

基于主成分分析和机器学习的激光水下尾流识别

王旭阳 陈伟

Laser recognition of underwater wakes based on principle component analysis and machine learning

WANG Xu-yang, CHEN Wei

引用本文:

王旭阳, 陈伟. 基于主成分分析和机器学习的激光水下尾流识别[J]. 中国光学, 优先发表. doi: 10.3724/CO.2026-0127

WANG Xu-yang, CHEN Wei. Laser recognition of underwater wakes based on principle component analysis and machine learning[J]. *Chinese Optics*, In press. doi: 10.3724/CO.2026-0127

在线阅读 View online: <https://doi.org/10.3724/CO.2026-0127>

您可能感兴趣的其他文章

Articles you may be interested in

基于同步累积法的舰船尾流微弱信号检测方法研究

Detection method of weak ship wake signals based on the synchronous accumulation method

中国光学 (中英文). 2024, 17(6): 1272 <https://doi.org/10.37188/CO.2024-0014>

基于回声状态网络的空间激光干涉低跟踪重力卫星数据恢复方法研究

Echo state network-based data recovery method for low-low satellite-to-satellite tracking missions in laser interferometry

中国光学 (中英文). 2025, 18(3): 641 <https://doi.org/10.37188/CO.2024-0177>

舰船尾流气泡目标激光后向散射特性研究

Laser backscattering characteristics of ship wake bubble target

中国光学 (中英文). 2023, 16(6): 1333 <https://doi.org/10.37188/CO.2023-0043>

基于主成分分析法的大气湍流相位畸变表征和还原影响因素分析

Influencing factor of the characterization and restoration of phase aberrations resulting from atmospheric turbulence based on Principal Component Analysis

中国光学 (中英文). 2025, 18(4): 899 <https://doi.org/10.37188/CO.EN-2024-0035>

利用改进互相关算法的游标效应光纤应变传感器解调方法

Demodulation of Vernier-effect-based optical fiber strain sensor by using improved cross-correlation algorithm

中国光学 (中英文). 2025, 18(6): 1463 <https://doi.org/10.37188/CO.EN-2025-0024>

复杂水文微弱多目标激光探测仿真与实验

Simulation and experiment of weak multi-target laser detection in complex hydrology

中国光学 (中英文). 2024, 17(3): 560 <https://doi.org/10.37188/CO.2023-0141>

基于主成分分析和机器学习的激光水下尾流识别

王旭阳, 陈 伟*

(国防科技大学 气象海洋学院, 湖南 长沙 410073)

摘要: 为了实现对水下尾流的识别, 本研究结合主成分分析(PCA)和不同的机器学习方法, 使用激光前向传输信号特性对不同尾流进行识别。在处理前向传输的光信号时, 首先计算时域和频域特征, 再使用主成分分析对原始特征进行降维, 最后通过机器学习处理降维后的特征, 实现在水槽条件下不同水下推进器尾流的识别。同时, 湖上试验也验证了该方法在实际应用中的可行性。结果表明, 在水槽条件下, 表现最优的机器学习方法为支持向量机(SVM), 综合准确率为 89.93%。而在湖上试验中, K 近邻(KNN)和随机森林(RF)的识别性能更为优秀, 综合准确率分别为 96.39% 和 96.25%。随着尾流强度的改变和推进器类型的增加, 不同尾流的差异程度逐渐减小, PCA 特征边界出现混淆。此外, 信号的时域特征和频域特征对不同识别任务的重要性具有显著差异。实验研究和湖上试验结果均说明该方法可以有效实现对不同水下尾流的识别。

关键词: 激光探测; 尾流; 机器学习; 前向散射

中图分类号: P733.3

文献标志码: A

doi: 10.3724/CO.2026-0127

CSTR: 32171.14.CO.2026-0127

Laser recognition of underwater wakes based on principle component analysis and machine learning

WANG Xu-yang, CHEN Wei*

(College of Meteorology and Oceanography, National University of Defense Technology,
Changsha, Hunan 410037, China)

