

Magnetic Data Inversion Optimization Using the Mountain Gazelle Optimization Algorithm: A Case Study of 2D Dipping Dykes

Reza Tushmalani 

1. Faculty of Skills and Entrepreneurship, Rasht Branch, Islamic Azad University, Rasht, Iran. E-mail: Creativeclient2@gmail.com

Article Info

Article type:
Research Article

Article history:
Received 19 May 2025
Accepted 31 August 2025

Keywords:
Mountain Gazelle
Optimization Algorithm,
Random Forest, Dipping
Dykes, Magnetic Data
Inversion Optimization.

ABSTRACT

Inversion of magnetic data to characterise geological structures, such as dikes, is a fundamental challenge in engineering geophysics due to its highly non-linear and ill-posed nature, necessitating robust optimization methods. This study introduces and evaluates for the first time, the Mountain Gazelle Optimizer (MGO) for the first time, examining its efficiency and potential as an effective solution to this problem. The MGO algorithm is designed to find the global optimum by intelligently balancing exploration and exploitation within the parameter space. The performance of the MGO was assessed by comparing it with two distinct approaches: a powerful machine learning algorithm called Random Forest (RF), and a classic processing-estimation method based on Reduction to the Pole (RTP). Evaluations were conducted on synthetic data (with noise levels ranging from 0% to 20%) as well as on real field data from the Gansu iron deposit in China. The results clearly demonstrated the superiority of MGO in all scenarios. Not only did the algorithm exhibit greater stability against noise than RF, it also, achieved a Root Mean Square Error (RMSE) of 0.48 in the real data case study, which was significantly lower than the error achieved by the classic method (0.88). Furthermore, the parameters estimated by MGO showed better alignment with the geological information from existing drilling data in the area. This study suggests that MGO's superiority obtained from its direct and global inversion approach. Ultimately, MGO is presented as an accurate and reliable tool for exploration and engineering applications.

Introduction

Magnetic data inversion is a crucial in geophysical exploration method used to identify subsurface structures such as dykes, faults, and mineral deposits. Among the algorithmic optimization techniques, Mountain Gazelle Optimization (MGO) is a novel method inspired by the optimization behaviours of mountain gazelles. Due to its global and local search capabilities, MGO is highly effective in converging to accurate solutions in complex geophysical problems.

This study examines, the application of MGO in the inversion of magnetic data generated by 2D dipping dyke-like structures. This algorithm minimizes the objective function in order to

estimate key parameters such as depth (z), half-width (w), magnetic susceptibility coefficient (K), dip angle (θ), and horizontal position (x_0). The performance of MGO is evaluated using both synthetic and real datasets, demonstrating its accuracy and reliability.

Methodology

This research involved generating synthetic magnetic datasets for both noise-free and noisy conditions (5%, 10%, 15%, and 20%) in order to evaluate the performance of the MGO algorithm. The initial parameters were set to $K = 750$ nT, $z = 8$ m, $x_0 = 0$, $w = 2$ m, and $\theta = 40^\circ$. Magnetic anomalies were calculated using standard

Cite this article: Tushmalani, R. (2025). Magnetic Data Inversion Optimization Using the Mountain Gazelle Optimization Algorithm: A Case Study of 2D Dipping Dykes. *Journal of Engineering Geology*, 19 (2), 271-289. <https://doi.org/10.22034/JEG.2025.19.2.1020351>



© The Author(s).

DOI: <https://doi.org/10.22034/JEG.2025.19.2.1020351>

Publisher: Kharazmi University.

equations, and MGO was employed to invert these data.

To compare performance, the Random Forest (RF) algorithm was also applied, and the results from both methods were analyzed. The parameter ranges for the inversion were configured as follows:

- z in the range [1, 50]
- w in the range [1, 10]
- θ in the range [0, 180]
- x_0 in the range [1, 10]

Discussion and Results

The results demonstrated that MGO is more accurate and stable than the Random Forest algorithm under various noise conditions. For noise-free synthetic data, MGO accurately converged on the correct parameters. In contrast,

the Random Forest algorithm was more sensitive to noise in some cases. Experiments using real data from the magnetite iron deposit in Gansu Province, China, also confirmed the success of MGO's ability to match observed data successfully.

Conclusion

This study confirmed that the Mountain Gazelle Optimization (MGO) algorithm is a powerful and effective method for the magnetic inversion of two-dimensional, dipping dyke-like structures. A comparison with the Random Forest algorithm also demonstrated the superiority of MGO in terms of accuracy and stability. Consequently, this method can be utilized in geophysical applications such as mineral exploration and identifying complex geological structures.



بهینه‌سازی و ارون‌سازی داده‌های مغناطیسی با استفاده از الگوریتم غزال کوهستان: مطالعه موردی دایک‌های دوبعدی

رضا توشمالانی[✉]

۱. دانشکده مهارت و کارآفرینی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. رایانامه: Creativeclient2@gmail.com

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۲/۲۹

تاریخ پذیرش: ۱۴۰۴/۰۶/۰۹

کلیدواژه‌ها:

الگوریتم بهینه‌سازی غزال کوهستان، جنگل تصادفی، دایک‌های دوبعدی، جنگل تصادفی (RF)، بهینه‌سازی و ارون‌سازی داده‌های مغناطیسی.

وارون‌سازی داده‌های مغناطیسی برای مشخصه‌یابی ساختارهای زمین‌شناسی مانند دایک‌ها، به دلیل ماهیت شدیداً غیرخطی و بدوضع (ill-posed)، یکی از چالش‌های اساسی در ژئوفیزیک مهندسی است که نیازمند روش‌های بهینه‌سازی قدرتمند است. این پژوهش برای نخستین بار، کارایی و پتانسیل الگوریتم بهینه‌سازی نوین غزال کوهستان (Mountain Gazelle Optimizer (MGO)) را به عنوان یک راهکار مؤثر برای حل این مسئله معرفی و ارزیابی می‌کند. این الگوریتم با ایجاد تعادل هوشمندانه بین اکتشاف و بهره‌برداری در فضای پارامترها، برای یافتن بهینه سراسری طراحی شده است. عملکرد MGO به صورت جامع و از طریق مقایسه با دو رویکرد متفاوت سنجیده شد: یک الگوریتم یادگیری ماشین قدرتمند، یعنی جنگل تصادفی ((Random Forest (RF))، و یک روش پردازشی-تخمینی کلاسیک مبتنی بر برگردان به قطب . ((Reduction to the Pole (RTP)) ارزیابی‌ها بر روی داده‌های مصنوعی (با سطوح نویز ۰٪ تا ۲۰٪) و همچنین داده‌های میدانی واقعی از کانسار آهن گانسو، چین، انجام گرفت. نتایج در تمامی سناریوها، برتری واضح MGO را به اثبات رساند. این الگوریتم نه تنها در برابر نویز پایداری بیشتری نسبت به RF نشان داد، بلکه در مطالعه موردی داده‌های واقعی، به خطای ریشه میانگین مربعات (RMSE) برابر با ۰/۴۸ دست یافت که به طور قابل توجهی کمتر از خطای روش کلاسیک (۰/۸۸) بود. مهم‌تر آنکه، پارامترهای تخمینی توسط MGO انطباق بیشتری با اطلاعات زمین‌شناسی حاصل از حفاری‌های موجود در منطقه داشتند. این مطالعه استدلال می‌کند که برتری MGO از رویکرد و ارون‌سازی مستقیم و یکپارچه آن نشأت می‌گیرد. در نهایت، MGO به عنوان ابزاری دقیق و قابل اعتماد برای کاربردهای اکتشافی و مهندسی معرفی می‌گردد.

