

基于深度信念网络的电力变压器故障分类建模

石鑫¹, 朱永利¹, 萨初日拉¹, 王刘旺¹, 孙岗²

(1. 华北电力大学控制与计算机工程学院, 河北 保定 071003; 2. 国家电网公司, 北京 100031)

摘要: 基于深度信念网络, 构建了深度信念网络分类器模型, 分析并用典型数据集对其分类性能进行测试。在此基础上结合电力变压器油中溶解气体分析数据, 提出了基于深度信念网络分类器的变压器故障分类新方法, 它使用油中溶解气体分析结果作为故障分类属性。对所提出的方法进行了测试, 测试结果表明该方法适用于变压器故障分类, 具有较强的从样本中提取特征的能力和容错特性, 性能优于 BP 神经网络和支持向量机的方法。

关键词: 电力变压器; 故障诊断; 深度信念网络; 无标签样本; 油中溶解气体分析

Power transformer fault classifying model based on deep belief network

SHI Xin¹, ZHU Yongli¹, SA Churila¹, WANG Liuwang¹, SUN Gang²

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China;

2. State Grid Corporation of China, Beijing 100031, China)

Abstract: Based on deep belief network (DBN), a deep belief network classifier (DBNC) model is built. Analysis and typical data set validate the classification performance of it. Combining power transformer dissolved gas-in-oil analysis (DGA) data, a new transformer fault classification method, which is based on DBNC, is proposed initially. The approach uses the results of DGA as the necessary attributes to classify power transformer's fault types. The proposed method is tested, which shows that it is suitable for power transformer fault classification. It has strong ability to extract features from samples, and has error-tolerance capability. Test results also show that the performance of the proposed approach prevails that of back propagation neural network (BPNN) and support vector machine (SVM) methods.

This work is supported by Natural Science Foundation of Hebei Province (No. E2009001392).

Key words: power transformer; fault diagnosis; deep belief network; unlabeled samples; gas-in-oil analysis

中图分类号: TM41

文章编号: 1674-3415(2016)01-0071-06

0 引言

电力变压器是电力系统中最重要设备之一, 它的运行状况直接关系到整个电力系统的安全稳定运行, 一旦发生故障必将引起局部乃至大面积的停电, 势必会造成巨大的经济损失。随着传感器技术、计算机技术及应用数学的高速发展, 对电力变压器实施在线监测已经成为可能, 而如何利用在线监测数据进行准确的故障诊断变得尤为重要。

电力变压器油中溶解气体分析(Dissolved Gas Analysis, DGA)不受外界电场和磁场的影响, 易于带电和在线实现, 已经成为油浸式变压器故障诊断的一种有效方法^[1-5], 并在此基础上形成了特征气体法、三比值法和 Rogers 法等传统方法^[6], 以及人工

神经网络(ANN)^[7-8]、支持向量机(SVM)^[9-10]和极限学习机(ELM)^[11]等人工智能方法。然而传统算法存在缺编码、编码界限过于绝对等主要缺陷^[6]; ANN 存在着收敛速度慢、易产生振荡、易陷入局部最优等问题^[7-8]; SVM 本质上属于二分类算法, 在多分类问题上存在构造学习器及分类效率低的缺点, 而且核函数的选择和参数的确定比较困难^[9-10]; ELM 训练速度快, 但是稳定性比较差^[11]。同时, 上述方法均属于浅层机器学习方法, 学习能力具有一定的有限性, 诊断准确率达到一定高度时很难再有大的提高; 而且需要样本准确、完备, 方能得到比较满意的结果; 不适用于大量样本的训练, 可扩展性较差。

深度信念网络(Deep Belief Network, DBN)是深度学习的一种, 具有较强的从大量样本中提取特征的能力, 以便于更好地分类, 进而提高分类的准确率。该方法已经成功应用于分类问题, 而且表

