

# 改进深度神经网络的电力线脉冲噪声抑制与补偿算法

庄元强, 申 敏

(重庆邮电大学 通信与信息工程学院, 重庆 400065)

**摘要:** 针对非线性抑制方法需要先验统计信息确定最佳门限且引起非线性失真的问题, 提出一种改进深度神经网络(DNN)的电力线脉冲噪声抑制与补偿算法。首先通过 DNN 锁定脉冲噪声的位置, 然后采用置零法清除该位置的数据, 最后对处理后的信号进行非线性失真重构与补偿, 并与其它算法进行了仿真对比实验。仿真结果表明: 所提算法提升了 DNN 的识别率, 降低了系统误码率, 具有较好的鲁棒性。

**关键词:** 电力线通信; 智能电网; 脉冲噪声; 深度学习; 人工智能; 深度神经网络

**中图分类号:** TN911.4 **文献标志码:** A **文章编号:** 1002-5561(2023)04-0067-06

**DOI:** 10.13921/j.cnki.issn1002-5561.2023.04.013

**开放科学(资源服务)标识码(OSID):**



## Improved deep neural network algorithm for power line pulse noise suppression and compensation

ZHUANG Yuanqiang, SHEN Min

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** To solve the problem that the nonlinear suppression method requires prior statistical information to determine the optimal threshold and causes nonlinear distortion, an improved deep neural network (DNN) algorithm for power line impulse noise suppression and compensation is proposed. Firstly, the position of pulse noise is locked by DNN, and then the data of the position is cleared by zero-setting method. Finally, the nonlinear distortion is reconstructed and compensated for the processed signal, and the simulation and comparison experiments are carried out with other algorithms. The simulation results show that the proposed method improves the recognition rate of the DNN, reduces the bit error rate of the system, and has good robustness.

**Key words:** power line communication, smart grid, impulse noise, deep learning, artificial intelligence, deep neural network

### 0 引言

随着国家“新基建”的提出, 电力线通信(PLC)与无线通信、车联网、物联网、可见光通信等领域深度融合, 共同构建“三合一”的能源互联网, 使万物互联成为现实<sup>[1]</sup>。但电力线信道中的脉冲噪声(IN)严重影响着 PLC 系统的误码率(BER)性能<sup>[2-3]</sup>, 且在车载通信、无线通信、图像处理、电缆老化监测等领域也都会遭受 IN 的干扰<sup>[4]</sup>。

IN 的抑制方法主要包括置零、限幅等<sup>[2,4]</sup>、基于压缩感知技术<sup>[5]</sup>、基于稀疏贝叶斯学习技术<sup>[6]</sup>、基于多重信号分类法(MUSIC)技术<sup>[7]</sup>等方法。其中, 置零和限幅等非线性法最简单、应用最广泛, 其门限依赖于 IN 先验信息的估计。文献[8]提出了一种自适应阈值计算方法, 但该方法需要估计的参数较多, 仅适用于幅度分布明显的噪声场景, 且会导致多载波系统中出现载波间干扰(ICI)问题<sup>[9]</sup>(非线性失真)。基于压缩感知技术虽然能解决非线性法依赖于噪声先验信息的难题, 但需要待恢复信号必须满足稀疏度的要求, 这在实际系统中难以做到。与基于压缩感知技术相比, 基于稀疏贝叶斯学习技术降低了稀疏度的要求, 性能更好, 但其运算复杂度大, 不符合系统实时性要求。基于 MUSIC 技术是通过引入 MUSIC 理论来估计 IN 的个数、位置、幅度等参数, 从而恢复出 IN, 在干扰严重的情况下能较好提升系统性能, 但计算过程过于复杂、处理

收稿日期: 2023-01-29。

基金项目: 国家电网有限公司科技项目(E2020-77)资助。

作者简介: 庄元强(1997—), 男, 山东泰安人, 硕士研究生, 现就读于重庆邮电大学通信与信息工程学院电子与通信工程专业, 主要研究方向为电力线通信、无线通信, 负责完成了国家电网有限公司科技项目 1 项。



