

Prediction of Standard Cement Mortar Compressive Strength Using Artificial Neural Network and Considering the Effect of Cement Fineness

Sahar Mahdinia

PhD Student, Structural Engineering, Department of Civil Engineering, Ferdowsi University of Mashhad

Mohammadreza Tavakkolizadeh*

Assistant Professor, Department of Civil Engineering, Ferdowsi University of Mashhad
drt@um.ac.ir

Mahdi Ahmadi Jalayer

MSc in Construction Management, Zaveh Torbat Cement Factory

Research paper

Abstract

The role of cement fineness in the process of hydration and development of compressive strength in the early ages of cement-based materials is irrefutable and it requires that its effect be investigated by predicting models. Therefore, an extensive study including 640 cement composition (1920 cement mortar specimens) from a cement factory with different percentages of raw materials feeding to the cement kiln including SiO_2 , Al_2O_3 , Fe_2O_3 , CaO , MgO , SO_3 , K_2O , and Na_2O were used to predict the 7-day compressive strength of cement mortar by artificial neural network (ANN). To investigate the effect of cement fineness, two models have been developed in two states of with and without fineness effect. Results confirmed the significant role of cement fineness as an input parameter in the performance of predicting model. The findings of this research can be used in cement production facilities in order to reduce the laboratory costs.

Keywords: Compressive Strength, Cement Mortar, Artificial Neural Network, Cement Fineness, Raw Materials.

*Corresponding Author: Mohammadreza Tavakkolizadeh

Mahdinia, S., Tavakkolizadeh, M., Ahmadi Jalayer, M. Prediction of Standard Sand cement Mortar Compressive Strength Using Artificial Neural Network and Considering the Effect of Cement Fineness. Journal of Concrete Structures and Materials, 2022; 7(2): 111-127. <http://doi.org/10.30478/jcsm.2023.375675.1305>

2538-5828/ © 2021 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/>).

پیش‌بینی مقاومت فشاری ملات استاندارد ماسه سیمان با استفاده از شبکه عصبی مصنوعی و در نظر گرفتن اثر نرمی سیمان

سحر مهدی‌نیا

دانشجوی دکتری سازه، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد

محمد رضا توکلی زاده

استادیار گروه مهندسی عمران، دانشکده مهندسی، دانشگاه فردوسی مشهد

drt@um.ac.ir (نویسنده مسئول)

مهدی احمدی جلایر

کارشناسی ارشد مدیریت ساخت، کارخانه سیمان زاوه تربت

نوع مقاله: مقاله پژوهشی

چکیده

نقش نرمی سیمان در روند هیدراتاسیون و رشد مقاومت فشاری در سنین پایین مواد پایه سیمانی غیرقابل انکار است؛ بر این اساس می‌تواند که اثر آن در مدل‌های پیش‌بینی مورد بررسی قرار گیرد. از این رو، در این پژوهش یک بررسی گسترده شامل ۶۴۰ ترکیب سیمان (۱۹۲۰ نمونه ملات سیمان) از محصولات کارخانه سیمان با درصد‌های مختلف مواد خام ورودی به کوره سیمان انجام شد. مواد خام اولیه شامل اکسیدهای سیلیس، آلومینیوم، آهن، کلسیم، منیزیم، گوگرد، پتاسیم و سدیم برای پیش‌بینی مقاومت فشاری ۷ روزه ملات استاندارد سیمان با استفاده از روش شبکه عصبی مصنوعی (ANN) در نظر گرفته شد. نرمی پودر سیمان مورد استفاده در این نمونه‌ها به عنوان یک عامل اثرگذار نیز مورد بررسی قرار گرفت. به این منظور، دو مدل در دو حالت با و بدون در نظر گرفتن نرمی سیمان در پارامترهای ورودی به کار گرفته شد. پس از بررسی نتایج به دست آمده می‌توان مشاهده کرد که مدل ANN با در نظر گرفتن نرمی سیمان عملکرد مناسب‌تری نسبت به مدل دیگر دارد. یافته‌های این پژوهش برای پیش‌بینی مقاومت فشاری سیمان تولیدی در کارخانه‌ها می‌تواند هزینه‌های آزمایشگاهی مربوطه را به شدت کاهش دهد.

کلمات کلیدی: مقاومت فشاری، ملات استاندارد سیمان، شبکه عصبی مصنوعی، نرمی سیمان، مواد خام.

سیمان به عنوان ماده اساسی در مواد پایه سیمانی مانند ملات سیمانی و بتن به شمار می‌آید [۱، ۲]. سیمان با ایفای چسبندگی در ترکیبات، نقشی مهم و اساسی در خواص مقاومتی مواد پایه سیمانی ایفا می‌کند. تاکنون پژوهش‌های آزمایشگاهی بسیاری به بررسی نقش سیمان بر ویژگی‌های فیزیکی، شیمیایی و ریز ساختار مواد پایه سیمانی تازه و سخت شده پرداخته‌اند [۳-۶]. از آن جایی که برنامه‌های آزمایشگاهی شامل فرآیند تهیه مصالح، ساخت نمونه و انجام آزمایش مواد پایه سیمانی هزینه‌های بالایی را به همراه خطاهای احتمالی انسانی در پی دارند، به کارگیری روش‌های هوش مصنوعی به عنوان جایگزینی موثر و کارآمد مورد توجه پژوهشگران در سراسر دنیا قرار گرفته است [۷، ۸]. در سال‌های اخیر روش‌های مختلف هوش مصنوعی همچون شبکه عصبی مصنوعی [۹]، ژنتیک بیان مسئله [۱۰]، فازی [۱۱] و ماشین بردار پشتیبان [۱۲] برای پیش‌بینی خواص و ویژگی‌های مواد پایه سیمانی مورد استفاده قرار گرفته‌اند.

