

基于混合核函数支持向量机的风电机组发电机 温度预警方法

Early warning method for wind turbine generator temperature based on HK-SVM

曹力, 潘巧波*, 王明宇, 马东
CAO Li, PAN Qiaobo*, WANG Mingyu, MA Dong

(华电电力科学研究院有限公司, 杭州 310030)
(Huadian Electric Power Research Institute Company Limited, Hangzhou 310030, China)

摘 要:发电机是风电机组的关键部件,其可靠性直接影响机组的运行状态。将混合核函数支持向量机用于发电机正常工作情况下的温度模型训练及预测。首先筛选合适的样本数据,利用相关性计算选择与发电机驱动端轴承温度关联度最高的几个参数,建立发电机正常工作的温度区间。当发电机运行发生异常时,其动态特性偏离正常工作状态,导致混合核函数支持向量机预测的温度值与实际值残差发生变化,通过动态计算滑动窗口内残差的分布特性,设定合理的报警逻辑及阈值,实现机组异常状态的预警。研究表明,该方法对于风电机组的故障预警、远程诊断具有重要的指导意义。

关键词:风电机组;支持向量机;混合核函数;风力发电机;温度预警

中图分类号:TK 83 **文献标志码:**A **文章编号:**1674-1951(2020)05-0043-07

Abstract: The operation state of a wind turbine will be affected by its generator, a key component of a wind turbine. The hybrid kernel-support vector machine (HK-SVM) was used to train the temperature model of a generator under normal working condition to make prediction. Firstly, appropriate sample data were screened, and the parameters with the highest correlation with the generator bearing temperature at driving end were selected from them by using correlation calculation. Then, temperature range for a generator at normal working condition was established. When the generator ran abnormally, its dynamic characteristics deviated from that under normal working state, resulting in residual difference between the actual temperature and the predicted temperature obtained by HK-SVM. The residual distribution characteristics in the sliding window were calculated dynamically, and a reasonable alarm logic and a threshold were set to realize the early warning for the abnormal state of generators. The results show that this method is of great guiding significance for fault early warning and remote diagnosis of wind turbine.

Keywords: wind turbine unit; support vector machine; hybrid kernel function; wind turbine generator; temperature warning

0 引言

近年来,风电事业得到了长足的发展,但风电机组长期工作在恶劣环境中,其中齿轮箱、发电机、叶轮等大部件的工作状态直接影响整机的运行性能^[1-3]。因此采取有效的状态监测与故障诊断方法对关键部件进行分析研究,预警故障并尽早开展排查检修工作,对于风电机组的健康管理及能效提升具有重要的指导意义。

发电机是风电机组工作的关键环节,承担着机械能转化为电能的功能,其工况比较复杂,发生故障后检修周期长、检修难度大,许多专家针对发电机状态监测与故障诊断开展了相应的研究。文献[4]阐述了双馈发电机组机械类故障和电气类故障常用的信号分析技术。文献[5]使用改进粒子群优化-反向传播(IPSO-BP)算法建立齿轮箱正常工作状态下的温度模型并用于故障预测,通过残差分析实现预警。文献[6]将极端梯度提升(XGBoost)模型与其他4类回归预测模型分别进行齿轮箱温度预测模型试验,结果表明XGBoost模型在齿轮箱温度预测中综合性能要优于其他4类模型。文献[7]提出一种堆叠自编码网络深度方法,使用自适应阈值

收稿日期:2020-02-03;修回日期:2020-04-01

基金项目:中国华电集团公司科技项目(CHDKJ19-02-208);
华电电力科学研究院重点科技项目(CHDERKJ-01-01)

监测重构误差的趋势变化,实现对故障的判定。上述文献在研究时或用信号分析手段,或用机器学习算法,从机理角度及数据角度对风电机组齿轮箱、发电机工作状态进行了分析,均取得了一定的研究成果,但都存在建模学习难度大,状态劣化时间点定位不准确的问题^[8-10]。

支持向量机(SVM)是一类按监督学习方式对数据进行二元分类的广义线性分类器。它易于建模,对于风电机组数据采集与监视控制(SCADA)系统的数据有良好的适应性,核函数支持向量机(K-SVM)常用的有 2 类核函数:多项式核函数(Polynomial Kernel)和高斯核函数(Gaussian Kernel)^[11-13]。高斯核函数可以把特征映射到无限多维,计算比较简单;但是高斯核函数存在计算速度慢,容易过拟合的缺点^[14-15]。多项式核函数泛化能力强,但是学习能力较弱。故可以将 2 种核函数结

