

Original Research

Prediction of compressive strength of concrete with rubber fibers using artificial neural networks

Seyed Reza Salim Bahrami^{1*}

¹PhD, Department of Civil Engineering, Faculty of Imam Mohammad Baqer, Mazandaran Branch, Technical and Vocational University (TVU), Sari, Iran.

ARTICLE INFO**Received:** 10.22.2020**Revised:** 02.08.2021**Accepted:** 03.07.2021**Keyword:**

Artificial Neural Networks

Recycling

Environment

Concrete

Waste Rubber Particles

ABSTRACT

A non-recyclable material that enters the environment is used car tires. Research shows that used tires are made of materials that, due to their non-decomposition under normal conditions, cause pollution and damage to the environment. According to research, one method of removing these materials is to use rubber waste in concrete. Therefore, in this study, aggregate composites were replaced by waste rubber particles the compressive strength of concrete was estimated by artificial neural network using the input parameters water to cement ratio, superplasticizer additive and granulation weight composition. The results of this study were compared with other related research studies and confirmed the superiority and high accuracy of the artificial neural network obtained in this study. The a-20 engineering index of the neural network was determined to be one and the error of 99% of the data was less than 15%, indicating the appropriate approximation of the compressive strength of concrete containing waste rubber particles by the artificial neural network. In addition, the results of the sensitivity analysis using the Millen method indicated a 40% effect of the weight of the superplasticizer additive as a sensitive parameter in this type of concrete.

***Corresponding Author:**

Seyed Reza Salim Bahrami

Email:

salimbahrami@semnan.ac.ir

تخمین مقاومت فشاری بتن دارای الیاف لاستیک ضایعاتی با استفاده از شبکه عصبی مصنوعی

سید رضا سلیم بهرامی*

۱- دکتری، گروه مهندسی عمران، دانشکده امام محمد باقر (ع)، دانشگاه فنی و حرفه‌ای استان مازندران، ایران.

چکیده

اطلاعات مقاله

یکی از مواردی که به‌عنوان مواد غیرقابل بازیافت وارد محیط‌زیست می‌شود، لاستیک‌های مستعمل خودرو است. تحقیقات انجام‌شده نشان می‌دهد لاستیک‌های مستعمل از موادی تشکیل‌شده‌اند که به دلیل تجزیه نشدن آن‌ها در شرایط معمول، سبب ایجاد آلودگی و آسیب به محیط‌زیست شده است. بر اساس تحقیقات صورت گرفته، یکی از راه‌های حذف این مواد، استفاده از ضایعات لاستیکی در بتن است. لذا در این تحقیق، با جایگزینی ذرات لاستیکی ضایعاتی به‌جای سنگ‌دانه‌ها و تخمین مقاومت فشاری بتن توسط شبکه عصبی مصنوعی با استفاده از پارامترهای ورودی (نسبت آب به سیمان، ماده افزودنی فوق‌روان‌کننده و ترکیب وزنی دانه‌بندی) پرداخته شده است. نتایج حاصل از این پژوهش با پژوهش‌های مرتبط محققان مورد مقایسه قرار گرفت که حاکی از برتری و دقت بالای شبکه عصبی مصنوعی حاصله در این پژوهش است. شاخص مهندسی $a=20$ برای شبکه عصبی برابر یک به‌دست‌آمده و خطای ۹۹ درصد از داده‌ها، کمتر از ۱۵ درصد به‌دست‌آمده که نشان از تقریب مناسب مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی توسط شبکه عصبی مصنوعی است. همچنین نتایج آنالیز حساسیت با استفاده از روش میلن حاکی از تأثیر ۴۰ درصدی مقدار وزنی ماده افزودنی فوق‌روان‌کننده به‌عنوان پارامتر حساس در این نوع از بتن است.

دریافت مقاله: ۱۳۹۹/۰۸/۰۱

بازنگری مقاله: ۱۳۹۹/۱۱/۲۰

پذیرش مقاله: ۱۳۹۹/۱۲/۱۷

کلید واژگان:

شبکه عصبی مصنوعی
بازیافت
محیط‌زیست
بتن
ذرات لاستیکی ضایعاتی

*نویسنده مسئول: سید رضا سلیم بهرامی

پست الکترونیکی:

salimbahrami@semnan.ac.ir

مقدمه

در بافت‌های بدن، در هر سال فقط در ایالات متحده ۲۵۰ میلیون تایلر فرسوده به وزن بیش از ۳ میلیون تن جمع‌آوری می‌شود. همچنین یکی از بزرگ‌ترین چالش‌های محیط‌زیستی موجود در اطراف کلان‌شهرها در جهان نحوه بازیافت و حذف مواد لاستیکی زائد از چرخه زیست‌محیطی می‌باشد. یکی از راه‌حل‌های که برای حل این مشکل پیشنهاد شده است استفاده از ذرات لاستیک تایلر به‌عنوان یک ماده افزودنی در مصالح بر پایه سیمان است [۱]. اگرچه بتن یک ماده محبوب و پر استفاده در مصالح ساختمانی است اما دارای نقطه‌ضعف‌هایی نیز می‌باشد. همانند مقاومت کششی پایین، شکل‌پذیری پایین، جذب انرژی کم، انقباض و جمع‌شدگی بتن و در پی آن ترک‌خوردگی ناشی از آن و در نهایت ترک‌های ناشی از عمل‌آوری نامناسب و سخت‌شدگی بتن است. یافته‌های جدید نشان می‌دهد که استفاده از ذرات تایلرهای فرسوده به میزان زیادی می‌تواند این نقاط ضعف بتن را برطرف کند. هرچند استفاده از لاستیک در آسفالت بیشتر از یک دهه است که صورت می‌گیرد اما کاربرد آن در بتن به‌تازگی صورت گرفته است و تحقیقات زیادی بر امکان‌سنجی آن انجام شده است [۲-۶].

شبکه‌های عصبی مصنوعی که برآمده از مدل مغز انسان هستند، امروزه توانسته با برقراری رابطه میان متغیرهای ورودی با صرف کمترین زمان و هزینه، مورد اقبال جامعه مهندسی جهت پیش‌بینی مقاومت فشاری بتن برآید. روش‌های مدل‌سازی سنتی به‌منظور تخمین و پیش‌بینی خواص بتن حاوی ذرات لاستیکی ضایعاتی بر پایه‌ی محدودی از اعداد و پارامترها بودند که به‌وسیله رگرسیون‌گیری خطی یا چند متغیره به دست می‌آمد. اگر داده‌های جدید تا اندازه‌ای با داده‌های اولیه متفاوت باشند، نه‌تنها متغیره‌ها، بلکه لازم است شکل روابط نیز تغییر کند [۷]. اما در مقایسه شبکه عصبی مصنوعی لازم نیست که رابطه با شکل و فرم خاص باشد. در عوض لازم است داده‌های ورودی و خروجی کافی در اختیار باشد. توانایی و کارایی شبکه‌های عصبی با رگرسیون‌های خطی و نمایی و حتی چندمتغیره مقایسه شده است [۸]. این مقایسه‌ها ثابت کرد که شبکه‌های عصبی به‌عنوان یک رهیافت هوشمند در مقابل روش‌های رگرسیونی چندمتغیره است. این در حالی است که روش‌های رگرسیونی کارایی خوبی داشته و در بسیاری از تحقیقات استفاده شده یا در حال استفاده است. یکی دیگر از امتیازات رهیافت شبکه‌های عصبی مصنوعی، تخمین کارایی و ارتباط متغیره‌های ورودی مختلف با یکدیگر است [۹، ۱۰].

