

基于注意力机制的互特征融合旋转机械故障检测技术

张玉华^{1,2}, 刚润振¹

(1. 河南工业职业技术学院 机械工程学院, 河南 南阳 473000;

2. 太原理工大学 材料与工程学院, 太原 030024)

摘要: 旋转机制在生产生活中的应用愈加广泛; 但旋转机械存在应用环境较为复杂, 生产环境恶劣, 各部件相互影响, 单一信号无法完整表现故障特征等问题; 针对此问题, 研究根据注意力机制构建卷积神经网络, 在网络结构中引入自注意力模块, 采用多信号源进行数据提取, 将不同信号特征互补融合并构建旋转机械故障检测模型, 同时使用傅里叶变化进行数据优化; 实验结果表明, 构建模型的故障分类准确率为 99.92%, 比第二优的算法高出 1.89%, 故障检测精度达到了 99.64%, 数据进行傅里叶变换后的检测精度平均提升了 17.32%; 由此可得, 构建的故障检测模型能够有效提取并融合不同数据采集的故障特征, 大幅提升旋转机械的故障检测精度, 且将数据特征融合模块加入模型中能够有效减少单独计算的运行成本, 提高运算速度, 减少因机械故障产生的生产安全事故。

关键词: 注意力机制; 特征融合; 卷积神经网络; 傅里叶变换; 旋转机械

Rotating Machinery Fault Detection Technology for Mutual Feature Fusion Based on Attention Mechanism

ZHANG Yuhua^{1,2}, GANG Runzhen¹

(1. Henan Polytechnic Institute, Nanyang 473000, China;

2. College of Materials Science and Engineering, Taiyuan University of Technology, Taiyuan 030024, China)

Abstract: Rotating mechanism is widely applied in production and life. However, the application environment of rotating machinery has the problems of complex application environment, harsh production environment, mutual influence of various components, and inability of a single signal to fully show fault characteristics. To solve this problem, a convolutional neural network is constructed according to the attention mechanism, self-attention module is introduced into the network structure, multiple signal sources are used for data extraction, the complementary fusion of different signal features is carried out to build a rotating machinery fault detection model, and Fourier transform is used for data optimization. Experimental results show that the fault classification accuracy of the constructed model is 99.92%, 1.89% higher than that of the second best algorithm, with a fault detection accuracy of 99.64%. The detection accuracy of the data is improved by an average of 17.32% after Fourier transform. It can be concluded that the fault detection model constructed can effectively extract and fuse fault features of different data acquisition, greatly improving the fault detection accuracy of rotating machinery. Moreover, the data feature fusion module is added in the model to effectively reduce the operating cost of separate calculation, improve the calculation speed, and reduce the production safety accidents caused by mechanical faults.

Keywords: attention mechanism; feature fusion; convolutional neural network; Fourier transform; rotating machinery

0 引言

旋转机械在日常生产生活中被广泛使用, 如汽轮机、压缩机、发电机、发动机以及水轮机等^[1], 同时在制造业中同样占据了重要地位, 纺织、石油、武器制造以及金属冶炼等行业发挥了重要作用^[2]。随着时代的进步, 旋转机械的发展呈现出两个极端, 即向着更大更复杂或者更小更精细方面发展, 但旋转机械的工作环境往往比较复杂, 且较为恶劣^[3]。随着时间的增长, 如果不及时对其进行维修

保养或者更换, 一旦发生事故, 会给企业带来巨大的经济损失, 乃至危害到人员的生命安全^[4]。因此, 及时准确地检测出旋转机械产生的故障, 就成为一个重要的研究方向。文献 [5] 为了解决多传感器数据融合在故障检测中的应用问题, 提出了一种采用注意力机制的多层深度融合网络。该网络采用分支网络自动捕捉单一传感器的数据特征, 根据融合策略将不同层次的数据特征在中心网络进行融合。实验表明, 该网络具有更高的检测精度, 和更好的泛化能力, 该方法存在复杂度较高, 计算速度慢的问题^[5]。

收稿日期: 2024-04-06; 修回日期: 2024-10-11。

基金项目: 河南省高等学校重点科研项目(23B460023)。

作者简介: 张玉华(1983-), 女, 硕士研究生, 讲师。

引用格式: 张玉华, 刚润振. 基于注意力机制的互特征融合旋转机械故障检测技术[J]. 计算机测量与控制, 2024, 32(11): 146-152.

文献 [6] 为了提高机械轴承检测的可靠性, 提出了一种多尺度注意力机制残差网络, 该网络使用注意力机制来构建残差块组合, 选择合适的卷积核搭建多尺度结构, 用以构建总体框架。实验表明, 该网络结构提高了对数据特征的敏感性, 能够有效地抵御多种噪声干扰, 提高了故障分类精度, 该方法存在环境越复杂检测精度越低的问题^[6]。文献 [7] 为了提高机械轴承故障的检测能力, 提出了一种采用深度对抗网络和关注机制的智能检测模型。该模型使用集成经验模态分解数据, 去除噪声干扰, 多个串联特征提取模块特征, 采用注意力机制保留关键特征。实验表明, 该模型能够有效减少模型参数, 提高计算速度, 减少过拟合概率, 提高故障检测精度, 该方法需要进行多次模态分解, 增加了计算负担^[7]。文献 [8] 为了解决地震图像的高保真断层检测问题, 提出了一种新的多尺度注意力卷积神经网络。该网络使用多尺度空间通道注意力机制来合并和细化不同空间分辨率的编码器特征图, 使得网络能有效地学习和利用特征映射的上下文信息。实验表明, 该网络能够生成分辨率更高的图像, 提高了断层的地质保真度和可解释性, 该方法需要的独立参数较多^[8]。

