

DOI:10.19651/j.cnki.emt.2518805

基于深度学习的无人机时频曲线重建算法<sup>\*</sup>孙嘉辰<sup>1,2</sup> 庞存锁<sup>1,2</sup> 任梓然<sup>1,2</sup> 杨志良<sup>1,2</sup> 安建平<sup>3</sup>(1.中北大学信息与通信工程学院 太原 030051;2.中北大学智能探测技术与装备山西省重点实验室 太原 030051;  
3.北京理工大学网络空间安全学院 北京 100081)

**摘要:**近年来,无人机技术在多个领域广泛应用,雷达探测因其远距离、高精度定位和快速响应优势而被广泛应用,且针对无人机的微多普勒特征研究备受关注。然而,无人机回波信号在复杂环境中易受干扰,导致时频特性畸变。传统时频分析方法在处理此类问题时存在局限性。为此,本文提出一种基于深度学习的无人机时频曲线重建算法,通过设计基于卷积神经网络的自编码器模型 SelfNet,从噪声干扰和信道失真中提取有效信息,重建高质量的时频曲线。SelfNet 利用编码器提取时频曲线特征,并通过解码器恢复信号结构。实验结果表明,SelfNet 的 PSNR 均值为 17.767 2, SSIM 均值为 0.431 7,优于 GoogLeNet 和 ResNet 等经典卷积神经网络,且通过小样本实验和迁移学习验证了其泛化能力,为复杂环境下无人机时频曲线的重建提供了一种思路。

**关键词:**无人机;时频分析;卷积神经网络;迁移学习;图像重建

**中图分类号:** TN957.51;TP391 **文献标识码:** A **国家标准学科分类代码:** 510.70

## UAV time-frequency curve reconstruction algorithm based on deep learning

Sun Jiachen<sup>1,2</sup> Pang Cunsuo<sup>1,2</sup> Ren Ziran<sup>1,2</sup> Yang Zhiliang<sup>1,2</sup> An Jianping<sup>3</sup>(1.School of Information and Communication Engineering, North University of China, Taiyuan 030051, China;2. Shanxi Province Key Laboratory of Intelligent Detection Technology and Equipment, North University of China, Taiyuan 030051, China;  
3. School of Cyberspace Science and Technology, Beijing Institute of Technology, Beijing 100081, China)

**Abstract:** In recent years, UAV technology has been widely used in many fields. Radar detection is widely used because of its advantages of long-distance, high-precision positioning and rapid response, and the research on micro-Doppler characteristics of UAV has attracted much attention. However, the echo signal of UAV is susceptible to interference in complex environment, resulting in time-frequency characteristics distortion. The traditional time-frequency analysis methods have limitations in dealing with such problems. Therefore, this paper proposes a time-frequency curve reconstruction algorithm for UAV based on deep learning. By designing autoencoder model based on convolutional neural network SelfNet, effective information is extracted from noise interference and channel distortion, and high-quality time-frequency curve is reconstructed. SelfNet uses the encoder to extract the characteristics of time-frequency curve, and restores the signal structure through the decoder. The experimental results show that the average PSNR is 17.767 2, and the average SSIM is 0.431 7, which is better than classical convolutional neural networks such as GoogLeNet and ResNet, and its generalization ability is verified by small sample experiments and transfer learning, which provides an idea for UAV time-frequency curve reconstruction in complex environment.

**Keywords:** UAV; time-frequency analysis; convolutional neural network; transfer learning; image reconstruction

## 0 引言

随着无人机(unmanned aerial vehicle, UAV)技术的快速发展,其在军事、民用、商用等领域的应用日益广泛。在众多无人机探测手段中,雷达探测因其独特的优势占据

重要地位。它不仅可以实现远距离探测,还能对目标进行高精度定位,并且具备快速响应的能力,这使得雷达探测在实际应用中能够及时、准确地提供无人机的位置和运动信息。

当前,针对无人机的研究热点集中在微多普勒特征上,

收稿日期:2025-05-13

\* 基金项目:国防科技重点实验室基金(6142001200406)项目资助

这是因为雷达能够通过探测运动的目标,捕捉其中的微多普勒特征。文献[1]提出了一种基于短时分数阶傅里叶变换(short-time fractional order Fourier transform, STFRFT)的复杂运动目标时频识别算法,通过多阶匹配提高了时频曲线拟合的估计精度。文献[2]提出了一种基于多普勒与微多普勒联合利用的弱小目标检测与估计方法,通过贝叶斯估计法实现目标多普勒与微多普勒信息的积累,提高了雷达对弱小目标的检测性能。

然而,在复杂环境(如城市、山区、电磁干扰等)中,无人机的信号传输往往受到噪声、多径效应和信道衰落的影响<sup>[3-5]</sup>,导致接收信号的时频特性发生畸变。时频曲线作为描述信号时域和频域特性的关键工具,能够直观反映信号的完整性和稳定性。如何从畸变的信号中恢复出准确的时频曲线,成为无人机信号处理领域的重要研究课题。

传统的时频分析方法虽然在一定程度上能够提取信号的时频特征,但在面对复杂噪声环境和非平稳信号时,往往表现出局限性。例如,短时傅里叶变换的分辨率受限于窗函数的选择<sup>[6]</sup>,而小波变换的基函数设计难以适应多样化的信号形态<sup>[7]</sup>。近年来,深度学习技术在图像处理、语音识别等领域取得了显著进展<sup>[8-9]</sup>,其强大的特征提取能力为解决复杂信号处理问题提供了新的思路。

基于深度学习的时频曲线重建算法,旨在利用深度神经网络的自适应学习能力,从噪声干扰和信道失真中提取有效信息,重建出高质量的时频曲线。目前,针对时频图像的增强已经有了一定的研究<sup>[10-12]</sup>,但针对无人机时频曲线重建的研究仍处于探索阶段,现有方法在模型结构设计、训练数据生成等方面仍存在诸多挑战。

