

# 基于U-Net网络的二维MIMO阵型稀疏成像

王 韬, 尹丽娟, 杨文龙, 柳 荧

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2024年4月24日; 录用日期: 2024年5月23日; 发布日期: 2024年5月31日

## 摘 要

传统雷达成像算法在处理不规则阵型的MIMO雷达成像时存在着诸多挑战。这些传统算法通常计算复杂且耗时长, 难以满足MIMO雷达对实时成像的要求。因此, 迫切需要一种适用于任意阵型且具备实时成像能力的新型成像算法。考虑到神经网络具有自学习、自组织和自适应等特点, 并已广泛应用于雷达成像领域, 因此提出了一种基于神经网络的二维MIMO不规则阵型稀疏成像算法。神经网络的训练通常需要大量的数据集, 而构建回波数据集的过程耗时较长。为了解决这一问题, 选择了U-Net网络结构, 该结构在少量数据集下也能进行有效训练。我们将神经网络算法得到的成像结果与传统的BP算法进行了对比。结果表明, 在相同数据集的条件下, 神经网络算法表现出更优异的成像性能和更短的成像时间, 从而实现了二维MIMO不规则阵型的高分辨率实时成像。

## 关键词

MIMO雷达成像, 深度学习, U-Net, 高分辨率成像

# U-Net Network-Based Two-Dimensional MIMO Array Sparse Imaging

Tao Wang, Lijuan Yin, Wenlong Yang, Ying Liu

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Apr. 24<sup>th</sup>, 2024; accepted: May. 23<sup>rd</sup>, 2024; published: May. 31<sup>st</sup>, 2024

## Abstract

Traditional radar imaging algorithms face numerous challenges when dealing with irregular MIMO radar imaging. These traditional algorithms are often complex and time-consuming, making

it difficult to meet the real-time imaging requirements of MIMO radar. Therefore, there is an urgent need for a novel imaging algorithm that is applicable to arbitrary array configurations and possesses real-time imaging capabilities. Considering the self-learning, self-organizing, and adaptive characteristics of neural networks, which have been widely applied in the field of radar imaging, a two-dimensional MIMO irregular array sparse imaging algorithm based on neural networks is proposed. Neural network training typically requires large datasets, and the process of constructing echo datasets is time-consuming. To address this issue, the U-Net network structure was chosen, which can effectively train with small datasets. We compared the imaging results obtained from the neural network algorithm with those from the traditional BP algorithm. The results demonstrate that under the same dataset conditions, the neural network algorithm exhibits superior imaging performance and shorter imaging time, thereby achieving high-resolution real-time imaging of two-dimensional MIMO irregular arrays.

## Keywords

MIMO Radar Imaging, Deep Learning, U-Net, High-Resolution Imaging

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

无论是稀疏 MIMO 还是 MIMO 雷达成像技术[1] [2], 其获取数据的方式都是并行的, 数据的观测通道为相对于发射机和接收机阵列的空间卷积, 这一点就明显区别于传统的合成孔径雷达[3] [4]和逆合成孔径雷达[5], 原因是传统的雷达一般都是基于天线本身进行收发共置, 并在时间上按顺序进行数据的采集。稀疏 MIMO 雷达在 MIMO 雷达的基础上进行稀疏降采样, 使得其阵型中阵元的位置更加的随机, 而阵型的不均匀性使得传统成像算法无法适用或者并不能满足其实时性的成像需求。

在稀疏 MIMO 雷达成像的研究中, 最早是由卓克索大学的 Y. Yu 等人研究将 CS 理论应用于 MIMO 雷达成像中[6], 研究中发现, 对于目标是静止的雷达成像, 利用目标在角度和距离空间域中的稀疏性, 可以使得收集到的很少的一部分采样数据利用稀疏重构技术就可以得到与全数据利用传统成像算法相似的成像效果, 特别是外部噪声比较大的情况下, 稀疏信号的成像性能要大大优于传统的成像。由于大场景中常规的 MIMO 雷达, 收发天线的数量较多, 电子科技大学的顾福飞、池龙等人提出了一种基于稀疏布阵的稀疏 MIMO 阵列, 该方法不仅减少了 MIMO 大阵列雷达成像的天线数目, 更加便于工程实现, 不增加硬件设计的难度, 降低处理采集数据的时间和工作量[7]。但是基于稀疏布阵的 MIMO 阵型由于阵型的不规则特性, 导致很多传统算法的成像适应性差或者成像需要的时间过长, 而不能满足 MIMO 雷达的实时性高分辨率成像。为了更好的适应阵型的不规则性和满足实时成像的需求, 需要引入对于目标特征具有自学习、自组织和自适应的神经网络等多种智能算法。

