

doi: 10.11720/wtyht.2021.1511

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.http://doi.org/10.11720/wtyht.2021.1511

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. http://doi.org/10.11720/wtyht.2021.1511

基于深度学习的中心回线瞬变电磁 全区视电阻率计算

吴国培,张莹莹,张博文,赵华亮

(新疆大学 地质与矿业工程学院,新疆 乌鲁木齐 830047)

摘 要:深度学习是人工神经网络算法的扩展,对复杂函数有很好的逼近能力,本文将其引入用于瞬变电磁视电阻率计算。首先,建立归一化感应电动势与瞬变场参数单一映射关系的 5 层深度神经网络,通过对单一隐含层不同神经元个数所训练的误差情况进行分析,确定 5 层深度神经网络各隐含层神经元个数为 13,8,5,8,13。训练算法选择了改进的具有自适应学习率的 Nadam 算法,该算法可加速训练过程。对训练好的深度神经网络模型进行仿真实验,采用典型地电模型加以验证,发现其对不同的地电模型均具有较好的反映,证明本文采用的基于深度学习计算视电阻率的可行性。应用结果表明训练好的深度神经网络模型可快速准确计算视电阻率。

关键词:瞬变电磁法;深度学习;人工神经网络;视电阻率

中图分类号: P631

文献标识码: A

文章编号: 1000-8918(2021)03-0750-08

0 引言

瞬变电磁法(TEM)是一种时间域的电磁探测方法,在水文、工程、环境等探测领域得到广泛应用^[1-4],全区视电阻率能快速直观反映地下地层的电性变化,目前在实际资料解释中应用广泛。由于电阻率参数与瞬变响应之间存在复杂的隐函数关系^[5],直接用解析式求解视电阻率存在一定困难。前人对视电阻率的计算做了一些研究:苏朱刘等^[6]提出了一种虚拟全区视电阻率,能相对反映地下电性层电阻率的变化规律;白登海等^[7]借助瞬变场参数,分别迭代求取早期、晚期视电阻率的精确值,进而通过转折点构成一条完整的全区视电阻率曲线;熊彬等^[8]使用逆样条插值的方法,以归一化感应电动势的极值点为界,分段用逆样条插值求解非线性方程的根,进而求出全区视电阻率;陈清礼等^[9]根据二分搜索算法,找到感应电动势与视电阻率单调

下降的区间,利用二分法直接求解全区视电阻率;武军杰等^[10]计算了分量视电阻率,为回线瞬变电磁法多个分量综合解释提供必要的基础;郝延松等^[11]对回线源瞬变电磁视电阻率计算方法进行讨论,用磁场定义全区视电阻率不存在双解问题,但现在通用的野外仪器测量感应电动势较为方便。

人工神经网络(artificial neural network, ANN)反演是模拟人脑机理和功能的一种新型计算机和人工智能技术,只需经过适当的学习训练就能够解决复杂的实际问题,具有广阔的发展前景^[12]。在瞬变电磁视电阻率求解方面已取得了一些研究进展,谢林涛等^[13]使用感应电压对电流的归一化值与视电阻率值构建 ANN 快速求解视电阻率;谢品芳等^[14]根据含时间的核函数、磁场与瞬变场参数之间的关系,构建 ANN 求解视电阻率。

2006 年, Hinton 等^[15]在《科学》首次提出深度学习,现已成为人工智能的一个研究热点。深度神经网络(DNN, deep neural network)模型相较于浅层

收稿日期: 2020-11-08; 修回日期: 2021-02-01

基金项目: 新疆维吾尔自治区自然科学基金项目(2017D01C064); 新疆维吾尔自治区研究生科研创新项目(XJ2020G044)

第一作者: 吴国培(1994-), 男, 在读硕士, 研究方向为瞬变电磁探测。Email: wu_guopei@163.com

通讯作者: 张莹莹(1989-), 女, 博士, 毕业于长安大学, 主要从事瞬变电磁场的理论与应用研究工作。Email: zhangyy19890423@163.com

