

基于加权图卷积网络的多传感器旋转机械故障诊断

胡艳艳^{2†}, 衣晓捷¹, 彭开香²

(1. 北京科技大学 智能科学与技术学院, 北京 100083; 2. 北京科技大学 自动化学院, 北京 100083)

摘要: 多传感器数据能为故障诊断提供更为全面和精确的信息, 但现有建模在欧氏空间里的深度学习算法难以有效处理传感器间复杂的相互影响和空间关系. 同时, 旋转机械振动信号的非平稳特性也极大影响了故障诊断的效果. 为解决上述问题, 本文提出了一种新的基于加权图卷积网络的多传感器旋转机械故障诊断方法. 利用希尔伯特-黄变换 (HHT) 自适应地提取故障特征, 克服信号非平稳性的影响. 考虑到图结构在空间关系上强大的表达能力以及图卷积网络强大的特征学习能力, 依据传感器节点特征向量之间的距离度量构建加权 HHT 图, 并搭建具有两层结构的图卷积网络进行故障诊断. 同时, 在网络损失函数中引入两个正则项以提高诊断的精度. 公开数据集上的实验结果验证了所提出方法的有效性及其相比其他方法的优越性.

关键词: 多传感器; 故障诊断; 希尔伯特-黄变换; 图卷积网络

引用格式: 胡艳艳, 衣晓捷, 彭开香. 基于加权图卷积网络的多传感器旋转机械故障诊断. 控制理论与应用, 2026, 43(3): 519 – 527

DOI: 10.7641/CTA.2024.30829

Multi-sensor rotating machinery fault diagnosis using weighted graph convolutional network

HU Yan-yan^{2†}, YI Xiao-jie¹, PENG Kai-xiang²

(1. School of Intelligence Science and Technology, University of Science and Technology Beijing, Beijing 100083, China;

(2. School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: Multi-sensor data can provide more comprehensive and accurate information for fault diagnosis, but current deep learning algorithms modeled in Euclidean space have difficulty effectively handling the complex interactions and spatial relationships between sensors. Additionally, the non-stationary characteristics of vibration signals in rotating machinery greatly affect the effectiveness of fault diagnosis. To address these issues, this paper proposes a novel multi-sensor fault diagnosis method for rotating machinery based on a weighted graph convolutional network. The Hilbert-Huang transform (HHT) is used to adaptively extract fault features, overcoming the impact of signal non-stationarity. Considering the strong expressive power of graph structures in spatial relationships and the powerful feature learning capabilities of graph convolutional networks, a weighted HHT graph is constructed based on the distance metric between sensor node feature vectors, and a two-layer graph convolutional network is built for fault diagnosis. Additionally, two regularization terms are introduced into the network's loss function to improve diagnostic accuracy. Experimental results on public datasets verify the effectiveness and superiority of the proposed method compared to other approaches.

Key words: multiple sensors; fault diagnosis; Hilbert-Huang transform; graph convolutional network

Citation: HU Yanyan, YI Xiaojie, PENG Kaixiang. Multi-sensor rotating machinery fault diagnosis using weighted graph convolutional network. *Control Theory & Applications*, 2026, 43(3): 519 – 527

1 引言

旋转机械是诸多工业生产设备的重要组成部分, 一旦发生故障, 将影响设备整体的健康运行, 甚至引发安全事故. 因此, 旋转机械的故障诊断具有重要意义^[1-3].

随着传感器技术的提高, 工业生产中可以利用的传感器越来越多. 这些传感器部署在设备的不同部位, 极大地扩展了监测信号的时间范围和空间范围^[4]. 此外, 随着计算机硬件技术的进步以及数据处理能力的提高, 各类深度学习方法, 如卷积神经网络 (convoluti-

收稿日期: 2023-12-25; 录用日期: 2024-12-27.

[†]通信作者. E-mail: huyanyan@ustb.edu.cn.

本文责任编辑: 张友民.

国家自然科学基金项目(62273038, U21A20483), 智控实验室开放基金项目(ZKSYS-KF03-05)资助.

Supported by the National Natural Science Foundation of China (62273038, U21A20483) and the Open Fund of Intelligent Control Laboratory (ZKSYS-KF03-05).

onal neural networks, CNN)^[5-6]、深度自编码器 (deep auto-encoder, DAE)^[7-8]、长短期记忆 (long short-term memory, LSTM)等^[9-11], 在多传感器旋转机械故障诊断中得到了越来越多的应用。

一般地, 实际工业生产中, 不同传感器数据对故障诊断结果的影响也不同。然而, 传统基于深度学习的故障诊断方法视不同传感器的数据同等重要, 这限制了故障诊断准确率的提高。得益于注意力机制强大的资源分配能力, 研究者们开始将注意力机制引入深度学习模型来解决上述问题。文献[12]提出了一种具有通道注意力的多尺度对抗网络, 可以实现轴承和齿轮箱的域自适应智能故障诊断。挤压和激励网络 (squeeze and excitation networks, SE-Net) 作为一种流行的通道注意力技术, 被广泛应用到机械诊断中。文献[13]提出了使用对称点阵表示的具有 SE-Net 注意力的 CNN 网络进行轴承诊断。文献[14]提出了一种基于 SE-Net 的特征级注意力方法, 并提出了用于轴承诊断和工况识别的多任务 CNN。虽然在深度学习模型中引入注意力机制一定程度上提升了模型的性能, 但这些方法对多个传感器数据和特征的处理方式几乎都是: 要么简单地将多个传感器的数据或特征直接组合成一维的扩展向量, 要么按序排列为二维的图像进而利用各类一维或二维的卷积网络进行处理。这种简单地将不同传感器数据特征在欧氏空间进行组合排列的处理方式, 难以反映传感器间复杂的相互影响和空间关系。