مقدمه

مغناطیس‌سنجی، به دلیل حساسیت بالا به کانی‌های آهن‌دار موجود در دایک‌های ماگمایی، ابزاری کارآمد، سریع و غیر مخرب برای اکتشاف این عوارض پنهان محسوب می‌شوند. با این حال، چالش اصلی پس از برداشت داده‌ها، در فرآیند تفسیر و و ارون‌سازی آن‌ها نهفته است؛ فرآیندی که هدف آن، تبدیل ناهنجاری‌های مغناطیسی مشاهده شده به یک

شناسایی و مدل‌سازی دقیق ساختارهای زمین‌شناسی زیرسطحی مانند دایک‌ها، در شاخه‌های مهندسی عمران، معدن و مدیریت منابع آب از اهمیت حیاتی برخوردار است. این ساختارهای نفوذی به دلیل تفاوت در خواص فیزیکی با سنگ‌های اطراف، می‌توانند بر پایداری سازه‌ها، طراحی تونل‌ها و سدها، و مسیر جریان آب‌های زیرزمینی تأثیرگذار باشند. روش‌های ژئوفیزیکی، و در میان آن‌ها روش

استناد: توشمالانی، ر. (۱۴۰۴). بهینه‌سازی و ارون‌سازی داده‌های مغناطیسی با استفاده از الگوریتم غزال کوهستان: مطالعه موردی دایک‌های دوبعدی. مجله زمین شناسی مهندسی، ۱۹ (۲)، ۲۷۱-۲۸۹. <https://doi.org/10.22034/JEG.2025.19.2.1020351>



زمین‌شناسی کمک شایانی می‌کند (Tan and Bora, 2019). در سال‌های اخیر، مطالعات مقایسه‌ای نشان داده‌اند که عملکرد الگوریتم‌ها به ماهیت مسئله وابسته است و رویکردهای ترکیبی (Hybrid) که نقاط قوت الگوریتم‌های مختلف را با هم ادغام می‌کنند، اغلب به نتایج برتری دست می‌یابند (Karthik et al., 2024; Fouad et al., 2024; Tushmalani et al., 2024).

در این راستا، الگوریتم بهینه‌سازی غزال کوهستان (MGO) به عنوان یک روش نوین معرفی شده است که با الهام از رفتار اجتماعی حیوانات، مکانیزم‌های جدیدی برای حل مسائل بهینه‌سازی ارائه می‌دهد (Abdollahzadeh et al., 2022). مطالعات اولیه نشان داده‌اند که این الگوریتم به دلیل ساختار ساده و سرعت همگرایی بالا، پتانسیل ارائه عملکردی بهتر از روش‌های متداولی مانند الگوریتم ژنتیک را دارد (Khunkitti et al., 2023). با این حال، با وجود اینکه الگوریتم‌های مشابهی مانند بهینه‌ساز گرگ خاکستری در ژئوفیزیک به کار رفته‌اند، کاربرد و ارزیابی عملکرد MGO در مسئله مشخص و آرون‌سازی داده‌های مغناطیسی دایک‌ها، حوزه‌ای است که تاکنون کمتر به آن پرداخته شده و این مقاله به دنبال بررسی آن است.

نوآوری تحقیق

معرفی الگوریتم غزال کوهستان (MGO)

با وجود موفقیت الگوریتم‌های موجود، پژوهش برای یافتن روش‌های کارآمدتر با سرعت همگرایی بالاتر و دقت بیشتر همواره ادامه دارد. در این میان، الگوریتم بهینه‌سازی غزال کوهستان (Mountain Gazelle Optimizer - MGO)، یک الگوریتم فراابتکاری نوین است که با الهام از رفتار اجتماعی غزال‌ها، مکانیزم‌های هوشمندانه‌ای برای ایجاد تعادل بین اکتشاف (Exploration) و بهره‌برداری (Exploitation) در فضای جستجو ارائه می‌دهد

مدل زمین‌شناسی کمی (شامل پارامترهایی نظیر عمق، عرض، و شیب دایک) است.

مسئله و آرون‌سازی داده‌های مغناطیسی ذاتاً یک مسئله بهینه‌سازی غیرخطی، چندوجهی و بدوضع (ill-posed) است که اغلب دارای پاسخ‌های متعدد و غیر منحصراً به فرد می‌باشد. برای غلبه بر این چالش، الگوریتم‌های بهینه‌سازی فراابتکاری (متاهوریستیک) مانند الگوریتم ژنتیک (Genetic Algorithm) بهینه‌سازی ازدحام ذرات (Particle Swarm Optimization) به طور گسترده در دهه‌های اخیر به کار گرفته شده‌اند. این الگوریتم‌ها با توانایی جستجوی سراسری در فضای پارامترها، از گرفتار شدن در بهینه‌های محلی اجتناب کرده و به راه‌حل‌های قابل اعتمادی دست می‌یابند (Mirjalili et al., 2014; Tushmalani et al., 2024). و آرون‌سازی داده‌های مغناطیسی، به دلیل ماهیت غیرخطی و چندوجهی، یک چالش بهینه‌سازی پیچیده است. به همین دلیل، الگوریتم‌های فراابتکاری به ابزارهای استاندارد در این حوزه بدل شده‌اند. الگوریتم‌های کلاسیک مانند الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و بهینه‌سازی کلونی مورچه‌ها (Ant Colony Optimization) برای توانایی‌شان در کاوش فضاهای راه‌حل گسترده و یافتن راه‌حل‌های بهینه در زمان محاسباتی معقول شناخته شده‌اند (Mirjalili et al., 2014; El-Henawy and Abdelmegeed, 2018). انعطاف‌پذیری این الگوریتم‌ها، آن‌ها را برای طیف وسیعی از مسائل تفسیر داده‌های مغناطیسی مناسب می‌سازد (Gharehchopogh et al., 2022). تحقیقات نشان داده‌اند که موفقیت این الگوریتم‌ها در کاربردهای زمین‌شناسی، به توانایی آن‌ها در ایجاد تعادل مؤثر بین اکتشاف (جستجوی گسترده) و بهره‌برداری (پالایش راه‌حل) بستگی دارد (Çinar and Kandemir, 2021; Du, 2021). ماهیت تطبیقی آن‌ها نیز به مدیریت عدم قطعیت‌های ذاتی موجود در داده‌های

از طریق این ارزیابی چندجانبه، این پژوهش به دنبال اثبات MGO به عنوان یک ابزار قدرتمند، دقیق و قابل اعتماد برای کاربردهای مهندسی و اکتشافی مرتبط با تحلیل داده‌های مغناطیسی است.

