法律声明

- 本课件包括：演示文稿，示例，代码，题库，视频和声音等，小象学院拥有完全知识产权的权利；只限于善意学习者在本课程使用，不得在课程范围外向任何第三方散播。任何其他人或机构不得盗版、复制、仿造其中的创意，我们将保留一切通过法律手段追究违反者的权利。



关注 小象学院

第8讲　图像检索

计算机视觉

主讲人：叶梓

上海交通大学博士
主要研究方向：机器学习、深度学习、人工智能

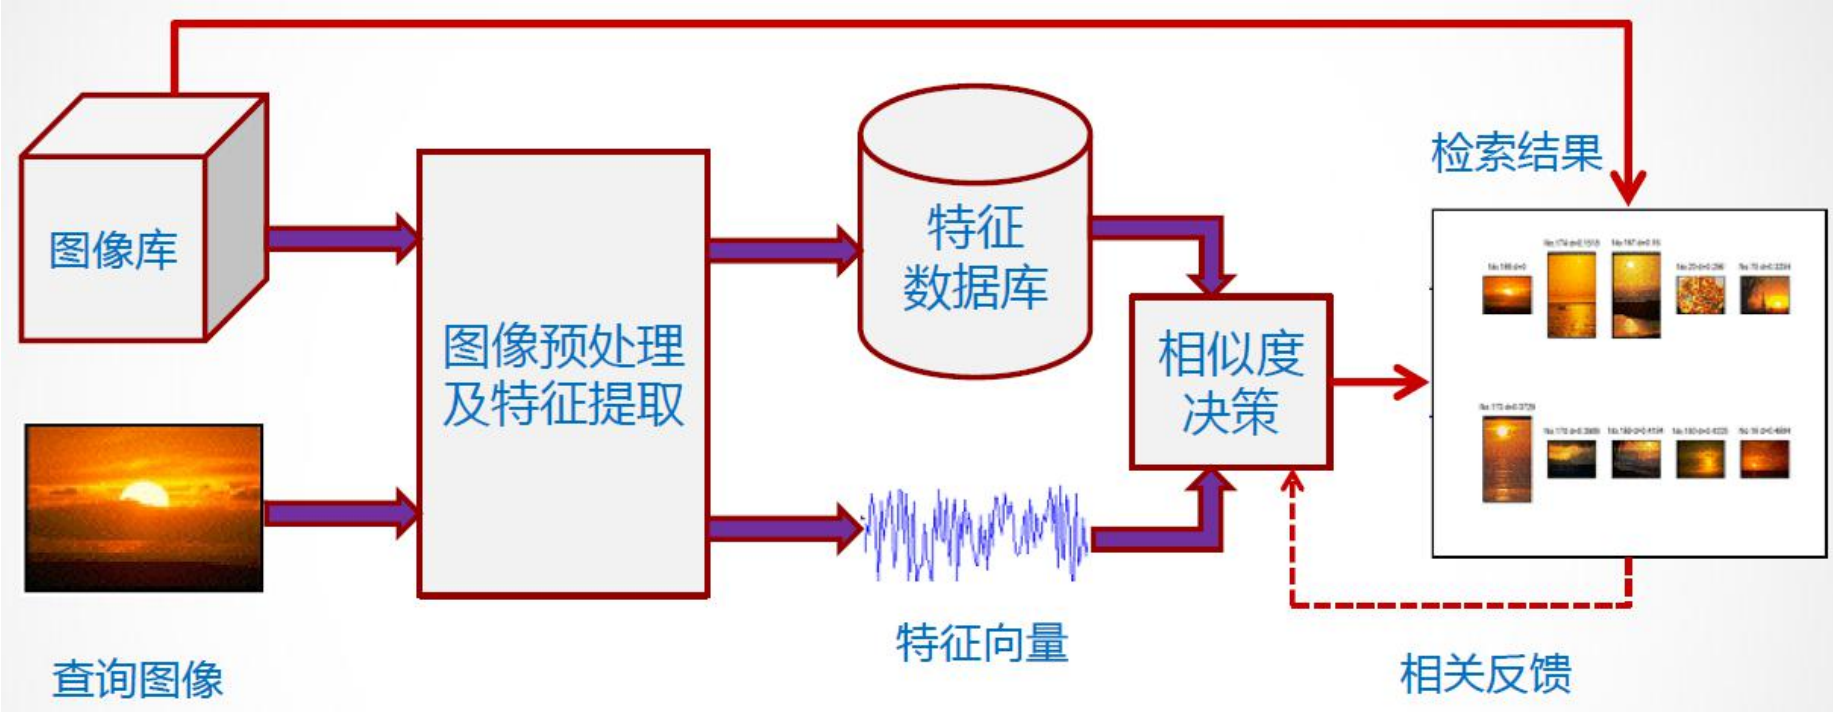
本章结构

- 相似检索
  - 颜色、纹理、形状
  - 局部特征点
  - 词包（Bag Of Visual Word）
- 索引加速
  - KD-tree
  - 局部敏感哈希（Locality Sensitive Hash）
- 应用案例
  - CBIR的应用

先看效果


图片
请输入关键词描述图片
百度一下
识图效果不好？尝试输入关键词描述
手动框选
图片尺寸：1282X1110
约3张
更多尺寸
图中植物可能是
木立芦荟
大芦荟
开普芦荟
木剑芦荟
异色芦荟
简介：木立芦荟是多年生植物，茎短或明显，叶肉质，呈莲座状簇生或有时二列着生，先端锐尖，边缘常有硬齿或刺。又称木剑芦荟，原产于南非，叶汁极苦，属百合科目。在日本进行商品化生产，日本人认为木立芦荟是最好的药用芦荟品种。用木立芦荟加工成芦荟干粉。可医治各种疾病。在医学上，木立芦荟已经被检验出具有很多有效成份，是一种公认最有效的品种。在药用方面，叶子除了可以生吃、榨果汁外，还可以加工成健康食品或化妆品等。由于容易处理，它也适合用作食用的家庭菜。
来自百度百科
查看ta的百科>
加载更多图片

