

基于低秩表征学习的图像记忆性预测模型

褚晶辉, 顾慧敏*, 苏育挺

天津大学电气自动化与信息工程学院, 天津 300072

摘要 图像记忆性预测包含两个核心问题: 特征表征与预测模型。当前对图像记忆性预测的研究多聚焦于探索对其有影响的视觉因素, 预测过程采用特征处理与预测相分离的方式, 这使预测性能很大程度上受前期特征处理的制约, 如果整个预测过程缺少整体性的学习机理, 可能会产生次优的预测结果。为解决上述问题, 提出了一种基于低秩表征学习的图像记忆性预测模型, 将低秩表征学习和线性回归整合到一个框架下。低秩表征学习将原始的特征矩阵映射到具有低秩约束的潜在子空间中, 以学习到本征稳健的特征表征; 线性回归学习了一个回归系数从而建立图像特征表征和记忆性分数之间的联系。基于增广拉格朗日乘子法求解以保证模型的收敛性, 大量实验结果表明本文方法的优越性。

关键词 图像处理; 图像记忆性; 低秩表征; 线性回归; 增广拉格朗日乘子法

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP55.071002

Image Memorability Prediction Model Based on Low-Rank Representation Learning

Chu Jinghui, Gu Huimin, Su Yuting

School of Electronics and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract Image memorability prediction involves two problems, feature representation and prediction model. Most of previous researches just focused on addressing the first problem by investigating the factors making an image memorable, and conducted feature fusion and regression learning in two separate steps. Results of feature fusion decide the performance of regression. Lack of using an integrated learning mechanism cannot efficiently address image memorability prediction tasks, since it may lead to sub-optimal prediction results. To solve the problem presented above, we introduce a novel image memorability prediction model based on low-rank representation learning. We seek the lowest-rank representation among all the samples by projecting the original feature matrix into a subspace spanned by a low-rank projection matrix. Meanwhile, we learn a regression coefficient to build connections between latent low-rank representations and memorability scores by linear regression. Furthermore, we develop an effective algorithm based on the augmented Lagrange multiplier method to solve our model. Extensive experiments conducted on publicly available image memorability datasets demonstrate the effectiveness of the proposed schemes.

Key words image processing; image memorability; low-rank representation; linear regression; augmented Lagrange multiplier method

OCIS codes 100.5010; 100.3008; 110.2960

1 引言

随着社交网络的快速发展和移动设备的普及,

图像越来越多地出现在我们的生活中。在成千上万的图像中, 一些图像能在脑海中存留很长时间, 而一些图像很快就会被遗忘。基于这种现象提出了图像

收稿日期: 2017-11-30; **收到修改稿日期:** 2017-12-17

基金项目: 国家自然科学基金(61572356)

