

doi: 10.11720/wtyht.2023.1547

游希然,张继锋,石宇.基于人工神经网络的瞬变电磁成像方法[J].物探与化探,2023,47(5):1206-1214. <http://doi.org/10.11720/wtyht.2023.1547>

You X R, Zhang J F, Shi Y. Artificial neural network-based transient electromagnetic imaging[J]. Geophysical and Geochemical Exploration, 2023, 47(5):1206-1214. <http://doi.org/10.11720/wtyht.2023.1547>

基于人工神经网络的瞬变电磁成像方法

游希然¹,张继锋^{1,2,3},石宇¹

(1. 长安大学 地质工程与测绘学院, 陕西 西安 710054; 2. 海洋油气勘探国家工程研究中心, 北京 100028; 3. 长安大学 地球物理场多参数综合模拟实验室, 陕西 西安 710054)

摘要:瞬变电磁法(transient electromagnetic method, TEM)目前常用的解释方法是采用全区视电阻率参数,其涉及的公式复杂,迭代过程繁琐耗时。本文分析 TEM 数据特征,引入人工神经网络(ANN),实现了瞬变电磁拟电阻率成像。设计多隐层 BP 神经网络,利用瞬变电磁解析方法计算出响应幅值,作为拟电阻率的映射参数参与网络训练,再使用训练集外的新数据来测试训练后的网络。构建了均匀半空间、一维层状模型,验证神经网络的正确性和适应性,对三维地电模型进行了成像。结果表明:神经网络计算的拟电阻率能够反映出地电模型的目标体异常,网络成像结果准确度较高。最后,利用神经网络算法处理实测数据,进一步说明神经网络成像可以作为资料解释的依据。该研究证明了人工神经网络在瞬变电磁成像上的可行性,为瞬变电磁成像提供了一种新的思路。

关键词:瞬变电磁成像;人工神经网络;拟电阻率

中图分类号: P631

文献标识码: A

文章编号: 1000-8918(2023)05-1206-09

0 引言

瞬变电磁法是地球物理探测领域中重要的勘探方法之一^[1],广泛应用于油气勘探、矿产勘查、工程勘查、环境调查、考古探测、军事探测等诸多方面^[2]。作为一种时间域电磁探测方法,瞬变电磁解释一般是将接收到的电磁响应转化为视电阻率、视深度等能够表征地下电性分布的参数,以视电阻率拟断面图形象地描述地下介质的电性特征,为后续解释工作提供依据。

瞬变电磁成像作为定性解释的基础,一直是瞬变电磁的研究热点之一。Fullagar^[3]提出了均匀半空间下基于对水平地层最大趋肤深度的近似成像理论,陈本池等^[4]提出了拟波动方程偏移成像方法,之后众多学者在该方法的基础上进行了优化和改进。Fullagar 等^[5]提出了 Emax 电导率—深度转换方法,该方法具有较好的适用性。严良俊等^[6]将全

区视电阻率计算方法用于瞬变电磁快速成像,并对中心回线装置的快速成像方法进行了研究。郭文波等^[7]借鉴地震解释方法,提出了将电磁衰减信号转换成拟地震子波的成像方法。Nekut^[8]提出了瞬变电磁数据近似成像方法,研究了成像中的电导率取值问题,提出了中心回线装置数据的近似成像方法。陈小红等^[9]提出了利用快速一阶与二阶近似成像算法改进的快速成像方法。樊亚楠等^[10]将地震勘探中的 Born 近似算法用于瞬变电磁成像计算中。

近年来随着机器学习的再度火热,将人工神经网络应用于地球物理方法中是目前热门方向之一。Spichak 等^[11]使用人工神经网络对可控音频大地电磁数据进行研究。Singh 等^[12]利用人工神经网络进行了垂直电阻率测深的反演,最后得出的结论是只能在非常有限的模型参数下进行信息提取。谢林涛^[13]基于瞬变电磁一维正演理论,将神经网络与视电阻率快速成像方法相结合进行了研究。朱凯光等^[14]将人工神经网络用于航空瞬变电磁数据简单

