

隐式半马尔科夫模型下的变压器故障诊断方法

李刚¹, 米琛浩¹, 郑顾平¹, 夏彦卫²

(1. 华北电力大学 计算机系, 河北 保定 071003;

2. 国网河北省电力公司 电力科学研究院, 石家庄 050021)

摘要: 变压器运行过程中存在多种状态, 能够正确划分运行状态, 对变压器的维修和故障诊断有着重要的意义; 首先, 详细分析了马尔科夫链的衍生模型, 并构造了隐式半马尔科夫模型 (hidden semi-markov models, HSMM); 然后, 通过引入“微状态-宏状态”的对应关系, 用于在 HSMM 中描述变压器运行过程中的状态; 最后, 建立了涵盖变压器历史状态信息, 并包含特征提取、状态分类和故障识别过程的 HSMM 故障诊断流程; 通过变压器 DGA 故障诊断的算例分析, 结果表明所述方法的有效性。

关键词: 隐马尔科夫; 故障诊断; DGA; 微状态-宏状态

Transformer Fault Diagnosis Method Based on Hidden Semi-Markov Model

Li Gang¹, Mi Chenhao¹, Zheng Guping¹, Xia Yanwei²

(1. Department of Computer, North China Electric Power University, Baoding 071003, China;

2. State Grid Hebei Electric Power Research Institute, Shijiazhuang 050021, China)

Abstract: There are many states in the operation of the transformer, which can correctly divide the operating state, which is of great significance for the maintenance and fault diagnosis of the transformer. Firstly, the derivative models of Markov chain are analyzed in detail and Hidden Semi-Markov Models (HSMM) are constructed. And then, the state of the transformer operation process is described in HSMM by introducing the correspondence of "micro-state & macro-state". Finally, the HSMM fault diagnosis process covering the historical state of the transformer and including feature extraction, state classification and fault identification process is established. Through the analysis of the transformer DGA fault diagnosis, the results show the effectiveness of the proposed method.

Keywords: hidden Markov; fault diagnosis; DGA; micro-state & macro-state

0 引言

在电力系统中, 变压器运行状态的变化将直接对电力系统的状态产生影响。因此, 对电力变压器的健康状态进行预测, 保障送变电安全, 对提高电力系统的可靠性、促进电力设备基于状态的维修 (condition based maintenance, CBM) 具有重要意义。为保障变压器的正常和安全运行, 对其健康状态的监控与故障预测技术越来越受到变压器运维人员和研究学者们的重视^[1]。在实际应用中, 变压器在故障产生前, 通常会经历一系列的退化状态, 当积累到一定程度时, 会最终导致变压器故障^[1]。如何正确的划分和识别变压器从正常状态到故障状态之间的状态序列, 是故障诊断研究中非常关键的一步, 也是能够得到较高诊断可靠度的前提条件之一^[2-3]。

近年来, 已有大量针对电力变压器状态评估与故障诊断的研究成果报道^[4-6], 但由于变压器是一类内部结构复杂、运行工况与外在环境多变的设备, 因此, 寻找一种有效的方法对其故障演化规律进行清晰的刻画较为困难。例如, 有研究者开始把 HMM 模型引入到基于状态的设备维修和故障诊断领域中来, 取得了良好的效果^[7-9]。HMM 在设备状态识别领域的应用是对设备历经的多个健康状态分别建立并训练对应的 HMM, 实现对状态的划分。文献 [10] 将 HMM 应用于机械设备故障诊断领域, 通过对振动信号的学习, 实现了基于状态的维修。文献 [11] 将 HMM 应用到发电机转子的状态识别中, 描述了设备运行状态的变化。文献 [12] 对旋转机械的变速过程进行 HMM 建模, 在建模过程中采用了多个观测变量进行分析, 得到了较好的诊断结果。但这些研究只使用了标准 HMM 技术, 因为 HMM 的状态持续时间遵循指数分布, 所以模型对时间结构的描述不够精确, 建模过程中未考虑设备的历史状态信息, 为充分利用马尔科夫过程的特点, 需要对 HMM 模型中对历史状态不敏感的缺点进行改进。

