

控制与决策

Control and Decision

基于深度在线迁移的变负载下滚动轴承故障诊断方法

康守强, 刘旺辉, 王玉静, 王庆岩, Mikulovich V I

引用本文:

康守强, 刘旺辉, 王玉静, 王庆岩, Mikulovich V I. 基于深度在线迁移的变负载下滚动轴承故障诊断方法[J]. 控制与决策, 2022, 37(6): 1521–1530.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1686>

您可能感兴趣的其他文章

Articles you may be interested in

改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

基于DLSR的归纳式迁移学习

DLSR based inductive transfer learning method

控制与决策. 2021, 36(12): 2982–2990 <https://doi.org/10.13195/j.kzyjc.2020.0703>

迁移学习引导的变源域长短时记忆网络建筑负荷预测

Load forecasting of buildings using LSTM based on transfer learning with variable source domain

控制与决策. 2021, 36(10): 2328–2338 <https://doi.org/10.13195/j.kzyjc.2020.0215>

考虑退化轨迹差异性与相似性的轴承RUL预测

Prediction of bearing remaining useful life involving difference and similarity of degradation trajectories

控制与决策. 2021, 36(11): 2832–2840 <https://doi.org/10.13195/j.kzyjc.2020.1028>

基于深度在线迁移的变负载下滚动轴承故障诊断方法

康守强¹, 刘旺辉¹, 王玉静^{1†}, 王庆岩¹, Mikulovich V I²

(1. 哈尔滨理工大学 电气与电子工程学院, 哈尔滨 150080; 2. 白俄罗斯国立大学, 明斯克 220030)

摘要: 针对变负载条件下滚动轴承源域与目标域中相同状态的数据特征分布差异性较大, 目标域数据按照序列方式在线获取时, 数据更新需重新训练模型的问题, 提出一种深度在线迁移的 CNN-ISVM (convolutional neural networks-incremental support vector machine) 变负载下滚动轴承故障诊断方法. 该方法运用短时傅里叶变换得到不同负载下滚动轴承振动信号的频谱图并构建数据集; 使用源域数据建立 CNN-ISVM 预训练模型并保存模型参数; 利用迁移学习将源域共享模型参数迁移至目标域 CNN-ISVM 模型训练过程中, 快速建立分类模型; 分类模型中的 ISVM 分类器在保留已学到知识的基础上, 在线处理目标域新增数据, 无需重新训练. 经实验验证, 所提出方法可实现数据按照序列方式采集的变负载下滚动轴承多状态在线分类, 并具有较好的稳定性及较高的准确率.

关键词: 滚动轴承; 迁移学习; 在线学习; 增量支持向量机; 卷积神经网络; 故障诊断

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1686

开放科学(资源服务)标识码(OSID):



引用格式: 康守强, 刘旺辉, 王玉静, 等. 基于深度在线迁移的变负载下滚动轴承故障诊断方法[J]. 控制与决策, 2022, 37(6): 1521-1530.

Fault diagnosis method of rolling bearing under varying loads based on deep online transfer

KANG Shou-qiang¹, LIU Wang-hui¹, WANG Yu-jing^{1†}, WANG Qing-yan¹, Mikulovich V I²

(1. School of Electrical and Electronic Engineering, Harbin University of Science and Technology, Harbin 150080, China; 2. Belarusian State University, Minsk 220030, Belarus)

Abstract: For the problem that the data feature distribution of the same state in the source domain and target domain of rolling bearing is quite different under varying loads, and the model needs to be retrained for data update when the target domain data is obtained online in a sequential manner, a fault diagnosis method of rolling bearing under varying loads with the deep online transfer CNN-ISVM (convolutional neural networks-incremental support vector machine) is proposed. Short time Fourier transform is used to obtain the time-frequency spectrum of rolling bearing vibration signals under different loads, and the data sets can be constructed; the source domain data is used to build the CNN-ISVM pre-training model, and the model parameters are saved; transfer learning is used to transfer the source domain shared parameters to the target domain CNN-ISVM model training process to quickly establish the classification model; the ISVM classifier in the classification model retains the learned knowledge and processes the new data in the target domain online without being retrained. The experimental results verify that the proposed method can realize multi-state online classification of rolling bearings under varying loads with data collected in a sequential manner, and has better stability and higher accuracy.

Keywords: rolling bearing; transfer learning; online learning; incremental support vector machine; convolutional neural network; fault diagnosis

0 引言

滚动轴承作为工业生产设备中的关键零部件, 一旦发生故障, 将直接影响整台机械设备的运行^[1]. 滚动轴承在变负载条件下, 其运行状态复杂多

变, 数据特征分布差异性较大. 实际中, 目标域数据采集往往按照序列方式在线获取, 无法满足训练数据在模型训练过程中的完备性假设, 这对现有的迁移学习方法提出了新的挑战^[2]. 因此, 开展变负载下滚动轴

收稿日期: 2020-12-04; 录用日期: 2021-03-29.

基金项目: 国家自然科学基金项目(51805120); 黑龙江省自然科学基金项目(LH2019E058); 黑龙江省普通高校基本科研业务专项资金项目(LGYC2018JC022).

责任编辑: 方华京.

[†]通讯作者. E-mail: mirrorwyj@163.com.

