

文章编号:1673-9469(2024)05-0008-08

DOI:10.3969/j.issn.1673-9469.2024.05.002

## 基于改进视图聚类的装配式建筑构件识别方法

李志猛,廖伟文,洪学武,张龙,钟文,赵坚\*

(天津城建大学控制与机械工程学院,天津300384)

**摘要:**为实现装配式建筑构件生产、存放和装配过程的智能化,设计了一种基于改进视图聚类的在线识别方法。该方法通过在信息瓶颈算法中加入标签信息嵌入和标签信息固化两个环节,将传统视图聚类算法改进为可用于装配式建筑构件在线识别的无监督模式识别方法。该方法在天津某工业化建筑公司的真实数据集上进行了测试,实验结果表明,模型识别精度达到90%以上,优于Softmax神经网络、支持向量机和贝叶斯网络等有监督模式识别方法。

**关键词:**视图聚类;信息瓶颈;装配式;在线识别

**中图分类号:**TP391.4;TU69

**文献标识码:**A

## Prefabricated Building Component Recognition Method Based on Improved View Clustering

LI Zhimeng, LIAO Weiwen, HONG Xuewu, ZHANG Long, ZHONG Wen, ZHAO Jian\*

(School of Control and Mechanical Engineering, Tianjin Chengjian University, Tianjin 300384, China)

**Abstract:** In order to realize the intelligence of the production, storage and assembly process of prefabricated building components, an online recognition method based on improved view clustering was designed. By adding label information embedding and label information solidification into the information bottleneck algorithm, the traditional view clustering algorithm was improved into an unsupervised pattern recognition method which could be used for online recognition of prefabricated building components. The method was tested on the real data set of an industrial construction company in Tianjin, and the experimental results show that the model recognition accuracy is above 90%, which is superior to Softmax neural network, support vector machine, Bayesian network and other supervised pattern recognition methods.

**Key words:** view clustering; information bottleneck; prefabricated; online recognition

近年来,建筑业作为国民经济支柱产业的作用不断增强,然而目前依然存在发展方式粗放、劳动生产率低、高耗能高排放等问题。构建装配式建筑标准化设计和生产体系,扩大标准化构件和部品部件使用规模,对于提升建筑工业化、数字化、智能化水平具有重要作用。目前装配式预制板在工程项目中的应用较多,促进了建筑工程的工业化发展<sup>[1]</sup>。

随着人工智能和机器人技术的发展,装配式预制构件的生产正从依赖人力的方式转变为自动化生产方式。谢琳琳等<sup>[2]</sup>结合BIM和数字孪生技术对项目的现场施工方案进行虚拟仿真调试,为现场施工提供参考。兰永祥<sup>[3]</sup>在地铁全装配式车站建设中使用预制构件智能生产信息化管理技术,提高了生产效率和质量控制水平。李文乔等<sup>[4-5]</sup>利用Revit软件建立装配式预制构件模型,采用工业基础类标准完成装配式预制构件质量

收稿日期:2023-10-31

基金项目:天津市自然科学基金重点项目(16JCZDJC38600)

作者简介:李志猛(1987-),男,内蒙古赤峰人,博士,讲师,研究领域为智能制造与故障诊断。

\*通信作者:赵坚(1966-),女,山西太原人,博士,教授,研究领域为动态测试与智能诊断。

自动化检测技术,为实现快速、精确的质量检测提供了新的解决方案。然而,这些自动化技术通常采用激光扫描和大量人工操作,导致成本增加。为了解决这类问题,熊朝阳等<sup>[6]</sup>采用视觉识别技术,成功提升了建筑构件质量检测的效率,使得检测更加精确无误。在视觉识别技术中,传统的机器学习算法如支持向量机<sup>[7]</sup>和随机森林<sup>[8]</sup>通常要手动选择合适的特征,并对模型进行参数调整。相比之下,深度学习技术中的卷积神经网络算法可以从原始数据中自动学习特征和模型表示。例如,刘文涛等<sup>[9]</sup>使用 FCN 对建筑屋顶进行监测,陈墨等<sup>[10]</sup>采用 R-CNN 对建筑表面裂缝缺陷进行识别,邢金昊等<sup>[11]</sup>基于改进的 YOLO 对建筑预埋件进行检测。以上深度学习算法比传统的机器学习算法优越性更好,提高了建筑物的质量和可靠性。然而,深度学习算法通常需要大量的计算资源和时间来进行训练,尤其是在深层网络和大规模数据集上需要更多资源和时间。

因此,本文针对上述问题提出了一种基于信息瓶颈算法<sup>[12]</sup>的在线识别方法,该算法充分利用

了传统机器学习中的特征提取和数据处理技术,同时还引入了信息瓶颈算法作为深度学习的一部分,以从数据中自动学习高级特征表示,结合了传统机器学习和深度学习的优点。该方法首先使用  $k$ -均值聚类对生产后的构件进行碎片化分类,然后通过信息瓶颈算法进行图像聚类,以确保对构件进行有效分类。