2016 年, RA Valente 等人提出了一种由人工神经网络(ANN)辅助的新的 MIMO 发射方案, 实现了双倍频谱效率的 MIMO 传输方案[8]。2017 年, J Gao, B Deng 等人研究了使用复值卷积神经网络加强雷达成像, 达到了引入 CNN 网络来提高雷达成像性能的目的[9]。2018 年, Dai Y 等人利用基于深度学习的单一图像超分辨率方法来提高合成孔径雷达和 MIMO 雷达的图像质量, 结果达到了两个神经网络都能锐化主波, 抑制侧波和光栅波, 并发现更深的神经网络有更好的性能[10]。2019 年, C Hu, L Wang 等人研究

了使用完全卷积神经网络的逆向合成孔径雷达成像,实现了基于 FCNN 的 ISAR 成像方法在图像质量和计算效率方面都优于最先进的 CS ISAR 成像方法[11]。2020 年,叶国耀等人提出了一种基于生成对抗网络的合成孔径雷达成像图像聚焦增强算法,来拟合未知的核函数,实现窄带成像的全聚焦恢复[12]。同年,Cheng Qiao 等人将 CS 和卷积神经网络(CNN)结合起来用于 MIMO 雷达成像,这种基于 CS 的 CNN (CS-CNN)方法保持了 CS 方法的良好特性,如稀疏采样和高分辨力,但没有耗时的计算机优化和对数据存储空间的要求[13]。

因为 BP 算法需要将每个网格点和阵元点逐点进行处理,所以其成像操作中运算量巨大,并不能满足 MIMO 雷达成像的实时性需求,而目前兴起的神经网络因其具有自学习、自组织、自适应性等优势,已经引起了广泛的关注。本章就神经网络具有的优势,提出一种基于神经网络的 MIMO 不规则阵型的稀疏成像算法,用于解决稀疏 MIMO 不规则阵型的传统成像算法适应性差、运行时间长等问题。而神经网络的训练,需要大量的训练数据集,为了获得神经网络的训练数据集,采用本文设计好的稀疏 MIMO 不规则阵型,构建训练回波数据集和图像标签数据集,使用“Fashion-MNIST”图像数据集[14]作为构建回波的目标。然后,对于图像标签集的构建,所以采用两种方式,一种是使用 BP 算法对仿真出的回波进行成像,成像的结果作为训练神经网络对应的图像标签集,另外一种方式就是直接将“Fashion-MNIST”图像数据集作为训练神经网络的图像标签集,进行网络的训练,采用两种方式的目的是用于验证神经网络算法对于目标特征提取的优越性。分别训练出适用于稀疏 MIMO 不规则阵型的两种神经网络算法,与传统的 BP 算法进行成像对比,并对两种图像标签集训练出来的网络分别进行成像对比。结果表明,神经网络算法表现出更优异的成像性能和更短的成像时间,从而实现了二维 MIMO 不规则阵型的高分辨率实时成像。

## 2. 方法概述

传统的 MIMO 雷达成像算法 BP 算法应用于稀疏 MIMO 不规则阵型的雷达成像中,在适用性方面, BP 算法展示出了对于特殊阵型的适用性,以及良好的成像效果。但是由于 BP 算法需要对每个发射接收阵元对应于整个成像网格进行逐点遍历,所以其计算量巨大,特别不适用于大阵型的成像场景,而成像时间过于长,也不能满足 MIMO 雷达成像的实时性需求。同时也考虑到目前针对稀疏 MIMO 不规则阵型的传统成像算法适用性较差的问题,在本文将提出使用神经网络来训练数据,形成一个基于神经网络的稀疏成像算法,来满足稀疏 MIMO 特殊阵型和 MIMO 雷达成像实时性的需求。

基于稀疏 MIMO 阵型的特殊性以及训练数据的稀缺性,本文采用 U-Net 作为主干网络。U-Net [15] 结构可以分为下采样和上采样,与其他神经网络算法不同的是,其没有全连接层,而且网络层中只包含卷积层和池化层。具体的结构如图 1 所示, U-Net 网络结构中,从左边开始,由上面到下面这个半 U 型结构,是为了捕捉网络结构中全部信息的收缩路径;从右边开始,由下面到上面这个半 U 型结构,是为了网络可以精确地找到对应位置的对称的拓展路径。U-Net 结构的优势在于,其可以适用于数据量很稀疏的数据集,完成整个网络端到端的训练过程,并且最终输出图像的效果都很好。这满足 MIMO 阵型的稀疏性以及训练集数据量缺乏的问题。U-Net 网络结构的上采样和下采样阶段,采用的卷积操作数量相同,网络层之间的连接方式采用的是跳跃连接方式,将下采样层与上采样层连接起来,这使得下采样层提取到的图像特征,可以直接地传递到上采样层[16]。U-net 结构在训练网络时采用的方式是高梯度下降法,这使得训练网络时,学习率会进行自我调节。而且在训练网络过程中会对像素点进行一个权重的划分,使得目标的特征更加容易被提取出来。然而在网络的拟合中,大多数线性变换的表达能力都不够,不能将输入的神经元很好的映射到输出,因此引入了激活函数,将线性变换变为非线性变换,使得网络模型可以更好的去理解和学习更加复杂的场景。

