

基于软分类的直流充电桩故障预警方法

李芝娟¹, 吴丹², 雷珽², 王宁³, 段艳³, 马洪恩³

(1. 国网上海浦东供电公司, 上海 200122; 2. 国网上海市电力公司, 上海 200122;
3. 同济大学 汽车学院, 上海 201804)

摘要: 针对目前直流充电桩故障频发、维护不及时的问题, 提出一种基于软分类模型的直流充电桩故障预警方法。基于充电桩充电过程中的电流电压序列, 构建充电功率的差分序列, 结合充电过程中车端的荷电状态 (SOC) 序列作为该过程的充电特征, 与充电桩的基础信息共同作为故障识别模型的输入特征; 集成随机森林 (RF)、极端梯度提升 (XGBoost) 和 K 近邻 (KNN) 算法构建充电桩故障识别模型, 模型采用软分类方法计算充电桩的充电特征属于各类故障状态的概率值。通过设定预警阈值, 在充电桩发生故障的概率超过预警阈值时, 向相关维护人员发出预警信息。采用从车联网平台获取的直流充电桩数据进行验证, 结果表明, 该方法可对即将发生故障的直流充电桩进行预警, 预警的准确率和召回率满足要求, 验证了该方法的有效性和实用性, 该方法对直流充电桩的运维工作具有一定的实用价值。

关键词: 直流充电桩; 故障预警; 软分类; 集成模型

中图分类号: TM715 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqed24192

Fault Early Warning Method of DC Charging Pile Based on Soft Classification

LI Zhijuan¹, WU Dan², LEI Ting², WANG Ning³, DUAN Yan³, MA Hongen³

(1. State Grid Shanghai Pudong Electric Power Supply Company, Shanghai 200122, China;
2. State Grid Shanghai Municipal Electric Power Company, Shanghai 200122, China;
3. School of Automotive Studies, Tongji University, Shanghai 201804, China)

Abstract: Aiming at the problems of frequent failures and untimely maintenance of DC charging pile, a fault early warning method of DC charging pile based on soft classification model was proposed. Based on the current sequence and voltage sequence of the charging pile in the charging process, the differential sequence of charging power was constructed, the state of charge (SOC) sequence of the electric vehicle was also regarded as the feature of the charging process, above characteristics were taken together with the basic information of the charging pile as the input feature of the fault identification model; based on the integration of random forest (RF), extreme gradient boosting (XGBoost) and K-nearest neighbor (KNN) algorithms, a charging pile fault identification model was constructed, the soft classification method was used in the model to calculate the probability that the charging characteristics of the charging pile belong to various fault states. By setting the early warning threshold, when the probability of failure of the charging pile exceeded the early warning threshold, an early warning message was sent to the relevant maintenance personnel. The DC charging pile data obtained from the internet of vehicles platform was used for experiments, the results show that the proposed method can carry out early warning for the DC charging pile that is about to fail, and the precision and recall of early warning meet the requirements, which verifies the effectiveness and practicability of this method. The proposed method has certain practical value for the operation and maintenance of DC charging pile.

Key words: DC charging pile; fault early warning; soft classification; ensemble model

发展电动汽车对推动产业节能减排、技术创新具有重要意义, 是实现“碳达峰、碳中和”目标

的重要策略^[1]。电动汽车的发展离不开基础设施的建设, 作为电动汽车的充电设备, 充电桩成为

基金项目: 上海市软科学基金项目 (21692100700)

作者简介: 李芝娟 (1991—), 女, 硕士, Email: xingkong0218@126.com

通讯作者: 马洪恩 (1998—), 男, 硕士, Email: 1094965118@qq.com

人们研究的热点。

充电桩投放后无法避免故障的发生。相较于交流充电桩而言,直流充电桩结构较复杂、充电功率大,所以直流充电桩更容易发生故障,并且故障原因更复杂^[2]。由于直流充电桩的服务率远高于交流充电桩,直流充电桩发生故障将对大规模用户带来不良影响,所以直流充电桩的使用质量成为电动汽车用户和电网公司的重点关注问题。

保障充电桩可靠性的有效方法是提高故障诊断技术,从而快速识别有故障的充电桩并定位故障点。目前,针对充电桩如何布局规划^[3]、充放电控制优化^[4]、充电负荷预测^[5]等方面的研究较多,但如何保障充电桩可靠性的研究相对缺乏,充电桩运维领域仍需凭借专家经验进行维护,运维效率低。

