

# مدل‌های شبکه عصبی پیش‌بینی انرژی و چقرمگی شکست مخلوط‌های آسفالتی مبتنی بر نتایج آزمایش خمش نیم دایره‌ای (SCB)

محمد سامانی پور<sup>۱</sup>، سید محمد ضیا علوی<sup>۲</sup>، عباس بابازاده<sup>۳\*</sup>

۱- کارشناس ارشد راه و ترابری، دانشکده مهندسی عمران، دانشکده فنی، دانشگاه تهران، تهران، ایران

۲- استادیار، دانشکده مهندسی عمران، دانشکده فنی، دانشگاه تهران، تهران، ایران

۳- دانشیار، دانشکده مهندسی عمران، دانشکده فنی، دانشگاه تهران، تهران، ایران

پست الکترونیکی نویسندگان:

۱- [mohamadsamani4@ut.ac.ir](mailto:mohamadsamani4@ut.ac.ir)

۲- [zia.alavi@ut.ac.ir](mailto:zia.alavi@ut.ac.ir)

۳- [ababazadeh@ut.ac.ir](mailto:ababazadeh@ut.ac.ir)

## چکیده:

اندازه‌گیری خصوصیات شکست در آزمایش خمش نیم دایره‌ای (SCB) مخلوط‌های آسفالتی در دهه گذشته گسترش وسیعی یافته و نتایج مطالعات آزمایشگاهی در این زمینه در مقالات متعددی انتشار یافته است. هدف این مقاله ایجاد و توسعه مدل‌های شبکه عصبی به منظور پیش‌بینی انرژی شکست و چقرمگی شکست مخلوط‌های آسفالتی بر مبنای اصول داده‌کاوی است. بدین منظور، تعداد ۳۲۹۰ داده حاصل از نتایج آزمایش شکست SCB نمونه‌های آسفالتی از ۱۰۲ مقاله معتبر جمع‌آوری شد که ۱۶۲۷ داده برای پیش‌بینی انرژی شکست و ۱۶۶۳ داده برای محاسبه چقرمگی شکست مورد استفاده قرار می‌گیرد. و لایه ورودی شبکه‌های عصبی شامل داده‌های جمع‌آوری شده از مُد شکست، سرعت بارگذاری، دمای آزمایش، ضخامت نمونه، عمق شیار، وجود اصلاح‌کننده، بزرگ‌ترین اندازه اسمی سنگدانه، درصد هوا، درصد قیر، پیرشدگی، و نوع قیر مخلوط آسفالتی است. در لایه خروجی انرژی و چقرمگی شکست برای هر ورودی مفروض تولید می‌شوند. نتایج نشان می‌دهند مدل‌های شبکه عصبی ساخته شده می‌توانند انرژی شکست را با دقت ۷۵٪ و چقرمگی شکست را با دقت ۷۰٪ پیش‌بینی کنند.

## واژگان کلیدی:

مخلوط‌های آسفالتی، آزمایش خمش نیم دایره‌ای، انرژی شکست، چقرمگی شکست، شبکه عصبی.

# Neural Network Models for Predicting Fracture Energy and Toughness of Asphalt Mixtures Based on Semi-circular Bending (SCB) Test Results

Mohammad. Samanipour<sup>1</sup>, Seyed Mohammad Zia Alavi<sup>2</sup>, Abbas. Babazadeh<sup>3</sup>

1- MSc, School of Civil Engineering, College of Engineering, University of Tehran, Tehran, Iran.

2- Assistant Professor, School of Civil Engineering, College of Engineering, University of Tehran, Tehran, Iran.

3- Associate Professor, School of Civil Engineering, College of Engineering, University of Tehran, Tehran, Iran.

## Abstract:

The measurement of failure characteristics in the semi-circular bending (SCB) test of asphalt mixtures has significantly expanded over the last decade, with laboratory study results being published in numerous studies. The purpose of this article is to develop neural network models to predict the fracture energy and fracture toughness of asphalt mixtures based on data mining principles. For this purpose, 3290 data points from SCB fracture test results of asphalt samples were collected from 102 credible articles. Out of these, 1627 data points are used to predict fracture energy and 1663 data points are used to predict fracture toughness.

The input layer of the neural networks includes data collected on fracture mode, loading rate, test temperature, sample thickness, notch dimension, presence of modifier, maximum nominal aggregate size, air percentage, binder percentage, aging, and binder type of asphalt mixtures. The output layer generates the energy and fracture toughness for each assumed input. The results show that the constructed neural network models can predict fracture energy with 75% accuracy and fracture toughness with 70% accuracy.

The sensitivity analysis reveals that the loading rate, test temperature, airvoid percentage, and binder percentage are the most influential characteristics on the prediction models' results. The integration of data mining principles and neural network algorithms enhances the prediction accuracy of asphalt mixture properties, which can aid in designing more durable pavement materials.

The accuracy of the models was validated using metrics such as Root Mean Squared Error (RMSE) and Mean Squared Error (MSE), with RMSE values of 0.727 for fracture energy and 0.170 for fracture toughness. The regression analysis between actual and predicted values showed  $R^2$  values of 0.75 for fracture energy and 0.70 for fracture toughness, indicating robust model performance.

In conclusion, the neural network models based on collected SCB test data exhibit acceptable performance in predicting the fracture energy and toughness of asphalt mixtures. The study's findings highlight the importance of considering key input variables such as airvoid percentage, binder percentage, test temperature, and loading rate in developing reliable predictive models for asphalt mixture behavior.

