

doi: 10.11720/wtyht.2023.1347

吴嵩, 宁晓斌, 杨庭伟, 等. 基于神经网络的探地雷达数据去噪[J]. 物探与化探, 2023, 47(5): 1298-1306. <http://doi.org/10.11720/wtyht.2023.1347>

Wu S, Ning X B, Yang T W, et al. Neural network-based denoising for ground-penetrating radar data[J]. Geophysical and Geochemical Exploration, 2023, 47(5): 1298-1306. <http://doi.org/10.11720/wtyht.2023.1347>

基于神经网络的探地雷达数据去噪

吴嵩¹, 宁晓斌^{2,3}, 杨庭伟^{2,3,4}, 姜洪亮^{2,3,4}, 卢超波^{2,3,4}, 苏煜堤²

(1. 广西田新高速公路有限公司, 广西南宁 530022; 2. 广西交科集团有限公司, 广西南宁 530007; 3. 广西壮族自治区公路隧道安全预警工程研究中心, 广西南宁 530007; 4. 广西道路结构与材料重点实验室, 广西南宁 530007)

摘要: 探地雷达数据在实际工程检测过程中常被各种随机噪声污染, 而数据中的噪声会降低数据的信噪比和分辨率, 进而给后续的反演和解释等工作带来不利影响。对此, 本文开展了基于神经网络的探地雷达数据去噪研究。首先, 建立 1 个多层神经网络, 向无噪声数据加入高斯白噪声破坏数据。然后, 将破坏后的数据和其对应的噪声的 patch 建立训练数据, 通过反向传播算法更新模型各层神经元权重, 使得模型训练损失值最小。最后, 将两个合成数据和实测雷达数据输入到已训练好的模型, 用其训练得到噪声特性权重计算模型输出。通过与曲波法的数值模拟试验结果对比验证了本文方法的有效性和鲁棒性, 且本文方法对结构复杂、幅值较弱区域的噪声压制更彻底, 有效信号展现得更清晰。

关键词: 探地雷达(GPR); 神经网络; 多层感知机; 反向传播; 高斯白噪; 数据去噪

中图分类号: P631.4 **文献标识码:** A **文章编号:** 1000-8918(2023)05-1298-09

0 引言

工程实际工作环境的复杂性使得工程人员在该试验场所获得的探地雷达数据很容易夹杂各种噪声, 能否有效地消除数据中混杂的噪声已成为解释成果正确与否的关键环节^[1-3]。

探地雷达数据中混杂的噪声根据其特性可分为不规则的随机噪声和规则的相干噪声, 早期雷达传统的去噪方法主要包括 F-K 滤波法^[4]、F-X 滤波法^[5]、小波去噪^[6]、曲波去噪^[7]、奇异值分解法^[8]以及多项式拟合去噪^[9]等。其中, 基于稀疏变换的数据去噪方法因其易于实现且普适性强的优点成为了近些年十分流行的方法。尽管基于稀疏变换的去噪方法取得了不错的效果, 然而这类方法由于基函数的特性有时会在去噪结果中带入新的噪声^[10], 且在一些复杂构造细节的噪声去除方面上难以满足人们

对探地雷达数据的要求, 因此大量学者不断探寻更有效获得高质量数据的去噪方法。

近年来, 随着计算机的硬件和算法的高速发展, 以神经网络为代表的人工智能在科学与工程等诸多领域取得了令人瞩目的成就, 尤其在图像识别^[11]、图像分类^[12]、参数反演^[13]、目标预测^[14]、图像去噪^[15]、滑坡监测^[16]等方面。Silver 等^[17]开发了 1 个基于神经网络和树搜索组合的围棋程序 AlphaGo, 在测试中对战其他围棋程序的胜率达到了 99.8%, 并以 5 比 0 击败了人类欧洲围棋冠军。Krizhevsky 等^[18]训练了 1 个大型的深度卷积神经网络, 在测试数据上, 分别实现了 37.5% 和 17.0% 的 top-1 和 top-5 错误率, 这大大优于之前的最新技术。Jain 等^[19]提出了使用卷积网络作为图像处理架构和从特定噪声模型合成训练样本的无监督学习过程, 并在自然图像去噪的挑战性问题上演示了这种方法。Lecun 等^[20]将卷积神经网络(convolutional neural net-

收稿日期: 2022-07-26; 修回日期: 2023-05-30

基金项目: 广西重点研发计划项目(AB21220069)

第一作者: 吴嵩(1984-), 男, 本科, 主要从事高速公路、铁路项目建设管理工作。Email: 262607406@qq.com

通讯作者: 宁晓斌(1994-), 男, 硕士, 主要从事公路试验检验检测工作。Email: 631118892@qq.com

works, CNN)应用于交通标志的分类任务。CNN 展示了一种专门为图像数据设计的结构,与普通的多层感知机(multi-layer perceptron, MLP)相比,在训练数据量较小时仍然提供较好的结果^[21]。另一方面,多层感知器可能比 CNN 更强大:MLP 可以被认为是通用函数逼近器,而 CNN 限制了可能的学习函数的类别^[22]。Hornik 等^[23]表示只要有足够多的隐藏单元可用,标准多层感知机就可以使用任意的压缩函数将任何 Borel 可测量函数从一个有限维空间逼近到另一个有限维空间,达到所需的任何准确度。Burger 等^[24]将多层感知机应用于图像去噪,通过算法描述有噪声图像到无噪声图像的映射问题,并证明了在大量图像数据库训练的基础上可以媲美当前最先进的去噪方法。由于神经网络学习方法不需要满足特定的先验条件,因此在探地雷达数据处理中也得了一些初步的应用研究,例如煤层界面识别^[25]、隧道衬砌结构自动识别^[26]和参数反演^[27]。

本文设计了 1 个 2 层的感知机模型,模型的输入为混入了高斯白噪声的数据,输出为去噪后的数据,损失函数为平方损失函数,即输出结果对应未加入噪声数据的方差。为了进一步验证该方法去除随机噪声的效果,加入曲波法对同一含噪数据进行去噪比对,根据信噪比结果表明了本文提出的去噪方法对随机噪声压制拥有更出色的能力。

