

Journal of Image
and Graphics

中国图象图形学报



ISSN1006-8961
CN11-3758/TB

2013 2
Vol.18 No.

中国科学院遥感应用研究所
中国图象图形学学会主办
北京应用物理与计算数学研究所

中国图象图形学报

Zhongguo Tuxiang Tuxing Xuebao

2013 年 2 月 第 18 卷 第 2 期(总第 202 期)

目 次

计算机视觉前沿论坛

- 计算机视觉——探索行为理解,认知内心世界 徐光祐, 刘允才, 章毓晋(131)
- 跨学科前沿与应用的交汇点: 日常活动理解 徐光祐, 陶霖密, 邸慧军(132)
- 时空行为理解 章毓晋(141)
- 视觉机制研究对机器视觉的启发示例 李雄, 刘允才(152)
- 视点无关的行为识别综述 冯家更, 肖俊(157)

图像处理和编码

- 基于演化算法的卷曲 DCT 图像压缩 李康顺, 韦蕴珊, 张文生(169)
- 基于欧氏距离图的图像边缘检测 张闯, 王婷婷, 孙冬娇, 葛益娴, 常建华(176)
- 基于暗原色先验模型的快速去雾算法 张冰冰, 戴声奎, 孙万源(184)

图像分析和识别

- Gabor 特征集结合判别式字典学习的稀疏表示图像识别 胡正平, 徐波, 白洋(189)
- 半监督 k 近邻分类方法 陈日新, 朱明早(195)
- 最小距离鉴别投影及其在人脸识别中的应用 黄璞, 唐振民(201)
- 图像 LSB 匹配隐藏的预分类检测模型 曹卫权, 韩杰思, 王宏霞(207)
- 具有旋转鲁棒性的纹理谱描述子 陈刚, 陈晓云(214)

计算机图形学

- 利用形体特征的铅笔素描画生成 莫晓斐, 丁友东(219)

医学图像处理

- 统计相似度特征的医学图像分割 郭艳蓉, 蒋建国, 郝世杰, 詹曙, 李鸿(225)

遥感图像处理

- 结合遗传算法和蚁群算法的高光谱图像波段选择 王立国, 魏芳洁(235)
- 相似度自适应样本块的高分辨 SAR 图像阴影修复 赵昊, 张弓(243)

第八届国际数字地球会议征稿通知 封 3

Journal of Image and Graphics

(Monthly, Started in 1996)

Vol. 18 No. 2 February 2013

Contents

Forum: Forefront of Computer Vision

Confluence of interdisciplinary frontiers and real-world application: understanding activities of daily living

..... Xu Guangyou, Tao Linmi, Di Huijun(132)

Understanding spatial-temporal behaviors Zhang Yujin(141)

The motivation of visual mechanisms to machine vision: examples Li Xiong, Liu Yuncai(152)

View-invariant action recognition: a survey Feng Jiageng, Xiao jun(157)

Image Processing and Coding

Warped DCT image compression based on an evolutionary algorithm Li Kangshun, Wei Yunshan, Zhang Wensheng(169)

Image edge detection based on the Euclidean distance graph

..... Zhang Chuang, Wang Tingting, Sun Dongjiao, Ge Yixian, Chang Jianhua(176)

Fast image haze-removal algorithm based on the prior dark-channel

..... Zhang Bingbing, Dai Shengkui, Sun Wanyuan(184)

Image Analysis and Recognition

Sparse representation for image recognition based on Gabor feature set and discriminative dictionary learning

..... Hu Zhengping, Xu Bo, Bai Yang(189)

Semi-supervised k -nearest neighbor classification method Chen Rixing, Zhu Minghan(195)

Minimum-distance discriminant projection and its application to face recognition Huang Pu, Tang Zhenmin(201)

Using pre-classification to attack LSB matching Cao Wei-quan, Han Jiesi, Wang Hongxia(207)

Robust rotation-invariant texture spectrum descriptor Chen Gang, Chen Xiaoyun(214)

Computer Graphics

Pencil sketch generation with shape features Mo Xiaofei, Ding Youdong(219)

Medical Image Processing

Medical image segmentation based on statistical similarity feature

..... Guo Yanrong, Jiang Jianguo, Hao Shijie, Zhan Shu, Li Hong(225)

Remote Sensing Image Processing

Band selection for hyperspectral imagery based on combination of genetic algorithm and ant colony algorithm

..... Wang Liguang, Wei Fangjie(235)

Adaptive shadow inpainting from high-resolution SAR image based on exemplar's similarity Zhao Hao, Zhang Gong(243)

中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2013)02-195-06

论文引用格式: 陈日新, 朱明早. 半监督 k 近邻分类方法[J]. 中国图象图形学报, 2013, 18(2): 195-200.

