پیش‌بینی گشتاور چرخشی موردنیاز برای انجام عملیات حفاری انحرافی در لایه‌های سنگی با استفاده از ترکیب شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی

هادی فتاحی*[1]، زهره بیات زاده فرد[2]

۱- استادیار، دانشکده مهندسی معدن، دانشگاه صنعتی اراک

۲- دانشجوی کارشناسی ارشد، دانشکده مهندسی معدن، دانشگاه صنعتی اراک

(دریافت: بهمن ۱۳۹۴، پذیرش: تیر ۱۳۹۶)

چکیده

امروزه عملیات حفاری انحرافی به‌طور گسترده‌ای در انواع شرایط زمین‌شناسی به کار می‌رود، اما استفاده بهینه از این فنّاوری در شرایط سنگی و سخت به دانش و تجربه بالای مهندسی نیاز دارد. مقدار گشتاور چرخشی یکی از پارامترهای بسیار مهمی است که باید برای انجام عملیات حفاری انحرافی پیش‌بینی شود. در این پژوهش جهت ارائه راهکار جدید برای پیش‌بینی گشتاور چرخشی موردنیاز برای انجام عملیات حفاری انحرافی در لایه‌های سنگی از روش ترکیب شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی استفاده شده است. درواقع برای بهینه‌سازی وزن‌های شبکه عصبی مصنوعی و بالا بردن توانایی‌های شبکه از الگوریتم مبتنی بر جغرافیای زیستی بهره گرفته شده است. هم‌چنین از نیروی محوری، سرعت چرخش مته، طول رشته حفاری، تغییر زاویه کلی گمانه، قطر *i*امین برقو، سرعت جریان گل و ویسکوزیته گل حفاری به‌عنوان پارامترهای ورودی مدل برای پیش‌بینی گشتاور چرخشی استفاده شده است. برای ارزیابی توانایی مدل در پیش‌بینی گشتاور چرخشی، از داده‌های پروژه انتقال گاز طبیعی غرب به شرق چین استفاده شده است. تعداد کل داده‌ها در این پروژه ۸۴ داده است که از این تعداد به‌طور تصادفی، ۷۵ درصد داده‌ها برای آموزش مدل و ۲۵ درصد داده‌ها برای آزمون مدل استفاده شده است. نتایج حاصل از این مطالعه بیانگر آن است که مدل پیشنهادی می‌تواند به‌عنوان یک ابزار قدرتمند برای مدلسازی مسائل حفاری انحرافی مورد استفاده قرار گیرد.

کلید واژه‌ها

حفاری انحرافی، گشتاور چرخشی، شبکه عصبی مصنوعی، الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی

* عهده دار مکاتبات: *H.fattahi@arakut.ac.ir*

۱- مقدمه

انجام عملیات حفاری انحرافی در لایه‌های سنگی به‌طور گسترده‌ای در سراسر جهان برای اهداف مختلفی به کار می‌رود. مبدأ این روش به اوایل دهه ۱۹۷۰ برمی‌گردد و از آن زمان به بعد، این فناوری پیشرفت کرده است [۱, ۲]. امروزه برای نصب خطوط لوله در سازندهای سنگی به دانش و تجربه بالای مهندسی نیاز است [۳-۶]. تاکنون مدل‌های مکانیکی مناسب و معادلات زیادی برای محاسبه پارامترهای مختلف مربوط به این نوع از ساخت‌وساز توسعه داده شده است [۷-۹]؛ با این حال فقدان مدل‌ها و روش‌های پیشرفته برای موقعیت‌های سخت‌تر، از جمله مناطقی با لایه‌های سنگی و در زیر بستر رودخانه‌ها (مانند پروژه انتقال گاز طبیعی) به چشم می‌خورد [۱۰]. برای استفاده بهینه از روش حفاری انحرافی در چنین شرایط سنگی و سخت، پیش‌بینی گشتاور موردنیاز برای انجام عملیات برقوکاری و هم‌چنین برای انتخاب نوع و سایز مناسب برقوها امری ضروری و غیر قابل اجتناب است [۱۱]. با این وجود، در حال حاضر یک روش مناسب و سریع برای انجام این کار، به ویژه برای خطوط لوله بزرگ وجود ندارد. همچنین لازم به ذکر است که گشتاور چرخشی موردنیاز در دکل حفاری به عوامل مختلفی بستگی دارد ازجمله: شرایط زمین‌شناسی، روش حفاری، اندازه و نوع برقو، سرعت چرخشی، نیروی محوری در مته، خواص گل حفاری، قطر گمانه، طول رشته حفاری در گمانه و سرمته حفاری [۱۲, ۱۳]. اگرچه دانش موجود برای روش‌های حفاری برخی از امکانات لازم برای پیش‌بینی گشتاور را فراهم می‌کند ولی برای رفع نیازهای حاضر کافی نیست. هدف از مطالعه حاضر پیش‌بینی گشتاور چرخشی موردنیاز برای انجام عملیات حفاری انحرافی در لایه‌های سنگی است. در سال‌های اخیر در این زمینه مطالعاتی با استفاده از روش‌های سنتی آماری انجام شده است [۱۱]، اما پژوهش حاضر به کاربرد روش‌های پیشرفته رایانش نرم در این زمینه می‌پردازد.

در سال‌های اخیر روش‌های هوشمند در حوزه‌های مختلف مهندسی و علوم جهت حل مسائل پیچیده و حجیم به لحاظ محاسباتی مورد استفاده قرار گرفته‌اند. شبکه عصبی مصنوعی[1]، سیستم‌های فازی، الگوریتم‌های تکاملی و بسیاری دیگر، از روش‌های هوشمند به حساب می‌آیند [۱۴] که کاربردهای فراوانی مانند مدلسازی و تقریب توابع، طبقه‌بندی، خوشه‌بندی، استخراج ویژگی، فشرده‌سازی، بهینه‌سازی، کنترل و شناسایی سیستم دارند. این روش‌ها در زمینه مسائل مختلف مهندسی معدن مانند اکتشاف ذخایر کانسارها [۱۵, ۱۶]، مباحث ژئوفیزیک [۱۷]، مسائل فرآوری مواد معدنی [۱۸]، حوزه مکانیک سنگ [۱۹-۲۱]، حفاری و چاه‌پیمایی [۲۲] و در مسائل زیست‌محیطی-معدنی [۲۳-۲۵] نیز کاربردهای فراوانی دارند؛ که با توجه به بالا بودن قابلیت این روش‌ها، در این پژوهش نیز از این روش‌ها استفاده شده است. در زمینه مدلسازی گشتاور چرخشی اگرچه مطالعات قبلی با ارزش هستند اما ارائه مدل‌هایی جدید با نتایجی دقیق و سریع می‌تواند بسیاری از مشکلات میدانی مربوط به این حوزه را رفع کند. از آنجایی که مدل‌های مبتنی بر هوش مصنوعی عملکرد بالایی در امر مدلسازی دارند می‌توانند راهگشای این مسئله باشند. یکی از روش‌های هوشمند، شبکه عصبی مصنوعی است که یک روش داده‌کاوی قوی است. هرچند این روش یک روش کارآمد برای مدلسازی پدیده‌های مختلف است ولی کاستی‌هایی هم دارد که برخی از کاربردهایش را محدود می‌کند. یکی از چالش‌های اصلی شبکه عصبی مصنوعی، نحوه به‌روزرسانی و بهینه‌سازی وزن‌های شبکه در هنگام آموزش است. استفاده از الگوریتم‌های بهینه‌سازی برای رفع ضعف الگوریتم‌های مبتنی بر گرادیان، در سالیان اخیر بسیار مورد توجه قرار گرفته است. در همین راستا، در تحقیق حاضر، به منظور دستیابی به هدف فوق، از الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی[2] (با الهام از رفتار مهاجرتی گونه‌های زیستی) به‌عنوان استراتژی جستجو برای یافتن مقدار بهینه وزن‌ها و بایاس‌های شبکه استفاده شده است. ترکیب شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی منجر به ایجاد مدلی می‌شود که می‌تواند مقدار گشتاور چرخشی را با دقت مطلوبی برآورد کند.

