



Ferdowsi
University of
Mashhad

Journal Ferdowsi Civil Engineering

Page Journal: civil-ferdowsi.um.ac.ir



Developing a Prediction Model for Rutting Depth of Warm Mix Asphalt Mixture using Neural Network

Research Article

Mahsa Rouhi Fariman¹, Sayyed Ali Hosseini² , Mansour Fakhri³

DOI: [10.22067/jfcei.2022.74238.1104](https://doi.org/10.22067/jfcei.2022.74238.1104)

1. Introduction

Pavements are the national capital of every country. A good pavement should have a smooth driving surface, withstand high traffic volumes, and sufficient resistance to fatigue, cracking, and rutting. In order to increase the resistance of pavements against destructive factors such as fatigue, cracks caused by severe temperature changes, and permanent deformation, additives are used to improve the mechanical properties of asphalt pavement. Less tensile strength of asphalt mixtures compared with their compressive strength has given rise to the use fiber with high tensile resistance as a solution to transfer the existing tensile stresses in the mixture through fiber and also the increase of absorbed strain energy during fatigue and fracture process. The benefits of using fibers in asphalt mixtures are increased tensile strength, fatigue resistance, resistance against rutting, and improved moisture susceptibility. Moreover, the addition of reclaimed asphalt pavement (RAP) can significantly improve the resistance to permanent deformation of asphalt mixtures. The benefits of using RAP are reducing energy consumption and greenhouse gas (GHG) emissions, reducing the required new asphalt content (virgin binder), and preserving nonrenewable natural resources such as virgin aggregate and asphalt, reduction of waste production, and reduction of landfill use.

This study uses the data obtained from the laboratory results of the previous study that warm mix asphalt modified with glass fibers and 0, 20, 40, and 50% recycled asphalt pavement (RAP).

The rutting depth of the mixtures was determined by multilayer perceptron neural network (MLP) and radial basis function neural network (RBF), and the results were compared. The post-compaction and rutting depth prediction model agreed well with the experimental results.

Post-compaction (PC) consolidation is defined as deformation (mm) at 500 cycles. Rutting is also a widespread failure mechanism observed in flexible asphalt

pavements. Usually, rutting is observed with longitudinal depressions in the wheel path.

In a previous study, the measurement of rutting and moisture sensitivity of warm asphalt mixtures and their short-term aging characteristics in dry and wet test conditions was carried out using the KNTU Wheel Track test. The KNTU Wheel Track was developed in 2015 at KN Toosi University of technology, which could build asphalt concrete slabs in 260 mm width, 400 mm length, and 50–100 mm thickness through rolling compaction, which is the closest method to field compaction. Another capability of this device is performing rutting test in dry and wet conditions.

2. Method

2.1. Artificial neural networks

Artificial Neural Network (ANN) is a mathematical model that tries to simulate the structure and functionalities of biological neural networks. The neural network consists of a large number of processing elements called neurons that work together to solve a problem and transfer information through synapses. The neuron is a basic unit of the nervous system and a simple processing unit that receives and processes the signal from other neurons. A network is created between the neurons, and the network is trained by the training algorithm (Figure 1). This study's post-compaction and rutting depth prediction was made with a multilayer perceptron and radial basis function neural network.

*Manuscript received: December 18, 2021, Revised, June 1, 2022, Accepted, September 18, 2022.

¹. Postgraduate Student in Civil Engineering, Shahrood University of Technology, Shahrood, Iran.

². Assistant Professor in Civil Engineering, Shahrood University of Technology, Shahrood, Iran.

Email: ahosseini@shahroodut.ac.ir

³. Professor in Civil Engineering Faculty of K.N. Toosi University of Technology.

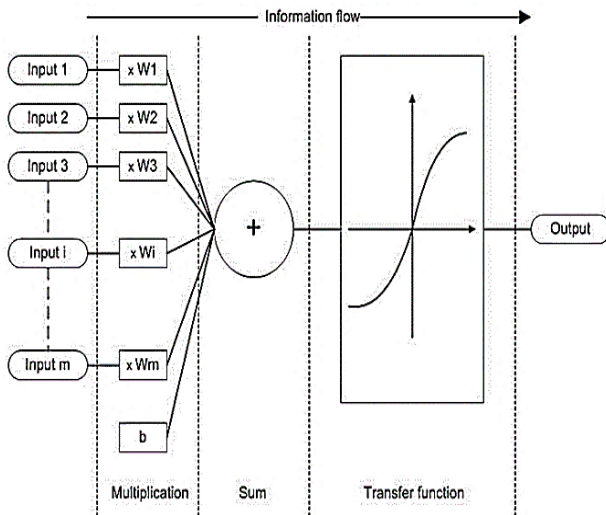


Figure 1. Artificial neural network model

2.1.1. Multilayer Perceptron neural networks

Multilayer Perceptron has at least three layers: input layer, hidden layer, and output layer. Multilayer perceptron has a set of weights and biases that are adjusted to train the neural network. The number of elements in the input layer is actually the same number of input variables introduced to the network. The hidden layer contains several neurons that influence the behavior of the network. Determining the number of hidden layers and neurons is the responsibility of the user. He determines the optimal number of layers and neurons by trial and error. The output layer of the neural network also represents the output of the problem that the network must predict.

2.1.2. Radial Basis Function neural networks

Radial Basis Function (RBF) neural network is another type of feed-forward neural network that uses radial basis functions as activation functions. RBF network consists of three layers: input layer, hidden layer with radial basis function as activation function, and output layer. The output of an RBF network is a linear combination of weighted radial basis functions. RBF networks are trained faster than MLP networks and create better decision boundaries. Although these networks require more neurons than MLP networks, they can be trained in a shorter time than the time required for MLP networks.

3. Conclusion

In this study, the data obtained from the laboratory results in a previous study were analyzed by Multilayer Perceptron Neural network (MLP) and Radial Basis Neural network (RBF), and the results of these methods were compared with each other. The results of this research are as follows:

1. Prediction of post-compaction by MLP neural network has a correlation coefficient of 0.999. The correlation coefficient for RBF neural network is 0.995, and the prediction of rutting depth by MLP neural network has a correlation coefficient of 0.997. The RBF neural network has a correlation coefficient of 0.945. MLP neural network was more accurate in prediction.

2. In order to further validate the model, additional data that were never used during modeling were used. The MLP neural network performed better for simulating these data compared to the RBF neural network and presented a lower error percentage.



توسعه مدل پیش‌بینی عمق شیارشدگی مخلوط‌های آسفالتی گرم با استفاده از شبکه عصبی *

مقاله پژوهشی

DOI: 10.22067/JFCEI.2022.74238.1104_

منصور فخری^(۳)

سید علی حسینی^(۲)

مهسا روحی فریمان^(۱)

چکیده محققان و مهندسان دائماً در تلاش هستند تا عملکرد روسازی‌های آسفالتی را بهبود بخشند. روسازی‌ها، به عنوان سطوحی که اغلب توسط محورهای سنگین بارگیری می‌شوند، باید مقاومت کافی در برابر خستگی، ترک‌خوردگی و شیارشدگی داشته باشند. در این مقاله با استفاده از داده‌های به دست آمده از نتایج آزمایشگاهی مطالعه قبلی که مخلوط‌های آسفالتی گرم (WMA) اصلاح شده با الیاف شیشه و ۰، ۲۰، ۴۰ و ۵۰ درصد آسفالت تراشیده شده بازیافتی (RAP) برای بررسی مقاومت مخلوط در برابر شیارشدگی ساخته شدند، پیش‌بینی عمق شیارشدگی مخلوط‌ها توسط شبکه‌های عصبی مصنوعی چندلایه (MLP) و شعاعی پایه (RBF) انجام شد و نتایج با یکدیگر مقایسه شدند. مدل پیش‌بینی عمق شیارشدگی و پیش‌تراکم با نتایج تجربی مطابقت خوبی نشان دادند. برای بررسی قدرت تعمیم شبکه عصبی با استفاده از داده‌هایی که در طول مدل‌سازی به کار گرفته نشده بودند، شبکه عصبی چندلایه عملکرد بهتری نسبت به شبکه عصبی شعاعی پایه داشت.

