

DOI:10.19651/j.cnki.emt.2312539

基于多模态和图卷积的飞机部段形变预测方法^{*}

孔志浩¹ 卢 鹏² 毛建华¹ 陆小峰^{1,3}(1. 上海大学通信与信息工程学院 上海 200444; 2. 上海飞机制造有限公司 上海 200436;
3. 上海大学温州研究院 温州 325000)

摘要:近年来,随着人工智能技术的发展,深度神经网络在智能制造中得到了广泛应用。本文将深度神经网络与飞机部段的形变预测相结合,提出了一种基于图卷积和多模态的飞机部段形变预测方法。在对飞机部段的形变分析中,对飞机部段的结构数据与工况数据两种模态的数据进行特征提取并在特征级和决策级进行融合。飞机结构数据为点云数据,具有非欧几里得数据的特性,在对飞机部段结构数据进行特征提取时,引入了基于图卷积的特征提取网络。基于ModelNet40和飞机部段的结构和工况数据构建了包含4种飞机部段的形变数据集,并在该数据集上进行了实验。实验结果表明,该方法在各个部段中的平均预测均方误差为0.188,并在机头部段取得了最好的预测结果,可以有效的对飞机部段的形变状况进行预测。

关键词:形变预测;图卷积网络;多模态;点云数据;特征融合

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520

Prediction method of aircraft segment deformation based on multi-mode and graph convolution

Kong Zhihao¹ Lu Hu² Mao Jianhua¹ Lu Xiaofeng^{1,3}(1. School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China;
2. Shanghai Aircraft Manufacturing Co., Ltd., Shanghai 200436, China;
3. Wenzhou Institute of Shanghai University, Wenzhou 325000, China)

Abstract: In recent years, with the development of artificial intelligence technology, deep neural network has been widely used in intelligent manufacturing. This paper combines deep neural network with aircraft deformation prediction, proposes a prediction method of aircraft segment deformation based on graph convolution and multi-mode. In the deformation analysis of aircraft segment, the model extracts the features of aircraft structure mode and working condition mode respectively, and fusion at the decision-making level. When extract features from aircraft segment structure data, the aircraft structure data is in point cloud format and has the characteristics of non-Euclidean data, this paper introduce the graph convolution. Based on ModelNet40 and real aircraft segment working condition data, construct aircraft segment deformation dataset deformation dataset including four aircraft segments, and experiments are conducted on this dataset. The experimental results show that the prediction mean square error of this method is 0.188, and get the best prediction in the nose segment of the aircraft, which can effectively predict the deformation of aircraft segments.

Keywords: deformation prediction; graph convolution network; multi-mode; point cloud data; feature fusion

0 引言

在民用飞机的装配过程中,对装配精度的要求非常严格,由于飞机结构材料是柔性材料^[1],在材料因素和工况因素的影响下,容易产生形变^[2]。飞机结构的变形会严重影响

响飞机的装配验收和实际使用,因此在装配过程中及时发现飞机的形变非常重要。对于飞机部段的形变相关研究可以采用力学物理建模进行分析。Wang等^[3]基于弹性梁的静态力学方程,导出了装配变形预测模型,为飞机变形偏差分析的预测奠定了基础,Huang等^[4]研究了初始应力对飞

收稿日期:2023-01-03

*基金项目:上海市科委科技创新行动计划(21511102605,22511103304,22511103403)项目资助

机装配变形的影响，并建立了分析装配变形的数学模型，为飞机变形分析提供了新的理论方法。Liu 等^[5]提出了一种新的跨尺度方法来预测飞机材料的结构变形，该方法已应用于多个装配阶段，并取得了良好的效果。Dvurecenska 等^[6]使用图像分解分析了不同飞机变形的特征向量，并评估了变形曲率之间的关系。但在飞机实际装配过程中的形变程度通常很小，很难以人工的方式发现飞机部段产生的形变。

