

## 基于超图的多模态关联特征处理方法

罗永恩<sup>a,b</sup>, 胡继承<sup>a,b</sup>, 徐 茜<sup>a</sup>

(武汉大学 a. 计算机学院; b. 软件工程国家重点实验室, 武汉 430072)

**摘 要:** 传统的模式识别方法认为特征是相互独立的, 容易忽略多模态特征之间多元的关联性, 从而造成识别的误差。为此, 基于超图模型, 提出一种新的特征整合方法。定义共享熵的计算方法用以表示多个特征之间的关联程度, 以每个特征作为顶点, 特征之间的多元关系作为超边。对形成的超图, 定义模块度函数取代传统的切边数, 作为衡量超图的社团特性强弱的指标, 应用超图分割算法, 对原始的多模态特征进行聚类划分。在划分集合上采用多分类 Boosting 方法, 形成最终的强分类器。实验结果表明, 与线性支持向量机、多核学习等当前流行的特征融合方法相比, 该方法能有效提高识别准确率。

**关键词:** 超图; 多模态特征; 共享熵; 模块度; 分类器

**中文引用格式:** 罗永恩, 胡继承, 徐 茜. 基于超图的多模态关联特征处理方法[J]. 计算机工程, 2017, 43(1): 226-230.

**英文引用格式:** Luo Yong'en, Hu Jicheng, Xu Qian. Multimodal Correlation Feature Processing Method Based on Hypergraph[J]. Computer Engineering, 2017, 43(1): 226-230.

## Multimodal Correlation Feature Processing Method Based on Hypergraph

LUO Yong'en<sup>a,b</sup>, HU Jicheng<sup>a,b</sup>, XU Qian<sup>a</sup>

(a. School of Computer; b. State Key Lab of Software Engineering, Wuhan University, Wuhan 430072, China)

**【Abstract】** Features are usually considered as independent of each other in traditional pattern recognition methods. The neglect of the correlation among multimodal features is part of the reason for recognition error. Aiming at integrating multimodal features, this paper presents a hypergraph framework. Under hypergraph model, this paper defines a new measure called shared entropy to capture the multivariate correlation among the multimodal features. Each feature is abstracted as a vertex, and if the value of shared entropy reaches the threshold, a hyperedge can be built. Then, the hypergraph is clustered into a set of partitions using the modularity instead of cut-edges to measure the community degree of sub-hypergraphs. Finally, combining the weak classifiers learned from each partition, a multiclass Boosting method is used to form the last strong classifier. Experimental results show that this method can improve the recognition accuracy effectively compared with the current popular methods such as linear Support Vector Machine (SVM) and Multiple Kernel Learning (MKL).

**【Key words】** hypergraph; multimodal feature; shared entropy; modularity; classifier

**DOI:** 10.3969/j.issn.1000-3428.2017.01.039

### 0 概述

每个物体都有描述其本身属性的多维特征, 在这些多维特征的共同作用下, 才能有效判断该物体所属的种类。如果只根据颜色特征, 不能区分梨子和香蕉。同理, 只根据形状, 也不能辨别出苹果和梨子的差别。但是如果将颜色特征和形状特征结合起来, 就能很简单地发现上述水果的差异。很多研究者从这种思想出发, 探索多模态特征的融合方法,

并将其应用于模式识别中, 用以提高识别的准确率。相比传统的单模态特征处理方法, 多模态特征无疑具有更多的可以用于类别区分的信息。如果能将不同形态的多模态特征有效地融合在一起, 将会带来识别准确度的大幅提高。

文献[1]提出了一种动态分类器选择算法, 将每一个多模态特征视为一个子分类器, 动态选择识别准确度最高的子分类器作为最终的识别结果。文献[2]改进了上述方法, 提出可以通过一些分类器合