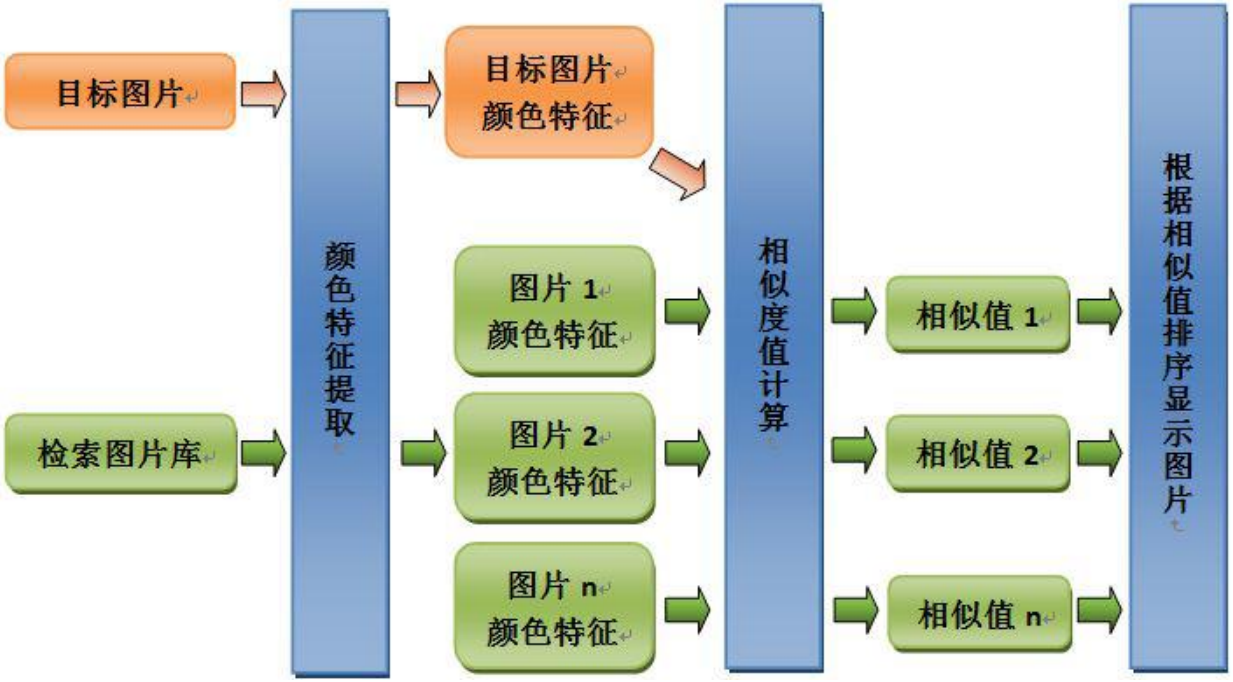
相似图像检索



相似颜色检索

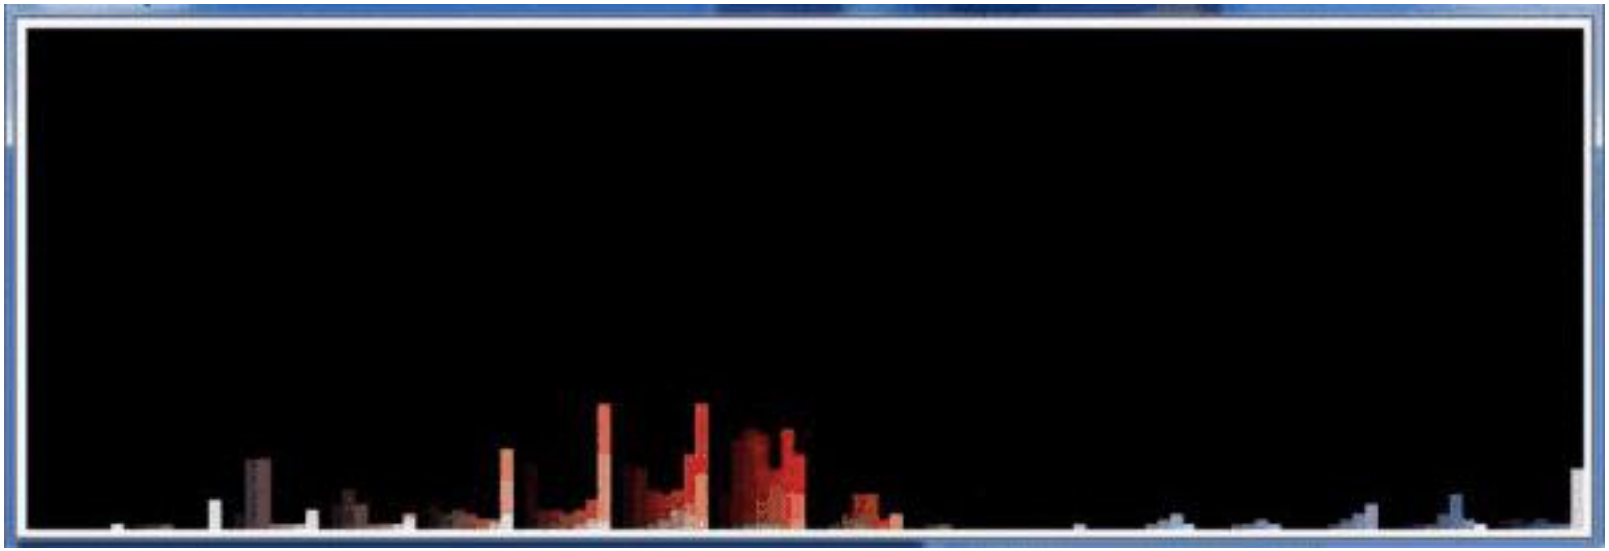
算法结构

- 目标：实现基于人类颜色感知的相似排序
- 模块：颜色特征提取 & 特征相似度计算



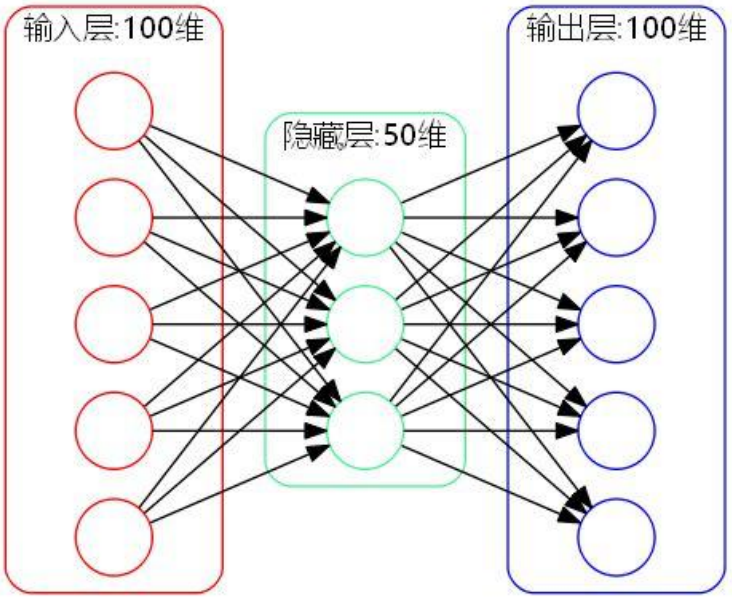
相似颜色检索

- 颜色直方图就是将RGB图像中出现的颜色进行统计。
- 将一张图像描述成一个256维度的特征向量



相似颜色检索

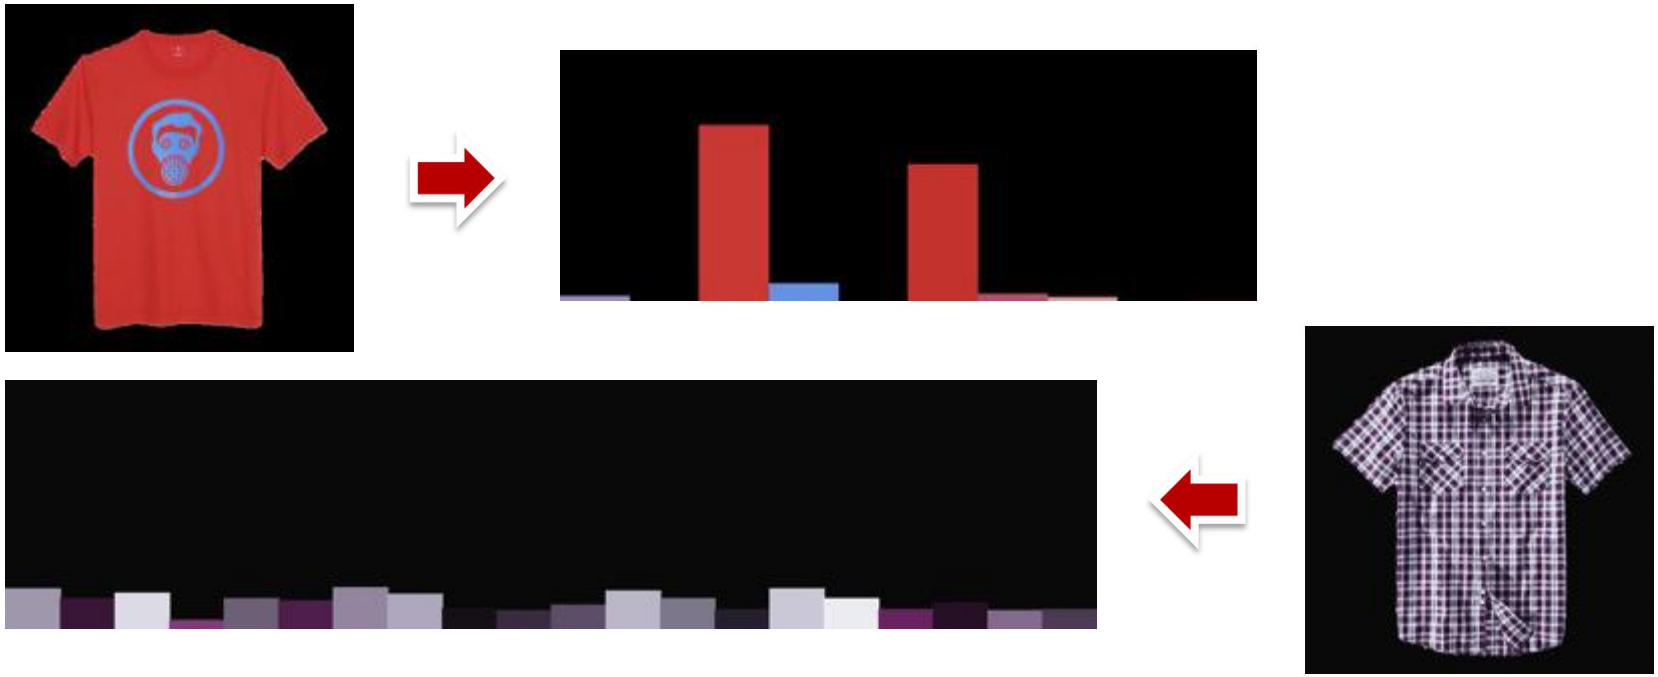
- 自编码器：是通过神经网络进行特征提取，提取出针对学习样本的通用特征降维方法。
- 神经网络的两端通过相同的数据限制，学习到中间的隐藏层权重，通过使用降维再升维的方法，使隐藏层输出最大限度的保存图像的主要特征，以使还原后的图像与原图像误差达到最小。



相似颜色检索

颜色特征提取

- 目标：统计图片的颜色成份→颜色聚类直方图
- 方法：使用K-means++对图片Lab像素值进行聚类



相似颜色检索

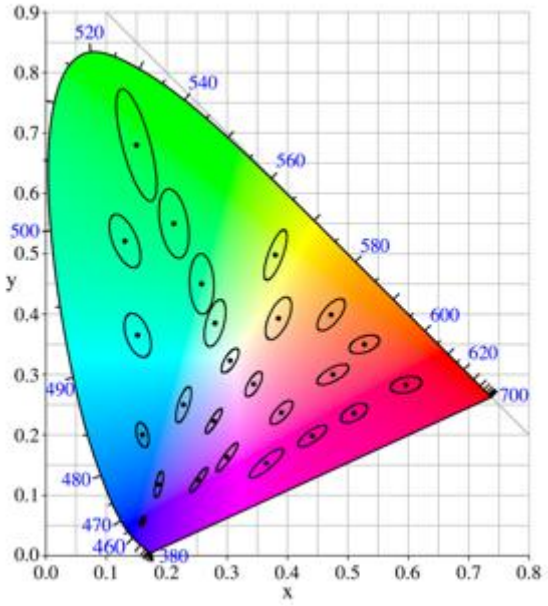
颜色特征相似度计算

- 颜色直方图距离
  - EMD（Earth Mover Distance，推土机距离）
  - 两个图片的颜色特征直方图之间的视觉相似度
  - 检索结果的排序依据
- 色差距离
  - CIEDE2000
  - Lab空间中两个颜色之间的视觉相似度
  - EMD距离的基础距离

相似颜色检索

色差距离

- 色差容忍度（Tolerance）
  - 概念：无法感知的色差
  - 计算：色差小于JND(Just-Noticeable-Difference)阈值
  - 前提：感知均匀的色差距离
- CIE1931颜色空间
  - 容忍椭圆
  - 非感知均匀
- CIELab颜色空间
  - 视觉感知均匀的颜色模型
  - 均匀性更好的距离CIEDE2000



相似颜色检索

色差距离

- CIE制定，用于CIE-Lab空间的色差距离
- 欧式距离→CIEDE1994 → CIEDE2000

$$\Delta E^*_{ab} = \sqrt{(L_2{}^* - L_1{}^*)^2 + (a_2{}^* - a_1{}^*)^2 + (b_2{}^* - b_1{}^*)^2}$$

$$\begin{aligned}\Delta E_{00}^{12} &= \Delta E_{00}(L_1^*, a_1^*, b_1^*; L_2^*, a_2^*, b_2^*) \\ &= \sqrt{\left(\frac{\Delta L'}{k_L S_L}\right)^2 + \left(\frac{\Delta C'}{k_C S_C}\right)^2 + \left(\frac{\Delta H'}{k_H S_H}\right)^2 + R_T \left(\frac{\Delta C'}{k_C S_C}\right)\left(\frac{\Delta H'}{k_H S_H}\right)}\end{aligned}$$

- 改进目标：人眼视觉的均匀性
- 具体公式链接
  - https://en.wikipedia.org/wiki/Color_difference#CIEDE2000

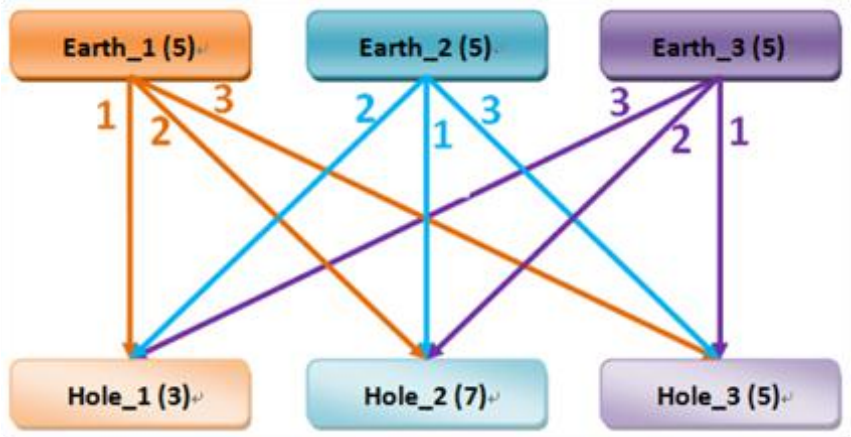
相似颜色检索：EMD距离

- 两个多维特征分布之间的非相似性度量
- 推土机距离(Wasserstein 距离)
- 传统运输问题
  - 场景：多对多分配
    - 物资运送：多个供应商→多个需求客户
    - 土堆搬运：多个土堆→多个土坑
  - 约束
    - 双方的节点总量相等
    - 不同节点之间的成本各异
  - 目标：完成分配的最小成本

	B_1	B_2	B_3	产量
A_1	6	4	6	200
A_2	6	5	6	300
销量	150	150	200	

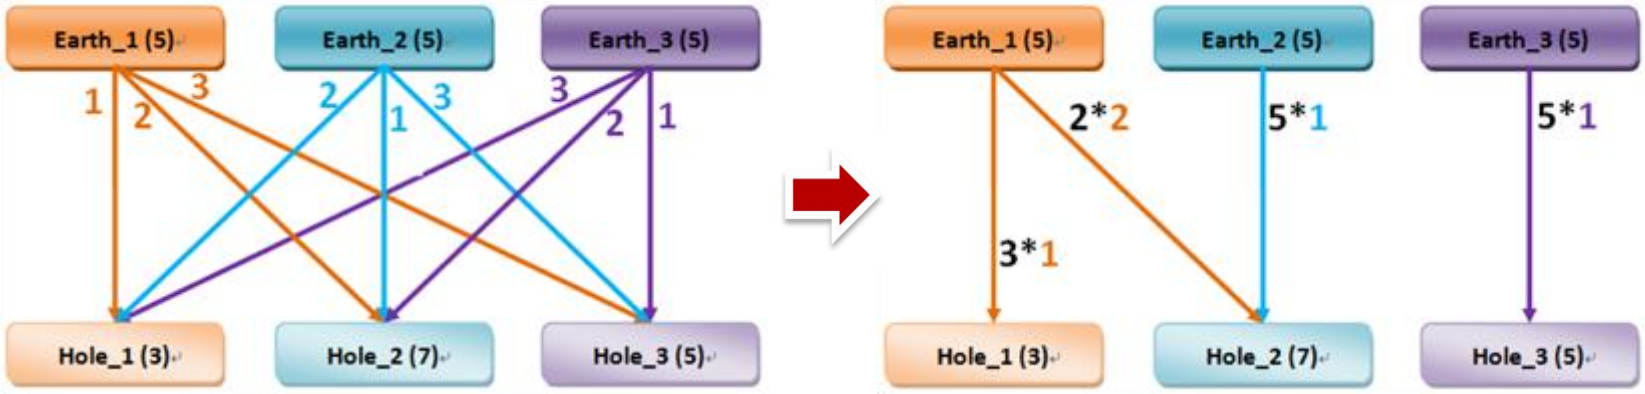
EMD距离直观解释

- 问题条件
  - 有三个土堆Earth_1，Earth_2，Earth_3，每个土堆都有5个单位的土量
  - 有三个土坑Hole_1，Hole_2，Hole_3，每个土坑所能容纳的土量分别为3、7、5
  - 不同的土堆和土坑之间的距离不同，距离值分别是1，2，3
  - 有一个搬运工，一趟只能搬运1单位的土



