

DOI: 10.19783/j.cnki.pspc.221233

基于改进 Noise2Noise 算法的电力线信号去噪

胡正伟, 王志红, 畅瑞鑫, 陈维寅, 谢志远

(华北电力大学电气与电子工程学院, 河北 保定 071003)

摘要: 针对电力线信道噪声干扰大、噪声建模复杂、重建无噪信号样本困难等问题, 提出了一种面向一维时间序列的 Noise2Noise 神经网络优化模型, 并验证分析 Noise2Noise 算法抑制电力线噪声的可行性。首先, 分析了 Noise2Noise 算法的原理, 对该算法原理进行了理论推导。其次, 通过选取合适的网络结构, 改进网络输入输出, 使神经网络适合处理实验数据, 并采用正弦波数据进行网络测试与模型验证。然后, 通过搭建正交频分复用 (orthogonal frequency division multi-plexing, OFDM) 调制模型, 产生 OFDM 符号, 并添加特定噪声, 形成带噪样本。最后, 基于改进的网络结构实现了对电力线接收信号的 OFDM 前导序列进行带噪样本测试, 增强了 Noise2Noise 方法的可行性与有效性, 具有较好的实用性。

关键词: Noise2Noise; 电力线去噪; OFDM; 神经网络

A denoising method of a power line signal based on an improved Noise2Noise algorithm

HU Zhengwei, WANG Zhihong, CHANG Ruixin, CHEN Weiyin, XIE Zhiyuan

(School of Electrical & Electronic Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: Since power line channel noise interference is large, noise modeling is complicated, and it is difficult to reconstruct noiseless signal samples. A Noise2Noise neural network optimization model for a one-dimensional time series is proposed, and the feasibility of Noise2Noise algorithm to suppress power line noise is verified and analyzed. First, the principle of the Noise2Noise algorithm is analyzed and theoretically deduced. Second, by selecting the appropriate network structure and improving network input and output, the neural network is suitable for processing experimental data. Sine wave data is used to test the network and verify the model. Then, by building an orthogonal frequency division multi-plexing (OFDM) modulation model, OFDM symbols are generated, and specific noise is added to form noisy samples. Finally, based on the improved network structure, the noise sample test of an OFDM leader sequence of power line received signals is realized. This enhances the feasibility and effectiveness of Noise2Noise method and has good practicability.

This work is supported by the General Program of National Natural Science Foundation of China (No. 52177083).

Key words: Noise2Noise; power line denoising; OFDM; neural network

0 引言

目前电力线网络具有负载阻抗失配、频率选择性衰落、噪声大等特点, 是一种很不理想的通信载体^[1-4]。如何有效地降低噪声, 提高信噪比, 促进电力线通信技术的实际应用, 是值得研究的重要课题之一。

目前, 在传统的去噪方法上主要包括三个方面:

基金项目: 国家自然科学基金面上项目资助 (52177083); 国家自然科学基金青年科学基金项目资助 (62001166)

1) 选择合适的调制方式, 减少噪声对信息传输的影响; 2) 选择合适的编码方式, 降低信息传输的误码率; 3) 选择适当的信号处理方法, 尽可能地去除噪声。基于负熵的快速独立成分分析 (fast independent component analysis, FASTICA) 算法以及独立分量的方法, 可以实现低压电力线信道载波进行去噪。对比小波去噪效果, 该方法的去噪效果与之接近, 并且该方法简单, 具有自适应的能力, 特别是节省了带宽资源^[5-7]。通过分析电力线信道噪声特性以及小波去噪理论, 在改进的去噪方法中, 引入了一个新的阈值函数, 使阈值变化与小波变换的尺度一致^[8-11]。

文献[12]提出了一种自适应选择小波、分解层数与阈值的局部放电去噪算法。文献[13]提出了基于时频滤波算法(time frequency peak filter, TFPPF)的 PLC 信号消除算法, 但相对于背景噪声来说, 该方法对脉冲噪声抑制比较有限。故提出一种归一化时频峰值滤波算法(normalization time frequency peak filter, NTFPPF), 该方法在时频峰值滤波之前对信号归一化处理, 可以起到抑制脉冲噪声的效果^[14]。利用小波变换双谱计算在处理信号和提取信号特征方面比传统的双谱分析方法更加有效。对信号进行小波处理并建立 AR 模型, 最后进行双谱计算更容易辨别出干扰因素及干扰强度^[15]。文献[16]提出了一种降低峰均比的噪声预处理算法来对 PLC 信号进行预处理, 通过对非线性噪声抑制以及小波噪声抑制仿真分析, 验证了该方法的有效性。针对算法时间复杂度高、执行效率差的问题, 文献[17]通过基于最优门限和功率估计的脉冲噪声抑制算法, 提出了一种基于 MIMO 结构的脉冲噪声压缩与检测算法。

在神经网络、深度学习等方面, 文献[18]提出了一种新型电力线检测方法, 采用 CNN 来帮助消除通过补丁分类的背景噪音, 大大提高了精度, 并显著降低了误报率。文献[19]提出了一种改进的去噪自编码器, 提高了带噪电力线信道传输特性样本的识别成功率。所提方案以一维时间序列代替二维图片作为输入, 改进了传统自编码器的处理数据网络结构, 引入 z-score 标准化及对应的反标准化对输入输出信号进行处理, 在提高去噪能力的同时加快了收敛速度。文献[20]提出了一种抑制电力线干扰以预处理抑制心电图信号的方法, 通过递归神经网络的训练模型和门控递归单元完成电力线干扰信号提取, 从而消除或抑制噪声。文献[21]针对噪声环境下的语音特征提取与识别问题, 构建了一种基于深度神经网络的无监督语音去噪模型, 将语音波形与噪声语音相位相合成, 提高了语音特征提取抗噪声能力。文献[22]提出了一种基于深度学习的电力线信道传输特性识别方法, 克服了传统信道识别算法在噪声较大时估计不理想的困难。为改善电能质量, 通过扰动信号在噪声干扰和无噪声环境下识别, 利用小波时频图和 Alex-Net 网络构建电能质量扰动识别模型, 无需经过去噪预处理, 且有较好的识别准确率^[23]。

本文需要准确的幅频特性样本, 但实际中的电力线信道幅频特性样本受噪声干扰, 无法获取无噪声样本。Noise2Noise 算法性价比高, 具有很多优势, 其中: 1) 当没有干净样本时, 可以将有噪声样本转

换为无噪声样本; 2) 当噪声样本足够多时, 即使噪声不可测, 网络也可以学习到真实的样本情况, 从而解决了电力线干净样本集收集困难的问题。本文提出了改进的 Noise2Noise 算法神经网络结构, 适用于处理一维时间序列, 通过实验数据验证了改进的 Noise2Noise 算法对电力线噪声抑制有明显效果。

本文介绍 Noise2Noise 算法的基本原理, 然后采用 U-Net 作为原始网络, 将其构建为适合处理一维时间序列的输入输出结构, 并将其卷积层、池化层、采样层与自身数据优化结构相适配。接着采用正弦波数据对改进网络及方法进行验证, 分析不同信噪比下的去噪效果, 为下一步正交频分复用(orthogonal frequency division multi-plexing, OFDM)符号达到去噪效果做准备。最后, 基于构建好的网络结构, 从相同 OFDM 符号样本、差异样本、相邻样本噪声相近三个方面实现去噪并进行数据分析, 验证了该方法的有效性, 同时估计了其适用的范围条件。

1 Noise2Noise 算法

文献[24]采用 Noise2Noise 算法, 通过无标签的噪声信号重建无噪声信号。该理论的创新点是输入图像和目标图像都是有噪声的图像, 网络可以通过将有噪声的图像转化为无噪声的干净图像, 采用机器学习与最基础的信号重建算法, 实现了通过噪声信号到干净信号的重建, 并得到一个重要结论: 可以通过无标签的噪声信号重建无噪声信号, 过程中不需要干净的样本, 并且在性能上超越了运用干净样本进行训练的方法。

1.1 理论背景

假设通过一定的方法获得某个器件上多个时刻的电压值, 想要进一步用一个值来代替这一组数据, 最好的方法是通过获得一个估计值 z 来得到最小化均值的偏差, 并得到损失函数 L_{oss} , 如式(1)所示。

$$L_{\text{oss}} = \arg \min_z E_y \{L(z, y)\} \quad (1)$$

式中: z 表示样本电压的估计值; y 表示样本电压值; L 表示其误差函数。

常用的损失函数有均方误差(MSE)、平方绝对误差(MAE)等。本文采用范数损失函数中的 L_2-L_{oss} , 由于该范数可以限制模型空间, 所以在一定程度上可以防止出现过拟合情况地发生, 使得模型具有更好的泛化能力。下面介绍 L_1-L_{oss} 和 L_2-L_{oss} 。当选择 L_1-L_{oss} 时, 即最小绝对误差, 那么

