

DOI: 10.13382/j.jemi.B2508583

# 基于多尺度残差网络的复值信号频率估计\*

王超<sup>1</sup> 杨辉跃<sup>1</sup> 肖玮<sup>1</sup> 何智杰<sup>2</sup> 王范东<sup>1</sup>  
(1. 中国人民解放军联勤保障部队工程大学 重庆 401331; 2. 31680 部队 崇州 611233)

**摘要:**频率估计是测量仪表领域的关键技术,针对传统周期图法与多信号分类(multiple signal classification, MUSIC)算法在低信噪比环境下性能急剧下降,难以满足仪表测量的精度需求。提出了一种基于多尺度残差网络的频率估计方法(multi-scale frequency representation, MultiFR)。首先,通过并行的3×1和5×1卷积核提取不同尺度特征,增强对局部细节和全局模式的捕获能力。然后,引入残差连接机制克服深层网络梯度消失问题,确保特征有效传播,采用L2范数平方损失函数,实现对网络输出频谱与理想频谱之间偏差的精确度量。最后,使用动态信噪比训练策略,提高模型在不同噪声水平下的适应性,通过高分辨率频率表示输出模块,实现精确的频率峰值定位。实验结果表明,所提方法的频率分辨能力得到提升,在0 dB极低信噪比条件下,MultiFR的漏检率为22.2%,Chamfer距离为0.145,较DeepFreq方法分别相对提升了4.1%和5.8%,并优于PSnet、MUSIC及周期图等主流方法。经过科式流量计信号验证,证明了所提方法在低信噪比下具有一定的可行性、有效性与鲁棒性。

**关键词:** 频率估计; 深度学习; 多尺度残差网络; 低信噪比; 复值信号; 测量仪表

**中图分类号:** TN911      **文献标识码:** A      **国家标准学科分类代码:** 460.40

## Frequency estimation of complex-valued signal based on multi-scale residual network

Wang Chao<sup>1</sup> Yang Huiyue<sup>1</sup> Xiao Wei<sup>1</sup> He Zhijie<sup>2</sup> Wang Fandong<sup>1</sup>  
(1. Engineering University of the Joint Logistics Support Force, Chongqing 401331, China;  
2. Unit 31680 of the People's Liberation Army, Chongzhou 611233, China)

**Abstract:** Frequency estimation is a key technology in the field of measurement instrumentation. Traditional periodogram and multiple signal classification (MUSIC) algorithms suffer from severe performance degradation under low signal-to-noise ratio environments, failing to meet the precision requirements of instrumentation measurements. This paper proposes a frequency estimation method based on multi-scale residual networks (MultiFR). First, parallel 3×1 and 5×1 convolutional kernels extract features at different scales, enhancing the ability to capture both local details and global patterns. Then, residual connections mechanisms are introduced to overcome the gradient vanishing problem in deep networks, ensuring effective feature propagation. The L2 norm squared loss function is adopted to achieve precise measurement of the deviation between the network output spectrum and the ideal spectrum. Finally, a dynamic SNR training strategy is utilized to improve the model's adaptability under different noise levels, and a high-resolution frequency representation output module is implemented to achieve accurate frequency peak localization. Experimental results demonstrate that the proposed method achieves improved frequency resolution capability. Under extremely low SNR conditions of 0, MultiFR achieves a miss detection rate of 22.2% and a Chamfer distance of 0.145, representing relative improvements of 4.1% and 5.8% respectively compared to the DeepFreq method, and outperforming mainstream methods such as PSnet, MUSIC, and periodogram. Validation with Coriolis flowmeter signals confirms the feasibility, effectiveness, and robustness of the proposed method under low SNR conditions.

**Keywords:** frequency estimation; deep learning; multi-scale residual network; low SNR; complex-valued signal; measurement instrument

## 0 引言

复值正弦信号的频率估计是信号处理的一个重要问题,涉及到遥感、通信、雷达、电力系统等诸多领域<sup>[1-5]</sup>,在现代工业自动化和精密测量领域具有广泛而深远的影响。例如,在科氏流量计、线性调频连续波雷达液位计等应用中<sup>[6-7]</sup>,信号频率估计结果直接影响着仪器的精准测量。

