

DOI:10.19651/j.cnki.emt.2211307

基于 Inception-DLSTM 双通道的滚动轴承故障诊断方法^{*}

范志伟 郭世伟 罗鑫 刘应桃 付孟新
(西南交通大学机械工程学院 成都 610031)

摘要: 卷积神经网络(CNN)对空间特征具有敏感性,而 Inception 相比 CNN 具备多尺度提取特征优势;长短时记忆网络(LSTM)对时间特征具有敏感性,而深层长短时记忆网络(DLSTM)比 LSTM 具备更深层次提取特征优势。为了多尺度充分提取滚动轴承振动信号在空间和时间上的特征,实现滚动轴承故障诊断,提出了一种 Inception 通道和 DLSTM 通道结合的 Inception-DLSTM 双通道滚动轴承故障诊断模型。对于 Inception 通道,把轴承振动信号经过小波变换生成的时频图作为输入,利用 Inception 网络多尺度提取时频图的空间特征信息;对于 DLSTM 通道,直接把轴承振动信号作为输入,利用 DLSTM 网络充分提取信号的时间特征信息。然后把两个通道输出的特征信息连接成一个时空特征向量,最后利用分类器进行轴承故障诊断识别。对轴承故障数据进行对比实验可得,Inception-DLSTM 双通道的故障识别准确率可达 100%,具备良好的故障诊断和特征提取能力。

关键词: Inception-DLSTM 双通道;滚动轴承;故障诊断;空间特征;时间特征

中图分类号: TH133.33 文献标识码: A 国家标准学科分类代码: 510.40

Rolling bearing fault diagnosis method based on Inception-DLSTM dual channel

Fan Zhiwei Guo Shiwei Luo Xin Liu Yingtao Fu Mengxin
(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Convolution neural network (CNN) is sensitive to spatial features, while Inception has the advantage of multi-scale feature extraction compared with CNN, long-short-term memory network (LSTM) is sensitive to temporal features, and deep short-term memory network (DLSTM) has deeper feature extraction advantages than LSTM. In order to fully extract the spatial and temporal characteristics of rolling bearing vibration signals in multi-scale, a dual-channel rolling bearing fault diagnosis model Inception-DLSTM based on the combination of Inception channel and DLSTM channel is proposed. For the Inception channel, the time-frequency diagram generated by the wavelet transform of the bearing vibration signal is used as the input, and the multi-scale Inception network is used to extract the spatial feature information of the time-frequency diagram; for the DLSTM channel, the bearing vibration signal is directly taken as the input, and the DLSTM network is used to fully extract the time feature information of the signal. Then the feature information output from the two channels is connected into a spatio-temporal feature vector, and finally the classifier is used to diagnose and identify the bearing fault. Comparing the bearing fault data can be obtained, and the fault identification accuracy of the Inception-DLSTM dual channel can reach 100%, and has good fault diagnosis and feature extraction capabilities.

Keywords: Inception-DLSTM dual channel; rolling bearing; fault diagnosis; spatial features; temporal characteristics

0 引言

当今人工智能飞速发展,机械故障诊断方面的研究也

紧跟步伐,进入“大数据”时代。滚动轴承正常工作是旋转机械设备正常运转的必备条件,必须对滚动轴承进行故障诊断与检测。传统的滚动轴承故障诊断方法是先人工提取

收稿日期:2022-09-06

*基金项目:四川科技厅重点研发项目(2020YFG0124)、博士后科学基金(2020M682506)项目资助

故障特征,然后再利用机器学习分类算法进行故障诊断,此类方法已经不再适合“大数据”时代,而在深度学习日臻成熟的情况下,由于其强大的自动学习与提取特征的能力,基于深度学习的滚动轴承故障诊断算法迅猛发展,已经取得较好的诊断结果。