作者简介: 褚晶辉(1969—), 女, 博士, 副教授, 硕士生导师, 主要从事图像处理、数字视频技术、模式识别方面的研究。

E-mail: cjh@tju.edu.cn

* **通信联系人.** E-mail: sherryghm@tju.edu.cn

记忆性的概念,以衡量一张图像在被浏览后能被记住的程度。因在图像处理、计算机视觉、用户界面设计等领域中的应用需求,图像记忆性成为了新兴热门研究方向。

近年来一些研究表明记忆性是图像的内在属性^[1]。通过观察可以发现,记忆性分数相似的图像包含的图像信息具有趋同性。比如,含有人物或突出物体的图像的记忆性相对较高,而描述自然风光等相对平和画面的图像的记忆性比较低,这表明图像记忆性在一定程度上可以通过其内容本身进行推断测量。目前的研究内容主要分为两个方向。1)探索能够影响图像记忆性的视觉因素,发掘图像特征与图像记忆性的潜在关系或通过学习的方式获取具有更强表征能力的图像特征集以提高图像记忆性预测性能。例如,当前研究表明图像的高级语义特征与图像记忆性存在更强的相关性^[2-3],包括目标类别、场景类别、情感种类和人物属性等。文献[3]基于信息论提出了一种新的特征选择模型并应用到图像记忆性预测任务中。文献[4]建立了一个大型的图像记忆性数据库 LaMem,并通过卷积神经网络对图像进行场景分类,将分类结果作为一种深度特征对图像记忆性进行预测。2)从模型的角度出发,针对不同的场景需求,设计更加稳健的预测模型以实现图像记忆性的自动预测,目前这方面的研究相对较少。文献[5]提出了一种多视图环境下的自适应回归模型,将多视角特征的融合和图像记忆性的预测统一到一个框架中。文献[6]提出了一种基于自适应迁移学习的图像记忆性预测模型,利用外部数据库提供的先验信息学习一组弱属性分类器,以进一步提高图像记忆性的预测性能。为取得较好的预测结果,通常会提取多种特征来描述图像。现有研究主要是对所有特征采用串联的方式,不仅造成信息冗余,而且容易受到“维数灾难”的影响,所以要考虑更有效的特征表示形式。此外,目前研究中用到的大部分预测模型较为简单,且与特征处理阶段分离进行,使整个预测过程缺少整体性的学习机理,不能很好地处理噪声干扰。为解决以上问题,本文从模型角度出发,结合低秩表征在数据全局结构探索中的优势,将低秩表征学习和回归预测整合到一个框架下,利用特征间的相关性和冗余性训练得到图像记忆性预测模型,以提高预测准确性。

2 低秩表征

低秩表征^[7]将数据分解为低秩部分与稀疏部

分,其对噪声的稳健性受到广大学者的关注并被广泛应用于机器学习、机器视觉、图像处理等诸多领域,可以解决人脸识别^[8]、图像重构^[9]、目标跟踪^[10]、图像分类^[11]、子空间分割^[12]等问题。

低秩表征由压缩感知理论^[13]衍生而来,将信号的稀疏性推广到矩阵的低秩性,并利用矩阵内部结构增强对噪声的稳健性。给定一个训练数据集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbf{R}^{D \times N}$,其中 N 代表样本个数, D 代表特征维数。低秩表征的核心是构造一个字典 \mathbf{G} ,为数据矩阵 \mathbf{X} 寻找一个基于 \mathbf{G} 的最低秩线性组合解,即最低秩表示系数矩阵 \mathbf{A} ,使得 $\mathbf{X} = \mathbf{GA}$ 。为了简化模型,一般会采用数据矩阵本身作为构造字典,在此情况下得到的数据最低秩表示系数矩阵 \mathbf{A} 可以有效地反映数据之间的相关性,揭示数据样本的低秩结构。低秩表征的基本模型可以表示为

$$\min_{\mathbf{A}, \mathbf{E}} \|\mathbf{A}\|_* + \beta \|\mathbf{E}\|_1, \text{ s.t. } \mathbf{X} = \mathbf{XA} + \mathbf{E}, \quad (1)$$

式中: \mathbf{E} 为稀疏的噪声部分; $\lambda > 0$ 为平衡参数; $\|\cdot\|_*$ 为核范数,代表矩阵奇异值的总和; $\|\cdot\|_1$ 为矩阵 l_1 范数,对噪声数据进行规则化。

3 基于低秩表征的图像记忆性预测模型

根据已有研究可知,为取得较好的预测结果,人们往往会提取多种特征来描述图像,但大部分情况下无法保证提取的图像特征之间完全不相关,因为很多特征是互相关联的或共生的。比如一副图像中有了发色等与人类有关的属性特征,是否有人这一信息也已经被包含。特征冗余会增加模型复杂度,降低模型预测准确性。鉴于低秩表征探究数据间相关性的优势,本文将其运用于图像记忆性预测研究中,提出了一种基于低秩表征的图像记忆性预测模型。该模型使特征表征与回归预测两个阶段的学习能够在同一框架下进行,进而提高预测结果的准确性。本文模型如图 1 所示,图中蓝色箭头代表训练过程,红色箭头代表预测过程。