近年来，基于深度学习方法的智能预测已经广泛应用于各个领域^[7]。在飞机装配过程中，使用基于深度学习的方法对飞机部段的形变进行分析可以减少人力的投入并实现智能分析。对于飞机部段的结构数据通常为点云格式，在使用传统的深度学习方法对飞机部段的形变进行预测时，飞机部段的结构数据可以提取出飞机部段的结构特征，具有较强的非线性能力，但其数据的泛化能力较差。此外，在飞机装配的实际场景中，工况数据对于飞机部段的形变也会产生较大影响，基于工况数据对飞机部段形变进行分析预测可以提取外部工况数据特征，具有较强的泛化能力，但预测精度不高，因此两种模态的数据可以达到优势互补。

本文提出了一种可以对飞机部段形变进行智能预测的方法，该方法同时考虑了飞机结构数据和工况数据两种模态，可同时提取两种模态的特征，对两种特征进行优势互补，从而提高对飞机部段形变预测的精确度。同时本文制作了飞机部段结构形变数据集和飞机部段工况数据集用来提取不同模态的特征，在对飞机结构特征的提取中，由于飞机结构数据为点云格式，点云格式的数据具有非欧几里得特性，且飞机部段的形变量通常较小，因此对于局部特征的提取尤为关键，图卷积通过定义作用于图上的卷积操作来提取节点的邻域信息，使用图卷积操作可以对图结构以及图上的邻域信息进行有效的提取。

1 相关理论

1.1 多模态融合

多模态分析可以同时提取多种模态数据的特征并进行融合，可以为模型决策提供更多信息，进一步提高整体决策结果的准确性。它已广泛应用于视频分类、目标检测、情绪分析和其他场景。多模态特征融合方法可分为早期融合和晚期融合。早期融合在对不同模态的特征完成提取之后立即进行融合，如图 1 所示。早期融合可以利用不同模态的数据之间的相关性加强对相似特征的提取。Murphy 等^[8]对特征级融合的研究，提出了多种方法来解决早期融合方法的同步问题。

后期融合是每种不同的模态都对回归或分类任务做出决策之后再进行的融合，如图 2 所示。这种融合方式需要对不同模态的数据训练完成的模型再进行决策融合，最后输出结果，它可以更好的处理不同数据的异步性，但是忽视了不同模态在低层次之间的相互作用。Kahou 等^[9]提出了

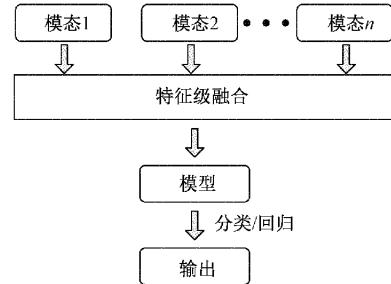


图 1 多模态早期融合示意图

后期融合方法，即确定规则的方法，如最大值融合和平均值融合，这为后续的后融合研究奠定了基础。Wang 等^[10]提出了一种以不同时间分辨率处理多个模式的方法，该方法大大提高了融合效率。Lan 等^[11]通过使用混合融合方法实现了多媒体事件检测的检测。该方法通过早期融合和后期融合来捕获特征关系并处理过拟合问题。

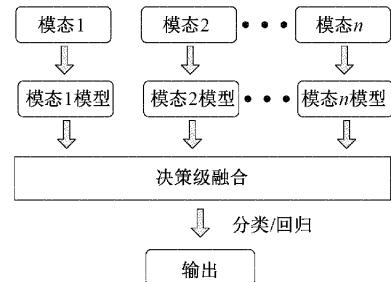


图 2 多模态后期融合示意图

1.2 图卷积

图卷积基于信息扩散机制将数据中每个样本作为更新目标，通过包含样本之间依赖关系的连接边按照某种规则进行信息交互与更新，对点云等非欧式数据非常适用，且对于点云数据空间域图卷积的泛用性更好^[12]。

