

中图法分类号: TP301.6 文献标志码: A 文章编号: 1006-8961(2011)09-1650-06

论文索引信息: 张俊, 赵光宙, 顾弘. 高维金字塔匹配核改进算法 [J]. 中国图象图形学报, 2011, 16(9): 1650-1655

高维金字塔匹配核改进算法

张俊, 赵光宙, 顾弘

(浙江大学电气工程学院, 杭州 310027)

摘要: 随着特征维数增加, 原金字塔匹配核(PMK)期望误差线性上升, 从而性能存在着大幅下降的可能。提出一种改进的金字塔匹配算法, 通过不断的二分维特征空间从而产生一系列特征子空间, 加权求和每一特征子空间内对特征的金字塔匹配核, 最后通过核优化得到半正定核矩阵, 从而能够利用基于核学习算法(如支持向量机)求解。在两个数据集(Caltech-101、ETH-80)上的实验表明, 相对于其他相应改进算法需要增加几百倍的计算时间, DP-PMK 只增加 4~6 倍的计算时间就能够达到与其一样的准确率。

关键词: 维度分割; 特征集; 支持向量机; 金字塔匹配; 核函数; 目标识别

Improved pyramid matching kernel for high dimension

Zhang Jun, Zhao Guangzhou, Gu Hong

(College of Electric Engineering, Zhejiang University, Hangzhou 310027 China)

Abstract: As the feature dimension increases, the original PMK suffers from distortion factors that increase linearly with the feature dimension. This paper proposes a new method by consistently dividing the feature space into two subspaces while generating several levels. In each subspace of the level, the original pyramid matching is used. Then a weighted sum of every subspace at each level is made. To optimize the added kernel matrix, we get a p. s. d. kernel which can be used in kernel based learning methods (such as SVM). Experiments on dataset Caltech-101 and ETH-80 show that: compared with other related algorithms which need hundreds of times of original computational time, It takes only about 4~6 times of original computational time to obtain the same accuracy by using the method of DP-PMK.

Keywords: dimension partition; bags of features; SVM; pyramid matching; kernel function; object recognition

0 引言

相比于图像的全局信息, 应用多组局部特征(如 SIFT 和 PCA-SIFT 等)能更好的表示一幅图像, 前者如颜色、灰度直方图甚至图像的原始像素组成的向量^[1-3]容易对成像条件敏感, 而后者由于局部特征描述符本身的局部转换不变性, 能够更好地在不同角度、不同光照条件下对同一目标、场景进行匹配。

基于核函数的方法, 如支持向量机和基于核的主成分分析、高斯过程等, 被广泛地应用在模式识别各个领域。而传统的核函数是针对单一特征向量, 因而无法处理局部特征向量集合所表示的图像。基于此, 研究人员提出若干处理特征集的方法, 如最近邻方法^[4]、贪心匹配^[5]、指数匹配^[6]等, 但是它们计算复杂性较高, 且有一定的限制(要求集合元素个数相等)。

Grauman 等人^[7-8]提出利用金字塔匹配核(PMK)来估算两个特征集合间的相似度。其核心

收稿日期: 2010-06-17; 修回日期: 2010-10-20

基金项目: 国家自然科学基金项目(60872070); 浙江省自然科学基金项目(Y1080766)。

第一作者简介: 张俊(1985—), 男, 现为浙江大学电气工程学院控制理论与控制工程专业硕士研究生, 主要研究方向为机器学习、图像分析及计算机视觉。E-mail: zhang_jun@zju.edu.cn。

思想是把无序特征集映射到多分辨率直方图中,然后对两个特征集在不同分辨率下最优匹配加权求和作为两幅图像的相似度衡量。不同于目前大部分无序特征集匹配算法的二次甚至三次时间计算复杂度。金字塔匹配只有线性时间复杂度,没有限制(除特征向量的维数要相等),且支持部分匹配。

1 金字塔匹配核函数

1.1 金字塔匹配基本原理

定义特征空间 S 内两个 d 维特征向量集合, $X = \{x_1, x_2, \dots, x_m\}$, $Y = \{y_1, y_2, \dots, y_n\}$, 金字塔匹配把特征集置于不同的分辨率下求直方图,对 X, Y 在各层分辨率下匹配数加权求和,高分辨率权重重大。

