

DOI: 10.12158/j.2096-3203.2023.03.012

基于 RF-BiLSTM 的柔直阀冷入阀水温预测及冷却能力评估

唐文虎¹, 林泽康¹, 辛妍丽², 赵伟¹, 吴亮³, 金晶³

(1. 华南理工大学电力学院, 广东 广州 510641; 2. 广东技术师范大学自动化学院, 广东 广州 510665; 3. 广东电网有限责任公司汕头供电局, 广东 汕头 515044)

摘要:为实现柔性直流(voltage sourced converter-high voltage direct current, VSC-HVDC)换流阀冷却系统入阀水温的智能预测,文中提出一种基于随机森林(random forest, RF)和双向长短时记忆(bi-directional long short-term memory, BiLSTM)网络混合的柔直换流阀冷却系统入阀水温的预测模型,并以此为基础对柔直换流站阀冷系统的冷却能力进行评估。首先,采用 RF 算法对由阀冷系统监测变量组成的高维特征集进行重要性分析,筛选出影响入阀水温的重要特征,与历史入阀水温构成输入特征向量。然后,将特征向量输入到 BiLSTM 预测模型,对模型进行训练并实现对入阀水温的准确预测和冷却能力定量评估。最后,以广东电网某柔直换流站为实例对所提方法进行验证,验证了所提出的基于 RF-BiLSTM 的混合模型预测精度优于 BiLSTM 模型、RF 模型、支持向量机(support vector machine, SVM)模型和自回归滑动平均模型(auto-regressive and moving average, ARMA)模型,并且实现了冷却能力的定量评估。结果表明该换流站冷却裕量达 98%,存在过度冷却、能源浪费的问题,与换流站现场运行情况相符,验证了文中所提方法的有效性和准确性。

关键词:柔直阀冷系统;机器学习;随机森林(RF)算法;双向长短时记忆(BiLSTM)网络;入阀水温预测;冷却能力评估

中图分类号:TM721.1

文献标志码:A

文章编号:2096-3203(2023)03-0102-10

0 引言

柔性直流(voltage sourced converter-high voltage direct current, VSC-HVDC)换流站作为柔直输电工程的“心脏”,保证其安全稳定运行极其重要^[1]。换流站中的换流阀在工作时,交换功率越大,阀体产生的热量越大。如果不加以控制,换流阀元件将会因温度过高而烧损,造成换流站闭锁,引发停电事故,导致巨大的社会影响和经济损失。因此,为了防止换流阀因温度过高而发生故障甚至损坏,换流站均会为其配备专门的冷却系统^[2]。因而,对柔直换流阀冷却系统的入阀水温进行预测并对其冷却裕量进行定量评估,实现对阀冷系统运行状态的准确监测、评估和故障预警十分必要。

目前国内外对阀冷系统传热机理建模开展了许多研究,文献[3-4]研究了阀冷系统的管道腐蚀,分析了阀冷系统内部结构和水冷管道的分布情况。文献[5]采用有限元方法构建了阀内冷却系统模型并对外冷系统进行了数值模拟分析。上述研究为阀冷系统的传热机理分析提供了一定的基础,但由于大部分情况下用户和研究人员无法获取较为完整详细的换流阀和阀冷系统的运行参数和设计参数,因此通过对阀冷系统的传热机理进行建模,并

以此为基础实现对阀冷系统入阀水温预测、状态监测及冷却能力评估还存在研究基础不足、建模难度大、准确率低等问题。

随着统计模型、数据挖掘和机器学习等方法在电力领域中的应用逐渐增多,这些方法在电力设备状态分析^[6-8]、功率预测^[9-11]、负荷预测^[12-13]等方面有着出色的表现。在阀冷系统入阀水温预测方面,文献[14]分别采用时间序列模型、简单神经网络模型对阀冷系统入阀水温进行预测。文献[15]采用长短时记忆(long short-term memory, LSTM)网络对入阀水温进行预测,并计算阀冷系统的冷却能力。文献[16]考虑多源影响因素,采用 LSTM 神经网络对入阀水温及冷却裕度进行预测,并对其在极端工况下的冷却裕度进行分析。上述研究为采用人工智能算法进行阀冷系统入阀水温预测提供了重要的参考作用,但已有的研究在特征选择方法、模型准确度上还有待进一步提升。

在阀冷系统冷却能力评估方面,文献[15]提出了在外冷系统已知条件不足时评估内冷系统冷却裕量的方法。文献[17]提出了考虑多种影响阀冷系统换热的主要因素冷却能力建模和预警方法,综合评估了阀冷系统的冷却能力。上述研究为高压直流换流站的阀冷系统的冷却能力及冷却裕量评估提供了重要的指导作用。

此外,上述文献研究对象大部分是高压直流换

收稿日期:2022-11-17;修回日期:2023-01-12

基金项目:国家自然科学基金资助项目(51977082)

流站阀冷系统。根据文献[18]的研究,柔直输电作为当前新兴的直流输电技术,其本身的结构和性能与高压直流存在差异,因而配套的阀冷系统及其关键设备、运行特性及监测量等同样存在差异,因此高压直流系统阀冷系统的研究结果不一定适用于柔直系统。相关研究还指出国内柔直输电工程较少,配套的阀冷系统在实际生产和运行过程中存在冷却能力冗余、能源浪费等不足,故应对其运行机理及关键环节等开展深入研究并优化。因此,开展柔直换流站阀冷系统入阀水温的智能预测和冷却裕量评估的研究十分必要。

文中提出一种基于随机森林(random forest, RF)和双向长短时记忆(bi-directional long short-term memory, BiLSTM)网络的柔直换流阀入阀水温预测方法,即 RF-BiLSTM 混合模型。该方法首先通过 RF 算法筛选出对阀冷系统入阀水温影响较大的重要特征量,再利用 BiLSTM 网络充分提取特征数据正反 2 个方向的时序特征信息,进而实现对入阀水温的准确预测,并实现阀冷系统的冷却能力评估。实验结果表明,所提出的模型可以有效提高入阀水温预测的准确度,降低预测误差,并且实现冷却能力的定量评估,为阀冷系统的运维和优化提供重要技术支撑。

1 柔直阀冷系统入阀水温预测及冷却能力评估方法框架

柔直阀冷系统入阀水温预测及冷却能力评估方法的流程如图 1 所示。该过程包括对阀冷系统运行数据的采集和预处理、基于 RF 算法的特征选择、基于 BiLSTM 网络的入阀水温预测模型和冷却裕量评估。

步骤 1: 阀冷系统运行数据的采集和预处理。文中以广东电网某柔直换流站采集的实际运行数据作为原始数据集,除了阀冷系统入阀水温数据,该数据集还包括环境温度、阀侧有功功率等共 16 个监测变量的数据;同时对该数据集进行归一化和降噪预处理。

