

基于可解释深度卷积网络的空时自适应处理方法

廖志鹏^① 段克清^{*①} 何锦浚^① 邱梓洲^① 王永良^②

^①(中山大学电子与通信工程学院 深圳 518107)

^②(空军预警学院 武汉 430019)

摘要: 在实际应用中, 空时自适应处理(STAP)算法的性能受限于足够多独立同分布(IID)样本的获取。然而, 目前可有效减少IID样本需求的算法仍面临一些问题。针对这些问题, 该文融合数据驱动和模型驱动思想, 构建了具有明确数学含义的多模块深度卷积神经网络(MDCNN), 实现了小样本条件下对杂波协方差矩阵快速、准确、稳定估计。所构建MDCNN网络由映射模块、数据模块、先验模块和超参数模块组成。其中, 前后端映射模块分别对应数据的预处理和后处理; 单组数据模块和先验模块共同完成一次迭代优化, 网络主体由多组数据模块和先验模块构成, 可实现多次等效迭代优化; 超参数模块则用来调整等效迭代中可训练参数。上述子模块均具有明确数学表述和物理含义, 因此所构造网络具有良好的可解释性。实测数据处理结果表明, 在实际非均匀杂波环境下该文所提方法杂波抑制性能优于现有典型小样本STAP方法, 且运算时间较后者大幅降低。

关键词: 多模块深度卷积神经网络; 空时自适应处理; 稀疏恢复; 非均匀杂波; 杂波抑制

中图分类号: TN957.51

文献标识码: A

文章编号: 2095-283X(2024)04-0917-12

DOI: 10.12000/JR24024

引用格式: 廖志鹏, 段克清, 何锦浚, 等. 基于可解释深度卷积网络的空时自适应处理方法[J]. 雷达学报(中英文), 2024, 13(4): 917-928. doi: 10.12000/JR24024.

Reference format: LIAO Zhipeng, DUAN Keqing, HE Jinjun, *et al.* Interpretable STAP algorithm based on deep convolutional neural network[J]. *Journal of Radars*, 2024, 13(4): 917-928. doi: 10.12000/JR24024.

Interpretable STAP Algorithm Based on Deep Convolutional Neural Network

LIAO Zhipeng^① DUAN Keqing^{*①} HE Jinjun^①

QIU Zizhou^① WANG Yongliang^②

^①(School of Electronic and Communication Engineering, Sun Yat-sen University, Shenzhen 518107, China)

^②(Air Force Early Warning Academy, Wuhan 430019, China)

Abstract: In practical settings, the efficacy of Space-Time Adaptive Processing (STAP) algorithms relies on acquiring sufficient Independent Identically Distributed (IID) samples. However, sparse recovery STAP method encounters challenges like model parameter dependence and high computational complexity. Furthermore, current deep learning STAP methods lack interpretability, posing significant hurdles in debugging and practical applications for the network. In response to these challenges, this paper introduces an innovative method: a Multi-module Deep Convolutional Neural Network (MDCNN). This network blends data- and model-driven techniques to precisely estimate clutter covariance matrices, particularly in scenarios where training samples are limited. MDCNN is built based on four key modules: mapping, data, priori and hyperparameter modules. The front- and back-end mapping modules manage the pre- and post-processing of data, respectively. During each

收稿日期: 2024-02-05; 改回日期: 2024-04-03; 网络出版: 2024-04-28

*通信作者: 段克清 duankeqing@aliyun.com *Corresponding Author: DUAN Keqing, duankeqing@aliyun.com

基金项目: 雷达信号处理全国重点实验室支持计划项目(JKW202302)

Foundation Item: The Foundation of National Key Laboratory of Radar Signal Processing (JKW202302)

责任主编: 谢文冲 Corresponding Editor: XIE Wenchong

©The Author(s) 2024. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

equivalent iteration, a group of data and priori modules collaborate. The core network is formed by multiple groups of these two modules, enabling multiple equivalent iterative optimizations. Further, the hyperparameter module adjusts the trainable parameters in equivalent iterations. These modules are developed with precise mathematical expressions and practical interpretations, remarkably improving the network's interpretability. Performance evaluation using real data demonstrates that our proposed method slightly outperforms existing small-sample STAP methods in nonhomogeneous clutter environments while significantly reducing computational time.

Key words: Multi-module Deep Convolutional Neural Network (MDCNN); Space-Time Adaptive Processing (STAP); Sparse recovery; Nonhomogeneous clutter; Clutter suppression

1 引言

机载雷达具备部署快速、视距广等优势,能高效完成预警、探测、监控等任务,在现代战场中扮演着重要角色。然而,当机载雷达处于下视工作状态时,杂波分布广且强度大,严重影响了雷达目标检测能力^[1,2]。空时自适应处理(Space-Time Adaptive Processing, STAP)技术通过阵元(波束)-脉冲(多普勒)二维联合自适应处理,能有效抑制具有空时耦合特性的强地/海杂波并实现目标相参积累,因此是当前运动平台雷达杂波抑制和目标检测的关键技术之一^[3]。STAP技术的自适应依赖于对当前待处理单元杂波协方差矩阵(Clutter Covariance Matrix, CCM)的实时、准确感知。然而,在实际应用中,准确CCM难以获取,需利用充足独立同分布(Independent Identically Distributed, IID)训练样本经最大似然估计得到。依据RMB准则^[4],为保证由CCM估计误差引起的杂波抑制性能损失在3 dB以内,至少需要两倍于系统自由度的IID训练样本。

在实际应用中,可用均匀训练样本严重短缺,进而引起STAP性能急剧下降^[5]。降维STAP可同时实现样本需求和运算量降低^[6,7],但其样本需求仍较为可观,在杂波非均匀较为严重的区域处理性能仍待进一步提升。知识辅助类STAP方法利用先验知识构建CCM^[8,9],对待检测单元杂波数据进行预白化处理,可显著降低均匀训练样本需求,但性能受先验信息的准确性影响较大且先验知识置信度较难确定。稀疏恢复(Sparse Recovery, SR) STAP类方法将空时谱超分辨问题建模为逆问题^[10-13],通过稀疏恢复优化算法实现对高分辨杂波空时谱系数的求解,最终可实现在极少训练样本条件下高性能空时滤波处理。然而,由于优化算法需多次迭代求解,运算量极大,因此CCM估计效率较低,与其实时获取需求相悖;同时,该类方法还需建立显式观测模型,因此存在模型误差补偿能力弱、复杂场景下稳健性差等问题。为解决上述问题,近年来部分学

者提出了深度学习STAP方法^[14-16],利用网络训练去探索观测数据与超分辨空时谱间复杂的非线性关系,从而实现有限训练样本到CCM的高精度重构。然而,上述基于数据驱动的STAP方法缺乏理论支撑导致网络可解释性较差,在解决实际问题时存在可信度差和稳定性低等问题^[17]。

为增强网络可解释性,一些学者将模型驱动与数据驱动相结合,提出了基于模型的深度学习方^[18-24]法,并在图像超分辨和信号处理等领域取得了一定的成效。其中,文献^[23]将交替方向乘子(Alternating Direction Method of Multipliers, ADMM)方法展开为神经网络,可同时实现最优迭代参数和超分辨空时谱的估计。然而,由于ADMM算法迭代次数较多,导致其对应网络结构相对复杂,因此运算时间较典型稀疏恢复STAP方法的改善不够显著。针对该问题,本文利用半二次分裂(Half Quadratic Splitting, HQS)算法将稀疏优化问题分解为两个可迭代优化的子问题^[21],并围绕上述问题求解构建结构简单的模块化神经网络,从而实现具有可解释性且高效的深度学习空时谱超分辨重构。所构建的多模块深度卷积神经网络(Multi-module Deep Convolutional Neural Network, MDCNN)主要由映射模块、数据模块、先验模块和超参数模块构成,各模块分别实现数据预/后处理、辅助变量求解、先验信息更新以及超参数优化功能,且均与确定数学表达式对应,因此具有较好的网络可解释性。网络输入为由小快拍数据估计的傅里叶谱,输出为待检测数据的最小方差无失真响应(Minimum Variance Distortionless Response, MVDR)谱。一旦神经网络训练完成,我们便能利用网络输出的高分辨空时谱重构CCM,进而获取空时二维滤波器对应的权矢量完成杂波抑制。所提方法在训练和测试过程中都具有较高的可控性,且仅使用较少组网络模块求解多次迭代优化问题,显著提升了算法的稳定性和运算效率。最后,本文对美国罗马空军实验室采集的多通道机载雷达测量(Multi-Channel Airborne

