

基于 SHAP 和 LightGBM 的云平台任务终止状态预测研究

李为丽¹, 张妮¹, 赵胜杰², 赵大卫³

1. 河南科技职业大学, 河南 周口 466000

2. 华北水利水电大学, 河南 郑州 450000

3. 国网河南省电力公司周口供电公司, 河南 周口 453003

DOI: 10.61369/TACS.2025120046

摘 要 : 随着云计算技术的广泛应用, 云平台任务调度的稳定性与可靠性成为影响服务质量的关键因素。任务异常终止会导致资源浪费、服务中断等问题, 而传统任务终止预测模型多存在可解释性差的缺陷, 难以精准定位终止诱因。本文提出一种基于 SHAP (SHapley Additive exPlanations) 的云平台任务终止状态分析方法, 通过构建 LightGBM 任务终止预测模型, 结合 SHAP 值对模型预测结果进行解释。首先采集云平台任务运行数据, 提取任务特征、资源特征及环境特征; 其次训练预测模型并利用 SHAP 值量化各特征对任务终止的影响程度; 最后通过实验验证方法的有效性。研究表明, 该方法不仅能实现较高的任务终止预测精度, 还能清晰揭示关键影响特征及作用机制, 为云平台任务调度优化与故障预警提供可靠依据。

关 键 词 : SHAP 值; 云平台; 任务终止; 预测模型; 特征解释; LightGBM

Research on Predicting Task Termination Status in Cloud Platforms Based on SHAP and LightGBM

Li Weili¹, Zhang Ni¹, Zhao Shengjie², Zhao Dawei³

1. Henan Vocational University of Science and Technology, Zhoukou, Henan 466000

2. North China University of Water Resources and Electric Power, Zhengzhou, Henan 450000

3. Zhoukou Power Supply Company, State Grid Henan Electric Power Company, Zhoukou, Henan 453003

Abstract : With the widespread application of cloud computing technology, the stability and reliability of cloud platform task scheduling have become key factors affecting service quality. Abnormal task termination may lead to resource waste, service interruption and other issues. However, traditional task termination prediction models mostly suffer from poor interpretability, making it difficult to accurately locate the causes of termination. This paper proposes a cloud platform task termination state analysis method based on SHAP (SHapley Additive exPlanations). A LightGBM task termination prediction model is constructed, and the SHAP values are used to explain the model's prediction results. Firstly, the cloud platform task operation data are collected, and the task features, resource features and environmental features are extracted. Secondly, the prediction model is trained, and the SHAP values are used to quantify the impact of each feature on task termination. Finally, experiments are conducted to verify the effectiveness of the method. The research results show that this method can not only achieve high prediction accuracy of task termination, but also clearly reveal the key influencing features and their action mechanisms, providing a reliable basis for cloud platform task scheduling optimization and fault early warning.

Keywords : SHAP value; cloud platform; task termination; prediction model; feature explanation; LightGBM

引言

云平台通过虚拟化技术实现资源的动态分配与共享, 能够高效满足不同用户的任务处理需求。然而, 云平台任务运行过程中易受多种因素影响, 如资源竞争、网络波动、硬件故障、任务配置不合理等, 导致任务出现异常终止现象^[1]。

基于机器学习的方法 (如神经网络、随机森林等) 通过数据驱动构建预测模型, 预测精度有所提升, 但这类模型多属于“黑箱”模型^[2], 无法解释预测结果的形成原因, 难以帮助运维人员精准定位问题根源, 限制了模型在实际场景中的应用^[3]。如果不能从人类的角度对模型决策进行理解, 寻找更好的模型最终将沦为试错法, 这意味着我们需要理解模型背后的机制^[4]。

部分学者采用支持向量机、逻辑回归等传统机器学习算法构建预测模型，但模型解释性不足^[5]。近年来，随着可解释性人工智能的发展，有研究尝试将 LIME 等局部可解释方法应用于任务预测模型，但 LIME 仅能提供局部样本的解释，缺乏全局解释能力^[6]。

SHAP 作为一种基于沙普利值的可解释性方法，能够为任意机器学习模型提供全局与局部解释^[7]，已在医疗、金融等领域得到成功应用，但在云平台任务终止分析中的应用尚处于起步阶段。本文正是基于此，将 SHAP 方法引入云平台任务终止状态研究，实现预测精度与解释性的协同提升。

一、相关理论基础

（一）云平台任务终止机制

云平台任务从提交到完成需经历任务提交、资源分配、运行执行、结果返回四个阶段，任一阶段出现问题都可能导致任务终止^[8]。根据终止原因，任务终止可分为正常终止与异常终止两类，本文重点研究异常终止状态的影响因素与预测解释。

（二）SHAP 核心原理

SHAP 基于合作博弈论中的沙普利值（Shapley Value），通过量化每个特征对预测结果的边际贡献，实现对机器学习模型预测结果的可解释性分析^[9]。其核心思想是将模型预测结果分解为各特征的贡献之和，构建加性解释模型。SHAP 值的正负表示特征对预测结果的促进或抑制作用，绝对值大小表示影响程度。

（三）LightGBM 算法概述

LightGBM 是一种基于梯度提升决策树（GBDT）的集成学习算法，具有训练速度快、内存占用低、预测精度高的特点，适用于大规模数据处理场景^[10]。LightGBM 能够高效处理云平台任务的高维运行数据，适合作为任务终止预测的基础模型。

