

DOI:10.12158/j.2096-3203.2020.06.011

# 基于贝叶斯优化 XGBoost 的短期峰值负荷预测

龚雪娇, 朱瑞金, 唐波

(西藏农牧学院电气工程学院, 西藏 林芝 860000)

**摘要:**随着电网结构愈发复杂, 负荷的多样性与波动性显著增加, 对预测模型提出了更高的泛化能力和精度要求。然而, 传统算法存在易过拟合、精度低等固有缺陷, 难以实现复杂电网下精准的尖峰负荷预测。为此, 文中提出一种基于贝叶斯优化极限梯度提升(XGBoost)的模型用于短期峰值负荷预测。首先, 通过特征重要度得分进行特征提取, 剔除冗余特征, 确保输入-输出有较优的映射关系; 然后, 引入贝叶斯优化算法进行超参数调优, 使XGBoost的性能达到最佳状态; 最后, 使用国内某市电力负荷数据对所提模型的有效性进行验证, 结果表明, 与其他机器学习方法相比, 贝叶斯优化 XGBoost 具有更高的预测精度。

**关键词:**贝叶斯优化; 极限梯度提升(XGBoost); 峰值负荷; 负荷预测; 超参数

**中图分类号:** TM933

**文献标志码:** A

**文章编号:** 2096-3203(2020)06-0076-06

## 0 引言

随着电网规模不断扩大, 提高电力系统负荷预测准确性对优化电力系统运行意义重大<sup>[1]</sup>。负荷预测精度越高, 越有利于调度部门及时把握负荷需求, 有序安排调度预案, 提升电网资源利用率和供电可靠性<sup>[2-4]</sup>。由于电网中负载的非线性和随机性, 负荷精确预测仍是电网亟待解决的难题<sup>[5-6]</sup>。

目前, 对于短期负荷预测模型, 国内外学者提出了诸多预测模型, 包括人工神经网络、支持向量机(support vector machine, SVM)、随机森林等<sup>[7-11]</sup>。文献[7]提出了一种基于小波分析与二阶灰色神经网络相结合的短期负荷预测方法。文献[8]基于负荷特性搭建 SVM 预测模型。文献[9]利用粒子群优化进一步提升 SVM 的预测精度。针对局部收敛速度慢的问题, 文献[10]应用随机森林算法对短期负荷进行预测。文献[11]通过模糊聚类选取训练样本, 提升随机森林的预测精度。

文献[7-8]提出的模型为简易线性模型, 难以有效挖掘高维非线性负荷数据; 文献[9-11]应用新方法或改进方法提升了预测精度, 但模型复杂度高, 存在过拟合风险。峰值负荷作为反应负荷行为的重要指标, 对优化调度与安全运行具有重要意义。尤其在用电高峰时段, 精准预测峰值负荷, 有助于保障重载区域的供电可靠性, 减少峰值负荷对电网的冲击<sup>[12]</sup>。相较于短期负荷预测模型的研究, 目前关于峰值负荷预测的研究较少。文献[13]建

立前馈神经网络模型预测每日峰值负荷。文献[14]基于机会约束规划构建核回归 SVM 用于尖峰负荷预测。然而, 上述方法均为线性模型, 难以适应复杂电网下的尖峰负荷预测。

极限梯度提升(extreme gradient boosting, XGBoost)是一种高效的集成学习算法, 已经广泛应用于光伏预测、轴承故障诊断、风电功率预测等领域<sup>[15-17]</sup>。为实现精准尖峰负荷预测, 文中将 XGBoost 算法运用于短期峰值负荷预测, 并引入贝叶斯优化算法进行超参数调优。使用国内某市电力负荷数据进行测试, 验证所提方法的有效性。

## 1 XGBoost 算法原理及贝叶斯优化

### 1.1 梯度提升决策树

梯度提升决策树(gradient boosting decision tree, GBDT)是基于决策树(decision tree, DT)的集成学习算法, 训练过程进行多轮迭代, 每轮迭代产生一个弱分类器, 每个分类器在上一轮分类器的残差基础上进行训练。GBDT 算法基本原理步骤如下。

