

DOI: 10.19650/j.cnki.cjsi.J2108460

基于图像卷积变分自编码的电站锅炉 燃烧稳定性评价方法*

蔡国源^{1,2}, 牛玉广^{1,2}, 刘雪菲^{1,2}, 杜 鸣^{1,2}, 张 庭^{1,2}

(1. 华北电力大学新能源电力系统国家重点实验室 北京 102206; 2. 华北电力大学控制与计算机工程学院 北京 102206)

摘 要:为实现基于电站锅炉火焰图像的燃烧稳定性定量表征,并克服不稳定燃烧样本不足的训练难题,提出一种基于卷积变分自编码模型的燃烧稳定性实时、定量表征方法。首先使用稳定燃烧工况下的火焰图像进行模型训练,利用卷积变分自编码器得到稳定燃烧图像的高维潜在概率分布。记录该模型对应的隐变量分布特征,计算该分布与标准正态分布之间的 KL 散度值,利用该 KL 散度实现燃烧稳定性的定量表征。在仿真验证中,通过对比说明引入变分推断理论可提高模型对于燃烧图像的重构质量,图片重构前后均方根误差为 0.005 48;通过磨煤机给煤量调整实验,人为制造不同稳定度的燃烧器燃烧工况,验证了该评价方法的准确性和有效性,评价准确率高达 92.1%;通过与煤火检评价结果的比较,表明该方法具备煤火检系统对于火焰的定量判断功能,且感知能力更加灵敏,能在燃烧器灭火前 167 s 给出燃烧不稳定的预警,具有一定的工程应用价值。

关键词: 火焰图像;卷积神经网络;变分自编码器;电站锅炉;燃烧稳定性

中图分类号: TH89 TK227 文献标识码: A 国家标准学科分类代码: 470.20

Combustion stability judgment of power plant boiler based on image convolutional variational auto-encoder

Cai Guoyuan^{1,2}, Niu Yuguang^{1,2}, Liu Xuefei^{1,2}, Du Ming^{1,2}, Zhang Ting^{1,2}

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: To realize the quantitative characterization of combustion stability based on boiler flame images and overcome the training problem of insufficient unstable combustion samples, a real-time and quantitative characterization method of combustion stability based on the convolutional variational autoencoding model is proposed. First, the model is trained by using the flame images under stable combustion conditions, and the high-dimensional latent probability distribution of the stable combustion image is obtained by using the convolutional variational autoencoder. The distribution characteristics of the latent variables corresponding to the model are recorded, the KL divergence value between the distribution and the standard normal distribution is calculated. The KL divergence is used to realize the quantitative characterization of combustion stability. In the simulation verification, the comparison experiments show that the introduction of variational inference theory can improve the reconstruction quality of the model for the combustion image, and the root mean square error before and after image reconstruction is 0.005 48. The accuracy and effectiveness of the evaluation method are verified through the experiment of adjusting the coal feeding amount of the coal mill to artificially create the combustion conditions of the burner with different degrees of stability, and the evaluation accuracy rate is as high as 92.1%. The comparison results with the coal fire inspection and evaluation show that the method has the quantitative judgment function of the coal fire inspection system for flame, and the sensing ability is more sensitive. It can give the warning of combustion instability in 167 s before the burner fires, which has certain engineering application value.

Keywords: flame image; convolutional neural network; variational auto-encoder; power plant boiler; combustion stability

收稿日期: 2021-08-22 Received Date: 2021-08-22

* 基金项目: 国家重点研发计划(2017YFB0902100)项目资助

0 引言

燃煤电站的燃烧稳定性研究一直以来都备受关注,一方面,锅炉燃烧的稳定性决定了机组运行的安全性及使用寿命,影响了机组运行时的经济性能和环保性能;另一方面,在当前阶段,低负荷深度调峰成为燃煤锅炉的主要改造趋势,只有在保证炉膛燃烧稳定的前提下,才能进一步降低锅炉的最小技术出力^[1-3]。因此,研究一种实时的燃煤锅炉燃烧稳定性检测方法具有重要意义。

电站锅炉燃烧稳定性的分析方法根据使用检测手段的不同,目前大致可以分成3种,基于火焰强度、基于机组运行过程参数、基于燃烧火焰图像。基于火焰强度的燃烧判稳主要是对提取到的火焰光强信号的频谱进行分析,文献[4]采用傅里叶变换将收集的高频火焰强度转换为功率谱分析,使用神经网络识别燃烧工况。文献[5]为解决误判现象,提出将火焰强度信号小波多尺度去噪、分解变换,以BP网络为分类识别器的方法去判别燃烧状态。该方法具有一定的可行性,适用于实验室环境,但因为煤粉炉膛燃烧器的布局影响,相邻燃烧器可能对光强信号产生干扰,部分应用场景下准确度有待提高。基于过程参数的燃烧判稳方法,是将锅炉视为一个系统整体,选取一部分与燃烧相关的过程参数用于表征燃烧稳定性。文献[6]在机理分析的基础上,选取了火焰强度、炉膛压力和蒸汽热能参数作为燃烧稳定性评价指标,提出了Hurst指数与燃烧稳定性的关系。文献[7]通过采用D-S证据理论方法对常规火检信号和炉膛压力信号进行融合,得到综合诊断结果,并提出了一种简单可行的基本概率分配方法来实现对燃烧稳定的判断。基于机组运行过程参数的燃烧判稳方法的准确性在很大程度上取决于测点对于燃烧的代表能力,因不同电站的测点各不相同,该方法通用性较差,并且该方法实用性较差。

相比于以上两种方法,基于火焰图像的燃烧稳定性判断是目前较为热门的一个研究方向。该方法主要是通过图像处理技术,提取图像的发光参数^[8-10]、颜色特征^[11-12]、几何特征^[13-14]、闪烁信息^[15]、纹理特征^[16]等,并依据这些图像的特征参数去表征燃烧稳定性。近年来随着机器学习的发展,神经网络自学习方法被利用在基于火焰图像的燃烧判稳。在最新的研究中,往往利用神经网络自学习方法对图像中的表达性特征进行学习,然后从这些特征里寻找与燃烧稳定性相关的表征信息。文献[17]利用深度置信网络获取炉膛内火焰图像的特征,进行燃烧状态识别,文献[18]将独立子空间与卷积神经网络结合,对回转窑火焰图像进行研究,得到燃烧图像的全局特征;文献[19]提出了一种自编码神经网络和隐马尔可夫链相结合的模型,对煤粉图像聚类,进而得到燃烧

