

DOI: 10.7652/xjtuxb202003020

面向螺丝锁附序列的多分辨率融合卷积神经网络

刘天宇, 周稻祥, 李明, 李心宇
(太原理工大学大数据学院, 030024, 太原)

摘要: 为了准确识别螺丝锁附是否发生故障和具体故障类型,提出了一种多分辨率融合卷积神经网络。使用原始序列数据作为输入以提高识别速度和精度;为了提取多尺度特征,分别在分辨率(数据长度)为 4 000、2 000 和 1 000 的特征向量上进行一维卷积运算;在 Fusion 层通过上采样、下采样和 1×1 卷积等策略,将各分辨率特征向量融合得到 3 组新特征向量,使得该网络能够获得锁附序列的整体和局部特征信息;在输出层使用类别加权交叉熵(CWCE)损失,通过为损失函数设置惩罚系数来加大对样本较少类别的惩罚力度,缓解了各类别数据不平衡的问题。收集了 3 149 条螺丝锁附序列,并在该数据集上进行了实验,结果表明:在 6 分类实验中,所提方法的准确率为 96.00%,宏 F1 为 93.93%,均高于其他方法;在 2 分类实验中,所提方法的准确率为 99.36%,CWCE 损失的有效性得到了验证;所提方法能够有效地判别锁附故障,并具有较好的实时性。

关键词: 螺丝;锁附故障;多分辨率融合;卷积神经网络;类别加权交叉熵

中图分类号: TP183 **文献标志码:** A **文章编号:** 0253-987X(2020)03-0161-08

Multi-Resolution Fusion Convolutional Neural Network for Screw Locking Series

LIU Tianyu, ZHOU Daoxiang, LI Ming, LI Xinyu
(College of Big Data, Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: For identifying whether a screw locking fault occurs and its type accurately, a multi-resolution fusion convolutional neural network is proposed. To improve recognition rate and accuracy, the network uses original series data as the input. To extract multi-scale features, 1-D convolutional operation is performed on the feature maps with resolutions (data length) of 4 000, 2 000 and 1 000, respectively. In the Fusion layer, the resolution feature maps are fused by upsample, downsample and 1×1 convolution to obtain three sets of new feature maps, so that the network can obtain the global and local information of locking series. In output layer, class weighted cross entropy (CWCE) loss is used to alleviate the issue of unbalanced data in different classes by setting a penalty coefficient for loss function to strengthen the punishment for small sample categories. 3 149 screw locking series datasets are collected, and experiments are performed on this dataset. In the experiments of six categories classification, this approach offers the accuracy rate of 96.00% and the macro F1 of 93.93%, higher than that of the other methods. In two categories classification, this approach offers the accuracy rate of 99.36% and verifies the

validity of CWCE loss. The proposed method can determine the locking fault effectively and has good real-time performance.

Keywords: screw; locking fault; multi-resolution fusion; convolutional neural network; class weighted cross entropy

随着全球电子产品需求量的上升,采用自动锁螺丝机代替人力来完成螺丝锁附工作已经成为电子产品组装企业增加产能、进一步保持市场竞争力的重要手段。然而,一般的自动锁螺丝机仅能根据人为设定的程序完成螺丝的锁附操作,无法识别锁附故障。带有故障螺丝的电子产品在正常使用或遭受外界震动、碰撞等影响时很容易损坏,降低了产品质量。由此可见,对锁附后的螺丝进行故障检验是必不可少过程。目前,螺丝锁附故障检验通常由人工完成,然而由于电子产品的螺丝数量多,每天的产品产量极大,单纯使用肉眼来识别是否存在锁附故障容易产生疲劳,进而影响检验结果。为了提升产品质量,需要自动锁螺丝机具备完成锁附操作后能及时识别锁附故障的能力,从而避免故障产品流入市场,实现螺丝锁附智能化。

如今,使用机器学习来解决现实中的问题已成为热点^[1]。针对螺丝锁附故障识别问题,一种解决方法是使用工业摄像头对锁附完成的螺丝拍照,根据图像来判断螺丝是否锁好^[2]。这种方法虽然能够较好地地对锁附结果进行判别,但是对外界光照干扰较为敏感,需要提供良好的成像环境,且对摄像头的要求较高,因此不适合大规模应用。另一种方法是通过电批内的传感器采集数据,通过分析这些时间序列数据并建立模型来判断锁附结果^[3]。这种方法摆脱了对外部环境的依赖,控制了生产成本,具有极高的实用价值,且取得了一定的效果。自动锁螺丝机工作时采集的锁附序列数据包括扭矩、转角和转速3个维度。由于锁附序列不等长,无法直接使用一般的分类算法。为了解决这个问题,Myers等提出了基于路径的动态时间反转方法^[4],该方法虽然效果较好,但计算成本很高。为降低计算量,罗川等提出了一种基于特征选择的方法来分析螺丝锁附数据,该方法从时间序列数据中提取出能够描述整个序列特性的人工特征,如最大转角、转速的均值等,使用它们代替整个序列,然后使用支持向量机(SVM)^[5]或随机森林(RF)^[6]等方法进行分类^[3]。这种方法虽然可以降低复杂性并减少计算量,但是人工特征的选择需要依赖丰富的经验,而且这些特征只能概括序列少量特性,无法应对种类繁多、原因