收稿日期: 2022-11-08; 修回日期: 2023-03-02

基金项目: 国家自然科学基金(42174168); 陕西自然科学基金(2021JM-159); 长安大学中央高校基本科研业务费专项资金(300102262201)

第一作者: 游希然(1999-),男,硕士研究生,主要从事地球物理瞬变电磁法反演研究工作。Email: chdyxr@163.com

通讯作者: 张继锋(1978-),男,教授,主要从事电磁法理论及正反演研究工作。Email: zjf0201@126.com

两层反演。李栋^[15]将神经网络应用于航空瞬变电磁成像,获得了一定的应用效果。Noh 等^[16]使用神经网络进行了航空瞬变电磁数据的视电阻率成像的研究。吴国培等^[17]利用神经网络进行瞬变电磁中心回线装置的视电阻率计算,结果表明神经网络可以进行视电阻率的快速计算。

相比传统成像方法,人工神经网络利用学习的特点有效避免了复杂解析公式的推导和数值算法计算过程中的迭代过程,但对样本的选择及网络训练的要求十分高。因此,使用神经网络进行成像是一种区别于常规成像方法的新思路。本文通过半空间模型、一维层状模型和三维模型的处理结果依次验证神经网络的效果;通过神经网络对实测数据进行处理,取得了较好的解释结果。

1 方法原理

1.1 数据准备

瞬变电磁法属于时间域电磁法,因此本文使用的训练数据包括时间和感应电动势两部分。利用一维正演算法生成一系列时间—感应电动势数据,计算出对应的视电阻率,将视电阻率作为训练样本的期望输出。要使得训练样本能够满足神经网络的需求,需要对数据进行转换和归一化处理。

由于 TEM 数据中的时间、感应电动势和视电阻率之间的数量级具有一定差异,为使网络能够成功拟合数据间的关系,需要进行数据转换。本文将感应电动势转化为响应幅值 $\alpha^{[15]}$,表达式如式(1)所示:

$$\alpha_i = \sqrt{V_i^2 + V_{i+k}^2}, \tag{1}$$

其中: α_i 为第 i 道的响应幅值; V_i 和 V_{i+k} 分别为第 i 道和第 $i+k$ 道的感应电动势, k 为道差。这样得到的响应幅值在数量级上与时间一致。将时间、响应幅值和视电阻率同时对数化,使 3 种数据数量级统一。

数据的归一化处理是机器学习中常见的数据挖掘工作,将数据限制在某一范围内,以增加数据指标间的可比性。本文所使用的归一化法则为 Minmax 法则^[18],其运算关系式为:

$$y = \frac{(y_{\max} - y_{\min}) \cdot (x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min}, \tag{2}$$

式中: x 为初始数据序列; y 为归一化后的数据序列; $x_{\max}$ 与 $x_{\min}$ 分别为初始数据中的最大值和最小值;

$y_{\max}$ 与 $y_{\min}$ 分别为设定的期望归一化区间的最大值和最小值, $y_{\max}$ 与 $y_{\min}$ 之间要求不包括 0 值,即 $y_{\max}$ 与 $y_{\min}$ 保持同号。本文所设置的期望区间为 $[0.1, 0.9]$,通过上式的运算,可以将样本数据大小全部控制在期望区间内。

为了保证神经网络的训练效果,本文通过正演得到了由 101 000 组数据构成的训练集,具体参数如表 1 所示。

表 1 训练数据参数
Table 1 Parameters of training data

发射电流/A	发射半径/m	采样时间/s	电阻率范围/(Ω·m)	时间道数
20	1.8	$10^{-6} \sim 10^{-1}$	1~1000	101

1.2 神经网络原理

人工神经网络是从信息处理的角度对人脑神经网络进行抽象,建立某种模型,按不同的连接方式组成的网络^[19],通过学习得到输入向量与输出结果之间的函数映射关系。其中最著名网络模型是 BP 神经网络,其学习规则由 Rumelhart 和 McClland 等领导的研究小组首次提出,至今仍被广泛使用。