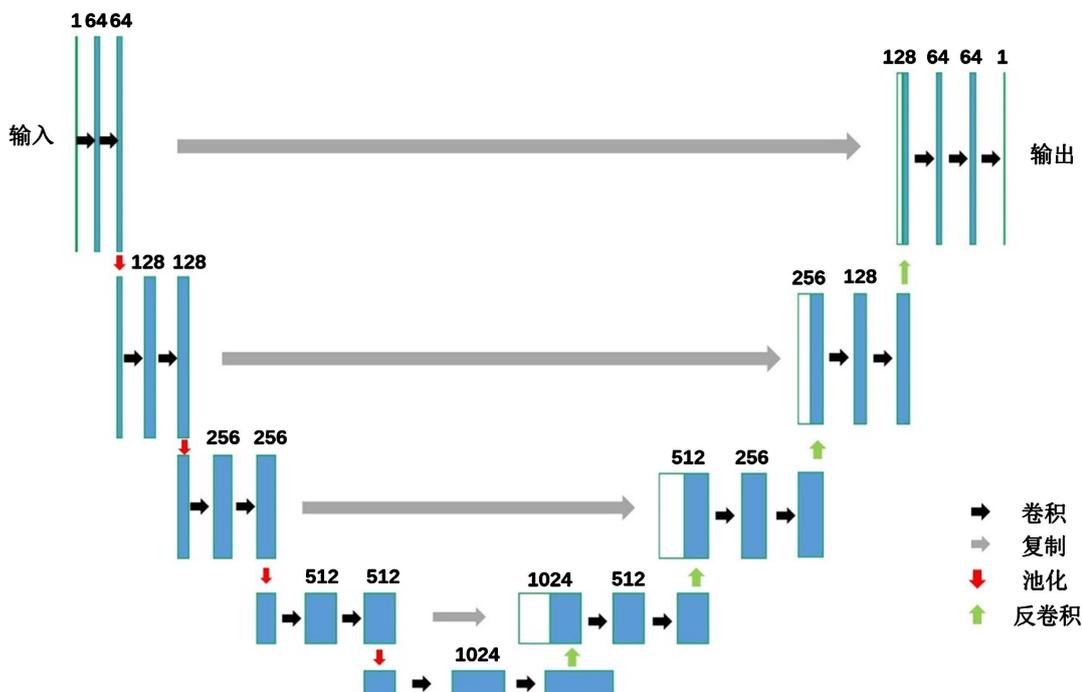


Figure 1. U-Net network structure

图 1. U-Net 网络结构图

### 3. 数据集构建

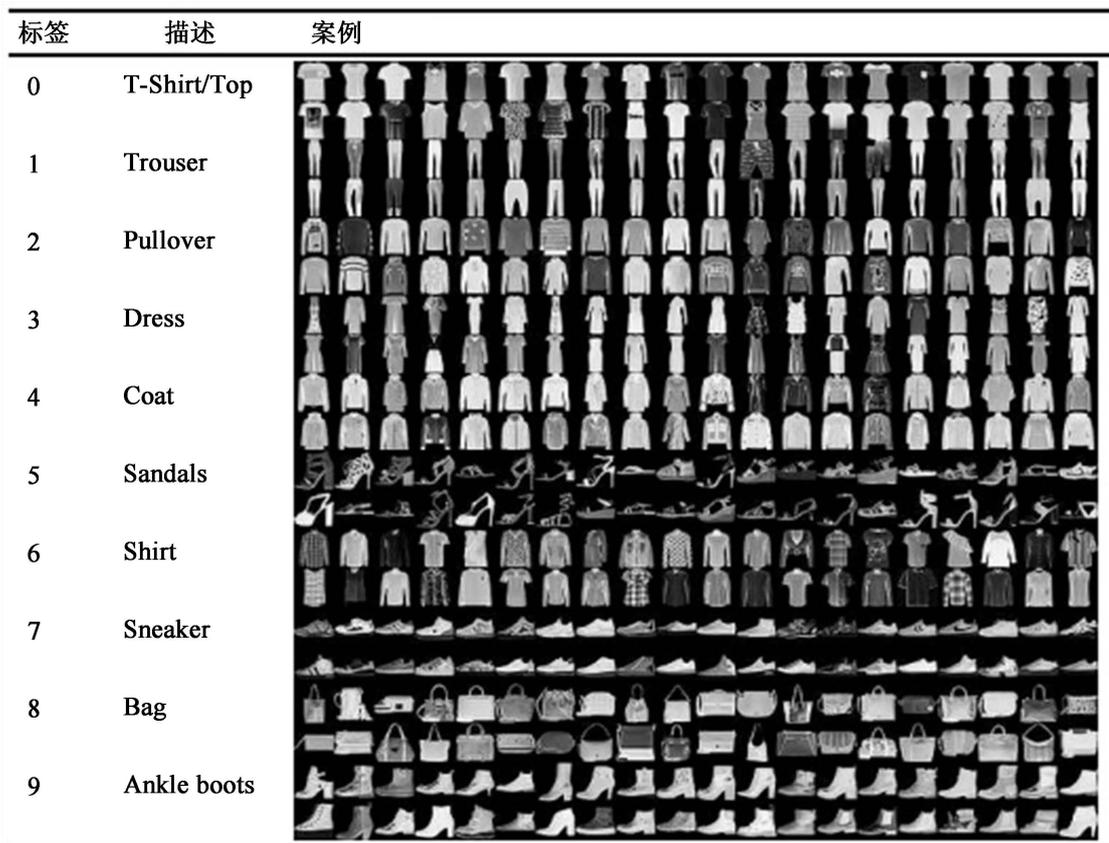
实际雷达成像的仿真或者实验中，目标非常重要。而对于训练神经网络，大量的、不同特征的目标也非常重要，但是拥有这么多，而且各自具有不同特征的目标在现实生活中很难实现。“Fashion-MNIST”图像数据集包含了 10 种类别的图像，分别是：T 恤、牛仔裤、卫衣、裙子、外套、凉鞋、衬衫、运动鞋、包、短靴，具体目标如图 2 所示。“Fashion-MNIST”图像数据集集结了大量不同种类、不同类型的图像，包含有 60,000 个训练集数据、10,000 个测试集数据，数据集的尺寸大小为  $28 \times 28$ 。使用其的优势是：可以直接用本文设计好的稀疏 MIMO 不规则阵型，用 MATLAB 程序遍历“Fashion-MNIST”图像数据集去构建回波数据集，构建过程如图 3 所示。在实际操作中，最终构建了 3000 组回波数据集，并以这部分回波数据集进行 BP 算法成像，构建出大小为  $94 \times 94$  的图像标签数据集。这样，网络训练数据集的构成就被分成了两个部分，第一部分，回波数据集使用的是稀疏 MIMO 阵型仿真的“Fashion-MNIST”回波，图像标签集采用的是 BP 算法对稀疏 MIMO 阵型仿真的“Fashion-MNIST”回波进行成像后的图像；第二部分，回波数据集使用稀疏 MIMO 阵型仿真的“Fashion-MNIST”回波，图像标签集采用的是“Fashion-MNIST”图像数据集本身，如图 4 所示。以上回波的制作方式和 BP 算法构建回波的方式相同，而且设置回波时，所有的参数设置如表 1 所示。