واژه‌های کلیدی آسفالت بازیافتی، پیش‌تراکم شیارشدگی، شبکه عصبی مصنوعی چندلایه، شبکه عصبی مصنوعی شعاعی پایه.

Developing a Prediction Model for Rutting Depth of Warm Mix Asphalt Mixture Using Neural Network

Mahsa Rouhi Fariman

Sayed Ali Hosseini

Mansour Fakhri

Abstract Researchers and engineers are constantly working to improve the performance of asphalt pavements. Pavements, as surfaces that are often loaded by heavy axles, must have sufficient resistance to fatigue, cracking and rutting. In this paper, using the data obtained from the laboratory results of the previous study that warm mix asphalt modified with glass fibers and 0, 20, 40 and 50% recycled asphalt pavement (RAP) were made to evaluate the resistance of the mixture against rutting, rutting depth of the mixtures was determined by multilayer perceptron neural network (MLP) and radial basis function neural network (RBF) and the results were compared with each other. The prediction model of post compaction and rutting depth showed good agreement with the experimental results. To evaluate the generalizability of the neural network using data that were not used during modeling, the multilayer perceptron neural network (MLP) performed better than the radial basis function neural network (RBF).

Keywords Recycle asphalt pavement, Rutting, Multilayer perceptron neural network, Radial basis function neural network, Post compaction.

* تاریخ دریافت مقاله ۱۴۰۰/۹/۲۷ و تاریخ پذیرش آن ۱۴۰۱/۶/۲۷ می‌باشد

(۱) دانشجوی کارشناسی ارشد راه و ترابری، دانشگاه صنعتی شاهرود، شاهرود، ایران

(۲) نویسنده مسئول: استادیار، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران.

(۳) استاد دانشکده مهندسی عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران

مقدمه

اصلاح‌شده با الیاف شیشه برای هر دو شرایط پیرشدگی کوتاه‌مدت و پیرنشده افزایش می‌یابد [5].



شکل ۱ دستگاه مسیر چرخ KNTU

آسفالت مخلوطی از قیر، سنگدانه و فیلر است که از جمله معمولترین روسازی مورد استفاده در جهان است [1]. روسازی راه‌ها سرمایه ملی هر کشور است و حمل و نقل جاده‌ای کارا، شرط اصلی در توسعه پایدار و توسعه اقتصادی است [2]. یک روسازی خوب باید سطحی صاف برای رانندگی داشته باشد، حجم بالای ترافیک را تحمل کند و کشش را با حداقل خسارت به سطح پایین منتقل کند [3]. خرابی‌هایی که در طول عمر مفید روسازی‌ها رخ می‌دهد، عمدتاً شامل تغییر شکل دائمی در مسیر چرخ خودروها، خراب شدن و ترک‌خوردگی حرارتی است [4]. از آنجا که هزینه‌های زیادی باید برای بازسازی این خرابی‌ها صرف شود، بنابراین پیشگیری زودهنگام مقرون به صرفه‌تر است. برای افزایش انعطاف‌پذیری روسازی‌ها و همچنین افزایش مقاومت آنها در برابر عوامل مخرب مانند خستگی، ترک‌های ناشی از تغییرات شدید دما و تغییر شکل دائمی، افزودنی‌هایی با قابلیت بهبود خواص مکانیکی روسازی آسفالتی استفاده می‌شود. در مطالعه قبلی، اندازه‌گیری شیارشدگی و حساسیت رطوبتی مخلوط‌های آسفالتی گرم، با و بدون الیاف شیشه حاوی ۰، ۲۰، ۴۰ و ۵۰ درصد آسفالت بازیافتی (Reclaimed Asphalt Pavement (RAP) و ویژگی‌های پیرشدگی کوتاه‌مدت آنها در شرایط خشک و مرطوب آزمایش با استفاده از آزمایش مسیر چرخ KNTU انجام شد [5]. مسیر چرخ KNTU در سال ۲۰۱۵ در دانشگاه خواجه نصیرالدین طوسی توسعه یافت (شکل ۱)، که می‌تواند دال‌های بتن آسفالتی با عرض ۲۶۰ میلی‌متر، طول ۴۰۰ میلی‌متر و ضخامت ۵۰ تا ۱۰۰ میلی‌متر را از طریق تراکم نورد، که نزدیک‌ترین روش به تراکم میدانی است، بسازد [5]. از دیگر قابلیت‌های این دستگاه انجام تست شیارشدگی در شرایط خشک و مرطوب بر روی دال‌های آسفالتی است.

در این مقاله، با استفاده از داده‌های به دست آمده از نتایج آزمایش در مطالعه قبلی، پیش‌بینی پیش‌تراکم و عمق شیارشدگی توسط شبکه عصبی چندلایه (Multi Layer Perceptron) و شبکه عصبی شعاعی پایه (Radial Basis Function) انجام شد و نتایج این دو روش بایکدیگر مقایسه شد. همچنین برای بررسی قدرت تعمیم شبکه‌های عصبی از داده‌های اضافی که در طول مدل‌سازی به کار گرفته نشدند استفاده شد. پیش‌تراکم (Post Compaction) به عنوان تغییر شکل روسازی (میلی‌متر) در ۵۰۰ چرخه بارگذاری تعریف می‌شود [5]. شیار شدگی نیز یک مکانیزم خرابی بسیار رایج مشاهده شده در روسازی‌های آسفالتی انعطاف‌پذیر است. به طور معمول شیارشدگی با فرورفتگی‌های طولی در مسیر چرخ مشاهده می‌شود [6].

پیشینه تحقیق

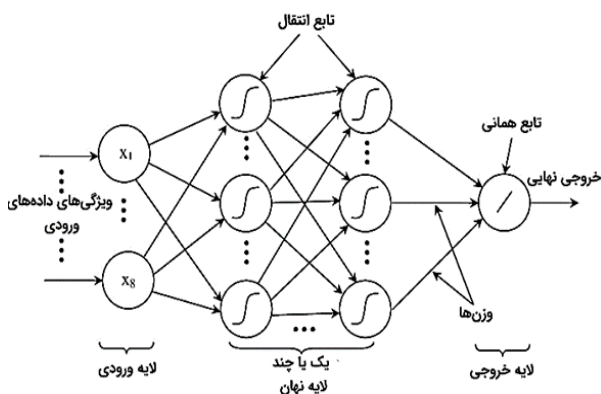
فعالیت‌های آزمایشگاهی از آن رو که زمان‌بر و پرهزینه هستند محققان را واداشته است تا امکان پیش‌بینی نتایج آزمایش را بررسی کنند. شبکه‌های عصبی مصنوعی در بیشتر رشته‌های

نتایج نشان داد، اگرچه افزودن الیاف شیشه به تنهایی به مخلوط‌های آسفالتی گرم، مقاومت در برابر شیارشدگی مخلوط را بهبود می‌بخشد، اما نمی‌تواند حساسیت رطوبتی مخلوط را بهبود بخشد. ترکیب RAP و الیاف شیشه می‌تواند به مخلوط‌هایی منجر شود که مقاومت بالایی در برابر شیارشدگی و حساسیت رطوبتی دارند. مشخص شد که RAP پتانسیل بهبود مقاومت شیارشدگی همه مخلوط‌ها را دارد و با افزایش درصد RAP، مقاومت در برابر حساسیت رطوبتی مخلوط آسفالتی گرم

روش های مدل سازی

شبکه های عصبی مصنوعی. سیستم های شبکه عصبی مصنوعی با الگوبرداری از ساختار مغز انسان، عملکرد مغز را به صورت مدل های ریاضی ساده شده شبیه سازی می کنند و برای پردازش داده ها استفاده می کنند [9]. این مطالعه از الگوریتم لونیبرگ-مارکواردت (Levenberg-Marquardt) برای به حداقل رساندن تابع خطا استفاده کرده است [10]. شبکه های عصبی برای تقریب و برآورد توابع ناشناخته استفاده می شوند. شبکه های عصبی نیز مانند مغز، از نورون های متصل به هم تشکیل شده است که ورودی را دریافت، اطلاعات را پردازش و خروجی تولید می کنند [11]. در این مطالعه پیش بینی پیش تراکم و عمق شیارشدگی با شبکه عصبی چندلایه و شبکه عصبی شعاعی پایه انجام شد.

