



مدل سازی وارون دو بعدی میدان گرانی باقی مانده با استفاده از شبکه عصبی پیشخور مدولار : مطالعه موردی یک معدن کرومیت

عطا اسحق زاده^{۱*}، علیرضا حاجیان^۲ و شکوفه خلیلی^۳

- ۱- دانش آموخته کارشناسی ارشد ژئوفیزیک، موسسه ژئوفیزیک دانشگاه تهران
- ۲- استادیار، گروه فیزیک، دانشکده علوم پایه، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، اصفهان، ایران
- ۳- دانش آموخته کارشناسی ارشد ژئوفیزیک، دانشگاه آزاد اسلامی، همدان

دریافت مقاله: ۱۳۹۶/۰۴/۲۷؛ پذیرش مقاله: ۱۳۹۶/۰۹/۰۱

* نویسنده مسئول مکاتبات: shagh@alumni.ut.ac.ir

چکیده

یکی از اهداف اصلی در اکتشافات ژئوفیزیکی، تعیین عمق و گسترش توده معدنی در زیر زمین می‌باشد. بدلیل عدم یکتایی جواب در وارون‌سازی میدان گرانی، روش‌های زیادی برای حذف یا کاهش خطای مدل‌سازی ارائه شده است. تشبیه کردن شکل توده مولد بی‌هنجاری به یکی از شکل‌های هندسی، تا حد زیادی ابهام موجود در مدل‌سازی وارون را کاهش می‌دهد. همانند سازی ساختار توده معدنی مولد بی‌هنجاری گرانی به یک شکل هندسی، نیازمند مطالعات زمین‌شناختی و صحرایی می‌باشد. در این مقاله استفاده از شبکه عصبی مصنوعی پیشخور مدولار برای وارون‌سازی دو بعدی بی‌هنجاری‌های گرانی شکل‌های هندسی کره، استوانه عمودی و استوانه افقی ارائه می‌شود. شبکه عصبی مدولار از چندین شبکه عصبی پیشخور موازی تشکیل می‌شود که به هر شبکه عصبی پیشخور، مدول گفته می‌شود. آموزش هر مدول بصورت مجزا توسط مدل‌های آموزشی صورت می‌پذیرد. یادگیری مدول‌ها با ناظر و با استفاده از الگوریتم پس انتشار خطا صورت می‌پذیرد. سه پارامتر عمق، فاکتور شکل و ضریب دامنه با توجه به مقادیر بردار گرانی، بعنوان لایه ورودی شبکه‌های عصبی پیشخور، توسط هر مدول تخمین زده می‌شود. همچنین یک واحد پردازشی یکپارچه کننده بنام واحد عملگر میانگین، خروجی‌های هر مدول را دریافت کرده و مقدار میانگین هر پارامتر را محاسبه می‌نماید. فاکتور شکل، تعیین کننده شکل تقریبی توده معدنی می‌باشد. با توجه به ضریب دامنه تخمین زده شده، می‌توان شعاع توده مولد بی‌هنجاری گرانی را نیز محاسبه نمود. داده‌های گرانی مدل‌های مصنوعی کره، استوانه افقی و عمودی، با و بدون نوفه تصادفی اضافه شده، با روش ارائه شده در این مقاله مورد بررسی قرار می‌گیرند. نتایج قابل قبول بدست آمده از مدل‌های مصنوعی، کارایی وارون‌سازی شبکه عصبی مدولار را نشان می‌دهند. همچنین در این مقاله، از روش شبکه عصبی مدولار برای مدل‌سازی میدان گرانی باقی‌مانده و نیز میدان گرانی فراسو شده یک معدن کرومیت در سبزوار استفاده شده است.

واژگان کلیدی

بی‌هنجاری گرانی
شبکه عصبی مدولار
عملگر میانگین
کرومیت
مدل‌سازی وارون

شروع کننده اولیه نیاز دارند و اگر این مدل به جواب واقعی نزدیک نباشد، جواب نهایی می تواند اشتباه باشد.

- شبکه های عصبی که بعنوان الگوریتم جستجوی سراسری مورد بررسی قرار می گیرند، نتایج رضایت بخشی را حاصل می نمایند، حتی اگر مدل اولیه آغازین (حدس اولیه) از جواب واقعی بسیار دور باشد.

در این مقاله، از روش وارون سازی شبکه عصبی مدولار (Modular neural network (MNN)) برای محاسبه عمق، فاکتور شکل و ضریب دامنه چشمه مولد بی هنجاری گرانی استفاده می گردد. شبکه عصبی مدولار بر اساس مدل سازی پیشرو آموزش می بیند و با استفاده از میدان گرانی، پارامترهای شکل های هندسی را محاسبه می نماید که در واقع نوعی مدل سازی وارون می باشد. کارایی شبکه عصبی مدولار با استفاده از سه مدل مصنوعی مورد تجزیه و تحلیل قرار می گیرد.

در ادامه داده های گرانی منطقه ای واقع در شهرستان سبزوار که برای اکتشاف کرومیت برداشت شده اند، با شبکه عصبی مدولار مورد تحلیل واقع می شوند. کرومیت ماده اولیه صنایع مهمی همچون فولاد، آلیاژهای غیر آهنی سخت، صنایع نسوز و ریخته گری است. چهار نوع کانسار کرومیت در جهان شناخته شده که دو نوع آن به صورت لایه ای و عدسی های معدنی و دو نوع آن به صورت لاتریت و پلاسر هستند که نسبت به دو نوع اول، اهمیت کمتری دارند (Barker et al., 2006). تقریباً همه کانسارهای کرومیت ایران خاستگاه افیولیتی دارند. از نظر اکتشافی توجه به ژنز کانسار کرومیت و ارتباط آن با سنگ های درون گیر بسیار مهم است، زیرا ارتباط ژنتیکی کروم با سنگ های اولترابازیک یکی از راه های مناسب برای پی جویی این ماده معدنی است. لازم است تمرکز کاوش در مناطق مجاور یا تبدیل سری اولترابازیک به گابرو انجام شود. با توجه به بالا بودن وزن مخصوص کانسنگ کرومیت نسبت به سنگ میزبان، گرانی سنجی، روش ژئوفیزیکی متداول در اکتشاف ذخایر کرومیت است (آقاجانی، ۱۳۹۱).

۲- میدان گرانی شکل های هندسی ساده

در گرانی برخلاف مغناطیس که راستای مغناطیدگی و راستای میدان مغناطیسی زمین میدان اندازه گیری شده را نامتقارن می سازد، میدان های بسیاری از اجسام هندسی ساده پیرامون موقعیت چشمه های مولد متقارن می باشند. مولفه عمودی کلی بی هنجاری گرانی تولید شده بوسیله یک کره (سه بعدی)، یک استوانه افقی طویل نامحدود (دو بعدی) و یک استوانه قائم نیمه نامحدود (سه بعدی) بصورت زیر ارائه داده شده است (شکل ۱) (Abdelrahman et al., 2001).

$$g(x_i, z, q) = \frac{A}{(x_i^2 + z^2)^q} \quad (1)$$

بطوریکه A ضریب دامنه متناسب با شعاع R و تباین چگالی σ چشمه بی هنجاری مدفون می باشد و بترتیب برای کره، استوانه افقی و استوانه

هدف اصلی از تفسیر داده گرانی تخمین عمق و موقعیت چشمه مولد بی-هنجاری می باشد. کاملاً مشخص است که تفسیر داده گرانی برای مناطقی که چشمه های بی هنجاری زیرسطحی متفاوت یک پاسخ یا اثر گرانی را نشان می دهند، غیر یکتا است؛ بنابراین داشتن اطلاعات اولیه از شکل هندسی چشمه مولد ممکن است به جواب هایی یکتا منجر گردد.

(Roy et al., 2000 ; Aboud et al., 2004). از روش های بسیار زیادی برای تفسیر بی هنجاری های گرانی باقی مانده استفاده شده است. از جمله این روش ها می توان به تبدیل فوریه (Sharma and Geldart, 1968)، همامیخت اوپلر (Roy et al., 1999 ; Thompson, 1982)؛ تبدیل هیلبرت ملین (Babu et al., 1991 ; Mohan et al., 1986)، تبدیل هارتلی (Sundararajan et al., 1983a and b)، تبدیل مربعات (Sundararajan and Rama, 1998)، کمینه سازی کمترین مربعات (Salem et al., 2003 ; Gupta, 1983) و تبدیل والش (Al-Garni, 2008) اشاره نمود. در روش های ذکر شده، شکل هندسی چشمه بی-هنجاری فرضی می باشد، بطوریکه دقت نتایج بستگی به این دارد که شکل مدل فرض شده چقدر به ساختار واقعی نزدیک باشد.

همچنین چندین روش جدید برای برآورد فاکتور شکل چشمه مولد بی-هنجاری گرانی پیشنهاد شده است. از جمله این روش ها، روش تبدیل والش (Shaw and Agarwal, 1990)، سیگنال تحلیلی (Nandi et al., 1997) و کمینه سازی کمترین مربعات غیرخطی (Abdelrahman and El-Araby, 1993 ; Abdelrahman et al., 2001) و مشتق قاعده عددی (Aboud et al., 2004) می باشند.


شبکه عصبی دارای چندین مزیت می باشد که آن را نسبت به دیگر روش های وارون سازی برتر می گرداند (Masters, 1993 ; Al-Garni, 2009)؛ یعنی:

- اطلاعات اولیه درباره ورودی - خروجی برای ایجاد مدل مورد نیاز نمی باشد، بطوریکه اندازه گیری های مجهول را می توان از داده های تهیه شده برای آموزش شبکه، استنتاج نمود.
- شبکه های عصبی پاسخ درستی به داده های جدیدی که در ایجاد مدل استفاده نشده باشد، ارائه می دهند.
- شبکه های عصبی می توانند داده ورودی یا خروجی خطی و غیرخطی را مدل سازی نمایند.
- شبکه های عصبی می توانند مدل سازی وارون را بصورت نامحدود و تقریب قابل قبول، بدون صرف زمان زیاد فقط با یکبار آموزش خوب، انجام دهند.
- اگر داده ها از نظر ریاضیات بی نظم باشند بطوریکه این رفتار داده ها در بیشتر روش های دیگر قابل استفاده نباشد، شبکه های عصبی بطور کلی نسبت به این داده های ورودی خوش رفتار هستند.
- شبکه های عصبی دارای گستره وسیعی برای مدل های شروع کننده ورودی می باشند؛ در حالیکه، روش های مرسوم دیگر به یک مدل

قائم داریم:

$$A = \begin{cases} \frac{4}{3} \pi G \sigma R^3 z \\ 2\pi G \sigma R^2 z \\ \pi G \sigma R^2 \end{cases} \quad (2)$$

و مقدار فاکتور شکل q برای استوانه قائم، استوانه افقی و کره برترتیب $1/5$ ، 1 و $1/5$ می باشد.