### 4. 实验结果分析

我们构建了 3000 组回波用来训练网络，并采用 4:1 的比例分配训练集和测试集，即训练集有 2400 组，测试集有 600 组。将回波数据集和图像标签数据集输入到 U-net 网络中，采用不同的损失函数对网络进行训练，发现不同的损失函数对于训练网络结果的影响不同。主要使用了二值交叉熵(Binary Cross Entropy, BCELoss)和均方根误差(Mean Squared Error, MSELoss)两种损失函数分别进行了网络训练结果的对比。其中 BCELoss 计算过程为图像标签和网络结果对应位置关系公式为：

**Table 1.** Basic parameter setting table  
**表 1.** 基础参数设置表

数量	质量	排序
阵列中心到目标的距离	$R$	0.5 m
单发单收全采的 $x$ 维阵元数	$N_x$	100
单发单收全采的 $y$ 维阵元数	$N_y$	100
发射信号中心频率	$f$	33 GHz
带宽	$B$	14 GHz
单发单收全采的采样间隔	$d = c/(2f)$	0.0043 m
单发单收全采的 $x$ 维孔径长度	$L_x = (N_x - 1)d$	0.4243 m
单发单收全采的 $y$ 维孔径长度	$L_y = (N_y - 1)d$	0.4243 m



**Figure 2.** “Fashion-MNIST” image dataset  
**图 2.** “Fashion-MNIST” 图像数据集

$$l_n = -[y_n \cdot \log \hat{y}_n + (1 - y_n) \cdot \log(1 - \hat{y}_n)] \quad (1)$$

其中， $\hat{y}_n$  为网络结果， $y_n$  为图像标签。BCELoss 的返回值为损失的平均值，即在计算完损失值之后需要将其除以点数。MSELoss 计算过程为图像标签和网络结果对应位置关系公式为：

