考虑小样本不平衡的快速可靠充电桩故障预测

陈静绵
中国人民大学 北京 100872

摘 要 随着新能源电动汽车的广泛应用，充电桩故障诊断预测对充电桩的快速维修与安全运行有着重要的现实意义。充电桩故障预测中针对表格数据的传统机器学习和深度学习需要大量训练数据，且依赖复杂超参数调优和特征工程，难以适应小样本分类不平衡的设备早期故障预警场景和日新月异的充电桩技术带来的变化。本文提出一种相对可靠、高效、可快速适配不同场景的充电桩故障预测通用模型。通过在小样本分类不平衡的数据集上训练了TabPFN充电桩故障预测模型，其准确率、精确率、f1值和AUC值达到97.8%、99.5%、97.7%、99.6%。同时本研究还融合SHAP技术，对模型进行了全局与局部层面的解释性分析，有效克服了模型在实际应用中的黑箱问题，为充电桩故障诊断研究及运维决策提供新的技术路径和思路。

关键词 充电桩故障；故障预测；小样本不平衡

Fast and Reliable Charging Pile Fault Prediction Considering Small-Sample Imbalance

Chen Jing-mian
Renmin University of China, Beijing 100872, China

Abstract With the widespread adoption of new energy electric vehicles, fault diagnosis and prediction of charging piles are of great practical significance for rapid maintenance and safe operation. Most traditional machine learning and deep learning methods for tabular data in charging pile fault prediction require large amounts of training data and rely on complex hyperparameter tuning and feature engineering, making it difficult to adapt to early fault warning scenarios with small-sample class imbalance and to keep pace with the evolving charging pile technology. This paper proposes a relatively reliable, efficient, and rapidly adaptable general model for charging pile fault prediction. The TabPFN-based charging pile fault prediction model was trained on a small-sample imbalanced dataset, achieving accuracy, precision, F1-score, and AUC values of 97.8%, 99.5%, 97.7%, and 99.6%, respectively. Additionally, this study integrates SHAP technology to conduct interpretability analysis at both global and local levels, effectively overcoming the black-box problem of the model in practical applications, and providing new technical pathways and insights for charging pile fault diagnosis research and operational decision-making.

Key words Charging Pile Fault; Fault Prediction; Small-Sample Imbalance

随着新能源汽车的普及，充电桩安全与故障预测日益受到关注。目前研究多集中于改进传统机器学习模型[1-4]或引入神经网络方法[5-8]以提升预测精度，但针对小样本不平衡场景的故障预测研究仍较缺乏。实际应用中，技术快速迭代与设备早期故障预警常面临样本少、类别不均衡的挑战，且充电桩品牌众多，难以统一适配通用预测模型。

因此，本文提出构建一种快速可靠、适用于小样本不平衡场景的通用故障预测模型。经文献调研发现，表格先验数据拟合网络（TabPFN）[9]具备小样本高精度、端到端、无须调参等优势，适合本研究目标。本文首次将TabPFN应用于充电桩故障预测，并结合SHAP[10]技术增强模型可解释性，为实现高透明度、端到端的充电桩故障预测提供新思路，助力充电桩运维与安全保障。

1 资料与方法

1.1 目标

本研究的主要目标是将TabPFN模型首次用于充电桩故障预测应用，并结合SHAP技术开发一种适用于不平衡数据、精准、高效的可解释性充电桩故障预测模型。与传统机器学习模型需要超大量复杂参数调优，神经网络模型需要大量数据样本训练的特点不同，由于其预训练机制，推理速度快、准确率高，计算量小且仅需少量样本，可快速适配到不同场景下的充电桩故障预测应用。

1.2 TabPFN简介

TabPFN是一种专为表格数据设计的神经网络模型。模型分

为预训练和推理两个阶段。预训练阶段使用因果推断模型合成多样化表格数据集作为训练集，利用Transformer的层堆叠来处理输入数据，具备可直接处理原始表格特征、分类变量及缺失值的能力，并对异常值与无关特征表现出良好的鲁棒性。模型针对表格数据特点引入双向注意力机制，很好地捕捉同一行特征之间的相互关注和同一列样本之间的相互关注；同时模仿大语言模型的上下文学习能力，通过输入的上下文直接推理出结果，无须显式训练过程。

通过在数以亿计的多样化数据集上反复进行预训练，从先验数据集学习潜在规律和模式，最终构成了一个先验数据拟合网络。通过用先验数据拟合网络来近似贝叶斯神经网络中的后验预测分布。

