

مدل سازی اسلامپ و مقاومت فشاری بتن توانمند با استفاده از شبکه‌ی عصبی مصنوعی و رگرسیون خطی چندگانه

کیومرث محمودی (کارشناس ارشد)

محمد جواد کتابداری* (دانشیار)

دانشکده‌ی مهندسی دریا، دانشگاه صنعتی امیرکبیر

به دلیل ساختار پیچیده‌ی بتن توانمند، ارائه‌ی مدلی برای پیش‌بینی رفتار آن دشوار است. مثلاً مطالعاتی مستقلاً نشان داده‌اند که مقدار اسلامپ بتن توانمند، فقط به مقدار آب و بیشترین اندازه‌ی مصالح درشت‌دانه بستگی ندارد، بلکه مقدار آن تحت تأثیر سایر اجزاء تشکیل‌دهنده‌ی بتن نیز هست. در پژوهش حاضر، عملکرد شبکه‌های عصبی مصنوعی تعدیه‌ی رو به جلو و آشناری رو به جلو و رگرسیون خطی چندگانه‌ی هم‌زمان و قدم به قدم در مدل‌سازی اسلامپ و مقاومت فشاری ۲۸ روزه‌ی بتن توانمند بررسی شده است. داده‌های آزمایش مورد استفاده در پژوهش حاضر از مرجع داده‌های استاندارد دانشگاه کالیفرنیا استخراج شده است. نتایج پژوهش و بررسی جذر میانگین مربعات و ضریب همبستگی نشان داده است که مدل شبکه‌ی عصبی مصنوعی آشناری رو به جلو توانسته است با دقت بهتری اسلامپ و مقاومت فشاری ۲۸ روزه را نسبت به روش‌های دیگر مدل‌سازی کند.

واژگان کلیدی: بتن توانمند، آزمایش اسلامپ، مقاومت فشاری ۲۸ روزه، شبکه‌ی عصبی مصنوعی، رگرسیون خطی چندگانه.

۱. مقدمه

یکی از مهم‌ترین انواع بتن که در سال‌های اخیر به طور قابل توجهی استفاده شده است، بتن توانمند (HPC)^۱ است. بتن توانمند به بتنی گفته می‌شود که عملکرد بهتری برای کاربرد موردنظر نسبت به بتن معمولی داشته باشد و بتواند خواص خود را برای عمر مفید سازه در شرایط بهره‌برداری حفظ کند. تاکنون تعاریف متعددی از بتن توانمند ارائه شده است، اما اساس همه‌ی آن‌ها تأکید بر مشخصاتی نظیر: مقاومت بالا، دوام بالا، پایداری بالا، کارایی مناسب، مقاومت خوب در برابر عواملی چون آتش، محیط و هوازدگی و قابلیت اجرایی مطلوب است.^[۲-۳]

مدل‌سازی کامل رفتار مخلوط بتن توانمند با توجه به استفاده از مواد مختلف در آن پیچیده است. این امر به‌ویژه هنگامی که علاوه بر اجزاء اصلی بتن (سیمان پرتلند، آب، ریزدانه و درشت‌دانه) از مواد افزودنی (مثل خاکستر بادی، فوق‌روان‌کننده و سرباره‌ی کوره‌ی آهن‌گدازی) نیز استفاده شود، پیچیده‌تر می‌شود. یکی از روش‌های مناسب برای مدل‌سازی رفتار مصالح، جمع‌آوری داده‌های آزمایشگاهی از خصوصیات آنهاست. هر چه مجموعه‌ی داده‌های جمع‌آوری شده کامل‌تر و بیشتر باشد، می‌توان رفتار مصالح را با دقت بهتری مدل‌سازی کرد. مجموعه‌ی داده‌های گردآوری شده از خصوصیات مصالح معمولاً چندمتغیره هستند و بین متغیرها یک رابطه‌ی غیرخطی

* نویسنده مسئول

تاریخ دریافت: ۱۳۹۴/۱۳/۳۱، اصلاحیه ۱۳۹۴/۹/۳۰، پذیرش ۱۳۹۴/۱۲/۲۲.

برقرار است. در سال‌های اخیر، استفاده از مدل‌ها و الگوریتم‌های نوین رایانه‌ی برای مدل‌سازی رفتار مصالح به طور قابل توجهی رایج شده است. یکی از ابزارهای مناسب برای مدل‌سازی رفتار بتن، استفاده از شبکه‌های عصبی مصنوعی است. در سال‌های اخیر، برخی از پژوهشگران از ابزار مذکور برای مدل‌سازی رفتار بتن استفاده کرده‌اند.^[۴-۹]

در پژوهشی در سال ۲۰۰۱، عنوان شده است که شبکه‌های عصبی می‌توانند با دقت خوبی، روانی بتن و نتایج آزمون تفکیک بتن خودمترکم را پیش‌بینی کنند.^[۱۰] همچنین چند مدل شبکه‌ی عصبی (۲۰۰۳) برای پیش‌بینی کارایی بتن توسعه داده شده است.^[۱۱] همچنین در سال ۲۰۰۶ پژوهشگران با استفاده از ۵ پارامتر ورودی از خواص بتن، مدل شبکه‌ی عصبی را برای پیش‌بینی مقاومت و اسلامپ بتن ایجاد،^[۱۲] و نیز از شبکه‌های عصبی برای بیان اثر اجزاء تشکیل‌دهنده‌ی بتن در اسلامپ استفاده کرده‌اند.^[۱۳]

همچنین با استفاده از مدل‌های شبکه‌ی عصبی مصنوعی و رگرسیونی، مقدار اسلامپ بتن با استفاده از داده‌های آزمایشگاهی مواد تشکیل‌دهنده‌ی بتن پیش‌بینی شده و با استفاده از آزمون‌های انجام شده در سال ۲۰۰۸ نشان داده شده است که شبکه‌های عصبی مصنوعی، توانایی بالاتری برای مدل کردن رفتار بتن دارند و با استفاده از آزمون تحلیل حساسیت، اثر هر یک از اجزاء تشکیل‌دهنده‌ی بتن روی مقدار اسلامپ بررسی و با استفاده از آن مشخص شده است که اسلامپ زمانی به

مقدار کمینه‌ی خود می‌رسد که آهک و مصالح درشت‌دانه به سطوح بحرانی خود برسند. در تحلیل و طراحی سازه‌های بتنی مسلح، یافتن نقطه‌ی بحرانی تنش و کرنش زیر بار سه‌محوره امری ضروری است.^[۱۴]

از شبکه‌های عصبی تابع پایه‌ی شعاعی نیز برای یافتن نقطه‌ی اوج تنش و کرنش در بتن زیر نیروی فشاری استفاده شده و چندین مدل شبکه‌ی عصبی پایه‌ی شعاعی برای پیش‌بینی نقطه‌ی اوج تنش و کرنش زیر بار سه‌محوره توسعه یافته است و برای ایجاد مدل‌ها از ۵۶ نمونه‌ی بتن با مقاومت نرمال و بالا استفاده شده و در نهایت با مقایسه‌ی مدل‌های ایجادشده با مدل‌های متداول رگرسیونی نشان داده شده است که دقت مدل شبکه‌ی عصبی تابع پایه‌ی شعاعی بیشتر از سایر مدل‌ها بوده و همچنین خاصیت تطبیق‌پذیری این مدل نسبت به سایر مدل‌ها بالاتر است.^[۱۵] همچنین در مطالعه‌ی در سال ۲۰۱۴، با استفاده از شبکه‌های عصبی تکامل‌یافته‌ی ژنتیک^۲ اسلامپ بتن آماده‌ی مدل‌سازی شده و روشی نوین برای تعیین پارامترهای ساختار شبکه‌ی عصبی بهینه که با استفاده از سعی و خطا تعیین می‌شده است، مبتنی بر الگوریتم ژنتیک ارائه شده و با استفاده از الگوریتم‌های ژنتیکی جستجوی تصادفی، تعداد بهینه‌ی نورون‌های لایه‌ی نهان، تابع انتقال، نرخ یادگیری و ضریب مومنتوم برای شبکه‌ی عصبی پیش‌خور تعیین شده و از ۶ روش آماری برای بررسی عملکرد مدل‌های ایجاد شده استفاده شده و نتایج حاکی از برتری روش پیشنهادی نسبت به روش سنتی مبتنی بر سعی و خطا بوده و همچنین با استفاده از روش مذکور، پیچیدگی تعیین پارامترهای بهینه‌ی شبکه کاهش یافته است.^[۱۶]

