

DOI:10.19651/j.cnki.emt.2005553

基于 GA-CNN 的滚动轴承故障诊断

李雪颖 刘慧明

(青岛科技大学 自动化与电子工程学院 青岛 266000)

摘要:为了解决滚动轴承故障诊断中人工选择卷积神经网络(CNN)结构具有不确定性从而导致诊断准确率低的问题,以CNN为基础,提出一种应用遗传算法(GA)自适应选择CNN网络结构的滚动轴承故障诊断新方法GA-CNN。首先对滚动轴承故障信号进行特征提取,然后将故障特征分别输入经GA改进的CNN和3组人工随机选择网络结构的CNN进行特征识别,最后将实验结果进行对比得出结论。GA自动选择CNN网络最佳结构,避免了人工选择CNN网络结构具有的不确定性,从而减少参数选择所需时间并提高滚动轴承故障诊断准确率。实验验证表明,所提出的基于GA-CNN的滚动轴承故障诊断方法与人工随机选择CNN网络结构相比,极大提高了故障诊断效率并具有更高的准确性。

关键词:卷积神经网络;网络结构;遗传算法;滚动轴承故障诊断

中图分类号: TH133.3;TP18 **文献标识码:** A **国家标准学科分类代码:** 460.1520

Fault diagnosis of rolling bearing based on GA-CNN

Li Xueying Liu Huiming

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266000, China)

Abstract: In order to solve the problem that the artificial selection of the convolutional neural network structure in the rolling bearing fault diagnosis is uncertain and the diagnosis accuracy is low, based on the CNN, this paper proposes an applied genetic algorithm (GA) GA-CNN, a new method for fault diagnosis of rolling bearings that adaptively selects CNN network structure. This paper first extract features of rolling bearing fault signals, and then input the fault features into CNN improved by GA and three groups of CNN with artificially randomly selected network structures for feature recognition. Finally, a conclusion is drawn by comparing the experimental results. GA automatically selects the best structure of CNN network, avoiding the uncertainty of manual selection of CNN network structure, thereby reducing the time required for parameter selection and improving the accuracy of rolling bearing fault diagnosis. Experimental verification shows that the GA-CNN-based rolling bearing fault diagnosis method proposed in this paper greatly improves the efficiency of fault diagnosis and has higher accuracy compared with manual random selection of CNN network structure.

Keywords: convolutional neural network; network structure; genetic algorithm; fault diagnosis of rolling bearing

0 引言

滚动轴承是旋转机械中应用最多但最易损坏的机器零件,其工作好坏直接影响机械的工作状态。据不完全统计,由滚动轴承故障引起的旋转机械故障约占总故障数的30%^[1]。滚动轴承一旦发生故障将会造成财产损失以及人员伤亡等一系列严重问题。如果能够及时提取故障特征信息并进行精准判别,则可有效避免连锁故障的发生,从而减少财产损失人员伤亡^[2-3]。如何对故障特征信息进行精准判别,在故障诊断领域具有深远意义。

卷积神经网络(convolutional neural network, CNN)广泛应用于深度学习及机器视觉领域^[4]。由于CNN具有强大的特征学习能力和对复杂数据的处理能力,近几年开始应用于故障诊断领域。2016年,Guo等^[5]将深度神经网络应用于故障诊断。2018年,曲建岭等^[6]将一维卷积神经网络用于滚动轴承故障诊断。2019年,Li等^[7]提出将故障特征信息的包络谱作为CNN的输入数据进行故障诊断。2019年,Zhang等^[8]提出将故障信息转化为二维码,并使用CNN对二维码进行故障诊断。2020年,唐波等^[9]提出利用短时傅里叶变换得到滚动轴承振动时间序列的二维时频

