

基于 MRVM 模型的级联 H 桥型逆变系统故障诊断方法^①

王天真^{②*} ** 邱洁* 徐浩* 汤天浩*

(* 上海海事大学电气自动化系 上海 200135)

(** 法国海军学院研究所 SIG 课题组 布雷斯特 29240)

摘要 为了实现级联 H - 桥多电平逆变系统的故障诊断, 提高诊断准确率和诊断速度, 在分析多电平逆变系统的故障特点的基础上, 提出了一种基于多分类相关向量机 (MRVM) 模型的级联 H 桥逆变系统故障诊断的方法。该方法以逆变系统的输出电压信号作为模型的输入故障信号, 通过快速傅立叶变换 (FFT) 进行信号预处理, 以降低噪声, 减少训练和测试时间, 采用 E-step 和最大期望估计的方法来进行模型推断。诊断输出为各故障类别的概率, 以概率最大的故障类别作为诊断结果。实验结果表明, 该方法具有更快的诊断速度和更高的诊断准确率, 满足了级联 H - 桥多电平逆变系统故障诊断的要求。

关键词 多分类相关向量机 (MRVM), 级联 H 桥, 逆变系统, 故障诊断

0 引言

随着高压大功率变换器被广泛应用于各种电气设备中, 多电平逆变器在高压大功率场合有着重要的应用前景^[1]。级联 H 桥型逆变器不需要大量箝位二极管或电容, 也不存在中间直流电压中性点偏移问题及均压问题, 而且采用模块化安装, 结构紧凑, 工作效率高, 因而是一种有很好应用前景的多电平逆变系统^[2]。但随着系统电平数的增加, 主电路所需要的开关数量也成倍增加, 电路结构和控制更加复杂。且级联 H 桥逆变器大量使用功率半导体器件, 这些开关器件增加了故障发生的可能性, 而且随着电压的增加, 故障出现的概率也会变大。因此, 级联 H 桥型多电平逆变系统的故障诊断问题显得尤为重要^[3]。本文致力于这方面的研究, 提出了一种基于多分类相关向量机 (multiclass relevance machine, MRVM) 模型的级联 H 桥逆变系统故障诊断方法, 其有效性得到了实验验证。

1 相关研究

在级联多电平逆变系统的故障诊断方法研究

上, 文献[4]采用机内测试设计, 在每个级联单元加入传感器, 这样可以实现较快的故障定位, 但这样会增加系统成本, 且传感器发生故障会直接导致系统误诊断。文献[5,6]提出了派克矢量 (Park's Vector) 变换的方法, 该方法首先基于周期平均计算线电流中的直流成分, 然后根据派克矢量变换, 计算复频域中交流电流的幅值和相角。该方法依赖负载, 一旦负载改变, 也会导致系统误诊断。文献[7,8]针对多电平逆变系统利用神经网络对故障进行识别诊断, 该方法诊断速度较慢, 且精度有待进一步提高。文献[9]建立支持向量机 (support vector machine, SVM) 分类模型对逆变系统进行故障分类诊断, 该方法诊断精度高, 泛化能力强, 但存在规范化系数确定困难, 核函数必须满足 Mercer 条件等固有局限。Damoulas 等人在相关向量机^[10] (relevance vector machine, RVM) 的基础上进行多元分类扩展, 提出了多分类相关向量机 (MRVM)^[11-13] 模型, 它是一种基于贝叶斯框架的统计学习算法。MRVM 模型除了具有 SVM 模型的优点之外, 其基函数权值只有少数非零, 相关向量数量少, 模型稀疏度高, 计算复杂度低, 可以直接实现多分类, 且其输出为各类成员概率, 输出具有概率统计意义。因此 MRVM 模型

① 国家自然科学基金 (61203089), 863 计划 (2013AA041106), 上海市教委创新重点项目 (14ZZ141) 和教育部博士基金 (20113121110002) 资助项目。

② 女, 1978 年生, 博士, 副教授; 研究方向: 智能信息处理与故障诊断; 联系人, E-mail: wtz0@sina.com
(收稿日期: 2013-04-16)

用于故障诊断时,输出结果为未知类型的故障属于每一种故障类型的概率,即可在获得除了其最大可能故障类型外,同时得到属于其他故障类型的概率。

本研究基于以上分析,提出了基于 MRVM 模型的级联 H 桥型多电平逆变系统故障诊断方法。该方法首先利用快速傅立叶变换(fast Fourier transformation,FFT)^[14]对系统输出电压故障信号进行预处理,将预处理后的数据输入 MRVM 模型实现故障分类诊断,得到该故障信号对应各故障类别的概率,最后以概率最大的故障类别作为诊断结果输出,该方法的有效性已通过实验得到了验证。