EMD距离直观解释

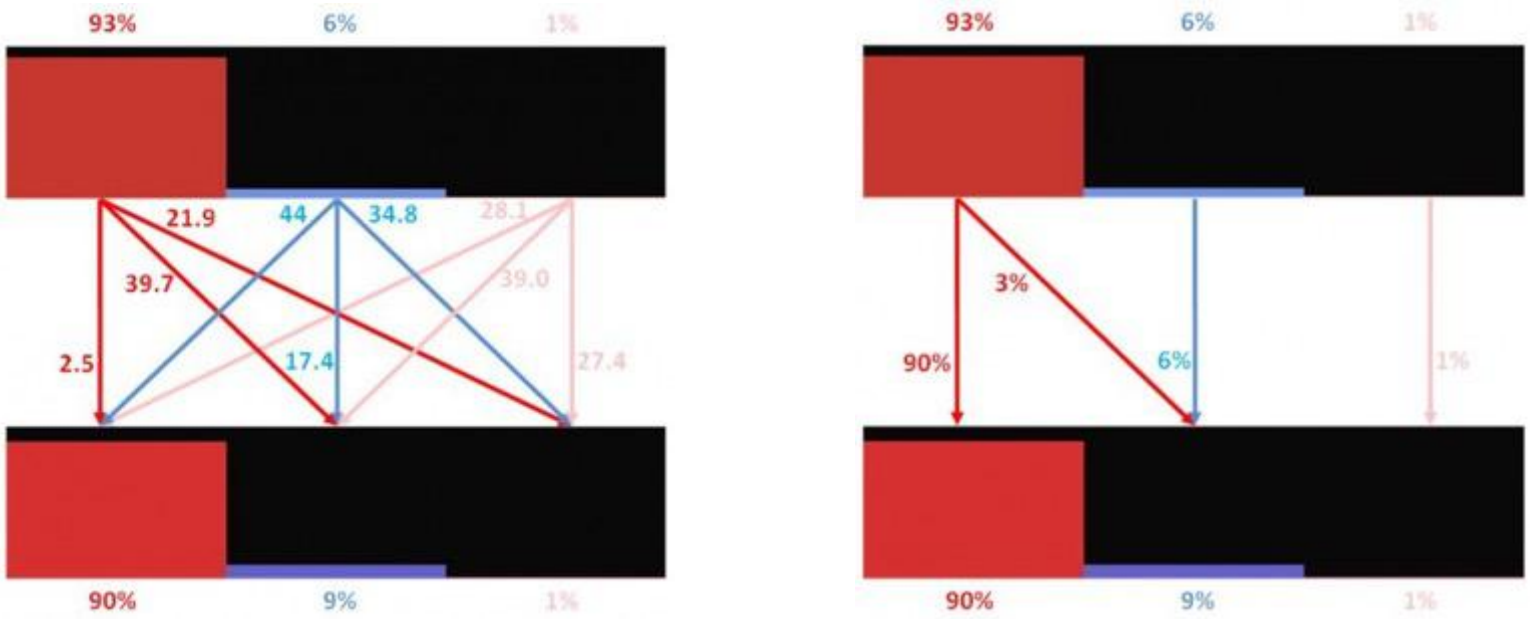
- 任务目标
  - 以最小的行走距离（EMD），将所有土堆运输到土坑处并填平
- 解决方案
  - 最小距离（ EMD ）：3*1+2*2+5*1+5*1=17
  - E1→H1：3，E1→H2：2，E2→H2：5，E3→H3：5