Radar Measurements, MCARM)数据进行了处理^[25], 结果表明所提方法在实际非均匀杂波环境下性能略优于稀疏贝叶斯学习(Sparse Bayesian Learning, SBL) STAP方法, 且在线运算量减少约5个量级。

2 信号模型

假定搭载雷达的运动平台在海拔 H 处以速度 v 匀速飞行。考虑 N 阵元均匀线阵, 阵元间隔为 d , 雷达发射波长为 λ , 脉冲重复频率为 f_r , 一个相干处理间隔内发射 K 个脉冲。图1给出了雷达阵列与地面的几何关系。如图1所示, 阵列轴向与坐标系 y 轴平行, 运动平台的飞行方向与阵列轴向夹角为偏航角 θ_c , 雷达到杂波块的斜距为 R_0 , 波束指向对应的方位角、俯仰角和空间锥角分别用 θ , φ 和 ψ 表示。

不考虑距离模糊的情况下, 将等距离环内杂波均匀划分为 N_c 个杂波块, 则机载雷达接收的杂波信号可以表述为

$$\mathbf{x}_c = \sum_{i=1}^{N_c} \beta_i (\mathbf{s}_{t,i} \otimes \mathbf{s}_{s,i}) = \sum_{i=1}^{N_c} \beta_i \mathbf{s}(\psi_i, f_{D,i}) \quad (1)$$

其中, β_i , ψ_i 和 $f_{D,i}$ 分别对应第 i 个杂波块的复幅度、空间锥角和归一化多普勒频率, $f_{D,i} = 2v \cos \psi_i / (\lambda f_r)$ 。 $\mathbf{s}(\psi_i, f_{D,i}) = \mathbf{s}_{t,i} \otimes \mathbf{s}_{s,i} \in \mathbb{C}^{NK \times 1}$ 是对应的空时二维导向矢量, 其中, \otimes 表示Kronecker乘积, $\mathbf{s}_{t,i}$, $\mathbf{s}_{s,i}$ 分别表示时域和空域导向矢量, 表示如下:

$$\mathbf{s}_{t,i} = \left[1, e^{j4\pi v \cos(\theta + \theta_c) \cos \varphi / (\lambda f_r)}, \dots, e^{j4\pi v (K-1) \cos(\theta + \theta_c) \cos \varphi / (\lambda f_r)} \right]^T \in \mathbb{C}^{K \times 1} \quad (2)$$

$$\mathbf{s}_{s,i} = \left[1, e^{j2\pi d \cos \theta \cos \varphi / \lambda}, \dots, e^{j2\pi (N-1) d \cos \theta \cos \varphi / \lambda} \right]^T \in \mathbb{C}^{N \times 1} \quad (3)$$

其中, $(\cdot)^T$ 表示矩阵转置运算。相应的CCM可以用式(4)表示:

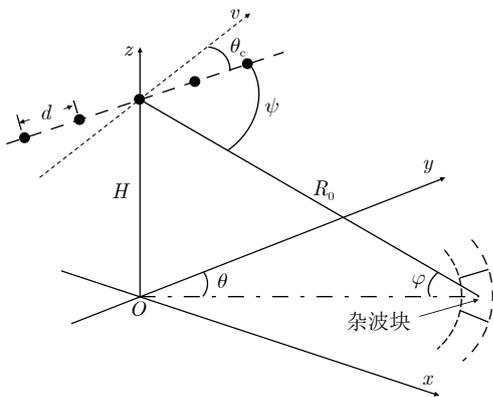


图1 机载雷达阵列与地面几何关系

Fig. 1 Airborne radar viewing geometry

$$\mathbf{R}_c = E[\mathbf{x}_c \mathbf{x}_c^H] \quad (4)$$

其中, $(\cdot)^H$ 和 $E[\cdot]$ 分别表示矩阵共轭转置操作和求数学期望。

在CCM确知情况下, 使输出信杂噪比(Signal to Clutter and Noise Ratio, SCNR)最大的空时二维滤波器权矢量为

$$\mathbf{w} = \frac{\mathbf{R}^{-1} \mathbf{s}(\psi_t, f_{D,t})}{\mathbf{s}(\psi_t, f_{D,t})^H \mathbf{R}^{-1} \mathbf{s}(\psi_t, f_{D,t})} \quad (5)$$

其中, $(\cdot)^{-1}$ 表示矩阵求逆操作, $\mathbf{s}(\psi_t, f_{D,t})$ 为目标来向对应空时二维导向矢量; $\mathbf{R} = \mathbf{R}_c + \sigma^2 \mathbf{I}_{NK}$ 为考虑对角加载的CCM, σ^2 是噪声方差, \mathbf{I}_{NK} 是 NK 阶单位矩阵。在实际应用场景下, 难以获取准确的CCM, 通常用多个训练样本经最大似然估计得到其近似值, 该方法被称为采样协方差矩阵求逆(Sample Matrix Inversion, SMI)方法, 其数学表达为

$$\hat{\mathbf{R}} = \frac{1}{L} \sum_{l=1}^L \mathbf{x}_l \mathbf{x}_l^H \quad (6)$$

其中, \mathbf{x}_l 是第 l 个距离单元回波数据, L 为最大似然估计所使用的训练样本数。根据RMB准则^[4], 若要保证SMI算法较最优STAP算法的SCNR损失不大于3 dB, 则需要满足 $L \geq 2NK$ 。在实际非均匀杂波环境下, 能够获取的IID样本数往往难以满足上述条件, 而以SR STAP为代表的小样本STAP方法能有效避免实际场景下样本数不足问题。

由式(1)可知, 雷达回波信号可视为由多个不同波束来向和不同多普勒频率的子信号累加而成, 为方便后续处理, 常对空域和多普勒域进行离散化。假设空间频率和多普勒频率分别被离散化为 $N_s = \rho_s N$ 和 $N_D = \rho_D K$ (通常要求离散化系数满足 $\rho_s \gg 1$, $\rho_D \gg 1$)。同时, 考虑阵元通道幅相(Gain/Phase, G/P)误差对雷达接收信号的影响, 则式(1)可改写为

$$\mathbf{x} = \sum_{q=1}^{N_s N_D} \beta_q \mathbf{s}_t \otimes (\mathbf{e} \odot \mathbf{s}_s) + \mathbf{n} \quad (7)$$

其中, \odot 表示Hadamard乘积, $\mathbf{e} = [e_1, e_2, \dots, e_N]^T$ 为G/P误差矢量, \mathbf{n} 为零均值高斯白噪声, 其噪声方差为 σ^2 , 且有

$$e_n = (1 + a_n) e^{j b_n}, n = 1, 2, \dots, N \quad (8)$$

其中, $a_n \in \mathbb{R}$ 和 $b_n \in \mathbb{R}$ 分别表示第 n 个阵元对应的幅度误差和相位误差。为进一步描述杂波的稀疏特性, 记空时字典为

$$\Phi = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_{N_s N_D}] \in \mathbb{C}^{NK \times N_s N_D} \quad (9)$$

并将每个空时网格的复包络按照空时字典对应顺序排列, 记为

$$\boldsymbol{\gamma} = [\beta_1, \beta_2, \dots, \beta_{N_s N_D}]^T \in \mathbb{C}^{N_s N_D \times 1} \quad (10)$$

同时, 可将G/P误差信息表述为一个矩阵:

$$\boldsymbol{\Gamma} = \mathbf{I}_K \otimes \text{diag}^*(\mathbf{e}) \in \mathbb{C}^{NK \times NK} \quad (11)$$

其中, $\text{diag}^*(\cdot)$ 表示将一个向量转化为对角矩阵。进而可由式(9)—式(11)推导出考虑G/P误差时的杂波信号稀疏表示:

$$\mathbf{x} = \boldsymbol{\Gamma} \boldsymbol{\Phi} \boldsymbol{\gamma} + \mathbf{n} \quad (12)$$

3 MDCNN STAP方法

3.1 HQS算法

为体现杂波稀疏特征, 常以较大的离散化系数划分方位-多普勒谱, 即满足 $N_s \times N_D \gg N \times K$ 。此时空时字典不满秩, 式(12)为欠定方程。依据SR理论, 求解该欠定方程可等效为

$$\min_{\boldsymbol{\gamma}} \|\mathbf{x} - \boldsymbol{\Gamma} \boldsymbol{\Phi} \boldsymbol{\gamma}\|_2^2, \quad \text{s.t.} \|\boldsymbol{\gamma}\|_0 \leq r_s \quad (13)$$

