۲۸/۰۰
VIS140	۱۲۰/۶۲	۶۵/۹۰	۱۰/۲۸	۳۶۶/۹۰	NDT32	۱۲/۴۹	۱۳/۵۱	۰/۰۰	۶۷/۳۴
PEN77	۷۹/۳۶	۳۳/۸۸	۶/۸۰	۱۵۸/۰۰	C7DHT	۸۳۸/۳۳	۳۴۵/۴۰	۱۹۷/۳۶	۱۸۴۶/۲۷
ALT	۱۵/۵۳	۹/۱۳	۲/۷۵	۴۰/۲۵	LAT	-۲۰/۲۰	۵/۶۱	-۳۲/۸۵	-۸/۳۹
BLT	۱۹/۳۰	۱۵/۲۹	۰/۰۰	۷۰/۰۰	CAFT	۲۰۲۳/۱۴	۹۱۲/۱۲	۶۸/۰/۰۰	۴۵۵/۰/۰۰
SLT	۲۴/۴۰	۲۸/۸۶	۰/۰۰	۱۸۷/۵۰	CMAH	۹۳۴/۴۴	۳۴۳/۱۶	۵۱۳/۰۰	۲۱۷۴/۰۰
DRG	متغیر dummy				ACC	۰/۵۶	۰/۰۶	۰/۴۲	۰/۶۹
NO4S	۶۸/۱۱	۱۸/۰۸	۳۰/۲۵	۱۰۰/۰۰	SSA	۱۲۳۳۷۷/۲۹	۱۶۹۵۶/۸۷	۷۸۵۱۲/۷۷	۱۶۴۹۸۲/۹۴
NO200S	۲۱/۹۲	۱۹/۴۲	۰/۳۵	۹۷/۵۰	TAP	۸۷۷/۹۷	۳۱۶/۵۰	۲۲۸/۵۶	۱۸۷۸/۳۴

۲-۵- بکه عصبی پرسپترون چند لایه

الگوریتم‌های شبکه عصبی مصنوعی یکی از کارآمدترین و محبوب‌ترین ابزارهای یادگیری ماشین محسوب می‌شوند. شبکه‌های عصبی مصنوعی بر اساس ساختار فیزیولوژیکی و مکانیسم مغز انسان کار می‌کند و قادر است مسائل پیچیده را با دقت بالا حل کند. با توجه به ماهیت مسئله، این ابزار به عنوان یک روش پردازش داده به صورت رگرسیون یا دسته‌بندی برای پیش‌بینی خروجی مسئله شناخته می‌شود. در این مطالعه از شبکه عصبی پرسپترون چند لایه<sup>۱</sup> برای پیش‌بینی عمق شیار شدگی در روسازی آسفالتی استفاده شده است. نورون‌ها عناصر اصلی شبکه‌های عصبی مصنوعی هستند که به عنوان عناصر پردازشگر شناخته می‌شوند. با اتصال نورون‌ها به یکدیگر شبکه‌ای تشکیل می‌شود که در آن نورون‌ها به طور همزمان در یک گروه عمل می‌کنند. شبکه شامل لایه ورودی، یک یا چند لایه پنهان و لایه خروجی است. هر نورون مصنوعی اطلاعاتی را که از نورون‌های دیگر دریافت کرده است پردازش می‌کند. سپس اطلاعات خود را به سایر نورون‌ها منتقل می‌کند. معماری شماتیک کلی شبکه عصبی در شکل ۳ نمایش داده

شده است. یک نورون سیگنال‌های ورودی شامل  $X_0$  تا  $X_n$  را دریافت کرده و برای هر یک وزنی ( $W_i$ ) در نظر می‌گیرد. این وزن قدرت اتصال آن ورودی را برای هر اتصال نشان می‌دهد و ممکن است در طول فرآیند آموزش شبکه تغییر کند. سپس هر سیگنال ورودی در وزن اتصال مربوط به خود ضرب می‌شود. عدد ثابت ( $b$ ) نیز به عنوان یک نوع وزن اتصال ثابت با مقدار غیرصفر به جمع ورودی‌ها و وزن‌های مربوط به آن‌ها اضافه می‌گردد. مقدار خروجی نورون ( $net$ ) به یک تابع فعال‌ساز یا انتقال ارسال شده و در انتها با نگاشت تابع انتقال بر ورودی ترکیبی مقدار خروجی نورون ( $Z$ ) به دست می‌آید [۳۰-۲۸]. شکل ۴ نحوه عملکرد نورون مصنوعی را نشان داده است. نحوه محاسبه مقدار  $net$  و  $Z$  در روابط (۲) و (۳) بیان شده است [۳۱].

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


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

1 Multi Layer Perceptron (MLP)

جدول ۳. آماره توصیفی متغیرهای تأثیرگذار بر خرابی شیار شدگی در مناطق گرم و خشک و سرد و خشک


Table 3. Descriptive statistics of variables affecting rutting failure in dry no freeze and dry freeze zones