相似颜色检索

EMD距离应用到颜色检索

- 多维分布→颜色特征直方图
- 推土机距离→CIEDE2000

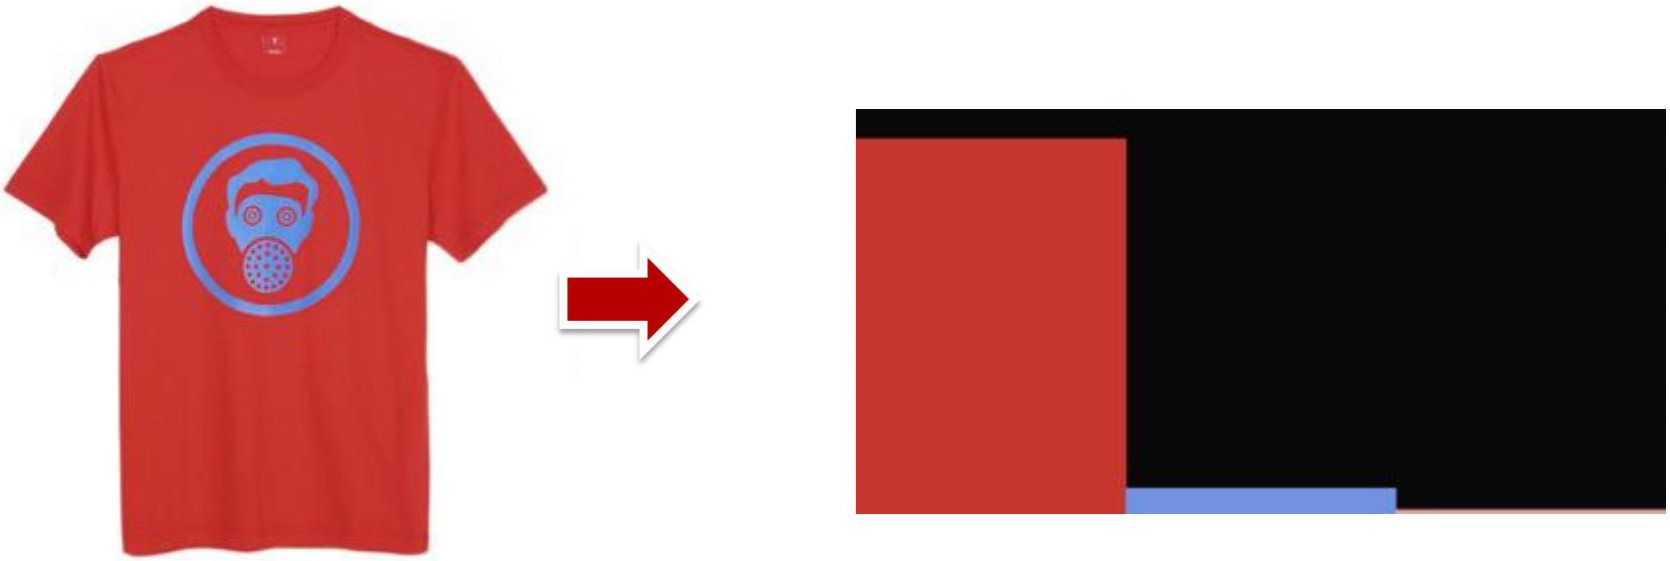


EMD值：2.5*90%+39.7*3%+17.4*6%+27.4*1%=4.795

相似颜色检索

流程说明

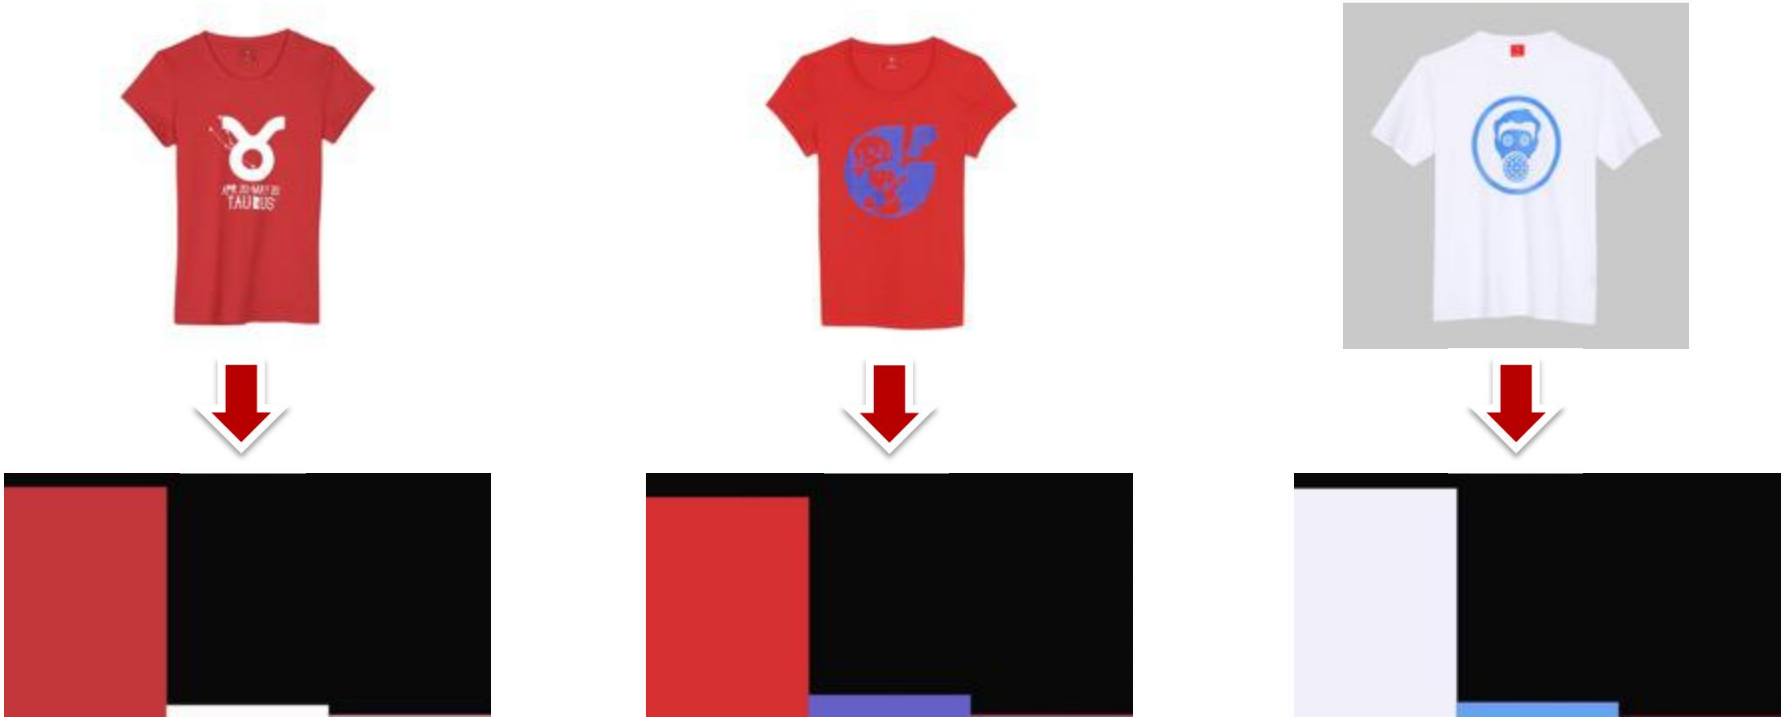
- Step1: 搜索图片的颜色特征提取



相似颜色检索

流程说明

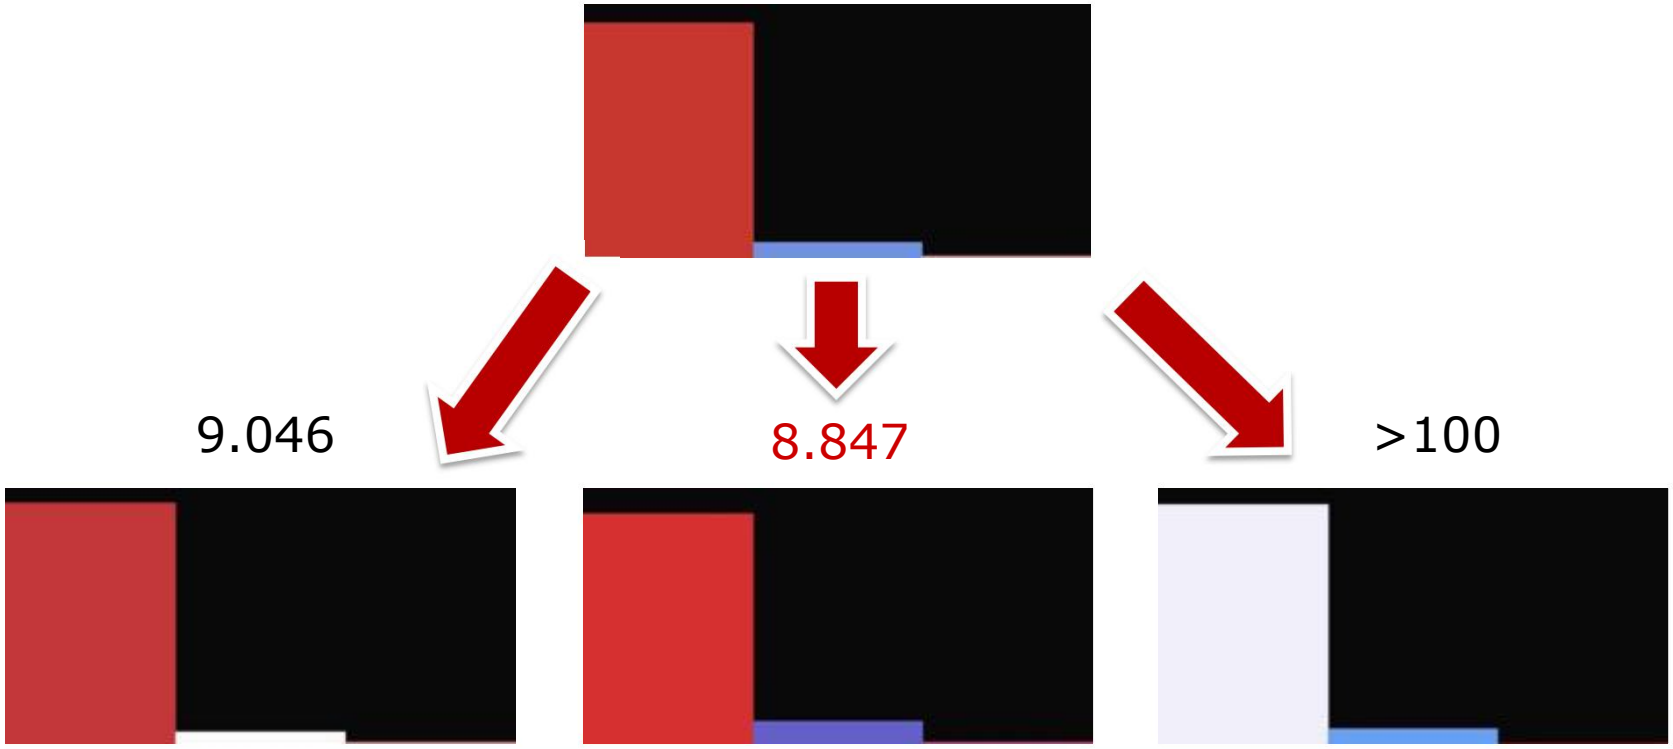
- Step2:图片库的颜色特征提取



相似颜色检索

流程说明

- Step3:颜色相似度(EMD)计算



相似颜色检索



流程说明

- Step4: 根据相似度排序

1st: 8.847



2nd: 9.046



3rd: >100





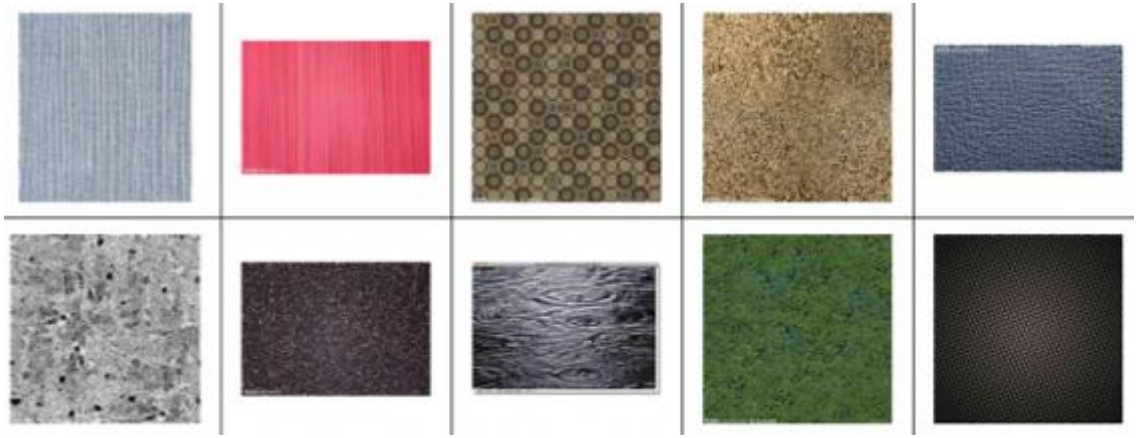




相似纹理检索

纹理（texture）

- 重复模式：元素或基元按一定规则排列
- 纹理特征
  - 反映图像中同质现象的视觉特征
  - 所有物体表面共有的内在特性
  - 包含了物体表面结构组织排列的重要信息



相似纹理检索

算法结构

- 目标：实现基于人类纹理感知的相似排序
- 模块（与相似颜色检索类似）
  - 纹理特征提取
    - 特征空间：多方向、多尺度Gabor滤波器组
    - 特征计算：Kmeans++聚类直方图
  - 特征相似度计算
    - 纹理聚类直方图：EMD
    - 纹理距离：L2

相似纹理检索

Gabor滤波器组

- Gabor 滤波器组类似于人类的生物视觉系统
  - 多频率/尺度
  - 多方向
- Gabor 滤波器
  - 频域：属于加窗傅立叶变换
  - 空域：一个高斯核函数和正弦平面波的乘积

复数：$$g(x,y;\lambda,\theta,\psi,\sigma,\gamma)=\exp\left(-\frac{x'^2+\gamma^2y'^2}{2\sigma^2}\right)\exp\left(i\left(2\pi\frac{x'}{\lambda}+\psi\right)\right)$$

实部：$$g(x,y;\lambda,\theta,\psi,\sigma,\gamma)=\exp\left(-\frac{x'^2+\gamma^2y'^2}{2\sigma^2}\right)\cos\left(2\pi\frac{x'}{\lambda}+\psi\right)$$

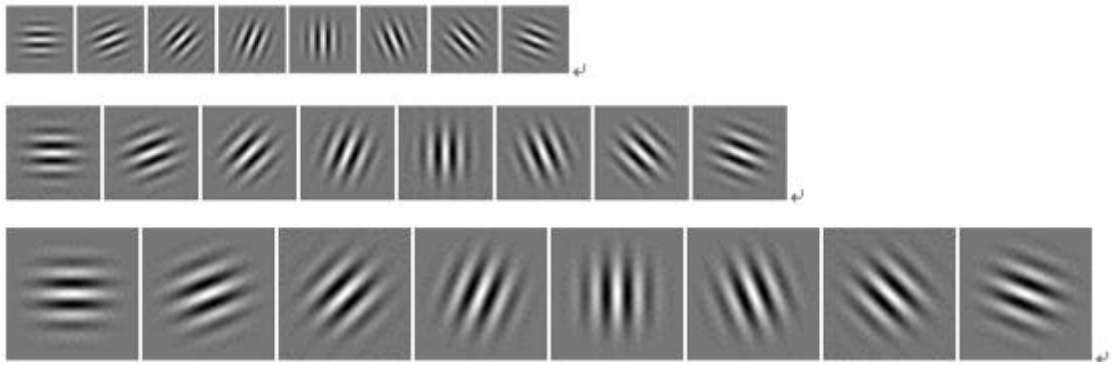
虚部：$$g(x,y;\lambda,\theta,\psi,\sigma,\gamma)=\exp\left(-\frac{x'^2+\gamma^2y'^2}{2\sigma^2}\right)\sin\left(2\pi\frac{x'}{\lambda}+\psi\right)$$

其中：$$x'=x\cos\theta+y\sin\theta, y'=-x\sin\theta+y\cos\theta$$

相似纹理检索

Gabor滤波器组

- 6频率（尺度）
  - 频率：1，2，3，4，5，6
  - 尺寸：25，35，49，69， 97，137
- 8方向
  - 0，22.5，45，67.5，90，112.5，135，157.5



相似纹理检索

Gabor纹理特征提取

- 彩色图片灰度化
- 提取灰度图的Gabor滤波器特征
  - 6频率（尺度）、8方向的Gabor，
  - 48个同尺寸的特征图
  - 每个像素对应48维的Gabor特征向量
- 使用Kmeans++聚类所有像素Gabor特征
  - K值(10)根据数据集纹理复杂度而定
  - 使用KD-tree版加速

相似纹理检索

Gabor纹理特征提取

- Gabor卷积操作加速
  - FFT
  - 采用"图片尺寸缩小替代Gabor模板尺寸增大"的策略

Gabor频率(尺度)	1	2	3	4	5	6
Gabor模板尺寸	25x25	35x35	49x49	69x69	97x97	137x137
原图尺寸	400x400	400x400	400x400	400x400	400x400	400x400



Gabor频率(尺度)	1	2	3	4	5	6
Gabor模板尺寸	25x25	35x35	25x25	35x35	25x25	35x35
原图尺寸	400x400	400x400	200x200	200x200	100x100	100x100

