

基于深度学习的 DTMB 外辐射源雷达参考信道估计

陈 赓¹, 田 波¹, 宫 健¹, 冯存前^{1,2}

(1. 空军工程大学防空反导学院, 西安, 710051; 2. 信息感知技术协同创新中心, 西安, 710077)

摘要 参考数据的纯度影响着地面数字广播多媒体(DTMB)外辐射源雷达的探测能力,而参考信道估计的精度是影响参考数据恢复的关键因素。针对此问题,文章将基于深度学习理论的信道估计方法引入外辐射源雷达参考信道估计过程。利用自回归模型对参考信道进行建模,并搭建参考信道估计网络。通过迭代训练后,估计得到参考信道响应。相比于传统算法,基于深度学习的参考信道估计精度得到有效提升,改善了雷达的探测性能。

关键词 外辐射源雷达;深度学习;DTMB 信号;信道估计

DOI 10.3969/j.issn.1009-3516.2020.02.009

中图分类号 TN958 **文献标志码** A **文章编号** 1009-3516(2020)02-0061-04

DTMB Passive Radar Reference Channel Estimation Based on Deep Learning

CHEN Geng¹, TIAN Bo¹, GONG Jian¹, FENG Cunqian^{1,2}

(1. Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China;
2. Collaborative Innovation Center of Information Sensing and Understanding, Xi'an 710077, China)

Abstract: The purity of reference data affects the detection capability of DTMB passive radar, and the accuracy of reference channel estimation is a key factor to affect the recovery of reference data. In view of this problem, the channel estimation method based on the deep learning theory is introduced into the passive radar reference channel estimation process. The reference channels are modeled by the autoregressive model and the reference channel estimation network is built. After iterative training, the reference channel response is estimated. Compared with the traditional algorithm, the estimation accuracy of reference channel based on deep learning is improved effectively, and the detection performance of radar is improved.

Key words: passive radar; deep learning; DTMB signal; channel estimation

近年来,外辐射源雷达以其低成本、重量轻以及良好的抗干扰性能等优点成为国内外研究的热点^[1-3]。DTMB 外辐射源雷达利用外部已经存在的 DTMB 信号,通过检测空中目标的反射回波,实现对目标的探测、定位和跟踪。其主要原理是利用参考信号和监测通道目标信号之间的相关性实现对目

标的探测^[4-5],参考信号的获取是信号处理中的一项关键技术,其纯度关系着雷达的探测性能^[6-7],而参考信道估计的精度关系着参考信号的获取纯度,因此对其精度的估计有着较高要求。

参考信道的估计本质上是无线通信的多径信道估计。基于最小二乘思想的 LS 算法^[8-9]、采用导频

收稿日期: 2019-08-27

基金项目: 国家自然科学基金(61601502);中国博士后基金(2019M662257)

作者简介: 陈 赓(1997—),男,陕西咸阳人,硕士生,主要从事雷达信号处理。E-mail:1291767183@qq.com

通信作者: 宫 健(1984—),男,山东德州人,副教授,主要从事雷达信号处理研究。E-mail:wcylys@163.com

引用格式: 陈赓,田波,宫健,等. 基于深度学习的 DTMB 外辐射源雷达参考信道估计[J]. 空军工程大学学报(自然科学版), 2020, 21(2): 61-64. CHEN Geng, TIAN Bo, GONG Jian, et al. DTMB Passive Radar Reference Channel Estimation Based on Deep Learning[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(2): 61-64.

