

基于复值卷积降噪自编码器去噪的矢量水听器 DOA估计方法

任晶, 谭秀辉, 白艳萍*, 王宏妍, 续婷, 程蓉

(中北大学 数学学院, 山西 太原 030051)

摘要: 针对现有的基于实值卷积神经网络估计矢量水听器波达方向(Direction of Arrival, DOA)对阵列接收到信号的相位特征提取不充分的缺点, 提出了一种基于复值卷积降噪自编码器(Complex-Valued Convolutional Denoising Autoencoder, CV-CDAE)和复值卷积神经网络(Complex-Valued Convolutional Neural Network, CV-CNN)联合的矢量水听器DOA估计方法CV-CDAE-CNN。首先, 将矢量水听器接收信号的复值协方差矩阵输入CV-CDAE模块去除噪声, 之后, 将去噪后的样本输入CV-CNN进行分类。其中, CV-CNN在下采样前使用双尺度膨胀卷积增大特征图的感受野, 缓解下采样带来的信息损失。通过CV-CDAE去噪以及CV-CNN独特的处理复值方式实现角度分类, 进而得到DOA估计值。仿真结果表明, 所提出方法与现有的CV-CNN相比, 在低信噪比或有限快拍数下泛化能力更强, DOA估计准确率更高, 且具有更高的估计精度。

关键词: 波达方向估计; 复值卷积降噪自编码器; 复值卷积神经网络; 双尺度膨胀卷积; 矢量水听器

中图分类号: TN911.7

文献标识码: A

doi: 10.62756/csjs.1671-7449.2025058

引用格式: 任晶, 谭秀辉, 白艳萍, 等. 基于复值卷积降噪自编码器去噪的矢量水听器DOA估计方法[J]. 测试技术学报, 2025, 39(4): 475-482.

REN Jing, TAN Xiuhui, BAI Yanping, et al. Vector hydrophone DOA estimation method based on complex-valued convolutional denoising autoencoder denoising[J]. Journal of Test and Measurement Technology, 2025, 39(4): 475-482.

Vector Hydrophone DOA Estimation Method Based on Complex-Valued Convolutional Denoising Autoencoder Denoising

REN Jing, TAN Xiuhui, BAI Yanping*, WANG Hongyan, XU Ting, CHENG Rong

(School of Mathematics, North University of China, Taiyuan 030051, China)

Abstract: To address the existing shortcomings of the real valued convolutional neural network based estimation of vector hydrophone direction of arrival(DOA) that does not adequately extract the phase features of the signals received by the array, a vector hydrophone DOA estimation method (CV-CDAE-CNN) based on combination of complex-valued convolutional denoising autoencoder(CV-CDAE) and complex-valued convolutional neural network(CV-CNN) is proposed. The complex-valued covariance matrix of the received signals from the vector hydrophone are firstly input into the CV-CDAE module to remove the noise, and then the denoised samples are input into the CV-CNN for classification. The double-scale dilation convolution is used to increase the receptive field of the feature map of CV-CNN before down-

收稿日期: 2024-10-28

基金项目: 国家自然科学基金资助项目(61774137); 山西省基础研究计划资助项目(202103021224195, 202103021224212, 202103021223189, 20210302123019); 山西省回国留学人员科研资助项目(2020-104, 2021-108)

作者简介: 任晶(2000-), 女, 硕士生, 主要从事信号处理及深度学习研究。E-mail: 13467212257@163.com。

* **通信作者:** 白艳萍(1962-), 女, 教授, 博士, 主要从事现代优化算法理论及应用研究。E-mail: baiyp666@163.com。

sampling and to mitigate the information loss caused by down-sampling. Angle classification is realized by CV-CDAE denoising and CV-CNN's unique way of dealing with complex values, and then DOA estimates are obtained. Simulation results show that the proposed method in this paper has stronger generalization ability, higher DOA estimation accuracy and higher estimation accuracy compared with the existing CV-CNN at low signal-to-noise ratio or limited number of snapshots.

Key words: direction-of-arrival estimation; complex-valued convolutional denoising autoencoder; convolutional neural network; double-scale dilation convolution; vector hydrophone

0 引言

波达方向(Direction of Arrival, DOA)估计在众多科学和技术领域中占据着举足轻重的地位^[1-3]。早期的DOA估计算法主要围绕波束形成技术,如传统的波束形成算法^[4],它利用每个阵列元素接收到的空间数据,而不是传统的时域数据。但该算法对在一个波束宽度内的目标无法做出准确分辨。之后, Schmidt^[5]提出了子空间类最具有代表性的算法——多重信号分类算法,该算法使DOA估计的研究得到了突飞猛进的发展。Roy等^[6]提出了通过旋转不变性技术算法估计信号参数,该方法利用子空间之间的旋转不变性进行DOA估计。许多学者基于这两种子空间类算法进行了改进^[7-9],尽管实现了超分辨率的估计技术,但在处理有限拍数据时,精确构建空间谱仍面临挑战。在子空间拟合类DOA估计算法中,具有代表性的是最大似然算法^[10],该方法通过求解非线性方向估计似然函数获得空间谱,但运算量较大。随着稀疏表示技术的发展,有学者将DOA估计问题转化为稀疏信号重构问题,提出了许多基于稀疏表示的DOA估计方法^[11],但稀疏表示类方法也存在网格划分难等问题。