روش‌شناسی تحقیق

در این پژوهش، برای حل مسئله وارون‌سازی داده‌های مغناطیسی و تخمین پارامترهای مدل دایک دو بعدی، از الگوریتم بهینه‌سازی غزال کوهستان (MGO) به عنوان روش اصلی استفاده شده است. به منظور ارزیابی کارایی و برتری این الگوریتم، نتایج آن با یک روش یادگیری ماشین قدرتمند، یعنی جنگل تصادفی و یک روش سنتی برگردان به قطب، مقایسه می‌گردد و فلوچارت این روش‌ها در زیر ارائه شده است.

الگوریتم بهینه‌سازی غزال کوهستان (MGO) برای وارون‌سازی مغناطیسی

الگوریتم بهینه‌سازی غزال کوهستان (MGO) یک الگوریتم فراابتکاری مبتنی بر جمعیت است که از رفتار اجتماعی غزال‌های کوهستانی در طبیعت الهام گرفته شده است (Abdollahzadeh et al., 2022). در چارچوب مسئله وارون‌سازی، هر «غزال» در جمعیت، یک راه‌حل بالقوه است که بردار پارامترهای مدل دایک را نمایندگی می‌کند. به عنوان مثال، یک غزال می‌تواند به صورت بردار $X = [d, w, M, \theta]$ تعریف شود که در آن:

d : عمق

w : عرض

M : شدت مغناطش

θ : زاویه شیب دایک

هدف الگوریتم، یافتن غزالی (بردار پارامتری) است که خطای بین داده‌های مغناطیسی مشاهده‌ای و داده‌های


(Abdollahzadeh et al., 2022). علی‌رغم پتانسیل بالای این الگوریتم در حل مسائل پیچیده مهندسی، کاربرد آن در حوزه وارون‌سازی داده‌های ژئوفیزیکی، به ویژه برای مدل‌سازی پارامتریک دایک‌ها، تاکنون مورد بررسی قرار نگرفته و این شکاف تحقیقاتی، انگیزه اصلی پژوهش حاضر است. این مقاله استدلال می‌کند که الگوریتم بهینه‌سازی غزال کوهستان (MGO) به دلیل رویکرد وارون‌سازی مستقیم و یکپارچه‌اش، برتری قابل توجهی نسبت به روش‌های موجود (شامل الگوریتم‌های یادگیری ماشین مانند جنگل تصادفی و روش‌های کلاسیک مانند برگردان به قطب) در وارون‌سازی داده‌های مغناطیسی دایک‌ها دارد و به عنوان ابزاری دقیق، قابل اعتماد و کارآمد برای کاربردهای اکتشافی و مهندسی معرفی می‌شود.

اهداف و رویکرد مطالعه

این مقاله با هدف پر کردن شکاف مذکور، برای نخستین بار کاربرد الگوریتم MGO را در وارون‌سازی داده‌های مغناطیسی برای مشخصه‌یابی دایک‌های دوبعدی معرفی و ارزیابی می‌کند. اهداف مشخص این مطالعه عبارتند از:

- معرفی و پیاده‌سازی الگوریتم MGO برای حل مسئله وارون‌سازی پارامترهای دایک.
- ارزیابی کمی عملکرد و دقت MGO از طریق مقایسه با یک مدل یادگیری ماشین قدرتمند، یعنی جنگل تصادفی (Random Forest - RF) و یک روش سنتی برگردان به قطب.
- سنجش پایداری و استحکام الگوریتم در برابر نویز با استفاده از داده‌های مصنوعی در سطوح مختلف آلودگی.
- اعتبارسنجی عملیاتی و نمایش کارایی روش بر روی داده‌های مغناطیسی میدانی واقعی از یک کانسار آهن شناخته‌شده.

محاسبه شده از مدل را به حداقل برساند. شکل ۱ فلوچارت الگوریتم‌های بهینه‌ساز غزال کوهستان، یادگیری ماشین و برگردان به قطب را نشان می‌دهد.



شکل ۱. فلوچارت الگوریتم‌های بهینه‌ساز: a) غزال کوهستان، b) جنگل تصادفی، c) برگردان به قطب

Fig. 1. Flowcharts of Optimization Algorithms: a) Mountain Gazelle b) Random forest c) Reduction to the Pole

گسترده در فضای جستجو است. نرهای جوان برای یافتن منابع غذایی بهتر (راه‌حل‌های بهتر) حرکت‌های بلند و تصادفی انجام می‌دهند. این حرکت با استفاده از پرواز لوی (Lévy Flight) مدل‌سازی می‌شود که به الگوریتم اجازه می‌دهد از بهینه‌های محلی فرار کند (Khunkitti et al., 2023).

معادله حرکت در این فاز به صورت زیر است:

$$X_{\text{new}} = X_{\text{current}} + S \otimes \text{Lévy}(d) \quad (1)$$

فرمول‌بندی ریاضی و فرآیند بهینه‌سازی

فرآیند MGO با ایجاد یک جمعیت اولیه از غزال‌ها (راه‌حل‌ها) به صورت تصادفی در فضای جستجو آغاز می‌شود. سپس، در هر تکرار، موقعیت غزال‌ها بر اساس چهار مکانیزم اصلی رفتار آن‌ها به‌روزرسانی می‌شود:

- گله‌های نرهای جوان (Bachelor Male Herds - BMH): این فاز مسئول اکتشاف (Exploration)

تابع برازش (Fitness Function) در هر تکرار برای هر غزال محاسبه می‌شود که در این پژوهش، از ریشه میانگین مربعات خطا (RMSE) بین داده‌های مغناطیسی مشاهده‌ای (d_{obs}) و داده‌های محاسبه‌شده (d_{calc}) استفاده شده است:

$$\text{Fitness} = \text{RMSE} = \sqrt{\left(\frac{1}{N}\right) * \sum (d_{obs} - d_{calc}(X))^2} \quad (۳)$$

الگوریتم تا رسیدن به معیار توقف (مانند حداکثر تعداد تکرار یا عدم بهبود قابل توجه در بهترین راه‌حل) ادامه می‌یابد. ساختار ساده و بدون پارامترهای تنظیم پیچیده، MGO را به یک ابزار کارآمد برای مسائل وارون‌سازی ژئوفیزیکی تبدیل کرده است.

