

DOI:10.12158/j.2096-3203.2020.06.024

基于HMM的无线充电系统PFC装置故障检测

吴争, 李瑶虹, 杨晓梅, 崔恒志, 费益军

(国网江苏省电力有限公司, 江苏 南京 210024)

摘要:功率因数校正(PFC)装置作为电动汽车无线充电系统中整流模块与高频逆变模块之间的重要桥梁,一旦发生故障,不仅会对电网产生严重影响,还会对后端高频逆变模块造成不可逆的破坏,因此需要对其进行快速和准确的故障检测。传统故障检测方法检测时间长,检测精度低。为此,文中提出一种基于隐马尔可夫模型(HMM)的电动汽车无线充电系统PFC装置故障检测方法。首先初始化模型,然后利用鲍姆韦尔奇(Baum-Welch)算法进行故障模型训练,最后利用维特比(Viterbi)算法进行故障检测。仿真实验结果表明,采用HMM进行PFC装置故障检测的正确率较神经网络和支持向量机(SVM)最大提高了约40%,是一种快速且准确的方法,因此文中采用HMM能够有效识别出电动汽车无线充电系统中PFC装置故障的类型。

关键词:电动汽车;无线充电系统;功率因数校正(PFC);隐马尔可夫模型(HMM);故障检测

中图分类号:TM46

文献标志码:A

文章编号:2096-3203(2020)06-0166-06

0 引言

为了节约能源、减少环境污染,国家重点强调新能源技术的发展,电动汽车^[1-2]受到了全世界各国的关注与推广,其中节能和减排是新能源电动汽车的主要研究方向。传统的电动汽车充电方式主要是靠电缆进行接触式充电,这种有线供电方式存在设备移动灵活性差、环境不美观、容易产生接触火花等问题,无线充电技术的出现有效克服了传统有线供电方式的一系列缺点^[3]。

电动汽车无线充电系统的发射端通常与电网相连接,市电经过整流模块和高频逆变模块后到达发射线圈,通常在整流模块和高频逆变模块之间增加功率因数校正(power factor correction, PFC)装置。PFC装置在电动汽车无线充电系统中担负着承上启下的作用,其出现故障时,会对后端高频逆变电路造成不可逆的破坏。因此,亟需一种快速、准确的PFC故障诊断方法使其出现故障时对电动汽车无线充电系统的损害降到最低。电力电子装置的电路出现故障后,应及时展开检测分析,有效完成故障排查和检修^[4-5]。国内外有很多电力电子装置的故障诊断相关研究成果,McArthur采用多媒体技术对开关电源进行自主故障诊断^[6];汤李华将专家系统引入到雷达电源诊断^[7]。文中拟对电动汽车无线充电系统中PFC装置进行诊断,可以运用的故障诊断方法有:(1)故障树诊断法^[8],虽然比较直

观,但是故障建模过程复杂,在故障状态数量很多的情况下,工作量太大;(2)神经网络^[9],结合了自学习的优点,但是建模速度依旧很慢;(3)基于专家经验^[10],充分利用了某个领域专家的经验,但局限性太大,精度低。特别的马尔可夫理论中的隐马尔可夫模型(hidden Markov model, HMM)是一种统计理论的模型^[11-14],在语音识别领域已经取得了重大的成果^[15],近年,在故障诊断领域也体现出其优越的一面。文献[16]将HMM应用于电力系统的故障检测;文献[17-19]在电机故障诊断中运用HMM。

文中就一种磁耦合式LCC-S型无线电能传输系统中的PFC模块展开典型性研究,为今后其他模块的故障检测奠定基础。选用升压斩波电路作为电动汽车无线充电系统中PFC的拓扑,将HMM引入到PFC装置的故障诊断中,在故障模型训练阶段采用鲍姆韦尔奇(Baum-Welch)算法,最后采用维特比(Viterbi)算法进行故障检测。

1 故障类型分类

在进行电动汽车无线充电系统PFC故障诊断之前,需要对PFC装置可能出现的故障情况进行总结和分类。文中选择升压斩波电路作为PFC的基本拓扑,图1为LCC-S型电动汽车无线充电系统基本拓扑,PFC模块内部元件的失效原因主要分为以下2类:(1)化学方面,如腐蚀;(2)机械方面,如机械疲劳。在PFC装置中最容易发生故障的元件是电容和功率器件,因此文中主要分析电容与功率器件的老化和失效。对PFC可能发生的故障进行编号,如表1所示,其中,C为电容;D为二极管;MOSFET为金氧半场效晶体管。

