

基于 PCA-BLS 的逆变器故障诊断

苏家懿, 崔博文

(集美大学轮机工程学院, 福建 厦门 361021)

[摘要] 为了确保电气设备的安全可靠运行, 提出基于主成分分析法与宽度学习系统的逆变器故障诊断方法。利用主成分分析法对逆变器输出的电流信号进行处理, 提取信号特征; 构建宽度学习系统, 并编写不同故障模式下的故障编码; 利用不同故障模式下的信号特征对宽度学习系统进行训练, 利用网络输出编码实现故障分类。仿真结果表明, 该研究方法在诊断准确率及训练时间方面优于传统的神经网络故障诊断方法。

[关键词] 逆变器故障; 主成分分析法; 宽度学习; 神经网络; 故障诊断

[中图分类号] TM 464

Inverter Fault Diagnosis Based on Broad Learning System

SU Jiayi, CUI Bowen

(School of Marine Engineering, Jimei University, Xiamen 361021, China)

Abstract: In order to ensure the safety and reliability of the electrical equipment during operating, the paper proposes a new inverter fault diagnosis method based on principal component analysis (PCA) and broad learning system (BLS). Firstly, the current signal of the inverter was processed by using PCA method, and the signal characteristics were extracted. Secondly, the BLS was constructed and the fault coding under different fault modes were obtained. Finally, the BLS network was trained by using the signal characteristics with different fault modes, and the fault classification was realized by using the network output coding. The simulation results show that the method proposed in the paper is superior to the traditional neural network in terms of diagnosis accuracy and training time.

Keywords: inverter fault; principal component analysis; broad learning system; neural network; fault diagnosis

0 引言

随着电力电子技术的持续发展, 逆变器供电的电动机驱动系统被广泛应用于机器人、新能源汽车、高铁、船舶、航空航天等各种工业系统中。在这些工业系统中, 逆变器承担着电能变换功能, 对系统的正常运行起着关键作用。然而, 逆变器中的开关器件极易发生开路或短路故障^[1], 开关器件发生故障会引起驱动系统无法正常工作, 严重情况下会导致灾难性事故发生。因此, 为了提高电机驱动系统的可靠性, 避免重大灾难性事故发生, 研究逆变器故障诊断就显得十分必要。

[收稿日期] 2020-9-28

[基金项目] 国家自然科学基金项目(51779102)

[作者简介] 苏家懿(1995—), 女, 硕士生, 从事智能信息处理和电力系统故障诊断研究。通信作者: 崔博文(1966—), 男, 教授, 博士, 从事电力系统状态监控与参数估计研究。

<http://xuebaobangong.jmu.edu.cn/zkb>

逆变器中的开关器件发生故障后, 其输出的相电压或电流波形会出现明显的异常现象。文献 [2] 利用仿真获得了开关器件故障后的相电流及转矩波形, 通过与系统无故障状态下的相电流和转矩波形对比, 实现了逆变器故障诊断。由于仿真难以完全模拟系统实际运行的各种工况, 而系统在载荷突变或频率改变时, 通过波形对比更难以有效实现故障诊断。为克服这种现象, 文献 [3] 利用小波变换对逆变器输出的相电压信号进行处理, 将得到的小波系数和小波能量作为故障特征, 利用误差后向传递神经网络 (back-propagation neural network, BPNN) 实现故障诊断, 但该方法计算所花费的时间过长, 难以实现在线故障诊断。针对这种情况, 文献 [4] 对得到的小波系数和小波能量进行处理, 获得包含主要故障特征的特定低频段信息, 利用 BP 神经网络实现故障诊断。文献 [5] 利用小波包分析对逆变器输出的相电压波形进行处理, 得到小波包分解后输出电压信号的细节, 通过频谱特征和功率谱识别逆变器故障, 但是, 在系统运行频率改变时, 逆变器输出电压信号频谱特征会相应发生变化, 该方法有可能会失效。文献 [6] 利用小波包分析对逆变器输出电压信号进行处理, 获得小波能量作为故障特征, 进一步利用主成分分析法对故障特征进行降维, 利用降维后的故障特征构建故障向量, 并以此训练 BP 神经网络, 实现故障诊断。考虑到 BP 神经网络存在局部收敛的问题, 容易陷入局部极小点而无法得到全局最优解, 研究者^[7]进一步提出了更有效的宽度学习系统 (broad learning system, BLS), 与传统的 BP 神经网络分层网络架构不同, BLS 网络是一种扁平式网络架构, 其计算高效、结构灵活, 利用结构增量式学习算法, 可有效降低训练样本数量, 同时可有效减少训练时间和训练误差^[8-9]。