نتایج تحقیقات توپچو^۱ و همکاران [۱۱] برای پیش‌بینی مقاومت فشاری بتن لاستیکی با استفاده از شبکه عصبی مصنوعی نشان داد که نتایج آموزش و آزمون داده‌های ورودی مشابه نتایج آزمایشگاهی است. همچنین آنان به این نتیجه دست یافتند که شبکه عصبی مصنوعی و مدل‌های منطق فازی می‌توانند خواص مکانیکی بتن با الیاف ضایعات لاستیکی را بدون هیچ‌گونه آزمایشی به دست آورد.

گزاوغلو و همکاران [۱۲] برای پیش‌بینی خصوصیات مکانیکی بتن حاوی ذرات لاستیکی ضایعاتی، شبکه عصبی مصنوعی و الگوریتم ژنتیک به‌دست‌آمده از ۷۰ نمونه آزمایشگاهی را پیشنهاد کردند. نتایج آنان حاکی از دقت بالای پیش‌بینی توسط دو الگوریتم (ANN و GEP) به‌کار رفته بوده است. هرچند مدل پیشنهادی الگوریتم ژنتیک کاربرپسندتر نسبت به شبکه عصبی است اما کارایی و دقت شبکه عصبی بیشتر از بقیه سیستم‌های پیش‌بینی منتج شد. گوپتا^۲ و همکاران [۱۳] به پیش‌بینی ویژگی‌های مکانیکی بتن حاوی ذرات لاستیکی در معرض دمای بالا با استفاده از شبکه عصبی مصنوعی پرداختند. نتایج آنان حاکی از آن بود که پارامتر دما بیشترین تأثیر را بر روی تمام پارامترهای خروجی به دنبال دارد. همچنین ال‌خوجا^۳ [۱۴] و همکاران و نایارکو^۴ و همکاران [۱۵] با مدل‌سازی تأثیر لاستیک

¹ Topçu et al.

² Gupta et al.

³ El-Khoja et al.

⁴ Hadzima-Nyarko et al.

ضایعاتی بر مقاومت فشاری بتن توسط شبکه‌های عصبی مصنوعی به این نتیجه رسیدند که شبکه عصبی مصنوعی در پیش‌بینی مقاومت فشاری بتن حاوی ذرات لاستیک ضایعاتی عملکرد مناسبی دارد. سهرابی و همکاران [۱۶] به پیش‌بینی مقاومت فشاری بتن حاوی خرده‌لاستیک با استفاده از مدل‌های فازی عصبی و شبکه‌های عصبی مصنوعی پرداختند که نتایج آنان حاکی از آن بود که سیستم‌های عصبی و فازی توانسته‌اند به خوبی مدل مناسبی را به‌عنوان جایگزین آزمایش‌های وقت‌گیر تکنولوژی بتن ارائه دهد. همچنین دقت شبکه عصبی تابع بنیادی شعاعی به نسبت سیستم استنتاج تطبیقی فازی مبتنی بر شبکه عصبی اندکی بهتر می‌باشد لیکن سرعت آموزش‌پذیری بسیار کندتر از سیستم فازی-عصبی است.

در پژوهش گیوچن لی و همکاران [۱۷] که با استفاده از الگوریتم جنگل تصادفی بدنبال به‌دست‌آوردن مقاومت فشاری بتن دارای الیاف لاستیکی بوده است؛ نتایج آن حاکی از دستیابی به ضریب رگرسیون ۰/۹۶ است که در مقایسه با نتایج پژوهشگران دیگر ضریب رگرسیون بالایی به نظر نمی‌رسد. جلال و همکاران [۱۸] با استفاده از شبکه عصبی مصنوعی، رابطه‌ای برای تخمین مقاومت فشاری بتن دارای الیاف لاستیکی پیشنهاد دادند. نتایج آنان نشان داد که با وجود رفتار پیچیده این نوع از بتن، رگرسیون به‌دست‌آمده از رابطه پیشنهادی ۰/۹۸ بوده که میزان خطای حاصل از این رابطه کم است.

از سوی دیگر، برخی از محققان در مورد تأثیر نسبت آب به سیمان بر روی خصوصیات مکانیکی مانند مقاومت فشاری بتن حاوی ذرات لاستیکی تحقیق کرده‌اند. نتایج نشان می‌دهد که با افزایش نسبت آب به سیمان (W/C) مقاومت فشاری بتن کاهش یافته است. اویگون اوغلو^۱ و همکاران [۱۹] با بررسی تأثیر جایگزینی جزئی سنگ‌دانه‌های درشت به همراه لاستیک ضایعاتی در بتن به این نتیجه رسیدند که برای یک مقدار لاستیک ضایعاتی معین و ثابت، با کاهش نسبت آب به سیمان، مقاومت فشاری بتن افزایش می‌یابد. لازم به ذکر است که بسیاری از محققان در بتن حاوی ذرات لاستیکی ضایعاتی به‌منظور کاهش نسبت آب به سیمان از مواد افزودنی فوق‌روان‌کننده استفاده می‌نمایند. از طرفی افزایش نسبت آب به سیمان باعث افزایش تخلخل کل شده و خصوصیات مکانیکی بتن حاوی ذرات لاستیکی وابسته به میزان تخلخل و توزیع منافذ آن می‌گردد [۲۰].

توماس^۲ و همکاران [۲۱] در مطالعه خود مقادیر نسبت آب به سیمان را ۰/۴، ۰/۴۵ و ۰/۵ و مقدار لاستیک ضایعاتی استفاده شده در بتن را از ۰٪ تا ۲۰٪ با دوره تناوب ۲/۵٪ در نظر گرفتند و تغییرات خواص موجود در مخلوط بتنی را مورد بررسی قرار داده‌اند. نتایج نشان می‌دهد که با افزایش درصد لاستیک ضایعاتی خرد شده و نسبت آب به سیمان مقدار تخلخل بتن افزایش می‌یابد. از طرف دیگر سیستم منافذ موجود در مواد مبتنی بر سیمان به‌صورت ژله‌ای است که به‌طور مستقیم با انقباض و خزش در ارتباط است و از طریق تخلخل آن بر استحکام بتن اثر نمی‌گذارد.

