

DOI: 10.19650/j.cnki.cjsi.J1904957

基于改进堆叠自编码网络的电站辅机故障预警*

李晓彬¹, 牛玉广^{1,2}, 葛维春³, 罗桓桓³, 周桂平³

(1.华北电力大学控制与计算机工程学院 北京 102206; 2.华北电力大学 新能源电力系统国家重点实验室北京 102206;
3.国网辽宁省电力有限公司 沈阳 110006)

摘要:为了提高对辅机故障的事前预知能力,结合深度学习中非监督学习方法的优势,提出基于改进堆叠自编码网络的电站辅机故障预警方法。以辅机的历史正常数据为训练集,利用堆叠自编码(SAE)网络的非线性表达能力表示辅机各变量之间的关系,同时引入批标准化(BN)算法优化网络性能。对于输入的观测向量,SAE网络给出相应的重构向量。构造基于融合距离的相似度表示观测向量与重构向量间的偏差,当辅机开始偏离正常状态时,观测值与重构值偏差增大,相似度下降至预警阈值即表明设备出现故障。分别利用某热发电机组中速磨煤机的正常数据与故障数据进行测试与验证,结果显示引入BN算法的SAE网络具有更低的重构误差,同时能够在磨煤机跳闸前做出预警,表明所提方法可对辅机故障进行有效预警,具有一定的工程应用价值。

关键词:堆叠自编码网络;批标准化;网络性能优化;电站辅机;故障预警

中图分类号: TP277 TH17 **文献标识码:** A **国家标准学科分类代码:** 470.3099

Fault warning of auxiliary equipment of power plant based on improved stacked autoencoder network

Li Xiaobin¹, Niu Yuguang^{1,2}, Ge Weichun³, Luo Huanhuan³, Zhou Guiping³

(1.School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;
2.State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, Beijing 102206, China;
3.State Grid Liaoning Electric Power Co., Ltd., Shenyang 110006, China)

Abstract:To improve the prediction ability of auxiliary equipment fault, a fault warning method for power plant auxiliary equipment is proposed. It is based on improved stacked autoencoder network, which fuses the advantages of unsupervised learning methods in deep learning. The method takes the historical normal data as the training set and utilizes the nonlinear expression ability of the stacked autoencoder (SAE) network to indicate the relationship among the variables of the auxiliary equipment. The batch normalization (BN) algorithm is utilized to optimize network performance. For the input observation vector, SAE network offers the corresponding reconstruction vector. The similarity based on the fusion distance is constructed to represent the deviation between the observation vector and the reconstruction vector. When the auxiliary equipment starts to deviate from the normal state, the difference between the observed value and the reconstructed value increase. The similarity drops to the warning threshold, which indicates that the machine is fault. Normal data and fault data of a medium speed mill of a thermoelectric unit are used to test and verify the proposed method. Experimental results show that SAE network with BN algorithm has lower reconstruction error. The model can provide fault warning before the coal mill trips. Therefore, the method can effectively make fault warning of auxiliary equipment, which has certain engineering application value.

Keywords:stacked autoencoder network; batch normalization; network performance optimization; auxiliary equipment of power plant; fault warning

0 引言

随着火电机组向着高参数、大容量、规模化的方向发展,电站辅机设备趋向于大型化,其重要性不亚于三大主机。与此同时,越来越多电站根据自身发电目标改变辅机的运行方式,比如将主要辅机单列配置^[1]、辅机在低负荷下运行^[2],这对辅机的运行可靠性提出了更高的要求。

实际中对于电站辅机的状态监测主要包括集散控制系统(distributed control system, DCS)的限幅报警与现场人员的点检定修,这类方法依赖辅机设备运行所设定的高低限参数与运行人员对辅机状态的主观分析,动态性与实时性较低,属于预防性检修与事后维护。随着运行年限的增加,磨损、老化程度增高,容易造成辅机出力不足、卡涩等异常状态,严重影响机组的经济性与安全性。因此,必须开发高实时性的辅机状态定量评估技术,完成由“事后维护”到“事前预知”的转变,实现对辅机设备异常状态提出预警,同时有助于设备管理人员进行有针对性的检修计划,减少不必要的检修工作^[3]。

