

海面短波地波通信中基于 DNN 神经网络的单样本极化滤波器预测研究

张嘉纹, 党小宇, 杨凌辉, 齐茹梦, 王 萌
(南京航空航天大学电子信息工程学院, 江苏南京 211106)

摘要: 针对海面通信受大气噪声干扰严重的问题, 该文提出一种基于 DNN(Deep Neural Network)神经网络的单样本极化滤波器预测模型, 研究其对海面短波地波通信链路中的大气噪声的抑制作用. 与传统算法不同, DNN 神经网络直接从大量输入数据获取信息间的非线性特性, 并以此更新网络参数, 通过对模型参数调整使得模型达到最优状态. 选择三种脉冲成分比例不同的大气噪声进行仿真, 结果表明传统算法与 DNN 网络模型在低信噪比约 0 ~ 15dB 时对信号的误码率影响基本一致, 在高信噪比约超过 15dB, 误码率达到 10^{-4} 时, 深度学习模型比传统算法所需信噪比显著提高约 5dB. 实验结果验证了神经网络在单样本极化滤波器预测方向的可行性与准确性, 具有很好的实用参考价值.

关键词: 深度神经网络; 大气噪声; 单样本极化滤波器

中图分类号: TN926

文献标识码: A

文章编号: 0372-2112 (2020)11-2250-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2020.11.022

Research on Single Sample Polarization Filter Based on Deep Neural Network in Short Ground-Wave Communication over the Sea Surface

ZHANG Jia-wen, DANG Xiao-yu, YANG Ling-hui, QI Ru-meng, WANG Meng

(School of Electronic Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 211106, China)

Abstract: Aiming at the problem that the sea surface communication is seriously disturbed by atmospheric noise, this paper proposes a single sample polarization filter prediction model based on deep neural network, and studies its suppression effect on atmospheric noise in the sea surface short ground wave communication link. DNN neural network directly obtains the non-linear characteristics between information from a large amount of input data, which uses it to update the network parameters, and adjusts the model parameters to make the model reach the optimal state. Three types of atmospheric noise with different proportions of pulse components are selected for simulation. The results show that the traditional algorithm and the DNN network model have basically the same effect on the signal error rate when the signal-to-noise ratio is about 0 ~ 15dB. When the bit error rate reaches 10^{-4} , the deep learning model improves the signal-to-noise ratio by about 5dB compared with the traditional algorithm. The experimental results verify the feasibility and accuracy of the neural network in predicting the direction of the single-sample polarization filter coefficients, which has good practical value.

Key words: deep neural network; atmospheric noise; single sample polarization filter

1 引言

现阶段海面通信方式主要包括卫星与微波传输, 卫星通信具有频带宽、覆盖面积广的特点, 但卫星造价昂贵, 设备使用周期受限, 卫星与通信设备无线链路时延较长, 且海面环境易受大气噪声影响, 更加不利于实

时大容量数据通信系统的建立^[1]. 微波通信频带宽, 传输信息的容量大, 海上微波通信设备设计灵活, 便于使用携带, 但微波波长较短, 遇到障碍就被反射或被阻断, 对微波通信设备的工艺要求也相对较高^[2]. 随着国家海洋领域重大创新工程“智慧海洋”的提出, 对海上通信的需求日益加强, 海面通信背景下, 针对传统卫星和

收稿日期: 2020-01-15; 修回日期: 2020-05-25; 责任编辑: 马兰英

基金项目: 国家自然科学基金(No. 61971221, No. 61971220); 中央高校基本科研业务费专项资金资助(No. 2020104); 南京航空航天大学研究生创新基地(实验室)开放基金(No. kfj20190416)

