

文章编号: 2095-2163(2023)05-0122-04

中图分类号: TP277

文献标志码: A

基于小波变换 CNN 的电机运行状态识别研究

龙 慧, 马家庆, 吴钦木, 何志琴, 陈昌盛, 覃 涛

(贵州大学 电气工程学院, 贵阳 550025)

摘要: 针对电机运行状态的特征提取与有效识别问题, 本文结合小波变换和卷积神经网络改进了电机的运行状态识别方法。首先, 将热像仪采集的电机数据图像经过小波变换转换, 得到系数矩阵; 其次, 将处理后的小波系数矩阵输入到改进的卷积神经网络模型进行特征提取; 最后, 利用反向传播不断调整结构的网络参数, 建立最合适的网络模型, 从而实现了对电机的运行状态进行识别。实验结果表明, 本文所提出的方法对电机运行状态识别的准确率达到 98%, 证明了该方法的可行性与有效性, 并应用于工程中。

关键词: 小波变换; 卷积神经网络; 电机运行状态; 特征提取

Research on recognition of motor running state based on ICNN of wavelet transform

LONG Hui, MA Jiaqing, WU Qinmu, HE Zhiqin, CHEN Changsheng, QIN Tao

(School of electrical engineering, Guizhou University, Guiyang 550025, China)

[Abstract] To the problems of feature extraction and effective recognition of motor running state. This paper combines discrete wavelet transform and convolution neural network to improve the recognition method of motor running state. Firstly, the motor data images collected by the thermal imager are transformed by wavelet transform to obtain the coefficient matrix. Then the preprocessed wavelet coefficient images are inputted to the improved convolutional neural network model for feature extraction. Finally, the network parameters of the structure are adjusted by using the back propagation to establish the most appropriate network model method, so as to realize the recognition of the running state of the motor. The experimental results show that the accuracy of the proposed method for identifying motor running state reaches 98%, which proves the feasibility and effectiveness of the method. And the method is applied in engineering.

[Key words] discrete wavelet transform; CNN; motor running state; feature extraction

0 引言

电机作为重要的机械设备, 在生产和生活中被广泛应用, 电机在运行过程中一般会伴随着温升的产生, 发生故障, 从而影响到设备的正常运行。为了保障设备的安全运行, 及时对电机进行故障识别是一项很重要的技术^[1]。随着计算机技术的快速发展, 卷积神经网络 (Convolution Neural Network, CNN) 被广泛应用于电机的故障识别。

CNN 在数据图像特征提取方面有着显著的优势, 目前已经被广泛应用于图像识别、人脸识别、特

征分类等方面。特征提取是 CNN 模型对电机运行状态识别的关键部分, 已经被广泛研究。小波变换 (Discrete Wavelet Transform, DWT) 有非冗余性, 能很好的对数据进行分解与去噪, 并能将信号中的时频特征表现出来^[2]。DWT 在图像降噪处理领域被广泛应用, 文献[3]先利用离散傅里叶变换, 将时域信息特征映射到频域, 再使用 CNN 学习数据特征, 从而实现故障诊断; 文献[4]提出一种基于 CNN 和离散小波变换的滚动轴承故障诊断方法, 对不同情况下的滚动轴承进行故障诊断; 文献[5]结合 DWT、Lorenz 混沌系统和 CNN 对电力电缆的绝缘故障进

基金项目: 国家自然科学基金(51867006, 61861007); 贵州省科技厅-贵大联合基金(黔科合 LH 字[2017]7229); 黔科合平台人才([2017]5788); 贵州省科技厅项目(黔科合支撑[2021]-般 442)。

作者简介: 龙 慧(1997-), 女, 硕士研究生, 主要研究方向: 图像处理; 马家庆(1981-), 男, 博士, 副教授, 主要研究方向: 交流电机非线性控制及传感器非线性特性、新能源发电等。

通讯作者: 马家庆 Email: 357287962@qq.com

收稿日期: 2022-05-13

行识别;文献[6]提出了一种基于小波时频图和卷积神经网络的断路器故障诊断方法,实现对操动机构故障状态的辨识诊断;文献[7]利用 DWT 从原始信号中提取高维器具特征,提出了主动深度学习对负载进行识别的方法;文献[8]提出了一种 CNN 的状态监测特征学习模型,对图像数据进行分类。