为使低秩表征能更好地应用于回归学习中,本文方法做了一些改进。传统的低秩表征模型训练得到的矩阵 $\mathbf{A} \in \mathbf{R}^{N \times N}$ 探究的是给定样本间的相关性,由此训练得到的低秩矩阵不适用于新的测试样本。为解决该问题,将低秩表征表达式中的 $\mathbf{X} = \mathbf{XA} + \mathbf{E}$ 变为 $\mathbf{X} = \mathbf{AX} + \mathbf{E}$,再对 $\mathbf{A} \in \mathbf{R}^{D \times D}$ 进行低秩约束,可将原始的特征矩阵映射到具有低秩约束的潜在子空间中,揭示图像特征间本质存在的相关性而非样本间的结构信息。改进后的低秩表征不仅适用于测试样本,也可以利用相关性和低秩约束来去除特征冗

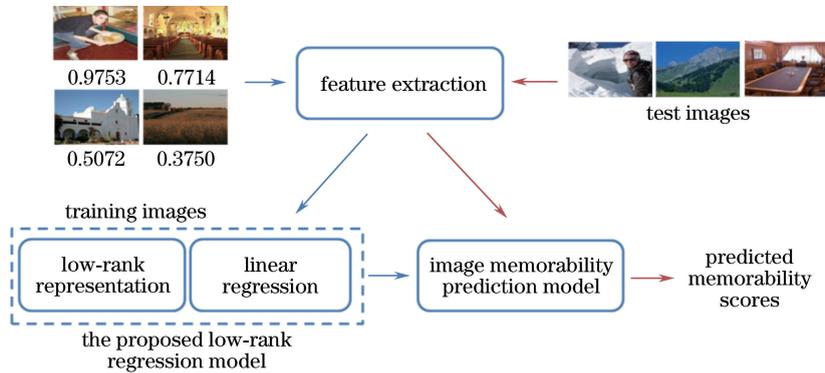


图1 本文模型示意图

Fig. 1 Illustration of the proposed model

余,此时模型表示为

$$\min_{\mathbf{A}, \mathbf{E}} \|\mathbf{A}\|_* + \beta \|\mathbf{E}\|_1, \text{ s.t. } \mathbf{X} = \mathbf{A}\mathbf{X} + \mathbf{E}, \quad (2)$$

式中: $\mathbf{A} \in \mathbf{R}^{D \times D}$ 代表低秩投影矩阵; $\mathbf{E} \in \mathbf{R}^{D \times N}$ 为稀疏噪声矩阵。

线性回归是一种典型的回归分析方法,常用于预测学习问题。给定 N 个图像样本集构成的特征矩阵 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbf{R}^{D \times N}$ 和对应记忆性分数向量 $\mathbf{y} = [y_1, y_2, \dots, y_N] \in \mathbf{R}^N$, 其中 D 代表图像特征维数。由线性回归模型可以得到图像特征与图像记忆性之间的系数向量 \mathbf{w} :

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} \|\mathbf{y} - \mathbf{X}^T \mathbf{w}\|_2^2, \quad (3)$$

式中: $\|\cdot\|_2$ 为向量 l_2 范数,表示向量绝对值的平方和的开方。

为了建立低秩表征和回归模型之间的关系,利用低秩投影后的特征映射矩阵 $\mathbf{A}\mathbf{X}$ 代替原来的样本

\mathbf{X} 代入回归模型的目标函数中,使回归模型的研究对象由原始图像特征矩阵变为低秩投影后的特征映射矩阵 $\mathbf{A}\mathbf{X}$, 采用一个新的回归系数向量 \mathbf{b} 表示特征映射矩阵和图像记忆性之间的关系。将低秩表征和回归模型的目标函数联合起来,最后得到目标函数:

$$\min_{\mathbf{A}, \mathbf{b}, \mathbf{E}} \|\mathbf{y} - \mathbf{X}^T \mathbf{A}^T \mathbf{b}\|_2^2 + \alpha \|\mathbf{A}\|_* + \beta \|\mathbf{E}\|_1, \text{ s.t. } \mathbf{X} = \mathbf{A}\mathbf{X} + \mathbf{E}. \quad (4)$$

目标函数将低秩表征学习和线性回归整合到一个框架下,两个阶段的学习不是相互独立的,会在学习过程中相互影响相互约束:结合回归学习,低秩表征会将图像记忆性没有影响的特征看作“噪声”,从而使特征表示更为“干净”,而更为“干净”的特征表示使回归模型在防止过拟合的同时可以提高预测准确度。算法的整体流程如图2所示。