针对上述问题,本文提出了一种基于深度学习的无人机时频曲线重建算法。本文设计了一个基于卷积神经网络的自编码器模型(后文用“SelfNet”代指)。SelfNet主要包括编码器和解码器两部分。编码器部分用于时频曲线的特征提取,通过多个卷积块逐步捕捉曲线的特征;解码器部分则利用这些特征重建时频曲线,通过转置卷积操作逐步恢复曲线的完整结构。为了验证SelfNet的性能,本文构建了时频曲线仿真数据集,并与经典的卷积神经网络(GoogLeNet和ResNet)进行了对比分析。结果表明,SelfNet能够对时频曲线实现良好的重建,为复杂环境下无人机时频曲线的重建问题提供了一种思路。

## 1 时频分析

### 1.1 无人机雷达回波模型建立

旋翼无人机的飞行运动轨迹是目标本体的相对平行移动加之其机身上旋翼的转动和机身抖动等<sup>[13]</sup>,本文的研究重点是旋翼无人机叶片转动时产生的微运动,这种微运动会引发回波信号的周期性以及时变频率的调制,进一步导致多普勒频移随时间而变化。下面以一个旋翼的叶片为例,设雷达与叶片处于同一平面上,如图1所示。

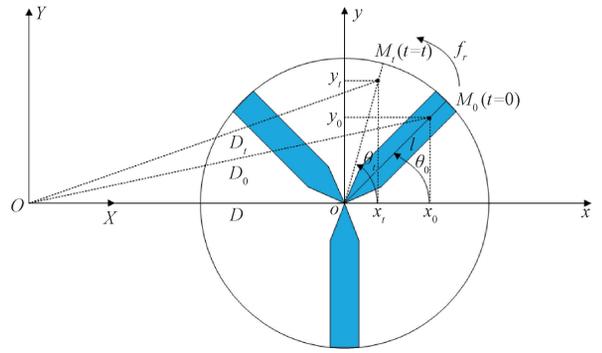


图1 无人机叶片转动与雷达的关系

Fig.1 The relationship between UAV blade rotation and radar

图1中, $XOY$ 坐标系代表雷达坐标系,原点 $O$ 是雷达的位置; $xoy$ 坐标系代表无人机坐标系,它是雷达坐标系的平移,点 $o$ 是叶片的几何中心。假设 $v$ 为无人机在雷达视线上的径向速度, $M_0(x_0, y_0)$ 是叶片上的一个散射点,它绕着中心点 $o$ 转动,旋转速率为 $f_r$ 。在 $t=0$ 时刻,点 $o$ 到 $M_0$ 的距离为 $l$ ,雷达到叶片中心的距离为 $D$ ,雷达到 $M_0$ 的距离为 $D_0$ ,初始相位为 $\theta_0$ 。经过时间 $t$ 后,散射点 $M_0$ 转动到点 $M_t(x_t, y_t)$ ,此时雷达到 $M_t$ 的距离为 $D_t$ ,相位为 $\theta_t$ ,且 $\theta_t = \theta_0 + 2\pi f_r t$ 。由于雷达和叶片处于同一平面上,则 $D_t$ 可表示为:

$$D_t = \sqrt{(D + vt)^2 + l^2 + 2(D + vt)l \cos \theta_t} = \sqrt{(D + vt)^2 + l^2 + 2(D + vt)l \cos(\theta_0 + 2\pi f_r t)} \quad (1)$$

通常情况下,无人机叶片长度往往远小于雷达到无人机的距离,则式(1)可以进行化简:

$$D_t \approx D + vt + l \cos(\theta_0 + 2\pi f_r t) \quad (2)$$

$\Phi(t)$ 为散射相位函数。结合式(2),可以得到无人机叶片的相位函数,有:

$$\Phi(t) = \frac{4\pi D_t}{\lambda} = \frac{4\pi}{\lambda} [D + vt + l \cos(\theta_0 + 2\pi f_r t)] \quad (3)$$

此时叶片上点 $M_t$ 的回波信号为:

$$S(t) = \rho \exp\{j\Phi(t)\} \exp(j2\pi f_d t) = \rho \exp\left\{j \frac{4\pi}{\lambda} [D + vt + l \cos(\theta_0 + 2\pi f_r t)]\right\} \exp(j2\pi f_d t) \quad (4)$$

式中: $\rho$ 为散射系数, $f_d$ 为无人机飞行时其自身运动产生的多普勒频率的变化。为了研究无人机微动产生的微多普勒特征,这里取 $\rho = 1$ ,并且忽略常数项和无人机速度的影响,则式(4)可以进一步简化:

$$S_B(t) = \exp\left\{j \frac{4\pi}{\lambda} l \cos(\theta_0 + 2\pi f_r t)\right\} \quad (5)$$

式(5)可以理解为无人机叶片上的单个散射点的回波,那么一整条叶片的回波信号实际上就是在 $[0, L]$ 上对所有的散射点进行积分,其中叶片长度为 $L$ ,即有:

$$S_L(t) = \int_0^L \exp\left\{j \frac{4\pi}{\lambda} l \cos(\theta_0 + 2\pi f_r t)\right\} dl =$$

$$L \exp \left\{ j \frac{4\pi}{\lambda} \frac{l}{2} \cos(\theta_0 + 2\pi f_r t) \right\} \operatorname{sinc} \left\{ \frac{4\pi}{\lambda} \frac{l}{2} \cos(\theta_0 + 2\pi f_r t) \right\} \quad (6)$$