卷积神经网络(convolutional neural network,CNN)具备局部连接、权重共享等特点^[1],被广泛应用在滚动轴承的故障诊断方面。Liu 等^[2]利用一维 CNN 对滚动轴承一维振动信号进行特征提取与故障诊断。杨勘立等^[3]利用 MED 理论对轴承信号进行预处理,再利用 CNN 提取特征,实现列车轴承故障诊断。陈里里等^[4]等利用小波包分解方法对轴承信号进行处理,获得时频图,再利用 CNN 对时频图进行特征提取,实现故障诊断。与原始信号相比,时频图包含更多故障空间特征^[5]。齐爱玲等^[6]提出了一种双通道 CNN 的轴承故障诊断网络,通道 1 的输入为时频图,通道 2 的输入为原始振动信号,将两通道各自提取到的特征进行拼接,最后再进行故障诊断。Inception 是一种特殊的 CNN,其具有不同卷积核并联的结构特点,能从不同尺度提取更多样的信息。Li 等^[7]利用改进的 Inception 胶囊网络,对滚动轴承的不同点蚀故障进行识别分类,实验结果表明该模型能够有效区分不同速度下不同程度的轴承点蚀故障。利用 CNN 能够有效挖掘滚动轴承振动信号空间上的故障特征,而由于自身网络结构特点,CNN 不能有效提取信号包含的时间特征。

循环神经网络(recurrent neural network,RNN)对时间信号敏感,可以充分提取时间特征。在 RNN 基础上又改进衍生了门控循环单元(gate recurrent unit,GRU)和长短时记忆(long short-term memory network,LSTM)等网络。张龙等^[8]构建了 CNN 通道与 GRU 通道结合的双通道轴承故障诊断方法,实现了齿轮箱的故障诊断。Hao 等^[9]先利用一维 CNN 直接提取滚动轴承振动信号的空间特征,在此基础上,再用 LSTM 进一步提取时间特征,最后对轴承故障进行分类。Shi 等^[10]先利用堆叠降噪编码器重构故障信号,再用 LSTM 对滚动轴承状态进行诊断分类。为了能更深层次提取特征,可把多个 LSTM 网络堆叠在一起构建更深的模型^[11],即深局长短时记忆网络(deep long short-term memory network,DLSTM)。

虽然利用 CNN 和 RNN 对轴承进行故障诊断的模型众多,但没有把 CNN 对空间的敏感性和 RNN 对时间的敏感性充分地结合在一起,因此提出一种 Inception-DLSTM 双通道的轴承故障诊断方法,利用 Inception 通道多尺度提取轴承故障时频图的空间特征,而 DLSTM 通道充分提取一维原始信号的时间特征,时空特征结合,再输入分类器进行故障诊断。

1 基本原理

1.1 小波变换理论

在 $L^2(R)$ 空间中,任何函数都能由一组函数的分解来

表示,该函数被称为小波基函数。满足平方可积,并且满足式(1)的函数 $\psi(t)$ 为一个小波基。

$$C_\psi = \int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|} d\omega < \infty \quad (1)$$

小波是由小波基 $\psi(t)$ 通过伸缩和平移而产生的一个函数族 $\psi_{(a,b)}(t)$:

$$\psi_{(a,b)}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

设 $f(t) \in L^2(R)$, 连续小波变换的定义为:

$$W_a(f,a,b) = |a|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (3)$$

滚动轴承故障基本表现为脉冲冲击,其产生的波形与 morlet 小波类似^[6],选择 morlet 小波中的 cmor3-3 型小波作为小波基函数对滚动轴承振动信号进行处理^[12],可以得到包含更多故障特征的时频图。

1.2 Inception 模块

在搭建传统的 CNN 时,需要对卷积层的过滤器大小和池化层的位置进行选择,这些主观的选择可能影响网络模型性能,而 Inception 网络的出现正好弥补了这种缺陷。Inception 模块有 4 个通道,包含不同尺寸的过滤器和最大池化操作,如图 1 所示。

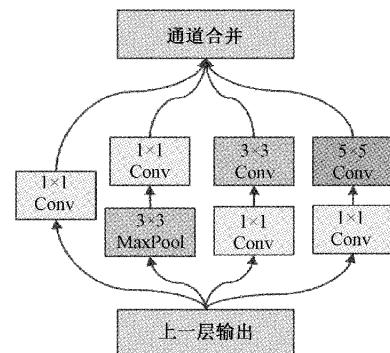


图 1 Inception 模块结构

Inception 模块各通道的参数可以用式(4)表示,如式(4)的 $I(i)$ 中 $(1 \times 1 \times i, 3 \times 3 \times i)$ 的含义是 Inception 模块的第三通道先用 i 个 1×1 大小的过滤器,对上一层的输出进行特征提取,再利用 i 个 3×3 大小的过滤器进一步提取故障特征。

$$I(i) = \begin{bmatrix} 1 \times 1 \times i \\ (3 \times 3, 1 \times 1 \times i) \\ (1 \times 1 \times i, 3 \times 3 \times i) \\ (1 \times 1 \times i, 5 \times 5 \times i) \end{bmatrix} \quad (4)$$