稳定性判别。火焰图像是煤粉燃烧的最直观表现形式,包含着许多燃烧特征,结合人工神经网络对图像的特征提取能力,用于燃烧稳定性的判断具有很大的研究价值。但是,上述文献提出的方法主要针对燃烧稳定和不稳定状态的判别,这种趋向二值的燃烧稳定性判断较为消极,不能给出一个稳定性的具体量化指标。另一方面,目前相关研究主要是利用神经网络对大量稳定和不稳定燃烧工况的图像进行有监督的学习,然而在实际电站锅炉运行中很难收集到足够多不稳定燃烧的样本,因此基于神经网络的方法具有很大的局限性。

针对上述问题,本文提出一种基于卷积变分自编码(convolutional variational autoencoder, CVAE)的燃烧稳定性实时、定量评价方法,在稳定燃烧工况下,对火焰图像进行CVAE模型训练,利用卷积变分自编码器学习出稳定燃烧图像的高维潜在概率分布,建立火焰图像与燃烧稳定程度的映射模型,实现对于煤粉燃烧的稳定性定量表征。该方法不仅使用了深度神经网络对火焰图像的特征进行挖掘,而且利用变分推断理论提升了模型对于不稳定燃烧图像的重构能力,模型的训练只需使用稳定工况的图像,克服了不稳定燃烧样本不足的训练难题。

1 卷积变分自编码

1.1 变分自编码

变分自编码器(variational autoencoder, VAE)是由Kingma等于2014年提出的基于变分贝叶斯推断的生成式网络结构,被广泛用于图像生成和故障诊断等方面^[20-22]。它是一类确定性逼近方法,通过变分参数的不断迭代更新来最大化观测数据的边缘似然函数的下界,近似得到不可观测变量的后验概率。变分自编码器利用两个神经网络建立两个概率密度分布模型:一个用于原始输入数据的变分推断,生成隐层变量的变分概率分布,称为推断网络;另一个根据生成的隐变量变分概率分布,还原生成原始数据的近似概率分布,称为生成网络。

图1为变分自编码的模型结构示意图,假设数据集 \mathbf{X} 为VAE模型的输入, z 为隐藏层变量,生成模型表示为 $p_{\theta}(\mathbf{X}|z)$,推断模型为 $q_{\phi}(z|\mathbf{X})$,数据集 \mathbf{X} 是由一个低维基础先验分布 $p_{\theta}(z)$ 和一个条件概率分布 $p_{\theta}(x|z)$ 形成的,如式(1)所示。

$$p_{\theta}(\mathbf{X}) = \int p_{\theta}(x|z)p_{\theta}(z)dz \quad (1)$$

如果极大化式(1)的似然概率,则可以估计观测数据的真实分布,但式(1)的积分公式无法直接计算。VAE通过变分推断的方法,假设所有的数据满足独立同分布,则可以使用推断模型去逼近真实的生成模型,并用KL散度(Kullback-Leibler divergence)去衡量这两个分布的

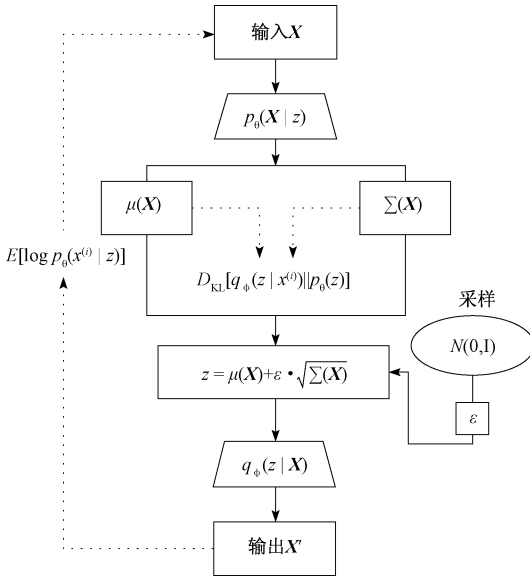


图1 变分自编码模型示意图

Fig.1 Schematic diagram of the variational autoencoding model

相似程度,如式(2)所示。

$$D_{\text{KL}}(q_{\phi}(z|x^{(i)}) \| p_{\theta}(z|x^{(i)})) = E_{q_{\phi}(z|x^{(i)})} [\log q_{\phi}(z|x^{(i)}) - \log p_{\theta}(z|x^{(i)})] \quad (2)$$

式中: D_{KL} 为 KL 散度函数, E 为数学期望函数, $x^{(i)}$ 表示数据集 X 的第 i 个样本数据。

该 KL 散度用来判断两个分布的相似程度, KL 散度小, 则分布越相似; 反之, 则分布偏差大。对式(2)进行变形, 得到式(3)。

$$\log p_{\theta}(x^{(i)}) - D_{\text{KL}}(q_{\phi}(z|x^{(i)}) \| p_{\theta}(z|x^{(i)})) = E[\log p_{\theta}(x^{(i)}|z)] - D_{\text{KL}}[q_{\phi}(z|x^{(i)}) \| p_{\theta}(z)] \quad (3)$$

在给定数据集 X 后, $\log p_{\theta}(x^{(i)})$ 是一个固定值, $E[\log p_{\theta}(x^{(i)}|z)]$ 是基于生成模型的数学期望, 通过推导, 优化目标可转化成为极大化 VAE 的变分下界 ELBO (evidence lower bound), 即式(4)。

$$\text{ELBO} = E[\log p_{\theta}(x^{(i)}|z)] - D_{\text{KL}}[q_{\phi}(z|x^{(i)}) \| p_{\theta}(z)] \quad (4)$$

该 ELBO 作为 VAE 训练模型的损失函数, 主要由两部分组成: 最小化生成数据集和原数据集的重构损失、最小化识别模型概率分布与潜在变量 z 的概率分布之间的 KL 散度。

假设潜在变量 z 服从多维正态分布, 并且让推断模型 $q_{\phi}(z|X)$ 去逼近具有对角协方差的正态分布, 即式(5):

$$p_{\theta}(z) \sim N(0, I) \quad q_{\phi}(z|x) \sim N(\mu(X), \Sigma(X)) \quad (5)$$

该公式中的 $\mu(X)$ 和 $\Sigma(X)$ 是近似后验分布的均值和方差, 由生成模型 $p_{\theta}(X|z)$ 计算得到。同时式(1)生成模型和推断模型由神经网络模型来组成。

基于式(5)给出的假设, 可将式(4)的 ELBO 右侧的具体化为式(6)和(7):

$$D_{\text{KL}}[q_{\phi}(z|x^{(i)}) \| p_{\theta}(z)] = \sum_{j=1}^J \frac{1}{2} (1 - (\sigma_{\text{encj}}^{(i)})^2 - (\mu_{\text{encj}}^{(i)})^2 + \log(\sigma_{\text{encj}}^{(i)})^2) \quad (6)$$

$$E[\log p_{\theta}(x^{(i)}|z)] = - \sum_{i=1}^n x_i \log(x_i') + (1 - x_i) \log(1 - x_i') \quad (7)$$

