

Basement Depth Estimation from Airborne Magnetic Data in the Rig-e Jen Sedimentary Basin Using Deep Neural Networks

Mousapour Yasoori, M.¹  | Motavalli-Anbaran, S. H.¹   | Parnian-Khoy, H.¹ 

1. Department of Earth Physics, Institute of Geophysics, University of Tehran, Tehran, Iran.

Corresponding Author E-mail: motavalli@ut.ac.ir

(Received: 11 Jan 2026, Revised: 11 May 2026, Accepted: 30 June 2026, Published online: 5 Sep 2026)

Summary

Determining the geometry and depth of sedimentary basins is a fundamental objective in geophysical exploration, particularly in regions with hydrocarbon potential. Magnetic methods are commonly applied for this purpose when sufficient magnetic contrast exists between the basement rocks and the overlying sedimentary sequences. The inversion of magnetic data, however, is inherently nonlinear and ill-posed, and conventional inversion approaches generally rely on iterative optimization schemes combined with regularization strategies to obtain stable solutions. While these methods have been successfully applied in numerous studies, their performance may depend on factors such as the choice of initial models, regularization parameters, and computational cost, especially in regional-scale applications. In recent years, data-driven techniques based on machine learning have been increasingly explored as complementary tools for addressing inverse problems in geophysics. Within this context, the present study examines the applicability of deep neural networks (DNNs) for the inversion of airborne magnetic data, with the aim of estimating the depth of the magnetic basement in the Rig-e Jen sedimentary basin, Central Iran.

Due to the limited availability of dense, labeled field data suitable for supervised learning, a large and diverse synthetic dataset was generated to train the neural network. The subsurface was represented by a simplified two-layer model consisting of a non-magnetic sedimentary cover overlying a magnetic basement. The basement surface geometry was constructed using ensembles of rectangular prisms with laterally varying depths designed to reflect geologically plausible scenarios. The lower boundary of the model was fixed at a depth of 25 km, while the average basement depth was randomly varied between 3 and 15 km. Magnetic responses were calculated along profiles 80 km in length with a sampling interval of 1 km, using the analytical formulation of Rao and Babu (1991). A constant magnetic susceptibility value of 0.034 SI was assumed for the basement, along with fixed geomagnetic field parameters. In total, 100,000 paired synthetic models and corresponding magnetic anomalies were generated efficiently to form the training dataset.

A fully connected multilayer perceptron (MLP) architecture was employed to approximate the nonlinear mapping between magnetic anomalies and basement depth. The network consisted of three hidden layers with 215 neurons each and utilized the GELU activation function. A normal initialization was applied to the network weights, and dropout layers were included to mitigate overfitting. Training was carried out using the AdamW optimization algorithm with a mean squared error loss function. The dataset was divided into training, validation, and independent test subsets to enable an objective evaluation of model performance. Tests conducted on synthetic data indicate that the trained network is capable of reproducing the general characteristics of basement topography. Additional experiments incorporating Gaussian noise with an amplitude of 10% demonstrate that the model maintains a reasonable level of stability under noisy conditions.

Following validation on synthetic datasets, the trained DNN was applied to airborne magnetic data from the Rig-e Jen region. A network of eight intersecting profiles, oriented along NE–SW and NW–SE directions, was designed to facilitate consistency checks at profile intersections. The estimated basement depths range approximately from 5 to 14 km, with greater depths predominantly observed in the northwestern part of the basin. Differences in predicted depths at profile intersection points average about 400 m, which is small relative to the overall basin thickness and suggests an acceptable level of internal consistency.

To evaluate uncertainty associated with physical assumptions, a sensitivity analysis was performed by varying the basement magnetic susceptibility within a realistic range (0.028–0.040 SI) while keeping the basement geometry fixed. The resulting variations in predicted basement depth were quantified using the standard deviation, providing an estimate of uncertainty linked to susceptibility heterogeneity. The mean standard deviation of the estimated depth was about 126 m, with a maximum of 417 m in deeper parts of the basin. The results indicate that susceptibility variations influence depth estimates, although the predicted basement geometry remains relatively stable over most parts of the study area.

In summary, this study demonstrates that deep neural networks can serve as a complementary, data-driven approach for the inversion of airborne magnetic data in sedimentary basins characterized by thick sedimentary cover. The proposed methodology offers a computationally efficient framework for estimating basement depth once the model is trained, while producing results that are consistent with regional geological constraints. The approach is particularly suitable for regional-scale investigations in data-limited settings and may be further refined through the incorporation of additional physical parameters or integration with independent geophysical datasets.

Keywords: Deep Neural Network, Magnetic Basement, Magnetic Data Inversion.

Cite this article: Mousapour Yasoori, M., Motavalli-Anbaran, S. H., & Parnian-Khoy, H. (2026). Basement Depth Estimation from Airborne Magnetic Data in the Rig-e Jen Sedimentary Basin Using Deep Neural Networks. *Journal of the Earth and Space Physics*, 52(2), 241-257. DOI: <http://doi.org/10.22059/jesphys.2026.409679.1007751>

E-mail: (1) mousapour@ut.ac.ir | h.oseinparnian@ut.ac.ir



© Authors Retain the Copyright and Full Publishing Rights.

Publisher: University of Tehran Press.

DOI: <http://doi.org/10.22059/jesphys.2026.409679.1007751>

Print ISSN: 2538-371X
Online ISSN: 2538-3906

تخمین عمق سنگ بستر از داده مغناطیس هوابرد در حوزه رسوبی ریگ جن با استفاده از شبکه‌های عصبی عمیق

مصطفی موسی‌پور یاسوری^۱ | سیدهای متولی عنبران^۱ ✉ | حسین پرنیان خوی^۱

۱. گروه فیزیک زمین، مؤسسه ژئوفیزیک، دانشگاه تهران، تهران، ایران.

رایانامه نویسنده مسئول: motavalli@ut.ac.ir

(دریافت: ۱۴۰۴/۱۰/۲۱، بازنگری: ۱۴۰۵/۲/۲۱، پذیرش نهایی: ۱۴۰۵/۴/۹، انتشار آنلاین: ۱۴۰۵/۶/۱۴)

چکیده

در این پژوهش، یک مدل شبکه عصبی عمیق برای وارون‌سازی غیرخطی داده‌های مغناطیس هوابرد به‌منظور برآورد عمق سنگ‌بستر مغناطیسی در حوزه رسوبی ریگ‌جن واقع در کویر بزرگ ایران توسعه و به‌کار گرفته شد. با توجه به نبود داده‌های واقعی برچسب‌دار، ابتدا مجموعه‌ای بزرگ و متنوع از داده‌های مصنوعی با استفاده از مدل‌های تصادفی سنگ‌بستر و حل تحلیلی مسئله پیش‌رو تولید شد. یک شبکه پرسپترون چندلایه با سه لایه پنهان و ۲۱۵ نورون در هر لایه، با استفاده از این داده‌ها آموزش داده شد. مدل آموزش‌دیده توانست نگاشت بین آنومالی‌های مغناطیسی و عمق سنگ‌بستر را با دقت مطلوب بیاموزد. ارزیابی بر روی داده‌های مصنوعی همراه با نویز، پایداری قابل‌قبول مدل را نشان داد. نتایج اعمال مدل بر هشت پروفیل متقاطع در منطقه ریگ‌جن، عمق سنگ‌بستر را در بازه ۵ تا ۱۴ کیلومتر و با بیشترین عمق در بخش شمال‌غربی حوزه برآورد کرد. سازگاری نتایج در نقاط تقاطع پروفیل‌ها (میانگین اختلاف حدود ۴۰۰ متر) و انطباق آن با الگوی کلی داده‌های مغناطیسی، عملکرد مدل را تأیید نمود. تحلیل عدم قطعیت نیز حساسیت نتایج به تغییرات خودپذیری مغناطیسی را بررسی کرد. این مطالعه نشان می‌دهد که رویکرد مبتنی بر شبکه عصبی عمیق، با سرعت بالا و کاهش وابستگی به مدل اولیه، ابزاری مؤثر برای اکتشاف ساختار عمقی در حوزه‌های رسوبی با پوشش رسوبی ضخیم است.