**Keywords:** asphalt mixtures, semi-circular bending test, fracture energy, fracture toughness, neural network.

## ۱- مقدمه و مرور ادبیات


برای اندازه‌گیری خصوصیات شکست در مخلوط‌های آسفالتی آزمایش‌های مختلفی از جمله آزمایش کشش غیر مستقیم آسفالت<sup>۱</sup> و آزمایش خمش نیم دایره‌ای<sup>۲</sup> (SCB) مورد استفاده قرار می‌گیرند. آزمایش خمش نیم دایره‌ای به طور گسترده‌ای برای اندازه‌گیری خصوصیات شکست مخلوط‌های آسفالتی مورد استفاده قرار گرفته است. دو نتیجه مهم حاصل از این آزمایش انرژی شکست<sup>۳</sup> و چقرمگی شکست<sup>۴</sup> هستند که به خوبی می‌توانند رفتار مخلوط آسفالتی را در برابر ایجاد و انتشار ترک تعیین کنند. نتایج حاصل از آزمایش شکست نمونه نیم دایره‌ای، علاوه بر خصوصیات مواد و نسبت مواد تشکیل‌دهنده مخلوط آسفالتی، وابسته به دمای آزمایش، نرخ بارگذاری، خصوصیات هندسی نمونه (نظیر ضخامت و عمق شیار) و مد بارگذاری اعمالی است. هدف از این مقاله ارائه مدل‌هایی قابل‌اعتماد به منظور پیش‌بینی انرژی و چقرمگی شکست مخلوط‌های آسفالتی بر مبنای نتایج آزمایش SCB جمع‌آوری شده از مقالات و منابع معتبر پژوهشی است.

به‌طور کلی بر اساس حرکت نسبی سطح ترک خورده، سه مدل اصلی شکست در رویه آسفالتی قابل‌تعریف است [۱]:

- مد اول (حالت باز شونده): در این حالت، در اثر تغییرات دما، انقباض و انقباض مصالح، ترک ایجاد شده و سپس در اثر خمش ناشی از بارگذاری ترافیک در لایه گسترش پیدا می‌کند.
- مد دوم (حالت برشی): در این حالت، در اثر تنش‌های برشی حاصل از بارگذاری ترافیک، ترک ایجاد شده و سپس در لایه گسترش پیدا می‌کند.
- مد سوم (حالت پارگی): در این حالت، در اثر تنش‌های سطحی افقی بین چرخ و سطح روسازی که حاصل بارگذاری ترافیک است، ترک ایجاد شده و سپس در لایه گسترش پیدا می‌کند.

انرژی شکست به معنای مقاومت پتانسیل مواد در برابر شکستگی است [۲]. علاوه بر این، انرژی شکست با نسبت کار شکستگی به ناحیه شیار ترک (ضخامت و طول شیار نمونه)

اندازه‌گیری می‌شود، جایی که کار شکست نشان دهنده ناحیه زیر منحنی بار - جابجایی نشان داده شده در شکل ۱ است.



شکل ۱: منحنی بار - جابجایی آزمایش شکست [۲]

مقدار انرژی شکست  $G_f$  با استفاده از معادلات (۱) و (۲) محاسبه می‌شود.

$$G_f = \frac{W_f}{A_{lig}} \quad (1)$$

در رابطه (۱)،  $G_f$  برابر با انرژی شکست بر حسب واحد ژول بر متر مربع ( $J/m^2$ ) و  $W_f$  برابر با کار شکست با واحد ژول ( $J$ ) و  $A_{lig}$  برابر با مساحت زیر منحنی می‌باشد.

$$W_f = \int_0^u P du \quad (2)$$

در رابطه (۲)،  $P$  مقدار بار وارده با واحد نیوتن ( $N$ ) و  $u$  جابجایی خط بار بر حسب متر ( $m$ ) است.

$$A_{lig} = (r - a) \cdot t \quad (3)$$

بر اساس رابطه (۳)،  $r$  برابر با شعاع نمونه بر حسب متر ( $m$ )،  $a$  برابر با عمق شیار بر حسب متر ( $m$ ) و  $t$  برابر با ضخامت نمونه بر حسب متر ( $m$ ) می‌باشد.

مقدار چقرمگی مخلوط آسفالتی بر اساس روابط (۴)، (۵) و (۶) محاسبه می‌شود [۲]:

$$\frac{K_I}{\sigma_0 \sqrt{\pi a}} = Y_{I(0.8)} \quad (4)$$

<sup>۳</sup> Fracture Energy (Kj/m<sup>2</sup>)

<sup>۴</sup> Fracture Toughness (MPa.m<sup>0.5</sup>)

<sup>۱</sup> Indirect Tensile Strength test

<sup>۲</sup> Semi-circular Bending Test

$$Y_{I(0.8)} = 4.782 - 1.219 \left( \frac{a}{r} \right) + 0.063 \exp \left( 7.045 \left( \frac{a}{r} \right) \right) \quad (5)$$

$$\sigma_0 = \frac{P_{cr}}{2rt} \quad (6)$$

که در آنها  $K_I$  فاکتور شدت تنش،  $P_{cr}$  بار بحرانی بر حسب نیوتن و  $Y_{I(0.8)}$  پارامتر بدون بعدی است که از تحلیل اجزا محدود بدست آمده و وابسته به طول ترک و شعاع نمونه می باشد.

هوانگ و همکارانش (۲۰۰۵) [۳] در پژوهش خود به مقایسه مقاومت کششی بدست آمده از آزمایش کشش غیرمستقیم آسفالت و آزمایش خمش نمونه نیم دایره ای پرداختند. آزمایش کشش غیرمستقیم آسفالت به عنوان آزمایش استاندارد مورد استفاده برای تعیین مقاومت کششی نمونه های آسفالت بطور گسترده مورد استفاده قرار می گیرد. علیرغم مزیت های بسیار زیاد این روش، تغییر شکل های ماندگار بوجود آمده بر روی نمونه آسفالت، در زیر میله های بارگذاری دستگاه آزمایش، نامطلوب بوده و در بعضی موارد نتایج آن برای ارزیابی پتانسیل ایجاد ترک در مخلوط های آسفالتی مناسب نیست. آزمایش خمش نمونه نیم دایره ای می تواند تا حد زیادی تغییر شکل های ماندگار ایجاد شده در زیر میله بارگذاری را کاهش داده و در نتیجه به عنوان گزینه مناسب تری برای تعیین مقاومت کششی نمونه های آسفالت نسبت به آزمایش کشش غیر مستقیم در نظر گرفته شود. در ادامه، تحقیقات دانشمندان در زمینه آزمایش خمش نمونه نیم دایره ای ارائه می شوند

استفاده از پلیمر SBS باعث بهبود مقاومت چسبندگی و افزایش مقاومت ترک خوردگی می شود. با کاهش نرخ بارگذاری، نرخ رهاسازی انرژی کاهش یافته و در نتیجه جذب انرژی در نمونه ها تا لحظه شکست کمتر می شود. در سرعت های بارگذاری بالاتر، رفتار ماده به رفتار الاستیک نزدیک تر می شود [۴].