شکل ۱: الف) مدل کره و استوانه افقی ب) مدل استوانه قائم

همچنین Z عمق و G ثابت جهانی گرانش می باشد. اگر واحد طول متر باشد، واحد ضریب دامنه برترتیب برای کره، استوانه افقی و قائم میلی گال در متر مکعب ($mGal.m^3$)، میلی گال در متر مربع ($mGal.m^2$) و میلی گال در متر ($mGal.m$) می باشد.

۳- شبکه عصبی مصنوعی

شبکه‌های عصبی را می توان بعنوان تخمین زننده عمومی که می توانند هر تابعی را بوسیله متغیرهایش تقریب بزنند، مطرح نمود. بنابراین، آنها می توانند در یافتن حل هایی برای کاربردهای متنوع ژئوفیزیکی مشارکت نمایند (Al-Garni, 2009 ; Poulton, 2001 ; Macias et al., 2000). شبکه‌های عصبی می توانند هرگونه تابع پیوسته را با دقت تعریف شده به نقشه درآورند (Jain and Martin, 1978 ; Jang et al., 1997 ; Yarger et al., 1978). (Al-Garni, 2010 ; 1999).


مدل های شبکه عصبی می توانند نسبت به مدل های رگرسیون چندجمله ای که برای توابع تقریب استفاده می شوند، دقیق تر باشند. اصولاً دو عامل مهم وجود دارد: ابعاد بیشتر نسبت به مدل های جدول جستجو و خروجی های متعدد برای یک مدل تنها (El-Kaliouby and Al-Garni, 2009).

بطور کلی، یک شبکه عصبی بوسیله مجموعه آموزشی از یک گروه نمونه ای تغذیه می شود؛ بطوریکه شبکه آموزش می بیند تا تابع نگاشت که بوسیله الگوهای نمونه تعریف شده است را برآورد نماید. الگوریتم شبکه های عصبی ممکن است به دو گروه اصلی تقسیم شده باشند که شامل یادگیری باناظر (شرکت پذیر) و یادگیری بدون ناظر (خود سازمانده) می باشد. یادگیری باناظر یا سرپرست بر اساس خروجی های

نشریه پژوهش های ژئوفیزیک کاربردی، دوره ۵، شماره ۲، ۱۳۹۸.

مورد انتظار می باشد. در طی آموزش، شبکه عصبی سعی می کند تا خروجی ها را با مقادیر مورد انتظار تطبیق دهد. در یادگیری بدون سرپرست، روش شبکه عصبی هیچگونه مقادیر هدف دریافت نمی کند، بطوریکه خروجی شبکه مجهول می باشد. در طی آموزش، شبکه عصبی چندین نوع از فشرده سازی داده ها مانند کاهش ابعادی یا خوشه بندی را انجام می دهد. بنابراین، شبکه عصبی توزیع الگوها را فرا می گیرد و دسته بندی از آن الگوها را انجام می دهد؛ بطوریکه الگوهای مشابه به چندین دسته خروجی اختصاص داده می شود (Al-Garni, 2009 and 2010 ; Poulton, 2001; El-Kaliouby and Al-Garni, 2009).


یک شبکه عصبی تک لایه شاخص دارای حداقل سه بخش غیرخطی لایه ای می باشد: یک لایه ورودی، یک لایه پنهان و یک لایه خروجی. شکل ۲ شبکه عصبی تک لایه ای را نشان می دهد که ورودی آن داده گرانی و خروجی آن عمق، فاکتور شکل و ضریب دامنه می باشد. با توجه به شکل ۲، هر لایه دارای گره هایی (نورونهایی) است که با دایره هایی نشان داده می شوند و خطوط بین گره ها دلالت بر حرکت اطلاعات از یک گره به دیگری دارد (ورودی تا خروجی). همچنین هر لایه یک واحد پردازش مجزا می باشد که روی داده ها عمل می کند تا یک نتیجه حاصل گردد. هر گره یک ورودی اضافه دارد که ورودی حدآستانه نامیده می شود که بعنوان یک سطح مرجع یا بایاس (bias) برای گره عمل می کند (Al-Garni, 2009 and 2010 ; El-Kaliouby and Al-Garni, 2009).



شکل ۲: ساختار یک شبکه عصبی تک لایه که از سه لایه ورودی، پنهان و خروجی تشکیل شده است.

بنابراین، داده ها از طریق لایه ورودی وارد شبکه می شوند، جایی که هر گره، یک مقدار داده تنهای وزندار شده را به سمت لایه پنهان سوق می دهد، سپس داده ها مورد پردازش قرار گرفته و نتایج به سمت لایه خروجی انتشار می یابند. گره های خروجی مجموعه های متفاوتی از وزن ها را شامل می شوند و مقادیر ورودی را جهت تولید نتایج پردازش می نمایند. فرایند ذکر شده برای این نوع از معماری، شبکه عصبی پرسپترون چندلایه پیشرو نامیده می شود (شکل ۲).

انجام دهد، به انتها برساند (Azam, 2000). به عبارت دیگر، شبکه می تواند به چندین مدول تجزیه شود بطوریکه این مدول ها با یکدیگر ارتباطی ندارند (شکل ۳ - ب).




شکل ۳: ساختار شبکه عصبی (الف) پیشخور، (ب) مدولار

آیودا و کامل (۱۹۹۹) هشت ساختار مختلف از شبکه عصبی مدولار را معرفی کرده اند. خروجی های مدول ها به یک واحد یکپارچه کننده واسط منتقل می شوند بطوریکه این واحد اجازه نمی دهد تا اطلاعات به مدول ها بازگردند (شکل ۴). در حقیقت، واحد یکپارچه کننده تصمیم می گیرد تا خروجی های مدول ها چگونه باید با هم ترکیب شوند تا خروجی نهایی سیستم شکل بگیرد.

در واقع می توان گفت که یک شبکه عصبی مدولار به یک واحد یکپارچه کننده نیاز دارد که شکل های مختلف ارتباط یا ترکیب پاسخ های مدول ها را باعث شود. در پایین تعدادی از روش ها که وظیفه ذکر شده را انجام می دهند، آورده شده است (Melin and Castillo, 2005):

- عملگر میانگین
- شبکه دروازه ای
- انتگرال های فازی
- مکانیزم رای گیری با استفاده از تابع Softmax
- و ...



ورودی بوسیله گره های لایه های پنهان در وزن خودش ضرب شده و با مقدار بایاس جمع می شود. سپس از طریق تابع انتقال غیرخطی به لایه خروجی منتقل می گردد. تابع انتقال استفاده شده در این مقاله، تابع انتقال حلقوی (sigmoid) می باشد (شکل ۳):

$$f(x) = (1 + e^{-x})^{-1} \quad (3)$$

آموزش شبکه عصبی مرحله بسیار مهم برای توسعه مدل می باشد، بطوریکه شبکه عصبی رفتار مسئله را فرا می گیرد. شبکه عصبی بوسیله نمونه های اندازه گیری شده یا بازسازی شده از یک مجموعه آموزشی از مدول ها، آموزش می بیند. عملکرد شبکه عصبی بوسیله اختلاف بین خروجی های شبکه عصبی و خروجی های مورد انتظار مورد ارزیابی قرار می گیرد.

فرایند آموزش، اصولا پارامترهای وزن (w) در شبکه عصبی را که خطای بین حدس های مدل شبکه عصبی و خروجی مورد انتظار [E(w)] را کمینه می نماید را تعدیل می کند. E(w) تابع غیرخطی از w می باشد. روش تکرار جهت بدست آوردن اندازه وزن استفاده می شود بطوریکه یک حدس اولیه در شروع آموزش باید انجام گیرد و سپس با تکرار W بصورت زیر تغییر می کند (Al-Garni, 2013):

$$w_{new} = w_{old} + \delta n \quad (4)$$

بطوری که w_{old} و w_{new} بترتیب بردارهای وزن جدید و موجود می باشند. n راستای بهنگام سازی و δ یک مقدار مثبت است که اندازه w را می تواند در آن راستا، تنظیم نماید (Zhang and Gupta, 2000 ; El-Kaliouby and Al-Garni, 2009).

در فرایند آموزش، خطا بایستی طی تکرار مکرر، کاهش یابد، بنابراین در بعضی موارد مقدار خطا بالا و ثابت باقی می ماند و نشانه این امر است که آموزش در یک کمینه محلی گیر کرده است. بنابراین می تواند w را تغییر داد و سپس با یک حدس اولیه جدید، روند آموزش آغاز گردد (Al-Garni, 2010 ; El-Kaliouby and Al-Garni, 2009).

۴- شبکه عصبی مدولار

در این مقاله، وارون سازی شبکه عصبی که برای آموزش استفاده شده است بر اساس ساختار شبکه عصبی مدولار می باشد. این نوع از شبکه عصبی در حیطه های مختلف ژئوفیزیکی بطور موفقیت آمیزی استفاده شده است

(El-Kaliouby, 2001 ; El-Kaliouby and Poulton, 1999) ; Al-Garni, 2009 ; Bhatt and Helle, 2002 ; Zhang et al., 2002 and 2010) . یک شبکه عصبی مدولار بوسیله مجموعه ای از شبکه های عصبی پیشخور مستقل مشخص می شود (شکل ۳ - الف). هر شبکه عصبی مستقل بعنوان یک مدول (کارشناس محلی Local expert) انجام وظیفه می کند. هر مدول روی ورودی مجزا عمل می نماید تا تعدادی از وظایف فرعی یا تمامی وظایف (تعدادی یا تمامی خروجی های مورد نظر) که شبکه عصبی می خواهد

به‌طور مشابه خروجی شبکه را می‌توان به صورت زیر بیان کرد (Macias et al., 2000):

$$O_k^q = f^o \left(\sum_{i=1}^L W_{kj}^o a_j^q + c_k \right) \quad (6)$$

در این رابطه O_k^q ، k امین خروجی شبکه به ازای q امین ورودی در این رابطه O_k^q ، k ، W_{kj}^o ، j امین وزن نرون k ، c_k بایاس، L تعداد نرون ها در لایه مخفی و f^o تابع تحریک لایه خروجی است. خطای اختلاف خروجی شبکه و خروجی مطلوب به‌صورت زیر تعریف می‌شود (Macias et al., 2000):

$$E = \frac{1}{2} \sum_{q=1}^Q \sum_{k=1}^M (y_k^q - o_k^q)^2 \quad (7)$$

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

$$w_{kj}^o(l+1) = w_{kj}^o(l) + \eta \sum_{q=1}^Q \delta o_k^q a_j^q \quad (8)$$

$$w_{kj}^h(l+1) = w_{kj}^h(l) + \eta \sum_{q=1}^Q \delta h_k^q a_j^q \quad (9)$$

در این روابط \square نرخ آموزش است. هر چه این مقدار کوچکتر باشد، تغییرات اوزان شبکه در هر تکرار کوچکتر خواهد بود. از طرف دیگر، اگر سعی شود با افزایش \square ، سرعت آموزش زیاد شود، تغییرات بزرگی در وزن‌های اتصال بوجود می‌آید که ممکن است شبکه را ناپایدار کند. مناسب‌ترین حالت این است که ضریب آموزش در ابتدا بزرگ انتخاب شود و در حین آموزش شبکه، به آرامی مقدار آن کاهش یابد. جهت توقف تکرار الگوریتم از دو شاخص زیر به‌طور همزمان استفاده می‌شود؛ الف- میانگین خطا در هر سیکل کمتر از مقدار از پیش تعیین شده باشد. ب- نرم گرادیان خطا خیلی کوچک باشد. ج- تعداد تکرار مشخص شده به اتمام برسد.