۲- مروری بر روش‌های به کار گرفته شده در این تحقیق

۲-۱- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده است و مانند مغز انسان به پردازش اطلاعات می‌پردازد. نورون کوچک‌ترین واحد یک شبکه عصبی مصنوعی است [۲۶]. ساختار یک نورون مصنوعی در شکل ۱ نشان داده شده است. از اجتماع چند نورون که به‌طور موازی عمل می‌کنند، یک لایه به وجود می‌آید. هر لایه وظیفه خاصی دارد و با ترکیب لایه‌ها، شبکه عصبی مصنوعی به وجود می‌آید. در حالت کلی در شبکه‌های عصبی مصنوعی سه نوع لایه نورونی وجود دارد که عبارت‌اند از: یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی. هر دو لایه از یک شبکه، به وسیله وزن‌ها و در واقع اتصالات با هم ارتباط می‌یابند. وزن‌ها در ابتدا به صورت تصادفی مقداردهی می‌شوند و سپس در طول فرآیند یادگیری با کاهش میزان خطا، اصلاح و مقادیر نهایی آن‌ها تعیین می‌شود. هیچ قاعده مشخص و دقیقی برای انتخاب و تعیین تعداد نورون‌ها در لایه پنهان شبکه وجود ندارد؛ بلکه در این مورد به‌طور عمده یک رویکرد تجربی صرف اتخاذ می‌شود. بر اساس نحوه ارتباط بین نورون‌ها انواع مختلفی از شبکه‌های عصبی مصنوعی مانند شبکه‌های پرسپترون، هاپفیلد و ... وجود دارد؛ در این بین شبکه‌های پرسپترون بیشترین کاربرد را دارند و به انواع تک لایه و چند لایه تقسیم‌بندی می‌شوند. برای یک مدل پرسپترون چند لایه با یک لایه پنهان (شکل ۲) رابطه‌های ارائه شده زیر به کار برده می‌شوند [۲۷]:

$$u_j = \sum_{i=1}^{N_{inp}} x_i a_{ij} + a_{0j} \quad (۱)$$

$$Z_j = g(u_j) \quad (۲)$$

$$v_k = \sum_{j=1}^{N_{hid}} Z_j b_{jk} + b_{0k} \quad (۳)$$

$$Y_k = g(v_k) \quad (۴)$$

که در این روابط Z_j خروجی لایه پنهان، Y_k خروجی لایه خروجی، g تابع انتقال (تحریک) و a_{ij} و b_{ij}: بردارهای وزن هستند.

از طرفی یک پرسپترون چند لایه را می‌توان به وسیله توابع غیرخطی به گونه‌ای آموزش داد که بتواند هر تابع قابل اندازه‌گیری را تخمین زده و اندازه‌گیری کند. این فرآیند در حالی صورت می‌گیرد که شبکه اطلاعاتی درباره توزیع ورودی‌ها نیاز ندارد. شبکه عصبی مصنوعی با استفاده از مجموعه داده‌های واقعی، الگوریتم‌های آموزشی را به کار می‌گیرد تا ارتباطات پنهانی میان داده‌های ورودی و خروجی را از طریق ضرایب وزنی، بایاس‌ها و توابع اعمالی به خروجی‌های هر لایه، شکل دهند.

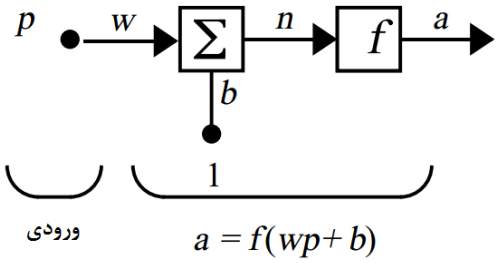

شکل ۱: ساختار یک نورون مصنوعی [۲۸]

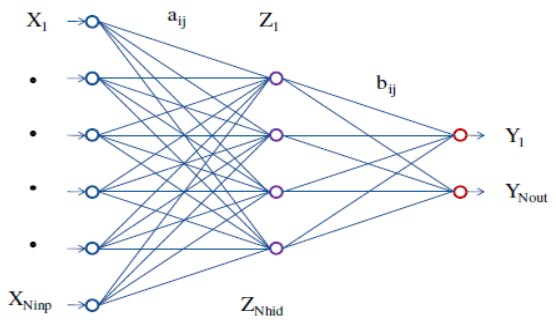

شکل ۲: یک مدل پرسپترون چند لایه با یک لایه پنهان [۲۹]

الگوریتم‌های آموزشی متنوعی جهت آموزش شبکه عصبی مصنوعی به کار گرفته شده است. از مهمترین الگوریتم‌های آموزشی می‌توان از الگوریتم پس انتشار نام برد. اساس کار این الگوریتم حرکت بر روی بردار گرادیان تابع مربعات خطای شبکه است که این بردار نیز به نوبه خود به وسیله مشتق‌گیری زنجیره‌ای از تابع خطا نسبت به تک‌تک پارامترهای شبکه به دست می‌آید. اگرچه امروزه استفاده از این روش برای آموزش شبکه عصبی مصنوعی رایج است اما الگوریتم‌های بهینه‌سازی مبتنی بر گرادیان و الگوریتم پس انتشار خطا، در سیستم‌های غیرخطی، مشکل افتادن در دام مینیمم محلی را دارند. از این رو استفاده از الگوریتم‌های تکاملی برای آموزش شبکه‌های عصبی مصنوعی مورد توجه محققان مختلف قرار گرفته است [۳۰-۳۳]. در این تحقیق از الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی به‌عنوان یک جایگزین برای آموزش شبکه عصبی مصنوعی استفاده شده است، که در ادامه این الگوریتم شرح داده می‌شود.

