

# بررسی امکان به کارگیری شبکه‌های عصبی مصنوعی در مدل‌سازی وارون دو بعدی ترکیبی داده‌های دو مد قطبش روش مگنتوتلوریک

نوشته: علی مرادزاده\*، فاطمه طهماسبی\* و محمد مهدی فاتح\*\*

\*دانشکده مهندسی معدن و ژئوفیزیک، دانشگاه صنعتی شاهرود \*\*دانشکده مهندسی برق و رباتیک، دانشگاه صنعتی شاهرود

## An Investigation on the Possibility of Two-Dimensional Joint Inversion of TE and TM Modes Data in Magnetotelluric (MT) Survey using Artificial Neural Network

By: A. Moradzadeh\*, F. Tahmasbi\* & M. Fateh\*\*

\* Faculty of Mining Eng. & Geophysics, Shahrood University of Technology

\*\* Faculty of Electrical Eng. & Robotic, Shahrood University of Technology

تاریخ پذیرش: ۱۳۸۵/۰۷/۱۸

تاریخ دریافت: ۱۳۸۳/۱۰/۰۶

### چکیده

روش مگنتوتلوریک یکی از روشهای الکترومغناطیس با چشمه طبیعی است که برای کسب اطلاعات الکتریکی از ساختارهای زیرزمینی استفاده می‌شود. کاربرد این روش، بیشتر برای اکتشاف منابع زمین گرمایی، نفت و ذخایر معدنی است. با توجه به اینکه داده‌های اندازه‌گیری شده در روش مذکور حجیم و دارای ساختاری پیچیده هستند، از این روش مدل‌سازی وارون داده‌های حاصل نسبت به دیگر روشهای الکتریکی مشکل‌تر و در بعضی موارد ناممکن است. هدف این مقاله، بر این است که قابلیت‌های شبکه‌های عصبی مصنوعی برای مدل‌سازی وارون ترکیبی داده‌های فاز و مقاومت ویژه دو مد قطبش این روش مورد بررسی قرار گیرد. به منظور نیل به این هدف از شبکه پرسپترون چند لایه با قانون فراگیری پس انتشار خطا استفاده شد. برای آموزش و طراحی شبکه مناسب، چندین مدل مصنوعی در گروه مورد نظر ساخته شد و سپس با مدل‌سازی مستقیم داده‌های مقاومت ویژه و فاز آنها برای دو مد قطبش الکتریکی عرضی (TE (Transverse Electric) و مغناطیس عرضی (TM (Transverse Magnetic) در چندین بسامد تولید شد. پس از بررسیهای جامع، یک شبکه پرسپترون سه لایه با ساختار ۳۹۶-۹-۹ طراحی شد و از آن برای مدل‌سازی دو بعدی استفاده شد. بررسی نتایج به دست آمده نشان می‌دهد که شبکه طراحی شده از دقت قابل قبولی برای مدل‌سازی داده‌های مگنتوتلوریک برخوردار است، به گونه‌ای که برای یکی از مدل‌های آزمایشی، مقدار میانگین خطای نسبی در نبود نوفه (Noise) ۳/۹ درصد و در حضور ۵ درصد نوفه ۶/۹ درصد است، که این امر حاکی از دقت خوب شبکه در برآورد پارامترهای مدل زیرزمینی است. همچنین نتایج مدل‌سازی شبکه برای یک مجموعه داده‌های صحرائی و مقایسه آن با نتایج یکی دیگر از روشهای معمول مدل‌سازی وارون نشان می‌دهد که مدل‌ها و پارامترهای به دست آمده توسط دو روش فوق، از شباهت و همخوانی خوبی برخوردار هستند که این مطلب گویای توانمندی شبکه طراحی شده برای مدل‌سازی داده‌های مورد نظر است.

**کلیدواژه‌ها:** روش مگنتوتلوریک، مدل‌سازی وارون ترکیبی، شبکه عصبی مصنوعی، مدهای قطبش الکتریکی عرضی و مغناطیس عرضی، داده‌های فاز و مقاومت ویژه.

### Abstract

The magnetotelluric (MT) method is a natural source electromagnetic geophysical technique, which is used mainly in petroleum, mineral and geothermal exploration. As in this method, the quantity of the measured data is bulky and have a complex structure, their modeling, compared with the modeling of the other electrical data, is a very complex task or even impossible in some instances.

The main objective of this paper is to use the ability of the artificial neural networks (ANN) to find a solution for two-dimensional (2D) joint TE (transverse electric) and TM (transverse magnetic) modes inverse modeling of MT data. To achieve the goal, a multilayer perceptron (MLP) network with back propagation (BP) learning algorithm is used. In order to learn the de-

signed network, many synthetic 2D models with the same category, have been created and their responses have been calculated for each polarization mode by forward modeling. Synthetic data include apparent resistivity and impedance phase in 9 stations and 11 frequencies in two polarization modes. After a comprehensive study, a perceptron with 3 layers and architecture of 396-9-9 has been designed and used to model the data.

This study show that the designed network is capable enough to produce an acceptable 2D underground model so that the correspondence mean relative modeling error is 3.9% and 6.9 % respectively for noise free data and 5 percent randomly added noisy data. This indicates that if ANN is designed and trained properly, then it would be capable enough to perform 2D inverse modeling of MT data. It has also shown that once the designed network has been trained properly it is able to perform the inverse modeling precisely in a short time. At the end, the performance of the designed network has been evaluated by a set of field MT data and its results has been compared with those produced by a common smooth rapid relaxation inversion (RRI) method. The comparison indicates that the results of these two different procedures are in close agreement.

**Keywords:** MT method, Joint inversion, Artificial neural networks, TE and TM modes, Resistivity and phase data

## مقدمه

در میدان مغناطیس زمین به عنوان چشمه موج استفاده می‌شود. از مهم ترین منابع این امواج، می‌توان به فعالیت‌های خورشیدی، آذر خشها، شفقهای قطبی، حرکتهای نسبی زمین، خورشید و ماه و همچنین میدانهای ناشی از گردبادهای بزرگ اشاره کرد (Dobrin & Sovit, 1988; Telford et al., 1990; Vozoff, 1991). امواج ایجاد شده تقریباً بدون تضعیف، پوسته نارسای هوا را طی کرده و به سطح زمین برخورد می‌کنند، بیشتر انرژی تابشی در سطح زمین بازتاب می‌شود و تنها بخش کوچکی از آن به طور عمود وارد زمین می‌شوند (Vozoff, 1991) که باعث القای جریانهای الکتریکی در درون زمین و پس از آن تولید میدانهای الکترومغناطیسی ثانویه می‌شوند.

تغییرات میدانهای الکتریکی و مغناطیسی در سطح زمین به طور همزمان برای باندهای بسامدی مورد نظر اندازه گیری می‌شود و سپس با پردازشهای لازم، نسبت میدانهای الکتریکی و مغناطیسی در هر بسامد کمیت مختلطی به نام پاگیری (امپدانس) الکتریکی  $Z_{ij} = (E_i/H_j)$  را نتیجه می‌دهد. با استفاده از پاگیری الکتریکی و رابطه زیر می‌توان مقاومت ویژه ظاهری و فاز پاگیری را در هر بسامد به دست آورد.

$$\rho_{ij} = 0.2T |Z_{ij}|^2 \Omega m \quad i, j = x, y$$
$$\varphi_{ij} = \tan^{-1} (\text{Im}(Z_{ij}) / \text{Re}(Z_{ij})) \quad (1)$$

در رابطه فوق  $\rho_{ij}$  مقاومت ویژه ظاهری بر حسب اهم-متر،  $T$  پریود اندازه گیری بر حسب ثانیه،  $\varphi_{ij}$  فاز پاگیری الکتریکی بر حسب درجه،  $\text{Im}(Z_{ij})$  بخش موهومی پاگیری الکتریکی و  $\text{Re}(Z_{ij})$  بخش حقیقی پاگیری الکتریکی است (Kaufman & Keller, 1981).

