

引用格式:屠钺,朱文丽,张旻,等.基于CNN特征的宽频段智能测向方法[J].信息对抗技术,2022,1(2):75-84. [TU Cheng, ZHU Wenli, ZHANG Min, et al. A broadband intelligent direction finding method based on CNN features[J]. Information Countermeasure Technology, 2022, 1(2):75-84. (in Chinese)]

基于CNN特征的宽频段智能测向方法

屠钺¹,朱文丽^{1,2*},张旻¹,李宇薇¹

(1. 国防科技大学电子对抗学院,安徽合肥 230037; 2. 中国西安卫星测控中心,陕西西安 710043)

摘要 当前电磁环境日益复杂,利用机器学习方法实现快速且精确的宽频段无线电测向逐渐成为研究的热点。使用卷积神经网络基于端到端的方式完成宽频段测向的方法能够在一定程度上解决宽频段相位模糊的问题,但卷积运算后特征维数大大增加,稀疏的特征影响了最后一层全连接前馈神经网络的分类效果。针对这一问题,提出将无线电测向分为特征学习任务 and 方向预测任务,使用卷积神经网络作为特征提取器,将通过多层卷积运算得到的结果视为二次提取的特征,作为方向预测任务的输入;针对二次提取特征的稀疏性,提出使用主成分分析算法对特征进行降维,并将稀疏性降低后的特征作为后续分类器的输入。此外,针对特征的特点,探索了几种分类模型作为分类器的效果,包括决策树、随机森林、径向基函数神经网络和K-近邻。实验结果表明,使用主成分分析算法对特征进行降维能够提升训练和测试效率;采用K-近邻构成分类器的准确度明显高于原卷积神经网络的准确度;若需要兼顾准确度和测向效率,采用随机森林构成分类器的效果最好。

关键词 宽频段测向;智能测向;深度学习;特征学习

中图分类号 TN 971 **文献标志码** A **文章编号** 2097-163X(2022)02-0075-10

DOI 10.12399/j.issn.2097-163x.2022.02.006

A broadband intelligent direction finding method based on CNN features

TU Cheng¹, ZHU Wenli^{1,2*}, ZHANG Min¹, LI Yuwei¹

(1. College of Electronic Engineering, National University of Defense Technology, Hefei 230037, China;
2. China Xi'an Satellite Control Center, Xi'an 710043, China)

Abstract At present, electromagnetic environment is becoming more and more complex. Using machine learning methods to achieve radio direction finding has become a research hotspot. The existing research work attempts to use convolution neural network to complete broadband radio direction finding based on end-to-end method. It can solve the problem of wide-band phase ambiguity. However, the dimension of the feature after convolution increases greatly, which results in the phenomenon of feature sparse and further, affects the performance of the fully connected feedforward neural network to a certain extent. To solve this problem, we divided radio direction finding into feature learning task and direction prediction

收稿日期:2021-12-10 修回日期:2022-05-21

通信作者:朱文丽,E-mail: li_3crystal@163.com

作者简介:屠钺(1998—),女,博士研究生,研究方向为数据挖掘、深度学习、知识图谱;朱文丽(1991—),女,博士,工程师,研究方向为信号处理、深度学习、通信安全;张旻(1966—),男,博士,教授,博士研究生导师,研究方向为网络空间安全、机器学习;李宇薇(1993—),女,博士,讲师,研究方向为深度学习、人工智能安全、软件安全

基金项目:国家自然科学基金资助项目(61971413)

task, and used convolution neural network as feature extractor to obtain secondary extracted features, which were the inputs of the direction prediction task. Further, we used the principal component analysis algorithm to reduce the dimension of the features. In addition, we explored the performance of several classification models as the final classifier, including decision tree, random forest, radial basis function neural network and K-nearest neighbor. The experimental results showed that using principal component analysis algorithm to reduce the dimension of features could improve the efficiency of training and testing, and the accuracy of K-nearest neighbor classifier was significantly higher than that of the original convolution neural network. If both accuracy and efficiency were considered, random forest classifier was the best.

Keywords broadband direction finding; intelligent direction finding; deep learning; feature learning

0 引言

无线电测向也称波达方向(direction of arrival, DOA)估计,是阵列信号处理领域一个重要的研究内容。随着电磁环境日益复杂,信号密集多样,无线电测向系统需要覆盖越来越宽的频率范围。测向频率范围与天线阵列密切相关。一般来说,系统最低接收频率决定天线阵元尺寸的大小,最高接收频率决定基线长度。当频率范围较宽时,天线阵列难以满足宽频段测向要求,造成测向系统面临着相位模糊问题。因此,如何在解决相位模糊问题的基础上实现快速、准确的宽频段 DOA 估计是无线电测向系统亟待解决的重难点问题。

现有的 DOA 估计算法可分为 3 大类,包括子空间类算法^[1-5]、稀疏类算法^[6-10]和机器学习类算法^[11-17]。子空间类算法和稀疏类算法作为传统主流测向算法,都是基于电磁波传播的物理模型,通常需要适用环境的特定信息才能实现高精度的测向,难以解决宽频段无线电测向中的相位模糊问题。随着机器学习相关技术的发展,机器学习类算法越来越多地被用于无线电测向领域,利用阵列接收信号中包含的信息,通过不断的感知和学习使得模型获得一定的测向能力。应用该类算法的智能测向系统能够满足更高的时效性和准确性,成为当前 DOA 估计的研究热点。文献[18]提出了一种基于卷积神经网络(convolutional neural network, CNN)的端到端(end-to-end)的宽频段 DOA 估计方法,通过多层卷积运算对原始方向特征进行加权求和,形成众多虚拟基线,从而一定程度上去除了相位模糊所带来的

影响。同时,多层卷积运算后特征的维数大大增加,造成了特征稀疏的现象,直接将卷积的结果作为全连接前馈神经网络(fully connected neural network, FCNN)的输入影响了分类效果。

