

# 基于计算机视觉的斗拱转动变形检测方法

王娟<sup>1,2</sup>, 申祖晨<sup>1,2</sup>, 姚远<sup>1,2</sup>, 杨娜<sup>1,2</sup>

(1. 北京交通大学 土木建筑工程学院, 北京 100044; 2. 北京交通大学 结构风工程与城市风环境北京市重点实验室, 北京 100044)

**摘要:** 古建筑木结构斗拱节点由斗、栱等构件交错层叠而成。受自身形制、环境和外力等影响, 这种“层叠式”节点易出现转动变形。针对人工及布设传感器的传统检测方法在可实施性及检测效率方面的局限性, 提出了一种基于姿态估计的斗拱转动变形计算机视觉检测方法。首先定义了斗拱的关键点, 并基于关键点推导出了各层斗的转动以及栌斗和阑额相对转动的计算公式; 其次通过采集斗拱实景图像、实验室模型图像以及缩尺模型图像, 构建了斗拱节点多样性数据集; 而后搭建 YOLOv8-Pose 姿态估计模型, 并开展了 6 种规模和 Batch Size 的 23 种工况对比实验; 结果表明, 最优性能模型目标检测的 mAP50(B) 达到 0.94, 关键点检测的 mAP50(P) 达到 0.91。最后利用缩尺模型转动变形检测实验验证了所提方法的有效性。

**关键词:** 斗拱节点; 转动变形; 姿态估计; YOLOv8-Pose; 直线检测

中图分类号: TU366

文献标志码: A

文章编号: 1006-7930(2024)05-0669-10

## Rotation deformation detection method for Dou-Gong based on computer vision

WANG Juan<sup>1,2</sup>, SHEN Zuchen<sup>1,2</sup>, YAO Yuan<sup>1,2</sup>, YANG Na<sup>1,2</sup>

(1. School of Civil Engineering, Beijing Jiaotong University, Beijing 100044, China;  
2. Beijing's Key Laboratory of Structural Wind Engineering and Urban Wind Environment,  
Beijing Jiaotong University, Beijing 100044, China)

**Abstract:** Dou-Gong joints of ancient wooden structure are composed of Dou and Gong and other components. Affected by its own shape, environment and external force, such “stackable” joints are prone to rotation deformation and other types of damage. In view of the limitations of traditional detection methods of manual and deployed sensors in the implementation and detection efficiency, a computer vision detection method of Dougong rotation deformation based on pose estimation was proposed. Firstly, the key points of the Dou-Gong were defined, and based on the key points, the calculation formula of the rotation of each layer of the Dou-Gong and the relative rotation of the Lu-Dou and the Lan-E were deduced. Secondly, a diverse dataset of Dou-Gong joints was constructed by collecting Dougong real scene image, laboratory model image and scaled model image. Then, the YOLOv8-Pose pose estimation model was built, and the comparative experiments were conducted under 23 conditions with 6 varying sizes and Batch Sizes. The results showed that the target detection part mAP50(B) of the optimal performance model reached 0.94, and the key point detection part mAP50 (P) reached 0.91. The effectiveness of the proposed method was verified by the rotation deformation detection experiment of the scale model.

**Key words:** Dou-Gong joints; rotation deformation; pose estimation; YOLOv8-Pose; line detection

中国古建筑木结构是我国极其珍贵的文化遗产。斗拱作为古建筑木结构特有的“层叠式”节点, 位于立柱和横梁交接处, 由斗形木块和弓形栱木交错搭接而成。斗拱主要承担荷载传递和装饰作用, 是一种能够承担竖向压力、水平剪力和弯矩

的刚度较大的变形体, 同时具有良好的减震耗能特性<sup>[1-3]</sup>。

然而, 斗拱易受温湿度、外力作用和自身材料性能老化等多维因素影响, 出现转动和开裂等损伤, 如图 1 所示。谢启芳等<sup>[4]</sup>、陈九璋等<sup>[5]</sup>采用

人工钻孔与开槽的方法模拟斗拱节点的腐朽、虫蛀和裂缝损伤，并进行了残损斗拱竖向荷载试验。薛建阳等<sup>[2, 6-8]</sup>则通过削减平板枋来模拟斗拱倾斜情况，结合实验室试验和数值模拟，分析不同倾斜情况下平身科斗拱力学与抗震性能变化规律。以上试验均表明，斗拱的损伤会导致其性能出现不同程度的削弱，进而可能给古建筑木结构带来安全隐患。目前，针对斗拱的损伤检测主要依赖人工检测和使用传感器等接触式方法。然而，由于斗拱在古建筑中分布广泛，人为攀高和大量布置传感器等措施不利于古建筑的保护，因此亟需引入新的检测方法。

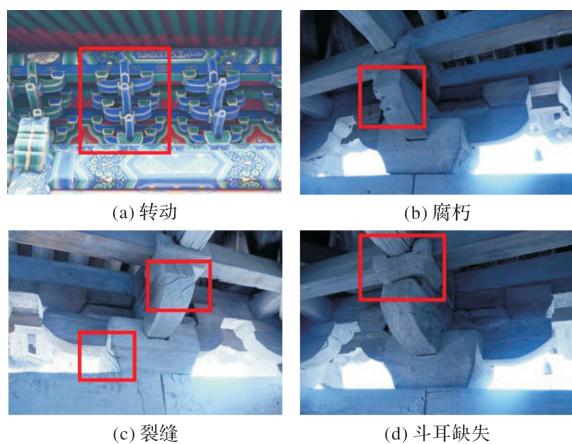


图 1 斗拱各类损伤

Fig. 1 The various damage of Dou-Gong

计算机视觉技术因其自动化、非接触、快速高效等优点，已在结构变形监测<sup>[9]</sup>、表面残损识别<sup>[10]</sup>、结构组件缺失<sup>[11]</sup>等损伤识别研究中得到应用。在古建筑木结构领域，杨娜等<sup>[12]</sup>采用模板匹配和特征点匹配技术对古建筑变形进行监测，并结合张正友相机标定方法，实现了任意倾斜图像的三维坐标分析。刘纲等<sup>[13]</sup>基于数字图像相关(DIC)技术，通过相机采集古建筑彩绘木梁振动的时序图像，运用位移搜索等算法提取木梁工作模态，进而识别木梁损伤部位和损伤程度。

