

引用本文:梁瑞悦,于海洋,陈纯毅,等.基于 PSO-WELM 的不平衡 OAM 识别模型研究[J].光通信技术,2025,49(3):67-72.

基于 PSO-WELM 的不平衡 OAM 识别模型研究

梁瑞悦¹,于海洋^{1,2*},陈纯毅^{1,2},倪小龙²,胡小娟¹,李延风¹

(1.长春理工大学 计算机科学技术学院,长春 130022;2.长春理工大学 光电测控与光信息传输技术教育部重点实验室,长春 130022)

摘要:针对标签分布不平衡的轨道角动量(OAM)识别问题,提出了基于粒子群优化(PSO)算法的加权极限学习机(WELM)识别模型。该模型利用 PSO 算法对 WELM 的输入权重和偏置进行联合优化,提高了 WELM 的稳定性和鲁棒性。对比分析了 PSO-WELM 模型与支持向量机(SVM)、深度学习(DL)、反向传播人工神经网络(BP-ANN)模型的性能。实验结果表明:PSO-WELM 模型在较弱湍流强度下能够完全正确识别少数类、多数类 OAM 光束;在中等湍流强度下,PSO-WELM 模型的各项评价指标值均优于对比方法,证明了该模型在识别不平衡状态 OAM 光束方面具有可行性和有效性。

关键词:不平衡数据;轨道角动量;机器学习;粒子群优化算法;极限学习机

中图分类号:TN929.12 文献标志码:A 文章编号:1002-5561(2025)03-0067-06

DOI:10.13921/j.cnki.issn1002-5561.2025.03.011

开放科学(资源服务)标识码(OSID):



Research on imbalanced OAM recognition mode based on PSO-WELM

LIANG Ruiyue¹, YU Haiyang^{1,2*}, CHEN Chunyi^{1,2}, NI Xiaolong², HU Xiaojuan¹, LI Yanfeng¹

(1. School of Computer Science and Technology, Changchun University of Science and Technology, Changchun 130022, China;

2. Key Laboratory of Photoelectric Measurement & Control and Optical Information Transfer Technology, Ministry of Education, Changchun University of Science and Technology, Changchun 130022, China)

Abstract: To address the orbital angular momentum (OAM) recognition problem with imbalanced label distribution, a weighted extreme learning machine (WELM) recognition model based on the particle swarm optimization (PSO) algorithm is proposed. This model jointly optimizes the input weights and biases of WELM using PSO algorithm, enhancing the stability and robustness of WELM. A comparative analysis was conducted on the performance of the PSO-WELM model against support vector machine (SVM), deep learning (DL), and backpropagation artificial neural network (BP-ANN) models. Experimental results show that the PSO-WELM model can correctly identify minority-class and majority-class OAM beams under weak turbulence intensity. Under moderate turbulence intensity, all evaluation metrics of the PSO-WELM model outperform those of the comparative methods, demonstrating the feasibility and effectiveness of the model in recognizing imbalanced OAM beams.

Key words: imbalanced data, orbital angular momentum, machine learning, particle swarm optimization algorithm, extreme learning machine

0 引言

轨道角动量(OAM)光束因其正交可分离特性,能

收稿日期:2024-10-30。

基金项目:国家自然科学基金项目(62305030)资助;吉林省科技发展计划项目(20240602123RC)资助。

作者简介:梁瑞悦(2000—),女,硕士研究生,现就读于长春理工大学计算机科学技术学院计算机技术专业,主要研究方向为智能信息处理。

*通信作者:于海洋(1989—),男,博士,副教授,主要研究方向为计算机应用、光传输仿真。



有效提升信号利用率和通信系统容量^[1],已成为自由空间光(FSO)通信领域的重要载体。然而,在实际应用中,不同调制方式和信号处理维度的需求导致各模态样本数据呈现非均衡分布。同时,大气湍流引发的模态串扰会破坏 OAM 光束的正交性^[2],诱发光强闪烁与光束漂移^[3]等现象,显著降低接收端模态识别精度。因此,建立针对大气湍流影响下非均衡 OAM 光束的准确识别方法具有重要应用价值。

