

doi: 10. 11720/wtyht. 2023. 1560

刘湘浩,刘四新,胡铭奇,等. 基于 OMAGA-BP 算法的高密度电阻率法反演研究[J]. 物探与化探, 2023, 47(6): 1519–1527. <http://doi.org/10.11720/wtyht.2023.1560>

Liu X H, Liu S X, Hu M Q, et al. Research on inversion of high-density resistivity method based on OMAGA-BP algorithm[J]. Geophysical and Geochemical Exploration, 2023, 47(6): 1519–1527. <http://doi.org/10.11720/wtyht.2023.1560>

基于 OMAGA-BP 算法的高密度电阻率法反演研究

刘湘浩,刘四新,胡铭奇,孙中秋,王千

(吉林大学 地球探测与科学技术学院,吉林 长春 130061)

摘 要: 高密度电阻率法由于其高效、直观的特点,在工程勘查中得到广泛应用。然而,由于反演问题的高度非线性,传统的反演方法在刻画异常体边界时存在一定的不精确性。为了实现高精度的高密度电法二维非线性反演成像,克服 BP 算法损失函数参数空间存在大量鞍点影响计算精度,及普通遗传算法存在早熟收敛、难以赋予 BP 网络最优的权值阈值的问题,本文提出基于最佳保留策略的自适应遗传算法(optimum maintaining adaptive genetic algorithm,简称 OMAGA)优化的 BP 神经网络进行高密度电法二维反演成像方法。该方法对仿真模型数据及实测数据的反演计算都得到了较好的结果,表明该方法具有泛化能力强、反演计算精度高的优点。该研究对未来高密度电阻率法的精确反演有一定的指导作用,有助于提高地下目标的识别精度。

关键词: 基于最佳保留策略的自适应遗传算法;BP 神经网络;高密度电阻率法;反演精度

中图分类号: P631

文献标识码: A

文章编号: 1000-8918(2023)06-1519-09

0 引言

高密度电阻率法具有采集半自动化、低成本及采集信息丰富等优点,近年来广泛应用于探测地下采空区、冻土检测、地下隐伏构造探测等工程地质调查任务中。该方法出现早期,对于其二维探测数据的反演解释,通常采用在初始模型附近线性近似的迭代反演方法^[1-4],其中以瑞典 Loke 博士等编写的 ERT 反演软件(RES2DINV、RES3DINV)应用最为广泛^[5]。但 ERT 反演是个非常复杂的非线性问题,将其线性化近似反演依赖初始模型、易陷入局部最优,无法得到精细的反演结果^[6]。

随着计算机科学与技术的发展,非线性方法在地球物理反演问题中应用越来越广泛。Raiche^[7]早在 1991 年就将神经网络应用于地球物理数据反演中,Calderón-Macías 等^[8]将神经网络应用于直流电阻率法及地震数据处理,证明了神经网络应用于地球物理数据反演的可行性。国外学者 El-Qady 等、

Stephen 等、Mann 及 Neyamadpour 等应用神经网络进行一维、二维电阻率数据反演计算的研究^[9-12];Neyamadpour 等^[13-14]应用神经网络进行三维 ERT 数据的反演计算,均取得了理想的结果,说明了神经网络进行电法数据的反演计算具备传统线性方法不具备的优越性。国内学者徐海浪等^[6]最早应用 MATLAB 神经网络工具箱进行二维 ERT 数据的反演计算,指出 RPROP 算法具备最快的收敛速度。但是由于神经网络学习算法的限制,使神经网络的损失函数在迭代过程中陷入鞍点,使得神经网络进行反演计算的精度受到限制。对于这一问题,国内外学者进行了深入研究,Maiti 等^[15]使用混合蒙特卡洛算法优化的贝叶斯神经网络进行二维直流电法数据的反演;张凌云^[16]对比了多种智能寻优算法优化的 BP 神经网络进行二维 ERT 数据的反演计算,指出遗传算法优化后的网络精度最高时间最长;戴前伟等^[17-18]使用混沌振荡的 PSO 算法及差分进化算法优化的 BP 神经网络实现 ERT 数据反演成像;高明亮等^[19]使用免疫遗传算法优化的 BP 神经网络