در پژوهشی در سال ۲۰۱۴، از سه مدل شبکه‌ی عصبی مصنوعی، مدل درختی و مدل رگرسیون غیرخطی برای مدل‌سازی مقاومت فشاری ۲۸ روزه‌ی بتن بازیافتی استفاده شده و نتایج به‌دست آمده حاکی از عملکرد مناسب‌تر شبکه‌ی عصبی در مدل‌سازی مقاومت فشاری بتن بوده است.^[۱۷] در سال ۲۰۱۵، نیز یک روش نوین برای تخمین رابطه‌ی ورودی - خروجی (مسئله‌ی رگرسیون) به نام Hybrid ANN-GA ارائه شده و در آن مقادیر وزن‌های اولیه و بایاس‌ها^۳ (اریب) توسط الگوریتم ژنتیک انتخاب و کارایی روش ارائه‌شده روی تخمین اسلامپ مخلوط بتن آماده بررسی شده و نتایج به‌دست آمده بیانگر سرعت هم‌گرایی بالاتر و دقت بیشتر نسبت به مدل‌های مشابه بوده است.^[۱۸]

در پژوهش حاضر با استفاده از مدل‌های شبکه‌ی عصبی مصنوعی و رگرسیون خطی چندگانه، دو پارامتر اسلامپ و مقاومت فشاری ۲۸ روزه‌ی بتن توانمند، مدل‌سازی و عملکرد آن‌ها با استفاده از معیارهای متداول ارزیابی عملکرد بررسی شده است. مقادیر دو پارامتر مذکور به صورت تابعی از اجزاء تشکیل‌دهنده‌ی بتن (در اینجا سیمان، خاکستر بادی، سرباره‌ی کوره آهن‌گدازی، آب، فوق روان‌کننده، درشت‌دانه و ریزدانه) با استفاده از شبکه‌ی عصبی مصنوعی و رگرسیون خطی چندگانه پیش‌بینی شده است. ایجاد مدل‌ها برای پیش‌بینی مقاومت فشاری و اسلامپ نیازمند داده‌های آزمایشگاهی است. در بخش بعد، مفاهیم شبکه‌های عصبی مصنوعی، رگرسیون خطی چندگانه و مجموعه‌ی داده‌های مورد استفاده در پژوهش حاضر به طور خلاصه بیان شده است.

۱.۲. مجموعه داده‌های مورد مطالعه

داده‌های مورد استفاده در پژوهش حاضر از مرجع داده‌های استاندارد دانشگاه کالیفرنیا یعنی UCI Machine Learning Repository^[۱۹] استخراج شده‌اند. مقادیر مجموعه‌ی داده‌های مورد بررسی با استفاده از آزمایش اسلامپ روی بتن توانمند شامل ۷ متغیر ورودی و ۳ متغیر خروجی بوده‌اند. متغیرهای ورودی عبارت از مقادیر مصالح تشکیل‌دهنده‌ی بتن بر حسب kg/m^3 شامل: سیمان، خاکستر بادی، سرباره‌ی کوره آهن‌گدازی، آب، فوق روان‌کننده، ریزدانه و درشت‌دانه؛ و متغیرهای خروجی عبارت از اسلامپ (cm) و مقاومت فشاری ۲۸ روزه‌ی بتن (MPa) بوده‌اند. اسلامپ با محاسبه‌ی تفاضل ارتفاع قالب از بالاترین ارتفاع بتن پس از برداشتن قالب و مقاومت فشاری با استفاده از قراردادن نمونه‌ی بتن ۲۸ روزه در دستگاه به‌دست آمده‌اند. برای تولید داده‌ها از ۱۰۳ ترکیب مختلف برای تهیه مخلوط استفاده شده است که در جدول‌های ۱ و ۲ جزئیات آن‌ها ارائه شده است.^[۲۰]

۲.۲. شناسایی داده‌های پرت احتمالی مجموعه‌ی داده‌های مورد مطالعه

عوامل مختلفی مثل خطاهای انسانی و دستگاهی و تغییر در شرایط اندازه‌گیری ممکن است سبب بروز داده‌های پرت در مقادیر اندازه‌گیری شده شود. معمولاً داده‌های پرت بیانگر بروز خطا در اندازه‌گیری‌ها هستند، از این رو نیاز است قبل از انجام هرگونه تجزیه و تحلیل و نتیجه‌گیری از داده‌ها، داده‌های پرت شناسایی و در صورت امکان از مجموعه‌ی داده‌ها حذف شوند. در پژوهش حاضر، داده‌ی پرت، داده‌ی در نظر گرفته شده است که از الگوی نرمال کلی مجموعه داده‌ها پیروی نکرده و از سایر مشاهدات به طور قابل ملاحظه‌ی دور افتاده باشد، به گونه‌ی که این سوءظن ایجاد شود که با یک روند متفاوت تولید شده است.^[۲۱]

در پژوهش حاضر از روش LSC-Mine^[۲۲] برای شناسایی داده‌های پرت استفاده شده است که یکی از روش‌های شناسایی داده‌های پرت مبتنی بر چگالی در مجموعه داده‌های چندمتغیره است و مبتنی بر فاصله‌ی یک داده k تا نزدیک‌ترین همسایه‌های آن است. k یک عدد صحیح مثبت است که توسط کاربر انتخاب می‌شود. برای اجرای روش LSC-Mine، انجام این گام‌ها ضروری است:

گام اول: محاسبه‌ی فاصله‌ی k آمین همسایه‌ی p از آن: برای هر داده‌ی p ، $k_distance(p)$ فاصله‌ی k آمین همسایه‌ی نزدیک p از آن است. فاصله می‌تواند با هر تابع اندازه‌گیری فاصله (مثل اقلیدسی، مانهالانویس و غیره) محاسبه شود. در پژوهش حاضر، در تمامی حالات از تابع اقلیدسی برای اندازه‌گیری فاصله‌ی بین نقاط استفاده شده است.

گام دوم: پیدا کردن همسایگی k آمین فاصله‌ی p : هر داده‌ی q که فاصله‌ی آن از p ، از $k_distance(p)$ کمتر یا مساوی باشد، در همسایگی k آمین فاصله‌ی p قرار می‌گیرد (رابطه‌ی ۱):

$$N_k(p) = \{q \in X \setminus \{p\} | dist(p, q) \leq k_distance(p)\} \quad (1)$$

گام سوم: محاسبه‌ی نسبت پراکندگی محلی p : نسبت پراکندگی محلی داده‌ی p که با $lstr_k(p)$ نشان داده می‌شود، به صورت نسبت تعداد عناصر واقع شده در فاصله‌ی k - همسایگی داده‌ی p به مجموع فواصل حقیقی در همسایگی

۲. مواد و روش‌ها

در بخش حاضر، جزئیات مجموعه‌ی داده‌ها بررسی و روش‌های استفاده‌شده برای مدل‌سازی مقاومت فشاری ۲۸ روزه و اسلامپ توضیح داده شده است.

جدول ۱. بخشی از مجموعه‌ی داده‌های مورد مطالعه. [۲۰]

ردیف	سیمان kg/m^3	خاکستر بادی kg/m^3	سر باره‌ی کوره‌ی آهن‌گذاری kg/m^3	آب kg/m^3	فوق روان‌کننده kg/m^3	ریزدانه kg/m^3	درشت دانه kg/m^3	اسلامپ cm	مقاومت فشاری ۲۸ روزه MPa
۱	۲۷۳	۸۲	۱۰۵	۲۱۰	۹	۹۰۴	۶۸۰	۲۳	۳۴٫۹۹
۲	۱۶۳	۱۴۹	۱۹۱	۱۸۰	۱۲	۸۴۳	۷۴۶	۰	۴۱٫۱۴
۳	۱۶۲	۱۴۸	۱۹۱	۱۷۹	۱۶	۸۴۰	۷۴۳	۱	۴۱٫۸۱
۴	۱۶۲	۱۴۸	۱۹۰	۱۷۹	۱۹	۸۳۸	۷۴۱	۳	۴۲٫۰۸
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
۱۰۰	۲۴۸	۱۰۱	۲۳۹٫۹	۱۶۹٫۱	۷٫۷	۹۴۹٫۹	۶۴۴٫۱	۲	۵۰٫۲۳
۱۰۱	۲۵۸٫۸	۸۸	۲۳۹٫۹	۱۷۵٫۳	۷٫۶	۹۳۸٫۹	۶۴۶	۰	۵۰٫۵
۱۰۲	۲۹۷٫۱	۴٫۹۰	۲۳۹٫۹	۱۹۴	۷٫۵	۹۰۸٫۹	۶۵۱٫۸	۲۷٫۵	۴۹٫۱۷
۱۰۳	۳۴۸٫۷	۰٫۱	۲۲۳٫۱	۲۰۸٫۵	۹٫۶	۷۸۶٫۲	۷۵۸٫۱	۲۹	۴۸٫۷۷