对于特征集合 X , 定义特征提取函数 Ψ 如下

$$\Psi(X) = [H_0(X), \dots, H_{L-1}(X)] \quad (1)$$

式中, $X \in S$, $L = \lceil \log_2 D \rceil + 1$, D 是特征空间定义域大小。 $H_i(X)$ 是 X 中所有向量在第 i 层分辨率下形成的直方图向量,其 d 维分块大小为 2^i , $H_i(X)$ 的维数 $r_i = \left(\frac{D}{2^i}\right)^d$, $\Psi(X)$ 是一个金字塔形状的直

方图组合,底层直方图 H_0 的 d 维分块足够小,每一个特征向量落到各自分块中;顶层 H_{L-1} 分块足够大到覆盖特征空间的定义域,所有特征都归并到一个分块中。金字塔匹配函数定义如下

$$\bar{K}(X, Y) = \sum_{i=0}^{L-1} \omega_i N_i \quad (2)$$

式中:

$$N_i = I(H_i(X), H_i(Y)) - I(H_{i-1}(X), H_{i-1}(Y))$$

$$I(H_i(X), H_i(Y)) = \sum_{j=1}^{j=r_i} \min(H_i(X)^{(j)}, H_i(Y)^{(j)})$$

$$I(H_{-1}(X), H_{-1}(Y)) = 0$$

w_i 表示第 i 层权重,文献[8]中定义 $w_i = \frac{1}{2^i}$ 。

$H_i(X)^{(j)}$ 是直方图向量 $H_i(X)$ 的第 j 维大小。Grauman 等人证明对任意两个特征集,其计算复杂度为 $O(dmL)$,对特征向量数量 m 成线性关系,相对于当前大部分算法二次甚至三次关系,其计算速度极快。而且其还被证明符合 Mercer 条件,适合 SVM 使用。

图1中,实线表示每层新匹配特征,虚线表示已经在更高分辨率下完成了的匹配。例子中两个特征集相似度为




图1 1维特征集 PMK 匹配例子

Fig. 1 The 1D pyramid matching example

$$\bar{K} = \sum_{i=0}^{L-1} w_i N_i = 1 \times 3 + \frac{1}{2} \times 1 + \frac{1}{4} \times 1 + \frac{1}{8} \times 1 = 3.875$$

实际应用时, Grauman 等人建议进行如下处理来提高其性能。

1) 归一化处理

$$K(X, Y) = \frac{1}{C} \bar{K}(X, Y) \quad (3)$$

式中, $C = \bar{K}(X, X) \bar{K}(Y, Y)$

2) 叠加 T 个金字塔匹配

$$K = \sum_{j=1}^T K_j(X, Y) \quad (4)$$

$K_j(X, Y)$ 表示由一个随机的初始值(而非一直是零)开始算起而产生的金字塔直方图计算得到的匹配值。据文献[8],可以消除离散化直方图所带来的量化效应。

3) 核函数标准处理

由 K 组成的对应两个特征集的核矩阵 K 为

$$K_{ij} = K_{ij}^p \quad K = KK^T \quad (5)$$

$0 < p < 1$, 归一化 K_{ij} 后矩阵转秩相乘, i, j 表示两个匹配向量。据 Grauman 等人描述可以消除作为 SVM 等核函数带来的记忆效应。

1.2 相关工作

金字塔匹配核被广泛应用到模式识别的多个领域,并取得很好结果^[9-14]。通过 Grauman 等人证明,其误差期望

$$E[K(X, Y)] \leq (cd \log_2 D + d) \Theta(M(X, Y; \pi^*)) \quad (6)$$

从上式可以看出,其误差限与特征向量维数成正比,在维数较高时(>10),匹配性能存在大幅度下降的可能,以致算法失去实用性。

Lazebnik 等人^[14]提出一种空间金字塔匹配核

改进算法 (spatial PMK), 加入图像的空间位置信息。该方法前期特征聚类较大幅度增加运算时间, 结构也明显更加复杂。Grauman 等人^[15] 则针对高维特征提出一种基于词汇引导的金字塔匹配核 (VG-PMK), 把部分特征向量用于层次聚类, 形成 L 层次 K 分支的词汇树, 金字塔匹配作用于每个向量的层次分支标记。当维数增加时, 该方法分类效率几乎不受影响, 而词汇树的加入同样使得特征匹配变得复杂, 耗时也较长。Liu 等人^[16] 提出一种维数遗忘 PMK (dimension amnesic PMK), 该算法利用高斯分布生成多个矩阵, 并利用这些矩阵把高维特征投影到低维空间, 同样, 计算复杂度提高了。

