

مدل‌سازی سه‌بعدی بی‌هنجری‌های گرانی با استفاده از روش شبکه‌های عصبی تحمیلی

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

^۱دانشجوی کارشناسی/رشد مهندسی معدن-اکتشاف، پردیس دانشکده‌های فنی، دانشگاه تهران، ایران

^۲دانشیار، مؤسسه ژئوفیزیک دانشگاه تهران، ایران

^۳دانشیار، دانشکده مهندسی معدن، پردیس دانشکده‌های فنی، دانشگاه تهران، ایران

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

abedi_95@yahoo.com, ahmad_Afshar63@yahoo.com, ebrahimz@ut.ac.ir, norouzih@ut.ac.ir, lucas@ut.ac.ir

(تاریخ دریافت: ۱۳۸۸/۵/۳، تاریخ پذیرش: ۱۳۸۸/۹/۲۲)

چکیده

در این مقاله، از یک روش جدید که شبکه‌های عصبی تحمیلی نامیده می‌شود، استفاده شده تا توزیع چگالی نهشته‌های مدفون در مقاطع عمقی متفاوت با فرض مدل مکعبی برای بی‌هنجری‌های گرانی، پیدا شود. هدف از این مدل‌سازی زمین‌شناسی، پیدا کردن شکل و محل ساختار زیرزمینی در مقاطع سه‌بعدی است. در اینجا، شبکه‌ای با یک نرون و الگوریتم پس‌انتشار خطا برای پیدا کردن اختلاف چگالی، به کار رفته است. از آنجاکه معمولاً در روش‌های مدل‌سازی داده‌های پتانسیل از شبیه‌سازی شکل‌های ساده هندسی استفاده می‌شود؛ در این مقاله سعی شده است که ساختار مورد نظر به صورت ترکیبی از مکعب‌های سه‌بعدی در نظر گرفته شود تا بتوان هر ساختار نامشخص هندسی را با استفاده از آن مدل کرد. این روش برای مدل‌های مصنوعی نوغه‌دار و بدون نویز آزمایش شد و بعد از اینکه نتایج رضایت‌بخشی حاصل شد؛ در مدل‌سازی زغال‌های بیتومینه دهلران ایران در حکم داده‌های واقعی مورد استفاده قرار گرفت. نتایج نهایی بدست آمده از این روش، بیانگر نهشته‌ای سطحی است که تا عمق کمتر از ۴۰ متر ادامه دارد.

واژه‌های کلیدی: شبکه‌های عصبی تحمیلی (FNN)، بی‌هنجری گرانی، مدل‌سازی سه‌بعدی، مدل‌های مصنوعی

3D modeling of gravity anomalies using the forced neural networks method

Maysam Abedi¹, Ahmad Afshar¹, Vahid Ebrahimzade Ardestani^{2*}, Gholam Hossain Norouzi¹
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: 25 July 2009, accepted: 13 December 2009)

Summary

Potential field data (gravity and magnetic data) are usually analyzed by employing linear transformations, the spectral method, inversion techniques and analytic signal methods. Nowadays, there are different methods of modeling the gravity data; but each has limitations. One of the limitations of these methods is the assumption of a

*Corresponding author:

ebrahimz@ut.ac.ir

*نگارنده رابط:

simple shape for buried structures whereas the actual shape could be entirely different. This study uses cubic units (3D model) to solve this limitation because affords the ability to make any shape for unknown underground structures by arranging these cubics.

In this paper, a new method called Forced Neural Networks (FNN) to find the density variation of buried deposits or underground structures in different depth sections by assuming the cubic model is described. The aim of the geological modeling is to determine the shape and location of underground structures in 3-D sections. Here, one neuron network and back propagation algorithm are applied to discover the density difference. In this method, weights of the neurons are assigned as density for each cubic and the activation function has a linear property such that the outputs are the same as the inputs. After using the back propagation, densities for each cubic are updated and the output of the neurons gives the gravity anomaly. Hence, the density differences are found. However, the results of this system are insufficient because non-uniqueness and horizontal locations are constrained; therefore, the value of density difference is set to zero if its value is very close to zero according to the density difference which is obtained from geological features of the region. Otherwise these values are set to the density difference of the geological region after back propagation.

Using a forced neural network, after sufficient epoch is applied, fixed values are assigned to the output of the neuron according to the density difference, and this process is continued until the mean square error of the output becomes sufficiently small. The method is used for both noise-free and noise-corrupted synthetic data and, after obtaining satisfactory results for three synthetic data models, this method was used for modeling of the real data.

The Dehloran Bitumen map in Iran was chosen as a real data application. The area under consideration is located in the Zagros tectonic zone, west of Iran where we are looking for Bitumen. Layers of Medium-bedded limestone with intermediate marl-limestone are the dominant formations in the area and the hydrocarbon zone is one of the most important characteristics of the area. A program was written using the Anomaly modeling method. The final result of this method shows that the deposit begins from the low depth to approximately less than 40 meters. This modeling yeilded satisfactory results for the drilling in the region. The results of the drillings show that the lowest depth of the deposit varies from 7 to 10 meters. This method can easily be applied for gravity, microgravity and magnetic data especially for porphyry deposits.

Key words: Forced neural networks, gravity anomaly, 3D modeling, synthetic model

نهشته‌های دارای شکل نامشخص، معمولاً سعی می‌شود که این ساختارهای زیرزمینی با شکل‌های ساده‌شده‌ای شبیه‌سازی شوند. نکته‌ای که در اینجا وجود دارد این است که شکل واقعی نهشته ممکن است کاملاً متفاوت با شکل شبیه‌سازی شده باشد (عبدی و همکاران، ۲۰۰۹). برای رفع این مشکل از کنار هم قرار دادن مدل‌های مکعبی در مدل‌سازی شکل‌های نامشخص هندسی استفاده می‌شود.

۱ مقدمه
داده‌های پتانسیل (گرانی و مغناطیس)، معمولاً با استفاده از تبدیل‌های خطی، روش‌های طیفی، روش‌های معکوس و سیگنال تحلیلی پردازش می‌شوند (اکینسی، ۲۰۰۸).