BP 算法规定神经网络的训练过程分为信号的正向传播和误差的反向传播。在正向传播中,训练样本从输入层传入网络,经各层隐含层逐层处理后到达输出层,若输出层的实际输出与期望输出的误差达到要求,则训练结束;否则,进入反向传播过程。反向传播是将输出误差以某种形式向隐含层逐层反传,将误差分摊给各层神经元,根据一定的规则来修正各神经元的权值。以上过程在网络训练中周而复始的进行,直到输出误差减小到可以接受的范围为止,或者设置其他条件来限制训练时长。

以 3 层网络为例,图 1 为 BP 神经网络的结构示意图,包含输入层、隐含层和输出层。输入层由 n 个神经元组成,输入数据由 x_i 表示;隐含层由 q 个神




图 1 三层 BP 神经网络结构

Fig. 1 Structure diagram of the three-layer BP neural network

经元组成, z_k 表示隐含层的输出;输出层由 m 个神经元组成,输出数据由 y_j 表示;用 v_{ki} 表示输入层到隐含层的连接权值,用 w_{jk} 表示隐含层到输出层的连接权值。

其中,隐含层的输入和输出的表达式为:

$$\begin{cases} S_k = \sum_{i=0}^n v_{ik} \cdot x_i, \\ z_k = f(S_k). \end{cases} \quad (3)$$

输出层的输入和输出可以表示为:

$$\begin{cases} S_j = \sum_{k=0}^q w_{jk} \cdot z_k, \\ y_j = f(S_j). \end{cases} \quad (4)$$

其中: $f(\cdot)$ 为节点的激活函数。在神经网络的某一次训练过程中,输出误差为:

$$E = \frac{1}{2} \sum_{j=0}^{m-1} (\lg y_j - \lg d_j)^2, \quad (5)$$

其中: d_j 为期望输出。对于任意神经元的连接权值

w_{jk} ,其修正量应使输出误差 E 减小,相应权值修正方法如式(6)所示:

$$\begin{cases} \delta_{zk} = (\sum_{j=1}^m \delta_{yj} w_{jk}) f'_z(S_k), \\ \Delta v_{ki} = \alpha [\sum_{j=1}^m \delta_{yj} w_{jk} f'_z(S_k)] x_i. \end{cases} \quad (6)$$

其中: α 为学习率,也叫作步长; δ 为误差信号项; S 为隐含层净输入。

采用以上算法训练的网络可以根据电磁响应预测出电阻率值,虽然这种方法拟合的电阻率曲线不能等价于模型或地层的真实电阻率曲线,但能够客观描述地电分布规律,因此这种预测得到的电阻率值被称为拟电阻率^[20]。

本文以 BP 神经网络为基础,建立了用于计算瞬变电磁拟电阻率的双隐层神经网络,其结构如图 2 所示。




图 2 瞬变电磁拟电阻率成像神经网络结构

Fig. 2 Structural diagram of neural network with transient electromagnetic pseudo resistivity

图 2 中, w 代表权值; b 代表误差因子,网络训练需不断地更改并保存 w 和 b ; t 为时间数据; α 为响应幅值; f 为激活函数,其中 f_1 为 Sigmoid 函数, f_2 为 Tanh 函数, f_3 为 Purelin 函数; ρ 为神经网络拟电阻率。

另外,本文选择 Levenberg-Marquardt 算法作为神经网络的训练算法,因其具有极快的收敛速度,适合中大型神经网络,因此适用于处理瞬变电磁数据。通过试凑法逐渐增加隐含层节点的数量,并与上一次网络的预测性能进行对比,最终确定隐含层神经元数量分别为 8 和 2,输出层神经元数量为 1。对于双层结构的网络来说,学习率设置在 0.01~0.001 内为宜,经对比测试,选择将学习率设置为 0.005,兼顾训练速度和效果。为防止训练出现过度拟合,选择输出误差、训练次数和误差梯度作为限制条件,其中最大训练次数为 10 000 次,目标误差为 10^{-6} ,最小误差梯度为 10^{-10} 。

