

基于多帧相位增强的米波雷达低仰角目标DOA估计方法

项厚宏 陈伯孝* 杨婷 杨明磊

(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘要: 针对米波雷达低仰角目标的DOA估计问题, 该文提出一种新的基于多帧相位特征增强方法, 所提方法可以有效解决低仰角条件下阵列接收信号中直达信号相位特征模糊问题, 进而提高DOA估计精度。通过学习多帧原始数据的相位分布特征与理想环境下直达波信号的相位分布特征之间的复杂映射关系, 有效削弱多径信号引起的相位误差, 将增强后的相位信息与原始的幅度信息进行数据重组, 并利用已有的超分辨算法进行DOA估计。通过计算机仿真实验和实测数据验证, 该文所提方法在DOA估计性能以及泛化能力上优于基于物理驱动的音乐算法以及数据驱动的基于特征反演和基于支持向量回归的两种估计方法。

关键词: 雷达信号处理; 来波方向估计; 多帧相位增强; 米波雷达

中图分类号: TN958

文献标识码: A

文章编号: 1009-5896(2020)07-1581-09

DOI: 10.11999/JEIT190432

Low-elevation DOA Estimation for VHF Radar Based on Multi-frame Phase Feature Enhancement

XIANG Houhong CHEN Baixiao YANG Ting YANG Minglei

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: For the DOA estimation problem of low-elevation target of VHF radar, a new multi-frame phase feature enhancement based method is proposed, which solves effectively the phase feature ambiguity of direct signal, and thus improves the accuracy of DOA estimation. By learning the complex mapping relationship between the phase distribution of the multi-frame data and ideal phase distribution of the direct signal, the fuzzy phase information is enhanced and is used to reconstruct a new data matrix with original amplitude information. The DOA is estimated by conventional methods using new data matrix, which effectively improves the DOA estimation accuracy of the low-elevation target. The effectiveness of proposed method is validated by computer simulation experiments and real data, and it shows higher accuracy compared with physics-driven methods including MUSIC method and state-of-the-art data-driven method including feature reversal and Support Vector Regression (SVR).

Key words: Radar signal processing; DOA estimation; Multi-frame phase feature enhancement; VHF radar

1 引言

米波雷达具有波长长、波束宽、阵列孔径受限等特点, 因此在低仰角条件下, 米波雷达接收到的回波信号中不仅包含来自目标散射的直达波信号, 而且还存在经地面反射或散射的多径信号。由于存在较强的多径效应, 米波雷达在处理低仰角目标的

探测和测量问题上存在一些亟待解决的科学难题^[1-3], 如: (1)对于低仰角目标, 直达波和多径散射回波通常处于一个波束宽度内, 由于阵列孔径受限, 难以从时域、频域或空域对直达波和多径散射回波进行分辨; (2)直达信号与多径散射回波通常为相干信号, 且受实际阵地地形的影响, 多径信号的幅相特征发生严重的“畸变”, “畸变”的多径信号叠加在直达信号上直接导致直达信号的幅相特征模糊, 目标仰角不能有效超分辨处理; (3)已有的超分辨算法均基于理想远场平面波模型, 而实际直达信号受多径信号的影响, 其模型特征难以满足远场平面波模型特征, 模型失配问题降低了超分辨算法性能^[4-6]。

目前, 已有的超分辨算法主要有基于信号子空

收稿日期: 2019-06-13; 改回日期: 2019-10-08; 网络出版: 2020-02-05

*通信作者: 陈伯孝 bxchen@xidian.edu.cn

基金项目: 国家自然科学基金(61571344, 61971323), 中央高校基本科研业务费专项基金, 西安电子科技大学研究生创新基金

Foundation Items: The Natural Science Foundation of China (61571344, 61971323), The Fundamental Research Funds for the Central University, Innovation Fund of Xidian University

间和噪声子空间正交性的多重信号分类算法(MUSIC)^[7]和旋转空间不变算法(ESPRIT)^[8]以及对噪声分布特征先验已知的最大似然算法(ML)^[9,10]。具体地,在米波雷达领域,近些年也有一些新的估计方法。考虑到多径信号主要来源于阵地地面的反射和散射,Zhu等人^[5]考虑到阵地反射面高度信息对算法的影响,研究了一种新的基于地形匹配的米波雷达测高方法。此方法虽然能有效应用于部分阵地,但精确的地形起伏信息往往是难以获取。此外,郑铁松等人^[6]在此基础上分析了反射系数和反射面高度对DOA估计的影响,并通过反演反射系数和反射面高度,进而提高米波雷达测高精度。然而对于精确建模的算法,构建精确信号模型需要更多精准的先验信息,这意味着更容易发生模型失配问题。因此,解决模型失配问题,使得信号特征更趋近于理想远场平面波模型是提高DOA估计精度的一个有效方向。