واژه‌های کلیدی: سنگ‌بستر مغناطیسی، شبکه عصبی عمیق، وارون‌سازی داده‌های مغناطیس.

۱. مقدمه

انتخاب پارامترها و راهبرد حل مسئله حساس باشد. در سال‌های اخیر، رویکردهای داده‌محور مبتنی بر یادگیری ماشین به‌عنوان رویکرد جدید برای مواجهه با مسائل وارون‌سازی ژئوفیزیکی مورد توجه قرار گرفته‌اند. این روش‌ها در مطالعات مختلف برای تقریب روابط غیرخطی پیچیده میان داده‌های مشاهده‌شده و پارامترهای زیرسطحی به‌کار رفته‌اند. از کاربردهای آنها می‌توان به برآورد هندسه و ابعاد بی‌هنجاری‌های توده‌ای، تعیین عمق و شکل سنگ‌بستر در حوزه‌های رسوبی و تخمین ساختارهای پوسته‌ای مانند عمق موهو اشاره کرد.

در این رویکردها، شبکه‌های عصبی با بهره‌گیری از داده‌های آموزشی، نگاشت غیرخطی مستقیمی میان داده‌های میدان پتانسیل و پارامترهای زیرسطحی می‌آموزند

روش‌های وارون‌سازی ژئوفیزیکی به‌طور کلی به دو دسته خطی و غیرخطی تقسیم می‌شوند و طی دهه‌های گذشته، الگوریتم‌های متنوعی برای حل این مسائل توسعه یافته‌اند. روش‌های کلاسیک مبتنی بر کمینه‌سازی تابع هدف با استفاده از مشتقات، و همچنین الگوریتم‌های بهینه‌سازی تصادفی و فراابتکاری نظیر الگوریتم ژنتیک، کلونی مورچگان و ازدحام ذرات (Particle Swarm Optimization)، به‌طور گسترده برای حل مسائل وارون‌سازی غیرخطی به‌کار گرفته شده‌اند. این روش‌ها در مطالعات متعددی نتایج قابل‌قبولی ارائه داده‌اند. با این حال، به‌دلیل ماهیت غیرخطی رابطه میان داده‌های میدان پتانسیل و پارامترهای زیرسطحی، فضای جواب‌ها معمولاً چندبعدی و ناهموار است و در نتیجه، فرایند وارون‌سازی می‌تواند به

استناد: موسی‌پور یاسوری، مصطفی؛ متولی عنبران، سیدهای و پرنیان خوی، حسین (۱۴۰۵). تخمین عمق سنگ بستر از داده مغناطیس هوابرد در حوزه رسوبی ریگ‌جن با استفاده از شبکه‌های عصبی عمیق. *مجله فیزیک زمین و فضا*، ۵۲ (۲)، ۲۴۱-۲۵۷. DOI: <http://doi.org/10.22059/jesphys.2026.409679.1007751>

رایانامه: (۲) mousapour@ut.ac.ir | h.oseinparnian@ut.ac.ir

نداشته باشد. در ایران، ضخامت حوضه‌های رسوبی در بسیاری از مناطق به چندین کیلومتر می‌رسد؛ به عنوان نمونه، عمق رسوبات در البرز ۵ کیلومتر (بلاتو و همکاران، ۲۰۱۱)، کپه داغ ۱۰ کیلومتر (بربریان و بربریان، ۱۹۸۱)، کویر بزرگ ۵ کیلومتر (جکسون و همکاران، ۱۹۹۰)، حوضه رسوبی قم ۱۲ کیلومتر (مورلی و همکاران، ۲۰۰۹)، حوضه رسوبی جنوب کاسپین ۲۰ تا ۲۵ کیلومتر (گلموف و همکاران، ۲۰۰۴) گزارش شده است. این ضخامت زیاد، کارایی داده‌های گرانی‌سنجی را در برآورد عمق سنگ‌بستر با محدودیت مواجه می‌سازد و استفاده از روش‌های لرزه‌ای نیز به دلیل هزینه‌های بالا در مقیاس‌های منطقه‌ای همواره امکان‌پذیر نیست. از این‌رو، داده‌های مغناطیسی هوابرد به عنوان ابزاری کارآمد برای مطالعه ساختار عمقی حوضه‌های رسوبی اهمیت ویژه‌ای دارند.

در این پژوهش، با بهره‌گیری از شبکه‌های عصبی عمیق و داده‌های مغناطیسی، عمق حوضه رسوبی در منطقه ریگ‌جن واقع در کویر بزرگ ایران مورد بررسی قرار گرفته است. بدین منظور، رویکرد پیشنهادی با الهام از روش ارائه‌شده توسط آشنا و همکاران (۲۰۲۳)، ابتدا بر روی داده‌های مصنوعی ارزیابی شده و سپس برای وارون‌سازی داده‌های واقعی مغناطیسی منطقه ریگ‌جن به کار گرفته شده است.

۲. روش پژوهش

مسائل وارون‌سازی ژئوفیزیکی، از جمله برآورد هندسه و عمق سنگ بستر بر اساس داده‌های مغناطیسی، به دلیل ماهیت غیرخطی و نامعین خود، با چالش‌های متعددی روبرو هستند؛ به طوری که مدل‌های زیرسطحی متعددی می‌توانند پاسخ‌های مشاهده‌شده یکسانی را بازتولید کنند (منکه، ۲۰۱۸). رابطه بین داده‌های مشاهده‌ای و پارامترهای مدل زیرسطحی را می‌توان به صورت زیر بیان کرد:

$$d_{obs} = F(m) \quad (1)$$

که در آن d_{obs} بردار داده‌های مغناطیسی مشاهده‌شده، m بردار پارامترهای مدل زیرسطحی و F عملگر پیش‌رو است. هدف مسئله وارون‌سازی، تخمین تقریبی عملگر معکوس

و بدین ترتیب، بدون حل صریح مسئله وارون‌سازی و تعریف تابع هدف کلاسیک، امکان برآورد پارامترهای مدل فراهم می‌شود. برای نمونه، وو و همکاران (۲۰۲۳) از یادگیری ماشین برای بهبود وضوح عمقی و انتخاب پارامترهای وارون‌سازی در داده‌های گرانی استفاده کردند. ویتال و همکاران (۲۰۲۳) رویکردهای یادگیری ماشین را برای برآورد عمق حوضه‌های رسوبی از داده‌های میدان پتانسیل به کار گرفتند. همچنین، هو و همکاران (۲۰۲۱) و آشنا و همکاران (۲۰۲۳) نشان دادند که شبکه‌های عصبی عمیق (Deep Neural Network) DNN ابزاری مؤثر برای وارون‌سازی غیرخطی داده‌های پتانسیل هستند؛ به طوری که اولی بر تعیین حدود بی‌هنجاری‌های توده‌ای و دومی بر برآورد عمق حوضه‌های رسوبی متمرکز بوده است.