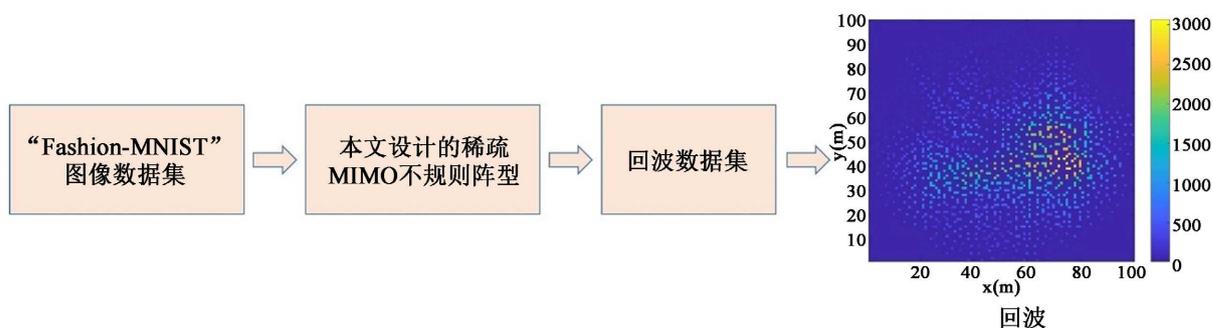


Figure 3. Construction of the echo dataset

图 3. 回波数据集的构建

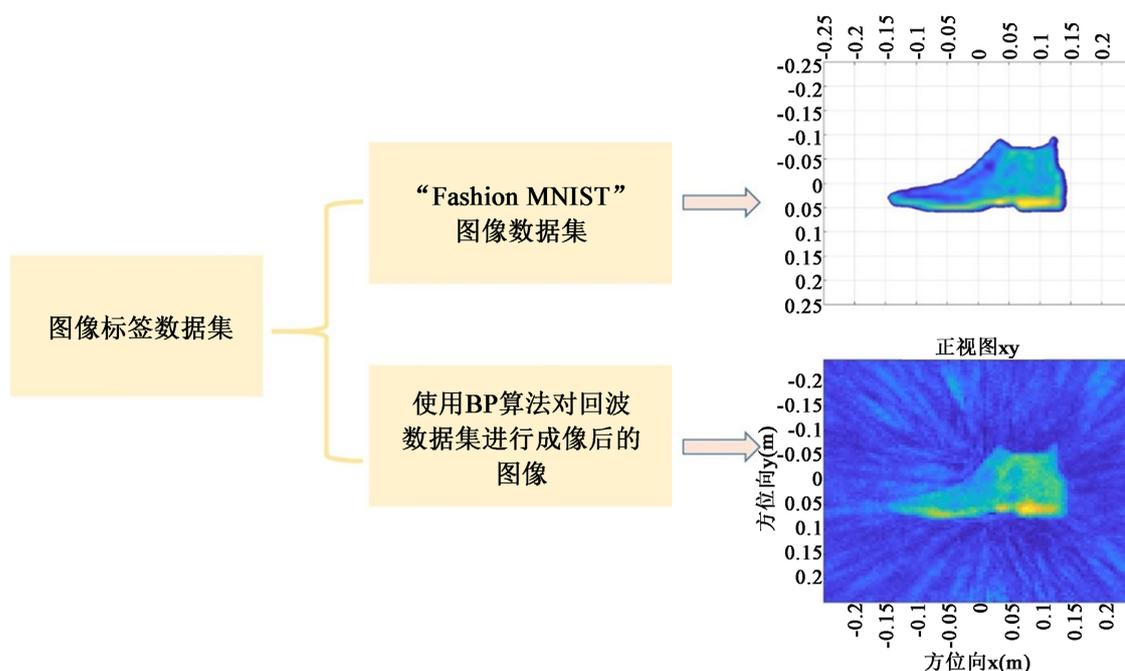


Figure 4. Composition of image labelling datasets

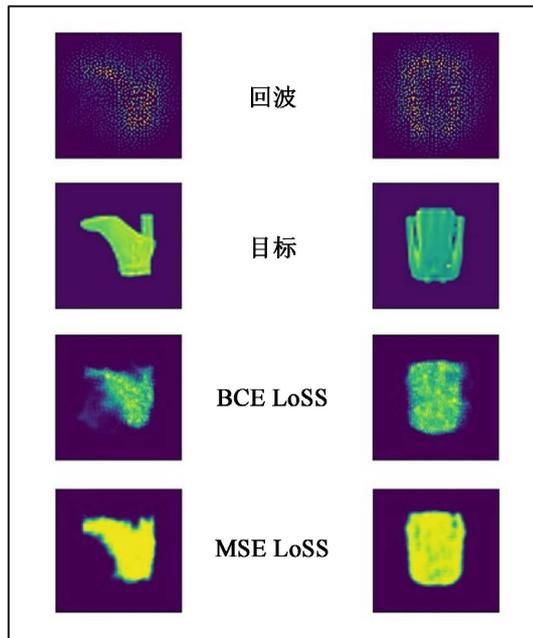
图 4. 图像标签数据集的组成

$$l_n = \sum_{n=1}^N (y_n - \hat{y}_n)^2 \quad (2)$$

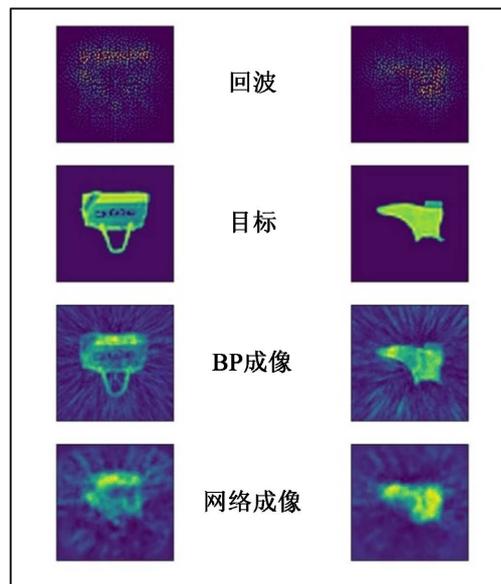
使用上述两种不同的损失函数训练网络的结果,如图 5 所示。从图中可以看出,使用 BCELoss 的网络训练效果明显要差于使用 MSELoss 的网络训练效果,使用 BCELoss 的结果中目标的轮廓信心损失严重,而使用 MSELoss 的结果中目标的轮廓清晰可见,因此后面的训练中使用的损失函数为 MSELoss。

在确定好损失函数之后,将分别使用两种数据标签集对网络进行训练,并将训练的结果与传统成像算法(BP 算法)进行成像效果的对比。采用 BP 算法成像时,仿真的信号频率为 26~40 GHz,距离维采样点数为 301 个,其余参数与表 1 的设置相同。