

南京理工大学泰州科技学院

学院(系): 电子电气工程学院

题 目： 基于电机转速声音的电机状态检测

评阅者: 李宇 讲师

2023 年 5 月

毕业设计说明书（论文）中文摘要

针对传统的电机故障问题，本文提出了通过与保存训练好的 BP 神经网络模型进行对比分析，最终实现故障类型判断方法。该方法包括声音采集，声音处理，故障识别等几个部分。由于电机在运行过程中振动，吸声率低，声音向外发射。故障电机发出与正常运行的电机不同的声音。因此，识别电机的噪声特性是最简单和最直接的。通过处理声音信号并提取电机声信号频谱的特征。最后，使用各种误差样本测试该方法的有效性。从而满足基于电机转速声音对电机状态检测的要求。

关键词 声学特征 模型融合 卷积神经网络 电机 故障诊断

毕业设计说明书（论文）外文摘要

Title Motor state detection based on motor speed sound

Abstract

In response to the traditional problem of motor faults, this article proposes a method for determining the type of fault by comparing and analyzing it with a saved trained BP neural network model. This method includes several parts such as sound acquisition, sound processing, and fault identification. Due to the vibration of the motor during operation, the sound absorption rate is low and the sound is emitted outward. A normally running motor emits a different sound than a faulty motor. Therefore, identifying the noise characteristics of a motor is the simplest and most direct. By processing sound signals and extracting the characteristics of the motor sound signal spectrum. Finally, the effectiveness of this method is tested using various error samples. Thus meeting the requirements for motor state detection based on motor speed sound.

Keywords Acoustic characteristics Model fusion Convolutional neural network
Electric machinery Fault diagnosis

目 录

1 绪论	1
1.1 研究背景和意义	1
1.2 研究历史和现状	1
1.3 章节安排	2
1.4 章节小结	2
2 总体方案论证	3
2.1 系统方案实现	3
2.2 声音采集	4
2.3 声音处理	4
3 系统方案设计	6
3.1 声音采集原理	6
3.2 声音信号处理	6
3.3 故障识别	7
3.3.1 故障识别功能模块	8
3.4 BP 神经网络原理	8
3.4.1 BP 神经网络结构	8
3.4.2 BP 神经网络学习算法	9
3.4.3 BP 神经网络不足改进	13
3.4.4 BP 神经网络系统设计	14
3.5 本章小结	16
4 软件设计	17
4.1 小波分解计算能量特征	18
4.2 构建 BP 神经网络	20
5 实验结果	22
结束语	27
致 谢	28
参 考 文 献	29

1 绪论

1.1 研究背景和意义

随着科技的进步，社会生产力得到了很大的提高。传统的工业化生产已经从关注人类的基本需求转向了对品质的要求。在那个资源匮乏的时代，只要是符合人们生活需求的工业产品，都会被抢购一空。但现在，随着资源的普及，掌握技术的人也越来越多，类似的东西，已经出现了供不应求的局面。所以，更多的人开始注意品质需求，像是对材质、噪音、环境等方面的注意，这将是公司保持领先地位的关键。因此，在满足人们对应用需求的同时，企业还要不断地创新，确保产品的品质，从而在激烈的竞争中取胜。在当今经济全球化、商品化的时代，企业不仅要与国内的竞争者打交道，更要与国外的竞争者打交道。所以，对生产出来的产品进行严格的质量监督，就成了一个公司能否取得成功的重要原因。在产品的质量管理中，检验是非常重要的。因为这是一种有效的方法，可以提前防止出现故障。若能及时发现设备的异常状况，并对其进行有效的反馈，则可防止其进一步发展，从而减少损失。自从 19 世纪出现了发电机、马达之后，随着电力的普及，马达为人类提供了无穷无尽的能量，使人类摆脱了沉重的工作负担。电机的应用很广，从钢厂的轧钢机，到水厂的水泵，再到家用空调，洗衣机，再到人们佩戴的手表，都是由电机来驱动的。随着社会经济的发展，电动机在社会中的应用日益广泛，电动机的故障频繁出现，给人们的生产和生活带来了很大的影响。所以，有必要对电动机的质量进行检验和监测。

电机在当今的科技，农业，工业方面有着非常广泛的应用，而其中电机的转速控制又与生产生活息息相关，在工农业生产生活中，大量用到电机。随着计算机微电子技术朝着高精度高速发展，对电机故障诊断、检测要求越来越高，所以选择基于电机转速声音的电机状态检测的设计这一课题。

意义是有了检测系统，方便人们更好的了解机型性能，来更好地进行应用生产和生活，实现人机一体，提高效率，保护机器。

1.2 研究历史和现状

我国是一个生产大国，同时也是家用空调，电视机，冰箱，微波炉等家电的生产基地。光是家用空调机的产量就高达上亿。而这一切，都是由马达驱动的。目前，在小马达生产线上，一般都是靠人工听觉判断马达的好坏。这是一种很难做到的工作。但是，这种做法不仅会消耗企业大量的人力资源和培训资金，更重要的是，因为长时间的听诊，会让人产生疲劳感，很容易造成错误的判断，将劣质的产品留在了市场上，这不仅对企业的信誉造成了很大的影响，还给人们的日常生活带来了很大的不便。

直到上世纪 80 年代之后，人们才开始重视电动机的故障诊断和研究。本文的主要研究目标是，如何能够在电机工作的情况下，用一种方法来对其进行诊断，通过与电机有关的参数来判断电机是否存在或即将出现故障。并以此来判断何时需要维修，何时需要维修等等。

电动机的故障诊断和检测是指电动机在运行过程中的工作状况。可以通过检测电机的噪声、电压等参数的变化来判断电机的安全与否。如果出现了问题，那么就必须对问题所在的地方进行维修。该测定法是对以往所采用的测定电动机测定法的一种方法。过去，人们总是在一定的时间内到现场进行检修，而如今，只需要对电动机的有关参数进行检测，就可以判断电动机有没有出现故障。这种方法不仅能极大地提高工作效率，还能防止重大事故的发生，其作用越来越为工程师们所认可。

