



基于多模型融合的电网故障抢修时长预测

潘坚跃¹, 吴懿臻², 徐汉麟¹

(1. 国网浙江省电力有限公司杭州供电公司, 浙江 杭州 310009;

2. 浙江华云信息科技有限公司, 浙江 杭州 310008)

摘 要: 电网故障种类繁多、原因复杂, 故障抢修时长的预测相对较难。由于深度学习等新技术的兴起, 从故障工单中挖掘有效的信息, 进而准确地预测故障抢修时长的方法正在变得可行。以历史电网故障抢修工单为研究对象, 提出多模型融合的预测方法, 将 LightGBM、XGBoost 和长短期记忆网络的预测结果进行加权融合。实验结果表明, 该多模型融合的预测方法可以较为准确地对故障抢修时长进行预估, 为电网故障抢修的自动化和智能化提供更好的支撑。

关键词: 电网故障; 抢修时长; LSTM; LightGBM; XGBoost

中图分类号: TN929.5

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020016

Prediction of power grid fault repair time based on multi-model fusion

PAN Jianyue¹, WU Yizhen², XU Hanlin¹

1. State Grid Zhejiang Electric Power Company Hangzhou Power Supply Company, Hangzhou 310009, China

2. Zhejiang Huayun Information Technology Co., Ltd., Hangzhou 310008, China

Abstract: There are many types of power grid faults, and the reasons are complicated. The prediction of fault repair time is difficult. Due to the rise of new technologies such as deep learning, it is feasible to accurately mine the faulty worksheet and accurately predict the fault repair time. Taking the historical grid fault repair worksheet as the research object, the multi-model fusion prediction method was proposed, and the prediction results of LightGBM, XGBoost and LSTM were weighted and fused. The experimental results show that the multi-model fusion prediction method can accurately estimate the fault repair time and provide better support for the automation and intelligence of grid fault repair.

Key words: grid fault, repair time, LSTM, LightGBM, XGBoost

1 引言

电网故障的分析和预测是电网自动化和智能化中的重要一环。由于电网故障种类繁多、原因

复杂, 电网故障的分析和预测较为困难, 尤其是对电网故障抢修时长的预测。随着智能电网的建设, 调度自动化水平不断提高, 信息采集系统的功能不断强大, 已有众多学者开展对电网故障预

测的研究。参考文献[1]综述了广泛应用于电网故障诊断的多种智能方法结合的故障诊断方法,包括基于专家系统、Petri 网、神经网络、贝叶斯网络等技术相结合的诊断技术;参考文献[2]使用模型预测和溯因推理网络相结合的方法进行电网故障的预测,能在保护装置和断路器动作前进行故障定位,具有故障预警功能;参考文献[3]提出了一种基于长短期记忆(long short-term memory, LSTM)网络的故障时间序列预测方法,证明 LSTM 在电网故障预测中比传统方法更加准确。已有的研究多从电网内部收集的信息作为预测依据,如电压、电流、功率等指标,这些指标某种程度上反映了电网的运行状况,但忽略了天气、人为破坏等外部因素。

本文从历史的故障抢修工单出发,依据多种内外部指标,对电网故障的抢修时长进行预测。首先,对电网故障数据进行数据清洗,进行电网故障数据分析,探究影响故障抢修时长的因素。使用多种机器学习方法进行建模,并将预测结果进行加权,融合多模型的优势特点。实验证明,多模型融合的故障抢修时长预测模型比单模型的预测结果更加准确。

2 电网故障抢修记录分析

本文研究数据来自电力系统服务热线——

95598 热线系统^[4]。其主要数据是抢修人员现场抢修完毕后,反馈回系统的故障抢修工单。数据包括杭州市 2016 年 3 月—2019 年 2 月所有故障抢修工单,共 21 万余条记录。除了内部电网故障数据外,还采集了公开的气象、地理、节假日等外部数据。故障反馈工单数据是由抢修人员手动输入的半结构化数据,需要将数据进行格式化处理。图 1 展示了数据的格式化过程,其中使用了命名体识别、实体对齐等自然语言处理技术。