1 方法原理

1.1 MLP 去噪原理

探地雷达数据去噪可以看作是 1 个有噪声数据到无噪声数据的映射问题,所以我们可以建立 1 个 MLP 网络模型展示输入与输出之间的映射关系。

假设探地雷达数据为 \mathbf{y} , 本文仅对随机噪声数据进行了训练,假设 \mathbf{n} 为高斯白噪声,则含噪声的雷达数据 \mathbf{x} 如下式表示:

$$\mathbf{x} = \mathbf{y} + \mathbf{n} \quad (1)$$

根据 MLP 建立出含噪声数据 \mathbf{x} 和无噪声数据 \mathbf{y} 关于映射问题的网络模型可表示为

$$\mathbf{y} = H(\mathbf{x}, \boldsymbol{\theta}) \quad (2)$$

式中: H 表示 MLP 网络结构; $\boldsymbol{\theta}$ 表示网络参数的集合。

1.2 MLP 网络结构

MLP 也称人工神经网络 (artificial neural network, ANN), 它可以将输入层的输入向量值通过 1 个或多个隐藏层映射到输出层输出向量值,神经网络中单个的神经元如图 1 所示。

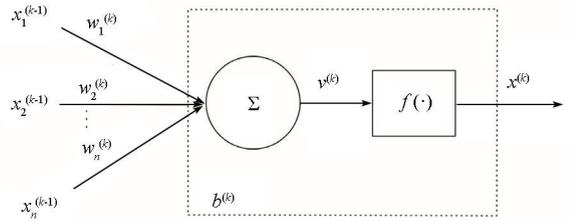


图 1 单个神经元模型

Fig. 1 Single neuron model

图 1 中, $\mathbf{x} = (x_1^{k-1}, x_2^{k-1}, \dots, x_n^{k-1})^T$ 表示神经元的 n 个输入; $w_1^{(k)}, w_2^{(k)}, \dots, w_n^{(k)}$ 为输入权重; $b^{(k)}$ 表示神经元的偏置; $f(\cdot)$ 为激活函数; $v^{(k)}$ 为神经元权值向量和输入向量的线性加权; $x^{(k)}$ 为神经元的输出,则单个的神经元输出可表示为:

$$v^{(k)} = \sum_{i=1}^n w_i^{(k)} x_i^{(k-1)} = (w_1^{(k)}, w_2^{(k)}, \dots, w_n^{(k)}) \begin{pmatrix} x_1^{(k-1)} \\ x_2^{(k-1)} \\ \vdots \\ x_n^{(k-1)} \end{pmatrix} \quad (3)$$

由上式可知,当没有激活函数时,输入和输出展现的是一种线性组合形式。加上激活函数后,非线性因素被引入神经元中,使得神经网络可以任意逼近任何非线性函数,这样神经网络就可以解决更复杂的非线性问题了。然而仅仅单层神经网络无法解决更为复杂的线性不可分问题,由此引入了多个神经元并列分层的方式,在输入层和输出层之间增加 1 个隐藏层,即多层感知机。多层感知机的简化模型如图 2 所示。

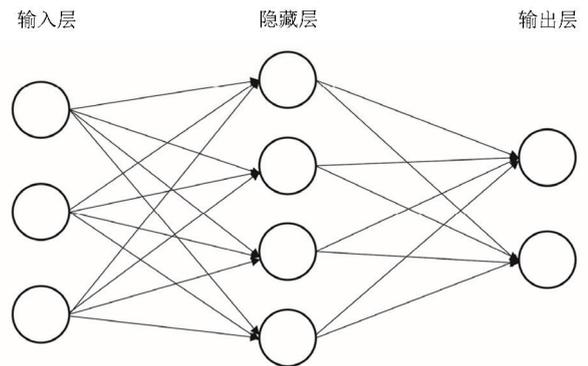


图 2 含 1 个隐藏层的感知机模型

Fig. 2 MLP with one hidden layer

目前,本文对神经网络的结构图的讨论中尚未提到偏置节点。实际上,偏置节点是默认存在的,它本质上是 1 个只含有存储功能,且存储值永远为 1 的单元。在神经网络的每个层次中,除了输出层以外,都会含有这样一个偏置单元,我们设这些参数值为向量 \mathbf{b} ,称之为偏置。

1 个简单的 3 层感知机可表示为

$$f(\mathbf{x}) = \mathbf{b}_2 + \mathbf{W}_2 s(\mathbf{b}_1 + \mathbf{W}_1 \mathbf{x}), \quad (4)$$

式中: s 为 Sigmoid 激活函数, 能将输入的连续实值变化为 0~1 之间的输出, 若是很大的负数, 输出为 0; 若是很大的正数, 则输出为 1。

1.3 批规范化

神经网络的训练中常采用随机梯度下降的优化方法, 当训练数据量比较庞大时, 可以将数据集拆解为多个批次 (Batch), 分别训练每个 Batch 的数据。

批规范化^[28]在深度学习发展中具有划时代的意义, 它提高了模型的训练速度和模型的泛化能力。规范化公式可写作

$$\tau = \frac{\alpha_i - \mu}{\sigma_i}, \quad (5)$$

$$a_i^{\text{norm}} = \gamma_i \tau + \beta_i, \quad (6)$$

式中: α_i 为某个神经元的原始激活值; a_i^{norm} 为规范后的值; γ_i 和 β_i 用于控制输出值分布的形态, 目的是使得网络的非线性; μ 为平均值, 其表达式为

$$\mu = \frac{1}{m} \sum_{k=1}^m \alpha_k, \quad (7)$$

ε 为一接近 0 的较小数值, 目的是使标准差 σ_i 不为 0, σ_i 可表示为

$$\sigma_i = \sqrt{\frac{1}{m} \sum_{k=1}^m (\alpha_k - \mu)^2 + \varepsilon}. \quad (8)$$