现有 OAM 模态识别研究主要分为光学方法^[4-6]和机器学习方法 2 类,其中后者凭借优异的非线性映射

能力成为当前研究重点。SUN R 等人^[7]通过结合分析光束闪烁指数、展宽及漂移特征,采用遗传算法优化支持向量机参数,实现了高模态值 OAM 光束的有效识别。NA Y 等人^[8]构建的大气湍流自适应神经网络,成功解决了不同湍流条件下分数 OAM 模态的高分辨率识别难题。付鑫^[9]通过精简卷积神经网络结构,实现了 5 种模态叠加的拉盖尔高斯光束分类。宋芝依等人^[10]则利用卷积神经网络对复杂大气湍流环境中的高阶复合 OAM 光束进行检测。这些方法虽在特定场景下表现良好,但普遍忽视了一个关键问题:当光斑样本呈现非均衡分布时,传统算法对少数类和多数类 OAM 光束都采用均等错分代价,必然导致识别结果向多数类偏移。

为解决大气湍流环境下非均衡 OAM 光束的识别难题,本文提出一种基于粒子群优化(PSO)算法^[11]的加权极限学习机(WELM)^[12]识别模型(下文简称 PSO-WELM 模型)。

1 PSO-WELM 模型

本文采用 WELM 构建识别模型,通过差异化处理不同类别样本的错分代价,有效改善非均衡数据集的识别性能。

1.1 基于代价敏感的 WELM 模型

WELM 在传统极限学习机(ELM)框架中引入权重矩阵,通过提升少数类样本的错分惩罚权重,使模型聚焦于少数类 OAM 光束的准确识别。然而,WELM 的输入权重和偏置随机初始化特性会导致识别性能波动。为此,本文采用 PSO 算法对 WELM 的输入权重和偏置进行联合优化,其粒子 s 的位置向量定义为

$$D_s = \begin{bmatrix} a_{11}^s, a_{12}^s, \dots, a_{1L}^s, a_{21}^s, a_{22}^s, \dots, a_{2L}^s, \dots, \\ a_{n1}^s, a_{n2}^s, \dots, a_{nL}^s, b_1^s, b_2^s, \dots, b_L^s \end{bmatrix}_{1 \times (n \times L + L)} \quad (1)$$

其中, a_{nl} 为 WELW 中输入层第 n 个节点和隐藏层的第 L 个节点间的输入权重, b_L 为 WELW 第 L 个隐藏节点的偏置。PSO 算法通过全局搜索确定最优参数组合,显著提升模型稳定性。

1.2 数据处理与模型构建

在预处理阶段,对受大气湍流影响的拉盖尔-高斯(LG)光束光强图像进行灰度化处理,构建训练集输入矩阵 $X = [x_1, x_2, \dots, x_N]_{n \times N}$ 、测试集输入矩阵 $X'_{n \times N'}$ 。其中, n 为样本的特征数, N 为训练集样本数, N' 为测试集样本数; x_i 为第 i ($1 \leq i \leq N$) 个训练样本的输入特征向量。根据训练集和测试集的标签,对应训练集期

望输出矩阵 $O = [t_1^T, t_2^T, \dots, t_N^T]_{N \times m}^T$ 和测试集期望输出矩阵 $O'_{N' \times m}$ 。其中, m 为样本类别数, t_i 为第 i 个训练样本的期望输出向量。

一个含有 L 个隐藏节点的 WELM 能零误差逼近训练集,可简写为

$$H\beta = O \quad (2)$$

隐藏层输出矩阵 H 和输出权重矩阵 β 分别定义为

$$H = \begin{bmatrix} G(a_1 x_1 + b_1) & \dots & G(a_L x_1 + b_L) \\ \vdots & \dots & \vdots \\ G(a_1 x_N + b_1) & \dots & G(a_L x_N + b_L) \end{bmatrix}_{N \times L} \quad (3)$$

$$\beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]_{L \times m}^T \quad (4)$$

其中, a_j 、 β_j 和 b_j 分别为第 j ($1 \leq j \leq L$) 个隐藏节点的输入权重、输出权重和偏置, $G(\cdot)$ 为激活函数。