在设置完以上参数后,让网络对训练集进行不

断学习,直到满足预期效果,训练停止后保存各神经元参数,之后即可用新数据来测试网络。

2 模型计算

为测试网络性能,本文设计了多种一维层状地电模型和三维地电模型,将正演计算的接收数据(时间 t 和感应电动势 V) 经预处理后输入网络,计算出拟电阻率,绘图分析网络输出的效果。其中,一维模型的发射参数均与训练集数据的发射参数一致(如表 1 所示),发射电流为 20 A,发射半径 1.8 m。

2.1 均匀半空间模型

均匀半空间模型是最基础的地电模型之一,设计了 3 种不同参数的半空间模型,模型的电阻率分别为 10、100、1 000 $\Omega \cdot \text{m}$,采样时间为 $10^{-6} \sim 10^{-1} \text{ s}$,时间道数 40 道。经网络计算后绘制出电阻率—时间曲线,如图 3 所示,其中黑色直线为模型的真电阻率。




图 3 不同参数的均匀半空间模型计算结果

Fig. 3 Calculation results of uniform half space model with different parameters

采用平均相对误差 E 和拟合优度 R 来作为神经网络的拟合效果的衡量指标,原理如式(7)和式(8)所示。

$$E = \frac{1}{n} \sum \left| \frac{(\rho_{1i} - \rho_{0i})}{\rho_{0i}} \right| \times 100\%, \quad (7)$$

$$R = 1 - \sqrt{\frac{\sum (\rho_{1i} - \rho_{0i})^2}{\sum \rho_{0i}^2}}, \quad (8)$$

其中: n 为时间道数; ρ_1 为神经网络拟电阻率; ρ_0 为模型的真电阻率; R 越接近于 1 说明两组数据相似程度越高,神经网络拟合效果越好。3 个模型的衡量指标如表 2 所示。

表 2 半空间模型衡量指标

Table 2 Measurement index of half-space model				
模型	$\rho/(\Omega \cdot \text{m})$	平均相对误差 $E/\%$	拟合优度 R	时间道数
a	10	2.15	0.9997	40
b	100	1.90	0.9998	40
c	1000	1.97	0.9998	40

对比图 3 进行讨论,半空间模型的电阻率不会随深度变化,拟电阻率的趋势与真实值基本吻合,曲线趋于稳定的直线。在 a 和 c 模型中曲线存在波动,b 模型中拟合效果最好。经测试发现,模型电阻

率在接近训练集边界值时(正演数据的范围是 $1 \sim 1\,000\,\Omega \cdot \text{m}$),拟电阻率曲线都会出现一定程度的波动,尤其是计算低阻模型时(一般小于 $100\,\Omega \cdot \text{m}$),网络拟合效果较差;对于高阻模型,拟电阻率曲线更加接近真实模型,并且比较稳定。

对于半空间模型,神经网络在误差范围内能够很好地反映模型真电阻率的变化。

2.2 一维模型

首先研究的是二层模型,本文设计了 2 种典型的水平二层模型,分别为 G 型模型和 D 型模型,模型参数如表 3 所示,时间道数为 101 道。经神经网络计算绘制出拟电阻率—深度曲线,如图 4 所示,网络拟合的衡量指标如表 4 所示。

对于二层模型,神经网络拟电阻率曲线的变化符合模型真电阻率的变化趋势,曲线在地层突变处出现骤增或骤降,数值上与真电阻率接近,网络对于 D 型模型的拟合效果相比 G 型模型而言要更好一些。因此,神经网络能够拟合二层模型的电阻率变化。

表 3 二层模型参数

Table 3 Parameters of two-layer model					
模型	层厚/m	$\rho/(\Omega \cdot \text{m})$	模型	层厚/m $\rho/(\Omega \cdot \text{m})$	
G 型	50	10	D 型	50	100
	Inf	100		Inf	10