شبکه عصبی مصنوعی، روشی برای پیش‌بینی حل مسئله تحت آزمایش‌های انجام‌شده قبلی است که با آموزش به آن می‌توان با صرف زمان و هزینه بسیار کم به دقت قابل قبولی از نتایج دست‌یافت. شبکه‌های عصبی مصنوعی به کمک بهره‌گیری از قابلیت‌های مغز انسان و با استفاده از تجربیات قبلی می‌توانند در موقعیت‌های جدید، پیش‌بینی انجام دهند. امروزه یکی از مهم‌ترین کارکردهای این شاخه از محاسبات نرم، شناسایی الگوی بین داده‌ها است. در سال‌های اخیر استفاده از شبکه‌های عصبی مصنوعی در زمینه مهندسی سازه و زلزله رشد قابل توجهی داشته است.

لذا در این پژوهش به‌منظور پیش‌بینی مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی، از شبکه‌های عصبی مصنوعی استفاده و تلاش شده است که با پالایش داده‌های ورودی و انتخاب تعداد بیشتری داده به نسبت کارهای گذشته، مدلی بهینه‌تر و دارای دقت بالاتر که در کمترین زمان، نتیجه‌ای مطلوب با کمترین خطا به نسبت پژوهش‌های


¹ Uygunoglu et al.

² Thomas et al.

صورت گرفته در گذشته حاصل گردد. همچنین شبکه حاصل از این پژوهش می تواند جایگزین مناسبی برای روش های زمان بر و پرهزینه آزمایشگاهی باشد و به کمک شبکه عصبی و با یافتن پارامتر تأثیرگذار می توان به طرح اختلاط بهینه دست یافت.

معرفی ساختار شبکه عصبی مصنوعی

یکی از مدل های پر کاربرد در محاسبات نرم، شبکه عصبی است که الهام گرفته از مغز انسان و شامل اتصالات وزن دار بین نرون های مصنوعی است. در حالت کلی در شبکه های عصبی سه نوع لایه نورونی وجود دارد: لایه ورودی که وظیفه دریافت اطلاعات خام را بر عهده دارد. لایه های پنهان که عملکرد این لایه ها به وسیله ورودی ها و وزن ارتباط بین آن ها و لایه های پنهان تعیین می شود. لایه خروجی نیز عملکرد آن بسته به فعالیت واحد پنهان و وزن ارتباطی بین واحد پنهان و خروجی است. اختلاف بین خروجی شبکه عصبی و خروجی مطلوب، تابع خطا تعریف می شود. سپس خطا برگشت می نماید و وزن ها و بایاس ها اصلاح می گردد تا خطا را کاهش دهد. این پروسه که به گام یادگیری معروف است، آن قدر تکرار می شود تا بیشترین دقت در تعیین خروجی ها ایجاد شود. صحت سنجی نیز در حین یادگیری به صورت غیرمستقیم انجام شده تا بیش برآزش^۱ شبکه عصبی را نشان دهد و نقطه توقف فرایند یادگیری زمانی است که خطای صحت سنجی شروع به افزایش یابد. آخرین گام مدل سازی شبکه عصبی مصنوعی، گام آزمایش است که صرفاً برای تعیین میزان کارایی شبکه آموزش دیده انجام می شود [۲۲]. شکل ۱ نمای شماتیکی از یک نرون محاسباتی و اجزای آن را نشان می دهد.



شکل ۱: نمای شماتیکی از یک نرون محاسباتی شبکه عصبی و اجزای آن [۲۳]

مطابق شکل ۱، هر کدام از گره ها در هر لایه به صورت کامل یا جزئی با گره های موجود در لایه های دیگر به کمک مقادیر وزنی اتصال می یابد. ورودی هر گره که از لایه قبلی به لایه فعلی وارد شده است (X_i) ، در یک مقدار وزنی تعدیل پذیر (W_{ij}) ضرب شده و در هر گره مقادیر حاصل ضرب $X_i \times W_{ij}$ با هم جمع می شوند. در نهایت، حاصل جمع فوق با یک مقدار آستانه θ_j جمع می شود. ورودی مرکب حاصل از این ترکیب (I_j) در یک تابع انتقال غیر خطی (تابع سیگموئیدی) قرار می گیرد و خروجی گره (Y_i) حاصل می شود. خروجی حاصل از یک گره، ورودی مورد نیاز برای گره های دیگر را فراهم می کند. این فرایند در رابطه ۱ به طور خلاصه نشان داده شده است.

$$I_j = \sum (w_{ij} \times x_i) + \theta_j \quad (1)$$

$$Y_i = f(I_j)$$

¹ Overfitting

مدل‌سازی

بانک اطلاعاتی گسترده و قابل‌اعتماد پیش‌شرط لازم برای عملکرد موفق هر شبکه عصبی مصنوعی است. لذا برای آموزش شبکه عصبی از اطلاعات آزمایشگاهی در حوزه بتن لاستیکی استفاده شده است. در این پژوهش، از بانک اطلاعاتی ۱۰۰ طرح اختلاط گزارش‌شده توسط مراجع معتبر [۱۲، ۲۴-۲۷] مطابق جدول ۱ استفاده شده است. در این پژوهش به‌منظور بررسی تأثیر نسبت آب به سیمان، ماده افزودنی فوق‌روان‌کننده و دانه‌بندی بر روی مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی مدلی در شبکه عصبی مصنوعی با ۱۰۰ طرح اختلاط آزمایشگاهی در نظر گرفته شده است. ترکیب طرح اختلاط استفاده شده شامل سیمان، آب، فوق‌روان‌کننده، درشت‌دانه (شن)، ریزدانه (ماسه)، خرده‌های لاستیک (۴-۰ میلی‌متر) و تراشه‌های تایر (۱۰-۴ میلی‌متر) است. لذا نسبت آب به سیمان (W/C)، وزن فوق‌روان‌کننده (SP) و وزن ترکیبات دانه‌بندی به‌عنوان پارامترهای ورودی به شبکه عصبی می‌باشد و خروجی آن مقاومت فشاری بتن است. در ادامه مشخصات آماری و حدود تغییرات پارامترهای ورودی و خروجی به شبکه عصبی مصنوعی در جدول ۲ ارائه شده است.