其中, r_s 为杂波稀疏度, $\|\cdot\|_0$ 和 $\|\cdot\|_2$ 分别表示向量的 L_0 拟范数和 L_2 范数。由于实际杂波环境下存在各种非理想因素, 无法获取杂波稀疏度的准确估计, 难以直接解式(13), 常将其变化为

$$\min_{\boldsymbol{\gamma}} \frac{1}{2} \|\mathbf{x} - \boldsymbol{\Gamma} \boldsymbol{\Phi} \boldsymbol{\gamma}\|_2^2 + \lambda \|\boldsymbol{\gamma}\|_0 \quad (14)$$

其中, λ 为依赖于模型先验知识的超参数, SR STAP的整体算法性能将严重依赖该超参数的准确性。同时, 由于式(14)中存在 L_0 拟范数, 这导致该优化问题为NP难问题。为解决该问题, 常将 L_0 拟范数松弛为 L_1 范数进行求解。在此基础上, 将 L_1 范数约束转化为最大后验估计, 可有效减少对先验知识的依赖性并提高其鲁棒性^[16]。基于最大后验估计视角, 并引入辅助变量 \mathbf{z} , 可将式(14)改写为

$$\begin{aligned} & \arg \min_{\boldsymbol{\gamma}} \frac{1}{2\sigma^2} \|\mathbf{x} - \mathbf{H} \boldsymbol{\gamma}\|^2 + \lambda \Omega(\mathbf{z}) \\ & \text{s.t.} \quad \mathbf{z} = \boldsymbol{\gamma} \end{aligned} \quad (15)$$

其中, $\mathbf{H} = \boldsymbol{\Gamma} \boldsymbol{\Phi}$ 为考虑各种非理想因素影响的观测矩阵, $\Omega(\mathbf{z})$ 是关于辅助变量的正则化项。式(15)的迭代形式解为

$$\mathbf{z}_k = \arg \min_{\mathbf{z}} \|\mathbf{x} - \mathbf{H} \mathbf{z}\|^2 + \mu \sigma^2 \|\mathbf{z} - \boldsymbol{\gamma}_{k-1}\|^2 \quad (16)$$

$$\boldsymbol{\gamma}_k = \arg \min_{\boldsymbol{\gamma}} \frac{\mu}{2} \|\mathbf{z}_k - \boldsymbol{\gamma}\|^2 + \lambda \Omega(\boldsymbol{\gamma}) \quad (17)$$

其中, μ 是正则化参数; $\Omega(\boldsymbol{\gamma})$ 是关于约束 $\boldsymbol{\gamma}$ 稀疏性的正则化项, 表征了杂波在空时谱上的稀疏先验信息。式(16)和式(17)分别对应的优化方程式(15)中

的保真项和正则化项, 交替迭代两个子优化问题至收敛, 便可得式(15)的解。同时, 注意到式(16)为Tikhonov正则化最小二乘问题, 可直接给出解析解:

$$\begin{aligned} \mathbf{z}_k &= (\mathbf{H}^T \mathbf{H} + \mu \sigma^2 \mathbf{I})^{-1} (\mathbf{H}^T \mathbf{x} + \mu \sigma^2 \boldsymbol{\gamma}_{k-1}) \\ &= (\mathbf{H}^T \mathbf{H} + \mu \sigma^2 \mathbf{I})^{-1} \mathbf{H}^T \mathbf{x} + (\mathbf{H}^T \mathbf{H} + \mu \sigma^2 \mathbf{I})^{-1} \\ &\quad \cdot \mu \sigma^2 \boldsymbol{\gamma}_{k-1} \\ &\approx \boldsymbol{\gamma}_F + \boldsymbol{\alpha}_k \cdot \boldsymbol{\gamma}_{k-1} \end{aligned} \quad (18)$$

由式(18)可以看出, 该最小二乘解可分解为两项。其中, 前一项是与训练样本 \mathbf{x} 相关的稀疏解(即杂波在方位-多普勒域的稀疏谱), 但由于真实阵列流形相关的 \mathbf{H} 未知, 因此我们采用 \mathbf{x} 的傅里叶变换(低分辨傅里叶谱)进行近似; 后一项为基于上一次迭代获取的稀疏系数 $\boldsymbol{\gamma}_{k-1}$ 的加权更新, 其加权系数 $\boldsymbol{\alpha}_k$ 为超参数模块对应第 k 个数据子模块的输出。

式(17)可从贝叶斯先验概率角度出发, 描述为一个噪声水平为 $\sqrt{\lambda/\mu}$ 的高斯降噪器^[22]:

$$\boldsymbol{\gamma}_k = \arg \min_{\boldsymbol{\gamma}} \frac{1}{2 \left(\sqrt{\lambda/\mu} \right)^2} \|\mathbf{z}_k - \boldsymbol{\gamma}\|^2 + \Omega(\boldsymbol{\gamma}) \quad (19)$$

已有工作证明, 该类型降噪器问题可使用卷积神经网络解决^[18-22]。

3.2 MDCNN网络结构及其数学表达

利用HQ S算法, 我们可将稀疏优化问题分解为两个可迭代优化的子问题, 并围绕上述问题求解构建结构简单的模块化神经网络。下面, 我们将进一步介绍所构建的多模块神经网络。

基于HQ S算法的迭代形式解, 我们构建了一个模块化的深度卷积神经网络。首先, 利用少量训练样本经傅里叶变换得到低分辨杂波空时谱; 其次, 设计一个映射模块 \mathcal{M} 对该傅里叶谱进行预处理; 然后, 构建数据模块 \mathcal{D} 求解式(16)中数据子优化问题; 继而, 构建先验模块 \mathcal{P} 求解式(17)中先验子优化问题; 最后构建超参数模块 \mathcal{H} 实现两个子优化问题中的参数调优, 其中该模块中超参数 $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 分别用于解决数据模块 \mathcal{D} 和先验模块 \mathcal{P} 中的参数调优问题。基于上述4个模块, 我们构建了 l 阶MDCNN, 其网络框架的示意图如图2所示。

如图2所示, 数据模块 \mathcal{D} 和先验模块 \mathcal{P} 共同构成一个等效迭代 \mathcal{I} , MDCNN的阶数 l 即为网络中等效迭代的次数。下面我们将分别介绍4个模块对应的数学含义及其在网络中所实现的功能。

(1) 映射模块 \mathcal{M} : 该模块主要完成输入低分辨杂波空时谱的预处理。在以往的深度学习空时谱超

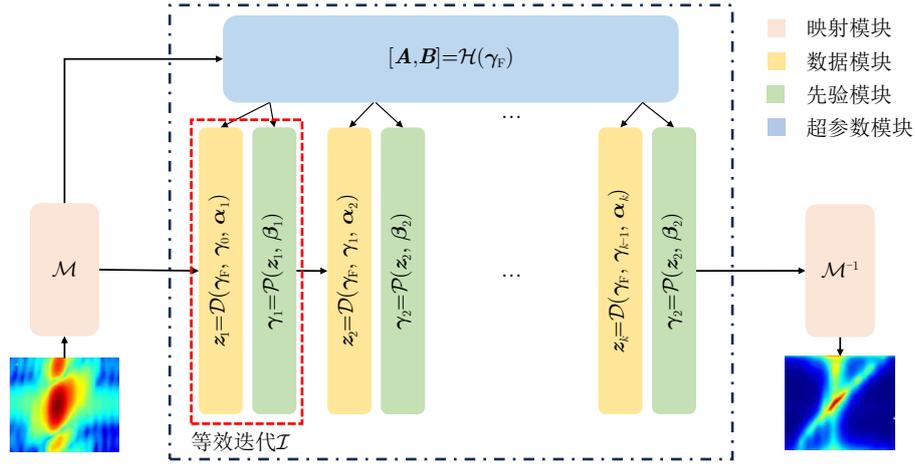


图2 MDCNN网络框架示意图

Fig. 2 The overview of MDCNN

分辨STAP算法中，通常将空时谱在输入端进行归一化操作，以提升网络收敛性^[14]。然而，这种操作要求在网络处理后重新估计空时谱的真实幅度，增加了计算负担，并将引入更多系统误差。同时，若谱系数估计不准确，将严重影响后续重构CCM的准确性，进而影响整体算法性能。为避免上述问题，我们利用映射模块对网络的输入数据进行预处理，以提高网络对谱系数的估计准确度。

