

# 基于性能改善深度置信网络的风电机组主轴承状态分析

赵洪山, 刘辉海

(华北电力大学 电气与电子工程学院, 河北 保定 071003)

**摘要:**针对风电机组数据采集与监视控制系统采集的状态数据具有大容量、多样性的特点,充分利用该数据研究风电机组主轴承的状态分析方法成为了重要问题。采用深度学习方法分析风电机组主轴承变量间的特征规则,提取反映主轴承状态的特征变量;通过指数加权移动平均法设定阈值检测特征变量的变化趋势,判定异常状态的发生;根据深度置信网络的特点,从数据集变量的异常数据剔除、训练数据批次的选择、参数调优的迭代周期以及在线学习训练等方面对模型性能进行优化和改善,从而使得深度置信网络能够充分挖掘数据集的信息特征,达到有效地反映主轴承状态的目的。通过对主轴承发生故障前、后记录的数据进行仿真分析,结果验证了深度置信网络方法对主轴承状态监测的有效性。

**关键词:**风电机组; 主轴承; 状态分析; 深度学习; 深度置信网络

中图分类号: TM 614

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2018.02.006

## 0 引言

近年来,快速发展的风电在能源产业结构中起到了越来越重要的作用。由于风电机组工作状况的复杂多变,风电机组的故障发生率较高,导致其维修成本一直居高不下。因此,对风电机组主轴承等关键部件进行及时、有效的故障预测成为了提高风电机组运行可靠性、降低维修成本的重要途径<sup>[1-2]</sup>。

目前,风电场普遍安装了数据采集与监视控制(SCADA)系统。由于风电机组监测点多、监测时间长,风电场积累了风电机组主轴承丰富、海量的样本数据,这使得对主轴承的状态分析具有了大数据的性质。针对风电机组海量的数据,如何挖掘其中的规律和特征,并转换为对风电机组关键部件的故障检测和状态分析,成为了研究的关键。随着机器学习领域的发展,深度学习理论由 Hinton<sup>[3]</sup>等首次提出作为一种工具应用在大数据的处理中,掀起了深度学习研究的浪潮。深度学习方法通过建立多层次神经网络模拟大脑学习过程,利用海量的样本数据训练激活网络的单元节点,提取和学习数据内部蕴含的内在信息,从而达到识别和预测的目的<sup>[4]</sup>。

深度学习已经在各个领域取得突破性成果。在图片的识别处理上,基于深度学习网络的航空数据的频谱-空间图像分类方法取得显著效果,与传统的分类方法相比提高了识别率<sup>[4]</sup>。文献[5]利用深度学习方法实现了太阳能电池板表面缺陷检测,并且

提高了准确率,摆脱了传统方法依赖人工完成识别的现状。针对机械系统大数据的特点与深度学习在信息特征提取中的优势,文献[6]提出了一种新的针对机械部件的状态监测方法,摆脱了传统方法对于信号处理与诊断技术的依赖性。针对复杂的机械装备的故障提取与选择,文献[7]提出了一种基于深度置信网络 DBN(Deep Belief Network)的故障提取方法,实现了对轴承信号故障特征的智能提取,解决了人工提取的不完备性与复杂性。针对风电机组主轴承的故障特征提取方法主要有状态变量残差检验法<sup>[8]</sup>、振动监测分析法<sup>[9-11]</sup>以及声发射检测法<sup>[12-13]</sup>。传统的故障分析方法比较复杂,并且容易受到环境和人为因素的影响。深度学习网络通过构建深层结构,在摆脱了传统方法不足的基础上实现了智能诊断与识别<sup>[7]</sup>。

风电机组 SCADA 系统在正常状态下积累了大量数据,这些数据包含了反映主轴承状态的信息特征。本文针对深度学习方法的特点,在原有 DBN 的基础上从训练样本数据和模型方面对 DBN 进行了改善,分析主轴承状态数据中的特征规则,提取主轴承的状态检测量以实现故障检测。

