

基于 CNN-LSTM 神经网络的前视成像算法

孙晓翰¹, 李凉海², 张彬¹

(1 北京遥测技术研究所 北京 100076;

2 中国航天电子技术研究院 北京 100094)

摘要: 雷达前视成像作为雷达成像领域的难点与重点, 在自动驾驶、导航、精确制导等方面具有广阔的应用前景。传统的前视成像算法受限于天线孔径的宽度, 无法实现高分辨率的成像, 本文使用卷积神经网络 (Convolutional Neural Networks, CNN) 与长短期记忆 (Long Short-Term Memory, LSTM) 网络相结合实现前视成像中方位角的预测, 首先介绍了扫描前视成像信号的类卷积模型及其病态性, 利用脉冲压缩以及距离徙动校正对回波信号预处理, 输入 CNN-LSTM 神经网络逐距离单元进行方位角估计。仿真结果表明: 算法能有效提高前视成像的方位分辨率, 实现前视成像的超分辨。

关键词: 前视成像; 深度学习; 卷积神经网络; 病态性逆问题

中图分类号: TP18; TP75 文献标志码: A 文章编号: 2095-1000(2024)02-0029-08

DOI: 10.12347/j.ycyk.20231225001

引用格式: 孙晓翰, 李凉海, 张彬. 基于 CNN-LSTM 神经网络的前视成像算法[J]. 遥测遥控, 2024, 45(2): 29-36.

Forward-looking Imaging Algorithm Based on CNN-LSTM Neural Network

SUN Xiaohan¹, LI Lianghai², ZHANG Bin¹

(1. Beijing Research Institute of Telemetry, Beijing 100076, China;

2. China Academy of Aerospace Electronics Technology, Beijing 100080, China)

Abstract: As a difficulty and focus in the field of radar imaging, radar forward-looking imaging has broad application prospects in automatic driving, navigation, precision guidance and so on. The traditional forward-looking imaging algorithm is limited by the width of the antenna aperture and cannot achieve high-resolution imaging. In this paper, CNN (Convolutional Neural Networks) neural network and LSTM (Long Short-Term Memory) neural network are combined to realize the prediction of azimuth in forward-looking imaging. Firstly, the convolution-like model of the scanning forward-looking imaging signal and its ill-posedness are introduced. The echo signal is preprocessed by pulse compression and range migration correction, and input into the CNN-LSTM neural network to perform azimuth estimation by range unit. The simulation results show that the algorithm can effectively improve the azimuth resolution of forward-looking imaging and realize the super-resolution of forward-looking imaging.

Keywords: Forward-looking imaging; Deep learning; Convolutional neural network; Ill-posed inverse problem

Citation: SUN Xiaohan, LI Lianghai, ZHANG Bin. Forward-looking Imaging Algorithm Based on CNN-LSTM Neural Network[J]. Journal of Telemetry, Tracking and Command, 2024, 45(2): 29-36.

0 引言

雷达成像技术是一种利用雷达系统生成目标图像的技术。它通过发射无线电波, 接收目标表面反射回来的信号, 然后通过分析这些信号生成目标的空间位置、形状和运动信息。雷达成像的工作原理包括发射脉冲或连续波, 通过调整雷达波束的方向和形状来扫描感兴趣区域^[1]。多普勒锐化技术(Doppler Beam Sharpening, DBS)^[2,3]与合成孔

径雷达(Synthetic Aperture Radar, SAR)^[4-6]是常见的雷达成像技术, 前者通过观测平台与目标之间的运动产生的多普勒频移来分辨目标的方位信息, 后者通过在雷达平台运动中合成长孔径来提高成像分辨率。雷达成像技术因其在各种天气条件下的全天候性和在复杂环境中的高效性而受到青睐, 广泛应用于军事、气象、地质勘探、自动驾驶等领域。