اکثر روش‌های مدل‌سازی دارای محدودیت‌اند و این محدودیت برای مدل‌سازی داده‌های پتانسیل نیز وجود دارد. به دلیل پیچیدگی روش‌های مدل‌سازی

۲ الگوریتم پس‌انتشار خطای

سیگنال خطای حاصل از خروجی نرون \hat{z} در تکرار n ام، به صورت زیر تعریف می‌شود (هیکین، ۱۹۹۹؛ عثمان و همکاران، ۲۰۰۶، ۲۰۰۷):

$$j(n) = d_j(n) - y_j(n), \quad (1)$$

که در آن نرون \hat{z} ، گره خروجی، $y_j(n)$ خروجی مطلوب و $d_j(n)$ خروجی واقعی شبکه‌های عصبی است. ارزش لحظه‌ای انرژی خطای برای نرون \hat{z} را می‌تواند به صورت $\frac{1}{2}e^2$ تعريف کرد. بر این اساس، ارزش لحظه‌ای انرژی خطای کل یعنی E ، با جمع همه $\frac{1}{2}e^2_j(n)$ نرون‌های لایه خروجی به دست می‌آید؛ فقط در نرون‌های قابل مشاهده، سیگنال خطای را می‌توان به صورت مستقیم محاسبه کرد. بنابراین،

$$E(n) = \frac{1}{2} \sum_{j \in C} e^2_j(n), \quad (2)$$

مجموعه C شامل همه نرون‌های لایه خروجی شبکه است. N (کل تکرارها) تمام الگوهای (مثال‌ها) را در مجموعه آموزشی مشخص می‌کند. انرژی میانگین مربعات خطای جمع $E(n)$ برای همه n ها است که نسبت به تعداد مجموعه یعنی N ، نرمال شده است.

$$E_{av} = \frac{1}{N} \sum_{n=1}^N E(n), \quad (3)$$

انرژی خطای لحظه‌ای $E(n)$ و همچنین انرژی میانگین خطای E_{av} ، تابع همه پارامترهای آزاد (برای مثال، وزن‌های اتصالی و سطوح بایاس) شبکه هستند. برای دادن مجموعه‌ی آموزشی، E_{av} تابع هزینه را به متنزه وسیله‌ای برای انجام آموزش عرضه می‌کند. هدف از فرایند آموزش، انطباق پارامترهای آزاد شبکه به حداقل E_{av} است. برای تحقق این حداقل‌سازی، از تقریبی مشابه با الگوریتم مشتق حداقل میانگین مربعات (LMS)، و

عمق و محدوده کافی سازی از مهم‌ترین پارامترهایی است که در مدل‌سازی داده‌های گرانی‌سنجدی بررسی‌های اکتشافی مورد توجه قراردارد. امروزه روش‌های گوناگونی مانند روش اویلر، حداقل مربعات، دی‌کانولوشن ورنر و مانند آن برای چنین مدل‌سازی‌هایی وجود دارد (سالم و همکاران، ۲۰۰۴). شبکه‌های عصبی از اجزای عملیاتی ساده‌ای به صورت موازی ساخته می‌شوند. این اجزا از دستگاه‌های عصبی زیستی الهام گرفته شده‌اند. در طبیعت، ساختار شبکه‌های عصبی از نحوه اتصال بین اجزا تعیین می‌شود. بنابراین می‌توان یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی ساخت و با تنظیم مقادیر هر اتصال تحت عنوان وزن اتصال، نحوه ارتباط بین اجزای آن را تعیین کرد. پس از تنظیم یا همان آموزش شبکه عصبی، اعمال یک ورودی خاص به آن، منجر به دریافت پاسخ خاص می‌شود. عموماً تعداد زیادی از این زوج‌های ورودی و خروجی به کار می‌رود تا در این روند که از آن با عنوان یادگیری نظارت شده یاد می‌شود، شبکه آموزش داده شود (کیا، ۱۳۸۷).

در سال‌های اخیر، کاربرد شبکه‌های عصبی گوناگون برای مدل‌سازی داده‌های گرانی و مغناطیسی افزایش یافته است. برای مثال محل کپسول‌های فلزی به کمک روش شبکه عصبی نظارت شده از روی دوقطبی مغناطیسی تعیین شده است (سالم و همکاران، ۲۰۰۱). همچنین عمق و شعاع حفره‌های زیرزمینی از روی داده‌های میکروگرانی‌سنجدی به کمک شبکه عصبی و روش پس‌انتشار خطای مدل‌سازی شده است (سالم و همکاران، ۲۰۰۱). روش شبکه عصبی سولولی برای جداسازی بی‌هنگاری محلی از منطقه‌ای نیز به کار رفته است (آلبرا و همکاران، ۲۰۰۱a, b).

$$y_j(n) = \phi_j(v_j(n)), \quad (8)$$

که دیفرانسیل آن نسبت به $v_j(n)$ برابر است با

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \phi'_j(v_j(n)), \quad (9)$$

۳ مدل به کار رفته

مدلی که اینجا به کار رفته است، یکی از معروف‌ترین مدل‌هایی است که پلوف برای مدل‌سازی سه‌بعدی بی‌亨جارتی‌های گرانی بیان کرده است (بلکلی، ۱۹۹۵). در این مدل، مجموعه‌ای از بلوک‌های مکعبی برای تقریب شکل نهشته به کار می‌رود. این تقریب سه‌بعدی در شکل ۲ نشان داده شده است. هریک از این بلوک‌ها می‌توانند اختلاف چگالی دلخواهی با محیط اطراف داشته باشند؛ بنابراین طبق اصل جمع‌پذیری اثر داده‌های پتانسیل (گرانی و مغناطیس)، بی‌亨جارتی گرانی در هر نقطه را می‌توان به صورت تقریبی از مجموع اثر هر کدام از بلوک‌ها دانست (بلکلی، ۱۹۹۵).

یک منشور چهاروجهی با چگالی یکنواخت ρ و با ابعاد مشخص در محدوده $x_1 \leq x \leq x_2$ ، $y_1 \leq y \leq y_2$ و $z_1 \leq z \leq z_2$ در مرکز مختصات، دارای جاذبه قائم به صورت زیر است :

$$\rho \int_{z_1}^{z_2} \int_{y_1}^{y_2} \int_{x_1}^{x_2} \frac{z'}{\left[x'^2 + y'^2 + z'^2 \right]^{\frac{3}{2}}} dx' dy' dz'. \quad (10)$$

پلوف (۱۹۷۵) با محاسبه عددی انتگرال بالا، فرمول زیر را عرضه کرد (بلکلی، ۱۹۹۵) :

$$g = \rho \sum_{i=1}^2 \sum_{j=1}^2 \sum_{k=1}^2 \mu_{ijk} \begin{bmatrix} x_i y_j \\ z_k \arctan \frac{x_i y_j}{z_k R_{ijk}} \\ -x_i \cdot \log(R_{ijk} + y_j) \\ -y_j \cdot \log(R_{ijk} + x_i) \end{bmatrix}, \quad (11)$$