## 1 DBN 模型原理

深度学习是一种典型的超过三层的深层神经网络,该网络能够逐层提取数据包含的特征规则,并且这种通过学习提取的深度特征非常稳定,不会随着输入数据的变化而改变。DBN 作为一种快速学习算法已经成为深度学习典型的学习模型。该网络包括模型预训练和利用反向传播(BP)算法的参数微

收稿日期:2017-02-14;修回日期:2017-11-11

基金项目:国家科技支撑计划项目(2015BAA06B03)

Project supported by the National Science and Technology Support Project of China(2015BAA06B03)

调两部分。

### 1.1 模型训练

DBN 是由多个限制玻尔兹曼机 RBM (Restricted Boltzmann Machine) 堆叠构成的深层学习网络。RBM 是一种两层网络结构,包括可见层单元  $v = \{v_1, v_2, \dots, v_n\}$  ( $v_i \in \{0, 1\}$ ) 和隐含层单元  $h = \{h_1, h_2, \dots, h_m\}$  ( $h_j \in \{0, 1\}$ ),用来逐层训练 DBN 模型中隐含层的参数,其结构如图 1 所示。该联合结构网络的层间单元节点具有的能量<sup>[14]</sup>表示为:

$$E(v, h; \theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m w_{ij} v_i h_j \quad (1)$$

其中,  $\theta = \{b_j, a_i, w_{ij}\}$ ,  $w_{ij}$  为可见层单元  $i$  与隐含层单元  $j$  的连接权重,  $b_j$ 、 $a_i$  分别为隐含层单元  $j$  与可见层单元  $i$  的偏置。

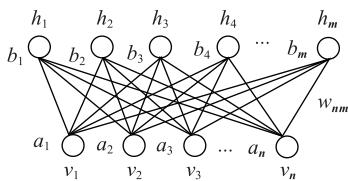


图 1 RBM 的结构

Fig.1 Structure of RBM

该网络的联合分布可由网络的节点能量表示为:

$$P(v, h; \theta) = \frac{1}{Z(\theta)} \exp(-E(v, h; \theta)) \quad (2)$$

$$Z(\theta) = \sum_v \sum_h E(v, h; \theta) \quad (3)$$

其中,  $Z(\theta)$  为标准化变量。该网络给出了经过能量函数表示后的每个输入向量的概率值。概率值可以通过改变参数  $\theta$  来改变式(1)所示能量值得到调整<sup>[15]</sup>。

RBM 中的隐含层单元  $h$  和可见层单元  $v$  的条件分布可以表示为:

$$P(h_j = 1 | v) = f\left(\sum_{i=1}^n w_{ij} v_i + b_j\right) \quad (4)$$

$$P(v_i = 1 | h) = f\left(\sum_{j=1}^m w_{ij} h_j + a_i\right) \quad (5)$$

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (6)$$

其中,  $f(x)$  为激活函数。本文采用 tanh 函数代替了 sigmoid 函数,当 sigmoid 函数的输入处于  $[-1, 1]$  之间时,函数值变化敏感,一旦接近或者超出区间便会失去敏感性,处于饱和状态将影响神经网络预测的精度值。另外 tanh 函数比 sigmoid 函数的输出收敛速度更快,tanh 函数的输出和输入能够保持非线性

单调上升和下降关系,符合 BP 算法的梯度求解。

隐含层的状态被激活后,根据式(5),当  $v_i = 1$  时得到输出,更新隐含层单元的状态。因此,隐含层的状态表示为网络对数据特征规则的提取。利用对比散度算法实现权重  $w$  的学习更新<sup>[16]</sup>,该权重的更新准则为:

$$\Delta w_{ij} = \epsilon (v_i h_{j,data} - v_i h_{j,recon}) \quad (7)$$

其中,  $\epsilon$  为学习率;  $v_i h_{j,data}$  为实际数据输入网络之后得到的实际权重值;  $v_i h_{j,recon}$  为网络重构得到的权值。通过 RBM 的逐层学习训练过程,可以得到合理的  $w$  值。