جدول ۱: بانک اطلاعاتی ۱۰۰ طرح اختلاط

ردیف	W/C	SP	CS	fc	ردیف	W/C	SP	CS	fc	ردیف	W/C	SP	CS	fc
1	0.42	13.5	1743.02	81	35	0.4	13.5	1467.6	26.4	69	0.4	3.15	1595.6	37.9
2	0.44	13.5	1735.97	82.7	36	0.42	13.5	1461.7	29.6	70	0.4	3.6	1567.9	33.75
3	0.47	13.5	1728.92	84	37	0.44	13.5	1455.8	30.5	71	0.4	4.05	1540.3	31
4	0.6	5.25	1773.4	53.8	38	0.47	13.5	1449.8	31.8	72	0.4	4.5	1512.5	25
5	0.63	5.25	1767.9	56.8	39	0.6	5.25	1487.1	16.2	73	0.4	3.15	1625.1	42.2
6	0.67	5.25	1762.4	57.7	40	0.67	5.25	1477.9	20.1	74	0.4	3.6	1571.4	36.13
7	0.71	5.25	1756.9	60.3	41	0.71	5.25	1473.3	21.2	75	0.4	3.55	1518	32.43
8	0.4	13.5	1721.8	70.4	42	0.4	13.5	1185	10.5	76	0.4	4.5	1464.4	26.1
9	0.44	13.5	1707.9	75.4	43	0.42	13.5	1180.2	11.2	77	0.4	5.4	1357.2	17
10	0.47	13.5	1701	78.3	44	0.44	13.5	1175.4	11.6	78	0.47	3.25	1600	52.5
11	0.6	5.25	1744.8	47	45	0.47	13.5	1170.8	11.7	79	0.47	3.25	1600	52.1
12	0.63	5.25	1739.3	50.2	46	0.6	5.25	1200.8	7.1	80	0.47	3.25	1600	51.2
13	0.67	5.25	1734	52.5	47	0.67	5.25	1193.4	8.1	81	0.47	3.25	1600	50.8

ردیف	W/C	SP	GS	f _c	ردیف	W/C	SP	GS	f _c	ردیف	W/C	SP	GS	f _c
14	0.71	5.25	1728.7	55.4	48	0.71	5.25	1189.7	8.4	82	0.47	3.25	1420	28.1
15	0.42	13.5	1686.8	67.8	49	0.5	13.5	1721.88	85.77	83	0.47	3.25	1420	27.7
16	0.44	13.5	1679.9	68.2	50	0.75	5.25	1751.5	59.7	84	0.47	3.25	1420	28.3
17	0.47	13.5	1673.1	68	51	0.5	13.5	1694.1	79.1	85	0.47	3.25	1420	28.6
18	0.6	5.25	1716.1	41.5	52	0.5	13.5	1666.3	69.4	86	0.47	3.25	1335	21.5
19	0.63	5.25	1710.8	43.1	53	0.75	5.25	1694.9	51.3	87	0.47	3.25	1335	19.6
20	0.71	5.25	1700.2	49.3	54	0.5	13.5	1610.7	61.7	88	0.47	3.25	1335	19.1
21	0.4	13.5	1637	50.7	55	0.75	5.25	1638.3	41.2	89	0.5	1.52	1785	32
22	0.42	13.5	1630.5	55.3	56	0.5	13.5	1555.1	47	90	0.5	1.52	1788.4	33
23	0.44	13.5	1659.9	56.3	57	0.75	5.25	1581.8	34.2	91	0.5	1.52	1788.5	30
24	0.47	13.5	1617.3	55.6	58	0.5	13.5	1443.9	31.8	92	0.5	1.52	1790	25
25	0.6	5.25	1658.9	31.8	59	0.75	5.25	1468.7	23.1	93	0.5	1.52	1804	30
26	0.67	5.25	1648.6	37.6	60	0.75	5.25	1186	8.6	94	0.5	1.52	1813	27
27	0.71	5.25	1643.6	41.3	61	0.4	1.8	1678.6	53.5	95	0.5	1.52	1823	20
28	0.4	13.5	1580.6	40.3	62	0.4	2.25	1652.7	49.7	96	0.47	3.03	1839.9	63.7
29	0.42	13.5	1574.3	44.5	63	0.4	2.7	1626.8	44.5	97	0.47	3.29	1743.8	39.5
30	0.44	13.5	1567.7	45.1	64	0.4	3.15	1601	40.7	98	0.47	3.61	1695.7	26.3
31	0.47	13.5	1561.5	46.4	65	0.4	3.6	1575.1	35.3	99	0.47	3.99	1647.7	17.9
32	0.63	5.25	1596.6	28.8	66	0.4	4.05	1549.2	34.34	100	0.4	13.5	1750.02	75.8
33	0.67	5.25	1591.7	31.4	67	0.4	4.5	1523.3	27					
34	0.71	5.25	1586.8	32.8	68	0.4	2.7	1623.2	43.77					

جدول ۲. مشخصات آماری و حدود تغییرات پارامترهای ورودی و خروجی

پارامتر ورودی و خروجی	حداقل	حداکثر	میانگین	انحراف از معیار
W/C	0.4	0.75	0.515	0.114
SP (kg/m ³)	1.52	13.5	7.029	4.51
GS (kg/m ³)	1166	1839.9	1579.65	171.93
f _c (MPa)	7.1	85.77	40.27	19.587

به منظور کاستن اثرات شاخصه‌های ناخواسته در نتایج آزمایشگاهی، تمامی پارامترهای ورودی و هدف قبل از آموزش در شبکه عصبی مصنوعی نرمال‌سازی و مقیاس‌سازی می‌شوند. مرحله مقیاس‌سازی از آن جهت مهم است که تابع تبدیل لوگ-سیگموئید^۱ تنها مقادیر بین ۰ تا ۱ را شناسایی می‌کند و برای مقیاس‌سازی داده‌ها از کمترین و بیشترین مقدار ۰/۱ تا ۰/۹ استفاده می‌شود. تابع مقیاس‌سازی برای داده‌های ورودی و هدف مطابق رابطه ۲ است.

$$x_i = (0.9 - 0.1) \frac{x - x_{\min}}{x_{\max} - x_{\min}} + 0.1 \quad (2)$$

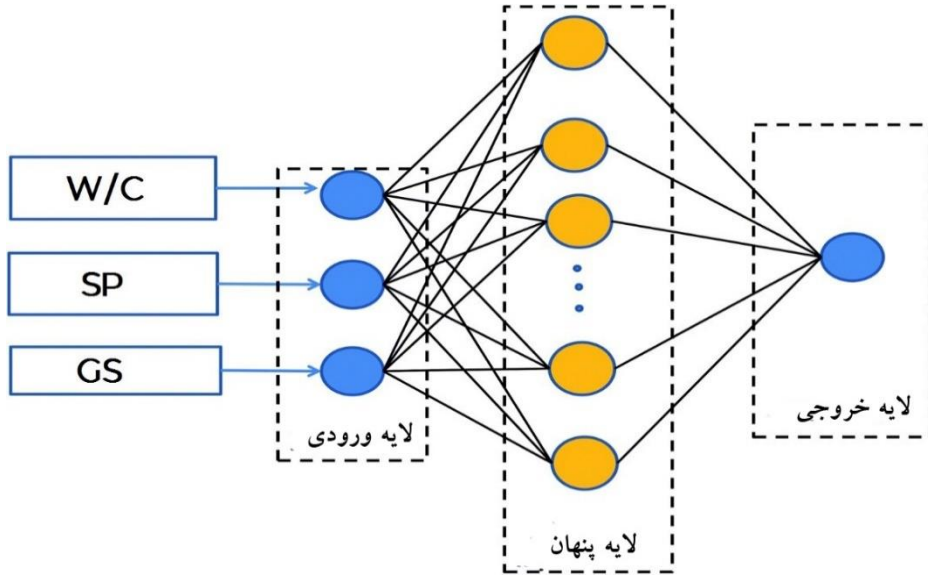
در رابطه ۲، x به‌عنوان داده ورودی و هدف است.