复杂的多种故障问题。

近年来,卷积神经网络(CNN)越来越受到研究人员的重视,并被广泛应用于图像分类任务中^[7]。Zhu等将电机转子产生的抖动信号转换为SDP(symmetrized dot pattern)图像,使用CNN提取SDP图像的特征来区分故障信号^[8]。该方法的缺点在于转换过程中损失了时间序列的局部细节特征,并且增加了额外的时间和计算成本,因此具有较大的局限性。在以往的研究中,一维CNN已经被成功地应用于心拍分类任务中^[9-13],如Baloglu等基于一维CNN建立了心电图信号识别模型,用于检测心律失常^[11]。然而,螺丝锁附序列的类别不平衡,而且序列长度远超心电图信号,使用常规的CNN难以提取锁附序列的有效特征。

针对上述问题,本文提出多分辨率融合卷积神经网络(MRFCNN)分类方法,该方法不仅能够直接使用原始的锁附序列来对螺丝锁附故障进行分类,而且能够学习并融合原始数据中不同分辨率的特征,进而将锁附序列映射到多维特征空间中。此外,本文提出了类别加权交叉熵(CWCE)损失函数,该函数的引入可以有效解决类别不平衡问题。

1 方法介绍

1.1 传统分类方法

传统分类方法^[3]从3个方面提取原始扭矩、转角和转速数据序列中的特征,具体提取特征的3个方面为:①序列横向及纵向上的最大值;②序列均值、方差、分位数、一阶差分绝对值的均值和方差;③序列曲线所覆盖的面积。

在得到特征后,传统分类方法使用基于RF的特征选择法度量特征重要性,并筛选出重要的特征^[3]。RF是集成学习方法的一个变体,它以 k 棵决策树为基础学习器,并在训练决策树时引入随机属性的选择^[6]。分类结果由成百上千棵决策树通过投票策略集成得到。

在RF训练过程中,采用后向搜索的方法从特征集合中找出重要性最低的特征,并将其排除,随后迭代多次并记录分类准确率,将准确率最高的特征组合作为最终结果。传统方法使用的螺丝锁附序列

特征共 19 个,分别为:最大转角、最大转角对应的扭矩、最大转角对应的转速、最大扭矩、最大扭矩对应的转角、最大扭矩对应的转速、扭矩均值、转速均值、扭矩标准差、转速标准差、扭矩 25%分位数、扭矩 50%分位数、扭矩 75%分位数、扭矩一阶差分的均值、转速一阶差分的均值、扭矩一阶差分的绝对值均值、转速一阶差分的绝对值均值、扭矩覆盖面积、转速覆盖面积。

对螺丝锁附序列提取出 19 个特征后,再使用基于监督学习的机器学习方法,如 k 近邻(k NN)、SVM、RF、极端梯度提升(XGBoost)或梯度提升树(GBDT)训练分类器,最终得到用于分类的模型。

使用传统方法对螺丝锁附序列进行分类,降低了维数,保留了序列的主要信息,并且一定程度上降低了计算量。但是,传统方法提取的特征过于粗糙,不能完整反映序列的细节,并且泛化性能弱,对于新数据集需要重新设计相关特征,因此具有局限性。

1.2 多分辨率融合卷积神经网络分类方法

1.2.1 卷积神经网络概述 CNN 可以看作是多层感知机的一种扩展。自从 2012 年 ImageNet 分类挑战赛^[14]之后,CNN 迎来了爆发性的发展,在图像领域的诸多应用场景(如图像分类^[15]、目标检测^[16]、姿态识别^[17])的准确率超过了人眼判断的结果,其原因在于 CNN 的卷积滤波器具有自主学习能力,可以提取不同尺度的图像特征并将图像从像素空间映射到语义空间中。对于二维图像,一般使用二维卷积提取特征,浅层的滤波器提取低层次特征,如图像的边缘信息,深层的滤波器提取高层次的信息,图像整体的信息。