深度学习作为计算机视觉的一个重要分支，具有更深层次的学习网络、自动特征学习、大规模数据处理等优势。马健等<sup>[14]</sup>采集了明代八王寺木结构裂缝图像，并结合 YOLOv5 算法实现了裂缝的精确识别。杨娜等<sup>[15]</sup>基于图像智能语义分割网络(U-Net)，开发了一套非接触式的裂缝预防性生长变形监测系统。王念念等<sup>[16]</sup>基于 R-CNN 检测、分割两级策略，实现了古建筑大面积琉璃瓦损伤的高精度识别。尽管如此，针对斗拱节点转动的研究相对较少，并且需要考虑斗拱的空间结

构以及复杂的背景干扰，以选择合适的算法开展研究。

YOLOv8 网络承袭了 YOLO 系列的优异性能，并通过集成深度学习平台，在工业<sup>[17]</sup>、交通<sup>[18]</sup>等领域得到了广泛应用。YOLOv8-Pose 姿态估计算法通过预测目标的关键点来识别目标姿态。这一技术为姿态估计方法在变形检测领域的应用提供了新的思路<sup>[19-20]</sup>。针对具有标准形制和明显水平分层的斗拱节点，本研究提出了一种基于计算机视觉的斗拱转动变形检测方法。该方法首先明确了斗拱转动变形的转动角度、关键点以及拍摄角度的定义，以确保关键点定义的合理性。随后，通过采集斗拱实景图像、实验室模型图像以及缩尺模型图像，构建了多样性的斗拱节点数据集。在此基础上，开展了姿态估计算法的对比实验，旨在探究不同训练环境下斗拱姿态估计的最优模型。同时，结合直线检测等方法，对斗拱在木结构中的转动姿态进行了综合分析。最后，利用缩尺模型的转动变形检测实验对上述方法进行了验证，进一步证明了其有效性和实用性。

## 1 斗拱转动变形计算方法

### 1.1 斗拱转动定义

斗拱由多个构件交错搭接而成，其中，构件一般垂直和平行于面阔方向分布，形成纵横相交的构造，而斗位于上下两层拱之间，使得斗拱整体呈现出层叠结构。在竖向或偏心荷载作用下，斗拱的各层之间容易产生转动变形，且这种转动情况在各层之间并不完全一致。斗拱的转动变形可以通过观察出跳拱构件上的交互斗(注：鉴于不同历史时期构件命名的差异，以宋式斗拱为例进行阐述)的转动情况来反映。此外，斗拱底部的栌斗与下部的阑额构件通过榫卯连接。当斗拱发生转动时，需要观察栌斗与阑额之间的相对转动情况，来分析斗拱在木构架中的整体转动状况。

在宋式斗拱中，每向外挑出一拱或一昂称为“一跳”，每增高一层则称为“一铺”。其中，栌斗定义为第 0 跳，命名为  $D_0$ 。垂直于面阔方向上，每一跳头的交互斗代表第  $i$  跳，并命名为  $D_i$ 。在平行于面阔方向的横拱上，分布有散斗，与  $D_i$  连接的两侧散斗定义为  $S_{ij}$ 。以  $D_i$  为分界，左侧的散斗定义为  $S_{ij}^-$ ，右侧的散斗定义为  $S_{ij}^+$ 。为计算转动角度，利用  $D$  和  $S$  两类斗的位置关系进行定义： $D_i$  与  $D_{i+1}$  之间的转动角度定义为  $\theta_i$ ， $S_{ij}$  的转动角度为  $\lambda_{ij}$ ， $D_i$  的转动角度定义为  $\lambda_i$ ，计算公式如下。

$$\theta_i = \arctan \left| \frac{y_{i+1} - y_i}{x_{i+1} - x_i} \right| \quad (1)$$

$$\lambda_{ij} = \arctan \left| \frac{y_{ij}^l - y_{ij}^r}{x_{ij}^l - x_{ij}^r} \right| \quad (2)$$

式中:  $(x_i, y_i)$  为  $D_i$  的底部中心点坐标;  $(x_{ij}^l, y_{ij}^l)$  和  $(x_{ij}^r, y_{ij}^r)$  为  $S_{ij}$  底部左右两个角点的坐标。

同时, 斗拱下方阑额出现转动时, 产生转角为  $\theta_L$ 。栌斗转动角度  $\lambda_0$  和  $\theta_L$  的差值即斗拱与阑额的相对转动角度。

图 2 中出跳数为 2, 即  $i=0, 1, 2$ 。在每一跳上, 左右两侧各有一个散斗, 故两个方向上  $j=1$ , 但需要注意的是, 第二跳采用了偷心造法, 所以不存在  $j$  的取值。图中标注了各类斗的类别以及对应的转动角度。

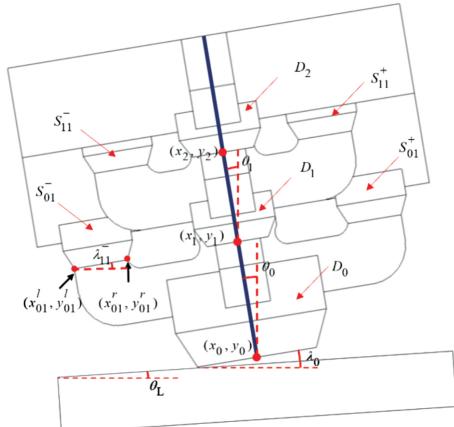


图 2 斗拱转动定义

Fig. 2 Rotation definition of Dou-Gong

## 1.2 斗拱关键点定义

关键点坐标是斗拱转动角度计算的基础, 因此, 关键点检测是斗拱转动变形检测的核心算法。关键点检测通常用于人体姿态识别任务中, 包含目标检测和关键点检测两个关键环节, 如图 3 所示。该任务旨在利用检测到的关键点坐标连接成骨架, 从而反映人体的当前姿态, 例如运动、摔倒等。