当雷达处在前视位置时, 平台的运动方向与

波束指向一致, 等距离线与等多普勒线平行, DBS与SAR技术同时失效^[7], 而一般的实波束前视成像技术受限于雷达的天线孔径宽度, 无法实现高分辨成像。各国学者在此领域展开了诸多的探索和研究, 提出了多种解决方案。文献[8-12]利用和差测角原理, 将单脉冲技术与前视成像结合, 提高了方位向的分辨率, 但无法精确分辨同一波束内的多个目标, 存在一定的缺陷; 双基地SAR技术^[13-15], 由于其复杂的时空同步、几何构型等问题, 使得其在实际应用中存在一定的难度; 解卷积成像技术^[16-22]的本质是信号还原技术, 其将同距离单元回波信号建模为目标散射系数与天线方向图的类卷积模型, 通过解卷积运算反演方位向的目标分布函数。

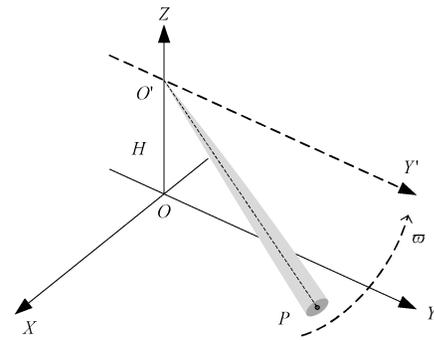
近几年来, 随着深度学习的迅速兴起, 深度学习网络在逆问题求解中得到广泛应用, 如图像超分辨、图像去噪、图像复原等光学图像逆问题, 在图像重构质量和工作效率方面均表现优异, 成为解决逆问题的主流方法。深度神经网络(Deep Neural Networks, DNN)基于数据驱动通过监督学习的方式自动从数据中学习先验知识, 以获得更加适用于观测场景的先验信息。通过网络训练去探索观测数据与重构图像之间复杂的非线性映射关系, 自行建立隐式成像模型, 以最大限度拟合输入与输出的精确映射关系, 具有较强的适应能力。同时, DNN将优化过程和计算压力集中在网络训练阶段, 训练完成后, 基于DNN的测试过程具有较高的工作效率。因此, 深度学习理论为突破当前雷达成像技术的瓶颈提供了全新思路^[23,24]。

传统的雷达前视成像算法在收敛速度、计算复杂度和成像分辨率等方面存在一些局限性。本论文致力于探讨一种基于CNN-LSTM神经网络的新型雷达前视成像算法, 旨在提高前视成像的分辨率和系统的稳健性。深度学习的引入使得我们能够从大规模数据中学习复杂的目标特征, 从而更好地适应不同的场景和目标类型。

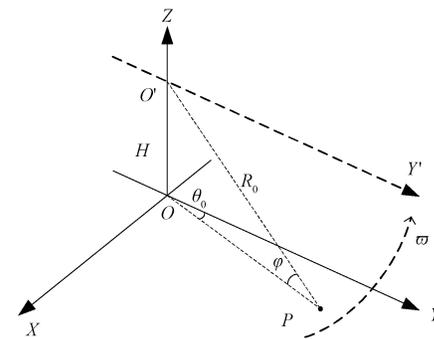
1 扫描前视成像模型

1.1 静止的几何模型

扫描前视成像的静止几何模型如图1所示, 图1(a)为雷达扫描过程图, 图1(b)给出了静止雷达与点目标的几何关系图。如图1(a)所示, 雷达平台与目标保持相对静止。



(a) Scanning process



(b) Geometric relations

图1 静止几何模型图

Fig. 1 Static geometric model diagram

如图1(a), 假设机载雷达平台处于 O' 位置, 目标在 XOY 平面, 平台垂直高度为 H , 天线波束以角速度 ω 沿逆时针方向对目标进行扫描。雷达天线波束初始方位角为 θ_0 , 俯仰角为 φ_0 。如图1(b), 以点 P 为例, $t=0$ 时刻, 机载平台与目标之间的方位夹角为 θ_0 , 距离为 R_0 ; 在 t 时刻, 机载平台与目标之间的方位向夹角变为 θ_t , 但由于目标始终在天线波束扫描范围内, 瞬时斜距 R_t 仍为 R_0 , 表示为 $R_t=R_0$ 。