۲-۲- الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی

الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی از جمله الگوریتم‌های بهینه‌سازی هوشمند است که اولین بار در سال ۲۰۰۸ توسط دن سایمون[۳] ارائه شده است [۳۴, ۳۵]. این الگوریتم بر پایه تئوری جغرافیای زیستی است و به مطالعه توزیع جغرافیایی ارگانیزم‌های زیستی می‌پردازد. جان‌مایه اصلی این الگوریتم گرایش به انحصار است. مدل‌های ریاضی جغرافیای زیستی، چگونگی مهاجرت گونه‌ها از یک سکونت‌گاه به سکونت‌گاه دیگر، چگونگی ظهور یک گونه جدید و نحوه انقراض یک گونه را تشریح می‌کنند [۳۶, ۳۷]. مناطق جغرافیایی که مکان مناسبی برای سکونت گونه‌های زیستی هستند، دارای شاخص شایستگی بالا می‌باشند [۳۸]، شاخص شایستگی می‌تواند به‌عنوان متغیر وابسته به زیستگاه در نظر گرفته شود. متغیرهایی که این شایستگی را شکل می‌دهند، متغیرهای شاخص شایستگی خوانده می‌شوند. این متغیرها می‌توانند به‌عنوان متغیرهای مستقل در نظر گرفته شوند [۳۹]. زمانی که جمعیت یک گونه در یک سکونت‌گاه با شاخص شایستگی بالا افزایش می‌یابد، برخی از اعضا مجبور به مهاجرت به سکونت‌گاه‌های با شاخص شایستگی پایین‌تر می‌شوند، در واقع با افزایش جمعیت و بالا بودن شاخص شایستگی، مهاجرت‌دهی سکونت‌گاه افزایش می‌یابد اما سکونت‌گاه‌های با شاخص شایستگی و جمعیت پایین‌تر تمایل به مهاجرت‌پذیری بیش‌تری دارند [۴۰-۴۲]؛ در شکل ۳ این رابطه نشان داده شده است.

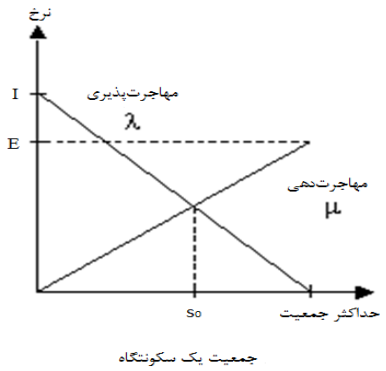

شکل ۳: رابطه بین مهاجرت‌دهی و مهاجرت‌پذیری در یک سکونت‌گاه [۴۳]

حال فرض کنید که یک مسئله و چندین راه‌حل داریم. مسئله می‌تواند در هر زمینه‌ای باشد و یک معیار قابل اندازه‌گیری برای شایستگی یک راه‌حل داریم. یک راه‌حل خوب شبیه یک سکونت‌گاه با شاخص شایستگی بالا است و یک راه‌حل ضعیف یک سکونت‌گاه با شاخص شایستگی پایین را نشان می‌دهد. به اشتراک گذاشتن اطلاعات در این روش با عملگر مهاجرت صورت می‌پذیرد. راه‌حل‌های با شاخص شایستگی بالا تمایل بیش‌تری برای به اشتراک گذاشتن خصوصیات با راه‌حل‌های با شاخص شایستگی ضعیف دارند. راه‌حل‌های ضعیف، مقدار زیادی خصوصیات جدید از راه‌حل‌های خوب دریافت می‌کنند. اضافه شدن این خصوصیات جدید، کیفیت این راه‌حل‌ها را بالا می‌برد. این روش حل مسئله، بهینه‌سازی مبتنی بر جغرافیای زیستی نامیده می‌شود که می‌تواند برای آموزش شبکه عصبی مصنوعی مورد استفاده قرار گیرد. در ادامه به بررسی پارامترهای این روش می‌پردازیم.

۲-۲-۱- نحوه مهاجرت

همان گونه که گفته شد، با افزایش جمعیت در یک سکونت‌گاه فرآیند مهاجرت اتفاق می‌افتد. در مسائل کاربردی، نحوه مهاجرت برای مسائل گسسته و پیوسته متفاوت است. برای توضیح بیش‌تر در این‌باره، دو سکونت‌گاه فرضی را مطابق شکل ۴ در نظر می‌گیریم؛ اگر بردار X_j برای توصیف موقعیت j و بردار X_i برای توصیف موقعیت i به صورت زیر تعریف شوند؛

$$X_j = (X_{j1}, X_{jn}) \quad (۵)$$

$$X_i = (X_{i1}, X_{in}) \quad (۶)$$

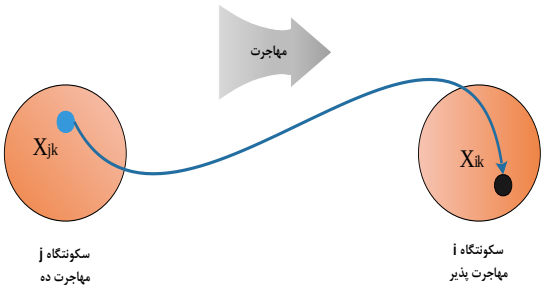

شکل ۴: دو سکونت‌گاه فرضی

X_{jk} مؤلفه kام از سکونت‌گاه j و X_{ik} مؤلفه kام از سکونت‌گاه i می‌باشند. مطابق شکل فوق مهاجرت از سکونت‌گاه j به i انجام می‌شود. به عبارتی گونه X_{jk} می‌خواهد به موقعیت X_{ik} منتقل شود، مقدار X_{ik} جدید بسته به نوع مسئله متفاوت است. برای مسائل گسسته مانند اعداد صحیح، مسائل باینری و غیره مقدار مؤلفه kام از سکونت‌گاه i بعد از عمل مهاجرت X_{ik}^{new} است که از رابطه زیر به دست می‌آید [۴۴]:

$$X_{ik}^{new} = X_{jk} \quad (۷)$$

اما برای مسائل پیوسته مانند اعداد حقیقی مقدار مؤلفه kام از سکونت‌گاه i بعد از عمل مهاجرت X_{ik}^{new} است که از رابطه زیر به دست می‌آید:

$$X_{ik}^{new} = X_{ik}^{old} + \alpha_k \left(X_{jk} - X_{ik}^{old} \right) \quad (۸)$$

که در رابطه بالا α_k معمولاً ضریبی بین صفر تا یک است.

۲-۲-۲- جهش

جهش[۴] یک تغییر ژنتیکی است که صفات زیستی بعضی از افراد یک گونه را تغییر می‌دهد [۴۵]. در الگوریتم مبتنی بر جغرافیای زیستی بعد از مهاجرت، می‌تواند جهش یا تغییرات تصادفی رخ دهد؛ که در مسائل گسسته و پیوسته قابل تعریف است [۴۶]. برای بررسی جهش در فضای گسسته، فرض می‌کنیم بردار X_i برای توصیف سکونت‌گاه i به صورت رابطه زیر تعریف شود:

$$X_i = \left(X_{i1}, \ldots, X_{ik}, \ldots, X_{in} \right) \quad (۹)$$

که X_{ik} مؤلفه kام از سکونت‌گاه i است که به‌عنوان جمله عمومی در نظر گرفته می‌شود و جهش روی آن اعمال می‌شود. اگر مجموعه همه مقادیر ممکن برای X_{ik} با A_k نمایش داده شود آنگاه، مؤلفه k ام جدید از سکونت‌گاه i بعد از جهش به صورت زیر تعریف می‌شود:

$$X_{ik}^{new} = A_k - \left\{ X_{ik}^{old} \right\} \quad (۱۰)$$

و در یک حالت خاص برای مسائل باینری از رابطه زیر به دست می‌آید [۴۷]:

$$X_{ik}^{new} = 1 = \left\{ X_{ik}^{old} \right\} \quad (۱۱)$$

اما برای بررسی جهش در فضای پیوسته، به علت این‌که حذف یک نقطه از یک بازه امکان‌پذیر نیست، برای یافتن X_{ik}^{new} باید از توزیع احتمالات استفاده کنیم. اگر X_{ik}، متعلق به بازه X_{min} تا X_{max} باشد آنگاه از سه روش زیر می‌توان X_{ik} جدید بعد از اعمال جهش را به دست آورد:

$$X_{ik}^{new} \approx U\left(X_{\min}, X_{\max} \right) \quad (۱۲)$$

$$X_{ik}^{new} \approx N\left(X_{ik} - \Delta, X_{ik} + \Delta \right) \quad (۱۳)$$

$$X_{ik}^{new} \approx N\left(X_{ik}, \sigma^2 \right) \quad (۱۴)$$

که U توزیع یکنواخت، N توزیع نرمال و Δ و σ پارامترهایی متناسب با عرض فضا $\left(X_{\max} - X_{\min} \right)$ هستند.

۲-۲-۳- مراحل طراحی الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی

۱) ابتدا مجموعه‌ای از سکونت‌گاه‌های تصادفی (جمعیت اولیه) تولید، ارزیابی و مرتب می‌شوند.
۲) نرخ‌های مهاجرت‌دهی و مهاجرت‌پذیری تعیین می‌شوند.
۳) به ازای هر سکونت‌گاه مانند i مراحل ۴ تا ۸ تکرار می‌شوند.
۴) به ازای هر متغیر مانند k در سکونت‌گاه i، مراحل ۵ تا ۸ انجام می‌شوند.
۵) با احتمال λ_i در X_{ik} تغییرات طبق مراحل ۶ تا ۸ اعمال می‌شوند.
۶) مبدأ مهاجرت با استفاده از مقادیر μها و به صورت تصادفی، تعیین می‌شود (نتیجه این مرحله یافتن j است).
۷) مهاجرت از X_{jk} به X_{ik} انجام می‌شود.
۸) با احتمال معین بر روی مؤلفه X_{ik} تغییرات تصادفی (جهش) اعمال می‌گردند.
۹) مجموعه پاسخ‌های جدید به دست آمده ارزیابی می‌شوند.
۱۰) جمعیت قدیمی و جمعیت ناشی از مهاجرت به روش‌های مختلفی با هم ترکیب می‌شوند و جمعیت مرحله بعد ایجاد می‌شود.
۱۱) در صورت برآورده نشدن شرایط خاتمه، الگوریتم به مرحله ۳ باز می‌گردد.

۳- ساختار داده‌ها (ورودی‌ها و خروجی) برای مدلسازی

جهت ارائه راهکار جدید برای پیش‌بینی گشتاور چرخشی موردنیاز برای انجام عملیات حفاری انحرافی در لایه‌های سنگی و اثبات توانایی روش ترکیبی مدل شبکه عصبی مصنوعی و روش بهینه‌سازی مبتنی بر جغرافیای زیستی، داده‌های استفاده شده در این مطالعه، از پروژه انتقال گاز طبیعی غرب به شرق چین قرض گرفته شده است (مرجع [۱۱]). در این مطالعه از نیروی محوری *(P)*، سرعت چرخش مته *(n)*، طول رشته حفاری *(L)*، تغییر زاویه کلی گمانه *(K_L)*، قطر *i*امین برقو *(D_i)*، سرعت جریان گل حفاری *(W)* و ویسکوزیته گل حفاری *(V)* به‌عنوان پارامترهای ورودی و گشتاور چرخشی *(M)* به‌عنوان پارامتر خروجی استفاده شده است. در این مطالعه تعداد کل داده‌ها ۸۴ داده است که از این تعداد به‌طور تصادفی، ۷۵ درصد داده‌ها (۶۳ داده) برای آموزش و ۲۵ درصد داده‌ها (۲۱

داده) برای آزمون انتخاب شـده اسـت. بخشـی از داده‌های اسـتفاده شده برای مدلسازی در جدول ۱ آورده شده است.

هم‌چنین توصیف آماری داده‌های به کار رفته در این مطالعه در جدول ۲ نشان داده شده است.

جدول ۱: بخشی از داده‌های استفاده شده برای مدلسازی [۱۱]

شماره داده	پارامترهای ورودی							پارامتر خروجی
	P $(KN\times10)$	N (r/min)	L (m)	K_L	D_i (mm)	W (L/min)	V (s)	M (KN.m)
۱	۱۱/۵	۱۵	۱۴۶/۰۱	۱/۱۷۷	۵۵۸/۸	۳۴۰۰	۶۲	۱۳
۲	۱۲	۱۵	۲۵۱/۲۷	۲/۳۶	۵۵۸/۸	۳۴۰۰	۶۵	۱۶/۵
۳	۷/۵	۱۵	۲۲۰/۴۷	۱/۸۷	۹۱۴/۴	۳۴۰۰	۵۲	۱۹
۴	۱۹	۳۳	۳۳۵/۸۲	۲/۰۹	۵۵۸/۸	۲۲۶۰	۶۵	۲۶
۵	۱۰	۳۰	۳۳۷/۹۲	۲/۷۸	۷۶۲	۴۰۰۰	۸۲	۲۰
۶	۱۱	۱۸	۱۹۳/۸۱	۲/۰۶	۸۱۲/۸	۲۲۶۰	۴۷	۲۰
۷	۱۰	۴۰	۴۷۹/۹۶	۳/۰۸	۹۶۵/۲	۲۰۰۰	۷۵	۳۶
۸	۲	۴۰	۱۷۴/۲۴	۱/۵۵	۷۶۲	۶۰۰	۸	۴
۹	۲۴	۴۵	۲۳۱/۵۳	۲/۵۹	۹۶۵/۲	۶۰۰	۴۳	۱۸
۱۰	۲۶/۵	۴۰	۴۵۲/۰۶	۲/۲۹	۵۵۸/۸	۱۶۰۰	۶۲	۳۲/۵

جدول ۱: توصیف آماری داده‌های به کار رفته در این مطالعه

پارامتر	میانگین	مینیمم	ماکزیمم	انحراف معیار
P $(KN\times10)$	۱۳/۸۳	۲	۳۰/۵	۵/۷۴
N (r/min)	۳۱/۵۸	۱۵	۵۰	۱۲/۴۵
L (m)	۳۲۲/۵۶	۱۱۶/۶۸	۵۸۶/۰۶	۱۲۹/۸
K_L	۲/۴۱	۱/۰۸	۳/۵۳	۰/۵۴
D_i (mm)	۷۶۰/۷۹	۴۵۷/۲۰	۱۱۱۷/۶	۱۸۶/۴۳
W (L/min)	۲۲۳۳/۰۹	۵۰۰	۴۰۰۰	۱۰۳۹/۲۴
V (s)	۶۳/۵۱	۴۲	۸۸	۱۴/۲۱
M (KN.m)	۲۱/۰۱	۴	۴۰	۸/۰۶

۴- پیش پردازش داده‌ها و شاخص‌های آماری جهت ارزیابی عملکرد مدل

برای مدلسـازی و ورود داده‌ها، اکثراً لازم است که دامنه تغییرات داده‌ها مشـابه یکدیگر باشـند که در اصـطلاح این عمل را، نرمال‌سـازی داده‌ها می‌نامند. نرمال‌سازی داده‌ها در این مطالعه توسط رابطه زیر انجام گرفته است که این رابطه دامنه داده‌ها را در بازه [۰ ۱] قرار می‌دهد.

$$p_n = \frac{p - p_{\min}}{p_{\max} - p_{\min}} \qquad (۱۵)$$

که در آن: P_n داده نرمال شـده، p داده حقیقی، $p_{\min}$ کمینه داده حقیقی و $p_{\max}$ بیشینه داده حقیقی هستند.