收稿日期:2020-06-12;修回日期:2020-07-23

基金项目:国家电网有限公司科技项目“电动汽车充放电故障智能诊断与安全预警关键技术及运维服务体系研究”

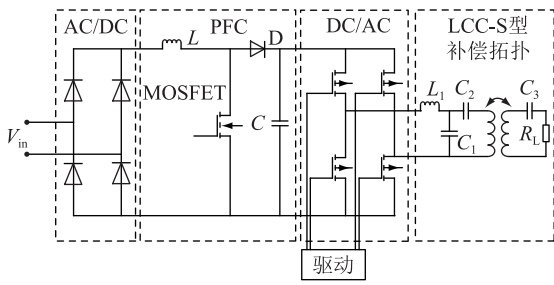


图 1 LCC-S 型电动汽车无线充电系统基本拓扑

Fig.1 Basic topology of LCC-S type EV wireless charging system

表 1 故障状态编号

Table 1 Fault status number

编号	故障状态	编号	故障状态
1	C 老化	6	C 老化, MOSFET 失效
2	C 失效	7	C 失效, MOSFET 老化
3	MOSFET 老化	8	C 失效, MOSFET 失效
4	MOSFET 失效	9	C, MOSFET 完好, D 老化
5	C 老化, MOSFET 老化	10	C, MOSFET 完好, D 失效

2 HMM

HMM 是一种统计学的模型, 可用来描述一个有未知参数的马尔可夫过程。自 20 世纪 80 年代以来, HMM 已被广泛应用于语音识别领域, 并取得了很大成就。一个 HMM 中含有 5 个基本元素, 这 5 个基本元素组成一个序列 $\{N, M, \pi, A, B\}$, 其中:

(1) N 为模型中隐藏状态的数目。将 N 个隐藏状态表示为 $\theta_1, \theta_2, \dots, \theta_N$, 同时将 t 时刻的状态定义为 q_t , $q_t \in (\theta_1, \theta_2, \dots, \theta_N)$ 。

(2) M 为模型中可观测状态的数目。将 M 个可观测状态定义为 v_1, v_2, \dots, v_M , 那么某个时刻的可观测状态为 O_t , $O_t \in (v_1, v_2, \dots, v_M)$ 。

(3) π 为模型中初始状态概率分布, 将其表示为 $\pi = (\pi_1, \pi_2, \dots, \pi_N)$, 其中 $\pi_i = P(q_t = \theta_i)$, $1 \leq i \leq N$ 。

(4) A 为隐藏状态的转移概率矩阵, $A = \{a_{ij}\}$, 并且 $a_{ij} = P(q_{t+1} = \theta_j, q_t = \theta_i)$, $1 \leq i \leq N, 1 \leq j \leq N$ 。

(5) B 为可观测的状态概率矩阵, $B = \{b_j(k)\}$, 其中 $b_j(k) = P(o_t = v_k, q_t = \theta_j)$ 。

HMM 可以简写为 $\lambda = (\pi, A, B)$ 。

3 运用 HMM 进行 PFC 故障诊断

3.1 方法总述

运用 HMM 进行电动汽车无线电能传输系统中 PFC 装置故障诊断的流程如图 2 所示, 主要分为模

型训练和故障检测 2 个模块。

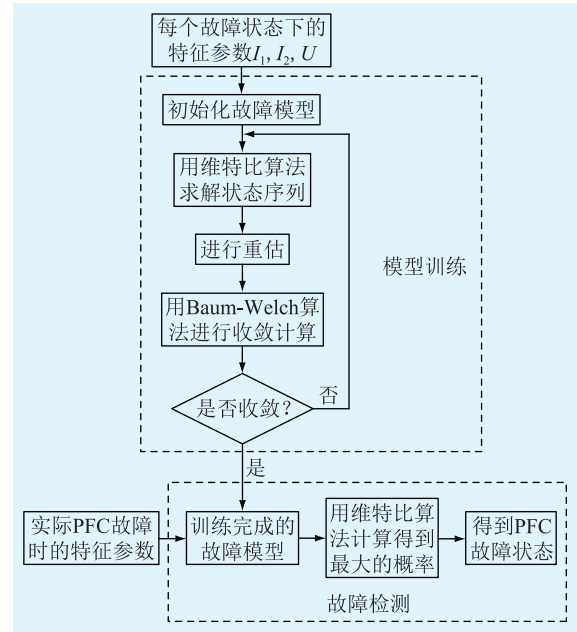


图 2 运用 HMM 进行 PFC 故障诊断的流程

Fig.2 Process of PFC fault diagnosis using HMM

3.2 模型训练

首先, 每一种故障需要训练出其对应的故障模型:

(1) 采集 PFC 装置每个故障状态下的流过电感的电流 I_1 、输出的电流 I_2 和输出的电压 U , 作为故障的特征参数, 得到 HMM 的观测状态序列 $O = [I_1, I_2, U]$ 。

(2) 建立 HMM, 确定模型的迭代初值, π, A 和 B 。初始状态概率 $\pi = [1 \ 0 \ 0 \ 0]$, 设置状态转换矩阵为:

$$A = \begin{bmatrix} 0.5 & 0.5 & 0 & 0 \\ 0 & 0.5 & 0.5 & 0 \\ 0 & 0 & 0.5 & 0.5 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (1)$$

观测状态概率矩阵 B 设置为:

$$b_j(O_t) = \sum_{m=1}^M c_{jm} N(O_t, u_{jm}, U_{jm}) \quad (2)$$

(3) 模型重估计算。

(4) 用 Baum-Welch 算法迭代, 直至收敛, 完成模型训练。Baum-Welch 算法如下。

首先定义概率 $\vartheta_i(i, j)$:

$$\vartheta_i(i, j) = P(O, q_t = \theta_i, q_{t+1} = \theta_j | \lambda) \quad (3)$$

得到:

$$\vartheta_i(i, j) = (a_i(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)) / P(O | \lambda) \quad (4)$$

那么 t 时刻处于状态 ϑ_i 的概率为:

$$\vartheta_i(i) = P(O, q_t = \theta_i | \lambda) = a_i(i) \beta_t(i) / P(O | \lambda) \quad (5)$$

定义 $\gamma_t(i)$ 为在 t 时刻处于状态 θ_i 的条件概率, 求和得:

$$\gamma_t(i) = \sum_{j=1}^N \vartheta_t(i, j) \quad (6)$$

其中, $\sum_{j=1}^N \vartheta_t(i, j)$ 是期望值。得出模型重估公式, 对 $\pi_i = \gamma_1(i)$ 进行重估:

$$\pi_i = \gamma_1(i) \quad (7)$$

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \vartheta_t(i, j)}{\sum_{i=1}^N \gamma_t(i)} \quad (8)$$

$$\bar{b}_{jk} = \frac{\sum_{t=1}^T \gamma_t(j) o_{t=\theta_k}}{\sum_{j=1}^N \gamma_t(j)} \quad (9)$$

用重估后的 $\bar{\lambda}$ 不断取代 λ , 直到达到收敛条件, 且不再明显增大, 这时所得到的参数就是最优解。

重复上述步骤训练出 10 种故障状态各自的 HMM。训练过程当中, 输出结果在不同的控制模式甚至是相同的控制模式应用于不同的场合时也有可能不一样。文中使用多个训练样本来进行模型训练, 考虑多个数据集的普遍特点, 即需要使用多个训练样本来训练某一个故障模型。

定义有 H 个训练样本, 即有 H 个可观测状态序列 $O^{(1)}, O^{(2)}, \dots, O^{(H)}$, 满足:

$$\begin{cases} P(O | \omega) = P(O^{(1)} | \omega) P(O^{(2)} | O^{(1)}, \omega) \dots \\ \quad P(O^{(H)} | O^{(H-1)} \dots O^{(1)}, \omega) \\ P(O | \omega) = P(O^{(2)} | \omega) P(O^{(3)} | O^{(2)}, \omega) \dots \\ \quad P(O^{(1)} | O^{(H)} \dots O^{(2)}, \omega) \\ \vdots \\ P(O | \omega) = P(O^{(H)} | \omega) P(O^{(1)} | O^{(H)}, \omega) \dots \\ \quad P(O^{(H-1)} | O^{(H)} \dots O^{(1)}, \omega) \end{cases} \quad (10)$$