1.2 回波模型

对于前视成像, 一般采用线性调频信号:

$$s(\tau) = \text{rect}\left(\frac{\tau}{T_r}\right) e^{j2\pi\left(f_c\tau + \frac{1}{2}\gamma\tau^2\right)} \quad (1)$$

其中, τ 为发射信号的快时间, T_r 为脉宽, γ 为调频率, $\text{rect}(u)$ 为矩形信号。

$$\text{rect}(u) = \begin{cases} 1 & u \leq \frac{1}{2} \\ 0 & u > \frac{1}{2} \end{cases} \quad (2)$$

以点 P 为例进行回波分析, 初始作用距离为 R_0 , 目标反射系数为 σ_0 , 可得回波为:

$$\mathbf{y}'_k = \sigma \left(\sum_{i \in M'_k} \mathbf{x}'_i * \mathbf{w}'_k + \mathbf{b}'_k \right) \quad (12)$$

其中, \mathbf{y} 为输出矢量, \mathbf{x} , \mathbf{w} 分别为输入矢量和卷积核, \mathbf{b} 表示为偏置矢量, $\sigma(\cdot)$ 为线性整流函数(Linear Rectification Function, ReLU)。

利用最大池化层压缩数据信息, 降低维度, 计算公式为:

$$\mathbf{y}'_k^{i+1} = \text{maxpool}(\mathbf{y}'_k) = \max[\mathbf{y}'_k(2i), \mathbf{y}'_k(2(i-1))] \quad (13)$$

经过特征提取后, 通过全连接的方式连接到回归层, 全连接层的公式为:

$$\mathbf{y}'_k = \sigma(\mathbf{x}'_i * \mathbf{w}'_k + \mathbf{b}'_k) \quad (14)$$

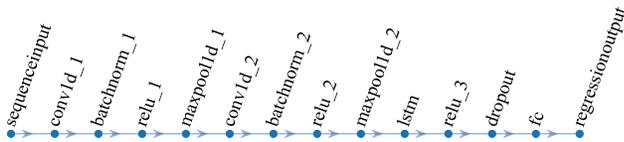


图2 CNN-LSTM神经网络结构
Fig. 2 CNN-LSTM neural network structure

图2所示为神经网络的结构, 其中卷积层的时间复杂度为 $O(M^2 \cdot K^2 \cdot C_{in} \cdot C_{out})$, 其中 M 为特征图边长, K 为卷积核的边长, C 为输入输出的通道数。LSTM层的时间复杂度为 $O(4 \cdot T \cdot h^2 + 4 \cdot T \cdot n \cdot h)$, 其中, T 为输入序列长度, n 为特征维度, h 为隐含状态维度。如图, 神经网络有两个卷积层, 一个LSTM层, 故该算法的时间复杂度为:

$$O(2 \cdot M^2 \cdot K^2 \cdot C_{in} \cdot C_{out} + 4 \cdot T \cdot h^2 + 4 \cdot T \cdot n \cdot h) \quad (15)$$

2.3 网络训练方法

在给定场景中生成多个目标点, 其位置和目標散射系数均服从高斯分布, 仿真生成目标在前视区域下的回波数据, 对回波数据进行脉冲压缩处理使其距离向固定, 得到前视实波束成像, 逐距离单元输入神经网络, 输出预测方位向目标散射系数, 仿真点位置与仿真的目标散射系数为真实值。

网络训练模式为监督训练, 使用均方根误差函数(Root Mean Squared Error, RMSE)作为损失函数, 表达式为:

$$\text{Loss}(y_i, \hat{y}_i) = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (16)$$

其中 y_i 是预测值, \hat{y}_i 是真实值, N 为序列元素个数。

训练中采用SGDM梯度下降算法更新权值,

更新公式为:

$$\begin{aligned} V_{\text{new}} &= V_{\text{old}} \times \eta + \alpha \times \Delta T \\ W_{\text{new}} &= W_{\text{old}} + V_{\text{new}} \end{aligned} \quad (17)$$