本文基于小波变换(Discrete Wavelet Transform, DWT)的改进卷积神经网络(Improved Convolutional Neural Network, ICNN)电机运行状态识别方法,将小波变换和卷积神经网络相结合,解决电机故障识别的问题。该方法先构建电机运行状态的数据集,小波变换将采集的数据图像转换为小波系数矩阵并进行系数增强,将处理后的图像输入到网络模型中,对变换后的图像进行特征提取,来提高电机运行状态识别的准确率。

1 理论基础

1.1 小波变换

小波变换是由傅里叶变换发展而来的,小波变换对于复杂信号有着较好的时频分辨率,被广泛应用于复杂单尺度信号的时频分析,通过不同的变换方法从不同的角度获得信号的特征,从而来实现信号的分析 and 处理。小波变换是一种以时频为特征的时频分析技术,是对不同分辨率信号进行分析的方法。

小波变换分为连续小波变换和离散小波变换。小波变换常用来抑制信号的噪声,本文采用离散小波变换来对数据图像信号进行小波系数变换。

离散小波函数 $\psi_{m,k}(t)$ 可以表示为式(1):

$$\psi_{m,k}(t) = \frac{1}{\sqrt{2^m}} \psi\left(\frac{t-k}{2^m}\right) \quad (1)$$

其中, m 和 k 分别为伸缩和平移参数; t 是时间; $\psi(t)$ 是小波基。

输入信号由低频(LF)和低频(HF)组成,通过 DWT 将其分解成频带,通过下采样得到第一级小波变换。

根据离散小波的特点,低频系数 cA_i 和高频系数 cD_i 的频带分别表示为式(2)和式(3):

$$cA_i = \left[0, \frac{f_s}{2^{i+1}}\right] \quad (2)$$

$$cD_i = \left[\frac{f_s}{2^{i+1}}, \frac{f_s}{2^i}\right] \quad (3)$$

其中, i 为分解层数, f_s 为信号的采样频率。

由于信号已被下采样,因此在重新配置时需要

对其进行上采样。小波变换是一种有效的定时信号压缩降噪方法,具有多分辨率和时频局部化等特点。

1.2 卷积神经网络

本文的网络模型由输入层、卷积层、池化层、全连接层和输出层所组成。卷积层是将输入层接收到经过 DWT 预处理的特征利用卷积核对数据特征进行提取,增强原始图像的特征信息。卷积操作的一般形式为式(4):

$$x = f\left(\sum x * \omega_{ij} + b\right) \quad (4)$$

其中, $*$ 为卷积运算符; b 为偏差; ω_{ij} 为卷积核; x 为输入特征图; $f(\cdot)$ 为激活函数。

池化层采用平均池化操作将卷积层提取的特征再次提取,使得其有更低的维度,减少计算量和过拟合的产生。池化层的一般形式为式(5):

$$x = f(\beta \text{down}(x) + b) \quad (5)$$

其中, β 为偏置系数, $\text{down}(\cdot)$ 为下采样函数。

选用 Tanh 激活函数,其取值范围为 $-1 \sim 1$, 输出均值是 0, Tanh 函数表示为式(6):

$$\text{Tanh}(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (6)$$

全连接层的特征是每一个神经元都与上一层的所有神经元相连。全连接层的输出为式(7):

$$F(x) = f(\omega x + b) \quad (7)$$

其中, x 为全连接层的输入, ω 为权值系数。

输出层一般是分类器层(Softmax 层),对识别目标进行分类。Softmax 层的输入是上一层全连接层的数据,输出的数据的每个值范围为 $0 \sim 1$, 输出值表示的是样本属于这一类别的概率。

2 基于 DWT 的 CNN 的电机运行状态识别方法

对于本文基于 DWT 的 ICNN 电机运行状态识别方法,将电机原始数据通过小波变换转化为小波系数矩阵,再通过 ICNN 进行无监督的学习时频图的图像特征,识别出电机故障的特征信息,最后由 Softmax 分类层将识别出的特征信息与相应故障类型做出对比,实现了电机的运行状态识别诊断。