半监督 k 近邻分类方法

陈日新, 朱明早

湖南文理学院电气与信息工程学院, 常德 415000

摘要: 加权 KNN (k -nearest neighbor) 方法, 仅利用了 k 个最近邻训练样本所提供的类别信息, 而未考虑测试样本的贡献, 因而常会导致一些误判。针对这个缺陷, 提出了半监督 KNN 分类方法。该方法对序列样本和非序列样本, 均能够较好地执行分类。在分类决策时, 还考虑了 c 个最近邻测试样本的贡献, 从而提高了分类的正确性。在 Cohn-Kanade 人脸库上, 序列图像的识别率提高了 5.95%, 在 CMU-AMP 人脸库上, 非序列图像的识别率提高了 7.98%。实验结果表明, 该方法执行效率高, 分类效果好。

关键词: 加权 KNN; 贝叶斯理论; 半监督 KNN; 流形

Semi-supervised k -nearest neighbor classification method

Chen Rixing, Zhu Minghan

College of Communication and Electric Engineering, Hunan University of Arts and Science, Changde 415000, China

Abstract: The category information of the k -nearest neighbor labeled samples is used, but the contribution of the test samples is omitted in the weighted k -nearest neighbor method, which often lead to misclassifications. Aimed at the problem, a semi-supervised k -nearest neighbor method is proposed in this paper. The method can classify sequential samples and non-sequential samples better than the k -nearest neighbor method. In the decision process of classification, the information of c -nearest neighbor samples in the test set is used. So, classification accuracy is improved. The recognition accuracy of the method is 5.95% higher for sequential images in Cohn-Kanade face database, and 7.89% higher for non-sequential images in Cohn-Kanade face database than it of weighted k -nearest neighbor method. The experiment shows that the method performs fast and has high classification accuracy.

Key words: weighted k -nearest neighbor; Bayesian theory; semi-supervised k -nearest neighbor; manifold

0 引言

KNN (k -nearest neighbor) 分类方法是一种非参数分类方法, 不需要估计参数, 因此在分类、回归和模式识别等领域中都有应用^[1-2]。KNN 是最近邻方法的推广^[3], 它的思想比较简便, 执行样本分类时, 将测试样本归为与它最接近的 k 个近邻训练样本中出现最多的那个类别。该方法在执行样本分类时,

赋予了这 k 个近邻样本平等的贡献, 为了得到可靠的分类结果, 常需要根据实际分类问题, 选取不同的 k 值^[4]。

对此一些学者展开了选取最优 k 值, 以及降低识别率对 k 值敏感性的研究。Gora 等人提出了自动选取最优 k 值的 KNN 方法^[5]。Hechenbichler 等人提出了加权 KNN 法^[6], 该方法根据各近邻样本到测试样本距离 (或其他相似度) 的大小, 赋予这 k 个近邻样本不同的权值, 距离越小权值越大。这样近

收稿日期: 2011-12-26; 修回日期: 2012-07-19

基金项目: 国家自然科学基金项目 (60776834); 湖南省教育厅优秀青年项目 (10B074)

第一作者简介: 陈日新 (1964—), 男, 副教授, 2005 年于湖南大学电气信息学院获电气专业硕士学位, 主要研究方向为模式识别与计算机视觉。E-mail: rixin_chen@qq.com

邻样本与测试样本的相似程度,就能通过权值的大小来体现。即使 k 值很大,对测试样本分类起决定作用的,仍是与它相距较近的那些样本。该方法的分类准确率对 k 值的选取不再敏感。Wang 等人提出了一种广义的最近邻分类方法^[7],他们从每类中选出与测试样本最接近的 k 个样本,并求出待测样本属于每类样本的权值,最后根据权值作分类判决。该方法的分类正确率随 k 值的变化波动更小,鲁棒性更强。

还有些学者则对 KNN 方法中,样本距离(或其他相似度)的测量问题进行了研究。陈振洲等人提出了基于 SVM 的特征加权 KNN 算法^[8];刘明等人提出了证据理论 k 近邻规则中,相似度的确定方法^[9];Vivencio 等人提出了基于 χ^2 统计检验的特征加权 KNN 算法^[10];孙岩等人提出了基于贝叶斯结构特征加权的 KNN 算法^[11]。这些算法主要是通过特征加权的方式,提高主要特征在样本距离中所占的比重,在一定程度上提高了 KNN 的分类准确率。

