doi: 10.11720/wtyht.2026.1198
张奋轩, 薛俊杰, 崔江伟, 等. 基于人工智能方法的瞬变电磁数据去噪[J]. 物探与化探, 2026, 50(5): 956-962. https://doi.org/10.11720/wtyht.2026.1198
Zhang F X, Xue J J, Cui J W, et al. An artificial intelligence-based method for denoising of transient electromagnetic data[J]. Geophysical and Geochemical Exploration, 2026, 50(5): 956-962. https://doi.org/10.11720/wtyht.2026.1198

基于人工智能方法的瞬变电磁数据去噪

张奋轩[1,2], 薛俊杰[3], 崔江伟[1,2], 古瑶[1,2]
(1. 自然资源部 煤炭资源勘查与综合利用重点实验室, 陕西 西安 710021; 2. 陕西省煤田物探测绘有限公司, 陕西 西安 710005; 3. 中国科学院 地质与地球物理研究所, 北京 100029)

摘 要: 瞬变电磁法在测量过程中易受到干扰, 因此去噪环节是其数据处理的关键步骤。传统的去噪方法需采用多种方法去除不同种类的噪声, 且这些方法受限于人工经验。本文提出利用人工智能深度学习方法对瞬变电磁数据进行去噪, 将有损信号输入到去噪自编码网络中, 经过编码以及解码工作后输出去噪后的数据。数值模拟结果表明利用深度学习神经网络方法可以较好地完成瞬变电磁数据去噪工作。

关键词: 瞬变电磁法; 人工智能; 神经网络; 深度学习; 去噪
中图分类号: P631.1;P31 **文献标识码:** A **文章编号:** 1000-8918(2026)05-0956-07

0 引言

瞬变电磁法(TEM)是一种时间域的电磁测深方法,具有勘探深度大、穿透高阻层能力强、随机干扰小、支持远区以及近区观测等特点, 被广泛应用于资源勘探和工程勘察领域, 是地球物理勘探中的重要技术手段[1]。在瞬变电磁测深中, 野外得到的实测信号具有动态、瞬变、受干扰大的特性, 而深部地质目标的瞬变电磁响应被淹没于噪声之中。噪声干扰主要来自外部的电磁噪声, 其中主要包括天然电磁场噪声及人类文化设施的噪声(即人文噪声), 所有干扰信号连同地质目标体的有用信号一起被测量到, 因此, 如何从如此多的干扰信号中提取有用信号对提高瞬变电磁数据的解释精度是至关重要的。高信噪比信号是数据分析以及处理的基本保障, 利用相关方法对含噪数据进行去噪处理, 对瞬变电磁数据的处理具有重要的意义。根据瞬变电磁法的扩散深度公式, 探测深度与测量时间成正比关系, 有效的晚期噪声压制以及去除技术可以有效提升最大探测深度[2-3]。因此, 噪声抑制处理即构成了瞬变电磁探测方法技术体系中非常重要的一环, 是瞬变电磁探测技术研究中的重点问题。想要获得更为准确的地质信息, 需要对各种干扰噪声进行处理[4]。

传统的电磁数据去噪方法基于功率谱估计的傅里叶变换, 因其时域局部性质无法表达信号特征, 国内学者们先后利用小波分析法来消除电磁噪声[5-6]。王书明等[7] 通过研究不同地区实测的大地电磁信号特征, 认为大地电磁信号具有非最小相位、非线性以及非高斯性等性质, 要解决电磁的噪声问题需要使用新的信号处理办法; 曹小玲等[8] 采用 M-FastICA 算法在独立分量分析算法上进行了补充, 证实了该方法在大地电磁去噪中的有效性。

远参考方法、小波去噪、物理去噪、经验模态分解法等都常被用于噪声处理, 然而上述方法往往只能针对单一的噪声类型进行去除[9-10]。去噪自编码器 (denoising auto-encoder, DAE) 是一种以有损信号作为输入, 通过训练实现对无损信号准确预测的自编码器 (auto-encoder, AE) 神经网络[11], 其训练过程属于非监督学习。相比传统方法, DAE 基于深度学习, 通过大量数据训练实现对网络参数的最优化调整, 此过程即通过机器经验在某种程度上替代人的

收稿日期: 2025-06-10; **修回日期:** 2026-03-10
基金项目: 陕西投资集团有限公司科技研发项目(SIGC-2024-KY-02); 陕西省煤田地质集团有限公司科技研发重大专项(SMDZ-2023ZD-8)
第一作者: 张奋轩(1971-), 男, 高级工程师, 主要从事煤田地球物理勘探工作。Email: 302912704@qq.com
通讯作者: 薛俊杰(1992-), 男, 博士后, 主要从事电磁场响应与反演成像算法研究工作。Email: junjie_58@126.com