收稿日期: 2022-11-22; 修回日期: 2023-02-24

基金项目: 国家重点研发计划课题“石窟岩体裂隙渗流精细探测与多源数据处理解释系统研究”(2021YFC1523401)

第一作者: 刘湘浩(2000-),男,博士生,主要研究方向为高密度电法数据的 AI 反演计算。Email: xianghao22@mails.jlu.edu.cn

通讯作者: 刘四新(1966-),男,教授,博士生导师,主要从事探地雷达、钻孔雷达及电磁波测井的方法理论研究工作。Email: liusixin@jlu.edu.cn

络进行二维 ERT 数据反演计算,提出并解决了普通遗传算法的寻优慢、易收敛于局部极小点的问题。

前人成果缺乏训练模型数据集的合理划分、针对实测 ERT 数据反演成像数据的网络模型数据设计不完全合理。针对这两个问题,本文指出了数据集合理划分的重要性,并提出基于最佳保留策略的自适应遗传算法(OMAGA)优化的 BP 神经网络 ERT 反演成像建模方案,通过最小二乘法、BP 算法、GA-BP 算法及 OMAGA-BP 算法对仿真模型及防空洞实测数据反演计算精度的对比,证明了本文提出的 ERT 反演方案可得到高精度的反演结果。

1 OMAGA 算法优化 BP 神经网络原理

1.1 BP 神经网络构建原理

1.1.1 BP 神经网络算法

BP 神经网络是误差反向传播的多层神经网络,其由输入层、若干隐藏层、输出层及层之间的连接关系构成,图 1 为三层 BP 网络示意。 i 为输入层节点个数, j 为输出层节点个数。网络中间结构为隐藏层,BP 神经网络的非线性特性正是来自于隐藏层处的非线性激活函数。




图 1 三层 BP 神经网络结构示意图

Fig.1 Schematic diagram of three-layer BP neural network structure

BP 神经网络算法分为正向传播拟合及误差反向传播调整网络权值阈值两个部分。正向传播拟合为输入数据通过网络拟合得到预测输出的过程。图 2 为单神经元算式示意;式(1)为输出值 a 与输入向量 $\boldsymbol{p}$ 对应的关系, f 为激活函数, $\boldsymbol{w}$ 为权值行向量,向量的维度均为 r , w_j 为输入值 P_j 与神经元之间的权值, b 为阈值。

$$f=f(\boldsymbol{w} \times \boldsymbol{p}+b)=f\left(\sum_{j=1}^r w_j \times p_j+b\right), \quad(1)$$




图 2 单神经元算式示意

Fig.2 Schematic diagram of single neuron formula

选用均方误差作为网络的损失函数,设第 t 次迭代时网络对输入数据的拟合结果为 y_{pq}^t ,实际值为 ρ_{pq} , m 为输入数据的维数, n 为网络模型样本个数。式(2)为本文损失函数的表示形式:

$$J'(w, b)=\sqrt{\left[\sum_{q=1}^n \sum_{p=1}^m\left(y_{pq}^t-\rho_{pq}\right)^2\right] /\left(m \times n\right)} . \quad(2)$$

BP 神经网络算法通过误差反向传播,使用学习算法调整网络权值阈值直到满足网络训练终止条件,徐海浪等^[6]经过对各种学习算法的对比,发现使用 RPROP 算法表现最优。RPROP 算法的运算过程为:

1)赋予每个节点权值阈值初始变化量 Δ_0 ,设置加速因子 η_+ 、减速因子 η_- ,并设置权值阈值变化上限 $\Delta_{\max}$ 及变化下限 $\Delta_{\min}$ 。

