

مدل‌سازی مستقیم دو بعدی بی‌هنجاري‌های گرانی نهشته‌های کم عمق با استفاده از روش شبکه‌های عصبی تحمیلی

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

چکیده

در این مقاله، از یک روش جدید که شبکه‌های عصبی تحمیلی نامیده می‌شود، استفاده می‌کنیم تا پارامترهای نهشته‌های مدفون را در یک مقطع مورد نظر ژئوفیزیکی با فرض مدل منشوری برای بی‌هنجاري‌های گرانی، پیدا کنیم. هدف از این مدل‌سازی زمین‌شناسی، پیدا کردن شکل و محل ساختار زیرزمینی در مقطع دو بعدی می‌باشد. در اینجا، شبکه‌ای با یک نرون و الگوریتم پس انتشار خطرا برای پیدا کردن اختلاف چگالی، بکار گرفته شده است. این روش برای داده‌های مصنوعی نویزدار و بدون نویز آزمایش شد و سپس زغال‌های بیتومینه دهلران ایران به عنوان داده‌های واقعی بکار گرفته شد.

کلید واژه‌ها: شبکه‌های عصبی تحمیلی، بی‌هنجاري گرانی، مدل‌سازی، مدل‌های مصنوعی

2-D Forward Modeling of Near Surface Gravity Anomaly by Using of Forced Neural Networks Method

Meysam Abedi, Ahmad Afshar, Dr. Vahid Ebrahimzadeh Ardestani,
Dr. Gholam-hossein Norouzi and Dr. Caro Lucas

Abstract

In this paper, we use a new method called Forced Neural Networks (FNN) to find the parameters of buried deposit in geophysical section respect to gravity anomaly assuming the prismatic model. The aim of the geological modeling is to find the shape and location of underground structures in 2-D cross section. Here, an one neuron network and back propagation algoritm are applied to fined out the density difference. The method is used for noise-free and noise-corruption synthetic data, and then the Dehloran bitumen field map in Iran is chosen as a real data.

Keywords: Forced Neural Networks, Gravity Anomaly, Modeling, Synthetic Model

۱- دانشجوی کارشناسی ارشد مهندسی معدن- اکتشاف، پردیس دانشکده‌های فنی، دانشگاه تهران

۲- دانشیار موسسه ژئوفیزیک، دانشگاه تهران

۳- دانشیار دانشکده مهندسی معدن، پردیس دانشکده‌های فنی، دانشگاه تهران

۴- استاد دانشکده مهندسی برق، پردیس دانشکده‌های فنی، دانشگاه تهران

مقدمه

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 پس انتشار خطا مدل سازی شده است (اسلام و همکاران ۲۰۰۱). روش شبکه عصبی سلولی برای جداسازی بی‌هنگاری محلی از منطقه‌ای نیز به کار گرفته شده است (آبراهام و همکاران ۲۰۰۱).

در مدل‌سازی داده‌های گرانی‌سنجدی، از مهمترین پارامترهایی که در کارهای اکتشافی مورد توجه می‌باشد، عمق و محدوده کانی‌سازی است. امروزه روش‌های مختلفی مانند روش اویلر، حداقل مربعات، روش دی‌کانولوشن ورنر و ... برای چنین مدل‌سازی‌هایی وجود دارند (سالم و همکاران ۲۰۰۴).

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای به صورت موازی ساخته می‌شوند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته شده‌اند. در طبیعت، ساختار شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. بنابراین ما می‌توانیم یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی بسازیم و با تنظیم مقادیر هر اتصال تحت عنوان وزن اتصال نحوه ارتباط بین اجزای آن را تعیین نمائیم. 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 گرفته می‌شود تا در این روند که از آن تحت عنوان یادگیری نظارت شده یاد می‌شود، شبکه آموزش داده شود (کیا ۱۳۸۷).

در سال‌های اخیر، کاربرد شبکه‌های عصبی مختلف برای مدل‌سازی داده‌های گرانی و مغناطیسی افزایش یافته است. به عنوان مثال محل کپسول‌های فلزی به کمک روش شبکه عصبی نظارت شده از

الگوریتم پس انتشار خطا

سیگنال خطای حاصل از خروجی نرون \mathbf{z} در تکرار n ، به صورت زیر تعریف می‌شود:

$$\mathbf{e}_j(n) = \mathbf{d}_j(n) - \mathbf{y}_j(n) \quad (1)$$

که در آن نرون \mathbf{z} ، گره خروجی، $\mathbf{d}_j(n)$ خروجی مطلوب و $\mathbf{y}_j(n)$ خروجی واقعی شبکه‌های عصبی است. ارزش لحظه‌ای انرژی خطا برای نرون \mathbf{z} می‌تواند به صورت $\frac{1}{2} e_{j(n)}^2$ تعریف شود. بر این اساس، ارزش لحظه‌ای انرژی خطا کل یعنی E ، با جمع تمام $\frac{1}{2} e_{j(n)}^2$ نرون‌های لایه خروجی بدست می‌آید؛ فقط برای نرون‌های قابل مشاهده، سیگنال خطا می‌تواند به صورت مستقیم محاسبه شود. بنابراین، داریم:

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

مجموعه C شامل تمام نرون‌های لایه خروجی شبکه است. N تمام الگوها (مثال‌ها) را در مجموعه آموزشی مشخص می‌کند. انرژی میانگین مربعات

فاکتور باقیمانده، یعنی مجموع k عنصر، به دو عبارت بستگی دارد: نخستین عبارت یعنی $(n)_j^\delta$ ، به دانش سیگنال‌های خطای $e_k(n)$ برای تمام نرون‌هایی که در لایه سمت راست بعد از نرون j مخفی j قرار گرفته‌اند و به طور مستقیم به نرون j متصل می‌باشد (شکل ۱). دومین عبارت یعنی $w_{kj}(n)$ ، شامل وزن‌های مرتبه با این اتصالات می‌باشد. ما می‌توانیم تعریف دوباره‌ای از گرادیان محلی $(n)_j^\delta$ برای نرون مخفی j به صورت زیر ارائه کنیم:

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

پارامتر محلی $v_j(n)$ در ورودی تابع تحریک مرتبه 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 $y_0 = +1$) مساوی بایاس b_j به کاربرده شده در نرون j می‌باشد. بنابراین، تابع سیگنال $y_j(n)$ که در ورودی نرون j در تکرار n ام ظاهر می‌شود، عبارت است از:

$$y_j(n) = \varphi_j(v_j(n)) \quad (8)$$

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

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_{j'}(v_j(n)) \quad (9)$$

خطا، جمع $E(n)$ برای تمام n ‌ها می‌باشد 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 تمام پارامترهای آزاد (به عنوان مثال، وزن‌های اتصالی و سطوح بایاس) شبکه می‌باشد (هیکین ۱۹۹۹، عثمان و همکاران ۲۰۰۶ و ۲۰۰۷). برای دادن مجموعه‌ای آموزشی، E_{av} تابع هزینه را به عنوان وسیله‌ای برای انجام آموزش ارائه می‌کند. هدف از فرایند آموزش، انطباق پارامترهای آزاد شبکه به حداقل E_{av} می‌باشد. برای انجام این حداقل سازی، ما از تقریبی مشابه با الگوریتم مشتق حداقل میانگین مربعات استفاده می‌کنیم. ما از روش ساده آموزشی استفاده می‌کنیم که در آن وزن‌ها، الگو به الگو بر اساس یک دوره به روز می‌شوند. یک ارائه‌ی کامل از کل مجموعه آموزشی به صورت زیر است:

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

که در آن $(n)_j^\delta$ ، گرادیان محلی و η ، سرعت یادگیری است. مقدار گرادیان در وزن‌های اتصالی مستلزم تغییر می‌شود و ما فرمول پس انتشار خطای را برای گرادیان محلی $(n)_j^\delta$ به صورت زیر بدست می‌آوریم:

$$\delta_j(n) = \varphi'_{j'}(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (5)$$

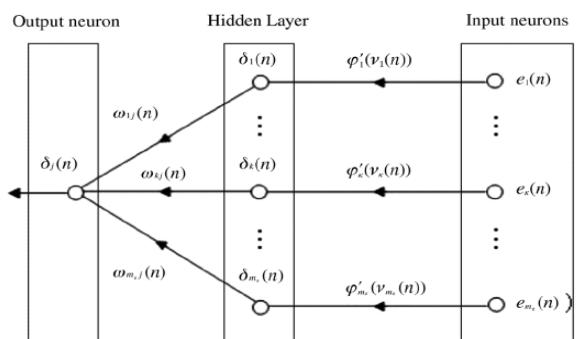
فاکتور $(v_j(n))' \varphi$ در رابطه (۵) که برای محاسبه گرادیان محلی $(n)_j^\delta$ آمده است، فقط به تابع تحریک مرتبه با نرون مخفی j ، بستگی دارد.

و γ ثابت جهانی جاذبه است.

روش شبکه‌های عصبی تحمیلی (FNN)

در این مدل سازی از شبکه عصبی یک لایه با یک نرون (شکل ۳) استفاده می‌شود (عثمان و همکاران ۲۰۰۶ و ۲۰۰۷).

در این شبکه ورودی‌ها a_{ij} ‌ها می‌باشند که نشان دهنده ارزش هر پیکسل و یا منشور می‌باشد. سپس از تابع تحریک خطی استفاده می‌گردد تا این ورودی‌ها با وزن مناسبی که از روش پس انتشار خطاب برای آن حاصل می‌شود به خروجی مورد نظر، نزدیک (براساس حداقل مربعات خطاب) کند. در اینجا خروجی‌ها، همان مقادیر بی‌هنجاری گرانی مشاهده شده می‌باشد. با نگاهی به معادله (۱۰)، متوجه می‌شویم که این وزن‌ها در واقع همان اختلاف چگالی ($v_j = \Delta\rho_{ij} = \Delta\rho_{ij}$) مورد نظر ما می‌باشد که از طریق شبکه عصبی به هر یک از این منشورها نسبت داده می‌شود. بعد از استفاده از روش پس انتشار خطاب، v_j (یا $\Delta\rho_{ij}$ ‌ها) به روز می‌شوند تا اینکه خروجی ما با کمترین خطای مطابق با بی‌هنجاری گرانی سنجی شود. بنابراین اختلاف چگالی بدست می‌آید. اما به دلیل عدم یکتاپی جواب به کارگیری این الگوریتم به تنها یک کافی نمی‌باشد. از آنجایی که مقدار وزن اولیه شبکه عصبی در همگرایی و واگرایی شبکه بسیار موثر می‌باشد؛ پس از هر توقف شبکه که در آن وزن مناسب حاصل شد، باید وزن‌های نزدیک به صفر را صفر نمائیم (فیلتر کردن) و این فرایند را در صورتی که چند بار انجام دهیم،



شکل ۱- مدل شبکه عصبی تحمیلی (FNN)

مدل بکار گرفته شده

مدل انتخابی در اینجا، یکی از معروف‌ترین مدل‌هایی است که لاست و کوبیک (۱۹۸۳) برای مدل‌سازی داده‌های گرانی از آن استفاده کرده‌اند. این مدل آرایه‌ای از مستطیل‌های است که با ثابت نگه داشتن هندسه به هر بلوک اجازه می‌دهد تا چگالی متغیر داشته باشد. این مدل در شکل (۲) نشان داده شده است. برای چنین مدلی، گرانی نقطه i ام از داده‌های مشاهده شده برابر است با:

$$g_i = \sum_{j=1}^M a_{ij} v_j + e_i, \quad i = 1 \dots N \quad (10)$$

که در آن v_j چگالی بلوک j ام و e_i نویه در داده i ام و a_{ij} ماتریس کرنل داده‌های است. برای a_{ij} می‌توان گفت:

$$a_{ij} = 2\gamma[(x_i - x_j + d/2)\log(r_2 r_3 / r_1 r_4) + d\log(r_4/r_3) - (z_j + h/2)(\theta_4 - \theta_2) + (z_j - h/2)(\theta_3 - \theta_1)] \quad (11)$$

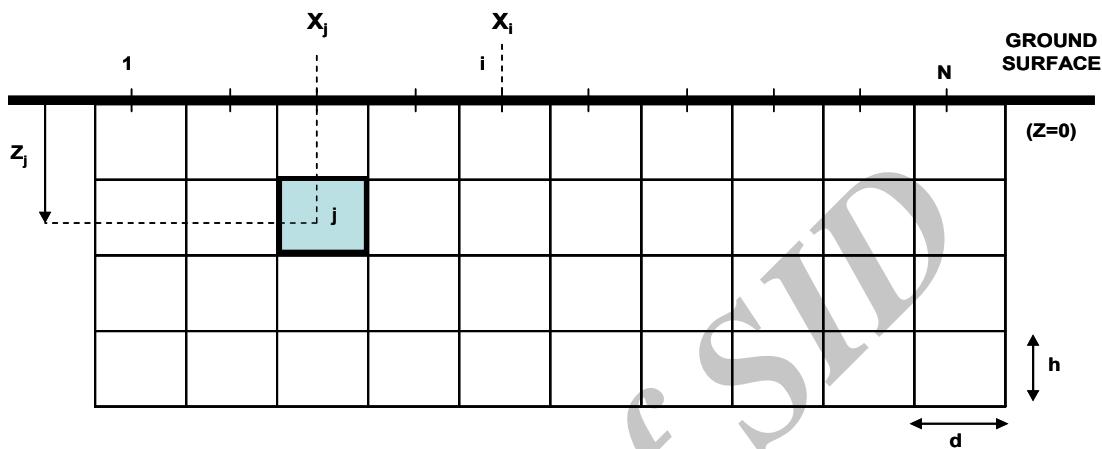
که در آن:

$$\begin{aligned} r_1^2 &= (z_j - h/2)^2 + (x_i - x_j + d/2)^2, \\ r_2^2 &= (z_j + h/2)^2 + (x_i - x_j + d/2)^2, \\ r_3^2 &= (z_j - h/2)^2 + (x_i - x_j - d/2)^2, \\ r_4^2 &= (z_j + h/2)^2 + (x_i - x_j - d/2)^2, \\ \theta_1 &= \arctan(x_i - x_j + d/2)/(z_j - h/2), \\ \theta_2 &= \arctan(x_i - x_j + d/2)/(z_j + h/2), \\ \theta_3 &= \arctan(x_i - x_j - d/2)/(z_j - h/2), \\ \theta_4 &= \arctan(x_i - x_j - d/2)/(z_j + h/2). \end{aligned}$$