文献 [9] 为了提高光网络的故障检测能力, 提出了一种注意力机制长短期记忆网络故障预测模型。该模型采用模型动态关注与目标密切相关的输入信息, 使用加性注意和点积注意来获取注意力权重。实验模型, 该模型的故障检测准确率为 98.73%, F_1 分数为 97.19 假阴性率为 2.6%, 假阳性率为 0.91%, 模型可以有效提升故障检测能力, 该模型缺乏对复杂结构的优化^[9]。文献 [10] 发现现有的液压系统故障检测存在较大的误差, 因此提出了一种多通道数据驱动故障诊断框架。该框架集成了不同的残差网络 (ResNets, residual networks) 和通道关注机制, 通过连续小波变化将通道信号转化为二维特征, 将通道信号作为多个 ResNets 的基础学习器, 使用特征向量训练学习器。实验表明, 该框架的故障检测性能明显优于其他方法, 该框架处理小规模数据集时效果较差^[10]。文献 [11] 针对测量位置影响故障检测精度的问题, 提出了一种基于经验模态分解的声振融合检测方法。该方法使用经验模态对多源信号进行分解, 采用 B 型关联度加强法对固有模态函数进行加权融合, 最后进行归一化处理。实验表明, 该方法能有效提升故障特征的信噪比, 提高故障检测精度, 该方法当信号相似时可能出现模态混叠^[11]。文献 [12] 为了减少噪声对机械轴承故障检测的影响, 提出了一种基于完全集合经验模态分解和深度时间自注意力的检测方法。该方法将信号模态分解为多个固有模态函数, 采用光谱放大因子筛选最优信噪比分量, 改进自注意力机制分配权重。实验表明, 该方法的故障检测准确率到达了 98.87%, 比卷积神经网络模型提高了 9.15%, 该方法可能过拟合数据中的噪声^[12]。综上所述, 现有的研究方法从多方面探讨了旋转机械的故障检测问题, 且取得了一定的成效, 但现有方法的检测精度无法满足日益增长的需求, 采用单一数据来源计

算出的故障检测结果具有较低的可信度。

此次研究构建了采用注意力机制的故障检测模型, 创新地使用注意力机制搭建卷积神经网络, 在网络结构中引入自注意力模块, 提高图像感受野范围。研究构建的故障检测模型将不同信号源提取出的特征进行互补融合, 并使用傅里叶变换进行数据优化。检测模型旨在提升旋转机械故障检测精度, 减少模型的计算成本, 提高计算速度。

1 基于注意力机制的卷积神经网络构建

1.1 引入注意力机制

在卷积神经网络运转时, 不同的卷积核将提取的特征信息映射到高维空间中得出的结果, 对故障分类程度的影响程度也不相同。而注意力机制可以提升卷积核针对不同特征信息的识别能力, 使得卷积神经网络能够自适应地判断特征信息的重要程度。相关研究表明, 二维卷积神经网络具有较高的数据图像识别能力, 因此需要先将提取到的初始一维信号转换为二维信号。

将初始一维信号按照窗口长度为 S 的标准进行数据切割, 将切割后的数据在二维层面进行重新排列组合, 构建一个新的二维矩阵, 矩阵的长度与窗口长度相同为 S 。为保障获得的信号特征能够维持多元化, 初始信号的切割过程需要连续切割和间隔切割交替进行, 但二维矩阵的排列组合需要按照信号切割的先后顺序进行, 既能保障初始信号的不间断性, 又能连接初始信号中不相邻的数据进行信息交换^[13]。注意力机制通过对输入数据的计算, 得出与整个序列有较大关联性的数据, 称为查询向量, 引入评分函数评估查询向量的重要程度以及与目标的关联程度, 完成每一组向量数据的注意力分配。根据查询向量计算出输入向量的概率如式 (1) 所示:

$$IV_n = \frac{\exp(s(x_n, q))}{\sum_{j=1}^N (s(x_n, q))} \quad (1)$$

式中, N 表示输入向量的总数, x_n 表示输入的第 n 个向量, q 表示查询向量, $(s(x_n, q))$ 表示评分函数, 计算如式 (2) 所示:

$$s(x_n, q) = x^T Y q \quad (2)$$

式中, Y 表示学习参数, x^T 为键向量, q 表示查询向量。式 (2) 为双线性模型, 在模型中添加了非对称性用来衡量特征的相似性。将特征图像的空间信息嵌入通道注意力, 提升网络结构的注意力关注范围, 再将通道注意力分解为两组相同的一维特征编码过程, 采用全局池化操作将空间信息的竖向和横向输入特征分别整合成为两组方向感知特征图^[14]。将两组特征图进行编码, 转换为注意力图, 每组注意力图都包含输入数据在某个空间方向上的长程依赖。采用注意力图和输入特征图相乘的方式来增强特征图的表达能力, 坐标注意力机制能够有效降低二维全局池化带来的位置信息丢失问题, 减少计算成本^[15]。在卷积神经网络进行卷积计算时, 各个卷积核计算出的数据特征值与最终的数据分类关联性各不相同, 可以利用注意力机制提升卷积