虽然在 CNN 中加入 Inception 模块会使网络架构变得复杂,但是可以让网络的特征提取能力更强大,多尺度提取特征,同时 Inception 模块的每个通道都使用了 1×1 的过滤器来压缩通道数,以此降低参数计算量和提升模型的非线性拟合能力。

1.3 DLSTM 网络

LSTM 相比 RNN 加入了门控结构,有效解决梯度消失问题^[13],LSTM 的基础模块如图 2 所示。

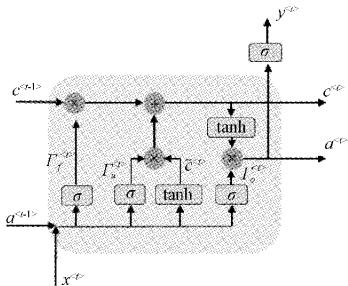


图 2 LSTM 基础模块结构

LSTM 最重要的部分是具备遗忘门 $\Gamma_f^{<t>}$ 、更新门 $\Gamma_u^{<t>}$ 和输出门 $\Gamma_o^{<t>}$, 3 种门的计算公式如下:

$$\Gamma_f^{<t>} = \sigma(W_f[a^{<t-1>}, x^{<t>}] + b_f) \quad (5)$$

$$\Gamma_u^{<t>} = \sigma(W_u[a^{<t-1>}, x^{<t>}] + b_u) \quad (6)$$

$$\Gamma_o^{<t>} = \sigma(W_o[a^{<t-1>}, x^{<t>}] + b_o) \quad (7)$$

式中: $a^{<t-1>}$ 是 $t-1$ 时刻的输出值, $x^{<t>}$ 是 t 时刻的输入, W 为权重, b 为偏置项, σ 是 Sigmoid 激活函数。

利用 $\Gamma_f^{<t>}$ 和 $\Gamma_u^{<t>}$ 更新记忆单元 $c^{<t-1>}$ 的值得到 $c^{<t>}$, t 时刻的输出值 $a^{<t>}$ 由 $c^{<t>}$ 和 $\Gamma_o^{<t>}$ 决定, 具体计算公式如下:

$$c^{<t>} = \tanh(W_c[a^{<t-1>}, x^{<t>}] + b_c) \quad (8)$$

$$c^{<t>} = \Gamma_f^{<t>} \times c^{<t-1>} + \Gamma_u^{<t>} \times c^{<t>} \quad (9)$$

$$a^{<t>} = \Gamma_o^{<t>} \times \tanh(c^{<t>}) \quad (10)$$

为了深层次提取特征, 可把 LSTM 进行堆叠, 如图 3 所示为一个 DLSTM 网络, 包含 3 层 LSTM 堆叠, 其中 $a^{[1]<t>}$ 和 $c^{[1]<t>}$ 表示第一层 LSTM 网络 t 时刻的输出值与记忆值, $a^{[2]<t>}$ 和 $c^{[2]<t>}$ 表示第二层 LSTM 网络 t 时刻的输出值与记忆值, 以此类推。滚动轴承故障诊断模型只保留最后时刻的输出 $y^{<t>}$ 作为 DLSTM 通道的输出。

