

## کمینه‌سازی اضافه‌حفاری ناشی از انفجار در تونل‌ها با استفاده از روش‌های هوشمند

محمد رضا کوپی علی‌پور<sup>۱</sup>، ابراهیم نوروزی قالینی<sup>۲</sup>، حسن مدنی<sup>۳</sup>\*

<sup>۱</sup> تونلسازی، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران، ایران، mr.koopialipoor@aut.ac.ir

<sup>۲</sup> استخراج معدن، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران، ایران، ebrahim.noroozi@aut.ac.ir

<sup>۳</sup> استادیار دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران، ایران، hmadani@aut.ac.ir

### چکیده

ایجاد پدیده حفر بیش از اندازه مقطع تونل یا همان اضافه‌حفاری مقطع تونل در مراحل اجرایی پروژه‌های تونل‌سازی، همواره از مهم‌ترین مسایلی است که ذهن متصدیان فنی و اجرایی این پروژه‌ها را به خود معطوف داشته است. امروزه با توجه به پیشرفت صنعت و ورود فناوری‌های نوین به صنعت تونل‌سازی و پذیرفته شدن تدریجی، روش‌های جدیدی جایگزین روش‌های سنتی (حفاری و آتشکاری) شده است. اگرچه تا حد زیادی مساله ایجاد حفاری خارج از طرح و نقشه، به کنترل اجراکنندگان پروژه درآمده است، ولی هیچ‌گاه وجود این مساله مهم و اساسی در پروژه‌های تونلی به طور کلی حذف نشده است. در این تحقیق با استفاده از شبکه‌های هوشمند پیش‌بینی و بهینه‌سازی اضافه‌حفاری مورد بحث قرار گرفت. پس از انتخاب بهترین مدل بر اساس امتیازدهی، مدل منتخب برای بهینه‌سازی مورد استفاده قرار گرفت. مقادیر شاخص‌های آماری ضریب تعیین ( $R^2$ ) و مجذور میانگین مربعات خطا (RMSE) مدل منتخب به ترتیب برای آموزش و آزمایش برابر با ۰/۹۲۱، ۰/۴۰۲۸ و ۰/۹۲۳ و ۰/۴۲۷۷ بود. الگوریتم زنبور عسل که یکی از الگوریتم‌های جدید بهینه‌سازی است برای بهینه‌سازی این پارامترهای الگوی انفجار استفاده شد. با توجه به اینکه اضافه‌حفاری از مشکلات اصلی در حفر تونل است، کاهش این مقدار می‌تواند کمک به سزایی برای تونل و پایداری آن داشته باشد. پس از ساختن چندین مدل بهینه‌سازی و تغییرات وزن‌های آن، مقدار بهینه آن برای اضافه‌حفاری مقطع تونل ۱/۶۳ مترمربع به دست آمد که نسبت به کمترین مقدار تجربه شده در اجرا (۳/۰۵۵ مترمربع) ۴۷ درصد کاهش یافته است.

### کلمات کلیدی

تونل، اضافه‌حفاری مقطع تونل، شبکه‌های عصبی مصنوعی، الگوریتم زنبور عسل

## ۱- مقدمه

امروزه حفر تونل‌ها برای اهداف مختلفی از جمله استخراج مواد معدنی و پروژه‌های معدنی مانند راه‌سازی، انتقال آب و نظایر آن انجام می‌شود. در ایران به علت وجود رشته‌کوه‌های بزرگی که قسمت عظیمی از مساحت آن را فرا گرفته است احداث تونل برای مقاصد مختلف الزامی است و با توجه به پیشرفت صنعت و ورود فناوری‌های نوین به صنعت تونل‌سازی و پذیرفته شدن تدریجی، روش‌های حفاری نیمه مکانیزه و مکانیزه جایگزین روش‌های حفاری سنتی شده‌اند؛ اما در مواردی مانند پروژه‌های کوچک و با مقیاس کم که بخش عمده‌ای از پروژه‌های عمرانی را در برمی‌گیرد، در حفاری سنتی ایجاد اضافه‌حفاری<sup>۱</sup> در مراحل اجرایی یک پروژه تونل‌سازی، همواره از مهم‌ترین مسائلی است که ذهن متصدیان فنی و اجرایی این پروژه‌ها را به خود معطوف داشته است.

آشنایی با مهم‌ترین علل پیدایش یک پدیده، به عنوان نخستین گام در پیش‌بینی و کنترل آن مطرح است؛ با در نظر گرفتن این دیدگاه، در تحقیق حاضر نیز با توجه به موضوع این تحقیق به مطالعات و بررسی‌های لازم برای شناسایی نتایج قابل‌دسترس و قابل‌اندازه‌گیری در ساختگاه تونل آب‌بر، طرح سد و نیروگاه سردشت انجام گرفت. از آنجا که پارامترهای تاثیرگذار زیادی بر روی ایجاد پدیده اضافه‌حفاری ناشی از فرآیند انفجار در این پروژه شناسایی شد، بررسی و مطالعه ارتباط بین آن‌ها بر روی این پدیده با استفاده از روش‌های آماری امکان‌پذیر نبود، بنابراین لزوم به کارگیری یک وسیله هوشمند قوی برای تجزیه و تحلیل این پارامترها ضروری به نظر می‌رسید. از این‌رو شبکه‌های عصبی مصنوعی به عنوان یکی از شاخه‌های محاسبات هوشمند در این تحقیق مورد استفاده قرار گرفت. شبکه‌های عصبی به دلیل قابلیت یادگیری، انعطاف‌پذیری و دقت بالای آن و قوانین یادگیری آن که بر پایه دستیابی به کمترین مجددور میانگین مربعات خطا (RMSE) ممکن بین مقادیر واقعی و پیش‌بینی شده از شبکه بناشده انتخاب شده است.