式中: J 为隐变量 z 的维度, n 为数据集的维度, $\mu_{\text{encj}}^{(i)}$ 和 $\sigma_{\text{encj}}^{(i)}$ 是第 i 个样本数据经过推断模型输出的隐层均值和方差。

ELBO 右侧的具体化后, 式(6)为隐层损失 (latent loss), 计算 VAE 模型隐藏分布与正态分布之间的 KL 散度值, 式(7)为重构误差 (reconstruction loss), 计算输入 X 与输出 X' 之间的交叉熵。两式之和为该 VAE 模型训练时的损失函数, 使用随机梯度下降算法最小化该损失函数, 即可对生成模型和推断模型的神经网络内参数进行更新, 当损失函数收敛或者趋于稳定时, 模型训练完毕。

在该变分自编码模型中, 由于使用了随机采样得到隐层变量 z , 在网络训练时将无法反向传播。本文采用“重参数化技巧” (reparameterization trick), 通过从 $N(0, I)$ 的标准分布中随机采样一个 ϵ , 使用式(8)结合近似后验分布计算出的均值 $\mu(X)$ 和方差 $\Sigma(X)$, 进行隐层 z 的计算。由此解决该网络模型无法反向传播的问题。

$$z = \mu(X) + \epsilon \cdot \sqrt{\Sigma(X)} \quad (8)$$

由于该模型整结构与自编码器结构类似, 因此被称为变分自编码器。但通过以上分析可知, VAE 的作用原理和自编码器的作用原理完全不同, VAE 的“编码器”和“解码器”的输出都是受参数约束变量的概率密度分布, 而不是某种特定的编码, 因此得到的隐变量更具有表达意义。

1.2 火焰图像卷积神经网络

在传统的变分自编码器中, 它的推断模型和生成模型使用人工神经网络代替, 即使用若干个全连接的线性层结合激活函数层进行模型的训练。本文使用的输入数据集是燃烧火焰的彩色图像, 维度较大, 若单纯使用全连接的线性层将使得训练参数数量十分巨大, 模型复杂度显著增大, 以至于无法完成传统 VAE 模型的训练。卷积神经网络具有参数共享 (parameter sharing) 和稀疏连接 (sparsity of connections) 的特点, 使得系统中参数数量大幅度减少。同时卷积网络具有平移不变性, 对于图片中某个目标位置的平移将有较大的鲁棒性。因此本文将卷积神经网络应用在变分自编码的推断模型和生成模型中, 提出一种卷积变分自编码模型。典型的卷积神经网络主要由输入层、卷积层、池化层、激活函数层、全连接层及输出层组成。

卷积层:卷积层的卷积操作是一种线性的、具有平移不变性的运算。通过卷积操作,可以让网络学习到火焰图像的轮廓信息,还可以学习到火焰图像的颜色、纹理等深层特征。假设输入 $M \times N$ 的图像,用矩阵 \mathbf{x} 表示,卷积核是一个大小为 $m \times n$ 的矩阵 \mathbf{W} ,偏置为 \mathbf{b} ,卷积计算过程如式(9)所示。

$$\mathbf{h} = \mathbf{x}_{M \times N} * \mathbf{W}_{m \times n} + \mathbf{b} \quad (9)$$

式中: * 代表二维卷积操作, \mathbf{h} 表示卷积后输出的图像。

池化层:池化层是一种模拟生物视觉神经系统对于视觉图像的抽样和降维的过程,可以对火焰图像部分特征进行降维且防止模型的过拟合现象,在卷积神经网络中通常会周期性的插入池化层。结合火焰图像的特点,该卷积变分自编码模型中选用最大下采样的池化操作,它通过对原图像定义一个空间邻域(例如一个 2×2 的窗口),并从邻域内取出最大值,以达到原图像数据压缩的目的。

激活函数层:提高网络对于非线性模型的表达能力。考虑到火焰图像的不同区域间亮度差异明显,存在亮区和暗区两个极端,本文的卷积变分自编码模型主要采用了指数线性单元(exponential linear unit, ELU)的激活函数,如式(10)所示。

$$f(x) = \begin{cases} a(e^x - 1), & x < 0 \\ x, & x \geq 0 \end{cases} \quad (10)$$

式中: x 表示激活函数层的输入值,参数 a 用于调整负数区域激活程度, e 为自然底数。

ELU 激活函数结合了 Sigmoid 函数和 ReLU 函数的特点,函数右侧线性部分使得能和 ReLU 一样缓解梯度消失问题;左侧软饱和部分可以让激活单元的输出均值往 0 逼近,达到与批标准化操作(batchnormalization)同样的效果且减少了计算量,提升网络对于噪声的鲁棒性。3个非线性激活函数如下图2所示。




图2 3种激活函数的数学形式

Fig. 2 The mathematical forms of three activation functions

图3为卷积变分自编码模型的简洁示意图,在实际运用中可以通过适当增加卷积层、池化层和全连接层的数量提升模型的准确性。

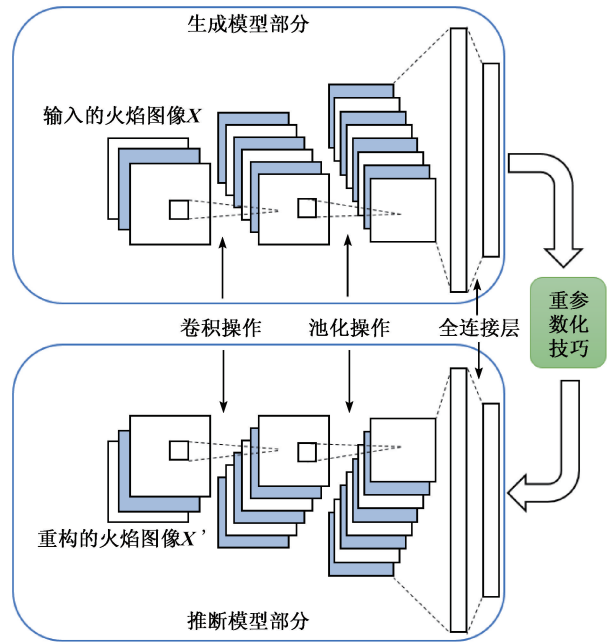


图3 卷积变分自编码模型示意图

Fig. 3 Schematic diagram of the convolutional variational autoencoding model

2 燃烧稳定性评判方法

综上所述,本文所提燃烧稳定性定量表征方法的流程如图4所示。

首先使用处于稳定燃烧工况下的火焰图像作为训练样本,对卷积变分自编码模型进行训练,因该模型能够自主学习出数据所服从的分布特点,所以认为训练后的CVAE模型中包含了火焰稳定燃烧工况下图像隐藏的关系特性。当使用新的火焰图像送入该模型时,可以重构原图像,并计算出隐藏层变量 z 的分布与标准正态分布之间的KL散度值。