收稿日期:2020-12-17

• 126 •

谱,通过 CNN 自适应提取利用短时傅里叶变换得到的时频谱中不同故障特征。2021 年,丁承君等^[10]等提出利用变分模态分解与 CNN 相结合的滚动轴承故障诊断。但 CNN 在各方面的应用中仍然存在很大的优化空间^[11]。大量学者对 CNN 进行了优化研究。2015 年,Rere 等^[12]提出模拟退火算法优化 CNN 全连接层权重。2016 年 Ijjina 等^[13]利用 GA 改进 CNN 初始权值并应用于人体动作识别。2016 年,Ayumi 等^[14]提出利用微正则退火算法优化 CNN 全连接层权重。2017 年,王丽敏等^[15]提出遗传算法(genetic algorithm, GA)优化 CNN 初始权重。

目前 CNN 优化方法多针对于权重的优化,CNN 网络结构的选择对于 CNN 的性能也具有很大的影响,但 CNN 网络结构的选择大多依据经验和大量的实验,具有不确定性,为了解决滚动轴承故障诊断中人工选择 CNN 网络结构具有不确定性从而导致诊断准确率低的问题,本文以 CNN 为基础,提出一种应用 GA 自适应选择 CNN 网络结构的滚动轴承故障诊断新方法 GA-CNN 来提高滚动轴承故障诊断准确率。首先对滚动轴承故障信号进行特征提取,然后将故障特征分别输入经 GA 改进的 CNN 和 3 组人工随机选择网络结构的 CNN 进行特征识别,最后将实验结果进行对比得出结论。本文采用美国凯斯西储大学轴承数据中心网站滚动轴承数据进行实验验证所提出的基于 GA-CNN 的滚动轴承故障诊断方法具有更高的准确率。

1 CNN

CNN 最先应用于图像识别,近些年开始应用于故障诊断。CNN 的核心结构由卷积层和池化层交替连接构成。如图 1 所示,CNN 的基本结构包括输入层、卷积层、池化层(也称降采样层)、全连接层以及输出层。CNN 通过局部连接、权值共享和池化操作 3 个核心思想来减少参数加快学习速率,从而简化后续网络复杂度。

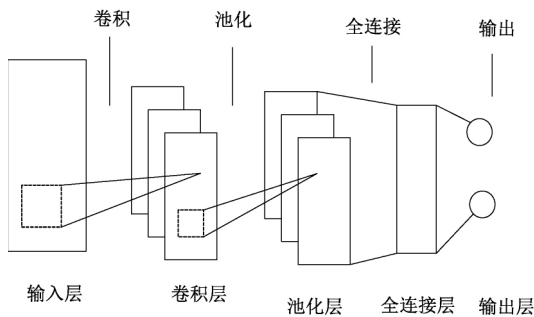


图 1 CNN 基本结构

1.1 卷积层

卷积层是 CNN 中最重要的部分,具有增强原始信号特征,降低噪声的作用。卷积层的输入与上层神经网络的输出通过对应的权值和偏置进行权值共享和局部连接。卷积层通过权值共享和局部连接这两个特点来降低网络复杂度并减少参数数量从而加快了学习速率,局部连接和权值

共享如图 2 所示。卷积层通过卷积操作提取输入信号特征,卷积层其输入输出对应关系为:

$$x_i^{out} = f(\sum_{j=1}^n (x_j^{in} \times \omega_{ij}) + b_j) \quad (1)$$

式中: x_i^{out} 为第 i 个神经元的输出; x_j^{in} 为第 j 个神经元的输入; $f(\cdot)$ 为非线性激励函数; ω_{ij} 为输入信号 x_j^{in} 与神经元 j 连接的权值; b_j 为输出偏置。




图 2 局部连接和权值共享

1.2 池化层

池化层位于卷积层后。最常见的池化操作有最大池化和平均池化。最大池化为对邻域内特征点求取最大值,平均池化为对邻域内特征点求取平均值。最大池化和平均池化如图 3 所示。最大池化和平均池化函数可以表现为:

$$y_i^{out} = f_{sub}(y_q^{in}, y_{q+1}^{in}) \quad (2)$$

式中: y_q^{in} 为输入特征面的第 q 个神经元的输出值; $f_{sub}(\cdot)$ 为求函数的最大或平均值; y_i^{out} 为输出特征面的第 i 个神经元的输出值。

