

基于深度学习的柴油发动机振动监测 测点布局优化研究

李利泉

(北京化工大学, 北京 100029)

摘要: 随着工业技术的不断进步, 深度学习作为人工智能的重要分支, 为各领域带来了新的可能性。本文研究了柴油发动机振动监测位置的优化布局, 专注于解决振动监测中的数据重叠和相互干扰问题。通过探讨柴油机传感器的最佳位置和数量, 提出了一种基于图池化神经网络的传感器布局优化方法。将传感器测点视为图的节点, 利用图卷积层处理邻接矩阵, 得到每个节点的特征向量。通过信息熵和独立性方法对特征向量进行筛选和排序, 选取具有代表性的特征向量作为重要节点。最后, 在池化层中进行分类和筛选, 考虑了覆盖范围和成本等因素, 从而确定最佳传感器布置位置和数量。

实验结果表明, 所提出的图池化网络模型能够有效地优化传感器测点布局, 并具有较高的准确性和稳定性。该方法不仅适用于柴油发动机振动监测, 还可以推广到其他领域需要进行传感器布置优化的问题中。

关键词: 柴油发动机; 图池化; 测点优化

分类号:

Optimization of diesel engine vibration monitoring point layout based on deep learning

Li Li Quan

(Beijing University of Chemical Technology, Beijing 100029)

Abstract: With the continuous progress of industrial technology, deep learning, as an important branch of artificial intelligence, has brought new possibilities to various fields. In this paper, the optimal location of diesel engine vibration monitoring is studied, focusing on the problem of data overlap and mutual interference in vibration monitoring. By discussing the best position and number of sensors on diesel engine, a method of sensor layout optimization based on graph pool neural network is proposed. In this method, the sensor points are regarded as the nodes of the graph, and the adjacency matrix is processed by the convolution layer of the graph, and the eigenvector of each node is obtained. The feature vectors are screened and sorted by information entropy and independence methods, and the representative feature vectors are selected as important nodes. Finally, classification and screening are carried out in the pooling layer, taking into account factors such as coverage and cost, so as to determine the optimal sensor placement and number.

The experimental results show that the proposed graph pool network model can effectively optimize the layout of sensor measuring points, and has high accuracy and stability. This method is not only suitable for diesel engine vibration monitoring, but also can be extended to other problems requiring sensor layout optimization.

Keywords: Diesel engine; Graph pooling ;monitoring point optimization

1 绪论

近些年来国内外学者都在不断开展监测测点优化方面的研究,研究过程经历了从机器学习到深度学习,最后发展到图卷积及图池化阶段。

首先机器学习是利用计算机算法和统计模型逐步提高完成特定任务的能力。其诸多算法主要包括了决策树算法,贝叶斯算法,向量机算法及遗传算法等。通过算法和传感器布局的融合加之以优化,目前已在在该领域取得不菲的成果。

其中北京邮电大学的张忠坤提出了一种新的基于蚁群优化的改进决策树算法,通过将蚁群算法应用于决策树的生成过程,使决策树得规模得到降低,并且生成过程得到了优化,也提高了生成决策树的预测精度^[1]。西安科技大学的刘志宏等人提出了一种基于贝叶斯的多传感器检测跟踪联合处理的方法,该方法可根据已有数据转化为动态模型并用于精确预测第 N 组数据^[2]。西安大学陈海霞等人针对支持向量机的参数优化问题,利用人工蜂群算法这种方法来优化支持向量机的传感器节点定位,并构建了相应模型,该法可反映当前传感器节点的位置,并获得较为精确的传感器节点定位效果^[3]。

而深度学习是一种基于人工神经网络的机器学习技术,其本质是一种模拟人类大脑结构和工作方式的算法。通过多层次的神经网络,深度学习可以实现对数据的自动分析和识别,从而在图像识别、语音识别、自然语言处理等任务中发挥着重要作用。