(1) 初始化弱学习器。

$$f_0(x) = \operatorname{argmin} \sum_{i=1}^N L(y_i, \hat{y}_i) \quad (1)$$

式中:  $N$  为样本数;  $L(\cdot)$  为损失函数;  $x$  为输入特征;  $y_i$  为实际值;  $\hat{y}_i$  为预测值。

(2) 对每个样本  $i=1, 2, \dots, N$ , 计算负梯度, 即残差为:

$$r_{im} = -\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \quad (2)$$

式中:  $f(x) = f_{m-1}(x)$ ;  $m=1, 2, \dots, M$ ,  $M$  为迭代次数, 即生成的弱学习器个数。

收稿日期: 2020-05-03; 修回日期: 2020-06-17

基金项目: 西藏自治区自然科学基金资助项目(XZ2019ZR-G-52(Z))

将式(2)求得的残差作为新的真实值,并把数据  $(x_i, r_{im}), i=1, 2, \dots, N$  作为下棵树的训练数据,得到新的回归树  $f_m(x)$ , 其对应的叶子节点区域为  $R_{jm}, j=1, 2, \dots, J, J$  为回归树  $t$  叶子节点的个数。

对叶子区域  $j=1, 2, \dots, J$ , 计算最佳拟合值为:

$$Y_{jm} = \operatorname{argmin}_Y \sum_{x_i \in R_{jm}} L(y_i, f_{m-1}(x_i) + Y) \quad (3)$$

式中:  $Y$  为残差;  $Y_{jm}$  为第  $j$  个叶节点的残差转换值。

更新强学习器为:

$$f_m(x) = f_{m-1}(x) + \sum_{j=1}^J Y_{jm} I_{x \in R_{jm}} \quad (4)$$

(3) 通过上述步骤, 得到最终学习器为:

$$f(x) = f_M(x) = f_0(x) + \sum_{m=1}^M \sum_{j=1}^J Y_{jm} I_{x \in R_{jm}} \quad (5)$$

## 1.2 XGBoost 算法

XGBoost 算法在 GBDT 基础上进行优化改进<sup>[18]</sup>, 对目标函数进行正则化及二阶泰勒展开。XGBoost 的数学模型可看作由  $K$  棵分类与回归树 (classification and regression tree, CART) 组成的加法模型。

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad f_k \in F \quad (6)$$

式中:  $K$  为树的棵数;  $F$  为所有可能的 CART;  $f_k$  为一棵具体的 CART。

在回归过程中, 参数  $\theta = \{f_1, f_2, \dots, f_k\}$ , 则 XGBoost 的目标函数变为:

$$O(\theta) = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (7)$$

式中: 第一部分为损失函数; 第二部分为正则项, 由  $K$  棵树的正则化项相加得到。

对于决策树的正则化项, 通过向量映射对每棵决策树进行改进, 得到 XGBoost 的正则化项为:

$$\Omega(f_i) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (8)$$

式中:  $\gamma, \lambda$  为模型的惩罚系数;  $T$  为树叶的节点个数;  $\omega$  为树叶的分数。

分步骤逐步逼近优化目标函数, 在第  $t$  步时, 在现有的  $t-1$  棵树基础上添加 1 棵最优化的 CART 即  $f_t$ , 则目标函数变为:

$$O(t) = \sum_{i=1}^N l(y_i, \hat{y}^{(t)}) + \sum_{i=1}^t \Omega(f_i) = \sum_{i=1}^N l(y_i, \hat{y}^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (9)$$