承多状态在线故障诊断工作,具有重要研究意义。

随着机器学习研究的不断深入,基于人工智能的数据驱动方法成为故障诊断领域研究的热点^[3]。其中比较有代表性的支持向量机(support vector machine, SVM)、反向传播神经网络和极限学习机已被广泛应用于故障诊断,并取得了较好的效果^[4-5]。虽然数据驱动的诊断方法在旋转机械的故障诊断中取得了显著的成绩,但固有的局限性仍然存在,较浅的网络结构导致难以挖掘和提取故障数据中更深层次的特征^[6],从而限制了诊断准确率的进一步提升。

近年来,深度学习理论逐渐成为机器学习领域中炙手可热的学习算法,其在机械智能故障诊断领域也受到越来越多的关注^[7]。卷积神经网络(convolutional neural networks, CNN)是应用于故障诊断最有效的深度学习方法之一, CNN强大的特征提取能力具备识别深层故障特征的潜力,克服了传统智能诊断方法中的固有缺陷。文献[8]将时域信号转变为时频图像,使用改进的CNN自适应提取图像特征并进行分类,获得了较高的故障诊断准确率。文献[9]将振动信号转换为频谱图输入到全卷积神经网络中,可准确识别出轴承故障位置及损伤程度,并具有较好的泛化性。文献[10]通过使用粒子群优化算法设置CNN超参数,针对不同轴承数据集进行有效诊断。由上述文献分析可知,基于深度学习的故障诊断方法能够有效地识别滚动轴承的健康状况。但在实际的工业生产中,滚动轴承常处于变负载的工作状态,相对于恒定负载,变负载下的滚动轴承振动特性更复杂。深度学习对于不同负载情况下的故障诊断普适性较差^[11],这限制了深度学习在变负载情况下的应用。

迁移学习放宽了传统机器学习中的两个基本假设,运用已有的知识解决不同但相关领域的问题,是一种新的机器学习方法^[12]。其中基于模型参数的知识迁移方法是从源域和目标域中找到共享的参数信息,通过参数传递实现迁移。如何利用深度神经网络进行有效的知识迁移成为学者们思考的问题,深度迁移学习方法在旋转机械故障诊断领域已崭露头角。文献[13]提出一种机械装备故障的深度迁移诊断方法,通过实验台滚动轴承数据进行知识迁移,识别出机车轴承的健康状态。文献[14]提出一种通用的轴承故障诊断模型,通过模型参数迁移的方法有效减少训练时间,取得了较好的效果。文献[15]提出一种深度迁移的非负约束稀疏自动编码器,利用参数传递解决带标签数据稀缺的滚动轴承故障诊断问题,具有较好的效果。

上述离线训练方式的深度迁移方法虽能较好解决变负载下的故障诊断问题,但应用的一个重要假定是目标域数据的可用性,即在识别模型建立前已准备好全部目标域数据。然而实际情况中,数据的在线获取导致待分类目标域的数据按照序列方式到达,无法满足目标域数据在模型训练过程中的完备性假设,因此,离线训练方式的深度迁移学习算法将不再适用。

在线学习的引入为解决上述问题提供了一种新思路。在线学习在保留绝大多数历史知识的前提下,不断地从新样本中学习新知识,使得更新后的知识适应新到达的样本。在线学习在很多领域都展示了它的有效性,如图像识别、语音识别和人机交互等领域。文献[16]提出目标域数据以在线方式接收,并利用来自多个源域的知识进行迁移学习,通过实验验证了该方法在图像分类中具有较高的准确率。文献[17]提出一种基于在线学习的非负卷积语音信号识别方法,其效果优于离线式识别方法。在线学习可以改进一些传统方法,例如极限学习机、在线随机森林和增量支持向量机(incremental support vector machine, ISVM)等以获得在线学习的能力。其中ISVM就是充分利用历史训练结果,即原始分类面和原始支持向量(support vector, SV)集,在不断学习过程中,选择最有可能成为新SV的样本,舍弃对分类结果没有太大贡献的历史样本,从而达到加快训练速度,减少存储空间的目的,同时也保证了良好的分类精度^[18]。

短时傅里叶变换(short time Fourier transform, STFT)是在傅里叶变换基础上发展而来的,是一种时-频分析方法,可同时反映出信号的时域和频域信息,被广泛应用于非平稳信号的研究^[19]。

针对变负载条件下滚动轴承振动数据特征分布差异性较大,目标域数据的在线获取与识别问题,本文提出一种深度在线迁移学习的故障诊断方法。该方法首先将原始时域振动信号作STFT处理,构建二维频谱数据集;然后使用源域数据训练源域CNN-ISVM模型,得到源域分类模型,保存模型参数并将模型共享参数迁移至目标域CNN-ISVM训练过程中,加速模型建立;最后通过在线数据对目标域CNN-ISVM模型中的ISVM分类器进行更新和修正,实现变负载下滚动轴承多状态在线识别。

1 深度在线迁移的CNN-ISVM算法

1.1 传统CNN网络

CNN是一种专门用于处理具有类网状结构数据的典型前馈神经网络,其本质是构建多个能够提取数据特征的滤波器,并运用这些滤波器对输入数据进行

逐层卷积和池化,提取蕴含在输入数据中的鲁棒特征.典型的CNN网络通常包含输入层、卷积层、池化层、全连接层和输出层.在CNN的前期特征提取算法中,通过利用交替的卷积层和池化层对输入数据进行层层提取特征,接近输出层则采用普通多层神经网络.在卷积层中,利用前一层的输出与多个卷积核卷积并生成特征映射,通过激活函数构建输出特征矢量.其数学模型描述为

$$y_i^{l+1}(j) = \sigma(\mathbf{K}_i^l * x^l(j) + b_i^l). \quad (1)$$

其中: \mathbf{K}_i^l 、 b_i^l 分别表示 l 层第 i 个卷积核的权重与偏置, $*$ 代表卷积运算, σ 为激活函数, $x^l(j)$ 为 l 层第 j 个神经元, 输出 $y_i^{l+1}(j)$ 为卷积核 \mathbf{K} 在输入 $x^l(j)$ 上学习到的特征.