1.3 优化问题求解

为实现训练误差最小化与模型泛化能力平衡,构建优化目标如下:

$$\begin{aligned} \min_{\beta, \varepsilon_i} : & \frac{1}{2} \|\beta\|^2 + \frac{1}{2} CW \sum_{i=1}^N \|\varepsilon_i\|^2 \\ \text{s.t.} : & h(x_i)\beta = t_i^T - \varepsilon_i^T, i=1, \dots, N \end{aligned} \quad (5)$$

其中, C 是正则化系数(用于调整 WELM 预测精确性和泛化性间的平衡), ε_i 是 x_i 的预测误差, $h(x_i)$ 是 x_i 在隐藏层的输出, W 是样本权重矩阵。根据 KKT (Karush-Kuhn-Tucker) 理论,求解优化式(5)可等效为求解式(6)。

$$\begin{aligned} \min_{\beta, \varepsilon_i, \alpha_i} : & \frac{1}{2} \|\beta\|^2 + \frac{1}{2} CW \sum_{i=1}^N \|\varepsilon_i\|^2 - \\ & \sum_{i=1}^N \sum_{q=1}^m \alpha_{iq} [h(x_i)\beta'_q - t_{iq} + \varepsilon_{iq}] \end{aligned} \quad (6)$$

其中, α_i 为拉格朗日乘子, $\alpha_i = [\alpha_{i1}, \dots, \alpha_{im}]^T$; $\beta = [\beta'_1, \dots, \beta'_m]_{L \times m}$, β'_q 为隐藏层节点和第 q 个输出层节点间的权重。

求解偏导为零的最优条件,最终得到输出权重解析解为

$$\beta_{\text{WELM}} = \begin{cases} H^T (\frac{I}{C} + WHH^T)^{-1} WO, N < L \\ (\frac{I}{C} + H^T WH)^{-1} H^T WO, N \geq L \end{cases} \quad (7)$$

其中, I 为单位矩阵。

1.4 PSO-WELM 模型实现流程

基于 PSO-WELM 模型的不平衡 OAM 光束识别

过程可分为初始化阶段、迭代寻优阶段、训练阶段和测试识别与评估阶段。

在初始化阶段,需要初始化 PSO-WELM 模型的相关参数,建立 PSO-WELM 结构。包括初始化粒子群规模和最大迭代次数、粒子 $s(1 \leq s \leq \text{种群规模})$ 的位置 D_s 和速度 V_s 、WELM 隐藏层节点个数和激活函数等,并将几何均值(G-mean)作为粒子的适应度值。

在迭代寻优阶段,每当粒子 s 对位置迭代更新后,都将重新计算其适应度值,并将此次的适应度值与粒子 s 的个体极值 P_s 的适应度值、群体极值 P_g 的适应度值作比较,根据比较结果对 P_s 、 P_g 进行选择更新。当满足终止条件时结束迭代寻优,最终的 P_g 即为全局最优解。

在 PSO 中,粒子 s 分别通过式(8)和式(9)对其速度 V_s 和位置 D_s 进行第 $k+1$ 次的迭代。

$$V_s^{k+1} = \omega V_s^k + c_1 r_1 (P_s^k - D_s^k) + c_2 r_2 (P_g^k - D_s^k) \quad (8)$$

$$D_s^{k+1} = D_s^k + V_s^{k+1} \quad (9)$$

其中, ω 为惯性权重, c_1 、 c_2 为学习因子, r_1 、 $r_2 \in [0, 1]$ 的随机数, V_s^k 、 D_s^k 、 P_s^k 和 P_g^k 分别为第 k 次迭代时粒子 s 的速度、位置、个体极值和粒子群的群体极值。

在训练阶段,根据 P_g 中最优的输入权重和偏置对 WELM 进行初始化,并在训练集输入矩阵 X 、训练集期望输出矩阵 O 中根据式(7)得到经 PSO 算法优化后的最优输出权重矩阵 β_{PSO} ,完成 PSO-WELM 模型的训练。

在测试识别与评估阶段,使用 PSO 优化后的 WELM 模型对 LG 光束测试数据 X' 进行识别,得到预测输出矩阵 O' , $O' = h(X')\beta_{\text{PSO}}$,然后根据预测结果和期望结果计算相应的评价指标值。

