

مدلسازی و پیش بینی مقاومت فشاری بتن های حاوی نیم کک شیل نفتی فعال شده با حرارت به کمک شبکه های عصبی GMDH

حسین بهشتی نژاد^{۱*}، اکرم حجازی نژاد^۲

۱-مرکز تحقیقات فناوری بتن، واحد بیرجند، دانشگاه آزاد اسلامی، بیرجند، ایران. Hbeheshti.nezhad@iau.ir

۲-دانشجوی کارشناسی ارشد، گروه مهندسی عمران، واحد بیرجند، دانشگاه آزاد اسلامی، بیرجند،

ایران akramhejazi2@gmail.com

خلاصه

استفاده از نیم کک حاصل از شیل نفتی به عنوان جایگزین بخشی از سیمان در بتن، راهکاری مؤثر برای کاهش اثرات زیست محیطی صنعت ساخت و ساز و بهره برداری از پسماندهای صنعتی است. تولید سیمان حجم قابل توجهی دی اکسید کربن تولید می کند که استفاده از مواد جایگزین را ضروری می سازد. این پژوهش از شبکه عصبی گروهی داده ها (GMDH) برای مدل سازی و پیش بینی مقاومت فشاری بتن حاوی نیم کک استفاده کرده است. نیم کک که در فرآیند پیرولیز شیل نفتی در دمای بالا تولید می شود، حاوی سیلیس، آلومینا و اکسید آهن است که پتانسیل واکنش پذیری بالایی دارد. نتایج آزمایش های گسترده روی نمونه های بتنی با درصدهای مختلف جایگزینی و دماهای متفاوت فعال سازی نشان می دهد که جایگزینی بهینه نیم کک در دمای فعال سازی مناسب نه تنها خواص مکانیکی بتن را حفظ می کند، بلکه در برخی شرایط باعث بهبود مقاومت و دوام آن می شود. مدل GMDH با دقت بالا توانسته رفتار خصوصیات مکانیکی بتن را پیش بینی کند. ساختار بهینه شبکه شامل چند لایه پنهان با توابع چند جمله ای حاصل از تجزیه سری ولترا است که ورودی های آن درصد جایگزینی نیم کک، دمای فعال سازی، سن نمونه، و خروجی آن مقاومت فشاری بتن است. این پژوهش می تواند به توسعه فناوری های جدید در صنعت بتن، کاهش مصرف سیمان، و استفاده بهینه از پسماندهای صنعتی کمک شایانی نماید و زمان و هزینه آزمایش های تجربی را به میزان قابل توجهی کاهش دهد.

کلمات کلیدی: نیم کک شیل نفتی، بتن، فعال سازی حرارتی، مقاومت مکانیکی، مواد معدنی افزودنی، هوش مصنوعی، مدلسازی، شبکه عصبی (GMDH).

