

引用格式:鞠建波,胡胜林,祝超,等.基于深度学习的装备故障诊断方法[J].电光与控制,2018,25(2):103-106. JU J B, HU S L, ZHU C, et al. A deep learning based method for equipment fault diagnosis[J]. Electronics Optics & Control, 2018, 25(2):103-106.

## 基于深度学习的装备故障诊断方法

鞠建波, 胡胜林, 祝超, 管晗  
(海军航空大学, 山东烟台 264001)

**摘要:**深度学习作为模式识别和机器学习领域的最新成果,在装备故障诊断和健康管理方面有着广阔的前景。结合装备故障大数据的特点和深度学习理论的优势,提出一种新的装备故障诊断方法。根据去噪自动编码器原理,实现训练网络的无监督特征学习,完成整个神经网络的构建;根据故障种类确定输出层,使用BP算法对整个网络进行有监督微调,提升故障分类的准确度。利用上述方法,通过实验完成了某通信电台的模块级故障诊断。

**关键词:**故障诊断;大数据;深度学习;模式识别;去噪自动编码器

**中图分类号:** TP206 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2018.02.021

## A Deep Learning Based Method for Equipment Fault Diagnosis

JU Jian-bo, HU Sheng-lin, ZHU Chao, GUAN Han  
(Naval Aeronautical University, Yantai 264001, China)

**Abstract:** As a new achievement in the field of pattern recognition and machine learning, deep learning has broad prospects in the field of equipment fault diagnosis and health management. In this paper, a new method of fault diagnosis is proposed based on the characteristics of equipment fault big data and the advantages of deep learning theory. According to the principle of the denoising auto-encoder, the unsupervised feature learning of the training network is achieved, and the structuring of the whole neural network is completed. According to the type of fault, the output layer is determined. Using the BP algorithm, the supervised fine-tuning of the whole network is carried out, and thus the accuracy of fault classification is enhanced. By means of the above methods, the module-level fault diagnosis of a communications station is completed through experiments.

**Key words:** fault diagnosis; big data; deep learning; pattern recognition; denoising auto-encoder

### 0 引言

众所周知,对装备建立可靠的健康管理系统是保证它们安全运行的必要措施。由于被监测的装备规模大,监测时间长,且每个监测点的采样频率较高,使得整个监测系统获得的是海量数据,从而使对装备的故障诊断和健康管理也进入了“大数据”时代<sup>[1]</sup>。

装备大数据主要包含以下几个特点<sup>[2]</sup>:一是数据容量大,仅仅依靠专业技术人员和诊断专家手动分析显得力不从心;二是数据的多样性,数据中包含了多种

来自各个方面、不同形式的信息;三是故障类型复杂多样,由于装备各部分之间紧密联系,使得微小的故障也可能导致整个装备系统瘫痪。因此,利用先进的理论方法,及时地从装备大数据中挖掘出故障信息并及时预警,准确地对装备进行故障诊断显得尤为重要。

传统的故障诊断方法采用“信号处理的特征提取+机器学习模型<sup>[3]</sup>”的形式,在特征提取方面,其不足之处在于需要大量的工程实践和信号处理技术来提取故障信息;在模型训练方面,浅层的模型无法解决数据量日益变大的设备故障问题,模型的监测和故障诊断能力均明显不足。

本文提出的基于深度学习的装备大数据故障诊断方法,利用大量装备实测数据训练深度学习网络,通过构建深层次模型,结合大量的训练数据,来学习数据中隐含的特征,通过输出层分类器,从而完成装备故障类型的诊断。

收稿日期:2017-04-08

修回日期:2017-11-26

基金项目:国家自然科学基金(60874112);军队科研专项资助项目(41512322)

作者简介:鞠建波(1961—),男,山东烟台人,教授,研究方向为军事装备故障研究和水下目标探测与识别。

## 1 深度学习方 法

深度学习<sup>[4]</sup>方法利用逐层训练的方式训练深度神经网络(DNN),该方法提高了故障特征提取的完整性和故障类型识别的准确性<sup>[5]</sup>。首先以无监督的学习方式,对 DNN 进行逐层训练,学习样本数据的故障特征<sup>[6]</sup>;然后以有监督学习方式对 DNN 参数进行微调,完成故障识别分类。有监督微调方式分为两种:一是只调整整个网络的输出层,也就是分类器;二是通过有标签样本,微调整整个训练系统。显然,在数据量满足条件的情况下,微调整整个系统能得到更好的效果。