رویکردهای مبتنی بر شبکه عصبی عمیق برخلاف روش‌های کلاسیک وارون‌سازی غیرخطی، نیازی به انتخاب مدل اولیه و تنظیم دستی پارامترهای منظم‌سازی ندارند؛ زیرا نگاشت معکوس را مستقیماً از داده‌های آموزشی یاد می‌گیرد. از دیگر مزایای این روش‌ها می‌توان به کاهش هزینه محاسباتی در مرحله پیش‌بینی اشاره کرد؛ به گونه‌ای که پس از آموزش شبکه، وارون‌سازی داده‌های جدید با سرعت بیشتری در مقایسه با روش‌های تکراری کلاسیک انجام می‌شود. با این حال، موفقیت این روش‌ها در عمل به داده‌های آموزشی وابسته است. اگر داده‌های آموزشی به اندازه کافی متنوع و معرف شرایط واقعی منطقه نباشند، شبکه دچار بیش‌برازش شده و توانایی تعمیم به داده‌های جدید را از دست می‌دهد. همچنین، تفسیرپذیری محدود نتایج و حساسیت به معماری شبکه از دیگر چالش‌های این رویکردها هستند (ویتال و همکاران، ۲۰۲۳).

شناخت هندسه و عمق حوضه‌های رسوبی نقش کلیدی در مطالعات اکتشافی، به ویژه در اکتشاف هیدروکربن، ایفا می‌کند. برآورد عمق سنگ‌بستر از داده‌های مغناطیسی زمانی امکان‌پذیر است که سنگ‌های آذرین زیرین نسبت به رسوبات رویی دارای مغناطیس‌پذیری بالاتری بوده و واحدهای مغناطیسی قابل توجهی درون رسوبات وجود

F^{-1} به منظور برآورد مدل زیرسطحی m از داده‌های مشاهده شده است:

$$m \approx F^{(-1)}(d_{obs}) \quad (2)$$

روش‌های کلاسیک وارون‌سازی، این مسئله را معمولاً از طریق بهینه‌سازی تکراری همراه با اعمال قیود منظم‌سازی حل می‌کنند. با این حال به دلیل ماهیت نامعین و غیرخطی مسئله، این روش‌ها اغلب نسبت به انتخاب مدل اولیه و تنظیم پارامترهای منظم‌سازی حساس بوده و ممکن است به کمینه‌های محلی همگرا شوند (اوتسوگی، ۲۰۱۹). در سال‌های اخیر، شبکه‌های عصبی عمیق به عنوان رویکردی داده‌محور برای تقریب مستقیم عملگر معکوس F^{-1} مطرح شده‌اند، به طوری که نگاشت غیرخطی میان داده‌های مشاهده شده و پارامترهای مدل زیرسطحی به صورت مستقیم و از طریق یادگیری نظارت شده آموزش داده می‌شود (کامیاب و همکاران، ۲۰۲۲).

در این پژوهش، از معماری پرسپترون پیش‌خور چندلایه MLP (Multi-Layer Perceptron) به عنوان یک تقریب‌زننده غیرخطی برای عملگر معکوس مسئله مغناطیسی استفاده شده است. این شبکه با

یادگیری الگوهای نهفته در مجموعه‌ای از داده‌های مصنوعی، نگاشتی از فضای داده به فضای مدل ایجاد می‌کند که امکان برآورد عمق سنگ‌بستر مغناطیسی را فراهم می‌سازد. فرایند پیشنهادی وارون‌سازی داده‌های مغناطیسی مبتنی بر شبکه عصبی عمیق در سه گام اصلی شامل تولید داده‌های مصنوعی، آموزش شبکه و پیش‌بینی داده‌های واقعی خلاصه می‌شود (شکل ۱).

۲-۱. تولید مجموعه داده‌ی مصنوعی

به دلیل نبود داده‌های واقعی برچسب‌دار با پوشش مکانی و تنوع کافی، یک مجموعه داده‌ی مصنوعی بزرگ و متنوع برای آموزش شبکه تولید شد. در این راستا، مدل‌های مصنوعی سنگ‌بستر با هندسه‌های متفاوت و از نظر زمین‌شناسی محتمل، بر اساس دانش پیشین از محدوده ایران مرکزی و به صورت تصادفی ایجاد شدند. پارامترهایی مانند عمق و هندسه سنگ‌بستر در بازه‌های واقع‌بینانه انتخاب شد تا طیف گسترده‌ای از سناریوهای ممکن زیرسطحی شبیه‌سازی شود.



شکل ۱. نمایی از مراحل انجام وارون‌سازی داده‌های مغناطیسی به روش شبکه عصبی عمیق (DNN).

به عنوان ورودی و عمق پی سنگ به عنوان برچسب (label) برای آموزش شبکه عصبی عمیق آماده شد. در مجموع، ۱۰۰ هزار نمونه داده مصنوعی تولید شد که فرایند تولید آنها در مدت حدود ۱۵ دقیقه بر روی یک رایانه شخصی با پردازنده Intel Core i5 فرکانس ۲/۱ گیگاهرتز و ۸ گیگابایت حافظه RAM انجام شد.

۲-۲. آموزش و تنظیم معماری شبکه

شبکه عصبی عمیق در این پژوهش به عنوان یک تقریب زننده غیرخطی برای نگاشت از فضای داده به فضای مدل به کار گرفته شد. این نگاشت به صورت زیر تعریف می شود:

$$m^{sym} = F_{DNN}(d^{sym}; \Theta) \quad (۳)$$

که در آن F_{DNN} تابع پیاده سازی شده توسط شبکه عصبی و Θ مجموعه پارامترهای قابل آموزش شبکه شامل وزن ها و بایاس ها است. هدف آموزش شبکه، استخراج این نگاشت غیرخطی از طریق تنظیم پارامترهای شبکه به گونه ای است که بتواند ارتباط بین آنومالی های مغناطیسی و عمق سنگ بستر را به طور دقیق تقریب بزند.


برای این منظور، یک شبکه پرسپترون پیش خور چند لایه با چندین لایه پنهان کاملاً متصل مورد استفاده قرار گرفت. پارامترهای شبکه با کمینه سازی تابع زیان بر روی مجموعه داده آموزشی و با بهره گیری از الگوریتم های بهینه سازی مبتنی بر گرادیان تعیین شدند. پس از پایان فرایند آموزش و ارزیابی عملکرد شبکه بر روی مجموعه داده آزمون مستقل، مدل آموزش دیده به عنوان یک عملکرد معکوس ثابت به کار گرفته شد. در این مرحله، داده های واقعی ژئوفیزیکی d_{obs} مستقیماً به ورودی شبکه اعمال شده و مدل زیرسطحی متناظر m_{pred} در خروجی تولید شد:

$$m_{pred} = F_{DNN}(d_{obs}; \Theta) \quad (۴)$$

در این مدل سازی، محیط زیرسطحی شامل یک لایه رسوبی در بالا و یک لایه سنگ بستر در پایین در نظر گرفته شد. لایه رسوبی فاقد خاصیت مغناطیسی فرض شد و سنگ بستر به مجموعه ای از منشورهای مستطیلی با طول یکسان تقسیم شد (شکل ۲). مرز بالایی مدل متناظر با سطح سنگ بستر و مرز پایینی آن در عمق ثابت ۲۵ کیلومتری تعریف شد. مرز بالایی مدل به صورت تصادفی تغییر داده شد تا ناهمواری های طبیعی سنگ بستر بازتاب یابد.

فرایند تولید مدل های مصنوعی با الهام از چارچوب ارائه شده توسط آشنا و همکاران (۲۰۲۳) توسعه یافت، با این تفاوت که دامنه پارامترها و ساختار هندسی مدل متناسب با ویژگی های منطقه مورد مطالعه تنظیم شد. در هر مرحله از شبیه سازی، ابتدا عمق متوسط سنگ بستر به صورت تصادفی در بازه ۳ تا ۱۵ کیلومتر انتخاب می شد. سپس چندین بی هنجاری با هندسه و موقعیت متفاوت، شامل طول، پهنای و ارتفاع متغیر، بر روی سطح سنگ بستر اعمال می شد که تعداد و ویژگی های هندسی آنها نیز از بازه های از پیش تعریف شده به صورت تصادفی تعیین می شد.