在推理阶段，预训练好的先验数据拟合网络能够在单次前向传播中快速生成对未观测数据的预测分布，无须重训练或调整模型参数，推理快、准确率高。

1.3 SHAP简介

沙普利可加性解释（SHAP）是一种基于合作博弈论提出的用于解释黑箱模型的解释框架。核心思想是沙普利值概念；通过各特征对预测的贡献值相加可得到模型最终预测结果，从而量化各特征对模型预测的重要性。

沙普利可加性解释基于博弈论，具有公平性、一致性等数学性质，在保持一致性和局部准确性方面具有显著优势，即可解释每一个单独预测值，也可聚合全局沙普利值揭示特征重要性排名。该方法具有强大的通用性，适用于任意机器学习模型。

1.4 充电桩故障预测模型

1.数据集描述。本研究采用百度点石新能源充电桩故障检测数据集：85 500个样本训练集和36 644个样本测试集，好坏样本比例约为1∶1。为验证TabPFN在小样本不平衡场景的预测性能，本文从训练集中按好坏样本8∶2的比例随机抽取1 000个样本作为训练集；随机抽取5 000个样本作为验证集。测试集用来最终评估模型预测效果。

数据集样本由6个特征及其故障标签构成，数据集样例如表1所示，标签中“0”表示正常样本，“1”表示故障样本。

表1 数据集样本表

K1K2驱动信号	电子锁驱动信号	急停信号	门禁信号	THDV-M	THDI-M	label
11.814	12.123	－0.069	12.059	32.302	18.200	0
11.814	12.134	－0.064	12.066	11.161	19.689	1

2.模型构建。通过在相同数据集上训练TabPFN、GBDT（梯度提升决策树）和TabNet 3个模型，确保研究模型与基线模型的可比性。首先深度学习在计算机视觉、语音识别、自然语言处理等方面表现优异，而在表格数据学习中树模型一直占优势。因此选择了树模型GBDT和专门针对表格型数据设计的基于神经网络架构的TabNet模型作为对比基线模型。

在充电桩故障预测模型构建阶段，首先将上述1 000个训练样本作为模型输入，模型通过在预训练阶段习得的先验知识，结合上下文学习能力对训练样本进行学习，完成了具备充电桩故障感知能力的先验数据拟合网络的构建；然后使用预测模型对验证集进行预测以评估模型是否出现过拟合。最后将模型应用于测试集上，通过对比分析法对各个模型进行最终的模型评估，并对其进行可解释性分析。

3.评估指标。本文采用常用的机器学习分类指标包括准确率（accuracy：正确预测的样本数占总预测样本数的比例）、精确率（precision：正确预测的阳性样本数占所有预测为阳性样本数的比例）、召回率（recall：正确预测的阳性样本数占所有实际阳性样本数的比例）、F1值（精确率和召回率的调和平均数）及AUC值（ROC曲线下的面积，数值越接近1说明模型区分正负样本的能力越强）。各指标公式如下：

$$accuracy=\frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$precision=\frac{TP}{TP+FP} \quad (2)$$

$$recall=\frac{TP}{TP+FN} \quad (3)$$

$$F_1-score=2\times\frac{precision\times recall}{precision+recall} \quad (4)$$

式中，TP（真阳性）—被正确预测为阳性的样本量；FP（假阳性）—被错误预测为阳性的样本量；TN（真阴性）—被正确预测为阴性的样本量；FN（假阴性）—被错误预测为阴性的样本量。

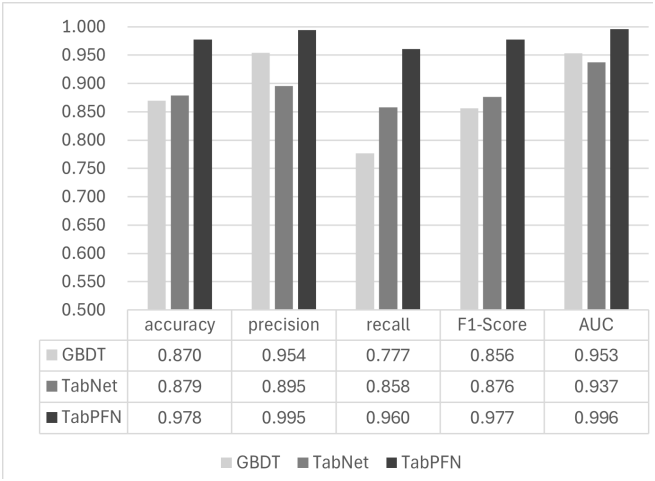
2 结果对比

2.1 模型性能分析

模型从训练到在验证集上，GBDT出现微过拟合现象，传统树模型在样本稀缺与类别失衡时其模型泛化能力差。在灵敏度上，GBDT召回率从93%下降到79.2%；而TabNet召回率从93%下降到86.3%，但精确率提高。反观TabPFN在各项指标上的表现均非常优异，远超其他两个模型。