نماد متغیر	میانگین	انحراف معیار	کمینه	بیشینه	نماد متغیر	میانگین	انحراف معیار	کمینه	بیشینه
MMD	۸/۵۹	۵/۰۰	۲/۰۰	۲۹/۰۰	MLDD	۳/۶۹	۲/۷۸	۰/۶۰	۱۴/۳۶
UOBB	متغیر dummy				OLM	۱۱۶/۳۶	۹/۴۰	۱۰۰/۰۰	۱۳۷/۰۰
MSGA	۲/۴۲	۰/۱۲	۱/۹۱	۲/۶۱	MR	۱۳/۲۵	۳/۹۴	۷/۵۰	۲۴/۰۰
BSGA	۲/۳۲	۰/۱۱	۱/۷۳	۲/۴۸	HYD02S	۸۲/۶۰	۲۶/۴۲	۴۰/۱۰	۱۵۶/۶۵
AC	۵/۴۹	۰/۵۲	۴/۲۰	۶/۶۰	AGE	۴۲۰۵/۵۹	۲۰۱۸/۲۶	۴۸۹/۰۰	۸۱۳۹/۰۰
AV	۴/۳۶	۱/۵۱	۱/۴۰	۱۰/۱۰	CKESAL	۱۹۷۸۱۸۵/۶۶	۲۵۵۷۶۴۸/۴۲	۳۸۰۹۸/۰۰	۱۵۳۶۹۳۰۹/۰۰
NO4A	۶۳/۳۶	۱۱/۸۷	۰/۰۰	۸۵/۰۰	AAT	۱۴/۰۲	۵/۷۷	۲/۰۰	۲۵/۰۰
NO200A	۴/۹۴	۱/۶۰	۲/۰۰	۱۱/۰۰	CTR	۳۷۲/۹۸	۲۱۶/۱۰	۱۰۶/۵۶	۱۰۵۸/۰۰
SGB	۰/۹۸	۰/۱۷	۰/۱۲	۱/۰۴	AAFI	۲۲۰/۳۲	۳۶۲/۶۵	۰/۰۰	۱۸۳۴/۰۰
VIS140	۱۵۳/۶۷	۸۳/۶۵	۹/۱۶	۳۳۵/۲۰	NDT32	۶۹/۸۲	۵۴/۴۲	۳/۶۹	۱۷۷/۵۰
PEN77	۹۰/۳۷	۳۱/۱۵	۳۲/۰۰	۱۶۳/۰۰	C7DHT	۱۱۰۹/۲۵	۵۴/۰۶۴	۲۵۴/۴۶	۲۲۲۸/۵۱
ALT	۱۳/۱۸	۶/۱۹	۲/۵۰	۳۱/۵۰	LAT	-۶/۹۸	۱۱۰/۳	-۳۲/۳۹	۱۹/۳۹
BLT	۲۰/۴۳	۱۱/۲۸	۰/۰۰	۵۷/۰۰	CAFT	۱۶۶۰/۰۹	۱۳۷/۰۵۰	۰/۰۰	۴۸۴۰/۰۰
SLT	۱۲/۱۵	۱۹/۳۵	۰/۰۰	۷۸/۵۰	CMAH	۵۰۷/۰۶	۱۱۱/۷۱	۳۲۴/۰۰	۹۵۰/۰۰
DRG	متغیر dummy				ACC	۰/۳۸	۰/۰۷	۰/۲۷	۰/۵۶
NO4S	۷۳/۱۰	۱۴/۰۳	۳۶/۲۵	۱۰۰/۰۰	SSA	۱۶۷۵۱/۰۰۰	۱۵۱۲۹/۱۸	۱۱۷۷۲۳/۷۰	۱۸۹۰۰۸/۴۱
NO200S	۲۲/۸۰	۱۲/۶۸	۵/۷۰	۶۸/۴۵	TAP	۳۱۱/۲۸	۱۳۴/۳۷	۷۸/۲۲	۶۴۸/۵۷



شکل ۳. معماری شبکه عصبی مصنوعی

Fig. 3. Artificial neural network architecture



شکل ۴. نحوه عملکرد نورون در شبکه عصبی

Fig. 4. Neurons function in the neural network

پیش از اجرای شبکه، داده‌ها به سه دسته آموزش<sup>۷</sup> (۷۰ درصد کل داده‌ها)، آزمایش<sup>۸</sup> (۱۵ درصد کل داده‌ها) و اعتبارسنجی<sup>۹</sup> (۱۵ درصد کل داده‌ها) تقسیم شده‌اند. در این مطالعه با توجه به ادبیات موجود و همچنین بررسی‌های جدید صورت گرفته حالات مختلف تعداد لایه پنهان (یک و دو لایه)، تعداد نورون (از ۱ تا ۳۰ نورون برای هر لایه پنهان)، توابع انتقال شامل توابع سیگموئید مختلف (TANSIG و LOGSIG) و همچنین روش‌های بهینه‌سازی شبکه مبتنی بر انتشار رو به عقب خطا (TRAINLM<sup>۱۰</sup> و TRAINSCG<sup>۱۱</sup>) در نظر گرفته شده است [۳۳-۳۴].

## ۲-۶- انتخاب موثرترین متغیرها با روش NSGA II-MLP

به منظور توسعه یک مدل مهندسی و کارآمد که در عین دقیق بودن ویژگی سادگی و سهولت استفاده را نیز داشته باشد، لازم است متغیرهایی که میزان اهمیت بیشتری در پیش‌بینی خرابی شیار شدگی دارند مشخص شوند. با توجه به اینکه تعداد متغیرهای موجود در این مطالعه برای پیش‌بینی خرابی بسیار زیاد است، می‌بایست تعداد متغیرهای ورودی مدل کاهش یابد. به این منظور یک مسئله بهینه‌سازی با دو تابع هدف تعریف شده است که تابع هدف اول مربوط به کمینه کردن تعداد متغیرهای ورودی و تابع هدف دوم مربوط به بیشینه کردن میزان دقت مدل شبکه عصبی است. با استفاده از روش NSGA II-MLP داده‌های ورودی مدل‌های مربوط به هر یک از مناطق آب و هوایی مورد مطالعه انتخاب شده است. سرانجام با استفاده از متغیرهای ورودی منتخب و آموزش شبکه عصبی با آن‌ها مدل‌های مورد نظر برای دو منطقه توسعه داده شده است.

الگوریتم NSGA II<sup>۱۲</sup> روش بهینه‌سازی مبتنی بر الگوریتم ژنتیک است. بر خلاف سایر روش‌های بهینه‌سازی تک هدفه این الگوریتم می‌تواند بهینه‌سازی را همزمان روی چند تابع هدف که با هم در تناقض هستند انجام دهد که منجر به ایجاد چندین جواب بهینه می‌گردد [۳۵ و ۱۹]. روند بهینه‌سازی در این الگوریتم به این صورت است که در ابتدا جمعیت اولیه تصادفی به اندازه N ایجاد شده است. سپس در گام دوم مقادیر توابع هدف برای جمعیت ایجاد شده محاسبه می‌گردد. جمعیت موجود در این مرحله بر

مقادیر وزن‌ها و عدد ثابت موجود در نورون‌ها با استفاده از روش بهینه‌سازی مورد استفاده در شبکه عصبی تعیین می‌شود. معمولاً مبنای عملکرد این روش‌ها به صورتی است که ابتدا مقادیر تصادفی برای وزن‌ها و عدد ثابت در نظر گرفته و با اجرای شبکه خطای مدل‌سازی به دست می‌آید. سپس با انتشار رو به عقب خطا در شبکه، وزن‌ها و عدد ثابت تغییر می‌کند تا خطا در چرخه بعدی پیش‌بینی کاهش یابد. از جمله انواع متداول توابع انتقال می‌توان به توابع گاوسی<sup>۱</sup> و سیگموئید<sup>۲</sup> اشاره کرد. توابع سیگموئید به دلیل متنوع بودن رواج بیشتری دارند، مانند تابع انتقال سیگموئید مماسی هذلولی<sup>۳</sup> (TANSIG)، سیگموئید لگاریتمی<sup>۴</sup> (LOGSIG) و تابع انتقال خطی<sup>۵</sup> (PURELIN) که بیشتر در شبکه عصبی استفاده می‌شود. روابط (۴) تا (۶) معادلات این توابع فعال‌ساز را نشان می‌دهد.