شبکه عصبی چندلایه پرکاربردترین نوع شبکه عصبی است. سه نوع لایه مشخص می شود: لایه های ورودی، پنهان و خروجی (شکل ۲). هر نورون ورودی های دریافتی را پردازش می کند و با توجه به عملکردی که به درستی تعریف شده است، خروجی تولید می کند [12]. هر اتصال به وزن خاصی (W_i) مربوط می شود که ورودی را تقویت یا کاهش می دهد [11]. رابطه بین ورودی ها (X_i) و خروجی (Y_i) با استفاده از یک تابع انتقال خاص که معمولاً دارای شکل سیگموئید لجستیک است تعریف می شود [13].



شکل ۲ شبکه عصبی پرسپترون چندلایه

شبکه عصبی شعاعی پایه دارای سه لایه (لایه ورودی، لایه پنهان با تابع فعال ساز گوسی و لایه خروجی) می باشند (شکل ۳). این شبکه ها از تابع شعاعی پایه (Radial Basis Function)، به عنوان تابع فعال سازی استفاده می کنند. شبکه های عصبی RBF و شبکه های MLP از نظر ساختاری تفاوت زیادی با یکدیگر ندارند

مهندسی، کاربرد قابل ملاحظه ای برای پیش بینی داشته اند. در تحقیقی، مدل تجربی برای تخمین عمق شیارشدگی مخلوط بتن آسفالتی با استفاده از پارامترهای ویسکوالاستیک و شبکه های عصبی مصنوعی ارائه شد. بر این اساس، نمونه های بتن آسفالتی حاوی ۳، ۵ و ۷ درصد فضای خالی با دو نوع سنگدانه آهکی و سیلیسی و قیرهای PG58-28 و PG64-22 ساخته شد و در معرض آزمایش خزش دینامیکی در دمای ۵۰ تا ۶۰ درجه سانتی گراد و محدوده تنش ۱۰۰ تا ۳۰۰ کیلوپاسکال قرار گرفت. سپس پارامترهای ویسکوالاستیک نمونه ها از نمودارهای خزش استخراج شد و در نهایت مدل پیش بینی عمق شیارشدگی توسط شبکه عصبی مصنوعی آموزش داده شد. مقایسه نتایج خروجی با نتایج آزمایش تجربی نشان داد که با استفاده از این مدل می توان رفتار خزشی و عمق شیارشدگی روسازی های بتن آسفالتی را بر اساس پارامترهای مؤثر بدون نیاز به آزمایش های پرهزینه و زمان بر تخمین زد [7]. در مطالعه دیگری آزمایش خزش دینامیکی تحت دماها و سطوح تنش مختلف برای ارزیابی عملکرد شیارشدگی نمونه های مخلوط آسفالتی داغ اصلاح شده با الیاف فورتا انجام شد. کاربرد شبکه های عصبی مصنوعی (ANN) برای پیش بینی عمق شیارشدگی بررسی و همچنین مقایسه ای بین مدل برگرز و مدل برنامه ریزی ژنتیکی (GP) در برآورد عمق شیارشدگی مخلوط آسفالتی انجام شد. نتایج نشان داد، مدل شبکه عصبی مصنوعی پیشنهادی (ANN) برای عمق شیارشدگی تطابق خوبی با نتایج تجربی نشان داده است. همچنین نتیجه گرفتند، مدل برنامه ریزی ژنتیکی پیشنهادی نسبت به مدل برگرز خطای کمتری در پیش بینی عمق شیارشدگی مخلوط آسفالتی داغ دارد [4]. در تحقیقی دیگر کاربرد شبکه عصبی مصنوعی بر پیش بینی تغییر شکل دائمی مخلوط های بتن آسفالتی اصلاح شده توسط نانو افزودنی ها مورد بحث قرار گرفت. ۲۷۰ مخلوط آسفالتی از دو منبع مختلف سنگدانه (طبیعی و سرباره فولادی) ساخته شد و توسط نانو افزودنی ها اصلاح شد. همه نمونه ها در سه دمای آزمایش مختلف ۴۰، ۵۰ و ۶۰ درجه سانتی گراد و پنج تنش ۱۰۰ تا ۵۰۰ کیلو پاسکال مورد آزمایش قرار گرفتند. مدل شبکه عصبی با استفاده از پنج پارامتر ورودی شامل نوع سنگدانه، نوع افزودنی، درصد افزودنی، دما و تنش ایجاد شد. نتایج انطباق عالی بین داده های پیش بینی شده و آزمایش را نشان داد [8].

آزمایش، \bar{D} ، \bar{Y} به ترتیب میانگین خروجی‌های پیش‌بینی شده توسط شبکه و خروجی‌های هدف و R ضریب همبستگی خطی است.

مقادیر MSE و $RMSE$ نیز مطابق روابط (۲ و ۳) محاسبه می‌شود [15]:

$$MSE = \frac{\sum_{i=0}^n (Y_i - \hat{Y}_i)^2}{n} \quad (2)$$

که در آن Y_i خروجی مطلوب برای مثال i ام از دسته آزمایش، \hat{Y}_i خروجی شبکه برای مثال i ام از دسته آزمایش و n تعداد مثال‌های موجود در دسته آموزشی یا آزمایش است.


$$RMSE = \sqrt{\frac{\sum_{i=0}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (3)$$

داده‌ها. در این مقاله پیش‌بینی پیش‌تراکم و عمق شیارشدگی با استفاده از شبکه‌های عصبی مصنوعی براساس داده‌های برداشت شده مطالعه قبلی انجام شده است [5]. نتایج آزمایشگاهی مطالعه قبلی در شکل‌های (۴-۶) ارائه شده است. همچنین در جدول (۱) که هر یک از مخلوط‌ها که در مطالعه قبل مورد بررسی قرار گرفتند، بدون در نظر گرفتن درصد RAP خلاصه شده است. داده‌های ورودی به شبکه عصبی شامل چرخه بارگذاری، درصد RAP، شرایط آزمایش (خشک (۱) و مرطوب (۲))، شرایط پیرشدگی نمونه‌ها (پیرنشده (۱) و کوتاه مدت پیرشده (۲)) و نوع نمونه (اصلاح نشده (۱) و اصلاح شده با الیاف شیشه (۲)) بودند.

جدول ۱. کد مخلوط‌های آزمایش شده در مطالعه قبل

کد مخلوط‌ها	توضیحات
WUD	مخلوط آسفالتی گرم و آزمایش در شرایط خشک
WUW	مخلوط آسفالتی گرم و آزمایش در شرایط مرطوب
WAD	مخلوط آسفالتی گرم کوتاه مدت پیرشده و آزمایش در شرایط خشک
WAW	مخلوط آسفالتی گرم کوتاه مدت پیرشده و آزمایش در شرایط مرطوب
GUD	مخلوط آسفالتی گرم اصلاح شده با الیاف شیشه و آزمایش در شرایط خشک
GUW	مخلوط آسفالتی گرم اصلاح شده با الیاف شیشه و آزمایش در شرایط مرطوب
GAD	مخلوط آسفالتی گرم اصلاح شده با الیاف شیشه، کوتاه مدت پیرشده و آزمایش در شرایط خشک
GAW	مخلوط آسفالتی گرم اصلاح شده با الیاف شیشه، کوتاه مدت پیرشده و آزمایش در شرایط مرطوب

و تنها نوع پردازشی که نورون‌ها روی ورودی‌هایشان انجام می‌دهند، متفاوت است. شبکه‌های RBF سریعتر از شبکه‌های MLP آموزش داده می‌شوند و نیز محدوده‌های تصمیم‌گیری بهتری را ایجاد می‌کنند. با وجود اینکه، این شبکه‌ها نیازمند نورون‌های بیشتری نسبت به شبکه‌های MLP هستند، ولی می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های MLP، آن‌ها را آموزش داد.