مقدمه

صنعت ساخت‌وساز به عنوان یکی از بزرگترین مصرف‌کنندگان منابع طبیعی، همواره با چالش یافتن راهکارهای پایدار برای تولید مصالح ساختمانی مواجه است [۱]. بتن به عنوان پرمصرف‌ترین ماده ساخته دست بشر پس از آب، سالانه حجم عظیمی از مواد اولیه را مصرف می‌کند که تولید آن‌ها اثرات زیست‌محیطی قابل توجهی دارد [۲]. با توجه به محدودیت‌های زیست‌محیطی و اقتصادی، استفاده از مواد جایگزین در ترکیب بتن به یک ضرورت تبدیل شده است [۳]. مطالعات نشان می‌دهد که تولید هر تن سیمان حدود ۰.۹ تن CO_2 تولید می‌کند که این امر جایگزینی بخشی از سیمان با مواد افزودنی را ضروری می‌سازد [۴]. نیم‌کک حاصل از شیل نفتی، به عنوان یکی از پسماندهای صنعتی، پتانسیل قابل توجهی برای استفاده در ساخت بتن دارد [۵]. این ماده که در فرآیند پیرولیز شیل نفتی در دمای ۵۰۰ تا ۵۵۰ درجه سانتی‌گراد تولید می‌شود [۶]، می‌تواند به عنوان افزودنی معدنی در بتن استفاده شود و بخشی از سیمان را جایگزین کند [۷]. مطالعات اولیه نشان داده‌اند که جایگزینی بهینه نیم‌کک (حدود ۱۵٪) در دمای فعال‌سازی مناسب (۵۰۰ درجه سانتی‌گراد) نه تنها خواص مکانیکی بتن را حفظ می‌کند [۸]، بلکه در برخی موارد باعث بهبود مقاومت و دوام آن می‌شود [۹]. همچنین استفاده از نیم‌کک به دلیل فعالیت پوزولانی در شرایط مناسب، می‌تواند به تشکیل ژل C-S-H بیشتر و در نتیجه بهبود ریزساختار بتن کمک کند [۱۰]. ترکیب شیمیایی نیم‌کک به دلیل محتوای بالای سیلیس و آلومینا، پتانسیل واکنش‌پذیری مناسبی دارد [۱۱]. با این حال، پیش‌بینی دقیق تأثیر این ماده بر خصوصیات مکانیکی بتن نیازمند روش‌های پیشرفته مدل‌سازی است [۱۲]. مدل‌های شبکه عصبی مصنوعی با توانایی شناسایی روابط پیچیده و غیرخطی میان متغیرها، ابزاری کارآمد برای پیش‌بینی رفتار مصالح ساختمانی هستند [۱۳]. در این میان، روش شبکه عصبی گروهی داده‌ها (GMDH) با قابلیت خودسازماندهی و انتخاب خودکار ساختار بهینه [۱۴]، برای مدل‌سازی سیستم‌های پیچیده مانند بتن مناسب است [۱۵]. شبکه عصبی GMDH که توسط ایواخنکو در دهه ۱۹۶۰ معرفی شد، از الگوریتم‌های تکاملی برای ساخت خودکار ساختار بهینه شبکه استفاده می‌کند [۱۶]. این روش با تولید مجموعه‌ای از توابع چند جمله‌ای درجه دوم در لایه‌های متوالی، یک ساختار عمیق و لایه‌بندی شده ایجاد می‌کند که قادر به توصیف روابط غیرخطی پیچیده در داده‌هاست [۱۷]. مزیت اصلی GMDH نسبت به سایر شبکه‌های عصبی، توانایی آن در انتخاب خودکار متغیرهای ورودی تأثیرگذار و حذف متغیرهای کم‌اهمیت است. این ویژگی باعث می‌شود GMDH برای مدل‌سازی سیستم‌های پیچیده با تعداد زیادی پارامتر ورودی مانند بتن بسیار مناسب باشد [۱۸]. در مدل GMDH پیشنهادی این پژوهش، ورودی‌های شبکه شامل درصد جایگزینی نیم‌کک (۰ تا ۲۵٪)، دمای فعال‌سازی (۳۰۰ تا ۶۰۰ درجه سانتی‌گراد)، نسبت آب به مواد سیمانی (۰.۳۵ تا ۰.۵۵)، مقدار سیمان (۳۰۰ تا ۵۰۰) و سن نمونه (۷، ۲۸ روز) در نظر گرفته شده است. خروجی مدل، مقاومت فشاری بتن است [۱۹]. ساختار بهینه شبکه پس از آزمایش چندین توپولوژی مختلف، شامل ۳ لایه پنهان با توابع انتقال گوسی در لایه‌های پنهان و تابع انتقال خطی در لایه خروجی انتخاب شده است [۲۰]. پژوهش حاضر با هدف توسعه یک مدل شبکه عصبی GMDH برای پیش‌بینی مقاومت مکانیکی بتن حاوی نیم‌کک شیل نفتی انجام شده است [۲۱]. در این پژوهش، داده‌های مورد نیاز برای پیش‌مدل‌سازی و پیش‌بینی شبکه از مقاله‌ی Bo Li و همکاران (۲۰۲۳) استخراج شده است. سپس با استفاده از شبکه عصبی GMDH، یک مدل به‌منظور پیش‌بینی مقاومت فشاری ارائه شده است. در نهایت، عملکرد مدل با استفاده از توابع خطا مورد ارزیابی و تحلیل قرار می‌گیرد [۲۲].

مواد و مصالح

در این پژوهش، داده‌های حاصل از مدل‌سازی مقاومت فشاری با استفاده از نیم‌کک شیل نفتی در مخلوط‌های سیمانی، که با بهره‌گیری از شبکه عصبی GMDH تحلیل شده‌اند، از مطالعه Bo Li و همکاران (۲۰۲۳) استخراج گردیده است. در این پژوهش، از سیمان پرتلند تیپ یک با سطح مخصوص بین ۳۰۰۰ تا ۳۵۰۰ سانتی‌متر مربع بر گرم استفاده شده است. ماسه به کاررفته عمدتاً ماسه استاندارد با دانه‌بندی مطابق با استانداردهای آزمایشگاهی و مدول نرمی در محدوده ۲.۵ تا ۳ بوده است. نسبت آب به مواد سیمانی در این ملات‌ها عموماً در بازه ۰.۴۰ تا ۰.۵۵ تنظیم شده و نسبت ماسه به سیمان ۳ به ۱ در نظر گرفته شده است.