针对这一问题,本文提出将无线电测向模型分为特征学习和方向预测 2 个任务,而不直接作为端到端模型预测来波方向,以利于对特征作进一步处理。在特征学习任务中,使用 CNN 作为特征提取器,将通过多层卷积运算得到的结果视为二次提取的特征,作为方向预测任务的输入。同时,在方向预测任务中,针对二次提取特征的稀疏性,提出使用主成分分析(principal component analysis, PCA)算法对特征进行降维,再将降维后的特征作为后续分类器的输入,提升后续与特征维数相关的分类模型的效率。通过实验验证了几种分类模型作为方向预测任务中分类器的效果。

1 阵列信号模型

以均匀圆阵(uniform circular array, UCA)为例,给出阵列接收信号的数学模型。首先,考虑 M 个各向同性的阵元均匀分布在半径为 r 的圆周上,各阵元之间相互独立工作,如图 1 所示。




图 1 均匀圆阵

Fig. 1 Uniform circular array

假设 P 个远场信号入射到天线阵列,则均匀圆阵在 t 时刻的接收信号为:

$$\mathbf{X}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{N}(t) \quad (1)$$

式中, $\mathbf{X}(t)$ 为 $M \times 1$ 维的阵列快拍数据矢量, $\mathbf{N}(t)$ 为 $M \times 1$ 维的阵列噪声数据矢量, $\mathbf{S}(t)$ 为 $P \times 1$ 维的空间信号矢量, \mathbf{A} 为 $M \times P$ 维的阵列导向矢量矩阵, $\mathbf{A} = [\mathbf{a}_1(f_0), \mathbf{a}_2(f_0), \dots, \mathbf{a}_P(f_0)]$, 其中, 导向矢量为:

$$\mathbf{a}_i(f_0) = \begin{bmatrix} e^{-j2\pi f_0 \tau_{1i}} \\ e^{-j2\pi f_0 \tau_{2i}} \\ \vdots \\ e^{-j2\pi f_0 \tau_{Mi}} \end{bmatrix}, i = 1, 2, \dots, P \quad (2)$$

从上面的分析可知,得到了阵元间的延迟 τ , 就可以得到空间阵列的导向矢量,下面来推导 M 元均匀圆阵阵元之间延迟 τ 的表达式。

以圆阵的圆心为参考点,阵元 1 为参考阵元,信号入射参数为 (θ_i, ϕ_i) , $i = 1, 2, \dots, P$, θ 表示方位角(入射信号在阵列平面的投影与 x 轴的夹角), ϕ 表示俯仰角(入射信号与 z 轴的夹角),则第 i 个信号源到达第 k 个阵元时相对于参考阵元的时延为:

$$\tau_{ki} = \frac{r}{c} \cos\left(\frac{2\pi(k-1)}{M} - \theta_i\right) \sin \phi_i \quad (3)$$

对于智能测向,同时对方位角和俯仰角进行估计,俯仰角、方位角、信号频率 3 个参数的交叉组合,导致训练样本呈爆炸式增长。因此,本文只考虑入射波是平面波的情况,即 $\phi = 90^\circ$, 此时式(4)可简化为:

$$\tau_{ki} = \frac{r}{c} \cos\left(\frac{2\pi(k-1)}{M} - \theta_i\right) \quad (4)$$

2 宽频段智能测向方法

针对使用卷积神经网络、基于端到端方式的宽频段无线电测向方法中所存在的多层卷积运算后特征具有稀疏性的问题,本文提出将宽频段无线电测向分为特征学习和方向预测 2 个任务。其整体流程如图 2 所示。

接下来将从原始方向特征的选择、基于 CNN 的特征学习、基于 PCA 的特征降维和分类器的选择与设计 4 个方面介绍本文提出的方法。

2.1 原始方向特征的选择

天线阵列接收信号中包含来波信息的有:阵元间的相位差、信号协方差矩阵等。对于观察者来说,获取空间信号的信息全部包含在阵列信号

矢量 $\mathbf{X}(t)$ 或协方差矩阵 \mathbf{R} 中,从协方差矩阵中就可以提取全部信息。由式(1)可得阵列接收信号的协方差矩阵为:

$$\mathbf{R} = E[\mathbf{X}(t)\mathbf{X}^H(t)] = \mathbf{A}E[\mathbf{S}(t)\mathbf{S}^H(t)]\mathbf{A}^H + E[\mathbf{N}(t)\mathbf{N}^H(t)] = \mathbf{A}\mathbf{R}_{ss}\mathbf{A}^H + \mathbf{R}_{nn} \quad (5)$$

式中, $\mathbf{R}_{ss} = E[\mathbf{S}(t)\mathbf{S}^H(t)]$ 和 $\mathbf{R}_{nn} = E[\mathbf{N}(t) \cdot \mathbf{N}^H(t)]$ 分别为信号协方差矩阵和噪声协方差矩阵, $(\cdot)^H$ 表示共轭转置。




图2 方法整体流程图

Fig. 2 Overall flow chart of the method

对式(5)进一步分析可知,第 m 个阵元的接收信号和第 l 个阵元的接收信号之间的互相关函数为:

$$\begin{aligned} R_{ml}(\tau) &= E\left\{X_m\left(t + \frac{\tau}{2}\right) X_l^*\left(t - \frac{\tau}{2}\right)\right\} = \\ &E\left\{S\left(t + \frac{\tau}{2}\right) S^*\left(t - \frac{\tau}{2}\right) \cdot \right. \\ &\exp\left[-j\xi\cos\left(\frac{2\pi(m-1)}{M} - \theta_k\right)\right] \cdot \\ &\left.\exp\left[j\xi\cos\left(\frac{2\pi(l-1)}{M} - \theta_k\right)\right]\right\} + \\ &E\left\{N_m\left(t + \frac{\tau}{2}\right) N_l^*\left(t - \frac{\tau}{2}\right)\right\} \quad (6) \end{aligned}$$