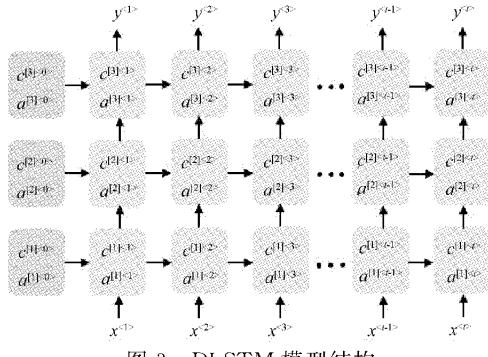


图 3 DLSTM 模型结构

2 基于 Inception-DLSTM 双通道的滚动轴承故障诊断网络

本文提出了一种基于 Inception-DLSTM 双通道的滚动轴承故障诊断网络, 该网络模型的组成部分如图 4 所示。

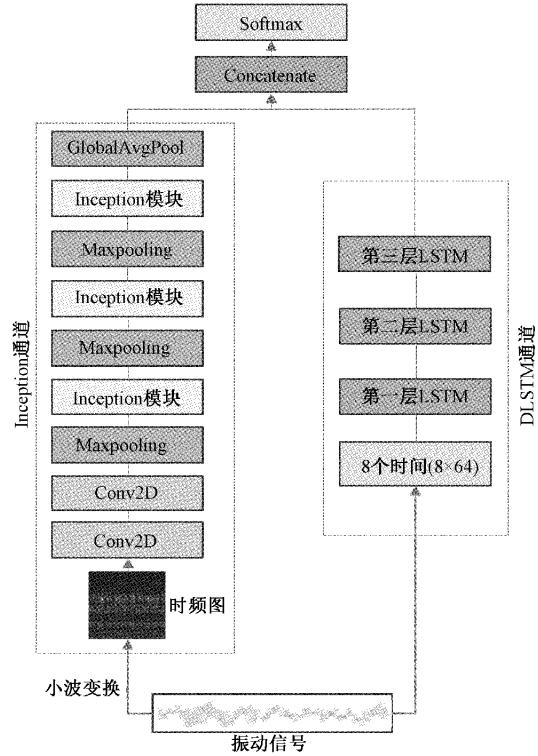


图 4 基于 Inception-DLSTM 双通道的滚动轴承故障诊断网络

Inception 通道的输入为时频图, 该通道先用两层传统卷积层对时频图初步提取特征, 经过大池化操作, 再进一步利用 Inception 模块提取空间特征, 最后以全局平均池化 (GlobalAvgPool) 代替最大池化, 起到降低待训练参数量, 提高训练效率的作用^[14]。

DLSTM 通道采用 3 层的 LSTM 堆叠组成, 输入为 8×64 个滚动轴承振动信号数据, 即分为 8 个时间步, $x^{<1>}$ 到 $x^{<8>}$, 该通道主要利用 DLSTM 网络提取滚动轴承故障信号的时间特征。

将 Inception 通道和 DLSTM 通道提取到的特征连接 (Concatenate) 成一个特征向量, 送入 Softmax 层, 最终输出故障类别, 得到诊断结果。

Inception 通道和 DLSTM 通道各层参数设置如表 1 和表 2 所示, 表 2 中循环舍弃 (recurrent_dropout) 和舍弃 (dropout) 操作可以让 LSTM 沿着时间正确地传播其学习误差, 降低过拟合^[15]。其中 Inception 通道或 DLSTM 通道最后也可以直接连接 Softmax 层, 形成单通道 Inception 或单通道 DLSTM 进行故障诊断, 与 Inception-DLSTM 双通道进行对比实验。

3 实验数据分析及设置

为了对提出的 Inception-DLSTM 双通道模型进行验证, 需要滚动轴承故障数据集并对其进行相应处理和实验, 验证模型的可行性与优势。

表 1 Inception 通道参数设置

结构名称	参数	输出尺寸	步长	是否零补
输入	$60 \times 60 \times 3$	—	—	—
Conv2D	$3 \times 3 \times 32$	$29 \times 29 \times 32$	2×2	否
Conv2D	$3 \times 3 \times 32$	$14 \times 14 \times 32$	2×2	否
MaxPooling	2×2	$7 \times 7 \times 32$	2×2	否
Inception 模块	$I(16)$	$7 \times 7 \times 64$	1×1	是
MaxPooling	2×2	$3 \times 3 \times 32$	2×2	否
Inception 模块	$I(32)$	$3 \times 3 \times 128$	1×1	是
MaxPooling	2×2	$1 \times 1 \times 128$	2×2	否
Inception 模块	$I(64)$	$1 \times 1 \times 256$	1×1	是
GlobalAvgPool	—	256	—	否

表 2 DLSTM 通道参数设置

结构名称	输入	输出	循环舍弃	舍弃
第一层 LSTM	8×64	8×64	0.1	0.1
第二层 LSTN	8×64	8×128	0.1	0.1
第三层 LSTN	8×128	256	0.1	0.1

3.1 实验数据来源和分析

本文所用到的轴承故障数据采用第三方数据,采用美国的凯斯西储大学轴承中心所提供的滚动轴承故障数据^[16]来作为本次研究内容的初始数据,该数据分别对滚动轴承的滚动体、内圈和外圈利用电火花加工得到三种不同损伤直径的单点故障。

根据凯斯西储大学轴承数据集,可以分为 10 种滚动轴承故障状态,并且以 4:1 的比例把数据划分为训练集和测试集,数据集的划分结果如表 3,其中每个样本具有 512 个振动信号数据点。