其中,重构图像与原图像的像素点偏差值可以反映该模型对于燃烧图像的评判能力,即式(7)。隐藏层变量 z 与标准正态分布之间的KL散度则可以作为燃烧稳定性的评判指标,即式(6)。由于变分自编码模型本身的性质,通过生成模型计算出的隐含层变量 z 是逼近于正态分布的,使用稳定工况下的燃烧图像计算出的KL散度的大小是相近的,当燃烧工况改变,该KL散度就会偏离,通过该偏差的大小即可反映燃烧稳定程度。

以下介绍将该KL散度转化成稳定程度的方法。首先,将经挑选得到的稳定工况下火焰图像送入训练后的CAVE模型,计算一组KL散度值。统计该组KL散度值的均值 μ_{KL} 和方差 σ_{KL} ,使用式(11)计算燃烧稳定性,该

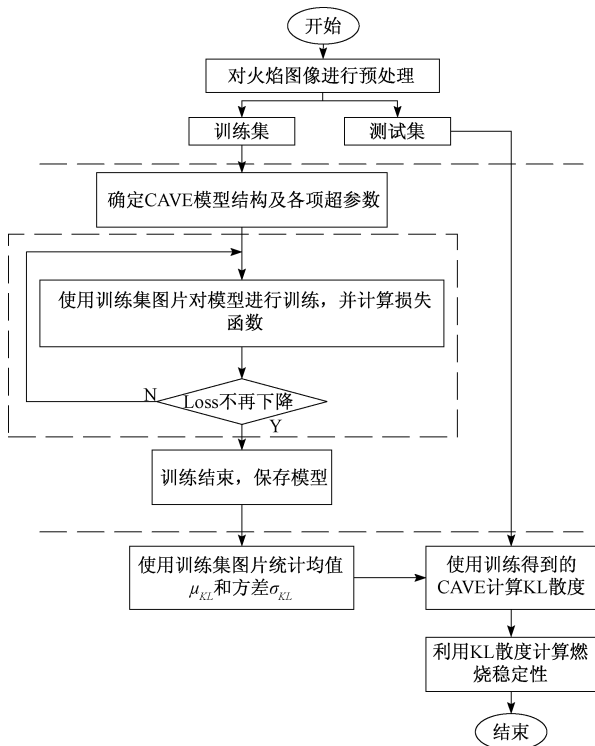


图4 燃烧稳定性计算方法流程

Fig. 4 Flow chart of the combustion stability calculation method

STA 数值(STABILITY)的大小范围在 $[0, 1]$ 之间,数值越大表示燃烧越稳定,趋近于0时候表示燃烧极不稳定或者炉膛灭火。

$$STA = \exp\left(\frac{-|D_{KL}[q_{\phi}(z|x^{(t)}) || p_{\theta}(z)] - \mu_{KL}|}{\sigma_{KL} \cdot C}\right) \quad (11)$$

式中: D_{KL} 为实时采集火焰图像样本输入模型计算的隐藏层变量 z 的分布与标准正态分布之间的KL散度值,参数 C 为燃烧稳定性的灵敏度,通过改变该数值的大小可以调整稳定评判的灵敏度。

3 实验数据获取

本文使用的燃烧火焰图像取自吉林省某660 MW燃煤火电机组,经过改造,该机组最小技术出力降低至30%额定负荷。该机组为前后墙对冲燃烧方式,使用低 NO_x 轴向旋流燃烧器,其中前墙从上到下依次为C、D、E、F层燃烧器,后墙从上到下依次为A、B、G层燃烧器,每层布置5个燃烧器。低负荷工况下使用底层燃烧器,F层燃烧器是锅炉底层燃烧器之一,该层的燃烧稳定性判断具有极高的价值,可代表锅炉的燃烧稳定性,是机组低负荷安全运行的一个重要参考依据。在F层3号燃烧器的观火孔位置安装CCD图像传感器,将光信号转化成电信

号,最后将视频图像存储在硬盘录像机里。视频图像每秒25帧,每帧火焰图片的分辨率为 960×576 ,为RGB三通道的彩色图像。图像探头为铁岭市北方自动化仪器仪表有限公司的BFDD-hj-2000型号火焰图像探头,相机的感光元件采用1/4英寸的CCD图像传感器,该探头近炉端使用透镜组将火焰图像传至炉墙外部,CCD图像传感器安装于尾部位于炉墙外侧,可在燃烧器平台处进行视角对焦和相关参数调整,保证火焰图像质量。

锅炉燃烧过程中,煤粉浓度是影响燃烧稳定性的重要因素,当煤粉浓度降低,煤热分解释放出的挥发分含量减少,燃烧释放的热量降低,导致炉膛温度下降,形成不稳定的燃烧工况。因此,燃烧器发生不稳定燃烧时,主要是燃烧器出口的煤粉燃烧不充分引起,该不充分燃烧现象可通过减少给煤量来模拟实现,并用火焰图像进行捕捉。通过给煤量调整实验可用于模拟不稳定燃烧工况,但反过来使用给煤量数值不能直接判断燃烧稳定与否,在实际运行中,一些突发的不稳定燃烧工况下给煤量数值正常,但因其他因素导致煤粉不充分燃烧,不稳定燃烧状况仍会发生。

基于上述分析,在该电厂F磨煤机上进行给煤量调整实验,通过改变F磨煤机的给煤量,使燃烧器产生稳定和 unstable 燃烧工况,进而得到代表不同稳定性程度的火焰燃烧图像。

下图5是实验当日11:00~17:00的给煤量变化图。图中的阶段I从11:00~14:00作为测试集,给煤量在50 t/h与64.5 t/h之间变化,标准差为3.15,这段时间里给煤量只进行了小幅度调整,因此认为该时间段内的火焰图像属于稳定燃烧工况。图中的阶段II从14:00~17:00作为验证集,该阶段内进行了给煤量递减和递增实验,在14:35给煤量开始逐渐递减,直到14:45给煤量降为0 t/h,保持停煤状态,接着从15:02开始给煤量逐渐增加,15:12左右恢复到50 t/h的给煤量,在这个阶段内,由于给煤量的减少,形成一个不稳定的燃烧工况,直到燃烧器灭火,之后由于给煤量增加,燃烧重新回到稳定状态。




