

# An Intelligent Data-Driven Framework for Optimizing HPFRCC Mix Designs Using a Hybrid ANN-EO-Taguchi Approach

Peyman FarhadiYeganeh<sup>1</sup>, Maryam Firoozi Nezamabadi<sup>2</sup>, Ata Hojatkashani<sup>2\*</sup>, Abbas Akbarpour NikghalbRashti<sup>2</sup>, Hassan Abbasi<sup>2</sup>

1- Ph.D. candidate, Department of civil engineering, Islamic Azad University south Tehran branch, Tehran, Iran

2- Assistant Professor, Department of civil engineering, Islamic Azad University south Tehran branch, Tehran, Iran  
ata\_hojat@aut.ac.ir

Received: 24 June 2025 Revised: 16 August 2025 Accepted: 25 October 2025

Research paper

## Abstract

performance fiber-reinforced cementitious composites (HPFRCC). Using the Taguchi method, an initial set of 16 physical mix designs was prepared, and their results were collected. Subsequently, synthetic data were generated through simulation, increasing the total number of mix designs to 44, and the additional designs were also fabricated and tested. The results from all 44 mixes were employed to train and optimize an artificial neural network (ANN) model. The model inputs included cement, pozzolans, fibers, water-to-cement ratio, sand, and superplasticizer contents. After optimizing the ANN architecture using the Equilibrium Optimizer (EO) algorithm, the model demonstrated high accuracy in predicting both the workability index and energy absorption capacity, with a mean squared error (MSE) of 0.0049 and a coefficient of determination ( $R^2$ ) exceeding 0.98. Experimental validation of the optimal mix design confirmed the model's accuracy with an error of less than 0.3%. The results indicated that the workability index of the proposed framework was, on average, approximately 40% higher than that of the reference sample obtained by the independent Taguchi method. Overall, the proposed data-driven framework provides an efficient tool for the precise and cost-effective design of advanced concretes.

**Keywords:** High-Performance Fiber-Reinforced Cementitious Composites (HPFRCC), Taguchi Method, Artificial Neural Network (ANN), Flexural Toughness, Equilibrium Optimization Algorithm (EO)

---

\*Corresponding Author: Ata Hojatkashani

Farhadi Yeganeh P., Firoozi Nezamabadi M., Hojatkashani A., Akbarpour NikghalbRashti A., Abbasi H. An Intelligent Data-Driven Framework for Optimizing HPFRCC Mix Designs Using a Hybrid ANN-EO-Taguchi Approach. J. Concr. Struct. Mater., 2024; 9(2): 135-152. <http://doi.org/10.30478/jcsm.2025.529988.1392>

2538-5828/ © 2025 The Authors. Published by Iranian Concrete Society

This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

## چارچوب هوشمند برای بهینه‌سازی طرح اختلاط بتن‌های HPFRCC با استفاده از ترکیب ANN، الگوریتم Eo و روش تاگوچی

پیمان فرهادی یگانه<sup>۱</sup>، مریم فیروزی نظام‌آبادی<sup>۲</sup>، عطا حجت کاشانی<sup>۳\*</sup>، عباس اکبرپور نیک قلب رشتی<sup>۴</sup>، حسن عباسی<sup>۵</sup>

۱- دانشجوی دکتری، گروه مهندسی عمران، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

۲- استادیار گروه مهندسی عمران، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

پست الکترونیک نویسنده مسئول: a\_hojatkashani@iaui.ac.ir

تاریخ دریافت: ۱۴۰۴/۰۴/۰۳، تاریخ بازنگری: ۱۴۰۴/۰۵/۲۵، تاریخ پذیرش: ۱۴۰۴/۰۸/۰۳

نوع مقاله: پژوهشی

### چکیده:

در این پژوهش، یک چارچوب ترکیبی داده‌محور برای بهینه‌سازی طرح اختلاط کامپوزیت سیمانی توانمند با الیاف و عملکرد بالا (HPFRCC) ارائه شده است. با استفاده از روش تاگوچی، ابتدا ۱۶ طرح اختلاط فیزیکی ساخته و نتایج آن‌ها جمع‌آوری شد. سپس با شبیه‌سازی داده‌های مصنوعی، تعداد طرح‌ها به ۴۴ افزایش یافت و این طرح‌های اضافه نیز ساخته و آزمایش شدند. نتایج حاصل از تمامی ۴۴ طرح برای آموزش و بهینه‌سازی مدل شبکه عصبی مصنوعی (ANN) به کار گرفته شد. ورودی‌های مدل شامل مقادیر سیمان، پوزولان‌ها، الیاف، نسبت آب به سیمان، ماسه و فوق‌روان‌کننده بودند. مدل ANN، پس از بهینه‌سازی معماری با الگوریتم تعادل (EO)، با MSE برابر ۰/۰۰۴۹ و  $R^2$  بیش از ۰/۹۸، در پیش‌بینی شاخص شکل‌پذیری و ظرفیت جذب انرژی دقت بالایی نشان داد. اعتبارسنجی تجربی طرح اختلاط بهینه نیز با خطای کمتر از ۰/۳٪، صحت مدل را تأیید کرد. بررسی نتایج نشان می‌دهد که شاخص شکل‌پذیری حاصل از چارچوب پیشنهادی، به طور میانگین حدود ۴۰ درصد بالاتر از (نمونه مرجع) مقادیر حاصل از روش مستقل تاگوچی بوده است. چارچوب پیشنهادی این مطالعه، با بهره‌گیری از رویکردی مبتنی بر داده، ابزاری کارآمد برای طراحی دقیق و مقرون‌به‌صرفه بتن‌های پیشرفته فراهم می‌آورد.