由式(6)可知,类似 sinc 函数的振荡现象会在整个叶片的回波信号中产生。将式(6)推广到叶片数量为  $N$  的情况,则有:

$$S_{sum}(t) = \sum_{k=1}^N L \exp \{ j[\Phi_k(t)] \} \operatorname{sinc} [\Phi_k(t)] \quad (7)$$

式中:  $\theta_k = \theta_0 + 2k\pi/N$  表示不同叶片数量  $N$  下的初始旋转角,  $\Phi_k(t)$  为相位函数,有:

$$\Phi_k(t) = \frac{4\pi}{\lambda} \frac{l}{2} \cos(\theta_k + 2\pi f_r t) \quad (8)$$

1.2 短时傅里叶变换

短时傅里叶变换<sup>[14]</sup> (short-time Fourier transform, STFT)的基本思想就是,利用一个窗函数,将原始信号截成一个有限长度的窗内信号,对这些窗内信号应用傅里叶变换,然后沿着时间轴移动窗函数,逐步得到每个窗内信号的频谱。

雷达接收信号是待测旋翼无人机上的所有散射点的回波<sup>[15]</sup>,因此接收到的雷达回波信号  $s(t)$  可以表示为:

$$s(t) = \sum_{i=1}^n k_i e^{-j\varphi_i(t)} + n(t) \quad (9)$$

式中:  $n$  为移动散射体的总数,  $k_i$  为第  $i$  个散射体的反射系数,  $\varphi_i(t) = 4\pi R_i(t)/\lambda$  为第  $i$  个散射体的相位调制,  $n(t)$  为加性噪声。

回波信号  $s(t)$  的短时傅里叶变换表达式为:

$$STFT(\tau, \omega) = \int_{-\infty}^{\infty} s(t) w(t - \tau) e^{-j\omega t} dt \quad (10)$$

式中:  $w(t)$  为窗函数,  $\tau$  为窗函数移动的位置,  $\omega$  为多普勒频率。

假设雷达载波频率为 90 GHz,采样频率为  $10^4$  Hz,无人机处于悬停状态,叶片长度为 20 cm,叶片旋转速率为 5 r/s,无人机距离雷达 100 m,旋翼相对雷达的仰角为  $60^\circ$ 。基于上述参数对旋翼数量  $N=2$  的无人机进行仿真,可得无人机的时频曲线,如图 2 所示。

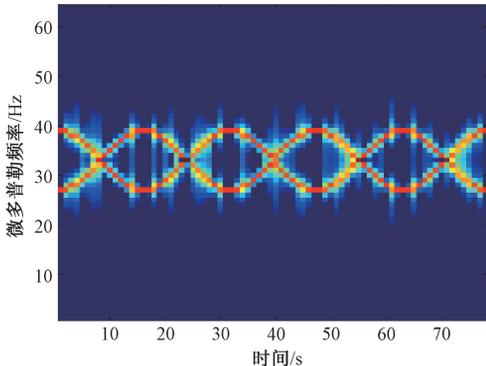


图 2 无人机微多普勒时频曲线

Fig. 2 Micro-Doppler time-frequency curve of UAV

图 2 表明,时频图中正弦线条数与旋翼数量  $N$  相同,因而可以确定无人机的旋翼数量。然而,在实际处理中,当信噪比较低时,上述特征并不明显。在图 2 中加入噪声后,可以看到,随着信噪比降低,时频图的有效信息逐渐被掩盖,难以进行有效的分析,如图 3 所示。

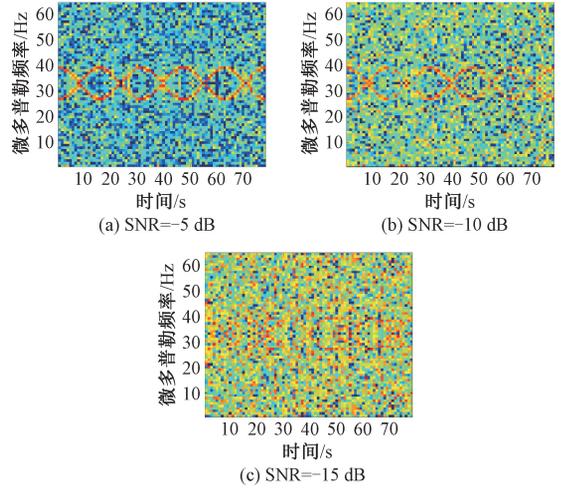


图 3 不同信噪比情况下无人机微多普勒时频曲线

Fig. 3 Micro-Doppler time-frequency curve of UAV under different SNR

2 基于深度学习的重建算法

2.1 卷积神经网络概述

卷积神经网络(convolutional neural network,CNN)是一种深度学习模型,广泛应用于图像分类、目标检测、语义分割等任务<sup>[16-18]</sup>。

CNN 的核心思想是通过卷积操作提取数据的局部特征。它通常由卷积层、池化层和全连接层组成。卷积层通过卷积核在输入数据上滑动,执行卷积操作以提取特征,同时利用参数共享机制减少计算量和参数数量。池化层则通过下采样降低特征图的空间维度,从而减少计算复杂度并增强模型对平移的不变性。全连接层通常位于网络末端,用于将提取的特征映射到输出空间,完成分类或回归任务。

2.2 时频曲线重建模型 SelfNet

本文设计了一种基于 CNN 的自编码器模型 SelfNet,用于无人机时频曲线图的特征提取和重建。

自编码器是一种无监督学习模型<sup>[19]</sup>,通过编码器将输入图像映射到低维特征空间,然后通过解码器将这些特征重建为与输入相似的输出图像。SelfNet 的主要结构是“编码器-解码器”结构,并结合全连接层进行特征融合,以实现时频曲线图的重建。