传统的频率估计方法主要分为参数化方法而非参数化方法 2 类。参数化方法以多信号分类和旋转不变技术估计信号频率为代表<sup>[8-9]</sup>,基于信号子空间理论,在高信噪比条件下能够实现超分辨率的频率估计。然而,这些方法对模型假设敏感,在低信噪比、频率密集时性能显著下降,且需要预先知道信号源数量。非参数化方法如周期图、Welch 方法等基于傅里叶变换<sup>[10-11]</sup>,计算简单但面临分辨率受限、频谱泄漏等问题。为解决以上这些问题,文献[6]先通过海明窗函数对信号进行处理,再用多信号分类算法进行频率估计,解决信号截获造成的频谱泄漏问题,提高多信号分类算法的分辨率和稳定性。文献[7]针对非整周期低信噪比科氏流量计相位差测量问题,提出了周期相移算法,极大抑制了频谱泄漏。文献[12]提出了基于改进 Chirp-Z 变换的高精度频率估计算法,通过频率细化和谱线插值提升了频率估计精度。尽管这些改进方法在一定程度上提高了频率估计性能,但在极低信噪比条件下频率估计的鲁棒性不足。

近年来,深度学习因优异的特征提取能力,已广泛应用于图像识别、语音识别、自然语言理解等领域<sup>[13]</sup>。在信号处理中,多种基于深度学习的频率估计算法被研究,主要聚焦于人声基频估计和多输入多输出系统的到达方向估计<sup>[14-15]</sup>。但这些方法实际应用灵活性不足,即网络需为不同 SNR 或目标数量重新训练。文献[16]提出基于学习的 PSnet 框架,在模拟数据上训练神经网络,从有限数量样本中估计多正弦信号频谱,在低信噪比时与线性非参数化频率估计方法的稳健性相当,在高信噪比时与参数化频率估计方法的准确性相当。文献[17]提出的 DeepFreq 深度学习框架,使用多通道编码器替换 PSnet 框架的单线性映射,通过神经网络直接从含噪样本中学习频谱表示,用于多正弦信号频率估计。其在中高噪声水平下显著超越传统 MUSIC、周期图法。然而,现有深度学习频率估计方法仍存在局限,单一尺度特征提取,难以同时捕获信号的局部细节和全局模式;深层网络训练困难,随着网络深度增加,梯度消失和性能退化问题逐渐显现。

本文提出了一种基于多尺度残差网络的复值信号频率估计方法 MultiFR。该方法通过引入并行的 3×1 和 5×

1 卷积核提取不同尺度特征,实现局部和全局信息的融合。引入残差连接解决深层网络训练困难的问题,确保梯度的有效传播和网络性能的稳定提升,在低信噪比下对含噪复值信号频率估计效果有一定的提升。

## 1 信号模型与频率表示

### 1.1 信号模型

在测量仪表应用中,接收到的观测信号  $y[n]$  通常由多个频率分量叠加构成,同时受到了环境噪声的干扰<sup>[18-20]</sup>。例如,在科氏流量计中,振动传感器输出的混合振动信号包含多个频率分量。在线性调频连续波雷达液位计中,回波信号经混频后产生的差频信号也呈现类似特性。基于这些应用背景,本文采用复值正弦信号模型<sup>[19]</sup>,其数学表达式为:

$$y[n] = \sum_{i=1}^m a_i e^{j2\pi f_i n} + w[n] \quad n = 0, 1, \dots, N-1 \quad (1)$$

式中:  $m$  为信号中正弦分量的个数;  $a_i \in \mathbb{C}$  为第  $i$  个分量的复数幅度;包含幅值和相位信息;  $f_i \in [-0.5, 0.5]$  为第  $i$  个分量的归一化频率;  $n$  为离散采样时刻索引,  $w[n]$  为加性高斯白噪声;频率估计的核心任务是从含噪观测信号  $y[n]$  中准确识别并估计出各个频率分量  $\{f_1, f_2, \dots, f_m\}$ 。

### 1.2 理想频率表示生成

理想频率表示是将频率估计问题转化为端到端回归学习的核心。其本质是将信号中真实频率分量在高分辨率频率网格上进行连续化表达,使深度网络能够直接学习的频率分布与理想频率表示的映射关系。理想频率表示  $T[u]$  定义为以每个真实频率为中心的窄高斯核叠加而成,其数学表达式如下:

$$T[u] = \sum_{i=1}^m K(u - f_i) \quad (2)$$

式中:  $f_i$  为信号中第  $i$  个真实频率;  $m$  为真实频率个数;  $u$  为频率域中的变量;  $K: \mathbb{R} \rightarrow \mathbb{R}$  为窄高斯核函数;  $T[u]$  是一个光滑函数,在真实频率位置有尖锐的峰值,并在远离这些位置时迅速衰减。