但是以上这些方法在对样本进行分类时,都只利用了训练集中 k 个近邻样本提供的信息,忽视了测试集中其他测试样本提供的信息。在样本分布状态未知的情况下,常会导致明显的误判。图 1 简明地展示了这种误判现象。若用加权 KNN 方法,则 I 会被归为 ω_A 类。实际上,不难看出 I 应属于 ω_B 类。图中“★”表示属于 ω_A 类的训练样本,“▲”表示属于 ω_B 类的训练样本,“△”则表示属于 ω_B 类的测试样本。




图 1 采用加权 KNN 方法时的错分情形

Fig. 1 Misclassification situation using weighted KNN

针对这个缺陷,提出了半监督 KNN 分类方法 (SKNN)。该方法在对某测试样本进行分类时,不仅利用了它在训练集中的 k 近邻样本所提供的类别信息,而且还让与该测试样本最相似的 c 个测试样本也参与分类决策,使分类的信息更加全面可靠,从

而提高了分类的正确率。

1 加权 KNN 原理

设 $L = \{(y_i, \mathbf{x}_i), \mathbf{x}_i \in \mathbf{R}^d, i = 1, 2, \dots, n\}$ 是一个已标记类别的训练集, $\mathbf{x}_i$ 是训练样本, y_i 是它的类别标记, $y_i \in \{\omega_1, \omega_2, \dots, \omega_r\}$ 。 $\mathbf{x}_t$ 为测试样本, 它的类别 y_t 待测。加权 KNN 的基本步骤^[6]如下:

1) 根据明考斯基 (Minkowski) 距离 $d(\mathbf{x}_t, \mathbf{x}_i) = \left(\sum_{j=1}^d |x_{tj} - x_{ij}|^q \right)^{1/q}$ (或其他特征加权相似度), 从训练集 L 中, 找出 $\mathbf{x}_t$ 的 $k+1$ 个近邻样本。用 $\mathbf{x}_{t(1)}, \mathbf{x}_{t(2)}, \dots, \mathbf{x}_{t(k+1)}$ 表示这 $k+1$ 个近邻样本, $y_{(1)}, y_{(2)}, y_{(3)}, \dots, y_{(k+1)}$ 分别是它们的类别标记。

2) 用第 $k+1$ 个近邻样本到 $\mathbf{x}_t$ 的距离 $d(\mathbf{x}_t, \mathbf{x}_{t(k+1)})$, 标准化前 k 个近邻样本到 $\mathbf{x}_t$ 的距离

$$D(\mathbf{x}_t, \mathbf{x}_{t(l)}) = \frac{d(\mathbf{x}_t, \mathbf{x}_{t(l)})}{d(\mathbf{x}_t, \mathbf{x}_{t(k+1)})} (l = 1, \dots, k) \quad (1)$$

3) 用加权核函数 $P(\cdot)$, 将标准距离 $D(\mathbf{x}_t, \mathbf{x}_{t(l)})$ 转化为 $\mathbf{x}_t$ 与 $\mathbf{x}_{t(l)}$ 同类的概率 $P(\mathbf{x}_{t(l)} | \mathbf{x}_t)$ 。若 $P(\cdot)$ 采用高斯核函数, 则有

$$P(\mathbf{x}_{t(l)} | \mathbf{x}_t) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{D(\mathbf{x}_t, \mathbf{x}_{t(l)})^2}{2}\right) \quad (2)$$

对于加权核函数 $P(\cdot)$, Hechenbichler 等人还提出了另外 7 种, 详细内容可参考文献^[6]。

4) 根据 $\mathbf{x}_t$ 的这 k 个近邻样本, 求出 $\mathbf{x}_t$ 为 $\omega_s (s = 1, 2, \dots, r)$ 类的后验概率

$$P(\omega_s | \mathbf{x}_t) = \frac{1}{\alpha} \sum_{l=1}^k P(\mathbf{x}_{t(l)} | \mathbf{x}_t) I(y_{(l)} = \omega_s) \quad (3)$$

$$I(A) = \begin{cases} 1 & A \text{ 为真} \\ 0 & A \text{ 为假} \end{cases}$$

式中, $\alpha = \sum_{l=1}^k P(\mathbf{x}_{t(l)} | \mathbf{x}_t)$ 为归一化因子。最大 $P(\omega_s | \mathbf{x}_t)$ 所对应的类别被判定为 $\mathbf{x}_t$ 的类别, 即

$$y_t = \arg \max_{\omega_s} P(\omega_s | \mathbf{x}_t) \quad (4)$$

2 半监督 KNN 方法

加权 KNN 方法在对各测试样本进行分类时, 每次都是单独地计算后验概率, 然后根据后验概率的大小来做判决。实际上, 加权 KNN 已经假定了待测样本的类别状态是不可预知的, 即类别状态被看成