از میان روش‌های عنوان شده، روش شبکه عصبی مصنوعی به خاطر توانایی بالای آن در دسته‌بندی داده‌ها و روابط بین ورودی و خروجی برای حل مسائل پیچیده به عنوان یکی از پرطرفدارترین و کاربردی‌ترین روش‌ها به کار گرفته شده است [۱۳]. در سال‌های اخیر پژوهش‌های زیادی در خصوص پیش‌بینی ویژگی‌های فیزیکی و مکانیکی مواد پایه سیمانی توسط روش شبکه عصبی مصنوعی در حوزه بتن [۱۴-۱۷]، خمیر سیمان [۱۸-۲۰] و ملات سیمان [۲۱-۲۳] انجام شده است. برای نمونه، اسکندری و کاظمی [۲۴] در پژوهش خود با استفاده از شبکه عصبی مصنوعی اثر رده مقاومتی سیمان را بر مقاومت فشاری در ۵۴ طرح اختلاط ملات‌های پایه سیمانی با نسبت‌های مختلف آب به سیمان و ماسه به سیمان مورد بررسی قرار دادند. نتایج حاصل از پیش‌بینی آنان نشان داد، مدلی که در آن اثر پارامتر رده مقاومتی سیمان در نظر گرفته شود در مقایسه با مدل مشابه بدون در نظر گرفتن این پارامتر نتایج نزدیک به نتایج آزمایشگاهی خواهد داشت. در مطالعه دیگری، پیش‌بینی مقاومت فشاری ملات پایه سیمانی توسط آکارت و همکاران [۲۵] انجام شد. در این پژوهش تجزیه و تحلیل تحلیل حساسیت ویژگی‌های فیزیکی و شیمیایی مختلف سیمان به عنوان پارامترهای ورودی مدل در نظر گرفته شد. نتایج نشان داد که تغییر در مقدار برخی از مواد مانند SO_3 ، C_2S و C_3A تاثیر به‌سزایی در مقاومت فشاری نهایی دارد که بر تاثیر قابل توجه مواد خام نخستین سیمان در دستیابی خواص مطلوب تاکید می‌کند. علاوه بر این، دان و همکاران [۲۶] در پژوهش خود در خصوص پیش‌بینی مقاومت فشاری بتن با خطاهای بزرگ در مدل‌های پیش‌بینی مواجه شدند که دلیل آن را عدم در نظر گرفتن نوع سیمان به عنوان پارامتر ورودی در مدل‌های به کار گرفته شده عنوان کردند.

بر اساس پیشینه پژوهشی بیان شده، تاکنون مطالعه‌ای در رابطه با اثر هم زمان مواد خام نخستین و نرمی سیمان با استفاده از روش شبکه عصبی مصنوعی انجام نشده است. از این رو، هدف پژوهش پیش رو گسترش یک مدل شبکه عصبی با در نظر گرفتن مقدار مواد خام نخستین سیمان و تمرکز بر نقش نرمی سیمان بر مقاومت فشاری ملات سیمانی استاندارد است. به این منظور، مدل ارائه شده براساس یک پژوهش گسترده بر روی ۱۹۲۰ نمونه (۶۴۰ نمونه سیمان تیپ ۲) در طول یک سال فعالیت یک کارخانه سیمان در شرق کشور صورت گرفته است. یافته‌های این پژوهش به عنوان اطلاعات پایه برای آغاز کار دیگر پژوهشگران و درک بهتر نقش نرمی سیمان در مدل‌های هوش مصنوعی به منظور پیش‌بینی مقاومت فشاری ملات‌های سیمانی استاندارد کمک خواهد کرد.

۲- برنامه آزمایشگاهی

۲-۱- مواد و مراحل آماده سازی نمونه‌ها

مواد مورد استفاده برای ساخت نمونه‌های ملات سیمانی استاندارد شامل: سیمان با رده مقاومتی ۵۲/۵ مگاپاسکال از کارخانه سیمان زاوه تربت، ریزدانه استاندارد (ماسه اتاوا) با وزن مخصوص ۲/۶ و مدول نرمی ۲/۴۸، آب مورد نیاز طرح اختلاط از آب لوله‌کشی شهری است.

