

基于一维卷积神经网络和 Soft-Max 分类器的 风电机组行星齿轮箱故障检测^{*}

李东东^{1,2}, 王 浩¹, 杨 帆^{1,2}, 郑小霞³, 周文磊⁴, 邹胜华⁵

- (1. 上海电力学院 电气工程学院, 上海 200090;
2. 上海高校高效电能应用工程研究中心, 上海 200090;
3. 上海电力学院 自动化工程学院, 上海 200090;
4. 国网吉林省吉林市供电公司, 吉林 吉林 132000;
5. 国网江西省赣东北供电分公司, 江西 乐平 333300)

摘 要: 将卷积神经网络引入风机故障检测领域, 设计了一种一维卷积神经网络的结构, 并和 Soft-Max 分类器相结合构造了一种双层智能诊断架构。一维卷积神经网络用于行星齿轮箱数据的特征提取, Soft-Max 分类器对提取的特征进行分类。与传统智能算法相比, 该方法具有训练样本少, 可直接使用原始数据训练网络; 计算效率高, 可以适应实时诊断的需要。试验结果证明, 该方法可以有效地诊断出不同工况下的行星齿轮箱中的齿轮故障。

关键词: 风力发电机; 行星齿轮箱; 卷积神经网络; 故障诊断; Soft-Max 分类器

中图分类号: TM 315 **文献标志码:** A **文章编号:** 1673-6540(2018)06-0080-08

Fault Detection of Wind Turbine Planetary Gear Box Using 1D Convolution Neural Networks and Soft-Max Classifier^{*}

LI Dongdong^{1,2}, WANG Hao¹, YANG Fan^{1,2}, ZHENG Xiaoxia³, ZHOU Wenlei⁴, ZOU Shenghua⁵

- (1. School of Electrical Engineering, Shanghai University of Electric of Power, Shanghai 200090, China;
2. Shanghai Higher Institution Engineering Research Center of High Efficiency Electricity Application, Shanghai 200090, China;
3. School of Atomation Engineering, Shanghai University of Electric of Power, Shanghai 200090, China;
4. Jilin Power Supply Company, State Grid, Jilin 132000, China;
5. Northeast of Jiangxi Power Supply Branch, State Grid, Leping 333300, China)

Abstract: The convolutional neural network was introduced into the field of fan fault detection for the first time, a new method based on one dimensional convolution neural network (CNNs) and Soft-Max classifier was proposed, which was applied to the fault diagnosis of gearbox planetary gear under different operating conditions. The structure of the network was a double layer structure, the improved convolutional neural network was used for feature extraction, and the Soft-Max classifier was used to classify the health status of the signal. Compared with the traditional intelligent algorithm, this method had the advantages of fewer training samples, direct training of network with raw data, high computational efficiency, and it can meet the needs of real-time diagnosis. The data of multi operating conditions are fused and verified by experiments. The experimental results showed that the method can effectively diagnose the gear

^{*} 基金项目: 国家自然科学基金项目(51407114, 51507098); 上海市科学技术委员会资助项目(13DZ2251900, 10DZ2273400); 上海市“曙光计划”资助项目(15SG50)

作者简介: 李东东(1976—), 男, 博士, 教授, 研究方向为电力系统分析、新能源技术和智能用电。

王 浩(1991—), 男, 硕士研究生, 研究方向为风力发电机故障检测。

faults in planetary gear box under different working conditions.

Key words: wind turbine; planetary gearbox; convolutional neural network; fault diagnosis; Soft-Max classifier

0 引言

风能是当前最有发展前景的新能源之一,行星齿轮箱作为风力发电机重要的传动装置,由行星轮、太阳轮、齿圈和行星架组成,可以在紧凑的空间中获得高的扭矩比。由于其振动传输路径复杂、多齿的啮合效应、信号的非平稳性以及工作背景噪声大等原因,导致其故障诊断具有自身的特点和难点,而传统方法对其进行时域或频域分析很难提取有效故障信息。随着 Internet 技术、物联网技术的发展,数据的获取和存储更为方便,基于数据驱动的故障诊断成为一个新的发展方向^[1-3]。与传统方法不同,数据驱动方法无需进行物理建模,直接对获取的数据进行适当的处理和分析来提取信息特征,从而发现故障规律。

