DOI: 10.3901/JME.2019.07.052

基于动态加权密集连接卷积网络的变转速行星齿轮箱故障诊断*

熊 鹏 汤宝平 邓 蕾 赵明航
(重庆大学机械传动国家重点实验室 重庆 400044)

摘要: 针对变转速工况下基于深度学习的行星齿轮箱故障诊断问题, 提出动态加权密集连接卷积网络的故障诊断方法。将行星齿轮箱振动信号的小波包系数二维矩阵输入到密集连接卷积网络作为网络的初始特征图; 在密集连接卷积网络的跨层连接中加入动态加权层, 形成动态加权密集连接卷积网络, 加强网络的深层信息传递; 通过动态加权网络层自适应提取不同频段内的故障特征信息进行行星齿轮箱故障诊断。试验表明了所提的动态加权密集连接卷积网络能有效诊断变转速行星齿轮箱故障。

关键词: 密集连接卷积网络; 故障诊断; 特征学习; 小波包变换; 行星齿轮箱

中图分类号: TH17

Fault Diagnosis for Planetary Gearbox by Dynamically Weighted Densely Connected Convolutional Networks

XIONG Peng TANG Baoping DENG Lei ZHAO Minghang

(The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044)

Abstract: Aiming at applying deep learning in fault diagnosis of the planetary gearbox, a fault diagnosis method based on dynamically weighted densely connected convolutional networks is proposed. The wavelet packet coefficient matrix of the planetary gearbox vibration signal is taken as the initial feature map for densely connected convolutional networks. Dynamically weighted layers are designed in cross-layer of densely connected convolutional networks to form dynamically weighted densely connected convolutional networks to enhance information flow in deep network layers. The fault features are extracted by dynamically weighted network layers adaptively to perform the planetary gearbox fault diagnosis. The experiment indicates that the dynamically weighted densely connected convolutional networks can realize fault diagnosis of planetary gearbox under varying speed condition more effectively.

Key words: densely connected convolutional networks; fault diagnosis; feature learning; wavelet packet transform; planetary gearbox

0 前言

行星齿轮箱具有传动比大、效率高等诸多优点, 已被广泛应用于风电、航空、船舶等行业的机械传动系统中, 其故障诊断问题不容忽视^[1]。行星齿轮箱的结构复杂, 其太阳轮与行星轮、行星轮与内齿圈啮合时产生的激励信号混叠, 且伴随转轴上轴承振动信号干扰, 行星齿轮箱故障所激励的信号常淹没在噪声中, 故障特征成分微弱, 导致其故障诊断

困难。基于信号处理的故障诊断方法^[2-3]和基于传统机器学习的故障诊断方法^[4]都未能很好地解决变转速工况下行星齿轮箱故障诊断问题, 近几年基于深度学习^[5]的行星齿轮箱故障诊断的研究日益增多^[6-8], 然而, 常用的深度学习算法的层数普遍较深、参数规模较大、深度学习故障诊断方法常遭遇网络模型训练困难的问题^[9-11]。

密集连接卷积网络^[12]利用跨层连接实现特征图信息的复用, 克服因网络层数深、参数规模大导致的网络模型训练困难的问题, 可以应用于行星齿轮箱故障诊断中。然而, 行星齿轮箱转速的变化会造成同类故障样本间的差异变大, 不同类故障样本间的差异相对减小, 降低了密集连接卷积网络对变

* 国家自然科学基金资助项目(51775065, 51675067)。20180709 收到初稿, 20181221 收到修改稿

转速工况的特征表征能力,严重影响基于密集连接卷积网络的故障识别率。因此本文提出基于动态加权密集连接卷积网络的变速行星齿轮箱故障诊断方法,采用动态加权的方法对跨层连接特征图对应的小波包系数矩阵进行动态权重调整,实现对不同频段信息自适应加权的功能,加强密集连接卷积网络对变速转速工况的特征表征能力,提高变速行星齿轮箱故障识别率。

1 密集连接卷积网络

普通的卷积神经网络,通过不同的网络层对输入的数据进行变换后向末端传导。一个卷积网络模型包含 M 层,每个神经网络层进行非线性网络变换 $H_m(\cdot)$, m 代表网络层数。 $H_m(\cdot)$ 作为综合函数,即为批量标准化、激活、池化与卷积操作的综合。把第 m 层网络的输出定义为 x_m 。