اجرای شبکه عصبی

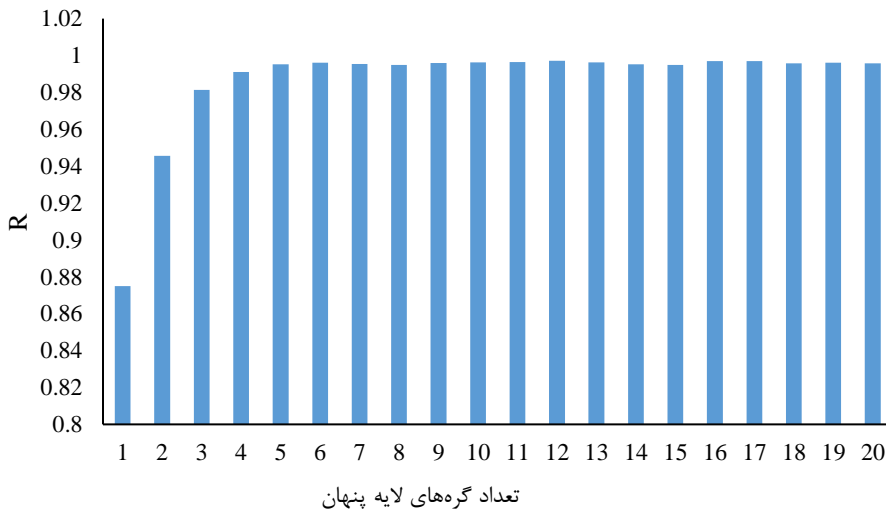
برای اجرای طرح اختلاط نمونه‌های آزمایشگاهی از شبکه انتشار برگشتی [۲۸] استفاده شده است. شبکه انتشار برگشتی به‌عنوان آسان‌ترین و مؤثرترین مدل در میان شبکه‌های چندلایه، داده‌های موردنیاز در شبکه را به دو گروه داده‌های آموزشی که حدود ۷۰ درصد از کل داده‌ها را جهت آموزش و وزن‌دهی و داده‌های آزمایشی که حدود ۳۰٪ از کل داده‌ها که در آموزش نقش نداشته و به‌عنوان راندمان شبکه آموزش دیده می‌باشند، تقسیم می‌نماید. این شبکه از یک‌لایه ورودی که تعداد ورودی‌های شبکه، بیانگر تعداد پارامترهای موجود در بخش ورودی شبکه است و از یک یا چندلایه پنهان که هر کدام دارای تعدادی نورون هستند که تعداد این نورون‌ها و نوع تابع رفتاری در رفتار شبکه موردنظر تأثیرگذار است، مطابق شکل ۲ تشکیل شده است. شکل ۲ نمونه شماتیک از لایه ورودی و پنهان شبکه عصبی مصنوعی را مشخص کرده است.

یک شبکه با تعداد گره بهینه در لایه پنهان، شبکه‌ای است که قادر باشد با حداقل مقدار خطای ممکن، همبستگی قابل‌قبولی بین مقادیر خروجی شبکه و مقادیر هدف برقرار نماید. در این پژوهش شبکه‌هایی با تعداد ۱ تا ۲۰ گره در لایه پنهان مورد آموزش قرار گرفتند. مقادیر ضرایب همبستگی و خطای این شبکه‌ها در شکل‌های ۳ و ۴ نشان داده شده است.


¹ Log-sigmoid



شکل ۲: نمونه شماتیک از ساختار شبکه عصبی مصنوعی



شکل ۳: ضرایب همبستگی به ازای تعداد گره‌های لایه پنهان



شکل ۴: میانگین مربعات خطاها به ازای تعداد گره‌های پنهان

با توجه به شکل‌های ۳ و ۴ اغلب شبکه‌ها دارای ضرایب همبستگی بالایی بوده و از این میان شبکه‌ای با ۱۲ گره در لایه پنهان علاوه بر دارا بودن بیشترین مقدار ضرایب همبستگی (R)، کمترین خطا را نیز دارد؛ بنابراین شبکه با ۱۲ گره در لایه پنهان به‌عنوان شبکه بهینه جهت پیش‌بینی مقاومت فشاری بتن انتخاب می‌شود.

معیار ارزیابی مدل

پس از ایجاد مدل‌ها با استفاده از روش‌های مورد بحث، باید کارایی آن‌ها ارزیابی شود. در این پژوهش برای ارزیابی میزان عملکرد مدل‌ها، از معیارهای ارزیابی جذر میانگین مربعات خطا (RMSE)، میانگین درصد مطلق خطا (MAPE) و ضریب همبستگی (R) استفاده شده است. در مجموع هرچه RMSE به صفر و R به یک نزدیک‌تر باشد، بدان معناست که مدل‌ها بهینه‌تر طراحی شده و عملکرد بهتری دارند. مقدار R همواره بین ۰ و ۱ است. مقادیر این پارامترها به ترتیب از روابط ۳ الی ۵ محاسبه می‌شوند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right| \quad (4)$$

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (5)$$

در روابط ۳ الی ۵، n تعداد داده‌های ورودی، x_i و y_i به ترتیب داده پیش‌بینی شده و داده هدف و \bar{x} میانگین داده‌های پیش‌بینی شده است.

علاوه بر این، شاخص مهندسی جدید با عنوان a20-Inex، برای ارزیابی قابلیت اطمینان مدل‌های شبکه عصبی مصنوعی توسعه یافته مطابق رابطه ۶ پیشنهاد شده است:

$$a20 - index = \frac{m20}{M} \quad (6)$$

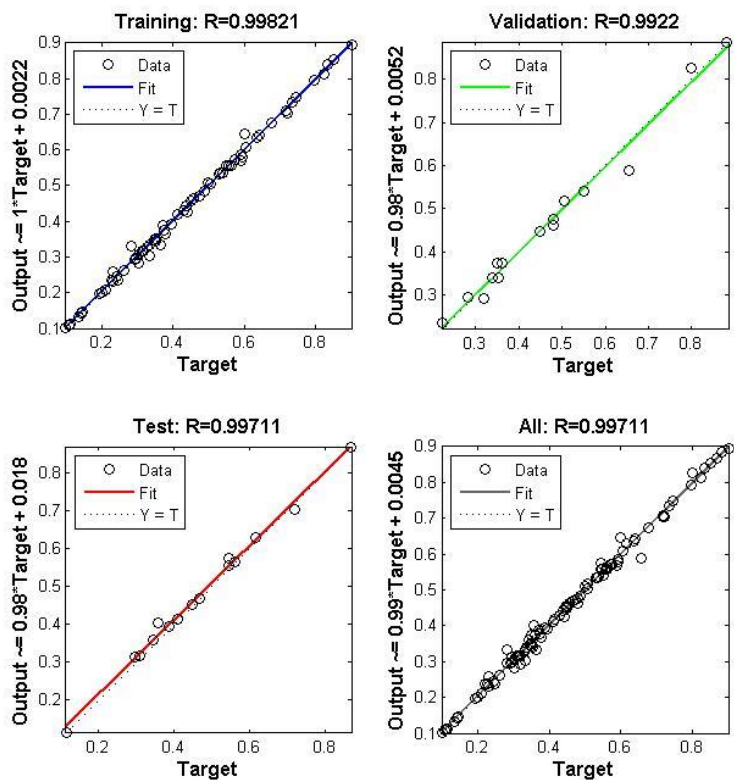
در رابطه ۶، M تعداد کل داده‌های ورودی و m20 تعداد داده‌هایی که نسبت داده خروجی آزمایشگاهی به داده خروجی پیش‌بینی شده بین ۰/۸ تا ۱/۲ باشد. برای داشتن یک مدل مناسب تخمینی بهتر است شاخص a20-index برابر با یک باشد. شاخص a20 از این جهت مورد توجه می‌باشد که نشان می‌دهد چه تعداد داده پیش‌بینی شده با انحراف ۲۰ درصد در مقایسه با مقادیر آزمایشگاهی می‌باشد.

صحت‌سنجی روش شبکه عصبی با نتایج آزمایشگاهی


پس از انتخاب هندسه شبکه عصبی مصنوعی، داده‌های مورد استفاده در قسمت صحت‌سنجی نباید در بخش آموزش شبکه مورد استفاده قرار گیرد. علت این کار از آن جهت است که سنجش صحت شبکه عصبی در ارائه تخمین دقیق از مقاومت فشاری ۲۸ روزه داده‌هایی است که در قسمت آموزش به کار گرفته نشده‌اند.

شکل ۵ نمودارهای عملکرد شبکه عصبی طراحی شده، شامل نمودار رگرسیون (R) داده‌های آموزش، صحت‌سنجی و آزمون و تمامی داده‌ها ارائه شده است. همچنین در شکل ۶ نمودار میانگین مربعات خطا در فرایند آموزش شبکه جهت تخمین مقاومت فشاری بتن نشان داده شده است. با توجه به شکل ۵، ضریب رگرسیون برای گروه آموزشی برابر ۰/۹۹۸، برای گروه ارزیابی برابر ۰/۹۹۲ و برای گروه آزمایشی برابر ۰/۹۹۷ به دست آمده است. مقادیر حاصله در نمودار شکل ۵، نزدیک به ۱ می‌باشد و حاکی از یادگیری و عملکرد بسیار خوب شبکه عصبی بوده و ضریب خطی همبستگی بین داده‌های مدل‌سازی و مقادیر پیش‌بینی شده بالا است.

از سوی دیگر، نمودار میزان دقت نتایج ناشی از مدل‌سازی شبکه عصبی در مقایسه با نتایج واقعی آزمایشگاهی مطابق شکل ۵ نشان می‌دهد که هر چه تمرکز این نقاط بر روی نیمساز ربع اول بیشتر باشد، نشانگر دقت بالاتر آن می‌باشد.




شکل ۵: نمودار رگرسیون (R) داده‌های آموزش، صحت سنجی و آزمون و تمامی داده‌ها



شکل ۶: عملکرد شبکه عصبی مصنوعی انتخاب شده

شکل ۶ عملکرد شبکه عصبی مصنوعی را نشان می‌دهد. مطابق شکل ۶ مقدار رگرسیون شبکه انتخابی در مراحل مختلف مدل‌سازی پس از ۶۵ اپوک مورد بررسی قرار گرفته است و افت حداقل مربعات خطا را نشان می‌دهد. همچنین میانگین مربع خطاها (MSE) در اپوک‌های مختلف یادگیری که با توجه به معیار همگرایی در نظر گرفته شده، نشان می‌دهد که یادگیری در اپوک ۶۵ به خوبی انجام شده است. همچنین شکل ۷ به ترتیب نمودار مقایسه مقادیر مقاومت فشاری بتن حاصله از نمونه‌های آزمایشگاهی با مقادیر پیش‌بینی شده از شبکه عصبی است. همان‌طور که در شکل ۷ مشاهده می‌شود انطباق خوبی بین مقادیر پیش‌بینی شده با مقادیر آزمایشگاهی وجود دارد. همچنین حداکثر خطای به دست آمده از مقایسه داده‌های حاصل از شبکه عصبی مصنوعی با داده‌های آزمایشگاهی در حدود ۲۰ درصد و حداقل صفر درصد می‌باشد و تقریباً به ۹۹ درصد از داده‌های پیش‌بینی شده توسط شبکه عصبی مصنوعی خطایی کمتر از ۱۵ درصد را دارا است.



شکل ۷: نمودار مقایسه نتایج آزمایشگاهی با نتایج حاصله از شبکه عصبی مصنوعی

همچنین مقایسه نتایج رگرسیون (R) شبکه عصبی به دست آمده در این پژوهش با پژوهش عبدالله زاده و همکاران [۲۹]، گسولگو و همکاران [۱۲] و بچیر و همکاران [۳۰] مطابق جدول ۳ نشان داده شده است. همان طور که در جدول ۳ مشاهده می شود نتایج به دست آمده از شبکه عصبی به دست آمده در این پژوهش، به نسبت روش های رگرسیون خطی و چندگانه و الگوریتم ژنتیک، از برتری بالایی برخوردار است.