近年来,卷积神经网络(Convolutional Neural Network, CNN)在图像和信号处理领域取得了显著进展^[12-14],有学者将其应用于DOA估计中。如Liu等^[15]提出双通道CNN模型,将信号协方差矩阵的实部和虚部作为网络的输入信号来估计DOA;Papa-georgiou等^[16]引入三通道CNN,使用样本协方差矩阵估计DOA,其在低信噪比条件下的DOA估计性能有了显著提高;Liu等^[17]将稀疏先验应用于构建深度卷积网络,利用稀疏性先验提高了DOA估计性能。直接采用实值处理方法会不可避免地损失信号的相位信息,而对于复值CNN(Complex-Valued CNN, CV-CNN)^[18],在处理信号时同时考虑到相位和幅度信息,比实值CNN获得的信息更多,其DOA

估计精度比实值CNN高^[19]。基于CNN的DOA估计方法在信噪比较低时,分类效果会受到较大的影响,导致DOA估计精度降低,因此,对信号进行去噪是有必要的。而卷积降噪自编码器(Convolutional Denoising Auto Encoder, CDAE)是一种有效的去噪模块^[20],该模型可以减少特征维度、消除噪声并提取关键向量。

在此基础上,本文提出将CV-CDAE与CV-CNN结合的矢量水听器阵列的DOA估计模型。将矢量水听器阵列接收信号的复值协方差矩阵输入CV-CDAE,该模块经过训练可以建立带噪样本和原始样本之间的映射,对样本进行去噪,之后,将去噪后的样本输入CV-CNN中处理DOA估计问题,在CV-CNN中利用双尺度膨胀卷积增大特征图的感受野,缓解下采样带来的信息损失问题。结果表明,在低信噪比或有限快拍数情况下,使用本文方法比CV-CNN算法^[19]的DOA估计精度有所提高。

1 基本理论

1.1 矢量水听器阵列信号模型

假设矢量水听器阵元个数为 M ,间距为 d ,有 K 个远场窄带信号源 $s_k(t)$,其入射角为 $\theta_k, k=1, 2, \dots, K$,在仅考虑水平方位角的情况下,矢量水听器均匀线阵的信号接收模型如图1所示。

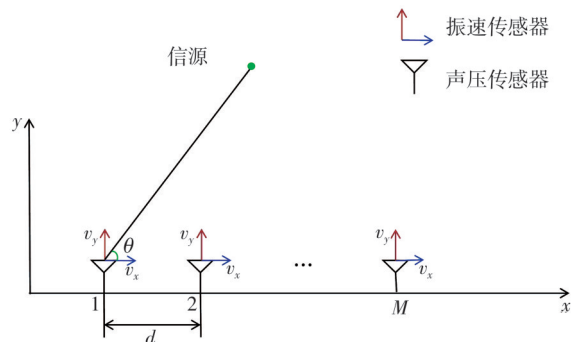


图1 矢量水听器均匀线阵信号接收模型

Fig. 1 Uniform linear array signal reception model for vector hydrophone

在图 1 中, v_x, v_y 为振速矢量 $\mathbf{v}(t)$ 沿 x 轴和 y 轴的分量, t 时刻声压标量 $p(t)$ 和振速矢量 $\mathbf{v}(t)$ 有如下关系

$$\mathbf{v}(t) = [\cos\theta \cdot \boldsymbol{\xi} + \sin\theta \cdot \boldsymbol{\eta}] p(t), \quad (1)$$

式中: $\boldsymbol{\xi}, \boldsymbol{\eta}$ 为正交的坐标单位向量。声压 $p(t)$ 与 v_x, v_y 的关系为

$$\begin{cases} p(t) = s(t), \\ v_x(t) = p(t) \cos\theta, \\ v_y(t) = p(t) \sin\theta, \end{cases} \quad (2)$$

式中: $s(t)$ 为接收到的标量信号, 因此, 单个矢量水听器的输出为

$$\mathbf{x}(t) = [p(t), v_x(t), v_y(t)]^T = s(t) [1, \cos\theta, \sin\theta]^T. \quad (3)$$