然而,在处理一维时间序列数据时,若将其转换为图像,然后使用二维卷积提取特征,会导致计算量及时间消耗同时增加。由于一维卷积因为能够直接在原始数据中提取特征,所以在计算速度上更具优势。目前,一维卷积已经广泛应用于信号分类任务中,例如 Reiss 等使用一维卷积神经网络进行心拍分类^[18]。离散形式的一维卷积可以表示为

$$s(n) = (x * w)(n) = \sum_{a=-\infty}^{\infty} x(a)w(n-a) \quad (1)$$

式中: $*$ 表示卷积运算; $x(n)$ 表示下标为 n 时序列 x 的观测值; $w(a)$ 为加权函数; a 为观测结果距当前时刻的时间间隔。

用于分类任务的 CNN 由两部分组成。第一部分为特征提取器,负责将输入的网格数据映射到特征空间。特征提取器一般由卷积层以及池化层组

成,其中每个卷积层由不同尺寸、不同数量的卷积核组成,而卷积核对特定的输入模式敏感,所以可以将输入数据转换为特征图,并传递给下一层。为了使特征变得稀疏,增加 CNN 的非线性表达能力,需要在卷积层后添加线性整流单元(ReLU)^[7]。池化层可以降低数据的维度,使卷积核学习到不同尺度和层次的特征,同时降低计算量并增加 CNN 的平移不变性。第二部分为分类器,负责接收来自特征提取器传来的特征,并通过全连接的方式使特征与类别建立映射。

1.2.2 多分辨率融合卷积神经网络结构 常规的一维 CNN 将多个卷积层和池化层组合在一起作为特征提取器,如图 1 所示,其中 L_m 代表分辨率索引为 i 的第 n 个卷积层,即当前卷积层的输入分辨率(数据长度)为第 1 层的 $1/2^{i-1}$ 。这样做的缺点在于,输入的数据经过浅层卷积层会得到一组特征向量(由于本文采用一维数据,因此不称之为特征图),这组特征向量之后会经过多个池化层,而池化层会降低特征向量的分辨率,逐级池化的特征向量会逐渐损失掉数据的细节,使得后面的卷积滤波器无法学习到有效的数据特征。若没有池化层,虽然特征向量的细节被保留了下来,但是由于分辨率固定不变,CNN 因过于关注细节而无法提取到整体的信息。

$$L_{11} \rightarrow L_{22} \rightarrow L_{33}$$

图 1 常规的一维 CNN 结构示意图

为了克服这个问题,本文提出了一种针对螺丝锁附序列的网络结构 MRFCNN,如图 2 所示。该网络具有 3 个阶段,分别以 S_i 表示,每个阶段对应相应分辨率的输入数据,并包含 n 个卷积层,最终输入到 Fusion 层 F_i 中。




图 2 MRFCNN 结构示意图

S_1 阶段输入数据的分辨率为螺丝锁附数据序列的原始长度 4 000,该阶段包含 3 个卷积层,每个卷积层由 32 个卷积核组成; S_2 阶段的输入由 L_{11} 输出的螺丝锁附序列特征向量下采样而来,分辨率为 2 000,该阶段包含 2 个卷积层,每个卷积层由 64 个卷积核组成; S_3 阶段的输入由 L_{21} 输出的螺丝锁附序列特征向量下采样而来,分辨率为 1 000,该阶段包含 1 个卷积层,由 128 个卷积核组成。卷积核的维度统一设置为 1×25 ,且各个卷积层的输出全部

使用批归一化层^[19]进行正则化,然后由 ReLU 函数^[7]激活。

Fusion 层 F_1 、 F_2 和 F_3 的结构如图 3 所示。




图 3 Fusion 层结构

从图 3 可以看出:每个 Fusion 层都是由 3 个阶段的特征向量融合而成;在 F_1 层中, L_{22} 和 L_{31} 输出的螺丝锁附序列特征向量分别使用 1×1 的卷积核将通道数缩小为 32,之后使用线性上采样将分辨率扩充至 4 000,再与 L_{13} 的输出相加融合; F_2 层则是将 L_{13} 和 L_{31} 输出的特征向量使用 1×1 的卷积核将通道数更改为 64,之后 L_{13} 输出的特征向量使用平均池化下采样至分辨率为 2 000, L_{31} 输出的特征向量线性上采样至分辨率 4 000,二者再与 L_{22} 的输出相加融合; F_3 层将 L_{13} 和 L_{22} 输出的特征向量使用 1×1 的卷积核将通道数扩充为 128,之后使用平均池化将分辨率下采样至 1 000,再与 L_{31} 的输出相加融合。

