

## 基于 Stokes 空间和 Stacking 模型的调制格式识别

刘昱, 刘战胜\*

(江苏大学 计算机科学与通信工程学院, 江苏 镇江 212000)

**摘要:** 为提高弹性光网络(EON)中调制格式识别(MFI)的准确性与鲁棒性, 提出一种基于 Stokes 空间和 Stacking 模型的 MFI 方法。该方法通过核密度估计提取 Stokes 空间三轴的一维概率分布特征, 构建 240 维特征向量; 采用遗传算法优化 Stacking 模型的基模型与元模型组合, 并利用贝叶斯优化调参, 提升模型在低信噪比下的分类性能。仿真结果表明: 在 5~30 dB 光信噪比(OSNR)范围内, 模型宏平均受试者工作特征曲线下的面积(AUC)为 1, 对偏振分复用-二进制相移键控(PDM-BPSK)、偏振分复用-四进制相移键控(PDM-QPSK)等调制格式的识别准确率超过 98.5%, 平均准确率较 XGboost、Tabnet 等对比模型提升 2.05%~5.63%, 且在 OSNR 为 18 dB 时即可实现 100% 识别精度。

**关键词:** 弹性光网络; 调制格式识别; 集成学习; 光信噪比

**中图分类号:** TN256 **文献标志码:** A **文章编号:** 1002-5561(2025)03-0108-06

**DOI:** 10.13921/j.cnki.issn1002-5561.2025.03.018

**开放科学(资源服务)标识码(OSID):**

Modulation format identification  
based on Stokes space and Stacking model

LIU Yu, LIU Zhansheng\*

(School of Computer Science and Communication Engineering, Jiangsu University, Zhenjiang Jiangsu 212000, China)

**Abstract:** To improve the accuracy and robustness of modulation format identification (MFI) in elastic optical network (EON), this paper proposes an MFI method based on Stokes space and a Stacking model. The method extracts one-dimensional probability distribution features of the three axes in Stokes space using kernel density estimation to construct a 240-dimensional feature vector. A genetic algorithm is employed to optimize the combination of base models and meta-models in the Stacking model, while Bayesian optimization is used for hyperparameter tuning, enhancing classification performance under low signal-to-noise ratios. Simulation results show that, within an optical signal-to-noise ratio (OSNR) range of 5~30 dB, the model achieves a macro-average area under the receiver operating characteristic curve (AUC) of 1. The identification accuracy exceeds 98.5% for modulation formats such as polarization-division multiplexing binary phase-shift keying (PDM-BPSK) and polarization-division multiplexing quadrature phase-shift keying (PDM-QPSK), with an average accuracy improvement of 2.05%~5.63% compared to benchmark models like XGBoost and TabNet. Additionally, 100% identification precision is achieved at an OSNR of 18 dB.

**Key words:** elastic optical network, modulation format identification, ensemble learning, optical signal-to-noise ratio

## 0 引言

随着网络数据传输的异构化和动态化发展, 下一

收稿日期: 2024-10-21。

基金项目: 江苏大学高级人才科研启动基金(16JDG023)资助。

作者简介: 刘昱(2000—), 男, 硕士研究生, 现就读于江苏大学计算机科学与通信工程学院通信工程专业, 研究方向为光纤通信, 主要从事光纤通信系统的仿真搭建和光性能监测相关工作。

\* 通信作者: 刘战胜(1975—), 男, 博士, 副教授, 主要研究方向为光纤通信。



代弹性光网络(EON)需具备更高的灵活性和适应性。具体而言, 发射机需根据传输链路状态和用户需求动态调整传输速率、信号功率及调制格式等参数, 以优化网络资源利用率并保障服务质量<sup>[1]</sup>。随着未来通信系统中调制格式的多样化与动态化需求日益显著, 可靠的调制格式识别(MFI)技术将成为提升系统灵活性与资源优化配置的关键<sup>[2]</sup>。

近年来, 针对数字相干检测系统的 MFI 技术已取得显著进展, 现有方案主要分为两类: 基于 Jones 空间的监测方案和基于 Stokes 空间的监测方案。Jones 空间

