

مدل سازی دو بعدی بی هنجاری های مغناطیسی با استفاده از شبکه عصبی پیشخور

احمد افشار^۱، میثم عابدی^۱، غلامحسین نوروزی^۲، وحید ابراهیم زاده اردستانی^{۳*} و کارو لوکس^۴

^۱دانشجوی کارشناسی ارشد مهندسی اکتشاف معدن، پردیس دانشکده های فنی دانشگاه تهران، ایران

^۲دانشیار، دانشکده مهندسی معدن، پردیس دانشکده های فنی دانشگاه تهران، ایران

^۳دانشیار، گروه فیزیک زمین، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

^۴استاد، دانشکده مهندسی برق و کامپیوتر، پردیس دانشکده های فنی دانشگاه تهران، ایران

aafshar.m@gmail.com, mabedi.mine@gmail.com, norouzih@ut.ac.ir, ebrahimz@ut.ac.ir, lucas@ut.ac.ir

(تاریخ دریافت: ۱۳۸۸/۱/۳۰، تاریخ پذیرش: ۱۳۸۹/۳/۲۶)

چکیده

در این مقاله، برای مدل سازی بی هنجاری های مغناطیسی از شبکه عصبی پیشخور استفاده شده، و مدل سازی با فرض شکل دایک شیبدار با گسترش نامحدود، انجام شده است. این روش قابلیت تخمین تمام پارامتر های هندسی یعنی؛ مختصات مرکز دایک بر روی پروفیل، عمق، شیب و عرض دایک را دارد.

ابتدا کارائی این روش، با مدل های مصنوعی بدون نویه و نو فهدار آزمایش شد، که نتایج رضایت بخشی بدست آمد. سپس از آن برای تفسیر داده های مغناطیس سنجی معدن مروارید زنجان، استفاده شد. نتایج حاصل از مدل سازی، با نتایج روش دیکانولوشن اولر و اطلاعات حاصل از ترانشه ها و خفاری مطابقت بسیار خوبی دارد.

واژه های کلیدی: شبکه عصبی پیشخور، بی هنجاری مغناطیسی، دایک، داده های آموزشی

2D modeling of magnetic anomaly through feed forward neural network

Ahmad Afshar¹, Meysam Abedi¹, Gholam Hossain Norouzi¹, Vahid Ebrahimzadeh Ardestani^{2*}, and Caro Lucas³

¹Faculty of Mining Engineering, University of Tehran, Iran

²Institute of Geophysics, University of Tehran, Iran

³Faculty of Electrical and Computer Engineering, University of Tehran, Iran

(Received: 19 April 2009, accepted: 16 June 2010)

Summary

One of the most important goals of magnetic data interpretation is to determine location, depth and shape of the magnetic anomaly. Extensive use of magnetic surveys in the field of mineral exploration, geology and environmental application make earth scientists to present suitable interpretation schemes.

Neural networks are part of a much wider field called artificial intelligence which have computer algorithm that solve several types of problems. The problems include classification, parameter estimation, parameter prediction, pattern recognition,

*Corresponding author:

ebrahimz@ut.ac.ir

*نگارنده رابطه:

completion, association, filtering, and optimization. The NNs are used in different aspects of interpretation and modeling of geophysics data. They are used for inverting geophysical data involving problems for which no easy solutions exist.

In this paper, Feed Forward Neural Network (FNN) is used for the magnetic anomaly modeling with assumption an infinite depth extent dike. The method can estimate all the geometric parameters of the dike; horizontal location on profile, width, depth and dip.

We used a three layer FNN; consisting of 11 neurons in the input layer, 20 neurons in the hidden layer and 4 neurons in the output layer. For the first and hidden layers, and the last layer sigmoid and linear activation functions are used, respectively. Here, the horizontal location, width, depth and dip of the dike were defined as the output and the magnetic profile data as the input of the neural network. The training of the network was done through synthetic data which were produced by forward modeling.

For preventing the neural network from holding to any particular sequence, the input data were assigned in a random and then, the profile related to these data was obtained by dike equation. For the FNN to recognize the pattern of the profile data, some parameters are defined as the input of the FNN. These parameters should be separated. In other words, they must have a relation with the geometrical parameters of the dike. In definition of the parameters from the Anomaly curve, maximum and minimum points, width of curve in points of 75% and 50% of maximum, area of positive and negative parts of anomaly curve are used. Furthermore, the width and depth of the dike may be found through using a horizontal derivative of anomaly and a derivative of Hilbert transform. Horizontal derivation of Anomaly curve and Hilbert transform of horizontal derivation, especially from their intersection points, are also used as input parameters of neural network.

The validity of this method was tested by using of noise-free and noise-corrupted synthetic models that satisfactory results were obtained. Then the Morvarid mine ,which located at a distance of 30Km south east of Zanjan, near Aliabad village, is chosen as a real data application. The outputs show a good accordance with the Euler method and the tranches results.

The FNN inversion provides satisfactory results despite the noise. Various techniques are applied for interpretation of magnetic data. Most of them estimate only the depth. So, careful determination of dip, depth and width of the dike are the benefits of the use of the FNN.

Key words: Feed forward neural network, magnetic anomaly, dike, training data

گرانی‌سنگی ارائه شده، که هر کدام از آن‌ها دارای مزايا و
معایي هستند. برای تعیین مرزها و عمق بی‌هنجاري،
روش‌هایی بر پایه مشتقات میدان به کار گرفته شد(بليکلى،
۱۹۹۵؛ نبيقيان، ۲۰۰۵).