经验, 从而增强了处理过程的客观性[12-14]。

1　DAE 网络去噪原理

有损信号(数据质量损坏)主要由噪声干扰或数据段残缺造成。如图 1 所示, 假设输入信号为受噪声干扰的有损信号 R_n, 输出信号为不含噪的无损信号 R, 两者间的关系假设为 $R_n = R +$ noise (noise 为噪声信号), 则在同一时刻, 两者的信号长度均为 6 个采样。

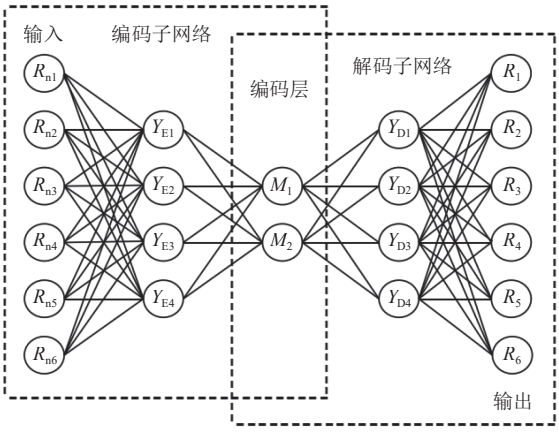


图 1　DAE 基本结构示意

Fig. 1　Schematic diagram of the basic structure of DAE

以 R_n 作为输入, 建立一个 DAE 神经网络, 包含编码 (encoder) 和解码 (decoder) 两个子网络, 这两个子网络均包含一个隐含层, 即 Y_E 和 Y_D。输入信号进入编码子网络后, 经过正向传播, 被大幅降维, 得到原信号的一种稀疏表示, 即 Code 层[12]。解码子网络以 Code 为输入信号, 实现对原始无噪信号的还原, 即输出 R。

在 DAE 中, 隐含层的工作原理如图 2 所示。以编码子网络中 Y_E 层第一个节点 Y_{E1} 为例:

$$Y_{E1} = G(V_1) = F(K_1 R_n + c_1)。\qquad (1)$$

式中: K_1 和 c_1 分别为对应隐含层节点 1 的权重系数与偏置系数; G 为激活函数。深度学习领域中常见的激活函数包括 sigmoid、tanh、ReLU、softmax 等, 因性能不同而用途各不相同。

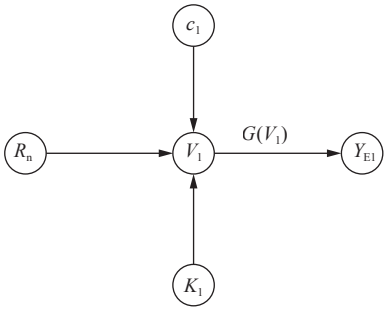


图 2　编码子网络隐含层节点工作过程示意

Fig. 2　Schematic diagram of the working process of hidden layer nodes in the encoding sub network

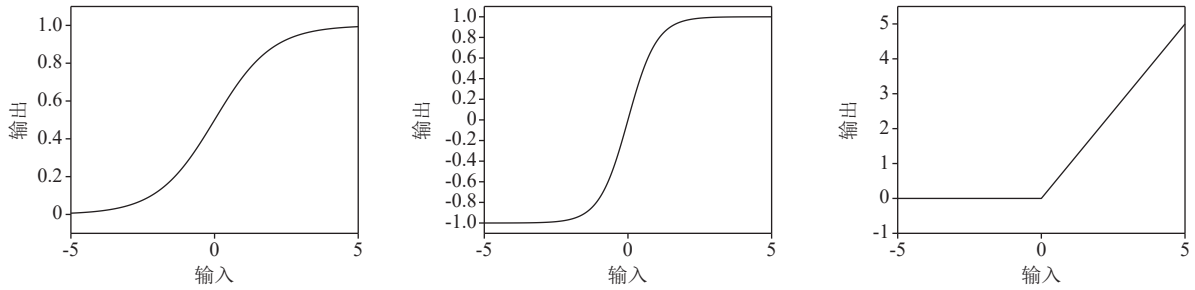
以相同的方式、不同的系数, 隐含层 Y_E 中的各节点值被进一步传播得到编码层, 即编码子网络的输出层。通过编码子网络, 输入信号被大幅降维, 得到其中对原输入信号的新的特征表达, 可以认为是对原输入信号的稀疏表示, 即 Code。以 Code 为输入, 解码子网络采用相同的传播方式、不同的系数, 经过一个隐含层 Y_D, 将 Code 中包含的信号信息进行还原, 从而实现对不含噪信号的重构(预测)。在本例中, 编码和解码子网络均仅包含一个隐含层。理论上, 如果可以实现有效训练, 则隐含层越多, 能够实现的信息压缩与重构越精细。