شکل ۳. شبکه عصبی شعاعی پایه

پس از اتمام مرحله آموزش شبکه‌های عصبی، کارایی مدل آموزش دیده توسط ضریب همبستگی (R)، میانگین مربعات خطا (Mean Square Error) و ریشه میانگین مربعات خطا (Root Mean Square Error) ارزیابی شد.

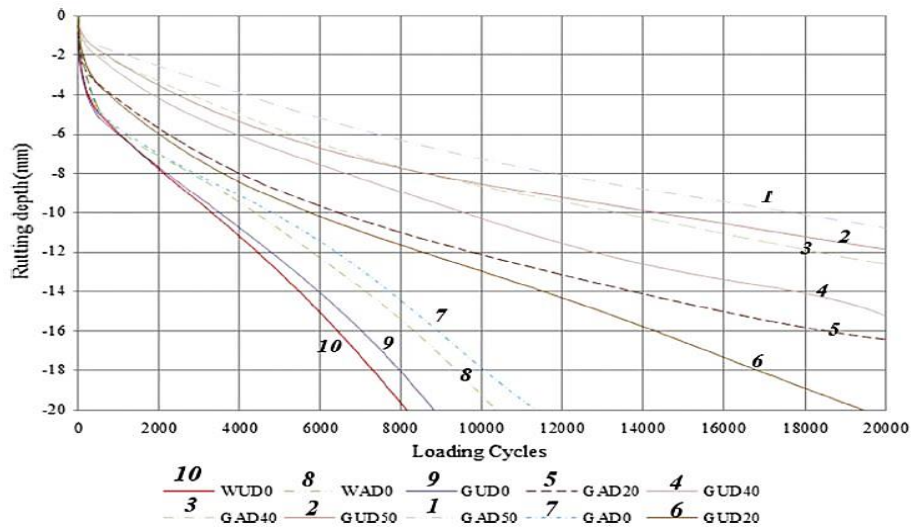
مقدار ضریب همبستگی مطابق رابطه زیر محاسبه می‌شود [14]:

$$R = \frac{\sum (D_i - \bar{D})(Y_i - \bar{Y})}{\left[\sum (D_i - \bar{D})^2 \sum (Y_i - \bar{Y})^2 \right]^{0.5}} \quad (1)$$

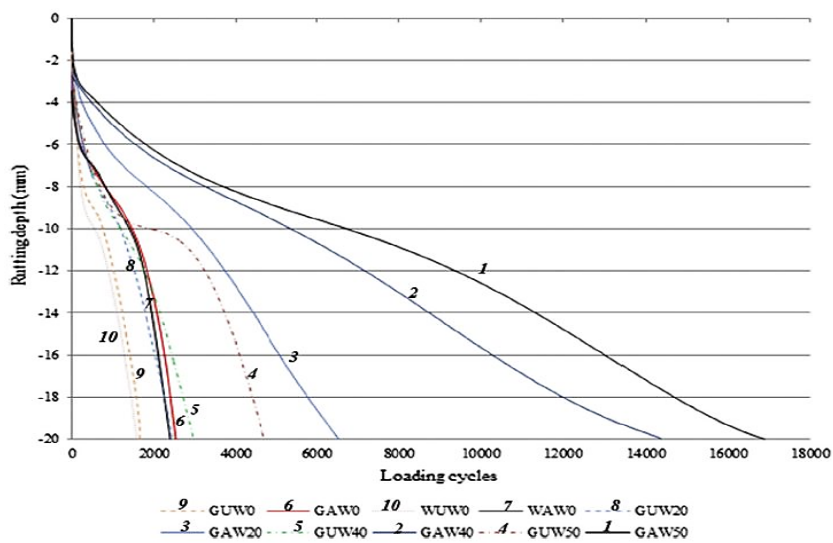
که در آن D_i خروجی هدف برای داده i ام از دسته آزمایش، Y_i خروجی پیش‌بینی شده توسط شبکه برای داده i ام از دسته



شکل ۴ پیش تراکم [5]



شکل ۵ عمق شیارشدگی برای آزمایش در شرایط خشک [5]



شکل ۶ عمق شیارشدگی برای آزمایش در شرایط مرطوب [5]

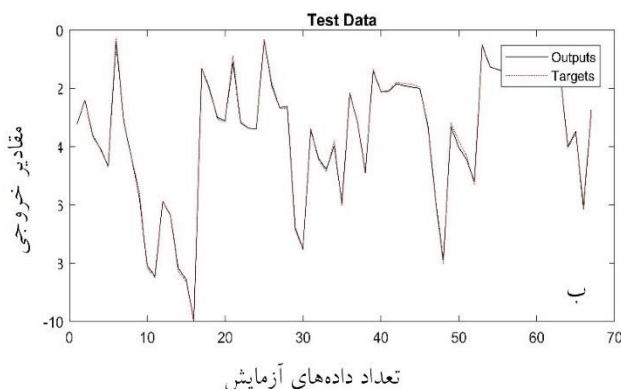
نتایج و بحث

ضریب همبستگی شدت ارتباط بین مقادیر هدف و مقادیر پیش‌بینی شده توسط شبکه عصبی را نشان می‌دهد. سنجش این همبستگی با استفاده از ضریبی به نام ضریب همبستگی خطی (R) انجام می‌شود. مقدار این ضریب بین -۱ تا ۱ تغییر می‌کند که ۱ به معنای همبستگی مثبت کامل، ۰ به معنای عدم همبستگی و -۱ به معنی همبستگی منفی کامل است [16]. در این مقاله، با توجه به ضرایب همبستگی، میزان یادگیری و عملکرد شبکه عصبی مناسب است.

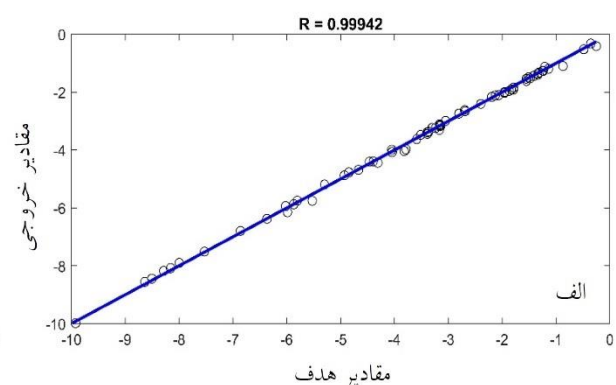
در شکل‌های (۷-ب) و (۸-ب) داده‌های هدف و شبیه‌سازی شده در برنامه که به صورت منحنی رسم و با انطباق بر یکدیگر خطای شبیه‌سازی را نشان می‌دهد، ارائه شده است. محور x تعداد داده‌هاست و محور y مقادیر داده‌های هدف و خروجی شبکه (نتایج مدل‌سازی) را نشان می‌دهد.

نتایج حاصل از آنالیز مدل با شبکه عصبی MLP. شبکه چند لایه مورد نظر، یک لایه ورودی، یک لایه پنهان و یک لایه خروجی دارد. تعداد عنصرهای موجود در لایه ورودی در حقیقت همان تعداد متغیرهای ورودی معرفی شده به شبکه هستند. لایه پنهان حاوی ۱۰ نورون (سلول عصبی) است که بر رفتار شبکه اثر می‌گذارد و با سعی و خطا تعداد بهینه آن مشخص شده است. لایه خروجی شبکه عصبی نیز بیانگر خروجی مسئله است که شبکه باید آن را پیش‌بینی کند. در شکل (۷) و شکل (۸) نتایج آموزش شبکه برای داده‌های آزمایش و برای دیگر داده‌ها در جدول (۲) ارائه شده است.