برای یک نیم فضای همگن مقاومت ویژه و فاز پاگیری به صورت زیر محاسبه می‌شود:

وارون سازی داده‌های الکترومغناطیس، روشهای مختلفی دارد که میزان دقت هر یک از این روشها به کیفیت داده‌ها و روش مورد استفاده در تفسیر و پردازش داده‌ها بستگی دارد. استفاده از روشهای معمول مدل سازی وارون (معکوس) (Inverse modelling) اغلب نیاز به یک حدس اولیه در مورد پارامترهای مدل دارد که این امر مستلزم شناسایی برخی از پارامترهای مدل با استفاده از دیگر روشهای ژئوفیزیکی و یا اطلاعات زمین شناسی است (مرادزاده و عرب امیری، ۱۳۸۳) همچنین این روشها به دلیل استفاده از الگوریتمهای تکرار شونده، بسیار زمان بر هستند. روشهای معمول وارون سازی اغلب از روشهای عددی در حل معادلات حاکم بر مسئله استفاده می‌کنند (Wannamaker et al., 1987; Mackie et al., 1993) که حل معادلات با استفاده از این روشها بویژه در مورد ساختارهای دو بعدی و سه بعدی منجر به افزایش زمان محاسبات و همچنین به دلیل فرضیات مختلف ساده سازی مسئله موجب کاهش دقت می‌شود. مشکل فوق با در نظر گرفتن خاصیت پخش (Diffusive) امواج مگنتوتلوریک (MT: Magnetotelluric) و پیچیدگی و حجم بودن داده‌ها افزایش می‌یابد. از سوی دیگر وارون سازی داده‌های حاوی نوفه نیز منجر به حصول نتایج دور از واقعیت می‌شود (Spichak & Popova, 2000). با توجه به غیر خطی بودن روابط بین پارامترهای مدل و پاسخ مدل و توانمندی شبکه‌های عصبی مصنوعی در حل چنین مسائلی به نظر می‌رسد، این شبکه‌ها بتوانند گزینه مناسبی برای مدل سازی، دست کم در مواردی که، ساختار زیر سطحی زمین مورد مطالعه ساده باشد، فراهم نمایند و علاوه بر آن پردازش همزمان داده‌ها را امکان پذیر سازند.

## تئوری روش مگنتوتلوریک

در روشهای الکترومغناطیس چشمه طبیعی (مگنتوتلوریک) از تغییرات طبیعی

افقی ثابت است که به آن جهت امتداد می‌گویند و معادلات درهم کنش امواج مگنتوتلوریک در دو مُد قطبش بررسی می‌شود. زمانی که مؤلفه میدان الکتریکی در جهت امتداد باشد این وضعیت را مُد الکتریکی عرضی (TE) می‌نامند و حالتی که مؤلفه میدان مغناطیسی در جهت امتداد باشد این وضعیت را مُد مغناطیسی عرضی (TM) می‌نامند (شکل ۱). رفتار این دو نوع قطبش در برخورد با ناهمگنیهای جانبی متفاوت است. از مُد TE برای شناسایی ساختارهای ژرف و از مُد TM برای شناسایی ساختارهای کم‌ژرفا استفاده می‌شود. (Moradzadeh, 1998; Berdichevsky et al., 1998)

مدل‌سازی و تفسیر دو بعدی داده‌های فاز و مقاومت ویژه هر مُد می‌تواند به طور جداگانه صورت گیرد ولی برای بهره‌مندی از قابلیت‌های هر دو مُد، مدل‌سازی داده‌های هر دو مُد به صورت ترکیبی (Joint) انجام می‌شود. به همین دلیل در مطالعه حاضر قابلیت مدل‌سازی وارون توسط شبکه عصبی بر روی ترکیب داده‌های هر دو مُد بررسی می‌شود. برای فهم بیشتر چگونگی انجام کار و پیش از پرداختن به طراحی و آموزش شبکه، لازم است ابتدا اصول و مبانی شبکه‌های عصبی مصنوعی و الگوریتم آموزشی شبکه مورد استفاده به طور فشرده مورد بررسی قرار گیرد.

### شبکه پرسپترون (MLP: Multilayer Perceptron) با الگوریتم آموزشی پس انتشار خطا (BP: Back Propagation)

شبکه‌های عصبی مصنوعی، الگوی بسیار ساده‌ای از دستگاه عصبی انسان و دارای قابلیت یادگیری هستند. دستگاه یادگیری آنها مشابه دستگاه یادگیری انسان است. شبکه‌های عصبی مصنوعی با دریافت الگوهای ورودی (Input pattern) قادر به استخراج مشخصات آنها و نسبت دادن یک گروه خاص به آنهاست، به این ترتیب در خلال فرایند آموزش، آنها مشخصات الگوها و گروه مورد نظر را با تطبیق دادن یک سری ضرایب وزنی به خاطر می‌سپرنند. چنانچه آموزش به درستی صورت گیرد آنها قادر به دسته‌بندی (Classification) الگوها هستند (Poulton, 2001).

تمام شبکه‌های عصبی دست کم در سه مؤلفه اصلی مشترک هستند.

۱- نرون یا گره یا واحد پردازش (PE: Processing Element)

۲- وزنه‌های ارتباطی

۳- لایه‌های مجزایی که شامل نرون‌ها هستند و توسط وزنها به هم مرتبط می‌شوند.

در هر نرون حاصلضرب نقطه‌ای بردار ورودی (P) و ماتریس وزنی (W) جمع وزنی (Sum<sub>j</sub>) را تشکیل می‌دهد. جمع وزنی ورودیها در هنگام عبور از یک تابع تحریک (f: Activation function) با آستانه آن (T) مقایسه می‌شود.

$$\rho_{xy} = \rho_{yx} = \rho \quad (2)$$

$$\phi = \pi/4$$

که در آن،  $\rho$  مقاومت ویژه واقعی نیم فضای همگن است. این مقادیر برای ساختارهای یک بعدی ژئوالکتریکی نیز به این صورت محاسبه می‌شود (Telford et al., 1990):

$$\rho_{xy} = \rho_{yx} = \rho_a \quad (3)$$

در این رابطه  $\rho_a$  مقاومت ویژه ظاهری و تابع بسامد است. در چنین ساختاری هنگام عبور از یک محیط مقاوم به یک محیط رسانا مقدار فاز از  $\pi/4$  بالاتر می‌رود و هنگام عبور از یک محیط رسانا به یک محیط مقاوم مقدار فاز از  $\pi/4$  کمتر می‌شود.

به منظور ارزیابی از ژرفای نفوذ امواج الکترومغناطیسی در درون زمین، از معیاری به نام ژرفای پوسته‌ای ( $\delta$ ) (Skin Depth) استفاده می‌شود که مقدار آن برای یک زمین همگن و همسانگرد برابر ژرفایی است که در آن دامنه موج به  $e^{-1}$  مقدارش در سطح زمین کاهش می‌یابد. ارتباط این کمیت با مقاومت ویژه و نفوذ پذیری مغناطیسی زمین و همچنین بسامد امواج نفوذی به صورت زیر است (Vozoff, 1991):

$$\delta = \left( \frac{2}{\omega \mu \sigma} \right)^{1/2} \approx 503 \sqrt{\frac{\rho}{f}} \quad (4)$$

که در آن  $\rho$  مقاومت ویژه زمین بر حسب اهم - متر،  $\mu$  ضریب نفوذ پذیری مغناطیسی زمین بر حسب هانری بر متر،  $f$  بسامد موج بر حسب هرتز و  $\delta$  ژرفای پوست بر حسب متر است. رابطه فوق نشان می‌دهد که در روش مگنتوتلوریک مانند دیگر روشهای اکتشاف الکترومغناطیسی، با کاهش بسامد موج می‌توان به ژرفای بیشتری دست یافت در حالی که با کاهش مقاومت ویژه زمین ژرفای نفوذ اکتشاف کاهش می‌یابد.

از آنجا که رابطه ۴ مقدار ژرفای نفوذ امواج الکترومغناطیسی را فقط برای زمین همگن و همسانگرد بیان می‌کند ولی در عمل ما با زمین ناهمگن و ناهمسانگرد مواجه هستیم بهتر است رابطه فوق برای به دست آوردن ژرفای نفوذ مؤثر اکتشافی (D) مورد بازبینی قرار گیرد. در رابطه زیر مقدار ژرفای نفوذ مؤثری که غالباً در روشهای اکتشافی مگنتوتلوریک مورد استفاده قرار می‌گیرد، بر حسب متر، داده شده است (Zonge & Hughes, 1991):

$$D = \delta / \sqrt{2} = 356 \sqrt{\frac{\rho}{f}} \quad (5)$$

در ساختارهای ژئوالکتریکی دو بعدی خواص الکتریکی به موازات یک جهت



الگوریتم آموزشی پس انتشار خطا یک روش کاهش شیب (Gradient descent) است. ضعف عمده این الگوریتم، سرعت کم همگرایی آن و نیز توقف یادگیری شبکه به دلیل به دام افتادن شبکه در نقاط کمینه محلی (Local minimum) است. در این روش، به دلیل ثابت بودن مقدار آهنگ یادگیری در حین آموزش، عملکرد الگوریتم آموزشی به انتخاب مناسب آهنگ یادگیری بسیار حساس است. از آنجا که پیش از آموزش انتخاب مناسب آهنگ یادگیری عملی نیست، چنانچه ما اجازه تغییر آهنگ یادگیری در خلال فرایند آموزش را بدهیم، عملکرد الگوریتم کاهش شیب می‌تواند توسعه یابد (منهاج، ۱۳۷۹؛ Poulton et al., 1992).