در مخلوط‌های بتنی علاوه بر سیمان و ماسه، از شن با حداکثر اندازه دانه‌های بین ۱۲.۵ تا ۱۹ میلی‌متر استفاده شده است. عیار سیمان در این مخلوط‌ها بین ۳۰۰ تا ۴۵۰ کیلوگرم بر مترمکعب تعیین شده و نسبت سنگدانه درشت به ریز در محدوده ۱.۵ تا ۲ تنظیم گردیده است. همچنین، به منظور حفظ کارایی مطلوب مخلوط‌های بتنی، از افزودنی‌های روان‌کننده با دوز مصرفی بین ۰.۳ تا ۰.۸ درصد وزن سیمان بهره گرفته شده است.

نیم‌کک شیل نفتی به صورت پودر با اندازه ذرات مشابه سیمان (کمتر از ۹۰ میکرومتر) و سطح ویژه‌ای در محدوده ۳۰۰ تا ۴۵۰ متر مربع بر کیلوگرم مورد استفاده قرار گرفته است. این ماده با درصد‌های جایگزینی مختلف شامل ۵، ۱۰، ۱۵، ۲۰ و ۲۵ درصد وزنی سیمان در مخلوط‌های ملات و بتن بررسی شده است. مطابق داده‌های جدول شماره ۱، فرآیند فعال‌سازی حرارتی نیم‌کک شیل نفتی در دماهای مختلف (۳۰۰، ۴۰۰، ۵۰۰ و ۶۰۰ درجه سانتی‌گراد) انجام پذیرفته و مدت زمان این فرآیند معمولاً بین ۱ تا ۴ ساعت تنظیم گردیده است.

این داده‌ها نقش اساسی در مدل‌سازی و پیش‌بینی رفتار مکانیکی مخلوط‌های سیمانی و بتنی با استفاده از تکنیک‌های شبکه عصبی GMDH دارند.

مطابق اطلاعات ارائه‌شده در جدول شماره ۱، نتایج اولیه نمونه‌ها با دماهای مختلف و درصد‌های جایگزینی نیم‌کک شیل نفتی مورد بررسی قرار گرفته است. این داده‌ها پایه اولیه تحلیل‌های پژوهش حاضر را تشکیل می‌دهند.

جدول شماره ۱- نتایج اولیه از نمونه های موجود با دما و درصد های مورد آزمایش [۲۲]

				مقاومت فشاری	
نمونه	دما	نیم کک	درصد نیم کک	۷	۲۸
۱	—	۰	۰	۳۱.۵۸	۴۴.۳۰
۲	۳۰۰	۲۲.۵	۵	۳۶.۸۸	۴۹.۶۰
۳	۳۰۰	۴۵	۱۰	۲۸.۴	۴۵.۳۶
۴	۳۰۰	۶۷.۵	۱۵	۲۶.۲۸	۴۰.۳۶
۵	۳۰۰	۹۰	۲۰	۲۵.۲۲	۳۶.۸۸
۶	۳۰۰	۱۱۲.۵	۲۵	۲۴.۱۶	۳۳.۷۰
۷	۴۰۰	۲۲.۵	۵	۳۰.۳۲	۴۴.۸۷
۸	۴۰۰	۴۵	۱۰	۳۳.۸۳	۴۶.۸۶
۹	۴۰۰	۶۷.۵	۱۵	۳۵.۸۳	۴۸.۸۸
۱۰	۴۰۰	۹۰	۲۰	۲۷.۸۱	۳۹.۸۵
۱۱	۴۰۰	۱۱۲.۵	۲۵	۲۴.۸۰	۳۶.۸۴
۱۲	۵۰۰	۲۲.۵	۵	۳۰.۷۲	۴۳.۵۰
۱۳	۵۰۰	۴۵	۱۰	۲۹.۷۲	۴۱.۴۴
۱۴	۵۰۰	۶۷.۵	۱۵	۲۶.۱۰	۳۸.۳۸
۱۵	۵۰۰	۹۰	۲۰	۳۹.۴۰	۴۸.۲۲
۱۶	۵۰۰	۱۱۲.۵	۲۵	۳۲.۰۸	۴۵.۵۴
۱۷	۶۰۰	۲۲.۵	۵	۲۵.۹۹	۳۶.۹۶
۱۸	۶۰۰	۴۵	۱۰	۳۶.۹۶	۴۶.۴۲
۱۹	۶۰۰	۶۷.۵	۱۵	۳۳.۴۸	۴۶.۹۲
۲۰	۶۰۰	۹۰	۲۰	۳۰.۹۸	۴۲.۹۴
۲۱	۶۰۰	۱۱۲.۵	۲۵	۲۹.۹۸	۴۰.۹۴

روش تحقیق

شبکه‌های عصبی GMDH : ساختار و ویژگی‌ها

شبکه‌های عصبی GMDH را می‌توان به عنوان تجلی الگوریتم GMDH در قالب ساختارهای شبکه‌ای در نظر گرفت. [۲۳] این رویکرد شبکه‌ای باعث افزایش قابلیت انعطاف و بهینه‌سازی الگوریتم شده و امکان ایجاد ساختارهای متنوع و پیاده‌سازی راحت‌تر در محیط‌های نرم‌افزاری را فراهم می‌کند. مزیت اصلی کاربرد مفهوم شبکه در این الگوریتم، تسهیل فرآیند ترکیب و تحلیل توابع جزئی با روش‌های مختلف است که نتیجه آن، طیف گسترده‌تری از مدل‌های بهینه با خطای کمتر و ساختار ریاضی منطقی‌تر می‌باشد.

