

基于“云管边端”技术的设备风险防范研究

奚增辉, 王卫斌

国网上海市电力公司互联网部, 上海
Email: shenyx@haoshudao.com

收稿日期: 2021年2月5日; 录用日期: 2021年3月15日; 发布日期: 2021年3月22日

摘要

在电力台区设备接入用户数逐步增加以及电力设备风险防范越来越重要的背景下, 对台区设备进行风险防范的必要性逐渐显现, 目前虽然设备的风险防范已有一定的研究及实践, 然而在实践中, 对于电力领域设备数量多、范围广、数据复杂的情况仍没有高效的解决方案。本文提出一种基于“云管边端”技术的台区设备进行风险防范方法, 基于本文所述方法, 能够显著提高风险防范的效率以及准确性。

关键词

大数据, 智能电网, 云管边端, 边云协同, 分布式计算, 台区设备, 风险评价, 风险防范

A Research on Equipment Risk Prevention Based on “Cloud Tube Edge End” Technology

Zenghui Xi, Weibin Wang

Internet Department of State Grid Shanghai Municipal Electric Power Company, Shanghai
Email: shenyx@haoshudao.com

Received: Feb. 5th, 2021; accepted: Mar. 15th, 2021; published: Mar. 22nd, 2021

Abstract

In the context of the gradual increase in the number of users connected to power distribution station and the increasing importance of power equipment risk prevention, the necessity of risk prevention for power distribution station has gradually emerged. Although there has been certain research and practice on equipment risk prevention, however, in the process of practice, there is still no efficient solution for the large number of equipment, wide range, and complex data in the power field. This paper proposes a risk prevention method for power distribution station based on the “cloud-network-edge-end” technology. Based on the method described in this article, the efficiency and accuracy of risk prevention can be significantly improved.

Keywords

Big Data, Smart Grid, Cloud Tube Edge End, Edge Cloud Collaboration, Distributed Computing, Power Distribution Station, Risk Evaluation, Risk Prevention

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着电力的发展,设备接入用户数量逐步增加,对于设备的运行要求越来越高,而随着设备使用时间的增长,设备在运行过程中会面临各种各样的风险,这些风险影响了用户的用电体验,同时也为设备运维增加不确定性,对于设备风险防范的重要性逐渐体现出来。

目前,对于电网设备的风险防范,业界有一些研究先例,文献[1]介绍了基于机器学习的电网信息系统安全风险预测模型构建的方法,基于交互式学习技术,完成采集运行数据的聚类分析,设置系统安全风险预测指标,并利用机器学习算法计算对应指标的权值,从系统网络攻击预测、用户行为预测和系统硬件设备故障预测3个方面,得出系统安全风险的预测值。

对于云管边端的研究,国内已有学者做过相关研究,文献[2]重点阐述了智能网联交通体系之车路协同云管边端架构方案,介绍了中心云、交通专网/电信网络、边缘云、车载/路侧终端协同的“云-管-边-端”统一架构,同时提出了基于云管边端架构的车路协同多源数据融合信息服务能力开放框架,并对其具体功能要求、API调用方式进行了详细论述。

然而,目前还有没有将“云管边端”技术与台区设备风险防范结合的应用案例,本文将以上海市浦东供电公司辖管的2万个台区设备为例,通过“云管边端”技术实现对设备的风险防范,以验证其可行性,同时与传统设备风险防范方法进行对比,探索基于“云管边端”技术的设备风险防范与传统做法的优势。

2. 背景

存在的问题

在目前对设备风险调控的方法,主要存在四大问题:

其一,将大量数据传输至云端会导致管道压力、运算压力提升;

其二,不够及时,效率低。目前采取的将所有数据集中上传至云端,再由云端进行统一数据处理及算法模型运算。首先,在数据传输的过程中,由于各个台区的数据量巨大,在数据传输至云端的过程中导致传输的效率不高,其次,由于电网数据量众多,数据类型也不尽相同,由云端统一进行数据处理和分析,需要采取大量时间进行数据处理与分析。在对上海浦东供电公司进行台区设备负荷预测的过程中,对两万个台区的数据收集到预测过程总共耗时4个小时的时间;