الگوریتم جنگل تصادفی (Random Forest)

به منظور سنجش عملکرد روش پیشنهادی MGO، از الگوریتم جنگل تصادفی (Random Forest) به عنوان یک مدل رگرسیون قدرتمند برای مقایسه استفاده شد. جنگل تصادفی، که توسط بریمن (Breiman, 2001) معرفی شد، یک تکنیک یادگیری جمعی است که با ساخت تعداد زیادی درخت تصمیم و تجمع نتایج آن‌ها، پیش‌بینی‌های دقیقی ارائه می‌دهد و از بیش‌برازش جلوگیری می‌کند (Cutler and Zhao, 2001).

کاربرد جنگل تصادفی در تخمین پارامترهای دایک

در این مطالعه، جنگل تصادفی برای حل مسئله رگرسیون آموزش داده شد. فرآیند کار به شرح زیر است:

- تولید داده‌های آموزشی: یک مجموعه داده مصنوعی بزرگ شامل هزاران مدل دایک با پارامترهای تصادفی (d, w, M, θ) تولید شد. برای هر مدل، پاسخ مغناطیسی آن (d_{calc}) محاسبه گردید.

که در آن $X_{current}$ موقعیت فعلی غزال، S بردار گام تصادفی و $Lévy(d)$ بردار اعداد تصادفی حاصل از توزیع لوی است که گام‌های بزرگ و ناگهانی را ممکن می‌سازد.

- گله‌های مادری (Maternity Herds - MH): این بخش مسئولیت ایجاد تعادل بین اکتشاف و بهره‌برداری (Exploitation) را بر عهده دارد. غزال‌ها در این گله‌ها در نزدیکی رهبر گله (یک راه‌حل نسبتاً خوب) حرکت می‌کنند و در عین حال فضای اطراف را نیز جستجو می‌نمایند. این مکانیزم به همگرایی تدریجی به سمت مناطق بهینه کمک می‌کند.

- نرهای منفرد سرزمینی (Territorial Solitary - TSM): این فاز کاملاً بر بهره‌برداری و پالایش راه‌حل‌های برتر متمرکز است. نرهای قدرتمند و مسلط (بهترین راه‌حل‌های یافت شده تاکنون) در یک قلمرو مشخص حرکت‌های کوچکی انجام می‌دهند تا موقعیت خود را بهبود بخشند. این حرکت به صورت یک راه رفتن تصادفی در اطراف بهترین راه‌حل کلی (X_{best}) مدل‌سازی می‌شود:

$$X_{new} = X_{best} - r * ((X_{best} - X_{current}) / (f_{best} - f_{current} + \epsilon)) \quad (۲)$$

در این معادله، r یک عدد تصادفی، f مقدار تابع برازش (میزان خطا) و ϵ یک عدد کوچک برای جلوگیری از تقسیم بر صفر است. این حرکت تضمین می‌کند که الگوریتم به دقت در اطراف بهترین پاسخ یافت شده جستجو کند.

- مهاجرت برای جستجوی غذا (Migration to Search for Food - MSF): این مکانیزم با جایگزین کردن بدترین راه‌حل‌ها با راه‌حل‌های جدید و تصادفی، از رکود الگوریتم و گیر افتادن در بهینه‌های محلی جلوگیری کرده و تنوع جمعیت را حفظ می‌کند.

پیچیده را مدیریت می‌کند (Rodriguez-Galiano et al., 2012).

مدل‌سازی مستقیم پاسخ مغناطیسی دایک

پاسخ میدان مغناطیسی کل ($M(x_i)$) ناشی از یک ساختار دایک شیب‌دار دوبعدی با مغناطیس‌پذیری یکنواخت (شکل ۱)، در هر ایستگاه مشاهده (x_i) در امتداد پروفیل، با استفاده از معادله تحلیلی زیر محاسبه می‌شود:

$$M(x_i) = K * [\sin(\theta) * \{ \operatorname{atan}((x_i - x_o + w)/z) - \operatorname{atan}((x_i - x_o - w)/z) \} + \cos(\theta) / 2 * \{ \ln(((x_i - x_o + w)^2 + z^2) / ((x_i - x_o - w)^2 + z^2)) \}] \quad (4)$$

که در آن پارامترهای مدل عبارتند از:

K : ضریب دامنه مؤثر که به مغناطیس‌پذیری وابسته است (بر حسب nT)

z : عمق تا سطح فوقانی دایک (متر)

w : نیمه عرض دایک (متر)

θ : زاویه شیب مؤثر دایک (درجه)

x_o : موقعیت افقی مرکز دایک (متر)


این معادله مبنای فرآیند وارون‌سازی است؛ به طوری که الگوریتم‌های بهینه‌سازی با تغییر پارامترهای مدل (K, z, w, θ, x_o) تلاش می‌کنند تا پاسخ محاسبه‌شده (M_{calc}) را بر پاسخ مشاهده‌شده (M_{obs}) منطبق کرده و خطای بین این دو را به حداقل برسانند.

• تعریف ویژگی‌ها و هدف: در مدل جنگل تصادفی، مقادیر پاسخ مغناطیسی در ایستگاه‌های مختلف به عنوان ویژگی‌های ورودی (Input Features) و پارامترهای مدل دایک (d, w, M, θ) به عنوان متغیرهای هدف (Target Variables) در نظر گرفته شدند.

• آموزش مدل: الگوریتم با استفاده از نمونه‌گیری بوت‌استرپ (Bootstrap Sampling)، زیرمجموعه‌هایی از داده‌های آموزشی را انتخاب کرده و بر روی هر کدام یک درخت تصمیم مستقل می‌سازد (Liaw and Wiener, 2002). در هر گره از درخت، تنها زیرمجموعه‌ای تصادفی از ویژگی‌ها برای تقسیم‌بندی در نظر گرفته می‌شود که این کار تنوع مدل را افزایش می‌دهد (Geurts et al., 2006).

• پیش‌بینی پارامترها: پس از آموزش، مدل جنگل تصادفی قادر است با دریافت یک پروفیل داده مغناطیسی (مشاهده‌ای یا مصنوعی)، پارامترهای دایک مربوط به آن را با میانگین‌گیری از خروجی تمام درختان، تخمین بزند.

این پژوهش از جنگل تصادفی برای ارزیابی دقت و پایداری الگوریتم بهینه‌ساز غزال کوهستان استفاده می‌کند، زیرا این روش به خوبی داده‌های نویزی و روابط غیرخطی



Dipping Dike Model

شکل ۲. نمودار شماتیک از یک ساختار زمین‌شناسی دایک مانند دوبعدی با ضریب مغناطیس پذیری یکنواخت و پارامترهای آن.
Fig. 2. Schematic diagram of a two-dimensional dike-like geological structure with uniform magnetic susceptibility and its parameters.

تعریف $x_o: [0, 10]$ و $w: [1, 10]$, $\theta: [0, 180]$ $z: [1, 50]$,

شدند.

نتایج و بحث

برای ارزیابی جامع عملکرد، دقت و پایداری الگوریتم پیشنهادی غزال کوهستان (MGO)، یک سری آزمایش‌ها بر روی داده‌های مصنوعی و یک مطالعه موردی بر روی داده‌های میدانی واقعی انجام شد. نتایج به دست آمده به طور مستقیم با الگوریتم جنگل تصادفی (RF) به عنوان یک روش مقایسه‌ای قدرتمند، سنجیده شد.

