

# مدل سازی سه بُعدی بی هنجاری های گرانی با استفاده از روش شبکه های عصبی تحمیلی

میثم عابدی<sup>۱</sup>، احمد افشار<sup>۱</sup>، وحید ابراهیم زاده اردستانی<sup>۲\*</sup>، غلامحسین نوروزی<sup>۳</sup> و کارو لوکس<sup>۴</sup>

<sup>۱</sup>دانشجوی کارشناسی ارشد مهندسی معدن- اکتشاف، پردیس دانشکده های فنی، دانشگاه تهران، ایران  
<sup>۲</sup>دانشیار، مؤسسه ژئوفیزیک دانشگاه تهران، ایران  
<sup>۳</sup>دانشیار، دانشکده مهندسی معدن، پردیس دانشکده های فنی، دانشگاه تهران، ایران  
<sup>۴</sup>استاد، دانشکده مهندسی برق و کامپیوتر، پردیس دانشکده های 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 شبکه های عصبی تحمیلی نامیده می شود، استفاده شده تا توزیع چگالی نهشته های مدفون در مقاطع عمقی متفاوت با فرض مدل مکعبی برای بی هنجاری های گرانی، پیدا شود. هدف از این مدل سازی زمین شناسی، پیدا کردن شکل و محل ساختار زیرزمینی در مقاطع سه بُعدی است. در اینجا، شبکه ای با یک نرون و الگوریتم پس انتشار خطا برای پیدا کردن اختلاف چگالی، به کار رفته است. از آنجاکه معمولاً در روش های مدل سازی داده های پتانسیل از شبیه سازی شکل های ساده هندسی استفاده می شود؛ در این مقاله سعی شده است که ساختار مورد نظر به صورت ترکیبی از مکعب های سه بُعدی در نظر گرفته شود تا بتوان هر ساختار نامشخص هندسی را با استفاده از آن مدل کرد. این روش برای مدل های مصنوعی نوفه دار و بدون نوفه آزمایش شد و بعد از اینکه نتایج رضایت بخشی حاصل شد؛ در مدل سازی زغال های بیتومینه دهلران ایران در حکم داده های واقعی مورد استفاده قرار گرفت. نتایج نهایی به دست آمده از این روش، بیانگر نهشته ای سطحی است که تا عمق کمتر از ۴۰ متر ادامه دارد.

واژه های کلیدی: شبکه های عصبی تحمیلی (FNN)، بی هنجاری گرانی، مدل سازی سه بُعدی، مدل های مصنوعی

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

Maysam Abedi<sup>1</sup>, Ahmad Afshar<sup>1</sup>, Vahid Ebrahimzade Ardestani<sup>2\*</sup>, Gholam Hossain Norouzi<sup>1</sup> and Caro Lucas<sup>3</sup>

<sup>1</sup>Faculty of Mining Engineering, University of Tehran, Iran

<sup>2</sup>Institute of Geophysics, University of Tehran, Iran

<sup>3</sup>Faculty 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 رابعا:

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 yielded 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

نهیته‌های 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 (عابدی 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 خطا

سیگنال خطای حاصل از خروجی نرون  $j$  در تکرار  $m$ ام، به صورت زیر تعریف می‌شود (هیگین، ۱۹۹۹؛ عثمان و همکاران، ۲۰۰۶، ۲۰۰۷):

