

پیش بینی نرخ نفوذ ماشین TBM در حفر فضاهای زیرزمینی با استفاده از الگوریتم های ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری-مطالعه موردی

هادی فتاحی^۱، محمدعلی شیرین زاده^۲

پذیرش مقاله: ۱۴۰۱/۰۶/۰۹

دریافت مقاله: ۱۴۰۰/۱۰/۰۹

چکیده

بعلت تخمین دقیق زمان حفاری و برآورد هزینه های اجرایی، پیش بینی نرخ نفوذ در حفاری مکانیزه حائز اهمیت است. از طرفی به دلیل قیمت بالای ماشین حفاری تمام مقطع (TBM)، ارزیابی عملکرد در حفاری با استفاده از این ماشین بسیار اهمیت دارد. یکی از شاخص های ارزیابی عملکرد ماشین TBM، پیش بینی نرخ نفوذ این دستگاه می باشد. طی سالیان اخیر توسط محققین روش ها و روابط متنوعی برای پیش بینی نرخ نفوذ پیشنهاد شده که هر کدام براساس پارامترهای مربوط به توده سنگ و مشخصات ماشین ارائه شده اند. هدف از نگارش این مقاله توسعه مدل های دقیق پیش بینی برای تخمین نرخ نفوذ TBM با استفاده از الگوریتم های فراابتکاری هوشمند نظیر الگوریتم ژنتیک، الگوریتم سیستم ایمنی مصنوعی، الگوریتم پژواک صدای دلفین و الگوریتم گرگ خاکستری است. برای ساخت مدل های پیش بینی از ۱۵۳ داده که شامل: مقاومت فشاری تک محوره سنگ بکر (UCS)، تردی سنگ بکر (BI)، زاویه بین صفحات ناپیوستگی و جهت حفاری TBM (α) و فاصله بین صفحات ناپیوستگی (DPW) به عنوان پارامترهای ورودی استفاده شده است. همچنین برای ارزیابی مدل ها از شاخص های آماری نظیر میانگین خطای مربعات (MSE) و ضریب همبستگی مربع (R^2) استفاده شده است. نتایج مدلسازی ها نشان می دهد الگوریتم ژنتیک با مقادیر $MSE_{Train}=0/012$ ، $MSE_{Test}=0/02$ ، $R^2_{Train}=0/9319$ و $R^2_{Test}=0/8473$ از دقت قابل قبولی در پیش بینی نرخ نفوذ TBM (نسبت به سایر الگوریتم ها) برخوردار است.

کلیدواژه ها: نرخ نفوذ TBM، الگوریتم ژنتیک، الگوریتم سیستم ایمنی مصنوعی، الگوریتم پژواک صدای دلفین، الگوریتم گرگ خاکستری

^۱ عضو هیات علمی دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک h.fattahi@arakut.ac.ir

^۲ دانشجوی دانشکده مهندسی علوم زمین، دانشگاه صنعتی اراک

* مسئول مکاتبات

۱. مقدمه

از دهه ۱۹۵۰، بعد از ساخت موفق اولین TBM و ورود این ماشین به صنعت تونل‌سازی، بسیاری از محققین و پژوهشگران برای ارزیابی عملکرد حفاری این ماشین، توسعه مدل‌ها و روابط متنوع را به‌عنوان هدف نهایی خود مدنظر قرار داده‌اند. به همین منظور مدل‌های زیادی برای پیش‌بینی عملکرد این ماشین‌ها براساس تحقیقات تجربی و نظری مطرح شده که بخش زیادی از این مدل‌ها به‌منظور تخمین نرخ نفوذ ماشین بر مبنای اندرکنش بین خواص توده‌سنگ و ویژگی‌های ماشین حفاری بوده است (Mansouri and Yagiz et al. 2009; Moomiv 2010). مدل‌های پیش‌بینی به دو گروه تجربی و نظری تقسیم می‌شوند که مدل‌های نظری فرآیند اثر نیروی برش توسط تیغه‌ها بر روی توده سنگ را در مقیاس آزمایشگاهی آنالیز می‌کنند تا روابط تعادلی بین نیروها را پیدا کنند. در مدل‌های تجربی از پارامترهای توده‌سنگ و پارامترهای عملیاتی به همراه طراحی ماشین برای تخمین عملکرد ماشین حفاری تمام مقطع، در شرایط زمین‌شناسی متفاوت استفاده شده است. در کل، برای ساخت یک مدل واقع‌گرایانه برای ارزیابی عملکرد ماشین، می‌بایست آزمایش‌های آزمایشگاهی، زمین‌شناسی منطقه و شرایط ساخت با هم ترکیب شوند.

در سال‌های اخیر تلاش‌های زیادی برای ساخت یک مدل عمومی که تمامی پارامترهای مؤثر بر نرخ نفوذ ماشین را در نظر بگیرد، صورت گرفته است. اما ساخت چنین مدلی، کاری بسیار دشوار و تا حدی غیرممکن بوده است. بنابراین تمامی مدل‌های پیش‌بینی عملکرد ماشین (مدل‌های نظری و تجربی) در عمل با خطاهایی همراه هستند. از میان همه مدل‌های پیش‌بینی، مدل نروژی (NTH)، مدل تجربی QTBM و مدل نظری مدرسه معدن کلرادو (CSM) مقبولیت بیشتری دارند (Bieniawski et al. 2008). از طرفی محققان متعددی روی اثر خصوصیات سنگ بکر و توده سنگ برای تخمین نرخ نفوذ TBM، مطالعاتی داشته‌اند. تحقیقات صورت گرفته در سه دهه اخیر نشان می‌دهد که برقراری ارتباط بین عملکرد TBM و

خواص توده سنگ از نظر فنی بسیار مشکل و پیچیده است. مرور پژوهش‌ها و روابط ذکر شده مشخص می‌کند این روابط راه‌حلی واحد و مناسبی را برای پیش‌بینی نرخ نفوذ و ضریب بهره‌وری TBM در پروژه‌های واقعی ارائه نمی‌دهند. در روابط اولیه براساس یک یا دو پارامتر نرخ نفوذ ماشین حفاری تخمین زده می‌شد، اما رفته‌رفته این روند تکمیل شده و در روابط بعدی از طبقه‌بندی مهندسی سنگ‌ها مانند RMR، GSI و Q استفاده شد. در ادامه به تعدادی از نتایج این مطالعات پرداخته می‌شود:

در رابطه ارائه‌شده توسط تارکوی (Tarkoy) با استفاده از سختی کل (H_T)، سختی سایشی (H_A) و سختی چکش اسمیت (H_R)، نرخ نفوذ (PR) برحسب میلی‌متر به ازای هر دور چرخش کله حفار به‌صورت زیر بدست آمده است:

$$PR = 3.716 - 0.019H_T \quad (1)$$

$$H_T = H_R' (H_A)^{0.5}$$

در رابطه‌ای دیگر توسط فارمر و گلوسوپ (Farmer and Glossop 1980)، نرخ نفوذ برحسب میلی‌متر به ازای هر دور چرخش کله حفار براساس نیروی نفوذ هر دیسک (F_n) و مقاومت کششی برزیلی (s_{tb}) به‌صورت زیر بدست آمده است:

$$PR = 624 \frac{F_n}{s_{tb}} \quad (2)$$

در رابطه ارائه‌شده دیگری توسط کاسینلی و همکاران (Cassinelli 1982)، نرخ نفوذ برحسب متر بر ساعت با استفاده از معیار رده‌بندی ساختاری سنگ (RSR) به‌صورت زیر بدست آمده است:

$$PR = -0.0059RSR + 1.59 \quad (3)$$

در رابطه ارائه‌شده دیگری توسط بامفورد (Nichols and Bamford 1985)، نرخ نفوذ برحسب متر بر ساعت با استفاده از نیروی محوری ماشین (T)، شاخص نفوذ (N) و زاویه اصطکاک داخلی (j) به‌صورت زیر بدست آمده است:

$$PR = 0.5355 - 8.49 - 0.00344T - \dots - 0.000823N + 0.0137j \quad (4)$$

$$FPI = 4.161 + 0.091s_c + \dots \quad (10)$$

$$+ 0.077RQD + 0.117 + J_c + 1.077 \log a$$

$$FPI = 9.401 + 0.397 \log a + 0.011J_c^2 + \dots \quad (11)$$

$$+ \frac{\pi}{6} 1.14 \cdot 10^{-5} RQD^3 + \frac{\pi}{6} \frac{1}{14} \cdot 10^{-5} \frac{\sigma_c}{\sigma} \frac{4 \frac{\sigma}{\sigma}}{\frac{\sigma}{\sigma}}$$

با توجه به مطالب بالا، پیش‌بینی نرخ نفوذ یک مسئله پیچیده غیرخطی و چند متغیره است که به بسیاری از متغیرها بستگی دارد. در این مدل‌ها استفاده از روش‌های رگرسیونی به دلیل دقت پایین اعتبار چندانی ندارند. اما هدف اصلی این مقاله این است که بتوان با توجه به پارامترهای ورودی و با استفاده از روش‌های قدرتمند الگوریتم‌های فراابتکاری یک رابطه کلی به دست آورد که جامعیت لازم را داشته باشد. در الگوریتم‌های فراابتکاری در هر مرحله تکرار، داده‌ها مرتب شده و داده‌های پرت از مدل حذف می‌شوند و تنها داده‌هایی که به واقعیت نزدیک‌تر هستند در مدل‌سازی باقی می‌مانند. اما در روش‌های رگرسیونی تنها یک مرحله تکرار دارند و در این حالت داده‌های پرت درون مدل‌سازی باقی مانده و سبب می‌شوند که مدل‌سازی مسئله از واقعیت دور شود. بنابراین، حل آن با یک روش ساده رگرسیون خطی آسان و میسر نیست. همچنین اگرچه تلاش‌های قبلی ارزشمند هستند اما بدلیل ساختارهای پیچیده در مهندسی سنگ و وجود عدم قطعیت که در ذات سنگ است، استفاده از این روابط در مناطق دیگر جهان با خطا همراه بوده است. لذا امروزه با وجود پیشرفت در علم داده‌کاوی در جهت کاهش خطای محاسباتی و همچنین مدل‌سازی رفتار غیرخطی داده‌ها، از روش‌های توسعه یافته هوش محاسباتی استفاده می‌شود. این روش‌ها ابزاری سریع، ارزان و با قابلیت بالا برای حل مسائل مهندسی هستند. لذا طی سالیان گذشته برای تخمین عملکرد TBM تکنیک‌های مختلف هوشمند مانند مدل‌های شبکه عصبی مصنوعی، بردار پشتیبان رگرسیونی و منطق فازی مورد استفاده قرار گرفته است (Gao et Armaghani et al. 2017; Minh; Mahdevari et al. 2014; Liu et al. 2020a, 2021; Yagiz and Karahan 2015; Wei et al. 2021 et al. 2017; Zhou et al. 2021; Zhou et al. 2019 Yin et al. 2014