模型(ANN)对非线性函数有更好的表示能力^[16],同时具有很高的容错性、鲁棒性及自组织性^[17]。目前,结合深度学习解决瞬变电磁相关问题的研究还较少,将其引入用于瞬变电磁视电阻率计算。本文以均匀半空间中心回线瞬变电磁的解析式为基础,将其与深度学习结合,构建归一化感应电动势 $F(u)$ 为输入,瞬变场参数 u 为输出的 DNN 模型。训练算法选择 Nadam 算法^[18],该算法自适应能力强,具有预更新能力,能够加速 DNN 训练过程。将训练好的 DNN 模型进行保存,不需要通过大量迭代,只需将归一化感应电动势值代入保存好的模型,就能快速计算视电阻率。通过仿真实验及实测资料的处理,验证了该方法的实际运用效果。

1 中心回线瞬变电磁视电阻率求解

1.1 瞬变电磁视电阻率基本求解理论

瞬变电磁中心回线装置下的瞬变电磁测深,在地下为均匀介质的情况下,采用的阶跃电流脉冲函数为

$$I(t) = \begin{cases} I_0, & t < 0; \\ 0, & t \geq 0. \end{cases} \quad (1)$$

电磁场存在如下解析解^[19]:

$$\frac{\partial B_z}{\partial t} = \frac{I_0 \rho}{a^3} \left[3\text{erf}(u) - \frac{2}{\sqrt{\pi}} u(3 + 2u^2) e^{-u^2} \right], \quad (2)$$

$$\text{erf}(u) = 2\sqrt{\pi} \int_0^u e^{-t^2} dt, \quad (3)$$

$$u = \left(\frac{\mu_0 a^2}{4t\rho} \right)^{1/2}, \quad (4)$$

结合式(2)及式(4)进行化简,可得:

$$3\text{erf}(u) - \frac{2}{\sqrt{\pi}} u(3 + 2u^2) e^{-u^2} = \frac{4ta u^2}{\mu_0 I_0} \cdot \frac{\partial B_z}{\partial t}. \quad (5)$$

式中: ρ 为均匀半空间电阻率; a 为发射回线半径; u 为瞬变场参数; $\text{erf}(u)$ 称为概率积分; t 为供电流关断后的延迟时间; μ_0 为均匀半空间的磁导率(一般取真空中的磁导率, $\mu_0 = 4\pi \times 10^{-7} \text{ H/m}$)。

1.2 视电阻率双值问题的讨论

实际工作中,感应电动势可以由仪器测出,则将式(5)进行化简,等式右侧均为已知量,左侧为只含有瞬变场参数 u 的形式,令 $F(u)$ 等于等式的左侧,可得:

$$F(u) = \frac{1}{u^2} \left[3\text{erf}(u) - \frac{2}{\sqrt{\pi}} u(3 + 2u^2) e^{-u^2} \right], \quad (6)$$

$F(u)$ 也被称为归一化感应电动势^[8]。

图 1 给出了归一化感应电动势 $F(u)$ 与瞬变场参数 u 之间的函数关系。通过计算可知: $u = 1.6136$ 时, $F(u)$ 存在极大值 0.7016。在实际应用中,式(4)可以方便地计算出归一化感应电动势的值,再根据式(6)即可计算出瞬变参数 u 。视电阻率与瞬变场参数 u 满足

$$\rho = \frac{\mu_0 a^2}{4tu^2}. \quad (7)$$

通过式(7)可计算出全区视电阻率,由此求解视电阻率关键的部分转化为求解式(6)。式(6)中含有概率积分,直接求解瞬变电磁场反函数存在一定困难,且根据图 1,给定一个归一化感应电动势的值 $F(u)$, 计算出的瞬变场参数 u 有 2 个解。




图 1 $F(u)$ 与瞬变场参数 u 的变化特征
Fig.1 $F(u)$ and the change characteristics of the transient field parameter u

对于视电阻率的双值问题,本文以瞬变场参数 $u = 1.6136$ 为界,构建 2 个以归一化感应电动势 $F(u)$ 为输入,瞬变场参数 u 为输出的 DNN 模型,并对瞬变场参数 u 另一区间最大值进行确定。据式(4),瞬变场参数 u 与发射回线边长呈正比,与延时、电阻率呈反比。发射回线边长取野外常用的大回线边长 600 m^[20],延时取接收机最小延时 $3 \times 10^{-6} \text{ s}$ ^[21],不同地质年代各种岩石电阻率的变化范围在 $[1, 100\,000] \Omega \cdot \text{m}$ ^[22],电阻率取其最小值 $1 \Omega \cdot \text{m}$,计算出瞬变场参数 u 为 194,以此确定瞬变场参数 u 的范围为 $(0, 194]$ 。则第一个 DNN 模型瞬变场参数 u 的区间为 $(0, 1.6136]$,第二个 DNN 模型瞬变场参数 u 的取值为 $(1.6136, 194]$ 。