神经网络对特征值的识别能力,采用注意力机制构建的卷积神经网络如图 1 所示。

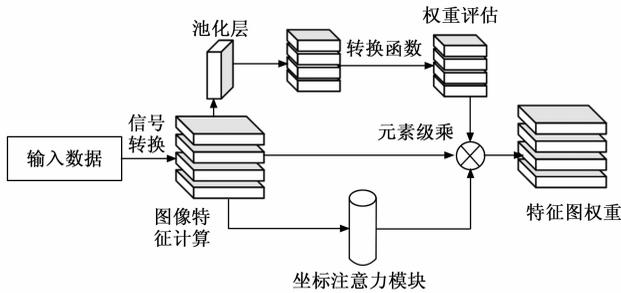


图 1 基于注意力机制的卷积神经网络结构

在图 1 中,将转换后的信号通过卷积层生成多个特征图,计算出每个特征图的维度向量,采用平均池化层进行降维操作,去除冗余信息,计算出所有图像的平均值。再使用转换函数评估降维后的特征向量的权重值,采用注意力模块计算出特征图像的空间方向注意力图,最后将初始特征图、特征向量全值以及空间方向注意力图进行元素级乘得出每个特征图的注意力权重。为提高图像的感受野范围,建立卷积神经网络结构的全局依赖关系,在卷积神经网络的卷积层加入一层自注意力模块,将单个序列的不同位置建立起联系,用以计算同一序列的表达。自注意力模块通过筛选过滤掉不重要的信息,抓取重要信息,可以有效减少模型的内存占用率,提高计算速度。

1.2 自注意力模块运行

自注意力是注意力机制的组成部分之一,通过动态生成大小不同的注意力权重,可以捕捉到远程依赖,从而更好地理解序列中的关系,更好地处理不连续的序列,在每个位置独立计算注意力权重,同时处理整个序列,提升计算速度。自注意力模块通过大量的数据进行练习,建立有效的全局关系,提高数据信息的提取能力,自注意力模块的运行流程如图 2 所示。

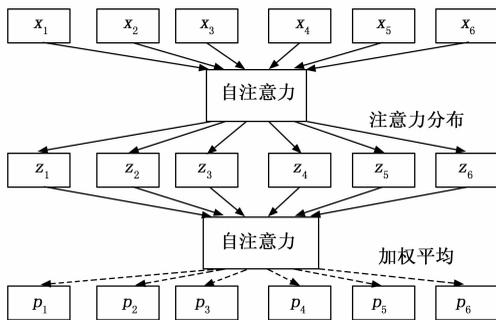


图 2 自注意力模块运行流程

在图 2 中,模块根据输入的数据信息,对生成的注意力权重进行动态改变,经过多轮计算生成最终的注意力权重。自注意力机制中的注意力权重动态变换需要先计算输入数据中的注意力分布和加权平均值,通过点积计算每个查询与所有键之间的相似度得分,通过 Softmax 函数得

分转换为概率分布值,概率分布值即为各个元素对应的注意力权重。第一轮采用自注意力模块进行注意力分布的计算,使用查询向量、键向量以及值向量对自注意力模块进行优化。将输入序列通过线性映射,得到 3 个并列空间中 Q, K, V 的值,线性映射计算如式 (3) 所示:

$$\begin{cases} Q = R_q X \in T^{n \times d} \\ K = R_k X \in T^{n \times d} \\ V = R_v X \in T^{n \times d} \end{cases} \quad (3)$$

式中, Q 表示查询向量, K 表示键向量, V 表示值向量, X 表示输入序列, $R_q \in T^{n \times d}$ 表示查询向量进行线性映射的参数矩阵, $R_k \in T^{n \times d}$ 表示键向量进行线性映射的参数矩阵, $R_v \in T^{n \times d}$ 表示值向量进行线性映射的参数矩阵。采用 q_1 至 q_n 的所有查询向量值构成查询向量矩阵, k_1 至 k_n 的所有键向量值构成键向量矩阵, v_1 至 v_n 的所有值向量的值构成值向量矩阵。将所有的查询向量值进行范围限度,计算出输出向量值,计算如式 (4) 所示:

$$p_n = \sum_{j=1}^N S(s(k_j, q_n)) v_j \quad (4)$$

式中, p_n 表示输出向量值, S 表示激活函数 Softmax, n 表示在输出向量序列中的位置, j 表示在输入向量序列中的位置, v_j 表示在输入向量序列 j 位置值向量的数值, k_j 表示在输入向量序列 j 位置键向量的值。自注意力模块计算出的注意力权重与输入数据的位置信息没有关联,权重大小只与输出序列的查询向量值和输入序列的键向量值的关联度有关。自注意力模块在计算时,通常还需要在模块中对数据的位置信息进行编码操作,修正位置信息。

2 MFAM-CNN

在进行故障检测时,可以采用多种信号进行检测,但单一的信号源所包含的故障信息不够全面,因此来自不同层或不同分支的特征进行组合。同时,简单的线性组合方式可能会出现语义或尺度不一致的问题,所以在组合时引入注意力机制,用以融合不同尺度的特征信息,提高模型的分类准确率,增强模型的鲁棒性。