1.3 章节安排

第一章概述了电动机的发展背景，历史，国内外研究现状，并对电动机的故障诊断方法做了简要的介绍。

第二章，对系统的方案、所采用的各种技术的原理进行了阐述，并对系统的基本原则进行了简单的说明，为下文的方案论证打下了坚实的基础。

第三章论述了系统方案实现，对声音的采集，声音的处理，故障识别进行方案实施

第四章在第三章的基础上，完成了实验结果分析

第五章是论文的结论部分，主要是对本文的工作进行了总结，并对不同话筒间距下的各个位置参数进行了分析。

1.4 本章小结

在第一章中，主要阐述了该系统的发展历程、选题的意义、选题的内容、选题的目的。

2 总体方案论证

方案一：本设计方案主要包括电机声音信号的采集、处理以及故障识别三大模块。在声音传感器的选择上采用的是 MIC 传感器用于对声音信号到电信号的转换。声音处理主要包括声音去噪和特征提取两大模块，用于去除收集到的声音信号中的噪音和提取电机声音信号的特征。故障诊断模块用于将收集到的信号进行识别，利用 BP 神经网络对数据进行故障类型诊断。

方案二：在瞬时频率非平稳性信号的时域特性上，采用经典的时频分析方法可以得到该信号的时域特性。先选取两个不同状态的电机，一个为正常电机，一个为故障电机，将两个电机启动，使用声音传感器对两台电机进行声音采集，在声音信号转换成数字信号后，对两台电机的声波图像对比，从而完成基于对电机转速声音的电机状态检测。

经比较，方案一总体算法更为简单，BP 神经网络的优点和缺点，不管是在网络原理上，还是在性能上，都已经相对成熟。它最大的优势在于它既有强大的非线性映射能力，又有灵活的网络结构。结构更为清晰，便于多次重复实验比较结果，更能满足毕业设计的需求，所以选择方案一

2.1 系统方案论证

在声学采集方面，主要是利用 MIC 传感器对电动机在故障及运行时所发出的声学信息进行采集。在声学处理上，重点对声学信号进行预处理和提取特征值的计算，并对小波门限降噪方法和三级小波包分解和重建方法进行分析，从而得到特征值。最后，通过对提取出来的能量特征值进行归一化处理，将其转化为能量特征向量，并将其输入到系统下部的故障识别模块中，并与现有的 BP 神经网络模型进行对比，从而完成对故障类型的判断。最后，通过 MATLAB 软件模拟分析了所选择的算法的可行性及有效性。在图 2.1 中显示了系统的流程。




图 2.1 系统流程设计图

打开电机声音检测与故障诊断系统后显示登陆界面，登陆后显示主界面，主界面有声音采集、声音处理、故障识别三大模块、声音采集模块负责录制、保存。声音处理模块负责声音去噪、特征提取、故障识别模块负责构造特征向量、神经网络模型设计、分类输出。

2.2 声音采集

在进行声学故障诊断时，首先要解决的就是声学信号的采集问题。在选用声敏元件时，使用了一种 MIC 型声敏元件，在该声敏元件的内部含有一种由振膜、隔离物和极板组成的电容。由于 MIC 隔膜是带电的，因此在隔膜承受较大的声压时，隔膜会出现振动，从而改变隔膜与极板的间距，从而将声波信号转化为电信号。

2.3 声音处理

声音信号的处理分为两个部分，即声音的降噪和声音的特征提取。因为电机在声音信号传递的过程中，总是不可避免地会包含噪声，这会对声音信号处理和分析的精确性造成很大的影响，所以在开始之前，有必要先对其进行去噪处理。小波门限降噪是一种常用的

降噪方法，具有方法简单，计算量小，降噪效果好等优点。另外，为了降低前期的噪声，我们需要尽可能地减少计算量，所以我们使用了小波门限去噪的方法，我们使用了小波包的分解和重建算法来选择提出了一种基于小波变换的信号特征抽取算法。小波包是在常规小波分析基础上的一种改进，将常规小波分析不能进一步细分的高频成分进一步分解，使其具有更高的分辨率。

3 系统方案设计

3.1 声音采集原理

声音信号的采集是语音信号处理中的首要问题。本论文选用了 MIC 作为声敏元件，在它的内部，有一个由振动膜，隔离物和极板组成的电容元件。在其工作的时候，MIC 膜片上充有电荷，因此，当膜片受到声压强的影响时，就会发生振动，这样就会改变膜片与极板之间的距离，实现对声信号到电信号的转换。

3.2 声音信号处理

声学加工包括声学降噪和声学特性抽取两大部分。因为马达在传递信号时，总会不可避免地夹杂着一些噪声，因此，对信号的处理与分析的准确性，都会产生较大的影响。所以，在开始的时候，我们要做的就是消除噪声。由于小波理论的发展和实践的验证，使得小波降噪方法得到了广泛的关注。当前，小波降噪技术有多种，包括小波模式大值降噪、小波域相关性降噪、小波门限降噪等，但这三种降噪技术都有各自的优点和不足，其中，小波门限降噪技术是最常用的降噪技术之一，具有算法简单、计算量小、降噪效果好等优点。此外，在前期去除噪音时，需要尽可能地减少计算量，所以本文使用了一个小阈值方法来去除噪音。将小波包分解与重建方法用于信号特征抽取方法的选取。小波包分析是对小波包进行二次分解而得到的一种改进，该方法不需要对高频分量作进一步的细分。小波包分析实质上是一种多频段的信号处理方法，它在正常情况下、每个频段的构成都不相同，通常情况下，机车运行中的电机在发生故障时，其输出信号都会产生相应的变化。在此背景下，本项目拟从频谱成分的变化判断系统是否发生了故障，并结合系统的结构特点及失效机制，找到其特征频谱。在小波生成函数的选取中，根据对时间和频率的要求，对生成函数在时间和频率上的紧支集进行了研究，并对其进行了分析。其次，对重建结果的精度要求很高，因此对生成函数的正交性要求也很高。在此基础上，本文选取了 DB6 小波作为信号处理的依据。