### 1.1 去噪自动编码器原理

自动编码器(AE)的基本单元是一个3层的非监督神经网络<sup>[7]</sup>,分为编码网络和解码网络两个部分,编码网络将输入数据转换为编码矢量,然后通过解码网络将编码矢量重构为输出数据,其目标是使输入数据和重构得到的输出数据相同。由于在输出层对输入数据进行重构,使得编码矢量作为输入数据的一种特征表示,其原理结构如图1所示。




图1 自动编码器的原理结构图

Fig.1 Principle structure of auto-encoder

给定一个无标签的训练数据样本集  $x^m$ ,编码网络通过编码函数  $f_\theta$  将训练样本  $x^m$  变换为编码矢量  $h^m$ ,即

$$h^m = f_\theta(x^m) = s_f(Wx^m + b) \quad (1)$$

式中: $m$ 为样本集内各样本数据可能的维数; $s_f$ 是编码网络的激活函数; $\theta$ 为编码网络的参数集合,且  $\theta = \{W, b\}$ 。然后通过解码函数  $g_{\theta'}$  将编码矢量  $h^m$  反向变换为  $x^m$  的重构表示  $y^m$ ,即

$$y^m = g_{\theta'}(h^m) = s_g(W'h^m + d) \quad (2)$$

式中: $s_g$ 为解码网络的激活函数; $\theta'$ 为解码网络的参数集合, $\theta' = \{W', d\}$ 。自动编码器通过最小化输入  $x^m$  和输出的  $y^m$  的重构误差  $L(x, y)$ ,完成网络基本单元的训练

$$L(x, y) = \frac{1}{n} \|x - y\|^2 \quad (3)$$

式中: $n$ 为样本总个数。通过编码网络和解码网络,如

果能很好地将输入  $x^m$  重构为输出  $y^m$ ,则输出数据保留了输入数据的主要信息,但由于设备所处的环境复杂、工况多样,使得样本数据容易受到干扰,只保留  $x^m$  的信息,并不足以使自动编码器获得一种有效的特征表示。因此,要给自动编码器一定的约束,使它学习到一种鲁棒的特征表示,降低 DAE 对微小随机扰动的敏感性,提高特征表达的鲁棒性。

DAE 通过重构含有噪声的样本数据解决这个问题,其大体实现过程如图2所示,在输入样本数据  $x$  中加入一种分布形式为  $q_D$  的噪声<sup>[8]</sup>,变为  $x'$ ,通过编码网络,将  $x'$  编码为编码矢量  $h$ ,通过  $h$  重构出输入得到  $y$ ,然后最小化  $x, y$  的重构误差  $L(x, y)$ ,通过随机梯度下降算法一步步优化代价函数,从含有噪声的输入  $x'$  中,最大化重构原始输入数据  $x$ 。




图2 去噪编码原理流程图

Fig.2 Flow chart of denoising coding

### 1.2 深度学习的网络预训练和微调

深度学习的网络预训练是利用无监督的方法,将多个 DAE 堆叠起来,形成网络的隐层结构<sup>[9]</sup>。首先使用训练样本  $x^m$  训练第1层 DAE<sub>1</sub>,将  $x^m$  通过编码网络,得到编码矢量  $h_1^m$ 。

$$h_1^m = f_{\theta_1}(x^m) \quad (4)$$

式中, $\theta_1$ 为 DAE<sub>1</sub> 的参数。这样  $h_1^m$  就获得了  $x^m$  的主要信息,然后利用  $h_1^m$  训练第2层 DAE<sub>2</sub>,得到编码矢量  $h_2^m$ 。重复步骤,直到将网络训练完毕,得到最终的编码矢量为

$$h_N^m = f_{\theta_N}(h_{N-1}^m) \quad (5)$$

式中, $N$ 为网络训练的层数。通过预训练,把多个 DAE 串联起来,构成整个网络的隐层,从而实现对故障信息的层层提取。

当预训练结束以后,则需要一层具有分类功能的输出层来判断设备的故障类型,使用 BP 算法对深度学习网络进行有监督微调,其输出层输出表示为

$$y^m = f_{\theta_{N+1}}(h_N^m) \quad (6)$$

式中, $\theta_{N+1}$ 是输出层的参数。设输入数据的故障类型  $z^m$ ,则最小化

$$\phi(\Theta) = \frac{1}{n} \sum_m L(y^m, z^m) \quad (7)$$

式中, $\Theta = \{\theta_1, \theta_2, \dots, \theta_{N+1}, L\}$ 为深度学习网络的参数集合。从而完成对深度学习网络进行有监督微调。其

