

# 基于神经网络的轴承设备故障诊断

Fault Diagnosis of Rolling Bearing Based Neural Network

李颖俐 lyl\_elena@163.com 华中科技大学

Yingli LI lyl\_elena@163.com Huazhong University of Science and Technology

**摘要:** 在设备运行中,故障的发生往往会带来巨大的损失。而不同的设备在运行中都会有不同的信号特征来反映设备的运行状态。因此通过对滚动轴承的振动信号的监控,可以推测出轴承所存在的故障类型。本文在已有实验的基础上,采用了BP神经网络的方式,将振动信号作为诊断的输入,故障类别作为诊断的输出,构建了针对设备故障诊断的模型,提出了一种基于神经网络的设备故障诊断方法,并通过数据仿真和对比试验证实了方法的有效性。

**关键词:** 故障诊断, BP 神经网络, 振动信号

**Abstract:** During the process of equipment operation, equipment's breakdown always led to huge losses. In operational process, different devices reflect itself operational situation with different characteristics. Thus, through monitoring vibration signal of equipment, we can diagnose the fault types of equipment. With the existing experiments, this paper adopts BP neural network as an diagnosis model, vibrational signal as input of diagnosis, fault type as output of diagnosis, which aims to build a model focus on bearing fault diagnosis, proposes a method of bearing fault diagnosis based on neural network, and confirmed the validity of method by a contrast tests.

**Key words:** fault diagnosis, BP neural network, vibrational signal

## 0. 引言

随着“工业 4.0”的发展,以及我国《制造 2025》的提出,智能制造越来越受到人们的广泛关注,如何实现制造的智能调控也成为了困扰科研人员的一大难题。智能制造的目的在于通过数据驱动下的智能感知,利用数据实现对未知的波动进行预测,从而进行及时调整,将波动对生产的影响降至最低。

数据显示,在设备运行中,故障的发生往往会带来巨大的损失。例如:美国的“挑战者”航天飞机失事,我国的秦山电站发电机主轴断裂等。而在制造生产过程中,故障则会造成加工零件的报废,设备损伤,甚至是现场人员的伤亡。所以,如何对设备的状态进行预测就显得十分重要。一方面故障检测可以防患于未然,降低故障带来的损失,表格 1 显示通过故障诊断所带来的设备维护成本,生命周期,以及产能的提升<sup>[1]</sup>;另一方面,故障作为生产波动的主要因素,其诊断结果可以为智能调控的输入,是智能制造的基础。因此,故障诊断受到了广大研究者的关注,而基于设备状态的故障诊断技术,结合了时兴的大数据,物联网等技术,越来越成为故障诊断领域研究的热点。

表格 1 采用设备诊断所带来的提升

维修成本	降低 50%~80%
设备损坏	降低 50%~70%
设备生命周期	提升 50%~60%
总产能	提升 20%~30%

在设备故障诊断中,人工智能算法一种非常常见的方法,其主要包括回归树与时间序列、灰色系统、模糊神经网络、实时专家系统、粒子滤波器等<sup>[2]</sup>。其中,比较典型的算法有 Wang<sup>[3]</sup> 在的利用自回归模型(AR)对齿轮的齿轮进行了健康监测, Lei<sup>[4]</sup>验证了包络分析在齿轮诊断中的效果,董明等人<sup>[5]</sup>提出了一种利用属于模式识别范畴的决策树 C4.5 法进行变压器故

障诊断的方法；张其林等人<sup>[6]</sup>提出了基于概率神经网络的电气设备故障诊断方法；徐贵斌等人<sup>[7]</sup>提出了基于在线学习的神经网络诊断方法，Rigatos 等人<sup>[8]</sup>提出了一种基于神经网络的设备状态监测模型。可见，人工智能在故障诊断中有着广泛的应用。而人工神经网络作为人工智能算法，近年来受到了广泛的关注，起具有的良好拟合性和泛化能力，使其在设备故障诊断领域有着广阔的应用前景。

## 1. BP 神经网络

### 1.1 神经网络简介

人工神经网络是一种模仿动物神经特征，进行分布式并行信息处理的模型。其具有良好的非线性拟合能力和极强的泛化能力使其可以胜任如文本翻译<sup>[9]</sup>、面部识别<sup>[10]</sup>、图片分类<sup>[11-13]</sup>等工作。人工神经网络通过模仿大脑构建大量复杂的神经元，并根据某种连接方式（如全连接，局部感受野等），通过权值  $w$  将神经元进行连接。

