

基于XGBoost与Stacking模型融合的短期母线负荷预测

刘波¹,秦川¹,鞠平¹,赵静波²,陈彦翔¹,赵健³

(1. 河海大学 能源与电气学院,江苏 南京 211100;

2. 国网江苏省电力有限公司电力科学研究院,江苏 南京 210008;

3. 国网南京供电公司,江苏 南京 210019)

摘要:母线负荷预测对于电网安全稳定调度具有重要意义,但母线负荷随机波动性较强,其负荷类型因供电区域的差异而不同。为此,提出一种基于极限梯度提升(XGBoost)与Stacking模型融合的短期母线负荷预测方法。基于XGBoost建立多个母线负荷预测元模型,组合构成Stacking模型融合的元素模型层,连接一个XGBoost模型对元模型进行融合,整体构成综合预测系统,并采用粒子群优化算法优化系统参数。通过对具有不同负荷属性的220 kV母线进行实例分析,验证了所提方法的有效性与适用性。

关键词:母线负荷;XGBoost;元模型;Stacking模型融合;粒子群优化算法

中图分类号:TM 715

文献标志码:A

DOI:10.16081/j.epae.202002024

0 引言

母线负荷是指由变电站主变压器供给某个供电区域终端负荷的总和^[1]。精准的负荷预测可以有效提升电网调度水平,有利于电网安全稳定运行^[2-3]。负荷预测包括系统负荷预测与母线负荷预测。相较于系统负荷,母线负荷量级低,随机性强,且由于供电区域用户性质的差异,各母线的负荷成分可能不同,比如某些母线以居民和商业负荷为主,而某些母线则包含工业负荷。不同类型负荷的变化规律不同,对负荷预测精度的影响也不同。因此,母线负荷的预测难度更大。

已有学者从不同角度对母线负荷预测进行了研究^[4-11]。母线负荷易受多种相关因素的影响,包括历史负荷、日期类型、气象因素等,考虑这些因素有助于提升预测精度^[4]。文献[5]将预测辅助状态估计与多层感知器神经网络顺序连接构成混合预测系统,以用于短期母线负荷预测。文献[8]基于人工神经网络开发母线日负荷与小时负荷预测模型,并通过聚类方法提升预测精度。针对母线负荷数据中含有较多坏数据的情况,文献[9-11]以数据预处理为工作重点,对母线负荷坏数据进行辨识与修复,以提升预测效果。

负荷预测通常为多步预测,基本策略主要有直接法和迭代法。直接法为直接向前预测多步,一次性得到完整预测结果;迭代法为一次向前预测一步,

每次在上一步预测值的基础上继续下一步预测。一般而言,迭代法优于直接法。在预测方法层面,传统负荷预测方法大多是由输入经单个预测模型后得到输出,模型的偏差直接影响预测效果。为了降低模型偏差,提高预测精度,一方面可设计更精确的新模型,另一方面可采用模型融合方法优化已有的预测模型。已有研究表明,将集成学习或模型融合的思想运用到负荷预测中可弱化单个模型的偏差影响,改进最终预测效果^[12-18]。文献[14]针对不同负荷聚合体建立不同结构的门控循环单元(GRU)网络,并采用随机森林RF(Random Forest)算法进行集成,提升了对不同规模负荷聚合体预测的适用性。文献[15]设计一个集成预测框架,基于多源数据构建多个训练集,同时建立多个非线性异构模型进行一次学习,依据一次学习的结果生成新训练集,并用于二次学习以实现最终的预测。

模型融合的思想是将多个个体模型按照一定方式进行组合,构成多模型综合系统,以期获得更好的学习效果。目前,基于加权组合和bagging算法的模型融合应用较多,基于Stacking模型融合的应用较少。Stacking模型融合是一种分层模型集成框架,其主要思想是将个体预测模型作为元模型,在其组合的基础上再连接一个预测模型,即将元模型的输出作为后一层预测模型的输入,该模型的输出为最终预测结果。为了保证模型融合的有效性,元模型之间要具有一定的互补性,其结构和参数不能完全一致。

本文提出基于极限梯度提升XGBoost(eXtreme Gradient Boosting)算法与Stacking模型融合的短期母线负荷预测方法,对母线日负荷曲线进行迭代预测。基于XGBoost建立多个母线负荷预测模型,以此构成Stacking模型融合的元素模型层,并在元模型层之后连接一个XGBoost模型,作为融合元模型的

收稿日期:2019-05-14;修回日期:2019-12-25

基金项目:国家自然科学基金重点资助项目(51837004);“111”计划(新能源发电与智能电网学科创新引智基地)(B14022) Project supported by the Key Program of the National Natural Science Foundation of China(51837004) and “111” Project(Innovation and Intelligence Introduction Base of Subject of Renewable Energy and Smart Grid)(B14022)