**کلمات کلیدی:** کامپوزیت سیمانی توانمند با الیاف و عملکرد بالا، روش تاگوچی، شبکه عصبی مصنوعی، شکل‌پذیری، الگوریتم

تعادلی EO

کامپوزیت سیمانی توانمند با الیاف و عملکرد بالا (HPFRCC) از جمله مصالحی هستند که به دلیل ویژگی‌هایی همچون سخت‌شوندگی کرنشی، مقاومت خمشی بالا و قابلیت بالای جذب انرژی، نقش مؤثری در بهبود ایمنی سازه‌ها در برابر بارهای دینامیکی و لرزه‌ای ایفا می‌کنند (۱ و ۲). در حالی که بتن‌های معمولی پس از بروز ترک اولیه به سرعت دچار افت مقاومت و گسیختگی می‌شوند، این بتن‌ها قادرند تغییر شکل‌های بزرگ را بدون کاهش محسوس در ظرفیت باربری تحمل کنند. این رفتار، ناشی از پدیده‌ی سخت‌شوندگی کرنشی و رشد کنترل‌شده ترک‌ها در مقیاس میکرو است. با وجود این مزایا، طراحی و بهینه‌سازی طرح اختلاط HP-FRCC فرایندی پیچیده و چالش‌برانگیز محسوب شده و خواص مکانیکی نهایی، به شدت تحت تأثیر تعاملات غیرخطی و چندگانه میان پارامترهای متعددی نظیر نوع و مقدار الیاف، نسبت آب به مواد سیمانی ( $w/b$ )، میزان و نوع مواد پوزولانی (مانند متاکائولین، سرباره یا خاکستر بادی) و افزودنی‌های شیمیایی نظیر فوق‌روان‌کننده‌ها قرار دارد. این وابستگی متقابل و اثرات ترکیبی، استفاده از رویکردهای سنتی طراحی را ناکارآمد ساخته و نیاز به روش‌های پیشرفته مدل‌سازی و بهینه‌سازی را برجسته می‌کند (۳).

در سال‌های اخیر، استفاده از روش‌های یادگیری ماشین برای پیش‌بینی خواص مکانیکی بتن‌های توانمند و تقویت‌شده با الیاف گسترش چشمگیری یافته است. دای و همکاران (۴) از الگوریتم‌های MLP، برای تخمین مقاومت فشاری بتن با الیاف فولادی مبتنی بر داده‌های منابع ثانویه استفاده کردند. به‌طور مشابه، حسن‌زاده و همکاران (۵) با بهره‌گیری از مدل‌های رگرسیونی، مقاومت فشاری، خمشی و کششی بتن حاوی الیاف بازالت را پیش‌بینی نمودند. جیاو و همکاران (۶) نیز رویکردی ترکیبی از آزمون‌های آزمایشگاهی، مدل‌سازی اجزای محدود و الگوریتم‌های یادگیری ماشین را جهت ارزیابی بتن‌های الیافی در کاربردهای ترمیمی به کار گرفتند.

افزون بر این، در مطالعات متعددی، مدل‌های ترکیبی هوشمند در طراحی سازه‌ای و مصالح نوین مورد استفاده قرار گرفته‌اند. به‌عنوان نمونه کنتونی و احمدی (۷) از ترکیب ANFIS-PSO برای تحلیل رفتار بتن محصورشده با FRP بهره بردند. شریعتی و همکاران (۸) نیز با مدل ELM-GWO مقاومت بتن اصلاح‌شده را پیش‌بینی نمودند. همچنین، احمدی، عبادی جمخانه و همکاران (۹) از مدل ترکیبی GEP-IWO برای تحلیل ظرفیت محوری ستون‌های پر شده استفاده کردند. در نهایت، شریعتی و همکاران (۱۰) نیز شبکه عصبی مصنوعی را با الگوریتم ژنتیک (ANN-GA) جهت تخمین مقاومت بتن حاوی مواد مکمل سیمانی به کار بردند. این مطالعات اثربخشی الگوریتم‌های هوشمند را در تحلیل رفتار مکانیکی مصالح ساختمانی نشان می‌دهند، هرچند که در اغلب آن‌ها از بهینه‌سازی هم‌زمان ساختار شبکه و طراحی آزمایش استفاده نشده است. مطالعات پیشین، نقش مؤثر الگوریتم‌های هوشمند را در پیش‌بینی خواص مکانیکی مصالح سیمانی تأیید کرده‌اند، اما اغلب این تحقیقات از رویکردی غیریکپارچه بهره گرفته‌اند. اغلب این مطالعات به‌صورت مستقل و بدون یکپارچگی روشی میان مراحل طراحی آزمایش، مدل‌سازی و بهینه‌سازی انجام شده‌اند. در پاسخ به این خلأ، پژوهش‌های اخیر به‌سوی تلفیق روش‌های طراحی آزمایش کلاسیک و هوش مصنوعی گام برداشته‌اند. از جمله، روش تاگوچی به‌واسطه‌ی بهره‌گیری از آرایه‌های متعامد، امکان کاهش تعداد آزمایش‌های تجربی را فراهم می‌سازد و درعین حال پوشش مناسبی از متغیرهای تأثیرگذار ارائه می‌دهد. شبکه عصبی مصنوعی (ANN) نیز با قابلیت مدل‌سازی روابط غیرخطی و پیچیده، ابزاری توانمند در تحلیل سیستم‌های چندمتغیره به شمار می‌آید. در کنار این‌ها، الگوریتم‌های فراابتکاری با مکانیزم‌های جست‌وجوی هوشمند خود، می‌توانند فرایند آموزش مدل را بهینه کرده و پایداری آن را در برابر نویزهای داده‌ای افزایش دهند. با این حال، هر یک از این روش‌ها در صورت استفاده‌ی مجزا، محدودیت‌هایی نظیر وابستگی به حجم بالای داده، تنظیمات حساس یا هزینه‌های محاسباتی بالا دارند. از این‌رو، در این پژوهش باهدف بهره‌گیری هم‌افزا از توانمندی‌های سه رویکرد یادشده، یک چارچوب ترکیبی ارائه شده است که با ادغام روش تاگوچی، مدل ANN و الگوریتم فراابتکاری تعادل (EO) (۱۱)، بهینه‌سازی دقیق و داده‌محور طرح اختلاط

HPFRCC را ممکن می‌سازد. این چارچوب ضمن کاهش قابل توجه هزینه‌های آزمایشگاهی، موجب ارتقای عملکرد مکانیکی طرح اختلاط شده و می‌تواند به‌عنوان مدلی هوشمند و مؤثر در توسعه مصالح سیمانی نوین مورد استفاده قرار گیرد. در راستای پوشش خلأهای موجود در ادبیات و پاسخ به چالش‌های طراحی بهینه HPFRCC، این پژوهش با اهداف مشخص زیر انجام شده است:


- توسعه مدلی داده‌محور مبتنی بر ANN برای پیش‌بینی دقیق شاخص شکل‌پذیری و ظرفیت جذب انرژی
- شناسایی طرح‌های اختلاط بهینه با استفاده از آزمایش تاگوجی، شبکه عصبی و الگوریتم EO
- بهینه‌سازی ساختار شبکه عصبی با بهره‌گیری از EO به‌منظور ارتقای دقت، پایداری و توان تعمیم مدل
- ارزیابی عملی و اعتبارسنجی مدل پیشنهادی از طریق اجرای طرح اختلاط بهینه در شرایط آزمایشگاه

## ۲- روش پژوهش

این پژوهش از یک چارچوب ترکیبی تجربی و محاسباتی برای توسعه و بهینه‌سازی طرح اختلاط HPFRCC بهره گرفته است. در این روش، داده‌های حاصل از آزمایش‌های فیزیکی با مدل‌سازی ANN و طراحی آماری تاگوجی ترکیب شده‌اند تا بهینه‌ترین طرح‌های اختلاط شناسایی شوند.