اعتبارسنجی با مدل مصنوعی

یک مدل دایک مصنوعی با پارامترهای مشخص و از پیش تعریف شده ($K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_o = 0 \text{ m}$, $2w = 4 \text{ m}$ یا 2 m و $\theta = 40^\circ$) ایجاد شد. پاسخ مغناطیسی این مدل بر روی یک پروفیل ۸۰ متری محاسبه گردید (منحنی "M" در شکل ۲). سپس دو الگوریتم MGO و RF برای وارون‌سازی این داده‌ها و تخمین پارامترهای مدل به کار گرفته شدند. بازه‌های جستجو برای پارامترها به صورت


تحلیل عملکرد در حالت بدون نویز

نتایج وارون‌سازی داده‌های بدون نویز در جدول ۱ و شکل ۳ ارائه شده است.

- تحلیل عملکرد MGO: الگوریتم MGO با موفقیت توانست پارامترهای مدل را با دقت بسیار بالایی بازایی کند. مقادیر تخمینی برای عرض کامل ($2w \approx 3/98 \text{ m}$)، زاویه ($\theta \approx 39/42^\circ$) و عمق ($z \approx 8/81 \text{ m}$) بسیار به مقادیر واقعی نزدیک هستند. خطای ریشه میانگین مربعات (RMSE) بسیار پایین ($2/72$)، نشان‌دهنده انطباق فوق‌العاده منحنی محاسبه‌شده (M') بر منحنی مشاهده‌شده (M) است (شکل ۲.۱).
- تحلیل عملکرد RF: در مقابل، الگوریتم جنگل تصادفی در تخمین پارامترها عملکرد بسیار ضعیفی داشت. مقادیر تخمینی به ویژه برای عمق ($z = 15/76 \text{ m}$) و موقعیت ($x_o = 6/68 \text{ m}$) انحراف بسیار زیادی از مقادیر واقعی دارند. RMSE بسیار بالای ($145/28$).

است که یک پروفیل منفرد، ویژگی‌های کافی برای آموزش مؤثر مدل پیچیده RF را فراهم نمی‌کند.

که بیش از ۵۰ برابر خطای MGO است، نشان‌دهنده عدم توانایی مدل RF در برازش صحیح داده‌ها در این حالت است (شکل ۲. b). این ضعف احتمالاً به این دلیل



شکل ۳. ناهنجاری مغناطیسی کل یک ساختار زمین‌شناسی دایک مانند بدون نویز با پارامترهای $K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_0 = 0$, $2w = 4 \text{ m}$, و $\theta = 40^\circ$. A و B به ترتیب نشان‌دهنده ناهنجاری‌های اندازه‌گیری شده (M) و محاسبه شده (M') در پنل بالا، و همچنین (a) غزال کوهستان (MGO) و (b) جنگل تصادفی (RF).

Fig. 3. Total magnetic anomaly of a noise-free dike-like geological structure with parameters: $K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_0 = 0$, $2w = 4 \text{ m}$, and $\theta = 40^\circ$. A and B represent the measured (M) and calculated (M') anomalies in the upper panel, respectively, while (a) Mountain Gazelle Optimizer (MGO) and (b) Random Forest (RF)

جدول ۱ نتایج وارون‌سازی مدل مصنوعی با الگوریتم

MGO و جدول ۲ نتایج وارون‌سازی مدل مصنوعی با

الگوریتم RF در سطوح مختلف نویز در زیر آمده است.

جدول ۱. نتایج به دست آمده از هر دو روش MGO

Table 1. Inversion results of the MGO algorithm for the synthetic model at different noise levels.

سطح نویز (%)	w	theta	x0	z	RMSE
0	3/9841	39/4266	1	8/8097	2/7183
0/05	3/8556	40/5237	1	8/5138	7/0474
0/1	3/9902	39/5597	1/2333	9/1094	4/5993
0/15	3/3097	40/7856	4/9875	9/2566	25/9889
0/2	3/9343	39/8044	1	8/6588	3/7618

جدول ۲. نتایج به دست آمده از هر دو روش Random Forest

Table 2. Inversion results of the Random Forest (RF) algorithm for the synthetic model at different noise levels.

سطح نویز (/.)	w	θ	x0	z	RMSE
0	7/18	40/85	6/68	15/76	145/28
0/05	3/73	42/32	5/61	13/63	65/35
0/1	3/08	51/75	1/77	6/4	63/54
0/15	7/38	33/34	5/62	18/99	112/7
0/2	3/77	52/69	3/27	11/46	57/59

تحلیل پایداری در برابر نویز

برای ارزیابی پایداری الگوریتم‌ها، نویز گاوسی با سطوح ۵٪، ۱۰٪، ۱۵٪ و ۲۰٪ به داده‌های مصنوعی اضافه شد. نتایج در جداول ۱ و ۲ و شکل‌های ۴ و ۵ خلاصه شده‌اند.


- پایداری MGO: نتایج نشان می‌دهد که MGO پایداری بالایی در برابر نویز دارد. با افزایش سطح نویز، خطای RMSE به طور منطقی افزایش می‌یابد، اما الگوریتم همچنان پارامترها را با دقت قابل قبولی تخمین می‌زند. حتی در سطح نویز ۲۰٪، مقادیر تخمینی همچنان به واقعیت نزدیک بوده و RMSE برابر با 3.76 است که نشان‌دهنده یک برازش بسیار خوب است. شکل 4 به وضوح نشان می‌دهد که

منحنی‌های محاسبه شده حتی در حضور نویز شدید،

شکل کلی ناهنجاری را به خوبی دنبال می‌کنند.


- پایداری RF: در مقابل، RF حساسیت بسیار بالایی به نویز نشان می‌دهد. خطای RMSE در تمام سطوح نویز بسیار بالا باقی می‌ماند و پارامترهای تخمینی نوسانات شدیدی دارند و قابل اعتماد نیستند. شکل 5 این بی‌ثباتی را به تصویر می‌کشد، جایی که منحنی‌های محاسبه شده توسط RF تطابق ضعیفی با داده‌های نویزی دارند.


این تحلیل نشان می‌دهد که MGO نه تنها دقیق‌تر است، بلکه برای کاربردهای عملی که در آن داده‌ها همیشه با نویز همراه هستند، ابزار بسیار پایدارتر و قابل اعتمادتری است.



شکل ۴. ناهنجاری مغناطیسی کل یک ساختار زمین‌شناسی دایک مانند بدون نویز با پارامترهای $K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_0 = 0$, $2w = 4 \text{ m}$ و $\theta = 40^\circ$. B و $\theta = 40^\circ$. به ترتیب نشان‌دهنده ناهنجاری‌های اندازه‌گیری شده (M) و محاسبه شده (M') در پنل بالا هستند و همچنین الگوریتم غزال کوهستان (MGO) با سطوح نویز 5%، 10%، 15% و 20% را نشان می‌دهند.

