

基于 BP 神经网络和小波包能量熵的异步电动机故障诊断

郭昱君¹, 王爱元^{1,2}, 姚晓东^{1,2}

(1. 上海电机学院 电气学院, 上海 201306;

2. 佛山市高明区明戈新型电机电控研究院, 广东 佛山 528500)

摘要: 为了高效解决异步电动机故障问题, 提出了一种基于反向传播 (BP) 神经网络和小波包能量分析的异步电动机故障诊断系统。采用定子电流信号作为异步电动机的故障信号, 运用小波包能量分析对采集的定子电流信号进行分析, 提取出相应的故障特征向量。为了提高诊断的准确性, 提取信号时域、频域的特征, 输入到 BP 神经网络中进行训练学习。经过足够多的训练后, 用测试样本对其精确率进行测试。通过所提方法, 可以及时排除及修正异步电动机故障, 提高工厂的经济效益。

关键词: 异步电动机; 小波包分析; 反向传播神经网络; 故障诊断

中图分类号: TM343 文献标志码: A 文章编号: 1673-6540(2022)10-0053-07

doi: 10.12177/emca.2022.105

Fault Diagnosis of Asynchronous Motor Based on BP Neural Network and Wavelet Packet Energy Analysis

GUO Yujun¹, WANG Aiyuan^{1,2}, YAO Xiaodong^{1,2}

(1. School of Electrical Engineering, Shanghai Dianji University, Shanghai 200120, China;

2. Mingge New Type Motor Electronic Control Research Institute, Gaoming District, Foshan City, Foshan 528500, China)

Abstract: In order to efficiently solve the problem of asynchronous motor fault, a fault diagnosis system of asynchronous motor based on back-propagation (BP) neural network and wavelet packet energy analysis is proposed. The stator current signal is used as the fault signal of asynchronous motor, and the collected stator current signal is analyzed by wavelet packet energy analysis to extract the corresponding fault feature vector. In order to improve the accuracy of diagnosis, the time-domain and frequency-domain features of signals are extracted and input into BP neural network for training and learning. After enough training, the accuracy is tested with test samples. Through the proposed method, the faults of asynchronous motor can be eliminated and corrected in time, and the economic benefits of the factory can be improved.

Key words: asynchronous motor; wavelet packet analysis; back-propagation (BP) neural network; fault diagnosis

0 引言

异步电动机作为工业生产中不可或缺的设备, 因其具有结构简单、成本低、效率高的优点, 被广泛

应用于多种领域。异步电动机故障诊断也成为工业生产中备受关注的问題, 一旦电动机发生故障, 工业生产的整个环节均会受到相应的影响, 工厂的经济效益也会降低。因此, 异步电动机故障的及时

收稿日期: 2022-06-19; 收到修改稿日期: 2022-08-26

作者简介: 郭昱君(1998—), 女, 硕士研究生, 研究方向为大型电机的远程状态检测、优化与控制。

诊断具有重要意义。本文选取了3个异步电动机常见故障,分别为异步电动机的转子断条、定子匝间短路以及气隙偏心故障,将这3个类型的故障作为研究对象,对异步电动机进行故障诊断研究。

传统的异步电动机故障诊断根据采集到的信号进行相应的频谱分析,由于采集的信号一般为振动信号或者定子电流信号,均属于非平稳信号,含有许多的干扰信号,无法精确地判断出故障的类型。国内外的研究学者针对该领域也有所研究。文献[1]的研究对象为三相电机故障,采集电机故障时的振动信号进行时域、频域分析,对故障的类型以及影响进行了研究。该方法先对信号进行快速傅里叶变换(FFT),再对不同频段内的细节信号处进行频谱分析,过程过于繁琐、费时。文献[2]的研究对象为无人机,主要研究飞行器电机故障和角速度传感器故障,通过FFT分析法对故障信号进行处理,提取出时域、频域的特征,再通过概率神经网络进行故障分类。由于故障信号的干扰因素过多,直接进行FFT分析会使结果不够精确。文献[3]的研究对象为机械设备故障,对故障设备的振动信号进行提取,通过FFT分析法,对机械设备及时进行故障诊断。虽然FFT分析法实时高效,但是对于振动信号这种不稳定的信号,很多时候其诊断结果不够精确。文献[4-7]研究的均为电机的各种故障,对于提取到的故障信号运用了小波分析法进行处理,提取到相应的故障特征再进行后续的诊断工作。为了减少干扰,通过小波分析可使研究结果更加准确。但是,小波变换对于高频信号处理不够敏感,所以该方法还存在一定的改进空间。

综上所述,本文采用了小波包能量分析的方法,对提取出的定子电流故障信号进行小波包分析能量重构,得出故障特征向量。为了使结果更加精确,本文还提取了定子电流信号的时域和频域特征,共同作为故障特征。BP神经网络具有很好的学习能力和自适应能力,且出错率很低,被广泛应用于故障诊断领域。因此,将小波包分析与BP神经网络结合,对异步电动机的故障进行研究。