خصوصیات کلیدی شبکه‌های GMDH

شبکه‌های GMDH، ساختارهای خودسازمانده و یک‌طرفه‌ای هستند که از چندین لایه تشکیل می‌شوند و هر لایه شامل تعدادی نرون است. همه نرون‌ها دارای ساختار یکسانی با دو ورودی و یک خروجی هستند و پردازش داده‌ها توسط پنج وزن و یک مقدار بایاس انجام می‌شود:

$$y_{ik}^* = N(x_{i\alpha}, x_{i\beta}) = b^k + w_1^k x_{i\alpha} + w_2^k x_{i\beta} + w_3^k x_{i\alpha}^2 + w_4^k x_{i\beta}^2 + w_5^k x_{i\alpha} x_{i\beta} \quad (1)$$

در رابطه بالا $i = 1, 2, 3, \dots, N$ می‌باشد که در آن N تعداد نمونه‌های ورودی و خروجی بوده و $K = 1, 2, 3, \dots, C_m^2$ می‌باشد که در آنها m تعداد نرون‌های لایه قبلی است که نتایج آن برای نمونه‌های ۷ و ۲۸ روزه برای مقاومت فشاری در آورده شده است.

وزن‌های هر نرون با استفاده از روش‌هایی مانند SVD یا SNE محاسبه شده و به عنوان مقادیر ثابت در نرون‌ها قرار می‌گیرند. یکی از ویژگی‌های متمایز این نوع شبکه‌ها این است که نرون‌های لایه قبلی، تولیدکننده نرون جدید هستند.

$$C_m^2 = \frac{m(m-1)}{2} \quad (2)$$

برای جلوگیری از واگرایی شبکه، بخشی از این نرون‌های تولید شده باید حذف شوند که به آنها "نرون مرده" گفته می‌شود. همچنین، برخی نرون‌ها که در ساختار نهایی شبکه باقی می‌مانند اما با نرون لایه آخر ارتباط ندارند، به عنوان "نرون غیرفعال" شناخته می‌شوند. معیار اصلی برای انتخاب یا حذف نرون‌ها در هر لایه، مجموع مربعات خطا بین خروجی واقعی و خروجی پیش‌بینی شده توسط نرون است:

$$r_j^2 = \frac{\sum_{i=1}^N (y_i - y_{ij}^*)^2}{N} \quad (3)$$

در رابطه بالا $j \in \{1, 2, 3, \dots, C_m^2\}$ می‌باشد که در آن m تعداد نرون‌های گزینش شده در لایه قبلی می‌باشد.

اصول طراحی شبکه‌های عصبی GMDH

برخلاف شبکه‌های عصبی معمولی (مانند پرسپترون) که نیاز به تعیین ساختار ثابت دارند، طراحی GMDH بر دو هدف اصلی تمرکز دارد:

کنترل واگرایی شبکه و ارتباط ساختار با پارامترهای عددی قابل تنظیم
دو اصل کلیدی طراحی مدیریت ساختار (کنترل تعداد لایه‌ها، تعیین تعداد نرون‌های هر لایه) و مدیریت ارتباطات (تعیین نحوه اتصال نرون‌ها، بهینه‌سازی ارتباطات بین لایه‌ها)
این رویکرد باعث انعطاف‌پذیری بیشتر و کنترل بهتر پیچیدگی شبکه می‌شود.

مکانیزم طراحی ساختار شبکه با روش افزایش فشار انتخاب (I.S.P)