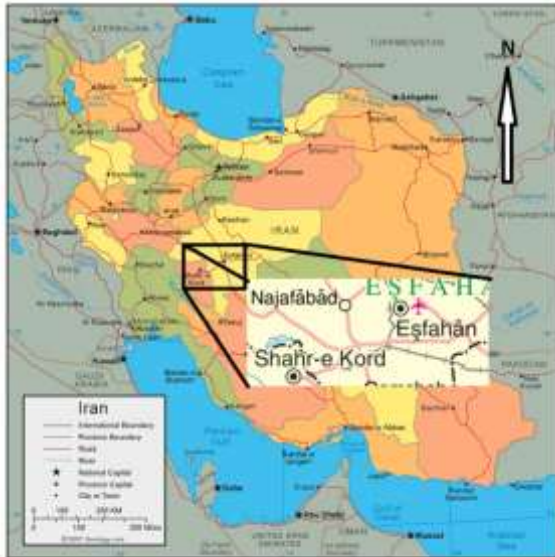
عوامل موثر در اضافه‌حفاری را می‌توان در سه گروه ویژگی‌های توده سنگ، خصوصیات ماده منفجره و مشخصات هندسی الگوی انفجار دسته‌بندی کرد [۱]. تاکنون تحقیقات زیادی بر روی اضافه‌حفاری در معادن و تونل‌ها انجام شده است. منجزی و دهقانی نسبت طول گل‌گذاری به بارسنگ، نسبت خرج ردیف آخر به کل خرج مصرفی، خرج ویژه مصرفی در کل الگوی انفجار، میزان خرج مصرفی در هر تاخیر و تعداد ردیف‌های انفجاری در هر مرحله را در معدن گل‌گوهر از عوامل موثر بر اضافه‌حفاری

دانسته‌اند [۲]. منجزی و همکاران بیان می‌کنند که در معدن سنگان شاخص کیفیت سنگ بیشترین و تعداد ردیفی چال‌ها کمترین تاثیر را بر اضافه‌حفاری داشته است [۳]. چانگ و توپال با استفاده از شبکه عصبی پرسپترون میزان اضافه‌حفاری را در تونل گیبی کره جنوبی با ضریب همبستگی ۰/۹۴۵ بین خروجی شبکه عصبی و اضافه‌حفاری واقعی پیش‌بینی کردند. ورودی مدل آن‌ها شامل مقاومت فشاری تک‌محوره توده‌سنگ، شاخص کیفی توده‌سنگ، شرایط هوازدگی سنگ، شرایط آب زیرزمینی و مقادیر شاخص طبقه‌بندی ژئومکانیکی توده‌سنگ و خروجی آن مقادیر اضافه‌حفاری را نشان می‌داد [۴]. خندوال و منجزی با استفاده از شبکه عصبی ماشین بردار پشتیبان مقادیر اضافه‌حفاری در معدن مس سونگون را با ضریب تخمین ۰/۹۸۷ و میانگین مجموع قدر مطلق خطای ۰/۲۹ پیش‌بینی کردند [۵]. منجزی و همکاران برای ایجاد یک مدل جامع در معدن چادرمو پارامترهای مقاومت فشاری تک‌محوره سنگ، حفاری ویژه، محتوی آب زیرزمینی، بارسنگ، فاصله‌داری چال‌ها، طول گل‌گذاری، قطر چال، ارتفاع پله، خرج ویژه و خرج مصرفی در هر تاخیر را به عنوان پارامترهای ورودی به شبکه عصبی استفاده کردند. آن‌ها با تحلیل حساسیت بر روی این پارامترها بارسنگ را به عنوان موثرترین پارامتر و محتوای آب زیرزمینی را کم اهمیت‌ترین پارامتر بیان کردند [۶]. هوک و براون گزارش دادند که هنگامی که امتداد صفحات ناپیوستگی موازی با محور تونل باشد، اثرات نامطلوبی بر روی اضافه‌حفاری دارد.

الویر<sup>۲</sup> تاخیرهای بسیار کوتاه را عامل اصلی و ازدیاد بارسنگ را یکی از مهم‌ترین عوامل اضافه‌حفاری می‌داند [۷]. منجزی و همکاران طول گل‌گذاری، عمق چال و فاصله چال‌ها را از مهم‌ترین عوامل موثر بر اضافه‌حفاری می‌دانند. از نظر شیبات فراوانی درزه به میزان سه تا چهار صفحه درزه تاثیر معکوسی بر روی اضافه‌حفاری دارد [۸]. ابراهیمی و همکاران بارسنگ، فاصله‌داری طول چال، اضافه‌حفاری و خرج ویژه را موثر بر اضافه‌حفاری می‌دانند [۹].

ساقی‌فروش<sup>۳</sup> و همکاران با ترکیب شبکه‌های عصبی مصنوعی (ANN) و الگوریتم بهینه‌سازی کلونی مورچگان با استفاده از متغیر در نظر گرفتن پارامترهای موثر میزان پرتاب سنگ و اضافه‌حفاری را هر کدام ۶۱ و ۵۸ درصد کاهش دادند [۱۰]. منجزی و دهقانی گزارش دادند که نسبت شارژ آخرین ردیف چال به شارژ کل از مهم‌ترین عوامل موثر بر اضافه‌حفاری است [۲]. اسماعیلی و همکاران بیان کردند که شارژ ردیف آخر، فاکتور پودر و اضافه‌حفاری از مهم‌ترین عوامل موثر

و عرض ۱۳ متر است که در استان چهارمحال و بختیاری و در فاصله ۳۰ کیلومتری از شهرکرد واقع شده است. مقطع تونل نعل اسبی است. مشخصات این تونل در جدول ۱ و محل تقریبی این تونل در شکل ۱ نشان داده شده است.



شکل ۱- محل تونل بر روی نقشه

در این تحقیق از ۲۵۰ دسته داده استفاده شد. هر دسته داده شامل پارامترهای RMR توده سنگ، میزان پیشروی در هر مرحله از انفجار، خرج ویژه مصرفی، بار سنگ چال‌های محیطی، بار سنگ چال‌های ماقبل محیط، فاصله‌داری چال‌های محیطی، فاصله‌داری چال‌های پیرامون، حفاری ویژه و تعداد تاخیرهای اعمال شده در هر مرحله حفاری برای داده‌های ورودی مدل شبکه عصبی انتخاب شدند، سپس با توجه به این داده‌ها، مقدار اضافه‌حفاری که به عنوان خروجی شبکه به کار می‌رود، پیش‌بینی می‌شود. خلاصه‌ای از ویژگی‌های آماری این داده‌ها در جدول ۲ ارائه شده است.