步骤 2: 基于 RF 算法的特征选择。特征的选择对模型的预测精度有着非常重要的影响,因此文中采用 RF 算法对 16 个监测变量进行重要性指标分析,选取除入阀水温外的最重要的 7 个特征,最后构成一个 8 维的输入特征向量。

步骤 3: 基于 BiLSTM 网络的入阀水温预测模型。以步骤 2 选出的 8 个特征作为模型输入特征、入阀水温作为模型输出的结构生成模型的训练集

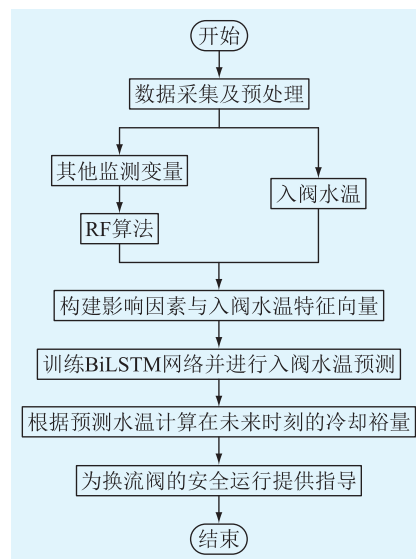


图 1 基于 RF-BiLSTM 混合模型的入阀水温预测与冷却能力评估流程

Fig.1 Flow chart of prediction of valve inlet water temperature and cooling capacity evaluation based on RF-BiLSTM hybrid model

和测试集,对不同的 BiLSTM 网络结构参数进行试验及优化,完成模型训练后并对入阀水温进行预测。

步骤 4: 阀冷系统冷却能力计算及评估。通过预测的入阀水温及其报警值计算出换流阀下一时刻允许传输的最大负荷,并根据阀冷系统冷却裕量计算公式,结合当前的阀侧负荷计算得到阀冷系统的冷却裕量,为系统的安全运行和故障预警提供重要参考。

2 基于 RF-BiLSTM 的阀冷系统入阀水温预测模型建立

2.1 RF 算法

RF 算法^[19-21]是常用的机器学习算法之一,它是由多棵决策树集成,通过每棵决策树的输出进行平均或投票来得到最终输出结果,并且在训练过程中能够发掘不同特征之间的相互作用及给出特征的重要性分析结果,因此文中采用 RF 算法进行特征选择。

RF 算法的优势来源于构建决策树时采用随机重采样技术和特征随机选取技术。随机重采样是一种有放回的重重复随机抽样方法,在训练决策树时采用随机重采样技术实现对样本的选择,可以提高决策树的泛化能力。同时,每次随机重采样后大概有 1/3 的数据未被抽中,这些数据称为“袋外数据”。袋外数据将用来对所训练的决策树组合进行误差估计,并计算特征变量的相对重要性。RF 算法的流程如图 2 所示。

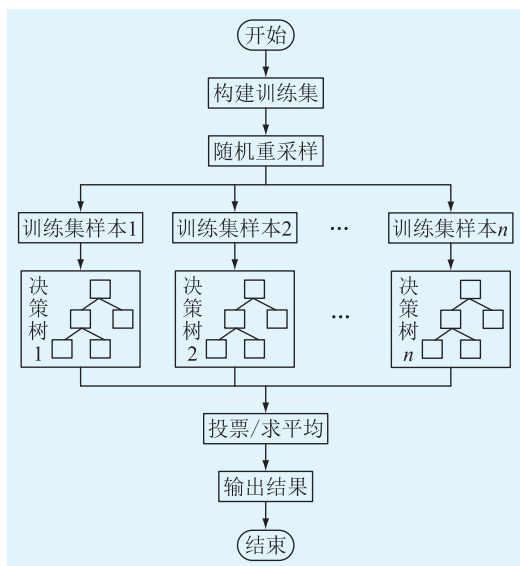


图2 RF 算法流程

Fig.2 Flow chart of the RF algorithm

RF 算法进行特征选择的过程可用以下步骤描述:

步骤 1:采用随机重采样技术对样本进行采样,选出 m 个样本作为训练集,未被选中的样本作为袋外数据,共进行 n 次采样,因此共有 n 个训练集,每个训练集用来训练一个决策树。

步骤 2:对于单棵决策树,假设共有 N 个特征,随机抽取其中 k 个特征作为该决策树的属性集,并对决策树进行训练。每个训练集用来训练一棵决策树,共训练 n 棵决策树,形成随机森林。

步骤 3:对于每棵决策树,采用其对应的袋外数据计算袋外误差 e_1 ,以计算特征 x 的重要性为例,对袋外数据所有样本中的特征 x 对应的数值加入随机干扰,再次计算袋外数据误差,记为 e_2 。

步骤 4:随机森林中的 n 棵决策树均进行袋外误差计算后,特征 x 的重要性如式(1)所示。

$$I = \sum_{j=1}^n \frac{e_{1j} - e_{2j}}{n} \quad (1)$$

式中: e_{1j} 、 e_{2j} 分别为第 j 棵决策树加随机干扰前后的袋外误差。因此可以根据各个特征的重要性指标筛选得到重要且有效的特征。

2.2 BiLSTM 神经网络

LSTM 网络是循环神经网络 (recurrent neural network, RNN) 中的一种变体结构,是目前 RNN 中应用最广的架构之一。

LSTM 不仅解决了 RNN 中的梯度消失和梯度爆炸的问题,同时相比 RNN 具有长时记忆功能,这些特性主要是由 LSTM 中的门控单元决定。LSTM 中引入了输入门、遗忘门和输出门,其中输入门用

于新信息的输入、历史信息融合及神经元状态的更新,遗忘门根据当前输入及历史信息来选择性地丢弃一些历史信息,输出门用于输出下一个隐藏状态的值,其相关计算过程及结构在许多研究中均有详细的描述^[9-10,12-13],在此不再赘述。

而 BiLSTM 网络^[22-24]是将正、反向的 LSTM 网络连接起来,其结构示意图如图 3 所示。图中 x_0 、 x_1 、 \dots 、 x_t 为输入的时序样本中 t 时刻所对应的特征向量; h_0 为隐藏层的初始状态。每个输入的数据都会从正反 2 个方向经过 BiLSTM 网络,对时间序列实现正向和反向 2 次特征提取,使得神经网络对特征的提取更具全局性和完整性,对数据的时间关联性有更高的关注,从而提高了预测的可靠性。记正向 LSTM 网络 t 时刻的输出为 $h_{f,t}$,反向 LSTM 网络 t 时刻的输出为 $h_{b,t}$,BiLSTM 网络将正、反向的输出作为输入,利用全连接 Dense 层进行拼接,得到最终输出结果,该计算过程如式(2)和式(3)所示。




图3 BiLSTM 网络结构

Fig.3 Structure of the BiLSTM network

$$h_{e,t} = ah_{f,t} + bh_{b,t} \quad (2)$$

$$p_{\text{predict},t} = h_{e,t} \quad (3)$$

式中: $h_{e,t}$ 为 BiLSTM 网络 t 时刻的输出隐藏状态; a 、 b 分别为正向网络和反向网络输出结果对应的权重; $p_{\text{predict},t}$ 为网络 t 时刻的最终输出。