表 3 滚动轴承数据集的划分

滚动轴承 故障状态	损伤直径/ mm	训练集 样本数	测试集 样本数	标签
正常	0	736	184	0
轻度滚动体故障	0.1778	736	184	1
轻度内圈故障	0.1778	736	184	2
轻度外圈故障	0.1778	736	184	3
中度滚动体故障	0.3556	736	184	4
中度内圈故障	0.3556	736	184	5
中度外圈故障	0.3556	736	184	6
重度滚动体故障	0.5334	736	184	7
重度内圈故障	0.5334	736	184	8
重度外圈故障	0.5334	736	184	9
合计	—	7 360	1 840	—

Inception 通道的输入为时频图,所以需要对每个样本进行小波变化得到时频图,结果如图 5 所示,由图 5 可以看出不同轴承状态的时频图具有可分辨性,可以利用 Inception 通道提取时频图的空间特征。

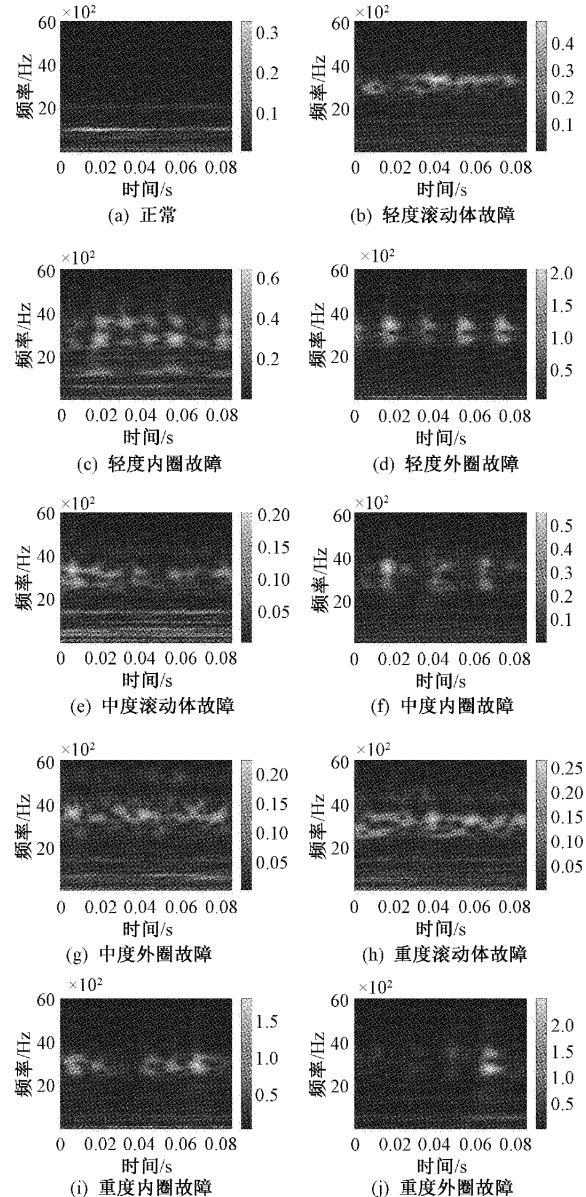


图 5 10 种滚动轴承故障状态小波时频图

3.2 实验相关参数设置

Inception-DLSTM 双通道模型实验所采用的框架为 keras, 基于 python 语言搭建, 以交叉熵计算损失, 采用 Adam 算法更新模型参数, 训练迭代 100 次, 采用小批量方式进行训练, 每次送入网络的样本数量为 32, 每完成一次迭代, 就对测试集进行预测, 计算诊断准确率。初始学习率设置为 0.001, 训练过程中动态调整学习率, 当连续经过 10 次迭代, 测试集的诊断准确率仍然没有增加时, 学习率就会设置为原来的 1/2, 继续训练模型, 直到达到迭代次数。

4 实验分析

4.1 实验结果分析

利用训练集进行模型训练,然后用测试集进行模型测试,得到测试集在单通道 Inception、单通道 DLSTM 和 Inception-DLSTM 双通道这 3 种模型下,各自的损失与诊断准确率随着迭代次数改变的曲线图,如图 6 和 7 所示。