بر اضافه حفاری است، در صورتی که نسبت بار سنگ به فاصله‌داری، سختی و چگالی کمترین اهمیت را دارند [۱۱]. ایبارا و همکاران خرج ویژه محیط را عاملی از ماده منفجره می‌دانند که باعث حفاری کمتر از حد نیاز<sup>۴</sup> در تونل‌ها می‌شود و کیفیت سنگ باعث افزایش اضافه‌حفاری خواهد شد [۱۲]. مندل بیان می‌دارد که علاوه بر شرایط سنگ تنش درجا نیز بر اضافه‌حفاری تاثیرگذار است. چندین پژوهشگر مدل‌های تجربی را برای تخمین میزان پرتاب سنگ و عقب‌زدگی پیشنهاد کردند [۱۳]. سینگ<sup>۵</sup> آزمایش تجربی بر روی مدل‌های کوچک مقیاس فیزیکی برای پیش‌بینی خسارات ناشی از انفجار انجام داد. در این مقاله آن‌ها ویژگی‌های توده سنگ، ویژگی‌های ماده منفجره و پارامترهای طراحی را موثر در اضافه‌حفاری می‌دانند [۱۵]. در تونل‌سازی تعداد معدودی تحقیق در زمینه پیش‌بینی اضافه‌حفاری انجام گرفته است. جانگ و توپال [۴] با استفاده از شبکه عصبی به پیش‌بینی اضافه‌حفاری در تونلی در کره جنوبی پرداختند. در این کار آن‌ها از یک مجموعه داده ۴۹ تایی که شامل ۶ ورودی بود استفاده کردند. این ورودی‌ها به ترتیب RMR، مقاومت سنگ، شاخص کیفیت سنگ، فاصله درزه‌ها، جهت درزه‌ها و سطح آب زیرزمینی بوده است. پژوهش دیگری برای اضافه‌حفاری در تونلی در چین توسط سان و همکاران ارائه شد [۱۶]. بر اساس تحقیقات آن‌ها، شبکه‌های عصبی می‌توانند برای پیش‌بینی اضافه‌حفاری در تونل‌ها به کار روند و با تقریب مناسبی این پدیده را پیش‌بینی کنند.

در تحقیق حاضر، با استفاده از شبکه‌های عصبی به پیش‌بینی اضافه‌حفاری در تونل‌هایی که با چال‌زنی و انفجار حفر می‌شوند، پرداخته شده است. پس از ایجاد مدل‌های مختلف از سیستم امتیازدهی بهترین مدل انتخاب شد. سپس در ادامه، الگوریتم بهینه‌سازی زنبور عسل برای به دست آوردن مقادیر بهینه الگوی انفجار برای کاهش مقدار اضافه‌حفاری مورد استفاده قرار گرفت. با توجه به نتایج به دست آمده می‌توان الگوهای مناسب برای کاهش اضافه‌حفاری در تونل‌ها را به کار گرفت.

## ۲- اصول و تئوری مقاله (جمع آوری داده‌ها)

تونل گردنه رخ یکی از مهم‌ترین تونل‌های منطقه غرب کشور ایران است. این تونل راه اصلی ارتباطی بین دو مرکز استان‌های اصفهان و چهارمحال و بختیاری است. جاده اصفهان - شهرکرد از نظر اقتصادی و استراتژیکی از شاه‌راه‌های بسیار مهم و حیاتی در کشور ایران به شمار می‌رود. تونل مسیر ارتباطی بین دو مرکز استان را هفت کیلومتر کوتاه‌تر و حدود یکصد پیچ و نقطه حادثه‌خیز در این محور را حذف می‌کند [۱۷]. تونل مورد مطالعه به طول ۱۳۰۰ متر

جدول ۱- مشخصات کلی حفاری بخش تاق تونل با استفاده از چالزنی و انفجار

ردیف	خصوصیت	توضیحات
۱	شکل مقطع	نعل اسبی
۲	سطح مقطع تونل در قسمت تاق	۳۲٫۱۵ مترمربع
۳	محیط تونل در قسمت تاق	۱۵۰٫۵۲ متر
۴	قطر چال	۴۵ و ۵۱ میلی‌متر
۵	نوع ماده منفجره مصرفی	دینامیت ژلاتینی
۶	تعداد چال	۴۵ تا ۸۸ عدد
۷	عمق چال	۱٫۲ تا ۳ متر
۸	آرایش چال‌های منطقه برش	گوه‌ای
۹	زاویه چال منطقه برش نسبت به خط عمود بر محور تونل	۶۹ تا ۷۲ درجه
۱۰	کل وزن ماده منفجره مصرفی	۴۸ تا ۱۱۸ کیلوگرم
۱۱	نحوه خرج‌گذاری چال‌ها	پیوسته
۱۲	طول گل‌گذاری چال‌ها	متناسب با شرایط سنگ از ۱۵ تا ۶۰ سانتی‌متر

جدول ۲- ویژگی‌های آماری داده‌های مورد استفاده در شبکه

ردیف	پارامتر	حداقل	حداکثر	انحراف استاندارد	نوع داده
۱	تعداد تاخیرها	۴	۱۰	۱٫۲	ورودی
۲	بار سنگ چال‌های ردیف آخر (متر)	۰٫۶	۲	۰٫۲	ورودی
۳	بار سنگ چال‌های ردیف پیرامون (متر)	۰٫۶	۱٫۸	۰٫۲۲	ورودی
۴	فاصله‌داری چال‌های ردیف آخر (متر)	۰٫۳	۱٫۷	۰٫۱۷	ورودی
۵	فاصله‌داری چال‌های ردیف پیرامون (متر)	۰٫۶	۱٫۲۵	۰٫۱۷	ورودی
۶	خرج ویژه (کیلوگرم/ مترمکعب)	۰٫۴۱	۱٫۶۵	۰٫۲۳	ورودی
۷	طول پیشروی (متر)	۰٫۵	۳٫۹۶	۰٫۵۸	ورودی
۸	شاخص طبقه‌بندی ژئومکانیکی توده‌سنگ (RMR)	۳۰	۳۹	۶٫۴۷	ورودی
۹	اضافه‌حفاری مقطع تونل (مترمربع)	۳٫۰۵۵	۱۱٫۳۵	۲٫۴۷	خروجی