神经网络通过批规范化操作能够增大学习率, 缩短训练时间, 提升训练速度, 进而可以实现更复杂的多层神经网络。批规范化可以将隐藏层的输出值转换为均值为 0、标准差为 1 的正态分布, 因此批规范化能够有效降低参数初始化方式的影响。此外, 对隐藏层的输出值进行规范化操作, 可以看作是对整个神经网络的一种正则化作用, 减小了网络对正则化的需求。

1.4 前向传播

神经网络可以看作是运算模块堆叠而成的序列模型, 运算模块可看作为函数 f , 单个运算模块如下图 3 所示, $w \in R$ 为 f 的参数, \mathbf{x} 为输入值, 通过 f 得到输出值 \mathbf{y} , 即

$$\mathbf{y} = f_w(\mathbf{x}). \quad (9)$$

当多个运算模块堆叠则组成有深度的神经网络, 输入 x_0 通过模块 f_1 得到 x_1 , 接着将 x_1 视为 f_2 的输入值进而得到 x_2 , 以此类推, 最终得到输出值 x_L , 该运算过程即网络模型的前向传播如图 4 所示, 表达如下:

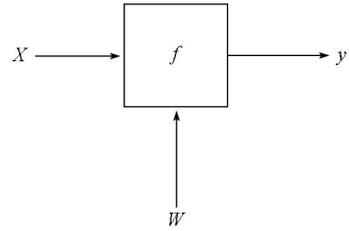


图 3 运算模块

Fig. 3 Operation module

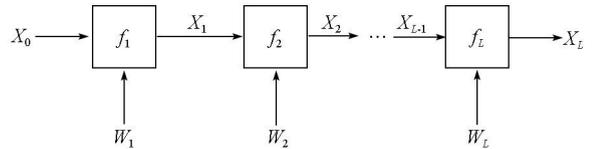


图 4 序列模型

Fig. 4 Sequence module

$$x_L = f_L \{ \dots f_2 [f_1 (x_0)] \}. \quad (10)$$

1.5 反向传播

隐藏层数的增加, 神经网络模拟能力也随之增强, 整个网络所需的参数就越多。神经网络可以看作是模拟特征和目标之间的真实关系函数的方法, 随着参数的增多, 其模拟复杂的函数的能力也随之增强。通常模型结构复杂易求得准确梯度, 因此求取梯度常常使用小批随机梯度下降法对样本子集、对整个训练数据集做无偏估计。假设训练集数据有 P 个样本, 将 P 拆成 k 批, 每批包含了 $n = 1, 2, \dots, N$ 个样本, P 则可以表示为

$$P = kn, \quad (11)$$

每个样本损失 L_n 可以通过向前传播计算, 故模型的损失可以由每批如下表示:

$$L(\theta) = \sum_{n=1}^N L_n(\theta), \quad (12)$$

计算出网络输出和实际输出的损失后, 利用梯度下降策略更新模型中参与学习的参数 θ :

$$\theta_{i+1} = \theta_i - \gamma_i [\nabla L(\theta_i)] = \theta_i - \gamma_i \sum_{n=1}^N [\nabla L_n(\theta_i)], \quad (13)$$

式中: γ_i 为步长, ∇ 为梯度算子。

网络中输出层权重可以直接参与到误差更新中, 但隐层中不存在误差, 所以在反向传播更新参数中, 可通过链式求导法计算损失函数关于某一层的梯度。假设前馈运算得到该批误差为 f , 则误差反向传播至第 l 层的权重 θ_l 的导数为

$$\frac{df}{d(\boldsymbol{\theta}_l)^T} = \frac{df_L(\mathbf{X}_{L-1}, \boldsymbol{\theta}_L)}{d(\mathbf{X}_{L-1})^T} \times \dots \times \frac{df_{l+1}(\mathbf{X}_l, \boldsymbol{\theta}_{l+1})}{d(\mathbf{X}_l)^T} \times \frac{df_l(\mathbf{X}_{l-1}, \boldsymbol{\theta}_l)}{d(\boldsymbol{\theta}_l^T)}, \quad (14)$$

\mathbf{X}_l 为 $l+1$ 层的输入, 计算得到误差 f 关于 $\boldsymbol{\theta}_l$ 的导数后, 便可通过上式更新 $\boldsymbol{\theta}_l$ 。此外仍需得到误

$$\frac{df}{d(\mathbf{X}_l)^T} = \frac{df_L(\mathbf{X}_{L-1}, \boldsymbol{\theta}_L)}{d(\mathbf{X}_{L-1})^T} \times \dots \times \frac{df_{l+1}(\mathbf{X}_l, \boldsymbol{\theta}_{l+1})}{d(\mathbf{X}_l)^T} \times \frac{df_l(\mathbf{X}_{l-1}, \boldsymbol{\theta}_l)}{d(\mathbf{X}_l^T)}, \quad (15)$$

上式求导结果用于误差向前层的反向传播, 通过链式求导法可以获得每一层关于 $\boldsymbol{\theta}_l$ 的导数, 并逐层更新其他需要学习的参数。每一层的参数更新完毕后, 向模型再输入下一批数据, 以此类推完成所有批样本的训练。

2 实验设置

2.1 数据集划分和标记

为了测试网络展现的去噪性能, 我们利用有限差分法^[29]合成不同模型雷达数据, 分别向这些测试数据加入不同程度的高斯白噪声对图像进行破坏。尽管正演模型数量有限, 但同一模型加入相同程度的随机噪声数据是不相同的两个个体, 训练数据集理论上可以任意扩展, 对 2 000 个含噪数据采用灰度模式进行训练。

2.2 数据预处理

不同的雷达数据其取值范围也不同, 为了使得网络在训练过程中快速且稳定的收敛, 通过预处理来减小数据的均值和方差, 数据的预处理公式可表示为

$$\hat{x}_{i,j} = x_{i,j} / [\max(x_{\cdot,j}) / 255], \quad (16)$$

式中: i 和 j 分别为二维矩阵中行和列, $\max(x_{\cdot,j})$ 表示矩阵 \mathbf{x} 中第 j 列的最大值, 归一化后乘上 255, 由此可控制图像数据上限值。