关于辅机故障预警的方法一般基于机理建模、统计分析以及数据驱动3大类。基于机理建模的方法主要依据相关定律与原理,建立对应的数学模型并应用于故障预警中。其中,文献[4]提出基于高精度性能模型实现动(静)叶调节轴流风机喘振故障的预报;文献[5]通过风机特性与管路特性建立汽动引风机全工况运行特性模型,并在特性曲面上划定超速、失速边界以确定引风机的安全运行范围;文献[6]基于质量和能量平衡并考虑原煤水分对能量平衡的影响,建立中速磨煤机的动态模型并实现对磨煤机动态性能的预测。基于统计分析的方法主要通过收集机组辅机设备的可靠性指标与历史故障案例,通过制定相应的状态评估方法与划分指标定量衡量辅机设备的可靠性水平。其中文献[7]定义了4种辅机设备的非健康运行状态,通过对多台机组的故障数据进行分析,形成非健康状态的识别标准;文献[8]综合多个指标建立辅机设备可靠性评价体系,并选取186台辅机的运行指标与故障案例进行实证。上述两类方法在一定程度上实现了辅机故障状态的识别与可靠性的定量评估,但仍存在一定的局限性:由于各类辅机设备子部件众多,耦合程度较高,利用机理建模的方法建立精确表征辅机真实运行状态仍存在不小难度;而基于数理统计基础的状态评价体系在很大程度上依赖于样本的数量大小,当样本不足时则制约了这类方法的应用。对于每一台辅机而言,其运行状态的评估属于个性问题,不同设备其运行年限、经历工况均不一样,依赖概率统计得到的评价体系难以满足对个体设备状态进行精确评估的需求^[9]。

由于电站辅机设备种类多,规模大,且每台设备的测

点众多,在实际运行中产生了大量的过程数据,如何从海量数据中挖掘辅机设备状态信息成为了辅机故障预警的关键。随着计算资源成本的降低,深度学习方法凭借其强大算力与特征提取能力成为大数据分析的利器,并被广泛应用于各领域。在设备状态监测与诊断领域,推进深度学习的应用成为了新的研究方向^[10-13]。目前相关研究大多是通过实验台积累大量故障数据进行模型训练,但对于电站而言,收集足够的实际辅机故障样本用于训练则较为困难,使得有监督学习算法的应用受到很大限制。针对上述问题,本文提出了基于堆叠自编码(stacked autoencoder, SAE)网络的电站辅机故障预警方法,利用辅机的历史正常数据并借助深度神经网络强大的非线性表达能力表征辅机各变量之间的内在关系,从而建立辅机状态变量与设备状态优劣程度之间的映射模型,实现辅机状态的智能监测与故障预警。本文方法不仅解决了机理建模难度大、概率统计难以进行个性化评估的问题,同时其训练数据只需要辅机正常数据,从而克服了故障样本不足的难题。

1 堆叠自编码神经网络

1.1 自编码器

自编码器(autoencoder, AE)是由Rumelhart等^[14]于1986年提出的一种表示学习算法,在保持输入与输出的误差尽可能小的前提下对隐含层特征提取与参数学习。

AE的运行机制包括编码和解码两个过程,如图1所示。在编码过程中,首先对输入 X 进行加权求和,加上偏置后通过激活函数生成一组特征,通过上述编码过程即获得编码 Y 。在解码过程中,将编码 Y 以同样的方式得到输出层。最后以输入、输出的误差,如均方误差最小为目标,通过反向传播不断优化自编码器参数 θ ,使得输出尽可能逼近输入,从而得到 X 的重构 $\hat{X}$ 。AE的数学表达式:

$$Y = f_a(W_a \cdot X + b_a) \quad (1)$$

$$\hat{X} = f_s(W_s \cdot Y + b_s) \quad (2)$$

$$E = \operatorname{argmin}(L(X, \hat{X})); \theta = [W_a, W_s, b_a, b_s] \quad (3)$$

式中: $X, Y, \hat{X}$ 分别为自编码器的输入,隐含层神经元输出值以及AE的输出; $f_a(\cdot), f_s(\cdot)$ 为激活函数; W_a, b_a 为编码器的权值与偏置; W_s, b_s 为解码器的权值与偏置。 L 为损失函数,一般选用输入 X 与输出 $\hat{X}$ 的均方误差来表示; E 代表最小损失误差。通过梯度下降法对损失函数 L 作极小化处理,逐次更新网络参数并使损失误差不断接近极小值。