RBM 的强大之处在于采用重构学习的方式实现参数的训练。在重构的过程中,只需要利用从样本数据中学习的隐含层的激活信息,可以实现输入数据的重构。如果这个模型能够非常好地重构输入数据,表明隐含层单元保留了输入数据丰富的特征信息,那么通过训练学习获得的权重和偏置就是输入数据的特征规则。

单个 RBM 的隐含层并不是提取数据特征的最好方式。在 RBM 训练完成后,将该 RBM 网络的输出特征结果作为下一个 RBM 的输入,这种逐层学习系统的堆叠构成 DBN<sup>[17-18]</sup>。利用这种方式,DBN 可以连续依次提取输入数据的特征规则,并将其保存在每个隐含层的单元节点中。图 2 为 DBN 的逐层学习模式。

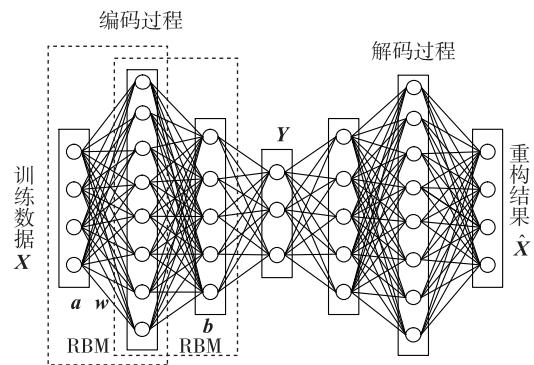


图 2 DBN 的结构

Fig.2 Structure of DBN

第一个 RBM 将输入数据作为第一层首次提取特征,利用上述的学习方式进行训练得到隐含层的参数。在训练完成之后,将输出作为下一个 RBM 的输入依次逐级训练。最后一个 RBM 的特征输出就是整个网络特征的深层特征。最终,利用这种逐层学习的模式进行反向 RBM 训练从而获得 DBN 对输入数据的重构。通过 RBM 网络进行逐层训练完成之后使得 DBN 获得了较好的初始参数,然后利用

BP 算法在原有基础上对参数进行微调,使得网络的重构输出与原始输入的损失最小<sup>[19]</sup>。

在训练过程中,这些训练样本选为风电机组主轴承长期正常运行状态下的 SCADA 系统无标签状态监测数据。为了减小风电机组主轴承不同类型变量的数值差异性引起的计算误差,并且保证原始数据结构相对不变,对训练样本中的变量做归一化处理。

### 1.2 主轴承故障检测量

DBN 模型利用风电机组主轴承的状态变量作为训练样本进行多层深度学习。当网络训练完成之后,隐含层保存了训练样本的特征规则,使得重构值能够较好地拟合输入数据。

在主轴承正常状态下,输入数据与其重构值的误差将会保持在一定的范围内波动,该误差定义为重构误差  $R_e$ 。图 3 为正常状态下 A01 号风电机组主轴承的  $R_e$ 。当主轴承发生故障时,主轴承的状态监测数据内部不再满足原有的规则,具体表现为  $R_e$  的趋势发生变化。因此,本文通过设定阈值检测  $R_e$  的趋势变化,实现主轴承的故障检测。 $R_e$  的求取如式(8)所示。