了一个随机的变量。但是,如果测试样本的类别状态之间存在着一定的相关性,如测试样本 $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_t$ 本身是来自于一个视频序列。可想而知,根据前后待测样本的相关性,就可以提高分类器的性能,也就是利用“上下文”的信息可以帮助做判决,提高分类的正确率。

设 $T = \{\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_t, \dots\}$ 为一样本序列,在对待测样本 $\mathbf{x}_t$ 进行分类时,考虑到 $\mathbf{x}_t$ 与 $\mathbf{x}_{0:t-1}$ 的类别状态存在着一定的相关性,同文献[12]一样,采用了联合后验概率 $P(\omega_s | \mathbf{x}_t, \mathbf{x}_{0:t-1})$ 作为它的分类依据,根据式(3)有

$$P(\omega_s | \mathbf{x}_t, \mathbf{x}_{0:t-1}) = \frac{1}{\alpha^*} \sum_{l=1}^k P(\mathbf{x}_{t(l)} | \mathbf{x}_{0:t}) I(y_{(l)} = \omega_s)$$

这里 $\mathbf{x}_{0:t}$ 表示序列 $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_t$ 。

$$\alpha^* = \sum_{l=1}^k \prod_{j=1}^t P(\mathbf{x}_j | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_0)$$

假设 $\mathbf{x}_t$ 与 $\mathbf{x}_{0:t-1}$ 在给定的 $\mathbf{x}_{t(l)}$ 下是条件独立的,运用贝叶斯理论,有如下的推理

$$\begin{aligned} P(\mathbf{x}_{t(l)} | \mathbf{x}_{0:t}) &= \frac{1}{\beta_1} P(\mathbf{x}_t | \mathbf{x}_{t(l)}, \mathbf{x}_{0:t-1}) P(\mathbf{x}_{t(l)} | \mathbf{x}_{0:t-1}) = \\ &= \frac{1}{\beta_1} P(\mathbf{x}_t | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_{0:t-1}) \end{aligned} \quad (5)$$

式中, $\beta_1 = P(\mathbf{x}_t | \mathbf{x}_{0:t-1})$ 。对式(5)继续递推

$$\begin{aligned} P(\mathbf{x}_{t(l)} | \mathbf{x}_{0:t}) &= \frac{1}{\beta_1 \beta_2} P(\mathbf{x}_t | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t-1} | \mathbf{x}_{t(l)}) \\ &= P(\mathbf{x}_{t(l)} | \mathbf{x}_{0:t-2}) \dots = \\ &= \frac{1}{\beta} \prod_{j=1}^t P(\mathbf{x}_j | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_0) \end{aligned}$$

式中, $\beta_j = P(\mathbf{x}_{t+1-j} | \mathbf{x}_{0:t-j})$, $(1 \leq j \leq t)$, $\beta = \beta_1 \beta_2 \dots \beta_t$ 。联合后验概率为

$$\begin{aligned} P(\omega_s | \mathbf{x}_{0:t}) &= \\ &= \frac{\frac{1}{\beta} \sum_{l=1}^k \prod_{j=1}^t P(\mathbf{x}_j | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_0) I(y_{(l)} = \omega_s)}{\frac{1}{\beta} \sum_{l=1}^k \prod_{j=1}^t P(\mathbf{x}_j | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_0)} = \\ &= \frac{1}{\alpha^*} \sum_{l=1}^k \prod_{j=1}^t P(\mathbf{x}_j | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_0) I(y_{(l)} = \omega_s) \end{aligned} \quad (6)$$

根据加权 KNN 原理, $\mathbf{x}_j$ 与 $\mathbf{x}_{t(l)}$ 同类的概率 $P(\mathbf{x}_j | \mathbf{x}_{t(l)}) = P(\mathbf{x}_{t(l)} | \mathbf{x}_j)$ 。因为根据式(2)有

$$\begin{aligned} P(\mathbf{x}_j | \mathbf{x}_{t(l)}) &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{D(\mathbf{x}_{t(l)}, \mathbf{x}_j)}{2}\right) \\ P(\mathbf{x}_{t(l)} | \mathbf{x}_j) &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{D(\mathbf{x}_j, \mathbf{x}_{t(l)})}{2}\right) \end{aligned}$$