将矢量水听器阵列输出写为矩阵形式, 即

$$\mathbf{X}(t) = \mathbf{A}(\theta) \mathbf{S}(t) + \mathbf{N}(t), \quad (4)$$

式中: $\mathbf{X}(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T$ 为阵列输出矩阵, $\mathbf{X}(t) \in \mathbb{C}^{3M \times 1}$; $\mathbf{S}(t) = [s_1(t), s_2(t), \dots, s_K(t)]^T$ 为接收到的信号矢量, $\mathbf{S}(t) \in \mathbb{C}^{K \times 1}$; $\mathbf{N}(t) = [n_1(t), n_2(t), \dots, n_M(t)]^T$ 为噪声矢量, $\mathbf{N}(t) \in \mathbb{C}^{3M \times 1}$; $\mathbf{A}(\theta) \in \mathbb{C}^{3M \times K}$ 为信号导向矩阵, 定义为

$$\mathbf{A}(\theta) = [\mathbf{a}(\theta_1) \otimes \mathbf{u}_1, \mathbf{a}(\theta_2) \otimes \mathbf{u}_2, \dots, \mathbf{a}(\theta_K) \otimes \mathbf{u}_K], \quad (5)$$

其中,

$$\mathbf{a}(\theta_k) = [a_1(\theta_k), a_2(\theta_k), \dots, a_M(\theta_k)]^T = \left[1, e^{-j2\pi d \frac{\cos\theta_k}{\lambda}}, \dots, e^{-j2\pi d(M-1) \frac{\cos\theta_k}{\lambda}} \right]^T, \quad (6)$$




图 3 CDAE 示意图

Fig. 3 Schematic of CDAE

1.3 CV-CNN

CV-CNN 的优势是能同时捕捉信号的幅度与相位信息, 网络的参数和输入信号均为复数形式, 这要求网络模型设计时需制定复数运算规则, 如复值卷积、批归一化等运算。

1.3.1 复值卷积

定义复数输入为 $\mathbf{w} = \mathbf{p} + i\mathbf{q}$, 复数卷积核为 $\mathbf{W} = \mathbf{P} + i\mathbf{Q}$, \mathbf{W} 与 \mathbf{w} 进行卷积, 具体表示为

$\mathbf{u}_k = [1, \cos\theta_k, \sin\theta_k]^T$; \otimes 为克罗内克积; λ 为入射信源的波长。

在实际应用中, 可以根据阵列输出的有限的 T 组数据, 估计阵列输出的协方差矩阵 $\tilde{\mathbf{R}}_{xx}$ 为

$$\tilde{\mathbf{R}}_{xx} = \frac{1}{T} \sum_{t=1}^T \mathbf{X}(t) \mathbf{X}^H(t). \quad (7)$$

1.2 CDAE 模型

降噪自编码器 (Denoising AutoEncoder, DAE) 的主要特点是在输入数据中引入噪声, 并从含有噪声的输入中重建出原始的无噪声数据^[21], 它是自编码器 (AutoEncoder, AE) 的扩展^[22], 能将数据压缩到低维空间, 实现非线性降维。在训练过程中, AE 的输出层旨在重现原始数据, 而隐藏层输出则为数据的压缩表示。通常情况下, DAE 由全连接层构成, 结构如图 2 所示。而 CDAE 是在 DAE 的基础上引入卷积层和池化层, 能够处理二维数据, 其结构如图 3 所示。

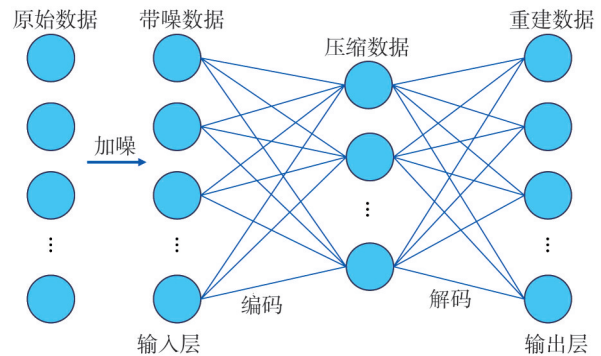


图 2 DAE 示意图

Fig. 2 Schematic of DAE

$$\mathbf{W} * \mathbf{w} =$$

$$(\mathbf{P} * \mathbf{p} - \mathbf{Q} * \mathbf{q}) + i(\mathbf{Q} * \mathbf{p} + \mathbf{P} * \mathbf{q}). \quad (8)$$

矩阵表示为

$$\begin{bmatrix} \text{Re}(\mathbf{W} * \mathbf{w}) \\ \text{Im}(\mathbf{W} * \mathbf{w}) \end{bmatrix} = \begin{bmatrix} \mathbf{P} & -\mathbf{Q} \\ \mathbf{Q} & \mathbf{P} \end{bmatrix} * \begin{bmatrix} \mathbf{p} \\ \mathbf{q} \end{bmatrix}, \quad (9)$$

式中: $\text{Re}(\mathbf{W} * \mathbf{w})$ 和 $\text{Im}(\mathbf{W} * \mathbf{w})$ 分别为卷积后特征图的实部和虚部; $*$ 为卷积运算。