其中, V 为动量因子, W 为网络权值, ΔT 为梯度, η 为动量系数, α 为学习率。本文网络的学习率为 $1E-5$, 每 800 次迭代下降一次, 学习率下降因子为 0.1。

2.4 算法流程

综上所述, 本文提出了基于 CNN-LSTM 神经网络的前视成像算法, 该算法对接收后的信号进行距离向处理, 逐距离单元输入神经网络, 实现方位向的精准估计。

雷达前视成像的 CNN-LSTM 算法流程图如图 3 所示, 算法训练主要步骤如下:

- ① 对训练集数据进行脉冲压缩处理, 实现距离向上的超分辨;
- ② 逐距离单元输入神经网络, 输出方位向预测结果;
- ③ 计算损失函数, 利用反向传播机制与SGDM梯度下降算法更新神经网络权值;
- ④ 经过一定次数的迭代, 使损失函数最小;
- ⑤ 利用测试集对算法功能性进行验证;
- ⑥ 训练完成。

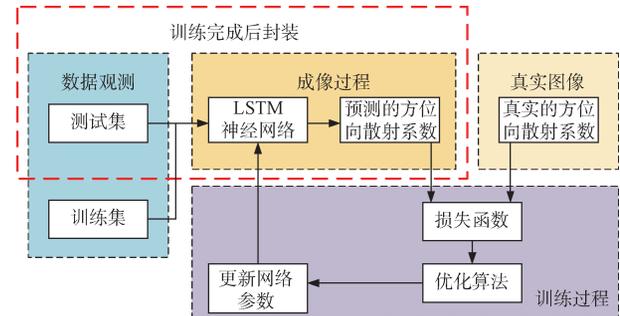


图3 基于 LSTM 神经网络的前视成像算法流程图
Fig.3 Flow chart of forward-looking imaging algorithm based on LSTM neural network

2.5 仿真结果及分析

为了验证本文所提基于 CNN-LSTM 神经网络的前视成像算法的有效性, 本节分别进行了点目标以及场景的前视成像仿真实验。为了衡量算法对实孔径成像的分辨率改善程度, 本文定义超分辨系数为:

$$\alpha = \Delta L / \Delta L_{\text{real}} \quad (18)$$

其中, ΔL 为实孔径雷达的前视成像分辨率, ΔL_{real}

为超分辨算法的分辨率。

在表1给定的雷达参数下，在成像区域中放置了10个点目标，距离和方位分别为：

表1 雷达参数

Table 1 Radar parameters

参数名	参数值	参数名	参数值
载频Fc	10 GHz	波束扫描速度	40 (°)/s
带宽B	100 M	波束主瓣宽度	5.37°
时宽Tp	1.5 μs	距离分辨率	0.5 m
采样频率Fs	200 M	距离范围	4 000 m ~ 5 000 m
脉冲重复频率PRF	4 000	扫描角范围	-5°~5°
信噪比	0~10 dB	扫描积累脉冲数	100

$$R=[4\ 200, 4\ 400, 4\ 400, 4\ 600, 4\ 600, 4\ 600, 4\ 800, 4\ 800, 4\ 800, 4\ 800]$$

$$\theta=[0^\circ, -1^\circ, 1^\circ, -1^\circ, 0^\circ, 1^\circ, -3^\circ, -0.1^\circ, 0.1^\circ, 3^\circ]$$

(19)

图4给出了仿真的实波束成像图，可以看出，同一距离单元内的多个点目标的回波发生了混叠现象，无法进行高分辨成像，这是因为点目标之间的角度差小于波束宽度，实波束成像算法失效，此时成像分辨率约为 $\theta \times R = 421.76\text{ m}$ 。

图5给出了在不同信噪比下的基于CNN-LSTM神经网络算法处理后的成像结果图。可以看出：在0~10 dB的信噪比区间下，图像均有明显目标亮点，可以清晰地分辨；其中，在0 dB条件下存在幅度较小的噪点。在10 dB的信噪比条件下