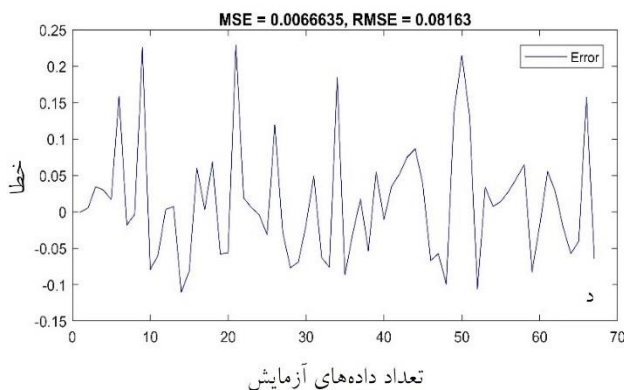
شکل‌های (۷-الف) و (۸-الف) نمودار همبستگی را نشان می‌دهند. خط برازش شده با توجه به مقادیر هدف و مقادیر پیش‌بینی شده توسط شبکه عصبی رسم شده است که هرچه بر خط مبنا که به صورت خط چین نشان داده شده است، منطبق‌تر باشد، دقت شبکه بیشتر است.



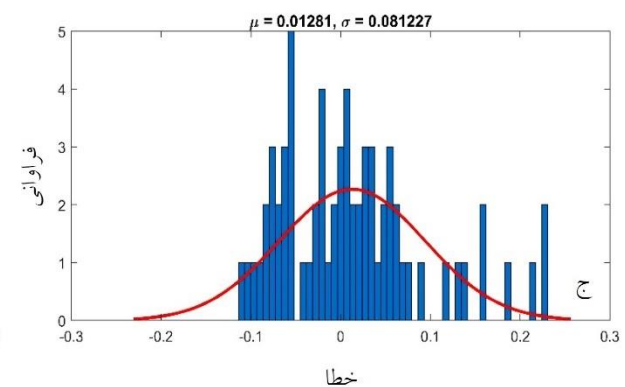
تعداد داده‌های آزمایش



مقادیر هدف

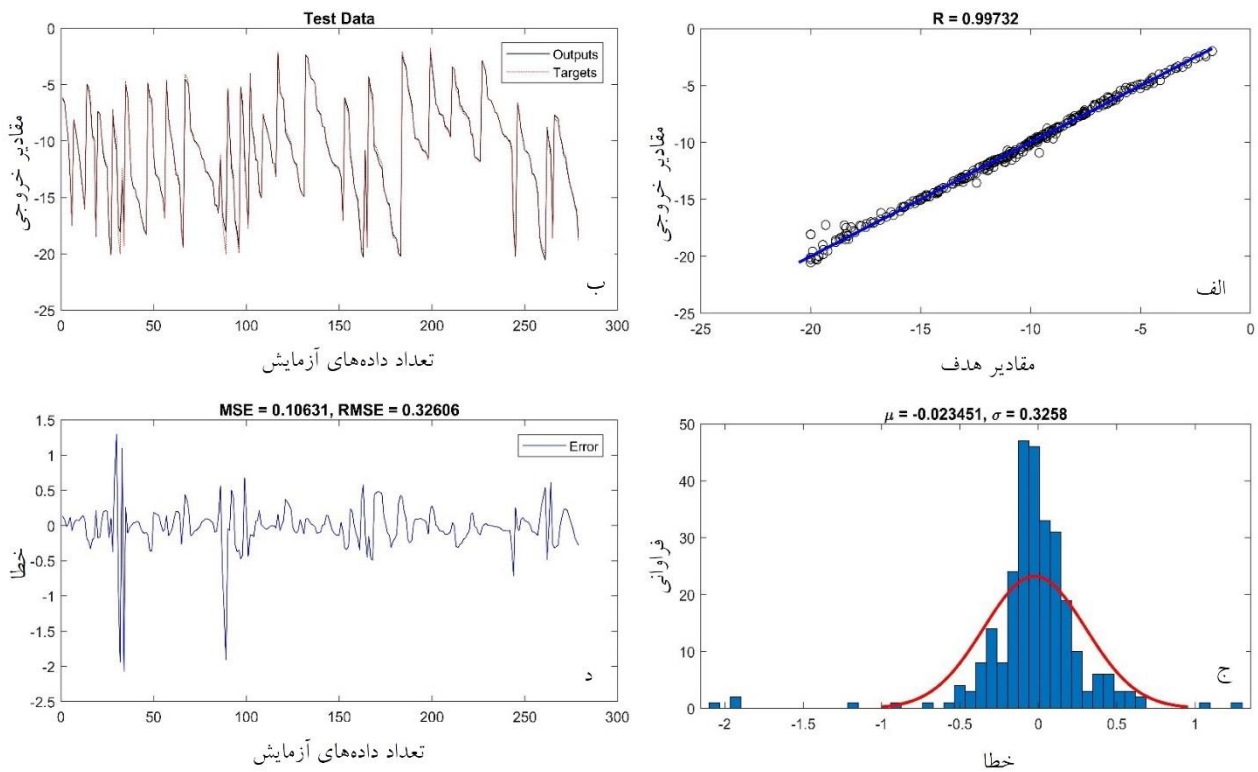


تعداد داده‌های آزمایش



خطا

شکل ۷ نتایج داده‌های آزمایش برای پیش‌بینی پیش‌تراکم توسط شبکه عصبی MLP



شکل ۸ نتایج داده‌های آزمایش برای پیش‌بینی عمق شیارشدگی توسط شبکه عصبی MLP

جدول ۲ نتایج داده‌های آموزش، صحت‌سنجی و تمام داده‌های شبکه عصبی MLP

پیش‌تراکم				
	R	MSE	RMSE	σ
داده‌های آموزش	۰/۹۹۹	۰/۰۰۵۲۱	۰/۰۷۲۲	۰/۰۷۲۳
داده‌های صحت‌سنجی	۰/۹۹۹	۰/۰۰۷۳۷	۰/۰۸۵۸	۰/۰۸۶۵
تمام داده‌ها	۰/۹۹۹	۰/۰۰۵۷۵	۰/۰۷۵۸	۰/۰۷۵۹
عمق شیارشدگی				
	R	MSE	RMSE	σ
داده‌های آموزش	۰/۹۹۸	۰/۰۶۱۳	۰/۲۴۷۶	۰/۲۴۷۷
داده‌های صحت‌سنجی	۰/۹۹۷	۰/۰۹۴۸	۰/۳۰۷۹	۰/۳۰۷۸
تمام داده‌ها	۰/۹۹۸	۰/۰۷۳۱	۰/۲۷۰۳	۰/۲۷۰۴

میانگین خطا و σ ، انحراف معیار خطا می‌باشد. مقدار سیگما تقریباً باید برابر RMSE باشد، هنگامی که میانگین نزدیک صفر باشد این دو مقدار تقریباً برابر هستند. منحنی قرمز رنگ در نمودارها، توزیع نرمال می‌باشند و هرچه میله‌ها شبیه منحنی رفتار کنند، به این معنا است که خطاها رفتار نرمال دارند، به معنای