برای هر مدل مصنوعی m_i^{sym} پاسخ مغناطیسی متناظر d_i^{sym} با حل مسئله ی پیش رو محاسبه شد. طول هر پروفیل داده ۸۰ کیلومتر در نظر گرفته شد که به ۸۰ بخش یک کیلومتری تقسیم شد و پاسخ مغناطیسی در نقاط مشاهده واقع بر سطح زمین در مرکز هر مستطیل محاسبه شد. در این مدل سازی، میل مغناطیسی برابر ۹۰ درجه، انحراف مغناطیسی صفر درجه و مقدار خودپذیری مغناطیسی سنگ بستر معادل ۰/۰۳۴ در واحد SI فرض شد. محاسبه پاسخ مغناطیسی با استفاده از فرمول بندی راثو و بابو (۱۹۹۱) انجام گرفت که توسعه یافته روش های پلوف (۱۹۷۶) و تالوانی (۱۹۶۵) برای مدل سازی سه بعدی میدان مغناطیسی است و امکان بازنمایی ساختارهای پیچیده زمین شناسی از طریق ترکیب چندین منشور را فراهم می کند. بدین ترتیب، مجموعه داده ی جفت شده $\{d_i^{sym}, m_i^{sym}\}$ شامل آنومالی مغناطیسی



شکل ۲. نمای شماتیک مدل پیش‌رو و موقعیت نقاط مشاهده (نقاط قرمز) بر روی سطح.

میانگین صفر و واریانس واحد باشند. تابع زیان مورد استفاده، میانگین مربعات خطا (MSE) به صورت زیر تعریف شد:

$$L_{MSE}(\Theta) = \frac{1}{N} \sum_{i=1}^N \left\| m_i^{sym} - F_{DNN}(d_i^{sym}; \Theta) \right\|_2^2 \quad (5)$$

که در آن m_i^{sym} مقدار واقعی پارامتر مدل، $F_{DNN}(d_i^{sym}; \Theta)$ مقدار پیش‌بینی شده توسط شبکه، و N تعداد کل نمونه‌ها در مجموعه داده است. داده‌ها به طور تصادفی به دو بخش آموزش-اعتبارسنجی (۹۰٪) و آزمون (۱۰٪) تقسیم شدند و بخش آموزش-اعتبارسنجی نیز به نسبت ۹۰ به ۱۰ به زیرمجموعه‌های آموزش و اعتبارسنجی تفکیک شد. آموزش مدل با اندازه دسته ۳۲ و حداکثر ۲۰۰ دوره انجام گرفت. برای جلوگیری از بیش‌برازش، از راهبرد توقف زودهنگام استفاده شد؛ به طوری که در صورت عدم بهبود خطای اعتبارسنجی طی ۱۰ دوره متوالی، فرایند آموزش متوقف و وزن‌های بهترین دوره ذخیره شد. روند کاهش خطای آموزش و اعتبارسنجی، همگرایی پایدار و موفقیت‌آمیز فرایند یادگیری را نشان می‌دهد (شکل ۳).

مدل نهایی بر روی مجموعه داده آزمون مستقل مورد ارزیابی قرار گرفت. دو نمونه از نتایج حاصل در شکل ۴ ارائه شده است. همان‌طور که مشاهده می‌شود، مدل توانسته توپوگرافی واقعی سنگ‌بستر را با دقت مناسبی بازسازی کند. مقدار ریشه میانگین مربعات خطا (RMSE Root Mean Square Error) آنومالی مغناطیسی در این نمونه‌ها


این رویکرد، برخلاف روش‌های کلاسیک وارون‌سازی، نیازی به تکرارهای عددی، محاسبه مشتقات عملگر پیش‌رو یا تنظیم دستی پارامترهای وارون‌سازی ندارد و امکان برآورد سریع و مستقیم عمق سنگ‌بستر را فراهم می‌کند. پیاده‌سازی شبکه عصبی با استفاده از چارچوب TensorFlow و رابط برنامه‌نویسی سطح بالای Keras انجام شد (شولت و همکاران، ۲۰۱۵). معماری شبکه شامل یک لایه ورودی متناسب با ابعاد بردار داده‌های مغناطیسی، سه لایه پنهان کاملاً متصل با ۲۱۵ نورون در هر لایه و یک لایه خروجی متناظر با پارامترهای مدل زیرسطحی بود. وزن‌های اولیه با روش He Normal مقداردهی شدند تا پایداری فرایند آموزش حفظ شود. در لایه‌های پنهان از تابع فعال‌سازی GELU استفاده شد که به دلیل ماهیت هموار و غیرخطی آن، همگرایی شبکه‌های عمیق را تسهیل می‌کند (هندریکس و گیمپل، ۲۰۱۶)، همچنین برای جلوگیری از بیش‌برازش، لایه‌های Dropout با نرخ ۰/۱ پس از هر لایه پنهان اعمال شد (سریواستاوا و همکاران، ۲۰۱۴).

آموزش شبکه با استفاده از الگوریتم AdamW انجام گرفت که به عنوان توسعه‌ای از Adam، با تفکیک صریح واپاشی وزن از به‌روزرسانی گرادیان، موجب بهبود تعمیم‌پذیری مدل می‌شود (لوشچیلوف و هوتر، ۲۰۱۷). نرخ یادگیری اولیه ۰/۰۰۱ و ضریب واپاشی وزن 1×10^{-5} انتخاب شد. پیش از آموزش، تمامی داده‌های ورودی و خروجی با استفاده از StandardScaler نرمال‌سازی شدند تا دارای


بدون آموزش مجدد بررسی شد (شکل ۵). اگرچه خطاها افزایش یافت (RMSE برابر با ۰/۷۹ و ۱/۱۶ و انحراف معیار تخمین عمق حدود ۵۸۰ تا ۷۱۶ متر)، اما ساختار کلی توپوگرافی سنگ بستر همچنان با دقت قابل قبولی بازسازی شد. این نتایج حاکی از پایداری مناسب مدل در برابر نویز است.

به ترتیب ۱/۳۱ و ۰/۱۷ نانوتسلا و انحراف معیار تخمین عمق حدود ۷۵۰ متر و ۱۶۶ متر است. تطابق خوب بین منحنی‌های واقعی و تخمین زده شده در شکل ۴ به وضوح قابل مشاهده است.


برای ارزیابی پایداری مدل در شرایط واقعی، نویز گاوسی با دامنه ۱۰٪ به داده‌های آزمون افزوده شد و عملکرد مدل



شکل ۳. روند تغییر دقت مدل شبکه عصبی در طی فرایند آموزش و اعتبارسنجی.



شکل ۴. نمونه‌ای از عملکرد مدل DNN بر روی داده‌های مصنوعی بدون نویز. در پنل بالایی، آنومالی مغناطیسی ورودی (خط چین قرمز) و خروجی مدل (خط آبی) نشان داده شده است. در پنل پایینی، توپوگرافی واقعی سنگ بستر (آبی) در مقایسه با برآورد شبکه عصبی (قرمز چین) ترسیم شده است. مقدار RMSE آنومالی مغناطیسی (نانوتسلا) در گوشه بالای سمت چپ هر تصویر درج شده است.



شکل ۵. عملکرد مدل DNN در مواجهه با داده‌های مصنوعی آلوده به نویز گاوسی با دامنه ۱۰٪. علیرغم افزایش خطا (RMSE گزارش شده در تصویر)، مدل بدون آموزش مجدد توانسته است، ساختار کلی توپوگرافی سنگ بستر را بازسازی کند. رنگ‌بندی منحنی‌ها مشابه شکل ۴ است.