1.3.2 复值批归一化

批归一化是通过归一化每个小批量数据的分

布,加速神经网络的训练过程并提高模型的稳定性。复数批归一化的形式为

$$BN(\hat{v}) = \gamma \hat{v} + \beta, \quad (10)$$

式中: γ 和 β 为可学习的参数; \hat{v} 为 v 的标准化形式,表示为

$$\hat{v} = \frac{(v - E(v))}{\sqrt{V}}, \quad (11)$$

式中: v 为输入的复数数据; $E(v)$ 为 v 的均值; V 为 v 的协方差矩阵。协方差矩阵的计算方式为

$$V = \begin{bmatrix} V_{rr} & V_{ri} \\ V_{ir} & V_{ii} \end{bmatrix} = \begin{bmatrix} \text{Cov}(\text{Re}(v), \text{Re}(v)) & \text{Cov}(\text{Re}(v), \text{Im}(v)) \\ \text{Cov}(\text{Im}(v), \text{Re}(v)) & \text{Cov}(\text{Im}(v), \text{Im}(v)) \end{bmatrix}. \quad (12)$$

1.3.3 复值激活函数

CV-CNN中最常使用的激活函数是CReLU,该方法将ReLU激活函数分别应用于复数的实部和虚部,实现了对复数数据的非线性激活处理,其表达式为

$$\text{CReLU}(s) = \text{ReLU}(\text{Re}(s)) + i\text{ReLU}(\text{Im}(s)), \quad (13)$$

式中: s 为经过ReLU激活函数前的复数数据。

2 基于CV-CDAE-CNN的矢量水听器DOA估计

本文提出的CV-CDAE-CNN网络结构如图4所示。将带噪声的复值协方差矩阵输入到CV-CDAE,单独训练CV-CDAE模块,在完成CV-CDAE模型的训练再联合训练CV-CDAE-CNN,即首先对样本进行去噪处理,然后,将去噪后的数据输入CV-CNN进行分类。




图4 CV-CDAE-CNN结构示意图

Fig. 4 Schematic diagram of CV-CDAE-CNN structure

2.1 CV-CDAE 模块

本文构建的CV-CDAE模块如图5所示。CV-CDAE是一种结合了CV-CNN和CDAE的模型,包含编码器(Encoder)和解码器(Decoder)。

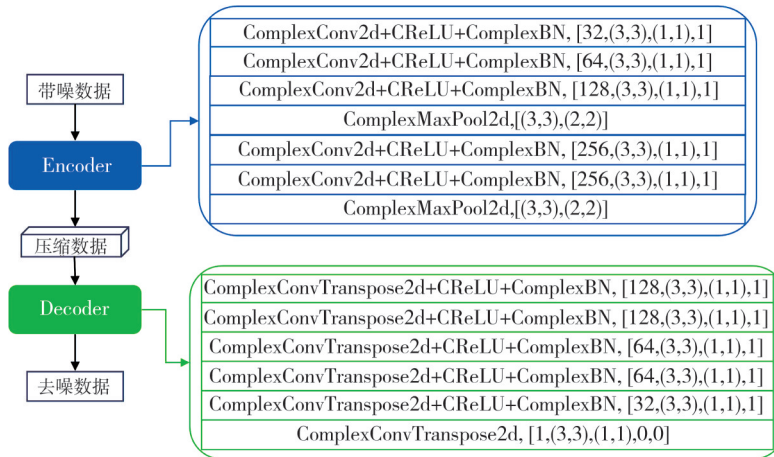


图5 CV-CDAE结构

Fig. 5 CV-CDAE structure

图5的Encoder中,输入为带噪声的复值协方差矩阵,包含5个复值卷积层(含复值批归一化和CReLU激活函数)对输入进行编码和2个最大池化层进行降噪,复值卷积层对应参数分别为[filters, kernel size, stride, padding],最大池化层对应参数为[kernel size, stride];在Decoder中,通过6个复值反卷积层来解码数据,前5层包含了复值批归一化和CReLU,以恢复输入样本大小和分辨率。为与CV-CNN结合, CV-CDAE的最后一层仅有复值反卷积,复值反卷

积层的参数分别为[filters, kernel size, stride, padding, outpadding]。

2.2 CV-CNN 模块

2.2.1 双尺度膨胀卷积

膨胀卷积通过在卷积核间填充零扩大感受野,使卷积操作覆盖更广的输入区域,该操作在保证特征图尺寸的同时增强信息捕获,减少信息丢失,但存在网格效应,导致有效覆盖区域离散,忽略了相

邻像素细节。为此,本文提出双尺度膨胀卷积,通过叠加 $D=D_1$ 和 $D=D_2$ 的膨胀卷积来提取不同尺

度信息,并融合这些特征。图 6 展示了卷积核大小为 3×3 时的 3 种双尺度膨胀卷积。




图 6 不同尺度下的双尺度膨胀卷积示意图

Fig. 6 Schematic of double-scale dilation convolution at different scales

图 7 展示了 3×3 卷积核的双尺度膨胀卷积过程。它是通过对输入特征图应用不同膨胀率的卷积来捕获多尺度空间信息,然后将这些特征图在对应空间位置上取像素平均值进行融合,最后,得到输出特征图。这种平均融合集成了多尺度特征,增强了模型对目标特征描述的丰富性和鲁棒性。