隐式半马尔科夫模型 (hidden semi-markov models, HSMM) 将历史状态信息纳入计算过程, 能够克服 HMM 对历史状态信息不敏感的局限性^[13]。本文尝试在变压器故障诊断中, 对 HSMM 模型引入“微状态-宏状态”的对应关系来描述变压器健康状态的转移。最后使用变压器 DGA

收稿日期: 2018-10-23; 修回日期: 2018-11-30。

基金项目: 国家电网公司科技项目资助 (5204DY170010); 国家自然科学基金资助 (51407076); 中央高校基本科研业务费专项资金资助 (2018MS075)。

作者简介: 李刚 (1980-), 男, 河北枣强人, 博士, 副教授, 主要从事智能电网与大数据、信息物理能源系统、故障预测与健康研究方向的研究。

郑顾平 (1960-), 男, 河北保定人, 教授, 博士, 主要从事智能电网与大数据方向的研究。

故障数据对 HSMM 模型进行训练, 并通过实验来验证模型的可靠性及准确性。

1 HMM 基本理论

1.1 基本理论

一个 HMM 模型可用下列参数描述^[9]:

(1) N 为模型中 Markov 链的状态数目。记 N 状态为: s_1, s_2, \dots, s_N , 记 t 时刻 Markov 链所处的状态为 q_t , 显然 $q_t \in (s_1, s_2, \dots, s_N)$ 。

(2) M 为一个隐状态产生的观测值种类数量。记 M 个观测值为 o_1, o_2, \dots, o_M , 记 t 时刻的观测值为 o_t , 其中, $o_t \in (o_1, o_2, \dots, o_M)$ 。

(3) π 为初始概率分布矢量, $\pi = (\pi_1, \pi_2, \dots, \pi_N)$ 。 π_N 初始时刻时, 模型处在该状态的概率。其中:

$$\pi_i = P(q_t = s_i), 1 \leq i \leq N \quad (1)$$

(4) A 为状态转移矩阵, $A = \{a_{ij}\}_{N \times N}$ 。其中:

$$a_{ij} = P(q_{t+1} = s_j | q_t = s_i), 1 \leq i, j \leq N \quad (2)$$

(5) B 为观测值概率矩阵, $B = \{b_{jk}\}_{N \times M}$ 。其中:

$$b_{jk} = P(o_t = v_k | q_t = s_j), 1 \leq j \leq N, 1 \leq k \leq M \quad (3)$$

这样可以记 HMM 为 $\lambda = (N, M, \pi, A, B)$, 因为在模型中, 各个参数之间又具有一定的关联, N 和 M 确定之后才能计算 A 和 B , 所以 HMM 可简写为 $\lambda = (\pi, A, B)$ 。

HMM 在实际应用中的 3 个相关基本问题及算法描述如下^[11]:

(1) 评估问题 (“前向—后向” 算法): 在给定的观察序列 $o = o_1, o_2, \dots, o_M$ 和参数组为 $\lambda = (\pi, A, B)$ 的 HMM 中, 该观察序列出现的概率是多少?

(2) 解码问题 (Viterbi 算法): 在给定的观察序列 $o = o_1, o_2, \dots, o_M$ 和参数组为 $\lambda = (\pi, A, B)$ 的 HMM 中, 隐藏状态序列 $s = s_1, s_2, \dots, s_N$ 生成所给出的观察序列的概率是多少?

(3) 学习问题 (Baum—Welch 算法): 观察序列确定的情况下, 如何设定 HMM 中的参数, 如: 初始概率分布 (π)、状态转移矩阵 (A) 等, 才能够使得 HMM 输出该观测序列的概率最大?

HMM 是一个双重随机过程, 它可以在概率统计学的基础上解答上述 3 个问题。HMM 的参数 $\lambda = (\pi, A, B)$ 可以由 Baum—Welch 算法从观测到的 DGA 数据中估计出来, 由估算出的 HMM 组成分类器, 可以实现对观测序列的分类。具体流程如图 1 所示。

1.2 HMM 初始模型选取

在使用 HMM 对变压器运行状态进行建模时, 将初始模型的隐状态数量设定为 4, 并采用均匀选取的办法对模型的观测值概率矩阵选取进行确定。HMM 的初始形态如图 2 所示。模型中变量之间的依赖关系用箭头来表示, 箭头上的数字表示此次状态转移的概率, 由圆圈中的数字表示 HMM 模型中不同的隐状态。根据 HMM 模型的基本理论可知, 每个隐状态都可能产生多个观测值, 图 2 中的 o_1, o_2, \dots, o_T 都表示为离散的观测值序列。

