

## مدل‌سازی مقاومت فشاری بتن غلتکی با استفاده از شبکه عصبی مصنوعی، انفیس و

### ماشین بردار پشتیبان

محمد عمدی، کارشناسی ارشد سازه، دانشگاه تحصیلات تکمیلی و فناوری پیشرفته کرمان  
سید حسام مدنی\*، عضو هیئت علمی، دانشکده عمران و نقشه‌برداری، دانشگاه تحصیلات تکمیلی و  
فناوری پیشرفته کرمان

Email: h.madani@kgut.ac.ir

دریافت: ۹۵/۱۰/۰۷ - پذیرش: ۹۶/۰۶/۱۹

### چکیده

امروزه از بتن غلتکی در ساخت سدها و روسازی راه‌ها استفاده می‌شود و طی سال‌های اخیر استفاده از این نوع بتن به علت مزایایی چون کوتاه شدن زمان ساخت، در دسترس بودن مصالح مورد نیاز، عملکرد مناسب در نواحی سرد و عمر مفید طولانی گسترش یافته است. مهم‌ترین خاصیت مکانیکی بتن غلتکی، مقاومت فشاری می‌باشد که افزایش آن می‌تواند عملکرد این نوع بتن را بهبود بخشد. حساسیت بتن غلتکی به اجزای تشکیل‌دهنده آن سبب مشکلاتی در پیش‌بینی مقاومت فشاری شده است. پارامترهایی نظیر مقدار سیمان، نسبت آب به مواد سیمانی، مقدار مواد سیمانی جایگزین و نسبت درشت‌دانه به ریزدانه اثر زیادی بر مقاومت فشاری بتن غلتکی دارند. در دهه‌های اخیر، مدل‌سازی به‌وسیله هوش مصنوعی، جایگاه ویژه‌ای در علوم فنی و مهندسی پیدا کرده است و پیش‌بینی رفتار موادی که با پیچیدگی‌های فراوانی روبه‌رو بوده، تا حدودی به کمک این روش میسر شده است. در این تحقیق، مجموعه‌ای از طرح‌های اختلاط ساخته شده توسط مؤلفین و طرح‌های اختلاط ساخته شده در مطالعات دیگر جمع‌آوری گردید. با در نظر گرفتن اجزای طرح اختلاط و سن نمونه‌ها به‌عنوان متغیرهای ورودی، مدل‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی عصبی تطبیقی و ماشین‌های بردار پشتیبان برای پیش‌بینی مقاومت فشاری ساخته شدند. مقایسه نتایج نشانگر این است که مدل شبکه عصبی مصنوعی توانایی بیشتری نسبت به مدل‌های سیستم استنتاج فازی عصبی تطبیقی و ماشین بردار پشتیبان در پیش‌بینی مقاومت فشاری بتن غلتکی دارد. همچنین، مقاومت‌های تخمین زده شده توسط شبکه عصبی مصنوعی و ماشین بردار پشتیبان به ترتیب بیشترین و کمترین تطابق را با مقاومت فشاری واقعی دارند. مقدار ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین خطای مطلق شبکه عصبی مصنوعی به ترتیب برابر با ۰/۹۷۱۷، ۲/۴۸۵۹ و ۲/۱۳۹۶ است. این مقادیر برای ماشین بردار پشتیبان به ترتیب برابر ۰/۹۵۶۶، ۳/۴۰۱۳ و ۳/۰۷۳۳ می‌باشند.

واژه‌های کلیدی: روسازی راه، مدل‌سازی، هوش مصنوعی، سیستم استنتاج فازی عصبی تطبیقی

## ۱. مقدمه

اکنون، مدل‌سازی مقاومت فشاری بتن غلتکی به‌وسیله مدل‌های هوش مصنوعی مانند شبکه عصبی مصنوعی، سیستم استنتاج فازی عصبی تطبیقی و ماشین‌های بردار پشتیبان و ارزیابی و مقایسه عملکرد این مدل‌ها گامی مهم در توسعه این علم می‌باشد.

اکثر روش‌های طراحی مخلوط بتن غلتکی نیاز به ساخت نمونه‌های اولیه و آزمایشی برای تعیین بهترین طرح مخلوط دارند که علاوه بر صرف هزینه و اتلاف مصالح، بسیار زمان‌بر هستند زیرا که معمولاً لازم است خواص مقاومتی نمونه‌ها در سن ۲۸ روز مورد بررسی قرار گیرد. حال اگر در حین انجام پروژه ناگزیر منبع مصالح مورد استفاده دچار تغییر شود روند انجام پروژه با مشکل روبه‌رو می‌شود. علاوه بر مشکل ذکر شده، طراح بتن غلتکی با روش‌های تجربی، استفاده از منابع خام که برای تعیین نسبت‌های بهینه طرح مخلوط مصرف می‌شود قطعاً به محیط‌زیست آسیب می‌رساند و در راستای توسعه پایدار نخواهد بود.

برای رفع این مشکل، استفاده از هوش مصنوعی برای پیش‌بینی مقاومت فشاری نه‌تنها بتن غلتکی بلکه تمامی انواع بتن می‌تواند گزینه مناسبی باشد. پیش‌بینی خواص مکانیکی بتن به‌وسیله روش‌هایی چون شبکه عصبی مصنوعی، انفیس و ماشین بردار پشتیبان با موفقیت انجام گرفته است (عمادی و مدنی، ۱۳۹۵؛ صدیق و همکاران، ۲۰۱۱؛ صدرممتازی و همکاران، ۲۰۱۳؛ تروکولی و همکاران، ۲۰۱۳؛ صدوقی یزدی و همکاران، ۲۰۱۳). از جمله مزایای این روش‌ها، پیش‌بینی مقاومت فشاری در سن مورد نظر با نسبت‌های متفاوت طرح اختلاط تنها در چند ساعت است؛ که علاوه بر صرفه‌جویی در مصالح، سبب استفاده درست از زمان، که پارامتری شاخص در انجام پروژه‌ها است، می‌شود.

سبحانی و همکاران (۲۰۱۰) برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بدون اسلامپ از مدل‌های رگرسیون، شبکه عصبی مصنوعی و سیستم استنتاج فازی

بتن غلتکی روسازی راه عبارت است از مخلوط سفت و نسبتاً خشکی از سنگ‌دانه با اندازه حداکثر ۱۹ میلی‌متر، مواد سیمانی و آب که توسط دستگاه‌های متداول روسازی آسفالتی پخش و پس از آن توسط غلتک ویرهای کوبیده و متراکم می‌گردد. مواد تشکیل‌دهنده بتن غلتکی در داخل مخلوط‌کن به یک مخلوط همگن تبدیل می‌شود و دارای کارایی و ظاهری مشابه مخلوط شن نم دار و یا بتن با اسلامپ صفر می‌گردد. پس از تراکم، عملیات عمل‌آوری و مرطوب نگه‌داشتن سطح بتن آغاز می‌گردد تا امکان دستیابی به روسازی با سطح سخت و بادوام فراهم آید (راهنمای طراحی و اجرای بتن غلتکی در روسازی راه‌های کشور، ۱۳۸۸).

گان (۱۹۹۹) رویه بتن غلتکی روسازی راه را شکل تحول‌یافته فناوری بتن غلتکی که در سدها استفاده می‌شود دانست؛ بتن‌هایی بدون اسلامپ که با اضافه کردن کمی خمیر سیمان به مخلوط ریزدانه و درشت‌دانه حاصل می‌گردد. بتن غلتکی روسازی با بیشینه اندازه سنگ‌دانه کوچک‌تر، خمیر سیمان باکیفیت‌تر و با نسبت آب به مواد سیمانی کمتر ساخته می‌شود.

حساسیت بتن غلتکی به اجزای تشکیل‌دهنده و طرح مخلوط سبب مشکلاتی در پیش‌بینی مقاومت فشاری شده است. امروزه، مدل‌سازی به کمک هوش مصنوعی جایگاه ویژه‌ای در علوم فنی و مهندسی پیدا کرده است و مدل‌سازی رفتار مواد که با پیچیدگی‌های فراوانی روبه‌رو بوده تا حدودی به کمک این روش میسر شده است. محققین بسیاری توسط روش‌های مختلف ریاضی، مدل‌های ارزشمندی را در زمینه تخمین رفتار بتن ارائه نموده‌اند که در گذشته این فنون بیشتر بر پایه رگرسیون‌های خطی و غیرخطی استوار بوده‌اند. امروزه، روش‌های بر پایه هوش مصنوعی مانند منطق فازی و شبکه‌های عصبی مصنوعی در این زمینه با موفقیت مورد استفاده قرار گرفته‌اند (عمادی و مدنی، ۱۳۹۵).

انفیس و شبکه عصبی بهتر و دقیق‌تر از نتایج حاصل از فرمول‌های آیین‌نامه بوده است. بعلاوه، پیش‌بینی‌های مدل شبکه عصبی مصنوعی نزدیک به نتایج آزمایشگاهی بوده، در حالی که نتایج حاصل از فرمول‌های آیین‌نامه‌ها پراکنده‌تر از نتایج آزمایشگاهی بودند.

نی و وانگ (۲۰۰۰) در تحقیق خود برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن، از شبکه عصبی مصنوعی استفاده کرده‌اند. طرح‌های اختلاط به‌کار گرفته شده در این تحقیق از دو بخش تشکیل شده، که بخش اول توسط محققین و بخش دوم از کارگاه ساخت بتن در شهر پکن گرفته شده است. به‌طور کلی، ۱۶۵ طرح اختلاط برای آموزش و آزمایش شبکه عصبی مصنوعی استفاده شده است. شبکه عصبی مصنوعی از یک لایه پنهان که دارای ۷ عصب می‌باشد تشکیل شده است. ایشان بیان می‌دارند که مدل‌های شبکه عصبی آموزش دیده می‌توانند برای شبیه‌سازی تأثیر برخی پارامترها بر مقاومت فشاری استفاده شوند و روابط بین برخی پارامترها و مقاومت را به دست آورده‌اند. مدل‌های شبکه عصبی ساخته شده می‌توانند مقاومت فشاری ۲۸ روزه بتن را بر مبنای فاکتورهای تأثیرگذار بر آن پیش‌بینی کنند. این روش محاسباتی هوشمند می‌تواند برای مهندسین عمران و کارگاه‌های ساخت بتن مفید واقع شود. مدل‌های شبکه عصبی مصنوعی دقت خوبی در پیش‌بینی داشته‌اند و عملکرد این مدل‌ها در پیش‌بینی مقاومت بتن مناسب بوده است.