现出了一定的优势,是当前国际上机器学习研究的热点领域^[12-17],但尚未见其应用于变压器故障诊断。

鉴于此,本文首先构建了分类深度信念网络模型,模型能够以概率形式输出分类结果,便于分析问题的不确定性。然后,结合在线监测油色谱特征及变压器故障类型,提出了基于 DBNC 的变压器故障诊断方法。该方法可以利用工程现场的大量无标签样本进行预训练,优化模型参数,加之少量有标签样本调优,可以有效解决变压器故障分类问题,提高故障诊断准确率。最后,通过工程实例对该方法进行了验证,并与基于 BPNN 和 SVM 的故障诊断方法进行了对比分析。

1 DBN 简介

深度信念网络由 Geoffrey Hinton 教授在 2006 年提出,它是一种概率生成模型,建立一个观察数据和标签之间的联合概率分布,对 $P(\text{Observation}|\text{Label})$ 和 $P(\text{Label}|\text{Observation})$ 均做了评估。结构上,它是由多个受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)堆叠而成,训练时采用逐层训练的方法,解决了传统神经网络训练方法不适用于多层网络的训练问题,整个 DBN 的训练分为预训练和调优两个阶段。

1.1 预训练

预训练实质上就是初始化网络参数的过程,采用逐层无监督特征优化算法进行,需要初始化的网络参数是层与层之间的连接权值及各层神经元的偏置值。以一层 RBM 为例介绍,结构如图 1 所示。

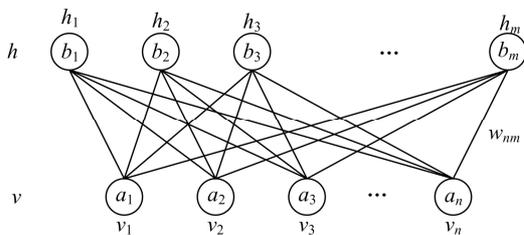


图 1 RBM 结构

Fig. 1 RBM structure

RBM 包含一个可视层 v 和一个隐含层 h ,每层单元之间无连接,层与层之间全连接。假设 v 层有 n 个可见单元, h 层有 m 个隐单元。那么,RBM 作为一个系统所具备的能量定义为

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

式中: v_i 表示第 i 个可见单元的状态; h_j 表示第 j

个隐单元的状态; $\theta = \{W_{ij}, a_i, b_j\}$ 是 RBM 的参数, W_{ij} 表示可见单元 i 与隐单元 j 之间的连接权重, a_i 表示可见单元 i 的偏置, b_j 表示隐单元 j 的偏置。基于该能量函数,可以得到 (v, h) 的联合概率分布为

$$P(v, h | \theta) = \frac{e^{-E(v, h | \theta)}}{Z(\theta)} \quad (2)$$

式中, $Z(\theta) = \sum_{v, h} e^{-E(v, h | \theta)}$ 为归一化因子,即配分函数。则联合概率分布 $P(v, h | \theta)$ 的边际分布(也称为似然函数)可以表示为

$$P(v | \theta) = \frac{1}{Z(\theta)} \sum_h e^{-E(v, h | \theta)} \quad (3)$$

学习 RBM 的任务就是求出参数 θ 的值,以拟合给定的训练数据。假设训练集包含 T 个样本,参数 θ 可以通过最大化 RBM 在训练集上的对数似然函数得到,关键步骤是计算 $\log P(v^{(t)} | \theta)$ 关于模型参数 θ 的偏导数,即

$$\frac{\partial \log P(v | \theta)}{\partial \theta} = \sum_{t=1}^T \left[\begin{array}{c} \left\langle \frac{\partial (-E(v^{(t)}, h | \theta))}{\partial \theta} \right\rangle_{P(h|v^{(t)}, \theta)} \\ - \left\langle \frac{\partial (-E(v, h | \theta))}{\partial \theta} \right\rangle_{P(v, h | \theta)} \end{array} \right] \quad (4)$$