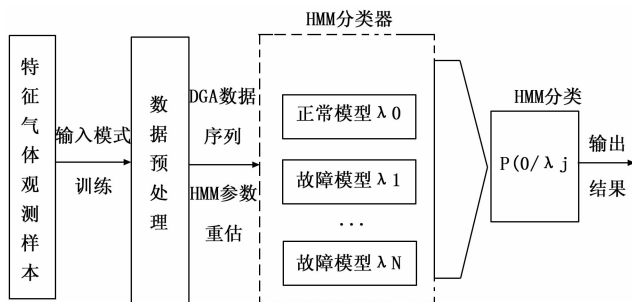


图 1 HMM 故障诊断流程图




图 2 HMM 变压器故障模型

当建立了 HMM 的初始模型后, 就可以采用 Baum—Welch 算法进行计算, 为变压器的每个故障类型训练出相应的 HMM, 从而建立起面向变压器的 HMM 分类器。

2 对 HMM 的适用性改进

2.1 HMM 的局限性分析

在 HMM 研究和应用领域的相关内容中可以归纳出其模型的局限性, 主要表现为以下几点^[14]:

(1) HMM 状态驻留概率遵循指数分布。即系统在状态 i 持续时间为 d 的概率为:

$$p_i(d) = a_i^{d-1}(1 - a_i) \quad (4)$$

式中, a_i 表示系统驻留在状态 i 的概率。根据公式 (4) 的表示, 随着驻留时间 d 的增加, $P_i(d)$ 呈指数下滑, 这也与实际情况不符合。

(2) HMM 假设模型中各观测变量之间互不影响, 即观测序列产生仅与当前所处的状态有关:

$$P(o_1, o_2, \dots, o_t | s_1, s_2, \dots, s_t) = P(o_t | q_t) \quad (5)$$

o_1 是由 s_1 生成的, o_2 是由 s_2 生成的, 但是 s_2 的形成受 s_1 影响, 所以 o_1 和 o_2 也一定有联系。但是为了研究和应用方便, 就假设 s_1 和 s_2 不独立, 但 o_1 和 o_2 独立。在实际的变压器 DGA 运行过程中, 各个状态之间能够相互转化, 所以这个假设与实际情况不符。

(3) HMM 模型中, 马尔可夫过程具有齐次性, 表现在变压器的状态转移中即为——状态转移矩阵确定后, 不会随变压器状态的变化而变化。在实际情况中, 随着变压器运行状态的不断改变, 其各个状态之间的转移概率肯定会不断变化。

2.2 改进思路

针对上述局限性, 目前的改进方法就是根据应用场景

的不同,适当放宽 HMM 模型的假设条件,主要思路如下:

(1) 在传统的 HMM 结构上加入时间要素,使状态转移矩阵能够根据历史状态信息进行改变,打破马尔科夫过程的齐次性。

(2) 在 HMM 模型各个状态转移概率的计算过程中,加入历史状态的变化量,来描述各个状态之间的跳转信息。该方法具有较强的适应性,但是每次状态转移过程的计算与建模较为复杂。文献 [15] 表明,在基于 HMM 的手写字体识别系统中,因为手写字母的分割处理程序本身具有极强的不确定性,所以使用结合历史状态的模型来实现手写字体的识别是切实可行的。

(3) 针对 HMM 的观测序列输出仅与当前状态有关的假设,可将观测序列之间的依赖性加入建模过程中。自回归隐马尔可夫模 (Auto-Regressive Hidden Markov Model, ARHMM) 通过 AR 模型计算的观测值概率矩阵 $B = \{b_{jk}\}_{N \times M}$, 其中, $b_{jk} = P(s_t = s_j | o_t = o_j)$, 反映了状态 s_t 和观测序列 o_t 之间的统计对应关系:

$$b_{jk} = P(s_j | o_t = o_j) = N(s_j | \sum a_k(i) o_{t-i} | \sum k) \quad (6)$$