基于数据驱动的故障诊断步骤通常包括:信号采集、特征提取和选择、故障分类 3 部分^[4-5]。对采集的振动数据、电流电压数据或者声音数据进行特征提取^[6-9]是其中最关键的步骤。由于原始数据包含很多无用的或不敏感的信息,这些信息会降低计算效率并且影响诊断的精度,所以在特征提取步骤需要对数据进行预处理操作,一般利用降维策略来去除无用信息,如滤波、主成分分析(Principal Component Analysis, PCA)和压缩感知等。故障分类是利用人工智能技术,如 K-近邻(KNN)、支持向量机(Support Vector Machine, SVM)和人工神经网络等,来对提取的特征进行分类的过程。在风机的健康监测和故障诊断领域,学者们已经做了大量研究。文献[10]提出了一种轴承故障的分类方法,首先利用局部和非局部投影技术提取故障特征,然后使用 KNN 分类对轴承的故障进行分类。杜朝辉等^[11]利用压缩传感技术对数据进行去噪降维处理,从而获得了鲁棒性更高的振动图像特征。Pramod 等^[12]提出了一种基于神经网络的风力发电机组状态监测方法,并用于轴承的早期故障检测。文献[13]利用蚁群算法优化神经网络,并将其用于齿轮箱的故障诊断,成功地诊断除了轴承的 4 种健康状态。智能算法已经在风力发电机的健康监测和故障诊断

领域取得了初步的效果。

在故障诊断技术中,如何有效地提取数据的代表性特征,对诊断的精度起到至关重要的作用。传统神经网络作为特征提取的重要算法,已经在故障诊断领域和电力系统检测领域得到广泛的研究和应用^[14-17]。但是传统的神经网络算法具有难以克服的缺点,如算法本身计算效率低、诊断精度难以达到要求、需要对原始数据进行预处理等。早期由于缺乏训练数据和计算能力,要在不产生过拟合的情况下训练高性能神经网络是很困难的,近来 GPU 的发展,使得卷积神经网络研究涌现。

卷积神经网络(Convolutional Neural Networks, CNNs)是近年发展起来的一种高效识别方法,已经在模式识别、医学等领域取得了广泛的应用^[18-21]。在模式识别领域, CNNs 主要用来识别位移、缩放及其他形式扭曲不变性的二维图形。由于该方法避免了对图像的复杂前期预处理,可以直接输入原始图像,因而得到了更为广泛的应用。

近年来,学者们开始研究将传统的卷积神经网络一维化,并运用于心电图波动识别和数据分类中。本文设计了一种一维卷积神经网络结构,首次将其引入风力发电机齿轮箱故障检测中。一维卷积神经网络用来提取行星齿轮箱振动信号的特征,利用 Soft-Max 分类器对特征进行分类,最终达到故障诊断的目的。在信号的特征提取过程中,直接将原始振动信号作为网络的输入来提取数据特征,无需进行任何预处理。试验中,考虑到风机不可能保持恒速运转,将不同转速的数据融合,来验证算法更具有实际意义。试验结果表明,该网络模型可以有效地诊断行星齿轮箱故障。

1 一维卷积神经网络

1.1 基本原理

卷积神经网络只对局部进行感知,然后在更高层将局部的信息综合起来以获得全局的信息。卷积神经网络的基本结构包括两层:(1)特征提取层,每个神经元的输入与前一层的局部接受域相连,并提取该局部的特征。卷积神经网络的这

种局部感知操作可以降低参数数目,从而提高计算效率。(2)特征映射层,网络的每个计算层由多个特征映射组成,每个特征映射看成是一个平面,平面上所有神经元的权值相等。因为一个映射面上的神经元共享权值,所以减少了网络自由参数的个数,达到提高计算效率的目的。

1.2 基本结构

卷积神经网络中,卷积层和池化层交替出现。将最后池化层的特征映射图首尾连接形成特征向量,特征向量通过全连接得到分类向量。一维卷积神经网络原理如图1所示。




图1 一维卷积神经网络原理图

假设第 \$l\$ 层是卷积层,则一维卷积层的计算式如下:

$$x_j^l = f\left(\sum_{i=1}^M x_i^{l-1} * k_{ij}^l + b_j^l\right) \quad (1)$$

式中: \$x_j^l\$——\$l\$ 层的第 \$j\$ 个特征映射;

\$f(\cdot)\$——激活函数;

\$M\$——输入特征映射的个数;