近些年,由于神经网络具有较强的非线性学习能力,神经网络技术已被应用于信号处理领域^[11,12]。在阵列信号处理领域,文献^[13]根据多径信号模型,提出了一种基于空域特征学习的端到端DOA估计方法,通过学习接收数据的俯仰维分布特征与真实DOA的关系,进而通过对接收数据的俯仰维分布特征反演DOA,实验结果表明该方法比已有的超分辨算法具有更高的估计精度,而且计算量更低。文献^[14]提出了一种基于支持向量回归的端到端DOA估计方法,通过学习接收数据协方差矩阵的上三角元素的实/虚部特征与真实DOA的复杂映射关系,进而实现DOA估计。这两种基于深度学习的DOA估计方法均表明了深度学习在DOA估计领域的有效性,但是其学习机制没能充分利用数据本身的物理特征以及特征冗余等问题,且实际的阵列误差等问题没有考虑。

因此,本文从信号模型出发,着重分析了已有的超分辨测角算法的物理机理以及数据所蕴含的物理特征,探索了一种新的基于多帧相位特征增强的DOA估计方法。具体地,在训练过程中,以接收数据协方差矩阵的上三角元素的相位特征作为学习对象,通过利用神经网络(DNN)和深度卷积神经网络(CNN)学习接收数据相位特征与理想无噪无多径数据相位特征之间的复杂映射关系,进而达到多径消除的效果并解决模型失配问题,最终提高DOA估计精度。由于所提方法训练过程是离线的,不需要考虑时间成本。且神经网络每层的映射都是纯实数运算,并不涉及复乘运算,故网络训练好后,增强过程带来的运算量较小。

2 信号模型

经典多径信号模型如图1所示,考虑 M 阵元的均匀线阵,阵元间距为半波长,快拍数为 L 。阵列接收数据 $\mathbf{y}(t)$ 可表示为

$$\mathbf{y}(t) = (\mathbf{a}(\theta_d) + \rho\mathbf{a}(\theta_i))s(t) + \mathbf{n}(t), t = 1, 2, \dots, L \quad (1)$$

其中, $\mathbf{a}(\theta_d) = \exp(-jk\mathbf{D}_M \sin(\theta_d))$ 表示直达波导向矢量, $\mathbf{a}(\theta_i) = \exp(-jk\mathbf{D}_M \sin(\theta_i))$ 表示多径信号导向矢量, θ_d 为直达波波达角, θ_i 为多径信号波达角, \mathbf{D}_M 为阵元到参考阵元的距离, $k = 2\pi/\lambda$ 为波数, λ 为波长, ρ 为多径信号复反射系数, $s(t)$ 为信号复包络, $\mathbf{n}(t)$ 表示0均值,方差为 σ^2 的复高斯白噪声。

观察导向矢量项 $\mathbf{a}(\theta_d) + \rho\mathbf{a}(\theta_i)$, 多径信号导向矢量项 $\rho\mathbf{a}(\theta_i)$ 可以建模成直达信号导向矢量项 $\mathbf{a}(\theta_d)$ 的幅相误差。因此,阵列模型式(1)可以简化成

$$\mathbf{y}(t) = \mathbf{\Gamma} \odot \mathbf{a}(\theta_d)s(t) + \mathbf{n}(t) \quad (2)$$

其中, $\mathbf{\Gamma}$ 表示幅相误差,且 $\mathbf{\Gamma} = [\tau_1, \tau_2, \dots, \tau_M]^T$ 。由于存在幅相误差,接收数据中各阵元的幅度特征不再一致,相邻阵元的相位不再具有等相位差特征,阵列模型特征不再满足远场平面波模型特征,这是基于远场平面波的超分辨算法如MUSIC, ML等算法性能大大下降的关键原因。图2给出了各算法的估计精度与幅相特征误差的敏感度曲线,仿真条件为:21阵元的均匀线阵,阵列间距半波长,波长1 m,信噪比是0 dB,30个快拍,误差范围为0%~40%。根据图2结果,可以看出幅度误差的大小对测角精度的影响较小,而测角误差与相位误差呈现明显的正比例关系。因此,消除由多径信号引起的相位误差是提高测角精度的一个有效手段。

此外,已有的物理驱动的超分辨DOA估计算法中,DBF算法、MUSIC和ML算法的估计公式可总结为

$$\hat{\theta}_{\text{DBF}} = \arg_{\theta} \max \mathbf{a}^H(\theta) \mathbf{R} \mathbf{a}(\theta) \quad (3)$$

$$\hat{\theta}_{\text{MUSIC}} = \arg_{\theta} \max \mathbf{a}^H(\theta) \mathbf{U}_N \mathbf{U}_N^H \mathbf{a}(\theta) \quad (4)$$