$$R_e = \|\hat{X} - X\|^2 \quad (8)$$

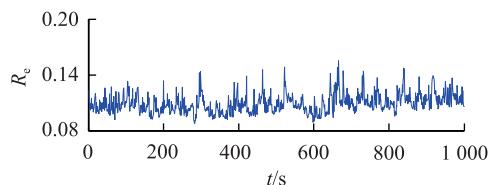


图 3 正常状态下 A01 号风电机组主轴承的  $R_e$

Fig.3  $R_e$  of main bearing of A01 wind turbine in normal condition

## 2 模型学习性能的改善方法

### 2.1 基于数据学习批次的模型改善

深度学习网络对输入数据学习的过程是对输入数据进行分批次反复迭代学习,这种方式使得网络的隐含层单元节点能够充分学习数据中的规则,并使节点充分激活。不同批次的数据量下 DBN 学习的重构误差  $R_e$ ,如图 4 所示。每批次数据量的大小影响着网络对于数据规则提取的充分性。当每一批次的数据量为 20 时, $R_e$  的值最小,训练数据的特征信息损失最小,网络学习数据规则的结果更充分。

### 2.2 基于参数调优迭代周期的模型改善

深度学习网络训练完成之后,构建模型框架使得网络的隐含层单元有初始学习结果的先验值。然

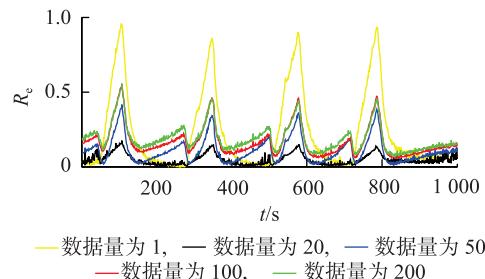


图 4 不同数据量下的  $R_e$

Fig.4  $R_e$  under different batches

后,利用主轴承长期正常运行的数据作为标签数据,对所建立的网络模型进行监督学习以实现对网络参数的微调。参数微调过程采用梯度上升法实现参数的更新,按照不同的迭代周期对参数进行寻优,获得具有深层表征性能的监督学习效果。图 5 为不同迭代周期下训练完成后相同输入测试数据的  $R_e$  对比。迭代周期选择越大,模型训练结果越优,但是当迭代周期达到一定值时模型的表征能力趋于稳定。综合考虑迭代周期越大模型训练时间越长和网络学习的充分性,迭代周期一般选为 200。

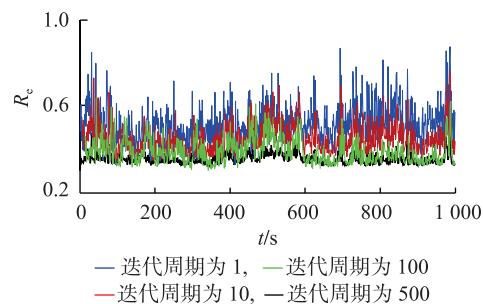


图 5 不同迭代周期下的  $R_e$

Fig.5  $R_e$  with different iteration cycles

### 2.3 基于数据的在线学习的模型改善

当风电机组主轴承的 DBN 构建完成后,可以利用该 DBN 实现主轴承的故障检测。正常运行的风电机组主轴承每天或每周都会积累一定的 SCADA 数据。这些数据对于模型的改善和稳定性的提高具有非常重要的价值。因此,可以通过选取主轴承一段时间内的正常数据在原来模型参数的基础上进行递进学习,实现网络参数的更新。

选取的时间为一天或一周的数据量比较小,这样可以大幅减小因重新训练模型需要的时间。另外利用新的数据集能够实现系统的在线学习训练,从而提高模型的稳定性,使得 DBN 对主轴承状态监测数据结构的学习更充分。因此,风电场可以在系统负载较小条件下利用积累的新数据集进行在线训练,充分地利用系统资源,并且避免因一次训练后的