### 1 视图聚类方法原理

视图聚类基于数据的不同视图或表示进行聚类。基本思想是将不同视图之间的相似性或相关性结合起来,以识别具有相似特征的样本,并将它们归为同一簇。在进行视图聚类时,通常需要定义不同视图之间的相似性度量或相关性度量。这些度量可以基于不同视图之间的距离、相关性系数、相似性度量等进行定义。本文将视图聚类应用于图形分类。视图聚类方法结构主要由四部分组成:图像预处理、加速稳健特征(Speeded Up Robust Features, SURF)提取、 $k$ -均值聚类和信息瓶颈图像分类,其结构如图 1 所示。

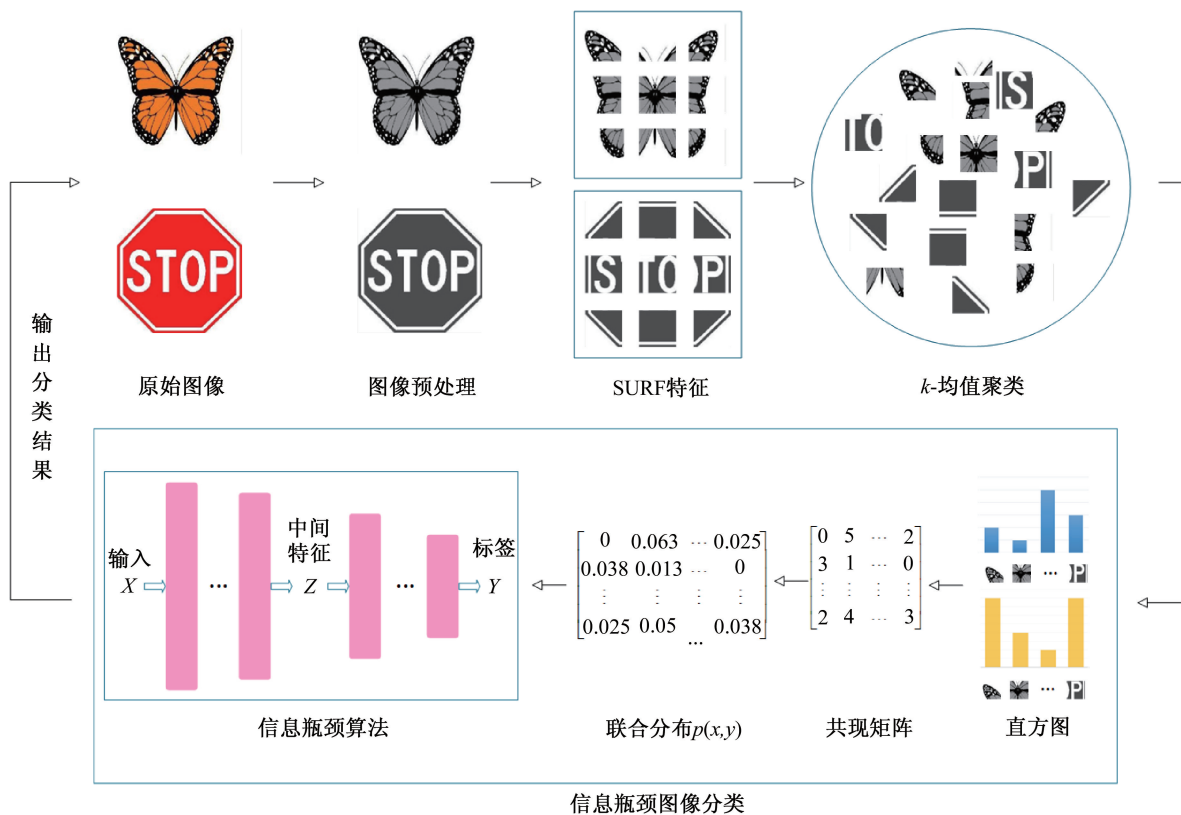


图 1 算法结构图

Fig. 1 Algorithm structural diagram

## 1.1 图像预处理

### 1.1.1 图像灰度化

为了降低后续的计算量并提高识别准确率,采取有效的方法来降低相机在工业现场采集的图像中的冗余信息。先将相机采集到的图像传递给程序,然后对图片进行灰度化处理,有效地保留图像的整体和局部信息。在彩色图像中,任一像素具有3个像素值,即 $R$ 、 $G$ 、 $B$ ,分别表示红色、绿色、蓝色的像素值,可通过下式将其灰度化为1个像素值:

$$I = W_r R + W_g G + W_b B \quad (1)$$

式中: $I$ 为该像素点的灰度值, $W_r$ 、 $W_g$ 、 $W_b$ 分别是 $R$ 、 $G$ 、 $B$ 的权值,实验表明当 $W_r=0.299$ 、 $W_g=0.587$ 、 $W_b=0.114$ 时,灰度化效果最佳<sup>[13]</sup>。