微波传输方式存在的时延长、抗干扰性差等问题,本文引入短波通信作为海上通信的主要方式.短波无线通信环境下,电波通常以天波形式传输,电波信号经由高空电离层反射到达地面接收机.由于受随机电离层反射的影响,天波信号具有明显的衰落特征^[3],不同时间、地点、季节、昼夜的电离层特性变化较大,导致天波通信信道呈现随机的不规则变化,信号强度不稳定.地波传输不涉及电离层反射,仅与地面性质有关^[4].传统地波多以窄带方式进行传输,但不能满足海面大容量数据传输业务需求.由于近年来,我国对海洋信息有了更高更多的要求,本文选用工作频率为 10MHz、带宽为 1MHz 的宽带短波地波作为粗糙海面主要传输方式,信号带宽变宽后,距离分辨力随之提高,从而我们会得到更多的信息.海面气候环境复杂,无线通信链路主要受海面上空雷电活动产生的大气噪声干扰.将大气噪声视为具有非高斯性的电磁脉冲信号,其频谱范围较广,脉冲频带较宽,对设备接收端信号影响较大.为了进一步抑制噪声干扰,研究提高短波通信系统性能的有效途径,本文对高频通信系统进行建模仿真和性能分析.

雷电瞬时放电引起的大气噪声是海面电波传播的主要干扰源,其幅度分布具有较厚的拖尾且波动较大.大量研究学者对生成符合实际信道特性的大气噪声进行相关研究^[5-9],文献[5]研究了对称 $\text{S}\alpha\text{S}$ (Symmetric alpha-Stable) 稳定分布的大气噪声建模方法.文献[6]提出一种基于 $\text{S}\alpha\text{S}$ 稳定分布的大气噪声计算方法,可以根据相应的参数实时计算产生不同分布的噪声信号.文献[7]提出可根据极大似然估计等方法来估计 $\text{S}\alpha\text{S}$ 稳定分布模型的参数.文献[8]中的实际测量结果表明对称 $\text{S}\alpha\text{S}$ 稳定分布,不仅包含了高斯分布的情形(特征指数 $\alpha = 2$),而且能够反映背景噪声的脉冲特性,满足广义中心极限定理^[9].

近年来,极化滤波技术在信号抗干扰方向被广泛应用^[10-13].文献[10]提出单凹口极化滤波器和多凹口极化滤波器,将其用于抑制雨杂波,取得了较理想的效果.文献[11]提出了零相移极化滤波器,成功解决了常规极化滤波方法对目标信号的幅度和相位带来的时变影响的问题.文献[12]提出一种单样本极化滤波方法,该方法不同于传统滤波算法,对数据样本规模依赖性较低,并将其应用在高频雷达领域.本文基于单样本极化滤波算法,研究了海面大气噪声干扰抑制对通信链路接收端误码率的影响.由于不稳定的大气噪声以及滤波器设计阶段存在的非线性等因素,如何设计更加精确的滤波器结构成为本文研究的重点问题.

随着机器学习在无线通信领域取得了很多成功的示范,深度神经网络以及强化学习在信道编码以及信道估计方面的研究取得了较大的进展^[14-17].例如:文献[14]

提出了一种基于信道互相关信息的神经估计器,有效改善了基于 DNN 网络信道编码的端到端无线网络通信系统性能.文献[16]使用深度神经网络实现调制系统的直接解码,证明了神经网络在无线通信系统中自动编解码的可行性.文献[17]基于 OFDM (Orthogonal Frequency Division Multiplexing) 调制系统,利用深度学习模型对信道失真问题进行了估计与检测.虽然深度学习在以上无线领域取得了较多研究成果,但是在单样本极化滤波器分量预测方面的研究还没有涉及.本文为提高通信系统误码性能,提出了基于 DNN 神经网络的单样本极化滤波器预测模型.实验结果表明,本文提出的深度学习模型,在不同的大气噪声分布环境下,相对于传统算法,可以抽象出不稳定大气噪声下极化滤波器带来的非线性影响,从而更好地抑制干扰信号并提高通信链路的误码性能.

2 系统模型

设在接收端接收到的混合信号为目标与干扰信号的矢量和,即为:

$$\mathbf{E}_i(n) = \mathbf{E}_s(n) + \mathbf{E}_d(n) \quad (1)$$

其中, $\mathbf{E}_i(n)$ 为混合信号, $\mathbf{E}_s(n)$ 为目标信号, $\mathbf{E}_d(n)$ 为干扰信号.假设目标信号是完全极化的电磁波,选取垂直和水平线极化基,设极化变换后的目标信号可以用 Jones 矢量描述为^[12]:

$$\mathbf{E}_s(n) = \begin{bmatrix} \mathbf{E}_{sh}(n) \\ \mathbf{E}_{sv}(n) \end{bmatrix} = E_s(n) \exp\left(j 2\pi \frac{f_c}{f_s} n\right) \begin{bmatrix} \cos \varepsilon_s \\ \sin \varepsilon_s \exp(j\delta_s) \end{bmatrix} \quad (2)$$

其中, $\mathbf{E}_{sh}(n)$ 和 $\mathbf{E}_{sv}(n)$ 分别代表水平极化和垂直极化方向上的目标信号分量, f_c 为目标信号的中心频率, f_s 为采样频率, ε_s 代表目标信号的极化角, δ_s 代表水平极化分量与垂直极化分量的相位差.