1 异步电动机故障

异步电动机有多种故障类型。故障可以分为电气故障和机械故障^[8]。电气故障包括定子匝间

短路故障;机械故障包括转子断条、气隙偏心以及轴承故障。本文主要对以上几类故障进行研究,提取故障特征,对故障进行分类。

在电机故障中,转子断条故障占很大比例,属于常见故障。转子导条在电动机工作时,会受到各种应变力的影响,这种应力随着电动机的运转起停和负载高低而变化^[9]。转子本身在生产制造的过程中也存在不足,会使电动机出现转子断条故障。

异步电动机在工作中承受各种应变力的作用,定子绕组匝间容易损坏。定子绕组破损的程度会随着时间的增加变得更加严重。匝间短路电流持续增大,使得损坏的一部分电路处温度上升,造成更大范围的短路,导致电动机无法运行^[10]。

气隙偏心故障也是常见的电机故障之一,主要是由其他故障引起的连锁反应,比如定、转子的故障和轴承的故障等。一旦气隙偏心过大,将会严重影响电动机的运行^[11]。

2 基于小波包能量熵的故障特征提取

2.1 小波包能量熵

小波包能量熵结合了小波包分析和信息熵,可以用来定位和检测故障信号,还可以用来描述系统的不确定程度^[12-14]。相比于小波分析,小波包分析能够处理小波分析无法解决的高频、非线性、非平稳信号的问题。当异步电动机发生故障时,采集的定子电流信号是非平稳的信号,而采集的信号拥有所需要的故障信息,这时故障状态的不确定性大于正常状态下的不确定性,小波包能量熵比正常状态下增加^[15-16]。因此,本文选择小波包能量熵作为故障特征。该算法的定义为

$$E_{j,k} = \left| \int_{-\infty}^{\infty} S_{j,k} dt \right|^2 = \sum_{j \in z} \sum_{k \in z} |d_{j,k}(n)|^2 \quad (1)$$

式中: S 为原始信号; $S_{j,k}$ 为小波包重构信号; j 为小波包分解层数, $j=1,2,3,\dots,n$; k 为第 j 层第 k 个节点, $k=1,2,3,\dots,m$; $E_{j,k}$ 为重构信号对应的能量; $d_{j,k}(n)$ 为小波包分解后节点 (k,j) 对应的第 n 个小波包系数。

归一化的公式为

$$\begin{cases} E = \left(\sum_k^{2j-1} |E_{j,k}|^2 \right)^{\frac{1}{2}} \\ \lambda_{j,k} = \frac{E_{j,k}}{E} \end{cases} \quad (2)$$

式中： E 为 k 层节点的总能量； $E_{j,k}$ 为第 k 层分解的 j 节点的小波包能量熵； $\lambda_{j,k}$ 为第 k 层分解的 j 节点的归一化值。

2.2 故障特征的提取

在异步电动机发生故障时,定子电流会发生相应的改变,所以采集故障状态下的定子电流信号进行分析。针对转子断条、定子匝间短路以及气隙偏心这3种故障进行电磁场有限元仿真。

2.2.1 电机故障电磁场有限元仿真

本文选用2.2 kW的鼠笼式异步电动机为研究对象,具体参数如表1所示。

表1 异步电动机的主要参数

参数名称	参数值
极对数	2
定子槽数	36
转子槽数	28
额定电压/V	380
额定频率/Hz	50
额定转速/(r·min ⁻¹)	1 458

将正常状态以及3种故障状态分别进行仿真。正常状态下的仿真模型如图1所示。转子断条仿真如图2所示,通过设置转子导条的材料,采用令材料的电导率为零的方法模拟断条。如图3所示,设置定子A相绕组短路线圈所在的槽号为1号和9号。如图4所示,气隙偏心故障为定、转子不同心,旋转中心为定子轴,设置偏心为0.02 mm。正常状态下槽内为43匝线圈,故障模型设定槽内20匝线圈出现匝间短路,对应图5外电路20匝线圈短路标识,剩余23匝线圈与A相绕组的其他线圈串联接入。