引入权重系数 ε :

$$\begin{cases} \varepsilon_1 = \frac{1}{H} P(O^{(2)} | O^{(1)}, \omega) \dots P(O^{(H)} | O^{(H-1)} \dots O^{(1)}, \omega) \\ \varepsilon_2 = \frac{1}{H} P(O^{(3)} | O^{(2)}, \omega) \dots P(O^{(1)} | O^{(H)} \dots O^{(2)}, \omega) \\ \vdots \\ \varepsilon_H = \frac{1}{H} P(O^{(1)} | O^{(H)}, \omega) \dots P(O^{(H-1)} | O^{(H)} \dots O^{(1)}, \omega) \end{cases} \quad (11)$$

最终得到:

$$P(O | \omega) = \sum_{h=1}^H \varepsilon_h P(O^{(h)} | \omega) \quad (12)$$

至此完成了 PFC 装置的 10 种故障模型训练, 接着运用训练完成的 HMM 进行 PFC 故障检测。

3.3 故障检测

文中采用 Viterbi 算法进行故障检测, 此算法基于动态规划, 可以找到一个最优的状态序列, 即具有最大的 $P(Q | O, \omega)$ 值, 具体过程如下。

首先定义一个变量 $\sigma_t(i)$, 表示 t 时刻沿着某一种方法的观测序列 o_1, o_2, \dots, o_t 的概率最大, 其表达式为:

$$\sigma_t(i) = \max_{q_1, \dots, q_{t-1}} P((q_1, q_2, \dots, q_t, o_1, o_2, \dots, o_t | \lambda)) \quad (13)$$

为了得到最优的隐藏序列 Q^* :

(1) 进行初始化:

$$\sigma_1(i) = \pi_i b_i(o_1) \quad (14)$$

$$\varphi_1(i) = 0 \quad 1 \leq i \leq N \quad (15)$$

(2) 迭代:

$$\sigma_t(i) = \max_{1 \leq i \leq N} [(\sigma_{t-1}(i) a_{ij})] b_j(o_t) \quad 2 \leq t \leq T, 1 \leq j \leq N \quad (16)$$

$$\varphi_t(i) = \operatorname{argmax}_{1 \leq i \leq N} [\sigma_{t-1}(i) a_{ij}] \quad 1 \leq t \leq T, 1 \leq j \leq N \quad (17)$$

(3) 终止:

$$P^* = \max_{1 \leq i \leq N} (\sigma_T(i)) \quad (18)$$

$$q_T^* = \operatorname{argmax}_{1 \leq i \leq N} (\sigma_T(i)) \quad (19)$$

其中, argmax 表示, 若 $i = I$ 时 $f(i)$ 最大, 则 $I = \operatorname{argmax}_{1 \leq i \leq N} (f(i))$ 。

(4) 最优的隐藏状态序列:

$$q_t^* = \varphi_{t+1}(q_{t+1}^*) \quad t = T, T-1, \dots, 1 \quad (20)$$

至此, 完成 PFC 故障诊断, 将故障状态下测得的电感电流 I_1 、输出电压 U 和输出电流 I_2 输入到训练完成的 HMM 中, 求得 10 个 $P(Q | O, \omega)$, 最大值所对应的 HMM 即为所诊断出来的故障。

4 仿真实验

采用第 3 章中的方法进行故障模型训练和故障检测。首先设定收敛误差为 1×10^{-6} , 10 种故障状态的训练所需步数如图 3 所示, 10 种故障模型的训练均已收敛稳定。不同故障模型下模拟所需的迭代步数如表 2 所示。HMM 的训练需要较少的迭代步骤, 具有较快的收敛速度。利用训练完成的 HMM 对待测量的信号识别和计算 $P(Q | O, \lambda_i)$, 具有最大 $P(Q | O, \lambda_i)$ 的模型即为识别结果。每个模型中选取 10 种故障的测试样本进行计算, 确定最大值,

计算结果如表 3 所示,可以发现模型号与故障号准确对应。




图 3 1~10 号故障模型训练所需步数
Fig.3 Steps required for the training of No.1~10 fault model

表 2 各个故障训练所需步数

Table 2 Number of steps required for each fault training

故障编号	迭代步数	故障编号	迭代步数
1	12	6	24
2	13	7	10
3	26	8	14
4	12	9	21
5	26	10	14

为验证用 HMM 进行电路状态识别的有效性,文中进行了大量样本实验,选取了 500 组不同状态的测试样本,样本由同一种仿真方法生成,每个故障状态取 50 组数据作为测试样本。仿真中的故障诊断结果如表 4 所示。整体识别精度达到 100%,具有非常精确的识别性能,因此,利用 HMM 进行电动汽车无线充电系统 PFC 故障诊断是快速且有效的。

