

DOI:10.11992/tis.201605010

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20170705.1657.010.html>

REM 记忆模型在图像分类识别中的应用

姜英, 王延江

(中国石油大学 信息与控制工程学院, 山东 青岛 266580)

摘要: 尝试将认知心理学中的记忆模型与图像学习识别联系在一起, 研究基于 REM (retrieving effective from memory) 记忆模型的视觉图像存储与识别方法。采用方向梯度直方图 (HOG) 和局部二进模式 (LBP) 生成图像特征向量, 并对每个特征向量中的每一个分量按概率进行复制, 允许错误复制, 最后采用 Bayesian 决策计算被探测图像特征向量与已学习图像集特征向量的平均似然比值, 根据该值判断被探测图像是否已学习过。实验结果表明, 提出的算法不仅对同一个物体的小幅度旋转图像具有很好的识别效果, 同时对同一类别物体图像识别也具有较好的效果, 而且其虚报率远远低于其他识别方法。

关键词: 图像识别; 记忆建模; HOG 特征; LBP 特征; Bayesian 决策

中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2017)03-0310-08

中文引用格式: 姜英, 王延江. REM 记忆模型在图像分类识别中的应用[J]. 智能系统学报, 2017, 12(3): 310-317.

英文引用格式: JIANG Ying, WANG Yanjiang. Application of REM memory model in image recognition and classification[J].

CAAI transactions on intelligent systems, 2017, 12(3): 310-317.

Application of REM memory model in image recognition and classification

JIANG Ying, WANG Yanjiang

(College of Information and Control Engineering, China University of Petroleum, Qingdao 266580, China)

Abstract: We attempt to combine a memory model with image learning and recognition and to research the application of the REM model in image recognition and classification. An image feature vector was obtained by histograms of oriented gradients (HOG) and local binary pattern (LBP) operators; every component of a feature vector was copied with a certain probability, allowing for an error-prone copy of the studied vector. Finally, Bayesian decision theory was applied for calculating the average likelihood ratio between the feature vector of the probe image and that of the studied image set. The value of the ratio was used to decide whether the probe image had been studied. Experimental results demonstrate that the proposed method can gain a good recognition effect not only for the classification of the same object with small rotation angles but also for the recognition of the same category object. Moreover, the false rate is far lower than that of other classification methods.

Keywords: image recognition; memory modeling; HOG feature; LBP feature; Bayesian decision

视觉图像的分类与识别研究是计算机视觉研究、模式识别与机器学习领域内的一个非常活跃的方向, 其在许多领域中应用广泛, 如银行系统的人脸识别、防御系统的行人检测与跟踪、交通系统的车牌检测与车辆跟踪等。近年来, 图像分类^[1]吸引了研究者的注意, 关于视觉图像识别与分类的各种理论与算法层出不穷, 如最近邻分类器^[2]、神经

网络分类器^[3-4]、SVM 支持向量机分类器^[5]、卷积神经网络分类器^[6]、ELM 极限学习机^[7]及稀疏编码方法等。为获得良好的图像分类效果, 研究者们在设计图像分类方法及改进分类准确性方面都做了大量工作。例如, 稀疏编码方法已被证实在图像分类中具有优秀的分类性能, 基于该方法的许多改进的稀疏编码方法也被相继提出, 如 SRC 方法^[8]、CRC 方法^[9]、RSC 方法^[10]及 RLRC 方法^[11]等。尽管现有的许多算法在图像分类方面表现突出, 但目前已有的识别分类算法大多侧重于“区别”, 忽视了“认识”, 即侧重将某一类物体与有限类已学过物体进

收稿日期: 2016-05-13. 网络出版日期: 2017-07-05.

基金项目: 国家自然科学基金项目 (61271407, 61301242); 山东省自然科学基金项目 (ZR2013FQ015); 中央高校基本科研业务费专项资金资助项目 (14CX06066A).

通信作者: 王延江. E-mail: yjwang@upc.edu.cn.