### 1.1.2 图像压缩

需要在特征提取之前对采集的图像进行尺寸压缩处理。这样既能避免特征被削弱,又能减少分类精度低的问题。使用公式(2)的双线性差值算法对图像的每个像素点 $f(i,j)$ 进行计算<sup>[14]</sup>。在 $i,j$ 方向分别插值,最后再插值得到中间像素值快速地调整图片尺寸。将图片像素调整为 $200 \times 250$ 。它可以提高图像质量,为后续的特征提取和识别分析提供更好的基础。

$$f(i,j) = w_1 p_1 + w_2 p_2 + w_3 p_3 + w_4 p_4 \quad (2)$$

式中: $p_i(i=1,2,3,4)$ 为最近的四个像素点, $w_i(i=1,2,3,4)$ 为各点相应权值。

## 1.2 SURF 特征提取

本文利用SURF算法来提取图像的特征。通过计算每张图片的SURF特征点集的位置和尺度,可以获得图像的特征描述子。由于SURF特征具有尺度、方向不变性,对光照变化及仿射变化能保持一定的稳定性;与SIFT特征相比,SURF特征速度上有很大的提升,因此利用SURF特征能很好地描述图像内容情况。

首先利用Hessian矩阵对图像进行特征点的检测,每个像素点Hessian矩阵行列式的响应值大小决定了该像素点是否为极值点。同时为了保证检测出来的特征点具有尺度不变性,SURF算法将高斯拉普拉斯算子(LOG)与Hessian矩阵行列式计算相结合,保证了利用Hessian矩阵行列式检测出来的特征点具有尺度不变性。Hessian矩阵是一个描述图像局部特征形状和尺度信息的二阶偏导数矩阵,定义为式(3):

$$H(x,\delta) = \begin{bmatrix} L_{xx}(x,\delta) & L_{xy}(x,\delta) \\ L_{xy}(x,\delta) & L_{yy}(x,\delta) \end{bmatrix} \quad (3)$$

式中: $H(x,\delta)$ 为该像素点的响应值, $L_{xy}$ 、 $L_{xx}$ 、 $L_{yy}$ 为高斯滤波后图像 $g(\delta)$ 在各个方向的二阶导数。

通过加权后的差分高斯滤波后,计算得到 $xx$ 、 $yy$ 、 $xy$ 三个方向的二阶微分响应(分别为 $D_{xx}$ 、 $D_{yy}$ 、 $D_{xy}$ ),代替了原来的 $L_{xx}$ 、 $L_{yy}$ 、 $L_{xy}$ 之后,利用积分图像的概念来计算响应的值。则在尺度 $\delta$ 上,某一图像点 $\det(H)$ 是否为关键点,可通过式(4)近似计算该点Hessian矩阵行列式的值来判别,如 $\det(H)>0$ ,表明该点为极值点。

$$\det(H) = D_{xx} D_{yy} - (\omega D_{xy})^2 \quad (4)$$

式中: $\omega$ 为权重系数,其值与尺度 $\delta$ 相关,主要是为了平衡准确值与近似值之间的误差,在实际的应用中,通常取0.9。

通过调整盒子滤波器的大小,构建3组12层的尺度图像,以获得尺度不变的特征点。同时,通过改变模板尺寸和高斯滤波系数 $\sigma$ ,构建尺度图像金字塔。在此基础上进行特征点检测。检测出的特征点经过阈值筛选和非极大值抑制。在 $3 \times 3 \times 3$ 的邻域内计算特征点,并得到满足条件的特征点及其位置。

以特征点为中心,计算 $6s$ 邻域( $s$ 为特征点所在尺度)内像素的Haar小波响应,得到特征点的 $x$ 和 $y$ 方向的响应。最终,每个特征点的描述子就是一个64维的向量。最后,进行归一化处理,得到稳定的SURF特征描述向量。这些特征点是图像中具有独特纹理、边缘和角点的区域。便于后续 $k$ -均值聚类以及图像识别。

## 1.3 $k$ -均值聚类

$k$ -均值聚类算法是聚类分析中的一种基本划分方法。由于其算法简便,计算复杂度低,通常被作为聚类分析的首选方案。针对预制件图像内部结构复杂、目标间相似性大的特点,本文采用 $k$ -均值聚类的方法对图像特征进行分割,以实现更快速、更精准的分割结果。