合起来,发挥各自的优点。

本文提出一种基于混合核函数支持向量机(HK-SVM)的方法来对风电机组发电机温度进行建模,计算理想值和实际值的差值,通过历史良好的样本数据确定监测指标阈值,再实时通过滑动窗口计算有关指标,完成预警工作。

1 风电机组信息

本文研究对象为河北某风电场 #134 和 #74 机组,型号均为华锐 SL1500/82,额定功率为 1 500 kW,额定风速为 10.5 m/s。

选取 #134 机组 2018 年 10 月 10 日至 2019 年 3 月 2 日共 178 865 条数据及 #74 机组 2018 年 8 月 10 日至 2019 年 3 月 2 日共 248 125 条数据进行研究,采集频率均为 1 min/次。2 台机组故障检修记录见表 1。

表 1 2 台机组故障检修记录

Tab. 1 Troubleshooting records of the two units

机组	故障时间	故障描述	原因及处理措施
#134	2018-12-28 T 07:40	发电机驱动端轴承温度高	2018-12-29 T 10:01 检查为油面低于加脂器壳体刻度合格位置,加油处理
#74	2019-01-17 T 05:05	发电机驱动端轴承温度高	2019-01-17 T 10:26 检查为油面低于加脂器壳体刻度合格位置,加油处理

2 基于混合核函数支持向量机原理

2.1 支持向量机原理

支持向量机通过寻找一个超平面将 2 类样本点切割开,可用于回归问题。给定训练数据集

$$D = \{(\mathbf{x}_1, \mathbf{y}_1), (\mathbf{x}_2, \mathbf{y}_2), \dots, (\mathbf{x}_m, \mathbf{y}_m)\}, \quad (1)$$

式中: $\mathbf{x}_i$ 和 $\mathbf{y}_i$ 分别代表样本点的输入和输出, $i=1, 2, \dots, m$ 。训练以期得到一个回归模型 $f(\mathbf{x})=\omega^T \mathbf{x}+b$,使得 $f(\mathbf{x})$ 与 $\mathbf{y}$ 的差值尽可能小, ω 和 b 是表征超平面的参数。和传统模型计算输出 $f(\mathbf{x})$ 与 $\mathbf{y}$ 的差值来衡量损失不同,支持向量回归(SVR)假设我们能允许 $f(\mathbf{x})$ 与 $\mathbf{y}$ 之间最多存在 ε 的误差,当且仅当 $f(\mathbf{x})$ 与 $\mathbf{y}$ 之间差的绝对值大于 ε 时才计算损失。SVR 问题可写作

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m l_{\varepsilon}(f(\mathbf{x}_i) - \mathbf{y}_i), \quad (2)$$

式中: C 为正则化常数; l_{ε} 表示损失函数,表达式为

$$l_{\varepsilon}(f(\mathbf{x}_i) - \mathbf{y}_i) = \begin{cases} 0, & |f(\mathbf{x}_i) - \mathbf{y}_i| < \varepsilon \\ |f(\mathbf{x}_i) - \mathbf{y}_i| - \varepsilon, & |f(\mathbf{x}_i) - \mathbf{y}_i| \geq \varepsilon \end{cases}, \quad (3)$$

引入松弛变量 $\xi_i, \hat{\xi}_i$,则式(2)变为

$$\min_{\omega, b, \xi_i, \hat{\xi}_i} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i), \quad (4)$$

满足约束条件:

$$\begin{aligned} f(\mathbf{x}_i) - \mathbf{y}_i &\leq \varepsilon + \xi_i, \\ \mathbf{y}_i - f(\mathbf{x}_i) &\leq \varepsilon + \hat{\xi}_i, \\ \xi_i &\geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m, \end{aligned}$$

引入拉格朗日乘子:

$$\mu_i \geq 0, \hat{\mu}_i \geq 0, \alpha_i \geq 0, \hat{\alpha}_i \geq 0,$$

得到下面的拉格朗日函数:

$$\begin{aligned} L(\omega, b, \alpha_i, \hat{\alpha}_i, \xi_i, \hat{\xi}_i, \mu_i, \hat{\mu}_i) \\ = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \hat{\xi}_i) - \sum_{i=1}^m \mu_i \xi_i - \\ \sum_{i=1}^m \hat{\mu}_i \hat{\xi}_i + \sum_{i=1}^m \alpha_i (f(\mathbf{x}_i) - \mathbf{y}_i - \varepsilon - \xi_i) + \\ \sum_{i=1}^m \hat{\alpha}_i (\mathbf{y}_i - f(\mathbf{x}_i) - \varepsilon - \hat{\xi}_i) \end{aligned}, \quad (5)$$