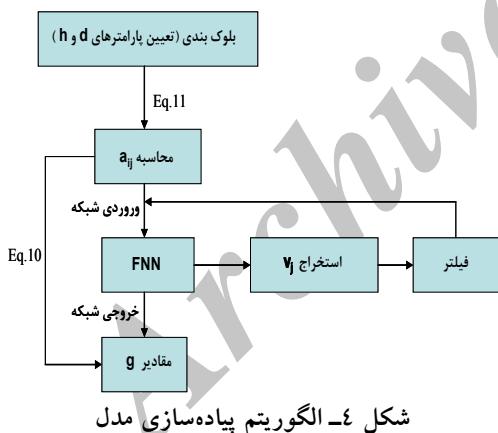
مدل‌سازی مستقیم دو بعدی بی‌هنجاری‌های گرانی نهشته‌های کم عمق با استفاده از...

قرار می‌دهیم. در شکل (۴)، پیاده‌سازی این الگوریتم به صورت فلوچارت آمده است.

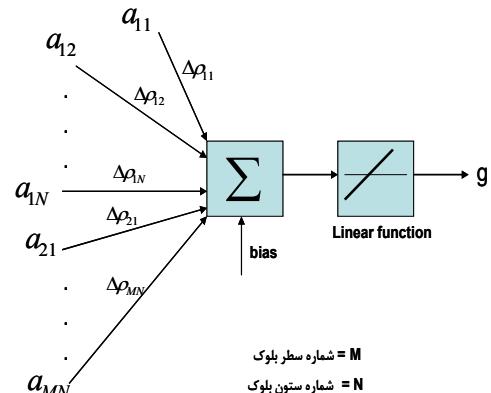
به مدل واقعی می‌رسیم. بعد از اینکه مدل‌سازی انجام شد، اختلاف چگالی را برابر با اختلاف چگالی ناحیه که از مطالعات زمین‌شناسی حاصل می‌گردد،



شکل ۲- مدل دو بعدی، در شکل بالا نقطه z ام و بلوک z نشان داده شده است. d و h به ترتیب طول و عرض بلوک‌ها هستند.
(لاست و کوبیک، ۱۹۸۳).



شکل ۴- الگوریتم پیاده‌سازی مدل



شکل ۳- شبکه بکار گرفته شده

مدل‌سازی داده‌های مصنوعی

به منظور بیان کارایی روش، به طرح چهار مثال می‌پردازیم. در هر مثال، مدل‌های مصنوعی با بلوک‌های تیره به همراه بی‌هنجاری ناشی از آن نشان داده شده است (شکل‌های ۸-۵). اختلاف چگالی کم Kg/m^3 فرض شده است.

نکته: طبق این فلوچارت، برای تست مدل‌های مصنوعی، بعد از محاسبه a_{ij} ‌ها، طبق معادله (۱۰) مقادیر g که همان خروجی شبکه می‌باشد، محاسبه می‌شود. برای داده‌های واقعی این مرحله دیگر نیاز نمی‌باشد؛ زیرا مقادیر g مشخص می‌باشند.

می باشد. از نظر زمین‌شناسی سنگ‌های منطقه آهکی – مارنی است. برای برداشت نقاط از دستگاه گرانی‌سنجد نوع CGS Scintrex با دقت ۵ میکروگال استفاده شده است. شبکه ۲۰ در ۲۰ متر برای برداشت این ناحیه توسط گروه گرانی‌سنجد موسسه ژئوفیزیک دانشگاه تهران صورت گرفته است. بعد از تصحیح داده‌های برداشت شده و حذف اثر روند ناحیه‌ای (درجه ۲)، بی‌هنجری مورد نظر ترسیم گردید (شکل ۱۰). در این بی‌هنجری، پروفیل شمال غربی – جنوب شرقی AB برای مدل سازی در نظر گرفته شده است که نمودار آن در شکل ۱۱. الف) آورده شده است.