而标准距离 $D(\mathbf{x}_j, \mathbf{x}_{t(l)}) = D(\mathbf{x}_{t(l)}, \mathbf{x}_j)$ 。另外,式(6)中所有的 $P(\omega_s | \mathbf{x}_{0:t})$ ($1 \leq s \leq r$)都有一个相同的归一化因子 α^* 。为了计算方便,采用式(7)计算出的 $P^*(\omega_s | \mathbf{x}_{0:t})$ 值,来度量 $\mathbf{x}_t$ 属于 ω_s 类的大小。

$$P^*(\omega_s | \mathbf{x}_{0:t}) =$$

$$\begin{aligned} &\sum_{l=1}^k \prod_{j=1}^t P(\mathbf{x}_j | \mathbf{x}_{t(l)}) P(\mathbf{x}_{t(l)} | \mathbf{x}_0) I(y_{(l)} = \omega_s) = \\ &\sum_{l=1}^k \prod_{j=1}^t P(\mathbf{x}_{t(l)} | \mathbf{x}_j) P(\mathbf{x}_{t(l)} | \mathbf{x}_0) I(y_{(l)} = \omega_s) = \\ &\sum_{l=1}^k \prod_{j=0}^t P(\mathbf{x}_{t(l)} | \mathbf{x}_j) I(y_{(l)} = \omega_s) \end{aligned} \quad (7)$$

最后,最大 $P^*(\omega_s | \mathbf{x}_{0:t})$ 所对应的类别,判定为 $\mathbf{x}_t$ 的类别,即

$$y_t = \arg \max_{\omega_s} P^*(\omega_s | \mathbf{x}_{0:t}) \quad (8)$$

考虑到该方法的识别率与执行时间,在对序列中的某测试样本进行分类时,无需将它之前的所有测样本全部利用,只选取在时间上与它最近的 c 个测试样本。即

$$y_t = \arg \max_{\omega_s} \sum_{l=1}^k \left(\prod_{j=t-c}^t P(\mathbf{x}_{t(l)} | \mathbf{x}_j) \right) I(y_{(l)} = \omega_s) \quad (9)$$

Seung 等人在 2000 年 Science 杂志上的一篇文章中指出^[13],高维的人脸图像在不同的表情、光照、姿态和尺度的变化下会构成一个低维空间的流形。经过对流形学习的研究^[14],发现序列中的各个样本在时间上表现为顺序性,在本质上则表现为特征变化的连续性、缓慢性。通过流形学习,这种时间上的顺序性会在流形上表现为空间上的相邻性。反过来,在流形上相邻的样本点在特征变化上具有缓慢性,这隐含了它们在时间上的顺序性。实际上,非序列样本集可以看成是由许多不同种类,不同序列的样本,杂乱无序排列而得到的。也就是说,它们之间的顺序已被打乱。而通过流形学习,则可以重新将时间上相关的(也就是特征变化上最相关的)样本重新组织在一起。

因此,若测试集 $\{\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_t, \dots\}$ 不是序列样本,在流形空间里根据欧氏距离,找出 $\mathbf{x}_t$ 的 c 个最近邻测试样本,使其参与 $\mathbf{x}_t$ 的分类。此时,式(9)中的 $\{\mathbf{x}_{t-1}, \mathbf{x}_{t-2}, \dots, \mathbf{x}_{t-c}\}$ 就代表 $\mathbf{x}_t$ 在流形空间里的 c 个最近邻测试样本。

总结上述的内容,设 $L = \{(y_i, \mathbf{x}_i), \mathbf{x}_i \in \mathbf{R}^d, i = 1, 2, \dots, n\}$ 是一个由 n 个样本组成的训练集,每个

样本 $\mathbf{x}_i$ 的类别标示 y_i 均为已知, $y_i \in \{\omega_1, \dots, \omega_r\}$ 。测试集为 $T = \{\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_t\}$, 它们的类别待测, 分别表示为 $\{y_0, y_1, \dots, y_t, \dots\}$ 。

半监督 KNN 分类方法的步骤如下:

1) 对于待测样本 $\mathbf{x}_t$ 的分类, 根据明考斯基距离

$$d(\mathbf{x}_t, \mathbf{x}_i) = \left(\sum_{j=1}^d |x_{tj} - x_{ij}|^q \right)^{1/q} \quad (\text{或其他特征加权相似度}),$$