相似纹理检索

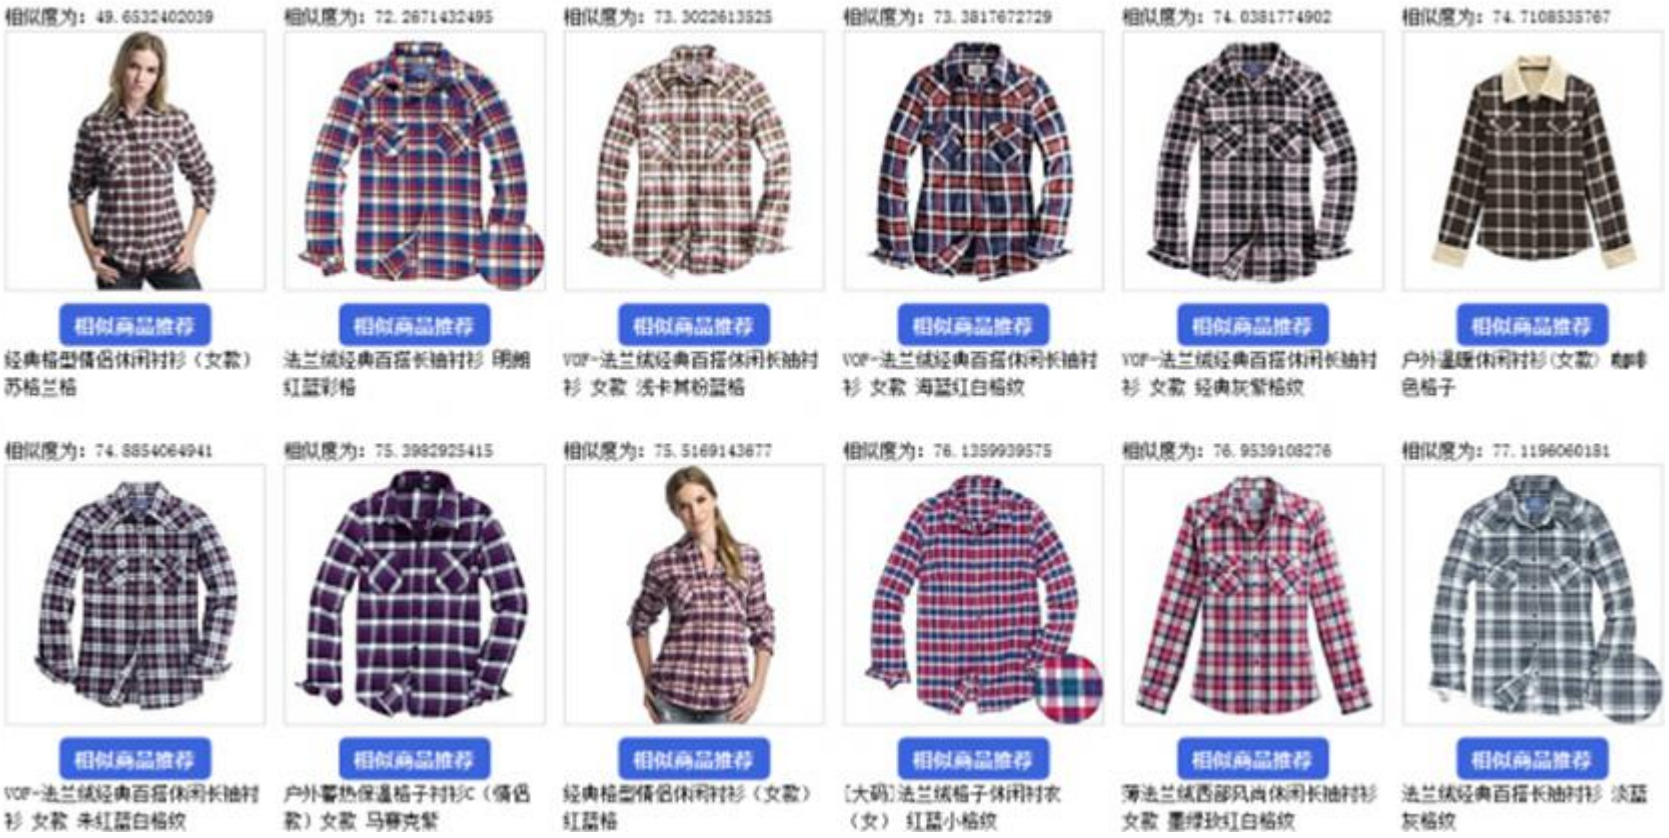
Gabor纹理特征提取可视化

- 10个纹理基元



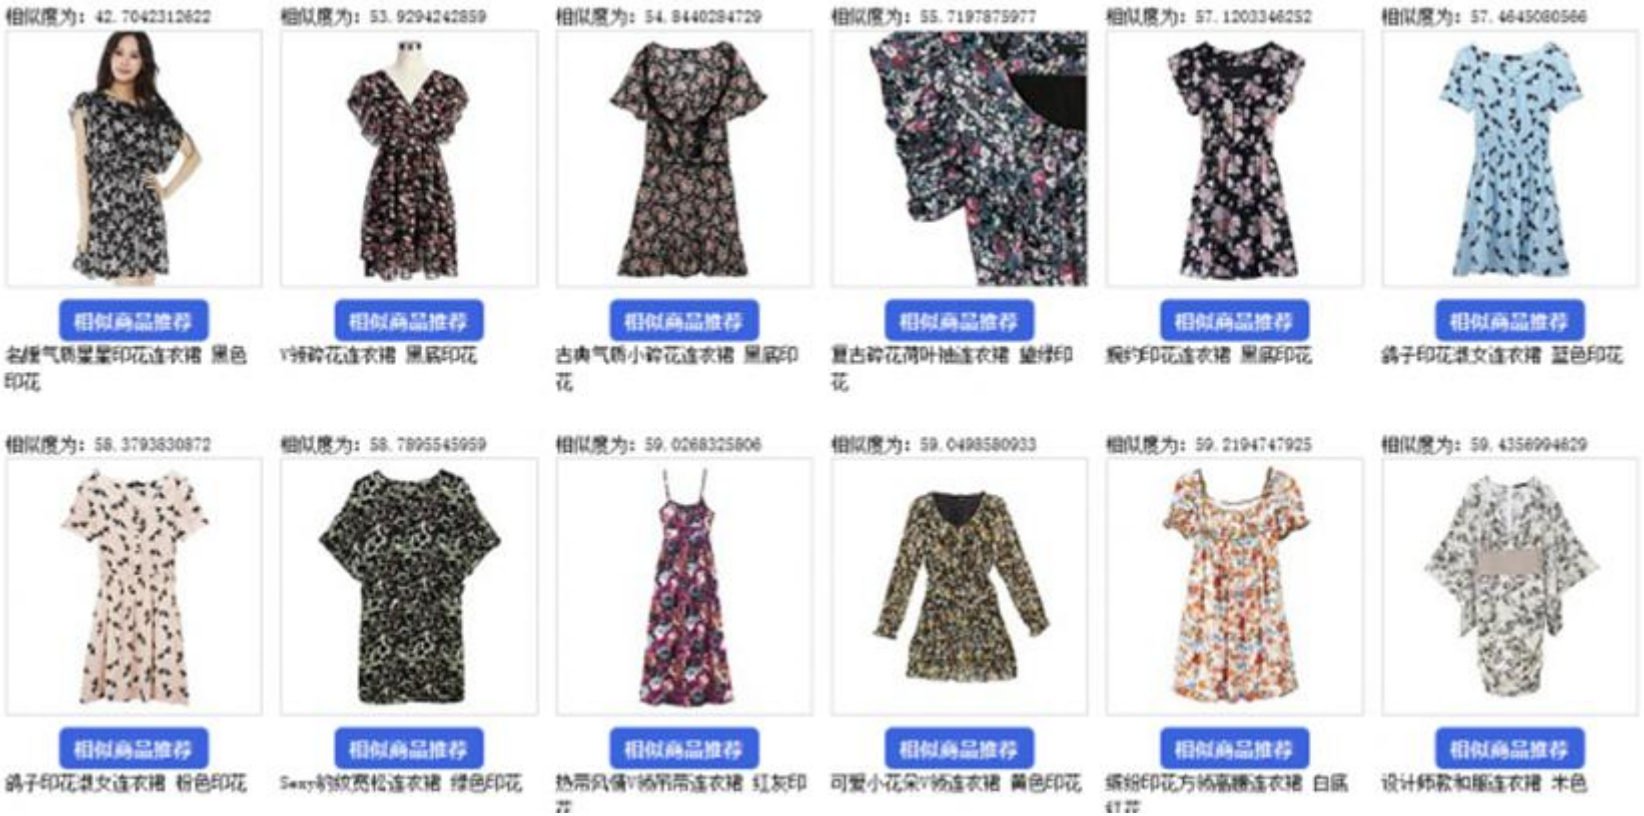
相似纹理检索

效果图1


相似度为：49.6532402039
相似商品推荐
经典格型情侣休闲衬衫（女款）苏格兰格
相似度为：72.2671432495
相似商品推荐
法兰绒经典百搭长袖衬衫 明朗红蓝彩格
相似度为：73.3022613525
相似商品推荐
VOF-法兰绒经典百搭休闲长袖衬衫 女款 浅卡其粉蓝格
相似度为：73.3817672729
相似商品推荐
VOF-法兰绒经典百搭休闲长袖衬衫 女款 海蓝红白格纹
相似度为：74.0381774902
相似商品推荐
VOF-法兰绒经典百搭休闲长袖衬衫 女款 经典灰繁格纹
相似度为：74.7108535767
相似商品推荐
户外温暖休闲衬衫（女款）咖啡色格子
相似度为：74.8854064941
相似商品推荐
VOF-法兰绒经典百搭休闲长袖衬衫 女款 朱红蓝白格纹
相似度为：75.3982925415
相似商品推荐
户外暖热保温格子衬衫C（情侣款）女款 马赛克紫
相似度为：75.5169143677
相似商品推荐
经典格型情侣休闲衬衫（女款）红蓝格
相似度为：76.1359939575
相似商品推荐
[大码]法兰绒格子休闲衬衣（女） 红蓝小格纹
相似度为：76.9539108276
相似商品推荐
薄法兰绒西部风尚休闲长袖衬衫 女款 墨绿玫红白格纹
相似度为：77.1196060181
相似商品推荐
法兰绒经典百搭长袖衬衫 淡蓝灰格纹

相似纹理检索

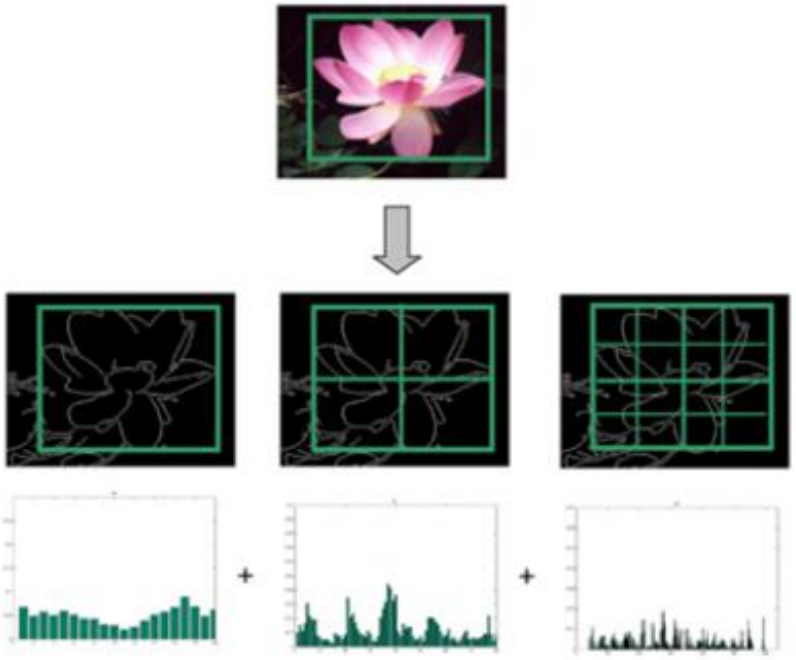
效果图2

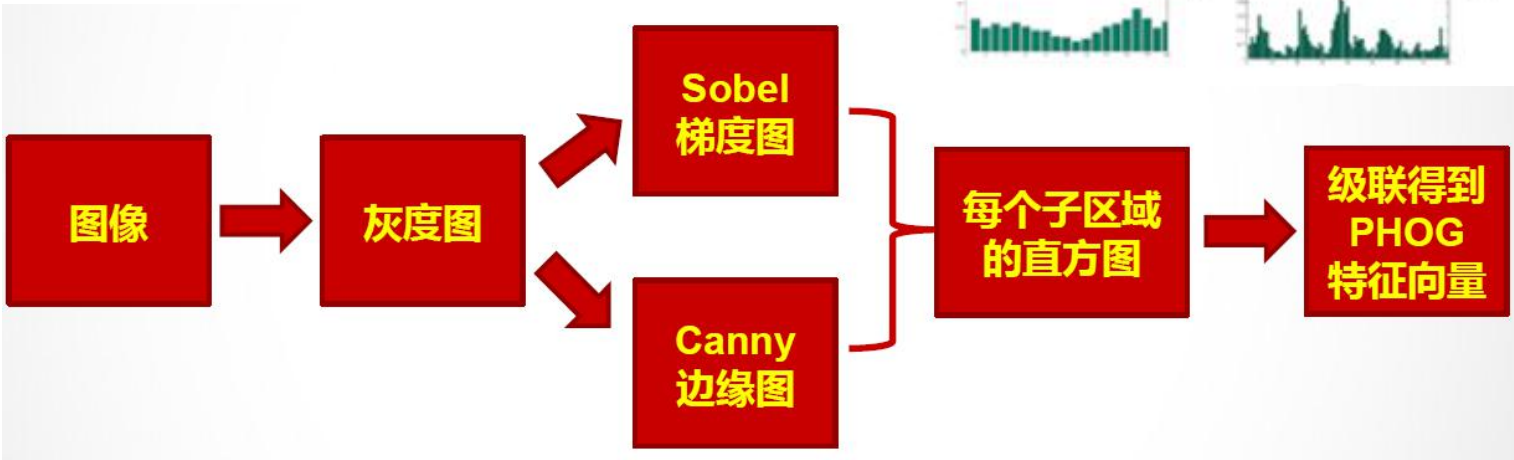

相似度为：42.7042312622
相似商品推荐
相似度为：53.9294242859
相似商品推荐
相似度为：54.8440284729
相似商品推荐
相似度为：55.7197875977
相似商品推荐
相似度为：57.1203346252
相似商品推荐
相似度为：57.4645080566
相似商品推荐
相似度为：58.3793830872
相似商品推荐
相似度为：58.7895545959
相似商品推荐
相似度为：59.0268325806
相似商品推荐
相似度为：59.0498580933
相似商品推荐
相似度为：59.2194747925
相似商品推荐
相似度为：59.4356994629
相似商品推荐

相似形状检索

PHOG形状特征提取

- 金字塔梯度方向直方图
  - 网格：1x1，2x2，4x4
  - 直方图方向数量：9
  - 维数：189 = (1+4+16)x9





相似形状检索

模型隐含的假设就是图像都是正着存储的（人都是站立的.....）

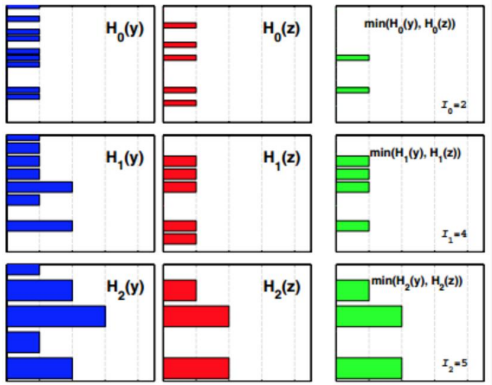
PHOG形状特征相似度计算

- 标准化欧氏距离
  - S_i 为样本集特征中每一维对应的标准差

$$Dist(P,Q) = \sqrt{\sum_i (\frac{P_i - Q_i}{S_i})^2}$$

- 直方图相交(Histogram Intersection)

$$Sim(P,Q) = \sum_{i=1}^{i=n} \min(P_i, Q_i)$$



相似形状检索

效果图1





相似形状检索

效果图2

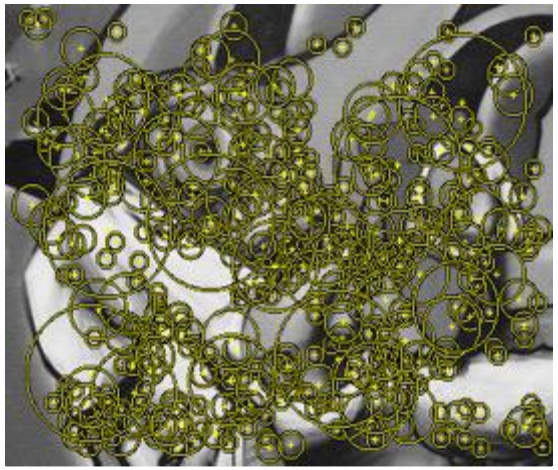


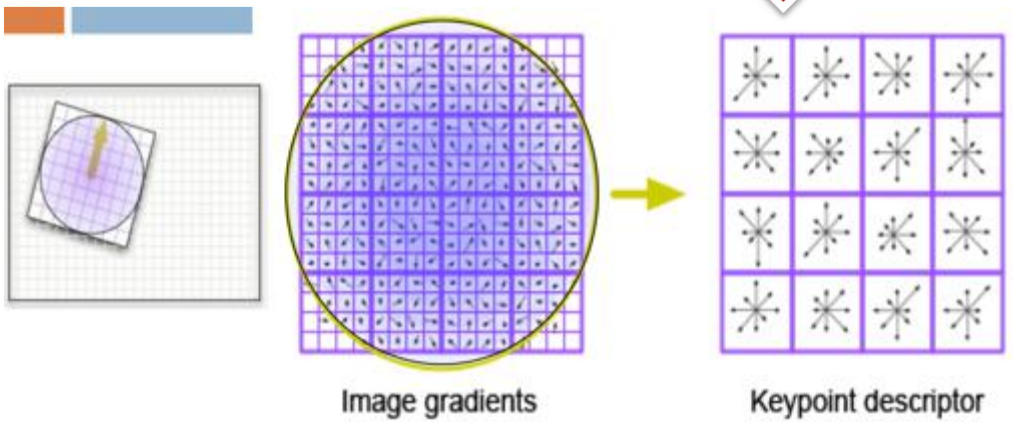
相似局部特征检索

局部特征点特征提取

- 检测出所有
  - 局部特征点
  - 特征描述子
- SIFT特征点
  - SURF
  - Color-SIFT
  - Affine-SIFT
  - Dense-SIFT
  - PCA-SIFT