در مجموع ۶۴۰ ترکیب سیمان تیپ ۲ (۳ نمونه برای هر طرح اختلاط) در طول یک سال فعالیت پیوسته‌ی یک کارخانه سیمان تهیه و مورد بررسی قرار گرفت. برای ساخت این نمونه‌ها در ابتدا ملات مورد استفاده با نسبت وزنی ماسه به سیمان ۲/۷۵ طبق استاندارد *ASTM C305* [۲۷] تهیه شد. فرآیند ساخت ملات به این صورت است که نخست آب با دمای ۲۰ درجه سانتی‌گراد در جام ریخته شده و در حالی که جام با سرعت کم در حال چرخش است سیمان به آن اضافه می‌گردد تا خمیر سیمان به دست آید. سپس، سنگدانه‌های ریز درون خمیر سیمان ریخته شده و همزن در ابتدا به مدت ۳۰ ثانیه با سرعت کم و پس از آن ۶۰ ثانیه با سرعت متوسط مواد را با هم مخلوط می‌کند تا ملات منسجمی تهیه و در قالب‌های مکعب مستطیلی به ابعاد ۴۰×۴۰×۱۶۰ میلی‌متری ریخته شود (شکل ۱). نمونه‌ها پس از ۲۴ ساعت از قالب‌ها بیرون آورده شده و طبق استاندارد *ASTM C109* [۲۸] درون آب عمل‌آوری می‌شوند. پس از ۷ روز از زمان تهیه نمونه‌ها برای اعمال بارگذاری، آن‌ها را خشک نموده و ذرات سست چسبیده به سطوح بارگذاری حذف می‌شود.



شکل ۱: نمونه خمشی تهیه شده در قالب خمشی ۴۰×۴۰×۱۶۰ میلی‌متری.

۲-۲- آزمایش‌های انجام شده

۲-۲-۱- آزمایش بلین (تعیین درجه نرمی سیمان)

در کارخانه‌های تولید سیمان، تعیین نرمی سیمان پرتلند، به کمک دستگاه نفوذ پذیری هوا (دستگاه بلین) است که طبق آیین‌نامه *ASTM C204-18* [۲۹] برای بر اساس مکش و عبور مقدار معینی هوا از طریق یک نمونه فشرده شده و متخلخل سیمانی انجام می‌شود. میزان نرمی سیمان بر حسب مساحت جانبی کل ذرات سیمان بر حسب سانتی‌متر مربع در یک گرم نمونه بیان می‌گردد. سلول نفوذپذیری دستگاه از یک استوانه صلب به قطر داخلی 12.7 ± 0.1 میلی‌متر از جنس فولاد ضد زنگ ساخته شده و سطح فوقانی آن باید بر محور اصلی سلول عمود باشد و بخش پایینی با انتهای فوقانی فشارسنج به خوبی جفت شود. فشارسنج باید تا وسط از یک مایع غیر فرار و غیر جاذب رطوبت و با وزن مخصوص و لزجت کم مانند دی‌بوتیل فتالیات یا یک روغن معدنی سبک با دمای $20 \pm 2^\circ\text{C}$ پر شود. شکل ۲ دستگاه آزمایش نرمی سیمان را نشان می‌دهد.




شکل ۲: دستگاه آزمایش نرمی سیمان.

۲-۲-۲- تحلیل XRF

پراش اشعه x یک روش غیر مخرب است که اطلاعات جامع و منحصر به فردی درباره عنصرهای شیمیایی تشکیل دهنده مواد براساس طرح پراش آن‌ها ارائه می‌دهد و در آزمایشگاه‌های کنترل کیفیت کارخانه‌های تولید سیمان به کار رفته و همچنین مورد تایید سازمان‌های استاندارد بین‌المللی نیز هست [۳۰]. این دستگاه قابلیت بالایی در تحلیل ترکیبی نمونه‌های سیمان و ملات دارد. برای تحلیل هر نمونه ابتدا حدود ۰/۵ تا ۳ گرم از نمونه به صورت پودر بسیار ریز در آمده (زیر الک شماره ۲۰۰) و سپس به صورت قرص تهیه می‌گردد و در معرض بمباران پرتوهای اشعه ایکس با طول موج ۰/۱ تا ۱۰۰ آنگستروم قرار داده می‌شود و الگوی پراش آن به دست می‌آید. هر نمونه الگوی پراش منحصر به فردی دارد که مقایسه آن با الگوهای استاندارد منجر به شناسایی عنصرهای شیمیایی تشکیل دهنده ماده می‌شود. شکل ۳ تجهیزات ساخت قرص، قرص تهیه شده و دستگاه تحلیل را نشان می‌دهد. نمونه نمودار پراش ذرات توسط اشعه x در شکل ۴ نشان داده شده است [۳۱].



شکل ۳: تجهیزات آزمایش XRF الف) دستگاه تهیه قرص، ب) قرص تهیه شده و پ) دستگاه تحلیل.



شکل ۴: تحلیل نمونه ملات پایه سیمانی استاندارد با استفاده از XRF [۳۱]

۳-۲-۲- آزمایش مقاومت فشاری

برای انجام آزمایش مقاومت فشاری از نمونه‌های ساخته شده مقاومت خمشی استفاده شده است. به همین منظور آزمون‌های شکسته شده در آزمایش مقاومت خمشی طبق آیین نامه *ASTM C349-02* [۳۲] برای انجام آزمایش مقاومت فشاری مورد استفاده قرار گرفته است. شکل ۵ دستگاه آزمایش مقاومت فشاری را نشان می‌دهد. مقدار مقاومت فشاری نمونه از رابطه ۲ به دست می‌آید:

$$F_c = 0.0625 P_c \quad (2)$$

F_c = مقاومت فشاری بر حسب کیلو پاسکال

P_c = حداکثر بار فشاری اعمال شده بر حسب نیوتن




شکل ۵: نمایش جک فشاری مورد استفاده

۳- شبکه عصبی مصنوعی (ANN)