模型评估以测试集预测作为最终结果，图1所示TabPFN模型在测试集表现非常优异，其充电桩故障预测准确率、精确率、召回率等各项指标远超另外两个模型。图2所示TabPFN模

型的K-S曲线陡峭，ROC曲线靠近左上角，模型故障识别能力强而稳定。



	accuracy	precision	recall	F1-Score	AUC
GBDT	0.870	0.954	0.777	0.856	0.953
TabNet	0.879	0.895	0.858	0.876	0.937
TabPFN	0.978	0.995	0.960	0.977	0.996

图1 测试集——各模型评估指标

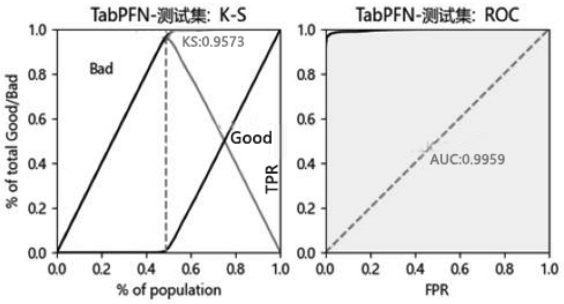


图2 测试集——各模型评估曲线图

2.2 模型可解性分析

本实验中TabPFN模型表现更优异，但其缺点在于可解释性差，在实际应用中无法满足运维决策需求。为解决模型这一缺陷，本文引入沙普利可加性解释方法，从全局和局部两个方面对模型进行可解释性分析。本文从测试集随机抽取500个样本作为全局可解释性分析代表，特征变量对模型预测结果贡献由强到弱依次为急停信号、THDV-M、电子锁驱动信号、门禁信号、THDI-M、K1K2驱动信号。排序最后的两个特征对模型预测的贡献非常微弱。

SHAP局部可解释性分析侧重于量化具体样本的不同特征对预测值的影响，热力图颜色分布与上述的全局特征重要性的结论是一致的。本文从中随机抽取2例正常和2例故障样本进行沙普利值分析，结果清晰展示了在多特征的影响下，模型决策随输入变化而产生的波动过程。

3 结束语

本研究通过TabPFN和SHAP融合建模方法，并以传统树模型及针对表格数据设计的神经网络模型作为基线模型进行对比，证实了其在小样本分类不平衡场景下充电桩故障预测的高性能，并得出以下结论：①TabPFN在小样本不平衡场景下充电桩故障预测性能优异。展示了其高准确性，高精度，高灵敏度的优势，模型准确率为97.8%，精确率为99.5%，F1值为97.7%，AUC值为99.6%；②融合SHAP技术量化并可视化关键特征对预测结果的贡献，提升模型透明度和可信度，有效解决TabPFN在实际应用中的黑箱问题；③TabPFN无须大量特征工程或超参数调优就能学习复杂特征交互关系，是实现端到端的快速可靠预测理想工具；④TabPFN融合SHAP的建模框架具有高效、准确、灵敏、可解释的故障预测性能，有望推广到其他工业设备故障预警场景中。

参考文献

[1]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.

[2]袁单,刘鸿鹏,陈良亮,等.基于改进决策树的充电桩故障预测方法[J].电气自动化,2023,45(6):92-94,103.

[3]王群飞,尹忠东,鄂涛.基于随机森林算法的V2G充电桩故障诊断研究[J].电测与仪表,2024,61(8):111-118.

[4]何柳,张梅.基于ISSA-SVM的充电桩故障诊断[J].电子测量技术,2023,46(20):104-109.

[5]茆敏,窦真兰,陈良亮,等.基于BOA-SSA-BP神经网络的充电桩故障诊断方法[J].吉林大学学报(信息科学版),2024,42(2):269-276.

[6]袁单.基于数据驱动的电动汽车充电安全预警方法研究[D].吉林:东北电力大学,2024.

[7]陈庆斌,杨耿煌,耿丽清,等.基于合作博弈策略和DBO-BiLSTM-Attention的电动汽车充电桩故障预测[J].电子测量与仪器学报,2025,39(4):163-171.

[8]张震,郭恩伯,郭恩仲,等.GBDT与感知机融合的充电桩故障诊断方案[J].自动化与仪表,2024,39(4):153-157.

[9]HOLLMANN N, MÜLLER S, PURUCKER L, et al. Accurate predictions on small data with a tabular foundation model[J]. Nature, 2025,637(8045):319-326.

[10]LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, CA, USA: Curran Associates Inc.,2017:4768-4777.

（本文编辑 曹 阳）