با افزایش درصد قیر، چقرمگی شکست نمونه ها کاهش و با کاهش دمای آزمایش، مقدار چقرمگی شکست نمونه ها افزایش می یابد [۵]. مقادیر چقرمگی شکست نمونه ها تحت مد II بارگذاری به طور قابل توجهی (سه برابر) بیشتر از مقاومت شکست تحت مد I بارگذاری است [۶]. عامل اصلی رشد ترک خوردگی در مد I

تنش های کششی است [۷]. با نرم تر شدن قیر مورد استفاده، سختی شکست نمونه ها در دمای پایین افزایش می یابد. استفاده از مصالح درشت دانه تر منجر به افزایش چقرمگی شکست نمونه ها می شود. با افزایش درصد فضای خالی، چقرمگی نمونه ها کاهش می یابد [۸].

ژیاو و همکاران (۲۰۰۹) [۹] با استفاده از شبکه عصبی مصنوعی ساخت مدل های پیش بینی رفتار سختی مخلوط های بتن آسفالت لاستیکی با تراشه آسفالت را بررسی کردند. در مجموع ۲۹۶ تیر مخلوط آسفالت از دو نوع لاستیک مختلف محیطی و برودتی، دو منبع تراشه آسفالت مختلف و چهار محتوی لاستیک صفر، ۵، ۱۰ و ۱۵ درصد ساخته شد. همه نمونه ها در دو دمای آزمایش مختلف ۵ و ۲۰ درجه سلسیوس آزمایش شدند. از روش آماری رگرسیون برای پیش بینی رفتار سختی این مخلوط ها از طریق ۷ متغیر ورودی که خواص مهندسی مواد تیرهای آسفالت را پوشش می دهند، استفاده شد. علاوه بر این، داده ها به صورت ۵ متغیر مستقل و یک متغیر وابسته به عنوان ورودی مدل های شبکه عصبی مصنوعی برای پیش بینی سختی تیرهای مخلوط اصلاح شده سازماندهی شدند. نتایج نشان داد که تکنیک های شبکه عصبی مصنوعی در پیش بینی عمر خستگی مخلوط اصلاح شده نسبت به مدل های پیش بینی مبتنی بر رگرسیون سنتی مؤثرتر هستند.

شفا بخش و همکاران (۲۰۱۵) [۱۰] به بررسی کاربرد شبکه های عصبی مصنوعی برای مدل سازی و پیش بینی عملکرد شیارافتادگی در مخلوط های آسفالتی پرداختند که با افزودنی های نانو و سرباره فولادی تقویت شده اند. در این مطالعه تعداد ۲۷۰ نمونه آسفالتی با دو نوع سنگدانه (طبیعی و سرباره فولادی) ساخته شدند. مخلوط ها با افزودنی های میکروسیلیکا و نانو  $TiO_2/SiO_2$  در غلظت های مختلف اصلاح شدند. آزمایش ها در سه دمای مختلف (۴۰، ۵۰ و ۶۰ درجه سانتی گراد) و پنج سطح تنش (۱۰۰ تا ۵۰۰ کیلو پاسکال) انجام شد. مدل ANN با پنج پارامتر ورودی طراحی شد: نوع سنگدانه، نوع افزودنی، مقدار افزودنی، دمای آزمایش و تنش اعمال شده. ضریب تعیین مدل شبکه عصبی مصنوعی (ANN) به میزان ۰/۹۸ گزارش شده است. این مقدار نشان دهنده دقت بسیار بالای مدل در پیش بینی شیارافتادگی مخلوط های آسفالتی تحت شرایط آزمایشی مختلف است.

میرعبدالعظیمی و شفابخش (۲۰۱۷) [۱۱] به بررسی مدل سازی پیش بینی عمق شیارافتادگی در آسفالت های مخلوط داغ (HMA) حاوی الیاف فورتا پرداختند. این مطالعه شامل آزمایش های خزش دینامیکی بر روی نمونه های آسفالت است که تحت شرایط دما و تنش های مختلف انجام شده است. این مطالعه از دو روش شبکه عصبی مصنوعی (ANN) و برنامه نویسی ژنتیکی (GP) برای توسعه مدل های پیش بینی استفاده کرده و عملکرد آنها را مقایسه کرده است. مدل های ANN و GP هم راستایی خوبی با داده های تجربی نشان دادند، در حالی که GP مدلهایی قابل تفسیر فراهم می کند، ANN انعطاف پذیری بیشتری در پیش بینی دارد. دقت مدل ANN ضریب تعیین ۰/۹۶ را ارائه می دهد در حالی که مدل GP ضریب تعیین ۰/۹۳ را نشان داده است. این نتایج نشان می دهد که هر دو مدل قابلیت پیش بینی قابل توجهی دارند، با این حال مدل ANN دقت بالاتری در پیش بینی عمق شیارافتادگی نشان می دهد.