方案通常利用星座图或幅度直方图等特征,结合机器学习算法实现调制格式分类<sup>[3]</sup>。例如,文献[4]采用多层感知机筛选  $K$  个最优特征,并借助主成分分析(PCA)和  $t$ -分布随机邻域嵌入( $t$ -SNE)方法实现数据降维与可视化;文献[5]提出基于信号幅度直方图的 MFI 方法;文献[6]设计 UniQGAN 网络,通过多条件嵌入和多域分类提升低信噪比下同相/正交(I/Q)数据的调制分类性能;文献[7]则提出多特征融合网络(MFF-Net),通过并行处理星座图及其水平投影以融合图像特征。然而, Jones 空间方案存在固有局限性:例如,多进制相移键控(MPSK)信号在载波恢复前的复平面分布相似,导致难以区分。相较而言, Stokes 空间方案对载波相位噪声、频偏及偏振混频不敏感,因而更具优势<sup>[3]</sup>。相关研究包括:文献[1]设计基于 Stokes 向量的多任务学习深度神经网络(DNN),提取 Stokes 参数  $S_1$  对应坐标轴分布及差分相位特征;文献[8]提出基于改进粒子群优化聚类的盲 MFI 方案,统计 Stokes 参数  $S_2$  与  $S_3$  对应坐标轴构成的平面聚类数量实现识别;文献[9]采用轻量级卷积神经网络(CNN)处理二维 Stokes 平面数据;文献[10]利用多芯光纤生成 Stokes 断层图像,结合迁移学习 CNN 实现 MFI;文献[11]提出  $k$  均值聚类辅助的高斯误码率估计方法;文献[12]则利用 Stokes 参数  $S_1$  和  $S_2$  对应坐标轴的拟合曲线的一阶导数特征进行识别。

尽管上述方法在理想信道条件下表现良好,但其局限性不容忽视:多数方案依赖二维图像数据,而图像视觉特征易受低噪声、失真及信号干扰的影响,导致星座点分布混乱,识别精度下降。此外,图像处理技术(如边缘检测、图像分割)通常计算复杂度较高。对于表格化数据,传统机器学习算法易过拟合,而深度学习模型则因数据特征的稀疏性和异质性难以有效挖掘特征间非线性关系<sup>[13]</sup>。因此,本文提出一种基于 Stokes 空间和 Stacking 模型的 MFI 方法,通过组合优化中的 Stacking 模型提升识别性能。

## 1 MFI 基本原理

### 1.1 MFI 前处理

数字相干接收机的数字信号处理(DSP)结构如图1所示。模/数转换后的信号首先经过与调制格式无关的预处理,包括色散补偿、时钟恢复和恒模算法(CMA)均衡。色散补偿用于消除光纤传输中由色散引起的信号展宽和畸变,保证信号在时域正确对齐;时钟恢复从接收信号中提取采样时钟信息,确保后续数




图1 DSP 结构

字处理的采样点与信号同步,避免采样误差;CMA 均衡则通过盲均衡算法自适应补偿信道中的偏振态变化和信号幅度失真,从而恢复信号的原始特征<sup>[14]</sup>。

### 1.2 基于 Stokes 空间的 MFI 处理

首先,将偏振分复用(PDM)信号通过式(1)映射到 Stokes 空间。

$$(S_0, S_1, S_2, S_3) = \begin{bmatrix} E_x E_x^* + E_y E_y^*, E_x E_x^* - E_y E_y^*, \\ E_x E_y^* + E_y E_x^*, j(E_x E_y^* - E_y E_x^*) \end{bmatrix} \quad (1)$$

其中,  $S_0$  为 2 个信号的总功率,  $S_1$  为 2 个信号的能量差,  $S_2$  和  $S_3$  为 2 个信号的相位差,  $E_x$  为  $x$  偏振信号,  $E_y$  为  $y$  偏振信号, 上标“\*”为共轭操作, 归一化参数( $s_1, s_2, s_3$ )分别为  $s_1 = S_1/S_0, s_2 = S_2/S_0, s_3 = S_3/S_0$ 。