令式(5)对 $\omega, b, \xi_i, \hat{\xi}_i$ 的偏导数为 0,可得

$$\begin{aligned} \omega &= \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) \mathbf{x}_i, \\ 0 &= \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i), \\ C &= \alpha_i + \mu_i, \\ C &= \hat{\alpha}_i + \hat{\mu}_i, \end{aligned} \quad (6)$$

将式(6)代入式(5),得到 SVR 对偶问题:

$$\max_{\alpha, \hat{\alpha}} \sum_{i=1}^m y_i (\hat{\alpha}_i - \alpha_i) - \varepsilon (\hat{\alpha}_i + \alpha_i) - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (\hat{\alpha}_i - \alpha_i) (\hat{\alpha}_j - \alpha_j) x_i^T x_j, \quad (7)$$

满足约束条件:

$$\sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) = 0, 0 \leq \hat{\alpha}_i, \alpha_i \leq C,$$

上述过程满足的库恩塔克条件(KKT)为

$$\begin{aligned} \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) &= 0, \\ \hat{\alpha}_i (y_i - f(x_i) - \varepsilon - \hat{\xi}_i) &= 0, \\ \alpha_i \hat{\alpha}_i &= 0, \xi_i \hat{\xi}_i = 0, \\ (C - \alpha_i) \xi_i &= 0, (C - \hat{\alpha}_i) \hat{\xi}_i = 0, \end{aligned} \quad (8)$$

SVR解为

$$f(x) = \sum_{i=1}^m (\hat{\alpha}_i - \alpha_i) x_i^T x + b. \quad (9)$$

完成以上求解的一个基础是使用核函数将样本点映射到高纬度特征空间。传统向量机选用核函数要求具备一定的先验知识,否则只能凭借经验或者凑试法来选择误差最小的核函数。本研究使用多项式核函数、高斯核函数的混合核函数进行处理。表达式为

$$k_{\text{mix}}(x, x') = k_{\text{Gauss}}(x_{\text{Gauss}}, x'_{\text{Gauss}}) + k_{\text{Poly}}(x_{\text{Poly}}, x'_{\text{Poly}}), \quad (10)$$

式中: k_{Gauss} 为高斯核函数; x_{Gauss} 为高斯核函数的输入值; x'_{Gauss} 为高斯核函数输入值的特定变换值; k_{Poly} 为多项式核函数; x_{Poly} 为多项式核函数的输入值; x'_{Poly} 为多项式核函数输入值的特定变换值。

选用混合核函数支持向量机进行发电机预警,流程如图1所示。




图1 发电机预警流程

Fig. 1 Flowchart of the generator warning system

2.2 混合核函数对回归性能的改进

2.2.1 输入参数的确定

回归问题需要确定输入量及输出量,本研究的输出量为发电机驱动端轴承温度。选取输入量时

应考虑其对于输出量的影响程度。用相关系数 r 表征为

$$r = \frac{\sigma_{xy}}{\sigma_x \sigma_y} = \frac{n \sum xy - \sum x \sum y}{\sqrt{n \sum x^2 - (\sum x)^2} \sqrt{n \sum y^2 - (\sum y)^2}}, \quad (11)$$

式中: x 和 y 为2个不同的样本集; σ_x 和 σ_y 分别为 x 和 y 的标准差, σ_{xy} 为 x 和 y 的协方差, n 为样本容量。

分别计算 #134 机组和 #74 机组的 SCADA 数据中 42 个参数与发电机驱动端轴承温度两两相关的系数,选取部分参数的相关系数,见表 2。

表2 发电机驱动端轴承温度与部分参数的相关系数

Tab. 2 Correlation coefficient of the generator bearing temperature at driving end and some parameters

参数	#134 机组	#74 机组
发电机转速	0.891 2	0.886 6
机舱温度	0.876 5	0.848 1
风速	0.786 6	0.717 6
功率	0.724 5	0.769 3
非驱动端轴承温度	0.717 8	0.753 2