行区分。然而人类认识事物的过程侧重于对某一类物体与无限类未知物体的区分,只在细小之处重视“区别”(如区别桌子与椅子或者鱼与海豚等)。对于首次遇到的从未学习过的物体,传统的模式识别方法会将其归类于某一个已学习的类别。但是同样情况下,人类对首次遇到的新物体的直接反应是从未见或者不认识该物体,而不是直接判断其属于哪一类已经学习过的物体。众所周知,计算机视觉研究的主要目标是使计算机能像人类一样轻易地识别视觉图像。神经生理学、心理学以及认知科学研究表明^[12-13],人类能够轻易地将目标从周围环境中识别出来与人类记忆机制有着非常密切的联系。人们所看到的和所经历的都要经过记忆系统的处理。当认知新的事物时,与该事物相关的记忆信息就会被提取出来,从而加快认知的过程并适应新的环境。然而,在人脑记忆过程中信息是如何被加工、存储和提取的仍然不得而知。Murdock^[14]认为现代人脑记忆建模理论至少要解释4个问题:信息是如何被表达、被存储与提取的信息的种类,存储与提取运算的本质以及信息存储的格式。围绕这些问题研究人员提出了包括情景记忆、语义记忆以及神经计算在内的记忆建模理论。Raaijmakers等^[15]提出了SAM模型,所存储的信息用“记忆影像”表达,能解释记忆研究中的列表强度效应、列表长度效应以及近因效应等,但无法解释镜像效应;Hintzman等^[16]提出的MINERVA 2模型首次将情景记忆与语义记忆联合用于提取建模,没有考虑列表强度效应以及镜像效应;Shiffrin等^[17]提出的REM记忆模型,采用Bayesian理论计算线索与记忆影像的似然度,用于匹配搜索。上述情景记忆模型均假设识别判断是在整体匹配相似度强度的基础上完成的,其中REM记忆模型的突出性不仅因为其坚实的数学基础,也源于其可以解释情景记忆研究中出现的许多现象,如列表长度、列表强度与词汇频率效应等。REM模型对情景记忆研究中的列表强度效应、列表长度效应、词汇频率效应以及镜面效应与正态ROC斜率效应的解释不仅吸引了众多研究人员对REM模型的进一步研究^[18-21],也引起了我们的思考——能否将记忆模型应用于图像识别分类中。目前大多数记忆模型均采用词汇列表的学习方式,对自然图像的学习和分类研究得很少,因此本文尝试将REM模型引入视觉图像的存储与识别,并提出一种基于REM记忆模型的视觉图像的学习、存储与提取方法。

1 图像特征表达

图像特征提取在视觉图像学习过程中起着非常关键的作用。近几年来,许多特征提取算法被陆续提出并被应用于物体识别、如方向梯度直方图(HOG)等^[22]、局部二值模式(LBP)^[23]、尺度不变特征转换(SIFT)^[24]、加速鲁棒特征(SURF)^[25]等。其中HOG算子能很好地描述局部目标的表现与形状,LBP算子具有灰度尺度不变性和旋转不变性,本文将这两种算子同时应用于图像特征提取以描述图像的形状与纹理特征。

1.1 HOG 特征

方向梯度直方图(histogram of oriented gradient, HOG)特征是由N.Dalal等^[22]提出的一种物体特征描述子,其通过计算和统计图像局部区域的梯度方向直方图来构成特征。HOG特征提取算法的具体实现过程如图1所示。

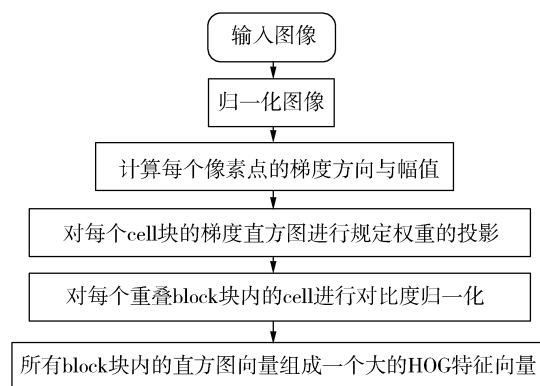


图1 HOG 特征提取算法流程

Fig.1 The flow chart of HOG algorithm

1.2 LBP 特征

局部二值模式(LBP)是由T.Ojala、M.Pietikäinen和D. Harwood提出的一种灰度尺度不变性和旋转不变性的纹理算子^[23]。原始LBP算子不能满足不同尺寸和频率纹理的需要,研究人员对其进行各种改进与优化,如半径为 R 的圆形区域内含有 P 个采样点的LBP算子及LBP旋转不变算子^[26]。T. Ojala^[27]定义了一个等价模式,模式数量减少为种,特征向量维数更少,减少了高频噪声带来的影响。

本文采用的LBP特征提取算法过程如下:

1)对图像中的每一个像素点,定义圆形邻域窗口,每个像素的灰度值与其相邻的8个像素的灰度值比较,若周围像素值大于中心像素值,则该像素点的

位置被标记为 1, 否则为 0。这样可产生 8 位二进制数, 即得到该窗口中心像素点的初始 LBP 值。

2) 不断旋转圆形邻域得到一系列初始定义的 LBP 值, 取最小值作为该像素点的 LBP 值。

3) 统计 LBP 值对应的二进制数从 0~1 或 1~0 跳变的次数, 根据跳变次数确定其属于哪一种 LBP 模式, 共有 $P+1=9$ 种模式, 得到的模式数值即为像素点的 LBP 值。