جدول ۲. محدوده‌ی اجزاء تشکیل‌دهنده‌ی مخلوط در مجموعه‌ی داده‌های مورد مطالعه. [۲۰]

جزء تشکیل دهنده	وزن مخصوص	کمترین وزن (kg/m^3)	بیشترین وزن (kg/m^3)
سیمان	۳٫۱۵	۱۳۷٫۰۰	۳۷۴٫۰۰
خاکستر بادی	۲٫۲۲	۰٫۰۰	۲۶۰٫۰۰
سر باره‌ی کوره‌ی آهن‌گذاری	۲٫۸۵	۰٫۰۰	۱۹۳٫۰۰
آب	۱٫۰۰	۱۶۰٫۰۰	۲۴۰٫۰۰
فوق روان‌کننده	۱٫۲۰	۴٫۴۰	۱۹٫۰۰
درشت دانه	۲٫۶۵	۷۰۸٫۰۰	۱۰۴۹٫۹۰
ریزدانه	۲٫۶۶	۶۴۰٫۶۰	۹۰۲٫۰۰

پس از محاسبه‌ی ضریب هرس، داده‌هایی که نسبت پراکندگی محلی آنها کمتر از Pf است، از محاسبات آتی کنار زده می‌شوند، چون پتانسیل کمتری به لحاظ پرت بودن دارند. این ضریب بیش از نیمی از داده‌های مجموعه داده‌ها را کنار می‌زند، به همین دلیل کارایی روش LSC-Mine افزایش می‌یابد. چون حجم محاسبات مورد نیاز کاهش می‌یابد و در نتیجه، مدت زمان کمتری برای اجرای برنامه مورد نیاز خواهد بود.

گام پنجم: محاسبه‌ی ضریب پراکندگی محلی p : ضریب پراکندگی محلی داده‌ی p که با $LSC_k(p)$ نشان داده می‌شود، به صورت نسبت میانگین نسبت پراکندگی محلی p به k تا نزدیک‌ترین همسایه‌های آن تعریف می‌شود (رابطه‌ی ۴):

$$LSC_k(p) = \frac{\sum_{o \in N_k(p)} \frac{lstr_k(o)}{lstr_k(p)}}{|N_k(p)|} \quad (4)$$

مقدار بالای ضریب پراکندگی محلی برای یک داده، بیانگر این نکته است که همسایگی اطراف داده، شلوغ نیست و در نتیجه پتانسیل بالایی به لحاظ پرت بودن دارد. در حالی که مقدار کم ضریب پراکندگی محلی، بیانگر اجتماع زیاد داده‌های واقع شده در همسایگی داده مورد بررسی است که در نتیجه می‌توان گفت که داده‌ی مذکور پتانسیل کمی به لحاظ پرت بودن دارد. بنابراین برای شناسایی داده‌های پرت با استفاده از روش LSC-Mine، ضریب LSC برای تمامی اعضاء مجموعه‌ی داده‌ها محاسبه می‌شود، اگر این ضریب از یک حد آستانه‌ی t تعریفی کاربر بیشتر باشد، می‌توان گفت آن داده، کاندیدای یک داده‌ی پرت است.

۳.۲. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی، اقتباسی بسیار ساده از هوش انسان هستند و می‌توانند در مسائلی مثل شناخت الگو، خوشه‌بندی، دسته‌بندی، تخمین تابع، مدل‌سازی، کنترل و به طور کلی در هر جا که نیاز به یادگیری یک نگاشت خطی و یا غیرخطی باشد، استفاده می‌شوند. این قابلیت‌ها سبب شده‌اند که پژوهشگران برای مدل‌سازی رفتار مصالح که وابسته به خصوصیات فیزیکی و شیمیایی اجزاء تشکیل‌دهنده‌ی آنها هستند، به استفاده از شبکه‌های عصبی روی آورند. [۲۳]

هر شبکه‌ی عصبی شامل یک لایه‌ی ورودی است که هر گره در آن معادل یکی از متغیرهای پیش‌بینی است. گره‌های موجود در لایه‌ی ورودی به تعدادی گره در لایه‌ی نهان وصل می‌شوند. هر گره ورودی به همه‌ی گره‌های لایه‌ی نهان وصل


تعریف می‌شود (رابطه‌ی ۲):

$$lstr_k(p) = \frac{|N_k(p)|}{\sum_{o \in N_k(p)} distofN_k(p)} \quad (2)$$

که در آن، $distofN_k(p)$ شامل فواصل حقیقی داده‌های موجود در فاصله‌ی k - همسایگی از p است. نسبت پراکندگی محلی، تراکم داده‌های اطراف داده‌ی p را اندازه‌گیری می‌کند. داده‌های با نسبت چگالی محلی بالا، پتانسیل بیشتری از لحاظ پرت بودن دارند و بالعکس. به جای استفاده از نسبت مذکور، اعلام نهایی داده‌های پرت وابسته به ضریب پراکندگی محلی است. ضریب هرس^۴ بر این فرض استوار است که اگر یک داده‌ی p موجود در مجموعه‌ی داده‌ها، پرت نیست؛ آنگاه نسبت پراکندگی محلی آن نباید کمتر از یک نسبت مشابه محاسبه شده از کل داده‌های مجموعه داده‌ها باشد. ضریب هرس یک حد بالا برای هر داده که کاندیدای داده‌ی پرت است، ارائه می‌کند.

گام چهارم: محاسبه‌ی ضریب هرس: ضریب هرس به صورت نسبت مجموع قدرمطلق فواصل همسایگی به مجموع کل فواصل حقیقی همسایگی تعریف می‌شود (رابطه‌ی ۳):

$$Pf = \frac{\sum |N_k(p)|}{\sum \sum_{o \in N_k(p)} distofN_k(p)} \quad (3)$$



شکل ۱. توابع فعال‌ساز در شبکه‌ی عصبی. [۲۵]

لایه‌ها، تعداد نرون‌ها در هر لایه، تعداد تکرارها برای هر الگو در خلال آموزش و سایر پارامترها تعیین شود. انتخاب بهینه‌ی مقادیر پارامترها منجر به ایجاد یک شبکه‌ی مطلوب و در نتیجه پیش‌بینی قابل اعتمادتری می‌شود. به این منظور باید شبکه را تحت پارامترهای مختلف که در واقع همان ویژگی‌های شبکه است، مورد آموزش و یادگیری قرار داد. به عبارت دیگر، با تغییر دادن مقادیر پارامترها، شبکه وزن‌های خروجی متفاوتی تولید خواهد کرد که در نهایت، وزنی که منجر به کمترین خطا شود، به‌عنوان وزن نهایی و پارامترهایی که موجب دست‌یابی به این وزن شده‌اند، به‌عنوان پارامترها و مشخصه‌های شبکه معرفی می‌شوند.

۴.۲. رگرسیون خطی چندگانه

مدل‌های رگرسیونی، رابطه‌ی بین متغیر وابسته y و متغیر یا متغیرهای مستقل X را توصیف می‌کنند. رگرسیون خطی چندگانه، [۲۶] تعمیمی از رگرسیون خطی با در نظر گرفتن بیش از یک متغیر مستقل است. مدل کلی رگرسیون خطی چندگانه به‌صورت رابطه‌ی ۸ است:

$$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i, \quad i = 1, \dots, n \quad (8)$$

که در آن، n بیانگر تعداد کل مشاهده‌ها، y_i متغیر وابسته‌ی متناظر با i امین مشاهده، p تعداد کل متغیرهای مستقل و نیز i امین مشاهده از n امین متغیر مستقل است که $j = 1, 2, \dots, p$ ، مقادیر β_k بیانگر k امین ضریب متغیرهای تخمین زده شده است. β_0 مقدار ثابت مدل است و ε_i نیز i امین خطای معمولی مستقل توزیع یافته به‌طور یکسان است. در حالت کلی، یک مدل خطی رگرسیونی می‌تواند به شکل رابطه‌ی ۹ مدل شود:

$$y_i = \beta_0 + \sum_{k=1}^K \beta_k f_k(X_{i1}, X_{i2}, X_{ip}) + \varepsilon_i \quad i = 1, \dots, n \quad (9)$$