图 3 人体关键点骨架<sup>[21]</sup>

Fig. 3 Human keypoint skeleton

斗拱中的斗可分为多种类型, 包括栌斗、交互斗和散斗等。在出跳方向的视图中, 枻斗和交互斗呈现出图 4 (a)所示样式, 而散斗呈现出图 4 (b)所示样式。结合转动定义, 在目标检测任务中, 将栌斗和交互斗定义为 D 类别, 散斗定义为 S 类别。为避免构件表面存在的裂缝、木纹和彩绘等因素的影响, 在斗耳、斗平和斗欹边缘较易检测的角度位置处, 共选取 7 个关键点, 具体位置如图 4 所示。

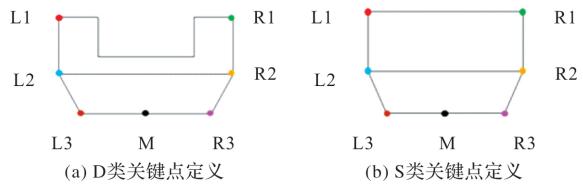


图 4 斗的关键点定义

Fig. 4 Definition of the key point of Dou

$L1$ 、 $R1$  为斗耳处关键点,  $L2$ 、 $R2$  为斗平处关键点,  $L3$ 、 $R3$  为斗欹处关键点。其中,  $L3$  和  $R3$  对应于式(2)中的两个角点坐标。关键点  $M$  表示斗的底部中心, 在计算转动角度时,  $M$  点的坐标  $(x_i, y_i)$  是通过  $L3$  和  $R3$  这两个角点确定的, 计算公式为

$$(x_i, y_i) = \left( \frac{x_{L3} + x_{R3}}{2}, \frac{y_{L3} + y_{R3}}{2} \right) \quad (3)$$

式中:  $(x_{L3}, y_{L3})$  为关键点  $L3$  的坐标;  $(x_{R3}, y_{R3})$  为关键点  $R3$  的坐标。

## 1.3 斗拱相对转动分析

为获取斗拱在木结构中的真实转动情况, 需要考虑栌斗底部与下方阑额构件间的相对转动关系。栌斗的转动角度仍由关键点计算。考虑到阑额存在较为明显的边界特征, 引入直线检测算法<sup>[22]</sup>, 通过检测阑额构件边缘直线, 计算相对于水平方向的转动角度  $\theta_L$ 。斗拱和阑额两构件的转动角度之间的差异, 即为它们的相对转动角度。

直线检测通常涉及以下图像处理操作: (1) 考虑到木结构通常存在木材纹理以及细小裂缝的干扰, 引入双边滤波算法, 该方法综合考虑了像素距离和色彩相似度, 能够在剔除纹理和裂缝干扰的同时, 有效地保留边缘信息; (2) 经过双边滤波之后的图像将被输入到 Canny 边缘检测算法中。在检测结果中, 枻斗和阑额构件的边缘以白色像素分布, 而非边缘部分为黑色背景; (3) Hough 直线检测算法会将位于图像直角坐标系中的边缘点坐标  $(x, y)$  通过极坐标  $(\rho, \theta)$  转换到霍夫空间中。在霍夫空间中, 一条直线上的点会成为一组曲线

的交点。组内曲线越多，说明原图中该直线存在的边缘点越多，越易于检测。

## 2 YOLOv8-Pose 斗拱姿态估计方法

### 2.1 YOLOv8-Pose 网络结构

YOLOv8-Pose 是一种结合了目标检测和关键点检测的单阶段姿态估计算法。相较于传统的两阶段关键点检测网络，其采用端到端的简化设计，避免了复杂的处理过程。YOLOv8-Pose 主要由 Backbone、Neck 和 Head 三个网络模块组成。主体网络是在 YOLOv5 的基础上发展而来的，并基于 YOLOv7 中 ELAN 结构对 C3 模块进行了改进。此外，YOLOv8 还采用了无锚框方法，进一步简化了目标检测过程，提高了模型性能。

待测图像输入到姿态估计网络后，会经过 Backbone 和 Neck 部分的 21 段特征提取与融合卷积操作，进而得到三种不同尺度的特征图像。将其输入到 Head 检测头中进行回归预测。预测信息中包含了目标检测框的位置与类别，以及关键点

的位置与类别信息，如图 5 所示。YOLOv8-Pose 网络的损失函数部分综合了目标检测和关键点检测两项任务。其中，关键点检测任务中的关键点回归损失  $L_{pose}$  记录了模型学习关键点位置的过程，是完成姿态估计算法的重要部分。通过迭代计算模型关键点预测值与关键点真实值之间的 L2 范式距离，直至此差距收敛至一个较小数值。关键点回归损失  $L_{pose}$  和总损失函数值为  $L_{total}$  计算公式<sup>[23]</sup>如下：

$$L_{pose} = \|K_{pred} - K_{gt}\|_2 \quad (4)$$

$$L_{total} = \sum_{i,j,k} (\alpha_{cls} L_{cls} + \alpha_{box} L_{box} + \alpha_{pose} L_{pose} + \alpha_{kobj} L_{kobj} + \alpha_{focal} L_{focal}) \quad (5)$$

式中： $K_{pred}$  是关键点预测值， $K_{gt}$  是关键点真实值； $L_{cls}$  是目标检测框分类损失； $L_{box}$  是目标检测框回归损失； $L_{pose}$  是关键点回归损失； $\alpha$  代表各项损失函数的权重系数， $\alpha_{cls} = 0.5$ ， $\alpha_{box} = 7.5$ ， $\alpha_{pose} = 12.0$ ， $\alpha_{kobj} = 1.0$ ， $\alpha_{focal} = 1.5$ 。