### ۲-۱ مواد اولیه و مشخصات آن‌ها

در این پژوهش، مواد اولیه با رعایت استانداردهای بین‌المللی و سازگاری با کامپوزیت‌های سیمانی انتخاب و پیش از مصرف ارزیابی شدند. اجزای به‌کاررفته در شکل ۱ نشان داده شده‌اند. مواد مورد استفاده شامل: سیمان پرتلند تیپ I، مطابق ASTM C150، ماسه طبیعی ریزدانه حداکثر ۱/۵ میلی‌متر، ASTM C33، پودر کربنات کلسیم ۱/۵ میکرومتر برای بهبود تراکم‌پذیری، متاکائولین ۱/۵ میکرومتر جهت اصلاح ریزساختار، سرباره، ۱/۵ میلی‌متر برای افزایش دوام، الیاف پلی‌پروپیلن ۱۲ میلی‌متر، قطر ۱۹ میکرومتر، مقاومت کششی ۴۰۰ مگاپاسکال برای ایجاد رفتار سخت‌شوندگی کرنشی، سرباره (SL)، آب آشامیدنی ASTM C1602 و فوق‌روان‌کننده پلی‌کربوکسیلاتی جهت بهبود کارایی و پراکنش الیاف (۱۲). با توجه به هدف اصلی این پژوهش که ارزیابی عملکرد مدل ترکیبی ANN و EO در بهینه‌سازی طرح اختلاط HPFRCC است، تمرکز بر این چهار پارامتر کلیدی صورت گرفت. سایر متغیرها با اقتباس از مطالعات معتبر و باهدف کاهش پیچیدگی تحلیلی، محدود کردن ابعاد مسئله، و کنترل متغیرهای مداخله‌گر، به‌صورت ثابت در نظر گرفته شدند. این رویکرد در مطالعات مشابهی نیز اتخاذ شده است؛ به‌عنوان نمونه، در پژوهش فنگ و همکاران صرفاً متغیرهای کلیدی در فرایند بهینه‌سازی لحاظ شده و سایر پارامترها تثبیت گردیدند تا تمرکز بر ارزیابی دقیق الگوریتم EO حفظ شود (۱۳).



شکل ۱- (الف) ماسه بادی (ب) پودر کربنات کلسیم (ج) سرباره (د) متاکائولین

## ۲-۲ آماده سازی نمونه‌ها

ابتدا سیمان، سرباره، متاکائولین، پودر کربنات کلسیم و ماسه به مدت ۶۰ ثانیه با سرعت ۷۰ دور در دقیقه مخلوط خشک شدند. سپس با افزودن دو سوم آب و فوق‌روان کننده، مخلوط‌تر اولیه به مدت ۱۲۰ ثانیه انجام شد. الیاف پلی‌پروپیلن طی ۱۰ دقیقه به تدریج افزوده شدند و باقیمانده آب و روان کننده در سه مرحله همراه با اختلاط ۰/۵ دقیقه‌ای (۳۰۰ دور در دقیقه) پس از هر افزودن استفاده شدند تا از توزیع یکنواخت و جلوگیری از کلوخه شدن اطمینان حاصل شود. نمونه‌ها در قالب‌های استاندارد ریخته‌گری، ویبره و پس از ۲۴ ساعت نگهداری در محیط، قالب‌ها جدا و به مدت ۲۸ روز در آب عمل‌آوری شدند (۱۴).

## ۲-۳ طراحی آزمایش به روش تاگوچی

برای کاهش تعداد آزمایش‌های فیزیکی و تحلیل تأثیر متغیرهای کلیدی طرح اختلاط بر شکل‌پذیری HPFRCC، از روش طراحی آزمایش تاگوچی استفاده شد. این روش بر مبنای آرایه‌های متعامد، امکان ارزیابی کارآمد ترکیبات متغیرها را با حداقل تعداد آزمون‌ها فراهم می‌کند (۱۵). در روش تاگوچی، نسبت سیگنال به نویز (S/N) با رویکرد Larger is Better به‌عنوان معیار عملکرد برای ارزیابی پایداری پاسخ‌ها و تعیین ترکیب بهینه پارامترها به کار رفت. همچنین، سهم نسبی عوامل تأثیرگذار با استفاده از تحلیل واریانس (ANOVA) بررسی شد. طراحی آزمایش‌ها در نرم‌افزار Minitab 18 انجام گرفت که با توجه به تعداد پارامترها و سطوح





ب

شکل ۲ - الف) دستگاه آزمون خمش سه نقطه‌ای (ب) نمونه‌ای از تیرهای ساخته شده و الگوی ترک در حین شکست خمشی

### ۲-۵ تابع هدف (شکل پذیری)

شکل‌پذیری به‌عنوان شاخصی حیاتی از توانایی ماده در تحمل تغییر شکل پلاستیک پیش از گسیختگی، از طریق شاخص شکل‌پذیری که مستقیماً از منحنی‌های نیرو - جابجایی آزمون‌های خمشی استخراج می‌گردد، کمی‌سازی شد (۱۹). این شاخص به‌صورت نسبت خیر نهایی متناظر با جابه‌جایی در لحظه‌ی گسیختگی - به خیز تسلیم معادل جابه‌جایی در آستانه‌ی رفتار غیرخطی پس از محدوده‌ی الاستیک خطی، مطابق رابطه‌ی زیر محاسبه می‌گردد:

$$\mu_{\Delta} = \frac{\Delta_U}{\Delta_y} \quad (1)$$

همچنین، ظرفیت جذب انرژی به‌عنوان معیاری کلیدی برای ارزیابی رفتار پس از ترک‌خوردگی و چقرمگی مصالح، از طریق محاسبه‌ی مساحت زیر بخش غیرخطی منحنی نیرو - جابجایی کمی‌سازی شد. این پارامتر که همبستگی مستقیمی با مقاومت ترک‌خوردگی و مکانیزم‌های اتلاف انرژی دارد، به‌طور خاص با انتگرال‌گیری از ناحیه‌ی پلاستیک منحنی (منطقه‌ی غیرالاستیک پس از نقطه‌ی تسلیم) محاسبه گردید (۲۰). در این مطالعه، شکل‌پذیری به‌عنوان مساحت زیر بخش پلاستیک منحنی بار - جابه‌جایی تعریف شده است که با واحد  $(N \cdot \mu m)$  بیان می‌شود. این واحد نشان‌دهنده کار مکانیکی (جذب انرژی) است و می‌تواند به‌طور مستقیم به ژول تبدیل شود (هر  $N \cdot \mu m$  معادل ژول). این رویکرد، معیار فیزیکی معنادار و ثابتی برای مقایسه ظرفیت تغییر شکل پس از تسلیم در میان مخلوط‌ها فراهم می‌کند. با توجه به عدم وضوح نقطه تسلیم در برخی نمونه‌ها، از این روش به‌عنوان جایگزینی برای شاخص‌های معمول شکل‌پذیری مانند  $\Delta u / \Delta y$  استفاده شد.

### ۲-۶ تولید داده‌های آموزشی

در مرحله نهایی طراحی آزمایش، مجموعاً ۴۴ طرح اختلاط بهینه بر اساس تحلیل آماری روش تاگوچی و با بهره‌گیری از شبیه‌سازی داده‌های مصنوعی تهیه شد و برای آموزش و ارزیابی مدل شبکه عصبی مصنوعی (ANN) مورد استفاده قرار گرفت. ابتدا ۱۶ طرح اختلاط فیزیکی با استفاده از روش تاگوچی ساخته و داده‌های عملکردی آن‌ها جمع‌آوری شد. این داده‌ها برای تولید ۲۸ طرح اختلاط



### ۳-۷-۲ آموزش الگوریتم

فرایند آموزش شبکه عصبی مصنوعی در این پژوهش با استفاده از الگوریتم Levenberg-Marquardt به‌عنوان یکی از روش‌های قدرتمند بهینه‌سازی مرتبه دوم صورت گرفت. این الگوریتم با ترکیب ویژگی‌های الگوریتم گرادیان نزولی و روش نیوتن، به دلیل سرعت بالای همگرایی، پایداری عددی مطلوب و عملکرد اثربخش در مدل‌سازی رگرسیون غیرخطی، گزینه‌ای مناسب برای آموزش شبکه در مسائل مهندسی محسوب می‌شود. در طی فرایند یادگیری، وزن‌ها و بایاس‌های شبکه به‌گونه‌ای به‌روزرسانی شدند که خطای میانگین مربعات (MSE) میان مقادیر پیش‌بینی‌شده توسط مدل و داده‌های واقعی آزمایشگاهی به حداقل ممکن برسد (۲۳).

### ۳-۷-۴ بهینه‌سازی شبکه عصبی

باتوجه به حساسیت عملکرد شبکه عصبی به معماری داخلی، ابر پارامترهای کلیدی تعداد لایه‌های پنهان: ۱-۲، نورون‌ها: ۵-۲۵، توابع فعال‌سازی با سه الگوریتم EO الگوریتم مبتنی بر آموزش راندگی (۲۴) (DTBO) و الگوریتم کپک مخاطی (SMA) طی ۵۰۰ تکرار و جمعیت اولیه ۱۰۰ بهینه‌سازی شدند. معیار ارزیابی، حداقل‌سازی MSE داده‌های اعتبارسنجی بود.

### ۳-۷-۵ بهینه‌سازی طرح اختلاط با EO

باتوجه به MSE به‌دست‌آمده، EO به‌عنوان یک روش کارآمد و مؤثر در بهینه‌سازی طرح اختلاط مورد استفاده قرار گرفته است. روابط ریاضی EO در معادلات ۲ تا ۶ ارائه شده‌اند. فرآیند مراحل بهینه‌سازی نیز به‌صورت فلوجارت در پیوست D نمایش داده شده است.

$$V \frac{dc}{dt} = Q + C_{eq} + G \quad (2)$$

$$\frac{dc}{\lambda C_{eq} - \lambda C + \frac{G}{V}} = dt \quad (3)$$

$$\int_{c_0}^c \frac{dc}{\lambda C_{eq} - \lambda C + \frac{G}{V}} = \int_{t_0}^t dt \quad (4)$$