در روش‌های آموزشی سریع تر مانند روش لوبنبرگ-مارکوآرت (Levenberg & Marquardt) که با اعمال تغییراتی در الگوریتم پس انتشار خطا حاصل شده است، آهنگ یادگیری ثابت نیست و در خلال آموزش شبکه تغییر می‌کند. به همین دلیل در این تحقیق از الگوریتم لوبنبرگ-مارکوآرت به عنوان یک روش آموزشی سریع برای مدل‌سازی داده‌های مگنتوتوریک استفاده شد.

### انتخاب کلاس مدل آموزشی

در طراحی یک شبکه، شیوه انتخاب کلاس مدل از اهمیت زیادی در آموزش صحیح آن برخوردار است. در انتخاب کلاس مدل‌های آموزشی باید ضمن ساده‌سازی مدل انتخابی به طبیعت داده‌های صحرائی اندازه‌گیری شده که مدل‌سازی برای آنها صورت می‌گیرد نیز توجه شود. داده‌های صحرائی مورد استفاده در این تحقیق توسط نگارنده اول مقاله در طول نیم‌رخ به طول ۱۲ کیلومتر در استرالیا جنوبی برداشت شد. برداشت داده‌ها در ۹ ایستگاه و ۲۱ بسامد صورت گرفت. در شکل‌های ۳ و ۴ شبه مقاطع مقاومت ویژه و فاز داده‌های حاصل برای دو مُد TE و TM ارائه شده است.

نیم‌رخ مذکور در یک دشت وسیع با توپوگرافی آرام قرار دارد و به همین دلیل از آوردن توپوگرافی مسیر در شبه مقاطع خودداری شده است. نگاهی اجمالی به شبه مقاطع داده شده نشان می‌دهد که دو بی‌هنجاری رسانا با مقاومت ویژه ظاهری حدود ۱۰ اهم - متر و فاز بیش از ۶۰ درجه در طرفین نیم‌رخ وجود دارد که البته بی‌هنجاری سمت راستی از گسترش بیشتری برخوردار است. بنابراین با توجه به اصل ساده‌سازی، کلاس مدل مورد استفاده برای آموزش شبکه عصبی مورد استفاده مطابق شکل ۵ دو بی‌هنجاری رسانا (توده رسانا) مدفون در یک نیم فضای همگن انتخاب شد. علاوه بر آن برای کاهش تعداد پارامترهایی که باید برآورد شود شکل بی‌هنجاریها به صورت مستطیل تقریب شد، شکل بی‌هنجاریهای واقعی، هر چه باشد، می‌توان آنها را در

چنانچه این جمع وزنی از مقدار آستانه فراتر رود نرون فعال می‌شود در غیر این صورت، ناعمال باقی می‌ماند (Melsa, 1989; Poulton et al., 1992). وزنها و مقدار آستانه با توجه به نوع مسئله به گونه‌ای محاسبه می‌شوند و تغییر می‌یابند تا هدف مسئله تأمین گردد. معمولاً شبکه‌ها دارای چند لایه هستند (شکل ۲).

این لایه‌ها عبارتند از لایه ورودی با تعداد نرونهای برابر با تعداد عناصر بردار ورودی، لایه خروجی که خروجی آن خروجی نهایی شبکه می‌باشد و لایه‌های پنهان که بین لایه ورودی و لایه خروجی قرار می‌گیرند، لازم به ذکر است که لایه‌های مختلف می‌توانند توابع تحریک متفاوت داشته باشند. در این تحقیق از یک شبکه پیشخور (Feed Forward) با ناظر با قانون فراگیری پس انتشار خطا استفاده شده است که در آن در هر لایه هر نرون به تمام نرونهای لایه بعدی متصل است (شکل ۲). در شبکه پیشخور، نرونها، ورودی خود را تنها از لایه قبلی دریافت و خروجی خود را تنها به لایه بعدی منتقل می‌کنند (منهاج، ۱۳۷۹؛ Poulton, 2001؛ Poulton et al., 1992). در یک شبکه با ناظر، جهت آموزش شبکه، باید خروجیهای مطلوب (Desired output) (d<sub>pk</sub>) متناظر با هر الگوی ورودی تهیه شوند، در این روش فراگیری، الگوهای خروجی مطلوب با خروجی محاسبه شده توسط شبکه با عنوان خروجی واقعی (Opk) (Actual output)، مقایسه می‌شود و اختلاف بین آنها (ep)، می‌بایست با تغییر وزنها شبکه به کمک رابطه زیر کمینه شود. لازم به ذکر است وزنها اولیه در شبکه به صورت تصادفی هستند.

$$e_p = \frac{1}{2} \sum_{k=1}^L (d_{pk} - o_{pk})^2 \quad (6)$$

خطای  $e_p$  خطای محاسبه شده برای  $p$  امین الگوی ورودی می‌باشد. در یک شبکه با الگوریتم آموزشی پس انتشار خطا ابتدا ورودی شبکه به طور مستقیم در طول شبکه به منظور محاسبه خروجی شبکه جریان می‌یابد. چنانچه مقادیر خروجی شبکه با مقادیر خروجی مطلوب در لایه خروجی متفاوت باشد با استفاده از خطای تعریف شده، مقادیر تغییرات وزن  $\Delta w_{ji}$ ، برای هر ضرب وزنی محاسبه و وزنها با بازگشت این تغییرات در طول شبکه تصحیح می‌شوند. چگونگی تصحیح ضرایب وزنی به صورت زیر است (Turhan, 1995).

$$\Delta w_{ji} = -\alpha \partial e_p / \partial w_{ji} \quad (7)$$

که در آن  $\alpha$  یک کمیت مثبت و ثابت موسوم به آهنگ یادگیری (Learning rate) است که در واقع اندازه گامها را در جهت دستیابی به کمینه خطا تنظیم می‌کند و انتخاب مناسب برای آن جهت عملکرد صحیح روش آموزش حیاتی است.

یک فضای ۹ بعدی است بنابراین پارامترهای مدل‌های تولید شده باید تقریباً این فضای ۹ بعدی را پوشش دهند. جهت تولید نمونه‌های آموزشی، برای هر پارامتر خروجی با تعریف کرانه‌های بالا و پایین یک محدوده معینی در نظر گرفته شده است. هرچه گام‌های حرکت در محدوده‌های تعریف شده کوچک‌تر باشد، داده‌های بیشتری برای تقریب رابطه خروجی بر حسب ورودی فراهم می‌شود.

از آنجا که ابتدا از میزان حساسیت شبکه به داده‌ها اطلاعی در دست نیست، لذا پوشش فضای مدل در مورد تمام پارامترها به طور یکنواخت صورت می‌گیرد. نکته مهم‌تر در تولید نمونه‌های آموزشی، حفظ تباین خوب بین مقاومت ویژه زمینه و بی‌هنجاریها (توده‌ها) با توجه به ابعاد و ژرفای آنها و بسامدهای اندازه‌گیری است. فرض کنید در تولید نمونه‌های آموزشی، پوشش خوب فضای مدل مد نظر قرار گرفته است اما به رغم این موضوع، شبکه ممکن است پس از آموزش به خوبی پاسخ ندهد. علت این امر عدم رعایت تباین مقاومت ویژه بی‌هنجاریها و زمینه با توجه به ژرفای بی‌هنجاریها، پیروی یا بسامد اندازه‌گیری و ابعاد بی‌هنجاریها می‌باشد. مثلاً چنانچه در چندین نمونه آموزشی تولید شده که در آنها بی‌هنجاریهای کوچکی در قسمتهای ژرف زمین قرار گرفته باشند، تباین مقاومت ویژه بسیار ضعیف باشد، داده‌های ثبت شده با توجه به بسامدهای اندازه‌گیری ممکن است حضور بی‌هنجاری را در این نمونه‌ها نشان ندهد. به بیان دیگر مانند این است که شبکه به ازای چندین الگوی ورودی یکسان، الگوهای خروجی کاملاً متفاوت دریافت کند این امر باعث می‌شود که به شبکه یک سری نمونه‌های آموزشی اضافی ارائه شود که هیچ نقشی جز افزایش خطا در شبکه، طی فرایند یادگیری ندارند. این نکته به وضوح پس از آموزش شبکه مشاهده شد که خطا روی مدل‌هایی که تباین مقاومت ویژه ضعیف‌تری داشته‌اند و بی‌هنجاریها از ابعاد کوچک‌تری نیز برخوردار بودند، افزایش یافته است. به همین جهت برای دست‌یابی به خطای کمتر در اختیار داشتن تعداد بیشتری از داده‌های مناسب است.