在现有研究基础上, 本文在 MATLAB/Simulink 环境下, 建立逆变器供电的电动机驱动系统仿真模块, 利用主成分分析方法对逆变器输出的三相电流信号进行处理, 获取逆变器故障特征, 并分别利用 BLS 网络和 BP 网络对故障进行分类, 研究结果验证了本文研究方法的有效性。

1 逆变器故障模式

三相电压型逆变电路驱动系统如图 1 所示。其中: 逆变器由 6 个开关器件 V_1 、 V_2 、 \dots 、 V_6 构成; D_1 、 D_2 、 \dots 、 D_6 为与开关器件反并联的二极管。通过控制逆变器中开关器件的通断, 就可以实现 DC-AC 变换。逆变器最容易发生的故障是开关器件短路和开路故障。短路故障是一种非常致命的故障, 往往需要采取特殊保护措施。为避免短路故障发生,

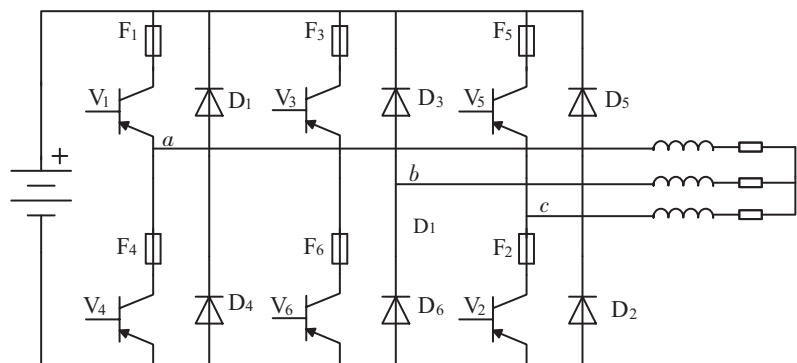


图 1 逆变器电路图

Fig.1 Inverter circuit

一般采取每个开关器件串联一个熔断器的措施来加以解决, 如图 1 所示, F_1 、 F_2 、 \dots 、 F_6 为与开关器件串联的熔断器。因此, 短路故障就等同于开路故障。开路故障虽然不会导致系统停机, 但如果任由开路故障发生而不去立即处理, 就会引起逆变器或其他器件发生二次故障, 最终导致系统停机^[10]。因此, 本文主要研究开关器件开路故障诊断, 所考虑的开关器件开路故障指任意时刻有 1 个或 2 个开关器件发生开路故障。对于任意时刻 1 个开关器件发生故障情形, 有 6 种故障模式, 对于任意时刻 2 个开关器件发生故障情形, 有 15 种故障模式。为便于研究, 将无故障模式看作特殊故障模式, 这样, 本文研究的故障模式总数就有 22 种。

为研究方便, 特制定故障编码, 故障模式与故障编码之间的关系如表 1 所示。

表 1 故障类型及编码
Tab. 1 Fault type and code

故障序号 Fault number	故障类型 Fault type	故障编码 Fault code	故障序号 Fault number	故障类型 Fault type	故障编码 Fault code
0	无故障 Fault-free	00000	11	V ₁ 和 V ₆ 故障 Fault	01011
1	V ₁ 故障 Fault	00001	12	V ₂ 和 V ₃ 故障 Fault	01100
2	V ₂ 故障 Fault	00010	13	V ₂ 和 V ₄ 故障 Fault	01101
3	V ₃ 故障 Fault	00011	14	V ₂ 和 V ₅ 故障 Fault	01110
4	V ₄ 故障 Fault	00100	15	V ₂ 和 V ₆ 故障 Fault	01111
5	V ₅ 故障 Fault	00101	16	V ₃ 和 V ₄ 故障 Fault	10000
6	V ₆ 故障 Fault	00110	17	V ₃ 和 V ₅ 故障 Fault	10001
7	V ₁ 和 V ₂ 故障 Fault	00111	18	V ₃ 和 V ₆ 故障 Fault	10010
8	V ₁ 和 V ₃ 故障 Fault	01000	19	V ₄ 和 V ₅ 故障 Fault	10011
9	V ₁ 和 V ₄ 故障 Fault	01001	20	V ₄ 和 V ₆ 故障 Fault	10100
10	V ₁ 和 V ₅ 故障 Fault	01010	21	V ₅ 和 V ₆ 故障 Fault	10101