在网络输入端，对sigmoid函数稍作调整，将输入数据映射到一个较小的范围，其映射函数为

$$\mathcal{M}(p) = \frac{m_a}{1 + e^{m_b \lg(\text{abs}(p))}} \quad (20)$$

其中， p 是映射函数自变量，不具备实际物理意义； m_a 和 m_b 是两个可调节的缩放参数，可根据实际数据分布进行调节，其本质目的是使数据压缩完后处于(0,1)开区间。

在网络的输出端，设置与映射模块 \mathcal{M} 对应的反射映射模块 \mathcal{M}^{-1} 便可以还原具有真实幅度的估计空时谱，反射映射模块 \mathcal{M}^{-1} 对应的函数为

$$\mathcal{M}^{-1}(p) = 10^{-\frac{1}{m_b} \ln\left(\frac{m_a}{p-1}\right)} \quad (21)$$

(2) 数据模块 \mathcal{D} ：该模块用于计算数据子优化问题的解析解，即实现式(18)的求解。在3.1节中，我们将HQS算法的核心优化方程的求解转化为两个子优化问题的循环迭代求解，而数据模块就是用于处理其中的数据子优化问题。具体而言，前一个等效迭代 \mathcal{I}_{k-1} 中的先验模块 \mathcal{P}_{k-1} 的输出将作为第 k 个数据模块 \mathcal{D}_k 的输入，而 \mathcal{D}_k 的输出则会传递给本次等效迭代 \mathcal{I}_k 的先验模块 \mathcal{P}_k 。数据模块将提取输入数据中与上一阶先验模块输出存在差异性的有效特征(主要由非理想因素导致)，然后与低分辨谱叠加输出到先验模块。在不断迭代的过程中，数据中对

性能贡献度较高的有效特征会保留，而贡献度较低的特征将不断弱化。需要说明的是，该模块没有待训练参数，可直接用解析式表达，如式(18)。为方便描述，可将数据模块表述为

$$z_k = \mathcal{D}(\gamma_F, \gamma_{k-1}, \alpha_k) \quad (22)$$

其中， γ_F 是原始数据的傅里叶谱经过映射模块后的输出， $\gamma_0 = \gamma_F$ 是第1次等效迭代的数据模块输入。

(3) 先验模块 \mathcal{P} ：该模块用于解决式(19)中的先验子优化问题。在数据模块提取空时谱特征后，先验模块进一步将上述特征用于空时谱重构。先验模块能有针对性地精细化重构具有不同非理想条件和噪声水平的空时谱。随着等效迭代次数 k 的增大，数据模块 \mathcal{D}_k 抽取的有效特征得到强化，从而先验模块 \mathcal{P}_k 重构的空时谱也将更加准确。从贝叶斯先验概率出发，可将先验模块 \mathcal{P} 描述成一个噪声水平为 $\sqrt{\lambda/\mu}$ 的高斯降噪器：

$$\gamma_k = \mathcal{P}(z_k, \beta_k) \quad (23)$$

该降噪器可通过膨胀卷积神经网络来实现，因膨胀卷积能在不增加实际卷积核大小的情况下扩大感受野，从而可在不增加额外计算量的同时提升网络性能。膨胀卷积神经网络的具体参数设置如图3所示，网络的核心包含3个膨胀卷积层，其通道数分别为32, 16和1。每个膨胀卷积层后面紧跟着一个批归一化层和一个ReLU激活层。图3中， k 表示二维卷积核尺寸， d 表示膨胀间隔。需要注意的是，在最后一次等效迭代时，先验模块网络的最后一个卷积层将直接连接到反射映射模块，不会经过批归一化和ReLU激活操作。

(4) 超参数模块 \mathcal{H} ：该模块主要完成等效迭代中涉及的超参数调优问题。超参数模块中设有两组超参数 α 和 β 。其中， α_k 解决数据模块涉及的一些

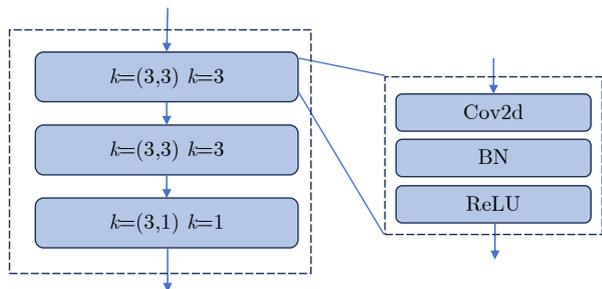


图3 先验模块神经网络

Fig. 3 The neural network of prior module

参数,例如 $\mu_k\sigma^2$ 的调优问题; β_k 解决先验模块涉及的一些参数,例如 $\sqrt{\lambda/\mu_k}$ 的调优问题。超参数模块的输出可以视为多个element-wise滤波器,本身不参与迭代,但是可以调控等效迭代的输出。由于我们无法参数化表示数据中的非理想因素,因此该模块直接采用数据的傅里叶谱作为输入,从中抽取非理想因素对应特征调控网络。为方便描述,记 $\mathbf{A} = [\alpha_1, \alpha_2, \dots, \alpha_k]$, $\mathbf{B} = [\beta_1, \beta_2, \dots, \beta_k]$, 则超参数模块可以表示为

$$[\mathbf{A}, \mathbf{B}] = \mathcal{H}(\gamma_F) \quad (24)$$

这里,我们采用多层卷积神经网络实现该模块。该网络的输入层是包含64个通道的卷积层,其隐藏层由4个普通卷积层组成,通道数分别为32, 16, 16和16。所有卷积层的卷积核为 3×3 。在每个卷积层之后都紧跟着一个批归一化层和一个Leaky ReLU激活层。

3.3 数据集构造

本文使用仿真程序生成的训练数据集完成训练。生成训练数据集时,考虑了不同地形地貌、不同距离门 L_r 、不同偏航角 θ_c 、不同G/P误差 e 和不同杂波起伏情况,能有效模拟实际非均匀杂波条件下的雷达回波数据。由于考虑因素较多,本文随机生成数据集中的非理想因素以尽可能涵盖各类情况。具体而言,训练集中考虑了海洋(5种海情)、沙漠、农田、丘陵和山脉地形;距离门 L_r 设置为 $L_r \in [1, 2, \dots, L_{r,\max}]$,其中 $L_{r,\max}$ 为最大不模糊距离对应距离门;偏航角 θ_c 设置为 $\theta_c \in [0, \theta_{c,\max}]$,其中 $\theta_{c,\max}$ 为最大偏航角;G/P误差 e 以式(8)的形式给出,具体参数为 $a_n \in [0, \sigma_e^2]$, $b_n \in \sigma_e^2[-\pi, \pi]$,其中 σ_e^2 为G/P误差的方差且有 $\sigma_e^2 \in [0, \sigma_{e,\max}^2]$ 。实践中,应根据实际应用场景调整上述各参数具体数值。本文中,仿真采用具体的雷达系统参数如表1所示,且 $L_{r,\max} = 630$, $\theta_{c,\max} = -7.3^\circ$, $\sigma_{e,\max}^2 = 0.05$, $N = 16$, $K = 8$ 。

本文构造谱估计器 $G(\mathbf{X})$ 获取训练样本 $\mathbf{X} = [\mathbf{x}_1,$

$\mathbf{x}_2, \dots, \mathbf{x}_L] \in \mathbb{C}^{N \times K \times L}$ 对应的空时谱 γ 。图4给出了训练样本的具体选取方式,即在待检测单元两侧设置若干保护单元,再选取保护单元外若干相邻距离门数据作为训练样本。在测试阶段,首先采用少量训练样本估计 $\hat{\mathbf{R}}$,并得到其傅里叶谱,该过程可表述为

$$\gamma_F = G(\mathbf{X}) = \text{diag}(\mathbf{L}\Phi^H \hat{\mathbf{R}}\Phi) \quad (25)$$

其中, $\text{diag}(\cdot)$ 表示提取方阵中的主对角线元素构成列矢量。随后,我们将 $\gamma_F \in \mathbb{C}^{N_s N_d \times 1}$ 重排为矩阵形式 $\gamma_M \in \mathbb{C}^{N_s \times N_d}$ 作为训练集中的一组训练数据。该训练数据对应的标签则为

$$\gamma_M = \text{diag}(1/(\Phi^H \mathbf{R}^{-1} \Phi)) \quad (26)$$

其中, \mathbf{R} 为待检测单元的CCM,可在仿真中直接获取。同时,标签也重排为 $\gamma_M \in \mathbb{C}^{N_s \times N_d}$ 。从而,包含 N_{data} 数据对的训练数据集可表示为 $\{\gamma_F, \gamma_M\}^{N_{\text{data}}}$ 。