一个图结构 G 由节点集合 V 和边集合 E 构成，表示为 $G = (V, E)$ ，其中每个节点特征 X_i 可以表示为一个 $N \times D$ 的矩阵， N 表示点的数量， D 表示点的特征维度。在图结构中每个点的特征都随着其邻域中的点权重实时更新并达到邻域间的平衡，在空间域中可以使用邻接矩阵 A 来表示不同节点间的连接情况。对于点云数据而言，要解决不能使用统一尺度的卷积核进行特征提取的问题。空间图卷积根据某种策略指定图顶点并划分邻域点，由顶点和邻域点的组合构成点对并由点对生成边，以邻接矩阵表示结构特征并设计聚合函数聚集邻域特征，通过递进的层级网络结构将节点特征与结构特征融合从而实现特征提取。输入无序点在输入无序的点云之后，每个点都可被看作一个节点，利用点云的相关特性，可以设计聚合函数建立独立点之间的关联来建立图结构。空间域的图卷积层可表示为：

$$h_i^{l+1} = \sigma \left(\sum_{j \in N_i} \frac{1}{c_{ij}} h_j^l w_j^l \right) \quad (1)$$

其中， h_i^{l+1} 表示节点 i 在第 l 层的特征， c_{ij} 表示归一化

因子,通常取节点度的倒数, w_j^l 表示第 l 层的权重矩阵。

2 网络框架

基于多模态和图卷积的飞机部段形变预测方法使用了两种特征提取网络分别对飞机部段结构数据和飞机部段工况数据进行特征提取,并基于多模态理论对两种模态的特征进行融合,其网络框架如图 3 所示。

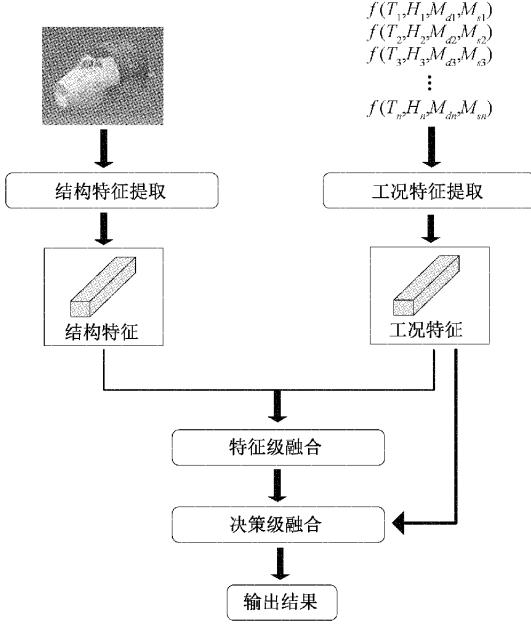


图 3 网络总体框架

2.1 特征提取网络

特征提取网络由两部分组成,分别用来提取飞机部段结构数据的特征和飞机部段工况数据特征。对于飞机部段结构数据而言,由于数据格式为点云格式,因此飞机部段结构特征提取网络与普通图像特征提取网络不同,需要考虑点云数据无序性和空间变换不变性。对于飞机部段形变的结构数据,不同类别之间的特征差异通常只存在于局部位置。因此需提高对局部特征的有效提取。

基于点云特征提取网络 PointNet^[13],本文新引入了图卷积结构,图卷积考虑了每个点在整个特征空间的下的邻近关系,可以更好的挖掘出整体的特征关联,有助于提升模型性能。图卷积结构通过 KNN 算法为 N 个点依次在空间域中构建 k 邻域,共享多层次感知机可以对局部邻域进行学习和训练,并通过最大池化聚合邻域点的特征向量。

构建局部邻域主要目的是确定点云中每个点的邻域空间,以便进行局部空间信息编码和特征图的构建。KNN 算法可用于构建点云中每一个点的局部邻域,通过计算点云中不同点间的距离,作为局部邻域构建指标,选取每个点的 K 个邻近点作为该点的局部邻域。中心节点与其邻域点形成点对构成边,从而生成空间图结构,并通过空间图结构进行卷积来完成局部邻域特征的提取,KNN 算子结构如