2.3 基于 RF-BiLSTM 的阀冷系统入阀水温预测模型

文中基于广东电网某柔直换流站提供的阀冷系统状态监测量及阀侧功率监测量等特征,首先采用 RF 算法对特征进行筛选,然后根据所得到的特征重要性排序结果,选择出影响阀冷系统入阀水温重要特征,从而形成 BiLSTM 模型的输入特征,最后以阀冷系统入阀水温作为模型输出,对模型进行训练并预测 $p_{\text{predict},t}$,如式(4)所示。

$$p_{\text{predict},t} = f(\mathbf{M}) \quad (4)$$

式中: \mathbf{M} 为模型的输入矩阵。

图 4 给出了基于 RF-BiLSTM 混合模型阀冷系统入阀水温预测模型结构。首先对运行数据进行预处理,然后采用 RF 算法对阀冷系统的所有监测变量进行特征选择并形成输入特征向量,根据特征

向量构造 BiLSTM 神经网络的训练集和测试集,此时 BiLSTM 神经网络中每个模块的遗忘门、输入门和输出门的参数在训练中不断调整自身参数,从时序数据中学习数据间的时间依从关系。最后,采用一个全连接层将正、反 2 个方向的输出结果进行拼接融合,实现对阀冷系统入阀水温的预测。

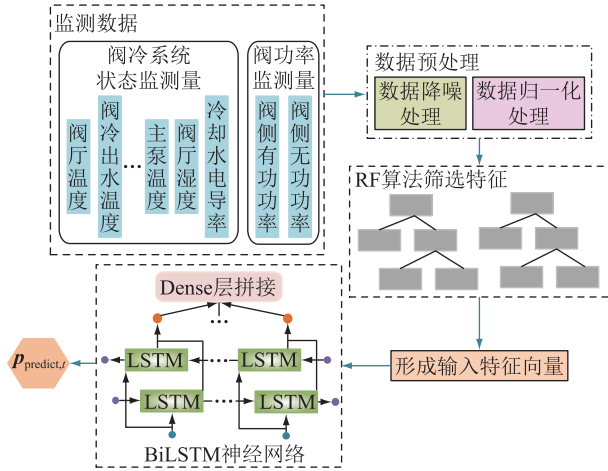


图4 基于 RF-BiLSTM 的阀冷系统入阀水温预测模型结构

Fig.4 Prediction model structure of inlet water temperature of valve cooling system based on RF-BiLSTM

文中采用时间反向传播 (back propagation through time, BPTT) 算法对 BiLSTM 模型梯度进行反向传播,即反向传播时将 BiLSTM 神经网络按照时间步长进行展开,沿时间通道实施反向传播算法,如图 3 红色箭头所示。模型训练过程中损失函数 L ,如式(5)所示。

$$L = \frac{1}{N_{\text{train}}} \sum_{t=1}^{N_{\text{train}}} (T_t - T_{\text{predict},t})^2 \quad (5)$$

式中: N_{train} 为训练集中的样本数量; T_t 为 t 时刻阀冷系统入阀水温真实值; $T_{\text{predict},t}$ 为 t 时刻阀冷系统入阀水温预测值。

3 实验算例

3.1 实验数据准备

文中以广东电网公司某柔直换流站作为研究对象,该柔直换流站中阀侧功率监测量和阀冷系统状态监测量的采样点的周期为 5 min。实验中采用 2021 年 8 月 1 日—2021 年 10 月 21 日的实际运行数据,期间对换流站停运检修时的数据进行剔除,共有 18 909 个运行点数据作为模型的数据集。在模型训练时,前 85% 的数据作为训练集,剩余数据作为测试集,训练时按停运检修时间点分段生成训练集后再进行拼接形成最后的训练集。同时,实验前对数据进行降噪及归一化处理,消除测量误差及不同类型数据范围差距过大等问题,以提高模型的预

测精度。

3.2 模型预测准确性评估

为准确评估模型的预测效果,文中采用 3 个指标来评判模型的预测效果,分别是均方误差 (mean square error, MSE)、均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE)。MSE、RMSE 和 MAE 的公式分别如式(6)一式(8)所示。

$$E_{\text{MSE}} = \frac{1}{M_{\text{test}}} \sum_{t=1}^{M_{\text{test}}} (x_{\text{real},t} - x_{\text{predict},t})^2 \quad (6)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{M_{\text{test}}} \sum_{t=1}^{M_{\text{test}}} (x_{\text{real},t} - x_{\text{predict},t})^2} \quad (7)$$

$$E_{\text{MAE}} = \frac{1}{M_{\text{test}}} \sum_{t=1}^{M_{\text{test}}} |x_{\text{real},t} - x_{\text{predict},t}| \quad (8)$$

式中: $x_{\text{real},t}$ 、 $x_{\text{predict},t}$ 分别为 t 时刻阀冷系统入阀水温的真实值和预测值; M_{test} 为测试集中数据点数。

3.3 原始数据降噪及预处理

在柔直换流站中,通过数据采集与监视控制 (supervisory control and data acquisition, SCADA) 系统或者合并单元进行数据采集,这些采集到的数据大部分含有大量的噪声,存在较多干扰,因此须对所采集的原始数据进行降噪处理。同时所采集的不同特征的数据所对应的取值范围相差均较大,因此须运用数据归一化来提高模型准确度。文中预处理的操作中归一化和降噪选用的数据均是全部数据,包括训练集和测试集。

3.3.1 数据降噪

文中采用 Daubiche4 小波对信号进行处理,分解层数为 4 层,阈值函数为软阈值函数,并自适应选取阈值,由于篇幅有限,降噪过程不在此赘述。此节对原始数据均进行相同的降噪处理。

3.3.2 数据归一化

由于原始数据中各个特征的取值范围差别较大,为了防止因数据量纲差异影响模型的精度,须对输入数据进行归一化处理。

文中采用式(9)对输入数据进行归一化处理,使原始数据的取值均落在 $[0, 1]$,从而提高模型的收敛速度及预测精度。

$$x_c = \frac{x_s - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

式中: x_c 为归一化后的模型输入数据; x_s 为输入数据的原始值; x_{\max} 、 x_{\min} 分别为原始数据中的最大值和最小值。

3.4 特征选择

阀冷系统入阀水温变化速度快,影响因素多,

与换流阀器件类型、损耗等参数以及阀冷系统的状态量有关。换流阀的稳态损耗、开关损耗、传输功率、器件类型等是影响阀本体温度的重要因素,也是间接影响入阀水温的因素。但由于文中研究获取的某柔直站换流阀运行数据及器件参数有限,不能准确计算各个损耗,因此仅考虑换流阀传输功率和阀冷系统监测量对入阀水温的影响。所以文中除了采用入阀水温作为特征外,还主要考虑柔直换流站提供的换流阀运行功率、环境温度、阀厅湿度、阀出水温度等共 16 个监测变量对入阀水温的影响,16 个相关变量如表 1 所示。文中对入阀水温进行预测前先对影响阀冷系统入水温的高维特征量进行筛选。