对所构建的 2 个 DNN 模型,发射回线边长取 100 m,作出 DNN 视电阻率选取判别图,如图 2 所示。图中横、纵坐标的取值覆盖了多数岩石电阻率

及市面上大多数接收机的延时范围。由图可得,第一个 DNN 模型比第二个 DNN 模型能够计算视电阻率的区域面积大很多。实际工作时,可根据发射回线边长、仪器延时范围并结合工区岩石电阻率的大致范围,确定选用哪个 DNN 模型进行计算。




图 2 DNN 计算视电阻率选取判别

Fig.2 DNN calculation of apparent resistivity selection discriminant diagram

在计算出视电阻率后,借助 M. N. Nabighian^[23]的烟圈扩散理论,根据

$$H = \frac{4}{\sqrt{\pi}} \sqrt{\frac{t\rho}{\mu_0}} \quad (8)$$

计算出视电阻率 ρ 所对应的视深度 H ,绘制视电阻率与视深度断面图进行快速成像解释。

2 深度学习的设计与实现

2.1 深度学习原理

深度学习属于机器学习的一种。对于传统程序设计,是已知数据与制定的规则,进而求出答案,而机器学习则是已知数据与答案,通过机器学习找到它们之间所对应的规则,深度学习的训练过程就相当于找到对应规则的过程。这些规则随后可应用于新的数据,并使计算机自主生成答案^[24]。深度学习是基于误差反向传播算法,学习的过程由信号的正向传播与误差的反向传播两个过程组成,其结构一般包含输入层、隐含层、输出层三部分。深度学习的核心在于存在多个隐含层。通用 5 层 DNN 结构如图 3^[25]所示,各层中的空心圆代表神经元。

具体的学习过程为:正向传播时,样本从输入层传入,输入层的值在激活函数的传递下,经各隐含层处理后,最终到达输出层。Sigmoid 激活函数表达式为^[26]:

$$f(p) = 1 + \frac{1}{1 + e^{-p}}, \quad (9)$$




图 3 通用 5 层 DNN 结构^[23]

Fig.3 Universal five layer DNN structure

式中: p 为前一层神经元的值, $f(p)$ 为传递到下一层神经元的值。本文选择 Sigmoid 激活函数,即在神经网络中互相传递的值,均以式(9)进行传递。正向传播的最后一步为计算传递到输出层的值与期望输出值之间的误差^[27]:

$$E = \frac{1}{2} \sum_k (t_k - p_k)^2, \quad (10)$$

式中: t_k 为期望值, p_k 为实际输出值, k 为样本数;对于本文所构建的 DNN, t_k 为训练样本中瞬变场参数 u 的值, p_k 为训练样本中 $F(u)$ 经神经网络各层神经元传递到输出层的值。

若计算出的误差不满足精度要求,则进行误差的反向传播,使用式(10)计算给定的瞬变场参数 u 值与 $F(u)$ 经隐含层处理后传递到输出层值之间的误差。计算所得的误差以某种形式通过隐含层向输入层逐层反传,将误差分摊给各层的所有神经元,得到各层神经元的误差,并据此修正各层神经元权值。本文使用的 Nadam 算法依据式(10)修正网络连接权值,该算法将 Nesterov 动量的思想与 adam 算法进行结合,在计算梯度前将动量向量应用到参数上,直接到达“向前”看到的位置 $\theta_{t-1} - \eta\mu \cdot \frac{m_{t-1}}{\sqrt{n_{t-1}} + \varepsilon}$,然后再计算梯度,得到梯度 g_t 的更新公式^[28]:

$$g_t = \nabla_{\theta_{t-1}} f\left(\theta_{t-1} - \eta\mu \frac{m_{t-1}}{\sqrt{n_{t-1}} + \varepsilon}\right), \quad (11)$$