* Corresponding author, E-mail: kevinkobegames@126.com

Abstract: To achieve the recognition of underwater wakes, this study integrates principal component analysis (PCA) with various machine learning methods to classify different types of wakes using the characteristics of forward-propagated laser signals. In processing the forward-propagated optical signals, time-domain and frequency-domain features are first computed, followed by dimensionality reduction of the original features via PCA. The reduced features are then fed into machine learning classifiers to distinguish wakes generated by different underwater thrusters under tank conditions. Furthermore, lake test validates the practical feasibility of the proposed method. Results indicate that under tank conditions, the optimal machine learning method is support vector machine (SVM), achieving a accuracy of 89.93%. Whereas in the lake test, the optimal methods are k-nearest neighbors (KNN) and random forest (RF), with accuracies of 96.39% and 96.25% respectively. As the wake intensity varies and the number of thruster types increases, the inter-wake dissimilarity de-

收稿日期: xxxx-xx-xx; 修订日期: xxxx-xx-xx

基金项目: 无

xxxx

creases, and the PCA feature boundaries become blurred. Additionally, the importance of time-domain versus frequency-domain features differs significantly across classification tasks. Both experimental and lake test results demonstrate that the proposed method can effectively discriminate among different underwater wakes.

Key words: laser detection; wakes; machine learning; forward scattering

1 引言

舰船和水下航行器在航行时会产生湍流和大量的气泡群,从而形成尾流^[1]。尾流携带了舰船和水下航行器的相关信息。由于螺旋桨工况和航速的不同,水下尾流的气泡尺度、气泡密度、气泡层厚度等特性存在明显的差异性^[1-3]。因此,水下尾流的精确探测对于航行器状态监控及跟踪等应用具有重要的意义。

传统的尾流探测识别方法包括流体动力学模拟和基于声学、光学的物理传感器测量技术,激光探测技术凭借其高灵敏度和高分辨率的特点成为尾流探测的重要手段^[4-5]。然而,水下环境的复杂性、多变性和不可预测性使得传统方法在实时性和准确性方面面临挑战^[6]。在激光探测技术中,闪烁因子(SI)和相对光强常常用于表征尾流的强弱^[7-10],但却无法用于准确判断产生尾流的目标类型。

近年来,机器学习技术快速发展,并被广泛应用于图像识别和信号分类,为水下尾流的激光探测提供了新的思路^[11-12]。通过主成分分析(PCA)^[1]和独立成分分析(ICA)^[13]等方法对尾流信号进行预处理和特征提取,可以有效降低信号特征维度,提高信号质量,从而提高机器学习的性能。已有的研究表明,实验条件下可以通过 PCA 和机器学习对不同的水下尾流进行有效的探测和识别^[14]。同时,尾流中的气泡群是对激光探测信号产生影响的主要因素,目前的研究大多集中于气泡群对激光传输特性的影响^[15-17],对于实际应用场景中的水下尾流激光前向探测关注较少。从复杂的尾流激光信号中提取对不同目标具有区分能力的特征,并通过机器学习方法进行识别,仍然是一个有待解决的问题。

基于激光的前向传输信号特性,本研究在实验室水槽条件下对不同尾叶数量螺旋桨产生的尾流进行探测,综合考虑水下推进器尾流对光学信号的影响,使用 PCA 方法对信号特征进行提取,对比了不同机器学习方法以及时域和频域特征对

目标尾流的识别结果,并通过湖上试验验证了该方法的可行性。

2 基本原理

本研究使用的数据为激光前向传输光信号,通过计算得到原始的时域和频域特征,再使用主成分分析方法减少原始特征中的冗余信息,实现特征降维,最后基于不同的机器学习方法使用降维后的特征数据进行尾流识别。

2.1 主成分分析

主成分分析是一种使用广泛的数据降维方法,可以消除特征的冗余性,提高机器学习的性能。设原始数据集包含 n 个样本,每个样本有 p 个特征,主成分分析的基本步骤如下:

(1)对特征矩阵 $\mathbf{X} \in \mathbb{R}^{n \times p}$ 进行数据标准化,得到矩阵 $\tilde{\mathbf{X}}$;

$$\tilde{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}, i = 1, 2, \dots, n; j = 1, 2, \dots, p, \quad (1)$$

其中, s_j 为第 j 个特征的标准差。

(2)由矩阵 $\tilde{\mathbf{X}}$ 计算协方差矩阵 $\mathbf{C} \in \mathbb{R}^{p \times p}$;

$$\mathbf{C} = \frac{1}{n-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}. \quad (2)$$

(3)对协方差矩阵 $\mathbf{C}$ 进行特征值分解,得到 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ 和对应的单位特征向量 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p$;

(4)选取主成分;

第 k 个主成分的方差贡献率 η_k 为

$$\eta_k = \frac{\lambda_k}{\sum_{j=1}^p \lambda_j}, \quad (3)$$

前 m 个主成分的累计方差贡献率 τ_m 为

$$\tau_m = \frac{\sum_{k=1}^m \lambda_k}{\sum_{j=1}^p \lambda_j}, \quad (4)$$

选取使得累计贡献率 τ_m 达到 95% 的前 m 个主成分作为新的特征。

(5) 数据投影与降维。

前 m 个单位特征向量组成投影矩阵 $\mathbf{W} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_m]$, 降维后的特征矩阵 $\mathbf{Z} \in \mathbb{R}^{n \times m}$ 为

$$\mathbf{Z} = \tilde{\mathbf{X}}\mathbf{W} \quad (5)$$

2.2 机器学习方法

本研究使用了 4 种常用的机器学习方法对降维后的特征数据进行处理, 分别是随机森林 (RF)、朴素贝叶斯 (NB)、K 近邻 (KNN) 和支持向量机方法 (SVM)。随机森林通过集成多棵决策树进行投票分类, 朴素贝叶斯基于贝叶斯定理与特征条件独立假设计算后验概率, K 近邻依据样本间距离度量进行多数表决, 支持向量机则通过构建最大化间隔的超平面实现类别划分。

为了准确评估各模型的性能, 在训练模型时使用了分层交叉验证方法。分层交叉验证方法可以防止因随机划分导致的类别分布不均, 从而获得更可靠、偏差更小的性能评估结果, 对于多类别分类问题尤其重要。本研究将数据集随机划分为 10 个子集, 依次使用其中 1 个子集作为测试集, 其余子集作为训练集, 最终取 10 次测试结果的平均值代表模型的性能, 并比较不同方法在处理尾流识别问题时的适用性。数据处理流程如图 1 所示。




图 1 数据处理流程图

Fig. 1 Data processing flowchart

3 实验与讨论

3.1 实验平台和数据

3.1.1 实验平台

本研究在实验室水槽条件下模拟了水下推进器的尾流区域。图 2 和图 3 分别为实验平台和探测光路示意图, 图 4 为实验中使用的不同水下推进器。




图 2 实验平台

Fig. 2 Experimental platform




图 3 探测光路示意图

Fig. 3 Schematic of the detection light path




图 4 水下推进器

Fig. 4 Underwater propellers

如图 2 所示, 实验平台的主体是一个 $1.5 \text{ m} \times 0.35 \text{ m} \times 0.3 \text{ m}$ 的水槽。在水槽一端放置功率为 15 mW 的 520 nm 激光二极管 (LP520-SF15) 和准直器 (CFS18-532-FC), 另一端放置硅探测器 (PDA36A2), 并在探测器前布置一个焦距为 $f = 35 \text{ mm}$ 的凸透镜和对应波长的滤光片。水槽中央为水下推进器的尾流区域。如图 4 所示, 本研究使用的水下推进器为三叶、四叶和五叶螺旋桨。