1.2 SAE网络的训练

Hinton等^[15]对AE作进一步改进并提出了SAE网络,SAE以非监督的训练方式实现数据降维与分类,是目




图 1 AE 结构

Fig.1 The structure of AE

前深度学习领域最重要的研究热点之一。目前在设备状态监测领域已有相关研究成果,其中文献[16-17]基于SAE神经网络实现风力发电机的故障检测与初步诊断;文献[18]提出一种深度AE模型,从数据采集与监视控制系统(supervisory control and data acquisition, SCADA)中提取叶片即将发生断裂的指标从而实现风机叶片破损监测。

SAE网络由多个AE堆叠而成,编码器与解码器呈对称结构。如图2所示,从下往上看,将归一化处理后的输入值 X 输入至第一层全连接层,各输入经过加权求和并加上偏置后,全连接层的输出通过激活函数后作为下一层全连接层的输入。经过多层上述前向传播后编码结束,得到逐层降维后的低维特征 Y ,之后 Y 通过与编码过程相同层数的隐含层训练得到重构值。将辅机的历史数据分成小批输入至所建立的SAE中训练,选择小批量输入数据与其重构值的均方误差作为SAE的损失函数,通过反向传播算法计算得到梯度后优化器将会根据梯度与学习率更新SAE的网络参数。




图 2 SAE 结构

Fig.2 The structure of SAE

使用不同非线性的激活函数会使训练的SAE具有不同的表达能力与泛化能力,从而影响训练效果。本文选择 $leakyrelu$ 函数作为激活函数,与传统的 $sigmoid$ 函数相比, $leakyrelu$ 克服了梯度消失的问题,同时在 $(-\infty, 0)$ 上 $leakyrelu$ 具有非零斜率,有效缓解了常规 $relu$ 函数在 $(-\infty, 0)$ 上的硬饱和问题,该非零斜率值本文取 -0.01 。3种激活函数的数学形式如图3所示。




图 3 3种激活函数的数学形式

Fig.3 The mathematical forms of three activation functions

在优化器的选择上,本文利用Adam算法优化网络参数,该算法是Kingma等^[19]在2015年提出的一种自适应学习率的优化算法,它根据损失函数对每个参数的梯度的一阶矩估计和二阶矩估计动态调整每个参数的学习速率。其算法策略如下:

$$\begin{cases} m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \\ W_{t+1} = W_t - \frac{lr}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \end{cases} \quad (4)$$

式中: m_t, v_t 分别为梯度的一阶矩估计与二阶矩估计; β_1, β_2 为矩估计衰减率,通常取0.9和0.999; $\hat{m}_t, \hat{v}_t$ 为修正值; W_t 为第 t 次迭代模型的参数; g_t 为第 t 次迭代损失函数关于 W_t 的梯度; lr 为学习率; ϵ 为数值稳定常数,一般为 10^{-8} ,从而避免分母为0。

2 网络性能优化

2.1 网络性能下降分析

SAE 网络通常包括多层全连接层,每层的神经元个数更是成千上百,而神经元的输出与激活函数一一对应,因此一个 SAE 网络拥有众多的激活值,这些激活值的分布对于神经网络的训练效果具有极为重要的影响。由于激活函数一般为非线性函数,其具有饱和区与敏感区。如果全连接层的激活函数输入大部分都处于非线性的敏感区,激活函数的导数不为 0,反向传播则能够进行有效的传递并优化网络参数;如果输入大部分处于激活函数导数为 0 的饱和区,反向传播不能有效传递,优化器也不能有效地优化网络参数。

本文所选的激活函数 *leakyrelu* 虽能缓解 *relu* 硬饱和的问题,但若 SAE 某一层神经元的输入值大多处于负区间,其激活值则大多接近于 0,而在训练过程中下一层神经元输入的分布会受到前一层的影响,经过多层的前向传播后整个网络的表达能力大大下降。为了使激活函数输入值的分布位于激活函数的敏感区,需要对激活函数的输入值作标准化处理。

2.2 批标准化

Ioffe 等^[20]首次提出了批标准化(batch normalization, BN)算法,通过标准化各层输入解决了饱和和非线性激活函数训练模型较为困难的问题,加快卷积神经网络训练速度并提高了图像识别的正确率。除了应用在卷积神经网络上,BN 算法作为一种网络性能提升的手段也可以应用于其他深度神经网络^[21-22]。