صدرممتازی و همکاران (۲۰۱۳) برای مدل‌سازی مقاومت فشاری بتن سبک حاوی دانه‌های منبسط‌شده پلی‌استایرن از آنالیز رگرسیون، شبکه عصبی مصنوعی و انفیس استفاده کرده‌اند. تعداد کل طرح‌های اختلاط به‌کار گرفته شده در این تحقیق ۷۵ عدد می‌باشد که ۶۴ عدد برای آموزش و ۱۱ عدد برای آزمایش شبکه‌ها استفاده شده است. برای جلوگیری از به وجود آمدن خطا در آموزش شبکه تمامی داده‌ها استفاده شده‌اند و ۱۰ طرح

عصبی تطبیقی (انفیس) استفاده کرده‌اند. تعداد کل داده‌های جمع‌آوری شده ۹۶ مورد بود که ۷۹ عدد برای آموزش و ۱۷ عدد برای آزمایش مدل‌ها اختصاص یافته‌اند. همچنین، دو معیار جذر متوسط مربعات خطا و ضریب همبستگی برای ارزیابی عملکرد هر مدل به‌کار گرفته شده است. برای ساخت مدل انفیس از ۵ تابع عضویت استفاده شده است. این توابع شامل تابع عضویت مثلثی، دوزنقه‌ای، زنگوله شکل، گوسی و پای شکل (Π) می‌باشند. در نتیجه‌گیری تحقیق بیان شده که مدل‌های شبکه عصبی و انفیس عملکرد بهتری نسبت به مدل رگرسیون داشته‌اند. مدل شبکه عصبی که با الگوریتم پس انتشار لونبرگ-مارکوارد آموزش داده شده بود و به ترتیب دارای ۵ و ۴ عصب در لایه اول و دوم بود نیاز به تکرار کمتری برای رسیدن به خطای مورد قبول داشت. تمامی مدل‌های انفیس ساخته شده عملکرد قابل قبولی از خود ارائه دادند و مدل انفیسی که دارای تابع عضویت گوسی بوده بهترین عملکرد را از خود نشان داد. در بین مدل‌های رگرسیون، مدل با تابع چندجمله‌ای درجه دو بهترین عملکرد را داشته است.

امانی و معینی (۲۰۱۲) برای پیش‌بینی مقاومت برشی تیرهای بتنی مسلح از سیستم استنتاج فازی عصبی تطبیقی و شبکه عصبی مصنوعی استفاده کرده‌اند. برای بررسی دقت پیش‌بینی، مدل‌ها با فرمول‌های تجربی بیان‌شده در آیین‌نامه بتن ایران و آمریکا برای محاسبه مقاومت برشی تیر مقایسه شده‌اند. تعداد کل داده‌ها ۱۲۳ عدد بوده که ۱۰۰ داده را برای آموزش و ۲۳ داده را برای آزمایش مدل‌های شبکه عصبی مصنوعی و انفیس اختصاص داده‌اند. نوزده مدل شبکه عصبی مصنوعی با یک لایه پنهان و تعداد عصب‌های متغیر بین ۲-۲۰ تشکیل شد و مدلی که کمترین میزان خطا را داشت به‌عنوان نماینده شبکه عصبی برای مقایسه با سایر مدل‌ها انتخاب شد. بررسی نتایج نشان‌دهنده این مسئله بود که عملکرد مدل شبکه عصبی بهتر از مدل انفیس و عملکرد مدل‌های

تعداد کم مشاهدات برای کامل کردن اطلاعات مدل پیش‌بینی کننده باشد.

تروکولی و همکاران (۲۰۱۳) در مطالعه خود به پیش‌بینی مقاومت فشاری بتن حاوی ضایعات ساختمانی به وسیله شبکه عصبی مصنوعی پرداختند. ایشان طرح‌های اختلاط مورد استفاده را از مطالعات گوناگون ۱۱۷۸ طرح جمع‌آوری کردند. نتایج بیانگر توانایی بالای شبکه عصبی در پیش‌بینی مقاومت فشاری بتن حاوی ضایعات ساختمانی است. شبکه عصبی توانایی بالایی در پیش‌بینی مقاومت فشاری در سنین مختلف از خود نشان داده است. صدیق و همکاران (۲۰۰۸) در تحقیق خود برای مدل‌سازی خواص بتن خودتراکم از روش ماشین‌های بردار پشتیبان استفاده کرده‌اند. همچنین، برای مقایسه عملکرد مدل‌های ماشین بردار پشتیبان، چندین مدل شبکه عصبی نیز ساخته شده است. برای ساخت مدل‌ها، مقاومت فشاری ۲۸ روزه و اسلامپ به‌عنوان خروجی و مقدار سیمان، ماسه، شن، نسبت آب به سیمان، فوق روان‌ساز و درصد خاکستر بادی به‌عنوان ورودی در نظر گرفته شدند. برای ساخت ماشین بردار پشتیبان از دو تابع هسته چندجمله‌ای و پایه شعاعی استفاده گردیده است. ماشین بردار پشتیبان با هسته توابع پایه شعاعی بهترین عملکرد را در پیش‌بینی مقاومت فشاری ۲۸ روزه و اسلامپ بتن خودتراکم داشته است.

فام و همکاران (۱۹۹۳) در تحقیق خود، برای پیش‌بینی مقاومت فشاری بتن توانمند از روش بردار پشتیبان بهینه شده با الگوریتم فراابتکاری استفاده کرده‌اند. داده‌های به‌کار گرفته شده از یک پروژه تحقیقاتی تهیه گردید که شامل ۲۳۹ طرح می‌شود. برای مقایسه عملکرد این روش، مدل‌های شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان نیز ساخته شده و مورد ارزیابی قرار گرفتند. شبکه عصبی مد نظر از یک لایه پنهان با هفت عصب در این لایه ساخته شده و با الگوریتم لوبنرگ-مارکوارد آموزش دیده است. مدل ابتکاری مورد استفاده در این

به‌صورت تصادفی جداگشته و برای اعتبارسنجی مدل‌ها استفاده شدند. معیارهایی که برای ارزیابی مدل‌ها در نظر گرفته شدند ضریب همبستگی و جذر میانگین مربعات خطا می‌باشد. در این مطالعه، از شبکه عصبی مصنوعی چندلایه استفاده شده است که شبکه عصبی با ۳ عصب در لایه پنهان بهترین نتایج را از خود نشان داده است. برای شکل‌دهی مدل انفیس، از توابع عضویت مختلف استفاده شده و عملکرد آن‌ها بررسی گردید؛ که در نهایت تابع عضویت زنگوله شکل بهترین نتیجه را از خود نشان داد. در مدل نهایی انفیس، برای هر ورودی سه تابع عضویت زنگوله شکل در نظر گرفته شد. در نهایت، بهترین مدل از هر روش انتخاب و با هم مقایسه شده است. بررسی نتایج نشان‌دهنده عملکرد مناسب شبکه عصبی مصنوعی و انفیس در پیش‌بینی مقاومت فشاری بتن سبک است. شبکه عصبی بهترین و مدل رگرسیون ضعیف‌ترین توانایی را در مدل‌سازی مقاومت فشاری بتن سبک از خود نشان داده‌اند.

چیترا و همکاران (۲۰۱۶) در تحقیق خود، به بررسی مقایسه‌ای مدل‌های پیش‌بینی کننده مقاومت فشاری برای بتن فوق توانمند حاوی نانوسیلیس و سرباره مس با استفاده از آنالیز رگرسیون و شبکه‌های عصبی مصنوعی پرداختند. در مجموع، ۲۶۴ طرح مخلوط که توسط نویسندگان ساخته شده است به‌عنوان اطلاعات ورودی برای پیش‌بینی مقاومت فشاری در نظر گرفته شد. اطلاعاتی که به‌عنوان ورودی مدل‌ها در نظر گرفته شد شامل مقدار سیمان، نانوسیلیس، ریزدانه، درشت‌دانه، روان‌ساز، سرباره مس، سن نمونه و مقدار آب می‌شود. سه مدل رگرسیون و سه مدل شبکه عصبی تشکیل شد که تفاوت مدل‌ها با هم در تعداد طرح مخلوط و نوع ورودی می‌باشد. برای ساخت مدل‌های شبکه عصبی، از یک لایه پنهان با ۱۰ عصب استفاده شده است. بررسی نتایج نشانگر عملکرد ضعیف مدل‌های رگرسیونی می‌باشد که دلیل آن می‌تواند

استفاده از این روش‌ها برای پیش‌بینی مقاومت فشاری بتن موفقیت‌آمیز بوده است.


## ۲. روش‌های مدل‌سازی و اطلاعات ورودی مدل‌ها

مدل را در دنیای واقعی، می‌توان نسخه کوچک‌شده یک شیء یا پدیده نامید که شباهت‌ها و حتی خصوصیات اصلی پدیده را در خود منعکس می‌کند. مدل‌ها با ساده‌سازی واقعیت و زدن شاخ و برگ‌های اضافه پدیده، کمک زیادی به شناخت بهتر پدیده و شناسایی متغیرها و اجزای مهم تشکیل دهنده پدیده می‌نمایند.

در این تحقیق، برای پیش‌بینی مقاومت فشاری بتن غلتکی از سه روش مدل‌سازی شبکه عصبی مصنوعی، سیستم استنتاج فازی عصبی (انفیس) و ماشین بردار پشتیبان استفاده شده است. لازم به ذکر است که از نرم‌افزار MATLAB R2014a برای مدل‌سازی هر سه روش استفاده گردیده است.