小波包分解与重构算法如下:设 $f(x)$ 在子空间 U_j^n 中的系数为 $\{c_j^{n,k}, k \in Z\}$ ，则在子空间 U_{j+1}^{2n} 和 U_{j+1}^{2n+1} 中的分解系数 $\{c_{j+1}^{2n,k}, c_{j+1}^{2n+1,k}, k \in Z\}$ 为:

$$\begin{cases} c_{j+1}^{2n,k} = \sum_{l \in Z} h_{l-2k} c_j^{n,l} \\ c_{j+1}^{2n+1,k} = \sum_{l \in Z} g_{l-2k} c_j^{n,l} \end{cases} \quad (3.2)$$

从上述公式可以看出，小波包的分解处理，本质上就是利用一组高和低通的共轭正交滤波器 h 和 g ，把信号分解成各个频率段。

表 3.2 db6 小波滤波器系数 h_k

db6 小波滤波器系数 h_k					
K	db6 小波滤波器系数 h_k				
0	0.111540743350	4	-0.226264693965	8	-0.031582039317
1	0.494645890398	5	-0.129766867567	9	0.000553842201
2	0.751133908029	6	0.097501605587	10	0.001077301085
3	0.315250351709	7	0.027522865530	11	-0.001077301085

同理，设 $f(x)$ 在子空间 U_{j+1}^{2n} 和 U_{j+1}^{2n+1} 中的分解系数 $\{c_{j+1}^{2n,k}, c_{j+1}^{2n+1,k}, k \in Z\}$ 则在子空间 U_j^n 中的重构系数为 $\{c_j^{n,k}, k \in Z\}$ 为： $c_j^{n,k} = \sum_{l \in Z} h_{k-2l} c_{j+1}^{2n,l} + \sum_{l \in Z} g_{k-2l} c_{j+1}^{2n+1,l}$

将小波包分解的系数进行重建，并在每一个频段中提取出信号，从而获得每一个频段中的信号的总能量，其中，以三级小波包分解为例第 3 级，从低至高八个频段中的能量是：

$$E_j = \int |S_{3j}(t)|^2 dt = \sum_1^n |x_{j,k}|^2 \text{ 其中 } E_j (j = 0, 1, \dots, 7) \text{ 为 } S_{3j}$$

相应的能本征值 ($j=0, 1, \dots, 7$)；其中， $k=1, 2, \dots, n$ 是重建后的信号中的离散点的幅度， n 是取样点的数目。

一般地，当系统发生故障时，每个频段的信号特性都会发生很大的变化。

$$T = [E_1, E_2, E_3, E_4, E_5, E_6, E_7, E_8]$$

3.3 故障识别

目前常用的几种电机故障诊断方法有四种，其结果见表 3.3

表 3.3 故障识别方法对比

诊断方法	特点
------	----

信号变换	瞬时非正态检验，信号混杂，缺乏学习能力
专家系统	简单，而且可以快速读取诊断结果，但存在着规则不唯一性和难度大等问题
粗糙集理论	这种方法对不确定和不连续的数据进行了处理
神经网络	具备自我学习能力、非线性近似能力和自适应能力

经过综合考量，选择了 BP 神经网络作为该项目的诊断手段。

3.3.1 故障识别功能模块

故障识别功能模块主要用于将声音采集、声音处理后的信号通过 BP 神经网络判断故障类型，首先， Sigmoid 函数同时具有灵敏度与稳定性的双重优势，即信号在小尺度上的变化敏感，但在大尺度上的稳定，因此，它是一种非常有效的特征识别方法。其次，在进行错误反演时，对传递函数的可导性要求较高，不然将会对网络容量、学习速率等造成不利的影响。基于这个，变量 a 等于 1。在采集到新的电机声音数据之后，经过对声音信号的预处理，将数据输入到系统故障识别模块中，并与已经建立好的 BP 神经网络模型进行比对，从而得到对应的电机工作正常或故障状态。

3.4 BP 神经网络原理

在 1986 年， Rumelhart 等人提出了 BP（Back Propagation）神经网络，也就是错误反向传播神经网络，这种网络通过非线性可微分函数的形式，对多层神经元网络中隐层连接权进行学习训练，其核心思想是利用反向传播来不断地调整网络的权值和国值，从而使网络的误差最小。建立了 BP 神经网络的数学模型，因其具有变化形式多样、结构简单、可塑性强、数学意义清晰、学习算法过程清晰等特点，已成为人工神经网络中的一种重要模型。BP 神经网络在模式识别、函数近似、信息分类、数据压缩等领域有着重要的应用。

3.4.1 BP 神经网络结构

在图 3.4 中给出了一个标准的 BP 网络结构，从该图可以看出它是由三个构造单位构成的。网络的输入层，隐含层，输出层。每一层都由若干个神经元组成，每个神经元之间都有一个完整的互连模式。在此基础上，本文提出了一种基于小波变换的小波变换方法。




图 3.4 双隐含层神经网络结构示意图

3.4.2 BP 神经网络学习算法

该方法包括两个步骤，一个是前向传输，另一个是后向传输。该方法的基本思想是：在正向传递的过程中，输入信号受激系数的影响，由输入层经隐含层逐渐传递到输出层，然后再由相邻的各层神经元之间进行相关。在此基础上，对实际输出与预期输出的误差进行反演，并利用反演网络对各个层次的权重进行修正，直到实际输出与预期输出一致为止。

在本文中，我们将结合 3.4.1 部分的图 3.4 中所示的双隐含层神经网络模型，来说明 BP 算法的正向转移和错误的反向转移的处理方法。

为了便于描述，假设：

输入向量 $X = (x_1, x_2 \dots x_i, \dots, x_n)$

隐层输出向量为 $Y = (y_1, y_2 \dots y_j \dots y_m)$

输出层输出向量 $O = (o_1, o_2 \dots o_k, \dots, o_l)$

期望输出向量 $D = (d_1, d_2 \dots d_k, \dots, d_l)$

输入层到隐层的权值矩阵为 $V = (V_1, V_2 \dots V_j, \dots, V_m)$

隐层到输出层的权值矩阵为 $W = (W_1, W_2 \dots W_k, \dots, W_l)$

对于输出层有 $j = 1, 2, \dots, m, k = 1, 2, \dots, l$

对于输出层有 $i = 1, 2, \dots, n$, $j = 1, 2, \dots, m$

w_{jk} 和 v_{ij} 分别输入到隐层以及隐层到输出层的各层权值。

BP 神经网络是一种基于误差梯度的方法，它的计算过程如图 3.4 中所示。从流程中我们可以看到，BP 神经网络算法的关键在于寻找网络误差，并在此基础上对网络误差进行修正。