信息辅助算法^[10],以及基于压缩感知理论方法^[11-12]是目前最常用的几种信道估计方法。传统的最小二乘算法在对信道估计时,虽然计算简单,不需要先验信息,但不能有效消除导频处噪声的影响,且计算时涉及矩阵求逆计算,当采样速率与符号速率为非整数倍的关系时,估计性能变差,影响参考信号的纯度。文献[10]中,采用基于模糊函数的方法提取接收信号的导频信息,并将其用于信道估计,实现对直达波提纯,仿真结果表明这种方法相比于LS算法估计的结果精度更高。文献[11]采用压缩感知理论,提出了一种高精度的多径信道估计算法,性能更优,鲁棒性和稳定性更好。当前,深度学习理论在模式识别、信号处理、自主决策等领域取得了重大的进展。针对不同处理任务,设计不同的神经网络,通过自身强大的学习归纳能力,对任务进行快速处理。为此,有学者将深度学习理论引入多径信道估计领域,并得到较好的估计效果。文献[13]基于OFDM信号传输系统,引入深度学习理论对信道进行估计,其将多径信道看作一个自回归模型^[14-15],使信道估计转换为自回归系数的估计,实验结果表明,基于深度学习理论的估计算法能够有效提高信道估计的精度,更好地追踪多径信道的变化。基于以上分析,本文将深度学习理论引入外辐射源雷达参考信道估计过程,以提高雷达的检测性能。

1 系统模型

DTMB信号以信号帧为基本的组成单位,信号帧包含帧头和帧体两部分。帧头由已知的伪随机二进制序列组成,帧体部分是多载波调制的OFDM信号。

外辐射源雷达的探测原理见图1。外辐射源雷达接收部分一般具有监测信号与参考信号2个接收通道,通过对监测通道的目标回波信号与参考通道的参考信号进行相关处理得到目标的位置与速度信息。参考信号提纯的实质是求得发射的基准信号。由于空间存在多条反射信号,因此参考信号的信道可以等效为多径信道。由于信号发射源与雷达接收机的空间位置相对固定,故可以假设多径信道在一个信号帧内没有发生变化^[16],其时域冲击响应表达式为:

$$h(t) = \sum_{i=0}^{I-1} h_i \delta(t - \tau_i) \quad (2)$$

式中: h_i 为第*i*条多径信道的增益; τ_i 为第*i*条多径信道的时延; I 为多径的个数。

多径信道传输的本质是由信号不同延迟构成,见图2,接收信号由不同的延迟信号以及直达波信号叠加产生。对于DTMB信号,由于帧头信号已知,因此可以在本地构造出帧头信号延迟矩阵 \mathbf{S}_N

表示不同延迟的帧头信号。

$$\mathbf{S} = [\mathbf{s}_1 \quad \mathbf{s}_2 \quad \cdots \quad \mathbf{s}_N] \quad (3)$$

系统传输模型为:

$$\mathbf{Z} = \mathbf{S}\mathbf{h} + \boldsymbol{\omega} \quad (4)$$

式中: \mathbf{Z} 为接收机接收到的信号; \mathbf{h} 为信道传输响应; $\boldsymbol{\omega}$ 为高斯白噪声,服从 $N(0, \sigma^2)$ 的高斯分布; σ^2 为噪声功率。

多径信道可以等效建模为自回归模型,文献[12]采用一阶自回归模型近似等效无线信道模型,这一模型更接近多径信道的真实情况,并且避免了高阶模型带来的复杂运算。因此,可以将外辐射源雷达参考信道等效为一阶自回归模型,见式(5):

$$\mathbf{Z}(n) = h_1 \mathbf{s}_1 + h_2 \mathbf{s}_2 + \cdots + h_N \mathbf{s}_N + \boldsymbol{\omega} \quad (5)$$