### ۳- نتایج و بحث

#### ۳-۱- شبکه عصبی

می‌توان آن را تعمیم الگوریتم موسوم به حداقل میانگین دانست. به طور کلی، یادگیری پیش‌خور شامل دو مرحله پیشروی و بازگشت است. در مرحله پیشروی، ورودی‌ها لایه به لایه در شبکه پیش می‌روند و در نهایت یک‌سری خروجی به عنوان پاسخ‌های واقعی شبکه حاصل خواهد شد. در مدت مرحله پیشروی، اوزان سیناپسی به دست خواهد آمد. از طرف دیگر، در مرحله بازگشت،

یکی از پرکاربردترین الگوریتم‌های یادگیری در شبکه‌های عصبی پرسپترون، الگوریتم یادگیری پیش‌خور است [۱۸]. این الگوریتم بر مبنای قانون یادگیری تصحیح خطا عمل می‌کند که

جدول ۳- روابط موجود برای تعیین نرون‌های لایه پنهان

مرجع	رابطه
[۲۰]	$\leq 2 \times N_i + 1$
[۲۱]	$(N_i + N_0)/2$
[۲۲]	$\frac{2 + N_0 \times N_i + 0.5 N_0 \times (N_0^2 + N_i) - 3}{N_i + N_0}$
[۲۳]	$2N_i/3$
[۲۴]	$\sqrt{N_i \times N_0}$
[۲۵] و	$2N_i$
[۲۶]	

با توجه به مقادیر پیشنهادی از روابط جدول ۳، برای الگوریتم یادگیری از نوع لونیبرگ-مارکوات، شبکه عصبی از محدوده‌ای بین ۲ تا ۱۸ نرون برای لایه پنهان الگوریتم‌ها استفاده شد. با توجه به اهمیتی که  $R^2$  (مجذور ضریب همبستگی بین داده‌ها) و RMSE (ریشه دوم میانگین مربعات خطا) هر سری از بخش‌های آموزش و آزمایش سیستم‌ها دارد، مقایسه‌ای بین آن‌ها برای انتخاب بهترین مدل انجام شد. به هر بخش امتیازبندی اختصاص داده می‌شود و در پایان، امتیاز هر ردیف از مدل‌ها جمع شده و به عنوان امتیاز کلی در نظر گرفته می‌شود [۲۷]. برای امتیازدهی ترتیب مدلی که دارای بزرگ‌ترین مقدار  $R^2$  است بیشترین امتیاز و با کاهش آن امتیاز کمتری می‌گیرد و برای خطای RMSE به ترتیب مدلی که دارای کمترین مقدار خطای RMSE است دارای بیشترین امتیاز و با افزایش آن امتیاز کمتری به آن اختصاص خواهد یافت. در جدول ۴ نتایج این شبکه عصبی آورده شده است.

همان‌طور که در جدول ۴ دیده می‌شود، مدل شماره ۷ که با الگوریتم یادگیری LM (لونیبرگ-مارکوات) ایجاد شده، به عنوان بهترین مدل بر اساس امتیازدهی انتخاب شد. در شکل‌های ۲ و ۳ نمودارهای مدل شماره ۷ رسم شده است.


این اوزان با قوانین تنظیم خطا تنظیم می‌شوند. تفاضل پاسخ پیش‌بینی‌شده شبکه و پاسخ مطلوب (مورد انتظار) که سیگنال خطا نامیده می‌شود در جهت مخالف اتصالات در شبکه منتشر می‌شود و اوزان به گونه‌ای تغییر می‌کنند که پاسخ پیش‌بینی‌شده به پاسخ مطلوب نزدیک‌تر شود. چون توزیع اخیر، در خلاف اتصالات وزنی انجام می‌گیرد، کلمه پیش‌خور برای توضیح اصلاح رفتاری شبکه انتخاب شده است. برای سنجش میزان همبستگی دو متغیر از  $R^2$  و RMSE استفاده شد.

در این تحقیق در ابتدا شبکه عصبی طبق الگوریتم یادگیری لونیبرگ-مارکوات پیاده‌سازی شد. این الگوریتم از جمله متداول-ترین الگوریتم‌های شبکه عصبی است. تعداد لایه‌های یک مدل شبکه عصبی مطابق با برخی از تحقیقات انجام گرفته [۱۹]، سه لایه انتخاب شد. این لایه‌ها شامل یک لایه ورودی با ۹ داده و لایه خروجی با یک خروجی و یک لایه پنهان انتخاب شد. بر اساس مطالعه هورنیک<sup>۷</sup> و همکاران [۱۹]، یک لایه پنهان می‌تواند هرگونه تابع غیرخطی را حل کند. برای انتخاب تعداد نرون‌های لایه پنهان تحقیقاتی انجام گرفته است که در آن تعداد مناسب را پیشنهاد داده‌اند. این کار برای جلوگیری از روش‌های سعی و خطا برای رسیدن به مقدار مناسب است. روش‌های موجود برای تعیین تعداد نرون‌های لایه پنهان در جدول ۳ ارایه شده است. در این جدول  $N_i$  تعداد ورودی،  $N_0$  تعداد خروجی‌های مدل است.