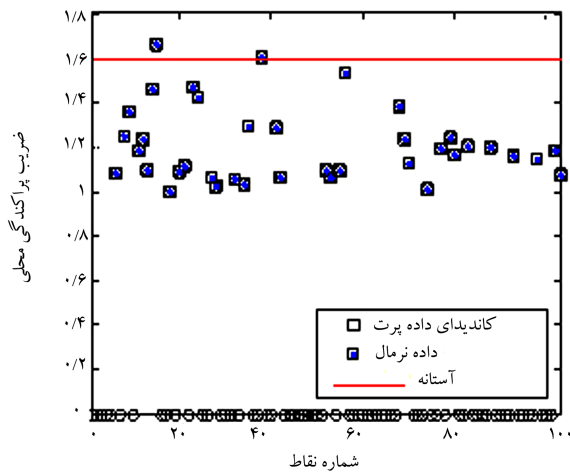
که در آن، $f(0)$ تابعی با خروجی یک مقدار اسکالار از متغیرهای مستقل X_{ij} است. $f(X)$ می‌تواند به هر شکلی شامل توابع غیرخطی یا چندجمله‌یی باشد. تابع خطی برازش شده به شکل رابطه‌ی ۱۰ است:

$$\hat{y}_i = b_0 + \sum_{k=1}^K b_k f_k(X_{i1}, X_{i2}, X_{ip}) + \varepsilon_i, \quad i = 1, \dots, n \quad (10)$$

می‌شود. گره‌های موجود در لایه‌ی نهان می‌توانند به گره‌های یک لایه‌ی نهان دیگر و یا به گره‌های لایه‌ی خروجی متصل شوند. لایه‌ی خروجی شامل یک یا چند متغیر خروجی است. هر گره نماینده‌ی یک سلول عصبی مصنوعی (نرون) است. در واقع یک شبکه‌ی عصبی مصنوعی، مجموعه‌ی نرون‌های متصل به هم در لایه‌های مختلف است که اطلاعاتی را برای یکدیگر ارسال می‌کنند. هر یال بین گره‌ها، یک وزن دارد که در محاسبات لایه‌های میانی استفاده می‌شوند. هر گره لایه‌ی میانی، مقدار هر ورودی را در وزن یال مربوط به آن ضرب و حاصل آن‌ها را با هم جمع می‌کند. سپس یک تابع از پیش تعیین‌شده (تابع فعال‌سازی) روی این حاصل جمع اعمال و نتیجه‌ی آن به‌عنوان خروجی به گره‌های لایه‌ی بعد فرستاده می‌شود. وزن یال‌ها، پارامترهای ناشناخته‌ی هستند که توسط تابع آموزش و داده‌های آموزشی که به سیستم داده می‌شوند، تعیین می‌شوند. [۲۷، ۲۸] به‌طور کلی نقش نرون‌ها در شبکه‌های عصبی پردازش اطلاعات است که این امر توسط یک پردازش‌گر ریاضی که همان تابع فعال‌سازی (تابع انتقال) است، انجام می‌شود. تابع فعال‌سازی می‌تواند خطی و یا غیرخطی باشد. یک تابع فعال‌سازی براساس نیاز خاص مسئله‌ی که قرار است توسط شبکه‌ی عصبی حل شود، از سوی طراح شبکه انتخاب می‌شود. اگر هدف پیش‌بینی باشد، باید در لایه‌ی خروجی از تابع خطی استفاده شود. یک نرون علاوه بر ورودی‌ها و وزن‌ها، شامل جزء دیگری با نام بایاس است. مقادیر بایاس با حاصل ضرب ورودی‌ها در وزن‌های مربوط جمع می‌شود. در توابع فعال‌سازی خطی، بایاس می‌تواند همان نقش عرض از مبدأ در رگرسیون را ایفا کند.

در پژوهش حاضر، کارایی دو نوع شبکه‌ی عصبی تغذیه‌ی رو به جلو^۵ و شبکه‌های عصبی آبتشاری رو به جلو^۶ در پیش‌بینی اسلامپ و مقاومت فشاری ۲۸ روزه بتن توانمند بررسی شده است. از مهم‌ترین انواع شبکه‌های عصبی، شبکه‌های عصبی تغذیه‌ی رو به جلو است. رو به جلو به این معنی است که مقدار پارامتر خروجی براساس پارامترهای ورودی و یک سری وزن‌های اولیه تعیین می‌شود. مقادیر ورودی با هم ترکیب و در لایه‌های نهان استفاده می‌شوند. مقادیر لایه‌های نهان نیز برای محاسبه مقادیر خروجی ترکیب می‌شوند. توسعه‌ی برگشتی به این معنی است که با مقایسه‌ی مقدار خروجی با مقدار مدنظر (مقادیر هدف)^۷ در داده‌های آزمایشی، خطای خروجی محاسبه می‌شود. از این مقدار برای تصحیح شبکه و تغییر وزن یال‌ها استفاده می‌شود که از گره خروجی شروع می‌شود و به عقب محاسبات ادامه می‌یابد. این عمل برای هر نمونه‌ی موجود در مجموعه‌ی داده‌ها تکرار می‌شود و آنقدر ادامه می‌یابد که دیگر مقدار خطا تغییر نکند. می‌توان ثابت کرد که شبکه‌های عصبی تغذیه‌ی رو به جلو با یک لایه‌ی نهان، تابع فعال‌سازی سیگموئید^۸ در لایه‌ی نهان، تابع فعال‌سازی خطی در خروجی و تعداد نرون‌های کافی در لایه‌ی نهان قادرند هر تابع خطی و غیرخطی را با دقت مطلوب تخمین بزنند. به همین دلیل این نوع شبکه، بهترین انتخاب برای مسائل پیش‌بینی است. بنابراین در پژوهش حاضر از این نوع شبکه برای مدل‌سازی کارایی بتن که به نوعی یک مسئله‌ی پیش‌بینی است، استفاده شده است. شبکه‌های عصبی چندلایه اغلب از تابع فعال‌سازی log-sigmoid استفاده می‌کنند. خروجی این تابع بین ۰ و ۱ است. همچنین این شبکه‌ها می‌توانند از تابع فعال‌سازی tan-sigmoid نیز استفاده کنند که خروجی آن بین ۱- و ۱ است. در شکل ۱، توابع مذکور نشان داده شده‌اند (روابط ۵ الی ۷). [۲۵]

شبکه‌های عصبی آبتشاری رو به جلو، مشابه شبکه‌های عصبی تغذیه‌ی رو به جلو هستند، اما یک اتصال از ورودی‌ها و هر لایه‌ی قبلی به لایه‌ی خروجی دارند. در شبکه‌ی ذکر شده، اگر تعداد نرون‌ها به‌طور کافی انتخاب شود، قادر خواهد بود هر رابطه‌ی دلخواه ورودی - خروجی را تخمین بزند. هنگام طراحی یک شبکه‌ی عصبی مصنوعی باید پارامترهای ساختار شبکه از قبیل: نوع الگوریتم آموزش، تعداد



شکل ۲. مقادیر ضریب پراکندگی محلی (LSC_k) محاسبه شده برای مجموعه‌ی داده‌های مورد بررسی.

پارامترهای k (تعداد k تا نزدیک‌ترین همسایه‌ها) و t (پارامتر آستانه) توسط کاربر است. در پژوهش حاضر، مقدار k برابر ۲۰ در نظر گرفته شده است. این بدان معنی است که برای هر نمونه، ۲۰ همسایه‌ی نزدیک آن به‌عنوان حوزه‌ی همسایگی تعیین شده است. مقدار پارامتر آستانه نیز با توجه به ماهیت داده‌های ورودی و آزمون و خطا برابر ۱/۶ انتخاب شده است. پس از اجرای روش LSC-Mine روی مجموعه‌ی داده‌های مورد بررسی، نمونه‌های ردیف ۸ و ۱۹ مجموعه‌ی داده‌ها به‌عنوان کاندیدای پرت انتخاب شده‌اند. با توجه به اینکه تعداد نمونه‌های پرت شناسایی شده، کم بوده است، این دو نمونه از مجموعه‌ی داده‌ها حذف شده‌اند. بنابراین تعداد کل نمونه‌های باقی‌مانده ۱۰۱ حالت است که از آن‌ها برای مدل‌سازی استفاده شده است. در شکل ۲، ضریب پراکندگی محلی (LSC_k) محاسبه شده برای تمامی نمونه‌های مجموعه‌ی داده‌ها نشان داده شده است. داده‌هایی که با علامت دایره در شکل ۲ نشان داده شده‌اند، نمونه‌هایی هستند که نسبت پراکندگی محلی (LSC_k) آن‌ها کمتر از ضریب هرس (Pf) است و در نتیجه نمونه‌ی پرت محسوب نمی‌شوند. اما داده‌های مشخص شده با علامت مربع بیانگر نمونه‌هایی هستند که همسایگی اطراف آنها شلوغ نیست و در نتیجه، پتانسیل بالایی به لحاظ پرت بودن دارند. در نهایت، نمونه‌هایی که بالای خط قرمز (پارامتر آستانه) قرار گرفته‌اند، به‌عنوان نمونه‌های پرت نهایی انتخاب شده‌اند.

