

基于深度学习的相干循环平稳信号波达方向估计

周巍,张骄*

(山西大学 物理电子工程学院,山西 太原 030006)

摘要:针对传统解相干的多重信号分类(MUSIC)算法在小信噪比和非平稳信号的情况下识别精度不高的问题,提出了一种结合了深度学习的波达方向(DOA)估计算法。该算法采用线性等距阵列接收相干的循环平稳信号,针对循环平稳信号的循环频率求出循环自相关函数并构造数据矢量矩阵,再将所得的矩阵通过矢量奇异值法分解,最后再将分解后的矩阵输入到训练好的卷积神经网络中得到DOA估计的结果。并且相较于传统的DOA估计算法,采用了卷积神经网络的估计时间更少。实验仿真结果表明,在非平稳信号、低信噪比环境下,该算法的均方根误差比现有最优算法最高降低了1度。

关键词:DOA估计;矢量奇异值法;多重信号分类算法;相干信号;循环平稳信号;卷积神经网络

中图分类号:TN911.23 **文献标志码:**A **文章编号:**0253-2395(2024)05-1028-08

Directions-of-arrival Estimation of Coherent Cyclostationary Signals Based on Deep Learning

ZHOU Wei, ZHANG Jiao*

(College of Physics and Electronics Engineering, Shanxi University, Taiyuan 030006, China)

Abstract: In this paper, we focus on the problem of direction-of-arrival (DOA) estimation with applications of deep learning in the case of small signal-to-noise ratio and non-stationary signals. The paper adopts linear equidistant array to receive coherent cyclostationary signals, calculates the cyclic autocorrelation function of cyclostationary signals and constructs the data vector matrix, then decomposes the obtained matrix by vector singular value method, and finally inputs the decomposed matrix into convolutional neural network to obtain the DOA estimation result. Compared with the traditional DOA estimation algorithm, the convolution neural network has less estimation time. The simulations show that the root mean square error of the algorithm is reduced by 1 degree compared with the existing optimal algorithm in the environment of non-stationary signal and low signal-to-noise ratio.

Key words: DOA estimation; SVD algorithm; MUSIC algorithm; coherent signal; cyclic stationary signal; convolutional neural network

0 引言

波达方向(Direction-of-arrival, DOA)估计是信号处理领域的重要分支,其主要任务是估计信号发射源位置和空域参数,DOA估计广泛地应用于通信系统、雷达系统、电子对抗、天文

等领域,随着几十年的发展,波达方向估计已经形成了十分成熟的理论体系,如多重信号分类(Multiple Signal Classification, MUSIC)算法、旋转不变子空间算法、子空间拟合算法^[1-4]等。当信号是相干信号时,需要对信号进行解相干

收稿日期:2023-02-22;接受日期:2023-05-26

基金项目:国家自然科学基金(62071282;61775126);广东省光纤传感与通信技术重点实验室开放基金

作者简介:周巍(1997-),男,江苏淮安人,硕士,研究方向为阵列天线的信号处理。E-mail:1113495596@qq.com

* 通信作者:张骄(ZHANG Jiao),E-mail:zhangjiao@sxu.edu.cn

引文格式:周巍,张骄.基于深度学习的相干循环平稳信号波达方向估计[J].山西大学学报(自然科学版),2024,47(5):1028-1035. DOI:10.13451/j.sxu.ns.2023102

处理,一类解相干算法是对相干信号进行降维处理,可以分为基于空间平滑、基于矩阵重构两种;另一类是对信号进行非降维处理,如频域平滑算法、Toeplitz方法等^[5-6]。当信号源相干时,数据的协方差矩阵的秩会变小,使得信号子空间的维数小于信号源数目,从而信号子空间和噪声子空间不完全正交,导致无法正确估计信号的波达方向。矢量奇异值法(Singular Value Decomposition, SVD)是一种经典的解相干算法^[7-8],SVD算法将数据协方差矩阵进行分解,得到由信号特征矢量组成的信号子空间和由噪声特征矢量组成的噪声子空间,当信号相干时信号子空间大特征值对应的特征向量是各信号源导向矢量的线性组合,即数据协方差矩阵的最大特征矢量包含了信号的所有角度信息,利用这一特性可以对相干信号进行解相干。另外在DOA估计时,绝大多数的DOA估计算法都假设信号是广义平稳信号,但在实际情况下需要估计的信号可能不具备平稳特性,即信号的统计特性会随着时间的变化而改变^[9],这就导致了在对信号进行DOA估计时精度损失,因此在DOA估计时,需要对这类信号单独讨论。