جدول ۴- مقادیر پیش‌بینی برای اضافه‌حفاری

No. Model	No. Neuron	Train		Test		Train		Test		Total rank
		R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	rank R <sup>2</sup>	rank RMSE	rank R <sup>2</sup>	rank RMSE	
۱	۲	۰٫۹۲۳	۰٫۳۷۹۸	۰٫۹۰۶	۰٫۴۴۹۴	۹	۱۱	۱۰	۸	۳۸
۲	۳	۰٫۹۱۷	۰٫۴	۰٫۹۰۲	۰٫۴۵۱۱	۶	۶	۸	۷	۲۷
۳	۴	۰٫۹۲۳	۰٫۳۸۴۳	۰٫۹۰۲	۰٫۴۷۱۶	۹	۷	۸	۶	۳۰
۴	۵	۰٫۹۱۳	۰٫۴۰۶۲	۰٫۹۱۲	۰٫۳۸۹۶	۵	۵	۱۱	۱۴	۳۵
۵	۶	۰٫۹۲۵	۰٫۳۷۸۱	۰٫۹۰۴	۰٫۴۱۳۱	۱۰	۱۲	۹	۱۳	۴۴
۶	۷	۰٫۹۱۹	۰٫۳۸۲۲	۰٫۹۱۳	۰٫۴۴۷۷	۷	۹	۱۲	۹	۳۷
۷	۸	۰٫۹۲۱	۰٫۳۷۱۶	۰٫۹۲۳	۰٫۴۳۰۸	۸	۱۳	۱۴	۱۱	۴۶
۸	۹	۰٫۹۱۹	۰٫۴۱۰۷	۰٫۸۹۶	۰٫۴۹۵۵	۷	۳	۷	۴	۲۱
۹	۱۰	۰٫۹۰۴	۰٫۴۱۹۷	۰٫۹۲۱	۰٫۴۱۸۷	۴	۲	۱۳	۱۲	۳۱
۱۰	۱۱	۰٫۹۲۹	۰٫۳۸۰۲	۰٫۸۸۳	۰٫۴۸۹۶	۱۲	۱۰	۴	۵	۳۱
۱۱	۱۲	۰٫۹۰۴	۰٫۵۴۵۳	۰٫۸۸۷	۰٫۴۴۲۹	۴	۱	۶	۱۰	۲۱
۱۲	۱۴	۰٫۹۲۷	۰٫۳۸۳۶	۰٫۸۸۶	۰٫۵۵۱۷	۱۱	۸	۵	۱	۲۵
۱۳	۱۶	۰٫۹۳۵	۰٫۴۰۷۱	۰٫۸۶۶	۰٫۵۴۲۸	۱۳	۴	۲	۲	۲۱
۱۴	۱۸	۰٫۹۴۴	۰٫۳۲۹۷	۰٫۸۶۸	۰٫۵۰۱۸	۱۴	۱۴	۳	۳	۳۴

آموزش R<sup>2</sup>



شکل ۲- مقادیر پیش‌بینی شده اضافه‌حفاری مقطع تونل برای آموزش مدل شماره ۷



شکل ۳- مقادیر پیش بینی شده اضافه حفاری مقطع تونل برای آزمایش مدل شماره ۷

### ۲-۲- تحلیل حساسیت

برای تعیین تاثیر موثرترین پارامترها بر پدیده اضافه حفاری، تحلیل حساسیت انجام شد. برای این هدف، از روش دامنه کسینوسی<sup>۸</sup> استفاده شد. در این روش، همه جفت داده ها به عنوان یک نقطه ویژه در فضای n بعدی تعریف می شوند. بدین ترتیب، هر پارامتر به صورت مستقیم به خروجی ها وصل می شود (رابطه ۱) [۲۸، ۲۹].

که در آن:


$X_i$  ورودی

$X_j$  خروجی

m تعداد مجموعه داده ها

هر چه مقدار  $r_{ij}$  بیشتر باشد، نشان می دهد که تاثیر آن پارامتر بیشتر است. مقادیر به دست آمده از  $r_{ij}$  در شکل ۴ نشان داده شده است. پارامترهای RMR و طول پیشروی بیشترین تاثیر را روی پدیده اضافه حفاری دارند.

$$r_{ij} = \left( \frac{\sum_{k=1}^m X_{ik} X_{jk}}{\sqrt{\sum_{k=1}^m X_{ik}^2 \sum_{k=1}^m X_{jk}^2}} \right) \quad (1)$$



شکل ۴- تحلیل حساسیت پارامترهای ورودی بر اضافه حفاری

## ۳-۳- الگوریتم بهینه‌سازی زنبورعسل

الگوریتم بهینه‌سازی زنبورعسل از زندگی اجتماعی زنبورها الهام گرفته شده است. در یک کلونی زنبور، هر یک از زنبورهای یک جزو ساده‌ای است، اما زمانی که این اجزا ساده با هم تشکیل یک کلونی زنبور را دهند دارای یک رفتار منسجم و پیچیده می‌شوند که توانایی ایجاد سیستمی یکپارچه برای کشف و بهره‌برداری از شهد گل‌ها را دارد. هر کلونی زنبور از سه دسته زنبور تشکیل شده است که هر یک از آن‌ها وظیفه‌ای را بر عهده دارند. اولین گروه از زنبورها را زنبورهای پیش‌آهنگ تشکیل می‌دهند. این دسته از زنبورها وظیفه کشف منابع جدید را برعهده دارند. زنبورهای پیش‌آهنگ به صورت تصادفی محیط اطراف را جستجو می‌کنند و پس از یافتن یک منبع غذایی مکان آن را در حافظه خود ذخیره می‌کنند. پس از بازگشت هر زنبور پیش‌آهنگ به کندو اطلاعات حاصل از منبع را در یک رقص چرخشی با سایر زنبورهای درون کندو به اشتراک می‌گذارد و تعدادی از آن‌ها را برای بهره‌برداری از آن کندو استخدام می‌کند. گروه دوم از زنبورهای درون یک کندو را زنبورهای کارگر تشکیل می‌دهند. زنبورهای کارگر وظیفه بهره‌برداری از منابع غذایی از پیش تعیین شده را بر عهده دارند. سومین گروه از زنبورهای یک کندو را زنبورهای ناظر تشکیل می‌دهند. این دسته از زنبورها درون کندو منتظر سایر زنبورها می‌مانند و پس از تبادل اطلاعاتی با سایر زنبورها در رقص چرخشی یکی از منابع را بر اساس شایستگی جواب برای بهره‌برداری انتخاب می‌کنند.

الگوریتم زنبور عسل برای اولین بار توسط کارابوگا در سال ۲۰۰۵ ارائه شد [۳۰]. از این الگوریتم در حل بسیاری از مسایل مهندسی، صنعتی و ریاضی همچون بهینه‌سازی مکان حفر چاه‌ها در مخازن نفتی [۳۱]، بهینه‌سازی تخلیه آب از سد [۳۲]، خوشه‌بندی داده‌ها [۳۳] و زمان‌بندی کار ماشین‌ها [۳۴]، خطایابی تصادفی نیروگاه اتمی [۳۵] و تلفیق آن با شبکه‌های عصبی مصنوعی مانند پیش‌بینی فشار انتهای چاه به همراه شبکه [۳۶] استفاده شده است. یکی از معدود مشاهدات استفاده شده از این الگوریتم در معدن، پیش‌بینی و بهینه‌سازی عقب‌زدگی<sup>۹</sup> ناشی انفجار در معادن است [۹].