## 2 方法原理

### 2.1 MultiFR 网络模型

MultiFR 网络模型在 DeepFreq 模型基础上引入多尺度残差块,实现了多尺度特征融合与深层残差学习。如图 1 所示,MultiFR 网络模型结构包括输入信号处理、特征投影层、多尺度残差编码器、频率域重构 4 个模块。

### 2.2 输入信号处理与特征投影

对原始含噪信号进行复数建模与分帧处理,设每一帧信




图1 MultiFR 网络模型结构

Fig. 1 Overall architecture of the MultiFR network model

号为  $\mathbf{y} \in \mathbb{C}^N$ , 其中  $N$  为采样点数。采用实部与虚部分离的方式, 将每帧复信号表示为  $\mathbf{X}_f = [\text{Re}(\mathbf{y}), \text{Im}(\mathbf{y})] \in \mathbb{R}^{2N}$ , 保留原始信号的全部幅度和相位信息。输入信号通过特征投影层的线性变换映射到高维特征空间, 其线性变换的输出可以用特征矩阵表示为  $[\mathbf{A}_{1y}, \mathbf{A}_{2y}, \mathbf{A}_{3y}, \dots, \mathbf{A}_{cy}]$ , 其中, 每个  $\mathbf{A}_i (1 \leq i \leq c)$  是固定的  $M \times N$  矩阵,  $c$  为通道数, 各通道从输入信号中提取互补特征。特征重塑将线性变换后的一维向量重组为三维张量, 这种线性变换与特征重塑相结合的设计使模型能够同时处理多个通道的特征表示, 为后续的多尺度卷积操作奠定基础。

### 2.3 多尺度残差编码器

深度网络架构能够逐层学习从低级到高级的频率特征表示, 有效提升对复杂频率模式的建模能力, 特别是在低信噪比下多分量信号场景中表现出更强

的鲁棒性<sup>[21-23]</sup>。这里多尺度残差编码器整体采用 20 层深度结构, 奇数层为多尺度残差块, 偶数层为标准卷积块, 两者交替堆叠。第 1 到第 4 层进行低级特征提取, 捕获基本频率模式。第 5 到第 18 层进行深度特征学习, 实现频谱的精细化与去噪。第 19 到 20 层进行高级特征抽象和最终特征编码, 生成最优的频谱信息。

MultiFR 网络模型的核心创新在于多尺度残差块, 其内部结构如图 2 所示, 多尺度残差块内部结构采用 2 条并行分支, 分别使用  $3 \times 1$  和  $5 \times 1$  一维卷积核捕获不同尺度的频率特征。每个分支包含 Conv1d 卷积层、BatchNorm 批归一化层和 ReLU 激活函数的组合。分支输出在通道维度拼接后, 经  $1 \times 1$  卷积和 BN 融合, 最后与输入残差相加, 并经 ReLU 激活输出。




图2 多尺度残差块内部结构

Fig. 2 Internal structure of the multi-scale residual block

### 2.4 频率域重构

频率域重构模块通过转置卷积将编码器输出的 64 通道 125 维特征上采样至 1 000 维高分辨率频率表示, 其输出尺寸  $S_o$  为:

$$S_o = (L - 1) \times s - 2p + k + o \quad (3)$$

式中:  $L$  为输入序列长度;  $s$  为步长;  $p$  为填充参数;  $k$  为卷积核大小;  $o$  为输出填充。频率表示输出模块生成最终一维高分辨率频谱  $\hat{\mathbf{T}} \in \mathbb{R}^{1000}$ , 其峰值位置对应估计的

信号频率。

2.5 损失函数设计

通过最小化训练模型预测频谱与理想高斯核频谱之间差值的 L2 范数的平方损失,该损失能够有效度量网络模型输出频谱与理想频谱之间的偏差,实现对 MultiFR 网络的校准。使其能够从含噪声的低分辨率数据中学习得到准确的频率表示,为频率估计提供可靠基础。单个样本损失  $L_b$  数学表达为:

$$L_b = \sum_{t=1}^{1000} (\tilde{T}(u_t) - T(u_t))^2 \tag{4}$$

式中:  $\tilde{T}(u_t)$  为 Multifr 网络模型预测输出的频率表示;  $T(u_t)$  为真实频率表示;  $t$  为网格点数;  $u_t$  网格上离散的点。