式中: θ_{t-1} 为第 $t-1$ 次迭代时选取的小批量参数值向量; μ 为指数衰减率,取值范围为 $[0, 1]$; η 是学习率; m_{t-1} 为梯度的一阶矩估计, n_{t-1} 为二阶矩估计, ε 是一个较小的随机正值,避免分母为 0 时学习率无穷大; $f\left(\theta_{t-1} - \eta\mu \frac{m_{t-1}}{\sqrt{n_{t-1}} + \varepsilon}\right)$ 是第 t 次迭代时的损失函数,即由式(10)计算所得的误差值; $\nabla_{\theta_{t-1}} f\left(\theta_{t-1} - \eta\mu \frac{m_{t-1}}{\sqrt{n_{t-1}} + \varepsilon}\right)$ 是第 t 次迭代时损失函数关于参

数向量 θ_{l-1} 的梯度向量。这种信号正向传播与误差反向传播调整各层权值的过程,是不断重复进行的。DNN 的学习训练过程,就是权值不断调整找到对应规则的过程,训练结束的条件可以设定为误差减小到某种精度或达到一定训练次数。

2.2 DNN 模型参数的选择及优化

根据瞬变电磁场的求解公式,不同物理参数具有不同的量纲,根据 ANN 特点,若不同物理参数直接输入网络,可能由于加权累加后变得异常巨大,从而使得网络难以收敛,因此有必要对网络的输入向量进行归一化处理。本文 DNN 中的输入及输出值使用最值法^[29]: $\hat{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$ 将值归一化到 $[0, 1]$ 区间, x_i 和 \hat{x}_i 分别为归一化前后的数值, x_{\max} 、 x_{\min} 分别为归一化前的最大、最小值。为增强 DNN 的泛化能力,将归一化的样本进行随机排序,再进行训练。

表 1 人工神经网络隐含层不同神经元个数的误差情况

Table 1 The convergence of different numbers of neurons in the hidden layer of ANN %

训练样本数	神经元个数					
	3	5	7	9	11	13
100	0.250000	0.250000	0.250000	0.250000	0.250000	0.240000
200	0.2400000	0.240000	0.088714	0.092951	0.091545	0.086794

从表 1 及训练过程中可得出:

1) 训练过程具有一定的随机性,不同神经元个数具有不同的训练误差,神经元个数为 13 时,训练结果相对较好;

2) 当训练样本数为 100 时,增加其隐含层神经元个数,训练误差下降到 0.002 5 后较长时间没有下降,可能为训练过程中出现局部极小值所致;

3) 当训练样本数为 200 时,训练误差能够较快速跳出局部极小值,训练结果更加精确。

据此确定本文隐含层第一层神经元个数为 13 个。第二层是输入数据层神经元个数的 1/3~2/3,第三层神经元个数也是第二层神经元个数的 1/3~2/3; 将二、三层结构倒置过来作为第四、五层^[17,25]。据此本文构建的 DNN 结构 1~5 层的隐含层神经元个数分别为:13、8、5、8、13。

本文使用上述 5 层 DNN 结构及神经元个数,训练样本数定为 200,选择 Nadam 算法^[27]对其进行 40 000 次训练。在 2.40 GHz 的 PC 上完成训练,耗时 1 232 s,训练结束后误差为 1.1978×10^{-5} 。误差下降曲线如图 4 所示,误差下降曲线总体呈单调下降,在局部极小值点附近,误差下降较慢,有一定的波动,但可有效跳出局部极小值。

隐含层神经元个数对构建的 DNN 也有较大的影响,选择合适的隐含层神经元个数可以加速 DNN 的收敛。文中先使用一个隐含层,即 ANN 模型进行确定,利用 $n_1 = \sqrt{n+m} + a$ ^[30] 确定隐含层神经元个数,其中: n 、 m 分别为输入单元数和输出单元数,构建的神经网络模型中 n 与 m 值均为 1; a 为 $[1, 10]$ 之间的常数; n_1 则为隐含层神经元个数,初值可取为 3,依次增加神经元个数至 13,通过式 (10) 计算其误差值。训练过程中,可以使用小批次的梯度下降,即把样本分为 10 组数据为一批进行训练,10 组数据共同决定了该次训练的梯度下降方向,以减少训练过程中的随机性。训练算法使用常用的 Nadam 算法,等差挑选了隐含层不同神经元个数,并使用 100 和 200 组样本进行了 5 000 次训练,表 1 给出了所得的误差情况。




图 4 深度神经网络 Nadam 训练算法误差下降
Fig.4 The convergence reduction graph of the DNN Nadam training algorithm