式中, $N(\cdot)$ 表示高斯函数, $\sum k$ 表示高斯分布的估计方差,通过统计学将状态与观测序列之间建立关系,实现了观测序列之间的依赖性。文献 [16] 通过 ARHMM 对工业控制过程的数据进行异常检测,提升了检测精度和抗干扰能力。

3 基于 HSMM 的变压器健康预测方法

3.1 HSMM 的构造

目前基于 HSMM 故障诊断的应用对象主要以旋转机械居多,通过对其工作过程中的振动信号进行建模分析,实现对其健康状态的划分,旋转机械振动信息采集的连续性较强^[17]。但是变压器的故障数据,如 DGA 数据的采集通常为间隔操作,变压器健康状态的持续时间也远较机械设备等更长久,具有宏观上的离散性。因此,本文结合变压器 DGA 数据采集特点及状态演变规律,引入“微状态-宏状态”的对应关系来描述变压器的运行过程,将变压器历史状态信息纳入建模过程中,以提升模型准确率。

变压器的运行状态分为正常状态和故障状态,故障类型分为放电性故障和过热性故障,其中放电性故障分为:低能放电、高能放电;过热性故障分为:中低温过热(温度 $\leq 700\text{ }^\circ\text{C}$)、高温过热(温度 $\geq 700\text{ }^\circ\text{C}$)^[18]。其中两种故障特性都包含的有:低能放电兼过热和高能放电兼过热。本文所采用的 HSMM 是在传统 HMM 结构上加入了时间要素,为变压器故障诊断提供更好的建模和数据分析能力,具体如下:

针对变压器的各个健康状态,使用各类 DGA 故障数据对 HSMM 进行训练,与 HMM 不同的是,HSMM 中的“宏状态”对应变压器的各个健康状态。

HSMM 与传统 HMM 的不同还体现在状态与观测值的产生方式上,传统 HMM 的一个状态仅产生单个观测值,但 HSMM 的一个状态会产生一个由多次观测值组成的观测

值片段。本文将 HSMM 中隐状态一次产生的观测值被称为“微状态”,由连续多次的观测值组成的片段称为“宏状态”。其对应关系如图 3 所示。在 HSMM 中 s 表示变压器的隐状态, o 表示由采集的 DGA 数据处理得来的观测序列。




图 3 HSMM 模型示意图

如图 3 所示,值为 $o_{q_1-1}, \dots, o_{q_1}$ 的观测序列,对应的微状态为 $s_{q_1-1}, \dots, s_{q_1}$, 这个微状态序列对应 HSMM 模型中相同的宏状态即 h_1 。

HSMM 可表示为 $\lambda = (\pi, \mathbf{A}, \mathbf{D}, \mathbf{B})$, 其中, π 表示初始状态分布, \mathbf{A} 表示状态转移矩阵, \mathbf{D} 表示状态持续时间分布, \mathbf{B} 表示观测值概率矩阵。在 HSMM 模型中具有多个微状态,这些微状态的转换不具有马尔科夫性,而模型中宏状态之间的转换是符合马尔科夫过程的,状态转移矩阵 (\mathbf{A}) 用来描述这些隐状态之间的转换:

$$P(h_{q_t} = j | h_{q_{t-1}} = i) = a_{ij} \quad (7)$$

3.2 基于 HSMM 的变压器故障诊断流程

为了能够使 HSMM 模型识别出变压器在运行过程中不同的状态,所以在训练模型时采用各种变压器 DGA 故障数据,为所有变压器的正常状态和每个故障类型各训练一个单独的 HSMM 模型,从而建立起变压器故障的 HSMM 分类器。如图 4 所示。




图 4 HSMM 故障诊断示意图

基于 HSMM 的变压器故障诊断流程,由特征提取、状态分类和故障识别 3 个部分组成。其中,状态分类是该流程中的关键步骤,其 HSMM 的计算过程如下:根据观测序列利用“前向-后向”算法求解最优模型 λ ,采用 Baum-Welch 算法训练模型,得到输出该观测序列概率值最大的模型参数。在模型中每个变压器的运行状态都对应一个训练好的 HSMM,将观测序列依次代入每个 HSMM 模型中进行计算,得到该观测序列的 $P(o | \lambda)$,即为发生该故障的概率。