$$C = C_{eq} + (C_0 - C_{eq})F + \frac{G}{\lambda V} (1 - F) \quad (5)$$

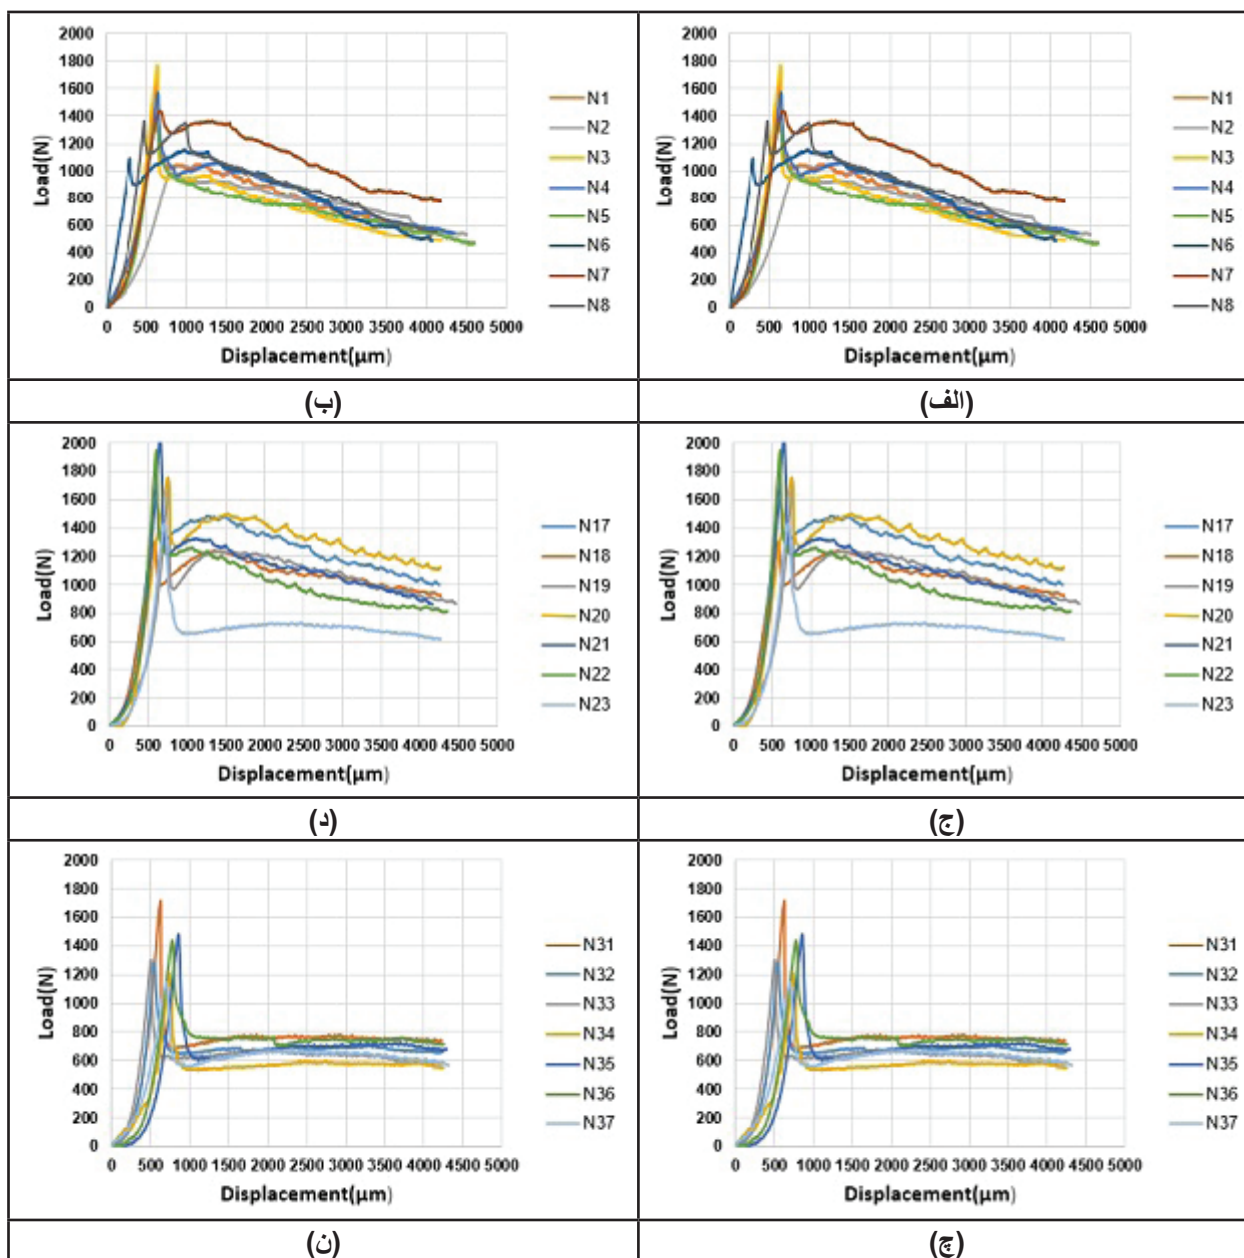
$$F = \exp(-\lambda(t - t_0)) \quad (6)$$

در این روابط، C مقدار جاری، C<sub>0</sub> مقدار اولیه، مقدار تعادلی، F عامل تأثیر، G بردار گرادیان، λ ضریب کنترل شدت، و V بردار سرعت ذرات هستند و t شماره تکرار جاری، و t. حداکثر تعداد تکرارها که همگی در چارچوب EO تعریف می‌شوند.

### ۳- یافته‌ها (نتایج)

این بخش به ارائه نتایج مربوط به روش تاگوچی در تحلیل تأثیر عوامل مختلف، نتایج تست‌های مکانیکی، نتایج بهینه‌سازی





شکل ۶- (الف - ن) منحنی‌های نیرو - جابجایی به دست آمده از آزمون‌های خمش سه نقطه‌ای

۳-۳ عملکرد مدل شبکه عصبی مصنوعی (ANN) در پیش‌بینی شکل‌پذیری

۳-۳-۱ نتایج مربوط به عملکرد الگوریتم‌ها

در جدول ۲، نتایج بهینه‌سازی معماری شبکه‌های عصبی توسط الگوریتم‌های مختلف، شامل تعداد لایه‌ها، نورون‌ها، نوع توابع فعال‌سازی و مقدار خطای میانگین مربعات (MSE)، قابل مشاهده است.

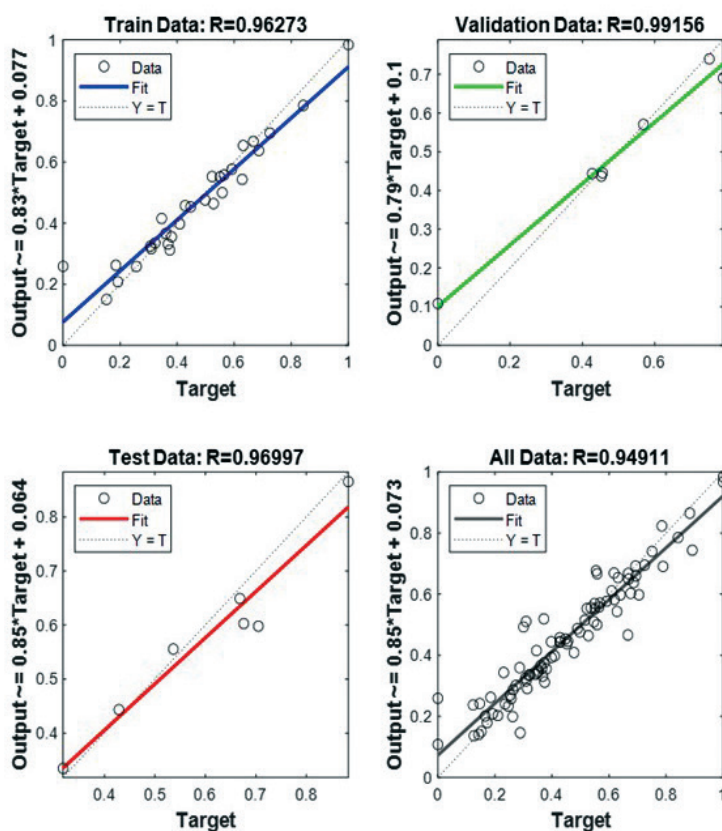
جدول ۲ - نتایج بهینه یابی معماری شبکه الگوریتم‌ها

