

基于时频增强的小样本跳频信号调制识别*

王思远, 刘高辉

(西安理工大学 自动化与信息工程学院, 陕西 西安 710048)

摘要: 针对小样本条件下跳频信号调制识别性能受限的问题, 提出了一种基于时频变换增强的跳频信号调制识别方法。该方法以跳频信号的单跳时频灰度图为研究对象, 通过离散小波变换 (DWT)、短时傅里叶变换 (STFT) 以及低能量区域扰动三类时频增强策略, 对时频图像的细节信息进行分解、扰动与重构, 从而生成结构多样的增强样本, 实现训练数据的有效扩展。其中, 基于 DWT 和 STFT 的增强方法通过全零替换、随机零替换和随机噪声替换等策略, 对时频图像细节信息进行扰动重构, 从而增强样本的多样性。仿真结果表明, 在小样本条件下, 所提出的时频增强方法能够显著提升跳频信号调制识别性能, 相较于使用原始样本, 整体识别率提升超过 13%, 相较于传统数据增强方法更具有效性。

关键词: 跳频信号; 调制识别; 时频变换; 数据增强; 小样本学习

中图分类号: TN911

文献标志码: A

DOI: 10.19358/j.issn.2097-1788.2026.05.005

中文引用格式: 王思远, 刘高辉. 基于时频增强的小样本跳频信号调制识别[J]. 网络安全与数据治理, 2026, 45(5): 30-39.

英文引用格式: Wang Siyuan, Liu Gaohui. Modulation recognition of small-sample frequency-hopping signals based on time-frequency enhancement[J]. Cyber Security and Data Governance, 2026, 45(5): 30-39.

Modulation recognition of small-sample frequency-hopping signals based on time-frequency enhancement

Wang Siyuan, Liu Gaohui

(School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: To address the performance degradation of frequency-hopping (FH) signal modulation recognition under small-sample conditions, this paper proposes a time-frequency transformation-based data augmentation method for FH signal modulation recognition. Focusing on single-hop time-frequency grayscale images of FH signals, the proposed method employs three categories of time-frequency augmentation strategies, namely discrete wavelet transform (DWT), short-time Fourier transform (STFT), and low-energy region perturbation, to decompose, perturb, and reconstruct the detailed components of time-frequency images. In this manner, structurally diverse augmented samples are generated, enabling effective expansion of the training dataset. Specifically, the DWT-and STFT-based augmentation methods perturb and reconstruct the time-frequency image details through all-zero replacement, random-zero replacement, and random-noise replacement strategies, thereby enhancing sample diversity. Simulation results demonstrate that, under small-sample conditions, the proposed time-frequency augmentation method can significantly improve the modulation recognition performance of FH signals, achieving an overall accuracy improvement of more than 13% compared with using only the original samples, and exhibiting superior effectiveness relative to conventional data augmentation methods.

Key words: frequency-hopping signals; modulation recognition; time-frequency transform; data augmentation; few-shot learning

0 引言

跳频 (Frequency Hopping, FH)^[1] 信号因具备较强的抗干扰能力和低截获概率, 在多领域得到广泛应

用。跳频信号调制识别是通信侦察与频谱管理中的关键技术之一, 其识别结果可为信号监测、通信侦察与干扰决策提供重要依据。

传统的调制识别方法主要包括基于似然比判决方法^[2]和基于特征提取的方法^[3]。但这两种方法在低信

* 基金项目: 国家自然科学基金 (61671375)

噪比或非平稳条件下鲁棒性不足, 识别性能易受影响。

近年来, 深度学习^[4-7]方法通过端到端方式自动学习信号的高层判别特征, 在调制识别领域表现出良好的性能优势。然而, 深度学习模型通常依赖大量样本进行训练, 而在实际应用场景中, 跳频信号往往受到条件限制, 有效样本数量有限, 导致模型在小样本条件下性能显著下降。因此, 小样本条件下跳频信号调制识别问题逐渐成为研究关注的重点。

针对样本不足引起的性能退化问题, 已有研究提出了多种解决思路。一类方法通过数据增强扩展训练样本分布, 例如文献[8]提出了一种基于离散余弦变换的数据增强方法, 用于增强卷积神经网络的训练性能; 文献[9]提出了基于旋转、翻转与加噪的数据增强方法, 该方法有效扩充了训练信号样本, 提升了模型在多种信噪比条件下的分类稳定性和泛化能力。然而, 这类方法难以充分刻画跳频信号复杂的时频结构特征。另一类方法则改变网络结构, 通过生成高质量合成样本扩充数据集。例如文献[10]提出了生成对抗网络模型框架, 通过判别器与生成器的对抗性训练机制, 实现了高质量数据的合成与分布拟合; 文献[11]提出了一种半监督学习框架, 利用未标注信号数据, 通过对比学习机制学习更具判别性的信号表示, 提升了小样本场景下的调制分类性能; 文献[12]使用了元学习实现自动调制分类方法, 学习可快速适应新任务的模型初始化参数, 使模型仅需少量样本即可高效识别新的调制类型, 提升了分类器在无线环境中的适应能力; 文献[13]使用迁移学习实现自动调制识别, 通过在源域数据上预训练模型, 并将学到的通用信号特征迁移至目标域, 从而利用极少量目标域样本实现高效调制分类。但这些方法大多训练过程复杂、稳定性依赖模型设计, 对小样本场景下的工程应用存在一定限制。