که

$$R_{ijk} = \sqrt{x_i^2 + y_j^2 + z_k^2}$$

$$\mu_{ijk} = (-1)^{i+j+k}$$

همچنین از روش ساده آموزشی استفاده می‌شود که در آن وزن‌ها، الگو به الگو براساس یک دوره روزآمد می‌شوند. عرضه کاملی از کل مجموعه آموزشی به صورت زیر است:

$$\Delta w_{ij}(n) = \eta \delta_j(n) y_i(n), \quad (4)$$

که در آن $\delta_j(n)$ ، گرادیان محلی و η ، سرعت یادگیری است. مقدار گرادیان در وزن‌های اتصالی مستلزم تغییر می‌شود و فرمول پس انتشار خطاب را گرادیان محلی $(\delta_j(n))$ به صورت زیر به دست می‌آید:

$$\delta_j(n) = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n), \quad (5)$$

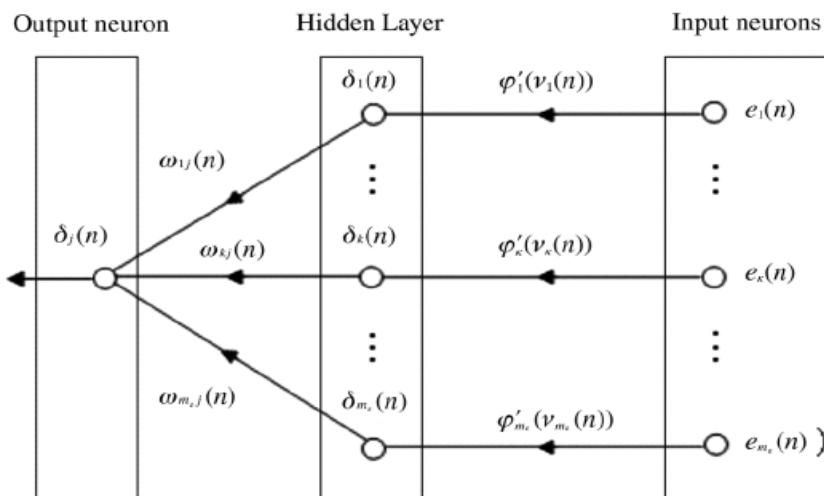
ضریب $(\phi'_j(v_j(n)))$ در رابطه (۵) که برای محاسبه گرادیان محلی $(\delta_j(n))$ آمده است، فقط به تابع تحريك مرتبط با نرون مخفی j بستگی دارد. فاکتور باقی مانده، یعنی مجموع k جزء، به دو عبارت بستگی دارد: نخستین عبارت یعنی $(\delta_j(n))$ ، به دانستن سیگنال‌های خطابی $e_k(n)$ برای همه نرون‌هایی که در لایه سمت راست بعد از نرون مخفی j قرار گرفته‌اند مربوط است و به طور مستقیم به نرون j متصل است (شکل ۱). دومین عبارت یعنی $w_{kj}(n)$ ، شامل وزن‌های مرتبط با این اتصالات است. می‌توان تعریف دوباره‌ای از گرادیان محلی $(\delta_j(n))$ برای نرون مخفی j به صورت زیر آورد:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial y_j(n)} \phi'_j(v_j(n)), \quad (6)$$

پارامتر محلی $(v_j(n))$ در ورودی تابع تحريك مرتبط با نرون j تولید می‌شود، بنابراین،

$$v_j(n) = \sum_{i=0}^m w_{ij}(n) y_i(n), \quad (7)$$

که در آن m تعداد کل ورودی‌ها (به استثنای بایاس) به نرون j است. وزن اتصالی w_{j0} (مطابق با ورودی ثابت y_0) مساوی بایاس b_j به کاررفته در نرون j است. بنابراین، تابع سیگنال $(y_j(n))$ که در ورودی نرون j در تکرار n ظاهر می‌شود، عبارت است از:



شکل ۱. مدل شبکه عصبی تحمیلی (عثمان و همکاران، ۲۰۰۶ و ۲۰۰۷).

رابطه (۱۲)، متوجه می‌شویم که این وزن‌ها در واقع همان اختلاف چگالی ($\Delta\rho_{ijk}$) مورد نظرند که از طریق شبکه عصبی به هریک از این مکعب‌ها نسبت داده می‌شوند. بعد از استفاده از روش پس‌انتشار خطای مقادیر $\Delta\rho_{ijk}$ روزآمد می‌شود تا اینکه خروجی با کمترین خطای مطابق با بی‌هنجاری، گرانی‌سنجد شود. درنتیجه، اختلاف چگالی به دست می‌آید. اما به دلیل نبود یکتاپی جواب، به کارگیری این الگوریتم به تنها یکی کافی نیست. از آنجاکه مقدار وزن اولیه شبکه عصبی در همگرایی و واگرایی شبکه بسیار موثر است؛ پس از هر توقف شبکه که در آن وزن مناسب حاصل شد، باید وزن‌های نزدیک به صفر را صفر کرد (فیلتر کردن) و این فرایند را در صورتی که چند بار صورت گیرد، به مدل واقعی همگرا می‌شود. بعد از اینکه مدل‌سازی به انجام رسید، اختلاف چگالی، با اختلاف چگالی ناسیه‌ای که از تحقیقات زمین‌شناسی بدست می‌آید، برابر گرفته می‌شود. در شکل ۴، پیاده‌سازی این الگوریتم به صورت نمودار گردشی (فلوچارت) آمده است. در اینجا مقدار آستانه (بایاس)، صفر در نظر گرفته شده و در اولین تکرار، شبکه عصبی تحمیلی، وزن اولیه را به صورت تصادفی انتخاب کرده است.

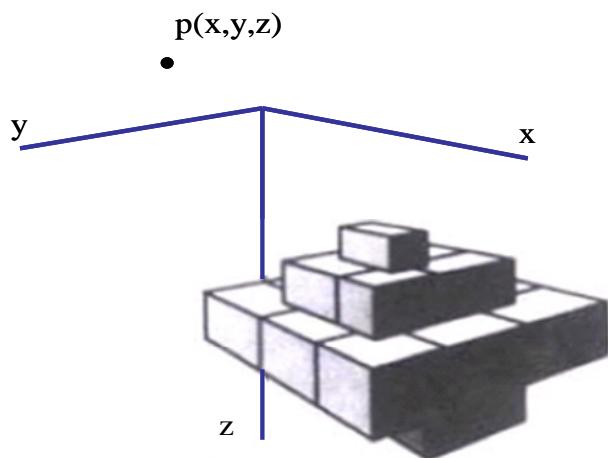
در حالت کلی می‌توان اثر بلوک‌های تولید کننده بی‌هنجاری گرانی را به صورت ضرب ماتریسی زیر نشان داد:

$$[G] = [A_{ijk}] \cdot [\Delta\rho_{ijk}] \quad (12)$$

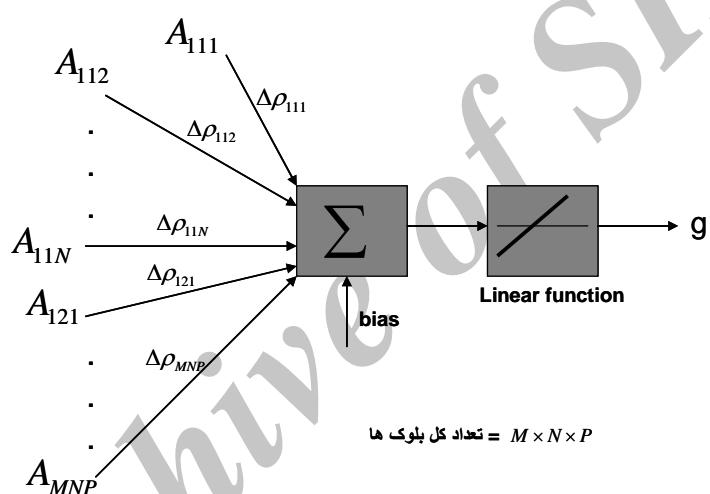
که در آن G ، گرانی مشاهده شده، $\Delta\rho_{ijk}$ ، توزیع چگالی بلوک‌ها و A_{ijk} ، ماتریس ژاکوبی (کرنل) است که طبق رابطه (۱۱) محاسبه می‌شود.

۴ روش شبکه‌های عصبی تحمیلی (FNN)

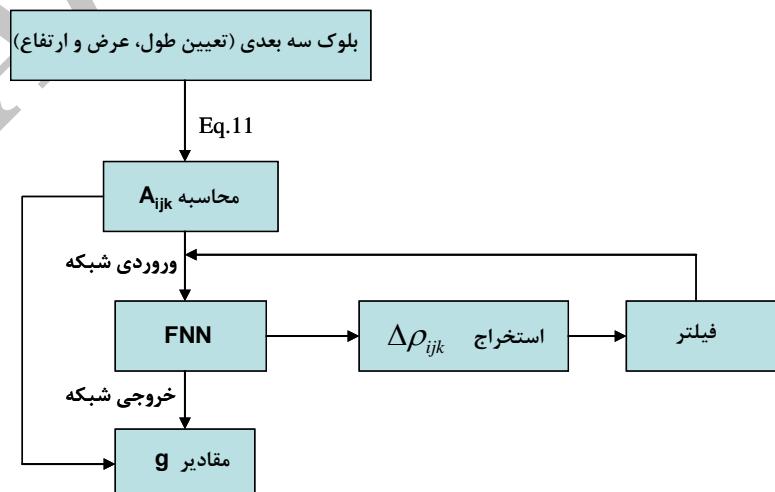
در این مدل‌سازی از شبکه عصبی تحمیلی از لایه‌ای که شامل یک نرون است استفاده می‌شود (شکل ۳). در این شبکه ورودی‌ها مقادیر A_{ijk} هستند که نشان دهنده ارزش هر مکعب‌اند. مقدار این ورودی از رابطه (۱۱) و با نوشتمن یک کد محاسبه می‌شود و ارزش آن در تمام مراحل پیاده‌سازی الگوریتم مدل‌سازی ثابت است. در اینجا ازتابع تحریک خطی استفاده می‌شود تا این ورودی‌ها با وزن مناسبی که از روش پس‌انتشار خطای برای آن حاصل می‌شود (براساس حداقل مربعات خطای) به خروجی مورد نظر نزدیک شود. خروجی‌ها، همان مقادیر بی‌هنجاری گرانی مشاهده شده هستند (عثمان و همکاران، ۲۰۰۶، ۲۰۰۷). با نگاهی به



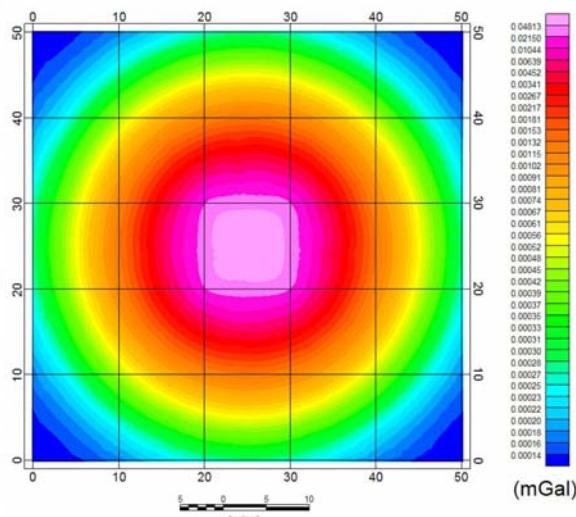
شکل ۲. تقریب یک نهشته با استفاده از مجموعه‌ای از بلوک‌ها در سه بعد (بالکلی، ۱۹۹۵).



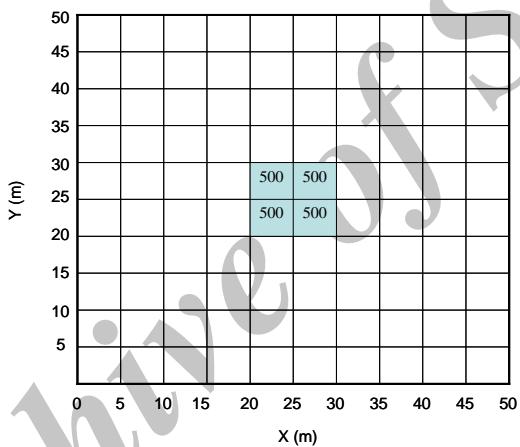
شکل ۳. شبکه به کار رفته.



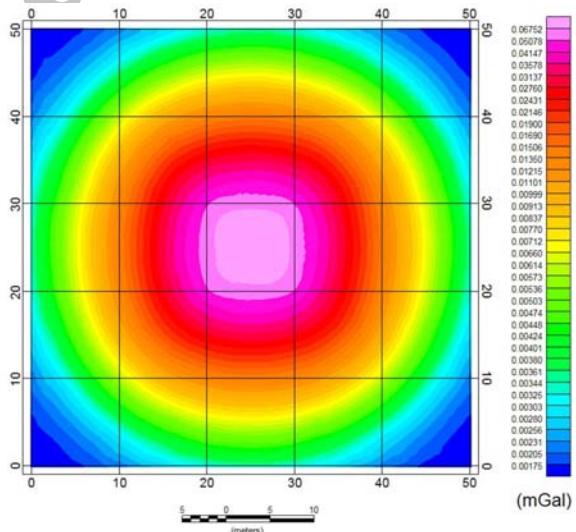
شکل ۴. الگوریتم پیاده‌سازی مدل.