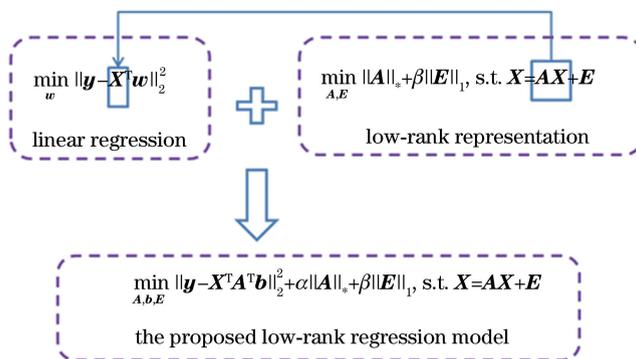


图2 算法的整体原理图

Fig. 2 Overall principle of the proposed algorithm

对目标函数采用基于拉格朗日乘子法的线性交替方向法^[14-15]进行求解,使得算法能够快速收敛并得到理想的结果。具体步骤如下。

引入 $\mathbf{w} = \mathbf{A}^T \mathbf{b}$, 使得目标函数变为

$$\min_{\mathbf{A}, \mathbf{b}, \mathbf{E}, \mathbf{w}} \|\mathbf{y} - \mathbf{X}^T \mathbf{w}\|_2^2 + \alpha \|\mathbf{A}\|_* +$$

$$\beta \|\mathbf{E}\|_1, \text{ s.t. } \mathbf{X} = \mathbf{A}\mathbf{X} + \mathbf{E}, \mathbf{w} = \mathbf{A}^T \mathbf{b}. \quad (5)$$

引入 $\mathbf{Y}_1, \mathbf{Y}_2$ 两个拉格朗日乘子矩阵得到增广拉格朗日乘子式:

$$L(\mathbf{A}, \mathbf{b}, \mathbf{E}, \mathbf{w}, \mathbf{Y}_1, \mathbf{Y}_2, \mu) = \|\mathbf{y} - \mathbf{X}^T \mathbf{w}\|_2^2 + \alpha \|\mathbf{A}\|_* + \beta \|\mathbf{E}\|_1 + \langle \mathbf{Y}_1, \mathbf{X} - \mathbf{A}\mathbf{X} - \mathbf{E} \rangle +$$

$$\langle \mathbf{Y}_2, \mathbf{w} - \mathbf{A}^T \mathbf{b} \rangle + \frac{\mu}{2} (\|\mathbf{X} - \mathbf{A}\mathbf{X} - \mathbf{E}\|_F^2 + \|\mathbf{w} - \mathbf{A}^T \mathbf{b}\|_2^2), \quad (6)$$

式中： μ 为惩罚参数； $\langle \cdot \rangle$ 为矩阵内积算子。

采用固定其余变量的迭代法求解上述增广拉格朗日乘子式，迭代式为

$$\mathbf{A}_{k+1} = \arg \min_{\mathbf{A}} \alpha \|\mathbf{A}\|_* + \frac{\eta_1 \mu}{2} \left\| \mathbf{A} - \mathbf{A}_k + \left[\left(\mathbf{A}_k \mathbf{X} - \mathbf{X} + \mathbf{E}_k - \frac{\mathbf{Y}_{1,k}}{\mu} \right) \mathbf{X}^T + \mathbf{b}_i \left(\mathbf{b}_i^T \mathbf{A}_k - \mathbf{w}_k^T - \frac{\mathbf{Y}_{2,k}}{\mu} \right) \right] / \eta_1 \right\|_F^2, \quad (7)$$

$$\mathbf{E}_{k+1} = \arg \min_{\mathbf{E}} \frac{\beta}{\mu} \|\mathbf{E}\|_1 + \frac{1}{2} \left\| \mathbf{E} - \left(\mathbf{X} - \mathbf{A}_{k+1} \mathbf{X} + \frac{\mathbf{Y}_{1,k}}{\mu} \right) \right\|_F^2, \quad (8)$$

$$\mathbf{w}_{k+1} = \arg \min_{\mathbf{w}} \left\| \mathbf{w} - \mathbf{w}_k + \left[(-\mathbf{X}) \sqrt{\frac{2}{\mu}} (\mathbf{y} - \mathbf{X}^T \mathbf{w}_k) + \left(\mathbf{w}_k - \mathbf{A}_{k+1}^T \mathbf{b}_k + \frac{\mathbf{Y}_{2,k}}{\mu} \right) \right] / \eta_2 \right\|_2^2, \quad (9)$$

$$\mathbf{b}_{k+1} = \arg \min_{\mathbf{b}} \left\| \mathbf{A}_{k+1} \mathbf{b} - \mathbf{w}_{k+1} - \frac{\mathbf{Y}_{2,k}}{\mu} \right\|_2^2, \quad (10)$$