图1 信号模型




图2 幅相敏感度分析

$$\hat{\theta}_{ML} = \arg_{\theta} \max \text{tr}[\mathbf{P}_{\mathbf{A}(\theta)} \mathbf{R}] \quad (5)$$

其中， \mathbf{U}_N 为噪声子空间， $\mathbf{P}_{\mathbf{A}(\theta)}$ 为投影到导向矢量矩阵 $\mathbf{A}(\theta)$ 的列向量张成空间的投影算子， $\text{tr}[\cdot]$ 表示矩阵的迹。通过搜索仰角 θ ，实现对目标仰角的估计。分析搜索仰角的过程，由于搜索仰角仅影响导

向矢量的相位，导向矢量的幅度特征并不受仰角的影响，因此搜索仰角的过程，实际上是搜索一个最佳的相位分布。阵列接收数据中关于真实目标仰角的相位特征准确与否，直接影响超分辨算法的估计性能。

因此，综合以上两种分析，增强直达信号的相位特征、消除多径信号带来的相位误差是提高已有超分辨算法性能的一个重要途径。故本文提出了一种新的基于多帧相位特征增强的DOA估计方法，所提方法着重研究了基于深度神经网络和基于深度卷积神经网络的两种相位增强框架。

3 基于相位增强的DOA估计方法

本文提出的相位增强方法系统框图如图3所示。其中，训练部分主要完成原始数据相位特征的提取、预处理以及DNN和CNN的训练；增强部分则将预处理后的相位特征作为训练好的神经网络的输入，增强后的相位特征与原始的幅度特征重构出新的数据协方差矩阵，并采用经典的物理驱动的超分辨算法进行DOA估计。




图3 相位增强系统框图

3.1 DNN/CNN网络结构

本文所采取的深度神经网络结构和深度卷积神经网络结构分别如图4和图5所示。其中， $\bar{\Phi}$ 为网络的输入特征， Φ' 为网络增强后的特征输出， \mathbf{W}^i 和 \mathbf{b}^i ($i = 1, 2, \dots, 4$)为第 i 层网络的权值和偏置值。深度卷积神经网络在神经网络的基础上引入了一个卷积核。对于相同的特征输入，不同的卷积核将学习到不同的数据特征，故多个卷积核将会学习到更加丰富的特征，这更加有利于网络学习到深层次的特征。图5给出了具有两层卷积层的深度卷积神经网络结构。

对于深度神经网络，每层神经元对上一层的输出数据完成一次非线性变换。假设深度神经网络的输出为 \mathbf{o} ，输入特征为 \mathbf{x} ，那么经过一次前向传播，网络输入与输出的函数关系可以表示为

$$\mathbf{o} = f(\mathbf{x}, \mathbf{W}) = f^{(n-1)}(f^{(n-2)}(f^{(n-3)}(\dots f^{(1)}(\mathbf{x})))) \quad (6)$$

其中， $f^{(i)}(\mathbf{x}) = g(\mathbf{W}^i \cdot \mathbf{x} + \mathbf{b}^i)$ 。经典的非线性激活函数 $g(\cdot)$ 包括Sigmoid函数和ReLU函数，分别表示为




图4 深度神经网络结构




图5 深度卷积神经网络结构

$$f_{\text{Sigmoid}}(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

$$f_{\text{ReLU}}(x) = \max(0, x) \quad (8)$$

其中, x 为函数参数。本文所采取的深度神经网络结构配置如表1。

表1 深度神经网络结构配置

网络结构	激活函数	学习率	初始化方式
$\mathbf{x} \times 1024 \times 1024 \times 1024 \times \mathbf{o}$	ReLU	10^{-4}	高斯随机初始化

深度卷积神经网络与深度神经网络的不同之处是深度卷积神经网络存在卷积核, 卷积核使得每个神经元只与输入特征的局部数据相连接, 而不是与输入的所有特征数据连接, 且所连接的数据特征的大小由卷积核的大小所决定。通常, 一个卷积核对应有一种特征, 因此为丰富下一层网络的输入特征, 通常卷积核具有一定深度。

经过非线性映射后, 输入特征的局部特征被有效提取。在若干层卷积层后, 嵌套一系列平坦层, 将2维或者更高维的特征矢量化, 以便全连接层学习。总之, 深度卷积神经网络是在深度神经网络结构的基础上通过引入卷积核, 丰富了数据的高维特征, 这样更加有利于网络挖掘到更深层次特征。本文所采用的深度卷积神经网络的结构配置如表2所示。