در رابطه ارائه‌شده دیگری توسط لیزلرود و همکاران (Lislerud 1988)، نرخ نفوذ برحسب متر بر ساعت با استفاده از ضریب اصلاح کلاس درزه‌ها (K_s)، ضریب اصلاح قطر دیسک (K_d) و نرخ نفوذ پایه‌شده (ib) به صورت زیر بدست آمده است:

$$PR = ib + K_s + K_d \quad (5)$$

در رابطه ارائه‌شده دیگری توسط ایناراتو (Innaurato et al. 1991)، نرخ نفوذ برحسب متر بر ساعت با استفاده از مقاومت تک‌محوری ماده سنگ (s_c) و معیار رده‌بندی ساختاری سنگ (RSR) به صورت زیر بدست آمده است:

$$PR = s_c^{-0.437} - 0.047RSR + 3.15 \quad (6)$$

در رابطه ارائه‌شده دیگری توسط بارتن (Barton 1999)، نرخ نفوذ برحسب متر بر ساعت با استفاده از معیار کیو (Q) به صورت زیر بدست آمده است:

$$PR = 5 Q_{TBM}^{-0.2} \quad (7)$$

در رابطه ارائه‌شده دیگری توسط بیناوسکی و همکاران (Bieniawski and Grandori 2007)، متوسط نرخ پیشروی (ARA) برحسب متر بر ساعت با استفاده از اندیس قابلیت حفاری توده‌سنگ (ME) به صورت زیر بدست آمده است:

$$ARA = 0.422ME - 11.61 \quad (8)$$


در رابطه ارائه‌شده دیگری توسط حسن‌پور و همکاران (Hassanpour et al. 2010)، اندیس نفوذ میدانی (FPI) با استفاده از رده‌بندی توده‌سنگ پایه ($BRMR$) (بدون در نظر گرفتن جهت‌یافتگی ناپیوستگی) و معیار کیو (Q) به صورت زیر بدست آمده است:

$$FPI = 0.222BRMR + 2.755, \quad (9)$$

$$FPI = 11.718Q^{0.098}$$

در رابطه ارائه‌شده دیگری توسط خادمی حمیدی و همکاران (Hamidi et al. 2010)، اندیس نفوذ میدانی (FPI) با استفاده از مقاومت تک‌محوری ماده سنگ (s_c)، شاخص کیفی سنگ (RQD)، زاویه بین محور تونل با صفحات ناپیوستگی (a) و عامل شرایط سطح درزه (J_c) به صورت زیر بدست آمده است:

زمین‌شناسی منطقه مورد مطالعه شامل گنیس گرانیتی عیار بالا، آمفیبولیت، ارتوگنیس، گنیس / شیسست و دایک‌های ریوداسیت است (Yagiz and Karahan 2011). نوع سنگ‌های حفاری شده در امتداد تونل به صورت درصدی در شکل ۱ طبقه‌بندی شده است.



شکل ۱- درصد متفاوت انواع سنگ‌های حفاری شده در امتداد تونل

Different percentages of types of rocks excavated along the tunnel

در این پایگاه داده، آزمایشات سنگ بکر شامل مقاومت فشاری تک محوری (UCS) و مقاومت کششی برزیلی (BTS) مطابق با استاندارد ASTM (انجمن آمریکایی آزمایش مواد) انجام شده است. همچنین مقادیر شکنندگی سنگ بکر (BI) با استفاده از آزمون نفوذ پنج با بررسی میزان شکنندگی و سختی سنگ در آزمایشگاه و در مطالعه میدانی، زاویه آلفا (a) (زاویه بین صفحات ناپیوستگی و جهت حرکت TBM)، فاصله بین صفحات ناپیوستگی (DPW) و نرخ نفوذ بدست آمده است. آمار توصیفی برای پارامترهای ورودی در توسعه مدل‌ها در جدول ۱ ذکر شده است.

جدول ۱- آمار توصیفی پارامترهای ورودی و خروجی

Parameter	Min.	Max.	Average	Std. deviation
UCS (MPa)	118.3	199.7	150.1	22.2
BI (kN/mm)	25	58	34.64	8.5
DPW (m)	0.05	2	1.02	0.64
a ($^{\circ}$)	2	89	44.7	23.3
Penetration rate (m/h)	1.27	3.07	2.05	0.36

در این قسمت بطور خلاصه چهار الگوریتم بکار گرفته شده در مدلسازی تخمین نرخ نفوذ TBM توضیح داده می‌شود.

در این مقاله، در ادامه استفاده از روش‌های هوشمند در حفاری مکانیزه، از الگوریتم‌های فراابتکاری جدید و متنوعی نظیر الگوریتم سیستم ایمنی مصنوعی، الگوریتم پژواک صدای دلفین، الگوریتم گرگ خاکستری و الگوریتم ژنتیک برای پیش‌بینی غیرمستقیم نرخ نفوذ TBM، پیشنهاد شده است که در ادامه پس از تجزیه و تحلیل خطاهای آماری بر روی نتایج مدل‌سازی، اثربخشی روش‌های پیشنهادی مورد بررسی قرار می‌گیرد.


۲- منطقه مورد بررسی و ساختار داده‌ها

در این مطالعه، از پایگاه داده (Yagiz 2008) مربوط به فاز دوم تونل کوئینز شماره ۳ در شهر نیویورک (Yagiz 2008) ; (and Karahan 2011) برای توسعه مدل‌ها در تخمین نرخ نفوذ TBM مورد استفاده قرار گرفته است. TBM نصب‌شده در این تونل مجهز به دیسک کاترهای ۴۸/۲ سانتی متری و ظرفیت بار تخمینی ۳۰ تنی به ازای هر کاتر برای حفاری در تونلی به طول ۷/۵ کیلومتر به قطر ۷/۰۶ متر و عمق تقریبی ۲۰۰ متری در جنوب غربی کوئینز در شهر نیویورک، ایالات متحده آمریکا می‌باشد (Yagiz and Karahan 2011). این تونل بین سال‌های ۱۹۹۷ و ۲۰۰۰ برای بهسازی توزیع آب شیرین در سطح شهر ساخته شده است. این تونل یکی از پیچیده‌ترین پروژه‌های مهندسی در جهان به دلیل نوع شرایط زمین‌شناسی موجود در محیط به‌شمار می‌رود. منطقه ساخت و ساز در امتداد تونل با شرایط زمین‌شناسی موجود، از جمله لیتولوژی غیرمنتظره و جهت‌گیری توده سنگ، دایک‌های متقاطع و گسیختگی‌های شکننده مسدود شده است. پیچیدگی

۳- روش تحقیق

(۲) تعقیب، احاطه‌کردن و خسته‌کردن طعمه تا زمانی که متوقف شود.

(۳) حمله به سوی طعمه.



شکل ۲- سلسله مراتب اجتماعی گرگ‌ها (Mirjalili et al. 2014)

۱-۱-۳- مدل ریاضی الگوریتم

در این بخش مدل‌های ریاضی رفتار سلسله مراتبی، مسیریابی، احاطه و حمله به طعمه آمده است (Mirjalili et al. 2014).

سلسله مراتب اجتماعی: برای اینکه به‌طور ریاضی سلسله مراتب اجتماعی گرگ‌ها مدل شود، زمانی که الگوریتم مدل می‌شود، بهترین حل به‌عنوان گرگ آلفا در نظر گرفته می‌شود. متعاقباً حل‌های دوم و سوم به‌عنوان بتا و دلتا در نظر گرفته شده و بقیه نماینده جواب‌ها به‌عنوان امگا شناخته می‌شوند. در الگوریتم بهینه‌یابی گرگ خاکستری، شکار (بهینه‌یابی) توسط گرگ‌های آلفا، بتا و دلتا هدایت می‌شود. گرگ‌های امگا از این سه گرگ تبعیت می‌کنند (Mirjalili et al. 2014).

احاطه کردن شکار: گرگ‌های خاکستری طعمه را حین شکار احاطه می‌کنند. برای مدل‌سازی رفتار احاطه کردن گرگ‌های خاکستری روابط زیر پیشنهاد می‌شود (Mirjalili et al. 2014):

$$D = \left| \vec{C} \cdot \vec{X}_p(t) - \vec{X}(t) \right| \quad (12)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (13)$$

که در آن، t تکرار فعلی، \vec{A} و \vec{C} بردار ضرایب، \vec{X}_p بردار موقعیت طعمه، \vec{X} بردار موقعیت یک گرگ خاکستری می‌باشد. بردارهای \vec{A} و \vec{C} مطابق روابط زیر محاسبه می‌شوند (Mirjalili et al. 2014):

۳-۱- الگوریتم گرگ خاکستری^۳

یکی از روش‌های جدیدی که در زمینه بهینه‌یابی مسائل پیچیده مهندسی توسط میرجلیلی و همکاران در سال ۲۰۱۳ ارائه شده است، الگوریتم بهینه‌یابی گرگ خاکستری (GWO) می‌باشد (Mirjalili et al. 2014). الگوریتم بهینه‌یابی گرگ خاکستری، از سلسله مراتب رهبری و مکانیزم شکار طبیعی گرگ‌ها تبعیت می‌کند. در این روش، چهار مدل گرگ خاکستری آلفا، بتا، دلتا و امگا برای شبیه‌سازی سلسله مراتب رهبری مورد استفاده قرار گرفته است. همانگونه که در شکل (۲) (Mirjalili et al. 2014) نشان داده شده است رهبران گروه از جنس یک نر و یک ماده بوده و به‌عنوان آلفا شناخته می‌شوند. آلفا عمدتاً پاسخ‌گو برای تصمیم‌گیری و هر چیز دیگری هستند. تصمیمات آلفاها به گروه تحمیل می‌شود. دومین سطح از سلسله مراتب گرگ‌های خاکستری بتا است. بتاها زیر مجموعه‌ای از گرگ‌ها هستند که در تصمیم‌گیری‌های گرگ‌های آلفا و یا سایر فعالیت‌های گروه کمک می‌کنند. گرگ بتا بایستی به گرگ آلفا احترام بگذارد، اما به سایر گرگ‌های گروه می‌تواند دستور بدهد. پایین‌ترین سطح گرگ‌های خاکستری امگا است. امگا نقش قربانی را بازی می‌کند. گرگ‌های امگا همواره مجبورند تا به همه گرگ‌های غالب سر فرود آورند. آنها آخرین گرگ‌هایی هستند که مجازند تا تغذیه کنند. اگر یک گرگ آلفا، بتا یا امگا نباشد، زیرمجموعه دلتا نامیده می‌شود. گرگ‌های دلتا مجبور هستند تا گرگ‌های آلفا و بتا را اطاعت کنند، اما از گرگ‌های امگا غالب‌ترند.