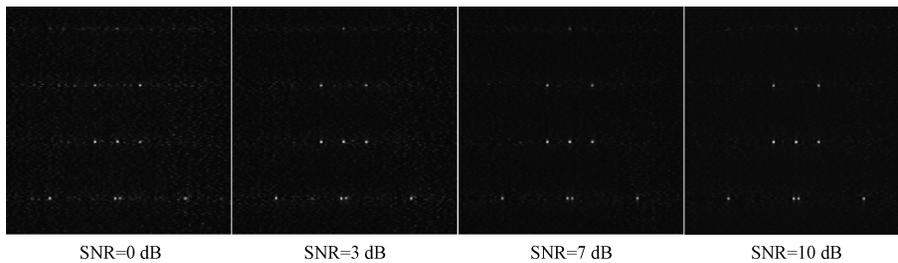
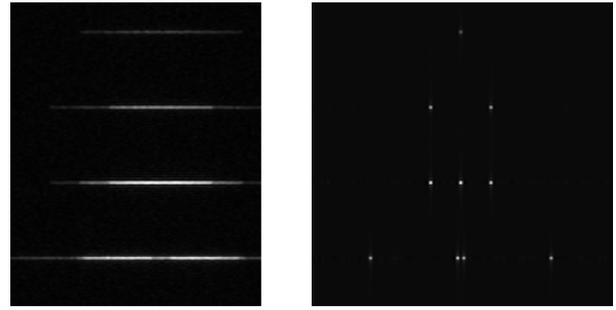


图5 点目标仿真结果

Fig.5 Point target simulation results

进一步分析算法的方位向分辨率，图7给出了在10 dB条件下某一距离单元的两种成像结果对比图。可以看出：图7(a)实波束成像对同个波束内多个点成像失效，四个目标的方位向信息混叠，无法分辨其位置与幅度。图7(b)中可以看出：基于CNN-LSTM算法的扫描方位向分辨结果出现四个峰值，并与实际波达方向一致，其中，中间两点



(a) 实波束成像
(b) 仿真基准图
(a) Real beam imaging
(b) Simulation benchmark image

图4 仿真基准图和实波束成像图

Fig.4 Simulation benchmark image and real beam imaging image

时，目标点清晰可见且没有明显噪点，有较好的噪声抑制能力。

为了进一步定量分析不同信噪比条件下算法的成像效果，进行了100次蒙特卡洛实验，统计得在不同信噪比下的均方根误差(Root Mean Square Error, RMSE)，其定义为：

$$\zeta_{\text{RMSE}} = \frac{1}{K} \sum_{k=1}^K \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (20)$$

其中， K 为蒙特卡洛实验次数，图6给出了该算法在不同SNR条件下的均方根误差的变化曲线。从图中可以看出，随着SNR的提升，RMSE大幅度降低，在SNR>9 dB时趋于平稳，得到最佳成像效果。

的角度为-0.1与0.1，证明该算法可以对目标角度大于0.1°的目标点进行分辨，分辨率约为 $\theta \times R = 15.7\text{ m}$ 。

为进一步验证CNN-LSTM网络模型的成像适用性，选用一幅高分辨SAR图像作为仿真场景，生成雷达回波信号，并进行成像处理，如图8所示。图8(a)为实波束成像，图8(b)为本文所提算法