二十世纪八九十年代,Gardner研究了循环平稳信号的特性,并将循环平稳信号的特性应用到信号的检测、分类和参数估计中并取得了巨大成功^[10-11]。在对循环平稳信号进行波达方向估计时,可以用阵列接收数据的循环互相关矩阵代替传统算法的互相关矩阵,再将循环互相关矩阵进行奇异值分解,得到信号子空间和噪声子空间矩阵,最后使用谱峰搜索的方法对信号进行方位角的估计,该算法是经典的循环平稳信号处理的谱相关信号子空间拟合(Spectral Correlation Signal-Subspace Fitting, SC-SSF)算法^[12-13]。在实际信号传输时,比如信号是相干循环平稳信号和低信噪比的条件下,该算法的效果不太理想,无法完成波达方向估计的任务,因此需要对现有算法加以改进,使其能在各种条件下完成较准确的循环平稳信号的波达方向估计。余黎煌等^[14]提出了一种快速多项式求根的方法,代替了谱峰搜索的过程,具有更快的运算速度,代价是牺牲了算法的精度。

You等^[15]使用均匀圆形阵列接收循环平稳信号,并提出了一种结合了最小均方自适应算法的循环平稳信号DOA估计算法,使用自适应滤波提高了在冲激噪声下的DOA估计精度,这种算法在冲激噪声的条件下有着较好的估计性能,但对信号在高斯白噪声下算法性能提升有限。张晋等^[16]提出了一种基于互质阵列的循环平稳信号的欠定DOA估计算法,构造虚拟模型拓展了天线的孔径,并使用多项式求根的方法简化计算,提升了阵列的自由度,这种算法仍存在低信噪比下估计误差较大的问题。谢前朋等^[17]提出了一种基于压缩感知原理恢复稀疏信号的算法,将循环平稳信号的DOA估计转换为稀疏信号的恢复问题,然而这种算法要求信号必须是稀疏信号且求解较复杂。

近年来深度学习理论的不断发展与完善^[18]为DOA估计提供了新的思路。与以往的DOA估计方法不同,深度学习方式使用大量的数据,训练特定的网络架构,挖掘出数据之间的非线性关系,并且由于深度学习模型具有较强的泛化能力,在低信噪比下也有较好的效果^[19-21]。朱晗归等^[22]利用信号的稀疏性结合深度学习算法,实现了信号源数目未知条件下的DOA估计,但是这种算法要求信号必须是稀疏信号,不适用于非稀疏信号。余佳润等^[23]使用卷积神经网络的回归模型提升了低信噪比下的均方根误差,然而这种算法不适用于相干的循环平稳信号。

为了解决上述问题并提升在低信噪比和相干信号下的性能,本文将矢量奇异值法、循环平稳DOA估计算法和卷积神经网络相结合,提出了一种新的算法,该算法对信噪比和接收阵元数目的条件没有严格的限制,即在较少天线阵元数目和较低信噪比的条件下对相干循环平稳信号可以完成高精度的DOA估计。仿真实验表明该算法在低信噪比的情况下,识别精度比SC-SSF算法更高,并且简化了谱峰搜索的流程,具有更快的估计速度。

1 波达方向估计

1.1 均匀线性阵列信号模型

假设有 N 个远场随机信号 $s(t)=[s_1(t), s_2(t), \dots, s_N(t)]^T$ 入射到线性等距阵列

上,远场信号的方位角 $\theta = [\theta_1, \theta_2, \dots, \theta_N]^T$, 其中天线阵列由 M 个阵元组成, 需要处理来自 M 个通道的数据。于是第 k 个阵列 ($k = 1, 2, \dots, M$) 的输出为

$$x_k(t) = \sum_{i=1}^N s_i(t - \tau_{ki}) + n_k(t), \quad (1)$$

其中 τ_{ki} 表示第 k 个阵列对第 i ($i = 1, 2, \dots, N$) 个信号的时延, $n_k(t)$ 表示第 k 个阵元接收的高斯白噪声。因此 M 个阵元在某一时刻的接收信号可以写成

$$X(t) = AS(t) + N(t), \quad (2)$$

其中 $X(t)$ 为阵元的 $M \times 1$ 维的快拍矢量, $N(t)$ 为阵列的 $M \times 1$ 维噪声数据矢量, $S(t)$ 为空间信号的 $N \times 1$ 维矢量, A 为空间阵列的 $M \times N$ 维阵列流形(导向矢量阵), $A = [a_1(\omega_0), a_2(\omega_0), \dots, a_N(\omega_0)]$, 导向矢量 $a_i(\omega_0) = (e^{-j\omega_0\tau_{1i}}, e^{-j\omega_0\tau_{2i}}, \dots, e^{-j\omega_0\tau_{Mi}})^T$, 其中 $i = 1, 2, \dots, N$, 式中 $\omega_0 = 2\pi f = 2\pi c/\lambda$, 其中 c 为光速, λ 为波长。