\$x_i^{l-1}\$——\$l-1\$ 层的第 \$i\$ 个特征映射;

\$*\$——卷积操作;

\$k_{ij}^l\$——可训练的卷积核;

\$b_j^l\$——偏置。

考虑到收敛速度和过拟合问题,本文采用线性整流函数(Rectified Linear Unit, ReLU)激活函数,其在梯度下降上比 Sigmoid 有更快的收敛速度,并且可以有效防止过拟合问题。ReLU 激活函数如下:

$$f(x) = \max(0, x) \quad (2)$$

第 \$l+1\$ 层是池化层,则第 \$l+1\$ 层计算公式如下:

$$x_j^{l+1} = f[\text{down}(x_j^l) + b_j^{l+1}] \quad (3)$$

其中, \$\text{down}(\cdot)\$ 为下采样函数,把 \$n \times 1\$ 向量的所有元素相加。由于下采样作用于不重合区域,因此所得的特征映射大小为原来的 \$1/n\$。本文中下采样函数没有偏置 \$b_j^l\$ 和激励函数 \$f(\cdot)\$。

假设最后的池化层为 \$l+1\$ 层,将其首尾连接后形成特征向量层,此层为 \$x^{l+1}\$,和输出全连接形成尾部单层感知机,则输出可表示为

$$y^{l+1} = f(u^{l+1}) = f(W^{l+1}x^{l+1} + b^{l+1}) \quad (4)$$

式中: \$W^{l+1}\$——权重;

\$b^{l+1}\$——偏置。

若输入层的尺寸为 \$N \times 1\$,卷积核尺寸为 \$k \times 1\$,每次卷积核的移动步数取 1,则输入通过卷积后得到的卷积层特征映射图的尺寸为 \$(N-k+1) \times 1\$。卷积层后面是池化层,用来求局部平均值或局部最大值。池化具有平移不变性的特性,同时可以减少特征映射图的分辨率。本文中选取平均池化。如果得到卷积层的尺寸为 \$(N-k+1) \times 1\$,池化因子为 \$s\$,则池化后的特征映射图尺寸为 \$(N-k+1)/s \times 1\$。

卷积操作和平均池化操作分别如图2、图3所示。取卷积核尺寸为 \$3 \times 1\$,池化因子为 \$s\$,取 \$s=2\$ 来说明平均池化操作。



图2 卷积操作示例图




图3 平均池化操作示例图

1.3 反向传播原理

1.3.1 全连接的残差传播

卷积神经网络的训练是基于反向传播原理,利用 BP 算法和最小化均方误差来训练卷积核和

偏置。令 $l=1$ 为输入层, $l=L$ 为输出层, NL 为分类个数。对于一个输入向量 p , 对应的理想输出(标签)和输出向量分别为 t_i^l 和 y_i^l , 其中 $i=1, 2, \dots, NL$, 则输出层对应的均方误差函数 E^p 表示为

$$E_p = \frac{1}{2} \times \frac{1}{NL} \sum_{i=1}^{NL} (y_i^L - t_i^L)^2 \quad (5)$$

定义残差为 δ , 输出层 L 残差:

$$\delta^L = (y^L - t^p) \cdot f'(u^L) \quad (6)$$

则第 l 层残差传播公式如下:

$$\delta^l = W^{l+1} \delta^{l+1} \cdot f'(u^l) \quad (7)$$

式中: “ $\cdot$ ”——每个元素相乘。

最后, 运用 δ 规则进行权值更新:

$$\frac{\partial E}{\partial W^l} = \delta^l x^{l-1} \quad (8)$$

$$\frac{\partial E}{\partial b^l} = \delta^l \quad (9)$$

1.3.2 卷积层的残差传播

每个卷积层都会跟着一个池化层。由于池化层存在下采样操作, 需要进行上采样得到卷积层的残差。假定 l 层为卷积层, $l+1$ 层为池化层, 则有:

$$\delta_j^l = \beta_j^{l+1} [f'(u_j^l) \cdot up(\delta_j^{l+1})] \quad (10)$$

其中, $up(\cdot)$ 表示一个上采样操作。如果下采样的采样因子是 n , 则简单的将每个像素在水平和垂直方向上分别拷贝 n 次, 即可恢复原来的大小。

计算偏置的梯度:

$$\frac{\partial E}{\partial b_j^l} = \sum_{u,v} (\delta_j^l)_{uv} \quad (11)$$

卷积核的权值的梯度:

$$\frac{\partial E}{\partial k_{ij}^l} = \text{rot180}[\text{conv}(x_i^{l-1}, \text{rot180}(\delta_j^l), \text{'valid'})] \quad (12)$$