2 级联 H 桥多电平逆变系统故障分析

图 1 所示为典型的三相级联 H 桥多电平逆变系统及其单相拓扑结构,其中每个 H 桥为一个功率单元。该系统中每相的结构相同,因此只需对其中一相进行故障分析即可。本文采用消谐波控制法来控制门极驱动信号,输出电压大小可以通过调制系数 m_c 来调节。

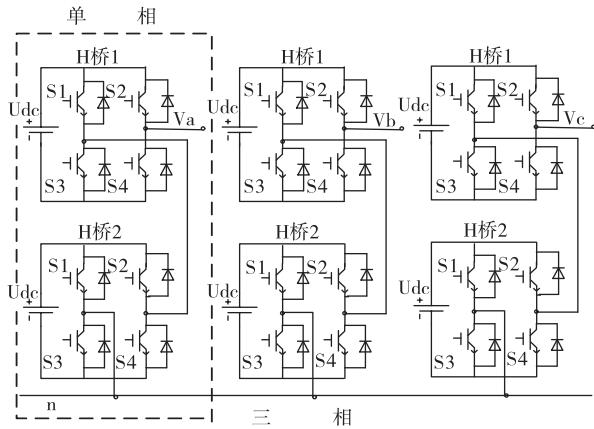


图 1 级联 H 桥多电平逆变系统及其单相拓扑图

2.1 故障特征信号选取

以图 1 单相级联 H 桥为例,若某一 H 桥 S_i 发生开路(或短路)故障,则该桥第 i 个开关管发输出电压为 U_{dc} (或 0),其中 U_{dc} 为一个周期内均值。因此当某一开关管发生故障时,其所在相无法产生期望的输出电压波形。图 2 分别为开关管正常工作和发生开路故障时系统输出的相电压波形。分析可知,任一 H 桥不同开关管发生故障时,系统输出电压波形都不相同,且输出的相电压信号与故障类型

和位置紧密相关,输出相电压不随负载变化^[15]。基于以上原因,本文采用系统输出的相电压信号作为故障诊断的输入信号。

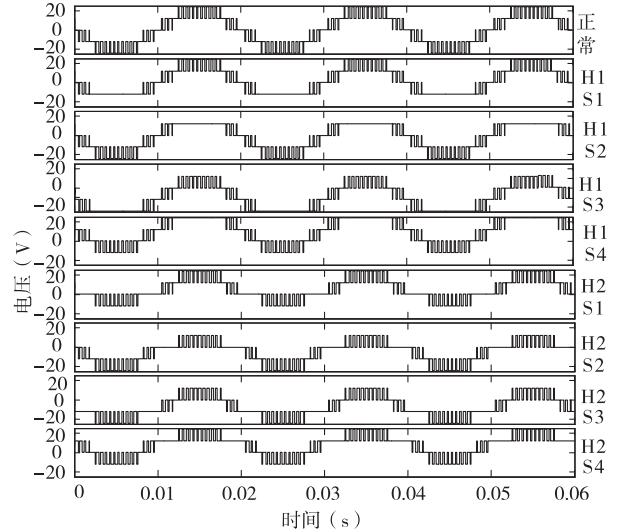


图 2 级联 H 桥开路故障时相电压输出波形($m_c = 0.85$)

2.2 故障类型划分及其表示方法

本文讨论五电平级联 H 桥单个开关管器件发生开路故障的情况,更高电平逆变系统或开关管短路故障,只需在五电平逆变基础上进行扩展。逆变系统故障诊断本质上是一个多分类问题,文中共分 9 种故障类别,其中将正常状态也列为一类特殊故障,并分别采用表 1 中所示的分类标签来表示,分类标签用于故障分类识别。当故障信号属于某一故障类别时,其对应故障类别的分类标号为 1,其余为 0,这样便于将每种故障类型区分。

表 1 故障类型划分及分类标签设置

序号	故障类别	分类标签
1	正常	$[1, 0, 0, 0, 0, 0, 0, 0, 0]^T$
2	H1S1 开路	$[0, 1, 0, 0, 0, 0, 0, 0, 0]^T$
3	H1S2 开路	$[0, 0, 1, 0, 0, 0, 0, 0, 0]^T$
4	H1S3 开路	$[0, 0, 0, 1, 0, 0, 0, 0, 0]^T$
5	H1S4 开路	$[0, 0, 0, 0, 1, 0, 0, 0, 0]^T$
6	H2S1 开路	$[0, 0, 0, 0, 0, 1, 0, 0, 0]^T$
7	H2S2 开路	$[0, 0, 0, 0, 0, 0, 1, 0, 0]^T$
8	H2S3 开路	$[0, 0, 0, 0, 0, 0, 0, 1, 0]^T$
9	H2S4 开路	$[0, 0, 0, 0, 0, 0, 0, 0, 1]^T$