近年来, 图卷积网络 (graph convolutional network, GCN) 发展迅速。得益于图结构在复杂关系数据存储和表示上的巨大优势, GCN 已在社交网络^[15]、知识图谱^[16]、自然语言处理^[17]等多个领域展示了强大的特征学习及分类能力。相应地, 也已有学者开始将 GCN 应用于旋转机械故障诊断。文献[18]采用了一种基于水平加权可视图的 GCN 对轴承故障信号进行诊断, 但因该方法直接采用原始信号构建图, 因此诊断精度受限于信号的质量。考虑到旋转机械振动信号的非平稳特性, 文献[19]提出了一种基于短时傅里叶变换的特征提取方法, 但方法中时间窗的面积是固定的。文献[20]提出了一种多通道的平均归一化 GCN 故障诊断网络, 在强噪声情形下实现了较高的诊断精度。以上研究展示了 GCN 在故障诊断领域的优势和潜力, 但上述 GCN 方法中图的构建都是基于传统的信号时域、频域或时频域分析方法, 如傅里叶变换^[21]、短时傅里叶变换^[22]和小波变换^[23]等, 这些方法受限于 Heisenberg 不确定原理, 难以同时兼顾时间分辨率和频率分辨率, 且自适应性较差。此外, 这些方法仅利用了单个传感器的数据, 没有充分发挥 GCN 在多源数据信息挖掘上的优势。因此, 结合更先进的自适应信号处理方法将 GCN 网络应用于多传感器故障诊断, 建模和学习多传

感器数据之间的联系以进一步提高故障诊断的精度非常有必要。

综上, 本文提出了一种基于加权希尔伯特-黄变换 (Hilbert-Huang transform, HHT) 图和改进 GCN 模型的多传感器旋转机械故障诊断方法。首先, 利用 HHT 提取故障信号固有模态函数 (intrinsic mode function, IMF) 分量特征以及边际谱特征; 其次, 基于所提取的信号特征构建加权 HHT 图。图的节点表示不同的传感器, 节点的特征为传感器信号经 HHT 后提取的特征, 节点间的边代表传感器之间的关系, 边上的权重则表示传感器间相互影响的大小; 进而, 利用改进的双层 GCN 实现故障诊断; 最后, 对所提出的方法在公开数据集上进行了验证, 并通过与其他方法的对比验证了所提出方法的优越性。

本文的剩余部分组织如下: 第2节介绍了 HHT 和 GCN 的原理; 第3节提出了加权 HHT 图的构建方法和改进的 GCN 故障诊断模型; 第4节展示了所提出的故障诊断方法的整体流程; 第5节验证了方法的有效性; 第6节对本文进行了总结。

2 预备理论

2.1 希尔伯特-黄变换特征提取

HHT 是近年来受到广泛关注的一种新的信号处理方法。HHT 首先利用经验模态分解 (empirical mode decomposition, EMD), 将时域原始信号分解为若干个 IMF 分量之和, 然后对每一个 IMF 分量进行希尔伯特变换以获得信号的时频谱。EMD 从根本上克服了传统傅立叶变换整体变换方法在提取信号频谱时需要利用信号全部时域信息, 缺少时域定位功能的局限性, 具有自适应的特点。正因如此, HHT 在处理旋转机械非平稳特性振动信号上更有优势。

原始信号 $\mathcal{X}(t)$ 经 p 次 EMD 分解后可表示为^[24]

$$\mathcal{X}(t) = \sum_{i=1}^p \mathcal{M}_i(t) + \mathcal{R}_p(t), \quad (1)$$

这里, t 表示时间, $\mathcal{M}_i(t)$ 表示第 i 个 IMF 分量, $\mathcal{R}_p(t)$ 表示 p 阶残差。

将各 IMF 分量信号的能量作为一种故障特征。构造 IMF 能量特征向量为

$$\mathcal{E}_{\text{IMF}} = [e_1 \ e_2 \ \cdots \ e_p], \quad (2)$$

其中 e_i 表示第 i 个 IMF 分量信号的归一化能量。

另一方面, IMF 分量 $\mathcal{M}_i(t)$, $i = 1, 2, \dots, p$ 的希尔伯特变换为^[24]

$$\mathcal{Y}_i(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{\mathcal{M}_i(\tau)}{t - \tau} d\tau. \quad (3)$$

构造如下分析信号:

$$\mathcal{Z}_i(t) = \mathcal{M}_i(t) + j\mathcal{Y}_i(t) = a_i(t)e^{j\varphi_i(t)}, \quad (4)$$

则 $a_i(t)$ 和 $\varphi_i(t)$ 分别表示瞬时振幅和相位。

$\varphi_i(t)$ 相应的瞬时频率函数 $w_i(t)$ 定义为

$$w_i(t) = \frac{d\varphi_i(t)}{dt}. \quad (5)$$

p 次EMD分解后的残差信号 $\mathcal{R}_p(t)$ 通常对信号提取没有实质影响,故舍去,则有^[25]

$$\mathcal{X}(t) \approx \text{Re} \sum_{i=1}^p a_i(t) e^{j \int w_i(t) dt}, \quad (6)$$

由式(6)可以看出,经过上述过程,原信号可以被表示为一个时间-频率-能量的三维分布,称为希尔伯特时频谱 $H(w, t)$. $H(w, t)$ 表示在给定时间 t 下,所有瞬时频率为 w 的分量的能量密度之和.