4 算例分析

在电力变压器的诊断分析环节中, DGA 分析技术的数据采集方便, 分析结果也较为准确, 所以近年来的变压器健康管理和 DGA 技术紧密结合^[19]。在运行过程中如果变压器发生过热或放电性故障时, 会使得内部固体绝缘材料和绝缘油如绝缘纸板、电缆纸等加速发生分解, 产出气体。主要气体有氢气 (H₂)、烃类气体如: 甲烷 (CH₄)、乙烷 (C₂H₆)、乙烯 (C₂H₄)、乙炔 (C₂H₂)、一氧化碳 (CO)、二氧化碳 (CO₂) 等。在这 7 种气体中, 因为变压器内部受到空气中二氧化碳渗入的影响较大, 故其不能够灵敏的反应运行状态变化, 所以一般不将二氧化碳 (CO₂) 作为判断故障的特征变量。当变压器运行状态发生改变时, 一氧化碳 (CO) 在绝缘油中的溶解浓度要远大于其他特征气体, 在 HSMM 建模过程中容易掩盖其他油中溶解气体对于模型计算的影响。为了简化问题, 同时结合实际情况, 将用于 HSMM 建模的特征变量定为 5 个, 即氢气 (H₂)、甲烷 (CH₄)、乙烷 (C₂H₆)、乙烯 (C₂H₄)、且只考虑样本之间的关系。由此可得到特征气体的矢量表达式:

$$X = [H_2, CH_4, C_2H_6, C_2H_4, C_2H_2] \quad (8)$$

先对 DGA 数据进行归一化, 使数据限制于 [0, 1] 之间。由于 H₂、CH₄、C₂H₆、C₂H₄、C₂H₂ 这几种特征气体都是可燃性气体, 通常将这些 DGA 特征气体含量总和称为可燃气体总量 (TCG)。通过将这 5 种特征气体变量与 TCG 的比值实现 DGA 数据的归一化处理, 即以 H₂/TCG、CH₄/TCG、C₂H₆/TCG、C₂H₄/TCG、C₂H₂/TCG 作为归一化的 DGA 数据, 从而将 DGA 数据限制在 0 到 1 之间。

当发生放电性故障时, 若 CH₄/H₂ > 1, 则同时伴随有过热性故障的发生, 即此时变压器的运行状态出现放电兼过热性故障; 当 CH₄/H₂ ≤ 1 时, 一般认为是纯放电性故障。当训练 HSMM 变压器故障模型时, 我们将放电性故障和放电兼过热性故障合为一种故障类型, 即将变压器的运行状态由 7 类合并为 5 类: 正常、中低温过热 (温度 ≤ 700℃)、高温过热 (温度 ≥ 700℃)、低能放电, 高能放电。合并运行状态, 可以提升 HSMM 的训练速度和正确率。例如, 若输入的特征气体观测矢量为 $x = [85.9, 66.0, 15.3, 25.7, 6.3]$, 则 HSMM 模型各状态的识别结果输出如表 1 所示, 其发生高能放电故障的概率是 98.45%。

表 1 HSMM 输出

输出	正常	中低温过热	高温过热	低能放电	高能放电
对数似然值	-Inf	-22.6	-124.0	-15.9	-14.0
故障可能性 (%)	0	0	0	1.55	98.45

表 1 中的对数似然值就是由 HSMM 对观测矢量 X 进行分类得到的对每个状态的 log P (o | λ), 其中 Inf 表示无穷大, HSMM 输出的对数似然值越大, 则表示此故障的发生概率就越大。

我们从相关文献和资料收集到的样本中选出变压器运

行过程中每个状态各 15 组数据, 这 75 组数据未在模型中参与训练过程, 作为 HSMM 的输入矢量进行分类测试。在本算例实验中, 因为变压器运行状态共有 5 种, 所以设定 HSMM 模型中隐藏状态数目为 5; 因为初始值的选取对于训练结果的影响不大^[19], 所以对于 HSMM 的初始模型 π, 我们采用均匀选取。设置训练过程中的收敛值 0.0001, 最大迭代次数为 100。在一开始的训练过程中, 随着迭代次数的增加, 各个状态输出的对数似然值也逐渐加大, 即状态识别的正确率也在逐步提高。各个状态输出的对数似然值曲线在 10 次后趋于平稳, 总体训练过程的迭代次数都在 15 次之内, 训练过程如图 5 所示。