3 MRVM 模型方法

3.1 MRVM 模型基本原理

设训练集 $X = \{\mathbf{x}_i, t_i\}_{i=1}^N, \mathbf{x} \in R^D, t \in \{1, \dots, C\}$ 为类别标签。当给定核函数时, 可得训练核函数集 $\mathbf{K} = [\mathbf{k}_1, \dots, \mathbf{k}_N]^T, \mathbf{K} \in R^{N \times N}, \mathbf{K}$ 中的行向量 \mathbf{k}_n 代表训练集中第 n 个样本数据与其他样本数据的相似度。引入辅助回归目标 $\mathbf{Y} \in R^{C \times N}$ 和回归量 $\mathbf{W} \in R^{N \times C}$, 可得标准噪音回归模型^[16,17] $y_{cn} | \mathbf{w}_c, \mathbf{k}_n \sim N_{y_{cn}}(\mathbf{w}_c^T \mathbf{k}_n, 1)$ 。利用多项式概率联系^[18], 通过式

$$t_n = i, y_{ni} > y_{nj} \forall j \neq i \quad (1)$$

将回归目标转化为类别标签, 实现多分类识别。

通过产生多项概率似然函数^[19]如式

$$\begin{aligned} P(t_n = i | \mathbf{W}, \mathbf{k}_n) \\ = \varepsilon_{P(u)} \{ \prod \Phi(u + w_i + w_j)^T \mathbf{k}_n \} \end{aligned} \quad (2)$$

用于实现输出类别成员的概率。其中 $u \sim N(0, 1)$, $j \neq i$, Φ 为高斯累积分布函数。

为了保证模型的稀疏性, 回归量 \mathbf{W} 中的每个回归参数 w_{nc} 要服从均值为零, 方差为 α_{nc}^{-1} 的高斯先验分布。其中先验超参 α_{nc} 服从超参为 a, b 的 Gamma 先验分布, 由 α_{nc} 组成的矩阵记为 $\mathbf{A} \in R^{N \times C}$ 。根据上文所述, MRVM 模型结构如图 3 所示, 可知其采用的是分层贝叶斯模型结构。根据图 3 可以推导出回归量 \mathbf{W} 的闭型后验概率分布为 $P(\mathbf{W} | \mathbf{Y}) \propto P(\mathbf{Y} | \mathbf{W}) P(\mathbf{W} | \mathbf{A}) \propto \prod_{c=1}^C N((\mathbf{K}\mathbf{K}^T + \mathbf{A}_c)^{-1} \mathbf{K} \mathbf{y}_c^T, (\mathbf{K}\mathbf{K}^T + \mathbf{A}_c)^{-1})$, 其中 \mathbf{A}_c 为由 \mathbf{A} 的第 c 列导出的对角阵。

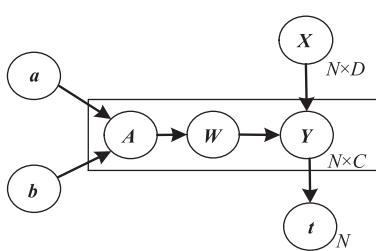


图 3 分层贝叶斯模型结构

由最大后验概率估计可得公式

$$\hat{\mathbf{W}} = \text{argmax}_{\mathbf{w}} P(\mathbf{W} | \mathbf{Y}, \mathbf{A}, \mathbf{K}) \quad (3)$$

因此给定给类别 c 时, 其基于最大后验概率估计的参数更新方法由下式所示:

$$\hat{\mathbf{w}}_c = (\mathbf{K}\mathbf{K}^T + \mathbf{A}_c)^{-1} \mathbf{K} \mathbf{y}_c^T \quad (4)$$

由式(4)和文献[20], 可以推导出辅助变量 \mathbf{Y} 的 E-step 形式。对于 $\forall c \neq i$, 其 E-step 形式为

$$\hat{y} \leftarrow \hat{\mathbf{w}}_c^T \mathbf{k}_n - \frac{\varepsilon_{P(u)} \{ N_u(\hat{\mathbf{w}}_c^T \mathbf{k}_n - \hat{\mathbf{w}}_i^T \mathbf{k}_n, 1) \Phi_u^{n,i,c} \}}{\varepsilon_{P(u)} \{ \Phi(u + \hat{\mathbf{w}}_i^T \mathbf{k}_n - \hat{\mathbf{w}}_c^T \mathbf{k}_n) \Phi_u^{n,i,c} \}},$$