علاوه بر سلسله مراتب اجتماعی گرگ‌ها، شکار گروهی یکی دیگر از رفتار اجتماعی غالب گرگ‌های خاکستری می‌باشد. بر طبق گفته میرجلیلی و همکاران، مراحل اصلی شکار گرگ‌های خاکستری به صورت زیر است (Mirjalili et al. 2014):

(۱) مسیریابی، تعقیب و نزدیکی به طعمه.

نزدیک شدن به طعمه مدل می‌شود و مقدار \vec{a} کاهش می‌یابد. توجه شود که محدوده نوسان بردار \vec{A} نیز برحسب \vec{a} کاهش می‌یابد. به عبارت دیگر \vec{A} یک مقدار تصادفی است در بازه $[2a, -2a]$ که در آن، a از دو تا صفر با بالا رفتن تعداد تکرار کاهش می‌یابد. زمانی که مقادیر تصادفی \vec{A} در بازه $[-1, 1]$ هستند، موقعیت بعدی یک عامل جستجو می‌تواند در هر موقعیتی بین موقعیت کنونی و موقعیت طعمه باشد. با عملگرهای پیشنهاد شده تاکنون، الگوریتم گرگ خاکستری به عوامل جستجوگر خود اجازه می‌دهد تا موقعیت‌های خود را براساس محل آلفا، بتا و دلتا بروز رسانی کرده و به سوی طعمه حمله کنند (Mirjalili et al. 2014).

جستجو برای طعمه (بهره‌برداری): گرگ‌های خاکستری عمدتاً جستجو را براساس موقعیت آلفا، بتا و دلتا انجام می‌دهند. آنها از یکدیگر برای جستجوی طعمه واگرا می‌شوند و برای حمله به طعمه همگرا می‌شوند. به منظور مدل‌سازی ریاضی واگرایی، مقدار \vec{A} را بزرگتر از ۱ و یا کوچکتر از -۱ در نظر گرفته می‌شود این امر باعث می‌شود تا گرگ‌ها به صورت سراسری برای طعمه (راه‌حل) جستجو کنند (Mirjalili et al. 2014). دیگر مؤلفه الگوریتم گرگ خاکستری که فاز جستجو را حمایت می‌کند، بردار \vec{C} می‌باشد. مقدار این بردار یک عدد تصادفی بین $[0, 2]$ است. این پارامتر باعث می‌شود تا گرگ‌ها رفتارهای تصادفی داشته باشند و در سرتاسر فضای جستجو به دنبال طعمه (راه‌حل) باشند. در شکل (۳) فلوچارت الگوریتم گرگ خاکستری نشان داده شده است. همچنین در شکل (۴) شبه کد الگوریتم گرگ خاکستری نشان داده شده است.

۳-۲- الگوریتم پژواک صدای دلفین^۴

این الگوریتم در سال ۲۰۱۱ توسط کاوه و همکاران ارائه شده است (Kaveh and Farhoudi 2013). موقعیت‌یابی صوتی دلفین‌ها یک رادار بیولوژیکی می‌باشد که دلفین‌ها از آن برای شکار در طبیعت استفاده می‌کنند. الگوریتم بهینه‌سازی دلفین با الهام از این رفتار دلفین‌ها اقدام به جستجو در فضای مسئله می‌کند. الگوریتم دلفین به علت نحوه فرمول‌بندی خود و

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (14)$$

$$\vec{C} = 2\vec{r}_2 \quad (15)$$

که در آن، مقدار \vec{a} به صورت خطی با بالا رفتن تعداد تکرار از دو تا صفر کاهش می‌یابد و \vec{r}_1 و \vec{r}_2 بردارهای تصادفی در $[0, 1]$ می‌باشند.

شکار: گرگ‌های خاکستری این توانایی را دارند تا محل یک طعمه را تشخیص دهند و آنها را احاطه کنند. شکار معمولاً توسط گرگ آلفا هدایت می‌شود. گرگ‌های بتا و دلتا ممکن است در شکار، در بعضی مواقع مشارکت داشته باشند. با این حال در یک فضای جستجوی محدود هیچ ایده‌ای درباره محل بهینه (طعمه) نیست. به جهت شبیه‌سازی ریاضی رفتار شکار گرگ‌های خاکستری، فرض می‌شود که آلفا (بهترین جواب)، بتا و دلتا اطلاع خوبی درباره پتانسیل محل طعمه دارند. بنابراین سه جواب بهتر بدست آمده تاکنون را ذخیره کرده و بقیه عوامل جستجو مجبور می‌شوند تا موقعیت‌های خود را براساس موقعیت عوامل بهتر بروز رسانی کنند. بدین منظور روابط زیر پیشنهاد شده است (Mirjalili et al. 2014):

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \quad (16)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}|$$

$$\vec{X}_1 = \vec{X}_\alpha - A_1 \cdot (\vec{D}_\alpha),$$

$$\vec{X}_2 = \vec{X}_\beta - A_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - A_3 \cdot (\vec{D}_\delta) \quad (17)$$

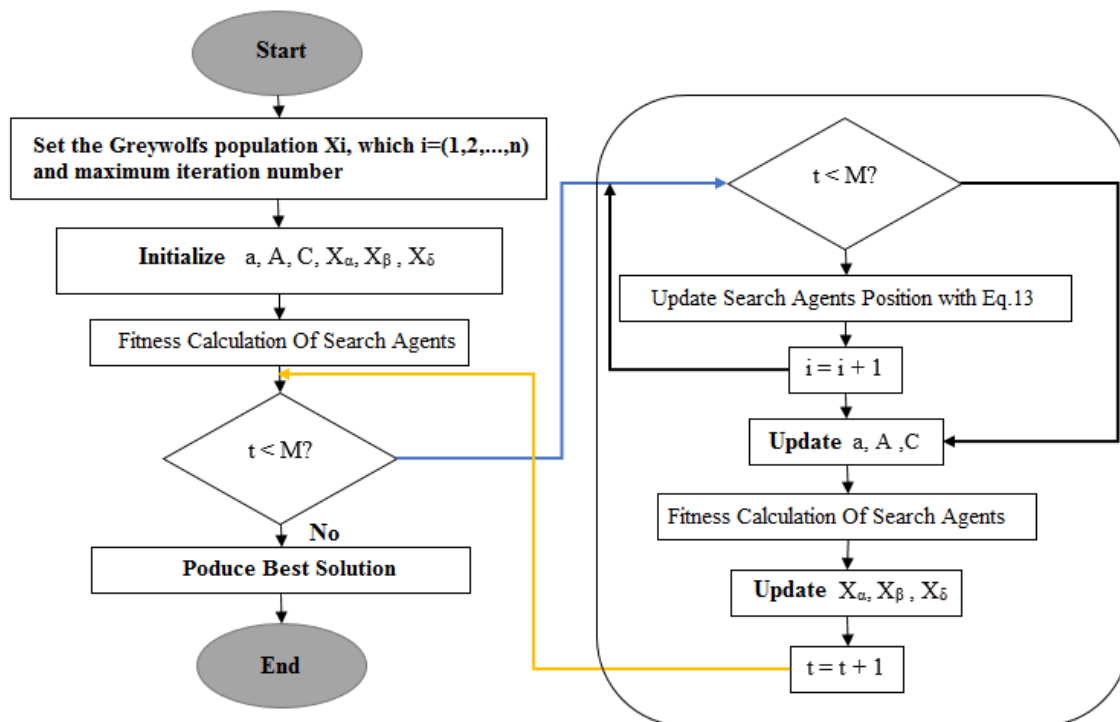
$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (18)$$

حمله کردن به طعمه: همانطور که در بالا اشاره شد گرگ‌های خاکستری شکار را با حمله به طعمه، زمانی که از حرکت باز می‌ایستد، خاتمه می‌دهند. به منظور این که به طور ریاضی وار

تصادفی به انجام می‌رسد. در مرحله دوم، الگوریتم دامنه جستجو را به طرف جواب‌های مناسب به دست آمده از مرحله قبل متمرکز می‌کند که این دو مرحله مشخصه ذاتی هر الگوریتم فراابتکاری می‌باشد. با استفاده از الگوریتم دلفین کاربر قادر به تغییر نسبت جواب‌های به دست آمده از دو مرحله، به وسیله منحنی از پیش تعیین شده می‌باشد. با استفاده از این منحنی معیار همگرایی مورد نظر به الگوریتم دیکته شده و بنابراین همگرایی الگوریتم با تعداد کم پارامتر میسر می‌شود (Kaveh and Farhoudi 2013).

همچنین تعداد کم پارامتر دارای مزیت‌های زیادی نسبت به سایر الگوریتم‌ها می‌باشد.

دلفین در ابتدا تمام فضای اطراف خود را برای یافتن شکار جستجو می‌کند و به محض یافتن آن، دامنه جستجو را به طرف هدف محدود کرده و همچنین ارسال صوت را به طرف آن متمرکز می‌کند. الگوریتم دلفین با شبیه‌سازی این رفتار، نسبت جستجوی خود در فضای طراحی را با توجه به فاصله از هدف مورد نظر تنظیم می‌کند. برای روشن شدن منظور می‌توان یک الگوریتم بهینه‌سازی را مورد توجه قرار داد که در آن دو مرحله مشخص وجود دارد. در مرحله اول الگوریتم تمام فضای طراحی را به صورت کلی مورد جستجو قرار می‌دهد. این عمل با تولید موقعیت‌های متعدد به صورت



شکل ۳- فلوچارت الگوریتم گرگ خاکستری

که در آن، PP احتمال از پیش تعیین شده، PP_1 ضریب همگرایی در تکرار اول، $Loop_i$ شماره حلقه و Power تعیین کننده درجه منحنی می باشد. همچنین LoopsNumber بیان کننده تعداد تکرار یا حلقه لازمه برای همگرا شدن الگوریتم می باشد که با توجه به تلاش محاسباتی لازمه الگوریتم برای رسیدن به جواب تعیین می شود. مراحل اصلی الگوریتم پژواک صدای دلفین برای بهینه سازی به صورت زیر می باشد (Kaveh and Farhoudi 2013):

(۱) اختصاص تصادفی NL موقعیت به دلفین ها: این مرحله شامل ساخت ماتریس $L_{NV} \times NV$ می باشد که NL تعداد مکان ها و NV تعداد متغیرهای مسئله را نشان می دهد.

(۲) محاسبه مقدار PP با استفاده از رابطه زیر (Kaveh and Farhoudi 2013):

$$PP(Loop_i) = PP_1 + (1 - PP_1) \frac{Loop_i^{Power - 1}}{(LoopsNumber)^{power - 1}} \quad (20)$$

(۳) ارزیابی شایستگی هر مکان (دلفین): شایستگی باید به شیوه ای تعریف شود که پاسخ های بهتر مقادیر بالاتری داشته باشند.