其中西安电子科技大学的李长乐等人提出了一种有向传感器网络优化部署系统和方法,使用粒子群算法搜索最小曝光路径,实现在最优部署点部署有向传感器,最终得到了传感器的最优部署方案^[4]。张丹等人通过径向基网络(RBF),结合神经网络可以在非线性映射发挥作用的的优势,最终实现了任意一个数据在连续函数上的拟合接近,这对传感器之间的非线性拟合有着重要意义^[5]。但是上述方法存在以下缺点:1)没有明确考虑多个传感器之间的相互作用,所应用的传感器数目较少;2)它们更偏向于建模时间的依赖性,而忽略了传感器的空间依赖性。

如今,基于深度学习以及卷积神经网络,图卷积神经网络(GCN)逐渐进入人们的视野,并凭借其强大的特征提取能力而得到广大研究者的重视。

其中在图卷积神经网络方面浙江大学赵健程等人提出了一种基于全量测点的估计的监测模型,并且他们还提出了一种多核的图卷积网络,使得对测点间耦合关系建模不充分的问题得到解决,最终实现了全测点的同步工况估计^[6]。姚晓宇等人构建了一种基于三重注意的深度卷积循环网络(TADCRN)的模型,并最终

表明,该方法优于传统的机器学习方法和深度学习方法^[7]。王磊等人提出了一种门控的图卷积网络(GGCN),并将该网络用于多传感器信号融合和 RUL 预测。验证了基于 GCNN 的预测框架的有效性^[7]。

随着科学技术的发展,图池化作为一种深度学习模型,因其不仅考虑了节点之间的局部连接关系,还利用了全局信息和图的拓扑结构,并且在处理非欧几里得数据方面具有很大潜力。所以越来越多的研究学者开始对图池化神经网络进行研究。

其中 Junhyun Lee 等人提出了一种基于 self-attention 的图池化方法。使用图卷积的 self-attention 使得其池化方法同时考虑了节点特征和图的拓扑结构,通过使用合理数量的参数,在基准数据集上获得了较好的图分类性能^[9]。国内学者陈雪峰等人提出了层次注意图卷积网络(HAGCN)对传感器网络进行建模,并且在 HAGCN 中设计了一种正则化的自注意图池,最终实现传感器的有效信息融合^[10]。

总的来说,图池化神经网络综合了前几种方法的优点。通过分层池化,同时考虑节点特征和图的拓扑结构,它具有合理的复杂度和端到端表示学习能力。此外,它还可以通过调整层数、卷积核大小、池化方式等参数来适应不同任务需求,并能够自适应地学习特征表示。由于其具有较强的全局信息处理能力,因此对于噪声和异常值具有较好的鲁棒性。本文基于上述原因选择了图池化神经网络作为传感器布局优化的基础框架。通过该框架,我们成功地将传感器测点映射为图节点,借助卷积层有效处理邻接矩阵,获得了具有代表性的节点特征向量。信息熵和独立性方法的引入使得我们能够精确筛选和排序特征,选取最具信息量的节点,从而实现了在池化层中的分类和筛选。

2 图池化神经网络研究

2.1 图神经网络定义

图神经网络(GNN)是一种深度学习模型,它可以将神经网络模型应用于图数据结构。其中常见的图神经网络有图卷积神经网络(GCN)和图注意力网络(GAT)。在处理图像、文本等二维数据的神经网络结构基础上应用图结构数据是该网络的本质。与传统的 CNN 卷积神经网络不同,GNN 主要研究对象为图数据,其可以在节点和边上执行操作,并且具有对局部信息进行聚合的能力。这使得 GNN 能够学习节点之间的关系和整个图的全局结构。目前研究者们在该领域已经进行了许多尝试。

GNN 通常由多个层组成，并且每个层都包含一个节点嵌入器和一个边嵌入器。在每个层中，节点嵌入器将节点特征转换为低维向量表示，并将其传递给邻居节点。边嵌入器则是将边特征转换为向量表示，并传递给相邻节点。然后，这些向量被聚合以更新每个节点的表示形式。总之，图神经网络是一种能够处理复杂的非欧几里得结构数据的深度学习模型。