2)计算初始化网络后损失函数的数值,并计算其对每个权值阈值的一阶导。

3)根据误差梯度变化调整权值阈值变化步长:

$$\Delta_t=\min \left(\eta^{+} \cdot \Delta_{t-1}, \Delta_{\max }\right), \quad\left(\frac{\partial J^t}{\partial V^t} \frac{\partial J^{t-1}}{\partial V^{t-1}}>0\right)$$
$$\Delta_t=\max \left(\eta^{-} \cdot \Delta_{t-1}, \Delta_{\min }\right), \quad\left(\frac{\partial J^t}{\partial V^t} \frac{\partial J^{t-1}}{\partial V^{t-1}}<0\right)$$
$$\Delta_t=\Delta_{t-1}, \quad\left(\frac{\partial J^t}{\partial V^t} \cdot \frac{\partial J^{t-1}}{\partial V^{t-1}}=0\right) . \quad(3)$$

调整权值阈值:

$$\Delta V_t=-\operatorname{sign}\left(\frac{\partial J^t}{\partial V^t}\right) \Delta_t, \quad(4)$$

$$V_{t+1}=V_t+\Delta V_t, \quad(5)$$

$$\operatorname{sign}(x)=\left\{\begin{array}{ll} 1 & (x>0) \\ -1 & (x<0) \\ 0 & (x=0) \end{array}\right. \quad(6)$$

4)重复步骤 2)~3)直到满足终止条件。

1.1.2 模型数据集的划分

若想在训练数据数量一定的前提下,训练出具备一定泛化能力的网络,将一小部分训练模型数据

划分成测试集和验证集是十分关键的。首先训练集的作用即是训练网络,通过拟合训练集的输入输出数据,达到网络可以精确反演训练集模型类型的数据的基本要求。

验证集不对网络的权值阈值进行调整,通过验证集的数据对调整了几次权值阈值的网络进行精度验证,根据验证集误差结果及时调整网络的权值阈值。Matlab 神经网络工具箱具有“validation check”功能,通过函数定义验证集误差最大连续不下降次数,当连续训练网络到此设置次数,验证集数据拟合误差还下降,网络停止训练,起到“early stopping”的作用^[20];尽管随着网络训练过程,对训练集的输入输出数据非线性关系的拟合程度不断提高,但是由于网络权值阈值的初值很小,而随着迭代次数的增加,权值阈值的数值增大,若验证集误差连续在规定次数内不下降时,停止网络的训练,此时权重阈值很小,网络对于输入、输出数据之间非线性关系的拟合便不能过于依赖网络的某个节点,避免了过拟合现象的发生,保证了网络具备一定的泛化能力。

测试集是数据集中不参与网络训练的数据集合,其有对经过训练及验证的网络精度验证的作用,是对训练好网络的泛化能力的一种近似,如果测试集误差无法达到精度需求,则需重新设定网络的超参数。

从上述 3 种数据集合划分的作用来看,模型数据集的划分十分关键,要想得到理想性能的网络,不能少划分任何一个数据集。

1.2 OMAGA 算法优化 BP 神经网络

BP 算法具备强大的非线性拟合能力,但由于网络的权值阈值总数很大,导致网络损失函数的维度相当高,使得网络损失函数的参数空间含有大量鞍点,使得 RPROP 算法等传统的学习算法甚至难以调整得到使网络损失函数陷入局部最小点的权值阈值结果^[21],这在某种程度上限制了网络的精度。

遗传算法是来源于对生物学中遗传现象模拟的智能寻优算法,通过一代代的遗传进化计算,从而得到目标函数的最优解。而普通遗传算法存在“早熟收敛”问题。恽为民等^[22]等说明了采用最佳保留策略的简单遗传算法(OMSGA)及交叉率和变异率自适应变化的自适应遗传算法(AGA)具有一定的全局收敛性。本文采用基于最佳保留策略的自适应遗传算法(OMAGA)对 BP 神经网络的初始权值阈值进行优化,通过 OMAGA 算法赋给 BP 神经网络接近最优的权值阈值初始值,再通过 RPROP 学习算法训练网络对权值阈值进一步微调,使得网络的损失

函数以最大程度上逼近全局最小值,从而达到提升网络预测精度的目的,使用 OMAGA 算法优化 BP 算法过程如下:

1) 确定网络参数:确定除权值阈值以外的其他参数。

2) 选择优化目标:遗传算法通常寻找适应度值大的个体,设网络在第 T 次迭代后终止训练,本文优化目标函数为:

$$fitness = \exp(-J^T(w, b)) \quad (7)$$

3) 种群大小的选择:种群是遗传算法每次迭代参与计算个体的总数,如果种群规模过小,其降低了个体多样性,导致精度不足,并且得到的解不稳定;若种群规模过大,会严重延长算法寻优时长,导致算法性能下降。本文选择种群规模为 100。

4) 编码方式选择:本文选择实数编码方式,其避免了基于二进制转换形式的编码方法求解精度受编码长度限制、需要频繁的解码操作影响计算速度等问题,保证了算法的局部搜索能力。

5) 初始化种群:其需要满足在解空间内随机采样且均匀分布,初始化结果在可行解范围内。群体中每个个体的基因向量维度大小为网络权值阈值数目总和,选择每个基因的值控制在 $[-1, 1]$ 范围内。初始化生成种群规模数量的个体。

6) 以式(7)计算种群中每个个体的适应度值。

7) 选择操作:模拟了自然界的“选择”,本文采用轮盘赌算法。

8) 交叉操作:其模拟了生物学的基因重组,基于初始化后个体均匀分布于解的编码空间全局,其具有全局寻优性。AGA 算法通过自适应调控交叉率,算法迭代前期保证全局寻优能力,而算法迭代后期种群平均适应度 f_a 与最佳适应度 f_m 接近时需减小交叉率从而弱化算法的全局寻优能力,避免破坏种群优良模式。初始交叉率选择 0.8,交叉率自适应选择公式:

$$P_{cross} = \begin{cases} 0.8 \times (f_m - 0.5f_a) / (f_m + f_a) & (f_a \geq 0.95f_m) \\ 0.8 & (f_a < 0.95f_m) \end{cases} \quad (8)$$

9) 变异操作:变异操作是对生物学染色体基因突变的模拟,其较大幅度地改变种群的表现型,体现的是算法局部寻优能力。当平均适应度和最佳适应度接近时,需增大变异率从而加强算法局部寻优能力,使得种群一定概率跳出局部最优解区域。初始变异率选择 0.15,变异率自适应选择公式:

$$P_{mutate} = \begin{cases} 0.15 \times (f_m + f_a) / (f_m - 0.5f_a) & (f_a \geq 0.95f_m) \\ 0.15 & (f_a < 0.95f_m) \end{cases}$$

(9)

10)最佳保留策略: 每轮迭代进行完交叉变异等操作后,此策略对比子代与父代最佳适应度大小,如果子代最佳适应度值优于父代,则不对子代进行任何操作,若子代最佳适应度差于父代,则将父代的最佳个体替换给子代的最差个体;即使种群没有进化,也会保证原有最佳个体不受破坏,增强了算法寻优搜索的稳定性。

11)终止条件的选择: 选择算法迭代达到一定次数或种群最优适应度值大于所设置值作为算法终止条件。

12)重复 6)~10)步直到满足终止条件,将得到最优的权值阈值赋给网络。

2 二维 OMAGA-BP 高密度电法反演成像

对于 OMAGA-BP 算法进行二维 ERT 数据反演成像,其原理是设计训练样本并给定该算法相应参数后,通过该算法学习训练样本中视电阻率和真电阻率的复杂非线性关系;学习完成之后,向网络中输入有关视电阻率向量即可预测真电阻率值向量,代入相应的坐标绘图即可实现成像。在确定所用算法的参数之前,需确定训练模型设计的方式以及选择反演成像网络建模方式。

模型设计基于 RES2DMOD 软件,首先要固定装置参数,本文采用电极距为 1 m、电极数量为 36 个的温纳装置,共采集 198 个视电阻率数据;其次要基于对装置探测范围内异常体的电性分布范围进行限制,在目标反演区域可先通过线性反演结果、地质资料调查、钻井资料获取等了解目标反演区域地质