محاسبه شایستگی تجمعی بر اساس قواعد دلفین به شرح زیر (Kaveh and Farhoudi 2013):

```

for i = 1: to the number of locations
  for j = 1: to the number of variables
    find the position of L(i,j) in jth column of the
    Alternatives matrix and name it as A.
    for k = -Re to Re
       $AF(A+K)_j = 1/Re \times (Re - |k|) Fitness(i) + AF(A+K)_j$ 
    end
  end
end

```

که در آن، $AF(A+K)_j$ شایستگی تجمعی $(A+K)$ امین عضو ماتریس فضای طراحی می باشد که برای متغیر z ام انتخاب شده است. Re مقدار شعاع تاثیری است که شایستگی تجمعی مربوط به یک موقعیت، فضای اطراف را تحت تاثیر

```

Initialize the grey wolf population  $X_i (i = 1, 2, \dots, n)$ 
Initialize a, A, and C
Calculate the fitness of each search agent
 $X_\alpha$  = the best search agent
 $X_\beta$  = the second best search agent
 $X_\delta$  = the third best search agent
while (t < Max number of iterations)
  for each search agent
    Update the position of the current search agent
  end for
  Update a, A, and C
  Calculate the fitness of all search agents
  Update  $X_\alpha$ ,  $X_\beta$ , and  $X_\delta$ 
  t = t + 1
end while
return  $X_\alpha$ 

```

شکل ۴- شبه کد الگوریتم گرگ خاکستری

۳-۲-۱- فرمول بندی الگوریتم دلفین

برای هر یک از متغیرهای طراحی، بردار فضای طراحی به صورت افزایشی یا کاهش طبقه بندی می شود. اگر این بردار بیش از یک مشخصه داشته باشد طبقه بندی با توجه به مهم ترین عامل انجام می شود. با این روش برای متغیر z بردار فضای طراحی A_j به طول LA_j ساخته می شود که شامل تمامی گزینه های ممکن برای استفاده در متغیر طراحی است. با ادامه این کار برای تمامی مراحل طراحی، ماتریس $MA \times NV$ Alternative تشکیل می شود که نشان دهند $\max(LA_j)_{j=1:NV}$ با NV تعداد طراحی می باشد (Kaveh and Farhoudi 2013).

بعد از تعریف فضای طراحی برای هر یک از متغیرهای طراحی در ابتدای فرآیند الگوریتم، نکته مهم دیگر در آغاز عملیات تعیین منحنی همگرایی می باشد. همانگونه که قبلا ذکر شد با استفاده از این منحنی نسبت جواب های به دست آمده در دو مرحله الگوریتم قابل کنترل می باشد. برای تعریف این منحنی ها می توان از فرمول زیر استفاده نمود (Kaveh and Farhoudi 2013):

$$PP(Loop_i) = PP_1 + (1 - PP_1) \frac{Loop_i^{Power - 1}}{(LoopsNumber)^{power - 1}} \quad (19)$$

متغیرهای بهترین پاسخ را یافته و AF آنها را برابر با صفر فرض کنید (Kaveh and Farhoudi 2013).

(۵) برای متغیر j که در آن $(j = 1 \text{ to } NV)$ است احتمال انتخاب جایگزین i که $(i = 1 \text{ to } AL_j)$ طبق رابطه زیر محاسبه می‌شود (Kaveh and Farhoudi 2013):

$$P_{ij} = \frac{AF_{ij}}{\sum_{i=1}^{LA_j} AF_{ij}} \quad (21)$$

(۶) احتمال مساوی با PP را به کلیه جایگزین‌های انتخاب شده برای همه متغیرهای بهترین موقعیت تخصیص داده و مابقی احتمال را طبق فرمول زیر به جایگزین‌های دیگر اختصاص داده می‌شود (Kaveh and Farhoudi 2013).

```

for i = 1: to the number of alternatives
  for j = 1: to the number of variables
    if i = The Best Location (j)
      Pij = PP
    else
      Pij = (1 - PP) Pij
    end
  end
end
end

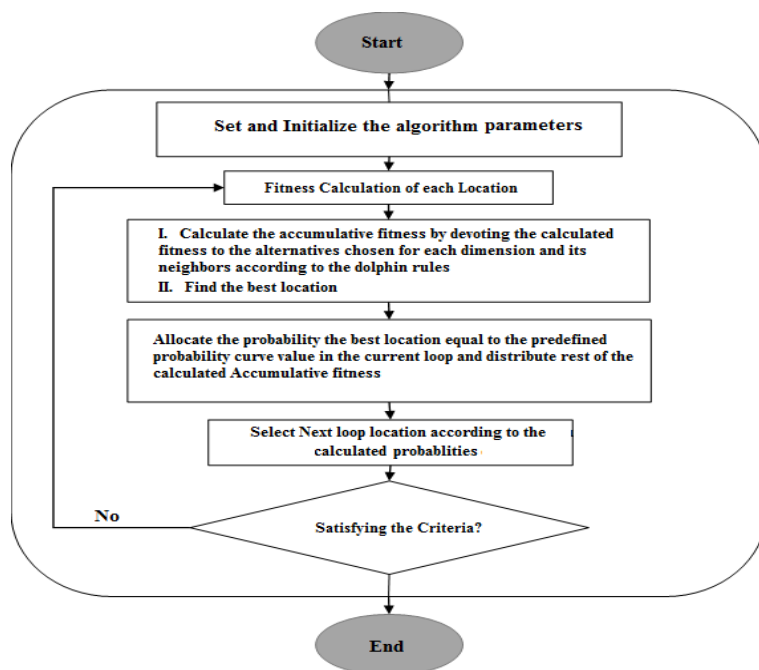
```

مکان‌های مرحله بعدی طبق احتمال تخصیص داده شده به هر جایگزین محاسبه می‌شود. مراحل ۲ تا ۶ را به اندازه تعداد دفعات تکرار الگوریتم تکرار می‌شود. در شکل (۵) فلوجارت الگوریتم نشان داده شده است.

قرار می‌دهد و همچنین Fitness(i) برابر مقدار شایستگی مربوط به موقعیت i می‌باشد.

برای توزیع هموارتر احتمالات در فضای طراحی یک مقدار کوچک ε به تمامی احتمالات محاسبه شده در گام قبلی به فضای طراحی افزوده می‌شود. مقدار این ε در الگوریتم استاندارد دلفین بستگی به نحوه محاسبه شایستگی دارد و در آن این مقدار، کمتر از حداقل مقدار شایستگی محاسبه شده در اجتماع، انتخاب می‌شود. با توجه به اینکه الگوریتم برای محاسبه موقعیت‌های گام بعدی از توزیع احتمالات به دست آمده در گام قبلی استفاده می‌کند، انتخاب مقدار ε نحوه جستجو در فضای طراحی را به شدت تحت تاثیر قرار می‌دهد. بنابراین جهت همگرایی الگوریتم به طرف جواب بهینه کلی انتخاب این عدد پراهمیت می‌باشد. در الگوریتم استاندارد دلفین با توجه به نحوه محاسبه AF که حداکثر مقدار آن برابر مقدار fitness در موقعیت مربوطه می‌باشد اضافه نمودن ε به AF باعث تحت تاثیر قرار گرفتن همگرایی الگوریتم می‌شود. اما در مطالعه حاضر و با توجه به فرمول ارائه شده برای محاسبه AF که حداکثر مقدار آن برابر $\text{Re} * \text{fitness}$ در موقعیت مربوطه می‌باشد. وابستگی الگوریتم به ε کمی کاهش می‌یابد (Kaveh and Farhoudi 2013). با این وجود انتخاب مقدار ε به علت موارد مطرح شده در بالا هنوز مهم می‌باشد.

(۴) بهترین مکان تکرار جاری را یافته و آن را The Best Location می‌نامیم. جایگزین‌های تخصیص داده شده به



شکل ۵- فلوجارت الگوریتم پژواک صدای دلفین

۳-۳- الگوریتم ژنتیک^۵

یکی از مشهورترین تکنیک‌های فراابتکاری استفاده شده برای بهینه‌سازی مسائل پیچیده، الگوریتم ژنتیک است. الگوریتم ژنتیک توسط هالند (Holland 1984; Holland 1992) توسعه یافته و امروزه به‌طور گسترده در حل مسائل بهینه‌سازی و فرایندهای یادگیری به‌کار می‌رود. به‌طور کلی در طبیعت از ترکیب کروموزوم‌های مناسب نسل‌های بهتری پدید می‌آیند. در این بین گاهی جهش‌هایی نیز در کروموزوم‌ها رخ می‌دهد که ممکن است باعث بهتر شدن نسل بعدی شوند. الگوریتم فراابتکاری ژنتیک نیز با استفاده از این ایده اقدام به حل مسائل می‌کند. الگوریتم ژنتیک مفاهیم تکاملی زیست‌شناسی را شبیه‌سازی می‌کند. این شبیه‌سازی شامل روش‌های احتمالی با استفاده از اصول تکاملی است. در الگوریتم ژنتیک ساختار داده اصلی به‌صورت برداری از ژن‌ها (که کروموزوم نامیده می‌شود) است. هر کروموزوم نمایش دهنده یک نمونه راه‌حل برای مسئله است. اعضای کروموزوم که (ژن‌ها نامیده می‌شوند) شامل بخشی از راه‌حل مسئله‌اند. کیفیت نمونه راه‌حل (یعنی یک کروموزوم) با نزدیکی آن به راه‌حل بهینه (که تابع برازندگی نامیده می‌شود) تعریف می‌شود. الگوریتم

ژنتیک با استفاده از عملگرهای تکاملی (که عملگرهای ژنتیک هم نامیده می‌شوند) راه‌حل بهینه را جستجو می‌کند. در ابتدا با حالت تصادفی ضعیف، کروموزوم‌ها برای نمایش مجموعه راه‌حل‌های مختلف تولید می‌شوند. سپس عملگرهای ژنتیک کروموزوم‌های ضعیف اعمال می‌شوند و کروموزوم‌های جدیدی را برای مرحله بعد تولید می‌کنند. اصطلاحات به‌کار رفته در الگوریتم ژنتیک به‌شرح زیر است (Holland 1984; Holland 1992):

ژن: هرکدام از پارامترهای تصمیم (یعنی پارامترهایی که انتخاب و تعیین مقدار آنها نقشی در تابع بهینگی دارند) در این الگوریتم به‌عنوان یک ژن تلقی می‌شوند.

کروموزوم: مجموعه‌ای شامل تمامی ژن‌ها (پارامترهای تصمیم) که مقداردهی می‌شوند، یک کروموزوم نامیده می‌شود و یک جواب ممکن از مسئله است.