3 实验数据及评估指标

3.1 实验数据集

实验数据集与 DeepFreq<sup>[20]</sup> 保持一致配置,使用式(1)生成的复值正弦信号。该信号系数由  $a_i = (0.1 + |\omega_i|)e^{j\theta_i}$  确定,其中  $\omega_i$  服从标准高斯分布,  $\theta_i$  在  $[0, 2\pi]$  上均匀分布,模拟实际信号的相位随机性。频率值  $f_1, f_2, \dots, f_m$ , 它们之间的最小间隔不小于  $1/N$ , 间隔设置为  $1/N + |\omega|$ , 其中  $\omega$  是标准偏差为  $2.5/N$  的高斯随机变量。

训练集包含 200 000 条复值正弦信号,每条信号长度为 50 个采样点,信号中的频率分量数量在 1~10 之间均匀随机分布,确保网络能够学习处理不同复杂度的频谱结构。训练过程采用动态信噪比策略,每个批次随机选择不同的信噪比水平,增强模型的噪声适应能力。验证集使用固定信噪比为 0 的 1 000 条信号进行评估,为确保验证过程的一致性,训练和验证使用不同的随机种子确保数据的独立性。

测试集包含 11 000 条信号样本(范围 0~50 dB,梯度 5 dB)构建 11 个不同信噪比级别,每个信噪比级别包含 1 000 条独立的信号,每条测试信号的频率分量数量在 1~10 之间均匀随机分布。测试阶段严格按照固定的信噪比级别进行评估,确保结果的可比性和可重复性。

3.2 评估指标

采用信号频率估计领域中广泛使用的 2 个核心评估指标,具体为漏检率(false negative rate, FNR)和 Chamfer 距离,对所提 MultiFR 模型的性能进行全面评估。

FNR 定义为未能检测到的真实频率比例,当估计频率与真实频率距离大于  $1/2N$  时,判定未检测到真实频率。FNR 反映了算法的检测完整性和鲁棒性,取值范围在 0%~100%,更低的 FNR 值意味着更好的检测性能。

在噪声水平和正弦分量数量均未知的实际场景中, Chamfer 距离能综合衡量真实频率与估计频率之间的匹配程度。Chamfer 距离计算式如下:

$$d(f, \tilde{f}) = \sum_{f_i \in f} \min_{\tilde{f}_j \in \tilde{f}} |f_i - \tilde{f}_j| + \sum_{\tilde{f}_j \in \tilde{f}} \min_{f_i \in f} |\tilde{f}_j - f_i| \tag{5}$$

式中:  $f = (f_1, f_2, \dots, f_m)$  为真实频率集合,  $\tilde{f} = (\tilde{f}_1, \tilde{f}_2, \dots, \tilde{f}_m)$  为估计频率集合, Chamfer 距离的取值范围在 0~1 之间,更低的 Chamfer 距离表示更好的频率估计质量。

3.3 实验参数设置

实验采用的计算平台配置如表 1 所示,网络训练参数配置如表 2 所示。

表 1 计算平台配置

Table 1 Computing platform configuration

| 参数名称 | 具体设置                      |
|------|---------------------------|
| 处理器  | Intel Xeon E-2224G        |
| GPU  | NVIDIA GeForce RTX 3060Ti |
| 操作系统 | Ubuntu 20.04 LTS          |

表 2 网络训练参数设置

Table 2 Network Training Parameter Settings

| 参数名称      | 符号       | 取值            |
|-----------|----------|---------------|
| 信号长度      | $N$      | 50            |
| 归一化频率     | $f_i$    | $(-0.5; 0.5)$ |
| 理想频率表示高斯核 | $\sigma$ | 0.3           |
| 特征投影层通道数  | $c$      | 64            |
| 特征投影层输出维度 | $M$      | 125           |
| 步长        | $s$      | 8             |
| 转置卷积核大小   | $k$      | 25            |
| 填充参数      | $p$      | 9             |
| 输出填充      | $o$      | 1             |

4 实验结果分析

分别与基于深度学习的基准 DeepFreq 模型、使用轻量级深度网络的 PSnet、采取经典子空间方法的 MUSIC 和基于传统 FFT 周期图方法进行对比,重点分析各方法在不同信噪比条件下的 FNR、Chamfer 距离及频率估计性能,特别关注低信噪比场景下的算法表现。

4.1 全信噪比的 FNR 性能分析

使用测试集每种信噪比的 1 000 个样本实验,计算 5 种方法的 FNR,结果取平均值。图 3 为全信噪比范围内 0~50 dB(5 dB 步进)各方法的 FNR 曲线。从整体趋势看,所有方法的 FNR 均随信噪比的提升而下降,但下降速率和收敛特性存在显著差异。在极低信噪比区间(0~10 dB),深度学习方法展现出明显优势。MultiFR 在信噪比为 0 时达到 22.2% 的最低 FNR,在中等信噪比区间