2.1.1 图数据

在研究 GNN 之前，我们需了解图数据的特性。图数据类比于 CNN 处理数字图像和 RNN 处理自然语言序列信息。数字图像由像素组成的矩阵构成，每个像素有数值表示亮度或颜色。卷积操作通过平移卷积核在图像上实现全局滑动，这使得卷积神经网络对数字图像数据具有平移不变性。相较之下，RNN 是一维结构模型，通过多门操作实现前后信息的相互影响，适用于捕捉序列特征完成机器学习等任务。

然而，实际应用中的空间数据结构通常是不规则和非欧式的，传统的 RNN 和 CNN 无法有效处理这些数据。因此，GNN 作为一种处理非欧式数据结构的研究方法应运而生。




图 2-1 图数据的结构图

2.1.2 特征矩阵

在图神经网络中，每个节点都可以有一个用于描述该节点属性信息的特征矩阵。这个特征矩阵可以含有一些离散或连续的特征值，如节点的颜色、位置、大小等等。这些特征值可以被用来计算节点之间的相似度或距离，并且在图神经网络中起到了非常重要的作用。一般情况下，特征矩阵是一个二维数组，其中每行代表一个节点，每列代表一个特征的维度。

2.1.3 邻接矩阵




图 2-2 邻接矩阵示例图

在图神经网络中，邻接矩阵通常被用来计算节点之间的相似度或距离，并且作为计算传播规则和更新节点特征的重要工具。同时，在许多基于邻接矩阵的图卷积神经网络中，邻接矩阵也被用来计算每个节点的聚合的权重大小。

2.2 图卷积网络

图卷积神经网络（GCN）是基于卷积神经网络（CNN）的图神经网络模型，将 CNN 的思想扩展到非欧几里得空间。不同于传统 CNN，GCN 通过对图上节点和边进行卷积操作，实现节点特征的提取和学习。在 GCN 中，每个节点与相邻节点相连，拥有一个特征向量。通过多层卷积操作，GCN 逐渐将全局信息融合到每个节点的特征中，实现对整张图的学习和预测。简言之，GCN 设计了一种巧妙的公式，能有效分类和边预测图数据，得到图的嵌入表示等信息。

GCN 凭借其强大的特征提取能力而受到极大关注，而 GCN 网络框架也在近些年得到了广泛的应用和研究，其网络框架通常包括输入层、图卷积层、readout 层和输出层等部分。

2.3 图池化网络

图池化（graph pooling）是一种将图形数据降维的方法，类似于在卷积神经网络中使用池化层。图池化可以通过对节点或边进行聚合来减少图形数据的规模，从而提高计算效率和模型泛化能力。

这里以本文所使用的 Top-K-Pooling 为例介绍：Top-K-Pooling 是一种基于节点重要性排序的图池化方法。它首先通过 GCN 层生成每个节点的嵌入向量，然后根据嵌入向量中某些特定维度上的值进行排序。接着，选取排名靠前的 K 个节点作为新图形数据中的节点，并且根据这些节点之间的连接信息重构新邻接矩阵。简单来说，就是对图像进行剪去枝条的操作，选择分低的节点进行剔除，然

后将剩下部分重新组合成一个新的图。如图 2-9 所示 y 是各个节点的得分， K 是保留的点的个数，保留得分高的点，剪掉不重要的点，最终实现方案的优化。

其传播规则如下：

在图卷积神经网络中，图池化层的传播规则通常是基于聚合操作的，通过该规则可以减少对输入信息的采样，从而减少参数数量和计算量，同时保留重要的特征信息。具体来说，对于一个输入图 $G = (V, E)$ 和其节点特征矩阵 H ，图池化层会首先计算每个节点的嵌入向量 h_i^l （其中 i 表示当前层数），然后根据一定的聚合策略将多个节点聚合成一个新的超节点。