式中： k 为迭代次数； $\eta_1 = \|\mathbf{X}\|_F^2$ ， $\eta_2 = 2/\mu \|\mathbf{X}\|_F^2$ 为辅助参数。

在预测阶段，利用训练得到的低秩投影矩阵 \mathbf{A} 和关系向量 \mathbf{b} 预测样本的记忆性，图像记忆性预测公式为

$$\mathbf{y} = \mathbf{x}^T \mathbf{A}^T \mathbf{b}, \quad (11)$$

式中： $\mathbf{x} \in \mathbf{R}^D$ 是图像的特征向量； \mathbf{y} 是图像对应的记忆性分数。

4 实验与结果分析

4.1 实验数据及设置

使用的实验数据为文献[3]中构建的数据库，作者从 SUN 数据库^[16] 中选取 2222 张图像，通过 ATM (Amazon Mechanical Turk) 平台上的视觉记忆游戏得到图像的记忆性分数。数据库图像样例如图 3 所示，图像下方为其对应的记忆性分数。实验中用图像的三类属性特征进行预测，分别为标签属性特征 (127 维)、物体属性特征 (256 维) 和场景属性特征 (540 维)。其中物体属性特征和场景属性特征通过 LabelMe^[17] 标注，描述图片所含物体类别和所属场景类别信息；标签属性特征是作者自定义的一些与美观性、情感、空间布局等相关的语义属性。实验采用三倍交叉验证方法，将数据库随机等分为 3 份，2 份作为训练集，1 份作为测试集进行实验。根据经验设置参数为 $\alpha=10$ ， $\beta=1$ ，求解过程中的惩罚参数和迭代次数分别设置为 $\mu=0.1$ ， $k=15$ 。

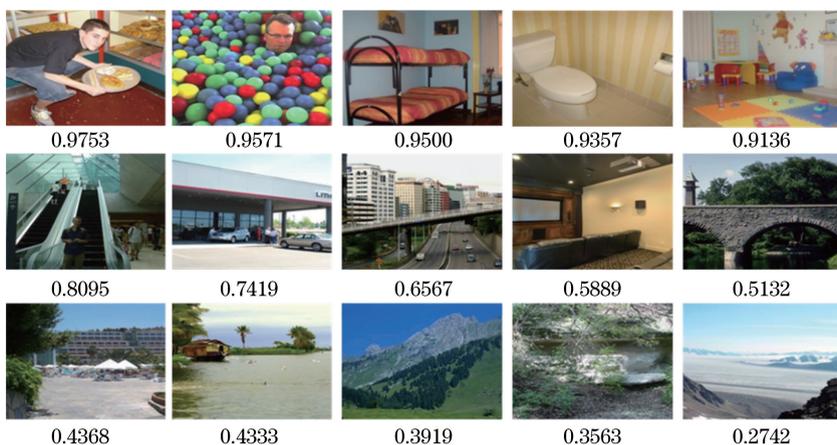


图 3 数据库中具有不同记忆性分数的样本图像

Fig. 3 Sample images with various memorability scores selected from the dataset

4.2 评估方法

斯皮尔曼等级相关系数评估方法：将测试集图像分别按照实际分数和预测分数排序，采用排序相关的斯皮尔曼等级相关系数的标准来衡量两种排序之间的相关系数，相关系数的取值范围是 $-1 \sim 1$ ，值越高代表两种排序越接近。斯皮尔曼等级相关系数计算公式为

$$\rho(r_1, r_2) = 1 - \frac{6 \sum_{i=1}^M (r_{1i} - r_{2i})^2}{M(M^2 - 1)}, \quad (12)$$