式中: $\langle \cdot \rangle_p$ 表示分布 P 的数学期望; $P(h | v^{(t)}, \theta)$ 表示可见单元为已知的训练样本 $v^{(t)}$ 时隐含层的概率分布; $P(v, h | \theta)$ 表示可见单元与隐单元的联合分布。

假设只有一个训练样本,我们分别用“data”和“model”来简记 $P(h | v^{(t)}, \theta)$ 和 $P(v, h | \theta)$ 这两个概率分布,则对数似然函数关于连接权重 W_{ij} 、可见层单元的偏置 a_i 和隐含层单元的偏置 b_j 的偏导数分别为

$$\frac{\partial \log P(v | \theta)}{\partial W_{ij}} = \langle v_i h_j \rangle_{\text{data}} - \langle v_i h_j \rangle_{\text{model}} \quad (5)$$

$$\frac{\partial \log P(v | \theta)}{\partial a_i} = \langle v_i \rangle_{\text{data}} - \langle v_i \rangle_{\text{model}} \quad (6)$$

$$\frac{\partial \log P(v | \theta)}{\partial b_j} = \langle h_j \rangle_{\text{data}} - \langle h_j \rangle_{\text{model}} \quad (7)$$

式(7)中: $\langle \cdot \rangle_{\text{data}}$ 表示对数据集的期望; $\langle \cdot \rangle_{\text{model}}$ 表示模型中定义的期望值。

1.2 调优

预训练完成之后,每层 RBM 可以得到初始化的参数,组成了 DBN 的初步框架,接下来需要对 DBN 作调优训练,进一步优化网络各层的参数,以

使得网络的判别性能更好。调优过程是有监督学习过程,即采用标签数据进行训练,利用BP算法对网络参数进行微调,最终使网络达到全局最优。这个性能会比单纯BP算法训练效果要好,因为它只需要对网络的参数空间进行一个局部的搜索,相比BP神经网络,训练速度要快,而且收敛时间短。

2 深度信念网络分类器

2.1 DBNC 模型

本文构建了深度信念网络分类器(Deep Belief Network Classifier, DBNC)模型,它的底部由若干层RBM堆叠而成,顶部增加代表期望输出变量的最后一层,即分类层,框架如图2所示。这里,分类器通常选用Softmax分类器,它是Logistic分类器在多分类问题上的推广,它在给出分类结果时还会给出结果的概率,适用于非线性多分类问题,与深度信念网络结合起来,往往会获得较优的判别性能^[18]。

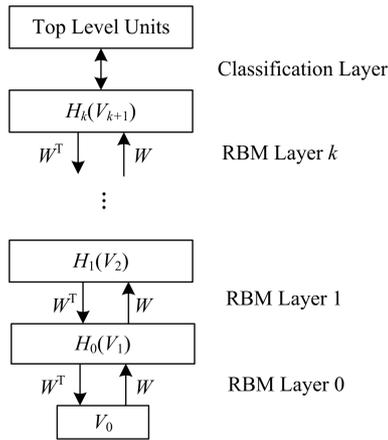


图2 深度信念网络分类器模型

Fig. 2 DBNC model

DBNC用于多分类问题时,训练过程与DBN一样,分为预训练和调优两个阶段。预训练主要是采用无标签样本或去标签样本作为网络的输入,通过CD算法完成底部若干层RBM参数的初始化;调优则是通过标签样本对包括分类器层在内的整个网络参数进行微调,使得网络的判别性能更优。

2.2 DBNC 分类性能分析

采用本文构建的DBNC对典型分类数据集Iris进行分类,网络参数 W 、 a 、 b 初始化为服从高斯分布的随机较小数值,初始学习速率 ρ 大小设为0.1。

分别采用BPNN、SVM和本文提出的DBNC对典型分类数据集Iris进行分类。BPNN训练最大迭代次数为2000,学习速率为0.01;SVM规则化

系数取500,核函数参数取0.5;DBNC初始学习速率取0.1,网络RBM层数为6。三种方法在不同训练集上的分类情况如表1所示。

表1 BPNN、SVM、DBNC在不同训练集上的分类情况

Table 1 BPNN, SVM and DBNC classification case on the

different training sets

算法	训练集	测试集	平均正确率/%
BPNN			74.75
SVM	60	30	79.17
DBNC			78.86
BPNN			83.22
SVM	90	30	87.89
DBNC			89.47
BPNN			88.76
SVM	120	30	90.38
DBNC			93.87