网络的输入神经元个数是确定的, 不同道集和不同采样时间的雷达数据则进行分割或零充策略使得每一层的输入和输出的尺寸保持一致。

2.3 超参数

超参数是网络训练前设置的神经元个数、学习率、隐层层数等。通常网络深度越深, 网络的残差越小, 但伴随着参数的增多。参数对训练结果有着很大的影响, 参数选择不当容易出现过拟合、计算时间过长等问题, 从而导致去噪效果不佳。本文采用了 Burger 等^[24]方法来优化网络中的参数, 其中参数设置学习率为 0.02, 隐藏层个数为 2, 隐藏层神经元数目为 511×511 , 输入层和输出层大小为 13×13 。本文 MLP 网络结构整体框架如图 5 所示。

差 f 关于输入 \mathbf{X}_l 的导数, 则公式可表示为:

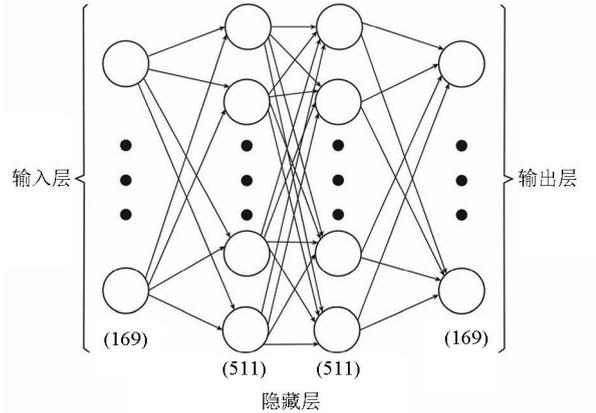


图 5 MLP 网络结构框架

Fig. 5 MLP network structure diagram

3 模型数据测试

采用时域有限差分法正演得到雷达数据, 对其加入高斯白噪声, 选取已训练好的神经网络进行去噪, 通过稀疏变换的曲波变换法作为去噪比较实验。定义信噪比的公式为

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \|y(i,j) - y'(i,j)\|^2, \quad (17)$$

$$PSNR = 20 \times \lg_{10} \left(\frac{MaxVal}{\sqrt{MSE}} \right), \quad (18)$$

式中: $MaxVal$ 为图像像素颜色的最大数值, 本文设图像像素在 0~255 之间; $y(i,j)$ 为含噪的雷达数据; $y'(i,j)$ 为无噪声的雷达数据。

此外, 局部图像质量评价能够凸显相关图像质量分级的更多信息, 而均方误差 MSE 是基于像素误差的图像宏观差异评价指标, 对含噪数据有效信息细节上的凸显和恢复评价上缺少指向性参考。因此, 本文引入了结构性相似指标 (structural similarity index method, $SSIM$) 对图像进行评价, 表征干净图像与含噪声图像之间的失真程度。 $SSIM$ 指标如下表:

$$SSIM = \frac{1}{M} \sum_{j=1}^M SSIM(g_j, h_j), \quad (19)$$

式中: g 为无噪声的雷达数据; h 为含噪的雷达数据; M 为高斯加权函数窗的个数。本文获取图像结

构性相似指标来自 Matlab 中自带的 SSIM 程序。

3.1 简单数据去噪

图 6a 为 1 个 3 层水平层状模型,背景区域尺寸为 150×200 ,第 1 层相对介电常数为 10,埋深为 0.5 m;第 2 层相对介电常数为 15,埋深为 0.9 m;第 3 层相对介电常数为 20。采用时域有限差分算法对模型正演计算,设置空间步长为 0.1 m,激励源为中心频率 500 MHz 的雷克子波,采样时间间隔为 0.02 ns,时窗长度为 40 ns。通过正演得到图 6b 雷达数据,加入高斯白噪声模拟工程检测中数据采集所受到的随机干扰。从曲波去除 25 dB 噪声结果(图 6e)可知,绝大部分噪声已被去除,信噪比比含噪数据提高了 7.66 dB,结构性相似性指标为 0.143,但也新增了较明显的椒盐状噪声,而本文方法(图 6d)对噪声去除更彻底,信噪比提高了 17.40 dB,结构

性相似性指标为 0.239,且其去噪结果几乎没新增其他干扰。图 6f 为加入 75 dB 噪声结果,从图中黑框可以看出,在高噪声覆盖下,同相轴局部已变得模糊不清。对该数据(图 6f)进行曲波去噪,所得信噪比结果(图 6h)提升了 9.78 dB,结构性相似性指标为 0.071,但黑框标示处同相轴明显残缺了一些有效信号,采用本文方法去噪后(图 6g)的信噪比增加了 20.52 dB,结构性相似性指标为 0.161。图 6i 为抽取图 6b、图 6d 和图 6e 中第 50 道数据进行对比结果,图 6j 为抽取图 6b、图 6g 和图 6h 中第 50 道数据进行对比结果,从图 6i 和图 6j 可以看出,随着含噪的上升,曲波法的椒盐状噪声现象随之严重,且同相轴处波峰信号恢复能力显著减弱,而本文 MLP 去噪方法对噪声压制更彻底,整体上与原始信号更接近,且对同相轴有效信号的保护也更完整。