以本文所使用的 Top-K Pooling 为例，其传播规则为：

（1）对于输入特征图 X 中的每个位置 (i, j) ，取其周围区域（如 3×3 或 5×5 ）内所有元素构成一个向量 V_{ij} 。

（2）对于向量 V_{ij} 中的所有元素，按照大小进行排序，取其中前 K 个最大值所组成的集合 $top - K(V_{ij})$ 。

（3）如果输入特征图 X 是多通道的，则对于每个通道分别执行上述操作，并将得到的结果在通道维度上进行拼接。

（4）将所有位置得到的结果组成一个新的特征图 Y 作为输出。

由此 Top-K-Pooling 操作可以表示为以下公式：

$$Y_{ij}^c = \left\{ \max topK(V_{ij}^c), \text{if } X_{ij}^c \in V_{ij}^c; 0, \text{otherwise} \right\} \quad (2-1)$$

3. 基于图池化网络的测点布局优化模型构建

3.1 图池化网络传感器优化模型网络框架

本研究构建了名为 GraphPoolNet 的图池化神经网络，其中包含了两个图卷积层（GCNConv），一个全局均值池化层（global_mean_pool）和两个全连接层（Linear）。输入包含点的特征 node feature x ，节点之间的连接关系 edge_index，节点之间连接的属性 edge_attr，以及 batch 表示每个节点属于哪个图。具体来说，这个模型先通过 GCNConv 对输入进行特征提取，并利用传感器的信息熵、正弦独立性得出各传感器综合分数，然后通过 TopKPooling 对节点进行池化，保留得分最高的一部分节点，减少计算量。池化后的结果再经过一层 GCNConv 进行特征提取，然后全局均值池化，最后通过两个全连接层输出分类结果。在过程中，还使用了一个线性层和得分计算，用于计算节点得分并进行池化。

最后使用以均方误差损失函数和 Adam 优化器对网络进行训练，并计算训练

过程中的损失和准确率，以求在传感器组里选择最好的 k 个传感器组合，构建的网络模型结构如图 3-1：




图 3-1 网络模型结构图

其网络框架主要分为以下部分：

(1) 输入层：这部分对传感器采集到的原始振动信号进行预处理，包括去噪、降维、归一化等操作，以提高数据质量和降低复杂度。

(2) 图池化层：采用不同的图池化方法对特征图进行下采样，减少参数数量和计算复杂度，增强模型的鲁棒性和泛化能力。本文采用 Top-K-Pooling 池化方法选取最佳传感器布置位置和布置数目。

(3) 图卷积层：使用 GCN 算法对图形数据进行卷积操作，提取特征信息，并通过多层卷积和非线性激活函数进行深度学习训练。GCN 利用图结构的局部邻居信息，将矩阵卷积运算扩展到图结构数据，实现类似 CNN 的卷积操作作用于节点的嵌入表示。核心思想是定义每个节点的邻居，将节点自身的特征向量与邻居节点的特征向量进行卷积运算，然后合并结果。多层 GCN 可提取更复杂的特征。

(4) 图读出层：用于将整个图的信息聚合到一个向量中，关键过程是将图信息转化为全局向量表示，可选择不同类型的池化方式以提升性能。

(5) 全连接层：经过多次卷积和池化后，将特征图转换为向量形式，通过

全连接层执行分类或回归等任务。

(6) 输出层： 根据需求选择相应输出层，使用适当损失函数衡量模型预测结果与真实结果的差异，并通过反向传播算法更新模型参数。

3.2 测点布局优化指标

3.2.1 信息熵

根据 Shannon 信息论的定义，某件事出现的概率为 p ，则信息量的定义如下：

$$I(x) = -\log_2 p(x) (0 \leq p \leq 1) \quad (3-1)$$

信息熵定义为所有单独事件信息量的加权和，其计算公式如下：

$$H(x) = E(I(x)) = -\sum p(x) \log_2 p(x) \quad (3-2)$$

时频图像的信息熵大小反映了其包含的信息量和信息的复杂度。较高的信息熵意味着图像包含更多、更复杂的信息，而较低的信息熵则表示图像信息相对简单或少。因此，通过分析时频图像的信息熵大小，可以判断信号的特征和过程的复杂度。本研究以时频图像的信息熵为指标，衡量各配气动作在各传感器振动响应中的信息量。