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

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

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

مجموعه  $C$  شامل همه نرون‌های لایه خروجی شبکه است.  $N$  (کل تکرارها) تمام الگوها (مثال‌ها) را در مجموعه آموزشی مشخص می‌کند. انرژی میانگین مربعات خطا، 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 خطا  $E_{av}$ ، تابع همه پارامترهای آزاد (برای مثال، وزن‌های اتصالی و سطوح بایاس) شبکه هستند. برای دادن مجموعه‌ی آموزشی،  $E_{av}$  تابع هزینه را به منزله‌ی 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 کانی‌سازی از مهم‌ترین پارامترهایی است که در مدل‌سازی داده‌های گرانی‌سنجی بررسی‌های اکتشافی مورد توجه قرار دارد. امروزه روش‌های گوناگونی مانند روش اولر، 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 مغناطیس 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 میکروگرانی‌سنجی به کمک شبکه عصبی و روش پس‌انتشار خطا مدل‌سازی شده است (سالم و همکاران، ۲۰۰۱). روش شبکه عصبی سلولی برای جداسازی بی‌هنجاری محلی از منطقه‌ای نیز به کار رفته است (آلبرا و همکاران، ۲۰۰۱a, b).

$$y_j(n) = \phi_j(v_j(n)), \quad (۸)$$

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

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \phi'_j(v_j(n)), \quad (۹)$$

### ۳ مدل به کار رفته

مدلی که اینجا به کار رفته است، یکی از معروف ترین مدل هایی است که پلوف برای مدل سازی سه بُعدی بی هنجاری های گرانی بیان کرده است (بلکلی، ۱۹۹۵). در این مدل، مجموعه ای از بلوک های مکعبی برای تقریب شکل نهشته به کار می رود. این تقریب سه بُعدی در شکل ۲ نشان داده شده است. هر یک از این بلوک ها می توانند اختلاف چگالی دلخواهی با محیط اطراف داشته باشند؛ بنابراین طبق اصل جمع پذیری اثر داده های پتانسیل (گرانی و مغناطیس)، بی هنجاری گرانی در هر نقطه را می توان به صورت تقریبی از مجموع اثر هر کدام از بلوک ها دانست (بلکلی، ۱۹۹۵).

یک منشور چهاروجهی با چگالی یکنواخت  $\rho$  و با

$$y_1 \leq y \leq y_2, \quad x_1 \leq x \leq x_2$$

و  $z_1 \leq z \leq z_2$  در مرکز مختصات، دارای جاذبه قائم به صورت زیر است :

$$\gamma \int_{z_1}^{z_2} \int_{y_1}^{y_2} \int_{x_1}^{x_2} \frac{z'}{[x'^2 + y'^2 + z'^2]^{\frac{3}{2}}} dx' dy' dz', \quad (۱۰)$$

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

$$g = \gamma \rho \sum_{i=1}^2 \sum_{j=1}^2 \sum_{k=1}^2 \mu_{ijk} \begin{bmatrix} z_k \arctan \frac{x_i y_j}{z_k R_{ijk}} \\ -x_i \cdot \log(R_{ijk} + y_j) \\ -y_j \cdot \log(R_{ijk} + x_i) \end{bmatrix}, \quad (۱۱)$$

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 می شود که در آن وزن ها، الگو به الگو براساس یک دوره روزآمد می شوند. عرضه کاملی از کل مجموعه آموزشی به صورت زیر است:

$$\Delta w_{ij}(n) = \eta \delta_j(n) y_i(n), \quad (۴)$$

که در آن  $\delta_j(n)$ ، گرادیان محلی و  $\eta$ ، سرعت یادگیری است. مقدار گرادیان در وزن های اتصالی مستلزم تغییر می شود و فرمول پس انتشار خطا برای گرادیان محلی  $\delta_j(n)$  به صورت زیر به دست می آید:

$$\delta_j(n) = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n), \quad (۵)$$

ضریب  $\phi'_j(v_j(n))$  در رابطه (۵) که برای محاسبه گرادیان محلی  $\delta_j(n)$  آمده است، فقط به تابع تحریک 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 سیگنال های خطای  $e_k(n)$  برای همه نرون هایی که در لایه سمت راست بعد از نرون مخفی  $j$  قرار گرفته اند مربوط است و به طور مستقیم به نرون  $j$  متصل است (شکل ۱). دومین عبارت یعنی  $w_{kj}(n)$ ، شامل وزن های مرتبط با این اتصالات است. می توان تعریف دوباره ای از گرادیان محلی  $\delta_j(n)$  برای نرون مخفی  $j$  به صورت زیر آورد:


$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \quad (۶)$$

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

پارامتر محلی  $v_j(n)$  در ورودی تابع تحریک مرتبط با نرون  $j$  تولید می شود، بنابراین،

$$v_j(n) = \sum_{i=0}^m w_{ij}(n) y_i(n), \quad (۷)$$

که در آن  $m$ ، تعداد کل ورودی ها (به استثنای بایاس) به نرون  $j$  است. وزن اتصالی  $w_{j0}$  (مطابق با ورودی ثابت  $y_0 = +1$ ) مساوی بایاس  $b_j$  به کاررفته در نرون  $j$  است. بنابراین، تابع سیگنال  $y_j(n)$  که در ورودی نرون  $j$  در تکرار  $n$  م ظاهر می شود، 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 هر یک از این مکعب‌ها نسبت داده می‌شوند. بعد از استفاده از روش پس‌انتشار خطا، مقادیر  $\Delta\rho_{ijk}$  روزآمد می‌شود تا اینکه خروجی با کمترین خطا مطابق با بی‌هنجاری، گرانی‌سنجی شود. در نتیجه، اختلاف چگالی به دست می‌آید. اما به دلیل نبود یکتایی جواب، به کارگیری این الگوریتم به تنهایی کافی نیست. از آنجا که 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 ناحیه‌ای که از تحقیقات زمین‌شناسی به دست می‌آید، برابر گرفته می‌شود. در شکل ۴، پیاده‌سازی این الگوریتم به صورت نمودار گردش (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:

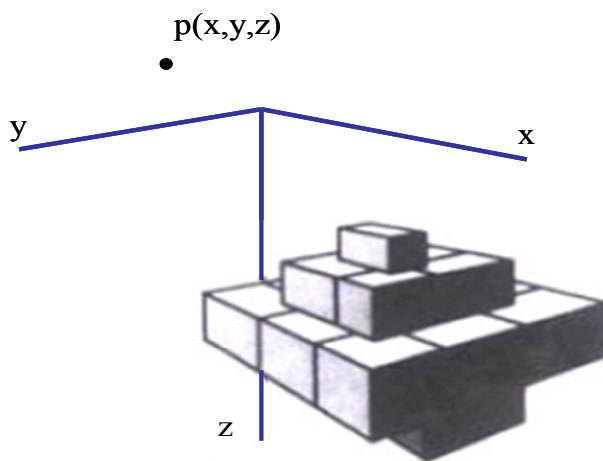
$$[G] = [A_{ijk}] \cdot [\Delta\rho_{ijk}] \quad (12)$$

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

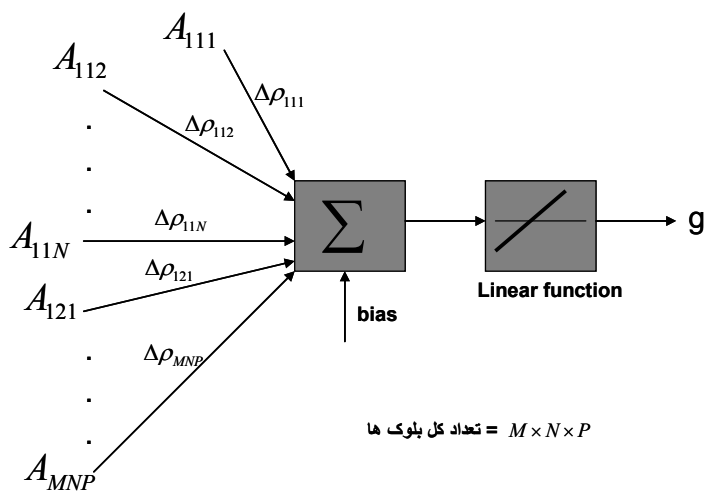
#### ۴ روش شبکه‌های عصبی تحمیلی (FNN)