模型长时间应用引起的状态检测误差。图 6 为初始训练与在线训练的  $R_e$  对比。

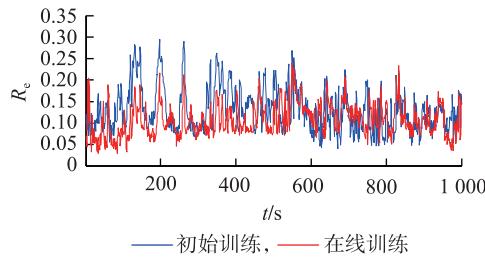


图 6 初始训练与在线训练的  $R_e$

Fig.6  $R_e$  of initial training and online training

#### 2.4 基于数据量与异常数据剔除的模型改善

风电机组 SCADA 系统采集的初始状态监测数据,通常包含由于系统未能记录的空数据以及异常的状态数据,如停机时记录的功率为 0 的值和转矩为负的值。因此,在建立训练数据集时需要将这些变量的异常数据剔除,而且训练数据集应该包含风电机组从起机到切机的整个风速范围内的正常运行数据,这样才能建立主轴承足够充分的状态样本集。

另外 DBN 的训练集中数据量所包含的风电机组正常运行风速范围内的运行数据量越大,训练的结果越能够深度提取状态变量数据间的规则特征,从而使得 DBN 模型的稳定性和表征能力会更加突出。图 7 为数据量为一个季度与一个月的数据训练后的  $R_e$  结果对比。

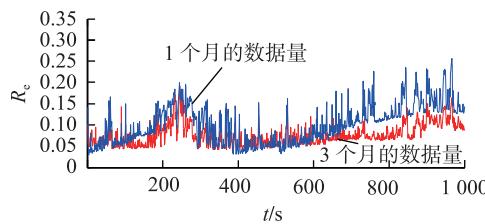


图 7 不同训练样本数据量下的  $R_e$

Fig.7  $R_e$  of training with different sample data sizes

### 3 主轴承的 DBN 故障检测分析

#### 3.1 主轴承正常状态下的模型

本文选取 A01 号和 A45 号风电机组主轴承 2015 年 2 月 1 日至 5 月 1 日正常状态下的 SCADA 系统数据,建立主轴承样本数据集,从 3 m/s 风电机组起动到 25 m/s 风电机组切除范围内的正常状态下的监测数据样本,训练主轴承 DBN 模型。选取 A01 和 A45 号风电机组主轴承故障前后的记录数据作为验证集。DBN 设定 4 个隐含层,其结构为 1 000 - 500 - 250 - 50,训练数据集的总数据量分别为

558 420×5 和 548 871×5。训练数据样本中主要包含 SCADA 系统监测的主轴承变量:风速  $v_o$  (m/s),发电机转速  $\Omega$  (r/s),发电功率  $P$ ,转子侧主轴承温度  $T_r$ (°C),齿轮箱侧主轴承温度  $T_c$ (°C)。

#### 3.2 主轴承正常状态下的模型分析结果

根据构建的风电机组主轴承 DBN 模型,选取 A01 号风电机组主轴承发生故障前后记录的数据,验证模型对故障检测的有效性。对 A01 号风电机组故障数据进行预处理之后,作为模型的输入计算  $R_e$ 。本文选用指数加权移动平均法 EWMA (Exponentially Weighted Moving Average) 设定  $R_e$  的阈值检测其趋势变化,该方法适用于检测连续  $R_e$  的趋势变化。

EWMA 控制线的统计量  $z_t$  为:

$$z_t = \lambda R_{et} + (1 - \lambda) z_{t-1} \quad (9)$$

其中,  $t$  为时刻;  $\lambda \in (0,1]$  为历史  $R_e$  对当前统计量的权重;  $R_{et}$  为  $t$  时刻的重构误差值;  $z_0$  为风电机组主轴承运行在正常状态一段时间内  $R_e$  的均值。该分析过程中  $\lambda$  取 0.2。

EWMA 统计量  $z_t$  的均值和方差可通过式(10)计算得到:

$$\mu_{z_t} = \mu_{R_e}, \quad \sigma_{z_t}^2 = \frac{\sigma_{R_e}^2}{n_s} \frac{\lambda}{2 - \lambda} [1 - (1 - \lambda)^{2t}] \quad (10)$$