表 1 预测相关变量集

Table 1 Relevant variables set for prediction

类型	监测变量
阀系统 状态监测量	冷却水电导率 $\sigma_1/(\mu\text{s}\cdot\text{cm}^{-1})$
	进阀压力 P_i/bar
	回水压力 P_h/bar
	膨胀罐压力 P_p/bar
	主泵温度 $T_b/^\circ\text{C}$
	阀厅温度 $T_v/^\circ\text{C}$
	膨胀罐液位 l/mm
	去离子水电导率 $\sigma_2/(\mu\text{s}\cdot\text{cm}^{-1})$
	环境温度 $T_a/^\circ\text{C}$
	主泵出水压力 P_b/bar
阀功率 监测量	阀厅湿度 $W/\%$
	冷却水流量 $F/(\text{L}\cdot\text{min}^{-1})$
	阀冷出水温度 $T_{vo}/^\circ\text{C}$
	空冷器出水温度 $T_{ao}/^\circ\text{C}$
	阀侧有功功率 P/MW
	阀侧无功功率 Q/Mvar

文中采用 RF 算法对特征进行选择。首先通过网格搜索法确定 RF 算法中决策树的数量 n_{tree} 为 300 及特征随机抽取数量 k 为 4。然后,通过随机重采样和特征随机方法生成 n_{tree} 个训练集并选出每个训练集对应的 k 个特征变量,分裂指标采用 Gini 指数,将训练集输入到每棵决策树进行训练并进行袋外误差计算,最终得到影响阀冷系统入阀水温的变量重要性,分析结果如图 5 所示。换流阀的阀侧有功功率 P 和无功率 Q 直接决定了换流阀的产热量,对水温影响最大;环境温度 T_a 、阀厅湿度 W 、冷却水流量 F 对阀冷系统的散热能力有着直接影响;阀冷系统出水温度 T_{vo} 和空冷器出水温度 T_{ao} 直接影响着阀冷系统冷却水的水温。在实际运行中,该阀冷系统水流量目前调节范围较小,且冷却水流速

基本工作在最大流速状态,处于过冷却状态,此时小幅度降低或增加冷却水流量对阀冷系统入阀水温变化影响较小。而阀厅湿度变化范围较大,较大的湿度变化范围对阀内冷系统、管道回路等部分的传热性能影响更大。因而本研究中阀厅湿度对阀冷系统入阀水温的影响重要性程度略大于冷却水流量。因此,结合图 5 分析可知由 RF 算法所得的变量重要性分析结果和实际运行经验相符合。




图 5 监测变量重要性分析结果

Fig.5 Importance analysis results of monitoring variables

同时,模型预测精度并非绝对与特征变量数量呈正相关,将数量较多的阀冷系统和换流阀的状态监测量同时作为特征变量直接输入预测模型会导致输入维度过多,计算量庞大,甚至降低预测精度。因此,综合考虑模型的精度和复杂度后,文中选取 8 个变量作为预测阀冷系统入阀水温的特征,包括入阀水温 T_{vi} ,以及图 5 中重要性按从大到小排序的 7 个变量,分别为 P 、 T_a 、 Q 、 W 、 F 、 T_{vo} 和 T_{ao} ,组合形成预测模型的输入特征向量 $\mathbf{Z} = [x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6 \ x_7 \ x_8]^T$,其中 x_1 — x_8 分别为 8 个特征变量同一时刻对应的采样值。

3.5 模型参数设定及训练

对阀冷系统入阀水温预测模型进行参数设定及训练。在获取到数据集后先构造模型的输入数据集,输入数据集中的单个输入样本形式可表示为 $[\mathbf{Z}_1 \ \mathbf{Z}_2 \ \mathbf{Z}_3 \ \dots \ \mathbf{Z}_D]^T$,其中 \mathbf{Z}_D 为 D 时刻对应的输入特征向量, D 也为该输入样本的时间序列长度,即输入步长;对应输出数据集中的输出样本形式可表示为 $[T_{vi,(D+1)} \ T_{vi,(D+2)} \ T_{vi,(D+3)} \ \dots \ T_{vi,(D+l)}]^T$, $T_{vi,(D+1)}$ 为 $D+1$ 时刻对应的阀冷系统入阀水温值, l 为预测步长。

由表 2 可知,当 BiLSTM 网络为 2 层,且第一层 LSTM 个数为 64 个,第二层 LSTM 个数为 16 个时,此时 BiLSTM 网络的误差最小,因此,确定网络结构

表 2 不同 BiLSTM 网络结构下预测结果
Table 2 Prediction results with different structure parameters of BiLSTM network

层数	第一层 LSTM 个数	第二层 LSTM 个数	$E_{RMSE}/^{\circ}\text{C}$
1	16		0.146 0
1	32		0.098 1
1	48		0.091 1
1	64		0.083 4
2	64	16	0.074 0
2	64	32	0.075 0
2	64	48	0.092 2
2	64	64	0.096 0

为 2 层,第一、二层 LSTM 个数分别为 64 个和 16 个。

确定 BiLSTM 网络结构后,对不同预测步长进行试验,结果如图 6 所示。由图 6 可知,在预测步长为 1,即预测 5 min 后的入阀水温时,网络的误差达到最小,因此选择预测步长为 1。对于输入时间序列长度,应用同样的试验方法,得到最优的输入序列长度为 40。




图 6 不同时间步长下的预测结果

Fig.6 Prediction results under different timesteps

综合上述实验及对不同的超参数进行最小化误差试验后,文中的网络结构参数如表 3 所示。

表 3 BiLSTM 网络结构参数

Table 3 Structure parameters of BiLSTM network

参数	数值	参数	数值
网络层数	2	预测步长	1
第一层 LSTM 个数	64	迭代次数	12
第二层 LSTM 个数	16	初始学习率	0.000 1
输入时间序列长度	40		

Adam 优化器是当前深度学习中被广泛使用的梯度下降优化器,该优化器在训练过程中能够根据参数的变化选择更合适的学习率,避免训练过程中梯度出现较大波动。因此文中选择 Adam 优化器对网络参数进行优化。

3.6 实验结果分析

文中所提出的基于 RF-BiLSTM 的 VSC-HVDC

换流阀冷却系统入阀水温预测模型采用 TensorFlow 深度学习框架进行搭建,使用 Python 语言编写,以 PyCharm 2020.3.2 为集成开发环境,使用的计算机系统是 Win10 64 位操作系统,硬件配置为: Intel Xeon CPU E3-1231 v3 处理器,32 G 运行内存,GTX 1050 显卡。