跳频信号通过伪随机序列实现载频的快速切换, 其非平稳特性使得单纯依赖时域或频域特征的识别方法难以取得理想效果。文献[14]将跳频信号转换为时频表示, 并利用时频能量分布进行分析, 是实现跳频信号调制识别的可行途径。但是现有方法缺乏对跨时频结构耦合特征的统一建模能力, 特别是在频率跳变带来的局部纹理断裂场景下, 容易造成特征提取不充分。针对上述问题, 本文提出一种基于时频变换增强的跳频信号调制识别方法。该方法以跳频信号的时频灰度图为研究对象, 分别从频域分解扰动与图像能量结构扰动两个层面进行样本增强: 一方面, 通过离散

小波变换 (Discrete Wavelet Transform, DWT) 和短时傅里叶变换 (Short-time Fourier Transform, STFT) 对时频图像进行多尺度分解, 并对高频或细节成分实施扰动替换以生成增强样本; 另一方面, 针对时频图中能量分布稀疏的特点, 设计了一种基于低能量区域扰动的图像级增强方法 (Energy-Masked Image Perturbation, EMIP), 在不依赖可逆变换的情况下扩展样本分布。通过多种增强策略的组合与对比, 实现训练样本的有效扩展, 从而提升模型在小样本条件下的调制识别性能。

本文的主要贡献可概括为以下三个方面:

(1) 构建了一种面向跳频信号调制识别的时频变换增强框架, 将 DWT、STFT 及图像级能量扰动统一用于时频图像增强, 验证了多种时频增强策略在小样本场景下的有效性;

(2) 针对时频图像中主体能量结构与细节信息的不同作用, 在 DWT 和 STFT 增强方法中设计了全零替换 (All-Zero Replacement, AZR)、随机零替换 (Random-Zero Replacement, RZR) 和随机噪声替换 (Random-Noise Replacement, RNR) 三种增强策略, 并系统分析了不同扰动方式对调制识别性能的影响;

(3) 通过多组仿真实验与对比分析, 验证了本文所提出增强策略在小样本跳频信号调制识别任务中的性能优势。

1 跳频信号模型

在跳频通信中, 信号通过伪随机序列控制的载频快速切换实现抗干扰与低截获。本文的跳频信号为慢跳频模式, 即跳频周期大于符号周期, 单跳内调制方式保持恒定。

假设接收机在观测时间内共接收 L 个跳频信号, 如式 (1) 所示:

$$g(t) = \sum_{l=1}^L s_l(t) + n(t) \quad (1)$$

其中 $g(t)$ 表示接收的跳频和噪声混合信号; $n(t)$ 表示高斯白噪声信号, 均值为 0, 方差为 σ^2 ; $s_l(t)$ 表示接收到的第 l 个跳频信号。假设跳频信号的跳频周期为 T_h , 那么跳频信号可以表示为:

$$s_l(t) = \sum_{n=1}^L A e^{j(2\pi f_{ln}t' + \varphi_{ln})} \cdot \text{rect}\left(\frac{t - nT_h}{T_h}\right) \quad (2)$$

其中, A 为信号幅度, f_{ln} 和 φ_{ln} 分别表示第 l 个跳频信号第 n 跳的载频频率和初始相位, $\text{rect}(\cdot)$ 表示单位矩形脉冲函数。

2 数据预处理

针对跳频信号非平稳特性明显、单跳结构随时间

变化较快的问题, 本文首先对接收信号进行时频分析, 并通过去噪与同步处理, 提取对齐的单跳时频图像, 为后续时频增强与调制识别提供标准化输入。整体预处理流程包括连续小波变换获取时频能量图、自适应维纳滤波去噪以及跳频参数辅助的同步与单跳分割, 如图 1 所示。



图 1 数据预处理流程

2.1 连续小波变换获取时频图

连续小波变换 (Continuous Wavelet Transform, CWT)^[15] 具有良好的多分辨率分析能力, 能够同时表征信号在时域和频域上的局部特征, 适用于跳频信号等典型非平稳信号的时频表示。本文采用 CWT 对接收的跳频信号进行处理, 生成对应的时频能量分布图。

在多种常用小波基函数中, 不同小波基在时频聚集性、对称性及频率分辨能力等方面存在差异。为兼顾时频分辨率与能量聚集特性, 本文选用 Morlet 小波作为 CWT 的小波基函数, 其复指数调制高斯窗结构能够有效刻画跳频信号频率随时间突变的特征。需要说明的是, 后续实验中将进一步比较不同小波基对增强与识别性能的影响, 此处仅给出 Morlet 小波的统一时频构建方式, 其余小波基在实现流程上保持一致。Morlet 小波表达式如下:

$$\psi_{\text{Mor}}(t) = \pi^{-1/4} e^{j\omega_0 t} e^{-t^2/2} \quad (3)$$

其中 ω_0 代表小波中心频率参数, 为平衡分辨率, 本文取 $\omega_0 = 6$ 。

使用 Morlet 小波基函数对跳频信号进行 CWT 变换:

$$\text{CWT}(a, b) = \frac{\pi^{-1/4}}{\sqrt{a}} \int g(t) \cdot e^{-j\omega_0 \frac{(t-b)}{a}} \cdot e^{-\frac{(t-b)^2}{2a^2}} dt \quad (4)$$

其中 a 是尺度参数 (与频率成反比, 且 $a > 0$), b 是平移参数 (对应时间位置)。

那么时频矩阵的能量值可表示为:

$$F(x, y) = \frac{1}{\sqrt{\pi}} \left| \int_{t_0^* + iT_h}^{t_0^* + (i+1)T_h} g(t) \cdot e^{-j\omega_0 \frac{(t-b)}{a}} \cdot e^{-\frac{(t-b)^2}{2a^2}} dt \right|^2 \quad (5)$$