图1 综合变换 H_m

在常用的卷积神经网络中,网络层与网络层之间前后连接。把第 m 层网络的输出作为 $(m+1)$ 网络层的输入,完成网络层与网络层之间的特征图变换传递,如式(1)与图2所示

$$x_m = H_m(x_{m-1}) \quad (1)$$

图2 普通卷积神经网络的前向传播过程

密集连接卷积网络是在常规的卷积网络中采用了一种全新的连接模式。基于跨层连接网络中的前后卷积层使得信息流可以在输入层和输出层之间高速流动,密集连接卷积网络中将所有相同特征维度的卷积层都进行两两连接,使得网络中的每一层都接受它的前续层输出的特征图作为输入。为了让特征图能够反复利用,在跨层连接时特征图采用并联粘接的方式,即每一层网络的输入由前面所有层的输出构成。图3展示了一个只有三层密集连接的密集块。

通过这种跨层并联粘接方式,密集块内的第 m 层接受了所有前续层输出的特征图 $x_0, x_1, \dots, x_{m-1}$ 的

并联粘接作为它的输入

$$x_m = H_m([x_0, x_1, \dots, x_{m-1}]) \quad (2)$$

矩阵 $[x_0, x_1, \dots, x_{m-1}]$ 表示为前面第 $0, 1, \dots, m-1$ 卷积层输出特征图的并联粘接。密集连接卷积网络通过对特征图的极致利用达到更好的效果。

图3 密集块示意图

密集连接卷积网络里面的网络层向后续层进行直接连接时,必须保证前续层与后续层的特征图尺寸相同。但是网络层中的特征图尺寸大小不能一直保持不变,否则网络模型的运算量将会增大。因此有必要随着网络向后端传输时,特征图的尺寸大小要逐步变小。因此按特征图尺寸大小的把网络层划分成不同的密集块,密集块内的特征图尺寸大小保持一致,密集块间的特征图尺寸依次变小。

特征图尺寸不同的密集块之间通过过渡层连接,形成密集连接卷积网络的主干。密集块内可以有数量不一的卷积层,卷积层内可以有多种不同类型卷积的综合变换组合。图4展示了一个具体的密集连接卷积网络的结构。

图4 完整的密集连接卷积网络结构

过渡层由卷积层与池化层构成,用于减少特征图维数与尺寸,实现了跨通道的信息组合,并增加了非线性特征。对密集块粘接后输出的特征

图进行 1×1 卷积, 降低特征图的维数, 以减少后续网络层的运算量。然后利用尺寸为 2×2 , 步长为 2 的平均池化对其进行池化操作, 使输出的特征图尺寸减半。

若图 4 中的每个卷积层输出 k 个特征图, 那么密集块内的第 n 个卷积层将有 $k_0 + k \times (n-1)$ 个特征图并联粘接输出, k_0 代表初始输入层的通道数。这个超参数 k 为卷积层内 $f \times f$ (f 为大于 1 的自然数) 卷积核的数目, 作为密集连接卷积网络的增长率。密集连接卷积网络相对较深, 网络宽度变窄。已有的研究^[12]验证了即使相对较小的增长率, 密集连接网络也能取得很好效果。

密集连接卷积网络与普通卷积神经网络的不同之处在于密集块内的卷积层输出的特征图都可以直接向后跨层并联粘接作为输出成为后续卷积层的输入。密集连接卷积网络按网络内部的特征图尺寸划分成不同的密集块, 密集块之间用过渡层来连接, 在过渡层中完成特征图维数与尺寸的变换, 最后通过全局平均池化与全连接层构成完整的密集连接卷积网络。

2 基于动态加权密集连接卷积网络的行星齿轮箱故障诊断

2.1 密集连接卷积网络初始特征图

行星齿轮箱的变转速, 其振动信号强烈的非稳态特性从而需要用时频分析方法进行处理。利用小波包^[13-15]对非稳态信号进行处理, 可以把信号分解到不同的频带, 在每个频带中有一系列小波包系数。每个小波包节点的系数包含了在不同频带上的故障信息。本文尝试对比不同结构的深度卷积神经网络的识别能力, 没有对小波包不同层的小波包系数进行分析比较。通过小波包变换把变转速振动信号分解成小波包系数二维矩阵作为深度卷积神经网络的特征图输入。