考虑冗余性能,最终确定输入参数为发电机转速、机舱温度、风速、非驱动端轴承温度。

2.2.2 各类核函数支持向量机训练

选用 #134 机组 2018 年 10 月 10 日至 11 月 10 日共 35 848 条数据及 #74 机组 2018 年 8 月 5 日至 10 月 10 日共 71 893 条数据进行支持向量机回归训练。分别选用高斯核函数、多项式核函数、混合核函数来进行训练。需要说明的是,原始数据在训练时需要经过去除异常值(如超正常范围点、零点值等)的处理;同时,考虑到不同参数之间量纲不同,取值范围存在较大差异,整个训练分析过程中均对所有数据进行归一化处理,确保建模的有效性。

训练过程中采用 KFold 函数交叉验证,将原始数据分成 k 组,将每个子集数据分别做一次验证集,其余的 $k-1$ 组子集数据作为训练集,这样会得到 k 个模型。这 k 个模型分别在验证集中评估,结果用泛化误差表示。将泛化误差加权平均得到交叉验证误差,然后使用泛化误差和交叉验证误差计算每个模型的平均泛化误差,选择平均泛化误差最小的模型作为结果模型。

最后,使用若干指标评定不同核函数的训练效果,见表 3。表 3 中, R^2 为决定系数,值越接近 1,说明模型拟合效果越好;RMSE 为均方根误差,值越小说明拟合值和实际值越接近。

表 3 几类核函数支持向量机训练效果
Tab. 3 Training performance of support vector machines using various kernel functions

核函数	R^2		RMSE		训练时间/s	
	#134	#74	#134	#74	#134	#74
高斯核函数	0.872 01	0.883 47	4.647 96	4.036 65	397.819	761.344
多项式核函数	0.730 81	0.754 43	5.989 45	5.456 67	361.122	780.899
混合核函数	0.851 30	0.863 32	4.723 45	4.118 51	412.435	812.988

训练结果说明如下:

- (1)使用混合核函数的支持向量机的 R^2 及 RMSE 指标接近于使用高斯核函数的支持向量机,两者均优于使用多项式核函数的支持向量机;
- (2)使用多项式核函数的支持向量机训练时间与使用高斯核函数的支持向量机接近,均短于使用混合核函数的支持向量机。

3 基于HK-SVM的发电机温度监测分析

3.1 状态监测试验

研究过程中选用的训练数据经查验无故障停机记录,数据本身也能覆盖机组大部分正常工作区间。当机组参数位于正常工作区间时,输入与发电机轴承温度有关的 4 个参数,应该能输出 1 个处于正常范围的发电机轴承温度值。当发电机轴承温度发生异常,实际值与模型输出的预测值的差值会变大,通过监测这种残差的变化,对发电机驱动端轴承温度的状态进行分析。

选用上一节训练好混合核函数支持向量机对全段数据集进行测试,测试结果如图 2、图 3 所示。




图 2 #134 机组发电机驱动端轴承温度趋势图(混合核函数)
Fig. 2 Temperature trend of the bearing at the driving end of generator in No. 134 unit (hybrid kernel)




图 3 #74 机组发电机驱动端轴承温度趋势图(混合核函数)
Fig. 3 Temperature trend of the bearing at the driving end of generator in No. 74 unit (hybrid kernel)

图 2 和图 3 中横坐标点数代表按照时间排列的数据序列位置(文中其余示意图横坐标为点数的意义也相同)。由图 2 可知 #134 机组发电机驱动端轴承温度预测值和实际值的情况。可见在 95 000 点(对应时间为 2018 年 12 月 15 日)左右残差已经有增大趋势。113 429 点(对应时间为 2018 年 12 月 28 日)为台账报发电机驱动端轴承温度过高的点。结果表明残差分析能提前 13 d 发现发电机驱动端轴承温度的异常变化。由图 3 可知 #74 机组发电机驱动端轴承温度预测值和实际值的情况。可见在 175 035 点(对应时间为 2019 年 1 月 3 日)左右残差已经有增大且波动加剧的趋势。195 233 点(对应时间为 2019 年 1 月 17 日)为台账报发电机驱动端轴承温度过高的点。结果表明,残差分析能提前 14 d 发现发电机驱动端轴承温度的异常变化。

作为对比,选用上一节训练好的高斯核函数支持向量机对全段数据进行测试,测试结果如图 4、图 5 所示。

由图 4 可知 #134 机组发电机驱动端轴承温度预测值和实际值的情况。可见在 95 000 点(对应时间




图4 #134机组发电机驱动端轴承温度趋势图(高斯核函数)