时延较大,无法应用于实际系统。

深度神经网络(DNN)正好解决了不同场景对噪声先验信息的估计问题。文献[10]利用带长短期记忆网络(LSTM)的卷积神经网络估计出有记忆 IN 模型的参数,但其研究重点仅在 IN 检测,未介绍抑制 IN 的方法。文献[11]利用 DNN 估计 IN 参数,使用对数似然比技术较好地抑制了 IN,但只能估计出预先设置区间内的参数值。文献[12-13]将深度学习方法应用到非正交多址接入系统中,虽然有效地抑制了 IN,但分类标签没有考虑无脉冲的情况,容易损失有用信号。文献[14]利用 DNN 直接恢复受 IN 影响的发送符号,证明了 DNN 在 IN 模型不匹配时 also 具有良好的鲁棒性,但未提出抑制 IN 的方法。文献[15]使用支持向量机去除信号中的 IN,完成了复杂噪声中的频谱感知任务,但研究的重点是频谱感知,且只使用了高斯混合噪声模型对其进行验证。为了克服上述缺点,文献[16]提出利用 DNN 检测 IN,再通过置零法去除这部分噪声数据,但 DNN 识别率低,且未考虑置零处理会导致非线性失真的问题。

因此,本文提出一种改进 DNN 的电力线 IN 抑制与补偿算法,进一步降低系统 BER。

## 1 PLC 系统模型

PLC 系统中的 IN 在时域上具有持续时间短、幅度大的特点,可分为工频同步 IN、工频异步 IN、随机 IN 3 类。为了便于分析,IN 通常采用 Bernoulli-Gaussian (BG)<sup>[9]</sup>非连续噪声模型进行研究。BG 模型具有数值分析简单的特点,广泛应用于性能分析与通信系统的设计中。

PLC 接收端的接收信号为

$$r_n = hx_n + w_n + i_n = s_n + w_n + i_n \quad (1)$$

其中,  $n=0, 1, \dots, N-1$ ;  $h$  为信道脉冲响应,  $x_n$  为加入循环前缀的正交频分复用(OFDM)符号;  $w_n$  为均值为 0、

方差为  $\sigma_w^2$  的加性高斯白噪声 (AWGN);  $s_n$  为信道输出信号,  $i_n$  为信道中的 IN。

## 2 算法设计

本文提出的改进 DNN 的电力线 IN 抑制与补偿算法的结构由 DNN 检测、置零处理、非线性失真补偿 3 个部分组成,如图 1 所示。

发射端符号数据  $X_k$  通过 OFDM 调制生成时域信号,经过信道后到达接收端。接收端接收到信号  $r_n$  后,首先通过 DNN 检测判断信号中是否含有 IN,输出的神经网络信号为  $y_{out}$ 。然后,根据该信号判断是否需要置零操作。若需要则经置零操作的输出信号为  $y_n$ ,再对该信号进行非线性失真重构与补偿,输出信号为  $y_n'$ ; 若不需要则直接输出  $r_n$ ,再通过快速傅里叶变换(FFT)变换为频域信号  $Y_k$  后进行处理。

### 2.1 DNN 检测

本文使用的 DNN 结构包含 1 个输入层、2 个隐藏层、1 个输出层,如图 2 所示。图中,  $W_1$ 、 $W_2$ 、 $W_3$  表示神经网络各层的权重矩阵,输出层后接 Softmax 层。采用后向传播算法和亚当(Adam)优化算法<sup>[17]</sup>对 DNN 进行训练。




图 2 DNN 结构图




图 1 改进 DNN 的电力线 IN 抑制与补偿算法结构图

1)输入层。该层设置在网络的第一层,共有6个神经元,分别表示从接收信号 $r_n$ 中提取的6个特征:①样点的幅度值。②绝对差值排序(ROAD)值。③样点实部幅度与中值的差。④样点实部幅度与上四分位点 $Q_2$ 的差。⑤样点实部幅度与下四分位点 $Q_1$ 的差。⑥样点的实部幅度。其中,ROAD、中值差、四分位数差分别定义如下:

◆ROAD计算过程如下:

当前样点值与剩余样点值差的模值<sup>[16]</sup>为

$$d(n)=|r_n-[r_1, r_2, \dots, r_{n-1}, r_{n+1}, \dots, r_N]| \quad (2)$$

对 $d(n)$ 按升序排列为

$$b(n)=\text{sort}(d(n)) \quad (3)$$

对 $b(n)$ 前一半的数据进行求和得到 $R_{\text{ROAD}}$ 值为

$$R_{\text{ROAD}}=\sum_{n=1}^{(N-1)/2} b(n) \quad (4)$$

◆中值差 $e_n$ 计算公式为

$$e_n=|\text{real}(r_n)|-\text{median}(|\text{real}[r_1, r_2, \dots, r_n, \dots, r_N]|) \quad (5)$$