从训练集 L 中, 找出 $\mathbf{x}_t$ 的 $k+1$ 个近邻样本。分别用 $\mathbf{x}_{t(1)}, \mathbf{x}_{t(2)}, \dots, \mathbf{x}_{t(k+1)}$ 表示, 它们的类别标记为 $y_{(1)}, y_{(2)}, \dots, y_{(k+1)}$, 均已知。

2) 如果 $\mathbf{x}_t$ 是某个测试序列中的样本, 从该序列中找出 c 个与它在时间上最近邻的测试样本, 分别用 $\mathbf{x}_{t-1}, \mathbf{x}_{t-2}, \dots, \mathbf{x}_{t-c}$ 表示; 如果 $\mathbf{x}_t$ 是非序列中的样本, 则在流形空间里找出它的 c 个空间最近邻测试样本, 分别用 $\mathbf{x}_{t-1}, \mathbf{x}_{t-2}, \dots, \mathbf{x}_{t-c}$ 表示。

3) 用第 $k+1$ 个近邻样本 $\mathbf{x}_{t(k+1)}$ 到 $\mathbf{x}_t$ 的距离 $d(\mathbf{x}_t, \mathbf{x}_{t(k+1)})$, 标准化这 k 个近邻样本 $\mathbf{x}_{t(1)}, \mathbf{x}_{t(2)}, \mathbf{x}_{t(3)}, \dots, \mathbf{x}_{t(k)}$ 到 $\{\mathbf{x}_j, j=t, t-1, \dots, t-c\}$ 的距离

$$D(\mathbf{x}_j, \mathbf{x}_{t(l)}) = \frac{d(\mathbf{x}_j, \mathbf{x}_{t(l)})}{d(\mathbf{x}_j, \mathbf{x}_{t(k+1)})} \quad (l=1, \dots, k) \quad (10)$$

4) 用加权核函数 $K(\cdot)$, 将标准距离 $D(\mathbf{x}_j, \mathbf{x}_{t(l)})$ 转化为 $\mathbf{x}_j$ 与 $\mathbf{x}_{t(l)}$ 同类的概率 $P(\mathbf{x}_{t(l)} | \mathbf{x}_t)$ 。若 $K(\cdot)$ 采用高斯核函数, 则有

$$P(\mathbf{x}_{t(l)} | \mathbf{x}_j) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{D(\mathbf{x}_j, \mathbf{x}_{t(l)})^2}{2}\right) \quad (11)$$

5) 确定 $\mathbf{x}_t$ 所属的类别 y_t , 即

$$y_t = \arg \max_{\omega_s} \sum_{l=1}^k \left(\prod_{j=t-c}^t P(\mathbf{x}_{t(l)} | \mathbf{x}_j) \right) I(y_{t(l)} = \omega_s) \quad (12)$$

3 实验与分析

分别用加权 KNN (简记为 WKNN) 和提出的半监督 KNN 分类方法 (简记为 SKNN), 在 Cohn-Kanade 人脸库^[15] 和 CMU-AMP 人脸库^[16] 上进行了人脸识别实验 (k 值均取 5, 这为 WKNN 最高识别率所对应的 k 值)。用 Cohn-Kanade 人脸库评估它们对序列样本的分类情况, CMU-AMP 人脸库评估它们对非序列样本的分类情况。

3.1 实验 1

Cohn-Kanade 人脸库共包含 104 个人的表情序列, 每个序列开始于中性表情, 结束于极值表情, 图 2 为 Cohn-Kanade 人脸库中的一些样本。



图 2 Cohn-Kanade 人脸库中的样本

Fig. 2 Samples from Cohn-Kanade face database

从中选取了 16 个对象的 6 种表情序列, 共 96 个序列, 每个序列有 12 幅图像, 共 1152 幅。先用 2 维 Fisher 线性判别分析 (2DFLD)^[17] 和保局投影 (LPP)^[18] 算法, 将所有的图像投影到 11 维的流形空间。然后, 从每个对象的序列中, 随机地取出 2 个作为训练集, 剩余的 4 个序列作为测试集。这样, 训练集共有 32 个序列, 384 个样本。测试集共有 64 个序列, 768 个样本。在对测试序列中的 $\mathbf{x}_t$ 分类时, 分别取 $\mathbf{x}_t$ 前的 $c=0, 1, 2, \dots, 11$ 个测试样本参与分类决策 ($c=0$ 为 WKNN)。更换训练集和测试集, 重复实验 4 次, 图 3 为平均识别率曲线图, 表 1 为部分识别率与消耗时间的精确数据。