式中, $\xi = \frac{2\pi r}{\lambda}$, λ 是波长。由于 $N(t)$ 为加性高斯白噪声,因此:

$$E\left\{N_m\left(t + \frac{\tau}{2}\right) N_l^*\left(t - \frac{\tau}{2}\right)\right\} = 0 \quad (7)$$

所以式(7)可简化为:

$$\begin{aligned} R_{ml}(\tau) &= R_{ss}(\tau) \exp\left\{j\xi\left[\cos\left(\frac{2\pi(l-1)}{M} - \theta_k\right) - \right. \right. \\ &\left.\left.\cos\left(\frac{2\pi(m-1)}{M} - \theta_k\right)\right]\right\} \quad (8) \end{aligned}$$

式中, $R_{ss}(\tau)$ 为信号的自相关函数。从式(8)可以看出来波的方向信息全部包含在互相关函数的幅角之中,因此可以提取协方差矩阵的幅角构成方向特征。阵元 m 的接收信号和阵元 l 的接收信号之间的互相关函数的幅角为:

$$\varphi_{ml} = \xi \left[\cos\left(\frac{2\pi(l-1)}{M} - \theta_k\right) - \cos\left(\frac{2\pi(m-1)}{M} - \theta_k\right) \right] \quad (9)$$

因此,取每两个阵元接收信号互相关函数的幅角构成“方向图”矩阵作为特征学习任务中 CNN 的输入。

2.2 基于 CNN 的方向特征学习

CNN 通过多层卷积运算,能将底层特征重新提取组合,构成更为抽象的高层特征,从而达到特征提取和数据重建的效果。在训练卷积神经网络的过程中,先根据输入和参数进行前向传播,再根据损失函数计算值进行反向梯度传播,从而更新参数。前向传播的过程如图 3 所示。

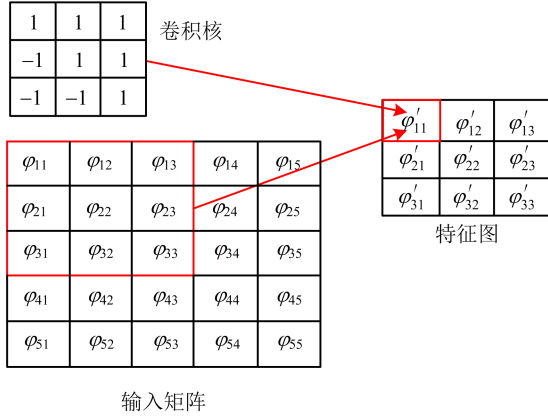


图 3 卷积神经网络前向传播过程

Fig. 3 Forward propagation process of CNN

设输入为 1 个单通道(channel)特征,则第 l 层卷积层中,第 j 个卷积核的最终输出为:

$$\begin{cases} u_j^l(i) = \sum_{k=1}^{n_{l-1}} \omega_{jk}^l * y_k^{l-1}(i) + b_j^l \\ y_j^l(i) = a(u_j^l(i)) \end{cases}, j = 1, 2, \dots, n_l \quad (10)$$

式中, $\omega_{jk}^l \in \mathbf{R}^2$ 为第 $l-1$ 层输出的第 k 个特征图和第 l 层输出的第 j 个特征图之间的卷积核, $y_j^l(i) \in \mathbf{R}^2$ 为第 l 层输出的第 j 个特征图, b_j^l 为第 l 层输出的第 j 个特征图的偏置项, $a(\cdot)$ 为激活函数, $*$ 为卷积运算符。将最后一层卷积输出的特征图按序平坦化为 N_c 维向量 $\mathbf{Z} = (z_1, z_2, \dots, z_n)^T$ 作为方向预测任务的输入。

2.3 基于 PCA 的特征降维

多层卷积运算后学习到的方向特征虽然解决了宽频段相位模糊问题,但最后一层卷积输出的方向特征维数过多,一定程度上造成方向特征的稀疏,增加了分类器建模的复杂性。以模型 CNN128-128-128(2-3-4) 为例,网络输入大小为 8×8 , 即有 64 维特征,卷积后的方向特征平坦化后有 512 维,维数增加了 8 倍。

图 4 描绘了 3 个不同频率和角度的来波卷积后的稀疏方向特征,从灰度图可以看出,白色占据了大部分区域,表明卷积后的方向特征包含了大量的 0 元素,也进一步说明卷积后的方向特征具有一定稀疏性。鉴于此,在分类算法完成方向预测任务前,对多层卷积运算提取的高维稀疏特征,采用 PCA 法^[19] 对其进行降维,降低方向特征各属性之间存在的线性相关关系,继而使分类器能够更好地拟合输入输出对的非线性函数。




图 4 不同频率和角度的来波卷积后的稀疏方向特征

Fig. 4 Sparse direction characteristics of incoming wave convolution with different frequencies and angles

基于 PCA 的特征降维过程可描述为:将多层卷积运算提取的方向特征表示为 $N_c \times 1$ 维的稀疏向量 $\mathbf{Z} = (z_1, z_2, \dots, z_{N_c})^T$ 。首先对稀疏向量进行去中心化处理,即每一个属性减去其平均值:

$$\begin{cases} \tilde{z}_i = z_i - \mu_z, (i = 1, 2, \dots, N_c) \\ \mu_z = \frac{1}{N_c} \sum_{i=1}^{N_c} z_i \end{cases} \quad (11)$$

去中心化后得到 $N_c \times 1$ 维的属性向量 \mathbf{Z} , 其

协方差矩阵为:

$$\mathbf{R} = [r_{ij}]_{N_c \times N_c} = \tilde{\mathbf{Z}}\tilde{\mathbf{Z}}^T \quad (12)$$