线性修正单元(ReLU)被广泛用作激活函数以缓解神经网络的过拟合问题. ReLU的公式为

$$z_i^{l+1}(j) = \sigma(y_i^{l+1}(j)) = \max\{0, y_i^{l+1}(j)\}, \quad (2)$$

其中 $z_i^{l+1}(j)$ 为 $y_i^{l+1}(j)$ 经过激活函数得到的激活值.

池化层是对上一层数据的缩放映射,池化能够提取每个特征映射中最重要局部信息,并通过该操作可以显著减小特征维度.本文选取实际中广泛使用的最大池化作为池化方式,池化长度为 N ,在卷积层与池化层中,所有操作的滑动步长皆为1.池化层的输入为卷积层生成的特征映射,即

$$p_i^{l+1}(j) = \max_{(j-1)N+1 \leq t \leq jN} \{z_i^l(t)\}. \quad (3)$$

其中: $z_i^l(t)$ 表示第 l 层第 i 个特征矢量中第 t 个神经元的值, $t \in [(j-1)N+1, jN]$, N 为池化区域的长度; $p_i^{l+1}(j)$ 表示第 $l+1$ 层第 j 个神经元所对应的池化值.

全连接层通常会与 Softmax 组合使用来完成分类任务.具体过程是,将最后一个池化层的输出展平为一维特征向量并作为全连接层的输入,其公式描述为

$$u_j^{l+1} = \sigma\left(\sum_{i=1}^n \mathbf{W}_{ij}^l z_j^l + b_j^l\right). \quad (4)$$

其中: \mathbf{W}_{ij}^l 为第 l 层第 i 个神经元与第 $l+1$ 层第 j 个神经元之间的权值, b_j^l 为第 l 层所有神经元对第 $l+1$ 层第 j 个神经元的偏置, u_j^{l+1} 为第 $l+1$ 层第 j 个神经元的输出, $\sigma(*)$ 为激活函数.

Softmax 回归函数是 Logistic 分类器的推广,主要用于多分类问题.类标签 y 具有向量形式,表明当前样本的类别在所有可能类别中的分布概率. Softmax 回归模型的损失代价函数可以表示为

$$J(\theta) = -\frac{1}{n} \left[\sum_{i=1}^n \sum_{t=1}^k I\{y_i = t\} \lg \frac{e^{\theta_t^T x_i}}{\sum_{l=1}^k e^{\theta_l^T x_i}} \right]. \quad (5)$$

其中: (x_i, y_i) 是训练样本; $y_i \in \{1, 2, \dots, k\}$ 为样本所属类别; n 为样本个数; $I\{\cdot\}$ 为逻辑指示函数,当大括号内的值为真时, $I = 1$, 否则 $I = 0$; θ 为训练模型参数集,用于最小化当前代价函数.

1.2 ISVM算法

SVM是一种结构风险最小化模型,广泛应用于分类和回归任务. ISVM是在SVM的基础上提出的,其核心思想是随着在线数据逐步训练一个模型,将其训练过的数据全部丢弃,仅保留作为SV的数据,这些SV将加入下一次循环训练. SV参数优化的准则为搜索支持向量的 Karush-Kuhn-Tucker (KKT) 条件,以下对 ISVM算法^[20]进行简要描述.

给定训练数据集为 $\{(x_i, y_i)\}, i = 1, 2, \dots, n, x_i \in \mathbf{R}^n, y_i \in \{+1, -1\}$. 标准的SVM分类问题可表述为下列求最优问题:

$$\begin{aligned} \min_{\omega, b, \xi} \quad & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i. \\ \text{s.t.} \quad & y_i(\omega \cdot x_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, n; \\ & \xi_i \geq 0, \quad i = 1, 2, \dots, n. \end{aligned} \quad (6)$$

其中: ξ_i 为松弛变量, C 为惩罚系数. 引入拉格朗日系数 α_i , 将上述优化问题转化为如下的对偶形式:

$$\min W = \frac{1}{2} \sum_{i,j=1}^n \alpha_i Q_{ij} \alpha_j - \sum_{i=1}^n \alpha_i + b \sum_{i=1}^n y_i \alpha_i. \quad (7)$$

其中: $Q_{ij} = y_i y_j K(x_i, y_j)$, $K(\cdot, \cdot)$ 为核函数运算.





图1 ISVM在线学习过程

KKT条件是求解上述优化问题的充要条件,受KKT条件的影响,训练样本分为3类:正确向量(R)、支持向量(S)和错误向量(E),取决于 α_i 与 C 之间的关系,如图1所示。

在线学习过程中,当新样本 x_c 加入到训练集时,不必重新训练,新的SV系数以及分类模型将以如下形式进行更新,使得上述KKT条件重新得到满足:

$$\begin{aligned} \Delta b &= \beta \Delta \alpha_c; \\ \Delta \alpha_j &= \beta_j \Delta \alpha_j, \forall j \in (S \cup E \cup R); \\ \Delta g_i &= \gamma_i \Delta \alpha_c. \end{aligned} \quad (8)$$

最终可以得到新的最优分类超平面,SVM的判决函数为

$$f(x) = \text{sgn}\left(\sum_{i=1}^n \alpha_i y_i K(x_i \cdot x) + b\right). \quad (9)$$

1.3 在线迁移的CNN-ISVM算法

在传统CNN网络中,判别输出层通常由一个全连接层与Softmax分类器组合构成,Softmax分类器实质上是对最终的分类结果做一次符合概率分布的

归一化操作,其在多分类性能上尚不如SVM功能强大.然而SVM存在对深层特征提取和数据挖掘能力不足^[21],以及新样本添加后需要重新训练分类器的问题.因此,本文将迁移学习所具备的减小数据分布差异、提高训练效率的能力与ISVM在线处理新增数据的优越性相结合,提出一种在线迁移的CNN-ISVM算法。