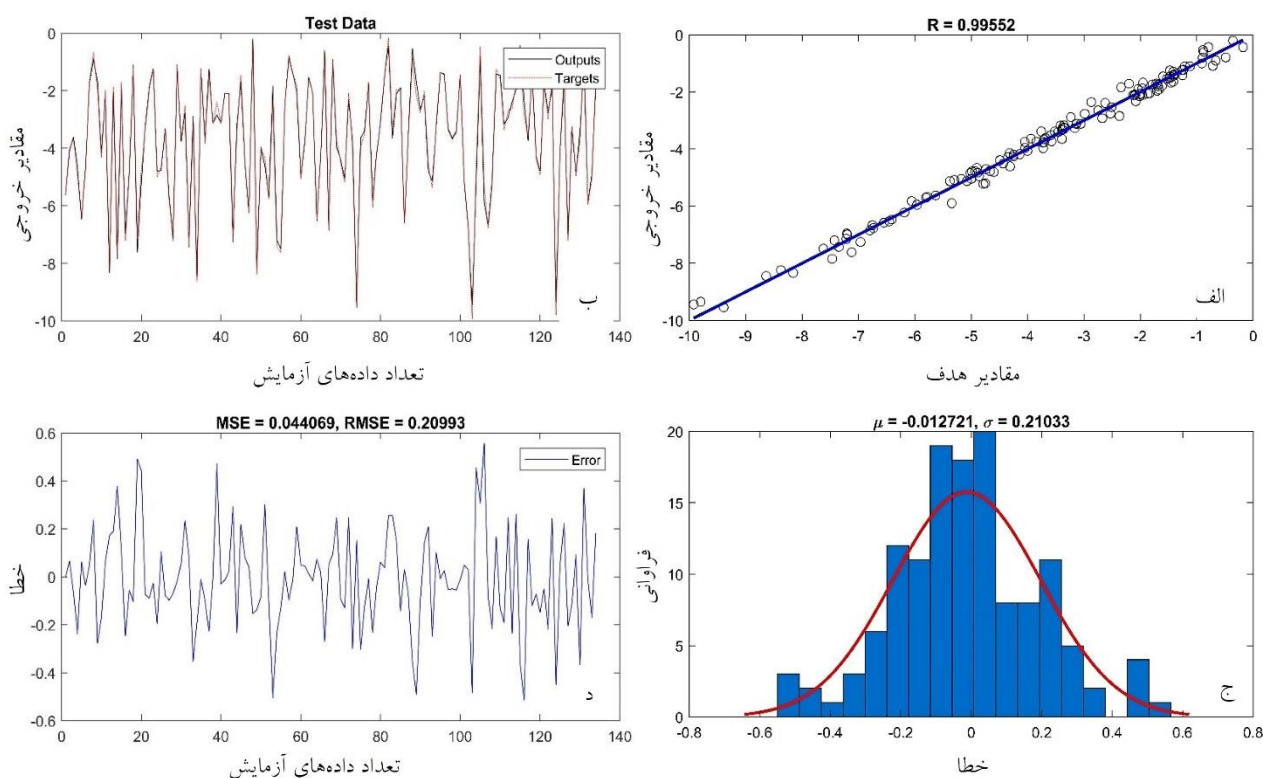
شکل‌های (۷-ج) و (۸-ج) توزیع خطای پیش‌بینی شبکه از کل مجموعه داده‌ها را نشان می‌دهد. پراکندگی هرچه متمرکزتر باشد شبکه عملکرد بهتری دارد (پراکندگی مرتبط است با میزان خطای کل شبکه عصبی). هرچه مقدار سیگما کمتر باشد نمودار متمرکزتر و عملکرد شبکه بهتر خواهد شد [17]. مقدار μ

است) نشان‌دهنده تناسب کامل با داده‌ها است [16]. نقاط اکسترمم و مینیمم نیز نشان‌دهنده این است که در آن نقاط اختلاف داده‌های هدف و خروجی شبکه بیشتر از نقاط دیگر است.

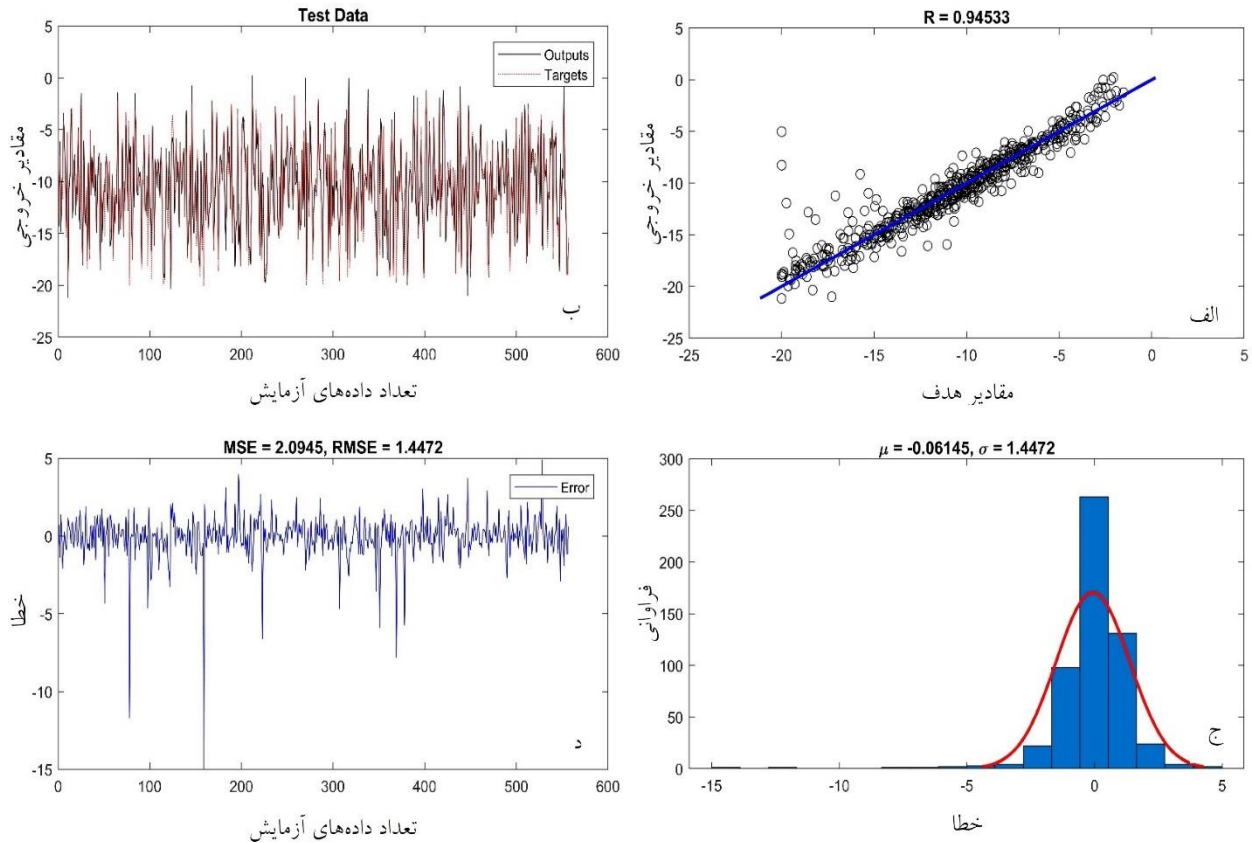
نتایج حاصل از آنالیز مدل با شبکه عصبی RBF. شبکه RBF دارای سه لایه است. لایه اول مربوط به ورودی‌های شبکه است، لایه دوم یک لایه پنهان است که شامل توابع RBF است و لایه آخر مربوط به خروجی نهایی شبکه است. از تابع گوسی به عنوان تابع انتقال در واحدهای محاسباتی استفاده می‌شود [18]. معماری شبکه عصبی RBF استفاده شده در این مقاله شامل سه لایه است (لایه ورودی، لایه پنهان و لایه خروجی) و تعداد نورون‌های لایه پنهان نیز براساس سعی و خطا، ۱۰۰ نورون انتخاب شد. در شکل (۹) و شکل (۱۰) نتایج آموزش شبکه برای داده‌های آزمایش و در جدول (۳) برای دیگر داده‌ها ارائه شده است.