۶- آموزش شبکه عصبی مدولار

در این مقاله سه شکل هندسی کروی، استوانه عمودی و افقی مورد بررسی قرار می‌گیرند. بر همین اساس برای آموزش شبکه عصبی نیاز داریم تا میدان گرانی دو بعدی این شکل‌های هندسی را برای مقادیر مختلف از ضریب دامنه A ، فاکتور شکل q و عمق Z محاسبه نماییم. برای هر مقدار مشخص از این پارامترها، یک بردار گرانی حاصل می‌شود. بنابراین ما چندین بردار گرانی با توجه به تعداد مقادیری که برای هر پارامتر ضریب دامنه A ، فاکتور شکل q و عمق Z در نظر می‌گیریم،

شکل ۴: ساختار شبکه عصبی پیشخور مدولار. به هر شبکه پیشخور، یک مدول گفته می‌شود. خروجی مدول‌ها وارد واحد یکپارچه‌کننده می‌شوند.

در این مقاله، واحد یکپارچه‌کننده، عملگر میانگین می‌باشد. مدول‌ها بوسیله داده‌های آموزشی یکسانی، بصورت مستقل آموزش می‌بینند. از آنجائی‌که در طی فرایند آموزش، ۶۰ درصد از داده‌های آموزشی بصورت تصادفی جهت یادگیری شبکه عصبی انتخاب می‌شوند، خروجی یا خروجی‌های مدول‌ها نسبت به یک بردار ورودی (که در این مقاله میدان گرانی می‌باشد) متفاوت می‌باشند. واحد عملگر میانگین قبل از میانگین‌گیری، خروجی‌ها را بررسی می‌کند تا اگر پارامتر محاسبه شده‌ای خارج از گستره در نظر گرفته شده برای آن پارامتر باشد، در محاسبات وارد نشود.

۵- الگوریتم آموزش شبکه

با توجه به توضیحات ارائه شده در بخش‌های قبلی، می‌توانیم شبکه عصبی مدولار را به‌عنوان یک شبکه عصبی که از چندین شبکه عصبی پیشخور موازی تشکیل شده است، در نظر بگیریم. بنابراین، از الگوریتم پس انتشار (Back Propagation) خطا برای آموزش شبکه‌های عصبی پیشخور استفاده می‌شود. رایج‌ترین تکنیک آموزش نظارتی، الگوریتم پس انتشار خطا است. یادگیری این الگوریتم بر پایه قانون تصحیح خطا بنا شده است که می‌توان آن را تعمیم الگوریتم مرسوم به کمترین میانگین مربعات دانست. یادگیری با این روش (پس انتشار) دو مرحله دارد: مرحله پیشروی و مرحله بازگشت. در مرحله پیشروی، ورودی‌ها به‌صورت لایه به لایه در شبکه پیش می‌روند و در پایان یک سری خروجی به عنوان جواب حقیقی شبکه به دست می‌آید، در این مرحله توزان اتصال ثابت است. در مرحله بازگشت، اوزان اتصال بر اساس قانون تصحیح خطا، تغییر می‌کند. تفاضل پاسخ حقیقی شبکه و پاسخ مورد انتظار که خطا نامیده می‌شود در سوی مخالف اتصالات در شبکه منتشر می‌شود و اوزان به گونه‌ای تغییر می‌یابند که پاسخ حقیقی شبکه به پاسخ مطلوب نزدیک‌تر شود.

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 دولایه ای را آموزش دهیم. وقتی X^q (q امین بردار ورودی) به یکی از نرون‌های لایه مخفی می‌رسد، پاسخ نرون به صورت زیر خواهد بود (Macias et al., 2000):

$$a_j^q = f^h \left(\sum_{i=1}^N W_{ji}^h x_i^q + b_j \right) \quad (5)$$

در این رابطه a_j^q پاسخ j امین نرون در لایه مخفی به q امین بردار ورودی (بالانویس h معرف لایه مخفی)، W_{ji}^h وزن نرون j ام، b_j بایاس و f^h تابع تحریک است.


اسحق زاده و همکاران، مدل سازی وارون دو بعدی میدان گرانی باقی مانده با استفاده از شبکه عصبی پیشخور مدولار، صفحات ۲۳۵-۲۵۱.

آموزش از آنها استفاده نشده است به کار گرفته شوند، سیستم عملگری بسیار بدی خواهد داشت و خطای پیش بینی زیاد خواهد بود (Gallagher, 1999). در طی آموزش، مجموعه داده‌های اولیه به سه دسته آموزش، آزمون و اعتبار تقسیم بندی می‌شوند. اعتبار شبکه همزمان با آموزش در هر دور سنجیده می‌شود و درست وقتی که خطای روی داده‌های اعتبار شروع به بالا رفتن می‌کند، آموزش شبکه قطع می‌شود تا شبکه بیش از حد آموزش نبیند. برنامه کامپیوتری از ۶۰ درصد داده‌ها که دارای ورودی و خروجی مشخص می‌باشد برای آموزش شبکه و از ۲۰ درصد داده‌ها برای اعتبارسنجی شبکه در حین آموزش استفاده می‌نماید. ۲۰ درصد از داده‌ها برای آزمایش شبکه عصبی مورد استفاده قرار می‌گیرد. در این مرحله مقادیر ورودی که برای شبکه عصبی نامشخص هستند به شبکه داده می‌شود تا خروجی شبکه با جواب واقعی مقایسه شود و درصد خطا تعیین گردد. آزمون شبکه مستقل از آموزش می‌باشد. با تکرار مقدار این خطا کاهش می‌یابد. در واقع آزمایش شبکه کنترل کارایی و دقت مدل شبکه عصبی می‌باشد. هدف نهایی از آموزش شبکه تعیین وزن‌ها و بایاس می‌باشد.

همانطور که ذکر شد، در این مقاله از سه مدول استفاده شده است. بنابراین ما سه شبکه عصبی پیشخور داریم. هر سه این شبکه‌ها با مدل‌های ذکر شده در بالا آموزش داده شدند. تابع آموزشی، تابع لونیبرگ-مارکوارت و نوع بهینه‌سازی و اجرای برنامه بر اساس خطای میانگین مربعات می‌باشد. روال آموزش در صورتی که خطای مجموعه ارزیابی در ۶ تکرار متوالی افزایش یابد، متوقف می‌شود (کیا، ۱۳۹۳). الگوریتم کلی روال آموزش در شکل ۶ نشان داده شده است.

بهترین کارایی برای این سه شبکه عصبی بترتیب در تکرار ۶۵، ۵۵۸ و ۶۲ رخ داده است.

بنابراین ما سه شبکه عصبی یا مدول آموزش دیده در اختیار داریم که با توجه به بردارهای ورودی و خروجی، بهترین مقادیر وزن و بایاس را محاسبه کرده‌اند.




شکل ۶: الگوریتم کلی روال آموزش شبکه عصبی

بدست می‌آوریم که به عنوان بردارهای ورودی برای آموزش شبکه عصبی استفاده می‌شوند. بنابراین جهت مطالعه کارایی شبکه عصبی مدولار، نیاز است تا در مرحله نخست داده‌های گرانی در قالب بردارهای ورودی جهت آموزش، به شبکه عصبی معرفی گردند. جهت تولید داده‌ی آموزشی، گستره در نظر گرفته شده برای پارامترهای ضریب دامنه A ، فاکتور شکل q و عمق Z بصورت زیر می‌باشد:

- شش مقدار برای ضریب دامنه بین ۱۰۰ تا ۲۰۰ واحد
- شش مقدار برای عمق بین ۱۰ تا ۲۰ واحد
- پانزده مقدار برای فاکتور شکل بین ۱/۳ تا ۱/۸

بنابراین برای ۵۴۰ حالت که از ترکیب مقادیر مختلف پارامترها حاصل می‌شود، داده گرانی در طول یک پروفیل ۲۰۰ واحدی با فاصله بین نقاط محاسبه‌ای چهار واحد برآورد گردید. پس ما ۵۴۰ بردار (مدل آموزشی) که هر بردار شامل ۵۱ مقدار گرانی می‌باشد در اختیار داریم بطوریکه برای هر بردار گرانی، یک بردار سه عضوی (بردار هدف) شامل ضریب دامنه، فاکتور شکل و عمق متناظر با آن بردارگرانی نیز وجود دارد. بنابراین ما یک ماتریس داده گرانی ۵۴۰×۵۱ و یک ماتریس ۵۴۰×۳ از پارامترهای مدل در اختیار داریم. از این دو ماتریس جهت آموزش هر کدام از شبکه‌های عصبی پیشخور استفاده می‌شود. ما تعداد ۲۰ نرون برای لایه پنهان در نظر گرفته‌ایم. تعداد نرون در لایه پنهان بر اساس سعی و خطا و نیز مقدار زمانی که جهت آموزش شبکه عصبی نیاز است، تعیین می‌شود. بنابراین شبکه عصبی ما دارای ۵۱ نرون در لایه ورودی، ۲۰ نرون در لایه مخفی و ۳ نرون در لایه خروجی (سه پارامتر ضریب دامنه، فاکتور شکل و عمق) می‌باشد (شکل ۵).