روش افزایش فشار انتخاب (I.S.P) تکنیکی خودکار برای تعیین بهینه ساختار شبکه‌های GMDH است که هم تعداد لایه‌ها و هم تعداد نرون‌های هر لایه را به صورت پویا تنظیم می‌کند. این روش بر پایه یک مکانیزم هوشمند انتخاب استوار است که با پیشرفت از لایه‌ای به لایه دیگر، فشار انتخاب را افزایش می‌دهد.
در هر لایه، ابتدا یک خطای مبنا ($\bar{r}^2$) محاسبه می‌شود که میانگین خطای تعداد مشخصی از بهترین نرون‌های آن لایه است. سپس خطای هر نرون با این خطای مبنا مقایسه شده و فقط نرون‌هایی که خطای کمتری دارند ($r_j^2 < \bar{r}^2$) به عنوان "نرون برنده" در ساختار شبکه باقی می‌مانند. بقیه نرون‌ها به عنوان "نرون‌های مرده" از ساختار حذف می‌شوند.
نکته کلیدی این روش در آن است که با حرکت به سمت لایه‌های عمیق‌تر، تعداد نرون‌هایی که در محاسبه خطای مبنا شرکت می‌کنند تحت تأثیر پارامتر فشار (SP_k) کاهش می‌یابد و همزمان این فشار به میزان ثابت α افزایش می‌یابد. این مکانیزم باعث می‌شود معیار انتخاب نرون‌ها سختگیرانه‌تر شده و فقط نرون‌های با کیفیت بالاتر در لایه‌های انتهایی باقی بمانند.

الگوریتم با دو پارامتر ورودی کلیدی کنترل می‌شود: فشار اولیه (SP_1) و میزان افزایش فشار (α). تغییر در هر یک از این پارامترها موجب ایجاد تغییر در ساختار نهایی شبکه و کیفیت مدل ایجاد شده می‌گردد. فرآیند ساخت لایه‌ها تا زمانی ادامه می‌یابد که حداقل یک نرون در لایه جدید شرایط انتخاب شدن را داشته باشد. با توجه به اینکه محاسبه وزن‌های هر نرون می‌تواند با روش‌های مختلفی مانند SVD و SNE انجام شود، این روش می‌تواند حتی با پارامترهای ورودی یکسان، به ساختارهای متفاوتی با دقت‌های متفاوت منجر شود.

روش طراحی ساختار از پیش تعیین شده (P.S.D)

روش P.S.D رویکردی انعطاف‌پذیر برای طراحی ساختار شبکه‌های GMDH است که در آن پارامترهای اصلی ساختار شامل تعداد لایه‌ها و تعداد نرون‌های هر لایه، به صورت اختیاری و بدون محدودیت خاصی توسط طراح تعیین می‌شوند.
این روش ماهیتی شبیه به سعی و خطا دارد که با آزمودن ساختارهای مختلف، به دنبال یافتن ساختار بهینه است.
در این روش، ابتدا تعداد لایه‌ها (NL) و تعداد نرون‌های هر لایه (mi) به عنوان پارامترهای ورودی مشخص می‌شوند.
سپس در هر لایه، تمام ترکیبات ممکن نرون‌های لایه قبل ایجاد شده و از میان آنها، تعداد مشخصی (mi) از بهترین نرون‌ها (نرون‌هایی با کمترین خطا) انتخاب می‌شوند. این فرآیند به صورت پیش‌رونده از لایه اول تا لایه آخر ادامه می‌یابد.

نکته مهم این است که حتی با پارامترهای ورودی یکسان (تعداد لایه‌ها و نرون‌ها)، استفاده از روش‌های مختلف برای محاسبه ضرایب نرون‌ها (مانند SVD و SNE) می‌تواند به مدل‌های متفاوتی منجر شود. همچنین، شیوه همگرایی شبکه و نحوه رسیدن آن به نرون خروجی نهایی، عواملی هستند که باعث ایجاد تفاوت بین ساختار طراحی شده و ساختار نهایی می‌گردند.

طراحی تکاملی ساختار شبکه عصبی (ED)

روش طراحی تکاملی (ED) رویکردی نوین در طراحی شبکه‌های GMDH است که از الگوریتم ژنتیک برای بهینه‌سازی ساختار شبکه بهره می‌گیرد. برخلاف روش‌های سنتی که خطا را به عنوان معیار اصلی تعیین ساختار در نظر می‌گرفتند، این روش محدودیت‌های مبتنی بر خطا را برداشته و به تمام نرون‌ها شانس یکسانی برای مشارکت در شبکه می‌دهد. فرآیند ایجاد شبکه به صورت تصادفی اما هدفمند انجام می‌شود و تنها معیارهای برازندگی، تعداد کل نرون‌های شبکه و میزان خطای خروجی در مقایسه با داده‌های آزمایشی است.

در مقایسه با روش ISP که تصمیم‌گیری برای انتخاب نرون‌ها در لحظه تشکیل هر لایه انجام می‌شود و تغییرات پارامتر فشار منجر به تغییرات ناپیوسته در ساختار می‌گردد، و نیز روش PSD که به دلیل ماهیت تصادفی خود عملاً در یافتن ساختار بهینه محدود است، روش ED انعطاف‌پذیری بیشتری دارد.