图 4 二层模型计算结果

Fig. 4 Calculation results of two-layer mode

表 4 二层模型衡量指标

Table 4 Measurement index of the two-layer model				
模型	$\rho/(\Omega \cdot \text{m})$	平均相对误差 $E/\%$	拟合优度 R	时间道数
G 型	10–100	10.79	0.9734	101
D 型	100–10	7.30	0.9923	101

接下来是对三层模型的研究,本文选择了 4 种经典三层地电模型,分别为 H 型、K 型、A 型和 Q 型,具体模型参数及模型衡量指标如表 5、表 6 所示,神经网络的计算结果如图 5 所示。

表 5 三层模型参数

Table 5 Parameters of three-layer model					
模型	层厚/m	$\rho/(\Omega \cdot \text{m})$	模型	层厚/m	$\rho/(\Omega \cdot \text{m})$
H 型	50	100	K 型	50	10
	100	10		100	100
	Inf	100		Inf	10
模型	层厚/m	$\rho/(\Omega \cdot \text{m})$	模型	层厚/m	$\rho/(\Omega \cdot \text{m})$
A 型	50	10	Q 型	50	500
	100	100		100	100
	Inf	500		Inf	10




图 5 三层模型计算结果

Fig. 5 Calculation results of the three-layer model

表 6 三层模型衡量指标

Table 6 Measurement index of the three-layer model				
模型	$\rho/(\Omega \cdot \text{m})$	平均相对误差 $E/\%$	拟合优度 R	时间道数
H 型	100–10–100	20.18	0.9790	101
K 型	10–100–10	17.22	0.9488	101
A 型	10–100–500	25.78	0.8054	101
Q 型	500–100–10	20.21	0.9764	101

如图 5 所示,拟电阻率曲线能够表现出模型电阻率随深度变化的趋势,对于 H 型模型(图 5a),曲线在地层边界处分别有 2 次转折,符合模型设定。对于 K 型模型(图 5b),曲线在模型第二层处有起伏,但因瞬变电磁法对低阻敏感,导致幅值较小,该情况符合理论常识,因此该模型的拟合效果最好。对于 A 型模型(图 5c),该模型的电阻率随深度而不断增高,电阻率范围跨度较大,而曲线符合电阻率递增趋势,但对第二层边界的识别度较低,因此误差相

对较大。对于 Q 型模型(图 5d),曲线符合电阻率 2 次下降趋势,突变处与地层边界接近,因此误差较小。

综上所述,对于一维层状模型而言,拟电阻率曲线符合模型电阻率随深度的变化,神经网络拟合效果符合正演结果。

2.3 三维模型

为进一步验证神经网络适用性,本文设计了三维半空间模型对网络进行测试。设置地下介质的电阻率背景值为 $1\,000\,\Omega \cdot \text{m}$,埋藏有 2 个低阻异常,异常体均为正方体。1 号异常体的棱长为 30 m,顶部埋深为 50 m,左端点水平位置为 20 m,电阻率为 $300\,\Omega \cdot \text{m}$,如图 6 中红色立方体;2 号异常体的棱长为 10 m,顶部埋深为 10 m,左端点水平位置为 110 m,电阻率设置为 $200\,\Omega \cdot \text{m}$,如图 6 中蓝色立方体。两个异常体在同一平面上,该平面与地表的交线即

为测线,共 20 个测点,点距为 7 m,采用中心回线装置,发射线圈为长方形线框,边长为 4 m,采样时间为 $10^{-6} \sim 10^{-2}$ s,发射电流为 20 A,时间道数为 40 道。神经网络计算结果如图 7 所示。