این الگوریتم از چهار مرحله تشکیل شده است. مراحل اصلی از الگوریتم زنبور در زیر آورده شده است [۳۷]:

- مقداردهی اولیه

- تکرار

ارسال زنبورهای کارگر به منابع غذایی

ارسال زنبورهای ناظر به منابع غذایی

ارسال زنبورهای پیش‌آهنگ برای جستجوی برای منابع غذایی جدید

تا (وضعیت مورد دلخواه بدست آید).

این مراحل را به صورت زیر می‌توان تشریح کرد:

**مرحله اول:** در الگوریتم ABC، برای اولین بار نیمی از جمعیت زنبورها، زنبور کارگر و نیمی دیگر زنبور غیرکارگرند. برای هر منبع غذایی، فقط یک زنبورعسل کارگر وجود دارد؛ به عبارت دیگر، تعداد زنبورهای کارگر با تعداد منابع غذایی اطراف کندو با هم برابرند، بنابراین به هر منبع غذایی یک زنبور کارگر اختصاص داده می‌شود که در محدوده جواب به تعداد منابع غذایی جواب اولیه ایجاد می‌شود. پس از ایجاد جواب‌های اولیه باید ارزش هر جواب با استفاده از روابط مربوط به مساله محاسبه شود.

**مرحله دوم:** در این مرحله به ازای هر یک از جواب‌های مساله یک جواب جدید با استفاده از رابطه ۲ ایجاد می‌شود.

$$v_{i,j} = x_{i,j} + \varphi_{i,j}(x_{i,j} - x_{k,j}) \quad (2)$$

$$i \in \{1, 2, \dots, BN\}$$

$$j \in \{1, 2, \dots, D\}$$

$$k \in \{1, 2, \dots, BN\} \& k \neq i$$

$$\varphi \in [-1, 1]$$

که در آن:

$x_{i,j}$  پارامتر  $z$ ام از جواب  $i$ ام مساله

$v_{i,j}$  پارامتر  $z$ ام در جواب جدید

$i$  عددی از یک تا تعداد جواب‌های مساله

$\varphi$  عددی تصادفی در بازه منفی یک تا یک

$k$  عددی تصادفی از یک تا تعداد جواب‌های مساله

$BN$  تعداد جواب‌های اولیه برای مساله

$D$  تعداد پارامترهای بهینه‌سازی

پس از ایجاد جواب جدید اگر ارزش این جواب بیش از ارزش جواب قبل باشد، جایگزین آن خواهد شد در غیر این صورت این جواب فراموش می‌شود.

**مرحله سوم:** در این مرحله احتمال دریافت زنبور به وسیله هر منبع از رابطه ۳ محاسبه می‌شود [۳۷].



تعداد عدم بهبود جواب ایجاد شود و در صورتی که در جواب بهبود حاصل نشود یک واحد به مقدار آن افزوده خواهد شد.

**مرحله چهارم:** در این مرحله اگر شمارنده تعداد عدم بهبود جواب برای آن به حد از پیش تعیین شده ( $C_{max}$ ) برسد این جواب با یک جواب تصادفی جایگزین خواهد شد. همچنین در این مرحله شرایط پایان تکرارها نیز در صورتی که شرایط پایان الگوریتم برقرار باشد تکرارها پایان می پذیرد و در غیر این صورت به مرحله دو باز خواهد گشت.

در این تحقیق، بعد از انتخاب بهترین شبکه ساخته شده از الگوریتم زنبور عسل برای کمیته سازی اضافه حفاری تونل استفاده شد. با توجه به اینکه مقدار RMR در محدوده ۳۰ تا ۳۹ متغیر است، بیشترین تعداد نمونه ها با RMR که در حدود ۳۶ بوده انتخاب شد و بهینه سازی برای این محدوده از توده سنگ مسیر تونل به دست آمد. در شکل ۶ هیستوگرام RMR آورده شده است.

$$p_i = \frac{fit_i}{\sum_{n=1}^{SN} fit_n} \quad (3)$$

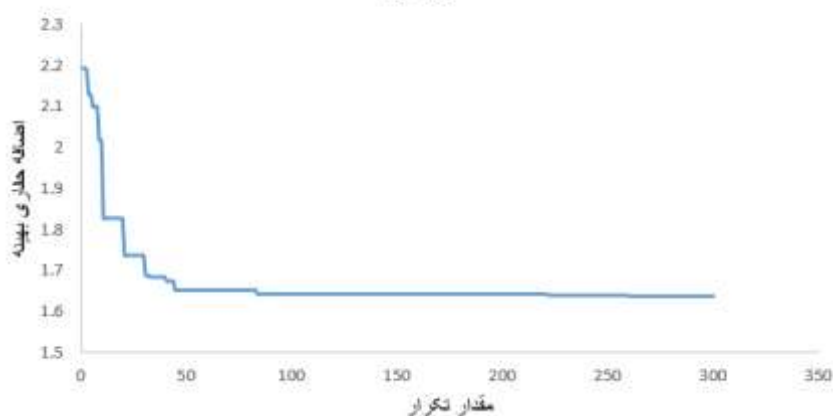
که در آن:

$fit_i$  شایستگی منبع  $i$


$p_i$  احتمال انتخاب منبع  $i$  توسط زنبورهای ناظر

با توجه به شایستگی به هر منبع تعدادی زنبور اختصاص داده می شود. در این مرحله ممکن است تمام زنبورهای ناظر به یک سایت غذایی با توجه به شایستگی اختصاص یابد. پس از محاسبه ارزش هر منبع با استفاده از رابطه ۲ جواب جدیدی به ازای جواب های انتخاب شده ایجاد می شود. اگر این جواب دارای ارزش بیشتری نسبت به جواب قبل باشد، این جواب جایگزین جواب قبل می شود و در غیر این صورت به این سایت جریمه تعلق می گیرد. جریمه به این منظور است که شمارنده ای برای

تابع هزینه



شکل ۵- کمیته سازی میزان اضافه حفاری مقطع تونل (مترمکعب)