雷电活动产生的大气噪声干扰信号的本质为电磁辐射,因此也可以在极化域表示成:

$$\mathbf{E}_d(n) = \begin{bmatrix} \mathbf{E}_{dh}(n) \\ \mathbf{E}_{dv}(n) \end{bmatrix} = E_d(n) \exp\left(j 2\pi \frac{f_d}{f_s} n\right) \begin{bmatrix} \cos \varepsilon_d \\ \sin \varepsilon_d \exp(j\delta_d) \end{bmatrix} \quad (3)$$

其中, $\mathbf{E}_{dh}(n)$ 和 $\mathbf{E}_{dv}(n)$ 分别代表水平极化和垂直极化方向上的干扰信号分量, f_d 为干扰信号的中心频率, ε_d 代表干扰信号的极化角, δ_d 代表干扰信号水平与垂直极化分量的相位差.

根据上述表达式,滤波器系数的向量矩阵可以在极化域表示为:

$$\mathbf{H}_r(n) = \begin{bmatrix} \mathbf{H}_{rh}(n) \\ \mathbf{H}_{rv}(n) \end{bmatrix} = H_r(n) \begin{bmatrix} \cos \varepsilon_r \\ \sin \varepsilon_r \exp(j\delta_r) \end{bmatrix} \quad (4)$$

式中, ε_r 和 δ_r 分别为滤波器矢量的极化角和水平与垂直极化分量的相位差.此时滤波器的输出信号为:

$$\begin{aligned} |V_o(n)| &= |E_i(n) * H_r(n)| \\ &= |H_r^H(n)E_s(n) + H_r^H(n)E_d(n)| \end{aligned} \quad (5)$$

考虑和干扰相关的部分 $H_r^H(n)E_d(n)$, 显然, 如果满足条件:

$$\varepsilon_r = \varepsilon_d + \frac{\pi}{2} \quad (6)$$

$$\delta_r = \delta_d \quad (7)$$

则

$$H_r^H(n)E_d(n) = 0 \quad (8)$$

此式说明理论上可以完全滤除接收到的混合信号中的干扰分量.

3 单样本极化滤波器

传统的滤波算法大多是通过估计自相关和互相关函数来生成滤波向量, 需要大量的样本数据. 本文考虑了单样本极化滤波思想, 认为部分极化波的瞬时极化状态可以看作是具有相同极化状态的完全极化波的一个样本, 打破了需要大量样本的限制, 该方法将滤波向量估计转化为估计三个分量因子. 将接收端用双极化天线接收到的混合信号通过一个带通滤波器进行截取从而得到干扰信号在水平和垂直极化方向上的极化信息^[13], 设定载波频率为 10MHz, 设定 FIR (Finite Impulse Response) 带通滤波器的中心频率设 35MHz, 带宽为 10MHz, 采样频率为 10MHz, 在频带上截取噪声信息.

得到的干扰信号在水平和垂直极化方向上的极化信息信号为:

$$R_H(n) = \text{Re}[E_{dH}(n)] = E_d(n) \cos \varepsilon_d(n) \cos\left(2\pi \frac{f_d}{f_s} n\right) \quad (9)$$

$$I_H(n) = \text{Im}[E_{dH}(n)] = E_d(n) \cos \varepsilon_d(n) \sin\left(2\pi \frac{f_d}{f_s} n\right) \quad (10)$$

$$\begin{aligned} R_V(n) &= \text{Re}[E_{dV}(n)] \\ &= E_d(n) \sin \varepsilon_d(n) \cos\left(2\pi \frac{f_d}{f_s} n + \delta_d(n)\right) \end{aligned} \quad (11)$$


$$\begin{aligned} I_V(n) &= \text{Im}[E_{dV}(n)] \\ &= E_d(n) \sin \varepsilon_d(n) \sin\left(2\pi \frac{f_d}{f_s} n + \delta_d(n)\right) \end{aligned} \quad (12)$$

其中, $R_H(n)$, $I_H(n)$, $R_V(n)$, $I_V(n)$ 分别为干扰信号在水平和垂直方向上的实部与虚部分量.