式中: rot180 ——旋转 180° ;

conv ——卷积;

valid ——不考虑边界补零的卷积操作。

1.3.3 池化层的残差传播

当 l 层为池化层, $l+1$ 层为卷积层, 则有:

$$\delta_j^l = f'(u_j^l) \cdot \text{conv}[\delta_j^{l+1}, \text{rot180}(k_j^{l+1}), \text{'full'}] \quad (13)$$

式中: full ——考虑边界补零的卷积操作。

$$\frac{\partial E}{\partial b_j} = \sum_{u,v} (\delta_j^l)_{uv} \quad (14)$$

1.3.4 权重的更新

因为池化层不含权重和偏置, 只对上一层卷积进行采样操作, 故权重的更新只在卷积层和单层感知机中完成。

单层感知机的权重更新:

$$W^l(t+1) = W^l(t) - \eta \frac{\partial E}{\partial W^l} \quad (15)$$

$$b^l(t+1) = b^l(t) - \eta \frac{\partial E}{\partial b^l} \quad (16)$$

卷积层的权重更新:

$$k_{ij}^l(t+1) = k_{ij}^l(t) - \eta \frac{\partial E}{\partial k_{ij}^l} \quad (17)$$

$$b_j^l(t+1) = b_j^l(t) - \eta \frac{\partial E}{\partial b_j^l} \quad (18)$$

式中: t ——第 t 次迭代;

η ——学习速率, 一般取小于 1 的数。

2 Soft-Max 分类器

齿轮箱的故障诊断属于多分类问题。其齿轮健康状况包括正常、磨损、点蚀和断齿等。为了解决这种多分类问题, 本文使用了 Soft-Max 回归模型。Soft-Max 回归模型是 Logistic 回归模型的一个扩展, 主要用于解决多分类问题。

假设训练样本为 $\{x^i\}_{i=1}^A$, 对应的标签集为 $\{l^i\}_{i=1}^A$ 。其中 $x^i \in R^{N \times 1}$, $l^i \in \{1, 2, \dots, K\}$ 。则 $p(y=k|x^i)$ 表示估算样本 x^i 属于类别 k 的概率, 当一个标签对应的概率值最大时, 则可以判定 x^i 属于该类别。定义假设函数如下:

$$h_\theta(x^i) = \begin{bmatrix} p(y^i=1|x^i;\theta) \\ p(y^i=2|x^i;\theta) \\ \vdots \\ p(y^i=K|x^i;\theta) \end{bmatrix} = \frac{1}{\sum_{k=1}^K e^{\theta_k^T x^i}} \begin{bmatrix} e^{\theta_1^T x^i} \\ e^{\theta_2^T x^i} \\ \vdots \\ e^{\theta_K^T x^i} \end{bmatrix} \quad (19)$$

其中, $\theta = [\theta_1, \theta_2, \dots, \theta_K]^T$ 表示 Soft-Max 回归模型中的训练参数, $\sum_{k=1}^K e^{\theta_k^T x^i}$ 是归一化函数。可以看出, 假设函数的所有元素之和为 1, 代表所有类别的概率和为 1。Soft-Max 回归模型的代价函数如下:

$$J(\theta) = -\frac{1}{M} \left[\sum_{i=1}^M \sum_{k=1}^K 1\{y^i = k\} \log \frac{e^{\theta_k^T x^i}}{\sum_{i=1}^K e^{\theta_k^T x^i}} \right] + \frac{\lambda}{2} \sum_{k=1}^K \sum_{l=1}^N \theta_{kl}^2 \quad (20)$$

式中: $1\{\cdot\}$ ——指标函数,当 $\{\cdot\}$ 值为真时,指标函数值为1,否则指标函数值为0;

λ ——权重衰减系数。

利用 L-BFGS 算法求解该模型的最优解。

3 基于一维卷积神经网络和 Soft-Max 分类器的行星轮故障检测

一般认为人对外界的认知过程是从局部到全局的。振动信号的空间联系也是局部的样本联系较为紧密,而距离较远的样本相关性则较弱。基于这种局部关系紧密特性,卷积神经网络可以方便快捷地提取和学习原始振动信号的故障特征。