2.3 DNN 模型训练误差对比

瞬变场参数 u 的精度对视电阻率的影响极大,需要构建极为精确的 DNN 模型。实际应用中还未有完善系统化的理论来指导样本的选取,在没有公认确定使用何种处理方法可以得到较好效果时,要提高所构建的 DNN 模型的精度,一个非常重要的方法就是增大训练样本数量^[28]。本文依据文献[19]选取训练样本数量及结合小批次的梯度下降算法,选取 200 000 组训练样本,发射电流为 1 A,发射线

框半径 $a=300\text{ m}$, 在训练过程中, 将误差为 4.6756×10^{-6} 、 5.5311×10^{-7} 的 2 个 DNN 模型进行保存, 用以对比分析不同训练误差 DNN 的实际使用效果。选取电阻率为 $100\text{ }\Omega\cdot\text{m}$ 的均匀半空间地电模型进行试算验证, 结果如图 5 所示: 在探测深度较浅时视电阻率基本一致, 探测深度较深时 DNN 需要更高的精确度; 训练误差达 5.5311×10^{-7} 的 DNN 模型能够更精确计算较深部的视电阻率。





图 5 不同训练误差 DNN 视电阻率对比
Fig.5 Comparison of DNN apparent resistivity with different training convergence


3 仿真实验

仿真实验选取 200 000 组训练样本, 发射电流为 1 A, 发射线框半径 a 为 300 m, 使用训练误差达 5.5311×10^{-7} 的 DNN 模型计算视电阻率。设计了几种地电模型: ①均匀半空间地电模型, 电阻率 $100\text{ }\Omega\cdot\text{m}$; ②H 型地电模型, $\rho_1=500\text{ }\Omega\cdot\text{m}$, $h_1=100\text{ m}$, $\rho_2=10\text{ }\Omega\cdot\text{m}$, $h_2=200\text{ m}$, $\rho_3=500\text{ }\Omega\cdot\text{m}$; ③K 型地电模型, $\rho_1=10\text{ }\Omega\cdot\text{m}$, $h_1=100\text{ m}$, $\rho_2=200\text{ }\Omega\cdot\text{m}$, $h_2=100\text{ m}$, $\rho_3=10\text{ }\Omega\cdot\text{m}$; ④四层 KH 型地电模型, $\rho_1=50\text{ }\Omega\cdot\text{m}$, $h_1=50\text{ m}$, $\rho_2=500\text{ }\Omega\cdot\text{m}$, $h_2=100\text{ m}$, $\rho_3=10\text{ }\Omega\cdot\text{m}$, $h_3=200\text{ m}$, $\rho_4=500\text{ }\Omega\cdot\text{m}$ 。将仿真正演出不同地电模型的感应电动势转化为归一化感应电动势并代入训练好的 DNN 模型, 由此得到所对应的瞬变场参数 u , 将其转换为视电阻率并计算出视深度后进行成像, 得到视电阻率与视深度断面(图 6)。


从图 6 可看出, 基于深度学习所得视电阻率与本文所设计的地电模型相符。图 6a 由 DNN 所得视电阻率与理论模型视电阻率吻合很好。图 6b 显示 DNN 得到的视电阻率对低阻地层反映相对较好。图 6c 反映出由 DNN 所得视电阻率在高阻层与理论




(a) 均匀半空间模型



(b) H型地电模型



(c) K型地电模型



(d) KH型地电模型

图 6 4 种地电模型视电阻率与视深度示意
Fig.6 Schematic diagram of apparent resistivity and apparent depth of 4 geoelectric models

值相差较大,只能看出相对变化的趋势,说明其对高阻层反映不敏感,这也是瞬变电磁法的固有特点。图 6d 为四层 KH 型地电模型,由 DNN 所得视电阻率对其也具有良好反映,证实了该方法对复杂层状大地的适用性。

4 应用实例

工作区位于新疆和静县北山凹陷谷地,该地层上部为第四系洪积砂卵石加漂石层 Q_{3-1}^{pl} ,下部为新近系钙质砾岩夹砂岩 N_2 ,地形较平坦,在该区开展了瞬变电磁法寻找地下承压水的工作。本次瞬变电磁法勘探采用中心回线方式,测点间距 5 m,线距 100 m,发射线圈边长为 300 m×300 m;发射机使用 PROTEM57-MK2 瞬变电磁探测系统,接收线圈为 PROTEM57-MK2 发射机专用配套接收线圈;供电电压使用 220 V,供电频率 60 Hz,采样叠加次数 24 次;数据采集延时范围在 36~2 525 μs 。根据图 2,并结合工区的地质资料,选用第一个 DNN 求解视电阻率。整个工区布置了 5 条测线,选取其中一条进行介绍,处理结果如图 7 所示。