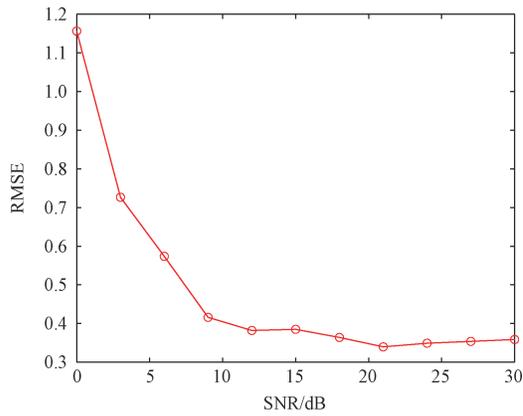


图 6 不同信噪比条件下的预测图像的 RMSE

Fig.6 RMSE of predicted images under different signal-to-noise ratio conditions

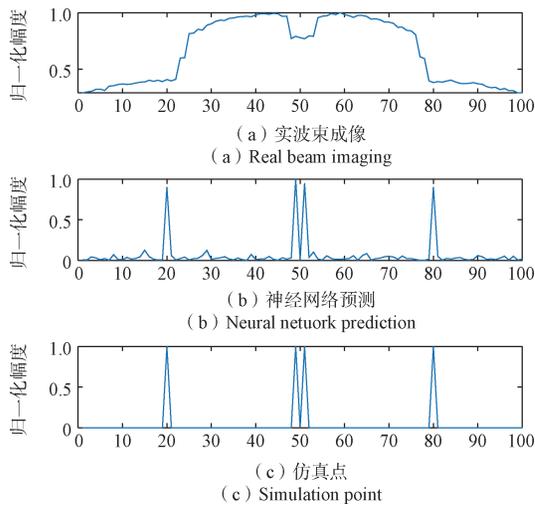


图 7 10 dB 条件下某一距离单元的两成像结果对比图

Fig.7 Comparison of two kinds of imaging results of a certain distance unit with 10 dB condition

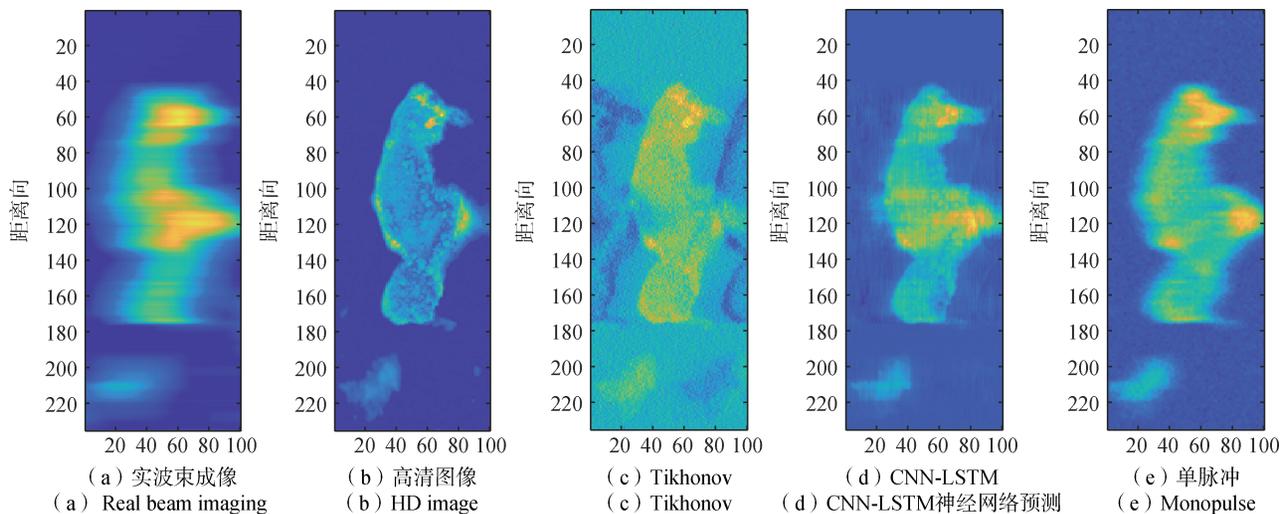


图 8 面目标场景成像结果

Fig.8 Surface target scene imaging results

的成像结果, 图 8(c)为仿真所用的高清图像。本文所提算法的成像结果中海岸分辨明显, 强散射目标清晰可见, 前视成像效果较好。

为进一步验证 CNN-LSTM 网络模型的成像适用性, 选用一副高分辨 SAR 图像作为仿真场景, 生成雷达回波信号, 并用多种算法进行成像处理, 如图 8 所示, 图 8(a)为经过脉压处理的实波束成像, 图 8(b)为仿真所用的高清图像, 图 8(c)、图 8(d)、图 8(e)分别为 SNR=10 dB 情况下三种不同的前视成像算法, 可以看出, 基于 Tikhonov 正则化的传统解卷积算法对噪声敏感, 极易受到噪声干扰, 且图像存在混叠现象; 单脉冲前视成像算法在面非稀疏场景时存在散焦现象, 边界轮廓不清晰; 而本文所提算法的成像结果中海岸分辨明显, 强散射目标清晰可见, 同时对噪声有着一定的抑制能力, 前视成像效果较好。