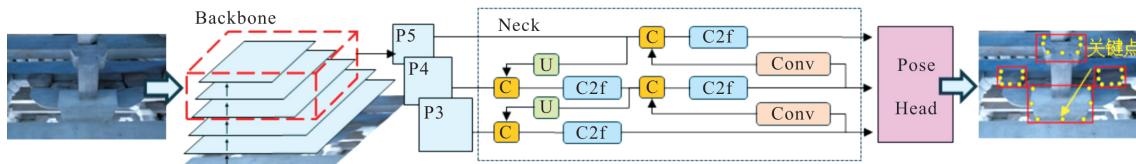


图 5 YOLOv8-Pose 模型

Fig. 5 YOLOv8-Pose model

### 2.2 数据集与运行环境

数据集是深度学习的基础，基于斗拱关键点和转动的定义，采集了多样式的斗拱节点图像，作为 YOLOv8-Pose 网络的学习样本。该数据集广泛涵盖了北京故宫、雍和宫、智化寺和山西飞云楼等地的实景斗拱图像，同时还包含了实验室模型图像和缩尺模型图像。图像的拍摄方式如图 6 所示，其中 X 方向为斗拱出跳方向，Y 方向为面阔方向，Z 方向为高度方向。为了更好地捕捉到 D、S 类目标，拍摄视角略微仰视。从所拍摄的图像中挑选出视角清晰、光线良好图像共计 270 张，如图 7 所示。采集设备为尼康 Zfc 相机，图像分辨率为  $4896 \times 3264$  像素，图像格式为 JPG。使用 Labelme 软件对斗拱关键点进行标注，并将标注的关键点坐标按照 YOLOv8-Pose 网络要求归一化至  $(0, 1)$  区间内。为了确保深度学习网络能够充分学习数据集的特征，并充分考虑测试集和验证集的作用，将训练集与验证集(同为测试集)的比例设定为 8 : 2。

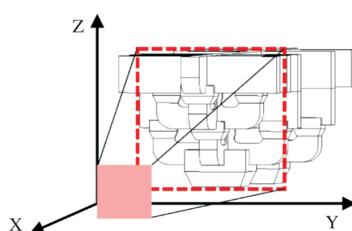


图 6 拍摄方式

Fig. 6 Photography method

YOLOv8-Pose 关键点检测网络的训练和测试任务全部在 Featurize 在线实验室部署和完成。深度学习框架为 Pytorch，版本 v2.0.1，Python 版本 v3.10.12，GPU 型号为 RTX 3090，GPU 显存为 24 GB。通过 Wandb 网站记录模型训练和评估数据。



(a) 实景图像



图 7 斗拱数据集采集

Fig. 7 Collection of Dou-Gong dataset

### 2.3 模型训练

YOLOv8-Pose 提供了 n、m、l、s、x 和 x-p6 六种不同规模的模型, 这些模型在参数数量、模型精度和速度各有差异。针对斗拱关键点检测任务, 需进行对比训练实验, 以确定最适合斗拱转动变形检测任务的最优模型。除了模型规模外, 模型性能还受到超参数影响, 如学习率和批量大小(Batch Size)等。其中, Batch Size 是较为直观的超参数, 它代表每次迭代训练所使用的学习样本数量。较大的 Batch Size 可以加速训练过程并提高模型的稳定性, 但该超参数会受到实际 GPU 内存的限制。因此, 本节开展了不同规模与不同 Batch Size(范围从 4 到 128)的对比训练实验, 共计 23 种工况, 旨在对比不同模型的学习能力, 结果见表 1。

表 1 Batch Size 对比训练

Tab. 1 Batch Size comparison training

模型	Batch Size					
	4	8	16	32	64	128
n	√	√	√	√	√	√
s	√	√	√	√	√	—
m	√	√	√	√	—	—
l	√	√	√	√	—	—
x	√	√	√	—	—	—
x-p6	√	—	—	—	—	—

注: “√”表示开展了训练, “—”表示由于训练超过了 GPU 内存(24 GB)的限制, 未能开展训练。

训练采用了在 COCO 数据集上预训练的 YOLOv8-Pose 模型。由于该模型已经具备一定的学习能力, 因此它对数据集的学习要求相对较低。为了进一步提高模型的性能, 结合了多种数据增

强手段, 包括调整图像的 HSV 色调、饱和度与亮度, 实施随机旋转和缩放处理, 以及采用 mosaic 图像处理方法等, 以增加数据集的多样性。具体训练参数见表 2。

表 2 姿态估计任务训练参数

Tab. 2 Training parameters for the pose estimation task

模型参数	参数值	模型参数	参数值
图像尺寸	640、1 280	预训练	True
训练批次	100	mosaic	True
目标类别	2	HSV	0.015、0.7、0.4
关键点类别	7	缩放比例	0.5
初始学习率	0.01	旋转角度	-10° ~ +10°

Pose loss 在姿态估计网络中占据重要地位。如图 8 所示, YOLOv8-Pose 模型在不同 Batch Size 下的损失均呈现下降趋势并逐渐趋于平稳。值得注意的是, 在最后 10 个 epochs 阶段, 由于停止了 mosaic 数据增强, 模型在第 90 个 epoch 时损失函数出现快速下降。此外, Batch Size 越大, Pose loss 的收敛速度越慢。然而, 这并不意味着 Batch Size 与模型训练最终效果有直接关联, 因此还需要结合模型在验证集上的表现来进行全面评估。

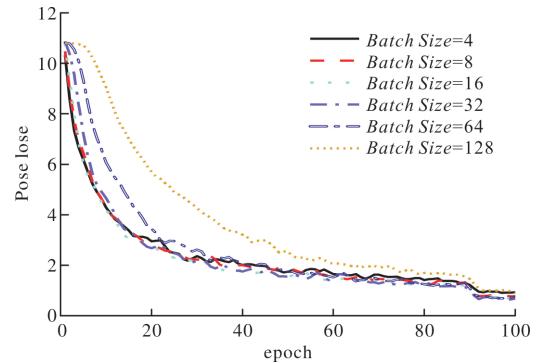


图 8 YOLOv8n-pose loss 函数

Fig. 8 YOLOv8n pose loss function

### 2.4 模型评估

在深度学习任务的性能评估中, 常用正确率(Precision, P)、召回率(Recall, R)、F1 分数和 mAP 等指标来衡量模型的学习效果。正确率 P 和召回率 R 这两个指标均反映了模型的识别能力, 同时相互制约, 更高的 R 会导致 P 下降, 反之同理。F1 分数作为 P 和 R 的调和平均值, 综合考量了 P 和 R 两个指标, 其值越高, 表示模型的性能越好。AP 指标是在 P-R 曲线的基础上积分得到的, 代表了在不同阈值下的检测准确率均值, 是深度学习任务中的重要评估指标。mAP 则是各类别 AP 的均值, 用于更全面地评估模型的整体性。