螺丝锁附序列 3 个分辨率的特征在经过 Fusion 层融合之后,为减少计算量,使用全局平均池化(GAP)将每个通道的特征向量的平均值作为输出^[20]。 S_1 、 S_2 和 S_3 这 3 个阶段对应的特征向量维度分别为 $1 \times 1 \times 32$ 、 $1 \times 1 \times 64$ 和 $1 \times 1 \times 128$,将 3 个特征向量拼接在一起,形成一个 $1 \times 1 \times 224$ 维的螺丝锁附特征向量。使用全连接层将这些特征与输出类别建立映射关系,并由 softmax 层得到每个类别的概率置信值。MRFCNN 的整体结构如图 4 所示。

1.2.3 类别加权交叉熵损失函数 神经网络训练阶段使用交叉熵对 softmax 层输出的分类结果进行计算并得到误差。一般的交叉熵损失函数定义为

$$J^{(s)} = \sum_{i=1}^K -y_i^{(s)} \log(\hat{y}_i^{(s)}) \quad (2)$$

式中: $\hat{y}_i^{(s)}$ 表示第 s 个样本 softmax 层第 i 个类别的输出值; $y_i^{(s)}$ 代表该类别的真实标签; K 为类别数。 $\hat{y}_i^{(s)}$ 的定义为

$$\hat{y}_i^{(s)} = \frac{e^{\theta_i^T x_1^{(s)}}}{\sum_{j=1}^K e^{\theta_j^T x_1^{(s)}}} \quad (3)$$

式中: θ_i 代表模型参数; $x_1^{(s)}$ 代表第 s 个输入样本 x_1 。CNN 在训练阶段随机取得 P 个样本作为一个小批次,分别为它们计算交叉熵损失,并将这 P 个样本损失的平均值作为该小批次的损失计算梯度。由此可得

$$J = -\frac{1}{S} \left(\sum_{s=1}^S \sum_{i=1}^K y_i^{(s)} \log \left(\frac{e^{\theta_i^T x_1^{(s)}}}{\sum_{j=1}^K e^{\theta_j^T x_1^{(s)}}} \right) \right) \quad (4)$$

由于螺丝锁附数据不同类别样本数量不一致,式(4)作为损失函数会导致某些类别样本数较少而对其惩罚力度不够,降低了分类效果。为解决样本数不均衡的问题,本文设计了 CWCE 损失函数来为不同类别分配不同权重,具体做法为引入一个惩罚系数 λ 。修改后的损失函数为

$$J = -\frac{1}{S} \left(\sum_{s=1}^S \sum_{i=1}^K y_i^{(s)} \lambda_i \log \left(\frac{e^{\theta_i^T x_1^{(s)}}}{\sum_{j=1}^K e^{\theta_j^T x_1^{(s)}}} \right) \right) \quad (5)$$

在常规的交叉熵损失函数中, λ 可以看作 1。在本文中:对样本数量较多的类别设置较小的 λ ,即减小对该类别的反馈;对样本数量较少的类别设置较大的 λ ,即增强该类别的反馈,从而提高该类别的分




图 4 MRFCNN 整体结构

类效果。

2 实验数据集和评价标准

2.1 实验数据集

2.1.1 数据采集 本文将锁附结果分为成功或不成功,其中不成功包括锁歪、空转、滑牙、未锁入和未锁紧。如果锁附结果为成功,则不进行任何后续处理;如果出现锁歪,则需要人工将歪斜的螺丝拧下,并重新进行锁附;如果发生空转,意味着电批没有正常吸附螺丝,则需要产线人员检查螺丝供料器是否故障;如果发生滑牙,则需要电批反转,将滑牙螺丝

拧下;如果螺丝未锁入,则需要尝试吸取螺丝并重新锁入;如果未锁紧,则需要将螺丝拧下后,检查螺孔内是否存在异物。

本文数据由应用于精密电子产品制造场景的定制自动锁螺丝机采集,该机器可以自动吸取螺丝、定位螺孔并完成锁附。电批的批头由三菱电机驱动旋转,扭矩、转角和转速由电机中的传感器每隔 1 ms 采集,并记录于 64 位 Windows 上位机之中。每一颗螺丝锁附完成后,由人工检验锁附结果。

本文数据集包含的 6 种类别的扭矩、转角和转速时序图,如图 5 所示。




图 5 6 种类别的转角、扭矩和转速时序图

本文所用的螺丝锁附数据集各个类别的数据量如下:成功为 1 652,未锁紧为 616,未锁入为 284,滑牙为 241,空转为 44,锁歪为 312,总计 3 149。

2.1.2 数据预处理 由于全连接层的限制,CNN 要求所有输入数据具有相同的分辨率,而每一条螺丝锁附数据的分辨率都不相同。为了解决这个问题,本文将分辨率不足 4 000 的数据末尾使用 0 补齐作为输入数据(实验发现使用插值法将分辨率扩充至 4 000,其效果不及末尾用 0 补齐)。