由此可见, 基于 DAE 实现噪声抑制的数学过程本质是: 首先, 对原始数据进行降维处理(编码过程), 得到原始数据的稀疏表示(得到的 Code); 然后, 有选择地对上述稀疏表示进行还原(依赖于解码子网络中的网络系数与激活函数), 使其仅还原希望还原的部分, 从而实现对原始数据中噪声部分的抑制。换句话说, 通过大量训练, DAE 网络中的编码子网络能够非常准确地将原始数据中包含的各类信号压缩为有限个特征, 而解码子网络则能够依据这些特征, 通过调整网络系数准确地还原有用信号, 抑制噪声信号。

2　DAE 网络参数

激活函数是人工神经网络的一个重要特征, 它决定一个神经元是否应该被激活, 即该神经元是否应该完成向后的信息传递。在建立 DAE 时需要非常慎重地选择激活函数, 因为激活函数一旦选定, 在整个训练及应用过程中均是无法修改的。目前, 在深度学习中常见的激活函数有 softmax、sigmoid、tanh、ReLU 等(图 3)。

softmax 函数的功能是将同层各节点的输出值统一转为概率值, 因此常被用于分类任务。然而, 在 SOTEM 去噪研究中, 问题本质是回归问题, 因此 softmax 函数并不适用。在常见激活函数里, sigmoid 或 tanh 函数可以用于回归问题, 但其抗梯度消失能力有限。随着近年来面向图像处理的深度学习技术的快速发展, ReLU 函数因其优异的性能成为目前深度学习神经网络设计中使用最广泛的激活函数。然而, 在面向含噪航空电磁探测数据时, 该激活函数完全关闭了负值节点, 经过多次测试, 认为 ReLU 函数



(a) Sigmoid函数 (b) Tanh函数 (c) ReLU函数

图 3 常见的三种激活函数

Fig. 3 Three common activation functions

的表现并不如在图像处理领域中那么突出。为此，引入了 ReLU 激活函数的一种发展型——SeLU 激活函数 (图 4)，其定义如下：

$$\begin{cases} f(x)=\lambda\cdot IN, & IN\geqslant 0; \\ f(x)=\lambda\alpha(\mathrm{e}^{IN}-1), & IN<0。 \end{cases} \tag{2}$$

式中：λ、α 为缩放因子，其中 λ=1.050 700 987 36，α=1.673 263 242 35；$f(x)$为网络输入参数；IN 为输出参数。SeLU 激活函数相对于 ReLU 激活函数，一是提升了对负值区的激活能力，二是其激活值平均为零，能加快模型收敛。

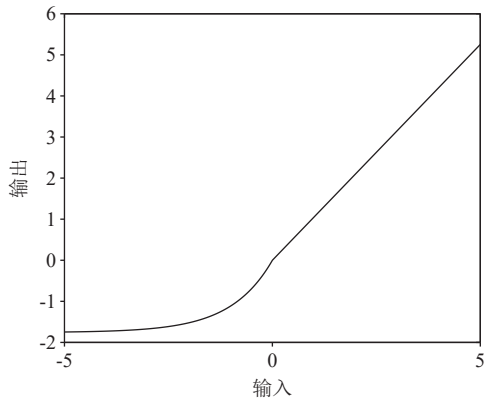


图 4 SeLU 激活函数

Fig. 4 SeLU activation function

在面向多源噪声处理的 DAE 中，损失函数 (loss function) 描述了神经网络预测结果与理论结果之间的差异，本文采用 mean-square error (MSE) 作为误差函数，记作LF_{MSE}：

$$LF_{\mathrm{MSE}}=\frac{1}{N}\sum_{n=1}^{N}\left\|R_p(n)-R(n)\right\|^2。 \tag{3}$$