2 基于 PCA – BLS 的故障诊断方法

2.1 主成分分析法

主成分分析法 (principal component analysis, PCA) 是一种数据降维处理技术, 其基本思想是通过映射, 将一种 n 维特征数据映射为 m 维特征数据 ($m < n$)^[11]。通过映射得到的 m 维特征数据, 既保持了原有数据的基本特征, 同时又具有一种新的正交特性, 实现用少数主成分来描述原来的高维特征数据。

设三相逆变器输出的三相电流分别为 i_a, i_b, i_c , 通过采样, 每相电流各取 r 个值。将所获得的三相电流数据作为故障样本, 故障样本可表示为:

$$\mathbf{x} = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_k]。 \quad (1)$$

式中: $\mathbf{x}_i (i = 1, 2, \dots, k)$ 为每种故障样本, 该故障样本可表示为

$$\mathbf{x}_i = [i_a, i_b, i_c], \quad (2)$$

$$\begin{aligned} i_a &= [i_{a1}, i_{a2}, i_{a3}, \dots, i_{ar}], \\ i_b &= [i_{b1}, i_{b2}, i_{b3}, \dots, i_{br}], \\ i_c &= [i_{c1}, i_{c2}, i_{c3}, \dots, i_{cr}]. \end{aligned} \quad (3)$$

由于负载扰动及开关器件存在换相死区, 实际的逆变器输出电流信号包含有谐波干扰及其他无用的信息或噪声。为了更好地获取有用的故障特征, 运用 PCA 对故障样本数据进行处理。具体故障特征提取步骤如下。

1) 对于 n 维故障样本数据 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]$, m 为总的样本个数, 计算每个样本 \mathbf{x}_i 的均值:

$$\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i。 \quad (4)$$

2) 用样本均值来计算协方差矩阵:

$$\mathbf{P} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T。 \quad (5)$$

3) 计算样本协方差矩阵的特征值和特征向量:

$$\begin{aligned} \mathbf{P} &= \mathbf{Q}\mathbf{\Lambda}\mathbf{Q}^T; \\ \mathbf{\Lambda} &= \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d), \lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0; \\ \mathbf{Q} &= [\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n]。 \end{aligned} \quad (6)$$

式中: $\mathbf{\Lambda}$ 为协方差矩阵; $\lambda_1, \lambda_2, \dots, \lambda_n$ 为特征值; \mathbf{Q} 为特征矩阵; $\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_n$ 为特征向量。

4) 用特征值和特征向量计算前 m 行主元素的累计反差贡献率:

$$\xi = \sum_{i=1}^m \lambda_i / \sum_{j=1}^d \lambda_j. \quad (7)$$

式中: ξ 为累计反差贡献率, 通常大于或等于 0.9。

选取特征矩阵 Q 前 m 个特征向量构建矩阵 Q_m , 利用式 (8) 实现 m 维故障样本数据提取:

$$Y = Q_m X. \quad (8)$$

式中: Q_m 是由 m 行特征值 ($m < n$) 组成的特征矩阵; X 是 n 维故障样本数据; Y 是 m 维故障样本数据。

2.2 宽度学习系统

宽度学习系统 (BLS) 是在随机向量函数链接神经网络 (random vector functional-link neural network, RVFLNN) 基础上发展的一种扁平神经网络结构^[12]。通过对 RVFLNN 中的隐层进行特殊运算, 形成增强层, 增强层与原有的输入层一起并列到同一层, 而输出层节点直接与所有映射的输入层特征节点和增强层节点相连, 这样就形成“扁平”化的网络结构。由于减少了隐层, 使得层间反向求导和迭代更新所花费的时间大大减少, 提高了网络运行效率。更重要的是, BLS 通过快速的增量学习来扩展网络结构, 而无需进行全面完整的网络再次训练, 更进一步减少了计算的冗余性和网络训练时间。图 2 为随机向量函数链接神经网络, 该网络由输入层、增强层和输出层构成, 图中的权值 W 为输入层及增强层节点到输出层节点之间的权值系数。如果将 RVFLNN 的增强层与输入层并列到同一层, 形成新的输入层, 就实现了网络向“宽度”方向扩展, 扩展后的网络就成为宽度学习系统网络结构, 如图 3 所示, 图中的权值 W_k 为输入层节点到输出层节点之间的权值系数。