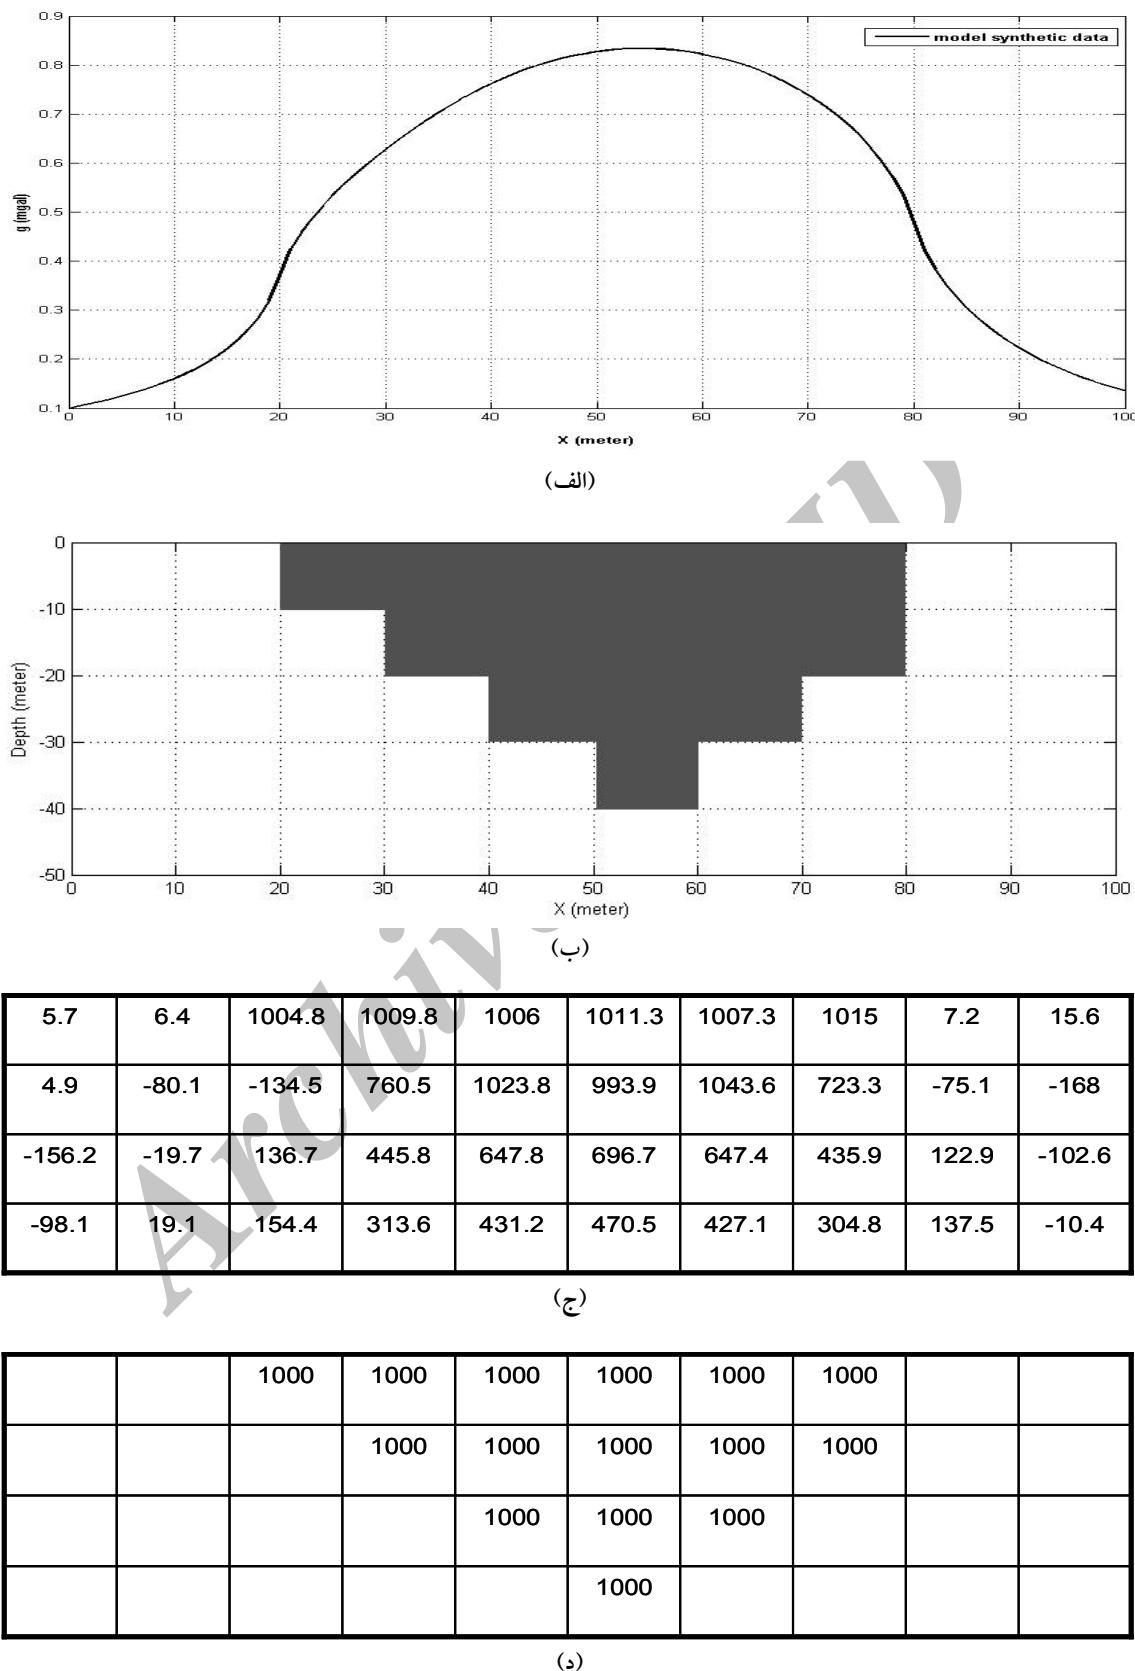
در این ناحیه، نتایج آنالیز نمونه‌های برداشت شده، حاکی از اختلاف چگالی حدود Kg/m^3 ۱۴۰۰–۱۴۰۰ بین نهشته مورد نظر و سنگ‌های ناحیه می باشد. با بکارگیری این روش مدل‌سازی روی مقطع AB، عمق و محدوده تقریبی نهشته بدست آمده که در شکل (۱۱. ب) نشان داده شده است. در این جا طول و عرض بلوک‌ها 5×5 در نظر گرفته شده است. همانطور که در شکل می‌بینیم، هدف مورد نظر از عمق حداقل ۱۰ متر شروع می‌شود و به عمق ماکزیمم ۳۵ متر می‌رسد. در این مدل سازی بهترین جواب برای حالتی پیش آمد که اختلاف چگالی بین نهشته مورد نظر و سنگ‌های ناحیه Kg/m^3 ۱۳۵۰–۱۳۵۰ فرض شد. مقدار بی‌هنجری حاصل از مدل بدست آمده، خیلی نزدیک به مقدار واقعی بی‌هنجری گرانی ما در مقطع AB می‌باشد (شکل ۱۱. الف).

در حالت اول، یک نهشته سطحی با رخمنون، مدل شده است که پس از ۱۰ تکرار، به کمک انتخاب فیلتر زمین‌شناسی مناسب، به مدل حقیقی همگرا شده است (شکل ۵). نکته‌ای که باید به آن توجه کرد این است که انتخاب این فیلتر کاملاً سلیقه‌ای می‌باشد و به تجربه و دید زمین‌شناسی شخص بستگی دارد. در حالت دوم، یک نهشته منفرد با عمق ۱۰ متر، مدل شده است که پس از ۱۰ تکرار به مدل حقیقی همگرا شده است (شکل ۶). سومین حالت، دو ساختار مجزا با عمق‌های متفاوت صفر و ۱۰ متر را مدل کرده که پس از ۶ تکرار به مدل حقیقی همگرا شده است (شکل ۷). نکته‌ای که از مدل سازی برای سایر حالت‌ها بدست می‌آید، حاکی از آن است که برای نهشته‌های نزدیک به سطح و کم عمق، دقت مدل سازی افزایش نشان می‌دهد. از آنجایی که در برداشت‌های ژئوفیزیکی، معمولاً نویز وجود دارد؛ ما این روش را روی یک مدل نویز دار تست می‌کنیم. در این حالت دو داده را به میزان ۵ و ۱۰٪ نویزدار می‌کنیم و سپس مانند حالات قبل مدل‌سازی را پیاده می‌کنیم (شکل ۸). همانطور که می‌بینیم، با وجود نویز، پس از ۶ تکرار به مدلی نزدیک به مدل واقعی می‌رسیم.