3.2 多帧相位特征预处理

考虑到实际情况下, 原始相位特征分布在 $-180^\circ \sim 180^\circ$ 范围内, 较小值的相位特征容易被较大值的相位特征所湮灭。为了保护原始的相位分布特征不变, 本文对训练集数据的相位特征进行高斯归一化处理, 归一化过程表示为

$$\bar{\Phi} = \frac{\Phi - \mu}{\sigma} \quad (9)$$

其中, Φ 为原始相位特征, μ 和 σ 分别为特征维的统计均值和标准差, 且 Φ , μ 和 σ 的维度与帧数相关。

表2 深度卷积神经网络结构配置

网络结构	卷积核大小	池化层大小	激活函数	学习率	初始化方式
2层卷积层	$3 \times 1 \times 15$	1×3	ReLU	10^{-4}	高斯随机初始化
3层全连接层	$3 \times 15 \times 30$				

当帧数为1时, Φ , μ 和 σ 的特征维度为 $M(M-1)/2$; 当帧数为3时, Φ , μ 和 σ 的维度为 $3M(M-1)/2$ 。

3.3 网络学习

无论是深度神经网络还是深度卷积神经网络, 均假设训练集数据提取到的相位特征为 Φ_1 , 经过多帧处理和归一化处理后的相位特征为 $\bar{\Phi}_1$, 理想的相位分布为 $\hat{\Phi}_1$ 。本文采取有监督学习方法, 网络目标函数为

$$(\mathbf{W}, \mathbf{b}) = \min_{\mathbf{W}, \mathbf{b}} \frac{1}{N} \|\bar{\Phi}_1 - \hat{\Phi}_1\|^2 \quad (10)$$

其中, N 为训练样本个数。

每次对神经网络进行前向传播后, 对误差进行反向传播^[15,16]并更新网络权值。本文采用Adam^[17]方法更新网络参数。经过反复多次更新网络参数, 直到网络目标函数收敛。为了防止网络过拟合问题, 这里采用Dropout^[18]策略, 以一定的概率随机剔除神经元, 以缓解网络对训练集数据分布的依赖性。为了确定网络的性能, 本文引入拟合优度(Goodness Of Fit, GOF), 其表达式为

$$R^2 = 1 - \frac{\sum_{i=1}^k \|y_i - y'_i\|^2}{\sum_{i=1}^k \|y_i - \bar{y}\|^2}, R^2 \leq 1 \quad (11)$$

其中, k 表示样本数; y_i 表示根据第 i 个样本的网络输出的特征矢量; y'_i 表示第 i 个样本的特征矢量标签; \bar{y} 表示 k 个样本的特征矢量统计均值。拟合优度 R^2 越接近于1, 表明网络拟合性能越优。

当网络完成训练后, 固定网络的参数和结构, 分别提取测试集数据协方差矩阵的幅度特征 ρ 和相位特征 φ 。为保证训练集相位特征分布和测试集相位特征分布匹配, 以训练集相位特征统计均值 μ 和标准差 σ 对测试集相位特征进行高斯归一化处理

$$\bar{\varphi} = \frac{\varphi - \mu}{\sigma} \quad (12)$$

以 $\bar{\varphi}$ 作为网络的输入, 网络的输出即为增强后的相位特征, 表示为 φ' 。将原始的幅度特征 ρ 和增强的相位特征 φ' 重组新的数据协方差矩阵, 并利用已有的超分辨算法进行DOA估计。

下面给出该方法的具体步骤:

- (1) 确定训练集/测试集数据及其标签数据, 随机初始化指定结构的网络参数;
- (2) 根据式(9)预处理相位特征, 并根据训练的帧数确定网络的输入;
- (3) 以处理好的相位特征作为深度神经网络或深度卷积神经网络的输入, 完成1次前向传播;

- (4) 对误差进行反向传播，并更新网络的权值；
- (5) 重复步骤(2)–步骤(4)，直到目标函数收敛；
- (6) 固定网络结构以及网络参数，以式(12)处理测试集数据的相位特征，输入到训练好的神经网络，并得到增强后的相位特征；
- (7) 以增强的相位特征和原始的幅度特征重构数据协方差矩阵并利用已有的超分辨率算法进行DOA估计；
- (8) 重复步骤(6)和步骤(7)，直到所有的测试集数据计算完毕。

4 仿真数据分析

这一节着重讨论训练集/测试集在信噪比和幅相误差匹配以及失配两种场景下，所提方法的测角性能以及泛化性能，本文考虑帧数范围是3帧(左1帧+当前帧+右1帧)，5帧(左2帧+当前帧+右2帧)，7帧(左3帧+当前帧+右3帧)。对比的方法包括基于物理驱动的音乐算法和最新的基于特征反演(FR)的DOA估计方法以及基于支持向量回归(SVR)的DOA估计方法。