图 3.4 BP 算法流程图

推导步骤如下：

BP 算法的传递函数 f 采用了一个 Sigmoid 函数，则在输出层有如下关系

$$o_k = f(\varpi_k) \quad (3.4)$$

$$\varpi_k = \sum_{j=1}^m w_{jk} y_j \quad (3.5)$$

在网络的隐层有如下关系

$$y_j = f(\varpi_j) \quad (3.6)$$

$$\varpi_j = \sum_{i=1}^n v_{ij} x_i \quad (3.7)$$

如果网络的输出与预期的输出不一致，则会产生一个输出误差 E ，它的定义是

$$E = \frac{1}{2}(D - O)^2 = \frac{1}{2}\sum_{k=1}^L [d_k - o_k] \quad (3.8)$$

把（3.8）公式扩展到网络的隐含层，可以得出

$$E = \frac{1}{2}\sum_{k=1}^l [d_k - f(\varpi_k)]^2 = \frac{1}{2}\sum_{k=1}^l \left[d_k - f\left(\sum_{j=1}^m w_{jk} y_j\right) \right]^2 \quad (3.9)$$

然后，在网络的输入层中，将公式（3.9）进一步展开，可以得出

$$E = \frac{1}{2}\sum_{k=1}^l \left\{ d_k - f\left[\sum_{j=1}^m w_{jk} f\left(\sum_{i=1}^n v_{ij} x_i\right)\right] \right\}^2 = \frac{1}{2}\sum_{k=1}^l \left\{ d_k - f\left[\sum_{j=1}^m w_{jk} f\left(\sum_{i=1}^n v_{ij} x_i\right)\right] \right\}^2 \quad (3.10)$$

由公式（3.10）可知，网络的每一层的权值 w_{jk} 和 v_{ij} ，的功能确定了网络的输出误差 E ，所以，可以通过调节网络每一层的权重来达到对网络误差的调整。为了持续地减少网络误差，在学习训练的过程中，应该使网络误差的梯度下降与网络权值的调整量成比例，也就是满足

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial E}{\partial w_k} \frac{\partial w_k}{\partial w_{jk}} \quad (3.11)$$

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} = -\eta \frac{\partial E}{\partial \varpi_j} \frac{\partial \varpi_j}{\partial v_{ij}} \quad (3.12)$$

式（3.11）和式（3.12）中，系数 $\eta \in (0,1)$ ，在网络的训练过程中 η 表示学习速率，负号表示网络是沿着梯度下降的方向来调整网络各层的权值。

如果 δ_k^o 代表输出层的一个误差信号而 δ_j^y 表示隐层的一个误差信号

$$\delta_k^o = -\frac{\partial E}{\partial \varpi_k} \quad (3.13)$$

$$\delta_j^y = -\frac{\partial E}{\partial \varpi_j} \quad (3.14)$$

根据式（3.4）和式（3.13），可将式（3.11）改写为

$$\Delta w_{jk} = \eta \delta_k^o y_j \quad (3.15)$$

同样根据式（3.6）和式（3.14），可将式（3.12）改写为

$$\Delta v_{ij} = \eta \delta_j^y x_i \quad (3.16)$$

因此， δ_k^o 在网络的输出层中可以展开表示为

$$\delta_k^o = -\frac{\partial E}{\partial \omega_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial \omega_k} = -\frac{\partial E}{\partial o_k} f'(\omega_k) \quad (3.17)$$

δ_j^y 在网络的隐层中可以展开表示为

$$\delta_j^y = -\frac{\partial E}{\partial \omega_j} = -\frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \omega_j} = -\frac{\partial E}{\partial y_j} f'(\omega_j) \quad (3.18)$$

对于网络的输出层，利用式（3.6）可以得到

$$\frac{\partial E}{\partial o_k} = -(d_k - o_k) \quad (3.19)$$

对于网络的隐层，利用（3.7）可以得到

$$\frac{\partial E}{\partial y_j} = -\sum_{k=1}^l (d_k - o_k) f'(\omega_k) w_{jk} \quad (3.20)$$

将两式代入（3.17）和（3.18），并根据 $f(x)=f(x)[1-f(x)]$ ，可以计算得

$$\delta_k^o = (d_k - o_k)(1 - o_k) \quad (3.21)$$

$$\delta_j^y = [\sum_{k=1}^l (d_k - o_k) f'(\omega_k) w_{jk}] f'(\omega_j) = (\sum_{k=1}^l \delta_k^o w_{jk}) y_j (1 - y_j) \quad (3.22)$$

再将式（3.19）到式（3.21）分别代入式（3.20）和式（3.22），最后得到三层 BP 网络误差权值调整表达式。

$$\Delta w_{jk} = \eta \delta_k^o y_j = \eta (d_k - o_k)(1 - o_k) y_j \quad (3.23)$$

$$\Delta v_{ij} = \eta \delta_j^y x_i = \eta (\sum_{k=1}^l \delta_k^o w_{jk}) y_j (1 - y_j) x_i \quad (3.24)$$

从式（3.23）和式（3.24）中可以看出，网络误差的调整和学习率 η 、本层输出的误差信号 δ 和本层输入信号 X 有关。

BP 算法的权重调节一般采用单个样本和分批两种方式。其中，单样例学习就是每次只输入一个训练样例，然后通过错误反馈来修正神经网络的权重。很明显，单样本训练仅仅是针对单一的输入样本和输出的误差，来对权值进行调整。我们可以看到，采用这种方法的网络，其收敛速度非常缓慢，经常会需要大量的训练次数，而且效果并不是很好。