ANN یک روش غیرخطی برای به دست آوردن روابط پیچیده موجود بین پارامترهای مختلف است که تلاش می‌کند براساس ساختار عصبی بیولوژیکی مغز انسان که متشکل از تعداد زیادی نورون‌های به هم پیوسته است به معادلاتی برای حل مسائل مختلف برسد [۳۳]. در شبکه‌های عصبی بازگشتی، نورون‌ها به صورت لایه‌ای مرتب شده‌اند به صورتی که همه نورون‌ها در لایه‌های متفاوت به یکدیگر متصل می‌شوند در حالی که هیچ ارتباطی بین نورون‌های همان لایه وجود ندارد [۳۴].

اولین لایه‌ای در روش شبکه عصبی مصنوعی لایه ورودی است که شامل پارامترهای ورودی ANN می‌باشد که تعداد نورون‌های آن به تعداد پارامترهای ورودی به مدل می‌باشد. آخرین لایه تحت عنوان لایه خروجی است تعداد نورون‌های آن همان تعداد خروجی مدل است. لایه‌های دیگر که در بین این دو لایه وجود دارند با نام لایه‌های پنهان شناخته می‌شوند که تعداد لایه‌های پنهان و تعداد نورون‌های بستگی به مسئله مورد بررسی دارد و تعیین


تعداد آن‌ها نیاز به ارزیابی معماری‌های مختلف به منظور دستیابی به بهترین معماری مدل است [۳۵]. شکل ۶ نشان دهنده مدل نورون‌های عصبی مغز انسان و مدل *ANN* الهام گرفته شده از آن است [۳۶].



شکل ۶: شکل نورون‌های عصبی، الف) مدل نورون‌های عصبی مغز انسان و ب) مدل *ANN* الهام گرفته شده از نورون‌های عصبی [۳۵]

۱-۳- آماده‌سازی مدل

به منظور دستیابی به ساختار *ANN* نیاز به تحلیل تعداد لایه و نورون‌ها در لایه/لایه‌های پنهان است. از این رو شکل ۷ تحلیل صورت گرفته بر روی ۵ مدل برتر با معماری‌های مختلف را نشان می‌دهد. از این میان مدل (۶-۱۲) شامل دو لایه پنهان به ترتیب با ۱۲ و ۶ نورون در هر لایه پنهان براساس کمترین خطای مطلق با کمترین تعداد تکرار به عنوان بهترین مدل انتخاب شده است.



شکل ۷: ارزیابی معماری‌های شبکه‌های عصبی با ۲ لایه پنهان و تعداد نورون‌های گوناگون ۶ تا ۱۲

همان گونه که در جدول ۱ مشاهده می‌شود، به منظور بررسی اثر نرمی سیمان در پیش‌بینی مقاومت فشاری، دو مدل *ANN-I* و *ANN-II* تعریف شده‌اند که در مدل *ANN-I* تعداد پارامترهای ورودی ۸ بوده و شامل تحلیل ترکیب‌های شیمیایی (اکسیدهای معدنی) مواد ورودی به کوره می‌باشد. در صورتی که در مدل *ANN-II* علاوه بر ۸ پارامتر ورودی مدل *ANN-I* پارامتر نرمی سیمان نیز به عنوان ورودی در نظر گرفته شده است. سایر پارامترها و مشخصات به کار گرفته شده در مدل‌سازی در جدول ۱ ارائه شده است. جدول ۲ بازه‌ی کمینه و بیشینه را برای پارامترهای ورودی و خروجی در نظر گرفته شده نشان می‌دهد.

جدول ۱: پارامترهای استفاده شده در مدل سازی شبکه عصبی

پارامترها	تنظیمات	ساختار ANN
SiO ₂ - Al ₂ O ₃ - Fe ₂ O ₃ - CaO- MgO- SO ₃ - K ₂ O- Na ₂ O	۸	مدل ANN-I
-SiO ₂ - Al ₂ O ₃ - Fe ₂ O ₃ - CaO- MgO- SO ₃ - K ₂ O- Na ₂ O	۹	مدل ANN-II
Fineness	۲	تعداد لایه های پنهان
-	۱۲	تعداد نورون های اولین لایه پنهان
-	۶	تعداد نورون های دومین لایه پنهان
مقاومت فشاری ۷ روزه	۱	تعداد خروجی
لونبرگ-مارکوارت	-	الگوریتم آموزشی
سیگموئید	-	تابع انتقال

جدول ۲: بازه کمینه و بیشینه پارامترهای ورودی و خروجی

پارامترها	ورودی								خروجی	
	نرمی - بلین	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	SO ₃	K ₂ O	Na ₂ O	مقاومت
	(m ² /g)	(%)							(MPa)	
کمترین مقدار	۰/۲۸۱۴	۲۰/۲۲	۱/۸۴	۳/۵۷	۶۲/۹۸	۲/۰۰	۰/۸۴	۰/۵۰	۰/۳۴	۲۷/۴
بیشترین مقدار	۰/۳۸۲۵	۲۱/۷۴	۵/۲۱	۴/۱۸	۶۴/۷۰	۳/۱۸	۲/۷۲	۰/۷۵	۰/۴۹	۴۷/۳

