

# 一种运动数据检索的相关反馈算法

陈松乐<sup>1,2</sup>, 孙正兴<sup>1</sup>, 张岩<sup>1</sup>, 李骞<sup>1</sup>

(1. 南京大学计算机软件新技术国家重点实验室, 江苏南京 210046;  
2. 南京邮电大学宽带无线通信与传感网教育部重点实验室, 江苏南京 210003)

**摘要:** 本文提出了一种基于 RankBoost 的运动数据检索相关反馈算法. 该算法具有以下二个方面的特点: 首先, 以 KNN-DTW 作为 RankBoost 集成学习的弱排序器, 在适应变长多变量时间序列 (Variable-Length Multivariate Time Series, VLMTS) 数据的同时, 利用 RankBoost 的集成性与高效性解决相关反馈实时性要求与 VLMTS 数据计算复杂度高的矛盾; 其次, 以本文提出的最小化排序经验损失和泛化损失风险作为 RankBoost 集成学习目标, 有效地克服了相关反馈小样本学习环境下的过拟合问题. 在 CMU 动作库上的实验结果验证了该方法的有效性.

**关键词:** 运动捕获数据; 相关反馈; RankBoost; 排序损失

**中图分类号:** TP391.41      **文献标识码:** A      **文章编号:** 0372-2112 (2016)04-0868-05  
**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2016.04.016

## A Relevance Feedback Algorithm for Motion Data Retrieval

CHEN Song-le<sup>1,2</sup>, SUN Zheng-xing<sup>1</sup>, ZHANG Yan<sup>1</sup>, LI Qian<sup>1</sup>

(1. State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing, Jiangsu 210046, China;  
2. Key Laboratory of Ministry of Education of China for Broadband Wireless Communication and Sensor Network Technology, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210003, China)

**Abstract:** A relevance feedback algorithm based on RankBoost for content-based motion data retrieval (CBMR) is presented and has two characteristics. First, KNN-DTW is employed as the weak ranker for RankBoost ensemble learning. While adapting to variable-length multivariate time series (VLMTS) data, by taking the advantage of the ensemble and efficiency of RankBoost, it can resolve the conflict between the real-time requirement of relevance feedback and the high computational complexity of VLMTS data. Second, minimizing ranking experience loss and generalization loss risk proposed in this paper are used as the learning objective for RankBoost ensemble learning, which can effectively solve the over-fitting problem caused by small-sample training in relevance feedback. Experimental results on CMU action library verify the effectiveness of the proposed algorithm.

**Key words:** motion capture data; relevance feedback; RankBoost; rank loss

## 1 引言

目前, 在基于内容的运动数据检索 (Content-Based Motion data Retrieval, CBMR)<sup>[1]</sup> 领域, 一些研究者已经开始尝试使用相关反馈技术来进一步提高检索性能, 然而现有的 CBMR 相关反馈仅采用了以类间类内差比值<sup>[2]</sup> 以及平均归一化折扣累积增益<sup>[3]</sup> 为规则进行特征权重调整的启发式方法. 启发式方法由于缺乏明确的优化目标, 很难取得令人满意的效果<sup>[4]</sup>, 而在图像等基

于内容的多媒体信息检索领域, 相关反馈技术已由最初的启发式特征权重调整发展到在线学习机制<sup>[4]</sup>. CBMR 亟需要引入有效的机器学习方法以准确捕捉用户的主观检索意图.

与其他机器学习问题相比, 小样本和实时性要求是相关反馈学习算法面临的主要挑战. 小样本问题是指反馈学习算法只能从用户获取数量有限的学习样本, 极易产生过拟合问题<sup>[5,6]</sup>. 实时性则要求反馈学习

收稿日期: 2014-02-21; 修回日期: 2015-06-23; 责任编辑: 李勇锋

基金项目: 国家高科技发展计划 (No. 2007AA01Z334); 国家自然科学基金 (No. 61272219, No. 61100110, No. 61321491); 教育部新世纪优秀人才资助计划 (No. NCET-04-0460); 江苏省科技计划 (No. BE2010072, No. BE2011058, No. BY2012190, No. BY2013072-04); 计算机软件新技术国家重点实验室创新基金重点项目 (No. ZZKT2013A12)