一旦神经网络完成训练,则可将任意输入的低分辨傅里叶谱 γ_F 非线性拟合为高分辨谱 γ_{out} 作为输出,进而重构得到CCM:

$$\hat{\mathbf{R}}_{\text{MDCNN}} = \sum_{q=1}^{N_s N_d} \gamma_{\text{out}_q} \mathbf{s}_q \mathbf{s}_q^H \quad (27)$$

4 实测数据处理结果与分析

20世纪90年代美国为研究STAP可行性及其相

表1 MCARM数据雷达系统参数

Tab. 1 MCARM data radar system parameters

参数	数值
飞行高度	3060 m
飞行速度	100.2 m/s
载波频率	1240 MHz
工作波长	0.2419 m
主波束方位角	0°
主波束俯仰角	5.4°
载机偏航角	-7.3°
相参脉冲数	16
阵元误差	1%~2%
峰值辐射功率	25 kW
不模糊距离门	630个
系统损耗	8 dB



■ 训练单元 ■ 保护单元 ■ 待检测单元

图4 训练数据构成

Fig. 4 Training data composition

关技术实测录取了MCARM数据。数据中包含了多种典型地貌，且存在速度误差和阵元天线误差，基本反映了机载雷达工作的真实环境。本文采用的MCARM数据编号为RL050575，它包含了从Delmarva半岛上空采集的数据，载机从西经75.972°、北纬39.379°靠近马里兰切萨皮克港处起飞。其具体的雷达系统参数如表1所示，由于阵面与速度夹角很小(-7.3°)，可以按正侧视数据进行处理^[26]。

MCARM数据采集项目采用了16×8的均匀平面阵天线，阵元上下间距约为5.54英寸(约合14.0716 cm)，左右间距约为4.3英寸(约合10.922 cm)。为方便后续处理，各列的8个阵元被均匀划分为不重叠的两个子阵，每个子阵包含4个阵元。因此，整个阵面共划分为32个子阵，并合成24个通道，具体合成方式如图5所示^[25]。

RL050575 数据共有630个距离门的回波数据，实验中主要处理的第181~630个距离门中8通道(图5所示的第17~24个通道)、16脉冲的回波数据完成测试。遵循图4中的数据组织结构，提取6个训练样本的回波数据，将相应的傅里叶谱作为测试集。因此，测试数据集由450个距离门的傅里叶谱组成。需要指出，在处理实测MCARM数据的相关实验时我们将映射模块的压缩稀疏设置为 $m_a = 10$, $m_b = 0.5$ 。后续的所有实验都将利用该测试数据集进行，且实验中各对比方法的实验条件完全一致。

4.1 网络收敛性能

本节验证了提出的MDCNN的收敛性。实验系统配置采用了Intel(R) Core(TM) i7-11700K @

3.60 GHz和NVIDIA GeForce RTX 3070。训练中， $N_{\text{data}} = 1 \times 10^4$ ，通过比较不同初始学习率下的均方根误差，确定了最佳初始学习率。为提升网络收敛性能，网络将首先使用Adam优化器以较大学习率训练50个epoch；然后将学习率衰减3个量级继续训练100个epoch。同时，为直观呈现网络的收敛情况，这里抽取了训练中若干epoch的输出空时谱加以对比。选择合适的学习率是神经网络训练中的关键因素之一。若学习率过大，会导致网络震荡难以收敛或错过最优解；若学习率过小，则会导致收敛速度慢或陷入局部最优。图6(a)的结果显示所提网络能有效收敛，且初始学习率为 1×10^{-3} 时网络收敛性能最佳，因此后续均采用该初始学习率。网络中的待学习参数均采用Kaiming初始化设置初始值。

以第280个距离门对应的数据为例，图6(b)—图6(d)分别为第5、第50和第150个epoch的输出空时谱。可以看到，在前几个epoch中网络就已经能有效学习到杂波脊的位置及分布情况。同时，随着网络训练的进行，输出端的均方根误差持续减小，输出的空时谱的细节也逐渐完善从而接近高分辨MVDR空时谱。

4.2 空时谱估计性能

本节展示所提MDCNN方法重构高分辨空时谱的性能，并将其与SBL STAP^[1]、FOCUSS STAP^[27]以及CNN STAP^[14]算法进行对比。以第301个距离门数据为例，不同方法重构的空时谱如图7所示。图7(a)—图7(f)分别展示了傅里叶谱、多个距离门样本估计的MVDR谱、FOCUSS方法重构谱、SBL方法重构谱、CNN方法重构谱和MDCNN方法