◆四分位数差计算公式为

$$f_n=|\text{real}(r_n)|-Q_1 \quad (6)$$

$$g_n=|\text{real}(r_n)|-Q_2 \quad (7)$$

其中, $f_n$ 表示与下四分位数 $Q_1$ 的差值, $g_n$ 表示与上四分位数 $Q_2$ 的差值。

将接收信号的实部幅度按从大到小的顺序进行排列,并将数据进行四等分,在25%数据长度位置上的数就是下四分位数 $Q_1$ ,在75%数据长度位置上的数就是上四分位数 $Q_2$ 。

2)隐藏层。该层设置在网络的第二层与第三层,分别由20、10个神经元组成。将上一层神经元的输出进行加权组合后传递到一个非线性激活函数——线性整流(ReLU)函数,即可获得该层中每个神经元的输出值。

3)输出层。该层设置在网络的第四层,由2个神经元构成,其作用是将隐藏层神经元的输出进行加权组合之后直接传递给下一层。分类标签设置为有脉冲噪声与无脉冲噪声2种状态。为了便于神经网络较好地处理数据,提升分类的准确性,本文采用独热编码对这2种状态进行分类。

4)Softmax层。该层设置在网络的最后一层,作为网络最后的输出。Softmax层是对神经网络的输出结果进行一次换算,将输出结果用概率的形式表现出来。第 $i$ 个神经元经过Softmax层的概率输出值 $z_i$ 计算如下:

$$z_i=\frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}} \quad (8)$$

其中, $x_i$ 表示第 $i$ 个神经元的输入, $K$ 表示输出层神经元个数。

在DNN训练过程中,相比基于均方误差(MSE)损失函数的方法,本文采用Softmax与交叉熵相结合的损失函数方法更好地衡量分类问题<sup>[14]</sup>,如式(9)所示。

$$L(W, b)=-\frac{1}{m}\left\{\sum_{i=1}^m[y_i \ln(\hat{y}_i)+(1-y_i) \ln(1-\hat{y}_i)]+\frac{\lambda}{2m} \sum_{l=1}^{L-1} \sum_{i=1}^{n_l} \sum_{j=1}^{n_{l+1}} W_{ij}^2\right\} \quad (9)$$

其中, $L$ 为损失函数, $W$ 、 $b$ 分别为神经网络的权重与偏置, $m$ 为训练样本个数, $n_l$ 为第 $l$ 层神经元的数量, $\lambda$ 为正则化超参数(用于在训练阶段防止过拟合), $y_i$ 为标签值, $\hat{y}_i$ 为DNN的预测值, $W_{ij}$ 为神经网络中每个神经元的权重。

权重 $W_{ij}$ 与偏置 $b_{ij}$ 初始化的值影响着DNN的训练时间与识别率。根据文献[19]提出的DNN各层神经元的权重与偏置的初始化方法,本文将每一层的偏置 $b_{ij}$ 、权重 $W_{ij}$ 按式(10)进行初始化。

$$W_{ij} \sim U\left[-\frac{1}{\sqrt{n_d}}, \frac{1}{\sqrt{n_d}}\right] \quad (10)$$

其中, $U[-a, a]$ 在区间 $(-a, a)$ 均匀分布, $n_d$ 为本层神经元的个数。

## 2.2 置零及非线性失真补偿

在DNN锁定IN位置后,采用置零法来清除该位置的数据。因此,置零信号的输出信号可以表示为

$$y_n=\begin{cases} r_n, y_{\text{out}}=0 \\ 0, y_{\text{out}}=1 \end{cases} \quad (11)$$

其中, $y_{\text{out}}$ 是DNN的输出,0表示当前样点没有IN,1表示当前样点有IN。

传统置零法引起的非线性失真包括:有用信号的幅度衰减和子载波间干扰<sup>[9]</sup>,而且被置零的样点越多,失真越严重。因此,本文对置零后的输出信号增加非线性失真补偿部分,进一步提升系统性能。