根据表 3 所示的 BiLSTM 网络结构参数,对所提出的 RF-BiLSTM 模型进行迭代训练。为了进一步验证所提模型的准确性和优越性,文中将所提出的基于 RF-BiLSTM 混合模型的阀冷系统入阀水温预测模型与未经特征量筛选的单一 BiLSTM 预测模型、支持向量机 (support vector machine, SVM) 预测模型、RF 预测模型,以及以入阀水温为单变量输入的自回归滑动平均模型 (auto-regressive and moving average, ARMA) 预测模型进行比较。

其中, BiLSTM 模型设置网络层数为 2 层,第一、二层 LSTM 个数分别为 48 和 16,迭代次数为 12,初始学习率为 0.000 1。SVM 模型^[25-26]设置核函数类型为径向基核函数,核函数系数 γ 为 0.059,惩罚系数 C 为 1.0。RF 模型设置决策树数量为 300,最大特征数为 4。ARMA 模型^[14,27]的参数设置自回归模型阶数 p 为 4,平均滑动模型阶数 q 为 3。设置完成后进行实验,得到预测及对比结果如图 7 和表 4 所示。




图 7 模型预测结果

Fig.7 Prediction results of models

表 4 不同方法预测结果比较

Table 4 Comparison of prediction results of different methods

模型	$E_{MSE}/(^{\circ}\text{C})^2$	$E_{RMSE}/^{\circ}\text{C}$	$E_{MAE}/^{\circ}\text{C}$
ARMA	2.409 75	1.552 34	1.498 97
SVM	0.866 25	0.930 72	0.706 73
RF	0.433 57	0.658 46	0.512 72
BiLSTM	0.039 52	0.198 80	0.157 09
RF-BiLSTM	0.005 48	0.074 03	0.058 98

由图 7 可知,基于 RF-BiLSTM 混合模型的阀冷系统入阀水温预测模型能够较好地预测真实的入阀水温,基本能够完全跟随实际入阀水温的变化趋势,仅在少部分时刻的捕捉稍微欠缺,表现优于 BiLSTM 的预测模型。而基于 SVM 和 RF 机器学习方法的预测模型则难以跟随入阀水温变化较为剧烈的时刻。传统的时序回归预测模型 ARMA 由于不能捕捉数据间复杂的非线性关系,所以效果更差。因此,与其他模型相比,基于 RF-BiLSTM 混合模型的阀冷系统入阀水温预测模型能够更加准确地贴合真实的阀冷系统入阀水温变化曲线,具有更优秀的预测能力。

同时,在误差评估指标方面,由表 4 可知 RF-BiLSTM 混合模型在 MSE、RMSE 和 MAE 等 3 个方面的表现优于其他 4 种预测模型,具有最高的预测准确度。

结合图 7 和表 4 可知,文中所提出的基于 RF-BiLSTM 混合模型的预测模型在温度平稳和剧烈变化时均能较好地跟随入阀水温的变化,且保持着较小的误差,表明 RF-BiLSTM 混合模型具有更高的鲁棒性和适应性。

4 阀冷系统冷却能力评估

4.1 阀冷系统冷却裕量计算

柔性直流换流阀在正常工作时所产生的热量,通过空气散热的部分一般小于总热量的 2%^[28-29],故可视为热量完全由阀冷系统的冷却水带走,因此,阀冷系统的入阀水温相当关键。当入阀水温过高时,所能带走的热量减少,阀冷系统的冷却能力就会下降。因此,阀冷系统会设定一个入阀水温报警值,当水温超过该报警值便会报警,表明当前阀冷系统的冷却能力已经无法满足换流阀在其运行状态下的换热需求,严重时甚至会导致换流阀烧损。但如果阀冷系统处于过度冷却状态,则会造成能源浪费。因此,将阀冷系统的冷却能力进行数值化定量评估有着重要的工程节能意义。

基于文中研究的柔性直流换流站实际情况,根据文献[15],对其中高压直流换流站阀冷系统冷却裕量的评估参数进行相应调整,同时不仅考虑换流阀传输的有功功率,还考虑其传输的无功功率,最后得到文中所研究的柔直换流站阀冷系统冷却裕量如式(10)所示。

$$S_r = [(S_{max} - S_n) / S_{max}] \times 100\% \quad (10)$$

式中: S_n 为当前阀侧负荷; S_{max} 为阀冷系统运行状态不变的情况下入阀水温报警值所对应的阀侧

负荷。

换流阀产热量主要由换流阀的传输功率决定,而换流阀的产热量是阀冷系统冷却水温度升高的直接原因,说明在同一时刻下,换流阀的负荷与阀冷系统的出阀水温和入阀水温的温差(以下简称出入水温差)存在一定相关性。因此,将测试集中的阀侧负荷 S_n 和阀冷系统出入水温差 ΔT 数据绘制成图 8,经过计算得到 2 组数据之间的相关系数为 97.76%,可以得出阀侧负荷和阀冷系统的出入水温差有着较强的正相关性。




图 8 阀侧负荷与阀冷系统出入水温差示意

Fig.8 Schematic diagram of the valve-side load and the temperature difference between the inlet and outlet water of the valve cooling system

因此,根据数据回归分析结果对阀侧负荷 S_n 与阀冷系统的出入水温差 ΔT 的关系进行描述,如式(11)所示。

$$S_n = 0.012\ 86\Delta T + 1.078 \quad (11)$$

再根据阀冷系统设定的入阀水温报警值 T_{max} ,结合入阀水温 T_{vi} ,根据式(12)即可计算出阀冷系统在该入阀水温下能够承受的最大产热量所对应的阀侧负荷。

$$S_{max} = \frac{T_{max} - T_{vi} - 1.078}{0.012\ 86} \quad (12)$$

由式(10)一式(12)计算出阀冷系统目前运行状态下的冷却裕量。通过阀冷系统的冷却裕量来指导阀冷系统的相关运维工作,相关流程如图 9 所示。

4.2 基于入阀水温的柔直阀冷系统冷却能力评估

阀冷系统冷却裕量的定量评估可为阀冷系统的运维工作提供至关重要的指导作用。基于 4.1 节中阀冷系统冷却裕量计算方法,4.2 节以一组连续预测的数据为例来说明该方法的可行性和准确性。