首先使用 BP 算法和神经网络算法,对“Fashion-MNIST”图像数据集中挑选出来的单目标进行仿真成像,将成像的结果作为网络的输入训练标签集,进行神经网络算法的训练,最终的成像结果如图 6 所示;另外一组神经网络算法,使用的训练标签集为“Fashion-MNIST”图像数据集本身,同一组回波数据进行网络的训练,最终的成像结果如图 7 所示。从

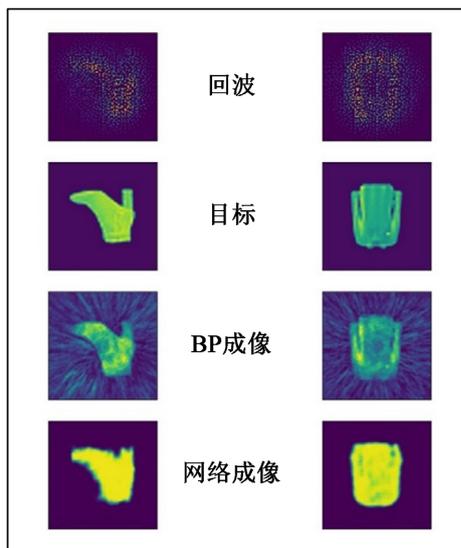
成像的结果来看，使用 BP 算法的成像结果作为神经网络输入训练标签集的训练结果，图像周围有很多的杂波，而且图像的边缘效果并不好，但成像的结果与 BP 算法的成像结果很相似，保留了 BP 算法成像图像背景中的杂波。而使用“Fashion-MNIST”图像数据集作为网络的输入训练标签集的训练结果中，成像的结果和原图十分接近，而且边界清晰。神经网络的训练结果和 BP 算法的成像结果对比，可以发现，传统的 BP 算法的成像结果中目标周围有很多的杂波，而神经网络算法训练的结果中，目标的轮廓清晰，而且目标周围几乎没有杂波，可以更清晰的看清目标。



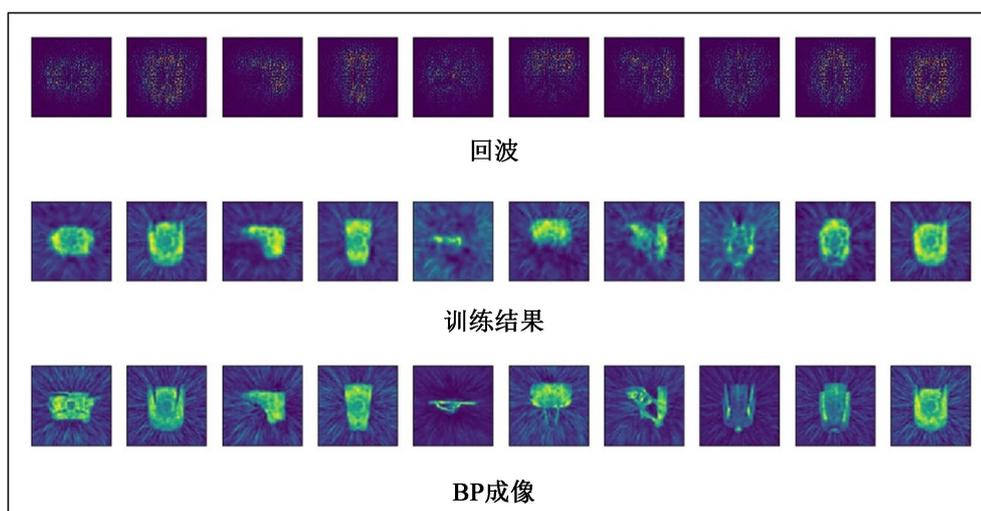
**Figure 5.** Comparison of network training results with different loss functions  
**图 5.** 不同损失函数的网络训练结果对比图