图5 F磨煤机给煤量变化图

Fig. 5 Coal quantity's variation diagram of coal mil F

图 6 是阶段 I 和阶段 II 里几个具有代表性的火焰图像,其中图 6(a)~(c)是 11:00~14:00 时间段里 3 个稳定燃烧的火焰图像,可以看到火焰形状丰满且具有明显的颜色分层;图 6(d)是给煤量减少过程的火焰图像,图 6(e)是给煤量为 0 t/h 时的火焰图像,图 6(f)是给煤量从 0 t/h 递增过程时的火焰图像,可以观察到这个时间段煤粉处于不稳定燃烧状态,火焰轮廓偏小或消失,火焰几乎不存在分层。




图 6 阶段 I 和阶段 II 里的火焰图像

Fig. 6 Fire images from stage I and stage II

4 实验与分析

4.1 模型基本参数设置

实验平台配置为 AMD-5950X 处理器,显卡为 NVIDIA GeForce RTX3080,内存为 32 G,操作系统为 Window10 专业版,代码采用 Python3.7 实现。

对于采集到的火焰图片,利用像素平均法对每秒内的 25 帧的图片进行处理,获得代表该秒级时间段的高质量燃烧火焰图像。原图像的分辨率为 $960 \times 576 \times 3$ 的 RGB 图像,为了提升 CVAE 模型的训练效率,减少训练的数据量和时间,通过双线性插值法将图像像素压缩为 $128 \times 128 \times 3$,并将图像像素范围由 $[0, 255]$ 归一化为 $[0, 1]$ 。其中阶段 I 为 11:00~14:00 共 3 个小时,经过上述的预处理,得到 108 000 张图像,用于 CVAE 模型的训练;阶段 II 为 14:00~17:00 共 3 个小时,经过上述的预处理得到 108 000 张图像,用于模型的验证和测试。

将阶段 I 的 10 800 张处理后的训练图像送入卷积变分自编码进行训练。选取不同超参数并对比不同参数下模型的训练误差,最终确定了如表 1 的网络结构。主要

使用了 3×3 的卷积核进行图像卷积操作,表中的 k 是卷积核的大小, d 是卷积核的数量, s 是步长, p 是边缘填充参数。该神经网络的中间部分的激活函数层使用 ELU 函数,生成网络最后一个非线性层考虑到需要重构图像的参数在 $[0, 1]$ 之间,使用 Sigmoid 函数。

选择 Adam 算法进行网络参数的优化,学习速率设置为 0.000 1,每次训练的样本批次大小设置为 50。为了验证 CVAE 模型的效果,同时建立了卷积自编码模型(convolutional variational autoencoder, CAE)^[19],CAE 模型与本文的 CVAE 模型参数设置基本相同,并采用相同的优化器参数进行训练。文中所提的传统 VAE 模型,因网络内使用的是全连接层结构,在使用该火焰图像样本时,模型参数将远超 CVAE 模型,计算速度和效果明显落后于 CVAE 模型,因此未纳入对比。

表 1 卷积变分自编码的架构及参数

Table 1 The architecture and parameters of convolutional variational autoencoding

操作类型	参数信息	输出维度
Conv2D+ELU	$k=3 \times 3; d=32; s=1; p=1$	(128, 128, 32)
Max-pooling	$k=2 \times 2; s=2$	(64, 64, 32)
Conv2D+ELU	$k=3 \times 3; d=16; s=1; p=1$	(64, 64, 16)
Max-pooling	$k=2 \times 2; s=2$	(32, 32, 16)
Conv2D+ELU	$k=3 \times 3; d=8; s=1; p=1$	(32, 32, 8)
Max-pooling	$k=2 \times 2; s=2$	(16, 16, 8)
Conv2D+ELU	$k=3 \times 3; d=4; s=1; p=1$	(16, 16, 4)
Max-pooling	$k=2 \times 2; s=2$	(8, 8, 4)
Flatten	-	(256)
Linear+ELU	Fully Connected	(30×2)
Reparameterization	Get z	(30)
Linear+ELU	Fully Connected	(256)
Reshape	-	(8, 8, 4)
Conv2D+ELU	$k=3 \times 3; d=4; s=1; p=1$	(8, 8, 4)
Upsampling	$k=2 \times 2; s=2$	(16, 16, 4)
Conv2D+ELU	$k=3 \times 3; d=8; s=1; p=1$	(16, 16, 8)
Upsampling	$k=2 \times 2; s=2$	(32, 32, 8)
Conv2D+ELU	$k=3 \times 3; d=16; s=1; p=1$	(32, 32, 16)
Upsampling	$k=2 \times 2; s=2$	(64, 64, 16)
Conv2D+ELU	$k=3 \times 3; d=32; s=1; p=1$	(64, 64, 32)
Upsampling	$k=2 \times 2; s=2$	(128, 128, 32)
Conv2D+Sigmoid	$k=3 \times 3; d=3; s=1; p=1$	(128, 128, 3)

4.2 实验结果分析

1) CVAE 模型训练与模型重构图像能力分析

将阶段 I 的稳定工况图像送入卷积变分自编码模型,并使用 Adam 算法优化神经网络的参数,训练集的数据迭代 30 次,对应训练步数为 6 480 次,图 7 是 CVAE 训练过程中损失函数值的变化情况。




图 7 CVAE 模型损失函数变化图

Fig. 7 Changes of loss function in the CVAE model

训练该 CVAE 模型时使用的损失函数包含两个部分:重构前后图像的信息熵、隐藏层变量 z 的分布与标准正态分布的 KL 散度。这两部分对应模型的两个不同优化方向,需要保持一定的比例大小,才能不让模型进入单一的极端,且损失函数中包含多个对数计算,因此该损失函数值一般不会趋近于 0,让该数值尽可能的小,模型的效果就越好。图 7 的损失函数值先是有个较大的衰减,之后缓慢下降,直至趋向于平稳,因此迭代 30 次后的模型训练效果良好。为了排除误差,用于对比的 CAE 模型也同样进行 30 次迭代训练。

图 8 为原图像与重构图像对比图,包括 CAE 重构图像和 CVAE 重构图像,从上到下依次为给煤量递减的不同工况下具有代表性的火焰图像。

通过对比可知,VAE 模型和 CVAE 模型都对原图像的大致形状和轮廓进行比较完整的重构,这归功于卷积神经网络对于图像的学习和归纳能力。随着给煤量的减少,CAE 模型对于图像的重构能力逐渐下降,图像中的亮色区域和轮廓逐渐模糊,当炉膛无火时,CAE 模型重构的图像为有火形状;相比之下,CVAE 模型重构图像的质量则不受给煤量变化的影响,重构的图像都能较好的展现原火焰图像的基本特征。