基于 DWT 的 CNN 的电机运行状态识别的具体步骤:

(1)通过热像仪采集电机图像数据集,将数据集预处理后划分为训练集和测试集;

(2)将数据集通过 DWT 处理数据图像,对数据图像进行小波系数矩阵的转换;

(3)将处理后的数据图像输入到 CNN 模型中,初始化网络模型,根据实验需求,确定适合本实验模

型的学习率和迭代次数等网络参数;

(4)通过网络模型运行得到输出误差,判断输出是否收敛;若不收敛执行步骤(5),若收敛直接进行识别;

(5)通过模型输出的误差进行反向传播,进行权值的修改;

(6)重复执行步骤(4)、步骤(5),直到模型的精度和损失函数等满足实验要求,输出网络模型,识别电机的运行状态。

3 实验结果分析

3.1 数据集

实验平台主要由电力电子技术及电机控制实验装置、电机、热像仪和计算机组成。通过热像仪采集电机运行状态的图像,将采集到的电机数据分为正常运行、停止和故障 3 种状态,每种状态采集 200 个样本,从总样本中随机选取 20% 构成测试样本,剩余的数据作为训练样本。对这 3 种状态的图像预处理,然后进行离散小波变换得系数矩阵,再输入到 CNN 网络模型。

3.2 评价指标

3.2.1 损失函数 (Loss)

用损失函数评估模型的预测值与真实值之间的不一致程度,式(8):

$$Loss = - \sum_x p(x) \log(q(x)) \quad (8)$$

其中, $p(x)$ 为真实的概率, $q(x)$ 为模型通过计算之后的概率估计。

3.2.2 结构相似函数 (SSIM)

结构相似函数用于评估模型运算后电机识别图片的失真程度,识别前后两张图像的结构相似函数 $SSIM$,如式(9):

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (9)$$

其中, μ 为平均像素值; σ 为标准差; C 为常数。

3.3 实验分析

迭代 50 次、权值调整步进值为 0.03 时所得到的实验结果见表 1。通过对不同小波变换 (Haar 小波、Daubechies (db) 小波、ReverseBior (rbio) 小波、Coiflet (Coif) 小波和 Fejer-Korovkin (fk) 小波) 的故障识别的性能比较,可以看出本文使用的小波变换表现出最好的性能。


权值调整为 0.03 时数据图像在不同迭代次数

下的结果如图 1 所示,可以看出随着迭代次数的增加,准确率逐渐升高、损失值逐渐减小;当迭代次数大于 40 时,迭代次数的增加,准确率和损失函数几乎都趋于稳定,准确率在 97% 及以上,损失函数的值在 0.2 附近波动。但随着迭代次数的增加,模型运行所需要的时间也在不断增加,为了节省时间且保证有好的准确率和损失值,本文所选择的迭代次数为 50,模型不仅能达到实验所需的实验精度,而且收敛速度比较快,稳定性较好。


表 1 不同小波变换在迭代 50 次下运行状态识别的性能比较

Tab. 1 Performance comparison of different wavelet transforms in running state recognition under 50 iterations

| 小波函数 | 测试集损失值 | 训练集损失值 | SSIM | 准确率/% |
|----------|---------|---------|---------|-------|
| Haar | 0.088 6 | 0.223 1 | 0.583 6 | 96.89 |
| 本文 | 0.086 3 | 0.089 2 | 0.585 2 | 98.47 |
| Rbio 3.1 | 0.118 8 | 0.103 5 | 0.585 6 | 97.01 |
| Coif1 | 0.167 4 | 0.147 7 | 0.583 6 | 95.46 |
| Fk4 | 0.118 1 | 0.085 3 | 0.583 9 | 97.68 |



(a) 准确率的比较




(b) 损失值的比较


图 1 数据图像在不同迭代次数下的比较

Fig. 1 Comparison of data images under different iterations

为了进一步验证本文所提方法的稳定性和可行性,在不同权值调整下对电机进行故障识别,结果如图2所示。可以看出,权值过大或过小都会使准确率相对过低、损失函数值过大;当权值调整为0.05时,本文所提出的方法的损失值和准确率都达到很好的效果,达到98%。