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

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

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

در گام بعد می‌بایست معماری شبکه عصبی شامل تعداد لایه‌های پنهان، تعداد نورون‌ها در هر یک از لایه‌های پنهان، نوع تابع انتقال نورون‌های مصنوعی و همچنین نوع روش بهینه‌سازی شبکه انتخاب گردد. روش قطعی برای تعیین معماری شبکه عصبی مصنوعی وجود ندارد. با توجه به اینکه ماهیت کارکرد شبکه به صورت تصادفی است، لذا بهترین روش برای انتخاب معماری شبکه عصبی، آزمون و خطا است [۳۲]. با استفاده از این روش برای حالات مختلف هر یک از عناصر معماری، شبکه به تعداد مناسبی (۳۰ بار برای هر حالت) اجرا شده و در نهایت معماری که کمترین مقدار میانگین مربعات خطا<sup>۶</sup> (MSE) را داشته باشد، برای حل مسئله انتخاب می‌شود.

- 
- 7 Train
  - 8 Test
  - 9 Validation
  - 10 Levenberg-Marquardt
  - 11 Scaled Conjugate Gradient
  - 12 Non-dominated Sorting Genetic Algorithm-II

- 
- 1 Gaussian
  - 2 Sigmoid
  - 3 Hyperbolic tangent sigmoidal transfer function
  - 4 Logarithmic sigmoidal transfer function
  - 5 Pure linear transfer function
  - 6 Mean Squared Error

خطا<sup>۹</sup> (MSE)، ریشه نسبی میانگین مربعات خطا<sup>۱۰</sup> (RRMSE)، میانگین خطای مطلق<sup>۱۱</sup> (MAE) و ریشه میانگین مربعات خطا<sup>۱۲</sup> (RMSE) دقت مدل‌ها مورد بررسی قرار گرفتند. روابط (۷) تا (۱۴) معادلات مربوط به محاسبه این شاخص‌ها را نشان می‌دهد [۳۸ و ۳۹].

$$R = \frac{\sum_{i=1}^n (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (7)$$

$$R^2 = \left( \frac{\sum_{i=1}^n (T_i - \bar{T})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (T_i - \bar{T})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (8)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (P_i - T_i)^2}{\sum_{i=1}^n (T_i - \bar{T})^2} \quad (9)$$

$$SI = \sqrt{\frac{\sum_{i=1}^n [(T_i - \bar{T}) - (P_i - \bar{P})]^2}{\sum_{i=1}^n T_i^2}} \quad (10)$$

$$MSE = \frac{\sum_{i=1}^n (T_i - P_i)^2}{n} \quad (11)$$

$$RRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (T_i - P_i)^2}}{\sum_{i=1}^n T_i} \times 100 \quad (12)$$

اساس دو پارامتر شروط نامغلوب<sup>۱</sup> و فاصله ازدحامی<sup>۲</sup> رتبه‌بندی می‌شوند. در گام بعدی با استفاده از عملگرهای جهش<sup>۳</sup> و ترکیب<sup>۴</sup>، پاسخ‌ها بهبود یافته و جمعیت‌های جهش‌یافتگان و فرزندان ایجاد می‌شوند. سرانجام از بین جمعیت کل به دست آمده که مجموع سه جمعیت اولیه، جهش‌یافتگان و فرزندان است، جمعیتی به اندازه N انتخاب می‌شود. در صورتی که پاسخ بهینه حاصل نشد، مراحل ذکر شده از گام دوم به بعد تکرار شده تا جواب بهینه به دست آید [۳۶].

در این مطالعه از یک مسئله بهینه‌سازی عدد صحیح استفاده شده است که در آن پاسخ هر متغیر تصمیم می‌تواند عدد صفر و یا ۱ باشد. در این مسئله متغیرهای تصمیم همان متغیرهای ورودی مدل هستند که در صورت گرفتن پاسخ ۱ آن متغیر انتخاب و در غیر این صورت رد می‌شود [۳۷]. همانطور که پیشتر نیز اشاره شد دو تابع هدف در این مسئله بهینه‌سازی وجود دارد که تابع هدف اول مربوط به کمینه کردن تعداد متغیرهای ورودی و تابع هدف دوم مرتبط با بیشینه کردن میزان دقت مدل شبکه عصبی می‌باشد.

پس از ایجاد جمعیت اولیه تصادفی، مقدار تابع هدف اول برای هر دسته جواب ثبت شده و در محاسبه مقدار تابع هدف دوم برای هر دسته جواب S بار شبکه عصبی اجرا (در این مطالعه ۳۰ بار) و بیشترین مقدار ضریب تعیین ثبت شده است. همان‌طور که پیش‌تر ذکر شد مراحل از گام دوم به بعد تا رسیدن به جواب‌های بهینه ادامه می‌یابد. در نهایت چندین جواب که هیچ کدام جواب دیگر را مغلوب نمی‌کند، با شرایط مختلف به عنوان جواب‌های بهینه ارائه می‌شوند. پس از انتخاب متغیرهای با اهمیت بالا در پیش‌بینی خرابی شیار شدگی برای هر منطقه آب و هوایی، دو مدل شبکه عصبی مصنوعی با توجه به روش بیان شده ساخته شده است.

## ۲-۷- ارزیابی دقت مدل‌ها

شاخص‌های آماری مختلفی برای ارزیابی دقت مدل‌ها وجود دارد. در این پژوهش با استفاده از ضریب همبستگی<sup>۵</sup> (R)، ضریب تعیین<sup>۶</sup> (R<sup>2</sup>) ضریب کارایی نش-ساتکلیف<sup>۷</sup> (NSE)، شاخص پراکندگی<sup>۸</sup> (SI)، میانگین مربعات

- 
- 9 Mean Squared Error
  - 10 Relative Root Mean Square Error
  - 11 Mean Absolute Error
  - 12 Root Mean Square Error

- 
- 1 Non-Dominated
  - 2 Crowding Distance
  - 3 Mutation
  - 4 Crossover
  - 5 Correlation Coefficient
  - 6 Coefficient of Determination
  - 7 Nash-Sutcliffe Coefficient
  - 8 Scatter Index