نوآوری اصلی این روش در ترکیب الگوریتم ژنتیک برای طراحی ساختار و SVD برای تعیین ضرایب نرون‌هاست. استفاده از SVD فضای جستجو را به شدت کاهش می‌دهد. همچنین این روش امکان ایجاد دو نوع شبکه را فراهم می‌کند: شبکه‌های CS که در آن نرون‌ها فقط به لایه مجاور متصل می‌شوند، و شبکه‌های GS که امکان اتصال به تمام لایه‌های قبلی را دارند. این ویژگی‌ها باعث می‌شود روش ED در یافتن ساختارهای بهینه موفق‌تر عمل کند.

کدگذاری ژنتیکی ساختار شبکه‌های GS-GMDH

در رویکرد ژنتیکی طراحی شبکه‌های GS-GMDH، هر ساختار شبکه با یک رشته سمبلیک متشکل از حروف الفبا بازنمایی می‌شود. این رشته سمبلیک، در واقع کروموزوم یا ژنوم شبکه نامیده می‌شود. هر حرف در این رشته، نماینده یکی از ورودی‌های شبکه عصبی است.

برای شبکه‌ای با N ورودی $X = (x_1, x_2, x_3, \dots, x_n)$ ، کروموزوم به صورت رشته‌ای با طول $2k$

$k \in \{1, 2, 3, \dots, (n_1 + 1)\}$ نشان دهنده تعداد لایه‌های مخفی است) شکل می‌گیرد.

در طراحی شبکه‌های عصبی GMDH، دو نوع ساختار CS و GS وجود دارد. در شبکه‌های CS، هر نرون از ترکیب دو نرون در لایه مجاور ساخته می‌شود و می‌توان آن را با کروموزوم‌هایی مانند abbcadbc نمایش داد. طول این کروموزوم‌ها با فرم $2^{HL+1} = \text{Lenght of neron}$ (که HL تعداد لایه‌های مخفی است) مشخص می‌شود. در شبکه‌های پیشرفته‌تر

GS، نرون‌ها می‌توانند با طول‌های مختلف ترکیب شوند و امکان جهش نرون‌ها از لایه‌های مختلف وجود دارد. در این حالت، برای حل مشکل ترکیب نرون‌ها با طول‌های متفاوت، نام نرون‌های کوچکتر به تعداد 2^n بار تکرار می‌شود (n تعداد لایه‌های جهش). برای طراحی این شبکه‌ها از الگوریتم ژنتیک استفاده می‌شود که در آن، شبکه‌ها به صورت رشته‌های حروف الفبا کدگذاری شده و برازندگی آنها بر اساس معادله زیر محاسبه می‌شود (که در آن E میانگین است).

$$\phi = 1/E \quad (4)$$


این فرآیند بهینه‌سازی تا زمانی که تغییر قابل توجهی در برازندگی مشاهده نشود ادامه می‌یابد و برای تعیین ضرایب از روش SVD استفاده می‌شود.

تفاوت بین شبکه‌های CS و GS

شبکه‌های CS: هر نرون تنها از ترکیب دو نرون در لایه قبلی ایجاد می‌شود
 شبکه‌های GS: نرون‌ها می‌توانند از ترکیب نرون‌های لایه‌های مختلف ایجاد شوند
 مکانیزم نمایش "جهش لایه‌ای" در GS-GMDH برای نمایش حالتی که یک نرون از لایه‌های میانی "جهش" می‌کند تا با نرونی از لایه دیگر ترکیب شود، از تکرار نام نرون استفاده می‌شود.
 نتایج نشان داد که استفاده از نیم‌گک شیل نفتی فعال شده با حرارت، به‌طور قابل توجهی مقاومت فشاری بتن را تحت تأثیر قرار می‌دهد و شبکه‌های عصبی GMDH به خوبی توانستند رابطه بین پارامترهای ورودی و خروجی را مدل‌سازی کرده و پیش‌بینی‌های دقیقی ارائه دهند. این موضوع نشان‌دهنده کارایی بالای روش GMDH در تحلیل و پیش‌بینی خواص بتن‌های اصلاح‌شده با مواد جایگزین است.

نتایج و بحث

همانطور که در جدول‌های ۲ و ۳ دیده می‌شود ضرایب رابطه (۱) با استفاده از شبکه عصبی GMDH و داده‌های پژوهش‌های گذشته محاسبه شده و با توجه به آن شکل شبکه عصبی در شکل‌های ۱ و ۲ نشان داده شده است. نتایج حاصله از پیش‌بینی مقاومت فشاری ۷ و ۲۸ روزه با استفاده از شبکه عصبی GMDH در نمودارهای ۱ و ۲ نمایش داده شده است. که نشان می‌دهد استفاده از درصد نیم کک ۱۵ و دمای ۵۰۰ درجه سانتی‌گراد نزدیک و بهینه‌ترین نتیجه ممکن در این آزمایش خواهد بود.




