

وارون‌سازی داده‌های دو بعدی مقاومت ویژه الکتریکی لوله‌های زیرسطحی به روش شبکه‌ی عصبی مصنوعی

کاظم ملک‌پور دهکردی^{1*}، احمد قربانی²، عبدالحمید انصاری³

1- دانشجوی کارشناسی ارشد، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد

2- استادیار، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد

3- دانشیار، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد

(دریافت: خرداد 1393، پذیرش: اسفند 1393)

چکیده

وارون‌سازی داده‌های ژئوفیزیکی به علت غیرخطی بودن داده‌ها، فرآیندی بسیار پیچیده است، بخصوص در حالتی که قدرت تفکیک بسیار بالا در عمق نفوذ کم نیز مد نظر باشد. در دو دهه‌ی اخیر الگوریتم‌های وارون‌سازی غیرخطی نظیر شبکه‌های عصبی و الگوریتم‌های ژنتیک با رشد قابل توجهی برای تفسیر داده‌های ژئوفیزیکی مورد استفاده قرار گرفته‌اند. در این مطالعه وارون‌سازی داده‌های ژئوالکتریک خط لوله‌ی زیرسطحی با قدرت تفکیک بالا انجام شده است. بدین منظور از شبکه‌ی پس انتشار خطا کمک گرفته شد تا داده‌های حاصل از برداشت توموگرافی مقاومت ویژه‌ی دوبعدی مورد تفسیر قرار گیرند. پارامترهای شبکه شامل انواع داده‌های ورودی و خروجی، تعداد لایه‌ها، تعداد نرون‌های موجود در هر لایه، مقادیر بهینه‌ی نرخ یادگیری شبکه، ضریب مومنتوم و میزان تأثیر آن‌ها بر مقدار خطای شبکه خواهد بود. پس از انجام 20 تکرار خطا به 0/001 کاهش می‌یابد. خط لوله‌ی مقاوم 1000 اهم‌متری در یک نیم فضای همگن 100 اهم‌متری توسط آرایش الکترودی دوقطبی-دوقطبی با فاصله‌ی الکترودی یک متر مدل شده است. 36 دسته داده‌ی 207 تائی در این مطالعه در نظر گرفته شد، که 18 دسته داده به مرحله‌ی آموزش، 9 دسته به مرحله‌ی ارزیابی و 9 دسته نیز به مرحله‌ی اعتبارسنجی اختصاص داده شد و داده‌های صحرائی پس از تفسیر با روش وارون‌سازی معمول مقایسه شد. مقایسه‌ی مقاطع تفسیر شده توسط روش شبکه‌ی عصبی مصنوعی و روش‌های معمول در این مطالعه نشان داد که گرچه هر دو روش به آشکارسازی خط لوله منجر می‌شوند اما روش شبکه‌ی عصبی این قابلیت را خواهد داشت که جدا از آشکارسازی خط لوله، به تفکیک دو لوله با قطر 32 سانتیمتر در فاصله‌ی 1/2 متری از یکدیگر پردازد و حتی می‌تواند تخمین تقریبی نیز از قطر لوله در شبه مقاطع در اختیار بگذارد.

کلمات کلیدی

شبکه‌های عصبی مصنوعی، توموگرافی مقاومت ویژه‌ی الکتریکی، خط لوله‌ی عایق

1- مقدمه

توصیف خصوصیات هندسی و فیزیکی زیرسطحی یک چالش معاصر در بسیاری از زمینه‌ها از جمله زمین‌شناسی، باستان‌شناسی، اکتشاف نفت و گاز، مسائل مهندسی و زیست‌محیطی است. اجسام مدفون در زمین خواص فیزیکی متمایزی نسبت به زمینه‌ی پیرامون خود دارند که روش‌های ژئوفیزیکی اجازه اندازه‌گیری این خواص را می‌دهند. ارزیابی‌های ژئوفیزیکی اطلاعات کسب شده از چاه‌ها را در کل زون تعمیم داده و مقایسه بین داده‌های ژئوفیزیکی و اطلاعات چاه اجازه‌ی توصیف دقیق لایه‌های سطحی را می‌دهد. روش‌های الکتریکی به دلیل این‌که قدرت تفکیک جانبی بالایی را برای اعماق بررسی کم تهیه می‌کنند، سال‌های زیادی است که به‌عنوان روش‌های پیش‌حفری استفاده می‌شوند. توموگرافی مقاومت ویژه‌ی الکتریکی اطلاعات مفیدی مربوط به زمین‌شناسی، بی‌هنجاری‌های مدفون، لایه‌های آبدار و غیره در زیر سطح زمین به دست می‌دهد. از عمده‌ترین محدودیت‌های توموگرافی مقاومت ویژه‌ی الکتریکی علاوه بر زمان بودن برداشت، این است که در زمین‌های با مقاومت ویژه‌ی الکتریکی بالا امکان تزریق وجود ندارد [1]. در سال‌های اخیر استفاده از این روش در اکتشاف اجسام مدفون در نزدیکی سطح زمین بسیار مورد توجه واقع شده است [2-5]. بر همین اساس روش توموگرافی مقاومت ویژه‌ی دوبعدی و سه‌بعدی به‌عنوان ابزاری برای شناسایی فضاهای زیرسطحی مدفون شناخته می‌شوند و کارایی قابل‌توجهی در زمینه‌ی اکتشاف و بهینه‌سازی شبکه‌ی حفاری دارند [6-8].

وارون‌سازی داده‌های حاصل از برداشت توموگرافی مقاومت ویژه‌ی الکتریکی به علت طبیعت غیرخطی داده‌ها کار پیچیده‌ای است [9] توزیع مقاومت ویژه‌ی حقیقی در محیط مورد بررسی می‌تواند توسط فرآیند معکوس‌سازی با کمینه‌سازی یک تابع مناسب تخمین زده شود [10]. محققینی از جمله بارکر و لوک [11] با استفاده از روش‌هایی نظیر اجزا محدود و تفاضل محدود اقدام به طراحی الگوریتم وارون‌سازی برای داده‌های مقاومت ویژه‌ی الکتریکی نموده‌اند تا داده‌های حاصل از برداشت توموگرافی مقاومت ویژه‌ی الکتریکی دوبعدی توسط نرم‌افزار Res2DInv وارون‌سازی و آماده‌ی تفسیر شوند.