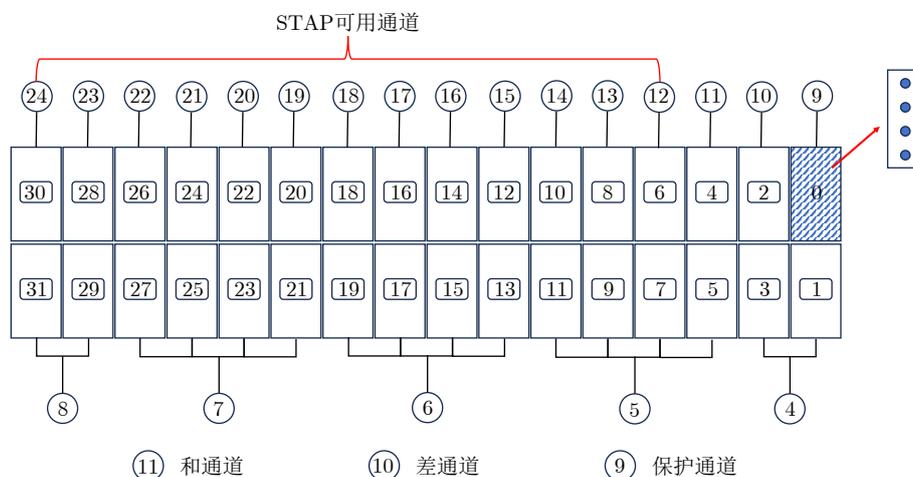


图5 MCARM天线结构

Fig. 5 The antenna structure of MCARM data

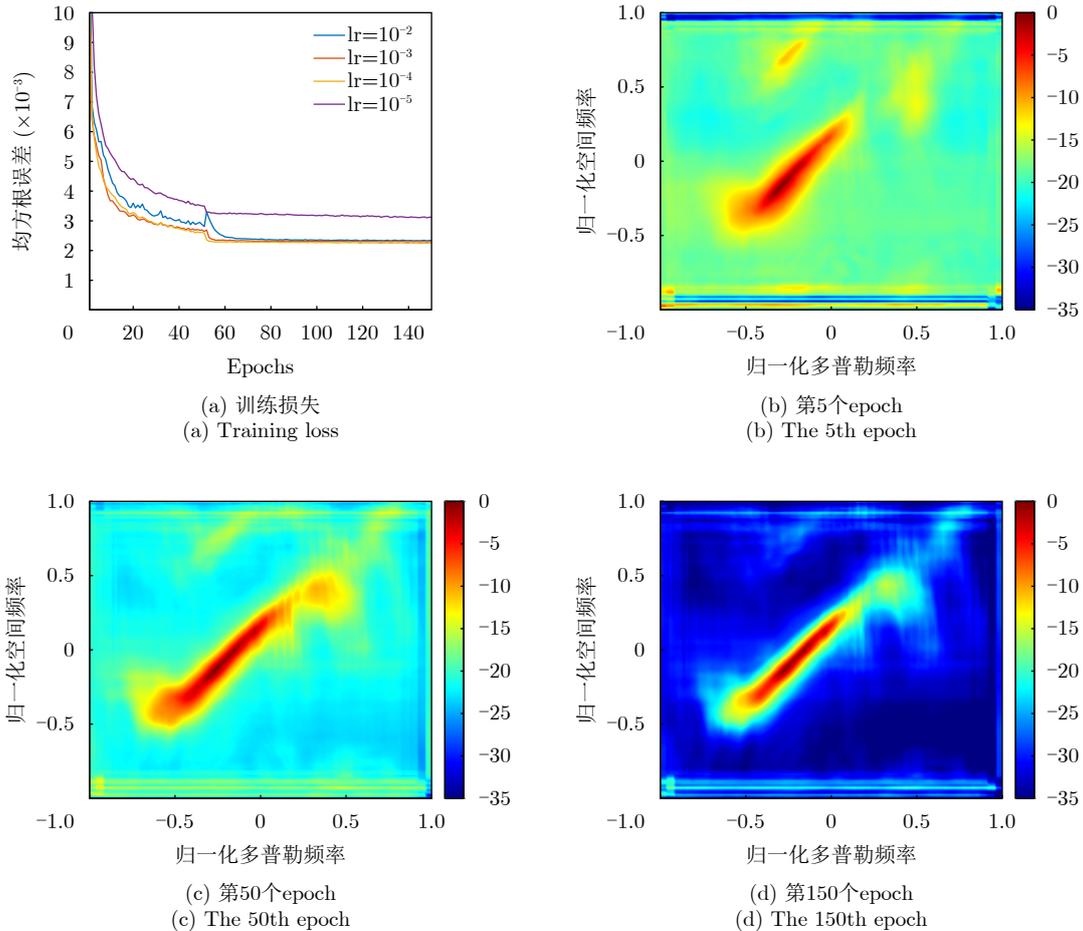


图6 网络收敛性能

Fig. 6 Network convergence performance

重构谱。其中, FOCUSS算法迭代100次, 正则化参数设置为 10^{-4} ; SBL算法迭代100次, 噪声系数设置为 10^{-6} 。

从图7可以观察到, 由于阵元幅相误差存在, 傅里叶谱和MVDR谱都存在由空域去相关导致的能量泄露, 对重构算法产生较大挑战。从主瓣形状和杂波脊恢复程度方面来看, MDCNN方法优于其他3种方法。从重构由阵元误差引起的能量扩散现象以及清洁区功率方面来看, SBL算法明显优于FOCUSS和CNN算法, 略优于所提MDCNN算法。综上所述, MDCNN算法的空时谱估计性能与SBL算法对比各有优劣, 且二者性能明显优于FOCUSS算法和CNN算法。

4.3 杂波抑制性能

本节对比了常规波束成形(Conventional Beam-Forming, CBF), SBL, FOCUSS, CNN和MDCNN算法在杂波抑制方面的性能。为验证杂波抑制性能, 本实验在第600个距离门主瓣杂波区注入一个信杂比为 -25 dB、归一化多普勒频率为0.125

的目标; 其次, 在第587个距离门的副瓣杂波区注入一个信杂比为 -40 dB、归一化多普勒频率为0.600的目标。以归一化输出功率作为性能指标, 则各方法的性能对比如图8所示。

如图8(a)所示, 对位于主瓣杂波区域的目标而言, SBL算法和MDCNN算法能够较好地将目标从背景杂波中提取出来, 且处理后的剩余杂波功率明显低于CNN, FOCUSS和CBF算法。从图8(b)可见, 当目标位于副瓣区域时, FOCUSS算法在第585个距离门出现了错误识别目标的现象, 并在某些距离门处表现出较高的剩余杂波功率, 杂波抑制性能较差, 而CNN, SBL和MDCNN算法的杂波抑制性能较好, 明显优于CBF算法。

综上所述, 在杂波抑制性能上, 相较于CBF算法, MDCNN算法和SBL算法在主瓣杂波区杂波抑制性能可改善约 15 dB, 在副瓣杂波区杂波抑制性能可改善约 10 dB。同时, MDCNN算法略优于SBL算法, 且显著优于FOCUSS算法、CNN算法和CBF算法。

值得注意的是, 从空时谱估计性能和杂波抑制

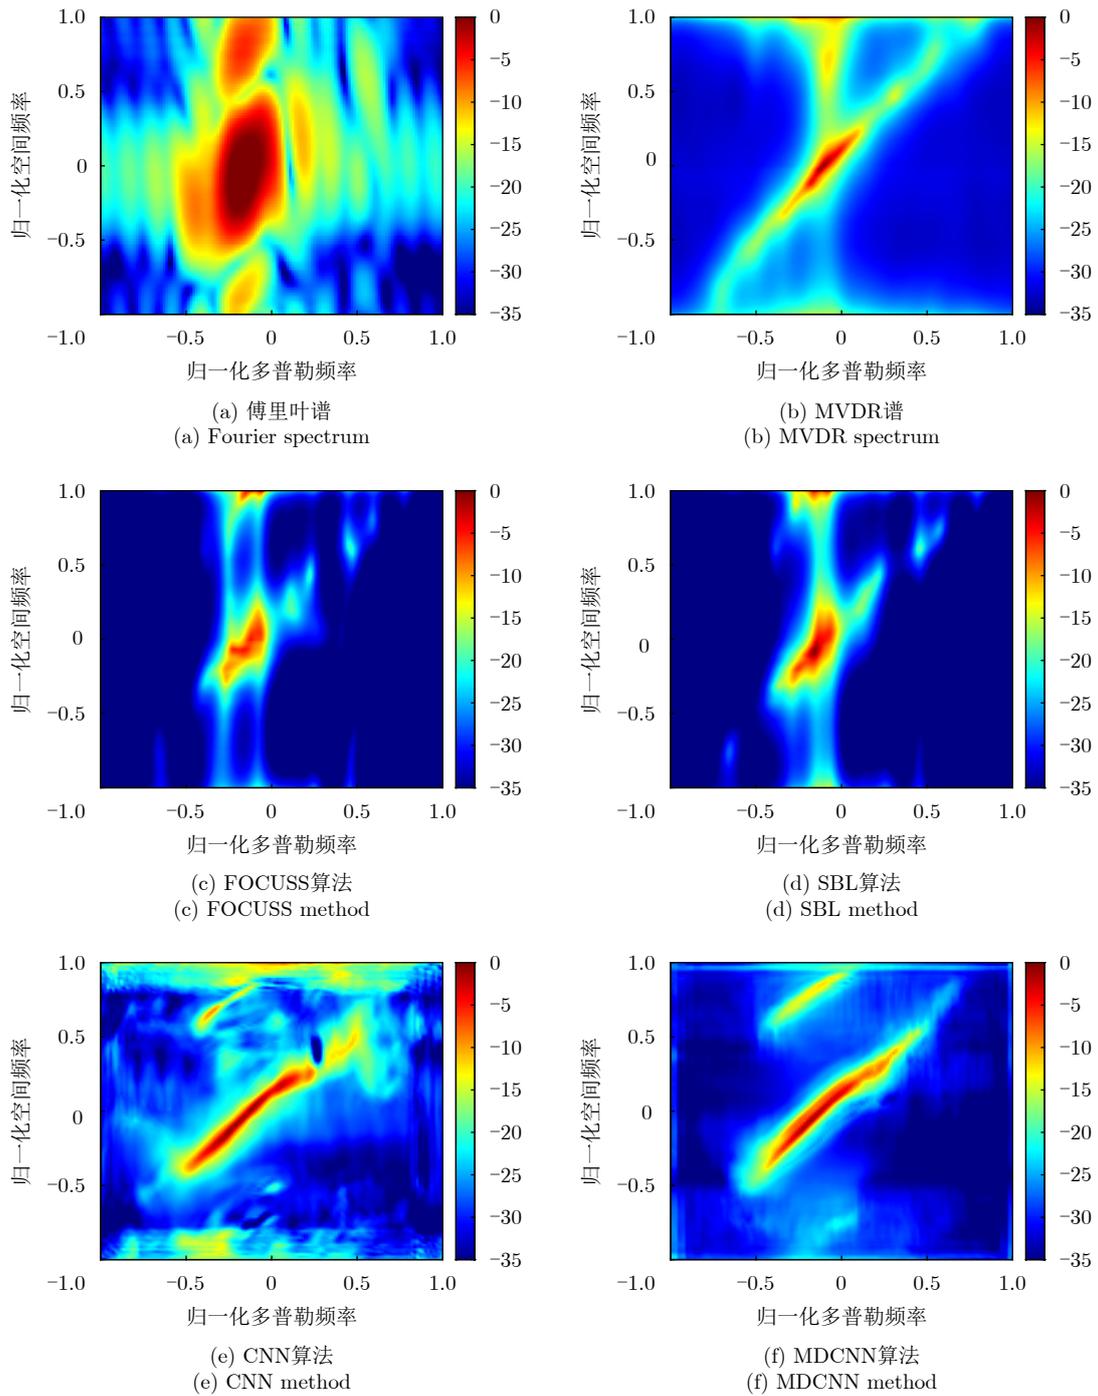


图7 各种算法重建的时空谱对比

Fig. 7 Comparison of space-time spectra restored by various methods

性能两方面来看，MDCNN算法要明显优于CNN算法。两种方法性能差异的根本原因在于，CNN采用了直接的非线性拟合策略来实现对杂波谱的超分辨重构，而MDCNN则融合了稀疏恢复模型来解决超分辨重构问题，能够更有效地利用杂波先验知识。就本质而言，CNN仅依赖于数据驱动方法，而MDCNN结合了数据驱动和模型驱动方法，从而实现更加稳定的网络训练，并提升网络性能。