成像距离为 4 500 m, 波束宽度为 5.37°, 根据公式:

$$\Delta L = \theta \times R \tag{21}$$

可得实波束分辨率约为 421.76 m。

扫描解卷积成像模型中, 扫描角范围为[-5°, 5°], 计算可得方位向扫描宽度为 1 570.8 m, 匀速扫描 100 个脉冲, 理论分辨率为 15.7 m, 可得该模型下的超分辨率系数为:

$$\Delta L / \Delta L_{real} \approx 26.85 \tag{21}$$

该成像算法的超分辨率系数为 26.85。该结果与点目标仿真所得超分辨率系数一致。

通过上述仿真实验, 分析了静止平台前视成

像模式下各种基于CNN-LSTM的超分辨成像方法的成像效果和分辨率改善情况,对不同信噪比情况下的成像效果进行了对比,验证了基于CNN-LSTM的前视成像方法能够在远距低信噪比环境下进一步提高方位向分辨率。

3 结束语

前视成像的传统算法中,实波束成像受限于孔径宽度回波易发生混叠现象,分辨率较低,而解卷积前视成像在面对简单场景时可以成像,但面对复杂场景时成像效果不佳,本文针对解卷积前视成像的病态性进行了分析,提出了一种基于CNN-LSTM神经网络的前视成像算法。该算法通过学习仿真方位向回波与目标散射系数的非线性关系来预测场景的方位向目标分布函数,仿真结果表明:该算法可以有效提高前视成像的方位分辨率。