图 4 所示。

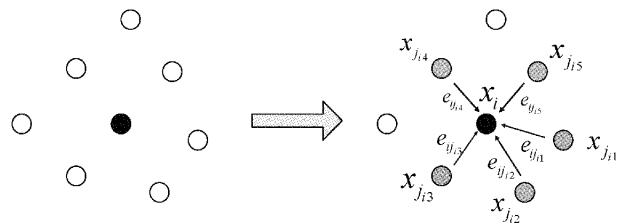


图 4 KNN 算子结构

图 4 中 x_i 为当前节点处理中的中心节点, $x_{j_1}, \dots, x_{j_{ik}}$ 表示当前中心节点的各邻域节点, e_{ij} 表示各邻域节点与当前中心节点所生成的边特征,整个空间图结构的输出为当前中心节点所有边特征的聚合,如式(2)所示。

$$x_i = \sum_{j:(i,j) \in [1, k]} h(x_i, x_j) \quad (2)$$

其中, $h(x_i, x_j)$ 为定义各个边特征的边缘函数。

在图结构中对于中心点 x_i 其特征向量 e_{ij} 定义为:

$$e_{ij} = g\left(\omega \sum_{i=1}^k x_{ji}\right) \quad (3)$$

其中, g 为对称函数,使用最大池化聚合邻域点的特征向量, ω 表示各邻域节点的权重。

引入了图卷积的飞机部段结构特征提取模块,如图 5 所示,将输入的 $n \times 3$ 的飞机部段结构点云首先经过输入旋转网络 T-Net, T-Net 结构和主干网络相似,目的将输入的飞机部段结构数据进行对齐,方便后续的特征提取,数据完成对齐后通过 KNN 算法遍历计算每个点与其余点的欧式距离并选取距离最近的 K 个点,在特征空间中构建邻域尺度大小为 K 的空间图结构,此时已经包含了所有特征邻域尺度内的 K 维邻域信息,经过共享 64 维多层次感知机得到 64 维特征,通过两层相同的图卷积与共享感知机可多次完成对特征的提取。将得到的 64 维特征再次完成特征对齐后经过三层维度分别为 64, 128, 1 024 的多层次感知机对特征向量进行升维,并与前两次提取的特征进行拼接,随着多层次感知机维度的深入加深了对特征的抽象层次从而有利于全局特征的聚合。此时对于飞机部段结构数据中的每个点都具有一个 1 024 维的特征向量,且当前存在一些特征点被多次应用的情况导致特征冗余,通过在 K 维度上选取最大值即邻域内所有特征点中影响最大的特征来解决冗余问题,将特征池化为 $1 \times 1 024$ 维,即得到了飞机部段结构数据的特征 F_s 。

对于飞机部段工况数据的特征提取,本文构建了具有深度残差模块的深度神经网络。飞机部段工况数据共包含 4 种不同类别的工况数据,包括环境温度、环境湿度、装配应力、装配时长,通过对该数据的特征提取可以使得网络学习不同工况因素下对飞机部段装配产生的影响。残差模块可以跳跃连接不同的层,即单元的输入与单元的输出直接相加,可以解决网络精度饱和梯度消失的问题。网络结构由六层神经网络和两个残差模块组成。每个残差模块包括

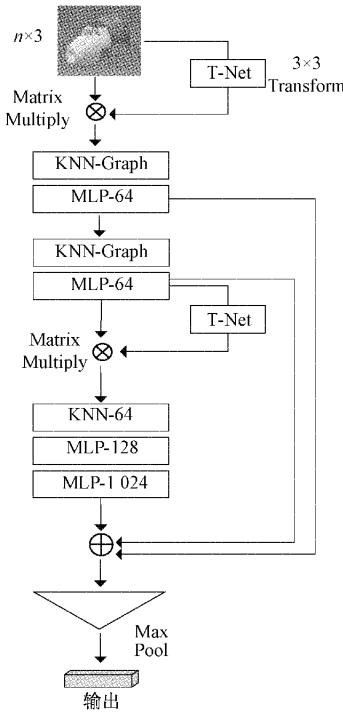


图 5 飞机部段结构特征提取网络

三层神经网络,输出通道数为 12、24 和 4。完成特征提取后可以得到飞机部段工况特征 F_{wc} 。

2.2 特征融合网络

经过特征提取得到两种不同模态的特征 F_s 和 F_{wc} 后,本文通过一个特征融合网络,将不同模态的特征空间映射到共享语义子空间中,从而融合多模特征。特征融合网络结构如图 6 所示。