本文所提出的算法基本结构如图2所示,由输入层、特征提取层和分类判别输出层组成.其中:特征提取层包含多个依次循环堆叠的卷积层和池化层,接收来自输入层的振动数据,利用卷积层中的多个卷积核实现对振动信号的特征提取,得到多个特征矢量;最大池化算子实现对特征矢量的维数约简,同时提高非线性特征的鲁棒性;交替的多个卷积池化层实现对输入信号非线性特征的层级式提取;全连接层实现对特征的“展平”操作,即将所有特征矢量首尾连接组成一维向量,并将该一维向量作为ISVM的输入特征向量.分类输出层接收来自特征提取层的一维向量,利用ISVM分类器实现目标输出类别。




图2 CNN-ISVM算法基本结构

2 在线迁移的CNN-ISVM滚动轴承多状态识别方法

不同负载情况下,滚动轴承正常、内圈、外圈和滚动体故障及不同故障程度的多状态在线识别方法流程如图3所示.具体流程步骤如下。

1) 数据预处理。

获取离线状态某些负载情况下滚动轴承振动信号作为源域.在线获取其他负载情况下滚动轴承振动信号作为目标域.对轴承原始时域振动信号中的源域数据(离线数据)和目标域数据(在线数据)做STFT,构建二维图像源域数据集和目标域数据集。

2) 源域CNN-ISVM预训练模型。

离线训练阶段,将处理好的源域数据集输入到网络中.首先,通过Softmax函数进行误差反向传播最小化损失函数 $J(\theta)$,完成CNN模型参数的训练;其次,用训练好的CNN模型对输入数据进行特征提取,将全连接层1中提取到的特征向量和对应标签输入给ISVM完成训练;最后,保存源域CNN-ISVM预训

练模型参数,并将卷积层及全连接层1的参数冻结。

3) 目标域CNN-ISVM模型在线更新。

在线更新阶段,将步骤2)中冻结的源域CNN-ISVM模型参数迁移至目标域CNN-ISVM模型.当目标域训练数据输入到网络时,利用目标域CNN模型进行特征提取,将该数据提取到的特征向量输入给ISVM分类器,ISVM分类器将得到的预测值与其真实值进行比对,判断该特征向量是否违背KKT条件.若违背,则需构造满足该特征向量和SV集合的新超平面,以此更新ISVM分类器;否则完成目标域CNN-ISVM模型更新.将目标域中实际测试/诊断数据输入至模型中,完成故障分类,输出故障诊断结果。

3 实验分析

3.1 实验数据

为验证本文所提出算法的有效性和准确性,采用美国凯斯西储大学的轴承数据集进行实验验证^[22],数据由加速度传感器在4种负载条件下采集,采样频率为12 kHz。

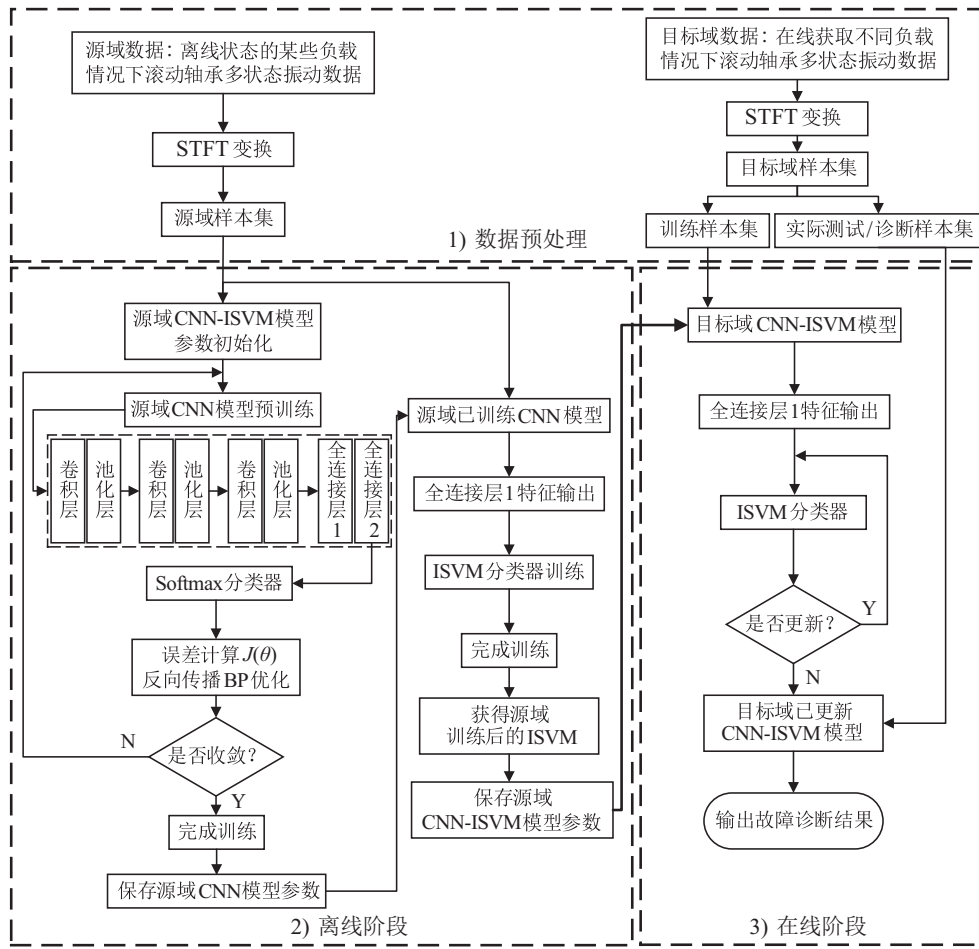


图3 在线迁移CNN-ISVM模型的滚动轴承多状态识别方法流程

负载类型包括0hp、1hp、2hp和3hp,根据负载的不同,电机转速在1730rpm与1797rpm之间变化.每种负载下均包含正常状态(N)以及内圈故障(IR)、外圈故障(OR)、滚动体故障(B)的3种故障损伤程度,损伤直径分别为0.1778mm、0.3556mm、0.5334mm.正常状态下滚动轴承没有发生损伤,因此,没有故障部位及故障损伤程度.对滚动轴承的正常状态,内圈、外圈、滚动体故障以及不同故障损伤程度10种

状态进行分类.以0hp为例,实验数据的表示方法如表1所示.