预测模型,从而构成XGBoost-Stacking模型融合母线负荷预测系统。针对各元模型结构和参数不一致且难以调整的情况,采用粒子群优化PSO(Particle Swarm Optimization)算法优化预测系统参数。对不同类型母线负荷的实例分析验证了所提方法的有效性与适用性。

1 XGBoost

XGBoost是借助梯度提升技术得以实现的机器学习算法,其基分类器是分类与回归树(CART)。XGBoost将多个CART进行组合^[19],即XGBoost为树集成模型,其示意图如图1所示。图中, K 为树的数量,即为提升迭代次数; Z 为树的最大深度。

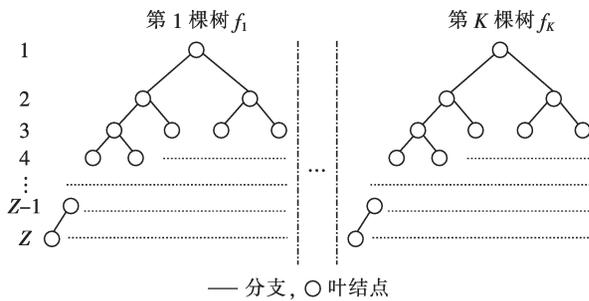


图1 树集成模型示意图

Fig.1 Schematic diagram of tree ensemble model

1.1 正则化学习目标

假设一个具有 n 个样本和 m 个特征的给定数据集为 $D = \{(X_i, y_i)\} (|D| = n, X_i \in \mathbf{R}^m, y_i \in \mathbf{R})$ 。其中, $|D|$ 表示集合 D 的维度,即集合 D 所包含的样本数量; X_i 为第 i 个样本的特征向量; y_i 为第 i 个样本的标签,即真实值。采用由 K 棵树集成的模型预测输出,如式(1)所示。

$$\hat{y}_i = \sum_{k=1}^K f_k(X_i), f_k \in \Gamma \quad (1)$$

其中, $\Gamma = \{f(X) = \omega_{q(X)}\} (q: \mathbf{R}^m \rightarrow T, \omega_{q(X)} \in \mathbf{R}^T)$ 为CART的函数空间, $X = (X_1, X_2, \dots, X_n)$, q 为每棵树的结构, T 为叶结点的数量,每个 f_k 都对应一个独立的树结构 q 与叶权重 ω 。为了学习 K 棵树的函数集,要最小化式(2)所示的正则化目标函数。

$$L = \sum_i l(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (2)$$

其中,损失函数项 $l(y_i, \hat{y}_i) = (y_i - \hat{y}_i)^2$;正则项 $\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2$,其作为模型复杂度的惩罚项,有助于避免过拟合, γ 控制叶结点的数量 T , λ 控制叶权重 ω 不会过大。

1.2 梯度提升

XGBoost模型以迭代添加树的方式建立, $\hat{y}_i^{(t)}$

为第 t 次迭代时第 i 个样本的预测值(在实际应用中,通常令 $\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \varepsilon f_t(X_i)$,其中 ε 为缩减权重,即学习率,其作用是弱化每棵树的影响,留更多的空间给后面的树提升)。迭代地添加树使目标函数式(3)不断降低,以最小化目标函数。

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(X_i)) + \Omega(f_t) \quad (3)$$

为了快速优化目标,对式(3)使用二阶泰勒展开,如式(4)所示。

$$L^{(t)} \approx \sum_{i=1}^n \left(l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(X_i) + \frac{1}{2} h_i f_t^2(X_i) \right) + \Omega(f_t) \quad (4)$$

其中, $g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$, $h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)})$ 分别为损失函数项的一阶和二阶导数。在添加第 t 棵树时,前面 $t-1$ 棵树已经训练完成,即 $l(y_i, \hat{y}_i^{(t-1)})$ 为常数项,移除该项获得第 t 步的简化目标函数,如式(5)所示。

$$\tilde{L}^{(t)} = \sum_{i=1}^n \left(g_i f_t(X_i) + \frac{1}{2} h_i f_t^2(X_i) \right) + \Omega(f_t) \quad (5)$$

定义 $I_j = \{i | q(X_i) = j\}$ 为叶结点 j 的样本集。通过展开正则项 Ω 可将式(5)写为:

展开正则项 Ω 可将式(5)写为:

$$\begin{aligned} \tilde{L}^{(t)} &= \sum_{i=1}^n \left(g_i \omega_{q(X_i)} + \frac{1}{2} h_i \omega_{q(X_i)}^2 \right) + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 = \\ &= \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) \omega_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T \end{aligned} \quad (6)$$

其中, ω_j 为叶结点 j 的权重。

对于固定结构 $q(X)$,叶结点 j 的最优权重 ω_j^* 如式(7)所示,相应的最优目标函数值如式(8)所示。

$$\omega_j^* = - \sum_{i \in I_j} g_i / \left(\sum_{i \in I_j} h_i + \lambda \right) \quad (7)$$

$$\tilde{L}^{(t)}(q) = - \frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i \right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (8)$$