انتخاب یک الگوریتم بهینه در زمانی که ماهیت داده‌ها غیرخطی است، مهم‌ترین نکته در انجام یک فرآیند پردازشی همچون وارون‌سازی است [12]. بر همین اساس در سال‌های اخیر، شبکه‌های عصبی مصنوعی (ANN) پیشرفت چشم‌گیری به‌ویژه در زمینه‌ی الگوریتم‌های بهینه برای وارون‌سازی داده‌های غیرخطی داشته‌اند و در بحث‌های ژئوفیزیکی نیز با وجود مشکلات و ابهامات بسیار، در بعضی از مطالعات موردی جایگاه خود را پیدا کرده است. پولتون و فولی [13] داده‌های رادار زمین‌شناسی را توسط شبکه‌ی عصبی پردازش کردند. پولتون و استنبرگ [14] به پردازش داده‌های سونداژ الکترومغناطیس پرداختند. اسپچاک و پوپوا [15] داده‌های برداشت مگنتوتلوریک را با استفاده از یک الگوریتم بهینه‌ی شبکه‌ی عصبی پردازش کردند. کادی و یوشیجیما [16] شبکه‌های عصبی را برای پردازش‌هایی با قدرت تفکیک بسیار بالا در ژئوفیزیک بکار گرفتند. در سال 2001، کالدرون ماکیاس‌سن و استوفا¹ به بررسی قابلیت شبکه‌های عصبی برای وارون‌سازی داده‌های ژئوفیزیکی یک‌بعدی برداشت سونداژ مقاومت ویژه پرداختند [17] و تفاسیر قابل‌قبولی را ارائه کردند. سینق و همکاران کاربرد شبکه‌های عصبی مصنوعی را در زمینه‌ی پردازش یک‌بعدی داده‌های سونداژ مقاومت ویژه‌ی الکتریکی بررسی کردند [9]. احمد نیامدپور و همکاران به وارون‌سازی داده‌های مقاومت ویژه‌ی الکتریکی دوبعدی و شبه سه‌بعدی از طریق شبکه‌های عصبی مصنوعی پرداختند [18].

در این مطالعه قصد بر این خواهد بود تا وارون‌سازی داده‌های مقاومت ویژه‌ی الکتریکی دوبعدی مربوط به خط لوله‌ی زیرسطحی توسط الگوریتمی بهینه با استفاده از شبکه‌های عصبی مصنوعی را بررسی شده و قدرت تفکیک بی‌هنجاری‌های زیرسطحی توسط این الگوریتم مورد بحث قرار گیرد. در پایان نیز نتایج الگوریتم وارون‌سازی کارآمد ارائه شده برای این مطالعه موردی با نتایج ارائه شده توسط نرم‌افزار Res2DInv مورد مقایسه و ارزیابی قرار گیرد.

2- تئوری روش توموگرافی مقاومت ویژه‌ی الکتریکی

توموگرافی یا تصویربرداری مقاومت ویژه‌ی الکتریکی (ERT) تکنیکی ژئوفیزیکی است که به بررسی ساختارهای

معکوس‌سازی می‌شوند. این نرم‌افزار از الگوریتم حداقل مربعات برای کاهش خطای RMS بین مقاومت ویژه‌ی ظاهری اندازه‌گیری شده و محاسبه شده در یک فرآیند تکراری استفاده می‌کند.

افزایش فاصله‌ی بین الکترودهای (جریان و پتانسیل) بررسی‌های عمیق را با کاهش قدرت تفکیک ممکن می‌سازد. عمق بررسی یا عمق نفوذ با توزیع مقاومت ویژه‌ی زیرسطحی و آرایه‌ی الکترودی ارتباط دارد. آرایه‌های الکترودی بر اساس هدف کاوش و حساسیت افقی و یا قائم لازم، انتخاب می‌شوند. آرایه‌های دوقطبی-دوقطبی، شولمبرژر و ونر دارای بیش‌ترین کاربرد در برداشت‌های توموگرافی مقاومت ویژه‌ی الکتریکی هستند.

آرایه دوقطبی-دوقطبی هر دو پوشش افقی و عمودی از محیط بررسی را فراهم می‌کند؛ علاوه بر این به تغییرات جانبی مقاومت ویژه‌ی الکتریکی بسیار حساس است [11] و همچنین نسبت به سایر آرایه‌ها، تا اعماق بیش‌تری نفوذ می‌کند [21]. بنابراین برای به نقشه درآوردن بی‌هنجاری‌های قائم مناسب است. به همین دلیل این آرایه برای برداشت در این مورد مطالعاتی انتخاب گردیده است. این آرایه با حرکت دادن دوقطبی‌های جریان و پتانسیل، تغییر فاصله بین دوقطبی‌ها و طول آن‌ها، ساختن یک شبه مقطع الکتریکی از زیر سطح زمین را ممکن می‌سازد که به منظور محاسبه‌ی مدل دوبعدی مقاومت ویژه‌ی الکتریکی زمین معکوس‌سازی می‌شود. در تعیین سازه‌های شناخته شده بهترین نتیجه را آرایه‌ی دوقطبی-دوقطبی می‌دهد و به نظر می‌رسد تفسیر آن با برون‌یابی نواحی بررسی نشده مرتبط‌تر است [22].

3- سیستم شبکه‌ی عصبی


تحقیقات اولیه پیرامون شبکه‌های عصبی مصنوعی به 50 سال قبل، زمانی که رزون‌بالت [23] تئوری پرسپترون را ارائه کرد، باز می‌گردد. در دهه‌های میانی 1960، گرایش به استفاده از شبکه‌های عصبی به دلیل ناتوانی و محدودیت‌های بسیار تئوری پرسپترون کاهش یافت. با پیشرفت علم و استفاده از الگوهای جدید شبکه‌ی عصبی، محدودیت‌های تئوری پرسپترون تا حد بسیاری رفع شد تا مطالعات در زمینه شبکه‌های عصبی از سر گرفته شوند.

زیرسطحی در دو یا سه بعد می‌پردازد. مزیت اصلی روش ERT در مقابل روش‌های مرسوم و سنتی، بررسی تغییرات مقاومت ویژه‌ی الکتریکی هم به صورت جانبی (CST) و هم به صورت قائم (VES) در فضا است. با توجه به این که بی‌هنجاری‌های معدنی اکثراً دارای گسترش دو یا سه بعدی هستند، لذا استفاده از روش‌های یک بعدی ساده‌سازی بیش از حد است و تفسیر دوبعدی برداشت‌های توموگرافی معمولاً نتایج واقعی‌تری را به دست می‌دهد. این روش به طور روزافزون در پی‌جویی‌های معدنی، بررسی آب‌های زیرزمینی (خواص هیدرولیکی، گسترش زون‌های آلوده به سموم یا مواد شیمیایی و غیره)، کارهای مهندسی مانند بررسی فعالیت زمین‌لغزش‌ها و فعالیت‌های باستان‌شناسی به کار گرفته می‌شود.

