

深度学习在家用空调外机振动检测中的应用*

程炜为¹ 刘芝庭² 王宇华¹

(1.佛山科学技术学院, 广东 佛山 528000 2.广州赛宝腾睿信息科技有限公司, 广东 广州 510610)

摘要: 利用堆叠自动编码器神经网络对家用空调外机的振动测量信号进行无监督特征值提取; 采用梯度下降算法对神经网络进行有监督学习; 结合 Softmax 分类器对测量信号进行分类; 通过实验确定隐层的层数和节点数, 并对神经网络的学习率、衰减因子、L2 正则化、Dropout 因子、批量样本个数等参数的影响进行实验分析, 为家用空调外机的振动自动化诊断检测提供实验依据。

关键词: 故障诊断; 深度学习; 自动编码器

中图分类号: TP216

文献标识码: A

文章编号: 1674-2605(2021)03-0008-05

DOI: 10.3969/j.issn.1674-2605.2021.03.008

0 引言

振动和噪声是影响家电静音质量的重要指标, 也是家电工作状态是否正常的直接反映。随着家电生产线自动化程度的提高, 家电产品振动、噪声的检测和原因分析也需同步自动化、智能化。家电产品的振动检测和故障诊断一般利用振动检测传感器实时检测其在各种运行工况下的振动数据, 并根据振动数据分析振动源、振动因素以及是否存在故障和故障因素。

本文利用堆叠自动编码器 (stacked auto encoder, SAE) [1]神经网络对家用空调外机振动测量信号进行特征量提取, 结合 Softmax[2]函数对家用空调外机在生产线上检测的 6 种工况进行诊断和分类识别。

1 深度学习基本原理

1.1 自动编码器

自动编码器 (auto encoder, AE) 神经网络由编码和解码 2 部分组成, 分为输入层、隐层和输出层, 模型如图 1 所示。其中, 隐层是编码层, 当编码层节点数小于输入节点数, 编码网络利用激活函数将输入层的高维度数据映射到低维度的隐层, 实现数据特征提取。解码网络对隐层进行解码, 复原输入层数据。利用梯度下降算法[3]调整网络的权值, 直至损失函数达到最小值, 以确保隐层特征值的可靠性。




图 1 AE 模型

设输入层为 $\{x_1^m, x_2^m, \dots, x_n^m\}$ (n 个维度为 m 的输入样本); 隐层为 $\{h_1^k, h_2^k, \dots, h_n^k\}$ (n 个维度为 k 的特征向量); 输出层为 $\{\hat{x}_1^m, \hat{x}_2^m, \dots, \hat{x}_n^m\}$ (n 个维度为 m 的重构样本), 本文选用 tanh 激活函数。

隐层输出公式为

$$f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (1)$$

$$h = f_{\theta_1}(z) = f(w_1 x + b_1) \quad (2)$$

式中, h 为隐层激活值; θ_1 为编码网络参数 $\{w_1, b_1\}$; w_1 为权值矩阵; b_1 为偏置; x 为输入样本。

输出层公式为

$$\hat{x} = f_{\theta_2}(z) = f(w_2 x + b_2) \quad (3)$$

式中, θ_2 为解码网络参数 $\{w_2, b_2\}$; w_2 为权值矩阵;

40 * 基金项目: 广东省区域联合基金资助 (2019A1515110418); 广东省公益研究与能力建设专项资金资助 (2015B010101014)。

b_2 为偏置。

AE 神经网络寻找最佳网络参数 $\theta^* = \{w_1^*, b_1^*, w_2^*, b_2^*\}$, 使重构样本 $\hat{x}$ 与输入样本 x 间的误差最小, 即损失函数 $L(w_1, b_1, w_2, b_2)$ 最小化。损失函数表达式为

$$L(w_1, b_1, w_2, b_2) = \frac{1}{n} \sum_{i=1}^n \frac{1}{2} (x^i - \hat{x}^i)^2 + \frac{\lambda}{2} \sum_{l=1}^s \sum_{i=1}^m \sum_{j=1}^k (w_{ij}^l)^2 \quad (4)$$

式中, 第一项为输入层与输出层的误差总和; x^i 为输入的第 i 个样本; $\hat{x}^i$ 为输出; n 为样本个数; 第二项为正则化约束项, 以防止过拟合。