به هر اندازه تعداد نمونه‌های آموزشی با خروجی متفاوت، اما ورودی نزدیک به هم در بین داده‌ها بیشتر باشد، شبکه دچار خطای بیشتری خواهد شد. بنابراین خطای شبکه در مناطقی از فضای مدل که چگال‌تر است و تباین مقاومت ویژه بهتری دارد، کاهش می‌یابد.

نمونه‌های آموزشی مورد نیاز در این تحقیق به طور مصنوعی توسط نرم افزار EMIXMT2D تولید شده است. این نرم افزار قابلیت مدل‌سازی دو بعدی معکوس و مستقیم داده‌های مگنتوتلوریک برای مدهای TE و TM و با هر دوی آنها با هم را دارد (Stoyer et al., 1999). همان طور که اشاره

یک مستطیل محاط، یا بر یک مستطیل محیط کرد، این ساده‌سازی به عنوان نقطه شروع در بررسی توانمندیهای شبکه عصبی در وارونه‌سازی داده‌های مگنتوتلوریک، مناسب به نظر می‌آید. علاوه بر موارد فوق، برای شبیه‌سازی هر چه بیشتر شرایط صحرائی، طول نیمرخ مورد استفاده در مدل‌های مصنوعی ساخته شده (شکل ۵) همانند طول نیمرخ واقعی ۱۲ کیلومتر با ۹ محل سونداژ مگنتوتلوریک با فاصله ۱۵۰۰ متر در نظر گرفته شده است.

### تعیین پارامترهای ورودی و خروجی شبکه

در طراحی یک شبکه، پارامترهای ورودی و خروجی آن جزو پارامترهای آزاد نیستند و توسط مسئله تعیین می‌شوند. در این بررسی پارامترهای ورودی شبکه، پاسخ زمین به امواج مگنتوتلوریک در حوزه بسامد است که شامل مقاومت ویژه ظاهری و فاز پاگیری برای دو مُد در ایستگاههای مختلف و بسامدهای مورد نظر هستند. پارامترهای خروجی شبکه نیز همان پارامترهای مدل زیر زمینی می‌باشند. مطابق شکل ۵ پارامترهای مدل عبارتند از:

$C = \rho_B / \rho_{An}$  نسبت مقاومت ویژه زمینه به مقاومت ویژه توده (بی‌هنجاری) می‌باشد. با توجه به داده‌های موجود صحرائی (شکل‌های ۳ و ۴) مقاومت ویژه بی‌هنجاریها ثابت و برابر با ۱۰ اهم - متر فرض شده است.

$x_1, z_1$ : مختصات مرکز بی‌هنجاری رسانای سمت چپ

$d_1$ : نصف طول بی‌هنجاری سمت چپ

$d_2$ : نصف عرض بی‌هنجاری سمت چپ

$x_2, z_2$ : مختصات مرکز بی‌هنجاری رسانای سمت راست

$d_3$ : نصف طول بی‌هنجاری سمت راست

$d_4$ : نصف عرض بی‌هنجاری سمت راست

به این ترتیب برای مدل ارائه شده در شکل ۵، شبکه باید برای برآورد ۹ پارامتر فوق آموزش ببیند.

### طراحی و آموزش شبکه

برای آموزش شبکه نمونه‌های آموزشی مورد نیاز است. یک نمونه آموزشی از دو بردار ورودی و خروجی تشکیل می‌شود. بردار ورودی شامل داده‌های مصنوعی تولید شده در ایستگاهها و بسامدهای مختلف و بردار خروجی شامل پارامترهای مدل می‌باشد. تولید نمونه‌های آموزشی با توجه به خروجیهای شبکه (پارامترهای مدل) صورت گرفته است. با توجه به حضور ۹ پارامتر خروجی، وزنها و بایاسهای شبکه باید در خلال فرایند آموزش به گونه‌ای تغییر یابند و اصلاح شوند که مجموع خطای پارامترهای خروجی شبکه کاهش یابد. وجود ۹ پارامتر خروجی در شبکه، معادل با در نظر گرفتن





$$Err_j = \frac{1}{N_{test}} \sum_n \frac{|target_{n,j} - neural_{n,j}|}{target} \times 100\% \quad (9)$$

$$j = 1, \dots, N_{par} \quad n = 1, \dots, N_{test}$$

که در روابط فوق:

(9)  $N_{par}$ : تعداد نرونهای خروجی،  $N_{test}$ : تعداد نمونه‌های آزمایشی،  $max(j), min(j)$  کمترین و بیشترین مقادیر ژامین پارامتر در سری آموزشی  $neural(n,j)$  نتیجه پیش‌بینی شبکه برای ژامین پارامتر در  $n$  امین نمونه آزمایشی و  $target(n,j)$  مقدار هدف برای ژامین پارامتر در  $n$  امین نمونه آزمایشی است.

به دلیل این که وارون‌سازی داده‌ها به عنوان یک مسئله برآورد تابع است در عمل از تابع محرک غیر خطی برای نرونهای لایه پنهان و از تابع خطی برای لایه خروجی استفاده می‌شود (راهنمای نرم‌افزار Matlab 2002؛ Poulton, 2001) در این تحقیق انواع توابع غیر خطی مورد آزمایش قرار گرفت و در عمل از تابع سیگموئیدی لگاریتمی با فرمول  $\text{logsig}(x) = 1/(1+\exp(-x))$  به دلیل ارائه نتایج بهتر استفاده شد.

از آنجا که گستره تغییرات داده‌های مورد بررسی بسیار زیاد است، و از طرفی طبیعت توابع محرک مورد استفاده در اغلب شبکه‌ها نیاز به این دارند که ورودی‌هایشان در یک گستره محدود قرار گیرند، این توابع معمولاً در مقادیر کوچک و بزرگ مسطح می‌شوند و در دنباله‌هایشان دیگر به تغییر مقادیر ورودی حساس نیستند. بنابراین، اغلب به جای استفاده از خود داده‌ها مقادیر بهنجار شده آنها استفاده می‌شود. به کار بردن روشهایی برای قرار دادن داده‌های ورودی در یک گستره محدود بهنجار کردن مقادیر یا دوباره مقیاس‌بندی کردن (Re-scaling) می‌نامند که یکی از روشهای پیش‌پردازش است (Poulton, 2001). از دیگر مزایای قرار دادن ورودیها در یک گستره محدود، جلوگیری از رشد زیاد وزنها می‌باشد. این محدودیت، مدت زمان همگرایی شبکه و حصول کمینه خطا را کاهش می‌دهد. داده‌های خروجی نیز غالباً جهت آموزش دادن به شبکه بهنجار می‌شوند و پیش از تحلیل نتایج به واحدهای اصلی برگردانده می‌شوند. برای بهنجار کردن داده‌های مورد مطالعه روشهای مختلفی مورد امتحان قرار گرفتند که در نهایت استفاده از رابطه زیر برای بهنجار کردن داده‌ها در محدوده [1, -1] نتایج بهتری را ارائه داد.

$$p_n = \frac{2(p - \min p)}{(\max p - \min p)} - 1 \quad (10)$$

که در این رابطه  $p$ : ماتریس ورودی به ابعاد  $R \times Q$ ،  $p_n$ : ماتریس ورودیهای بهنجار شده به ابعاد  $R \times Q$ ،  $\min p$ : بردار  $R \times I$  شامل مقدار کمینه به ازای هر  $p$  و  $\max p$ : بردار  $R \times I$  شامل مقدار بیشینه به ازای هر  $p$  است.