从表1可以看出,当训练集样本数偏少时,DBNC与BPNN、SVM分类结果平均正确率基本相当,随着训练集样本数的增多,DBNC的分类平均正确率高于BPNN和SVM。

3 基于DBNC的变压器故障分类

3.1 选取样本数据

为避免样本集偏斜,同时又能保证得到足够多的样本,可以选取多个工程现场记录的变压器发生故障前后较短一段时间内的油色谱在线监测数据,这些数据均是无标签数据,可以用作预训练样本。对于调优阶段所采用的少量标签样本,可以通过搜集故障变压器测试实验数据获得。

3.2 选取特征变量

根据工程现场油色谱在线监测数据特点,选取 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 、 CO 、 CO_2 七种特征气体含量作为DBNC的输入。由于DGA数据差异比较大,为了减小输入数据的差值,降低计算误差,采用式(8)对各气体进行标准化处理,以提高诊断正确率。

$$x_{\text{new}} = \frac{x - x_{\text{mean}}}{x_{\text{std}}} \quad (8)$$

式中: x_{new} 为标准化后气体的含量值; x 为气体原始含量值; x_{mean} 为训练集或测试集 X 中该类气体含量的均值; x_{std} 为 X 中该类气体含量的标准差值。

3.3 变压器状态编码

变压器故障诊断是一个多分类任务,诊断结果

可以分为正常、中低温过热、高温过热、局部放电、低能放电和高能放电六种类型，下面依次对其进行编码，如表 2 所示。

表 2 变压器状态编码

Table 2 Transformer status codes

变压器状态	编码
正常	(0,0,0,0,0,1)
中低温过热	(0,0,0,0,1,0)
高温过热	(0,0,0,1,0,0)
局部放电	(0,0,1,0,0,0)
低能放电	(0,1,0,0,0,0)
高能放电	(1,0,0,0,0,0)

3.4 基于 DBNC 的变压器故障分类模型

基于 DBNC 的变压器故障分类模型如图 3 所示，模型的输入为油色谱在线监测的七种特征气体含量值(经标准化处理后)，最终经顶层 Softmax 分类器后的输出为相应样本分别属于不同状态的概率值，概率值最大的状态即为分类的最终结果。

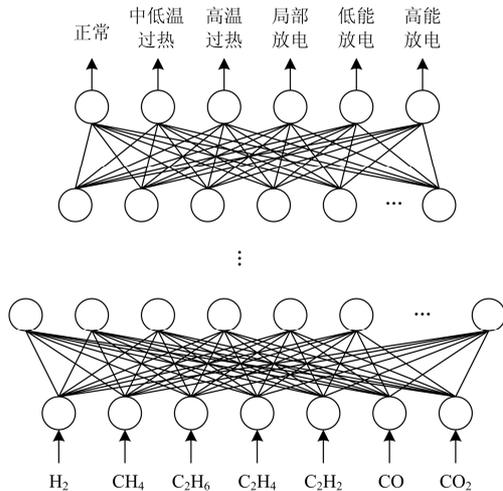


图 3 基于 DBNC 的变压器故障分类模型

Fig. 3 Transformer fault classification model based on DBNC

3.5 基于 DBNC 的变压器故障诊断方法的实现

基于 DBNC 的变压器故障诊断方法实现过程如下：

- (1) 选取样本数据和特征变量，对样本数据进行标准化处理后按一定比例将其分为训练集和测试集。
- (2) 对变压器状态进行编码。
- (3) 建立基于 DBNC 的变压器故障分类模型。
- (4) 初始化变压器故障分类 DBNC 模型参数为服从高斯分布的较小随机数值。
- (5) 采用训练集中的无标签样本通过 CD 算法对模型底部 RBM 层进行预训练。