然后,对该空间的 3 个轴分别进行一维的核密度估计,所采用的核函数为高斯核。带宽选择方法为 Silverman 经验法则<sup>[15]</sup>,即

$$h = 1.06 \sigma n^{-\frac{1}{5}} \quad (2)$$

其中,  $h$  为带宽,  $\sigma$  为样本标准差,  $n$  为样本数。

数据处理时,将归一化参数( $s_1, s_2, s_3$ )每个轴的核密度估计结果均匀分布在 80 个点上,得到一个  $80 \times 1$  的向量;将 3 个轴依次拼接起来,得到一个  $240 \times 1$  的向量  $v$ 。对于每一组向量,用 0~6 的数字标量  $m$  进行标记,0~6 分别对应偏振分复用-二进制相移键控(PDM-BPSK)、偏振分复用-四进制相移键控(PDM-QPSK)、偏振分复用-八进制相移键控(PDM-8PSK)、偏振分复用-八进制正交幅度调制(PDM-8QAM)、PDM-16QAM、PDM-32QAM、PDM-64QAM 信号。然后,将向

刘昱,刘战胜;基于 Stokes 空间和 Stacking 模型的调制格式识别

量  $v$  和标量  $m$  输入到本文所提出优化组合的 Stacking 模型中进行训练与预测,以确定信号的调制格式。

### 1.3 MFI 后处理

在确定调制格式后,首先对信号进行偏振解复用处理。该步骤基于信道的偏振特性,将接收到的偏振复用信号分解为原始的正交偏振分量,从而准确恢复信号的初始偏振态。随后进入频偏估计阶段,通过计算激光器频率漂移或频偏不匹配产生的偏差,实施频偏补偿,以确保解调后的信号频率保持同步。完成频偏校正后,需执行载波相位恢复操作,采用相位估计算法消除信号在传输过程中引入的相位噪声,精确重构信号的相位信息,为后续相位解调提供保障。最终,依据已识别的调制格式对信号进行解码处理,将数字信号转换为二进制数据序列。通过将接收数据与参考数据进行比对,可计算出系统的误码率,该指标客观反映了通信链路的传输性能。

## 2 Stacking 模型的性能优化

Stacking 模型是一种典型的双层集成学习框架,其核心机制在于通过异构或同构异参的基模型组合,利用模型间的误差分布差异性实现性能提升。在该架构中,第一层由基模型构成,第二层元模型通过对基模型输出的二次学习,有效降低单一模型的偏差和方差,从而显著提升整体预测精度<sup>[6]</sup>。

本文采用基于树结构 Parzen 估计器(TPE)的贝叶斯优化方法对各模型超参数进行独立优化。该方法通过构建概率模型指导参数搜索,确保基模型与元模型均能在各自的超参数空间中获得最优配置。

### 2.1 采用遗传算法优化 Stacking 模型组合

Stacking 模型的性能优化涉及 2 个关键维度:各子模型的独立性能以及基模型与元模型的组合策略。该组合优化问题本质上是一个高维搜索问题,需要在

庞大的模型排列组合空间中定位最优配置。传统网格搜索方法虽能实现穷举式搜索,但由于参数空间维度灾难,其计算效率难以满足实际需求。通过对主流优化算法的实证比较(包括随机搜索、遗传算法、贝叶斯优化和模拟退火),本文发现遗传算法以 93.32% 的准确率表现最优,这得益于其仿生学优化机制:通过种群进化过程中的选择、交叉和变异操作,系统性地探索解空间,有效规避局部最优陷阱。尽管其计算耗时相对较长,但获得的性能提升具有显著优势,故本文选用遗传算法实施模型组合优化。具体实施流程如下:

- 1) 编码设计:采用实数编码方案,每个染色体对应一个完整的模型组合配置。
- 2) 种群初始化:随机生成 20 个初始模型组合构成第一代种群,确保初始种群多样性。
- 3) 适应度评估:以测试集预测准确率为适应度指标,建立模型性能的量化评价标准。
- 4) 选择操作:结合轮盘赌选择(保障概率公平)与精英保留策略,平衡探索与开发需求。
- 5) 交叉运算:设定 0.4 的交叉概率,通过单点交叉操作实现不同组合间的特征交换。
- 6) 变异操作:采用均匀变异策略,以 0.05 的概率随机替换个体中的模型组件,维持种群多样性。
- 7) 终止准则:设置双重停止条件——最大迭代次数 50 次或连续 10 次适应度提升小于 0.1%,确保收敛稳定性。

### 2.2 Stacking 模型组合优化结果分析

经过多次遗传算法迭代优化,确定最佳 Stacking 模型的基模型由随机森林(RF)、支持向量机(SVM)、AdaBoost 和多层感知机(MLP)组成,元模型选用 CatBoost 与 MLP。该模型在 5~30 dB 内表现出卓越性能,预测准确率达 95.97%,显著优于原始候选模型组合。图 2 为优化后的 Stacking 模型架构,其工作流程可分




图 2 优化后的 Stacking 模型架构



为 2 个阶段;第一阶段,预处理数据输入基模型后,采用五折交叉验证进行性能评估,并将各基模型输出的预测概率拼接构成新特征集;第二阶段,元模型基于软投票机制,通过加权平均整合基模型的预测概率,最终输出预测结果。

在确定最佳模型组合后,为进一步提升模型性能,本文对集成模型进行了系统的贝叶斯超参数优化,结果如表 1 所示。

表 1 优化后的超参数配置表

| 超参数                 | 数值      | 超参数                           | 数值    |
|---------------------|---------|-------------------------------|-------|
| RF_n_estimators     | 200     | RF_max_depth                  | 30    |
| SVM_c               | 7.089 8 | SVM_gamma                     | 0.169 |
| SVM_kernel          | RBF     | ADA_n_estimators              | 50    |
| Ada_max_depth       | 30      | MLP_B_hidden_size             | 50    |
| MLP_B_activation    | (0,1)   | MLP_B_max_iter                | 100   |
| MLP_M_activation    | [0,+∞)  | MLP_M_hidden_size             | 100   |
| MLP_M_iter          | 100 00  | CAT_iterations                | 300   |
| CAT_depth           | 4       | CAT_learning_rate             | 0.216 |
| CAT_stopping_rounds | 20      | W <sub>i</sub> (MLP:CatBoost) | 4:6   |

模型的性能对比结果如表 2 所示。可以看出,经过贝叶斯调参后,最终优化模型在测试集上取得了最佳的预测准确率、召回率、F1 分数,性能优于原始组合模型和优化调参前模型。因此,本文将采用优化后的模型进行相关实验的测试。

表 2 模型性能对比

| 模型    | 准确率/%    | 精确度/%    | 召回率/%    | F1 分数   |
|-------|----------|----------|----------|---------|
| 原始组合  | 95.481 5 | 95.486 1 | 95.493 6 | 0.954 7 |
| 优化调参前 | 95.978 4 | 95.910 1 | 96.044 7 | 0.959 6 |
| 最终优化  | 96.698 9 | 96.788 9 | 96.780 9 | 0.967 6 |

### 3 结果与讨论

#### 3.1 仿真设置

本文采用 OptiSystem 15 搭建了仿真链路,用于收集数据,其仿真设置如图 3 所示。

在发送端,光载波信号由外腔激光器(ECL)提供,输出线偏振光以 45°入射至偏振分束器(PBS)。激光器中心波长为 1 550 nm,线宽约 100 kHz。PBS 输出的 x 偏振态与 y 偏振态两路正交光信号,分别由 I/Q 调制器调制生成 PDM-BPSK、PDM-QPSK、PDM-8PSK、PDM-8QAM、PDM-16QAM、PDM-32QAM 及 PDM-64QAM 信号,传输速率为 28 GBaud。调制后信号经偏振合束器(PBC)复用为单路偏振复用光信号并输入传输链路。

在传输链路中,光信噪比(OSNR)设置模块通过掺铒光纤放大器(EDFA)自发辐射(ASE)噪声源和可变光衰减器(VOA)调节 OSNR,背靠背(BtB)传输场景下由光谱分析仪(OSA)实时监测 OSNR 值。