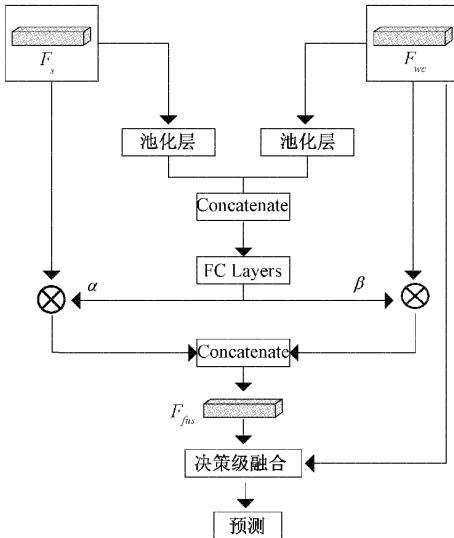


图 6 特征融合网络

飞机部段结构特征 F_s 和工况特征 F_{wc} 对飞机形变产生的影响权重是不同的,本文采用一个门结构对两种不同模态的特征进行特征级的融合,对得到的两种特征,经过池

化层可分别计算出最大值、最小值、平均值以及标准差,并对两种特征进行早期合并,将合并的特征输入到全连接层结构进行归一化得到不同的权重系数,其全连接层结构包括两个全连接层、Tanh 层以及 Sigmoid 层。对得到的两个权重系数 α 和 β 分别乘以对应的输入特征,并通过 Concatenate 函数进行合并得到特征级融合后的特征向量 F_{fus} 。飞机部段工况数据提取出的特征为低层次特征,但在实际装配过程中细微工况差异化就会对飞机形变产生不定量的影响,因此在完成特征级的融合之后,在决策层将多模态特征与工况数据特征进行高层次融合,以丰富特征信息并实现多模态特征的深度融合。基于双线性池化(Bilinear Pooling)的思想,决策层融合方式为:

$$P = \text{LayerNorm}(\mathbf{M}_{fus}^T F_{fus} + \mathbf{M}_{wc}^T F_{wc}) \quad (4)$$

其中, $\mathbf{M}_{fus}^T, \mathbf{M}_{wc}^T \in \mathbb{R}^{d \times d_p}$ 为线性投影矩阵,由全连接层参数决定, LayerNorm 层在输入特征的最后一个维度求均值和方差同时对输入的特征进行标准化,最终输出预测结果。

3 实验与分析

3.1 数据集

实验数据集分为两部分,分别为飞机部段形变结构数据集和飞机部段形变工况数据集,使用不同的特征提取网络进行多模态的特征提取。

根据开源点云数据集 ModelNet40^[14] 中的 Airplane 类别以及飞机部段实际装配数据通过改变各采样点在空间坐标中的位置从而改变不同点到点云几何中心的欧几里得距离得到飞机部段形变数据集,平均欧几里得距离计算公式为:

$$d_1 = \frac{1}{M} \sum_{i=1}^M \sqrt{(x_{di} - x_0)^2 + (y_{di} - y_0)^2 + (z_{di} - z_0)^2} \quad (5)$$

对于飞机部段形变数据通过点云分割的方式将飞机点云数据划分为 4 个部段,分别为机头、机翼、机身以及机尾,每个部段各包含 726 条数据,其可视化效果如图 7 所示。

根据飞机实际装配过程中各工况数据对飞机部段形变产生的影响大小的不同,飞机部段形变工况数据集共包含了环境温度 T , 环境湿度 H , 装配时长 M_d 和装配应力 M_s 4 种参数。