图 7 双尺度膨胀卷积过程

Fig. 7 Double-scale dilation convolution process

2.2.2 CV-CNN 模型

本文构建的 CV-CNN 如图 8 所示。将双尺度膨胀卷积放于第 2 个池化层前,多个实验证明将膨胀卷积放在第 2 个下采样开始的每个下采样的前一个

卷积层时,分类效果均好于原网络^[23]。本文矢量水听器个数为 10,故网络输入大小为 $30 \times 30 \times 1$,输入为 CV-CDAE 去噪后的复值协方差矩阵。

在复值卷积层中,首先,进行复值卷积;之后,使用复值批归一化对复值卷积的输出进行归一化;再通过 CReLU 激活函数,得到复值卷积层的输出。第 $l+1$ 个复值卷积层的具体运算为

$$X_i^{(l+1)} = \sum_{k=1}^K \omega_{ik}^{(l+1)} * O_k^l + b_i^{(l+1)} = \sum_{k=1}^K [\text{Re}(\omega_{ik}^{(l+1)}) * \text{Re}(O_k^l) - \text{Im}(\omega_{ik}^{(l+1)}) * \text{Im}(O_k^l)] + i \sum_{k=1}^K [\text{Im}(O_k^l) * \text{Re}(\omega_{ik}^{(l+1)}) + \text{Im}(\omega_{ik}^{(l+1)}) * \text{Re}(O_k^l)] + b_i^{(l+1)}, \quad (14)$$

$$O^{(l+1)} = \text{CReLU}(\text{BN}(X_i^{(l+1)})), \quad (15)$$

式中: $\text{BN}(\bullet)$ 为复值批归一化; $X_i^{(l+1)}$ 为第 $l+1$ 层的复值权重 $\omega_{ik}^{(l+1)}$ 与上一层的输出 O_k^l 进行卷积求和,再加上偏置 $b_i^{(l+1)}$ 的和; $O^{(l+1)}$ 为第 $l+1$ 层的输出。

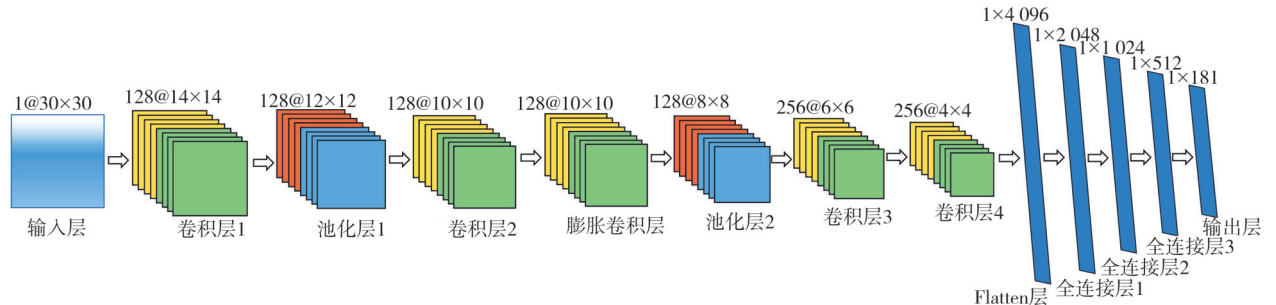


图 8 CV-CNN 结构

Fig. 8 CV-CNN structure

池化层中选择复值最大池化。通过计算池化窗口内复数元素的模值,选择模值最大的复数作为输出,有效保留重要特征并抑制噪声。

在复值全连接层利用复值 Dropout 防止过拟合现象。复值 Dropout 对实部和虚部进行联合 Dropout,确保实部和虚部同时设置为 0,以 30%

的概率随机为权重矩阵中的特定元素分配0。之后,为了将复值特征映射到实空间,将最后的复值全连接层输出的复数分类向量的实、虚部进行求和,再使用Sigmoid函数将输出向量映射到概率空间,最后,得到DOA估计值。

3 仿真与实验

为了验证双尺度膨胀卷积的有效性以及选取双尺度膨胀卷积中尺度的最佳组合,对比CV-CDAE-CNN1、CV-CDAE-CNN2、CV-CDAE-CNN3、CV-CDAE-CNN12、CV-CDAE-CNN13和CV-CDAE-CNN23算法的估计性能;然后,将最佳组合的双尺度膨胀卷积的CV-CDAE-CNN算法与CV-CNN算法^[19]进行比较,验证CV-CDAE模块的有效性。其中, CV-CDAE-CNN1算法是第二个池化前的卷积层为膨胀率为1的卷积, CV-CDAE-CNN12算法是第二个池化层的卷积层的膨胀率为1和2的双尺度膨胀卷积,以此类推。本文实验平台为64位Window10系统,运行在3.3 GHz的Intel(R) Core(TM) i7-5820K处理器和NVIDIA GeForce GTX 1080 Ti。