دیگر هرچه منحنی نوک تیزتر باشد، مقدار سیگما کمتر، در نتیجه RMSE و MSE نیز کوچکتر خواهند شد. همان طور که در شکل مشخص است برابری قابل قبول در مقایسه چنین توزیع خطا در هر مجموعه داده (آموزش، اعتبارسنجی و آزمایش) مشاهده شد که نشان می‌دهد تقسیم‌بندی پایگاه داده مناسب است و هر مجموعه داده نماینده کل مجموعه داده است.

شکل‌های (۷-د) و (۸-د) میانگین مربعات خطا (MSE) و ریشه میانگین مربعات خطا (RMSE) را نشان می‌دهد. میانگین مربعات خطا (MSE) در شبکه عصبی، روشی برای برآورد میزان خطاست که در واقع تفاوت بین مقادیر هدف و آنچه تخمین زده شده، می‌باشد. هر چه مقدار MSE کمتر باشد، باعث می‌شود شبکه، ورودی‌ها را بهتر آموزش ببیند و خروجی دقیقتری ارائه دهد و هر قدر مقدار آن به صفر نزدیکتر باشد، نشان دهنده میزان کمتر خطاست [16]. ریشه میانگین مربعات خطا (RMSE) همیشه غیر منفی است و مقدار ۰ (تقریباً هرگز در عمل به دست نیامده



شکل ۹ نتایج داده‌های آزمایش برای پیش‌بینی تراکم توسط شبکه عصبی RBF



شکل ۱۰ نتایج داده‌های آزمایش برای پیش‌بینی عمق شیارشدگی توسط شبکه عصبی RBF


جدول ۳ نتایج داده‌های آموزش و تمام داده‌های شبکه عصبی RBF

پیش‌تراکم				
	R	MSE	RMSE	σ
داده‌های آموزش	۰/۹۹۸	۰/۰۰۹۹۸	۰/۰۹۹۹	۰/۱
تمام داده‌ها	۰/۹۹۷	۰/۰۲۰۱۷	۰/۱۴۲۰	۰/۱۴۲۱
عمق شیارشدگی				
	R	MSE	RMSE	σ
داده‌های آموزش	۰/۹۸۷	۰/۴۷۳۲	۰/۶۸۷۹	۰/۶۸۸۲
تمام داده‌ها	۰/۹۷۴	۰/۹۵۹۵	۰/۹۷۹۵	۰/۹۷۹۶


توسعه یافته و به دست آوردن برآورد بی‌طرفانه از خطای تعمیم، داده‌های اضافی که هرگز در طول توسعه مدل شبکه عصبی استفاده نشده بود، به شبکه ارائه شدند. در شکل (۱۱) و شکل (۱۲) نمودار مقایسه مقادیر هدف (مقادیر به دست آمده از نتایج آزمایشگاهی) و مقادیر خروجی (مقادیر به دست آمده از شبکه عصبی) برای پیش‌تراکم و عمق شیارشدگی ارائه شده است.

ضریب همبستگی بین خروجی‌های هدف و شبکه عصبی نتایج خوبی را نشان می‌دهد، اما عملکرد شبکه عصبی MLP بهتر از RBF است. میزان یادگیری و عملکرد شبکه عصبی زمانی بهتر است که ضریب همبستگی به یک نزدیکتر و همچنین مقادیر MSE و RMSE نزدیک به صفر باشد.

بررسی قدرت تعمیم شبکه‌های عصبی. برای اعتبار بیشتر مدل



شکل ۱۱ نتایج حاصل از مقایسه شبیه‌سازی شبکه عصبی با نتایج تجربی برای پیش‌تراکم: الف) MLP، ب) RBF



شکل ۱۲ نتایج حاصل از مقایسه شبیه‌سازی شبکه عصبی با نتایج تجربی برای عمق شیارشدگی: الف) MLP، ب) RBF

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk} بایاس نورون k در لایه پنهان، W_{ik} وزن بین ورودی i و نورون k لایه پنهان، P_i پارامتر ورودی و f_T تابع فعال‌ساز (تابع فعال‌ساز از نوع سیگموئید (tansig)) است.

$$PC(Rutting\ depth) = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk} + \sum_{i=1}^m W_{ik} P_i \right) \right] \quad (5)$$

که در آن، B_0 بایاس لایه خروجی، W_k وزن نورون k لایه پنهان و نورون لایه خروجی، B_{Hk} بایاس نورون k در لایه پنهان، W_{ik} وزن بین ورودی i و نورون k لایه پنهان، P_i پارامتر ورودی و f_T تابع فعال‌ساز (تابع فعال‌ساز از نوع گوسی (radbas)) است.

همان‌طور که از شکل‌های (۱۱ و ۱۲) مشخص است، در نمودار مقایسه، مقادیر هدف (مقادیر به دست آمده از نتایج آزمایشگاهی) و مقادیر خروجی (مقادیر به دست آمده از شبکه عصبی) برای شبکه عصبی MLP نسبت به شبکه عصبی RBF بر یکدیگر منطبق‌تر می‌باشند.

مدل ریاضی شبکه‌های عصبی MLP و RBF برای محاسبه خروجی‌های شبکه (پیش‌تراکم و عمق شیارشدگی) به ترتیب در روابط (۴ و ۵) آورده شده است.

$$PC(Rutting\ dept) = B_0 + \sum_{k=1}^n \left[W_k \cdot f_T \left(B_{Hk} + \sum_{i=1}^m W_{ik} P_i \right) \right] \quad (4)$$

جدول ۴ مقایسه پیش تراکم پیش بینی شده با شبکه عصبی و پیش تراکم آزمایشگاهی

ورودی‌ها					خروجی‌ها			درصد خطای شبکه عصبی MLP	درصد خطای شبکه عصبی RBF
چرخه بارگذاری	درصد RAP	شرایط آزمایش	شرایط پیرشدگی	نوع نمونه	PC آزمایشگاهی	PC پیش بینی شده با شبکه عصبی MLP	PC پیش بینی شده با شبکه عصبی RBF		
۵۴	٪۰	۲	۲	۱	-۴/۵۹	-۴/۵۷	-۴/۳۱	۰/٪۴۳	۶/٪۱
۱۳۸	٪۰	۲	۱	۲	-۶/۶۵	-۶/۶۱	-۷/۰۲	۰/٪۶	-۵/٪۵۶
۶۲	٪۲۰	۱	۱	۲	-۱/۶۳	-۱/۶۵	-۱/۵۲	-۱/٪۲	۶/٪۷۴
۱۹۶	٪۲۰	۲	۲	۱	-۳/۹۷	-۳/۹۵	-۴/۰۴	۰/٪۵	-۱/٪۷۶
۳۹۶	٪۴۰	۱	۲	۲	-۱/۹۲	-۱/۹۷	-۲/۰۶	-۲/٪۶	-۷/٪۲۹
۱۷۶	٪۴۰	۲	۲	۱	-۳/۲۴	-۳/۲۵	-۳/۲۸	-۰/٪۳۱	-۱/٪۲۳
۶۴	٪۵۰	۱	۲	۱	-۱/۲۷	-۱/۲۹	-۱/۱۴	-۱/٪۵۷	۱۰/٪۲۳
۴۹۸	٪۵۰	۲	۱	۲	-۷	-۶/۹۱	-۷/۰۸	۱/٪۲۸	-۱/٪۱۴