(6) 采用训练集中的标签样本通过 BP 算法对整个网络进行调优。

(7) 保存训练好的网络，并对其进行测试。

以从训练集中选取的一个训练样本 x_0 为例，CD 算法步骤如下：

步骤 1 初始化可见层单元的初始状态 $v_0=x_0$ ，初始化 W 、 a 、 b 为服从高斯分布的随机较小数值，设定各层 RBM 最大训练迭代次数；

步骤 2 对所有隐单元计算 $P(h_{0j}=1|v_0)=\sigma(b_j+\sum_{i=1}^n v_{0i}W_{ij})$ ，从条件分布 $P(h_{0j}|v_0)$ 中抽取 $h_0\sim P(h_0|v_0)$ ，其中， $\sigma(x)$ 为 sigmoid 函数，下同；

步骤 3 对所有可见单元，计算 $P(v_{1i}=1|h_0)=\sigma(a_i+\sum_{j=1}^m h_{0j}W_{ij})$ ，从条件分布 $P(v_{1i}|h_0)$ 中抽取 $v_1\sim P(v_1|h_0)$ ；

步骤 4 对所有隐单元计算 $P(h_{1j}=1|v_1)=\sigma(b_j+\sum_{i=1}^n v_{1i}W_{ij})$ ；

步骤 5 按下式更新各个参数：

$$W \leftarrow W + \rho(P(h_0=1|v_0)v_0^T - P(h_1=1|v_1)v_1^T)$$

$$a \leftarrow a + \rho(v_0 - v_1)$$

$$b \leftarrow b + \rho(P(h_0=1|v_0) - P(h_1=1|v_1))$$

步骤 6 重复步骤 2~步骤 5，直至达到最大迭代次数或重构误差足够小，结束该层 RBM 的训练。

4 工程实例分析

本文采用多个工程现场实测的变压器发生故障前后一段时间内的 1 500 组油色谱数据作为预训练集，另用 300 组变压器电气实验数据按 4:1 分别用作调优集和测试集。对于基于 DBNC 的变压器故障分类方法，笔者由实测数据作了如下测试。

(1) 故障分类情况与预训练集、网络 RBM 层数关系

测试中，笔者发现故障分类平均正确率与预训练集和网络 RBM 层数均有一定的关系，而且预训练集不同时，网络最优 RBM 层数也会发生相应变化。由实测数据经过大量实验，绘制出三者之间的关系图，如图 4 所示。

从图中可以看出，随着预训练集的增大，故障分类平均正确率达到最高时的最少 RBM 层数由开始时的 6 层增加到 8 层，层数逐渐增加。在预训练集一定的情况下，随着网络 RBM 层数的增加，故障分类平均正确率呈上升趋势，且趋势逐渐变缓。

(2) 不同预训练集时故障分类情况

分别测试了预训练集为 100、500、1 000 和 1 500

时故障分类情况, 如表 3 所示。从表中可以看出, 随着预训练集的增大, 变压器故障分类平均正确率不断升高。

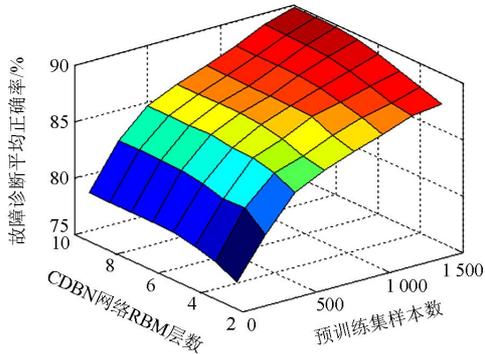


图 4 不同 RBM 层数、预训练集时变压器故障分类情况
Fig. 4 Transformer fault classification case on different RBM layers and pre-training sets