图3 全信噪比范围 FNR 性能对比

Fig. 3 FNR performance comparison across the full SNR range

(10~30 dB), 各方法性能差距逐渐缩小。MultiFR 和 DeepFreq 在 15 dB 后 FNR 降至 5% 以下, 20 dB 时接近 1%。PSnet 及传统方法下降缓慢。在高信噪比区间 (30~50 dB), 所有方法趋于收敛, MultiFR 和 DeepFreq

的 FNR 接近 0, MUSIC 在 50 dB 时 FNR 接近 0。表明在近似无噪声条件下, 各方法都能准确估计频率, 性能差异主要体现在噪声鲁棒性上。

图 4 从 4 个维度全面展示无噪声条件下各方法的性能表现, 图 4(a) FNR 对比显示 MultiFR 达到 22.2% 最优性能, 分别优于 DeepFreq 的 23.1%、PSnet 的 28.1%、MUSIC 的 38.4% 和周期图的 29.7%。图 4(b) 为相对改进性能分析, 量化了 MultiFR 的优势幅度, 相比 DeepFreq 仅有 4.1% 改进, 但相比 PSnet、MUSIC 和周期图分别改进 21.2%、42.3%、25.4%。由图 4(c) 可以看出, 在 0~10 dB 低信噪比区间, MultiFR 的 FNR 略低于 DeepFreq 始终保持领先, 验证了模型在极端噪声条件下的鲁棒性。图 4(d) 为使用 10 000 个无噪声测试样本进行的统计显著性分析结果, 计算各方法的 FNR 均值和 95% 置信区间, 以 MultiFR 为基准通过  $t$  分布检验, 结果显示 MultiFR 与其他方法之间差异达到了显著水平  $p < 0.001$ , 这表明 MultiFR 在低信噪比条件下的性能优势具有统计学意义。





(a) 无噪声条件下漏检率对比  
(a) False negative rate comparison at 0 dB(b) MultiFR 相对性能提升  
(b) Relative performance improvement of MultiFR(c) 低信噪比下漏检率对比  
(c) False negative rate comparison at Low SNR(d) 无噪声条件下的下显著性对比  
(d) Significance analysis at 0 dB

图4 无噪声条件下综合性能分析

Fig. 4 Comprehensive performance analysis under 0 dB SNR

## 4.2 全信噪比的 Chamfer 距离性能分析

使用测试集每种信噪比 1 000 个样本进行实验, 计算 5 种方法的 chamfer 距离, 结果取平均值以降低随机误差。图 5 为 5 dB 步进的 0~50 dB 范围各方法的 Chamfer 距离, MultiFR 在无噪声时达到 0.145 的最优 Chamfer 距离, 采用相对误差减少率分析, 相对 DeepFreq 的 0.154

改进 5.8%, 相对传统方法 PSnet 的 0.307、周期图的 0.376 和 MUSIC 的 0.540 分别改进 52.8%、61.4% 和 73.1%。这些数据表明, MultiFR 不仅减少了频率漏检, 同时有效抑制了虚警, 实现了更平衡的估计性能。随着信噪比提升, 各方法的 Chamfer 距离呈指数下降趋势。在 15 dB 后, 3 种深度学习方法 MultiFR、DeepFreq 及

PSnet 的 Chamfer 距离收敛至 0.01 左右,而传统方法仍保持在较高水平。




图 5 Chamfer 距离性能对比

Fig. 5 Chamfer distance performance comparison

#### 4.3 不同信噪比条件下的频率估计

考虑到实际应用中存在多信号场景,从测试集中选取 20 dB 和无噪声 2 种典型的信噪比样本,该样本是由 9 个不同频率正弦波叠加相应信噪比噪声合成的信号。图 6 为各方法的频率估计结果。图 6 中纵轴为频率响应,

横轴为归一化频率,黑色虚线为真实频率位置,红色实线为估计频率位置,蓝色曲线为不同方法计算出的频率表示。

图 6(a) 为 20 dB 中等信噪比的频率估计结果,MultiFR 输出的频谱峰值尖锐且定位准确,成功识别出全部 9 个频率分量,DeepFreq、PSnet 和周期图方法识别出 8 个频率分量,但峰值略有展宽,MUSIC 仅识别 7 个频率分量,部分相邻频率未能分辨。