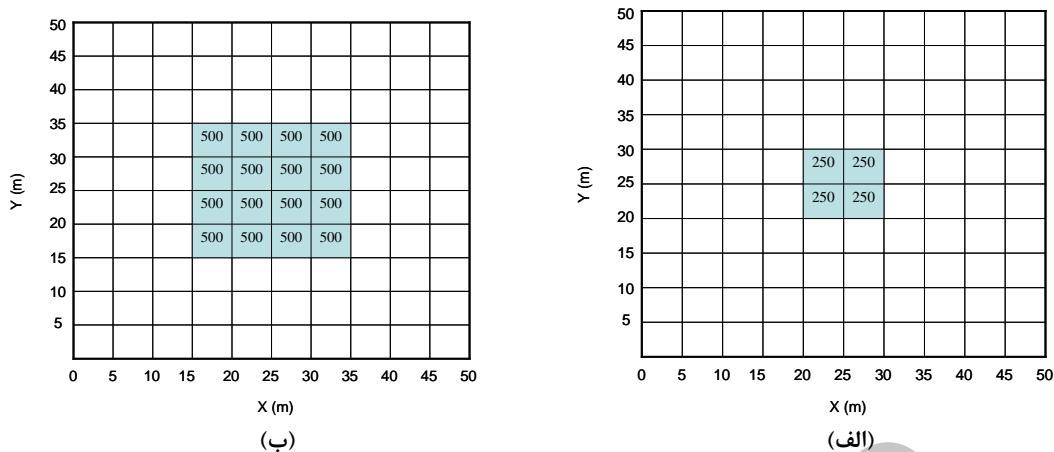
شکل ۵. بی‌هنجاری گرانی مدل مصنوعی اول.



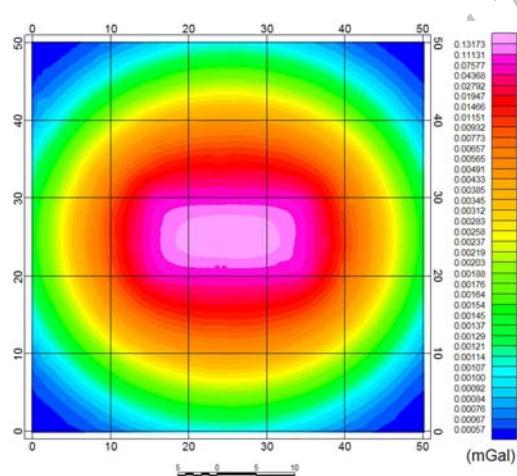
شکل ۶. نتایج مدل‌سازی ساختار مصنوعی اول.



شکل ۷. بی‌هنجاری گرانی مدل مصنوعی دوم.



شکل ۸. نتایج مدل‌سازی ساختار مصنوعی دوم: (الف) عمق بین ۵-۱۰ متر و (ب) عمق بین ۵-۱۰ متر.



شکل ۹. بی‌هنجری گرانی مدل مصنوعی سوم.

مدل را نشان می‌دهد. اختلاف چگالی مدل با زمینه 500 kg/m^3 ، فرض شده است. برای پیاده‌سازی این روش، از بلوک‌های مکعبی با اضلاع ۵ متر استفاده شد. نتایج این مدل‌سازی در شکل ۶، آورده شده است. همان‌طور که می‌بینید، نتایج مدل‌سازی با ساختار واقعی همگرا شده است. در مثال دوم، دو ساختار با اندازه و اختلاف چگالی متفاوت در کنار یکدیگر مدل شده‌اند. یکی با طول و عرض ۱۰ متر و دارای عمقی تا ۵ متر است و به صورت رخنمون دار و دارای اختلاف چگالی 250 kg/m^3 با زمینه است. طول و عرض دیگری ۲۰ متر و محدوده

۵ مدل‌سازی سه‌بعدی داده‌های مصنوعی

برای بیان کارایی مدل، سه مثال آورده شده است. از آنجاکه بی‌نهایت حالت متفاوت برای درنظر گرفتن مدل‌های مصنوعی وجود دارد، سعی شده است از مدل‌های ساده استفاده شود تا فرایند مدل‌سازی راحت‌تر و قابل فهم باشد. بی‌هنجری حاصل از هر مدل با استفاده از رابطه (۱۱) و با نوشتن کدی در نرم‌افزار Matlab به دست آمده است.

در مثال اول، ساختاری با طول و عرض ۱۰ متر و عمقی تا ۵ متر، مدل شده است. این ساختار در سطح زمین رخنمون دارد. شکل ۵ بی‌هنجری ناشی از این

برداشت نقاط از دستگاه گرانی‌سنجدی نوع Scintrex CG3 با دقت ۵ میکروگال استفاده شده است. شبکه ۲۰ در ۲۰ متر برای برداشت این ناحیه را بخش گرانی‌سنجدی موسسه ژئوفیزیک دانشگاه تهران به انجام رسانده است. بی‌هنجاری مورد نظر بعد از تصحیح داده‌های برداشت شده و حذف اثر روند ناحیه‌ای (درجه ۲)، ترسیم شد (شکل ۱۲). برای پیاده‌سازی روش شبکه عصبی FNN و مدل‌سازی سه‌بعدی، از بلوک‌های مکعبی با اضلاع ۵ متر استفاده شد. نتایج این مدل‌سازی در شکل‌های ۱۳ تا ۲۱، و تا عمق ۴۵ متر آورده شده است. در اینجا برای عمق‌های گوناگون، نقشه اختلاف چگالی مدل واقعی نشان داده شده است. برای رسم این نقشه‌ها، اختلاف چگالی هر مدل مکعبی به مختصات مرکز مکعب نسبت داده شده است.

همان‌طور که در این شکل‌ها می‌بینید، نهشته‌های عمقی کمتر از ۴۰ متر گسترش دارد؛ زیرا به ازای عمق‌های بالاتر از ۴۰ متر (شکل ۲۱)، اختلاف چگالی نهشته با زمینه بسیار کم است. نحوه توزیع اختلاف چگالی در عمق‌های گوناگون، مطابق با گسترش نهشته زغال است. نکته‌ای که باید به آن توجه کرد این است که در واقع هیچ روش مدل‌سازی سه‌بعدی وجود ندارد که بتواند به طور دقیق توزیع نهشته‌ها را در اعمق گوناگون نشان دهد و این روش پیشنهادی نیز از این قاعده مستثنی نیست؛ اما به کمک این روش می‌توان به طور تقریبی وضعیت گسترش نهشته در عمق‌های گوناگون را مدل کرد و برآورده با احتمال زیاد از حجم و محدود نهشته به دست آورد.