**基金项目:** 国际科技合作项目(2013DFA12460)。

**作者简介:** 罗永恩(1990—), 男, 硕士, 主研方向为模式识别、超图划分; 胡继承, 教授、博士后; 徐 茜, 硕士。

**收稿日期:** 2016-01-04 **修回日期:** 2016-02-22 **E-mail:** 651977032@qq.com

并策略综合考虑子分类器的识别结果。文献[3]提出了一个通过调整多模态特征的协方差矩阵, 选择对应多模态特征的方法。在多核学习 (Multiple Kernel Learning, MKL)<sup>[4]</sup>方法中, 综合考虑每个多模态特征的核函数, 将它们按一定方式结合起来作为最终的分类策略。但是上述方法都是将每个多模态特征单独进行考虑, 而忽略了多模态特征之间的相互联系和关联性。为了解决这个问题, 文献[5]提出了一个多模态特征分组方法, 先将特征分为不同的组, 再在支持向量机 (Support Vector Machine, SVM)<sup>[6]</sup>的核空间上将属于同一组的特征整合在一起。虽然这个方法提高了识别的准确率, 但是它需要提前定义支持向量机的核函数, 这在一定程度上影响了准确率的进一步提高, 也缺乏分类识别灵活性。并且该方法只考虑了多模态特征两两之间的二元关系, 而无法表示实际多模态特征间的多对多关系。

超图<sup>[7]</sup>是图的拓展, 其区别在于超图的一条边可以连接 2 个或以上的顶点, 称作超边。超图模型已经被广泛应用于图片检索<sup>[8]</sup>以及视频分割<sup>[9]</sup>等领域, 已经被证明是很好的多元关系的建模和处理方法。而传统的超图划分都是以寻找最小切边数作为超图分割的目标的<sup>[10]</sup>, 这种方法存在 2 个明显的缺陷: 1) 在切分之前必须先确定分组数目, 最小切边数是建立在固定分组数的基础上的最优, 这就导致只有预先确定分组数目或者通过分组数的多轮递增迭代才能应用这种方法; 2) 切边数只能表示出不同分组之间的关联程度, 而不能反映每个组的内部紧密度。文献[11-12]采用了转化为图模型的图相似社团发现 (Community Learning by Graph Approximation, CLGA) 算法, 但也需要分组数目的多轮迭代划分才能获得较好的识别率。

基于此, 本文提出一种基于超图模型的多模态关联特征的处理方法。用超边代替特征间的多元关系, 采用一种共享熵的计算方法用以度量关联关系的强弱。在进行特征分组即超图划分的过程中, 给出一种模块度的计算方法, 作为衡量超图的社团特性强弱的指标, 使得超图的划分可以在不指定聚类数目的前提下自动进行, 切分的目的始终是为了寻找最大的模块度。根据分组结果形成的子图矩阵, 为每个分组构建子分类器。结合每个子分类器, 采用多分类 Boosting 方法<sup>[13]</sup>, 形成最终的强分类器。

### 1 超图建模

特征之间多元关联关系的建模是多模态特征融合很重要的一部分。但是不管是单向量模式<sup>[14]</sup>, 还是传统的图模型, 都不能准确地反映多模

态特征之间复杂的多元关系。超图是图的拓展, 是一种可以建立多顶点之间联系的一种数学模型  $G = \{V, E\}$ , 包括顶点和超边 2 种结构, 超边是顶点超边集合, 一条超边可以包括多个顶点, 一个顶点可以隶属多个超边, 超图结构如图 1 所示。在这种超边和顶点的结构下, 用顶点表示每个多模态特征, 用超边将有关联关系的特征集合在一起, 这样多模态特征之间的多元关系就可以用超图模拟出来。另外, 用超边表示的关系还可以赋予权重属性, 用来表示特征之间的紧密程度, 因此, 合理地量化多模态特征之间的关联程度, 也是超图建模的关键组成部分。




图 1 超图示例

#### 1.1 共享熵

本文提供一种共享熵的计算方法, 用来量化多模态特征之间的关联程度。对于给定的多模态特征  $X_1, X_2, \dots, X_m$  ( $m \geq 2$ ), 文献[15]定义了它们的联合熵为:

$$J(X_1, X_2, \dots, X_m) = - \sum_{X_1, X_2, \dots, X_m} P(X_1, X_2, \dots, X_m) \cdot \text{lb}P(X_1, X_2, \dots, X_m) \quad (1)$$

其中,  $P(X_1, X_2, \dots, X_m)$  是多模态特征值  $X_1, X_2, \dots, X_m$  的联合概率分布。基于联合熵, 考虑共享熵的定义如下:

$$S(X_1, X_2, \dots, X_m) = (-1)^0 \sum_{i=1}^m J(X_i) + (-1)^1 \cdot \sum_{1 \leq i < j \leq m} J(X_i, X_j) + \dots + (-1)^{m-1} J_{1,2,\dots,m} \quad (2)$$