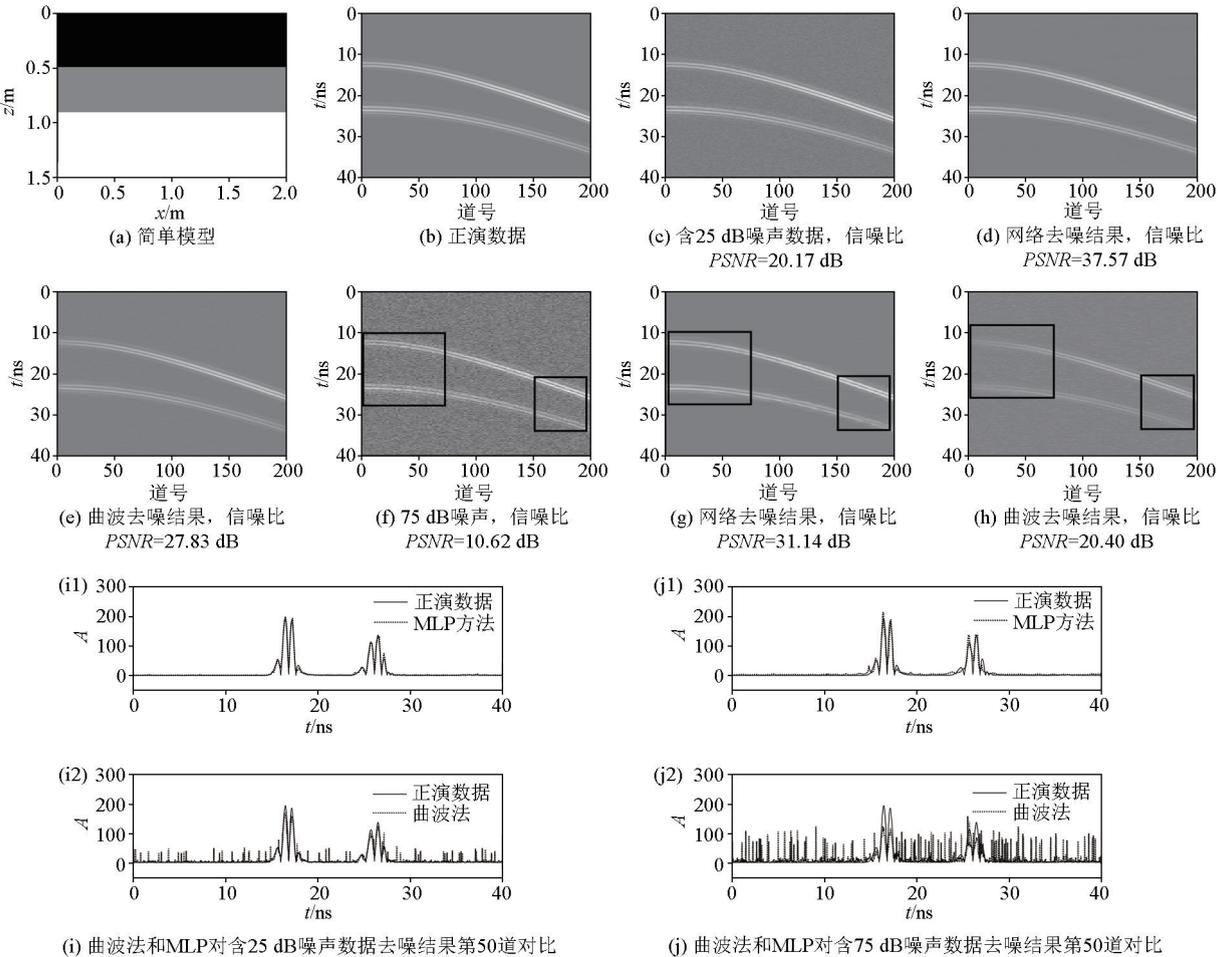


图 6 去噪结果

Fig. 6 Denoising results

表 1 为本文 MLP 去噪方法与曲波去噪方法对不同含量噪声去噪结果的信噪比和结构相似性数据对比,图 7 为本文 MLP 去噪方法与曲波去噪方法对不同含量噪声去噪结果的信噪比和结构相似性数据

对比直方图。从表 1、图 7a 和图 7b 中都可以直观看出,随着信噪比不断下降,MLP 去噪方法所获得图像的信噪比和结构性相似性指标也都要高于曲波去噪。

表 1 神经网络和曲波去噪方法对不同噪声去噪效果的比较

Table 1 Comparison of denoising effects of neural network and curvelet denoising on different noises

噪声/dB	正演数据含噪	MLP 去噪结果	曲波去噪结果	MLP 去噪后结	曲波去噪后结
	信噪比/dB	信噪比/dB	信噪比/dB	构性相似指标	构性相似指标
10	28.14	42.38	35.59	0.239	0.196
25	20.17	37.57	27.83	0.229	0.143
35	17.24	35.57	25.36	0.200	0.124
50	14.13	33.21	22.90	0.182	0.099
65	11.86	32.26	21.24	0.166	0.081
75	10.62	31.14	20.40	0.161	0.071
170	3.54	25.88	16.87	0.099	0.022

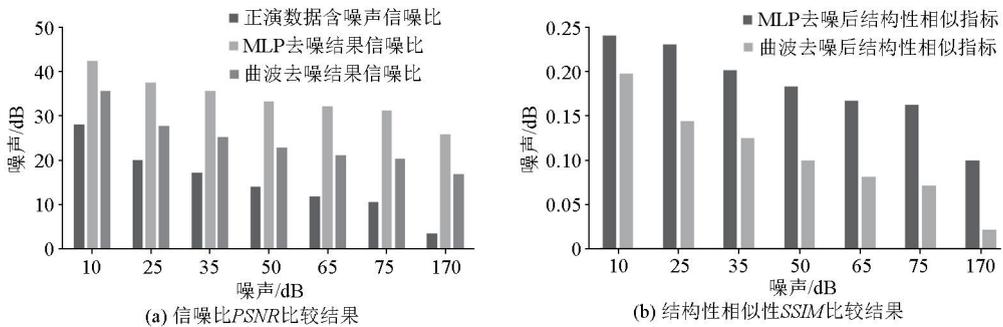


图 7 MLP 和曲波去噪方法对不同噪声去噪效果的比较

Fig. 7 Comparison of denoising effects of MLP and curvelet denoising on different noises

3.2 复杂数据去噪

图 8a 所示的复杂层状模型,介电常数呈随机分布,局部区域横向变化大,模型区域为 220×226 ,采用时域有限差分算法对模型正演计算,观测方式采用共偏移距,设置空间步长为 0.1 m,激励源为中心频率 500 MHz 的雷克子波,采样时间间隔为 0.02 ns,时窗长度为 48 ns。图 8b 为正演数据压缩后的

灰度显示,共 226 道数据。加入 25 dB 噪声(图 8c)后信噪比为 20.18 dB,噪声的覆盖使得同相轴纹理不清晰,尤其是深部能量较弱的同相轴已无法分辨。