4) 图像中所有像素点的 LBP 值组合起来形成一个 LBP 特征矩阵, 即为该图像的 LBP 特征。

2 REM 模型在视觉图像的表达、存储与提取中的应用

认知记忆的快速提取模型——REM 模型是 Shiffrin 等^[17] 1997 年提出的一个用于识别单词的记忆模型, 该模型采用 Bayesian 理论计算线索与记忆影像的似然度, 用于匹配搜索。该模型能够解释许多情景记忆研究中的一些科学现象, 如列表强度效应、列表长度效应、词汇频率效应、镜面效应与正态 ROC 斜率效应; 其与 SAM、MINERVA2 模型的主要区别之一在于, 其实现了似然率的贝叶斯计算, 是国际上公认的最好的记忆模型之一。

REM 记忆模型被提出之后, 研究人员陆续对 REM 模型进行研究。Stams 等^[18] 通过对编码与提取过程中的项目强度的控制, 对比研究了 REM 模型与 BCDMEM 模型对提取过程中项目强度对误报率降低的解释说明。Cox 等^[19] 在 REM 与 RCA-REM 模型基础上提出一个新认知记忆模型, 证实了即使在任务、学习因素、刺激及其他因子变化情况下, 所提方法都有可能获得合理的认知决策。Criss 等^[20] 对比了 REM 模型与 SLiM (the subjective likelihood model) 模型, 发现 REM 模型预测的误报率较高; M. Montenegro 等^[21] 研究了 REM 模型的解析表达式, 文中引入 Fourier 变换, 给出 REM 模型的 FT 积分方程, 导出在给定参数值下模型预测的命中率与误报率的双积分形式的解析表达式, 同时发现其具有与 BCDMEM 模型相同的一些性质; 模型是不确定的, 除非其中的一个参数固定为一个预设值, 向量长度参数是不可忽略的参数。

2.1 特征表达与存储

REM 模型指出人脑记忆由图像构成, 每幅图像是由一个特征值向量表示的, 并且最终存储结果是对

特征值向量的一个不完整且容易出错的复制。本文试图借鉴 REM 模型对单词的存储学习过程来模拟人脑对图像的学习过程, 有概率地对图像的特征向量进行复制, 同时在复制过程中允许出现错误值。

从图像库中选取图像, 提取图像 LBP 与 HOG 特征, 将其分别写成行向量形式并连接起来生成图像特征向量。HOG 特征是由小数组成的, 并不是非负整数, 为方便 REM 模型的计算, 在实验中简单地对该特征扩大 10 倍并四舍五入。每学习一次图像特征向量, 对于那些还没有存储任何信息的位置, 存储新信息的概率为 u^* 。注意到, 一旦某个值被存储, 之后该值不会改变。如果对某个特征有存储, 其特征值从已学向量中正确复制的概率是 c , 以 $1-c$ 的概率根据 $P[V=j]=(1-g)^{j-1}g, j=1, 2, \dots, \infty$ 随机取值, 并允许偶然选取正确值的可能性。

用 $V=\{V_j\}_{j=1,2,\dots,N}$ 标记所有已学习图像的特征集, 其中 V_j 表示已学习图像集合中第 j 副图像 I_j 的特征向量, N 为已学习图像集合中的图像个数。

2.2 提取

给定要检测的图像 I_{test} , 将其特征向量 V_{test} 与 $V=\{V_j\}_{j=1,2,\dots,N}$ 进行匹配, 匹配结果为 $D=\{D_j\}_{j=1,2,\dots,N}$, 其中 D_j 为被检测图像特征与第 j 个视觉图像特征的匹配结果。用 s 图像表示与被检测图像相同的存储图像, d 图像表示除被检测图像之外的其他视觉图像的存储图像。

被检测图像 I_{test} 与第 j 幅已存储图像 I_j 的匹配过程的关键步骤是, 计算似然率 λ_j , 即在观测结果 D_j 基础上第 j 幅图像为 s 图像与 d 图像的概率比值:

$$\lambda_j = \frac{P(D_j | S_j)}{P(D_j | N_j)} = (1-c)^{n_{jq}} \prod_{k \in M} \frac{c + (1-c)g(1-g)^{V_{kj}-1}}{g(1-g)^{V_{kj}-1}} \quad (1)$$

式中: S_j 为第 j 副图像为 s 图像的事件; N_j 为第 j 副图像为 d 图像的事件; M 为非零特征值与被检测向量特征值匹配的目录; V_{kj} 为第 j 副图像中第 k 个特征值; n_{jq} 为 V_j 与 V_{test} 不匹配的非零特征值个数; g 为几何分布参数。