شکل شماره ۱- ساختار شبکه عصبی برای نمونه‌های ۷ و ۲۸ روزه مقاومت فشاری (الف) یک لایه، (ب) دو لایه، (ج) سه لایه

جدول شماره ۲- ضرایب مدل شبکه عصبی ۷ روزه


	b	w ₁	w ₂	w ₃	w ₄	w ₅
y ₁	۳۱.۵۴۲۵	۰.۰۲۰۶۳	-۰.۷۳۲۶۵	-۵.۲۰E-۰۵	-۰.۰۱۷۷۱۳	۰.۰۰۲۴۷
y ₂	۴۳.۷۴۵۵	-۳.۶۰۵۹۳	۰.۱۰۴۶۷	۰.۱۰۲۰۸۵۵	-۳.۵۵E-۰۶	-۰.۰۰۳۲۷
y ₃	-۵۳.۴۳۱۹	۳.۳۷۶۰۷	۱.۷۶۵۰۹	-۰.۰۲۱۵۱۵	-۰.۰۰۲۴۳۷	-۰.۰۵۴۸۳
y ₄	۳۱.۵۴۲۵	-۰.۷۳۲۶۵	۰.۰۲۰۶۳	-۰.۰۱۷۷۱۳	-۵.۲۰E-۰۵	۰.۰۰۲۴۷
y ₅	-۴۵.۴۵۶	۱.۰۶۴۳۸	۳.۴۱۹۹۱	-۱.۰۱۱۹۰۲	-۱.۱۳۷۴۳۱	۲.۰۸۵۲۵
y ₆	۲۸.۱۳۳۷	-۰.۵۱۰۲۷	-۰.۵۱۰۲۶	۰.۰۱۱۸۹۹۶	۰.۰۱۱۹۰۳۱	۰.۰۱۱۹۴
y ₇	-۵۰.۰۵۸۳	۲.۵۰۷۲۱	۱.۶۲۶۴	۱.۲۱۱۰۲۷	۱.۱۶۹۵۵۳۳	-۲.۴۳۰۸۱

جدول شماره ۲- ضرایب مدل شبکه عصبی ۲۸ روزه

	b	w ₁	w ₂	w ₃	w ₄	w ₅
y ₁	۴۴.۴۸۱۸	۰.۰۳۷۶۷	-۰.۹۸۱۹۸	-۹.۰۳E-۰۵	-۰.۰۲۴۱۷۴	۰.۰۰۳۲۷
y ₂	۲۱.۵۷۸۵	-۰.۸۱۰۲۹	۰.۰۷۵۷۴	۰.۰۲۹۷۵۸۲	-۳.۳۳E-۰۶	-۰.۰۰۱۶۷
y ₃	-۵۲.۸۲۴۸	۳.۰۹۶۵۹	۱.۱۶۹۱۱	-۰.۰۲۰۳۹	-۰.۰۰۳۱۱۲	-۰.۰۲۵۴
y ₄	۲۱.۵۷۸۶	۰.۰۷۵۷۴	-۰.۸۱۰۲۹	-۳.۳۳E-۰۶	۲.۹۸E-۰۲	-۰.۰۰۱۶۷
y ₅	-۶۷.۰۶۵۸	-۲۱.۲۸۰۲	۲۵.۹۳۶۳	-۳.۲۴۱۸۳۷	-۳.۸۸۱۵۳۶	۷.۰۷۵۳۱
y ₆	-۷۰.۰۹۷۵	۱۹.۳۳۷۱	-۱۴.۵۹۴۷	-۱.۶۶۰۲۱۹	-۱.۱۶۵۰۷۵	۲.۷۷۶۷۸
y ₇	-۷.۶۷۷۳	-۵.۳۹۱۸۱	۶.۷۳۱۳۸	-۰.۴۸۱۲۵۲	-۰.۶۰۵۳۰۸	۱.۰۸۳۲۴



شکل شماره ۲- پیش بینی مقاومت فشاری ۷ روزه در سه لایه با استفاده از شبکه عصبی GMDH



شکل شماره ۳- پیش بینی مقاومت فشاری ۲۸ روزه در سه لایه با استفاده از شبکه عصبی GMDH

با بررسی شکل های ۲ و ۳ مشخص می شود مدل شبکه عصبی ۳ لایه به خوبی می تواند مقاومت ۷ و ۲۸ روزه را پیش بینی نماید.