误差函数为

$$L(z, y) = \sum_{i=1}^n |z - y_i| \quad (2)$$

式中, y_i 表示样本值。

对 z 求导获取驻点, 得

$$\frac{dL}{dz} = \sum_{i=1}^n \text{sgn}(z - y_i) = 0 \quad (3)$$

若要使得式(3)成立, 那么 z 取所有样本的中位数。当选择 L_2 - L_{oss} 时, 即最小平方误差, 那么误差函数为

$$L(z, y) = \frac{1}{2} \sum_{i=1}^n (z - y_i)^2 \quad (4)$$

对 z 求导获取驻点, 得

$$\frac{dL}{dz} = \sum_{i=1}^n (z - y_i) = 0 \quad (5)$$

若使得式(5)成立, 那么 z 取所有样本的算术平均值, 如式(6)所示。

$$z = \frac{1}{n} \sum_{i=1}^n y_i \quad (6)$$

1.2 Noise2Noise 原理

文献[24]在使用 L_2 - L_{oss} 时, 网络是一对多的映射关系, 学习到映射值的均值。基于此, 将干净的图像加上零均值的噪声作为目标样本, 当数据量足够多时, 网络便能够学习到预测干净的图像。在高分辨率算法中, 低分辨率图到高分辨率图的对应关系是一对多的关系, 网络直接使用 L_2 - L_{oss} 回归高分辨率的结果。实际的网络预测结果可能约等于高分辨率图的均值, 因此预测的高分辨率图倾向于模糊。

针对式(1), 其最小值在 $z = E\{y\}$ 处取得。同样对于神经网络而言, 图像去噪通常被当作一个回归模型, 运用卷积神经网络(convolutional neural network, CNN)训练样本对 x_i, y_i' , 而样本函数 $f_\theta(x)$ 需要学习出参数 θ 。通过 $E_{(x, y')}$ 可以得到最小化误差, 并用神经网络拟合函数 $f(x)$ 表示一对多的任务, 如式(7)所示。

$$f(x) = \arg \min_{\theta} E_{(x, y')} \{L_{\text{CNN}}(f_\theta(x), y')\} \quad (7)$$

式中: $f(x)$ 表示 CNN 模型中的拟合函数; x 表示有噪样本; y' 表示无噪样本; L_{CNN} 表示 CNN 模型中的损失函数。由于一张图对应多个目标, 所以在优化式(7)时需要同时针对 x, y' 两个变量。如果输入变量 x 之间相互独立, 则 $f(x)$ 为

$$f(x) = \arg \min_{\theta} E_{(y'|x)} \{L_{\text{CNN}}(f_\theta(x), y')\} \quad (8)$$

以上计算过程可以分成两步进行优化。首先, 如果一张图对应的噪声样本足够多, 并且噪声样本的噪声满足零均值分布, 那么 $y'|x$ 的优化结果理应是干净的噪声样本。然后对每张输入图进行第二步优化, 如式(9)所示。

$$E \left\{ \hat{y}_i' \middle| \hat{x}_i \right\} = y_i' \quad (9)$$

式中, y_i' 表示干净数据。当噪声近似满足零均值分布时, 优化结果可以将噪声均值化, 从而达到去噪的目的。

1.3 网络结构

本文以 U-Net 网络作为原始网络, 并基于 Python 语言下的 TensorFlow 及 Keras 架构编写程序。由于实验数据为一维时间序列, 故将网络的卷积层、池化层、采样层与自身数据结构相适配, 使得网络输入与输出结构一致。该网络结构可以使得数据的每个部分均具有去噪能力, 并且结构上更加完善, 在保证特征提取精度的同时也提高了训练速度^[25-28]。通过对 U-Net 网络结构分析, 将网络模型的数值和尺寸按照实验数据结构的需要对设置的大小进行替换, 如表 1 所示。

此次实验的 U-Net 模型共有 9 个层级, 各层级由卷积层、池化层或全连接层以不同顺序及数量组成。网络分为左右两通道: 左通道用于特征提取, 共计 4 层; 右侧为扩展通道, 与左侧相对应, 用于还原数据的细节信息。

2 正弦波数据去噪验证

为了验证改进 Noise2Noise 算法的有效性, 采用正弦波数据作为神经网络的输入样本, 整个去噪验证流程如图 1 所示。

2.1 样本构建与仿真环境

本文首先验证该方法的正确性, 通过 Matlab 生成多个频率下的正弦波数据, 每个样本采样 1024 个数据点, 保留小数点后 8 位的离散数据形式, 并保存为 txt 文件, 总共生成了 512 个样本, 其中训练集中 480 个样本, 测试集中 32 个样本, 任一训练样本示意图如图 2 所示。

仿真实验平台分为两部分: 在 Windows 操作系统下, 采用 Matlab 软件生成样本数据以及对后续实验数据进行分析; 在 Ubuntu16 操作系统下, 采用 Python 语言进行编程, 版本为 Python3.6, 并基于 TensorFlow、Keras 等框架进行神经网络数据训练。

由于神经网络结构复杂、计算量大等, 采用

CPU 进行训练时, 其花费的时间太长, 计算力不够, 所以并不实用, 故采用英伟达生产的图形处理器(graphics processing unit, GPU)进行神经网络训练, 版本型号为 GeForce GTX 1080Ti, 显示存储为 11 GB。

表 1 U-Net 模型各层参数

Table 1 Parameters of each layer of U-Net model

区域	层级	名称	核函数 (尺寸/信道)	步长	边界 填充	激活 函数
压缩 通道		conv1_1	3/64	1	1	ReLU
	1	conv1_2	3/64	1	1	ReLU
		pool1	2/—	2	—	—
		conv2_1	3/128	1	1	ReLU
	2	conv2_2	3/128	1	1	ReLU
		pool2	2/—	2	—	—
		conv3_1	3/256	1	1	ReLU
	3	conv3_2	3/256	1	1	ReLU
		pool3	2/—	2	—	—
		conv4_1	3/512	1	1	ReLU
4	conv4_2	3/512	1	1	ReLU	
	pool4	2/—	2	—	—	
过渡	5	conv5_5	3/1024	1	1	ReLU
		conv5_2	3/1024	1	1	ReLU
		up6	2/512	2	1	ReLU
	6	conv6_1	3/512	1	1	ReLU
		conv6_2	3/512	1	1	ReLU
	up7	2/256	2	1	ReLU	
7	conv7_1	3/256	1	1	ReLU	
扩展 通道		conv7_2	3/256	1	1	ReLU
		up8	2/128	2	1	ReLU
	8	conv8_1	3/128	1	1	ReLU
		conv8_2	3/128	1	1	ReLU
		up9	2/64	2	1	ReLU
9	conv9_1	3/64	1	1	ReLU	
	conv9_2	3/64	1	1	ReLU	
输出		conv10	1/1	1	—	ReLU

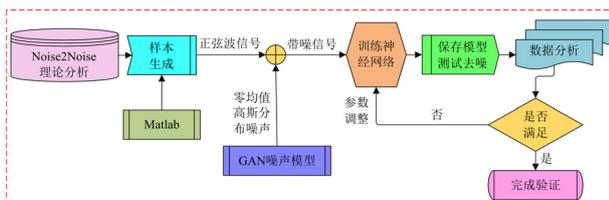


图 1 正弦波数据去噪验证流程图

Fig. 1 Flow chart of sine wave data denoising verification

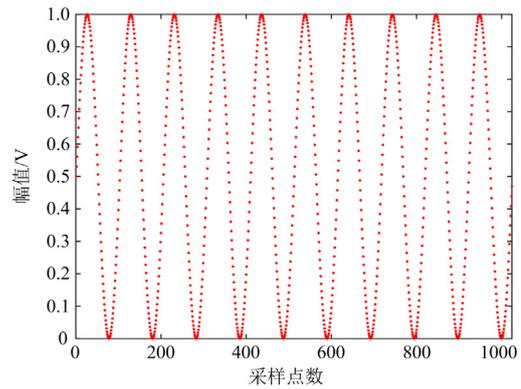


图 2 训练样本示意图

Fig. 2 Schematic diagram of training samples

2.2 加噪原理

依据 Noise2Noise 原理, 首先对样本进行加噪处理, 如图 3 所示。每个样本是一维离散的 1024 个点, 每个小方块是一个信号点, 其中噪声类型是均值为零的高斯噪声。加噪过程是通过干净信号与高斯噪声相对应的每个点相加, 最终得到带噪样本。