روش توموگرافی مقاومت ویژه‌ی الکتریکی که بر اساس قانون اهم استوار است ($\rho_a = k \frac{\Delta V}{I}$) زمانی که هدف تعیین تغییرات مقاومت ویژه‌ی الکتریکی باشد، جهت مطالعه‌ی بی‌هنجاری‌های زیرسطحی قابل استفاده است و در آن جریانی به وسیله‌ی یک جفت الکترودها درون زمین تزریق می‌گردد و پتانسیل الکتریکی توسط جفت الکترودی دیگر که معمولاً (نه همیشه) با الکترودهای جریان هم‌خط هستند، اندازه‌گیری می‌شود. تمام آنالیزها و تفسیر بر اساس جریان مستقیم (DC) انجام می‌گردند؛ به دلیل این که جریان مستقیم عمق بررسی بیش‌تری را نسبت به جریان متناوب در اختیار قرار می‌دهد و پیچیدگی‌های به وجود آمده در اثر ضریب القایی و ظرفیت زمین و فرکانس منتج از آن که به مقاومت ویژه وابسته است را در نظر نمی‌گیرد. در رابطه‌ی مذکور، ρ_a مقاومت ویژه‌ی الکتریکی ظاهری، k فاکتور هندسی که تنها به عکس موقعیت مکانی الکترودهای جریان و پتانسیل وابستگی دارد، ΔV اختلاف پتانسیل الکتریکی اندازه‌گیری شده و I شدت جریان تزریقی است [19].

مقادیر مقاومت ویژه‌ی الکتریکی ظاهری به توزیع مقاومت ویژه‌ی حقیقی بستگی دارند. توزیع مقاومت ویژه‌ی حقیقی در محیط مورد بررسی می‌تواند توسط فرآیند معکوس‌سازی یا کمینه‌سازی یک تابع مناسب تخمین زده شوند [۲۰، ۱۰]. داده‌های توموگرافی مقاومت ویژه‌ی الکتریکی به‌طور معمول توسط نرم‌افزار Res2Dinv

برای رسیدن به یک خروجی مطلوب، بر اساس نوع پارامترهای ورودی یک سری معادلات انتخاب می‌کند و با استفاده از تغییر پارامترهای این معادلات، خروجی شبکه بدون شناخت روابط ریاضی برگزیده از سوی شبکه، بهینه می‌گردد [25]. شکل 1، نمای کلی از معماری شبکه‌ی عصبی مورد استفاده در این مطالعه شامل پارامترهای ورودی و خروجی، تعداد و نوع آن‌ها و تعداد لایه‌های پنهان را نشان می‌دهد.



شکل 1: معماری شبکه‌ی عصبی بکار رفته در این مطالعه

در لایه‌ی ورودی برابر سه و به علت تک هدفی بودن این مطالعه لایه‌ی خروجی تک نرون است. نرون‌های موجود در لایه‌ی ورودی با یکدیگر هیچ‌گونه ارتباطی ندارند و از طریق توابع انتقال با نرون‌های خروجی موجود در اولین لایه‌ی پنهان ارتباط خواهند داشت. تعداد نرون‌های موجود در لایه‌های پنهان با توجه به پیچیدگی مسئله و همچنین تعداد داده‌های ورودی متغیر است [17].

در این مطالعه به علت وجود داده‌های ورودی پرشمار و همچنین پیچیدگی نسبی مسئله، تعداد نرون‌های موجود در هر لایه‌ی پنهان در شبکه‌ی عصبی بهینه برابر با عدد 32 است. نرون‌های موجود در لایه‌ی پنهان می‌توانند با نرون‌های لایه‌ی خروجی و ورودی ارتباط داشته باشند. بر اساس قوانین یادگیری شبکه‌ی عصبی پس انتشار خطا، هدف این شبکه از آموزش، به حداقل رساندن میزان خطای بین داده‌های خروجی محاسباتی و داده‌های خروجی اولیه‌ای است که برای آموزش به شبکه داده شده است. روند کلی در مسیر آموزش شبکه‌های عصبی پس انتشار خطا آن است که ابتدا داده‌های ورودی به شبکه معرفی

شبکه‌های عصبی مصنوعی مثل سیستم طبیعی مغز انسان، از تعدادی نرون عصبی که با استفاده از سیناپس‌ها با یکدیگر در ارتباط هستند، تشکیل شده و با استفاده از تعداد زیادی پردازش‌های نسبتاً سخت داخلی مبتنی بر یک الگوریتم خاص عمل می‌کنند تا با توجه به معیارها و معادلاتی که شبکه‌ی عصبی بر اساس مدل‌های موجود در مرحله‌ی آموزش برای رسیدن به خروجی مطلوب در نظر گرفته است، به کنش‌های خروجی پاسخ دهند [24]. در واقع شبکه‌ی عصبی یک روش اکتشافی و بهینه‌سازی است که

نوع معماری شبکه‌ی عصبی و همچنین نوع توابع انتقال و آموزش مورد استفاده، از جمله مواردی است که با توجه به نوع هدف، به علت متغیر بودن نحوه‌ی ارتباط نرون‌های موجود در شبکه و همچنین نحوه‌ی به‌روزرسانی وزن نرون‌ها باعث تمایز در نتایج حاصله می‌شود. در این مطالعه از شبکه‌های پس انتشار خطا (BP)²، که یکی از توسعه‌یافته‌ترین و کاربردی‌ترین شبکه‌های حال حاضر است، استفاده شده است [15].

شبکه‌های عصبی پس انتشار خطا بر ساختارهای پردازشی استوار هستند که توزیع اطلاعات به‌صورت موازی صورت می‌گیرد و رابطه‌ی بین نرون‌ها از طریق کانال‌های سیگنال غیرخطی برقرار می‌شود، بنابراین این نوع شبکه به‌طور گسترده در زمینه‌های مهندسی بکار می‌رود. در این گونه از شبکه‌ها سه دسته لایه وجود دارد: یک لایه‌ی ورودی، یک یا بیش‌تر لایه‌ی پنهان و یک لایه‌ی خروجی. تعداد نرون‌های موجود در لایه‌ی ورودی و خروجی به تعداد متغیرهای موجود در بین داده‌های ورودی وابسته است. به علت سه متغیره بودن این مطالعه تعداد نرون‌های موجود

تابع لگاریتمی سیگموئید بر روی محور افقی را نیز مشخص می‌کند. مقادیر فعال‌سازی (خروجی‌ها) مربوط به واحد j را می‌توان با استفاده از رابطه‌ی 3 محاسبه نمود:

$$a_j = f(\text{net}_j) = \frac{1}{1 + \exp(-\text{net}_j)} \quad (3)$$

در ساده‌ترین شکل آن، به‌روزرسانی وزن طبق یک الگوی مدرج در جهت مخالف شیب قرار دارد. بنابراین قانون به‌روزرسانی وزن‌ها به‌صورت رابطه 4 خواهد بود:

$$\Delta_p w_{ij}(t) = -\varepsilon \cdot \frac{\partial E_P}{\partial w_{ij}}(t) + \alpha \cdot \Delta_p w_{ij}(t-1) \quad (4)$$