هم‌چنین در این تحقیق برای ارزیـابی عملکرد مـدل، از دو شـاخص آماری اسـتفاده شده است که روابط مربوطه در جدول ۳ ارائه شده است.

جدول ۳: شاخص‌های آماری جهت ارزیابی عملکرد مدل

شاخص آماری		فرمول
ضریب تعیین	(۱۶)	$R^2 = 1 - \dfrac{\sum_{i=1}^{n}\left(y_i - y_i^{'}\right)^2}{\sum_{i=1}^{n} y_i^2 - \dfrac{\sum_{i=1}^{n} y_i^{'2}}{n}}$
میانگین مربعات خطا	(۱۷)	$MSE = \dfrac{1}{n}\sum_{i=1}^{n}\left(y_i - y_i^{'}\right)^2$

که در این روابط y_i مقدار اندازه‌گیری شده و $y_i^{'}$ مقدار پیش‌بینی شده است. لازم به توضیح است که معیار ضریب تعیین (R^2) نشان دهنده انطباق بین مقادیر اندازه‌گیری شده و پیش‌بینی شده است که بهترین حالت آنجایی است که مقدار آن یک باشد و اگر صفر باشد بدان معنی است که عملکرد مدل برای پیش‌بینی خیلی ضعیف است. معیار میانگین مربعات خطا (*MSE*) نیز بیانگر خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده است و هر چه مقدار آن کم‌تر باشد عملکرد مدل از اطمینان بیش‌تری برخوردار است.

۴-۱- نتایج حاصل از مدلسازی با روش ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی

همان‌طور که قبلاً هم اشاره شد در این مدلسازی از نیروی محوری، سرعت چرخش مته، طول رشته حفاری، تغییر زاویه کلی گمانه، قطر *i*امین برقو، سرعت جریان گل حفاری و ویسکوزیته گل حفاری به‌عنوان پارامترهای ورودی شبکه برای پیش‌بینی گشتاور چرخشی (به‌عنوان پارامتر خروجی شبکه) استفاده شده است (شکل ۶). تعداد کل داده‌ها ۸۴ داده است که از این تعداد به‌طور تصادفی، ۷۵ درصد داده‌ها (۶۳ داده) برای آموزش و ۲۵ درصد داده‌ها (۲۱ داده) برای آزمون انتخاب گردیده‌اند. در این تحقیق برای به روزرسانی و بهینه‌سازی وزن‌های شبکه در هنگام آموزش، از الگوریتم آموزش بهینه‌سازی مبتنی بر جغرافیای زیستی استفاده شده است. فلوچارت این مدل ترکیبی در شکل ۵ نشان داده شده است.

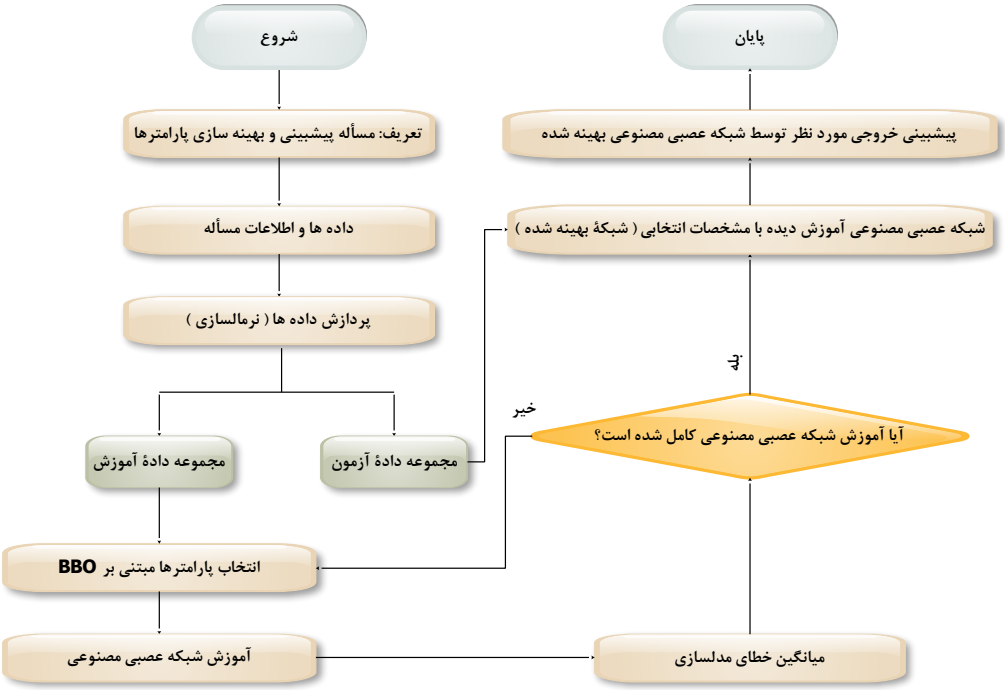

شکل ۵: فلوچارت مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی

در این تحقیق به کمک سعی و خطا، برای انجام بهترین مدلسازی، آنالیز حساسیت روی پارامترهای مدل از جمله تابع فعالسازی، تعداد تکرار، ساختار مدل (تعداد لایه‌های پنهان و تعداد نورون‌های هر لایه) در شبکه عصبی مصنوعی و تعداد سکونت‌گاه در الگوریتم مبتنی بر جغرافیای زیستی انجام شده است که بخشی از آنالیز حساسیت مدل ترکیبی به کار رفته در جدول ۴ نشان داده شده است. همانطور که جدول ۴ نشان می‌دهد با انجام آنالیز حساسیت، ساختار بهینه مدل مشخص (شکل ۶) و با استفاده از آن، می‌توان گشتاور چرخشی را در محدوده مورد مطالعه پیش‌بینی نمود. همچنین مقادیر پارامترهای استفاده شده برای الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی در جدول ۵ آورده شده است. شکل ۷ و شکل ۸ همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده در مجموعه داده‌های آموزش و آزمون را نشان می‌دهند. بعلاوه مقایسه بین مقادیر اندازه‌گیری شده و پیش‌بینی شده گشتاور چرخشی توسط مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی در مراحل

آزمون و آموزش در شکل‌های ۹ و ۱۰ نشان داده شده است. نتایج حاکی از آن است که این مدل قابلیت بالایی در برآورد گشـتاور چرخشی با استفاده از مجموعه پارامترهای ورودی ذکر شـده را دارد و می‌تواند برای پروژه‌های دیگر با شـرایط مشابه، به‌طور مطلوبی مورد استفاده قرار گیرد.