其三,精准度不足。目前采取将所有数据上传至云端,再有云端统一进行分析,多台区数据的融合,没有考虑台区与台区之间的特性,比如有的台区是白天高负荷性,有的台区是工作日高负荷型,将两万个不同台区的数据融合在一起再统一进行分析,导致预测结果、判断结果不准确;

其四,设备风险防范评价过程依赖员工专业性。经验丰富的员工可以快速基于云端数据对设备风险进行评价,而经验欠缺的员工往往无从下手。

本文所采取的方法为基于“云管边端”方法实现设备风险防范, 则可以对上述问题进行优化, 本文描述的方法利用“云管边端”的技术, 在云端进行模型的训练及优化, 将模型下放到边端, 在边端进行数据提取以及基于云端下放模型的算法运算。

其一, 通过边端进行数据预处理, 只选择有价值的的数据传送至云端, 避免了大量数据传输至云端会导致管道压力提升;

其二, 由于云端数据为经过筛选和预处理过的数据, 优化了云端的运算能力;

其三, 对于风险评价的算法模型运算将云数据中心的处理任务卸载到网络的边缘, 在靠近用户侧进行数据计算、查询、挖掘、存储等功能, 提升了模型运算的精准度;

其四, 基于以上描述, 对设备的风险评价工作由员工转移至边端算法上, 降低了员工的专业性要求。

3. 技术及方案分析

3.1. 云管边端

“云管边端”和云计算的区别主要是云计算中心/平台只储存数据, 处理数据和传输数据, 云计算中心/平台是数据的使用者; 但是边缘计算因为靠近用户侧, 处于网络的边缘位置, 分布式的数据处理中心/平台不仅存储、处理、传输数据, 更重要的是, 在边缘计算架构下, 数据处理中心/平台还是数据的生产者。这种将核心网用户面功能下沉到边缘侧的架构减少了网络的重复操作, 降低了数据请求传输到响应请求的时延, 提高了用户的服务质量和体验。合理的架构还可以增加提供的数据信息量、缓解网络拥塞的程度, 并为用户带去更多的应用和更佳的服务[3]。

在本文中, 基于“云管边端”的设备风险防范方法, 通过在浦东供电公司两万个供电台区的实践, 将大量数据处理和负荷预测计算工作在边缘端的设备层面完成, 大大提高了设备状态识别的及时性, 降低了数据传输带宽耗用, 减轻了云端服务器的计算压力, 实现“云管边端”计算的高效应用模式, 提高了数据传输的时效性, 减少了电力云端的计算压力。

3.2. 设备风险防范

在设备风险防范的过程中, 本文通过对台区设备负荷进行预测, 对设备重过载发生概率进行预测, 以及刻画设备标签, 综合以上几个维度的数据, 实现对设备风险的评价, 进而实现对设备风险的防范。

本文将浦东供电公司应用为例, 分别从边端和云端的分工描述如何进行设备风险防范。

在云端, 通过边端采集的处理过的数据, 对预测模型算法进行训练以及优化, 之后将训练好的模型下放到边端。

在边端, 进行数据收集、数据预处理、特征提取以及基于云端下放的模型进行计算, 从而获得边端设备的风险评价指标。

本文在预测算法上选择 Xgboost 算法作为风险预测的算法, Xgboost 算法作为一种提升算法, 是基于 AdaBoost 算法和 GBDT 算法演化而来。通常来说, 目标函数的优化效果决定了模型的准确性, 目标函数优化的好, 预测值就越接近真实值, 模型的繁华能力也就越好。最小化损失函数和增加模型复杂度的惩罚项可以达到以上两个目标。不同于传统的 GBDT 只利用一阶导数信息的方式, Xgboost 对 loss function 做了二阶的泰勒展开, 并且在目标函数之外加入了正则项来整体求最优解, 以权衡目标函数的下降和模型的复杂程度, 避免模型的过度拟合。