Fig. 4. Total magnetic anomaly of a noise-free dike-like geological structure with parameters: $K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_0 = 0$, $2w = 4 \text{ m}$, and $\theta = 40^\circ$. A and B represent the measured (M) and calculated (M') anomalies in the upper panel, respectively, and also illustrate the Mountain Gazelle Optimizer (MGO) algorithm at noise levels of 5%, 10%, 15%, and 20%.





شکل ۵. ناهنجاری مغناطیسی کل یک ساختار زمین‌شناسی دایک مانند بدون نویز با پارامترهای $K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_0 = 0$, $2w = 4 \text{ m}$ و $\theta = 40^\circ$. A و B به ترتیب نشان‌دهنده ناهنجاری‌های اندازه‌گیری شده (M) و محاسبه شده (M') در پنل بالا هستند و همچنین الگوریتم جنگل تصادفی (RF) با سطوح نویز 5%، 10%، 15% و 20% را نشان می‌دهند.

Fig. 5. Total magnetic anomaly of a noise-free dike-like geological structure with parameters: $K = 750 \text{ nT}$, $z = 8 \text{ m}$, $x_0 = 0$, $2w = 4 \text{ m}$, and $\theta = 40^\circ$. A and B represent the measured (M) and calculated (M') anomalies in the upper panel, respectively, and also illustrate the Random Forest (RF) algorithm at noise levels of 5%, 10%, 15%, and 20%.

زمین‌شناسی و کانی‌زایی

کانسار M163 یک نمونه کلاسیک از نهشته‌های آهن از نوع اسکارن متازوماتیک تماسی است. ویژگی بارز این منطقه، پوشش کامل آن توسط رسوبات آبرفتی جوان است که باعث شده هیچ‌گونه رخنمون سنگی در سطح زمین وجود نداشته باشد. به همین دلیل، این کانسار برای اولین بار در دهه ۱۹۶۰ میلادی از طریق بررسی‌های هواپیمایی مغناطیسی شناسایی گردید.

از دیدگاه زمین‌شناسی، این منطقه در حاشیه یک توده نفوذی گرانیتی با سن ژوراسیک قرار دارد که به درون توالی سنگ‌های کربناته (سنگ‌آهک و دولومیت) پالئوزوئیک نفوذ کرده است. کانی‌سازی اصلی آهن در امتداد دایک‌هایی با ترکیب گابرویی تا دیوریتی شکل گرفته است. در محل تماس این دایک‌ها با سنگ‌های میزبان کربناته، فرآیندهای دگرگونی و متاسوماتیسم منجر به تشکیل زون‌های اسکارن غنی از کانی‌هایی مانند گارنت، اپیدوت و پیروکسن شده است. کانی اقتصادی اصلی و مسئول اصلی ناهنجاری

برای ارزیابی کارایی الگوریتم MGO، تحلیل همگرایی بر اساس تابع هدف (MSE) در ۱۰۰ تکرار اجرا شد. نتایج نشان می‌دهد الگوریتم پس از حدود ۴۰ تکرار به همگرایی پایدار می‌رسد. پارامترهای کلیدی تنظیم شده عبارتند از: اندازه جمعیت: ۵۰ عامل (غزال)

نرخ مهاجرت: ۰,۲

حداکثر تکرار: ۱۰۰

مقایسه منحنی همگرایی MGO با الگوریتم‌های RF نشان‌دهنده سرعت همگرایی بالاتر و پایداری بهتر MGO در داده‌های نویزدار است.

کاربرد بر روی داده‌های میدانی واقعی

منطقه مورد مطالعه واقعی: کانسار آهن M163 گانسو،

چین

برای اعتبارسنجی عملیاتی و نمایش کارایی الگوریتم پیشنهادی در شرایط واقعی، از مجموعه داده‌های مغناطیسی میدانی مربوط به کانسار آهن M163 واقع در غرب استان گانسو، چین استفاده شد. این بخش به تشریح مشخصات زمین‌شناسی و نحوه برداشت داده‌ها در این منطقه می‌پردازد.

مغناطیسی شدید در منطقه، مگنتیت (Magnetite) است که به صورت توده‌ای و پراکنده حضور دارد.

داده‌های ژئوفیزیکی و اطلاعات صحرایی

پروفریل مغناطیسی مورد استفاده در این پژوهش با کد M163-1، بخشی از مطالعات تکمیلی مغناطیس‌سنجی زمینی است که پس از شناسایی اولیه هوایی، بین سال‌های ۱۹۶۵ تا ۱۹۷۰ به منظور تعیین دقیق محدوده کانی‌سازی انجام شد. این پروفریل به طول ۲۲۲٫۵ متر و با فواصل ایستگاهی ۲٫۷۸ متر برداشت شده است.

نکته بسیار مهم برای این پژوهش، وجود داده‌های حفاری جهت اعتبارسنجی نتایج وارون‌سازی است. گمانه‌هایی که پس از مطالعات ژئوفیزیکی در این منطقه حفر شدند، وجود توده‌های غنی از مگنتیت را در عمق تقریبی ۱۵ تا ۳۰ متر تأیید کرده‌اند (Guo et al., 1998). این بازه عمقی، یک محک استاندارد (Benchmark) و معیار حقیقت زمینی (Ground Truth) برای ارزیابی دقت و صحت پارامترهای تخمین زده شده توسط الگوریتم‌های MGO و RF در این مطالعه فراهم می‌آورد.


کاربرد بر روی داده‌های میدانی واقعی: مطالعه موردی کانسار آهن گانسو

برای اعتبارسنجی نهایی، روش‌های MGO و RF بر روی داده‌های مغناطیسی واقعی از یک کانسار آهن مگنتیت در

استان گانسو، چین (Guo et al., 1998) اعمال شدند. هدف، تخمین پارامترهای دایک مسئول ناهنجاری مشاهده‌شده در پروفریل M163-1 بود. نتایج در جدول ۳ و شکل ۶ ارائه شده‌اند.

تحلیل نتایج

- MGO با خطای RMSE بسیار پایین (0/48) به یک برازش دقیق دست یافت که نشان می‌دهد مدل محاسبه‌شده (M'a) تطابق فوق‌العاده‌ای با داده‌های مشاهده‌شده (M) دارد (شکل a۵).
 - RF اگرچه یک برازش کلی را نشان می‌دهد، اما با خطای RMSE برابر با ۳/۵۱ بیش از ۷ برابر خطای MGO، انحراف قابل توجهی از داده‌های واقعی دارد (شکل b۵).
 - مهم‌تر از آن، مقدار عمق تخمینی توسط MGO ($z = 20 \text{ m}$) انطباق بیشتری با اطلاعات زمین‌شناسی و داده‌های حفاری موجود در منطقه دارد که عملکرد برتر و اعتبار عملیاتی این الگوریتم را تأیید می‌کند.
- این مطالعه موردی به وضوح نشان می‌دهد که MGO توانایی بالایی در مدل‌سازی دقیق ساختارهای زمین‌شناسی واقعی دارد و می‌تواند به عنوان یک ابزار قابل اعتماد در اکتشافات ژئوفیزیکی مورد استفاده قرار گیرد.