جدول ۴: بخشی از آنالیز حساسیت مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم مبتنی بر جغرافیای زیستی

ساختار مدل	توابع فعالسازی	تکرار الگوریتم	تعداد سکونت‌گاه‌ها	R^2_{Train}	MSE_{Train}	R^2_{Test}	MSE_{Test}
۷-۵-۸-۱	log-log-log	۱۰۰	۲۰۰	۰/۹۲۴۶	۰/۰۱۴۲	۰/۱۳۱۹	۰/۰۶۶۷
۷-۴-۴-۱	tan-log-log	۱۰۰	۴۰۰	۰/۶۲۹۵	۰/۰۲۲۴	۰/۵۵۲۰	۰/۰۱۲۴
۷-۹-۱	log-tan	۲۰۰	۴۰۰	۰/۷۱۳۵	۰/۰۱۶۹	۰/۳۸۶۳	۰/۰۵۶۴
۷-۳-۱	tan-log	۲۰۰	۲۰۰	۰/۷۳۶۹	۰/۰۱۱۵	۰/۴۲۱۴	۰/۰۸۸۵
۷-۵-۱	log-tan	۲۰۰	۴۰۰	۰/۸۶۰۶	۰/۰۰۹۱	۰/۴۱۶۸	۰/۰۳۶۲
۷-۸-۱	tan-log	۲۰۰	۴۰۰	۰/۸۱۹۸	۰/۰۱۶۱	۰/۴۵۱۳	۰/۰۳۵۵
۷-۸-۱	tan-log	۱۰۰	۵۰	۰/۷۳۹۱	۰/۰۱۶۴	۰/۵۸۸۸	۰/۰۵۹۴
۷-۶-۱	tan-log	۴۵۰	۵۰	۰/۷۰۰۸	۰/۰۲۹۰	۰/۶۷۷۰	۰/۰۴۰۱
۷-۱۰-۱	tan-log	۳۰۰	۵۰	۰/۷۰۲۱	۰/۰۵۱۵	۰/۷۰۷۵	۰/۰۶۴۵
۷-۸-۱	**tan-log**	**۵۰۰**	**۴۰**	**۰/۸۷۰۲**	**۰/۰۰۸۴**	**۰/۹۲۰۳**	**۰/۰۱۱۳**

جدول ۵: مقادیر پارامترهای الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی در حالت بهینه

پارامترها	تعریف	مقدار
N_{pop}	تعداد سکونت‌گاه‌ها (اندازه جمعیت)	۴۰
$MaxIt$	بیشترین تعداد تکرار مراحل الگوریتم	۵۰۰
$Alpha(\alpha_k)$	ضریب فرمول مهاجرت	۰/۹
$P_{Mutation}$	درصد جهش	۰/۱
$KeepRate$	درصدی از جمعیت قدیمی که به‌طور مستقیم به جمعیت جدید منتقل می‌شوند	۰/۴

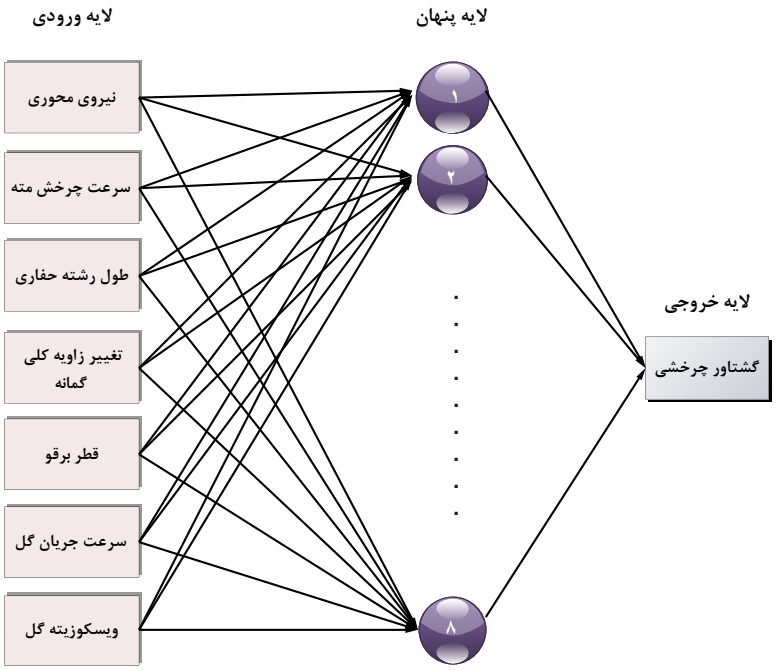

شکل ۶: ساختار مدل شبکه عصبی مصنوعی به کار رفته

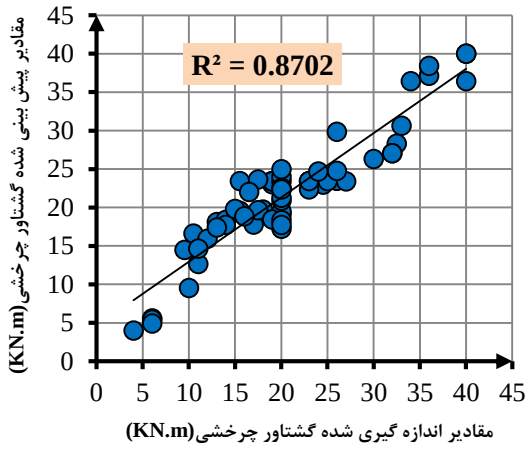

شکل ۷: همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده در مجموعه داده‌های آموزش

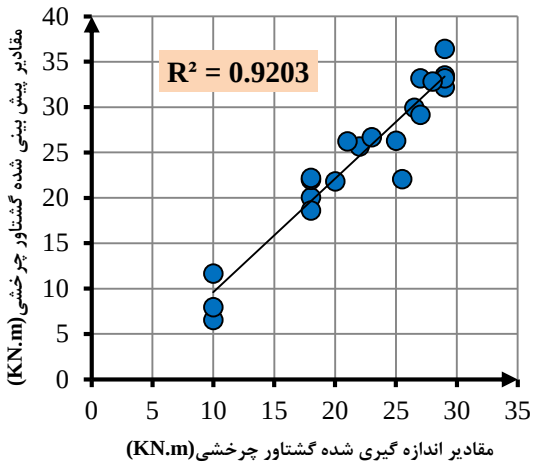

شکل ۸: همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده در مجموعه داده‌های آزمون