لئون و گی (۲۰۱۹) [۱۲] با استفاده از روش برنامه نویسی بیان ژن (GEP) به مدل سازی و بررسی تأثیر زاویه داری سنگدانه ها بر تغییر شکل دائمی مخلوط های آسفالتی پرداختند. در این مطالعه، داده های آزمایشگاهی برای اندازه گیری تغییر شکل دائمی مخلوط های آسفالتی جمع آوری شدند. این داده ها شامل آزمایش نمونه هایی با مقادیر مختلف زاویه داری سنگدانه ها بود که اثر این متغیر را بر رفتار تغییر شکل تحت بارگذاری مکرر بررسی کردند. از آزمایش های خزش دینامیکی برای کمی سازی ویژگی های تغییر شکل دائمی استفاده شد. این آزمایش ها داده های لازم برای توسعه و ارزیابی مدل GEP را فراهم کردند. زاویه داری سنگدانه ها تأثیر قابل توجهی بر مقاومت مخلوط های آسفالتی در برابر تغییر شکل دائمی داشت. مدل GEP دقت بالایی داشت و ضریب تعیین حدود ۰/۹۵ نشان دهنده توافق بسیار خوب بین نتایج پیش بینی شده و داده های تجربی بود.

مجدی فرد و همکاران (۲۰۱۹) [۱۳] به بررسی استفاده از دو روش برنامه نویسی بیان ژن (GEP) و ترکیب شبکه عصبی مصنوعی با آنیلینگ شبیه سازی شده (ANN/SA) برای پیش بینی انرژی شکست در مخلوط های آسفالتی پرداختند، پایگاه داده این پژوهش شامل نتایج آزمایش های تنش دیسک شکل فشرده


(DC(T)) که در دماهای مختلف بر روی نمونه های آسفالتی انجام شده، می باشد. متغیرهای ورودی شامل: درجه بندی عملکرد قیر (PG)، محتوای قیر، اندازه و دانه بندی سنگدانه ها، محتوای آسفالت بازیافتی (RAP) و شینگل آسفالتی بازیافتی (RAS)، محتوای لاستیک خرد شده، و دمای آزمایش بودند. در نتایج این پژوهش مدل GEP عملکرد بهتری نسبت به ANN/SA نشان داد. ضریب تعیین مدل GEP ۰/۹۷ و مدل ANN/SA ۰/۹۳ بود که نشان دهنده مدل GEP نسبت به ANN/SA می باشد.

یارو و همکاران (۲۰۲۲) [۱۴] به پیش بینی مدول سختی و شیارافتادگی در قیر های اصلاح شده با کلینکر روغن پالم با استفاده از شبکه های عصبی مصنوعی و روش سطح پاسخ پرداختند. برای ساخت قیر های اصلاح شده از ۲، ۴، ۶ و ۸ درصد کلینکر روغن پالم استفاده شد. نتایج آزمایش مرسوم نشان داد که اختلاط کلینکر روغن پالم خواص قیر ساده را با افزایش سختی و حساسیت دما بهبود می بخشد. نتایج مدل های پیش بینی نشان داد که مدل شبکه عصبی مصنوعی از روش سطح پاسخ عملکرد بهتری دارد.

برغبانی و همکاران (۲۰۲۲) [۱۵] به بررسی استفاده از مدل های هوش مصنوعی برای پیش بینی رفتار شکست در مخلوط های آسفالتی با استفاده از داده های آزمایش SCB پرداختند. مدل توسعه یافته با دقت بالا نرخ رهایی انرژی کرنشی بحرانی (Jc) را به عنوان یک پارامتر کلیدی شکست پیش بینی می کند. این مدل بر مبنای روابط غیرخطی بین متغیرهای ورودی (مانند ترکیب بندی مخلوط آسفالتی، دانه بندی، نوع قیر، دمای آزمایش، نرخ بارگذاری) طراحی شده است و در بهبود طراحی و عملکرد مخلوط های آسفالتی نقش مؤثری دارد. مدل شبکه عصبی توانست با دقت بالا با ضریب تعیین حدود ۰/۹۴ مقدار Jc را پیش بینی کند. مدل توانایی عمومی سازی برای شرایط مختلف مخلوط های آسفالتی را داشت.


نوآوری این مطالعه مشخصاً کاربرد علم داده کاوی در تحلیل داده های گسترده جمع آوری شده از خصوصیات شکست مخلوط های آسفالتی و ارائه مدل های قابل اعتماد برای پیش بینی این خصوصیات با تکیه بر الگوریتم های شبکه عصبی است. به دلیل زمان نسبتاً طولانی آزمایش خمش نیم دایره ای و همچنین مطالعات بسیار زیاد قبلی در این زمینه که جمع آوری داده های مناسب برای مدلسازی انرژی شکست و چقرمگی شکست را ممکن می سازد، انجام مطالعه

برای ساخت چنین مدل‌هایی با توجه به صرفه‌جویی در هزینه و زمان قابل توجه است.



شکل ۳: تعداد مقالات جمع‌آوری شده به تفکیک کشور

شکل ۴ تعداد داده‌های جمع‌آوری شده برای انرژی شکست را به تفکیک مد شکست نشان می‌دهد. همانطور که ملاحظه می‌شود تعداد کل داده‌ها برابر ۱۶۲۷ است، که ۱۳۸۲ عدد آن برای مد I شکست و تعداد ۲۴۵ در مد II شکست قرار دارد. شکل ۵ نشان می‌دهد که تعداد داده‌های جمع‌آوری شده برای چقرمگی شکست برابر با ۱۶۶۳ است، که ۱۴۶۲ عدد از آن‌ها برای مد I شکست، و تعداد ۲۰۱ در مد II شکست قرار دارد. جدول ۱ داده‌های جمع‌آوری شده از خصوصیات مخلوط‌های آسفالتی نمونه و بازه تغییرات هر کدام را نشان می‌دهد. این خصوصیات در این مقاله برای مدل‌سازی شبکه‌های عصبی پیش‌بینی انرژی شکست و چقرمگی شکست مخلوط آسفالتی استفاده می‌شوند. به جز دو خصوصیت انرژی و چقرمگی شکست که به عنوان نتیجه شبکه عصبی در لایه خروجی قرار می‌گیرند، سایر خصوصیات لایه ورودی شبکه عصبی را تشکیل می‌دهند. دمای آزمایش به عنوان مهم‌ترین داده ورودی از بین تمامی خصوصیات در نظر گرفته می‌شود. همچنین درصد قیر، درصد هوا و نرخ بارگذاری نیز در کنار دمای آزمایش تاثیرگذاری بیشتری نسبت به سایر داده‌های ورودی دارند. برای استفاده از نوع قیر به عنوان ورودی در مدل‌های شبکه عصبی از دو ورودی دمای بالای قیر و دمای پایین قیر استفاده شده است، سایر داده‌ها نیز در جدول ۱ آورده شده‌اند.