式中：R_p为不含噪声的标签信号；R为预测的去噪信号；n 为时间道数。

在完成正向传播后(即由输入计算输出的过程)，需要利用损失函数结果，通过将其在神经网络中反向传播来实现对网络系数的更新。本文采用 Adam(adaptive moment estimation) 计算网络系数：

$$w_{i+1}=w_i-\frac{\alpha}{\sqrt{\hat{S}_i+\varepsilon}}\hat{V}_i, \tag{4}$$

$$\hat{V}_i=\frac{V_i}{1-\beta_1^i}=\frac{\beta_1 V_{i-1}+(1-\beta_1)\dfrac{\partial LF}{\partial w_i}}{1-\beta_1^i}, \tag{5}$$

$$\hat{S}_i=\frac{S_i}{1-\beta_2^i}=\frac{\beta_2 S_{i-1}+(1-\beta_2)\left(\dfrac{\partial LF}{\partial w_i}\right)^2}{1-\beta_2^i}。 \tag{6}$$

式中：w为权重系数；V_0 和 S_0 均为 0，分别表示初始的一阶和二阶矩估计；方法提出者给出的参数 α、β_1、β_2、ε 的推荐值分别为 0.001、0.9、0.999、10^{-8}。在本项研究中，为增加训练初期学习速度，一般会把学习速率 α 设为 0.01，其他参数保持不变。

DAE 数据处理流程可分为以下几个步骤：①数据输入，将含噪电磁数据输入到 DAE 网络中；②特征提取，编码器模块通过非线性变换，将含噪数据映射到低维特征空间，并且在此过程中过滤噪声；③信号重建，将编码器模块的输出部分输入到解码器模块，重建出理想的瞬变电磁信号。

3 仿真测试

采用 Tensorflow 完成 DAE 的设计，并使用一个 NVIDIA RTX 2080Ti GPU 完成 DAE 的训练工作。在本算例中，所设计的 DAE 结构为 500-200-50-200-500，即输入及输出节点数为 500，Code 层节点数为 50，编码和解码子网络中的隐含层节点数均为 200。完成 DAE 设计后，对训练数据进行模拟准备，同时利用前期获取的实际数据，将运动噪声、中近源天电噪声、工频噪声以及背景 EM 噪声等与模拟数据结合，合成数据后将 100 000 条训练数据导入网络，经过约 30 万 epochs 的训练(增大训练 epoch 数，还可进一步提升 DAE 性能)，认为 DAE 基本达到要求。