۲.۳. مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی تغذیه‌ی

رو به جلو و آبخاری رو به جلو

از آنجایی که یک شبکه‌ی ۳ لایه قادر به تقریب هر تابع غیرخطی است، در پژوهش حاضر از یک شبکه‌ی ۳ لایه‌ی تغذیه‌ی رو به جلو برای مدل‌سازی‌ها استفاده شده است. برای طراحی شبکه، باید آن را تحت پارامترهای مؤثر در عملکرد آن تحت آموزش و یادگیری قرار داد و در نهایت، بهترین پارامترها را انتخاب کرد. در اینجا برای مدل‌سازی دو مشخصه‌ی اسلامپ و مقاومت فشاری ۲۸ روزه، چندین مدل مختلف شبکه‌ی عصبی طراحی شده است. ساختار این شبکه‌ها یکسان و تفاوت آنها در وزن‌های ارتباطی بین گره‌ها بوده است. این به دلیل متفاوت بودن مجموعه‌ی داده‌های آموزشی هر شبکه است. هر مدل ۷ متغیر ورودی و ۱ متغیر خروجی (هدف) دارد. برای همه‌ی مدل‌ها، متغیرهای ورودی یکسان است، ولی متغیر خروجی آنها پارامتری است که سعی در پیش‌بینی مقدار آن است. در

که در آن، \hat{y}_i مقادیر تخمینی متغیر وابسته و b_k ضریب برازش شده است. ضرایب به‌گونه‌ی تخمین زده می‌شوند که مربع میانگین تفاوت بین بردار پیش‌بینی $bf(X)$ و بردار مقادیر واقعی y کمینه شود، یعنی $y - \hat{y}$. به این روش، روش کمینه‌ی مربعات گفته می‌شود. همچنین ضرایب درست‌نمایی^۹ مذکور، بردار پیش‌بینی را پیشینه می‌سازند. در معادله‌ی رگرسیون چندگانه، ضرایب متغیرهای مستقل به‌عنوان ضرایب رگرسیون جزئی شناخته می‌شوند که بدین معنی است که آن‌ها میزان افزایش متغیر وابسته را به ازاء یک واحد افزایش متغیر مستقل موردنظر نشان می‌دهند. در پژوهش حاضر، دو روش رگرسیون چندگانه مد نظر است:

۱. رگرسیون خطی چندگانه‌ی هم‌زمان: تمام متغیرهای مستقل موجود هم‌زمان وارد معادله می‌شوند.

۲. رگرسیون خطی چندگانه‌ی قدم به قدم: متغیرهای مستقل تک‌تک وارد معادله می‌شوند و اگر نقش معنی‌داری در رگرسیون نداشته باشند، از آن خارج می‌شوند. ترتیب ورود متغیرها براساس ملاحظات آماری تعیین می‌شود.

۵.۲. معیارهای ارزیابی عملکرد

پس از ایجاد مدل‌ها با استفاده از روش‌های مورد بحث، باید کارایی آن‌ها ارزیابی شود. در پژوهش حاضر، برای ارزیابی میزان عملکرد مدل‌ها، از معیارهای ارزیابی جذر میانگین مربعات خطا ($RMSE$) و ضریب هم‌بستگی (R) استفاده شده است. در مجموع هر چه $RMSE$ به صفر و R^2 به ۱ نزدیک‌تر باشد، یعنی مدل‌ها بهینه‌تر طراحی شده‌اند و عملکرد بهتری دارند. مقدار R^2 همواره بین ۰ و ۱ است. مقادیر این پارامترها به ترتیب از روابط ۱۱ و ۱۲ محاسبه می‌شوند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (11)$$

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (12)$$

که در آن‌ها، y_i داده‌های پیش‌بینی شده، x_i داده‌های اندازه‌گیری شده، \bar{y} میانگین داده‌های پیش‌بینی شده و \bar{x} میانگین داده‌های اندازه‌گیری شده هستند.

۳. بحث

در بخش حاضر، عملکرد روش‌های شبکه‌ی عصبی مصنوعی و رگرسیون خطی چندگانه در مدل‌سازی مقاومت فشاری ۲۸ روزه و اسلامپ بتن توانمند با استفاده از معیارهای ارزیابی عملکرد، که در بخش ۵.۲ معرفی شده، بررسی شده است. هر روشی که منجر به کمترین خطا و بیشترین ضریب هم‌بستگی شود، به‌عنوان کاراترین روش انتخاب خواهد شد. لازم به ذکر است که برای اجرای تمامی روش‌ها و انجام تجزیه و تحلیل‌های لازم از نرم‌افزار MATLAB استفاده شده است.

۱.۳. شناسایی داده‌های پرت مجموعه داده‌های مورد بررسی با

استفاده از روش LSC-Mine

برای ایجاد مدل‌های هر چه دقیق‌تر لازم است قبل از انجام مدل‌سازی‌ها، داده‌های پرت مجموعه‌ی داده‌های مورد بررسی، شناسایی و در صورت امکان حذف شوند. استفاده از روش LSC-Mine برای شناسایی داده‌های پرت نیازمند تعیین مقادیر

جدول ۵. نتایج شبکه‌ی عصبی مصنوعی آبخاری رو به جلو روی مجموعه داده‌های اسلامپ و مقاومت فشاری ۲۸ روزهی بتن توانمند.


نام مجموعه‌ی داده	تعداد نرون	مجدور ضریب همبستگی	مجدور میانگین مربعات خطا	
اسلامپ	۵	۰٫۷۰	۳٫۶۳cm	
	۶	۰٫۸۳	۴٫۳۰cm	
	۷	۰٫۸۴	۴٫۹۵cm	
	۸	۰٫۸۹	۲٫۹۹cm	
	۹	۰٫۹۱	۲٫۷۲cm	
	۱۰	۰٫۸۷	۳٫۱۵cm	
	مقاومت فشاری ۲۸ روزه	۵	۱٫۰۰	۰٫۱۰MPa
		۶	۱٫۰۰	۰٫۰۹MPa
		۷	۱٫۰۰	۰٫۱۰MPa
		۸	۱٫۰۰	۰٫۰۹MPa
۹		۱٫۰۰	۰٫۰۷MPa	
۱۰		۱٫۰۰	۰٫۰۸MPa	

جدول ۳. مشخصات ساختار شبکه‌های عصبی طراحی شده.


نوع شبکه	سه لایه‌ی تغذیه‌ی رو به جلو
تعداد نرون‌های لایه‌ی ورودی	۷
تعداد نرون‌های لایه‌ی میانی	$[10 - 5]$
تعداد نرون‌های لایه‌ی خروجی	۱
تعداد داده‌های آموزش *	۷۱
تعداد داده‌های اعتبارسنجی **	۱۵
تعداد داده‌های آزمون ***	۱۵
الگوریتم آموزش	لئونبرگ مارکواردت ****
تابع فعال‌سازی لایه‌ی نهان	تانژانت هیپربولیک
تابع فعال‌سازی لایه‌ی خروجی	خطی
تابع اندازه‌گیری خطا	جذر میانگین مربعات خطا
** validation data	* training data
**** levenberg-marquardt	*** test data

جدول ۴. نتایج شبکه‌ی عصبی مصنوعی تغذیه‌ی رو به جلو روی مجموعه داده‌های اسلامپ و مقاومت فشاری ۲۸ روزهی بتن توانمند.

نام مجموعه‌ی داده	تعداد نرون	مجدور ضریب همبستگی	مجدور میانگین مربعات خطا	
اسلامپ	۵	۰٫۸۱	۳٫۹۲cm	
	۶	۰٫۸۴	۳٫۵۵cm	
	۷	۰٫۸۴	۳٫۴۶cm	
	۸	۰٫۸۵	۳٫۶۲cm	
	۹	۰٫۸۵	۳٫۴۱cm	
	۱۰	۰٫۸۳	۳٫۵۶cm	
	مقاومت فشاری ۲۸ روزه	۵	۱٫۰۰	۰٫۲۳MPa
		۶	۱٫۰۰	۰٫۳۵MPa
		۷	۱٫۰۰	۰٫۱۵MPa
		۸	۱٫۰۰	۰٫۰۹MPa
۹		۱٫۰۰	۰٫۳۹MPa	
۱۰		۱٫۰۰	۰٫۲۹MPa	



الف) معماری شبکه‌ی آبخاری تغذیه‌ی رو به جلو برای مقاومت فشاری ۲۸ روزه؛



ب) معماری شبکه‌ی آبخاری رو به جلو برای اسلامپ و مقاومت فشاری ۲۸ روزه.