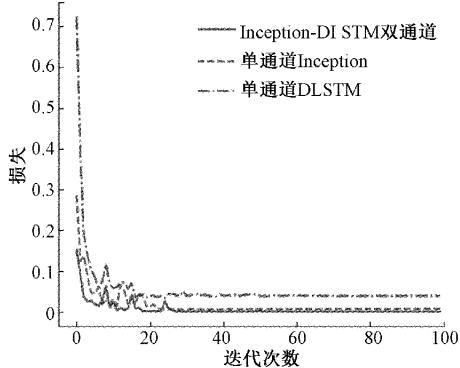


图 6 测试集损失变化曲线

由图 6 可知,在首次迭代时,测试集的损失在 Inception-DLSTM 双通道中最低,在单通道 DLSTM 中最大。随着训练迭代次数增多,这 3 种模型各自的测试集损失值大幅度降低,但都存在一些波动。虽然单通道 Inception 和 Inception-DLSTM 双通道大约都经过 25 次迭

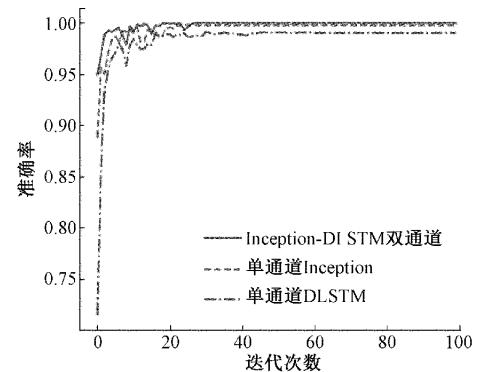


图 7 测试集识别准确率变化曲线

代之后损失值逐渐稳定,但是单通道 Inception 的损失稳定值高于 Inception-DLSTM 双通道,而单通道 DLSTM 的损失稳定值最高。

在图 6 的基础上,结合图 7 可知,3 种模型的损失值趋于稳定之后,识别准确率随之趋于稳定,最终双通道 Inception-DLSTM 的故障诊断准确率达到 100%,而单通道 Inception 和单通道 DLSTM 的准确率分别为 99.89% 和 99.24%,由此可见,Inception-DLSTM 双通道的滚动轴承故障诊断效果优于单通道的 Inception 和 DLSTM 模型。

为了观察 3 种模型对 10 种滚动轴承故障状态的具体诊断情况,以混淆矩阵的形式输出测试集的诊断结果,如图 8 所示。

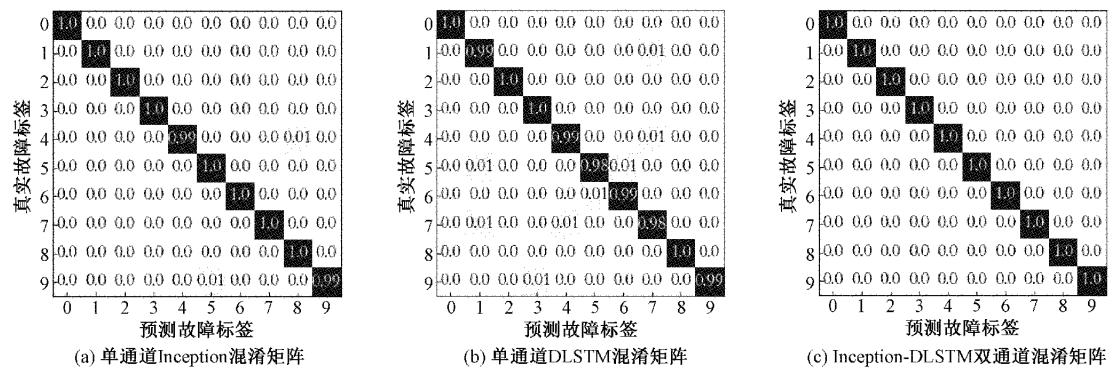


图 8 3 种模型的故障诊断结果混淆矩阵

由图 8 可以看出,单通道 Inception 对标签 4 和标签 9 对应的滚动轴承故障不能百分百诊断准确,会有少数样本被错误地诊断为其他故障,同时单通道 DLSTM 对标签 1、标签 4、标签 5、标签 6、标签 7 和标签 9 中少量的故障样本也会诊断错误,而 Inception-DLSTM 双通道对每种标签都能百分百诊断准确,说明 Inception-DLSTM 双通道能够充分提取故障的时间和空间特征,根据不同滚动轴承故障特征的不同,百分百实现滚动轴承故障诊断。