3.1.2 实验数据

实验采集的数据为激光前向传输的光强时域信号, 采样频率为 20 KS / s。依次使用三叶、四叶和五叶螺旋桨, 调整推进器的推力和转速, 通过

闪烁因子判断尾流的强弱,从而对每一类螺旋桨分别制造不同强度的尾流,分别采集 300 组数据。使用光强 I 计算闪烁因子 SI 的方法如下式所示。

$$\sigma_I^2 = \frac{\langle I^2 \rangle - \langle I \rangle^2}{\langle I \rangle^2}, \quad (6)$$

SI 随着尾流强度增大而增大, SI 小于 0.01 为弱尾流, SI 大于 0.01 且小于 0.50 为中强度尾流, SI 大于 0.50 为强尾流。在相似的螺旋桨工况条件下,实验使用的五叶桨排量明显大于三叶桨和四叶桨,排量过大导致了尾流强度增大,五叶桨尾流的 SI 均大于 0.01。

此外,当 SI 大于 2.00 时,继续增大尾流强度将会引起 SI 减小的异常现象,出现异常尾流^[18]。图 5 为五叶桨强尾流和异常尾流的光信号,过强的尾流导致激光严重衰减,接收光强维持在较低水平。同时,接收光强随着尾流强度间歇性的减弱而出现增强现象,总体信号波动程度远小于正常情况,从而引起 SI 减小的异常现象。该现象进一步表明,仅使用传统的光学参数无法有效区分不同尾流,需要引入机器学习进行更深入的研究。




图 5 五叶桨强尾流和异常尾流的光信号

Fig. 5 Optical signal of 5-Blade intense and abnormal wake

3.1.3 时域和频域特征

实验数据的原始特征共 23 维,由 13 维时域特征和 10 维频域特征构成。时域特征均使用相对光强进行计算,频域特征则直接采用各频段能量占总能量的比值。

时域特征包括相对光强的均值、标准差、偏度、峰度、均方根等特征,可以根据性质分为两类。I 类是直接统计量,II 类是计算统计量,具体

如表 2 所示。根据前期的研究结果^[4],频域的有效信息集中在低频段。本研究将 0-500 Hz 频段作为研究重点,将其平均划分为 10 个子频段分别计算能量占比。

表 1 实验数据的时域特征

Tab. 1 Time-domain features of experimental data

时域特征类型	I 类	II 类
特征名称	均值	标准差
	最大值	偏度
	最小值	峰度
	范围	均方根
	第一四分位数	绝对中位差
	中位数	四分位距
	第三四分位数	\

表 2 使用不同时域特征的识别结果

Tab. 2 Classification results using different time-domain features

机器学习方法	时域特征识别准确率		
	I 类	II 类	I 类 + II 类
RF	84.63%	86.41%	87.48%
NB	74.19%	73.70%	77.22%
KNN	85.11%	84.81%	86.59%
SVM	84.70%	88.26%	89.93%

注:识别时同时使用了频域特征。

3.2 实验结果

本研究使用的 4 种机器学习方法中, SVM、RF 和 KNN 均表现优异, NB 的识别性能随着识别难度的增大出现显著下降。图 6 为不同条件下的各方法识别结果。

图 6(a) 对同一类型推进器(以四叶桨为例)的尾流进行识别时,4 种方法的综合准确率均达到 95% 以上。图 6(b) 对不同类型推进器产生的相同强度尾流(SI 的范围为 0.015 ± 0.001)进行识别时, NB 的准确率出现明显下降,其余方法的性能保持稳定。NB 对四叶桨尾流的识别准确率仅有 80.00%, 而 SVM 和 KNN 的准确率分别为 98.00% 和 96.33%。

图 6(c) 对不同类型推进器的不同强度尾流进行识别时,4 种方法的综合准确率均出现了下

降, SVM、RF、KNN、NB 的综合准确率依次为 89.93%、87.48%、86.59%、77.22%。从各类型尾流的识别结果来看, SVM、RF 和 KNN 在大多数情况下依然保持着良好的识别性能。其中, 五叶

桨强尾流的识别结果最好, 而三叶桨弱尾流的光学特征变化微弱, 导致识别存在困难, 即使是综合表现最优的 SVM, 识别准确率也仅有 66.67%。




图 6 不同条件下各方法的识别结果。(a)不同强度的四叶桨尾流;

Fig. 6 The classification results of methods under different conditions.