3.1 仿真设置

本文矢量水听器均匀线阵个数 $M=10$,网络输入的复值协方差矩阵大小为 $30 \times 30 \times 1$,阵元间距 d 为半波长,待估计信号源DOA范围 $G=[-90^\circ, 90^\circ]$,分辨率 $\Delta\theta=1^\circ$,即 $\tilde{\theta}=\{-90^\circ, -89^\circ, \dots, 90^\circ\}$,共181个网格点,信号源数目 $K=2$,因此,在每个信噪比下有 $D=16\ 290$ 个训练样本,信号中加入了高斯白噪声,信噪比设置区间为 $[-20\text{ dB}, 10\text{ dB}]$,信噪比步长 $\Delta\vartheta=5$,快拍数 $T=500$ 。在每个信噪比条件下有16 290个训练样本,共计114 030个训练样本。将网络的输入定义为 $\mathbf{X}=\{\mathbf{X}_{(1)}, \mathbf{X}_{(2)}, \dots, \mathbf{X}_{(D)}\}$ 。

接下来,对于每个 $\mathbf{X}_{(c)}$, $c=1, 2, \dots, D$,将角度对进行二值化,如角度对 $\mathbf{X}_{(c)}=\{-90^\circ, -89^\circ\}$ 对应的 181×1 的二值序列为 $\mathbf{y}_{(c)}=\{1, 1, 0, \dots, 0\}$,角度对对应的位置为1,其余为0。将二值化后的 $\mathbf{y}_{(c)}$ 作为网络标签。因此,数据集 $\mathcal{D}=\{(\mathbf{X}_{(1)}, \mathbf{y}_{(1)}), (\mathbf{X}_{(2)}, \mathbf{y}_{(2)}), \dots, (\mathbf{X}_{(D)}, \mathbf{y}_{(D)})\}$,对数据集 \mathcal{D} 进行划分。实验中使用均方根误差(RMSE)来评价算法性能,定义为

$$RMSE = \sqrt{\frac{1}{HK} \sum_{k=1}^K \sum_{m=1}^H (\theta_k^{(h)} - \hat{\theta}_k^{(h)})^2}, \quad (16)$$

式中: K 为信号源个数; H 为蒙特卡洛实验次数; $[\theta_1^{(h)}, \theta_2^{(h)}, \dots, \theta_k^{(h)}]^T$ 为DOA真实值; $[\hat{\theta}_1^{(h)}, \hat{\theta}_2^{(h)}, \dots, \hat{\theta}_k^{(h)}]^T$ 为DOA估计值。

3.2 实验分析

3.2.1 RMSE随信噪比的变化

在实验中,快拍数设置为 $T=400$,估计两个信源在 $\theta_1=40.3^\circ$ 和 $\theta_2=50.7^\circ$ 方向上的DOA,信噪比设置为 $\{-20, -15, -10, -5, 0, 5, 10\}$ dB。在每个信噪比下进行了1 000次蒙特卡洛实验,相同条件下将各算法进行对比,各算法RMSE随信噪比变化如图9所示。

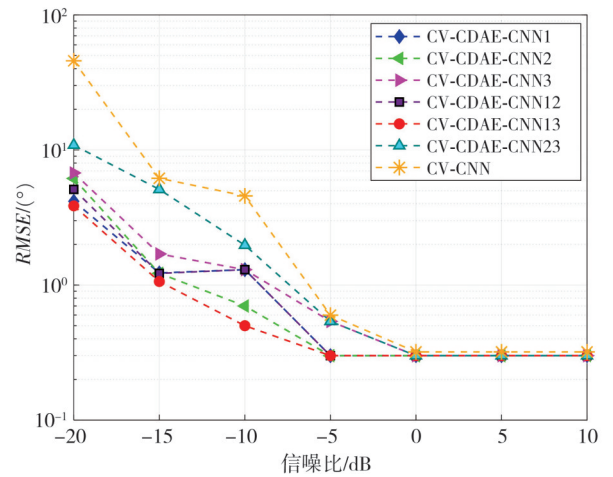


图9 快拍数为400时不同SNR下的RMSE

Fig. 9 RMSE at different SNR for the number of snapshots of 400

从图9可以看出,在不同信噪比条件下, CV-CDAE-CNN13的估计性能最好,在信噪比小于 -5 dB时效果更明显。将CV-CDAE-CNN13与CV-CNN算法^[19]进行比较,在低信噪比条件下,本文算法的估计性能明显优于CV-CNN算法^[19],验证了本文所提出的CV-CDAE及双尺度膨胀卷积的有效性。由图9所示,对比CV-CDAE-CNN13和其他膨胀率不同的降噪算法可知:双尺度膨胀卷积的估计性能优于单个膨胀卷积。然而,并非双尺度膨胀卷积的尺度越大,其性能越好,当卷积尺度过大时,其估计性能将低于单个膨胀卷积,如CV-CDAE-CNN23。