2.2 动态加权密集连接

在密集连接卷积网络中密集块内的跨层连接时所有卷积层都是平等关系, 均为把当前层与前续层输出的特征图进行并联粘接后再进行综合变换操作。密集块内所有卷积层输出的跨层特征图在并联粘接时应该是有主次分别的, 即跨层连接时当前层输出的特征图起到主要作用, 之前所有层输出的特征图起到辅助作用。但是直接对恒等映射的跨层连接进行加权会影响密集连接的作用^[10], 因此不考虑对输入到后续层的特征图直接施加重数。同时考虑

到输入的小波包系数矩阵的特点, 不同频带的小波包系数携带的故障特征信息不一致, 有必要对小波包系数矩阵里面不同频带的系数施加不同的权重比例, 使之更加有效地提取出有效的故障特征信息。基于以上考虑, 设计一个动态加权层对小波包系数进行加权。

动态加权层对变换后的小波包不同频带对应的特征图进行动态加权, 特别是对里面的频带系数均施加重数, 权重随机初始化设置, 采样梯度下降法与卷积网络一同训练。以如下公式表示

$$y_i = x_i \cdot w_i \quad (3)$$

在公式中, x_i 指定为输入特征图的第 i 行, 即小波包系数变换矩阵的第 i 行小波包系数。 w_i 是与第 i 行的每个小波包系数相乘的权重系数, y_i 为输出的加权的特征图。对小波包系数进行的动态加权的过图如图 5 所示。

图 5 对小波包矩阵进行动态加权

动态加权层的所有权重在训练过程中用梯度下降法进行同样的迭代训练。经过网络动态加权, 小波包系数矩阵不同频带的系数赋予不同的权重, 实现对不同频带信息自适应加重的功能。一个只有三层综合变换的动态加权密集连接块如图 6 所示。

图 6 动态加权密集块示意图

2.3 故障诊断流程

利用小波包变换和动态加权密集连接卷积网络进行行星齿轮箱故障状态识别。图 7 展示了利用动态加权密集连接卷积网络进行变转速下行星齿轮箱的故障诊断流程。

图7 基于动态加权密集连接网络的故障诊断流程图

通过独特设计的动态加权层，添加到密集块中形成动态加权密集块，形成动态加权密集连接卷积网络用于行星齿轮箱故障诊断。首先利用小波包变换对振动信号进行处理，转换成小波包系数矩阵，作为动态加权密集连接网络的原始输入，最后全连接层分类识别出行星齿轮箱的不同的故障类别。

3 实例验证

行星齿轮箱故障诊断试验台如图8所示，由一个电动机、一个二级行星齿轮箱、二级平行齿轮箱、扭矩控制器、磁粉制动器等部分构成。

图8 行星齿轮箱故障诊断综合试验台

通过水平与竖直安置在行星齿轮箱部位的两个振动传感器采集振动信号。其不同故障状态如表1所示。

表1 行星齿轮箱不同健康状态的描述

状态	描述	标签
健康	行星齿轮箱中无故障	类别1
故障	轴承滚动体故障、齿轮无故障	类别2
	轴承内圈故障、齿轮无故障	类别3
	轴承外圈故障、齿轮无故障	类别4
	轴承复合故障、齿轮无故障	类别5
	轴承无故障、行星齿轮齿根裂纹	类别6
	轴承无故障、行星齿轮表面点蚀	类别7
	轴承无故障、行星齿轮断齿	类别8
	轴承无故障、行星齿轮缺齿	类别9

针对九种不同类别的行星齿轮箱故障状态，分别采集48 s时间段内转速由20 Hz线性加速上升到36 Hz的振动信号。采集卡以25.6 kHz的采样频率采取振动信号，每种状态的振动信号分别采集四次。

数据采集完成后，需要对数据进行简单的前续处理。首先将48 s的振动数据样本划分成300段，每段包含了4 096个点的振动信号。因此每种状态类别的振动数据样本为1 200个。每种状态的样本被随机分为训练样本集与测试样本集，随机选取1 000个样本作为训练样本集，余下的200个样本作为测试样本集。对数据样本进行小波包变换，获取第六层的小波包系数矩阵。这样每个终端节点就会包含 $4\,096/2^d=4\,096/2^6=64$ 个小波包系数， d 为小波包分解的层数。获得尺寸大小为 64×64 的小波包系数矩阵，作为动态加权密集连接卷积网络的输入。