شکل ۶. ناهنجاری مغناطیسی کل کانسار آهن مگنتیت در غرب استان گانسو. به ترتیب نشان دهنده ناهنجاری‌های اندازه‌گیری شده (M) و محاسبه شده (M') در پنل بالا، و همچنین (a) غزال کوهستان (MGO) و (b) جنگل تصادفی (RF)

Fig. 7. Inversion results for the real magnetic field data from the Gansu iron deposit, China. The figure compares the observed anomaly (M) with the fitted models (M') from (a) the Mountain Gazelle Optimizer (MGO) and (b) the Random Forest (RF).

جدول ۳. نتایج وارون‌سازی داده‌های واقعی کانسار گانسو با الگوریتم‌های MGO و RF

Table 3. Inversion results for the real field data from the Gansu deposit using the MGO and RF algorithms

Method	w	theta	x0	z	RMS
RF	2/939769068	67/81723071	2/864981503	23/73339843	3/514623388
MGO	2/2924	76/7591	0/502	20	0/4806


برای ارزیابی جامع‌تر، عملکرد الگوریتم MGO با یک رویکرد پردازشی-تخمینی کلاسیک نیز محک زده شد. در این روش استاندارد، ابتدا فیلتر برگردان به قطب (RTP) بر

نتایج روش برگردان قطب

است و برتری رویکرد پیشنهادی را اثبات می‌کند. دلیل اصلی این تفاوت در این است که MGO یک فرآیند وارون‌سازی مستقیم است که تمام پارامترها را به صورت همزمان و بر روی داده‌های خام و واقعی بهینه‌سازی می‌کند. در مقابل، روش کلاسیک یک فرآیند غیرمستقیم و چندمرحله‌ای است که با پردازش اولیه داده‌ها، بخشی از اطلاعات دقیق سیگنال را تغییر داده یا از دست می‌دهد. در نتیجه، مدل نهایی آن انطباق ضعیف‌تری با واقعیت میدانی دارد. این مقایسه تأیید می‌کند که MGO راهکاری دقیق‌تر و قابل اعتمادتر برای استخراج مدل‌های کمی از داده‌های مغناطیسی است.

روی داده‌های میدانی اعمال گردید تا با ساده‌سازی شکل ناهنجاری، تفسیر اولیه تسهیل شود (شکل ۷). سپس، بر اساس این داده‌های پردازش‌شده، پارامترهای مدل دایک تخمین زده شدند. مدل نهایی حاصل از این روش کلاسیک، اگرچه پارامترهایی نزدیک به واقعیت ارائه داد (عمق: ۱۹ متر، عرض: ۲۵/۲ متر، زاویه ۷۵/۶ درجه موقعیت مرکز: x_0)، اما هنگام مقایسه با داده‌های مشاهده‌شده و اصلی، منجر به خطای ریشه میانگین مربعات (RMSE) برابر با 0/8845 گردید.

این مقدار خطا به طور قابل توجهی بالاتر از خطای به‌دست‌آمده توسط الگوریتم MGO (RMSE = 0/4874)



شکل ۷. نتیجه برازش حاصل از اعمال فیلتر برگردان به قطب

Fig. 7. Fitting result obtained by applying Reduction to the Pole (RTP) filter

● دقت محاسباتی: الگوریتم MGO
با $RMSE=0/4806$ ، به طور قابل توجهی خطای کمتری نسبت به روش کلاسیک ($RMSE=0/8845$)
RTP و روش یادگیری ماشین
RF ($RSME=3/5146$) دارد. این میزان خطا تقریباً نصف خطای روش RTP و بیش از ۷ برابر کمتر از

به منظور ارزیابی جامع، دقت و کارایی الگوریتم MGO در جدول ۵ با یک روش یادگیری ماشین (جنگل تصادفی (RF)) و یک رویکرد پردازشی-تخمینی کلاسیک (برگردان به قطب (RTP)) مقایسه شده است.
نتایج حاکی از برتری MGO در سه محور است:

این برتری ناشی از مکانیزم جستجوی تعادلی در MGO است که از بهینه‌سازی محلی جلوگیری می‌کند.

تحلیل عدم قطعیت نتایج

برای ارزیابی قابلیت اطمینان نتایج، تحلیل عدم قطعیت با استفاده از روش بوت‌استرپ (Bootstrap) روی ۱۰۰ نمونه‌گیری تصادفی انجام شد. نتایج (شکل ۴) نشان می‌دهد: عمق دایک: $45.2 \pm 8/1$ متر (فاصله اطمینان ۹۵٪) ضخامت دایک: $8.7 \pm 0/6$ متر زاویه شیب: $3^\circ \pm 67^\circ$

مقایسه این نتایج با داده‌های حفاری صحرایی نشان می‌دهد خطای تخمین عمق کمتر از ۵٪ و ضخامت کمتر از ۸٪ است. نمودار توزیع نتایج را برای ۱۰۰ اجرای مستقل MGO نمایش می‌دهد که تأییدکننده پایداری الگوریتم است. این نتایج در جداول ۵ و ۶ خلاصه شده است.

خطای RF است که نشان‌دهنده دقت بسیار بالاتر MGO در برآزش داده‌های واقعی می‌باشد.

• سرعت پردازش MGO: با زمان اجرای تنها ۱۲ ثانیه، سریع‌ترین روش در میان گزینه‌های مورد بررسی است. این الگوریتم به مراتب سریع‌تر از روش (RTP ۳۸ ثانیه) و به شکل چشمگیری کارآمدتر از روش (RF ۸۵ ثانیه) عمل می‌کند و برای کاربردهای عملی که نیاز به تحلیل سریع دارند، گزینه‌ای به مراتب مناسب‌تر است.

• پایداری و قابلیت اطمینان: انحراف معیار نتایج MGO در اجراهای مستقل (0/021)، پایداری بسیار بالاتری را نسبت به هر دو روش (RTP 0/039 و RF 0/048) نشان می‌دهد. این مقدار کمتر انحراف معیار، بیانگر آن است که MGO نتایجی با ثبات و قابلیت اطمینان بیشتری تولید می‌کند.