批量训练是计算全部样本输入之后网络的总误差 $E_{\text{总}}$

$$E_{\text{总}} = \sqrt{\frac{1}{2} \sum \sum (d_k - o_k)^2} \quad (3.25)$$

然后，给出了一种新的聚类方法——模糊聚类方法。批量训练是利用累积的错误来对网络进行训练，这样就可以使网络的，总错误会沿降低的方向发生变化，从而使网络的收敛速度更快。

通过对 BP 神经网络的分批训练，得到了最优的预测结果，同时也加快了神经网络的学习速度。

3.4.3 BP 神经网络不足及改进

Sigmoid 非线性函数的三层神经网络可以对任意的连续函数进行近似，所以在实际工程中，BP 神经网络是最常用的一种。但是，它也不可避免地存在着许多不足之处，比如：在实际应用中，由于 BP 神经网络具有很强的自适应能力，使得 BP 神经网络在实际应用中存在着很大的局限性。在求解过程中，极易出现局部极小化和寻找最优权的问题。该方法利用梯度下降的方法对权重进行调节，得到的权重收敛结果不一定是全局最小的。对于以多维曲面为误差函数的复杂网络，即便是通过网络进行训练，也极有可能会在某个小谷区的局部极小值会产生，因此，在训练中无法将其清除。潜在的不确定性。对于隐层节点的数量，目前还没有一个公认的计算公式，而且，一个隐层节点的数量是否合适，对一个 BP 网络模型的输出有很大的影响，目前，对于隐层节点的数量决定，一般都是依靠网络设计者的经验，或者是一些前人总结的一些公式。在学习新的样本时，可以使自己的样本进入状态，造成突如其来的遗忘。因为 BP 算法需要对现有的样本进行权重调节，使其真实结果和期望结果之间的偏差最小化，所以在学习新的样本时，会出现已学到的样本被遗忘的情况。

为了解决这些问题，最近几年，人们对 BP 神经网络做了很多改进和优化，并提出了很多新的 BP 神经网络算法。最近被广泛应用的有：统计算法、Sigmoid 函数改进、加入动量项、自适应调低学习率和弹性反向传播算法等，本文利用自适应的调整学习速率来对其进行改进。在 BP 训练算法的实际应用中，要确保每一次的修炼都是有难度的。然而，在常规 BP 算法中，一般将 n 设为固定值。

该方法通过向后传播对神经网络权重进行修正，使 BP 算法沿着网络错误梯度下降的方向改变步长由学习速率确定。如果学习率 η 选择不当，可能出现以下两种情况：

学习率 η 较大，如果选取较大的学习率，则由于网络中每一层的权值调整量比较大，从而使整个网络的学习速度变得更快。但是，当误差趋近于较小时，如果选取太大的学习率，则会造成权值调整幅度太大，从而出现振荡或者不收敛；

学习率 η 较小，选取一个小的学习速率将导致整个网络的学习速率太慢。所以，如果只使用一个固定不变的学习率，很难保证误差在不同的范数下的收敛性。通常，在网络的训练中，我们希望在训练的过程中，可以对学习率进行调节，以确保学习率足够快，并且不会引起网络的振荡。假设初始学习率为 $\eta(t)$ ，其调整方法

在 $t+1$ 时刻权值调整后总误差 E 总增加了，则令 $\eta(t+1) = \beta\eta(t)$, $\beta < 1$

在 $t+1$ 时刻权值调整后总误差 E 总减小了，则令 $\eta(t+1) = \mu\eta(t)$, $\mu > 1$

而当总误差 E 总不随时间变化时，则保持学习率 η 不变

$$\Delta W(t+1) = \begin{cases} \beta\eta\delta X + \alpha\Delta W(t) & E_{\text{总}}(t+1) > E_{\text{总}}(t) \\ \eta\delta X + \alpha\Delta W(t) & E_{\text{总}}(t+1) = E_{\text{总}}(t) \\ \mu\eta\delta X + \alpha\Delta W(t) & E_{\text{总}}(t+1) < E_{\text{总}}(t) \end{cases} \quad (3.4.3)$$

3.4.4 BP 神经网络系统设计

网络层次的选择 BP 网络层次指的是隐含层层次。通常情况下，通过增加隐含层层次，可以降低误差，提升网络的准确度。但是，这也会让网络变得更为复杂，训练的时间也会变得更长。容易出现过拟合。在一些实际问题中，由于对应关系比较复杂，人们经常会考虑采用两个或多个隐含层网络。通过对该项目的试验，证明了在使用单一隐含层的情况下，该方法的收敛性达到了 0.00276，而在使用双重隐含层的情况下，该方法的收敛性达到了 0.000998。为此，文章采用了双重隐含层的方法。

对于输入层、输出层和隐含层的选取，分别考虑了输入层、输出层和隐含层的选取。在输入层中，根据向量维度来确定神经元的数目，并根据状态型输出的数目来确定输出层中神经元的数目。本文将电机声讯信号，分别从八个频率段中提取出特征矢量信号，再分别进行小波降噪及三重小波包变换，从而使输入层中的神经元数目达到 $m=8$ 。在选择输出的状态类型方面，本题根据客观实际情况，仅选取了即将牵引电动机工作状态统归为故障和正常两种的两种工作状态，因此，输出神经元的数量 $p=2$ 。

选择隐含层神经元的个数是个很难的问题，但通常情况下，它与神经元的输入和输出之间存在着间接的联系。隐含层数选择不当，会造成学习时间过长，容错性差，误差不一定最好等问题，也会对故障诊断的效果造成影响。但暗层单位数的确定并没有理想的表示，往往需要根据经验或多次试验验证才能确定。本题考查的是比较实验，参考公式 $S=2M+1$ ，其中， M 是输入层的神经元数目。

p 是外显层的神经元数目， s 是内显层的神经元数目。最后，本文提出了一种新的算法，即对输入层、输出层和隐含层进行了选择。在输入层中，根据向量维度来确定神经元的数目，并根据状态型输出的数目来确定输出层中神经元的数目。本文将电机声讯信号，分别从八个频率段中提取出特征矢量信号，再分别进行小波降噪及三重小波包变换，从而使输入层中的神经元数目达到 $m=8$ 。在选择输出的状态类型时，本题从客观实际情况出发，只选取了即将牵引电动机工作状态统归为故障和正常两种的两种工作状态，所以，输出神经元的数目 $p=2$ 。由于其与输入和输出之间存在着某种联系，因此如何选择隐层神