2.3 Bayesian 决策

给定探测图像 I_{test} , 将其与所有已学习图像 $I=\{I_j\}_{j=1,2,\dots,N}$ 进行匹配与不匹配比较, 计算对应的似然值 $\lambda=\{\lambda_1, \lambda_2, \dots, \lambda_N\}$, 进而得到被检测图像为旧的而非新的概率为

$$\phi = \frac{P(O|D)}{P(N|D)} = \frac{\frac{P(O)P(D|O)}{P(D)}}{\frac{P(N)P(D|N)}} = \frac{P(D|O)}{P(D|N)} = \frac{P(D)}{P(N)}$$

$$\sum_{j=1}^N \frac{P(D|S_j)P(S_j)}{P(D|N)} = \sum_{j=1}^N \frac{1}{N} \frac{P(D|S_j)}{P(D|N)} =$$

$$\frac{1}{N} \sum_{j=1}^N \frac{P(D_j|S_j) \prod_{i \neq j} P(D_i|N_i)}{P(D_j|N_j) \prod_{i \neq j} P(D_i|N_i)} =$$

$$\frac{1}{N} \sum_{j=1}^N \frac{P(D_j|S_j)}{P(D_j|N_j)} = \frac{1}{N} \lambda_j$$

若 $\phi > 1$, 那么认为被检测的图像为已学习的图像, 同时认为该图像匹配最大 λ_j 值对应第 j 幅图像; 反之认为被检测图像是新的, 从未学习过。

如果被检测图像是已学习过图像的极小变化如旋转之后的图像, 由于当前图像特征向量的提取技术限制, 被检测图像与对应的已学习过图像的特征向量中部分特征值并不一致。而原 REM 模型中的复制过程亦会导致不一致特征值的个数增加, 计算似然率时会有很多 $1-c$ 项相乘, 使得 $\lambda \ll 1$, 故本文忽略了该复制过程。同时, 由于所提取的特征值包含 LBP 特征, 而 LBP 特征向量中值为 8 对应的是像素不变区域, 故同时忽略特征值为 0 与 8 的区域。我们用图 2 简单地解释该记忆模型过程, 其中参数采用 $g = 0.4, c = 0.7$ 。

已学习图像特征向量	1 0 6 8 4 5 3	2 7 0 1 5 3 0
被检测图像特征向量	1 0 4 8 4 5 3	
匹配结果	1m 0 6q 8 4m 5m 3m	2q 7q 0 1q 5m 3q 0
每个特征的概率	1.45 1.0 3 1.4 1.7 6.49 2.78	0.3 0.3 1 0.3 6.49 0.3 1
似然率 λ	$\lambda_1 = 11.77$	$\lambda_2 = 0.18$
概率	$\phi = (\lambda_1 + \lambda_2) / 2 = 5.98$	
判决	$\phi > 1$, 故回应“旧”, 且与第 1 幅图像匹配	

图 2 改进的图像特征存储提取数值例子

Fig.2 An improved numerical example for the storage and retrieval of the image feature

3 实验结果

为验证本文所提方法的有效性, 在 Matlab 编程环境下, 先后对哥伦比亚大学 Coil-20 图像数据库^[28]与加州福尼亚理工大学 Caltech-256 数据库^[29]中的图像进行实验测试。

3.1 Coil-20 数据库实验结果

Coil-20 数据库由 20 个不同对象的旋转图像构成, 每个对象在水平方向上旋转 360° , 并每隔 5° 拍摄一张照片, 故每个项目有 72 幅图像, 每幅图像的像素为 128×128 。

从 Coil-20 图像数据库中选取已学习图像, 本文选择了 15 个不同项目的图像, 构成图 3 所示已学习图像集。图 3 中大写英文字母 (A~O) 分别代表不同项目图像的序号。