3.2.2 RMSE随快拍数的变化

在实验中,设置信噪比为0 dB,两个信源方向为 $\theta_1=-30.7^\circ$ 和 $\theta_2=-23.1^\circ$,快拍数设置为 $T=\{20, 50, 100, 200, 500\}$ 。在每个快拍下进行了

1 000 次蒙特卡洛实验, 在相同条件下, 将各算法进行了对比, 各算法 RMSE 随快拍数变化如图 10 所示。




图 10 信噪比为 0 dB 时不同快拍数下的 RMSE

Fig. 10 RMSE at different number of snapshots with SNR of 0 dB

由图 10 可知, 随着快拍数增大, 各算法估计性能均有所提升。对比 CV-CDAE-CNN13 与其他膨胀率不同的单尺度和双尺度膨胀卷积降噪算法, CV-CDAE-CNN13 的 RMSE 最小。另外, CV-CDAE-CNN13 算法的 RMSE 也小于文献[19]中的 CV-CNN 算法。这些结果表明了 CV-CDAE-CNN13 算法在估计性能上更具优势。


由图 9 和图 10 可知, 双尺度膨胀卷积中膨胀率为 1 和 3 时估计性能最好, 之后的空间谱估计实验选用该算法与 CV-CNN 算法^[19]进行比较, 进一步验证本文提出算法的性能。

3.2.3 空间谱估计结果

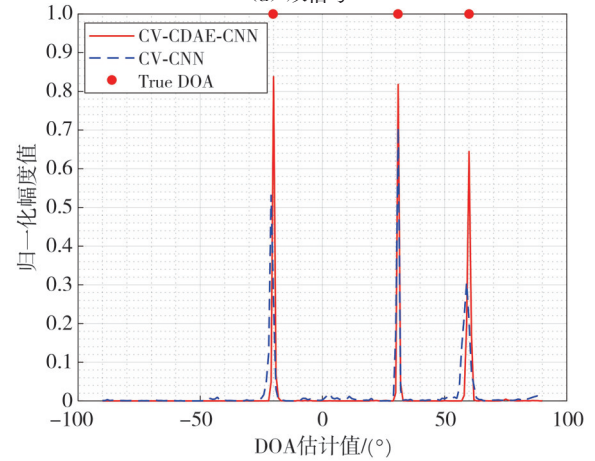
快拍数为 $T=500$, 信噪比为 -5 dB, 绘制出 CV-CDAE-CNN 与 CV-CNN 算法^[19]的 DOA 估计精度图像, 峰值越高代表对应角度为入射角的可能性越大。利用训练好的模型对双信号入射角度为 -18.6° 和 -50° 进行空间谱估计, 重建的空间频谱如图 11(a) 所示, 两个信号分离良好, 且 CV-CDAE-CNN 的 DOA 估计准确率比 CV-CNN 高。之后, 对三信号入射角度为 -20.2° , 30.9° 和 60° 进行空间谱估计。重建的空间频谱为图 11(b), CV-CNN 算法^[19]估计的第 1 个和第 3 个信号偏离真实信号较大, 且 CV-CDAE-CNN 的 DOA 估计准确率比 CV-CNN 高。

为了进一步测试算法对入射信源的分辨力, 在快拍数为 $T=500$, 信噪比为 -5 dB, 信号入射角度为 32.8° 和 38.9° 的条件下进行空间谱估计。两信源之间的角度小, 对其重建的空间谱估计图如图 12 所示, 两算法有效地区分了不同的 DOA, 但 CV-CNN