本文仅讨论均匀线阵下的波达方向估计, 当阵元是线阵时有 $\tau_{ki} = (x_k \sin \theta_i)/c$, 其中 θ_i 为第 i 个信源的方位角。

1.2 基于解相干的矢量奇异值算法

假设 N 个窄带远场信号入射到 M 个阵元组成的阵列上, 考虑极端情况, 当 N 个窄带远场信号源完全相干时, 则在高斯白噪声的条件下信号子空间的特征矢量 e_1 满足如下关系

$$e_1 = \sum_{n=1}^N a_1(n) a(\theta_n) \quad (3)$$

其中 $a_1(n)$ 为线性组合因子, $a(\theta_n)$ 为导向矢量, (3) 式包含了信号的所有信息, 因此可以通过对 (3) 式的重构来获得信号的波达角度信息, 根据 (3) 式, 重构得到如下矩阵

$$Y = \begin{bmatrix} e_{11} & e_{12} & \cdots & e_{1p} \\ e_{12} & e_{13} & \cdots & e_{1p+1} \\ \vdots & \vdots & \ddots & \vdots \\ e_{1m} & e_{1m+1} & \cdots & e_{1M} \end{bmatrix}, \quad (4)$$

其中 $p = M - m + 1$, $m > N$, $P > N$, 对 Y 进行奇异值分解

$$Y = U \Lambda V^H, \quad (5)$$

其中 Λ 是一个由 $m \times p$ 由奇异值组成的矩阵, U 是由左奇异矩阵, V 是右奇异矩阵, 理想情况下矩阵 Y 的非零奇异值为 N 个, 小奇异值对应的左奇异值矩阵中的矢量组成的空间是噪声子

空间, 非零奇异值对应的矢量即信号子空间。

由于信号噪声子空间和信号子空间具有正交性, 即 $a_i(\omega_0)U = 0$, 由于噪声的存在, 信号子空间和噪声子空间的乘积不等于 0, 而是一个接近于 0 的一个数, 所以可以用最小值搜索的方法找到最小值, 最小值所对应的角度即信号的波达方向角。所以, 基于解相干的矢量奇异值算法的谱公式为

$$P_{\text{SVD}}(\theta) = \frac{1}{a^H(\theta)UU^H a(\theta)}. \quad (6)$$

对于一般相干信号, 经奇异值分解后可以直接使用 MUSIC 算法进行谱峰搜索后得到方位角的估计。

1.3 基于循环平稳信号的 SC-SSF 算法

谱相关信号子空间拟合(SC-SSF)算法本质上是在矢量奇异值算法基础上增加了循环平稳信号的处理部分, SC-SSF 算法使用循环自相关矩阵替代矢量奇异值法的自相关矩阵来进行 DOA 估计。

而循环平稳信号是非平稳信号的一种, 与其他非平稳信号相比, 循环平稳信号的数学统计特性具有周期性。以二阶循环平稳信号为例, 假设一个信号 $x(t)$ 对于一个循环频率 α , 信号 $x(t)$ 关于 α 的循环自相关函数

$$R_x^\alpha(\tau) = \lim_{T \rightarrow \infty} 1/T \int_{-T/2}^{T/2} R_x(t + \tau/2, t - \tau/2) e^{-j2\pi\alpha t} dt =$$

$$\lim_{T \rightarrow \infty} 1/T \int_{-T/2}^{T/2} x(t + \tau/2) x^*(t - \tau/2) e^{-j2\pi\alpha t} dt$$

不等于 0, 则 $x(t)$ 具有循环平稳特性。常见的循环平稳信号有二进制相移键控(Binary Phase Shift Keying, BPSK)信号, 双边带调幅(Double-sideband Modulation, DSB-AM)信号, 线性调频信号等。

按照信号不同的统计特性, 循环平稳信号可分为一阶循环平稳信号、二阶循环平稳信号和高阶循环平稳信号。本文主要讨论对二阶循环平稳信号的 DOA 估计。

对于均匀天线阵列 x_p , $p = 1, 2, \dots, M$, 阵元的循环互相关函数为

$$R_{x_p x_p}^\alpha(\tau) = \sum_{n=1}^N R_{s_n s_n}^\alpha(\tau) e^{-j2\pi\alpha(\rho-1)\tau_p}. \quad (7)$$