شکل ۵: ساختار شبکه عصبی استفاده شده برای مدل مصنوعی

قابل ذکر است که تمامی کدنویسی‌های لازم در محیط متلب صورت گرفته و از جعبه ابزار شبکه عصبی متلب جهت آموزش استفاده شده است. برای اینکه شبکه عصبی هیچ ترتیب خاصی را حفظ نکند، با استفاده از دستور rand که مقداری بین صفر و یک تولید می‌کند، ترتیب منظم بین مقادیر مختلف پارامترهای ضریب دامنه A ، فاکتور شکل q و عمق Z ، واقع در گستره ذکر شده در بالا را از بین می‌بریم تا داده‌های گرانی تصادفی تولید شوند که دارای یک نظم خاص نباشند.

توجه به این نکته اهمیت دارد که اگر تعداد نرون‌ها و لایه پنهان مورد استفاده، بیش از حد معمول باشد، سیستم به جای تجزیه و تحلیل داده‌ها، آنها را حفظ می‌کند و اصطلاحاً دچار بیش برآزشی (Over Fitting) می‌شود. در این حالت مدل به دست آمده قادر خواهد بود که داده‌های مشابهی که در مرحله یادگیری مورد استفاده قرار گرفته است را به طور دقیق پیش بینی کند؛ اما اگر داده‌های جدیدی که در مرحله

۷- بررسی مدل مصنوعی

جهت بررسی کارایی شبکه عصبی مدولار، سه مدل مصنوعی کروی، استوانه عمودی و افقی در نظر گرفته‌ایم. متغیرهای فرض شده برای این سه مدل بصورت زیر می‌باشد:

- عمق ۱۵ واحد
- فاکتور شکل بترتیب برای کره، استوانه عمودی و افقی ۱/۵، ۱ و ۰/۵
- ضریب دامنه ۱۵۰ واحد

باید دقت شود که پارامترهای مدل مصنوعی فرض شده حتما در گستره پارامترهای اولیه که جهت تولید مدل آموزشی برای آموزش شبکه عصبی در نظر گرفته شده است، قرار داشته باشد. ما میدان گرانی مربوط به این سه مدل مصنوعی را محاسبه کرده و به‌عنوان ورودی به شبکه عصبی معرفی نموده‌ایم. خروجی مدول‌ها و میانگین محاسبه شده برای این سه مدل مصنوعی استوانه عمودی، استوانه قائم و کره بترتیب در جدول‌های ۱ الی ۳ آورده شده است.

از خطای استاندارد بعنوان یک معیار آماری جهت مقایسه میدان گرانی اندازه گیری شده و میدان گرانی محاسبه شده بر اساس پارامترهای تخمین زده شده، استفاده می‌شود.

خطای استاندارد از رابطه زیر محاسبه می‌گردد (Tlas and Asfahani 2008):

$$\mu = \sqrt{\frac{\sum_{i=1}^N [g(x_i) - g_c(x_i)]^2}{N}} \quad (10)$$

بطوریکه $g(x_i)$ مقادیر گرانی مشاهده‌ای و $g_c(x_i)$ مقادیر گرانی محاسبه‌ای می‌باشد. درصد خطای پارامترهای محاسبه شده نیز در جدول‌های ذکر شده، آورده شده است. هرچه مقدار خطای محاسبه شده کمتر باشد، موکد پارامترهای فاکتور شکل، ضریب دامنه و عمق بهینه برای بی‌هنجاری گرانی خواهد بود که بر اساس آنها میدان گرانی محاسبه‌ای برآورد شده است. مقدار خطای استاندارد بین مقادیر میدان گرانی مدل‌های مصنوعی و مقادیر میدان گرانی که از پارامترهای بهینه محاسبه شده توسط شبکه عصبی مدولار حاصل شده است (شکل‌های ۷ الی ۹) در جدول ۴ آورده شده است. بعد از محاسبه میانگین پارامترهای عمق، ضریب دامنه و فاکتور شکل توسط عملگر میانگین، مقدار خطای پارامترها محاسبه شده و نیز مقدار میانگین برآورد می‌گردد و پارامتری که دارای کمترین مقدار خطا باشد، به‌عنوان مقدار بهینه و خروجی اصلی شبکه عصبی در نظر گرفته می‌شود. برای نمونه، در جدول ۲ مقدار خطای عمق بدست آمده در مدول ۳ حتی از مقدار میانگین کمتر می‌باشد.

جدول ۱: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

میدان گرانی مدل استوانه عمودی

پارامتر (واحد)	مدول ۱	مدول ۲	مدول ۳	میانگین
عمق اولیه	۱۵	۱۵	۱۵	۱۵
عمق محاسبه شده	۱۵/۲۹	۱۵/۴۳	۱۴/۴۶	۱۵/۰۶
درصد خطای عمق	۱/۹	۲/۹	۳/۶	۰/۴
فاکتور شکل اولیه	۰/۵	۰/۵	۰/۵	۰/۵
فاکتور شکل محاسبه شده	۰/۴۸۹	۰/۵۲	۰/۴۶۴	۰/۴۹۱
درصد خطای فاکتور شکل	۲/۲	۴	۷/۲	۱/۸
ضریب دامنه اولیه	۱۵۰	۱۵۰	۱۵۰	۱۵۰
ضریب دامنه محاسبه شده	۱۴۶/۹	۱۴۷/۴۹	۱۵۵/۶۵	۱۵۰/۰۱
درصد خطای ضریب دامنه	۲/۱	۱/۷	۳/۸	۰/۰۰۷

جدول ۲: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

میدان گرانی مدل استوانه افقی

پارامتر (واحد)	مدول ۱	مدول ۲	مدول ۳	میانگین
عمق اولیه	۱۵	۱۵	۱۵	۱۵
عمق محاسبه شده	۱۵/۲۷	۱۵/۶۸	۱۴/۸۷	۱۵/۲۷
درصد خطای عمق	۱/۸	۴/۵۳	۰/۸۷	۱/۸
فاکتور شکل اولیه	۱	۱	۱	۱
فاکتور شکل محاسبه شده	۰/۹۶۴	۱/۰۱	۱/۰۴	۱/۰۰۵
درصد خطای فاکتور شکل	۳/۶	۱	۴	۰/۵
ضریب دامنه اولیه	۱۵۰	۱۵۰	۱۵۰	۱۵۰
ضریب دامنه محاسبه شده	۱۵۲/۹۶	۱۴۷/۱	۱۵۳	۱۵۱/۰۲
درصد خطای ضریب دامنه	۱/۹۷	۱/۹۳	۲	۰/۶۸

جدول ۳: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

میدان گرانی مدل کروی

پارامتر (واحد)	مدول ۱	مدول ۲	مدول ۳	میانگین
عمق اولیه	۱۵	۱۵	۱۵	۱۵
عمق محاسبه شده	۱۵/۴۷	۱۴/۷۴	۱۶/۱۱	۱۵/۴۴
درصد خطای عمق	۳/۱۳	۴/۹	۷/۴	۲/۹۳
فاکتور شکل اولیه	۱/۵	۱/۵	۱/۵	۱/۵
فاکتور شکل محاسبه شده	۱/۵	۱/۵۳	۱/۳۸	۱/۴۷
درصد خطای فاکتور شکل	۰	۱/۵	۸	۲
ضریب دامنه اولیه	۱۵۰	۱۵۰	۱۵۰	۱۵۰
ضریب دامنه محاسبه شده	۱۵۶/۱۷	۱۴۵/۲	۱۵۲/۹	۱۵۱/۴۲
درصد خطای ضریب دامنه	۴/۱	۳/۲	۱/۹۳	۰/۹۵

جدول ۴: خطای استاندارد محاسبه شده بین میدان گرانی مدل های مصنوعی و میدان گرانی حاصل از پارامترهای تخمین زده شده توسط شبکه عصبی مدولار

مدل مصنوعی	کروی	استوانه افقی	استوانه عمودی
خطای استاندارد (واحد)	۰/۰۰۰۸	۰/۰۰۰۳	۰/۲۶۳

۸- بررسی تاثیر نوفه

به داده های گرانی حاصل از مدل های مصنوعی تعریف شده در بخش قبلی مقدار ۵٪ نوفه تصادفی بر اساس رابطه ۱۱ اضافه گردید و بردارهای گرانی نوفه دار بعنوان ورودی به شبکه عصبی مدولار معرفی گردید.

$$g_n = g + \left[\frac{(\max(g) - \min(g))}{2} \times (\text{randn}(\text{size}(g)) \times 0.05) \right] \quad (11)$$

که در آن g_n داده گرانی نوفه دار می باشد. نتایج حاصل از وارون سازی شبکه عصبی برای سه مدل استوانه عمودی، استوانه افقی و کره در جدول های ۵ الی ۷ آورده داده شده است. شکل های ۱۰ الی ۱۲ بترتیب تغییرات میدان گرانی مدل های مصنوعی استوانه عمودی، استوانه افقی و کره که ۵٪ نوفه تصادفی به آنها اضافه و تغییرات میدان گرانی که از پارامترهای محاسبه شده توسط شبکه عصبی مدولار با توجه به داده های گرانی نوفه دار حاصل شده است را در طول پروفیل نشان می دهند.