图 3 在 Cohn-Kanade 人脸库上 WKNN 与 SKNN 的识别率

Fig. 3 Recognition accuracy of WKNN and SKNN on the Cohn-Kanade database

表 1 在 Cohn-Kanade 人脸库上 WKNN 与 SKNN 的识别率与用时比较

Table 1 Recognition accuracy and running time comparison of WKNN and SKNN on the Cohn-Kanade database

	WKNN	SKNN			
		$c=1$	$c=3$	$c=5$	$c=11$
识别率/%	85.13	86.54	90.31	91.08	89.92
运行时间/s	6.72	7.02	7.56	7.91	9.32

3.2 实验2

CMU-AMP 人脸库由 13 人,每人 75 幅共 975 幅 8 位灰度图像组成,图像的分辨率为 64×64 ,图 4 为 CMU-AMP 人脸库中的一些样本。从该库中取出 10 个人的样本,共 750 幅图像,用局部线性嵌入算法(LLE)^[19]将它们投影到 11 维的流形空间。然后,从每人中随机地取 20 个,共 200 个样本作为训练集,剩余的 55 个,共 550 个样本作为测试集,进行人脸识别实验。在对该测试集中的某样本分类时,分别取它在测试集中的 $c=0,1,2,\dots,54$ 个最近邻样本参与分类决策($c=0$ 时对应于 WKNN)。更换训练集和测试集,实验 5 次,图 5 为它们的平均识别率曲线图,表 2 为部分识别率和消耗时间的精确数据。

3.3 实验分析

实验 1 和实验 2 的数据表明,SKNN 方法的分类正确率会随 c 值的不同发生变化,但都高于 WKNN 方法。实验 1 中,对 768 个样本进行分类,WKNN 的正确率为 85.13%,耗时 6.72 s。SKNN 方法的正确率在 $c=5$ 时达到最大值 91.08%,耗时为 7.02 s。正确率提高了 5.95%,耗时仅增加了 0.32 s。




图 4 CMU-AMP 人脸库中的样本

Fig. 4 Samples from CMU-AMP face database




图 5 在 CMU-AMP 人脸库上 WKNN 与 SKNN 的识别率

Fig. 5 Recognition accuracy of WKNN and SKNN on the CMU-AMP database

表 2 在 CMU-AMP 人脸库上 WKNN 与 SKNN 的识别率与用时比较

Table 2 Recognition accuracy and running time comparison of WKNN and SKNN on the CMU-AMP database

	WKNN	SKNN							
		$c=1$	$c=5$	$c=11$	$c=16$	$c=21$	$c=26$	$c=36$	$c=54$
识别率/%	87.32	90.03	95.3	93.67	92.69	91.82	91.70	91.39	91.18
运行时间/s	5.31	5.82	6.36	6.84	7.21	8.13	9.32	10.45	11.87

实验 2 中,对 550 个样本进行分类,WKNN 的正确率为 69.57%,耗时 22.67 s。SKNN 的正确率在 $c=5$ 时达到最大值 95.3%,耗时 6.36 s。正确率提高了 7.98%,耗时只增加了 1.05 s。

当 c 值超过某个阈值后,分类的正确率不升反降,最终到达一个比较稳定的值。而耗时是随 c 值的增加而不断增加的。因此用 SKNN 方法分类, c 值不宜取得太大。SKNN 识别率最大值所对应的 c 值并不大,此时该算法的耗时并没出现成倍的增长。可见,SKNN 是一种较好的分类方法,具有较好的实际应用前景。

4 结 论

针对加权 KNN 方法的缺陷,提出了半监督

KNN 分类方法。由于它的分类决策既利用了待测样本在训练集中的 k 近邻样本,又利用了待测样本在测试集中的 c 近邻样本,因而使得它的分类决策更为合理,分类的正确率比加权 KNN 要高。实际上,加权 KNN 可以看成是半监督 KNN 算法的一个特例,即当 $c=0$ 时的情况。当然,针对某种具体的样本分类实例,怎样获得最佳的 c 值,从而使分类正确率达到最大值,这仍值得进行一步地研究。

参考文献 (References)

- [1] Yang Y M, Liu X. A re-examination of text categorization methods [C]//Proceedings of the 22nd Annual International ACM SIGIR conference on Research and Development in Information Retrieval. New York, USA: Association for Computing Machinery, 1999: 42-49.