这里进一步比较两个模型在给煤量减少时对原图像的重构能力。在阶段 II 的给煤量调整实验里,可以分为给煤量递减时段、停止给煤时段、给煤量递增时段,这里引入图像质量评估指标的均方根误差(mean squared error, MSE),分别计算重构前后图像的 MSE 大小,如表 2 所示。




图 8 原图像与重构图像对比

Fig. 8 Comparison between the original image and the reconstructed image

表 2 不同时间段内图像重构前后的 MSE

Table 2 MSE before and after image reconstruction in different time periods

方法	给煤量减少时	停止给煤时	给煤量增加时	均值
CAE	3.342×10^{-3}	8.999×10^{-3}	4.366×10^{-3}	7.02×10^{-3}
CVAE	2.766×10^{-3}	6.703×10^{-3}	3.485×10^{-3}	5.48×10^{-3}

可以看到在 3 个时段里面 MSE 均值大小,CVAE 模型 (5.48×10^{-3}) 都小于 CAE 模型 (7.02×10^{-3}),其中停止给煤时段内领先的幅度最大,因此 CVAE 对于图片的重构能力更优秀。这是因为普通的 CAE 模型的隐空间是固定的编码值,对于训练集里不存在无火图像或者不稳定燃烧的图像不存在重构能力;而 CVAE 基于贝叶斯的变分推断理论,隐变量的实质是变分概率分布,可以学习到一个连续且平滑的隐空间,因此对于测试集中不存在的图像,也能较好地重构。考虑到 CVAE 模型拥有能对

不稳定燃烧乃至无火焰图像的重构能力,将其选为燃烧稳定性判断的模型。

2) 基于 CVAE 模型的燃烧稳定性定量判断方法

原图像送入训练后的 CVAE 模型,可使用式(6)计算出隐藏层变量 z 的分布与标准正态分布的 KL 散度,图 9(a)为 14:30~15:30 时段的 KL 散度值绘制出的频率分布直方图,图 9(b)为 14:30~15:30 时段的 KL 散度值绘制的频率分布直方图。

从图 9(a)可知,阶段 I 的 11:00~14:00 时段主要是稳定燃烧的火焰图像,对应计算出的 KL 散度分布较为集中,计算得均值 μ_{KL} 为 51.312,方差 σ_{KL} 为 2.407。在阶段 II 的 14:30~15:30 时间段内,开展了给煤量调整实验,火焰燃烧图像包含稳定燃烧的样本和不稳定燃烧的样本,从图 9(b)可以看出 KL 散度存在两个集中分布区域,分别在 53 和 86 附近,并且过渡较为平滑,因此可以使用 KL 散度值对燃烧稳定性进行衡量。使用上文的式(11)计算燃烧稳定性,其中稳定性的灵敏度参数 C 由经验设置为 3。为了提高准确性,防止个别闪烁图像对结果的干扰,计算得到的稳定性进行中值滤波处理。




图 9 KL 散度的频率分布直方图

Fig. 9 Histogram of frequency distribution of KL divergence

该方法应用于工业现场时,进行稳定性计算的流程为:1)对采集到的每秒内 25 帧图片预处理,得到单张代表该秒级时间段火焰的图像;2)使用训练完毕的 CVAE 模型计算火焰图像隐藏层变量 z 的分布与标准正态分布的 KL 散度;3)通过 KL 散度值计算燃烧稳定性。使用上

述阶段 II 测试集里的图片进行验证,结果表明在该实验平台上,平均 0.25 s 内可完成一个秒级时间段内燃烧稳定性的计算,因此该判稳方法的计算实时性较好,可用于工业现场实时跟踪燃烧稳定性的变化。

3) 燃烧稳定性定量判断结果分析

对 14:00~17:00 时间段内的火焰图像使用本文 CVAE 模型进行计算,燃烧稳定性结果如图 10 所示。参考文献[19],[23]提出真实的燃烧器燃烧稳定性可以由给煤量的大小进行表示,因此本文使用给煤量代表稳定性进行对比分析。




图 10 14:00~17:00 时间段内燃烧稳定性图
Fig. 10 Combustion stability diagram during 14:00~17:00 period

从图 10 中可以看出,计算得到的燃烧稳定性数值变化与给煤量大小的变化趋势一致。1)给煤量在 50 t/h~70 t/h 之间变化时,炉膛内燃烧充分,处于稳定燃烧工况,通过火焰图像计算得到的燃烧稳定性均保持在 0.5 以上;2)在 14:35~15:15 这个时间段内,给煤量调整实验让炉膛内的真实稳定度经历稳定到不稳定,再回到稳定的状态,本文的模型计算出来的燃烧稳定性与该实验情况一致,并且随着给煤量减少稳定性逐渐降低,当给煤量为 0 时稳定性数值近似为 0,给煤量递增时稳定性计算结果逐渐上升;3)图中存在多个给煤量突变超过 10 t/h 的情况,如 14:24、16:00、16:15 时刻附近,这种给煤量的突变也会让燃烧稳定性下降,可以看到本文计算的燃烧稳定性能在一定程度上反应这种情况。

电站锅炉都配备煤火检系统,实际燃煤锅炉在运行时,通常使用煤火检探头对单个燃烧器的煤粉燃烧进行监测,输出的火焰品质参数接入 DCS 系统,作为炉膛燃烧状态的重要监测指标。该火焰品质指数范围为 [0,100],但是大部分情况下处于满偏 100,表示火焰存在且稳定,火焰消失时火焰品质指数突变为 0,线性度较差,不能很好的表示从稳定到不稳定的变化过程。图 11 是在 14:30~15:30 时间段内,该燃烧器上的型号为

Uvisor FAU810 的火焰分析单元测得的火焰品质与燃烧稳定性对比图。




图 11 14:30~15:30 时间段内燃烧稳定性与火焰品质对比图

Fig. 11 Comparison of combustion stability and flame quality in the period of 14:30~15:30

从图 11 可以看出, CVAE 模型计算出的燃烧稳定性与煤火检探头的火焰品质结果基本相同, 在炉膛无火时都做出了准确的判断。在 14:45 分附近, 因为燃烧器火焰消失后炉膛仍然有部分火焰存在, 导致该品质信号在 0 和 0.7 之间反复跳跃, 这对无火的判断造成了一定的影响, 而本文计算的稳定性数值则较为稳定, 在无火时间段内, 稳定性数值在 0 附近不存在较大跳变现象。如果将 0.5 作为判断稳定和不稳定的阈值, 本文的评价方法给出燃烧不稳定判断的时刻比火焰品质第一次跳变为 0 提前了 167 s。因此, 该燃烧稳定性评价模型具有提前预警不稳定燃烧的能力, 可以比煤火检系统更早的预知炉膛灭火现象, 在燃烧器完全灭火前为现场运行人员进行燃烧调整提供一定的时间裕度。