式(8)为评价树结构 q 的评分函数,得分越小,说明树的结构越好。对于树结构的建立,采用贪心算法对树进行分支,从单个叶结点开始,迭代地添加分割点以分裂叶结点进行分支。

叶结点的分裂是基于特征(即模型的输入变量)进行的,某输入变量被应用于叶结点分裂的次数可认为是该输入变量的重要性得分,反映了该输入变量与模型输出结果之间的相关性。因此可根据输入变量重要性得分来选择XGBoost的输入。

综上所述,XGBoost模型建立的原理流程图如

图 2 所示。XGBoost 的正则化提升可有效避免负荷预测中容易出现的过拟合问题,再基于 XGBoost 模型进行 Stacking 模型融合可进一步提升预测效果。

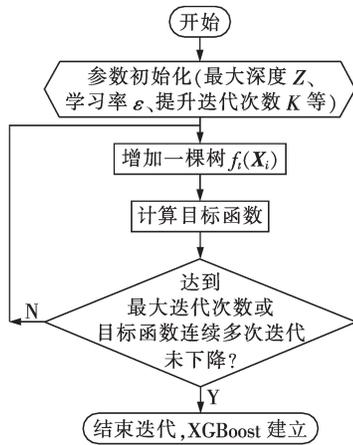


图 2 XGBoost 建立流程图

Fig.2 Flowchart of establishing XGBoost

2 Stacking 模型融合

本文将 Stacking 模型融合应用于多个不同的 XGBoost 模型的集成,以提升母线负荷预测精度。

Stacking 模型融合系统设计为 2 层结构,既能强化学习效果又不至于造成预测模型过冗余复杂。第一层由 N 个不同的元模型集成,构成融合系统的元模型层,再连接一个预测模型作为第二层,从而对 N 个元模型进行融合。

假设输入为 X_i ,记第一层第 h 个元模型为 F_h ,第二层预测模型为 F ,则第一层第 h 个元模型的输出为

$F_h(X_i)$,第二层预测模型以 $F_h(X_i)$ 作为输入,其输出 y_i 为最终预测结果,如式(9)所示。

$$y_i = F(F_1(X_i), \dots, F_h(X_i), \dots, F_N(X_i)) \quad (9)$$

Stacking 模型融合过程如图 3 所示,整体分为 2 个步骤。

(1) 利用元模型层生成训练集与测试集的 N 组预测值。

基于交叉验证思想,将训练集划分为 5 份,记为 S_1-S_5 。首先,应用 S_2-S_5 训练元模型 1,并基于训练好的元模型 1 对 S_1 和测试集进行预测;然后,再应用 S_1, S_3-S_5 重新训练元模型 1,对 S_2 与测试集进行预测。依此类推,基于元模型 1 获得 S_1-S_5 的预测值(组合得到训练集的第 1 组预测值)以及测试集的 5 组预测值(5 组预测值的平均值作为测试集的第 1 组预测值)。

同理,对元模型 2— N 重复上述步骤,可获得训练集与测试集的第 2— N 组预测值。

(2) 利用由元模型层输出的训练集的 N 组预测值构建新的训练集,用于第二层预测模型的训练;利用由元模型层输出的测试集的 N 组预测值构建新的测试集,用于第二层预测模型的预测,获得最终预测值。

不同的元模型具有不同的误差特性,模型融合的目的是弱化单一元模型的误差影响,使融合系统预测性能得到提升。针对各元模型结构和参数不一致且难以调整的情况,本文采用 PSO 算法优化系统参数,具体包括各元模型以及第二层预测模型的参