الگوریتم	MSE	تعداد لایه‌ها	تعداد نورون‌ها (لایه ۱ / لایه ۲)	توابع فعال‌سازی
EO	۰/۰۰۴۹	۲	۲۲/۱۵	satlins / logsig / purelin
DTBO	۰/۰۰۷۰	۲	۷/۶	tansig / ellitsig / tansig
SMA	۰/۰۰۹۸	۱	۱۲/۰	logsig / - / purelin

در مقایسه‌ی عملکرد الگوریتم‌های بهینه‌سازی، EO به طور چشمگیری برتر عملکرد و با دستیابی به کمترین خطای اعتبارسنجی ۰/۰۰۴۹، دقیق‌ترین معماری شبکه عصبی مصنوعی را ارائه داد. DTBO با MSE معادل ۰/۰۰۷۰ عملکردی قابل قبول ثبت کرد، در حالی که SMA با دقت پایین‌تر و خطاهای بالاتر، نشان‌دهنده‌ی محدودیت‌های رویکرد جستجوی آن در مواجهه با پیچیدگی این مسئله بود.

### ۳-۳-۲ معیارهای عملکرد مدل ANN


عملکرد مدل شبکه عصبی مصنوعی با معیارهای آماری شامل MSE برابر با ۰/۰۰۴۹، ضریب تعیین ( $R^2$ ) بیش از ۰/۹۸ برای هر دو خروجی، و میانگین خطای مطلق (MAE) کمتر از ۰/۰۱ ارزیابی شد. این نتایج نشان‌دهنده دقت بالا و همگرایی مطلوب مدل در طول آموزش است که در شکل ۷ روند کاهش خطا، همراستایی قابل توجه بین مقادیر پیش‌بینی شده و واقعی را تأیید می‌کند.



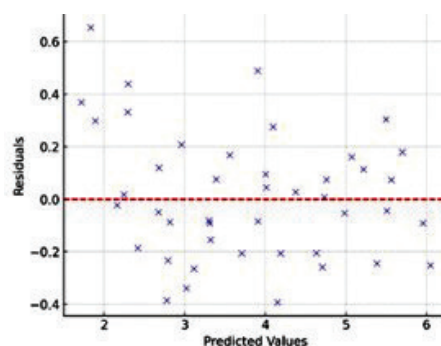
شکل ۷ - منحنی‌های خطای آموزش و اعتبارسنجی در طول تکرارها

### ۳-۳-۳ تحلیل آماری خطاهای مدل ANN

به منظور تکمیل ارزیابی عملکرد مدل ANN، تحلیل آماری باقیمانده‌ها و آزمون نرمال بودن خطاها نیز انجام شد. باقیمانده‌ها به عنوان تفاضل میان مقادیر واقعی و پیش‌بینی شده محاسبه گردید و نمودار پراکنش باقیمانده‌ها در برابر مقادیر پیش‌بینی شده ( $Re-$  siduals vs. Predicted) حاکی از توزیع تصادفی و بدون الگوی سیستماتیک بود. همچنین، نمودار (Quantile-Quantile) بر پایه فرض نرمال بودن خطاها ترسیم شد که تطابق قابل قبولی با خط نرمال استاندارد نشان داد. آزمون Shapiro-Wilk نیز برای مجموعه داده آزمون انجام شد که مقدار  $0.078/0$  به دست آمد؛ این مقدار بالاتر از سطح معنی داری  $0.05/0$  بوده و نشان دهنده‌ی پیروی تقریبی خطاها از توزیع نرمال است. (شکل ۸).



(ب)



(الف)

شکل ۸ - (الف) نمودار Q-Q جهت بررسی نرمال بودن توزیع خطاها، (ب) نمودار پراکنش باقیمانده‌ها نسبت به مقادیر پیش‌بینی شده

### ۳-۴ آنالیز نتایج بهینه‌سازی EO

جدول ۳ جزئیات مربوط به طرح اختلاط بهینه حاصل از الگوریتم EO را ارائه می‌کند که شامل مقادیر هر یک از اجزای تشکیل دهنده و مقدار شاخص شکل پذیری است.

جدول ۳ - طرح اختلاط بهینه

شکل پذیری ( $N-\mu m$ )	SL	MTK	LP	C	طرح اختلاط بهینه ( $kg/m^3$ )
۶۹۳۳۱۰	۰	۲۶/۱۹	۶۲/۳۵	۷۳۷	

### ۳-۵ مقایسه چارچوب پیشنهادی با روش‌های سنتی طراحی اختلاط

عملکرد چارچوب ترکیبی پیشنهادی ( $ANN + EO$ ) با دو روش رایج طراحی تجربی، شامل طراحی فاکتوریل کامل و روش تاگوچی، مقایسه شد. همان‌طور که در جدول ۴ مشاهده می‌شود، چارچوب پیشنهادی با استفاده از ۴۴ طرح اختلاط فیزیکی، دقت پیش‌بینی بسیار بالا و انعطاف‌پذیری بیشتری نسبت به روش‌های سنتی ارائه می‌دهد، در حالی که تعداد آزمایش‌ها به طور قابل توجهی کاهش یافته است.



مقایسه عملکرد الگوریتم‌های فراابتکاری در بهینه‌سازی معماری شبکه عصبی نشان داد که الگوریتم تعادل (EO) با دستیابی به کمترین مقدار خطای اعتبارسنجی برابر ۰/۰۰۴۹، از پایداری و کارایی بالاتری در جست‌وجوی فضای پارامترهای شبکه نسبت به الگوریتم‌های بهینه‌سازی مبتنی بر آموزش راندگی (DTBO) و الگوریتم کپک مخاطی (SMA) برخوردار است. این برتری می‌تواند به مکانیسم هوشمند به‌روزرسانی جمعیت در EO نسبت داده شود که از مفهوم تعادل شیمیایی برای کنترل تعادل بین اکتشاف و بهره‌برداری استفاده می‌کند. در مقابل، DTBO و SMA در مواجهه با پیچیدگی غیرخطی این مسئله، دچار همگرایی زود هنگام یا ناپایداری در یافتن بهینه سراسری شدند. این نتیجه با گزارش‌های اخیر درباره کارایی EO در مسائل بهینه‌سازی پیچیده مهندسی فرامرزی و همکاران، مطابقت دارد.