2 改进的 PMK 算法

2.1 维数分割金字塔匹配

假设两个 128 维特征向量 $\mathbf{x} = (1, 1, \dots, 1, 63)$, $\mathbf{y} = (1, 1, \dots, 1, 1)$ 。按照原 PMK 匹配算法, 定义域设为 $D = 64$ 。第 0 层, 两个向量在各自分块中; 在第 1 层, \mathbf{x} 落在分块 $\mathbf{x} = (2, 2, \dots, 2, 64)$ 中, \mathbf{y} 落在分块 $\mathbf{y} = (2, 2, \dots, 2, 2)$ 中; 这样, 到第 6 层 (最低分辨率层) 两者发生匹配 (假设它们没有与其他向量发生匹配)。对于这两个向量, 前 127 维相同, 两者相关性应该很大, PMK 却没有表现出来。

对于任意两个特征向量, 发生匹配层别取决于两个特征向量距离相差最大那一维。前一个例子中, 两个向量除了最后一维, 其他所有维对应距离为零, 最后一维相差 62, 这决定了它们最终发生匹配层别。但是对于高维特征空间, 即使同一类别, 图像特征也可能存在若干差距较大维, 从而让匹配在低层才发生, 无法与不同类图像区别开来。

本文提出一种维数分割金字塔匹配核的改进算法 (DP-PMK)。其核心思想是不断分割高维空间, 产生一系列低维子空间, 加权求和每一特征子空间中对特征金字塔匹配核, 最后优化得到核矩阵。具体地说, DP-PMK 做一个层次随机分割模型 (见图 2) 来产生 T 层特征空间: 第 0 层, 特征空间由原高维特征空间组成; 第 1 层, 随机分割原高维特征空间成两个子空间; 接下来, 第 t 层对 $t-1$ 层中最大维子空间随机二分维产生两个子空间, 然后加上 $t-1$ 层所有其他子空间组成 t 层的特征子空间集。这样, 每一层都比上一层多一个子空间, 越到后面层, 空间分割越多, 越均匀。




图 2 层次随机分割模型 (4 层)

Fig. 2 A model of hierarchy random partition (4 levels)

基于此, 提出维数分割金字塔匹配核函数

$$K = \sum_{i=1}^T \alpha_i (K'_i + K''_i - \omega_i K_{i-1}^\Sigma) + K_b \quad (7)$$

α_i 是各层权重, K'_i 和 K''_i 是 $t-1$ 层具有最大维子空间二分维所产生的两个子空间内原金字塔匹配核。 K_{i-1}^Σ 是 $t-1$ 层具有最大维的子空间内的原金字塔匹配核, ω_i 是其系数, 且 $\omega_i \in [0, 2]$, K_b 是一个基核。

2.2 DP-PMK 分析

2.2.1 计算复杂度

DP-PMK 保持了原 PMK 算法的线性计算复杂度, 解决了原 PMK 算法对高维空间失效问题。Grauman 等人证明, 原 PMK 算法计算复杂度为 $O(dmL)$, 则 DP-PMK 计算复杂度为所有层别内所有子空间计算复杂度的总和, 即

$$O\left(\sum_{i=1}^T \sum_{j=0}^{i-1} (d_j^i mL)\right) \quad (8)$$

式中, $d_j^i mL$ 表示第 t 层第 i 个特征子空间的计算复杂度。根据层次随机分割模型

$$\sum_{i=1}^T \sum_{j=0}^{i-1} (d_j^i mL) = \left(\sum_{i=1}^T \sum_{j=0}^{i-1} d_j^i\right) mL = TdmL$$

从而最终只有增加 T 倍时间, 对于 128 维的特征一般设 $T = 4$ 。

2.2.2 核优化

分析式 (7) 中第 t 层核函数 $K'_i + K''_i - \omega_i K_{i-1}^\Sigma$ 。假设两个同样大小特征集, 根据 PMK 性质知, 它们是一对一匹配, 每一个特征都有它唯一的对应另一个特征集的特征。由于匹配层是由两个特征发生最大的那一维决定, 二分维该特征空间后, 必定有一个子特征向量在原层匹配, 而另一个子特征向量发生匹配的层别分辨率大于或等于原层, 这是假设中间过程中它们没有与其他特征向量发生匹配。若中间过程中与其他向量发生匹配, 那么匹配层别就是提前的。如果两个特征集合的大小不一样, 那么匹配相似度也必定变大。因此, 对于任意两个特征集合 $K'_i + K''_i \geq 2K_{i-1}^\Sigma$, 当 $\omega_i = 2$ 时, 匹配核是通过分维