池化层(降采样层)通过最大池化或平均池化对卷积层输出的特征图进行降维操作。池化层通过降低特征面的分辨率来获得具有空间不变性的特征。

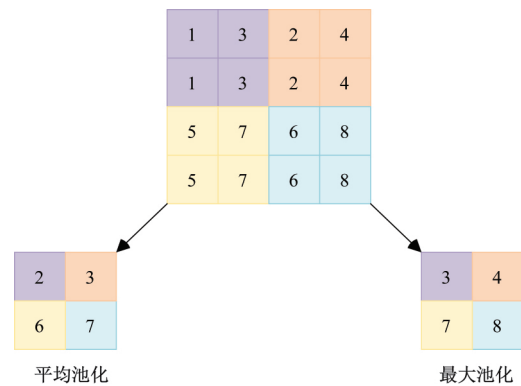


图 3 最大池化和平均池化

1.3 全连接层

全连接层位于交替连接的卷积层和池化层后,全连接层用来把卷积层和池化层提取到的特征综合起来。CNN 结构具有一个或者多个全连接层。全连接层每个神经元都

与前一层所有神经元进行全连接。由于其全连接的特性,一般全连接层的参数也是最多的。最后一层全连接层连接所有的特征后,将输出值发送给 softmax 层进行分类。

2 GA

1969年,John holland 通过模拟达尔文生物进化论和遗传学机理的生物进化过程提出了 GA 计算模型,该模型是一种通过模拟自然进化过程来搜寻最优解的算法。GA 具有对结构对象进行直接操作的特点,因此对函数的连续性没有要求;GA 搜索方法采用概率搜索而非确定规则,能自适应地调整搜索方向。因此 GA 具有更好的全局寻优能力。

GA 的核心操作为编码、种群初始化、适应度函数的设计和遗传操作设计。应用 GA 时首先进行编码操作,编码方法对于后续遗传操作具有很大的影响,因此编码的选择具有重要意义。最常见的编码方式有二进制编码法、格雷码编码法、浮点数(实数)编码法和排列编码法等。

GA 的操作对象是一个群体中的所有个体。GA 的遗传操作是指对染色体的操作,也称遗传算子。GA 具有 3 种遗传操作:选择、交叉和变异。GA 不同的遗传操作对结果有较大的影响,遗传操作中的选择是指利用适应度函数选取优质个体遗传到下一代,常见的选择操作有轮盘赌选择、随机竞争选择、最佳保留选择、无放回随机选择、确定式选择、均匀排序、最佳保留、随机比赛等。遗传操作中的交叉是 GA 产生新个体的主要方法,也与 GA 的全局搜索能力相关。遗传操作中的交叉是指对两个相互配对的染色体按某种方式相互交换部分基因而形成新个体的操作。常见的交叉操作有单点交叉、两点交叉、多点交叉、均匀交叉、算数交叉等。遗传操作中的变异是 GA 产生新个体的辅助方法,也与 GA 的局部搜索能力相关。遗传操作中的变异是指将个体染色体编码串中的某些基因座上的基因值用该基因座的其他等位基因来替换而形成一个新的个体的操作。常见的变异操作有基本位变异、均匀变异、边界变异、非均匀变异等。

GA 算法流程如图 4 所示。GA 主要算法步骤为:

- 1) 随机产生一个种群,并对种群个体进行编码;
- 2) 对每个个体进行适应度评价,适应度低的个体被淘汰;
- 3) 适应度高的个体进行选择、交叉和变异产生新的种群;
- 4) 将后代中表现最好的个体作为遗传算法的执行结果。