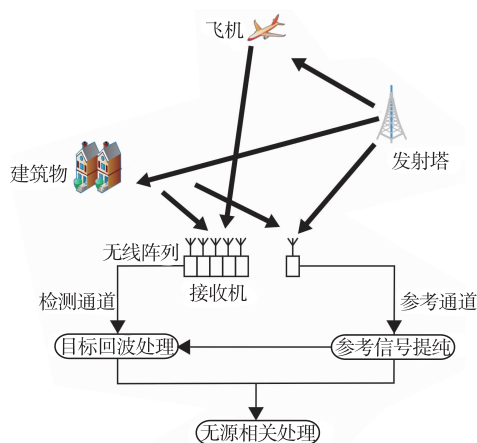


图1 DTMB外辐射源雷达探测示意图




图2 多径信道示意图

2 基于深度学习的参考信道估计

基于深度学习的信道估计流程由训练和估计2部分组成。首先利用先验的信道数据对学习网络进行训练,使估计网络学习到信道的频域相关系数和信道的分布特征,即实现对信道的拟合去噪^[13]。在估计阶段,神经网络的输入为LS算法对帧头序列进行信道估计得到的信道响应,这样可以加快深度神经网络的收敛时间,避免其陷入局部最优解。

2.1 模型构建

学习网络由深度神经网络(DNN)组成,网络采用多层结构,层与层之间采用全联接方式,非线性函数作为每一层神经元之间的传递函数。在实际搭建中,层与层之间的连接采用非线性函数 Sigmoid 或

Tanh, 本文选用前一种作为连接函数, 该函数表达式为 $f(x) = \frac{1}{1 + e^{-x}}$ 。

由图 3 可以看出, 该网络由输入层、隐含层、输出层 3 层构成。输入层为帧头处的信道响应, 由 LS 算法估计得到, LS 算法的思想是使得式(6)中 J 最小:

$$J = (\mathbf{Z} - \mathbf{S}\hat{\mathbf{h}})^H (\mathbf{Z} - \mathbf{S}\hat{\mathbf{h}}) \quad (6)$$

为使式(6)最小, 计算可得信道估计值为:

$$\hat{\mathbf{h}} = (\mathbf{S}^H \mathbf{S})^{-1} \mathbf{S}^H \mathbf{Z} \quad (7)$$

由于输入的信道数据为复数, 在输入网络之前将数据的虚部与实部提取出来, 将其串联在一起, 并行输入。输入层之后链接隐含层, 每个隐含层由多个神经元构成, 每个的输出由前一层输入数据的加权的非线性变换构成。其变换的表达式为:

$$q_{1,i} = f(\sum_j \omega_{1,j} h(j) + b) \quad (8)$$

式中: $\omega_{1,j}$ 、 b 、 $q_{1,i}$ 分别为第 1 个隐含层中第 i 个神经元的权值、偏置和输出。同理, 第 k 个隐含层的变换式为:

$$\mathbf{q}_k = f(\boldsymbol{\omega}_k \mathbf{q}_{k-1} + \mathbf{b}_k) \quad (9)$$

式中: \mathbf{q}_{k-1} 为第 $k-1$ 个隐含层的输出; $\boldsymbol{\omega}_k$ 与 \mathbf{b}_k 为第 k 个隐含层的权值和偏置;

故神经网络最终输出为:

$$\hat{\mathbf{h}} = f(\boldsymbol{\omega}_k \mathbf{q}_k + \mathbf{b}_k) \quad (10)$$




图 3 神经网络结构

2.2 模型训练

历史研究中, 相关专家提出了许多信道模型以便很好的描述信道。外辐射源雷达参考信道实质为莱斯信道, 故采用莱斯信道生成的数据对网络进行训练, 训练数据通过仿真得到。对于训练阶段, 将一个 OFDM 序列作为训练数据, 帧头处的信道响应作为学习网络的输入数据, 一个 OFDM 符号帧体处的信道响应作为标签数据对神经网络进行训练。

本地构造的帧头序列 \mathbf{PN} 与接收序列 \mathbf{Z} 进行时域互相关操作^[17], 以在接收信号中找到帧头与帧体的位置, 计算表达式见式(11)。相关处理的峰值即为接收信号的帧头位置。

$$R = E\{\mathbf{PNZ}^*\} \quad (11)$$

在本文中, 网络训练使用端到端方法获得信道估计网络中的权重和偏移量, 并使用随机梯度下降算法来更新网络中的参数集。网络中的代价函数采

用均方误差, 其表达式为:

$$L(\boldsymbol{\theta}_{\text{test}}) = \frac{1}{M} \sum_{m=1}^M (\hat{h} - h')^2 \quad (12)$$