جدول ۵: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای


میدان گرانی مدل استوانه عمودی با ۵٪ نوفه اضافه شده

پارامتر (واحد)	مدول ۱	مدول ۲	مدول ۳	میانگین
عمق اولیه	۱۵	۱۵	۱۵	
عمق محاسبه شده	۱۵/۶۵	۱۴/۶۴	۱۵/۲۵	۱۵/۱۸
درصد خطای عمق	۴/۳	۲/۴	۱/۶۷	۱/۲
فاکتور شکل اولیه	۰/۵	۰/۵	۰/۵	
فاکتور شکل محاسبه شده	۰/۴۷۶	۰/۵۸	۰/۵۸۷	۰/۵۴۸
درصد خطای فاکتور شکل	۴/۸	۱۶	۱۷/۴	۹/۶
ضریب دامنه اولیه	۱۵۰	۱۵۰	۱۵۰	
ضریب دامنه محاسبه شده	۱۴۵/۵۴	۱۶۳/۸	۱۵۶/۴۷	۱۵۵/۲۷
درصد خطای ضریب دامنه	۲/۹۷	۹/۲	۴/۳۱	۳/۵۱


جدول ۶: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

میدان گرانی مدل استوانه افقی با ۵٪ نوفه اضافه شده


پارامتر (واحد)	مدول ۱	مدول ۲	مدول ۳	میانگین
عمق اولیه	۱۵	۱۵	۱۵	
عمق محاسبه شده	۱۴/۸	۱۴/۸۴	۱۵/۱	۱۴/۹۱
درصد خطای عمق	۱/۳	۱/۰۷	۰/۷	۰/۶
فاکتور شکل اولیه	۱	۱	۱	
فاکتور شکل محاسبه شده	۱/۰۱۵	۱/۱۹	۱/۰۹	۱/۰۹۸
درصد خطای فاکتور شکل	۱/۵	۱۹	۹	۹/۸
ضریب دامنه اولیه	۱۵۰	۱۵۰	۱۵۰	
ضریب دامنه محاسبه شده	۱۳۸/۶۴	۱۶۳/۴۵	۱۵۸/۴۹	۱۵۲/۵
درصد خطای ضریب دامنه	۷/۶	۸/۹۷	۵/۶۶	۲/۳




شکل ۷: میدان گرانی مدل استوانه عمودی و میدان گرانی حاصل از پارامترهای مدل محاسبه شده توسط شبکه عصبی مدولار



شکل ۸: میدان گرانی مدل استوانه افقی و میدان گرانی حاصل از پارامترهای مدل محاسبه شده توسط شبکه عصبی مدولار



شکل ۹: میدان گرانی مدل کروی و میدان گرانی حاصل از پارامترهای مدل محاسبه شده توسط شبکه عصبی مدولار



شکل ۱۲: تغییرات میدان گرانی در طول پروفیل برای مدل مصنوعی کروی با ۵٪ نوفه تصادفی اضافه شده و میدان گرانی که از پارامترهای محاسبه شده توسط شبکه عصبی مدولار حاصل شده است

مقدار خطای استاندارد برآورد شده بین مقادیر میدان گرانی مدل‌های مصنوعی با ۵٪ نوفه اضافه شده و مقادیر میدان گرانی که از پارامترهای بهینه محاسبه شده توسط شبکه عصبی مدولار حاصل شده است (شکل‌های ۱۰ الی ۱۲)، در جدول ۸ آورده شده است.

جدول ۸: خطای استاندارد محاسبه شده بین میدان گرانی مدل‌های مصنوعی با ۵٪ نوفه اضافه شده و میدان گرانی حاصل از پارامترهای تخمین زده شده توسط شبکه عصبی مدولار


مدل مصنوعی	کروی	استوانه افقی	استوانه عمودی
خطای استاندارد (واحد)	۰/۰۰۱۵	۰/۰۱۷۲	۰/۰۶۸

۹- موقعیت و زمین‌شناسی منطقه تحت مطالعه


منطقه مورد اکتشاف در بخش ۴۰ شمالی مختصات UTM بین طول‌های ۶۰۶۸۴۰ متر تا ۶۰۶۹۶۵ متر شرقی و عرض‌های ۴۰۱۲۲۱۰ متر و ۴۰۱۲۳۹۰ متر شمالی بین شهرستان‌های سبزوار و نیشابور واقع شده است. منطقه تحت مطالعه در زون سبزوار از زون ساختاری بزرگ ایران مرکزی، قرار دارد. در نگاهی وسیع‌تر این ناحیه بین دو گسل بزرگ و زیربنایی درونه (در جنوب) و گسل بینالود (در شمال) واقع شده است. زون سبزوار از شمال با زون بینالود و از جنوب با زون بلوک لوت در ارتباط است، این ارتباط‌ها تکتونیکی و گسله هستند. منطقه سبزوار در حقیقت جزئی از منطقه آفیولیتی است که از خاور تا جنوب کشور امتداد دارد. شکل ساختاری منطقه مورد مطالعه بدون شک تحت تأثیر گسل‌هایی مانند درونه و تکنار قرار گرفته است. روند ساختمانی این ناحیه از روند گسل درونه تبعیت می‌کند. گسل درونه خود یک گسل امتداد لغز (چپ گرد) می‌باشد. منطقه سبزوار محتوی تعداد زیادی

جدول ۷: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

پارامتر (واحد)	مدول ۱	مدول ۲	مدول ۳	میانگین
عمق اولیه	۱۵	۱۵	۱۵	
عمق محاسبه شده	۱۵/۵۳	۱۵/۹۹	۱۴/۵۴	۱۵/۳۵
درصد خطای عمق	۳/۵۳	۶/۶	۳/۱	۲/۳۳
فاکتور شکل اولیه	۱/۵	۱/۵	۱/۵	
فاکتور شکل محاسبه شده	۱/۵۵	۱/۳۹	۱/۴۷	۱/۴۷
درصد خطای فاکتور شکل	۳/۳	۷/۳	۲	۲
ضریب دامنه اولیه	۱۵۰	۱۵۰	۱۵۰	
ضریب دامنه محاسبه شده	۱۴۲/۷۳	۱۵۲/۹۴	۱۴۶/۵۸	۱۴۷/۷۵
درصد خطای ضریب دامنه	۴/۸۵	۲/۶۳	۲/۲۸	۱/۵




شکل ۱۰: تغییرات میدان گرانی در طول پروفیل برای مدل مصنوعی استوانه عمودی با ۵٪ نوفه تصادفی اضافه شده و میدان گرانی که از پارامترهای محاسبه شده توسط شبکه عصبی مدولار حاصل شده است



شکل ۱۱: تغییرات میدان گرانی در طول پروفیل برای مدل مصنوعی استوانه افقی با ۵٪ نوفه تصادفی اضافه شده و میدان گرانی که از پارامترهای محاسبه شده توسط شبکه عصبی مدولار حاصل شده است

اسحق زاده و همکاران، مدل سازی وارون دو بعدی میدان گرانی باقی مانده با استفاده از شبکه عصبی پیشخور مدولار، صفحات ۲۳۵-۲۵۱.

با حروف A, B و C مشخص شده‌اند. این بی‌هنجاری‌ها به احتمال زیاد دارای چشمه مولدی هستند که سنگ میزبان کرومیت را تشکیل می‌دهند.



شکل ۱۴: نقشه بی‌هنجاری گرانی باقی‌مانده منطقه مورد مطالعه. سه بی-هنجاری مثبت A, B و C مشخص شده است

۱۱- مدل سازی میدان گرانی باقی‌مانده با استفاده از

شبکه عصبی مدولار

برای مدل‌سازی چشمه بی‌هنجاری‌های موجود، نیاز است تا در راستای پروفیل‌های داده‌برداری گرانی صورت بپذیرد. همچنین لازم است تا دقت شود که تغییرات میدان گرانی در طول پروفیل بایستی تا حد امکان یک منحنی هموار را تشکیل بدهد تا با منحنی تغییرات میدان گرانی شکل‌های هندسی که جهت آموزش شبکه عصبی بکارگرفته می‌شوند، متشابه باشند. در این صورت شبکه عصبی آموزش داده شده با دقت بهتری می‌تواند داده‌گرانی واقعی را تحلیل کرده و تخمین‌هایی با دقت بیشتر ارائه دهد.

داده‌برداری گرانی در راستای دو پروفیل L1 و L2 مطابق شکل ۱۵ که از روی دو بی‌هنجاری A و B آشکار شده در نقشه بی‌هنجاری گرانی باقی‌مانده، عبور کرده‌اند، صورت پذیرفت. طول پروفیل‌های L1 و L2 بترتیب ۶۰ متر و ۹۶ متر می‌باشد داده‌برداری با فاصله دو متر انجام شده است. بنابراین ۳۱ داده گرانی در طول پروفیل L1 و ۴۹ داده گرانی در طول پروفیل L2 در اختیار داریم.


برای تخمین عمق، ضریب دامنه و فاکتور شکل، نیاز است تا شبکه عصبی مدولار با سه مدول موازی تعریف نماییم. در مرحله نخست، همانطور که قبلاً ذکر شد، جهت آموزش شبکه عصبی نیاز است تا مدل‌های مصنوعی تعریف شوند و آموزش با استفاده از میدان‌های گرانی مربوط به این مدل‌ها صورت بپذیرد.

توده‌های کرومیت به شکل رشته‌ها و عدسی‌های بزرگ و کوچک می‌باشد. توده‌های آذرین این ناحیه در جهت تقریباً شرقی- غربی کشیده می‌شود و در وهله اول از سنگهای بسیار قلیایی تشکیل می‌گردد. توده‌های کرومیت به صورت نامنظم ولیکن با تمرکز معین در این سنگها پخش شده است. مقدار ذخیره آنها که غالباً بکلی استخراج شده است بسیار متغیر بوده است. باروز و همکاران (۱۹۸۳) سن مجموعه‌های افیولیتی را به کرتاسه فوقانی (کنیاسین) نسبت می‌دهند.

در محدوده مورد مطالعه، برونزدهای سنگی محدود، در برگرنده سنگ‌های آذرین از جنس اولترابازیک است که بیشتر به سرپانتین و کانی‌هایی مانند تالک و ورمیکولیت تبدیل شده است (آقاجانی، ۱۳۹۱).

۱۰- میدان گرانی منطقه تحت مطالعه

شکل ۱۳ میدان گرانی بوگه بخشی از منطقه تحت مطالعه گرانی‌سنجی در سبزواری را نشان می‌دهد که قصد داریم تا با روش شبکه عصبی مدولار مورد تحلیل قرار دهیم.



شکل ۱۳: نقشه میدان گرانی بوگه منطقه مورد مطالعه

نیاز است تا با استفاده از روش روند سطحی، میدان منطقه‌ای را از میدان گرانی بوگه منطقه حذف نماییم تا بی‌هنجاری گرانی باقی‌مانده یا محلی بدست آید. تقریباً تمامی تحلیل‌های کیفی و کمی بر روی میدان گرانی باقی‌مانده صورت می‌پذیرد. شکل ۱۴ میدان گرانی باقی‌مانده بر اساس روند سطحی درجه یک را نشان می‌دهد. بدلیل تباین چگالی بالای سنگ میزبان کرومیت نسبت به محیط اطراف، انتظار داریم تا مناطق مستعد وجود کرومیت بر روی نقشه بی‌هنجاری گرانی باقی‌مانده با مقدار بالای گرانی برجسته گردند. همانطور که در نقشه بی‌هنجاری گرانی باقی‌مانده شکل ۱۴ دیده می‌شود، سه منطقه با مقدار میدان گرانی مثبت بیشینه

جدول ۱۰: محدوده و تعداد نقاط انتخابی برای پارامترهای عمق، ضریب

دامنه و فاکتور شکل برای مدل استوانه عمودی		
تعداد نقاط انتخابی	محدوده انتخابی	پارامتر
۱۴	۳۵ - ۵	عمق (m)
۱۶	۵۰ - ۵	ضریب دامنه (mGal.m ³)
۸	۰/۹ - ۰/۱	فاکتور شکل

با توجه به جدول‌های ۹ و ۱۰، ۲۴۰۰ مدل کروی و ۱۷۹۲ مدل استوانه عمودی برای آموزش شبکه عصبی در اختیار داریم. ساختار شبکه‌های عصبی پیشخور (مدول) مورد استفاده برای هر دو مدل کره و استوانه دارای ۲۰ نرون در لایه پنهان و سه نرون مطابق با سه پارامتر عمق، ضریب دامنه و فاکتور شکل در لایه خروجی دارد. از آنجائیکه ۳۱ داده گرانی در طول پروفیل L1 و ۴۹ داده گرانی در طول پروفیل L2 در اختیار داریم، برای تحلیل داده‌های گرانی پروفیل L1 از ۳۱ نرون در لایه ورودی و برای تحلیل داده‌های گرانی پروفیل L2 از ۴۹ نرون در لایه ورودی شبکه عصبی استفاده می‌شود.