برخی از روش‌های مدل‌سازی بر اساس رابطه ميان
بی‌هنجاري مغناطیسی و ویژگی‌های منبع مغناطیسی با
فرض شکل‌های ساده، عمل می‌کنند(کيوستل و همکاران،
۲۰۰۸). از روش‌های خودکار مانند؛ طيف توانی،

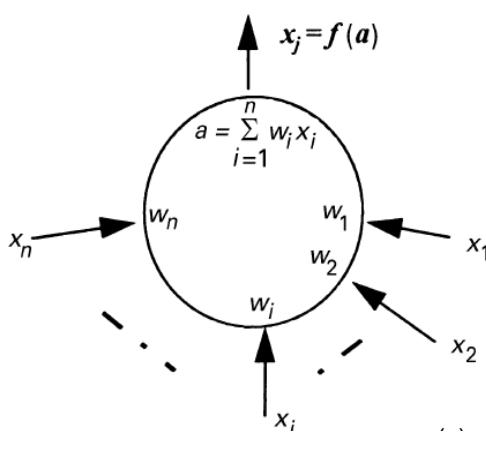
۱ مقدمه

یکی از اهداف مهم تفسیر داده‌های مغناطیسی تعیین محل،
عمق و شکل بی‌هنجاري‌های مغناطیسی می‌باشد. کاربرد
وسيع اكتشافات مغناطیسی در زمینه‌های اكتشاف منابع
معدنی، کاربردهای زمین‌شناسی و زیست محیطی،
دانشمندان علوم زمین را در طرح راهکارهای مناسب در
اين زمينه، به تلاش واداشته است. تاکنون روش‌های
متعددی برای تفسیر داده‌های مغناطیس‌سنگی و

نگاشت بردار ورودی بر روی بردار خروجی است (ماکیاس و همکاران، ۲۰۰۰).

مطابق شکل ۱ در یک نرون، هر مولفه از بردار ورودی در وزن متناظر ضرب شده و مجموع آنها، ورودی شبکه را تشکیل می‌دهد. انتقال ورودی شبکه به خروجی توسطتابع تحریک انجام می‌شود. نرون‌ها در یک شبکه پیشخور در لایه‌های متواالی قرار گرفته‌اند، به طوریکه هر نرون فقط با نرون‌های لایه‌های بعدی ارتباط داشته و با نرون‌های لایه‌خود ارتباطی ندارد (شکل ۲) (ماکیاس و همکاران، ۲۰۰۰).

جريان داده‌ها از لایه اول یا لایه ورودی شروع شده و وزن‌ها عمدتاً با حداقل سازی اختلاف بین خروجی‌های شبکه و خروجی‌های مطلوب، محاسبه می‌شوند. در شبکه عصبی به فرآیند یافتن وزن‌های بهینه، آموزش شبکه و مجموعه داده‌های ورودی- خروجی، داده‌های آموزش گفته می‌شود. هدف از آموزش شبکه، ایجاد تناظر یک به یک بین الگوی ورودی و خروجی معلوم، در مساله مورد نظر است. سپس از شبکه آموزش یافته، در محاسبه خروجی مجهول در ازای ورودی معین استفاده می‌شود. از این نظر شبکه عصبی یکتابع غیر خطی است که فرآیند آموزش، مساله بهینه‌سازی و وزن‌ها، پارامترهایی هستند که باید تخمین زده شوند (راملهارت و همکاران، ۱۹۸۶).



دیکانولوشن اولر و دیکانولوشن ورنر برای تفسیر سریع و تعیین عمق بی‌亨جاری‌ها استفاده شده است (تلفورد و همکاران، ۱۹۸۸؛ تامپسون، ۱۹۸۲؛ هانسن و سیموندز، ۱۹۹۳).

شبکه‌های عصبی شاخه‌ای از هوش مصنوعی است که دارای الگوریتم‌های کامپیوتی در زمینه‌های متفاوت؛ طبقه‌بندی و تشخیص الگوهای تخمین پارامتر و غیره می‌باشد. تفسیر و مدل‌سازی داده‌های ژئوفیزیکی در زمینه‌های مختلف، با این ابزار طی سال‌های اخیر انجام گرفته است (عثمان و همکاران، ۲۰۰۷). سالم و همکاران (۲۰۰۱) از آن برای تعیین محل لوله‌های مدفون با دوقطبی مغناطیسی استفاده کردند. اسلام و همکاران (۲۰۰۱) با استفاده از شبکه عصبی پرسپترون چند لایه با الگوریتم آموزش پس انتشار خطأ، عمق و شعاع حفره‌های زیرزمینی را از روی داده‌های میکروگرانی‌سنجدی تخمین زدند. البورا و همکاران (۲۰۰۱) از شبکه عصبی سلولی Cellular Neural Network برای جداسازی میدان مغناطیسی منطقه‌ای از محلی استفاده کردند.

در این مطالعه، از شبکه عصبی پیشخور (Feed Forward) برای مدل‌سازی بی‌亨جاری مغناطیسی حاصل از یک دایک شیدار با گسترش نامحدود استفاده شده است. صحت و دقت روش پیشنهادی برای مدل‌های مصنوعی نوونه دار و بدون نوونه مورد آزمایش واقع شده، سپس برای مدل‌سازی داده‌های مغناطیسی‌سنجدی در معدن مروارید زنجان، بکار گرفته شده است.