从曲波法(图 8e)和神经网络(图 8d)去噪结果可以看出,曲波法信噪比提升 7.01 dB,结构性相似性指标为 0.034,网络法信噪比提升了 17.56 dB,结构性相似性指标为 0.188。对于有效信号尚未被噪

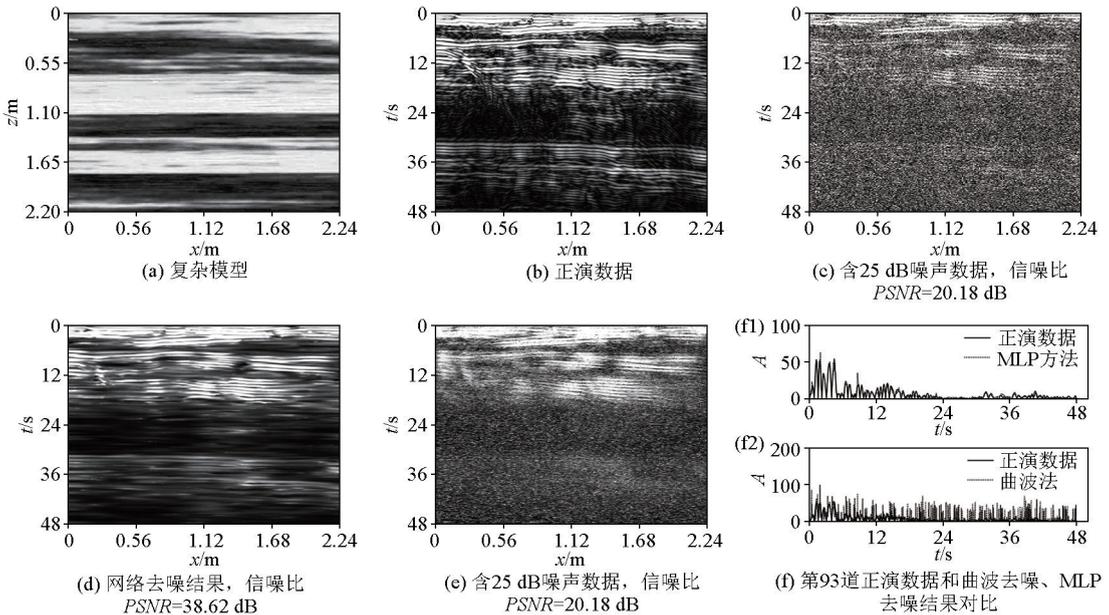


图 8 复杂数据去噪结果

Fig. 8 Complex data denoising results

声覆盖的数据,两种方法都取得了较好的结果,但曲波法整体依然受椒盐状噪声影响,深部或能量较弱的同相轴信号都未能很好地得到重构。图 8f 为第 93 道正演数据和曲波去噪、MLP 去噪结果的对比图,从图 8f2 中可以看出,曲波法浅部区域强振幅信号在椒盐状噪声干扰下仍能大致分辨,但在深部区域的弱振幅信号基本被椒盐状噪声淹没而难以分辨。本文网络去噪结果(图 8f2)不仅在浅部区域展现了更清晰的底层结构,浅部的弱振幅细节及深部的弱振幅同相轴都得到了较好的重现。

4 实际雷达数据去噪

为了进一步说明本文方法的有效性,本节利用实际探地雷达数据对本文方法进行验证。

图 9a 为某地探地雷达实测数据,截取部分数据,其中采样点 512 个,共 400 道数据,在随机噪声

的影响下,数据中平缓区域和双曲绕射边缘区域变得模糊,人眼系统高度集中于该视觉场景仍仅能获得部分信息。从神经网络(图 9b)和曲波法(图 9c)去噪结果可以看出,两种方法都削弱了噪声的影响,视觉感官上得到了一定的提升,但曲波法依然受椒盐状噪声的影响,对复杂结构中弱信号区域去噪效果不佳,如 505~512 采样点处的绕射双曲线仍被噪声淹没;而本文方法处理后的图像更干净,弱幅值信号的噪声也得到了压制,分布于强幅值信号附近的弱幅值信号也得到了更好的分辨。分别抽取图 9a、图 9b 和图 9c 中第 210 道数据进行对比,对比结果如图 9d 所示,本文方法恢复了更多的同相轴信息,如图 9d 中双曲绕射边缘区域 J1 和 J2 箭头所指信号,复杂结构区域中被噪声淹没的信号得到更清晰的辨识,同时去噪后的同相轴也更平滑,更符合人眼的视觉系统。