式中,

$$r_{ij} = z_i \cdot z_j, (i, j = 1, 2, \dots, N_c) \quad (13)$$

通过奇异值分解计算协方差矩阵 \mathbf{R} 的特征值与特征向量,则可以计算出 N_c 个特征值 $\{\lambda_1, \lambda_2, \dots, \lambda_{N_c}\}$ 和其对应的 N_c 个特征向量 $\{\boldsymbol{\eta}_1, \boldsymbol{\eta}_2, \dots, \boldsymbol{\eta}_{N_c}\}$ 。将特征值按照从大到小的顺序进行排序,选择其中前 M_c 个特征值, M_c 亦称为主分量个数。给定贡献率 ρ_c 的取值,按照式(15)确定主成分个数 M_c 的值。 ρ_c 可作为一个超参数进行训练和测试。

$$\left(\sum_{i=1}^{M_c} \lambda_i / \sum_{i=1}^{N_c} \lambda_i \right) \geq \rho_c \quad (14)$$

利用这 M_c 个特征向量构成的 $M_c \times N_c$ 维矩阵 $\boldsymbol{\Omega}$ 与去中心化的向量 $\tilde{\mathbf{Z}}$ 相乘,则得到降维后的向量 $\tilde{\mathbf{Z}}_{\text{PCA}}$,即:

$$\tilde{\mathbf{Z}}_{\text{PCA}} = \boldsymbol{\Omega} \cdot \tilde{\mathbf{Z}} \quad (15)$$

至此,利用 PCA 将经过 CNN 学习得到的 N_c 维稀疏特征降维到 M_c 维,且各维属性相互独立。

2.4 分类器的选择与设计

由于宽频段测向系统的复杂性,使得 CNN 二次提取的特征也十分复杂,基于 PCA 的压缩一定程度上解决了方向特征稀疏性的问题,但压缩后的特征与频率间依然存在着复杂的非线性关联关系,究竟哪种分类器适合完成最后的方向预测需要通过实验进行对比和验证。如图 5 所示,本文拟选择以下 4 种分类器:

(1) 决策树(decision tree, DT)。经过 PCA 压缩后特征各属性所带来的信息量大不相同,决策树能够较好处理属性所占权重不同的情况。对于压缩后得到的特征,采用自顶向下的递归方法,通过计算各属性的信息增益值,以信息熵为度量构造一棵熵值下降最快的树,当有未知样本输入时,通过遍历树能够预测该样本的来波方向。

(2) 随机森林(random forest, RF)。RF 具有抗过拟合的能力,能实现并行训练,节约训练时间和提升效率,也能在一定程度上减小方差,提升估计精度。对于压缩后得到的特征,本文基于从训练集中多次独立抽取的子训练集构建多个弱分类器,即多棵决策树,再将多棵决策树整合成森林,通过投票或取均值等方式组合多棵决

策树的方向预测结果。

(3) 径向基函数神经网络(radial basis function neural network, RBFNN)。经过 PCA 压缩后的特征与频率间有较强的关联,RBFNN 具有“局部映射”特性,即仅根据待预测样本附近的数据逼近目标函数。RBFNN 是由空间局部化核函数构成的具有单隐层的 3 层前向神经网络,其关键在于隐层神经元中心参数的合理确定。我们采用基于 K-均值(K-means)的自组织学习选取中心法确定隐层神经元中心。

(4) K-近邻(K-nearest neighbor, KNN)。经过 PCA 压缩后的特征与频率间存在着复杂的非线性关联关系,KNN 能够通过多个局部逼近隐含地表示方向特征到波达方向的全局映射函数。KNN 在特征空间中寻找与待预测样本最相近的 k 个样本,通过计算它们来波方向的算术平均值,得出待预测样本的来波方向。

同时,在针对波达方向角进行建模时,由于输出方向角 θ 在 $360^\circ \rightarrow 0^\circ$ 转换的不连续性,这种不连续性会降低估计精度。为了保证输出函数的连续性,以上所述的每种分类模型都采用 2 个输出,分别对应于波达方向角的正弦函数和余弦函数。

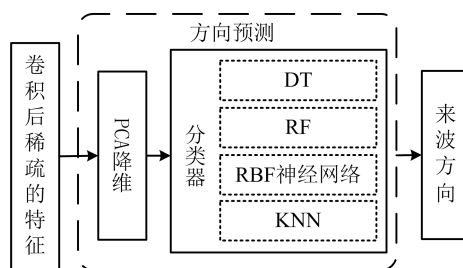


图 5 分类器的选择

Fig. 5 Framework of the method

3 仿真实验及结果分析

3.1 实验设置

在仿真实验中,依据文献[20]设置实验参数,采用 8 元均匀圆阵作为天线阵列,半径 $r=0.75$ m,快拍数 $N=256$ 。仿真样本的参数设置为:信号频率 $150 \sim 500$ MHz(其中 $150 \sim 250$ MHz 的步进为 3 MHz, $250 \sim 400$ MHz 的步进为 2 MHz, $400 \sim 500$ MHz 的步进为 1 MHz),角度为 $0^\circ \sim 360^\circ$,步进为 0.3° ,信噪比为 25 dB,共产生 253 200 个样本。仿真参数设置如表 1 所示。

表 1 仿真实验参数设置

Tab. 1 Parameters setting of simulation experiment

名称	参数值
阵元数目	8
阵列半径/m	0.75
信号频率/MHz	150~500
信噪比/dB	25
快拍数	256

从样本中按频率范围随机抽取约 60% 作为训练样本, 剩余作为测试样本。训练和测试样本的规模如表 2 所示。

表 2 训练集和测试集的规模

Tab. 2 The size of the training set and the test set

频率范围/MHz	训练集规模	测试集规模	总计
150~250	24 000	16 800	40 800
250~400	54 000	37 200	91 200
400~500	72 000	49 200	121 200
总计	150 000	103 200	253 200

本文实验环境为 Intel Core i7-10875H @ 2.30 GHz 型号 CPU, 32 G 内存, RTX 2060Ti 显卡。

3.2 评价指标

评价指标包括平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean square error, RMSE)、最大绝对误差 (max absolute error, MXAE) 和绝对误差比率 (absolute error ratio, AER)。