۳. زمین‌شناسی منطقه مورد مطالعه


ایران در بخش میانی سیستم کوهزایی آلپ-همیالیا واقع شده و تکامل زمین‌شناسی آن در مقیاس کلان به‌طور عمده تحت تأثیر تاریخچه تحول اقیانوس‌های تتیس (پالئوتتیس و نئوتتیس) و کمرندهای کوهزایی حاصل از آنها در دوران فانروزوئیک بوده است (بربریان و کینگ، ۱۹۸۱). این سیستم کوهزایی بازتاب‌دهنده فرایندی پیچیده از گشایش و بسته‌شدن اقیانوس‌های تتیسی است که منجر به شکل‌گیری واحدهای مختلف با سوابق چینه‌ای، ماگمایی و کوهزایی متمایز شده است. بر این اساس، ایران به چندین پهنه ساختاری اصلی از جمله زاگرس، البرز، ایران مرکزی و مکران تقسیم‌بندی می‌شود که هر کدام سبک ساختاری و تاریخچه زمین‌شناسی ویژه‌ای دارند (شکل ۶).

پوسته قاره‌ای ایران در اواخر پرکامبرین تحت تأثیر کوهزایی پان‌آفریکا قرار گرفت که منجر به دگرگونی، گرانیته شدن، چین‌خوردگی و گسله‌شدن گسترده شد. سنگ‌های دگرگون‌شده با رخنمون محدود، پی‌سنگ این منطقه را تشکیل می‌دهند (ندیمی، ۲۰۰۷). در ایران مرکزی، این پی‌سنگ دگرگونی توسط توده‌های آذرین نفوذی قطع شده و با سنگ‌های آتشفشانی و رسوبی نئوپروتروزوئیک همراه است (بربریان و کینگ، ۱۹۸۱). از

این‌رو، ایران مرکزی یکی از واحدهای کلیدی در بازسازی تکامل ژئودینامیکی ایران به‌شمار می‌رود.

از دیدگاه زمین‌ساختی، ایران مرکزی میان دو کمرند کوهزایی اصلی قرار دارد: کمرند شمالی مرتبط با بسته‌شدن پالئوتتیس و کمرند جنوبی مرتبط با بسته‌شدن نئوتتیس. در این چارچوب، فرورانش لیتوسفر اقیانوسی نئوتتیس به زیر بلوک ایران به‌عنوان عامل اصلی ماگماتیسیم سنوزوئیک در ایران مرکزی در نظر گرفته می‌شود (عمرانی و همکاران، ۲۰۰۸). همچنین، فرایند عقب‌گرد ورقه فرورونده (slab roll-back) نقش مؤثری در گسترش و تداوم پهنه‌های ماگمایی ایفا کرده است (مورلی و همکاران، ۲۰۰۹؛ وردل و همکاران، ۲۰۱۱؛ شفیع‌مقدم و همکاران، ۲۰۱۸).

در نتیجه این فرایندها، ماگماتیسیم گسترده ائوسنی مرتبط با کوهزایی آلپی در ایران مرکزی شکل گرفت که منجر به توسعه کمرندهای آتشفشانی وسیع، به‌ویژه در امتداد قوس ماگمایی ارومیه-دختر شد (عمرانی و همکاران، ۲۰۰۸؛ شفیع‌مقدم و همکاران، ۲۰۱۸). در این دوره، حجم قابل‌توجهی از سنگ‌های آتشفشانی-رسوبی و واحدهای آهکی نهشته شدند که امروزه نقش مهمی در ساختار زیرسطحی منطقه ایفا می‌کنند (رادفر و همکاران، ۱۹۹۹).




شکل ۶. نقشه تکتونیکی صفحات ایران و عربستان که پهنه‌های ساختاری اصلی ایران و زیرپهنه‌های ایران مرکزی را نشان می‌دهد (کردی، ۲۰۱۹).

الیگوسن-میوسن سازند قم پوشیده شده‌اند، به‌عنوان سنگ‌بستر مغناطیسی در نظر گرفته می‌شوند. سازند قم نیز به‌عنوان یکی از سنگ‌های منبع هیدروکربنی مهم این حوزه شناخته می‌شود (مورلی و همکاران، ۲۰۰۹). از این‌رو، تعیین دقیق هندسه و عمق سنگ‌بستر ائوسن، علاوه بر اهمیت زمین‌ساختی، نقش کلیدی در ارزیابی چارچوب ساختاری حوزه و تحلیل پتانسیل‌های اکتشافی آن ایفا می‌کند. در چنین شرایطی، داده‌های مغناطیسی به‌عنوان یکی از کارآمدترین ابزارهای ژئوفیزیکی، امکان برآورد ساختار سنگ‌بستر زیر پوشش ضخیم رسوبی ایران مرکزی را فراهم می‌کنند و مبنای روش پیشنهادی این پژوهش را تشکیل می‌دهند.

منطقه مورد مطالعه ریگ‌جن در زیرحوضه دشت کویر، واقع در بخش شمالی حوضه ایران مرکزی قرار دارد. این زیرحوضه عمدتاً توسط رسوبات سنوزوئیک و کواترنری پوشیده شده و به‌دلیل ضخامت بالای پوشش رسوبی، شناخت هندسه سنگ‌بستر در آن با عدم قطعیت قابل توجهی همراه است (مورلی و همکاران، ۲۰۰۹) (شکل ۸).


۴. وارون‌سازی داده‌های واقعی با استفاده از مدل DNN منطقه ریگ‌جن در شمال شهر انارک، غرب جندق، جنوب دریاچه نمک سمنان و شرق پارک ملی کویر واقع شده و بخشی از کویر بزرگ ایران محسوب می‌شود. این محدوده در مرز بین استان اصفهان (شهرستان نائین) و استان سمنان (شهرستان‌های سمنان و سرخه) قرار دارد. جنوب محدوده مورد مطالعه با گسل درونه و شمال آن با گسل کوه گوگرد محدود شده است. مختصات تقریبی منطقه بین ۵۳ تا ۵۴ درجه طول شرقی و ۳۳/۸ تا ۳۴/۷ درجه عرض شمالی قرار دارد (شکل ۸).

پس از کاهش فعالیت‌های ماگمایی در اواخر ائوسن، این واحدها دچار بالاآمدگی و فرسایش شده و شرایط برای رسوب‌گذاری گسترده در حوضه ایران مرکزی فراهم شد. بدین‌ترتیب، توالی رسوبی سنوزوئیک شامل سازند قرمز زیرین، سازند قم و سازند قرمز بالایی بر روی سنگ‌های آتشفشانی-رسوبی ائوسن نهشته شد (عباسی و همکاران، ۲۰۲۰) (شکل ۷). این توالی، گذار محیطی از شرایط دریایی کم‌عمق به محیط‌های قاره‌ای را نشان می‌دهد که سنگ‌های آتشفشانی ائوسن را به‌عنوان پی‌سنگ ساختاری و مغناطیسی منطقه می‌پوشاند.



شکل ۷. واحدهای سنگ‌چینه‌ای در بخش غربی حوضه ایران مرکزی (عباسی و همکاران، ۲۰۲۰).


حوضه رسوبی ایران مرکزی به‌عنوان بزرگ‌ترین حوضه رسوبی کشور، به‌دلیل پتانسیل هیدروکربنی، همواره مورد توجه مطالعات اکتشافی بوده است. در این حوضه، سنگ‌های آتشفشانی ائوسن که مستقیماً توسط رسوبات



شکل ۸. نقشه زمین‌شناسی منطقه مورد مطالعه (برگرفته از عباسی و همکاران (۲۰۲۰) با کمی تغییر).