注意力机制故障检测模型包含多个输入通道,根据实际需求来增加或减少通道数量,具有较强的灵活性和延展性。根据旋转机械的信号特征主要分为振动信号和扭矩信号,选择两个数据通道来进行数据特征融合。根据注意力机制卷积神经网络结构构建的互特征融合故障检测 (MFAM-CNN, mutual feature fusion of attention mechanisms in convolutional neural networks) 模型如图 3 所示。

在图 3 中,模型由两个信号源提供输入数据,经过一系列卷积、池化和标准化操作,使得输出数据的均值为 0,方差为 1,服从正态分布。采用基于注意力机制的卷积神经网络结构计算特征图像的权重,将标准化层输出的数据进行一次一维卷积后与特征图权重数据进行拼接,拼接后的数据再进行一轮上述操作,最后将信号源 1 和信号源 2 计算出的数据进行拼接得到最终输出数据。

采用注意力机制进行图像特征提取,需要先对输入数

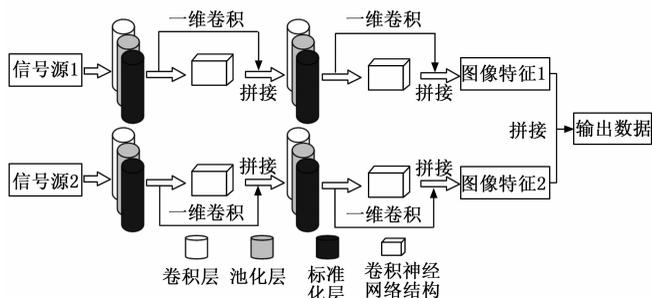


图 3 MFAM-CNN 模型

据进行一维卷积, 提取输入图像的局部特征和模式, 再使用最大池化层对数据进行降维操作, 提取窗口内的数据最大值, 降低特征图的大小。采用标准化层, 将数据进行规范, 提高模型的性能和稳定性, 得到 n 个向量长度为 x 特征。对所有特征进行全局最大池化操作, 提取特征图中所有通道的最大值, 获得与通道数相同的一维向量。使用全连接层将获取的分布式特征映射到样本标记空间中, 第一个全连接层采用线性修正单元激活函数, 第二个全连接层采用 softmax 激活函数。在第一层选择线性修正单元激活函数, 可以使函数的所有输出为正, 在正区间的梯度恒为 1, 能够有效缓解梯度消失的问题, 同时还能加快模型的训练速度。第二层选取 softmax 激活函数是为了神经网络输出的原始分数转化为概率分布, 使得输出值分别在 $[0, 1]$ 之间。特征的重要性加权拼接计算如式 (5) 所示:

$$y_i = r_i \cdot t_i, i = 1, 2, \dots, C_i \quad (5)$$

式中, y_i 为输入数据在第 i 个卷积核的计算结果, r_i 表示标准化处理后得出的数据, t_i 表示第 i 个数据的评估向量, C_i 表示输入数据的特征总量。为了防止故障信息在计算过程中丢失, 保障故障信息的完整性, 在进行特征提取的同时采用一个单一卷积层对输入数据进行计算, 得到的结果和 C_i 个特征进行拼接。特征拼接计算如式 (6) 所示:

$$H = Trans \left(\begin{bmatrix} f_{1,1}^1 \dots f_{1,S_1}^1, f_{1,1}^2 \dots f_{1,S_2}^2 \\ f_{C_i+1,1}^1 \dots f_{C_i+1,S_1}^1, f_{C_i+1,1}^2 \dots f_{C_i+1,S_2}^2 \end{bmatrix} \right) \quad (6)$$

式中, H 表示拼接后的特征数据, $Trans$ 为转置函数, $C_i + 1$ 表示卷积操作重新生成的特征, S_1 表示第一个通道得到的特征长度, S_2 表示第二个通道得到的特征长度。普通的特征提取只能融合一部分数据的特征, 想要将所有深层次特征图像全部融合, 需要使用一维卷积神经网络和二维卷积神经网络共同提取图像的多尺度特征。采用多尺度特征提取优化 MFAM-CNN 如图 4 所示。

在图 4 中, 将故障检测模型的输出数据作为多尺度特征提取结构的输入数据, 对输入数据进行两种卷积操作, 第一种经过卷积、池化和标准化操作后, 采用注意力机制计算出特征图注意力权重与标准化计算结果进行拼接, 拼接后的数据在经过一道卷积操作后拉伸为一维向量。第二种在进行二维卷积前加入可学习的偏移量, 调整卷积核的位置, 提升局部特征提取的灵活性。将标准化操作后的数据再进行一次二