其中,  $\mu_{R_e}$  为该风电机组主轴承历史  $R_e$  的均值;  $\sigma_{R_e}$  为  $R_e$  的标准差;  $n_s$  为采样长度。因此风电机组主轴承的 EWMA 控制图基于  $t$  时刻的上限阈值为:

$$U_L(t) = \mu_{R_e} + k \sigma_{R_e} \sqrt{\frac{\lambda [1 - (1 - \lambda)^{2t}]}{(2 - \lambda) n_s}} \quad (11)$$

其中,  $k=3$ 。

结合  $R_e$  的阈值,A01 号风电机组主轴承  $R_e$  的变化如图 8 所示。

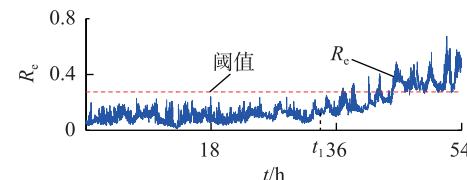


图 8 故障状态下 A01 号风电机组主轴承的  $R_e$

Fig.8  $R_e$  of main bearing of A01 wind turbine with fault

仿真结果显示,正常状态下主轴承  $R_e$  的变化趋势一直处于动态平稳的变化中,并且保持在控制范围内波动。这表明主轴承的 DBN 能够动态反映状态监测数据间的特征规则和主轴承的运行状态。图 8 中,主轴承的  $R_e$  从  $t_1$  时刻开始出现异常波动,趋势偏离原来的稳定状态,并逐渐接近控制上限。经

过一段时间最终越过上限并一直保持在阈值之上，据此可判定主轴承出现异常，发出故障预警。提取DBN反映主轴承状态的变量 $R_e$ ，当其趋势发生变化并超过阈值时可以判定出现异常，实现了风电机组主轴承的异常检测，达到主轴承故障预测的目的。

### 3.3 改善 DBN 模型的风电机组异常检测

通过利用模型性能改善的方法对DBN模型进行重新训练，将A45号风电机组主轴承发生故障前后的记录数据作为模型的输入，其 $R_e$ 与初始训练模型的 $R_e$ 对比结果如图9所示。图9(a)、(b)分别为DBN模型改善前、后的检测结果，从图中可以看出模型改善后检测的主轴承异常的时刻比改善前的检测结果提前。另外，从图9中可看出主轴承 $R_e$ 在DBN模型改善后比改善前的幅值小，保留的主轴承状态变量的关系信息更充分。因此，改善模型对主轴承的异常检测更灵敏，从而能够较早地反映主轴承状态的异常，发现故障。

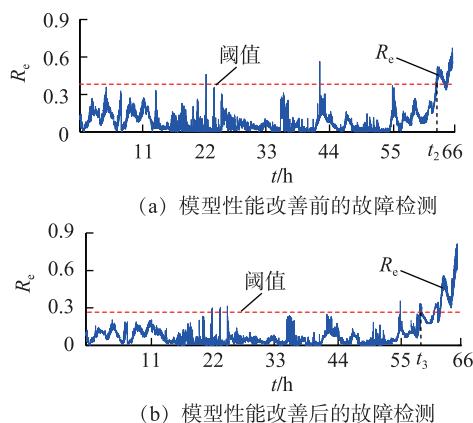


图9 模型性能改善前、后的故障检测结果

Fig.9 Fault detection results before and after improving model performance

结合主轴承的状态监测变量，本文选取多元线性回归分析方法构建主轴承回归模型与改善后DBN模型的检测结果进行对比。采用的主轴承变量同3.1节。首先对数据进行分析，构建主轴承正常状态下的预测模型。通过引入主轴承故障前后的实际监测数据，分析实际运行状况与回归分析模型估计的残差趋势实现对故障的检测。图10为主轴承多元线性回归分析方法的结果，与图9(b)对比可以看出模型改善后检测的故障时刻 $t_3$ 比多元线性回归分析方法的检测结果 $t_4$ 提前。DBN深度学习方法能够智能地逐层学习主轴承所有正常状态下状态变量间的关系和运行规律。与回归分析方法相比，DBN提取的主轴承的运行状态信息更全面，能够较灵敏地反映主轴承状态的异常变化。