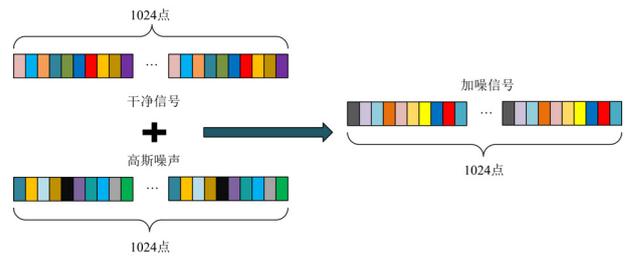


图 3 加噪原理结构图

Fig. 3 Structure diagram of noise adding principle

2.3 去噪效果

通过神经网络进行训练, 可以实现对正弦波信号的去噪, 去噪验证损失以及信噪比如图 4 所示, 其中训练样本所加噪声为零均值的高斯噪声, 原始信号与噪声的信噪比为 10 dB, 学习率为 0.001, 训练批次为 32, 训练轮数为 60。

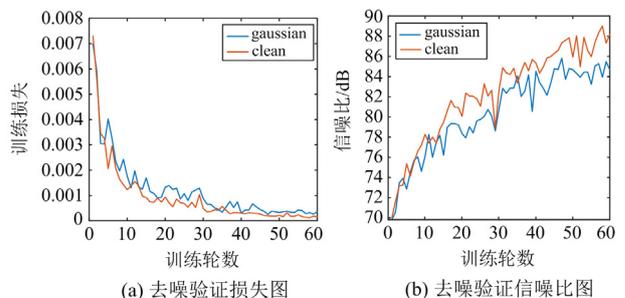


图 4 去噪验证损失和信噪比图

Fig. 4 Loss and signal-to-noise ratio of denoising verification

去噪前后时域、频域波形图如图 5 所示。由图 5 可以看出：该训练已经达到了去噪的效果，去噪后的波形与原始信号几乎一样，对应频域上干扰也很小；去噪前后变化趋势保持一致，但无法对其进行精确描述，所以下面针对去噪前后效果进行具体的数据分析。

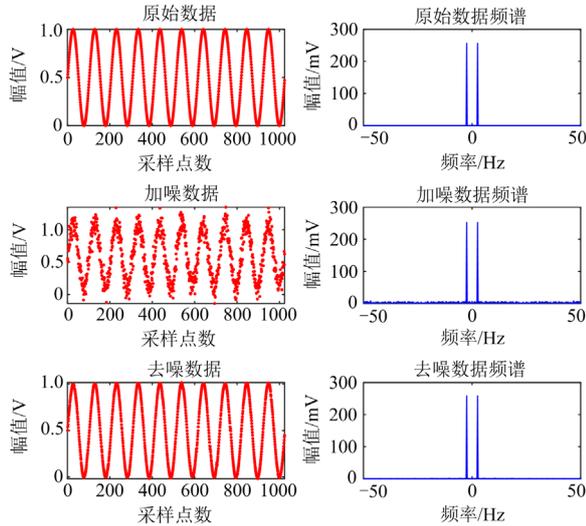


图 5 去噪前后时域及频域对比图

Fig. 5 Time domain and frequency domain comparison before and after denoising

2.4 时域误差与频域误差

为了验证 Noise2Noise 方法的去噪效果，将去噪后的信号与原始信号在时域上对应的各个采样点及频域上各频率点对应值作差，得到如图 6 所示的时域误差及频域误差。可以看到每个时域采样点及频点对应的误差都很小，并取其平均值，分别为 0.0019 和 0.1463，在误差范围内。

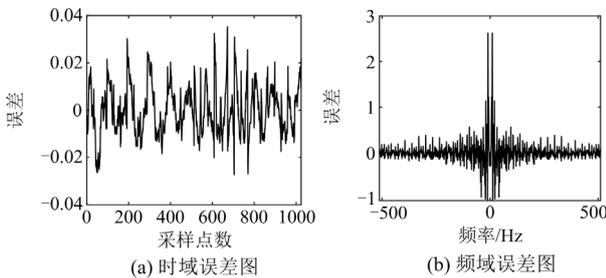


图 6 时域及频域误差

Fig. 6 Time domain and frequency domain error

2.5 相关性

为进一步验证去噪的效果，对原信号和去噪信号分别做自相关和互相关运算，并得到去噪信号互相关与原信号自相关之间的相对误差，如图

7 所示。

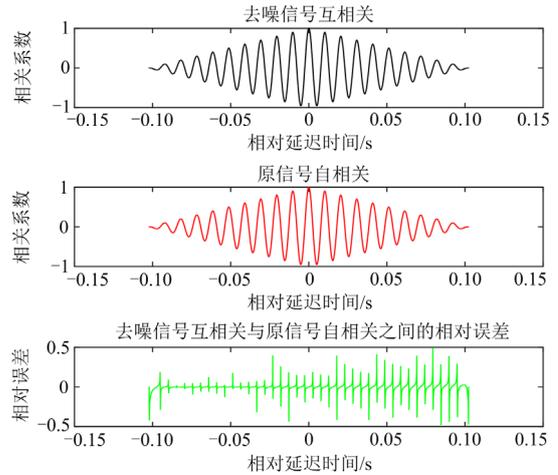


图 7 信号相关性

Fig. 7 Signal correlation

对每点的相对误差值相加求平均，得到的平均误差值为 0.0027。一组数据不能说明不同信噪比下的去噪效果，下面将训练多组不同噪声条件下的数据来验证去噪的可靠性，结果如表 2 所示。同时将不同噪声下的相关性求得相对误差，结果如表 3 所示。

表 2 不同噪声下的去噪结果

Table 2 Noise reduction results of different noises

噪声/dB	时域误差	频域误差
10	-0.0013	0.2845
5	0.0084	0.1744
0	0.0091	0.2918
-5	0.0104	0.5243
-10	-0.0118	0.2109
-15	0.2782	1.5513

表 3 不同噪声相关性的相对误差

Table 3 Correlation relative error of different noises

噪声/dB	相对误差
10	0.0010
5	0.0014
0	0.0043
-5	0.0128
-10	0.0189
-15	0.2975

2.6 结构分析

由表 2 进一步分析可知，从时域上看，随着噪声不断增大，误差也逐渐增大。当信噪比为 0~10 dB 时，误差几乎不变，始终保持在 10^{-3} 内。当信噪比为 -5~-10 dB 时，误差略微上升，但也在 10^{-2} 内。从频域上看，当信噪比为 10~-10 dB 时，误差范围等级始终在 10^{-1} 内。而当信噪比小于 -10 dB 时，误

差变化明显, 对应的时域及频域波形如图 8 所示。

由图 8 中可以明显看出去噪效果开始降低, 波形变得不再光滑, 并且断断续续, 主频率周围的干

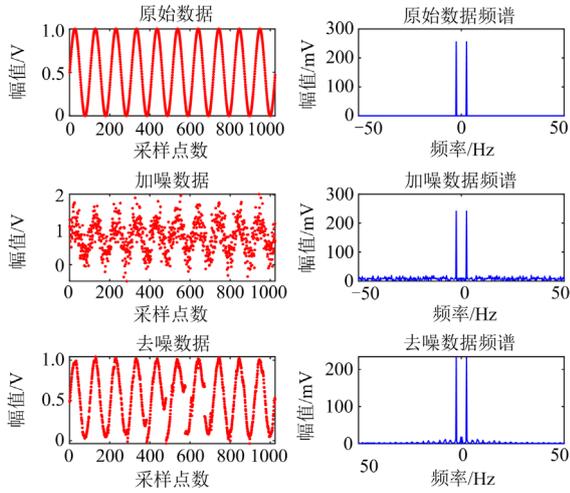


图 8 去噪前后时域及频域对比图

Fig. 8 Time and frequency domain before and after denoising

扰相较于之前有所增加, 对应的误差变大。由表 3 进一步分析可知, 随着噪声的不断增大, 相对误差也逐渐增大。当信噪比为 0~10 dB 时, 相对误差几乎不变, 始终保持在 10^{-3} 内。当信噪比为 -5~-10 dB 时, 相对误差略微上升, 并保持在 10^{-2} 内, 而小于 -10 dB 时, 相对误差明显增大。

3 OFDM 接收信号前导序列去噪

基于上述正弦波的去噪验证, 改进的 Noise2Noise 算法可以实现对一维数据的带噪信号去噪。下面以 OFDM 接收信号作为训练样本进行带噪信号去噪, 具体包括三个方面: 1) 相同 OFDM 符号样本对去噪效果的影响; 2) 不同 OFDM 符号样本之间的差异对去噪效果的影响; 3) 相邻 OFDM 符号样本的噪声相近对去噪效果的影响。