前后两者相似距离的维度个数变化来衡量,这对于原 PMK 靠最大距离的维度来衡量更加可靠;当 $\omega_i = 0$ 时,由于 PMK 核是 Mercer 核^[8],而且多 Mercer 核的正加权和仍然是 Mercer 核^[17],从而 DP-PMK 是一个 Mercer 核,直接可以利用支持向量机等求解多分类问题。因此, ω_i 是一个参数平衡纯 Mercer 核和它的主对角元都为零的核(没有基核情况下)。

当 $\omega_i = 2$ 时, DP-PMK 主对角元为零,特征向量的自相似性为零,这是不合理的。因此,加入了一个基核,以此来增大主对角元,使得核矩阵近似达到半正定,从而能够利用支持向量机等求解。实验中设

$$K_b = \beta K_0 \quad (9)$$

K_0 是原高维空间 PMK 核矩阵,其主对角元远大于非对角元素。 β 是其系数 $\beta \in (0, 1]$, 通过合理的增大该系数,可以使 DP-PMK 主对角元逐渐增大。由矩阵性质知,逐渐增大主对角元到一定程度,可以保证该矩阵所有各阶顺序主子式大于或等于零,从而成为半正定阵。

在实验中,设置了维数分割的最小维,防止二分维时产生过低维度的特征空间。根据文献^[8], PMK 对维数 8 ~ 128 之间匹配最有效,故设最低维数为 8。

3 实验

本文的程序实现基于 MIT Lee 的 LIBPMK 开源库^[18],该开源库还包括一些基础特征提取函数,以及 PMK 和 VG-PMK 的实现。本文所有实验运行平台:Inter[®] Core[™] 2 Duo CPU E7400 @ 2.80 GHz; 4 GB 内存, Linux 操作系统。

3.1 Caltech-101

数据集 Caltech-101 包含 102 类共 9 197 幅图片,由 Fei-Fei 等人^[19]通过 Google 图像搜索得到,部分样图示于图 3。除近来的 Caltech-256,它是目前最复杂,最具挑战性的图片数据集之一。实验中,利用 Harris 等人^[20]检测兴趣点,而后利用 SIFT^[21]提取 128 维的高维局部特征。

首先随机抽取 102 类中的 15 类(每类最多 60 幅图片),提取 SIFT-128 特征向量;然后分别计算 PMK 和 DP-PMK 核矩阵;最后通过一对多 SVM 训练(训练样本为 30),进行多分类实验。下面所有实



图3 Caltech-101 数据集示例图片

Fig. 3 Example images from Caltech-101 dataset

验结果中的平均准确率都是基于 10 次独立重复计算的平均值。实验中设 $\beta = \omega_i = 1, T = 2, \alpha_i = 1, w'_i = \frac{1}{d^{2i}}$, 参见文献^[8]。

对于任意的 15 类,把 PMK 和 DP-PMK 的分类效果做一比较,示于图 4。从图中可以看出,分类准确率 DP-PMK 至少高于 PMK 10%。




图4 DP-PMK 分类效果初探

Fig. 4 A preliminary study of DP-PMK

选择其中的一个 15 类数据(Caltech-15)(见表 1)做相关参数优化。这里选择一个次序,逐级优化:当优化一个参数时,固定其他参数。参数优化的目的是为了选择能够适用于任意数据集的参数。

表 1 选择的 Caltech-15 数据集

Tab. 1 Selected Caltech-15 dataset

| | | | | |
|----------|-------------|------------|-------------|-------------|
| revolver | joshua_tree | headphone | okapi | Motorbikes |
| garfield | octopus | strawberry | ceiling-fan | stegosaurus |
| cannon | louts | emu | schooner | cougar-face |