3 GA 优化 CNN 网络结构

3.1 基本思想

由于 CNN 强大的特征学习能力和对复杂数据的处理能力而被应用于故障诊断,但在故障诊断领域 CNN 仍存

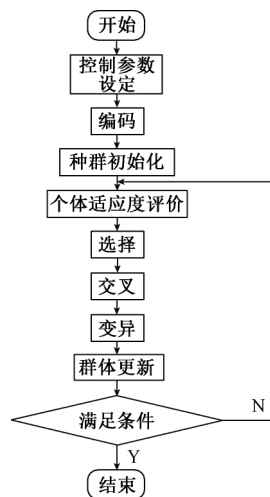


图 4 GA 算法流程

在很大的优化空间。面对不同的实际问题,研究者需要进行大量的实验和拥有丰富的经验才能选择较为合适的 CNN 网络结构。CNN 网络结构的选择影响诊断准确率,结构不合适是造成 CNN 结果准确率低的一个重要因素。在面对具体实际问题选择 CNN 网络结构时,由于 CNN 网络参数选择组合众多,如果仅依据经验和实验,需要耗费大量的时间去调整 CNN 网络结构,且不一定能找到最合适的 CNN 网络结构。而 GA 的可调参数少,全局搜索快,搜索过程中使用的是基于目标函数值的评价信息,搜索过程不要求优化函数必须可导,也不受优化函数连续性约束,思想简单易于实现。因此本文针对滚动轴承故障诊断提出了 GA 优化 CNN 网络结构的 GA-CNN 方法。

GA 编码方式和遗传操作的选取对结果的产生具有较大影响。本文选取精度高且适合大空间搜索的实数编码作为 GA 的编码方式;选取适应度值越好的个体被选择的概率越大的轮盘赌选择法作为 GA 的选择操作;选取最基础的单点交叉作为 GA 的交叉操作;选取对个体编码以变异概率随机指定的某几位基因进行变异的基本位变异作为 GA 的变异操作。

本文提出的 GA 优化 CNN 网络结构算法主要由 CNN 网络的搭建、GA 优化、CNN 网络结构的确定和 CNN 故障诊断 4 部分组成。

3.2 算法流程

算法流程如图 5 所示,具体流程如下:

- 1) 使用实数编码随机产生初始群体(初始种群产生范围如表 1 所示),群体中的每一个个体表示一种 CNN 网络结构参数;
- 2) 设置 GA 染色体数、基因数、进化代数、变异率和交叉率,设置值如表 2 所示;
- 3) 搭建 CNN,以 GA 每个染色体上的基因作为 CNN 结构;
- 4) 将 CNN 测试准确率作为 GA 适应度函数;

- 5) GA 算法对个体进行适应度评价并对群体进行遗传操作;
- 6) GA 算法判断是否满足最大进化代数,若满足,程序结束,若不满足,重复步骤 5),直至满足进化代数;
- 7) 程序输出每一代个体适应度函数值,选择输出最大函数值的个体作为最优个体。

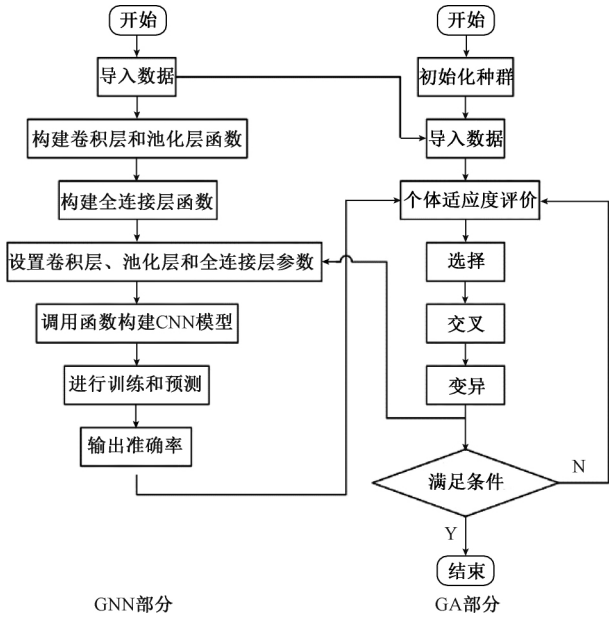


图 5 算法流程

表 1 需要优化参数

优化参数	初始值范围
卷积层数(C)	1~5
每层卷积层卷积核数	5~300
全连接层数	1~5
每层全连接层神经元数	10~300

4 实验与分析

4.1 实验数据介绍

本文采用了美国凯斯西储大学(Case Western Reserve




图 6 原始信号波形图

表 2 GA 参数设置

GA 参数	参数值
染色体数	10
每条染色体基因数	4
进化代数	20
变异率	0.01
交叉率	0.9

University) 轴承数据中心网站的滚动轴承数据^[16]进行实验。被测轴承信息如表 3 所示。本文使用的实验数据共包括 3 组:正常基准数据、滚动体故障数据和外圈居中位置故障数据。