شد به منظور تولید نمونه‌های آموزشی، برای هر پارامتر خروجی با تعریف کرانهای بالا و پایین یک محدوده معینی در نظر گرفته شد و سعی شد تا گامهای حرکت در محدوده‌های تعیین شده برای تمام پارامترها یکنواخت باشد. برای هر یک از مدلها، داده‌ها به صورت مقاومت ویژه ظاهری و فاز در ۹ ایستگاه و ۱۱ بسامد (۱۷/۱۸۷۵، ۵/۶۶۴۱، ۰/۸۳۰، ۰/۳۸۰۹، ۰/۱۴۶۵، ۰/۰۶، ۰/۰۲۱۵، ۰/۰۱۲۲، ۰/۰۰۷۳، ۰/۰۰۳۱، ۰/۰۰۱۸، ۰/۰۰۱۸) هر تری (برای دو مُد TE و TM تولید شدند. با توجه به رابطه  $N=N_{ir}N_{T}N_{S}$  که در آن  $N_{ir}$  تعداد مؤلفه‌های مورد استفاده در وارون‌سازی،  $N_T$  تعداد بسامدها و  $N_S$  تعداد ایستگاههای برداشت می‌باشد، به ازای هر مدل در هر دو مُد در مجموع ۳۹۶ داده تولید شد. هر نمونه آموزشی با حرکت افقی و قائم بی‌هنجاریها نسبت به یکدیگر و تغییر همزمان ابعاد و مقاومت ویژه زمینه تولید شد.

تعداد نمونه‌های آموزشی برای دستیابی به یک دقت خوب و تعمیم‌دهی مناسب، باید بزرگ‌تر از تعداد وزنه‌های داخلی باشد (Van der Bean & Jutten, 2000; Poulton, 2001). بنابراین، یک شبکه بزرگ (مانند شبکه مورد نظر) نیاز به سری آموزشی بزرگی برای ایجاد توازن بین تعداد وزنه‌های ارتباطی و نمونه‌های آموزشی دارد. این شبکه با وجود ۳۹۶ نرون در لایه ورودی و ۹ نرون در لایه خروجی، یک شبکه نسبتاً بزرگ می‌باشد و تولید و به‌کارگیری تعداد زیادی نمونه آموزشی با توجه به امکانات محدود رایانه‌ای در دسترس (PIV-2800MHz) و عدم آگاهی از تعداد وزنه‌های داخلی پیش از آموزش شبکه کار بسیار دشواری است. به همین دلیل از روش دیگری با نام توقف سریع (Early stopping) برای تعمیم‌دهی و تسریع در امر آموزش و طراحی شبکه استفاده شد. در این روش، از تقسیم سری آموزشی به سه دسته آموزشی (Training)، اعتبارسنجی (Validation) و آزمایشی (Testing) استفاده شد. در این تقسیم‌بندی ۲۰ درصد از کل نمونه‌های آموزشی به طور تصادفی برای اعتبارسنجی، ۱۰ درصد برای آزمایش و ۷۰ درصد نیز برای آموزش شبکه انتخاب شد. به منظور بررسی عملکرد شبکه از خطای RMS (Root Mean Squares) تعریف شده به صورت زیر استفاده شد. این خطا روی سری آزمایشی و به ازای تمام پارامترها تعریف شده است (Spichak & Popova, 2000).

$$RMS = \left[ \frac{1}{N_{test} N_{par}} \sum_{n,j} err_{n,j}^2 \right]^{1/2} \quad (8)$$

$$err(n,j) = [target(n,j) - neural(n,j)] / [\max(j) - \min(j)]$$

$$j = 1, \dots, N_{par} \quad n = 1, \dots, N_{test}$$

علاوه بر آن به منظور ارزیابی کیفیت مدل‌سازی داده‌ها توسط شبکه عصبی، برای هر پارامتر مجهول  $z$  ام، میانگین خطای نسبی روی تمام نمونه‌های آزمایشی به صورت زیر محاسبه شد (Spichak & Popova, 2000).

### بحث

همان‌طور که اشاره شد مناسب‌ترین ساختار شبکه طراحی شده برای آموزش ترکیبی و همزمان داده‌های فاز و مقاومت ویژه دو مد قطبش پس از بررسی‌های لازم به صورت شبکه‌ای سه لایه با ساختار ۹-۹-۳۹۶ انتخاب شده است. شبکه طراحی شده فوق در مرحله آزمایش به خطای  $RMS=0.156$  دست یافت.

مقادیر میانگین خطای نسبی محاسبه شده به ازای هر پارامتر برای سری آزمایشی داده‌ها در جدول ۲ درج شده است.

همان‌طور که جدول فوق نشان می‌دهد، کمترین خطای به دست آمده مربوط به پارامتر ششم ( $x_2$ ) و بیشترین خطا مربوط به پارامتر نهم ( $d_p$ ) است. به رغم پوشش یکنواخت فضای مربوط به تمام پارامترها ملاحظه می‌شود که میزان خطا در مورد پارامترهای مختلف، متفاوت است. علت این امر را باید در نحوه یادگیری شبکه جستجو کرد. شبکه با استخراج مشخصه‌های بارز الگوهای ورودی سعی می‌کند با استفاده از الگوریتم آموزشی تعیین شده، رابطه بین این مشخصه‌ها را با پارامترهای خروجی به دست آورد. هر یک از پارامترهای خروجی تابعی از این مشخصه‌ها هستند. تقریب یک تابع برای تمام پارامترها که به وسیله آن بتوان در یک زمان ۹ پارامتر را برآورد کرد، موجب خواهد شد تا تابع تقریب شده توسط شبکه برای برآورد یکی از پارامترها مناسب‌تر از پارامتر دیگر باشد و یا به بیان دیگر میزان حساسیت شبکه به یک پارامتر بیشتر از پارامترهای دیگر باشد.

برای بررسی بهتر عملکرد شبکه، مدل واقعی و مدل برآورد شده توسط شبکه را برای یکی از مدل‌های آزمایشی مورد نظر در شکل ۶ نشان می‌دهیم. در این شکل، مدل واقعی با خط توپر و مدل داده شده توسط شبکه با خط چین نشان داده شده است. مقادیر عددی پارامترهای مدل واقعی و مدل بازسازی شده توسط شبکه نیز در جدول ۳ ارائه شده است. لازم به ذکر است واحد پارامترهای هندسی ارائه شده در همه جدولها، متر است.

با توجه به نتایج مندرج در جدول ۳ و همچنین با توجه به شکل ۶، ملاحظه می‌شود این شبکه از آموزش و تعمیم خوبی برخوردار بوده است به گونه‌ای که با ارائه نمونه‌ای که شبکه آن را در طی فرایند آموزش ندیده است (سری آزمایشی) غیر از محل مرزهای جانبی در بی‌هنجاری (توده) سمت راست، بقیه پارامترها از دقت قابل قبولی برخوردار است. در کل مقدار میانگین خطای نسبی روی تمام پارامترها ۳/۹۹۸ درصد است که این امر حاکی از دقت بالای شبکه در برآورد پارامترهای مدل می‌باشد.

برای بررسی رفتار شبکه در حضور نوفه، مقادیر ۳، ۵ و ۱۰ درصد نوفه با توزیع نرمال و میانگین صفر به طور تصادفی به داده‌های ورودی اضافه شد،

برای بررسی عملکرد و انتخاب برخی از پارامترهای شبکه، ابتدا یک شبکه کوچک‌تر با انتخاب ۳۰ مدل تصادفی از سری آموزشی ایجاد شد. جهت ارائه داده‌های ورودی به شبکه، داده‌های تولید شده به عنوان پاسخ هر مدل، به صورت بردار ستونی در ستونهای یک ماتریس قرار گرفت بنابراین ماتریسی حاصل شد که تعداد ستونهای آن معادل با تعداد مدلها و تعداد سطرها آن برابر با تعداد مؤلفه‌های اندازه‌گیری شده به ازای هر مدل بود.

متناظر با هر بردار ستونی قرار گرفته در ماتریس ورودی، یک بردار ستونی شامل پارامترهای مدل در ماتریس خروجی قرار گرفت، بنابراین پارامترهای مدل نیز تشکیل ماتریسی با تعداد سطرها برابر با تعداد پارامترهای مدل ( $=9$ ) و تعداد ستونهای برابر با تعداد مدل‌های به کار گرفته برای آموزش شبکه، را داد.