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 نوشتن یک کد محاسبه می‌شود و

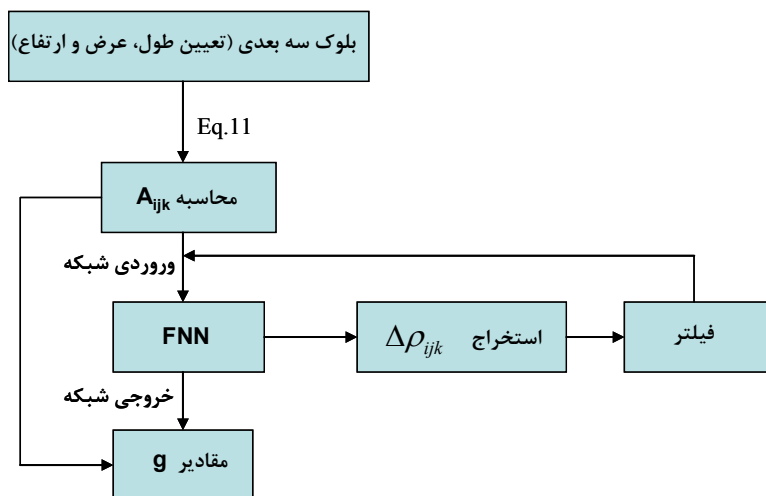
ارزش آن در تمام مراحل پیاده‌سازی الگوریتم مدل‌سازی ثابت است. در اینجا از تابع تحریک خطی استفاده می‌شود تا این ورودی‌ها با وزن مناسبی که از روش پس‌انتشار خطا برای آن حاصل می‌شود (براساس حداقل مربعات خطا) به خروجی مورد نظر نزدیک شود. خروجی‌ها، همان مقادیر بی‌هنجاری گرانی مشاهده شده هستند (عثمان و همکاران، ۲۰۰۶، ۲۰۰۷). با نگاهی به




شکل ۲. تقریب یک نهشته با استفاده از مجموعه‌ای از بلوک‌ها در سه‌بعد (بلکلی، ۱۹۹۵).




شکل ۳. شبکه به کار رفته.




شکل ۴. الگوریتم پیاده‌سازی مدل.



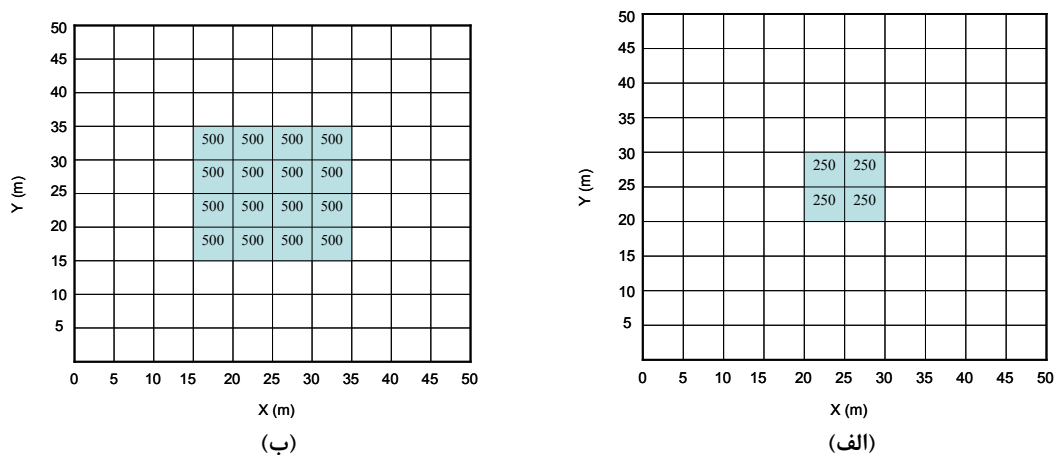
شکل ۵. بی‌هنجاری گرانیتی مدل مصنوعی اول.