图 6(b) 为当信噪比降至 0 时的频率估计,MultiFR 保持了良好的频谱形态,准确识别出 8 个频率分量,仅在边缘频率 -0.326 处因噪声干扰产生漏检。DeepFreq、PSnet 和周期图方法峰值频谱展宽,估计出 7 个频率分量。MUSIC 方法退化严重,多个频率合并为宽峰,仅识别出 6 个频率分量。相比传统方法,MultiFR 在极低信噪比条件下估计频率位置与真实频率位置重合最好,这一结果验证了 MultiFR 的多尺度特征融合机制在复杂频谱估计中的优势,多尺度残差架构中的  $3 \times 1$  和  $5 \times 1$  并行卷积分支的协同作用保证了其在低信噪比频率估计中有良好的鲁棒性。




图 6 多信噪比条件下频率估计对比

Fig. 6 Frequency estimation comparison under multiple SNR conditions

#### 4.4 科氏流量计信号应用验证

由于科式流量计信号实际频率波动范围很小,这里不考虑频率扰动情况,信号仿真设置在 0 信噪比条件下进行,该信号由科式流量计典型工作频率 100 Hz、工频干扰 50 Hz 组成,采样频率 2 000 Hz。测试 5 种方法的频率检测性能,如图 7 所示,可以看出在 0 信噪比条件下 3 种

深度学习方法均能估计出 100 Hz 工作频率,在 50 Hz 附近均有幅值响应,DeepFreq 比 MultiFR 幅值较高,但两者估计的频率一致,而 MUSIC 与 Periodogram 估计的频率偏离 100 Hz,未能估计出 50 Hz 频率。总体上深度学习方法在低信噪比条件下多频率估计的性能较好。

为比较深度学习方法与传统方法针对实际信号的频




图7 仿真信号频谱对比

Fig. 7 Spectrum comparison of simulated signals

率估计能力,使用科氏流量计实验平台,该实验平台分为管道装置和数据采集装置2个部分。管道装置由罗斯蒙特 F200S 型科氏流量计、TQ884 型科氏流量计、电动调节阀、电子台秤、水箱等组成,数据采集装置由 PC 机只利用 NI 多通道数据采集器采集罗斯蒙特 F200S 型科氏流量计第一路信号,传感器输出信号采样频率 20 000 Hz。使用开关阀开度 25%,流量计瞬时流量示值 15.9 kg/min 的传感器信号。由于采集的信号真实频率未知但是在很小范围内波动,这里以自适应陷波器 (adaptive notch filter, ANF) 方法估计的频率为参考频率,各方法估计结果如图 8 所示,可以看出深度学习方法 MultiFR 与 DeepFreq 估计的频率接近 ANF 估计的频率,但分辨率还需要进一步提高。




图8 实际信号频率估计对比

Fig. 8 Comparison of frequency estimation for actual signals

## 5 结论

针对测量仪表在低信噪比条件下频率估计精度不足的问题,提出了多尺度频率表示网络 MultiFR。该方法通过并行的  $3 \times 1$  和  $5 \times 1$  卷积分支提取多尺度时频特征,结合残差连接机制克服深层网络梯度消失问题,实现了局部与全局信息的有效融合。实验证明,在 0 信噪比条件下 MultiFR 的漏检率为 22.2%, Chamfer 距离为 0.145,相对 DeepFreq 网络分别提升 4.1% 和 5.8%,优于 PSnet、MUSIC 及周期图等传统方法,在该信噪比的下 9 个频率

分量的含噪信号测试中,MultiFR 估计频率与真实频率位置重合最好。经过科氏流量计信号测试,MultiFR 实现了在未知信噪比条件下稳定运行,通过修改训练数据集可扩展至其他信号和噪声模型。未来研究将探索如何确保模拟训练数据能稳健泛化到实际测量场景,以及设计能够提供不确定性估计的频率表示模型,进一步提升 MultiFR 在工业仪表测量中的实用价值。