仿真1：对比不同信噪比条件下所提方法的有效性。仿真条件：阵列结构为21阵元的均匀线阵，波长1 m，阵元间距为半波长，快拍数为42，信噪比范围是-10~-2 dB，信噪比采样间隔2 dB，目标仰角范围是1°~5°，阵列存在20°的相位误差。图6和图7分别给出了经DNN和CNN增强后的测角均方根误差与信噪比的关系曲线。从结果中可以看

出，增强后MUSIC算法的测角误差明显下降，而且帧数越多，测角精度越高。为了更好地展示不同帧数的增强效果，图8和图9分别给出了DNN和CNN增强网络在不同帧数和不同信噪比条件下的特征拟合优度(GOF)。从结果中可以看出信噪比越高、帧数越大，拟合优度越好，测角误差也就越小。由于基于特征反演(FR)和基于支持向量回归(SVR)的DOA估计方法是基于理想平面波模型，幅相误差的大小影响其估计性能，故DOA估计精度远低于所提方法和物理驱动的方法。

仿真2：比较不同相位误差条件下所提方法的有效性。仿真条件：信噪比 0 dB，相位误差的范围是5%~20%，误差采样间隔5%，其余条件同仿真1。图10和图11分别给出了DNN和CNN增强后的测角均方根误差与相位误差的关系曲线。可以看出，基于特征反演(FR)和支持向量回归(SVR)的两种DOA估计方法受相位误差的影响已经完全失效，通过DNN/CNN增强相位特征后，MUSIC算法的测角精度有效提高。图12和图13分别给出了不同帧数增强后的特征拟合优度(GOF)，随着误差的增大，网络拟合性能逐渐下降。且帧数越多，网络拟合性能有效提高，但帧数越大，边缘帧数据的相位特征与当前帧的相位特征相关性越弱，因此，当帧数得到一定程度后，拟合性能处于饱和状态，性能提升缓慢。

仿真3：比较信噪比失配条件下所提方法的泛化能力。仿真条件：训练集信噪比范围是-10~0 dB，

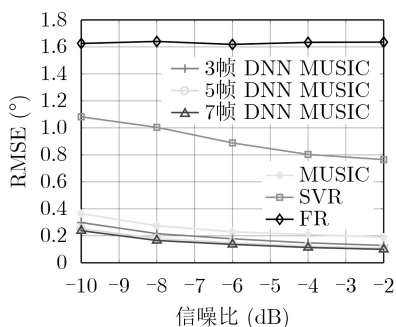


图6 信噪比匹配条件下，DNN增强的RMSE与信噪比关系曲线

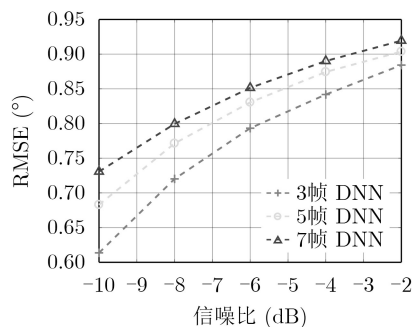


图8 信噪比匹配条件下，DNN增强的GOF与信噪比关系曲线

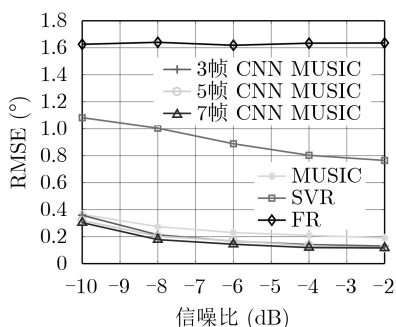


图7 信噪比匹配条件下，CNN增强的RMSE与信噪比关系曲线




图9 信噪比匹配条件下，CNN增强的GOF与信噪比关系曲线

而测试集信噪比范围是-11~ -1 dB, 信噪比采样间隔2 dB, 其余条件同仿真1。图14和图15分别给出了信噪比失配条件下DNN/CNN测角均方根误差与信噪比的关系曲线。可以看出, 所提方法在DOA估计精度上均优于基于物理驱动的音乐算法以及基于数据驱动的特征反演(FR)和基于支持向量回归(SVR)的DOA估计方法, 且帧数越多, 误差越小。因此, 就对信噪比的泛化性能而言, 所提方法比基于特征反演和支持向量回归的DOA估计方法要高。图16和图17分别给出了信噪比失配条件下的所提的两种增强网络的特征拟合优度(GOF)。可以看出, 帧数越多, 网络拟合性能越好, 但帧数提高到一定程度时, 受帧间相关性的影响, 网络拟合性能趋近于饱和状态