整个神经网络模型分为训练和预测两部分，其中在训练过程中，其本质是一个优化问题，利用已有的数据作为输入样本并构建目标函数，通过迭代的方式调整连接权值（及阈值）的方式，如常用的随机梯度下降，拟牛顿法以及智能算法等优化方法，实现目标函数最小化（或最大化）。预测阶段则是直接将待测样本放入人工神经网络模型中，通过不同的权值组合最终给样本一个相应的输出。目前，常用的神经网络有 BP 神经网络<sup>[14]</sup>、自组织神经网络<sup>[15]</sup>、Hopfield 神经网络<sup>[16]</sup>等。其中，BP 神经网络因其具有良好的拟合和泛化能力，可以构建和表达复杂的模型问题，受到广泛的应用，也使得通过针对设备信号设计 BP 神经网络，使其输入的对设备故障信号进行识别和预测成为可能。

### 1.2 BP 神经网络

传统的 BP（back-propagation）神经网络由输入层，多个隐含层以及输出层组成，每层由数量不同的神经元组成，其结构如图 1 所示。同一层之间的神经元无连接，相邻层之间的神经元通过权值连接，隐含层神经元的个数根据问题情况而定。整个 BP 神经网络的训练可以分成前向传递和后想调整两部分，其中，前向传递的过程如下。




图 1 BP 神经网络结构

在前向传递中，信号只能通过连接权值向前传递。设 BP 神经网络输入层的输入为  $x \in R^d$ ，隐含层  $h \in \{h_1, h_2 \dots h_L\}$ ，其中  $L$  表示隐含层的个数， $h_l$  代表了第  $l$  个隐含层的输入，则隐含层  $h_l$  的输出值可以表示为：

$$net_l = w_l h_{l-1} + b_l \quad j \in (1, L) \quad (1)$$

其中， $w_l$  代表层与层之间的连接权重， $b_l$  隐含层  $h_l$  的偏置。则隐含层  $h_l$  的输出可以表示为：

$$a_l = activation(net_l)$$

其中,  $\text{activation}(\cdot)$ 表示隐含层 $h_l$ 激活函数, 常用的激活函数有  $\text{sigmoid}$ 、 $\text{relu}$  等。 $y$  表示 BP 神经网络输出层的输出,  $t$  表示每个样本所对应的真实标记, 则最终神经网络的输出  $y$  和误差  $E$  可以如下表示:

$$y = s(\text{net}_l) \quad (3)$$

$$E = L(y, d) \quad (4)$$

其中  $L$  代表构建的目标函数。到此为止, 前向传递过程结束。反响传递过程中, 误差信号通过连接权值反向传播, 采用反向求导和链式法则的方式, 对神经网络的权值和偏置进行更新。

## 2. BP 神经网络故障诊断模型的构建与仿真

### 2.1 模型构建

在设备故障诊断中, 目前最常采用的是振动信号。从数据分析的角度来看, 振动信号属于时序信号, 需要对其进行分割处理, 设立采样时间和采样频率, 然而, 设备振动信号因其周期性不强, 无论采用什么怎样的切割方式, 都会造成采样点的偏移, 从而导致样本识别困难, 因此, 为了减弱采样点偏移造成的误差, 在构建 BP 神经网络时, 采用低维向高维映射, 再逐渐向低维映射的网络结构, 从而将时间序列分割不均匀所造成的误差均摊到每一个神经元中, 从而降低偏移误差对模型准确性的影响, 为此, 整个网络采用[500-200]的隐含层神经元。

从样本数值的角度来看, 振动信号具有波动性强, 数值差值大的特点, 为了避免过大或过小的数值对神经网络造成干扰(如数值过大会直接导致激活函数饱和, 无法调整), 因此, 在数据输入前需要对样本进行归一化操作, 其公式如下

$$x_{new} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

其中,  $x$  代表了当前样本值,  $x_{new}$  代表归一化后的样本值,  $x_{\max}$ ,  $x_{\min}$  分别代表所有样本中的最大值和最小值。通过归一化, 我们可以将输入样本映射到一个(0,1)的空间中, 从而避免出现输入值过大或过小的情况。

在激活函数方面, 同样为了降低采样偏移所造成的误差, 本文采用  $\text{sigmoid}$  作为神经网络的激活函数, 它可以将输入值映射到(0,1)的空间中, 从而在神经网络的传递过程中, 尽可能保证样本特征的完整性, 其公式如下。在神经网络顶层则采用  $\text{softmax}$  进行多元逻辑回归, 通过概率估计实现故障预测。

$$\text{sigmoid}(x) = \frac{1}{1 + \exp(-x)} \quad (6)$$

### 2.2 仿真验证

为了验证模型的有效性, 我们采用了一组音频信号的标准集作为测试样本。该数据集共包含 4 类数据, 分为训练集和测试集两部分, 其中训练集包含了 1500 数据用于训练神经网络, 测试集中则包含了 500 条样本, 用于测试模型的性能, 其部分样本如下图所示:




图 2 音频信号样本

从上图中可以看出，音频信号与设备的故障振动信号一样具有是一个数值波动较大连续的时序数据，同时也具有采样点偏移的问题，因此，可以通过该标准集测试构建模型的有效性。整个神经网络有一个隐含层，包含 200 个神经元，其余均采用上述建模所采用的方法，实验重复十次，其最终测试结果平均值为：93.92%，标准差为 0.0129，因此，通过仿真结果可以证明该模型可以适用于振动信号识别。

### 3. 实例验证

#### 3.1 实验过程

本次实验针对凯斯西储大学提供的滚动轴承故障公开测试集，利用 BP 神经网络对轴承出现的故障进行识别诊断，整个数据集包含了十种轴承工作状态的振动信号，其故障类型及样本数量如下表所示：

表格 2 滚动轴承状态

轴承状态	训练集数目	测试集数目	类别
正常	300	200	1
0.1778mm 轴承滚子损坏	300	200	2
0.1778mm 轴承内腔损坏	300	200	3
0.1778mm 轴承外腔损坏	300	200	4
0.3556mm 轴承滚子损坏	300	200	5
0.3556mm 轴承内腔损坏	300	200	6
0.3556mm 轴承外腔损坏	300	200	7
0.5334mm 轴承滚子损坏	300	200	8
0.5334mm 轴承内腔损坏	300	200	9
0.5334mm 轴承外腔损坏	300	200	10

其中训练集中选取了在 10 种状态下的在转速 1797rpm 转速下的 3000 个样本，其信号如图 3 所示，并根据每个样本的不同的故障类别分别标记为 1 到 10。测试集采用的样本是 1772rpm 转速下所收集到 10 种状态下的振动信号，并作最终的测试来进行验证故障诊断模型的性能。图 3 和图 4 分别给出了 10 状态下的振动信号曲线，以及每一个样本通过主成分分析提取出的三维特征。从图 3 可以看出，根据人工识别很难找到明显的特征将十种不同的信号区分，

而在提取了主成分特征信息之后，我们仍然可以看到大量的不同状态的点重合在一起，肉眼或者传统的线性分类等方式根本无法将各个样本区分开。因此就需采用机器学习的方式进行特征识别，而神经网络正是目前应用最广泛的一类机器学习方法。




图 3 十种状态下采样信号




图 4 十种状态的主成分分析

3.2 实验结果

本次实验采用 500-200 的神经网络结构，网络参数采用随机初始化的方式，利用随机梯度下降的方式进行优化，迭代次数设为 150 次，其他参数均不做特殊设置，采用常用的默认值。神经网络采用 sigmoid 作为激活函数，采用均方误差 MSE

$$L = MSE = \sum (y - x)^2 \tag{7}$$

作为网络训练的评价指标，并利用交叉验证的方式来防止过拟合现象的发生。为了验证方法的有效性，本文采用了机器学习中常见的支持向量机<sup>[17]</sup> (support vector machine, SVM) 作为对比参照，以此验证 BP 神经网络在该类故障诊断问题中有着更加优异的表现。整个实验重复十次，图 5 为十次 BP 神经网络训练的迭代过程，准确率采用十次实验的平均值作为比较，其预测结果如下：

表格 3 实验结果

	训练集准确率	测试集准确率	训练时间
BP 神经网络	70.1%	67.3%	147 秒
支持向量机	60.8%	56.2%	123 秒

由表 3 可知，本文提出基于 BP 神经网络的预测模型对滚动轴承的故障预测的平均准确率为 70.1%，均方误差为 0.24%，相对于支持向量机的方法在准确率上有着明显的优势。因此，运用 BP 神经网络的预测方法进行设备故障的预测是可行的，能够较好地解决设备故