MAE 为预测值和观测值之间绝对误差的平均值, 表示为:

$$r_{MAE} = E |\boldsymbol{\theta}_{ref} - \boldsymbol{\theta}_{est}| \quad (16)$$

其中, $\boldsymbol{\theta}_{ref}$ 是来波方位角的真实值, $\boldsymbol{\theta}_{est}$ 是来波方位角的估计值。

RMSE 为预测值和观测值之间差异的样本标准差, 表示为:

$$r_{RMSE} = \sqrt{E \{(\boldsymbol{\theta}_{ref} - \boldsymbol{\theta}_{est})^2\}} \quad (17)$$

MXAE 为预测值和观测值之间绝对误差的最大值, 表示为:

$$r_{MXAE} = \max |\boldsymbol{\theta}_{ref} - \boldsymbol{\theta}_{est}| \quad (18)$$

绝对误差比率 $r_{acc}(\alpha)$ 指 DOA 估计的绝对误差小于 α 的样本数占总样本的比例, 即:

$$r_{acc}(\alpha) = \frac{f_{num}(|\boldsymbol{\theta}_{ref} - \boldsymbol{\theta}_{est}| < \alpha)}{n_{test-number}} \quad (19)$$

式中, $f_{num}(\cdot)$ 表示计数函数, $n_{test-number}$ 指的是测试样本的总数量。

3.3 实验结果及分析

3.3.1 基于 CNN 的宽频段 DOA 估计 (实验 I)

实验构建了 1 个包含有 5 层卷积层和 1 个全连接层的卷积神经网络来实现宽频段 DOA 估计, 并将最后一层卷积输出的稀疏方向特征用于后续的研究。各卷积层的卷积核数目为 8, 16, 32, 64, 64, 对应的卷积核大小为 3×3 , 3×3 , 3×3 , 1×1 , 1×1 。卷积层的激活函数皆为 ReLU 函数。全连接层有 256 个神经元, 输出为方位角的正弦值和余弦值。CNN 模型结构如图 6 所示。




图 6 CNN 模型结构设计

Fig. 6 Structural design of CNN

该模型的各项性能指标具体为: r_{MAE} 为 0.476 2, r_{RMSE} 为 0.620 4, r_{MXAE} 为 14.337 8, $r_{acc}(1^\circ)$ 为 91.4%, 整个测试集完成测试的时间为 6.00 s, 即单次测试时间平均为 58.14 μ s, 后续实验皆以整个测试集的测试时间作为指标衡量时效性。

3.3.2 基于 CNN 特征的各分类模型对比 (实验 II)

选择实验 I 中 CNN 模型最后一个卷积层的输出作为二次提取的特征, 将其平坦化后作为方向预测任务的输入, 则该输入具有 256 维。在使

用 PCA 算法 (贡献率 ρ_C 设置为 0.98) 进行特征降维及不使用 PCA 算法进行特征降维 2 种情况下, 分别使用 DT, RF, RBF 神经网络和 KNN 4 种模型作为方向预测任务的分类器进行对比实验。

3.3.2.1 基于 CNN-DT 模型的宽频段 DOA 估计

使用 DT 模型构建分类器, 图 7 分别展示了在不使用和使用 PCA 进行特征降维的情况下, 基于 CNN-DT 进行宽频段 DOA 估计的误差结果。

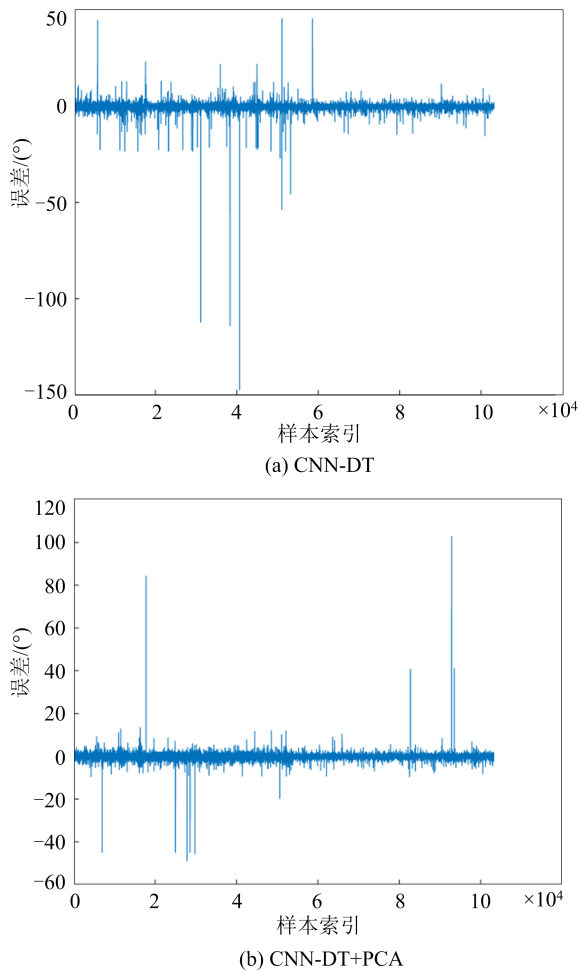


图 7 基于 CNN-DT 的宽频段 DOA 估计模型误差结果
Fig. 7 The bias of broadband DOA estimation based on CNN-DT

由图 7 可知, 当采用 PCA 算法进行特征降维时, 最大绝对误差有所降低, 且绝大多数样本的估计误差都在 0° 左右较小的范围内波动, 其中部分误差较大的原因可能在于 DT 算法容易过拟合, 更深层的原因还需要进行进一步研究。模型具体的性能指标如表 3 所示。

表 3 基于 CNN-DT 的宽频段 DOA 估计模型实验结果
Tab. 3 The results of broadband DOA estimation model based on CNN-DT