U-Net 最初是为医学图像分割任务设计的<sup>[20]</sup>,其独特的对称结构能够有效捕捉图像的多尺度特征,从而实现高质量的图像分割。SelfNet 在设计上借鉴了 U-Net 的“编码器-解码器”结构思想,同时针对无人机时频曲线重建任务

的特点做出了一些改进。

SelfNet 的模型结构如图 4 所示。在编码器部分, SelfNet 沿用了 U-Net 的卷积和池化操作来提取特征并降低特征图的空间维度,但改为使用了卷积块进行特征提取。SelfNet 使用了五个卷积块。每个卷积块包含两组“卷积层+批量归一化+Leaky ReLU 激活函数+Dropout 层”和一组“最大池化层+Dropout 层”。两个卷积层用于提取时频曲线图中的复杂特征;Leaky ReLU 激活函数用于缓解神经元“死亡”问题;批量归一化操作用于加速训练和提升特征表达能力;Dropout 层用于增强模型的泛化能力,防止模型过拟合;最大池化层用于逐步减少特征图的尺寸,减少训练过程中的计算量,加速训练过程。每个卷积块通过卷积操作提取局部特征,通过池化操作逐步降低特征图的分辨率,从而提取更高级的特征。

中间融合部分首先利用 flatten 操作,将多维特征图压缩为一维向量,然后通过全连接层对特征进行压缩和融合,同时引入 Dropout 层。Dropout 通过随机丢弃一部分神经元的输出,防止模型对训练数据的过拟合,从而提高模型在测试数据上的性能。

在解码器部分,SelfNet 借鉴了 U-Net 的反卷积操作来逐步恢复特征图的分辨率,但改为使用了转置卷积。它能够学习到如何将低分辨率特征图映射到高分辨率特征图,通过学习卷积核的参数,可以更好地恢复出特征图的细节信息。解码器部分首先利用 unflatten 操作将一维特征向量恢复为多维特征图,然后通过多层转置卷积逐步放大特征图的分辨率,最终重建出与输入图像大小相同的输出图像。这种逐步上采样的过程使得解码器能够从复杂的特征表示中恢复出图像的细节信息,从而实现图像重建。

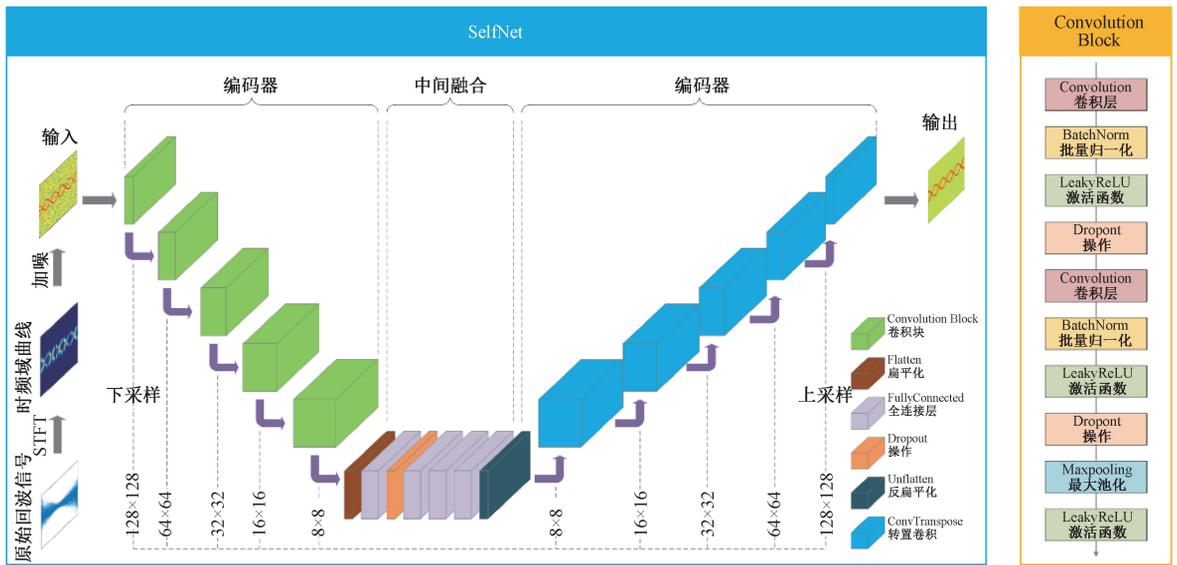


图 4 SelfNet 模型结构图

Fig. 4 The model structure of SelfNet

### 2.3 数据集生成

目前无人机雷达信号级回波数据相对稀缺,难以找到一个完整的数据集进行无人机时频曲线图的训练及重建。本文基于无人机雷达回波信号理想物理模型,生成了一个无人机时频曲线数据集,主要考虑了叶片旋转引起的微多普勒效应及加性高斯白噪声干扰。参数设置如表 1 所示。

表 1 仿真参数设置

Table 1 Simulation parameter settings

仿真参数	取值设置	仿真参数	取值设置
旋翼数量	[1,6]	雷达与无人机的距离	100 m
叶片长度	20 cm	采样率	$10^4$ Hz
载波频率	90 GHz	采样点数	5 000
仰角	$60^\circ$	信噪比范围	$[-5,0]$ dB
旋转速率	5 r/s		

在信噪比范围 $[-5,0]$  dB 的条件下,为不同旋翼数量  $N=1,2,3,4,5,6$  均生成等信噪比间隔的 2 000 张时频图,其中 80% 作为训练集,10% 作为验证集,10% 作为测试集。仿真得到的时频图如图 5 所示。