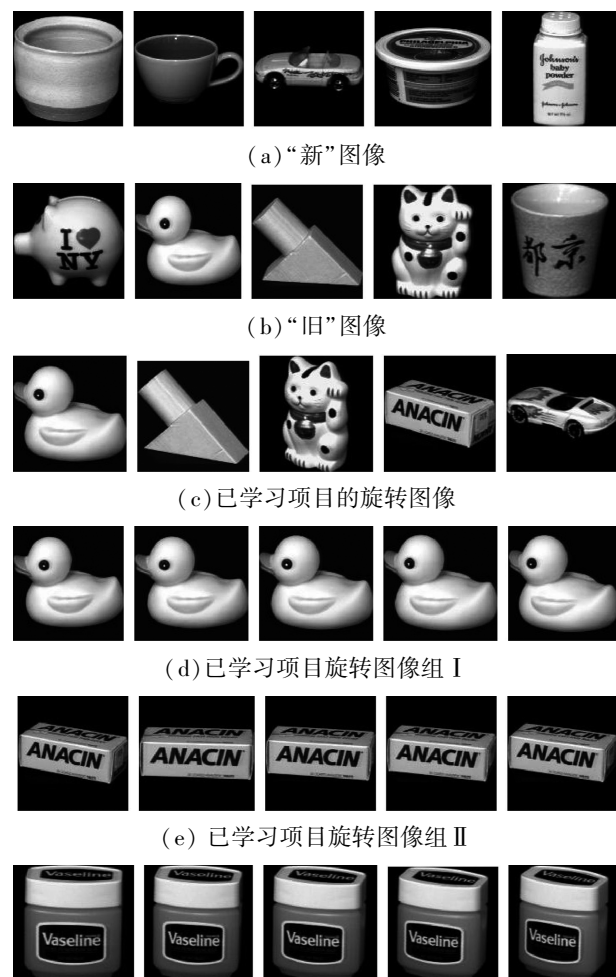


图 3 已学习图像集

Fig.3 The studied images set

接着从数据库中选取被测试图像, 被测试图像根据实验需要选取图 4 所示几组图像。



(f) 已学习项目旋转图像组 III

图 4 被测试图像集

Fig.4 The probe images set

由于特征向量维数比原 REM 模型中单词特征维数大得多,计算似然率过程中会出现多个 $1-c$ 项相乘,导致 $\lambda \ll 1$,最终会影响到识别效果,故将 ϕ 值扩大到 10^{100} 倍。表1是利用本文所提算法对6组实验图像运行得到的识别结果。

表1 Coil-20 数据库实验结果

Table 1 The experimental result on the Coil-20 database

图像组	第 1 幅	第 2 幅	第 3 幅	第 4 幅	第 5 幅					
(a)	新	✓	新	✓	新	✓				
(b)	(AL)	✓	(BA)	✓	(DB)	✓	(KD)	✓	(KL)	✓
(c)	(A)	✓	(B)	✓	新	×	新	×	新	×
(d)	(A)	✓	(A)	✓	(A)	✓	(A)	✓	(A)	✓
(e)	(E)	✓	(E)	✓	(E)	✓	新	×	新	×
(f)	(I)	✓	(I)	✓	(I)	✓	(I)	✓	新	×

表1中大写字母代表测试图像对应的已学习图像序号,“✓”说明识别正确,“×”说明判别错误。很显然,图像组(a)、(b)识别效果不错;图像组(c)由5副已学习项目的旋转图像组成,只有2副图像被正确识别为已学习图像,即图像发生旋转时识别效果变差。通过对图像组(d)、(e)、(f)的测试实验发现,随着图像旋转角度增加,算法识别率降低。导致识别效果不理想的原因在于,尽管采用的 LBP 算子具有旋转不变性,但是当旋转角度超过一定范围之后算子不能很好地刻画图像特征。

3.2 Caltech-256 数据库实验结果

Caltech-256 数据库来自加利福尼亚理工学院,该数据库共有 29 780 副图像,包含了 256 个不同图像项目类别,每个图像类别包含不少于 80 幅属于该类别的不同图像,这些图像属于同一类,但并不是完全相同的项目,实验选择的已学习图像列表如图5所示。




图5 Caltech-256 数据库中已学习图像集

Fig.5 The studied images set on the Caltech-256 database

从数据库中选取 20 副被测试图像,包含 10 副已学习过类别的图像与 10 副新类别的图像,如图6所示。



图6 Caltech-256 数据库中被检测图像集

Fig.6 The probe images set on the Caltech-256 database

利用本文所提算法并将 LBP 特征值扩大两倍, ϕ 值扩大 10^{75} 倍的实验结果由表2给出。

表2 Caltech-256 数据库实验结果

Table 2 The result on the Caltech-256 database

图像	结论	图像	结论
1	(a) ✓	11	新 ✓
2	新 ×	12	新 ✓
3	新 ×	13	新 ✓
4	(j) ✓	14	新 ✓
5	(g) ✓	15	新 ✓
6	(c) ✓	16	新 ✓
7	新 ×	17	新 ✓
8	(d) ✓	18	新 ✓
9	(i) ✓	19	新 ✓
10	新 ×	20	新 ✓

对于前 10 副“旧”的图像,其中有 7 副图像被正确识别出来,其余 3 副图像被错误地判断为“新”,后 10 副图像都被正确地判断为“新”。该实验说明,本文所提的基于 REM 记忆模型的图像识别算法不止对同一个物体的识别有效,也为同一类物体的识别方法给出了一个新思路。