محاسبه تابع بهینگی: مرحله برازش برای هر کروموزوم مقدار تابع بهینگی را محاسبه می‌کند که همان احتمال ترکیب آن برای تولید نسل‌های آینده است. بنابراین کروموزوم‌های بهینه شانس بیشتری برای ترکیب با دیگر کروموزوم‌ها دارند.

روش چرخ‌رولت: در این روش کروموزوم‌ها برحسب مقدار برازندگی‌شان روی قسمت‌هایی از دایره قرار می‌گیرند. هرچه کروموزوم‌های داخل یک قسمت مقدار برازندگی بهتری داشته باشند، مساحت آن قسمت نیز بیشتر خواهد بود. سپس یک عدد تصادفی تولید شده و کروموزوم‌های قسمت متناسب با آن عدد تصادفی به نسل بعد منتقل می‌شوند. فلوجارت کلی الگوریتم ژنتیک در شکل (۶) نمایش داده شده است. همچنین در شکل (۷) شبه کد الگوریتم ژنتیک نشان داده شده است.

۳-۴- الگوریتم سیستم ایمنی مصنوعی^۶

الگوریتم سیستم ایمنی مصنوعی در گروه الگوریتم‌های بهینه سازی اتفاقی قرار دارند که در آنها از قوانین موجود در سیستم ایمنی بیولوژیکی به منظور بهینه‌سازی استفاده می‌شود. ایده اصلی در سیستم ایمنی مصنوعی، برگرفته از فرآیند تکثیر سلولی پس از تشخیص عامل خارجی در سیستم ایمنی طبیعی است. این فرآیند در سیستم ایمنی مصنوعی با نام انتخاب کلونی شناخته می‌شود و شامل سه مرحله است. در مرحله اول، گروهی از بهترین سلول‌ها (سلول‌هایی که آنتی بادی مربوط به آنها بیشترین تطابق را با آنتی‌ژن‌ها داشته باشد) انتخاب می‌شود.

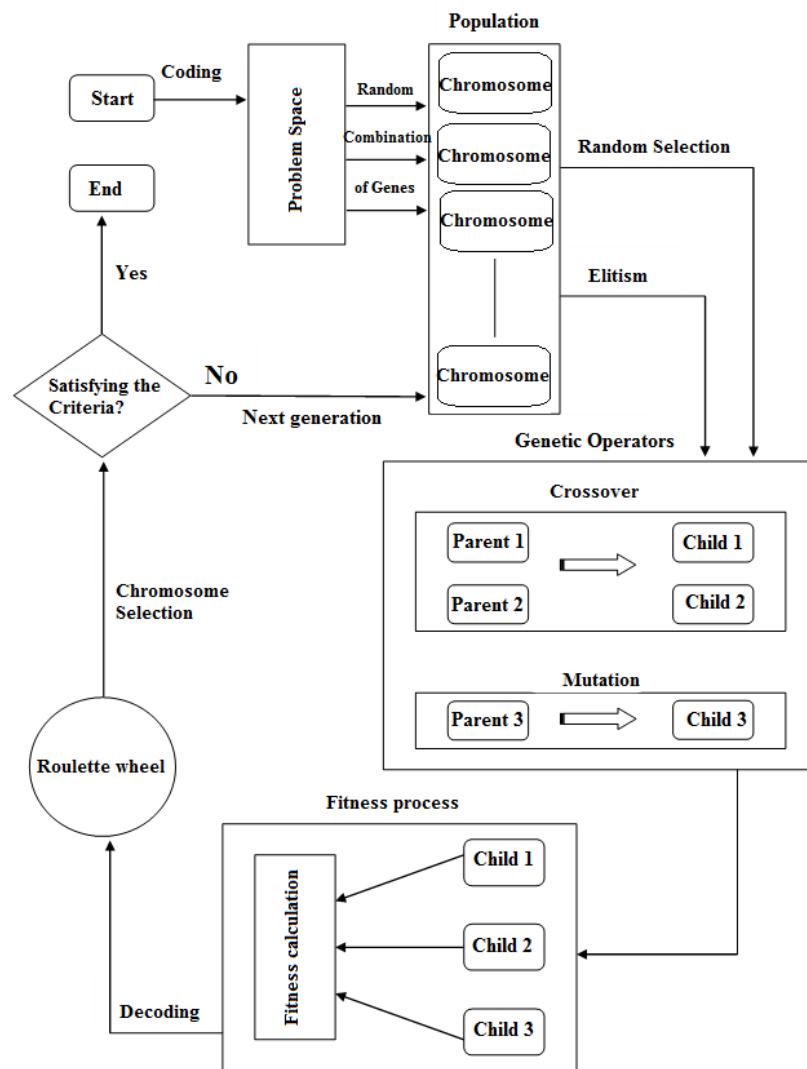
انتخاب: این عملگر کروموزوم‌های انتخابی را با هم ترکیب می‌کند تا شاید کروموزوم‌های فرزند حاصل از ترکیب، از کروموزوم‌های والد بهتر باشد. به‌طور معمول عملگر ترکیب روی یک جفت از کروموزوم‌ها عمل می‌کند و یک یا دو فرزند برای هر جفت تولید می‌شود.

جهش: به‌منظور اجتناب از همگرایی به بهینه محلی و ایجاد تنوع و گوناگونی در جمعیت با استفاده از عملگر جهش یک تعداد از کروموزوم‌ها به‌دست آمده از ترکیب تغییر داده می‌شود.

متداول‌ترین تکنیک‌های انتخاب به‌صورت زیر هستند:

روش برش: ابتدا همه کروموزوم‌ها براساس عددی که تابع ارزیابی به آنها تخصیص داده به‌صورت نزولی از بهترین به بدترین مرتب می‌شوند. سپس n کروموزوم بالایی این لیست با احتمال یکسان به نسل بعد منتقل می‌شوند.

روش مسابقه‌ای: عدد r به‌صورت تصادفی انتخاب می‌شود سپس r کروموزوم از جمعیت انتخاب شده و کروموزوم با بهترین مقدار (زمان اجرا) به نسل بعدی منتقل می‌شود. این روند ادامه می‌یابد تا به مقدار مناسب جمعیت نسل بعد رسیده شود. در این روش ممکن است یک کروموزوم، چند بار انتخاب شود.



شکل ۶- فلوچارت الگوریتم ژنتیک

انتخاب شده تحت عملیات کلون گرفته و با توجه به یک پارامتر با نام نرخ تکثیر، مورد تکثیر واقع می‌شود. تعداد کپی‌هایی که از هر سلول تولید می‌شود بستگی به ارزش آن سلول دارد. هر چقدر برازش یک سلول بیشتر باشد، تعداد کپی‌های بیشتری از آن ایجاد خواهد شد. در مرحله سوم، سلول تکثیر شده تحت عملگری با نام فراجش قرار می‌گیرد. این عملگر که مشابه عملگر جهش در الگوریتم ژنتیک است، با توجه به پارامتری با نام P_m که نرخ جهش است، تغییر کوچکی را به هر سلول تکثیر شده اعمال می‌کند. تفاوتی که عملگر فراجش با عملگر جهش در GA دارد آن است که در فراجش، اندازه تغییراتی که در سلول ایجاد می‌شود بستگی

- 1: Set parameters
- 2: Choose encode method
- 3: Generate the initial population
- 4: **while** $i < MaxIteration$ and $Bestfitness < MaxFitness$ **do**
- 5: Fitness calculation
- 6: Selection
- 7: Crossover
- 8: Mutation
- 9: **end while**
- 10: Decode the individual with maximum fitness
- 11: **return** the best solution

شکل ۷- شبه کد الگوریتم ژنتیک

در اینجا عملاً هر سلول معادل به پاسخ مساله است همانند کروموزوم در یک الگوریتم ژنتیک. در مرحله دوم، سلول‌های

به برآزش آن سلول دارد. هر چقدر یک سلول برازنده‌تر باشد، تغییرات کمتری به آن اعمال خواهد شد.

AIS در اواسط دهه ۱۹۸۰ توسط فارمر و همکاران (۱۹۸۶) (Farmer et al. 1986) و برسینی و وارلا (۱۹۹۰) (Bersini and Varela 1990) در شبکه‌های ایمنی توسعه یافت. فارست و همکاران (Forrest et al. 1993) و کپارت و همکاران (Kephart et al. 1995) اولین مقالات خود در مورد انتخاب معکوس در AIS را در سال ۱۹۹۴ منتشر کردند، و داسگوپتا (Dasgupta 1993; Dasgupta 2012) مطالعات گسترده‌ای در مورد الگوریتم‌های انتخاب معکوس انجام داد. پژوهش‌های دی‌کاسترو و زوبن (De Castro and Von Zuben 1999) (در مورد انتخاب کلونال) در سال ۲۰۰۲ مورد توجه قرار گرفت.

هنگامی که عوامل بیماری‌زای خارجی مانند ویروس‌ها و باکتری‌ها در یک قالب کلی آنتی‌ژن‌ها در ارگانیسم موجودات زنده را مورد تهاجم قرار می‌دهند، ضمن تخریب سلول‌ها به تکثیر نیز می‌پردازند. یکی از مکانیسم‌های جالب توجه سیستم تدافعی موجودات زنده در مقابله با این تهاجم تکثیر سریع سلول‌های تدافعی است که توفیق لازم در شناسایی آنتی‌ژن‌ها و نابود کردن آن‌ها را دارا هستند. جالب اینجاست که میزان تکثیر سلول‌های تدافعی و آنتی‌بادی به میزان موفقیت آنها در نابود کردن فاکتورهای تهاجمی وابسته است. یعنی سیستم ایمنی سلول‌های تدافعی با عملکرد بهتر را بیشتر و آنهایی که دارای قابلیت کمتری هستند را کمتر تکثیر می‌کند. میزان تشخیص یک آنتی‌ژن به‌وسیله سلول‌های تدافعی به‌وسیله فاکتوری به نام «قرابت» شناخته می‌شود. سلول‌های تدافعی با قرابت کمتر باید متحمل عملگر زیستی به نام «جهش» شوند تا با تغییرات ساختاری بتوانند قرابت خود را با عوامل بیماری‌زا بیشتر کرده عملکرد دفاعی خویش را بهبود بخشند. میزان جهش برای عوامل دفاعی با قرابت بیشتر، کمتر است و بالعکس. با توجه به توضیحات فوق چهار مفهوم مهم «قرابت»، «انتخاب»، «جهش»، و «تکثیر» دخالت عمده‌ای در عملکرد سیستم ایمنی موجودات زنده دارند.