در معادله‌ی فوق α برابر پارامتر ممنتوم است که در واقع بیان‌گر تأثیر تکرار قبل بر تکرار فعلی است. رابطه 5 نیز خطای کلی شبکه‌ی پس انتشار خطا را بیان خواهیم کرد که وظیفه‌ی تنظیم وزن‌ها را دارد.

$$E = MSE = \sum_{p=1}^Q \frac{1}{Q} E_P = \frac{1}{Q} \sum_{p=1}^Q \sum_{j=1}^N (d_{pj} - a_{pj})^2 \quad (5)$$

در معادلات بالا، پارامتر ε مربوط به نرخ آموزش است و در بازه‌ی (0,1) قرار دارد. دو پارامتر d_{pj} و a_{pj} به ترتیب برابر مقادیر هدف و پاسخ‌های حقیقی مقادیر خروجی نرون j هستند، که مربوط به هر کدام از نمونه‌ها هستند. پارامترهای Q و N به ترتیب برابر تعداد نمونه‌های لازم برای آموزش و تعداد واحدهای خروجی مورد نیاز هستند. پس از آن که تعداد تکرار تعیین شده به پایان رسید، شبکه‌ی عصبی پس از محاسبه‌ی خروجی‌ها در بهترین شرایط محاسبات خود را پایان می‌دهد. شبکه‌ی پس انتشار خطا دارای الگوهای متفاوتی از نظر روش محاسبه و به‌روزرسانی وزن‌ها است. به علت وابستگی سرعت شبکه به عوامل مختلفی از جمله تعداد داده‌های آموزشی، تعداد نرون‌ها، تعداد وزن‌ها و بایاس‌ها و بسیاری از پارامترهای دیگر، برای حل یک مشکل انتخاب الگوی سریع‌تر سخت است، تا این امر همچنان یکی از ابهامات شبکه‌ی عصبی باشد.

4- الگوی لونبرگ-مارکوت³

از الگوریتم فوق در شبکه‌ی عصبی بکار رفته در این مطالعه استفاده شد. این الگوریتم [26] برای آموزش مرتبه دوم بدون محاسبه‌ی ماتریس هسیان به‌عنوان یک روش

شود. سپس توابع و پارامترهای لازم در مسیر آموزش به شبکه معرفی شود تا این شبکه کار خود را آغاز کند و بر اساس داده‌های ورودی، خروجی‌ها را محاسبه کند و سپس خروجی‌های محاسباتی را با خروجی‌های مطلوب از پیش تعیین شده مقایسه نماید و با توجه به میزان خطا، اقدام به کاهش خطا و بهینه ساختن شبکه‌ی کند تا الگوریتم به نتایج ایده‌آل خود نزدیک شود. در الگوریتم طراحی شده، برای به حداقل رساندن میزان خطا، تکنیک گرادیان شیب را بکار گرفته شده است. با توجه به محاسبات مربوط به مشتقات جزئی تابع خطا با در نظر گرفتن هر وزن، اصلاحات لازم مربوط به وزن‌های شبکه برای هر ممنتوم به دست می‌آید؛ بدین ترتیب با توجه به نتایج به دست آمده، وزن‌های شبکه پس از این فرآیند به‌روزرسانی می‌شوند.

یک سیگنال x_i در سیناپس i ورودی با نرون j که در وزن سنپتیک w_{ij} ضرب شده است، در ارتباط است. یک ترکیب متصل سیگنال‌های ورودی را که با استفاده از سیناپس‌های نرون وزن دار شده‌اند، اضافه می‌کند. هر واحد پردازش (نرون) دارای یک تابع فعال‌سازی است که معمولاً از تابع سیگموئید برای این هدف استفاده می‌شود. در این مطالعه ما از سه تابع مختلف (logsig)، (tansig) و (satlines) استفاده کرده‌ایم. تابع لگاریتمی سیگموئید نوع خاصی از تابع سیگموئید خواهد بود (رابطه 1).

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (1)$$

تابع‌های فعال‌سازی نقش محدود ساختن دامنه‌ی یک نرون را که در بین یک گستره از سیگنال‌های خروجی با مقادیر مشخص و محدود قرار دارد، بر عهده دارد. پردازشی که بر روی ورودی‌های i شبکه در واحد j صورت می‌گیرد را می‌توان به‌صورت رابطه 2 نوشت:

$$\text{net}_j = \sum_i w_{ij} + b_j \quad (2)$$


در رابطه‌ی فوق x_i خروجی لایه‌ی قبل است و w_{ij} وزن ارتباطی بین واحدهای i و j است. وزن مربوط به هر اتصال نشان می‌دهد که تا چه حد سیگنال انتقالی کاهش یا افزایش یافته است. بایاس خارجی b_j برای افزایش یا کاهش ورودی‌های شبکه‌ی عصبی در هنگام اعمال تابع فعال‌سازی فعالیت می‌کند که البته بسیار نیز به مثبت یا منفی بودن مقدارش وابسته است. همچنین این بایاس خارجی موقعیت

مدل شده است (شکل 2). با تغییر موقعیت افقی و همچنین عمق قرارگیری خط لوله‌ی مقاوم برای عمومیت یافتن شبکه، چندین دسته داده با مدل مقاومتی یکسان در نظر گرفته خواهد شد. در برداشت توموگرافی مقاومت ویژه در سایت ژئوفیزیک دانشگاه یزد با انتخاب فاصله‌ی الکترودی یک متر و آرایش الکترودی دوقطبی-دوقطبی خط لوله‌ی (دارای دو لوله به فاصله‌ی 1/2 متر) واقع در عمق سه متری شناسایی شده است؛ بنابراین داده‌های مصنوعی نیز با همین فاصله و آرایش الکترودی تولید می‌شود. مقدار فاکتور "n" در این مطالعه برخلاف تئوری‌های مقاومت ویژه (حداکثر تا 6) از یک تا 9 انتخاب می‌شود.

بهینه‌سازی بسیار قدرتمند طراحی شد تا نتایج بسیار مطلوب‌تری نسبت به الگوی گرادیان شیب نشان دهد. درواقع، این الگو زمانی که شبکه دارای چند صد وزن است، همگرایی بسیار سریعی را انجام خواهد داد، البته با خطای (MSE) به مراتب بزرگ‌تر نسبت به سایر الگوریتم‌های پس انتشار خطا. هرچه تعداد وزن‌ها افزایش یابد کارایی این الگوریتم کاهش خواهد یافت.