因为扭矩、转角和转速单位不同,它们的取值上限和下限具有较大的差别,不可以直接输入 CNN 训练,因此需要对数据进行预处理。本文将扭矩、转角和转速 3 个维度归一化,分别对 3 个维度求均值 μ 和标准差 σ ,并使用公式将输入数据 X' 标准化,使用的公式为

$$X = \frac{X' - \mu}{\sigma} \tag{6}$$

2.2 评价标准

螺丝锁附序列具有多个类别,在处理监督学习

问题时,适合使用混淆矩阵来具体反映每个类别错分的分布情况。对于本文的 6 分类问题,其混淆矩阵为

$$\begin{matrix} & \text{预测标签} \\ & \begin{matrix} 1 & 2 & \cdots & 6 \end{matrix} \\ \begin{matrix} \text{真实标签} \\ 1 \\ 2 \\ \vdots \\ 6 \end{matrix} & \begin{pmatrix} n_{11}^T & n_{12}^F & \cdots & n_{16}^F \\ n_{21}^F & n_{22}^T & \cdots & n_{26}^F \\ \vdots & \vdots & \ddots & \vdots \\ n_{61}^F & n_{62}^F & \cdots & n_{66}^T \end{pmatrix} \end{matrix} \tag{7}$$

式中:对角线元素 n_{ii}^T 是分类正确的数据量; n_{ij}^F 为将类别 i 分成类别 j 的数据量。

准确率 A 为分类正确的数据量与所有数据量的比,计算式为

$$A = \frac{\sum_i n_{ii}^T}{\sum_{ij} n_{ij}} \tag{8}$$

每个类别的查准率 P_i 和召回率 R_i 的计算式为

$$P_i = \frac{n_{ii}^T}{n_{ii}^T + \sum_j n_{ij}^F} \tag{9}$$

$$R_i = \frac{n_{ii}^T}{n_{ii}^T + \sum_j n_{ji}^F} \tag{10}$$

宏查准率 M_P 、宏召回率 M_R 为所有类别的查准率、召回率的平均值,计算式为

$$M_P = \frac{1}{N} \sum_{i=1}^N P_i \tag{11}$$

$$M_R = \frac{1}{N} \sum_{i=1}^N R_i \tag{12}$$

宏 $F1(M_{F1})$ 是 M_P 和 M_R 的调和平均值,计算式为

$$M_{F1} = \frac{2M_P M_R}{M_P + M_R} \tag{13}$$

3 实验结果

螺丝锁附故障分类实验在 CPU 为 Intel Xeon E5-1620 v4 3.5 GHz、GPU 为 Nvidia Tesla P100、内存为 8 GB 的 64 位 Ubuntu PC 进行,MRFCNN 由基于 Python 语言的 PyTorch 深度学习框架实现。

为了验证所提方法的有效性,本文采用 10 折交叉验证法来评估螺丝锁附故障分类性能。将数据集划分为 10 个大小相似的互斥子集,每次实验使用 9 个子集的并集用作训练集,剩余的 1 个子集用作测试集。这样就可以获得 10 组训练集和测试集,并进行 10 次训练和测试。

3.1 锁附结果 6 分类

使用传统方法进行螺丝锁附序列 6 分类实验作为对比。提取 1.1 节所示的 19 个特征^[3]作为输入,分别使用 k NN、SVM、RF、XGBoost 和 GBDT 进行分类,结果如表 1 所示。

表 1 传统方法分类结果

方法	$M_{F1} / \%$	$A / \%$
k NN	68.02	75.67
SVM	87.42	82.37
RF	88.36	92.32
XGBoost	88.86	92.57
GBDT	89.29	92.70

对于基于 CNN 的方法,实验训练阶段的小批次数量为 128,学习率设定为 0.000 1 并使用 Adam 优化器^[21]更新梯度,训练迭代次数为 200,耗时 12 min。本文提出的 MRFCNN 训练及测试准确率随迭代次数的变化关系如图 6 所示。

为了验证 MRFCNN 中 3 个阶段特征融合的有效性,设计了 3 层卷积 2 层池化结构(CNN-A)、3 层卷积 1 层池化结构(CNN-B)和 3 层卷积无池化结




图 6 MRFCNN 训练及测试准确率

构(CNN-C)的网络,分别独立代表 S_3 、 S_2 和 S_1 ,3 种网络结构的参数如表 2~4 所示。将 3 种网络结构和 MRFCNN 的实验结果进行了对比,结果如表 5 所示。

表 2 CNN-A 的参数

层类型	核维度	步长	核数量
卷积	1×25	1	32
平均池化	1×2	2	
卷积	1×25	1	64
平均池化	1×2	2	
卷积	1×25	1	128
输出层	1×6		