在 $k$ -均值聚类算法中,首先从特征数据集中随机选择 $K$ 个数据点作为初始的聚类中心。然后,遍历数据集中的每个数据点,并使用欧氏距离作为度量标准来计算该数据点与所有聚类中心之间的距离。在第 $i(i=1,2,\dots,K)$ 类 $C_i$ 中有 $N_{c_i}$ 个样本 $x$ ,此时 $C_i$ 中所有样本的均值为 $m_i$ ,通过式(5)计算其所有数据点的均值,并将该均值作为新的聚类中心。重复之前的步骤,直到聚类中心不再发生变化或者达到预定的迭代次数。

$$m_i = \frac{1}{N_{ci}} \sum_{j=1}^{N_{ci}} x_j \quad (5)$$

### 1.4 信息瓶颈图像分类

经过聚类后的特征把信息相似的归为一起,然后通过构建直方图将特征值映射为频率分布,按照一定的区间进行统计,得到不同特征值的频率分布。所有这些直方图形成共生矩阵。为了更好地描述图像的特征统计信息,还需要对直方图进行归一化得到联合分布概率  $p(x,y)$ 。

最后,利用信息瓶颈算法,从联合分布概率  $p(x,y)$  选择最重要的特征,以实现图像的高效识别和分类。使用信息瓶颈的无监督计算方式,在互信息概念的基础上进行分类,互信息衡量了两个随机变量之间的相关性,表示了它们联合分布与各自边缘分布之间的相似程度。互信息描述了  $p(x,y)$  与两个边缘分布  $p(x)$  和  $p(y)$  乘积的相似程度,互信息  $I(X,Y)$  计算公式为

$$I(X,Y) = \sum_x \sum_y p(x,y) \log \frac{p(x,y)}{p(x)p(y)} \quad (6)$$

式中:  $p(x) = \sum_y p(x,y)$ ,  $p(y) = \sum_x p(x,y)$ 。

在信息瓶颈算法中,本文通过最大化特征变量  $T$  与原始数据  $X$  的互信息  $I(T,X)$ ,同时最小化  $T$  与目标变量  $Y$  的互信息  $I(T,Y)$  实现对数据的有损压缩,以保留最关键的特征信息。通过以下公式获取目标图像分类的最优解:

$$L_{\min}[p(t|x)] = I(T,X) - \beta I(T,Y) \quad (7)$$

式中:  $p(t|x)$  为隶属度概率,表示将每个点  $x$  分配给第  $t$  个聚类的可能性,  $\beta \in (0, +\infty)$  权衡了互信息的压缩和保存。

先初始化聚类的个数  $k$ ,随机初始化  $T$  的分布通过迭代优化,计算  $I(T,X)$  和  $I(T,Y)$  并更新  $T$  的分布。更新  $T$  的公式如式(8):

$$p(t|x) = \frac{p(t)}{Z(x,\beta)} e^{-\beta D_{KL}[p(y|x) \| p(y|t)]} \quad (8)$$

式中:  $p(t) = \sum_{x,y} p(x,y) p(t|x)$ ,  $p(y|t) = \frac{1}{p(t)} \sum_x p(x,y) p(t|x)$ ,  $Z(x,\beta)$  是一个归一化函数  $D_{KL}$  是 Kullback-Leibler 散度,计算如下:

$$D_{KL} = P(y|x) \log(P(y|x)/P(y|t)) \quad (9)$$

通过 Jensen-Shannon 散度判断  $p(t|x)$  的变化,设  $X$  表示任意离散随机变量  $p(X)$ ,定义两个分布  $p_1(x)$  和  $p_2(x)$  之间的 Jensen-Shannon (JS) 散度为

$$JS_{\Pi}[p_1,p_2] = H(\bar{p}) - \pi_1 H(p_1) - \pi_2 H(p_2) \quad (10)$$

式中:  $0 < \pi_1 < 1, 0 < \pi_2 < 1, \pi_1 + \pi_2 = 1, \bar{p} = \pi_1 p_1 + \pi_2 p_2$ , 熵为  $H(X) = -\sum_x p(x) \log p(x)$ 。通过这个过程,最终得到  $p(t|x)$ 。

## 2 基于改进的信息瓶颈的图像分类

改进的信息瓶颈算法在图像分类中具有关键作用。首先,通过引入图像标签作为输出,它可以在变量中保留与分类任务相关的信息。接下来,本文利用信息瓶颈原理选择最具信息量的特征。通过最小化  $T$  与目标变量  $Y$  的互信息,有效地减少冗余信息并保留关键信息。随后,预测新的标签分布,并验证其是否符合预期要求,从而进一步提高分类的准确度。如图 2 所示,改进的版本引入了更精细的潜变量分布和更智能的初始化方法,以优化特征选择过程。