预训练和微调流程如图 3 所示。

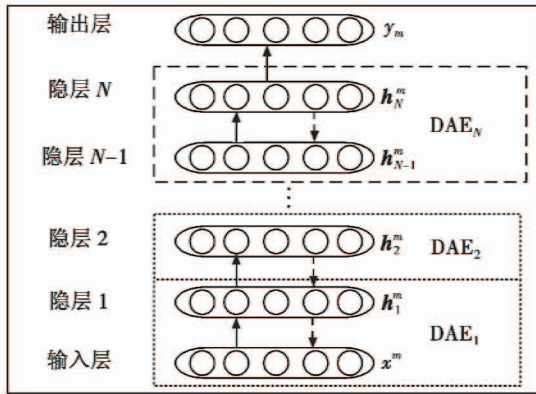


图 3 网络预训练和微调流程图

Fig.3 Flow chart of network pre-training and fine adjustment

经过预训练和微调的深度学习网络优化了对故障类型的特征表示,具备了装备故障诊断的能力。

## 2 基于深度学习的装备故障诊断方法

本文结合大数据的特点,利用深度学习方法,实现装备的故障诊断。通过深度学习网络,利用无监督特征学习和有监督微调整个网络系统,实现大数据装备故障特征提取和故障类型模式识别,其具体步骤如图 4 所示。

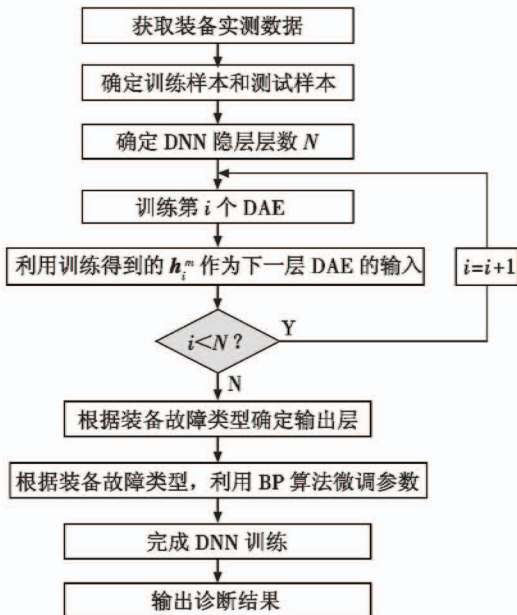


图 4 基于深度学习的故障诊断方法实验步骤

Fig.4 Experimental steps of the fault diagnosis method based on deep learning

通过上述实验步骤,完成对装备的故障诊断。

## 3 实验验证

### 3.1 实验数据

本文以通信电台发生“抗干扰收正常,发不正常”

的故障现象为例,对其进行故障分析,结合其工作原理和专家经验,将此故障现象下可能的故障模块、相应的样本个数和故障模块标签对应关系列于表 1。

表 1 “抗干扰收正常、发不正常”故障状态对应关系

Table 1 Fault state of “Normal receiving and abnormal sending in anti-interference”

故障模块	特征参数	样本个数	模块标签
前面板模块	发信端电流 发射功率	300	1
同步模块	发信端电流 频率误差	300	2
激励模块	发信端电流 频率误差 发射功率	300	3
功放模块	发信端电流 发射功率 侧音电平 侧音响应 侧音失真	500	4

可能导致该故障状态发生的模块有 4 个,各模块对应的主要特征参数也不相同。实验采集得到的样本数据,除了功放模块故障数据为 500 个以外,其他模块都为 300 个,正常工作的数据也有 300 个,标签设为 0。实验中,随机选择 50% 的样本用于训练,剩余的用于测试,实验重复进行 10 次。本文 DNN 结构为 8-8-16-16-输出层,共计 5 层,每层神经元个数分别为 8, 8, 16, 16。利用有标签的训练数据训练神经网络,完成数据的特征学习,使用 BP 算法对学习网络进行有监督微调;将测试数据输入训练好的网络,通过网络和输出层,输出预测标签的结果,从而完成故障模块诊断。