شکل ۲: روند کلی انجام مطالعه


## ۲- مشخصات داده‌های جمع‌آوری شده

در این مطالعه، حدود ۲۵۰ مقاله برای جمع‌آوری داده‌ها مورد استناد قرار گرفت، و در مجموع تعداد ۳۲۹۰ داده قابل اعتماد از ۱۰۲ مقاله به دست آمد. شکل ۲ روند کلی مطالعه را نشان می‌دهد. اطلاعات استخراج شده شامل سال انتشار، نام نویسنده، مرجع انتشار، دمای آزمایش، نرخ بارگذاری، ضخامت نمونه، عمق شیار ایجاد شده در نمونه، مد شکست، نوع قیر بر اساس ذکر دمای بالا و پایین عملکردی قیر، درصد قیر، بزرگترین اندازه اسمی سنگدانه، درصد هوای مخلوط، نوع اصلاح‌کننده (در صورت استفاده)، شرایط پیرشدگی، مقدار چقرمگی شکست و انرژی شکست اندازه‌گیری شده برای نمونه‌های آسفالتی است. شکل ۳ تعداد مقالات جمع‌آوری شده را به تفکیک کشور نشان می‌دهد.

به عبارت دیگر، در مدل متوالی هیچ ارتباط پرش یا بازگشتی بین لایه‌ها وجود ندارد و اطلاعات فقط در یک جهت جریان می‌یابند. در مدلسازی از الگوریتم آنالیز مؤلفه‌های اصلی<sup>۲</sup> برای بهینه سازی استفاده شده است. آنالیز مؤلفه‌های اصلی یک روش ریاضی است که در تجزیه و تحلیل داده‌ها و کاهش ابعاد استفاده می‌شود. هدف اصلی این نوع آنالیز کاهش تعداد خصوصیات ورودی به شبکه عصبی ضمن حفظ اطلاعات مهم است. به طور خلاصه، آنالیز مؤلفه‌های اصلی تبدیلی خطی است که به صورت اتوماتیک ورودی‌های اصلی را طوری استخراج می‌کند که بیشترین واریانس را در داده‌ها توضیح دهند. کاهش تعداد ورودی‌ها در کاربردهایی چون تجزیه و تحلیل داده‌ها، تشخیص الگو، دسته‌بندی داده‌ها و تصاویر، روش‌های شناسایی چهره و غیره مورد استفاده قرار گرفته است. ساختار شبکه‌های عصبی این مطالعه به این صورت است که لایه ورودی خصوصیات تعیین شده در آنالیز مؤلفه‌های اصلی را به عنوان ورودی می‌گیرد، لایه‌های پنهان از تابع فعال‌سازی واحد خطی/اصلاح شده<sup>۳</sup> (Relu) استفاده می‌کند که غیرخطی را به مدل یادگیری معرفی می‌کند. لایه خروجی یک مقدار واحد تولید می‌کند که همان انرژی شکست یا چقرمگی پیش‌بینی شده توسط شبکه عصبی است. انتخاب معماری با لایه‌های مخفی متعدد به شبکه عصبی اجازه می‌دهد تا الگوهای پیچیده در داده‌ها را بیاموزد. تعداد نورون‌ها در هر لایه را می‌توان بر اساس پیچیدگی و میزان داده‌های موجود برای آموزش تنظیم کرد. تابع Relu به دلیل توانایی آن در مدل‌سازی روابط غیرخطی معمولاً در لایه‌های پنهان استفاده می‌شود. فعال‌سازی خطی برای مسائل رگرسیون مناسب است، جایی که هدف پیش‌بینی یک مقدار پیوسته در لایه خروجی است. شکل ۶ ساختمان شبکه عصبی ایجاد شده را نشان می‌دهد که در آن تمامی خصوصیات ذکر شده مخلوط آسفالتی در جدول ۱ در لایه ورودی استفاده شده است. در این مدل از یک لایه پنهان با تعداد ۵۱۲ نورون استفاده شده است و در نهایت مدل انرژی شکست یا چقرمگی را به عنوان تنها خروجی ارائه می‌دهد. با افزایش دادن تعداد لایه پنهان و یا تعداد نورون بهبودی در عملکرد مدل ایجاد نشد و زمان اجرای مدل افزایش پیدا کرد. در ساختار نشان داده شده در



شکل ۴: نسبت مدهای شکست در داده‌های جمع‌آوری شده برای انرژی شکست



شکل ۵: نسبت مدهای شکست در داده‌های جمع‌آوری شده برای چقرمگی شکست

### ۳- روش انجام مدلسازی


در این مرحله پایش داده‌ها صورت گرفت. باتوجه به نیازهای مدل شبکه عصبی از دوازده خصوصیت ورودی برای پیش‌بینی مقدار انرژی شکست و چقرمگی شکست استفاده شد، که شامل خصوصیات مخلوط و شرایط آزمایش هستند.

برای پیش‌بینی خصوصیات انرژی و چقرمگی شکست مخلوط آسفالتی از مدل شبکه عصبی متوالی<sup>۱</sup> استفاده شد. مدل شبکه عصبی متوالی یک نوع معماری شبکه عصبی است که در آن لایه‌ها به صورت ترتیبی یکی پس از دیگری قرار می‌گیرند. در این نوع معماری خروجی هر لایه به عنوان ورودی لایه بعدی استفاده می‌شود و اطلاعات از ابتدا تا انتها به صورت خطی انتقال می‌یابند.

<sup>۲</sup> Relu Activator Function

<sup>۱</sup> Sequential Neural Network Model

<sup>۲</sup> Principal Component Analysis (PCA)



شکل ۶: ساختمان شبکه عصبی

#### ۴ - نتایج عددی

در این بخش نتایج حاصل از شبکه‌های عصبی ساخته شده در این مقاله ارائه می‌شود.