图 5 5 种状态 HSMM 的训练曲线

当各种故障类型的 HSMM 建立以后, 就可以使用图 4 所示的方法进行故障识别。为了能够直观的了解 HSMM 变压器诊断方法的效果, 把这 75 组数据用传统 HMM 方法进行诊断, 和本文所述的诊断方法进行比较。从本次实验的结果可以看出, 相较于传统 HMM 方法, HSMM 方法正确率更高。HSMM 对于每个故障类型的划分都要比 HMM 准确。测试结果如表 2 所示。

表 2 暂态运动各自由度稳态误差

故障类型	样本数量	HMM			HSMM		
		识别正确	识别错误	正确率	识别正确	识别错误	正确率
正常	15	14	1	93.3%	14	1	93.3%
中低温过热	15	13	2	86.7%	14	1	93.3%
高温过热	15	12	3	80.0%	13	2	86.7%
低能放电	15	14	1	93.3%	14	1	93.3%
高能放电	15	13	2	86.7%	14	1	93.3%
总计	75	66	9	88.0%	69	6	92.0%

5 结束语

本文针对传统 HMM 在电力设备故障诊断中的局限性, 通过引入“微状态-宏状态”, 考虑变压器运行过程中的历史状态对于状态转移的影响, 给出了一种基于 HSMM 的变压器故障诊断流程, 并采用 DGA 数据进行了算例分析, 结果验证了模型的有效性, 也更加符合变压器实际运行状态。

参考文献:

[1] 李 刚, 于长海, 刘云鹏, 等. 电力变压器故障预测与健康管理: 挑战与展望 [J]. 电力系统自动化, 2017, 41 (23): 156

- 167.

[2] 汪可, 李金忠, 张书琦, 等. 变压器故障诊断用油中溶解气体新特征参量 [J]. 中国电机工程学报, 2016, 36 (23): 6570 - 6578.

[3] 李刚, 张博, 赵文清, 等. 电力设备状态评估中的数据科学问题: 挑战与展望 [J]. 电力系统自动化, 2018, 42 (21): 10 - 20.

[4] 叶彦斐, 郑源, 张勇气, 等. 基于改进证据推理规则的变压器故障诊断 [J]. 计算机测量与控制, 2014, 22 (12): 3894 - 3896.

[5] 刘春鹏, 姚毅, 贾金玲, 等. 两种前向神经网络在变压器故障诊断中的应用 [J]. 计算机测量与控制, 2016, 24 (2): 34 - 37.

[6] 谢荣斌, 张霖, 鄢小虎, 等. 模拟退火优化 SVM 参数的变压器故障诊断 [J]. 计算机测量与控制, 2015, 23 (5): 1495 - 1498.

[7] 李燕斌, 张久菊, 肖俊明, 等. 灰色-马尔可夫链统计组合模型在光伏发电功率短期预测中的应用 [J]. 电测与仪表, 2015, 52 (23): 111 - 116.

[8] P. Baruah, R. B. Chinnam. HMMs for diagnostics and prognostics in machining processes [J]. International Journal of Production Research, 2005, 43 (6): 1275 - 1293.

[9] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition [J]. Proceedings of the IEEE, 1989, 77: 257 - 286.

[10] Bunks C, Dan M, Al - Ani T. Condition - based maintenance of machines using hidden Markov models [J]. Mechanical Systems & Signal Processing, 2000, 14 (4): 597 - 612.

[11] Lee J M, Kim S J, Hwang Y, et al. Diagnosis of mechanical

fault signals using continuous hidden Markov model [J]. Journal of Sound & Vibration, 2004, 276 (3-5): 1065 - 1080.

[12] 冯长建, 丁启全, 吴昭同. 混合 SOM 和 HMM 方法在旋转机械升速全过程故障诊断中的应用 [J]. 中国机械工程, 2002, 13 (20): 1711 - 1714.

[13] Yu S Z. Hidden semi - Markov models [J]. Artificial Intelligence, 2010, 174 (2): 215 - 243.