本文构建了一种一维卷积神经网络和 Soft-Max 回归模型的双层网络结构。首先利用样本数据和对应的标签数据训练一维卷积神经网络,再将得到的分类向量来训练 Soft-Max 回归模型,最后将训练好的卷积神经网络和 Soft-Max 回归模型结合。其中卷积神经网络用于特征提取,Soft-Max 回归模型用于故障的分类。

本文构建了由两个卷积层、两个池化层和一个全连接的单层感知机组成一维卷积神经网络。将此网络结构命名为 $CN8(k_1)-s_2-CN16(k_3)-s_4$,其中, k_1 和 k_3 分别代表卷积核的尺寸, s_2 和 s_4 代表池化层下采样的缩小尺度。其结构图如图4所示。




图4 $CN8(k_1)-s_2-CN16(k_3)-s_4$ 网络结构图

先是利用8个不同的卷积核来提取信号的局部特征,并利用下采样来减少特征的分辨率,对提取的特征进一步和16个不同的卷积核卷积并下采样处理,从而提取出深层次的特征。最后得到分类向量。

本文采集了行星齿轮箱行星轮的4种健康状况:正常、磨损、点蚀和断齿。训练过程中,输入向量为采集的行星轮正常、磨损、点蚀和断齿的振动数据,其对应的理想输出分别为 $[1,0,0,0]$ 、 $[0,1,0,0]$ 、 $[0,0,1,0]$ 、 $[0,0,0,1]$ 。由于实际的输出和理想输出之间存在误差,故本文采用双层网络结构。将训练得到的实际输出向量对 Soft-Max 分类器进行训练,得到最后的分类结果。

在本文提出的双层网络结构中,可以直接用原始的齿轮振动数据来训练网络模型,无需进行数据的预处理,如白化、降维以及滤波等。网络训练流程如图5所示。




图5 网络训练流程图

训练过程分为两个阶段。首先训练卷积神经

网络,初始化神经网络的参数,利用 BP 算法来训练网络,迭代直到网络误差或者迭代次数到达设定要求。再次将神经网络得到的分类向量作为输入来训练 Soft-Max 分类器,当迭代次数到达设定次数时停止迭代。最终检验网络的训练精度是否足够高,若满足精度要求,则保存网络模型,若不满足,则重新设定卷积核尺寸核池化因子。

在分类器的训练过程中,发现迭代次数对分类器精度的影响很小,而且本文着重于设计卷积神经网络结构,故分类器的训练迭代次数设置为 100 次。

4 齿轮箱行星轮试验

4.1 试验平台介绍

测试行星齿轮安装在变速箱齿轮箱内,加速度计安装在齿轮箱壳体上以测量振动信号。可以通过速度控制器来改变电动机转速,旋转频率可设定范围为 0~60 Hz。试验信号的采样频率为 12 kHz。试验平台如图 6 所示。故障行星齿轮如图 7 所示,从左往右依次为磨损、点蚀、断齿故障。行星齿轮的健康状况包括:正常、磨损、点蚀以及断齿状况。当驱动电机旋转频率为 40 Hz,采集的行星轮时域波形如图 8 所示。



图 6 齿轮箱故障模拟试验平台



图 7 故障行星轮

采集数据过程中,设定电动机旋转频率分别为 30、40、50 Hz。每种转速下不同健康状况均采集 600 个样本,共包含 7 200 个样本,每个样本包




图 8 行星齿轮箱行星轮振动波形图

含 1 200 个数据点。

4.2 参数选择

卷积层的特征映射图个数、卷积核的大小、池化层的缩小尺度、学习率以及迭代次数对数据集的识别准确率都有很大的影响。本文构建的卷积神经网络为双卷积层双池化层的结构。为了研究各种参数对分类准确率的影响,首先构造了一个单卷积层单池化层的网络结构 $CN8(k_1)-s_2$,输入层和输出层跟前述网络相同。其次研究了 k_1 和 s_2 对准确率的影响。确定 k_1 和 s_2 后,构造网络 $CN8(k_1)-s_2-CN16(k_3)-s_4$,研究 k_3 和 s_4 对准确率影响。确定网络结构后,最后研究学习率 η 和迭代次数对准确率的影响。