### ۲-۱. شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، مدلی ریاضی یا محاسباتی است که تلاش در شبیه‌سازی ساختار یا وظایف شبکه‌های عصبی بیولوژیک دارد (دوآن و همکاران، ۲۰۱۳). به عبارتی، شبکه‌های عصبی مصنوعی بر مبنای فهم کنونی از سیستم عصب‌های بیولوژیک ساخته شده‌اند، اگرچه از بسیاری خواص عصب بیولوژیک صرف‌نظر شده است (ساردمیر، ۲۰۰۹). شکل ۱، ساختار عصب بیولوژیک را نشان می‌دهد.




شکل ۱. عصب بیولوژیک (آبراهام، ۲۰۰۵)

تحقیق از ترکیب رگرسیون بردار پشتیبان و الگوریتم بهینه‌سازی کرم شب‌تاب تشکیل شده است، که الگوریتم کرم شب‌تاب به بهینه‌سازی پارامترهای مدل رگرسیون بردار پشتیبان می‌پردازد. مقایسه نتایج نشان می‌دهد که روش کمترین مربعات رگرسیون بردار پشتیبان بهینه‌شده با الگوریتم کرم شب‌تاب بهترین عملکرد را در پیش‌بینی مقاومت فشاری داشته است.

سبحانی و همکاران (۲۰۱۳) از ماشین بردار پشتیبان و شبکه عصبی برای پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بدون اسلامپ استفاده کرده‌اند. به‌طور کلی، ۹۶ طرح اختلاط برای مدل‌سازی استفاده شده است. هر دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان به‌وسیله الگوریتم ژنتیک بهینه شدند. در مدل ماشین بردار پشتیبان از هسته گوسی استفاده شده است. در این تحقیق از شبکه عصبی با دو لایه پنهان استفاده شده که در این شبکه، الگوریتم ژنتیک در دو مرحله به‌کار گرفته شده است. در مرحله اول از الگوریتم ژنتیک برای بهینه کردن ساختار شبکه (تعداد عصب) و در مرحله دوم برای بهینه کردن وزن‌های این شبکه استفاده شده است. شبکه عصبی نهایی دارای سه عصب در لایه پنهان اول و هفت عصب در لایه پنهان دوم است. نتایج نشان می‌دهد که هر دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان قابلیت مناسبی در پیش‌بینی مقاومت فشاری ۲۸ روزه بتن بدون اسلامپ دارند. اما روش ماشین بردار پشتیبان بهینه شده با الگوریتم ژنتیک به دلایلی مانند تعداد پارامترهای کمتر برای تنظیم و بهینه کردن مدل، یادگیری سریع‌تر، قدرت بیشتر و حساسیت کمتر هنگام وجود داده‌های آموزش نامناسب نسبت به شبکه عصبی مصنوعی ترجیح داده می‌شود.

مطالعه و بررسی تحقیقات صورت گرفته در زمینه استفاده از روش‌های مدل‌سازی مانند شبکه عصبی مصنوعی، انفیس و ماشین بردار پشتیبان نشان می‌دهد که

و آزمون خطا به دست می آید (أزکان و همکاران، ۲۰۰۹). برای تعیین تابع تحریک مناسب در لایه پنهان و خروجی از توابعی همچون تانژانت سیگموئیدال، لگاریتم سیگموئیدال و خطی استفاده می شود. در شکل ۳، تابع تانژانت سیگموئیدال رسم شده است.



شکل ۳. تابع تحریک تانژانت سیگموئیدال

معادله (۱) بیانگر تابع تانژانت سیگموئیدال است:

$$a = \text{tansig}(n) = \frac{2}{(1 + \exp(-2*n)) - 1} \quad (1)$$


## ۲-۲. سیستم استنتاج فازی عصبی تطبیقی (انفیس)

تئوری منطق فازی توسط لطفی زاده در سال ۱۹۶۵ مطرح شد. فایده بزرگ منطق فازی این است که می تواند به سؤالات بله-خیر پاسخ بینابینی دهد. انسان چنین کاری را همیشه انجام می دهد. مثلاً در بیان سرعت خودرو معمولاً از مقادیر کم، متوسط و زیاد به جای مقدار دقیق سرعت استفاده می کند؛ اما چنین چیزی برای کامپیوتر یک فن جدید است (أزکان و همکاران، ۲۰۰۹).

سیستم استنتاج فازی-عصبی تطبیقی توسط جانگ در سال ۱۹۹۳ ساخته شد و به عنوان یک تقریب زننده جامع به کار گرفته شد (بیلگهان، ۲۰۱۱). اگر سیستم استنتاج فازی برای مسئله ای به کار گرفته شود که دارای مجموعه ای از داده های ورودی و خروجی باشد، الزاماً نیاز نیست که ساختار فازی از پیش تعیین شده ای برای حل مسئله به کار رود. از سوی دیگر، نمی توان با بررسی اجمالی اطلاعات توابع عضویت مناسب را تشخیص داده و به ورودی ها اختصاص داد. نیاز است که پارامترهای

اولین موج توجه به شبکه های عصبی بعد از معرفی اعصاب ساده شده توسط مک کولاج و پیترز در سال ۱۹۴۳ شکل گرفت و گسترش یافت.

المان پردازشگر پایه شبکه های عصبی، عصب های مصنوعی یا گره نامیده می شوند. در مدل ریاضی ساده شده عصب، تأثیر سیناپس ها با وزن های اتصال که اثر سیگنال های ورودی را بیان می کنند ارائه می شود. همچنین، خاصیت غیرخطی یا خطی عصب ها به وسیله تابع انتقال (فعال سازی یا تحریک) نمایندگی می شود. قابلیت آموزش شبکه عصبی با تنظیم وزن ها با توجه به الگوریتم آموزش به دست می آید (بیهل، ۲۰۰۵). شکل ۲، یک عصب مصنوعی معمولی با ورودی، تابع جمع و تابع فعال سازی را نشان می دهد.




شکل ۲. ساختار عصب مصنوعی (صدرممتازی و همکاران، ۲۰۱۳)

شبکه های عصبی پیش خور مشهورترین و پرکاربردترین شبکه عصبی مصنوعی است که با نام های متفاوتی از جمله شبکه عصبی چندلایه پرسپترون شناخته شده اند. شبکه عصبی پرسپترون توسط فرانک روزنبلات در سال ۱۹۵۸ میلادی ابداع شد (فاست، ۱۹۹۴). این شبکه ها دارای سه لایه ورودی، پنهان و خروجی می باشند. در شبکه های عصبی پیش خور، سیگنال های ورودی از واحدهای ورودی به سمت واحدهای خروجی در جریان هستند. تعداد عصب های موجود در لایه ورودی و خروجی به ترتیب در ارتباط مستقیم با تعداد پارامترهای ورودی و خروجی است. برای تعیین تعداد عصب ها در لایه خروجی، قانون و اصول مدونی تاکنون طرح نشده است و این تعداد با توجه به پیچیدگی مسئله

## ۲-۳. ماشین بردار پشتیبان

ماشین بردار پشتیبان<sup>۱</sup> (SVM) یکی از روش‌های یادگیری با نظارت است که هم برای دسته‌بندی و هم رگرسیون اطلاعات قابل استفاده است. ماشین بردار پشتیبان در اصل یک دسته‌بندی کننده دو کلاسه است که کلاس‌ها را توسط یک مرز خطی از هم جدا می‌کند. در این روش، نزدیک‌ترین نمونه‌ها به مرز تصمیم‌گیری را بردارهای پشتیبان می‌نامند. این بردارها معادله مرز تصمیم‌گیری را مشخص می‌کنند. این روش به دلیل استفاده از اصل کمینه‌سازی ریسک ساختاری از طریق بیشینه کردن فاصله بین دو ابرصفحه گذرا از بردارهای پشتیبان هر دو کلاس اعمال می‌شود که سعی در کمینه کردن خطای آموزش دارد و عملکرد بهتری بر روی داده‌هایی که مدل با آنها ساخته نشده است از خود نشان می‌دهد. شکل ۵، تقسیم‌بندی اطلاعات به وسیله ماشین بردار پشتیبان را نشان می‌دهد.




شکل ۵. دسته‌بندی کننده ماشین بردار پشتیبان

الگوریتم اولیه ماشین بردار پشتیبان در سال ۱۹۶۳ توسط وپنیک ابداع شد و در سال ۱۹۹۵ توسط وپنیک و کورتس برای حالت غیرخطی تعمیم داده شد (شفیعی نیک‌آبادی، ۲۰۱۵). این روش از جمله روش‌های نسبتاً

مربوط به توابع عضویت به گونه‌ای انتخاب شوند که بیشترین هماهنگی را با داده‌های ورودی-خروجی داشته باشند. برای این کار می‌توان از تکنیک سازگاری عصبی، توسط دستورهای موجود در جعبه‌ابزار فازی، استفاده کرد. روش آموزش سازگاری عصبی شبیه شبکه‌های عصبی کار می‌کند. سیستم استنتاج فازی-عصبی تطبیقی در حقیقت سیستم‌های فازی هستند که برای بهبود پارامترهای خود از روش آموزش تطبیقی استفاده می‌کنند. یا به عبارت دیگر از شبکه‌های عصبی برای آموزش مدل بهره می‌گیرند (جانگ، ۱۹۹۳).

برای آموزش مدل در انفیس از دو روش انتشار بازگشتی خطا و روش ترکیبی (ترکیب انتشار بازگشتی خطا با کمترین مربعات) که به تازگی در جعبه ابزار متلب گنجانده شده است استفاده می‌شود. در شکل ۴، ساختار کلی روش انفیس نشان داده شده است.