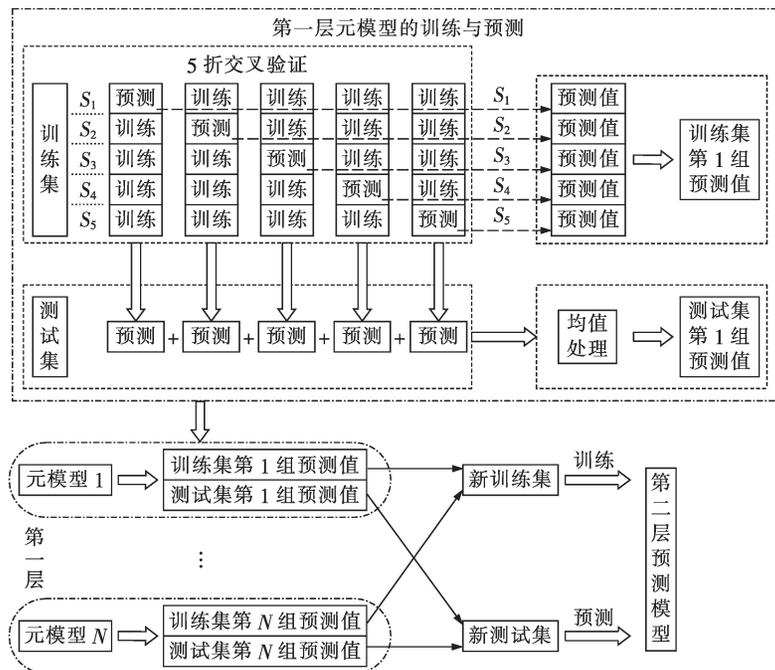


图 3 Stacking 模型融合过程

Fig.3 Process of Stacking model fusion

数。本文将多个 XGBoost 模型进行 Stacking 融合, XGBoost 的典型参数包括树的最大深度 Z 、学习率 ε 以及提升迭代次数 K 。其中, K 通常设置得较大并附加“早停”规则,“早停”规则设置为连续迭代达到 10 次未出现提升则停止迭代。因此,基于 PSO 算法优化的参数为各个 XGBoost 模型的学习率 ε 和树的最大深度 Z 。

将不同的 XGBoost 模型作为 Stacking 模型融合系统第一层的元模型,将另一 XGBoost 模型作为第二层的预测模型,使 XGBoost 的性能得到最大化的发挥。元模型的数量对融合效果具有直接影响,元模型数量较少不能有效实现各元模型间的互补,数量过多则会造成冗余,且使系统调参复杂。通常,Stacking 模型融合的元模型数量为 3~5 个,经过测试得知 3 个元模型的融合效果最佳,因此,Stacking 模型融合预测系统的元模型数量取 3 个,预测系统的流程图如图 4 所示。

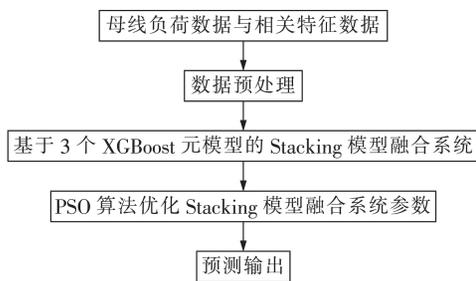


图4 预测系统流程图

Fig.4 Flowchart of forecasting system

3 算例验证与分析

3.1 评价指标与算例数据

3.1.1 评价指标

根据国家电网公司发布的《国家电网公司日前负荷预测管理规定》，母线负荷预测考核指标采用单母线 t 时刻的负荷预测引用误差 E_t ，其定义为：

$$E_t = \frac{|P'_t - P_t|}{P_B} \times 100\% \quad (10)$$

其中, P'_t 为单母线 t 时刻的负荷预测值,单位为 MW; P_t 为单母线 t 时刻的负荷真实值,单位为 MW; P_B 为负荷基准值,220 kV 母线负荷基准值为 305 MV·A。

3.1.2 算例数据

算例为某地区 2 条供给不同类型负荷的 220 kV 母线:母线 1 的负荷主要为居民和商业负荷;母线 2 的负荷为工业与非工业混合负荷,比例约为 2:1。数据采集粒度为 15 min,每日 96 个数据。样本集时间跨度为 2017-01-01 至 2018-10-23。

母线负荷数据中往往掺杂部分坏数据,易对模型训练造成干扰,影响母线负荷预测的精度。参考

文献[9],本文采用 db4 小波去噪法处理母线负荷数据的异常波动,平滑异常干扰值。

3.2 预测模型训练集与输入变量

分别以 2018 年 1 月、4 月、8 月为测试集检验所提方法对冬季、春秋季节、夏季母线负荷的预测效果,预测目标为每日 96 点日负荷曲线,训练集可有 2 种选择:一种为与待预测时段属于相同季节的历史样本集(以下称为季节样本集);另一种为待预测时段之前的全部历史样本集(以下称为全样本集)。具体如下表 1 所示。

表 1 训练集与测试集的配置

数据集	时间			
	冬季	春秋季节	夏季	
训练集	季节样本集	2017年1、2、12月	2017年3—5、9—11月, 2018年3月	2017年6—8月, 2018年6、7月
	全样本集	2017年1—12月	2017年1月至2018年3月	2017年1月至2018年7月
测试集	2018年1月	2018年4月	2018年8月	

在训练元模型时,首先需要确定元模型的输入变量,相关性较高的可选输入变量包括历史负荷、时间属性以及温度因素等,如表 2 所示。由于 XGBoost 训练时可获取各输入变量的重要性得分,基于 2017 年样本集得到输入变量重要性并排序,结果见表 3,

表 2 可选输入变量

符号	说明	符号	说明
v_1	月份	v_9	2 d 前时刻负荷
v_2	工作日/节假日	v_{10}	3 d 前时刻负荷
v_3	时刻	v_{11}	4 d 前时刻负荷
v_4	预测时刻温度	v_{12}	5 d 前时刻负荷
v_5	预测日平均温度	v_{13}	6 d 前时刻负荷
v_6	前一日时刻温度	v_{14}	7 d 前时刻负荷
v_7	前一日平均温度	v_{15}	前一时刻负荷
v_8	1 d 前时刻负荷		