于是可以由阵元的互相关函数构造矩阵:

$$\begin{pmatrix} R_{x_1 x_1}^\alpha(\tau) \\ R_{x_2 x_2}^\alpha(\tau) \\ \vdots \\ R_{x_M x_M}^\alpha(\tau) \end{pmatrix} = \begin{pmatrix} e^{-j2\pi\alpha(1-1)\tau_1} & e^{-j2\pi\alpha(1-1)\tau_1} & \dots & e^{-j2\pi\alpha(1-1)\tau_1} \\ e^{-j2\pi\alpha(2-1)\tau_1} & e^{-j2\pi\alpha(2-1)\tau_1} & \dots & e^{-j2\pi\alpha(2-1)\tau_1} \\ \vdots & \vdots & \ddots & \vdots \\ e^{-j2\pi\alpha(M-1)\tau_1} & e^{-j2\pi\alpha(M-1)\tau_1} & \dots & e^{-j2\pi\alpha(M-1)\tau_1} \end{pmatrix} \begin{pmatrix} R_{s_1 s_1}^\alpha(\tau) \\ R_{s_2 s_2}^\alpha(\tau) \\ \vdots \\ R_{s_N s_N}^\alpha(\tau) \end{pmatrix}, \quad (8)$$

记作

$$R_s^\alpha(\tau) = A_2^\alpha R_s^\alpha(\tau), \quad (9)$$

再由不同的时延 τ 构造 $M \times L$ 维的数据矩阵

$$R(\alpha) = [R_s^\alpha(0), R_s^\alpha(T_s), \dots, R_s^\alpha((L-1)T_s)]. \quad (10)$$

对于矩阵 $R(\alpha)$ 使用公式(5)的矢量奇异值法分解,得到信号子空间和噪声子空间,再使用信号子空间和噪声子空间的正交性,得出关于波达方向角的谱峰,从而得到波达方向角度信息。

2 本文算法

2.1 卷积神经网络模型

卷积神经网络采用分层的思想,不同的层可以提取不同的结构信息,卷积神经网络主要是由卷积层、池化层和全连接层构成。

神经网络使用线性激活函数 ReLU 加快神经网络的收敛速度,输出层采用 softmax 函数。本文算法将由线性阵列接收的信号经过 SC-SSF 算法后得到的矩阵作为神经网络的输入,神经网络的输出则是将波达方向角 $[-90^\circ, 90^\circ]$ 平均分成 181 份的角度标签值。每一个角度随机生成 5 000 个训练集和 2 000 个测试集,并进行神经网络的训练。卷积神经网络的网络结构如图 1 所示。

神经网络泛化能力的好坏可以用损失函数来衡量,使用均方误差来定义误差函数

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2, \quad (11)$$

其中 y_i 表示神经网络的输出, \hat{y}_i 表示监督数据即波达方向角的标签值,神经网络通过反向传

播来更新权值,使神经网络总的误差函数达到最小值,从而达到精确估计的效果。




图1 卷积神经网络的结构

Fig. 1 Structure of convolutional neural network

2.2 本文算法模型

本文算法首先由线性等距阵列接收信号,其次由接收数据和不同的循环频率求出循环自相关,然后由式(10)构造出数据矩阵 $R(\alpha)$,并使用矢量奇异值法将 $R(\alpha)$ 分解,接着将分解后的矩阵作为神经网络的输入,最后得到波达角度的估计值。整体结构由 7 个部分组成,分别是线性等距阵列、SC-SSF 算法、SVD 算法、卷积层、池化层、全连接层组成和 softmax 输出层组成。算法流程图如图 2 所示。




图2 本文算法流程图

Fig. 2 Flow chart of the algorithm proposed this paper

2.3 数据集的获取

数据集是在 MATLAB 环境下生成均匀线阵模型,天线阵元数目为 M ,选取相干的 BPSK 信号作为相干循环平稳信号作为信号源,相干 BPSK 信号的频率 $f_c = 3 \times 10^8$ Hz,相干 BPSK 信号的循环频率 $\alpha = 2f_c = 6 \times 10^8$ Hz,来波数目为 4,入射角度 $\theta = [31^\circ, 68^\circ, 22^\circ, \bar{\theta}]$,其中 $\bar{\theta}$ 是在一定的信噪比下遍历 $[-90^\circ, 90^\circ]$,步长为 1° ,先由式(2)生成数据矩阵,再由式(7)到式(10)得到互相关矩阵,然后通过式(5)将互相关矩阵进行奇异值分解,分解后的矩阵 Y 作为神经网络的输入,由于矩阵 Y 为复数矩阵,将矩阵 Y 向量化和归一化处理为 $\bar{r} = [\text{Real}(\bar{r}^T), \text{Imag}(\bar{r}^T)]^T / \|\bar{r}\|_2$,其中 $\|\bar{r}\|_2$ 表示 \bar{r} 的 2 范数。由于其中噪声为加性高斯白噪声,加