Fig. 4 Temperature trend of the bearing at the driving end of generator in No. 134 unit (Gaussian kernel)




图5 #74机组发电机驱动端轴承温度趋势图(高斯核函数)

Fig. 5 Temperature trend of the bearing at the driving end of generator in No. 74 unit (Gaussian kernel)

为2018年12月15日)左右残差没有明显增大的趋势。原因为高斯核函数支持向量机训练存在过拟合,导致轴承温度升高时残差的变化没有被捕捉到。由图5可知#74机组发电机驱动端轴承温度预测值和实际值的情况。可见在175 035点(对应时间为2019年1月3日)左右残差没有明显增大的趋势,并且台账报警点附近除了波动较大,使得残差分布较“稠密”外,残差绝对值并不明显区别于前期数据。同样轴承温度升高时残差的变化没有被捕捉到。

上述分析表明,混合核函数支持向量机能有效避免过拟合的情况发生,及时定位到状态异常点,综合性能优于高斯核函数支持向量机。

3.2 模型构建及统计分析

3.2.1 模型构建

从上一节研究可知,如果选用发电机历史良好的数据作为样本训练,当发电机轴承工作状态发生变化时,实际温度会偏移训练模型给出的“理想值”。通过对二者的残差进行分析可以实现发电机轴承工作异常变化的预警。选取某时间段,发电机轴承温度的残差序列

$$\varepsilon_g = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n], \quad (12)$$

式中: ε_i 为某时间点残差, $i=1, 2, \dots, n$ 。

选择长度为 N 的滑动窗口,连续计算窗口内残差的均值及标准差

$$\begin{cases} E_\varepsilon = \frac{1}{N} \sum_{i=1}^N \varepsilon_i \\ \delta_\varepsilon = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (\varepsilon_i - E_\varepsilon)^2} \end{cases} \quad (13)$$

选用滑动窗口计算残差序列的原因如下:

(1)采用滑动窗口计算残差序列,便于实时监测发电机轴承温度的动态变化;

(2)滑动窗口计算残差序列的统计参数,可以抑制孤立差值增大点的影响,排除偶然因素导致的误判;

(3)通过合理的窗口设置,可以及时、迅速地发现发电机轴承工作状态的变化,消除随机影响。

除了残差均值和标准差以外,还对窗口内 N 个残差计算超出阈值的比例,这个阈值包括上限阈值 $\varepsilon_{\max}$ 及下限阈值 $\varepsilon_{\min}$,均根据训练数据计算得来。为了较好地符合工程实际,应用中可根据经验进行调整,即阈值标准为

$$\begin{cases} \varepsilon_{\max} = k_1 \varepsilon_{\max} \\ \varepsilon_{\min} = k_2 \varepsilon_{\min} \end{cases}, \quad (14)$$

式中: k_1, k_2 是为运行人员根据工程实际情况进行调整的系数。

3.2.2 残差统计分析

选择窗口长度为1天(1 440 min),采样频率为1 min/次,阈值调整系数 k_1, k_2 均为1.5。对上述2台机组的残差序列进行窗口计算,结果如图6、图7所示。

由图6可知,#134机组预警模型残差超限比例在80 000点(对应时间为2018年12月5日)附近开始超过50%,90 000点(对应时间为2018年12月12日)后持续超过50%,大约提前23 d实现预警。由




图 6 #134 机组发电机驱动端轴承温度残差分析

Fig. 6 Analysis on the temperature residual of the bearing at generator driving end in No. 134 unit




图 7 #74 机组发电机驱动端轴承温度残差分析

Fig. 7 Analysis on the temperature residual of the bearing at generator driving end in No. 74 unit

图 7 可知, #74 机组预警模型残差超限比例在 150 000 点(对应时间为 2018 年 12 月 17 日)后开始增加, 在 160 000 点(对应时间为 2018 年 12 月 24 日)附近开始超过 50%, 大约提前 24 d 实现预警。

上述例子证明残差超限比例检查方法可以自动实现状态变化点定位, 有效预警发电机轴承的异常。

4 结论

本文针对河北某风电场 1.5 MW 风电机组的 SCADA 数据, 利用了基于高斯核函数、多项式核函数、混合核函数的支持向量机进行训练, 比较了 3 种核函数的各项训练指标, 确定混合核函数在支持向量机训练中综合性能优于其他 2 类。随后使用机组历史良好的运行工况数据进行训练建模, 确定合适的阈值进行预警。以 2 台机组发电机驱动端轴承故障为例, 分析了残差超限比例的增长趋势。结果表明该模型可以提前 20 d 左右发现异常, 较好地实现