在充电桩故障诊断领域,部分文献提出了故障诊断及定位的模型:文献[6]构建了基于整数线性规划的充电桩故障定位模型,该模型根据充电桩发生故障时所产生的扰动功率来定位故障充电桩所在的支路;文献[7]在文献[6]的基础上,提出基于二进制粒子群算法的求解方法,模型性能得到提升;文献[8]通过仿真发现直流充电桩在不同控制策略和不同状态下的输出电压波形存在差异,由此利用充电桩的输出电压数据构建了基于深度神经网络的直流充电桩故障诊断模型;文献[9]分别将隐生灭过程模型和隐马尔科夫模型用于识别充电桩故障,仿真结果表明隐生灭过程模型的故障识别速度更快;文献[10]将相似性聚类与隐马尔科夫相结合来构建充电桩故障诊断模型,在一定程度上提高了模型的诊断精度。上述模型采用人工智能算法对故障进行定位,但是模型的故障诊断类型比较单一。文献[11]中对直流充电桩的故障类型进行了详细划分,根据故障现象和故障原因建立了基于故障树的直流充电桩故障诊断专家系统,但故障树的构建和分析过程离不开人工,故障预测方面的研究不足。

针对直流充电桩的故障频率高、种类多、人工检测难度大,本文提出基于软分类识别模型的充电桩故障预警模型。首先,依据充电桩在一次充电过程中的功率变化,挖掘充电过程的阶段性特征。然后构建功率的差分序列,结合电动汽车的荷电状态(state of charge, SOC)序列作为充电桩的充电特征,采用基于“随机森林(random for-

est, RF) + 极端梯度提升(extreme gradient boosting, XGBoost) + K 近邻(K-nearest neighbor, KNN)”集成的软分类故障识别模型,该模型会计算充电桩在故障发生前的充电特征属于各类故障状态的概率值,在故障发生概率超过预警阈值时发出预警信息。最后通过车联网数据进行算例分析,验证文中模型的有效性。

1 充电功率特性分析

利用来自充电桩端监控到的实时充电电流、电压信息可以计算实时的充电功率,从而反映充电桩在单位时间内的电量输出情况,通过来自车端的实时 SOC 信息可以反映电动汽车的电量输入情况。在正常充电过程中,直流充电桩的充电功率与电池 SOC 随时间的变化趋势如图 1 所示,该充电桩的额定功率为 60 kW,最大输出电压为 500 V,充电时间为“2021-08-28 10:08:39”至“2021-08-28 12:28:02”。




图1 充电功率与电池 SOC 随时间的变化趋势

Fig.1 Change trend of charging power and battery SOC with time

直流充电桩的充电过程具有三个不同阶段的充电特征:阶段1对应车端 SOC 值为 0% ~ 90% 范围内,该阶段的桩端充电功率维持在较高数值水平,缓慢增长;阶段2对应车端 SOC 值一般位于 90% ~ 95% 范围内,该阶段的桩端充电功率由最高值快速下降到较低值;阶段3对应车端 SOC 值临近 100%,该阶段的桩端充电功率一直维持在最低水平。

基于充电桩正常充电时的三阶段特征,无故障充电桩的充电功率曲线具有相同的变化趋势,对每个数据采集时间点的功率值作一阶差分处理,用于表示在单位数据采集间隔时间内的功率变化率,直流充电桩的充电功率差分 ΔP 随电池

SOC的变化曲线如图2所示。电池SOC低于90%时,充电功率的差分序列不低于0,当SOC超过90%左右时,充电功率的差分值迅速减小为负值,当SOC临近100%时,充电功率的差分值在0附近小范围波动。




图2 正常充电功率差分随SOC变化的规律

Fig.2 Variation of normal charging power difference with SOC

与正常充电规律变化图对比,图3展示了部分故障类型的充电功率差分曲线图,在故障充电过程中,功率差分值提前出现大幅度下降,并在0值附近出现较大幅度的波动。




图3 异常充电功率差分曲线示例

Fig.3 Example of abnormal charging power difference curves

2 软分类算法原理

软分类故障识别模型对于所输入的每个样本,都将输出一组数值,对应该样本发生每一类故障的概率。本文采用将软分类模型中的随机森林、KNN和XGBoost组合的集成方法,构建直流充电桩故障识别模型。