5- داده‌های آموزشی و ارزیابی

به منظور تولید داده‌های مورد نیاز برای آموزش و ارزیابی شبکه‌ی عصبی، یک خط لوله‌ی عایق (دارای دو لوله) با مقاومت 1000 اهم‌متر در یک زمین همگن با مقاومت 100 اهم‌متر را توسط برنامه‌ی (Res2Dmod)



شکل 2: مدل توده‌ی آنومالی مصنوعی ساخته شده با استفاده از نرم‌افزار (Res2Dmod)

دلخواه قرار داده می‌شود که منجر به نتایج مطلوب و البته دلخواهی می‌گردد.

جدول 1: فرم داده‌های ورودی و خروجی برای شبکه‌ی عصبی مورد مطالعه.

داده‌های ورودی			داده‌ی هدف
مختصه‌ی طول	مختصه‌ی عرض	ρ_a	ρ

گذشته از نحوه‌ی محاسبه‌ی موقعیت‌های افقی و عمودی مربوط به داده‌های ورودی که در عین سادگی است، باید گفت که این روابط توابعی از طول آرایش الکترودی و همچنین فاکتور "n" هستند.


7- تعداد نرون‌های موجود در هر کدام از لایه‌های پنهان

در این مطالعه شبکه دارای دو لایه‌ی پنهان است. برخلاف عدم حضور یک رابطه‌ی مشخص بین میزان

6- نحوه‌ی تولید داده‌های اختصاصی برای مراحل آموزش و ارزیابی

با توجه به محدودیت‌های بسیاری که در تشخیص مقاومت ویژه‌ی حقیقی با استفاده از دو نرم‌افزار (Res2Dmod) و (Res2Dinv) وجود دارد، ترجیح داده شده است که در یک شرایط خاص داده‌های ورودی مختص به لایه‌ی ورودی، یعنی موقعیت افقی و عمودی داده‌های مصنوعی تولید شوند. در این مطالعه موقعیت افقی داده‌ها را در مرکز آرایش الکترودی (دوقطبی-دوقطبی) و موقعیت عمودی یا عمق نگاشته شده توسط این آرایش در مرکز آرایش برابر با عمق متوسط نفوذ خواهد بود (شکل 3). حال باید گفت که استفاده از عمق نفوذ متوسط خود به نوعی باعث اعمال تابع حساسیت یا تابع فریسه خواهد شد، بنابراین با یک انتخاب مناسب شبکه‌ی عصبی در مسیر

در جدول 2 مشاهده می‌شود که کم‌ترین میزان خطا مربوط به زمانی است که تعداد نرون‌های موجود در هر دو لایه‌ی پنهان برابر با عدد 32 است. میزان دقت آموزش شبکه برابر با 0/001 است که در واقع این مقدار با استفاده از تابع کمترین مربعات خطا به دست خواهد آمد. در بسیاری از تئوری‌های شبکه‌ی عصبی استفاده از ساختار سه لایه‌ای می‌تواند برای تخمین بسیاری از توابع منطقی مفید واقع شود.



شکل 3: نحوه‌ی چیدمان داده‌های برداشت شده با توجه به موقعیت افقی و عمودی هر داده.

نشان دهد. بین ممنتوم و نرخ آموزش شبکه یک رابطه‌ی ریاضی نامشخص برقرار است.

در ادامه به بررسی میزان تأثیرگذاری ممنتوم و نرخ آموزش شبکه بر میزان خطای شبکه پرداخته می‌شود. بر طبق جدول 2، مقدار بهینه برای ممنتوم و نرخ آموزش برابر 0/002 و 0/1 است.

9- ارزیابی شبکه‌ی عصبی آموزش دیده با یک دسته داده‌ی مصنوعی

پس از آموزش شبکه‌ی عصبی، بهینه‌سازی پارامترهای آن و به حداقل رساندن خطای آن، می‌بایست شبکه را در عمل نیز با یک دسته داده‌ی مصنوعی تصادفی مطابق با سایر دسته داده‌های آموزشی ارزیابی کرد و نتایج وارون‌سازی داده‌ها را مورد بررسی قرار داد. پس از انجام وارون‌سازی باید نحوه‌ی عملکرد شبکه در اولین اقدام مطابق شکل 4 بررسی شود. در ادامه به بررسی شبه مقطع حاصل از وارون‌سازی توسط شبکه‌ی عصبی و مقایسه‌ی آن با شبه مقطع حاصل از وارون‌سازی معمول با استفاده از نرم‌افزار (Res2Dinv) پرداخته خواهد شد. شکل‌های 5 و 6 مدل یک خط لوله با مقاومت 1000 اهم متر در عمق سه متری یک زمین همگن 100 اهم‌متری را نشان می‌دهد که

نرون‌ها و میزان خطای شبکه، در عمل با افزایش تعداد نرون‌ها میزان خطای شبکه کاهش می‌یابد و عملکرد شبکه بهبود می‌یابد. با توجه به این امر در این مطالعه، بررسی کوتاه بر روی نحوه‌ی تغییرات میزان خطای شبکه با توجه به افزایش تعداد نرون‌های هر کدام از لایه‌های پنهان صورت گرفته است. در لایه‌ی ورودی سه متغیر به نام‌های موقعیت افقی داده، موقعیت عمودی داده و مقدار مقاومت ویژه‌ی ظاهری داده و سه نرون، در لایه‌ی خروجی تنها یک متغیر به نام مقاومت ویژه‌ی حقیقی و یک نرون وجود دارد.

8- تنظیم و انتخاب نرخ آموزش و ممنتوم شبکه‌ی عصبی

انتخاب یک الگو و پارامترهای مناسب در راستای به نتیجه رسیدن شبکه‌ی عصبی بسیار مهم است. بنابراین در این مطالعه نرخ آموزش (ϵ) شبکه‌ی پس انتشار خطا به‌عنوان پارامتر برجسته‌ای در بازه‌ی $[0.1, 1]$ ، در نظر گرفته می‌شود تا مقدار خطای منفی که باید قبل از انجام هر تکرار به وزن‌های ارتباطی اضافه گردد را کنترل می‌کند. حال اگر نرخ آموزش شبکه بزرگ انتخاب شود، تغییرات در وزن‌های ارتباطی بزرگ و اگر نرخ آموزش کوچک در نظر گرفته شود، تغییرات در وزن‌های ارتباطی کوچک خواهد بود و زمان آموزش افزایش خواهد یافت و میزان خطا نیز تا حد بسیاری کاهش می‌یابد.