利用归一化作图方法, 噪声信号在两路方向的实部与虚部信号频谱图如图 1 所示.

定义:


$$P_0(n) = \frac{1}{[P_1(n) + P_2(n)]} \quad (13)$$




(a) 水平方向实部信号频谱



(b) 水平方向虚部信号频谱



(c) 垂直方向实部信号频谱



(d) 垂直方向虚部信号频谱

图1 噪声信号频谱图

$$P_1(n) = R_H^2(n) + I_H^2(n) \quad (14)$$

$$P_2(n) = R_V^2(n) + I_V^2(n) \quad (15)$$

$$P_3(n) = [(R_H(n) + R_V(n))/2]^2 + [(I_H(n) + I_V(n))/2]^2 \quad (16)$$

$$P_4(n) = [(\mathbf{R}_H(n) - \mathbf{I}_V(n))/2]^2 + [(\mathbf{R}_V(n) + \mathbf{I}_H(n))/2]^2 \quad (17)$$

根据上述五个分量构造单样本极化滤波器分量:

$$\mathbf{H}_1(n) = -[\mathbf{P}_2(n)\mathbf{P}_0(n)]^{0.5} \quad (18)$$

$$\mathbf{H}_2(n) = [2\mathbf{P}_4(n)\mathbf{P}_0(n) - 0.5]/\mathbf{H}_1(n) \quad (19)$$

$$\mathbf{H}_3(n) = [0.5 - 2\mathbf{P}_3(n)\mathbf{P}_0(n)]/\mathbf{H}_1(n) \quad (20)$$

其中 $\mathbf{H}_1(n), \mathbf{H}_2(n), \mathbf{H}_3(n)$ 构成滤波向量. 当滤波向量与干扰信号完全正交时, 噪声被完全抑制. 因此, 以上三个因子可以直接从干扰信号中推导出来. 在本实验中, 目标与干扰信号的极化角均可在 $0^\circ \sim 90^\circ$ 随机产生. 在实际应用中, 发射信号常采用垂直极化, 因此本文在整个模拟通信过程中对发射信号采用垂直极化方式, 假设发射信号的极化参数不改变, 设置目标信号的极化角为 90° , 干扰信号的极化角由均值为 45° 的随机分布产生. 带有单样本极化滤波器的调制系统干扰抑制框图如图 2 所示.