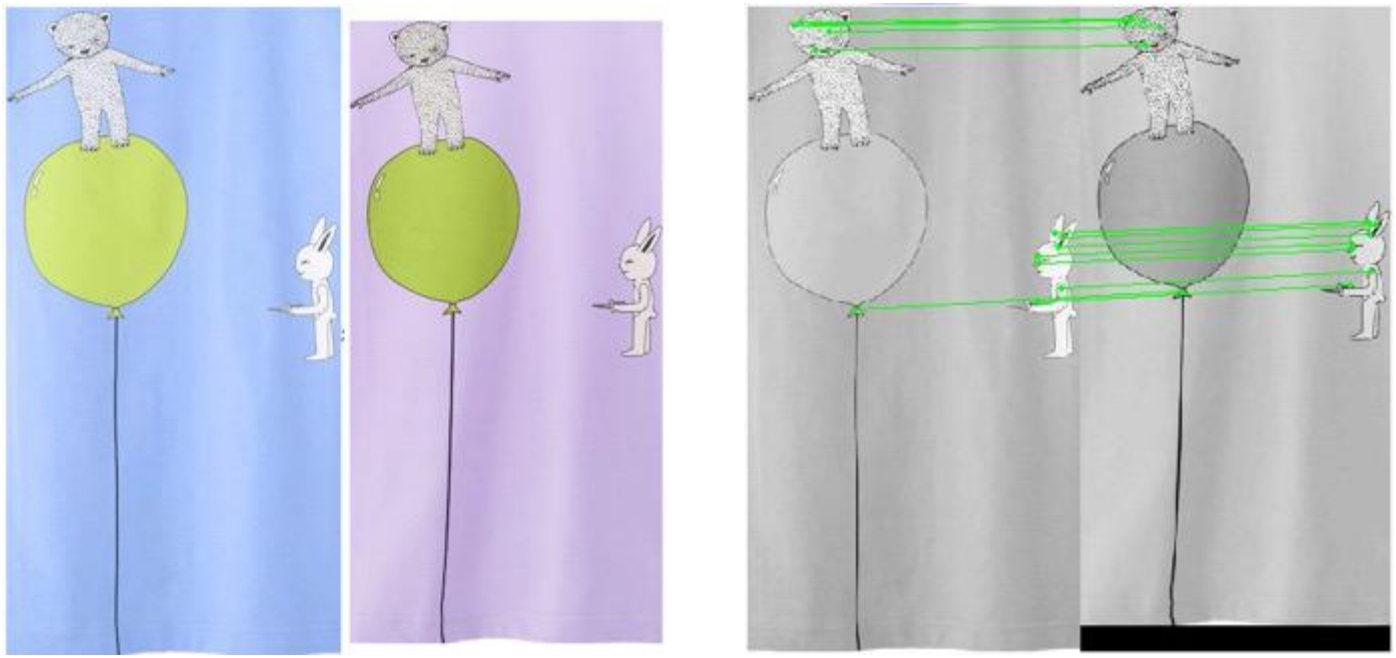


4x4个8方向梯度方向直方图 = 128维描述子

相似局部特征检索

图之间的相似度匹配

- 两个图SIFT点集之间的匹配对数
- 双向匹配



相似局部特征检索

效果图

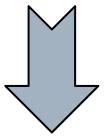


Bag Of Visual Word

- （BoW model）忽略文本的语法和语序，用一组无序的单词（words）来表达一段文字或一个文档。
- 近年来BoW 模型被广泛应用于计算机视觉中，与应用于文本的BoW 类比，图像的特征（feature）被当作单词（Word）。

```
John likes to watch movies. Mary likes too.

John also likes to watch football games.
```



"John": 1, "likes": 2, "to": 3, "watch": 4, "movies": 5,
"also": 6, "football": 7, "games": 8, "Mary": 9, "too": 10

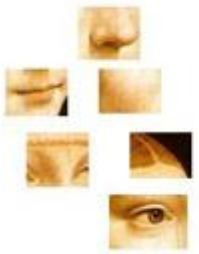
```
[1, 2, 1, 1, 1, 0, 0, 0, 1, 1]

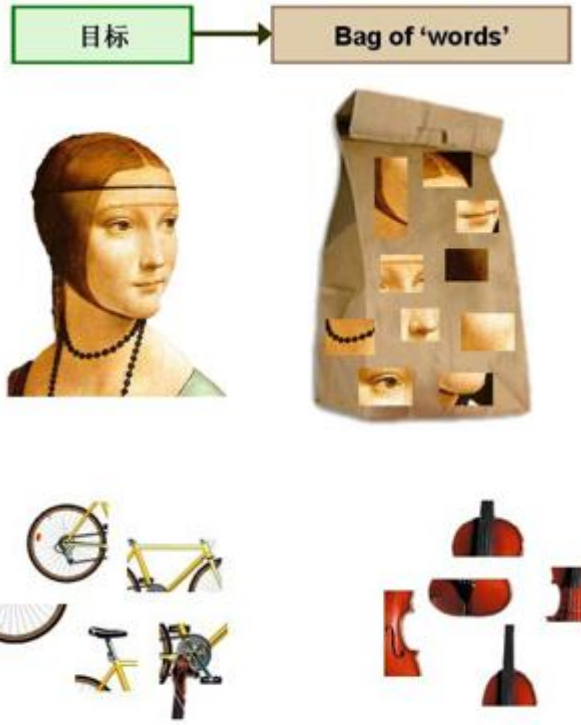
[1, 1, 1, 1, 0, 1, 1, 1, 0, 0]
```

Bag Of Visual Word

视觉词汇的字典

- 由图片集的所有视觉词汇构成
  - 视觉词汇的物理含义不明显
  - 不是现成的，需要构建
    - 特征检测
      - 特征点：SIFT、SURF等
    - 特征表示
      - SIFT描述子、颜色、纹理等
    - 字典生成
      - Kmeans等聚类





Bag Of Visual Word

- 假设训练集有M幅图像，对训练图象集进行预处理。包括图像增强、分割，图像统一格式，统一规格等等。
- 对每一幅图像提取若干数量的SIFT特征。每一个SIFT特征用一个128维的描述子矢量表示，假设M幅图像共提取出N个SIFT特征。
- 用K-means对上一步提取的N个SIFT特征进行聚类。聚类中心有k个（这里的聚类中心：称为视觉词），码本的长度也就为k，计算每一幅图像的每一个SIFT特征到这k个视觉词的距离，并将其映射到距离最近的视觉词中（即将该视觉词的对应词频+1）。
- 完成这一步后，每一幅图像就变成了一个与视觉词序列相对应的词频矢量。

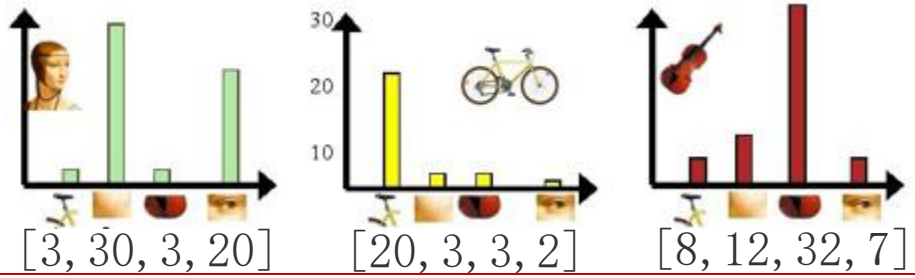
Bag Of Visual Word

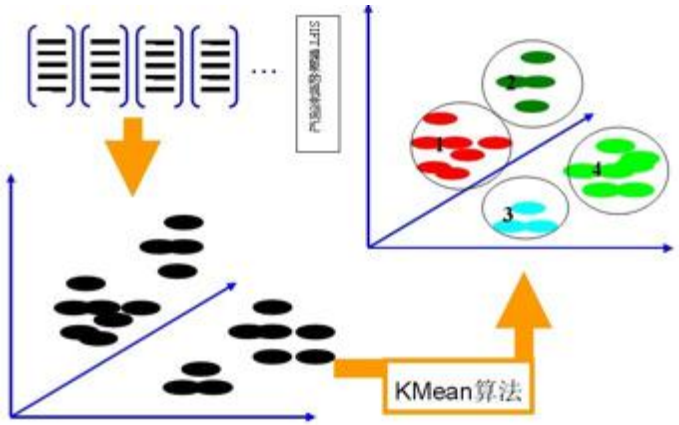
SIFT视觉词汇的字典应用

- 利用SIFT算法提取图片集中所有视觉词汇



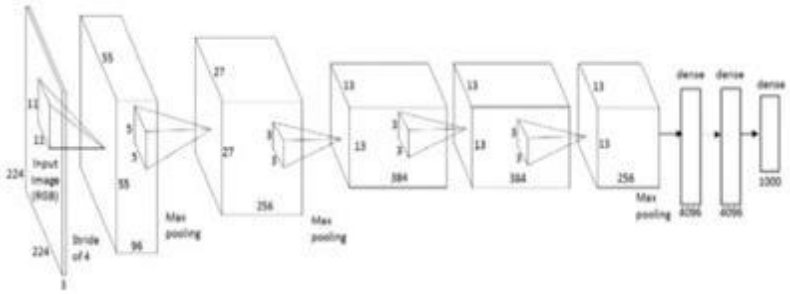
- 利用Kmeans算法对所有词汇聚类，收缩为字典
- 基于字典编码图片特征
  - 词汇频数直方图
  - 最邻近词汇
  - 特征相似距离 ： L1、L2





基于DL的二值哈希编码

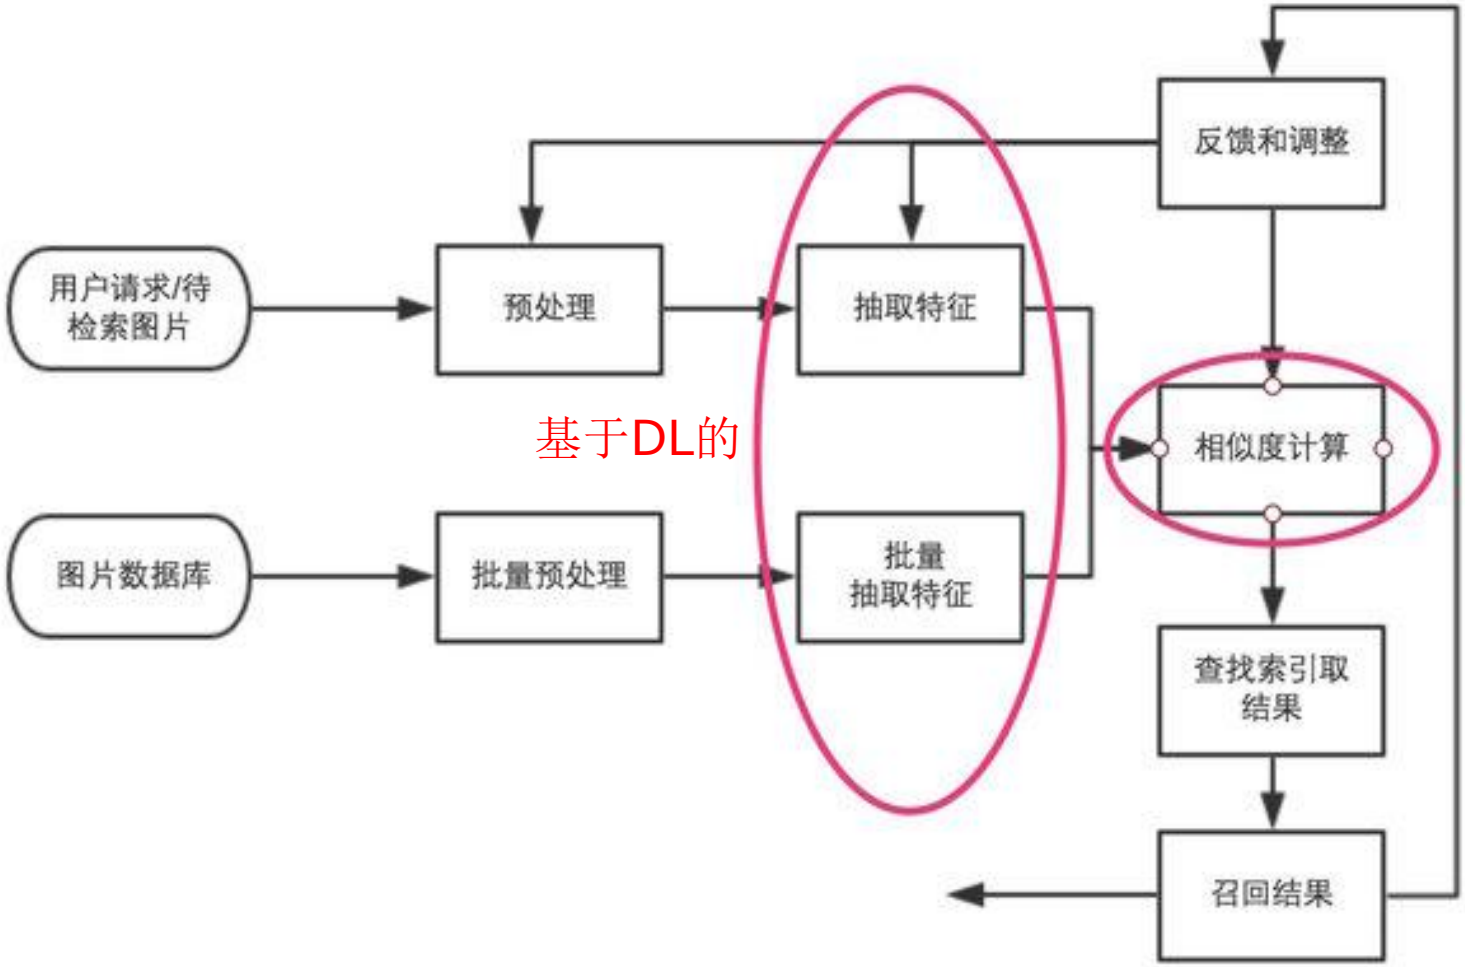
- 在ImageNet中的卷积神经网络结构基础上，在第7层(4096个神经元)和output层之间多加了一个隐层(全连接层)。
- 隐层的神经元激励函数，可以选用sigmoid，这样输出值在0-1之间值，可以设定阈值(比如说0.5)之后，将这一层输出变换为01二值向量作为“二值检索向量”