شکل ۴. ساختار سیستم استنتاج فازی-عصبی تطبیقی

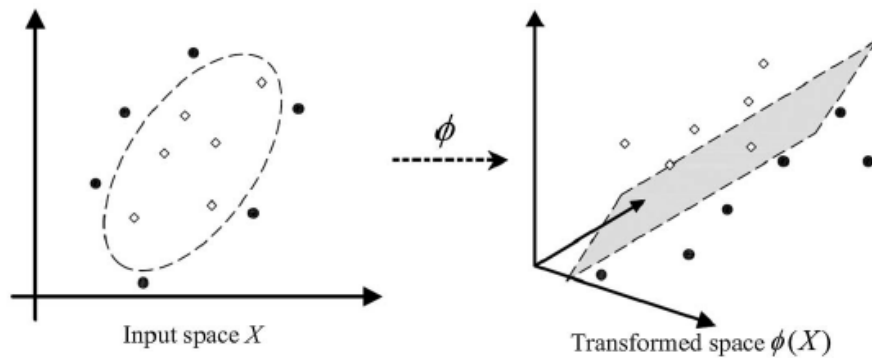
(کاظمی نژاد و همکاران، ۲۰۰۵)

همان‌طور که در شکل ۴ مشاهده می‌شود، انفیس از یک شبکه عصبی پنج لایه تشکیل شده است که لایه اول شامل ورودی‌ها، لایه دوم شامل ترم‌های کلامی ورودی‌ها یا به عبارتی توابع عضویت، لایه سوم نشانگر بخش مقدم قوانین فازی، لایه چهارم شامل بخش تالی قوانین فازی و لایه پنجم نشان دهنده مرحله فازی‌زدایی است.

$$\begin{aligned} & \text{Min } \frac{1}{2} \|w\|^2 + C \left( \sum_{i=1}^l (\xi_i + \xi_i^*) \right) \quad (2) \\ & \text{s.t. } y_i - W^T \phi(X_i) - b \leq \varepsilon + \xi_i - y_i + W^T \phi(X_i) + b \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \quad \forall i = 1, \dots, l \end{aligned}$$

که  $\xi_i, \xi_i^*$  متغیرهایی برای انعطاف پذیر کردن مرزها،  $W$  شیب خط مماس بر بردار پشتیبان،  $b$  عرض از مبدأ خط و  $\varepsilon$  خطای مورد انتظار است.

شکل ۶ انتقال داده‌ها از فضای دوبعدی به سه‌بعدی را نشان می‌دهد. در اغلب موارد، داده‌هایی که برای طبقه‌بندی به مدل ارائه می‌شوند، به‌طور خطی قابل تفکیک نیستند. در چنین مواردی، ماشین بردار پشتیبان از یک تصویرگر غیرخطی استفاده می‌کند تا داده‌ها را به فضایی با ابعاد بالاتر منتقل کند. با این بعد جدید، این روش ابر صفحه‌ای را جستجو می‌کند که داده‌ها را از هم جدا کند. با یک تصویرگر غیرخطی مناسب برای انتقال داده‌ها به فضایی با ابعاد بالا، ماشین بردار پشتیبان همیشه می‌تواند دو گروه از داده‌ها را از هم جدا کند.



شکل ۶. انتقال داده‌ها به فضای بالاتر (صدوقی یزدی و همکاران، ۲۰۱۳)

$$\begin{aligned} & \text{Max } -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(X_i, X_j) - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \\ & \text{s.t. } \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0, \quad \alpha_i, \alpha_i^* \in [0, C] \quad (3) \end{aligned}$$

که  $\alpha_i, \alpha_i^*$  ضرایب لاگرانژ و ماتریس  $K(X_i, X_j)$  برابر با معادله (۴) است:

$$\phi(X_i)^T \phi(X_j) \quad i, j = 1, 2, \dots, M \quad (4)$$

جدید است که در سال‌های اخیر کارایی خوبی در پیش-بینی خواص مکانیکی بتن از خود نشان داده است (صدوقی و همکاران، ۲۰۰۸؛ سبحانی و همکاران، ۲۰۱۳؛ صدوقی یزدی و همکاران، ۲۰۱۳).

مدل‌های ماشین بردار پشتیبان بسیار شبیه به شبکه‌های عصبی هستند. در واقع، یک مدل ماشین بردار پشتیبان با هسته سیگموئیدی برابر با یک شبکه عصبی پیش‌خور دولایه است (شرو، ۲۰۱۴).


حل معادله پیدا کردن خط بهینه برای داده‌ها به‌وسیله روش‌های برنامه‌نویسی درجه دو صورت می‌گیرد. قبل از تقسیم خطی، برای اینکه ماشین بتواند داده‌های با پیچیدگی بالا را دسته‌بندی کند، داده‌ها با استفاده از تابع ۲ به فضایی با ابعاد بیشتر انتقال می‌یابد (صدوقی یزدی و همکاران، ۲۰۱۳):

برای اینکه بتوان مسئله با ابعاد خیلی بالاتر را با استفاده از این روش حل کرد، از قضیه دوگانگی لاگرانژ برای تبدیل مسئله مینیمم‌سازی مورد نظر فرم دوگانگی آن که از تابع ساده‌تری به نام تابع هسته که ضرب برداری تابع ۲ است، استفاده می‌شود. معادله (۳) فرم دوگانگی لاگرانژ را نشان می‌دهد:



$$K(X_i, X_j) = e^{-\frac{\|X_i - X_j\|^2}{2\sigma^2}} \quad (8)$$

که  $\sigma^2$  انحراف معیار تابع هسته پایه شعاعی است. شکل ۸ نشان‌دهنده دو دسته اطلاعات است که به وسیله تابع هسته پایه شعاعی از هم جدا شده‌اند.



شکل ۸ تفکیک اطلاعات به وسیله تابع هسته پایه شعاعی (شرود، ۲۰۱۴)

## ۲-۴. جمع‌آوری اطلاعات

در این تحقیق، دو سری طرح مخلوط مورد استفاده قرار گرفته است. سری اول توسط مؤلفین طراحی و ساخته شده‌اند و سری دوم از سایر تحقیقات و مطالعات پیشین جمع‌آوری گردیده است (مردانی آقا بگلو و همکاران، ۲۰۱۳؛ آتیش و همکاران، ۲۰۰۴). دلیل استفاده از اطلاعات سایر تحقیقات، افزایش کمی اطلاعات می‌باشد زیرا آموزش مدل‌های مد نظر با تعداد کم اطلاعات نتیجه مناسبی را در بر نخواهد داشت.

### ۲-۴-۱. سری اول

این سری شامل ۹ طرح مخلوط مختلف می‌شود که با روش حجم بهینه خمیر طراحی و ساخته شده‌اند. در این تحقیق، از سیمان پرتلند تیپ ۲ با وزن مخصوص ۳۱۵۰ کیلوگرم بر متر مکعب استفاده شده است. خواص شیمیایی و فیزیکی سیمان تیپ ۲ به ترتیب در جداول ۱ و ۲ آورده شده است.

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \times \phi(X_i) \rightarrow f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, X_i) + b \quad (5)$$


که  $f(x)$  تابع تعیین‌کننده خروجی است. از توابع مختلف هسته می‌توان برای تعیین خروجی استفاده کرد. رایج‌ترین توابع مورد استفاده شامل تابع هسته خطی، چندجمله‌ای و پایه شعاعی می‌باشند (صدوقی یزدی و همکاران، ۲۰۱۳).

در این تحقیق، از هر سه تابع هسته استفاده شده و عملکرد آن‌ها در پیش‌بینی مقاومت فشاری بتن غلتکی مورد ارزیابی قرار گرفته است. فرمول‌های توابع هسته خطی و چندجمله‌ای به ترتیب در معادله‌های ۶ و ۷ آورده شده است (شرود، ۲۰۱۴):

$$K(X_i, X_j) = X_i^T X_j \quad (6)$$

$$K(X_i, X_j) = (X_i^T X_j + t)^d, \quad t \geq 0 \quad (7)$$

که  $t$  عرض از مبدأ و  $d$  درجه چندجمله‌ای می‌باشد. شکل ۷ شیوه تفکیک دو دسته اطلاعات را به وسیله توابع هسته خطی و چندجمله‌ای نشان می‌دهد.



شکل ۷. تفکیک دو دسته اطلاعات به وسیله توابع هسته خطی و چندجمله‌ای (شرود، ۲۰۱۴)

معادله (۸) بیانگر فرمول تابع هسته پایه شعاعی است:

جدول ۱. خواص شیمیایی سیمان تیپ ۲

مؤلفه	مقدار موجود در سیمان (%)	مقدار مجاز آیین نامه (%)
Loss on Ignition	۱/۳	حداکثر ۳
SiO <sub>2</sub>	۲۱/۷۴	حداقل ۲۰
Al <sub>2</sub> O <sub>3</sub>	۵	حداکثر ۶
Fe <sub>2</sub> O <sub>3</sub>	۴	حداکثر ۶
CaO	۶۳/۰۴	---
MgO	۲	حداکثر ۵
SO <sub>3</sub>	۲/۳	حداکثر ۳
C <sub>3</sub> S	۴۵/۵	---
C <sub>2</sub> S	۲۸	---
C <sub>3</sub> A	۶/۵	حداکثر ۸
C <sub>4</sub> AF	۱۲/۲	---

جدول ۲. خواص فیزیکی سیمان تیپ ۲

نرمی (cm <sup>2</sup> /g)	زمان گیرش		مقاومت فشاری (Mpa)		
	اولیه (min)	ثانویه (H)	۳ روزه	۷ روزه	۲۸ روزه
۲۹۰۰	۱۴۰	۳	۲۲	۲۷/۵	۴۱

استفاده شده است. سنگدانه مطالعه انجام شده در دانشگاه مذکور دارای مشخصات کاملاً یکسان با مطالعه حاضر بوده است. لیکن در مطالعه انجام شده در مرکز تحقیقات راه، مسکن و شهرسازی، ماسه رودخانه‌ای با حداکثر اندازه ۴/۷۵ میلی‌متر و مدول نرمی ۳/۵۳ به‌عنوان سنگدانه ریز استفاده شده است. همچنین، سنگدانه نخودی دارای دانه‌بندی بین ۴/۷۵ و ۱۲/۷ میلی‌متر و سنگدانه بادامی دارای محدوده ابعادی ۹/۵ الی ۱۹ میلی‌متر بود. جذب آب ماسه، شن نخودی و شن بادامی به ترتیب برابر ۳/۲۷، ۲/۱۸ و ۲/۱ درصد و جرم حجمی آنها به ترتیب برابر ۲/۷، ۲/۵۷ و ۲/۵۶ گرم بر سانتی‌متر مکعب اندازه‌گیری شده است. شایان ذکر است که ۱۷ طرح ذکر شده تحت نظارت نویسنده مسئول مقاله طراحی و ساخته شده است. شانزده طرح باقی‌مانده از مقالات آتیش و همکاران

سنگدانه مورد استفاده در این تحقیق شامل ماسه طبیعی با حداکثر اندازه ۴/۷۵ میلی‌متر و جذب آب ۲/۵۴ درصد و چگالی اشباع با سطح خشک ۲۵۸۰ کیلوگرم بر متر مکعب، شن با حداکثر اندازه ۱۹ میلی‌متر و جذب آب ۰/۷ درصد و چگالی اشباع با سطح خشک ۲۷۰۰ کیلوگرم بر متر مکعب بوده است. حداکثر اندازه شن برای دستیابی به کیفیت مطلوب سطح به ۱۹ میلی‌متر محدود شده است.