对于第 i 类, 其 E-step 形式为 $\tilde{y}_{in} \leftarrow \hat{\mathbf{w}}_i^T \mathbf{k}_n - (\sum_{j \neq i} \tilde{y}_{jn} - \hat{\mathbf{w}}_j^T \mathbf{k}_n)$ 。

回归量先验参数的闭型后验概率分布为 $P(\mathbf{A} | \mathbf{W}) \propto P(\mathbf{W} | \mathbf{A}) P(\mathbf{A} | a, b) \propto \prod_{c=1}^C \prod_{n=1}^N G(a + \frac{1}{2}, \frac{w_{nc}^2 + 2b}{2})$ 。

Gamma 分布的均值由下式所示:

$$\tilde{\alpha}_{nc} = \frac{2a + 1}{w_{nc}^2 + 2b} \quad (5)$$

3.2 MRVM 模型学习

本文的 MRVM 模型学习采用 E-step 法^[20]来更新超参 $\boldsymbol{\alpha}$ 。该方法使得样本集经历一个自下而上的修剪过程。该过程始于完全模型, 并通过不断地剔除非相关样本, 最终得到一个稀疏模型, 被剔除的样本不会再被引入模型中。由图 3 MRVM 模型结构可得超参的后验概率分布为 $P(\boldsymbol{\alpha} | \mathbf{W}, a, b) \propto P(\mathbf{W} | \boldsymbol{\alpha}) P(\boldsymbol{\alpha} | a, b)$ 。若参数先验服从正态分布 $\mathbf{W} | \boldsymbol{\alpha} \sim \prod_{c=1}^C \prod_{n=1}^N N(w_{nc}(0, \frac{1}{\alpha_{nc}}))$, 共轭先验服从 Gamma 分布 $\alpha_{nc} | w_{nc}, a, b \sim G(1 + a, w_{nc}^2 + b)$, 则根据 E-step 法可得到 α_{nc} 的更新如下式所示:

$$\alpha_{nc} = \frac{1 + a}{w_{nc}^2 + b} \quad (6)$$

设迭代过程中有活动集 A , 活动集样本个数为 M , 在模型学习的过程中, 式(4)修正成为下式:

$$\hat{\mathbf{W}}_* = (\mathbf{K}_* \mathbf{K}_*^T + \mathbf{A}_*)^{-1} \mathbf{K}_* \tilde{\mathbf{Y}}^T \quad (7)$$

其中 $\mathbf{K}_* \in R^{M \times N}, \mathbf{A}_* \in R^{M \times M}, M < N$ 。

本文根据文献[19]中给出的收敛标准选择 $conv2$ 。

4 基于 MRVM 模型的故障诊断

本文提出的基于 MRVM 模型的故障诊断方法结构如图 4 所示。该方法主要分为信号预处理、MRVM 分类诊断、诊断输出和开关模式计算 4 部分, 本文研究了前 3 个部分。根据 2.1 节分析, 本文选取逆变系统输出相电压作为故障诊断输入信号。采样得到的数据空间很大, 很难列出重要的特征用于故障诊断分类, 所以采用 FFT 处理离散的输出电压信号, 选取前次谐波幅值构成故障特征向量, 达到降低数据空间大小, 减少训练测试时间和噪声干扰,

从而改善诊断能力的目的。采用按照从完整模型中逐步剔除非相关样本的方法对 MRVM 模型进行学习,将预处理后的故障特征向量输入 MRVM 模型进行训练,从而得到基于 MRVM 模型的级联 H 桥多电平逆变系统故障分类诊断模型。