算法必须足够快以满足用户和系统的实时交互需求.此外,在图像等基于内容的多媒体信息检索领域,检索对象通常采用向量表示,而 CBMR 的检索对象为连续的姿态形成的动作,是一种典型的变长多变量时间序列 (Variable-Length Multivariate Time Series, VLMTS),其通常采用行(列)数相同但列(行)数不等的矩阵进行表示<sup>[7]</sup>.由于不同动作在时间轴上存在局部非线性形变,一方面导致了很难采用统一的向量空间进行表示,另一方面需要采用弹性匹配以准确地度量不同序列模式的相似程度,计算复杂度较高,而运动数据的高维性使得这一问题更加突出.

基于在线分类或者优化的相关反馈技术在基于内容的图像检索 (Content-Based Image Retrieval, CBIR) 中已有大量研究,支持向量机 (Support Vector Machine, SVM) 和 Boosting 是两种最具有代表性的判别式相关反馈方法<sup>[8]</sup>.在 CBIR 中,SVM 相关反馈方法普遍采用的径向基等核函数一般都以向量作为输入,但 CBMR 中的检索对象为 VLMTS 数据,如何构建满足 Mercer 定理条件并能够实时计算的基于序列距离的核函数仍然是研究者面临的一个复杂问题<sup>[9]</sup>.Boosting 作为一种封装器特征选择技术在小样本学习环境下极易产生过拟合问题<sup>[10]</sup>,而 CBIR 中用来克服 Boosting 学习面临的小样本等问题的贝叶斯分类器<sup>[11]</sup>、模糊特征对比模型<sup>[12]</sup>以及 BiasMap 算法<sup>[13]</sup>很难应用于 VLMTS 数据,导致这些解决方法并不适用于 CBMR 系统.

针对 CBMR 相关反馈中 VLMTS 数据在线学习面临的小样本与实时性要求问题,本文提出了一种基于 RankBoost<sup>[14]</sup>的相关反馈算法,在 CMU 动作库<sup>[15]</sup>上的实验结果表明该算法具有较好的检索精度和较快的响应速度.

## 2 CBMR 相关反馈算法 RankBoost-RF

本节首先介绍 RankBoost-RF 算法的弱排序器,然后给出其学习目标,最后给出具体算法描述.

### 2.1 弱排序器:KNN-DTW

本文采用姿态布尔几何特征<sup>[16]</sup>与关节对距离特征<sup>[3]</sup>作为姿态的特征表示.设  $F = \{f_k, k = 1, \dots, d\}$  为姿态特征集合,采用动态时间弯曲算法 (Dynamic Time Warping, DTW)<sup>[17]</sup>计算实例在每个特征  $f_k$  上的两两弹性匹配距离,  $X_L^+, X_L^-$  分别为反馈过程中用户标记的相关实例集和不相关实例集,定义特征  $f_k$  对实例  $x_i$  的评分函数为:

$$h_k(x_i) = \frac{|x_i^R|}{|x_i^R| + |x_i^{RR}|} \quad (1)$$

其中,  $x_i^R \in X_L^+, x_i^{RR} \in X_L^-$  为  $x_i$  在  $X_L^+ \cup X_L^-$  上的  $K$  个最近邻样本.  $h_k(x_i) \in [0, 1]$ ,  $h_k(x_i)$  越高,则  $x_i$  的排序位置

越靠前.

RankBoost-RF 以 KNN-DTW 作为集成学习的弱排序器,一方面能够利用 KNN 仅需距离测度的特点克服 VLMTS 数据难以采用统一向量空间进行表示的不足并以 DTW 算法适应其弹性匹配需求,另一方面能够利用 RankBoost 的集成性在离线处理中计算库中实例在每个特征上的两两弹性匹配距离,而 RankBoost 在特征空间搜索的高效性则有利于解决运动数据的高维性问题,从而为反馈算法的高效性提供了基础.