仿真4: 比较相位误差失配条件下所提方法的泛化能力。仿真条件: 信噪比0 dB, 训练集相位误

差范围是5%~20%, 而测试集相位误差范围是3%~23%, 相位误差采样间隔5%, 其余条件同仿真1。图18和图19分别给出了相位误差失配条件下所提的两种方法的测角性能。可以看出, 在相位误差失配条件下, 所提两种方法均能有效进行DOA估计, 且测角精度性能已有超过基于物理驱动和基于数据驱动的多种方法, 且对相位误差的泛化能力更高。图20和图21分别给出了所提方法在不同帧数、不同相位误差下的网络拟合优度(GOF)。可以看出, 随着相位误差的增大, 网络拟合性能虽然逐渐下降, 但帧数越多, 网络拟合性能越优, 但同样存在饱和状态。

为了直观论证所提方法能有效消除相位误差, 图22给出了经过DNN/CNN增强前后的相位特征分布图。可以看出, 经过网络增强后, 原始接收数据中的相位误差已经有效消除, 且增强后的相位与真




图 10 误差匹配条件下DNN增强的RMSE与相位误差关系曲线




图 13 误差匹配条件下CNN增强的GOF与相位误差关系曲线




图 11 误差匹配条件下CNN增强的RMSE与相位误差关系曲线

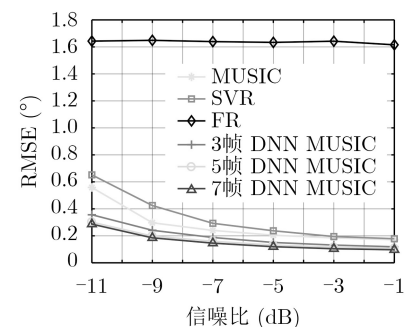


图 14 信噪比失配条件下DNN增强的RMSE与信噪比关系曲线




图 12 误差匹配条件下DNN增强的GOF与相位误差关系曲线

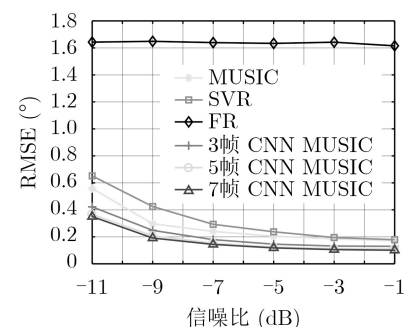


图 15 信噪比失配条件下CNN增强的RMSE与信噪比关系曲线




图 16 信噪比失配条件下DNN增强的GOF与信噪比关系曲线




图 20 误差失配条件下DNN增强的GOF与相位误差关系曲线




图 17 信噪比失配条件下CNN增强的GOF与信噪比关系曲线

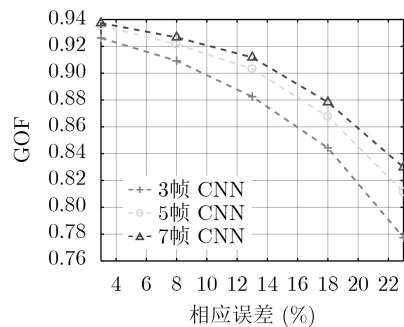


图 21 误差失配条件下CNN增强的GOF与相位误差关系曲线

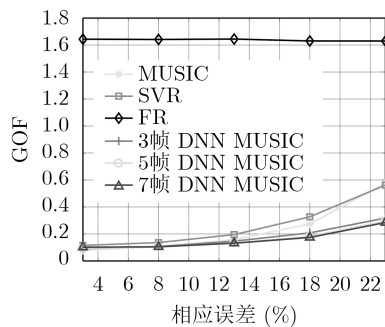


图 18 误差失配条件下DNN增强的RMSE与相位误差关系曲线

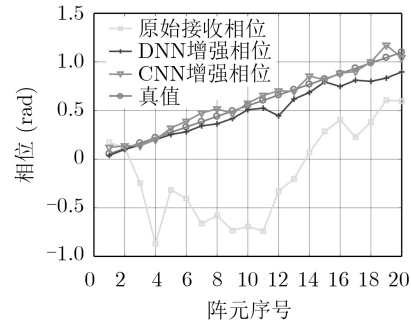


图 22 相位增强前后分布图

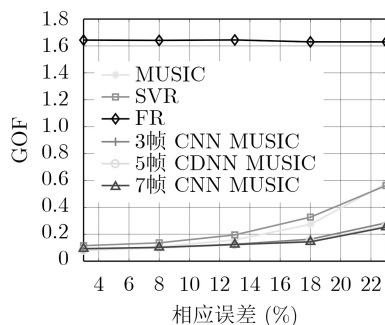


图 19 误差失配条件下CNN增强的RMSE与相位误差关系曲线

值结果具有较小的误差。这与本文理论分析的结果相符合，进一步证明了所提方法的有效性。

上述计算机仿真分析的结果表明所提的两种相位增强框架和方法在DOA估计问题是适用的。随着帧数的增大，网络性能逐步提高，测角结果远超过已有的多种方法。由于当前帧数据相位特征与