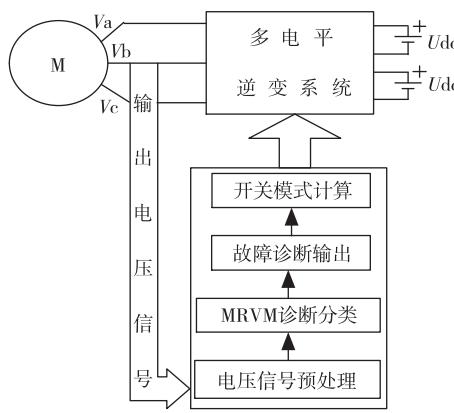


图 4 故障诊断方法结构图

4.1 故障信号预处理

采样得到的一个周期内的离散输出电压信号 $\{f_n\}_{0}^{N-1}$, 经过 FFT 变换后, 得到数据集 $X_{a \times b}$, 其中 a 为观测值个数, b 为选取的前次谐波个数(对应 0 到 $b-1$ 次谐波)。FFT 变换公式如下:

$$F_k = G_k + W_N^k H_k \quad (8)$$

$$F_{k+N/2} = G_k - W_N^k H_k \quad (9)$$

其中 $W_N = e^{-j2\pi/N}$, N 为采样点个数, $k = 0, \dots, \frac{N}{2}-1$, G_k 为 f_n 的偶数序列求和, H_k 为 f_n 的奇数序列求和。 G_k 和 H_k 可以通过以下两公式计算:

$$G_k = \sum_{n=0}^{(N/2)-1} f_{2n} W_N^{nk} \quad (10)$$

$$H_k = \sum_{n=0}^{(N/2)-1} f_{2n+1} W_N^{nk} \quad (11)$$

4.2 基于 MRVM 模型的多电平逆变系统故障分类诊断

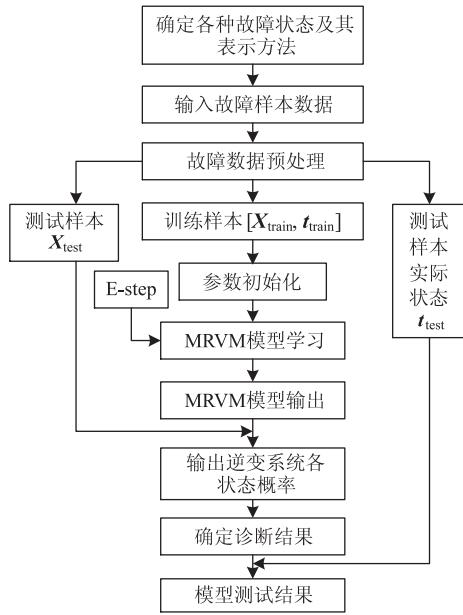
基于 MRVM 模型的逆变系统故障诊断流程如图 5 所示。分类诊断流程如下:

(1) 依据 2.2 节确定的逆变系统故障类型划分和各种故障状态相应的表示方法。

(2) 将预处理后的故障样本数据 $X_{a \times b}$ 与其分类标签向量一一对应, 作为输入样本数据 $[X, t]$ 。

(3) 选取合适的核函数, 并确定核函数参数。

(4) 样本数据分为训练集 $[X_{train}, t_{train}]$ 和测试集 $[X_{test}, t_{test}]$, 分别进行 MRVM 模型学习和测试;

图 5 基于 MRVM 模型的多电平逆变系统
故障分类诊断流程

(5) 将测试集的测试结果与其实际状态比较, 得到最终的模型测试结果。

4.3 故障诊断输出向量

MRVM 分类模型可以直接实现多分类和输出逆变系统为各种状态的概率, 故障诊断的输出向量模式为 $[P_{normal}, P_{H1S1}, P_{H1S2}, P_{H1S3}, P_{H1S4}, P_{H2S1}, P_{H2S2}, P_{H2S3}, P_{H2S4}]$, $P_{normal}, P_{H1S1}, P_{H1S2}, P_{H1S3}, P_{H1S4}, P_{H2S1}, P_{H2S2}, P_{H2S3}, P_{H3S4}$ 分别代表逆变系统的状态为正常, H1S1 开路、H1S2 开路、H1S3 开路、H1S4 开路、H2S1 开路、H2S2 开路、H2S3 开路和 H2S4 开路的概率, 记输出向量的索引集为 $I = \{normal, H1S1, H1S2, H1S3, H1S4, H2S1, H2S2, H2S3, H2S4\}$ 。诊断结果为逆变电路各种状态中概率最大的状态, 如式

$$t = i, P_i > P_j \forall j \neq i (j, i \in I) \quad (12)$$

所示。

5 实验验证

图 6 为实验平台的硬件框图。

本实验根据图 1 所示的单相五电平级联逆变原理搭建了一个多电平逆变故障分类诊断的硬件实验平台, 来验证算法的可行性。硬件框架中数字信号处理器 DSP 控制芯片为 SY-F2812, 驱动电路选用 Bamac 的 MAST 驱动芯片, 功率开关管选取型号为 SSH70N10A 的 N 沟道功率金属氧化物半导体场效