3.2 实验环境设置

实验采用的平台为 Intel i7-12700K 3.6 GHz 中央处理器, NVIDIA RTX3090, 采用的集成开发环境是 Anaconda3.6, 开发环境为 Python 3.8, PyTorch 1.8.0, CUDA 11.1。使用 Adam 优化器来优化参数,其初始学习率为 0.01, 每迭代 10 次后降低为原来的 1/10。Batch Size 为 32, 共训练 200 个 epoch。对飞机部段形变数据集中数据随机选择 80% 作为训练集, 20% 作为测试集。

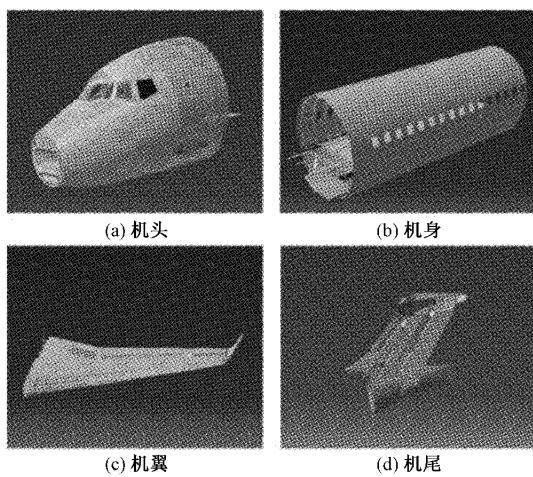


图 7 飞机部段结构数据可视化图

3.3 实验评价标准

在实验评价标准的定义上,本文使用了平均百分比误差(mean absolute percentage error, MAPE)、平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)以及最大误差(E_{\max})作为评价指标对预测结果准确性进行评估。针对形变预测而言,评价指标的值越小说明模型对于飞机部段形变数据的拟合程度高,模型具有较高的预测精度,值越大说明模型的预测值与实际值之间存在的偏差越大,最大误差则可评价模型在实际效果中可能产生的最坏影响。MAE、MAPE、RMSE、 E_{\max} 四种评价指标的计算公式为:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{true,i} - y_{out,i}| \quad (6)$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y_{true,i} - y_{out,i}}{y_{true,i}} \right| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{true,i} - y_{out,i})^2} \quad (8)$$

$$E_{\max} = \max_i |y_{true,i} - y_{out,i}| \quad (9)$$

其中, N 为数据总个数, $y_{true,i}$ 为第 i 个数据的真实值, $y_{out,i}$ 为第 i 个数据的预测值。

3.4 实验结果

本文在飞机部段形变数据集上验证了该方法,同时为了验证图卷积模块在对飞机部段结构特征进行充分的有效性,将飞机部段结构特征的提取网络更换为主流的点云特征提取网络进行实验对比,其实验结果如表 1 所示,与主流点云特征提取的骨干网络相比,融合图卷积的飞机结构特征提取网络在各个部段的预测效果都有着明显提升,以 RMSE 为例,本文的方法在机头、机身、机翼以及机尾 4 个部段预测中的值分别为 0.213、0.162、0.183、0.195,相较于其他模型中效果最好的模型分别降低了 15.1%、20.5%、20.1%、15.5%。以机身部段为例,使用经典点云特征提取网络 PointNet 对飞机部段结构数据进行特征提取的模型的 RMSE 为 0.312,而 PointNet++^[15]引入了多层次结构可以提取更高级的特征,RMSE 达到了 0.263,PointCNN^[16]引入了点云卷积来提升特征提取能力,PointWeb^[17]考虑到了局部特征的重要性获得了较好的预测效果,本文的方法进一步考虑到了局部特征邻域之间的强作用关系,在飞机部段的结构数据中,可以更好的区分不同形变程度之间的微小特征差异,达到了最好的预测效果,实验证明本文的模型在飞机部段的形变预测中取得了更好的拟合效果,可以实现更精准的飞机部段形变预测。对于不同的飞机部段模型的预测效果也存差异,预测效果最好的部段为机身,其 RMSE 为 0.162,MAE 达到了 0.128,而机头部段的 RMSE 为 0.213,在机头部段中,结构构成较为复杂,不同的形变程度所能提取到的特征有限,其预测值于真实值对比如图 8 所示。对于机身部段而言,其结构较为单一,点云数据也主要以直线为主,有利于区分不同形变程度的特征差异。在飞机结构数据的特征提取中,部段本身物理特性也能够影响到模型的最终预测结果。