(b)不同推进器类型的中强度尾流;(c)不同推进器类型和强度的尾流

(a) wakes with different intensities generated by 4-blade propeller; (b) wakes with moderate intensity generated by different propellers; (c) wakes with different intensities generated by different propellers

图 7 给出了不同情况下各类型尾流在 PCA 特征空间中的分布。随着尾流强度的改变和推进器类型的增加, 不同尾流的差异程度逐渐减小, 在 PCA 特征空间中的重叠程度加剧, 边界发生混淆。

图 7(a) 中, 不同尾流强度的样本形成了各自

的聚类, 类间界限清晰。图 7(b) 中, 不同类型推进器产生的尾流样本已经逐渐发生重叠。而图 7(c) 中, 只有五叶桨强尾流的样本高度聚集, 三叶桨弱尾流的样本穿插于其他类别的分布区域, 造成了不同尾流边界的严重混淆。






图 7 不同条件下的 PCA 特征空间散点图。(a)不同强度的四叶桨尾流;

Fig. 7 PCA feature space scatter plot under different conditions.

(b)不同推进器类型的中强度尾流; (c)不同推进器类型和强度的尾流

(a) wakes with different intensities generated by 4-blade propeller; (b) wakes with moderate intensity generated by different propellers; (c) wakes with different intensities generated by different propellers

3.3 分析与讨论

3.3.1 不同特征域对识别结果的影响

为了探究不同特征域对识别结果的影响, 在前述的 3 种情况下分别仅使用时域特征或频域特

征进行机器学习, 并将识别结果与使用全部特征的结果进行对比, 综合准确率的变化情况如图 8 所示。




图 8 仅使用时域特征和频域特征时的识别结果。(a)不同强度的四叶桨尾流;

Fig. 8 Classification results using time-domain and frequency-domain features respectively.

(b)不同推进器类型的中强度尾流; (c)不同推进器类型和强度的尾流

(a) wakes with different intensities generated by 4-blade propeller; (b) wakes with moderate intensity generated by different propellers; (c) wakes with different intensities generated by different propellers

在所有的情况下, 仅使用单一特征域对应的准确率变化都为负值, 即都导致了识别准确率的降低。而在不同的情况下, 时域特征和频域特征的重要性存在显著差异。图 8(a) 对四叶桨尾流进行识别, 时域特征的准确率优于频域特征, 说明时域特征包含了更多的有效信息, 在尾流强度的识

别任务中更为重要。图 8(b) 对不同推进器类型的尾流进行识别, 结果则恰好相反, 频域特征的重要性大于时域特征。

图 8(c) 对不同推进器类型和强度的尾流进行识别, 单一特征域导致所有方法的识别性能显著下降。时域特征的结果仍然明显优于频域特征,

在复杂识别任务中具有主导性的贡献。只使用频域特征时, 准确率均降低 30% 以上, 识别性能基本失去可靠性, 说明频域特征存在提取不充分的问题。随着尾流强度的改变和推进器类型的增加, 不同尾流的频域能量分布差异减小。对 0-500 Hz 频段进行均分并计算各自的能量占比, 不能有效表征类别间的差异, 是导致图 7 特征空间中不同尾流边界混淆的重要原因。

3.3.2 不同时域特征对识别结果的影响

为了进一步探究不同时域特征对识别结果的影响, 表 2 汇总了不同推进器类型和强度尾流情况下, 单独使用 I 类时域特征或 II 类时域特征的识别结果, 并与同时使用 I 类和 II 类时域特征的结果进行对比。