其原理是将原始数据集分割成多个子数据集, 将每个子数据集随机的分配给基分类器进行预测, 然后将弱分类的结果按照一定的权重进行计算, 来预测最后的结果。Xgboost 对损失函数使用二阶泰勒展开, 对于第 t 次的目标函数 $Ob_t^{(t)}$ 如下:

$$Obj_i^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) + \text{constant} \quad (1)$$

其中, $l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i))$ 为样本 x_i 的训练误差, $\hat{y}_i^{(t-1)}$ 表示组合 $(t-1)$ 棵树模型对样本 x_i 的预测结果, f_t 表示第 t 棵树, $\Omega(f_t)$ 表示第 t 棵树的正则项, constant 为常数项。

对目标函数进行二次泰勒展开, 并引入正则项:

$$Obj_i^{(t)} \approx \sum_{i=1}^n \left[l(y_i, \hat{y}_i^{(t-1)}) + g_t f_t(x_i) + \frac{1}{2} h_t f_t^2(x_i) \right] + \Omega(f_t) + \text{constant} \quad (2)$$

其中定义如下函数:

$$g_t = \partial_{\hat{y}^{(t-1)}} l(y_i, \hat{y}^{(t-1)}) \quad (3)$$

$$h_t = \partial_{\hat{y}^{(t-1)}}^2 l(y_i, \hat{y}^{(t-1)}) \quad (4)$$

利用这种方式使得求解的目标函数只依赖于每个数据点在误差函数的一阶导数和二阶导数, 从而能更快并准确的得到最优的预测值。

此外, Xgboost 相对 GBDT 还有其他优势, 包括:

- 1) 使用近似算法来判断最佳分割点;
- 2) 不仅支持以 CART 作为基分类器, Xgboost 还支持线性分类器;
- 3) 对于特征的值有缺失的样本, Xgboost 可以自动学习出它的分裂方向;
- 4) 可在系统设计模块, 块结构设计等进行并行化处理;
- 5) 针对 cache 和内存做了优化;

基于这些优势, 在相同的数据规模下, Xgboost 的训练速度远快于 GBDT 以及其他算法, 并且其精度不会下降, 故而在本文的风险预测模型选择中, 优先选择 Xgboost 进行建模分析。

Xgboost 的预测准确性取决于特征选取的是否全面, 本文在特征构建的过程中, 构建了: 1) 设备属性特征, 包括设备额定容量、总装接容量、设备投运时间以及基于设备属性等基本属性特征, 以及衍生出来如设备负荷趋势类型等特征; 2) 历史数据特征, 包括整体分布特征、趋势增长特征、周期性特征、波动程度特征等基于历史数据构建的特征; 3) 外部环境特征: 包括日期类型特征、气象特征等与设备风险相关联的外部特征。相比于原始的设备层面的特征, 本文基于“云管边端”技术的应用, 在特征选择方面充分考虑了特征的全面性。

3.3. 方案设计

目前业界在“云管边端”技术的应用方法为在云端, 通过边端采集的数据对模型算法进行训练以及优化, 之后将训练好的模型下放至边端。在边端, 进行数据收集、数据预处理、特征提取以及基于云端下放的模型进行计算。因此本文在浦东供电公司实践中所设计的方案为在云端进行负荷预测模型的优化及下放, 在边端进行台区负荷及相关的收集、数据预处理、特征提取以及算法模型的计算。

本文使用方法的流程图如图 1 所示。

4. 结果分析

1) 从对设备风险防范的效率上来看, 采用传统云端的方法, 对浦东供电公司 2 万个台区的实际用时为 200 分钟, 而采用本文所述的“云管边端”技术的响应时间为分钟级(图 2)。可以发现, 传统云端的不能实时对设备风险进行防范, 而基于“云管边端”技术则可以实现对设备风险的实时监控及防范。