1.2 基于深度学习的特征提取

单个 AE 构造函数的能力有限, 为构造表达能力更强的函数, 将多个 AE 堆叠组成堆栈自动编码器 (stacked auto encoder, SAE)。将第 1 个 AE 的隐层作为第 2 个 AE 的输入层, 第 2 个 AE 的隐层作为第 3 个 AE 的输入层, 如此将多个 AE 堆叠, 即可实现深度神经网络 (deep neural networks, DNN)。3 层 SAE 模型如图 2 所示。




图 2 3 层 SAE 模型

1.3 Softmax 分类器

Softmax 分类器针对多分类问题的 Softmax 函数为

$$y_i = \zeta(\mathbf{x})_i = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (5)$$

式中, $i = 1, 2, 3, \dots, k$ 为输出类别编号; $\mathbf{x}$ 为输入特征向量。

设训练样本为 $\{(x^1, \hat{y}^1), \dots, (x^n, \hat{y}^n)\}$; $\mathbf{x}$ 为维度 m 的向量; 类别标签 y 可取 k 个不同值; 网络参数 $\theta^* = \{w_{ij}, b_j\}$ 。概率 $p = (y = j | \mathbf{x}^i; \theta)$ 表示在输入 $\mathbf{x}^i$ 和网络参数 θ 的情况下, 样本被判别为第 i 类的概率。一个 k 分类的 Softmax 分类器将输出一个 k 维的向量 (向量的元素和为 1)。Softmax 分类器在网络参数 θ 和输入 x 条件下的输出为

$$y_\theta(\mathbf{x}^i) = \begin{pmatrix} p(y^i = 1 | \mathbf{x}^i; \theta) \\ p(y^i = 2 | \mathbf{x}^i; \theta) \\ \vdots \\ p(y^i = k | \mathbf{x}^i; \theta) \end{pmatrix} = \frac{1}{\sum_{j=1}^k \exp(\theta_j; \mathbf{x}^i)} \begin{pmatrix} \exp(\theta_1; \mathbf{x}^i) \\ \exp(\theta_2; \mathbf{x}^i) \\ \vdots \\ \exp(\theta_j; \mathbf{x}^i) \end{pmatrix} \quad (6)$$

式中, θ_j 为第 j 类输出的模型参数; $y_\theta(\mathbf{x}^i)$ 之和为 1。Softmax 模型的代价函数为交叉熵函数:

$$L(\theta) = -\frac{1}{n} \sum_{i=1}^n \hat{y} \ln y_i + (1 - \hat{y}) \ln(1 - y_i) \quad (7)$$

式中, $\hat{y}$ 为真实输出, 通过最小化 $L(\theta)$ 求解最佳参数 θ^* 。

1.4 深度学习诊断网络

将 SAE 和 Softmax 分类器结合组成一个深度学习诊断网络, 其模型如图 3 所示。




图 3 深度学习诊断网络模型

SAE 网络对信号进行识别分类分为 2 阶段: 1) 利用 SAE 对原始数据进行逐层特征提取, 此部分为非监督学习阶段, 逐级对单独的 AE 层进行训练, 利用梯度下降算法对各 AE 层网络参数进行调整, 保

证编码网络能精确提取原始信号的特征; 2) 将最终隐层作为特征向量输入 Softmax 分类器进行分类, 此部分为监督学习阶段, 利用梯度下降算法对全局网络权值和偏值进行微调。

2 数据分析

2.1 实验数据检测

空调外机的主要振动源为压缩机、风扇和电机等。采用 He-Na 激光测振仪 LV-S01, NI USB-6212 采集卡对空调外机的 6 种工况进行振动数据的检测采样, 每种工况采样 2000 组, 一共 12000 组数据, 采样率为 1000, 采样时长为 2 s, 如表 1 所示。

表 1 空调外机 6 种工况振动数据采样		
标签	状态	样本数
1	正常	2000
2	缺少隔音棉	2000
3	扇叶裂纹	2000
4	扇叶不平衡	2000
5	缺少阻尼块	2000
6	风扇支架松动	2000

为研究不同输入信号对深度学习诊断网络的影响, 分别选取检测数据的时域、频域、时域+频域信号输入该网络。经过大量的网络处理对比实验发现: 频域信号分类正确率最高, 时域+频域信号次之, 时域信号最差。空调外机 6 种工况信号频谱如图 4 所示。