表 3 CNN-B 的参数

层类型	核维度	步长	核数量
卷积	1×25	1	32
平均池化	1×2	2	
卷积	1×25	1	64
卷积	1×25	1	128
输出层	1×6		

表 4 CNN-C 的参数

层类型	核维度	步长	核数量
卷积	1×25	1	32
卷积	1×25	1	64
卷积	1×25	1	128
输出层	1×6		

表 5 3 种网络结构和 MRFCNN 的实验结果

网络结构	$M_{F1} / \%$	$A / \%$
CNN-A	91.93	94.86
CNN-B	91.06	94.63
CNN-C	90.94	94.51
MRFCNN	93.93	96.00

由表 1 和表 5 可知:传统方法的性能较低,最优的传统方法 GBDT 的 M_{F1} 与 A 分别为 89.29% 和 92.70%,不及 CNN 的最次方法 CNN-C;对照组 CNN-A、CNN-B 和 CNN-C 的 M_{F1} 和 A 呈现递减的顺序,其中 CNN-A 最高,为 91.93% 和 94.86%;MRFCNN 的 M_{F1} 和 A 分别为 93.93% 和 96.00%,相比 CNN-A 高了 2.00% 和 1.14%。由此可见,特征融合取得了最佳分类性能。

使用 MRFCNN 进行 6 分类实验,各个类别的查准率、召回率和 F_1 分值 S_{F1} 如表 6 所示,表中宏平均指每个类别下查准率、召回率和 S_{F1} 的平均值,混淆矩阵如图 7 所示。

表 6 使用 MRFCNN 的 6 分类实验结果

分类结果	查准率/%	召回率/%	S_{F1} /%
成功	98.62	99.46	99.04
未锁紧	94.55	92.86	93.69
未锁入	91.86	95.42	93.61
滑牙	93.99	90.87	92.41
空转	97.62	93.18	95.35
锁歪	89.94	88.78	89.35
宏平均	94.43	93.43	93.93

	成功	未锁紧	未锁入	滑牙	空转	锁歪
成功	1 634	9	0	0	0	0
未锁紧	13	573	2	0	0	29
未锁入	2	0	271	10	0	1
滑牙	1	1	18	219	1	1
空转	0	0	0	3	41	0
锁歪	7	23	4	1	0	277

图 7 使用 MRFCNN 的 6 分类混淆矩阵

由本节可知:传统方法由于受到手工设计特征的局限,螺丝锁附数据的细节信息被忽视,因此无法完整地描述锁附状况,分类效果最差;CNN 由于具有自适应的卷积核,因此可以学习到螺丝锁附序列扭矩、转角和转速序列的特征,但是由于 CNN-C 不具备池化层结构,锁附序列分辨率过大,卷积核往往只能学习到序列的局部细节信息;具有池化结构的 CNN-A 和 CNN-B,由于特征向量的分辨率被缩短,卷积核可以学习到螺丝锁附序列的整体特征,因此分类效果随池化层数量增加而提升,但是池化层在

帮助卷积核学习到整体特征的同时,本身又会降低螺丝锁附序列的分辨率,抹去数据的细节,因此又限制了分类效果;本文提出的 MRFCNN 网络结构综合了低分辨率和高分辨率的优点,能够同时对 3 个分辨率的特征向量提取特征,并经过 Fusion 层将特征向量融合并拼接,既能够敏感地挖掘到螺丝锁附序列细节信息,又能掌握序列的整体信息,因此具有最佳识别效果。

3.2 锁附结果 2 分类

进一步使用 MRFCNN 进行螺丝锁附序列 2 分类实验,即将锁附序列区分为成功和不成功这 2 类。数据集中,锁附结果为成功的数据量明显多于不成功的数据量,而神经网络对不平衡的数据较为敏感,因此本文分别使用常规的交叉熵损失函数和 CWCE 损失函数(式(5))训练神经网络,其中成功和不成功数据序列的惩罚系数分别为 $\lambda_{OK}=0.8, \lambda_{NG}=1$ 。

实验结果如下:在准确率方面,使用常规的交叉熵损失函数与 CWCE 损失函数结果相同,都为 99.36%;在不成功类别的召回率方面,常规的交叉熵损失函数为 99.27%,CWCE 损失函数表现较好,为 99.40%。虽然将成功类别的螺丝误分类为不成功类别会造成螺丝的浪费,但是将不成功类别误分类为成功类别可能导致锁附过程中损坏电路板,或者使带有故障螺丝的产品流入市场,后果比前者更加严重。由此可见,使用 CWCE 损失函数在确保准确率不下降的情况下,能够提高不成功类别的召回率,进而提高分类质量。