如图 5a 所示，设计 1 个三层模型，在高阻背景

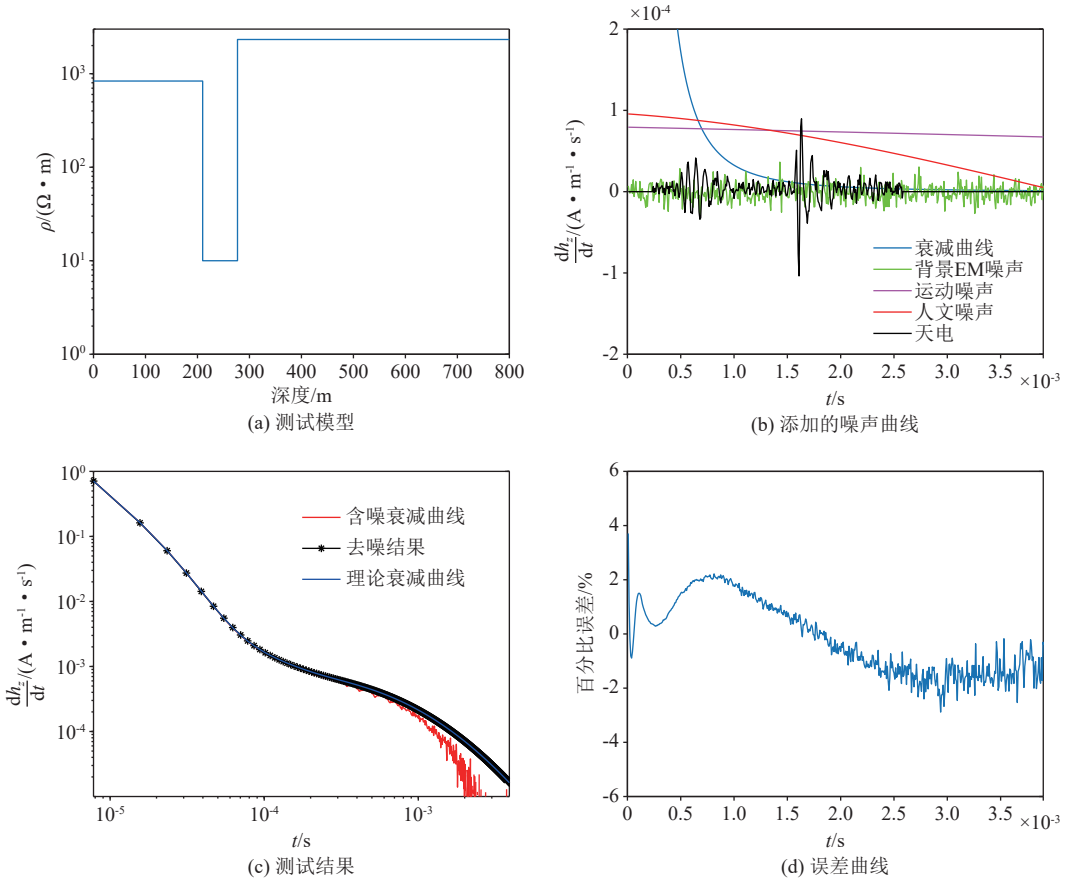


图 5　基于 DAE 的 SOTEM 电磁探测多源噪声抑制方法测试结果

Fig. 5　Test results of multi-source noise suppression method for SOTEM electromagnetic detection based on DAE

下存在一低阻层, 其电阻率为 10 Ω·m, 厚度为 67 m。利用上述模型计算理论衰减曲线, 并随机分别选取背景 EM 噪声、工频噪声、运动噪声及中近源天电噪声。如图 5b 可见, 背景 EM 噪声为中值为零的白噪声, 运动噪声整体为正值, 工频噪声整体为负值, 中近源天电大约位于 500 μs 处。由于运动噪声频率相对较低, 在约 4 ms 的时间长度内, 其曲线特征并不明显。将理论衰减曲线与上述噪声叠加作为输入数据, 带入训练好的 DAE, 经过一次向前传播得到处理结果(图 5c)。图 5d 为噪声去除结果相对理论衰减曲线的百分比误差, 表明在整个处理过程中, 结果相对于理论值的百分比误差基本可认为小于 5%, 尤其是晚期段, 百分比误差整体小于 1%。

由于已经完成了神经网络训练, 因此仅需要将待处理数据作为输入数据, 经过一次向前传播即可得到处理结果。图 5 所示算例的整个处理结果仅耗时 0.021 s。传统的处理方法一般采用一个处理流程, 分别对数据进行特征分析与处理。基于 DAE 的深度学习方法通过大量训练数据, 将对信号进行特征分析的时间搬移至了获取实测数据之前, 从而在获取实测数据之后可以以非常快的速度实现对数据的处理, 显著压缩了处理时间, 提高了工作效率。

由上述算例可见, 经过训练的 DAE 对航空电磁探测中的多源噪声具有良好的抑制性能, 能够非常有效、准确地从含噪数据中将理论响应曲线提取出来。为进一步提升 DAE 的泛化性能, 只需要进一步建立基于更多层电阻率模型的训练数据集, 即可达到图 5 的处理效果。此外, 还可以采用基于传统方法获取的实测数据训练集对 DAE 进行训练, 从而进一步提升网络的泛化性能。

4　野外测试

测试地点位于山西晋城, 区域上大致由南向北依次出露奥陶系、石炭系、二叠系, 第四系广泛覆盖于上述各时代地层之上, 选择电性源时间域地空电磁法作为本次的地球物理普查勘探方法。本次项目采用 1∶10 000 的比例尺进行施工, 其中地空电磁法采用 100 m 线距的航线间距, 采样间隔由仪器采样率、发射基频和实际飞行速度共同决定, 实测测点间距约为 8 m。测区位置如图 6 所示。

根据搜集到的已知地质资料, 在晋城 B 区 JCB-

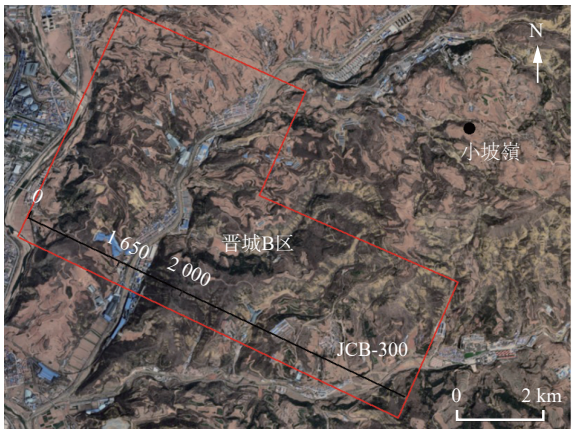


图 6　测试区地形地貌

Fig. 6　Topography and geomorphology of the test area

300 线(50~1 650 段)开展了地空电磁对已知采空区的探测,采用的主要参数为:源长 1 700 m,供电电流 40 A,发射基频 12.5 Hz,预设飞行速度 8 m/s,飞行高度 50 m。

