



تأثیر نوآورانه ترکیب مواد شیمیایی افزودنی بر مقاومت فشاری طولانی مدت بتن

با استفاده از الگوریتم‌های یادگیری ماشین

سید ایمان غفوریان حیدری^(۱) مجید صافحیان^{(۲)*} فرامرز مودی^(۳) شبنم شادرو^(۴)

(۱) گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

(۲) گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران*

(۳) گروه مهندسی عمران، دانشگاه صنعتی امیرکبیر، تهران، ایران

(۴) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

تاریخ دریافت: ۱۴۰۳/۰۹/۲۵ تاریخ پذیرش: ۱۴۰۳/۱۱/۲۷

چکیده

ترکیبات مواد شیمیایی افزودنی نقش مهمی در تولید بتن دارند. درک خواص مکانیکی آن‌ها برای تضمین ایمنی و دوام ضروری است. مقاومت فشاری، به عنوان مهم‌ترین ویژگی بتن، تعیین‌کننده دوام و عملکرد سازه‌ها است. این تحقیق به بررسی بلندمدت اثرات ترکیبات مختلف افزودنی‌های شیمیایی بر مقاومت فشاری بتن می‌پردازد. با ۷۸۴۵ نمونه آزمایشگاهی و تحلیل سنین مختلف بتن از ۳ روز تا ۳ سال، این تحقیق داده‌های جامع‌تری نسبت به مطالعات قبلی ارائه می‌دهد. برای پیش‌بینی مقاومت فشاری، مدل‌های یادگیری ماشین شامل NARX، RF، MLP، DT و SVR ارزیابی شدند. مدل NARX با ضریب تعیین R^2 برابر ۰٫۹۹۳۲ و خطای میانگین مربعات نرمال‌شده (NMSE) برابر ۱۸٫۹۷، بهترین عملکرد را داشت. یافته‌ها نشان داد که کاهش مقاومت فشاری طولانی‌مدت در یک و سه سال در مقایسه با ۹۰ روز، تأثیرات منفی بر ظرفیت تحمل بار و عمر سازه‌ها دارد. این نتایج بر ضرورت بازنگری در برخی استانداردهای طراحی سازه‌های بتنی تأکید می‌کند تا کاهش طولانی‌مدت مقاومت فشاری در نظر گرفته شود. این تحقیق بر نقش مدل‌های پیشرفته یادگیری ماشین در بهبود دقت پیش‌بینی و کاهش اثرات اقتصادی و زیست‌محیطی تأکید دارد.

کلمات کلیدی: افزودنی‌های شیمیایی، پیش‌بینی مقاومت فشاری، یادگیری ماشین، NARX، RF، DT، MLP

*عهده‌دار مکاتبات:

مجید صافحیان

نشانی: گروه مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

پست الکترونیکی: safchian@srbiau.ac.ir

در سال‌های اخیر، استفاده از مواد افزودنی شیمیایی در تولید بتن برای کاربردهای مختلف ساختمانی به‌طور چشمگیری افزایش یافته است. این مواد شیمیایی به منظور بهبود ویژگی‌های بتن تازه مورد استفاده قرار می‌گیرند [1]. با این حال، این مواد تأثیرات متنوعی بر مقاومت فشاری بلندمدت بتن دارند. پیش‌بینی خواص مکانیکی مواد ساختمانی، از جمله مقاومت فشاری بتن، یک مسئله حیاتی در علوم مواد و مهندسی ساختمان است. این خاصیت به‌طور مستقیم با دوام و پایداری ساختمان‌ها در طول زمان مرتبط است و برای تضمین عمر مفید و ایمنی سازه‌ها ضروری است. علاوه بر این، مقاومت فشاری بتن نه تنها نشان‌دهنده کیفیت بتن است، بلکه عاملی کلیدی در ارزیابی دوام، ظرفیت باربری و عملکرد بلندمدت سازه‌ها به‌شمار می‌رود. مقاومت فشاری بتن به عنوان یک عامل کلیدی نه تنها ایمنی سازه‌ها را تضمین می‌کند، بلکه نقش مهمی در کاهش هزینه‌های بلندمدت نگهداری ایفا می‌نماید. مقاومت فشاری بلندمدت بر توانایی تحمل بار، رفتار خزشی، مقاومت در برابر آتش و انعطاف‌پذیری سازه تأثیر می‌گذارد [2][3]. کاهش مقاومت فشاری بلندمدت بتن می‌تواند منجر به افزایش نیاز به تقویت، تغییرات ساختاری و هزینه‌های نگهداری شود و تاب‌آوری ساختمان‌ها در برابر شرایط محیطی شدید را کاهش دهد. علاوه بر این، کاهش مقاومت می‌تواند منجر به افزایش مصرف انرژی، تخریب منابع طبیعی و کاهش دوام شود. به‌ویژه در پروژه‌های زیرساختی، کاهش مقاومت فشاری می‌تواند خطرات ایمنی قابل توجهی ایجاد کرده و بهره‌وری اقتصادی پروژه را تحت تأثیر قرار دهد. بنابراین، تحلیل دقیق تأثیرات بلندمدت مواد افزودنی بر مقاومت فشاری بتن می‌تواند تأثیرات اقتصادی و زیست‌محیطی مثبتی به همراه داشته باشد. این مسئله اهمیت مدیریت و کنترل ترکیب مواد افزودنی شیمیایی مانند فوق‌روان‌کننده‌ها، کندگیرکننده‌ها و عوامل هوازا را برای بهینه‌سازی طرح‌های مخلوط بتن و تضمین عملکرد بلندمدت و پایداری آن برجسته می‌کند [4][5]. مدیریت دقیق اثرات مواد افزودنی می‌تواند به کاهش پیامدهای منفی و افزایش عمر مفید و عملکرد سازه‌ها کمک کند.

روش‌های سنتی پیش‌بینی مقاومت فشاری، مانند روابط تجربی یا رگرسیون خطی، هرچند ساده هستند، در تحلیل سیستم‌های پیچیده و داده‌های غیرخطی محدودیت دارند [6][7]. این روش‌ها در مدل‌سازی تعاملات پیچیده مواد افزودنی با عوامل محیطی دقت کافی ندارند و معمولاً برای کاربردهای خاص بتن، به‌ویژه در سنین بلندمدت، کارایی محدودی نشان می‌دهند. این محدودیت‌ها به‌ویژه در بتن‌های خاص که تحت تأثیر عوامل متعددی مانند نسبت آب به سیمان، دما و نوع مواد ترکیبی قرار دارند، مشهودتر است. در نتیجه، مدل‌های یادگیری ماشین به عنوان ابزارهایی مؤثر برای غلبه بر این چالش‌ها مطرح شده‌اند. در تحقیقات پیشین، داده‌های ورودی متنوعی برای تخمین مقاومت فشاری بتن با استفاده از مدل‌های یادگیری ماشین استفاده شده است. به عنوان مثال، داده‌هایی مانند نسبت آب به سیمان (W/C),
 ۱

وزن سیمان، وزن سنگدانه‌ها و مواد زائد مورد بررسی قرار گرفته‌اند. این تحقیق، برخلاف مطالعات پیشین، از تنها یک نوع ورودی یعنی سن بتن استفاده کرده است. این روش نه تنها باعث ساده‌سازی مدل‌ها شده، بلکه دقت پیش‌بینی را نیز به طور چشمگیری افزایش داده است. تحقیقات Saridemir و Moradi، هرچند پیشرفت‌هایی در استفاده از الگوریتم‌های یادگیری ماشین ارائه داده‌اند، اما به دلیل تمرکز بر سنین کوتاه‌مدت بتن و استفاده از مجموعه داده‌های محدود، توانایی پیش‌بینی بلندمدت دقیق را نداشته‌اند. این تغییر در داده‌های ورودی به بهبود قابل توجه همبستگی داده‌ها منجر شده است [8] [10] [9]. با این حال، اکثر مطالعات قبلی به تأثیر کوتاه‌مدت مواد افزودنی پرداخته‌اند و پژوهش‌های کمتری به بررسی اثرات بلندمدت این مواد بر مقاومت فشاری بتن پرداخته‌اند [1]. یکی از چالش‌های کلیدی در این زمینه، پیش‌بینی دقیق مقاومت فشاری بتن در سنین بلندمدت است. کاهش مقاومت بتن در طولانی‌مدت می‌تواند منجر به افزایش نیاز به تقویت سازه و نگهداری مکرر شود که این مسئله هزینه‌های نگهداری و مصرف انرژی را افزایش می‌دهد. تحقیقات اخیر نشان داده‌اند که تکنیک‌های یادگیری ماشین می‌توانند دقت پیش‌بینی مقاومت فشاری بتن را به میزان قابل توجهی بهبود بخشند. جدول ۱ مدل‌های یادگیری ماشین استفاده‌شده در تحقیقات پیشین برای پیش‌بینی مقاومت فشاری بتن و تعداد نمونه‌های مرتبط با هر مدل را نشان می‌دهد. این جدول بر ضرورت استفاده از مدل‌های پیشرفته‌تر با قابلیت تحلیل داده‌های پیچیده‌تر و تعداد داده‌های بیشتر برای دستیابی به پیش‌بینی‌های دقیق‌تر تأکید دارد. به‌طور خاص، مدل‌های پیشرفته‌ای مانند NARX و RF که توانایی پردازش داده‌های بزرگ و پیچیده را دارند و در مطالعات قبلی جهت تخمین مقاومت فشاری بتن از آنها استفاده نشده است، می‌توانند نتایج دقیق‌تری ارائه دهند.