将式(9)进行泰勒二级展开得:

$$O(t) = \sum_{i=1}^N \left[ l(y_i, \hat{y}^{(t-1)}) + g_i f_t(x_i) + \right.$$

$$\left. \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (10)$$

式中:  $g_i$  为损失函数的一阶导数;  $h_i$  为损失函数的二阶导数。

$$g_i = \frac{\partial (l(y_i, \hat{y}^{(t-1)}))}{\partial \hat{y}^{(t-1)}} \quad (11)$$

$$h_i = \frac{\partial^2 (l(y_i, \hat{y}^{(t-1)}))}{\partial \hat{y}^{(t-1)^2}} \quad (12)$$

## 1.3 贝叶斯优化原理

贝叶斯优化算法为基于概率分布的优化算法, 2 个核心过程分别为先验函数与采集函数。文中先验函数采用高斯过程回归, 采集函数采用改进概率 (probability of improvement, PI)。贝叶斯优化过程如图 1 所示。

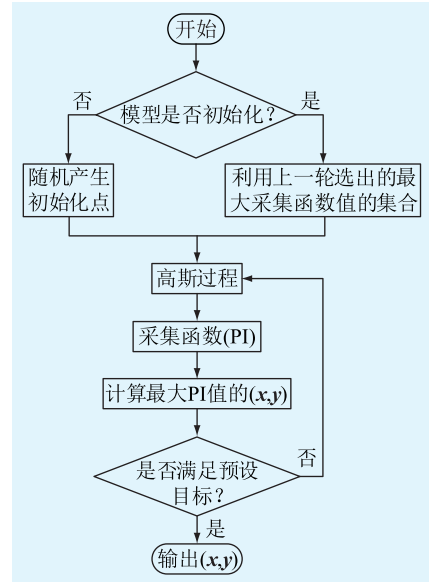


图 1 贝叶斯优化流程

Fig.1 Bayesian optimization flow

### 1.3.1 高斯过程回归

高斯过程可用于非线性分类、参数寻优、非线性回归等。在用于预测时, 高斯过程考虑了  $y_N$  和  $y_{N+1}$  之间的关系, 即:

$$P(y_{N+1} | X_{N+1}, y_N) \quad (13)$$

高斯过程在考虑  $y_N, y_{N+1}$  之间的关系时, 假设  $\mathbf{Y}$  服从联合正态分布, 则需给定参数: 均值向量和协方差矩阵, 即:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \sim N \left( \mathbf{0}, \begin{bmatrix} k(x_1, x_1) & k(x_1, x_2) & \cdots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \cdots & k(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \cdots & k(x_n, x_n) \end{bmatrix} \right) \quad (14)$$

式中:协方差矩阵又称为核矩阵,记为  $\mathbf{K}$ ,其仅与特征  $\mathbf{x}$  有关,与  $\mathbf{y}$  无关。

高斯过程思想是:假设  $\mathbf{Y}$  服从高维正态分布,最优的协方差矩阵可以根据训练集获得,从而得到后验公式来估计测试集  $\mathbf{Y}_*$ ,后验公式为:

$$P(y_* | y \sim N(\mathbf{K}_* \mathbf{K}^{-1} \mathbf{y}, \mathbf{K}_{**} - \mathbf{K}^{-1} \mathbf{K}_*^T)) \quad (15)$$

式中: $\mathbf{K}_*$  为训练集的核向量,满足式(16); $\mathbf{K}_{**}$  为新加入样本的核向量。

$$\begin{bmatrix} y \\ y_* \end{bmatrix} \sim N\left(0, \begin{bmatrix} \mathbf{K} & \mathbf{K}_*^T \\ \mathbf{K}_* & \mathbf{K}_{**} \end{bmatrix}\right) \quad (16)$$

由式(16)可知,只有均值与训练集  $\mathbf{Y}$  有关,方差则仅与核矩阵  $\mathbf{x}$  有关,与训练集  $\mathbf{K}$  无关。

### 1.3.2 采集函数

常见的采集函数有 3 种:置信区间上界(upper confidence bound, UCB)、PI、预期改进(expected improvement, EI),文中主要介绍 PI 函数。

$$f_{PI}(x) = P(f(x) \geq f(x^+) + \theta) = \Phi\left(\frac{\mu(x) - f(x^+) - \theta}{\sigma(x)}\right) \quad (17)$$