پروفیل‌های منفرد آموزش دیده است، اما طراحی مقاطع پروفیل‌ها امکان ارزیابی سازگاری فضایی نتایج را در یک چارچوب شبه‌سهم‌بندی را فراهم می‌کند. به کارگیری مدل دوبعدی از پیش آموزش دیده و تلفیق خروجی‌های آن در قالب شبکه‌ای از پروفیل‌های مقاطع، تخمینی از هندسه سنگ‌بستر را با صرف هزینه و منابع بسیار کمتر نسبت به توسعه یک مدل کامل سهم‌بندی ممکن می‌سازد. ایجاد مدل سهم‌بندی مستلزم تولید مجموعه داده‌های مصنوعی بسیار بزرگ، طراحی معماری پیچیده و منابع محاسباتی قابل توجه است؛ در حالی که رویکرد پیشنهادی حاضر با حفظ دقت قابل قبول، کارایی عملیاتی بالاتری دارد و تخمینی عملی و قابل اعتماد از ساختار سنگ‌بستر ارائه می‌دهد.

به منظور بررسی ویژگی‌های ساختاری و مغناطیسی منطقه ریگ‌جن، یک شبکه مقاطع شامل هشت پروفیل طراحی شد. این شبکه شامل دو مجموعه چهارتایی عمود بر هم در راستاهای شمال‌شرق-جنوب‌غرب و شمال‌غرب-جنوب‌شرق است. طول هر پروفیل ۸۰ کیلومتر و فاصله بین پروفیل‌های موازی تقریباً ۲۰ کیلومتر در نظر گرفته شد. داده‌های مغناطیسی مورد استفاده از داده‌های مغناطیس هوابرد ایران استخراج شده‌اند (شکل ۹). لازم به ذکر است که داده‌های مغناطیسی هوابرد پیش از اعمال به مدل شبکه عصبی، عملیات برگردان به قطب RTP (Reduction to Pole) شده‌اند. اگرچه مدل DNN برای وارون‌سازی دوبعدی و تحلیل



شکل ۹. داده مغناطیس هوابرد منطقه مورد مطالعه.


۵. نتایج وارون سازی داده های ریگ جن

تعیین هندسه و عمق سنگ بستر مغناطیسی نقش کلیدی در درک تکامل تکتونیکی و ارزیابی پتانسیل های ساختاری حوزه های رسوبی ایفا می کند. در این پژوهش، مدل شبکه عصبی عمیق آموزش دیده به منظور برآورد توپوگرافی سنگ بستر مغناطیسی منطقه ریگ جن بر روی داده های مغناطیسی واقعی اعمال شد.

نتایج وارون سازی در امتداد پروفیل های L1 تا L4 و T1 تا T4 در شکل ۱۰ ارائه شده است. مدل توسعه یافته توانسته تغییرات میدان مغناطیسی مشاهده شده را با دقت مطلوبی بازتولید کند. مقدار RMSE داده های مغناطیسی در پروفیل ها بین ۱/۶ تا ۵/۹ نانوتسلا (میانگین ۳/۹ نانوتسلا) است که نشان دهنده تطابق قابل قبول بین داده های مشاهده ای و محاسبه ای می باشد (شکل ۱۰ و شکل ۱۲). عمق سنگ بستر مغناطیسی در بازه ۵ تا ۱۴ کیلومتر برآورد

شده که با ضخامت قابل توجه رسوبات در حوزه ایران مرکزی سازگار است.

به منظور بررسی پیوستگی فضایی، مقادیر عمق سنگ بستر بین پروفیل ها درونیابی شد و یک مدل سه بعدی از توپوگرافی سنگ بستر تهیه شد (شکل ۱۱). مدل حاصل وجود یک حوزه رسوبی ناهمگن با تغییرات جانبی قابل توجه در عمق سنگ بستر را نشان می دهد. بیشترین عمق پیش بینی شده در این مدل در بازه ۱۳ تا ۱۴ کیلومتر قرار دارد که بخش غربی حوزه را در بر می گیرد. بر اساس نتایج، حوزه رسوبی ریگ جن به دو پهنه اصلی قابل تفکیک است که توسط یک بالآمدگی ساختاری سنگ بستر با راستای تقریبی شمالی-جنوبی از یکدیگر جدا می شوند. این الگوی فضایی می تواند بازتابی از کنترل های ساختاری و تکتونیکی منطقه، از جمله گسل های عمیق و ناهمگنی های ماگمایی در سنگ بستر مغناطیسی، باشد.



شکل ۱۰. نتایج وارون‌سازی در امتداد پروفیل‌های منطقه مورد مطالعه. پنل‌های سمت چپ مربوط به پروفیل‌های L1 تا L4 و پنل‌های سمت راست مربوط به T1 تا T4 هستند (به ترتیب از بالا به پایین). در بخش بالایی هر تصویر، آنومالی مغناطیسی مشاهده‌ای (منحنی قرمز)، محاسبه‌شده (خط چین آبی) و آنومالی مغناطیسی مدل تکنیک و قدس (۲۰۱۷) (خط چین سبز) همراه با مقدار RMSE (نانوتسلا) نشان داده شده است. در بخش پایینی، عمق سنگ‌بستر برآوردشده توسط روش پیشنهادی (خط چین قرمز) در کنار نتایج تکنیک و قدس (۲۰۱۷) (منحنی آبی) مقایسه شده است.

خطی نمودار لگاریتم توان طیفی بر حسب عدد موج برآورد می‌شود.

مقایسه نتایج این پژوهش با مدل مذکور (شکل ۱۱) اختلاف‌هایی را، به‌ویژه در بخش‌های مرکزی و جنوب شرقی حوضه، نشان می‌دهد. مدل DNN برازش

به‌منظور ارزیابی نتایج، مقایسه‌ای با مدل ارائه‌شده توسط تکنیک و قدس (۲۰۱۷) انجام شد. ایشان با استفاده از تحلیل طیفی فرکتالی داده‌های مغناطیسی هوابرد در حوزه عدد موج، نقشه عمق سنگ‌بستر ایران را تهیه کرده‌اند. در این روش، عمق سنگ‌بستر از شیب بخش

داده شود.


۶. عدم قطعیت نتایج و ارزیابی خطا

ارزیابی جامع عملکرد مدل و شناسایی منابع عدم قطعیت، برای تفسیر قابل اطمینان نتایج ضروری است. اگرچه مدل در بخش قابل توجهی از سناریوها رفتاری پایدار داشته، اما نمی‌توان ادعا کرد که در تمامی مدل‌های زمین‌شناسی خطای ناچیزی نشان می‌دهد.


مهم‌ترین منبع عدم قطعیت در این پژوهش، فرض ساده‌سازانه مربوط به مقدار خودپذیری مغناطیسی سنگ‌بستر ($0.34 \pm$ واحد SI) است. این مقدار بر اساس مطالعه تکنیک و همکاران (۲۰۱۹) و با توجه به قرارگیری منطقه مورد مطالعه در پهنه تکتونیکی ایران مرکزی انتخاب شده است. اگرچه این فرض برای کاهش تعداد پارامترهای مجهول ضروری بود، اما خودپذیری مغناطیسی در واقعیت می‌تواند در طول یک پروفیل و بین پروفیل‌ها تغییر کند و مستقیماً بر دامنه و شکل آنومالی مغناطیسی اثر بگذارد.

بهتری با داده‌های مغناطیسی مشاهده‌ای دارد. میانگین RMSE آن حدود $3/9$ نانوتسلا (در محدوده $1/6$ تا $5/9$ نانوتسلا) است، در حالی که این مقدار برای مدل تکنیک و قدس به طور میانگین $44/7$ نانوتسلا (در محدوده $18/9$ تا $72/1$ نانوتسلا) محاسبه شد (شکل ۱۰). با این وجود، هر دو روش میانگین عمق سنگ‌بستر را حدوداً 11 کیلومتر برآورد کرده‌اند که نشان‌دهنده همخوانی نسبی در محدوده کلی عمق‌ها است.