یکی از جنبه‌های نوآورانه این مطالعه، بررسی تأثیر ترکیب چند ماده افزودنی شیمیایی بر مقاومت فشاری بلندمدت بتن با استفاده از الگوریتم‌های پیشرفته یادگیری ماشین مانند NARX و RF است. برخلاف مطالعات پیشین که بیشتر بر سنین اولیه بتن تمرکز داشته‌اند، این تحقیق با تحلیل داده‌های آزمایشگاهی گسترده و استفاده از تکنیک‌های پیشرفته پیش‌پردازش داده مانند خوشه‌بندی K-means و تولید داده‌های مصنوعی، به بررسی مقاومت فشاری بتن در سنین یک و سه سال پرداخته است. این تحلیل جامع بر تعاملات پیچیده بین مواد افزودنی و اثرات ترکیبی آنها در دوره‌های زمانی بلندمدت متمرکز است و به‌عنوان یک رویکرد نوین ارائه شده است. همچنین، تأکید بر تعاملات پیچیده بین مواد افزودنی و اثرات ترکیبی آنها در دوره‌های بلندمدت، این تحقیق را از سایر مطالعات متمایز می‌کند.

این تحقیق به بررسی تأثیر ترکیب چندین ماده افزودنی شیمیایی بر مقاومت فشاری بلندمدت بتن در دوره‌های بلندمدت (۱ و ۳ سال) می‌پردازد. برخلاف پژوهش‌های پیشین که بر پیش‌بینی مقاومت فشاری بتن در سنین اولیه (۳، ۷، و ۲۸ روز) تمرکز داشته‌اند و اثرات ترکیب موارد افزودنی شیمیایی را هم در نظر نگرفته‌اند [12] [11]. استانداردهای

بین‌المللی معمولاً مقاومت فشاری ۲۸ روزه را مرجع طراحی سازه‌های بتنی می‌دانند [14] [13]، اما نتایج سن مقاومت فشاری بتن برای پیش‌بینی دوام و پایداری سازه‌ها در شرایط بلندمدت کافی نیست. Sarıdemir و همکاران، با استفاده از مدل‌های یادگیری ماشین، تأثیرات متقابل مواد افزودنی شیمیایی مانند پودر سنگ کوتاه (KSP)، نیترات کلسیم، و تری‌اتانول‌آمین بر مقاومت بتن بررسی نمودند. برخلاف مطالعاتی که تأثیر جداگانه مواد را تحلیل کرده‌اند، این تحقیق به ارزیابی اثرات ترکیبی پرداخته و نشان داده است که در برخی موارد، ترکیب مواد می‌تواند کیفیت بتن را کاهش دهد [15]، نتایج این مطالعه توسط Moradi و همکاران، نشان می‌دهد که تکنیک‌هایی مانند شبکه‌های عصبی مصنوعی (ANN) و سیستم‌های منطق فازی (FL) قابلیت بالایی در پیش‌بینی اثرات مواد افزودنی بر مقاومت فشاری بلندمدت بتن دارند [16]. این رویکردها امکان شبیه‌سازی دقیق‌تر رفتار بتن و کاهش هزینه‌های آزمایشگاهی را فراهم می‌کنند. یافته‌ها تأکید می‌کنند که تحلیل داده‌های بلندمدت برای بهینه‌سازی طراحی سازه‌های پایدار ضروری است. این تحقیق با ارائه ابزارهای پیشرفته یادگیری ماشین و تمرکز بر داده‌های طولانی‌مدت، گامی مؤثر در ارتقاء کیفیت بتن و بهبود طراحی سازه‌های بادوام برداشته است. تحقیقات Sarıdemir و Moradi و همکاران هرچند پیشرفت‌هایی در استفاده از الگوریتم‌های یادگیری ماشین ارائه داده‌اند، اما تمرکز آن‌ها بر سنین کوتاه‌مدت بتن و استفاده از داده‌های محدود بوده است. علاوه بر این، این مطالعات به اثرات ترکیبی مواد افزودنی بر مقاومت بلندمدت بتن نپرداخته‌اند [15][16].

در این تحقیق، از ۷۸۴۵ نمونه بتن استفاده شده است. پس از جمع‌آوری، داده‌ها پیش‌پردازش شده و خوشه‌بندی شدند [17][18] و داده‌های مصنوعی با استفاده از روش K-means تولید شدند. سپس داده‌ها به سه بخش تقسیم شدند: آزمون، آموزش، و اعتبارسنجی، و از اعتبارسنجی متقاطع ده‌گانه برای ارزیابی مدل استفاده شد. مدل‌های یادگیری ماشین، شامل NARX، SVR، RBF، MLP، DT و RF، برای تخمین مقاومت فشاری طولانی‌مدت بتن تا یک سال و سه سال به کار گرفته شدند. این روش در مقابل مطالعات مختلفی قرار دارد که تنها بر اثرات کوتاه‌مدت تمرکز دارند. استفاده از چندین ماده افزودنی شیمیایی در مخلوط بتن نیازمند پیروی از استانداردها و دستورالعمل‌های خاصی است. بیشتر استانداردهای بین‌المللی و محلی اجازه افزودن این مواد به بتن را می‌دهند. این استانداردها بر لزوم آزمایش‌های دقیق و ارزیابی تأثیرات تعاملات بین افزودنی‌ها تأکید می‌ورزند.

هدف نهایی این بود که مدل‌هایی برای پیش‌بینی دقیق و زود هنگام مقاومت فشاری طولانی‌مدت بتن ارائه دهد. نتایج این تحقیق می‌تواند به مهندسان و پژوهشگران در بهینه‌سازی نوع و ترکیب افزودنی‌ها برای دستیابی به خواص مکانیکی مطلوب بتن کمک کند. این یافته‌ها نشان می‌دهند چگونه ترکیب مناسب افزودنی‌ها می‌تواند به دوام و عملکرد سازه‌های بتنی آسیب برساند و نیاز به نگهداری و تعمیرات را افزایش دهد. علاوه بر این، با بازنگری در کدها و

استانداردهای طراحی، ساختمان‌هایی با دوام طولانی‌تر و تأثیرات زیست‌محیطی کمتر می‌توان به دست آورد. این تحقیق نه تنها به بهبود کیفیت بتن کمک می‌کند، بلکه در جلوگیری از مصرف بی‌رویه منابع طبیعی و حفاظت از محیط زیست نیز مؤثر است. ادامه این تحقیق به شرح زیر سازماندهی شده است: بخش ۲، روش‌شناسی تحقیق، روش‌های ارزیابی و رویکرد برای تنظیم مدل‌های پیشنهادی را توضیح می‌دهد. بخش ۳، مشخصات مواد را ارائه می‌دهد، در حالی که بخش ۴، توصیف داده‌ها را بحث می‌کند. بخش ۵، نتایج پیش‌بینی را بحث کرده و عملکرد مدل‌ها را مقایسه می‌کند، و بخش ۶ خلاصه‌ای از یافته‌ها را فراهم می‌کند.

جدول ۱: مقایسه انواع الگوریتم‌ها و تعداد نمونه‌های آزمایشگاهی در تخمین مقاومت فشاری بتن

ردیف	انواع الگوریتم‌های تکاملی در تعیین مقاومت- فشاری ANN بتن	تعداد نمونه‌ها	موضوع تحقیق	ردیف	الگوریتم به کار گرفته شده	تعداد نمونه‌ها	موضوع تحقیق
1	شبکه عصبی عمیق	335	بتن ژئوپلیمری	7	الگوریتم کرم شب تاب + RF	1030	بتن با کارایی بالا
2	دستگاه بولتزمن با عمق محدود	103	بتن با کارایی بالا	8	تابع هزینه آنتروپی متقاطع و DNN+	1133	فوم بتن
3	سیستم استنتاج شبکه عصبی فازی تطبیقی	1033	بتن با کارایی بالا	9	الگوریتم بهینه سازی گروه گریه SVM+	1761	بتن با کارایی بالا
4	ماشین یادگیری افراطی	1133	بتن با کارایی بالا	10	الگوریتم بهینه سازی گرگ خاکستری LSSVM+	150	فوم بتن
5	یادگیری شبکه عصبی تابع پایه شعاعی	37	بتن با کارایی بالا	11	الگوریتم کرم شب تاب + LSSVM	239	بتن با کارایی بالا
6	شبکه عصبی کانولوشنال	74	بتن سنگدانه باز یافتی	12	جستجوی شاخک سوسک + RF	138	بتن لاستیکی

این بخش الگوریتم‌های مورد استفاده در فرآیند مدل‌سازی برای پیش‌بینی مقاومت فشاری طولانی مدت بتن که شامل مواد افزودنی شیمیایی می‌شود را توضیح می‌دهد. در این تحقیق، مدل‌های مختلف از جمله خودرگرسیون غیرخطی با ورودی‌های بیرونی (NARX)، رگرسیون بردار پشتیبان (SVR)، تابع پایه شعاعی (RBF)، پرسپترون چندلایه (MLP)، درخت تصمیم‌گیری (DT) و جنگل تصادفی (RF) مورد استفاده قرار گرفته و مقایسه شدند.