式中: $\Phi(\cdot)$  为正态累积分布函数; $f(x)$  为目标函数值; $f(x^+)$  为目前最优的目标函数值; $\mu(x)$ ,  $\sigma(x)$  分别为高斯过程所得目标函数的均值、方差,即  $f(x)$  的后验分布; $\theta$  为超参数,用于探索未知的空间或在最大值附近进行探索, $\theta$  为 0 则倾向于收敛到  $f(x^+)$  附近,避免陷入局部最优。

利用贝叶斯优化 XGBoost 进行短期负荷预测的执行步骤为:

- (1) 设定待优化参数范围,优化目标为决定系数  $R_2$ ;
- (2) 利用贝叶斯对 XGBoost 进行优化;
- (3) 返回优化的  $R_2$  最大值及对应 XGBoost 模型的超参数。
- (4) 将贝叶斯优化 XGBoost 模型的超参数作为最终 XGBoost 模型的参数。

### 1.4 模型框架

所提基于贝叶斯优化 XGBoost 的负荷预测模型如图 2 所示。首先,基于负荷历史数据和天气数据构建数据集,并对数据进行必要的归一化及缺失值处理。基于数据集对 XGBoost 进行训练,获取每个特征的重要度,剔除低贡献度的输入特征,减少占用的计算机资源。利用高贡献度的特征重新训练 XGBoost 模型,并引入贝叶斯优化算法进行超参数调优,提升模型预测性能。训练好的 XGBoost 模型可用于短期尖峰负荷预测,输入待评估时段高贡献度的特征数据,预测未来尖峰负荷值,为优化调度与

安全运行提供参考。




图 2 基于贝叶斯优化 XGBoost 的峰值负荷预测模型

Fig.2 The model of peak load forecasting based on Bayesian optimized XGBoost

## 2 峰值负荷预测特征与模型评价指标

### 2.1 特征重要程度排序

原始输入特征数据中存在相似或冗余的输入特征,在模型训练过程中必然会浪费大量的计算机资源,降低模型的训练速度和泛化能力。为了提高贝叶斯优化 XGBoost 模型的学习速度和预测性能,应保证该模型的输入特征数据与预测输出峰值负荷有较强的映射关系。文中以输入特征的重要程度得分为依据,结合预先设定的阈值选择重要的输入特征。在 XGBoost 模型中,特征的相对重要性可通过计算该特征在所有树中被用作分割样本的次數得到。

### 2.2 特征相关性分析

通过皮尔逊相关系数分析输入特征间的相关性,确定是否存在冗余特征。相关系数的大小表示 2 个变量  $C_1, C_2$  之间的线性相关程度,计算公式为:

$$r_{C_1, C_2} = \frac{\sum_{i=1}^N (C_{1,i} - \bar{C}_1)(C_{2,i} - \bar{C}_2)}{\delta_{C_1} \delta_{C_2}} \quad (18)$$

式中: $\delta_{C_1}, \delta_{C_2}$  分别为  $C_1, C_2$  的标准偏差; $r \in [-1, 1]$ ,  $|r|$  越接近 1,则 2 个输入特征间的相关性越强,  $|r|$  越接近 0,则 2 个输入特征间的相关性越弱。

### 2.3 模型评价指标

选用平均绝对百分比误差(mean absolute percentage error, MAPE)和决定系数  $R_2$  综合评估模型的预测性能,分别如式(19)、式(20)所示。

$$e_{MAPE} = \frac{\sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right|}{N} \quad (19)$$

$$R_2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2} \quad (20)$$

式中: $\bar{y}$  为实际峰值负荷的平均值。

### 3 实验结果与分析

#### 3.1 输入输出特征数据

文中的实验数据选用中国某市每日的电力负荷供需数据和每日的平均、最低、最高温度数据。选取 2017-01-01—2019-01-31 的数据。该数据集的输入特征如表 1 所示。