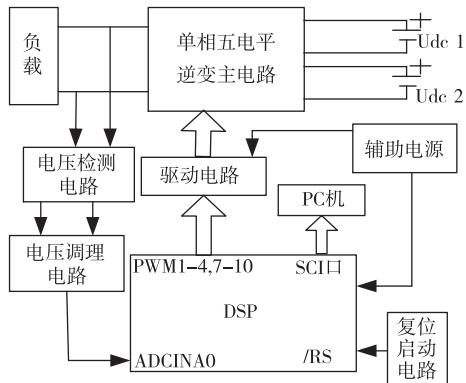


图 6 多电平逆变故障诊断系统的实验平台硬件框图

应晶体管(MOSFET), 直流电源电压为 12V。

5.1 基于 MRVM 模型故障诊断训练

对图 6 中单相五电平级联逆变进行硬件实验, 取得 8 个开关管正常工作和分别开路时的输出电压波形, 训练数据集涉及整个工作区域 ($0.5 \leq m_c \leq 1$), 采样频率为 50kHz, 采样个数 $N = 1000$ 。采样后得到的输出电压信号经过 FFT 变换成 0 到 39 次谐波。其中 0 次谐波为输出电压信号中的直流分量。取 315 个样本(共 9 种故障类型, 每种故障为 35 组)作为实验故障样本数据集, 从该数据集中随机取

162 个样本作为训练样本, 其余 153 个样本作为测试样本来对本文所提方法进行验证。根据 2.2 节所述设置样本故障分类标签。

5.2 基于 MRVM 模型故障诊断测试

本文测试共分为 a,b 两组实验进行:

取 162 个样本对 MRVM 模型训练时, 相关向量的数量在模型学习迭代过程中的变化情况如图 7 所

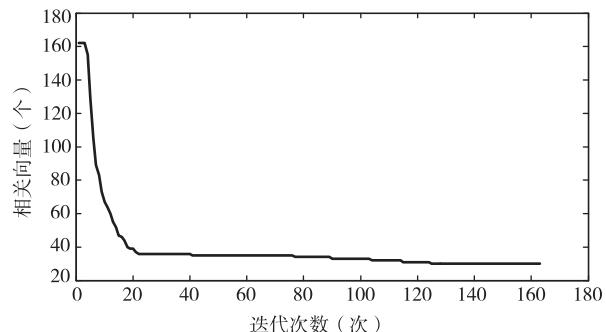


图 7 相关向量在模型学习迭代过程中的变化情况

示, 可以看出 MRVM 模型最终只需要少量的相关向量, 模型稀疏度高, 模型确定后, 输入新的样本数据进行诊断时, 计算复杂度低。

(a) 取一组故障数据对模型测试, 得到模型输出结果 P , 如下所示:

$$P = \begin{bmatrix} 0.9688 & 0.0290 & 3.4629e-05 & 8.8243e-04 & 8.5160e-07 & 5.6388e-13 & 3.6531e-22 & 0.0012 & 1.8720e-09 \\ 5.5380e-04 & 0.6483 & 0.1854 & 0.1629 & 2.5432e-05 & 3.5259e-04 & 5.6968e-07 & 0.0024 & 1.4486e-04 \\ 1.0127e-07 & 0.2176 & 0.5160 & 0.2663 & 1.2909e-04 & 8.2398e-10 & 1.0145e-07 & 1.0088e-07 & 1.9256e-07 \\ 0.0059 & 0.1588 & 0.0048 & 0.8180 & 0.0084 & 0.0037 & 3.9256e-04 & 1.7022e-05 & 4.7500e-10 \\ 1.2385e-28 & 1.3981e-34 & 2.4822e-11 & 3.4359e-23 & 0.9667 & 2.7910e-12 & 0.0333 & 6.6909e-35 & 1.4321e-12 \\ 3.8259e-004 & 2.3332e-08 & 2.1429e-04 & 1.0624e-05 & 3.3066e-04 & 0.3355 & 0.0457 & 0.0446 & 0.5733 \\ 2.0545e-07 & 9.9081e-08 & 9.3020e-05 & 9.0650e-08 & 0.0274 & 0.1975 & 0.5769 & 1.3797e-05 & 0.1981 \\ 0.0011 & 0.0014 & 0.0416 & 6.1974e-05 & 2.6766e-05 & 7.2674e-04 & 0.2566 & 0.6921 & 0.0064 \\ 1.4436e-26 & 4.0541e-12 & 1.7865e-04 & 9.0793e-55 & 4.7764e-09 & 2.2674e-17 & 2.0345e-06 & 3.7900e-19 & 0.9998 \end{bmatrix}$$