داده‌های آزمایشی در مرحله اول از نتایج آزمایشگاهی جمع‌آوری شدند. این داده‌ها شامل مشخصات مواد مانند نسبت آب به سیمان، نوع سیمان، نوع و میزان سنگدانه‌ها، مواد افزودنی شیمیایی مانند فوق‌روان‌کننده، دیرگیرکننده و مواد هوازا، و همچنین شرایط آزمون شامل دما، رطوبت و مدت زمان عمل‌آوری بتن بودند. مقاومت فشاری بتن در سنین مختلف از جمله ۳ روزه، ۷ روزه، ۲۸ روزه، ۹۰ روزه و یک‌ساله به‌عنوان داده‌های ورودی ثبت شدند، در حالی که مقاومت فشاری سه‌ساله به‌عنوان متغیر خروجی در نظر گرفته شد.

در ادامه داده‌ها پیش‌پردازش شدند. در این مرحله ابتدا داده‌ها از نظر کیفیت بررسی شدند تا مقادیر گم‌شده و داده‌های پرت شناسایی و اصلاح شوند. برای بهبود عملکرد مدل‌های یادگیری ماشین، ویژگی‌های عددی نرمال‌سازی شدند تا در بازه‌ای مشخص قرار گیرند. پس از پیش‌پردازش اولیه، داده‌ها با استفاده از الگوریتم خوشه‌بندی K-means بر اساس ویژگی‌های مشترک گروه‌بندی شدند. تعداد خوشه‌ها با استفاده از روش‌های Elbow و Silhouette تعیین گردید تا داده‌ها به‌طور بهینه و بدون پیچیدگی اضافی خوشه‌بندی شوند. در نهایت، داده‌های مصنوعی بر اساس الگوهای استخراج‌شده از خوشه‌ها تولید شدند. در این مرحله سه سطح داده شامل ۱،۰۰۰، ۵،۰۰۰ و ۱۰،۰۰۰ نمونه انتخاب شدند [19]. تعداد بهینه داده‌ها برای هر سن مقاومت فشاری بتن، بر اساس معیارهای عملکردی مانند ضریب تعیین (R^2) و سایر شاخص‌های آماری تعیین شد.

پس از آماده‌سازی داده‌ها، مجموعه داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمایش تقسیم شدند. تقسیم‌بندی به‌صورت ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمایش انجام شد. فرآیند اعتبارسنجی متقاطع-k برابر ($k=10$) به‌منظور بهبود دقت مدل‌ها و جلوگیری از بیش‌برازش بر روی مجموعه داده‌های آموزش و اعتبارسنجی اعمال شد. مقاومت‌های ۳، ۷، ۲۸، ۹۰ روزه و یک‌ساله به‌عنوان ورودی‌های مدل در نظر گرفته شدند. عملکرد هر مدل با استفاده از معیارهایی شامل ضریب تعیین (R^2)، میانگین مربع خطای نرمال‌شده (NMSE) و میانگین خطای مطلق نرمال‌شده (NMAE) ارزیابی شد. در صورتی که مدل‌ها خطاهای قابل توجهی نشان دادند، فرآیند تنظیم پارامترها (مانند نرخ یادگیری، تعداد نرون‌ها و عمق درخت‌ها) تکرار شد تا مدل‌ها بهینه شوند.

این فرآیند امکان تحلیل دقیق‌تری از تغییرات زمانی مقاومت فشاری بتن، اثرات مواد افزودنی شیمیایی و عملکرد مدل‌های مختلف را فراهم آورد. همچنین، با مقایسه نتایج حاصل از مدل‌های مختلف، عواملی که بیشترین تأثیر را بر

پیش‌بینی مقاومت بتن داشتند، شناسایی شدند. داده‌های مورد استفاده در این تحقیق از پروژه‌های ساختمانی مختلف در ایران استخراج شده‌اند. جدول ۲ مشخصات طرح‌های اختلاط نهایی بتن را ارائه می‌دهد. این طرح‌ها شامل مواد اصلی بتن (سیمان، شن، ماسه، آب) و مواد افزودنی شیمیایی (فوق‌روان‌کننده، دیرگیرکننده، و مواد هوازا) هستند. هر ردیف نشان‌دهنده ترکیب یک طرح اختلاط است که مقادیر مواد بر حسب کیلوگرم در متر مکعب بتن تنظیم شده‌اند.

۳- مشخصات مواد

مواد مورد استفاده در بتن شامل سنگدانه‌ها (شن و ماسه)، سیمان، آب، و مواد افزودنی شیمیایی است [20]. سنگدانه‌ها، با حداکثر اندازه ذرات ۲۰ میلی‌متر (۴/۳ اینچ)، مطابق با الزامات درجه‌بندی اندازه سنگدانه درشت شماره ۶ هستند که در ASTM C33 مشخص شده است [21]. در طراحی مخلوط نهایی، سنگدانه درشت مورد استفاده شامل شن خرد شده (۵-۲۰ میلی‌متر) با حداکثر اندازه ذره ۲۰ میلی‌متر (۴/۳ اینچ) است که مطابق با درجه‌بندی سنگدانه درشت شماره ۶ ذکر شده در مشخصات ASTM C33 است. مخلوط بتن نهایی از ترکیب ۱:۱ شن طبیعی به عنوان سنگدانه ریز استفاده می‌کند. آب مورد استفاده در تولید و شکل‌گیری بتن قابل شرب بوده و فاقد هرگونه مواد مضر است، که آن را برای آماده‌سازی بتن مناسب می‌سازد. سیمان اصلی مورد استفاده، سیمان نوع II از کارخانه سیمان تهران است. بر اساس استانداردهای ایران، خواص شیمیایی و فیزیکی این سیمان ارائه شده است. به دلیل شرایط خاص پروژه‌های ساختمانی، مواد افزودنی شیمیایی در طراحی مخلوط بتن استفاده شده‌اند [22]. نمونه‌های بتن مطابق با استانداردهای ASTM C31 عمل‌آوری شده‌اند [23]. آن‌ها برای ۲۴ ساعت مرطوب نگه داشته شده، سپس تا سن آزمون در حمام آب با رطوبت ۱۰۰٪ قرار گرفته‌اند، و در نهایت برای آزمون‌های بتن سخت شده آماده شده‌اند.

جدول ۲: مشخصات طرح‌های اختلاط نهایی بتن

شماره طرح مخلوط	سیمان kg/m ³	W/C	فوق روان کننده kg/m ³	دیرگیرکننده kg/m ³	درصد هوازا kg/m ³	شن متوسط کاملاً خشک kg/m ³	ماسه مخلوط کاملاً خشک kg/m ³	مقاومت فشاری مشخصه kg/cm ²
MIX1	420	0/31	0/5	1	5	766	920	350
MIX2	400	0/32	1/1	1	6	763	915	340
MIX3	450	0/35	1/0	1	5/5	765	910	330
MIX4	400	0/4	0/8	0/8	4	760	880	315
MIX5	430	0/42	0/9	1	3	750	885	312
MIX6	380	0/42	0/9	1	3	740	880	315

۴- توصیف داده‌ها


۴-۱- جمع‌آوری داده‌ها

ایجاد یک مجموعه داده جامع و قابل اعتماد برای توسعه مدل‌های پیش‌بینی یادگیری ماشین (ML) حیاتی است. نمونه‌های داده استفاده شده شامل متغیرهایی برای ساخت مدل‌ها به منظور پیش‌بینی مقاومت فشاری بتن در سنین مختلف است، بر اساس چهار طرح مخلوط و ۷۸۴۵ نمونه که قصد استفاده آن‌ها در پروژه‌های عملی و آزمایشگاهی وجود دارد، این نمونه‌ها از پروژه‌های میدانی در ایران به دست آمده‌اند. درصد تعداد نمونه های بتن در طرح اختلاط های مختلف در شکل ۲ نمایش داده شده است.

۴-۲- پیش پردازش داده‌ها و تحلیل آماری داده‌ها

در اولین گام، داده‌ها پالایش شدند تا ناهنجاری‌ها و داده‌های پرت، همچنین موارد دارای مقادیر گم شده حذف شوند [17] [18]. در بخش پیش‌پردازش داده‌ها، داده‌های خام جمع‌آوری شده از منابع مختلف تحت فرایندهای مختلفی قرار گرفتند تا برای مدل‌سازی مناسب شوند. این فرآیند شامل پاک‌سازی داده‌ها برای حذف نویز و داده‌های ناقص، و همچنین نرمال‌سازی مقادیر عددی برای اطمینان از یکنواختی مقیاس داده‌ها بود. علاوه بر این، داده‌های کیفی به مقادیر عددی تبدیل شدند تا توسط مدل‌های یادگیری ماشین قابل پردازش باشند.