#### ۲-۴-۲. سری دوم

سری دوم شامل ۳۳ طرح مخلوط می‌شود که ۸ طرح در مرکز تحقیقات مسکن و شهرسازی ایران و ۹ طرح در دانشگاه تحصیلات تکمیلی و فناوری پیشرفته کرمان ساخته شده است. در این تحقیقات، از سیمان تیپ ۲

پارامترهایی که به‌عنوان ورودی مدل در نظر گرفته شده‌اند شامل سن نمونه، مقدار شن، ماسه، سیمان، آب و خاکستر بادی (کلاس C) و پارامتر خروجی مقاومت فشاری بتن غلتکی می‌باشد که در جدول ۳ بیشینه، کمینه و محدوده تغییرات پارامترهای ذکر شده بیان شده است. علت انتخاب خاکستر بادی در این مطالعه به‌عنوان یکی از ورودی‌های طرح، متداول بودن استفاده از مواد پوزولانی به‌عنوان مکمل سیمان در اجرا و مطالعات مختلف است. به همین لحاظ، خاکستر بادی به‌عنوان یک پوزولان نمونه بررسی شده است.

(۲۰۱۴) و آتیش و همکاران (۲۰۱۴) جمع‌آوری شده است. در مطالعه آتیش و همکاران (۲۰۱۴) سیمان نوع NPC-42.5 مطابق با استاندارد ترکیه، ماسه دارای جرم حجمی و رطوبت اشباع با سطح خشک به ترتیب برابر ۱/۵ درصد و ۲/۶۵ و شن دارای جرم حجمی و رطوبت اشباع با سطح خشک به ترتیب برابر ۰/۹۹ درصد و ۲/۷۳ بوده‌اند. در مطالعه آتیش و همکاران (۲۰۱۴) سیمان از نوع تیپ I-425 و ماسه و شن به ترتیب دارای رطوبت اشباع با سطح خشک برابر ۲/۶ و ۲/۶۵ درصد و جرم حجمی اشباع با سطح خشک به ترتیب برابر ۱/۷۴ و ۱/۵ گرم بر سانتی متر مکعب می‌باشند.

جدول ۳. بیشینه، کمینه، محدوده تغییرات و مقدار میانگین پارامترهای مورد استفاده

مقدار میانگین	محدوده تغییرات	کمینه	بیشینه	متغیر
<b>ورودی</b>				
۴۳/۷	۱۷۹	۱	۱۸۰	سن نمونه (روز)
۷۳۸/۹	۶۴۱/۳	۴۲۱	۱۰۶۲/۳	شن $[kg/m^3]$
۸۹۲/۹	۹۸۹/۷	۳۹۴/۹	۱۳۸۴/۶	ماسه $[kg/m^3]$
۲۷۱/۵	۳۰۰	۱۰۰	۴۰۰	سیمان $[kg/m^3]$
۱۴۰/۱	۹۰/۵	۹۷/۵	۱۸۸	آب $[kg/m^3]$
۴۴/۱	۱۸۰	۰	۱۸۰	خاکستر بادی $[kg/m^3]$
<b>خروجی</b>				
۳۱	۶۲/۹	۱,۵	۶۴/۴	مقاومت فشاری [Mpa]

می‌باشد. معیارهای ارزیابی مورد استفاده در این تحقیق به شرح زیر است:

### ۳-۱. ضریب همبستگی

این ضریب میزان نزدیکی مقاومت‌های پیش‌بینی شده و مشاهده شده را نشان می‌دهد. مقدار ضریب همبستگی از صفر تا یک متغیر است. هرچه پاسخ به یک نزدیک‌تر باشد، نشان‌دهنده برازش بهتر مدل می‌باشد (صدیق و

لازم به ذکر است که تمامی اطلاعات ورودی و خروجی به بازه بین ۱ و ۱- انتقال یافته‌اند و به اصطلاح نرمال شده‌اند. دلیل این کار بهبود عملکرد مدل‌سازی می‌باشد.

### ۳. معیارهای ارزیابی

منظور از ارزیابی مدل، به دست آوردن میزان خطا با توجه به خروجی پیش‌بینی شده توسط مدل و مقدار هدف

تطبیقی و ماشین بردار پشتیبان پرداخته می شود. برای هر روش حالتی که بهترین نتایج را داشته است به عنوان مدل برگزیده انتخاب و باهم مقایسه گردیده اند تا بهترین روش برای پیش بینی مقاومت فشاری بتن غلتکی مشخص شود. لازم به ذکر است که هدف از مدل سازی مقاومت فشاری، امکان سنجی توانایی روش های مذکور در پیش بینی مناسب می باشد.

#### ۴-۱. شبکه عصبی مصنوعی

در این تحقیق، از شبکه عصبی چندلایه پرسپترون استفاده شده است. این شبکه دارای یک لایه پنهان می باشد. برای تعیین تعداد عصب بهینه در لایه پنهان، ۲۰ مدل شبکه عصبی ساخته و مورد ارزیابی قرار گرفتند. برای انجام این مهم، بر تعداد عصب ها در لایه پنهان تک تک افزوده شد (۲۰-۱ عدد) و عملکرد هر مدل بررسی گردید. برای آموزش شبکه عصبی از الگوریتم لونیبرگ- مارکوارد استفاده شد. برای تعیین تابع تحریک مناسب در لایه پنهان و خروجی از توابع تانژانت سیگموئید، لگاریتم سیگموئید و خطی استفاده شد که بهترین نتیجه را تابع تانژانت سیگموئید در لایه پنهان و تابع خطی در لایه خروجی داده است.

برای آموزش، اعتبارسنجی و آزمایش شبکه ها به ترتیب از ۸۰٪ (۱۰۴ عدد)، ۱۰٪ (۱۲ عدد) و ۱۰٪ (۱۲ عدد) اطلاعات استفاده شده است. ارزیابی عملکرد مرحله آزمایش در جدول ۴ ملاحظه می شود. ملاک تعیین مدل نهایی، عملکرد آن در مرحله آزمایش می باشد. شکل ۹ معیارهای ارزیابی خطا در هر مدل شبکه عصبی مصنوعی را در قالب نمودار نشان می دهد.

همکاران، ۲۰۱۱). این ضریب با معادله (۹) محاسبه می شود:

$$R^2 = \frac{\sum (CS - PCS)^2}{\sum (CS - \overline{CS})^2} \quad (9)$$

که CS مقاومت فشاری واقعی، PCS مقاومت فشاری پیش بینی شده و  $\overline{CS}$  میانگین مجموع مقاومت های فشاری واقعی است.

#### ۳-۲. ریشه میانگین مربعات خطا

این معیار نشان دهنده ریشه دوم مربعات اختلاف میان مقاومت مشاهده شده و پیش بینی شده است. مقدار آن از صفر تا بی نهایت متغیر است و هرچه این مقدار به صفر نزدیک تر باشد نشان دهنده عملکرد بهتر مدل است (الشپهری و همکاران، ۲۰۰۹). معادله (۱۰) بیانگر این پارامتر می باشد:

$$RMSE = \sqrt{\left( \frac{1}{n} \sum_{i=1}^n (CS - PCS)^2 \right)} \quad (10)$$

که n تعداد طرح اختلاط می باشد.

#### ۳-۳. میانگین خطای مطلق

این معیار نشان دهنده میانگین اختلاف مطلق میان مقاومت های مشاهده شده و پیش بینی شده است. مقدار آن از صفر تا بی نهایت متغیر است و هرچه این مقدار به صفر نزدیک تر باشد نشان دهنده عملکرد بهتر مدل است. این ضریب با معادله (۱۱) محاسبه می شود:


$$MAE = \frac{1}{n} \sum_{i=1}^n |PCS - CS| \quad (11)$$

#### ۴. نتایج و بحث

در این بخش، به ترتیب به ارزیابی عملکرد مدل های شبکه عصبی مصنوعی، سیستم استنتاج فازی عصبی

جدول ۴. معیارهای ارزیابی مدل‌های شبکه عصبی مصنوعی در مرحله آزمایش

نام مدل	$R^2$	RMSE	MAE
ann 1	0.6017	9.1612	6.6627
ann 2	0.8354	5.9332	4.0070
ann 3	0.9312	4.0046	3.4447
ann 4	0.9529	3.2105	2.8221
<b>*ann5*</b>	<b>0.9717</b>	<b>2.4859</b>	<b>2.1396</b>
ann 6	0.9687	2.7306	2.4112
ann 7	0.9483	3.4746	2.9109
ann 8	0.9432	3.4935	2.7747
ann 9	0.9463	3.4800	2.8953
ann 10	0.9561	3.3839	2.9627
ann 11	0.9470	3.9521	3.2539
ann 12	0.9479	4.3181	3.5441
ann 13	0.9438	4.5270	3.8660
ann 14	0.9124	4.7252	4.0253
ann 15	0.9154	4.4569	3.9988
ann 16	0.9404	5.5767	4.5021
ann 17	0.9516	4.6017	3.7472
ann 18	0.9392	4.6778	3.8108
ann 19	0.9259	4.5468	3.6579
ann 20	0.9300	4.6669	4.1524




شکل ۹. مقایسه مقدار خطاهای مدل ann 5


بهترین نتیجه را در برداشته است؛ یعنی دارای کمترین مقدار خطا (RMSE و MAE) و بیشترین مقدار همبستگی ( $R^2$ ) است. پس مدل ann 5 بهترین مدل شبکه

شکل ۹. مقایسه مقدار خطاهای مدل ann 5 همان‌گونه که از جدول ۴ و شکل ۹ قابل استنباط است، حالتی که ۵ عصب در لایه پنهان وجود دارد،

را در مراحل آزمایش و آموزش برای مدل شبکه عصبی با ۵ عصب در لایه پنهان را نشان می دهد.