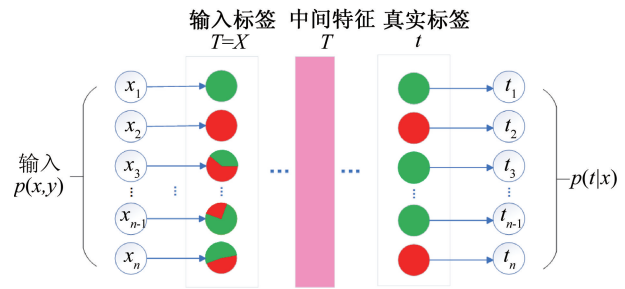


图 2 改进的信息瓶颈结构

Fig. 2 Improved information bottleneck structure

### 2.1 图像标签

由于信息瓶颈算法是一种用于无监督学习的方法,其迭代过程中使用了随机初始化,得到的结果通常是无序的。这导致不同的运行可能会将相同的输入图像分配到不同的类别中。这种无序性是由初始化过程中随机分配每张图像概率所导致的。为了解决这个问题并使结果变得有序,本文通过控制输入标签来约束算法的输出。具体而言,可以在初始化过程中先输入带有标签的图像,然后将特征明显的图像依次排列,并且以每张图像的标签作为输入,以确定其所属的类别,即本文从输入  $t$  类的图像中,每  $t_k$  类选择一张图像用于标签固定,如将  $x_i$  (其中  $i$  为前  $t$  个图像的个数) 关于  $t$  的占比改为  $p(t_{k=1}|x_i) = 1$ , 则  $p(t_{k \neq 1}|x_i) = 0$ 。除此之外的其他图像  $p(t|x)$  随机分配。在应用该方法时,需要仔细选择和输入标签,以确保它们能够准确地反映图像类别信息。通过这种方

式,本文将使用信息瓶颈算法对图像的分布  $p(x,y)$  进行计算,并在结果中获得一定程度的有序性。

## 2.2 图像分类

当应用信息瓶颈算法计算新的图像分布时,算法会在迭代过程对新的  $p(t|x)$  进行更新,以降低信息误差并提高图像识别的准确性,通过最大化输入与输出的互信息来学习有关数据的有用表示。即通过公式(8)计算  $p(t|x)_{new}$  时,算法在迭代中会不断调整模型参数,以使预测的标签分布  $p(t|x)$  与真实标签分布  $p(t|x)$  之间的互信息最大化。在每次迭代中,信息瓶颈算法会根据当前的模型参数和输入数据,计算新的预测标签分布  $p(t|x)_{new}$ 。新的分布基于先前迭代中得到的结果,会尝试降低信息误差,即与真实标签分布之间的差异。但是会导致最终结果图像的标签丢失从而失去对图像分类的意义。因此本文在通过不断迭代计算新的预测标签分布的时候,通过随机数  $\beta$  对计算得到的  $p(t|x)_{new}$  标签与输入的  $p(t|x)$  标签进行比较使模型逐步优化,选择最优  $\beta$  并提高图像识别的准确率。算法通过调整模型参数和优化损失函数,使得预测的标签分布与真实标签分布之间的互信息逐渐增加,从而更好地捕捉图像类别信息。因此,在该算法中,通过迭代计算新的图像分布  $p(t|x)_{new}$ ,可以实现不改变之前的图像标记并提高图像识别的准确率。这种迭代过程可以降低信息误差,使得算法的输出结果更加有序。

本文通过对此算法进行 5、10、20 次循环,选择最佳互信息实验,对比发现循环 5 次的互信息为最佳。算法 1 给出了图像分类的伪代码。

### 算法 1:构建视图分类

输入:联合分布概率  $p(x,y)$ , 图像类别种类  $t$ 。

输出:分布结果  $p(t|x)$

For  $i=5$

1. 初始化:随机分配  $x$  在  $t$  中信息的占比。

2. 对前  $t$  个图像进行标定。

3. Repeat

通过公式(9)求  $D_{KL}$  最小化分布,对  $\beta$  进行控制,由公式(7)求得  $p(t|x)_{new}$

If  $p(t|x)_{new(1,t)} = p(t|x)_{(1,t)}$

$p(t|x) = p(t|x)_{new}$

4. Until  $JS_{II}$  集群的数据点保持不变。

End

根据公式(7)找到最优结果  $p(t|x)$ 。

综合上述步骤,通过计算特征与类别的互信息,筛选出最重要的特征。互信息度量了特征与类别之间的相关性和信息量,信息瓶颈算法将尝试选择最能代表类别信息的特征进行归类,从而实现图像的高效识别和分类。这种复合方法能够在图像识别任务中获得优异的性能,使计算机能够更加准确地理解和解析图像信息,从而实现自动化的图像识别和分类应用。

## 3 实验与分析

### 3.1 实验概述

本文实验所用计算机的配置为:11th Gen Intel (R) Core (TM) i5-11260 H, 主频 2.6 GHz, 内存 16 GB, 显存 8 GB。使用的数据集均为天津某装配式建筑有限公司现场拍摄,如图 3 为该公司存放预制板件的场地,可以真实地反映实际工程场景。采集过程中考虑了预制板摆放位置、设备的存在等环境因素,提出的算法在自制的数据集上进行实验,所拍摄的工件类型是在装配式建筑中常见的。实验数据集采用的构件图像为现场拍摄,表 1 所示为 5 种不同类型的构件,样本总数为 25 张。其中每种构件选取 1 张作为标记样本,其余 20 张作为测试样本。