表 1 模型预测结果对比

部段类型	模型	MAE	E_{\max}	MAPE	RMSE	部段类型	模型	MAE	E_{\max}	MAPE	RMSE
机头	PointNet	0.297	0.369	20.891	0.436	机身	PointNet	0.244	0.314	18.542	0.312
	PointNet++	0.249	0.354	19.145	0.327		PointNet++	0.237	0.298	16.391	0.263
	PointCNN	0.223	0.312	16.839	0.274		PointCNN	0.162	0.243	14.673	0.195
	PointWeb	0.193	0.243	12.653	0.251		PointWeb	0.155	0.208	11.562	0.204
	Ours	0.166	0.198	9.734	0.213		Ours	0.128	0.173	7.623	0.162
机翼	PointNet	0.285	0.361	19.532	0.349	机尾	PointNet	0.288	0.346	19.973	0.396
	PointNet++	0.232	0.310	17.274	0.317		PointNet++	0.237	0.301	18.249	0.334
	PointCNN	0.184	0.264	15.397	0.262		PointCNN	0.211	0.267	16.423	0.263
	PointWeb	0.173	0.234	12.231	0.229		PointWeb	0.187	0.236	12.487	0.231
	Ours	0.141	0.187	8.256	0.183		Ours	0.154	0.207	8.872	0.195

在特征融合阶段,本文使用了特征级融合和决策级融

合相结合的方式,为了验证融合方法的有效性和起到的优

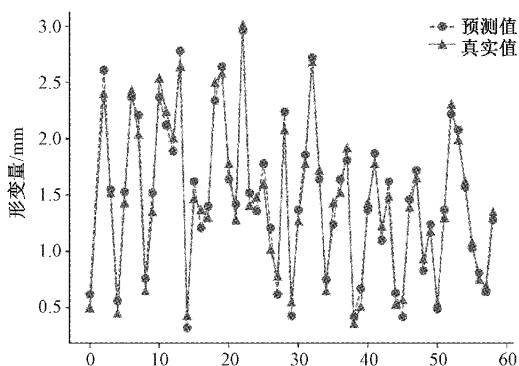


图 8 机头部段形变真实值与预测值对比图

化效果,本文进行了特征融合阶段的消融实验,即只在特征级进行融合和只在决策级进行融合,实验结果如表 2 所示。相比于只使用特征级融合方法,使用特征级和决策级融合相结合的方法在机头、机身、机翼、机尾 4 个部段上的形变预测模型的 RMSE 分别降低了 7.8%、13.8%、17.1%、14.4%,相比于只使用决策级融合的方法,在 4 个部段上的模型 RMSE 则分别降低了 13.4%、20.5%、22.1%、20.1%。因此对于飞机部段形变预测,特征级别的融合的重要性会更高,实验结果表明,在不同的飞机部段形变预测中,使用特征级和决策级融合相结合的方式可以更好的丰富特征信息并将两种模态的数据在高层次深度融合,从而提升模型的预测效果。

表 2 不同融合方式预测结果对比

部段类型	融合方式	MAE	MAPE	RMSE
机头	特征级融合	0.195	11.349	0.231
	决策级融合	0.204	12.168	0.246
	特征+决策	0.166	9.734	0.213
机身	特征级融合	0.155	10.421	0.188
	决策级融合	0.174	11.548	0.204
	特征+决策	0.128	7.623	0.162
机翼	特征级融合	0.166	11.237	0.221
	决策级融合	0.184	12.821	0.235
	特征+决策	0.141	8.256	0.183
机尾	特征级融合	0.182	10.273	0.228
	决策级融合	0.197	13.657	0.244
	特征+决策	0.154	8.872	0.195

4 结 论

针对飞机部段在装配过程中可能发生的形变问题,本文提出了一种基于图卷积和多模态的形变预测方法,采用飞机部段结构数据和飞机部段工况数据两种数据集分别进行特征提取,并针对飞机部段结构数据形变程度差异较小的特点,引入了图卷积模块提升对局部特征的提取能