利用 Matlab 仿真工具, 实现 4 径低压电力线信道衰落模型以及 OFDM 的调制解调模型得到 OFDM 符号样本, 如图 9 所示。

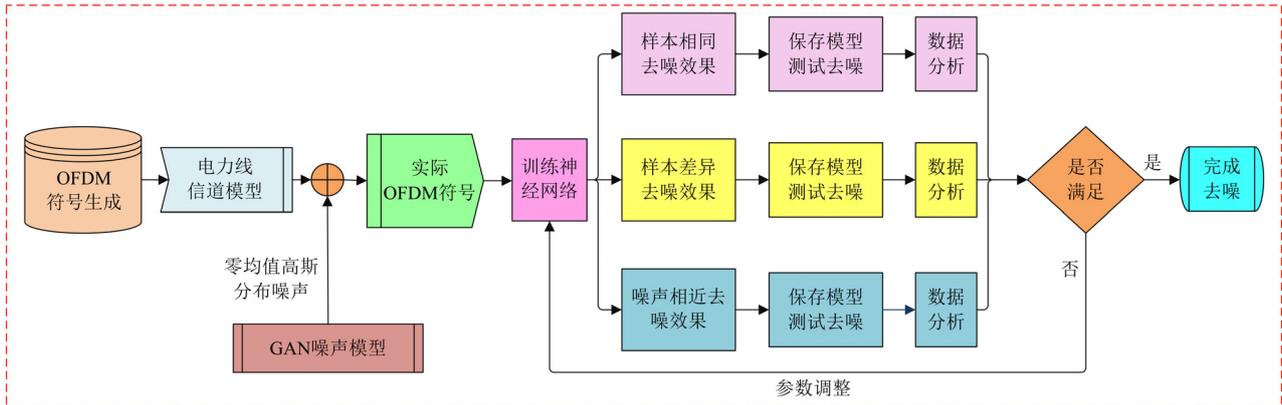


图 9 OFDM 去噪实现流程图

Fig. 9 Implementation flow chart of OFDM denoising

3.1 样本数据采集

通过 Matlab 仿真软件搭建 OFDM 调制模型, 获取电力线信号的前导序列符号, 并对电力线信道进行建模仿真, 使得到的 OFDM 符号更接近真实情况。样本点数为 1024 的 OFDM 符号时域波形以及采样点数为 1024 的频域波形如图 10 所示。

3.2 传统方法下的去噪效果

传统去噪方法是将信号先通过小波变换, 再通过小波分解。这是因为信号经过变换后, 小波系数较大, 而噪声的小波系数较小, 因此可以选取一个合适的阈值, 并将小于阈值的小波系数置为 0, 从而达到去噪的目的, 其实质是抑制信号中无用的部分, 增强信号中有用的部分。基于小波变换的去噪方法采

用一组数据, 与神经网络有所差别, 而本文改进算法是基于 Noise2Noise 网络结构的。因此, 以下使用相同样本作为对比, 以信噪比为 20 dB 的去噪效果为例进行分析, 如图 11 所示。

通过求去噪信号与原信号互相关系数和原信号自相关系数, 可得到信噪比为 20、15、10、5、0 dB 的平均相对误差, 如表 4 所示。通过表 4 数据的对比分析可知, 平均相对误差随着信噪比的减小而增大, 实验表明信噪比越小去噪效果越好。

为了更好地表达去噪效果, 以下从 OFDM 符号的输入信噪比和输出信噪比两个方面对比分析, 如图 12 所示, 由图可以看出在不同输入信噪比下, 经过去噪均能使输入、输出信噪比有明显增大。

实验表明,在一定范围内,随着输入信噪比的增大,去噪效果越好,基于小波变换的去噪方法达到了去噪的效果。

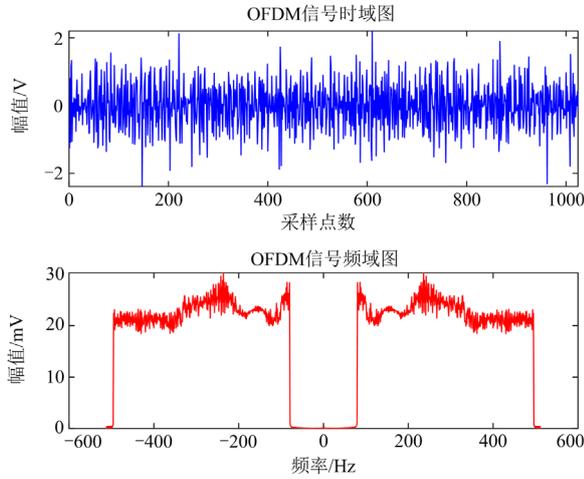


图 10 OFDM 时域与频域波形图

Fig. 10 Time and frequency domain waveforms of OFDM

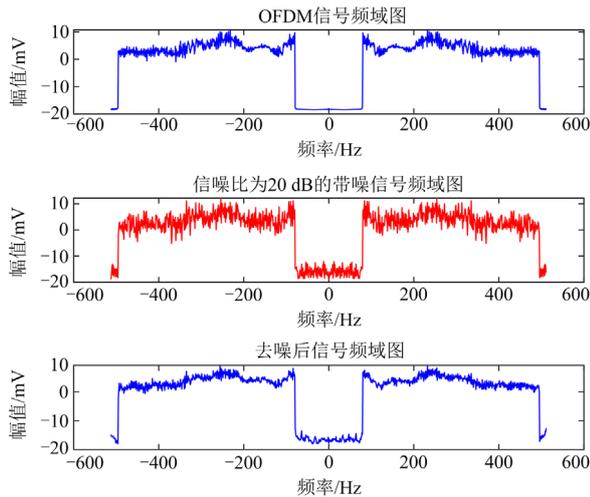


图 11 信噪比为 20 dB 的去噪效果对比图

Fig. 11 Comparison of noise reduction effect under 20 dB signal-to-noise ratio

表 4 不同信噪比下的相关性平均相对误差

Table 4 Correlation average relative error under different signal-to-noise ratios

信噪比/dB	平均相对误差
20	0.0896
15	0.1124
10	0.2069
5	0.4356
0	0.7962

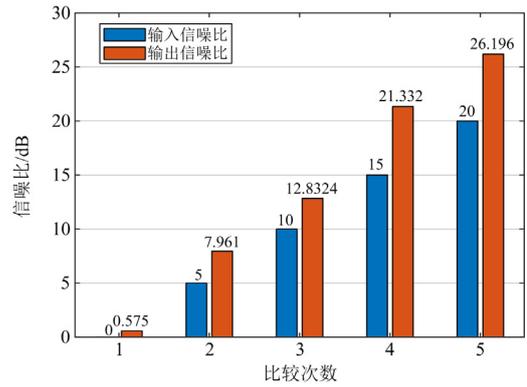


图 12 不同信噪比下的输入输出信噪比

Fig. 12 Input and output signal-to-noise ratios under different signal-to-noise ratios

3.3 相同样本对下的去噪效果

基于 Noise2Noise 的去噪原理,采用电力线信道的 OFDM 符号进行带噪信号的去噪训练。首先基于相同的两个样本进行加噪与去噪学习,每次只需采样一次,复制相同数据组成样本对,并加入均值为 0 dB 的高斯白噪声,然后将加噪的数据样本输入到神经网络中进行训练学习。为了更好地验证该方法的去噪效果,给 OFDM 符号样本分别加上 20、15、10、5、0 dB 的高斯白噪声,并进行去噪分析。信噪比为 20 dB 的去噪效果如图 13 所示。

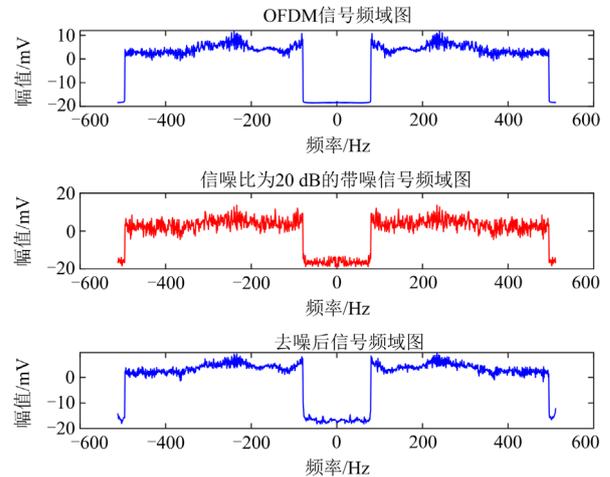


图 13 信噪比为 20 dB 的去噪效果

Fig. 13 Noise reduction effect under 20 dB signal-to-noise ratio

由图 13 可以看出,去噪前后有明显变化。为了进一步验证去噪效果,对原信号进行自相关运算,对去噪信号与原信号进行互相关运算,并求两者互相关相对于原信号自相关的相对误差。信噪比为 20 dB 的相关性误差如图 14 所示。