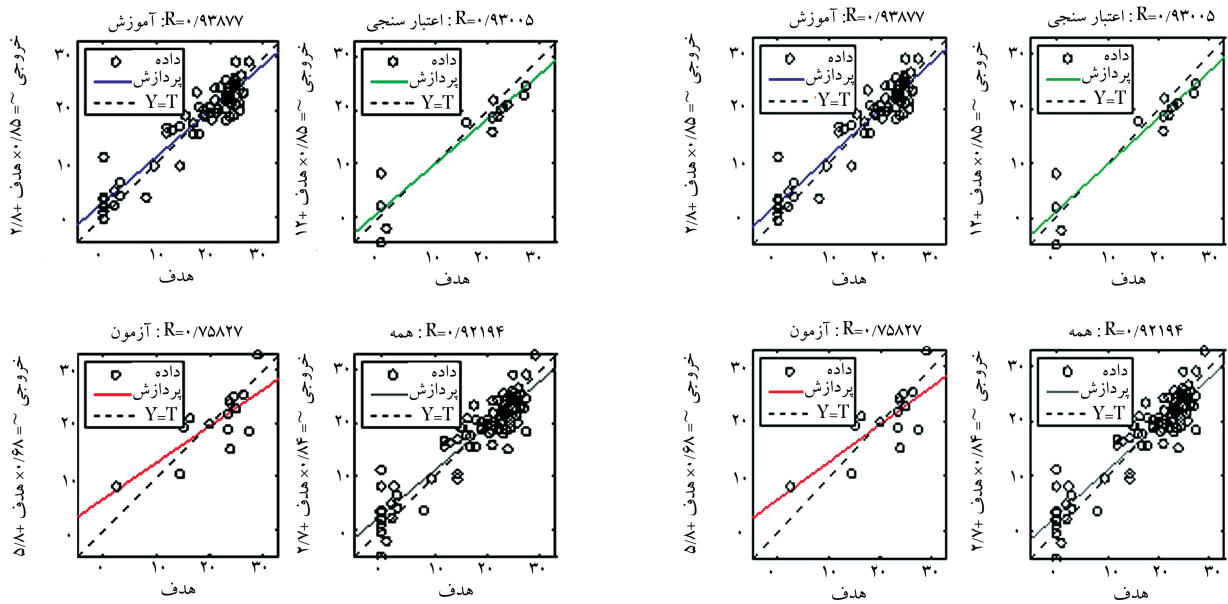
شکل ۳. معماری شبکه‌ی عصبی بهینه‌ی طراحی شده برای مدل‌ها.

شده‌اند، به‌عنوان مدل نهایی در نظر گرفته شده‌اند. شبکه‌ی عصبی مصنوعی تغذیه‌ی رو به جلو در مجموعه‌ی داده‌ی اسلامپ به ازا ۹ نرون و مقاومت فشاری ۲۸ روزه به ازا ۸ نرون بهترین پاسخ را تولید کرده است. همچنین شبکه‌ی عصبی مصنوعی آبخاری رو به جلو در مجموعه‌ی داده‌ی اسلامپ و مجموعه‌ی داده‌ی مقاومت فشاری ۲۸ روزه به ازا ۹ نرون، بهترین پاسخ را تولید کرده است. در شکل ۳، طرح کلی معماری شبکه‌های بهینه طراحی شده برای مدل‌ها ارائه شده است، که در آن W بیانگر وزن‌ها و b بیانگر بایاس است. مثلاً در شکل‌های ۴ و ۵، نمودارهای عملکرد شبکه‌ی بهینه‌ی طراحی شده برای مجموع داده‌های اسلامپ و مقاومت فشاری ۲۸ روزهی بتن ارائه شده است. نمودارها شامل موارد زیر است:

- شکل الف: نمودار رگرسیون (مقدار R) داده‌های آموزش، داده‌های اعتبارسنجی، داده‌های آزمون و تمامی داده‌ها.
- شکل ب: نمودار فراوانی خطای داده‌های آموزش، داده‌های اعتبارسنجی و داده‌های آزمون.


جدول ۳، مشخصات کلی ساختار شبکه‌های طراحی شده ارائه شده است. در تمامی مدل‌های ایجاد شده، کلیه پارامترهای شبکه ثابت بوده و فقط به منظور دستیابی به بهترین مدل، مقدار نرون‌های لایه‌ی میانی از ۵ تا ۱۰ تغییر داده شده است.

در جدول‌های ۴ و ۵، نتایج مدل‌سازی شبکه‌ی عصبی مصنوعی تغذیه‌ی رو به جلو و آبخاری رو به جلو برای پیش‌بینی مقادیر اسلامپ و مقاومت فشاری ۲۸ روزه به ازا مقادیر مختلف نرون‌های لایه‌ی میانی (از ۵ تا ۱۰) ارائه شده است. در جدول‌های مذکور، بهترین مدل تهیه شده با رنگ تیره‌تر از سایر مدل‌ها جدا شده است. هر چه مقدار پارامتر R^2 به ۱ و $RMSE$ به ۰ نزدیک‌تر باشد، عملکرد شبکه‌ی طراحی شده بهتر خواهد بود. برای کسب مطلوب‌ترین مدل به ازا هر نرون، شبکه چندین بار تحت پارامترهای مختلف مورد آموزش و یادگیری قرار گرفته و در نهایت، مناسب‌ترین پارامترها که منجر به بهترین پاسخ از سوی شبکه




الف) ضریب رگرسیون داده های آموزش، داده های اعتبار سنجی و داده های آزمون و تمامی داده ها برای مدل مقاومت فشاری ۲۸ روزه؛

الف) ضریب رگرسیون داده های آموزش، داده های اعتبار سنجی، داده های آزمون و تمامی داده ها برای مدل اسلامپ؛



ب) نمودار فراوانی خطای داده های آموزش، داده های اعتبار سنجی و داده های آزمون برای مدل مقاومت فشاری ۲۸ روزه.



ب) نمودار فراوانی خطای داده های آزمون، داده های اعتبار سنجی و داده های آزمون برای مدل اسلامپ.

شکل ۵. نمودار ضریب رگرسیون و فراوانی خطا مدل مقاومت فشاری تهیه شده توسط شبکه‌ی عصبی مصنوعی آبخاری رو به جلو.

شکل ۴. نمودار ضریب رگرسیون و فراوانی خطا مدل اسلامپ توسط شبکه‌ی عصبی مصنوعی تغذیه‌ی رو به جلو.

همچنین به‌عنوان نمونه در شکل ۶، نمودار مقادیر واقعی (حاصل شده در آزمایشگاه) اسلامپ و مقاومت فشاری ۲۸ روزه با مقادیر پیش‌بینی شده با شبکه‌های عصبی نشان داده شده است. برای نمایش بهتر تفاوت میان مقادیر، داده‌ها به صورت صعودی مرتب شده‌اند. مطابق شکل مذکور، اختلاف مقادیر واقعی با مقادیر پیش‌بینی شده برای مدل مقاومت فشاری ناچیز است. اما در مدل تهیه شده برای اسلامپ، این تفاوت بیشتر است.


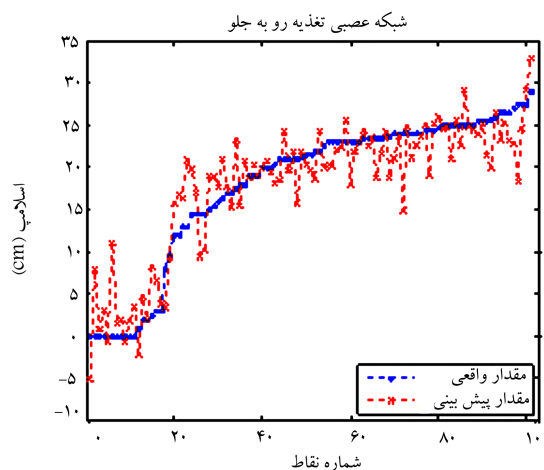
۳.۳. مدل‌سازی با استفاده از رگرسیون خطی چندگانه‌ی هم‌زمان و قدم به قدم
برای مدل‌سازی اسلامپ و مقاومت فشاری ۲۸ روزه با استفاده از مدل رگرسیون

پرت مجموعه‌ی داده‌ها حذف شوند که در پژوهش حاضر داده‌های کاندیدای پرت، شناسایی و حذف شده‌اند. در روش رگرسیون خطی چندگانه‌ی قدم به قدم برخلاف روش رگرسیون هم‌زمان، فقط می‌توان از الگوریتم کمینه‌ی مربعات استفاده کرد و الگوریتم Robust قابل به‌کارگیری نیست. بنابراین نتایج فقط با استفاده از روش کمینه‌ی مربعات ارائه شده است. نتایج عملکرد روش معادلات رگرسیون خطی قدم به قدم حاصل شده از الگوریتم کمینه‌ی مربعات برای اسلامپ و مقاومت فشاری ۲۸ روزه در جدول ۶ ارائه شده است.