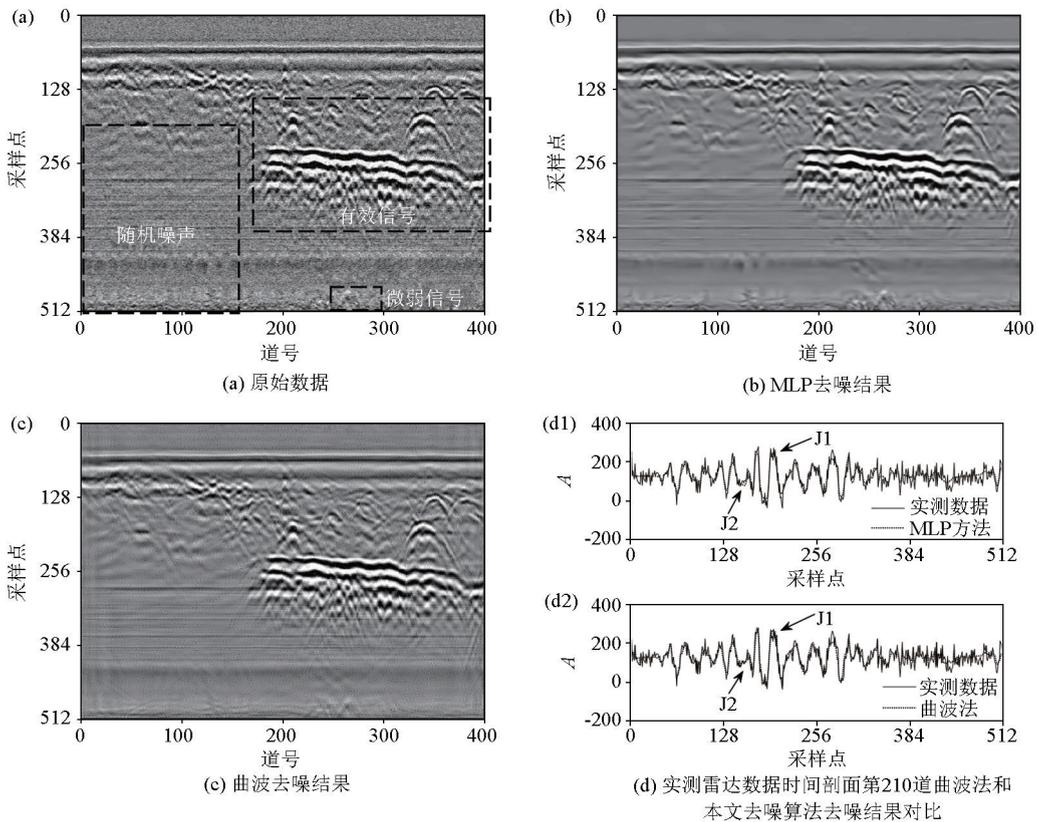


图 9 实际数据去噪结果
Fig. 9 Real data denoising results

5 结论

本文基于新兴起的神经网络图像去噪方法,主要研究了探地雷达数据去噪,在去噪处理中,不同于

让网络直接识别目标体的有效信号,而是让网络识别特性更简单的随机噪声。通过含噪及实测雷达数据和传统基于稀疏变换的曲波法比较去噪能力,得出了如下结论:基于神经网络训练学习的去噪方法不受阈值和稀疏变换基等参数的影响,且不会产生

新的噪声;对不同噪声含量的数据去噪,信噪比提升的表现更优,且信噪比较低的数据也表现出了较好的鲁棒性;对一些构造复杂且弱幅值区域仍能很好地重构。

本文研究基于 MLP 的二维雷达数据去噪方法,在应用中取得了一定的成果,但仅对随机噪声进行了训练,并不能预判其他非随机噪声的去噪效果,而探地雷达在实际工程检测中常会遇到有色噪声、表面多次波和脉冲噪声等其他非随机噪声。因此,对诸多非随机噪声的压制是我们今后工作的研究对象,也将致力于如何将二维数据去噪延伸至三维数据中去。

参考文献 (References):

- [1] 戴前伟,吴铠均,张彬. 短时傅里叶变换在 GPR 数据解释中的应用[J]. 物探与化探,2016,40(6):1227-1231.
Dai Q W, Wu K J, Zhang B. A study of application of short-time Fourier transform to GPR data interpretation[J]. Geophysical and Geochemical Exploration, 2016, 40(6):1227-1231.
- [2] 张斯薇,吴荣新,韩子傲,等. 双边滤波在探地雷达数据去噪处理中的应用[J]. 物探与化探,2021,45(2):496-501.
Zhang S W, Wu R X, Han Z A, et al. The application of bilateral filtering to denoise processing of ground penetrating radar data[J]. Geophysical and Geochemical Exploration, 2021, 45(2):496-501.
- [3] 戴前伟,成沁宇,冯德山. 基于 FastICA 的低信噪比探地雷达信号去噪[J]. 物探化探计算技术,2017,39(6):727-735.
Dai Q W, Cheng Q Y, Feng D S. Low signal-noise ratio GPR signal denoising based on FastICA[J]. Computing Techniques for Geophysical and Geochemical Exploration, 2017, 39(6):727-735.
- [4] 苏智光,廖建军,钱东宏. 探地雷达野外勘察数据干扰及其滤除方法[J]. 物探与化探,2011,35(3):427-430.
Su Z G, Liao J J, Qian D H. The interference signal in GPR survey data and its filtering[J]. Geophysical and Geochemical Exploration, 2011, 35(3):427-430.
- [5] 周威帆. 基于 $f-x$ 域模态分解的探地雷达数据处理与解释[D]. 长春:吉林大学,2020.
Zhou W F. Data processing and interpretation of GPR based on mode decomposition in $f-x$ domain[D]. Changchun: Jilin University, 2020.
- [6] 王超,沈斐敏. 小波变换在探地雷达弱信号去噪中的研究[J]. 物探与化探,2015,39(2):421-424.
Wang C, Shen F M. Study of wavelet transform in ground penetration radar weak signal denoising[J]. Geophysical and Geochemical Exploration, 2015, 39(2):421-424.
- [7] 李静和,何展翔,杨俊,等. 曲波域统计量自适应阈值探地雷达数据去噪技术[J]. 物理学报,2019,68(9):74-83.
Li J H, He Z X, Yang J, et al. Scale and rotation statistic-based self-adaptive function for ground penetrating radar denoising in curvelet domain[J]. Acta. Phys. Sin., 2019, 68(9):74-83.
- [8] 吴学礼,闫枫,甄然,等. 基于小波变换和 K-SVD 的探地雷达杂波抑制研究[J]. 河北科技大学学报,2021,42(2):111-118.
Wu X L, Yan F, Zhen R, et al. Research on adaptive clutter suppression for ground penetrating radar based on wavelet transform and K-SVD[J]. Journal of Hebei University of Science and Technology, 2021, 42(2):111-118.
- [9] 周旭辉,马杰良,吴蕾,等. 基于正交多项式拟合的风廓线雷达风谱识别[J]. 现代雷达,2011,33(11):27-31.
Zhou X H, Ma J L, Wu L, et al. Wind spectra identification of the WPR based on orthogonal polynomial fitting[J]. Modern Radar, 2011, 33(11):27-31.
- [10] 唐斌兵,王正明,汪雄良. 一种含椒盐噪声图像去噪的新方法[J]. 系统工程,2008,26(10):123-126.
Tang B B, Wang Z M, Wang X L. A new method of removing salt-and-pepper noise in images[J]. Systems Engineering, 2008, 26(10):123-126.
- [11] 张东昊,覃晖. 基于探地雷达和深度学习的隧道初期支护检测方法[J]. 现代隧道技术,2020,57(S1):174-178.
Zhang D H, Qin H. Tunnel primary support detection using ground penetrating radar and deep learning[J]. Modern Tunnelling Technology, 2020, 57(S1):174-178.
- [12] Han D, Tao L, Leng J B, et al. GCN:GPU-based cube CNN framework for hyperspectral image classification[C]//International Conference on Parallel Processing, 2017,46:41-49.
- [13] 景卓鑫. 基于神经网络方法与 RADARSAT-2 雷达遥感数据的水稻参数反演研究[D]. 上海:华东师范大学,2014.
Jing Z X. Retrieving paddy rice biophysical parameters from RADARSAT-2 radar using neural network[D]. Shanghai: East China Normal University, 2014.
- [14] 徐昕军,勾妍妍,杨峰. 基于探地雷达与概率神经网络的城市道路病害预警模型研究[J]. 科学技术与工程,2017,17(17):118-124.
Xu X J, Gou Y Y, Yang F. Research on early warning Model of roadbed diseases under urban roads based on GPR and probabilistic neural network[J]. Science Technology and Engineering, 2017, 17(17):118-124.
- [15] 吕永标,赵建伟,曹飞龙. 基于复合卷积神经网络的图像去噪算法[J]. 模式识别与人工智能,2017,30(2):97-105.
Lyu Y B, Zhao J W, Cao F L. Image denoising algorithm based on composite convolutional neural network[J]. Pattern Recognition and Artificial Intelligence, 2017, 30(2):97-105.
- [16] 李寻昌,叶君文,李葛,等. 基于滑坡监测数据的 Elman 神经网络动态预测[J]. 煤田地质与勘探,2018,46(3):113-120,126.
Li X C, Ye J W, Li G, et al. Elman neural network dynamic prediction based on landslide monitoring data[J]. Coal Geology & Exploration, 2018, 46(3):113-120, 126.
- [17] Silver D, Huang A, Maddison C J, et al. Mastering the game of go with deep neural networks and tree search[J]. Nature, 2016, 529(7587):484-489.
- [18] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communication ACM, 2017, 60(6):84-90.
- [19] Jain V, Seung H S. Natural image denoising with convolutional networks[J]. Advances in Neural Information Processing Systems