جدول ۲ خطای مدل‌های شبکه عصبی انرژی شکست و چقرمگی شکست را بر حسب معیارهای ریشه خطای میانگین مربعات (RMSE) خطای میانگین مربعات (MSE) و ضریب تعیین ( $R^2$ ) نشان می‌دهد. مقدار RMSE برای انرژی شکست و چقرمگی به ترتیب برابر ۰/۷۲۷ و ۰/۱۷۰ می‌باشد که نشان می‌دهد خطای میانگین بین مقادیر پیش‌بینی شده و واقعی برای انرژی شکست نسبتاً کم و برای چقرمگی بسیار کم است. همچنین مقدار MSE برای این دو خصوصیت به ترتیب برابر ۰/۵۲۹ و ۰/۰۳۲ به دست آمده است که نشان می‌دهد خطای مربع میانگین برای پیش‌بینی انرژی شکست کمتر از ۱ و برای چقرمگی شکست بسیار کمتر از ۱ است. این مقادیر حاکی از عملکرد خوب مدل‌های شبکه عصبی در پیش‌بینی خصوصیات شکست مخلوط‌های آسفالتی است. بنابراین، این نتایج بیانگر کارایی مدل‌های شبکه عصبی در پیش‌بینی انرژی شکست و چقرمگی شکست مخلوط‌های آسفالتی هستند و می‌توانند

شکل ۶ مدل در حالت بهینه خود عمل کرده و از پیش‌برازش جلوگیری می‌کند.

جدول ۱: خصوصیات جمع‌آوری شده از مخلوط‌های آسفالتی و دامنه تغییرات آنها برای شبکه‌های عصبی انرژی شکست و چقرمگی شکست

Table 1: Properties collected from asphalt mixtures and their range of variation for fracture energy and fracture toughness neural networks

| Fracture toughness | Fracture energy | Characteristic                             |
|--------------------|-----------------|--------------------------------------------|
| 0.018 – 50.8       | 0.03 – 50.8     | Loading rate(mm/min)                       |
| 4 – 70             | 25 – 75         | Sample thickness(mm)                       |
| 2 – 30             | 0 – 50          | Notch dimension(mm)                        |
| 4.75 – 25.4        | 4.75 – 25.4     | NMAS(mm)                                   |
| 3 – 11             | 3 – 11          | airvoid percentage                         |
| 0 – 2              | 0 – 2           | Aging                                      |
| -33 – 44           | -33 – 44        | Test temperature(C°)                       |
| 28 – 70            | 64 – 82         | High binder temperatur                     |
| -64 – -16          | -34 – -16       | Low binder temperatur                      |
| 3.6 – 8.8          | 1.5 – 8.8       | Binder percentage                          |
| ---                | 0.042 – 8.92    | Fracture energy(KJ/m <sup>2</sup> )        |
| 0.06 – 2.49        | ---             | Fracture toughness (MPa.m <sup>0.5</sup> ) |



شکل ۸: خط رگرسیون بین مقادیر واقعی و پیش‌بینی شده چقرمگی شکست

برای اعتبارسنجی بهتر مدل‌های شبکه عصبی، اثر چهار ورودی مهم (درصد هوا، درصد قیر، دمای آزمایش و نرخ بارگذاری) بر پیش‌بینی خصوصیات انرژی شکست و چقرمگی مخلوط‌های آسفالتی بررسی می‌شود. نتایج آزمایشگاهی ارائه شده در مراجع [۱۶] و [۱۷] نتایج یکسانی را در مورد تاثیر درصد قیر بر انرژی شکست مخلوط‌های آسفالتی ارائه نداده‌اند، در حالی که شکل ۹ نشان می‌دهد که انرژی شکست با افزایش درصد قیر روندی افزایشی دارد. نتایج آزمایشگاهی مرجع [۱۸] نشان داده است که با افزایش درصد هوا، مقدار کار شکست کاهش یافته، و در نتیجه انرژی شکست نیز کاهش می‌یابد. ولی نتایج مدل شبکه عصبی انرژی شکست که در شکل ۱۰ ارائه شده نشان می‌دهد که با افزایش درصد هوا، انرژی شکست افزایش پیدا می‌کند.

نتایج مدل انرژی شکست ارائه شده در شکل ۱۱ نشان می‌دهد که در دماهای زیر صفر با افزایش دما، انرژی شکست افزایش و در دماهای بالای صفر با افزایش دما، انرژی شکست کاهش پیدا کرده است. این نتایج با نتایج مرجع [۱۹] برای دماهای آزمایش بالای صفر، و با نتایج مرجع [۲۰] برای دمای‌های آزمایش زیر صفر تطابق دارد. همچنین، بر اساس مرجع [۱۹]، با افزایش نرخ بارگذاری انرژی شکست روند افزایشی ملایمی دارد، که با توجه به شکل ۱۲ با نتایج مدل شبکه عصبی انرژی شکست همخوانی دارد.

بر اساس نتایج مرجع [۲۱] با افزایش درصد قیر چقرمگی شکست کاهش می‌یابد. شکل ۱۳ نشان می‌دهد که در مدل شبکه عصبی هم با افزایش درصد قیر چقرمگی شکست کاهش می‌یابد. بر


به عنوان ابزارهای مفیدی در طراحی و ارزیابی مصالح روسازی مورد استفاده قرار گیرند.

شکل‌های ۷ و ۸ خطوط رگرسیون بین مقادیر واقعی (حاصل از آزمایش) و پیش‌بینی شده انرژی شکست و چقرمگی مخلوط‌های آسفالتی را نشان می‌دهند. ضریب  $R^2$  این خطوط رگرسیون به ترتیب برابر با ۰/۷۵ و ۰/۷۰ می‌باشد که نشان دهنده دقت قابل قبول مدل‌ها در پیش‌بینی این خصوصیات است. مقدار  $R^2$  بیانگر این است که ۷۵٪ از تغییرات در مقادیر انرژی شکست و ۷۰٪ از تغییرات در مقادیر چقرمگی توسط مدل‌های شبکه عصبی تبیین می‌شود، که حاکی از توانایی مناسب این مدل‌ها در پیش‌بینی نتایج است.