表1 实验数据表示方法

故障程度/mm	内圈故障	外圈故障	滚动体故障
0.1778	IR07	OR07	B07
0.3556	IR14	OR14	B14
0.5334	IR21	OR21	B21

表2 实验数据集组成

任务编号	源域/hp	目标域/hp	源域样本数/个	目标域样本数/个	
				训练样本数	实际测试/诊断样本数
1	2	1	2000	2000	600
2	2	3	2000	2000	600
3	0	2	2000	2000	600
4	1	2	2000	2000	600
5	1	3	2000	2000	600
6	3	2	2000	2000	600
7	23	01	4000	4000	1200
8	02	13	4000	4000	1200
9	12	03	4000	4000	1200
10	13	02	4000	4000	1200
11	3	012	2000	4000	1200
12	2	013	2000	6000	1800

本文共设置12组实验数据集,分别使用某些负载下10种状态数据作为源域数据集,其他负载下10种状态数据作为目标域数据集.目标域数据集包括训练数据集和实际测试/诊断数据集,具体数据集组成如表2所示.以任务1为例进行说明,源域数据集为2hp的2000个样本;目标域训练样本集为1hp的2000个样本,目标域实际测试/诊断数据集为1hp的600个样本,用来验证模型性能.其他任务设置同理.

3.2 在线迁移的CNN-ISVM模型结构及参数设置

为实现对滚动轴承不同故障位置及不同故障程度的智能识别,建立CNN-ISVM模型.以启发的方式设置CNN模型的超参数,采用ReLU函数作为激活函数,减少过拟合现象;为了控制网络的学习率,使用Adam优化算法更新网络参数,学习率设置为0.001;在全连接层引入Dropout正则化方法,避免过度拟合训练数据,速率为0.5;CNN模型超参数设置如表3所示.

表3 CNN网络超参数设置

名称	结构参数	输出尺寸	激活函数
输入层	224×224	—	—
卷积层1	8@3×3	222×222×8	ReLU
池化层1	2×2	111×111×8	—
卷积层2	16@3×3	109×109×16	ReLU
池化层2	2×2	55×55×16	—
卷积层3	32@3×3	53×53×32	ReLU
池化层3	2×2	27×27×32	—
全连接层1	—	512×1	ReLU
全连接层2	—	10×1	ReLU
Softmax层	—	10×1	Softmax

经实验验证,ISVM采用线性核函数,惩罚系数 $C = 1$ 可获得最佳的实验效果.为减少随机初始化训练参数及实验不确定因素对滚动轴承故障诊断结果的影响,每组实验重复验证5次取均值.实验环境硬件配置CPU: Intel Xeon E5-2620 v4;内存: 64 GB; GPU: NVIDIA GTX1080Ti.

3.3 在线迁移学习实验

3.3.1 在线新增故障类型数据实验

对目标域训练数据集10种故障类型数据进行设置,以模拟在线学习过程中新增故障类型数据的情况,具体设置见表4.

任务1、任务7和任务12分别代表表2中1种、2种和3种负载种类组成的目标域训练数据集,每种负载下初始选择5种故障类型共计1000个样本,逐次新增一种故障类型样本,新增故障类型样本为200个,直到包含10种故障类型数据,实验结果如图4所示.

表4 新增故障类型数据设置

故障类型种类	样本量/个		
	任务1	任务7	任务12
5	1000	2000	3000
6	1200	2400	3600
7	1400	2800	4200
8	1600	3200	4800
9	1800	3600	5400
10	2000	4000	6000




图4 新增故障类型实验结果

由图4可知,本文所提出方法能在保留现有故障类型知识的基础上,对新增故障类型进行学习,更新目标域模型,随着目标域模型学习到的故障类型知识越来越全面,准确率逐步提升,最终得到具有较高准确率的故障诊断模型.其他任务也可得到类似的实验结果.

3.3.2 在线新增数据样本实验

为验证本文所提出CNN-ISVM方法具有处理在线新增数据的能力,将目标域训练数据集作为在线数据进行处理.将在线数据分批地输入到模型中进行训练,模拟在线学习过程中新增数据样本的情况,具体设置见表5.

表5 任务1在线数据集设置

在线数据集	在线数据集百分比/%	在线数据集样本量/个	目标域训练集样本总量/个
第1组	10	200	2000
第2组	30	200→600	2000
第3组	60	600→1200	2000
第4组	100	1200→2000	2000

以表5任务1为例进行说明,其余任务设置同理.目标域训练集总量为包含10种故障状态的2000个样本,将其按照不同比例划分为4组在线数据集,以模拟在线数据增加过程.第1组在线数据集样本量为总量的10%,即200个样本;第2组在线数据集样本量为总量的30%,即从200个样本增加至600个样本;其余组别以此类推.递增的4组在线数据集分别作为CNN-ISVM的输入进行实验,实验结果如图5~图7所示.