选取 2021 年 10 月 21 日的一段样本数据输入至已训练好的模型中,针对文中研究的广东电网某柔直换流站阀冷系统,其入阀水温报警值为 50 °C,

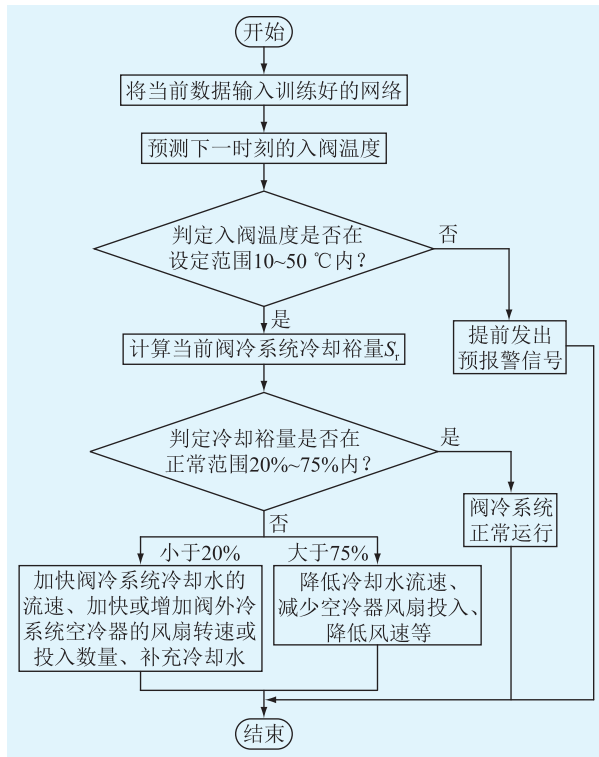


图9 柔直换流站阀冷系统冷却能力计算流程

Fig.9 Flow chart of the cooling capacity calculation of VSC-HVDC convert valve cooling system

入阀水温采用模型的预测值,由式(10)计算可得冷却裕量,结果如表5所示。

表5 下一时刻入阀水温及冷却裕量预测结果

Table 5 The prediction results of the inlet valve water temperature and cooling margin at the next step

时刻	入阀水温 实际值/℃	入阀水温 预测值/℃	误差/%	下一时刻 冷却裕量/%
06:50	30.01	30.11	0.33	98.504
06:55	30.06	30.15	0.30	98.474
07:00	30.11	30.21	0.33	98.456
07:05	30.15	30.26	0.36	98.445
07:10	30.20	30.27	0.23	98.448
07:15	30.25	30.30	0.16	98.448
07:20	30.29	30.31	0.07	98.446

由表5可知,文中所提预测模型在阀冷系统入阀水温的预测上误差非常小,满足精度要求,具有较高的准确性。同时可根据所预测的入阀水温计算下一时刻阀冷系统的冷却裕量,并实现了对阀冷系统的冷却能力的定量评估,为阀冷系统的运行维护工作提供指导作用。根据柔直换流站现场运维经验,当阀冷系统的冷却裕量低于20%时,说明该阀冷系统的冷却能力不足,应对与散热相关的零部件进行检查,加强换流阀的散热能力,例如加快阀冷系统冷却水的流速、加快或增加阀外冷系统空冷

器的风扇转速或投入数量、补充冷却水等;当阀冷系统的冷却裕量大于75%时,说明阀冷系统处于过冷却状态,存在能源浪费,须对当前运行状态进行优化,例如降低冷却水流速、减少空冷器风扇投入数量或降低阀外冷系统空冷器的风扇转速等。

在文中所研究的柔直换流站阀冷系统中,若出现冷却裕量较低的情况,应该对主循环泵、膨胀罐、补水罐及变频风机等关键散热设备进行检查,达到准确预警并提前消除风险、维护系统安全稳定运行的目的。而当阀冷系统的冷却裕量过高时,说明该系统运行在一个过度冷却状态,存在着能源浪费的情况,则可对系统的运行条件进行优化调整,降低能源损耗,节省能源。因此,根据表5可以看出,该阀冷系统存在着过度冷却的情况,这也与该阀冷系统目前的实际运行情况吻合。因为该阀冷系统当前是工作在主循环泵满负荷运行的工作状态,存在冷却能力冗余、能源浪费的情况,故该阀冷系统后续可针对主循环泵的运行策略进行优化。

5 结论

为实现对柔直换流站阀冷系统入阀水温的智能预测及对阀冷系统冷却能力进行评估,文中提出了一种基于 RF-BiLSTM 的柔直阀冷却系统入阀水温的预测及冷却能力评估方法。首先通过 RF 算法对可能影响入阀水温的高维变量进行重要性分析和选择,根据筛选后形成的特征向量构建 BiLSTM 预测模型的输入,构建 RF-BiLSTM 混合模型对入阀水温进行预测,最后根据预测的入阀水温对阀冷系统进行冷却裕量评估,为阀冷系统的运行维护提供参考和指导。文中方法有以下主要优点:

(1) 采用 RF 算法对可能影响入阀水温的 16 个特征进行重要性分析,最终选择出 7 个重要特征,使其与历史入阀水温构成输入特征向量,减少预测模型输入的维度,并提高预测精度。

(2) BiLSTM 模型能更加全面地挖掘时间序列数据中的信息,建立特征量与输出量之间的非线性时间序列关系。由实验结果可知,RF-BiLSTM 混合模型能够准确地有效地预测阀冷系统入阀水温, RMSE 可降至 0.074 03,优于其他模型。

(3) 利用 RF-BiLSTM 混合模型的预测水温可对阀冷系统的冷却能力进行定量评估。由实验结果可知,采用 RF-BiLSTM 混合模型预测水温的冷却裕量评估方法可以准确计算得到当前该阀冷系统的冷却裕量高达 98%,存在过度冷却、能源浪费的问题,与该换流站现场运行情况相符,说明文中所

提方法能够准确有效地指导阀冷系统运维决策过程。

文中采用 RF 算法对入阀水温重要影响特征进行选择,由于所能够获取的设计手册和设备参数有限,未深入探究各个特征对入阀水温影响的内在机理,因此在评估阀冷系统冷却能力后未能给出更加准确有效运维指导方案。在后续的研究中,将进一步研究各个重要影响特征对入阀水温的影响机制以及其他节点的水温预测与冷却能力评估,从而为整个柔直阀冷系统的运维工作提供更加准确有效的指导方案。

致 谢

本文得到中国南方电网有限责任公司科技项目(030500KK52200004(GDKJXM20200761))资助,谨此致谢!

参考文献:

[1] 周竞宇,赵宇,胡雨龙,等. MMC-HVDC 系统换流阀在线监测系统研究[J]. 自动化与仪表,2021,36(6):61-66,73.
ZHOU Jingyu,ZHAO Yu,HU Yulong,et al. Research on on-line monitoring technology of converter valve in MMC-HVDC system [J]. Automation & Instrumentation,2021,36(6):61-66,73.

[2] 杨柳,张丽,周月宾,等. 柔性直流换流阀与水冷变压器外冷却系统一体化设计方案[J]. 南方电网技术,2021,15(6):15-19,35.
YANG Liu,ZHANG Li,ZHOU Yuebin,et al. Integrated design scheme of external cooling system of VSC-HVDC converter valve and water-cooled transformer[J]. Southern Power System Technology,2021,15(6):15-19,35.

[3] BING G,HE T T,FAN Y,et al. Investigation on deposition behavior of HVDC water cooling system based on electro-mass transfer-velocity coupling model [J]. IEEE Access, 2019, 7: 67960-67971.