式中： M 是图像个数； r_1 中的元素 r_{1i} 是第 i 张图片在实际分数下排序的位置； r_2 中的元素 r_{2i} 是第 i 张图片在预测结果中排序的位置。

4.3 结果分析

4.3.1 算法收敛性

本文算法采用基于增广拉格朗日乘子法的线性交替方向法进行求解,为证明算法可行性及求解方法合理性,以某一变量在迭代前后的绝对差值为参考值验证其收敛性。为体现算法整体性能,在参数 α 取不同值时验证算法收敛性,收敛结果如图4所示。从图中可以看出,参数 α 的取值会适当影响算法收敛性,但整体收敛趋势大致相同,变量的绝对差值随着迭代次数的增加快速递减,并且在大约12次后收敛。所以在后续实验中,设置迭代次数 $k=15$ 。参数 β 取值对收敛性影响差异量级很小,可视为没有影响,收敛曲线也在12次后平稳。

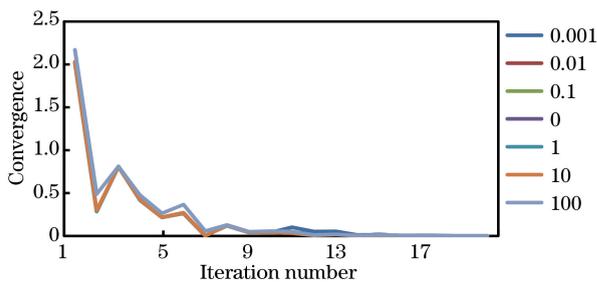


图4 参数 α 取不同值时算法收敛性曲线图

Fig. 4 Convergence curves of the proposed algorithm for different α

4.3.2 参数对比实验

经实验发现目标函数中的平衡参数 α 的取值对预测结果的影响比较大,当 $\beta=1$ 时,取不同 α 值并观察其影响。实验中 α 的取值范围为 $0\sim 100$,实验对比结果如图5所示。从图中可以看出, $\alpha=10$ 时能取得最好的预测结果,当 α 增加到100时预测性

能降低,当 $\alpha=0$ 时相当于忽略了目标函数中的低秩约束,预测结果也变差,这证明了低秩表征学习在模型中的重要性。

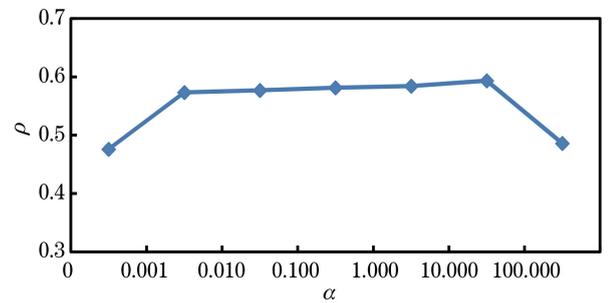


图5 不同 α 取值对本文算法预测性能的影响

Fig. 5 Influence of α on the performance of the proposed algorithm

4.3.3 与其他算法的对比

为证明本文预测模型的性能,利用相同的数据库和图像特征将本文方法与其他方法进行比较。除斯皮尔曼等级相关系数评估方法外,选取在真实记忆性分数排序下的前20、100、200张图像和后20、100、200张图像,计算这些图像对应的预测分数的平均值以检验整体预测趋势。当模型性能较好时,原先记忆性分数较高的一组图像在预测后分数依然整体较高,反之亦然。对比结果如表1所示。采用的对比算法有线性回归(LR)、支持向量回归(SVR)^[18]、岭回归(RR)^[19]、Lasso回归、多阶回归(MRR)^[20]及多特征融合分层回归(MLHR)^[21]。从比较结果可以看出,相较于其他回归方法和文献[3]中基于信息理论的回归模型的实验结果 $\rho=0.554$,本文提出的预测模型预测效果更好。