شکل ۶- تحلیل حساسیت پارامترها

آماري ضريب تعيين ( $R^2$ ) و مجذور میانگین مربعات خطا (RMSE) مدل منتخب به ترتیب برای آموزش و آزمایش برابر با ۰٫۹۲۱، ۰٫۴۰۲۸ و ۰٫۹۲۳ و ۰٫۴۲۷۷ بود. تحلیل حساسیت بر روی داده‌ها نشان داد که RMR بیشترین و تعداد تاخیرات کمترین تاثیر را بر روی اضافه‌حفاری دارد. الگوریتم زنبورعسل که یکی از الگوریتم‌های جدید بهینه‌سازی است برای بهینه‌سازی پارامترهای الگوی انفجار استفاده شد. با توجه به اینکه اضافه‌حفاری از مشکلات اصلی در حفر تونل است، کاهش این مقدار می‌تواند کمک به سزایی برای صرفه‌جویی و ایمنی داشته باشد. پس از ساختن چندین مدل بهینه-سازی و تغییرات وزن‌های آن، مقدار بهینه آن برای اضافه‌حفاری مقطع تونل ۱٫۶۳ مترمربع به دست آمد که نسبت به کمترین مقدار (۳٫۰۵۵ مترمربع) ۴۷ درصد کاهش یافته است. به این ترتیب می‌توان الگوی بهینه با کمترین مقدار اضافه‌حفاری را به دست آورد. این روش بهینه-سازی را می‌توان در کارهای دیگر مهندسی معدن و عمران برای به دست آوردن الگوی‌های اقتصادی و ایمن استفاده کرد.

#### پی‌نوشت‌ها

1. Overbreak
2. Elviar.Hoek
3. Saghatforoush
4. Underbreak
5. Singh
6. Feed-forward
7. Hornik
8. Cosine Amplitude Method (CAM)
9. Back break

#### منابع و مراجع

1. S. Mandal and M. Singh, "Evaluating extent and causes of overbreak in tunnels," *Tunnelling and Underground Space Technology*, vol. 24, pp. 22-36, 2009.
2. M. Monjezi and H. Dehghani, "Evaluation of effect of blasting pattern parameters on back break using neural networks," *International Journal of Rock Mechanics and Mining Sciences*, vol. 45, pp. 1446-1453, 2008.
3. M. Monjezi, S. H. Rizzi, V. J. Majd, and M. Khandelwal, "Artificial neural network as a tool for backbreak prediction," *Geotechnical and Geological Engineering*, vol. 32, pp. 21-30, 2014.
4. H. Jang and E. Topal, "Optimizing overbreak prediction based on geological parameters comparing multiple regression analysis and artificial neural network," *Tunnelling and*

همانطور گفته شد، این جستجو تا یافتن کمینه مقدار اضافه‌حفاری ادامه می‌یابد. چندین مدل از الگوریتم زنبورعسل با تعداد زنبورهای مختلف اجرا شد. در شکل ۵ اجرای الگوریتم برای کمینه‌سازی میزان اضافه‌حفاری نشان داده شده است. پس از اجرای الگوریتم زنبورعسل، پارامترهای بهینه‌شده در جدول ۵ آورده شده است. با توجه به الگوریتم زنبورعسل، پارامتر بهینه‌شده برای اضافه‌حفاری در تونل‌ها که به روش چالزنی و انفجار اجرا می‌شود، ۱٫۶۳ مترمربع به دست آمد. همانطور که در جدول ۲ اشاره شد، کمترین مقدار برای اضافه‌حفاری در حدود ۳٫۰۵۵ مترمربع بوده است که با استفاده از مقدار الگوریتم بهینه-سازی زنبورعسل این مقدار به ۴۷ درصد نسبت به حالت اولیه کاهش یافته است. همچنین مقادیر ۴، ۰٫۹۲۱، ۱٫۷۹۶، ۱٫۶۹۵، ۱٫۲۴۲، ۱٫۲۳۵ و ۱٫۹۲۷ به ترتیب برای تعداد تاخیرها، بارسنگ چال‌های ردیف آخر، بارسنگ چال‌های ردیف آخر، فاصله‌داری چال‌های ردیف ماقبل آخر، فاصله‌داری چال‌های ردیف ماقبل آخر، خرج ویژه و طول پیشروی به دست آمد.

جدول ۵- مقادیر بهینه‌سازی الگوی انفجار

پارامتر	مقادیر بهینه
تعداد تاخیرها	۴
بارسنگ چال‌های ردیف آخر (متر)	۰٫۹۲۱
بارسنگ چال‌های ردیف پیرامون (متر)	۱٫۷۹۶
فاصله‌داری چال‌های ردیف آخر (متر)	۱٫۶۹۵
فاصله‌داری چال‌های ردیف پیرامون (متر)	۱٫۲۴۲
خرج ویژه (کبلوگرم / مترمکعب)	۱٫۲۳۵
طول پیشروی (متر)	۳٫۹۲۷
اضافه‌حفاری مقطع تونل (مترمربع)	۱٫۶۳

#### ۴- نتیجه‌گیری

در این تحقیق با استفاده از روش‌های هوشمند به پیش‌بینی و بهینه‌سازی اضافه‌حفاری پرداخته شد. با توجه به اینکه در ایران، برای حفر تونل‌ها از روش چالزنی و انفجار استفاده می‌شود، شناخت پارامترهای مهم برای پیش‌بینی این موضوع اهمیت زیادی دارد. در اینجا از ۹ پارامتر ورودی برای ایجاد شبکه عصبی با استفاده از الگوریتم یادگیری لونیبرگ-ماکوات استفاده شد. پس از انتخاب بهترین مدل بر اساس امتیازدهی، مدل منتخب برای بهینه‌سازی مورد استفاده قرار گرفت. مقادیر شاخص‌های