4.4 运算复杂度

本节对MDCNN算法的运算复杂度进行了分析，并与FOCUSS, SBL, CNN算法进行了对比。值得注意的是，CNN和MDCNN都采用了离线训练-在线预测的模式，因此比较运行时主要关注在线预测时间^[15]。表2给出了几种对比算法的运算复杂度和运行时间，表中 I_{FOC} 和 I_{SBL} 分别表示FOCUSS算法和SBL算法迭代次数。同时，为方便

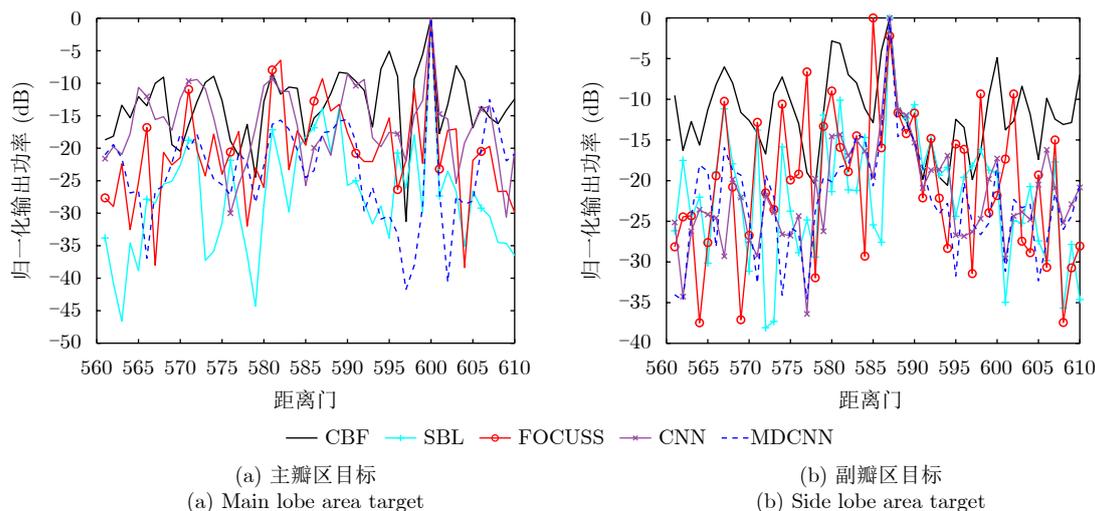


图8 杂波抑制性能对比

Fig. 8 Comparison of clutter suppression performance

表2 运算复杂度分析

Tab. 2 Analysis of computational complexity

方法	运算复杂度	运行时间(s)
FOCUSS	$O\left(\left(NKN_S N_D + (NK)^3 + 3(NK)^2 N_S N_D + 2NK(N_S N_D)^2\right) I_{SBL}\right)$	61.870
SBL	$O\left(\left(NKN_S N_D + (NK)^3 + 2(NK)^2 N_S N_D + NK(N_S N_D)^2\right) I_{FOC}\right)$	130.400
CNN	$O(28777N_S N_D)$	0.003
MDCNN	$O(12960N_S N_D)$	0.002

直观比较, 图9给出了各对比方法在不同数据规模下的运算复杂度曲线。其中, $N = K = 4 \sim 80$, 离散化系数取 $\rho_S = \rho_D = 4$, FOCUSS算法和SBL算法的迭代次数和迭代初始条件与4.2节空时谱估计性能时的参数设置保持一致。

由表2可见, FOCUSS算法和SBL算法需多次迭代, 且每次迭代中的运算复杂度与 NK 的三次幂相关。当回波数据的阵元个数和脉冲数增加时, 算法的运算量急剧增加。CNN和MDCNN算法采用离线训练-在线预测的模式, 其中绝大部分的运算量都在离线训练阶段。在实际的在线预测阶段, CNN和MDCNN算法的运算复杂度与 NK 线性相关, 明显少于FOCUSS和SBL算法。从运行时间角度来看, CNN和MDCNN算法的运行时间比FOCUSS和SBL算法低5个量级, 具有明显优势。同时, MDCNN算法的运行时间比CNN算法更短。

如图9所示, FOCUSS和SBL算法的运算复杂度均远大于CNN和MDCNN算法。当 $N = 8$ 时, 即本文处理MCARM数据时采用的参数设置, CNN和MDCNN算法的运算量较其他两种算法低约4个量级, 表2中的运行时间对比结果接近; 而当 $N = 72$, SBL算法的运算量比FOCUSS算法高2个量级, 较CNN和MDCNN算法高近9个量级。

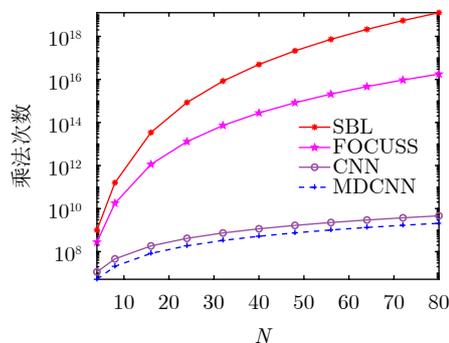


图9 运算复杂度对比

Fig. 9 Comparison of computational complexity

5 结语

传统STAP技术在处理实际非均匀杂波时面临可用训练样本不足的问题, 而SR STAP算法虽降低了对样本的需求, 但仍面临高运算量和模型失配等挑战。基于卷积神经网络的STAP方法可显著减少运算量且避免模型失配, 但缺乏网络可解释性; 而基于ADMM展开网络的STAP算法具备一定可解释性, 但网络较为复杂, 运算量仍然较大。为解决上述两个问题, 本文基于HQS和SR算法原理提出了MDCNN STAP算法。所构建神经网络可利用少量训练样本准确非线性拟合高分辨杂波空时谱, 进

而重构准确CCM。MDCNN STAP算法具备较好的网络可解释性，且能通过少量模块堆叠等效稀疏重构优化的大量迭代过程，实现小样本条件下对CCM的快速、准确、稳定估计。在复杂非均匀杂波环境下，所提方法实现了次最优的杂波抑制性能，并且在线运算量明显低于现有典型稀疏恢复类STAP方法。经MCARM实测数据处理验证，所提MDCNN STAP算法在主瓣杂波区性能略优于SBL STAP算法，并显著优于CNN STAP和FOCUSS STAP方法。同时，MDCNN STAP在运行时间上比SBL STAP算法减少了5个量级，因此更适用于实际工程应用。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no conflict of interests