了提前预警功能。

参考文献:

- [1] 杜胜磊, 高庆水, 潘巧波, 等. 风电机组在线智能故障诊断技术发展趋势[J]. 黑龙江电力, 2017, 39(2): 173-177.
DU Shenglei, GAO Qingshui, PAN Qiaobo, et al. Development trend of on-line intelligent fault diagnosis of wind turbines[J]. Heilongjiang Electric Power, 2017, 39(2): 173-177.
- [2] 刘志超, 王洪彬, 沙浩, 等. 我国风电利用技术现状及其前景分析[J]. 发电技术, 2019, 40(4): 389-395.
LIU Zhichao, WANG Hongbin, SHA Hao, et al. Status and prospect analysis of wind power utilization technology in China [J]. Power Generation Technology, 2019, 40(4): 389-395.
- [3] 潘巧波, 刘杨. 双馈风电机组油温超限运行的控制策略[J]. 黑龙江电力, 2015, 37(4): 360-363.
PAN Qiaobo, LIU Yang. Control strategy for doubly-fed wind turbine units operation under over-standard oil temperature [J]. Heilongjiang Electric Power, 2015, 37(4): 360-363.
- [4] 赵勇, 韩斌, 房刚利. 风力发电机状态监测与故障诊断技术综述[J]. 热力发电, 2016, 45(10): 1-5.
ZHAO Yong, HAN Bin, FANG Gangli. A survey of condition monitoring and fault diagnosis for wind power generators [J]. Thermal Power Generation, 2016, 45(10): 1-5.
- [5] 郭鹏, 李淋淋, 马登昌. 基于 IPSO-BP 的风电机组齿轮箱状态监测研究[J]. 太阳能学报, 2012, 33(3): 439-445.
GUO Peng, LI Linlin, MA Dengchang. Wind turbine gearbox condition monitoring with IPSO-BP [J]. Acta Energetica Solaris Sinica, 2012, 33(3): 439-445.
- [6] 王桂松, 郭鹏, 胥佳, 等. 基于 XGBoost 建模和 Change-Point 残差处理的风电机组齿轮箱温度预警[J]. 电力科学与工程, 2018, 34(9): 46-53.
WANG Guisong, GUO Peng, XU Jia, et al. Temperature warning of wind turbines gearbox based on XGBoost modeling and Change-Point residual processing [J]. Electric Power Science and Engineering, 2018, 34(9): 46-53.
- [7] 赵洪山, 刘辉海, 刘宏杨, 等. 基于堆叠自编码网络的风电机组发电机状态监测与故障诊断[J]. 电力系统自动化, 2018, 42(11): 102-108.
ZHAO Hongshan, LIU Huihai, LIU Hongyang, et al. Condition monitoring and fault diagnosis of wind turbine generator based on stacked autoencoder network [J]. Automation of Electric Power Systems, 2018, 42(11): 102-108.
- [8] 张少敏, 毛冬, 王保义. 大数据处理技术在风电机组齿轮箱故障诊断与预警中的应用[J]. 电力系统自动化, 2016, 40(14): 129-134.
ZHANG Shaomin, MAO Dong, WANG Baoyi. Application of