为了验证 HMM 诊断 PFC 故障的优越性,将其

与其他传统的模式识别方法进行了比较。在以往的研究中,传统的模式识别方法有基于神经网络和基于支持向量机(support vector machine, SVM)。

神经网络可以模拟人脑的学习、记忆、识别等多种功能,反向传播(back propagation, BP)神经网络是一种前馈网络。利用神经网络对模型中的 10 种故障进行识别,在这种方法中,选择隐藏层节点的数目对结果有很大的影响。理论上,隐层节点数越大,正确识别率越高。使用 BP 神经网络进行故障诊断很容易陷入局部最小值,收敛速度慢,产生振荡;同时,没有明确的公式和理论来指导确定隐藏层和节点的数量,通常根据经验来计算,这也是文中所采用的 BP 方法训练时间长、正确率低的原因。因此,该算法存在缺陷。

SVM 基于结构风险最小化的原理,存在 2 个问题:(1) 选择合适的核函数;(2) 选择合适的误差代价系数。在该方法中,核函数的选择和误差代价系数 C 对故障识别有显著影响^[20]。这 2 个参数的选择在不同的系统中有所不同。在使用 SVM 进行故障诊断时,如果不进行优化,就无法获得满意的诊断精度。因此,该方法也存在缺陷,不稳定,鲁棒性差,且识别精度比 HMM 低。

为了研究将 HMM 应用于 PFC 故障诊断的优越性和可行性,对上述 3 种方法进行了比较分析。表 5 为 3 种不同方法获得的诊断结果。

从表 5 可以看出,HMM 的正确识别率明显优于其他 2 种方法。因此,基于 HMM 方法的故障诊断是可行的,结果显示运用 HMM 的结果较为理想,更具优势。文中针对的是 PFC 装置中典型的 10 种故障状态,意在说明 HMM 的可行性与优越性,这 10 种故障状态特征较为明显,而 HMM 的优势正是依

表 3 1~10 号故障模型的输出值

Table 3 The output value of No.1~10 fault model

模型	故障									
	1	2	3	4	5	6	7	8	9	10
1	1.01	-162.59	-116.54	-303.25	-81.36	-90.02	-112.26	-26.19	-111.67	-91.98
2	-533.7	62.83	-291.39	-41.78	-2 116.14	1.02	-198.24	-146.31	-267.32	-314.04
3	-60.64	-51.16	-9.98	-282.6	-62.87	-3 213.22	-64.28	-2 289.19	-41.92	-1 130.29
4	-2 012.42	-812.68	-1 314.97	-12.92	-612.06	-61.89	-510.17	-1 792.3	-1 137.26	-94.37
5	-90.71	-2 155.77	-2 154.18	-50.68	1.77	0.56	-76.13	-327.27	-68.29	-278.46
6	-4 161.51	-163.12	-3 913.54	-541.46	-161.9	2.13	-430.19	-419.69	-10.34	-367.12
7	-89.12	-2 613.51	-10.87	-72.11	-411.57	-89.14	9.89	-2 116.43	-190.47	-679.56
8	-141.16	-61.14	-871.24	-190.4	-166.66	60.12	-2 563.17	-0.68	-133.79	-20.12
9	-67.44	-611.14	-479.5	-713.09	-161.13	-2 156.89	-542.19	-257.18	1.62	-339.67
10	-456.21	-41.69	-376.12	-112.13	-267.81	-624.16	-2 433.18	-9.12	-398.12	-3.42
结果	1	2	3	4	5	6	7	8	9	10

表 4 故障诊断结果

Table 4 Results of fault diagnosis

故障编号	诊断次数	HMM	
		正确诊断次数	正确率/%
1	50	50	100
2	50	50	100
3	50	50	100
4	50	50	100
5	50	50	100
6	50	50	100
7	50	50	100
8	50	50	100
9	50	50	100
10	50	50	100

表 5 不同方法的诊断结果

Table 5 Diagnosis results of different methods %

故障编号	诊断方法正确识别率		
	HMM	BP 神经网络	SVM
1	100	61	90
2	100	79	79
3	100	52	83
4	100	76	79
5	100	81	86
6	100	76	71
7	100	79	87
8	100	80	60
9	100	71	86
10	100	72	80