2.2 维纳滤波去噪算法

噪声会破坏时频能量分布, 因此需进一步进行去噪, 本文采用维纳滤波^[16] 进行去噪处理。 $F(x, y)$ 表

示时频矩阵 F 第 x 行 y 列的能量值, 时频矩阵 F 大小为 $M \times N$, 定义域为 D_F , 则 $(x, y) \in D_F$, $0 \leq x < M$, $0 \leq y < N$ 。取时频点大小为 $m \times n$ 的 $F(x, y)$ 邻域 ϑ , ϑ 的期望 μ 和方差 v^2 如下所示:

$$\mu = \frac{1}{mn} \sum_{x, y \in \vartheta} F(x, y) \quad (6)$$

$$v^2 = \frac{1}{mn} \sum_{x, y \in \vartheta} F^2(x, y) - \mu^2 \quad (7)$$

在滤波时, 由于实际跳频信号的噪声方差很难准确估计, 需要计算时频矩阵 F 的全局均值 μ_w 和全局方差 v^2 , 用于量化时频图中噪声的功率:

$$\mu_w = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(x, y) \quad (8)$$

$$v^2 = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [F(x, y) - \mu_w]^2 \quad (9)$$

经过维纳滤波后可得到去噪时频图像 $F'(x, y)$:

$$F'(x, y) = \mu + \frac{v^2 - v'^2}{v^2} [F(x, y) - \mu] \quad (10)$$

2.3 跳频同步检测与灰度化

在跳频信号调制识别任务中, 尽管跳频周期、频点集合等参数在部分应用场景中可获得, 但信号起始时间通常未知, 仍需进行同步处理以保证单跳结构的完整性。本文采用基于时频能量分布的自同步方法, 实现跳频信号的时间对齐与单跳分割。

通过寻找每一时刻 d 点的能量最大点所在的尺度 $e_{\max}(d)$ 获取主频轨迹 f_d :

$$f_d = \frac{f_c}{e_{\max}(d)} \quad (11)$$

其中 f_c 表示小波函数的中心频率。

计算轨迹的一阶差分序列:

$$\Delta f_d = |f_d - f_{d-1}| \quad (12)$$

其中 Δf_d 表示时刻时间点的频率突变幅度。根据设置跳变阈值 θ_f 提取跳频点集合:

$$T = \{b \mid \Delta f_b > \theta_f\} \quad (13)$$

已知跳频周期为 T_h , 设跳频点时间序列为 $\{t_k\}_{k=1}^N$, 构造代价函数:

$$C(t_0) = \sum_{k=0}^K (t_k - (t_0 + kT_h))^2 \quad (14)$$

其中 t_0 表示拟合起点候选值, K 是拟合使用的跳频点数量。在一段候选区域内滑动 t_0 , 寻求最优起点:

$$t_0^* = \arg \min_{t_0} C(t_0) \quad (15)$$

得到同步起点 t_0^* 后, 为保证单跳时频结构的完整性与对齐性, 设第 i 跳对应的时间域信号片段为 $S_i(t)$:

$S_i(t) = \{g(t) \mid t \in [t_0^* + iT_h, t_0^* + (i+1)T_h]\}$ (16)
其中 $i=0,1,\dots,K-1$ 。在此基础上,从去噪时频能量图 $F'(x,y)$ 中按照时间索引截取对应的时频区域,得到时频能量谱 $F''(x,y)$ 。该过程实现了单跳信号在时频域中的精确定位与分离。

为便于后续图像增强处理与深度网络输入,将单跳时频能量谱进一步映射为时频灰度图。具体而言,通过式 (17) 对 $F''(x,y)$ 进行归一化与量化处理:

$$Q(x,y) = \text{round} \left\lfloor \frac{J F''(x,y)}{\max F''(x,y)} \right\rfloor \quad (17)$$

其中, $F''(x,y)$ 表示单跳时频能量谱中第 x 行第 y 列的能量值, $\text{round} \lfloor \cdot \rfloor$ 表示向下取整运算, $Q(x,y)$

为对应位置的灰度值, J 为灰度级数。本文取 $J=255$, 即 $Q(x,y) \in [0, 255]$ 。

3 时频变换增强图像算法

本文提出的时频变换的数据增强方法整体框架如图 2 所示。首先利用时频变换对时频灰度图进行分解,得到不同分辨率下的主体系数和细节系数;使用相应的替换方法来替换细节系数,并使用替换的细节系数和原始的主体系数来重建一张新的时频图。通过不同的替换方法不断替换细节系数,本文可以获得大量新的重构时频图。将重构时频图与原始时频图合并,得到增广数据集。最后,将该增广数据集作为网络输入,从而提高识别率。




图 2 时频变换增强图像框架

3.1 离散小波分解增强算法

对已经得到的二维单跳时频图 $Q(x,y)$, 选取合适的标度函数 $\varphi(x)$, 结合确定的小波基函数 $\psi(x)$, 则 $Q(x,y)$ 的二维小波分解过程可表示为:

$$\begin{cases} CA(m,n) = \sum_x \sum_y Q(x,y) \varphi(x-m) \varphi(y-n) \\ CD_H(m,n) = \sum_x \sum_y Q(x,y) \psi(x-m) \varphi(y-n) \\ CD_V(m,n) = \sum_x \sum_y Q(x,y) \varphi(x-m) \psi(y-n) \\ CD_D(m,n) = \sum_x \sum_y Q(x,y) \psi(x-m) \psi(y-n) \end{cases} \quad (18)$$