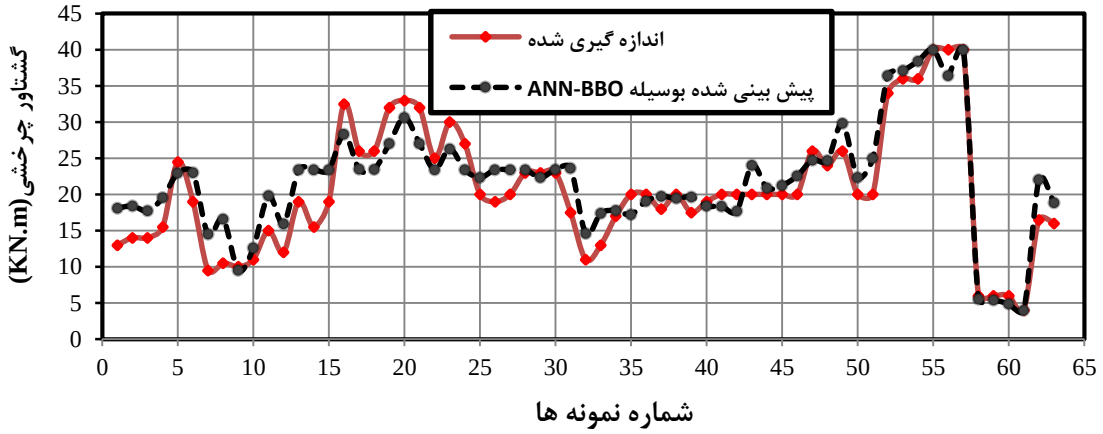

شکل ۹: مقایسه بین مقادیر اندازه‌گیری و پیش‌بینی شده برای مجموعه داده‌های آموزش

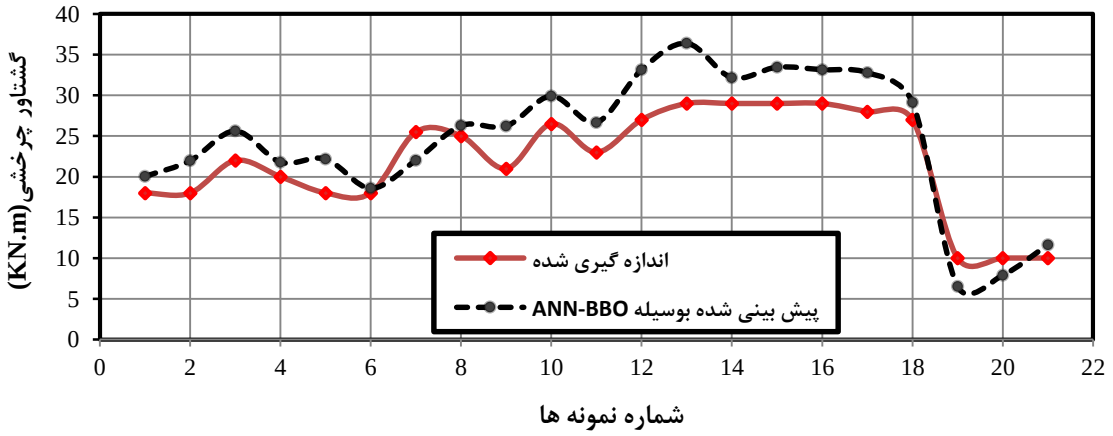

شکل ۱۰: مقایسه بین مقادیر اندازه‌گیری و پیش‌بینی شده برای مجموعه داده‌های آزمون

همچنین در این تحقیق نتایج به دست آمده از مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم مبتنی بر جغرافیای زیستی با نتایج لان و همکاران [۱۱] در سال ۲۰۱۰ در جهت به دست آوردن گشتاور چرخشی موردنیاز برای انجام عملیات حفاری انحرافی مورد مقایسه قرار گرفت. لان و همکاران [۱۱] برای مدلسازی از روش آنالیز رگرسیون غیرخطی چندگانه استفاده کرده‌اند که نتایج را به صورت رابطه زیر ارائه دادند:

$$M = 2.2803P^{0.4226}n^{0.3676}L^{0.2156}D_i^{0.5430} \times \times W^{0.3933}V^{-0.2348}\exp(-0.0329K_L) \quad (۱۸)$$

برای مقایسه از دو فاکتور ضریب تعیین و میانگین مربعات خطا استفاده شده که در جدول ۶ مقایسه بین نتایج دو مدل آورده شده است. نتایج جدول ۶ نشان می‌دهد که کاربرد مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی خطاها را به مقدار قابل‌توجهی کاهش می‌دهد و برای پیش‌بینی گشتاور چرخشی موردنیاز در انجام عملیات حفاری انحرافی روش بهتر و دقیق‌تری است.

جدول ۶: مقایسه بین نتایج دو مدل

روش	R^2_{Train}	MSE_{Train}	R^2_{Test}	MSE_{Test}
مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم مبتنی بر جغرافیای زیستی (پیشنهادی در این تحقیق)	۰/۸۷۰۲	۰/۰۰۸۴	۰/۹۲۰۳	۰/۰۱۱۳
رگرسیون غیرخطی چندگانه (پیشنهادی در مرجع [۱۱])	۰/۷۶۸۵	۰/۰۱۵۱	۰/۷۸۴۵	۰/۰۱۴۱

۵- نتیجه گیری

مقدار گشتاور چرخشی موردنیاز برای انجام عملیات حفاری انحرافی یکی از پارامترهای بسیار مهمی است که باید برای انجام عملیات برقوکاری و انتخاب نوع و سایز مناسب برقوها پیش‌بینی شود. در این تحقیق روش جدیدی بنام مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی برای این کار ارائه شده است. در راهکار ارائه شده، الگوریتم مبتنی بر جغرافیای زیستی برای بروز رسانی و بهینه‌سازی وزن‌های شبکه در هنگام آموزش استفاده شده است و این کار باعث شد که قابلیت شبکه به‌طور چشمگیری بهبود داده شود. پس از مدلسازی در جهت پیش‌بینی گشتاور چرخشی موردنیاز در انجام عملیات حفاری انحرافی، آنالیز عملکرد مدل بیانگر این است که نتایج مدل پیشنهادی از دقت بالایی برخوردار است. علاوه بر این مقایسه انجام شده بین استراتژی این مطالعه با یک مطالعه رگرسیونی، کارایی بالاتر مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی مبتنی بر جغرافیای زیستی را تأیید می‌کند. این مطالعه نشان می‌دهد مدل پیشنهادی می‌تواند به‌عنوان یک ابزار قدرتمند برای مدلسازی مسائل حفاری انحرافی مورد استفاده واقع شود.

مراجع

[1]. Ariaratnam ST, Harbin BC, Stauber RL. 2007. Modeling of annular fluid pressures in horizontal boring. Tunnelling and Underground Space Technology 22, pp. 610-619.

[2]. Hair JD. 1989. River crossing technology. Pipeline & Gas Journal 216, pp. 29-35.

[3]. Allouche EN. 2001. Implementing quality control in HDD projects—a North American prospective. Tunnelling and Underground Space Technology 16, pp. 3-12.

[4]. Najafi M. , 2005, Trenchless technology: pipeline and utility design, construction, and renewal: McGraw Hill Professional.

[5]. David A. , 2005, Horizontal Directional Drilling–Utility and Pipeline Applications. McGraw-Hill Company Inc., New York.

[6]. Bennett D, Ariaratnam ST, Consortium H. , 2008, Horizontal Directional Drilling: Good Practices Guidelines: North American Society for Trenchless Technology.

[7]. Lesso W, Chau M, Lesso W., 1999, Quantifying bottomhole assembly tendency using field directional drilling data and a finite element model. SPE/IADC drilling conference.

[8]. Polak MA, Lasheen A. 2001. Mechanical modelling for pipes in horizontal directional drilling. Tunnelling and Underground Space Technology 16, pp. 47-55.