ایمنی از مولکول‌ها، سلول‌ها و قوانینی تشکیل شده که از آسیب‌رساندن عواملی مانند پاتوژن‌ها به بدن جلوگیری می‌کند، قسمتی از پاتوژن به نام آنتی‌ژن که توسط این سیستم قابل شناسایی و موجب فعال شدن پاسخ سیستم ایمنی می‌شود. یک نمونه‌ای از پاسخ سیستم ایمنی ترشح آنتی‌بادی توسط سلول‌های B، که آنتی‌بادی‌ها مولکول‌های شناساگری به شکل Y هستند که به سطح سلول‌های B متصل است و با یک‌سری قوانین از پیش‌تعریف‌شده آنتی‌ژن را شناسایی می‌کنند. مولکول‌های آنتی‌بادی قسمتی از آنتی‌ژن را به نام اپیتوپ شناسایی می‌کنند، ناحیه‌ای از آنتی‌بادی که وظیفه شناسایی و اتصال به آنتی‌ژن را دارد پاراتوپ گویند که با نام V شناخته می‌شود، که به‌منظور ایجاد بیشترین میزان تطابق با آنتی‌ژن‌ها می‌توانند شکل خود را تغییر دهند و به همین دلیل ناحیه متغیر نامیده می‌شود. برای حل مساله با استفاده از AIS باید ۳ مرحله انجام پذیرد (Dasgupta 1993): (۱) نحوه نمایش داده‌های مساله (تعریف فضای شکل)، (۲) معیار اندازه‌گیری میل ترکیبی و (۳) انتخاب یک الگوریتم ایمنی مصنوعی برای حل مساله.

فضای شکل: سیستم ایمنی بر مبنای شناسایی الگو یا شناسایی شکل آنتی‌ژن است و می‌توان این سیستم را فضایی مملوء از اشکال مختلف تشبیه کرد و هدف پیدا کردن مکمل اشکال و در نتیجه شناسایی آنها است، یعنی پیدا کردن تعدادی شکل بهینه یا آنتی‌بادی در فضای شکل که مکمل تمامی شکل‌های موجود در داده‌های مسئله آنتی‌ژن است. آنتی‌ژن‌ها به‌صورت آرایه‌ای از اعداد نمایش داده می‌شود و هر شیوه‌های که برای نمایش آنتی‌ژن استفاده می‌شود برای نمایش آنتی‌بادی هم نیز استفاده می‌شود (نحوه نمایش آنتی‌بادی و آنتی‌ژن یکسان است).

نحوه محاسبه و میل ترکیبی آنتی‌بادی با آنتی‌ژن: هر چه آنتی‌بادی میل ترکیبی بیشتری با آنتی‌ژن داشته باشد یعنی هر چه فاصله آنتی‌بادی و آنتی‌ژن کمتر شود مکمل بهتری برای آنتی‌ژن است و میل ترکیبی را می‌توان به‌صورت شباهت آرایه‌ها در نظر گرفت. که بر همین اساس در الگوریتم AIS از

بر تنظیم شدن به یک نوع خاص آنتی ژن، در آینده هم برای فعال شدن نیاز به تحریک شدن کمتری دارند و در نتیجه سرعت و کارایی پاسخ ایمنی را زمانی که پاتوژن برای بار دوم به بدن حمله می کند زیاد می شود.

انتخاب معکوس: میل ترکیبی سلول های T نابالغ با سلول های موجود در تیموس بررسی می شود و هرکدام از سلول های T نابالغ میل ترکیبی زیادی با یکی از سلول ها داشته باشند حذف می شوند و سایر سلول های T وارد جریان خون می شوند که به این گونه انتخاب در آن برای حذف شدن انتخاب می شود انتخاب معکوس گویند.

تئوری شبکه ایمنی: آنتی بادی های موجود بر روی B-Cell ها می توانند علاوه بر تشخیص آنتی ژن، آنتی بادی را هم تشخیص بدهند و باعث می شود سیستم ایمنی رفتاری پویا داشته که از آن در AIS استفاده می شود، و براساس این تئوری هر آنتی بادی قسمتی به نام ایدوتوپ دارد که توسط آنتی بادی دیگر قابل شناسایی است که در نتیجه آنتی بادی ها با شناسایی کردن یکدیگر سیگنال هایی را ارسال می کنند که می توانند یکدیگر را تحریک کنند و بدین ترتیب این شناسایی و تاثیرگذاری بر روی یکدیگر باعث پویایی شبکه ایمنی مصنوعی می شود. به مجموعه آنتی بادی ها که یکدیگر را شناسایی می کنند شبکه ایمنی یا ایدوتوبی گفته می شود. در شکل (۸) شبه کد الگوریتم الگوریتم سیستم ایمنی مصنوعی نشان داده شده است.

```

Input: Ab, Ag, Ngen, n, d, L, β
Output: Abm

for t = 1 to Ngen begin
  for j = 1 to M begin
     $\bar{f}_j := \text{affinity}(Ab, ag_j);$ 
     $Ab_{[n]}^j := \text{select}(Ab, \bar{f}_j, n);$ 
     $C^j := \text{clone}(Ab_{[n]}^j, \beta, \bar{f}_j);$ 
     $C^{j*} := \text{hypermut}(C^j, \bar{f}_j);$ 
     $\bar{f}_j^* := \text{affinity}(C^{j*}, ag_j);$ 
     $ab_j^* := \text{select}(C^{j*}, \bar{f}_j^*, 1);$ 
     $Ab_{[m]}^j := \text{insert}(Ab_{[m]}^j, ab_j^*);$ 
     $Ab_{[r]} := \text{replace}(Ab_{[r]}, C^{j*}, f);$ 
     $Ab_{[d]} := \text{generate}(d, L);$ 
     $Ab_{[r]} := \text{replace}(Ab_{[r]}, Ab_{[d]}, f);$ 
  end;
end
end

```

شکل ۸- شبه کد الگوریتم سیستم ایمنی مصنوعی

فاصله به عنوان معیار ارزیابی خوب یا بد بودن یک آنتی بادی استفاده می شود.

الگوریتم های AIS: الگوریتم های AIS به ۳ دسته تقسیم می شوند (Dasgupta 1993):

۱- دسته اول؛ الگوریتم هایی که بر مبنای انتخاب کلونی سلول های B ایجاد شده اند.

۲- دسته دوم؛ الگوریتم هایی که بر مبنای انتخاب معکوس سلول های T ایجاد شده اند.

۳- دسته سوم؛ بر مبنای تئوری شبکه ایمنی ایجاد شده اند.

انتخاب کلونی: زمانی که سلول B آنتی ژن را شناسایی می کند و سلول های B شروع به تکثیر شدن می کنند و تعداد زیادی سلول B یکسان و مشابه تولید می شود، ۱۲ ساعت طول می کشد که یک سلول B رشد کرده و به دو سلول تبدیل شود و بعد از تحریک شدن دوره تکثیر حدوداً یک هفته طول می کشد و از یک سلول ۲ به توان ۱۴ (۱۶۰۰۰) سلول مشابه تولید می شود و هر چه میل پیوندی بین سلول B و آنتی ژن بیشتر شود نرخ تکثیر بیشتر خواهد شد، در نتیجه سلول های B با میل پیوندی بالاتر، کلونی بیشتری تولید می کنند که اصل انتخاب کلونی نام دارد. اصل انتخاب کلونی در AIS الگوریتم خاص خودش را دارد که بعد از تکثیر شدن سلول های B شروع به بالغ شدن می کنند که این فرایند در ۳ مرحله صورت می پذیرد: (۱) دگرگونی ایزوتاوپ، (۲) بلوغ میل پیوندی و (۳) تصمیم گیری بین حافظه یا پلاسما شدن سلول B.

سلول B در صورتی به تکثیر ادامه می دهد که جهش باعث افزایش میل پیوندی شده باشد و آنتی بادی به طور مداوم توسط آنتی ژن تحریک می شود و تلاش برای ایجاد سلول های B بهتری دارد که فرایند بلوغ پیوندی نام دارد. گام بعدی فرایند بلوغ پیوندی انتخاب بین حافظه یا پلاسما شدن سلول B است که سلول های پلاسما سازندگان آنتی بادی هستند و در حجم زیادی آنتی بادی ترشح می کنند و عمر زیادی ندارند و حالت دیگر تبدیل سلول های B به سلول های حافظه که این سلول ها میل پیوندی زیادی با آنتی ژن دارند و هدف بخاطر سپردن این آنتی ژن برای آینده است. سلول های حافظه علاوه

DPW و آلفا به ترتیب با نرخ نفوذ ارتباط نمایی و چندجمله‌ای دارند. بنابراین، مدل براساس معادلات چندمتغیره بدست آمد. تابع عملکرد مدل، $F(h)$ به صورت زیر تعریف می‌شود:

$$F(h) = \sum_{i=1}^m (Y_{measure} - Y_{predict}) \quad (23)$$

که در آن، $Y_{measure}$ و $Y_{predict}$ ، به ترتیب، نشانگر نرخ نفوذ اندازه‌گیری شده و نرخ نفوذ پیش‌بینی می‌باشند و m بیانگر تعداد مشاهدات است.

در ادامه از چهار الگوریتم ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری در نرم افزار MATLAB و با هدف پیش‌بینی نرخ نفوذ TBM کدنویسی شدند. به منظور آموزش بهتر مدل‌ها و ارائه مدل دقیق‌تر، مقادیر عددی پارامترهای ورودی و خروجی نرمال‌سازی (به مقادیر بین ۰ و ۱) شدند تا داده‌ها کاملاً مناسب امر مدل‌سازی باشند.

پارامترهای تنظیم اولیه الگوریتم‌های بهینه‌سازی ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری برای نیل به روابط پیش‌بینی با خطای کم با روش سعی و خطا تعیین شدند که در جدول ۲ مقدار این پارامترها نشان داده شده است. برای ارزیابی و تأیید اعتبار روابط بدست آمده توسط الگوریتم‌های ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری، شاخص‌های آماری ضریب همبستگی مربع (R^2) و میانگین خطای مربع (MSE) برای سنجش دقت مدل‌ها انتخاب شدند. در روابط ۲۴ و ۲۵، $Y_{measure}$ و $Y_{predict}$ ، به ترتیب، نشانگر مقدار اندازه‌گیری شده و پیش‌بینی شده نرخ نفوذ و n تعداد نمونه‌ها می‌باشند. در این حالت، هر چقدر مقدار MSE به صفر نزدیک‌تر و مقدار R^2 به عدد ۱ نزدیک‌تر باشد، مدل پیش‌بینی شده به عنوان مدل ایده‌آل و نزدیک‌تر به واقعیت پذیرفته می‌شود.