در مرحله بعد، داده‌ها با استفاده از الگوریتم خوشه‌بندی K-means به ۲۰ گروه مشابه تقسیم شدند. انتخاب تعداد ۲۰ خوشه بر اساس تحلیل ساختار داده‌ها و استفاده از روش Elbow انجام شد، که نشان داد این تعداد بهترین تعادل بین پیچیدگی و کیفیت خوشه‌بندی را فراهم می‌کند. این خوشه‌بندی کمک کرد تا داده‌های مصنوعی برای هر خوشه تولید شوند و کیفیت داده‌های ورودی برای مدل‌سازی بهینه شود. این مرحله برای کاهش خطاهای ناشی از داده‌های پرت و افزایش دقت مدل‌های پیش‌بینی طراحی شد. اثربخشی مدل توسط اجزاء و مقادیر آن تعیین می‌شود. جدول ۳ و شکل ۲ نشان می‌دهند که بیشتر نمونه‌ها توزیع نرمال دارند که با استانداردهای آماری برای مقاومت فشاری بتن مطابقت دارد.



شکل ۱: تعداد نمونه‌های واقعی آزمایشگاهی بتن در طرح‌های مخلوط مختلف

۳-۴- تقسیم داده‌ها و اعتبارسنجی متقاطع-K برابر

پس از به‌دست‌آوردن و پیش‌پردازش و تحلیل آماری داده‌ها، آنها به سه بخش تقسیم شد: مجموعه آموزشی، مجموعه اعتبارسنجی، و مجموعه آزمایشی، با نسبت ۷۰٪ - ۱۵٪ - ۱۵٪ [24]. برای کاهش خطاهای نمونه‌گیری تصادفی و اطمینان از نمایندگی مناسب داده‌ها، محققان از اعتبارسنجی متقاطع-K برابر استفاده کردند. در این تحقیق، مقدار K برابر با ۱۰ انتخاب شد، زیرا مطالعات قبلی نشان داده‌اند که این مقدار بهترین تعادل بین دقت مدل و زمان محاسباتی را ارائه می‌دهد [25] [24]. در هر تکرار، یک زیرمجموعه به عنوان مجموعه آزمایشی و زیرمجموعه‌های باقی‌مانده برای آموزش استفاده می‌شوند. این فرآیند K بار تکرار می‌شود تا هر زیرمجموعه یک بار به عنوان مجموعه آزمایشی و K-1 بار به عنوان مجموعه آموزشی استفاده شود. این روش دقت و قابلیت تعمیم مدل را ارزیابی می‌کند و از بیش‌برازش جلوگیری می‌کند [24]. مزایای استفاده از اعتبارسنجی متقاطع-K برابر شامل کاهش سوگیری نمونه‌گیری تصادفی، بهبود تعمیم‌پذیری مدل، و ارائه ارزیابی قابل‌اعتمادتر از عملکرد مدل است [26] [24]. در این تحقیق، از اعتبارسنجی متقاطع ده‌برابر استفاده شد که در آن مجموعه داده به ده زیرمجموعه تقسیم می‌شود و هر زیرمجموعه یک بار به عنوان داده آزمایشی و نه بار به عنوان داده آموزشی استفاده می‌شود [26] [24]. دقت الگوریتم محاسبه و به‌عنوان میانگین دقت به‌دست‌آمده از ده مدل در ده دوره اعتبارسنجی گزارش می‌شود، که ارزیابی مدل را دقیق و قابل‌اعتماد کرده و عملکرد آن را در شرایط مختلف داده ارزیابی می‌کند [27].

MIX-1							MIX-2						
Age	Mean	Std	Min	Max	Standard error	Mode	Mean	Std	Min	Max	Standard error	Mode	
3Day	292	54	140	402	0.54	302	265	49	65	503	0.49	65	
7Day	385	41	295	462	0.41	361	349	37	224	540	0.37	224	
28Day	476	41	359	536	0.41	531	432	37	286	583	0.37	286	
90Day	578	72	449	720	0.72	583	525	66	306	772	0.66	306	
1 Year	542	55	425	665	0.55	567	491	50	304	686	0.5	304	
3 Year	499	47	407	608	0.47	507	452	43	286	630	0.43	286	
MIX-3							MIX-4						
Age	Mean	Std	Min	Max	Standard error	Mode	Mean	Std	Min	Max	Standard error	Mode	
3Day	260	35	153	376	0.35	153	189	35	61	318	0.35	61	
7Day	343	39	242	442	0.39	242	250	26	153	354	0.26	153	
28Day	425	46	322	526	0.46	322	309	26	216	404	0.26	216	
90Day	515	61	345	675	0.61	345	375	46	171	536	0.46	171	
1 Year	483	54	347	621	0.54	347	351	36	205	479	0.36	205	
3 Year	444	49	330	585	0.49	330	323	31	210	439	0.31	210	
MIX-۵							MIX-۶						
Age	Mean	Std	Min	Max	Standard error	Mode	Mean	Std	Min	Max	Standard error	Mode	
3Day	168	18	61	212	0/18	61	167	31	50	284	0/31	50	
7Day	229	12	153	261	0/12	153	220	23	129	310	0/23	129	
28Day	286	11	216	319	0/11	216	272	23	174	360	0/23	174	
90Day	342	22	171	401	0/22	171	331	41	184	488	0/41	184	
1 Year	323	16	205	371	0/16	205	310	32	190	421	0/32	190	

۴-۴- توصیف روش‌های یادگیری ماشین انتخاب‌شده برای تحقیق

این بخش به توضیح الگوریتم‌های استفاده‌شده در مدل‌سازی برای پیش‌بینی مقاومت فشاری بتن بر اساس ترکیبات افزودنی‌ها می‌پردازد [28] برای پیاده‌سازی مدل‌ها از نرم‌افزارهای Matlab و Anaconda استفاده شد [30] [29]. الگوریتم‌های استفاده‌شده در این تحقیق عبارت‌اند از، خود رگرسیون غیرخطی با ورودی‌های بیرونی (NARX^۱).

^۱ Nonlinear Autoregressive Exogenous Model

رگرسیون بردار پشتیبان (SVR^1)، تابع پایه شعاعی (RBF^2)، پرسپترون چندلایه (MLP^3)، درخت تصمیم‌گیری (DT^4) و جنگل تصادفی (RF^5) . جدول ۴ مشخصات مدل‌های مختلف یادگیری ماشین مورد استفاده در این تحقیق را نشان می‌دهد. این الگوریتم‌ها به دلیل توانایی بالای آن‌ها در تحلیل داده‌های غیرخطی و مدل‌سازی سیستم‌های پیچیده انتخاب شده‌اند، به‌ویژه NARX که برای پیش‌بینی‌های زمانی مناسب است و RF که دقت بالایی در مدیریت داده‌های بزرگ دارد. جدول ۴ مشخصات مدل‌های مختلف یادگیری ماشین مورد استفاده در این تحقیق را نشان می‌دهد.


^۱ Support Vector Regression

^۲ Radial Basis Function

^۳ Multilayer Perceptron

^۴ Decision Tree

^۵ Random Forest




شکل ۲: مقایسه‌ی تطابق توزیع‌ها برای مقاومت فشاری بتن در بازه‌های زمانی مختلف

۴-۵- روش‌های ارزیابی عملکرد

برای ارزیابی دقت مدل‌های استفاده شده، معیارهای به کار رفته شامل ضریب تعیین (R^2)، خطای میانگین مربعات نرمال شده (NMSE)، خطای مطلق میانگین نرمال شده (NMAE)، و خطای میانگین ریشه مربعات نرمال شده (NRMSE) هستند. معادلات مربوط به این معیارها در شکل ۳ نشان داده شده‌اند. استفاده از نسخه‌های نرمال شده این معیارها به تنظیم مقادیر خطا نسبت به مقیاس داده کمک می‌کند و مقایسه بین مدل‌ها را آسان‌تر و دقیق‌تر می‌سازد.