本次实验发射源采用长导线源,共计 1 700 m,发射电流 40 A,基频 12.5 Hz。地空电磁接收系统由接收线圈(图 7)、多通道接收机和通讯系统组成。因其需要搭载于无人飞行平台上(图 8),因此对电磁接收机提出了较高的要求:接收系统需要具有轻便化、小型化、低功耗的特点。



图 7　接收系统

Fig. 7　Receiving system



图 8　旋翼无人机

Fig. 8　Rotary wing drone

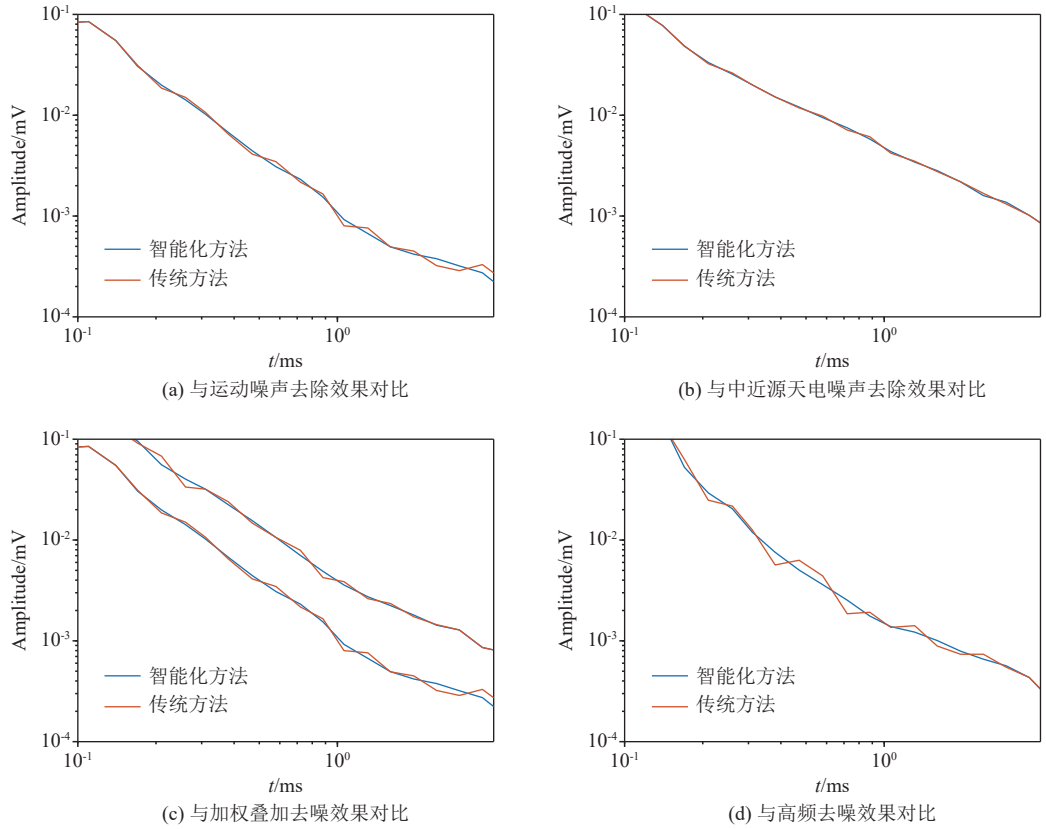
智能式去噪方法基于去噪自编码器神经网络,最早被用来开展全航空瞬变电磁法噪声去除,获得了良好的处理效果。然而,将其直接引入半航空瞬变电磁数据处理中尚有困难,其主要难点在于:全航空瞬变电磁系统收发装置的位置相对固定,但对于半航空系统而言,在整个观测过程中,收发装置的相对位置始终处于变动状态,导致相同的大地结构在不同偏移距、不同高程上的观测结果本身具有不同的特征,由此导致直接对信号进行特征提取存在重构困难。为此,在开展处理之前,首先对原始数据进行变换,将其由时间序列转为特征序列,在此基础上,将高程与偏移距作为两个额外特征加入信号的特征序列,并以此作为网络训练的输入数据。经过训练后的输出结果在删除高程和偏移距后,对余下的特征序列进行反变换,从而实现对时间序列的重构。需要指出的是:时间序列与特征序列之间的正反变换过程是由一个非线性网络实现的,其功能是按照需求输出给定数目(长度)的特征序列。

图 9 为智能式处理方法与 4 种传统流程式去噪方法(运动噪声去除、中近源天电噪声、加权叠加去噪、高频去噪)的结果对比,可以看到,流程式处理方法的晚期数据仍有较大可能受剩余噪声的影响,而智能式处理方法的结果更为平滑,说明噪声得到了有效去除。