对 $H(w, t)$ 在时间维度上积分可以得到希尔伯特边际谱^[26]

$$H(w) = \int_{-\infty}^{\infty} H(w, t) dt. \quad (7)$$

边际谱 $H(w)$ 反映了故障发生时不同频率上所产生的振动能量分布.因此, $H(w)$ 在不同频率区间上的能量分布也可作为一种故障特征.根据 $H(w)$ 能量在频率上的分布情况,将 $H(w)$ 划分为 q 个区间,计算各频率区间的归一化能量 $h_j, j = 1, 2, \dots, q$,则可构造边际谱特征向量 \mathcal{E}_H 为

$$\mathcal{E}_H = [h_1 \ h_2 \ \dots \ h_q]. \quad (8)$$

这里需要说明的是频率区间划分个数 q 的取值需要根据实际情况折中选取. q 取值越大,频率划分越细,频率特征信息损失越小,但是特征向量的维度也会相应增加,从而导致后续GCN计算量的增加,且过多的细节信息有时反而不利于后续故障诊断效果的改善.反之, q 取值太小,频率划分太粗,信息特征损失较多,后续GCN的计算量会减小,但也会导致诊断精度的降低.

最后,将IMF特征向量 \mathcal{E}_{IMF} 和边际谱特征向量 \mathcal{E}_H 进行拼接,可得到最终的组合特征向量为

$$f = [\mathcal{E}_{\text{IMF}} \ \mathcal{E}_H]. \quad (9)$$

2.2 图卷积网络

GCN是一种能直接作用于图并能有效利用图结构信息的卷积神经网络.

GCN中一般采用无向图,可表示为 $G = \{V, S, A, F\}$,这里: $V = \{V_i\}_{i=1}^N$ 表示节点集, S 表示边的集合, $F \in \mathbb{R}^{N \times M}$ 表示图 G 的特征矩阵, N 为节点个数, M 为节点特征数, $A \in \mathbb{R}^{N \times N}$ 表示邻接矩阵.

记图 G 正则化后的拉普拉斯矩阵为 L ,则经矩阵特征分解, L 可表示为^[27]

$$L = U \Lambda U^{-1} = U \Lambda U^T, \quad (10)$$

这里, $\Lambda = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_N\}$ 表示特征值对角阵, U 为相应特征向量构成的正交矩阵.对于输入信号 f ,

图卷积操作定义为^[27]

$$(f \times g_\theta)_G = U g_\theta(\Lambda) U^T f, \quad (11)$$

这里: G 表示图卷积操作, $U^T f$ 为 f 的图傅里叶变换, $g_\theta(\Lambda)$ 为图卷积核, θ 为待学习参数.

以上图卷积操作涉及拉普拉斯矩阵的正则化及正交分解,其中包含大量的矩阵乘法运算.当图的节点数过多时,会造成拉普拉斯矩阵的过度膨胀,给图卷积的计算带来困难.为了简化计算,可利用切比雪夫多项式将图卷积近似为^[28]

$$(f \times g_\theta)_G = \theta \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} f, \quad (12)$$

这里, $\tilde{A} = A + I$, \tilde{D} 是邻接矩阵为 \tilde{A} 的图的度矩阵.

因此,简化后以多个传感器节点特征为输入并带有激活函数的GCN的卷积层更新函数为

$$F^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} F^{(l)} \Theta^{(l)}), \quad (13)$$

其中: l 为图卷积层数, $\Theta^{(l)}$ 为图卷积核的可训练参数矩阵, $F^{(l)}$ 为第 l 层图卷积输入的特征矩阵, σ 为激活函数, $F^{(l+1)}$ 为第 l 层图卷积输出的特征矩阵.

3 提出的方法

3.1 加权HHT图的构造

所提出的基于加权HHT和GCN的故障诊断模型的结构如图1所示,记为加权HHT-GCN (weighted HHT-GCN, WHHT-GCN).虽然基于HHT的特征提取方法能够克服旋转机械振动信号非平稳特性的影响,并自适应地提取特征,但是这样得到的特征仍是欧氏空间的一维向量,不能直接用于GCN网络的输入,需要将其转化为非欧氏空间的图结构.为了充分利用多传感器的信息,用图的节点表示不同的传感器,节点的特征为传感器信号经HHT后提取的特征,节点间的连接反映各个传感器间的关系.其中,确定节点间的连接关系为构建图的核心,详细过程如下:

1) 构造节点特征矩阵:对于第 i 个传感器的一段振动信号 \mathcal{X}_i ,利用HHT进行特征提取,得到如式(9)的特征向量 f_i .进而, N 个传感器特征向量构成的特征矩阵 F 为

$$F = [f_1 \ f_2 \ \dots \ f_N]^T. \quad (14)$$

2) 构造邻接矩阵:邻接矩阵表征图中各个节点的连接关系,利用 K 近邻算法,以节点间的欧氏距离 $\text{Dis}\{V_i, V_j\} = \sqrt{\|f_i - f_j\|}$ 为依据,选择与当前节点最近的 K 个节点作为当前节点的邻居节点,

$$\psi(V_i) = \{V_{ij}\}_{j=1}^K, \quad i = 1, 2, \dots, N, \quad (15)$$

这里: $\psi(V_i)$ 为节点 V_i 邻居节点的集合, V_{ij} 为节点 V_i 的第 j 个邻居节点.进而,邻接矩阵 A 第 i 行 j 列元素

$A_{i,j}$ 的取值为

$$A_{i,j} = \begin{cases} 1, & V_{i,j} \in \psi(V_i), \\ 0, & \text{其他}, \end{cases} \quad i, j \in \{1, 2, \dots, N\}. \quad (16)$$

3) 构造边的权重: 上述步骤将 N 个传感器的振动信号转化为了一个包含 N 个节点的图, 图的节点特征由特征矩阵 F 表示, 图的结构由邻接矩阵 A 表示. 为了体现节点间相互影响的差异, 将边的权重矩阵引入图