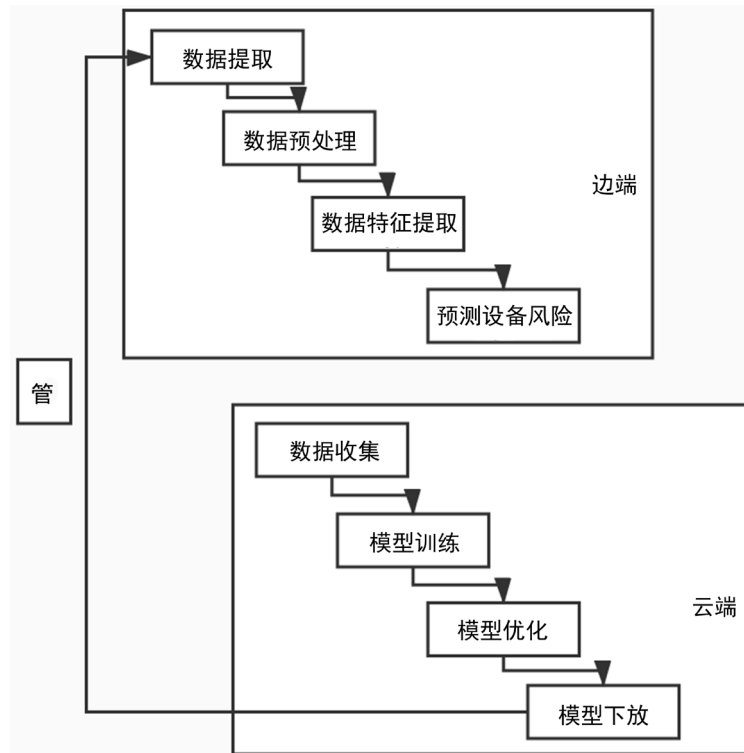


Figure 1. Flow chart of Equipment Risk Prevention Based on “Cloud Tube Edge End” Technology

图 1. 基于“云管边端”技术的设备风险防范方法流程图




Figure 2. Example of Response time comparison

图 2. 响应时间对比图

2) 对设备风险判断的准确性,传统做法通过对两万个台区的数据进行融合,预处理,统一建模分析,经过多次的模型训练以及优化模型,风险预测的结果如图3所示:其中均方根误差(RMSE)为:0.1,平均绝对误差(MAE)为0.07, R^2 为0.67, 如果以 R^2 作为模型预测结果好坏的参考标准,采用传统做法,对于两万个台区的风险预测准确性可以达到70%。




Figure 3. Example diagram of the results of risk prediction

图3. 风险预测的结果示例图

而采用本文所述的“云管边端”技术,对于2万个台区设备风险预测指标中, RMSE 的平均值为0.03, MAE 的平均值为0.02, R^2 的平均值为0.96, 如果以 R^2 作为模型预测结果好坏的参考标准,基于“云管边端”技术风险预测准确性高达96%, 预测结果如图4所示(以单台区示例):




Figure 4. Result of power distribution station load prediction

图4. 台区负荷预测结果

因此,可以得出结论:“云管边端”技术可以显著提高对设备风险预测的准确性。

5. 结语

综上所述,基于“云管边端”的设备风险防范一方面提高了风险防范的效率,缓解了云端的存储能力和计算压力,基本上可以实现风险实时报警,一方面提高了对风险预测的准确性。

通过“云管边端”的高效协同,实现多源数据的快速采集融合与精准分析应用,发挥了设备多维度

数据在风险防范方面的价值, 强化电网风险应急处置和多能互补联合调度, 带动电网安全能级的提升和治理效率的优化; 支撑经济发展趋势和社会运行态势的洞察, 为电网设备运维提供了指标和依据。

因此, 通过本文的研究以及在国网浦东供电公司的实践, 本文认为, 基于“云管边端”的设备风险方法可以在设备运维过程中进行推广和应用。

参考文献

- [1] 陆冰芳, 张希翔. 基于机器学习的电网信息系统安全风险预测模型构建[J]. 电子设计工程, 2020, 28(13): 128-132.
- [2] 熊小敏, 杨鑫, 刘兆麟, 朱雪田. 车路协同的云管边端架构及服务研究[J]. 电子技术应用, 2019, 45(8): 14-18+31.
- [3] 徐亚兰, 郭承军. 基于边缘计算的高精度地图数据处理方法研究现状[C]//第十一届中国卫星导航年会. 论文集 S02 导航与位置服务, 2020: 96-101.