جدول ۵ مقایسه عمق شیارشدگی پیش بینی شده با شبکه عصبی و عمق شیارشدگی آزمایشگاهی

ورودی‌ها					خروجی‌ها			درصد خطای شبکه عصبی MLP	درصد خطای شبکه عصبی RBF
چرخه بارگذاری	درصد RAP	شرایط آزمایش	شرایط پیرشدگی	نوع نمونه	عمق شیارشدگی آزمایشگاهی	عمق شیارشدگی پیش بینی شده با شبکه عصبی MLP	عمق شیارشدگی پیش بینی شده با شبکه عصبی RBF		
۱۵۵۰	۰	۲	۱	۱	-۱۹/۳۸	-۱۹/۰۱	-۱۷/۲	۱/۹٪	۱۱/۲۴٪
۵۶۰	۰	۲	۱	۲	-۹/۱۱	-۸/۲۹	-۸/۲۹	۹٪	۹٪
۵۸۷۰	۲۰	۱	۲	۱	-۹/۷۱	-۹/۹۱	-۱۱/۱۱	-۲/۰۶٪	-۱۴/۴۱٪
۲۱۸۰	۲۰	۲	۱	۲	-۱۷/۳۲	-۱۷/۴۵	-۱۷/۶۲	-۰/۷۵٪	-۱/۷۳٪
۴۱۳۰	۴۰	۱	۲	۱	-۵/۵۸	-۵/۴۷	-۵/۷۶	۱/۹۷٪	-۳/۲۲٪
۱۲۶۰۰	۴۰	۱	۲	۲	-۱۹/۳۶	-۱۹/۶	-۱۸/۱۷	-۱/۲۴٪	۶/۱۴٪
۱۸۲۰۰	۵۰	۱	۲	۲	-۱۰/۱۸	-۱۰/۲۲	-۹/۸۴	-۰/۳۹٪	۳/۳۴٪
۲۰۹۰	۵۰	۲	۲	۲	-۶/۳۷	-۶/۰۹	-۶/۲۶	۴/۳۹٪	۱/۷۲٪

نتیجه گیری

در این مقاله داده‌های به دست آمده از نتایج آزمایشگاه در مطالعه قبل، توسط شبکه عصبی چندلایه (MLP) و شبکه عصبی شعاعی پایه (RBF) تحلیل شد و نتایج این روش‌ها با یکدیگر مقایسه شدند. نتایج حاصل این پژوهش به شرح زیر است:

۱. پیش بینی پیش تراکم توسط شبکه عصبی MLP دارای ضریب همبستگی ۰,۹۹۹ و توسط شبکه عصبی RBF دارای ضریب همبستگی ۰,۹۹۵ و پیش بینی عمق شیارشدگی توسط شبکه

با توجه به مقادیر وزن‌ها و بایاس‌های به دست آمده از آموزش شبکه توسط نرم‌افزار متلب و روابط بالا، برای داده‌های جدید، مقادیر پیش تراکم و عمق شیارشدگی را با شبکه عصبی پیش بینی کرده و با نتایج آزمایشگاهی مقایسه شدند و درصد خطای پیش بینی در جدول (۴ و ۵) ارائه شده است. همان طور که از جداول (۴) و (۵) مشخص است، درصد خطای شبکه عصبی MLP برای پیش بینی پیش تراکم و عمق شیارشدگی نسبت به شبکه عصبی RBF، کمتر است.

- عصبی MLP دارای ضریب همبستگی ۰,۹۹۷ و توسط شبکه عصبی RBF دارای ضریب همبستگی ۰,۹۴۵ بود که شبکه عصبی MLP دقت بیشتری در پیش‌بینی داشت.
۲. معماری بهینه شبکه عصبی MLP به صورت ۱-۱۰-۵ است، که نشان‌دهنده ۵ ورودی، ۱۰ نورون در لایه پنهان و ۱ خروجی می‌باشد.
۳. معماری بهینه شبکه عصبی RBF به صورت ۱-۱۰-۵ است، که نشان‌دهنده ۵ ورودی، ۱۰ نورون در لایه پنهان و ۱ خروجی می‌باشد.
۴. به منظور اعتبار بیشتر مدل، داده‌های اضافی که هرگز در طول مدل‌سازی استفاده نشده بودند، به کار گرفته شدند که شبکه عصبی MLP برای شبیه‌سازی این داده‌ها در مقایسه با شبکه عصبی RBF عملکرد بهتری داشت و درصد خطای پایتتری ارائه داد.

مراجع

- [1] M.Fakhri, S.M.Karimi, M. Qorbani Nik," Estimation of Pavement Roughness Based on Surface Distresses Using Artificial Neural Network (case study: Iran's arterial roads)," *Journal of Transportation Engineering*, vol. 12, no. 48, pp. 697-713(2021) (In Persian)
- [2] M.Fakhri, E. Shahebrahimi, F. Chavoshian nain," Study Rutting and Effect of Self-healing on Fatigue Behavior of Modified Asphalt Mixtures," *Journal of Transportation Research*, vol. 1, no. 67, pp. 143-156(2019) (In Persian)
- [3] A.Tarek, A. Amr, H. Mahgoub, Asphalt crack detection using thermography,: university of central florida, center for advanced transportation systems simulation (CATSS) infra mation, 2005.
- [4] S.M.Mirabdolazimi, Gh. Shafabakhsh, "Rutting depth prediction of hot mix asphalts modified with forta fiber using artificial neural networks and genetic programming technique," *Construction and Building Materials*, 148, pp. 666-674, 2017.
- [5] M.Fakhri, S.A. Hosseini, "Laboratory evaluation of rutting and moisture damage resistance of glass fiber modified warm mix asphalt incorporating high RAP proportion," *Construction and Building Materials*, 134, pp. 626-640, 2017.
- [6] A. Choubdar, A. Farajollahi, A. Ameli," Experimental Evaluation of Rutting Performance of Polymer Modified Binders and Its Relation to Rutting Resistance of Mixture," *Journal of Transportation Research*, vol. 17, no. 64, pp. 91-102(2020) (In Persian)
- [7] N. Kamboozia, H. Ziari, H. Behbahani, "Artificial neural networks approach to predicting rut depth of asphalt concrete by using of visco-elastic parameters," *Construction and Building Materials*, 158, pp. 873-882, 2018.
- [8] G.H. Shafabakhsh, O. Jafari 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, pp. 136-143, 2015.
- [9] M. Fakhri, R. Shahni Dezfouliaian," Determination of Effective Structural Number based on IRI and Surface Distress Using Regression and Neural Network Model," *Journal of Transportation Research*, vol. 15, no. 57, pp. 207-221(2019) (In Persian)
- [10] H. Ziari, A. Amini, A. Goli, & D. Mirzaiyan, "Predicting rutting performance of carbon nano tube (CNT) asphalt binders using regression models and neural networks," *Construction and Building Materials*, 160, pp.415-426, 2018.

- [11] G. Sollazzo, T.F. Fwa, G. Bosurgi, "An ANN model to correlate roughness and structural performance in asphalt pavements," *Construction and Building Materials*, 134, pp. 684-693, 2017.
- [12] H. Fizza, A. Yasir, I. Muhammad, A. Murtaza, A. Shafeeq, "A data-driven model for phase angle behaviour of asphalt concrete mixtures based on convolutional neural network," *Construction and Building Materials*, 269, p.121235, 2020.
- [13] E. Ozgan, "Artificial neural network based modelling of the Marshall Stability of asphalt concrete," *Expert Systems with Applications*, 38, pp. 6025-6030, 2011.
- [14] R.Hecht-Neilsen, *Neurocomputing*,: Addison-Wesley, Boston, 1989.
- [15] Gupta, M., Jin, L., & Homma, N., *Static and Dynamic Neural Network*,: Hobokon, New Jersey, 2004.
- [16] H. Taherkhani, A. Ebrahimimoghadam, "Prediction of the Fatigue Life of Asphalt Mixtures using Artificial Neural Networks ," *Journal of Transportation Research*, vol. 4, no. 1, pp. 45-58(2013) (In Persian)
- [17] M. Saltan, T. Mesut, K. Mustafa, "Artificial neural networks application for flexible pavements thickness modeling," *Turkish Journal of Engineering & Environmental Sciences*, vol. 26, pp. 243-248. 2002.
- [18] K. Suzuki, *Artificial Neural Networks - Methodological Advances and Biomedical Applications*,: Apr. 2011, doi: 10.5772/644.