式中: $\boldsymbol{\theta}_{\text{test}}$ 表示网络中所有参数; h' 为监督数据; M 为训练样本集中的总样本数。

3 仿真实验

本节采用仿真实验比较基于神经网络估计算法与传统的信道估计算法的性能区别。本文采用 PN945 模式的 DTMB 信号进行仿真实验。仿真采用的神经网络模型层数为 7 层, 5 层为隐含层, 2 层分别为网络输入层与输出层。其中输入层和输出层的神经元个数分别为 50 和 500, 隐含层的神经元个数为 2 048。对于训练过程, 本文采用的训练集、校验集与测试集大小分别为 50 000, 30 000, 10 000。仿真设置的基本条件见表 1。设置 5 条多径延迟信道。

表 1 仿真系统参数

参数	数值
载波频率/MHz	786
带宽/MHz	7.56
子载波个数	3 780
保护间隔符号个数	945
调制方式	4QAM
信道模型	Rician
多径时延/ μs	[0 5 8 10 15]
路径增益/dB	[-1 -4 -10 -12 -15]

图 4 和图 5 分别比较了 LS 算法, OMP 算法和深度学习算法在不同 SNR 条件下的参考信道均方根误差 (RMSE) 性能以及误码率 (BER) 性能。RMSE 的计算表达式为:

$$\text{RMSE} = \sqrt{\frac{1}{L} \sum_{i=1}^L (h(i) - \hat{h}(i))^2} \quad (13)$$

从图 4 中可以看出, 不同算法的 RMSE 性能伴随着信噪比的增加和下降趋势。在信噪比相同的条件下, LS 算法的性能最差, OMP 算法较好, 神经网络算法最优。这是因为 LS 算法是一种线性估计算法, 其计算误差较大, 故 RMSE 性能较差。基于压缩感知理论的 OMP 算法则是一种非线性算法, 相比于 LS 算法具有较好的效果, 但在多径条数增加, 存在弱径信号时, 由于迭代门限的设置, 会导致估计结果不精确。若降低迭代门限值, 则会增加迭代次数, 涉及大量的伪逆运算, 不可避免的会引起误差。深度学习算法具有最佳的 RMSE 性能。这是因为基于深度学习理论的信道估计算法采用的是一种深层非线性的网络结构, 其依靠内部的神经层之间的非线性连接, 通过不断迭代, 可以无限逼近复杂函数, 从而得到多径信道响应。因此, 这种方法具有较好的性能。

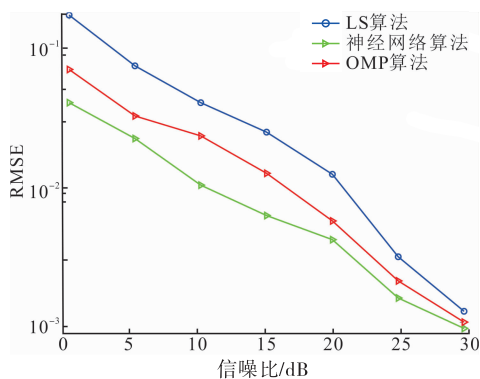


图4 不同估计算法下的 RMSE 曲线




图5 不同估计算法下的 BER 曲线

图5为不同信道估计算法的BER性能图,可以看出,不同算法的BER性能曲线和RMSE曲线基本保持一致,都随着信噪比的不断提高,误码率逐渐降低。本文采用的深度学习算法具有最好的BER性能。从以上分析可以看出,基于深度学习的信道估计算法具有较好的估计性能,对提高参考信号的纯度和提高雷达的探测性能具有积极作用。