مدل شبکه عصبی مصنوعی بهینه‌شده با الگوریتم تعادل توانست با ضریب تبیین بالاتر از ۰/۹۸ و خطای میانگین مطلق کمتر از ۰/۰۱، روابط پیچیده و غیرخطی بین پارامترهای طرح اختلاط و شاخص شکل‌پذیری را به‌خوبی شبیه‌سازی کند. این دقت بالا نه تنها ناشی از کیفیت داده‌های آزمایشگاهی و شبیه‌سازی شده است، بلکه نشان‌دهنده توانایی چارچوب ترکیبی در کاهش عدم قطعیت‌های مدل‌سازی است. علاوه بر این، نتایج تحلیل آماری باقیمانده‌ها مقدار  $p = 0.0078$  برابر که بیشتر از ۰/۰۰۵ است توزیع تصادفی و نزدیک به نرمال خطاها را تأیید می‌کند که بیانگر عدم وجود بایاس سیستماتیک و اعتبار بالای پیش‌بینی‌های مدل است. این یافته‌ها با مطالعات مشابه در پیش‌بینی خواص بتن با استفاده از هوش مصنوعی (دای و همکاران، شریعتی و همکاران) هم‌راستا است.

مقایسه چارچوب پیشنهادی با روش‌های سنتی نشان می‌دهد که ترکیب تاگوچی، شبکه عصبی مصنوعی و الگوریتم تعادل، تعادل مناسبی بین دقت، هزینه و انعطاف‌پذیری ایجاد می‌کند. در حالی که روش فاکتوریل کامل با ۲۵۶ آزمایش از دقت بالایی برخوردار است، اما از نظر هزینه و زمان غیرعملی است. از سوی دیگر، روش تاگوچی تنها با ۱۶ آزمایش، اگرچه کارآمد است، اما در مدل‌سازی روابط غیرخطی پیچیده محدودیت دارد. چارچوب پیشنهادی با تنها ۴۴ آزمایش فیزیکی، نه تنها دقتی قابل‌مقایسه با روش‌های دقیق‌تر ارائه می‌دهد، بلکه امکان بهینه‌سازی پیوسته و یافتن ترکیبات فراتر از آرایه طراحی اولیه را فراهم می‌کند. این رویکرد، با کاهش ۹۵ درصدی نیاز به آزمایش‌های فیزیکی نسبت به روش فاکتوریل، گامی مؤثر در جهت توسعه پایدار و مقرون‌به‌صرفه مصالح ساختمانی محسوب می‌شود.

بررسی طرح اختلاط بهینه (جدول ۳) نشان می‌دهد که عدم استفاده از سرباره در ترکیب با مقادیر بالای سیمان، منجر به حداکثر شاخص شکل‌پذیری شده است. این یافته بیانگر آن است که افزایش بیش از حد SL ممکن است به دلیل افزایش حجم مواد گرانولی یا تأخیر در واکنش‌های هیدراتاسیون، منجر به کاهش چسبندگی ماتریس و در نتیجه افت شکل‌پذیری شود. این رفتار با شواهد آزمایشگاهی از کاهش عملکرد در نمونه‌های حاوی SL بالا مطابقت دارد و نشان می‌دهد که بهینه‌سازی مواد پوزولانی باید با دقت انجام شود.

## ۴-۲ نتیجه گیری

در این پژوهش، یک چارچوب ترکیبی داده‌محور برای بهینه‌سازی طرح اختلاط بتن‌های کامپوزیتی توانمند با الیاف و عملکرد بالا (HPFRCC) توسعه داده شد. این چارچوب با ادغام روش طراحی آزمایش تاگوچی، مدل شبکه عصبی مصنوعی (ANN) و الگوریتم فراابتکاری تعادل (EO)، امکان طراحی دقیق، مقرون‌به‌صرفه و با کیفیت بالا را فراهم می‌کند. رویکرد پیشنهادی نه تنها دقت بالایی در پیش‌بینی شاخص شکل‌پذیری و جذب انرژی دارد، بلکه با کاهش ۹۵ درصدی نیاز به آزمایش‌های فیزیکی نسبت به روش‌های سنتی، گامی مؤثر در جهت توسعه پایدار و کاهش هزینه‌های آزمایشگاهی محسوب می‌شود.

نوآوری اصلی این پژوهش، ایجاد یک چرخه یکپارچه بین طراحی آزمایش، مدل‌سازی هوش مصنوعی و بهینه‌سازی فراابتکاری

است که به‌طور همزمان هم از دقت روش‌های آماری و هم از توانایی شبکه‌های عصبی در مدل‌سازی روابط غیرخطی بهره می‌برد. این چارچوب می‌تواند به‌عنوان الگویی قابل تعمیم برای طراحی سایر مصالح پیشرفته سیمانی مورد استفاده قرار گیرد. یافته‌های کلیدی این پژوهش به شرح زیر است:

- توسعه چارچوب ترکیبی Taguchi-ANN-EO که به‌طور دقیق و مقرون‌به‌صرفه، بهینه‌ترین طرح اختلاط را شناسایی می‌کند.
- کاهش ۹۵ درصدی نیاز به آزمایش‌های فیزیکی نسبت به روش طراحی فاکتوریل کامل، بدون تضعیف دقت مدل.
- بهبود ۴۰ درصدی شاخص شکل‌پذیری (جذب انرژی) در مقایسه با مطالعه مرجع (روش مستقل تاگوچی).
- شناسایی مقدار سیمان (C) به‌عنوان عامل غالب مؤثر بر شکل‌پذیری، و اثر منفی احتمالی افزایش بیش از حد سرباره (SL) بر عملکرد نهایی.
- اعتبارسنجی تجربی مدل ANN که نشان می‌دهد پیش‌بینی‌ها با خطای نسبی کمتر از ۰,۳٪ با نتایج آزمایشگاهی همخوانی دارند.
- تأیید صحت مدل از طریق تحلیل آماری باقیمانده‌ها و آزمون شاپرو-ویلک، که نشان‌دهنده توزیع نرمال خطاها و عدم وجود بایاس سیستماتیک است.