1) 随机森林(RF)模型。RF模型使用了Bagging

技巧,在训练每一个分类器时,仅使用样本的部分特征来构建分类器,从而实现分类器的多样性,通过这种方法,可以获得具有不同关注点的分类器。在RF中,分类器就是单棵决策树,通过训练多棵决策树并将它们的判断结果通过投票计数的方式总和起来,得到森林的判断结果。通过Bagging技巧,随机森林中的分类器性能结构各不相同,使得森林在性能上往往优于单棵的决策树,具有更低的过拟合风险和更强的模型泛化能力^[12]。

2) K近邻(KNN)模型。KNN模型通过计算样本点之间的距离(通常为欧拉距离),将样本点划分为离其最近的K个点的标签众数。KNN模型对于群体分布敏感性较高,在区分分布较为混杂的群体时,KNN模型精度有限,但其模型简单,训练速度较快,在简单常规分类问题中也有着不错的表现^[12]。但是KNN模型对于不同特征的距离权重需要人为设定,较为繁琐,在本研究中,各特征距离权重均相等,以简化模型。

3) 极端梯度提升(XGBoost)模型。XGBoost是在梯度提升决策树(gradient boosting decision tree,GBDT)原理上发展改进而来。GBDT会串行地训练多个分类器,每个分类器会注重于学习前一个分类器判断错误的样本,起到学习并弥补前一个分类器错误的作用,最后,各分类器的判断结果加和在一起,作为整个模型的判断结果。与传统的GBDT不同,XGBoost在对目标函数进行泰勒展开时会展开至二阶而非一阶;其次,GBDT给下一层分类器寻找新的拟合标签,XGBoost则是寻找新的目标函数;最后,XGBoost还在子叶权重中加入了L2正则化(平方正则化)。这些改进使得XGBoost在近年来的机器学习竞赛中获得了较传统GBDT更为优异的性能^[13]。

4) 集成模型。针对不同的分类器模型对于数据的处理方式有所区别,从而导致出现各分类器从样本特征中获得的信息不同的问题,集成模型通过将子分类器的结果进行策略性结合之后作为模型的输出,即综合各分类器获得的信息和判断依据,从而获得更精确可靠的结果。

本文构建的充电桩故障识别模型的原理如图4所示。RF,KNN和XGBoost作为子分类器,每个子分类器会对所输入的样本发生每一类故障的概率进行计算,集成模型通过将各分类器对样本发生各类故障的概率计算值进行加权加和,将加和结果最高的故障类型作为识别模型的判别

结果。




图4 基于软分类的充电桩故障识别模型原理

Fig.4 Principle of charging pile fault identification model based on soft classification

3 模型框架与评价指标

3.1 模型框架与阈值设置

在数据采集过程中,直流充电桩只输出A相电流电压值,其他B、C相的电流电压值恒为0。将直流充电桩在每次充电过程中的A相电流、A相电压、SOC记录数据视为一个独立样本信息,提取电流、电压序列中的最大电流、电压值,并计算功率的差分序列,与该次充电过程的SOC序列一块作为样本的充电特征,再结合直流充电桩的额定功率、最大输出电压这些基本信息作为故障识别模型的输入特征,模型内核采用基于“RF+KNN+XGBoost”集成的故障识别模型,该模型将会输出发生每类故障的概率值,直流充电桩故障识别模型的框架如图5所示。




图5 直流充电桩故障识别模型框架

Fig.5 Framework of DC charging pile fault identification model

预警阈值 T_A 与预警精确度和预警提前时间密切相关:随着预警阈值的增大,模型的预警精确度增大,预警可信度越高,但预警提前时间随着预警阈值的增大而减小,预警的实际价值降低。不同类型故障各有不同的特征,所以不同故障类型的预警阈值应该分别设置。本文采用统计学方法设置预警阈值。通过拟合无故障充电桩的正常样本经过模型计算得到的发生各类故障的概率值,以故障A为例,求解概率密度函数 $f(P_A)$,预警阈值通过下式计算:

$$\int_{T_A}^{+\infty} f(P_A) dP_A = \alpha \quad (1)$$

式中: P_A 为模型识别出样本发生A类故障的概率值; T_A 为A类故障的预警阈值; α 为显著性水平,考虑到样本量不是很多,本文选取 α 为0.005。

通过比较 P_A 和 T_A 的大小,制定预警准则如下:

$$\begin{cases} P_A < T_A & \text{充电桩不发生A类故障} \\ P_A > T_A & \text{充电桩发生A类故障} \end{cases}$$