图5 在线学习准确率




图6 在线学习消耗时间




图7 在线学习SV数量

任务1是以2hp作为源域,1hp作为目标域的在线迁移变负载下故障诊断实验,采用2hp的2000个样本构建预训练模型,利用1hp设定的在线数据集进行更新目标域模型,最终完成在线迁移的变负载下故障诊断.图5较为直观地反映了随着在线数据集百分比的增加,本文方法的实验准确率不断上升的过程.在线数据集由10%增加到100%,任务1的实验准确率从97.17%逐渐增加到98.67%并趋于平稳,说明随着在线数据获取增多,模型学习到的故障特征更为充分,准确率有所增加.且任务1的实验准确率未出现较大的波动,说明本文方法具有较好的稳定性.同理,其他任务也可得到类似结论.

图6表示不同百分比在线数据集更新模型时间,由图6任务1可知,在线数据集百分比由30%增加至60%时,更新ISVM只需1.83s而不需重新训练模型,在保证较高准确率的前提下,节约了时间成本,提高了故障诊断的效率.同理,其他任务也可得到类似结论.

图7表示随着在线数据集百分比增加,学习到的SV数量不断增加的过程.结合图5~图7可知,随着在线数据的获取逐渐增多,ISVM学习到的滚动轴承知识更为全面,构造ISVM所需的SV不断增加,模型

更新更复杂,所需时间略有增加,同时准确率也趋于平稳,因此,本文方法可有效实现变负载下滚动轴承在线故障诊断,准确率高且具有较好的稳定性.

为进一步验证CNN-ISVM算法的有效性,本文引用精确率和召回率对所提出算法进行评价.由于篇幅有限,本文仅以表2中任务6的实验结果进行计算,如表6所示.

表6 CNN-ISVM模型诊断结果评价

故障损伤程度	精确率	召回率
N	1.0000	1.0000
IR07	0.9833	1.0000
IR14	1.0000	0.9836
IR21	1.0000	1.0000
B07	1.0000	1.0000
B14	1.0000	1.0000
B21	1.0000	1.0000
OR07	1.0000	1.0000
OR14	1.0000	1.0000
OR21	1.0000	1.0000
平均值	0.9983	0.9983

从表6中可知,CNN-ISVM模型的故障识别精确率和召回率均为99.83%,充分说明本文所提出的CNN-ISVM方法具有较好的性能.为了更清楚直观地展示本文算法对故障误判的细节情况,本文使用多分类混淆矩阵对表6诊断结果进行量化分析,混淆矩阵比较全面地反映了滚动轴承在不同故障等级下的诊断正确率和误判数量,以及真实故障类型被误判为何种类型等信息,混淆矩阵如图8所示.

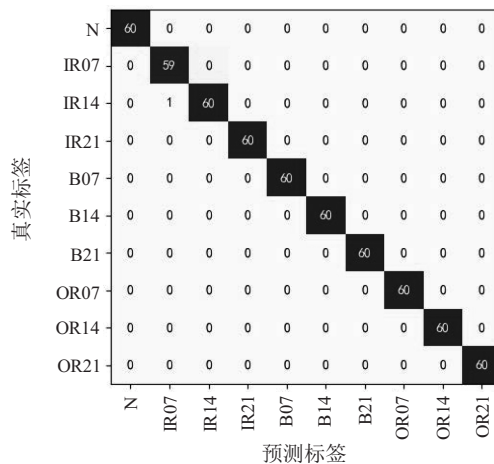


图8 滚动轴承故障分类混淆矩阵

从图8中明显可见,在测试集上的600个样本中只有1个样本被预测错误,被错判样本的真实标签为故障类型IR07,而预测类别为故障IR14,均为内圈故障.除此之外,其他类型故障的诊断准确率均为100%.

使用t-SNE^[23]维数约简算法对图8混淆矩阵结

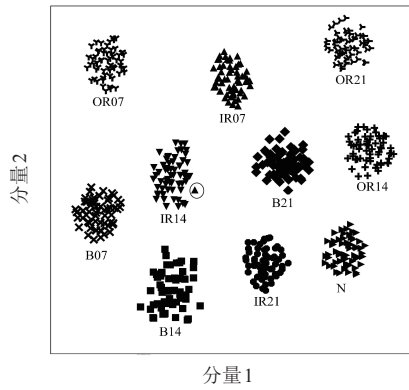


图9 t-SNE特征可视化

果进行特征可视化,如图9所示.可见,除IR14的样本含有部分异类外,其余样本均聚拢在相应的区域,与图8的结果相符,最终测试集上的整体识别率为99.83%.其他任务也可获得类似的实验结果.经实验验证,CNN-ISVM算法对滚动轴承故障具有优越的识别能力和较高的诊断准确率.

3.4 与其他方法对比实验

为更好验证所提出方法的效率,本文比较了3种方法的时间消耗及准确率,其中在线数据集的设定与表5一致,实验结果见表7.

表7 3种方法时间消耗及准确率对比

训练方式	方法	在线数据集百分比/%							
		训练时间/s				准确率/%			
		10	30	60	100	10	30	60	100
离线方式	方法1: CNN-Softmax	170.52	198.89	243.68	303.37	70.70	88.70	95.00	96.80
	方法2: CNN-SVM	171.33	202.72	248.38	309.35	96.67	98.17	98.33	98.33
在线方式	方法3: CNN-ISVM	171.88	1.65	1.83	2.07	97.17	98.17	98.33	98.67

实验中,方法1和方法2采用离线的训练方式,即每次重新训练模型来处理新增在线数据.方法3为在线训练方式,只需对新增在线数据部分进行更新模型.具体而言:方法1为CNN与Softmax组合进行反向传播优化训练CNN模型;方法2是将方法1训练好的CNN模型对故障数据进行特征提取后,再输入给SVM进行故障分类;方法3为本文提出的CNN-ISVM滚动轴承多状态识别方法.在准确率方面,方法3诊断准确率均高于方法1和方法2,说明CNN的提取深层特征能力与ISVM在多分类功能方面的优越性相结合,可获得较好的效果.在时间方面,方法2和方法3虽然在CNN的基础上,使用SVM和ISVM进行分类,但是,在建立模型所需时间上较方法1并未过多增加,而且方法3能在保留已学到的知识基础上继续处理新的样本,通过在线获取的新增样本对ISVM的知识进行更新与修正,并不需要重新建立模型来处理新增在线数据.由表7训练时间结果对比可知,在线数据集百分比由10%增加至100%时,方法1和方法2的总训练时间消耗各为916.46s和931.78s,而方法3只需177.43s,大约是方法2和方法3总时间的20%,极大减少了模型训练时间,从而表明本文方法具有较高的建模效率.