当  $m = 1$  时, 多模态特征的共享熵等于其熵的值; 当  $m = 2$  时, 这 2 个多模态特征的共享熵的值就是其信息增益<sup>[16]</sup>。多模态特征之间的共享熵越大, 其关联性越强。在图 2 中, 用每个圆环代表一个多模态特征, 共享熵即是这些圆环重叠的地方。




图 2 特征之间的共享熵关系示例

### 1.2 超图建模方法

以多模态特征为顶点,在关联度较强的特征之间建立超边,为了避免超大边的出现,定义超图:

$$G = \{V, E, w, \sigma_m, \sigma_s\} \quad (3)$$

其中,  $\sigma_m$  表示一条超边内最多允许的顶点数目;  $\sigma_s$  是共享熵的阈值。考虑数目不大于  $\sigma_m$  的所有顶点之间的可能组合,求出每个组合的共享熵,保留共享熵的值大于  $\sigma_s$  的组合,在这些剩余的组合里面,贪心地寻找顶点数更多的组合构建超边,如果一个组合内的所有顶点已经隶属于某一条超边,那么跳过该组合。如图 2 所示,如果  $S(X_1, X_2, X_3)$  已经构建了一条超边,那么忽略  $S(X_1, X_2)$ ,  $S(X_1, X_3)$  和  $S(X_2, X_3)$  的组合。只有在  $S(X_1, X_2, \dots, X_n) > \sigma_s$  的情况下,才有可能在  $X_1, X_2, \dots, X_n$  上建立一条超边  $e$ , 超边权重为:

$$d(e) = S(X_1, X_2, \dots, X_n) \quad (4)$$

对于  $\sigma_m$ , 需要计算  $\sum_{i=2}^{\sigma_m} C_m^i$  次共享熵才能得到最终结果,当  $\sigma_m$  较大时,这是一个很大的计算量。考虑共享熵的计算特点,如果  $S(X_1, X_2, \dots, X_n) > \sigma_s$ , 那么必有  $S(X_1, X_2, \dots, X_{n-1}) > \sigma_s$ , 利用动态规划的思想降低计算的复杂度。如图 2 所示,只有  $S(X_1, X_2)$ ,  $S(X_1, X_3)$  和  $S(X_2, X_3)$  都大于  $\sigma_m$  的时候,才考虑构建 3 顶点超边  $S(X_1, X_2, X_3)$ 。在这种情况下每一轮迭代形成的组合数目和  $\sigma_s$  有关,对于给定的  $\sigma_s$ , 每一轮的组合数目和  $m$  正相关,因此,该建模方法的时间复杂度为  $O(m^3 \sigma_m^2)$ 。




图 3 不同分割情况下模块度的变化

### 2.2 分类器

超图划分的结果用矩阵  $P \in \{0, 1\}^{m \times \gamma}$  表示,其中,  $\gamma$  是最终的分组数目。分组后的每一个社团都是一个子超图  $G_i$ , 对于划分结果  $\{G_i\}_{i=1}^{\gamma}$ , 采用多步游走核<sup>[19]</sup>的方法为每一个社团构建核矩阵。子超图  $G_i$  和  $G_j$  的  $\lambda$  步游走核定义为:

$$k^\lambda(G_i, G_j) = \sum_{v \in V_{G_i}, v' \in V_{G_j}} k^\lambda(G_i, G_j, v, v') \quad (7)$$

## 2 超图划分和分类器构造

### 2.1 模块度

为了将多模态特征分组,文献[11-12]采用了图相似社团发现算法,应用图模型的社团发现算法处理超图的邻接矩阵,也在一定程度上提高了识别的准确率。但是将超图转化为图,就损失了超图本身具有的多层次的结构特点,而且需要预先给定分组数目  $\gamma$  才能进行超图的划分。为了解决上述问题,本文定义了超图的模块度计算方法,用模块度的值反映切分过程中各个模块的社团特性,切分的过程就转化为了寻找最大模块度的过程,从而实现切分的自动化。模块度定义如下:

$$Q = \sum_r (T_r - E_r) \quad (5)$$

其中,  $T_r$  表示社团  $r$  所有内部超边占整个超图全体超边的比例,表示社团  $r$  的内部紧密度;  $E_r$  表示随机条件下社团  $r$  内的超边分布的期望值。

$$E_r = |C_r|^2 \quad (6)$$

其中,  $C_r$  是所有与社团  $r$  相关联的超边(包括内部边和边界边)占整个超图全体超边的比例。  $Q \in [0, 1]$ , 如果社团内部边的比例不大于任意连接时的期望值,那么有  $Q = 0$ 。当  $\sigma_m = 2$  时,这里的模块度就是复杂网络中图的模块度<sup>[17]</sup>。