从图 5 中可以看出,随着层数的增加,分类准确率增加。考虑到时间的影响,设 $T = 4$ 。

图 6 中,设定 $\omega_i = 2, \beta = 0.6$ 。




图 5 不同的 T 对性能的影响

Fig. 5 Performance of different T




图 6 不同的 ω_i 和 β 对性能的影响

Fig. 6 Performances of different ω_i and β

图 7 (a) 是对 Caltech-15 中 747 幅图像共 288 621 个 PCA-SIFT 特征做 PMK 操作, 统计各层发生的匹配数。从图 (a) 中可以看出, 随着特征空间维数的增加, 特征主要发生的匹配层别逐渐增大, 分辨率变小。图 (b) 是对 Caltech-15 中 747 幅图像共 287 429 个 128 维的 SIFT 特征做 PMK 及 DP-PMK 操作, 统计各层发生的匹配数。从图 (b) 中可以看出, PMK 核基本上都在倒数第 2 层发生匹配, 导致不同类区分度小, 而 DP-PMK 发生匹配的层别分布相对均匀。

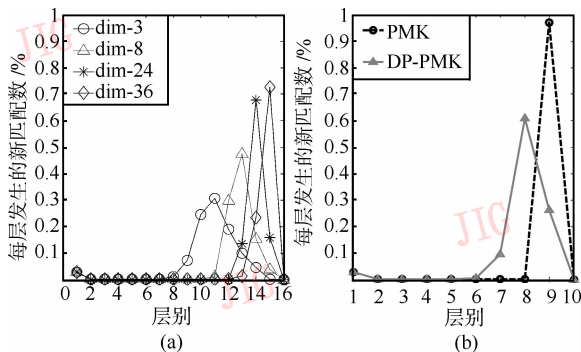


图 7 Caltech-15 各层发生的匹配数统计

Fig. 7 Number of matches at each level in Caltech-15

最后把 DP-PMK 与 PMK、VG-PMK 在该数据集上的分类性能做一比较, 示于表 2。对于 VG-PMK, 设 $K=5, L=10$, 由文献[15]建议。

表 2 DP-PMK 与 PMK、VG-PMK 的比较
Tab. 2 A comparison with PMK and VG-PMK

| 匹配方法 | 平均准确率 | 计算时间/s |
|--------|-----------|---------|
| PMK | 0.229 293 | 41.58 |
| DP-PMK | 0.623 569 | 248.76 |
| VG-PMK | 0.621 212 | 1 082.2 |

从表 2 中可以看出, 相对于 VG-PMK 花费约 250 倍原 PMK 的计算时间, DP-PMK 只花费 6 倍, 分类的平均准确率却还能够比 VG-PMK 高。

3.2 ETH-80

ETH-80^[22] 包含 8 个大类, 每类共有 10 个对象, 共 80 个对象。每个对象又有大量不同的视角, 统一蓝色背景, 图 8 是该数据集的部分示例图片。




图 8 ETH-80 数据集示例图片

Fig. 8 Example images from ETH-80 dataset

实验中按照文献[8]同样的设置: 先对每个对象提取 5 个不同的视角, 共 400 幅图片; 然后利用网格过滤方法检测兴趣点; 而后利用 SIFT 提取 128 维局部特征。实验特征数据可以由文献[18]下载。VG-PMK 的源程序也可以由该网站下载。为公平对比, DP-PMK 完全按照 VG-PMK 的方式进行性能比较。实验中, DP-PMK 采取前文优化好的参数; 而 VG-PMK 的参数取 $K=3, L=12$, 比文献[15]中建议的性能好。结果见表 3。

表 3 DP-PMK 与 VG-PMK 性能比较
Tab. 3 A comparison between DP-PMK and VG-PMK

| 匹配方法 | 平均准确率 | 平均计算时间/s |
|--------|---------|-----------|
| DP-PMK | 0.801 6 | 64.523 |
| VG-PMK | 0.800 0 | 1 387.247 |

从上表3中可以看出,DP-PMK的平均计算时间只占VG-PMK的0.05,分类准确率略高于VG-PMK。

4 结论

针对原PMK算法高维性能下降问题,提出一种改进的金字塔匹配算法。通过不断的分割特征空间,在各特征空间内做原金字塔匹配,加权求和各子空间,最后加入基础核矩阵以优化满足Mercer条件。原算法只靠两特征间最大值决定匹配层,DP-PMK则由两个特征维相似度的变化来衡量,相对于前者,后者更加可靠。实验表明,DP-PMK在只增加4~6倍时间的情况下,取得了其他相应算法要增加几十甚至几百倍时间下相近的性能表现。在应用PCA-SIFT特征进行匹配实验时,性能提高不是非常明显,因而本文未给出。估计PCA-SIFT本身经过主成分分析,不适合维数分割,有待今后深入研究。