3.1 超参数设置

根据网络层数、样本数目等对网络模型的超参数进行设置^[16]。卷积神经网络的学习率如果设置过大，容易越过最优值，设置太小则容易训练过慢，综合考虑设置为0.01。批量大小是同时输入一个网络的样本数目，其大小根据网络参数数目与运行显存大小来指定，综合设置为100。动量是权重更新系数^[17]，使之前的迭代能够帮助本次的迭代使系数更新，加速训练过程与避免局部最优，此参数设为0.5。权重进行了随机初始化，偏重系数初始化为零。增长率 k 为密集块中卷积层的卷积核数目，若 k 较大，输入的特征图维度多大，对网络运算性能要求过高。若 k 值太小，输出的特征图维度过小，可能会遗漏传递的信息。依据计算机运行性能、网络深度、初始输入特征图尺寸设定 k 值为12。

试验中的动态加权密集连接网络的网络层数、密集块中卷积尺寸大小与数目、移动步长、以及池化操作等参数如表2所示。

表2 动态加权密集连接卷积神经网络尺寸表

网络层	输入尺寸	卷积、池化尺寸与数量	步长	增长率	输出尺寸
卷积层	$64 \times 64 \times 1$	3×3 卷积	$\times 16$	1	$64 \times 64 \times 16$
密集连接块1	$64 \times 64 \times 16$	$\begin{bmatrix} 1 \times 1 & \text{卷积} \\ 3 \times 3 & \text{卷积} \end{bmatrix} \times 6$	1	12	$64 \times 64 \times 88$
过渡层1	$64 \times 64 \times 88$	1×1 卷积	1	—	$32 \times 32 \times 44$
		2×2 平均池化	2		
密集连接块2	$32 \times 32 \times 44$	$\begin{bmatrix} 1 \times 1 & \text{卷积} \\ 3 \times 3 & \text{卷积} \end{bmatrix} \times 6$	1	12	$32 \times 32 \times 116$
			1		
过渡层2	$32 \times 32 \times 116$	1×1 卷积	1	—	$16 \times 16 \times 58$
		2×2 平均池化	2		
密集连接块3	$16 \times 16 \times 58$	$\begin{bmatrix} 1 \times 1 & \text{卷积} \\ 3 \times 3 & \text{卷积} \end{bmatrix} \times 6$	1	12	$16 \times 16 \times 120$
			1		
全局池化	$16 \times 16 \times 120$	16×16 平均池化	1	—	$1 \times 1 \times 120$
全连接层	120	—	—	—	9

动态加权密集连接卷积网络中共有三个密集块和两个过渡层如表2所示。每个过渡层中有两层，一层用于卷积降维，另外一层用于平均池化。每个密集块中共有六个卷积模块，以及初始输入端的卷积层与最后输出端的全局平均池化层以及最后用输出故障类别的全连接层。

为了验证动态加权密集连接卷积网络的有效性，设计相同网络层数的卷积神经网络和没有进行动态加权的密集连接卷积网络与其进行对比。普通卷积神经网络的网络层数及参数设置与加权密集连接网络一致，但没有任何跨层连接。作为对比的密集连接卷积网络设置与动态加权密集连接网络保持相同大小与数量的密集块与卷积核。

3.2 试验结果分析

用已处理好的数据组对设置好的网络模型进行测试，每个网络模型分别测试十次。动态加权密集连接网络、密集连接卷积网络与卷积神经网络十次平均训练准确率均保持在96%以上，然而密集连接卷积网络和普通的卷积神经网络的测试准确率相比它们的训练准确率差异较大，且在训练后期，密集连接卷积网络与卷积神经网络的准确率波动较大，不稳定。设计的三种卷积神经网络的十次测试准确率如图9所示。

图9 三个网络模型每次训练之后的测试准确率

动态加权密集连接卷积网络、密集连接卷积网络与卷积神经网络的准确率与损失数值分别如图10、11所示。

从试验数据结果分析可看出，动态加权密集连接卷积网络的性能最优，在对小波包系数进行动态加权后，不但收敛的速度最快，且达到最高值后趋于稳定。普通的卷积神经网络在训练后期损失函数波动较大，其性能在后期训练时趋于饱和。密集连接卷积网络比动态加权密集连接网络的测试精度低，而且测试损失数值波动大，测试精度很不稳定。动态加权密集连接卷积网络结构融合了密集连接卷积网络和动态加权层二者的优势，既能加强深