3.3 实时性分析

本文方法能够在保证准确性的情况下,仍具有较快的计算速度。当使用 2 834 条数据用作训练集时,迭代 200 次大约需要 12 min。在测试阶段,平均每条数据只需约 0.3 ms 即可得到分类结果,即每秒可以判断大约 3 300 条螺丝锁附数据所属的类别,具有较好的实时性。

4 结 论

本文针对螺丝锁附故障识别问题提出了 MRF-CNN 网络,并用于锁附序列 6 分类及 2 分类,该网络能够提取序列多个分辨率下不同层次的特征,并使用 CWCE 损失函数缓解了数据不平衡的问题。本文方法无需人工设计特征,不依赖螺丝锁附的相关经验,能够自动地从已有序列中学习特征。为了验证本文方法的有效性,与传统的人工设计特征结

合分类器的方法、常规的 CNN 方法进行了对比。实验结果表明,使用 MRFCNN 进行 6 分类获得了最高的准确率(96.00%)和宏 F1(93.93%),同时本方法在 2 分类问题的准确率达 99.36%,可应用到实际的生产中。

但是,本文方法使用的数据集存在某些类别数据量过少的问题,未来的工作将针对这些类别收集更多的数据,使模型能够学习到更丰富的特征进而提高分类准确率。此外,未来拟研究使用模型剪枝方法缩减模型的参数,以减少运行时间和内存占用。

参考文献:

- [1] DIETTERICH T G. Machine learning research: four current directions [J]. *AI Magazine*, 1997, 18(4): 97-136.
- [2] DIFILIPPO N M, JOUANEH M K. A system combining force and vision sensing for automated screw removal on laptops [J]. *IEEE Transactions on Automation Science and Engineering*, 2018, 15(2): 887-895.
- [3] 罗川, 黄迟, 曾文绶, 等. 基于随机森林的智能锁螺丝机锁附判别研究 [J]. *济南大学学报(自然科学版)*, 2019(5): 410-416.
LUO Chuan, HUANG Chi, ZENG Wenshou, et al. Discrimination of intelligent screw machine based on random forest [J]. *Journal of University of Jinan (Science and Technology)*, 2019(5): 410-416.
- [4] MYERS C, RABINER L, ROSENBERG A. Performance tradeoffs in dynamic time warping algorithms for isolated word recognition [J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1980, 28(6): 623-635.
- [5] CORTES C, VAPNIK V. Support-vector networks [J]. *Machine Learning*, 1995, 20(3): 273-297.
- [6] BREIMAN L. Random forests [J]. *Machine Learning*, 2001, 45(1): 5-32.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [8] ZHU X X, HOU D N, ZHOU P, et al. Rotor fault diagnosis using a convolutional neural network with symmetrized dot pattern images [J]. *Measurement*, 2019, 138: 526-535.
- [9] LI D, LI X M, ZHAO J M, et al. Automatic staging model of heart failure based on deep learning [J]. *Bio-medical Signal Processing and Control*, 2019, 52: 77-83.
- [10] SWAPNA G, KP S, VINAYAKUMAR R. Automated detection of diabetes using CNN and CNN-LSTM network and heart rate signals [J]. *Procedia Computer Science*, 2018, 132: 1253-1262.
- [11] BALOGLU U B, TALO M, YILDIRIM O, et al. Classification of myocardial infarction with multi-lead ECG signals and deep CNN [J]. *Pattern Recognition Letters*, 2019, 122: 23-30.
- [12] 庞彦伟, 李潇, 梁金升, 等. 基于卷积神经网络的第一导联心电图心拍分类 [J]. *天津大学学报(自然科学与工程技术版)*, 2018, 51(10): 997-1004.
PANG Yanwei, LI Xiao, LIANG Jinsheng, et al. Classification of first lead electrocardiogram heartbeats based on convolutional neural networks [J]. *Journal of Tianjin University (Science and Technology)*, 2018, 51(10): 997-1004.
- [13] 原永朋, 游大涛, 渠慎明, 等. 卷积神经网络在心拍类识别中的应用 [J]. *计算机应用*, 2018, 38(12): 3638-3642, 3648.
YUAN Yongpeng, YOU Datao, QU Shenming, et al. Application of convolution neural network in heart beat recognition [J]. *Journal of Computer Applications*, 2018, 38(12): 3638-3642, 3648.
- [14] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet et large scale visual recognition challenge [J]. *International Journal of Computer Vision*, 2015, 115(3): 211-252.
- [15] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C]// *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*. London, UK: ICLR, 2015: 1-14.
- [16] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]// *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway, NJ, USA: IEEE, 2014: 580-587.
- [17] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation [C]// *Proceedings of the 2019 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway, NJ, USA: IEEE, 2019: 5693-5703.
- [18] REISS A, INDLEKOFER I, SCHMIDT P, et al. Deep PPG: large-scale heart rate estimation with convolutional neural networks [J]. *Sensors*, 2019, 19(14): 3079.