شکل ۶. نتایج مدل‌سازی ساختار مصنوعی دوم.



شکل ۷. بی‌هنجاری گرانیتی مدل مصنوعی دوم.



شکل ۸. نتایج مدل‌سازی ساختار مصنوعی دوم: (الف) عمق بین ۰-۵ متر و (ب) عمق بین ۵-۱۰ متر.



شکل ۹. بی‌هنجاری گرانی مدل مصنوعی سوم.

#### ۵ مدل‌سازی سه‌بُعدی داده‌های مصنوعی

برای بیان کارایی مدل، سه مثال آورده شده است. از آنجاکه بی‌نهایت حالت متفاوت برای در نظر گرفتن مدل‌های مصنوعی وجود دارد، سعی شده است از مدل‌های ساده استفاده شود تا فرایند مدل‌سازی راحت‌تر و قابل فهم باشد. بی‌هنجاری 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 بی‌هنجاری ناشی از این

مدل را نشان می‌دهد. اختلاف چگالی مدل با زمینه  $500 \text{ kg/m}^3$  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 رخنمون‌دار و دارای اختلاف چگالی  $250 \text{ kg/m}^3$  با زمینه است. طول و عرض دیگری ۲۰ متر و محدوده



برداشت نقاط از دستگاه گرانی‌سنجی نوع Scintrex CG3 با دقت ۵ میکروگال استفاده شده است. شبکه ۲۰ در ۲۰ متر برای برداشت این ناحیه را بخش گرانی‌سنجی 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 سه‌بُعدی، 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، نهشته تا 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 سه‌بُعدی وجود ندارد که بتواند به طور دقیق توزیع نهشته‌ها را در اعماق 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 برآوردی با احتمال زیاد از حجم و محدود نهشته به دست آورد.

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

عمقی آن بین ۵ تا ۱۰ متر است که اختلاف چگالی آن با زمینه  $500 \text{ kg/m}^3$  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 آنجا که در برداشت‌های گرانی‌سنجی معمولاً نوفه وجود دارد، در مثال سوم، ساختاری مدل شده که چند تا از داده‌های آن به صورت تصادفی تا ۱۰ درصد نوفه‌دار شده‌اند. برای اینکه نوفه روی داده اثر داده شود از تابع 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)،  $G_{noise}$  بی‌هنجاری نوفه‌دار حاصل از مدل بدون نوفه 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 رخنمون دارد. بی‌هنجاری ناشی از این مدل در شکل ۹ نشان داده شده است. اختلاف چگالی مدل با زمینه  $1000 \text{ kg/m}^3$  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.

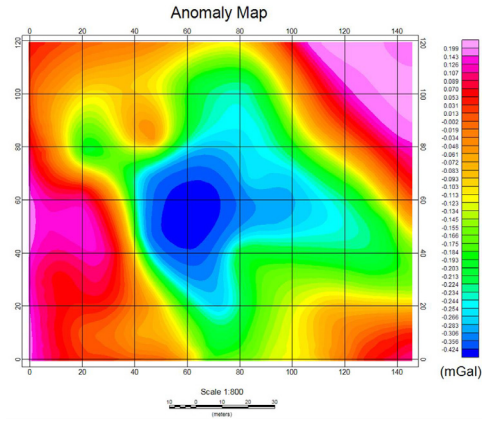
## ۶ مدل‌سازی داده‌های واقعی

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







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




شکل ۱۲. نقشه بی‌هنجاری بازماند ناحیه برداشت شده.




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




شکل ۱۴. نقشه توزیع اختلاف چگالی در عمق ۵-۱۰ متر.




شکل ۱۷. نقشه توزیع اختلاف چگالی در عمق ۲۰-۲۵ متر.