جدول ۲: نتایج پیش‌بینی انرژی شکست و چقرمگی مخلوط‌های آسفالتی

Table 2: Results of prediction of fracture energy and toughness of asphalt mixtures

| Coefficient of determination ( $R^2$ ) | Mean square error (MSE) | Root mean square error (RMSE) | Characteristics of fracture                 |
|----------------------------------------|-------------------------|-------------------------------|---------------------------------------------|
| 0.75                                   | 0.529                   | 0.727                         | Fracture energy ( $\text{KJ/m}^2$ )         |
| 0.71                                   | 0.032                   | 0.170                         | Fracture toughness ( $\text{MPa.m}^{0.5}$ ) |



شکل ۷: خط رگرسیون بین مقادیر واقعی و پیش‌بینی شده انرژی شکست

اساس نتایج آزمایشگاهی مرجع [۱۹]، با افزایش درصد هوا چقرمگی شکست کاهش می‌یابد، و شکل ۱۴ نیز چنین رفتاری را برای نتایج مدل شبکه عصبی چقرمگی نشان می‌دهد. در ضمن، بر اساس مرجع [۱۹]، با افزایش دمای آزمایش در دماهای زیر صفر چقرمگی شکست کاهش پیدا می‌کند، که با نتایج مدل شبکه عصبی ارائه شده در شکل ۱۵ تطابق دارد. نتایج آزمایشگاهی مرجع [۲۲] نیز نشان داده است که با افزایش نرخ بارگذاری، چقرمگی شکست روند افزایشی دارد، و شکل ۱۶ نیز این روند افزایشی را در نتایج مدل نشان می‌دهد.


## ۵ - نتیجه‌گیری

نتایج آزمایش خمشی نیم دایره‌ای (SCB) و سایر اطلاعات مورد استفاده در این مطالعه از حدود ۱۰۰ مقاله معتبر جمع‌آوری، و از این داده‌ها برای ساخت مدل‌های شبکه عصبی پیش‌بینی نتایج آزمایش SCB، شامل انرژی شکست و چقرمگی، استفاده شد. مقالات مختلف در شرایطی متفاوت از جمله درصد قیر، افزودنی، و یا نوع قیر متفاوت و موارد دیگر آزمایش را انجام داده بودند. براساس داده‌های جمع‌آوری‌شده، دو مدل شکست در نظر گرفته شد و مدل‌سازی هم برای مد I شکست، هم برای مد II و هم برای ترکیب داده‌های این دو مدل به صورت اضافه کردن یک متغیر باینری صورت گرفت. سپس خروجی‌های مدل‌های ساخته شده مورد تجزیه و تحلیل قرار گرفت و نتایج زیر به دست آمد:


- مدل‌های شبکه عصبی ساخته شده بر مبنای داده‌های جمع‌آوری شده از مقالات دارای عملکردی قابل قبول در پیش‌بینی انرژی شکست و چقرمگی شکست هستند.
- استفاده از ترکیب داده‌های مد I و مد II شکست در ساخت مدل‌های شبکه عصبی، دقت مدل‌های پیش‌بینی انرژی شکست و چقرمگی مخلوط آسفالتی را بهبود بخشید.
- ضریب تعیین  $R^2$  خط رگرسیون بین مقادیر واقعی و پیش‌بینی شده انرژی شکست و چقرمگی شکست به ترتیب برابر با ۰/۷۵ و ۰/۷۰ شد که نشان دهنده دقت قابل قبول مدل‌های شبکه عصبی است.
- خطای پیش‌بینی انرژی شکست و چقرمگی مدل‌های شبکه عصبی برحسب معیارهای RMSE و MSE در حد قابل

قبولی بود، هر چند خطای مدل پیش‌بینی چقرمگی به مراتب کمتر است.


- مدل‌های شبکه عصبی قابل استفاده در پیش‌بینی عملکرد مواد و ساختارهای شکست‌پذیر هستند.
- اثر چهار ورودی مهم (درصد هوا، درصد قیر، دمای آزمایش و نرخ بارگذاری)
- مدل‌های شبکه عصبی ساخته شده قابلیت پیش‌بینی دقیق و مؤثر انرژی شکست و چقرمگی را در سناریوهای مختلف درصد هوا، درصد قیر، دمای آزمایش و نرخ بارگذاری نشان دادند.
- ترکیب داده‌های آزمایشگاهی و محاسباتی بهبود قابل توجهی در عملکرد و دقت مدل‌های شبکه عصبی ساخته شده ایجاد کرد.