سه مدول شبکه عصبی مدولار یکبار با ۴۹ نرون در لایه ورودی (مطابق با تعداد داده‌های گرانی پروفیل L2) و یکبار با ۳۱ نرون در لایه ورودی (مطابق با تعداد داده‌های گرانی پروفیل L1) با مدل‌های کروی و استوانه عمودی آموزش داده شده‌اند. بنابراین چهار شبکه عصبی مدولار آموزش دیده در اختیار داریم.


۱۱-۱- پروفیل L1

مقادیر گرانی پروفیل L1 یکبار با شبکه عصبی مدولار آموزش دیده شده با مدل کروی و یکبار با شبکه عصبی مدولار آموزش دیده شده با مدل استوانه عمودی مورد تحلیل واقع گردید.

میانگین مقادیر پارامترهای عمق، ضریب دامنه و فاکتور شکل تخمین زده شده توسط شبکه عصبی مدولار برای داده‌های گرانی پروفیل L1 در جدول ۱۱ آورده شده است.

جدول ۱۱: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

داده‌های گرانی پروفیل L1			
مدل	عمق (m)	فاکتور شکل	ضریب دامنه (mGal.m ³)
کروی	۲۸/۴	۱/۲۷	۲۷۸۷
استوانه عمودی	۱۷/۶	۰/۵۴	۱۳/۱



شکل ۱۵: موقعیت و راستای دو پروفیل L1 و L2 روی نقشه بی‌هنجاری گرانی باقی‌مانده

برای داده‌های واقعی گرانی، گستره پارامترهای عمق، ضریب دامنه و فاکتور شکل بایستی بر اساس مقادیر میدان گرانی واقعی، شکل بی-هنجاری‌ها و نیز اطلاعات زمین‌شناسی منطقه انتخاب شوند. البته با توجه به خروجی شبکه عصبی نیز می‌توان به درست بودن یا نبودن گستره انتخابی برای یک پارامتر پی برد (Al-Garni, 2013). اگر خروجی شبکه عصبی خارج از گستره انتخابی باشد، می‌توان با تغییر آن گستره شبکه عصبی را دوباره آموزش داد. همچنین اگر برای دو یا چند شکل هندسی، خروجی شبکه عصبی در محدوده انتخابی پارامترها واقع شده بود، با محاسبه خطای استاندارد بین میدان گرانی واقعی و میدان‌های گرانی حاصل از آن پارامترها، می‌توان شکل هندسی که به چشمه بی‌هنجاری نزدیک‌تر است را، با توجه به خطای استاندارد کمتر، حدس زد (Al-Garni, 2013).

از روی شکل نقشه بی‌هنجاری باقی‌مانده می‌توان حدس زد که توده‌های مولد بی‌هنجاری‌های A و B نمی‌توانند به شکل استوانه افقی باشند. بر همین اساس ما دو شبکه عصبی برای مدل کروی و استوانه عمودی آموزش می‌دهیم که محدوده انتخابی برای پارامترهای عمق، ضریب دامنه و فاکتور شکل آنها برترتیب در جدول‌های ۹ و ۱۰ آورده شده است. اگر تعداد نقاط انتخابی زیاد باشد، بالطبع تعداد مدل‌های آموزشی افزایش یافته و در نتیجه زمان زیادی برای آموزش شبکه عصبی صرف خواهد شد. نقاط با دستور rand در متلب بصورت تصادفی انتخاب شده‌اند.

جدول ۹: محدوده و تعداد نقاط انتخابی برای پارامترهای عمق، ضریب

دامنه و فاکتور شکل برای مدل کروی		
تعداد نقاط انتخابی	محدوده انتخابی	پارامتر
۱۲	۳۵ - ۱۰	عمق (m)
۲۰	۳۵۰۰ - ۱۰۰۰	ضریب دامنه (mGal.m ³)
۱۰	۲ - ۰/۹	فاکتور شکل

اسحق زاده و همکاران، مدل سازی وارون دو بعدی میدان گرانی باقی مانده با استفاده از شبکه عصبی پیشخور مدولار، صفحات ۲۳۵-۲۵۱.


جدول ۱۳ آورده شده است.

جدول ۱۳: پارامترهای تخمین زده شده توسط شبکه عصبی مدولار برای

داده های گرانی پروفیل L2

مدل	عمق (m)	فاکتور شکل	ضریب دامنه (mGal.m ³)
کروی	۱۲/۳۷	۱/۶۱	۲۳۵۳
استوانه عمودی	۸/۲۵	۰/۵۴	۷/۳

شکل ۱۷ میدان گرانی پروفیل L2 و میدان های گرانی محاسبه شده برای مدل های کروی و استوانه عمودی بر اساس پارامترهای تخمین زده شده را نشان می دهد. در جدول ۱۴ مقدار خطای استاندارد و شعاع محاسبه شده، آورده شده است. همانطور که مشاهده می شود، خطای استاندارد مدل استوانه عمودی از خطای استاندارد مدل کروی کوچکتر می باشد.



شکل ۱۷: میدان گرانی پروفیل L2 و میدان های گرانی محاسبه شده برای مدل های کروی و استوانه عمودی بر اساس پارامترهای تخمین زده شده

جدول ۱۴: شعاع و خطای استاندارد محاسبه شده


مدل	خطای استاندارد	شعاع (m)
کروی	۰/۲۱۹۵	۱۶/۵۴
استوانه عمودی	۰/۱۰۶۳	۱۵/۲

۱۲- مدل سازی میدان گرانی فراسوی شده ۱۲ متر با

استفاده از شبکه عصبی مدولار

در نقشه میدان گرانی ادامه فراسوی ۱۲ متر نشان داده شده در شکل ۱۸، طول موج های کوتاه مربوط به بی هنجاری های سطحی و کوچک تضعیف و طول موج های بزرگ مربوط به بی هنجاری های عمیق تر و بزرگتر تقویت شده است. در نقشه شکل ۱۸ یک بی هنجاری مثبت مربوط به توده کرومیت مشاهده می شود. داده برداری گرانی در طول پروفیل L3

شکل ۱۶ میدان گرانی پروفیل L1 و میدان های گرانی محاسبه شده برای مدل های کروی و استوانه عمودی بر اساس پارامترهای تخمین زده شده را نشان می دهد. میدان گرانی هر مدلی که دارای خطای استاندارد کمتری باشد، چشمه مولد بی هنجاری را از نظر هندسی به آن شکل تشبیه می نمایم. مقدار خطای استاندارد محاسبه شده در جدول ۱۲ آورده شده است. همانطور که مشاهده می شود، خطای استاندارد مدل کروی از خطای استاندارد مدل استوانه عمودی کوچکتر می باشد.



شکل ۱۶: میدان گرانی پروفیل L1 و میدان های گرانی محاسبه شده برای مدل های کروی و استوانه عمودی بر اساس پارامترهای تخمین زده شده

چگالی میانگین کرومیت در حدود ۴/۴ گرم بر سانتیمتر مکعب می باشد. چگالی متوسط محیط اطراف توده های درازای کرومیت در منطقه مورد مطالعه که بیشتر شامل دونیت و سرپانتین می باشد، ۲/۹ گرم بر سانتیمتر مکعب است. بنابراین تباین چگالی در حدود ۱/۵ گرم بر سانتیمتر مکعب یا ۱۵۰۰ کیلوگرم بر متر مکعب است. با توجه به رابطه ضریب دامنه مدل می توانیم شعاع حدودی چشمه بی هنجاری را تخمین بزنیم. برای مدل کروی عمق مرکز کره ۲۸/۴ متر می باشد که با کم کردن شعاع از آن، عمق سطح بالا کره (توده بی هنجاری) ۱۵/۱ متر بدست می آید. شعاع های محاسبه شده برای هر دو مدل در جدول ۱۲ آورده شده است.

جدول ۱۲: شعاع و خطای استاندارد محاسبه شده

مدل	خطای استاندارد	شعاع (m)
کروی	۰/۱۰۴۴	۱۳/۳
استوانه عمودی	۰/۱۳۶۹	۲۰/۴

۱۱-۲- پروفیل L2

مشابه پروفیل L1، مقادیر گرانی پروفیل L2 یکبار با شبکه عصبی مدولار آموزش دیده شده با مدل کروی و یکبار با شبکه عصبی مدولار آموزش دیده شده با مدل استوانه عمودی مورد تحلیل واقع گردید. میانگین مقادیر پارامترهای عمق، ضریب دامنه و فاکتور شکل تخمین زده شده توسط شبکه عصبی مدولار برای داده های گرانی پروفیل L2 در

عمق (m)	۱۵ - ۳۵	۱۲
ضریب دامنه (mGal.m ³)	۱۰ - ۵۰	۱۵
فاکتور شکل	۰/۱ - ۰/۹	۸

به طول ۹۰ متر با فاصله دو متر انجام شده است.

برای مدل‌سازی وارون میدان گرانی پروفیل L3، دو شبکه عصبی برای مدل‌های کروی و استوانه افقی آموزش داده شد. محدوده‌های فرض شده برای پارامترهای عمق، فاکتور شکل و ضریب دامنه جهت تولید مدل‌های آموزشی بترتیب برای مدل‌های کروی و استوانه عمودی در جدول‌های ۱۵ و ۱۶ نشان داده شده است و بنابراین با توجه به جدول‌های، ۲۲۴۰ مدل کروی و ۱۴۴۰ مدل استوانه عمودی برای آموزش شبکه عصبی مدولار در اختیار داریم.


نتایج حاصل شده از مدل‌سازی با شبکه عصبی برای داده‌های گرانی پروفیل L3 در جدول ۱۷ آورده شده است.