边缘帧数据相位特征的相关性随帧数的增大而逐渐下降，故网络拟合性能在帧数提高到一定程度后，其拟合性能提升较小，但总体呈现上升趋势。

5 实测数据验证

本节以某阵地环境下某型号米波雷达采集的数据论证本文所提的两种增强方法的可靠性。阵地雷达是21阵元均匀线阵，阵地地形属于斜坡阵地，3 dB波束宽度约5°。以DBF算法和解相的空间平滑MUSIC(SSMUSIC)算法脱机处理某条航线数据，目标航迹和测角结果如图23所示。可以看出，DBF算法和SSMUSIC算法均已失效。经过DNN和CNN增强后，测角误差结果如图24和图25所示。可以看出，测角误差几乎均匀分布在±0.5°范围内，测量性能明显提高。以测角误差为0.3°作为有效点迹的评价标准，表3给出了DNN和CNN增强前后有效点百分比。从统计结果可以看出，增强前物理驱




图 23 目标航迹图和测角结果图

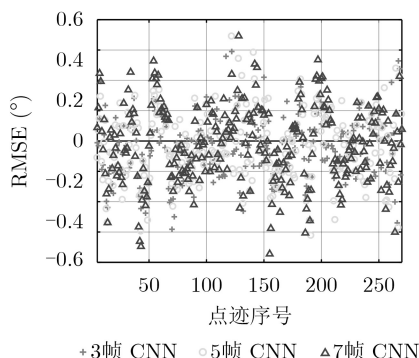


图 25 CNN增强后测角误差




图 24 DNN增强后测角误差

动算法几乎无法有效估计，而经过网络增强后有效点迹提高到95.6%，性能提升得非常显著。因此，本文所提的两种深度神经网络的相位增强方法是可靠的，能够有效解决实际情况下米波雷达低仰角目标DOA估计问题。

6 结束语

本文针对米波雷达低仰角估计问题，通过分析

已有基于物理驱动的DOA估计算法的幅相敏感度以及其估计原理，提出一种新的基于深度神经网络和深度卷积神经网络学习的多帧相位增强方法。通过学习原始接收数据的相位分布特征与真实无多径信号环境下的相位分布特征之间的复杂映射关系，进而消除多径信号带来的相位误差，使得增强后的信号特征与理想远场平面波模型特征更加匹配，最终提高已有估计方法的性能。通过计算机仿真实验，可以看出所提方法具有更高的DOA估计精度，且与最新的基于特征反演的估计方法和基于支持向量回归的估计方法对比，在信噪比和相位误差失配条件下具有更高的泛化性能。且直接训练相位特征比训练幅/相特征和实/虚部更高效，多帧训练效果更佳。因此，选取有效特征并设计合理的网络模型均能提高DOA估计精度。结合实测数据分析结果，可以看出所提方法在DOA估计方面具有较高的可靠性。

表 3 有效点数占比(%)

方法	DBF	SSMUSIC	3帧DNN	5帧DNN	7帧DNN	3帧CNN	5帧CNN	7帧CNN
占比	1.8	0.2	95.6	93.5	89.8	85.1	81.1	72.7

参考文献

[1] 朱伟. 米波数字阵列雷达低仰角测高方法研究[D]. [博士学位论文], 西安电子科技大学, 2013.
ZHU Wei. Study on low-angle altitude measurement in VHF Radar[D]. [Ph.D. dissertation], Xidian University, 2013.

[2] 郑铁松. 米波阵列雷达低仰角测高若干问题研究[D]. [博士学位论文], 西安电子科技大学, 2017.
ZHENG Yisong. Study on some issues of low-angle altitude measurement for VHF array radar[D]. [Ph.D. dissertation], Xidian University, 2017.

[3] 李存勋. 米波雷达低仰角测高相关问题研究[D]. [博士学位论文], 西安电子科技大学, 2018.
LI Cunxu. Study on some issues of altitude measurement of low-angle target for VHF array radar[D]. [Ph.D. dissertation], Xidian University, 2018.