图 7 和静水资源勘察视电阻率拟断面

Fig.7 Schematic diagram of apparent aesity and depth of Hejing’s water resources survey

该测线分布在测区中部,呈近 SN 向展布,由北向南测量,剖面全长 100 m,测点间隔 5 m。从图 7 中可见,视电阻率总体呈现出中部高阻、上下低阻的特征,其中在 50 m 以浅可见深蓝色低阻条带,其视电阻率在 50 $\Omega \cdot m$ 以下;向下在 50~160 m 范围处,出现高阻覆盖层,电阻率常见 150 $\Omega \cdot m$,该高阻覆盖层延续性也很好;该地层下部存在延续性良好的低阻地层,推测该高阻地层可能为承压水的顶板;在 250 m 附近出现条带状低阻地层,平均视电阻率 60 $\Omega \cdot m$,根据其低阻特征及其上覆盖高阻致密层,认为该处极大可能为承压水层。后期通过钻探进行验证,和推断结果相符。

5 结论及讨论

- 1)深度学习相较于传统人工神经网络,对抽象数据的拟合能力更强,本文将其应用于瞬变电磁视电阻率计算。使用 Tensorflow2.0 构建归一化感应电动势与瞬变场参数的 5 层 DNN 模型,并对各隐含层神经元个数进行确定。训练算法选择 Nadam 算法,该算法能够加速训练过程,能取得较好的训练效果。
- 2)本文以瞬变场参数 $u = 1.6136$ 为界,建立了 2 个 DNN 模型求解视电阻率,并讨论了延时范围与电阻率的关系,DNN 计算视电阻率选取判别图可较好解决计算视电阻率存在双值的问题。在观测时间较长时,对 DNN 的精度要求更高,对训练的 DNN 精度需要达到何种程度,还需要进一步的研究。
- 3)本文训练好的 DNN 模型在实测资料处理中取得了良好的使用效果。DNN 在瞬变电磁的实际应用还较少,可以针对不同装置训练出与之对应的 DNN,将训练出的符合精度要求的 DNN 运用到实际工作中。虽然训练过程费时较多,但使用保存好的 DNN 模型不需要进行大量迭代计算,将数据代入 DNN 模型就可迅速计算视电阻率,能够极大提高视电阻率计算效率。
- 4)影响 DNN 训练的参数也较多,调整不同参数就可能对训练的 DNN 造成较大的影响。DNN 对于不同参数的选择现在还没有统一的结论,对于不同情况,要训练出符合精度要求的 DNN 还需要大量实验。

致谢:感谢审稿专家提出的修改意见和编辑部的大力支持!

参考文献 (References) :

[1] 朴化荣. 电磁测深法原理[M]. 北京:地质出版社,1990.