- [2] Li B L, Chen Y Z, Yu S W. A comparative study on automatic categorization methods for Chinese search engine [C] // Proceedings of the 8th Joint International Computer Conference. Hangzhou: Zhejiang University Press, 2002:117-120.
- [3] Cover T M, Hart P E. Nearest neighbor pattern classification [J]. IEEE Transactions on Information Theory, 1967, 13(1): 21-27.
- [4] Duda R O, Hart P E, Stork D G. Pattern Classification [M]. Beijing: China Machine Press, 2006:150-151. [Duda R O, Hart P E, Stork D G. 模式分类 [M]. 李宏东, 姚天翔, 等译. 北京: 机械工业出版社, 2006:150-151.]
- [5] Gora G, Wojna A. A classifier combining rule induction and KNN method with automated selection of optimal neighbourhood [C] // Proceedings of the 13rd European Conference on Machine Learning. London, UK: Springer-Verlag, 2002:111-123.
- [6] Hechenbichler K, Schliep K. Weighted k-nearest-neighbor techniques and ordinal classification, Discussion Paper 399 [R]. Munich, Germany: Ludwig-Maximilians University Munich, 2004.
- [7] Wang B, Yong Z, Yupu Y. Generalized nearest neighbor rule for pattern classification [C] // Proceedings of the 7th World Congress on Intelligent Control and Automation. Washington DC, USA: Institute of Electrical and Electronics Engineers, 2008: 8465-8470.
- [8] Chen Z Z, Li L, Yao Z A. Feature-weighted k-nearest neighbor algorithm with SVM [J]. Acta Scientiarum Naturalium Universitatis Sunyatseni, 2005, 44(1):17-20. [陈振洲, 李磊, 姚正安. 基于 SVM 的特征加权 KNN 算法 [J]. 中山大学学报: 自然科学版, 2005, 44(1): 17-20.]
- [9] Liu M, Yuan B Z, Tang X F. A new approach to determine the similarity parameters in evidence-theoretic K-NN rule [J]. Acta Electronica Sinica. 2005, 33(4):766-768. [刘明, 袁保宗, 唐晓芳. 证据理论 K-NN 规则中确定相似度参数的新方法 [J]. 电子学报, 2005, 33(4): 766-768.]
- [10] Vivencio D P, Hruschka E R, Nicoletti M C, et al. Feature-weighted k-nearest neighbor classifier [C] // The IEEE Symposium on Foundations of Computational Intelligence. Washington DC, USA: IEEE Communications Society, 2007: 481-486.
- [11] Sun Y, Lv S P, Tang Y Y. No previous ordering for KNN algorithm [J]. Journal of Chinese Computer Systems, 2008, 29(4): 682-686. [孙岩, 吕世聘, 唐一源. 无先序条件约束的 KNN 算法 [J]. 小型微型计算机系统, 2008, 29(4): 682-686.]
- [12] Shan C, Gong S, McOwan P W. Dynamic facial expression recognition using a Bayesian temporal manifold mode [C] // Proceedings of British Machine Vision Conference. Edinburgh, UK: British Machine Vision Association, 2006: 297-306.
- [13] Seung H S, Lee D D. The manifold ways of perception [J]. Science, 2000, 290(5500):2268-2269.
- [14] Zhu M H, Luo D Y, Yi L Q, et al. Incremental locally linear embedding algorithm based on orthogonal iteration method [J]. Acta Electronica Sinica, 2009, 37(1):132-136. [朱明早, 罗大庸, 易励群, 等. 基于正交迭代的增量 LLE 算法 [J]. 电子学报, 2009, 37(1):132-136.]
- [15] Kanade T, Cohn J, Tian Y. Comprehensive database for facial expression analysis [C] // Proceeding of the Fourth IEEE International Conference on Automatic Face and Gesture Recognition. Washington DC, USA: IEEE Computer Society, 2000: 46-53.
- [16] Chen T. CMU-AMP face expression database [EB/OL]. (2002-4-18) [2010-3-12]. <http://amp.ece.cmu.edu/projects/FaceAuthentication/>.
- [17] Kong H, Teoh E K, Wang J G. Two dimensional fisher discriminant analysis: forget about small sample size problem [C] // Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing. Washington DC, USA: IEEE Communications Society, 2005:761-764.
- [18] Hei X F, Niyogi P. Locality preserving projections [C] // Proceedings of Advances in Neural Information Processing Systems. Cambridge, MA: MIT Press, 2004:1-8.
- [19] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290:2323-2326.