将模块度作为超图切分和优化的指标,采用多层次超图并行划分算法<sup>[18]</sup>进行超图切分。如图 3(a)所示,沿  $H_1$  将超图切成 2 份时,模块度的值为 0.08;但是按照图 3(b)的切分方式,模块度为 0.12,达到最大值,所以,切分按照图 3(b)进行。

$$k^\lambda(G_i, G_j, v, v') = k^1(G_i, G_j, v, v') \cdot \sum_{v \in N_{G_i}^v, v' \in N_{G_j}^{v'}} k^{\lambda-1}(G_i, G_j, v, v') \quad (8)$$

其中,  $k^1(G_i, G_j, v, v')$  表示顶点  $v$  和  $v'$  的径向基函数(Radial Basis Function, RBF)<sup>[20]</sup>;  $N_{G_i}^v$  表示在  $G_i$  内顶点  $v$  的邻居节点的集合。基于上述方法,通过样本训练,得到  $\gamma$  个核矩阵  $\{M_i\}_{i=1}^{\gamma}$ 。

根据得到的核矩阵,在  $\{\{M_i\}_{i=1}^{\gamma}, L\}$  ( $L$  是类别

标签向量)上训练得到 SVM 分类器  $\{C_i\}_{i=1}^y$ , 但是这些单独的分类器精度较低, 为了提高分类的准确度, 需要将这些弱分类器整合在一起形成最终的强分类器  $C$ 。考虑多分类 Boosting 方法<sup>[19]</sup>, 如图 4 所示, 每一次迭代都从当前分布下的  $\{C_i\}_{i=1}^y$  中选择一个最优的分类器, 计算其误差率, 动态改变该分类器在最终结果中所占的比重, 通过多轮迭代形成最后的  $C$ 。




图 4 Boosting 流程

### 3 实验结果与分析

#### 3.1 数据集简介

NUS-WIDE<sup>[21]</sup> 是新加坡国立大学采集的来源于 Flickr 的真实的网络图像数据集, 已经被广泛应用于多模态特征合并的实验中。该数据集包含了 269 648 幅图片和对应的 5 018 条不同的标签信息, 对于图片数据, NUS-WIDE 提供了 6 种底层特征: 1) 64-D 的颜色直方图; 2) 144-D 的颜色相关图; 3) 75-D 的边缘分布直方图; 4) 128-D 纹理图; 5) 225-D 的 black-wise color moment; 6) 500-D 的 SIFT。并且 NUS-WIDE 提供了 81 种不同先验种类, 用以判定识别结果。

MSRA-MM<sup>[22]</sup> 是微软亚洲研究院多媒体图像数据集。图像数据包括 68 类, 每类大约有 1 000 幅图像, 一共是 65 443 幅图像, 有效特征包括: 1) 225-D black-wise color moment; 2) 64-D HSV 颜色直方图; 3) 256-D RGB 颜色直方图; 4) 144-D 颜色相关图; 5) 75-D 边缘分布直方图; 6) 128-D 纹理图; 7) 7-D 人脸特征。因此, 样本是 899 维的。

本文基于上述 2 个数据集, 来验证在本文所提的多模态关联特征融合的方法下识别的准确度。如表 1 所示, NUS-WIDE 数据集共有 81 个种类 34 926 个样本, 训练集和测试集各占样本的一半; MSRA-MM 数据集在每个种类下, 分别提供了 100 个训练样本和 100 个测试样本。

表 1 实验数据集

数据集	样本总数	种类数	训练样本数	测试样本数
NUS-WIDE	34 926	81	17 463	17 463
MSRA-MM	2 000	10	1 000 (每个种类 100 个)	1 000 (每个种类 100 个)