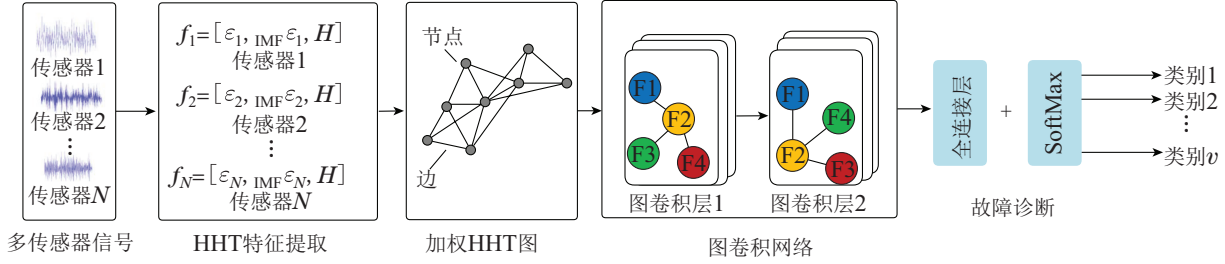


图1 WHHT-GCN故障诊断模型

Fig. 1 WHHT-GCN fault diagnosis model

注1 通过给距离较远节点间的边赋以较小的权值, 距离较近节点间的边赋以较大的权值, 增强了强相关传感器间的相互影响, 将传感器间不同的影响程度体现在了图结构中.

3.2 故障诊断GCN模型设计

1) GCN模型: 利用上节构图方法, 每个包含 N 个传感器振动信号的故障样本都被转化为了一个加权HHT图. 图1中节点代表不同传感器, 节点特征是 f_i , $i = 1, 2, \dots, N$, 整个图的特征矩阵为 F , 图中传感器节点之间的关系由邻接矩阵 A 表示, 边的权重由权重矩阵 W 表示. 这样对样本的故障诊断就被转化为一个图分类任务. 构建两层GCN模型进行图分类, 模型各层的组成及输入输出如下:

$$\begin{cases} Y^{(1)} = \text{GCNConv1}(F, A, W, \Theta^{(1)}), \\ Y^{(2)} = \text{Dropout}(\sigma(Y^{(1)})), \text{训练时}, \\ Y^{(3)} = \text{GCNConv2}(\sigma(Y^{(2)}), A, W, \Theta^{(2)}), \\ Y_{\text{output}} = \text{Globalmaxpooling}(Y^{(3)}), \end{cases} \quad (18)$$

这里: σ 为ReLU激活函数, $\Theta^{(1)}$ 和 $\Theta^{(2)}$ 为训练参数矩阵, Dropout(\cdot)操作通过为节点设置保留概率, 确保节点权重不会过大, 减轻网络过拟合. Globalmaxpooling(\cdot)为全局最大化池化操作.

最后, 将GCN模型的输出接入一个全连接层进行分类, 得到样本的预测标签为

$$\text{Label} = \text{Softmax}(W_{\text{fc}}Y_{\text{output}} + b_{\text{fc}}), \quad (19)$$

这里, W_{fc} 和 b_{fc} 表示全连接层的权重和偏置项.

2) 分类损失函数: 负对数似然(negative log-likelih-

ood, NLL) 损失函数被广泛应用于故障诊断任务, 度量模型诊断输出的故障类别与真实类别的吻合程度,

$$W_{i,j} = \begin{cases} \frac{1}{k}, & j \text{ 是 } i \text{ 的 } k \text{ 近邻且 } k \in \{1, \dots, K\}, \\ 0, & \text{其他}, \end{cases} \quad (17)$$

这里, $i, j \in \{1, 2, \dots, N\}$.

这里, u 为样本个数, y 为网络最后一层隐藏层的输出, $P(y^{(\text{true},j)})$ 为第 j 个样本预测为真的概率.

NLL损失主要通过最大化样本的对数似然来进行优化. 然而在一些问题上, 如类内样本分散、类间样本重合等情况, NLL损失不能很好地起到优化效果. 这是因为NLL损失只关注如何使得正确类别的预测概率最大, 并没有考虑同类样本的聚合性和异类样本的分散性.

为了进一步提高故障诊断的精度, 对损失函数进行改进, 增加两个正则项 Loss^1 和 Loss^2 , 即

$$\text{Loss}^1 = \frac{1}{2} \sum_{i=1}^v \sum_{j=1}^u \|P(y^{(i,j)}) - C^{(i)}\|^2, \quad (21)$$

$$\text{Loss}^2 = \frac{1}{2} \sum_{i=1}^v \sum_{j=i+1}^v \|C^{(i)} - C^{(j)}\|^2, \quad (22)$$

这里, v 为样本的故障种类, $P(y^{(i,j)})$ 为第 j 个样本预测为第 i 类故障的概率, $C^{(i)}$ 为样本被预测为第 i 类故障的概率均值, 即

$$C^{(i)} = \frac{1}{u} \sum_{j=1}^u P(y^{(i,j)}), \quad i = 1, 2, \dots, v. \quad (23)$$

Loss^1 通过最小化同类样本标签与均值的距离来使同类样本更加聚合, Loss^2 通过最大化不同类样本均值间的距离来使不同类样本更加分散, Loss^1 和 Loss^2 结合有效地弥补了NLL损失的不足, 则最后改进后的损失函数 $\text{Loss}^{\text{total}}$ 为

$$\text{Loss}^{\text{total}} = \text{Loss}^0 + \alpha\text{Loss}^1 - \beta\text{Loss}^2, \quad (24)$$

这里, α 和 β 为相应权重系数.

4 故障诊断整体过程

本文所提出的故障诊断方法的详细过程如图2所示, 包括数据的获取、加权HHT图的构建、GCN模型的搭建以及故障分类. 首先, 由部署在设备不同位置的多个传感器对故障信号进行采集, 得到多传感器振动信号. 其次, 对每个传感器的振动信号利用HHT进行特征提取. 进而, 以传感器为节点, 以传感器特征为

节点特征, 构造HHT图, 并依据节点特征间的距离建立节点间的联系和分配连接边的权重, 反映传感器之间的相互影响. 最后, 以加权HHT图为输入, 故障类型为输出, 构建GCN图分类网络实现故障诊断. 具体应用中, 首先需要基于多传感器采集到的历史数据利用滑窗法构建故障样本, 然后将多传感器故障样本转化为加权HHT图的形式, 进而利用历史故障样本对GCN网络模型中的参数进行离线训练, 最后将训练好的模型用于在线故障诊断. 所提出的方法故障诊断过程的全流程伪代码如算法1所示(见表1).