عصبی مصنوعی می باشد. همچنین، شکل ۱۰ همبستگی بین مقاومت فشاری واقعی و پیش بینی شده بتن غلتکی



شکل ۱۰. همبستگی بین مقاومت فشاری واقعی و پیش بینی شده بتن غلتکی به وسیله مدل ann 5 در مراحل آزمایش و آموزش

شکل ۱۱، ساختار شبکه عصبی مصنوعی ann 5 با ۵ عصب در لایه پنهان که از بین تمامی حالت های ساخته شده شبکه عصبی به عنوان مدل نهایی برگزیده شده است را به همراه نوع و تعداد ورودی به تصویر می کشد.

این مسئله که زوج های مقاومت فشاری واقعی و پیش بینی شده توسط مدل ann 5 در نمودارهای ۱۰ حول خط همبستگی جمع شده اند و پراکنده نیستند نشان دهنده دقت بالای شبکه عصبی مصنوعی در پیش بینی مقاومت فشاری در مراحل آموزش و آزمایش می باشد.



شکل ۱۱. ساختار شبکه عصبی مصنوعی استفاده شده به عنوان مدل نهایی (ann 5)

برای تشکیل انفیس به شیوه خوشه بندی تفریقی از دستور GENFIS2 استفاده می گردد. برای تعیین بهترین مدل در این روش، ضریب تأثیر از ۰/۱ تا ۲/۱ با گام های ۰/۱ افزایش داده شده و مدل متناظر با هر ضریب ارزیابی گشته است. برای آموزش مدل ۱۵۰۰ تکرار در نظر گرفته و این مقدار از بین ۵۰۰، ۱۰۰۰، ۱۵۰۰، ۲۰۰۰ و ۲۵۰۰ تکرار انتخاب شده است (حالت بهینه). جمعاً ۲۱ مدل ساخته و عملکرد آن ها مورد ارزیابی قرار گرفته است (جدول ۵).

#### ۴-۲. سیستم استنتاج فازی عصبی تطبیقی


مدل های انفیس ساخته شده بر مبنای روش تاکاگی- سوگنو می باشد. برای ساختن مدل های پیش بینی کننده مختلف انفیس از خوشه بندی تفریقی استفاده شده است. برای ساخت این مدل ها ۸۰٪ داده ها (۱۰۲ عدد) برای آموزش و ۲۰٪ داده ها (۲۶ عدد) برای آزمایش مدل استفاده شده است.

جدول ۵. معیارهای ارزیابی مدل‌های انفیس در مرحله آزمایش

نام مدل	ضریب تأثیر	RMSE	MAE	R <sup>2</sup>
anfis s2	0.1	11.4403	7.4277	0.4803
anfis s3	0.2	28.4928	15.0733	0.4094
anfis s4	0.3	7.5583	5.7367	0.7186
anfis s5	0.4	2511.0862	699.7640	0.1108
anfis s6	0.5	5.8076	4.7516	0.8567
anfis s7	0.6	5.5229	4.8160	0.8516
anfis s8	0.7	5.4892	4.7827	0.8535
anfis s9	0.8	5.3603	4.6664	0.8605
anfis s10	0.9	5.8093	4.7512	0.8542
anfis s11	1	5.8743	4.8163	0.8506
anfis s12	1.1	6.7084	5.3250	0.8030
anfis s13	1.2	5.4687	4.5804	0.8616
anfis s14	1.3	5.2237	4.4195	0.8730
anfis s15	1.4	5.0538	4.2630	0.8797
anfis s16	1.5	5.1730	4.2280	0.8697
anfis s17	1.6	5.2775	4.2677	0.8639
<b>*anfis s18*</b>	<b>1.7</b>	<b>5.0299</b>	<b>3.8985</b>	<b>0.8810</b>
anfis s19	1.8	5.0554	3.9279	0.8794
anfis s20	1.9	5.0801	3.9527	0.8780
anfis s21	2	5.1395	4.0591	0.8756
anfis s22	2.1	7.2140	5.3337	0.8241

مدل با ضریب تأثیر ۰/۱ می‌باشد که منجر به تشکیل ۷۹ قانون گردیده است. برای حل این مشکل می‌توان تعداد تکرار آموزش را کاهش داد، یا ضریب تأثیر را بالا برد. همان‌گونه که مشاهده می‌شود، با بالا بردن ضریب تأثیر، این مشکل مرتفع گردیده است. شکل ۱۲، همبستگی مدل anfis\_s18 را به ترتیب در مراحل آموزش و آزمایش نشان می‌دهد.

مدل anfis\_s18 با ضریب تأثیر ۱/۷ که منجر به تشکیل ۲ قانون شده است بهترین جواب را در بین مدل‌های انفیس با خوشه‌بندی تفریقی داشته است. همچنین، مدل anfis\_s2 علی‌رغم آموزش عالی نتوانسته است داده‌های آزمایش را به‌خوبی پیش‌بینی کند. زمانی که این اتفاق رخ می‌دهد اصطلاح بیش‌آموزشی مدل را مطرح می‌کنند. دلیل بیش‌آموزشی، پیچیدگی بالای



شکل ۱۲. همبستگی بین مقاومت فشاری واقعی و پیش‌بینی شده بتن غلتکی به‌وسیله مدل anfis s18 در مراحل آموزش و آزمایش

#### ۴-۳. ماشین بردار پشتیبان

و ۲۰٪ داده‌ها (۲۶ عدد) برای آزمایش مدل استفاده شده است. تمامی داده‌ها به صورت تصادفی انتخاب گردیده‌اند. در جداول ۶ و ۷ به ترتیب معیارهای ارزیابی عملکرد مدل‌های ماشین بردار پشتیبان در مراحل آموزش و آزمایش بیان شده است.

برای تشکیل مدل‌های پیش‌بینی‌گر ماشین بردار پشتیبان از سه تابع هسته متفاوت استفاده شده است که شامل تابع خطی، تابع چندجمله‌ای و تابع پایه شعاعی می‌شود. در ساخت این مدل‌ها ۸۰٪ داده‌ها (۱۰۲ عدد) برای آموزش

جدول ۶. معیارهای ارزیابی مرحله آموزش



نام مدل	نوع هسته	RMSE	MAE	$R^2$
svm 1	lin_kernel	8.6130	6.4774	0.6795
svm 2	poly_kernel	3.1007	2.4767	0.9585
svm 3	RBF_kernel	3.1422	2.5163	0.9574

جدول ۷. معیارهای ارزیابی مرحله آزمایش

نام مدل	نوع هسته	RMSE	MAE	$R^2$
svm 1	lin_kernel	7.7880	6.0197	0.6952
svm 2	poly_kernel	4.7591	3.9510	0.8923
svm3	<b>RBF-kernel</b>	<b>4.4135</b>	<b>3.5426</b>	<b>0.9066</b>

فشاری نامناسب تلقی می‌شود. در شکل ۱۳، همبستگی بین مقاومت فشاری واقعی و پیش‌بینی شده توسط مدل svm 3 نشان داده شده است. این همبستگی قابل قبول بوده و نشان از توان بالای این مدل در پیش‌بینی مقاومت فشاری بتن غلتکی دارد.

همان‌گونه که از نتایج بیان شده مشخص است، مدل svm با هسته متشکل از تابع پایه شعاعی، بهترین عملکرد را در میان مدل‌های svm داشته است. دلیل این امر می‌تواند انعطاف‌پذیری و توانایی بالای این تابع نسبت به توابع خطی و چندجمله‌ای باشد. عملکرد مدل svm 2 نیز قابل قبول است. ولی مدل svm 1 برای پیش‌بینی مقاومت



شکل ۱۳. همبستگی بین مقاومت فشاری واقعی و پیش‌بینی شده بتن غلتکی به وسیله مدل svm 3 در مراحل آموزش و آزمایش مدل‌ها، ۱۰٪ طرح‌های اختلاط (۱۲ عدد)، که به صورت تصادفی انتخاب شده، به عنوان ورودی مدل‌ها برای پیش‌بینی مقاومت فشاری در نظر گرفته شده است. مشخصات طرح‌های اختلاط در جدول ۸ آورده شده است.