力,在特征融合阶段采取特征级融合与决策级融合相结合的方法进一步提升了模型的预测能力,经过实验证明,该模型能够有效的预测飞机部段的形变,图卷积特征提取模块和两种方法相结合的特征融合方式相比于其他方法的优势在 MAE、MAPE、RMSE 三种指标中得到了体现,通过该方法可以及时发现飞机部段存在的形变,从而提高实际装配效率。

参 考 文 献

- [1] MEI, ZHONGYI, MAROPOULOS, et al. Review of the application of flexible, measurement-assisted assembly technology in aircraft manufacturing [J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of engineering manufacture, 2015, 229(1):183-183.
- [2] JI Y, LI Z, LIU L, et al. A deformation detection method for aircraft skin on uniform pressure by using speckle image correlation technology [J]. Measurement: Elsevier, 2020, 154: 107525.
- [3] WANG Q, HOU R, LI J, et al. Positioning variation modeling for aircraft panels assembly based on elastic deformation theory[J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2018, 232 (14): 2592-2604.
- [4] HUANG X, LIU X, LI J, et al. Machining deformation analysis of aircraft monolithic components based on the energy method[J]. The International Journal of Advanced Manufacturing Technology: Springer, 2022: 1-9.
- [5] LIU C, CHENG H, ZHANG K, et al. An efficient trans-scale and multi-stage approach for the deformation analysis of large-sized thin-walled composite structure in aircraft assembly [J]. The International Journal of Advanced Manufacturing Technology: Springer, 2022, 120(9): 5697-5713.
- [6] DVURECENSKA K, DIAMANTAKOS I, HACK E, et al. The validation of a full-field deformation analysis of an aircraft panel: A case study[J]. The Journal of Strain Analysis for Engineering Design, 2021, 56(4): 265-272.
- [7] 刘晓磊,刘连胜,王璐璐,等.基于状态空间模型的飞机APU在翼 RUL 预测方法[J].仪器仪表学报,2021, 42(2):45-54.
- [8] MURPHY R R. Computer vision and machine learning in science fiction[J]. Science Robotics, 2019, 4(30): eaax7421.
- [9] KAHOU S E, PAL C, BOUTHILLIER X, et al. Combining modality specific deep neural networks for

- emotion recognition in video[C]. Proceedings of the 15th ACM on International Conference on Multimodal Interaction, 2013: 543-550.
- [10] WANG Y, HUANG W, SUN F, et al. Deep multimodal fusion by channel exchanging [J]. Advances in Neural Information Processing Systems: NIPS, 2020, 33: 4835-4845.
- [11] LAN Z, BAO L, YU S I, et al. Multimedia classification and event detection using double fusion[J]. Multimedia Tools and Applications: Springer, 2014, 71 (1): 333-347.
- [12] 王博豪,孙战里.用于三维点云识别的双模块图卷积网络[J].传感器与微系统,2022,41(9):132-135.
- [13] QI C R, SU H, MO K, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 652-660.
- [14] WU Z, SONG S, KHOSLA A, et al. 3d shapenets: A deep representation for volumetric shapes [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1912-1920.
- [15] QI C R, YI L, SU H, et al. Pointnet++: Deep hierarchical feature learning on point sets in a metric space[J]. Advances in Neural Information Processing Systems, NIPS, 2017, 30.
- [16] LI Y, BU R, SUN M, et al. Pointcnn: Convolution on x -transformed points [J]. Advances in Neural Information Processing Systems, NIPS, 2018, 31.
- [17] ZHAO H, JIANG L, FU C W, et al. Pointweb: Enhancing local neighborhood features for point cloud processing [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2019: 5565-5573.

作者简介

孔志浩,硕士研究生,主要研究方向为深度学习。

E-mail: kongzihao@shu.edu.cn

陆小锋,硕士生导师,高级实验师,主要研究方向为智能信息处理。

E-mail: luxiaofeng@shu.edu.cn