2 分析与讨论

2.1 参数设置与数据集

在模拟 LG 光束通过大气湍流信道传输的过程中,设定仿真参数如下:大气湍流内尺度 $l_0=0.0003$ m,大气湍流外尺度 $L_0=50$ m,传输距离 $z=1000$ m,束腰半径 $\omega_0=3$ cm,波长 $\lambda=1550$ nm,径向指数 $p=0$,初始生成的光强图像像素为 300×300 ,输入模型的像素为 32×32 。

在 PSO-WELM 模型中,设置 WELM 的隐藏层节点数 L 为 3600,激活函数 G 为 Sigmoid 函数。

本文选用 $l=1 \sim 10$ 的 LG 光束作为分析对象,其中 $l=1$ 的 LG 光束被定义为少数类,并赋予类别标签值

1;而将 $l=2 \sim 10$ 的 LG 光束定义为多数类,其类别标签值设为 0,从而形成一个二分类问题,以便探讨基于 PSO-WELM 模型对受不同强度大气湍流影响的 2 类 LG 光束的识别能力。

实验数据根据不同的大气湍流强度生成:较弱湍流条件下 $C_n^2=1 \times 10^{-16} \text{ m}^{-2/3}$,中等湍流条件下 $C_n^2=7 \times 10^{-15} \text{ m}^{-2/3}$,较强湍流条件下 $C_n^2=7 \times 10^{-14} \text{ m}^{-2/3}$ 。对于每种湍流下的 LG 光束,分别生成了 300 张受大气湍流影响的光强图片,总计 3000 张。这些数据进一步划分为训练集 1400 张、验证集 800 张和测试集 800 张。

2.2 评价指标

传统分类方法通常采用准确率作为性能评价指标,但在处理非均衡数据时,该指标可能因多数类样本占比较高而呈现过于乐观的评估结果。为全面评估分类器性能,本文除采用均方根误差(RMSE)外,还引入适用于非均衡数据评价的 G-mean 值和受试者工作特征(ROC)曲线,以综合分析 PSO-WELM 及对比方法对少数类和多数类 LG 光束的识别能力。

RMSE 用于量化模型预测误差,其计算公式为

$$S_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (R_i - \hat{R}_i)^2} \quad (10)$$

其中, N 为测试样本数量, R_i 、 $\hat{R}_i$ 分别为第 i 个测试样本的实际值、模型预测值。

混淆矩阵作为计算 G-mean 值、绘制 ROC 曲线的基础,如表 1 所示。其中, F_1 为被正确分类的少数类 LG 光束数量, F_2 为被正确分类的多数类 LG 光束数量, F_3 为少数类被误分成多数类的 LG 光束数量, F_4 为多数类被误分成少数类的 LG 光束数量。

表 1 混淆矩阵

实际类别	预测类别	
	正类	负类
正类	F_1	F_3
负类	F_4	F_2

对于本文的 LG 光束二分类问题, G-mean 值的计算公式为

$$g_{\text{G-mean}} = \sqrt{\frac{F_1}{F_1 + F_3} \times \frac{F_2}{F_2 + F_4}} \quad (11)$$

其中, $\frac{F_1}{F_1 + F_3}$ 、 $\frac{F_2}{F_2 + F_4}$ 分别为少数类、多数类的分类准确率。

在分类数据分布不平衡的情况下,ROC 曲线仍具

梁瑞悦,于海洋,陈纯毅,等. 基于 PSO-WELM 的不平衡 OAM 识别模型研究

有适用性。ROC 曲线的横轴为假阳性率(FPR),其计算公式为 $\frac{F_4}{F_2+F_4}$;纵轴为真阳性率(TPR),其计算公式为 $\frac{F_1}{F_1+F_3}$ 。为绘制 ROC 曲线,首先需对测试数据被预测为少数类 LG 光束的预测分数进行降序排列,依次将各预测分数作为判别阈值。然后,基于测试数据的预测分数与实际标签,计算每一阈值下的(FPR,TPR)坐标点。最终,通过连接这些点形成 ROC 曲线。模型性能可通过 ROC 曲线的相对位置进行评价:若某模型的 ROC 曲线完全位于另一模型的左上方,则前者具有严格更优的分类性能。