و روش بهینه‌سازی برای یک لایه پنهان بررسی شدند. همان‌طور که در شکل ۵-الف مشاهده می‌شود، چهار نمودار برای هر کدام از حالات مختلف تابع انتقال و روش بهینه‌سازی با رنگ‌های متفاوت نمایش داده شده است. محور افقی تعداد نورون مربوط به یک لایه پنهان و محور قائم میانگین مربعات خطای شبکه عصبی می‌باشد. سرانجام با توجه به شکل ۵-الف برای مناطق سرد و مرطوب تابع انتقال TANGSIG به همراه روش بهینه‌سازی TRAINSCG و برای مناطق گرم و سرد خشک تابع انتقال LOGSIG به همراه روش بهینه‌سازی TRAINSCG که کمترین مقدار میانگین مربعات خطا را نسبت به سه حالت دیگر داشته است، انتخاب شد. در گام دوم با استفاده از تابع انتقال و روش بهینه‌سازی انتخاب شده برای یک لایه پنهان، تعداد نورون‌های مختلف برای دو لایه پنهان مورد بررسی قرار گرفته است. همان‌طور که در شکل ۵-ب مشاهده می‌گردد، ۶ نمودار برای حالات مختلف تعداد نورون‌های لایه اول (اعداد ۵، ۱۰، ۱۵، ۲۰، ۲۵ و ۳۰) با رنگ‌های متفاوت در مقابل تعداد نورون‌های لایه دوم (اعداد ۱ تا ۳۰) در محور افقی نمایش داده شده است. محور قائم در این نمودار میانگین مربعات خطای شبکه عصبی برای هر اجرا می‌باشد. همانند گام اول با ۳۰ بار اجرای شبکه عصبی برای هر حالت، ۵۴۰۰ حالت مختلف برای هر تعداد نورون در لایه اول و دوم به صورت مجزا بررسی و آن مجموعه جواب که دارای کمترین خطاست، استفاده شده است. سرانجام با توجه به شکل ۵-ب برای مناطق سرد و مرطوب دو لایه پنهان با ۳۰ نورون در لایه اول (نمودار سبز رنگ) و ۸ نورون در لایه دوم و برای مناطق گرم و سرد خشک دو لایه پنهان با ۲۰ نورون در لایه اول (نمودار زرد رنگ) و ۳ نورون در لایه دوم که نسبت به سایر حالات کمترین میانگین مربعات خطا را داشتند انتخاب شده است.

### ۳-۲- نتخاب متغیرهای موثر

پس از انتخاب معماری شبکه عصبی، الگوریتم بهینه‌سازی NSGA II-MLP روی داده‌های هر منطقه اجرا شده است. همان‌طور که در بخش ۲-۶ توضیح داده شد، مجموعه جواب برای دو تابع هدف که تعداد متغیرهای انتخابی و مقدار ضریب تعیین مدل‌سازی است، به دست آمد. در شکل ۶ خروجی الگوریتم بهینه‌سازی قابل مشاهده است که در آن محور افقی تعداد متغیر انتخاب شده و محور قائم ضریب تعیین مدل‌سازی با آن متغیرها است. لازم به ذکر است که هر کدام از نقاط نشان داده شده در شکل نشان دهنده یک مجموعه جواب از متغیرهای انتخاب شده با استفاده از الگوریتم

$$MAE = \frac{1}{n} \sum_{i=1}^n (|T_i - P_i|) \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (T_i - P_i)^2}{n}} \quad (14)$$

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.


### ۳- نتایج و بحث

در این مطالعه مقدار عمق خرابی شیار شدگی با استفاده از ابزار شبکه عصبی مصنوعی پیش‌بینی شده است. در این بخش نتایج حاصل از مدل‌های ساخته شده برای هر منطقه آب و هوایی ارائه شده است. در گام اول معماری شبکه عصبی بر روی تمامی داده‌های موجود در هر منطقه با روش آزمون و خطا انتخاب شده است. در مرحله دوم با استفاده از الگوریتم بهینه‌سازی NSGA II-MLP متغیرهای تاثیرگذار بر خرابی شیار شدگی شناسایی شده است. معماری شبکه عصبی با متغیرهای منتخب مجدداً تعیین شده و در گام سوم دقت مدل‌های ساخته شده مورد ارزیابی قرار گرفته است. در مرحله آخر آنالیز حساسیت متغیرهای انتخاب شده بر خرابی شیار شدگی با استفاده از مدل‌های توسعه داده شده برای هر منطقه مورد بررسی قرار گرفته است.

### ۳-۱- انتخاب معماری شبکه عصبی

در این مطالعه از شبکه عصبی با دو لایه پنهان برای توسعه مدل استفاده شده است. با توجه به اینکه شبکه عصبی دارای ماهیت تصادفی است، انتخاب معماری شبکه عصبی بر اساس روش آزمون و خطا انجام شده است. در این بخش از داده‌های تمامی متغیرهای مستقل ورودی به هر کدام از مدل‌ها استفاده شده است. در گام اول برای یک لایه پنهان، تابع انتقال و روش بهینه‌سازی انتخاب شده است. همان‌طور که در بخش ۲ بیان شد، شبکه ۳۰ بار برای حالات مختلف تعداد نورون (۳۰ حالت) اجرا شده است. در انتها پس از ۳۶۰۰ بار اجرای شبکه عصبی، حالات مختلف تابع انتقال






شکل ۵. میانگین مربعات خطا برای معماری‌های مختلف با در نظر گرفتن (الف) یک لایه پنهان، و (ب) دو لایه پنهان

Fig. 5. Mean square error for different architectures considering (a) one hidden layer, and (b) two hidden layers

همان‌طور که در جدول ۴ مشاهده می‌شود، متغیر سن روسازی در هر دو مدل موثر شناسایی شده که بیان‌کننده اهمیت زمان بر خرابی شیار شدگی است. عوامل موثر ترافیکی (بار هم ارز معادل)، سازه‌ای (ضخامت آسفالت، نوع اساس، و تراکم خاک بستر)، مشخصات مواد و مصالح روسازی (نفوذپذیری قیر و درصد عبوری الک از شماره ۴ و ۲۰۰) و آب و هوایی (سیکل ذوب و یخبندان و اختلاف حداکثر و حداقل دما) در توسعه مدل‌ها استفاده شده است که در بخش آنالیز حساسیت تاثیر هر کدام بر خرابی شیار شدگی بررسی شده است.

NSGA II-MLP می‌باشد. واضح است که با افزایش تعداد متغیرهای انتخابی مقدار دقت مدل افزایش پیدا کرده است، اما هدف در این مسئله کمینه‌سازی تعداد متغیرهای ورودی (به منظور کاهش میزان پیچیدگی و سهولت استفاده از مدل) و بیشینه‌سازی دقت مدل شبکه عصبی است. همان‌طور که در شکل ۶ مشاهده می‌شود در مناطق سرد و مرطوب با ۷ متغیر ورودی (شکل ۶-الف) و در مناطق گرم و خشک با ۸ متغیر (شکل ۶-ب) ضریب تعیین مدل‌ها به بیشترین مقدار رسیده است. نام متغیرهای انتخاب شده با استفاده از الگوریتم بهینه‌سازی برای هر کدام از مناطق مورد بررسی در جدول ۴ آمده است.