图 10 为 JCB-300 线 50~1 650 区段地空瞬变电磁数据(去噪后)的反演电阻率断面。该测线位于测区西南方向,测线所涵盖区域全区大部已采掘,仅余部分未采区域和巷道,采掘时间为 2004~2008 年,该采空区回采率较高,于 2010 年封闭,经了解采空区内部分积水,其积水区位置在图 10 中显示。从图中可以看出,标高 400 m 附近区域整体呈弱低阻反映,该低阻异常所在深度与 3#煤层及附近含水砂岩层较为吻合;在标高 200~300 m 出现明显电性界面层,且该电性界面以深呈现明显高阻,与区内奥灰顶界面及奥陶系地层电性特征较为吻合。在位于标高 360~380 m 处的 50~300 m 及 500~1 200 m 区段存在 2 个明显的强低阻区,与搜集到的已知积水区基本吻合。

5　结论

高信噪比的原始数据是信号分析以及解释的重要前提,本文针对瞬变电磁数据的去噪问题,系统性地构建了一种自编码器深度学习网络,该网络可以精确、快速地提取有用信号,通过数值模拟与实测案例,验证了本文提出方法的有效性。



(a) 与运动噪声去除效果对比　(b) 与中近源天电噪声去除效果对比

(c) 与加权叠加去噪效果对比　(d) 与高频去噪效果对比

图 9　智能式方法与传统流程式去噪方法处理结果对比

Fig. 9　Comparison of processing results between intelligent methods and process based denoising methods

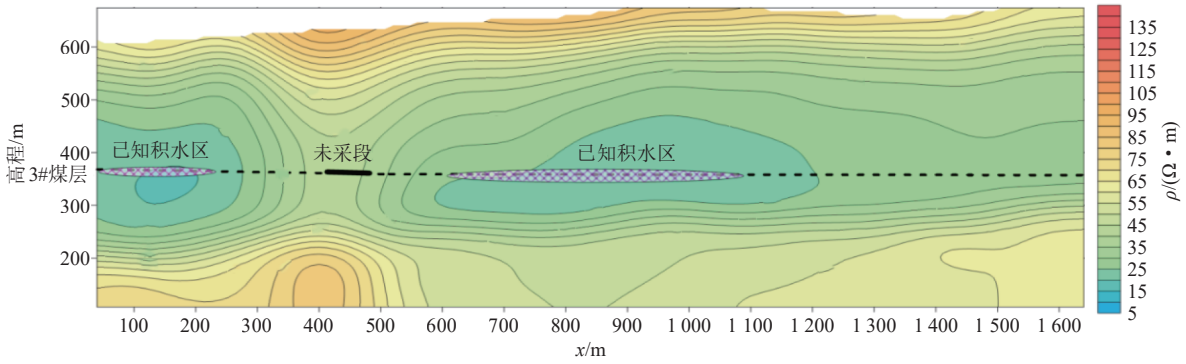


图 10　JCB-300 线(局部)时间域地空电磁反演电阻率断面

Fig. 10　JCB-300 line (partial) time domain Semi aerial electromagnetic detection resistivity inversion section

参考文献(References):

[1] 柳建新, 赵然, 郭振威. 电磁法在金属矿勘查中的研究进展 [J]. 地球物理学进展, 2019, 34(1): 151−160.
Liu J X, Zhao R, Guo Z W. Research progress of electromagnetic methods in the exploration of metal deposits[J]. Progress in Geophysics, 2019, 34(1): 151−160.

[2] Combrinck M. The Impact of AEM receiver noise levels on detection, discrimination and resolvability of conductive targets[C]//Expanded Summary of the 21st International Geophysical Conference and Exhibition, Australian Society of Exploration Geophysicists, 2010.

[3] 闫述, 石显新, 陈明生. 瞬变电磁法的探测深度问题 [J]. 地球物理学报, 2009, 52(6): 1583−1591.
Yan S, Shi X X, Chen M S. The probing depth of transient electromagnetic field method[J]. Chinese Journal of Geophysics, 2009, 52(6): 1583−1591.

[4] 武欣, 薛国强, 陈卫营, 等. 半航空电磁法全流程低噪声关键技术研究 [J]. 地球物理学报, 2023, 66(9): 3904−3913.
Wu X, Xue G Q, Chen W Y, et al. Research on key technologies of the low-noise system for Semi-airborne electromagnetic method[J]. Chinese Journal of Geophysics, 2023, 66(9): 3904−3913.