در شکل (۲۲)، بی‌هنجاری حاصل از مدل‌سازی صورت گرفته آمده است که با خطای کمتر از ۵ درصد با بی‌هنجاری زغال بی‌تومینه دهلران مطابقت دارد. در شکل (۲۳)، نمایش سه‌بعدی مدل‌سازی صورت گرفته برای مقاطع طولی نشان داده شده است.

عمقی آن بین ۵ تا ۱۰ متر است که اختلاف چگالی آن با زمینه kg/m^3 ۵۰۰، فرض شده است. بی‌هنجاری ناشی از این مدل در شکل ۷ نشان داده شده است.

برای پیاده‌سازی این روش، از بلوک‌های مکعبی با اضلاع ۵ متر استفاده شد. نتایج این مدل‌سازی در شکل ۸ نشان داده شده است. همان‌طور که می‌بینید، نتایج مدل‌سازی با ساختار واقعی همگرا شده است.

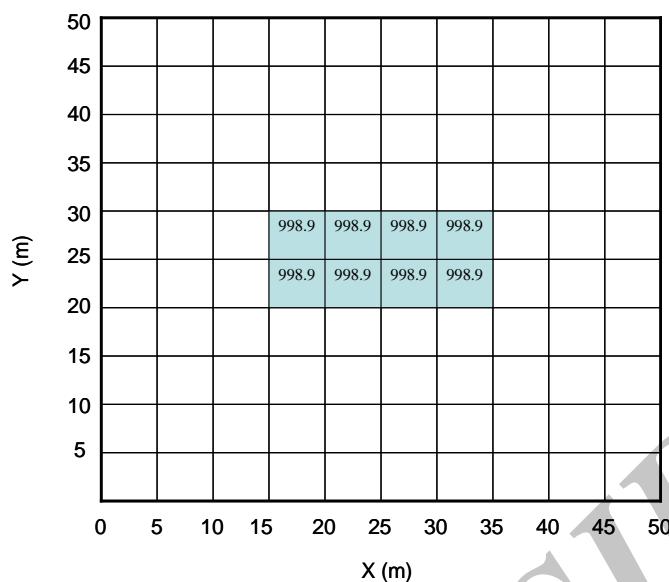
از آنجاکه در برداشت‌های گرانی‌سنجدی معمولاً نوافه وجود دارد، در مثال سوم، ساختاری مدل شده که چند تا از داده‌های آن به صورت تصادفی تا ۱۰ درصد نوافه دار شده‌اند. برای اینکه نوافه روی داده اثر داده شود ازتابع Rand نرم‌افزار Matlab استفاده شد که مقدار آن از رابطه زیر به دست می‌آید:

$$G_{noise} = \pm(0.1 \times Rand \times G) + G, \quad (13)$$

تابع Rand به صورت تصادفی اعدادی بین ۰ تا ۱ را تولید می‌کند. در رابطه (۱۳)، بی‌هنجاری نوافدار حاصل از مدل بدون نوافه با بی‌هنجاری G است. در اینجا، ساختاری با طول ۲۰ متر، عرض ۱۰ متر که دارای عمقی تا ۵ متر است، مدل شده است. این ساختار در سطح زمین رخمنون دارد. بی‌هنجاری ناشی از این مدل در شکل ۹ نشان داده شده است. اختلاف چگالی مدل با زمینه kg/m^3 ۱۰۰۰ فرض شده است. برای پیاده‌سازی این روش، از بلوک‌های مکعبی با اضلاع ۵ متر استفاده شد. نتایج این مدل‌سازی در شکل ۱۰ آورده شده است. همان‌طور که می‌بینید، نتایج مدل‌سازی با ساختار واقعی همگرا شده است.

۶ مدل‌سازی داده‌های واقعی

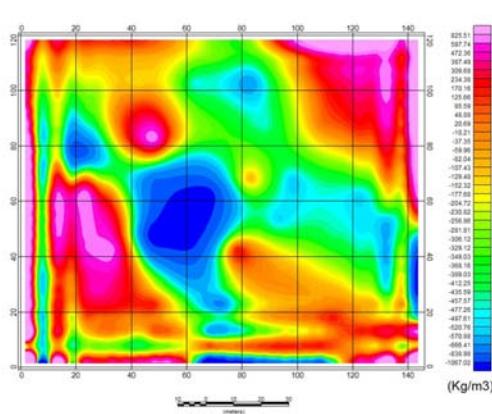
ناحیه مورد نظر در غرب ایران و در زون تکتونیکی زاگرس واقع شده است (شکل ۱۱). در منطقه دهلران، هدف، اکتشاف بی‌تومینه‌های نفتی است. سنگ‌های منطقه از نظر زمین‌شناسی آهکی مارنی است. برای



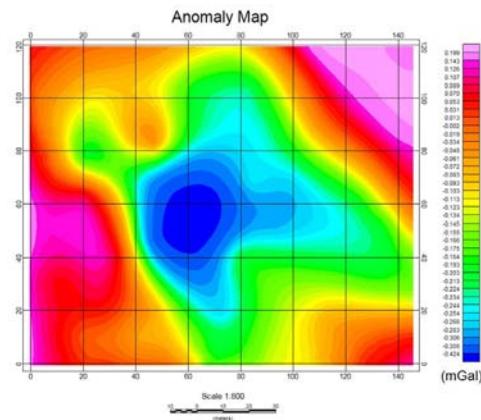
شکل ۱۰. نتایج مدلسازی ساختار مصنوعی سوم.



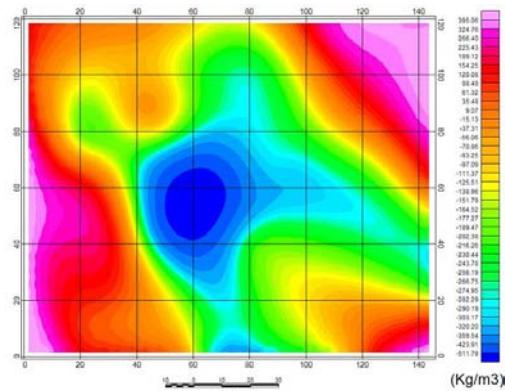
شکل ۱۱. نقشه ناحیه مورد اکتشاف (دھران).



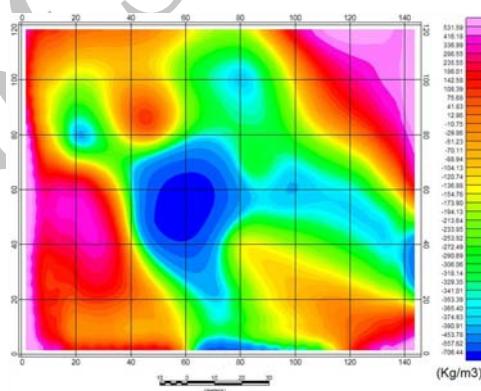
شکل ۱۳. نقشه توزیع اختلاف چگالی در عمق ۰-۵ متر.