[4] 刘学忠,王晨星,刘宁,等. 换流阀内水冷系统泄漏电流对散热器腐蚀的影响[J]. 高电压技术,2020,46(5):1781-1790.
LIU Xuezhong,WANG Chenxing,LIU Ning,et al. Influence of leakage currents on corrosion of heat sinks in inner water cooling system for converter valve[J]. High Voltage Engineering,2020,46(5):1781-1790.

[5] 王涛. 基于 Fluent 的晶闸管阀冷却系统仿真研究[D]. 武汉:华中科技大学,2011.
WANG Tao. Simulation and research of thyristor valve cooling system based on Fluent [D]. Wuhan: Huazhong University of Science and Technology,2011.

[6] 唐文虎,牛哲文,赵柏宁,等. 数据驱动的人工智能技术在电力设备状态分析中的研究与应用[J]. 高电压技术,2020,46(9):2985-2999.
TANG Wenhui,NIU Zhewen,ZHAO Boning,et al. Research and application of data-driven artificial intelligence technology for condition analysis of power equipment[J]. High Voltage Engi-

neering,2020,46(9):2985-2999.

[7] 李东东,刘宇航,赵阳,等. 基于改进生成对抗网络的风机行星齿轮箱故障诊断方法[J]. 中国电机工程学报,2021,41(21):7496-7507.
LI Dongdong,LIU Yuhang,ZHAO Yang,et al. Fault diagnosis method of wind turbine planetary gearbox based on improved generative adversarial network [J]. Proceedings of the CSEE, 2021,41(21):7496-7507.

[8] ZHAO B N,NIU Z W,LIANG Q H,et al. Signal-to-signal translation for fault diagnosis of bearings and gears with few fault samples[J]. IEEE Transactions on Instrumentation and Measurement,2021,70:1-10.

[9] 杨子民,彭小圣,郎建勋,等. 基于集群动态划分与 BLSTM 深度学习的风电集群短期功率预测[J]. 高电压技术,2021,47(4):1195-1203.
YANG Zimin,PENG Xiaosheng,LANG Jianxun,et al. Short-term wind power prediction based on dynamic cluster division and BLSTM deep learning method[J]. High Voltage Engineering,2021,47(4):1195-1203.

[10] 张群,唐振浩,王恭,等. 基于长短时记忆网络的超短期风功率预测模型[J]. 太阳能学报,2021,42(10):275-281.
ZHANG Qun,TANG Zhenhao,WANG Gong,et al. Ultra-short-term wind power prediction model based on long and short term memory network [J]. Acta Energiæ Solaris Sinica, 2021,42(10):275-281.

[11] SASSER C,YU M L,DELGADO R. Improvement of wind power prediction from meteorological characterization with machine learning models [J]. Renewable Energy, 2022, 183: 491-501.

[12] 董彦军,王晓甜,马红明,等. 基于随机森林与长短期记忆网络的电力负荷预测方法[J]. 全球能源互联网,2022,5(2):147-156.
DONG Yanjun,WANG Xiaotian,MA Hongming,et al. Power load forecasting method based on random forest and long short-term memory [J]. Journal of Global Energy Interconnection, 2022,5(2):147-156.

[13] 张宇帆,艾芊,林琳,等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术,2019,43(6):1884-1892.
ZHANG Yufan,AI Qian,LIN Lin,et al. A very short-term load forecasting method based on deep LSTM RNN at zone level [J]. Power System Technology,2019,43(6):1884-1892.

[14] 张朝辉,梁家豪,梁秉岗,等. 基于时序分析的阀冷进阀温度预测方法[J]. 计算机系统应用,2021,30(4):9-16.
ZHANG Chaohui,LIANG Jiahao,LIANG Binggang,et al. Prediction of inlet valve temperature based on time series analysis [J]. Computer Systems & Applications,2021,30(4):9-16.

[15] 陈强华. 基于多维时序数据的运维优化技术研究[D]. 济南:山东大学,2020.
CHEN Qianghua. Research on optimization of operation and maintenance based on multidimensional time series data [D]. Jinan:Shandong University,2020.

- [16] 廖毅,罗炜,蒋峰伟,等. 基于 LSTM 的阀冷系统入水温度及冷却裕度预测[J]. 山东大学学报(工学版),2021,51(4):124-130.
LIAO Yi,LUO Wei,JIANG Fengwei,et al. Prediction of converter valve cooling capacity and water inlet temperature based on LSTM[J]. Journal of Shandong University (Engineering Science),2021,51(4):124-130.
- [17] 廖毅,罗炜,蒋峰伟,等. 换流阀冷却能力多维度分析与预警模型[J]. 南方电网技术,2020,14(7):1-9.
LIAO Yi,LUO Wei,JIANG Fengwei,et al. Multi-dimensional analysis and early warning model for the cooling capacity of converter valve[J]. Southern Power System Technology,2020,14(7):1-9.
- [18] 桂辉阳,杨贵军,谢保鸡,等. 柔性直流阀冷系统设计缺陷及改进措施研究[J]. 电工技术,2021(20):158-160.
GUI Huiyang,YANG Guijun,XIE Baoji,et al. Research on design defects and improvement measures of flexible DC valve cooling system[J]. Electric Engineering,2021(20):158-160.
- [19] 邓艺璇,黄玉萍,黄周春. 基于随机森林算法的电动汽车充放电容量预测[J]. 电力系统自动化,2021,45(21):181-188.
DENG Yixuan,HUANG Yuping,HUANG Zhouchun. Charging and discharging capacity forecasting of electric vehicles based on random forest algorithm[J]. Automation of Electric Power Systems,2021,45(21):181-188.
- [20] 李冠争,李斌,王帅,等. 基于特征选择和随机森林的电力系统受扰后动态频率预测[J]. 电网技术,2021,45(7):2492-2502.
LI Guanzheng,LI Bin,WANG Shuai,et al. Dynamic frequency prediction of power system post-disturbance based on feature selection and random forest[J]. Power System Technology,2021,45(7):2492-2502.
- [21] 李蔚,吴恺逾,陈坚红,等. 基于非线性自回归神经网络和随机森林算法的核电汽轮机组出力优化[J]. 中国电机工程学报,2021,41(2):409-416.
LI Wei,WU Kaiyu,CHEN Jianhong,et al. Output optimization of nuclear power steam turbine based on nonlinear autoregressive neural network and random forest algorithm[J]. Proceedings of the CSEE,2021,41(2):409-416.
- [22] 江叶峰,孙少华,仇晨光,等. 电网故障处置预案文本中的命名实体识别研究[J]. 电力工程技术,2021,40(5):177-183.
JIANG Yefeng,SUN Shaohua,QIU Chenguang,et al. Named entity recognition in power fault disposal preplan text[J]. Electric Power Engineering Technology,2021,40(5):177-183.
- [23] ZHANG C,MA H X,HUA L,et al. An evolutionary deep learning model based on TVFEMD,improved sine cosine algorithm,CNN and BiLSTM for wind speed prediction[J]. Energy,2022,254:124250.
- [24] 冯斌,张又文,唐昕,等. 基于 BiLSTM-Attention 神经网络的电力设备缺陷文本挖掘[J]. 中国电机工程学报,2020,40(S1):1-10.
FENG Bin,ZHANG Youwen,TANG Xin,et al. Power equipment defect record text mining based on BiLSTM-Attention neural network[J]. Proceedings of the CSEE,2020,40(S1):1-10.
- [25] 余印振,韩哲哲,许传龙. 基于深度卷积神经网络和支持向量机的 NO_x 浓度预测[J]. 中国电机工程学报,2022,42(1):238-248.
YU Yinzhen,HAN Zhezhe,XU Chuanlong. NO_x concentration prediction based on deep convolution neural network and support vector machine[J]. Proceedings of the CSEE,2022,42(1):238-248.
- [26] 田书欣,周全,程浩忠,等. 基于鸽群优化算法的支持向量机在电力需求总量预测中的应用[J]. 电力自动化设备,2020,40(5):173-181.
TIAN Shuxin,ZHOU Quan,CHENG Haozhong,et al. Application of pigeon-inspired optimization algorithm based SVM in total power demand forecasting[J]. Electric Power Automation Equipment,2020,40(5):173-181.
- [27] 邓祥力,张乾波. 基于 ARMA 和 Copula 理论的多因素 GIS 设备家族性缺陷故障预警[J]. 高压电器,2022,58(2):9-16.
DENG Xiangli,ZHANG Qianbo. Fault warning of family defects in multi-factor GIS equipment based on ARMA and Copula theory[J]. High Voltage Apparatus,2022,58(2):9-16.
- [28] 娄彦涛,袁妮,刘琦. 高压直流输电晶闸管换流阀损耗仿真计算方法研究[J]. 高压电器,2021,57(1):116-122,128.
LOU Yantao,YUAN Ni,LIU Qi. Study on simulation calculation method of power losses for HVDC thyristor valve[J]. High Voltage Apparatus,2021,57(1):116-122,128.
- [29] 蒋冠前,吴红艳,王帅卿,等. 柔性直流输电换流阀阀塔电场分布与结构设计研究[J]. 电力系统保护与控制,2022,50(17):178-186.
JIANG Guanqian,WU Hongyan,WANG Shuaiqing,et al. Study on electric field distribution and structural design of converter valve tower of flexible DC transmission[J]. Power System Protection and Control,2022,50(17):178-186.