式 (18) 将 $Q(x,y)$ 分解为近似系数和细节系数。低频近似系数 (CA) 包含低频成分, 反映信号的整体趋势。细节系数分为水平细节 (CD_H)、垂直细节 (CD_V) 和对角细节 (CD_D), 它们分别表示高频水平边缘信息、高频垂直边缘信息和高频对角边缘信息。

接着对低频近似系数 CA 进一步施加一维离散小波变换, 进行多层分解, 过程如下所示:

$$\begin{cases} CA_i(n) = \sum_{f=0}^{F-1} CA_{i-1}(2n-f) \cdot g[f] \\ CD_i(n) = \sum_{f=0}^{F-1} CA_{i-1}(2n-f) \cdot h[f] \end{cases} \quad (19)$$

其中 CA_i 和 CD_i 分别为 i 阶 DWT1 分解的近似系数和细

节系数, $g[f]$ 和 $h[f]$ 分别为低通滤波器和高通滤波器, n 表示位置索引, f 为滤波器的长度。定义 E 为总共执行分解的次数, 包括二维和一维离散小波分解, 共可得 $C = \{CH, CV, CD, CD_1, \dots, CD_{E-1}, CA_{E-1}\}$ 系数集。后续用 DWT 分解来表示上述过程。

通过对细节系数进行分析和处理, 可以实现去噪、压缩、特征提取等一系列应用。基于小波变换的详细系数集 C , 本文提出了三种数据增强方法, 通过替换细节系数来获得增强样本, 以提高神经网络的识别精度。本文采用顺序替换的方法来替换细节系数集中的每个细节系数, 随后利用替换系数进行重建并生成 $(E+2)$ 新样本, 该过程视为增强操作。增广运算的次数记为 A 。

设输入时频灰度图像为 $Q(x,y)$, 其在第 i 次增强中经二维 DWT 得到的小波系数表示为:

$$W_i = \{A_i, D_{i,1}, D_{i,2}, D_{i,3}\} \quad (20)$$

其中 A_i 表示近似系数, $D_{i,1}, D_{i,2}, D_{i,3}$ 分别表示同一分解层下的三个细节子带系数。小波增强方法通过对选定细节系数进行替换或扰动, 并保持其余系数不变, 以生成新的增强样本。增强后的图像通过二维离散小波逆变换 (IDWT) 重构得到:

$$\hat{Q}_i(x,y) = W^{-1}(W_i^{AZR}) \quad (21)$$

其中 W^{-1} 表示二维 IDWT 算子。

3.1.1 全零替换

全零替换策略通过将选定层的二维 DWT 细节系数置零, 以抑制时频图中的高频扰动成分。设第 i 次增强中被替换的细节系数矩阵为 D_i , 则其定义为:

$$\hat{D}_i^{\text{AZR}}(x, y) = 0, \forall (x, y) \quad (22)$$

增强后的系数集合表示为:

$$W_i^{\text{AZR}} = \{A_i, D_{i,1}, D_{i,2}, \hat{D}_i^{\text{AZR}}\} \quad (23)$$

其中未被选中的细节系数保持不变。通过二维 IDWT 重构增强图像:

$$\hat{Q}_i^{\text{AZR}}(x, y) = W^{-1}(W_i^{\text{AZR}}) \quad (24)$$

3.1.2 随机零替换

随机零替换策略通过引入随机置零掩码, 对选定的细节子带系数施加随机稀疏扰动, 以增强样本多样性。设掩码矩阵 $M(x, y)$ 为一组与目标细节系数同尺寸的独立同分布伯努利随机变量, 其定义为:

$$M(x, y) \sim \text{Bernoulli}(1-p), \forall (x, y) \quad (25)$$

其中 $p \in [0, 1]$ 表示置零概率。

在第 i 次增强中, 目标细节系数的替换形式定义为:

$$\hat{D}_i^{\text{RZR}}(x, y) = M(x, y) \cdot D_i(x, y) \quad (26)$$

由此构造增强后的二维小波系数集合:

$$\hat{W}_i^{\text{RZR}} = \{A_i, D_{i,1}, D_{i,2}, \hat{D}_i^{\text{RZR}}\} \quad (27)$$

其中未被选中的系数保持不变。对该系数集合执行二维 IDWT, 得到增强后的时频灰度图:

$$\hat{Q}_i^{\text{RZR}}(x, y) = W^{-1}(\hat{W}_i^{\text{RZR}}) \quad (28)$$

3.1.3 随机噪声替换

随机噪声替换策略通过将目标细节系数替换为功率匹配的随机高斯噪声, 以模拟细节扰动并增强样本的鲁棒性。首先计算原始细节系数的平均功率:

$$\beta = \frac{1}{HW} \sum_{x=1}^H \sum_{y=1}^W D_i^2(x, y) \quad (29)$$

其中 H 和 W 分别表示细节系数矩阵的高度和宽度。随后生成与 $D_i(x, y)$ 尺寸一致、均值为 0、方差为 β 的白噪声矩阵, 并用于替换目标细节系数:

$$\hat{D}_i^{\text{RNR}}(x, y) = \sqrt{\beta} \cdot \mathcal{N}(0, 1) \quad (30)$$

增强后的系数集合表示为:

$$\hat{W}_i^{\text{RNR}} = \{A_i, D_{i,1}, D_{i,2}, \hat{D}_i^{\text{RNR}}\} \quad (31)$$