本文提出对应计算公式如下：

$$S_{FIR} = \text{fillter}_{high}(s, 3000) \quad (3-3)$$

$$S = \text{stft}(S_{FIR}) \quad (3-4)$$

其中 s 为传感器振动信号， fillter_{high} 为高通滤波器， S_{FIR} 为滤波信号， stft 为短时傅里叶变换函数， S 为时频图像。

3.2.2 独立性

柴油机相邻缸体距离较近，振动冲击互相传递，相邻传感器收集到的信号往往存在一定程度的相关性，这会对数据处理和信息提取造成不利影响。对于连体式缸盖，1 个传感器测点即可监测到多个缸的振动冲击，导致传感器组对一个配气动作引起的冲击重复监测，故分析相邻传感器之间信号的独立性，也是传感器优化的一个重要指标。

两个向量的相似性通常使用余弦相似度来度量，相反的用正弦相似度度量向量的独立性，本研究采用正弦相似度计算两个传感器振动信号包络波形的独立性，对应公式见下：

$$\sin_{xy} = \frac{|x \times y|}{||x|| ||y||}$$

(3-5)

4. 柴油机振动监测技术研究

4.1 柴油发动机振动信号分析与数据处理

通过对柴油发动机进行实验，对柴油机的缸盖，曲轴箱，齿轮箱，机架四部分传感器所收集到振动信号进行分析，在柴油机的每一个工作周期内，缸盖加速度振动信号会显示振动幅值大小和冲击角度等时域特性。这些特性与配气机构运动和气缸内点火冲击直接相关。这里以缸盖振动信号为例。

4.1.1 测点信息熵和立性计算

(1) 时频图像信息熵计算

本文通过提取缸盖传感器对应配气相位所划分的曲轴转角区间的时频数据，以缸盖传感器 L1 为例，提取其排气关闭相位所对应的曲轴转角区间的时频数据，可以计算该相位区间内的时频图像熵，进一步处理后可实现对同一配气动作做出归一化的图像熵。最终得到如图 4-1 所示 7 个缸盖传感器的 9 个冲击段的图像熵。






图 4-1 缸盖传感器振动信号时频图信息熵

(2) 独立性计算

这里以两个缸盖传感器为例，分别截取了两个传感器在 0° - 720° 的曲轴转角区间内的信号，所得结果如图 4-2 所示，将对应信号分别形成两个新向量 x 和 y ，同时使用交叉互相关函数，将两个传感器信号进行时延对齐，使得在进行相关系数计算时信号的波形大致重合，最后计算相关系数。



(a) 传感器 L1-1 在 0° - 720° 的时域信号及包络线图



(b) 传感器 L2-1 在 0° - 720° 的时域信号及包络线图

图 4-2 相同区间两传感器信号

分别对 7 个传感器 9 个配气相位端的信号求相似度, 并对 9 个配气相位端信号相似度求均值, 得到传感器之间的正弦独立性, 求均值得到 7 个传感器的独立性。 $\sin$ 值越大, 说明各传感器对于其他传感器更独立。依次可作缸盖传感器正弦值图如图 4-3:




图 4-3 缸盖传感器振动信号正弦值

4.2 柴油机缸盖测点集

4.2.1 不同传感器保留个数实验结果

通过改变图池化操作中的超参数 $\text{ratio}=x$ (表示保留输入图中较重要的节点数量占原节点数量的比例) 可以得出对应缸盖传感器准确率及损失函数, 由此可以最终确定最佳传感器数目 K 的大小, 如图 4-4 和 4-5 所示。