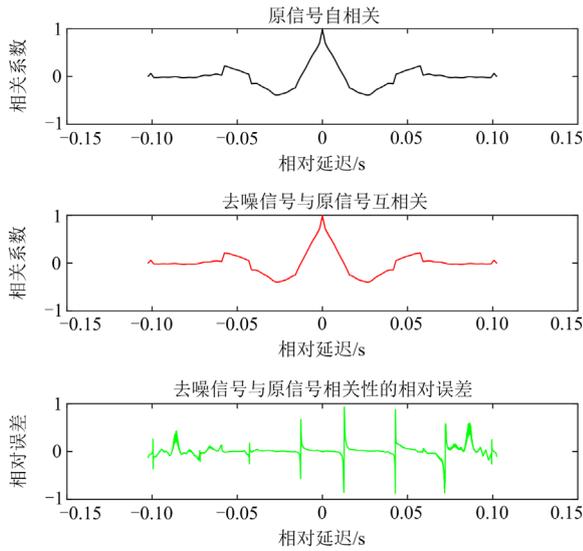


图 14 信噪比为 20 dB 的相关性相对误差
Fig. 14 Correlation relative error under 20 dB signal-to-noise ratio

信噪比为 20、15、10、5、0 dB 的平均相对误差如表 5 所示。由图 14 可知, 去噪信号与原信号在相对延迟时间为 0 s 附近时, 其互相关系数达到了最大值(0.99)。通过与表 5 对比分析可知, 相关性平均相对误差随着信噪比的减小而增大。同样也说明, 在噪声越小的情况下去噪效果越好。

表 5 不同信噪比的相关性平均相对误差
Table 5 Correlation average relative error under different signal-to-noise ratios

信噪比/dB	平均相对误差
20	0.0622
15	0.0647
10	0.1831
5	0.3843
0	0.7051

下面通过对 32 个测试样本作误差计算, 每个样本共 1024 个频域采样点。实际有用信号为第 81~496 这 416 个子载波, 因此直接对这 32 个样本对应的子载波频率点误差求取平均值。画出对应的在信噪比为 0、5、10、15、20 dB 的误差曲线, 如图 15 所示。

不同信噪比的输入、输出信噪比如图 16 所示, 去噪后, 得到新信号样本的信噪比有明显增大。实验表明, 在一定范围内, 随着输入信噪比的增大, 去噪效果越好, 基于 Noise2Noise 的去噪方法达到去噪效果。

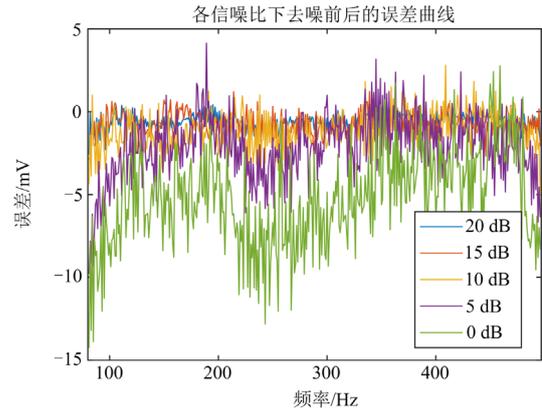


图 15 不同信噪比下去噪前后误差曲线
Fig. 15 Error curve before and after noise reduction under different signal-to-noise ratios

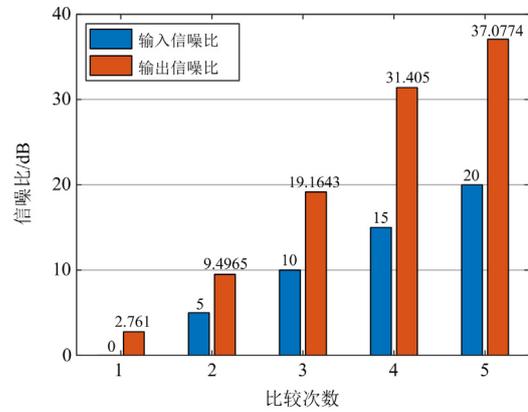


图 16 不同信噪比的输入、输出信噪比
Fig. 16 Comparison of input and output signal-to-noise ratios under different signal-to-noise ratios

通过对比传统去噪方法与 Noise2Noise 去噪方法可以看出, 两者在去噪能力上都有明显的效果。但相对于传统去噪方法来说, 基于 Noise2Noise 的去噪能力更强, 相对误差更小, 输出信噪比更大。

3.4 差异样本的去噪效果

根据上一节实验方法及步骤, 进一步对两个不同 OFDM 符号样本进行加噪与去噪分析。每次需要获取两个样本组成样本对, 并加入均值为 0 dB 的高斯白噪声, 然后将加噪数据样本输入到神经网络中进行训练学习。不同 OFDM 符号的时域与频域波形及对应误差如图 17 所示。

为了更好地验证该方法的去噪效果, 给 OFDM 符号样本分别加上 20、15、10、5、0 dB 的零均值高斯白噪声, 并进行去噪分析。但为了区分样本间的差异, 对每对样本中的一个样本进行加噪处理, 样本的差异程度通过添加 40、30、20、10、0 dB 噪声进行区分。

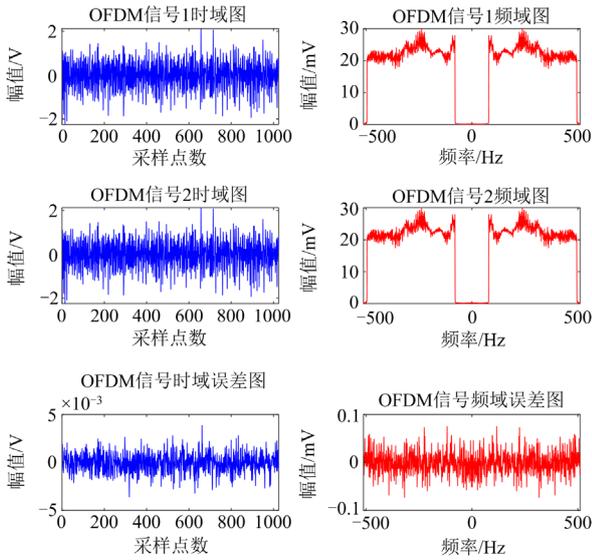


图 17 不同 OFDM 符号的时域、频域波形及对应误差
Fig. 17 Time domain and frequency domain waveforms and corresponding errors of different OFDM symbols

1) 带噪样本信噪比为 20 dB 时

以信噪比为 20 dB 的样本为例，其去噪频域效果如图 18 所示。对原信号进行自相关运算，对去噪信号与原信号进行互相关运算，并求得两者互相关相对于原信号自相关的相对误差，如图 19 所示。

通过求去噪信号与原信号互相关相对于原信号自相关的相对误差，可得到 20 dB 信噪比的带噪样本，样本差异在 40、30、20、10、0 dB 的相对误差平均值，如表 6 所示。

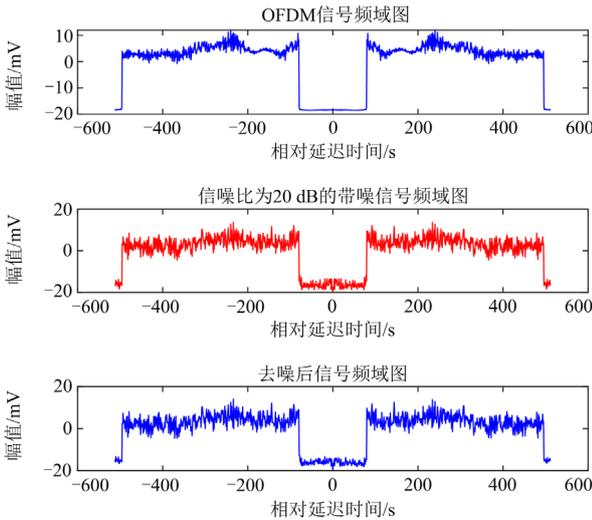


图 18 20 dB 信噪比差异下去噪效果
Fig. 18 Noise reduction effect of 20 dB signal-to-noise ratio difference