PCA	$r_{MAE}/(^{\circ})$	$r_{RMSE}/(^{\circ})$	$r_{MXAE}/(^{\circ})$	$r_{acc}(1^{\circ})$ (%)	训练 时间/s	测试 时间/s
×	0.390 6	1.114 1	147.3	92.81	345.08	2.15
√	0.388 0	0.879 1	102.9	92.42	31.46	2.06

从表 3 可以看出, 使用 PCA 进行特征降维的 CNN-DT 宽频段 DOA 估计模型能够显著提升训练效率, 同时在 r_{MAE} , r_{RMSE} 和 r_{MXAE} 3 个指标上有

更好的表现力, 但误差在 1° 以内的比率有所下降。

3.3.2.2 基于 CNN-RF 模型的宽频段 DOA 估计

使用 RF 模型构建分类器, 取决策树棵数 k 分别为 10 和 15, 图 8 展示了 $k=10$ 时在不使用和使用 PCA 进行特征降维的情况下, 基于 CNN-RF 进行宽频段 DOA 估计的误差结果。

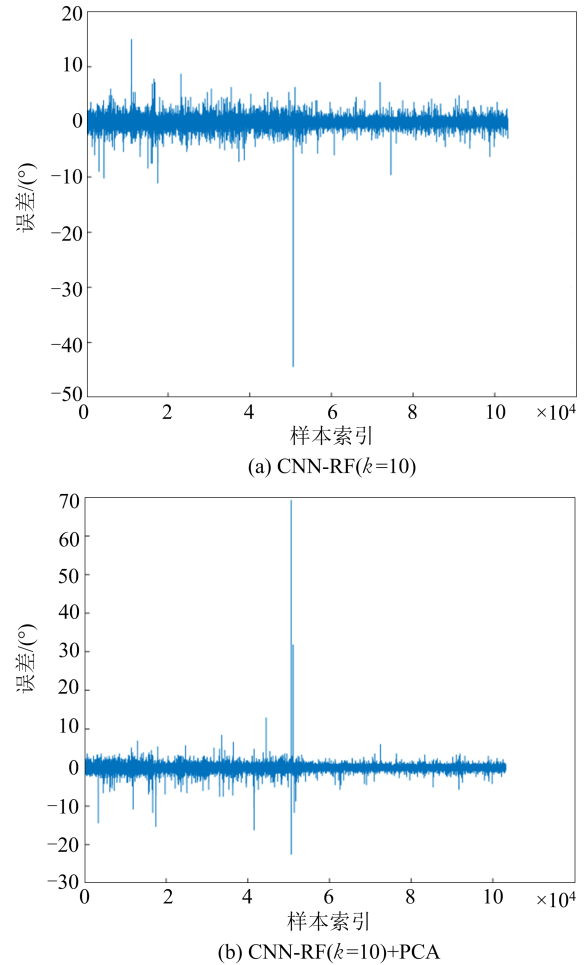


图 8 基于 CNN-RF 的宽频段 DOA 估计模型误差结果图
Fig. 8 The bias of broadband DOA estimation based on CNN-RF

由图 8 可知, 在决策树棵数 k 相等的前提下, 采用 PCA 算法进行特征降维时, 最大绝对误差同样有所降低, 且绝大多数样本的估计误差都在 0° 左右较小的范围内波动, 其中个别误差较大的原因可能在于: (1) 角度在 $359^\circ \rightarrow 0^\circ$ 的转换存在数值上的不连续性, 对于真实角度为 359.6° 的来波方向可能预测为 0° ; (2) RF 是一个集成学习模型, 它对多棵决策树的预测结果取平均值, 因此当多棵决策树的预测结果分别在 359° 和 0° 左右

时,取平均后就会得到一个具有较大误差的预测结果。模型具体的性能指标如表 4 所示。

表 4 基于 CNN-RF 的宽频段 DOA 估计模型实验结果

Tab. 4 The experimental results of broadband DOA estimation model based on CNN-RF

k 值	PCA	$r_{MAE}/(^{\circ})$	$r_{RMSE}/(^{\circ})$	$r_{MXAE}/(^{\circ})$	$r_{acc}(1^{\circ})$ (%)	训练 时间/s	测试 时间/s
10	×	0.283 4	0.549 5	69.3	96.20	250.89	39.77
10	✓	0.306 5	0.548 5	44.4	95.19	227.19	40.69
15	×	0.264 0	0.488 4	54.3	96.73	373.96	69.82
15	✓	0.291 7	0.520 0	44.7	95.64	345.72	59.52

从表 4 可以看出,使用 PCA 进行特征降维的 CNN-RF 宽频段 DOA 估计模型训练效率没有明显提升,同时在 r_{MAE} 和 r_{RMSE} 2 个指标上逊色于不使用 PCA 进行特征降维的 CNN-RF 宽频段 DOA 估计模型,且误差在 1° 以内的比率下降了 1%。

3.3.2.3 基于 CNN-RBF 模型的宽频段 DOA 估计

使用 RBFNN 模型构建分类器,图 9 分别展示了在不使用和使用 PCA 进行特征降维的情况下,基于 CNN-RBF 进行宽频段 DOA 估计的误差结果。

由图 9 可知,采用 PCA 算法进行特征降维对测向误差没有造成显著影响,绝大多数样本的估计误差都在 0° 左右较小的范围内波动。模型具体的性能指标如表 5 所示。

表 5 基于 CNN-RBF 的宽频段 DOA 估计模型实验结果

Tab. 5 The experimental results of broadband DOA estimation model based on CNN-RBF

PCA	$r_{MAE}/(^{\circ})$	$r_{RMSE}/(^{\circ})$	$r_{MXAE}/(^{\circ})$	$r_{acc}(1^{\circ})$ (%)	训练 时间/s	测试 时间/s
×	0.384 2	0.632 4	7.646 7	93.41	39 806.74	1.96
✓	0.417 9	0.695 2	8.036 6	92.73	12 801.97	1.73