برای ارائه تصویر کاملی از زمین، مقادیر مقاومت ویژه ظاهری و فاز پایداری هر یک از مدها که در ۹ ایستگاه (به فواصل 1500 m) و ۱۱ بسامد اندازه‌گیری شده بود، به صورت چهار پارامتر ورودی به ترتیب  $\rho_{xy}$ ،  $\phi_{xy}$ ،  $\rho_{yx}$  و  $\phi_{yx}$  برای مد TE و خود یک بردار ستونی متشکل از  $9 \times 11 = 99$  مؤلفه می‌باشد. بنابراین هر ستون از ماتریس ورودی شامل  $4 \times 99 = 396$  مؤلفه است.

به تدریج تعداد مدل‌های بیشتری به ماتریس ورودی و خروجی اضافه شد، و ملاحظه شد که با افزایش تعداد نمونه‌های آموزشی مناسب به شبکه، دقت برآورد پارامترهای مدل افزایش و شبکه به خطای کمتری دست می‌یابد (جدول ۱).

در نهایت شبکه نسبتاً بزرگی با ماتریس ورودی به ابعاد  $498 \times 396$  و ماتریس خروجی به ابعاد  $9 \times 498$  تشکیل شد. سطح خطای هدف در فضای بهنجار نیز  $0.001$  در نظر گرفته شد.

تعیین تعداد لایه‌ها و نرونهای لایه پنهان به صورت آزمون و خطا انجام شد. ابتدا یک شبکه سه لایه‌ای انتخاب شد و عملکرد شبکه به ازای تعداد مختلف نرونهای پنهان بررسی شد و تعداد ۹ نرون پنهان انتخاب شد. سپس لایه پنهان دیگری به شبکه اضافه شد و در حالی که تعداد نرونهای پنهان در لایه اول ثابت بود عملکرد شبکه به ازای تعداد مختلف نرونهای پنهان در لایه دوم بررسی شد. به این ترتیب شبکه‌ای سه لایه با ساختار ۹-۹-۳۹۶ طراحی شد. این ساختار نشان می‌دهد که تعداد نرونهای موجود در لایه ورودی برابر با تعداد داده‌های موجود در دو مد TE و TM یعنی ۳۹۶ بوده، تعداد نرونهای موجود در لایه میانی (لایه پنهان) ۹ عدد و تعداد نرون در لایه خروجی برابر با تعداد پارامترهای مدل مورد نظر یعنی ۹ است.



می‌شود گستره این تغییرات در اغلب نقاط بین ۸۰۰ تا ۱۰۰۰ اهم - متر است. در صورتی که در هر یک از نمونه‌های آموزشی مورد استفاده در شبکه، مقدار مقاومت ویژه زمینه در حین مدل‌سازی ثابت در نظر گرفته شده است. با این وجود مقدار پارامتر برآورد شده مقاومت ویژه زمینه توسط شبکه ۹۵۴/۸۴ اهم متر می‌باشد که در گستره تعیین شده در مقطع مدل‌سازی هموار قرار دارد، که این امر بیانگر میزان دقت شبکه می‌باشد. از آنجا که اطلاعات اضافی دیگری از منطقه مورد مطالعه موجود نیست از این رو با وضع موجود و بدون اطلاعات اضافی دیگر و یا پیش از حفاری نمی‌توان در مورد صحت نتایج اظهار نظر و یا اینکه تعیین کرد که کدام یک از این دو روش دقیق‌تر است. از آنجا که مدل واقعی زمین بسیار پیچیده‌تر از کلاس مدل در نظر گرفته شده برای مدل‌سازی است، بنابراین چنانچه شکل هندسی مفروض برای بی‌هنجارها به جای مستطیل، بیضی یا چند ضلعی انتخاب شود، شاید بتوان به دلیل نزدیک شدن به مدل واقعی زمین، نتایج بهتری دریافت کرد.

### نتیجه‌گیری

بررسی نتایج به دست آمده روی نمونه‌های آزمایشی نشان می‌دهد که شبکه‌های آموزش داده شده قادر به بازسازی مدل زیر سطحی با دقت قابل قبولی در نبود و یا حضور نوفه هستند. همچنین بررسی و مقایسه نتایج به دست آمده با استفاده از شبکه‌های عصبی برای یک مجموعه داده صحرایی و نتایج حاصل از مدل‌سازی وارون این داده‌ها با استفاده از یکی از روشهای معمول معکوس سازی (RRI) نشان می‌دهد که با وجود انتخاب کلاس ساده‌ای برای داده‌های صحرایی، این دو روش در برآورد بسیاری از پارامترهای مدل زمینی با یکدیگر همخوانی دارند. مزیت اصلی استفاده از شبکه‌های عصبی در وارون‌سازی داده‌ها این است که شبکه یک بار در کلاس خاصی از مسائل آموزش می‌بیند و چنانچه آموزش و تعمیم شبکه به خوبی صورت گیرد، شبکه قادر به برآورد خروجی برای یک ورودی معین در مدت زمان بسیار کوتاه می‌باشد. در این تحقیق به منظور ساده‌سازی مسئله، مقاومت ویژه بی‌هنجارها برابر با هم و ثابت فرض شد، این مورد ممکن است در طبیعت کمتر دیده شود. از این رو ترکیب نمونه‌های آموزشی متنوع‌تر در همین کلاس به منظور توانمندتر کردن شبکه پیشنهاد می‌شود، همچنین در این شبکه تابع تحریک انتخاب شده برای نرونهای هر لایه یکسان فرض شده است این در حالی است که ممکن است انواع دیگری از توابع تحریک برای برآورد هر پارامتر مناسب باشد، از این رو انتخاب و آزمایش تابع تحریکهای متفاوت برای نرونهای مختلف پیشنهاد می‌شود. اگر چه مطالعه حاضر قابلیت خوب شبکه‌های عصبی را برای مدل‌سازی داده‌های مگنتوتلوریک نشان داد

علت اضافه کردن نوفه به داده‌ها، شبیه‌سازی تقریبی شرایط صحرایی و بررسی رفتار شبکه در برابر داده‌های صحرایی است. البته ساختار نوفه تزریقی به داده‌ها بسیار ساده است در حالی که نوفه موجود در طبیعت پیچیده‌تر می‌باشد. از این رو این شبیه‌سازی تقریبی است. بررسیهای انجام شده در مطالعه حاضر نشان می‌دهد که تزریق نوفه روی داده‌ها سبب افزایش خطای مدل‌سازی می‌شود به طوری که با افزایش ۳، ۵، و ۱۰ درصدی نوفه، خطای RMS شبکه به ترتیب ۰/۲، ۰/۲۳ و ۰/۲۹ می‌شود.

از آنجا که در برداشتهای صحرایی، حضور ۵ درصد نوفه در داده‌ها معمول است، از این رو نمونه‌های انتخاب شده برای ارزیابی عملکرد شبکه‌ها در حضور نوفه از نمونه‌هایی انتخاب شد که اول اینکه جزو سری آزمایشی بودند، به بیان دیگر این نمونه‌ها در فرایند آموزش شرکت نداشتند و دوم اینکه ۵ درصد نوفه به آنها اضافه شده بود. جدول ۴ پاسخ شبکه را همراه با مدل واقعی در حضور ۵ درصد نوفه برای یکی از مدل‌های سری آزمایشی نشان می‌دهد.

مقادیر مندرج در جدول ۴ نشان می‌دهند که با وجود ۵ درصد نوفه شبکه توانسته پارامترهای مدل را با دقت قابل قبولی برآورد نماید. این امر با محاسبه میانگین خطای ۶/۹۶ درصدی برای این مدل مشهود است.

به منظور بررسی عملکرد شبکه در برابر داده‌های صحرایی، مدل‌سازی وارون ترکیبی داده‌های مگنتوتلوریک نشان داده شده در شکل‌های ۳ و ۴ توسط شبکه طراحی شده صورت گرفت و نتایج آن در جدول ۵ ارائه شد.

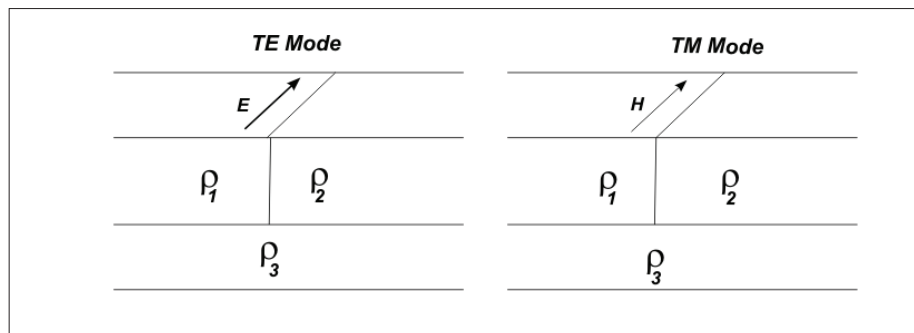
بر اساس مقادیر پارامترهای مندرج در جدول ۵، مدل نشان داده شده در بخش بالایی شکل ۷ بازسازی شد. برای مقایسه، همچنین نتایج مدل‌سازی هموار ترکیبی داده‌های دو مد قطبش که با روش PRI (Rapid Relaxation Inversion) صورت گرفت (Moradzadeh, 1998) در بخش پایینی شکل ۷ نشان داده شده است.