入高斯白噪声可以提高模型的泛化能力,有效地避免过拟合现象的出现。由此构建训练集 $D_{\text{train}} = \{(\bar{\mathbf{r}}^1, \theta^1), (\bar{\mathbf{r}}^2, \theta^2), \dots, (\bar{\mathbf{r}}^D, \bar{\theta}^D)\}$, 其中 D 表示训练样本数。当训练集数目不够时,导致神经网络无法收敛,从而无法准确识别波达角度,因此每一个角度生成 5 000 个训练集和 2 000 个测试集。

3 仿真结果分析

为了验证结合了卷积神经网络的相干循环平稳信号算法的估计性能,将 SC-SSF 算法、矢量奇异值法(SVD)、前向空间平滑算法(Forward Spatial Smoothing, FSS)、确定性最大似然估计法(Deterministic Maximum Likelihood, DML)与本文算法的估计性能进行对比。

估计的性能使用均方根误差(RMSE)来衡量

$$\text{RMSE} = \sqrt{\frac{1}{K} \sum_{k=1}^K (\hat{\theta}_k - \theta)^2}, \quad (12)$$

其中 K 为实验的次数, $\hat{\theta}_k$ 为角度的估计值, θ 为角度的真实值。

选取 4 路相干的 BPSK 信号作为输入信号,第一路方向角为 31° ,第二路方向角为 68° ,第三路方向角设置为 22° ,第四路为估计的方向角 $\bar{\theta}$,即 $\theta = [31^\circ, 68^\circ, 22^\circ, \bar{\theta}]$,噪声为加性高斯白噪声,相干 BPSK 信号的频率 $f_c = 3 \times 10^8 \text{ Hz}$,相干 BPSK 信号的循环频率 $\alpha = 2f_c = 6 \times 10^8 \text{ Hz}$ 。

选定的阵元数目为 10,阵元间距为半波长,卷积神经网络的搭建基于 Matlab 深度学习工具箱,训练的损失函数基于式(11)的 MSE,激活函数使用 ReLU 函数加快模型的收敛。Batchsize 大小为 180,一个 epoch 集中有 Batchsize 个样本,一共训练 5 000 个 epochs,初始卷积神经网络的学习率为 0.01,设置动态下降学习率,当神经网络训练损失函数连续 10 个 epochs 不下降时,学习率减少 90%,这样可以加快神经网络模型的收敛。

选取一次典型的识别结果如图 3 所示。从图中可以看出识别结果是一条平滑的直线,误差主要集中在 $\pm 90^\circ$ 附近,忽略掉在 $\pm 90^\circ$ 处的误差,该算法的识别准确率接近 100%。

实验 1:在信噪比、天线阵元数固定的条件下,改变卷积神经网络结构,比较不同网络结




图 3 角度识别结果

Fig. 3 Results of angle recognition

构下角度估计的效果。

考虑四个窄带远场信号,第一路方向角为 31° ,第二路方向角为 68° ,第三路方向角设置为 22° ,第四路为估计的方向角 $\bar{\theta}$,其中 $\bar{\theta}$ 是在该信噪比下遍历 $[-90^\circ, 90^\circ]$,步长为 1° ,每一个角度生成 100 个数据样本并将样本输入到训练好的网络中,获得神经网络输出的角度标签值 $\bar{\theta}$ 。识别正确率的公式为:

$$\text{识别正确率} = \frac{\text{识别正确个数}}{\text{识别总数}}, \quad (13)$$

信噪比设置为 -10 dB ,天线阵元数为 10,采用本文算法仿真结果如图 4 所示。

从图 4 可知,卷积层层数太多和太少时都会影响到算法的识别正确率,并且采用了池化层的卷积神经网络总体的识别正确率要低于没有采用池化层的神经网络,这是因为在池化的过程中池化层删去了一些矩阵的信息,导致循环相关矩阵秩的亏损。因此可以采用 4 层卷积神经网络不加池化层的网络结构来进行 DOA 估计。

实验 2:在天线阵元数固定的条件下,比较不同算法在不同信噪比下的估计效果。

天线阵列阵元数目设置为 10,改变 BPSK 信号的信噪比,比较 SC-SSF 算法、矢量奇异值法(SVD)、前向空间平滑算法(FSS)、确定性最大似然估计法(DML)和本文算法(Convolutional Neural Network, CNN)的均方根误差大小,其中 FSS 算法在信噪比小于 0 dB 的情况下计算出的角度与真实值偏离太大,因此信噪比小于 10 时 FSS 算法失效,仿真结果如图 5 所示。




图4 不同网络结构识别正确率对比图

注:图中实线为神经网络删去池化层进行训练后的识别正确率,虚线为神经网络添加池化层后的识别准确率,识别正确率越大说明神经网络的泛化效果越好。

Fig. 4 Comparison chart of recognition accuracy of different network structures

Note: In this figure, the solid line shows the recognition accuracy after deleting the pool layer, and the dotted line shows the recognition accuracy after adding the pool layer. The greater the recognition accuracy, the better the generalization effect of the neural network.