神经元的个数是一个很困难的问题。当隐变量的数目不合理时，会造成训练时间过长，容错性差，精度不能保证达到最优，从而影响故障诊断结果。然而，到现在为止，还没有一个好的关于暗地层单位数量的计算公式，一般都是通过大量的实验和经验来确定。这是一道关于对比试验的题目，参照的公式为 $S=2M+1$ 。

p 是外显层的神经元数目， s 是内显层的神经元数目。最后敲定其中，内层细胞的数量为 14。

传递函数的选择传递函数也被称作激活函数，它作用在各个连接层之间，从而实现神经元输入到输出的转换，它是神经网络的另一个重要部分。在转移函数的选取方面，项目选取了被广泛使用的 Sigmoid 转移函数。

$$f(x) = [1 + \exp(-ax)]^{-1} \quad a > 0$$

由公式可知 $f(x)$ 是定义区域中的连续可微性。其中， a 是倾斜变量， a 的取值不同，对应函数的形状也会有相应的区别，图 3.4 为 a 取 1、2、3 时对应的函数曲线图。在这两种情况下，函数的斜率随 a 的增加而减小。




图 3.4 a 取 1、2/3 时对应的函数曲线图

与其它连续函数相比，Sigmoid 函数具有以下优势：

首先，Sigmoid 函数同时具有灵敏度与稳定性的双重优势，即信号在小尺度上的变化敏感，但在大尺度上的稳定，使其成为特征识别的重要工具。

其次，在进行误差反演的时候，传输函数必须是可导的，否则会影响到网络的容量和学习速度。所以在此基础上，以 1 为基准。当新的电动机声音数据被采集后，将其预处理后的数据输入到系统故障识别模块中，并与已经建立好的 BP 神经网络模型进行比对，得出电动机工作正常还是故障的对应状态。

3.5 本章小结

本章论述了基于电机转速声音的电机状态检测,研究了使用神经网络对于声音处理的方法,推导出了 Sigmoid 函数,并通过神经网络产生了函数曲线图。

4 软件设计

本实验主程序流程图如图 4.1 所示：




图 4.1 主程序流程图

将声音传感器靠近电机进行采集，采集后将声音信号转换为数字信号，然后用小波阈值降噪方法对声音进行降噪，然后用小波包分解方法对声音的特征进行提取，然后用能量特征值进行计算，构建特征向量，用 BP 神经网络进行诊断，最终对故障类型进行判定，并将结果输出。

4.1 小波分解计算能量特征

子程序主要流程如图 4.2 所示。




图 4.2 子程序 1 流程图

读取数据集载入语音文件，读取指定文件夹下所有.wav 文件的信息，小波阈值去噪，依次得到.wav 的文件名存放在 Names 元胞数组里用 db4 小波对含噪信号，进行 5 层分解并提取系数取第 5 层低频近似系数取各层高频细节系数阈值获取，进行软阈值处理可视化声音波形，声音小波阈值去噪后结果图输出，最后小波分解计算能量特征。

小波阈值去噪

for k=1:N

Names{k}=wav_data(k).name; // 依次得到.wav 的文件名，存放在 Names 元胞数组里
[wav{k},Fs{k}]=audioread(['chunks/Fault/' Names{k}]); // 依次得到.wav 的矩阵，存放在元胞数组里

```

y=wav{k}(:,1); % 单声道// 用 db4 小波对含噪信号进行 5 层分解并提取系数
[c,l]=wavedec(y,5,'db4');// 取第 5 层低频近似系数
ca5=appcoef(c,l,'db4',5);// 取各层高频细节系数
cd5=detcoef(c,l,5);
cd4=detcoef(c,l,4);
cd3=detcoef(c,l,3);
cd2=detcoef(c,l,2);
cd1=detcoef(c,l,1);
thr=thselect(y,'sqtwolog');// 阈值获取
// 进行软阈值处理
ysoft5=wthresh(cd5,'s',thr);
ysoft4=wthresh(cd4,'s',thr);
ysoft3=wthresh(cd3,'s',thr);
ysoft2=wthresh(cd2,'s',thr);
ysoft1=wthresh(cd1,'s',thr);
c1=[ca5;ysoft5;ysoft4;ysoft3;ysoft2;ysoft1];
Y1{k}=waverec(c1,l,'db4');
    
```

TPT R: 为阈值指定选择规则。

在 TPTR=“heursure”时，选取第一个选取的启发变量为阈值；

在 TPTR=' rigrsure'的情况下，使用 Stan 无偏似然估计

(Stain Unbiased Risk Estimate) 进行自适应阈值选取；

当 TPT R = 'sqtwolog'时，采用公式: $\sqrt{2 * \log(\text{length}(X))}$ 来计算所取阈值；

当 TPT R = 'minimaxi'时，用极大值极小值原理选取的阈值。SO RH: 指定选取软阈值或者是选取硬阈值

4.2 构建 BP 神经网络

子程序主要流程如图 4.2 所示。




图 4.2 子程序 2 流程图

设置类别标签划分训练集，测试集训练数据和预测数据固定随机数，不然每次计算结果有差异，归一化到[0,1]之间，inputps 用来作下一次同样的归一化建立模型，利用 purelin 来进行传递函数的训练，并通过梯度下降的方法来设定输入层到中间层的权值、中间各层的神经元阈值、中间层到输出层的权值、输出层各神经元阈值。将训练次数的学习速率设定为 0.01，将训练目标最小误差设定为 0.00001 开始训练，其中 inputn, outputn 分别为输入输出样本，对样本数据进行归一化用。训练好的模型进行仿真，计算结果整数化预测值和真实值的误差，最后做真实值与预测值误差比较。