以上结果表明, 本文提出燃烧稳定性评价方法能通过单个燃烧器的火焰图像, 实时计算出该燃烧器当前的燃烧稳定性, 可以作为现场运行人员对燃烧器燃烧状态的参考依据, 在燃烧器的燃烧状态进入不稳定前及时进行调整。

现有的燃烧稳定性判断方法是针对稳定和 不稳定燃烧工况进行辨别和区分, 是一种标签分类模型, 而本文方法的创新点在于给出了燃烧稳定性的一个定量衡量指标, 不仅能通过设定阈值做到标签分类, 同时能对燃烧的稳定程度进行表征。

为了证明本文方法相比传统机器学习方法的优越性, 将上述的火焰图像利用其他方法进行燃烧判稳, 方法包括: 高斯混合模型、K-means 聚类、模糊 C-means、隐马尔科夫链, 具体训练过程参考文献[19]。本文的卷积变

分自编码方法这里取 0.5 作为判断稳定和 不稳定的阈值, 小于 0.2 则判定 灭火状态, 以此来对燃烧情况分类。以上文 14:30~15:30 时间的火焰图像作为样本, 并依据火焰品质和现场操作人员人为分类为标准判定结果进行对比, 下面表 3 是不同判稳方法的准确度对比, 前 3 列分别是对稳定燃烧图像、不稳定燃烧图像、灭火图像判断结果的准确率, 最后一列为总体判断精度。

从表 3 可以看出, 本文的卷积变分自编码燃烧判稳方法总精确度较高(0.921), 对于不稳定燃烧火焰的判断(0.768)相比其他几种方法都有较高的提升。但对于稳定燃烧火焰的判断上本文方法比其他方法略低, 这是灵敏度参数 C 设置较高导致的, 参与对比的 4 种方法在实际运用时无法调节灵敏度, 且为标签类判断方式, 无法适应实际机组环境的变化。而本文提出的卷积变分自编码方法, 可以通过更改上文所述的灵敏度参数 C 来适应机组调整和操作人员实际需要, 并且给出燃烧的定量化表征, 在实际运用中可给出更清晰的度量, 相比单纯稳定与否的标签分类更据参考意义。

表 3 不同判稳方法的准确度对比

Table 3 Comparison of the accuracy of different methods of judging stability

方法	稳定	不稳定	灭火	总精度
高斯混合模型	0.969	0.036	1.000	0.878
K-means 聚类	0.992	0.030	1.000	0.895
模糊 C-means	0.986	0.156	1.000	0.904
隐马尔科夫链	0.984	0.313	1.000	0.913
卷积变分自编码	0.921	0.768	1.000	0.921

5 结 论

在使用火焰图像进行燃烧稳定性评价方法的研究中, 本文首次采用卷积变分自编码模型完成了基于火焰图像的燃烧稳定性分析, 并在该方法基础上, 提出了一种基于 KL 散度值的燃烧稳定性定量表征方法。卷积变分自编码对于火焰图像的处理更加高效和精确, 并且利用了贝叶斯变分推断方法, 可以学习到一个连续且平滑的隐空间, 因此对于训练集中不存在的图像, 也能较好地对图像进行重构。本文所提燃烧稳定性的定量表征方法不仅解决了燃烧机理建模难度大、特征参数难以进行个性化评估的问题, 同时该方法中的模型训练只需要稳定工况下的燃烧图像, 从而克服了不稳定燃烧样本不足的难题。

通过现场实验, 构造和记录了单只燃烧器在不同稳定性程度下的火焰图像。通过仿真结果的对比分析得到

了以下结论:

1) 相比于现有 CAE 方法,本文采用的 CVAE 方法对火焰图像重构能力更强,且拥有对不稳定燃烧图像和无火焰图像的重构能力,因此 CVAE 方法的隐含层的表达能力优于 CAE 方法;

2) 变分自编码模型损失函数中的 KL 散度值对稳定燃烧工况和不稳定燃烧工况的区分度高,计算出来的燃烧稳定性指标与磨煤机给煤量反映出来的燃烧稳定度情况相同,具有较高的精确度;

3) 经过对比,本文计算出的燃烧稳定度与煤火检系统的评判结果基本相同,但相比于煤火检,该方法对于燃烧稳定程度的感知更加灵敏,且算法计算周期仅为 0.25 s,实时性强,具有提前预警不稳定燃烧的能力,可为现场运行人员对燃烧器状态调整提供依据。

4) 通过与其他机器学习的燃烧判稳方法对比,本文提出的方法总精度有所提高,达到 92.1%,且相比其他方法的标签分类方式,本文的 CVAE 方法计算得到了燃烧稳定度的定量表征,比单纯的分类燃烧稳定与不稳定更具参考意义。

参考文献

- [1] 张广才,周科,鲁芬,等. 燃煤机组深度调峰技术探讨[J]. 热力发电,2017,46(9):17-23.
ZHANG G C,ZHOU K,LU F,et al. Discussions on deep peaking technology of coal-fired power plants [J]. Thermal Power Generation,2017,46(9):17-23.
- [2] 宋民航,黄云,黄莺,等. 旋流煤粉燃烧器低负荷稳燃技术探讨[J]. 中国电机工程学报,2021,41(13):4552-4566.
SONG M H,HANG Y,HUANG Q,et al. Discussion on low-load stable combustion technology of swirl pulverized-coal burner[J]. Proceeding of the CSEE,2021,41(13):4552-4566.
- [3] 刘吉臻,杨光军,谭文,等. 基于数据驱动的电站燃烧稳定度综合评价[J]. 中国电机工程学报,2007(35):1-6.
LIU J ZH,YANG G J,TAN W,et al. Synthetic evaluation on the degree of combustion stability in power station based on data-driven[J]. Proceeding of the CSEE,2007(35):1-6.
- [4] 马骏,余岳峰,范浩杰. 基于频谱分析和自组织神经网络的火焰燃烧诊断研究[J]. 动力工程,2004,24(6):852-856.
MA J,YU Y F,FAN H J. Research on flame detection and combustion diagnosis based on spectrum analysis and with self organized neural networks [J]. Power Engineering,2004,24(6):852-856.
- [5] 熬丽敏,黎建华,宋轩. 一种基于自适应小波变换的火

焰检测方法的研究[J]. 热能动力工程,2006,21(6):594-597.

AO L M,LI J H,SONG X. An investigation of the flame detection method based on self-adaptive wavelet conversion [J]. Engineering for Thermal Energy and Power,2006,21(6):594-597.