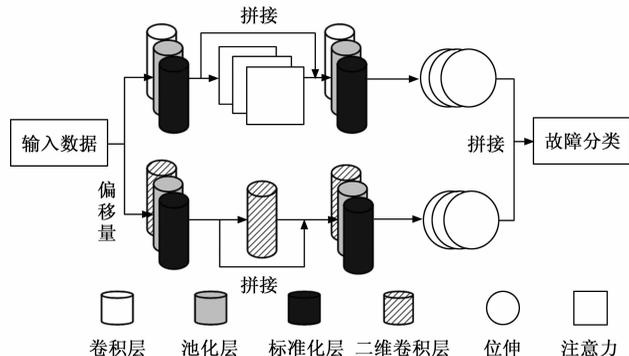


图 4 优化 MFAM-CNN

维卷积, 并与卷积前的数据进行拼接, 拼接后的数据在经过一次二维卷积操作后拉伸为一维向量, 将两组一维向量拼接进行最终的故障分类, 完成故障检测工作。

旋转机械的故障分类采用 Softmax 回归多类别分类算法, 可以预测轴承的故障属于哪一类, 通过反向传播来更新神经网络的权重, 在数据进行反向传播时, 取算法的损失函数的最小值为结构优化参数, 损失函数采用交叉熵来计算预测类别的概率和实际标签的差异。故障分类需要对算法获取的特征图像进行映射, 特征映射通过卷积神经网络来进行, 将特征向量转换为便于分类的形式。模型的输出结果是一组概率值, 每个值对应数据属于某个故障类别的可能性, 研究将最高概率值对应的类别作为预测结果, 确定哪个故障的可能性最大, 故障概率计算如式 (7) 所示:

$$K_j(x) = \frac{e^{x_j}}{\sum_{i=1}^B e^{x_i}}, j = 1, 2, \dots, B \quad (7)$$

式中, $K_j(x)$ 表示选择机械的故障概率, e^{x_j} 表示算法输入的第 j 个特征, e^{x_i} 表示算法输入的第 i 个特征, B 表示现有的故障类型总量, 所有故障的概率相加等于 1。算法输出数据与真实数据的误差采用交叉熵损失函数来计算, 如式 (8) 所示:

$$R(y, K(x)) = \sum_{j=1}^B y_j \log(K_j(x)) \quad (8)$$

式中, $R(y, K(x))$ 表示输出数据与真实数据之间的误差, y 表示模型中输入的真实数据, y_j 表示算法对第 j 个特征的输出数据。考虑到计算速度和计算精度, 还需要对旋转机械传递的数据进行预处理, 如式 (9) 所示:

$$\begin{cases} X_v = (x_v^{1/m}, x_v^{m+1/2m}, \dots, x_v^{(\lfloor p/m \rfloor - 1)m + 1 / \lfloor p/m \rfloor m}) \\ X_t = (x_t^{1/n}, x_t^{n+1/2n}, \dots, x_t^{(\lfloor q/n \rfloor - 1)n + 1 / \lfloor q/n \rfloor n}) \end{cases} \quad (9)$$

式中, X_v 表示振动数据, X_t 表示扭矩数据, 将两组数据等分为不同长度的数据段, m 表示分割后的振动数据长度, n 表示分割后的扭矩数据长度。 p 为振动数据的数据量, q 为扭矩数据的数据量, $\lfloor \cdot \rfloor$ 表示计算内容向下取整数。因为两种数据的采样频率不同, 所以根据查阅相关资料和计算得出, 当 m 的长度为 2 048 和 4 096 时, 机械故障检测效果明显优于其他长度。 m 等于 4 096 时, 故障检测能力略优于 m 等于 2

048 时, 但 m 取 4 096 时的计算难度明显高于 m 取 2 048 时, 因此选择 2 048 为振动数据的分割长度。扭矩数据的分割长度对检测效果的影响较小, 但为使两种数据的采集时间在相同时间段内, n 的分割长度取 256。因为分割后的数据呈现出的周期性, 需要对分割数据进行傅里叶变换, 如式 (10) 所示:

$$X(m) = \sum_{i=0}^{I-1} x(i)e^{-j2\pi mi/I} \quad (10)$$

式中, I 表示样本总数, i 表示第几个样本。在进行傅里叶变换后, 每个数据的取值大小也会相应进行改变, 所以需要对所有数据采用归一化方程进行计算, 统一各个数据的取值范围方便后续计算。归一化计算如式 (11) 所示:

$$\bar{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

式中, x 表示原始数据, x_{\min} 表示每个数据的最小取值, x_{\max} 每个数据的最大取值。

3 实验分析

实验采用凯斯西储 (CWR, case western reserve) 数据集, 数据集中的轴承健康状况分为 3 种, 包括正常状态、内圈故障、外圈故障。为了模拟机械在生产中遇到的真实故障情况, 根据真实实验场景设计了一个轴承寿命加速实验装置, 如图 5 所示。

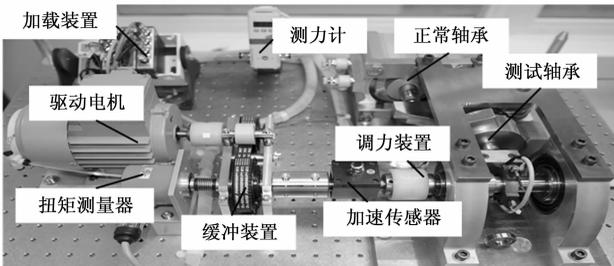


图 5 轴承寿命加速实验装置

在图 5 中, 装置由一个驱动电机、正常轴承、测试轴承、加速传感器、缓冲装置、测力计、调力装置、扭矩测量器以及一个加载装置组成。凯斯西储数据集的具体故障类别和数量如表 1 所示。

表 1 凯斯西储数据集具体故障类别与损伤情况

故障类型	损伤/cm	标签	代号	训练数据集样本个数/个	测试数据集样本个数/个
内圈故障	0.017 64	1	Ir01	1 075	160
	0.034 28	2	Ir02	1 075	160
	0.052 47	3	Ir03	1 075	160
外圈故障	0.017 64	4	Or01	1 075	160
	0.034 28	5	Or02	1 075	160
	0.052 47	6	Or03	1 075	160
滚动体故障	0.017 64	7	Ba01	1 075	160
	0.034 28	8	Ba02	1 075	160
	0.052 47	9	Ba03	1 075	160
正常	/	10	N	1 075	160