### ۳-۴ محدودیت‌ها و پیشنهادات برای پژوهش‌های آتی

#### محدودیت‌ها :

- حجم نسبتاً محدود داده‌های تجربی (۱۶ طرح فیزیکی و ۴۴ طرح شبیه‌سازی شده).
- عدم در نظر گرفتن متغیرهای محیطی مانند دما، رطوبت و سن بتن.
- عدم استفاده از روش‌های تحلیل حساسیت قابل تفسیر مانند SHAP, permutation, و LIME

#### پیشنهادات برای پژوهش‌های آتی:

- گسترش حجم داده‌های آزمایشگاهی برای افزایش قابلیت تعمیم مدل.
- ارزیابی عملکرد مدل در شرایط محیطی متنوع.
- به‌کارگیری روش‌های هوش مصنوعی قابل تفسیر (explainable AI) برای بهبود تفسیرپذیری و پذیرش مدل در محیط‌های صنعتی.

### ۵- تقدیر و تشکر

نویسندگان بر خود لازم می‌دانند از همکاری و حمایت‌های فنی و آزمایشگاهی دانشگاه علم و صنعت در فرایند اجرای این پژوهش صمیمانه قدردانی نمایند. همچنین، از داوران محترم و سردبیر ارجمند نشریه بابت بازخوردهای ارزشمند و علمی که نقش مؤثری در ارتقای کیفیت مقاله ایفا نمود، سپاسگزاری می‌شود.

### ۶. منابع

- [1]. Almeida, J.A., Bandelt, M.J., (2024), Plastic hinge length in reinforced HPFRCC beams and columns, *Engineering Structures*, 315: 118345.
- [2] Lu, T., (2025), *Mechanical Analysis of HPFRCC Precast Composite Column*, *Materials*, 18(7):

1567.

- [3] Guo, P., (2025), *Applications of machine learning methods for design and characterization of high-performance fiber-reinforced cementitious composite (HPFRCC): a review*, *Journal of Sustainable Cement-Based Materials* : 1-24.
- [4] Dai, L., (2022), *Using machine learning algorithms to estimate the compressive property of high strength fiber reinforced concrete*, *Materials*, 15(13): 4450.
- [5] Hasanzadeh, A., (2022), *Prediction of the mechanical properties of basalt fiber reinforced high-performance concrete using machine learning techniques*, *Materials*, 15(20): 7165.
- [6] Jiao, P., (2019), *High-performance fiber reinforced concrete as a repairing material to normal concrete structures: Experiments, numerical simulations and a machine learning-based prediction model*, *Construction and Building Materials*, 223: 1167-1181.
- [7] Kontoni, D.-P.N., Ahmadi, M., (2024), *Practical prediction of ultimate axial strain and peak axial stress of FRP-confined concrete using hybrid ANFIS-PSO models*, in *Artificial intelligence applications for sustainable construction*, Elsevier, : 225-255.
- [8] Shariati, M., (2022), *A novel hybrid extreme learning machine–grey wolf optimizer (ELM-GWO) model to predict compressive strength of concrete with partial replacements for cement*, *Engineering with Computers*, 38(1): 757-779.
- [9] Ahmadi, M., (2024), *Hybrid bio-inspired metaheuristic approach for design compressive strength of high-strength concrete-filled high-strength steel tube columns*, *Neural Computing and Applications*, 36(14): 7953-7969.
- [10] Shariati, M., (2020), *Prediction of concrete strength in presence of furnace slag and fly ash using Hybrid ANN-GA (Artificial Neural Network-Genetic Algorithm)*, *Smart Structures and Systems*, 25(2): 183-195.
- [11] Faramarzi, A., (2020), *Equilibrium optimizer: A novel optimization algorithm*, *Knowledge-based systems*, 191: 105190.
- [12] Natalli, J.F., (2021), *A review on the evolution of Portland cement and chemical admixtures in Brazil*, *Revista IBRACON de Estruturas e Materiais*, 14: e14603.
- [13] Feng, Z., (2022), *Optimal design of a low-cost high-performance hybrid fiber engineered cementitious composites*, *Construction and Building Materials*, 345: 128372.
- [14] Naseri, M., (1402), *Investigation of the effect of calcination temperature of clay on compressive strength and durability of LC3 concrete*, *Journal of Concrete Structures and Materials*, 8(2): 95-111
- [15] Abdolazade, S., Nili, M., (2022), *Evaluation of engineering properties of self-compacting geopolymer concrete using Taguchi method*, *Journal of Concrete Structures and Materials*, 7(2): 213-228
- [16] Rai, R., Dhal, K.G., (2023), *Recent developments in equilibrium optimizer algorithm: its variants and applications*, *Archives of Computational Methods in Engineering*, 30(6): 3791-3844.
- [17] Emani, D.M., (1403), *Optimization of mixture design of cementitious concrete containing various percentages of recycled and waste materials: Crumb rubber and reclaimed asphalt pavement (RAP)*, *Journal of Transportation Infrastructure Engineering*, 11(1): 11-20.
- [18] Rahmani, K., Naserlazade, K., Rostami Golehdar, M., (1402), *Experimental study on the effect of aggregate and fiber content on the mechanical properties of single-component slag-based*

- alkali-activated concrete, Journal of Concrete Structures and Materials, 8(2): 146-162.*
- [19] Ling, J.H., Lim, Y.T., Euniza, J., (2023), *Methods to determine ductility of structural members: a review, Journal of the Civil Engineering Forum.*
- [20] Temesi, O.K., (2024), *Ductility Index for Refractory High Entropy Alloys, Crystals, 14(10): 838.*
- [21] Cong, S., Zhou, Y., (2023), *A review of convolutional neural network architectures and their optimizations, Artificial Intelligence Review, 56(3): 1905-1969.*
- [22] Hossen, M.S., (2020), *Data preprocess, Machine Learning and Big Data: Concepts, Algorithms, Tools and Applications 71-103 : .*
- [23] Hematibahar, M., (2024), *Analysis of models to predict mechanical properties of high-performance and ultra-high-performance concrete using machine learning, Journal of Composites Science, 8(8): 287.*
- [24] Dehghani, M., Trojovská, E., Trojovský, P., (2022), *Driving training-based optimization: a new human-based metaheuristic algorithm for solving optimization problems.*