构造及相应电性特征;然后大量设计针对目标反演区域电性分布特征的特定模型训练网络,从而在保证反演结果精度的前提下,提高模型设计的效率。

对于 BP 网络进行 ERT 二维反演成像,本文选择徐海浪等^[6]的网络建模方式,输入向量为 198 个视电阻率数据,输出向量为 1 540 个真电阻率数据。而在进行实际野外数据采集时,由于电极位置误差、高密度电法仪器质量不稳定等因素,实测数据的采集不可能不包含误差,主要成分是白噪声。如果将数值模拟得到的数据直接用于训练网络的情况下,相当于这部分白噪声直接被减掉了,而实际情况下干扰一定存在,这会影响网络对实测数据的预测精度。Chen 等^[23]向输入电阻率向量中加入一定比例的高斯噪声,很好地解决了这一问题;同时在弱噪声的前提下,有学者证明向神经网络的输入加入噪声相当于 Tikhonov 正则化的作用^[24],其提高了神经网络解决回归问题的泛化性能^[25]。本文对网络的输入数据矩阵加入 2% 的高斯噪声,然后对学习样本的输入输出数据进行归一化到[0,1]范围内处理,旨在降低数据之间的大小差距,加快网络的训练速度。图 3 为二维 OMAGA-BP 高密度电法反演成像流程。

3 仿真模型反演成像

本节主要对比最小二乘法、BP 法、GA-BP 法及 OMAGA-BP 法 4 种方法进行二维 ERT 仿真模型反演成像的精细程度,并且通过回归值 R (训练集 R 值、验证集 R 值、测试集 R 值和网络整体 R 值)对比 3 种非线性反演方法 (BP、GA-BP 及 OMAGA-BP) 的精度,回归值 R 代表网络对输入输出之间非线性关系的拟合程度,其表达式为:

$$R = \sqrt{\frac{[mn(\sum_{q=1}^n \sum_{p=1}^m y_{pq}^t \cdot \rho_{pq}) - (\sum_{q=1}^n \sum_{p=1}^m y_{pq}^t) \cdot (\sum_{q=1}^n \sum_{p=1}^m \rho_{pq})]}{[\sum_{q=1}^n \sum_{p=1}^m (y_{pq}^t \cdot y_{pq}^t) - (\sum_{q=1}^n \sum_{p=1}^m y_{pq}^t)^2] \cdot [\sum_{q=1}^n \sum_{p=1}^m (\rho_{pq} \cdot \rho_{pq}) - (\sum_{q=1}^n \sum_{p=1}^m \rho_{pq})^2]}}$$

(10)

式中: n 为网络模型样本总数; R 代表网络整体的回归值,若 n 取训练集、验证集或测试集样本个数,则 R 分别对应网络对 3 种数据集拟合的回归值。共制作含双高阻块体的电阻率分界面模型 50 组,图 4 为部分模型样本示意,其中训练集:验证集:测试集=

40:5:5,选用四层 BP 神经网络,第一、二隐藏层节点数分别选择为 20 和 25,激活函数分别选择 tansig 和 logsig,网络终止条件为验证集连续 10 次误差不下降,关于 GA-BP 及 OMAGA 算法参数选择同第 1 节。




图 3 二维 OMAGA-BP 高密度电法反演成像流程

Fig. 3 2D OMAGA-BP high-density electrical inversion imaging diagram





图 4 部分电阻率模型样本示意

Fig. 4 Schematic diagram of some resistivity model samples

表 1 模拟数据训练 3 种网络的性能比较

反演网络	训练集 R 值	验证集 R 值	测试集 R 值	总体 R 值
BP	0.96175	0.95273	0.93846	0.95814
GA-BP	0.97779	0.9529	0.94298	0.97095
OMAGA-BP	0.99403	0.97646	0.96735	0.98909



a—电阻率测试模型示意;b—电阻率模型最小二乘法反演结果;c—BP 法反演结果;d—GA-BP 法反演结果;e—OMAGA-BP 法反演结果
a—schematic diagram of the test resistivity model;b—least-squares inversion result of resistivity model;c—BP inversion result;d—GA-BP inversion result;e—OMAGA-BP inversion result