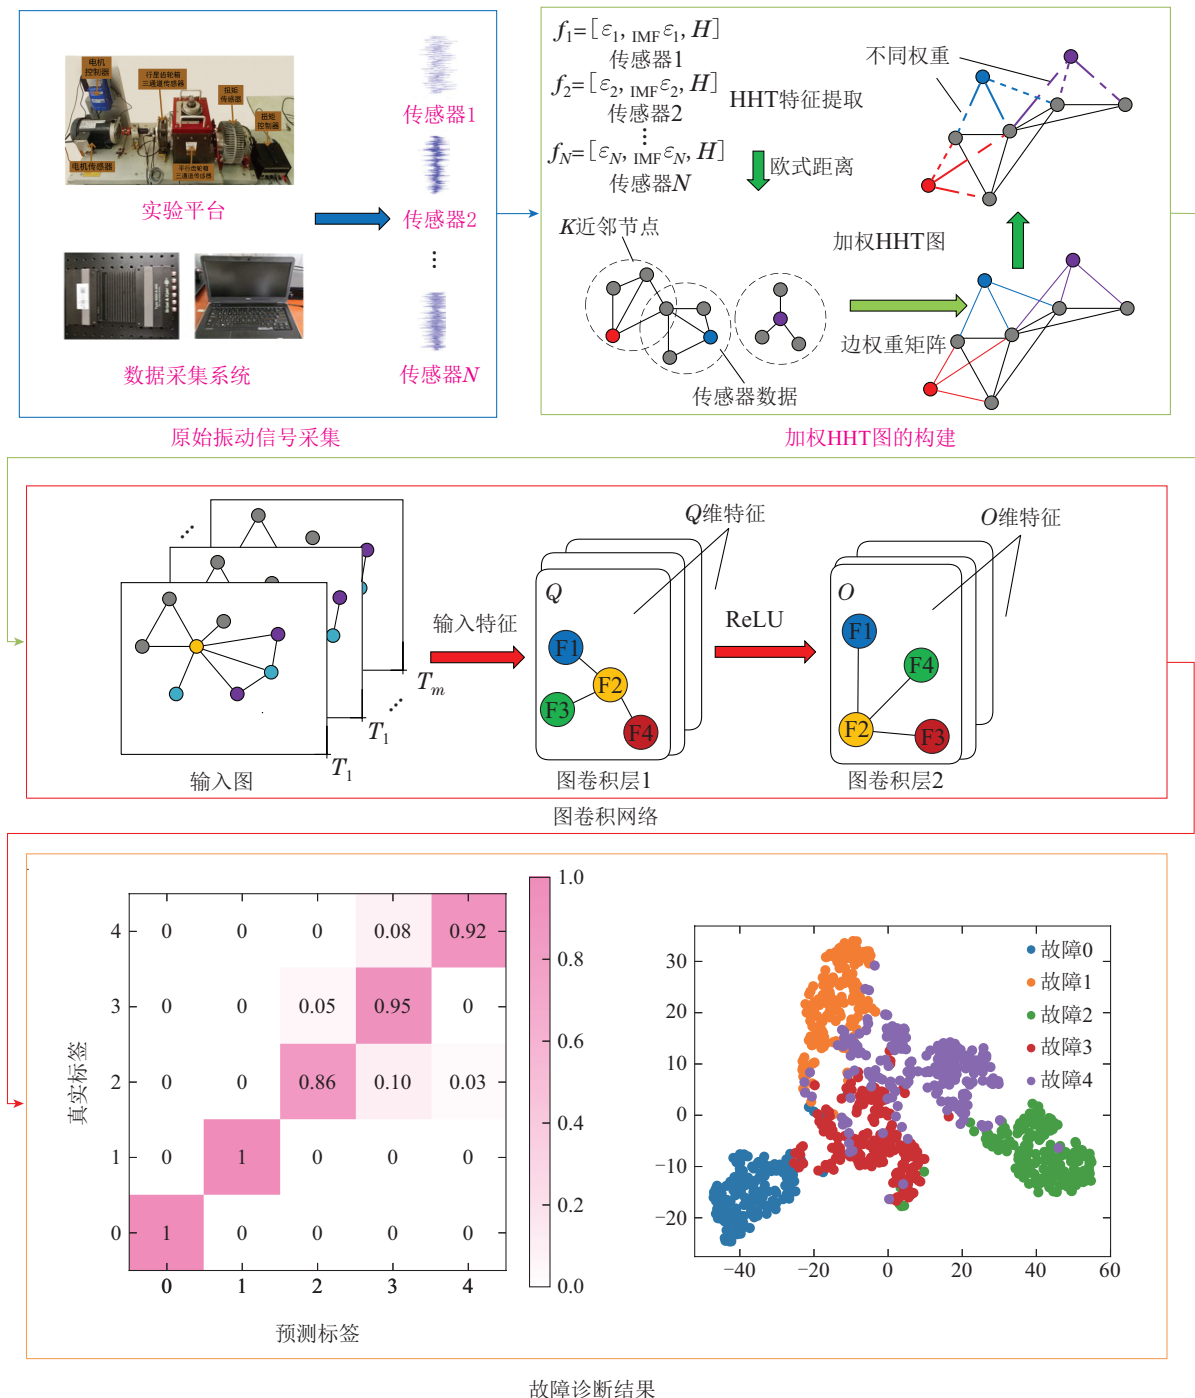


图2 故障诊断整体过程

Fig. 2 Whole process of fault diagnosis

表1 算法1故障诊断流程

Table 1 Algorithm 1 fault diagnosis process

A. 构造HHT加权图

输入: 多传感器数据 $\mathcal{X}_1, \mathcal{X}_2, \dots, \mathcal{X}_N$

输出: 图 $G = \{V, S, A, F\}$, 权重矩阵 W

1 每个传感器信号 \mathcal{X}_i 按式(1)进行EMD分解, 并根据式(3)–(7)计算希尔伯特边际谱

2 利用式(2)和式(8)获取EMD特征 \mathcal{E}_{IMF} 和边际谱特征 \mathcal{E}_{H} , 基于式(9)得到组合特征向量 $f \leftarrow \mathcal{E}_{\text{IMF}} + \mathcal{E}_{\text{H}}$