图 6 三维模型示意

Fig. 6 Diagram of 3D model




图 7 三维模型计算结果

Fig. 7 Calculation results of 3D model

图 7 为神经网络拟电阻率剖面,该剖面位于测线正下方,为 2 个异常体所在平面,图中白框标注的是模型中 2 个异常体所在位置。剖面中能清晰地分辨出 2 个低阻异常范围,根据色标判断异常体电阻率的大小分别为 $300 \Omega \cdot \text{m}$ 和 $280 \Omega \cdot \text{m}$ 。异常范围与模型真实位置(白框所示)基本吻合,成像效果较好。

二号异常体的拟电阻率与真电阻率并不完全一致,原因是模型与正演训练数据的接收参数有差异,因此计算结果之间存在一定倍数关系,可根据线框的面积与电流的差计算出一个比例系数来矫正,若只需定性解释则无需矫正。

以上结果足够说明,神经网络能够适用于三维模型数据,模型计算结果符合预期,可以反映出异常体在均匀半空间介质中的分布状况。

3 实测数据处理

为验证神经网络应用于实际资料处理的可行性,检验对实测数据的处理能力,本文选用西安某地管道探测工作采集的数据进行神经网络成像研究。本次工作目的是探测漏水管道位置,目标探测深度为 8 m 以内。测区共布设了 11 条测线(如图 8),选择靠近异常的 L7~L11 号测线进行处理,测线长度 10 m,每条测线 10 个测点(编号从 7 开始),点距 1 m。测量采用重叠回线装置进行采集,发射线框边长 1 m,线圈数为 10 匝,接收线框边长为 1m,20 匝线圈,发射电流为 3.2 A,发射频率 25 Hz,时间道数 40 道。



图 8 测线位置

Fig. 8 Survey line location map

在采集到原始数据后,首先对数据进行去噪、滤波等处理,在一定程度上提高信噪比。将处理后的数据进行数据转换,然后分批输入网络进行计算,得到拟电阻率,绘制出拟电阻率剖面,如图 9 所示。由于实测数据存在互感的影响,直接用拟电阻率成像效果不尽人意,因此实际工作中需要去除背景突出异常。

这里采用计算剩余电阻率的方式进行处理,该方法是利用不同点位电阻率的相对大小来突出异常。在实际工作中,由于每条测线第一个测点离异常体较远,因此可将其计算值视为背景值,将后续测点的计算值统一减去该背景,得到一个相对电阻率值。将该值与时深转换后的深度一起输出为电阻率剖面,如图 10 所示,经过处理后的剖面可以很好地反应异常范围。

由图 10 所示,L7 号测线的 15 号测点下方存在一部分低阻区域,从 L9 号之后的测线剖面出现了 2 个非常明显的低阻区域,分别位于 11~12 号、15~16 号测点之间。可以看出随着测线的切换异常范围越来越大,最终在 L11 号测线的剖面图上形成了 2 个圆形异常区域,因此推测测区存在 2 个低阻异常,靠近 L10~L11 号测线,异常分别在 11~12 号测点与 15~16 号测点下方,埋深在 5~6 m。

通过实地验证可以得知左侧低阻异常为管线导致,右侧低阻异常为隧道外侧钢筋结构,依次贯穿 5 条测线,与解释结果符合。由于管道异常从 8 号测线开始出现,因此还能推测管道漏水范围延伸至此。

因此根据以上处理结果,可以验证神经网络在瞬变电磁实测数据成像中的可行性,能用于实际工作中寻找异常体的位置。

4 结论

本文基于人工神经网络基本原理,构建了用于瞬变电磁拟电阻率成像的双隐层 BP 神经网络,对网络性能进行测试,择优选择网络参数。设计了均匀半空间模型、一维层状模型和三维模型来测试网络。结果表明,神经网络拟电阻率能够正确反映上述模型的电性变化,突显模型中的异常范围。通过对实测资料的处理,验证了神经网络用于实测数据资料处理的可行性,解释结果与实际情况吻合,可作为瞬变电磁快速成像方法进行资料的处理和解释。神经网络对数据的要求较为苛刻,由于噪声和互感对于结果的影响,实际数据常常需要进行预处理和噪声的压制等才能取得较好成像效果。综上所述,