۲ شبکه عصبی پیشخور
شبکه‌های عصبی پیشخور به علت سهولت کاربرد و توانایی زیاد به طور گسترده در حل مسائل مختلف از قبیل تشخیص الگو کاربرد دارند. این شبکه از یک سری نرون یا اجزای پردازشگر تشکیل شده، که هر نرون شامل برداری از وزن‌های قابل تنظیم است. وظیفه هر نرون،

در این رابطه، پارامتر α شیب تابع را در $x = 0$ است و وسعت ناحیه خطی بودن تابع را کنترل می‌کند. این مقدار در تابع تحریک حلقوی، عددی نزدیک یک است. به طور مشابه خروجی شبکه را می‌توان به صورت زیر بیان کرد (ماکیاس و همکاران، ۲۰۰۰):

$$o_k^q = f^o \left(\sum_{i=1}^L W_{kj}^o a_j^q + c_k \right), \quad (3)$$

در این رابطه، o_k^q ، k امین خروجی شبکه به ازای q امین ورودی ($k=I, \dots, M$)، W_{kj}^o ، j امین وزن نرون، k بایاس، L تعداد نرون‌ها در لایه مخفی و f^o تابع تحریک لایه خروجی است. خطای اختلاف خروجی شبکه و خروجی مطلوب به صورت زیر تعریف می‌شود (ماکیاس و همکاران، ۲۰۰۰):

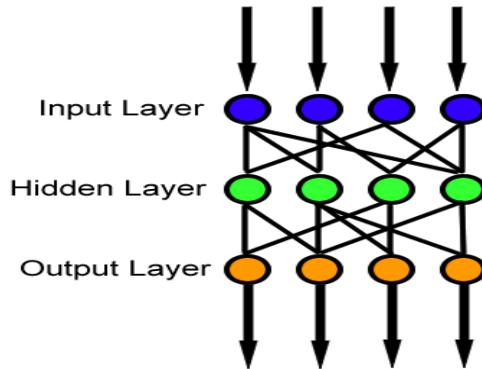
$$E = \frac{1}{2} \sum_{q=1}^Q \sum_{k=1}^M (y_k^q - o_k^q)^2, \quad (4)$$

در الگوریتم پس انتشار خطا، از لایه خروجی به سمت لایه ورودی (مسیر برگشت) بردار خطا توزیع می‌شود و گرادیان محلی نرون به نرون با الگوریتم بازگشته محاسبه می‌شود. در نهایت ماتریس‌های وزن و بردارهای بایاس با روابط زیر تنظیم می‌شوند (منهاج، ۱۳۷۹):

$$w_{kj}^o(l+1) = w_{kj}^o(l) + \eta \sum_{q=1}^Q \delta o_k^q a_j^q, \quad (5)$$

$$w_{kj}^h(l+1) = w_{kj}^h(l) + \eta \sum_{q=1}^Q \delta h_k^q a_j^q, \quad (6)$$

در این روابط، η نرخ آموزش است. هرچه این مقدار کوچکتر باشد، تغییرات اوزان شبکه در هر تکرار کوچکتر خواهد بود. از طرف دیگر، اگر سعی شود با افزایش η ، سرعت آموزش زیاد شود، تغییرات بزرگی در اوزان اتصال بوجود می‌آید که ممکن است شبکه را ناپایدار



شکل ۲. ساختار شبکه عصبی پیشخور با ۳ لایه.

۳ الگوریتم آموزش شبکه

در این مقاله، از الگوریتم پس انتشار (Back Propagation) که به طور خلاصه به نحوه عملکرد آن در ذیل اشاره می‌شود.

اگر بردارهای x با N عضو، ورودی شبکه و بردارهای y با M عضو، خروجی مطلوب شبکه باشد، می‌خواهیم با Q داده آموزشی، یک شبکه دولایه‌ای را آموزش دهیم. وقتی x^q (q امین بردار ورودی) به یکی از نرون‌های لایه مخفی می‌رسد، پاسخ نرون به صورت زیر خواهد بود (ماکیاس و همکاران، ۲۰۰۰):

$$a_j^q = f^h \left(\sum_{i=1}^N W_{ji}^h x_i^q + b_j \right), \quad (1)$$

در این رابطه، a_j^q پاسخ j امین نرون در لایه مخفی به q امین بردار ورودی (بالا نویس h معرف لایه مخفی)، w_{ji} وزن نرون زام، b_j بایاس و f^h تابع تحریک است. از تابع تحریک متعددی می‌توان استفاده نمود که در اینجا از تابع حلقوی (Sigmoid) با رابطه زیر، در لایه مخفی استفاده شده است (ماکیاس و همکاران، ۲۰۰۰؛ منهاج، ۱۳۷۹):

$$f(x) = \frac{1-e^{-2\alpha x}}{1+e^{2\alpha x}}, \quad (2)$$

۱-۴ مدل‌سازی مستقیم

برای ایجاد مدل‌های مصنوعی، مطابق شکل ۴، از مدل دایک شیبدار با گسترش نامحدود، با رابطه زیر استفاده شده است (مک‌گرات و هود، ۱۹۷۰).

$$T(x)$$

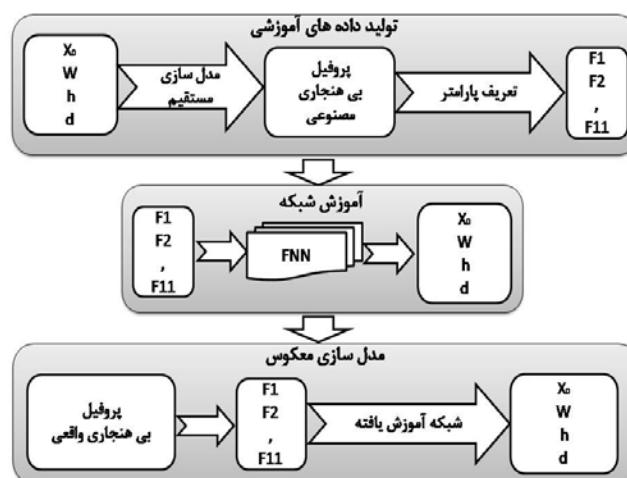
$$= kF \begin{pmatrix} \sin(\alpha) \begin{bmatrix} \tan^{-1}\left(\frac{x+b}{h}\right) \\ -\tan^{-1}\left(\frac{x-b}{h}\right) \end{bmatrix} \\ -\frac{\cos(\alpha)}{2} \ln \begin{bmatrix} (x+b)^2 + h^2 \\ (x-b)^2 + h^2 \end{bmatrix} \end{pmatrix}, \quad (7)$$

در این رابطه، $T(x)$ بی‌هنگاری میدان کلی ایجاد شده توسط دایک، k خودپذیری مغناطیسی، F میدان مغناطیسی زمین، I زاویه میل میدان زمین، b نصف عرض دایک (w)، d شیب، h عمق دایک، $x = x_j - x_o$ که x_j مختصات زمین نقطه از پروفیل برداشت است، x_o مختصات مرکز دایک و زاویه α به صورت $i + I - d$ تعریف می‌شود که i زاویه میل بردار مغناطیس شدگی دایک است. از آنجا که مدل‌سازی برای داده‌های برگردان به قطب انجام شده، زاویه میل میدان زمین و زاویه میل مغناطیس شدگی دایک برابر با هم و مساوی 90° درجه در نظر گرفته شده است.