(下转第 178 页)

- [9] 国家能源局. 架空输电线路杆塔结构设计技术规定: DL/T5154—2012 [S]. 北京: 中国电力出版社, 2012: 45-47.
- [10] 俞登科, 任吉华, 段松涛, 等. 基于区格法的输电塔有劲塔脚板强度分析 [J]. 电力勘测设计, 2017(2): 42-45.
YU Dengke, REN Jihua, DUAN Songtao, et al. Strength analysis of tower footing plate with stiffening in transmission tower based on lattice method [J]. Electric Power Survey & Design, 2017(2): 42-45.
- [11] 杨攀, 张雷, 孟宪乔, 等. 单角钢八地脚螺栓的受力分析及其塔脚板厚度设计 [J]. 南昌大学学报(工科版), 2016, 38(3): 240-244.
YANG Pan, ZHANG Lei, MENG Xianqiao, et al. Stress analysis of single eight foundation bolts and its design of bottom plate thickness [J]. Journal of Nanchang University (Engineering & Technology), 2016, 38(3): 240-244.
- [12] 殷黎明, 邓锦辉. 输电铁塔塔脚板厚度有限元分析 [J]. 河南电力技术, 2016(10): 57-59.
YIN Liming, DENG Jinhui. Finite element analysis of thickness for base plate in steel transmission tower [J]. Henan Power Technology, 2016(10): 57-59.
- [13] 刘俊卿, 袁红丽, 文凡, 等. 输电塔结构八地脚螺栓塔座板的抗拉承载力试验与计算方法研究 [J]. 土木工程学报, 2019, 52(7): 48-56.
LIU Junqing, YUAN Hongli, WEN Fan, et al. Experimental research and calculation method for tensile bearing capacity of the base plate with eight bolts in transmission tower structure [J]. China Civil Engineering Journal, 2019, 52(7): 1-9.
- [14] 中华人民共和国国家质量监督检验检疫总局. 金属材料 拉伸试验: 第1部分 室温试验方法: GB/T 228.1—2010 [S]. 北京: 中国标准出版社, 2010: 1-19.
- [15] BOUZID A H. Comparative study of bolt spacing formulas used in bolted joint designs [J]. International Journal of Pressure Vessels and Piping, 2014, 120/121: 47-54.
- [16] 中华人民共和国住房和城乡建设部. 钢结构设计标准: GB 50017—2017 [S]. 北京: 中国建筑工业出版社, 2017: 128-139.
- [17] CAO J J, PACKER J A, YANG G J. Yield line analysis of RHS connections with axial loads [J]. Journal of Constructional Steel Research, 1998, 48(1): 1-25.

(编辑 武红江)

(上接第 118 页)

- [32] WONGSAGONSUP R, DEEYAI P, CHAIWAT W, et al. Modification of tapioca starch by non-chemical route using jet atmospheric argon plasma [J]. Carbohydrate Polymers, 2014, 102: 790-798.
- [33] LIH C, LIAO C, STOBINSKI L, TOMASIK P. Behaviour of granular starches in low-pressure glow plasma [J]. Carbohydrate Polymers, 2002, 49(4): 499-507.
- [34] CHEN Huahan, CHANG H C, CHEN Yukuo, et al. An improved process for high nutrition of germinated brown rice production: low-pressure plasma [J]. Food Chemistry, 2016, 191: 120-127.
- [35] SARANGAPANI C, THIRUMDAS R, DEVI Y, et al. Effect of low-pressure plasma on physico-chemical and functional properties of parboiled rice flour [J]. LWT: Food Science and Technology, 2016, 69: 482-489.
- [36] 中国储备粮管理总公司成都粮食储藏科学研究所. 玉米储存品质判定规则: GB/T 20570—2015 [S]. 北京: 中国标准出版社, 2015: 1-16.

(编辑 武红江)

(上接第 168 页)

- [19] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning (ICML). Princeton, NJ, USA: International Machine Learning Society (IMLS), 2015: 448-456.
- [20] LIN M, CHEN Q, YAN S. Network in network [C]//Proceedings of the 2nd International Conference on Learning Representations (ICLR). London, UK: ICLR, 2014: 1-10.
- [21] KINGMA D, BA J. Adam: a method for stochastic optimization [C]//Proceedings of the 3rd International Conference on Learning Representations (ICLR). London, UK: ICLR, 2015: 1-15.

(编辑 陶晴)