همان‌گونه که در این شکل دیده می‌شود، برآورد مختصات طولی بی‌هنجارها (توده‌ها) توسط شبکه با محل ارائه شده در مقطع مدل‌سازی هموار همخوانی دارد. با توجه به این که مدل‌سازی هموار قادر به برآورد دقیق مرزهای بی‌هنجارها نیست و حدود بی‌هنجارها به صورت هاله مشخص می‌شود، مشاهده می‌شود ابعاد حدودی بی‌هنجارها شامل بعد عرضی بی‌هنجاری سمت چپ، ابعاد طولی و عرضی بی‌هنجاری سمت راست با مقادیر برآورد شده این پارامترها، توسط شبکه همخوانی دارد. ولی ژرفا و بعد طولی بی‌هنجاری سمت چپ با مقادیر برآورد شده توسط شبکه همخوانی کامل ندارد. همچنین روش مدل‌سازی هموار اجازه می‌دهد تا مقاومت ویژه زمینه تغییر تدریجی داشته باشد که با توجه به مقطع ارائه شده در شکل ۷ مشاهده




اینکه با بهره‌گیری از روشهای فشرده‌سازی و یا نمونه‌گیری مجدد از داده‌ها یک شبکه کوچک‌تر که نیاز به سری آموزشی کمتری نیز دارد، ایجاد نمود و بدین طریق کار مدل‌سازی را با شبکه‌های عصبی ساده‌تر کرد. البته فشرده‌سازی اطلاعات باید به گونه‌ای انجام شود که ماهیت داده‌ها از بین نرود، در غیر این صورت نه تنها دقت افزایش نمی‌یابد بلکه به دلیل حذف اطلاعات مهم دقت کاهش می‌یابد. از این رو استفاده از روشهای کاهش اندازه مانند استفاده از تبدیل فوریه پیشنهاد می‌شود.

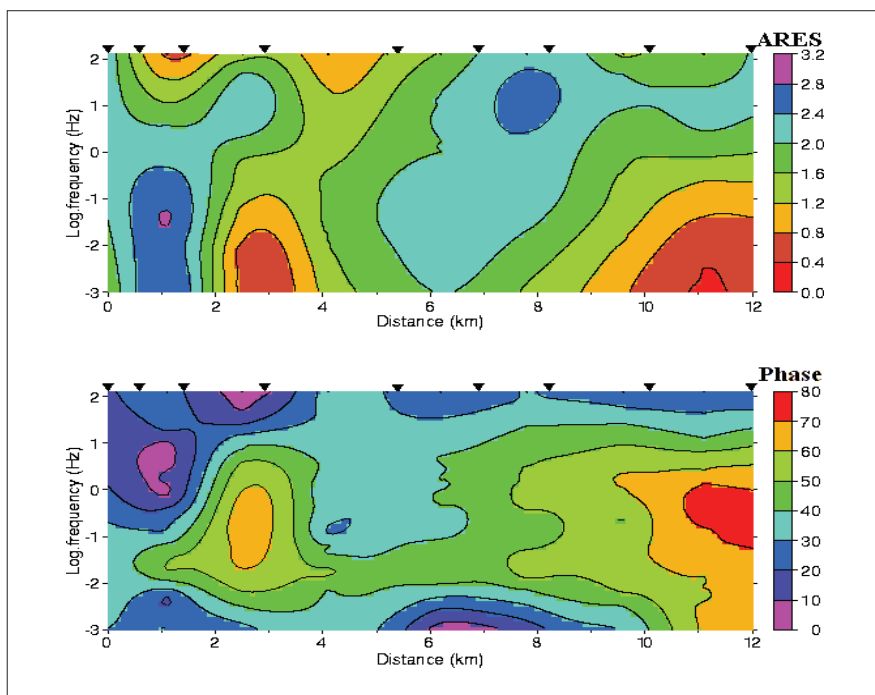
ولی باید توجه کرد که کار با این روش در مواقعی که ساختار مدل زمین مورد مطالعه پیچیده بوده و علاوه بر آن مدل‌سازی همزمان داده‌های دو مد قطبش همراه با داده‌های توپوگرافی باشد انجام مدل‌سازی کار ساده‌ای نخواهد بود. در چنین شرایطی، به دلیل ماهیت پیچیده شرایط زمین‌شناسی حاکم، پارامترهای مدل و یا حتی تعداد داده‌ها زیاد بوده و پردازش آنها از دشواریهای خاصی برخوردار خواهد بود. در این موارد بهتر است از دیگر روشهای مدل‌سازی که بر پایه روشهای کمترین مربعات هموار و یا جستجوی زیر فضایی استوار هستند برای تفسیر داده‌ها استفاده شوند و یا




شکل ۱- نمایش دو مد قطبش در ساختارهای ژئوالکتریکی دو بعدی





شکل ۲- یک شبکه سه لایه‌ای همراه با چگونگی ارتباط نرونها در آن



شکل ۳- شبه مقاطع مقاومت ویژه (بالا) و فاز (پایین) برای داده‌های صحرائی مُد TE، مثلثهای وارون محل ایستگاههای اندازه‌گیری را نشان می‌دهند. در نقشه راهنما لگاریتم مقادیر مقاومت ویژه (بر حسب اهم- متر) و مقادیر فاز به درجه آمده است (Moradzadeh, 2003)

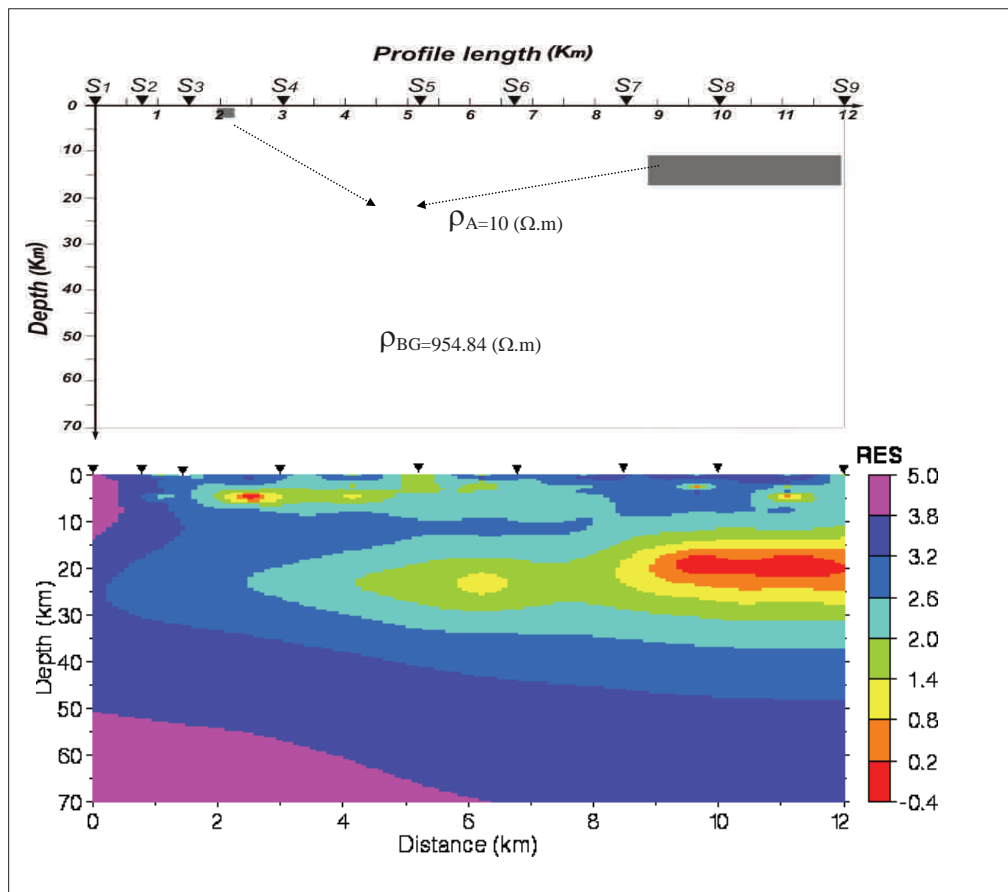


شکل ۴- شبه مقاطع مقاومت ویژه (بالا) و فاز (پایین) برای داده‌های صحرائی مُد TM، مثلثهای وارون محل ایستگاههای اندازه‌گیری را نشان می‌دهند. در نقشه راهنما لگاریتم مقادیر مقاومت ویژه (بر حسب اهم- متر) و مقادیر فاز به درجه آمده است (Moradzadeh, 2003)



شکل ۶- مدل واقعی (خط پر با نسبت  $\rho_{BG}/\rho_A = 50$ ) و مدل تخمینی توسط شبکه (خط چین با نسبت  $\rho_{BG}/\rho_A = 53/95$ )

شکل ۵- شمایی از کلاس مدل انتخاب شده (دو بی‌هنجاری رسانای مدفون در یک نیم فضای همگن) مثلثهای وارون محل ایستگاههای اندازه‌گیری را با فاصله یکسان ۱۵۰۰ متر نشان می‌دهند.