从表 5 可以看出,使用 PCA 进行特征降维的 CNN-RBF 宽频段 DOA 估计模型能够显著提升训练效率,但在 r_{MAE} , r_{RMSE} , r_{MXAE} 和 $r_{acc}(1^{\circ})$ 4 个指标上都逊色于不使用 PCA 进行降维的 CNN-RBF 宽频段 DOA 估计模型。同时,基于 CNN-RBF 的宽频段 DOA 估计模型在训练时间上明显长于前 2 种模型。

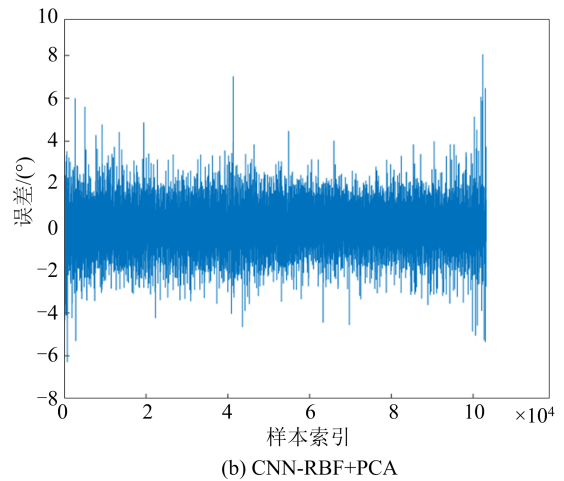



图 9 基于 CNN-RBF 的宽频段 DOA 估计模型误差结果图
Fig. 9 The bias of broadband DOA estimation based on CNN-RBF

3.2.3.4 基于 CNN-KNN 模型的宽频段 DOA 估计

使用 KNN 模型构建分类器,取最近邻居数 k 为 1, 2 和 3,图 10 展示了 $k=1$ 时在不使用和使用 PCA 进行特征降维的情况下,基于 CNN-KNN 进行宽频段 DOA 估计的误差结果。

由图 10 可知,基于 PCA 进行降维对测向误差没有造成显著影响,绝大多数样本的估计误差都在 0° 左右较小的范围内波动。模型具体的性能指标如表 6 所示。

从表 6 可以看出,各条件下的 $r_{acc}(1^{\circ})$ 指标差别较小,综合考虑 r_{MAE} , r_{RMSE} 和 r_{MXAE} 3 个指标, k 值取 1 时基于 CNN-KNN 的宽频段 DOA 估计模型效果最好; k 值取大于 1 时, r_{MXAE} 显著增大,与 CNN-RF 模型出现个别较大误差的原因类似, KNN 会对 k 个距离最近的预测值取平均,不能很好地适应角度从 $359^{\circ} \rightarrow 0^{\circ}$ 数值上不连续的特性。此外,由于 KNN 消极学习的特性,使用 PCA

进行特征降维能够显著提升测试效率。

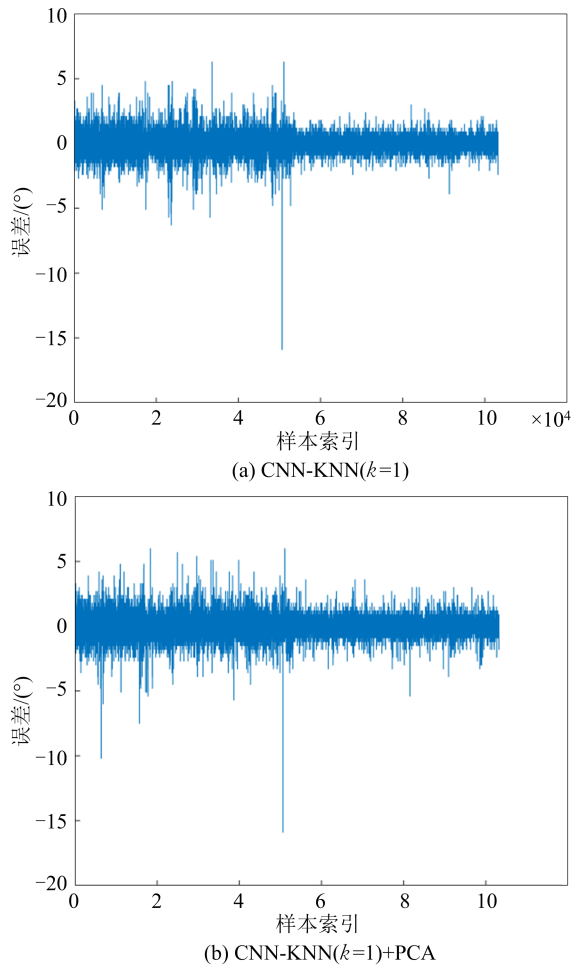


图 10 基于 CNN- KNN 的宽频段 DOA 估计模型误差结果图

Fig. 10 The bias of broadband DOA estimation based on CNN-KNN

表 6 基于 CNN-KNN 的宽频段 DOA 估计模型实验结果

Tab. 6 The experimental results of broadband DOA estimation model based on CNN-KNN

k 值	PCA	$r_{MAE}/(^{\circ})$	$r_{RMSE}/(^{\circ})$	$r_{MMAE}/(^{\circ})$	$r_{acc}(1^{\circ})$ (%)	训练 时间/s	测试 时间/s
1	×	0.275 1	0.450 1	15.9	96.74	0.03	2 606.23
1	√	0.284 8	0.472 0	15.9	96.15	0.02	660.72
2	×	0.337 6	3.855 9	180	96.94	0.01	3 980.47
2	√	0.364 0	4.094 6	180	96.28	0.01	617.26
3	×	0.322 2	3.038 9	121.4	96.97	0.02	4 672.01
3	√	0.353 8	3.242 1	121.3	96.17	0.01	655.23

综合上述实验结果可得,以 r_{MAE} 为主要评价指标,本文提出的将多层卷积运算学习到的特征作为输入,重新构建分类器的方法的预测效果明显好于直接使用基于 CNN 的端到端模型。其中,由于 KNN 算法以多个局部逼近隐含表示特征到波达方向的全局映射函数,因此采用 KNN