表 3 被测轴承信息

轴承型号	故障直径/in	转速/(r·min ⁻¹)	电机负载	采样频率/kHz
SKF6205-2RS	0.007	1 797	0	12
JEMSKF				

本文对美国凯斯西储大学轴承数据中心网站滚动轴承数据的正常振动信号和两类故障振动信号进行分类,随机选取正常数据 100 000 个、滚动体故障数据 100 000 个、外圈故障数据 100 000 个,3 类滚动轴承震动数据经 CEEMDAN-Hilbert 变换后作为训练集,正常数据 20 000 个、滚动体故障数据 20 000 个、外圈故障数据 20 000 个,3 类滚动轴承震动数据经 CEEMDAN-Hilbert 变换作为测试集。

4.2 实验数据预处理

对滚动轴承故障特征信息进行分类之前需要对滚动轴承故障特征信息进行提取。原始信号波形由图 6 可知难以区分哪个是故障信号,因此对原始信号进行 CEEMDAN 分解。可以得到从高频到低频分布的 IMF 分量。CEEMDAN 分解滚动体故障信号前 5 个 IMF 分量如图 7 所示。将分解过的 IMF 分量进行 Hilbert 变换,即可得到

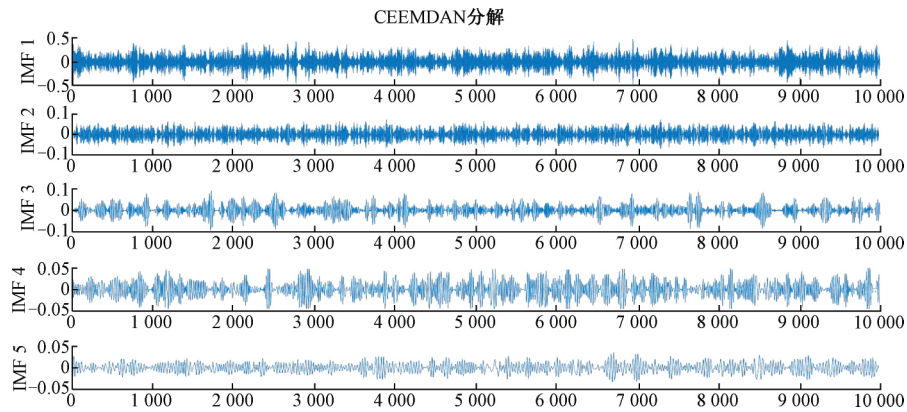


图 7 CEEMDAN:滚动体故障信号前 5 个 IMF 分量

3 种数据矩阵。本文将经过 CEEMDAN-Hilbert 处理过的振动特征信号作为 GA-CNN 的分类数据。GA-CNN 需要优化的参数范围如表 2 所示。

4.3 实验结果与分析

GA-CNN 为本文所提算法选择 CNN 参数, CNN1、CNN2 和 CNN3 为人工随机选择 CNN 参数, 表 4 所示为 3 种方法的实验数据, (C1、C2、C3、C4 为卷积层每层卷积核数量, F1、F2、F3、F4 为全连接层每层神经元) 本文提出的 GA-CNN 特征分类准确率达 98.65%, 人工随机选取 3 组 CNN 网络结构 (CNN1、CNN2、CNN3) 准确率分别 96.35%、95.98%、95.14%。在对美国凯斯西储大学轴承数据中心网站的滚动轴承数据进行故障诊断中, 本文所提方法 GA-CNN 与人工选择 CNN 结构参数相比准确率更高一些, 实验证明本文提出 GA 优化 CNN 网络结构比人工选择 CNN 网络结构在故障诊断中具有更高准确率。