شکل ۱۹ میدان گرانی پروفیل L3 و میدان‌های گرانی محاسبه شده برای مدل‌های کروی و استوانه عمودی بر اساس پارامترهای تخمین زده شده، را نشان می‌دهد.

جدول ۱۷: پارامترهای تخمین زده شده از مدل‌سازی شبکه عصبی

مدولار برای پروفیل L3

مدل	عمق (m)	فاکتور شکل	ضریب دامنه (mGal.m ³)	خطای استاندارد	شعاع (m)
کروی	۳۲/۵	۱/۲۹	۲۲۸۴	۰/۰۲۴۱	۱۱/۸۷
استوانه عمودی	۲۴/۶	۰/۶۵	۱۸/۶	۰/۰۴۰۲	۲۴/۳



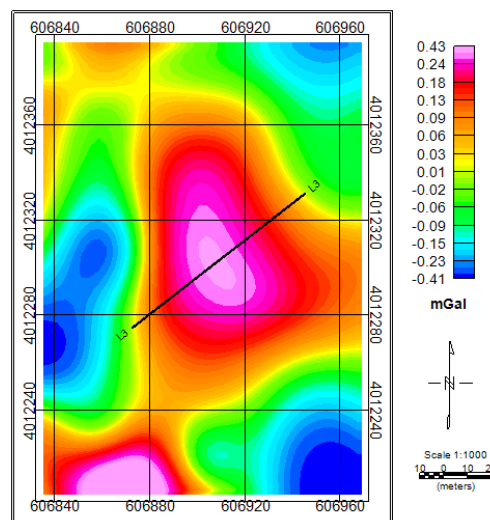
شکل ۱۹: میدان گرانی پروفیل L3 و میدان‌های گرانی محاسبه شده برای مدل‌های کروی و استوانه عمودی بر اساس پارامترهای تخمین زده شده

با توجه به مقادیر خطای استاندارد محاسبه شده که در جدول ۱۷ نشان داده شده است، توده مولد بی‌هنجاری را می‌توان از نظر هندسی به کره تشبیه نمود. همچنین، از آنجایی که میدان گرانی ۱۲ متر به سمت بالا گسترش داده شده است، بنابراین بایستی مقدار عددی ۱۲ را از عمق محاسبه شده ۳۲/۵ متر برای کره کم نماییم. پس عمق مرکز کره (توده کرومیت) ۲۰/۵ از سطح زمین می‌باشد. از طرفی، شعاع کره ۱۱/۸۷ متر برآورد شده است؛ در نتیجه عمق سطح بالای توده ۸/۶۳ متر می‌باشد.

۱۳- تخمین عمق اویلر

روش واهمامیخت اویلر، یک روش مرسوم و متداول تخمین عمق چشمه بی‌هنجاری پتانسیل می‌باشد که بطور گسترده در سراسر جهان برای پروژه‌های اکتشافی مورد استفاده قرار می‌گیرد.

در این مقاله از روش اویلر استفاده شده است تا عمق‌های بدست آمده از دو روش (ویلر بعنوان روش مبنا و شبکه عصبی مدولار) باهم مقایسه گردند. تخمین عمق توده‌های کرومیت با روش اویلر در نرم افزار ژئوسافت صورت پذیرفت. تخمین‌های عمقی بدست آمده در روی نقشه گرانی باقی‌مانده نشان داده شده است (شکل ۲۰). با توجه به نتایج بدست آمده از روش شبکه عصبی مدولار، شکل هندسی توده‌های کرومیت را می‌توان



شکل ۱۸: نقشه میدان گرانی ادامه فراسوی ۱۲ متر همراه با موقعیت و راستای پروفیل L3

جدول ۱۵: محدوده و تعداد نقاط انتخابی برای پارامترهای عمق، ضریب دامنه و فاکتور شکل برای مدل کروی

پارامتر	محدوده انتخابی	تعداد نقاط انتخابی
عمق (m)	۱۵ - ۴۰	۱۴
ضریب دامنه (mGal.m ³)	۱۰۰۰ - ۸۰۰۰	۲۰
فاکتور شکل	۰/۹ - ۱/۸	۸

جدول ۱۶: محدوده و تعداد نقاط انتخابی برای پارامترهای عمق، ضریب دامنه و فاکتور شکل برای مدل استوانه عمودی

پارامتر	محدوده انتخابی	تعداد نقاط انتخابی
---------	----------------	--------------------

اسحق زاده و همکاران، مدل سازی وارون دو بعدی میدان گرانی باقی مانده با استفاده از شبکه عصبی پیشخور مدولار، صفحات ۲۳۵-۲۵۱.

از روش شبکه عصبی پیشخور مدولار برای تخمین پارامترهای مدل و تعیین شکل هندسی توده‌های مولد بی‌هنجاری گرانی مربوط به یک منطقه مطالعاتی در اطراف سبزوار که هدف از مطالعات گرانی‌سنجی اکتشاف توده‌های کرومیتی است، استفاده گردید.

در وارون‌سازی با شبکه عصبی مدولار، میدان گرانی حاصل از پارامترهای تخمین زده شده که دارای کمترین خطای استاندارد با میدان گرانی واقعی باشد، شکل چشمه بی‌هنجاری، از نظر هندسی، به آن مدل نسبت داده می‌شود. بر همین اساس شکل چشمه بی‌هنجاری A و چشمه مولد میدان گرانی مثبت در نقشه فراسو شده ۱۲ متر، به کره و شکل چشمه بی‌هنجاری B به استوانه عمودی قابل تشبیه می‌باشد. همچنین مقادیر فاکتورهای شکل تخمین زده شده برای هر سه پروفیل L1، L2 و L3 بترتیب برابر ۰/۱۲۷، ۰/۵۴ و ۱/۲۹ به مقدار فاکتور شکل بهینه مربوط به همان مدل، نزدیک می‌باشند.

عمق‌های بالای محاسبه شده برای بی‌هنجاریهای A، B و میدان گسترش یافته به بالا، بترتیب بر اساس میدان گرانی پروفیل‌های L1، L2 و L3 و با توجه به شکل هندسی استخراج شده از مدل‌سازی داده‌های گرانی، ۱۵/۱ متر، ۸/۲۵ متر و ۸/۶۳ متر می‌باشد. روش اویلر، عمق بی‌هنجاری A را در حدود ۱۵ متر، بی‌هنجاری B بین ۵ تا ۱۰ متر و بی‌هنجاری C در حدود ۱۰ متر تخمین زده است. در نتیجه تخمین‌های عمقی با هر دو روش اویلر و شبکه عصبی مدولار کاملاً همخوانی دارند.

بر اساس تحلیل‌های کمی و کیفی (نقشه ادامه فراسو)، بی‌هنجاری‌های کوچک A، B و C بصورت شاخه‌ای بالای توده بزرگتر و عمیق‌تر واقع شده‌اند و تمرکز توده بزرگتر و عمیق‌تر کرومیت به سمت مرکز و جنوب (بی‌هنجاری‌های B و C) می‌باشد. با توجه به مدل‌سازی میدان گرانی در راستای پروفیل L3 با شبکه عصبی مدولار، عمق مرکز کره (توده کرومیت) ۲۰/۵ از سطح زمین می‌باشد. از طرفی، شعاع کره ۱۱/۸۷ متر برآورد شده است؛ در نتیجه عمق بیشینه (عمق سطح پایین) توده در حدود ۳۲/۳۷ متر تخمین زده می‌شود.


۱۵- منابع

آقاجانی، ح؛ ۱۳۹۱. انجام پیمایش و مطالعات ثقل‌سنجی در محدوده کرومیت شرق سبزوار. طرح پژوهشی، دانشکده مهندسی معدن، نفت و ژئوفیزیک، دانشگاه صنعتی شاهرود.
کیا، م؛ ۱۳۹۳. محاسبات نرم در Matlab. تهران. انتشارات دانشگاهی کیان.
منهاج، م؛ ۱۳۷۹. مبانی شبکه‌های عصبی (هوش محاسباتی). دانشگاه صنعتی امیرکبیر، مرکز نشر پرفسور حسابی.

Abdelrahman, E.M. and El-Araby, H.M., 1993, Shape and depth solutions from gravity data using correlation factors between successive least-squares residuals. Geophysics, 58, 1785-1791.

بین شکل‌های کره و استوانه عمودی فرض نمود. بر همین اساس شاخص ساختاری را ۱/۵ (شاخص ساختاری کره ۲ و استوانه عمودی ۱ است) در نظر گرفتیم. همچنین طول پنجره متحرک ۵×۵ در نظر گرفته شده است.

با توجه به محدوده تخمین‌های عمقی شکل ۲۰، عمق بی‌هنجاری A در حدود ۱۵ متر، بی‌هنجاری B بین ۵ تا ۱۰ متر و بی‌هنجاری C در حدود ۱۰ متر با استفاده از روش اویلر تخمین زده شده است.



شکل ۲۰: تخمین‌های عمقی بدست آمده از روش اویلر در روی نقشه گرانی باقی مانده

۱۴- بحث و نتیجه‌گیری

در این مقاله، روش شبکه عصبی مدولار برای تخمین پارامترهای عمق، فاکتور شکل و ضریب دامنه شکل‌های هندسی کروی، استوانه افقی و عمودی مورد استفاده قرار گرفته است. شبکه عصبی مدولار خود از چندین شبکه عصبی پیشخور موازی تشکیل شده است. وارون‌سازی توسط شبکه عصبی مدولار برای مدل‌های مصنوعی کروی، استوانه افقی و عمودی، پاسخ‌های بسیار قابل قبولی ارائه داده است و پارامترهای تخمین زده شده برای میدان گرانی مدل فرض شده، دارای دقت بسیار بالایی می‌باشند. با افزودن نوفه تصادفی به داده‌های گرانی نیز، شبکه عصبی عملکرد خوبی نشان می‌دهد که کارایی روش و الگوریتم نوشته شده را اثبات می‌نماید. در تحلیل داده‌های گرانی با شبکه عصبی مدولار، باید دقت شود که مقادیر عددی از نظر واقعی قابل توجیه و تفسیر باشند. صرف اینکه بر اساس مقدار فاکتور شکل، شکل هندسی توده تفسیر گردد، ممکن است که اشتباه باشد. برای نمونه در تحلیل پروفیل L2، مقدار عمق کره ۱۲/۳۷ متر و شعاع آن ۱۶/۵۴ برآورد شده است. اگرچه مقدار عمق تخمین زده شده در گستره مورد نظر اولیه، که بر اساس میدان گرانی واقعی تعیین شده است، قرار دارد، اما مدل کروی، بزرگترین شعاعی که می‌تواند داشته باشد، برابر عمق می‌باشد.