3.2.1 实验参数对识别率的影响

为说明 ϕ 值和 LBP 特征向量的倍数变化对 Caltech-256 数据库实验结果的影响,本文采用多组 ϕ 值和 LBP 变化数据进行实验,实验结果如图7。

图7分别描述了在不同 ϕ 值和 LBP 特征倍数情况下的图像击中率 P_H 、虚报率 P_F 、识别率与 ROC 曲线。3 种曲线分别代表 ϕ 值扩大 10^{50} 、 10^{72} 、 10^{100} 倍之后的实验结果。不论 ϕ 值被扩大多少倍,随着 LBP 特征倍数的增加,击中率都在增加,但同时虚报率也在增加。当 LBP 倍数为 2 时,识别率取得最大值,即不论 ϕ 值被扩大多少倍,LBP 特征被扩大 2 倍时图像识别率都最高。很明显, ϕ 值被扩大 10^{100} 倍时的识别率较其他情况的识别率低,其余两种情

况下的识别率相近。观察 3 个实验的 ROC 曲线下的面积(AUC)进行比较,很明显 ϕ 值被扩大 10^{75} 倍时 ROC 曲线下的面积最大,即实验准确性最佳。当

LBP 特征值被扩大两倍且 ϕ 值扩大 10^{75} 倍时,实验识别效果达到最佳。

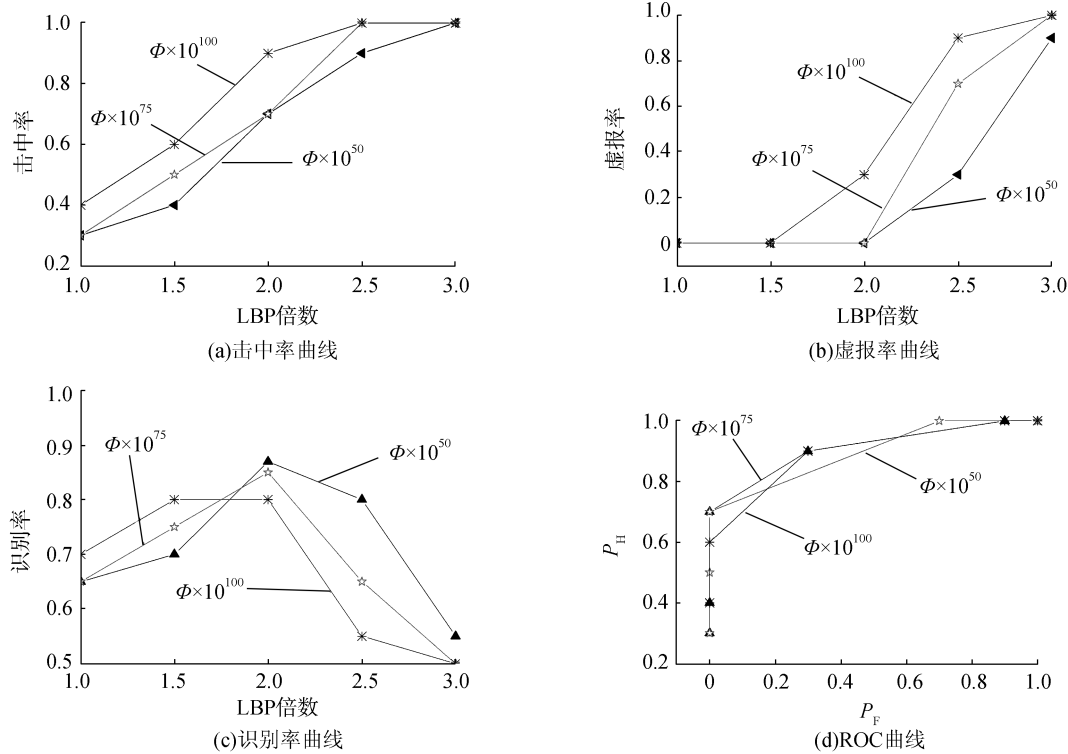


图 7 不同 ϕ 值与 LBP 倍数变化下的实验曲线

Fig.7 The hit and false rate curve under the varying value of ϕ and LBP

3.2.2 与 SRC 算法的实验性能对比

实验采用的 SRC 算法^[8]描述如下:所有已学习图像特征向量被标记为 X ,对每一个探测图像特征向量记为 Y ,求解如下最优问题:

$$\min_H \|Y - XH\|_2^2 \quad (3)$$

然后计算 $F = \|Y - X_i H_i\|_2^2, i = 1, 2, \dots$,并搜索最小值 F_{\min} 。给定阈值 λ ,若 $F_{\min} > \lambda$,那么该被探测图像被认为是新的;若 $F_{\min} \leq \lambda$,则反馈结果为已学过的,并且与 F_{\min} 对应的图像匹配。