3.2 模型评价指标

混淆矩阵是用于统计分类模型测试结果正确量和错误量信息的矩阵,以二分类任务(含有两类标签A、B)为例,混淆矩阵结构如图6所示。

		实际分类	
		A	B
预测分类	A	a	b
	B	c	d

图6 二分类混淆矩阵

Fig.6 Confusion matrix of binary classification

图6中, a 代表样本真实标签为A、模型识别标签为A的样本数; b 代表样本真实标签为B、模型识别标签为A的样本数; c 代表样本真实标签为A、模型识别标签为B的样本数; d 代表样本真实标签为B、模型识别标签为B的样本数。

为评价直流充电桩故障识别模型的性能好坏,采用准确率(Precision)、召回率(Recall)、 F_1 -Score作为评价指标。以标签A为例,各项指标的计算方式如下:

$$Precision(A) = \frac{a}{a+b} \quad (2)$$

$$Recall(A) = \frac{a}{a+c} \quad (3)$$

$$F_{1-Score}(A) = \frac{2 \times Precision(A) \times Recall(A)}{Precision(A) + Recall(A)} \quad (4)$$

式中: $Precision$ 为模型识别结果的可靠性指标;

*Recall*为模型正确识别出该类标签的比例指标;
 $F_{1-Score}$ 为模型的综合性能指标,融合了*Precision*
及*Recall*两个指标的信息。

以上三个指标的值越大,模型性能越好。

考虑到模型识别的故障标签有多个,计算各个评价指标的Macro Average(数值平均)和Micro Average(加权平均)值作为故障识别模型性能的评估指标,其中,数值平均可以反映各类故障在同一类指标上的平均性能,而加权平均值由于结合了各类样本的占比信息,能综合反映模型在整个数据集上的表现。

4 算例分析

实验数据来自车联网平台中的6 506个上海市内的直流充电桩的历史信息,包括实时采集信息、故障信息及设备信息,时间为2021年8月24日到2021年11月16日。采集信息记录的是直流充电桩每隔3 min采集一次的实时电压、实时电流以及实时*SOC*数据,故障信息记录了直流充电桩每次发生故障的具体故障类型、故障开始时间、故障结束时间等信息,设备信息记录的是直流充电桩的位置、额定功率、最大输出电压、生产厂家等信息,以上三类信息通过充电桩编号进行关联。

在直流充电桩间隔3 min采样的数据中,利用Python编程将每次充电过程的采集数据提取出来,基于实时电流、实时电压计算实时功率,然后对功率进行一阶差分处理,对直流充电桩进行充电功率分析。

在直流充电桩的充电过程中均匀选取30个采集时间点所对应的功率差分值和*SOC*值分别作为该充电过程的功率差分序列和*SOC*序列,将直流充电桩在每次充电过程中的最大电流、最大电压、功率差分序列、*SOC*序列、额定功率、最大允许输出电压信息作为一个样本的输入特征,通过故障信息对位于故障开始与结束时间段内的样本进行标记,当故障时间段内没有相关的充电记录,即充电桩因为故障而停止提供充电服务的情况,将距离故障开始时间最近的充电过程样本标记为故障样本。

据统计,数据中一共出现了40多种故障类型,通过电力公司工作人员进行商量选择故障频率较高、比较重要的故障类型,得到如表1所示的12种直流充电桩常见故障类型。

表1 故障类型统计

Tab.1 Statistics of fault types

故障编号	故障类型	样本数量
1	充电模块过温告警	4 831
2	充电中车辆控制引导告警	778
3	充电接口过温告警	813
4	TCU与控制器通信故障	983
5	绝缘监测告警	502
6	充电模块交流输入告警	181
7	充电模块风扇故障	55
8	充电模块输入欠压告警	205
9	直流母线输出过流告警	203
10	电度表异常故障	241
11	直流母线输出过压告警	74
12	充电接口电子锁故障	133