[5] 何兰芳, 王绪本, 何展翔, 等. MT 时间序列的小波去噪分析 [J]. 地震地质, 2001, 23(2): 222−226.
He L F, Wang X B, He Z X, et al. Wavelet-based denoising of MT time series[J]. Seismology and Geology, 2001, 23(2): 222−226.

[6] 凌振宝, 王沛元, 万云霞, 等. 强人文干扰环境的电磁数据小波去

噪方法研究 [J]. 地球物理学报, 2016, 59(9): 3436−3447.
Ling Z B, Wang P Y, Wan Y X, et al. A combined wavelet transform algorithm used for de-noising magnetotellurics data in the strong human noise[J]. Chinese Journal of Geophysics, 2016, 59(9): 3436−3447.

[7] 王书明, 王家映. 关于大地电磁信号非最小相位性的讨论 [J]. 地球物理学进展, 2004, 19(2): 216−221.
Wang S M, Wang J Y. Discussion on the non-minimum phase of magnetotelluric signals[J]. Progress in Geophysics, 2004, 19(2): 216−221.

[8] 曹小玲, 严良俊. 一种改进的独立分量分析算法在大地电磁去噪中的应用 [J]. 石油物探, 2017, 56(6): 890−897.
Cao X L, Yan L J. The application of an improved independent component analysis algorithm in magnetotelluric data denoising[J]. Geophysical Prospecting for Petroleum, 2017, 56(6): 890−897.

[9] 杨俊, 李静和, 孟淑君, 等. 小波与曲波变换探地雷达数据去噪对比分析 [J]. 地球物理学进展, 2019, 34(5): 2097−2105.
Yang J, Li J H, Meng S J, et al. Comparative analysis of ground penetrating radar data denoising with wavelet transform and curvelet transform[J]. Progress in Geophysics, 2019, 34(5): 2097−2105.

[10] Spies B R. Local noise prediction filtering for central induction transient electromagnetic sounding[J]. Geophysics, 1988, 53(8): 1068−1079.

[11] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders[C]//Proceedings of the 25th International Conference on Machine Learning. ACM, 2008: 1096-1103.

[12] 滑世辉, 韩立国. 基于深度卷积自编码网络地震数据去噪方法 [J]. 地球物理学进展, 2023, 38(2): 654−661.
Hua S H, Han L G. Seismic data denoising method based on deep convolutional auto-encoder network[J]. Progress in Geophysics, 2023, 38(2): 654−661.

[13] 柳炳利, 谢淼, 孔韫辉, 等. 基于卷积自编码网络的夏河—合作地区金矿定量预测 [J]. 地球学报, 2023, 44(5): 877−886.
Liu B L, Xie M, Kong Y H, et al. Quantitative gold resources prediction in Xiahe-Hezuo area based on convolutional auto-encode network[J]. Acta Geoscientia Sinica, 2023, 44(5): 877−886.

[14] 杨德贺, 王秀英, 申旭辉, 等. 基于自编码网络的浅源和深源诱发型微震识别 [J]. 地球物理学进展, 2018, 33(5): 1844−1853.
Yang D H, Wang X Y, Shen X H, et al. Discrimination of shallow and deep induced-microearthquakes based on autoencoder network[J]. Progress in Geophysics, 2018, 33(5): 1844−1853.

An artificial intelligence-based method for denoising of transient electromagnetic data

ZHANG Fen-Xuan [1, 2], XUE Jun-jie [3], CUI Jiang-Wei [1, 2], GU Yao [1, 2]

(1. *Key Laboratory of Coal Resources Exploration and Comprehensive Utilization, Ministry of Natural Resources, Xi'an* 710021, *China*; 2. *Shaanxi Coalfield Geophysical Prospecting and Surveying Co., Ltd., Xi'an* 710005, *China*; 3. *Institute of Geology and Geophysics, Chinese Academy of Sciences, Beijing* 100029, *China*)

Abstract: Since the transient electromagnetic (TEM) method is susceptible to interference during surveys, denoising is a key step in TEM data processing. For conventional denoising methods, multiple techniques are required to suppress various types of noise, while the performance of these methods depends on manual experience. This study proposes a method for denoising of TEM data using artificial intelligence and deep learning. Specifically, signals bearing noise are input to the self-coding network for denoising, while the denoised data are output after encoding and decoding. Numerical simulation results indicate that the method using deep learning and neural networks enables the effective denoising of TEM data.

Key words: transient electromagnetic (TEM) method; artificial intelligence; neural network; deep learning; denoising

（本文编辑：王萌, 沈效群）