表 4 GA 算法及人工选择的 CNN 结构参数

CNN 层	GA-CNN	CNN1	CNN2	CNN3
C1	268	120	100	200
C2	248	126	60	50
C3	85	35	40	130
C4	195	76	20	5
F1	244	54	60	199
F2	25	8	40	45
F3	35	3	20	11
F4	12	0	3	9
准确率/%	98.65	96.35	95.98	95.14

5 结 论

针对滚动轴承故障诊断本文提出了 GA-CNN 特征分类方法, 利用 GA 算法适合全局寻优的特性来选择 CNN 最佳结构。与人工依据大量经验和实验来选择 CNN 参数相比, 该算法能够自动选择 CNN 最佳结构。经实验验证

针对滚动轴承故障诊断, 本文方法是合理有效的。但是 GA 的实现也需要进行参数的选择, 这些参数的选择严重影响解的质量, 而目前这些参数的选择大部分是依靠经验来实现, 自适应的选取 GA 参数是进一步需要解决的问题。

参考文献

- [1] 陈夔蛟. 基于振动信号的滚动轴承故障诊断研究[D]. 西安: 西安电子科技大学, 2011.
- [2] 梅检民, 肖云魁, 贾继德, 等. 基于改进阶比的变速器微弱故障特征提取[J]. 振动工程学报, 2012, 25(3): 317-322.
- [3] 冯辅周, 司爱威, 饶国强, 等. 基于小波相关排列熵的轴承早期故障诊断技术[J]. 机械工程学报, 2012, 48(13): 73-29.
- [4] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks [J]. Pattern Recognition, 2018, 77: 354-377.
- [5] GUO X, CHEN L, SHEN C. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis[J]. Measurement, 2016, 93: 490-502.
- [6] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
- [7] LI X, ZHANG W, DING Q. Understanding and improving deep learning-based rolling bearing fault diagnosis with attention mechanism [J]. Signal Processing, 2019, 161: 136-154.
- [8] ZHANG J, SUN Y, GUO L, et al. A new bearing fault diagnosis method based on modified convolutional neural networks[J]. Chinese Journal of Aeronautics, 2019, 33(2): 1-9.
- [9] 唐波, 陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.

- [10] 丁承君,冯玉伯,王曼娜. 基于变分模态分解与深度卷积神经网络的滚动轴承故障诊断[J]. 振动与冲击, 2021, 40(2): 287-296.
- [11] 白燕燕,曹军,张福元,等. 基于粒子群算法优化卷积神经网络结构[J]. 内蒙古大学学报, 2019, 50(1): 85-88.
- [12] RERE L M R, FANANY M I, ARYMURTHY A M. Simulated annealing algorithm for deep learning[J]. Procedia Computer Science, 2015, 72:137-144.
- [13] IJJINA E P, CHALAVADI K M. Human action recognition using genetical algorithms and convolutional neural networks[J]. Pattern Recognition, 2016, 59(11): 199-212.
- [14] AYUMI V, RERE L M R, FANANY M I, et al. Optimization of convolutional neural network using microcanonical annealing algorithm[C]. International Conference on Advanced Computer Science and Information Systems(ICACSIS), 2016: 506-511.
- [15] 王丽敏,乔玲玲,魏霖静. 结合遗传算法的优化卷积神经网络学习方法[J]. 计算机工程与设计, 2017, 38(7): 1945-1950.
- [16] Case Western Reserve University Bearing data[EB/OL]. (2013-09-04)[2013-09-04]. <https://csegroups.case.edu/bearingdatacenter/pages/download-data-file>.

作者简介

李雪颖,工学硕士,主要研究方向为模式识别、故障诊断等。

E-mail: 1203949199@qq.com

刘慧明,工学博士,硕士研究生导师,教授,主要研究方向为模式识别与机器视觉,故障诊断、系统的分析、建模、优化与控制,自适应控制技术等。

E-mail: 176698787@qq.com