## 参考文献

- [1] XU S, NIU X, RU H, et al. Classification of small targets on sea surface based on improved residual fusion network and complex time-frequency spectra[J]. Remote Sensing, 2024, 16(18): 3387.
- [2] 黄翔东,吕冲,李燕平,等. 基于渐进可控频偏范围的多频实信号频率估计器[J]. 振动与冲击, 2024, 43(17): 12-18.  
HUANG X D, LYU CH, LI Y P, et al. Multi-frequency real signal frequency estimator based on gradually controllable frequency offset range [J]. Journal of Vibration and Shock, 2024, 43(17): 12-18.
- [3] 黄云志,翟丽文,吴晨,等. 面向强周期振动干扰的涡街流量计系统研制[J]. 电子测量与仪器学报, 2023, 37(8): 105-112.  
HUANG Y ZH, ZHAI L W, WU CH, et al. Development of vortex flowmeter system for strong periodic vibration interference [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 105-112.
- [4] QI Mi J, BO Q, LIU J Y, et al. Frequency Estimation Method Based on Complex Network [C]. 2025 International Conference on Communication Networks and Smart Systems Engineering (ICCNSE). IEEE, 2025: 234-239.
- [5] 王迪,邓小涛,唐隆煌,等. 基于卷积-长短时记忆网络的含噪正弦信号频率估计算法[J]. 天津工业大学学报, 2025, 44(6): 82-90.  
WANG D, DENG X T, TANG L H, et al. Frequency estimation algorithm for noisy sinusoidal signals based on convolutional-long short-term memory network [J]. Journal of Tiangin Polytechnic University, 2025, 44(6): 82-90.
- [6] 李昊宇,黄丹平,罗凡. 非整周期低信噪比科氏流量计相位差测量研究[J]. 国外电子测量技术, 2023, 42(11): 89-96.  
LI H Y, HUANG D P, LUO F. Research on phase difference measurement of Coriolis flowmeter with non-integer period and low signal-to-noise ratio [J]. Foreign

- Electronic Measurement Technology, 2023, 42 ( 11 ): 89-96.
- [ 7 ] 孙苏云,郭剑,付阳烨,等. 基于 FMCW 雷达的非接触式心率估计方法[J]. 电子测量技术, 2023, 46 ( 14 ): 117-122.
- SUN S Y, GUO J, FU Y Y, et al. Non-contact heart rate estimation method based on FMCW radar[J]. Electronic Measurement Technology, 2023, 46 ( 14 ): 117-122. DOI: 10.19651/j.cnki.emt.2211489.
- [ 8 ] MERKOFER J P, REVACH G, SHKEZINGER N, et al. DA-MUSIC: Data-driven DoA estimation via deep augmented MUSIC algorithm[J]. IEEE Transactions on Vehicular Technology, 2023, 73(2): 2771-2785.
- [ 9 ] LV L, WU S, SU Y, et al. Dual-stream reconstruction network-aided ESPRIT algorithm for DoA estimation in coherent scenarios[J]. IEEE Transactions on Vehicular Technology, 2024, 73(12): 19669-19681.
- [ 10 ] ASTFALCK L C, SYKULSKI A M, CRIPPS E J. Debiasing Welch's method for spectral density estimation [J]. Biometrika, 2024, 111(4): 1313-1329.
- [ 11 ] SELVA J. Detection and estimation of diffuse signal components using the periodogram[J]. Sensors, 2024, 24(20): 6650.
- [ 12 ] 朱颖洁,张武雄,易辉跃,等. 基于改进 Chrip-Z 变换的高精度频率估计算法[J]. 电子科技大学学报, 2024, 53(4): 525-532.
- ZHU Y J, ZHANG W X, YI H Y, et al. High-precision frequency estimation algorithm based on improved Chrip-Z transformation[J]. Journal of University of Electronic Science and Technology of China, 2024, 53 ( 4 ): 525-532.
- [ 13 ] AHMED S F, ALAM M S B, HASSAN M, et al. Deep learning modelling techniques: Current progress, applications, advantages, and challenges[J]. Artificial Intelligence Review, 2023, 56(11): 13521-13617.
- [ 14 ] YAN Y, HUANG Q. Robust doa estimation using multi-scale fusion network with attention mask [J]. Applied Sciences, 2024, 14(11): 4488.
- [ 15 ] NAVABHARAT REDDY G, CV R. Ensemble learning-based channel estimation and hybrid precoding for millimeter-wave massive multiple input multiple output system [J]. Transactions on Emerging Telecommunications Technologies, 2023, 34(6): e4766.
- [ 16 ] IZACARD G, BERNSTEIN B, FERNANDEZ-GRANDA C. A learning-based framework for line-spectra super-resolution [C]. ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2019: 3632-3636.
- [ 17 ] IZACARD G, MOHAN S, FERNANDEZ-GRANDA C. Data-driven estimation of sinusoid frequencies [J]. Advances in Neural Information Processing Systems, 2019, 32: 5128-5138.
- [ 18 ] 张锦轩,匡华星,王犇,等. 基于多尺度注意力增强深度残差网络的 DOA 估计[J/OL]. 现代防御技术, 1-11 [2026-01-11]. <https://link.cnki.net/urlid/11.3019.tj.20251009.1042.002>.
- ZHANG J X, KUANG H X, WANG B, et al. DOA estimation based on multi-scale attention enhanced deep residual network [J/OL]. Modern Defence Technology, 1-11 [2026-01-11]. <https://link.cnki.net/urlid/11.3019.tj.20251009.1042.002>.
- [ 19 ] PAN P, ZHANG Y, DENG Z, et al. Complex-valued frequency estimation network and its applications to superresolution of radar range profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-12.
- [ 20 ] 胡泰洋,邵晓浪,肖孟煊,等. 一种线性调频连续波探测抗雷达辐射源干扰方法[J]. 仪器仪表学报, 2022, 43(8): 253-260.
- HU T Y, SHAO X L, XIAO M X, et al. Methods of anti-radar emitter signal jamming for linear frequency modulated continuous wave detector[J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 253-260.
- [ 21 ] 聂钰蓉,张育芝. 基于多尺度残差网络的联合声呐与通信系统[J]. 舰船科学技术, 2025, 47(18): 149-154.
- NIE Y R, ZHANG Y ZH. Joint sonar and communication system based on multi-scale residual network[J]. Ship Science and Technology, 2025, 47(18): 149-154.
- [ 22 ] FANG H, LU C, HONG F, et al. Sleep apnea detection based on multi-scale residual network[J]. Life, 2022, 12(1): 119.
- [ 23 ] YAN Y, HUANG Q. Robust doa estimation using multi-scale fusion network with attention mask [J]. Applied Sciences, 2024, 14(11): 4488.