图2 函数链接神经网络

Fig.2 A functional-link neural network

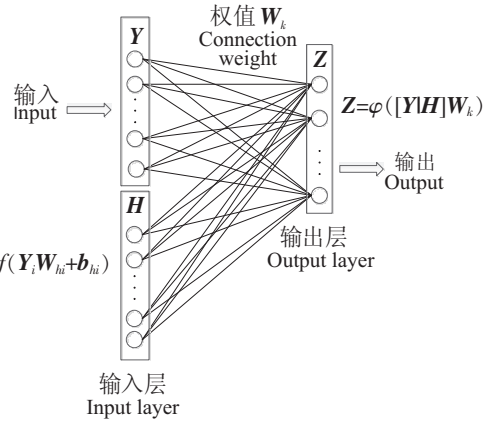


图3 宽度学习系统网络结构

Fig.3 Framework of BLS

电流故障样本数据经过 PCA 特征提取后, 可得到数据样本 Y_i , 将其作为 BLS 的输入数据。因此, 输入层任意第 i 种电流故障数据样本表示为:

$$Y_i \in [Y_1, Y_2, \dots, Y_m], i = 1, \dots, m. \quad (9)$$

增强层第 i 个节点的输出可表示为:

$$H_i = f(Y_i W_{hi} + b_{hi}), i = 1, \dots, m. \quad (10)$$

式中: W_{hi} 和 b_{hi} 分别为对应节点的随机权重和随机偏移量; f 表示神经网络激活函数。

最终输出层可表示为:

$$Z = \varphi([Y|H] W_k). \quad (11)$$

式中: W_k 表示连接输出层权重; φ 表示神经网络激活函数, 本文均采用 Sigmoid 函数。

为了减少网络训练过程中的过拟合现象, 需要计算总误差:

$$E(W^{n+m}) = \sum_{t=1}^k \|\sigma_t - \delta_t\|^2 / 2. \quad (12)$$

式中: \mathbf{W}^{n+m} 表示输出层权重; σ 和 δ 分别表示整个系统中的实际输出和预期输出; k 表示输出的故障样本数。

网络中使用了梯度下降算法, 分别对权值 \mathbf{W} 和偏移量 \mathbf{b} 进行更新。通过推导误差函数得到给定点的梯度。

$$\Delta \mathbf{W} = -\eta \partial E / \partial \mathbf{W}。 \quad (13)$$

由式 (13) 可推出 \mathbf{W}^{n+m} 的更新方程为:

$$\mathbf{W}_{t+1}^{n+m} = \mathbf{W}_t^{n+m} + \eta \partial E(\mathbf{W}_t^{n+m}) / \partial \mathbf{W}_t^{n+m} = \mathbf{W}_t^{n+m} + \eta \mathbf{E}'(\mathbf{W}_t^{n+m})。 \quad (14)$$

式中: η 表示步长参数, 用于根据误差程度调整权重。

综上所述, BLS 的方法主要有以下几个步骤: 1) 对输入数据进行线性变换, 形成特征节点; 2) 特征节点通过非线性变换, 随机生成一个增强节点; 3) 所有的特征和增强节点都直接连接到输出层; 4) 对权值进行更新, 以降低误差; 5) 得到相应的输出权值。

3 仿真分析

在 MATLAB/Simulink 环境中搭建三相逆变器驱动的电系统仿真模块, 仿真中直流电压为 600 V, 采用 PID 控制方法。故障数据采样时长为 1 s, 采样间隔时间为 0.05 s, 采集得到三相逆变器输出电流信号, 每一相有 21 个数据。通过 PCA 特征提取, 将三相逆变器故障数据尺寸从 63×22 降低到 20×22 , 设置训练步长为 0.01, 最高训练次数为 2 000 次。

图 4 为 BLS 与 BP 迭代次数与训练误差之间的关系曲线。从图 4 中可以看出, 刚开始时, BLS 的训练误差减少速度较慢, 但是随着迭代次数的增加, 其训练误差迅速减小, 在迭代次数达到 2 000 次后, 其训练误差几乎为零, 而 BP 网络仍然存在较大的训练误差。

表 2 为迭代次数相同时两种方法输出结果需要耗费的时间。从表 2 中可得, 当迭代次数为 1 000 次时, BP 训练和测试所用的时间大约是 BLS 的 3 倍; 当迭代次数为 2 000 次时, BLS 训练和测试所用的时间约为 BP 的 2/5。




图 4 迭代次数与训练样本误差的关系

Fig.4 Relationship between epochs and errors

表 2 用时比较

Tab.2 Comparisons of the time consumed

迭代次数 Iterations/次	PCA - BLS 用时 Computing time by using BLS/s	PCA - BP 用时 Computing time by using BP NN/s
1000	0.103	0.314
2000	0.190	0.498