#### 3.2 结果分析

在多模态特征的超图建模过程中, 最终形成的超图的拓扑结构和  $\sigma_m$  (超边内最多允许的顶点数目) 有较大关系, 理论上  $\sigma_m$  越大, 多模态特征之间的关系建模越准确, 但同时也带来更大的计算量。对于给定的  $\sigma_m$ , 其对应的超图聚类划分过程中的模块度值如图 5 所示。这里值得注意的是: 1) 不同的  $\sigma_m$  对应不同的超图拓扑结构, 而模块度只是用来反映当前超图拓扑结构下社团特性的强弱, 因此, 模块度和  $\sigma_m$  并没有直接的线性关系; 2) 当  $\sigma_m$  达到一定数值后, 模块度的值基本保持不变, 这是因为  $\sigma_m$  达到某个临界值以后, 继续增加  $\sigma_m$  并不会生成新的超边, 所以超图的拓扑结构不再变化, 而此时模块度有细微变化的原因是多层次超图划分<sup>[18]</sup> 具有一定的随机性。

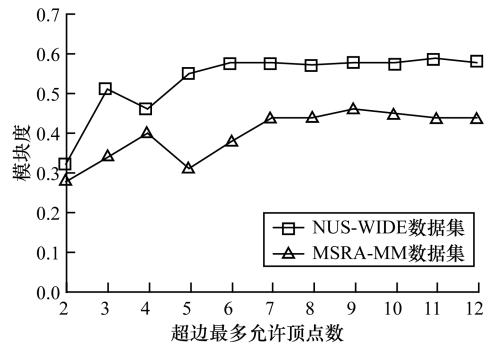


图 5  $\sigma_m$  与超图模块度的关系

在设定  $\sigma_m = 10$  的条件下, 生成并划分超图, 为每个分组构建分类器, 而最终形成的强分类器是由这些分组的分类器通过多轮循环迭代聚合而成的。迭代次数  $\tau$  和误差率的关系如图 6 所示, 当迭代次数达到 200 时, 训练误差和测试误差都较低并且开始处于一个平稳的状态, 没有出现拟合现象<sup>[23]</sup>。




图 6 迭代次数与误差率的关系

为了验证本文的多模态特征处理方法的有效性, 加入了针对不做融合原始多模态特征的线性 SVM 方法作为对比实验, 同时作为对比的还有

MKL<sup>[4]</sup>, SMO-MKL<sup>[4]</sup> 和 LPboost<sup>[24]</sup> 这些流行的特征融合方法。在  $\sigma_m = 10, \tau = 200$  的条件下,得到的

结果如表 2 所示,可以看出本文的多模态特征融合方法提高了识别的准确率。

表 2 不同方法识别准确率对比

数据集	不做特征融合的方法	MKL 方法	SMO-SKL 方法	LP- $\beta$ 方法	LP-B 方法	本文方法
NUS-WIDE	0.081 5	0.120 3	0.132 8	0.118 2	0.119 5	0.137 1
MSRA-MM	0.392 3	0.552 0	0.594 5	0.568 3	0.539 3	0.602 4

## 4 结束语

本文提出一种共享熵的计算方法用以度量多元关系。引入超图模型,在此基础上,定义度量超图划分好坏的模块度函数,用于表示当前分割下的社团特性,在不需要预先设定分组数目的前提下实现划分的自动化。实验结果表明,该方法在 2 个数据集上都表现了较优的识别率,验证了本文方法的有效性。本文方法还存在一些改进的地方:1) 共享熵只能表示离散型特征之间的关系,对于连续型的特征需要先进行离散化;2) 在超图划分过程中,每一次迭代优化都要进行模块度的计算,会导致较大的计算量,需要考虑用局部极值来优化全局模块度的方法,从而提高运算效率。这些是下一步的研究重点。