4.2 实验结果可视化分析

常用的降维算法有主成分分析^[17](principal component analysis, PCA) 和 t 分布邻域嵌入^[18](t-distributed

stochastic neighbor embedding, t-SNE) 两种,其中 PCA 倾向于保存全局特征,而 t-SNE 倾向于保存局部特征,因此先采用 PCA 分别对 3 种模型的 Softmax 层的前一层提取到的高维特征降成 9 维,在此基础上,利用 t-SNE 降为 2 个维度进行可视化分析,以此验证 Inception-DLSTM 双通道模型是否具备更加优异的特征提取能力,结果如图 9 所示,图中椭圆所圈为不同特征重叠混淆区域。

由图 9 可以看出,单通道 Inception 提取的特征中,有两种标签的少量特征与其他标签特征区域重叠,从而造成故障诊断错误,与单通道 Inception 混淆矩阵结果一致;单通道 DLSTM 的特征混淆的种类和数量更多,结果也与单

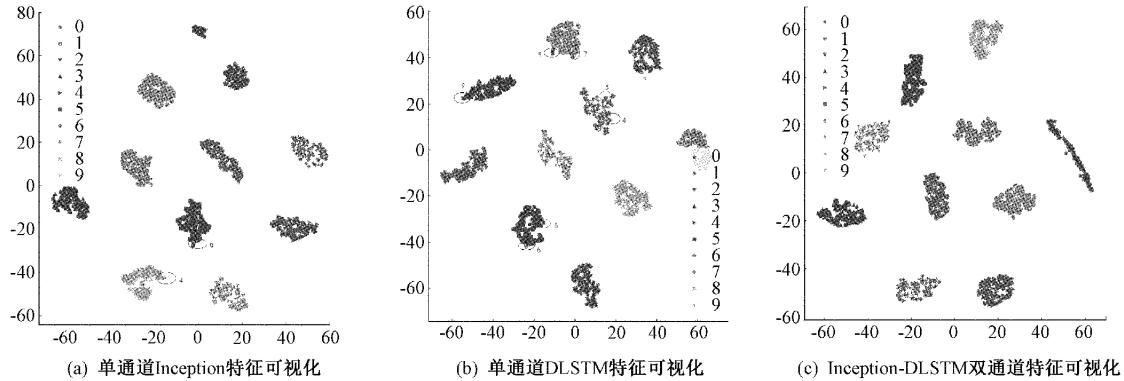


图 9 3 种模型的特征可视化

通道 DLSTM 混淆矩阵一致；而 Inception-DLSTM 双通道的各标签的特征分布区域明显，无重叠区域，各标签类间距大，说明 Inception-DLSTM 双通道具备良好的特征提取能力，可以有效提取各种滚动轴承故障包含的空间特征和时间特征。

4.3 与其他模型的对比分析

在同样数据集和同种条件下，搭建了 1DCNN、LSTM、1DCNN-LSTM、2DCNN、2DCNN-LSTM、2DCNN-1DCNN 双通道^[6] 和 1DCNN-BiLSTM 双通道^[19] 7 种模型，与 Inception-DLSTM 双通道模型进行对比分析，不同模型下测试集的准确率如表 4 所示。

表 4 不同模型测试集诊断结果

输入	实验模型	准确率/%
振动信号	1DCNN	99.07
振动信号	LSTM	98.34
振动信号	1DCNN-LSTM	99.26
时频图	2DCNN	99.85
时频图	2DCNN-LSTM	99.88
时频图+振动信号	2DCNN-1DCNN 双通道	99.69
振动信号+振动信号	1DCNN-BiLSTM 双通道	99.88
时频图+振动信号	Inception-DLSTM 双通道	100

由表 4 可知，相比于只用单一 CNN 或者 LSTM 模型，在 CNN 提取故障特征之后，再利用 LSTM 进一步提取特征，这种 CNN-LSTM 串联式模型可以提高故障诊断准确率，但是仍然不能达到百分百诊断准确；再对比 3 种双通道模型可知，2DCNN-1DCNN 双通道的准确率最低，而 Inception-DLSTM 双通道的准确率最高，达到 100%，说明 Inception-DLSTM 双通道具备良好的故障诊断能力。

5 结 论

为了实现滚动轴承故障诊断，提出了一种 Inception-DLSTM 双通道的轴承状态识别模型，通过实验分析得到以下结论：

Inception 通道多尺度地提取轴承振动信号空间特征，而 DLSTM 通道深层次提取轴承振动信号时间特征，采用并联式的双通道模型，可以把两种网络的优势有机结合，能够充分提取滚动轴承故障的空间和时间特征。