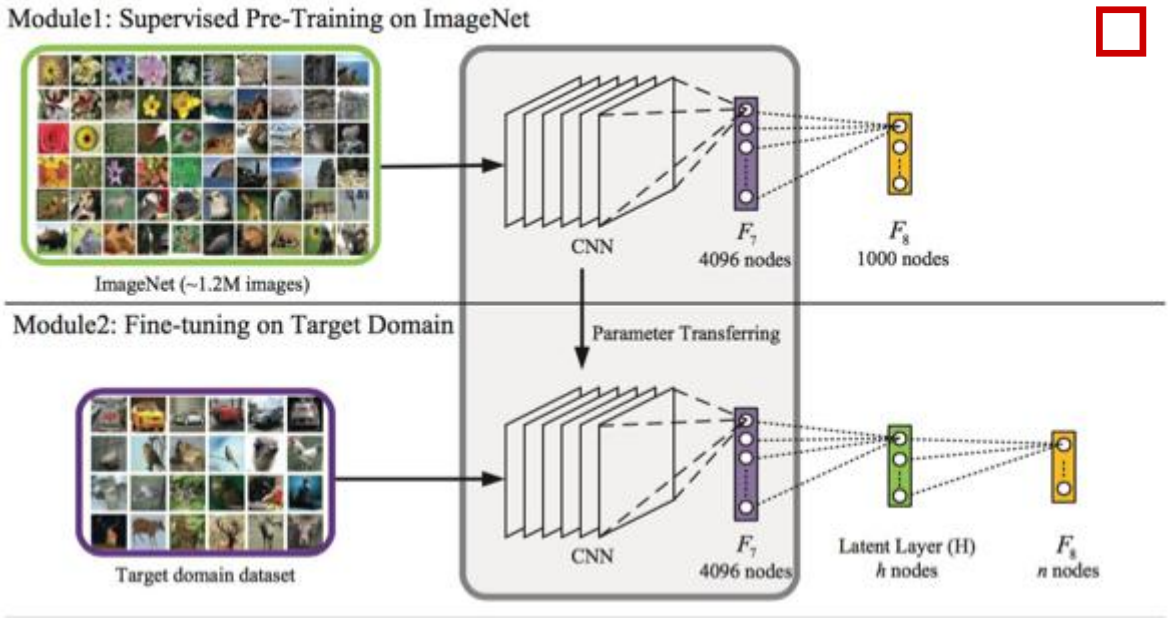
基于DL的二值哈希编码

- 这样在使用卷积神经网做图像分类训练的过程中，会"学到"和结果类别最接近的01二值串，也可以理解成，我们把第7层4096维的输出特征向量，通过神经元关联压缩成一个低维度的01向量。
- 但不同于其他的降维和二值操作，这是在一个神经网络里完成的，每对图片做一次完整的前向运算拿到类别，就产出了表征图像丰富信息的第7层output(4096维)和代表图片分桶的第8层output。

基于DL的二值哈希编码



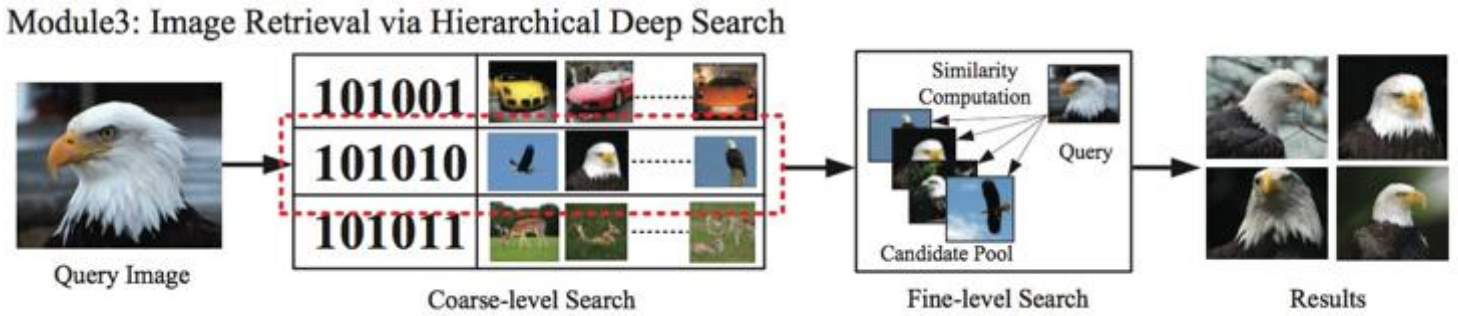
基于DL的二值哈希编码



- 上图为ImageNet比赛中使用的卷积神经网络；

- 下图为调整后，在第7层和output层之间添加隐层后的卷积神经网络，复用ImageNet中得到最终模型的前7层权做fine-tuning，得到第7层、8层和output层之间的权重。

基于DL的二值哈希编码

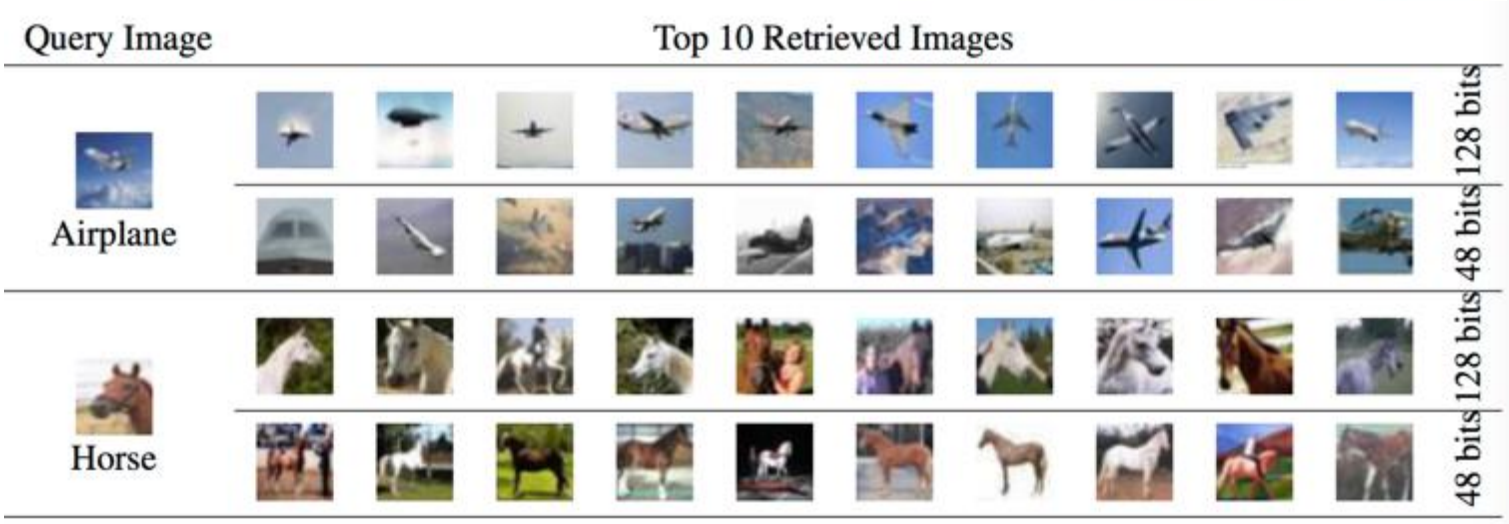


- 实际检索过程：对于所有的图片做卷积神经网络前向运算得到第7层4096维特征向量和第8层128维输出(设定阈值0.5之后可以转成01二值检索向量)。
- 对于待检索的"鹰"图像，算得二值检索向量为101010，取出桶内图片(可以看到基本也都为鹰)，比对4096维特征向量之间距离，重新排序拿得到最后的检索结果。

基于DL的二值哈希编码

- 检索效果：





在高维空间检索

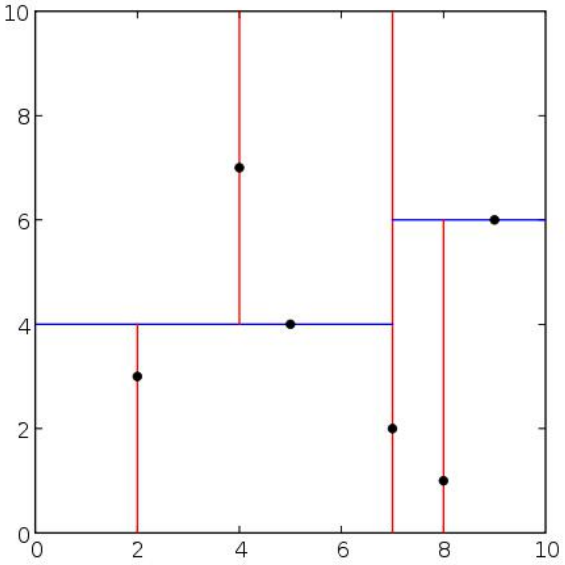
- 在图像检索领域，需要处理的数据往往是海量并且具有很高的维度，怎样快速地从海量的高维数据集合中找到与某个数据最相似（距离最近）的一个数据或多个数据成为了一个难点和问题。
- 为了解决该问题，我们需要采用一些类似索引的技术来加快查找过程，通常这类技术称为最近邻查找（Nearest Neighbor），例如K-d tree；或近似最近邻查找（Approximate Nearest Neighbor），例如LSH。

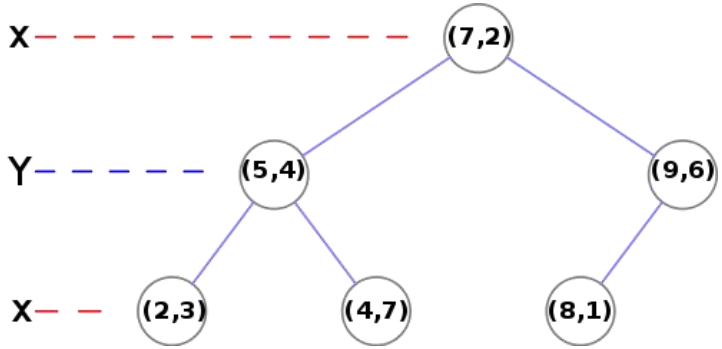
索引加速：KD-Tree

- 一种用于多维度检索的二叉平衡树
  - 输入：N个D维空间的数据点
  - 构建过程
    1. 确定split值：方差最大的维度
    2. 确定分割点：在split维度上的中值点，首次为根节点
    3. 确定分割面：通过分割点，垂直split维度的超平面
    4. 确定左右子树
       - 左子树：split维度上小于分割点
       - 右子树：split维度上大于分割点
    - 迭代1-4，直到空间只包含一个数据点

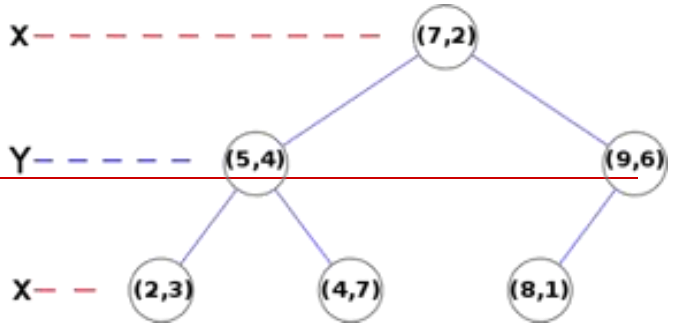
KD-Tree

- 输入
  - (2,3), (5,4), (4,7) , (9,6) , (7,2) , (8,1)
- 第一轮：
  - Split = 1(x)
  - (7,2)在x轴上是中点 → 根节点
  - 左子树：(2,3), (5,4), (4,7)
    - 第二轮：
      - Split = 2(y)
      - (5,4)是y轴上中点
      - (2,3)为左子树， (4,7)为右子树
  - 右子树：(8,1) , (9,6)
    - 第二轮…