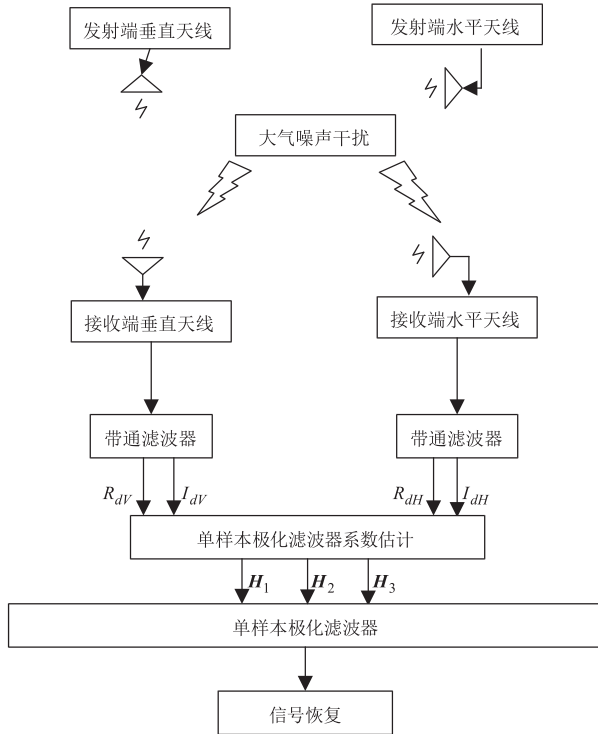


图2 大气噪声干扰抑制系统图

4 DNN 网络模型

4.1 网络模型及参数设置

接收端采用双极化天线进行接收, 接收端目标和干扰的混合信号主要存在于水平和垂直方向的极化信息中, 为使网络更容易学习到数据间特征, 将接收端每个混合信号的实部和虚部拆分, 分别作为独立数据进行训练. 选取水平与垂直方向的混合信号极化信息即 R_H, I_H, R_V, I_V 作为网络输入进行训练, 采用 DNN 深度神经网络作为模型训练架构, 具体如图 3 所示. 模型输入

为 4 维度的特征向量.

$$\mathbf{T} = [\mathbf{R}_H, \mathbf{I}_H, \mathbf{R}_V, \mathbf{I}_V] \quad (21)$$

隐藏层采用全连接方式, 共 3 层, 分别选择每层 16、32、64 个神经元. 输出层为 3 维向量, 即预测的单样本极化滤波器分量 H_1, H_2, H_3 .

$$\mathbf{O} = [\mathbf{H}_1, \mathbf{H}_2, \mathbf{H}_3] \quad (22)$$

模型训练过程中抽取的训练样本和对应标签的数据为: $\mathbf{D}_{\text{input}} = \{(\mathbf{T}_1, \mathbf{O}_1), (\mathbf{T}_2, \mathbf{O}_2), \dots, (\mathbf{T}_m, \mathbf{O}_m)\}, m = 1, 2, \dots, 10^4$ (23)

将网络训练中的每层输出特征数据分成“小批”样本, 对每个“小批”样本结合标准差拟合方法进行批量归一化算法后再输入到神经网络的下一层, 克服了极化滤波算法在数据集中数据不完整情况下预测不佳的问题.

模型训练过程主要包括训练样本的网络前向传播以及误差项的网络反向传播过程. 网络前向传播得到学习后的滤波器系数预测值, 通过损失函数计算网络在这批数据上的输出值与目标值之间的误差, 以此衡量网络在训练数据后的预测值与预期结果的匹配程度, 计算损失相对于网络权重的梯度, 通过梯度下降法来一步步的迭代更新各个神经元的权重以及偏置参数, 直至达到模型预先设定的迭代次数或者所得误差在指定的范围为止.

本文使用 10000 个数据进行训练, 设定一批数据包含的样本数目为 64, 迭代次数的初始阈值设为 156, 经观测预测值与实际值间误差 Loss 图, 可知在训练初期, 误差值会迅速降低, 随后趋于稳定. 若迭代次数过高, 则会导致资源浪费, 算法耗时较长. 因此设置 H_1, H_2 与 H_3 迭代次数均为 55.




图3 DNN网络模型架构

第 l 层第 i 个节点输入为:

$$z_i^l = \sum_{k=1}^N \mathbf{w}_{ik}^l \mathbf{a}_k^{l-1} + \mathbf{b}_i^l, i = 1, 2, \dots, n, l = 1, 2, \dots, L \quad (24)$$

其中, \mathbf{w}_{ik}^l 为第 $l-1$ 层第 i 个节点与第 l 层第 k 个节点之间的权重. \mathbf{b}_i^l 为第 l 层第 i 个节点的偏置. N 为第 $l-1$ 层的节点数量. 权重及偏置按照标准正态分布采用随

机初始化的方法. 每个神经元的权重向量初始化为从均值为 0 的单位标准高斯分布进行取样的随机向量.

第 l 层第 i 个节点的输出为:

$$\mathbf{a}_i^l = f_{\text{Relu}}(z_i^l), i = 1, 2, \dots, n, l = 1, 2, \dots, L \quad (25)$$

在每层网络间引入了非线性激活函数. 若无激活函数, 无论神经网络深度如何, 模型与一层网络本质上是没有区别的. 通过在层与层之间添加非线性项以及偏置项, 当增加网络层数时, 模型会有更好拟合性. 文中 f_{Relu} 为 'Relu' 激活函数, 也用于解决 DNN 网络模型训练过程中梯度爆炸和梯度消失的问题^[16], 如式(26)所示, 参数小于 0 激活函数输出为 0, 参数大于 0 则自身作为激活函数输出.

$$f_{\text{Relu}}(\mathbf{T}(n)) = \max(0, \mathbf{T}(n)) \quad (26)$$

输出层输出为:

$$O = f\left(\sum_{j=1}^J \mathbf{w}_{ji}^l L_j^l\right), i = 1, 2, \dots, n, l = 1, 2, \dots, L \quad (27)$$

其中 J 为隐藏层节点数, f 代表线性输出, 作为回归预测模型的输出层激活函数.