مدل‌سازی داده‌های واقعی

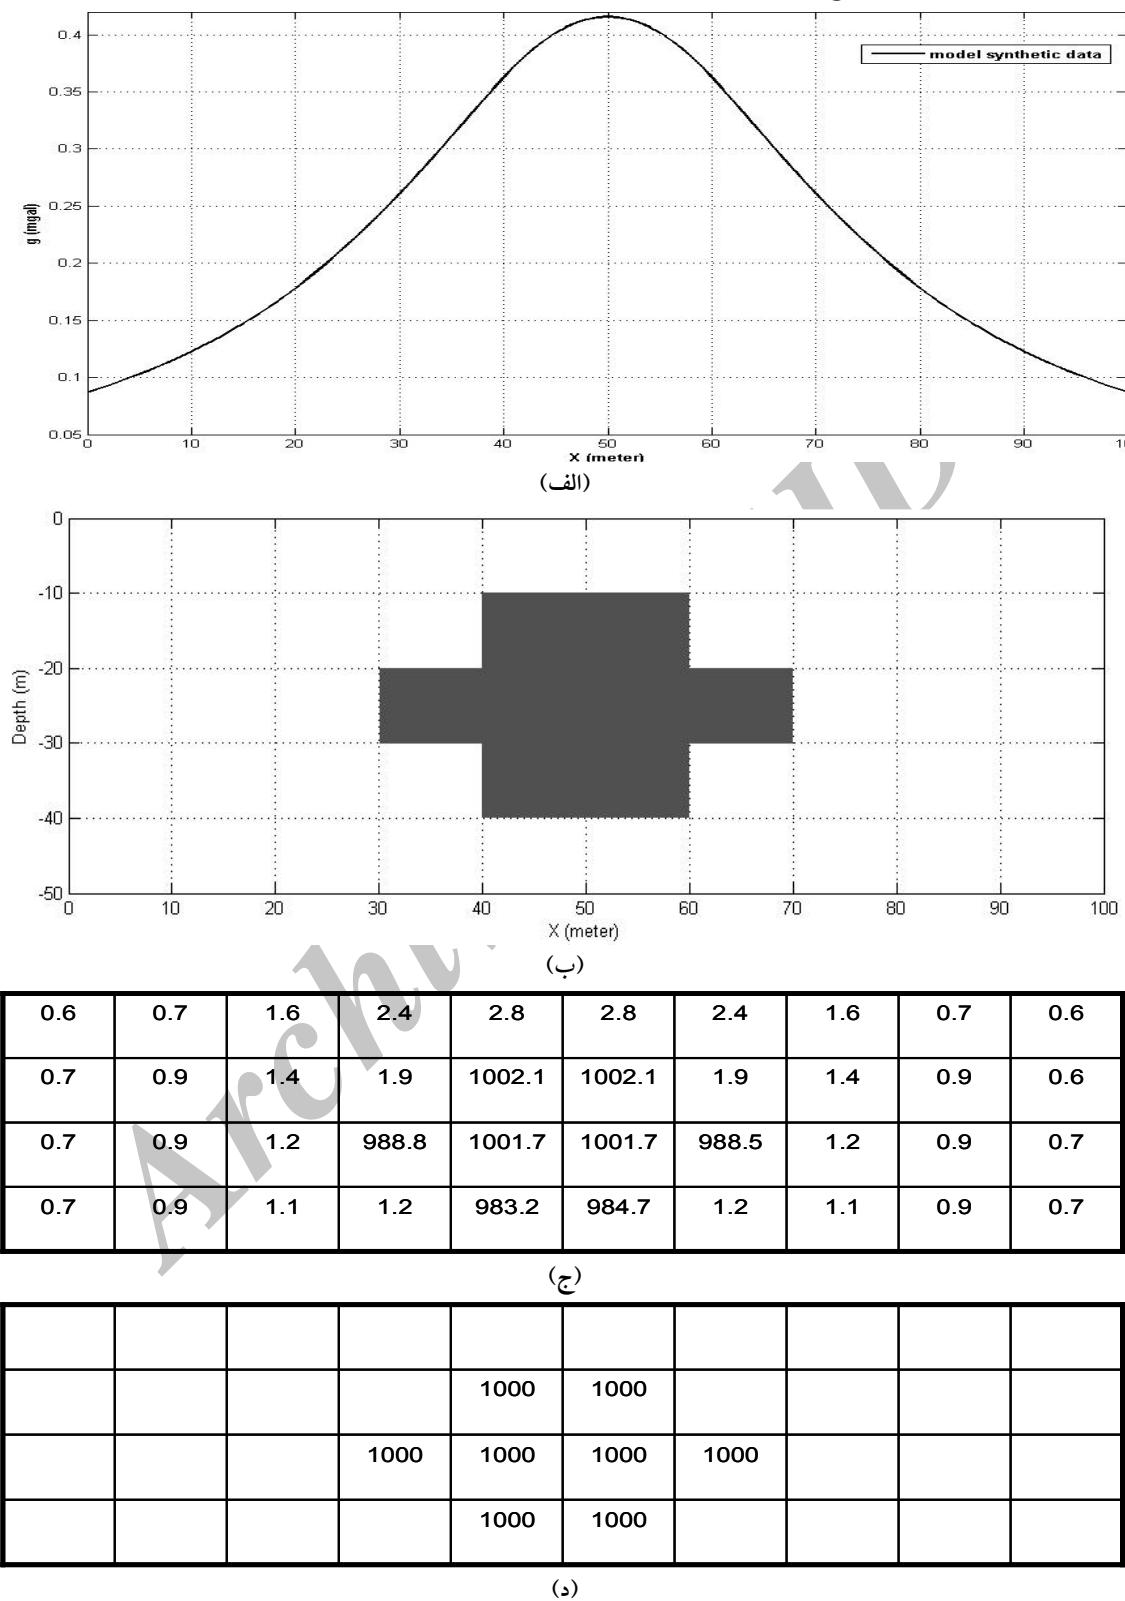
ناحیه مورد نظر در غرب ایران و در زون تکتونیکی زاگرس واقع شده است (شکل ۹). در منطقه‌ی دهلران، هدف ما اکتشاف بیتومین‌های نفتی

مدل‌سازی مستقیم دو بعدی بی‌هنجاری‌های گرانی نهشته‌های کم عمق با استفاده از...