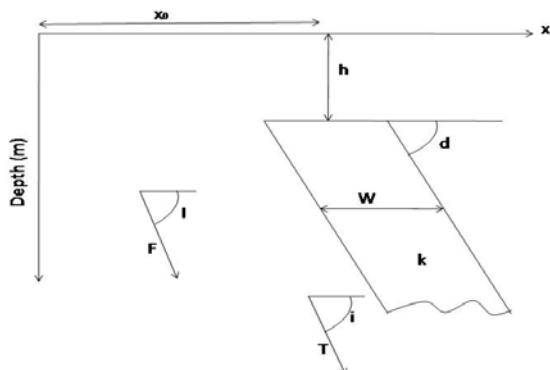
کند. مناسب‌ترین حالت این است که ضریب آموزش در ابتدا بزرگ‌گر انتخاب شود و در حین آموزش شبکه، به آرامی مقدار آن کاهش یابد. در این مقاله، از این روش استفاده شده است. جهت توقف تکرار الگوریتم از دو شاخص زیر به طور همزمان استفاده می‌شود؛ الف- میانگین خطای هرسیکل کمتر از مقدار از پیش تعیین شده باشد. ب- نرم گرادیان خطای خیلی کوچک باشد (منهاج، ۱۳۷۹).

۴ روش مدل‌سازی

در این مطالعه، از شبکه عصبی برای انجام مدل‌سازی معکوس استفاده شده است. مساله به این صورت است که مختصات مرکز، عرض، عمق و شیب دایک، خروجی شبکه و داده‌های پروفیل مغناطیسی به عنوان ورودی شبکه تعریف شده است. با توجه به زیاد بودن تعداد داده‌های پروفیل، به جای آنها پارامترهایی تعریف، و از این پارامترها به عنوان ورودی شبکه عصبی استفاده شده است. برای آموزش شبکه، با استفاده از مدل‌سازی مستقیم داده‌های مصنوعی تولید شده است. شکل ۳ نمودار کلی این روش را نشان می‌دهد.



شکل ۳. نمودار مراحل مدل‌سازی با شبکه عصبی.



شکل ۴. مدل دایک شبیدار با گسترش نامحدود (X_0) مختصات مرکز بی‌هنجاری، h عرض، k شیب، W عرض، d خودپذیری مغناطیسی، I زاویه میل میدان زمین، i زاویه مغناطیس شدگی، F میدان بی‌هنجاری دایک است. برای داده‌های برگردان به قطب، $I = 90^\circ$ می‌باشد).

پروفیل باید مشخصه باشند. به بیان دیگر، با پارامترهای هندسی دایک مرتبط باشند. در تعریف پارامترها، از مختصات و مقادیر ماکزیمم و مینیمم بی‌هنجاری، عرض منحنی در نقاط ۷۵ درصد و ۵۰ درصد ماکزیمم، همچنین مساحت بخش‌های مثبت و منفی منحنی بی‌هنجاری، استفاده شده است (شکل ۵).

علاوه بر این، موهان و همکاران (۱۹۸۵) نشان دادند که عرض دایک و عمق آن را می‌توان با استفاده از مشتق افقی میدان بی‌هنجاری و تبدیل هیلبرت (Hilbert Transform) مشتق بدست آورد. بنابراین، همانطوریکه در شکل ۶ نشان داده شده است، از مختصات نقطه ماکزیمم تبدیل هیلبرت مشتق (f_{θ}) و مختصات نقاطی که به ازای آن‌ها مشتق افقی میدان بی‌هنجاری و تبدیل هیلبرت آن مقادیر یکسانی دارند (f_{II} ، f_{I0}) نیز به عنوان ورودی شبکه عصبی، استفاده شده است.

بعد از تعیین ورودی و خروجی شبکه، برای مدل‌سازی شبکه پیشخور ۳ لایه، با ترکیب ۱۱ نرون در لایه اول (برابر با تعداد ورودی)، ۲۰ نرون در لایه مخفی و ۴ نرون در لایه آخر (برابر با تعداد خروجی)، طراحی شده است. برای لایه اول و لایه مخفی، از تابع تحریک حلقوی و در لایه آخر، تابع خطی بکار گرفته شده است. در نهایت شبکه با ۵۰۰۰ داده آموزشی، آموزش داده شده

۴-۲ تولید داده‌های آموزشی

برای اینکه شبکه عصبی هیچ ترتیب خاصی را حفظ نکند، بردارهای ورودی شبکه (پارامترهای هندسی دایک) با استفاده از روابط (۸)، به صورت تصادفی تولید شده، سپس پروفیل متناظر با این داده‌ها با رابطه (۷)، بدست آمده است.

$$\begin{aligned} x_o &= (x_{\max} - x_{\min}) \times \text{Rand} + x_{\min} \\ d &= (d_{\max} - d_{\min}) \times \text{Rand} + d_{\min} \\ h &= (h_{\max} - h_{\min}) \times \text{Rand} + h_{\min} \\ b &= (b_{\max} - b_{\min}) \times \text{Rand} + b_{\min} \end{aligned} \quad (8)$$

در روابط (۸)، Rand عددی بین صفر و یک است. با تعیین حدود تقریبی پارامترهای مدل (مقادیر ماکزیمم و مینیمم) از طریق اطلاعات حاصل از روش‌های ساده تفسیر داده‌های مغناطیس سنجی، دقت مدل‌سازی بیشتر می‌شود. در صورت عدم وجود اطلاعاتی از حدود پارامترهای مدل، می‌توان بازه مربوط به آن‌ها را بزرگ‌تر در نظر گرفت به طوریکه تمام جواب‌های نزدیک به واقعیت را شامل شود. در نتیجه، باید تعداد داده‌های آموزشی را نیز، افزایش داد.