据故障特征对故障模型进行建立和识别,因此采用 HMM 检测这 10 种故障的效果明显优于其他 2 种方法。

5 结语

文中介绍了一种运用 HMM 对 LCC-S 型磁耦合谐振式电动汽车无线充电系统 PFC 装置进行故障诊断的方法。仿真实验结果表明,用 HMM 诊断 PFC 装置故障是可行且有效的,与传统的故障诊断方式相比,HMM 的识别正确率为 100%,优于神经网络和 SVM。因此,将 HMM 用于 LCC-S 型磁耦合谐振式电动汽车无线充电系统 PFC 装置故障诊断具有重要的理论和实际应用价值。

参考文献:

[1] 许珊,李扬. 含电动汽车负荷的分布式风电源优化配置[J]. 电力需求侧管理,2019,21(1):11-15.
XU Shan,LI Yang. Optimal allocation of distributed wind generation including loads of electric vehicles[J]. Power Demand

Side Management,2019,21(1):11-15.

[2] 袁军,李波,刘志凯,等. 基于虚拟仪器技术的电动汽车充电桩综合测试系统[J]. 浙江电力,2018,37(6):36-41.
YUAN Jun,LI Bo,LIU Zhikai,et al. Integrated testing system of electric vehicles charging pile based on virtual instrument technology[J]. Zhejiang Electric Power,2018,37(6):36-41.

[3] 杨晓梅,王金虎,费益均,等. 基于 DC/DC 电路的无线充电系统功率温度控制方法[J]. 电力工程技术,2019,38(6):173-178.
YANG Xiaomei,WANG Jinhu,FEI Yijun,et al. Power stability control method of wireless charging system based on DC/DC circuit[J]. Electric Power Engineering Technology,2019,38(6):173-178.

[4] 冯雪兰. 电力电子电路故障诊断技术探索与预测[J]. 电子制作,2018(8):97-98.
FENG Xuelan. Exploration and prediction of power electronic circuit fault diagnosis technology[J]. Electronic Manufacture,2018(8):97-98.

[5] 王尉军,殷慧. 线路电子式互感器渐变性故障诊断方法[J]. 电力工程技术,2018,37(1):136-140.
WANG Weijun,YIN Hui. Diagnosis method of progressive fault of line electronic transformer[J]. Electric Power Engineering Technology,2018,37(1):136-140.

[6] MCARTHUR S D J,STRACHAN S M,JAHN G. The design of a multi-agent transformer condition monitoring system[J]. IEEE Transactions on Power Systems,2004,19(4):1845-1852.

[7] 汤李华. 基于故障树的雷达故障诊断方法研究[J]. 无线互联科技,2019,16(1):3-4.
TANG Lihua. Research on radar fault diagnosis based on fault tree[J]. Wireless Internet Technology,2019,16(1):3-4.

[8] 彭华亮,沈暑龙,李军,等. 基于故障树的故障诊断专家系统设计[J]. 控制工程,2019,26(3):585-588.
PEN Hualiang,SHEN Shulong,LI Jun,et al. Design of fault diagnosis expert system based on fault tree[J]. Control Engineering,2019,26(3):585-588.

[9] 周汝胜,焦宗夏,王少萍,等. 基于专家系统的导弹发射车液压系统故障诊断[J]. 航空学报,2008,29(1):197-203.
ZHOU Rusheng,JIAO Zongxia,WANG Shaoping,et al. Fault diagnosis of missile launcher hydraulic system based on expert system[J]. Acta Aeronautica et Astronautica Sinica,2008,29(1):197-203.

[10] 颜梦香,姬东鸿,任亚峰. 基于层次注意力机制神经网络模型的虚假评论识别[J]. 计算机应用,2019(7):1925-1930.
YAN Mengxiang,JI Donghong,REN Yafeng. False comment recognition based on neural network model of hierarchical attention mechanism[J]. Computer Applications,2019(7):1925-1930.

[11] 孙子文,李富. 基于 HMM 与 D-S 证据理论的手势身份认证方法[J]. 信息安全,2018,214(10):23-29.
SUN Ziwen,LI Fu. Gesture authentication method based on HMM and D-S evidence theory[J]. Netinfo Security,2018,214(10):23-29.