### 2.2 学习目标:最小化排序经验损失与泛化损失风险

设  $X$  为库中所有动作实例构成的集合,  $Y = \{-1, +1\}$  描述实例是否和查询相关.若  $x_i \in X$  和查询相关则  $y_i = +1$ ,  $y_i = -1$  则表示  $x_i$  和查询不相关.在相关反馈过程中,反馈算法通过在用户标记的训练集  $X_L^+ \cup X_L^-$  上的学习,得到评分函数  $H: x \rightarrow R$ ,使得和查询越相关的实例评分越高.设  $X_U$  为从库中随机抽取的动作实例集 ( $X_U$  中的实例是否和查询相关未知).  $X_T = X_L^+ \cup X_L^- \cup X_U$  构成  $H$  的验证集.设  $\theta$  为阈值,对于  $x_i \in X_T$ ,若  $H(x_i) \geq \theta$ ,则  $x_i$  被  $H$  认定和查询相关,若  $H(x_i) < \theta$ ,则  $x_i$  被  $H$  认定和查询不相关,即:

$$y'_i = \begin{cases} +1, & \text{if } H(x_i) \geq \theta \\ -1, & \text{if } H(x_i) < \theta \end{cases} \quad (2)$$

记  $|X_U^+|, |X_U^-|$  分别为  $X_U$  中被  $H$  和  $\theta$  划分为相关实例和不相关实例的数量.对于  $X_U$  中的实例,设其和查询相关的概率为  $P_R$ ,不相关的概率为  $P_{RR}$ ,则  $X_U$  的最大排序损失  $R_u$  采用 Pointwise<sup>[18]</sup>表示为:

$$R_u = \frac{P_R \cdot |X_U^-| + P_{RR} \cdot |X_U^+|}{|X_U|} = P_R + \frac{(1 - 2P_R) \cdot |X_U^+|}{|X_U|} \quad (3)$$

在检索过程中,根据库中只包含极少与查询相关实例这一基本假设<sup>[19]</sup>,  $P_R \ll 0.5$ ,因此  $R_u$  随着  $|X_U^+|$  的减小而减小.固定阈值  $\theta$ ,不妨假设  $H$  能够对  $X_L^+, X_L^-$  进行正确的排序(在小样本学习环境下,该假设容易得到满足),通过分析应用  $H$  对  $X_T$  排序后  $X_U, X_L^+, X_L^-$  中实例之间的位置关系,可得到如下结论:  $X_U$  中的实例越远离  $X_L^+$  中的实例(即  $X_U$  中的实例越邻近  $X_L^-$  中的实例),  $|X_U^+|$  越小,因此  $H$  在  $X_U$  上的排序损失风险越小.

根据这一结论,我们可以用  $X_T$  上的排序结果来评估  $H$  的排序损失风险.本文采用具有偏序关系的实例对 (Pairwise)<sup>[14]</sup>来量化排序后不同集合中实例之间的位置关系.在使用  $H$  对  $X_T$  进行排序后,  $X_U$  中的实例和  $X_L^+$  中的实例的远离程度可通过偏序对之间的平均距离表示,即:

$$D_{\text{avg}}(X_L^+, X_U) = \frac{1}{|X_L^+| \cdot |X_U|} \sum_{x_+ \in X_L^+, x_- \in X_U} H(x_+) - H(x_-) \quad (4)$$

其中,  $X_L^+$  中的实例和  $X_U$  中的实例两两构成偏序对,  $D_{\text{avg}}(X_L^+, X_U)$  越大, 则  $X_U$  中的实例越远离  $X_L^+$  中的实例,  $H$  在  $X_U$  上的排序损失风险也就越小.

排序后用户标记的相关实例集  $X_L^+$  和不相关实例集  $X_L^-$  上的平均距离采用偏序对表示为:

$$D_{\text{avg}}(X_L^+, X_L^-) = \frac{1}{|X_L^+| \cdot |X_L^-|} \sum_{x_+ \in X_L^+, x_- \in X_L^-} H(x_+) - H(x_-) \quad (5)$$

$D_{\text{avg}}(X_L^+, X_L^-)$  越大,  $X_L^+$  中的实例越远离  $X_L^-$  中的实例,  $H$  在训练集  $X_L^+ \cup X_L^-$  上的排序经验损失也就越小.