پایداری و انسجام درونی مدل از طریق ارزیابی نتایج در نقاط تقاطع شبکه پروفیل‌های متعامد تأیید شد. در این نقاط، اختلاف میان عمق‌های برآوردشده از دو پروفیل مستقل محاسبه شد. میانگین این اختلاف حدود 400 متر است که در مقیاس عمق کلی حوضه (5 تا 14 کیلومتر) بسیار کوچک بوده و نشان‌دهنده سازگاری و تکرارپذیری مناسب مدل می‌باشد. اختلاف‌های بزرگ‌تر (در صورت وجود) می‌تواند به پیچیدگی ساختاری، تغییرات جانبی در مغناطیس‌پذیری یا محدودیت‌های رویکرد دوبعدی نسبت



شکل ۱۱. مدل سه‌بعدی توپوگرافی سنگ‌بستر حاصل از درون‌یابی پروفیل‌ها. پل راست نتایج روش تکنیک و قدس (۲۰۱۷) و پل چپ نتایج روش DNN این پژوهش را نشان می‌دهد.




شکل ۱۲. ارزیابی کیفی عملکرد مدل DNN در بازتولید داده‌های مغناطیسی منطقه. پل چپ: آنومالی محاسبه‌شده توسط مدل، پل میانی: داده‌های مشاهده‌ای (مغناطیس هوابرد)، پل راست: نقشه اختلاف (مشاهده‌ای منهای محاسبه‌ای).


به دست آمد که تنها تفاوت آنها ناشی از تغییر خودپذیری است.

برای کمی سازی عدم قطعیت، انحراف معیار عمق پیش بینی شده در هر نقطه محاسبه شد. نتایج این تحلیل در شکل ۱۳ (دوبعدی) و شکل ۱۴ (شبه سه بعدی) ارائه شده است. میانگین انحراف معیار عمق در تمام پروفیل ها حدود ۱۲۶ متر و حداکثر آن (عمدتاً در بخش های عمیق حوضه) حدود ۴۱۷ متر است که در مقیاس کلی عمق حوضه (۵ تا ۱۴ کیلومتر) می تواند ناچیز فرض باشد. این یافته بر اهمیت در نظر گرفتن تغییرات جانبی خودپذیری در تفسیر نتایج و توسعه مدل های آتی تأکید می کند.

برای ارزیابی حساسیت مدل به تغییرات خودپذیری، یک آزمون تحلیلی طراحی شد. ابتدا عمق پیش بینی شده توسط مدل DNN به عنوان عمق مرجع در نظر گرفته شد. سپس با فرض ثابت بودن هندسه سنگ بستر، پاسخ مغناطیسی برای مقادیر مختلف خودپذیری در بازه ۰/۰۲۸ تا ۰/۰۴۰ واحد SI و با گام ۰/۰۰۲ محاسبه شد. این بازه دامنه واقع بینانه ای از تغییرات احتمالی خودپذیری منطقه را پوشش می دهد. در گام بعد، هر یک از پاسخ های مغناطیسی محاسبه شده، بدون آموزش مجدد، به ورودی مدل اعمال شد و عمق سنگ بستر مجدداً پیش بینی شد. بدین ترتیب برای هر پروفیل، هفت تخمین مستقل از عمق



شکل ۱۳. تحلیل حساسیت مدل DNN نسبت به تغییرات خودپذیری مغناطیسی در بازه ۰/۰۲۸ تا ۰/۰۴۰ (SI). پروفیل L1-L4 در پنل چپ و پروفیل T1-T4 در پنل راست، به ترتیب از بالا به پایین، نشان داده شده است. در بخش بالایی هر تصویر، آنومالی مغناطیسی مشاهده ای (خط مشکی) و در بخش پایینی، عمق پیش بینی شده سنگ بستر (خط قرمز) همراه با نوار بنفش (محدوده انحراف معیار ناشی از تغییرات خودپذیری) ارائه شده است.



شکل ۱۴. توزیع سه بعدی عدم قطعیت ناشی از تغییرات خودپذیری مغناطیسی. پتل چپ: انحراف معیار عمق سنگ بستر، پتل راست: انحراف معیار آنومالی مغناطیسی (محاسبه شده از هفت سناریوی خودپذیری متفاوت).

۷. بحث

تفسیر نتایج این تحقیق و تحلیل اختلافات آن با مطالعه پیشین، مستلزم در نظر گرفتن فرضیات و محدودیت‌های ذاتی روش به کار گرفته شده است. همان‌طور که در بخش "عدم قطعیت نتایج و ارزیابی خطا" به تفصیل مورد بررسی قرار گرفت، اصلی‌ترین منبع عدم قطعیت کمی در این مطالعه، فرض مقدار ثابت برای خودپذیری مغناطیسی سنگ بستر ($SI=0.034$) است. تحلیل حساسیت انجام شده نشان داد که تغییرات واقع بینانه این پارامتر اثر قابل قبولی بر برآورد عمق داشته و مدل از پایداری نسبی برخوردار است (بخش ۵ و شکل ۱۳ و شکل ۱۴).

علاوه بر این، عواملی دیگر نیز بر دقت نهایی مدل تأثیر گذارند. نخست، مدل برای شناسایی ساختارهایی آموزش دیده که میانگین عمق و دامنه ناهمواری‌های آنها به ترتیب در بازه‌های از پیش تعریف شده ۳ تا ۱۵ کیلومتر و ۳ تا ۱۱ کیلومتر قرار دارد. این بازه‌ها اگرچه بر اساس دانش پیشین از منطقه انتخاب شدند، اما در صورتی که ساختار واقعی سنگ بستر خارج از این حدود باشد، دقت مدل کاهش می‌یابد. دوم، عملکرد بهینه شبکه‌های عصبی عمیق منوط به تناسب داده‌های آموزشی با شرایط واقعی منطقه است. این مدل‌ها عمدتاً برای محیط‌هایی با ویژگی‌های فیزیکی و ابعادی مشابه داده‌های مصنوعی قابل اطمینان هستند و تعمیم نتایج به محیط‌های متفاوت نیازمند احتیاط و

اعتبارسنجی تکمیلی است.

بنابراین، اختلاف مشاهده شده بین نتایج این پژوهش و مطالعه تکنیک و قدس (۲۰۱۷) را می‌توان حاصل ترکیبی از عدم قطعیت در پارامترهای فیزیکی، محدودیت در دامنه پارامترهای آموزشی و تفاوت‌های روش مدل‌سازی دانست. تفاوتی که با توجه به ماهیت متفاوت دو روش (طیفی فرکانس در حوزه عدد موج در مقابل وارون‌سازی مبتنی بر شبکه عصبی عمیق در حوزه فضا) قابل انتظار است.

۸. نتیجه گیری

در این پژوهش، از یک مدل شبکه عصبی عمیق برای وارون‌سازی داده‌های مغناطیس هوابرد و تعیین توپوگرافی سنگ بستر حوضه ریگ جن استفاده شد. مدل ارائه شده توانست نداشت غیرخطی بین آنومالی مغناطیسی و عمق سنگ بستر را با موفقیت بیاموزد و تخمینی سازگار و زمین‌شناسی معقول ارائه دهد که با الگوی کلی میدان مغناطیسی منطقه همخوانی داشت. میانگین RMSE داده‌های مغناطیسی در پروفیل‌ها حدود ۳/۹ نانوتسلا بود که در مقایسه با مدل تکنیک و قدس (۲۰۱۷) با میانگین RMSE حدود ۴۴/۷ نانوتسلا، نشان‌دهنده برآزش بهتر روش پیشنهادی است. پایداری فضایی مدل نیز با همخوانی مناسب نتایج در نقاط تقاطع پروفیل‌های مستقل (میانگین

اختلاف عمق حدود ۴۰۰ متر) تأیید شد.