**Figure 6.** Using the imaging results obtained from the BP algorithm as the training label set for the network  
**图 6.** 使用 BP 算法的成像结果作为网络训练标签集



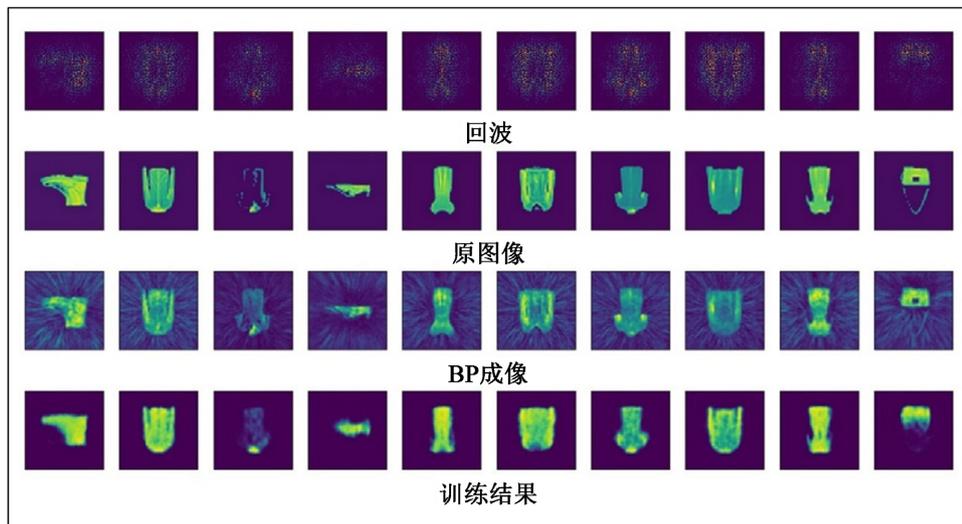
**Figure 7.** Using the “Fashion-MNIST” image dataset as the training label set for the network  
**图 7.** 使用 “Fashion-MNIST” 图像数据集作为网络训练标签集



**Figure 8.** The results obtained by training the network using BP imaging images as labels  
**图 8.** BP 成像图像作为标签训练网络结果图

多目标对比成像中，使用 BP 算法成像图像作为图像标签集输入来训练网络，结果如图 8 所示。从图像中可以看出使用 BP 算法成像的图像周围是有很多杂波的，这导致网络训练出来的效果很差。而使用 “Fashion-MNIST” 图像数据集作为图像标签集输入来训练网络，结果如图 9 所示。从图中可以看出，使用 “Fashion-MNIST” 图像数据集训练出来的网络成像效果较好，但是对于一些细节方面，BP 算法成像要稍微好一点，比如图中包包的带子，神经网络训练出来的结果中，不仔细看基本看不出来，但是 BP 算法成像图中可以看出包的袋子，但是网络成像对比于 BP 算法的优势还是很明显的，首先，成像图周围没有那么多的杂波；其次，网络训练好了之后，输入一个回波成像的速度要比 BP 算法快的多，其中 BP 算法的成像时间为 469 秒，而神经网络对单个目标的成像时间仅需要 1.15 秒，整个网络训练的时间为 90 秒(20 次迭代)，满足 MIMO 雷达对实时性成像的需求；最后，神经网络训练出来的算法，同样适用于任意阵型的拓扑成像。但其缺点也很明显，首先，需要大量的时间制作数据集和标签集；其次，训

练出来的网络只对这一种阵型适用，其余阵型需要重新训练网络；最后，制作回波和训练网络时，对于计算机硬件和软件的要求高。



**Figure 9.** The results obtained by training the network using the “Fashion-MNIST” image dataset as labels  
**图 9.** “Fashion-MNIST” 图像集作为标签训练网络结果图