在接收端,光带通滤波器(OBPF)首先滤除带外 ASE 噪声。偏振复用信号经 PBS 分离为 2 路正交光波,在混频器中分别与 2 路正交本振光混频,经光电探测器(PD)接收后,由低通滤波器(LPF)和模/数转换器(ADC)处理为数字信号,最终输入 DSP 模块。

本文以 1 dB 步长调节 7 种调制信号的 OSNR (5~30 dB)。每种调制格式在固定 OSNR 下生成 200 组仿真数据,采样时随机选取 100 个时间节点以增强随机性。每组数据包含 8 192 个符号,最终共生成 18 200 组数据。本文按 80%(14 560 组)训练集与 20%(3 640 组)测试集划分,用于 Stacking 模型训练与测试。

#### 3.2 MFI 结果

为评估模型性能,本文基于测试集生成了受试者工作特征(ROC)曲线。该曲线通过展示真阳性率(TPR)





图 3 仿真设置示意图


刘昱,刘战胜;基于 Stokes 空间和 Stacking 模型的调制格式识别

与假阳性率(FPR)之间的关系来衡量分类模型的有效性。当 ROC 曲线趋近于左上角时,表明模型在保持高 TPR 的同时维持低 FPR, 此时的模型表现更为出色。此外,ROC 曲线下的面积(AUC)作为评估模型整体表现的关键指标,其值越接近 1,则说明模型的分类效果越佳。图 4(a)为不同调制格式下模型的 ROC 曲线。可以看出,模型的宏平均 AUC 值达到最优水平,这表明其在各类调制格式上的分类性能均表现出色。

在 5~30 dB 的 OSNR 范围内,测试集的 MFI 混淆矩阵如图 4(b)所示。可以看出,除 32QAM 和 64QAM 外,其它信号的分类准确率超过了 98.5%。尽管 32QAM 和 64QAM 的性能略低于其它调制格式,但在低 OSNR 环境下,由于信道条件恶劣且高阶调制格式的信号点间距较小,噪声引起的相邻信号点混淆影响了解调准确性。因此,32QAM 和 64QAM 的整体分类性能依然保持在较高水平。



(a) 测试集的 ROC 曲线



(b) 测试集的混淆矩阵

图 4 测试集的 ROC 曲线和混淆矩阵

### 3.3 OSNR 对 MFI 的影响

本文研究了 OSNR 对模型性能的影响, 得到 BPSK、QPSK、8PSK、8QAM、16QAM、32QAM 和 64QAM 信号的识别准确率与 OSNR 的关系如图 5 所示。其中, 对于 28 GBaud 的上述各类信号, 其理论 OSNR 值(7%硬判决前向纠错阈值)分别为 10、12.04、17.38、17.14、18.75、22、24 dB<sup>[17]</sup>, 而测试中所有识别准确率达到 100% 前对应的 OSNR 值均低于其理论前向纠错阈值, 这表明该模型在低 OSNR 环境下具有卓越的性能表现。




图 5 不同调制格式在不同 OSNR 下的识别准确率

### 3.4 与不同方法的比较

为了进一步验证所提出模型的性能, 本文将其与经典模型 XGboost、Tabnet、FT-transformer 和 Elastic-net 进行了比较, 其对比结果如图 6 所示。可以看出, Stacking 模型在低 OSNR 时性能显著优于其它模型, 且在 OSNR 为 18 dB 时平均识别准确率就已经达到了 100%。相较于 XGboost、Tabnet、FT-transformer、Elastic-net, Stacking 模型的平均识别准确率分别提高了 3.5%、5.63%、2.05%、2.72%。