#### ۵. مقایسه مدل‌های برگزیده

در این بخش از تحقیق به مقایسه عملکرد مدل‌های برگزیده پرداخته و مدل نهایی برای پیش‌بینی مقاومت فشاری بتن غلتکی انتخاب می‌گردد. برای مقایسه این



جدول ۸. مشخصات طرح‌های اختلاط ساخته شده در این تحقیق


تعداد	سن نمونه (روز)	شن ( $Kg/m^3$ )	ماسه ( $Kg/m^3$ )	سیمان ( $Kg/m^3$ )	آب ( $Kg/m^3$ )	خاکستر بادی ( $Kg/m^3$ )
1	28	585	394.875	400	160	0
2	180	851	1248	200	100	50
3	3	682.5	460.69	170	166	30
4	3	633.75	427.781	300	159	0
5	7	845.55	1156.2	370	122.1	0
6	28	717.68	1384.57	280	109.2	0
7	7	695	1020	250	188	150
8	7	1015.45	1004.3	370	122.1	0
9	28	697.85	1346.31	335	113.9	0
10	180	823	1209	100	115	150
11	180	682.5	460.69	140	168	60
12	180	695	1020	250	188	150

نشان می‌دهد. شکل ۱۵، مقایسه روند پیش‌بینی مقاومت فشاری توسط مدل‌ها و مقاومت فشاری واقعی را نشان می‌دهد. همان‌گونه که از نمودارها مشخص است، شبکه عصبی مصنوعی و انفیس نزدیک‌ترین پیش‌بینی را به مقاومت‌های واقعی داشته‌اند.

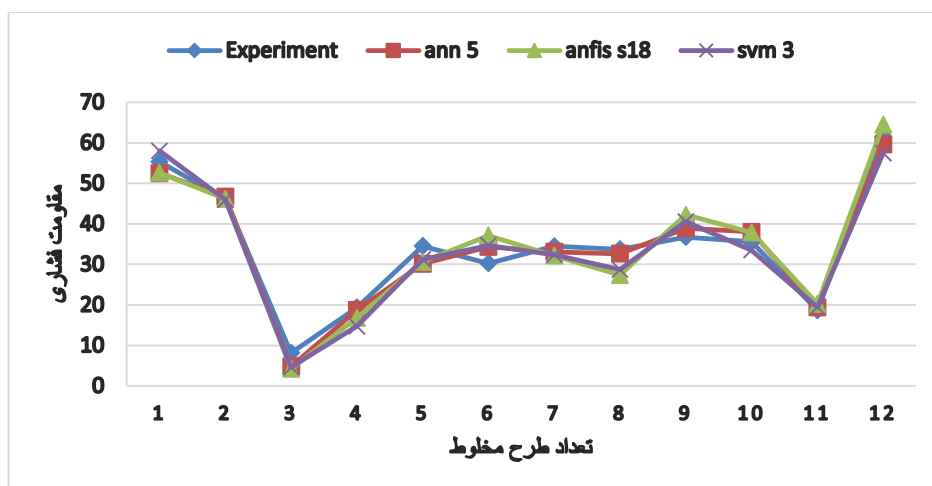
مقاومت‌های پیش‌بینی شده توسط مدل‌های برگزیده شبکه عصبی مصنوعی، سیستم استنتاج فازی عصبی و ماشین بردار پشتیبان به همراه مقاومت‌های واقعی (مشاهداتی در آزمایشگاه) در جدول ۹ آورده شده است. شکل ۱۴، نمودار میله‌ای مقاومت فشاری واقعی و پیش‌بینی شده توسط مدل‌های برگزیده را در کنار هم

جدول ۹. مقاومت‌های پیش‌بینی شده توسط مدل‌های برگزیده

شماره	آزمایش	ann 5	anfis s18	svm 3
1	55.32	52.47	52.59	60.75
2	46.13	46.70	46.16	47.32
3	8.14	4.82	4.2	4.29
4	19.36	18.71	16.76	15.76
5	34.53	30.13	30.58	32.40
6	30.23	34.33	37.12	36.36
7	34.47	33.07	32.16	38.40
8	33.73	32.61	27.35	29.81
9	36.72	38.90	42.21	40.59
10	35.61	38.01	37.88	34.04
11	18.62	19.35	20.25	19.94
12	61.55	59.60	64.45	53.12



شکل ۱۴. مقاومت فشاری واقعی و پیش بینی شده توسط مدل های برگزیده



شکل ۱۵. مقایسه روند پیش بینی مقاومت فشاری توسط مدل ها و مقاومت فشاری واقعی

برای مقایسه بهتر مدل‌ها با هم، معیارهای ارزیابی هر یک محاسبه گردید و در جدول ۱۰ به ترتیب برای مرحله آزمایش نشان داده شده است.

همان‌طور که در شکل‌های ۱۴ و ۱۵ نیز مشخص است، مقاومت‌های فشاری پیش‌بینی شده توسط شبکه عصبی مصنوعی و انفیس به مقاومت فشاری واقعی نزدیک‌تر می‌باشند.

جدول ۱۰. معیارهای ارزیابی عملکرد مدل‌های برگزیده هر روش

مدل	R <sup>2</sup>	RMSE	MAE
*ann 5*	0.9717	2.4859	2.1396
anfis s18	0.9396	3.9278	3.4254
svm 3	0.9566	3.4013	3.0733

و توانایی بالای این تابع نسبت به توابع خطی و چندجمله‌ای باشد. مدل svm 1 که از هسته با تابع خطی ساخته شده است برای پیش‌بینی مقاومت فشاری نامناسب تلقی می‌شود.

با بررسی معیارهای ارزیابی عملکرد مدل‌ها، مشخص شد که شبکه عصبی مصنوعی بهترین عملکرد را داشته و مقاومت‌های پیش‌بینی شده توسط این مدل بسیار به مقادیر واقعی مقاومت فشاری نزدیک است.

با استفاده از مدل شبکه عصبی می‌توان مقاومت فشاری بتن غلتکی را با و بدون خاکستر بادی در سن دلخواه و بدون صرف وقت زیاد، محاسبه کرد که این امر کمک بسیار شایانی در صرفه‌جویی در زمان و هزینه به مهندسین سازه می‌کند. علاوه بر این، استفاده از مدل شبکه عصبی در پیش‌بینی مقاومت فشاری، استفاده از مواد خام طبیعی را کاهش می‌دهد و به کاربر کمک می‌کند طرح خود را در راستای توسعه پایدار قوت بخشد. استفاده از مدل‌های پیش‌بینی‌کننده می‌تواند به اعتبارسنجی طرح‌های اختلاطی که توسط نرم‌افزار یا فرمول‌های نوین طراحی شده‌اند کمک کند.

با توجه به نتایج ارائه شده، شبکه عصبی مصنوعی بهترین عملکرد را در پیش‌بینی مقاومت فشاری بتن غلتکی در بین روش‌های مذکور دارد.

## ۶. نتیجه‌گیری

تمامی مدل‌های برگزیده شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی و ماشین بردار پشتیبان عملکرد مناسبی از خود برای پیش‌بینی مقاومت فشاری بتن غلتکی حاوی خاکستر بادی نشان داده‌اند.

شبکه عصبی مصنوعی با یک لایه پنهان، که در آن ۵ عصب استفاده شده، بهترین نتیجه را نشان داده است. استفاده از تابع تحریک تانژانت سیگموئید در عصب‌های لایه پنهان و تابع خطی در لایه خروجی شبکه عصبی سبب بهبود عملکرد مدل شده است. استفاده از الگوریتم آموزش لوبز-مارکوارد در شبکه عصبی نسبت به سایر روش‌های آموزش نتیجه بهتری در بر داشته است.

مدل ماشین بردار پشتیبان با هسته متشکل از تابع پایه شعاعی بهترین عملکرد را در میان مدل‌های ماشین بردار پشتیبان داشته است. دلیل این امر می‌تواند انعطاف‌پذیری

## ۷. منابع

معاونت برنامه‌ریزی و نظارت راهبردی ریاست جمهوری. ۱۳۸۸. "راهنمای طراحی و اجرای بتن غلتکی در روسازی راه‌های کشور. نشریه شماره ۳۵۴.

عمادی، م. و مدنی، س. ح. ۱۳۹۵. "ارزیابی مدل‌های هوش مصنوعی در تخمین مقامت فشاری بتن غلتکی". هشتمین کنفرانس ملی سالانه بتن ایران، ۱۵ تا ۱۷ مهر، تهران.