## 作者简介



王超, 2018 年于武汉科技大学获得学士学位, 现为中国人民解放军联勤保障部队工程大学硕士研究生, 主要研究方向为数字信号处理、计算机视觉。

E-mail: 2285868751@qq.com

Wang Chao received his B. Sc. degree from Wuhan University of Science and Technology in 2018. Now

he is a M. Sc. candidate in Engineering University of the Joint Logistics Support Force. His main research interests include digital signal processing and computer vision.



**杨辉跃** (通信作者), 2009 年于后勤工程学院获得学士学位, 2012 年于后勤工程学院获得硕士学位, 2015 年于后勤工程学院获得博士学位, 现为中国人民解放军联勤保障部队工程大学副教授, 主要研究方向为智能检测与智能控制、军事物联网。

E-mail: huiyue\_yang@163.com

**Yang Huiyue** (Corresponding author) received his B. Sc. degree from Logistical Engineering University in 2009, M. Sc. degree from Logistical Engineering University in 2012, and Ph. D. degree from Logistical Engineering University in 2015, respectively. Now he is an associate professor in Engineering University of the Joint Logistics Support Force. His main research interests include intelligent detection and intelligent control, military Internet of Things.



**肖玮**, 2005 年于后勤工程学院获得学士学位, 2008 年于后勤工程学院获得硕士学位, 2012 年于后勤工程学院获得博士学位, 现为中国人民解放军联勤保障部队工程大学教授, 主要研究方向为数字信号处理、计算机视觉、物联网工程与系统。

E-mail: wzwy@163.com

**Xiao Wei** received her B. Sc. degree from Logistical

Engineering University in 2005, M. Sc. degree from Logistical Engineering University in 2008, and Ph. D. degree from Logistical Engineering University in 2012, respectively. Now she is a professor in Engineering University of the Joint Logistics Support Force. Her main research interests include digital signal processing, computer vision, Internet of Things engineering and systems.



**何智杰**, 2010 年于国防科技大学获得学士学位, 现为 31680 部队工程师, 主要研究方向为计算机视觉、深度学习、数据挖掘。  
E-mail: hezhijie@alumni.nudt.edu.cn

**He Zhijie** received his B. Sc. degree from National University Defense and Technology in 2010. Now he is an engineer of Unit 31680. His main research interests include computer vision, deep learning and data mining.



**王范东**, 2015 年于解放军理工大学获得学士学位, 现为中国人民解放军联勤保障部队工程大学硕士研究生, 主要研究方向为数字信号处理、计算机视觉。

E-mail: wsfandong@qq.com

**Wang Fandong** received his B. Sc. degree from PLA University of Science and Technology in 2015. Now he is a M. Sc. candidate in Engineering University of the Joint Logistics Support Force. His main research interests include digital signal processing and computer vision.