图 3 产品放置场地

Fig. 3 Product storage area

### 3.2 实验结果分析

方向梯度直方图 (Histogram of Oriented Gradient, HOG) 与局部二值模式 (Local binary patterns, LBP) 是目标检测和图像匹配中常用的特征描述子,所提取的特征对图像的结构进行描述,在图像匹配中经常使用<sup>[15-16]</sup>。为了验证本文算法的有效性,本文进行了 HOG 特征、LBP 特征与支持向量机 (Support Vector Machines, SVM)、Softmax 回归、

表 1 构件种类表

Tab. 1 List of component types




表 2 聚类评价指标比较

(单位: %)

Tab. 2 Comparison of cluster evaluation indicators

(unit: %)

算法	纯度	聚类相似性度量	归一化互信息	基于类的交叉熵	基于聚类的交叉熵
方向梯度直方图结合 Softmax 回归	95	91.52	93.30	8.40	4.31
方向梯度直方图结合贝叶斯分类器	70	72.25	68.53	19.85	36.29
方向梯度直方图结合支持向量机	90	87.52	85.08	16.17	12.08
局部二值模式结合 Softmax 回归	85	83.72	80.06	22.37	14.76
局部二值模式结合贝叶斯分类器	85	83.73	80.06	22.37	14.76
局部二值模式结合支持向量机	85	83.72	80.06	22.37	14.76
<b>本文算法</b>	<b>98</b>	<b>96.77</b>	<b>97.85</b>	<b>3.26</b>	<b>3.00</b>

贝叶斯分类器的组合进行识别对比的实验。通过对算法结果进行分析,对工作过程中识别的正确率指标进行了测试。当有可用的基准真值时,外部聚类评价可以提供更多可靠性的类标签,本文采用了五种外部聚类评价指标,即纯度、基于聚类的交叉熵、基于类的交叉熵<sup>[17]</sup>、聚类相似性<sup>[18]</sup>以及归一化互信息<sup>[19]</sup>,来全面比较聚类算法生成的聚类标签与数据集内部真实聚类结构之间的吻合程度。其对比结果如表 2 所示。

本文采用的方法在纯度、聚类相似性度量、归一化互信息、基于类的交叉熵和基于聚类的交叉熵上表现都是最好,这意味着本文的方法在聚类结果的这几个评价方面取得了较好的表现。在使用 LBP 特征进行图像识别时,三种算法(Softmax、贝叶斯分类器和 SVM)的识别效率都不高,纯度均为 85%,其他四项评价指标也相对较低。这可能意味着 LBP 特征与该任务中的区分能力较弱, HOG 特征其次。在表 2 中,本文提出的算法在所有评价指标中都表现得最好,具有最高的纯度以及较低的基于类的交叉熵和基于聚类的交叉熵指标。产生这种结果的原因在于, HOG 是通过计算图像中每个像素点的梯度信息来描述物体的边缘

和纹理特征,对图像的尺度和形状变化比较敏感。LBP 通过比较像素点与周围邻居像素的灰度值,统计其出现频次作为特征向量,对图像的旋转和尺度变化较为敏感。因此 HOG 与 LBP 这类算法更适用于样本密集而且各类之间又明显分离的图形聚类问题。而本文算法首先检测和描述图像中的关键点,并提取这些关键点周围区域的特征。然后,通过改进的 IB 算法,利用标签样本提供的信息对测试样本提取具有较高相关性的特征,以实现准确的样本匹配和分类,具有较好的尺度不变性和旋转不变性,最终能得到较高识别率。

将测试数据集从第 1 张图像开始,逐步增加到 20 张图像,并比较了各个算法的识别效果。各个算法在不同数量的测试图像上的识别效果如图 4 所示。分析数据发现,随着累计测试样本数的增加,本文算法能够通过标签样本和测试样本的互信息来选择最优信息量的特征,从而更好地进行数据处理,使得识别结果趋于稳定。由于缺少足够的标签样本用于训练, SVM 找不到足够的支持向量,导致决策边界过于简单或者过于复杂,无法很好地泛化到新的未见过的样本上; Softmax 分类器无法充分学习每个类别之间的区别,导致分类