随机抽取8 000个正常样本和上述故障样本作为模型的训练与测试数据,按照7:3划分训练集和测试集,为得到无偏的模型测试结果,采用分层抽样的方法保证每类样本在训练集和测试集中的占比相同,训练时采用五折交叉验证法,模型参数采用网格调参。在使用相同数据集的前提下,将本文所提的集成模型与KNN,XGBoost,RF做对比,各模型的训练与测试效果如表2所示。

表2 模型性能对比

Tab.2 Model performance comparison

评价指标			模型			
			KNN	RF	XGBoost	“RF+KNN+XGBoost”集成模型
训练集	Macro Average (数值平均)	Precision	0.88	0.95	0.91	0.94
		Recall	0.91	0.81	0.83	0.87
		F _{1-Score}	0.89	0.87	0.87	0.90
	Weighted Average (加权平均)	Precision	0.92	0.94	0.95	0.96
		Recall	0.92	0.93	0.95	0.96
		F _{1-Score}	0.92	0.93	0.94	0.95
测试集	Macro Average (数值平均)	Precision	0.88	0.94	0.90	0.93
		Recall	0.90	0.79	0.82	0.86
		F _{1-Score}	0.89	0.85	0.85	0.89
	Weighted Average (加权平均)	Precision	0.92	0.93	0.94	0.95
		Recall	0.92	0.93	0.94	0.95
		F _{1-Score}	0.92	0.92	0.94	0.95

结果表明,与单一算法的故障识别模型相比,集成模型的准确度更高,模型性能更优,验证了该模型应用于充电桩故障诊断的有效性。

利用集成模型对未发生过故障的充电桩样本进行预测,模型预测出上述正常样本不发生故障的概率分布和概率累积分布如图7所示,90%的正常样本被模型预测为无故障发生的概率值超过0.8,说明了模型识别准确度高。




图7 正常样本的正常概率分布及累积分布

Fig.7 Probability distribution and cumulative distribution of normal samples

模型预测出上述正常样本发生各类故障的概率累积分布如图8所示,在模型预测概率值较低的位置,各类故障的累积分布接近了100%,进一步验证了模型的准确性。




图8 正常样本的故障概率累积分布

Fig.8 Cumulative distribution of failure probability of normal samples

以故障1(充电模块过温告警)为例,基于软分类的集成模型预测正常样本发生故障1的概率值 P_1 ,拟合概率值 P_1 的概率分布,根据式(1),可求得故障1的预警阈值 $T_1=0.429\ 342\ 638\ 751\ 654$,利用发生过故障1的充电桩样本检验该预警阈值下的模型预警性能:该充电桩在“2021-10-01 12:54:59”发生了故障1,之前未发生过故障,利用模型对该充电桩进行预警的过程如图9所示。




图9 故障1预警示意图

Fig.9 Schematic diagram of fault 1 early warning

经过基于软分类算法的集成模型预测,该充电桩在“2021-09-26 01:06:04”的充电样本被模型预测出发生故障1的概率值 P_1 超过了预警阈值 T_1 ,比实际故障发生提前了5 d时间,虽然中间有几次充电均没有触发预警,但故障概率值的抖动上升趋势明显,可以判断出故障的发生,可以认为该预警阈值设置合理,具备早期预警能力。

5 结论

针对直流充电桩故障频发的问题,通过挖掘桩端的充电功率对电动汽车充电效率的影响,提出将功率差分序列和车端SOC序列作为样本特征,构建一种基于软分类算法的直流充电桩故障预警模型,该模型通过集成RF,KNN,XGBoost三种分类算法实现优势互补,能对直流充电桩中频繁发生的12种故障类型进行识别,模型的识别准确度、召回率以及 $F_{1-Score}$ 的加权平均值均达到了95%,模型效果最优。

通过拟合模型预测正常样本发生故障概率值的概率分布函数,设计了显著性水平为0.005条件下的故障预警阈值,实例验证了该模型在所设计预警阈值下能够提前对直流充电桩故障进行预警,并能准确识别出具体的故障类型,给维护人员留出了充分的故障应对时间,体现了该模型的预警价值。