برای اینکه شبکه عصبی الگوی بی‌هنجاری را در هر حالت شناسایی کند، پارامترهای تعریف شده از داده‌های

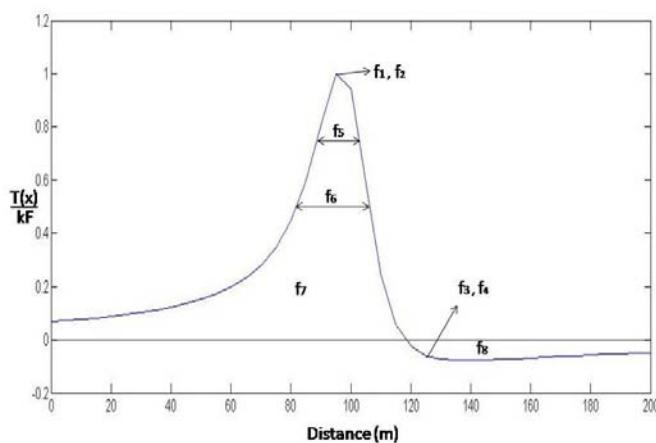
است. توضیح اینکه، تعداد نرون‌های لایه مخفی و همچنین تعداد داده‌های آموزشی با سعی و خطأ بدست آمده، این منظور آزمایش حساسیت مقادیر بدست آمده به نویه، به طور تصادفی نویه‌های ۵ و ۱۰ درصد در داده‌ها ایجاد شده، و نتایج مدل‌سازی برای داده‌های بدون نویه و نویه‌دار در جدول ۱ نشان داده شده است. همانطور که در این جدول ملاحظه می‌شود، مقادیر تخمین زده شده برای داده‌های بدون نویه، با خطای کمتر از ۲ درصد و برای داده‌های نویه‌دار، مقدار خطأ به ۱۰ درصد نمی‌رسد.

است. توضیح اینکه، تعداد نرون‌های لایه مخفی و همچنین تعداد داده‌های آموزشی با سعی و خطأ بدست آمده، این منظور آزمایش حساسیت مقادیر بدست آمده به نویه، به طور تصادفی نویه‌های ۵ و ۱۰ درصد در داده‌ها ایجاد شده، و نتایج مدل‌سازی برای داده‌های بدون نویه و نویه‌دار در جدول ۱ نشان داده شده است. همانطور که در این جدول ملاحظه می‌شود، مقادیر تخمین زده شده برای داده‌های بدون نویه، با خطای کمتر از ۲ درصد و برای داده‌های نویه‌دار، مقدار خطأ به ۱۰ درصد نمی‌رسد.

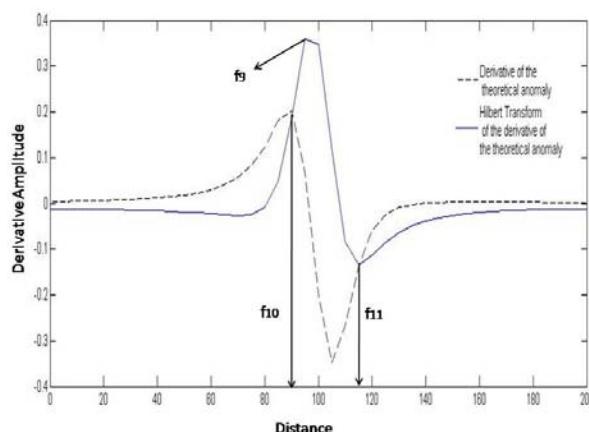
۵ بررسی کارائی روش با مدل‌های مصنوعی

۱-۵ مدل تئوریکی دو بعدی

این مدل، دایکی با مشخصات فرضی ($X_0 = 100 \text{ m}$)



شکل ۵. میدان بی هنجاری کلی حاصل از مدل دایکی با مشخصات منحنی بی هنجاری: f_1 و f_2 به ترتیب مختصات و مقدار نقطه ماکریم، f_3 و f_4 به ترتیب مختصات و مقدار نقطه مینیمم، f_5 و f_6 به ترتیب عرض منحنی در نقاط درصد و ۵۰ درصد ماکریم، f_7 مساحت ناحیه مثبت و f_8 مساحت ناحیه منفی.



شکل ۶. مشتق افقی میدان بی هنجاری و تبدیل هیلبرت مشتق افقی و پارامترهای تعریف شده: f_9 مختصات نقطه ماکریم تبدیل هیلبرت مشتق افقی بی هنجاری، f_{10} مختصات نقاطی که مشتق افقی و تبدیل هیلبرت آن برابر است.

نقشه برگردان به قطب آن نشان داده شده است. برای اینکه داده‌های پروفیل، نسبت به ثابت مغناطیس شدگی (kF) نرمال شوند، بر ماکریم مقدار پروفیل تقسیم شده‌اند. مدل‌سازی بر روی داده‌های یک پروفیل عمود بر امتداد بی‌هنجاری، انجام شده که نتایج آن به همراه مقادیر فرضی در جدول ۲ آمده است. همانطور که مشاهده می‌شود، خطای مقادیر بدست آمده کمتر از ۶ درصد می‌باشد.