由图5可知,本文的算法在低信噪比的条件下的识别精度远高于SC-SSF算法,随着信噪比的增加,SC-SSF算法的精确度逐渐与本文算法接近。

实验3:在信噪比固定的条件下,比较不同阵元数下的估计效果。

比较SC-SSF算法、矢量奇异值法(SVD)、前向空间平滑算法(FSS)、确定性最大似然估计法(DML)和本文算法(CNN)的均方根误差大小,由于SC-SSF算法和SVD算法对天线阵元数目有一定的要求,重构矩阵的行数和列数必须都大于信号元数目,即 $m > N, p > N$,否则无法将所得的矩阵奇异值分解,本文中的信源为4路相干信号源,因此天线阵元数目需要大于等于10,在天线阵元数目小于10的情况下SC-SSF算法失效。当阵元数目小于10时,FSS算法无法准确判断来波数目,因此阵元数目小于10时,FSS算法失效。信噪比设置为10 dB,仿真结果如图6所示。

从图6可以看出本文的算法不受阵元数目的限制,在小阵元数的情况下也有着较高的识




图5 不同信噪比下算法均方根误差对比图

注:图中算法依次为矢量奇异值法(SVD)、本文深度学习算法、前向空间平滑算法(FSS)、确定性最大似然估计法(DML)和子空间拟合算法(SC-SSF),随着信噪比的增加,真实角度和预测角度的均方根误差越小,识别的结果越精确。

Fig. 5 Comparison chart of root mean square error of algorithms under different signal-to-noise ratios

Note: The algorithms in the figure are singular value decomposition algorithm (SVD), this paper's deep learning algorithm, forward spatial smoothing algorithm (FSS), deterministic maximum likelihood algorithm (DML) and spectral correlation signal-subspace fitting (SC-SSF) algorithm. With the increase of signal-to-noise ratio, the root mean square error is smaller and the recognition result is more accurate.

别精度,且增加阵元数目对识别精度的提升不大。

实验4:在其他条件一定的情况下,比较不同算法的估计所需时间。

信噪比设置为-10 dB,天线阵元数为10,先计算使用SSF算法、SVD算法、FSS算法和DML算法识别从-85°到85°中间间隔10°共18个角度所需的总时间,再计算使用本文算法利用已经完成训练的神经网络识别一个测试集内5000个角度所用的总时间,仿真结果如表1所示。

从表1可以看出,SSF算法、SVD算法、FSS算法和DML算法识别所需的时间远远高于本文的算法,本文的算法使用训练好的网络模型,单次识别的时间可以忽略不计,因此本文算法可以对大量的数据进行实时和准确的处理。

4 结论

本文针对循环平稳信号在低信噪比和相

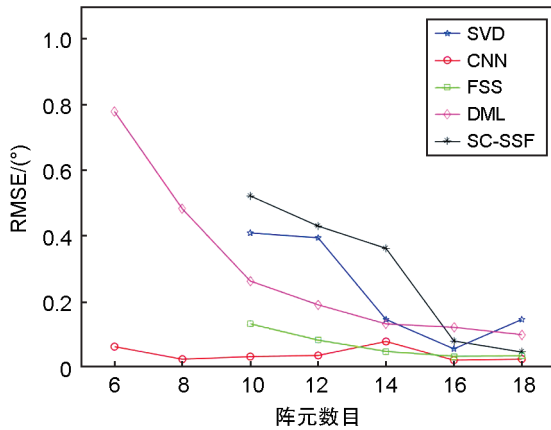


图6 不同阵元下算法均方根误差对比图

注:图中算法依次为矢量奇异值法(SVD)、本文深度学习算法、前向空间平滑算法(FSS)、确定性最大似然估计法(DML)和子空间拟合算法(SC-SSF),随着阵元数目的增加,真实角度和预测角度的均方根误差越小,识别的结果越精确,同时计算量也越大。

Fig. 6 Comparison chart of root mean square error of algorithms under different array elements

Note: The algorithms in the figure are singular value decomposition algorithm (SVD) and this paper's deep learning algorithm, forward spatial smoothing algorithm (FSS), deterministic maximum likelihood method (DML) and spectral correlation signal-subspace fitting algorithm (SC-SSF). With the increase of the number of elements, the root mean square error is smaller and the computation is larger.