شکل ۱۲: تغییرات انرژی شکست با افزایش نرخ بارگذاری در مدل شبکه عصبی




شکل ۹: تغییرات انرژی شکست با افزایش درصد قیر در مدل شبکه عصبی




شکل ۱۳: تغییرات چقرمگی شکست با افزایش درصد قیر در مدل شبکه عصبی



شکل ۱۰: تغییرات انرژی شکست با افزایش درصد هوا در مدل شبکه عصبی




شکل ۱۴: تغییرات چقرمگی شکست با افزایش درصد هوا در مدل شبکه عصبی




شکل ۱۱: تغییرات انرژی شکست با افزایش دمای آزمایش در مدل شبکه عصبی

4. Lancaster, I. and Khalid, H., 2011. Crack growth analysis of polymer modified asphalt using linear and non linear fracture mechanics. *Fifth International Conference on Bituminous Mixtures and Pavements*, pp.612–623.
5. Biligiri, K., Said, S. and Hakim, H., 2012. Asphalt mixtures crack propagation assessment using semi-circular bending tests. *International Journal of Pavement Research and Technology*, 5(4), pp.209–217.
6. Im, S., Ban, H. and Kim, Y. R., 2014. Mode-dependent fracture behavior of asphalt mixtures with semicircular bend test. *Transportation Research Record, Journal of the Transportation Research Board*, pp.23–31. <https://doi.org/10.3141/2447-03>
7. Mahmoud, E., Saadeh, S., Hakimelahi, H. and Harvey, J., 2014. Extended finite-element modelling of asphalt mixtures fracture properties using the semi-circular bending test. *Road Materials and Pavement Design*, 15, pp.153–166. <https://doi.org/10.1080/14680629.2013.863737>
8. Pirmohammad, S. and Ayatollahi, M., 2015. Asphalt concrete resistance against fracture at low temperatures under different modes of loading. *Cold Regions Science and Technology*, 110, pp.149–159. <https://doi.org/10.1016/j.coldregions.2015.03.001>
9. Xiao, F. and Serji, N., 2009. Artificial neural network approach to estimating stiffness behavior of rubberized asphalt concrete containing reclaimed asphalt pavement. *Journal of Transportation Engineering*, 135, (8), pp.580–589. [https://doi.org/10.1061/\(ASCE\)TE.1943-5436.0000014](https://doi.org/10.1061/(ASCE)TE.1943-5436.0000014)
10. Shafabakhsh, G. H., Jafraei Ani, O. and Talebsafa, M., 2015. Artificial neural network modeling (ANN) for predicting rutting performance of nano-modified hot-mix asphalt



شکل ۱۵: تغییرات چقرمگی شکست با افزایش دمای آزمایش در مدل شبکه عصبی



شکل ۱۶: تغییرات چقرمگی شکست با افزایش نرخ بارگذاری در مدل شبکه عصبی

## منابع

1. Pirmohammad, S. and Ayatollahi, M., 2020. *Fracture behavior of asphalt materials*. <http://dx.doi.org/10.1007/978-3-030-39974-0>
2. Huang, B., Shu, X. and Tang, Y., 2005. Comparison of semi-circular bending and indirect tensile strength tests for HMA mixtures. *Advances in Pavement Engineering*, pp.1–12. [https://doi.org/10.1061/40776\(155\)14](https://doi.org/10.1061/40776(155)14)
3. AASHTO. Determining the fracture energy of asphalt mixtures using the semi circular bend geometry(SCB) In. designation: *TP 105-20*. Washington, DC 200042010.

- for asphalt mixtures using an artificial neural network approach. *Journal of the Transportation Research Board*.  
<https://doi.org/10.1177/03611981211036357>
16. Abuawad, I., Al-Qadi, I. and Trepanier, J., 2015. Mitigation of moisture damage in asphalt concrete: testing techniques and additives/modifiers effectiveness. *Construction and Building Materials*, 84, pp.437–443.  
<https://doi.org/10.1016/j.conbuildmat.2015.03.001>
  17. Hamed, G. H., Saedi, D. and Ghahremani, H., 2020. Effect of short-term aging on low-temperature cracking in asphalt mixtures using mechanical and thermodynamic methods. *ASCE*, 32.  
[https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0003388](https://doi.org/10.1061/(ASCE)MT.1943-5533.0003388)
  18. Malek, M. and Keymanesh, M., 2023. Impact of thickness, void content, temperature and loading rate on tensile fracture toughness and work of fracture of asphalt mixtures-an experimental study using the SCB test. *Engineering Solid Mechanics*, 11, pp.163–174.  
<https://doi.org/10.5267/j.esm.2023.000015>
  19. Nsengiyumva, G., You, T. and Kim, Y., 2017. Experimental-statistical investigation of testing variables of a semicircular bending (SCB) fracture test repeatability for bituminous mixtures. *Journal of Testing and Evaluation*, 45, pp.1691–1701.  
<https://doi.org/10.1520/JTE20160103>
  20. X., J. and Li, M., 2010. Using semi circular bending test to evaluate low temperature fracture resistance for asphalt concrete. *Experimental Mechanics*, 50, pp.867–876.  
<https://doi.org/10.1007/s11340-009-9303-0>
  - mixtures containing steel slag aggregates. *Construction and Building Materials*, 85, pp.136–143.  
<https://doi.org/10.1016/j.conbuildmat.2015.03.060>
  11. Mirabdolazimi, S. and Shafabakhsh, G., 2017. 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.  
<https://doi.org/10.1016/j.conbuildmat.2017.05.088>
  12. Leon, P. L. and Gay, D., 2019. Gene expression programming for evaluation of aggregate angularity effects on permanent deformation of asphalt mixtures. *Construction and Building Materials*, 211, pp.470–478.  
<https://doi.org/10.1016/j.conbuildmat.2019.03.225>
  13. Majdifard, H., Jahangiri, B., Buttlar, W. G. and Alavi, A. H., 2019. New machine learning-based prediction models for fracture energy of asphalt mixtures. *Measurement*, 135, pp.438–451.  
<https://doi.org/10.1016/j.measurement.2018.1.081>
  14. Yaro, N., Sutanto, M. H., Habib, N. Z., Napiah, M., Usman, A. and Muhammad, 2022. Comparison of response surface methodology and artificial neural network approach in predicting the performance and properties of palm oil clinker fine modified asphalt mixtures. *Construction and Building Materials*, 324, pp.1–12.  
<https://doi.org/10.1016/j.conbuildmat.2022.126618>
  15. Barghabany, P., Zhang, J., Mohammad, L. N. and Cooper, S. B., 2022. Novel model to predict critical strain energy release rate in semi-circular bend test as fracture parameter

21. Bui, H. and Mofreh, S., 2021. Effects of specimen size and loading conditions on the fracture behaviour of asphalt concretes in the SCB test. *Engineering Fracture Mechanics*, 242, <https://doi.org/10.1016/j.engfracmech.2020.107452>
22. Arabani, M. and Ferdowsi, B., 2007. Evaluating the semi-circular bending test for HMA mixtures. *International Journal of Engineering*, 22, pp.47–58. <https://doi.org/10.22068/ije.22.1.47>