通过二维 IDWT 重构增强图像:

$$\hat{Q}_i^{\text{RNR}}(x, y) = W^{-1}(\hat{W}_i^{\text{RNR}}) \quad (32)$$

3.2 短时傅里叶增强算法

该方法通过对时频图像的行信号进行 STFT 分解,

并在保持相位信息不变的前提下对频谱高频幅值施加扰动, 从而生成多样化的增强样本。

设输入的时频灰度图像为 $Q(x, y)$, 其中 x 表示时间索引, y 表示频率索引。本文将图像的每一行视为一维离散时间信号, 并对其独立进行 STFT 处理。设第 r 行对应的一维信号表示为:

$$x_r[n], n=0, 1, \dots, N-1 \quad (33)$$

对信号 $x_r[n]$ 进行 STFT, 其表达式为:

$$Z_r(k, m) = \sum_{n=0}^{L-1} x_r[n+mH]w[n]e^{-j2\pi kn/L} \quad (34)$$

其中 k 为频率索引, m 为时间帧索引, $w[n]$ 表示窗函数, L 为窗长, H 为帧移。STFT 系数 $Z_r(k, m)$ 为复数形式, 可表示为:

$$Z_r(k, m) = |Z_r(k, m)|e^{j\varphi_r(k, m)} \quad (35)$$

其中 $|Z_r(k, m)|$ 和 $\varphi_r(k, m)$ 分别表示幅值与相位。

设 STFT 频率索引集合为 $\mathcal{K} = \{0, 1, \dots, K-1\}$, 根据频率阈值定义高频区域为:

$$\mathcal{H} = \{k \in \mathcal{K} | k \geq k_0\} \quad (36)$$

其中 k_0 可根据频谱能量分布或经验比例确定。后续增强操作仅作用于高频区域 $\mathcal{H}$, 其余频率分量保持不变。

保持相位 $\varphi_r(k, m)$ 不变, 本文设计三种幅值扰动策略, 对高频区域的 STFT 幅值进行修改。

3.2.1 全零替换

全零替换策略将高频区域的幅值完全置零, 其定义为:

$$\hat{Z}_r^{\text{AZR}}(k, m) = \begin{cases} |Z_r(k, m)|e^{j\varphi_r(k, m)}, & k \notin \mathcal{H} \\ 0, & k \in \mathcal{H} \end{cases} \quad (37)$$

3.2.2 随机零替换

随机零替换策略通过引入随机掩码, 对高频幅值进行随机稀疏扰动。设掩码变量为独立同分布的伯努利随机变量:

$$\delta_r(k, m) \sim \text{Bernoulli}(1-p) \quad (38)$$

其中 p 表示置零概率。

高频幅值的替换方式定义为:

$$\hat{Z}_r^{\text{RZR}}(k, m) = \begin{cases} |Z_r(k, m)|e^{j\varphi_r(k, m)}, & k \notin \mathcal{H} \\ \delta_r(k, m)|Z_r(k, m)|e^{j\varphi_r(k, m)}, & k \in \mathcal{H} \end{cases} \quad (39)$$

3.2.3 随机噪声替换

随机噪声替换策略将高频幅值替换为功率匹配的随机高斯噪声。首先对高频区域 STFT 幅值进行能量统计, 计算其均方幅值:

$$\sigma^2 = \frac{1}{|\mathcal{H}|M} \sum_{k \in \mathcal{H}} \sum_m |Z_r(k, m)|^2 \quad (40)$$

其中 M 表示时间帧数。随后生成与高频幅值尺寸一致的白噪声：

$$\eta_r(k, m) \sim \mathcal{N}(0, \sigma^2) \quad (41)$$

并构造替换后的 STFT 系数：

$$\hat{Z}_r^{\text{RNR}}(k, m) = \begin{cases} |Z_r(k, m)| e^{j\varphi_r(k, m)}, & k \notin \mathcal{H} \\ \eta_r(k, m) e^{j\varphi_r(k, m)}, & k \in \mathcal{H} \end{cases} \quad (42)$$

在完成幅值扰动后，对修改后的 STFT 系数执行逆短时傅里叶变换 (ISTFT)：

$$\hat{x}_r[n] = S^{-1}(\hat{Z}_r(k, m)) \quad (43)$$

其中 S^{-1} 表示与式 (34) 中 STFT 参数一致的 ISTFT 算子。对所有行信号重复上述过程，并将重构结果按行拼接，最终获得增强后的时频图像。

3.3 低能量区域扰动的图像增强方法

考虑到跳频信号时频图通常呈现出显著的能量集中结构，为避免对判别性主干特征造成破坏，本文提出一种基于低能量区域掩码的图像扰动增强方法。该方法通过仅对时频图中的低能量区域注入受控随机扰动，在保持主体能量分布结构稳定的同时提升样本多样性，从而增强模型的泛化能力。该策略适用于任意形式的时频图像。

设输入灰度时频图像为 $Q(x, y) \in [0, 255]$ ，首先进行归一化处理：

$$q(i, j) = \frac{Q(i, j)}{255} \quad (44)$$

为刻画图像中的低能量区域，设定能量阈值 $\tau \in (0, 1)$ ，并定义能量掩码矩阵：

$$M(i, j) = \begin{cases} 1, & q(i, j) < \tau \\ 0, & \text{其他} \end{cases} \quad (45)$$

其中 $M(i, j)$ 表示对应像素属于低能量区域。阈值 τ 用于区分时频图中的主体能量结构与背景区域。它的取值基于经验统计与预实验结果确定，用以保证扰动主要施加于低能量区域，在不破坏主体时频结构的前提下引入有效随机扰动。

为保证扰动幅度与原始图像整体能量水平相匹配，首先计算归一化图像的全局标准差：

$$\sigma_q = \sqrt{\frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W (q(i, j) - \mu_q)^2} \quad (46)$$