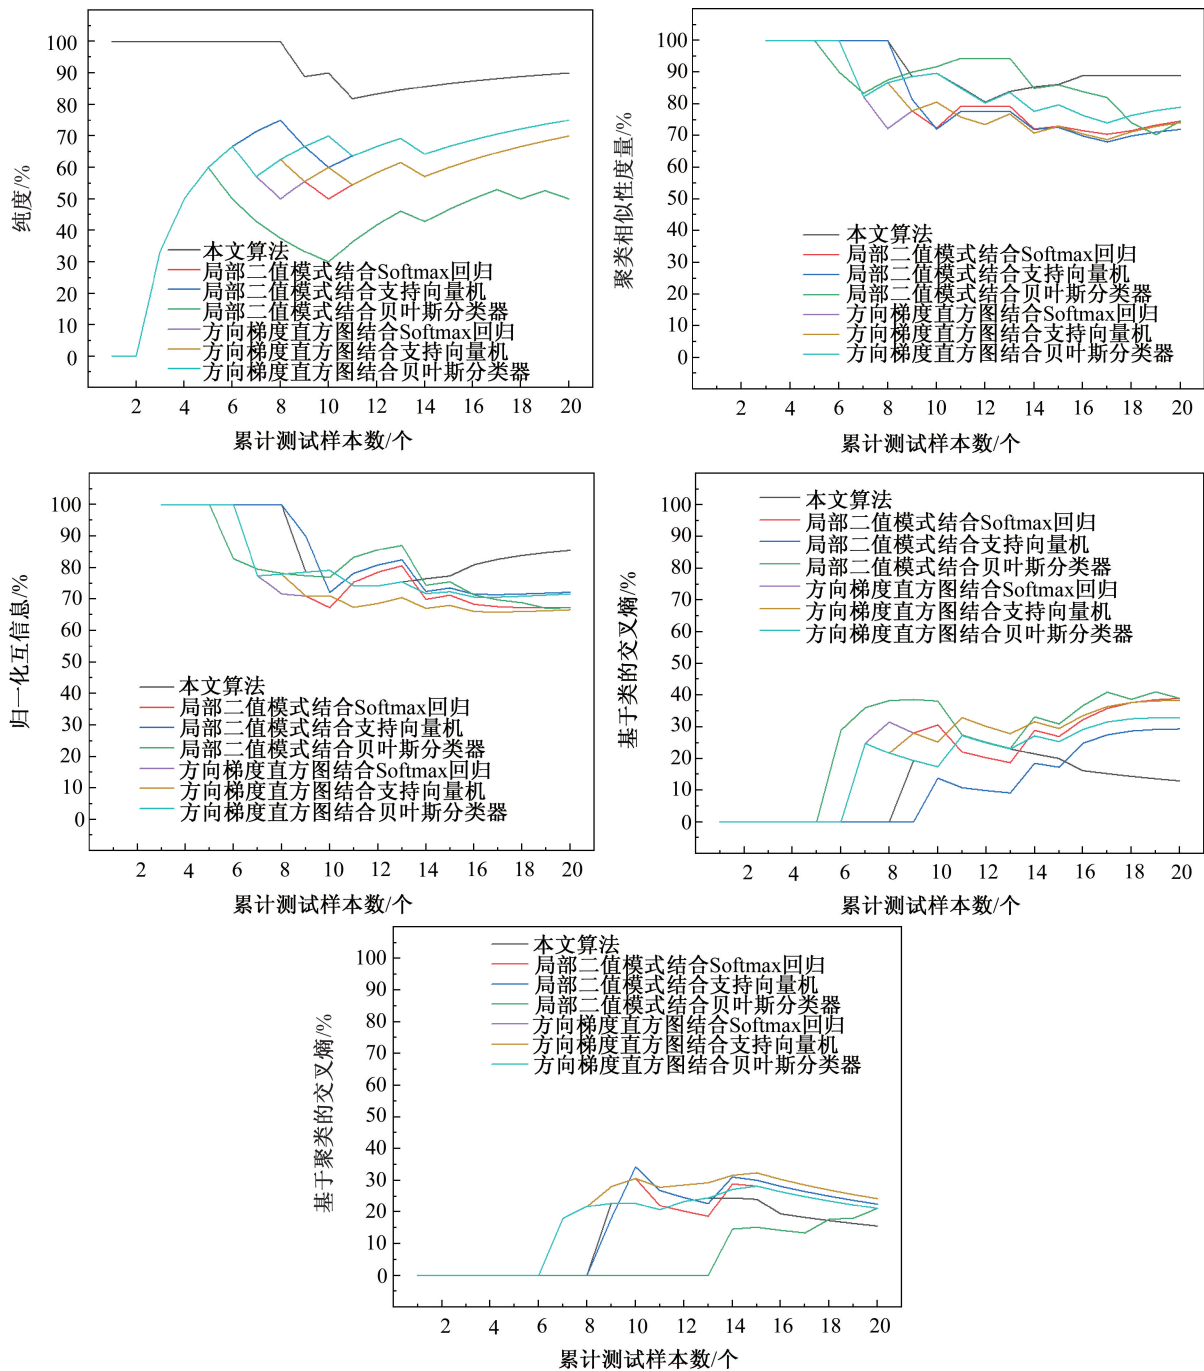


图4 算法识别率折线图

Fig. 4 Line chart of algorithm recognition rate

器可能会倾向于预测频次较高的类别,而对于样本较少的类别预测准确性较低;贝叶斯分类器无法估计类别的先验概率和条件概率分布,缺乏足够的样本来捕捉特征之间的相关性,可能无法很好地对相关特征进行建模,从而导致这些算法识别结果的波动性增加。这些结果展示了本文算法在识别任务上具有很好的鲁棒性。