图 5 测试模型示意及不同反演方法成像结果

Fig. 5 Schematic diagram of the test model and inversion imaging results of different methods

从表 1 中 3 种非线性算法回归值 R 的结果对比可以看出,OMAGA-BP 算法得到的各个回归值 R 结果都优于 GA-BP 以及 BP 算法,说明优化后的网络对输入、输出数据间的拟合能力显著提高。从图 5 显示的结果可以看出,最小二乘法反演结果无法分辨出电阻率分界面的拐点位置,并且两个高阻块体的电性异常叠加在了一起;而 BP 算法可以准确计算出两个高阻块体的纵向位置,但对两个高阻块体的横向位置反演结果准确性较差,且有较明显的边界失真现象;GA-BP 算法可以准确地计算出横纵向位置,但边界失真现象较 OMAGA-BP 算法得到的结果明显,说明 OMAGA-BP 算法具备更优的反演计算精度。而 3 种非线性方法的训练模型样本相同,OMAGA-BP 算法的结果更优,在一定程度上可以说明 OMAGA-BP 算法的泛化能力更优。

4 实测数据反演测试

为了进一步说明本文针对高密度电法二维数据反演建模方法的可靠性,笔者进行了实测数据反演测试,实测数据采集地点位于吉林大学朝阳校区篮球馆东侧防空洞,使用 EDJD-2 数字多功能直流电法仪进行数据采集,选用电极距为 1 m、电极个数为 36 个的温纳装置,共采集 11 层共 198 个视电阻率数据。目标为空洞探测,目标一为防空洞,其顶部距离地面将近 0.5 m,最深深度约为 2.25 m;防空洞北部有一下水巷道,其尺寸为 1 m×1.6 m,深度为 2 m,而防空洞北侧 3.5 m 左右有一排水管道,直径不到 0.15 m。图 6 为防空洞及数据采集示意。





图 6 防空洞及数据采集示意

Fig. 6 Bomb shelter and its data acquisition diagram



a—最小二乘法反演结果;b—BP 法反演结果;c—GA-BP 法反演结果;d—OMAGA-BP 法反演结果

a—least-squares inversion result;b—BP inversion result;c—GA-BP inversion result;d—OMAGA-BP inversion result

图 7 4 种反演方法对防空洞数据的反演结果

Fig. 7 Inversion results of air raid shelter data by four inversion methods

图 7 为最小二乘法、BP、GA-BP 及 OMAGA-BP 这 4 种算法对防空洞实测数据得到的反演结果,其中线性反演结果失真很明显,BP 法无法准确识别出下水管道的位置。而可以明显地看出 GA-BP 算法以及 OMAGA-BP 算法可以更准确地识别异常体的位置及轮廓,且 OMAGA-BP 算法对下水管的识别更胜一筹,进一步说明 OMAGA-BP 算法具备更优的反演计算精度及泛化能力;但存在轻微的失真现象,并且有很小的一块计算得到了负的电阻率值,负电阻率值的出现与输入数据归一化到 $[0, 1]$ 范围内有关。同时可以看 3 种非线性方法反演结果显示下水管道和防空洞附近有浅色阴影异常,这是由于图 6 所示的防空洞示意是一个三维模型,垂直于测线方

向上电性分布明显变化,而网络输入的模型数据是通过 2.5 D 正演软件设计的,导致计算误差,出现了假异常。

5 结论及讨论

本文实现了 OMAGA-BP 算法 ERT 反演成像方法,改善了 BP 算法损失函数空间存在大量鞍点,影响网络精度的问题。通过最小二乘法、BP 法、GA-BP 法、OMAGA-BP 法对含双高阻块体的分界面仿真模型及防空洞实测数据的反演成像结果的对比,说明 OMAGA-BP 算法具备更高的反演计算精度及泛化能力。