能。计算公式如下。

$$P = \frac{TP}{TP+FP} \quad (6)$$

$$R = \frac{TP}{TP+FN} \quad (7)$$

$$F1 = 2 \cdot \frac{P \cdot R}{P+R} \quad (8)$$

$$AP = \int_0^1 PR dR \quad (9)$$

$$mAP = \sum AP/Q \quad (10)$$

式中:  $TP$  表示正确识别为正样本数量;  $FP$  表示误识别为正样本的负样本数量;  $FN$  表示误识别为负样本的正样本数量;  $Q$  表示目标检测或关键点检测的种类数。

各评估指标列于表 3。其中,  $mAP50$  表示阈值在 50% 时的  $AP$  均值,  $mAP50-95$  表示阈值在 50%~95% 范围内的  $AP$  均值。 $mAP50-95$  更能全面反映模型的综合性能。“B”代表目标检测任务, “P”代表关键点检测任务。

表 3 模型评估指标值

Tab. 3 The value of the model evaluation metrics

模型	Pose loss	mAP 50(B)	mAP 50-95(B)	mAP 50(P)	mAP 50-95(P)
n-4	0.923	0.951	0.725	0.932	0.831
n-8	0.754	0.950	0.743	0.928	0.827
n-16	0.650	0.936	0.738	0.912	0.823
n-32	0.673	0.947	0.766	0.923	0.839
n-64	0.710	0.942	0.749	0.916	0.809
n-128	0.886	0.930	0.709	0.884	0.739
s-4	0.870	0.943	0.719	0.917	0.827
s-8	0.646	0.947	0.758	0.924	0.861
s-16	0.566	0.938	0.759	0.924	0.861
s-32	0.524	0.944	0.760	0.919	0.853
s-64	0.601	0.948	0.752	0.932	0.865
m-4	0.726	0.936	0.713	0.908	0.832
m-8	0.652	0.927	0.713	0.915	0.840
m-16	0.526	0.932	0.764	0.907	0.853
m-32	0.539	0.928	0.756	0.901	0.857
l-4	0.615	0.939	0.701	0.916	0.857
l-8	0.552	0.936	0.721	0.915	0.871
l-16	0.426	0.917	0.754	0.883	0.850
l-32	0.431	0.939	0.767	0.919	0.890
x-4	0.665	0.936	0.703	0.908	0.850
x-8	0.534	0.944	0.716	0.922	0.872
x-16	0.439	0.933	0.742	0.907	0.872
x-P6-4	0.676	0.942	0.675	0.919	0.857

以  $mAP50-95(P)$  指标为依据, 选取五个性能较好的模型进行对比。这五个 YOLOv8-Pose 模型

分别为 s-64、l-8、l-32、x-8 和 x-16, 它们的 Pose loss 相较于其他模型收敛于较小的损失值。五个模型的评估指标值如图 9 所示。训练结束时, loss 和  $mAP$  等指标已趋于平衡。通过对比曲线和评估指标发现, 五个模型的性能较为接近。其中,  $mAP50$ (B) 的值均在 0.93 至 0.95 的范围内, 而  $mAP50-95(P)$  的值则均在 0.87 至 0.89 的范围内。

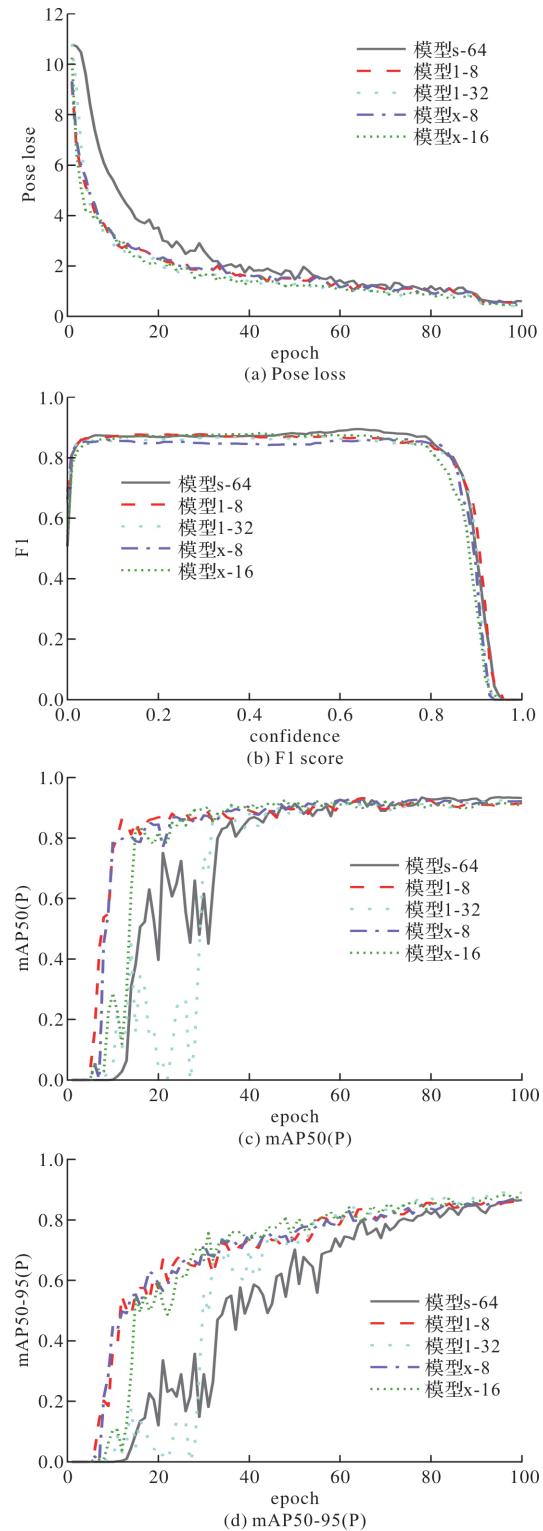


图 9 评估指标

Fig. 9 Evaluation metrics

在关键点检测任务中, 模型通过推理来预测关键点的坐标, 如图 10 所示。假设 A 是某一目标的关键点, 而 A1~A5 则是各个模型对该关键点的预测结果。尽管关键点 A 也可能被某个模型检测出来, 但综合来看, 各模型的检测点往往会在目标点 A 附近呈环形分布。当预测的坐标用于角度计算时, 即使出现仅 1 像素误差, 也可能对计算出的角度产生显著影响。因此, 为确定最优模型, 需通过测试试验, 对比不同模型的转动角度计算精度以评估最优模型。