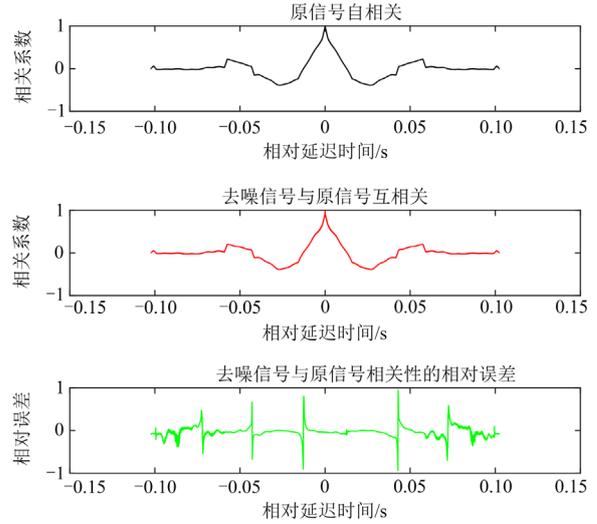


图 19 20 dB 信噪比差异下的相关性相对误差
Fig. 19 Correlation relative errors of 20 dB signal-to-noise ratio difference

由图 19 可知，去噪信号与原信号在相对延迟时间为 0 s 附近时，其互相关系数达到了最大值(0.99)。但随着样本差异的不断增大，相应产生的影响也越严重，在相同的情况下相对延迟时间已经偏离 0 s，其相关性越小。从 10 表 6 可以看到，相关性平均相对误差随着信噪比的增大而减小，同样也说明，在信号样本差异越小的情况下去噪效果越好。

表 6 不同样本差异下的相关性平均相对误差
Table 6 Correlation average relative error under different sample differences

样本差异/dB	平均相对误差
40	0.0577
30	0.0580
20	0.0813
10	0.1174
0	0.3230

为了更好地表达数据样本的去噪效果及规律，通过对 20 dB 信噪比下的带噪样本进行去噪过程，对 OFDM 符号样本的信噪比进行了对比分析，如图 20 所示。

由图 20 可以看出，随着样本差异的减小，信噪比增大，其输出信噪比也在增大。但在样本差异为 10 dB 时，其输出信噪比为 19.5103 dB，与测试样本输入信噪比 20 dB 相比，其值十分接近且略小于输入信噪比，此时几乎没有去噪效果。而在样本差异为 0 dB 时，输出信噪比为 5.1644 dB，低于测试样本输入信噪比。进一步说明了，样本差异对去噪效果造成了较大干扰，使去噪后的数据噪声更大。

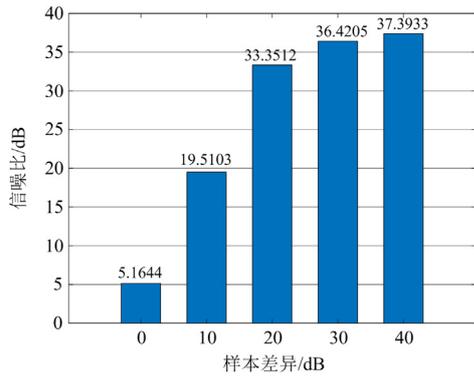


图 20 不同信噪比的输出信噪比

Fig. 20 Output signal-to-noise ratio under different signal-to-noise ratios

2) 带噪样本信噪比为 15 dB 时

带噪样本信噪比 15 dB 下, 各样本差异的相关性平均相对误差和去噪后的输出信噪比如表 7 和图 21 所示。由表 7 可知, 相关性平均相对误差随着信噪比的增大而减小, 反映了在样本差异越小的情况下去噪效果越好。由图 21 可知, 随着样本差异的减小, 即对应的信噪比增大, 其输出信噪比也增大。但在样本差异为 10 dB 时, 其输出信噪比已经明显小于测试样本输入信噪比。此时几乎没有去噪效果, 且随着样本差异的增大, 其差异对去噪效果造成了较大干扰, 使得去噪后的数据噪声更大。

表 7 不同样本差异的相关性平均相对误差

Table 7 Correlation average relative error under different sample differences

样本差异/dB	平均相对误差
40	0.1289
30	0.1291
20	0.1267
10	0.2191
0	0.4176

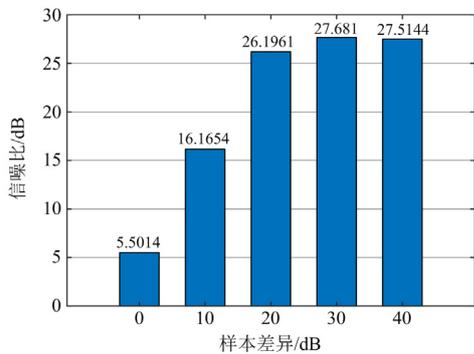


图 21 不同信噪比下的输出信噪比

Fig. 21 Output signal-to-noise ratio under different signal-to-noise ratios

3) 带噪样本信噪比为 10 dB 时

带噪样本信噪比 10 dB 下, 各样本差异的相关性平均相对误差和去噪后的输出信噪比如表 8 和图 22 所示。从表 8 可以看到, 相关性平均相对误差随着信噪比的增大而减小, 反映了在样本差异越小的情况下, 去噪效果越好。由图 22 可以看出, 随着样本差异的减小, 即对应的信噪比增大, 其输出信噪比增大, 但全部小于输入信噪比, 此时在各样本差异的情况下, 几乎没有去噪效果, 且随着样本差异的增大, 对去噪效果造成了较大的干扰, 使得去噪后的数据噪声更大。

表 8 不同样本差异下的相关性平均相对误差

Table 8 Correlation average relative error under different sample differences

样本差异/ dB	平均相对误差
40	0.3092
30	0.3179
20	0.3180
10	0.3526
0	0.4860

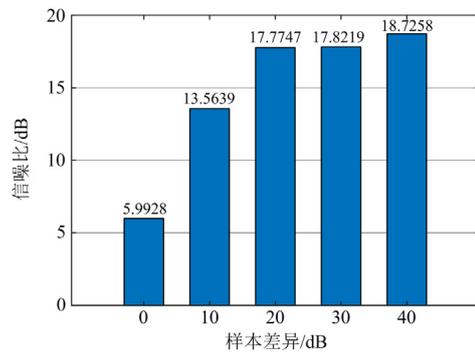


图 22 不同信噪比下的输出信噪比

Fig. 22 Output signal-to-noise ratio under different signal-to-noise ratios

4) 带噪样本信噪比为 5 dB 时

带噪样本信噪比 5 dB 下, 各样本差异的相关性平均相对误差和去噪后的输出信噪比如表 9 和图 23 所示。由表 9 可知, 相关性平均相对误差值随着信噪比的提升而降低, 且相对误差都大于 0.5, 反映了在此时已经无法达到去噪的效果。由图 23 可知, 随着样本差异的减小, 即对应的信噪比增大, 其输出信噪比也增大, 但达不到输入信噪比的 1/2。此时在各样本差异的情况下, 造成了很大的干扰, 使得去噪后的数据噪声更大。

表 9 不同样本差异的相关性平均相对误差

Table 9 Correlation average relative error under different sample differences

样本差异/dB	平均相对误差
40	0.5430
30	0.5475
20	0.5525
10	0.5583
0	0.5994

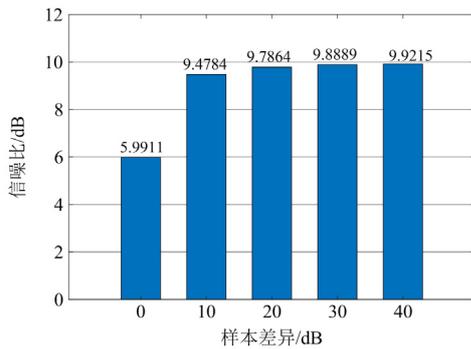


图 23 不同信噪比下的输出信噪比

Fig. 23 Output signal-to-noise ratio under different signal-to-noise ratios

5) 带噪样本信噪比为 0 dB 时

带噪样本信噪比 0 dB 下,各样本差异大小的相关性相对误差表和去噪后信号的输出信噪比如表 10 和图 24 所示。

从表 10 可以看到,相关性的平均相对误差随着信噪比的增大而减小,且平均相对误差都接近于 0.8,此时已毫无去噪的效果。由图 24 可以看出,随着样本差异的减小,即对应的信噪比增大,但其输出信噪比的增大十分微小,且全部不足输入信噪比的 1/4。此时在各样本差异的情况下,造成了很大的干扰,去噪后的信号所包含的原始信号特性几乎消失殆尽。