- (NIPS), 2008, 21: 769–776.
- [20] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [21] Chen S, Abhinav S, Saurabh S, et al. Revisiting unreasonable effectiveness of data in deep learning era[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017: 843–852.
- [22] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229–1251.
Zhou F Y, Jin L P, Dong J. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229–1251.
- [23] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359–366.
- [24] Burger H C, Schuler C J, Harmeling S, et al. Image denoising: Can plain neural networks compete with BM3D? [C]//Computer Vision and Pattern Recognition, 2012: 2392–2399.
- [25] 杨光照. 基于探地雷达的煤岩界面识别技术研究[D]. 徐州: 中国矿业大学, 2019.
Yang G Z. Research on coal-rock interface recognition technology based on ground penetrating radar[D]. Xuzhou: China University of Mining and Technology, 2019.
- [26] 冯德山, 杨子龙. 基于深度学习的隧道衬砌结构物探地雷达图像自动识别[J]. 地球物理学进展, 2020, 35(4): 1552–1556.
Feng D S, Yang Z L. Automatic recognition of ground penetrating radar image of tunnel lining structure based on deep learning[J]. Progress in Geophysics, 2020, 35(4): 1552–1556.
- [27] 季银涛. 基于深度学习的探地雷达图像介电常数反演研究[D]. 济南: 山东大学, 2021.
Ji Y T. Deep learning based ground penetrating radar image permittivity inversion research[D]. Jinan: Shandong University, 2021.
- [28] Sergey I, Christian S. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//International Conference on Machine Learning, PMLR, 2015: 448–456.
- [29] 冯德山, 戴前伟, 何继善, 等. 探地雷达 GPR 正演模拟的时域有限差分实现(英文)[J]. 地球物理学进展, 2006, 21(2): 630–636.
Feng D S, Dai Q W, He J S, et al. Finite difference time domain method of GPR forward simulation[J]. Progress in Geophysics, 2006, 21(2): 630–636.

Neural network-based denoising for ground-penetrating radar data

WU Song¹, NING Xiao-Bin^{2,3}, YANG Ting-Wei^{2,3,4}, JIANG Hong-Liang^{2,3,4}, LU Chao-Bo^{2,3,4}, SU Yu-Di²

(1. Guangxi Tianxin Expressway Co., Ltd., Nanning 530022, China; 2. Guangxi Transportation Co., Ltd., Nanning 530007, China; 3. Guangxi Highway Tunnel Safety Warning Engineering Research Center, Nanning 530007, China; 4. Guangxi Key Lab of Road Structure and Materials, Nanning 530007, China)

Abstract: Ground-penetrating radar (GPR) data are often contaminated by random noise in the actual engineering inspection. The noise in data will reduce the signal-to-noise ratio and resolution of the data, adversely affecting the subsequent inversion and interpretation. Accordingly, this study proposed neural network-based denoising for GPR data. First, a multi-layer neural network model was constructed to integrate the data corrupted by white Gaussian noise into the noise-free data. Then, the corrupted data and their corresponding noise patches were built as training data. The weights of neurons in every layer of the model were updated using a back-propagation algorithm to minimize the model training loss. Finally, the two synthetic data and the measured radar data were input to the trained model, and the model's output was calculated using the noise characteristic weights acquired from the training. Compared with the curvelet transform, the numerical simulation test results verify the effectiveness and robustness of the method proposed in this study. Moreover, the proposed method can suppress the noise more thoroughly in areas with complex structures and weak amplitudes, and show effective signals more clearly.

Key words: ground penetrating radar (GPR); neural network; multi-layer perceptron; back propagation; white Gaussian noise; data denoising

(本文编辑: 叶佩)