از مجموع ۱۹۲۰ نمونه (سه نمونه برای هر ۶۴۰ ترکیب سیمان)، مقدار میانگین سه نمونه برای هر ترکیب تعیین شده و برای تحلیل مورد استفاده قرار گرفته است. از این میان ۴۴۸ نمونه (۷۰ درصد) برای آموزش (train) و تعداد ۹۶ نمونه (۱۵ درصد) برای آزمایش (test) و ۹۶ نمونه (۱۵ درصد) برای درست آزمایی (validate) مدل در نظر گرفته شده است. توابع مورد استفاده در هر سه مرحله آموزش، آزمایش و درست آزمایی عبارتند از: جذر میانگین مربعات خطا (RMSE)، میانگین درصد قدر مطلق خطا (MAPE) و ضریب همبستگی (R²)، که در معادله های ۳ تا ۵ معرفی شده اند:

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

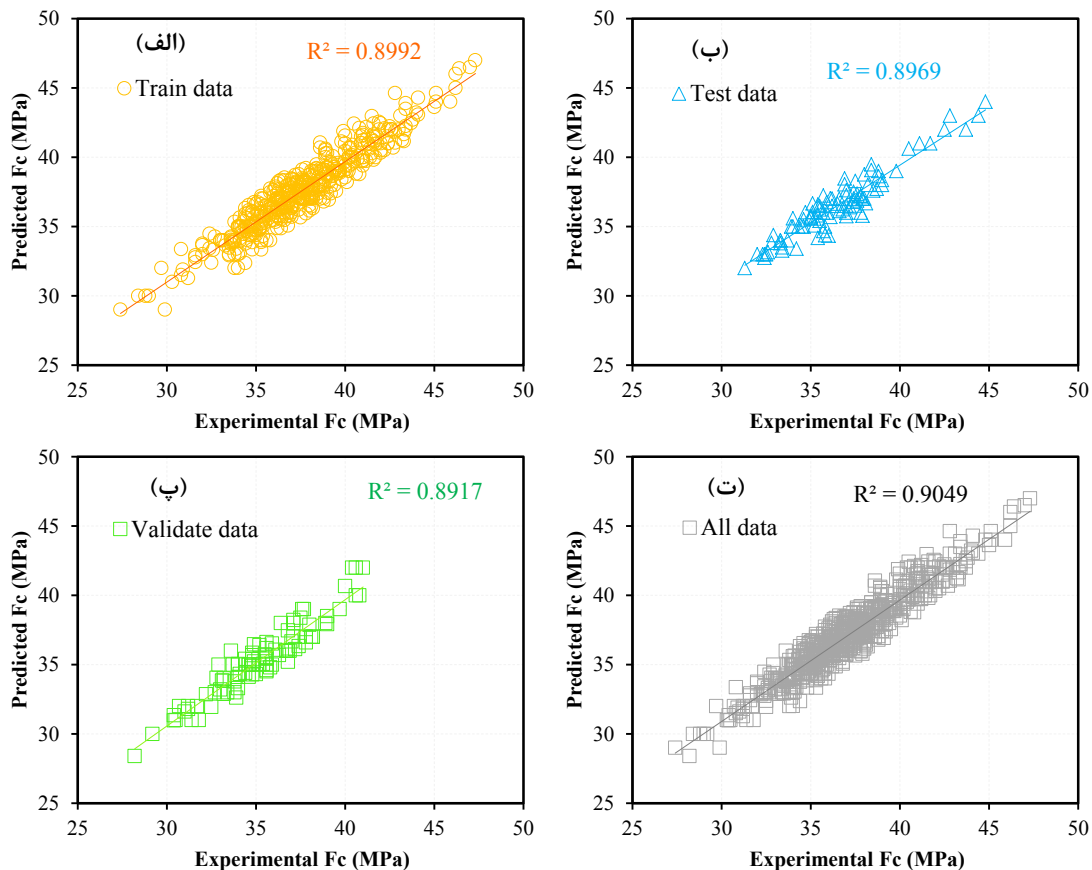
$$MAPE = \frac{1}{n} \sum_i \left| \frac{A_i - P_i}{A_i} \right| * 100 \quad (4)$$

$$R^2 = 1 - \left(\frac{\sum_i (A_i - P_i)^2}{\sum_i (P_i)^2} \right) \quad (5)$$


در معادله های ۳ تا ۵، n تعداد کل داده ها، A_i و P_i به ترتیب مقادیر واقعی و پیش بینی شده برای هر یک از داده ها می باشند.