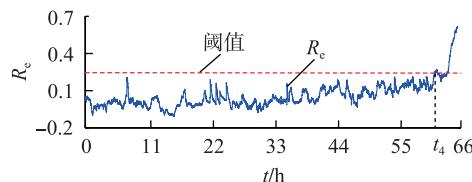


图10 基于线性回归的A45号风电机组主轴承故障检测结果

Fig.10 Fault detection result of A45 wind turbine main bearing based on linear regression

## 4 结论

本文通过分析风电机组SCADA系统数据和深度学习网络的特点，针对传统方法的不足之处，提出了一种基于深度学习理论的风电机组主轴承状态分析方法。该深度学习方法能够提取状态变量间的特征规则，并选取反映主轴承状态的特征变量 $R_e$ ，实现对多个变量的同时监测。本文从多个方面对模型的性能进行了提升，取得了较好的监测结果。与传统的分析方法相比，该方法更适用于提取大量数据中的特征，识别设备的运行状况。

## 参考文献：

- [1] 陈雪峰,李济猛,程航,等.风力发电机状态监测与故障诊断技术的研究与进展[J].机械工程学报,2011,47(9):45-52.  
CHEN Xuefeng, LI Jimeng, CHENG Hang, et al. Research and application of condition monitoring and fault diagnosis technology in wind turbines [J]. Journal of Mechanical Engineering, 2011, 47 (9):45-52.
- [2] HANG Jun,ZHANG Jianzhong,CHENG Ming,et al. An overview of condition monitoring and fault diagnostic for wind energy conversion system[J]. Transactions of China Electrotechnical Society,2013,28 (4):261-271.
- [3] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural network [J]. Science, 2006, 313 (5786):504-507.
- [4] CHEN Yushi, LIN Zhouhan, ZHAO Xing, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 7 (6):2094-2107.
- [5] 王宪保,李洁,姚明海,等.基于深度学习的太阳能电池片表面缺陷检测方法[J].模式识别与人工智能,2014,27(6):517-523.  
WANG Xianbao, LI Jie, YAO Minghai, et al. Solar cells surface defects detection based on deep learning[J]. Pattern Recognition and Artificial Intelligence, 2014,27(6):517-523.
- [6] 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 Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015,51(21):49-56.
- [7] 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 Guangquan, GE Qiangqiang, LIU Xiaoyong, et al. Fault feature extraction and diagnosis method based on deep belief network [J]. Chinese Journal of Scientific Instrument, 2016, 37 (9):1946-1953.
- [8] 张小田, 鄢盛腾, 周雪青, 等. 基于状态监测的风电机组主轴承早期故障预测方法[J]. 广东电力, 2012, 25(11):6-10.
- ZHANG Xiaotian, YAN Shengteng, ZHOU Xueqing, et al. Early stage failure forecast method for main bearing of wind turbine based on state monitoring[J]. Guangdong Electric Power, 2012, 25(11): 6-10.
- [9] 郭艳平, 颜文俊, 包哲静, 等. 基于经验模态分解和散度指标的风电机组滚动轴承故障诊断方法[J]. 电力系统保护与控制, 2012, 40(17):83-88.
- GUO Yanping, YAN Wenjun, BAO Zhejing, et al. Fault diagnosis of bearing in wind turbine based on empirical mode decomposition and divergence index[J]. Power System Protection and Control, 2012, 40(17):83-88.
- [10] 唐贵基, 庞彬. ITT 变换在风电机组滚动轴承故障诊断中的应用[J]. 电力自动化设备, 2017, 37(9):83-89.
- TANG Guiji, PANG Bin. Application of ITT transform in fault diagnosis of wind turbine rolling bearing[J]. Electric Power Automation Equipment, 2017, 37(9):83-89.
- [11] 赵洪山, 邵玲, 连莎莎. 基于最大信噪比的风电机组主轴承的故障特征提取[J]. 可再生能源, 2015, 33(3):410-415.
- ZHAO Hongshan, SHAO Ling, LIAN Shasha. Method for extracting fault feature of wind turbine main bearing based on maximum signal to noise ratio [J]. Renewable Energy Resource, 2015, 33 (3): 410-415.
- [12] 李宁, 魏鹏, 莫宏, 等. 光纤光栅声发射检测新技术用于轴承状态监测的研究[J]. 振动与冲击, 2015, 34(3):172-177.
- LI Ning, WEI Peng, MO Hong, et al. Bearing state monitoring using a novel fiber bragg grating acoustic emission technique[J]. Journal of Vibration and Shock, 2015, 34(3):172-177.
- [13] LI R, HE D. Rotational machine health monitoring and fault detection using EMD-based acoustic emission feature quantification[J]. IEEE Transactions on Instrumentation & Measurement, 2012, 61 (4):990-1001.
- [14] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2014, 18 (7): 1527-1554.
- [15] CHEN Y, ZHAO X, JIA X. Spectral-spatial classification of hyperspectral data based on deep belief network[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2015, 8(6):2381-2392.
- [16] HINTON G E. Training products of experts by minimizing contrastive divergence [J]. Neural Computation, 2002, 14 (8): 1771-1800.
- [17] ROUX N L, BENGIO Y. Deep belief networks are compact universal approximators[J]. Neural Computation, 2010, 22(8):2192-2207.
- [18] 石鑫, 朱永利, 宁晓光, 等. 基于深度自编码网络的电力变压器故障诊断[J]. 电力自动化设备, 2016, 36(5):122-126.
- SHI Xin, ZHU Yongli, NI Xiaoguang, et al. Transformer fault diagnosis based on deep auto-encoder network[J]. Electric Power Automation Equipment, 2016, 36(5):122-126.
- [19] HECHTNIELSEN R. Theory of the backpropagation neural network [C] // International Joint Conference on Neural Networks. Washington DC, USA: IEEE, 2002:593-605.