影响故障抢修时长的因素众多。为了发现影响抢修时长的相关因素,分析了包括环境因素(温度等天气状况)、抢修人因素(抢修队、抢修人等)、发生时间、故障所在位置、故障类型等。图 2 展示了平均气温与每天平均抢修时长的变化关系,这里的平均抢修时长是当天的总抢修时长除以总故障数。从图 2 可知,平均抢修时长与平均气温有很强的相关性,随着气温的上升,平均抢修时长也呈上升的趋势。故障发生时间也会影响故障的抢修时长。为了探索故障发生时间对故障抢修时长的影响,将全天划分为 5 个时间段,分别为:0:00–8:00、8:00–12:00、12:00–16:00、16:00–20:00 和 20:00–24:00。从图 3 可以看出,发生在凌晨以后的故障平均抢修时长较长,发生在白天的故障平均抢修时长较短。




图1 故障抢修工单数据格式化过程




图2 平均温度与平均抢修时长关系




图3 故障发生时间区与平均抢修时长关系

除了上述影响因素,还分析了不同故障类型、是否发生在节假日、发生区域、不同的抢修单位和抢修人等对抢修时长的影响。分析发现这些因素都会对抢修时长产生一定影响,因此可根据这些影响因素对故障的抢修时长进行预测。

3 多模型融合的电网故障抢修时长预测算法

3.1 基于集成学习的预测模型

在深度学习技术出现以前的相当长一段时间内,以 Boosting^[5]技术为代表的集成学习方法一直是机器学习领域综合性能最为出众的算法之一。Boosting 技术从弱学习算法出发,反复学习,得到一系列的弱分类器(基分类器),然后组合这些弱分类器,构成一个强分类器。基于树模型的提升算法被称为提升树(boosting tree)^[6],它以分类树或回归树作为基分类器,以分类器构建过程中错误分类产生的残差作为损失函数,即通过拟合残差构造损失函数。假设初始提升树为 $f_0(x)=0$,则第 m 步的模型是:

$$f_m(x) = f_{m-1}(x) + T(x; \Theta) \quad (1)$$

其中, $f_{m-1}(x)$ 为当前模型, L 为损失函数,通过经验风险极小化确定下一棵树的参数 Θ_m :

$$\hat{\Theta}_m = \arg \min_{\Theta_m} \sum_{i=1}^N L(y_i, f_{m-1}(x_i) + T(x_i; \Theta_m)) \quad (2)$$

随着树的不断生成,损失函数不断下降,每棵树学习的都是之前所有树的结论和残差。对于一般损失函数,优化比较困难,因此提出了更一般的提升树模型——梯度提升树(gradient boosting decision tree, GBDT)^[7],它使用负梯度代替残差,基分类器使用 CART 回归树。GBDT 主要思想是利用损失函数的负梯度在当前模型的值作为回归问题提升树算法中的残差的近似值,拟合一个回归树。这类技术中,当前较为先进和出众的是 LightGBM^[8]和 XGBoost^[9],它们都是基于梯度提升树技术改进实现的。本研究分别尝试了使用 LightGBM 和 XGBoost 进行建模。

3.2 基于深度学习的预测模型

自兴起以来, 基于神经网络的深度学习技术在人工智能领域取得了众多令人瞩目的进展。传统的前馈神经网络中, 层与层之间的神经元是全连接的, 层内部的神经元无连接。这种神经网络对存在前后依赖关系的序列数据是无能为力的。为此, 具有特殊结构的循环神经网络 (recurrent neural network, RNN) [10] 被提出, 它可以保存序列间的前后关系。但是, 循环神经网络很难通过反向传播算法来训练。主要的困难在于梯度消失和梯度爆炸问题。长短期记忆网络 [11] 对传统的循环神经网络结构进行了修改, 通过“门”结构控制细胞状态, 避免了消失梯度问题, 保持了训练算法的稳定性。

图4展示了LSTM的门结构。其中, x 是输入数据, f 是遗忘门输出, o 是输出门输出, h 为最终输出数据, c 为记忆单元的值。从图4中可以看出LSTM最终的输出数据不仅与当前状态有关, 还与上一个状态存在关系。