构建 BP 神经网络

`net=newff(inputn,outputn,hiddennum,{'purelin','purelin'},'trainlm');`% 建立模型，传递函数使用 `purelin`，采用梯度下降法训练

`W1= net. iw{1,1};`//输入层到中间层的权值

`B1 = net.b{1};`//中间各层神经元阈值

`W2 = net.lw{2,1};`//中间层到输出层的权值

`B2 = net. b{2};`//输出层各神经元阈值

真实值与预测值误差比较

`figure(1)`

`stem(output_test,'bo')`

`hold on`

`stem(test_simul,'r*')`

`hold on`

`legend('实际','预测')`

`xlabel('测试样本')`

`set(gca,'YTick',0:2)`

`set(gca,'YTickLabel',{'0' '1-异常' '2-正常' })`

`[c,l]=size(output_test);`

`MAE1=sum(abs(error))/l;`

`MSE1=error*error'/l;`

`RMSE1=MSE1^(1/2);`

5 实验结果

本项目以集宁机务段 YJ85A 电动机的语音信号为实验对象，对电动机在正常及故障情况下的 65 组语音信号进行了实验研究，并对实验结果进行了分析。为了更好地反映出这些信号的特性，该系统将降噪前和降噪后的波形分别显示在正常和故障两种情况下。图 5.1 和图 5.2 是两种情况下的初始波形和去除噪声后的波形，其中，横轴是信号取样点的数量，纵轴是各取样点相应的幅度。




图 5.1 正常状态下原始波形




图 5.2 故障状态下原始波形




图 5.3 正常状态下去噪波形




图 5.4 故障状态下去噪波形

通过图 5.3、图 5.4 中两种状态下去噪波形的比较，我们可以看到，在正常状态下，去噪波形中，各个采样点都是比较稀疏的，而且波形幅值的跳动性也显著地低于其他采样点；在故障情况下，各个采样点的振幅都比较平稳，只有一些振幅有显著的抖动，其他振幅没有显著的差别。

通过两种状态下去噪前后波形的比较，我们可以看出，在正常状态下的声音信号波形比在故障状态下的声音信号波形更加稳定。并利用小波包阈值的方法，对图像中的信号进行了检测。证明了该方法具有较好的降噪效果。所以，在一定程度上，我们可以通过电机两种状态下的时域信息，来对电机的状态做出一些初步的判断。在电机声音的故障检测中，时域波形分析只能够对电机的状态做出一种直观的、定性的分析，而且它的准确度并不高，只是能够提供一个参考。所以，定量地分析电动机的工作状态是非常必要的。所以，本论文的研究重点是对小波包变换后的能量系数进行重建，这是一种有效的方法。

从第 3 章中的分析中，我们发现利用小波包分解方法对每一个节点上的信号进行重构，从而对其进行识别。如图 5.5、图 5.6 所示在结点 1 故障状态下小波商能量百分比高于正常状态下小波商能量百分比。




图 5.5 正常状态下小波商能量比柱状图




图 5.6 故障状态下小波商能量比柱状图

如何选择特征频率是实现电机故障模式识别的重要环节,若选择不能反映电机故障特征的频带,则所训练的分类器就无法判断电机有无故障。通过对不同频率下的振动信号进行分析,获得了不同频率下振动信号的振动信号 120 个,而没有不同频率下振动信号的振动信号 120 个。鉴于异音马达存在与不存在的特性,我们选择了 1500Hz—2000Hz、1800Hz—2300Hz、1700Hz—2200Hz 作为特征区。通过主成分分析,将其降到了 70 个维度。判定的结果就是对该电机的识别率.下面是试验结果。

表 5.7 故障电机在不同特征频率下的判别率对比

特征	1500Hz-2000Hz	1800Hz-2300Hz	1700Hz-2200Hz
频率			
因子			
0.46	79.17%	41.67%	100%
0.48	74.17%	25%	100%
0.50	70%	5%	100%
0.53	66.67%	0%	100%
0.55	43.17%	0%	98.33%

由表 5.7 可知，在 1700Hz-2200Hz 的特征频率范围内，鉴别效应是有效的。另外，我们还发现，由各种因素所组成的判别函数，对于试验结果的影响也是相当大的。所以，为了取得较好的分类结果，我们需要选取适当的因素作为判别函数。

既要识别出故障的电动机，又要识别出正常的电动机。但也有小部分正常的、没有问题的电动机被错误地判定为有问题。但当错误的概率过大时，这个办法就会变得无效，变得无效。所以，我们不仅要有高辨识度的故障电机，而且要有高辨识度的正常电机，辨识度也要高。所以，有必要比较普通的无异声电机的区别率。

实验结果如下表 5.8

表 5.8 正常电机在不同特征频率下的判别率对比

特征	1500Hz-2000Hz	1800Hz-2300Hz	1700Hz-2200Hz
频率			
因子			
0.46	96.67%	45%	22.5%
0.48	85%	25%	45.83%
0.50	68.33%	91.67%	62.5%
0.53	71.67%	42.5%	27.5%

0.55	100%	96.67%	81.67%
------	------	--------	--------

为了验证算法的识别率，我们采集了各种电机样本，实验结果如下：

表 5.9 不同电机故障的识别率

因子	电磁异音	轴承异音	摩擦异音	松动异音	无异音
大小					
0.1	92.31%	100%	99.24%	99%	12.64%
0.13	80.49%	81.17%	68.33%	61.75%	40.11%
0.15	68.68%	66.82%	30.83%	33%	71.7%
0.166	57.70%	73.41%	11.54%	16.25%	79.4%
0.18	46.43%	47.53%	33.33%	10%	94.72%

由表 5.9 可知，在系数为 0.1 的情况下，分类法是有效的，可以区分出不同类型的电动机。但是，对于没有异响的普通电机，其辨识率较低。造成这一现象的主要原因是由于样本数量太少，支撑矢量网不能涵盖全部样本。所以，必须有足够数量的普通马达，才能对网络进行最大限度的覆盖。