表1 程序运行时间

Table 1 Running time of programs

算法	总时间/s	时间/s
SC-SSF	2.019 6	0.112 2
FSS	4.606 2	0.255 9
SVD	8.551 8	0.475 1
DML	3.497 4	0.194 3
本文算法	0.240 8	5.51×10^{-6}

干的情况下估计精度不高的问题,将传统的循环平稳算法与深度学习算法相结合,提出了一种解相干的循环平稳信号的估计算法。首先针对不同循环平稳信号的不同循环频率建立起循环相关的函数矩阵,再将矩阵奇异值分解,将分解后的矩阵作为神经网络的输入,从而实现高精度的波达方向估计。仿真结果表明本文算法在相干循环平稳信号下具有较小的均方根误差,角度估计所需的时间也大幅度地缩小。

参考文献:

- [1] 王永良. 空间谱估计理论与算法[M]. 北京: 清华大学出版社, 2004: 3-13.
WANG Y L. Theory and Algorithm of Spatial Spectrum Estimation[M]. Beijing: Tsinghua University Press, 2004: 3-13.
- [2] PAN J J, SUN M, WANG Y D, *et al.* An Enhanced Spatial Smoothing Technique with ESPRIT Algorithm for Direction of Arrival Estimation in Coherent Scenarios[J]. *IEEE Trans Signal Process*, 2020, **68**: 3635-3643. DOI: 10.1109/TSP.2020.2994514.
- [3] STOICA P, SHARMAN K C. Maximum Likelihood Methods for Direction-of-arrival Estimation[J]. *IEEE Trans Acoust Speech Signal Process*, 1990, **38**(7): 1132-1143. DOI: 10.1109/29.57542.
- [4] GONG P, ZHANG X F, AHMED T. Computationally Efficient DOA Estimation for Coprime Linear Array: a Successive Signal Subspace Fitting Algorithm[J]. *Int J Electron*, 2020, **107**(8): 1216-1238. DOI: 10.1080/00207217.2020.1726485.
- [5] YANG H C, WANG P Y, YE Z F. Robust Adaptive Beamforming via Covariance Matrix Reconstruction and Interference Power Estimation[J]. *IEEE Commun Lett*, 2021, **25**(10): 3394-3397. DOI: 10.1109/LCOMM.2021.3103208.
- [6] BINGBING QI, LI W. An Improved Multiple-Toeplitz Matrices Reconstruction Algorithm for DOA Estimation of Coherent Signals[J]. *Radio Engineering*, 2021, **30**(3): 532-539. DOI: 10.13164/re.2021.0532.
- [7] CADZOW J A, KIM Y S, SHIUE D C. General Direction-of-arrival Estimation: A Signal Subspace Approach[J]. *IEEE Trans Aerosp Electron Syst*, 1989, **25**(1): 31-47. DOI: 10.1109/7.18659.
- [8] 高世伟, 保铮. 利用数据矩阵分解实现对空间相关信号源的超分辨率处理[J]. *通信学报*, 1988, **9**(1): 6-15.
GAO S W, BAO Z. Using Data Matrix Decomposition to Realize Super-resolution Processing of Spatially Correlated Signal Sources[J]. *J China Institute Commun*, 1988, **9**(1): 6-15.
- [9] SHAMSUNDER S, GIANNAKIS G B. Signal Selective Localization of nonGaussian Cyclostationary Sources[J]. *IEEE Trans Signal Process*, 1994, **42**(10): 2860-2864. DOI: 10.1109/78.324756.
- [10] GARDNER W. Spectral Correlation of Modulated Signals: Part I: Analog Modulation[J]. *IEEE Trans Commun*, 1987, **35**(6): 584-594. DOI: 10.1109/tcom.1987.1096820.
- [11] GARDNER W A. Exploitation of Spectral Redundancy in Cyclostationary Signals[J]. *IEEE Signal Process Mag*, 1991, **8**(2): 14-36. DOI: 10.1109/79.81007.