### 3.2 故障诊断结果

本文所提方法的实验结果准确率如图 5 所示,由图可知所有实验的准确率都在 94% 以上,表明该方法在完成故障诊断时的准确性较高。为了比较,利用单隐层的 BP 神经网络诊断相同的数据集,实验结果也表示在图 5。




图 5 不同方法 10 次实验的诊断准确率

Fig.5 Diagnostic accuracy of different methods in 10 experiments

实验结果表明,本文方法相比较于单隐层的 BP 神经网络方法,诊断准确率高出很多,且诊断的准确率的波动较小。这是由于单隐层的 BP 神经网络的单层模型,因为层数限制而不能有效地进行数据特征学习,从而导致诊断准确率不高。

#### 4 结语

本文简单介绍装备故障大数据的特点,提出一种以深度学习为基本理论电子装备故障诊断方法。通过多层神经网络和输出层,利用无监督特征学习和有监督微调,有效地提取各数据中蕴藏的故障信息;利用输出层的模式分类,完成装备模块故障诊断。

#### 参 考 文 献

[1] BUXTON B, GOLDSTON D, DOCTORO C, et al. Big data; science in the petabyte era [ J ]. Nature, 2008, 455 ( 7209 ): 8-9.

[2] 李国杰,程学旗. 大数据研究:未来科技及经济社会发展的重大战略领域——大数据的研究现状与科学思考[J]. 中国科学院院刊,2012,27(6):647-657.

[3] 李学军,李平,蒋玲莉. 类均值核主元分析法及在故障

诊断中的应用[J]. 机械工程学报,2014,50(3):123-129.

[4] 刘建伟,刘媛,罗雄麟. 深度学习研究进展[J]. 计算机应用研究,2014,31(7):1921-1930.

[5] BENGIO Y. Learning deep architectures for AI [ J ]. Foundations and Trends in Machine Learning, 2009, 2 ( 1 ): 1-127.

[6] CHERIYADAT A M . Unsupervised feature learning for aerial scene classification[ J ]. IEEE Transactions on Geoscience & Remote Sensing, 2013, 52 ( 1 ): 439-451.

[7] SHIN H C, ORTON M R, COLLINS D J, et al. Stacked autoencoders for unsupervised feature learning and multiple organ detection in a pilot study using 4D patient data[ J ]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35 ( 8 ): 1930-1943.

[8] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders[ C ]//Proceedings of the 25th International Conference on Machine Learning, ACM, 2008:1096-1103.

[9] YOON H, PARK C S, KIM J S, et al. Algorithm learning based neural network integrating feature selection and classification [ J ]. Expert Systems with Applications, 2013, 40 ( 1 ): 231-241.

(上接第 64 页)

[10] 王彬彬,王辉,丰建. 基于抗差估计的控制网数据处理方法探究[J]. 科技视界,2016(21):27-28.

[11] SIMANDL M, KRALOVEC J, SODERSTROM T. Anticipative grid design in point-mass approach to nonlinear state estimation [ J ]. IEEE Transactions on Automatic Control, 2002, 47 ( 4 ): 699-702.

[12] GUSTAFSSON F, GUNNARSSON F, BERGMAN N, et al. Particle filters for positioning, navigation, and tracking [ J ]. IEEE Transactions on Signal Processing, 2002, 50 ( 2 ): 425-437.

[13] JULIER S J, UHLMANN J K, DURRANT-WHYTE H F.

A new method for the nonlinear transformation of means and covariances in filters and estimators[ J ]. IEEE Transactions on Automatic Control, 2000, 45 ( 3 ): 477-482.

[14] JULIER S J. The scaled unscented transformation[ C ]// Proceedings of the American Control Conference, IEEE, 2002:4555-4559.

[15] CRASSIDIS J L, MARKLEY F L. Predictive filtering for nonlinear systems[ J ]. Journal of Guidance, Control, and Dynamics, 1997, 20 ( 3 ): 566-572.

[16] HUNT L R, LUKSIC M, SU R J. Exact linearizations of input-output systems [ J ]. International Journal of Control, 1986, 43 ( 1 ): 247-255.