参考文献(References)

- [1] Chapelle O, Haffner P, Vapnik V. SVMs for histogram-based image classification[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 1055.
- [2] Roobaert D, Van Hulle M. View-based 3D object recognition with support vector machines [C]//Proceedings of the IEEE International Workshop on NNSP. Madison, Wisconsin, USA: IEEE, 1999: 77-84.
- [3] Odono F, Barla A, Verri A. Building kernels from binary strings for image matching[J]. IEEE Transactions on Image Processing, 2005, 14(2): 169-180.
- [4] Grauman K, Darrell T. Fast contour matching using approximate earth mover's distance [C]//Proceedings of the IEEE Computer Society Conference on CVPR. Washington DC, USA: IEEE, 2004: 220-227.
- [5] Berg A, Berg T, Malik J. Shape matching and object recognition using low distortion correspondences [C]//Proceedings of the IEEE Conference on CVPR. San Diego, USA: IEEE, 2005: 26-33.
- [6] Lyu S. Mercer kernels for object recognition with local features [C]//Proceedings of the IEEE Conference on CVPR. San Diego, USA: IEEE, 2005: 223-229.
- [7] Grauman K, Darrell T. The pyramid match kernel: discriminative classification with sets of image features [C]//Proceedings of the IEEE Conference on ICCV. Beijing, China: IEEE, 2005: 1458-1465.
- [8] Grauman K, Darrell T. The pyramid match kernel: efficient learning with sets of features [J]. Journal of Machine Learning Research, 2007, 8(2): 725-760.
- [9] Kapoor A, Shenoy P, Tan D. Combining brain computer interfaces with vision for object categorization [C]//Proceedings of the IEEE Conference on CVPR. Alaska, USA: IEEE, 2008: 1-8.
- [10] Bosch A, Zisserman A, Munoz X. Representing shape with a spatial pyramid kernel [C]//Proceedings of the 6th ACM International Conference on Image and Video Retrieval. Amsterdam, Netherlands: Association for Computing Machinery, 2007: 401-408.
- [11] Yeh T, Lee J, Darrell T, et al. Adaptive vocabulary forests for dynamic indexing and category learning [C]//Proceedings of the IEEE International Conference on Computer Vision. Rio de Janeiro, Brazil: IEEE, 2007: 1-8.
- [12] Fu Siyao, Guo Shengyang, Hou Zengguang, et al. Multiple kernel learning from sets of partially matching image features [C]//Proceedings of International Conference on Pattern Recognition. Florida, USA: IEEE Computer Society, 2008: 1-4.
- [13] Saenko K, Darrell T. Filtering abstract senses from image search results [C]//Proceedings of the 23rd Annual Conference on NIPS. Vancouver, BC, Canada: MIT Press, 2009: 1-9.
- [14] Lazebnik S, Schmid C, Ponce J. Beyond bags of features: spatial pyramid matching for recognizing natural scene categories [C]//Proceedings of the IEEE Conference on CVPR. New York, USA: IEEE, 2006: 2169-2178.
- [15] Grauman K, Darrell T. Approximate correspondences in high dimensions [J]. Advances in Neural Information Processing Systems, 2006, 19(1): 505-512.
- [16] Liu Y, Wang X, Zha H. Dimension amnesic pyramid match kernel [C]//Proceedings of the 23rd National Conference on Artificial Intelligence. Chicago, USA: AAAI Press, 2008: 652-658.
- [17] Shawe-Taylor J, Cristianini N. Kernel Methods for Pattern Analysis [M]. New York, USA: Cambridge University Press, 2004.
- [18] Lee J. LIBPMK: A Pyramid Match Toolkit [CP/OL]. (2008-04). <http://hdl.handle.net/1721.1/41070>.
- [19] Fei-Fei L, Fergus R, Perona P. Learning generative visual models from few training examples: an incremental Bayesian approach tested on 101 object categories [C]//Workshop on Generative Model Based Vision. Washington, DC, USA: Academic Press, 2004: 178-178.
- [20] Harris C, Stephens M. A combined corner and edge detector [C]//Proceedings of Alvey Vision Conference. Manchester, UK: [s. n.], 1988: 147-152.
- [21] Lowe D. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [22] Leibe B, Schiele B. Analyzing appearance and contour based methods for object categorization [C]//Proceedings of the IEEE Conference on CVPR. Madison, USA: IEEE, 2003: 409-415.