[4] 陈伯孝, 胡铁军, 郑自良, 等. 基于波瓣分裂的米波雷达低仰角测高方法及其应用[J]. 电子学报, 2007, 35(6): 1021–1025. doi: 10.3321/j.issn:0372-2112.2007.06.003.
CHEN Baixiao, HU Tiejun, ZHENG Ziliang, et al. Method of altitude measurement based on beam Split in VHF radar and its application[J]. *Acta Electronica Sinica*, 2007, 35(6): 1021–1025. doi: 10.3321/j.issn:0372-2112.2007.06.003.

[5] ZHU Wei and CHEN Baixiao. Altitude measurement based on terrain matching in VHF array radar[J]. *Circuits, Systems, and Signal Processing*, 2013, 32(2): 647–662. doi: 10.1007/s00034-012-9472-4.

[6] 郑铁松, 陈伯孝. 米波雷达低仰角目标多径模型及其反演方法

- 研究[J]. 电子与信息学报, 2016, 38(6): 1468–1474. doi: [10.11999/JEIT151013](https://doi.org/10.11999/JEIT151013).
- ZHENG Yisong and CHEN Baixiao. Multipath model and inversion method for low-angle target in very high frequency radar[J]. *Journal of Electronics & Information Technology*, 2016, 38(6): 1468–1474. doi: [10.11999/JEIT151013](https://doi.org/10.11999/JEIT151013).
- [7] SCHMIDT R. Multiple emitter location and signal parameter estimation[J]. *IEEE Transactions on Antennas and Propagation*, 1986, 34(3): 276–280. doi: [10.1109/TAP.1986.1143830](https://doi.org/10.1109/TAP.1986.1143830).
- [8] ROY R and KAILATH T. ESPRIT-estimation of signal parameters via rotational invariance techniques[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1989, 37(7): 984–995. doi: [10.1109/29.32276](https://doi.org/10.1109/29.32276).
- [9] ZISKIND I and WAX M. Maximum likelihood localization of multiple sources by alternating projection[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1988, 36(10): 1553–1560. doi: [10.1109/29.7543](https://doi.org/10.1109/29.7543).
- [10] CHOI Y H. Alternating projection for maximum-likelihood source localization using eigendecomposition[J]. *IEEE Signal Processing Letters*, 1999, 6(4): 73–75. doi: [10.1109/97.752057](https://doi.org/10.1109/97.752057).
- [11] WU Bo, LI Kehuang, GE Fengpei, *et al.* An end-to-end deep learning approach to simultaneous speech dereverberation and acoustic modeling for robust speech recognition[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2017, 11(8): 1289–1300. doi: [10.1109/JSTSP.2017.2756439](https://doi.org/10.1109/JSTSP.2017.2756439).
- [12] WU Bo, LI Kehuang, YANG Minglei, *et al.* A reverberation-time-aware approach to speech dereverberation based on deep neural networks[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2017, 25(1): 102–111. doi: [10.1109/TASLP.2016.2623559](https://doi.org/10.1109/TASLP.2016.2623559).
- [13] XIANG Houhong, CHEN Baixiao, YANG Minglei, *et al.* Altitude measurement based on characteristics reversal by deep neural network for VHF radar[J]. *IET Radar, Sonar & Navigation*, 2019, 13(1): 98–103. doi: [10.1049/iet-rsn.2018.5121](https://doi.org/10.1049/iet-rsn.2018.5121).
- [14] WU Liuli and HUANG Zhitao. Coherent SVR learning for wideband direction-of-arrival estimation[J]. *IEEE Signal Processing Letters*, 2019, 26(4): 642–646. doi: [10.1109/LSP.2019.2901641](https://doi.org/10.1109/LSP.2019.2901641).
- [15] WERBOS P J. Backpropagation through time: What it does and how to do it[J]. *Proceedings of the IEEE*, 1990, 78(10): 1550–1560. doi: [10.1109/5.58337](https://doi.org/10.1109/5.58337).
- [16] LECUN Y, BOSER B, DENKER J S, *et al.* Backpropagation applied to handwritten zip code recognition[J]. *Neural Computation*, 1989, 1(4): 541–551. doi: [10.1162/neco.1989.1.4.541](https://doi.org/10.1162/neco.1989.1.4.541).
- [17] KINGMA D P and BA J. Adam: A method for stochastic optimization[J]. arXiv: 2014, 1412.6980.
- [18] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, *et al.* Dropout: A simple way to prevent neural networks from overfitting[J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929–1958.
- 项厚宏: 男, 1994年生, 博士生, 研究方向为阵列信号处理、米波雷达测高、机器学习, 深度学习。
- 陈伯孝: 男, 1966年生, 教授, 博士生导师, 研究方向为新体制雷达系统设计及其实现、目标精确制导与跟踪、机器学习、深度学习等。

责任编辑: 陈倩