BN 算法原理如图 4 所示,在神经网络各层全连接层与激活函数之间添加 BN 层,BN 层对全连接层的输出作标准化处理,使得激活函数输入不会总处于负区间。除了对数据进行标准化,BN 层还引入两个待训练参数进行缩放和平移,即在标准化后进行反标准化操作,最后通过激活函数输出到下一层全连接层。该算法公式如下:

$$\begin{cases} \mu_B = \frac{1}{m} \sum_{i=1}^m x_i \\ \sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \\ \hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \\ y_i = \gamma \hat{x}_i + \beta \end{cases} \quad (5)$$

式中: $B = \{x_1, \dots, x_m\}$, x_i 为用于训练的小批量数据; μ_B 与 σ_B 分别为小批量数据的均值与标准差; ε 为数值稳定常数; y_i 为 BN 层的输出; γ 与 β 为 BN 层的可优化参数,用于保证标准化操作能够起到优化激活值分布的作用。




图4 加入 BN 层的示意图

Fig.4 The schematic diagram of adding BN layers

3 相似度定义与预警决策

3.1 基于距离融合的相似度

本文所构建的 SAE 网络通过正常历史数据的训练学习到辅机各变量之间的关系特性,当新的观测数据输入至模型后,模型根据所学的关系特性给出相应的重构值,该重构值表示模型对于辅机观测状态的真实估计。当故障发生时,输入的观测变量之间的关系发生变化,模型给出的重构值与模型输入值的偏差也将偏离正常时的稳定状态。为了定量衡量模型输入值与重构值之间的相似程度,构造相似度作为观测指标,该指标通常基于欧式距离作为相似度的计算依据。

对于向量 X 与 Y ,其欧氏距离可表示为:

$$dist_{\text{euc}}(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (6)$$

为了更直观地判断两向量间的相似程度,通常使相似度与距离成反比,且映射在 $[0, 1]$ 内,因此相似度可定义成如下形式:

$$sim(X, Y) = \frac{1}{1 + dist_{\text{euc}}(X, Y)} \quad (7)$$

基于欧氏距离的相似度仅仅考虑了两向量之间距离的相似性,而忽略了向量之间形态的相似性。为了更全面地分析输入值与重构值之间的差异,本文在欧式距离的基础上引入余弦距离,将形态的相似性也作为相似程度量化的依据^[23]。本文所定义的余弦距离与相似度如式(8)与(9)所示:

$$dist_{\text{cos}}(X, Y) = \frac{1}{2} \frac{dot(X, Y)}{\sqrt{\|X\|} \cdot \sqrt{\|Y\|}} + \frac{1}{2} \quad (8)$$

$$sim(X, Y) = \frac{1}{1 + dist_{\text{euc}}(X, Y) / dist_{\text{cos}}(X, Y)} \quad (9)$$

式中: $\text{dot}(\cdot)$ 表示内积运算, $\|\cdot\|$ 表示向量的 2 范数, $\text{sim}(X,Y)$ 表示向量 X 与 Y 的相似度。式(8)的构造使余弦距离值介于 0 与 1 之间,且越接近于 0 代表重构值与输入值的形态相似程度越低。

3.2 预警决策

预警决策通常包含两部分,一是预警阈值的选取,二是发出预警的条件。预警阈值代表设备正常与异常的临界线,可从正常状态数据的相似度中取最小值,并乘以阈值系数来表示,其公式如下:

$$E_m = k \cdot \text{Sim}_{\min} \quad (10)$$

式中: E_m 为预警阈值, k 为阈值系数, $\text{Sim}_{\min}$ 为正常状态数据对应的相似度的最小值。

在实际监测中因传感器测量误差等不确定因素可能会引起相似度的下降,本文设定当连续两个时刻的相似度都低于 E_m 时,认为辅机运行状态出现异常,此时模型做出预警。

4 基于改进 SAE 网络的电站辅机故障预警实现过程

针对所研究的辅机对象获取其历史正常数据,将数据集作归一化处理并分成训练集与测试集,在确定 SAE 网络的激活函数与优化器类型、初始网络结构参数以及学习率等超参数后将训练集应用于 SAE 网络的训练,并引入 BN 算法优化 SAE 网络性能。对于输入的观测值,所建立的 SAE 网络模型给出相应的重构值。基于距离融合的相似度计算方法得到重构值与观测值的相似度曲线,同时计算出预警阈值。在辅机设备运行出现异常时,各变量间的关系偏离正常状态,此时相似度曲线下降,当连续两个时刻低于预警阈值即做出预警。基于改进 SAE 网络的电站辅机故障预警实现流程如图 5 所示。