表 3 预测模型输入变量重要性排名

Table 3 Ranking of importance for input variables of forecasting model

样本集	重要性排名	
	母线 1	母线 2
春秋季节样本集	$v_3 > v_{15} > v_4 > v_8 > v_6 > v_5 > v_{14} > v_9 > v_{11} > v_{12} > v_{10} > v_{13} > v_7 > v_2 > v_1 > v_7$	$v_{15} > v_3 > v_8 > v_{14} > v_4 > v_{11} > v_9 > v_6 > v_{14} > v_{12} > v_{10} > v_{13} > v_7 > v_5 > v_1 > v_2$
	$v_3 > v_{15} > v_4 > v_{14} > v_6 > v_{12} > v_8 > v_5 > v_{13} > v_{10} > v_9 > v_{11} > v_7 > v_2 > v_1$	$v_{15} > v_3 > v_8 > v_4 > v_{11} > v_9 > v_6 > v_{14} > v_{12} > v_{10} > v_{13} > v_5 > v_7 > v_1 > v_2$
	$v_{15} > v_3 > v_4 > v_8 > v_9 > v_6 > v_{10} > v_{14} > v_{12} > v_{11} > v_{13} > v_5 > v_7 > v_1 > v_2$	$v_{15} > v_3 > v_8 > v_4 > v_6 > v_{14} > v_9 > v_{10} > v_{12} > v_{13} > v_{11} > v_7 > v_5 > v_1 > v_2$
夏季样本集	$v_3 > v_{15} > v_4 > v_8 > v_6 > v_{14} > v_9 > v_{11} > v_{12} > v_{10} > v_{13} > v_7 > v_2 > v_1$	$v_3 > v_{15} > v_8 > v_4 > v_{14} > v_6 > v_{11} > v_{13} > v_{12} > v_9 > v_7 > v_5 > v_1 > v_2$
	$v_{15} > v_3 > v_4 > v_8 > v_9 > v_6 > v_{10} > v_{14} > v_{12} > v_{11} > v_{13} > v_5 > v_7 > v_1 > v_2$	$v_{15} > v_3 > v_8 > v_4 > v_6 > v_{14} > v_9 > v_{10} > v_{12} > v_{13} > v_{11} > v_7 > v_5 > v_1 > v_2$
	$v_3 > v_{15} > v_4 > v_8 > v_6 > v_{14} > v_9 > v_{11} > v_{12} > v_{10} > v_{13} > v_7 > v_2 > v_1$	$v_3 > v_{15} > v_8 > v_4 > v_{14} > v_6 > v_{11} > v_{13} > v_{12} > v_9 > v_7 > v_5 > v_1 > v_2$
冬季样本集	$v_{15} > v_3 > v_4 > v_8 > v_9 > v_6 > v_{10} > v_{14} > v_{12} > v_{11} > v_{13} > v_5 > v_7 > v_1 > v_2$	$v_{15} > v_3 > v_8 > v_4 > v_6 > v_{14} > v_9 > v_{10} > v_{12} > v_{13} > v_{11} > v_7 > v_5 > v_1 > v_2$
	$v_3 > v_{15} > v_4 > v_8 > v_6 > v_{14} > v_9 > v_{11} > v_{12} > v_{10} > v_{13} > v_7 > v_2 > v_1$	$v_3 > v_{15} > v_8 > v_4 > v_{14} > v_6 > v_{11} > v_{13} > v_{12} > v_9 > v_7 > v_5 > v_1 > v_2$
	$v_{15} > v_3 > v_4 > v_8 > v_9 > v_6 > v_{10} > v_{14} > v_{12} > v_{11} > v_{13} > v_5 > v_7 > v_1 > v_2$	$v_{15} > v_3 > v_8 > v_4 > v_6 > v_{14} > v_9 > v_{10} > v_{12} > v_{13} > v_{11} > v_7 > v_5 > v_1 > v_2$

可得到以下结论:

(1)历史负荷变量的重要性排名普遍靠前,说明了历史负荷对于母线负荷预测的重要性;

(2)相较于母线2,母线1更易受到时刻与温度的影响,原因在于母线1的负荷主要为居民和商业负荷,具有更显著的时间规律性以及温度敏感性;

(3)对于单独一条母线,采用不同规模的样本集,输入变量重要性的排名总体上变化不大。

输入变量重要性越高说明该变量与预测输出的相关性越高,去除重要性较低的输入变量反而能降低冗余度。经过测试,根据输入变量重要性排名,选择排名靠前的11个变量作为预测模型的输入,预测效果最佳,因此,后续实验中均以排名靠前的11个变量作为元模型的输入。此外,训练集分别采用季节样本集和全样本集时的预测引用误差如图5所示。