(a) 训练准确率

(b) 测试准确率

图10 三种网络的训练与测试准确率

(a) 训练损失

(b) 测试损失

图11 三种网络的训练与测试损失

层信息的传递，避免梯度消失，又可以实现变转速振动信号的特征提取。试验表明了本文设计的动态加权密集连接卷积网络能有效诊断变转速行星齿轮箱故障。

4 结论

(1) 在同等网络深度的条件下, 密集连接卷积网络比普通的卷积网络对变转速行星齿轮箱的故障识别率更高, 收敛速度更快。

(2) 通过动态加权网络层, 对变换后的小波包不同频带信息进行自适应权重叠加, 提取不同频带内的故障特征信息, 使动态加权密集连接卷积网络的故障诊断性能优于密集连接卷积网络。

(3) 通过对跨层连接特征图进行并联粘接, 实现对信息的高效利用, 使密集连接卷积网络的训练更加平稳, 性能更加稳定。

参 考 文 献

- [1] 雷亚国, 何正嘉, 林京, 等. 行星齿轮箱故障诊断技术的研究进展[J]. 机械工程学报, 2011, 47(19): 59-67.
LEI Yaguo, HE Zhengjia, LIN Jing, et al. Research advances of fault diagnosis technique for planetary gearboxes[J]. Journal of Mechanical Engineering, 2011, 47(19): 59-67.
- [2] LEI Yaguo, LIN Jing, ZUO M J, et al. Condition monitoring and fault diagnosis of planetary gearboxes: A review[J]. Measurement, 2014, 48(1): 292-305.
- [3] 何国林, 丁康, 林慧斌. 基于匹配追踪的齿轮箱耦合调制振动信号分离方法研究[J]. 机械工程学报, 2016, 52(1): 102-108.
HE Guolin, DING Kang, LIN Huibin. Matching pursuit method for coupling modulation signal separation of gearbox vibration[J]. Journal of Mechanical Engineering, 2016, 51(1): 102-108.
- [4] YU Jun, HE Yongjun. Planetary gearbox fault diagnosis based on data-driven valued characteristic multigranulation model with incomplete diagnostic information[J]. Journal of Sound and Vibration, 2018, 429: 63-77.
- [5] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436.
- [6] JIA Feng, LEI Yaguo, LIN Jing, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems & Signal Processing, 2016, 72-73: 303-315.
- [7] HE Miao, HE D. Deep Learning based approach for bearing fault diagnosis[J]. IEEE Transactions on Industry Applications, 2017, 53(3): 3057-3065.
- [8] WANG Lihua, ZHAO Xiaoping, WU Jiaxin, et al. Motor fault diagnosis based on short-time fourier transform and convolutional neural network[J]. Chinese Journal of Mechanical Engineering, 2017, 30(6): 1-12.
- [9] SRIVASTAVA R K, GREFF K, SCHMIDHUBER J. Training very deep networks[C]// Proceedings of the 28th International Conference on Neural Information Processing Systems(NIPS), December 7-12, 2015, Montreal, Canada. Cambridge, MA, USA: MIT Press, 2015: 2377-2385.
- [10] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 26-July 1, 2016, Las Vegas, Nevada, United States, 2016: 770-778.
- [11] ZHAO Minghang, KANG M, TANG Baoping, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4290-4300.
- [12] HUANG Gao, LIU Zhuang, WEINBERGER K Q, et al. Densely connected convolutional networks[C]// 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, Honolulu, USA 2017: 2261-2269.
- [13] WALNUT D. F. An introduction to wavelet analysis[M]. Boston, MA, USA: Birkhäuser, 2004.
- [14] YAN Ruqiang, GAO R X, CHEN Xuefeng. Wavelets for fault diagnosis of rotary machines: A review with applications[J]. Signal Processing, 2014, 96(5): 1-15.
- [15] WANG Yi, XU Guanghua, LIANG Lin, et al. Detection of weak transient signals based on wavelet packet transform and manifold learning for rolling element bearing fault diagnosis[J]. Mechanical Systems & Signal Processing, 2015, 54-55: 259-276.
- [16] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification[C]// Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), Dec.13-16, 2015, Vis, Santiago, Chile, Washington, DC, USA: IEEE Computer Society, 2015: 1026-1034.
- [17] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. Deep learning[M]. Cambridge: MIT Press, 2016.

作者简介: 熊鹏, 男, 1989 年出生, 博士研究生。主要研究方向为机械故障识别。

E-mail: davidxiongpeng@gmail.com

汤宝平(通信作者), 男, 1971 年出生, 博士, 教授, 博士研究生导师。主要研究方向为机电装备安全服役与寿命预测、测试计量技术及仪器、无线传感器网络等。

E-mail: bptang@cqu.edu.cn