شکل ۶. ضریب تعیین مدل سازی با متغیرهای انتخاب شده برای مناطق (الف) سرد و مرطوب و (ب) گرم و خشک و سرد و خشک

**Fig. 6. Coefficient of determination of the developed model with selected variables for (a) wet freeze and (b) dry no freeze and dry freeze zones**

جدول ۴. متغیرهای انتخاب شده به عنوان عوامل تأثیرگذار بر خرابی شیار شدگی در مناطق آب و هوایی مورد بررسی

**Table 4. Selected variables as effective factors on rutting failure in the studied climatic zones**

مناطق گرم و خشک و سرد و خشک	مناطق سرد و مرطوب	متغیرهای انتخاب شده
UOBB	AGE	۱
AGE	CAFT	۲
CAFT	CKESAL	۳
CKESAL	CTR	۴
CTR	ALT	۵
PEN77	NO4S	۶
ALT	MLDD	۷
NO4A	-	۸
NO200A	-	۹



شکل ۷. نتایج شبکه عصبی مصنوعی ساخته شده با متغیرهای انتخاب شده برای مناطق سرد و مرطوب

Fig. 7. Artificial neural network results made with selected variables for wet freeze zones


(ت) مقادیر خطا در هر کدام از ردیف داده‌ها نشان داده شده و در نهایت مقدار میانگین مربعات خطا و ریشه میانگین مربعات خطا گزارش شده است. با توجه به شکل ۷-ت مقدار میانگین مربعات خطا و ریشه میانگین مربعات خطا برای مدل مناطق سرد و مرطوب به ترتیب حدوداً ۲/۰۵ و ۱/۴۳ به دست آمده است. مقادیر ذکر شده برای مدل مناطق گرم و سرد خشک (شکل ۸-ت) به ترتیب حدود ۳/۴۵ و ۱/۸۶ محاسبه شده است. نتایج حاصل شده از مدل‌های توسعه داده شده برای هر منطقه حاکی از آن است که خطای مدل در پیش‌بینی مقادیر خروجی (عمق شیار شدگی) بسیار ناچیز بوده و شبکه عصبی به خوبی آموزش دیده است.

برای بررسی هر چه بهتر عملکرد شبکه عصبی با توجه به معادلات (۷) تا (۱۴)، دقت مدل‌ها و میزان خطای سه دسته داده‌ی آموزش، آزمایش و اعتبارسنجی برای هر مدل به صورت جداگانه محاسبه شده است. در جدول ۵ مقدار شاخص‌های آماری برای مدل مناطق سرد و مرطوب و مدل مناطق گرم و خشک و سرد و خشک نشان داده شده است.

با توجه به نتایج این بخش می‌توان دریافت که ضرایب تعیین هر دو مدل نسبت به کارهای پیشین بالاتر بوده و نشان دهنده توانمندی شبکه عصبی مصنوعی در پیش‌بینی عمق خرابی شیار شدگی در روسازی‌های آسفالتی است. از جمله دلایل این امر می‌توان به بررسی گسترده وسیعی از متغیرهای موجود، استفاده از روش کارآمد و جدید NSGA II-MLP جهت انتخاب متغیرهای تأثیرگذار و در نهایت انتخاب بهترین معماری و آموزش صحیح شبکه عصبی اشاره کرد.

### ۳-۳- مدل‌سازی نهایی با متغیرهای منتخب

با استفاده از متغیرهای انتخاب شده در مرحله قبل و انتخاب مجدد معماری با استفاده از این داده‌ها، مدل شبکه عصبی مصنوعی برای هر منطقه توسعه داده شد. نتایج کلی مدل‌سازی برای داده‌های هر منطقه در شکل‌های ۷ و ۸ قابل مشاهده است. در تصویر (الف) هر دو شکل، ارتباط بین مقادیر پیش‌بینی شده و مقادیر واقعی (هدف) مشاهده می‌شود. هر چه نقاط به خط  $y = x$  نزدیک‌تر باشند، به این معناست که مقادیر پیش‌بینی شده و هدف به یکدیگر نزدیک‌تر بوده و مدل از دقت بالاتری برخوردار است. همان‌طور که مشخص است، نقاط به خط  $y = x$  نزدیک بوده و مدل‌ها از ضریب همبستگی (R) بالایی برخوردارند. ضریب همبستگی کلی مدل شبکه عصبی برای مناطق سرد و مرطوب حدوداً ۰/۹۶ (شکل ۷-الف) و برای مناطق گرم و سرد خشک حدوداً ۰/۹۴ (شکل ۸-الف) به دست آمده است. در تصویر (ب) اختلاف مقادیر پیش‌بینی شده با مقادیر مشاهده‌ای برای هر کدام از ردیف داده‌ها بررسی شده است. همان‌طور که در شکل‌های ۷-ب و ۸-ب مشاهده می‌شود، مقادیر پیش‌بینی شده مدل‌های شبکه عصبی به خوبی بر داده‌های مشاهده‌ای متناسب شده است. همچنین در تصویر (پ) منحنی توزیع خطا رسم و مقادیر میانگین و انحراف معیار خطای مدل محاسبه شده است. با توجه به شکل ۷-پ برای مدل مناطق سرد و مرطوب مقدار میانگین و انحراف معیار خطا به ترتیب حدوداً ۰/۳۴- و ۱/۴۰ به دست آمده است. همچنین این مقادیر برای مدل مناطق گرم و سرد خشک (شکل ۸-پ) به ترتیب حدوداً ۰/۰۶ و ۱/۸۷ محاسبه شده است. سرانجام در تصویر



شکل ۸. نتایج شبکه عصبی مصنوعی ساخته شده با متغیرهای انتخاب شده برای مناطق گرم و خشک و سرد و خشک

Fig. 8. Artificial neural network results made with selected variables for dry no freeze and dry freeze zones

جدول ۵. شاخص‌های آماری مدل‌های توسعه داده شده برای مناطق آب و هوایی مورد بررسی


Table 5. Statistical indicators of the developed models for the studied climatic zones

مناطق گرم و خشک و سرد و خشک			مناطق سرد و مرطوب			شاخص‌های آماری
اعتبارسنجی	آزمایش	آموزش	اعتبارسنجی	آزمایش	آموزش	
۰/۹۷	۰/۹۲	۰/۹۸	۰/۹۴	۰/۹۴	۰/۹۷	R
۰/۹۴	۰/۸۴	۰/۹۶	۰/۸۸	۰/۸۸	۰/۹۴	R <sup>2</sup>
۰/۶۱	۰/۸۰	۰/۹۶	۰/۸۹	۰/۸۸	۰/۹۴	NSE
۰/۳۲	۰/۲۲	۰/۰۹	۰/۱۷	۰/۱۶	۰/۱۰	SI
۱۱/۷۱	۷/۹۲	۰/۷۹	۴/۳۵	۳/۷۳	۱/۱۹	MSE
۲/۸۵	۲/۰۵	۰/۱۶	۰/۶۰	۰/۵۵	۰/۰۸	RRMSE
۲/۱۱	۲/۱۶	۰/۶۲	۱/۶۵	۱/۴۴	۰/۸۴	MAE
۳/۴۲	۲/۸۱	۰/۸۸	۲/۰۹	۱/۹۳	۱/۰۹	RMSE