结束语

针对传统的电机故障问题，本文提出了通过与保存训练好的 BP 神经网络模型进行对比分析，最终实现故障类型判断方法。该方法包括声音采集，声音处理，故障识别等几个部分。由于电机在运行过程中振动，吸声率低，声音向外发射。正常运行的电机发出与故障电机不同的声音。因此，识别电机的噪声特性是最简单和最直接的。通过处理声音信号并提取电机声信号频谱的特征。最后，使用各种误差样本测试该方法的有效性。从而满足基于电机转速声音对电机状态检测的要求。该系统能够很好地应用到电动机的实际测试中。在一定程度上，它可以满足电机检修的实际需求，为机务段的检测人员判断电机是否出现了故障，提供了相应的参考依据，可以起到一定的辅助诊断效果。但是，其中也存在一些模块的功能，还需要对其进行进一步的完善，例如，要想让故障检测系统的准确度得到提升，还需要在之后，进一步构建一个完善的、大型的、全面的电机声音故障特征库。

致 谢

时光荏苒，在南泰科的四年即将结束，四年时间，有悲伤，有痛苦，有欢笑，有喜悦，回顾求学生涯，首先要感谢我的论文指导老师，张朋老师，他一次次的耐心讲解，帮助我不断完善自己的论文，遇到问题时，也是他的悉心指导，都成功一一克服。其次，感谢身边几位挚友，我们一起度过的这段求学时光，充实且愉悦，最后，感谢南泰科电子工程学院的各位老师，是他们孜孜不倦的辛苦教学，才成就了现在的我。

在大学期间的学习，我收获的不仅是学业上的成长，更收获了如何正确为人处事的宝贵财富，本科求学生涯即将结束，学无止境，我也继续踏上研究生的求学之路，由衷的感谢一路陪我成长的老师，同学，亲人。

参 考 文 献

- [1] 严建援, 张丽, 张蕾. 电子商务中在线评论内容对评论有用性影响的实证研 [J]. 情报科学, 2012, 30(5) : 713-716, 719.
- [2] 赵妍妍, 秦兵, 刘挺. 文本情感分析 [J]. 软件学报, 2010, 21(8) : 1834-1848.
- [3] 王晓东, 王娟, 张征. 基于情感词汇本体的主观性句子倾向性计算 [J]. 计算机应用, 2012, 32(6) : 1678-1681, 1684.
- [4] 董丽丽, 赵繁荣, 张翔. 基于领域本体、情感词典的商品评论倾向性分析 [J]. 计算机应用与软件, 2014, 31(12) : 104-108, 194.
- [5] 冯秀珍, 郝鹏. 基于词性分析的产品评价信息挖掘 [J]. 计算机工程与设计, 2013, 34(1) : 283-288.
- [6] 杨经, 林世平. 基于 SVM 的文本词句情感分析 [J]. 计算机应用与软件, 2011, 28(9) : 225-228.
- [7] 王刚, 杨善林. 基于 RS-SVM 的网络商品评论情感分析研究 [J]. 计算机科学, 2013, 40(11A) : 274-277.
- [8] 钟将, 杨思源, 孙启干. 基于文本分类的商品评价情感分析 [J]. 计算机应用, 2014, 34(8) : 2317-2321.
- [9] 钟将, 邓时滔. 基于多特征融合的汉语情感分类研究 [J]. 计算机应用研究, 2012, 29(1) : 98-100.
- [10] 刘志明, 刘鲁. 基于机器学习的中文微博情感分类实证研究 [J]. 计算机工程与应用, 2012, 48(1) : 1-4.
- [11] 薛小芳, 施春宏. 语块的性质及汉语语块系统的层级关系 [J]. 当代修辞学, 2013(3) : 32-46.
- [12] 王天航, 史树敏, 龙从军, 等. 基于错误驱动学习策略的藏语句法功能组块边界识别 [J]. 中文信息学报, 2014, 28(5) : 170-175, 191.
- [13] LIN C. Libsvm——A library for support vector machines [OL]. [2015 - 05 - 08]. <http://www.csie.ntu.edu.tw/~cjlin/>.
- [14] 徐琳宏, 林鸿飞, 潘宇, 等. 情感词汇本体的构造 [J]. 情报学报, 2008, 27(2) : 180-185.
- [15] 周杰, 林琛, 李弼程. 基于机器学习的网络新闻评论情感分类研究 [J]. 计算机应用, 2010, 30(4) : 1011-1014.

- [16] 夏梦南, 杜永萍, 左本欣. 基于依存分析与特征组合的微博情感分析 [J]. 山东大学学报: 理学版, 2014, 49(11) : 22-30.
- [17] 李纲, 刘广兴, 毛进, 等. 一种基于句法分析的情感标签抽取方法 [J]. 图书情报工作, 2014, 58(14) : 12-20.
- [18] 欧阳纯萍, 阳小华, 雷龙艳, 等. 多策略中文微博细粒度情绪分析研究 [J]. 北京大学学报: 自然科学版, 2014, 50(1) : 67-72.
- [19] 贺飞艳, 何炎祥, 刘楠, 等. 面向微博短文本的细粒度情感特征抽取方法 [J]. 北京大学学报: 自然科学版, 2014, 50(1) : 48-54.
- [20] Liu B. Sentiment analysis and opinion mining [M]. USA: Morgan & Claypool, 2012: 1-167.
- [21] Guojon B. Text mining for opinion target detection [C] // Proceedings of the 2011 European Intelligence and Security Informatics Conference. Piscataway: IEEE Press, 2011: 322-326.
- [22] Pak A, Paroubek P. Twitter as a corpus for sentiment analysis and opinion mining [C] // Proceedings of the 2010 International Conference on Language Resources and Evaluation. Paris: European Language Resources Association, 2010: 17-23.
- [23] Somprasetspi G, Lalitrojwong P. Mining feature-opinion in online customer reviews for opinion summarization [J]. Journal of Universal Computer Science, 2010, 16(6) :