در فرمول‌های ارائه شده در شکل ۳، n نشان‌دهنده تعداد کل نمونه‌ها، y_i مقدار واقعی، میانگین مقادیر واقعی و $\bar{y}$ مقدار میانگین مقادیر واقعی را نشان می‌دهد و $\hat{y}_i$ مقدار پیش‌بینی شده را نشان می‌دهد



شکل ۳: روش‌های ارزیابی عملکرد مدل‌های یادگیری ماشین

۴-۶- مدل‌های بکار رفته در تحقیق

هدف از استفاده از مدل‌های یادگیری ماشین در این تحقیق، ارائه پیش‌بینی دقیق و قابل اعتماد مقاومت فشاری بتن در سنین بلندمدت است. مدل‌های مختلف به دلیل توانایی‌های منحصربه‌فرد خود در تحلیل روابط پیچیده، مدیریت داده‌های نویزی، و مدل‌سازی غیرخطی انتخاب شده‌اند. در ادامه، ویژگی‌ها و عملکرد هر مدل بررسی می‌شود. مدل‌های استفاده شده در این تحقیق شامل شبکه عصبی بازگشتی با ورودی‌های برون‌زا (NARX)، شبکه عصبی با تابع پایه شعاعی (RBF)، پرسپترون چندلایه (MLP)، جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVR) و درخت تصمیم (DT) بوده‌اند. هر یک از این مدل‌ها به دلیل قابلیت‌ها و ویژگی‌های منحصربه‌فرد خود برای پیش‌بینی مقاومت فشاری بتن انتخاب شدند. شبکه NARX به دلیل توانایی بالا در مدل‌سازی روابط پیچیده و استفاده از طراحی حلقه باز و حلقه بسته برای کاهش خطاهای تجمعی، عملکرد برجسته‌ای در پیش‌بینی سری‌های زمانی بلندمدت داشته است. این مدل با استفاده از مقادیر پیش‌بینی شده به جای مقادیر واقعی در طراحی حلقه بسته، دقت پیش‌بینی‌ها را بهبود می‌بخشد. شبکه RBF با معماری ساده خود و استفاده از توابع پایه شعاعی در لایه پنهان، عملکرد مناسبی در تقریب توابع و پیش‌بینی

سری های زمانی از خود نشان داده است. این مدل از الگوریتم K-means برای انتخاب مراکز توابع پایه شعاعی استفاده کرده که باعث افزایش کارایی در تحلیل داده ها شده است. پرسپترون چندلایه (MLP) با ساختار غیرخطی و لایه های متعدد، قادر به یادگیری الگوهای پیچیده بوده و با تنظیم صحیح هایپرپارامترها، توانسته است دقت بالایی را در پیش بینی مقاومت فشاری بتن به دست آورد. مدل جنگل تصادفی (RF) با استفاده از تکنیک بگینگ و انتخاب تصادفی ویژگی ها، تنوع بیشتری در درخت های تصمیم ایجاد کرده و با کاهش واریانس و جلوگیری از بیش برآزش، به عملکرد بهینه دست یافته است. این مدل همچنین قادر به محاسبه اهمیت ویژگی ها بوده که تحلیل تأثیر متغیرهای مختلف را تسهیل کرده است.

ماشین بردار پشتیبان (SVR) با استفاده از توابع کرنل متنوع، مرزهای تصمیم گیری دقیقی برای پیش بینی مقاومت فشاری بتن ارائه کرده است. با این حال، حساسیت این مدل به انتخاب پارامترهای کرنل و جریمه (C) نیازمند تنظیم دقیق این پارامترها برای دستیابی به بهترین عملکرد بوده است. درخت تصمیم (DT) با ساختار ساده و تفسیرپذیر خود، به عنوان ابزاری مناسب برای تحلیل روابط سلسله مراتبی بین متغیرها به کار گرفته شد. با این حال، این مدل به دلیل حساسیت به نوفه در داده ها، ممکن است در برخی موارد دچار بیش برآزش شود. هر یک از مدل های مذکور با تنظیم هایپرپارامترهای کلیدی از جمله تعداد لایه های پنهان، نرخ یادگیری، تعداد درخت ها و کرنل های مورد استفاده بهینه سازی شدند. این تنظیمات منجر به بهبود دقت پیش بینی ها و کاهش خطاها در تمامی مدل ها شد. استفاده از این مدل ها و تنظیمات به عنوان بخشی از این تحقیق، توانست بینش های ارزشمندی را درباره رفتار بلندمدت بتن فراهم کرده و دقت پیش بینی مقاومت فشاری را بهبود بخشد. جدول ۴ مشخصات مدل های مختلف یادگیری ماشین ارائه شده است.

جدول ۴: مشخصات مدل های مختلف یادگیری ماشین

پارامترها	معماری مدل	کاربرد	تابع هدف	هدف	نام مدل
$C=1.0$ ، $\epsilon=0.1$	استفاده از بردارهای پشتیبان با هسته گوسی (RBF)	پیش بینی مقادیر واقعی مانند قیمت سهام، دما، فروش، تخمین مقاومت فشاری بتن	مینیمم سازی خطاهای رگرسیونی در حالیکه مقادیر خطاهای کمتر از را نادیده می گیرد	تخمین مقدار متغیر وابسته	(SVR)
تعداد تاخیرها $n=10$ ، $m=5$	شبکه های عصبی با دو لایه پنهان	پیش بینی سری های زمانی مانند ترافیک، تخمین مقاومت فشاری بتن	مینیمم سازی خطای پیش بینی	مدل سازی غیرخطی و پیش بینی سری های زمانی	(NARX)
تعداد توابع پایه $N=50$ ،	شبکه های عصبی با ۵۰ تابع پایه شعاعی	طبقه بندی، رگرسیون، تقریب توابع، تخمین مقاومت فشاری بتن	مینیمم سازی خطاهای رگرسیونی یا طبقه بندی		(RBF)

	مدل سازی غیر خطی و پیش بینی				k- means ، وزن ها روش کمترین مربعات
(RF)	بهبود دقت پیش بینی از طریق ترکیب چندین درخت تصمیم	کاهش خطای تعمیم از طریق تجمیع چندین درخت تصمیم	طبقه بندی تصاویر، تشخیص تقلب، تحلیل داده های بزرگ، تخمین مقاومت فشاری بتن	مجموعه ای از ۱۰۰ درخت تصمیم	تعداد درخت ها n=100 ، عمق درخت ها حداکثر ۱۰، تعداد ویژگی ها $\sqrt{p}$
(MLP)	یادگیری نگاشت غیر خطی بین ورودی ها و خروجی ها	مینیم سازی خطای شبکه عصبی	تشخیص الگوها، تحلیل داده ها، پیش بینی، تخمین مقاومت فشاری بتن	شبکه عصبی چند لایه با دو لایه پنهان	تعداد لایه های پنهان = ۲، تعداد نورون ها در هر لایه = ۶۴، نوع تابع فعال سازی = ReLU
(DT)	ایجاد مدل ساده و قابل تفسیر برای تصمیم گیری	کاهش خطای تصمیم گیری با پیشینه سازی اطلاعات	تحلیل تصمیمات، تشخیص بیماری تخمین مقاومت فشاری بتن	ساختار درختی با گره های تصمیم و برگ ها	عمق درخت حداکثر ۵، معیار تقسیم GINI


۵- نتایج و بحث

۵-۱- نتایج

در این بخش، ابتدا تعداد مورد نیاز داده های مصنوعی و مدل های پیش بینی مقاومت فشاری بررسی شد. سپس، بر اساس نتایج معیارهای اعتبارسنجی، مدل مناسب انتخاب شد. تغییرات طولانی مدت مقاومت فشاری بتن تحت شرایط استفاده از ترکیبات شیمیایی مختلف مورد بررسی و تحلیل قرار گرفت.

۵-۱-۱- تعداد داده‌های مصنوعی

معیارهای ارزیابی R^2 برای تعداد داده‌های مصنوعی تولیدشده در تمام سطوح در شکل ۴ ارائه شده است. تمام مدل‌ها بهترین عملکرد خود را در سطح ۵,۰۰۰ داده نشان دادند. تحلیل‌ها نشان می‌دهند که با افزایش تعداد داده‌ها تا ۵۰۰۰ داده برای هر سن بتن (سه روزه تا سه ساله)، دقت پیش‌بینی مدل‌ها در مقایسه با داده‌های اولیه آزمایشگاهی بهبود یافته است. لذا در این حقیق از سطوح این تعداد نمونه بتن برای هر سن استفاده شده است.



شکل ۴: نتایج شاخص برای سطوح داده‌های آزمون (۱,۰۰۰، ۵,۰۰۰ و ۱۰,۰۰۰) برای چهار مخلوط و شش مدل R^2

۵-۱-۲- تنظیمات اعتبارسنجی متقاطع K-برابر

معیارهای عملکرد R^2 , NMAE, NMSE, NRMSE برای مدل‌های پیشنهادی که با استفاده از روش اعتبارسنجی متقاطع K-برابر آموزش دیده‌اند، در شکل ۵ ارائه شده است. شکل ۵ نشان‌دهنده عملکرد مدل‌ها در شش طرح اختلاط Mix-1 تا Mix-6 است و تفاوت‌های میان مقادیر شاخص‌های آماری را برای هر مدل مشخص می‌کند. نتایج


نشان می‌دهند که استفاده از روش K-fold cross-validation باعث افزایش دقت ارزیابی مدل‌ها و ارائه نتایج قابل اعتمادتر می‌شود. این روش امکان بررسی جامع عملکرد مدل‌ها را فراهم کرده و از خطاهای ناشی از تقسیم تصادفی داده‌ها جلوگیری می‌کند. الگوریتم NARX در تمامی طرح‌های اختلاط با مقدار بالای R^2 و مقادیر کم NMAE، NMSE، NRMSE عملکرد برتری داشته است.