在表 1 中, 内圈故障和外圈故障的损伤程度都分为 3 种, 分别为 0.017 64 cm、0.034 28 cm 以及 0.052 47 cm, 每一种损失类别都有 1 075 个样本作为训练集, 160 个样本作为测试集。采用 MFAM-CNN 模型, 根据不同数据得出旋转机械故障检测精准度如图 6 所示。

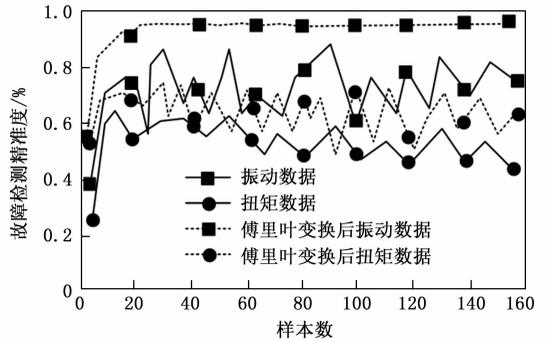


图 6 数据处理前后的故障检测精准度

在图 6 中, 根据振动数据的故障检测精准度明显比扭矩数据的检测精准度要高, 平均高出 13.21%。在傅里叶变换前振动数据的最大故障检测精准度为 86.83%, 扭矩数据的最大故障检测精准度 67.28%, 振动数据的最大检测精准度比扭矩数据的高出 19.55%。数据经过傅里叶变换后, 故障检测精准度明显提升, 振动数据的检测精准度平均提升了 17.32%, 扭矩数据的检测精准度平均提升了 12.15%。傅里叶变换后的振动数据最大检测精准度为 96.47%, 扭矩数据的最大检测精准度为 72.58%, 比振动数据的最大检测精度低了 23.89%。振动数据傅里叶变换后的故障检测精度变化趋势更加平缓, 在样本数为 20 次时, 检测精准度基本稳定在 96% 左右, 其他三组故障检测精准度上下波动幅度较大, 上下波动幅度平均超过了 10% 在实际生产中, 不利于进行安全生产, 对企业的稳定生产影响较大。数据融合时不同方法对故障检测精准度的影响如图 7 所示。

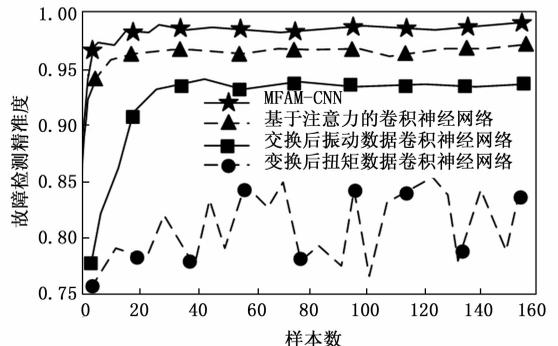


图 7 两种数据特征融合后的故障检测精准度

在图 7 中, 精准度最高的两条曲线均采用振动数据和扭矩数据融合后的数据进行实验, 数据融合后的检测精准度明显比采用单一数据的检测精准度更高, 采用基于注意力的卷积神经网络的融合数据的检测精准度分别比振动数据和扭矩数据的检测精准度高出 3.27% 和 15.13%。MFAM-CNN 模型的检测精准度平均为 99.64%, 基于注意

力的卷积神经网络检测精度为 96.52%, MFAM-CNN 的检测精度平均高出 3.12%。MFAM-CNN 模型的最大检测精度为 99.84%, 采用注意力机制的卷积神经网络的最大检测精度 97.28%, MFAM-CNN 模型的最大检测精度比卷积神经网络的最大检测精度高出 2.56%。说明振动数据和扭矩数据提取出的特征能够实现互补, 提高故障检测精度。采用振动数据和扭矩数据的融合特征的检测精度的收敛速度更快, 两种模型基本在 20 个样本左右就达到了收敛值, 而采用振动数据特征的模型在 40 个样本时达到收敛值。不同检测模型的状态混淆情况如图 8 所示。

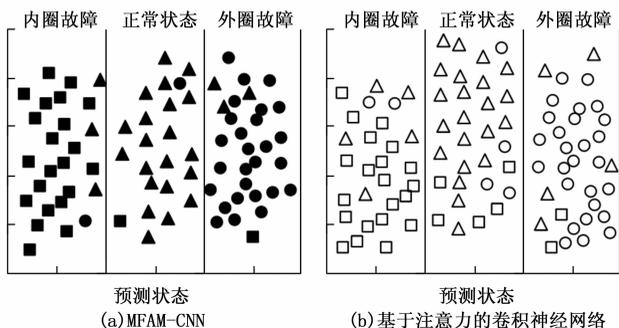


图 8 不同模型的检测状态混淆情况

在图 8 (a) 中, 采用 MFAM-CNN 模型时, 有少量的样本状态划分出现错误, 正常状态的检测准确率为 99.27%, 外圈故障的检测准确率为 99.35%, 内圈故障的检测准确率为 99.14%。有部分样本在正常时被误检测为故障状态, 而故障状态被误检测为正常状态的情况较少, 有利于企业生产的安全运行。在图 8 (b) 中, 采用基于注意力的卷积神经网络时, 大量的内圈和外圈故障被误检为正常状态, 少数内圈故障和外圈故障被相互误检, 正常状态的检测准确率为 82.67%, 外圈故障的检测准确率为 80.45%, 内圈故障的检测准确率为 83.16%。使用 Softmax 激活函数进行回归处理后的故障检测结果如图 9 所示。