- Piao H R. The theory of electromagnetic sounding[M]. Beijing: Geological Publishing House, 1990.
- [2] 方文藻, 李予国, 李貅. 瞬变电磁测深法原理[M]. 西安: 西北工业大学出版社, 1993.
- Fang W Z, Li Y G, Li X. Principle of transient electromagnetic sounding[M]. Xi'an: Northwestern Polytechnical University Press, 1993.
- [3] 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. The theory of time-domain electromagnetic methods[M]. Changsha: Central South University of Technology Press, 1992.
- [4] 蒋邦远. 实用近区磁源瞬变电磁法勘探[M]. 北京: 地质出版社, 1998.
- Jiang B Y. Practical near zone source transient em sounding[M]. Beijing: Geological Publishing House, 1998.
- [5] 李貅. 瞬变电磁测深的理论与应用[M]. 西安: 陕西科学技术出版社, 2002: 1195 - 1200.
- Li X. The theory and application of transient electromagnetic sounding[M]. Xi'an: Shanxi Science Technology Press, 2002: 1195 - 1200.
- [6] 苏朱刘, 胡文宝. 中心回线方式瞬变电磁测深虚拟全区视电阻率和一维反演方法[J]. 石油物探, 2002, 41(2): 216 - 221.
- Su Z L, Hu W B. Pseudo full-region apparent resistivity and its one-dimensional inversion for center loop line configuration TEM data[J]. Geophysical Prospecting for Petroleum, 2002, 41(2): 216 - 221.
- [7] 白登海, Meju Maxwell-A, 卢健, 等. 时间域瞬变电磁法中心方式全程视电阻率的数值计算[J]. 地球物理学报, 2003, 46(5): 697 - 704.
- Bai D H, Meju M A, Lu J, et al. Numerical calculation of all-time apparent resistivity for the central loop transient electromagnetic method[J]. Chinese Journal of Geophys., 2003, 46(5): 697 - 704.
- [8] 熊彬. 大回线瞬变电磁法全区视电阻率的逆样条插值计算[J]. 吉林大学学报: 地球科学版, 2005, 35(4): 515 - 519.
- Xiong B. Inverse spline interpolation for the calculation of all-time resistivity for the large loop transient electromagnetic method[J]. Journal of Jilin University: Earth Science Edition, 2003, 35(4): 515 - 519.
- [9] 陈清礼. 瞬变电磁法全区视电阻率的二分搜索算法[J]. 石油天然气学报, 2009, 31(2): 45 - 49.
- Chen Q L. Searching algorithm for full time apparent resistivity from TEM electromotive force data[J]. Journal of Oil and Gas Technology, 2009, 31(2): 45 - 49.
- [10] 武军杰, 王兴春, 邓晓红, 等. 定源回线瞬变电磁 x 分量视电阻率计算方法[J]. 物探与化探, 2012, 36(4): 684 - 687.
- Wu J J, Wang X C, Deng X H, et al. The method for Calculating x -component apparent resistivity of TEM fixed loop[J]. Geophysical and Geochemical Exploration, 2012, 36(4): 684 - 687.
- [11] 郝延松, 胡博, 于润桥, 等. 磁性源瞬变电磁法视电阻率计算方法[J]. 物探与化探, 2012, 36(6): 1034 - 1039.
- Hao Y S, Hu B, Yu R Q, et al. The calculation of apparent resistivity for magnetic source TEM[J]. Geophysical and Geochemical Exploration, 2012, 36(6): 1034 - 1039.
- [12] 薛国强, 李貅, 底青云. 瞬变电磁法正反演问题研究进展[J]. 地球物理学进展, 2008, 90(4): 1165 - 1172.
- Xue G Q, Li X, Di Q Y. Research progress in TEM forward modeling and inversion calculation[J]. Progress in Geophysics, 2008, 90(4): 1165 - 1172.
- [13] 谢林涛, 付志红, 谢品芳, 等. 基于神经网络的视电阻率快速算法[J]. 地球物理学进展, 2009, 24(4): 1527 - 1532.
- Xie L T, Fu Z H, Xie P F, et al. A fast algorithm of apparent resistivity based on neural networks[J]. Progress in Geophysics, 2009, 24(4): 1527 - 1532.
- [14] 谢品芳, 谢林涛, 付志红, 等. 基于 BP 网络的视电阻率快速计算[J]. 重庆大学学报, 2009, 32(9): 1111 - 1116.
- Xie P F, Xie L T, Fu Z H, et al. Fast algorithm for apparent resistivity calculation based on BP neural networks[J]. Journal of Chongqing University, 2009, 32(9): 1111 - 1116.
- [15] Hinton G, Salakhutdinov R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504 - 507.
- [16] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799 - 1804.
- Yu K, Jia L, Chen Y Q, et al. Yesterday, today and tomorrow of deep learning[J]. Journal of Computer Research and Development, 2013, 50(9): 1799 - 1804.
- [17] 毛健, 赵红东, 姚婧婧. 人工神经网络的发展及应用[J]. 电子设计工程, 2011, 19(24): 62 - 65.
- Mao J, Zhao H D, Yao J J. Development and application of artificial neural networks[J]. Electronic Design Engineering, 2011, 19(24): 62 - 65.
- [18] Dozat T. Incorporating nesterov momentum into adam[J]. ICLR Workshop, 2016, 20(1): 2013 - 2016.
- [19] 秦善强, 付志红, 朱学贵, 等. 遗传神经网络的瞬变电磁视电阻率求解算法[J]. 电工技术学报, 2017, 32(12): 146 - 154, 250.
- Qin S Q, Fu Z H, Zhu X G, et al. Genetic neural network for apparent resistivity solution of transient electromagnetic[J]. Transactions of China Electrotechnical Society, 2017, 32(12): 146 - 154, 250.
- [20] 薛国强. 论瞬变电磁测深法的探测深度[J]. 石油地球物理勘探, 2004, 39(5): 575 - 578.
- Xue G Q. On the detection depth of the transient electromagnetic sounding method[J]. Petroleum Geophysical Prospecting, 2004, 39(5): 575 - 578.
- [21] 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, 29(S1): 111 - 115.
- Lyu G Y. The status quo and development trend of transient electromagnetic method[J]. Computing Techniques for Geophysical and Geochemical Exploration, 2007, 29(S1): 111 - 115.
- [22] 刘天佑. 地球物理勘探概论[M]. 北京: 地质出版社, 2007.
- Liu T Y. Introduction to geophysical prospecting[M]. Beijing: Geological Publishing House, 2007.
- [23] Nabighian M N. Quasi-static transient response of a conducting half-space-an approximate representation[J]. Geophysics, 1979, 44(10): 1700 - 1705.
- [24] Francois Chollet. Python 深度学习[M]. 张亮, 译. 北京: 人民邮电出版社, 2018.