表 1 数据集的输入特征  
Table 1 Input characteristics of the data set

输入特征	含义
$a_1$	净尖峰供电能力
$a_2$	备转容量
$a_3$	备转容量率
$a_4$	工业用电
$a_5$	民生用电
$a_6 \sim a_{11}$	各核电站发电量
$a_{12} \sim a_{67}$	各火电厂和水电站发电量
$a_{68}$	风力发电量
$a_{69}$	太阳能发电量
$a_{70}$	平均温度
$a_{71}$	最低温度
$a_{72}$	最高温度

将表 1 中的特征作为贝叶斯优化 XGBoost 模型的输入,预测某市未来一周的峰值负荷。

#### 3.2 特征重要程度排序

将贝叶斯优化后的 XGBoost 对输入数据特征变量的重要性进行排序,统计每个特征在所有树中被用作分割样本的次数,选择重要程度前 30 的特征作为输入特征,并进行降序排序,如图 3 所示。




图 3 特征重要程度排序

Fig.3 Ranking graph of feature importance

#### 3.3 特征相关性分析

重要特征之间的相关关系见图 4,图中颜色越白或越黑,则表明 2 个特征间的相关性越强。模型的每个输入特征应该是最佳的,并能很好地映射到

峰值负荷值。从图中可以看出,备转容量  $a_2$  和备转容量率  $a_3$  具有较强的相关性;同时,最高温度  $a_{72}$ 、最低温度  $a_{71}$ 和平均温度  $a_{70}$ 三者两两间的相关性也较强。结合特征重要程度值的高低,相关性强的特征中保留备转容量率  $a_3$  和最高温度  $a_{72}$ 作为输入。




图 4 重要特征间的相关系数

Fig.4 The correlation coefficients between important features

#### 3.4 不同模型性能比较

为了验证贝叶斯优化的 XGBoost 模型性能,将其与 XGBoost、SVM 和 DT 的峰值负荷预测效果进行比较。SVM 和 DT 的参数为 python 机器学习库 stick-learn 中的默认参数。未被优化的 XGBoost 模型参数为:最大层数 149;学习率 0.01;迭代次数 2 000。测试效果如图 5 所示。




图 5 不同模型的短期峰值负荷预测

Fig.5 Short-term peak load forecasting of different models

由图 5 可知,贝叶斯优化 XGBoost 模型的未来一周短期峰值负荷预测结果与实际值最为接近,模型具有较好的预测效果。进一步比较不同模型的预测性能,采用 MAPE 和  $R_2$ 对 4 种模型进行综合评价,结果见表 2。由表 2 可知,XGBoost 将多个基学习器进行集成增加了输出多样性,有效提升了预测精度,与 DT 和 SVM 模型相比,XGBoost 的 MAPE 分别下降了 50%,84.5%。通过贝叶斯优化搜索超参

数,进一步提升了 XGBoost 的预测精度。贝叶斯优化 XGBoost 的 MAPE 比 XGBoost 的 MAPE 降低 29.03%,且  $R_2$  基本接近于 1,体现了贝叶斯优化 XGBoost 模型的优越性。

表 2 4 种模型预测性能综合评价  
Table 2 Comprehensive evaluation on prediction performance of four models

算法	$e_{MAPE}$	$R_2$
贝叶斯优化 XGBoost	0.440	0.990
XGBoost	0.620	0.983
DT	1.240	0.887
SVM	4.000	0.316

#### 4 结语

针对实际的短期峰值负荷预测,提出了贝叶斯优化 XGBoost 模型。通过特征重要程度和特征相关性分析降低特征维度,使输入特征变量和峰值负荷具有较好的映射关系。通过贝叶斯优化确定超参数,使 XGBoost 的性能达到最优。模型能很好地挖掘输入与输出之间的映射关系,在实际短期峰值负荷预测中效果较好,验证了文中所提算法的有效性。