图4 长短期记忆网络LSTM的门结构

$$f_t = \delta(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \delta(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$o_t = \delta(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$\tilde{c}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tilde{c}_t \quad (7)$$

$$h_t = o_t \times \tanh(c_t) \quad (8)$$

式(3)~式(5)分别是遗忘门、输入门和输出门的计算式。在 t 时刻, 门结构接受上一时刻记忆单元的输出 h_{t-1} 和当前时刻记忆单元的输入 x_t , 与各自的权重矩阵 w 相乘, 然后加上偏置向量, 通过 Sigmoid 函数产生一个 0~1 之间的值, 对信息进行筛选。式(6)~式(8)是对细胞状态进行更新。其中, 式(8)计算记忆单元最终的输出。式(3)~式(6)中, “ $\cdot$ ” 表示矩阵内积, 式(7)、式(8)中 “ $\times$ ” 表示对应位置相乘。本研究尝试使用 LSTM 对故障抢修时长进行预测, 通过学习历史故障工单的抢修数据, 对未来新故障数据进行预测。

3.3 多模型融合的抢修时长预测模型

多模型融合的抢修时长预测模型如图5所示。在故障抢修时长的预测前, 对输入的特征数据进行清洗, 排除异常数据; 使用清洗后的数据进行特征工程建设, 找出适合特征最后分别输入 XGBoost、LightGBM 或 LSTM 中进行建模; 在建模的过程中, 分别对单个模型参数进行调优, 输出最优的预测结果; 最后, 对预测结果进行加权求和, 输出最终的预测值。




图5 多模型融合的抢修时长预测模型



4 实验结果与分析

故障抢修反馈工单是抢修人员手动输入，这导致部分异常数据存在。在实验过程中，需要先对异常数据进行清洗。表 1 给出了抢修时长的统计分布情况。从表 1 中可以看出，未去除异常数据的原始数据中，均值为 69.95 min，最大值达到了 44 718 min，即 31 天。由于少量极大异常数据的影响，导致的标准差非常大，达到了 290，这显然是不合理的，需要过滤掉少量的异常数据。表 1 的第 2 列、第 3 列为分别过滤掉抢修时长超过 1 天和超过 6 h 的数据分布情况。可以发现，去除抢修时长超过 6 h 的数据，仍保留了 96.5% 的数据，但是数据的标准差从 290.84 下降到了 58.47，下降了 80% 左右。过滤异常数据，有利于模型更好地发现数据分布规律，提高模型的准确率。

为了更精准地预测故障的抢修时长，尽可能减少潜在的未知因素对抢修时长预测的影响，将抢修时长以 15 min 为单位进行重新计算，在预测时也以 15 min 为单位进行预测。故障抢修时长的预测采用平均绝对误差（mean absolute error，

表 1 异常数据清洗结果

统计指标	未过滤	过滤时长超过 1 天数据	过滤时长超过 6 h 数据
数据总数	201 412	200 916	194 333
过滤数据量	—	496(0.25%)	7 079(3.5%)
抢修时长均值	69.65	63.07	43.57
抢修时长标准差	290.84	131.09	58.47
抢修时长最大值	44 718	1 439	359

MAE)^[12]作为主要的性能评价指标。模型训练完成后，可以使用测试集数据对模型进行验证。故障抢修时长的预测任务训练模型时使用的训练集样本为 2019 年 1 月 1 日—2 月 17 日数据，共 194 333 个训练样本。测试数据为 2019 年 2 月 18 日的数据，共 89 个测试样本。

模型训练时，分别对单个模型进行训练，并进行模型参数的调优。为了对比单个模型的建模效果，分别测试单个模型的预测效果。图 6 给出了 LightGBM 在测试样本的预测效果，从图 6 中可以看出模型预测值和真实值在大部分趋势上是拟合的，部分抢修工单存在预测不准确的情况。图 7 给出了 LightGBM、XGBoost 和 LSTM 共 3 种




图 6 LightGBM 模型的抢修时长预测结果




图 7 单个模型预测结果对比

模型的预测结果对比,从图 7 中可以看出 LightGBM 和 LSTM 的预测效果相对较好, XGBoost 的预测值则比实际值整体偏小。

通过实验发现,单个模型的预测能力有限。本文分别训练完 3 种算法后,需要将 3 种算法输出结果根据权重进行融合。根据多次实验结果,经过分析给出 LightGBM、XGBoost 和 LSTM 的权重分别为 0.65、0.15 和 0.2 时输出的加权结果较好。图 8 给出了根据权重融合了 3 种模型的预测结果。