表1 不同算法的预测性能对比

Table 1 Performance comparison of different algorithms

Item	LR	SVR	RR	Lasso	MRR	MLHR	Proposed
Top 20	0.8613	0.7842	0.8274	0.8752	0.8785	0.8883	0.8752
Top 100	0.8287	0.7815	0.8136	0.8003	0.8440	0.8126	0.8320
Top 200	0.7925	0.7832	0.7964	0.7589	0.8110	0.7727	0.8023
Bottom 200	0.5998	0.5976	0.6036	0.5798	0.6006	0.5791	0.5902
Bottom 100	0.5483	0.5695	0.5774	0.5555	0.5800	0.5396	0.5483
Bottom 20	0.5261	0.5631	0.5224	0.5189	0.5584	0.5078	0.5212
ρ	0.5257	0.5310	0.5263	0.5493	0.5757	0.5816	0.5936

4.3.4 子数据集下的预测性能

提取三类图像属性特征,即标签属性特征、物体属性特征和场景属性特征。每一类特征在预测中发挥的作用不同。不同特征在预测模型中的性能如图6所示。造成这种现象的原因在于不同类型图像包含的信息有区别。比如在包含人的图像中,与人相

关的标签属性特征较多且与图像记忆性更相关,而风景图像包含的场景信息更多,所以对记忆性产生影响的也多为场景属性特征。实验中用到的数据库图像中包含人的图像和室内图像更多,室外风景图相对较少,所以相比于其他两个特征,场景属性特征预测性能较差。从数据库中挑选图片构成4个子数

数据集,分别是人脸图像数据集、建筑图像数据集、室内图像数据集和室外风景图像数据集,每个数据集所含的图像个数分别为 100、70、110 和 89,对子数据集图像记忆性进行预测,实验结果如图 6 所示。在不同数据集下,某一类属性特征对图像记忆性影响更大,其余特征可视为“干扰噪声”特征。从结果中可以看出即使在有“干扰噪声”特征的情况下本文提出的预测模型依然表现出不错的性能,能够利用特征间相关性进行特征选择并去除冗余特征,因而在实际应用中具有一定优势。

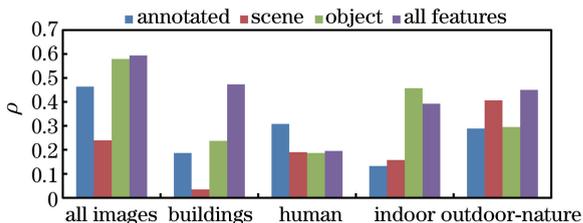


图 6 不同图像子数据集上的预测性能对比

Fig. 6 Comparison of the performance in predicting image memorability within different image subsets

5 结 论

针对目前关于图像记忆性预测模型研究较少的现状及研究中遇到的挑战,提出了一种基于低秩表征学习的图像记忆性预测模型,将低秩表征学习和线性回归整合到一个框架下。该框架利用低秩表征挖掘特征的相关性,学习更本征稳健的特征表征,结合线性回归以得到预测模型。采用基于增广拉格朗日乘子法的线性交替方向法对提出的模型进行求解。在公开的图像可记忆性数据集上的实验结果表明,模型能够在多特征融合的情况下通过特征间的相关性选择有用信息,去除冗余信息,提高预测准确性。

参 考 文 献

- [1] Isola P, Xiao J, Torralba A, *et al.* What makes an image memorable? [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2011: 145-152.
- [2] Chen C Y, Han J W, Hu X T, *et al.* Image memorability model based on visual saliency entropy and Object Bank feature[J]. Journal of Computer Applications, 2013, 33(11): 3176-3178.
陈长远, 韩军伟, 胡新韬, 等. 基于视觉显著熵与 Object Bank 特征的图像记忆性模型[J]. 计算机应用, 2013, 33(11): 3176-3178.