3 利用所有传感器节点特征向量构造特征矩阵 F

4 计算节点间欧氏距离 $\text{Dis}(f_i, f_j)$, 得到每个节点的 K 近邻节点集 $\psi(V_i)$, 建立边的链接 S 并利用式(16)计算邻接矩阵 A

5 用图的节点表示不同传感器, 构造节点集合 V , 进而构造图 $G = \{V, S, A, F\}$, 并依据式(17)计算权重矩阵 W

B. 故障诊断

输入: 图 G , 权重矩阵 W , 训练次数 T

输出: 故障分类结果Label

1 划分训练集和测试集: $G_{\text{train}}, G_{\text{test}}$

2 基于权重矩阵 W , 按照式(18)构造加权GCN

3 for $i = 1$ to T

4 在 G_{train} 上训练模型

5 Label $\leftarrow \text{Softmax}(\text{GCN}(G_{\text{train}}))$

6 依据式(24)取损失函数为 $\text{Loss}^{\text{total}}$

7 反向传播更新参数

8 end For

9 由式(19)得Label = $\text{Softmax}(\text{GCN}(G_{\text{test}}))$

5 实验验证

本节利用实验数据验证所提出的WHHT-GCN模型的有效性. 为避免偶然性, 重复10次实验以获得平均值.

5.1 数据集介绍

实验使用来自东南大学的公开数据集. 该数据集提供了转速/负载为1200 (r·min)/0V工况下轴承和齿轮箱发生5种故障类型时的数据, 其中, 轴承部分故障包含“健康状态”、“滚动体故障”、“内外圈复合故障”、“内圈故障”和“外圈故障”故障, 齿轮箱部分故障包含“健康状态”、“齿上裂纹”、“齿轮断齿”、“根部裂纹”和“表面磨损”故障. 电机和齿轮箱由3个加速度传感器进行监测, 可获得8个通道的采样数据.

5.2 故障诊断结果

以轴承内圈故障情况下通道1信号为例, 信号经EMD分解后各阶IMF分量如图3所示.

从图3可以看出, IMF分量在第5个之后与原始信号的相关性已经很低, 所含的有用信息也很少. 因此, 计算前5个IMF分量的归一化能量, 得到IMF能量特征向量. 对前5个IMF分量进行希尔伯特变换, 依据式(6)得到希尔伯特时频谱, 并进一步按照式(7)对时频谱在时间上进行积分可得如图4所示的边际谱. 从图中可

以看出, 大部分频谱分布在0~2500 Hz的频率区间. 为此, 以每500 Hz作为一个子区间将上述频率范围划分为5个子区间, 然后计算各子区间的归一化能量即可得到边际谱特征.




图3 EMD分解结果

Fig. 3 EMD decomposition results




图4 边际谱分析

Fig. 4 Marginal spectral analysis


对8通道数据分别进行上述特征提取过程, 进而将样本数据转化为具有8个节点的加权HHT图. GCN模型训练中训练集和测试集的比例为4:1, 故障诊断任务为5种类型的图分类任务. 图5给出了模型在测试集上的故障诊断结果. 从图5中可以看出, 所提出的方法在轴承和齿轮箱两个数据集上都取得了较好的效果. 为

为了使结果更加直观, 采用 t-SNE 算法对诊断结果进行可视化处理, 如图6所示. 由图6可以看出, 各类故障得到了明显的区分.


5.3 参数影响分析

加权图构建过程中利用 K 近邻算法来确定图中各节点间的关系. 其中 K 值的选择至关重要. K 取值太大, 图中大部分节点都会彼此连接, 不仅会削弱重要节点的影响, 也大大增加了计算成本. 反之, K 值太小, 则无法获得足够的邻居节点信息. 图7给出了实验中 K 取不同值时模型的故障诊断准确率. 由图可见, K 取值为3时, 准确率最高.

GCN网络每层输出节点的特征维数也是网络实现中的可调参数, 记为 Q . 实验中可利用对比实验的方式来确定 Q 的取值. 不同大小 Q 值对应的模型诊断精度和损失函数的下降情况分别如表2和图8所示. 从中可以看出, 在收敛到同一水平损失值附近的前提下, Q 为9时所需的训练次数最少, 收敛速度最快, 诊断精度最高. 因此, 实验中 Q 取值为9.




(a) 轴承




(b) 齿轮箱

图 5 模型分类结果

Fig. 5 Model classification results



(a) 轴承



(b) 齿轮箱

图 6 分类结果 t-SNE 可视化

Fig. 6 Visualization of classification results using t-SNE




图 7 不同 K 值对应的准确率

Fig. 7 Accuracy of different K values

表 2 不同尺寸隐藏层的性能

Table 2 Performance with different hidden layer sizes

尺寸	准确率 / %	损失值	训练次数
6×6	76	4.8198×10^{-3}	161
7×7	84	4.8196×10^{-3}	168
8×8	88	4.8199×10^{-3}	192
9×9	94.4	4.8197×10^{-3}	6
10×10	90.9	4.8184×10^{-3}	16
11×11	86.8	4.8087×10^{-3}	21
12×12	82.5	4.8190×10^{-3}	57

5.4 与其他方法的比较

为进一步验证本文所提出方法的优越性,在轴承数据集上,将本文提出的方法与其他方法进行了对比,包括随机森林(random forest, RF)、CNN以及残差网络(residual network, ResNet).不同模型的结构参数如表3所示.表4给出了上述方法的故障诊断结果.