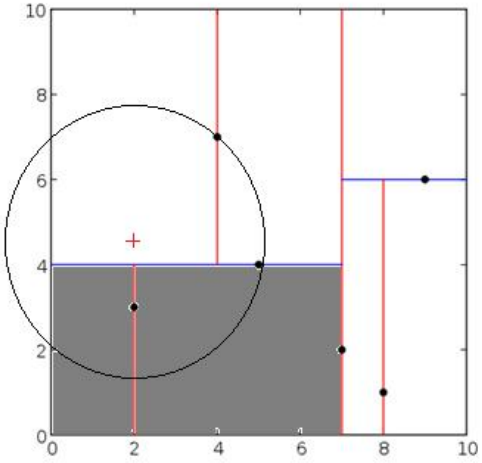




KD-Tree

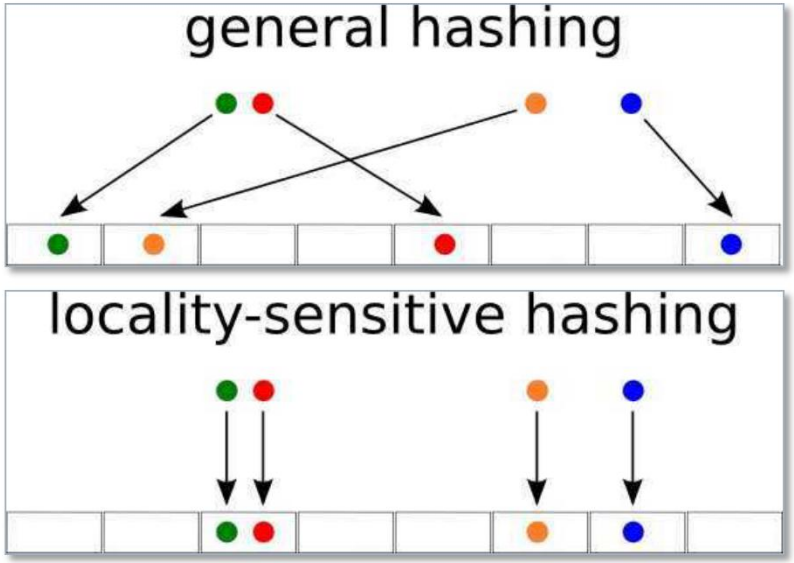


- 最邻近查询
  - 路径：类似二叉树搜索，从根节点开始，根据每个维度的split维进行左右子树的查询，直到叶子节点构建过程
  - 回溯：检查查询路径上节点的另一半子空间是否有距离更近的点
- 查询点(2, 4.5)
  - 路径：(7, 2)→(5, 4)→(4, 7)
  - 回溯：(5, 4)→(2,3)



索引加速：LSH

- 局部敏感哈希（Locality Sensitivity Hashing）：使得2个相似度很高的数据以较高的概率映射成同一个hash值，而令2个相似度很低的数据以极低的概率映射成同一个hash值。
- 能高效处理海量高维数据的最近邻问题。
- 利用collisions
  - 普通哈希避免collisions
- 支持常见距离
  - Hamming
  - Lp Norm (L1, L2)
  - Jaccard
  - Cosine
  - ……



Locality Sensitivity Hashing

- 将这样的一族hash函数 H={h:S→U}称为是(r1,r2,p1,p2)敏感的，如果对于任意H中的函数h，满足以下2个条件：
  - 如果d(O1,O2)<r1，那么Pr[h(O1)=h(O2)]≥p1
  - 如果d(O1,O2)>r2，那么Pr[h(O1)=h(O2)]≤p2
- 其中，O1,O2∈S，表示两个具有多维属性的数据对象，d(O1,O2)为2个对象的相异程度，也就是1 - 相似度。
- 上面的这两个条件说得直白一点，就是当足够相似时，映射为同一hash值的概率足够大；而足够不相似时，映射为同一hash值的概率足够小。

Locality Sensitivity Hashing

- 构建LSH索引
  1. 重构LSH函数g
     - 串接k个具有(r1, r2, P_1, P_2)局部敏感性的哈希原子函数

$$\mathcal{G} = \{g : S \to U^k\} \text{ such that } g(v) = (h_1(v), \ldots, h_k(v)), \text{ where } h_i \in \mathcal{H}.$$

  2. 独立、随机选取L个LSH函数

$$g_1, \ldots, g_L \text{ from } \mathcal{G}$$

  3. 构建L个LSH索引表（离线执行）
     - 为所有数据点计算 $g_j(v)$, for $j = 1, \ldots, L.$ ，并存入桶中
  4. 计算查询的L个LSH值 $g_1(q), \ldots, g_L(q)$，并在LSH桶中搜索

Locality Sensitivity Hashing

- **p稳定分布：**
  - **对于一个实数集R上的分布D，如果存在P>=0，对任何n个实数$v_1,\ldots,v_n$和n个满足D分布的变量$X_1,\ldots,X_n$，随机变量$\Sigma_i v_i X_i$（向量点乘，一个数）和$(\Sigma_i |v_i|^p)^{1/p} X$（p(阶)范数，一个数）有相同的分布，其中X是服从D分布的一个随机变量，则称D为 一个p-稳定分布。**
  - **p=1是柯西分布，p=2时是高斯分布。**
- p稳定分布有什么作用呢？就是可以估计给定向量v在欧式空间下的p范数的长度，也就是$\|v\|_p$

Locality Sensitivity Hashing

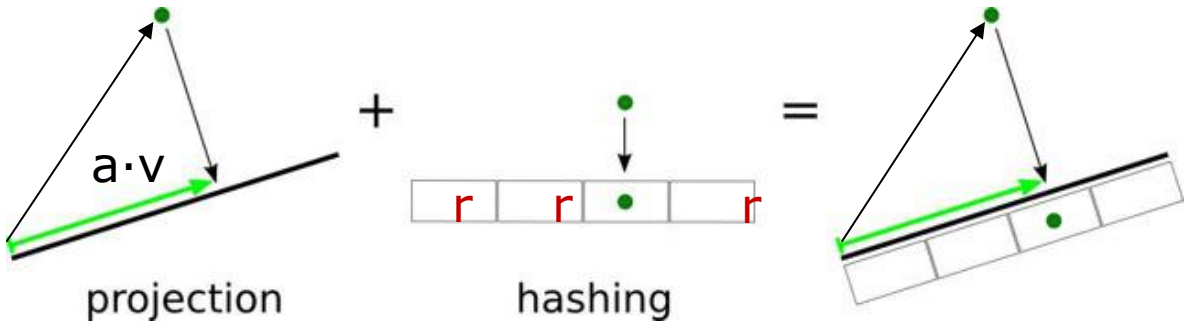
- 翻译成白话：
  - 取满足正态分布的一个数列，与某个特征向量做向量点乘，得到一个数值，这个数值与这个特征向量本身的2阶范数（即向量每一维的元素绝对值的平方和再开方，代表向量的长度，也是一个数值），有同分布的性质。
  - 假设有两个图像特征X1,X2，用这两个特征分别与同一个正态分布的数列做向量点乘，所得到的2个数值在一维上的距离与X1,X2在多维上的欧氏距离是同分布的。

索引加速：P-stable LSH

- 原子哈希函数

$$h_{\boldsymbol{a},b}(\boldsymbol{v}) = \lfloor \frac{\boldsymbol{a}\cdot\boldsymbol{v}+b}{r} \rfloor \ : \mathcal{R}^d \rightarrow \mathcal{N}$$

  - 把d维向量v映射为一条直线上的一个整数值
  - 随机投射a：在p-stable分布上独立、随机选取的d维向量
  - 桶宽r：映射直线上的分段长度
  - 随机偏移b：在[0, r]上均匀随机选取的偏移值
  - 对于 $(\boldsymbol{v_1}, \boldsymbol{v_2})$，投射距离 $(\boldsymbol{a}.\boldsymbol{v_1} - \boldsymbol{a}.\boldsymbol{v_2})$ 与 $||\boldsymbol{v_1} - \boldsymbol{v_2}||_p X$ 同分布



索引加速：P-stable LSH

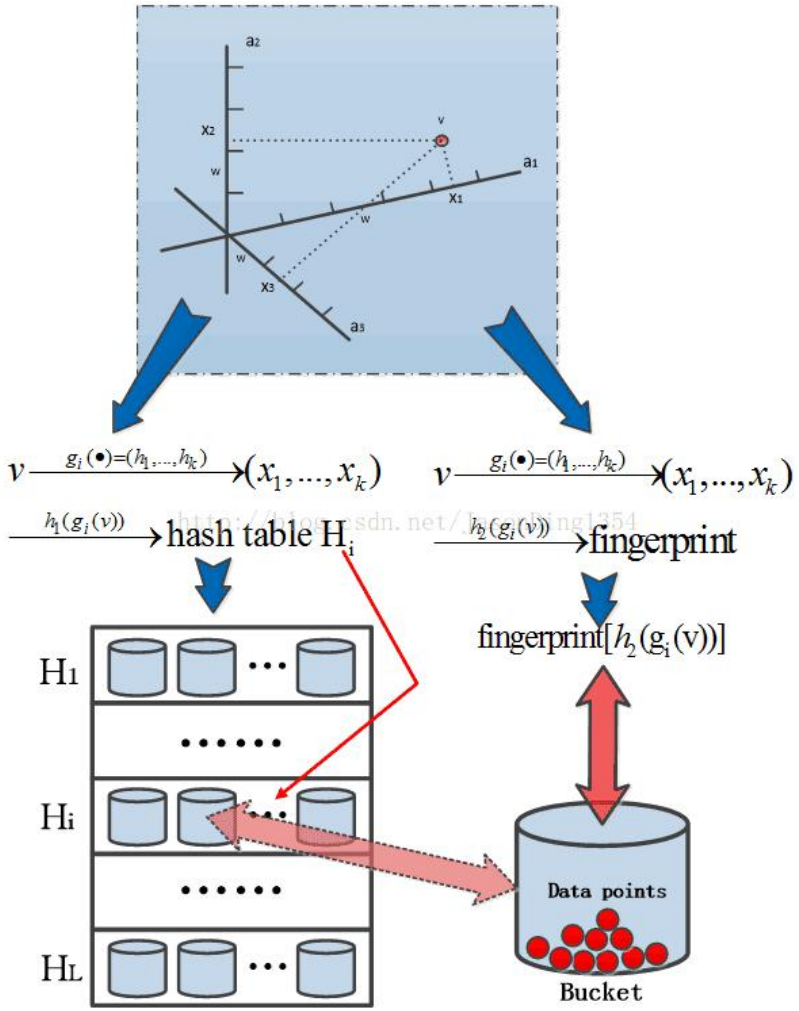
- 为了减少漏报率（就是本来很相近的两条数据被认为是不相似的），一种解决方案是用多个hash函数对向量执行hash运算。
- 比如说，对任意一个向量v_i，现在准备了k个hash函数$(h_1(),h_2(),\ldots,h_k())$，这k个hash函数是从LSH函数族中随机选取的k个，
- 这样，通过计算，就得到了k个hash值：$(h_1(v_i),h_2(v_i),\ldots,h_k(v_i))$，而对于查询q，用同样的k个hash函数，也能得到一组值$(h_1(q),h_2(q),\ldots,h_k(q))$，
- 这两组值之间，只要有一个对应位的值相等，就认为v_i是查询q的一个近邻。

索引加速：P-stable LSH

$$H_1(x_1,\ldots,x_k) = ((\sum_{i=1}^{k} r_i x_i) \mod C) \mod size$$

$$H_2(x_1,\ldots,x_k) = (\sum_{i=1}^{k} r_i' x_i) \mod C$$

- 每个数据向量经过$g_i(\cdot)$被映射成一个整型向量，记为$(x_1, \ldots, x_k)$
- 将2步生成的$(x_1,\ldots,x_k)$通过H_1,H_2计算得到两个数值：index, fp
- 前者是hash table的索引，后者是数据向量对应的指纹。



参考资料

- https://blog.csdn.net/guoziqing506/article/details/53019049
- http://www.iis.sinica.edu.tw/~kevinlin311.tw/cvprw15.pdf
- https://blog.csdn.net/guoziqing506/article/details/53019049/
- https://blog.csdn.net/jasonding1354/article/details/38237353

问答互动

在所报课的课程页面，

1、点击“全部问题”显示本课程所有学员提问的问题。

2、点击“提问”即可向该课程的老师和助教提问问题。



联系我们

小象学院：互联网新技术在线教育领航者

– 微信公众号：**小象学院**