- [3] Isola P, Parikh D, Torralba A, *et al.* Understanding the intrinsic memorability of images [C]. International Conference on Neural Information Processing Systems, 2011: 2429-2437.
- [4] Khosla A, Raju A S, Torralba A, *et al.* Understanding and predicting image memorability at a large scale[C]. IEEE International Conference on Computer Vision, 2015: 2390-2398.
- [5] Peng H, Li K, Li B, *et al.* Predicting image memorability by multi-view adaptive regression[C]. International Conference on Multimedia, 2015: 1147-1150.
- [6] Jing P, Su Y, Nie L, *et al.* Predicting image memorability through adaptive transfer learning from external sources [J]. IEEE Transactions on Multimedia, 2017, 19(5): 1050-1062.
- [7] Xue Z X, Yu X C, Tan X, *et al.* Local hypergraph Laplacian regularized low-rank representation for noise reduction of hyperspectral images [J]. Acta Optica Sinica, 2017, 37(5): 0510001.
薛志祥, 余旭初, 谭熊, 等. 局部超图拉普拉斯约束的高光谱影像低秩表示去噪方法[J]. 光学学报, 2017, 37(5): 0510001.
- [8] Ma L, Wang C, Xiao B, *et al.* Sparse representation for face recognition based on discriminative low-rank dictionary learning [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2012: 2586-2593.
- [9] Weng J W, Tan S Y. Imaging resolution of self-interference incoherent digital holographic system[J]. Chinese Journal of Lasers, 2016, 43(6): 0609006.
翁嘉文, 谭穗妍. 自干涉非相干全息成像系统分辨率[J]. 中国激光, 2016, 43(6): 0609006.
- [10] Liu F, Liu P Y, Li B, *et al.* Deep learning model design of video target tracking based on TensorFlow platform [J]. Laser & Optoelectronics Progress, 2017, 54(9): 091501.
刘帆, 刘鹏远, 李兵, 等. TensorFlow 平台下的视频目标跟踪深度学习模型设计[J]. 激光与光电子学进展, 2017, 54(9): 091501.
- [11] Li J, Chang H, Yang J. Learning discriminative low-rank representation for image classification [C]. International Joint Conference on Neural Networks, 2014: 313-318.
- [12] Liu G C, Lin Z C, Yan S C, *et al.* Robust recovery of subspace structures by low-rank representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 171-184.

- [13] Lian Q S, Xia C C. Compressed sensing of color images based on local Gaussian model in the dual-tree complex wavelet [J]. *Laser & Optoelectronics Progress*, 2011, 48(10): 101001.
练秋生, 夏长城. 基于双树复数小波局部高斯模型的彩色图像压缩感知[J]. *激光与光电子学进展*, 2011, 48(10): 101001.
- [14] Lin Z, Liu R, Su Z. Linearized alternating direction method with adaptive penalty for low-rank representation[J]. *Advances in Neural Information Processing Systems*, 2011: 612-620.
- [15] Hou Y Q, Jin M Y, He X W, *et al.* Fluorescence molecular tomography using a stochastic variant of alternating direction method of multipliers[J]. *Acta Optica Sinica*, 2017, 37(7): 0717001.
侯榆青, 金明阳, 贺小伟, 等. 基于随机变量交替方向乘法法的荧光分子断层成像[J]. *光学学报*, 2017, 37(7): 0717001.
- [16] Xiao J, Hays J, Ehinger K A, *et al.* SUN database: Large-scale scene recognition from abbey to zoo[C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2010: 3485-3492.
- [17] Russell B C, Torralba A, Murphy K P, *et al.* LabelMe: A database and web-based tool for image annotation [J]. *International Journal of Computer Vision*, 2008, 77: 157-173.
- [18] Chong W, Sha Y Z, Xing H Y, *et al.* A new correction algorithm for diffuse irradiance measured with rotating shadow-band pyranometer based on support vector regression [J]. *Acta Optica Sinica*, 2012, 32(1): 0112001.
崇伟, 沙奕卓, 行鸿彦, 等. 一种基于支持向量机回归的旋转遮光带日射表散射辐照度修正新算法[J]. *光学学报*, 2012, 32(1): 0112001.
- [19] Lu Y, Dhillon P S, Foster D, *et al.* Faster ridge regression via the subsampled randomized hadamard transform [C]. *International Conference on Neural Information Processing Systems*, 2013: 369-377.
- [20] Hou C, Nie F, Yi D, *et al.* Efficient image classification via multiple rank regression [J]. *IEEE Transactions on Image Processing*, 2013, 22(1): 340-352.
- [21] Yang Y, Song J, Huang Z, *et al.* Multi-feature fusion via hierarchical regression for multimedia analysis [J]. *IEEE Transactions on Multimedia*, 2013, 15(3): 572-581.