۲-۵ مدل دایک سه بعدی

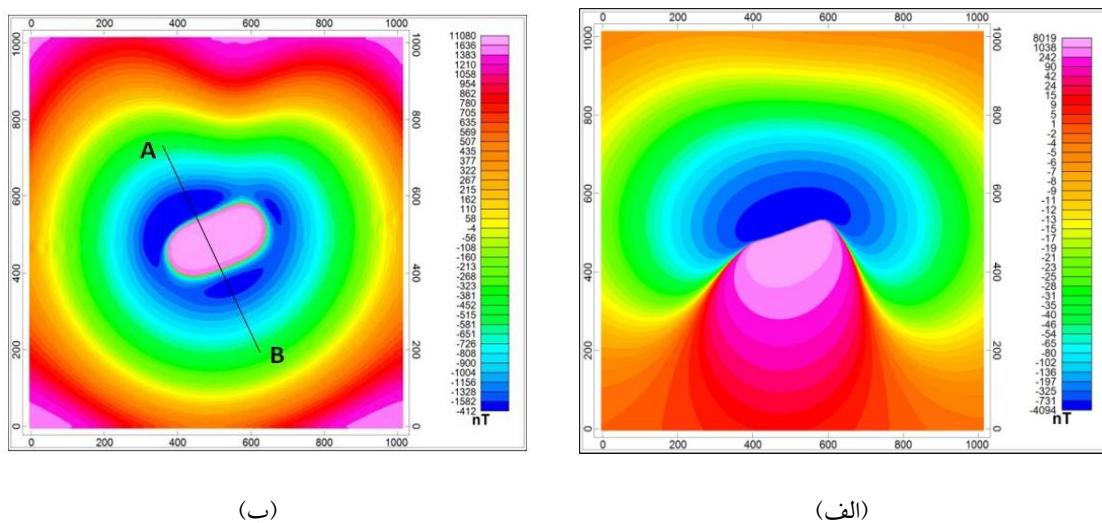
برای بررسی بیشتر، پاسخ مغناطیسی یک دایک شیدار از طریق مدل‌سازی مستقیم توسط نرم افزار Model Vision بدست آمده است. در مدل‌سازی شرایط میدان زمین مشابه شرایط داده‌های واقعی (معدن مروارید) و خودپذیری مغناطیسی برابر با ۰/۱ (در مقیاس سی‌جی)، اس)، در نظر گرفته شده است. در شکل ۷-الف نقشه بی‌هنجاری مغناطیسی حاصل از مدل و در شکل ۷-ب

جدول ۱. نتایج مدل‌سازی برای داده‌های بدون نویف و نویهدار.

نویف تصادفی درصد ۱۰		نویف تصادفی ۵ درصد	داده‌های بدون نویف	مقادیر فرضی	پارامترها	
۱۰۰/۹۳		۹۹/۹	۹۹/۹	۱۰۰	مقدار (متر)	مختصات مرکز
۰/۹۳		۰/۱	۰/۱		خطا٪	
۹/۱۲		۱۰/۷۹	۹/۹۶	۱۰	مقدار (متر)	عرض
۸/۸		۷/۹	۰/۴		خطا٪	
۱۰/۶		۱۰/۱۹	۱۰/۰۱	۱۰	مقدار (متر)	عمق
۶		۱/۹	۰/۱		خطا٪	
۶۳/۵		۵۷/۶	۵۹	۶۰	مقدار (درجه)	شیب
۵/۸		۴	۱/۶۶		خطا٪	

جدول ۲. نتایج مدل‌سازی پروفیل AB مدل دایک سه بعدی (شکل ۷-ب).

خطا٪	نتایج شبکه عصبی	مقادیر واقعی	پارامترها
۲	۲۰۴	۲۰۰	مختصات مرکز
۳	۱۹/۴	۲۰	عمق (متر)
۵	۲۱	۲۰	ضخامت (متر)
۵/۷	۷۴	۷۰	شیب (درجه)



شکل ۷. (الف) نقشه میدان بی‌هنگاری مغناطیسی حاصل از مدل دایک، ابعاد تصویر ۱۰۰۰ در ۱۰۰۰ متر، مشخصات مدل به صورت زیر می‌باشد: مختصات مرکز در نقشه (۵۰۰ و ۵۰۰)، عمق ۲۰ متر، ضخامت ۲۰ متر، طول ۱۰۰ متر، شیب ۷۰ درجه و گسترش عمقی ۱۰۰ متر. (ب) نقشه کاهش به قطب شکل الف، و خط AB پروفیل مدل‌سازی را نشان می‌دهد.

شوند، بر مکریمم مقدار پروفیل تقسیم شده‌اند.
خروجی شبکه عصبی در جدول ۳ آورده شده است.
برازش خیلی خوبی بین داده‌های پروفیل AB و میدان بی‌هنگاری کلی حاصل از دایکی با پارامترهای جدول (۳) ایجاد شده است (شکل ۹). در نهایت عمق واقعی مدل، با کم کردن ارتفاع گسترش به بالا (۵ متر) و ارتفاع سنسور (۲/۲ متر) بدست می‌آید (شکل ۱۰).