- El-Kaliouby, H.M., 2001, Poulton MM (ed) Extracting IP parameters from TEM data computational. neural networks for geophysical data processing, chapter 17. Pergamon, Oxford.
- El-Kaliouby, H.M. and Al-Garni, M.A., 2009, Inversion of self-potential anomalies caused by 2D inclined sheets using neural networks. *J. Geophys. Eng.*, 6, 29–34.
- El-Kaliouby, H.M. and Poulton, M.M., 1999, Inversion of coincident loop TEM data for layered polarizable ground using neural networks. Society of Exploration Geophysicists (SEG) 69th annual meeting, Houston, Texas, USA.
- Gupta, O.P., 1983, A least-squares approach to depth determination from gravity data. *Geophysics*, 48, 537–360.
- Jain, L.C. and Martin N.M., 1999, Fusion of neural networks, fuzzy sets and genetic algorithms: industrial applications. CRC, Boca Raton.
- Jang, J.S.R., Sun, C.T. and Mizutani E., 1997, Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. Prentice-Hall, New York.
- Macias C., Sen, M. and Stoffa P., 2000, Artificial neural networks for parameter estimation in geophysics. *Geophys. Prospect.*, 48, 21–47.
- Masters, T., 1993, Practical neural network recipes in C++. Academic, CA, USA.
- Melin, P. and Castillo, O., 2005, Hybrid Intelligent Systems for Pattern Recognition. Springer, Heidelberg.
- Mohan, N.L., Anandababu, L. and Roa S., 1986, Gravity interpretation using Mellin transform. *Geophysics*, 52, 114–122.
- Nandi, B.K., Shaw, R.K. and Agarwal, N.P., 1997, A short note on identification of the shape of simple causative sources from gravity data. *Geophys. Prospect.*, 45, 513–520.
- Poulton, M.M., 2001, Computational neural networks for geophysical data processing. Pergamon, Oxford, UK.
- Roy, L., Agarwal, N.P. and Shaw, R.K., 1999, Estimation of shape factor and depth from gravity anomalies due to some simple sources. *Geophys. Prospect.*, 47, 41–58.
- Roy, L., Agarwal, N.P. and Shaw R.K., 2000, A new concept in Euler deconvolution of isolated gravity anomalies. *Geophys. Prospect.*, 48, 559–575.
- Salem, A., Elawadi, E. and Ushijima, K., 2003, Short note: depth determination from residual anomaly using a simple Abdelrahman, E.M., El-Araby, T.M., El-Araby, H.M. and Abo-Ezz, E.R., 2001, A new method for shape and depth determinations from gravity data. *Geophysics*, 66, 1774–1778.
- Aboud, E., Salem, A., Elawadi, E. and Ushijima, K., 2004, Estimation of shape factor of buried structure from residual gravity data. The 7th SEGJ International Symposium, November 24–26, Tohoku University, Sendai.
- Al-Garni, M.A., 2008, Walsh transforms for depth determination of a finite vertical cylinder from its residual gravity anomaly. *SAGEEP*, 6–10:689–702.
- Al-Garni, M.A., 2009, Interpretation of some magnetic bodies using neural networks inversion. *Arab J. Geosci.*, 2, 175–184.
- Al-Garni, M.A., 2010, Interpretation of spontaneous potential anomalies from some simple geometrically shaped bodies using neural network inversion. *Acta Geophysica*, 58, 143–162.
- Al-Garni, M.A., 2013, Inversion of residual gravity anomalies using neural network. *Arab J. Geosci.*, 6, 1509–1516.
- Asfahani, J. and Tlas, M., 2008, An automatic method of direct interpretation of residual gravity anomaly profiles due to spheres and cylinders. *Pure and Applied Geophysics*, 165(5), 981–994.
- Auda, G. and Kamel, M., 1999, MODULAR NEURAL NETWORKS: A SURVEY. *International Journal of Neural Systems*, 9(2), 129–151.
- Azam, 2000, Biologically inspired modular neural networks. PhD Dissertation. Virginia Tech., 183 p. <http://scholar.lib.vt.edu/theses/available/etd-06092000-12150028/unrestricted/etd.pdf>.
- Babu, L.A., Reddy, K.G. and Mohan, N.L., 1991, Gravity interpretation of vertical line element and slab—a Mellin transform method. *Indian J. Pure Appl. Math.*, 22, 439–447.
- Barker, J., Kogel, J., Krukowski, S. and Trivedi N., 2006, *Industrial Minerals and Rocks-Commodities. Markets, and Uses.*
- Baroz, J., Macaudiere, J., Montigny, R., Noghrean, M., Ohnenstetter, M. and Rocci G.A., 1983, Ophiolites and related formations in the central part of the Sabzevar (Iran) and possible geotectonic reconstructions, Geodynamic Project (Geotraverse) in Iran. GSI, Rep. No: 51.
- Bhatt, A. and Helle H., 2002, Committee neural network for porosity and permeability prediction from well logs. *Geophys. Prospect.*, 50, 645–660.

Sundararajan, N. and Rama Brahman G., 1998, Spectral analysis of gravity anomalies due to slab like structures—a Hartley transform technique. *J. Appl. Geophys.*, 39, 53–61.

Thompson, D.T., 1982, EULDPH—a new technique for making computer-assisted depth estimates from magnetic data. *Geophysics*, 47, 31–37.

Yarger, H.L., Robertson, R.R. and Wentland, R.L., 1978, Diurnal drift removal from aeromagnetic data using least squares. *Geophysics*, 46, 1148–1156.

Zhang, Q. and Gupta, K., 2000, Neural networks for RF and microwave design. Artech House, London, UK.

Zhang, L., Poulton, M.M. and Wang T., 2002, Borehole electrical resistivity modeling using neural networks. *Geophysics*, 67, 1790–1797.

formula. *Computer Geosci.*, 29, 801–804.

Sharma, B. and Geldart, L.P., 1968, Analysis of gravity anomalies of twodimensional faults using Fourier transforms. *Geophys. Prospect.*, 16, 77–93.

Shaw, R.K. and Agarwal, P., 1990, The application of Walsh transforms to interpret gravity anomalies due to some simple geometrical shaped causative sources: a feasibility study. *Geophysics*, 55, 843–850.

Sundararajan, N., Mohan, N.L. and Seshagiri Rao S.V., 1983a, Gravity interpretation of 2-D fault structures using Hilbert transform. *J. Geophysics*, 3, 34–47.

Sundararajan, N., Mohan, N.L. and Seshagiri Rao S.V., 1983b, Interpretation of gravity anomalies due to some 2-D structures—a Hilbert transform technique. *Indian AcadSci (Earth and Planetary Sciences)* 92, 179–188.



2D inverse modeling of residual gravity field using modular feed forward neural network: A case study; a chromite mine

Ata Eshaghzadeh^{1*}, Alireza Hajian², Shokufeh Khalili³

1. Master Graduated in Geophysics, Institute of Geophysics, University of Tehran, Iran.
2. Department of Physics, Islamic Azad University (Najafabad Branch), Isfahan, Iran.
3. Master Graduated in Geophysics, Islamic Azad University (Hamedan Branch), Hamedan, Iran.

Received: 18 July 2018; Accepted: 22 November 2018

Corresponding author: shagh@alumni.ut.ac.ir

Keywords

Gravity anomaly
Modular neural network
Chromite
Inverse modeling

Extended Abstract

Summary

One of the most important aspects of mineral deposit exploration is depth estimation values of the mineral masses. Gravity method is used widespread for detection of mineral deposits. A new approach is presented in order to interpret residual gravity anomalies due to simple geometrically shaped bodies such as horizontal cylinder, vertical cylinder, and sphere. This approach is mainly based on using feed forward modular neural network (MNN) inversion for estimating the shape factor, depth, and the amplitude coefficient. The sigmoid function has

been used as the activation function in the MNN inversion. The new approach has been tested first on synthetic data from different models using only one well-trained network. The results of this approach show that the parameter values estimated by the modular inversion are almost identical to the true parameters. Furthermore, noise analysis has been made. The inversion of noisy data produces satisfactory results for the data up to 5% of random noise. The reliability of this approach is demonstrated for real gravity field anomalies taken over a chromite deposit near Sabzevar City, Khorasan Province, Iran.

Introduction

Forward modeling plays an important role in gravity data interpretation. Gravity data interpretation aims mainly to estimate the depth and location of the causative target. It is known that the gravity data interpretation is non-unique where different subsurface causative targets may yield the same gravity response (anomaly); however, a priori information about the geometry of the causative target may lead to a unique solution (Roy et al., 2000; Aboud et al., 2004). Neural networks (NNs) provide means to build mathematical models that relate input data to desired output data. The neural networks do not know the physics of the forward problem; they have only catalogs of the input/output pairs of the forward mapping that have been fed to it. In this paper, MNN inversion is used mainly to compute the depth and the shape factor of the causative target from a gravity anomaly. NNs can offer a unique solution, especially for noisy data, when acknowledge of a task is not available or unknown nonlinearity between input and output may exist (Bhatt and Helle, 2002; Al-Garni, 2010).

Methodology and Approaches

NNs can be considered as universal approximation which can approximate any function in terms of its variables. Generally, a NN is fed by a training set of a group of examples from which it learns to estimate the mapping function described by the example patterns. NNs algorithms may be divided into two main groups, which are supervised (associative) learning and unsupervised (self-organization) learning. The supervised learning is based on desired outputs. During the training, the NN tries to match the outputs with the desired values. In unsupervised learning, the method is not given any target value where the desired output of the network is unknown. During the training, the network performs some kind of data compression such as dimensionality reduction or clustering. The NN inversion that has been used for training is based on the MNN architecture. A MNN is characterized by a series of independent NNs moderated by some intermediary. Each independent NN serves as a module (local expert) and operates on separate inputs to accomplish some subtask of the task that the network wishes to implement (Azam, 2000). The outputs of the modules are mediated by an integrated unit called gating network, which does not permit to feed information back to

the modules.

Results and Conclusions

NN inversion of gravity data over simple geometric shaped bodies such as sphere, horizontal cylinder, and vertical cylinder has been investigated in this paper. MNN inversion has been used in order to obtain three parameters: shape factor, depth, and amplitude coefficient. This approach has been tested first on synthetic data using only one well-trained network, and then, on a field example taken from Sabzevar area, Iran. The results show the upper and bottom depths of the ore body are about 8 m and 32 m, respectively.