P 中的行向量代表与之对应的测试数据中的行向量为输入时, 逆变系统的状态为正常, H1S1 开路、H1S2 开路、H1S3 开路、H1S4 开路、H2S1 开路、H2S2 开路、H2S3 开路和 H2S4 开路的概率。根据式(12)可以得到该测试数据的诊断结果为 $t = [\text{正常}, \text{H1S1}, \text{H1S2}, \text{H1S3}, \text{H1S4}, \text{H2S4}, \text{H2S2}, \text{H2S3}, \text{H2S4}]^T$, 与输出向量索引集 I 比较后得到该测试数据的模型测试准确率为 88.89%。

(b) 分别采用 BP 神经网络、SVM 和 MRVM 方法进行逆变故障诊断实验验证。参数选择和设置见表 2。

表 2 三种方法参数选择与设置

BP	3 层神经网络, 隐层传递函数 tansig, 节点数 8, 输出层传递函数 logsig, 节点数 9, 调用动量 BP 训练算法训练网络
SVM	RBF 核函数, 交叉验证法取核参 0.01
MRVM	RBF 核函数, 多次实验取核参 0.01

从 153 个测试数据中随机选取测试样本数目为 45、72、108、153 来测试不同方法的运行时间和诊断准确率, 每种方法对这 4 个测试数据集分别进行了 50 次实验, 表 3 给出了这 3 种方法的故障诊断结果

的平均值。分析表 3 可知, BP 神经网络的诊断准确率只有 70% 左右, 且算法运行时间过长。SVM 的诊断准确率为 87%, 运行时间也比 BP 算法提高了很多, 平均运行时间只有 BP 的 0.03%。MRVM 方法

诊断准确率达到 90%, 且运行时间只有 BP 算法的 0.58%。与 BP 和 SVM 相比, MRVM 算法诊断准确率高, 运行时间短。实验结果验证了算法的正确性和有效性。

表 3 五电平逆变故障诊断结果比较

样本数目	3 种方法			算法平均运行时间(s)			平均诊断准确率(%)		
	BP	SVM	MRVM	BP	SVM	MRVM	BP	SVM	MRVM
45	15.339	0.00282	0.0398	72.36	93.33	94.76			
72	15.488	0.00285	0.0591	69.50	87.50	90.33			
108	6.961	0.00422	0.0815	72.96	83.33	89.02			
153	13.571	0.00582	0.118	69.70	84.31	87.91			

6 结 论

本文分析了级联 H 桥多电平逆变系统的特点, 提出了基于 MRVM 模型的故障诊断方法, 搭建了级联五电平逆变系统的硬件平台。分析了故障信号的选取, 利用 FFT 频谱分析对系统输出电压信号进行转换, 这样便于输入数据去噪和减少 MRVM 训练和测试时间, 得到更好的诊断性能。实验结果表明, 基于 MRVM 模型的多电平逆变系统故障诊断方法具有较好的故障诊断能力和较快的运行速度, 这将直接减少非正常情况下电气设备的工作时间, 延长设备的使用寿命。与 BP 神经网络算法和 SVM 分类算法相比, 基于 MRVM 模型的诊断方法无论在算法运行时间上还是在诊断准确率上都具有相当大的优势, 且基于 MRVM 模型的诊断方法的输出结果具有概率统计意义。对 MRVM 模型本身进行进一步的算法优化, 对于核参数的选取或在数据预处理上进行优化, 以提高 MRVM 模型的诊断速度和诊断准确率是今后研究努力的方向。