图 9 实测数据计算结果

Fig. 9 Calculation results of measured data




图 10 去除背景值后的剖面

Fig. 10 Profile after removing background value

本文验证了利用人工神经网络进行瞬变电磁成像的可行性和有效性,为瞬变电磁资料的处理提供了一种区别于传统成像的新方法。

参考文献 (References) :

[1] 牛之琰. 时间域电磁法原理[M]. 长沙:中南工业大学出版社, 1992.
Niu Z L. Principle of time domain electromagnetic method [M]. Changsha: Central South Polytechnic University Press, 1992.
[2] 吕国印. 瞬变电磁法的现状与发展趋势[J]. 物探化探计算技

术, 2007, 10(S1): 111-115, 10.
Lyu G Y. Current status and development trend of transient EM method [J]. Computing Techniques for Geophysical and Geochemical Exploration, 2007, 10(S1): 111-115, 10.
[3] Fullagar P K. Generation of conductivity-depth pseudo-sections from coincident loop and in-Loop TEM data [J]. Australian Society of Exploration Geophysicists (ASEG), 1989, 20(1/2): 43-45.
[4] 陈本池, 牟永光, 孙吉定. 瞬变电磁法资料的快速反演成像技术与软件[J]. 物探与化探, 2000, 24(5): 377-382, 386.
Chen B C, Mou Y G, Sun J D. Fast inversing imaging technique and softwares for data of transient electromagnetic method [J]. Geophysical and Geochemical Exploration, 2000, 24(5): 377-382, 386.
[5] Fullagar P K, Reid J E. Emax conductivity-depth transformation of airborne TEM data [J]. ASEG Extended Abstracts, 2001(1): 1-4.
[6] 严良俊, 徐世浙, 胡文宝, 等. 中心回线瞬变电磁测深法快速电阻率成像方法及应用[J]. 煤田地质与勘探, 2002, 30(6): 58-61.
Yan L J, Xu S Z, Hu W B, et al. A rapid resistivity imaging method for central loop transient electromagnetic sounding and its application [J]. Coal Geology & Exploration, 2002, 30(6): 58-61.
[7] 郭文波, 李貅, 薛国强, 等. 瞬变电磁快速成像解释系统研究[J]. 地球物理学报, 2005, 48(6): 187-192.
Guo W B, Li X, Xue G Q, et al. A study of the interpretation system for TEM tomography [J]. Chinese Journal of Geophysics, 2005, 48(6): 187-192.
[8] Nektu A G. Direct inversion of time-domain electromagnetic data [J]. Society of Exploration Geophysicists, 2012, 52(10): 1431-1435.
[9] 陈小红, 段奶军. 时间域航空电磁快速成像研究[J]. 地球物理学进展, 2012, 27(5): 2123-2127.
Chen X H, Duan N J. Study on fast imaging of airborne time-domain electromagnetic data [J]. Progress in Geophysics, 2012, 27(5): 2123-2127.
[10] 樊亚楠, 李貅, 戚志鹏, 等. 瞬变电磁虚拟波场 Born 近似算法研究[J]. 地球物理学进展, 2019, 34(2): 529-536.
Fan Y N, Li X, Qi Z P, et al. Study on Born approximation algorithm of TEM pseudo wave-field [J]. Progress in Geophysics, 2019, 34(2): 529-536.
[11] Spichak V, Fukuoka K, Kobayashi T, et al. ANN reconstruction of geoelectrical parameters of the Minou fault zone by scalar CSAMT data [J]. Journal of Applied Geophysics, 2002, 49(1): 75-90.
[12] Singh U K, Tiwari R K, Singh S B. One-dimensional inversion of geo-electrical resistivity sounding data using artificial neural networks—A case study [J]. Computers and Geosciences, 2005, 31(1): 99-108.
[13] 谢林涛. 瞬变电磁快速成像方法的研究[D]. 重庆: 重庆大学, 2009.
Xie L T. Research on fast inversing imaging method for transient electromagnetic method [D]. Chongqing: Chongqing University, 2009.
[14] 朱凯光, 马铭遥, 车宏伟, 等. 基于主成分的时间域航空电磁数

据神经网络反演仿真研究[J]. *Applied Geophysics*, 2012, 9(1):1-8, 114.