如果训练模型在输出层未能达到定义误差函数精度要求, 则转入深度网络反向传播阶段, 计算损失相对于网络权重的梯度, 通过梯度下降法来一步步的迭代求解, 将权重参数沿着梯度的反方向移动, 使损失函数最小化^[14]. 本研究选用平均绝对误差 (MAE) 函数 (Mean-Square Error) 作为损失函数.

$$\text{MAE} = \frac{\sum_{i=1}^N |H_i - H_{pre}|}{N} \quad (28)$$

其中 H_i 和 H_{pre} 分别代表期望的滤波器分量和模型预测出的滤波器分量.

深度网络反向传播阶段, 第 l 输出层梯度为:

$$\zeta_i^l = (\mathbf{w}_i^{l+1})^T \zeta_i^{l+1} \odot f'_{\text{Relu}}(z_i^l) \quad (29)$$

更新第 l 层的权重和偏置为:

$$\mathbf{w}_l = \mathbf{w}_l - \alpha \sum_{i=1}^m \zeta_i^l (\mathbf{a}_i^{l-1})^T \quad (30)$$

$$\mathbf{b}_l = \mathbf{b}_l - \alpha \sum_{i=1}^m \zeta_i^l \quad (31)$$

随着深度学习网络层数的加深以及大量的训练数据, DNN 网络也会面临过拟合的问题. Nitish 等人^[13]提出 Dropout 技术的应用可以使网络获得较好的性能. 该文引入 Dropout 技术, 每次训练过程中网络随机将部分输出值舍弃, 减少训练参数的同时, 可以增强模型的泛化能力, 寻找到更优解.

以上对 DNN 网络各个参数及其理论进行了分析, 本文最终设计以下网络训练参数, 具体如表 1 所示, 该参数下, 模型观测指标朝着减小预测滤波器系数和期

望值误差的方向优化.

表 1 DNN 网络仿真参数

参数名称	数值
输入层维度	4
隐藏层维度	3 * 32
输出层维度	3
激活函数	Relu
Dropout 层	0.2
学习率	0.001
损失函数	MAE
训练 Epochs	100
优化器	RMSprop
训练步长 Batch Size	64
训练集所占数据比例	80%
交叉验证集所占数据比例	10%
测试集所占数据比例	10%

4.2 模型指标监测

模型训练效果可以通过观察指定迭代次数内指标变化趋势, 从而对模型训练效果做出评价. 图 4 分别给出了 3×32 结构的 DNN 模型对于三个滤波器分量在




图4 MAE训练指标监测

MAE 指标上的训练效果,可以看出,在训练次数逐步增大的过程中,模型在交叉验证数据集上的预测滤波器系数数值与期望值之间的误差指标在逐步减小,说明网络的权重与偏置参数在朝着减小预测值与期望值之间误差的方向优化。

4.3 通信系统误码率仿真分析

本文由雷电辐射产生的大气噪声信号用 Alpha 稳定分布模型来表示.模型中最重要的参数特征指数 α ($0 \leq \alpha \leq 2$),代表了脉冲程度分布,当 α 越小时,噪声尖峰脉冲越明显,衰减越慢,拖尾就更厚^[5].特征指数大于 1 时更接近实际雷电活动产生的大气噪声。

本文选择三个不同的大气噪声特征指数,分别为 1.1、1.3、1.5,分别用传统算法和 DNN 网络模型对单样本极化滤波器分量进行预测,再对整个调制系统进行误码率性能仿真,具体对比图如图 5 所示.仿真选择 BPSK 调制方式,仿真系统产生 10^4 个原始比特,采样频率设置为 10MHz,载波频率为 10MHz,码元速率 10^6 bit/s.结果表明,在大气噪声特征指数为 1.1 时,最接近实际情况的大气噪声,混合信号中噪声脉冲幅度较高,噪声中的脉冲所占比例较大,在达到 10^{-4} 误码率条件下,所需信噪比较大.随着特征指数增加,混合信号中噪声脉冲所占比例较小,对系统性能影响较小,在达到 10^{-4} 误码率条件下,所需信噪比随之减小。