Francois chollet. Python deep learning [M]. Zhang L, translated. Beijing: People's Posts and Telecommunications Press, 2018.

[25] 毛勇华, 桂小林, 李前, 等. 深度学习应用技术研究 [J]. 计算机应用研究, 2016, 33 (11): 3201 – 3205.

Mao Y H, Gui X L, Li Q, et al. Research on deep learning application technology [J]. Application Research of Computers, 2016, 33 (11): 3201 – 3205.

[26] 牟晋娟. 深度神经网络中激活函数的研究 [J]. 电脑编程技巧与维护, 2019, 414 (12): 59 – 61.

Mou J J. Research on activation function in deep neural networks [J]. Computer Programming Skills & Maintenance, 2019, 414 (12): 59 – 61.

[27] 张崇荣. 基于卷积神经网络的图像分类方法研究 [D]. 成都: 电子科技大学, 2019.

Zhang C R. Research on image classification method based on convolutional neural network [D]. Chengdu: University of Electronic Science and Technology of China, 2019.

[28] 吴昌友. 神经网络的研究及应用 [D]. 哈尔滨: 东北农业大学, 2007.

Wu C Y. Research and application of neural network [D]. Harbin: Northeast Agricultural University, 2007.

[29] 柳小桐. BP 神经网络输入层数据归一化研究 [J]. 机械工程与自动化, 2010, 160 (3): 122 – 123, 126.

Liu X T. Study on data normalization in BP neural network [J]. Mechanical Engineering & Automation, 2010, 160 (3): 122 – 123.

[30] 沈花玉, 王兆霞, 高成耀, 等. BP 神经网络隐含层单元数的确定 [J]. 天津理工大学学报, 2008, 91 (5): 13 – 15.

Shen H Y, Wang Z X, Gao C Y, et al. Determining the number of BP neural network hidden layer units [J]. Journal of Tianjin University of Technology, 2008, 91 (5): 13 – 15.

The calculation of full-region apparent resistivity of central loop TEM based on deep learning

WU Guo-Pei, ZHANG Ying-Ying, ZHANG Bo-Wen, ZHAO Hua-Liang
(School of Geology and Mining Engineering, Xinjiang University, Urumqi 830047, China)

Abstract: Deep learning is an extension of the artificial neural network algorithm, which has a good approximation ability for complex functions. This paper introduces this means for the calculation of transient electromagnetic apparent resistivity. First, a 5-layer deep neural network is established with a single mapping relationship between the normalized induced electromotive force and the transient field parameters. By analyzing the error conditions trained by different numbers of neurons in a single hidden layer, the hidden layers of the 5-layer deep neural network are determined. The number of layered neurons is 13, 8, 5, 8, 13. The training algorithm chooses the improved Nadam algorithm with adaptive learning rate, which can speed up the training process. The trained deep neural network model is simulated and verified by a typical electrical model, and it is found that it has a good response to different geoelectric models, which proves the feasibility of calculating apparent resistivity based on deep learning put forward in this paper. The actual application results show that the trained deep neural network model can quickly and accurately calculate the apparent resistivity, and its effectiveness is verified by drilling.

Key words: TEM; deep learning; artificial neural network; whole-region apparent resistivity

(本文编辑: 沈效群)