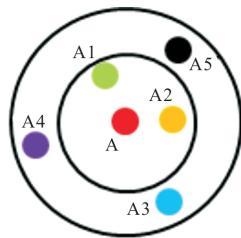


图 10 关键点检测示意图

Fig. 10 Schematic diagram of keypoint detection

### 3 验证实验

#### 3.1 实验模型

实验模型选用宋式重棋出单抄单下昂柱头铺作  $1:10$  缩尺模型, 遵循《营造法式》形制要求。材质为北美红樱桃, 规格为  $180 \text{ mm} \times 110 \text{ mm} \times 180 \text{ mm}$ , 模型包括斗、枋、栱等 29 种不同的组件, 共计 54 个。按照图 7 视角采集图像, 如图 11 所示。根据转动变形定义, 需检测模型上的 3 处 D 类别关键点和 6 处 S 类别关键点。



图 11 实验模型

Fig. 11 Experiment model

#### 3.2 转动工况设计

一般情况下, 斗拱在实际结构中转动角度通常比较小。将图 11 初始状态设置为转动工况 Rotation-1。将 Rotation-1 图像分别顺时针转动  $5^\circ$  和  $10^\circ$ , 并将这两种状态分别设置为转动工况 Rota-

tion-2 和 Rotation-3。由于实验模型中各构件并非紧密连接, 存在一定的相对位移, 因此需通过表 4 中关键点坐标来计算真实的转动角度。根据坐标信息, 计算得到 Rotation-1 工况下的实际角度  $\theta_0$  为  $-0.18^\circ$ ,  $\theta_1$  为  $-1.31^\circ$ 。三类工况真实角度值以及模型计算值分别列于表 5~表 7 中, 其中, 向左倾斜的角度被定义为负值。

表 4 Rotation-1 人工选取关键点坐标

Tab. 4 Manually selected key point coordinates of Rotation-1

位置	L3		R3	
	x	y	x	y
$D_0$	236	558	351	558
$D_1$	254	401	332	400
$D_2$	244	205	333	203

由表 5~表 7 可知, 各姿态估计模型的计算结果与人工选取的关键点计算结果相差不大, 表明这些模型取得了较好的学习成效。计算得到 5 个模型在 3 种工况下的误差绝对值的平均值, 分别为  $0.23$ 、 $0.13$ 、 $0.48$ 、 $0.73$  和  $0.38$ 。其中, YOLOv8-pose 模型 l-8, 计算效果最优, 最大误差为  $-0.45^\circ$ , 最小误差为  $0^\circ$ 。为进一步验证该模型性能, 利用该模型对实验模型中单个斗的转动角度  $\lambda_{ij}$  进行计算。工况 Rotation-2 和 Rotation-3 结果列于表 8。

表 5 Rotation-1 工况  $\theta_i$  计算

Tab. 5 Calculation of Rotation-1 condition

模型	$\theta_0 = -0.18^\circ$		$\theta_1 = -1.31^\circ$	
	计算值/ $^\circ$	绝对误差/ $^\circ$	计算值/ $^\circ$	绝对误差/ $^\circ$
s-64	-0.54	-0.36	-1.32	-0.01
l-8	-0.18	0	-1.31	0
l-32	0	0.18	-0.73	-0.58
x-8	-0.89	-0.71	-1.18	0.13
x-16	-0.54	-0.36	-1.02	0.29

表 6 Rotation-2 工况  $\theta_i$  计算

Tab. 6  $\theta_i$  Calculation of Rotation-2 condition

模型	$\theta_0 = 4.82^\circ$		$\theta_1 = 3.69^\circ$	
	计算值/ $^\circ$	绝对误差/ $^\circ$	计算值/ $^\circ$	绝对误差/ $^\circ$
s-64	5.10	0.28	4.41	0.72
l-8	4.74	-0.07	3.24	-0.45
l-32	5.51	0.69	4.00	0.30
x-8	3.64	-1.17	4.56	0.87
x-16	5.33	0.51	3.61	-0.08

表 7 Rotation-3 工况  $\theta_i$  计算Tab. 7  $\theta_i$  Calculation of Rotation-3 condition

模型	$\theta_0 = 9.82^\circ$		$\theta_1 = 8.69^\circ$	
	计算值/°	绝对误差/°	计算值/°	绝对误差/°
s-64	10.81	0.99	8.59	-0.10
l-8	9.70	-0.12	8.81	0.12
l-32	9.37	-0.45	9.34	0.65
x-8	10.86	1.04	9.14	0.46
x-16	10.38	0.57	8.21	-0.48

表 8 斗转动角度  $\lambda_{ij}$  计算Tab. 8  $\lambda_{ij}$  Calculation of Dou rotation

转动	Rotation-2/°			Rotation-3/°		
	真实值	计算值	绝对误差	真实值	计算值	绝对误差
$\lambda_{01}^-$	5.44	5.62	0.18	10.44	9.04	-1.40
$\lambda_{01}^+$	5.19	5.19	0	10.18	10.78	0.59
$\lambda_{11}^-$	4.48	3.43	-1.05	9.48	8.53	-0.95
$\lambda_{11}^+$	5.49	5.60	0.11	10.49	10.01	-0.48
$\lambda_{21}^-$	2.60	2.66	0.06	7.60	7.82	0.21
$\lambda_{21}^+$	1.85	2.82	0.97	6.85	5.71	-1.14

图 12 给出了 YOLOv8 模型 l-8 在 Rotation-1 工况下关键点检测结果。可以看出，D 类和 S 类斗构件及其内部关键点均被成功检测出来。各个关键点之间通过直线连接，描绘出了斗构件的轮廓形状。