- [6] 刘吉臻,杨光军,谭文. 一种基于数据驱动的电站状态稳定性能评价指标[J]. 热力发电,2008(1):45-49.
LIU J ZH,YANG G J,TAN W. An index based data-driven for evaluating the state stability in power plant[J]. Thermal Power Generation,2008(1):45-49.
- [7] 郝祖龙,刘吉臻,常太华,等. 采用数据融合方法诊断电站锅炉的燃烧稳定性[J]. 动力工程,2007(6):910-913.
HAO Z L,LIU J ZH,CHANG T H,et al. A way of diagnosing combustion stability of utility boilers by data fusion[J]. Power Engineering,2007(6):910-913.
- [8] CHEN H,ZHANG X,HONG P,et al. Recognition of the temperature condition of a rotary kiln using dynamic features of a series of blurry flame images [J]. IEEE Transactions on Industrial Informatics,2016,12(1):148-157.
- [9] 陈荣保,孟芳慧,肖本贤,等. 基于区间数和多属性决策的燃烧稳定性研究[J]. 仪器仪表学报,2015,36(3):552-559.
CHEN R B,MENG F H,XIAO B X,et al. Research on combustion stability based on interval number and multiple attribute decision making[J]. Chinese Journal of Scientific Instrument,2015,36(3):552-559.
- [10] 王飞,马增益,严建华,等. 运用计算机图像处理和神经网络技术对炉膛火焰进行诊断[J]. 热力发电,2003,02:24-28.
WANG F,MA Z Y,YAN J H,et al. Firing diagnosis of flame in the furnace of utility boilers by means of computer-based image processing and neural network technology [J]. Thermal Power Generation,2003,2:24-28.
- [11] BAI X J,LU G,HOSSAIN M M,et al. Multi-mode combustion process monitoring on a pulverised fuel combustion test facility based on flame imaging and random weight network techniques [J]. Fuel,2017,202:656-664.
- [12] 刘禾. 基于火焰图像和模糊神经网络的锅炉燃烧稳定性判别[J]. 仪器仪表学报,2008(6):1280-1284.
LIU H. Judging boiler combustion stability based on flame image and fuzzy neural network [J]. Chinese Journal of Scientific Instrument,2008(6):1280-1284.
- [13] LIU D G,LV L X,LIU C L,et al. Flame furnace in

- thermal power plant condition monitoring using SVM[J]. International Conference on Intelligent Computation Technology and Automation, 2009(3):67-70.
- [14] 毛翠丽, 马卫红, 孟立庄, 等. 基于数字图像处理的火焰长度计算方法[J]. 光学仪器, 2007, 01:27-31.
MAO C L, MA W H, MENG L ZH, et al. Calculation methods of flame length based on digital image processing[J]. Optical Instruments, 2007, 01:27-31.
- [15] SUN D, LU G, ZHOU H, et al. Quantitative assessment of flame stability through image processing and spectral analysis[J]. IEEE Transactions on Instrumentation and Measurement, 2015, 64(12):3323-3333.
- [16] WANG J S, REN X D. GLCM based extraction of flame image texture features and KPCA-GLVQ recognition method for rotary kiln combustion working conditions[J]. International Journal of Automation and computing, 2014, 11(1):72-77.
- [17] LV Y T, CHEN J H, SONG Z H. Image-based process monitoring using deep learning framework [J]. Chemometrics and Intelligent Laboratory Systems, 2019, 189:8-17.
- [18] 周晓杰, 蔡元强, 夏克江, 等. 基于火焰图像显著区域特征学习与分类器融合的回转窑烧结工况识别[J]. 控制与决策, 2017, 32(1):187-192.
ZHOU X J, CAI Y Q, XIA K J, et al. Burning state recognition for rotary kiln sintering process based on burning salient zone image feature learning and classifiers fusion[J]. Control and Decision, 2017, 32(1):187-192.
- [19] QIU T, LIU M J, et al. An unsupervised classification method for flame image of pulverized coal combustion based on convolutional auto-encoder and hidden markov model[J]. Energies, 2019, 12(13):2585.
- [20] 余博, 田福庆, 梁伟阁. 基于深度卷积变分自编码网络的故障诊断方法[J]. 仪器仪表学报, 2018, 39(10):27-35.
SHE B, TIAN F Q, LIANG W G. Fault diagnosis based on a deep convolution variational autoencoder network[J]. Chinese Journal of Scientific Instrument, 2018, 39(10):27-35.
- [21] 宋辉, 代杰杰, 张卫东, 等. 基于变分贝叶斯自编码器的局部放电数据匹配方法[J]. 中国电机工程学报, 2018, 38(19):5869-5877.
SONG H, DAI J J, ZHANG W D, et al. A data matching method of partial discharge data based on auto-encoding variational bayes [J]. Proceeding of the CSEE, 2018, 38(19):5869-5877.
- [22] 马波, 赵祎, 齐良才. 变分自编码器在机械故障预警中的应用[J]. 计算机工程与应用, 2019, 55(12):245-249.
MA B, ZHAO Y, QI L C. Application of variational auto-encoder in mechanical fault early warning [J]. Computer Engineering and Applications, 2019, 55(12):245-249.
- [23] 闫顺林, 王冬生, 李永华, 等. 锅炉燃烧稳定性影响因素分析[J]. 电站系统工程, 2005(1):29-30.
YAN SH L, WANG D SH, LI Y H, et al. Analysis of the influential factors to boiler combustion stability[J]. Power Syst Eng, 2005(1):29-30.

作者简介



蔡国源 (通信作者), 2019 年于华北电力大学(保定)获得学士学位, 现为华北电力大学硕士研究生, 主要研究方向为发电过程状态检测与优化控制。

E-mail: jackcai007@126.com

Cai Guoyuan (Corresponding author)

received his B. Sc. degree from North China Electric Power University (Baoding) in 2019. He is currently a master student at North China Electric Power University. His main research interests include power generation process condition monitoring and optimization control.



牛玉广, 1983 年于武汉水利电力学院获得学士学位, 1988 年于华北电力学院获得硕士学位, 1997 年于华北电力大学获得博士学位, 现为华北电力大学教授、博士生导师, 主要研究方向为发电过程状态监测与优化控制、控制系统故障检测与诊断。

E-mail: nyg@ncepu.edu.cn

Niu Yuguang received his B. Sc. degree from Wuhan Institute of Water Conservancy and Electric Power in 1983, and received his M. Sc. degree and Ph. D. degree both from North China Electric Power University in 1988 and 1997, respectively. He is currently a professor and a Ph. D. advisor at North China Electric Power University. His main research interests include power generation process condition monitoring and optimization control, control system fault detection and diagnosis.