其中 μ_q 为 $q(i, j)$ 的全局均值。扰动强度 σ 设定为：

$$\sigma = s \cdot \sigma_q \quad (47)$$

其中 s 为经验扰动系数，用于控制低能量区域中噪声注入的幅度，其取值直接影响增强样本的结构保持性

与多样性。为避免扰动过弱或过强带来的性能退化，综合实验表现，本文选取 $s=0.3$ 作为扰动系数，该取值在不同信噪比条件下均表现出较好的稳定性。

随后，仅在低能量区域内注入零均值高斯噪声：

$$\hat{q}(i, j) = q(i, j) + M(i, j)\epsilon(i, j), \quad \epsilon(i, j) \sim \mathcal{N}(0, \sigma^2) \quad (48)$$

此外，为进一步提升模型对不同扰动强度的鲁棒性，本文采用递归增强策略，将上一级增强结果作为输入，重复执行上述扰动过程，从而构建多级 EMIP 增强样本集。

为直观展示不同时频增强策略对信号结构的影响，图 3 给出了 QPSK 跳频信号在不同替换方法下的时频灰度图对比结果。

从图 3 可以看出，在保持主体跳频结构不变的前提下，相比于原始灰度图，不同增强策略的细节区域的能量分布与纹理结构发生了可控扰动，从而引入了更丰富的局部差异性，有助于提升模型对同类信号内部变化的鲁棒性。

4 实验仿真与分析

4.1 实验设置

本文实验的电脑配置如下：AMD Ryzen 7 7840H CPU @ 3.80 GHz，16 GB 内存，Windows 64 bit 系统，GPU 为 RTX 4060。使用 PyTorch 框架识别，并使用 GPU 加速。使用 ResNet18 网络进行训练识别，并将准确率作为评价指标。

实验中跳频信号每个跳周期 1 000 个采样点，采样率为 1 MHz，频率集为 $\{5, 10, 15, 20, 25, 30, 35, 40, 45\}$ kHz，跳频间隔为 6 kHz，跳频频率伪随机跳变，调制方式分别为 BPSK、QPSK、2FSK、16QAM、32QAM、2ASK、4ASK、GMSK 共八种，跳频序列采用伪随机 m 序列，噪声为加性高斯白噪声且均值为零，在信噪比 -10 dB ~ 20 dB 范围内，每间隔 2 dB 对每种调制方式的跳频信号各采集 50 个样本，通过预处理算法将其转化为单跳时频灰度图，共采集单跳时频灰度图 6 400 幅用于后续分析。通过预处理算法将其转化为 256×64 大小的时频灰度图，其中，时间维 (256) 用于完整表征单跳信号在一个跳频周期内的时域演化过程，能够较好地保留跳频瞬态结构；频率维 (64) 在保证主要频谱分布清晰可辨的前提下，有效降低了冗余频率分量带来的计算负担。该尺寸设置在多组预实验中表现出较好的稳定性与识别性能，同时与后续卷积神经网络的输入规模相匹配，避免了额外的插值失真与信息损失。




图 3 不同方法替换的 QPSK 信号灰度图

4. 2 增强算法性能分析

4. 2. 1 DWT 增强分析

为评估所提出 DWT 增强策略在小样本条件下对跳频信号调制识别性能的影响，本文引入增强层数 E 表示时频增强的递归执行次数。当不采用任何增强策略 ($E=0$) 时，模型在原始数据上的识别准确率仅为 47.33%，表明在小样本条件下直接训练存在明显性能瓶颈。

在相同网络结构和训练参数下，本文分别采用 DWT 全零替换 (D-AZR)、DWT 随机零替换 (D-RZR) 和 DWT 随机噪声替换 (D-RNR) 三种 DWT 增强策略进行对比实验。实验中选用 haar 小波作为基函数，其中第一级仅进行二维离散小波分解与重构，后续各级在前一级增强结果的基础上进一步引入一维分解，并最终重构生成增广样本。实验结果如表 1 所示。

从表 1 可以观察到，当增强层数较少 ($E \leq 3$) 时，三种增强策略均能随着增强次数的增加持续提升识别准确率；而当增强层数进一步增大时，识别率出现一定程度的回落，但整体性能仍显著优于仅使用原

表 1 DWT 策略增强分析 (%)

E	D-AZR	D-RZR	D-RNR
0		47.33	
1	50.54	51.88	50.33
2	53.09	54.17	53.71
3	54.03	55.72	57.88
4	51.95	57.43	59.74
5	50.45	56.77	58.71

始样本的基线结果。这一现象表明，适度的多级时频增强有助于缓解样本不足问题，但过度扰动可能引入冗余或破坏性特征，从而影响模型判别能力。

在三种增强策略中，随机噪声替换 (RNR) 表现出最显著的性能提升。当 $E=4$ 时，其识别准确率达到 59.74%，较原始样本提高约 12.41%。该结果说明，在保持整体能量分布一致性的前提下，引入随机噪声扰动能够有效丰富样本的局部特征分布，从而提升模型对复杂调制模式的鲁棒性。

进一步考虑不同小波基在多尺度特征提取方面的差异性，本文采用 db5、coif3、sym4 和 rbio1.1 多种小

波基函数对时频图像进行 RNR 增强实验，结果如表 2 所示。

表 2 不同小波基的识别准确率 (%)

<i>E</i>	sym4	db5	coif3	rbio1.1
1	50.74	48.21	50.65	51.84
2	52.36	51.12	53.52	55.23
3	53.21	55.63	56.66	57.39
4	57.23	59.32	59.74	57.67

可以看出，当增强层数为 4 时，采用 db5 和 coif3 小波基的识别性能整体优于其他小波基。这表明在本文实验设置下，coif3 与 db5 小波基更有利于提升跳频信号调制识别性能。