ردیف داده‌های ورودی به شبکه عصبی انجام شده است. روند انجام کار به گونه‌ای است که به متغیر انتخاب شده ۲۱ عدد با تصاعد حسابی از کمترین تا بیشترین مقدار آن اختصاص داده شده و برای بقیه متغیرها، مقادیر ردیف داده اصلی در نظر گرفته شده است. در نتیجه با این روش، تأثیر متغیرهای ورودی مدل بر متغیر خروجی به صورت مجزا مشخص می‌شود. برای انجام آنالیز حساسیت شبکه عصبی برای هر مجموعه ردیف داده اجرا شده و در نهایت با میانگین‌گیری از مقادیر به دست آمده، نمودارهای آنالیز حساسیت رسم گردید. شکل‌های ۹ و ۱۰ منحنی‌های آنالیز حساسیت متغیرهای انتخاب شده را به ترتیب برای مناطق سرد و مرطوب و مناطق گرم و خشک و سرد و خشک نشان می‌دهد.


۳-۴- آنالیز حساسیت تأثیر متغیرهای انتخاب شده بر روی مدل‌های توسعه داده شده برای هر منطقه

در روش مدل‌سازی شبکه عصبی مصنوعی درک رابطه بین متغیرهای ورودی و خروجی امکان‌پذیر نیست [۴۰ و ۴۱]. از این رو برای جبران این کمبود، آنالیز حساسیت با استفاده از بهترین مدل شبکه عصبی توسعه یافته برای پیش‌بینی شیار شدگی انجام گرفته است. برای انجام آنالیز حساسیت با استفاده از مدل‌های هر منطقه، فقط بهترین متغیرهای انتخاب شده در مرحله قبل برای آن منطقه مورد استفاده قرار گرفته است. هدف از این روش بررسی تأثیر رابطه متقابل هر متغیر بر خرابی شیار شدگی است [۴۲ و ۴۳]. در این مطالعه، آنالیز حساسیت با استفاده از مجموعه



شکل ۹. نمودارهای آنالیز حساسیت متغیرهای موثر در مناطق سرد و مرطوب

Fig. 9. Sensitivity analysis charts of effective variables in wet freeze zones



شکل ۱۰. نمودارهای آنالیز حساسیت متغیرهای موثر در مناطق گرم و خشک و سرد و خشک

Fig. 10. Sensitivity analysis charts of effective variables in dry no freeze and dry freeze zones

هوایی مورد بررسی قرار گرفته است. با بهره‌گیری از اکثر داده‌های برنامه بلند مدت روسازی تأثیر متغیرهای مختلف آب و هوایی، سازه‌ای، مشخصات مواد و مصالح و ترافیکی بر مقدار خرابی شیار شدگی مورد ارزیابی قرار گرفته است. از آنجا که دقت مناسب در عین سادگی جزء مهم‌ترین ویژگی‌های یک مدل پیش‌بینی به شمار می‌رود، لذا با استفاده از روش بهینه‌سازی چند هدفه NSGA II-MLP متغیرهایی که میزان اهمیت بیشتری در پیش‌بینی خرابی شیار شدگی دارند، مشخص و به عنوان ورودی مدل در نظر گرفته شدند. در نتیجه با استفاده از شبکه‌های عصبی مصنوعی دو مدل مجزا جهت پیش‌بینی مقدار این خرابی در مناطق آب و هوایی ذکر شده در بالا توسعه داده شده است. در نهایت با استفاده از شاخص‌های آماری میزان دقت دو مدل توسعه داده شده، محاسبه شد. نتایج حاصل شده از این مطالعه به شرح زیر است:

- در این مطالعه نقش پر رنگ روش NSGA II-MLP در انتخاب متغیرهای ورودی موثر و بالتبع ایجاد مدلی با پیچیدگی و متغیرهای ورودی کمتر به چشم می‌خورد. با استفاده از این روش، مدل‌های بهینه با در نظر گرفتن متغیرهای موثرتر در هر مدل برای پیش‌بینی خرابی شیار شدگی در مناطق آب و هوایی سرد و مرطوب و گرم و خشک و سرد و خشک توسعه داده شدند.

- برای توسعه مدل پیش‌بینی خرابی شیار شدگی در مناطق آب و هوایی سرد و مرطوب، متغیرهای میانگین سالانه تعداد روزهایی که سیکل ذوب و یخ در آن اتفاق می‌افتد (CAFT)، مقدار تجمعی اختلاف دمای حداکثر و دمای حداقل روزانه در سال (CTR)، ضخامت لایه آسفالتی (ALT)، حداکثر وزن مخصوص خشک خاک بستر (MLDD)، درصد مصالح سنگی عبوری از الک شماره ۴ (۴/۷۵ میلی‌متر) در خاک بستر (NO4S)، عمر روسازی (AGE) و تعداد تجمعی بار معادل هم‌ارز (CKESAL) استفاده شده‌اند. ضریب تعیین مدل به دست آمده برای داده‌های آموزش، اعتبارسنجی و آزمایش به ترتیب ۰/۹۴، ۰/۸۸ و ۰/۸۸ محاسبه شده است. همچنین میانگین مربعات خطای مدل توسعه یافته در این مطالعه برای مناطق سرد و مرطوب برای داده‌های آموزش، اعتبارسنجی و آزمایش به ترتیب ۱/۱۹، ۳/۷۳ و ۴/۳۵ به دست آمده است.