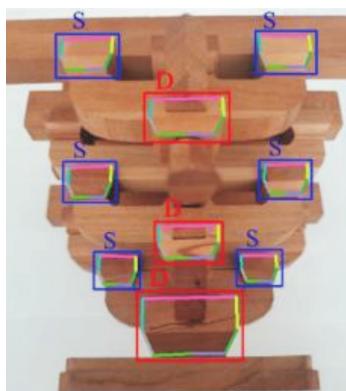


图 12 关键点检测结果

Fig. 12 Keypoint detection results

### 3.3 枠斗与阑额相对转动验证实验

枠斗与下方阑额构件的相对转动角度按照 1.3 节所提方法计算。为直观展示计算过程，截取了枠斗与阑额构件的局部区域，并放大了相对转动区域，如图 13(a)所示。通过计算分析两构件相对于图像水平方向的转动角度可得到斗栱相对于木构架的相对转动情况。枠斗的转动角度仍通过姿态估计检测 L3 和 R3 关键点来计算。而阑额构件的转动角度则是通过计算霍夫检测所得直线与水平方向的夹角计算得出。处理过程如图 13 所示。

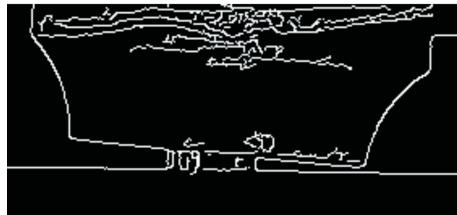
在处理过程中，首先运用双边滤波对图像进行了灰度处理，如图 13(b)所示。不仅削弱了木材内部纹理、表观裂纹的影响，还突出了边界信息；接着使用 Canny 边缘检测算法，将图像的边缘信息可视化为白色像素，而非边缘信息可视化为黑色背景，如图 13(c)所示；最后，利用直线检测对边缘中的点进行分析，成功检测出了阑额构件边缘，如图 13(d)所示。



(a) 相对转动区域



(b) 双边滤波



(c) Canny 边缘检测



(d) Hough 直线检测

图 13 阑额转动计算

Fig. 13 Rotation calculation of Lan-E

直线转动角度  $\theta_L$  和枠斗转动角度  $\lambda_0$ 。计算结果见表 9，计算误差均较小。

表 9 相对转动角度

Tab. 9 Angle of relative rotation

参数值	真实值/°	计算值/°	绝对误差/°
$\theta_L$	0.84	0.99	0.15
$\lambda_0$	5.87	5.66	-0.21

通过  $\theta_L$  和  $\lambda_0$  换算得出枠斗相对于木构架的转动角度计算值为  $4.42^\circ$ 。由此可知，当测出的角度  $\theta_L$  和  $\lambda_0$  相差较小时，代表枠斗与木结构连接较为紧密。此时枠斗的转动主要是由下方梁枋构件引

起的。反之,如果 $\theta_L$ 和 $\lambda_0$ 相差较大,则代表斗拱与阑额构件出现了相对转动。

## 4 结论

(1) 对斗拱每一层之间的转动角度 $\theta_i$ 、单个斗构件的转动角度 $\lambda_{ij}$ 、斗拱构件7个关键点以及拍摄角度进行定义。同时,构建具有多样性的斗拱节点数据集,为深度学习姿态估计研究提供学习样本;

(2) 开展涵盖23类工况的YOLOv8-Pose姿态估计算法对比训练实验,获得5个高性能模型。在目标检测部分,mAP50(B)可达0.94;关键点检测部分mAP50(P)可达0.91;mAP50-95(P)可达0.87;

(3) 五个最优模型需结合转动角度计算实验综合评估。经过三个转动工况实验,得出最优模型1-8,其角度计算误差最大为 $-0.45^\circ$ ,最小为 $0^\circ$ 。同时,结合斗拱与阑额相对转动的实验结果证明,该方法能够有效分析斗拱在木结构中的转动情况。

针对(1)和(2)部分,后续研究将进一步探究丰富数据集多样性和提高训练工况强度,以提高转动变形的检测精度,同时,增强模型的适用性,使其能够适应更多类型的斗拱,包括多类型损伤斗拱等复杂情况,从而进一步拓展论文所提方法在实际工程中的应用潜力。

## 参考文献 References

- [1] 隋癸,赵鸿铁,薛建阳,等.古建木构斜侧向刚度的试验研究[J].西安建筑科技大学学报(自然科学版),2009,41(5): 668-671.  
SUI Yan, ZHAO Hongtie, XUE Jianyang, et al. Experimental research on the lateral stiffness of ancient wooden dougong [J]. J. Xi'an Univ. of Arch. & Tech. (Natural Science Edition), 2009, 41 (5): 668-671.
- [2] 吴晨伟,薛建阳,宋德军,等.歪闪平身科斗拱轴压性能试验研究及有限元分析[J/OL].工程力学,2023: 1-11. 2023-06-13. [2024-04-26]. <http://kns.cnki.net/kcms/detail/11.2595.O3.20230612.1556.003.html>.  
WU Chenwei, XUE Jianyang, SONG Dejun, et al. Experimental research and finite element analysis on axial compression performance of inclined pingshenke DOU-GONG brackets [J/OL]. Engineering Mechanics, 2023: 1-11. 2023-06-13. [2024-04-26]. <http://kns.cnki.net/kcms/detail/11.2595.O3.20230612.1556.003.html>.
- [3] 邵云,邱洪兴,乐志,等.宋、清式斗拱低周反复荷载试验研究[J].建筑结构,2014, 44(9): 79-82, 38.  
SHAO Yun, QIU Hongxing, LE Zhi, et al. Experimental study of low-cycle loading test on Song-style and Qing-style dougong[J]. Building Structure, 2014, 44(9): 79-82, 38.
- [4] 谢启芳,向伟,杜彬,等.残损古建筑木结构叉柱造式斗拱节点抗震性能退化规律研究[J].土木工程学报,2014,47(12): 49-55.  
XIE Qifang, XIANG Wei, DU Bin, et al. Study on seismic behavior degradation of damaged "Dougong" joint built with fork column of Chinese ancient timber structure[J]. China Civil Engineering Journal, 2014, 47(12): 49-55.
- [5] 陈九璋,陈雪瑶,戴璐.残损斗拱节点受力性能试验研究[J].北京林业大学学报,2020,42(2): 149-158.  
CHEN Jiuzhang, CHEN Xueyao, DAI Lu. Experimental research on mechanical performance of damaged bracket set joints [J]. Journal of Beijing Forestry University, 2020, 42(2): 149-158.
- [6] 薛建阳,宋德军,吴晨伟,等.不同倾斜角度下平身科斗拱抗震性能研究[J/OL].工程力学,2023: 1-13. 2023-11-27. [2024-04-26]. <http://kns.cnki.net/kcms/detail/11.2595.O3.20231124.1506.010.html>.  
XUE Jianyang, SONG Dejun, WU Chenwei, et al. Study on seismic behavior of DOU-GONG bracket sets between columns under different inclinations [J/OL]. Engineering Mechanics, 2023: 1-13. 2023-11-27. [2024-04-26]. <http://kns.cnki.net/kcms/detail/11.2595.O3.20230612.1556.003.html>.
- [7] 薛建阳,路鹏,董晓阳.古建筑木结构歪闪斗拱抗震性能的ABAQUS有限元分析[J].世界地震工程,2017,33(4):11-17.  
XUE Jianyang, LU Peng, DONG Xiaoyang. Finite element analysis on the seismic behavior of the skewed DOU-GONG brackets in ancient timber buildings by ABAQUS program [J]. World Earthquake Engineering, 2017,33(4): 11-17.
- [8] 薛建阳,路鹏,董晓阳.古建筑木结构歪闪斗拱竖向受力性能的ABAQUS有限元分析[J].西安建筑科技大学学报(自然科学版),2017,49(1): 8-13.  
XUE Jianyang, LU Peng, DONG Xiaoyang. Finite element analysis on the vertically mechanical behavior of the skewed Dou-Gong in ancient timber buildings by ABAQUS program [J]. J. Xi'an Univ. of Arch. & Tech. (Natural Science Edition), 2017,49(1): 8-13.
- [9] 叶肖伟,董传智.基于计算机视觉的结构位移监测综述[J].中国公路学报,2019,32(11): 21-39.  
YE Xiaowei, DONG Chuanzhi. Review of computer vision-based structural displacement monitoring [J].