## 3 实验验证

### 3.1 实验参数设置

本文使用的软件平台为 Pycharm Community Edition,操作系统为 Windows 11。在具体的训练过程中,本文设置批量大小 batch size = 16,总训练轮数 epochs = 50,初始学习率 learning\_rate =  $10^{-3}$ ,定义损失函数为均方误差 (mean square error, MSE) 损失函数,优化器为 AdamW 优化器,学习率调度器为步进学习率调度器,并设置步长 step size = 5,衰减因子 gamma = 0.9,即每 5 个 epoch 后将学习率乘以 0.9。

此外,在训练过程中使用早停法,防止模型过拟合。在每个训练周期(epoch)结束后,比较当前验证损失与之前记录的最佳验证损失。如果当前验证损失更低,说明模型在验证集上的表现有所改善,此时更新最佳验证损失,并将耐心计数器重置为 0。反之,如果验证损失没有改善,耐心计数器会增加 1。当耐心计数器达到预设的耐心值

(patience=5)时,认为模型已经无法进一步优化,触发早停机制,停止训练过程。

### 3.2 模型重建效果

利用 SelfNet 对数据集进行训练,得到对应的模型权重。读取模型权重即可实现对无人机时频图的重建。对图 5 中的例图进行重建,结果如图 6 所示。

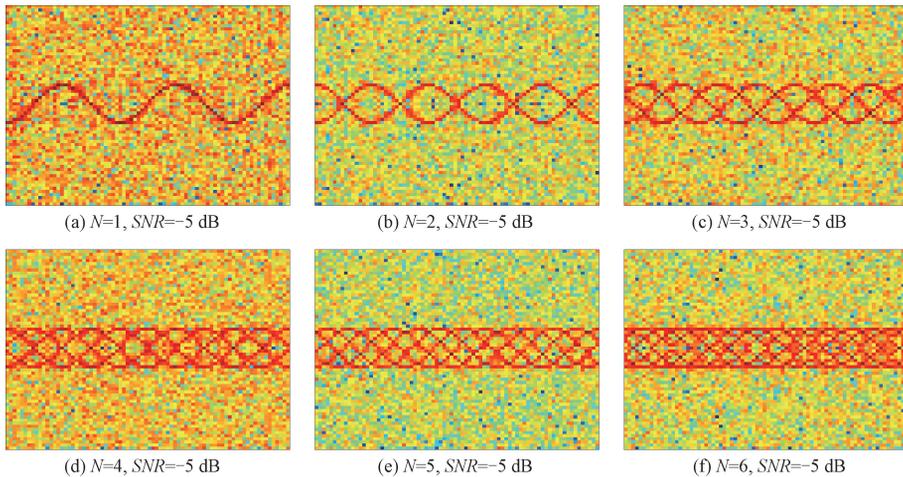


图 5 不同旋翼数量下的无人机时频曲线例图

Fig. 5 Time-frequency sample curves of UAV with different  $N$  values

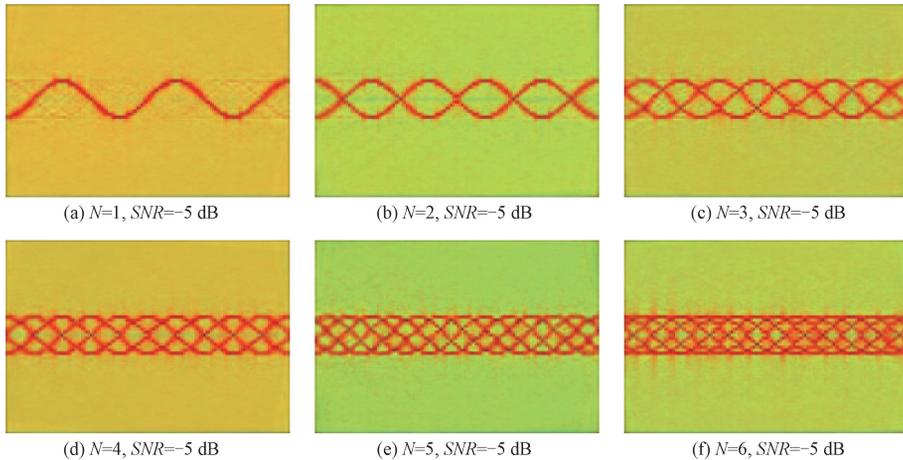


图 6 不同旋翼数量下的无人机时频曲线例图(SelfNet 重建)

Fig. 6 Time-frequency sample curves of UAV with different  $N$  values (SelfNet reconstruction)

对比图 5 和图 6 中相同参数下的时频曲线,可以看到,经过 SelfNet 训练后,时频曲线的有效特征得到保留,并且抑制了原先情况下的噪声,提高了时频曲线的分辨率,实现了良好的重建。

### 3.3 对比实验

为了验证 SelfNet 的性能,本文还利用了 GoogLeNet 和 ResNet18 进行了对比实验。参数设置与 SelfNet 实验设置相同。在 GoogLeNet 和 ResNet18 模型的基础上,去掉最后的全连接层,将剩余的部分视为提取特征的“编码器”,并在后面加上“解码器”部分,以适应时频曲线的重建

任务。在训练过程中,冻结编码器部分的参数,并解冻编码器的最后三层。修改后的 GoogLeNet 和 ResNet18 的模型图(用 GoogLeNet-Decoder 和 ResNet18-Decoder 代指)如图 7 和图 8 所示。

为了对比 3 种模型的性能,引入峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性指数(structure similarity index measure, SSIM)为评价指标。