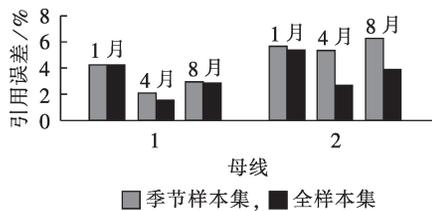


图5 采用不同训练集的预测结果

Fig.5 Forecasting results of different training sets

由图5可知,对于母线1,采用不同规模的训练集对1月(冬季)和8月(夏季)的预测结果影响不大,对于4月(春秋季),当训练集采用全样本集预测时精度明显更高;对于母线2,训练集采用全样本集的预测精度在各月份均明显优于采用季节样本集的预测精度,其原因在于母线2的负荷属性为工业与非工业混合负荷,季节性体现不明显,扩大训练集能够有效提升模型学习效果。总体而言,对于母线负荷预测,扩大训练集带来的增益大于选用具有针对性的训练集带来的增益,因此后续实验中的训练集均采用待预测时段之前的全部样本,即全样本集。

3.3 Stacking模型融合

3.3.1 基于PSO算法的模型融合参数优化

由第2节可知,在综合预测系统中,PSO算法所优化的参数为各个XGBoost模型的学习率 ϵ 与树的最大深度 Z 。基于PSO算法优化参数使得所提方法具有泛化性,对于不同母线负荷预测可自动寻取最优参数配置。以母线1与母线2为例,基于2017年样本集配置系统参数,PSO算法迭代超过40次后达到最优值,最优参数配置结果如表4所示。由表中可见,各元模型间参数差异明显,这说明Stacking模型融合是通过元模型彼此间的差异性来实现元模型间互补的。

表4 预测系统参数配置

Table 4 Parameter configuration of forecasting system

系统单元	母线1		母线2	
	最大深度	学习率	最大深度	学习率
元模型1(XGBoost_1)	5	0.2924	8	0.1438
元模型2(XGBoost_2)	6	0.1730	6	0.2212
元模型3(XGBoost_3)	8	0.2198	4	0.3000
第二层预测模型(XGBoost)	6	0.0471	6	0.0341

3.3.2 预测结果对比分析

本节对比所提方法与传统机器学习模型及其模型融合系统的预测性能。首先,测试单一XGBoost模型,考虑到RF是机器学习中应用广泛的一种算法,而XGBoost是梯度提升回归GBR(Gradient Boosting Regression)的一种强化方法,因此引入RF、GBR与XGBoost进行对比^[20]。其次,分别对XGBoost模型、RF模型与GBR模型进行Stacking模型融合,以检验Stacking模型融合方法的适用性。各模型的参数均由PSO算法优化得到。最终预测结果如表5所示。

表5 预测引用误差

Table 5 Forecasting quoted error

母线	模型	预测引用误差/%		
		1月	4月	8月
1	RF	4.211	1.097	2.843
	GBR	5.036	1.382	3.396
	XGBoost	4.035	1.297	2.578
	RF-Stacking	4.090	1.041	2.554
	GBR-Stacking	3.845	1.155	2.090
	XGBoost-Stacking	3.556	1.011	1.729
2	RF	5.521	2.801	4.509
	GBR	5.930	2.986	4.572
	XGBoost	5.104	2.465	3.604
	RF-Stacking	5.380	2.697	4.387
	GBR-Stacking	5.339	2.811	3.164
	XGBoost-Stacking	3.951	2.187	2.838

根据表5的预测结果可得如下结论。

(1)总体而言,母线1的预测精度优于母线2。这主要是因为母线1为居民和商业负荷,规律性较强,而母线2为工业与非工业混合负荷,具有一定的随机性。

(2)不论是母线1还是母线2,4月(春秋季)的预测精度最高,8月(夏季)预测精度次之,1月(冬季)预测精度最低。可见,负荷预测的精度受季节影响较大。

(3)未采用Stacking模型融合时,除母线1的4月外,其余时间XGBoost模型均取得了最佳预测效果,这说明相较于RF和GBR,XGBoost在母线负荷预测方面具有一定的优越性。

(4)各模型经Stacking模型融合后,母线预测引用误差均有所降低,XGBoost与Stacking模型融合的

综合系统在各种情况下均取得最佳预测效果,验证了所提方法的有效性。以夏季8月1—15日为例,所提方法的预测结果如图6所示。由图可见,整体预测结果良好,少部分峰谷存在一定的预测偏差。