作者简介:



唐文虎

唐文虎(1974),男,博士,教授,研究方向为电力设备智能化、风力发电、智能变电站和电力系统状态风险评估(E-mail:wenhutang@scut.edu.cn);

林泽康(1997),男,硕士在读,研究方向为机器学习在电力设备状态监测、数字孪生;

辛妍丽(1988),女,博士,讲师,研究方向为海上风电场建模、电力设备及线路故障诊断、过电压机理与绝缘配合、数字孪生技术。

(下转第 148 页)

Low carbon scheduling of multi-energy system based on power to gas combined with oxygen enriched combustion

WANG Can^{1,2}, LI Xinran¹, ZHAO Jihong³, TIAN Fuyin¹, CHU Sihui¹, WANG Aoqi¹

(1. School of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station (China Three Gorges University), Yichang 443002, China; 3. Hunan Deli Electric Power Construction Group Co., Ltd., Changde 415009, China)

Abstract: Power to gas (P2G) technology realizes the mutual coupling of electric energy and natural gas, and plays an important role in improving the economy of multi-energy system and reducing the carbon emissions of the system. In order to solve the problem that the oxygen produced by electrolyzed water in the process of P2G conversion can not be fully utilized, a multi-energy system optimal scheduling model is proposed based on the joint operation of P2G and oxygen enriched combustion power plants. Firstly, the P2G process is divided into power to hydrogen process and methanation process. The oxygen generated in the power to hydrogen process is delivered to oxygen enriched combustion power plant for use. Then, the CO₂ captured by the oxygen enriched combustion power plant and the hydrogen generated during the power to hydrogen conversion process are used as the raw materials for the methanation reaction, and the natural gas generated is supplied to the gas turbine unit for use, so as to realize the full utilization of resources. Secondly, the joint operation model of P2G and oxygen enriched combustion power plants is introduced into the multi-energy system, and a low carbon multi-energy system architecture based on the joint P2G and oxygen enriched combustion power plants is built. Finally, a low-carbon economic scheduling model with the goal of minimizing the operating cost of the multi-energy system is established and verified by setting up a scenario comparison. The simulation results show that the proposed model effectively reduces the system cost and carbon emissions.

Keywords: power to gas (P2G); oxygen enriched combustion; carbon capture; multi-energy system; low carbon optimization; carbon trading

(编辑 吴昊)

(上接第 111 页)

Prediction of valve inlet water temperature and cooling evaluation of VSC-HVDC convert valve cooling system based on random forest and bi-directional long short-term memory

TANG Wenhui¹, LIN Zekang¹, XIN Yanli², ZHAO Wei¹, WU Liang³, JIN Jing³

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China;
2. School of Automation, Guangdong Polytechnic Normal University, Guangzhou 510665, China;
3. Shantou Power Supply Bureau of China Southern Power Grid Co., Ltd., Shantou 515000, China)

Abstract: In order to realize the intelligent prediction of valve inlet water temperature of a voltage sourced converter-high voltage direct current (VSC-HVDC) valve cooling system, a prediction model of inlet water temperature of VSC-HVDC based on a hybrid model of the random forest (RF) and bi-directional long short-term memory (BiLSTM) is proposed, and the cooling capacity of the cooling system is evaluated on the basis of the proposed prediction model. Firstly, a RF algorithm is used to analyze the importance of high-dimensional feature sets, which consist of all the monitoring variables of the valve cooling system. Then the important characteristic parameters affecting the inlet water temperature are filtered out to form an input feature vector with the historical inlet water temperature. Secondly, the feature vector is input to the developed BiLSTM prediction model to train the model for accurately predicting inlet valve water temperature and quantitatively evaluating the cooling capacity. Finally, a VSC-HVDC converter station in Guangdong power grid is taken as an example to verify the effectiveness and superiority of the proposed method. Simulation results indicate that the accuracy of the proposed hybrid model based on RF-BiLSTM is higher than that based on BiLSTM model, RF model, support vector machine (SVM) model and auto-regressive and moving average (ARMA) model. Moreover, the cooling capacity is evaluated quantitatively and accurately. Analysis results show that the cooling margin of this converter station is up to 98%, which indicates that there is a problem of overcooling and energy waste. The evaluation result of the cooling capacity is well consistent with the field operation result of the converter station, which confirms the effectiveness and the accuracy of the proposed method.

Keywords: voltage sourced converter-high voltage direct current (VSC-HVDC) convert valve cooling system; machine learning; random forest (RF) algorithm; bi-directional long and short-term memory (BiLSTM) network; valve water inlet temperature prediction; cooling capacity assessment

(编辑 李栋)