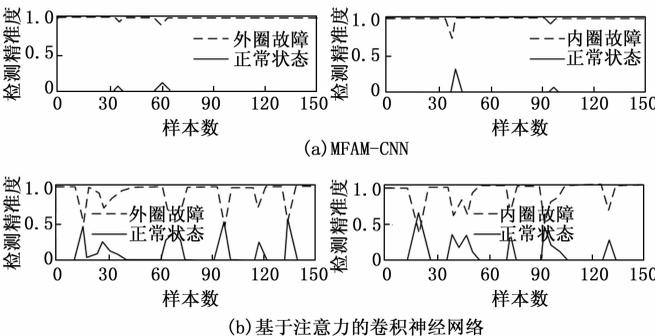


图 9 不同模型进行 Softmax 回归后检测结果

在图 9 (a) 中, 外圈故障状态和正常状态虽然有些许波动, 波动值小于 0.1, 内圈故障与正常状态的检测精度波动值小于 0.25, 且没有交叉的状态出现, 说明没有出现误分类情况, 且波动时的故障状态和正常状态的检测精度相差较远, 再次进行检测时也不容易出现状态误检测的情况。在图 9 (b) 中, 外圈故障和内圈故障都与正常状态有

交集, 部分样本的交集超过 0.1, 部分样本被误分类, 且没有相交的多个波动点的距离大于 0.4, 当再次进行检测时, 距离较近的点被误检测的概率会大大增加, 不能保证故障检测性能。误检是因为多源数据在特征级融合时产生的故障信息丢失, 可以通过插值法对数据进行重采样, 确保不同数据源的数据在时间序列上尽可能对齐。不同算法和模型的旋转机械故障分类准确率如表 2 所示。

表 2 不同算法对旋转机械的故障分类准确率

训练方法	算法类型	分类准确率/%
振动神经与扭矩数据融合	主元分析法	98.03
	随机森林法	97.42
	基于决策树检测法	96.24
	基于支持向量机检测法	85.63
	梯度增强法	89.35
	最近邻算法	68.27
融合数据傅里叶变换前	基于注意力的卷积神经网络	94.61
融合数据傅里叶变换后	基于注意力的卷积神经网络	96.55
融合数据傅里叶变换后	卷积神经网络	94.27
融合数据傅里叶变换前	MFAM-CNN	96.44
融合数据傅里叶变换后	MFAM-CNN	99.92

在表 2 中, MFAM-CNN 在使用的振动数据和扭矩数据傅里叶变换后的分类准确率, 比分类前高出了 3.48%, 比单独的卷积神经网络高出 5.65%, 比数据傅里叶变换后的基于注意力机制的卷积神经网络高出 3.37%。说明 MFAM-CNN 提取融合数据特征的能力比基于注意力机制的卷积神经网络更强。MFAM-CNN 模型的故障分类准确率是最高的, 平均比主元分析法、随机森林法、基于决策树算法的检测方法、基于支持向量机算法的检测方法、梯度增强法、最近邻算法以及基于注意力的卷积神经网络分别高出 1.89%、2.50%、3.68%、14.29%、10.57%、31.65% 以及 3.37%。主元分析法的准确率虽然达到了 98.03%, 但该方法需要单独进行数据融合与特征提取步骤, 导致计算成本比 MFAM-CNN 的成本更高, 同时计算速度也更慢。MFAM-CNN 与最新的基于神经网络模型的轴承故障检测方法性能对比如表 3 所示。

表 3 MFAM-CNN 与基于神经网络模型的轴承故障检测方法性能对比

算法	分类准确率/%	检测精度度/%	运行时间/ms
MFAM-CNN	99.92	99.84	19.6
CNN-LSTM	96.73	95.42	24.5
DCNN	89.27	92.58	18.3
CNN-FA	94.26	92.18	23.6

在表 3 中, MFAM-CNN 的故障分类准确率分别比长短期记忆卷积神经网络 (CNN-LSTM, convolutional neural network long short-term memory)、深度卷积神经网络 (Deep Convolutional Neural Network) 以及融合注意力机制卷积神经

网络 (CNN-FA, convolutional neural network focal attention) 高出 3.19%、10.65% 和 5.66%。MFAM-CNN 的故障检测精度分别比 3 种算法高出 4.42%、7.26% 以及 7.66%，运行时间分别比 3 种算法低了 4.9 ms、-1.3 ms 和 4.0 ms。研究所提方法的适应性分析如表 4 所示。

表 4 不同算法的计算复杂度分析

文献	数据集规模					
	1 000		2 000		3 000	
	平均处理时间/ms	标准偏差/ms	平均处理时间/ms	标准偏差/ms	平均处理时间/ms	标准偏差/ms
5	32.5	3.2	95.3	5.9	207.5	8.6
6	20.2	2.3	79.2	5.1	174.6	8.2
7	30.1	2.7	86.5	5.5	199.2	8.5
8	22.4	2.4	84.2	5.2	184.5	8.6
9	23.9	2.6	94.5	4.8	192.6	9.1
10	24.6	2.9	85.3	5.6	201.3	8.5
11	25.8	3.1	90.5	4.9	197.6	7.9
12	28.4	2.7	89.5	5.4	197.5	8.4
此次研究	18.4	2.1	74.3	4.4	170.2	7.8