جدول ۳: مقایسه نتایج محاسبات نرم به دست آمده در این پژوهش با پژوهش محققان

رگرسیون (R)			
داده آزمایشی	داده آموزشی	سیستم پیش بینی	نتایج این پژوهش
۰/۹۹۷۱	۰/۹۹۸۲	شبکه عصبی مصنوعی (ANN)	نتایج این پژوهش
۰/۹۸۲۳	۰/۹۸۸۵	شبکه عصبی مصنوعی (ANN)	عبدالله زاده و همکاران [۲۹]
۰/۷۴	۰/۷۴	روش رگرسیون چندگانه	گسولگو و همکاران [۱۲]
۰/۹۹۲	۰/۹۹۰	روش رگرسیون خطی	بچیر و همکاران [۳۰]
۰/۹۷۷۰	۰/۹۹۷۲	الگوریتم ژنتیک	بچیر و همکاران [۳۰]
۰/۹۷۷۰	۰/۹۹۷۲	شبکه عصبی مصنوعی (ANN)	بچیر و همکاران [۳۰]
۰/۹۵۹۶	۰/۹۸۵۴	الگوریتم جنگل تصادفی	گیوچین لی ^۱ [۱۷]
۰/۹۸۹	۰/۹۵۶	شبکه عصبی مصنوعی (ANN)	ال خوجا و همکاران [۱۴]
۰/۹۷۷۹	۰/۹۵۸۲	شبکه عصبی مصنوعی (ANN)	نایارکو و همکاران [۱۵]

¹ Guichen Li

رگرسیون (R)			
داده آزمایشی	داده آموزشی	سیستم پیش‌بینی	جلال و همکاران [۱۸]
۰/۹۶۸۸	۰/۹۸۶۰	شبکه عصبی مصنوعی (ANN)	
۰/۹۸۲۲	۰/۹۸۲۲	رابطه‌ی پیشنهادی	

آنالیز حساسیت پارامترهای ورودی

تا پایان سال ۱۹۸۰ روش‌های مختلفی برای تفسیر شبکه‌های عصبی مصنوعی که دارای نورون‌های ورودی (N)، نورون‌های پنهان (L) و نورون‌های خروجی (M) می‌باشد، برای تحلیل تأثیر متغیرهای ورودی بر خروجی این شبکه ارائه شده‌اند. آنالیز بر اساس مقادیر وزن، منحصرأ بر مبنای مقادیر ذخیره‌شده در ماتریس استاتیک وزن‌ها برای تعیین تأثیر نسبی هر یک از داده‌های ورودی بر داده‌های خروجی شبکه می‌باشد. معادلات مختلفی مبتنی بر مقادیر وزن‌ها ارائه شده است که تمامی آن‌ها با محاسبه حاصل ضرب وزن‌ها W_{ij} (وزن اتصال بین نورون ورودی i و نورون مخفی j) و U_{jk} (وزن اتصال بین نورون مخفی j و نورون خروجی k) برای هر یک از نورون‌های مخفی شبکه به صورت مجموع حاصل ضرب‌های محاسبه‌شده به دست می‌آید. یکی از کاربردی‌ترین معادلات، معادله میلن^۱ [۳۱] می‌باشد. معادله میلن روش اصلاح‌شده روش گارسون^۲ بوده که با استفاده از قدر مطلق وزن‌ها، نسبت صحیحی را به دست آورد. رابطه γ معادله میلن را نشان می‌دهد.


$$IIF = \frac{\sum_{j=1}^{n_{hidden}} \frac{W_{ji}}{\sum_{l=1}^{n_{inputs}} |W_{jl}|} W_{oj}}{\sum_{k=1}^{n_{inputs}} \left(\sum_{j=1}^{n_{hidden}} \frac{W_{jk}}{\sum_{l=1}^{n_{inputs}} |W_{jl}|} W_{oj} \right)} \quad (7)$$

مطابق با رابطه ۷، درصد اهمیت پارامترهای ورودی^۳ به شبکه عصبی در شکل ۸ محاسبه و ارائه شده است. نتایج آنالیز حساسیت در شکل ۸ حاکی از تأثیر بالای مقدار وزنی مواد افزودنی فوق‌روان‌کننده و تأثیر کم مقدار نسبت آب به سیمان بر روی تابع هدف شبکه عصبی دارد. لذا برای داشتن یک طرح اختلاط کارا باید بر روی مواد افزودنی فوق‌روان‌کننده حساسیت بیشتری به خرج داد.

¹ Milne

² Garson

³ Importance of Input Factors (IIF)



شکل ۸: درصد اهمیت پارامترهای ورودی به شبکه عصبی

نتیجه گیری

در این پژوهش، برای پیش‌بینی مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی، از شبکه‌های عصبی مصنوعی استفاده گردید. لذا به‌منظور آموزش شبکه عصبی، ۱۰۰ داده آزمایشگاهی در این زمینه جمع‌آوری شد. نسبت آب به سیمان، وزن ماده افزودنی فوق‌روان‌کننده و وزن ترکیب دانه‌بندی به‌عنوان پارامترهای تأثیرگذار و ورودی انتخاب شدند. همچنین مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی (f_c) به‌عنوان تابع هدف در نظر گرفته شد و شبکه بهینه با ۱۲ لایه پنهان و ضریب همبستگی ۰/۹۹۷۱ طراحی گردید. نتایج زیر به‌عنوان یافته‌های پژوهش ارائه می‌شود:

- ۱- شاخص مهندسی a-20 برای شبکه عصبی برابر یک به دست آمد که نشان از تقریب مناسب مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی توسط شبکه عصبی مصنوعی است.
- ۲- ضریب همبستگی تقریباً برابری در خروجی‌های آزمایش مقاومت فشاری بتن حاصل از شبکه عصبی مصنوعی موجود است، بنابراین این روش می‌تواند قابلیت پیش‌بینی مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی (f_c) را در حد مطلوب و مناسب داشته باشد.
- ۳- همچنین مقدار خطای شبکه بهینه‌شده در این مقاله با این تعداد نمونه بتن آزمایش‌شده حداکثر ۱۵ درصد است. با توجه به اطلاعات آماری موجود حاصل از نتایج تحقیق، ۸۴ مورد خطای کمتر از ۵ درصد، ۱۱ مورد خطای بین ۵ تا ۱۰ درصد و ۴ مورد خطای بین ۱۰ تا ۱۵ درصد داشتند که در مجموع ۹۹ درصد از نتایج پیش‌بینی‌شده توسط شبکه عصبی مصنوعی خطایی کمتر از ۱۵ درصد با نمونه‌های آزمایشگاهی داشته‌اند؛ بنابراین می‌توان بیان کرد، استفاده از شبکه بهینه معرفی‌شده در این پژوهش، راهگشای مناسبی برای پیش‌بینی مقاومت فشاری بتن حاوی ذرات لاستیکی ضایعاتی به شمار می‌رود.
- ۴- مقایسه ضریب رگرسیون (R) شبکه عصبی حاصله از این پژوهش با پژوهش‌های محققان حاکی از برتری دقت و عملکرد سیستم پیش‌بینی این مقاله در مقایسه با سایر روش‌های به‌دست‌آمده در پژوهش‌های محققان است.

به‌منظور مشخص کردن میزان تأثیر هر یک از پارامترهای ورودی بر مقاومت فشاری، آنالیز حساسیت با استفاده از روش میلن با وزن‌های تنظیم‌شده و حاصل از شبکه عصبی بهینه انجام شد که نتایج حاصل، حاکی از تأثیر بالای مقدار

وزنی مواد افزودنی فوق‌روان‌کننده و تأثیر کم مقدار نسبت آب به سیمان بر روی تابع هدف شبکه عصبی دارد. لذا برای داشتن یک طرح اختلاط کارا باید بر روی مواد افزودنی فوق‌روان‌کننده حساسیت بیشتری را اعمال کرد.