#### 作者简介:



赵洪山

赵洪山(1965—),男,河北沧州人,教授,博士,主要研究方向为电力系统运行与控制以及电力设备故障诊断与优化检修(**E-mail**: zhaohshcn@126.com);

刘辉海(1991—),男,河北沧州人,硕士研究生,主要研究方向为风电机组故障检测(**E-mail**: hhliu3@126.com)。

## Condition analysis of wind turbine main bearing based on deep belief network with improved performance

ZHAO Hongshan, LIU Huihai

(School of Electrical & Electronic Engineering, North China Electric Power University, Baoding 071003, China)

**Abstract:** The condition data collected by supervisory control and data acquisition system of wind turbine has the characteristics of large capacity and diversity, based on which to analyze the condition of wind turbine main bearing has becoming an important research point. The characteristic rules of the main bearing variables of wind turbine are analyzed by deep learning method to extract the characteristic variables reflecting the condition of main bearing. Threshold value is set by exponentially weighted moving average approach to detect the variation trend of characteristic variables and determine the occurrence of abnormal conditions. According to the characteristics of deep belief network, the performance of the model is optimized and improved from aspects of: abnormal data exclusion from data sets, selection of training data batches, iteration cycles of parameter optimization, on-line learning and training and so on, so that the information characteristics of data sets are fully excavated by deep belief network to achieve the purpose of reflecting main bearing's condition effectively. The recorded data of the main bearing with and without faults are simulated, and the results verify the effectiveness of the deep belief network method on bearing's condition monitoring.

**Key words:** wind turbines; main bearing; condition analysis; deep learning; deep belief network