图8 不同 Q 值对应的损失值

Fig. 8 Loss function corresponding to different Q values

表3 不同模型的结构参数

Table 3 Structural parameters of different models

模型	输入尺寸	模型的结构
RF	8*1024	RF: 树的数目(10); 最大深度(2)
CNN	8*1024	CNN: 1-10-10; 全连接层: 10-5
ResNet	8*1024	ResNet: 1-10-10; 全连接层: 10-5
WHHT-GCN	8*10	GCN: 10-9-5; 全连接层: 20-5

表4 不同模型的性能

Table 4 Performance of different models

模型	准确率/%	精确率/%	召回率/%	F1-分数/%
RF	85	87	87	86
CNN	84	91	84	81
ResNet	88	92	86	86
WHHT-GCN	94.4	94.8	94	94

从表4可以看出,所提出的方法在各种分类指标上都取得了最佳的效果,这证明了所提出方法的优越性.

5.5 消融实验

为了分析所提出的故障诊断模型各部分的有效性,在轴承数据集上进行了消融实验研究,分析了模型中加权图和改进的故障损失函数对模型故障诊断效果的影响.实验结果如图9所示.因为加权图包含更多的结构信息,更能体现出图中各节点间的关系,因此,采用加权图作为模型输入的网络具有更高的精度.此外,图9的结果也说明,改进的损失函数使模型诊断的准确率得到了提高.

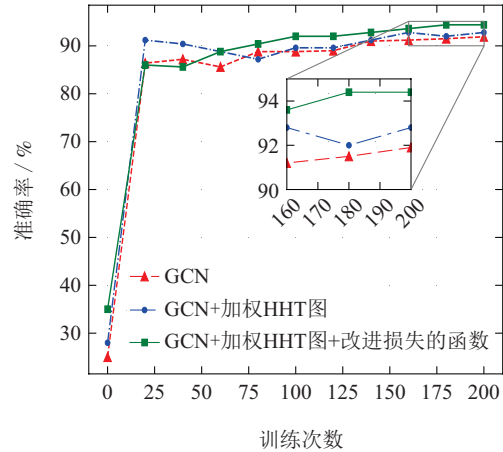


图9 消融实验结果.

Fig. 9 Results of ablation experiments

6 总结

本文提出了一种新的基于加权HHT图和改进GCN模型的多传感器旋转机械故障诊断方法.与传统方法不同,使用HHT可以克服信号非线性非平稳性带来的影响,自适应地提取信号特征.此外,与已有工作的构图方法不同,本文以传感器为节点,以提取的传感器信号特征为节点特征,利用 K 近邻算法构建加权HHT图,并依据节点间的距离分配边的权重.最后,搭建两层GCN模型从加权HHT图中学习故障特征进而实现故障诊断.实验结果表明,所提出的故障诊断方法以更小的模型复杂度在各种性能指标下都具有满意的故障诊断精度.

在本文工作的基础上,后续研究可重点考虑其他的构图权重分配方式以进一步提高故障诊断的效果.

参考文献:

- [1] HE Xiao, GUO Yaqi, ZHANG Zhao, et al. Active fault diagnosis for dynamic systems. *Acta Automatica Sinica*, 2020, 46(8): 1557 – 1570. (何潇, 郭亚琦, 张召, 等. 动态系统的主动故障诊断技术. 自动化学报, 2020, 46(8): 1557 – 1570.)
- [2] HUAI Wuxiang, GAO Ming, SHENG Li. Intermittent fault detection for linear stochastic systems under event-triggered transmission mechanism. *Control Theory & Applications*, 2023, 40(9): 1602 – 1610. (怀务祥, 高明, 盛立. 事件触发传输机制下线性随机系统的间歇故障检测. 控制理论与应用, 2023, 40(9): 1602 – 1610.)
- [3] XU Shuiqing, WANG Jian, HU Youqiang, et al. Open-circuit fault diagnosis of single-phase three-level rectifier in high-speed train traction system based on adaptive sliding mode observer. *Control Theory & Applications*, 2023, 40(11): 1920 – 1930. (许水清, 王健, 胡友强, 等. 基于自适应滑模观测器的高铁牵引系统单相三电平整流器开路故障诊断. 控制理论与应用, 2023, 40(11): 1920 – 1930.)
- [4] MA Liling, GUO Jian, WANG Shoukun, et al. Multi-source sensor fault diagnosis method based on improved CNN-GRU Network. *Transactions of Beijing Institute of Technology*, 2021, 41(12): 1245 – 1252. (马立玲, 郭建, 汪首坤, 等. 基于改进CNN-GRU网络的多源传感器故障诊断方法. 北京理工大学学报, 2021, 41(12): 1245 – 1252.)