PSNR 是衡量重建图像与原始图像之间质量差异的指标。它通过计算原始图像与重建图像的均方误差来评估图像质量。其值越高,表示重建图像的质量越好。PSNR

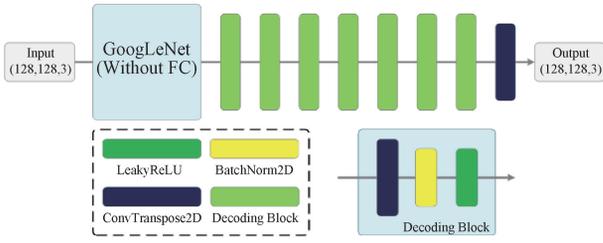


图7 GoogLeNet-Decoder 模型结构图

Fig. 7 The model structure of GoogLeNet-Decoder

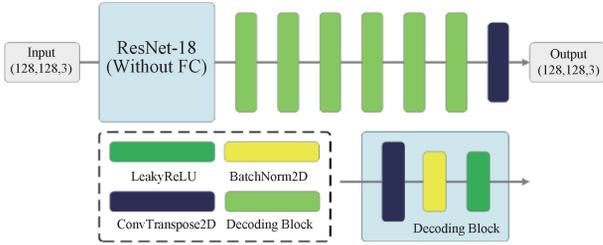


图8 ResNet18-Decoder 模型结构图

Fig. 8 The model structure of ResNet18-Decoder

计算公式如下:

$$PSNR = 10 \times \lg \left( \frac{MAX^2}{MSE} \right) \quad (11)$$

式中:  $MAX$  表示图像的最大可能像素值,  $MSE$  表示均方误差, 其计算公式为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (12)$$

式中:  $x_i$  表示原始图像的像素值,  $y_i$  表示重建图像的像素值,  $n$  表示像素总数。

SSIM 是衡量原始图像和重建图像之间结构相似性的指标。它不仅考虑了图像的亮度和对比度, 还考虑了图像的结构信息。SSIM 的取值范围在  $0 \sim 1$  之间, 值越接近 1, 表示图像结构相似性越高。SSIM 定义如下:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (13)$$

式中:  $\mu_x$  和  $\mu_y$  表示原始图像  $x$  和重建图像  $y$  的均值,  $\sigma_x^2$  和  $\sigma_y^2$  表示原始图像  $x$  和重建图像  $y$  的方差,  $\sigma_{xy}$  表示原始图像  $x$  和重建图像  $y$  的协方差,  $C_1$  和  $C_2$  是用于防止分母为零的常数。

利用 3 种模型对数据集进行训练, 对验证集和测试集的图像进行重建, 计算每一张图像的 PSNR 和 SSIM, 再对所有图像取平均值, 得到每个模型对整个验证集和测试集的 PSNR 和 SSIM 的均值, 如表 2 所示。

由表 2 可知, SelfNet 的 PSNR 和 SSIM 均值最大, 超过了另外两种模型, 说明 SelfNet 的重建性能更具优势。

### 3.4 小样本实验

前文所提到的实验结果均是在大数据集上进行的。为了体现模型的泛化性能, 本文另生成了一组小样本数据集, 参数设置如表 3 所示。

表 2 3 种模型评价指标均值对比

Table 2 Comparison of average evaluation indicators for three models

所用模型	PSNR	SSIM
SelfNet	17.767 2	0.431 7
GoogLeNet-Decoder	17.473 6	0.423 7
Resnet18-Decoder	17.258 1	0.412 3

表 3 仿真参数设置

Table 3 Simulation parameter settings

仿真参数	取值设置
旋翼数量	[1, 6]
叶片长度	20 cm
载波频率	90 GHz
仰角	$60^\circ$
旋转速率	5 r/s
雷达与无人机的距离	100 m
采样率	$10^4$ Hz
采样点数	5 000
信噪比范围	$[-10, -5]$ dB

在信噪比范围  $[-10, -5]$  dB 的条件下, 为不同旋翼数量  $N=1, 2, 3, 4, 5, 6$  均随机生成不同信噪比的 100 张时频图, 其中 80% 作为训练集, 10% 作为验证集, 10% 作为测试集。在测试集中选取一张例图, 如图 9 所示。

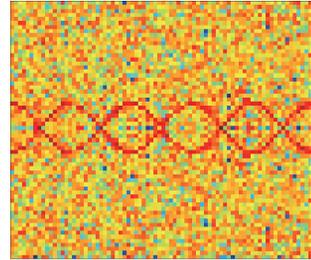


图9 小样本数据集中的无人机时频曲线例图

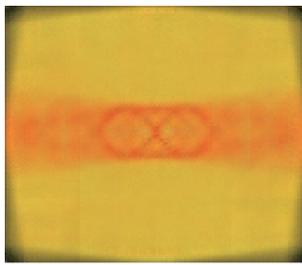
Fig. 9 Time-frequency sample curve of UAV in small sample dataset

直接利用 3 个模型对小样本进行训练及重建, 参数设置和训练策略与 3.1 节对大数据集的训练方法保持一致, 得到的结果如图 10 所示。

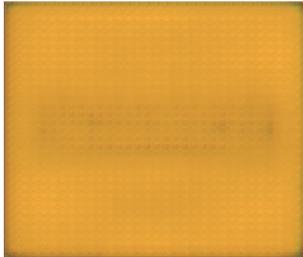
对比图 9 和图 10, 可以看到, 无论是哪种模型, 原有曲线的特征都完全没有提取出来, 有效的特征信息几乎完全丧失, 直接对小样本进行训练及重建的效果很差。

为了提升小样本的重建质量, 将 SelfNet 在大数据集上训练得到的权重迁移到小样本上, 再进行训练及重建。

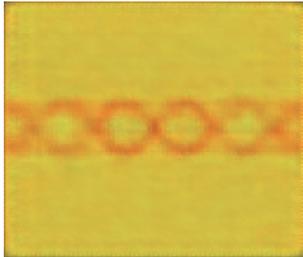
在训练过程中, 本文设置 batch size = 16, epochs = 50, learning\_rate =  $10^{-3}$ , 损失函数为 MSE 损失函数, 优化器为 AdamW 优化器, 学习率调度器为余弦退火学习率调度器, 并设置周期长度为 10, 学习率最小值为  $10^{-6}$ , 即学习率