文中所提预测方法可为电力调度的方案制定提供参考,合理确定各发电厂的出力及备用容量,提高电网迎峰度夏供电服务能力。后续将在以下方面进一步研究。

(1) 除温度因素,进一步考虑节假日、电价等因素的影响,充分挖掘负荷大数据特性,更好地构建短期峰值负荷模型;

(2) 采用并行集群技术对大规模负荷数据进行处理,提升数据挖掘潜力及分析速度,提高预测实时性。

#### 参考文献:

[1] 张智晟,于道林. 考虑需求响应综合影响因素的 RBF-NN 短期负荷预测模型[J]. 中国电机工程学报,2018,38(6):1631-1638.  
ZHANG Zhisheng, YU Daolin. RBF-NN based short-term load forecasting model considering comprehensive factors affecting demand response[J]. Proceedings of the CSEE, 2018, 38(6): 1631-1638.

[2] 康重庆,夏清,刘梅. 电力系统负荷预测[M]. 北京:中国电力出版社,2007.  
KANG Chongqing, XIA Qing, LIU Mei. Power load forecasting [M]. Beijing: China Electric Power Press, 2007.

[3] 王灵娇,夏伟,谭貌,等. 供电系统电力短期负荷预测优化仿真研究[J]. 计算机仿真,2018,35(4):53-57.  
WANG Lingjiao, XIA Wei, TAN Mao, et al. Power system short-term load forecasting optimization simulation research[J]. Com-

puter Simulation, 2018, 35(4):53-57.

[4] 李龙,魏靖,黎灿兵,等. 基于神经网络的负荷模型预测[J]. 电工技术学报,2015,30(8):225-230.  
LI Long, WEI Jing, LI Canbing, et al. Prediction of load model based on artificial neural network [J]. Transactions of China Electrotechnical Society, 2015, 30(8):225-230.

[5] 李昭昱,艾芊,张宇帆,等. 基于 attention 机制的 LSTM 神经网络超短期负荷预测方法[J]. 供用电,2019,36(1):17-22.  
LI Zhaoyu, AI Qian, ZHANG Yufan, et al. A LSTM neural network method based on attention mechanism for ultra short-term load forecasting [J]. Distribution & Utilization, 2019, 36(1):17-22.

[6] 赵立强,杨镜非,张美霞,等. 基于相似日选择和 BP 神经网络的商场短期负荷预测[J]. 供用电,2019,36(1):23-28.  
ZHAO Liqiang, YANG Jingfei, ZHANG Meixia, et al. Short-term load forecasting of shopping malls based on similar day method and BP neural network [J]. Distribution & Utilization, 2019, 36(1):23-28.

[7] LI Bowen, ZHANG Jing, HE Yu, et al. Short-term load-forecasting method based on wavelet decomposition with second-order gray neural network model combined with ADF test [J]. IEEE Access, 2017, 10(7):16324-16331.

[8] ERVIN C, VLADIMIR C, ADRIJAN B. A strategy for short-term load forecasting by support vector regression machines [J]. IEEE Transactions on Power Systems, 2013, 28(4):4356-4364.

[9] 王义军,李殿文,高超,等. 基于改进的 PSO-SVM 的短期电力负荷预测[J]. 电测与仪表,2015,52(3):22-25.  
WANG Yijun, LI Dianwen, GAO Chao, et al. Short-term power load forecasting based on improved PSO-SVM [J]. Electrical Measurement & Instrumentation, 2015, 52(3):22-25.

[10] KENJI N F, ANNA D P L, CARLOS R M. Short-term multi-nodal load forecasting using a modified general regression neural network [J]. IEEE Transactions on Power Delivery, 2011, 26(4):2862-2869.

[11] 吴潇雨,和敬涵,张沛,等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测[J]. 电力系统自动化,2015,39(12):50-55.  
WU Xiaoyu, HE Jinghan, ZHANG Pei, et al. Power system short-term load forecasting based on improved random forest with grey relation projection [J]. Automation of Electric Power Systems, 2015, 39(12):50-55.