图 6 不同方法的识别准确率

## 4 结束语

本文针对 EON 中调制格式识别面临的挑战, 提出了一种基于 Stokes 空间和 Stacking 模型的 MFI 方法。该方法利用核密度估计从数据样本中推断概率分布, 无需对总体分布进行预设假设, 从而更准确地反映数据的真实特性。仿真结果表明: Stacking 模型在各类调制格式上的分类性能均表现出色, ROC 曲线的 AUC 为 1; 与其它模型相比, 该模型的平均识别准确率提高了 2.05% 以上。然而, 本方法在处理更高阶调制格式及复杂信道环境(如色散、非线性效应等联合影响)时仍存在局限性。后续研究将重点优化模型结构, 结合更多维度的信道特性, 以提升方法在复杂环境中的泛化能力, 从而进一步提高 EON 系统 MFI 的性能与适用性。

## 参考文献:

- [1] PU Z, JIANG L, YAN L, et al. Joint modulation format identification and OSNR monitoring based on Stokes vector distribution features for digital coherent optical receivers[J]. Chinese Optics Letters, 2024, 22(5): 27–33.
- [2] WANG M, LIU J, ZHANG J, et al. Modulation format identification based on phase statistics in Stokes space[J]. Optics Communications, 2021, 480: 126481–1–126481–7.
- [3] XIANG Q, YANG Y, ZHANG Q, et al. Joint, accurate and robust optical signal to noise ratio and modulation format monitoring scheme using single Stokes-parameter-based artificial neural network[J]. Optics Express, 2021, 29(5): 7276–7287.
- [4] XU H, YANG L, YU X, et al. Blind and low-complexity modulation format identification scheme using principal component analysis of Stokes parameters for elastic optical networks[J]. Optics Express, 2020, 28(14): 20249–20263.
- [5] LV H, ZHOU X, HUO J, et al. Joint OSNR monitoring and modulation format identification on signal amplitude histograms using convolutional neural network[J]. Optical Fiber Technology, 2021, 61: 102455–1–102455–6.
- [6] LEE I, LEE W. UniQGAN: unified generative adversarial networks for augmented modulation classification[J]. IEEE Communications Letters, 2021, 26(2): 355–358.
- [7] LI J, MA J, LIU J, et al. Modulation format identification and OSNR monitoring based on multi-feature fusion network[J]. Photonics, 2023, 10(4): 373–388.
- [8] ZHAO R, XU H, BAI C, et al. A modulation format identification scheme based on modified PSO clustering in Stokes space[C]//IEEE. Proceedings of 2020 Asia Communications and Photonics Conference (ACP) and International Conference on Information Photonics and Optical Communications (IOPC). Beijing: IEEE, 2020: 1–3.
- [9] ZHANG W, ZHU D, HE Z, et al. Identifying modulation formats through 2D Stokes planes with deep neural networks[J]. Optics Express, 2018, 26(18): 23507–23517.
- [10] GUO Z, LIU B, REN J, et al. Modulation format recognition with transfer learning assisted convolutional neural network using multiple Stokes sectional plane image in multi-core fibers[J]. Optics Express, 2022, 30(12): 21990–22005.
- [11] ZHANG Q, YANG Y, GUO C, et al. Accurate BER estimation scheme based on K-means clustering assisted Gaussian approach for arbitrary modulation format[J]. Journal of Lightwave Technology, 2019, 38(8): 2152–2157.
- [12] YI A, YAN L, LIU H, et al. Modulation format identification and OSNR monitoring using density distributions in Stokes axes for digital coherent receivers[J]. Optics Express, 2019, 27(4): 4471–4479.
- [13] ARIK S, PFISTER T. Tabnet: attentive interpretable tabular learning [[EB/OL]. <https://arxiv.org/abs/1908.07442>.
- [14] HAO M, HE W, JIANG X, et al. Modulation format identification based on multi-dimensional amplitude features for elastic optical networks[J]. Photonics, 2024, 11(5): 390–404.
- [15] SILVERMAN B W. Density estimation for statistics and data analysis [M]. London: Routledge, 2018.
- [16] GANAIE M A, HU M, MALIK A K, et al. Ensemble deep learning: a review[J]. Engineering Applications of Artificial Intelligence, 2022, 115: 105151–1–105151–18.
- [17] YANG L, XU H, BAI C, et al. Modulation format identification using graph-based 2D Stokes plane analysis for elastic optical network[J]. IEEE Photonics Journal, 2021, 13(1): 1–15.