14. J. Roth, "A model for the determination of flyrock range as a function of shot conditions. US Bureau of Mines contract J0387242," *Management Science Associates, Los Altos*, 1979.
15. S. P. Singh and P. Xavier, "Causes, impact and control of overbreak in underground excavations," *Tunnelling and Underground Space Technology*, vol. 20, pp. 63-71, 2005.
16. S. Shaorui, L. Jiaming, and W. Jihong, "Predictions of overbreak blocks in tunnels based on the wavelet neural network method and the geological statistics theory," *Mathematical Problems in Engineering*, vol. 2013, 2013.
۱۷. گ. م. سپاسد، «مقاطع حفاری و برداشت شده پس از هر انفجار»، ۱۳۹۱.
18. D. J. Armaghani, M. Hajihassani, M. Monjezi, E. T. Mohamad, A. Marto, and M. R. Moghaddam, "Application of two intelligent systems in predicting environmental impacts of quarry blasting," *Arabian Journal of Geosciences*, vol. 8, pp. 9647-9665, 2015.
19. K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators," *Neural networks*, vol. 2, pp. 359-366, 1989.
20. R. Hecht-Nielsen, "Kolmogorov's mapping neural network existence theorem," in *Proceedings of the International Joint Conference in Neural Networks*, 1989, pp. 11-14.
21. B. D. Ripley, "Statistical aspects of neural networks," *Networks and chaos—statistical and probabilistic aspects*, vol. 50, pp. 40-123, 1993.
22. J. Paola, "Neural network classification of multispectral imagery," *Master Tezi, The University of Arizona, USA*, 1994.
23. C. Wang, "A theory of generalization in learning machines with neural network applications," 1994.
24. T. Masters, *Practical neural network recipes in C++*: Morgan Kaufmann, 1993.
25. Kaastra and M. Boyd, "Designing a neural network for forecasting financial and economic Underground Space Technology ,vol. 38, pp. 161-169, 2013.
5. M. Khandelwal and M. Monjezi, "Prediction of backbreak in open-pit blasting operations using the machine learning method," *Rock mechanics and rock engineering*, vol. 46, pp. 389-396, 2013.
6. M. Monjezi, Z. Ahmadi, A. Y. Varjani, and M. Khandelwal, "Backbreak prediction in the Chadormalu iron mine using artificial neural network," *Neural Computing and Applications*, vol. 23, pp. 1101-1107, 2013.
7. P. H. Oliver, "Changes to drill pattern and adequate inter-row delay time improve blasting performance," *CIM bulletin*, vol. 96, pp. 60-65, 2003.
8. E. Hoek and E. T. Brown, *Underground excavations in rock*, 1980.
9. E. Ebrahimi, M. Monjezi, M. R. Khalesi, and D. J. Armaghani, "Prediction and optimization of back-break and rock fragmentation using an artificial neural network and a bee colony algorithm," *Bulletin of Engineering Geology and the Environment*, vol. 75, pp. 27-36, 2016.
10. Saghatforoush, M. Monjezi, R. S. Faradonbeh, and D. J. Armaghani, "Combination of neural network and ant colony optimization algorithms for prediction and optimization of flyrock and back-break induced by blasting," *Engineering with Computers*, vol. 32, pp. 255-266, 2016.
11. M. Esmaeili, M. Osanloo, F. Rashidinejad, A. A. Bazzazi, and M. Taji, "Multiple regression, ANN and ANFIS models for prediction of backbreak in the open pit blasting," *Engineering with computers*, vol. 30, pp. 549-558, 2014.
12. J. Ibarra, N. Maerz, and J. Franklin, "Overbreak and underbreak in underground openings part 2 :causes and implications," *Geotechnical and Geological Engineering*, vol. 14, pp. 325-340, 1996.
13. N. Lundborg, "The hazards of flyrock in rock blasting," *Swedish Detonic Research Foundation, Reports DS*, vol. 12, 1974.

- Conference on Parallel Problem Solving from Nature*, 2012, pp. 143-152.
35. M. S. de Oliveira, R. Schirru, and J. de Medeiros, "On the performance of an artificial bee colony optimization algorithm applied to the accident diagnosis in a pwr nuclear power plant," in *2009 international nuclear Atlantic conference (INAC 2009)*, 2009.
  36. R. Irani and R. Nasimi, "Application of artificial bee colony-based neural network in bottom hole pressure prediction in underbalanced drilling," *Journal of Petroleum Science and Engineering*, vol. 78, pp. 6-12, 2011.
  37. D. Karaboga and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm," *Journal of global optimization*, vol. 39, pp. 459-471, 2007.
  - time series," *Neurocomputing*, vol. 10, pp. 215-236, 1996.
  26. Kanellopoulos and G. Wilkinson, "Strategies and best practice for neural network image classification," *International Journal of Remote Sensing*, vol. 18, pp. 711-725, 1997.
  27. K. Zorlu, C. Gokceoglu, F. Ocakoglu, H. Nefeslioglu, and S. Acikalin, "Prediction of uniaxial compressive strength of sandstones using petrography-based models," *Engineering Geology*, vol. 96, pp. 141-158, 2008.
  28. Sayadi, M. Monjezi, N. Talebi, and M. Khandelwal, "A comparative study on the application of various artificial neural networks to simultaneous prediction of rock fragmentation and backbreak," *Journal of Rock Mechanics and Geotechnical Engineering*, vol. 5, pp. 318-324, 2013.
  29. M. Rezaei, M. Monjezi, and A. Y. Varjani, "Development of a fuzzy model to predict flyrock in surface mining," *Safety science*, vol. 49, pp. 298-305, 2011.
  30. D. Karaboga, "An idea based on honey bee swarm for numerical optimization," Technical report-tr06, Erciyes university, engineering faculty, computer engineering department 2005.
  31. B. Nozohour-leilabady and B. Fazelabdolabadi, "On the application of artificial bee colony (ABC) algorithm for optimization of well placements in fractured reservoirs; efficiency comparison with the particle swarm optimization (PSO (methodology," *Petroleum*, vol. 2, pp. 79-89, 2016.
  32. Ahmad, S. F. M. Razali, Z. S. Mohamed, and A. El-shafie, "The Application of Artificial Bee Colony and Gravitational Search Algorithm in Reservoir Optimization," *Water Resources Management*, vol. 30, pp. 2497-2516, 2016.
  33. Zhang, D. Ouyang, and J. Ning, "An artificial bee colony approach for clustering," *Expert Systems with Applications*, vol. 37, pp. 4761-4767, 2010.
  34. F. J. Rodriguez, C. García-Martínez, C. Blum, and M. Lozano, "An artificial bee colony algorithm for the unrelated parallel machines scheduling problem," in *International*