## 5. 总结

本文主要针对稀疏 MIMO 不规则阵型的成像算法进行研究，发现目前传统的雷达成像算法，大部分都不适用于不规则阵型的 MIMO 雷达成像，而且目前的传统成像算法运算量巨大，操作时间长，不能满足 MIMO 雷达的实时性成像要求。因此，寻求一种适用于任意阵型，且能满足 MIMO 雷达实时性成像需求的成像算法变得十分迫切。而由于神经网络的自学习、自组织和自适应性等特点目前已广泛应用于雷达成像，提出训练神经网络来获取二维 MIMO 不规则阵型的稀疏成像算法，又因为神经网络训练需要大量的训练数据集，而实际中构建回波数据集的时间过长，故使用满足少量数据集就可正常训练网络的 U-Net 网络结构。为了获得大量不同的目标，本文使用“Fashion-MNIST”图像数据集构建网路需要的回波数据集和图像标签数据集，并使用两种不同的图像标签数据集代入网络训练，最终对比成像效果。实验结果显示，在相同数据集的条件下，与 BP 算法相比，本文所提算法在成像性能和成像时间上均表现更优，尤其适用于二维 MIMO 不规则阵型，实现高分辨率成像并保持实时性。

## 参考文献

- [1] Li, J. and Stoica, P. (2007) MIMO Radar with Colocated antennas. *IEEE Signal Processing Magazine*, **24**, 106-114. <https://doi.org/10.1109/MSP.2007.904812>
- [2] Haimovich, A.M., Blum, R.S., Leonard, J, *et al.* (2008) MIMO Radar with Widely Separated Antennas. *IEEE Signal Processing Magazine*, **25**, 116-129. <https://doi.org/10.1109/MSP.2008.4408448>
- [3] Hovanesian, S.A. (1980) Introduction to Synthetic Array and Imaging Radars. Artech House, Dedham.
- [4] Jordan, R.L., Huneycutt, B.L. and Werner, M. (1991) The SIR-C/X-SAR Synthetic Aperture Radar System. *Proceedings of the IEEE*, **79**, 827-838. <https://doi.org/10.1109/5.90161>
- [5] 汪玲. 逆合成孔径雷达成像关键技术研究[D]: [博士学位论文]. 南京: 南京航空航天大学, 2006.
- [6] Yu, Y., Petropulu, A.P. and Poor, H.V. (2010) MIMO Radar Using Compressive Sampling. *IEEE Journal of Selected Topics in Signal Processing*, **4**, 146-163. <https://doi.org/10.1109/JSTSP.2009.2038973>
- [7] 顾福飞, 池龙, 张群, 等. 基于压缩感知的稀疏阵列 MIMO 雷达成像方法[J]. 电子与信息学报, 2011, 33(10):

---

2452-2457.

- [8] Valente, R.A. and Abrão, T. (2016) MIMO Transmit Scheme Based on Morphological Perceptron with Competitive Learning. *Neural Networks*, **80**, 9-18. <https://doi.org/10.1016/j.neunet.2016.03.009>
- [9] Gao, J., Deng, B., Qin, Y., *et al.* (2017) Complex-Valued Convolutional Neural Network Enhanced Radar Imaging. arXiv preprint arXiv: 1712.10096.
- [10] Dai, Y., Jin, T., Song, Y., *et al.* (2018) SRCNN-Based Enhanced Imaging for low Frequency Radar. 2018 *Progress in Electromagnetics Research Symposium (PIERS-Toyama)*, Toyama, 1-4 August 2018, 366-370. <https://doi.org/10.23919/PIERS.2018.8597817>
- [11] Hu, C., Wang, L., Li, Z., *et al.* (2019) Inverse Synthetic Aperture Radar Imaging Using a Fully Convolutional Neural Network. *IEEE Geoscience and Remote Sensing Letters*, **17**, 1203-1207. <https://doi.org/10.1109/LGRS.2019.2943069>
- [12] Ye, G., Zhang, Z., Ding, L., *et al.* (2020) GAN-Based Focusing-Enhancement Method for Monochromatic Synthetic Aperture Imaging. *IEEE Sensors Journal*, **20**, 11484-11489. <https://doi.org/10.1109/JSEN.2020.2996656>
- [13] Cheng, Q., Ihalage, A.A., Liu, Y., *et al.* (2020) Compressive Sensing Radar Imaging with Convolutional Neural Networks. *IEEE Access*, **8**, 212917-212926. <https://doi.org/10.1109/ACCESS.2020.3040498>
- [14] Xiao, H., Rasul, K. and Vollgraf, R. (2017) Fashion-Mnist: A Novel Image Dataset for Benchmarking Machine Learning Algorithms. arXiv preprint arXiv: 1708.07747.
- [15] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015*, Springer, Cham, 9351. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- [16] 华郁秀, 李荣鹏, 赵志峰, 等. 基于生成对抗网络的 MIMO 信道估计方法[J]. 电信科学, 2021, 37(6): 14-22.