为了降低系统计算的复杂度,本文在时域上进行非线性失真重构与补偿,结构框图如图3所示。首先,经过置零操作的输出信号 $y_n$ 变换到频域信号 $Z_k$ ;然后,经过均衡判决后得到判决符号 $X_k'$ , $X_k'$ 再除以均衡系数后通过快速傅里叶逆变换(IFFT)变换到时域信号 $S_n'$ ;最后,根据式(12)和式(13)重构出时域非线性失






图3 非线性失真补偿框图

真  $D_n$ , 再利用式(14)得到补偿之后的信号。重复上述步骤以提升重构的精确度, 本文迭代次数设置为2次。当达到迭代次数时, 控制器输出最后一次补偿的信号。

$$D_n = (B_n - 1)S_n \quad (12)$$

$$B_n = \begin{cases} 1, y_{\text{out}} = 0 \\ 0, y_{\text{out}} = 1 \end{cases} \quad (13)$$

$$y_n^{(l)} = y_n - D_n^{(l)} \quad (14)$$

其中,  $B_n$  是根据 DNN 输出设置的序列;  $l$  是重构过程的重复次数, 即迭代次数。

### 3 实验与分析

#### 3.1 数据预处理及训练数据集

由于接收信号的幅度在不同信噪比(SNR)内是不同的, 为了避免不同 SNR 信号的幅度变化过大的问题, 减轻由幅度不同引起的数据集偏差, 需要对接收信号按式(15)进行预处理。

$$x_n' = \frac{x_n - M}{\sigma} \quad (15)$$

其中,  $x_n'$  为预处理后的 OFDM 符号的样点值,  $M$  为 OFDM 符号幅度的中值,  $\sigma$  为 OFDM 符号幅度的标准差。中值在不同 IN 场景中比较稳定, 可以尽量保持原来信号的特征不变, 使 DNN 适应不同的 IN 场景。

对接收数据进行预处理后, 再进行数据集获取。训练数据集在需要研究的 SNR 与信号干扰比(SIR)范围内产生, 本文对所有 SNR 内的特征数据进行 Z 分数标准处理, 且对数据集内的样本进行随机打乱, 去除可能存在的因素影响。为了验证 DNN 模型在不同噪声环境中的鲁棒性, 训练集、验证集数据在 SNR 为 0~12 dB、SIR 为 0 dB、脉冲噪声发生概率  $p=0.1$  条件下生成, 而测试集数据按 SNR 为 0~12 dB、SIR 为 0 dB 且  $p=0.06, 0.11$  产生。实验时的 PLC 信道根据文献[20]所提的电力线信道模型进行设置。

#### 3.2 实验结果分析

本文使用 Matlab 搭建基于正交频分复用(OFDM)的仿真链路, 使用 Tensorflow 来建立 DNN 模型。计算机的配置为 i5-8250U CPU intel 内核、4G 内存、GPU GeForce MX130。根据 DNN 识别率、系统 BER、算法鲁棒性这 3 个指标对所提算法的性能进行评价。

部分仿真参数如表 1 所示。其中,  $\Gamma$  表示背景噪声与脉冲噪声的功率比值;  $J$  表示指产生脉冲噪声的分量个数;  $\gamma$  表示产生的脉冲噪声的方差。

表 1 部分仿真参数

| 参数名称             | 值                        |
|------------------|--------------------------|
| 子载波间隔/kHz        | 24.414                   |
| FFT 点数           | 1024                     |
| 数据子载波位置          | [81, 491]                |
| 调制模式             | QPSK                     |
| 循环前缀点数/个         | 512                      |
| 学习率 $\eta$       | 0.001                    |
| 正则化超参数 $\lambda$ | 0.001                    |
| 批量大小、迭代次数(epoch) | 700、100                  |
| 米德尔顿 A 类(MCA)    | $\Gamma=0.1, J=10$       |
| 高斯混合模型(GMM)      | $\gamma=10, 100, 1\ 000$ |