(a) 损失值的比较



(b) 准确率的比较

图2 数据图像在不同权值下的比较

Fig. 2 Comparison of data images under different weight adjustment

4 结束语

本文基于DWT的CNN实现了电机运行状态识别。该方法将小波变换和卷积神经网络结合在一起,很好的避免了传统方法对于经验的依赖,利用DWT小波系数的特点,对数据图像进行转换,提取数据的重要特征,提高了电机运行状态识别的准确率。实验结果表明,迭代次数不断增加,准确率不断增大,最后趋于一个稳定状态,准确率达到最高的时候,损失函数值也达到最低,说明该方法有效。

参考文献

- [1] 王威. 基于多尺度卷积神经网络的电机故障诊断方法研究[D]. 徐州: 中国矿业大学, 2020.
- [2] 袁建虎, 韩涛, 唐建, 等. 基于小波时频图和CNN的滚动轴承智能故障诊断方法[J]. 机械设计与研究, 2017, 33(2): 93-97.
- [3] Cao X, Yao J, Fu X, et al. An enhanced 3-D discrete wavelet transform for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 18(6): 1104-1108.
- [4] 陈仁祥, 黄鑫, 杨黎霞, 等. 基于卷积神经网络和离散小波变换的滚动轴承故障诊断[J]. 振动工程学报, 2018, 31(5): 883-891.
- [5] Wang M H, Lu S D, Liao R M. Fault diagnosis for power cables based on convolutional neural network with chaotic system and discrete wavelet transform [J]. IEEE Transactions on Power Delivery, 2021, 37(1): 582-590.
- [6] 鄢仁武, 林穿, 高硕勋, 等. 基于小波时频图和卷积神经网络的断路器故障诊断分析[J]. 振动与冲击, 2020, 39(10): 198-205.
- [7] GUO L, WANG S, CHEN H, et al. A load identification method based on active deep learning and discrete wavelet transform [J]. IEEE Access, 2020, 8: 113932-113942.
- [8] JANSSENS O, SLAVKOVIKJ V, VERVISCH B. Convolutional neural network based fault detection for rotating machinery [J]. Journal of Sound and Vibration, 2016, 377: 331-345.

(上接第121页)

- [4] 姚宗伟, 杨宏飞, 胡际勇, 等. 基于机器视觉和卷积神经网络的轨道表面缺陷检测方法[J]. 铁道学报, 2021, 43(4): 101-107.
- [5] 陈宗仁, 谢文达, 余君, 等. 基于深度学习的金属机械零件表面缺陷检测方法[J]. 制造业自动化, 2021, 43(12): 170-173.
- [6] 谢跃雷, 邓涵方. 基于改进 ResNet 的射频指纹识别方法[J]. 电讯技术, 2022, 62(4): 416-423.
- [7] 刘晨, 赵晓晖, 梁乃川, 等. 基于 ResNet50 和迁移学习的岩性识别与分类研究[J]. 计算机与数字工程, 2021, 49(12): 2526-2530, 2578.
- [8] 仲点点, 吴杰, 余腾, 等. 改进小波阈值图像去噪方法[J]. 科学技术创新, 2022(26): 84-87.

- [9] 张楠妮. 基于深度学习的方钢缺陷识别算法研究[D]. 西安: 西安理工大学, 2021.
- [10] 罗婷瑞. 基于可调 Q 因子小波变换和迁移学习的脑电数据分析方法研究[D]. 西安: 西北大学, 2021.
- [11] THANARAJ K P, PARVATHAVARTHINI B, TANIK U J, et al. Implementation of deep neural networks to classify EEG signals using gramian angular summation field for epilepsy diagnosis [J]. arXiv preprint arXiv:2003.04534, 2020.
- [12] CZIMMERMANN T, CIUTI G, MILAZZO M, et al. Visual-based defect detection and classification approaches for industrial applications—a survey [J]. Sensors, 2020, 20(5): 1459.