4.2.1 卷积核尺寸和池化层缩小因子的选取

首先构造简单网络结构 $CN8(k_1)-s_2$,初始学习率为 0.05,卷积神经网络训练的迭代次数为 100 次。随机从行星轮样本中抽取 10% 的样本用于训练,剩余 90% 样本用于测试网络准确率。Soft-Max 中 λ 取值为 $1E-5$,训练迭代次数为 100 次。

取 s_2 的值为 10,即第一个池化层的池化因子为 10 倍。研究 k_1 对准确率的影响。表 1 列出了各个 k_1 值下对应的准确率。考虑到训练准确率和测试准确率,选取 k_1 值为 51,构造网络结构 $CN8(51)-s_2$,其他条件不变,研究 s_2 对准确率的影响。表 2 列出了各个 s_2 值下对应的,得出 s_2 选取 25 时,达到最好效果。

表 1 CN8(k_1)-10 准确率

k_1	训练准确率/%	测试准确率/%
21	48.61	45.53
31	49.17	45.97
41	49.03	46.65
51	49.44	46.65
61	25.00	25.00

表 2 CN8(51)- s_2 准确率

S_2	训练准确率/%	测试准确率/%
2	25.00	25.00
5	25.00	25.00
10	49.44	46.65
23	49.58	49.61
25	96.11	92.51

得到 CN8(51)-25 结构有最好效果,在此基础上加深网络,构造网络 CN8(51)-25-CN16(k_3)- s_4 。用同样的方法,首先令 s_4 为 5,得到 k_3 ,之后再优化 s_4 。得到的结果分别如表 3 和表 4 所示。 k_3 值为 2、 s_4 值为 9 时可以得到最高准确率,即网络结构为 CN8(51)-25-CN16(2)-9。

表 3 CN8(51)-25-CN16(k_3)-5 准确率

k_3	训练准确率/%	测试准确率/%
2	94.31	94.51
7	50.00	49.88
12	71.94	71.42
17	73.47	72.93
22	73.89	73.03

表 4 CN8(51)-25-CN16(2)- s_4 准确率

s_4	训练准确率/%	测试准确率/%
3	94.86	93.67
5	94.31	94.51
9	94.17	95.14
15	70.42	70.78

4. 2. 2 学习率 η 和训练迭代次数的选取

学习率影响网络的收敛速度。学习率过高,将导致网络瘫痪,权重和卷积核在学习过程中被置零,学习率太低,导致网络无法快速收敛。在适合的学习率下,迭代次数的增加可以减小网络的误差,使网络有更高的准确率。在神经网络迭代

100 次,分类器迭代 100 次的情况下,表 5 列出了卷积神经网络不同学习率下的测试准确率。图 9 所示为分类器不同衰减系数 λ 下的测试准确率。

表 5 不同学习率 η 下的测试准确率

η	测试准确率/%
0.05	94.51
0.10	96.21
0.15	95.13
0.20	95.52
0.25	96.33
0.30	96.12
0.35	95.96
0.40	69.54
0.45	48.33




图 9 不同衰减系数 λ 下的测试准确率

随着网络迭代次数的增加,网络的误差逐渐减小,图 10 所示为卷积神经网络的均方误差随迭代次数的变化。




图 10 均方误差随迭代次数的变化

从表 5 中可以看出,当学习率为 0.25 时,测试准确率达到最高,为 96.33%。从图 9 中可以看出,当分类器的衰减系数 λ 为 1E-5 时,继续增加 λ 值,准确率基本不再变化,故 λ 取 1E-5,以上结果均在卷积神经网络训练迭代 100 次得到。由图 10 可以看出,随着迭代次数的增高,均方误差逐渐缩小,当迭代 500 次时,网络的误差变化变得很

缓慢,再增加迭代次数效率不高,故选择迭代次数为 500 次。

在试验中,计算机处理器选用英特尔奔腾 g2030,内存选用 2 GB 的 DDR3 内存。迭代 100 次所需时间大约为 3.5 min。若将 1 s 的振动数据输入训练好的网络,前向传播获得分类向量和 Soft-Max 分类诊断的总时间小于 0.045 s。考虑到网络只需要训练一次,网络计算速度能够适应实时诊断的需要。

4.3 行星轮试验

确定网络结构为 CN8(51)-25-CN16(2)-9,即 C1 层和 C3 层分别含有 8 个和 16 个特征映射图, k_1 和 k_2 尺寸分别为 51×1 和 2×1,池化层的池化因子分别为 25 和 9。 η 取值为 0.25, λ 取值为 1×10^{-5} 。