(a) SelfNet重建  
(a) SelfNet reconstruction



(b) GoogLeNet-Decoder重建  
(b) GoogLeNet-Decoder reconstruction



(c) ResNet18-Decoder重建  
(c) ResNet18-Decoder reconstruction

图 10 直接对小样本进行训练得到的重建结果

Fig. 10 Reconstruction results obtained by directly training small sample dataset

会在 10 个 epoch 内按照余弦函数的形状变化,从初始值逐渐下降到最小值,并在每个周期结束后重新开始。此外,利用早停法(patience = 5)监控训练过程中验证损失的变化,防止模型过拟合。迁移训练得到的结果如图 11 所示。

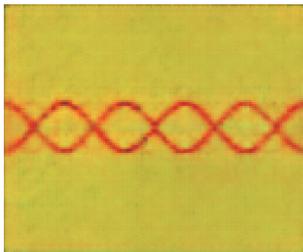


图 11 SelfNet 训练权重迁移后得到的重建结果

Fig. 11 Reconstruction results after SelfNet training weight transfer

对比图 9~11,可以看到,利用在大数据集上训练得到的模型权重,迁移到小样本上再进行训练和重建后,SelfNet 成功有效提取出时频曲线的特征信息,而且抑制了原有情况的噪声,实现了良好的重建。

### 3.5 实测数据实验

为了验证 SelfNet 在实测数据上的性能,本文使用了一个公开的雷达探测无人机数据集<sup>[21]</sup>,该数据集基于 S 波段相控阵雷达,采集了多种场景下的无人机回波数据。

本文使用“Data1”文件夹,读取了前 50 个回波文件,提取第一个通道的数据,先后进行脉冲压缩、动目标检测、低通滤波、短时傅里叶变换,得到对应的时频图。总计生成了 50 张时频图,典型例图如图 12 所示。

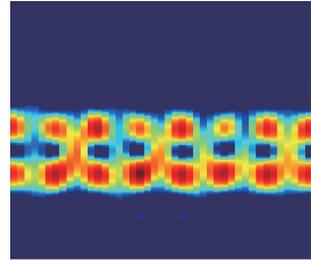


图 12 原始时频曲线例图

Fig. 12 Original time-frequency curve example

为了验证 SelfNet 的性能,本文在 50 张时频图的基础上进行了扩充。在原始时频图中添加高斯噪声,设置信噪比范围为 $[-5, 0]$  dB。最终总计生成了 500 张时频图,其中 80% 作为训练集,10% 作为验证集,10% 作为测试集。以  $\text{SNR} = -5$  dB 为例,如图 13 所示。

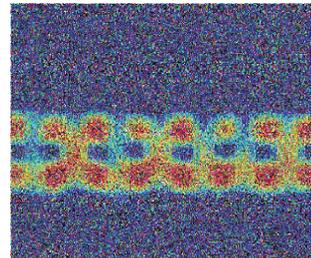


图 13 加入噪声后的时频图

Fig. 13 Time-frequency image after adding noise

利用 3.4 节中 SelfNet 直接对小样本训练得到的权重进行重建,结果如图 14 所示。

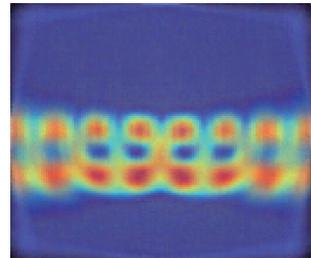


图 14 SelfNet 小样本训练权重得到的重建时频图

Fig. 14 Reconstructed time-frequency image obtained by SelfNet small sample training weight

利用 3.4 节中 SelfNet 进行迁移训练后得到的权重进行重建,结果如图 15 所示。

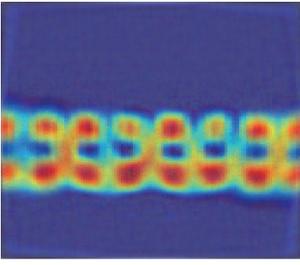


图 15 SelfNet 迁移训练权重得到的重建时频图  
Fig. 15 Reconstructed time-frequency image obtained by SelfNet transferring training weight

对比图 14 和图 15, 可以看到: SelfNet 直接利用小样本训练的权重进行重建的效果很差, 时频曲线的特征信息遭到破坏; 而利用迁移训练的权重进行重建后, 时频曲线的特征信息成功提取出来, 更接近图 12 所示的原始时频曲线, 实现了良好的重建。

## 4 结 论

本文提出了一种基于 CNN 的无人机时频曲线重建模型 SelfNet。实验结果表明, SelfNet 能够有效提取时频曲线的特征并实现良好的重建。通过小样本实验和迁移学习, 验证了 SelfNet 在数据稀缺情况下的泛化能力。重建后的时频图具有清晰的时频特征, 为后续无人机的分类和微动参数估计奠定了良好的基础。尽管如此, SelfNet 对实测回波数据的重建质量仍有提升空间, 需要进一步优化结构以提高模型的性能。总体而言, 本文的研究为复杂环境下无人机时频曲线的重建提供了一种新的思路。