در شکل‌های مربوط به Mix-1 تا Mix-6، مشاهده می‌شود که مدل‌های RF و RBF نیز نتایج قابل قبولی ارائه کرده‌اند، اما مدل‌های SVR و MLP دارای مقادیر بالاتری از خطا هستند که دقت پایین آن‌ها را نشان می‌دهد. این اختلاف‌ها نشان‌دهنده حساسیت این مدل‌ها به پیچیدگی داده‌ها و تنظیمات پارامترها است. به‌طور کلی، الگوریتم NARX با مقادیر کم خطا و ضریب تعیین بالا در تمام طرح‌ها بهترین عملکرد را ارائه داده است. استفاده از این الگوریتم به دلیل توانایی آن در تحلیل داده‌های پیچیده و حفظ حافظه بلندمدت توصیه می‌شود.

۵-۱-۳- نتایج مدل پیش‌بینی

خلاصه‌ای از نتایج عملکرد مدل‌های مختلف در جدول ۵ و شکل ۶ ارائه شده است و بهترین مدل که بالاترین دقت و کمترین خطا را دارد، شناسایی شده است. در شکل ۷، تغییرات متوسط مقاومت فشاری برای چهار طرح اختلاط بتن مختلف Mix-1 تا Mix-6 در دوره‌های زمانی مختلف (از ۳ روز تا ۳ سال) نشان داده شده است. همه طرح‌ها افزایش مقاومت فشاری را از روزهای اولیه تا ۹۰ روز نشان می‌دهند. پس از ۹۰ روز، روند کاهشی در مقاومت فشاری مشاهده شده است، که بر اهمیت پیش‌بینی مقاومت بلندمدت بتن در طراحی سازه تأکید می‌کند.

یکی از اهداف اصلی این تحقیق پیش‌بینی کاهش مقاومت فشاری زمانی است که افزودنی‌های شیمیایی خاصی به مخلوط بتن اضافه می‌شوند. این موضوع می‌تواند منجر به کاهش عمر مفید و دوام سازه‌های بتنی شده و نیاز به تعمیرات و نگهداری زودهنگام را افزایش دهد. برای تخمین مقاومت فشاری در مدل‌های مختلف، داده‌های مربوط به سنین مختلف (۳ روز، ۷ روز، ۲۸ روز، ۹۰ روز، و ۱ سال) به‌عنوان ورودی استفاده شد و مقاومت ۳ ساله به‌عنوان خروجی مدل در نظر گرفته شد. نتایج نشان داد که استفاده از داده‌های مصنوعی برای آموزش مدل‌های یادگیری ماشین دقت پیش‌بینی را در مقایسه با داده‌های آزمایشگاهی بهبود داده است. مدل NARX با ضریب تعیین بالای ۰.۹۹ و کمترین خطاهای NMAE و NRMSE، بهترین عملکرد را در پیش‌بینی مقاومت فشاری بتن نشان داد.



شکل ۵: شاخص‌های آماری برای اعتبارسنجی متقاطع K-برابر برای مدل‌های مختلف و انواع مخلوط‌ها

۵-۲-۲- مقایسه عملکرد مدل‌ها

جدول ارائه شده عملکرد مدل‌های مختلف یادگیری ماشین را برای پیش‌بینی مقاومت فشاری بتن در شش طرح اختلاط Mix-1 تا Mix-6 مقایسه می‌کند. مدل NARX در تمامی طرح‌های اختلاط عملکرد برتری از خود نشان داد. بالاترین مقدار R^2 مربوط به Mix-2 با مقدار ۰,۹۹۹۲ است که نشان‌دهنده دقت بسیار بالا در پیش‌بینی مقاومت فشاری بتن است. این مدل در تمامی طرح‌ها مقدار NRMSE و NMAE پایینی دارد که بیانگر خطای کم در پیش‌بینی‌ها است. توانایی حفظ حافظه بلندمدت و تحلیل سری‌های زمانی، باعث شده NARX در پیش‌بینی مقاومت فشاری در سنین مختلف بتن بهترین عملکرد را داشته باشد. مدل RF نیز دقت بالایی داشته و مقدار R^2 آن در Mix-1 و Mix-


به ترتیب ۰,۹۸۰۸ و ۰,۹۸۸۴ است. این مدل عملکردی نزدیک به NARX ارائه کرده و توانایی مناسبی در تحلیل داده‌های نویزی و پیچیده دارد.

مدل‌های RBF و DT در مقایسه با NARX و RF دقت کمتری نشان دادند، اما همچنان مقادیر R^2 قابل قبولی دارند. برای مثال، مدل RBF در Mix-1 مقدار R^2 برابر با ۰,۹۷۰۳ و مدل DT مقدار ۰,۹۶۷۱ را ثبت کرده‌اند. این مدل‌ها برای داده‌هایی با پیچیدگی کمتر و سری‌های زمانی کوتاه‌تر مناسب هستند، اما در پیش‌بینی بلندمدت محدودیت‌هایی دارند. مدل‌های MLP و SVR ضعیف‌ترین عملکرد را در میان تمامی مدل‌ها داشتند. برای مثال، مقدار R^2 مدل SVR در Mix-3 برابر با ۰,۷۰۳۰ و در Mix-6 برابر با ۰,۷۰۳۱ است که نشان‌دهنده خطای بالا در پیش‌بینی است. مدل MLP نیز در Mix-4 با مقدار R^2 برابر ۰,۶۳۰۲ عملکرد نامناسبی ارائه داده است. این مدل‌ها به تنظیمات دقیق پارامترها و مجموعه داده‌های ساده‌تر نیاز دارند. به دلیل پیچیدگی داده‌های بتن، این مدل‌ها نمی‌توانند رفتارهای غیرخطی و بلندمدت را به خوبی تحلیل کنند.


مدل NARX به دلیل دقت بالا و خطای کم، بهترین مدل برای پیش‌بینی مقاومت فشاری بتن است. مدل RF نیز به دلیل توانایی مدیریت داده‌های پیچیده و عملکرد پایدار، گزینه‌ای قابل اعتماد محسوب می‌شود. مدل‌های RBF و DT در شرایط ساده‌تر قابل اعتماد هستند. اما مدل‌های MLP و SVR برای داده‌های پیچیده و بزرگ مناسب نیستند. این تحلیل نشان می‌دهد که انتخاب مدل مناسب به پیچیدگی داده‌ها و نوع پیش‌بینی بستگی دارد. برای کاربردهای مهندسی با داده‌های پیچیده، استفاده از مدل‌های پیشرفته مانند NARX و RF توصیه می‌شود [31]. مدل NARX به دلیل قابلیت شبیه‌سازی روابط غیرخطی و تحلیل دقیق سری‌های زمانی به عنوان یکی از مدل‌های اصلی این تحقیق انتخاب شد. این مدل با طراحی خاص خود (حلقه باز و حلقه بسته) توانسته است در پیش‌بینی مقاومت فشاری بتن در دوره‌های بلندمدت (یک سال و سه سال) عملکرد برتری از خود نشان دهد. در مقایسه با سایر مدل‌ها، مدل RF نزدیک‌ترین عملکرد را به NARX داشته است. مدل‌های RBF و DT در تحلیل داده‌های ساده‌تر قابل اعتماد بودند اما در پیش‌بینی بلندمدت محدودیت داشتند. مدل‌های SVR و MLP به دلیل محدودیت در شبیه‌سازی رفتارهای پیچیده و حساسیت به تنظیم پارامترها، نتایج ضعیف‌تری ارائه دادند. نتایج تحقیق نشان داد که مدل NARX با ضریب تعیین بالاتر از ۰,۹۹ و خطاهای کم NMAE و NRMSE بهترین گزینه برای پیش‌بینی بلندمدت مقاومت بتن است. مطالعات کمی به برآورد مقاومت فشاری در بتن حاوی مواد افزودنی شیمیایی متعدد در سنین بلندمدت پرداخته‌اند [1] [32]. یک تحقیق [33] اثرات طولانی مدت (تا ۳۶۵ روز) ترکیب مواد افزودنی شیمیایی و معدنی در بتن را بررسی کرد. یافته‌های این تحقیق به خوبی با نتایج تحقیق حاضر همخوانی دارد که باعث کاهش مقاومت بتن تا یک سال می‌شود. با این حال، تحقیقاتی در مورد سنین بیش از یک سال انجام نشده است.