障预测问题。

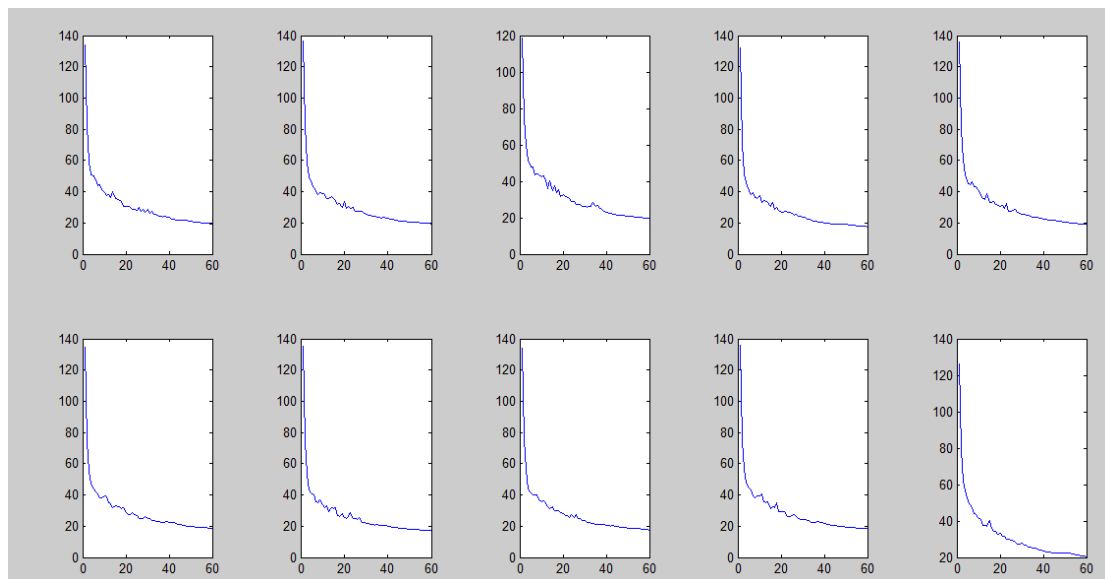


图 5 十次训练的迭代过程

#### 4. 结论

针对振动信号变化复杂，人工识别困难的问题，本文采用了BP神经网络的方法，将振动信号作为输入，故障类别作为输出，构建了设备故障诊断模型，并通过音频信号仿真验证了模型的有效性。最终将该模型用于振动信号的设备故障诊断中，提出了基于BP神经网络的振动信号设备故障诊断方法。实验表明，该方法在实际应用中可以起到准确识别振动信号故障类型的作用，且效果要明显优于支持向量机等其他对比方法。证明了本文提出的方法在理论和实践中都切实可行。

#### 参考文献：

- [1] HENRIQUEZ P, ALONSO J B, FERRER M A, et al. Review of automatic fault diagnosis systems using audio and vibration signals [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2014, 44(5): 642-52.
- [2] 艾红, 周东华. 动态系统的故障预测方法 [J]. 华中科技大学学报: 自然科学版, 2009, 37(1): 222-5.
- [3] WANG W, WONG A K. Autoregressive model-based gear fault diagnosis [J]. Journal of vibration and acoustics, 2002, 124(2): 172-9.
- [4] LEI Y, HE Z, ZI Y. A new approach to intelligent fault diagnosis of rotating machinery [J]. Expert Systems with Applications, 2008, 35(4): 1593-600.

- [5] 董明, 屈彦明, 周孟戈, et al. 基于组合决策树的油浸式电力变压器故障诊断 [J]. 中国电机工程学报, 2005, 25(16): 35-41.
- [6] 张其林, 赵永标, 康长青. 基于概率神经网络的 SF6 电气设备故障诊断 [J]. 湖北文理学院学报, 2013, 34(8): 10-4.
- [7] 徐贵斌, 周东华. 基于在线学习神经网络的状态依赖型故障预测 [J]. 浙江大学学报: 工学版, 2010, 7): 1251-4.
- [8] RIGATOS G, SIANO P. Power transformers' condition monitoring using neural modeling and the local statistical approach to fault diagnosis [J]. International Journal of Electrical Power & Energy Systems, 2016, 80(150-9).
- [9] LIOU C-Y, CHENG W-C, LIOU J-W, et al. Autoencoder for words [J]. Neurocomputing, 2014, 139(84-96).
- [10] ZHANG J, SHAN S, KAN M, et al. Coarse-to-fine auto-encoder networks (cfan) for real-time face alignment; proceedings of the European Conference on Computer Vision, F, 2014 [C]. Springer.
- [11] YU J, TAO D, WANG M, et al. Learning to rank using user clicks and visual features for image retrieval [J]. IEEE transactions on cybernetics, 2015, 45(4): 767-79.
- [12] YU J, RUI Y, CHEN B. Exploiting click constraints and multi-view features for image re-ranking [J]. IEEE Transactions on Multimedia, 2014, 16(1): 159-68.
- [13] YU J, RUI Y, TANG Y Y, et al. High-order distance-based multiview

stochastic learning in image classification [J]. IEEE transactions on cybernetics, 2014, 44(12): 2431-42.

[14] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. Cognitive modeling, 1988, 5(3): 1.

[15] KOHONEN T. The self-organizing map [J]. Proceedings of the IEEE, 1990, 78(9): 1464-80.

[16] HOPFIELD J J. Neural networks and physical systems with emergent collective computational abilities [J]. Proceedings of the national academy of sciences, 1982, 79(8): 2554-8.

[17] VAPNIK V N, VAPNIK V. Statistical learning theory [M]. Wiley New York, 1998.