5 算例分析

5.1 数据采集与变量选取

某 350 MW 热发电机组的中速磨煤机在 2017 年 11 月 16 日 7 时 59 分 45 秒发生了跳闸,经现场人员事后分析判定为堵煤故障。为了对本文所提故障预警模型的有效性进行验证,从电厂数据库中导出 11 月 1 日 12 时 0 分~11 月 16 日 4 时 0 分内的 280 800 组数据作为模型的训练集,该训练集包含了该机组 168 h 试运行的数据,基本覆盖了该磨煤机在全工况下的运行状态,保证 SAE 网络能充分学习正常运行状态下的特征。另外选取 11 月 16 日 4 时 0 分至 7 时 0 分内的 10 800 组数据作为测试集,取 7 时 40 分至磨煤机跳闸内的 1 185 组数据作为验证集,上述数据时间间隔均为 1 s。




图 5 基于改进 SAE 网络的电站辅机故障预警实现全流程

Fig.5 The whole process of fault warning of auxiliary equipment of power plant based on improved SAE network

传统的应用于故障预警的智能算法为了避免矩阵维度过大而降低运算速度,通常在选择建模变量时采用如主成分分析技术、皮尔逊相关分析方法选取建模对象的关键变量。而 SAE 神经网络模型由于具备强大的运算能力,突破了建模变量数量的限制。本文将该机组磨煤机的所有实际变量用作模型的输入,减少了状态信息的损失。

建模选取的变量如表 1 所示,将上述训练集数据用于所建立 SAE 网络的训练,选取不同超参数并对不同参数下模型的训练误差,最终确定 SAE 网络层数为 14 层,编码器与解码器各 7 层,网络的输入变量与重构变量为 14,每一层的神经元数目为 512, 256, 128, 64, 24, 12, 3,神经网络学习率设为 0.005,每次训练的小批量数据设为 64。

在选择超参数后对 SAE 网络进行训练,并将测试集数据输入至模型中,发现各变量的重构值虽与观测值在数值上基本一致,但对于观测值的波动变化,该模型的重构值尚有一定的偏离,未能达到精确跟踪的效果。由于篇幅有限,以下仅给出风粉混合物温度与出入口差压的重构结果与相对误差,如图 6 所示。

表 1 建模选取变量

Table 1 Selected variables of modeling		
序号	变量	单位
1	风粉混合物温度	℃
2	反作用力加载油压	MPa
3	磨辊加载油压	MPa
4	磨煤机电流	A
5	磨煤机一次风压力	kPa
6	密封风母管压力	kPa
7	一次风与密封风差压	kPa
8	磨煤机出入口差压	kPa
9	油箱油温	℃
10	一次风流量	t·h ⁻¹
11	电机轴承温度	℃
12	减速机推力瓦温	℃
13	减速机油池油温	℃
14	实际功率	MW

由图 6 可见,出入口差压的重构值的相对误差偏高,重构值最大偏差达 10% 以上,而且两个变量的重构值与观测值在形态上的相似程度较低,说明模型对于磨煤机各变量的非线性关系的表达能力仍有待提高。为了改善网络的学习性能,本文根据 3.2 节的方法在神经网络各全连接层与激活函数之间添加 BN 层,并将其训练误差与未加入 BN 层的 SAE 网络的训练误差作对比,对比结果如图 7 所示。




图 7 SAE 网络的训练对比

Fig.7 Training comparison of SAE networks

从训练对比结果可看出,未加入 BN 层的 SAE 网络的训练误差起初呈下降趋势,随着训练继续进行,训练误差持续增大;加入 BN 层的 SAE 网络的训练误差在训练起初快速下降并达到一个稳定值,之后训练误差收敛至零,说明该网络找到最优网络参数。将测试集数据输入到加入 BN 层的 SAE 模型,同样给出风粉混合物温度与出入口差压的重构结果与相对误差,如图 8 所示。与图 6 相比,两个变量的重构值的相对误差更小,变化趋势相似程度更高。利用 3.1 节基于距离融合的相似度方法分别计算网络改进前后测试集观测值与其重构值的相似程度,结果如图 9 所示,可看出加入 BN 层后测试集的相似度基本保持在 0.85 以上,而未加入 BN 层的测试集相似度普遍较低,表明在训练过程中引入 BN 算法能够显著提高 SAE 网络的学习效果。