将  $-D_{\text{avg}}(X_L^+, X_U)$ 、 $-D_{\text{avg}}(X_L^+, X_L^-)$  分别看作为  $H$  在偏序对集合  $X_L^+ \times X_U$ 、 $X_L^+ \times X_L^-$  上的排序损失  $R(X_L^+, X_U)$  和  $R(X_L^+, X_L^-)$ , 则  $H$  的总加权排序损失可表示为:

$$R(H) = R(X_L^+, X_L^-) + \beta R(X_L^+, X_U) \quad (6)$$

本文使用最小化  $R(H)$  代替传统的最小化训练集上的分类误差<sup>[11]</sup>或者排序损失<sup>[13]</sup>学习目标, 并将其称之为最小化排序经验损失与泛化损失风险 (Minimizing Ranking Experience Loss and Generalization Loss Risk, MR-EL&GLR) 学习目标. 一方面,  $R(H)$  越小, 则训练集上的排序损失就越小,  $H$  的排序经验损失也就越小; 另一方面,  $R(H)$  越小, 则验证集上的排序损失也就越小, 隐含着  $H$  的泛化损失风险也就越小. 对于在训练集上具有较好排序能力的若干个排序器, RankBoost-RF 算法采用 MR-EL&GLR 作为学习目标能够进一步筛选出具有较低泛化风险的排序器, 从而能够有效解决其在相关反馈小样本学习环境下的过拟合问题.

### 2.3 RankBoost-RF 算法描述

以 KNN-DTW 为弱排序器并以 MR-EL&GLR 为学习目标的 RankBoost-RF 算法如算法 1 所示. 算法在迭代过程中根据训练集和验证集上的加权排序损失确定弱排序器及其权重并分别更新训练集和验证集中每个偏序对的权重.

#### 算法 1 RankBoost-RF 算法

输入:

- 1) 用户标记的训练集  $X_L^+, X_L^-$ ;
- 2) 从动作库中随机抽取的实例集  $X_U$ ;
- 3) 姿态特征集合  $F = \{f_k, k = 1, \dots, d\}$ ;
- 4)  $D_{\text{DTW}}(x_1, x_2, f_k), x_1, x_2 \in X, f_k \in F$ , 即动作库中实例在  $f_k$  上的两两 DTW 距离.

过程:

- 1) 初始化  $X_L^+ \times X_L^-$  和  $X_L^+ \times X_U$  中偏序对权重分布  $D_t^0, D_t^1$ ;  
 $D_{t=0}^0(x_-^0, x_+^0) = 1/|X_L^+| \cdot |X_L^-|$ ;  
 $D_{t=0}^1(x_-^1, x_+^1) = 1/|X_L^+| \cdot |X_U|$ .
- 2) 初始化累计归一化因子  $M_0^0 = 1, M_0^1 = 1$ ;
- 3) 对于  $x_i \in X_L^+ \cup X_L^- \cup X_U$ , 根据式(1)计算在  $f_k (k = 1, \dots, d)$  上评分;

4) For  $t = 1, \dots, T$

4.1) 进行弱排序学习, 获得弱排序器  $h_t$ ;

$$r^* = 0; r_t^0 = 0; r_t^1 = 0$$

For  $k = 1, \dots, d$

$$r_{t,k}^0 = \sum D_t^0(x_-^0, x_+^0) (h_k(x_+^0) - h_k(x_-^0));$$

$$r_{t,k}^1 = \sum D_t^1(x_-^1, x_+^1) (h_k(x_+^1) - h_k(x_-^1));$$

If  $r^* < |M_{t-1}^0 r_{t,k}^0 + \beta M_{t-1}^1 r_{t,k}^1|$  then

$$r^* = |M_{t-1}^0 r_{t,k}^0 + \beta M_{t-1}^1 r_{t,k}^1|;$$

$$h_t = h_k; r_t^0 = r_{t,k}^0; r_t^1 = r_{t,k}^1$$

End if

End for

4.2) 计算  $h_t$  的权重  $\alpha_t = \frac{1}{2} \ln \frac{M_{t-1}^0 (1 + r_t^0) + \beta M_{t-1}^1 (1 + r_t^1)}{M_{t-1}^0 (1 - r_t^0) + \beta M_{t-1}^1 (1 - r_t^1)}$ ;

4.3) 更新权重  $D_t^0, D_t^1$ ;

$$D_{t+1}^0(x_-^0, x_+^0) = D_t^0(x_-^0, x_+^0) \exp(\alpha_t (h_t(x_-^0) - h_t(x_+^0))) / Z_t^0;$$

$$D_{t+1}^1(x_-^1, x_+^1) = D_t^1(x_-^1, x_+^1) \exp(\alpha_t (h_t(x_-^1) - h_t(x_+^1))) / Z_t^1;$$