- [5] SHAO H D, XIA M, HAN G J, et al. Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images. *IEEE Transactions on Industrial Informatics*, 2021, 17(5): 3488 – 3496.
- [6] NAI Yongqiang, YANG Qingyu, ZHOU Wenxing, et al. Adaptive CFB control for a class of nonlinear systems with intermittent actuator faults. *Acta Automatica Sinica*, 2022, 48(10): 2442 – 2461. (乃永强, 杨清宇, 周文兴, 等. 具有间歇性执行器故障的非线性系统自适应CFB控制. *自动化学报*, 2022, 48(10): 2442 – 2461.)
- [7] HAN K, WANG Y H, ZHANG C, et al. Autoencoder inspired unsupervised feature selection. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Calgary, Canada: IEEE, 2018: 2941 – 2945.
- [8] ZHANG Siyuan, JI Hongquan, LIU Yang. Bearing fault diagnosis based on ISCNN-LightGBM. *Control Theory & Applications*, 2023, 40(4): 753 – 760. (张思源, 纪洪泉, 刘洋. 基于ISCNN-LightGBM的轴承故障诊断. *控制理论与应用*, 2023, 40(4): 753 – 760.)
- [9] AN Y Y, ZHANG K, LIU Q, et al. Rolling bearing fault diagnosis method base on periodic sparse attention and LSTM. *IEEE Sensors Journal*, 2022, 22(12): 12044 – 12053.
- [10] HAN Y M, QI W, DING N, et al. Short-time wavelet entropy integrating improved LSTM for fault diagnosis of modular multilevel converter. *IEEE Transactions on Cybernetics*, 2022, 52(8): 7504 – 7512.
- [11] YE S, JIANG J G, LI J J, et al. Fault diagnosis and tolerance control of five-level nested NPP converter using wavelet packet and LSTM. *IEEE Transactions on Power Electronics*, 2020, 35(2): 1907 – 1921.
- [12] ZHAO B, ZHANG X M, ZHAN Z H, et al. Deep multi-scale adversarial network with attention: A novel domain adaptation method for intelligent fault diagnosis. *Journal of Manufacturing Systems*, 2021, 59: 565 – 576.
- [13] WANG H, XU J W, YAN R Q, et al. A new intelligent bearing fault diagnosis method using SDP representation and SE-CNN. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(5): 2377 – 2389.
- [14] WANG H, LIU Z L, PENG D D, et al. Feature-Level attention-guided multitask CNN for fault diagnosis and working conditions identification of rolling bearing. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 33(9): 4757 – 4769.
- [15] LIU X Y, ZHAO Z Y, ZHANG Y H, et al. Social network rumor detection method combining dual-attention mechanism with graph convolutional network. *IEEE Transactions on Computational Social Systems*, 2023, 10(5): 2350 – 2361.
- [16] ZHU J W, HAN X, DENG H H, et al. KST-GCN: A knowledge-driven spatial-temporal graph convolutional network for traffic forecasting. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(9): 15055 – 15065.
- [17] MARREDDY M, OOTA S R, VAKADA L S, et al. Multi-task text classification using graph convolutional networks for large-scale low resource language. *International Joint Conference on Neural Networks (IJCNN)*. Padua, Italy: IEEE, 2022: 1 – 8.
- [18] LI C Y, MO L F, YAN R Q. Fault diagnosis of rolling bearing based on WHVG and GCN. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3519811.
- [19] FONG S, HARMOUCHE J, NARASIMHAN S, et al. Mean shift clustering-based analysis of nonstationary vibration signals for machinery diagnostics. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(7): 4056 – 4066.
- [20] YUAN Z H, MA Z Q, LI X, et al. A multichannel MN-GCN for wheelset-bearing system fault diagnosis. *IEEE Sensors Journal*, 2023, 23(3): 2481 – 2494.
- [21] ZHANG Cheng, LÜ Peichen, YI Haidi, et al. Fault detection approach using random Fourier feature dissimilarity. *Control Theory & Applications*, 2022, 39(7): 1251 – 1260. (张成, 吕佩琛, 伊海迪, 等. 随机傅里叶特征相异度的故障检测算法. *控制理论与应用*, 2022, 39(7): 1251 – 1260.)
- [22] ZHU Qinyue, HE Haihao, LI Feng, et al. A fault diagnosis method of helicopter gearbox based on short-time fourier transform and deep convolutional neural network. *Failure Analysis & Prevention*, 2022, 17(1): 1 – 8. (朱沁月, 何海昊, 李峰, 等. 基于短时傅里叶变换和深度卷积神经网络的直升机齿轮箱故障诊断方法. *失效分析与预防*, 2022, 17(1): 1 – 8.)
- [23] WEN Zhupeng, CHEN Jie, LIU Lianhua, et al. Fault diagnosis of wind power gearbox based on wavelet transform and improved CNN. *Journal of Zhejiang University (Engineering Science)*, 2022, 56(6): 1212 – 1219. (温竹鹏, 陈捷, 刘连华, 等. 基于小波变换和优化CNN的风电齿轮箱故障诊断. *浙江大学学报(工学版)*, 2022, 56(6): 1212 – 1219.)
- [24] GUO M F, YANG N C, CHEN W F. Deep-learning-based fault classification using Hilbert-Huang transform and convolutional neural network in power distribution systems. *IEEE Sensors Journal*, 2019, 19(16): 6905 – 6913.
- [25] ZHU C Y, CAO T Y, ZHAO X G, et al. A time-frequency domain detection method for measurement data of non-stationary signals based on optimized Hilbert-Huang transform. *IEEE Instrumentation and Measurement Magazine*, 2023, 26(2): 29 – 39.
- [26] YANG Q Y, RUAN J J, ZHUANG Z J, et al. Fault identification for circuit breakers based on vibration measurements. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(7): 4154 – 4164.
- [27] GUO K, HU Y L, QIAN Z, et al. Dynamic graph convolution network for traffic forecasting based on latent network of laplace matrix estimation. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(2): 1009 – 1018.
- [28] LI T F, ZHAO Z B, SUN C, et al. Multireceptive field graph convolutional networks for machine fault diagnosis. *IEEE Transactions on Industrial Electronics*, 2021, 68(12): 12739 – 12749.

作者简介:

胡艳艳 副教授, 博士生导师, 目前研究方向为设备智能故障诊断和预测, E-mail: huyanyan@ustb.edu.cn;

衣晓捷 硕士研究生, 目前研究方向为设备智能故障诊断, E-mail: yixiaojie@xs.ustb.edu.cn;

彭开香 教授, 博士生导师, 目前研究方向为工业智能与智能制造、故障诊断与容错控制, E-mail: kaixiang@ustb.edu.cn.