4 结语

本文基于DTMB外辐射源雷达系统,针对传统算法对参考信道估计时精度不佳而导致参考信号的纯度不高的问题,将基于深度学习的信道估计算法引入外辐射源雷达系统。仿真实验可以看出,训练后基于深度学习的神经网络可以得到更优的信道估计结果,这对于改善雷达的探测精度有着积极的作用。因此,将深度学习理论引入外辐射源雷达系统是一种提高雷达性能的有效手段。

参考文献(References):

[1] PETO T, SELLER R. Quad Channel DVB-T Based Passive Radar[C]//17th International Radar Symposium, Krakow, 2016: 1-4.
 [2] WOJACZEK P, COLONE F, CRISTALLINI D, et al. Reciprocal Filter-Based STAP for Passive Radar on Moving Platforms[J]. IEEE Trans Aerosp Electron

Syst, 2018, 55(2): 967-988.
 [3] FENG W, FRIEDT JM, CHERNIAK G. Novel Algorithm for High Resolution Passive Radar Imaging with ISDB-T Digital TV Signal[C]//In Proc IEEE Int. Geosci. Remote Sens Symp, Valencia, Spain, 2018.
 [4] 万显荣,岑博,易建新,等. 中国移动多媒体广播外辐射源雷达参考信号获取方法研究[J]. 电子信息学报, 2012, 34(2): 338-343.
 [5] WAN X R, WANG J F, HONG S, et al. Reconstruction of Reference Signal for DTMB-Based Passive Radar Systems [C]//2011 IEEE CIE International Conference on Radar. Chengdu: [s. n.], 2011: 165-168.
 [6] 万显荣,唐慧,赵俊芳,等. DTMB外辐射源雷达信号纯度对探测性能的影响分析[J]. 系统工程与电子技术, 2017, 39(4): 725-729.
 [7] 饶云华,明燕珍,林静,等. WiFi外辐射源雷达参考信号重构及其对探测性能影响研究[J]. 雷达学报, 2016, 5(3): 284-292.
 [8] ZARRINKOUB D H. Understanding LTE with MATLAB: From Mathematical Modeling to Simulation and Prototyping[M]. Hoboken: Wiley Publishing, 2014.
 [9] 廖勇,沈轩帆,代学武,等. 基于扩展卡尔曼滤波的联合迭代检测译码信道估计方法[J]. 电子学报, 2018, 46(3): 554-561.
 [10] 卢开旺,杨杰,张良俊. 基于OFDM信号的外辐射源雷达杂波信道估计[J]. 现代雷达, 2014, 36(3): 23-28.
 [11] 李明阳,柏鹏,王徐华,等. 基于压缩感知的稀疏多径信道估计[J]. 系统工程与电子技术, 2013, 35(5): 909-913.
 [12] SONG K, YANG L. Low Computational Complexity Design over Sparse Channel Estimator in Underwater Acoustic OFDM Communication System [J]. IET Communications, 2017, 11(7): 1143-51.
 [13] 廖勇,花远肖,姚海梅. 基于深度学习的OFDM信道估计[J]. 重庆邮电大学学报(自然科学版), 2019, 31(6): 348-353.
 [14] GHANDOUR-HAIDAR S, ROS L, BROSSIER J M. On the Use of First-Order Autoregressive Modeling for Rayleigh Flat Fading Channel Estimation with Kalman Filter[J]. Signal Processing, 2012, 92(2): 601-606.
 [15] LIANG Y M, LUO H W, HUANG J G. Extended Kalman Filtering-Based Channel Estimation for Space-Time Coded MIMO-OFDM Systems[J]. Journal of Shanghai University (English Edition), 2007, 11(5): 469-473.
 [16] 万显荣,程熠瑶,易建新,等. DTMB外辐射源雷达参考信号重构信道估计新方法[J]. 电子信息学报, 2017, 39(5): 1044-1050.
 [17] SONG B W, GUI L, GUAN Y F, et al. On Channel Estimation and Equalization in TDS-OFDM Based Terrestrial HDTV Broadcasting System[J]. IEEE Transactions on Consumer Electronics, 2005, 51(3): 790-797.

(编辑:徐敏)