本文网络训练模型是通过 2.5 D 正演软件设计的,而实际反演计算的模型沿垂直测线方向电位分布明显变化,导致产生计算误差及假异常的现象,虽准确识别出异常体的位置及轮廓,但应指出使用 2.5 D 正演软件设计的模型数据训练的网络应适用于垂直测线方向电性分布不发生明显变化的实测数据。模型设计受限于 RES2DMOD 软件仅可以设计以规则块体为单元模型,限制了方法适用目标体的范围,针对此问题将在后续发表的论文中得到解决。

参考文献 (References):

- [1] 杨文采. 地球物理反演的理论与方法[M]. 北京:地质出版社, 1997.
Yang W C. Theory and method of geophysical inversion[M]. Beijing: The Geological Publishing House, 1997.
- [2] 何继善. 电法勘探的发展和展望[J]. 地球物理学报, 1997, 40(S1): 308-316.
He J S. Development and prospect of electrical prospecting method[J]. Chinese Journal of Geophysics, 1997, 40(S1): 308-316.
- [3] 何门贵, 温永辉. 高密度电阻率法二维反演在工程勘探中的应用[J]. 物探与化探, 2002, 26(2): 156-159.
He M G, Wen Y H. The application of high density resistivity 2D inversion to engineering exploration[J]. Geophysical and Geochemical Exploration, 2002, 26(2): 156-159.
- [4] 吕惠进, 刘少华, 刘伯根. 高密度电阻率法在地面塌陷调查中的应用[J]. 地球物理学进展, 2005, 20(2): 381-386.
Lyu H J, Liu S H, Liu B G. Application of resistivity tomography survey method in detecting ground subsidence[J]. Progress in Geophysics, 2005, 20(2): 381-386.
- [5] Loke M H, Barker R D. Least-squares deconvolution of apparent resistivity pseudosections[J]. Geophysics, 1995, 60(6): 1682-1690.
- [6] 徐海浪, 吴小平. 电阻率二维神经网络反演[J]. 地球物理学报, 2006, 49(2): 584-589.
Xu H L, Wu X P. 2-D resistivity inversion using the neural network method[J]. Chinese Journal of Geophysics, 2006, 49(2): 584-589.
- [7] Raiche A. A pattern recognition approach to geophysical inversion using neural nets[J]. Geophysical Journal International, 1991, 105(3): 629-648.
- [8] Calderón-Macías C, Sen M K, Stoffa P L. Artificial neural networks for parameter estimation in geophysics[J]. Geophysical Prospecting, 2000, 48(1): 21-47.
- [9] El-Qady G, Ushijima K. Inversion of DC resistivity data using neural networks[J]. Geophysical Prospecting, 2001, 49(4): 417-430.
- [10] Stephen J, Manoj C, Singh S B. A direct inversion scheme for deep resistivity sounding data using artificial neural networks[J]. Journal of Earth System Science, 2004, 113(1): 49-66.
- [11] Mann C J H. Geophysical applications of artificial neural networks and fuzzy logic[J]. Kybernetes, 2006, 35(3/4): 599-600.
- [12] Neyamadpour A, Taib S, Wan-Abdullah W A T W. Using artificial neural networks to invert 2D DC resistivity imaging data for high resistivity contrast regions: A MATLAB application[J]. Computers & Geosciences, 2009, 35(11): 2268-2274.
- [13] Neyamadpour A, Wan-Abdullah W A T, Taib S. Inversion of quasi-3D DC resistivity imaging data using artificial neural networks[J]. Journal of Earth System Science, 2010, 119(1): 27-40.
- [14] Neyamadpour A, Wan-Abdullah W A T, Taib S, et al. 3D inversion of DC data using artificial neural networks[J]. Studia Geophysica et Geodaetica, 2010, 54(3): 465-485.
- [15] Maiti S, Gupta G, Erram V C, et al. Inversion of Schlumberger resistivity sounding data from the critically dynamic Koyna region using the Hybrid Monte Carlo-based neural network approach[J]. Nonlinear Processes in Geophysics, 2011, 18(2): 179-192.
- [16] 张凌云. 高密度电阻率勘探反演的非线性方法研究[D]. 太原:太原理工大学, 2011.
Zhang L Y. The study of nonlinear inversion method in high-density resistivity method inversion[D]. Taiyuan: Taiyuan University of Technology, 2011.
- [17] 戴前伟, 江碧波. 基于混沌振荡 PSO-BP 算法的电阻率层析成像非线性反演[J]. 中国有色金属学报, 2013, 23(10): 2897-2904.
Dai Q W, Jiang F B. Nonlinear inversion for electrical resistivity tomography based on chaotic oscillation PSO-BP algorithm[J]. The Chinese Journal of Nonferrous Metals, 2013, 23(10): 2897-2904.
- [18] Dai Q W, Jiang F B, Dong L. Nonlinear inversion for electrical resistivity tomography based on chaotic DE-BP algorithm[J]. Journal of Central South University, 2014, 21(5): 2018-2025.
- [19] 高明亮, 于生宝, 郑建波, 等. 基于 IGA 算法的电阻率神经网络反演成像研究[J]. 地球物理学报, 2016, 59(11): 4372-4382.
Gao M L, Yu S B, Zheng J B, et al. Research of resistivity imaging using neural network based on immune genetic algorithm[J]. Chinese Journal of Geophysics, 2016, 59(11): 4372-4382.
- [20] Wu X X, Liu J G. A new early stopping algorithm for improving neural network generalization[C]//2009 Second International Conference on Intelligent Computation Technology and Automation. Changsha, China, IEEE, 2009: 15-18.
- [21] Dauphin Y N, Pascanu R, Gulcehre C, et al. Identifying and attacking the saddle point problem in high-dimensional non-convex optimization[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014.
- [22] 恽为民, 席裕庚. 遗传算法的全局收敛性和计算效率分析[J]. 控制理论与应用, 1996, 13(4): 455-460.
Hun W M, Xi Y G. The analysis of global convergence and computational efficiency for genetic algorithm[J]. Control Theory & Applications, 1996, 13(4): 455-460.
- [23] Chen L, Gallet A, Huang S S, et al. Probabilistic cracking prediction via deep learned electrical tomography[J]. Structural Health Monitoring, 2022, 21(4): 1574-1589.
- [24] Bishop C M. Training with noise is equivalent to tikhonov regularization[J]. Neural Computation, 1995, 7(1): 108-116.
- [25] An Z. The effects of adding noise during backpropagation training on a generalization performance[J]. Neural Computation, 1996, 8(3): 643-674.