- big data processing technology in fault diagnosis and early warning of wind turbine gearbox[J]. Automation of Electric Power Systems, 2016, 40(14): 129-134.
- [9] ZAHER A, MCARTHUR S D J, INFIELD D G, et al. Online wind turbine fault detection through automated SCADA data analysis[J]. Wind Energy, 2009, 12(6): 574-593.
- [10] 郭鹏, INFIELD D, 杨锡运. 风电机组齿轮箱温度趋势状态监测及分析方法[J]. 中国电机工程学报, 2011, 31(32): 129-136.
- GUO Peng, INFIELD D, YANG Xiyun. Wind turbine gearbox condition monitoring using temperature trend analysis [J]. Proceedings of the CSEE, 2011, 31(32): 129-136.
- [11] 唐英, 李应珍. 线性支持向量机多类分类器几何构造方法[J]. 计算机工程, 2012, 38(4): 152-154.
- TANG Ying, LI Yingzhen. Geometric construction method of linear SVM multi - class classifier [J]. Computer Engineering, 2012, 38(4): 152-154.
- [12] 齐永锋, 火元莲, 等. 支持向量机研究[J]. 甘肃联合大学学报(自然科学版), 2005, 19(2): 23-26.
- QI Yongfeng, HUO Yuanlian, et al. Statistical learning theory and support vector machines [J]. Journal of Gansu Lianhe University (Natural Science Edition), 2005, 19(2): 23-26.
- [13] 颜根廷, 马广富, 肖余之. 一种混合核函数支持向量机算法[J]. 哈尔滨工业大学学报, 2007, 39(11): 1704-1706.
- YAN Genting, MA Guangfu, XIAO Yuzhi. Support vector machines based on hybrid kernel function [J]. Journal of Harbin Institute of Technology, 2007, 39(11): 1704-1706.
- [14] 徐立祥, 李旭. 基于混合核函数支持向量机的回归模型[J]. 合肥学院学报(自然科学版), 2013, 23(2): 4-8.
- XU Lixiang, LI Xu. The regression model of support vector machine based on mixed kernel function [J]. Journal of Hefei University (Natural Science Edition), 2013, 23(2): 4-8.
- [15] HUANG C L, TSAI C Y. A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting [J]. Expert Systems with Applications, 2009, 36(2): 1529-1539.

(本文责编: 张帆)

作者简介:

曹力(1993—), 男, 贵州毕节人, 工程师, 工程硕士, 从事风电机组状态监测、故障诊断及处理方面的研究(E-mail: li-cao@chder.com)。

潘巧波*(1993—), 男, 浙江金华人, 工程师, 工学硕士, 从事风力发电技术设计及优化方面的研究(E-mail: qiaobo-pan@chder.com)。

“边缘计算在能源互联网中的应用”专刊征稿启事

2020年, 国家正式组织实施新型基础设施建设工程, 重点发展新兴产业。能源互联网作为未来可能接入设备最多的物联网生态圈, 产业发展空间巨大。在能源领域, 新型电气信息技术的出现对能源互联网的发展起到了重要的支撑作用, 同时也带来了诸如安全性、网络负载及异构设备融合等问题, 边缘计算具有靠近数据源、实时性好、低时延、响应快等特征, 可以在一定程度上缓解这些问题。

《华电技术》作为行业科技创新、技术交流平台, 特推出“边缘计算在能源互联网中的应用”专刊, 并邀请华北电力大学李彬教授担任特约主编, 欢迎业内同仁踊跃投稿。

一、征文范围(包括但不限于)

(1) 边缘计算在能源互联网中的技术发展前景和趋势分析; (2) 边缘计算相关标准化工作; (3) 边缘计算在能源领域5G网络中的应用; (4) 边缘计算与能源区块链、人工智能等交叉领域研究; (5) 边缘计算在能源互联网中的智能数据分析服务; (6) 边缘计算在能源互联网中的信息安全问题; (7) 边缘计算在能源互联网中所衍生的商业模式; (8) 区域边缘计算中心建设及部署方案; (9) 能源互联网中边缘计算与云计算的协同优化技术及相关架构; (10) 边缘计算的落地应用场景以及解决方案和产品; (11) 能源互联网中的边缘计算的项目实践案例; (12) 基于边缘计算的能源行业中的业务应用, 如: 智能巡检、安防监控、智能配用电、电动汽车车联网、光伏云网等; (13) 其他相关研究。

二、时间进度

专刊拟于2020年8月31日截稿, 2020年10期(10月25日)后择期出版。

三、征文要求

(1) 专刊只收录未公开发表的论文, 拒绝一稿多投。作者对论文内容真实性和客观性负责。(2) 按照《华电技术》论文格式要求使用Word软件排版, 请登录《华电技术》在线采编系统(<http://www.hdpower.net>)下载论文模板。(3) 请保留论文中图片、曲线和表格的原始格式文件, 并在投稿时按规定提交。(4) 论文作者应遵守相关学术不端规定。

四、投稿方式

(1) 在线投稿(推荐): 登录《华电技术》在线采编系统(<http://www.hdpower.net>), 完成在线全文投稿。

(2) 邮箱投稿: direfish@163.com(李教授); hdjs-chd@vip.163.com(编辑部)

(3) 咨询联系: 刘芳 0371-58501060 13838002988; 杨满成 010-63918755 13801175292