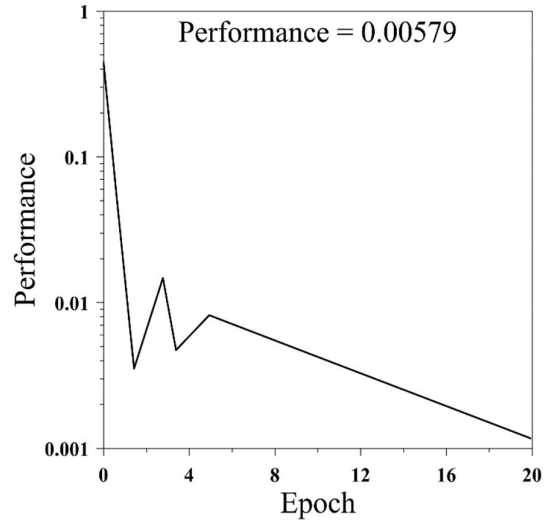
ممنتوم که از دیگر پارامترهای تأثیرگذار در مسیر آموزش شبکه‌ی عصبی است، که با حرف (α) نشان داده می‌شود. ممنتوم، میرایی میزان تغییرات وزن‌های ارتباطی اعمال شده قبل از انجام تکرار⁴ را بعد از انجام تکرار بین صفر تا یک نشان می‌دهد. ممنتوم به شبکه اجازه می‌دهد تا علاوه بر تغییرات شیب به تغییرات سطح خطا نیز واکنش

برداشت آزمایشگاهی با آرایش الکترودی دایپل‌دایپل، مشابه
برداشت توموگرافی مقاومت ویژه دوبعدی سایت ژئوفیزیک

جدول 2: بررسی میزان تأثیرگذاری افزایش نرون‌های لایه‌ها پنهان بر میزان کاهش خطای شبکه‌ی عصبی (MSE error) و میزان تأثیر تغییرات در مقدار ممنوم و نرخ آموزش شبکه


نرخ آموزش	ممنوم	زمان (دقیقه:ثانیه)	تعداد تکرار	لایه‌ی پنهان Nh1	لایه‌ی پنهان Nh2	MSE error (%)
0/001	0	3:32	154	4	0	0/0098
	0/002	2:30	101		4	0/0095
	0/4	3:45	186		12	0/0092
	0/6	3:47	189		20	0/0084
	0/8	4:01	203		28	0/0089
0/01	0	10:43	423	12	32	0/0096
	0/002	10:00	409		0	0/0065
	0/4	11:21	507		4	0/0045
	0/6	11:32	507		12	0/0092
	0/8	12:02	512		20	0/0017
0/1	0	8:25	326	20	28	0/0092
	0/002	14:32	700		32	0/0092
	0/4	3:21	123		0	0/0065
	0/6	3:02	101		4	0/0045
	0/8	3:25	145		12	0/0037
1	0	1:32	89	28	20	0/0045
	0/002	2:32	109		28	0/0042
	0/4	2:01	105		32	0/0029
	0/6	1:36	79		0	0/0027
	0/8	1:02	54		4	0/003
				32	12	0/0023
					20	0/0019
					28	0/0021
					32	0/0029
					0	0/0045
				32	4	0/0032
					12	0/0034
					20	0/005
					28	0/002
					32	0/00101

در برداشت توموگرافی مقاومت ویژه با آرایش الکترودی دوقطبی-دوقطبی، با وجود حساسیت جانبی، نمی‌توان دو لوله‌ی موجود به قطر 32 سانتیمتر با فاصله‌ی 1/2 متری از یکدیگر را تفکیک کرد و ابعاد لوله‌ها را تخمین زد، که این خود از معایب شبه مقطع حاصل از نرم‌افزار (Res2Dinv) است. بررسی دقیق مدل و شبه مقطع، جابجایی‌های عرضی در آنومالی را نشان می‌دهد. حال باید دید که شبه مقطع حاصل از شبکه‌ی عصبی پس از بررسی عملکرد آن به چه گونه است (شکل 4).




شکل 4: نمودار عملکرد شبکه‌ی عصبی برای دسته داده‌ی مصنوعی مدل ساخته شده


شکل 7 شبه مقطع حاصل از شبکه‌ی عصبی را برای داده‌های مصنوعی مدل خط لوله نمایش می‌دهد. شبکه‌ی عصبی بر خلاف برنامه‌ی (Res2Dinv) قابلیت تفکیک دو لوله‌ی موجود در خط لوله و تخمین تقریبی ابعاد لوله‌ها را از طریق شبه مقطع دارد. حساسیت نسبت عمق چندان قابل توجه نیست.



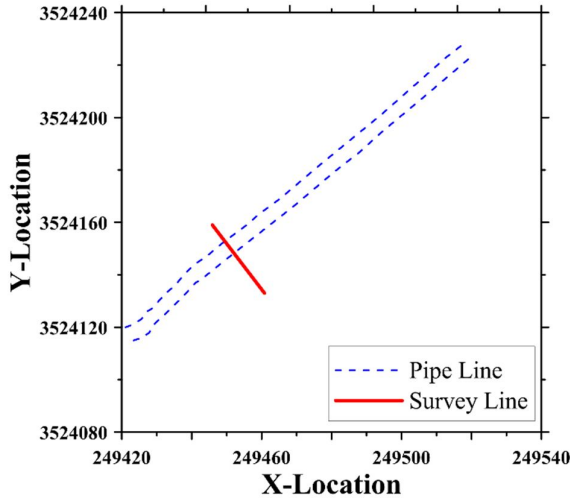
شکل 5: مدل طراحی شده برای ارزیابی شبکه‌ی عصبی با استفاده از نرم‌افزار (Res2Dmod).



شکل 6: شبه مقطع مقاومت ویژه ظاهری مدل مصنوعی ساخته شده



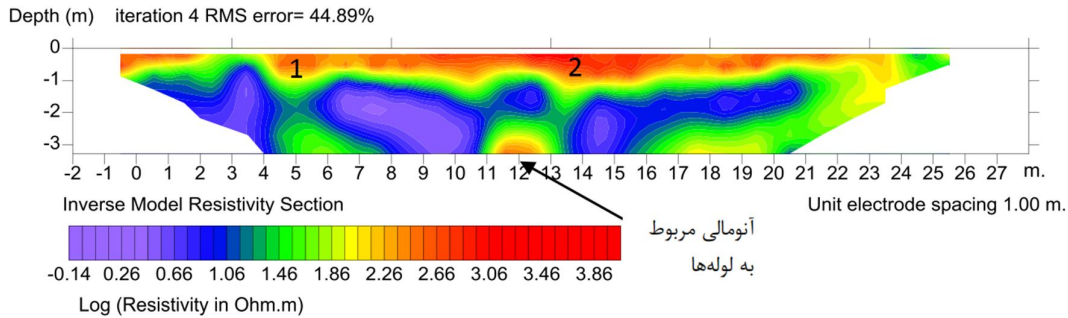
شکل 7: مقطع تفسیر شده‌ی مدل مصنوعی با استفاده از شبکه‌ی عصبی طراحی شده




شکل 8: موقعیت جغرافیائی قرارگیری خط لوله و خط برداشت توموگرافی دوبعدی مقاومت ویژه الکتریکی.