##### 3.2.1 DNN 识别率

增加输入特征和对接收数据进行预处理将有助于提升 DNN 的识别率, 通过以下四步来逐级验证。

DNN 的识别率如图 4 所示。“第一步”是指文献[16]所提 DNN 对 IN 的识别率。“第二步”是在文献[16]所提 DNN 的基础上增加 3 个输入特征得到的识别率。“第三步”是在“第二步”的基础上, 在输出层后接 Softmax 层得到的识别率。“第四步”是在“第三步”的基础上, 对接收数据进行预处理得到的识别率。可以看出, 当 DNN 收敛时, “第二步”网络识别率比“第一步”提升了 2.59%; “第三步”的识别率比“第二步”提升了 0.48%; “第四步”的识别率与“第三步”相差不大, 但是“第四步”的 DNN 在第 13 个 epoch 左右就能收敛, 比“第三步”大约少 63 个 epoch, 大大提升了 DNN 的收敛速度。这说明增加输入特征有助于提升网络识别率, 对接收数据进行预处理有助于加快 DNN 的收敛速度。

##### 3.2.2 系统 BER

为验证所提算法的 BER 性能, 本文将所提算法与传统置零法和文献[16]算法进行对比。传统置零法的门限获取过程如下:




图4 DNN 识别率对比

首先,采用矩估计的方法获得 IN 的参数,令  $a$ 、 $v$  和  $c$  分别表示接收信号  $r_n$  的多阶矩估计期望值,分别如式(16)~式(18)所示。

$$a = \sqrt{\frac{\pi}{2}} \{ |r| \} \quad (16)$$

$$v = E \{ |r|^2 \} \quad (17)$$

$$c = \sqrt{\frac{2\pi}{4}} E \{ |r|^3 \} \quad (18)$$

其中,  $r$  是与  $r_n$  相对应的随机变量。因此,标准差  $\sigma_1$  和  $\sigma_2$  可以表示为

$$\sigma_1 = \frac{av - c + \sqrt{(av - c)^2 - 4(a^2 - v)(v^2 - ac)}}{2(a - v)} \quad (19)$$

$$\sigma_2 = \frac{av - c - \sqrt{(av - c)^2 - 4(a^2 - v)(v^2 - ac)}}{2(a - v)} \quad (20)$$

然后,利用最优阈值对接收信号进行置零处理。最优阈值表达式如式(21)所示。

$$T_{\text{opt}} = \sqrt{\frac{2\sigma_1^2 \sigma_2^2}{\sigma_2^2 - \sigma_1^2}} \ln \left( \frac{\sigma_2}{\sigma_1} \right) \quad (21)$$

当 SIR 为 0 dB、 $p=0.06$  时, BG 噪声模型下系统 BER 曲线图如图 5 所示。“AWGN”表示发射信号只受 AWGN 影响时系统的 BER 曲线,“传统置零法”是利用式(21)对信号进行置零处理的算法,“未处理”表示不对 IN 进行处理。可以看出,在 BER 为  $10^{-3}$  左右时,本文算法所需的 SNR 要优于“传统置零”算法 4 dB 左右,优于文献[16]算法 2 dB 左右。因此,与其它算法相比,本文算法需要的 SNR 较低。

### 3.2.3 算法鲁棒性

本文采用 GMM<sup>[9]</sup>与 MCA<sup>[9]</sup>非连续噪声模型进行研究。GMM 将 IN 表示为几个高斯分量的组合,而 MCA 模型能够描述大部分实际场景中系统性能的损失,且仅需要少量参数,有助于理论研究。






图5 在 BG 噪声模型下系统的 BER 曲线图

系统 BER 曲线分别如图 6、图 7 所示。由图 6 可知,当 SIR 为 0 dB、 $p=0.11$  且 BER 为  $10^{-3}$  时,本文算法所需信号与干扰噪声比(SINR)优于传统置零算法 2 dB 以上,优于文献[16]算法 2~4 dB。由图 7 可知,在不同 IN 模型数据下,本文算法所需的 SINR 优于文献[16]算法 2 dB 左右。综上所述,本文算法的性能具有较高的优越性。



(a) BG 噪声模型



(b) MCA 噪声模型

图6 系统在 2 种噪声模型下的 BER 曲线图

庄元强, 申敏. 改进深度神经网络的电力线脉冲噪声抑制与补偿算法




图7 MCA模型训练的DNN在GMM下测试的BER

## 4 结束语

本文结合 DNN 和非线性失真补偿方法, 提出了一种改进 DNN 的电力线 IN 抑制与补偿算法, 解决了 IN 先验信息的估计和置零引起的非线性失真的问题。仿真结果表明: 所提算法提升了神经网络的识别率, 降低了系统 BER, 具有较好的鲁棒性。