表 10 不同样本差异的相关性平均相对误差

Table 10 Correlation average relative error under different sample differences

样本差异/dB	平均相对误差
40	0.7223
30	0.7349
20	0.7445
10	0.7447
0	0.7490

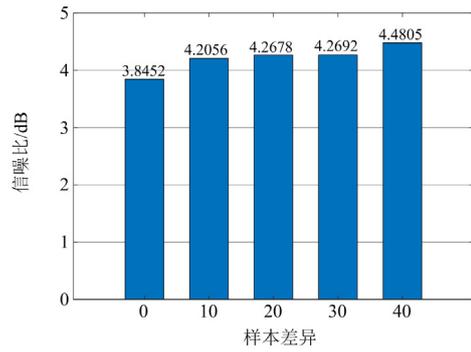


图 24 不同信噪比的输出信噪比

Fig. 24 Output signal-to-noise ratio under different signal-to-noise ratios

综上所述,各个带噪样本信噪比下的不同样本差异的相对误差及输出信噪比的三维图如图 25 和图 26 所示。

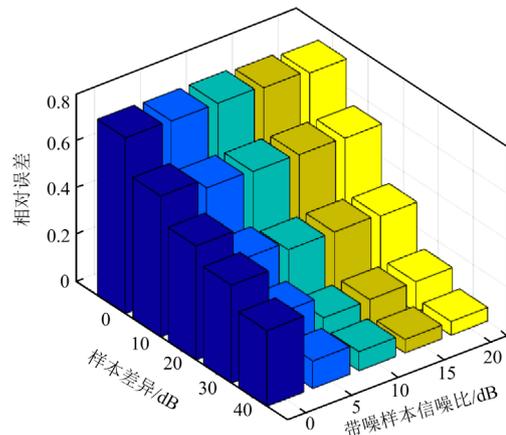


图 25 不同带噪样本信噪比下不同样本差异的相对误差

Fig. 25 Relative error of sample difference under different signal-to-noise ratios of different samples with noise

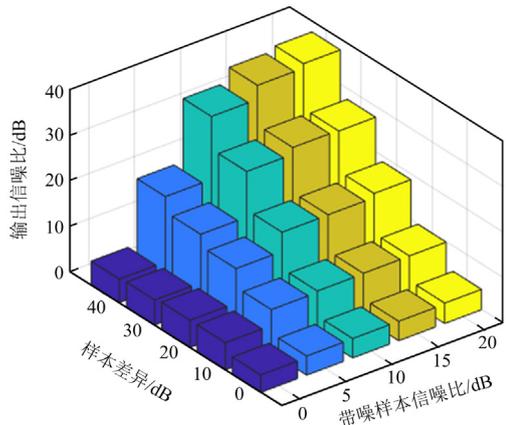


图 26 不同带噪样本信噪比下不同样本差异的输出信噪比

Fig. 26 Output signal-to-noise ratios of sample difference under different signal-to-noise ratios of different samples with noise

由图 25 和图 26 及上述分析可知: 1) 在带噪样本信噪比一定时, 去噪信号与原始信号相对误差随着样本差异的增大而增大, 输出信噪比随着样本差异的减小而增大; 2) 在样本差异一定时, 去噪信号与原始信号相对误差随着带噪样本信噪比的增大而减小, 输出信噪比随着带噪样本信噪比的增大而增大; 3) 在带噪样本信噪比大于 10 dB 且样本差异的信噪比大于 10 dB 时, 才能够有明显的去噪效果, 输出信噪比才得到增加, 且大于输入信噪比即带噪样本信噪比。

3.5 相邻样本噪声相近下的去噪效果

由于在电力线上采样速率很快, 相邻 OFDM 符号噪声的相关性很高。基于此前提, 对该类样本进行带噪训练, 分析其去噪效果。同样, 为了能更好地验证该方法的去噪效果, 分析在 20、15、10、5、0 dB 信噪比的带噪样本下, 以及各自对应 3 种噪声相关系数情况的去噪结果。联合带噪样本信噪比和噪声相关系数画出对应相关性平均相对误差和输出信噪比三维图, 如图 27 和图 28 所示。

由图 27 可以看出, 在各自带噪样本信噪比条件下, 相关系数越大, 计算后相对误差值越大, 表明在噪声越不相关时, 网络越能学习到信息, 与 Noise2Noise 算法理论方面比较吻合, 基于一对多的映射关系而学习到映射值的均值。只要变量之间越独立, 对应相关性也越小, 从而更能达到去噪的效果, 从图 28 同样可以说明上述这一点。但也需要在一定的信噪比范围内, 当带噪样本信噪比小于 10 dB 时, 输出信噪比低于输入的信噪比 20 dB, 使得噪声的干扰太大, 而无法达到去噪的目的。

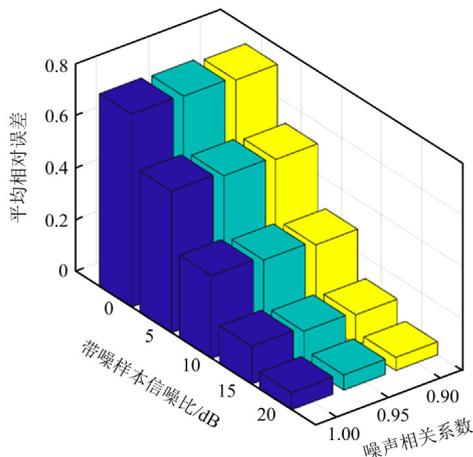


图 27 不同噪声相关系数的相关性平均相对误差
Fig. 27 Correlation average relative error under different noise correlation coefficients

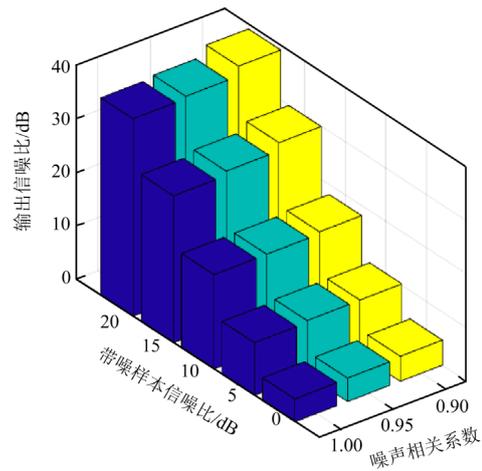


图 28 不同噪声相关系数下的输出信噪比
Fig. 28 Output signal-to-noise ratio under different noise correlation coefficients

4 结论

本文提出了一种面向电力线噪声抑制的改进优化 Noise2Noise 神经网络算法, 结论如下:

1) 改进的 Noise2Noise 算法, 增加了算法应用的普遍性, 对于不同的噪声分布, 选择不同的损失函数, 也可以获取干净样本, 并且还增加了算法的应用场景, 该算法适用于一维时间序列电力线去噪, 仿真验证了其电力线去噪的可行性;

2) 改进的 Noise2Noise 算法的最大优势在于解决了干净样本集获取困难的问题, 可以通过无标签的噪声信号重建无噪信号, 无需干净样本也可从噪声样本中学习得到干净样本;

3) 与传统的去噪方法对比, 该算法在去噪效果上和性能上都优于传统去噪方法, 并简化了电力线去噪的工作流程, 为智能电网中的实际应用提供了一种可选方案。

参考文献

[1] 张文远, 李天昊. 电力线传输特性和噪声干扰对通信性能的相对影响[J]. 电力系统保护与控制, 2022, 50(7): 145-152.
ZHANG Wenyuan, LI Tianhao. Relative impacts of channel characteristics and noise characteristics on the performance of a power line communication system[J]. Power System Protection and Control, 2022, 50(7): 145-152.