的第 1 个信号估计值偏离真实角度较大。



(a) 双信号



(b) 三信号

图 11 -5 dB 下空间谱估计图

Fig. 11 Spatial spectrum estimation at -5 dB

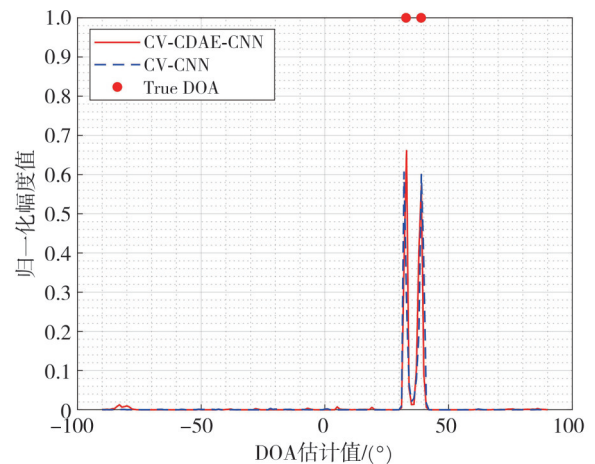


图 12 -5 dB 下小角度的空间谱估计图

Fig. 12 Spatial spectrum estimation for small angles at -5 dB

以上实验中, CV-CDAE-CNN 在非信号源方向上结果接近 0, 验证了该算法学习复值协方差矩阵与信号源方向之间的映射关系, 不仅仅拟合于

训练数据。通过以上实验说明本文算法的泛化能力强, DOA 估计值更准确, 且估计精度更高。

4 结 论

本文提出了一种 CV-CDAE 和 CV-CNN 联合的估计矢量水听器 DOA 方法。首先, 单独训练 CV-CDAE 模块, 利用 CV-CDAE 对矢量水听器接收信号的协方差矩阵进行去噪, 建立带噪样本和原始样本之间的映射, 在完成 CV-CDAE 模型的训练后, 再联合训练 CV-CDAE-CNN, 最后, 使用 CV-CDAE-CNN 来处理 DOA 估计问题。其中, CV-CNN 在下采样前利用双尺度膨胀卷积增大特征图的感受野, 缓解下采样带来的信息损失。实验结果表明, 双尺度膨胀卷积估计性能比单尺度好, 但两个尺度的膨胀率过大会导致估计性能降低, 本文双尺度膨胀卷积的最佳组合为 1 和 3; 在低信噪比或有限快拍数下, CV-CDAE-CNN 比 CV-CNN 算法^[19]估计性能好, 且 CV-CDAE-CNN 比 CV-CNN 算法^[19]重建空间谱的效果好, 验证了 CV-CDAE 模块以及双尺度膨胀卷积模块的有效性。综上所述, 本文所提出算法的 DOA 估计准确率更高, 泛化能力更强, DOA 估计性能更好。

参考文献:

- [1] NIU R, ZHANG Z. Harmonic frequency enhanced direction of arrival estimation using non-uniform linear arrays[J]. IEEE Access, 2024, 12: 36942-36950.
- [2] YU J, WANG Y. Deep learning-based multipath DoAs estimation method for mmWave massive MIMO systems in low SNR [J]. IEEE Transactions on Vehicular Technology, 2023, 72(6): 7480-7490.
- [3] PAN M, LIU P, LIU S, et al. Efficient joint DOA and TOA estimation for indoor positioning with 5G picocell base stations[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 8005219.
- [4] XU Z, LI H, YANG K. A modified differential beamforming and its application for DOA estimation of low frequency underwater signal [J]. IEEE Sensors Journal, 2020, 20(16): 8890-8902.
- [5] SCHMIDT R. Multiple emitter location and signal parameter estimation [J]. IEEE Transactions on Antennas and Propagation, 1986, 34(3): 276-280.
- [6] ROY R, PAULRAJ A, KAILATH T. ESPRIT: a subspace rotation approach to estimation of parameters of cisoids in noise [J]. IEEE Transactions on Acous-

tics, Speech, and Signal Processing, 1986, 34(5): 1340-1342.

- [7] MERKOFER J P, REVACH G, SHLEZINGER N, et al. DA-MUSIC: data-driven DoA estimation via deep augmented MUSIC algorithm[J]. IEEE Transactions on Vehicular Technology, 2024, 73(2): 2771-2785.
- [8] NING Y M, MA S, MENG F Y, et al. DOA estimation based on ESPRIT algorithm method for frequency scanning LWA [J]. IEEE Communications Letters, 2020, 24(7): 1441-1445.
- [9] LI W, ZHU Z, GAO W, et al. Stability and super-resolution of MUSIC and ESPRIT for multi-snapshot spectral estimation [J]. IEEE Transactions on Signal Processing, 2022, 70: 4555-4570.
- [10] WANG P, HE W, GUO F, et al. An improved atomic search algorithm for optimization and application in ML DOA estimation of vector hydrophone array [J]. AIMS Mathematics, 2022, 7(4): 5563-5593.
- [11] GERSTOFT P, MECKLENBRÄUKER C F, XENAKI A, et al. Multisnapshot sparse Bayesian learning for DOA [J]. IEEE Signal Processing Letters, 2016, 23(10): 1469-1473.
- [12] KATTENBORN T, LEITLOFF J, SCHIEFER F, et al. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 173: 24-49.
- [13] YUAN F, ZHANG Z, FANG Z. An effective CNN and Transformer complementary network for medical image segmentation [J]. Pattern Recognition, 2023, 136: 109228.
- [14] YANG R, ZHA X, LIU K, et al. A CNN model embedded with local feature knowledge and its application to time-varying signal classification [J]. Neural Networks, 2021, 142: 564-572.
- [15] LIU Y, CHEN H, WANG B. DOA estimation based on CNN for underwater acoustic array [J]. Applied Acoustics, 2021, 172: 107594.
- [16] PAPAGEORGIOU G K, SELLATHURAI M, ELDAR Y C. Deep networks for direction-of-arrival estimation in low SNR [J]. IEEE Transactions on Signal Processing, 2021, 69: 3714-3729.
- [17] WU L, LIU Z M, HUANG Z T. Deep convolution network for direction of arrival estimation with sparse prior [J]. IEEE Signal Processing Letters, 2019, 26(11): 1688-1692.

(下转第 490 页)