10- مقایسه نتایج شبکه ی عصبی با نتایج روش های معمول بر روی داده های سایت ژئوفیزیک دانشگاه یزد

در سایت ژئوفیزیک دانشگاه یزد دو لوله ی عایق در عمق سه متری با قطر 32 سانتیمتر و فاصله ی 1/2 متری از یکدیگر در زیر زمین قرار گرفته است که با یک برداشت توموگرافی مقاومت ویژه با آرایش الکترودی دوقطبی- دوقطبی و فاصله ی الکترودی یک متر در راستای عمود بر آن، آشکاری سازی شده اند (شکل 8) که در ادامه نتایج در شکل های 9 و 10 ارائه خواهند شد



شکل 9: مقطع تفسیر شده ی خط لوله ی زیر سطحی به روش وارون سازی معمول



شکل 10: مقطع تفسیر شده ی خط لوله ی زیر سطحی به روش وارون سازی شبکه ی عصبی

همگرایی کم تر با توجه به داده های مورد آموزش، استفاده شد. در اینجا از شبکه ی پس انتشار خطای سه لایه ای که در هر دو لایه ی پنهان آن 32 نرون در نظر گرفته شده است، استفاده شد. در مجموع 36 دسته داده ی مصنوعی (هر کدام شامل 207 داده) برای این مطالعه در نظر گرفته

11- بحث و نتیجه گیری

در این مطالعه روش (LMBP) پس انتشار خطا با الگوی لونیبرگ-مارکوت برای آموزش، به عنوان نوع خاصی از شبکه های عصبی به دلیل داشتن کمترین خطا و البته زمان

برداشت توموگرافی مقاومت ویژه الکتریکی دوبعدی در راستای خط برداشت مورد بررسی در این مطالعه با فاصله الکترودی 5 متر گرچه به علت افزایش عمق بررسی و کاهش قدرت تفکیک، توان آشکارسازی خط لوله‌ی عایق موجود را ندارد، اما به‌خوبی سنگ کف آهکی مقاوم را آشکار می‌کند. بر همین اساس پیشنهاد می‌گردد برای تعیین عمق سنگ کف از وارون‌سازی به روش شبکه‌ی عصبی مصنوعی استفاده شود و نتایج با نتایج وارون‌سازی با نرم‌افزار Res2Dinv مقایسه شوند. انتظار می‌رود که به دلیل این که سنگ کف محیط کاملاً آهکی و مقاوم است، شبکه‌ی فعلی توان تفکیک آن را خواهد داشت، هرچند شاید ناهمگن‌های زیرسطحی مانعی بر سر این کار محسوب شوند.

12- مراجع

- [1]. Szalai, S; Szarka, L; 2008; "Parameter sensitivity maps of surface geoelectric arrays"; Part 1: linear arrays, Acta Geodaetica et Geophysica Hungarica. J. Int., 43, pp.419-437.
- [2]. Leucci, G; Greco, F; De Giorgi, L; Mauceri, R; 2007; "Three-dimensional image of seismic refraction tomography and electrical resistivity tomography survey in the castle of Occhiola` (Sicily, Italy)"; Journal of Archaeological Science. J. Int., 34, pp.233-242.
- [3]. Drahor, M.G; Kurtulmus, T.O; Berge, M.A; Hartmann, M; Speidel, M.A; 2008; "Magnetic imaging and electrical resistivity tomography studies in a Roman military installation found in Satala archaeological site, northeastern Anatolia, Turkey"; Journal of Archaeological Science. J. Int., 35, pp.259-271.
- [4]. Cardarelli, E; Di Filippo, G; 2009, "Integrated geophysical methods for the characterisation of an archaeological site (Massenzio Basilica — Roman forum, Rome, Italy)"; Journal of Applied Geophysics. J. Int., 68, pp. 508–521.
- [5]. Gracia, V.P; Caselles, J.O; Clapes, J; Osorio, R; Martı'nez, G; Canas, J.A; 2009; "Integrated near-surface geophysical survey of the Cathedral of Mallorca"; Journal of Archaeological Science, vol. 36, pp.1289–1299.
- [6]. Mochales, T; Casas, A.M; Pueyo, E L; Pueyo, O; Roman, M T; Pocovi, A; Soriano, M A; Anson, D; 2008; "Detection of underground cavities by combining gravity, magnetic and ground penetrating radar surveys: A case study from the Zaragoza area"; Environ. Geol 53:1067–1077.
- [7]. Dahlin, T; Bring, Z; 2004; "Numerical comparison of 2D resistivity imaging with ten

شد، که از این تعداد 18 دسته داده به مرحله‌ی آموزش، 9 دسته به مرحله‌ی ارزیابی و 9 دسته نیز به مرحله‌ی اعتبارسنجی شبکه‌ی عصبی اختصاص داده شدند. بیشینه‌ی گستره‌ی خطای RMS شبکه بین 0/001 تا 0/08 تشخیص داده شد که با توجه به انتخاب تابع آموزش لونبرگ مارکوت قابل قبول است.

مقایسه‌ی مقاطع تفسیر شده توسط روش شبکه‌ی عصبی مصنوعی و روش‌های معمول در این مطالعه نشان داد که گرچه هر دو روش به آشکارسازی خط لوله منجر می‌شوند اما روش شبکه‌ی عصبی این قابلیت را خواهد داشت که جدا از آشکارسازی خط لوله، به تفکیک دو لوله با قطر 32 سانتیمتر در فاصله‌ی 1/2 متری بپردازد و حتی می‌تواند تخمین تقریبی نیز از قطر لوله در شبه مقاطع در اختیار بگذارد. نکته‌ی دیگری که در نتایج شبکه‌ی عصبی مصنوعی شاهد آن هستیم، کاهش جابجایی جانبی است که در روند وارون‌سازی به روش‌های معمول شاهد آن هستیم، بخصوص زمانی که از آرایش الکترودی دوقطبی-دوقطبی نیز در حین برداشت بهره برده باشیم.

وارون‌سازی به روش شبکه‌ی عصبی مصنوعی در این مطالعه گرچه با نگاه اکتشافی به خط لوله‌ی زیرسطحی انجام شده است اما با نگاهی به مقاطع تفسیر شده شاهد این نکته هستیم که رس‌های سطحی مقاوم که هسته‌ی آن‌ها در شکل 9 با شماره‌های 1 و 2 مشخص شده است، به دلیل قرار گرفتن در گستره‌ی مقاومت ویژه الکتریکی یکسان با خط لوله‌ی عایق در مقاطع تفسیر شده‌ی حاصل از روش شبکه‌ی عصبی نیز قابل مشاهده هستند و این امر تأکیدی بر این مسئله است که هرچه طیف آموزش شبکه عصبی گسترده‌تر باشد، نتایج جامع‌تری را در اختیار خواهیم داشت.