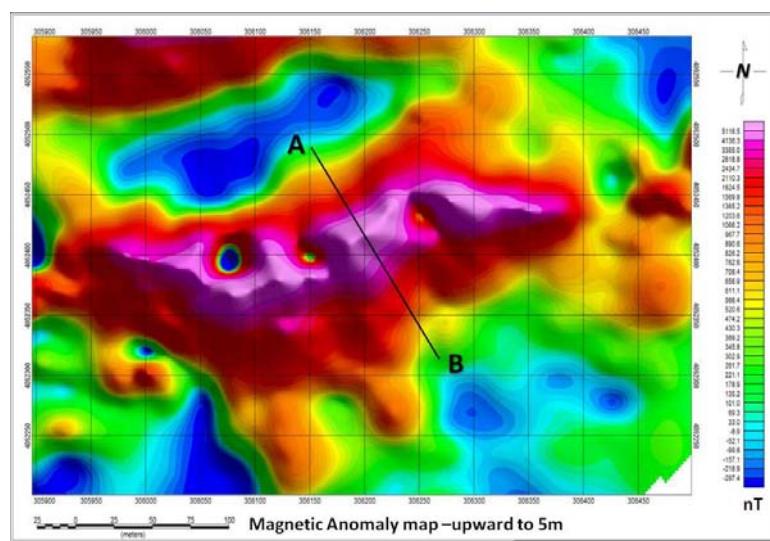
در محل پروفیل AB، تخمین عمق به روش دیکانولوشن اولر نیز انجام گرفته و نتایج آن در شکل ۱۱ نشان داده شده است. با توجه به اطلاعات حاصل از ترانشه‌ها، عمق واقعی در حدود ۱۰-۷ متر می‌باشد. که خروجی روش اولر نیز موید این مطلب است. همچنین شکل واقعی بی‌هنگاری به صورت مجموعه‌ای از رگه‌های در کنار هم است که کل مجموعه را می‌توان، یک دایک با امتداد شمال شرقی-جنوب غربی، و شیب تقریباً قائم به سمت شمال غرب، در نظر گرفت.

۶ مدل‌سازی داده‌های واقعی

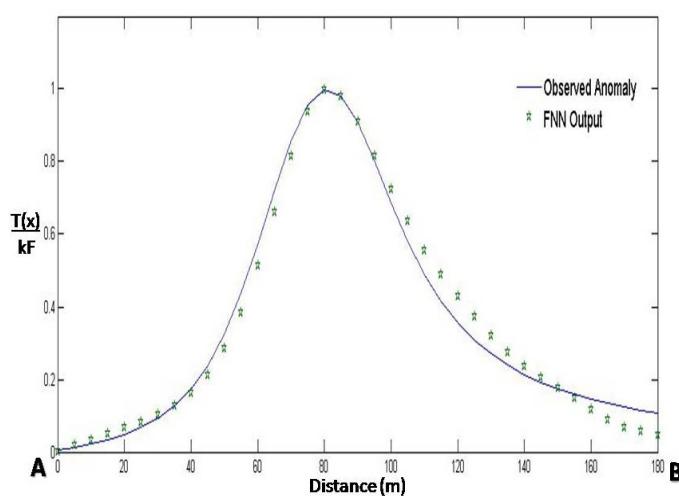
برای بررسی کاربرد روش بر روی داده‌های واقعی، از داده‌های معدن مروارید استفاده شده است. این معدن در ۳۰ کیلومتری جنوب شرقی زنجان، در نزدیکی روستای علی‌آباد قرار دارد که برای اکتشاف بی‌هنگاری‌های اطراف معدن، برداشت مغناطیسی انجام گرفته است. میدان مغناطیسی متوسط منطقه ۴۷۴۰۰ نانوتسلا (گاما) و زاویه میل مغناطیسی ۵۵ درجه و زاویه انحراف مغناطیسی ۴/۵ درجه می‌باشد. به منظور حذف اثر زاویه میل میدان زمین، ابتدا تصحیح کاهش به قطب بر روی داده‌های منطقه انجام شده، سپس برای از بین بردن اثر شکستگی‌های سطحی، گسترش به ارتفاع ۵ متری بر روی داده‌ها انجام شده است. در شکل ۸، نقشه میدان بی‌هنگاری کلی (بعد از کاهش به قطب و گسترش به بالا) و محل پروفیل عمود بر امتداد کانسار، نشان داده شده است. در اینجا نیز برای اینکه داده‌های پروفیل AB نسبت به ثابت مغناطیس شدگی نرمال

جدول ۳. پارامترهای تخمین زده شده توسط شبکه عصبی برای پروفیل AB (شکل ۸).

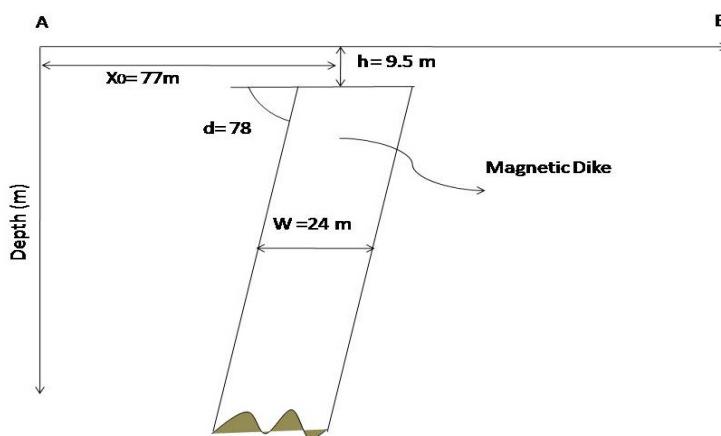
پارامترها	نتایج بدست آمده برای پروفیل AB
مختصات مرکز (متر)	۷۷
عرض (متر)	۲۴
عمق (متر)	۱۶/۷
شیب (درجه)	۷۸