4.2.2 STFT 与 EMIP 增强分析

在本节实验中，进一步对比分析基于 STFT 的时频增强方法与基于 EMIP 的增强方法在跳频信号调制识别任务中的性能差异。其中，STFT 增强方法通过对时频图像逐行进行短时傅里叶分解，并采用不同频谱替换策略生成增强样本；EMIP 方法则以原始时频图像作为输入，逐级生成 EMIP1 至 EMIP5 五级增强样本，并与原始样本联合构建训练集。与依赖频域分解与逆变换的 STFT 增强不同，EMIP 直接在图像空间对低能量区域施加扰动，因此灵活性更高。

在相同网络结构与训练参数条件下，将 EMIP 方法与 STFT 增强策略进行对比，其中 STFT 增强分别采用全零替换 (S-AZR)、随机零替换 (S-RZR) 和随机噪声替换 (S-RNR) 三种策略。不同增强方法在各增强层数下的识别准确率如表 3 所示。

表 3 STFT 与 EMIP 增强对比 (%)

<i>E</i>	S-AZR	S-RZR	S-RNR	EMIP
1	50.27	52.64	51.41	51.82
2	54.32	54.76	55.22	54.39
3	56.63	55.36	57.66	56.42
4	57.35	57.45	58.74	57.14
5	53.71	58.27	57.23	55.19

从表 3 可以看出，在 STFT 增强策略中，随机噪声替换 (S-RNR) 在多数增强层数下取得了最高的识别准确率，整体性能优于 S-AZR 和 S-RZR。这一结果表明，在保持相位信息不变的前提下，引入功率受控的随机噪声扰动能够更有效地丰富时频特征分布，从而提升模型的判别能力。

相比之下，EMIP 方法的整体识别性能略低于基于 STFT 的 S-RNR 策略，其原因在于 EMIP 扰动仅施加于图像级低能量区域，在增强样本多样性的同时对主干能量结构的调控能力相对有限。尽管如此，该方法在无需频域变换的条件下仍能取得稳定的性能提升，验证了其在跳频信号调制识别任务中的有效性与适用性。

4.2.3 增强图像混合对比

为进一步探究不同时频增强方法之间的互补性，将基于 DWT 的随机噪声替换 (D-RNR)、基于 STFT 的随机噪声替换 (S-RNR) 以及 EMIP 方法生成的增强样本进行混合，构建随机噪声替换混合增强数据集 (RNR-M)。在对比实验中，每次从混合数据集中随机选取与单一方法等量的样本进行训练，以排除样本数量差异对识别性能的影响。实验结果如表 4 所示。

表 4 混合增强对比 (%)

<i>E</i>	D-RNR	S-RNR	EMIP	RNR-M
1	50.33	51.41	51.82	58.87
2	53.71	55.22	54.39	59.24
3	57.88	57.66	56.42	60.74
4	59.74	58.74	57.14	61.14
5	58.71	57.23	55.19	59.32

从表 4 可以看出，混合增强策略在所有增强层数下均取得了最高的识别准确率。当增强层数 $E=4$ 时，RNR-M 方法的识别准确率达到 61.14%，较原始数据提升约 13.81%。这一结果表明，不同时频增强方法在特征层面具有互补性，通过融合多种增强策略生成的样本，可以显著提升模型对多种调制模式的判别能力和泛化性能。

4.3 对比实验结果及分析

在现有的调制识别数据增强方法中，方法 1 采用旋转增强，将调制信号在星座图中旋转特定角度，以增加样本数^[9]；方法 2 采用自监督增强一致性 (SAC) 方法应用动量网络结合光照扰动，通过跨增强视图的预测一致性生成增广样本^[17]；方法 3 通过掩码信号重构，将信号片段替换为高斯噪声从而扩充数据集^[18]。以上方法在样本数相同情况下与本文混合增强方法进行对比试验，各模型分类器在信噪比不同情况下的识别率如图 4 所示。

如图 4 所示，在 -10 dB ~ 20 dB 的信噪比范围内，本文方法在各条件下均取得最优识别性能。尤其在低信噪比区间优势显著：在 -4 dB 时，本文方法识别




图4 与现有方法的识别率对比曲线

率为 40.68%，高于其他方法的 31.25% ~ 35.62%；在 0 dB 条件下提升至 68.02%，相比其他方法提高 17.66% ~ 21.13%；当信噪比为 4 dB 时，识别率达到 87.57%，明显优于其他方法。高信噪比条件下，本文方法识别率更高，在 20 dB 时实现 100% 识别率，表明其在不同噪声环境下具有稳定的鲁棒性。

4.4 计算复杂度与训练效率分析

本文方法在网络结构层面未引入额外参数，训练与推理阶段均采用相同的 ResNet18 网络，因此与对比方法相比，其模型参数规模保持一致。从理论复杂度角度看，各方法在训练阶段的时间复杂度均可表示为 $O(L)$ ，其中 L 表示参与训练的样本数量。不同方法之间的主要差异体现在数据增强阶段生成的有效训练样本规模。

所提出的 RNR-M 方法通过融合 DWT、STFT 及 EMIP 等多种增强策略生成多样化训练样本，在相同训练轮数下需要处理更多的输入样本，从而导致单轮训练时间略有增加。为定量评估不同增强方法对训练效率的影响，本文在相同硬件环境与训练配置下，对各方法的单轮训练时间进行了统计，对比结果如表 5 所示。

表5 不同方法的识别性能与训练时间对比

指标	RNR - M	方法 1	方法 2	方法 3
准确率/%	61.14	53.26	54.83	58.39
单轮训练时间/s	15.2	13.6	15.8	17.3
最高准确率/%	100	83.12	89.03	94.25
时间复杂度	$O(L)$	$O(L)$	$O(L)$	$O(L)$