仅使用 I 类时域特征或 II 类时域特征时, 各方法的识别准确率均出现降低, 准确率降低最多的方法分别为 SVM 和 NB, 两者分别降低了 5.23% 和 3.52%。这说明 I 类时域特征对 NB 更重要, 而 II 类时域特征对 SVM 更重要。图 8 和表 2 的对比结果表明, 虽然不同特征域对尾流强度和推进器类型识别任务的重要性不同, 但单一特征域和单一类别的时域特征在识别时均具有一定的局限性, 结合时域和频域特征可以更有效地描述尾流特性, 提高识别性能。

4 湖上试验

本研究在湖上环境中选取了两艘工况不同的船只作为探测目标, 如图 9(a)(b) 所示。目标船只 1 和船只 2 分别为电动船和燃油船, 两艘目标船只的尾流在影响范围、持续时间、气泡尺寸和数密度等方面具有较大差异。图 9(c) 为湖上试验的探测设备, 发射端和接收端固定并对准, 目标船只尾流经过二者之间时采集数据, 探测原理与实验相同, 采样频率为 30 KS /s, 分别采集 42 组数据。

图 10 给出了湖上试验两艘目标船只和实验研究中四叶桨尾流信号的频域曲线, 目标船只的频域曲线相似程度较高, 难以直接区分, 且频带能量主要集中在 0-10 Hz, 与实验研究中的四叶螺旋桨曲线存在明显差异。同时, 针对可能存在的频域能量分布差异不明显问题, 在提取湖上测试数据的频域特征时, 对频带划分进行了调整, 以

0.5 Hz 和 10 Hz 为带宽, 分别将 0-10 Hz 和 10-100 Hz 频段分为 20 个和 9 个子频带。




图 9 湖上试验的目标船只和设备
Fig. 9 Detection targets and device of lake test




图 10 归一化的平均频域曲线
Fig. 10 Normalized average frequency curve

表 3 的湖上试验结果表明, 通过对船只尾流的激光探测和识别, 该方法有效地区分了两艘目标船只。4 种机器学习方法均表现出良好的识别性能, KNN、RF、NB 和 SVM 的综合识别准确率依次为 96.39%、96.25%、93.89% 和 90.14%。KNN 和 RF 的识别性能相近, 且识别准确率达到 95% 以上, 而 SVM 则相对表现较差。

表 3 湖上试验测试结果

Tab. 3 Classification results of lake test

机器学习方法	目标1 识别准确率	目标2 识别准确率	综合准确率
RF	97.50%	95.00%	96.25%
NB	95.00%	92.50%	93.89%
KNN	95.50%	97.50%	96.39%
SVM	85.50%	95.00%	90.14%

实验研究中对三叶桨和四叶桨采集了弱、中、强三种强度的尾流数据,对五叶桨采集了中、强、异常三种强度的尾流数据,每种情况采集了 300 组数据。而湖上实验对两艘目标船只尾流各采集了 42 组数据。

尾流中的气泡是影响接收光信号的主要因素,气泡的散射作用导致接收端相对光强发生起伏。在湖上试验的环境中,风浪、水流等环境因素难以对水下的目标尾流气泡条件造成影响,也就不会掩盖不同目标尾流的特征差异。

尽管湖上环境的干扰和变量远多于实验环境,但是两艘目标船只工况的不同,尤其是尾流气泡特性的不同,导致其尾流信号的特征存在明显差异。即便湖上试验的数据样本较少,KNN 和 RF 的识别准确率仍然很高。而在水槽实验中,随着尾流强度的改变和推进器类型的增加,不同尾流的特征差异程度逐渐减小,SVM 的性能优于 KNN 和 RF,KNN 和 RF 的适用性减弱。

参考文献:

- [1] 张银波,李思宁,姜鹏,等. PCA 特征提取和弹性 BP 神经网络的水下气泡识别[J]. *红外与激光工程*, 2021, 50(6): 209-215.
ZHANG Y B, LI S N, JIANG P, *et al.*. Underwater bubbles recognition based on PCA feature extraction and elastic BP neural network[J]. *Infrared and Laser Engineering*, 2021, 50(6): 209-215. (in Chinese).
- [2] 田恒斗,金良安,王涌,等. 考虑单气泡运动特性的舰船尾流气泡分布研究[J]. *兵工学报*, 2011, 32(9): 1126-1130.
TIAN H D, JIN L A, WANG Y, *et al.*. Study on wake bubble distribution based on single bubble motion characteristics[J]. *Acta Armamentarii*, 2011, 32(9): 1126-1130. (in Chinese).
- [3] 宗思光,张鑫,曹静,等. 舰船尾流激光探测跟踪方法与试验[J]. *红外与激光工程*, 2023, 52(3): 202205.
ZONG S G, ZHANG X, CAO J, *et al.*. Method and experiment of laser detection and tracking of ship wake[J]. *Infrared and Laser Engineering*, 2023, 52(3): 202205. (in Chinese).
- [4] 梁善勇,王江安,宗思光,等. 基于多重散射强度和偏振特征的舰船尾流气泡激光探测方法[J]. *物理学报*, 2013, 62(6): 060704.
LIANG SH Y, WANG J A, ZONG S G, *et al.*. Laser detection method of ship wake bubbles based on multiple scattering intensity and polarization characteristics[J]. *Acta Physica Sinica*, 2013, 62(6): 060704. (in Chinese).
- [5] 宗思光,段子科,张鑫,等. 基于同步累积法的舰船尾流微弱信号检测方法研究[J]. *中国光学(中英文)*, 2024, 17(6): 1272-1280.

5 结 论

本研究通过激光对尾流进行探测,并结合 PCA 和机器学习方法处理激光的前向传输光强信号,实现对尾流的识别。在实验条件下,随着尾流种类的增加,SVM、RF 和 KNN 的识别性能始终保持良好稳定,而 NB 的识别性能显著退化。针对复杂情况,SVM 的综合准确率最高,为 89.93%。在湖上试验中,KNN 和 RF 的识别性能最佳,综合准确率分别为 96.39% 和 96.25%,SVM 相对表现较差,但综合准确率仍然达到 90.14%。总体而言,该方法可以有效地探测并识别不同尾流,具有实际应用价值。

同时,时域特征和频域特征对不同识别任务的贡献具有显著差异,时域特征对尾流强度的识别更重要,频域特征则对尾流推进器类型的识别更重要。在情况复杂的识别任务中,仅使用单一类型特征无法充分描述尾流特性,不足以取得有效的识别结果。

PCA 对信号特征的处理结果表明,随着尾流强度的改变和推进器类型的增加,不同尾流的差异程度逐渐减小,频域特征的提取不充分导致了 PCA 特征空间中的边界混淆问题。湖上试验根据实际情况对频域特征提取进行了调整,后续的工作中将考虑对频域特征提取进行更深入的研究。