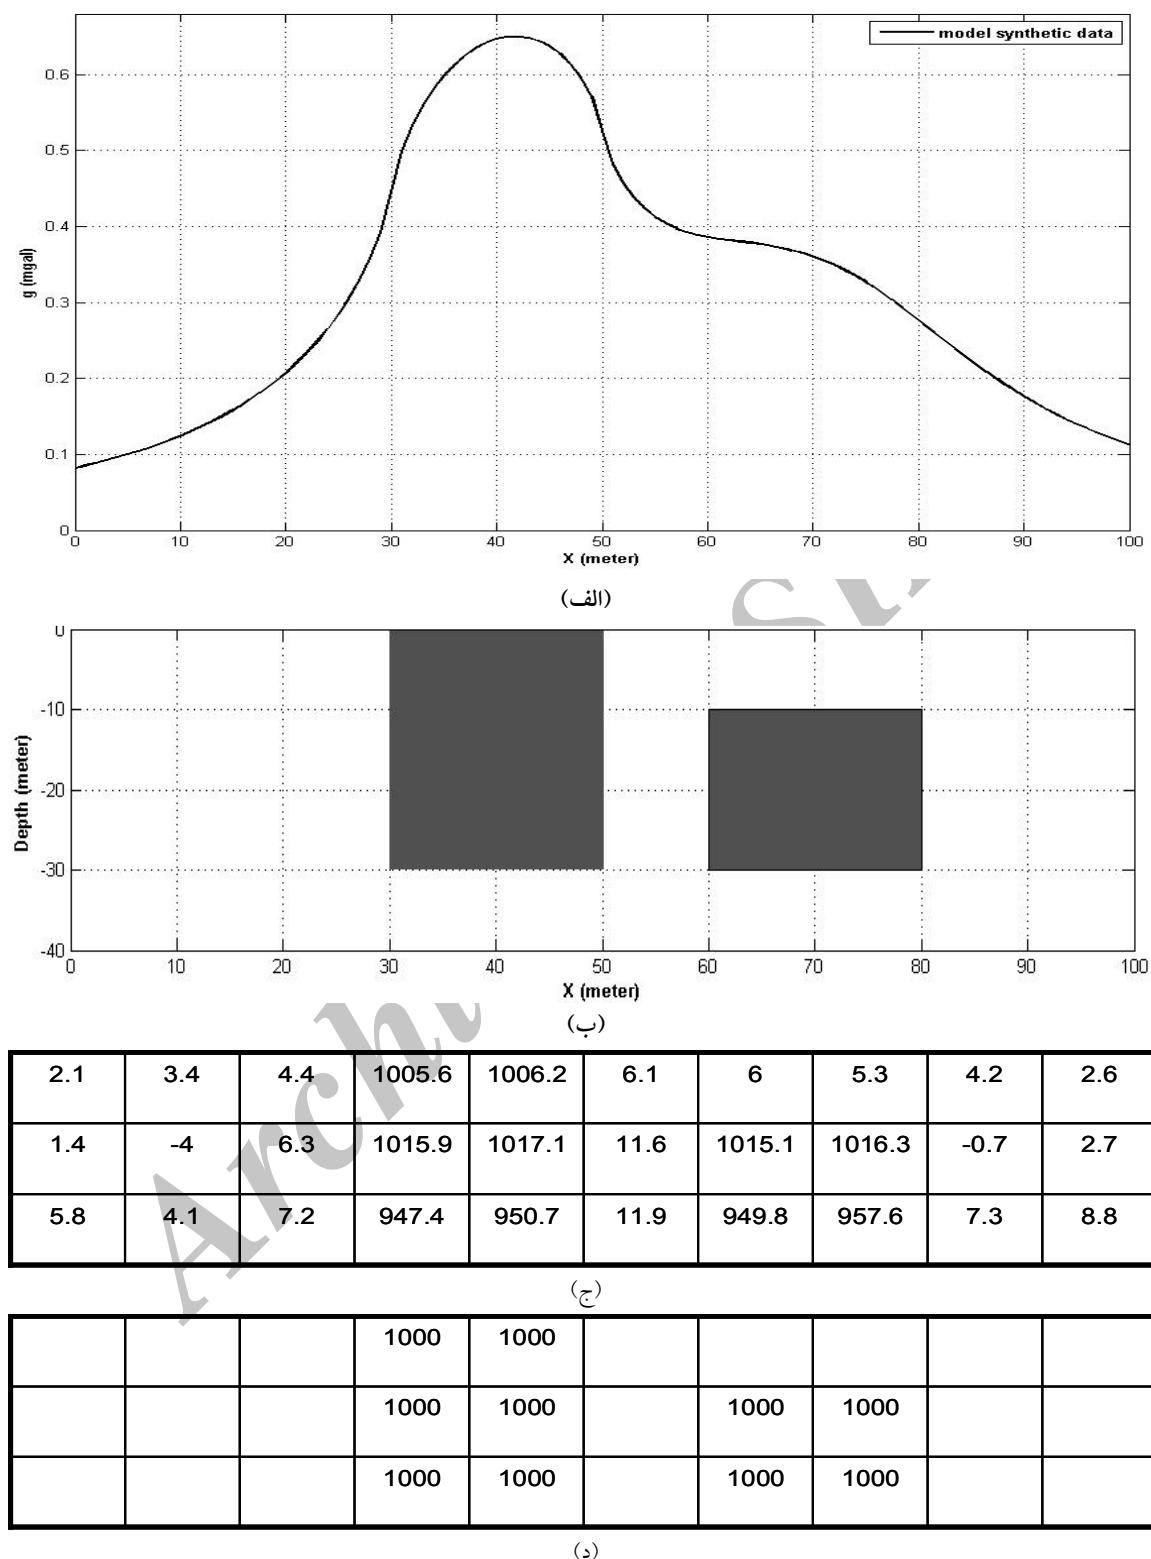
شکل ۵- مدل‌سازی داده‌های مصنوعی، (الف) بی‌هنجاری ناشی از مدل، (ب) مدل در نظر گرفته شده بدون عمق،