图 4-4 缸盖传感器数目为 1-7 时的准确率图




图 4-5 缸盖传感器数目为 1-7 时的损失函数图

由图可知当 $K=1$ 时, 此时缸盖传感器的准确率较低, 在训练 5000 次后准确率仍然只能达到 0.9 左右, 并且此时损失较大, 效果很差。而当 $K=2$ 时, 其准确率及损失函数相较于 $K=1$ 时有了很大改善, 但仍不能快速达到理想的效果, 仅在训练 5000 次后准确率勉强可以达到 1 左右, 效果较差。从 $K=3$ 开始到 $K=7$, 此时缸盖传感器的准确率已经能快速达并稳定于到 1 附近, 并且损失情况较低, 效果较好。

4.2.2 最佳传感器保留个数寻优




图 4-6 缸盖传感器时频图像信息熵图

结合 4.2.1 内容, 并由图 4-4 可以看出缸盖传感器在数目为 1 和 2 时准确率较低, 还未达到 1.0, 而从传感器数目为 3 开始其准确率都能快速稳定于 1.0 附

近, 并且由时频图像信息熵 4-6 可知缸盖传感器 L2-1, L2-2 和 L1-3 的熵值较大, 所包含的信息更多, 可知三个传感器就已经包含足够的信息, 其数目也与该准确率所得结果吻合, 并且出于经济性考虑, 将保留最终得分最高的三个传感器。

5 总结

为解决柴油发动机振动监测中的数据重叠和相互干扰问题, 本文研究了传感器最佳布置位置和数量。使用图池化神经网络进行测点布局优化, 对柴油发动机故障数据进行处理和分析, 提取特征矩阵和邻接矩阵, 并将其输入图池化神经网络。通过训练模型、分析实验结果, 调整图池化神经网络参数, 最终确定测点的最佳布局位置和数量。考虑实际应用和经济成本, 通过图池化模型得出的结论表明可以达到良好监测效果。研究发现, 在选取得分前三的传感器时, 缸盖传感器的监测效果最佳。

参考文献

- [1] 张忠坤. 基于蚁群优化的决策树算法研究与应用[D]. 北京: 北京邮电大学, 2015.
- [2] 刘志宏, 夏双志, 戴奉周. 基于贝叶斯理论的多传感器检测跟踪联合处理方法[D]. 山西: 西安电子科技大学, 2016.
- [3] 陈海霞, 王连明. 人工蜂群算法优化支持向量机的传感器优化节点定位[J]. 吉林大学学报, 2017, 55(03): 647-651.
- [4] 李长乐, 王路乔, 王辉, 等. 有向传感器优化部署系统和方法[P]. 中国: CN20201034222 1.2, 2022.3.22.
- [5] 张丹, 于朝民, 付永杰. 基于人工神经网络的传感器非线性拟合方法的研究[J]. 工业计量. 2004(05): 31-33.
- [6] 赵健程, 赵春晖. 面向全量测点耦合结构分析与估计的工业过程监测方法[J]. 自动化学报, 2022: 0254-4156.
- [7] Xiaoyu Yao, Hegong Zhu, GangWang, Zhangjun Wu, Wei Chu. Triple Attention-based deep convolutional recurrent network for soft sensors[J]. Measurement, 2022, Vol.202: 111897
- [8] Lei Wang, Hongrui Cao, HaoX u, Haichen Liu. A gated graph convolutional network with multi-sensor signals for remaining useful life prediction[J]. Knowledge-Based SystemsVolume, 2022, Vol.252: 109340.
- [9] Junhyun Lee, Inyeop Lee, Jaewoo Kang. Self-Attention Graph Pooling[J]. Computer Science, 2019, Vol.3: 1467-5463.
- [10] Tianfu Li, Zhibin Zhao, Chuang Sun, Ruqiang Yan, Xuefeng Chen. Hierarchical attention graph convolutional network to fuse multi-sensorsignals for remaining useful life prediction[J]. Reliability Engineering and System Safety, 2021, Vol.215: 107878.