图 6 未加入 BN 层时风粉混合物温度与出入口差压的重构值与相对误差

Fig.6 Reconstruction value and relative error of wind powder mixture temperature and differential pressure at the entrance and exit without BN layers



(a) 风粉混合物温度的重构值与相对误差
(a) Reconstruction value and relative error of wind powder mixture temperature




图8 加入BN层后风粉混合物温度与出入口差压的重构值与相对误差

Fig.8 Reconstruction value and relative error of wind powder mixture temperature and differential pressure at the entrance and exit with BN layers




图9 网络改进前后测试集相似度的对比

Fig.9 Comparison of similarity of test set before and after network improvement

5.2 基于改进SAE的磨煤机故障预警

在得到磨煤机正常状态下的相似度曲线后,可求得最小相似度为0.801。根据式(10)预警阈值的计算规则,得到预警阈值为0.7845,其中 $k=0.98$ 。将带有故障状态的验证集数据输入至模型中,所得到的相似度变化趋势与报警结果如图10所示。




图10 验证集的相似度变化趋势与预警结果

Fig.10 Similarity trend and fault warning result of verification set

从图10可得验证集的相似度起初保持在0.8以上,磨煤机运行良好,之后相似度曲线开始下降,并从第947个时刻点起相似度小于预警阈值,与实际磨煤机跳闸时间相比,模型提前238s发出预警。从结果可看出,本文模型能够提前对故障做出预警,可作为现场运行人员对辅机设备状态的参考依据,在故障发生前为抢修与维护争取一定的时间裕度。

6 结论

针对电站辅机故障预警方法的研究,本文提出了基于SAE网络的辅机故障预警方法,并引入了BN算法以提升网络性能。通过对辅机历史正常数据特征的逐层提取,SAE网络能够表示辅机各变量之间的非线性关系,对于输入的观测值SAE网络给出相应重构值,且重构误差较小。但正常信号在不同工况下表现形式千差万别,SAE网络重构的稳定性仍需通过收集更多工况下的正常数据进行验证。利用中速磨煤机故障数据对模型有效性进行验证,结果表明该模型能够对磨煤机的故障状态作有效的预警。该故障样本属于短时故障,对于渐变故障识别的准确度仍需收集相应样本作进一步的验证。本文方法不仅适用于电站辅机的故障预警,还可应用于锅炉过程、风力发电机等多变量工业过程的异常检测。而若要对故障的类型、部位及程度进行识别与判定,则需收集充足的故障样本或现场经验,并结合故障诊断的算法作进一步的研究。

参考文献

- [1] 武志惠,王蕾,牛海明,等.660 MW 超超临界机组单列辅机控制系统可靠性研究与工程应用[J].中国电力,2015,48(10):33-37.
WU ZH H, WANG L, NIU H M, et al. Reliability study and engineering application of the control system for main auxiliary system of single row configuration in 660-MW ultra-supercritical units [J]. Electric Power, 2015, 48(10): 33-37.
- [2] 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.
- [3] 朱卫列,王智微,李振华.基于设备特征值的电站设备状态检修[J].热力发电,2018,47(12):72-76.
ZHU W L, WANG ZH W, LI ZH H. Condition based maintenance for power station equipments based on