- China Journal of Highway and Transport, 2019, 32 (11): 21-39.
- [10] ATHA D J, JAHANSOHI M R. Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection [J]. Structural Health Monitoring, 2018, 17(5): 1110-1128.
- [11] LIU J J, LIU C Y, WU Y Q, et al. Insulators' identification and missing defect detection in aerial images based on cascaded YOLO models [J]. Computational Intelligence and Neuroscience, 2022; 1-15.
- [12] 杨娜, 张翀, 李天昊. 基于无人机与计算机视觉的中国古建筑木结构裂缝监测系统设计 [J]. 工程力学, 2021, 38(3): 27-39.  
YANG Na, ZHANG Chong, LI Tianhao. Design of crack monitoring system for Chinese ancient wooden buildings based on UAV and CV[J]. Engineering Mechanics, 2021, 38(3): 27-39.
- [13] 刘纲, 顾嘉伟, 李孟珠, 等. 基于数字图像相关的古建筑彩绘梁损伤识别方法 [J]. 土木与环境工程学报(中英文), 2022, 44(2): 148-157.  
LIU Gang, GU Jiawei, LI Mengzhu, et al. Damage identification method of painted beams based on digital image correlation[J]. Journal of Civil and Environmental Engineering, 2022, 44(2): 148-157.
- [14] 马健, 阎卫东, 刘国奇. 基于 YOLO v5 的古建筑木结构裂缝检测方法 [J]. 沈阳建筑大学学报(自然科学版), 2021, 37(5): 927-934.  
MA Jian, YAN Weidong, LIU Guoqi. Research on crack detection method of wooden ancient building based on YOLO v5 [J]. Journal of Shenyang Jianzhu University (Natural Science), 2021, 37(5): 927-934.
- [15] 杨娜, 王砾, 汪德佳. 基于计算机视觉的藏式古建筑石砌体壁画墙裂缝生长变形监测 [J/OL]. 工程力学, 2023; 1-15. 2023-05-22. [2024-04-26]. <http://kns.cnki.net/kcms/detail/11.2595.O3.20230519.1729.016.html>.  
YANG Na, WANG Shuo, WANG Dejia. Deformation monitoring during the growth of cracks in-mural walls with stone masonry material of Tibetan ancient buildings based on computer vision[J/OL]. Engineering Mechanics, 2023; 1-15. 2023-05-22. [2024-04-26]. <http://kns.cnki.net/kcms/detail/11.2595.O3.20230519.1729.016.html>.
- [16] WANG N N, ZHAO X f, ZOU Z, et al. Autonomous damage segmentation and measurement of glazed tiles in historic buildings via deep learning [J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35 (3): 277-291.
- [17] HU D A, YU M, WU X Y, et al. DGW-YOLOv8: A small insulator target detection algorithm based on deformable attention backbone and WIoU loss function [J]. IET Image Processing, 2024, 18(4): 1096-1108.
- [18] ZHANG L J, FANG J J, LIU Y X, et al. CR-YOLOv8: Multiscale object detection in traffic sign images [J]. IEEE Access, 2023, 12: 219-228.
- [19] FANG S, YANG L, TANG J, et al. Visual measurement of lateral relative displacement of wheel-rail of high-speed train under earthquake [J]. Engineering Structures, 2024, 305: 117736.
- [20] SUN C, GU D, LU X. Three-dimensional structural displacement measurement using monocular vision and deep learning based pose estimation [J]. Mechanical Systems and Signal Processing, 2023, 190: 110141.
- [21] SAMET N, AKBAS E. HPRNet: Hierarchical point regression for whole-body human pose estimation [J]. Image and Vision Computing, 2021, 115: 104285.
- [22] MUKHOPADHYAY P, CHAUDHURI B B. A survey of hough transform [J]. Pattern Recognition, 2015, 48(3): 993-1010.
- [23] LI S, SCHIEBER H, CORELL N, et al. GBOT: Graph-based 3D object tracking for augmented reality-assisted assembly guidance [C]//2024 IEEE Conference Virtual Reality and 3D User Interfaces (VR). Orlando: IEEE, 2024: 513-523.

(编辑 郑晓龙 李睿奇)