[14] Camci F, Chinnam R B. Dynamic Bayesian networks for machine diagnostics: hierarchical hidden Markov models vs. competitive learning [A]. IEEE International Joint Conference on Neural Networks, 2005. Proceedings of IEEE [C]. 2005 (3): 1752 - 1757.

[15] Chen M Y, Kundu A, Srihari S N. Variable duration hidden Markov model and morphological segmentation for handwritten word recognition. [J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 1995, 4 (12): 1675.

[16] 刘芳, 毛志忠. 应用阶数自学习自回归隐马尔可夫模型对控制过程异常数据的在线检测 [J]. 控制理论与应用, 2011, 28 (5): 631 - 638.

[17] 曾庆虎, 邱静, 刘冠军. 基于隐半马尔可夫模型设备退化状态识别方法研究 [J]. 机械科学与技术, 2008, 27 (4): 429 - 432.

[18] 徐康健, 汪卫国. GB/T7252 - 2001《变压器油中溶解气体分析和判断导则》中一问题的探讨 [J]. 中国电力, 2009 (2): 62 - 63.

[19] 李志斌, 李启本. 基于信息融合技术的变压器多层次故障诊断 [J]. 电测与仪表, 2014, 51 (16): 37 - 40.

(上接第 29 页)

测效率最高都没有超过 80%，而 DBN 系统检测效率最低也超过 85%，由此对比结果可知，采用基于深度信念网络的脑电信号疲劳检测系统设计是具有合理性的。

5 结束语

5.1 研究成果

结合深度信念网络设计脑电信号疲劳检测系统是一种全新思路，该网络具备高维特征向量，具有较强特征学习能力。通过深度信念网络能够从脑电信号中提取相关特征数据，并正确分类，经过对不同被试进行测试分析可知，采用该网络设计的系统检测效果优于基于支持向量机检测系统 (SVM)、面部特征检测系统 (Ff) 和基于特征数据检测系统 (Fd)，且最高检测效率可达到 0.995，具有良好检测效果。

5.2 未来展望

虽然使用深度信念网络能够得到良好检测效率，但是只是对小范围内的运动脑电信号进行疲劳检测，对于未来工作可从如下几个方面进行：利用电子设备采集更多样本数据，结合深度信念网络检测复杂脑电信号，不断优化结构参数，有效提高脑电信号疲劳检测能力。

参考文献:

[1] 杨豪, 张俊然, 蒋小梅, 等. 基于深度信念网络脑电信号表征情绪状态的识别研究 [J]. 生物医学工程学杂志, 2018 (2): 182 - 190.

[2] 陈骥驰, 王宏, 王翘秀, 等. 基于脑电信号的疲劳驾驶状态研究 [J]. 汽车工程, 2018, 40 (5): 515 - 520.

[3] 韩霜, 吴奇, 孙礼兵, 等. 基于深度收缩自编码网络的飞行员疲劳状态识别 [J]. 生物医学工程学杂志, 2018, 22 (3): 13 - 29.

[4] 胡剑锋, 王涛涛. 基于脑电信号模糊熵的驾驶疲劳检测分析 [J]. 中国安全科学学报, 2018, 32 (4): 15 - 21.

[5] 张丞, 何坚, 张岩, 等. 基于脑电与眨眼频率的可穿戴疲劳驾驶检测系统 [J]. 计算机工程, 2017, 43 (2): 293 - 298.

[6] 李明爱, 张梦, 孙炎珺. 基于小波包和深度信念网络的脑电特征提取方法 [J]. 电子测量与仪器学报, 2018, 15 (1): 18 - 49.

[7] 王宏鹏, 艾力 & #; 斯木吐拉. 高原公路低氧路段驾驶疲劳脑电信号检测分析 [J]. 中国安全科学学报, 2016, 26 (7): 7 - 11.

[8] 裴玉龙, 金英群, 陈贺飞. 基于脑电信号分析的不同年龄驾驶人疲劳特性 [J]. 中国公路学报, 2018, 31 (4): 13 - 18.

[9] 蔡羽, 徐朝阳. 疲劳驾驶检测模块设计及仿真验证 [J]. 电子设计工程, 2018, 26 (1): 183 - 188.