其中  $Z_t^0 = \sum D_t^0(x_-^0, x_+^0) \exp(\alpha_t (h_t(x_-^0) - h_t(x_+^0)))$ ,

$$Z_t^1 = \sum D_t^1(x_-^1, x_+^1) \exp(\alpha_t (h_t(x_-^1) - h_t(x_+^1))).$$

4.4) 更新累积归一化因子  $M_t^0 = M_{t-1}^0 Z_t^0, M_t^1 = M_{t-1}^1 Z_t^1$ ;

4.5)  $H = H + \alpha_t h_t$ ;

End for

5) 使用  $H$  计算库中实例的评分, 排序后将 top-N 个候选动作返回.

## 3 实验设计与结果分析

### 3.1 实验数据集与评价标准

来源于 CMU<sup>[15]</sup> 运动捕获数据库包含实例数较多的 17 类动作构成了实验数据集, 共含有 658 个实例, 其组成和示意图如表 1 和图 1 所示.

表 1 三维人体动作库构成

运动类型	动作类别	数量
一般运动	侧手翻、蹲、跑、跳、走、行进	285
搏击	左(右)勾拳、左(右)直拳、左(右)踢	229
体育	篮球手势无效、翻腕、走步、运球、投篮	144
总数		658



图 1 数据集中各动作示意图

本文主要通过平均查全率和查准率来评估检索性能. 为了模拟实际的检索过程, 我们从每个动作类别中随机抽取 10 个动作进行检索, 最后我们将每次检索结果的平均值作为不同方法的平均检索性能.

### 3.2 学习目标有效性评估

为验证学习目标 MR-EL&GLR 的有效性,我们将其和最小化训练集上的分类误差和排序损失这两种传统的相关反馈学习目标进行对比. 为避免不同算法的影响,我们采用 Boosting 集成学习框架并使用相同的 KNN-DTW 学习器来评估这三种学习目标的反馈性能. Boosting 集成学习的迭代次数统一设置为 20, 对于 RankBoost-RF, 设置参数  $\beta$  为 0.5, 每次随机抽取的实例数  $|X_U|$  为 100. 每轮反馈中用户标记的样本数设定为 20, 查准率基数  $N$  为 30. 图 2 给出了三种学习目标前 5 次反馈的平均查准率对比.

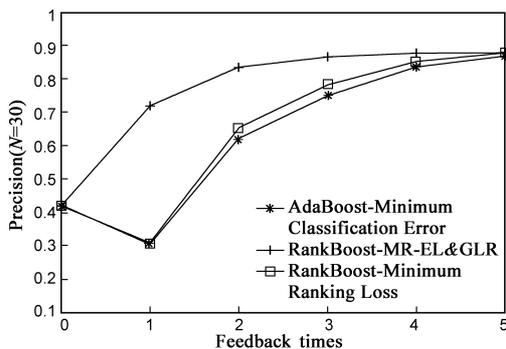


图2 不同学习目标前5次反馈平均查准率对比

图 2 中反馈次数为 0 对应的检索性能为通过内容匹配获得的首次检索结果. 从图 2 可以看出, 最小化训练集上分类误差和排序损失的学习目标尽管在反馈后期取得了较好的反馈性能, 然而在反馈初期特别是在首次反馈时, 反馈性能甚至低于首次检索结果. 本文提出的学习目标 MR-EL&GLR 取得了最好的反馈性能, 实验结果表明以 MR-EL&GLR 作为学习目标的 RankBoost-RF 算法能够有效克服相关反馈小样本学习环境下的过拟合问题.

### 3.3 反馈有效性评估

我们实现了 CBMR 中目前已有的根据特征类内差比值 (VRII-RF)<sup>[2]</sup> 以及特征的平均归一化累计折扣增益 (AnDCG-RF)<sup>[3]</sup> 这两种反馈算法以和 RankBoost-RF 算法进行对比. 图 3 给出了三种反馈算法前 5 次反馈平均查准率对比.