在表 4 中，研究提出的算法的平均处理时间在数据集规模为 1 000、2 000、3 000 时，分别为 18.4 ms、74.3 ms 以及 170.2 ms，均小于其他方法。说明多源数据融合不会进一步增加算法的复杂度，学习和故障分类时间均在可接受范围内。

4 结束语

针对旋转机械故障检测速度慢，单一信号源提供的数据无法满足检测精度要求，研究提出了采用注意力机制，多源数据融合的特征互补旋转机械故障检测技术。研究结果表明，MFAM-CNN 模型使用单一振动数据的平均故障检测精准度为 79.34%，单一扭矩数据的平均检测精准度为 58.67%，经过傅里叶变换后的振动数据故障检测精度变化趋势更加平缓。将振动数据和扭矩数据进行特征融合后的故障检测精度有明显提升，采用融合特征的卷积神经网络检测精度分别比单独使用振动数据和扭矩数据高出 3.27% 和 15.13%，使用融合数据特征的 MFAM-CNN 模型故障检测精度达到了 99.64%，MFAM-CNN 模型的最大检测精准度比卷积神经网络的最大检测精准度高出 2.56%。MFAM-CNN 模型的状态混淆情况明显要优于基于注意力卷积神经网络，只有少了故障情况出现误判。在进行 Softmax 激活函数回归处理后，MFAM-CNN 的三种检测状态只有些微波动，并未出现交叉情况，不会影响检测精度。与其他方法相比，MFAM-CNN 比第二优的主元分析法的故障分类准确率高出 1.89%，且主元分析法要进行单独行数据融合与特征提取，计算成本更高，速度更慢。此次研究还存在一些不足，例如未考虑齿轮等其他旋转构件的影响，后续可以继续改进提高模型的泛化能力，使模型能够检测更多部件的故障问题。

参考文献:

- [1] 蒋科若, 姜炯挺, 杨帆, 等. GIS 机械振动和局部放电融合检测系统研究 [J]. 高压电器, 2023, 59 (8): 154-163.
- [2] 胡爱军, 邢磊, 张鑫, 等. 基于时空特征深度融合的双馈式风力发电机故障早期预测 [J]. 中国工程机械学报, 2023, 21 (4): 353-357.
- [3] 张娜, 段礼祥, 李肇阳, 等. 声学和电流特征融合的行星齿轮箱诊断方法 [J]. 石油机械, 2023, 51 (9): 76-86.
- [4] 付忠广, 高玉才, 王诗云, 等. 混合注意力机制的旋转机械故障诊断方法 [J]. 中国工程机械学报, 2022, 20 (5): 459-464.
- [5] LI X, WAN S, LIU S, et al. Bearing fault diagnosis method based on attention mechanism and multilayer fusion network. ISA transactions, 2022, 128 (12): 550-564.
- [6] WANG Y, LIANG J, GU X, et al. Multi-scale attention mechanism residual neural network for fault diagnosis of rolling bearings. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2022, 236 (20): 10615-10629.
- [7] WU H, LI J, ZHANG Q, et al. Intelligent fault diagnosis of rolling bearings under varying operating conditions based on domain-adversarial neural network and attention mechanism. ISA transactions, 2022, 130 (5): 477-489.
- [8] GAO K, HUANG L, ZHENG Y, et al. Automatic fault detection on seismic images using a multiscale attention convolutional neural network. Geophysics, 2022, 87 (1): 13-29.
- [9] ZHANG C, WANG D, JIA J, et al. Potential failure cause identification for optical networks using deep learning with an attention mechanism. Journal of Optical Communications and Networking, 2022, 14 (2): 122-133.
- [10] PENG X, XU H, WANG J, et al. Ensemble multiple distinct resnet networks with channel-attention mechanism for multi-sensor fault diagnosis of hydraulic systems. IEEE Sensors Journal, 2023, 23 (10): 10706-10717.
- [11] 高云端, 田野, 朱永波, 等. 基于稀疏注意力机制的齿轮早期磨损故障诊断研究 [J]. 机械传动, 2023, 47 (3): 105-112.
- [12] 陈博, 魏豪, 权伟. 基于 CEEMDAN 和 CNN-TSAGRU 的滚动轴承故障识别方法研究 [J]. 轻工机械, 2023, 41 (4): 68-74.
- [13] LIU Y, GAN H, CONG Y, et al. Research on fault prediction of marine diesel engine based on attention-LSTM. Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment, 2023, 237 (2): 508-519.
- [14] 邵海东, 李伟, 刘翊, 等. 时变转速下基于双阈值注意力生成对抗网络和小样本的转子-轴承系统故障诊断 [J]. 机械工程学报, 2023, 59 (12): 215-224.
- [15] CHU H, WANG W, DENG L. Tiny-Crack-Net: A multiscale feature fusion network with attention mechanisms for segmentation of tiny cracks. Computer-Aided Civil and Infrastructure Engineering, 2022, 37 (14): 1914-1931.