جدول ۵: خلاصه ای از نتایج عملکرد مدل های مختلف (داده های آزمون)

Mix-1					Mix-2				
مدل	R ²	NMSE	NMAE	NRMSE	مدل	R ²	NMSE	NMAE	NRMSE
NARX	0/9946	17/89	1/54	7/60	NARX	0/9992	7/62	0/61	6/96
RBF	0/9703	72	6/10	18	RBF	0/9656	38	5/30	8/21
DT	0/9671	86/96	9/02	10/39	DT	0/9797	67/95	6/71	8/21
RF	0/9808	72/41	5/87	8/30	RF	0/9884	38/42	5/27	6/18
MLP	0/8198	138/17	17/14	25/40	MLP	0/8022	153/75	31/65	44/91
SVR	0/6899	173/90	22/79	34/01	SVR	0/6912	186/66	27/07	39/14
Mix-3					Mix-4				
NARX	0/9970	17/30	2/54	5/74	NARX	0.9932	21.55	2.46	6.73
RBF	0/9711	40	7/01	8/76	RBF	0.9501	66.79	6.63	10.09
DT	0/9764	70/94	6/97	8/52	DT	0.9030	171.93	7.82	12.
RF	0/9869	40/11	5/36	6/32	RF	0.9810	65.42	5.97	8.08
MLP	0/6827	161/72	23/19	32/24	MLP	0.8213	132.88	19.73	24.19
SVR	0/7030	191/51	31/88	48/78	SVR	0.7056	249.66	19.77	31.40
Mix-5					Mix-6				
NARX	0/9953	17/56	2/29	6/38	NARX	0/9922	17/56	2/21	6/38
RBF	0/9733	40/90	5/40	17/06	RBF	0/9688	35	5/90	10/53
DT	0/9788	72/75	6/93	8/46	DT	0/9694	72/79	6/88	8/38
RF	0/9880	40/89	5/42	6/43	RF	0/9822	41/26	5/32	6/55
MLP	0/8921	96/39	14/85	18/63	MLP	0/6302	188/39	31/27	45/15
SVR	0/6849	108/56	23/60	32/91	SVR	0/7102	162/86	27/21	40/27



شکل ۶: مقایسه مقادیر R² برای مدل های مختلف و همه مخلوط ها



شکل ۷: وضعیت میانگین مقاومت فشاری طرح‌های مختلف مخلوط بتن در سنین مختلف

نتایج به دست آمده به خوبی با نتایج پژوهش حاضر همخوانی دارد، که کاهش مقاومت بتن را تا یک سال نشان می‌دهد. با این حال، تحقیقاتی برای بررسی سنین بیش از یک سال انجام نشده است. کاهش طولانی مدت مقاومت بتن به عواملی مانند محیط‌های مخرب، اثرات خستگی، و بارگذاری‌های خاص مرتبط است که در برخی تحقیقات مورد بررسی قرار گرفته‌اند [2]. با این حال، کاهش طولانی مدت مقاومت بتن به دلیل اثرات ترکیب‌های شیمیایی مختلف هنوز مورد تحقیق قرار نگرفته است. بنابراین، این تحقیق نیاز به بررسی کاهش مقاومت فشاری و اثرات آن را به عنوان یک شکاف تحقیقاتی مهم شناسایی کرده است.

مطالعات قبلی [19][9] با چالش‌هایی مانند کمبود داده‌ها برای تخمین مقاومت فشاری بتن حاوی ترکیبی از چندین افزودنی شیمیایی، از جمله فوق‌روان‌کننده‌ها، کندگیرکننده‌ها، و عوامل حباب‌زا مواجه شده‌اند. این تحقیق نشان داده است که تولید داده‌های مصنوعی و استفاده از فناوری‌های هوش مصنوعی در تخمین مقاومت فشاری بتن با استفاده از مدل‌های مختلف می‌تواند هزینه‌ها، زمان، و مصرف منابع را کاهش دهد. استفاده از الگوریتم خاص NARX نسبت به مدل‌های مورد استفاده در تحقیقات پیشین مزیت جدیدی ارائه می‌دهد.

برای اطمینان از دقت و قابلیت تعمیم مدل‌های مورد استفاده در این تحقیق در مقایسه با تحقیقات قبلی، علیرغم کمبود تاریخی مطالعات، تلاش‌هایی برای اعتبارسنجی مدل با استفاده از داده‌های تحقیق انجام شده توسط [27] صورت

گرفت. نتایج نشان می‌دهند که مدل‌های استفاده شده در این تحقیق، با بهره‌گیری از داده‌های تحقیق [27]، قابلیت پیش‌بینی قوی‌ای برای مقاومت فشاری بتن دارند و ضریب تعیین (R^2) متوسطی برابر با ۰,۹۲ را به دست آورده‌اند. مطالعات کمی به بررسی اثر ترکیبات افزودنی شیمیایی در بتن در سنین بلندمدت پرداخته‌اند. این تحقیق تلاش کرده تا این شکاف علمی را با استفاده از مدل‌های یادگیری ماشین و تحلیل دقیق داده‌ها پر کند. با این حال، موضوعاتی مانند تأثیر خزش و افت بتن هنوز به‌طور جداگانه بررسی نشده‌اند و می‌توانند به عنوان محورهای تحقیقات آینده در نظر گرفته شوند. نویسندگان برنامه دارند تا در پژوهش‌های آتی، تأثیر ترکیبات افزودنی بر سایر خواص مکانیکی بتن و پیش‌بینی مقاومت فشاری برای دوره‌های پنج و ده ساله را بررسی کنند.

۶- نتیجه‌گیری

تحقیقات قبلی هنوز به بررسی تخمین مقاومت فشاری بتن با استفاده از الگوریتم‌های یادگیری ماشین همراه با افزودنی‌های شیمیایی مانند فوق روان‌کننده‌ها، کندگیرکننده‌ها، و عوامل حباب‌زا نپرداخته است. این تحقیق تأثیر این افزودنی‌ها بر مقاومت فشاری در سنین مختلف بتن (سه روز تا سه سال) را بررسی کرده و با استفاده از روش خوشه‌بندی K-means، ۵۰۰۰ داده مصنوعی برای هر گروه سنی تولید کرده است تا دقت مدل‌ها افزایش یابد. الگوریتم‌های یادگیری ماشین شامل شبکه عصبی بازگشتی NARX، تابع پایه شعاعی (RBF)، درخت تصمیم‌گیری (DT)، جنگل تصادفی (RF)، پرسپترون چندلایه (MLP) و رگرسیون بردار پشتیبان (SVR) برای پیش‌بینی مقاومت فشاری بتن به کار گرفته شدند. فرآیند اعتبارسنجی متقاطع K-fold نشان داد که الگوریتم NARX با میانگین R^2 برابر با ۰,۹۹۶۸ عملکرد برتری نسبت به سایر مدل‌ها ارائه کرده است.

در مقایسه با سایر مدل‌ها، الگوریتم NARX دقت بالاتری را نشان داد و مقادیر کمتر NMSE، NMAE، NRMSE دقت بالای آن را تأیید کردند. مدل‌های RF و RBF نیز نتایج قابل قبولی داشتند، اما الگوریتم‌های SVR و MLP عملکرد ضعیف‌تری نشان دادند. عملکرد ضعیف این مدل‌ها ممکن است به دلیل حساسیت بالای آن‌ها به تنظیمات پارامترها و پیچیدگی غیرخطی داده‌ها باشد. تحقیق حاضر تأیید کرد که استفاده از الگوریتم‌های پیشرفته یادگیری ماشین نظیر NARX می‌تواند پیش‌بینی مقاومت فشاری بتن را با دقت بسیار بالا امکان‌پذیر سازد. علاوه بر این، یافته‌های این تحقیق نیاز به بازنگری در پارامترهای طراحی بتن را برای دوره‌های بلندمدت برجسته می‌سازد، که می‌تواند به بهبود عمر مفید سازه‌های بتنی و دوام آن‌ها کمک کند. یکی از یافته‌های کلیدی این پژوهش، نیاز به بازنگری در برخی از پارامترهای کدهای طراحی سازه‌های بتنی به دلیل کاهش مقاومت فشاری طولانی مدت (در یک و سه سال)

در بتن‌های دارای ترکیبات افزودنی شیمیایی را برجسته می‌کند. به‌روزرسانی این پارامترها می‌تواند به مهندسان در طراحی سازه‌هایی با عمر طولانی‌تر و عملکرد بهتر کمک کند.

این تحقیق نشان داد که تکنیک‌های یادگیری ماشین، از طریق انتخاب بهتر پارامترهای ورودی و الگوریتم‌ها، می‌توانند پیش‌بینی‌های دقیق‌تری را ارائه دهند. در کارهای آینده، برای افزایش قابلیت اطمینان، دوزهای بهینه افزودنی‌ها در طرح‌های جدید بررسی خواهند شد. علاوه بر این، تحلیل سایر خواص مکانیکی بتن و پیش‌بینی مقاومت فشاری بتن برای دوره‌های پنج و ده ساله مورد بررسی قرار خواهد گرفت. این توسعه‌ها به منظور بهبود درک تأثیرات افزودنی‌ها و افزایش دقت مدل‌های پیش‌بینی در مهندسی مواد انجام می‌شوند.