为了更好地验证本文方法的泛化能力,使用表2中全部实验数据集进行验证.通过对多组实验分析得出,方法1和方法2的平均测试准确率是94.53%和

97.79%,方法3的平均测试准确率为98.33%,较方法1和方法2均有提升.说明在更加复杂变负载的条件下,训练集和测试集的数据结构与分布存在较大的差异,CNN-ISVM模型能很好地适应数据分布的变化,模型的泛化性很好.这进一步说明,本文方法能在保证较高准确率的前提下,节约时间成本,提高故障诊断效率.

为进一步表明本文方法在变负载下滚动轴承在线故障诊断问题上具有明显的优势,选择ISVM、OS-ELM^[24]及文献[25]所提出的在线学习方法进行对比实验研究.其中ISVM和OS-ELM方法采用文献[26]的特征提取方法,提取10种时域特征和4种频域特征,再将所提取的特征输入诊断算法以完成故障诊断.实验过程中使用相同的源域和目标域数据集,时间对比结果见表8,准确率对比结果如图10所示.

表8 与其他在线学习方法的时间对比 单位: s

迁移任务	本文方法	ISVM	OS-ELM	文献[25]
任务1	6.91	4.04	3.60	102.73
任务2	5.79	3.87	4.32	103.81
任务7	15.47	5.53	8.04	171.14
任务10	14.12	5.46	8.62	169.40
任务11	29.14	9.65	12.82	226.27
任务12	30.41	10.87	14.13	234.28
平均值	16.97	6.57	8.59	167.94




图 10 与其他在线学习方法准确率对比

由表8可知,所提出方法在线学习的平均时间为16.97s,约为文献[25]的方法用时的10%,与其他对比学习方法相比,用时也仅增加了约10s.由图10可以看出,在不同迁移任务的在线学习中,对变负载下滚动轴承进行状态分类时,本文方法的平均准确率达到98.46%,相对于其他对比的在线学习方法,准确率大幅提升.进一步说明,本文方法能够保证在较短的学习时间前提下,提高识别准确率,可有效解决变负载下滚动轴承在线故障诊断,并具有更加优越的效果.

4 结论

1) 基于ISVM具有保留历史知识、能够处理在线新增数据的特点,本文提出了一种深度在线迁移CNN-ISVM的新方法.该方法只需对在线新增数据进行处理,更新现有模型,从而避免重新训练整个模型,极大地减少了模型训练时间和计算量.

2) 利用模型参数知识迁移,减小由于负载变化而引起的源域数据与目标域数据之间的分布差异,进而解决变负载下在线采集滚动轴承数据进行故障状态识别问题.实验表明,在处理相同数量的轴承数据时,本文方法所需模型训练的时间约为离线方法的20%,具有较高的建模效率.同时所提出方法在不同迁移任务下平均准确率较所对比的离线方法提升3.80%,较所对比的在线学习方法提升至少3.60%,表明本文方法具有良好的泛化性.而且在线学习耗时较短,表明本文方法在变负载下滚动轴承在线故障诊断问题上具有明显的优势.

3) 本文提出的深度在线迁移的CNN-ISVM算法可较好地解决变负载条件下的滚动轴承在线故障诊断,在保证较高识别准确率的基础上,提高了诊断效

率,这对滚动轴承在实际工作中故障的在线监测与快速诊断有着重要的指导意义.

下一步工作将在本文研究的基础上,研究基于CNN的深度迁移学习模型微调方法.同时,对实际中使用嵌入式微处理器完成实时故障诊断工作也需要进一步深入研究.

参考文献(References)

- [1] 曲建岭, 余路, 袁涛, 等. 基于卷积神经网络的层级化智能故障诊断算法[J]. 控制与决策, 2019, 34(12): 2619-2626.
(Qu J L, Yu L, Yuan T, et al. A hierarchical intelligent fault diagnosis algorithm based on convolutional neural network[J]. Control and Decision, 2019, 34(12): 2619-2626.)
- [2] Wang J Y, Mo Z L, Zhang H, et al. Ensemble diagnosis method based on transfer learning and incremental learning towards mechanical big data[J]. Measurement, 2020, 155: 107517.
- [3] Kang S Q, Chen W W, Wang Y J, et al. Method of state identification of rolling bearings based on deep domain adaptation under varying loads[J]. IET Science, Measurement & Technology, 2020, 14(3): 303-313.
- [4] 蔡赛男, 宋卫星, 班利明, 等. 基于鲸鱼算法优化LSSVM的滚动轴承故障诊断[J]. 控制与决策, 2022, 37(1): 230-236.
(Cai S N, Song W X, Ban L M, et al. Fault diagnosis method of rolling bearing based on LSSVM optimized by whale optimization algorithm[J]. Control and Decision, 2022, 37(1): 230-236.)
- [5] 马洪斌, 佟庆彬, 张亚男. 优化参数的变分模态分解在滚动轴承故障诊断中的应用[J]. 中国机械工程, 2018, 29(4): 390-397.
(Ma H B, Tong Q B, Zhang Y N. Applications of optimization parameters VMD to fault diagnosis of rolling bearings[J]. China Mechanical Engineering, 2018,