۴- تحلیل نتایج مدل


شکل‌های ۸ تا ۱۱ مقایسه نتایج آزمایشگاهی و پیش‌بینی براساس دو مدل *ANN-I* و *ANN-II* را نشان می‌دهد. شکل ۸ مربوط به مدل‌سازی با *ANN-I* است که درون‌یابی خطی داده‌های آموزش، آزمایش و درست‌آزمایی و کلی را به ترتیب در بخش‌های (الف) تا (ت) نشان داده است. مقادیر R^2 برای داده‌های آموزش، آزمایش و درست‌آزمایی و کلی به ترتیب برابر ۰/۸۹۷، ۰/۸۹۲، ۰/۹۰۵ و ۰/۸۹۹ است. شکل ۹ درصد خطای بین مقادیر پیش‌بینی مدل *ANN-I* و مقادیر واقعی را نشان می‌دهد و بیانگر آن است که خطا در بازه‌ی ۸- تا ۶+ درصد قرار دارد. نتایج درون‌یابی خطی برای مدل‌سازی *ANN-II* در شکل ۱۰ نشان داده شده است. مقادیر R^2 برای داده‌های آموزش، آزمایش و درست‌آزمایی و کلی در این مدل به ترتیب برابر ۰/۹۷۷، ۰/۹۶۹، ۰/۹۶۶ و ۰/۹۷۶ است. نتایج مربوط به درصد خطای مقادیر پیش‌بینی مدل *ANN-II* و مقادیر واقعی در شکل ۱۱ حاکی از کاهش بازه‌ی خطا به ۵- تا ۴+ درصد است. با مقایسه نتایج شکل‌های ۸ و ۱۰ به همراه شکل‌های ۹ و ۱۱ می‌توان مشاهده کرد که در نظر گرفتن پارامتر تاثیرگذار نرمی سیمان در مدل‌سازی افزون بر این که در مقدار R^2 موثر است (نمودارهای شکل ۱۰ مقادیر بیشتری از R^2 را به نسبت نمودارهای شکل ۸ نشان می‌دهد)، سبب شده تا درصد خطای پیش‌بینی (شکل ۹) کاهش آشکار حدود ۵۰٪ داشته باشد. این نتایج عملکرد بهتر مدل *ANN-II* در پیش‌بینی مقادیر مقاومت فشاری ۷ روزه ملات پایه سیمانی استاندارد را نشان می‌دهد.




شکل ۸: مدل درون‌یابی خطی برای داده‌های (الف) آموزش، (ب) آزمایش، (پ) درست‌آزمایی و (ت) کلی.



شکل ۹: مقایسه درصد خطای مقادیر پیش‌بینی در مدل ANN-I و مقادیر آزمایشگاهی.



شکل ۱۰: مدل درون‌یابی خطی ANN-II برای داده‌های (الف) آموزش، (ب) آزمایش، (پ) درست‌آزمایی و (ت) کلی.



شکل ۱۱: مقایسه درصد خطای مقادیر پیش‌بینی در مدل ANN-II و مقادیر آزمایشگاهی.

مقادیر آماری بخش‌های آموزش، آزمایش، درست‌آزمایی و کل نمونه‌ها با دو مدل‌سازی *ANN-I* و *ANN-II* برای مقاومت فشاری ملات سیمان در سن ۷ روز در جدول ۳ ارائه شده است. نزدیک‌ترین مقادیر R^2 به ۱ و کمترین مقادیر خطا ($RMSE$ و $MAPE$) نشان دهنده بهترین مدل می‌باشد، بنابراین مدل *ANN-II* با دارا بودن مقادیر کل $RMSE=0.489$ و $MAPE=1.090$ ، $R^2=0.976$ در مقایسه با مدل *ANN-I* با $MAPE=2.194$ ، $R^2=0.905$ و $RMSE=0.973$ بهترین عملکرد را به عنوان مدل پیشنهادی داشته است.

جدول ۳: مقایسه مقادیر آماری برای دو مدل *ANN-I* و *ANN-II*

مدل <i>ANN</i>	مجموعه داده	R^2	$MAPE$	$RMSE$
<i>ANN-I</i>	آموزش	0.899	2.219	1.007
	آزمایش	0.897	2.086	0.880
	درست‌آزمایی	0.892	2.183	0.893
	کل	0.905	2.194	0.973
<i>ANN-II</i>	آموزش	0.977	1.076	0.485
	آزمایش	0.969	1.047	0.472
	درست‌آزمایی	0.966	1.199	0.523
	کل	0.976	1.090	0.489

۵- نتیجه گیری

هدف از این مطالعه بررسی نقش مواد خام نخستین به کار رفته در تولید و نرمی سیمان در مقاومت فشاری ۷ روزه ملات استاندارد ماسه سیمان با استفاده از روش *ANN* است. برای این منظور، اطلاعات گسترده از ۶۴۰ ترکیب گوناگون سیمان تیپ ۲ شامل ۱۹۲۰ آزمون‌های ملات سیمان استاندارد از کارخانه سیمان زاوه تربت با نرمی‌های متفاوت و درصد‌های گوناگونی از مواد خام ورودی به کوره پخت سیمان شامل CaO ، Fe_2O_3 ، Al_2O_3 ، SiO_2 ، MgO ، SO_3 ، K_2O و Na_2O مورد استفاده قرار گرفته است. تاثیر پارامتر نرمی سیمان به عنوان ورودی در مدل‌سازی و اثر آن در پیش‌بینی با دو مدل *ANN-I* (بدون در نظر گرفتن پارامتر نرمی سیمان) و *ANN-II* (با در نظر گرفتن پارامتر نرمی سیمان) مورد ارزیابی قرار گرفت. نتیجه‌گیری‌های زیر را می‌توان دست آورده‌های مهم این پژوهش دانست:

ساختار معماری شبکه عصبی آموزش داده شده توسط الگوریتم لونیگ-مارکوارت با دوازده و شش نورون به ترتیب در نخستین و دومین لایه‌ی پنهان، می‌تواند مقاومت فشاری ۷ روزه ملات سیمانی استاندارد را به بهترین گزینه و با کمترین تکرار مورد نیاز در مقایسه با سایر معماری‌های شبکه عصبی پیش‌بینی کند. مقایسه نتیجه‌های دو مدل با یکدیگر نشان می‌دهد که *ANN-II* از ضریب‌های همبستگی بالاتر نسبت به *ANN-I* در هر چهار مجموعه‌ی مورد بررسی (آموزش، آزمایش، درست‌آزمایی و کلی) برخوردار است، به گونه‌ای که این مقدار برای کل داده‌ها در *ANN-II* برابر ۰/۹۷۶ و *ANN-I* برابر ۰/۹۰۵ بوده است. درصد خطا بین مقادیر پیش‌بینی شده و مقادیر واقعی حاکی از بازه‌های خطای (۸- تا ۶+ درصد) برای *ANN-I* و (۵- تا ۴+ درصد) برای *ANN-II* است. این نشان دهنده کاهش تقریبی ۵۰٪ بازه‌ی خطای پیش‌بینی در مدل

ANN-II نسبت به *ANN-I* است (از ۱۴ به ۹ درصد). همچنین مقایسه نتایج سایر توابع خطا همچون *MAPE* و *RMSE* حاکی بر عملکرد بهتر مدل *ANN-II* بوده است.

مدل *ANN-II* نقش پارامتر نرمی سیمان را در مدل‌سازی و اثر آن در پیش‌بینی مقادیر نزدیک به واقعیت را به دلیل در نظر گرفتن آن به عنوان پارامتر ورودی تاثیرگذار گواهی می‌کند.

یافته‌های این پژوهش به در نظر گرفتن نقش نرمی سیمان در مدل‌سازی روش‌های پیش‌بینی ویژگی‌ها و رفتار مواد سیمانی در سایر پژوهش‌های آینده تاکید می‌کند.

سپاسگزاری

انجام این پژوهش بدون حمایت‌های معاونت پژوهشی دانشگاه فردوسی مشهد و همکاری مادی و معنوی کم نظیر مدیریت شرکت و کارکنان کوشای کارخانه سیمان زاوه تربت امکان پذیر نبود. به این وسیله از تمامی کارشناسان آزمایشگاه شیمی کارخانه سیمان زاوه تربت نیز سپاسگزاری می‌شود.

منابع

1. Ahmadi B, Khalooee S. (2022). The Use of high Volume of Glass Powder as a Substitute for Cement in Self-Compacting Concrete. *Journal of Concrete Structure and Materials*. 7(1): p. 137-156. (in persian).
2. Mahdinia S, Eskandari-Naddaf H and Shadnia R. (2017). Effect of Main factors on fracture mode of mortar, a graphical study. *Civil Engineering Journal*. 3(10): p. 897-903. 10.28991.
3. Lesko S, Lesniewska E, Nonat A, Mutin J-C, and Goudonnet J-P. (2001). Investigation by atomic force microscopy of forces at the origin of cement cohesion. *Ultramicroscopy*. 86(1-2): p. 11-21.
4. Korouzhdeh T and Eskandari-Naddaf H. (2022). Mechanical properties and microstructure evaluation of cement mortar with different cement strength classes by image analysis. *Arabian Journal for Science and Engineering*. 47(4): p. 4763-4783.
5. Yuan Q, Xie Z, Yao H, Huang T, and Fan M. (2022). Hydration, mechanical properties, and microstructural characteristics of cement pastes with different ionic polyacrylamides: A comparative study. *Journal of Building Engineering*: p. 104763.
6. Mansourghanaei M, Biklaryan M and Mardookhpour A. (2022). Experimental Investigation of the Effect of Nanosilica on the Mechanical Properties and Durability of Slag Geopolymer Concrete. *Journal of Concrete Structure and Materials*. 7(1): p. 93-113. (in persian).
7. Ghanei A, Eskandari-Naddaf H, Ozbakkaloglu T and Davoodi A. (2020). Electrochemical and statistical analyses of the combined effect of air-entraining admixture and micro-silica on corrosion of reinforced concrete. *Construction and Building Materials*. 262: p. 120768.
8. Arabshahi A, Gharaei-Moghaddam N and Tavakkolizadeh M. Development of applicable design models for concrete columns confined with aramid fiber reinforced polymer using Multi-Expression Programming. in *Structures*. 2020. Elsevier.
9. Kooshkaki A and Eskandari-Naddaf H. (2019). Effect of porosity on predicting compressive and flexural strength of cement mortar containing micro and nano-silica by multi-objective ANN modeling. *Construction and Building Materials*. 212: p. 176-191.
10. Mahdinia S, Eskandari-Naddaf H and Shadnia R. (2019). Effect of cement strength class on the prediction of compressive strength of cement mortar using GEP method. *Construction and Building Materials*. 198: p. 27-41.
11. Saridemir M. (2009). Predicting the compressive strength of mortars containing metakaolin by artificial neural networks and fuzzy logic. *Advances in Engineering Software*. 40(9): p. 920-927.
12. Azimi-Pour M, Eskandari-Naddaf H and Pakzad A. (2020). Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete. *Construction and Building Materials*. 230: p. 117021.