- [12] GARDNER W, BROWN W, CHEN C K. Spectral Correlation of Modulated Signals: Part II: Digital Modulation[J]. *IEEE Trans Commun*, 1987, **35**(6): 595–601. DOI: 10.1109/tcom.1987.1096816.
- [13] 金梁, 殷勤业, 汪仪林. 广义谱相关子空间拟合 DOA 估计原理[J]. *电子学报*, 2000, **28**(1): 60–63. DOI: 10.3321/j.issn: 0372-2112.2000.01.016.
JIN L, YINQIN Y, WANG Y L. The Principle of Generalized Spectral Correlation Signal Subspace Fitting for DOA Estimation[J]. *Acta Electron Sin*, 2000, **28**(1): 60–63. DOI: 10.3321/j.issn: 0372-2112.2000.01.016.
- [14] 余黎煌, 刘平凡, 张石, 等. 一种高精度低复杂度的改进 Root-MUSIC 算法[J]. *东北大学学报(自然科学版)*, 2022, **43**(4): 457–462. DOI: 10.12068/j.issn.1005-3026.2022.04.001.
SHE L H, LIU P F, ZHANG S, *et al.* An Improved Root-MUSIC Algorithm with High Precision and Low Complexity[J]. *J Northeast Univ Nat Sci Ed*, 2022, **43**(4): 457–462. DOI: 10.12068/j.issn.1005-3026.2022.04.001.
- [15] YOU G H, QIU T S, YANG J. A Novel DOA Estimation Algorithm of Cyclostationary Signal Based on UCA in Impulsive Noise[J]. *AEU Int J Electron Commun*, 2013, **67**(6): 491–499. DOI: 10.1016/j.aeue.2012.11.006.
- [16] 张晋, 王大鸣, 崔维嘉, 等. 基于互质阵的循环平稳信号低复杂度欠定 DOA 估计算法[J]. *计算机应用研究*, 2021, **38**(7): 2060–2065. DOI: 10.19734/j.issn.1001-3695.2020.09.0234.
ZHANG J, WANG D M, CUI W J, *et al.* Low-complexity Underdetermined DOA Estimation Algorithm for Cyclostationary Signals Based on Coprime Array[J]. *Appl Res Comput*, 2021, **38**(7): 2060–2065. DOI: 10.19734/j.issn.1001-3695.2020.09.0234.
- [17] 谢前朋, 王伦文. 基于连续稀疏恢复循环平稳信号的 DOA 估计[J]. *现代雷达*, 2017, **39**(1): 32–39. DOI: 10.16592/j.cnki.1004-7859.2017.01.007.
XIE Q P, WANG L W. DOA Estimation Method for Cyclostationary Signals Based on Continuous Sparse Reconstruction[J]. *Mod Radar*, 2017, **39**(1): 32–39. DOI: 10.16592/j.cnki.1004-7859.2017.01.007.
- [18] DONG C, LOY C C, HE K M, *et al.* Image Super-resolution Using Deep Convolutional Networks[J]. *IEEE Trans Pattern Anal Mach Intell*, 2015, **38**(2): 295–307. DOI: 10.1109/TPAMI.2015.2439281.
- [19] LIU Z M, ZHANG C W, YU P S. Direction-of-arrival Estimation Based on Deep Neural Networks with Robustness to Array Imperfections[J]. *IEEE Trans Antennas Propag*, 2018, **66**(12): 7315–7327. DOI: 10.1109/TAP.2018.2874430.
- [20] ELBIR A M. DeepMUSIC: Multiple Signal Classification via Deep Learning[J]. *IEEE Sens Lett*, 2020, **4**(4): 1–4. DOI: 10.1109/LESENS.2020.2980384.
- [21] 葛晓凯, 胡显智, 戴旭初. 利用深度学习方法的相干源 DOA 估计[J]. *信号处理*, 2019, **35**(8): 1376–1384. DOI: 10.16798/j.issn.1003-0530.2019.08.012.
GE X K, HU X Z, DAI X C. DOA Estimation for Coherent Sources Using Deep Learning Method[J]. *J Signal Process*, 2019, **35**(8): 1376–1384. DOI: 10.16798/j.issn.1003-0530.2019.08.012.
- [22] 朱哈归, 冯存前, 冯为可, 等. 一种深度学习稀疏单快拍 DOA 估计方法[J]. *信号处理*, 2022, **38**(10): 2114–2123. DOI: 10.16798/j.issn.1003-0530.2022.10.012.
ZHU H G, FENG C Q, FENG W K, *et al.* A Deep Learning Approach for Sparse Single Snapshot DOA Estimation[J]. *J Signal Process*, 2022, **38**(10): 2114–2123. DOI: 10.16798/j.issn.1003-0530.2022.10.012.
- [23] 余佳润, 王亚峰. 一种低信噪比下基于深度学习的 DoA 估计方法[J]. *北京邮电大学学报*, 2022, **45**(6): 115–121. DOI: 10.13190/j.jbupt.2022-157.
YU J R, WANG Y F. A Deep Learning-based DoA Estimation Method in Low SNR[J]. *J Beijing Univ Posts Telecommun*, 2022, **45**(6): 115–121. DOI: 10.13190/j.jbupt.2022-157.