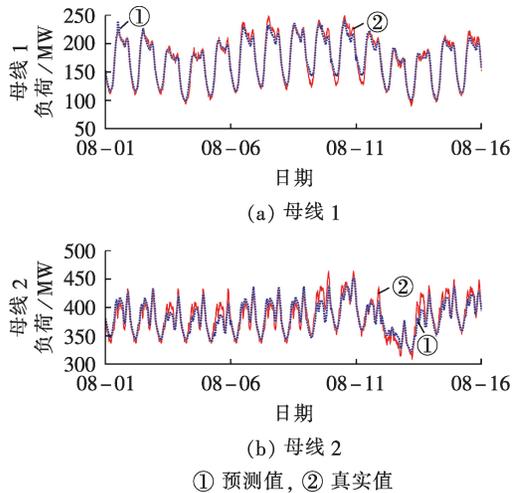


图6 8月1—15日的预测结果

Fig.6 Forecasting results for August 1st to 15th

(5) Stacking模型融合对于不同模型的提升效果如图7所示。由图可知, XGBoost、GBR、RF的预测引用误差分别平均降低了20.33%、20.86%、4.52%,可见Stacking模型融合对于XGBoost与GBR的提升效果明显;且该方法对于8月(夏季)母线负荷预测的改进效果最为显著,对于1月(冬季)与4月(春秋季节)的改进效果相当;此外,对于以居民和商业负荷为主的母线1,其预测的提升效果略优于以工业与非工业混合负荷为主的母线2。

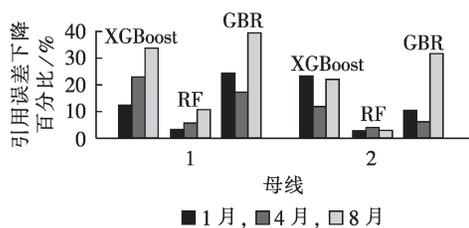


图7 Stacking模型融合后引用误差下降百分比

Fig.7 Reduction of quoted error with Stacking model fusion

4 结论

母线负荷比系统负荷量级小,随机性强,其负荷类型因供电区域的差异而有所不同。本文针对短期母线负荷预测,提出基于XGBoost与Stacking模型融合的综合预测系统,得到以下结论。

(1) 相较于RF与GBR, XGBoost具有更好的预测性能。

(2) 对于母线负荷预测,相较于对应季节的小规模样本集,训练集采用更大规模的全样本集时的预

测效果更佳。

(3) 与单模型相比,基于Stacking模型融合方法将多个XGBoost模型集成构成综合预测系统,并采用PSO算法进行优化参数,提升了预测精度。

(4) 对于以居民和商业负荷为主的母线以及工业与非工业负荷混合的母线,所提方法均表现出较好的预测性能,验证了所提方法对于多类型母线负荷预测的适用性。

(5) 不同负荷成分和不同季节对母线负荷预测的精度均有较大影响。因此,笔者后续研究重点是如何提升包含工业负荷成分的母线负荷预测精度以及如何提升母线负荷夏、冬季预测精度。

参考文献:

- [1] 康重庆,夏清,刘梅. 电力系统负荷预测[M]. 2版. 北京:中国电力出版社,2017:429.
- [2] 王雁凌,吴梦凯. 经济新常态下基于偏最小二乘回归的中长期负荷预测模型[J]. 电力自动化设备,2018,38(3):133-139. WANG Yanling, WU Mengkai. Medium and long term load forecasting model based on partial least-square regression under new normal economy[J]. Electric Power Automation Equipment, 2018, 38(3): 133-139.
- [3] 祖向荣,田敏,白焰. 基于模糊聚类与函数小波核回归的短期负荷预测方法[J]. 电力自动化设备,2016,36(10):134-140. ZU Xiangrong, TIAN Min, BAI Yan. Short-term load forecasting based on fuzzy clustering and functional wavelet-kernel regression[J]. Electric Power Automation Equipment, 2016, 36(10): 134-140.
- [4] 李博,门德月,严亚勤,等. 基于数值天气预报的母线负荷预测[J]. 电力系统自动化,2015,39(1):137-140. LI Bo, MEN Deyue, YAN Yaqin, et al. Bus load forecasting based on numerical weather prediction[J]. Automation of Electric Power Systems, 2015, 39(1): 137-140.
- [5] AMJADY N. Short-term bus load forecasting of power systems by a new hybrid method[J]. IEEE Transactions on Power Systems, 2007, 22(1): 333-341.
- [6] 韩勇,李红梅. 基于小波分解的支持向量机母线负荷预测[J]. 电力自动化设备,2012,32(4):88-91. HAN Yong, LI Hongmei. Bus load forecasting based on wavelet transform and SVM[J]. Electric Power Automation Equipment, 2012, 32(4): 88-91.
- [7] 尹星露,肖先勇,孙晓璐. 基于预测有效度和马尔科夫-云模型的母线负荷预测模型筛选与变权重组合预测[J]. 电力自动化设备,2015,35(3):114-119. YIN Xinglu, XIAO Xianyong, SUN Xiaolu. Bus load forecasting model selection and variable weights combination forecasting based on forecasting effectiveness and Markov chain-cloud model[J]. Electric Power Automation Equipment, 2015, 35(3): 114-119.
- [8] PANAPAKIDIS I P. Clustering based day-ahead and hour-ahead bus load forecasting models[J]. International Journal of Electrical Power & Energy Systems, 2016, 80: 171-178.
- [9] 李光珍,刘文颖,云会周,等. 母线负荷预测中样本数据预处理的新方法[J]. 电网技术,2010,34(2):149-154. LI Guangzhen, LIU Wenyong, YUN Huizhou, et al. A new data preprocessing method for bus load forecasting[J]. Power System Technology, 2010, 34(2): 149-154.
- [10] CHEN X Y, KANG C Q, TONG X, et al. Improving the