- 29(4): 390-397.)
- [6] Shao H D, Jiang H K, Lin Y, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders[J]. *Mechanical Systems and Signal Processing*, 2018, 102: 278-297.
- [7] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. *控制与决策*, 2017, 32(8): 1345-1358.
(Ren H, Qu J F, Chai Y, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. *Control and Decision*, 2017, 32(8): 1345-1358.)
- [8] Verstraete D, Ferrada A, Droguett E L, et al. Deep learning enabled fault diagnosis using time-frequency image analysis of rolling element bearings[J]. *Shock and Vibration*, 2017, 2017: 5067651.
- [9] Zhang W D, Zhang F, Chen W, et al. Fault state recognition of rolling bearing based fully convolutional network[J]. *Computing in Science & Engineering*, 2019, 21(5): 55-63.
- [10] Wang F A, Jiang H K, Shao H D, et al. An adaptive deep convolutional neural network for rolling bearing fault diagnosis[J]. *Measurement Science and Technology*, 2017, 28(9): 095005.
- [11] Zhang R, Tao H Y, Wu L F, et al. Transfer learning with neural networks for bearing fault diagnosis in changing working conditions[J]. *IEEE Access*, 2017, 5: 14347-14357.
- [12] 康守强, 邹佳悦, 王玉静, 等. 基于无监督特征对齐的变负载下滚动轴承故障诊断方法[J]. *中国电机工程学报*, 2020, 40(1): 274-281.
(Kang S Q, Zou J Y, Wang Y J, et al. Fault diagnosis method of a rolling bearing under varying loads based on unsupervised feature alignment[J]. *Proceedings of the CSEE*, 2020, 40(1): 274-281.)
- [13] 雷亚国, 杨彬, 杜兆钧, 等. 大数据下机械装备故障的深度迁移诊断方法[J]. *机械工程学报*, 2019, 55(7): 1-8.
(Lei Y G, Yang B, Du Z J, et al. Deep transfer diagnosis method for machinery in big data era[J]. *Journal of Mechanical Engineering*, 2019, 55(7): 1-8.)
- [14] Wang J Y, Mo Z L, Zhang H, et al. A deep learning method for bearing fault diagnosis based on time-frequency image[J]. *IEEE Access*, 2019, 7: 42373-42383.
- [15] Li X Q, Jiang H K, Zhao K, et al. A deep transfer nonnegativity-constraint sparse autoencoder for rolling bearing fault diagnosis with few labeled data[J]. *IEEE Access*, 2019, 7: 91216-91224.
- [16] Wu Q Y, Wu H R, Zhou X M, et al. Online transfer learning with multiple homogeneous or heterogeneous sources[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29(7): 1494-1507.
- [17] Wang D, Vipplera R, Evans N, et al. Online non-negative convolutive pattern learning for speech signals[J]. *IEEE Transactions on Signal Processing*, 2013, 61(1): 44-56.
- [18] Chen Y T, Xiong J, Xu W H, et al. A novel online incremental and decremental learning algorithm based on variable support vector machine[J]. *Cluster Computing*, 2019, 22(3): 7435-7445.
- [19] 朱茂桃, 吴新佳, 郑国峰, 等. 基于短时傅里叶变换的汽车零部件耐久性载荷信号编辑方法[J]. *机械工程学报*, 2019, 55(4): 126-134.
(Zhu M T, Wu X J, Zheng G F, et al. Load signal edition method based on the short-time Fourier transform to durability test of vehicle component[J]. *Journal of Mechanical Engineering*, 2019, 55(4): 126-134.)
- [20] Cauwenberghs G, Poggio T. Incremental and decremental support vector machine learning[C]. *International Conference on Neural Information Processing Systems*. Denver, 2000: 409-415.
- [21] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. *仪器仪表学报*, 2020, 41(1): 195-205.
(Gong W F, Chen H, Zhang M L, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(1): 195-205.)
- [22] Loparo K A. Bearings vibration data set[EB/OL]. [2019-12-14]. http://www.eecs.case.edu/laboratory/bearing/welcome_overview.htm.
- [23] Hinton G. Visualizing high-dimensional data using t-SNE[J]. *Vigiliae Christianae*, 2008, 9: 2579-2605.
- [24] Liang N Y, Huang G B, Saratchandran P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. *IEEE Transactions on Neural Networks*, 2006, 17(6): 1411-1423.
- [25] Mao W T, Tian S Y, Liang X H, et al. Online bearing fault diagnosis using support vector machine and stacked auto-encoder[C]. *IEEE International Conference on Prognostics and Health Management*. Seattle, 2018: 1-7.
- [26] Xia M, Li T, Xu L, et al. Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks[J]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23(1): 101-110.

作者简介

康守强(1980—), 男, 教授, 博士生导师, 从事非平稳信号处理、机械故障诊断、状态评估与预测技术等研究, E-mail: kangshouqiang@163.com;

刘旺辉(1993—), 男, 硕士生, 从事旋转机械故障诊断技术的研究, E-mail: 461404241@qq.com;

王玉静(1983—), 女, 副教授, 博士, 从事非平稳信号处理、机械故障诊断、状态评估与预测技术等研究, E-mail: mirrorwyj@163.com;

王庆岩(1984—), 男, 讲师, 博士, 从事图像处理与模式识别、遥感图像处理技术等研究, E-mail: wangqy@hrbust.edu.cn;

Mikulovich V I(1946—), 男, 教授, 博士生导师, 从事旋转机械故障诊断、状态评估与预测技术等研究, E-mail: falcon@tut.by.

(责任编辑: 李君玲)