图 4 空调外机 6 种工况信号频谱

2.2 实验数据分析

信号输入网络做 0,1 归一化处理:

$$\hat{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{8}$$

实验分析显示, 第一层隐层的层数和节点数对分类正确率的影响较大。为确定合适的层数和节点数, 构建层数为 N ($N=1,2,3,4,5$) 的 SAE 网络, 并分别令节点数为 400, 300, 200, 100 进行实验(学习率为 0.5, 衰减因子为 1, L2 范正则化系数为 0, 批量处理样本个数为 800, Dropout 因子为 0, 预训练次数为 100, 微调次数为 1000)。分类正确率与隐层的层数关系如图 5 所示。




图 5 分类正确率与隐层的层数关系

由图 5 可知: 在不同隐层的层数和节点数下, 分类正确率呈凸函数变化。当层数为 3、节点数为 100 时, 分类正确率最高, 故取深度学习诊断网络节点数为 100, 层数为 3。

深度学习诊断网络在训练过程中学习率、衰减因子、L2 范正则化、Dropout 因子和批量处理样本个数等参数对提高分类正确率也有一定影响, 对以上参数进行单一变量分析。训练深度学习诊断网络时, 学习率对正确率有较大影响, 学习率过大导致网络无法收敛至最优解, 学习率过小导致网络收敛速度缓慢。不同学习率的参数设置如表 2 所示。

表 2 不同学习率的参数设置		
参数指标	组 1	组 2
学习率	0.9	0.1
衰减因子	1	1
L2 范正则化	0	0
批量次数	800	800
Dropout 因子	0	0
正确率/%	33.33	92.58

衰减因子可在每一轮迭代中更新学习率，使学习率动态变化，有无衰减因子的参数设置如表 3 所示。

表 3 有无衰减因子的参数设置

参数指标	组 1	组 2
学习率	0.1	0.1
衰减因子	1	0.99
L2 范正则化	0	0
批量次数	800	800
Dropout 因子	0	0
正确率/%	92.58	98.42

L2 范正则化可对网络参数进行限制，防止过拟合。有无正则化的参数设置如表 4 所示。

表 4 有无 L2 范正则化的参数设置

参数指标	组 1	组 2
学习率	0.1	0.1
衰减因子	0.99	0.99
L2 范正则化	0	0.01
批量次数	800	800
Dropout 因子	0	0
正确率/%	98.42	95.42

Dropout 因子在梯度下降算法中关闭部分网络参数的更新，以防止过拟合。有无 Dropout 因子的参数设置如表 5 所示。

表 5 有无 Dropout 因子的参数设置

参数指标	组 1	组 2
学习率	0.1	0.1
衰减因子	0.99	0.99
L2 范正则化	0	0
批量次数	800	800
Dropout 因子	0	0.05
正确率/%	98.42	99.25

在确定学习率为 0.1，衰减因子为 0.99，L2 范正则化系数为 0，Dropout 因子为 0.05，预训练次数为 100，微调训练次数为 1000 的条件下，对批量处理样

本个数进行分析，如表 6 所示。不同参数模型错误率如图 6 所示。

表 6 不同批量处理样本个数正确率

批量样本个数	迭代次数	正确率/%
800	6000	98.42
600	8000	99.50
300	16000	99.67
100	48000	99.75
50	96000	99.92
20	240000	99.83
10	480000	99.83
5	960000	99.83




图 6 不同参数模型错误率

由上述分析可知：分类正确率受学习率的影响最大；衰减因子和 Dropout 因子能略微提升分类正确率；L2 范正则化不一定能提升分类正确率；批量训练样本个数并不是越小越好。

3 结论

本文利用 SEA 深度神经网络对家用空调外机进行振动检测诊断，对检测信号的类型、网络参数的选取和确定进行实验分析。在 6 种不同工况下的 SEA 检测诊断正确率达 99.92%，可初步满足产品出厂的检验要求，为家用空调外机振动检测诊断提供了新途径。SEA 检测诊断方法的进一步实用化，还需用先验的方法收集涵盖各种可能的质量故障工况的特征信号和优化检测诊断网络的参数，以进一步提高检测诊断网络的应用范围和检测正确率。

(下转第 49 页)