- ZONG S G, DUAN Z K, ZHANG X, *et al.*. Detection method of weak ship wake signals based on the synchronous accumulation method[J]. *Chinese Optics*, 2024, 17(6): 1272-1280. (in Chinese).
- [6] 刘昱, 李永胜, 刘礼文, 等. 基于时频分析和迁移学习的舰船尾流检测方法[J]. *水下无人系统学报*, 2022, 30(4): 465-473.
- LIU G, LI Y SH, LIU L W, *et al.*. Method of ship wake detection based on time-frequency analysis and transfer learning[J]. *Journal of Unmanned Undersea Systems*, 2022, 30(4): 465-473. (in Chinese).
- [7] 吴鹏飞, 胡田田, 王姣, 等. 拉盖尔-高斯涡旋光束经混合海洋介质相位屏传输的闪烁因子[J]. *激光与光电子学进展*, 2024, 61(15): 1501002.
- WU P F, HU T T, WANG J, *et al.*. Scintillation index of Laguerre-Gaussian vortex beam propagation through an ocean mixed-medium phase screen[J]. *Laser & Optoelectronics Progress*, 2024, 61(15): 1501002. (in Chinese).
- [8] 卢腾飞, 刘永欣, 吴志军. 涡旋光束在不同盐度的水下湍流中的传输特性的实验研究 (英文)[J]. *中国光学*, 2022, 15(1): 111-118.
- LU T F, LIU Y X, WU ZH J. Experimental investigation on propagation characteristics of vortex beams in underwater turbulence with different salinity[J]. *Chinese Optics*, 2022, 15(1): 111-118.
- [9] KHAMEES H T, ALGBURI S, KOTB H E. Computation of the scintillation index and BER of super Lorentz Gaussian laser beam in a slant propagation at atmospheric turbulence[J]. *Ain Shams Engineering Journal*, 2025, 16(3): 103295.
- [10] 项玉龙, 陈伟. 气泡散射影响下的水下光传输特性研究[J]. *红外与激光工程*, 2024, 53(12): 202403.
- XIANG Y L, CHEN W. Research on underwater light transmission characteristics under influence of bubbles scattering[J]. *Infrared and Laser Engineering*, 2024, 53(12): 202403. (in Chinese).
- [11] 邱琳琳, 朱卫纲, 李永刚, 等. 基于深度学习的 SAR 图像目标检测综述[J]. *兵工自动化*, 2026, 45(3): 72-76.
- QIU L L, ZHU W G, LI Y G, *et al.*. Survey of SAR image target detection based on deep learning[J]. *Ordnance Industry Automation*, 2026, 45(3): 72-76. (in Chinese).
- [12] 杨长生, 苟文博, 梁红. 基于一维卷积神经网络的舰船尾流检测[J]. *水下无人系统学报*, 2023, 31(6): 839-846.
- YANG CH SH, GOU W B, LIANG H. Ship wake detection based on one-dimensional convolutional neural network[J]. *Journal of Unmanned Undersea Systems*, 2023, 31(6): 839-846. (in Chinese).
- [13] 王振, 樊超阳, 杨苏辉, 等. 独立成分分析方法在水下激光雷达中的应用[J]. *光学学报*, 2024, 44(18): 1801002.
- WANG ZH, FAN CH Y, YANG S H, *et al.*. Application of independent component analysis method in underwater lidar[J]. *Acta Optica Sinica*, 2024, 44(18): 1801002. (in Chinese).
- [14] WANG X Y, CHEN W. Classification of underwater propeller wakes based on machine learning[J]. *Journal of Physics: Conference Series*, 2026, 3178: 012035.
- [15] 唐勤, 张宇. 激光探测尾流微气泡的偏振特性研究[J]. *红外与激光工程*, 2020, 49(1): 010500.
- TANG M, ZHANG Y. Research on polarization characteristics of micro-bubbles laser detection in wake[J]. *Infrared and Laser Engineering*, 2020, 49(1): 010500. (in Chinese).
- [16] 宗思光, 张鑫, 杨劲鹏, 等. 舰船尾流气泡目标激光后向散射特性研究[J]. *中国光学 (中英文)*, 2023, 16(6): 1333-1342.
- ZONG S G, ZHANG X, YANG SH P, *et al.*. Laser backscattering characteristics of ship wake bubble target[J]. *Chinese Optics*, 2023, 16(6): 1333-1342. (in Chinese).
- [17] 焦贵金, 张建生, 闫林波, 等. 尾流气泡幕对激光的传输特性研究[J]. *水下无人系统学报*, 2024, 32(5): 833-838.
- JIAO G J, ZHANG J SH, YAN L B, *et al.*. Laser transmission characteristics of wake bubble curtain[J]. *Journal of Unmanned Undersea Systems*, 2024, 32(5): 833-838. (in Chinese).
- [18] JAMALI M V, KHORRAMSHAHI P, TASHAKORI A, *et al.*. Statistical distribution of intensity fluctuations for underwater wireless optical channels in the presence of air bubbles[C]. *2016 Iran Workshop on Communication and Information Theory (IWCIT)*, IEEE, 2016: 1-6.

作者简介:

王旭阳 (2002—), 男, 江苏南京人, 硕士, 主要从事海洋光学方面的研究。E-mail: xuyangwang24@126.com 联系方式: 18013015727