从表 5 可以看出，RNR-M 方法在单轮训练时间仅

有小幅增加的情况下，实现了显著的识别性能提升。该结果表明，所提出的增强策略在不显著增加计算开销的前提下，有效改善了模型的性能 - 效率权衡，验证了其在小样本跳频信号调制识别任务中的实用性与工程可行性。

5 结论

本文针对小样本条件下跳频信号调制识别性能受限的问题，提出了一种基于时频增强的跳频信号调制识别方法。该方法通过对跳频信号时频图像进行多尺度结构扰动与样本扩展，在不引入额外模型参数的前提下有效提升了模型在小样本场景下的泛化能力。实验结果表明，所提出方法在整个信噪比范围内均优于对比方法，在 0 dB 和 4 dB 条件下识别率分别达到 68.02% 和 87.57%，并在 20 dB 时实现 100% 的识别准确率，验证了其在提升跳频信号调制识别鲁棒性和判别能力方面的有效性。需要指出的是，本文方法在一定程度上依赖于时频图生成及单跳对齐过程，其性能可能受跳频参数估计误差的影响。未来研究可通过引入更稳健的跳频参数估计机制，或将该时频增强框架与元学习、对比学习等小样本学习方法相结合，进一步提升方法在复杂实际环境中的适用性。

参考文献

[1] KHAN M T. A modified convolutional neural network with rectangular filters for frequency-hopping spread spectrum signals[J]. Applied Soft Computing, 2024, 150: 111036.

[2] ABU-ROMOH M, ABOUTALEB A, REZKI Z. Automatic modulation classification using moments and likelihood maximization[J]. IEEE Communications Letters, 2018, 22 (5): 938 - 941.

[3] ZHANG X L, SUN J T, ZHANG X T. Automatic modulation classification based on novel feature extraction algorithms[J]. IEEE Access, 2020, 8: 16362 - 16371.

[4] XIE W W, HU S, YU C, et al. Deep learning in digital modulation recognition using high order cumulants[J]. IEEE Access, 2019, 7: 63760 - 63766.

[5] ZHANG F X, LUO C B, XU J L, et al. Deep learning based automatic modulation recognition: models, datasets, and challenges[J]. Digital Signal Processing, 2022, 129: 103650.

[6] MOHSEN S, ALI A M, EMAM A. Automatic modulation recognition using CNN deep learning models[J]. Multimedia Tools and Applications, 2024, 83 (3): 7035 - 7056.

[7] ZHANG F X, LUO C B, XU J L, et al. An efficient deep learning model for automatic modulation recognition based on parameter estimation and transformation[J]. IEEE Communications Letters, 2021, 25 (10): 3287 - 3290.

- [8] ITO I. Flipping data augmentation of convolutional neural networks using discrete cosine transforms[C]//Proceedings of 2021 29th European Signal Processing Conference (EUSIPCO). Dublin: IEEE, 2021: 1501–1505.
- [9] HUANG L, PAN W J, ZHANG Y, et al. Data augmentation for deep learning-based radio modulation classification[J]. IEEE Access, 2020, 8: 1498–1506.
- [10] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63 (11): 139–144.
- [11] KONG W S, JIAO X, XU Y H, et al. A transformer-based contrastive semi-supervised learning framework for automatic modulation recognition[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9 (4): 950–962.
- [12] HAO X Y, FENG Z X, YANG S Y, et al. Automatic modulation classification via meta-learning[J]. IEEE Internet of Things Journal, 2023, 10 (14): 12276–12292.
- [13] LIN W S, HOU D B, HUANG J S, et al. Transfer learning for automatic modulation recognition using a few modulated signal samples[J]. IEEE Transactions on Vehicular Technology, 2023, 72 (9): 12391–12395.
- [14] 李红光, 郭英, 睦萍, 等. 基于时频能量谱纹理特征的跳频调制方式识别[J]. 通信学报, 2019, 40 (10): 20–29.
- [15] CHEN T, ZHENG S L, QIU K F, et al. Augmenting radio signals with wavelet transform for deep learning-based modulation recognition[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10 (6): 2029–2044.
- [16] CRUZ D P, STRONG G, BATES O, et al. Convolve and conquer; data comparison with Wiener filters[J/OL]. [2024–01–10]. <http://doi.org/10.48550/arXiv.2311.06558>.
- [17] CHEN X K, YUAN Y H, ZENG G, et al. Semi-supervised semantic segmentation with cross pseudo supervision[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2021: 2613–2622.
- [18] XU Y C, HUANG L, ZHANG L H, et al. Diffusion-based radio signal augmentation for automatic modulation classification[J]. Electronics, 2024, 13 (11): 2063.

(收稿日期: 2026–01–18)

作者简介:

王思远(2000–), 男, 硕士研究生, 主要研究方向: 调制识别。

刘高辉(1968–), 通信作者, 男, 博士, 教授, 主要研究方向: 通信信号处理、认知无线电、雷达信号处理和导航技术。

E-mail: liugh68@xaut.edu.cn。

版权声明

凡《网络安全与数据治理》录用的文章，如作者没有关于汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权等版权的特殊声明，即视作该文章署名作者同意将该文章的汇编权、翻译权、印刷权及电子版的复制权、信息网络传播权与发行权授予本刊，本刊有权授权本刊合作数据库、合作媒体等合作伙伴使用。同时，本刊支付的稿酬已包含上述使用的费用，特此声明。

《网络安全与数据治理》编辑部

www.pcachina.com