منابع

- [1] K. Bedada, A. Nyabuto, I. Kinoti, and J. Marangu, "Review on advances in bio-based admixtures for concrete," *J. Sustain. Constr. Mater. Technol.*, vol. 8, no. 4, pp. 344–367, 2023.
- [2] A. Harapin, M. Jurišić, N. Bebek, and M. Sunara, "Long-Term Effects in Structures: Background and Recent Developments," *Applied Sciences (Switzerland)*, vol. 14, no. 6. Multidisciplinary Digital Publishing Institute (MDPI), 2024. doi: 10.3390/app14062352.
- [3] M. R. Garcez, A. B. Rohden, and L. G. G. de Godoy, "The role of concrete compressive strength on the service life and life cycle of a RC structure: Case study," *J. Clean. Prod.*, vol. 172, pp. 27–38, 2018, doi: 10.1016/j.jclepro.2017.10.153.
- [4] M. Husem and S. Gozutok, "The effects of low temperature curing on the compressive strength of ordinary and high performance concrete," *Constr. Build. Mater.*, vol. 19, no. 1, pp. 49–53, Feb. 2005, doi: 10.1016/j.conbuildmat.2004.04.033.
- [5] J. Bashir, S. A. Rather, F. A. Laherwal, and V. Garg, "IMPACT OF COLD WEATHER ON WORKABILITY, COMPRESSIVE AND FLEXURAL STRENGTH OF CONCRETE," *Int. Res. J. Eng. Technol.*, 2019, [Online]. Available: www.irjet.net
- [6] V. Rathakrishnan, S. Bt. Beddu, and A. N. Ahmed, "Predicting compressive strength of high-performance concrete with high volume ground granulated blast-furnace slag replacement using boosting machine learning algorithms," *Sci. Rep.*, vol. 12, no. 1, p. 9539, 2022, doi: 10.1038/s41598-022-12890-2.
- [7] X. Dong, Y. Liu, and J. Dai, "Application of Fully Connected Neural Network-Based PyTorch in Concrete Compressive Strength Prediction," *Adv. Civ. Eng.*, vol. 2024, no. 1, p. 8048645, 2024.
- [8] X. Hu, B. Li, Y. Mo, and O. Alselwi, "Progress in artificial intelligence-based prediction of

- concrete performance,” *J. Adv. Concr. Technol.*, vol. 19, no. 8, pp. 924–936, 2021, doi: 10.3151/jact.19.924.
- [9] H. Naderpour, A. H. Rafiean, and P. Fakharian, “Compressive strength prediction of environmentally friendly concrete using artificial neural networks,” *J. Build. Eng.*, vol. 16, no. January, pp. 213–219, 2018, doi: 10.1016/j.job.2018.01.007.
- [10] K. L. Chung, L. Wang, M. Ghannam, M. Guan, and J. Luo, “Prediction of concrete compressive strength based on early-age effective conductivity measurement,” *J. Build. Eng.*, vol. 35, p. 101998, 2021, doi: <https://doi.org/10.1016/j.job.2020.101998>.
- [11] M. Nithurshan and Y. Elakneswaran, “A systematic review and assessment of concrete strength prediction models,” *Case Stud. Constr. Mater.*, vol. 18, p. e01830, 2023, doi: <https://doi.org/10.1016/j.cscm.2023.e01830>.
- [12] ACI Committee 318, “Building Code Requirements for Structural Concrete (ACI 318-19) Commentary on Building Code Requirements for Structural Concrete (ACI 318R-19) Reported by ACI Committee 318,” *318-19 Build. Code Requir. Struct. Concr. Comment.*, 2019.
- [13] M. I. Khan *et al.*, “Prediction of compressive strength of cementitious grouts for semi-flexible pavement application using machine learning approach,” *Case Stud. Constr. Mater.*, vol. 19, no. February, p. e02370, 2023, doi: 10.1016/j.cscm.2023.e02370.
- [14] M. Al-Gburi and S. A. Yusuf, “Investigation of the effect of mineral additives on concrete strength using ANN,” *Asian J. Civ. Eng.*, vol. 23, no. 3, pp. 405–414, Apr. 2022, doi: 10.1007/s42107-022-00431-1.
- [15] M. Saridemir, İ. B. Topçu, F. Özcan, and M. H. Severcan, “Prediction of long-term effects of GGBFS on compressive strength of concrete by artificial neural networks and fuzzy logic,” *Constr. Build. Mater.*, vol. 23, no. 3, pp. 1279–1286, 2009, doi: <https://doi.org/10.1016/j.conbuildmat.2008.07.021>.
- [16] M. J. Moradi, M. Khaleghi, J. Salimi, V. Farhangi, and A. M. Ramezaniapour, “Predicting the compressive strength of concrete containing metakaolin with different properties using ANN,” *Measurement*, vol. 183, p. 109790, 2021, doi: <https://doi.org/10.1016/j.measurement.2021.109790>.
- [17] V. Çetin and O. Yıldız, “A comprehensive review on data preprocessing techniques in data analysis,” *Pamukkale Univ. J. Eng. Sci.*, vol. 28, no. 2, pp. 299–312, 2022, doi: 10.5505/pajes.2021.62687.
- [18] I. Nunez, A. Marani, M. Flah, and M. L. Nehdi, “Estimating compressive strength of modern concrete mixtures using computational intelligence: A systematic review,” *Constr. Build. Mater.*, vol. 310, p. 125279, 2021, doi: <https://doi.org/10.1016/j.conbuildmat.2021.125279>.
- [19] M. Shariati, D. J. Armaghani, M. Khandelwal, J. Zhou, and M. Khorami, “Assessment of

- Longstanding Effects of Fly Ash and Silica Fume on the Compressive Strength of Concrete Using Extreme Learning Machine and Artificial Neural Network,” *J. Adv. Eng. Comput.*, vol. 5, no. 1, p. 50, Mar. 2021, doi: 10.25073/jaec.202151.308.
- [20] L. Jin, W. Yu, D. Li, and X. Du, “Numerical and theoretical investigation on the size effect of concrete compressive strength considering the maximum aggregate size,” *Int. J. Mech. Sci.*, vol. 192, p. 106130, 2021.
- [21] A. International, “Standard Specification for Concrete Aggregates- ASTM C33 / C33M-23,” 2023. [Online]. Available: 10.1520/C0033_C0033M-23
- [22] N. Zeminian, G. Guarino, and Q. Xu, “Chemical admixtures for the optimization of the AAC production,” *Ce/papers*, vol. 2, no. 4, pp. 235–240, 2018.
- [23] A. International, “Standard Practice for Making and Curing Concrete Test Specimens in the Laboratory: ASTM C192/C192M-24,” West Conshohocken, PA, 2024, 2024. doi: 10.1520/C0192_C0192M-24.
- [24] J. Pachouly, S. Ahirrao, K. Kotecha, G. Selvachandran, and A. Abraham, “A systematic literature review on software defect prediction using artificial intelligence: Datasets, Data Validation Methods, Approaches, and Tools,” *Eng. Appl. Artif. Intell.*, vol. 111, no. November 2021, p. 104773, 2022, doi: 10.1016/j.engappai.2022.104773.
- [25] A. L. Kaminsky, Y. Wang, and K. Pant, “An efficient batch K-fold cross-validation voronoi adaptive sampling technique for global surrogate modeling,” *J. Mech. Des.*, vol. 143, no. 1, p. 11706, 2021.
- [26] K. Phinzi, D. Abriha, and S. Szabó, “Classification efficacy using k-fold cross-validation and bootstrapping resampling techniques on the example of mapping complex gully systems,” *Remote Sens.*, vol. 13, no. 15, p. 2980, 2021.
- [27] J. S. Chou and A. D. Pham, “Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength,” *Constr. Build. Mater.*, vol. 49, pp. 554–563, 2013, doi: 10.1016/j.conbuildmat.2013.08.078.
- [28] H. Song *et al.*, “Predicting the compressive strength of concrete with fly ash admixture using machine learning algorithms,” *Constr. Build. Mater.*, vol. 308, p. 125021, 2021.
- [29] “Anaconda, Anaconda,” *World’s Most Pop. Data Sci. Platf.*, 2019.
- [30] T. W. M. P. D. S. Platform, “Matlab R2021a,” *World’s Most Pop. Data Sci. Platf.*, [Online]. Available: The World’s Most Popular Data Science Platform
- [31] X. Hu, B. Li, Y. Mo, and O. Alsawi, “Progress in artificial intelligence-based prediction of concrete performance,” *J. Adv. Concr. Technol.*, vol. 19, no. 8, pp. 924–936, 2021.
- [32] D. H. de Bem, D. P. B. Lima, and R. A. Medeiros-Junior, “Effect of chemical admixtures on

concrete's electrical resistivity," *Int. J. Build. Pathol. Adapt.*, vol. 36, no. 2, pp. 174–187, 2018, doi: 10.1108/IJBPA-11-2017-0058.

- [33] M. Saridemir, I. B. Topçu, F. Özcan, and M. H. Severcan, "Prediction of long-term effects of GGBFS on compressive strength of concrete by artificial neural networks and fuzzy logic," *Constr. Build. Mater.*, vol. 23, no. 3, pp. 1279–1286, Mar. 2009, doi: 10.1016/j.conbuildmat.2008.07.021.