۴- یافته‌های تحقیق، صحت‌سنجی و اعتبار مدل

همانطور که قبلاً گفته شد در این مقاله برای مدل‌سازی و پیش‌بینی نرخ نفوذ TBM از الگوریتم‌های فراابتکاری ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری استفاده شده است. پارامترهای ورودی جهت مدل‌سازی شامل: مقاومت فشاری تک محوره سنگ بکر (UCS)، تردی سنگ بکر (BI)، زاویه بین صفحات ناپیوستگی و جهت حفاری TBM (α) و فاصله بین صفحات ناپیوستگی (DPW) و داده‌های میدانی نرخ نفوذ TBM می‌باشند پایگاه داده که شامل ۱۵۳ داده می‌باشد، به دو دسته داده‌های آموزش (برای ساخت مدل‌ها) و داده‌های آزمون (برای ارزیابی دقت مدل‌ها) بصورت تصادفی تفکیک می‌شوند. در این راستا، ۱۲۲ داده (۸۰ درصد کل داده‌ها) برای آموزش و ۳۱ داده (۲۰ درصد کل داده‌ها) برای ارزیابی صحت و دقت مدل‌ها استفاده شده است. برای پیش‌بینی نرخ نفوذ TBM در این مقاله، رابطه زیر پیشنهاد شد که با استفاده از الگوریتم‌های فراابتکاری ضرایب آن بصورت دقیق بدست خواهد آمد:

$$ROP(i) = w_1 UCS + w_2 BI + \dots \quad (22)$$

$$+ w_3 DPW + w_4 + w_5 a + w_6 + w_7$$

که در آن، w به وزن پارامترهای جستجو اشاره دارد، i تعداد حالات ممکن را نشان می‌دهد که $(i = 1, 2, 3, \dots, N)$ و $R^N = \{w_1, w_2, \dots, w_N\}$ پارامترهایی هستند که باید توسط الگوریتم‌های فراابتکاری ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری تخمین زده شوند.

معادله ۲۲ بر حسب سعی و خطا به عنوان نتیجه بهترین مدل‌های تخمین نرخ نفوذ بر حسب متر بر ساعت بدست آمده است. در مرحله اولیه ارزیابی پارامترها، تأثیر پارامترهای سنگ به صورت دو به دو با پارامتر خروجی (نرخ نفوذ) از طریق تجزیه و تحلیل رگرسیون ساده مورد بررسی قرار گرفت. در این تحلیل مشخص شد که برخی متغیرها از جمله UCS و BI با نرخ نفوذ ارتباط خطی داشته و دیگر پارامترها مانند

$$R^2 = 1 - \frac{\sum_{k=1}^n (Y_{measure} - Y_{predict})^2}{\sum_{k=1}^n Y_{measure}^2 - \frac{\sum_{i=1}^n Y_{predict}^2}{n}} \quad (24)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{measure} - Y_{predict})^2 \quad (25)$$

پس از مدلسازی با استفاده از الگوریتم‌ها، ضرایب وزنی بهینه و نهایتاً روابط پیش‌بینی در جدول ۳ برای برآورد نرخ نفوذ TBM نشان داده شده است. بعد از بدست آمدن روابط پیش‌بینی، مقادیر حاصله برای شاخص‌های آماری R^2 و MSE برای هر چهار الگوریتم در دو فاز آموزش و آزمون محاسبه شد که نتایج در جدول ۴ نشان داده شده است. همچنین در شکل ۹ رابطه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برای حالت آزمون توسط الگوریتم‌های بهینه‌سازی ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری نمایش داده شده است.

جدول ۲. پارامترهای تنظیم شده برای اجرای الگوریتم‌های ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری

Algorithm	Value	Variable
Genetic	Maximum iterations	500
	Population number	100
	Crossover rate	0.9
	Mutation rate	0.3
	Selection type	Tournament
	Fitness	MSE
Artificial immune system	Maximum iterations	500
	Population number	100
	Colony size factor	5
	The most error factor	0.02
	The size of the best population	10
	Fitness	MSE
Grey wolf optimizer	Maximum iterations	500
	Population number	100
	Fitness	MSE
Dolphin echolocation	Maximum iterations	500
	Population number	100
	Effective radius	5
	Power (the degree of the curve)	2.88
	PPI (the convergence factor of the first loop)	0.095
	Fitness	MSE

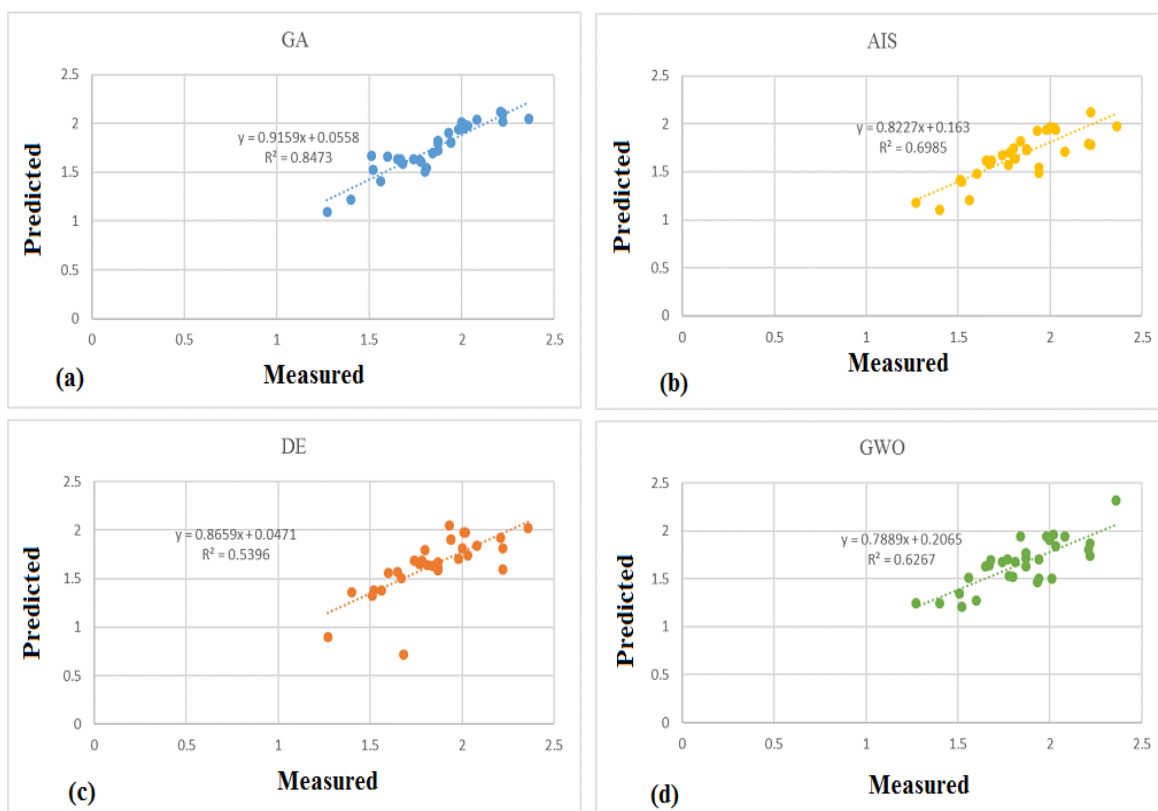
روابط R^2 و MSE به صورت زیر تعریف می‌شوند:

جدول ۳. روابط پیش‌بینی بدست آمده از اجرای الگوریتم‌های فراابتکاری پیشنهادی

Algorithm	Predictive relationships obtained
Genetic	$ROP(m/hr) = -0.00058UCS + 0.01842BI - 0.2241DPW^{0.9975} - 1.5876\alpha^{-0.7988} + 3.1183$
Artificial immune system	$ROP(m/hr) = -0.0057UCS + 0.0587BI - 0.4315DPW^{0.715} - 1.9472\alpha^{-0.774} + 2.6749$
Grey wolf optimizer	$ROP(m/hr) = -0.0775UCS + 0.08244BI - 0.7656DPW^{-0.316} - 1.7806\alpha^{-0.747} + 0.9749$
Dolphin echolocation	$ROP(m/hr) = -0.0132UCS + 0.6067BI + 1.5894DPW^{-0.106} - 1.5424\alpha^{-0.649} + 0.4219$

جدول ۴. مقادیر حاصله برای شاخص‌های آماری با استفاده از الگوریتم‌های فراابتکاری پیشنهادی

Algorithm	R^2_{test}	R^2_{train}	MSE_{test}	MSE_{train}
Genetic	0.8473	0.9319	0.02	0.012
Artificial immune system	0.6985	0.9652	0.105	0.082
Grey wolf optimizer	0.6267	0.9042	0.296	0.24
Dolphin echolocation	0.5396	0.8779	0.521	0.375

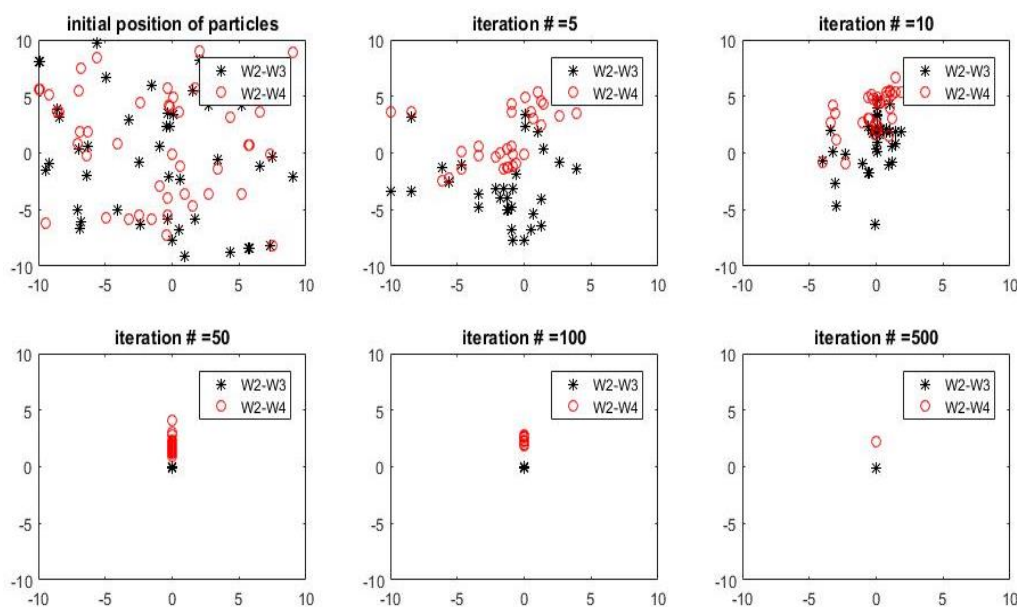


شکل ۹- همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی برای داده‌های آزمون توسط الگوریتم‌های (الف) ژنتیک، (ب) سیستم ایمنی مصنوعی، (پ) پژواک صدای دلفین و (ت) گرگ خاکستری.