从表 3 中可以看出,SRC 算法在 $\lambda = 290$ 时的击中率 P_H 与本文算法相同,但是其虚报率 P_F 高达 7/10,远高于本文算法的虚报率。

表 3 本文方法与 SRC 算法在 Caltech-256 数据库实验对比
Table 3 Performance comparison between the proposed method and the SRC method on the Caltech-256 database

实验方法	P_H	P_F
本文方法	7/10	0/10
SRC($\lambda = 270$)	5/10	2/10
SRC($\lambda = 280$)	6/10	3/10
SRC($\lambda = 290$)	7/10	7/10

3.2.3 与支持向量机(SVM)算法的实验性能对比

为进一步说明所提方法的有效性,对比了本文所提算法与支持向量机(SVM)算法在 Caltech-256 数据库上的识别分类性能。实验中选取图 5 所示的训练图像,即分别属于 10 个不同类别的 10 幅图像。对测试图像集,选取 20 个不同类别(10 个已学习类别与 10 个新类别)的 100 幅图像,每个类别分别选取 5 幅图像,实验参数选取 $c = 0.3, g = 0.4$,实验结果如表 4 所示。

表 4 本文方法与 SVM 算法在 Caltech-256 数据库实验对比
Table 4 Performance comparison between the proposed method and the SVM method on the Caltech-256 database

实验方法	P_H	P_F
本文方法	68	0
SVM	64	100

很明显,对已学习过的类别,本文算法有着很好的识别率,并且对从未学习过的类别的虚报率为 0,即拒识率达到 100%,而 SVM 算法的虚报率高达 100%。

4 结束语

在人脑认知记忆模型启发下将图像学习识别与 REM 模型结合在一起,验证了 REM 记忆模型可以用于自然图像的存储与提取。实验结果证实了,所提方法能够实现在小幅度旋转情况下的简单图像的识别任务与简单类别图像的分类任务。同时与 SRC、SVM 算法的实验对比结果说明,本文方法的虚报率远低于 SRC 与 SVM 方法。但由于现有特征提取方法限制,及 REM 模型本身对特征表达采用非负整数的这种要求均限制了图像分类识别率。因此如何对大范围旋转变换图像提取恰当的特征向量改进图像特征表达,同时改进 REM 模型的特征表达存储方法,以提高图像识别率是下一步的研究重点。

参考文献:

- [1] XU Y, ZHANG B, ZHONG Z. Multiple representations and sparse representation for image classification[J]. Pattern recognition letters, 2015, 68: 9–14.
- [2] HELLMAN M E. The nearest neighbor classification rule with a reject option[J]. IEEE transactions on systems science and cybernetics, 1970, 6(3): 179–185.
- [3] DENOUEUX T. A neural network classifier based on Dempster-Shafer theory[J]. IEEE transactions on systems man and cybernetics-Part A systems and humans, 2010, 30(2): 131–150.
- [4] DAVTALAB R, DEZFOULIAN M H, MANSOORIZADEH M. Multi-level fuzzy min-max neural network classifier[J]. IEEE transactions on neural networks and learning systems, 2014, 25(3): 470–482.
- [5] CHANG C C, LIN C J. LIBSVM: a library for support vector machines[J]. ACM transactions on intelligent systems and technology, 2011, 2(3): 389–396.
- [6] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer science, 2014.
- [7] HUANG G B. What are extreme learning machines? Filling the gap between Frank Rosenblatt's dream and John von Neumann's puzzle[J]. Cognitive computation, 2015, 7(3): 263–278.
- [8] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation[J]. IEEE transactions on pattern analysis and machine intelligence, 2008, 31(2): 210–227.
- [9] ZHANG L, YANG M, FENG X. Sparse representation or collaborative representation: Which helps face recognition[C]//International Conference on Computer Vision, 2011: 471–478.
- [10] YANG M, ZHANG L, YANG J, ZHANG D. Robust sparse coding for face recognition[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2011, 42(7): 625–632.
- [11] SCHOLKOPF B, PLATT J, HOFMANN T. Sparse representation for signal classification[J]. Advances in neural information processing systems, 2007, 19: 609–616.
- [12] WANG Y. Formal description of the cognitive process of memorization[M]//Transactions on Computational Science V. Springer Berlin Heidelberg, 2009: 81–98.
- [13] WANG Y, CHIEW V. On the cognitive process of human problem solving[J]. Cognitive systems research, 2010, 11(1): 81–92.
- [14] MURDOCK B B. A theory of the storage and retrieval of item and associative information[J]. Psychological review, 1982, 89(6): 609–626.
- [15] RAAIJMAKERS J G W, SHIFFRIN R M. SAM: a theory of probabilistic search of associative memory[J]. Psychology of learning and motivation, 1980, 14: 207–262.
- [16] HINTZMAN D L. Judgments of frequency and recognition memory in a multiple-trace model[J]. Psychological review, 1988, 95(4): 528–551.
- [17] SHIFFRIN R M, STEYVERS M. A model for recognition memory: REM-retrieving effectively from memory[J]. Psychonomic bulletin and review, 1997, 4(2): 145–166.
- [18] STARN J J, WHITE C N, RATCLIFF R. A direct test of the differentiation mechanism: REM, BCDMEM, and the strength-based mirror effect in recognition memory[J]. Journal of memory and language, 2010, 63(1): 18–34.
- [19] COX G E, SHIFFRIN R M. Criterion Setting and the dynamics of recognition memory[J]. Topics in cognitive science, 2012, 4(1): 135–150.
- [20] CRISS A H, MCCLELLAND J L. Differentiating the differentiation models: a comparison of the retrieving effectively from memory model (REM) and the subjective likelihood model (SLiM)[J]. Journal of memory and language, 2006, 55(4): 447–460.
- [21] MONTENEGRO M, MYUNG J I, PITT M A. Analytical expressions for the REM model of recognition memory[J]. Journal of mathematical psychology, 2014, 60(3): 23–28.
- [22] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]//Computer Vision and Pattern Recognition. IEEE Computer Society Conference, on, 2005: 886–893.