图1 正常电动机

分别提取正常状态、转子断条、定子匝间短路以及气隙偏心故障下的定子电流信号,仿真得到4种状态下的A相定子电流波形图如图6~图8所示。




图2 转子断条




图3 定子匝间短路




图4 气隙偏心



图5 定子匝间短路外电路图




图6 转子断条

如图6所示,转子断条的波形与正常状态下的A相定子电流有细微的不同;如图7所示,定




图7 定子匝间短路




图8 气隙偏心




图9 电动机正常时小波包重构电流信号




图10 转子断条故障小波包能量重构电流信号

子匝间短路的波形起伏比转子断条明显;图8中的偏心故障波形变化最为剧烈,所以通过定子电流信号的变化能够对故障状态进行辨别。但是仅仅凭借波形图的变化结果分析故障类型不够准确,所以需要采集到的定子电流信号进行小波包分析,分析结果如图9~图12所示。根据以往的电机故障研究可知,故障发生的频段一般是在电源频率的分数倍或者整数倍处,选择db8小波对A相定子电流信号进行3层小波包分解,可以从中提取能量不同的8个信号频段,得到相应的故障特征向量输入到后续的神经网络中。

图9为电动机正常时波形重构的每个频段的状态。图9(a)为正常状态下去除干扰信号后的波形,与仿真所得的波形相比,其波形明显变得更加平滑,去除了多余的毛刺影响。转子断条和定子匝间短路的小波包分解波形与原始波形也是




图 11 定子匝间短路的小波包能量重构电流信号




图 12 气隙偏心的小波包能量重构电流信号

如此。对比这 4 种状态下的每个频段处的波形可以发现,在不同的频段,不同故障的能量也不尽相同。因此,在特征提取上采用小波包分析进行信号处理比直接进行信号处理更加准确。故障时的小波包能量会比正常的状态高很多,凭借此特性

可以区分出电机正常与故障状态以及故障的类型,为后续的 BP 神经网络训练做铺垫。经过小波包能量重构得到的故障特征向量如表 2 所示,此处列举了 4 个状态下的特征向量,分别是正常、转子断条、匝间短路以及气隙偏心。

表 2 故障特征向量

故障类型	重构节点							
	(3,0)	(3,1)	(3,2)	(3,3)	(3,4)	(3,5)	(3,6)	(3,7)
正常	0.991 42	0.002 07	0.006 35	0.000 05	0.000 04	0.000 04	0.000 01	0.000 02
转子断条	0.891 79	0.106 60	0.000 43	0.000 51	0.000 51	0.000 11	0.000 02	0.000 02
匝间短路	0.888 47	0.105 74	0.000 86	0.002 54	0.002 30	0.000 07	0.000 01	0.000 02
气隙偏心	0.891 80	0.105 74	0.000 29	0.001 07	0.001 04	0.000 02	0.000 01	0.000 03

从表 2 可以看出,每个故障在各个频段处的特征向量都会发生变化,变化最为明显的有两个节点为(3,1)和(3,3),其他许多节点处的特征向量也呈现细微的不同。因此,借助小波包分解得到的特征向量对故障识别的方式是行之有效的,可以在保证精确的基础上过滤掉不必要的信息量,且节省诊断时间。

3 基于 BP 神经网络的诊断模型

3.1 BP 神经网络

BP 神经网络是传统的神经网络,也是目前发展比较成功的神经网络之一,被广泛用于机器学习。BP 神经网络是误差反向传播的多层前馈型网络,会根据每一次的训练值和预测值进行误差分析。BP 神经网络的模型如图 13 所示,其由输入层、隐藏层和输出层组成。将采集的信号正向输入到网络中,经过学习和训练,误差原路返回,不断修改相应的权值与阈值,逐步减小误差,得到与预期结果一致的模型。




图 13 BP 神经网络模型

本文采用 BP 神经网络建立故障诊断模型,具体流程如图 14 所示。选择小波包分析作为信号处理的方式,处理 3 种故障状态下采集的信号,得到故障特征向量,加上从时域、频域提取的特征,一并输入到 BP 神经网络中进行训练。




图 14 故障诊断流程图

3.2 故障诊断仿真

根据 Kolmogorov 定理,在合理的结构和恰当的权值条件下,3 层 BP 神经网络可以逼近任何一个非线性网络,所以本文采用 3 层网络进行研究。

将上一节中由小波包分析以及时域、频域提取的特征结果,直接输入到 BP 神经网络中进行模式识别。输入层的神经元个数由故障特征的数目决定,采集的定子电流信号经过信号处理后提取出 30 个故障特征,因此将 30 个神经元输入到输入层中,输出层的神经元个数由需要输出的目标值决定。本文研究的 3 种故障状态分别为转子断条、定子匝间短路和气隙偏心,所以输出层的神经元个数为 3 个,分别表示对应的期望输出向量,BP 神经网络的期望输出向量如表 3 所示。

表 3 期望输出向量

故障类型	期望输出		
转子断条	1	0	0
定子匝间短路	0	1	0
气隙偏心	0	0	1

BP 神经网络输入、输出层的选取都比较容易,难点在于隐藏层的选取,其会影响整个网络的性能。对于样本量少的数据集,隐藏层数选择 1 或 2,但如果数据集较为复杂,则需要选择更多层数的隐藏层。隐藏层的数量与拟合函数的能力在一定范围内成正比,这代表如果层数过多,反而会影响效果。根据已有的模型试验,选取 10 个节点数的隐含层较为合适,训练的函数选择 trainlm 函数,训练速度和误差结果能够达到预期效果。