为了验证 PCA - BLS 故障诊断方法的有效性, 在测试样本数据中分别加入不同信噪比的高斯白噪声干扰, 并与传统的 BP 神经网络诊断结果进行比较。两种方法的网络训练迭代次数均为 2 000 次, 实验结果如表 3 所示。从表 3 可以看出, 随着信噪比的增加, 其准确率逐渐上升, 且在各种噪声干扰条件下, BLS 的故障诊断准确率总是优于 BP。当信噪比为 40 dB 时, BLS 的准确率可达到 100%, 而 BP 的准确率只有 95.45%, 因此, 在故障分类准确率及抗噪能力方面, BLS 明显优于 BP 神经网络。

表3 两种方法准确率比较
Tab.3 Comparisons of accuracies determined by two methods

信噪比 Signal to noise ratio/dB	PCA-BLS 准确率 Accuracy by using BLS/%	PCA-BP 准确率 Accuracy by using BP NN/%
10	36.36	18.18
20	68.18	50.00
30	95.45	86.36
40	100.00	95.45

4 结论

针对逆变器存在的开关器件开路故障问题, 提出一种基于主成分分析和宽度学习系统的逆变器故障诊断方法。根据不同开关元件开路故障模式, 建立对应故障编码。在 MATLAB/Simulink 环境下, 搭建了逆变器供电的电动机驱动系统仿真模型。利用主成份分析方法对逆变器输出的三相电流进行处理, 获得故障样本数据。建立了宽度学习网络系统, 利用获得的故障样本数据对宽度学习系统进行训练, 通过宽度学习网络系统的输出编码, 实现了开关元件开路故障诊断。为了验证本文研究方法的有效性, 在故障样本数据中增加不同信噪比噪声干扰, 分别对宽度学习系统和传统的 BP 神经网络进行训练, 网络输出结果表明, 本研究方法的故障诊断准确率优于传统的 BP 神经网络。

[参考文献]

- [1] YANG S, XIANG D, BRYANT A, et al. Condition monitoring for device reliability in power electronic converters [J]. IEEE Transactions on Power Electronics, 2010, 25(11): 2 734-2 752.
- [2] SPEE R, WALLACE A K. Remedial strategies for brushless dc drive failures [J]. IEEE Trans Ind Applica, 1990, 26(2): 259-266.
- [3] ZIN A A M, SAINI M, MUSTAFA M W, et al. New algorithm for detection and fault classification on parallel transmission line using DWT and BPNN based on Clarkes transformation [J]. Neurocomputing, 2015, 168: 983-993.
- [4] HUANG ZH, WANG ZH, ZHANG H. A diagnosis algorithm for multiple open-circuited Faults of microgrid inverters based on main fault component analysis [J]. IEEE Trans Energy and Conversion, 2018, 33(3): 925-937.
- [5] 周晨阳, 沈艳霞. 基于小波分析的二重三相电压型逆变器开路故障诊断 [J]. 电机与控制学报, 2020, 24(9): 65-75.
- [6] 宋保业, 徐继伟, 许琳. 基于小波包变换-主元分析-神经网络算法的多电平逆变器故障诊断 [J]. 山东科技大学学报 (自然科学版), 2019, 38(1): 111-120
- [7] CHEN C L P, LIUZH. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture [J]. IEEE Trans Neural Networks and Learning Systems, 2018, 29(1): 10-24
- [8] 贾晨, 刘华平, 续欣莹, 等. 基于宽度学习方法的多模态信息融合 [J]. 智能系统学报, 2019, 14(1): 150-157.
- [9] FENG J, YAO Y, LU S, et al. Domain knowledge-based deep-broad learning framework for fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2021, 68(4): 3454-3464.
- [10] ESTIMA J O, CARDOSO A J M. A new algorithm for real-time multiple open-circuit fault diagnosis in voltage-fed PWM motor drives by the reference current errors [J]. IEEE Trans Ind Elec, 2013, 60(8): 3496-3505.
- [11] ZHAO H, ZHENG J, XU J, et al. Fault diagnosis method based on principal component analysis and broad learning system [J]. IEEE Access, 2019(7): 99 263-99 272.
- [12] CHU F, LIANG T, CHEN C L P, et al. Weighted broad learning system and its application in nonlinear industrial process modeling [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(8): 3 017-3 031.

(责任编辑 陈 敏 英文审校 郑青榕)