- متغیرهای میانگین سالانه تعداد روزهایی که سیکل ذوب و یخ در آن اتفاق می‌افتد (CAFT)، مقدار تجمعی اختلاف دمای حداکثر و دمای حداقل روزانه در سال (CTR)، ضخامت لایه آسفالتی (ALT)، عمر روسازی (AGE)، تعداد تجمعی بار معادل هم‌ارز (CKESAL)،

همانطور که در شکل ۹ مشاهده می‌شود، مقدار خرابی شیار شدگی با افزایش سن روسازی افزایش یافته است که مطابق با نظر و قضاوت مهندسی است (شکل ۹-الف). همچنین با افزایش بار ترافیکی میزان شیار شدگی به تدریج افزایش می‌یابد (شکل ۹-ب). این روند با رسیدن بار ترافیکی به مقداری معین به دلیل تراکم ایجاد شده در سازه روسازی به تدریج ثابت و کمی نزولی می‌گردد. در بررسی تأثیر متغیر تعداد سیکل ذوب و یخبندان نتیجه شد که با افزایش تعداد سیکل ذوب و یخ به دلیل سست شدن لایه‌های پایینی روسازی مقدار شیار شدگی افزایش یافته اما از جایی به بعد یخبندان باعث افزایش مقاومت در برابر خرابی شده است (شکل ۹-پ). در بررسی پارامتر دمایی (اختلاف حداکثر و حداقل دمای روزانه) به این نکته می‌توان اشاره کرد که با افزایش این متغیر مقدار شیار شدگی افزایش یافته چرا که روسازی حداکثر دماهای بیشتری را تجربه کرده است (شکل ۹-ت). از طرف دیگر همان‌طور که با قضاوت مهندسی نیز سازگار است با افزایش ضخامت لایه آسفالتی میزان شیار شدگی کاهش یافته است (شکل ۹-ث). علت اینکه در بخشی از نمودار شاهد افزایش روند شیار شدگی هستیم این است که مقاومت روسازی آسفالتی در این ضخامت‌ها بیشتر تحت تأثیر مقاومت برشی مصالح قیری است اما با افزایش ضخامت تأثیر سازه‌ای کل آسفالت نقش ایفا کرده است. با افزایش مصالح سنگی عبوری از الک ۴ در خاک بستر ابتدا میزان شیار شدگی کاهش یافته و سپس افزایش یافته است (شکل ۹-ج). دلیل این اتفاق این است که مصالح با این خصوصیت باعث تحکیم بهتر شده اما از جایی به بعد افزایش این مصالح باعث روان شدن و سر خوردن دانه‌ها روی یکدیگر می‌گردد. همان‌طور که از شکل‌های آنالیز حساسیت (شکل ۱۰) در منطقه آب و هوایی گرم و خشک و سرد و خشک مشاهده می‌شود، رفتار شیار شدگی در مورد سایر متغیرها تقریباً همانند متغیرهای ذکر شده برای مناطق با آب و هوای سرد و مرطوب است. در مورد متغیر نفوذپذیری قیر نیز می‌توان گفت که با افزایش آن میزان روانی مخلوط و در نتیجه پتانسیل شیار شدگی افزایش یافته است (شکل ۱۰-چ). همچنین با تغییر نوع اساس روسازی از تثبیت نشده به حالت تثبیت شده میزان شیار شدگی کاهش یافته است.

#### ۴- نتیجه‌گیری

هدف اصلی این مطالعه پیش‌بینی خرابی شیار شدگی با مدل شبکه عصبی است. با توجه به اینکه روند میزان خرابی شیار شدگی در اقلیم‌های مختلف آب و هوایی متفاوت است، در این مطالعه دو اقلیم مختلف آب و

## منابع

- [1] T.F. Fwa, The handbook of highway engineering, CRC press, 2005.
- [2] K.H. McGhee, Automated pavement distress collection techniques, Transportation Research Board, 2004.
- [3] K.A. Abaza, Deterministic performance prediction model for rehabilitation and management of flexible pavement, International Journal of Pavement Engineering, 5(2) (2004) 111-121.
- [4] J.A. Prozzi, F. Hong, Transportation infrastructure performance modeling through seemingly unrelated regression systems, Journal of Infrastructure Systems, 14(2) (2008) 129-137.
- [5] K.A. Zimmerman, D.M. Testa, An Evaluation of Idaho Transportation Department Needs for Maintenance Management and Pavement Management Software Tools, (2008).
- [6] A. Miede, Tyre model for truck ride simulations, CPGS Dissertation, University of Cambridge, (2004).
- [7] A.R. Archilla, Development of rutting progression models by combining data from multiple sources, University of California, Berkeley, 2000.
- [8] B. Ali, Numerical Model for the Mechanical Behavior of Pavement: Application to the Analysis of Rutting, PhD, University of Science and Technology Lille, France, (2006).
- [9] M. Anyala, J. Odoki, C. Baker, Hierarchical asphalt pavement deterioration model for climate impact studies, International Journal of Pavement Engineering, 15(3) (2014) 251-266.
- [10] J.D. Porras-Alvarado, Z. Zhang, L.G.L. Salazar, Probabilistic approach to modeling pavement performance using IRI data, 2014.
- [11] I. ARA, ERES Consultants Division, Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures, Final Rep., NCHRP Project 1-37A, (2004).
- [12] A. Isa, D. Ma'Soem, L.T. Hwa, Pavement performance model for federal roads, in: Proceedings of the Eastern

نوع اساس (UOBB)، نفوذپذیری قیر در دمای ۷۷ درجه فارنهایت (PEN77) و درصد مصالح سنگی عبوری از الک ۴ و مانده روی الک ۲۰۰ (NO4A-NO200A) به عنوان متغیرهای ورودی تاثیرگذار در توسعه مدل پیش‌بینی میزان خرابی شیار شدگی در مناطق آب و هوایی گرم و خشک و سرد و خشک انتخاب شدند. دقت مدل توسعه داده شده برای این مناطق نیز بالا بوده و ضریب تعیین به دست آمده برای داده‌های آموزش، اعتبارسنجی و آزمایش به ترتیب ۰/۹۶، ۰/۸۴ و ۰/۹۴ به دست آمده است.

- با توجه به تحلیل حساسیت انجام شده در بخش قبل، متغیرهایی که بیشترین تاثیرگذاری را بر خرابی شیار شدگی دارند در مناطق مورد مطالعه معرفی شدند. متغیرهایی که بیشترین اثرگذاری را بر خرابی شیار شدگی در اقلیم سرد و مرطوب دارند، به ترتیب اهمیت متغیر زمانی AGE و متغیر دمایی CTR با تاثیر مستقیم و متغیر سازه‌ای ALT با تاثیر معکوس بر خرابی مشخص گردید. همچنین در اقلیم گرم و سرد خشک به ترتیب متغیرهای ترافیکی CKESAL و متغیر مشخصات مواد PEN77 با تاثیر مستقیم و مشابه مدل قبل متغیر سازه‌ای ALT با تاثیر معکوس بر خرابی از بیش‌ترین اهمیت برخوردارند. نتایج به دست آمده حاکی از آن است که رفتار خرابی شیار شدگی و میزان تأثیر عوامل مختلف سازه‌ای، آب و هوایی و ترافیکی در مناطق مختلف آب و هوایی متفاوت بوده است. بنابراین با لحاظ کردن تاثیر این پارامترها در طراحی و تعمیر و نگهداری روسازی می‌توان به کاهش شدت این خرابی و در نتیجه افزایش عمر خدمت‌دهی روسازی کمک کرد.