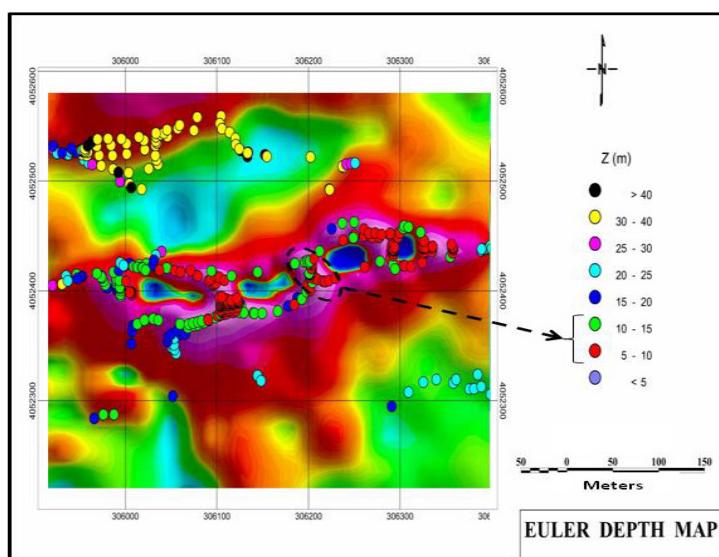
شکل ۸. میدان بی هنجاری کلی کاهش یافته به قطب بعد از ۵ متر گسترش به بالا، معدن مروارید زنجان. خط AB نشان دهنده پروفیل مدل سازی می باشد.



شکل ۹. میدان بی هنجاری کلی پروفیل AB در شکل ۸ و میدان حاصل از مدل تخمین زده شده توسط شبکه عصبی.



شکل ۱۰. مقطع قائم حاصل از مدل‌سازی توسط شبکه عصبی.



شکل ۱۱. نقشه تخمین عمق اولر برای داده‌های معدن مروارید زنجان.

خصوص، در مواردی مانند؛ طراحی شبکه حفاری زاویه‌دار، تعیین دقیق شیب بی‌هنگاری می‌تواند ریسک حفاری موازی با شیب را کاهش دهد. در مسائل مدل‌سازی بی‌هنگاری‌های مغناطیسی، یکی از مجهول‌ها خودپذیری مغناطیسی است که تعیین نادرست آن باعث بوجود آمدن خطای قابل ملاحظه‌ای در تعیین پارامترهای هندسی بی‌هنگاری می‌شود. با نرمال نمودن مقادیر میدان مغناطیسی نسبت به ثابت مغناطیس شدگی،

۷ نتیجه‌گیری

همانطور که ملاحظه شد، به خاطر قدرت بالای شبکه عصبی در تعمیم الگوها و آموزش شبکه با داده‌های بدون نویفه، حساسیت این روش نسبت به نویفه خیلی کم است. روش‌های متعددی برای تفسیر داده‌های مغناطیسی بکار برده می‌شوند که اکثر این روش‌ها، فقط قادر به تخمین عمق هستند. بنابراین تعیین دقیق شیب و عرض بی‌هنگاری بر روی پروفیل، از مزایای این روش است. به

- Artificial neural networks for parameter estimation in geophysics: Geophys. Prospecting, **48**, 21-47.
- McGrath, P. H., and Hood, D. J., 1970, The dipping dike case A computer curve-matching method of magnetic interpretation: *Geophysics* **35**, 831-848.
- Mohan, N. L., Raghava, M. S. V., and Rao S. V. S., 1985, Hilbert transform in the interpretation of magnetic anomalies of various components due to a thin infinite dike: *Pure and Applied Geophysics*, **123**, 557-566.
- Nabighian, M. N., 2005, The historical development of the magnetic method in exploration: *Geophysics*, **70**-76.
- Osman, O., Albora, A. M., and Ucan, O. N., 2007, Forward modeling with forced neural networks for gravity anomaly profile: *Math Geol*, **39**, 593-605.
- Rummelhart, D. E., Hinton, G. E., and Williams, R. J., 1986, Learning internal representation by back propagating errors: *Nature*, **332**, 533-536.
- Salem, A., Ravat, D., Johnson, R., and Ushijima, K., 2001, Detection of buried steel drums from magnetic anomaly data using a supervised neural network: *J. Environ. Eng. Geophys.*, **6**, 115-22.
- Telford, W. M., Geldart, L. P., Sheriff, R. E., and Keys., D. A., 1988, *Applied geophysics*: Cambridge University Press.
- Thompson, D., 1982, EULDPH -A new technique for making computer-assisted depth estimates from magnetic data: *Geophysics*, **47**, 31-37.
- Quesnel, Y., Langlais, B., Sotin, C., and, Gald eano, A., 2008, Modelling and inversion of local magnetic anomalies: *J. Geophys. Eng.* **5**, 387-400.

خودپذیری مغناطیسی از مجھول‌ها حذف می‌شود.
بنابراین، مقادیر بدست آمده برای پارامترهای هندسی، اعتبار بیشتری می‌یابد.

پس از بررسی کارائی روش پیشنهادی با استفاده از مدل‌های مصنوعی نویه‌دار و بدون نویه، از آن برای مدل‌سازی داده‌های مغناطیس سنجی معدن مروارید زنجان، استفاده شده، که نتایج بدست آمده رضایت‌بخش است.

منابع

- منهاج، م..، ۱۳۷۹، مبانی شبکه‌های عصبی (هوش محاسباتی): دانشگاه صنعتی امیرکبیر، مرکز نشر پروفسور حسابی، چاپ پنجم ۱۳۸۷.
- Albora, A. M., Ozmen, A., and Ucan, O. N., 2001, Residual separation of magnetic field using a cellular neural network approach: *Pure and Appl Geophys*, **158**, 1797-1818.
- Blakely, R., 1995, *Potential theory in gravity and magnetic applications*: Cambridge University Press.
- Eslam, E., Salem, A., and Ushijima., K., 2001, Detection of cavities and tunnels from gravity data using a neural network: *Explor. Geophys*, **32**, 204-208.
- Hansen, R. O., and Simmonds, M., 1993, Multiple-source Werner deconvolution: *Geophysics*, **58**, 1792-1800.
- Macias, C., Sen M. K. and Stoffa P. L., 2000,