### 参考文献

- [1] Woods K, Kegelmeyer W P, Bowyer K. Combination of Multiple Classifiers Using Local Accuracy Estimates[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1997, 19(4): 405-410.
- [2] Eiben A E, Smith J E. On Combining Classifiers[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1998, 20(2): 226-239.
- [3] Zhao Zheng, Liu Huan. Multi-source Feature Selection via Geometry-dependent Covariance Analysis[J]. Journal of Machine Learning Research, 2008, 4(232): 36-47.
- [4] Sun Zhaonan, Ampornpant N, Varma M, et al. Multiple Kernel Learning and the SMO Algorithm[C]//Proceedings of the 24th Annual Conference on Neural Information Processing Systems. Vancouver, Canada: Advances in Neural Information Processing Systems, 2010: 2361-2369.
- [5] Wu Y, Chang E Y, Chang K C C, et al. Optimal Multimodal Fusion for Multimedia Data Analysis[C]//Proceedings of the 12th Annual ACM International Conference on Multimedia. New York, USA: ACM Press, 2004: 572-579.
- [6] Hearst M A, Dumais S T, Osman E, et al. Support Vector Machines[J]. IEEE Intelligent Systems and Their Applications, 1998, 13(4): 18-28.
- [7] Karypis G, Aggarwal R, Kumar V, et al. Multilevel Hypergraph Partitioning: Applications in VLSI Domain[J]. IEEE Transactions on Very Large Scale Integration Systems, 1999, 7(1): 69-79.
- [8] Huang Yuchi, Liu Qingshan, Zhang Shaoting, et al. Image Retrieval via Probabilistic Hypergraph Ranking[C]//Proceedings of 2010 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2010: 3376-3383.
- [9] Huang Yuchi, Liu Qingshan, Metaxas D. Video Object Segmentation by Hypergraph Cut[C]//Proceedings of

- IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2009: 1738-1745.
- [10] Selvakumaran N, Karypis G. Multiobjective Hypergraph-partitioning Algorithms for Cut and Maximum Subdomain-degree Minimization[J]. IEEE Transactions on Computer-aided Design of Integrated Circuits and Systems, 2006, 25(3): 504-517.
- [11] Zhang Luming, Gao Yue, Hong Chaoqun, et al. Feature Correlation Hypergraph: Exploiting High-order Potentials for Multimodal Recognition[J]. IEEE Transactions on Cybernetics, 2014, 44(8): 1408-1419.
- [12] Long Bo, Xu Xiaoyun, Zhang Zhongfei, et al. Community Learning by Graph Approximation[C]//Proceedings of the 7th IEEE International Conference on Data Mining. Washington D. C., USA: IEEE Press, 2007: 232-241.
- [13] Eibl G, Pfeiffer K P. Multiclass Boosting for Weak Classifiers[J]. Journal of Machine Learning Research, 2005, 6(6): 189-210.
- [14] Zhou Xiaoli, Bhanu B. Feature Fusion of Side Face and Gait for Video-based Human Identification[J]. Pattern Recognition, 2008, 41(3): 778-795.
- [15] MacKay D J C. Information Theory, Inference and Learning Algorithms[M]. Cambridge, USA: Cambridge University Press, 2003.
- [16] Kent J T. Information Gain and a General Measure of Correlation[J]. Biometrika, 1983, 70(1): 163-173.
- [17] Ethiraj S K, Levinthal D. Modularity and Innovation in Complex Systems[J]. Management Science, 2004, 50(2): 159-173.
- [18] Trifunović A, Knottenbelt W J. Parallel Multilevel Algorithms for Hypergraph Partitioning[J]. Journal of Parallel and Distributed Computing, 2008, 68(5): 563-581.
- [19] Zhu Ji, Zou Hui, Rosset S, et al. Multi-class Adaboost[J]. Statistics and Its Interface, 2009, 2(3): 349-360.
- [20] 林升梁, 刘志. 基于 RBF 核函数的支持向量机参数选择[J]. 浙江工业大学学报, 2007, 35(2): 163-167.
- [21] Chua Tat-Seng, Tang Jinghui, Hong Richang, et al. NUS-WIDE: A Real-world Web Image Database from National University of Singapore[C]//Proceedings of ACM International Conference on Image and Video Retrieval. New York, USA: ACM Press, 2009: 48-49.
- [22] Li Hao, Wang Meng, Hua Xiansheng. MSRA-MM 2.0: A Large-scale Web Multimedia Dataset[C]//Proceedings of IEEE International Conference on Data Mining Workshops. Washington D. C., USA: IEEE Press, 2009: 164-169.
- [23] 覃光华, 丁晶, 陈彬兵. 预防过拟合现象的人工神经网络训练策略及其应用[J]. 长江科学院院报, 2002, 19(3): 59-61.
- [24] Gehler P, Nowozin S. On Feature Combination for Multiclass Object Classification[C]//Proceedings of IEEE the 12th International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2009: 221-228.

编辑 刘冰