- equipment characteristic value [J]. Thermal Power Generation, 2018, 47(12): 72-76.
- [4] 马良玉, 安连锁, 王松岭, 等. 基于高精度性能模型的轴流通风机喘振故障预报方法[J]. 风机技术, 2003, 45(4): 52-56.
- MA, L Y, AN L S, WANG S L, et al. Forecasting method of surge trouble for axial fan based on high accuracy performance model[J]. Compressor Blower & Fan Technology, 2003, 45(4): 52-56.
- [5] 邵壮, 司凤琪, 郭俊山, 等. 静叶可调汽动引风机运行特性与性能优化[J]. 东南大学学报(自然科学版), 2015, 45(4): 707-713.
- SHAO ZH, SI F Q, GUO J SH, et al. Operation characteristic and performance optimization of adjustable static blade steam-driven induced draft fan[J]. Journal of Southeast University (Natural Science Edition), 2015, 45(4): 707-713.
- [6] 曾德良, 高珊, 胡勇. MPS 型中速磨煤机建模与仿真[J]. 动力工程学报, 2015, 35(1): 55-61.
- ZENG D L, GAO SH, HU Y. Modeling and simulation of MPS medium speed coal mills[J]. Journal of Chinese Society of Power Engineering, 2015, 35(1): 55-61.
- [7] 白翎. 火电厂重要辅助设备可靠性状态识别研究[J]. 热力发电, 2017, 46(11): 25-31.
- BAI L. Reliability state identification for key auxiliary equipments in thermal power units[J]. Thermal Power Generation, 2017, 46(11): 25-31.
- [8] 白翎, 陈杭君, 李石, 等. 火力发电厂辅助设备可靠性指标评价体系研究[J]. 中国电力, 2017, 50(9): 148-154.
- BAI L, CHEN H J, LI SH, et al. Study on the reliability evaluation system for the auxiliary equipment in the thermal power plant[J]. Electric Power, 2017, 50(9): 148-154.
- [9] 何正嘉, 曹宏瑞, 瞿艳阳, 等. 机械设备运行可靠性评估的发展与思考[J]. 机械工程学报, 2014, 50(2): 171-186.
- HE ZH J, CAO H R, ZI Y Y, et al. Developments and thoughts on operational reliability assessment of mechanical equipment [J]. Journal of Mechanical Engineering, 2014, 50(2): 171-186.
- [10] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
- LEI Y G, JIA F, ZHOU X, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [11] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化, 2019, 43(4): 180-197.
- ZHOU N CH, LIAO J Q, WANG Q G, et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems, 2019, 43(4): 180-197.
- [12] 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.
- [13] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946-1953.
- ZHAO G Q, GE Q Q, LIU X Y, et al. Fault feature extraction and diagnosis method based on deep belief network[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1953.
- [14] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323: 533-536.
- [15] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [16] ZHAO H SH, LIU H H, HU W J, et al. Anomaly detection and fault analysis of wind turbine components based on deep learning network[J]. Renewable Energy, 2018, 127: 825-834.
- [17] 赵洪山, 闫西慧, 王桂兰, 等. 应用深度自编码网络和 XGBoost 的风电机组发电机故障诊断[J]. 电力系统自动化, 2019, 43(1): 81-90.
- ZHAO H SH, YAN X H, WANG G L, et al. Fault diagnosis of wind turbine generator based on deep autoencoder network and XGBoost [J]. Automation of Electric Power Systems, 2019, 43(1): 81-90.
- [18] WANG L, ZHANG Z J, XU J, et al. Wind turbine blade

breakage monitoring with deep autoencoders [J]. IEEE Transactions on Smart Grid, 2018, 9(4):2824-2833.

- [19] KINGMA D P, BA J L. Adam: a method for stochastic optimization [C]. Proceedings of the 3rd International Conference on Learning Representations, 2015: 1-15.

- [20] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. 32nd International Conference on Machine Learning, 2015: 448-456.

- [21] 张西宁, 向宙, 夏心锐, 等. 堆叠自编码网络性能优化及其在滚动轴承故障诊断中的应用 [J]. 西安交通大学学报, 2018, 52(10): 49-56, 87.

ZHANG X N, XIANG ZH, XIA X R, et al. Optimization of stacking auto-encoder with application in bearing fault diagnosis [J]. Journal of Xi'an Jiaotong University, 2018, 52(10): 49-56, 87.

- [22] 李传煌, 吴艳, 钱正哲, 等. SDN 下基于深度学习混合模型的 DDoS 攻击检测与防御 [J]. 通信学报, 2018, 39(7): 176-187.

LI CH H, WU Y, QIAN ZH ZH, et al. DDoS attack detection and defense based on hybrid deep learning model in SDN [J]. Journal on Communications, 2018, 39(7): 176-187.

- [23] 焦嵩鸣. 基于融合相似度的制粉系统健康预警及故障诊断 [J]. 系统仿真学报, 2018, 30(2): 595-604.

JIAO S M. Health warning and fault diagnosis of pulverizing system based on syncretic similarity [J]. Journal of System Simulation, 2018, 30(2): 595-604.

作者简介



李晓彬 (通信作者), 2017 年于华北电力大学获得学士学位, 现为华北电力大学硕士研究生, 研究方向为电站设备状态监测与故障预警。

E-mail: lxb@ncepu.edu.cn

Li Xiaobin (Corresponding author) received his B. Sc. degree from North China Electric Power University in 2017. He is currently a M. Sc. student at North China Electric Power University. His main research interests include condition monitoring and fault warning of power plant equipment.



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分析诊断。

E-mail: nyg@ncepu.edu.cn

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