## پیشنهاد در راستای بهره‌برداری از مدل‌های توسعه داده

### شده

اگر چه به دلیل عدم وجود داده‌های منسجم و طولانی مدت برای روسازی‌های ایران، داده‌های برنامه عملکرد بلند مدت روسازی (LTPP) که مربوط به ایالات متحده آمریکا و کانادا می‌باشد در این تحقیق مورد استفاده قرار گرفته است، تشابه بین نقاط مختلف آب و هوایی در ایالات متحده آمریکا و ایران این امکان را فراهم می‌کند که از مدل توسعه داده شده در این تحقیق برای پیش‌بینی شیار شدگی در روسازی‌های کشور نیز استفاده شود. این کار ممکن است به دلیل یکسان نبودن مصالح مورد استفاده در ساخت روسازی‌ها، تفاوت در بهره‌برداری ترافیکی و... توأم با دقت کافی نباشد ولی می‌تواند به عنوان روشی برای تخمین و مقایسه شیار شدگی در کشور مورد استفاده قرار گیرد.



- user reference guide, Turner-Fairbank Highway Research Center, 2003.
- [23] <https://infopave.fhwa.dot.gov>, in.
- [24] H.J. Adèr, G.J. Mellenbergh, Advising on research methods.: Proceedings of the 2007 KNAW colloquium, Johannes van Kessel Publ., 2008.
- [25] R.J. Little, D.B. Rubin, Statistical analysis with missing data, John Wiley & Sons, 2019.
- [26] F. Yu, X. Xu, A short-term load forecasting model of natural gas based on optimized genetic algorithm and improved BP neural network, Applied Energy, 134 (2014) 102-113.
- [27] V. Safak, Min-mid-max scaling, limits of agreement, and agreement score, arXiv preprint arXiv:2006.12904, (2020).
- [28] G. Shafabakhsh, O.J. Ani, M. Talebsafa, Artificial neural network modeling (ANN) for predicting rutting performance of nano-modified hot-mix asphalt mixtures containing steel slag aggregates, Construction and Building Materials, 85 (2015) 136-143.
- [29] 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.
- [30] J. Domitrović, H. Dragovan, T. Rukavina, S. Dimter, Application of an artificial neural network in pavement management system, Tehnički vjesnik, 25(Supplement 2) (2018) 466-473.
- [31] 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.
- [32] M. Jalal, Z. Grasley, C. Gurganus, J.W. Bullard, A new nonlinear formulation-based prediction approach using artificial neural network (ANN) model for rubberized cement composite, Engineering with Computers, (2020) 1-18.
- [33] A. Kostopoulos, T. Grapsa, Self-scaled conjugate gradient training algorithms, Neurocomputing, 72(13-14) (2000) 4285-4296.
- Asia Society for Transportation Studies, Citeseer, 2005, pp. 428-440.
- [13] A.K. Naiel, Flexible pavement rut depth modeling for different climate zones, (2010).
- [14] M. Svensson, Modeling pavement performance based on data from the Swedish LTPP database: predicting cracking and rutting, KTH Royal Institute of Technology, 2013.
- [15] M. RADWAN, A.-H. Mostafa, M. HASHEM, H. FAHEEM, Modeling pavement performance based on LTPP database for flexible pavements, Teknik Dergi, 31(4) (2020) 10127-10146.
- [16] A. Fathi, M. Mazari, M. Saghafi, A. Hosseini, S. Kumar, Parametric study of pavement deterioration using machine learning algorithms, in: Airfield and highway pavements 2019: Innovation and sustainability in highway and airfield pavement technology, American Society of Civil Engineers Reston, VA, 2019, pp. 31-41.
- [17] S. Inkoom, J. Sobanjo, A. Barbu, X. Niu, Prediction of the crack condition of highway pavements using machine learning models, Structure and Infrastructure Engineering, 15(7) (2019) 940-953.
- [18] W. Zeiada, S.A. Dabous, K. Hamad, R. Al-Ruzouq, M.A. Khalil, Machine learning for pavement performance modelling in warm climate regions, Arabian Journal for Science and Engineering, (2020) 1-19.
- [19] X. Cai, P. Wang, L. Du, Z. Cui, W. Zhang, J. Chen, Multi-objective three-dimensional DV-hop localization algorithm with NSGA-II, IEEE Sensors Journal, 19(21) (2019) 10003-10015.
- [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] FHWA, LONG-TERM PAVEMENT PERFORMANCE Information Management System Pavement Performance Database User Reference Guide, 088 (2003).
- [22] G.E. Elkins, P.N. Schmalzer, T. Thompson, A. Simpson, Long-term pavement performance information management system: Pavement performance database

- Hydrology, 509 (2014) 379-386.
- [39] 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.
- [40] H. Adeli, Neural networks in civil engineering: 1989–2000, *Computer-Aided Civil and Infrastructure Engineering*, 16(2) (2001) 126-142.
- [41] J.D. Olden, D.A. Jackson, Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks, *Ecological modelling*, 154(1-2) (2002) 135-150.
- [42] M. Gevrey, I. Dimopoulos, S. Lek, Review and comparison of methods to study the contribution of variables in artificial neural network models, *Ecological modelling*, 160(3) (2003) 249-264.
- [43] J.H. Choi, T.M. Adams, H.U. Bahia, Pavement Roughness Modeling Using Back-Propagation Neural Networks, *Computer-Aided Civil and Infrastructure Engineering*, 19(4) (2004) 295-303.
- 15) (2009) 3000-3019.
- [34] K. Gopalakrishnan, Effect of training algorithms on neural networks aided pavement diagnosis, *International Journal of Engineering, Science and Technology*, 2(2) (2010) 83-92.
- [35] M.H. Esfe, H. Hajmohammad, R. Moradi, A.A.A. Arani, Multi-objective optimization of cost and thermal performance of double walled carbon nanotubes/water nanofluids by NSGA-II using response surface method, *Applied Thermal Engineering*, 112 (2017) 1648-1657.
- [36] S. Ramesh, S. Kannan, S. Baskar, Application of modified NSGA-II algorithm to multi-objective reactive power planning, *Applied Soft Computing*, 12(2) (2012) 741-753.
- [37] M. Ehsani, Development of a prediction model for concrete pavement failures using the LTPP data, Amirkabir University of Technology, 2021.
- [38] 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*

چگونه به این مقاله ارجاع دهیم

A. R. Askari, P. Hajikarimi, M. Ehsani, F. Moghadas Nejad, Prediction of rutting deterioration in flexible pavements using artificial neural network and genetic algorithm, *Amirkabir J. Civil Eng.*, 54(9) (2022) 3581-3602.

DOI: 10.22060/ceej.2022.20965.7581