[2] 王学良, 李蕊, 姜慧竹, 等. 智能电网电力线宽带载波通信测试系统关键技术研究[J]. 电力信息与通信技术, 2018, 16(5): 82-88.
WANG Xueliang, LI Rui, XIAN Huizhu, et al. Research on key technologies of power line broadband carrier

- communication test system in smart grid[J]. *Electric Power Information and Communication Technology*, 2018, 16(5): 82-88.
- [3] 王艳, 王阳, 赵洪山. 中压配电网电力线载波通信信道建模[J]. *电力系统保护与控制*, 2021, 49(8): 50-57.
WANG Yan, WANG Yang, ZHAO Hongshan. Channel modeling of power line communication in a medium voltage distribution network[J]. *Power System Protection and Control*, 2021, 49(8): 50-57.
- [4] 王勇, 张明, 马洲俊. 电力线信道通信特性影响因素分析[J]. *电力科学与技术学报*, 2021, 36(3): 157-164, 173.
WANG Yong, ZHANG Ming, MA Zhoujun. Analysis of influence factors of power line channel communication characteristics[J]. *Journal of Electric Power Science and Technology*, 2021, 36(3): 157-164, 173.
- [5] 杨帆, 樊晓平. 基于独立分量分析的低压电力线信号去噪[J]. *计算机工程与应用*, 2008(13): 224-227.
YANG Fan, FAN Xiaoping. Noise cancellation for low voltage power line signals using independent component analysis[J]. *Computer Engineering and Applications*, 2008(13): 224-227.
- [6] IYER D, ZOURIDAKIS G. Single-trial evoked potential estimation: comparison between independent component analysis and wavelet denoising[J]. *Clinical Neurophysiology*, 2007, 118.
- [7] HYVARINEN A, OJA E. A fast fixed-point algorithm for independent component analysis[J]. *Signal Processing*, 1997, 39: 3917-3920.
- [8] 刘思议, 金涛, 刘对. 基于改进小波阈值去噪和RCRSV-MP算法的电力系统低频振荡模态辨识[J]. *电力自动化设备*, 2017, 37(8): 166-172.
LIU Siyi, JIN Tao, LIU Dui. Power system low-frequency oscillation mode identification base on improved wavelet threshold de-noising and RCRSV-MP algorithm[J]. *Electric Power Automation Equipment*, 2017, 37(8): 166-172.
- [9] FU P, YANG L, SHI J. A fault location method based on improved wavelet denoising for open-line fault in the low-voltage distribution network[C] // 2020 IEEE 3rd International Conference on Automation, Electronics and Electrical Engineering (AUTEEE), November 20-22, 2020, Shenyang, China: 111-115.
- [10] 张程, 邱炳林. 基于可调 Q 因子小波变换与稀疏时域法的电力系统低频振荡模态辨识[J]. *电力系统保护与控制*, 2022, 50(13): 63-72.
ZHANG Cheng, QIU Binglin. Power system low frequency oscillation modal identification based on a tunable Q-factor wavelet transform and sparse time domain method[J]. *Power System Protection and Control*, 2022, 50(13): 63-72.
- [11] 喻敏, 王斌, 陈绪轩. 同步挤压小波变换在电力系统低频振荡模态参数提取中的应用[J]. *电工技术学报*, 2017, 32(6): 14-20.
YU Min, WANG Bin, CHEN Xuxuan. Application of synchrosqueezed wavelet transform for extraction of the oscillatory parameters of low frequency oscillation in power systems[J]. *Transactions of China Electrotechnical Society*, 2017, 32(6): 14-20.
- [12] 米翰宁, 王昕, 任广振, 等. 自适应小波阈值去噪算法用于局部放电白噪声去噪[J]. *高压电器*, 2021, 57(6): 94-101.
MI Hanning, WANG Xin, REN Guangzhen, et al. De-noising for white noise in partial discharge signals by adaptive wavelet threshold estimation[J]. *High Voltage Apparatus*, 2021, 57(6): 94-101.
- [13] 苏岭东. 低压电力线通信信道噪声特性及消除研究[D]. 北京: 华北电力大学, 2016.
SU Lingdong. Research on noise characteristics and noise mitigation technology in low voltage power line communication channel[D]. Beijing: North China Electric Power University, 2016.
- [14] 耿文飞. 小波去噪结合双谱分析在载波通信中的应用研究[D]. 昆明: 昆明理工大学, 2016.
GENG Wenfei. Research on wavelet denoising combined with bispectral analysis in carrier communication[D]. Kunming: Kunming University of Science and Technology, 2016.
- [15] 任俐. 基于预处理的电力线信道噪声抑制方法研究[D]. 长沙: 湖南大学, 2018.
REN Li. Power line channel noise suppression method research based on the pretreatment[D]. Changsha: Hunan University, 2018.
- [16] 谭周文. 基于 OFDM 的低压电力线通信噪声抑制方法研究[D]. 长沙: 湖南大学, 2018.
TAN Zhouwen. Research on noise mitigation method of low-voltage power line communication based on OFDM[D]. Changsha: Hunan University, 2018.
- [17] PAN C, CAO X, WU D. Power line detection via background noise removal[C] // 2016 IEEE Global Conference on Signal and Information Processing (GlobalSIP), December 7-9, 2016, Washington, DC, USA: 871-875.
- [18] QIU Y, HUANG K, XIAO F, et al. Power-line interference suppression in electrocardiogram using recurrent neural networks[C] // 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), October 14-16, 2017, Shanghai, China: 1-6.

- [19] 胡正伟, 赵然, 陈维寅, 等. 基于改进去噪自编码器的电力线信道传输特性识别实现[J]. 电力信息与通信技术, 2021, 19(9): 86-92.
HU Zhengwei, ZHAO Ran, CHEN Weiyin, et al. Realization of power line channel transmission characteristics identification based on improved denoising auto-encoder[J]. Electric Power Information and Communication Technology, 2021, 19(9): 86-92.
- [20] CHEN X. Unsupervised speech denoising method based on deep neural network[C] // 2018 11th International Symposium on Computational Intelligence and Design (ISCID), December 8-9, 2018, Hangzhou, China: 254-258.
- [21] 史建超, 胡正伟, 贺冬梅, 等. 基于深度学习的电力线信道传输特性识别方法[J]. 电网技术, 2019, 43(12): 4283-4290.
SHI Jianchao, HU Zhengwei, HE Dongmei, et al. Transmission characteristic recognition method of power line channel based on deep learning[J]. Power System Technology, 2019, 43(12): 4283-4290.
- [22] 何巨龙, 王根平, 刘丹, 等. 基于提升小波和改进 BP 神经网络的配电网系统电能质量扰动定位与识别[J]. 电力系统保护与控制, 2017, 45(10): 69-76.
HE Julong, WANG Genping, LIU Dan, et al. Localization and identification of power quality disturbance in distribution network system based on lifting wavelet and improved BP neural network[J]. Power System Protection and Control, 2017, 45(10): 69-76.
- [23] 张镇涛. 基于小波变换和深度学习的电能质量扰动信号去噪与识别研究[D]. 南昌: 南昌大学, 2021.
ZHANG Zhentao. Research on de-noising and recognition of power quality disturbance signal based on wavelet transform and deep learning[D]. Nanchang: Nanchang University, 2021.
- [24] LEHTINEN J, MUNKBERG J, HASSELGREN J, et al. Noise2noise: learning image restoration without clean data[J]. arxiv: 1803.04189, 2018.
- [25] 汪颖, 孙建风, 肖先勇, 等. 基于优化卷积神经网络的电缆早期故障分类识别[J]. 电力系统保护与控制, 2020, 48(7): 10-18.
WANG Ying, SUN Jianfeng, XIAO Xianyong, et al. Cable incipient fault classification and identification based on optimized convolution neural network[J]. Power System Protection and Control, 2020, 48(7): 10-18.
- [26] 杨帆, 王干军, 彭小圣. 基于卷积神经网络的高压电缆局部放电模式识别[J]. 电力自动化设备, 2018, 38(5): 123-128.
YANG Fan, WANG Ganjun, PENG Xiaosheng. Partial discharge pattern recognition of high-voltage cables based on convolution neural network[J]. Electric Power Automation Equipment, 2018, 38(5): 123-128.
- [27] 苏玉刚, 阳剑, 戴欣, 等. 基于 TensorFlow 神经网络的 MCR-WPT 系统负载与互感识别方法[J]. 电力系统自动化, 2021, 45(18): 162-169.
SU Yugang, YANG Jian, DAI Xin, et al. TensorFlow neural network based load and mutual inductance identification method for magnetic coupling resonant wireless power transfer system[J]. Automation of Electric Power Systems, 2021, 45(18): 162-169.
- [28] 李海英, 沈益涛, 罗雨航. 基于改进深度置信网络的智能电网暂态安全状态感知[J]. 电力系统保护与控制, 2022, 50(5): 171-177.
LI Haiying, SHEN Yitao, LUO Yuhang. Transient security situational awareness of smart grids based on an improved deep belief network[J]. Power System Protection and Control, 2022, 50(5): 171-177.

收稿日期: 2022-08-02; 修回日期: 2022-09-27

作者简介:

胡正伟(1978—), 男, 博士, 副教授, 研究方向为智能电网通信技术; E-mail: hzwwizard@hotmail.com

王志红(1997—), 女, 硕士研究生, 研究方向为智能电网通信技术; E-mail: 1562197303@qq.com

谢志远(1964—), 男, 教授, 博士生导师, 研究方向为电力线通信及智能信息传感技术。

(编辑 姜新丽)