传统算法构造的单样本极化滤波器对噪声有较好的抑制作用,在达到 10^{-4} 误码率的条件下,经过滤波器比不经过滤波器的所需信噪比提高约 5dB.本文选择三种神经网络模型结构,隐藏层采用全连接方式,共 3 层,分别选择每层 16、32、64 个神经元.在三种大气噪声分布下,DNN 网络模型对单样本极化滤波器的分量中非线性因素的预测效果更稳定,低信噪比约 15dB 以下时,通过神经网络和传统单样本极化滤波算法构造出的滤波器对信号的误码率影响基本一致,说明传统算法提取噪声信息的能力与模型效果一致.但是在高信噪比约超过 15dB 时,由于传统算法提取的噪声信息会有部分信号混入,导致滤波器性能下降,而深度学习模型在高信噪比情况下依然能保持较准确地噪声滤波器分量预测.DNN 模型构造出的滤波器比传统算法所需信噪比显著提高约 5dB.

在同一特征指数分布下,DNN 网络模型在高信噪比约超过 15dB 时随着神经元个数的增加对滤波器分量的预测会略有不同.在达到 10^{-4} 误码率的条件下,含有不同神经元个数的 DNN 网络模型所需信噪比一致.本文为此类问题提供了另一条思路,即利用端到端思想,从大量数据样本空间寻找潜在规律,从而构造滤波器分量.以上分析表明,DNN 网络模型能从被污染的接收端信号中,最大可能地提取噪声信

息,以此构造极化滤波器,达到最大程度抑制噪声的能力.这源于 DNN 网络直接从输入的大量数据特征中寻找变量间的非线性特性,提高了模型在复杂的噪声干扰下的泛化能力。




图5 传统算法与DNN网络模型误码率对比图

5 结束语

本文研究了单样本极化滤波器对调制系统的误码性能的影响,大量的仿真和数值分析表明单样本极化滤波器对大气噪声有明显的抑制作用,在达到 10^{-4}

误码率的条件下,经过滤波器比不经过滤波器的所需信噪比提高约 5dB. 而采用 DNN 模型的极化滤波器预测方法,对大气噪声的抑制效果更加明显,比传统算法所需信噪比显著提高约 5dB. 产生这种差异的原因在于在高信噪比时,传统算法截取噪声信息会有少量传输信号混入,导致滤波器分量设计有较大波动. 而深度学习模型在高信噪比情况下依然能保持较准确地提取能力. DNN 神经网络直接从大量输入数据获取信息间的相关特性,并以此更新网络参数,通过对模型参数调整以及误差指标的监控,使得模型达到最优状态,模型测试结果表明, DNN 网络模型能够有效地从被大气噪声污染的信号中提取滤波器分量,从而达到大气噪声抑制效果. 粗糙海面能否进行通信很大程度上取决于链路的误码性能,本文提出的 DNN 神经网络相较于传统单样本极化滤波器算法,抑制噪声的能力有较大提升,对海面短波地波通信具有重要的指导意义.