## 参考文献:

- [1] 王子坤. 基于机器学习的电力通信网切片资源分配与脉冲噪声削减方法[D]. 南京: 南京理工大学, 2021.
- [2] 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.
- [3] BAI T, ZHANG H, WANG J, et al. Fifty years of noise modeling and mitigation in power-line communications [J]. IEEE Communications Surveys & Tutorials, 2020, 23(1): 41–69.
- [4] 吕新荣. 低压电力线通信系统抗干扰的理论与方法研究[D]. 宁波: 宁波大学, 2019.
- [5] CAIRE G, AL-NAFFOURI T Y, NARAYANAN A K. Impulse noise cancellation in OFDM: an application of compressed sensing [C]//IEEE. Proceedings of 2008 IEEE International Symposium on Information Theory. Toronto: IEEE, 2008: 1293–1297.
- [6] LIN J, NASSAR M, EVANS B L. Impulsive noise mitigation in power-line communications using sparse Bayesian learning [J]. IEEE Journal on Selected Areas in Communications, 2013, 31(7): 1172–1183.
- [7] SHRESTHA D. Impulsive noise cancellation and channel estimation in power line communication systems [D]. Barcelona: Universitat Politècnica de Catalunya, 2019.
- [8] NDO G, SIOHAN P, HAMON M H. Adaptive noise mitigation in impulsive environment: application to power-line communications [J]. IEEE Transactions on Power Delivery, 2010, 25(2): 647–656.
- [9] 申敏, 李飞, 张恒. 一种改进的电力线通信系统脉冲噪声抑制方法[J]. 电讯技术, 2018, 58(1): 46–51.
- [10] ISAC A, SELIM B, SOBHANIGAVGANI Z, et al. Impulsive noise parameter estimation: A deep CNN-LSTM network approach [C]//IEEE. Proceedings of 2021 4th International Conference on Advanced Communication Technologies and Networking (CommNet). Rabat: IEEE, 2021: 1–6.
- [11] SELIM B, ALAM M S, KADDOUM G, et al. A deep learning approach for the estimation of Middleton class-A impulsive noise parameters [C]//IEEE. Proceedings of International Conference on Communications (ICC). Dublin: IEEE, 2020: 1–6.
- [12] HUSSAIN M, SHAKIR H, RASHEED H. Deep learning approaches for impulse noise mitigation and classification in NOMA-based systems[J]. IEEE Access, 2021, 9: 143836–143846.
- [13] SELIM B, ALAM M S, EVANGELISTA J V C, et al. NOMA-based IoT networks: impulsive noise effects and mitigation[J]. IEEE Communications Magazine, 2020, 58(11): 69–75.
- [14] TSENG D F, LIN C S. A study of neural network receivers in OFDM systems subject to memoryless impulse noise [C]//IEEE. Proceedings of 2021 30th Wireless and Optical Communications Conference (WOCC). Taipei: IEEE, 2021: 16–20.
- [15] 卢致坚. 脉冲噪声下基于支持向量机的频谱感知技术研究 [D]. 广州: 广东工业大学, 2022.
- [16] BARAZIDEH R, NIKNAM S, NATARAJAN B. Impulsive noise detection in OFDM-based systems: a deep learning perspective[C]//IEEE. Proceedings of 2019 IEEE 9th Annual Computing and Communication Workshop and Conference(CCWC). Las Vegas: IEEE, 2019: 0937–0942.
- [17] KINGMA D P, BA J. Adam: a method for stochastic optimization [EB/OL]. (2017–01–30)[2023–01–29]. <https://arxiv.org/abs/1412.6980v6>.
- [18] BARAZIDEH R, NIKITIN A V, NATARAJAN B. Practical implementation of adaptive analog nonlinear filtering for impulsive noise mitigation [C]//IEEE. Proceedings of 2018 IEEE International Conference on Communications(ICC). Kansas City: IEEE, 2018: 1–7.
- [19] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [C]//IEEE. Proceedings of Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. JMLR Workshop and Conference Proceedings. Sardinia: IEEE, 2010: 249–256.
- [20] ZIMMERMANN M, DOSTERT K. A multipath model for the power-line channel[J]. IEEE Transactions on Communications, 2002, 50(4): 553–559.