Zhu K G , Ma M Y , Che H W , et al. 2012. PC-based artificial neural network inversion for airborne time-domain electromagnetic data [J]. *Applied Geophysics*, 2012, 9(1):1-8, 114.

[15] 李栋. 基于人工神经网络的航空瞬变电磁拟电阻率成像方法研究[D]. 西安:长安大学, 2019.

Li D. Study on airborne transient electromagnetic quasi-resistivity imaging method based on artificial neural network [D]. Xi'an: Chang'an University, 2019.

[16] Noh K, Yoon D, Byun J. Imaging subsurface resistivity structure from airborne electromagnetic induction data using deep neural network [J]. *Exploration Geophysics*, 2020, 51(2), 214-220.

[17] 吴国培, 张莹莹, 张博文, 等. 基于深度学习的中心回线瞬变电磁全区视电阻率计算[J]. *物探与化探*, 2021, 45(3):750-757.

Wu G P, Zhang Y Y, Zhang B W, et al. The calculation of full-region apparent resistivity of central loop TEM based on deep learning [J]. *Geophysical and Geochemical Exploration*, 2021, 45(3):750-757.

[18] 白旸. 基于小波神经网络的航空瞬变电磁成像方法研究[D]. 西安:长安大学, 2021.

Bai Y. Study on airborne transient electromagnetic imaging method based on wavelet artificial neural network [D]. Xi'an: Chang'an University, 2021.

[19] 万永革, 李鸿吉. 人工神经网络在地球物理中的应用综述[J]. *国际地震动态*, 1995(1):9-14.

Wan Y G, Li H J. An overview of the application of artificial neural network in geophysics[J]. *Recent Developments in World Seismology*, 1995(1):9-14.

[20] 杨振峰, 田仁飞, 肖学, 等. 拟电阻率重构在岩性油藏油层识别中的应用[J]. *科学技术与工程*, 2014, 14(7):117-120.

Yang Z F, Tian R F, Xiao X, et al. The application pseudo-resistivity reconstruction to identify oil layers in lithologic reservoir[J]. *Science Technology and Engineering*, 2014, 14(7):117-120.

Artificial neural network-based transient electromagnetic imaging

YOU Xi-Ran¹, ZHANG Ji-Feng^{1,2,3}, SHI Yu¹

(1. College of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China; 2. National Engineering Research Center of Offshore Oil and Gas Exploration, Beijing 100028, China; 3. Integrated Geophysical Simulation Laboratory, Chang'an University, Xi'an 710054, China)

Abstract: The transient electromagnetic method (TEM) commonly uses the all-time apparent resistivity parameter for interpretation, which involves complex formulas and time-consuming iterative processes. Based on the characteristics of TEM data, this study employed the artificial neural network (ANN) for TEM pseudo-resistivity imaging. First, this study designed a multi-hidden-layer BP neural network and calculated a response amplitude through TEM analysis. The response amplitude, as the mapping parameter of pseudo resistivity, was used for network training. Then new data outside the training set were used to test the trained network. A homogeneous half-space and one-dimensional layered model was built to verify the correctness and adaptability of the neural network. The imaging of the three-dimensional geoelectric model was performed. As revealed by the results, the pseudo resistivity calculated based on the neural network can reflect the target anomalies of the geoelectric model, with highly accurate network imaging results. Finally, the measured data were processed using the neural network algorithm, further indicating that the neural network-based imaging can serve as a basis for data interpretation. This study verified the feasibility of the ANN in TEM imaging, thus providing a new approach for TEM imaging.

Key words: TEM imaging; artificial neural network; pseudo resistivity

(本文编辑:王萌)