参考文献

- [1] 张建飞,丁广,杨建东. 海上云层和降水对船载高频段卫星通信的影响[J]. 电子学报,2018,46(2):381-386.
ZHANG Jian-fei, DING Guang, YANG Jian-dong. Influence of ocean clouds and precipitation to shipborne high frequency band satellite communication [J]. Acta Electronica Sinica,2018,46(2):381-386. (in Chinese)
- [2] 刘西川,宋堃,高太长,胡云涛. 复杂大气条件对微波传播衰减的影响研究[J]. 电子与信息学报,2018,40(1):181-188.
LIU Xi-chuan, SONG Kun, GAO Tai-chang, HU Yun-tao. Research on the effect of complex atmospheric condition on microwave propagation attenuation[J]. Journal of Electronics and Information Technology, 2018, 40(1): 181-188. (in Chinese)
- [3] 周万幸. 天波超视距雷达发展综述[J]. 电子学报,2011,39(6):1373-1378.
ZHOU Wan-xing. An overview on development of skywave over-the-horizon radar [J]. Acta Electronica Sinica, 2011, 39(6): 1373-1378. (in Chinese)
- [4] 王玉珏. 粗糙海面短波地波通信链路分析与计算[J]. 通信技术,2015,48(6):677-681.
WANG Yu-jue. Analysis and calculation of short-wave ground wave communication link on rough sea surface [J]. Journal of Electronics and Information Technology, 2015, 48(6): 677-681. (in Chinese)
- [5] 陈媛,刘金磊,孙奇福. S α S 分布噪声环境下高分辨率二维 DOA 估计算法及快速实现[J]. 电子学报,2018,46(06):1384-1389.
CHEN Yuan, LIU Jin-lei, SUN Qi-fu. A high resolution algorithm for 2d-doa estimation and its fast implementation in the presence of s α s distributed noise [J]. Acta Electronica Sinica, 2018, 46(06): 1384-1389. (in Chinese)
- [6] 罗忠涛,卢鹏,张杨勇,张刚. 抑制脉冲型噪声的限幅器自适应设计[J]. 电子与信息学报,2019,41(5):1160-1166.
LUO Zhong-tao, PENG Lu, ZHANG Yang-yong, ZHANG Gang. Adaptive design of limiters for impulsive noise suppression[J]. Journal of Electronics and Information Technology, 2019, 41(5): 1160-1166. (in Chinese)
- [7] BENAÏSSA A, ABDELMALEK A, FEHAM M. Improved reliability of power line communication under alpha-stable noise[A]. Proceedings of 2017 International Conference on Electrical Engineering[C]. Boumerdes, Algeria;2017. 1-5.
- [8] LAGUNA-SANCHEZ G, LOPEZ-GUERRERO M. On the use of alpha-stable distributions in noise modeling for PLC [J]. IEEE Transactions on Power Delivery, 2015, 30(4): 1863-1870.
- [9] MAHMOOD A, CHITRE M. Optimal and near-optimal detection in bursty impulsive noise[J]. IEEE Journal of Oceanic Engineering, 2017, 42(3): 639-653.
- [10] GHERARDELLI, M. Adaptive polarisation suppression of intentional radar disturbance [J]. Radar Sgzgnal Process, IEE Processing F, 1990, 137(6): 407-417.
- [11] 毛兴鹏,刘永坦,邓维波. 频域零相移多凹口极化滤波器[J]. 电子学报,2008,36(3):537-542.
MAO Xing-peng, LIU Yong-tan, DENG Wei-bo. Frequency-domain zero-phase shift multi-notch polarization filter [J]. Acta Electronica Sinica, 2008, 36(3): 537-542. (in Chinese)
- [12] Qiao X L, Jin M. Radio disturbance suppression for HF radar [J]. IEE Proceedings-Radar Sonar and Navigation, 2001, 148(2): 89-93.
- [13] Xiaolin Q, Ming J, Xinpeng M. Atmospheric noise suppression for HF radar [A]. CIE International Conference on Radar Proceedings (Cat No. 01TH8559) [C]. Beijing: 2001. 992-995.
- [14] FRITSCHKE R, SCHAEFER R F, WUNDER G. Deep learning for channel coding via neural mutual information estimation [A]. 2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications [C]. Cannes, France; 2019. 1-5.
- [15] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [16] GRUBER T, CAMMERER S, HOYDIS J, et al. On deep learning-based channel decoding [A]. 2017 51st Annual Conference on Information Sciences and Systems (CISS) [C]. Baltimore, MD, USA; 2017. 1-6.
- [17] HAO Ye, LI G Y, JUANG B-H. Power of deep learning

for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2018, 7

(1):114-117.

作者简介



张嘉纹 女,1997 年出生. 现为南京航空航天大学硕士研究生. 主要研究方向为海面无线信道建模、信号极化信息处理及极化滤波器设计研究.

E-mail:17843103897@163.com



党小宇(通信作者) 男,1973 年出生. 现为南京航空航天大学电子信息学院教授、博士生导师. 主要研究领域为航空航天通信和测控网络中的科学理论与应用.

E-mail:dang@nuaa.edu.cn