参考文献

- [1] 保铮,邢孟道,王彤. 雷达成像技术[M]. 电子工业出版社, 2005.
- [2] 陈洪猛. 机载广域监视雷达高分辨成像方法研究[D]. 西安: 西安电子科技大学, 2016.
- [3] MAO D, ZHANG Y, ZHANG Y, et al. Doppler beam sharpening using estimated Doppler centroid based on edge detection and fitting[J]. IEEE Access, 2019, 7(99): 123604-123615.
- [4] MOREIRA A, HUANG Y. Airborne SAR processing of highly squinted data using a chirp scaling approach with integrated motion compensation[J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(5): 1029-1040.
- [5] MOREIRA A, PRATS-IRAOLA P, YOUNIS M, et al. A tutorial on synthetic aperture radar[J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(1): 6-43.
- [6] LI Z, XING M, LIANG Y, et al. A frequency-domain imaging algorithm for highly squinted SAR mounted on maneuvering platforms with nonlinear trajectory[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(7): 4023-4038.
- [7] 庞礴,代大海,邢世其,等. 前视SAR成像技术的发展和展望[J]. 系统工程与电子技术, 2013, 35(11): 2283-2290. PANG Bo, DAI Dahai, XING Shiqi, et al. Development and perspective of forward-looking SAR imaging technique[J]. Systems Engineering and Electronics, 2013, 35(11): 2283-2290.
- [8] 吴迪,朱岱寅,田斌,等. 单脉冲成像算法性能分析[J]. 航空学报, 2012, 33(10): 1905-1914.
- [9] 杨成杰. 单脉冲雷达前视成像技术研究[D]. 南京: 南京航空航天大学, 2017.
- [10] 吴迪,杨成杰,朱岱寅等. 一种用于单脉冲成像的自聚焦算法[J]. 电子学报, 2016, 44(08): 1962-1968. WU Di, YANG Chengjie, ZHU Daiyin, et al. An autofocusing algorithm for monopulse imaging[J]. Acta Electronica Sinica, 2016, 44(08): 1962-1968.
- [11] CHEN H, LU Y, MU H, et al. Knowledge-aided monopulse forward-looking imaging for airborne radar by exploiting the antenna pattern information[J]. Electronics Letters, 2017, 53(8): 566-568.
- [12] 李悦丽,马萌恩,赵崇辉,等. 基于单脉冲雷达和差通道多普勒估计的前视成像[J]. 雷达学报, 2021, 10(1): 131-142. LI Yueli, MA Meng'en, ZHAO Chonghui, et al. Forward-looking imaging via Doppler estimates of sum-difference measurements in scanning monopulse radar[J]. Journal of Radars, 2021, 10(1): 131-142.
- [13] PU W, WU J, HUANG Y, et al. Fast factorized backprojection imaging algorithm integrated with motion trajectory estimation for bistatic forward-looking SAR[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(10): 3949-3965.
- [14] 梅海文,孟自强,李亚超,等. 双基前视SAR几何定位及同步误差分析[J]. 电子与信息学报, 2018, 40(4): 882-889. MEI Haiwen, MENG Ziqiang, LI Yachao, et al. Bistatic forward-looking SAR geometrical positioning and analysis of synchronization error[J]. Journal of Electronics and Information Technology, 2018, 40(4): 882-889.
- [15] LI Y, ZHANG T, MEI H, et al. Focusing translational-variant bistatic forward-looking SAR data using the modified Omega-K algorithm[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, (99): 1-16.
- [16] 周静. 相控阵雷达前视成像算法研究[D]. 西安: 西安电子科技大学, 2021.
- [17] 陈洪猛,李明,王泽玉等. 基于多帧数据联合处理的机载单通道雷达贝叶斯前视成像[J]. 电子与信息学报, 2015, 37(10): 2328-2334. CHEN Hongmeng, LI Ming, WANG Zeyu, et al. Bayesian forward-looking imaging for airborne single-channel radar based on combined multiple frames data[J]. Journal of Electronics & Information Technology, 2015, 37(10): 2328-2334.
- [18] CHEN H M, LI M, WANG Z, et al. Sparse super-

- resolution imaging for airborne single channel forward-looking radar in expanded beam space via l_p regularisation[J]. Electronics Letters, 2015, 51(11): 863-865.
- [19] LI Y, LIU J, JIANG X, et al. Angular superresolution for signal model in coherent scanning radars[J]. IEEE Transactions on Aerospace & Electronic Systems, 2019, 55(6): 3103-3116.
- [20] TUO X, ZHANG Y, HUANG Y, et al. Fast sparse-TSVD super-resolution method of real aperture radar forward-looking imaging[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(8): 6609-6620.
- [21] IVERSON D D. Beam sharpening via multikernal deconvolution[C]// CIE International Conference on Radar, 2001.
- [22] 李悦丽, 梁甸农, 黄晓涛. 一种单脉冲雷达多通道解卷积前视成像方法[J]. 信号处理, 2007(5): 699-703.
LI Yueli, LIANG Diannong, HUANG Xiaotao. A multi-channel deconvolution based on forward-looking imaging method in monopulse radar[J]. Signal Processing, 2007(5): 699-703.
- [23] 张云, 穆慧琳, 姜义成, 等. 基于深度学习的雷达成像技术研究进展[J]. 雷达科学与技术, 2021, 19(5): 467-478.
ZHANG Yun, MU Huilin, JIANG Yicheng, et al. Overview of radar imaging techniques based on deep learning[J]. Radar Science and Technology, 2021, 19(5): 467-478.
- [24] 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.
WANG Jun, ZHENG Tong, LEI Peng, et al. Study on deep learning in radar[J]. Journal of Radars, 2018, 7(4): 395-411.

[作者简介]

- 孙晓翰 1998年生, 硕士研究生。
李凉海 1965年生, 硕士, 研究员。
张彬 1981年生, 硕士, 研究员。

(本文编辑: 杨秀丽)