[9]. Cheng E, Polak MA. 2007. Theoretical model for calculating pulling loads for pipes in horizontal directional drilling. Tunnelling and Underground Space Technology 22, pp. 633-643.

[10]. Ma B, Najafi M. 2008. Development and applications of trenchless technology in China. Tunnelling and Underground Space Technology 23, pp. 476-480.

[11]. Lan H, Ma B, Shu B, Wu Z. 2011. Prediction of rotational torque and design of reaming program using horizontal directional drilling in rock strata. Tunnelling and Underground Space Technology 26, pp. 415-421.

[12]. Maidla EE, Wojtanowicz AK. 1988. A field method for assessing borehole friction for directional well casing. Journal of Petroleum Science and Engineering 1, pp. 323-333.

[13]. Niżnik D, Gonet A. 2007. Identification of rotational torque and power in HDD. Archives of Mining Sciences 52, pp. 49-60.

[14]. Kecman V. , 2001, Learning and soft computing: support vector machines, neural networks, and fuzzy logic models: MIT press.

[15]. Rigol-Sanchez J, Chica-Olmo M, Abarca-Hernandez F. 2003. Artificial neural networks as a tool for mineral potential mapping with GIS. International Journal of Remote Sensing 24, pp. 1151-1156.

[16]. Brown WM, Gedeon T, Groves D, Barnes R. 2000. Artificial neural networks: a new method for mineral prospectivity mapping. Australian Journal of Earth Sciences 47, pp. 757-770.

[17]. Van der Baan M, Jutten C. 2000. Neural networks in geophysical applications. Geophysics 65, pp. 1032-1047.

[18]. Stange W. 1993. Using artificial neural networks for the control of grinding circuits. Minerals engineering 6, pp. 479-489.

[19]. Fattahi H. 2016. Application of improved support vector regression model for prediction of deformation modulus of a rock mass. Engineering with Computers pp. 1-14.

[20]. Fattahi H. 2016. Indirect estimation of deformation modulus of an in situ rock mass: an ANFIS model based on grid partitioning, fuzzy c-means clustering and subtractive clustering. Geosciences Journal pp. 1-10.

[21]. Fattahi H. 2016. A hybrid support vector regression with ant colony optimization algorithm in estimation of safety factor for circular failure slope. International Journal of Optimization in Civil Engineering 6, pp. 63-75.

[22]. Irani R, Nasimi R. 2011. Application of artificial bee colony-based neural network in bottom hole pressure prediction in underbalanced drilling. Journal of Petroleum Science and Engineering 78, pp. 6-12.

[23]. Aryafar A, Gholami R, Rooki R, Ardejani FD. 2012. Heavy metal pollution assessment using support vector machine in the Shur River, Sarcheshmeh copper mine, Iran. Environmental earth sciences 67, pp. 1191-1199.

[24]. Mohammadi L, Meech JA. 2013. AFRA–Heuristic expert system to assess the atmospheric risk of sulphide waste dumps. Journal of Loss Prevention in the Process Industries 26, pp. 261-271.

[25]. Pourjabbar A, Sârbu C, Kostarelos K, Einax J, Büchel G. 2014. Fuzzy hierarchical cross-clustering of data from abandoned mine site contaminated with heavy metals. Computers & Geosciences 72, pp. 122-133.

[26]. Mitchell TM. Machine learning. WCB. McGraw-Hill Boston, MA:, 1997.

[27]. Betrie GD, Sadiq R, Morin KA, Tesfamariam S. 2014. Uncertainty quantification and integration of machine learning techniques for predicting acid rock drainage chemistry: A probability bounds approach. Science of the Total Environment 490, pp. 182-190.

[28]. Dmuth H, Beale M. 2000. Neural Network Toolbox for use with Matlab, User's Guide. Natick, MA pp.

[29]. Thomas G, Wilmot T, Szatmary S, Simon D, Smith W. 2013. Evolutionary optimization of artificial neural networks for prosthetic knee control. Efficiency and Scalability Methods for Computational Intellect 7, pp. 142-161.

[30]. Bazdar H, Fattahi H, Ghadimi F. Hybrid ANN with Invasive Weed Optimization Algorithm, a New Technique for Prediction of Gold and Silver in Zarshuran Gold Deposit, Iran. Journal of Tethys: Vol 3, pp. 273-286.

[31]. Shen C, Wang L, Li Q. 2007. Optimization of injection molding process parameters using combination of artificial neural network and genetic algorithm method. Journal of Materials Processing Technology 183, pp. 412-418.

[32]. Sivagaminathan RK, Ramakrishnan S. 2007. A hybrid approach for feature subset selection using neural networks and ant colony optimization. Expert Systems with Applications 33, pp. 49-60.

[33]. Mirjalili S, Hashim SZM, Sardroudi HM. 2012. Training feedforward neural networks using hybrid

particle swarm optimization and gravitational search algorithm. Applied Mathematics and Computation 218, pp. 11125-11137.

[34]. Simon D. 2008. Biogeography-based optimization. Evolutionary Computation, IEEE Transactions on 12, pp. 702-713.

[35]. Simon D. 2011. A probabilistic analysis of a simplified biogeography-based optimization algorithm. Evolutionary computation 19, pp. 167-188.

[36]. Sinha A, Das S, Panigrahi BK. 2011. A linear state-space analysis of the migration model in an island biogeography system. Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on 41, pp. 331-337.

[37]. Simon D, Ergezer M, Du D, Rarick R. 2011. Markov models for biogeography-based optimization. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on 41, pp. 299-306.

[38]. Simon D. 2011. A dynamic system model of biogeography-based optimization. Applied Soft Computing 11, pp. 5652-5661.

[39]. Simon D, Omran MG, Clerc M. 2014. Linearized biogeography-based optimization with re-initialization and local search. Information Sciences 267, pp. 140-157.

[40]. Guo W, Chen M, Wang L, Ge S, Wu Q. Design of migration operators for biogeography-based optimization and markov analysis. Submitted to Information Sciences pp.

[41]. Guo W, Wang L, Wu Q. 2014. An analysis of the migration rates for biogeography-based optimization. Information Sciences 254, pp. 111-140.

[42]. Ma H. 2010. An analysis of the equilibrium of migration models for biogeography-based optimization. Information Sciences 180, pp. 3444-3464.

[43]. MacArthur R, Wilson E. 1967. The theory of biogeography. Princeton University Press, New Jersey pp. 19-67.

[44]. Ma H, Simon D, Fei M. 2014. On the convergence of biogeography-based optimization for binary problems. Mathematical Problems in Engineering 2014, pp.

[45]. Guo W, Wang L, Wu Q, Ge SS, Ren H. Drift Analysis of Mutation for Biogeography-Based Optimization. pp.

[46]. Gong W, Cai Z, Ling CX, Li H. 2010. A real-coded biogeography-based optimization with mutation. Applied Mathematics and Computation 216, pp. 2749-2758.

[47]. Ma H, Simon D. 2011. Analysis of migration models of biogeography-based optimization using Markov theory. Engineering Applications of Artificial Intelligence 24, pp. 1052-1060.

1-Artificial Neural Network (ANN)
2-Bio-geography Based Optimization (BBO)
3-Dan Simon
4- Mutation