اگرچه مدل تحت تأثیر فرضیات ساده‌سازانه (مانند خودپذیری ثابت) بود، اما تحلیل عدم قطعیت نشان داد که نتایج در برابر تغییرات واقع‌بینانه این پارامتر از پایداری نسبی برخوردارند؛ به طوری که میانگین انحراف معیار عمق حدود ۱۲۶ متر و حداکثر آن ۴۱۷ متر برآورد شد که در مقیاس عمق کلی حوضه (۵ تا ۱۴ کیلومتر) ناچیز است. در مقایسه با روش‌های مرسوم، رویکرد DNN مزایایی نظیر سرعت بالای استنتاج و کاهش وابستگی به مدل اولیه دارد. با این حال، عملکرد این روش به کیفیت و تنوع داده‌های

مصنوعی آموزشی و همچنین دانش قبلی از محدوده پارامترهای منطقه وابسته است.

در مجموع، روش شبکه عصبی عمیق به عنوان ابزاری مکمل و کارآمد در اکتشاف ساختار عمقی در حوضه‌های رسوبی کم‌داده، نظیر ریگ‌جن، معرفی می‌شود. در حوضه‌های فاقد اطلاعات کافی از سنگ‌بستر، تخمین‌های حاصل از این روش می‌تواند به عنوان پیش‌فرض اولیه برای مطالعات بعدی به کار رود.

مراجع

- Abbasi, G., Motamedi, H., Orang, K., & Nickandish, A. A. (2020). Petroleum geology of the western part of the Central Iran Basin. *Journal of Petroleum Geology*, 43(2), 171-190.
- Ashena, Z., Kabirzadeh, H., Kim, J.W., Wang, X. and Ali, M., 2023. A Novel 2.5 D Deep Network Inversion of Gravity Anomalies to Estimate Basement Topography. *SPE Reservoir Evaluation & Engineering*, 26(04), pp.1484-1497.
- Ballato, P., Uba, C.E., Landgraf, A., Strecker, M.R., Sudo, M., Stockli, D.F., Friedrich, A. and Tabatabaei, S.H., 2011. Arabia-Eurasia continental collision: Insights from late Tertiary foreland-basin evolution in the Alborz Mountains, northern Iran. *Bulletin*, 123(1-2), pp.106-131.
- Berberian, F. and Berberian, M.J.Z.H.K.H.G.E., 1981. Tectono-plutonic episodes in Iran. *Zagros Hindu Kush Himalaya Geodynamic Evolution*, 3, pp.5-32.
- Berberian, M. and King, G.C.P., 1981. Towards a paleogeography and tectonic evolution of Iran. *Canadian journal of earth sciences*, 18(2), pp.210-265.
- Chollet, F. & others. (2015). Keras. Available at: <https://keras.io>
- Glumov, I.F., Malovitskiy, Y.P., Novikov, A.A. and Senin, B.V., 2004. Regional geology and oil and gas content of Caspian Sea. Nedra, Moscow.
- Hendrycks, D., & Gimpel, K. (2016). Gaussian error linear units (gelus). arXiv preprint arXiv:1606.08415.
- Hu, Z., Liu, S., Hu, X., Fu, L., Qu, J., Wang, H., & Chen, Q. (2021). Inversion of magnetic data using deep neural networks. *Physics of the Earth and Planetary Interiors*, 311, p.106653.
- Jackson, M.P.A., Cornelius, R.R., Craig, C.H., Gansser, A., Stöcklin, J., & Talbot, C.J. (1990). Salt diapirs of the Great Kavir, central Iran.
- Kamyab, S., Azimifar, Z., Sabzi, R., & Fieguth, P. (2022). Deep learning methods for inverse problems. *PeerJ Computer Science*, 8, e951.
- Kordi, M. (2019). Sedimentary basin analysis of the Neo-Tethys and its hydrocarbon systems in the Southern Zagros fold-thrust belt and foreland basin. *Earth-Science Reviews*, 191, 1-11.
- Loshchilov, I., & Hutter, F. (2017). Decoupled weight decay regularization. arXiv preprint arXiv:1711.05101.
- Menke, W. (2018). Geophysical data analysis: Discrete inverse theory. Academic press.
- Morley, C.K., Kongwung, B., Julapour, A.A., Abdolghafourian, M., Hajian, M., Waples, D., Warren, J., Otterdoorn, H., Srisuriyon, K., & Kazemi, H. (2009). Structural development of a major late Cenozoic basin and transpressional belt in central Iran: The Central Basin in the Qom-Saveh area. *Geosphere*, 5(4), pp.325-362.
- Nadimi, A. (2007). Evolution of the Central Iranian basement. *Gondwana Research*, 12(3), pp.324-333.
- Omrani, J., Agard, P., Whitechurch, H., Benoit, M., Prouteau, G., & Jolivet, L. (2008). Arc-magmatism and subduction history beneath the Zagros Mountains, Iran: a new report of adakites and geodynamic consequences. *Lithos*, 106(3-4), pp.380-398.
- Plouff, D. (1976). Gravity and magnetic fields of polygonal prisms and application to magnetic terrain corrections. *Geophysics*, 41(4), 727-741.
- Radfar, J., Amini Chehragh, M. R., & Emani, M. H. (1999). 1: 100,000 geological map of the Ardestan. Geological Survey of Iran (GSI), Tehran.
- Rao, D. B., & Babu, N. R. (1991). A rapid method for three-dimensional modeling of magnetic anomalies. *Geophysics*, 56(11), 1729-1737.
- Shafaii Moghadam, H., Griffin, W.L., Kirchenbaur, M., Garbe-Schönberg, D., Zakie Khedr, M., Kimura, J.I., Stern, R.J., Ghorbani,

- G., Murphy, R., O'Reilly, S.Y., & Arai, S. (2018). Roll-back, extension and mantle upwelling triggered Eocene potassic magmatism in NW Iran. *Journal of Petrology*, 59(7), pp.1417-1465.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- Talwani, M. (1965). Computation with the help of a digital computer of magnetic anomalies caused by bodies of arbitrary shape. *Geophysics*, 30(5), 797-817.
- Teknik, V., & Ghods, A. (2017). Depth of magnetic basement in Iran based on fractal spectral analysis of aeromagnetic data. *Geophysical Journal International*, 209(3), pp.1878-1891.
- Teknik, V., Ghods, A., Thybo, H., & Artemieva, I. M. (2019). Crustal density structure of the northwestern Iranian Plateau. *Canadian Journal of Earth Sciences*, 56(12), 1347-1365.
- Utsugi, M. (2019). 3-D inversion of magnetic data based on the L1-L2 norm regularization. *Earth, Planets and Space*, 71(1), 73.
- Verdel, C., Wernicke, B. P., Hassanzadeh, J., & Guest, B. (2011). A Paleogene extensional arc flare-up in Iran. *Tectonics*, 30(3).
- Vitale, A., Gabbriellini, G., & Fedi, M. (2023). Deep learning to estimate the basement depth by gravity data using a feedforward neural network. *Geophysics*, 88(3), G95-G103.
- Wu, G., Wei, Y., Dong, S., Zhang, T., Yang, C., Qin, L., & Guan, Q. (2023). Improved Gravity Inversion Method Based on Deep Learning with Physical Constraint and Its Application to the Airborne Gravity Data in East Antarctica. *Remote Sensing*, 15(20), 4933.