随机从行星轮样本中抽取 10% 的样本,即每种健康状况随机抽取 180 个样本,共 720 个样本用于训练,剩余 90% 样本,即每种健康状况 1 620 个样本,共 6 480 个样本用于测试网络的分类准确率。一维卷积神经网络训练迭代次数为 500,Soft-Max 分类器训练迭代次数为 100。

表 6 所示为一次行星轮故障分类结果的混淆矩阵。混淆矩阵清晰地显示出了每种健康状况分类错误的情况。可以看出,对于断齿故障分类的错误率较高,1 620 组测试样本中,60 组分到正常状况,24 组分到点蚀状况,原因可能是一方面断齿信号和正常信号都存在大量的背景噪声,导致分类错误,另一方面断齿和点蚀都属于局部故障,其故障特征相似,从而导致分类错误。

表 6 行星轮故障混淆矩阵

		预测标签			
		正常	磨损	点蚀	断齿
真实标签	正常	1 608	0	1	11
	磨损	0	1 607	8	5
	点蚀	5	0	1 610	5
	断齿	60	0	24	1 536

为了排除试验的随机性,分别进行了 5 组试验,得到平均训练的分类准确率为 99.86%,平均测试分类准确率为 98.17%。

5 结 语

行星齿轮箱的振动信号包含大量的噪声信

号。如果不能有效去除噪声和提取故障特征,将降低计算效率,并影响故障诊断的准确率。本文将卷积神经网络引入风机故障检测领域,构造了一种一维卷积神经网络结构,应用新的 ReLU 激活函数代替传统的 sigmoid 激活函数,将一维化的卷积神经网络用于行星齿轮箱故障诊断中。该方法无需对振动数据进行预处理,同时仅仅利用 10% 的样本训练网络,即可达到较高的诊断准确率,并且该方法能够适应实时性的需要。

本文研究了卷积神经网络各参数对诊断准确率的影响,通过逐个测试的方法选取了最佳参数。但只是单纯研究了单个参数对准确率地影响,并未考虑各参数间的耦合关系。在试验过程中,发现卷积核尺寸大小和学习率 η 之间存在相关性,当其同时改变时,对网络的准确率有不一样的影响。在下一步的工作中,一方面应加大数据集,研究神经网络的适用性;另一方面,应寻找更加简便的方法,对卷积神经网络参数进行整体优化。

【参 考 文 献】

- [1] QIN S J. Process data analytics in the era of big data [J]. AICHE Journal, 2014, 60(9): 3092-3100.
- [2] FRANKEL F, REID R. Big data: Distilling meaning from data [J]. Nature, 2008, 455(7209): 30.
- [3] CHEN X W, LIN X. Big data deep learning: Challenges and perspectives [J]. IEEE Access, 2014, 2(1): 514-525.
- [4] WORDE K, STASZEWSK W J, HENSMAN J J. Natural computing for mechanical systems research: A tutorial overview [J]. Mech Syst Signal Process, 2011, 25(1): 4-111.
- [5] SHATNAWI Y, AL-KHASSAWENEH M. Fault diagnosis in internal combustion engines using extension neural network [J]. IEEE Trans Ind Electron, 2014, 61(3): 1434-1443.
- [6] PRIETO M D, CIRINCIONE G, ESPINOSA A G, et al. Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks [J]. IEEE Trans Ind Electron, 2013, 60(8): 3398-3407.
- [7] 杨明莉,刘三明,张卫,等.基于振动分析的风力机齿轮箱故障诊断 [J]. 电机与控制应用, 2015, 42(1): 66-71.

(下转第 108 页)