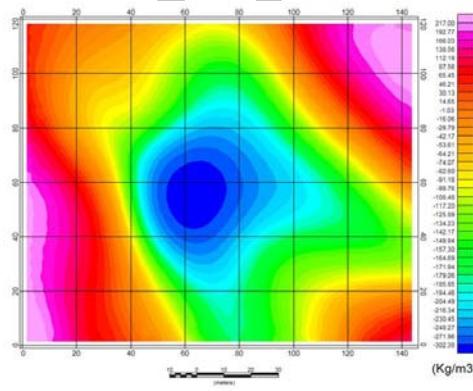
شکل ۱۲. نقشه بی هنجاری بازنده ناحیه پرداشت شده.



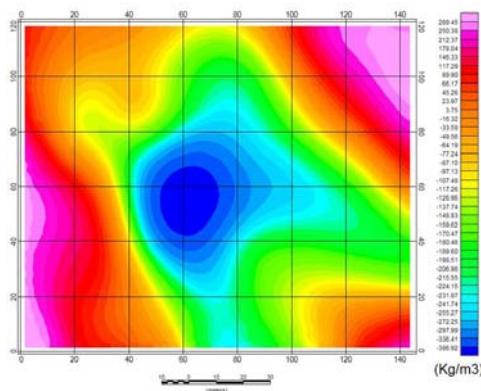
شکل ۱۵. نقشه توزیع اختلاف چگالی در عمق ۰-۱۰ متر.



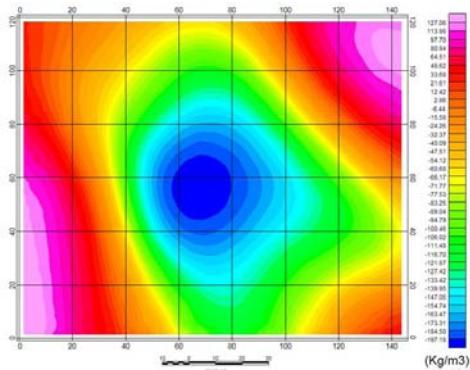
شکل ۱۴. نقشه توزیع اختلاف چگالی در عمق ۰-۵ متر.



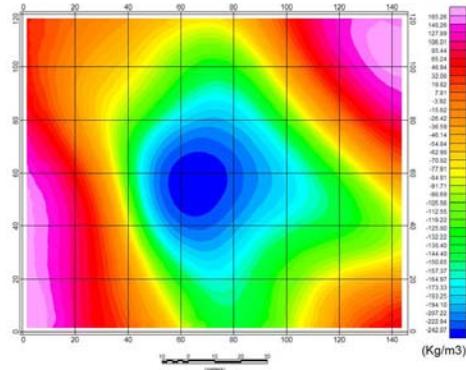
شکل ۱۷. نقشه توزیع اختلاف چگالی در عمق ۰-۲۰ متر.



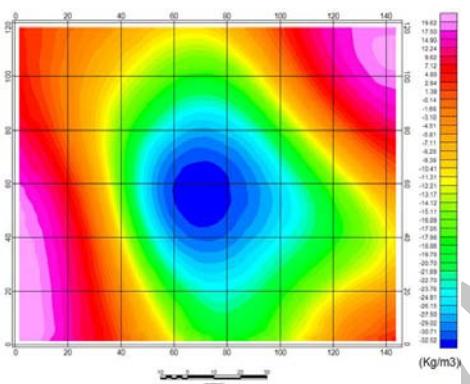
شکل ۱۶. نقشه توزیع اختلاف چگالی در عمق ۰-۱۵ متر.



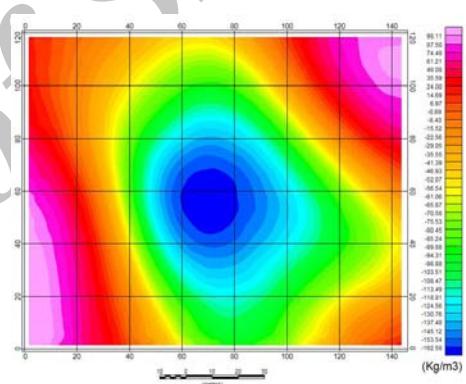
شکل ۱۹. نقشه توزیع اختلاف چگالی در عمق ۳۰-۳۵ متر.



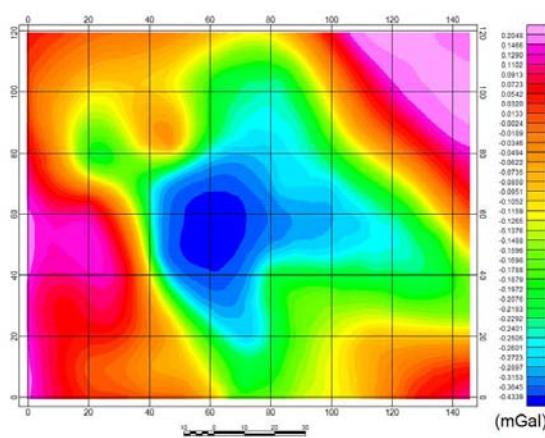
شکل ۱۸. نقشه توزیع اختلاف چگالی در عمق ۲۵-۳۰ متر.



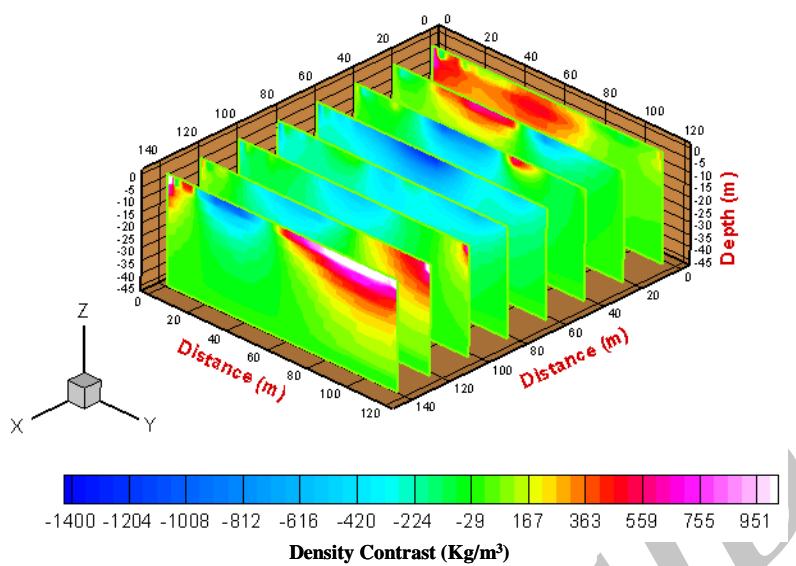
شکل ۲۱. نقشه توزیع اختلاف چگالی در عمق ۴۰-۴۵ متر.