与其他模型相比，Inception-DLSTM 双通道模型具备最高的滚动轴承故障识别准确率，可达 100%，体现了该方法良好的诊断性能。

下一步的工作将针对测试集中包含未知故障类型的情况，进行故障诊断，即开放集域适应(Open Set Domain Adaptation)类型的滚动轴承故障诊断，更加符合现实诊断需求。

参 考 文 献

- [1] 简定辉, 李萍, 黄宇航, 等. 基于 CNN-LSTM 网络的短期电力负荷预测[J]. 电工电气, 2022(9): 1-6.
- [2] LIU R, MENG G, YANG B, et al. Dislocated time series convolutional neural architecture: An intelligent fault diagnosis approach for electric machine[J]. IEEE Transactions on Industrial Informatics, 2017, 13(3): 1310-1320.
- [3] 杨劫立, 林建辉, 谌亮. 基于 MED 辅助特征提取 CNN 模型的列车轴承故障诊断方法[J]. 中国测试, 2020, 46(10): 124-129.
- [4] 陈里里, 付志超, 凌静, 等. 基于 WPD-CNN 二维时频图像的滚动轴承故障诊断[J]. 组合机床与自动化加工技术, 2021(3): 57-60, 65.
- [5] LIU H, MI X, LI Y. An experimental investigation of three new hybrid wind speed forecasting models using multi-decomposing strategy and ELM algorithm[J]. Renewable Energy, 2018, 123: 694-705.
- [6] 齐爱玲, 李琳, 朱亦轩, 等. 基于融合特征的双通道 CNN 滚动轴承故障识别[J]. 机械与电子, 2021, 39(5): 15-19.
- [7] LI X, KONG X, ZHANG J, et al. A study on fault diagnosis of bearing pitting under different speed condition based on an improved inception capsule

- network[J]. Measurement, 2021, DOI: 10.1016/j.measurement.2021.109656.
- [8] 张龙,甄灿壮,易剑昱,等.双通道特征融合 CNN-GRU 齿轮箱故障诊断[J].振动与冲击,2021,40(19): 239-245.
- [9] HAO S, GE F X, LI Y, et al. Multisensor bearing fault diagnosis based on one-dimensional convolutional long short-term memory networks[J]. Measurement, 2020, DOI:10.1016/j.measurement.2020.107802.
- [10] SHI H, GUO L, TAN S, et al. Rolling bearing initial fault detection using long short-term memory recurrent network[J]. IEEE Access, 2019, 7: 171559-171569.
- [11] 段桂英,姜洪开.基于数据融合驱动和 DLSTM 网络的轴承 RUL 预测[J].计算机应用与软件,2021,38(12): 22-29.
- [12] 黄驰城.结合时频分析和卷积神经网络的滚动轴承故障诊断优化方法研究[D].杭州:浙江大学,2019.
- [13] 韩宇,李剑,马慧宇,等.基于 CNN-LSTM 的桥梁结构损伤诊断方法[J].国外电子测量技术,2021,40(7): 1-6.
- [14] JIN M, CHEN Q, YAN S. Network In Network[J]. ArXiv Preprint, 2013, ArXiv:10.48550.1312.
- [15] GAL Y, GHAHRAMANI Z. Dropout as a bayesian approximation: Representing model uncertainty in deep learning[C]. CoRR,2015,DOI:10.48550/arXiv.1506.02142.
- [16] 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.
- [17] 李元,张昊展,唐晓初.基于多模态数据全信息的概率主成分分析故障检测研究[J].仪器仪表学报,2021,42(2): 75-85.
- [18] 王辉,徐佳文,严如强.基于深度宽卷积 Q 网络的行星齿轮箱故障智能诊断方法[J].仪器仪表学报,2022,43(3): 109-120.
- [19] 刘志,彭成,满君丰,等.引入自注意力机制的 1DCNN-BiLSTM 模型及其在滚动轴承故障诊断中的应用[J].信息与电脑(理论版),2021, 33(23): 80-83.

作者简介

范志伟,硕士研究生,主要研究方向为机械故障诊断、深度学习、图像处理等。

E-mail:2151816612@qq.com

郭世伟(通信作者),博士,副教授,主要研究方向为机电设备测控技术、机械动力学分析、机械故障诊断等。

E-mail:732734691@qq.com

罗鑫,硕士研究生,主要研究方向为机械故障诊断、深度学习、图像处理等。

刘应桃,硕士研究生,主要研究方向为图像处理,深度学习等。

付孟新,硕士研究生,主要研究方向为图像处理,深度学习等。