شکل ۷- نتایج مدل‌سازی وارون ترکیبی داده‌های صحرائی شکل ۳ و ۴، مدل داده شده توسط شبکه در بالا و مدل حاصل از روش RRI در پایین شکل آمده است (توجه شود که لگاریتم مقادیر مقاومت ویژه در مدل پایینی آورده شده است).

جدول ۱- تغییرات خطای RMS با افزایش تعداد نمونه‌ها

تعداد کل مجموعه نمونه‌های ارائه شده به شبکه	خطای RMS
۱۲۴	۰/۲۹
۱۵۵	۰/۲۰
۱۸۵	۰/۲۶
۴۹۸	۰/۱۵۶

جدول ۲- مقادیر عددی میانگین خطای نسبی به ازای هر پارامتر

پارامتر	c	x <sub>1</sub>	z <sub>1</sub>	d <sub>1</sub>	d <sub>2</sub>	x <sub>2</sub>	z <sub>2</sub>	d <sub>3</sub>	d <sub>4</sub>
درصد خطا	۱۰/۵۴۶	۱۲/۹۱۷	۱۳/۵۰۷	۱۶/۳۰۷	۱۲/۴۵	۶/۲۲۸	۱۸/۲	۱۰/۸۵۹	۲۰/۷۱۲

جدول ۳- مقادیر عددی پارامترهای واقعی و برآورد شده توسط شبکه برای یکی از نمونه‌های آزمایشی

پارامترهای مدل	مدل واقعی	مدل برآورد شده توسط شبکه
c	۵۰	۵۳/۹۵
x <sub>1</sub>	۲۷۰۰	۲۶۹۱/۸
z <sub>1</sub>	۵۷۰۰	۵۶۶۷/۸
d <sub>1</sub>	۴۰۰	۴۰۷/۹۶
d <sub>2</sub>	۱۲۰۰	۱۰۷۴
x <sub>2</sub>	۱۰۲۵۰	۹۶۵۹/۵
z <sub>2</sub>	۱۳۵۰۰	۱۳۴۴۶
d <sub>3</sub>	۱۴۵۰	۱۳۴۸/۶
d <sub>4</sub>	۴۰۰۰	۴۰۶۲

جدول ۴- مقادیر پارامترهای واقعی و برآورد شده توسط شبکه برای یکی از نمونه‌های آزمایشی در حضور ۵ درصد نوفه

پارامترهای مدل	مدل واقعی	مدل برآورد شده توسط شبکه
c	۵۰	۵۵/۰۵۲
x <sub>1</sub>	۲۷۰۰	۲۶۲۸/۴
z <sub>1</sub>	۵۷۰۰	۵۰۸۱/۶
d <sub>1</sub>	۴۰۰	۴۱۰/۳۶
d <sub>2</sub>	۱۲۰۰	۱۰۶۷/۹
x <sub>2</sub>	۱۰۲۵۰	۹۷۹۴/۴
z <sub>2</sub>	۱۳۵۰۰	۱۲۴۳۴
d <sub>3</sub>	۱۴۵۰	۱۳۴۱/۸
d <sub>4</sub>	۴۰۰۰	۴۲۲۹

جدول ۵- نتایج مدل سازی وارون ترکیبی داده‌های صحرائی توسط شبکه

پارامترهای مدل	پاسخ شبکه
c	۹۵/۴۸۴
x <sub>1</sub>	۲۰۸۹/۱
z <sub>1</sub>	۱۴۸۹/۵
d <sub>1</sub>	۱۲۱/۷۵
d <sub>2</sub>	۸۷۱/۰۱
x <sub>2</sub>	۱۰۴۰۰
z <sub>2</sub>	۱۴۰۲۳
d <sub>3</sub>	۱۵۲۷/۷
d <sub>4</sub>	۳۰۶۴

### کتابنگاری

- مراذزاده، ع.، عرب امیری، ع.، ر.، ۱۳۸۳- مدل سازی معکوس پارامتری داده‌های پلاریزاسیون القایی و مقاومت ویژه اندیس معدنی پاینده. هشتمین همایش انجمن زمین شناسی ایران، شهریور ۸۳، دانشگاه صنعتی شاهرود.
- منهاج، م.ب.، ۱۳۷۹- مبانی شبکه‌های عصبی مصنوعی. جلد اول و دوم، انتشارات دانشگاه صنعتی امیرکبیر.



## References

- Berdichevsky, M.N., Dmitriev, V.I. & Pozdnjakova, E.E., 1998- On two-dimensional interpretation of magnetotelluric soundings. *Geophys. J. Int.*, 133, 585-606.
- Dobrin, M.B. & Sovit, C.H., 1988- Introduction to Geophysical prospecting. McGraw-Hill ,Inc, 868.
- Kaufman, A.A. & Keller, G.V., 1981- The magnetotelluric sounding method. Elsevier, 595.
- Mackie, R.L., Madden, T.R. & Wannamaker, P.E., 1993- Three-dimensional magnetotelluric modelling using difference equations - Theory and comparisons to integral equations. *Geophysics*, 58, 215-226.
- Melsa, P.J.W., 1989- Neural Networks: A Conceptual Overview. Tellabs Research Center.
- Moradzadeh, A., 2003- Static shift appraisal and its correction in magnetotelluric (MT) surveys. The 21<sup>st</sup> symposium on geosciences. Tehran, Iran.
- Moradzadeh, A., 1998- Electrical imaging of the Adelaide geosyncline using magnetotelluric (MT). Ph.D Thesis, Flinders University of south Australia, 334.
- Poulton, M.M., 2001- Computational neural networks for geophysical data processing. PERGAMON, 335.
- Poulton, M.M., Sternberg, B.K. & Glass, C.E., 1992- Location of subsurface targets in geophysical data using neural networks. *Geophysics*, 57, 1534-1544.
- Spichak, V. & Popova, I., 2000- Artificial neural network inversion of magnetotelluric data in terms of three- dimensional earth macroparameters. *Geophys. J. Int.*, 142, 15-26.
- Stoyer, C., Zerelli, A., Slee, C. & Buttler, M.S., 1999- Manual of EMIXMT2D. Interpex.
- Telford, W.M., Geldart, L.P. & Sheriff, R.E., 1990- Applied Geophysics. Cambridge University Press, 770.
- The MathWork, I., 2002- Matlab user manual, The language of technical computing.
- Turhan, M., 1995- Neural networks and computation of neural network weights and biases generalized delta rule and backpropagation of errors. [http://www.discoby.com/pdf/neural\\_network](http://www.discoby.com/pdf/neural_network).
- Van der Bean, M. & Jutten, C., 2000- Neural networks in geophysical applications. *Geophysics*, 65, 1032-1047.
- Vozoff, K., 1991- The magnetotelluric method. In: Nabighian, M.N. (Ed), *Electromagnetic Method In Applied Geophysics*. Society of Exploration Geophysicist, 641-712.
- Wannamaker, P.E., Stodt, J.A. & Rijo, L., 1987- A stable finite element solution for two-dimensional magnetotelluric modelling. *Geophys. J. R. astr. Soc.*, 88, 277-296.
- Zonge, K.L. & Hughes, L.J., 1991- Control source audio-frequency magnetotellurics. In: Nabighian, M.N. (Ed), *Electromagnetic Methods In Applied Geophysics*. Society of Exploration Geophysicists, 713-809.