图 3 表明 VRII-RF 算法的反馈效果最差, 其检索性能只在首次反馈中得到了较大的提高. AnDCG-RF 算法的反馈性能略优于 VRII-RF 算法. 基于学习的 RankBoost-RF 算法的反馈性能明显优于基于启发式规则调整的 VRII-RF 和 AnDCG-RF 反馈算法. 图 4 进一步给出了三种反馈算法经过 5 次反馈后获得的平均查全率-查准率曲线, 可以看出本文提出的 RankBoost-RF 算法取得了较理想的反馈效果.

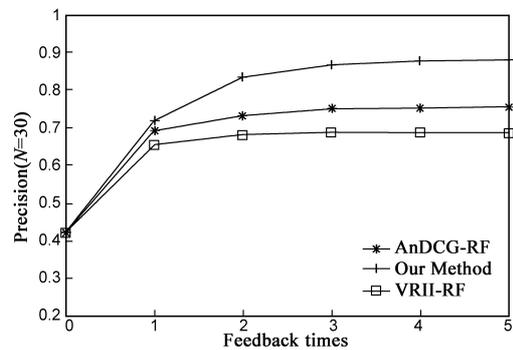


图3 不同反馈算法前5次反馈平均查准率对比

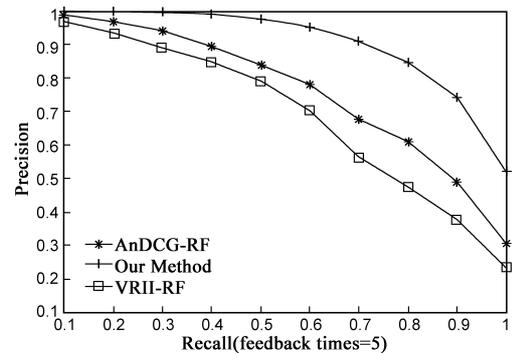


图4 不同反馈算法经过5次反馈后平均查全率-查准率对比

### 3.4 反馈效率与参数影响分析

我们在离线处理中计算库中动作在每个特征上的两两 DTW 距离以提高反馈效率. 相关反馈包含学习过程以及对库中实例重新排序两个阶段. RankBoost-RF 学习过程的时间复杂度为  $O(d \times (n + l) \times n \log n)$ , 排序过程的时间复杂度为  $O(A \times T \times n \times \log n + A \log A)$ , 其中,  $d$  为姿态特征数,  $n$  为用户标记的样本数,  $l$  为从库中随机抽取的实例数,  $A$  为库中所有动作实例数. 在 Intel (R) Core™ i7-3770@3.40GH 的 PC 上每轮反馈的平均响应时间小于 0.5s, 能够满足 CBMR 相关反馈的实时性要求.

RankBoost-RF 主要涉及 3 个参数, 即  $R(H)$  中  $R(X_L^+, X_U)$  所占的权重  $\beta$ , RankBoost 的迭代次数  $T$ , 以及随机抽取的实例集  $X_U$  的数量  $l$ . 通过实验分析可知, 当  $\beta > 0, T \geq 20, l \geq 100$  时, RankBoost-RF 算法的反馈性能对于参数的不同取值并不敏感, 均能够取得较接近的最优反馈性能.

## 4 总结与展望

本文提出了一种基于 RankBoost 的 CBMR 相关反馈算法. 考虑到 VLMTS 数据表示形式的特殊性、弹性匹配距离计算的复杂性以及高维性, 本文采用 RankBoost 为在线学习算法并以 KNN-DTW 构建弱排序器. 为了解决 RankBoost 在相关反馈小样本学习环境下的过拟合问题, 本文提出了 MR-EL&GLR 学习目标. 实验结果表

明:本文提出的 RankBoost-RF 算法能够有效解决 CBMR 小样本学习环境下的过拟合问题并能够满足实时性要求;相比于 CBMR 中目前已有的相关反馈方法,本文方法具有更好的检索精度和更快的响应速度.

在 CBMR 中,用户的需求和理解与运动特征之间的映射是一个十分复杂的问题,如何利用相关反馈来进一步缩小用户与计算机之间的语义鸿沟,仍是有待于深入研究的课题.此外,我们计划引入手绘草图等技术,以为用户提供更加自然和便捷的查询提交接口.