Research on inversion of high-density resistivity method based on OMAGA-BP algorithm

LIU Xiang-Hao, LIU Si-Xin, HU Ming-Qi, SUN Zhong-Qiu, WANG Qian
(College of Geo-Exploration Sciences and Technology, Jilin University, Changchun 130061, China)

Abstract: High-density resistivity method is widely used in engineering exploration because of its efficient and intuitive features. However, due to the high nonlinearity of the inversion problem, the traditional inversion method has some inaccuracy in describing the boundary of anomalous body. In order to achieve high precision two-dimensional nonlinear inversion imaging with high-density electrical method, to overcome the problem that a large number of saddle points in the parameter space of loss function of BP algorithm affect the calculation accuracy and that it is difficult to assign optimal weight threshold to BP network due to the precocious convergence of general genetic algorithm. In this paper, an Optimum Maintaining Adaptive Genetic Algorithm(OMAGA) is proposed to optimize the BP neural network for high density electrical two-dimensional inversion imaging. Good results have been obtained for the inversion calculation of simulation model data and measured data through this method, it shows that this method has strong generalization ability and high inversion accuracy. This study is helpful for the accurate inversion of high density resistivity method in the future, it is helpful to improve the accuracy of underground target identification.

Key words: optimum maintaining adaptive genetic algorithm; BP neural network; high-density electrical method; inversion accuracy

(本文编辑:王萌)