- [23] OJALA T, HARWOOD I. A Comparative study of texture measures with classification based on feature distributions [J]. Pattern recognition, 1996, 29(1): 51-59.
- [24] LOWE D G. Distinctive image features from scale-invariant keypoints [J]. International journal of computer vision, 2004, 60(2): 91-110.
- [25] BAY H, TUYTELAARS T, VAN GOOL L. SURF: speeded up robust features [J]. Computer vision and image understanding, 2006, 110(3): 404-417.
- [26] PIETIKAINEN M, OJALA T, XU Z. Rotation-invariant texture classification using feature distributions [J]. Pattern recognition, 2000, 33(1): 43-52.
- [27] OJALA T, PIETIKAINEN, MAENPAA T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns [J]. IEEE transactions on pattern analysis and machine intelligence, 2002, 24(7): 971-987.
- [28] NENE A S, NAYAR S K, MURASE H. Columbia object image library (COIL-20) [R]. CUCS-005-96, 1996.
- [29] GRIFFIN G, HOLUB A, PERONA P. Caltech-256 object category dataset [R]. Pasadena: California Institute of Technology, 2007.

作者简介:



姜英,女,1985年生,博士研究生,主要研究方向为计算机视觉、认知记忆建模。



王延江,男,1966年生,教授,博士生导师,主要研究方向为模式识别与智能信息处理、人脑记忆计算建模以及人脑结构与功能网络连接分析。主持多项国家自然科学基金项目、山东省自然科学基金项目,发表学术论文100余篇,其中被SCI/EI检索40余篇。

2017 第 13 届中国智能系统会议 The Chinese Intelligent Systems Conference (CISC)

中国智能系统会议是由中国人工智能学会智能空天系统专业委员会发起的系列学术会议,其宗旨是为本领域的专家学者、研究生以及工程技术人员提供一个学术交流的平台,以推动我国智能系统相关理论、技术与应用的发展。第13届中国智能系统会议(CISC'2017)将于2017年10月14-15日在黑龙江省牡丹江市召开。本次会议由中国人工智能学会主办,中国人工智能学会智能主天系统专业委员会协办,牡丹江师范学院与北京航空航天大学承办。会议论文集将由Springer出版社在Lecture Notes in Electrical Engineering系列正式出版,EI收录。热忱欢迎海内外广大同仁踊跃投稿并出席本届会议,交流学术成果。

主办单位:中国人工智能学会

协办单位:中国人工智能学会智能主天系统专业委员会

承办单位:牡丹江师范大学、北京航空航天大学

会议主席:贾英民,北京航空航天大学、杨敬民,牡丹江师范学院

征文范围:

S01 多智能体系统

S02 网络控制

S03 智能机器人

S04 复杂系统与群集行为

S05 事件与数据驱动控制

S06 拟人系统与人工生命

S07 鲁棒与自适应控制

S08 大数据与脑科学

S09 过程控制

S10 非线性与变结构控制

S11 智能传感器与检测技术

S12 嵌入式系统与无线传感网络

S13 智能交通与控制

S14 预测与学习控制

S15 信息获取与信息融合

S16 飞行器导航、靠IJ导与控制

S17 混杂与离散事件系统

S18 智能制造与云制造

S19 高超声速飞行器控制

S20 电力系统及其自动化

S21 模糊系统与神经网络

S22 航天智能发射系统

S23 其他

会议网站: <http://sias.buaa.edu.cn/info/1007/1132.htm>