Reference

1. Sukontasukkul, P., & Chaikaew, C. (2006). Properties of concrete pedestrian block mixed with crumb rubber. *Construction and Building Materials*, 20(7), 450-457.
2. Belabdelouahab, F., Trouzine, H., Hellal, H., Rahali, B., Kaci, S. O., & Medine, M. (2018). Comparative analysis of estimated young's modulus of rubberized mortar and concrete. *International Journal of Civil Engineering*, 16(2), 243-253.
3. Elchalakani, M. (2015, February). High strength rubberized concrete containing silica fume for the construction of sustainable road side barriers. In *Structures* (Vol. 1, pp. 20-38). Elsevier.
4. Medine, M., Trouzine, H., & Aguiar, J. L. (2016). Fresh state properties of concrete incorporating scrap tire rubber.
5. Medine, M., Trouzine, H., De Aguiar, J. B., & Asroun, A. (2018). Durability properties of five years aged lightweight concretes containing rubber aggregates. *Periodica Polytechnica Civil Engineering*, 62(2), 386-397.
6. Youssf, O., ElGawady, M. A., Mills, J. E., & Ma, X. (2014). An experimental investigation of crumb rubber concrete confined by fibre reinforced polymer tubes. *Construction and Building Materials*, 53, 522-532.
7. Trtnik, G., Kavčič, F., & Turk, G. (2009). Prediction of concrete strength using ultrasonic pulse velocity and artificial neural networks. *Ultrasonics*, 49(1), 53-60.
8. Benardos, P. G., & Vosniakos, G. C. (2007). Optimizing feedforward artificial neural network architecture. *Engineering applications of artificial intelligence*, 20(3), 365-382.
9. Shah, A. A., Ribakov, Y., & Zhang, C. (2013). Efficiency and sensitivity of linear and non-linear ultrasonics to identifying micro and macro-scale defects in concrete. *Materials & Design*, 50, 905-916.
10. Wei, S., Yunsheng, Z., & Jones, M. R. (2014). Using the ultrasonic wave transmission method to study the setting behavior of foamed concrete. *Construction and Building Materials*, 51, 62-74.
11. Topçu, İ. B., & Sarıdemir, M. (2008). Prediction of rubberized mortar properties using artificial neural network and fuzzy logic. *Journal of Materials Processing Technology*, 199(1-3), 108-118.
12. Gesoğlu, M., Güneyisi, E., Özturan, T., & Özbay, E. (2010). Modeling the mechanical properties of rubberized concretes by neural network and genetic programming. *Materials and structures*, 43(1), 31-45.
13. Gupta, T., Patel, K. A., Siddique, S., Sharma, R. K., & Chaudhary, S. (2019). Prediction of mechanical properties of rubberised concrete exposed to elevated temperature using ANN. *Measurement*, 147, 106870.
14. El-Khoja, A. M. N., Ashour, A. F., Abdalhmud, J., Dai, X., & Khan, A. (2018). Prediction of Rubberised Concrete Strength by Using Artificial Neural Networks. *training*, 30, 35.
15. Hadzima-Nyarko, M., Nyarko, E. K., Ademović, N., Miličević, I., & Kalman Šipoš, T. (2019). Modelling the influence of waste rubber on compressive strength of concrete by artificial neural networks. *Materials*, 12(4), 561.
16. Saeb, A., Sohrabi, M., Ghasemi, M., and Ahani, G. (2012). Prediction of compressive strength of concrete containing crumb rubber using fuzzy neural model and artificial neural networks. In *6th National Congress of Civil Engineering*, S. University, Ed., ed. Semnan.

17. Sun, Y., Li, G., Zhang, J., & Qian, D. (2019). Prediction of the strength of rubberized concrete by an evolved random forest model. *Advances in Civil Engineering*, 2019.
18. Jalal, M., Grasley, Z., Gurganus, C., & Bullard, J. W. (2020). A new nonlinear formulation-based prediction approach using artificial neural network (ANN) model for rubberized cement composite. *Engineering with Computers*, 1-18.
19. Uygunoğlu, T., & Topcu, I. B. (2010). The role of scrap rubber particles on the drying shrinkage and mechanical properties of self-consolidating mortars. *Construction and Building Materials*, 24(7), 1141-1150.
20. Turatsinze, A., & Garros, M. (2008). On the modulus of elasticity and strain capacity of self-compacting concrete incorporating rubber aggregates. *Resources, conservation and recycling*, 52(10), 1209-1215.
21. Thomas, B. S., & Gupta, R. C. (2015). Long term behaviour of cement concrete containing discarded tire rubber. *Journal of Cleaner Production*, 102, 78-87.
22. Naderpour, H., Kheyroddin, A., & Amiri, G. G. (2010). Prediction of FRP-confined compressive strength of concrete using artificial neural networks. *Composite Structures*, 92(12), 2817-2829.
23. Jariwala, V. H., Patel, P. V., & Purohit, S. P. (2013). Strengthening of RC beams subjected to combined torsion and bending with GFRP composites. *Procedia Engineering*, 51, 282-289.
24. Cuong Ho, A. (2010). *Optimisation de la composition et caractérisation d'un béton incorporant des granulats issus du broyage de pneus usagés.: application aux éléments de grande surface* (Doctoral dissertation, Toulouse, INSA).
25. Ganjian, E., Khorami, M., & Maghsoudi, A. A. (2009). Scrap-tyre-rubber replacement for aggregate and filler in concrete. *Construction and building materials*, 23(5), 1828-1836.
26. Gesoglu, M., Güneyisi, E., Hansu, O., İpek, S., & Asaad, D. S. (2015). Influence of waste rubber utilization on the fracture and steel-concrete bond strength properties of concrete. *Construction and Building Materials*, 101, 1113-1121.
27. Nguyen, T. H., Toumi, A., & Turatsinze, A. (2010). Mechanical properties of steel fibre reinforced and rubberised cement-based mortars. *Materials & Design*, 31(1), 641-647.
28. Bosscher, P. J., Edil, T. B., & Kuraoka, S. (1997). Design of highway embankments using tire chips. *Journal of geotechnical and geoenvironmental engineering*, 123(4), 295-304.
29. Abdollahzadeh, A., Masoudnia, R., & Aghababaei, S. (2011). Predict strength of rubberized concrete using artificial neural network. *WSEAS Transactions on Computers*, 10(2), 31-40.
30. Bachir, R., Mohammed, A. M. S., & Habib, T. (2018). Using artificial neural networks approach to estimate compressive strength for rubberized concrete. *Periodica Polytechnica Civil Engineering*, 62(4), 858-865.
31. Milne, L. (1995). Feature selection using neural networks with contribution measures. In *AI-CONFERENCE-* (pp. 571-571). World Scientific Publishing.