- accuracy of bus load forecasting by a two-stage bad data identification method[J]. IEEE Transactions on Power Systems, 2014,29(4):1634-1641.
- [11] 王毅,李鼎睿,康重庆. 低秩矩阵分解在母线坏数据辨识与修复中的应用[J]. 电网技术,2017,41(6):1972-1979.
WANG Yi,LI Dingrui,KANG Chongqing. Application of low-rank matrix factorization in bad data identification and recovering for bus load[J]. Power System Technology,2017,41(6):1972-1979.
- [12] 吴京秋,孙奇,杨伟,等. 基于D-S证据理论的短期负荷预测模型融合[J]. 电力自动化设备,2009,29(4):66-70.
WU Jingqiu,SUN Qi,YANG Wei,et al. Short-term load forecast model fusion based on D-S evidence theory[J]. Electric Power Automation Equipment,2009,29(4):66-70.
- [13] WANG Y,CHEN Q X,SUN M Y, et al. An ensemble forecasting method for the aggregated load with subprofiles[J]. IEEE Transactions on Smart Grid,2018,9(4):3906-3908.
- [14] 陈海文,王守相,王绍敏,等. 基于门控循环单元网络与模型融合的负荷聚合体预测方法[J]. 电力系统自动化,2019,43(1):65-74.
CHEN Haiwen,WANG Shouxiang,WANG Shaomin,et al. Aggregated load forecasting method based on gated recurrent unit networks and model fusion[J]. Automation of Electric Power Systems,2019,43(1):65-74.
- [15] ZHOU M,JIN M. Holographic ensemble forecasting method for short-term power load[J]. IEEE Transactions on Smart Grid,2019,10(1):425-434.
- [16] LIN Y,YANG M,WAN C,et al. A multi-model combination approach for probabilistic wind power forecasting[J]. IEEE Transactions on Sustainable Energy,2019,10(1):226-237.
- [17] HU Z N,MA J,YANG L W, et al. Decomposition-based dynamic adaptive combination forecasting for monthly electricity demand[J]. Sustainability,2019,11(5):1272.
- [18] ZHANG Y C,LE J,LIAO X B,et al. A novel combination forecasting model for wind power integrating least square support vector machine, deep belief network, singular spectrum analysis and locality-sensitive hashing[J]. Energy,2019,168:558-572.
- [19] CHEN T Q,GUESTRIN C. XGBoost[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco,USA:[s.n.],2016:85-97.
- [20] 陆继翔,张琪培,杨志宏,等. 基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化,2019,43(8):131-137.
LU Jixiang,ZHANG Qipei,YANG Zhihong,et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems,2019,43(8):131-137.

作者简介:



刘波

刘波(1995—),男,江苏淮安人,硕士研究生,主要研究方向为地区负荷功率模型(**E-mail**:bliu1995@163.com);

秦川(1981—),男,江苏靖江人,副教授,博士,主要研究方向为电力系统分析与控制(**E-mail**:cqin@hhu.edu.cn);

鞠平(1962—),男,江苏靖江人,教授,博士,主要研究方向为电力系统建模与控制(**E-mail**:pju@hhu.edu.cn)。

(编辑 王锦秀)

Short-term bus load forecasting based on XGBoost and Stacking model fusion

LIU Bo¹,QIN Chuan¹,JU Ping¹,ZHAO Jingbo²,CHEN Yanxiang¹,ZHAO Jian³

(1. College of Energy and Electrical Engineering,Hohai University,Nanjing 211100,China;

2. State Grid Jiangsu Electric Power Company Research Institute,Nanjing 210008,China;

3. State Grid Nanjing Power Supply Company,Nanjing 210019,China)

Abstract: Bus load forecasting plays an important role in safe and stable dispatching of power grid, but bus load has strong stochastic fluctuation, and its attributes are various because of the difference of power supply areas, for which, a short-term bus load forecasting method based on XGBoost (eXtreme Gradient Boosting) and Stacking model fusion is proposed. Multiple bus load forecasting meta-models are built based on XGBoost to form the meta-model layer of Stacking model fusion, an XGBoost model is connected to the meta-model layer for fusion, and the comprehensive forecasting system is formed. The particle swarm optimization algorithm is adopted to optimize the system parameters. The cases of 220 kV bus with different load attributes are analyzed, and the validity and applicability of the proposed method are verified.

Key words: bus load; XGBoost; meta-model; Stacking model fusion; particle swarm optimization algorithm