#### 参考文献

- [1] LIU F, ZHUANG Y T, Wu F, et al. 3D motion retrieval with motion index tree [J]. Computer Vision and Image Understanding, 2003, 92(2-3): 265 - 284.
- [2] CHEN S L, SUN Z X, LI Y, et al. Partial similarity human motion retrieval based on relative geometry features [A]. Proceedings of 4th International Conference on Digital Home [C]. Washington: IEEE Computer Society, 2012. 298 - 303.
- [3] TANG J K T, LEUNG H. Retrieval of logically relevant 3D human motions by adaptive feature selection with graded relevance feedback [J]. Pattern Recognition Letters, 2012, 33(4): 420 - 430.
- [4] HUANG T S, ZHOU X S. Image retrieval with relevance feedback; from heuristic weight adjustment to optimal learning methods [A]. Proceedings of 2001 International Conference on Image Processing [C]. Washington: IEEE Computer Society, 2001. 2 - 5.
- [5] ZHOU X S, HUANG T S. Relevance feedback in image retrieval; a comprehensive review [J]. Multimedia Systems, 2003, 8(6): 536 - 544.
- [6] WU K, YAP K H. Fuzzy SVM for content-based image retrieval [J]. IEEE Computational Intelligence Magazine, 2006, 1(2): 10 - 16.
- [7] YOON H, YANG K, SHAHABI C. Feature subset selection and feature ranking for multivariate time series [J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(9): 1186 - 1198.
- [8] HUANG W, GAO Y, CHAN K L. A review of region-based image retrieval [J]. Journal of Signal Processing Systems for Signal Image and Video Technology, 2010, 59(2): 143 - 161.
- [9] LEI H S, SUN B Y. A study on the dynamic time warping in kernel machines [A]. Proceedings of the 2007 Third International IEEE Conference on Signal-Image Technologies and Internet-Based System [C]. Washington: IEEE Computer Society, 2007. 839 - 845.
- [10] KOHAVI R, SOMMERFIELD D. Feature subset selection using the wrapper method; overfitting and dynamic search space topology [A]. Proceedings of 1st International Conference on Knowledge Discovery and Data Mining [C]. California: Amer Assn for Artificial, 1995. 192 - 197.
- [11] HUANG S H, WU Q J, LAI S H. Improved AdaBoost-based image retrieval with relevance feedback via paired feature learning [J]. Multimedia Systems, 2006, 12(1): 14 - 26.
- [12] JIANG W, ER G, DAI Q H, GU J W. Similarity-based online feature selection in content-based image retrieval [J]. IEEE Transactions on Image Processing, 2006, 15(3): 702 - 712.
- [13] ZHOU X S, GARG A, HUANG T S. Nonlinear variants of biased discriminants for interactive image retrieval [J]. Vision, Image and Signal Processing, IEE Proceedings, 2005, 152(6): 927 - 936.
- [14] FREUND Y, IYER R, SCHAPIRE R E, et al. An efficient boosting algorithm for combining preferences [J]. Journal of Machine Learning Research, 2003, 4: 933 - 969.
- [15] CMU. Motion Capture Database [DB/OL]. <http://mocap.cs.cmu.edu/>, 2003.
- [16] MULLER M, RODER T, CLAUSEN M. Efficient content-based retrieval of motion capture data [J]. ACM Transactions on Graphics, 2005, 24(3): 677 - 685.
- [17] SAKOE H, CHIBA S. Dynamic programming algorithm optimization for spoken word recognition [J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1978, 26(1): 43 - 49.
- [18] LIU T Y. Learning to rank for information retrieval [J]. Foundations and Trends in Information Retrieval, 2009, 3(3): 225 - 331.
- [19] CRUCIANU M, FERECATU M, BOUJEMAA N. Relevance feedback for image retrieval; a short survey [R]. Basel: DELOS2 European Network of Excellence (FP6), 2004.

#### 作者简介



陈松乐 男, 1976 年生于江苏淮阴. 博士. 现为南京邮电大学物联网学院讲师. 主要研究方向为多媒体数据分析与处理、计算机视觉.  
E-mail: chensongle@hotmail.com



孙正兴 (通信作者) 男, 1964 年生于江苏张家港. 博士. 现为南京大学计算机科学与技术系教授、博士生导师. 主要研究方向为智能人机交互、多媒体计算、计算机视觉.  
E-mail: szx@nju.edu.cn