二、研究方法

本文提出的基于 SHAP 的云平台任务终止状态研究框架主要包括四个阶段：

1. 数据采集与预处理：采集云平台任务运行日志数据，进行数据清洗、缺失值填充、异常值处理等操作，构建标准化数据集；
2. 特征工程：从任务维度、资源维度、环境维度提取特征，通过特征筛选去除冗余特征，提升模型训练效率；
3. 预测模型构建：以 LightGBM 为基础，构建云平台任务终止预测模型，利用预处理后的数据集进行模型训练与参数优化；
4. SHAP 解释性分析：利用 Tree SHAP 计算各特征的 SHAP 值，从全局与局部两个层面分析特征对任务终止的影响，定位关键影响因素；
5. 优化建议：结合解释结果提出任务调度优化与故障预警策略。

三、实验结果与分析

（一）实验环境

实验硬件环境：CPU 为 Intel Core i7-12700H，内存为

32GB，硬盘为 1TB SSD；软件环境：操作系统为 Windows 10，编程语言为 Python 3.8。

（二）预测模型性能评估

将本文构建的 LightGBM 预测模型与逻辑回归（LR）、随机森林（RF）、XGBoost 三种常用算法进行对比实验，各模型在测试集上的性能指标如下：LightGBM 模型的准确率、精确率、召回率及 F1 值均优于其他对比模型，其中准确率与 F1 值分别达到 92.3% 与 91.7%。这表明 LightGBM 模型能够充分挖掘云平台任务数据的非线性特征，实现对任务终止状态的精准预测，为后续 SHAP 解释性分析提供可靠的模型基础。

（三）SHAP 全局解释分析

1. 全局特征重要性：通过 SHAP 摘要图对 16 个特征的重要性进行排序，结果显示，影响云平台任务终止的前 5 个关键特征依次为：内存使用率、节点负载率、CPU 使用率、网络延迟、预设运行时长。其中，内存使用率的 SHAP 值绝对值均值最大，是影响任务终止的核心因素，这与实际场景中内存不足易导致任务崩溃的认知一致。

2. 特征影响趋势：通过 SHAP 依赖图分析关键特征的影响趋势：当内存使用率低于 60% 时，SHAP 值多为负，对任务终止起抑制作用；当内存使用率超过 80% 时，SHAP 值迅速变为正且绝对值增大，任务终止风险显著提升；节点负载率与任务终止呈正相关，当节点负载率超过 70% 时，任务终止概率大幅增加；网络延迟对任务终止的影响存在阈值效应，当延迟低于 50ms 时影响较小，超过 100ms 后任务终止风险急剧上升。

（四）SHAP 局部解释分析

选取测试集中 3 个典型异常终止样本与 2 个正常终止样本，通过 SHAP 力导向图进行局部解释。以某异常终止样本为例，运行过程中内存使用率达到 89%，节点负载率为 78%，网络延迟为 120ms。结果显示，内存使用率（SHAP 值为 0.82）、节点负载率（SHAP 值为 0.65）及网络延迟（SHAP 值为 0.43）为主要促进因素，共同推动预测值偏离基线值，最终模型预测该任务为异常终止；而 CPU 核心数（SHAP 值为 -0.12）为抑制因素，略微降低了终止风险。该解释结果与样本实际运行情况吻合，验证了 SHAP 解释的准确性。

四、研究局限与未来展望

（一）研究局限

本文研究仍存在一定局限：首先，实验数据来源于单一公有云平台，样本类型与场景存在一定局限性，可能影响结论的通用

性；其次，模型仅针对任务终止状态进行预测与解释，未涉及终止后的故障恢复策略研究。

（二）未来展望

未来可进一步深化研究，扩大数据来源，采集多类型云平台的任务数据，提升模型的泛化能力，探索 SHAP 与深度学习模型的结合，提升对复杂任务场景的适应能力。

五、结论

本文提出一种基于 SHAP 的云平台任务终止状态研究方法，通过构建 LightGBM 预测模型与 SHAP 解释性分析相结合的技术框架，实现了对云平台任务终止状态的精准预测与深度解释。SHAP 方法能够有效量化各特征的影响程度，对提升云平台运行稳定性与服务质量具有重要意义。

参考文献

- [1] 代丽萍. 大规模云平台任务终止状态预测方法研究 [D]. 新乡：河南师范大学，2020.
- [2] 曾春艳，严康，王志锋，等. 深度学习模型可解释性研究综述 [J]. 计算机工程与应用，2021, 57(08): 1-9.
- [3] 化盈盈，张岱卿，葛仕明. 深度学习模型可解释性的研究进展 [J]. 信息安全学报，2020, 5(03): 1-12. DOI: 10.19363/j.cnki.cn10-1380/tn.2020.05.01.
- [4] Tjoa E, Guan C. A survey on explainable artificial intelligence: Toward medical [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(11): 4793-4813.
- [5] 潘梓豪，于福东，石新颖，等. 基于多种机器学习算法的东北地区潜在湿地分布模拟 [J]. 湿地科学，2025(3).
- [6] 黄丽冰. 深度学习模型的可解释性及其在医学影像分析应用中的研究进展 [J]. 桂林航天工业学院学报，2023, 28(01): 51-60.
- [7] Lundberg S M, Erion G, Chen H, et al. Explainable AI for trees: From local explanations to global understanding [J]. arXiv preprint, arXiv:1905.04610, 2019.
- [8] 刘春红，李为丽，焦洁，等. 一种可解释的云平台任务终止状态预测方法 [J]. 计算机研究与发展，2024, 61(03): 716-727.
- [9] 张磊. 面向工业控制系统入侵检测机器学习算法研究 [D]. 北京石油化工学院，2023.
- [10] 龚薇，王晶，任彦双，等. 基于机器学习算法对医学生心理健康影响因素分析 [J]. 宁夏医科大学学报，2025, 47(01): 69-75.