综上所述,本文提出的算法在这5个评价指标上都优于其他方法。这些结果表明本文算法在图

像识别任务中具有较高的准确性和可靠性,对不同产品有很好的鲁棒性。

## 4 结论

本文提出了一种基于视图聚类的装配式建筑构件在线识别方法,通过对工件的几何形状和纹理特征进行聚类分析,实现了对装配式建筑构件的自动识别。通过实验验证,在正方形叠合楼板、

带窗墙体、剪力墙、空调安装阳台以及长方形叠合楼板等构件的识别中,本文提出的方法识别率为98%。相比之下,传统机器学习方法的最高识别率为95%。本文方法识别过程简单,可满足装配式建筑构件识别所需的精度标准,成功降低了误识率,提高了识别的准确性。

#### 参考文献:

- [1] 江蒙,刘建行. 基于 BIM 的装配式建筑构件质量检测方法探究[J]. 智能城市, 2021, 7(9): 17-18.
- [2] 谢琳琳,陈雅娇. 基于 BIM+数字孪生技术的装配式建筑项目调度智能化管理平台研究[J]. 建筑经济, 2020, 41(9): 44-48.
- [3] 兰永祥. 地铁全装配式车站预制构件智能生产信息化管理技术研究[J]. 工程技术研究, 2023, 8(6): 139-141.
- [4] 李文乔,江蒙,刘建行. 基于 Revit 的装配式建筑构件质量自动化检测技术[J]. 自动化技术与应用, 2023, 42(5): 60-63+71.
- [5] 陈亮伟,邵必林. 基于 BIM 的装配式建筑构件质量检测方法研究[J]. 建筑技术, 2019, 50(3): 354-357.
- [6] 熊朝阳,王婷. 基于卷积神经网络的建筑构件图像识别[J]. 计算机科学, 2021, 48(S1): 51-56.
- [7] 张伟,周梦源,夏坚. 基于改进 HOG 特征提取与 SVM 分类器的建筑裂缝识别方法[J]. 南昌工程学院学报, 2022, 41(1): 47-51.
- [8] 邱阳,李盛,金亮,等. 基于统计特征混合与随机森林重要性排序的桥梁异常监测数据识别方法[J]. 传感技术学报, 2022, 35(6): 756-762.
- [9] 刘文涛,李世华,覃馥楚. 基于全卷积神经网络的建筑物屋顶自动提取[J]. 地球信息科学学报, 2018, 20(11): 1562-1570.
- [10] 陈墨,杨沛,陈丽君. 基于深度学习的建筑表面裂缝缺陷识别[J]. 齐齐哈尔大学学报(自然科学版), 2021, 37(5): 57-61+66.
- [11] 邢金昊,饶颖露,张恒,等. 基于改进 YOLO 的建筑预埋件检测算法[J]. 计算机应用与软件, 2021, 38(11): 179-184.
- [12] HU S Z, LOU Z Z, YE Y D. View-wise versus cluster-wise weight: Which is better for multi-view clustering? [J]. IEEE Transactions on Image Processing, 2022, 31: 58-71.
- [13] 李贞培,李平,郭新宇,等. 三种基于 GDI+ 的图像灰度化实现方法[J]. 计算机技术与发展, 2009, 19(7): 73-75+79.
- [14] 王森,杨克俭. 基于双线性插值的图像缩放算法的研究与实现[J]. 自动化技术与应用, 2008(7): 44-45+35.
- [15] BAI K, ZHOU Y, CUI Z B, et al. HOG-SVM-based image feature classification method for sound recognition of power equipments [J]. Energies, 2022, 15(12): 4449.
- [16] ASUMAN Y G, UĞUR T, VASIF N. Face presentation attack detection performances of facial regions with multi-block LBP features[J]. Multimedia Tools and Applications, 2023, 82(26): 21-25.
- [17] SONG M Z, ZHANG L. Comparison of cluster representations from partial second-to full fourth-order cross moments for data stream clustering[C]//2008 Eighth IEEE International Conference on Data Mining. IEEE, 2008: 560-569.
- [18] HUI Z, TU B H, YANG Z, et al. Unsupervised feature extraction for time series clustering using orthogonal wavelet transform[J]. Informatica, 2006, 30: 305-319.
- [19] STREHL A, GHOSH J. Cluster ensembles—A knowledge reuse framework for combining multiple partitions [J]. Journal of Machine Learning Research, 2003, 3(3): 583-617.

(责任编辑 王利君)