2.3 结果对比与分析

为验证 PSO-WELM 模型在识别受大气湍流影响的少数类与多数类 LG 光束时的有效性,本文采用相同数据集对支持向量机(SVM)、深度学习(DL)、反向传播神经网络(BP-ANN)模型进行训练与测试,并基于评价指标与 PSO-WELM 模型进行对比分析。

图 1 为在中湍流强度 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下,PSO-WELM 模型与 3 种对比模型在测试集上的 RMSE 对比结果。可以看出,PSO-WELM 模型的 RMSE 值最低 (0.1),较 SVM、DL 和 BP-ANN 模型分别降低了 0.027 48、0.032 29 和 0.027 48。由此可见,PSO-WELM 模型在中湍流条件下对少数类及多数类 LG 光束的识别具有更优的泛化性能。

这一优势可能归因于 PSO-WELM 模型的双重优化机制:一方面,该模型能够有效学习多数类样本的特征;另一方面,其对少数类样本施加更高的错分惩罚权重,从而增强模型对少数类的识别能力,最终降




图 1 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下,PSO-WELM 模型和对比模型的 RMSE 对比图

低整体泛化误差。

图 2 为中湍流强度 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下 PSO-WELM 模型和 3 种对比模型在测试集上的 G-mean 值对比图。可以看出,PSO-WELM 模型具有最高的 G-mean 值,其值为 0.971 15。相较于 SVM、DL、BP-ANN 模型分别高出 0.025 77、0.027 44、0.024 69。结果表明 PSO-WELM 模型相较于对比模型,能够更好地权衡分类中湍流下的少数类、多数类 LG 光束。这是因为 WELM 在尽量保持多数类分类准确率的基础上,提高了少数类的分类准确率。同时,PSO 算法对 WELM 的优化进一步强化了模型的整体性能,最终提高了 G-mean 值。

图 3 为中湍流强度 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下 PSO-WELM 模型和 3 种对比模型在测试集上的 ROC 曲线图。可以




图 2 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下,PSO-WELM 模型和对比模型的 G-mean 值对比图




图 3 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下,PSO-WELM 模型和对比模型的 ROC 曲线图

看出,PSO-WELM 模型的 ROC 曲线最靠近左上角、几乎始终位于对比模型 ROC 曲线的左上方,说明 PSO-WELM 模型有着更好的分类性能。图中 ROC 曲线对应的面积(AUC)值如表 2 所示。可以看出,4 种模型的 AUC 值相差不大,但 PSO-WELM 模型的 AUC 值依然最高(0.998 38)。由此可以进一步看出 PSO-WELM 模型相较于对比模型在识别受中湍流影响的少数类和多数类 LG 光束上,有着更好的分类效果。这可能因为利用 PSO 算法优化 WELM,可以在更广泛的参数空间中找到最优的输入权重和偏置,从而稳定并提升了 WELM 的分类性能。

表 2 $C_n^2=7\times 10^{-15} \text{ m}^{-2/3}$ 下 PSO-WELM 模型和对比模型的 AUC 值

模型	AUC
SVM	0.996 06
DL	0.996 66
BP-ANN	0.994 39
PSO-WELM	0.998 38

图 4 为较弱湍流强度 $C_n^2=7\times 10^{-16} \text{ m}^{-2/3}$ 下 PSO-WELM 模型和 3 种对比模型在测试集上的 G-mean 值对比图。其中 SVM 模型的 G-mean 值为 0.942 81,DL、BP-ANN、PSO-WELM 模型的 G-mean 值均为 1,由此可知,DL、BP-ANN、PSO-WELM 模型对于识别较弱湍流下的少数类、多数类 LG 光束的准确率均为 100%。

图 5 为较强湍流强度 $C_n^2=7\times 10^{-14} \text{ m}^{-2/3}$ 下 PSO-WELM 模型和 3 种对比模型在测试集上的 G-mean 值对比图,