- [12] TOKUDA K, YOSHIMURA T, MASUKO T, et al. Speech parameter generation algorithms for HMM-based speech synthesis [C]//IEEE International Conference on Acoustics. IEEE Computer Society, 2002.
- [13] NI Ji, CHEN Bowei, ALLINSON N M. A hybrid model for predicting human physical activity status from lifelogging data[J]. European Journal of Operational Research, 2020, 281(3): 532-542.
- [14] RAINER Kelz, SEBASTIAN Bock, GERHARD Widmer. Deep polyphonic ADSR piano note transcription [C]//ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2019.
- [15] 苗苗, 马海武. HMM 在语音识别系统中的应用[J]. 现代电子技术, 2006, 29(16): 64-66.
MIAO Miao, MA Haiwu. Application of HMM in speech recognition system [J]. Modern Electronics Technique, 2006, 29(16): 64-66.
- [16] 汪崔洋, 江全元, 唐雅洁, 等. 基于告警信号文本挖掘的电力调度故障诊断[J]. 电力自动化设备, 2019, 39(4): 132-138.
WANG Cuiyang, JIANG Quanyuan, TANG Yajie, et al. Fault diagnosis of power dispatching based on text mining of warning signals[J]. Electric Power Automation Equipment, 2019, 39(4): 132-138.
- [17] 胡为, 高雷, 傅莉. 基于最优阶次 HMM 的电机故障诊断方法研究[J]. 仪器仪表学报, 2013, 34(3): 524-530.
HU Wei, GAO Lei, FU Li. Study on motor fault diagnosis based on optimal order HMM [J]. Chinese Journal of Instrumentation, 2013, 34(3): 524-530.
- [18] 张菲. 基于 LMD 和 HSMM 的旋转机械故障诊断方法研究 [D]. 成都: 西南交通大学, 2016.
ZHANG Fei. Study on fault diagnosis methods of rotating machinery based on LMD and HSMM [D]. Chengdu: Southwest Jiaotong University, 2016.
- [19] 李志农, 何永勇, 褚福磊, 等. 用于机械故障诊断的门限自回归模型盲辨识[J]. 清华大学学报(自然科学版), 2005, 45(8): 1036-1039.
LI Zhinong, HE Yongyong, ZHU Fulei, et al. Blind identification of threshold autoregression model for mechanical fault diagnosis[J]. Journal of Tsinghua University (Natural Science Edition), 2005, 45(8): 1036-1039.
- [20] 周启超, 刘剑, 刘丽, 等. 基于 SVM 的通风系统故障诊断惩罚系数与核函数系数优化研究[J]. 中国安全生产科学技术, 2019, 15(4): 47-53.
ZHOU Qichao, LIU Jian, LIU Li, et al. Study on optimization of fault diagnosis penalty coefficient and kernel function coefficient of ventilation system based on SVM [J]. China Production Safety Science and Technology, 2019, 15(4): 47-53.

作者简介:



吴争

吴争 (1971), 男, 硕士, 教授级高级工程师, 从事电力系统相关工作 (E-mail: wuzheng@js.sgcc.com.cn);

李瑶虹 (1972), 女, 硕士, 高级经济师, 从事电力系统相关工作;

杨晓梅 (1973), 女, 硕士, 教授级高级工程师, 从事电力系统相关工作。

Fault detection of PFC device in wireless charging system based on HMM

WU Zheng, LI Yaohong, YANG Xiaomei, CUI Hengzhi, FEI Yijun
(State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210024, China)

Abstract: As an important bridge between the rectification module and the high-frequency inverter module in the wireless charging system of electric vehicles, the power factor correction (PFC) device not only has a serious impact on the power grid, but also causes irreversible damage to the back-end high-frequency inverter module. Therefore, fast and accurate fault detection is needed. Traditional fault detection methods have long detection time and low detection accuracy. Therefore, a fault detection method of PFC device in the wireless charging system of EVs based on hidden Markov model (HMM) is proposed. Firstly, the model is initialized. Then Baum-Welch algorithm is used for fault model training. Finally, Viterbi algorithm is used for fault detection. Simulation results show that the accuracy of PFC device fault detection using HMM is about 40% higher than that of neural network and support vector machine, which is a fast and accurate method. Therefore, HMM is used to effectively identify the type of PFC device fault in the wireless charging system of electric vehicles.

Keywords: electric vehicle; wireless charging system; power factor correction (PFC); hidden Markov model (HMM); fault detection

(编辑 钱悦)