13. Adeli H and Seon Park H. (1995). Counterpropagation neural networks in structural engineering. *Journal of Structural Engineering*. 121(8): p. 1205-1212.
14. Xi X, Yin Z, Yang S and Li C-Q. (2021). Using artificial neural network to predict the fracture properties of the interfacial transition zone of concrete at the meso-scale. *Engineering Fracture Mechanics*. 242: p. 107488.
15. Felix E F, Carrazedo R and Possan E. (2021). Carbonation model for fly ash concrete based on artificial neural network: Development and parametric analysis. *Construction and Building Materials*. 266: p. 121050.
16. Abuodeh O R, Abdalla J A and Hawileh R A. (2020). Assessment of compressive strength of Ultra-high Performance Concrete using deep machine learning techniques. *Applied Soft Computing*. 95: p. 106552.
17. Ghorbani A. (2021). Experimental and Analytical Investigation on The Effect of Steel Fibers on The Mechanical Properties and Performance of Fibrous Self-Compacting Concretes. *Journal of Concrete Structure and Materials*. 6(2): p. 115-131. (in persian).
18. Soltangharaei V, Anay R, Assi L, Bayat M, Rose J, and Ziehl P. (2021). Analyzing acoustic emission data to identify cracking modes in cement paste using an artificial neural network. *Construction and Building Materials*. 267: p. 121047.
19. Mohammed A, Rafiq S, Mahmood W, Al-Darkazalir H, Noaman R, Qadir W, and Ghafor K. (2021). Artificial Neural Network and NLR techniques to predict the rheological properties and compression strength of cement past modified with nanoclay. *Ain Shams Engineering Journal*. 12(2): p. 1313-1328.
20. Terzić A, Radulović D, Pezo M, Stojanović J, Pezo L, Radojević Z, and Andrić L. (2020). Prediction model based on artificial neural network for pyrophyllite mechano-chemical activation as an integral step in production of cement binders. *Construction and Building Materials*. 258: p. 119721.
21. Onal O and Ozturk A U. (2010). Artificial neural network application on microstructure–compressive strength relationship of cement mortar. *Advances in Engineering Software*. 41(2): p. 165-169.
22. Onyari E and Ikotun B. (2018). Prediction of compressive and flexural strengths of a modified zeolite additive mortar using artificial neural network. *Construction and Building Materials*. 187: p. 1232-1241.
23. Nasr D, Behforouz B, Borujeni P R, Borujeni S A, and Zehtab B. (2019). Effect of nano-silica on mechanical properties and durability of self-compacting mortar containing natural zeolite: Experimental investigations and artificial neural network modeling. *Construction and Building Materials*. 229: p. 116888.
24. Eskandari-Naddaf H and Kazemi R. (2017). ANN prediction of cement mortar compressive strength, influence of cement strength class. *Construction and Building Materials*. 138: p. 1-11.
25. Akkurt S, Ozdemir S, Tayfur G and Akyol B. (2003). The use of GA-ANNs in the modelling of compressive strength of cement mortar. *Cement and concrete research*. 33(7): p. 973-979.
26. Duan Z-H, Kou S-C and Poon C-S. (2013). Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. *Construction and Building Materials*. 40: p. 1200-1206.
27. ASTM C. (1999). 305, Standard Practice for Mechanical Mixing of Hydraulic Cement Pastes and Mortars of Plastic Consistency. *ASTM International*.
28. Astm C. (2021). 109: Standard Test Method for Compressive Strength of Hydraulic Cement Mortars. *Annual Book of ASTM Standards*.
29. Astm C. (2016). 204: Standard Test Methods for Fineness of Hydraulic Cement by Air-Permeability. *Annual Book of ASTM Standards*. 4.
30. ASTM C. (2018). 114, Standard Test Methods for Chemical Analysis of Hydraulic Cement. *Annual Book of ASTM Standards*.
31. Garcia-Florentino C, Maguregui M, Morillas H, Marcaida I, and Madariaga J M. (2017). A fast in situ non-invasive approach to classify mortars from a construction of high historical value. *Microchemical Journal*. 133: p. 104-113.

32. *Astm C. (2002). 349-02: Standard Test Method for Compressive Strength of Hydraulic-Cement Mortars (Using Portions of Prisms Broken in Flexure). ASTM International.*
33. *Jin L, Dong T, Fan T, Duan J, Yu H, Jiao P, and Zhang W. (2022). Prediction of the chloride diffusivity of recycled aggregate concrete using artificial neural network. Materials Today Communications: p. 104137.*
34. *Zhao Y, Hu H, Song C and Wang Z. (2022). Predicting compressive strength of manufactured-sand concrete using conventional and metaheuristic-tuned artificial neural network. Measurement. 194: p. 110993.*
35. *Hatami F and Amiri M. (2022). Experimental study of mechanical properties and durability of green concrete containing slag, waste rubber powder and recycled aggregate with artificial neural network. Cleaner Materials. 5: p. 100112.*
36. *Azimi-Pour M and Eskandari-Naddaf H. (2018). ANN and GEP prediction for simultaneous effect of nano and micro silica on the compressive and flexural strength of cement mortar. Construction and Building Materials. 189: p. 978-992.*