(ج) اختلاف چگالی‌ها در تکرار اول، (د) مدل نهایی بعد از ۱۰ تکرار

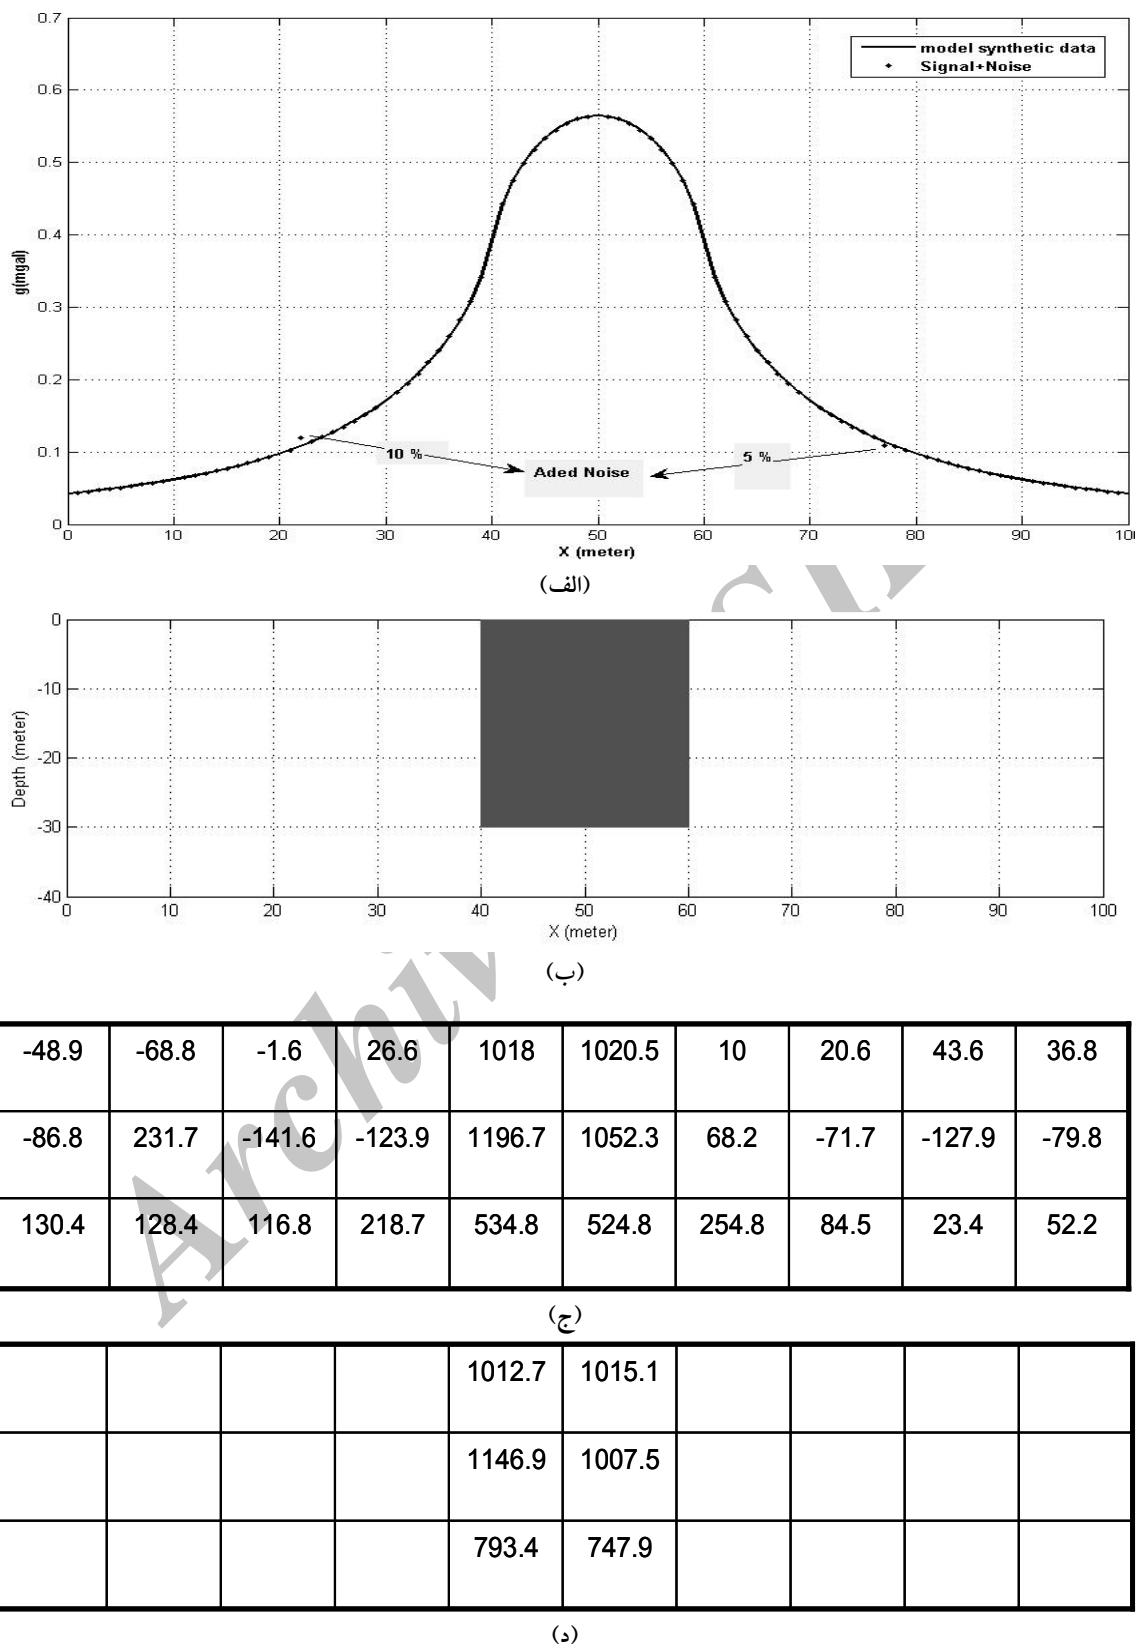


شکل ۶- مدل‌سازی داده‌های مصنوعی، (الف) بی‌هنجری ناشی از مدل، (ب) مدل در نظر گرفته شده با عمق ۱۰ متر، (ج) اختلاف چگالی‌ها در تکرار ۱۰، (د) مدل نهایی بعد از ۱۰ تکرار

مدل‌سازی مستقیم دو بعدی بی‌هنگاری‌های گرانی نهشته‌های کم عمق با استفاده از...