## 参考文献

- [1] PANG C S, HAN Y, HOU H L, et al. Micro-doppler signal time-frequency algorithm based on STFRFT[J]. Sensors(Switzerland), 2016, 16(10): 1559.
- [2] 宋志勇, 许云涛. 基于多普勒与微多普勒联合利用的弱小目标检测与估计方法[J]. 电子与信息学报, 2023, 45(11): 4083-4091.
- [3] SONG ZH Y, XU Y T. Weak targets detection and estimation based on joint use of doppler and micro-doppler[J]. Journal of Electronics & Information Technology, 2023, 45(11): 4083-4091.
- [4] YANG S J, ZHANG Z T, ZHANG J L, et al. Impact of rotary-wing UAV wobbling on millimeter-wave air-to-ground wireless channel[J]. IEEE Transactions on Vehicular Technology, 2022, 71(9): 1-12.
- [5] BANAGAR M, DHILLON H S, MOLISCH A F. Impact of UAV wobbling on the air-to-ground wireless channel [J]. IEEE Transactions on Vehicular Technology, 2020, 69(11): 14025-14030.
- [6] XIAO ZH Y, ZHU L P, LIU Y M, et al. A survey

- on millimeter-wave beamforming enabled UAV communications and networking [J]. IEEE Communications Surveys and Tutorials, 2022, 24(1): 557-610.
- [7] WANG Z X, CHEN L X, XIAO P, et al. Enhancing time-frequency resolution via deep-learning framework[J]. IET Signal Processing, 2023, 17(4): e12210.
- [8] RHIF M, BEN ABBES A, FARAH I R, et al. Wavelet transform application for/in non-stationary time-series analysis: A Review[J]. Applied Sciences, 2019, 9(7): 1345.
- [9] BISHT A, DHIMAN A, KUMAR S, et al. A comprehensive review of deep learning techniques for image and video analysis [C]. 2024 International Conference on Emerging Innovations and Advanced Computing(INNOCOMP), 2024.
- [10] MEHRISH A, MAJUMDER N, BHARDWAJ R, et al. A review of deep learning techniques for speech processing [J]. Information Fusion, 2023, 99: 101869.
- [11] ZHANG L, ZHANG Y Y, SU Y R, et al. A new method for improving time and frequency resolution of passive receiving radar system[J]. IEEE Transactions on Industrial Informatics, 2024, 20(11): 1-13.
- [12] KRISHNA B M, SATYANARAYANA S V V, SATYANARAYANA P V V, et al. Improving time-frequency resolution in non-stationary signal analysis using a convolutional recurrent neural network[J]. Signal, Image and Video Processing, 2024, 18(5): 4797-4810.
- [13] CHOUDHURY M D, BLINCOE K, DHUPIA J S. Deep learning based time-frequency image enhancement method for machinery health monitoring[C]. 2023 IEEE/ASME International Conference on Advanced Intelligent Mechatronics(AIM), 2023.
- [14] 张梓鑫. 基于时频分析和深度学习的飞行目标分类识别方法研究[D]. 太原: 中北大学, 2020.
- [15] ZHANG Z X. Research on classification and recognition method of flying target based on time-frequency analysis and deep Learning[D]. Taiyuan: North University of China, 2020.
- [16] 范世琦, 涂刚毅, 申鑫. 基于改进 Kalmus 滤波的悬停无人机检测技术[J]. 电子测量技术, 2023, 46(16): 32-37.
- [17] FAN SH Q, TU G Y, SHEN X. Hovering UAV detection technology based on improved Kalmus filtering [J]. Electronic Measurement Technology, 2023, 46(16): 32-37.

- 2023, 46(16): 32-37.
- [15] 孙延鹏, 李思锐, 屈乐乐. 基于多域特征融合的旋翼无人机分类识别[J]. 雷达科学与技术, 2023, 21(4): 447-453.  
SUN Y P, LI S R, QU L L. Rotorcraft UAV classification and recognition based on multi domain feature fusion [J]. Radar Science and Technology, 2023, 21(4): 447-453.
- [16] 吴胜垚, 陈星. 图像任务中空间和通道注意力机制研究综述[J]. 微电子学与计算机, 2025, 42(3): 1-13.  
WU SH Y, CHEN X. A review of the spatial and channel attention mechanisms in image tasks [J]. Microelectronics & Computer, 2025, 42(3): 1-13.
- [17] 黄诚. 基于卷积神经网络的雷达探测无人机目标分类[D]. 天津: 中国民航大学, 2021.  
HUANG CH. Classification of UAVs detected by radar based on convolutional neural networks [D]. Tianjin: Civil Aviation University of China, 2021.
- [18] PANG C S, LIU ZH N, SUN J CH, et al. ECM Net- A lightweight neural network for target micro-doppler feature classification in complex scenarios[J]. Digital Signal Processing, 2025, 164: 105247.
- [19] 袁非牛, 章琳, 史劲亭, 等. 自编码神经网络理论及应用综述[J]. 计算机学报, 2019, 42(1): 203-230.  
YUAN F N, ZHANG L, SHI J T, et al. Theories and application of auto-encoder neural networks: a literature survey[J]. Chinese Journal of Computers, 2019, 42(1): 203-230.
- [20] RONNEBERGER O, PHILIPP F, BROX T. U-Net: Convolutional networks for biomedical image segmentation [J]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015, 9351: 234-241.
- [21] 林钱强, 秦正阳, 蒋李兵, 等. 简单野外背景条件下地面雷达对“低慢小”无人机探测数据集[J]. 信号处理, 2024, 40(11): 2095-2104.  
LIN Q Q, QIN ZH Y, JIANG L B, et al. Ground-based radar detection dataset of “low slow small” unmanned aerial vehicles under simple field background conditions[J]. Journal of Signal Processing, 2024, 40(11): 2095-2104.

### 作者简介

**孙嘉辰**, 硕士研究生, 主要研究方向为雷达信号处理、无人机检测与分类。

E-mail: 1176053023@qq.com

**庞存锁**(通信作者), 博士, 教授, 主要研究方向为雷达成像、时频分析、目标检测与分类。

E-mail: pangcunsuo@126.com