表 3 不同预训练集时变压器故障分类情况

Table 3 Transformer fault classification case on the different pre-training sets

序号	预训练集	调优集	测试集	正确率/%
1	100	240	60	78.35
2	500	240	60	84.67
3	1 000	240	60	87.72
4	1 500	240	60	89.86

对于基于 BPNN 和 SVM 的变压器故障分类方法, 采用标签样本进行训练, 笔者测试了不同训练集时故障分类情况, 如表 4 所示。

表 4 不同训练集时基于 BPNN、SVM 变压器故障分类情况

Table 4 Transformer fault classification case based on BPNN and SVM on the different training sets

方法	参数	训练集	测试集	正确率/%
BPNN	$Epochs = 1\ 500$ $lr = 0.01$	60	60	57.67
		120	60	62.33
		180	60	78.56
		240	60	79.34
SVM	$C = 2\ 048$ $\gamma = 0.03$	60	60	60.23
		120	60	76.78
		180	60	82.43
		240	60	83.21

表中, $epochs$ 和 lr 分别表示 BPNN 最大训练迭代次数和学习速率, C 和 γ 分别表示 SVM 正则化系数和核函数参数, 这些参数的初始值均由实测数据经大量实验确定。通过表 3 和表 4 的故障分类结果

对比可知, 本文提出的基于 DBNC 的变压器故障分类方法同基于 BPNN、SVM 的故障分类方法相比, 前者故障分类准确率更高。

5 结论

(1) 构建了深度信念网络分类器(DBNC)模型, 并对其分类性能进行了分析, Iris 数据集测试表明, 与 BPNN、SVM 相比, DBNC 分类平均正确率更高。

(2) 提出基于 DBNC 的变压器故障分类方法, 可以采用无标签样本对网络进行预训练, 克服了 BPNN、SVM 方法无法利用无标签样本训练的缺点, 提高了工程现场无标签样本的利用率。

(3) 工程实例分析表明, 基于 DBNC 的变压器故障分类方法随着预训练集增大, 故障分类平均正确率增高, 该方法适用于大量样本的训练, 可扩展性好, 与 BPNN、SVM 方法相比, 故障分类平均正确率更高, 可以更好地满足工程需要。

致 谢

本研究受到国家电网公司浙北~福州特高压输电工程专项研究经费资助, 特表感谢!

参考文献

- [1] TANG W H, WU Q H. Condition monitoring and assessment of power transformers using computational intelligence[M]. New York: Springer-Verlag Press, 2011.
- [2] 朱德恒, 严璋, 谈克雄, 等. 电气设备状态监测与故障诊断技术[M]. 北京: 中国电力出版社, 2009.
- [3] 鹿鸣明, 王逸飞, 郭创新, 等. 一种基于 PHM 考虑老化和设备状态的油浸式变压器故障率模型[J]. 电力系统保护与控制, 2014, 42(18): 66-71.
- [4] LU Mingming, WANG Yifei, GUO Chuangxin, et al. Failure rate model for oil-immersed transformer based on PHM concerning aging process and equipment inspection information[J]. Power System Protection and Control, 2014, 42(18): 66-71.
- [4] 尹金良, 朱永利, 郑晓雨, 等. 代价敏感 VBGP 在变压器故障诊断中的应用[J]. 电工技术学报, 2014, 29(3): 222-228.
- [5] YIN Jinliang, ZHU Yongli, ZHENG Xiaoyu, et al. Cost-sensitive gaussian process classification with variational Bayesian treatment for fault diagnosis of power transformers[J]. Transactions of China Electrotechnical Society, 2014, 29(3): 222-228.
- [5] 尹金良, 朱永利, 俞国勤, 等. 基于高斯过程分类器的变压器故障诊断[J]. 电工技术学报, 2013, 28(1): 158-164.