参 考 文 献

- [1] 谢文冲, 王永良, 熊元斌. 机载雷达空时自适应处理[M]. 北京: 清华大学出版社, 2024: 1-8.
XIE Wenchong, WANG Yongliang, and XIONG Yuanyi. Airborne Radar Space-time Adaptive Processing[M]. Beijing: Tsinghua University Press, 2024: 1-8.
- [2] 谢文冲, 段克清, 王永良. 机载雷达空时自适应处理技术研究综述[J]. 雷达学报, 2017, 6(6): 575-586. doi: [10.12000/JR17073](https://doi.org/10.12000/JR17073).
XIE Wenchong, DUAN Keqing, and WANG Yongliang. Space time adaptive processing technique for airborne radar: An overview of its development and prospects[J]. *Journal of Radars*, 2017, 6(6): 575-586. doi: [10.12000/JR17073](https://doi.org/10.12000/JR17073).
- [3] BRENNAN L E and REED L S. Theory of adaptive radar[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1973, AES-9(2): 237-252. doi: [10.1109/TAES.1973.309792](https://doi.org/10.1109/TAES.1973.309792).
- [4] REED I S, MALLETT J D, and BRENNAN L E. Rapid convergence rate in adaptive arrays[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1974, AES-10(6): 853-863. doi: [10.1109/TAES.1974.307893](https://doi.org/10.1109/TAES.1974.307893).
- [5] WANG Yongliang, CHEN Jianwen, BAO Zheng, *et al.* Robust space-time adaptive processing for airborne radar in nonhomogeneous clutter environments[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(1): 70-81. doi: [10.1109/TAES.2003.1188894](https://doi.org/10.1109/TAES.2003.1188894).
- [6] DIPIETRO R C. Extended factored space-time processing for airborne radar systems[C]. The 26th Asilomar Conference on Signals, Systems and Computers, Pacific Grove, USA, 1992, 1: 425-430. doi: [10.1109/ACSSC.1992.269236](https://doi.org/10.1109/ACSSC.1992.269236).
- [7] DUAN Keqing, XU Hong, YUAN Huadong, *et al.* Reduced-DOF three-dimensional STAP via subarray synthesis for non sidelooking planar array airborne radar[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2020, 56(4): 3311-3325. doi: [10.1109/TAES.2019.2958174](https://doi.org/10.1109/TAES.2019.2958174).
- [8] MELVIN W L and GUERCI J R. Knowledge-aided signal processing: A new paradigm for radar and other advanced sensors[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2006, 42(3): 983-996. doi: [10.1109/TAES.2006.248215](https://doi.org/10.1109/TAES.2006.248215).
- [9] MELVIN W L and SHOWMAN G A. An approach to knowledge-aided covariance estimation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2006, 42(3): 1021-1042. doi: [10.1109/TAES.2006.248216](https://doi.org/10.1109/TAES.2006.248216).
- [10] YANG Zhaocheng, DE LAMARE R C, and LIU Weijian. Sparsity-based STAP using alternating direction method with gain/phase errors[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 53(6): 2756-2768. doi: [10.1109/TAES.2017.2714938](https://doi.org/10.1109/TAES.2017.2714938).
- [11] DUAN Keqing, WANG Zetao, XIE Wenchong, *et al.* Sparsity-based STAP algorithm with multiple measurement vectors via sparse Bayesian learning strategy for airborne radar[J]. *IET Signal Processing*, 2017, 11(5): 544-553. doi: [10.1049/iet-spr.2016.0183](https://doi.org/10.1049/iet-spr.2016.0183).
- [12] CUI Ning, XING Kun, YU Zhongjun, *et al.* Reduced-complexity subarray-level sparse recovery STAP for multichannel airborne radar WGMTI application[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 59(5): 6292-6313. doi: [10.1109/TAES.2023.3274104](https://doi.org/10.1109/TAES.2023.3274104).
- [13] WANG Degen, WANG Tong, CUI Weichen, *et al.* A clutter suppression algorithm via enhanced sparse Bayesian learning for airborne radar[J]. *IEEE Sensors Journal*, 2023, 23(10): 10900-10911. doi: [10.1109/JSEN.2023.3263919](https://doi.org/10.1109/JSEN.2023.3263919).
- [14] DUAN Keqing, CHEN Hui, XIE Wenchong, *et al.* Deep learning for high-resolution estimation of clutter angle-Doppler spectrum in STAP[J]. *IET Radar, Sonar & Navigation*, 2022, 16(2): 193-207. doi: [10.1049/rsn2.12176](https://doi.org/10.1049/rsn2.12176).
- [15] VENKATASUBRAMANIAN S, WONGKAMTHONG C, SOLTANI M, *et al.* Toward data-driven STAP radar[C]. 2022 IEEE Radar Conference (RadarConf22), New York, USA, 2022: 1-5. doi: [10.1109/RadarConf2248738.2022.9764354](https://doi.org/10.1109/RadarConf2248738.2022.9764354).
- [16] LIU Jing, LIAO Guisheng, XU Jingwei, *et al.* Autoencoder neural network-based STAP algorithm for airborne radar with inadequate training samples[J]. *Remote Sensing*, 2022, 14(23): 6021. doi: [10.3390/rs14236021](https://doi.org/10.3390/rs14236021).
- [17] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4): 395-411. doi: [10.12000/JR18040](https://doi.org/10.12000/JR18040).
WANG Jun, ZHENG Tong, LEI Peng, *et al.* Study on deep learning in radar[J]. *Journal of Radars*, 2018, 7(4): 395-411. doi: [10.12000/JR18040](https://doi.org/10.12000/JR18040).

- [18] YANG Yan, SUN Jian, LI Huibin, *et al.* ADMM-CSNet: A deep learning approach for image compressive sensing[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(3): 521–538. doi: [10.1109/TPAMI.2018.2883941](https://doi.org/10.1109/TPAMI.2018.2883941).
- [19] MA Jiawei, LIU Xiaoyang, SHOU Zheng, *et al.* Deep tensor ADMM-net for snapshot compressive imaging[C]. The IEEE/CVF International Conference on Computer Vision, Seoul, Korea (South), 2019: 10222–10231. doi: [10.1109/ICCV.2019.01032](https://doi.org/10.1109/ICCV.2019.01032).
- [20] MARQUES E C, MACIEL N, NAVINER L, *et al.* Deep learning approaches for sparse recovery in compressive sensing[C]. 2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA), Dubrovnik, Croatia, 2019: 129–134. doi: [10.1109/ISPA.2019.8868841](https://doi.org/10.1109/ISPA.2019.8868841).
- [21] ZHANG Kai, VAN GOOL L, and TIMOFTE R. Deep unfolding network for image super-resolution[C]. The IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2020: 3214–3223. doi: [10.1109/CVPR42600.2020.00328](https://doi.org/10.1109/CVPR42600.2020.00328).
- [22] BEN SAHEL Y, BRYAN J P, CLEARY B, *et al.* Deep unrolled recovery in sparse biological imaging: Achieving fast, accurate results[J]. *IEEE Signal Processing Magazine*, 2022, 39(2): 45–57. doi: [10.1109/MSP.2021.3129995](https://doi.org/10.1109/MSP.2021.3129995).
- [23] ZOU Bo, WANG Xin, FENG Weike, *et al.* DU-CG-STAP method based on sparse recovery and unsupervised learning for airborne radar clutter suppression[J]. *Remote Sensing*, 2022, 14(14): 3472. doi: [10.3390/rs14143472](https://doi.org/10.3390/rs14143472).
- [24] 朱晗归, 冯为可, 冯存前, 等. 机载雷达深度展开空时自适应处理方法[J]. 雷达学报, 2022, 11(4): 676–691. doi: [10.12000/JR22051](https://doi.org/10.12000/JR22051).
- ZHU Hangui, FENG Weike, FENG Cunqian, *et al.* Deep unfolding based space-time adaptive processing method for airborne radar[J]. *Journal of Radars*, 2022, 11(4): 676–691. doi: [10.12000/JR22051](https://doi.org/10.12000/JR22051).
- [25] SANYAL P K. STAP processing monostatic and bistatic MCARM data[R]. MITRE Technical Report AFRL-SN-RS-TR-1999-197, 1999.
- [26] 周宇, 张林让, 刘楠, 等. 非均匀环境下利用杂波脊信息的杂波滤除方法研究[J]. 电子与信息学报, 2010, 32(6): 1332–1337. doi: [10.3724/SP.J.1146.2009.01104](https://doi.org/10.3724/SP.J.1146.2009.01104).
- ZHOU Yu, ZHANG Linrang, LIU Nan, *et al.* Study on exploring knowledge of the clutter ridge for clutter suppression in heterogeneous environments[J]. *Journal of Electronics & Information Technology*, 2010, 32(6): 1332–1337. doi: [10.3724/SP.J.1146.2009.01104](https://doi.org/10.3724/SP.J.1146.2009.01104).
- [27] SUN Ke, MENG Huadong, WANG Yongliang, *et al.* Direct data domain STAP using sparse representation of clutter spectrum[J]. *Signal Processing*, 2011, 91(9): 2222–2236. doi: [10.1016/j.sigpro.2011.04.006](https://doi.org/10.1016/j.sigpro.2011.04.006).

作者简介

廖志鹏, 博士生, 主要研究方向包括深度学习、阵列信号处理、空时自适应处理等。

段克清, 副教授, 博士生导师, 主要研究方向包括机载/星载雷达信号处理、阵列信号处理、空时自适应处理等。

何锦浚, 硕士生, 主要研究方向包括双基地机载雷达信号处理、阵列信号处理、空时自适应处理等。

邱梓洲, 博士生, 主要研究方向包括MIMO雷达信号处理、阵列信号处理、空时自适应处理等。

王永良, 教授, 博士生导师, 主要研究方向包括雷达信号处理、空时信号处理、阵列信号处理等。

(责任编辑: 高山流水)