为了对比个模型的预测性能,使用平均绝对误差 MAE 对预测结果进行评价。表 2 给出了 3 种算法的性能对比。从表 2 中可以看出,单个算法中 LightGBM 的效果最佳;而进行多模型的融合后,加权结果预测效果最好。由于时长的预测以 15 min 为单位,预测最好结果的 MAE 为 1.15,对应的抢修时长误差大致为 17.25 min。

表 2 不同模型的故障抢修时长预测误差

算法类型	平均绝对误差 MAE
LightGBM	1.21
XGBoost	1.52
LSTM	1.23
加权结果	1.15

5 结束语

随着电网信息化和智能化进程的推进,信息采集系统的功能不断强大,已有较多针对电网故

障预测的研究。目前关于电网故障预测本身的预测较多,故障抢修时长的预测相对较少。本文以 95598 电力系统服务热线的故障抢修反馈工单为研究对象,分析了影响故障抢修时长的各种因素,分别使用 XGBoost、LightGBM 和 LSTM 共 3 种模型进行抢修时长预测模型的建模。最后,根据实验结果对 3 种模型的预测结果进行加权融合。实验表明,多模型融合的抢修时长预测模型相比单模型更加准确,可以为电力抢修调度的智能化提供更加有效的支撑。

参考文献:

- [1] 喻圣, 邹红波, 余凡, 等. 基于多种智能方法结合的电网故障诊断综述[J]. 电力学报, 2019, 34(1): 35-41.
YU S, ZOU H B, YU F. Review on fault diagnosis based on a combination of intelligent methods[J]. Journal of Electric Power, 2019, 34(1): 35-41.
- [2] 薛涵磊, 刘晓琴. 基于模型预测方法的电网故障预测[J]. 辽宁石油化工大学学报, 2017(2).
XUE H L, LIU X Q. Power grid fault forecast based on model prediction method[J]. Journal of Liaoning Shihua University, 2017(2).
- [3] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018(4): 772-784.
WANG X, WU J, LIU C, et al. Exploring LSTM based recurrent neural network for failure time series prediction[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018(4): 772-784.
- [4] 陈小峰, 赵雅迪, 张利鹏, 等. 电力潜在敏感客户预测的大数据方法应用[J]. 电信科学, 2019, 35(11): 117-124.
CHEN X F, ZHAO Y D, ZHANG L P, et al. Application of big




图 8 多模型融合的抢修时长预测结果



- data method in forecasting potential sensitive customers of electric power[J]. Telecommunications Science, 2019, 35(11): 117-124.
- [5] SCHAPIRE R E. A brief introduction to boosting[C]//The Sixteenth International Joint Conference on Artificial Intelligence, IJCAI 99, July 31-August 6, 1999, Stockholm, Sweden. [S.l.: s.n.], 1999: 1450.
- [6] TU Z. Probabilistic boosting-tree: learning discriminative models for classification, recognition, and clustering[C]//Tenth IEEE International Conference on Computer Vision, October 17-21, 2005, Beijing, China.. Piscataway: IEEE Press, 2005.
- [7] FRIEDMAN J, HASTIE T, TIBSHIRANI R. Additive logistic regression: a statistical view of boosting [J]. Annals of Statistics, 2000, 28(2): 337-374.
- [8] KE G, MENG Q, FINLEY T. LightGBM: a highly efficient gradient boosting decision tree[C]//Advances in Neural Information Processing Systems, December 4-9, 2017, Long Beach, CA, USA. [S.l.: s.n.], 2017: 3146-3154.
- [9] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//ACM Sigkdd International Conference on Knowledge Discovery & Data Mining, August 24-27, 2016, San Francisco, USA. New York: ACM Press, 2016: 785-794.
- [10] SCHUSTER M. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 2002, 45(11): 2673-2681.
- [11] HOCHREITER S, SCHMIDHUBER J. Long short-term mem


ory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[12] Mean absolute error [EB]. 2019.

[作者简介]



潘坚跃（1961—），男，国网浙江省电力有限公司杭州供电公司高级工程师，长期从事数据集成、大数据应用分析方面的工作。



吴懿臻（1984—），女，浙江华云信息科技有限公司助理工程师，长期从事数据应用分析、数据挖掘方面的工作。



徐汉麟（1990—），男，国网浙江省电力有限公司杭州供电公司助理工程师，主要研究方向为信息系统及网络安全。