- YIN Jinliang, ZHU Yongli, YU Guoqin, et al. Fault diagnosis of transformers based on Gaussian process classifier[J]. Transactions of China Electrotechnical Society, 2013, 28(1): 158-164.
- [6] 王致杰, 徐余法, 刘三明, 等. 电力设备状态监测与故障诊断[M]. 上海: 上海交通大学出版社, 2012.
- [7] 程加堂, 艾莉, 段志梅. 改进证据理论与神经网络集成的变压器故障诊断[J]. 电力系统保护与控制, 2013, 41(14): 92-96.
- CHENG Jiatang, AI Li, DUAN Zhimei. Transformer fault diagnosis based on improved evidence theory and neural network integrated method[J]. Power System Protection and Control, 2013, 41(14): 92-96.
- [8] 公茂法, 张言攀, 柳岩妮, 等. 基于 BP 网络算法优化模糊 Petri 网的电力变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(3): 113-117.
- GONG Maofa, ZHANG Yanpan, LIU Yanni, et al. Fault diagnosis of power transformers based on back propagation algorithm evolving fuzzy Petri nets[J]. Power System Protection and Control, 2015, 43(3): 113-117.
- [9] 武中利, 杨建, 朱永利, 等. 基于粗糙集理论和支持向量机的变压器故障诊断[J]. 电力系统保护与控制, 2010, 38(18): 80-83.
- WU Zhongli, YANG Jian, ZHU Yongli, et al. Power transformer fault diagnosis based on rough set theory and support vector machines[J]. Power System Protection and Control, 2010, 38(18): 80-83.
- [10] 薛浩然, 张珂珩, 李斌, 等. 基于布谷鸟算法和支持向量机的变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(8): 8-13.
- XUE Haoran, ZHANG Keheng, LI Bin, et al. Fault diagnosis of transformer based on the cuckoo search and support vector machine[J]. Power System Protection and Control, 2015, 43(8): 8-13.
- [11] 遇炳杰, 朱永利. 加权极限学习机在变压器故障诊断中的应用[J]. 计算机工程与设计, 2013, 34(12): 4340-4344.
- YU Bingjie, ZHU Yongli. Transformer fault diagnosis using weighted extreme learning machine[J]. Computer Engineering and Design, 2013, 34(12): 4340-4344.
- [12] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [13] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Comp, 2006, 18(7): 1527-1554.
- [14] BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-127.
- [15] HINTON G E. A practical guide to training restricted Boltzmann machines[R]. Toronto, Canada: University of Toronto, 2010.
- [16] 余凯, 贾磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.
- YU Kai, JIA Lei, CHEN Yuqiang, et al. Deep learning: yesterday, today, and tomorrow[J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804.
- [17] 吕启, 窦勇, 牛新, 等. 基于DBN模型的遥感图像分类[J]. 计算机研究与发展, 2014, 51(9): 1911-1918.
- LÜ Qi, DOU Yong, NIU Xin, et al. Remote sensing image classification based on DBN model[J]. Journal of Computer Research and Development, 2014, 51(9): 1911-1918.
- [18] 马勇, 鲍长春, 夏丙寅. 基于判别性深度信念网络的说话人分割[J]. 清华大学学报(自然科学版), 2013, 53(6): 804-807.
- MA Yong, BAO Changchun, XIA Bingyin. Speaker segmentation based on discriminative deep belief networks[J]. Journal of Tsinghua University (Science and Technology), 2013, 53(6): 804-807.

收稿日期: 2015-03-22

作者简介:

石鑫(1988-), 男, 通信作者, 硕士研究生, 主要研究方向为人工智能在电力系统中的应用; E-mail: ncepshixin@163.com

朱永利(1963-), 男, 教授, 博士生导师, 主要研究方向为网络化监控与智能信息处理;

萨初日拉(1992-), 男, 硕士研究生, 研究方向为云计算在电力系统中的应用。

(编辑 周金梅)