- Abraham, A. 2005. "Artificial neural networks". Handbook of Measuring System Design.
- Alshihri, M. M., Azmy, A. M. and El-Bisy, M. S. 2009. "Neural networks for predicting compressive strength of structural light weight concrete". *Constr. Build. Mater.*, 23(6): 2214-2219.
- Amani, J. and Moeini, R. 2012. "Prediction of shear strength of reinforced concrete beams using adaptive neuro-fuzzy inference system and artificial neural network". *Sci., Iran.*, 19: 242-248.
- Atiş, C. D., Sevim, U. K., Özcan, F., Bilim, C., Karahan, O. and Tanrikulu, A. H. 2004. "Strength properties of roller compacted concrete containing a non-standard high calcium fly ash". *Mater. Lett.*, 58(9): 1446-1450.
- Bilgehan, M. 2011. "Comparison of ANFIS and NN models- with a study in critical buckling load estimation". *Appl. Soft Comput. J.* 11(4): 3779-3391.
- Chithra, S., Senthil Kumar, S. R. R., Chinnaraju, K. and Ashmita, F. A. 2016. "A comparative study on the compressive strength prediction models for high performance concrete containing nano silica and copper slag using regression analysis and artificial neural networks". *Constr. Build. Mater.*, 114: 528-535.
- Duan, Z. H., Kou, S. C. and Poon, C. S. 2013. "Prediction of compressive strength of recycled aggregate concrete using artificial neural networks". *Constr. Build. Mater.*, 40: 1200-1206.
- Fausett, L. 1994. "Fundamentals of Neural Networks: Architectures, Algorithms, and Applications". Prentice-Hall, Inc.
- Gagne, R. 1999. "Proportioning for non-air-entrained RCCP". *Concrete Int.*, 21(5): 37-41.
- Ni, H. G. and Wang, J. Z. 2000. "Prediction of compressive strength of concrete by neural networks". *Cement Concrete Res.*, 30(8): 1245-1250.
- Jang, J. S. R. 1993. "ANFIS: Adaptive-network-based fuzzy inference system". *IEEE Trans. Sys., Man, Cyber.*, 23(3):665-685.
- Kazeminezhad, M. H., Etemad-Shahidi, A. and Mousavi, S. J. 2005. "Application of fuzzy inference system in the prediction of wave parameters". *Ocean Eng.*, 32: 1709-1725.
- Mardani-Aghabaglou, A., Andiç-Çakir, Ö. and Ramyar, K. 2013. "Freeze-thaw resistance and transport properties of high-volume fly ash roller compacted concrete designed by maximum density method." *Cement Concrete Compos.*, 37(1): 259-266.
- Ozcan, F., Atis, C. D., Karahan, O., Oncuoglu, E. and Tanyildizi H., 2009. "Comparison of artificial neural network and fuzzy logic models for prediction of long-term compressive strength of silica fume concrete". *Adv. Eng. Software*, 40: 856-863.
- Pham, A. D., Hoang, N. D. and Nguyen, Q. T. 1993. "Predicting compressive strength of high-performance concrete using metaheuristic-optimized least squares support vector regression". *J. Comp. Civ. Eng.*, 30(3), DOI: 10.1061/(ASCE)CP.1943-5487.0000506.
- Sadoghi Yazdi, J., Kalantary, F. and Sadoghi Yazdi, H. 2013. "Prediction of elastic modulus of concrete using support vector committee method". *J. Mater. Civ. Eng.*, 25(1): 9-20.
- Sadrmomtazi, A., Sobhani, J. and Mirgozar, M. A. 2013. "Modeling compressive strength of EPS lightweight concrete using regression, neural network and ANFIS". *Constr. Build. Mater.*, 42: 205-216.
- Sarıdemir, M. 2009. "Predicting the compressive strength of mortars containing metakaolin by artificial neural networks and fuzzy logic". *Adv. Eng. Software* 40(9): 920-927.
- Shafiei Nikabadi, A. and Azimi, M. 2015. "Demand forecasting in a supply chain using machine learning algorithms". *J. Model. Eng.* 13(41): 127-136.
- Sherrod, P. H. 2014. "DTREG: Predictive modeling software".
- Siddique, R., Aggarwal, P. and Aggarwal, Y. 2011. "Prediction of compressive strength of self-compacting concrete containing bottom ash using artificial neural networks". *Adv. Eng. Software*, 42(10): 780-786.
- Siddique, R., Aggarwal, P., Aggarwal, Y. and Gupta, S. M.. 2008. "Modeling properties of self-compacting concrete: Support vector machines approach". *Comp. Concrete*, 5(5): 123-129.
- Sobhani, J., Najimi, M., Pourkhorshidi, A. R. and Parhizkar, T. 2010. "Prediction of the compressive strength of no-slump concrete: A comparative study of regression, neural network and ANFIS models". *Constr. Build. Mater.* 24(5): 709-718.
- Sobhani, J., Khanzadi, M. and Movahedian-Attar, A. 2013. "Support vector machine for prediction of the compressive strength of no-slump concrete". *Comp. Concrete*, 11(4): 337-350.
- Trocoli, A., Dantas, A., Batista Leite, M. and De Jesus Nagahama, K. 2013. "Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks". *Constr. Build. Mater.* 38: 717-722.

## ۸. پیوست

در جدول زیر، مقادیر پارامترهای ورودی و خروجی مشاهده می‌گردد.

Num.	Age	Gravel	Sand	Cement	Water	Fly Ash	Compressive Strength
1	28	633.75	427.781	165	168	135	14.78
2	7	789	1098	300	165	0	25
3	28	755	1107	250	150.5	100	41.24
4	7	755	1107	250	150.5	100	32.16
5	7	800	1114	375	135	0	19.4
6	28	751.8	1154.9	380	133	0	48
7	180	633.75	427.781	165	168	135	29.56
8	28	821	1144	350	122.5	0	43
9	28	867	1185.56	335	113.9	0	41.2
10	28	633.75	427.781	255	162	45	44.31
11	90	807	1185	250	123	50	50.18
12	1	585	394.875	400	160	0	11.85
13	180	633.75	427.781	255	162	45	46.67
14	7	690.5	1332.13	370	111	0	26.23
15	28	682.5	460.688	110	170	90	9.5
16	7	889.27	1215.98	300	105	0	29.17
17	180	585	394.875	220	176	180	25.08
18	28	585	394.875	280	168	120	39.65
19	1	633.75	427.781	255	162	45	5.53
20	180	682.5	460.688	170	166	30	23.89
21	3	633.75	427.781	255	162	45	16.39
22	7	867	1185.56	335	113.9	0	34
23	180	841	1235	150	105	100	39.03
24	180	585	394.875	340	164	60	64.37
25	7	812	1131	350	126	0	26
26	28	800	1114	375	135	0	35.1
27	7	793.1	1218.2	320	112	0	32.85
28	7	807	1185	250	123	50	31.07
29	28	682.5	460.688	200	164	0	18.06
30	28	1062.79	1051.1	300	105	0	37.07
31	28	765.2	1175.5	350	129.5	0	42.4
32	28	1036.2	1024.8	335	113.9	0	39
33	1	585	394.875	220	176	180	6.26
34	90	755	1107	250	150.5	100	55.09
35	7	841	1235	150	105	100	17.44
36	1	633.75	427.781	210	165	90	4.08
37	3	585	394.875	340	164	60	22.73
38	28	793.1	1218.2	320	112	0	43.35
39	28	821	1144	325	130	0	44
40	28	585	394.875	340	164	60	57.24

41	28	421	1144	350	122.5	0	43.2
42	7	1036.2	1024.8	335	113.9	0	32.44
43	7	795.2	1221.5	392.3	145.1	0	33.2
44	3	682.5	460.688	200	164	0	7.99
45	7	821	1144	350	122.5	0	33.4
46	28	682.5	460.688	170	166	30	20.71
47	28	633.75	427.781	300	159	0	41.53
48	7	735.3	1129.5	307.7	113.8	0	28.1
49	28	736.2	1130.9	380	148.2	0	42.7
50	1	682.5	460.688	200	164	0	3.14
51	28	851	1248	200	100	50	33.97
52	180	633.75	427.781	300	159	0	48.64
53	180	633.75	427.781	210	165	90	35.39
54	3	585	394.875	220	176	180	10.86
55	28	861	1263	250	97.5	0	35.96
56	28	585	394.875	220	176	180	22.14
57	180	861	1263	250	97.5	0	53.09
58	180	682.5	460.688	110	170	90	15.66
59	28	841	1235	150	105	100	30.43
60	1	585	394.875	280	168	120	6.67
61	90	841	1235	150	105	100	37.18
62	1	633.75	427.781	165	168	135	3.48
63	28	830	1157	350	115.8	0	48.5
64	7	823	1209	100	115	150	14.16
65	1	682.5	460.688	170	166	30	2.04
66	7	1062.79	1051.1	300	105	0	30.25
67	28	633.75	427.781	210	165	90	34.94
68	7	765.2	1175.5	350	129.5	0	30.55
69	90	823	1209	100	115	150	34.96
70	180	682.5	460.688	200	164	0	18.91
71	1	682.5	460.688	140	168	60	2.1
72	28	823	1209	100	115	150	26.72
73	3	682.5	460.688	110	170	90	2.98
74	28	812	1131	350	126	0	37
75	28	811	1130	350	133	0	38.2
76	7	751.8	1154.9	380	133	0	34.1
77	28	755.2	1160.1	350	139.3	0	35.95
78	180	585	394.875	400	160	0	58.48
79	7	851	1248	200	100	50	24.15
80	1	585	394.875	340	164	60	9.65
81	28	775.7	1191.5	350	119.3	0	44.8
82	28	735.3	1129.5	307.7	113.8	0	39.8
83	180	807	1185	250	123	50	54
84	7	811	1130	350	133	0	21.9
85	90	861	1263	250	97.5	0	49.09
86	3	585	394.875	400	160	0	27.58
87	1	682.5	460.688	110	170	90	1.5

عمادی-مدنی

88	7	755.2	1160.1	350	139.3	0	28.4
89	28	889.27	1215.98	300	105	0	37.97
90	3	585	394.875	280	168	120	17.12
91	7	421	1144	350	122.5	0	29.3
92	28	1015.45	1004.3	370	122.1	0	41.87
93	7	821	1144	325	130	0	33
94	180	585	394.875	280	168	120	55.3
95	28	780	1198	320	124.8	0	35
96	7	775.7	1191.5	350	119.3	0	36.7
97	28	807	1185	250	123	50	39.29
98	90	695	1020	250	188	150	58.73
99	3	682.5	460.688	140	168	60	4.06
100	28	795.2	1221.5	392.3	145.1	0	44.7
101	180	755	1107	250	150.5	100	58.45
102	7	717.68	1384.57	280	109.2	0	26.03
103	3	633.75	427.781	165	168	135	6.91
104	7	697.85	1346.31	335	113.9	0	30.93
105	3	633.75	427.781	210	165	90	10.9
106	7	861	1263	250	97.5	0	28.64
107	1	633.75	427.781	300	159	0	7.61
108	28	695	1020	250	188	150	44.59
109	7	830	1157	350	115.8	0	42.5
110	7	780	1198	320	124.8	0	24.2
111	90	851	1248	200	100	50	42.95
112	28	690.5	1332.13	370	111	0	34.67
113	28	845.55	1156.2	370	122.1	0	42.4
114	28	789	1098	300	165	0	31
115	7	736.2	1130.9	380	148.2	0	36.45
116	28	682.5	460.688	140	168	60	14.56
117	28	585	394.875	400	160	0	55.32
118	180	851	1248	200	100	50	46.13
119	3	682.5	460.688	170	166	30	8.14
120	3	633.75	427.781	300	159	0	19.36
121	7	845.55	1156.2	370	122.1	0	34.53
122	28	717.68	1384.57	280	109.2	0	30.23
123	7	695	1020	250	188	150	34.47
124	7	1015.45	1004.3	370	122.1	0	33.73
125	28	697.85	1346.31	335	113.9	0	36.72
126	180	823	1209	100	115	150	35.61
127	180	682.5	460.688	140	168	60	18.62
128	180	695	1020	250	188	150	61.55