- [5] 汤新舟. 永磁同步电机的矢量控制系统[D]. 杭州: 浙江大学, 2005.
- [6] 张鹏. 永磁同步电动机弱磁调速控制方法的研究[D]. 天津: 天津大学, 2007.
- [7] 方晓春, 胡太元, 林飞, 等. 基于交直流电流耦合的单电流调节器永磁同步电机弱磁控制[J]. 电工技术学报, 2015, 30(2): 141-147.
- [8] 陈宁士, 张跃, 桂卫华, 等. 内埋式永磁同步电机驱动系统的弱磁控制[J]. 控制理论与应用, 2013, 30(6): 718-723.
- [9] CHE H S, LEVI E, JONES M. Current control methods for an asymmetrical six-phase induction motor drive [J]. IEEE Transactions on Power Electronics, 2014, 29(1): 407-417.
- [10] PILLAY P, KRISHNAN R. Modeling, simulation and analysis of permanent magnet motor drives, Part 1: The permanent-magnet synchronous motor drive [J]. IEEE Trans Ind Applicat, 1989(25): 265-273.
- [11] DING S H, WU Q H. Research on inverse model based on and analytic method for induction motor [J]. International Journal of Automation & Control, 2011, 5(4): 356-370.
- [12] BOWES S R, LAI Y S. The relationship between space-vector modulation and regular-sampled PWM [J]. IEEE Transactions on Industry Electronics, 1997, 44(5): 670-679.
- [13] YAZDANI D, KHAJEHODDIN S A, BAKHSHAI A. Full utilization of the inverter in split-phase drives by means of a dual three-phase space vector classification algorithm [J]. IEEE Transactions on Industry Electronics, 2009, 56(1): 120-129.
- [14] 纪志成, 周寰, 李三东. 基于 PSIM 永磁同步电机矢量控制系统的仿真建模[J]. 系统仿真学报, 2004, 16(5): 898-901.
- [15] 左曙光, 林福, 吴旭东. 车用永磁同步电机转矩解析模型和波动特性分析[J]. 浙江大学学报, 2015, 49(9): 1731-1736.
- [16] 王斯博, 赵慧超, 李志宇, 等. 电动车永磁同步电机转矩波动分析及测试[J]. 电机与控制学报, 2015, 19(9): 95-101.
- [17] 杨贵杰, 孙力, 崔乃政. 空间矢量脉宽调制方法的研究[J]. 中国电机工程学报, 2001, 21(5): 79-83.
- [18] 王立欣, 王宇野, 王丰欣. 基于 DSP 的电动车用永磁同步电机的控制方法[J]. 电机与控制学报, 2005, 9(1): 51-54.

收稿日期: 2017 -12 -06

(上接第 87 页)

- [8] 肖蕙蕙, 熊隽迪, 李川, 等. 基于定子电流监测方法的电机故障诊断[J]. 电机与控制应用, 2008, 35(1): 54-57.
- [9] 张文秀, 武新芳. 风电机组状态监测与故障诊断相关技术研究[J]. 电机与控制应用, 2014, 41(2): 50-56.
- [10] YU J. Local and nonlocal preserving projection for bearing defect classification and performance assessment [J]. IEEE Trans Ind Electron, 2012, 59(5): 2363-2376.
- [11] DU Z. Feature identification with compressive measurements for machine fault diagnosis [J]. IEEE Trans Instrum Meas, 2016, 65(5): 977-987.
- [12] BANGALOR P. An artificial neural network approach for early fault detection of gearbox bearings [J]. IEEE Trans Smart Grid, 2015, 6(2): 980-987.
- [13] 朱俊, 刘天羽, 王致杰, 等. 基于蜂群算法的选择性神经网络集成的风机齿轮箱轴承故障诊断[J]. 电机与控制应用, 2017, 44(1): 6-11.
- [14] 于生宝, 何建龙, 王睿家, 等. 基于小波包分析和概率神经网络的电磁法三电平变换器故障诊断方法[J]. 电工技术学报, 2016, 31(17): 102-112.
- [15] 史丽萍, 汤家升, 王攀攀, 等. 采用最优小波树和改进 BP 神经网络的感应电动机定子故障诊断[J]. 电工技术学报, 2015, 30(24): 38-45.
- [16] 杨凌霄, 朱亚丽. 基于概率神经网络的高压断路器故障诊断[J]. 电力系统保护与控制, 2015(10): 62-67.
- [17] 程声烽, 程小华, 杨露. 基于改进粒子群算法的小波神经网络在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2014(19): 37-42.
- [18] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2515.
- [19] YUAN Y, CHAO M, LO Y C. Automatic skin lesion segmentation using deep fully convolutional networks with jaccard distance [J]. IEEE Transactions on Medical Imaging, 2017, 36(9): 1876-1886.
- [20] DOSOVITSKIY A, SPRINGENBERG J T, TATARCHENKO M, et al. Learning to generate chairs, tables and cars with convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(4): 692-700.
- [21] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312.

收稿日期: 2017 -10 -10