۴.۳. مقایسه‌ی مدل‌ها

در جدول ۶، عملکرد روش‌های شبکه‌ی عصبی مصنوعی و رگرسیون خطی چندگانه روی مجموعه‌ی داده‌های مورد بحث مقایسه شده است. در جدول مذکور، نتایج بر حسب بهترین عملکرد مرتب شده‌اند. با توجه به نتایج جدول ۶ می‌توان گفت در حالت کلی، شبکه‌ی عصبی مصنوعی عملکرد بهتری نسبت به روش رگرسیون خطی چندگانه داشته است. بهترین عملکرد مربوط به روش شبکه‌ی عصبی مصنوعی آبخاری رو به جلو و ضعیف‌ترین عملکرد مربوط به روش رگرسیون خطی هم‌زمان با الگوریتم کمینه‌ی مربعات بوده است. از میان مدل‌های رگرسیونی، رگرسیون خطی قدم به قدم بهترین عملکرد را داشته و توانسته است مدل‌ها را با دقت بهتری ایجاد کند. عملکرد رگرسیون خطی هم‌زمان با الگوریتم Robust از عملکرد رگرسیون خطی هم‌زمان با الگوریتم کمینه‌ی مربعات بهتر بوده است. علت آن است که الگوریتم Robust در مدل رگرسیون، کمتر از الگوریتم کمینه‌ی مربعات تحت تأثیر داده‌های پرت قرار می‌گیرد. در مجموع تمامی روش‌ها توانسته‌اند با دقت بهتری مقاومت فشاری ۲۸ روزه را نسبت به اسلامپ مدل‌سازی کنند. علت برآزش بهتر داده‌های مقاومت فشاری نسبت به داده‌های اسلامپ آن است که مقادیر مقاومت فشاری توسط دستگاه به‌دست آمده و میزان خطاهای انسانی در آن کمتر از داده‌های اسلامپ بوده است که اندازه‌گیری دستی در آن دخالت دارد. به دلایل مختلف، اندازه‌گیری دستی سبب بروز داده‌های پرت در مقادیر اندازه‌گیری شده می‌شود. وجود داده‌های پرت منجر به تولید مدل‌های با دقت کمتر می‌شود. مثلاً در شکل ۷، نمودار احتمال نرمال مقادیر باقی‌مانده‌ی محاسبه‌شده با استفاده از روش رگرسیون خطی هم‌زمان با الگوریتم کمینه‌ی مربعات برای مقادیر اسلامپ و مقادیر مقاومت فشاری ۲۸ روزه ارائه شده است. هر چه داده‌ها به خط راست نزدیک‌تر باشند، به این معناست که بیشتر داده‌های مجموعه‌ی داده‌ها از الگوی نرمال تبعیت کرده‌اند و در نتیجه تعداد داده‌های پرت در آنها کمتر بوده است. مطابق شکل ۷، مقادیر باقی‌مانده‌ی محاسبه‌شده برای مقاومت فشاری ۲۸ روزه نسبت به مقادیر باقی‌مانده‌ی اسلامپ به خط راست نزدیک‌تر هستند، به همین دلیل مدل‌ها توانسته‌اند برآزش بهتری از مجموعه‌ی داده‌ها مقاومت فشاری ۲۸ روزه ارائه دهند.

در پژوهشی در سال ۲۰۰۷ که روی داده‌های اسلامپ همین آزمایش انجام شده است، با استفاده از شبکه‌های عصبی مصنوعی مدلی برای پیش‌بینی مقدار اسلامپ ایجاد کرده‌اند، که خصوصیات آن به این شرح است: تعداد لایه‌های نهان: ۱، تعداد نرون‌های لایه‌ی نهان: ۷، نرخ یادگیری: ۱، ضریب مومنتوم: ۰/۵، چرخه‌ی یادگیری: ۲۰۰۰، مقدار مجذور ضریب هم‌بستگی حاصل‌شده در پژوهش مذکور برابر ۰/۷۲ و مقدار جذر میانگین مربعات خطا برابر ۸/۵۲ سانتی‌متر بوده است. این اعداد نشان می‌دهند که مدل مذکور در مقایسه با مدل تهیه‌شده در پژوهش حاضر، کارایی کمتری دارد. در نتیجه یکی از نقاط قوت پژوهش حاضر، تهیه‌ی یک مدل



شکل ۶. مقادیر واقعی (آزمایشگاهی) و پیش‌بینی شده‌ی اسلامپ و مقاومت فشاری ۲۸ روزه توسط شبکه‌های عصبی تهیه شده.

عملکرد روش رگرسیون خطی هم‌زمان حاصل شده از الگوریتم کمینه‌ی مربعات و الگوریتم Robust برای اسلامپ و مقاومت فشاری ۲۸ روزه در جدول ۶ ارائه شده است. همچنین به‌عنوان مثال در جدول ۷، جزئیات معادله‌ی رگرسیون خطی حاصل شده برای اسلامپ با استفاده از الگوریتم کمینه‌ی مربعات ذکر شده است، که مطابق آن: SP, Water, Flyash, Slag, Cement, Intercept, CoarseAggr و FineAggr به ترتیب بیانگر متغیرهای عرض از مبدأ، سیمان، خاکستر بادی، سرباره‌ی کوره‌ی آهن‌گدازی، آب، فوق روان‌کننده، ریزدانه و درشت‌دانه در رابطه‌ی حاصل شده از مدل رگرسیون هستند. این رابطه به شکل رابطه‌ی ۱۳ است:

$$y = -52,508 - 0,0077691\text{Cement} - 0,03358\text{Slag} - 0,0057464\text{Flyash} + 0,24286\text{Water} - 0,2786\text{VSP} + 0,01311\text{CoarseAggr} + 0,025489\text{FineAggr} \quad (13)$$

مقدار p با استفاده از آزمون آماری t با فرض نرمال بودن خطاها حاصل شده است. متغیرهایی که مقدار p محاسبه شده برای آنها از سایرین بیشتر باشد، اثرگذاری کمتری در متغیر وابسته دارند. قبل از استفاده از روش رگرسیون خطی چندگانه‌ی قدم به قدم به قدم نیاز است داده‌های

جدول ۶. مقایسه‌ی عملکرد روش‌های مورد بحث روی مجموعه‌ی داده‌ها.

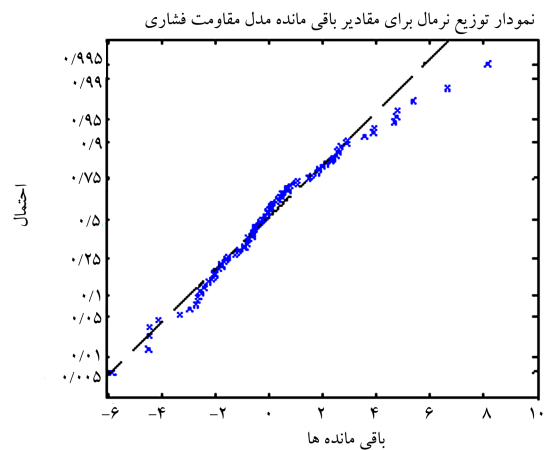

نام مجموعه‌ی داده	روش	مجدور ضریب همبستگی	جذر میانگین مربعات خطا
اسلامپ	شبکه‌ی عصبی آبخاری رو به جلو	۰٫۹۱	۲٫۷۲cm
	شبکه‌ی عصبی تغذیه‌ی رو به جلو	۰٫۸۵	۳٫۴۱ cm
	رگرسیون خطی قدم به قدم	۰٫۵۶	۶٫۱۹cm
	رگرسیون خطی هم‌زمان با الگوریتم Robust	۰٫۳۴	۷٫۷۴cm
	رگرسیون خطی هم‌زمان با الگوریتم کمینه‌ی مربعات	۰٫۳۲	۷٫۳۰cm
مقاومت فشاری ۲۸ روزه	شبکه‌ی عصبی آبخاری رو به جلو	۱٫۰۰	۰٫۰۷MPa
	شبکه‌ی عصبی تغذیه‌ی رو به جلو	۱٫۰۰	۰٫۰۹MPa
	رگرسیون خطی قدم به قدم	۰٫۹۹	۰٫۶۱MPa
	رگرسیون خطی هم‌زمان با الگوریتم Robust	۰٫۹۱	۲٫۴۱MPa
	رگرسیون خطی هم‌زمان با الگوریتم کمینه‌ی مربعات	۰٫۹۰	۲٫۵۰MPa

جدول ۷. مشخصات معادله‌ی رگرسیون خطی هم‌زمان حاصل شده برای اسلامپ با استفاده از الگوریتم کمینه‌ی مربعات.