شکل ۱۶. نقشه توزیع اختلاف چگالی در عمق ۱۵-۲۰ متر.



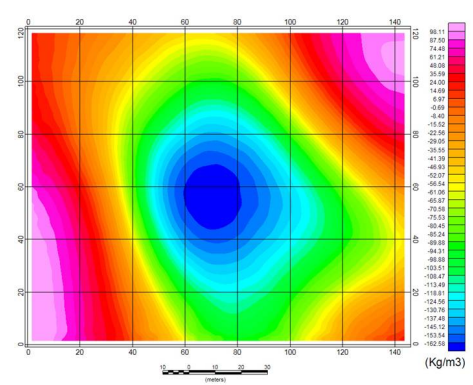
شکل ۱۹. نقشه توزیع اختلاف چگالی در عمق ۳۰-۳۵ متر.




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



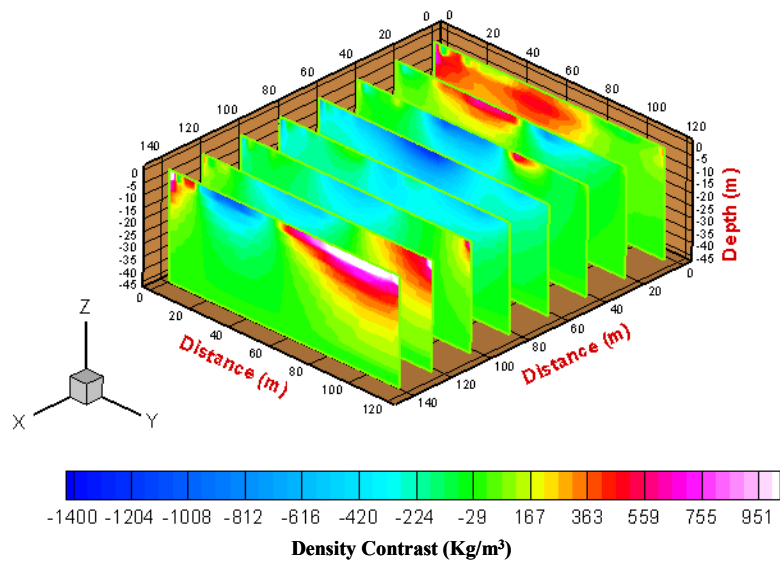
شکل ۲۱. نقشه توزیع اختلاف چگالی در عمق ۴۰-۴۵ متر.



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



شکل ۲۲. بی‌هنجاری ناشی از مدل‌سازی صورت گرفته.



شکل ۲۳. نمایش سه‌بُعدی مدل‌سازی صورت‌گرفته.

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

این روش در ابتدا در مورد سه مدل مصنوعی آزمایش شد و بعد از آن که نتایج مناسبی حاصل آمد؛ روی داده‌های واقعی یعنی نهشته زغال بیتومینه دهلران ایران، پیاده شد که نتایج آن همان‌طور که مشاهده شد، مناسب بود. نتایج این مدل‌سازی سه‌بُعدی حاکی از آن است که نهشته به صورت سطحی است و تا عمقی کمتر از ۴۰ متر ادامه دارد. به دلیل آن که توزیع اختلاف چگالی با زمینه به ازای مقطع عمقی ۴۰-۴۵ بسیار کاهش می‌یابد می‌توان این نتیجه را گرفت که گسترش زغال بیتومینه تا محدوده عمقی ۴۰ متر است. نکته اساسی برای این روش مدل‌سازی سه‌بُعدی که نخستین بار پیشنهاد شده این است که در واقع به دلیل نبود یکتای داده‌های پتانسیل، هیچ روش مدل‌سازی گرانی‌سنجی نمی‌تواند با قاطعیت مدل سه‌بُعدی 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 مدل‌سازی

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. به دلیل 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 سه‌بُعدی بی‌هنجاری‌های 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 واقعی تری 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