حساسیت نسبت به عمق یکی دیگر از نکاتی است که درستی وارون‌سازی به روش شبکه‌ی عصبی را تصدیق می‌کند. گرچه در مرحله‌ی ارزیابی شبکه‌ی عصبی مصنوعی با داده‌های مصنوعی حساسیت نسبت به عمق چندان دقیق و برتر نسبت به سایر روش‌های معمول نشان نداد، اما در مرحله‌ی تفسیر داده‌های صحرایی شبکه‌ی عصبی موفق شد به‌خوبی عمق توده‌های زیرسطحی را نشان دهد (عمق سه متر) و از این بابت با روش‌های معمول قابل رقابت باشد (شکل 10).

- [23]. Rosenblatt, F; 1962; Principles of neuro-dynamics: perceptrons and the theory of brain mechanisms; Washington DC: Spartan books.
- [24]. Hagan, M.T; Demuth, H.B; Beale, M.H; 1996; Neural Network Design; Boston, MA: PWS Publishing.
- [25]. Baum, E; Hausler, D; 1989; "what size net gives valid generalization?" Neural Computation 1:151-160.
- [26]. Hagan, M T; Menhaj, M.B; 1994; "Training feed forward networks with the Marquardt algorithms"; IEEE Trans. on Neural Networks 5:989-993.
- electrode arrays"; Geophysical Prospecting 52:379-398.
- [8]. Zhou, W; Beck, B.F; Adams, A. L; 2002; "Effective electrode array in mapping karst hazards in electrical resistivity tomography", Environmental Geology 42:922-928.
- [9]. Singh, U.K; Tiwari, R.K; Singh, S.B; 2005; "One-dimensional inversion of geoelectrical resistivity sounding data using artificial neural networks – a case study"; Comput. Geosci. 31 99-108.
- [10]. Loke, M.H; 1999; "Electrical imaging survey for environment and engineering studies a practical guide to 2D and 3-D surveys"; 5, Cangkat Miden Lorong 6, Miden Heights, 11700 Penang, Malaysia (mloke@pc.jaring.my). Downloaded from <http://www.abem.se>.
- [11]. Loke, M.H; Barker, R.D; 1996; "Rapid least squares inversion of apparent resistivity pseudosections by a quasi Newton method"; Geophysical Prospecting. J. Int.; 44, pp.131-152.
- [12]. Scales, L. E; 1985; Introduction to non-linear optimization. New York, Springer-Verlag.
- [13]. Poulton, M; El-Fouly, A; 1991; "Preprocessing GPR signatures for cascading neural network classification"; 61st SEG meeting, Houston, USA, Expanded Abstracts 507-509.
- [14]. Poulton, M; Sternberg, K; Glass, C; 1992; "Neural network pattern recognition of subsurface EM images"; J. Appl. Geophys. 29 21-36.
- [15]. Spichak, V.V; Popova, I.V; 2000; "Artificial neural network inversion of MT – data in terms of 3D earth macro – parameters"; Geoph. J. Int. 42:15-26.
- [16]. El-Qady, G; Ushijima, K; 2001; "Inversion of DC resistivity data using neural networks"; Geophys. Prospect. 49: 417-430.
- [17]. Calderón-Macías, C; Sen, M.K; Stoffa, P.L; 2001; "Artificial neural networks for parameter estimation in geophysics"; Geophysical Prospecting 48:21-47.
- [18]. Neyamadpour, A; Wan Abdullah, W A T; Samsudin, T; 2010; "Inversion of quasi-3D DC resistivity imaging data using artificial neural networks"; J. Earth Syst. Sci 119:27-40.
- [19]. Parasnis, D.S., 1997, Principles of Applied Geophysics, fifth ed., Chapman and Hall, London.
- [20]. Milsom, J; 2003; Field Geophysics; 3rd edition; John Wiley & Sons; Chichester, UK.
- [21]. Candansayar, M.E; 2008; "Two-dimensional individual and joint inversion of three- and four-electrode array DC resistivity data"; Journal of Geophysical Engineering. J. Int., 5, pp. 290-300.
- [22]. Pánek, T; Margielewski, W; Tábořík, P; Urban, J; Hradecký, J; Szura, C; 2010; "Gravitationally induced caves and other discontinuities detected by 2D electrical resistivity tomography: Case studies from the Polish Flysch Carpathians", Geomorphology. J. Int., 123, pp.165-180.

1- Calderon-Macias, Sen & Stoffa

2- Back Propagation

3- Levenberg-Marquardt

4- Iteration

2-D resistivity inversion using artificial neural network of subsurface pipeline's data

K. Malekpour Dehkordi^{1*}, A. Ghorbani², A. Ansari³

1- MSc. Student of Mining Engineering, Dept. of Mining and Metallurgy, Yazd University, Iran

2- Assistant Professor, Dept. of Mining and Metallurgy, Yazd University, Iran

3- Associate Professor, Dept. of Mining and Metallurgy, Yazd University, Iran

* Corresponding Author: Kazemmalekpour@yahoo.com

(Received: June 2014, Accepted: March 2015)

Abstract

Inverting geophysical data due to their nonlinear nature is a very complex process, especially when a very high resolution in low depth is considered. In the past two decades, nonlinear inversion algorithms such as neural networks and genetic algorithms with significant growth for the interpretation of geophysical data have been used. In this study, geophysical inverting subsurface pipeline's data with high resolution is done. Thus, back-propagation network helped us to interpreting two-dimensional resistivity tomography data. Network parameters, including input and output data types, number of layers, number of neurons in each layer, network optimal learning rate, momentum coefficient and their impact on the value of the network error. After 20 iterations the error is reduced to 0.001. Robust pipeline (1000 ohm m) in a homogeneous half- space (100 Ohm m) by dipole-dipole array and one meter electrode spacing was modeled. 36 data sets that contained 207 components, were considered in this study, the 18 data sets in the training phase, 9 data sets in the evaluation phase and other data sets were assigned to a validation phase and the field data sets after the interpretation were compared with conventional inversion method. In this study, Comparing pseudo-sections interpreted by the artificial neural network method and conventional methods showed that although both methods lead to the detection pipeline but the artificial neural network method has a capability to separate two tube in pipelines that perched in 1.2 meter distance from each other and have 32 centimeter diameter and even can offer an approximately estimation of the diameter of the pipelines in pseudo-sections.

Keywords

Artificial Neural Network; Electrical Resistivity Tomography; Shell Pipeline