图 4 $C_n^2=7\times 10^{-16} \text{ m}^{-2/3}$ 下,PSO-WELM 模型和对比模型的 G-mean 值对比图




图 5 $C_n^2=7\times 10^{-14} \text{ m}^{-2/3}$ 下,PSO-WELM 模型和对比模型的 G-mean 值对比图

其中 SVM、DL、BP-ANN、PSO-WELM 模型的 G-mean 值分别为 0.697 39、0.369 57、0.348 66、0.715 90。这是因为在较强湍流强度下,接收光斑的强度分布弥散得较为严重,进而为模型识别少数类、多数类 LG 光束带来较大影响。此时,虽然 PSO-WELM 模型识别少数类、多数类 LG 光束的 G-mean 值高于对比方法,但 G-mean 值仍较低。

3 结束语

本文就不平衡 LG 光束少数类、多数类识别问题,提出了 PSO-WELM 模型。该模型通过 WELM 为少数类样本赋予更高的错分代价,并采用 PSO 算法优化 WELM 的输入权重和隐藏层偏置参数。实验结果表明:在较弱湍流强度下,PSO-WELM 模型的 G-mean 值达到 1;在中湍流强度下,其 RMSE 值为 0.1,G-mean 值为 0.971 15,AUC 值为 0.998 38,验证了该方法用于不平衡 OAM 光束识别的可行性。与 SVM、DL 和 BP-ANN 模型相比,PSO-WELM 模型在中湍流条件下的各项评价指标均表现更优,展现出更好的分类性能,为不平衡 OAM 光束识别提供了有效解决方案。然而,在强湍流条件下,PSO-WELM 模型对少数类和多数类 LG 光束的识别性能仍有提升空间。未来的研究可进一步优化 WELM 模型结构,从而提升该模型在强湍流环境下对不平衡 OAM 光束的识别性能。

参考文献:

- [1] 谢炎辰,梁静远,丁德强,等. 无线光通信系统轨道角动量技术研究进展[J]. 激光与光电子学进展,2023,60(21):58-99.

梁瑞悦,于海洋,陈纯毅,等. 基于 PSO-WELM 的不平衡 OAM 识别模型研究

- [2] SINHA S, KUMAR C, ARMUGHAN A, et al. Simulative investigation of the hybrid, spatially multiplexed MIMO-FSO transmission system under atmospheric turbulence[J]. IEEE Access, 2023(11): 55071–55080.
- [3] 姜楠,李晓英,牛春晖,等. 大气湍流对激光空间传输特性影响的实验研究[J]. 激光技术, 2022, 46(5): 708–712.
- [4] 于淼,王雅秋,张鹤,等. 改进的马赫-曾德尔干涉仪测量涡旋光束的轨道角动量[J]. 激光与光电子学进展, 2022, 59(17): 87–93.
- [5] 吴鹏飞,王小蝶,王姣,等. 间隔轨道角动量的复合涡旋光束编/解码[J]. 光学学报, 2023, 43(11): 257–264.
- [6] GRUNWALDR, BOCK M. Characterization of orbital angular momentum beams by polar mapping and Fourier transform[J]. Photonics, 2024, 11(4): 296–1–296–15.
- [7] SUN R, GUO L, CHENG M, et al. Identifying orbital angular momentum modes in turbulence with high accuracy via machine learning[J]. Journal of Optics, 2019, 21(7): 075703–1–075703–10.
- [8] NA Y, KO D K. Adaptive demodulation by deep-learning-based identification of fractional orbital angular momentum modes with structural distortion due to atmospheric turbulence[J]. Scientific Reports, 2021, 11(1): 23505–1–23505–12.
- [9] 付鑫. 涡旋光大气湍流传输与基于深度学习的 OAM 测量[D]. 成都: 电子科技大学, 2022.
- [10] 宋芝依,金兆祥,王雨燕,等. 基于卷积神经网络的高阶复合 LG 光束的 OAM 模式识别[J]. 光通信技术, 2023, 47(4): 58–61.
- [11] 冯茜. 基于改进粒子群算法的多目标优化及其应用[D]. 北京: 北京科技大学, 2022.
- [12] ZONG W, HUANG G, CHEN Y. Weighted extreme learning machine for imbalance learning[J]. Neurocomputing, 2013, 101(1): 229–242.