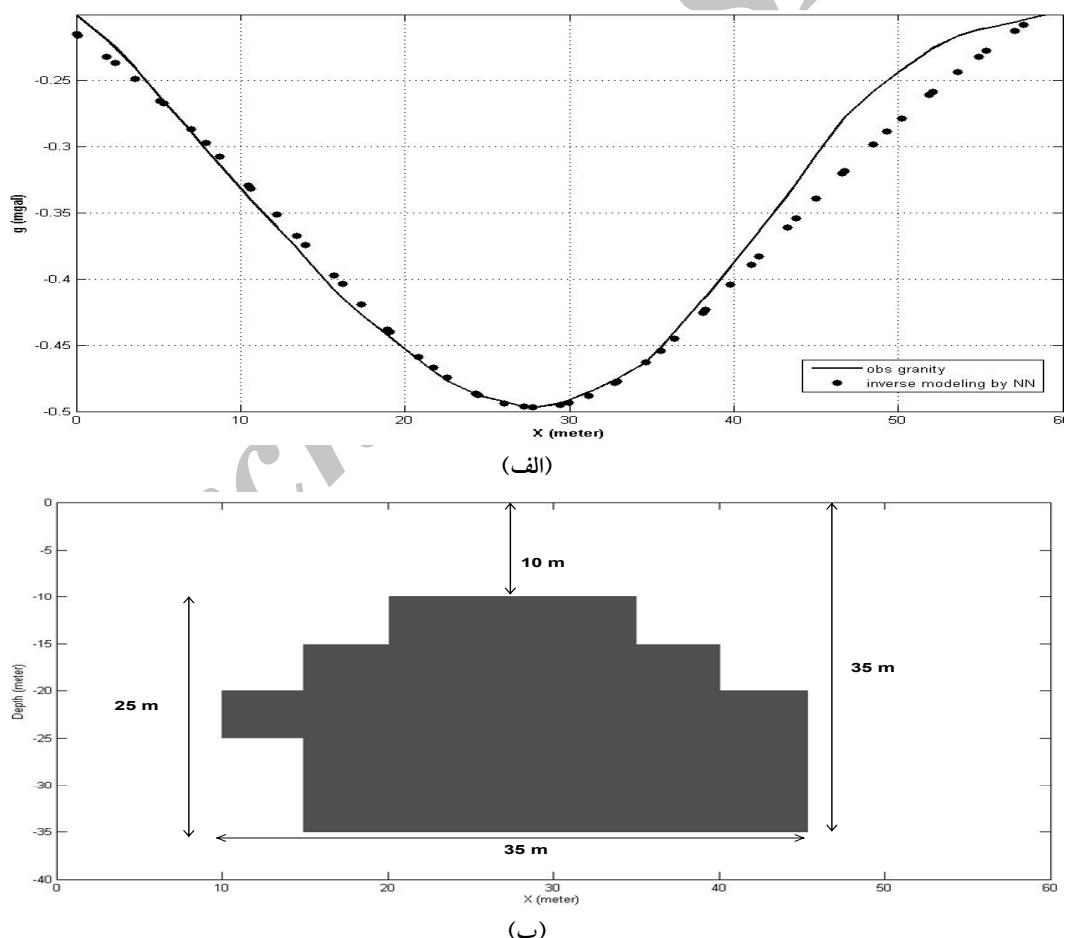
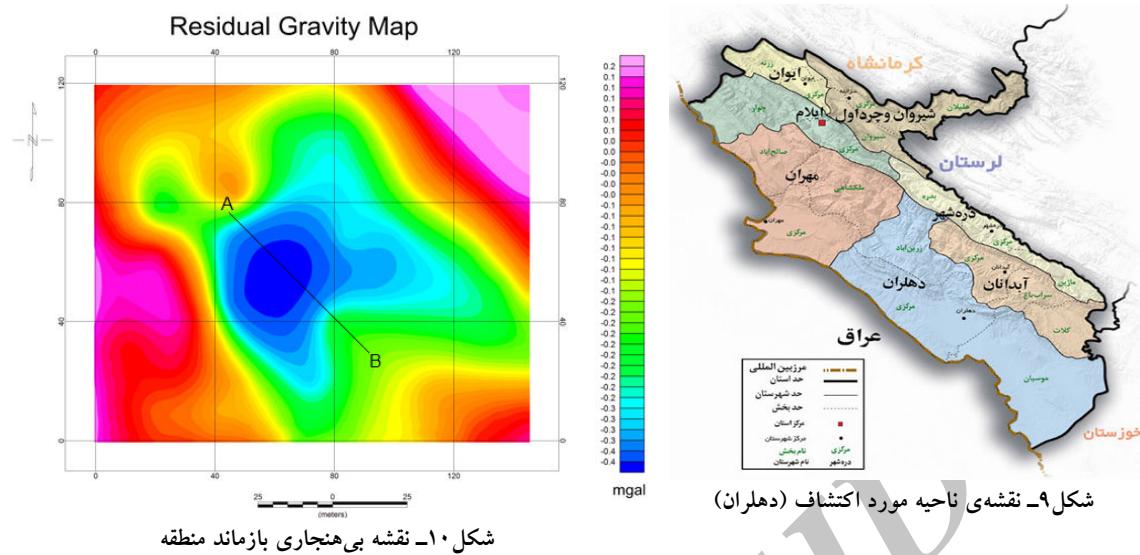


شکل ۷- مدل‌سازی داده‌های مصنوعی، (الف) بی‌هنگاری ناشی از دو مدل مجزا، (ب) مدل‌های در نظر گرفته شده با عمق ۱۰ متر و بدون عمق، (ج) اختلاف چگالی‌ها در تکرار ۶، (د) مدل نهایی بعد از ۶ تکرار



شکل ۸ - مدل‌سازی داده‌های مصنوعی نویزدار، (الف) بی‌هنگاری ناشی از مدل، (ب) مدل در نظر گرفته شده بدون عمق،
 (ج) اختلاف چگالی‌ها در تکرار ۱، (د) مدل نهایی بعد از ۶ تکرار

مدل‌سازی مستقیم دو بعدی بی‌هنجاری‌های گرانی نهشته‌های کم عمق با استفاده از...



شکل ۱۱- مدل‌سازی داده‌های واقعی، (الف) بی‌هنجاری ناشی از مقطع AB و بی‌هنجاری ناشی از مدل‌سازی انجام شده، (ب) مدل نهشته بدست آمده به کمک روش FNN

نتیجه‌گیری

- Albora, A. M., Ucan, O. N., Ozmen, A. and Ozkan, T., (2001a), Evaluation of Sivas-Divrigi Region akdag iron ore deposits using 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.
- Eslam, E., Salem, A., Ushijima, K., (2001), Detection of cavities and tunnels from gravity data using a neural network, *Explor Geophys.*, 32:204-208.
- Haykin, S., (1999), Neural networks, Prentice Hall, New York, 852p.
- Last, B. J. J., and Kubik, K., (1983), Compact gravity inversion, *Geophysics*, Soc. of Expl. Geophys., 48, 713-721.
- Osman, O., Albora, A. M. and Ucan, O. N., (2006), A new approach for residual gravity anomaly profile interpretations: Forced Neural Network (FNN), *Annals of Geophysics*, Vol.49, N.6.
- 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.
- Salem, A., Ravat, D. 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
- Salem, A., Ravat, D., Mushayandebvu, M. F. and Ushijima, K., (2004), Linearized least-squares method for interpretation of potential-field data from sources of simple geometry, *Geophysics*, vol .69, No .3 (MAY-JUNE); P.783-788.

با استفاده از روش شبکه‌های عصبی تحمیلی، می‌توان نهشته‌هایی را که هیچ گونه دیدی از شکل آن نداریم با توجه به مدل‌های منشوری مدل‌سازی کرد. البته لازم به ذکر است که داشتن اطلاعات اولیه از نهشته کانساری، کمک شایانی به مدل‌سازی در انتخاب فیلتر خواهد کرد.

این روش در ابتدا برای چهار مدل مصنوعی تست شده و بعد از آن که نتایج قابل قبولی حاصل شد؛ آن را روی داده‌های واقعی یعنی نهشته‌ی زغال بیتومینه دهلران ایران، پیاده کردیم که نتایج آن همان طور که مشاهده شد، راضی کننده بود.

با استفاده از این روش عمق بالای نهشته ۱۰ متر بدست آمد که با نتایج حاصل از حفاری که حدود عمق را بین ۷-۱۰ متر نشان داده مطابقت دارد. این روش را روی داده‌های بی‌亨جاری‌های مغناطیسی (بخصوص نهشته‌های پرفیری) نیز می‌توان اجرا کرد.

تشکر و قدردانی

در انتهای از موسسه ژئوفیزیک دانشگاه تهران به دلیل در اختیار قرار دادن داده‌ها، کمال تشکر را داریم.

منابع

- کیا، م.، (۱۳۸۷)، شبکه‌های عصبی در "MATLAB" نشر کیان رایانه سیز، (۱۳۸۷).