参考文献

- [1] 王琛琛, 李永东. 多电平变换器拓扑关系及新型拓扑. 电工技术学报, 2011, 26(1): 92-99
- [2] Rivera S, Kouro S, Wu B, et al. Cascade H-bridge multilevel converter multistring topology for large scale photovoltaic systems. In: Proceedings of the 2011 IEEE International Symposium on Industrial Electronics, Gdansk, Poland, 2011. 1837-1844
- [3] 孙丰涛, 张承慧, 崔纳新等. 变频器故障诊断技术研究与分析. 电机与控制学报, 2005, 9(3): 272-274
- [4] Rothenhagen K, Fuchs F W. Performance of diagnosis methods for IGBT open circuit faults in three voltage source inverters for AC variable speed drivers. In: Proceedings of Power Electronics and Applications, Dresden, Germany, 2005. 10pp. -P. 7
- [5] 于泳, 蒋生成, 杨荣峰等. 变频器 IGBT 开路故障诊断方法. 中国电机工程学报, 2011, 31(9): 30-35
- [6] Ventura R P S, Mendes A M S, Cardoso A J M. Fault detection in multilevel cascaded inverter using Park's vector approach with balanced battery power usage. In: Proceedings of the 14th European Conference on Power Electronics and Applications, Birmingham, UK, 2011. 1-10
- [7] 戴鹏, 蔡云, 符晓等. 基于小波包变换和神经网络的逆变器故障诊断. 电源技术应用, 2011, 14(8): 17-22
- [8] Babu B P, Srinivas J V S, Vikranth B, et al. Fault diagnosis in multi-level inverter system using adaptive back propagation neural network. In: Proceedings of India Conference, Kanpur, India, 2008. 494-498
- [9] Delpha C, Hao C, Diallo D. SVM based diagnosis of inverter fed induction machine driver: a new challenge. In: Proceedings of the 38th Annual Conference on IEEE Industrial Electronics Society, Montreal, Canada, 2012. 3931-3936
- [10] Changyuan L, Yan L, Xiaojun B. Face recognition based on relevance vector machine. In: Proceedings of the 6th International Forum on Strategic Technology, Harbin, China, 2011. 1202-1206
- [11] Jain V, Pillai G N, Gupta I. Fault diagnosis in analog circuits using multiclass relevance vector machine. In: Proceedings of 2011 International Conference on Emerging Trends in Electrical and Computer Technology, Tamil, India, 2011. 641-643
- [12] Psorakis I, Damoulas T, Girolami M A. Multiclass relevance vector machines. In: Proceedings of the 2004 International Conference on Machine Learning, Banff, Alberta, Canada, 2004. 736-743

- vance vector machines: sparse and accuracy. *IEEE Trans on Neural Networks*, 2010, 21(10): 1588-1598
- [13] 尹金良, 朱永利, 俞国勤. 基于多分类相关向量机的变压器故障诊断新方法. 电力系统保护与控制, 2013, 41(5): 77-82
- [14] Vinay K I, John G P. Digital Signal Processing Using MATLAB. 第三版. 北京: 科学出版社, 2012. 187-199
- [15] Khomfoi S, Tolbert Leon M. Fault diagnosis and reconfiguration for multilevel inverter drive using AI-based techniques. *IEEE Transactions on Industrial Electronics*, 2007, 54(6): 2954-2968
- [16] Girolami M, Rogers S. Hierarchic Bayesian models for kernel learning. In: Proceedings of the 22nd International Conference on Machine Learning, Bonn, Germany, 2005. 241-248
- [17] Albert J, Chib S. Bayesian analysis of binary and polychotomous response data. *Journal of the American Statistical Association*, 1993, 88: 669-679
- [18] Girolami M, Zhong M. Data integration for classification problems employing Gaussian process priors. In: Proceedings of the 2006 Conference on Advances in Neural Information Processing Systems 19, Cambridge, MA, 2007. 465-472
- [19] Damoulas T, Girolami M A. Probabilistic multi-class multi-kernel learning: on protein fold recognition and remote homology detection. *Bioinformatics*, 2008, 24(10): 1264-1270
- [20] Damoulas T, Girolami M A. Combining feature spaces for classification. *Pattern Recognition*, 2009, 42(11): 2671-268

Fault diagnosis method in cascade H-bridge multilevel inverter system based on MRVM

Wang Tianzhen * ** , Qi Jie * , Xu Hao * , Tang Tianhao *

(* Department of Electrical Automation, Shanghai Maritime University, Shanghai 200135, China)

(** SIG Group, Naval Academy Research Institute of France, Brest 29240, France)

Abstract

In order to realize the fault diagnosis for cascade H-bridge multilevel inverter systems and improve the accuracy and the speed of fault diagnosis, a new fault diagnosis method based on the MRVM (multiclass relevance vector machine) model was proposed on the basis of the study of the fault characteristics of multi level inverter systems. This method takes the output voltage of a inverter system as the input fault signal, preprocesses the fault signal through the fast Fourier transform (FFT) to reduce the influence of noises and decrease the test time, and then adopts the E-step and the expectation maximization (EM) to infer the fault classifier model of MRVM. Diagnostic outputs are the probability of each fault category, the fault type with the highest probability is taken as the diagnosis result. The experimental results show that the diagnosis method has the higher computing efficiency and the higher diagnosis accuracy in fault diagnosis for cascade H-bridge multilevel inverter systems.

Key words: multiclass relevance vector machine (MRVM), cascaded H-bridge, inverter system, fault diagnosis