شکل ۲۰. نقشه توزیع اختلاف چگالی در عمق ۳۵-۴۰ متر.



شکل ۲۲. بیهنجاری ناشی از مدل‌سازی صورت گرفته.



شکل ۲۳. نمایش سه‌بعدی مدل‌سازی صورت گرفته.

کانساری، کمک شایانی به مدل‌سازی در انتخاب فیلتر خواهد کرد.

این روش در ابتدا درمورد سه مدل مصنوعی آزمایش شد و بعد از آن که نتایج مناسبی حاصل آمده؛ روی داده‌های واقعی یعنی نهشته زغال بیتومینه دهلران ایران، پیاده شد که نتایج آن همان‌طور که مشاهده شد، مناسب بود. نتایج این مدل‌سازی سه‌بعدی حاکی از آن است که نهشته به صورت سطحی است و تا عمقی کمتر از ۴۰ متر ادامه دارد. بدلیل آن که توزیع اختلاف چگالی با زمینه به ازای مقطع عمقی ۴۵–۴۰ بسیار کاهش می‌یابد می‌توان این نتیجه را گرفت که گسترش زغال بیتومینه تا محدوده عمقی ۴۰ متر است. نکته اساسی برای این روش مدل‌سازی سه‌بعدی که نخستین بار پیشنهاد شده این است که در واقع به دلیل نبود یکنای داده‌های پتانسیل، هیچ روش مدل‌سازی گرانی‌سنگی نمی‌تواند با قاطعیت مدل سه‌بعدی برآورد شده را با مدل واقعی یکسان بداند و این روش پیشنهادی نیز از این قاعده مستثنی نیست. حداقل نتیجه‌ای که می‌توان از این روش گرفت این است که به مدل‌ساز

از جمله مزیت‌های این روش نسبت به روش رایج لاست و کوییک این است که در صورت داشتن اطلاعات زمین‌شناسی (مثلاً دانستن محدوده اختلاف چگالی نهشته با زمینه)، می‌توان این اطلاعات را در فیلتر قرار داد تا به مدل واقعی تری همگرا شود؛ ولی در روش لاست و کوییک این توانایی وجود ندارد. بدلیل چنین خاصیتی، این روش را شبکه عصبی تحمیلی نامیده‌اند. از نکات مهم دیگر در این روش پیشنهادی، اندازه ابعاد بلوک‌ها است که هر چه کوچک‌تر باشد نتایج مناسب‌تری حاصل می‌گردد. ولی زمان مدل‌سازی افزایش می‌یابد و نیاز به کامپیوترهای با قابلیت پردازش بالا است.

۷ نتیجه‌گیری

با استفاده از روش پیشنهادی مدل‌سازی سه‌بعدی بی‌هنگاری‌های گرانی، یعنی شبکه‌های عصبی تحمیلی، می‌توان نهشته‌هایی را که هیچ‌گونه تصویری از شکل آن نداریم با توجه به مدل‌های مکعبی مدل‌سازی کرد. البته لازم به ذکر است که داشتن اطلاعات اولیه از نهشته

- cellular neural network: *J. Appl. Geophys.*, **46**, 129-142.
- Albora, A. M., Ucan, O. N., and Ozmen, A., 2001b, Residual separation of magnetic fields using a cellular neural network approach: *Pure Appl. Geophys.*, **158**, 1797-1818.
- Blakely, R. J., 1995, Potential theory in gravity and magnetic applications: Cambridge Univ. 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.
- Ekinci, Y. L., 2008, 2D focusing inversion of gravity data with the use of parameter variation as a stopping criterion: *Journal of the Balkan Geophysical Society*, **11**, (1), 1-9.
- Haykin, S., 1999, Neural Networks: Prentice Hall International Inc, 852.
- Osman, O., Albora, A. M., and Ucan, O. U., 2006, A new approach for residual gravity anomaly profile interpretations: Forced Neural Network (FNN). *Annals of Geophysics*, **49**, (6), 1201-1208.
- Osman, O., Albora, A. M., and Ucan, O. U., 2007, Forward modeling with forced Neural networks for gravity anomaly profile: *Math. Geol.*, **39**, 593-605.
- Plouff, D., 1975, Derivation of formulas and FORTRAN program to compute gravity anomalies of prisms: National Technical Information Service PB, 243-526, U. S. Department of Commerce.
- Salem, A., Ravat, D., Mushayandebvu, R. M. and Ushijima, K., 2004, Linearized least-squares method for interpretation of potential-field data from sources of simple geometry: *Geophysics*, **69**, (3), 783-788.
- 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**, 115-122.

دید اولیه‌ای از وضعیت عمقی و گسترش نهشته در مقاطع عمقی گوناگون می‌دهد که کمک شایانی است برای ادامه فرایندهای مدل‌سازی‌های پیشرفته‌تر و برآورد ذخیره واقعی‌تری که با استفاده از سایر روش‌های غیر ژئوفیزیکی مانند گمانه‌های حفاری و روش‌های زمین‌آماری و زمین‌ریاضی حاصل می‌شود.

نتایج حفاری حاکی از این است که نهشته دارای عمقی بین ۷ تا ۱۰ متر است. این روش برای داده‌های میکروگرانی و مغناطیسی (بهخصوص نهشته‌های پرفیری) نیز کاربرد دارد.

تشکر و قدردانی

از مؤسسه ژئوفیزیک دانشگاه تهران به دلیل در اختیار قرار دادن داده‌ها، کمال تشکر را داریم. در انتها از استادانی که زحمت داوری این مقاله را بر عهده داشته‌اند و با پیشنهادات اساسی باعث بهبود آن شده‌اند تشکر و قدردانی می‌کنیم.

منابع

- کیا، م., ۱۳۸۷، شبکه‌های عصبی در MATLAB: نشر کیان رایانه سبز.
- Abedi, M., Afshar, A., Ardestani, V. E., Norouzi, G. H., and Lucas, C., 2009, Application of various methods for 2D inverse modeling of residual gravity anomalies: *Acta Geophysica*, **58**, (2), 331-336.
- Albora, A. M., Ucan, O. N., Ozmen, A., and Ozkan, T., 2001a, Evaluation of sivas-divrigi region akdag iron ore deposits using