本文在提取故障特征时,加入了时域、频域的特征。图 15 为仅提取小波包能量熵的训练结果,可以看出精确度不够高,只有 90.2%,将时域、频域特征加入特征向量能够提高结果的精确性。




图 15 分类结果

将提取出的特征向量输入网络,共 150 组样本数据,每种故障状态为 50 组,选择 100 组数据进行训练,剩下的 50 组数据作为测试数据,BP 神经网络在训练 22 次后能够达到预期目标。从图

16 可以看出,改进后方法的分类结果十分准确,分类精确度达到了 100%。根据上述分析可以得出,基于 BP 神经网络和小波包能量熵的方法确实能够更快、更准确地诊断出异步电动机故障类型。




图 16 改进后的分类结果

4 结 语

(1) 运用小波包分析和时域、频域分析作为信号处理的前置手段,效果十分明显,不仅过滤掉了不必要的信号,而且使得故障特征更加明显。

(2) 仿真结果表明,本文设计的基于 BP 神经网络和小波包能量熵的异步电动机故障诊断系统,能够准确地检测出发生的故障类型,诊断速度快且精度高。将其应用到工业生产中,可以减少电动机故障的发生,提高经济效益。

【参 考 文 献】

[1] 马文昌. 三相电机故障分析及诊断方法研究[J]. 防爆电机, 2021, 56(4): 61.

[2] 韩亮, 郭杰鹏, 卢国华. 基于改进 BP 算法的异步电机故障诊断[J]. 工业控制计算机, 2021, 34(2): 71.

[3] 李梦含, 李垣江, 夏炎, 等. 基于 LSTM 网络在时变转速鼠笼电机断条诊断中的应用[J]. 计算机与数字工程, 2021, 49(10): 2078.

[4] 田勇, 董国贵. 基于轻量级 CNN 的电机轴承故障诊断研究[J]. 齐齐哈尔大学学报(自然科学版), 2022, 38(1): 11.

[5] 戴连铭, 李春华. 基于小波包能量熵与 SVM 的电网故障诊断[J]. 计算机与数字工程, 2021, 49(10): 2126.

[6] 赵恒, 左金威, 瞿科. 基于小波包能量的漏电保护方案研究[J]. 四川电力技术, 2022, 45(1): 30.

[7] 张健, 张子阳, 起雪梅, 等. 基于 EMD 和 VPMCD 的滚动轴承故障诊断[J]. 机械设计, 2019, 36(S2): 91.

[8] HUANG N E, WU Z. A review on Hilbert-Huang transform; method and its applications to geophysical studies[J]. Reviews of Geophysics, 2008, 46(2): RG2006.

[9] 皮骏, 马圣, 贺嘉诚, 等. 基于 IGA-ELM 网络的滚动轴承故障诊断[J]. 航空学报, 2018, 39(9): 233.

[10] 罗丹. 基于 ReliefF-RF 的刀具磨损状态识别方法[J]. 信息技术与信息化, 2021(8): 102.

[11] 商航, 王炜富, 李雨寰. 数据融合下的异步电动机故障诊断[J]. 内燃机与配件, 2021(22): 131.

[12] MIN F, XUE J, MA F. Probabilistic neural network motor bearing fault diagnosis based on improved feature extraction[J]. Journal of Physics: Conference Series, 2020, 1684(1): 012158.

[13] GUO S, LI H, WU B, et al. Combined optimization of neural network fault diagnosis methods for analog circuits on ships[J]. Journal of Coastal Research, 2020, 99(sp1): 158.

[14] LIN S L. Application of machine learning to a medium gaussian support vector machine in the diagnosis of motor bearing faults[J]. Electronics, 2021, 10(18): 2266.

[15] YAN Y, LIU Q, GAO X. Motor fault diagnosis algorithm based on wavelet and attention mechanism[J]. Journal of Sensors, 2021, 2021: 3782446.

[16] YANG Z, KONG C, WANG Y, et al. Fault diagnosis of mine asynchronous motor based on MEEMD energy entropy and ANN[J]. Computers and Electrical Engineering, 2021, 92(4): 107070.

(上接第 26 页)

[11] ANTONELLO R, ORTOMBINA L, TINAZZI F, et al. Online stator resistance tracking for reluctance and interior permanent magnet synchronous motors[J]. IEEE Transactions on Industry Applications, 2018, 54(4): 3405.

[12] ZANUSO G, PERETTI L, SANDULESCU P. Stator reference frame approach for DC injection-based stator resistance estimation in electric drives[C]//2015 IEEE 11th International Conference on Power Electronics and Drive Systems, 2015.