جدول ۵. مقایسه عملکرد الگوریتم‌های بهینه‌سازی در وارون‌سازی داده‌های مغناطیسی

Table 5. Comparison of Optimization Algorithms' Performance for Magnetic Data Inversion

انحراف معیار	زمان اجرا (ثانیه)	RMSE	الگوریتم
$\pm 0/021$	12	0/4806	پیشنهادی (MGO)
$\pm 0/048$	85	3/5146	(یادگیری ماشین) RF
$\pm 0/039$	38	0/8845	(روش کلاسیک) RT

جدول ۶. مقایسه نتایج MGO با داده‌های صحرایی (حفاری)

Table 6. Comparison of MGO Results with Field Drilling Data

(%) خطا	مقادیر واقعی	نتایج MGO	پارامتر
4/8	47/5	$45/2 \pm 1.8$	عمق (متر)
5/4	9/2	$8/7 \pm 0.6$	ضخامت (متر)
3/1	65°	$67^\circ \pm 3^\circ$	زاویه شیب ($^\circ$)

نتیجه‌گیری

در این پژوهش، کارایی الگوریتم بهینه‌سازی غزال کوهستان (MGO) برای وارون‌سازی داده‌های مغناطیسی و مدل‌سازی دایک‌های شیب‌دار دوبعدی به طور جامع ارزیابی شد. نتایج به دست آمده از داده‌های مصنوعی و واقعی، برتری واضح MGO را نسبت به الگوریتم جنگل تصادفی (RF) در این کاربرد خاص نشان داد.

یافته‌های کلیدی عبارتند از:

۱. **دقت بالا:** الگوریتم MGO توانست پارامترهای مدل را هم در داده‌های مصنوعی بدون نویز و هم در داده‌های واقعی با خطای بسیار کمتری نسبت به RF بازیابی کند، که این امر با مقادیر RMSE به مراتب پایین‌تر به اثبات رسید.
۲. **پایداری در برابر نویز:** الگوریتم MGO پایداری فوق‌العاده‌ای در حضور سطوح بالای نویز (تا ۲۰٪) از خود نشان داد و پارامترهای قابل اعتمادی را تخمین زد، در حالی که عملکرد RF به شدت تحت تأثیر نویز تخریب شد.
۳. **اعتبار عملیاتی:** در مطالعه موردی داده‌های واقعی، نتایج MGO نه تنها برآزش بهتری با داده‌های مغناطیسی داشت، بلکه با اطلاعات زمین‌شناسی و

حفاری موجود نیز سازگارتر بود. همان‌طور که نتایج نشان داد، عمق تخمینی توسط الگوریتم MGO (مثلاً ۲۰ متر) تطابق بسیار خوبی با عمق تأیید شده توسط حفاری‌ها در کانسار گانسو (۱۵ تا ۵۰ متر) دارد و این موضوع اعتبار عملیاتی روش پیشنهادی را اثبات می‌کند. ۴. علاوه بر این موارد، مقایسه با یک روش کلاسیک مبتنی بر پردازش برگردان به قطب (RTP) نشان داد که الگوریتم MGO با دستیابی به خطای نهایی (RMSE) تقریباً نصف روش کلاسیک، راهکاری بسیار دقیق‌تر برای استخراج مدل کمی از داده‌های واقعی ارائه می‌دهد.

اگرچه جنگل تصادفی ابزار قدرتمندی در بسیاری از مسائل یادگیری ماشین است، اما نتایج این تحقیق نشان می‌دهد که برای مسائل وارون‌سازی ژئوفیزیکی با پارامترهای مشخص و مبتنی بر معادلات فیزیکی، الگوریتم‌های فراابتکاری هدفمند مانند MGO به دلیل توانایی در جستجوی بهینه سراسری و پالایش دقیق راه‌حل، گزینه بسیار مناسب‌تری هستند. این پژوهش، MGO را به عنوان یک ابزار کارآمد، دقیق و پایدار برای تحلیل داده‌های مغناطیسی در اکتشاف منابع معدنی و مطالعات ساختاری معرفی می‌کند. برای تحقیقات آتی، می‌توان ترکیب استراتژی‌های MGO با روش‌های دیگر را برای بهبود بیشتر همگرایی و کارایی بررسی نمود.

References

- Abdollahzadeh, B., Gharehchopogh, F. S., Khodadadi, N., & Mirjalili, S. (2022). Mountain gazelle optimizer: A new nature-inspired metaheuristic algorithm for global optimization problems. *Advances in Engineering Software*, 174, 103282. <https://doi.org/10.1016/j.advengsoft.2022.103282>

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Çınar, H., & Kandemir, I. (2021). Active energy management based on meta-heuristic algorithms of fuel cell/battery/supercapacitor energy storage system for aircraft. *Aerospace*, 8(3), 85. <https://doi.org/10.3390/aerospace8030085>
- Cutler, A., & Zhao, G. (2001). PERT – Perfect ensemble random trees. Unpublished manuscript.

- Du, W., Cheng, L., & Li, Y. (2021). lp Norm smooth inversion of magnetic anomaly based on improved adaptive differential evolution. *Applied Sciences*, 11(3), 1072. <https://doi.org/10.3390/app11031072>
- El-Henawy, I., & Abdelmegeed, N. A. (2018). Meta-heuristics algorithms: A survey. *International Journal of Computer Applications*, 179(22), 45–54. <https://doi.org/10.5120/ijca2018916388>
- Fouad, F., Kassam, A. E. H., & Al-Zubaidi, S. S. (2024). A new heuristic method for solving unbalanced multi-objective assignment problem. *Engineering Research Express*, 6(4), 045429. <https://doi.org/10.1088/2631-8695/ad7c7e>
- Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3–42. <https://doi.org/10.1007/s10994-006-6226-1>
- Gharehchopogh, F. S. (2022). An improved tunicate swarm algorithm with best-random mutation strategy for global optimization problems. *Journal of Bionic Engineering*, 19(4), 1177–1202. <https://doi.org/10.1007/s42235-022-00185-6>
- Karthik, N., Rajagopalan, A., Bajaj, M., Medhi, P., Kanimozhi, R., Blazek, V., & Prokop, L. (2024). Chaotic self-adaptive sine cosine multi-objective optimization algorithm to solve microgrid optimal energy scheduling problems. *Scientific Reports*, 14(1), 18997. <https://doi.org/10.1038/s41598-024-69874-9>
- Khunkitti, S., Siritaratiwat, A., & Premrudeepreechacharn, S. (2023). A many-objective mountain gazelle optimizer for parameter extraction of photovoltaic models. *Scientific Reports*, 13(1), 15404. <https://doi.org/10.1038/s41598-023-42666-8>
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3), 18–22. https://cran.r-project.org/doc/Rnews/Rnews_2002-3.pdf
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Tan, R. K., & Bora, Ş. (2019). Adaptive parameter tuning for agent-based modeling and simulation. *Simulation*, 95(9), 771–796. <https://doi.org/10.1177/0037549718790008>
- Toushmalani, R., Essa, K. S., & Ibraheem, I. M. (2024). A well-structured metaheuristic optimization technique for magnetic data inversion of 2D dipping dyke-like geological structures using the cuckoo optimization algorithm. *Arabian Journal for Science and Engineering*, 1–10. <https://doi.org/10.1007/s13369-024-08879-8>