构成分类器的预测准确度最高。同时,由于其在待预测样本来临时才决定如何从训练数据中泛化,因此所需的测试时间最长。若需要兼顾准确度和测向效率,采用随机森林构成分类器的效果最好。当使用 KNN 构成分类器时,使用 PCA 降维能在基本不影响预测结果的前提下显著提升预测效率。

4 结论

采用智能的方式进行宽频段测向,相较传统需要通过解析计算的基于数学模型的测向方法,能够满足更高的时效性和准确性,且能解决难以工程化的问题,因此具有较好的应用前景。本文提出了一种基于 CNN 特征的宽频段智能测向方法,将宽频段无线电测向分为特征学习和方向预测两个任务。在特征学习任务中,使用 CNN 作为特征提取器二次提取方向特征,通过多层卷积运算对原始方向特征进行加权求和,形成众多虚拟基线,从而获得消除相位模糊的方向特征。在方向预测任务中,提出使用主成分分析算法对二次提取的稀疏方向特征进行降维,提升后续与特征维数休戚相关的分类模型的效率。最后探索使用几种不同的分类模型预测来波方向。实验结果表明,采用 K-近邻构成分类器的测向准确度最高,相较原端到端的卷积神经网络模型具有显著提升。同时,对于需要兼顾测向准确度和效率的场景,采用随机森林构成分类器的测向效果最优。

参 考 文 献

[1] YAN F G, LIU S, WANG J, et al. Two-step root-music for direction of arrival estimation without EVD/SVD computation[J]. International Journal of Antennas and Propagation, 2018(2): 1-8.

[2] KWIZERA E. Direction of arrival estimation based on music algorithm using uniform and non-uniform linear arrays[J]. International Journal of Engineering Research and Applications, 2017, 7(3): 51-58.

[3] CUI K, WU W, HUANG J, et al. DOA estimation of LFM signals based on STFT and multiple invariance ESPRIT[J]. AEU International Journal of Electronics and Communications, 2017, 77: 10-17.

[4] WANG Z, ZHANG X, SUN H, et al. Non-circular generalised-ESPRIT algorithm for direction of arrival estimation[J]. IET Radar Sonar & Navigation, 2017,

- 11(5): 736-744.
- [5] CHENG Q. A simple modification of ESPRIT[J]. *IEEE Signal Processing Letters*, 2018, 99: 1-5.
- [6] ROCCA P, HANNAN M A, SALUCCI M, et al. Single-snapshot DOA estimation in array antennas with mutual coupling through a multiscaling BCS strategy[J]. *IEEE Transactions on Antennas and Propagation*, 2017, 65(6): 3203-3213.
- [7] ZHAO Y, ZHANG L, ZHANG J, et al. Low complexity method for wideband DOA estimation based on sparse representation using rotational signal subspace [C]//*Proceedings of 2017 IEEE Radar Conference*. Seattle, USA: IEEE, 2017: 460-463.
- [8] SHI Y, MAO X, ZHAO C, et al. Underdetermined DOA estimation for wideband signals via joint sparse signal reconstruction[J]. *IEEE Signal Processing Letters*, 2019, 26(10): 1541-1545.
- [9] ZHANG X, JIANG T, LI Y, et al. A novel block sparse reconstruction method for DOA estimation with unknown mutual coupling[J]. *IEEE Communications Letters*, 2019, 23(10): 1845-1848.
- [10] WANG Y, WANG L, XIE J, et al. DOA estimation under mutual coupling of uniform linear arrays using sparse reconstruction[J]. *IEEE Wireless Communications Letters*, 2019, 8(4): 1004-1007.
- [11] XIAO X, ZHAO S, ZHONG X, et al. A learning-based approach to direction of arrival estimation in noisy and reverberant environments[C]//*Proceedings of 2015 IEEE International Conference on Acoustics, Speech and Signal*. South Brisbane, Australia: [s. n.], 2015: 2814-2818.
- [12] GAO Y, HU D, CHEN Y, et al. Gridless one-bit DOA estimation exploiting SVM approach[J]. *IEEE Communications Letters*, 2017, 21(10): 2210-2213.
- [13] PAN J, WANG Y, LE C B, et al. DOA finding with support vector regression based forward-backward linear prediction[J]. *Sensors*, 2017, 17(6): 1-11.
- [14] HARKOUSS Y, SHRAIM H, BAZZI H. Direction of arrival estimation for smart antenna in multipath environment using convolutional neural network[J]. *International Journal of RF and Microwave Computer Aided Engineering*, 2018, 28(6): 1-11.
- [15] HUANG H, GUI G, SARI H, et al. Deep learning for super-resolution DOA estimation in massive MIMO systems[C]// *Proceedings of the 88th Vehicular Technology Conference*. Chicago, USA: [s. n.], 2018:1-5.
- [16] LIU Z, ZHANG C AND YU P S. Direction-of-arrival estimation based on deep neural networks with robustness to array imperfections[J]. *IEEE Transactions on Antennas and Propagation*, 2018, 66(12): 7315-7327.
- [17] XIANG H, CHEN B, YANG T, et al. Phase enhancement model based on supervised convolutional neural network for coherent DOA estimation[J]. *Applied Intelligence*, 2020, 50(6): 1-12.
- [18] ZHU W L, ZHANG M, WU C X, et al. Broadband direction of arrival estimation based on convolutional neural network[J]. *IEICE Transactions on Communications*, 2020(3): 148-154.
- [19] ABDI H, WILLIAMS L J. Principal component analysis[J]. *Wiley Interdisciplinary Reviews Computational Statistics*, 2010, 2(4): 433-459.
- [20] ZHANG M, LI P F. A broadband direction of arrival (DOA) estimation approach based on hierarchy neural networks[J]. *Journal of Electronics & Information Technology*, 2009, 31(9): 2118-2122.

责任编辑 安 蓓