[12] 冯明灿,谢宁,王承民,等. 考虑瞬时性峰值负荷特性的配电网可靠性规划[J]. 电网技术,2015,39(3):757-762.  
FENG Mingcan, XIE Ning, WANG Chengmin, et al. Reliability planning of distribution power network considering the characteristics of short-term peak load [J]. Power System Technology, 2015, 39(3):757-762.

[13] 董立文,范澍. 基于自组织映射网络的峰值负荷预测方法[J]. 中国电力,2007,30(8):32-35.  
DONG Liwen, FAN Shu. Peak load forecasting using the self-organizing map [J]. Electric Power, 2007, 30(8):32-35.

[14] 蒋刚. 基于模糊支持向量核回归方法的短期峰值负荷预测

- [J]. 控制理论与应用,2007,24(6):986-990.  
JIANG Gang. Short-term peak load forecasting based on fuzzy support vector kernel regression method[J]. Control Theory and Applications,2007,24(6):986-990.
- [15] 张小博,王婷,秦浩,等. 基于循环神经网络的 95598 小尺度网络流量预测[J]. 电力信息与通信技术,2019,17(2):9-14.  
ZHANG Xiaobo, WANG Ting, QIN Hao, et al. A prediction method for 95598 small scale network traffic[J]. Electric Power Information and Communication Technology,2019,17(2):9-14.
- [16] 吴定会,郑洋,韩欣宏. 基于多特征融合与 XGBoost 的风机轴承故障诊断[J]. 传感器与微系统,2020,39(7):145-149.  
WU Dinghui, ZHENG Yang, HAN Xinhong. Fault diagnosis of wind turbine bearing based on multi-feature fusion and XGBoost[J]. Transducer and Microsystem Technologies,2020,39(7):145-149.
- [17] 杨森,刘三明,王致杰. 基于 GRU-XGBoost 的风电场功率短期预测[J]. 仪表技术,2020,30(1):17-21.  
YANG Sen, LIU Sanming, WANG Zhijie. Short-term prediction of wind farm power based on GRU-XGBoost[J]. Instrumentation Technology,2020,30(1):17-21.
- [18] 李浩,朱焱. 基于梯度分布调节策略的 XGBoost 算法优化[J]. 计算机应用,2020,40(6):1633-1637.  
LI HAO, ZHU Yan. XGBoost algorithm optimization based on gradient distribution harmonized strategy[J]. Journal of Computer Applications,2020,40(6):1633-1637.

---

作者简介:



龚雪娇

龚雪娇(1989),女,硕士,讲师,研究方向为新能源发电技术(E-mail:gxj2018@hhu.edu.cn);

朱瑞金(1986),男,硕士,副教授,研究方向为智能算法及其应用;

唐波(1991),男,硕士,讲师,研究方向为智能算法及其应用。

## Short-term peak load forecasting based on Bayesian optimization XGBoost

GONG Xuejiao, ZHU Ruijin, TANG Bo

(School of Electrical Engineering, Tibet Agriculture & Animal Husbandry College, Linzhi 860000, China)

**Abstract:** With the increasing complexity of integrated load structure of power grid, the diversity and volatility of the load increase significantly. Higher generalization ability and accuracy are required for the prediction model. However, the traditional algorithms have inherent defects such as easy overfitting and low accuracy, making it difficult to achieve accurate peak load forecasting under complex grids. To solve above problems, Bayesian optimized XGBoost model for short-term peak load forecasting is proposed. Firstly, the important features are screened through feature importance score to ensure better mapping relationship between input and output. Then, Bayesian optimization algorithm is introduced to determine the hyper-parameters to ensure the best state performance of XGBoost. Effectiveness of the proposed model is verified using power load data of a certain city in China. The results show that Bayesian optimized XGBoost has higher prediction accuracy compared with other machine learning methods.

**Keywords:** Bayesian optimization; extreme gradient boosting(XGBoost); peak load; load prediction; hyper-parameter

(编辑 吴楠)