نام متغیر	مقدار ضریب متغیر	مقدار P
Intercept	-۵۲٫۵۰۸۰	۰٫۷۹۳۱۰
Cement	-۰٫۰۰۷۷۶۹۱	۰٫۹۰۴۰۸
Slag	-۰٫۰۳۳۵۸۷	۰٫۷۰۸۰۴
Flyash	-۰٫۰۰۵۷۴۶۴	۰٫۹۲۹۷۶
Water	۰٫۲۴۲۸۶۰	۰٫۲۲۹۹۳
SP	-۰٫۲۷۸۶۷۰	۰٫۴۶۳۳۸
CoarseAggr	۰٫۰۱۳۱۱۰	۰٫۸۶۵۴۱
FineAggr	۰٫۰۲۵۴۸۹	۰٫۷۵۳۲۲

۴. نتیجه‌گیری

با توجه به خصوصیات فیزیکی و ترکیبات شیمیایی متنوعی که اجزاء بتن توانمند را شکل می‌دهند، معمولاً ارائه‌ی مدلی که بتواند دقیقاً مشخصات بتن توانمند را پیش‌بینی کند، دشوار است. در پژوهش حاضر با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون خطی چندگانه، مدل‌هایی برای پیش‌بینی اسلامپ و مقاومت فشاری ۲۸ روزهی بتن توانمند تهیه شده است. از میان مدل‌های ایجاد شده، روش شبکه‌ی عصبی مصنوعی آبخاری رو به جلو بهترین عملکرد را داشته است. این روش توانسته است با دقت خوبی رابطه‌ی بین ورودی‌ها و خروجی‌ها را تخمین بزند. در مجموع عملکرد روش رگرسیون خطی چندگانه رضایت‌بخش نبوده و نتوانسته است مدل قابل قبولی ارائه دهد. معمولاً در مسائل چندمتغیره، روش‌های کلاسیک آماری عملکرد ضعیف‌تری نسبت به روش‌های جدید مبتنی بر محاسبات نرم دارند. به همین دلیل پیشنهاد می‌شود در مسائل مربوط به پیش‌بینی مشخصه‌های مصالح و موضوعات مرتبط، که از طریق مطالعات آزمایشگاهی انجام



شکل ۷. نمودار احتمال نرمال مقادیر باقی مانده.

بهینه‌تر برای پیش‌بینی مقدار اسلامپ بتن توانمند است. پس از ایجاد مدل برای هر مشخصه، می‌توان از آن برای پیش‌بینی مقادیر سایر ترکیبات استفاده کرد، در نتیجه منجر به صرفه‌جویی در هزینه‌ها و زمان می‌شود و در مواقعی که فقط اطلاعات مربوط به میزان ترکیبات مخلوط در دسترس باشد، می‌توان بدون صرف هزینه و در کمترین زمان ممکن، مشخصات بتن را با دقت خوبی سنجید.

منظور مدل‌سازی رفتار پیچیده‌ی مصالح در زمانی که فقط تعداد کمی از داده‌های آزمایشگاهی در دسترس است، استفاده کرد و سبب صرفه‌جویی در هزینه‌ها شد.

و در آن‌ها حجم زیادی از داده‌های چندمتغیره برداشت می‌شود، از روش‌های مبتنی بر محاسبات نرم مانند: شبکه‌های عصبی مصنوعی، درخت‌های تصمیم و مدل‌های ترکیبی استفاده کرد. روش ارائه‌شده در پژوهش حاضر را می‌توان به

پانوشته‌ها

1. high performance concrete (HPC)
2. genetically evolved artificial neural networks (GEANN)
3. bias
4. pruning factor (Pf)
5. feed-forward back propagation
6. cascade-forward neural network
7. target value
8. sigmoid
9. likelihood

منابع (References)

1. Aitcin, P.C. and Neville, A. "High-performance concrete demystified", *Concrete international*, pp. 21-26 (1993).
2. Nawy, E.G., *Fundamentals of High-Performance Concrete*, 2nd Edition, John Wiley & Sons, pp. 123-136 (2001).
3. Neville, A. and Aitcin, P.C. "High performance concrete-an overview", *Materials and Structures*, **31**(2), pp. 111-117 (1998).
4. Brown, D.A., Murthy, P.L.N. and Berke, L. "Computational simulation of composite ply micromechanics using artificial neural networks", *Microcomput Civil Eng.*, **6**(2), pp. 87-97 (1991).
5. Ghaboussi, J., Garrett, J.H. and Wu, X. "Knowledge-based modeling of material behaviour with neural networks", *Journal of Eng. Mech.*, **117**(1), pp. 129-34 (1991).
6. Yeh, I-C. "Modeling slump flow of concrete using second-order regressions and artificial neural networks", *Cement & Concrete Composites*, **29**(6), pp. 474-480 (2007).
7. Kasperkiewicz, J., Racz, J. and Dubrawski, A. "HPC strength prediction using artificial neural network", *Journal of Comput Civil Eng.*, **9**(4), pp. 279-84 (1995).
8. Yeh, I-C. "Design of high performance concrete mixture using neural networks", *Journal of Computing Civil Eng.*, **13**(1), pp. 36-42 (1999).
9. Yeh, I-C. "Modeling concrete strength with augment-neuron networks", *Journal of Materials Civil Eng.*, **10**(4), pp. 263-268 (1998).
10. Nehdi, M., El Chabib, H. and El Naggar, M.H. "Predicting performance of self-compacting concrete mixtures using artificial neural networks", *ACI Materials Journal*, **98**(5), pp. 394-401 (2001).
11. Bai, J., Wild, S., Ware, J.A. and Sabir, B.B. "Using neural networks to predict workability of concrete incorporating metakaolin and fly ash", *Adv Eng. Software*, **34**(11-12), pp. 663-669 (2003).
12. Ji, T., Lin, T. and Lin, X. "A concrete mix proportion design algorithm based on artificial neural networks", *Cem. Concr. Res.*, **36**(7), pp. 1399-408 (2006).
13. Yeh, I-C. "Exploring concrete slump model using artificial neural networks", *Journal of Comput. Civil Eng.*, **20**(3), pp. 217-221 (2006).
14. Jain, A., Jha, S. and Misra, S. "Modeling and analysis of concrete slump using artificial neural networks", *J. Materials Civil Eng.*, **20**(9), pp. 628-633 (2008).
15. Tang, C. "Radial basis function neural network models for peak stress and strain in plain concrete under triaxial stress", *Journal of Materials in Civil Engineering*, pp. 923-934 (2009).
16. Chandwani, V., Agrawal, V. and Nagar, R. "Modeling slump of ready mix concrete using genetically evolved artificial neural networks", *Advances in Artificial Neural Systems*, pp. 1-9 (2014).
17. Deshpande, N., Londhe, S. and Kulkarni, S. "Modeling compressive strength of recycled aggregate concrete by artificial neural network, model tree and non-linear regression", *International Journal of Sustainable Built Environment*, **3**(2), pp. 187-198 (2014).
18. Chandwani, V., Agrawal, V. and Nagar, R. "Modeling slump of ready mix concrete using genetic algorithms assisted training of artificial neural networks", *Expert Systems with Applications*, **42**(2), pp. 885-893 (2015).
19. <https://archive.ics.uci.edu/ml/datasets.html>
20. Yeh, I-C. "Modeling slump flow of concrete using second-order regressions and artificial neural networks", *Cement & Concrete Composites*, **29**(6), pp. 474-480 (2007).
21. Hawkins, D., *Identification of Outliers*, Chapman and Hall (1980).
22. Agyemang, M. and Ezeife, C.I. "LSCMine: Algorithm for mining local outliers", *15th Information Resources Management Association (IRMA) International Conference*, New Orleans, Louisiana, USA, pp. 23-26 (2004).

23. Mahmoodi, K., Rostami, H., Sayehbani, M. and Moradi, A. "A review of data mining and its applications in the offshore industry", *5th Offshore Industries Conference*, Tehran, Sharif University of Technology (2013).
24. *Two Crows Corporation, Introduction to Data Mining and Knowledge Discovery*, 3ed Edition, Massachusetts Institute of Technology (1999).
25. Edelstein, H. A, "Introduction to Data Mining and Knowledge Discovery, Two Crows Corporation", 3rd Edition, Massachusetts, Institute of Technology (1999).
26. Draper, N.R. and Smith, H., *Applied Regression Analysis*, Hoboken, NJ: Wiley-Interscience, 736 p. (1998)