در شکل ۱۰ نشان داده شده است. همانطور که مشهود است ذرات در ابتدا به صورت تصادفی در فضای جستجو پراکنده هستند که رفته‌رفته با بروزرسانی موقعیت ذرات در فضای جستجو به بهینه سراسری دست پیدا می‌کنند. همچنین نحوه همگرایی بین تابع برازش (MSE) و تعداد تکرار الگوریتم ژنتیک در شکل ۱۱ نشان داده شده است.

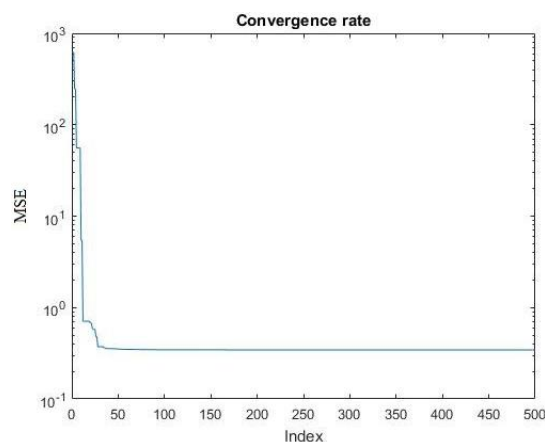
همانطور که در جدول ۴ و شکل ۹ ملاحظه می‌شود، واضح است که دقیق‌ترین مدل پیش‌بینی مربوط به الگوریتم ژنتیک و بعد از آن الگوریتم سیستم ایمنی مصنوعی دارای جایگاه دوم است. مدل بدست آمده برای پیش‌بینی نرخ نفوذ در سنگ سخت به اندازه کافی از دقت بالایی برخوردار است که نشان از کارایی بالای کاربرد الگوریتم‌های فراابتکاری در حوزه حفاری مکانیزه دارد.

در دقیق‌ترین مدل که مربوط به الگوریتم ژنتیک است، نحوه همگرا شدن ذرات در فضای جستجو نسبت به تعداد تکرارها



شکل ۱۰- موقعیت ذرات از موقعیت اولیه تا پایان تکرار در الگوریتم ژنتیک

محوره سنگ بکر (UCS)، تردی سنگ بکر (BI)، زاویه بین صفحات ناپیوستگی و جهت حفاری TBM (α) و فاصله بین صفحات ناپیوستگی (DPW) به عنوان پارامترهای ورودی و عملکرد دستگاه TBM (نرخ نفوذ بعنوان پارامتر خروجی) برای ایجاد مدل‌های پیش‌بینی عملکرد ماشین حفاری TBM تشکیل شد. با توجه به ضرایب وزنی به دست آمده روابط در جدول ۳ معرفی شدند. سپس برای اعتبارسنجی روابط به دست آمده برای هر مدل، خطاهای نسبی و شاخص‌های آماری از جمله ضریب همبستگی مربع (R^2) و میانگین خطای مربع (MSE) برای دو مجموعه داده‌های آموزش (۱۲۲ داده) و مجموعه داده‌های آزمون (۳۱ داده) به منظور بررسی عملکرد هر مدل استفاده شد. با استناد به مقادیر حاصل شده، مشخص شد که الگوریتم ژنتیک با توجه به پایین بودن میزان خطا و نزدیک بودن به مقدار اندازه‌گیری، بهترین پیش‌بینی کننده و قابل اعتمادترین مدل را نسبت به سایر مدل‌ها دارد. با توجه به نتایج به دست آمده از این مقاله می‌توان دریافت که الگوریتم‌های بهینه‌سازی توانایی بالایی برای حل مسائل مهندسی فضاهای زیرزمینی را در سایر موضوعات دارند.



شکل ۱۱- بهترین تابع برازش (MSE) در الگوریتم GA.

۵- نتیجه‌گیری

یکی از مسائل حیاتی در تخمین هزینه‌های ساخت و زمان اجرای پروژه‌های تونلی، پیش‌بینی عملکرد ماشین‌های حفاری مکانیزه تمام مقطع تونل (TBM) است. عملکرد TBM به شدت وابسته به میزان نرخ نفوذ دستگاه است. در این مطالعه، از الگوریتم‌های بهینه‌سازی ژنتیک، سیستم ایمنی مصنوعی، پژواک صدای دلفین و گرگ خاکستری برای پیش‌بینی نرخ نفوذ TBM در سنگ سخت استفاده شده است. براساس داده‌های به دست آمده از ۷/۵ کیلومتر تونل کوپینز شماره ۳ که در ۱۵۱ ایستگاه اندازه‌گیری شده است، بانک اطلاعاتی شامل ویژگی‌های توده سنگ (مقاومت فشاری تک

منابع

- Armaghani DJ, Mohamad ET, Narayanasamy MS, Narita N, Yagiz S (2017) Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition Tunn Undergr Sp Tech 63:29-43
- Barton N (1999) TBM performance estimation in rock using QTBM T & T international 31:30-34
- Bersini H, Varela FJ Hints for adaptive problem solving gleaned from immune networks. In: International Conference on Parallel Problem Solving from Nature, 1990. Springer, pp 343-354
- Bieniawski Z, Celada B, Galera J, Tardáguila I New applications of the excavability index for selection of TBM types and predicting their performance. In: ITA World Tunneling Congress, Agra, India, 2008 .
- Bieniawski Z, Grandori R (2007) Predicting TBM excavability-part II Tunnels & Tunnelling International
- Cassinelli F (1982) Power consumption and metal wear in tunnel-boring machines: analysis of tunnel-boring operation in hard rock
- Dasgupta D (1993) An overview of artificial immune systems and their applications Artificial immune systems and their applications:3-21
- Dasgupta D (2012) Artificial immune systems and their applications. Springer Science & Business Media ,
- De Castro LN, Von Zuben FJ (1999) Artificial immune systems: Part I–basic theory and applications Universidade Estadual de Campinas, Dezembro de, Tech Rep 210
- Farmer I, Glossop N (1980) Mechanics of disc cutter penetration Tunnels Tunnelling;(United Kingdom) 12
- Farmer JD, Packard NH, Perelson AS (1986) The immune system, adaptation, and machine learning Physica D: Nonlinear Phenomena 22:187-204
- Forrest S, Javornik B, Smith RE, Perelson AS (1993) Using genetic algorithms to explore pattern recognition in the immune system Evolutionary computation 1:191-211
- Gao B, Wang R, Lin C, Guo X, Liu B, Zhang W (2021) TBM penetration rate prediction based on the long short-term memory neural network Underground Space 6:718-731
- Hamidi JK, Shahriar K, Rezai B, Rostami J (2010) Performance prediction of hard rock TBM using Rock Mass Rating (RMR) system Tunn Undergr Sp Tech 25:333-345
- Hassanpour J, Rostami J, Khamehchiyan M, Bruland A, Tavakoli H (2010) TBM performance analysis in pyroclastic rocks: a case history of Karaj water conveyance tunnel Rock Mechanics and Rock Engineering 43:427-445
- Holland JH (1984) Genetic algorithms and adaptation .In: Adaptive Control of Ill-Defined Systems. Springer, pp 317-333
- Holland JH (1992) Genetic algorithms Scientific american 267:66-73
- Innaurato N, Mancini A, Rondena E, Zaninetti A Forecasting and effective TBM performances in a rapid excavation of a tunnel in Italy. In: 7th ISRM Congress, 1991. International Society for Rock Mechanics and Rock Engineering ,
- Kaveh A, Farhoudi N (2013) A new optimization method: Dolphin echolocation Advances in Engineering Software 59:53-70
- Kephart JO, Sorkin GB, Arnold WC, Chess DM, Tesauro GJ, White SR, Watson T Biologically inspired defenses against computer viruses. In: IJCAI (1), 1995. pp 985-996
- Lislerud A (1988) Hard rock tunnel boring: prognosis and costs Tunn Undergr Sp Tech 3:9-17
- Liu B, Wang R, Zhao G, Guo X, Wang Y, Li J, Wang S (2020) Prediction of rock mass parameters in the TBM tunnel based on BP neural network integrated simulated annealing algorithm Tunn Undergr Sp Tech 95:103103
- Mahdevari S, Shahriar K, Yagiz S, Shirazi MA (2014) A support vector regression model for predicting tunnel boring machine penetration rates Int J Rock Mech Min Sci 72:214-229
- Mansouri M, Moomiv H (2010) Influence of rock mass properties on TBM penetration rate in Karaj-Tehran water conveyance tunnel Journal of Geology and Mining Research 2:114-121
- Minh VT, Katushin D, Antonov M, Veinthal R (2017) Regression models and fuzzy logic prediction of TBM penetration rate Open Engineering 7:60-68
- Mirjalili S, Mirjalili SM, Lewis A (2014) Grey wolf optimizer Advances in engineering software 69:46-61

-
- Nichols O, Bamford M (1985) Reptile and frog utilisation of rehabilitated bauxite minesites and dieback-affected sites in Western Australia's jarrah *Eucalyptus marginata* forest *Biological Conservation* 34:227-249
- Tarkoy PJ Ninth Canadian Symposium on Rock Mechanics
- Wei M, Wang Z, Wang X, Peng J, Song Y (2021) Prediction of TBM penetration rate based on Monte Carlo-BP neural network *Neural Comput Appl* 33:603-611
- Yagiz S (2008) Utilizing rock mass properties for predicting TBM performance in hard rock condition *Tunn Undergr Sp Tech* 23:326-339
- Yagiz S, Karahan H (2011) Prediction of hard rock TBM penetration rate using particle swarm optimization *International Journal of Rock Mechanics and Mining Sciences* 48:427-433
- Yagiz S, Karahan H (2015) Application of various optimization techniques and comparison of their performances for predicting TBM penetration rate in rock mass *Int J Rock Mech Min Sci* 80:308-315
- Yagiz S, Rostami J, Kim T, Ozdemir L, Merguerian C Factors influencing performance of hard rock tunnel boring machines. In: *ISRM Regional Symposium-EUROCK 2009, 2009. International Society for Rock Mechanics and Rock Engineering* ,
- Yin L, Gong Q, Zhao J (2014) Study on rock mass boreability by TBM penetration test under different in situ stress conditions *Tunn Undergr Sp Tech* 43:413-425
- Zhou J, Bejarbaneh BY, Armaghani DJ, Tahir M (2019) Forecasting of TBM advance rate in hard rock condition based on artificial neural network and genetic programming techniques *Bull Eng Geology Envir*:1-16
- Zhou J, Qiu Y, Armaghani DJ, Zhang W, Li C, Zhu S, Tarinejad R (2021) Predicting TBM penetration rate in hard rock condition: A comparative study among six XGB-based metaheuristic techniques *Geoscience Frontiers* 12:101091