نتیجه گیری

استفاده از نیم کک شیل نفتی به عنوان یکی از محصولات جانبی صنعت استخراج نفت، نه تنها راهکاری نوین برای کاهش ضایعات صنعتی و حفاظت از محیط زیست محسوب می شود، بلکه فرصت های قابل توجهی را در صنعت ساخت و ساز برای کاهش هزینه ها و بهبود کیفیت مصالح ساختمانی فراهم می آورد. بررسی ها نشان می دهند که این ماده، به دلیل دارا بودن ترکیبات معدنی همچون سیلیکا (SiO_2) و آلومینا (Al_2O_3)، پتانسیل بالایی برای بهبود خواص مکانیکی و شیمیایی بتن دارد. فعال سازی حرارتی نیم کک، با ایجاد تغییراتی در ساختار و ترکیب شیمیایی آن، امکان واکنش های پوزولانی و تقویت ویژگی های بتن را فراهم می آورد. در ترکیب نیم کک با بتن از طریق بهره گیری از مدل های پیشرفته هوش مصنوعی نظیر GMDH امکان پیش بینی دقیق خواص آن فراهم می گردد و زمینه ای برای طراحی بهینه ترکیبات بتن در مقیاس صنعتی ایجاد می کند. این ابزارهای نوین می توانند هزینه های آزمایشگاهی را کاهش داده و بهره وری تحقیق و توسعه را افزایش دهند. در مجموع، استفاده از نیم کک شیل نفتی یک راه حل چندجانبه است که علاوه بر کاهش هزینه ها، بهبود خواص مصالح ساختمانی و حفاظت از محیط زیست، چشم انداز روشنی در مدیریت ضایعات صنعتی ارائه می دهد.

مراجع

- [1] Rahman et al., "Sustainable construction practices: Current challenges and future perspectives," Sustainability, 2024
- [2] Wang and Chen, "Environmental footprint reduction strategies in concrete production: A 2024 review," Journal of Cleaner Production, 2024
- [3] Azimi and Huang, "Circular economy in construction materials: Progress and challenges," Materials Today Sustainability, 2024
- [4] Zhang et al., "Carbon dioxide emissions from global cement production: Updated assessment and mitigation strategies," Nature Sustainability, 2024
- [5] Liu and Park, "Oil shale semi-coke as a sustainable admixture in cementitious materials," Resources, Conservation and Recycling, 2024
- [6] Johnson et al., "Thermal activation of oil shale by-products for cement replacement," Journal of Cleaner Production, 2024

- [7] Rashid and Mohammed, "Recent advances in supplementary cementitious materials from industrial wastes," *Construction and Building Materials*, 2025
- [8] Guo et al., "Thermo-mechanical behavior of oil shale semi-coke in concrete: An experimental investigation," *Journal of Building Engineering*, 2024
- [9] Ahmed and Thompson, "Enhanced durability of concrete containing thermally activated oil shale semi-coke," *Cement and Concrete Research*, 2024
- [10] Chen et al., "C-S-H gel formation mechanisms in concrete containing activated waste materials," *Cement and Concrete Composites*, 2025
- [11] Zhou and Liu, "Chemical and mineralogical characterization of oil shale semi-coke for cementitious applications," *Journal of Materials in Civil Engineering*, 2024
- [12] Park and Kim, "Advanced computational methods in concrete technology: A state-of-the-art review," *Construction and Building Materials*, 2025
- [13] Moradi et al., "Artificial intelligence in construction materials design: Current status and future prospects," *Automation in Construction*, 2024
- [14] Li and Wang, "Self-organizing neural network architectures for materials science applications," *Neurocomputing*, 2024
- [15] Zhang and Kumar, "Emerging deep learning techniques for performance prediction of sustainable concrete mixtures," *Journal of Computing in Civil Engineering*, 2025
- [16] Johnson and Brown, "Evolution of GMDH algorithms: From classic to modern implementations," *Neural Networks*, 2024
- [17] Singh et al., "Polynomial neural networks for complex systems modeling: A comprehensive review," *Information Sciences*, 2025
- [18] Taha and Ahmed, "GMDH-based modeling of cement-based composites: Advantages and limitations," *Cement and Concrete Research*, 2024

[19] Liu et al., “Multi-parameter optimization of concrete mixtures using advanced neural networks,” *Construction and Building Materials*, 2025

[20] Wang and Zhang, “Optimal neural network architecture design for concrete property prediction,” *Engineering Structures*, 2024

[21] Sharma and Wilson, “GMDH modeling of alternative cementitious materials: Case studies and applications,” *Journal of Materials in Civil Engineering*, 2025

[22] Bo Li, Jiadong Wang, Gui Cao, Xueli Nan, Xiaomin Li, Wenju Li, Yunpeng Zhang, Laboratory investigation and BP neural network modeling on heat-activated oil shale semi-coke attributable to the mechanical properties of concrete, *Case Studies in Construction Materials*, (2023) ,ISSN 2214-5095,

[23] Beheshti Nezhad, H., Miri, M. & Ghasemi, M.R. New neural network-based response surface method for reliability analysis of structures. *Neural Comput & Applic* 31, 777–791 (2019).