所提充电桩故障预警方法具有理论价值和实用性,能为建设智能充电桩维护平台提供参考。

参考文献

- [1] 王震坡. 双碳目标下电动汽车有序充电与车网互动技术研究[J]. 电力工程技术, 2021, 40(5): 1.
WANG Zhenpo. Research on orderly charging and vehicle network interaction technology of electric vehicle under double carbon target[J]. Electric Power Engineering Technology, 2021, 40(5): 1.
- [2] 方华亮, 廖家齐, 徐彦, 等. 基于风险评估的电动汽车直流充电站运维策略[J]. 电力科学与技术学报, 2021, 36(1): 96-105.
FANG Hualiang, LIAO Jiaqi, XU Yan, et al. Maintenance strategy research of DC charging stations for electric vehicle based on risk assessment[J]. Journal of Electric Power Science and Technology, 2021, 36(1): 96-105.
- [3] 严干贵, 刘华南, 韩凝晖, 等. 计及电动汽车时空分布状态的充电站选址定容优化方法[J]. 中国电机工程学报, 2021, 41(18): 6271-6284.
YAN Gangui, LIU Huanan, HAN Ninghui, et al. An optimization method for charging station location and capacity determination considering the spatiotemporal distribution of electric vehicles[J]. Proceedings of the Chinese Academy of Sciences, 2021, 41(18): 6271-6284.

- tion method for location and capacity determination of charging stations considering spatial and temporal distribution of electric vehicles[J]. Proceedings of the CSEE, 2021, 41(18): 6271-6284.
- [4] LIAO Jiantang, HUANG Haowei, YANG Hongtzer, et al. Decentralized V2G/G2V scheduling of EV charging stations by considering the conversion efficiency of bidirectional chargers[J]. Energies, 2021, 14(4): 962.
- [5] LIN L, XU W, XIANG Y, et al. Optimal allocation of charging piles in multi-areas considering charging load forecasting based on Markov chain[J]. Advanced Engineering Science, 2017, 49(3): 170-178.
- [6] 原亚宁, 李琳. 电动汽车充电桩故障定位系统优化配置模型[J]. 电气自动化, 2021, 43(2): 41-43, 46.
YUAN Yaning, LI Lin. Optimized configuration model for the fault locating system of charging piles for electric vehicles[J]. Electrical Automation, 2021, 43(2): 41-43, 46.
- [7] 易忠林, 巨汉基, 王杰, 等. 基于二进制粒子群的充电桩故障定位系统配置与定位方法[J]. 电测与仪表, 2021, 58(2): 139-145.
YI Zhonglin, JU Hanji, WANG Jie, et al. Fault location system configuration and location method of charging pile based on binary particle swarm optimization[J]. Electrical Measurement & Instrumentation, 2021, 58(2): 139-145.
- [8] 赵翔, 陈良亮, 李明贞, 等. 一种基于深度神经网络的直流充电桩故障诊断方法[J]. 电测与仪表, 2021, 58(6): 148-152.
ZHAO Xiang, CHEN Liangliang, LI Mingzhen, et al. A fault diagnosis method for DC charging pile based on deep neural network[J]. Electrical Measurement & Instrumentation, 2021, 58(6): 148-152.
- [9] 林越, 刘廷章, 潘建, 等. 基于隐生灭过程模型的充电桩故障诊断研究[J]. 合肥工业大学学报(自然科学版), 2019, 42(4): 486-492.
LIN Yue, LIU Tingzhang, PAN Jian, et al. Fault diagnosis of charging piles based on hidden birth-death process model[J]. Journal of Hefei University of Technology (Natural Science), 2019, 42(4): 486-492.
- [10] 林越, 刘廷章, 陈一凡, 等. 基于AP-HMM混合模型的充电桩故障诊断[J]. 广西师范大学学报(自然科学版), 2018, 36(1): 25-33.
LIN Yue, LIU Tingzhang, CHEN Yifan, et al. The fault diagnosis of charging piles based on hybrid AP-HMM model[J]. Journal of Guangxi Normal University (Natural Science Edition), 2018, 36(1): 25-33.
- [11] 杨莎莎. 基于故障树的直流充电桩故障诊断专家系统研究[D]. 北京: 北京交通大学, 2019.
YANG Shasha. Research on DC charging pile fault diagnosis expert system on fault tree[D]. Beijing: Beijing Jiaotong University, 2019.
- [12] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
ZHOU Zhihua. Machine learning[M]. Beijing: Tsinghua University Press, 2016.
- [13] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//The 22nd ACM SIGKDD International Conference, 2016.

收稿日期: 2022-02-14

修改稿日期: 2022-05-12