

自适应用户的 Item-based 协同过滤推荐算法*

汪从梅^a, 王成良^b, 徐 玲^b

(重庆大学 a. 计算机学院; b. 软件学院, 重庆 400044)

摘要: 传统 Item-based 协同过滤算法计算两个条目间相似性时, 将每个评分视为同等重要, 忽略了共评用户 (对两个条目共同评分的用户) 与目标用户间的相似性对条目间相似性的影响。针对此问题, 提出了一种自适应用户的 Item-based 协同过滤算法。该算法将共评用户与目标用户的相似性作为共评用户评分重要性的权重, 以实现针对不同的目标用户, 为目标条目选择不同的、适合目标用户的最近邻居集, 从而提高推荐准确性。实验结果表明, 提出的算法可以显著提高推荐系统的推荐质量。

关键词: 推荐系统; 协同过滤; Item-based; 自适应用户; 条目相似性; 信息过载

中图分类号: TP312; TP301.6

文献标志码: A

文章编号: 1001-3695(2013)12-3606-04

doi:10.3969/j.issn.1001-3695.2013.12.023

User-adaptive Item-based collaborative filtering recommendation algorithm

WANG Cong-mei^a, WANG Cheng-liang^b, XU Ling^b

(a. College of Computer Science, b. School of Software Engineering, Chongqing University, Chongqing 400044, China)

Abstract: The traditional Item-based collaborative filtering algorithm regards every rating as equal importance when calculating the similarity between items, and ignores the impact of the similarity between co-rated users (users co-rate both two items) and target user on the similarity between items. This paper proposed a user-adaptive Item-based collaborative filtering recommendation algorithm, in which the rating of a co-rated user on an item was weighted by the user similarity between the co-rated user and target user, in order to select different neighbors of a certain target item for different target users, and so as to improve the recommendation accuracy. The experiment results suggest that the proposed algorithm can efficiently improve the recommendation quality.

Key words: recommender system; collaborative filtering; Item-based; user-adaptive; item similarity; information overloading

0 引言

随着互联网技术的迅猛发展, 信息超载问题随之而来, 用户在面对大量信息时无法从中快速获得自己所需的信息。推荐系统作为一种信息过滤的重要手段, 是解决信息超载问题的主要途径之一。它的目的是根据用户的偏好向用户推荐感兴趣的物品^[1,2]。推荐算法是个性化推荐系统的核心部分, 推荐算法的精度和效率直接影响推荐系统性能的优劣。目前, 个性化推荐算法主要有基于内容的推荐算法^[3]、协同过滤推荐算法^[4-6]、关联规则推荐算法^[7]、混合推荐算法^[8]、基于网络结构的推荐算法^[9,10]等。其中协同过滤推荐是目前应用最广泛、最成功的个性化推荐技术。它的基本思想是根据用户对条目的偏好, 寻找与目标用户偏好类似的邻居用户, 把邻居用户对条目的偏好观点提供给目标用户, 从而产生推荐^[11]。

基于条目的协同过滤 (Item-based collaborative filtering, IB-CF) 根据用户对相似条目的评分, 预测用户对目标条目的评分^[12], 因此, 目标条目邻居的选择是提高推荐质量的关键。传统 Item-based 协同过滤算法在使用 Pearson 相关相似性、余弦相似性、修正的余弦相似性等计算目标条目与其他条目之间的

相似性时, 将每个共评用户 (对两个条目共同评分的用户) 的评分都视为同等重要, 没有考虑共评用户与目标用户的相似性对条目相似性的影响, 使得针对不同目标用户同一个目标条目的邻居集都是一样的。合理的情况应该是目标条目的邻居会因目标用户的不同而不同。例如, 目标用户是男性, 那么受男性喜欢的条目应该成为目标条目更重要的邻居。因此, 计算目标条目与其他条目间相似性时, 应考虑共评用户与目标用户间的相似性对条目间相似性的影响。

1 传统 Item-based 协同过滤推荐算法

Item-based 协同过滤算法根据用户对相似条目的评分预测目标条目的评分, 然后给用户推荐预测评分值最高的 Top- N 个条目。这个过程一般有三个步骤: a) 构建用户—条目评分矩阵; b) 寻找目标条目的若干个最近邻居; c) 预测目标条目的评分, 并向用户产生推荐。

1.1 建立用户—条目评分矩阵

建立用户—条目评分矩阵需收集处理每个用户对条目的评分情况, 用户的历史评分数据可以用一个 $m \times n$ 阶的矩阵 R 表示, $R_{m \times n} = (R_{i,j})_{m \times n}$ 。

收稿日期: 2013-04-02; 修回日期: 2013-05-12 基金项目: 中央高校基本科研业务费科研专项基金资助项目 (CDJZR11090001)

作者简介: 汪从梅 (1988-), 女, 重庆江津人, 硕士研究生, 主要研究方向为 Web 数据挖掘、推荐引擎 (wangcongmei1988@qq.com); 王成良 (1964-), 男, 教授, 主要研究方向为数据库和 Web 开发; 徐玲 (1975-), 女, 博士, 主要研究方向为图像处理、计算机视觉。

$$\begin{bmatrix} R_{1,1} & \cdots & R_{1,j} & \cdots & R_{1,n} \\ \vdots & & \vdots & & \vdots \\ R_{i,1} & & R_{i,j} & & R_{i,n} \\ \vdots & & \vdots & & \vdots \\ R_{m,1} & \cdots & R_{m,j} & \cdots & R_{m,n} \end{bmatrix}$$

其中: m 是用户数; n 是条目数; $R_{i,j}$ 表示用户 i 对条目 j 的评分值。 $R_{i,j}$ 的值越大,说明用户对条目越喜欢。

1.2 选择邻居

协同过滤推荐算法的核心阶段是邻居选择,邻居条目的选择是否准确,直接关系到推荐系统性能的优劣。寻找邻居时,根据用户-条目评分矩阵 R 获得与目标条目按相似度大小降序排列的条目集合 $I = \{i_1, i_2, \dots, i_p\}, i \notin I$, 选择与目标条目相似度最大的前 K 个条目作为目标条目的最近邻居。条目相似性的度量方法主要有余弦相似性、修正的余弦相似性和 Pearson 相关相似性等^[13]。

1) 余弦相似性 两个条目的评分被看做是 m 维用户空间上的向量,条目间的相似性通过向量间的余弦夹角度量。设条目 i 和 j 在 m 维用户空间上的评分分别表示为向量 i, j , 则条目 i 和 j 之间的相似性计算方法如下:

$$\text{sim}(i, j) = \cos(i, j) = \frac{i \cdot j}{|i| \times |j|} \quad (1)$$

2) 修正的余弦相似性 在余弦相似性度量方法中,没有考虑不同用户的评分尺度问题,修正的余弦相似性度量方法通过减去用户对条目平均评分来解决上述问题。条目 i, j 之间相似性计算公式如下:

$$\text{sim}(i, j) = \frac{\sum_{v \in U_{i,j}} (R_{v,i} - \bar{R}_v)(R_{v,j} - \bar{R}_v)}{\sqrt{\sum_{v \in U_{i,j}} (R_{v,i} - \bar{R}_v)^2} \sqrt{\sum_{v \in U_{i,j}} (R_{v,j} - \bar{R}_v)^2}} \quad (2)$$

其中: $U_{i,j}$ 表示对条目 i, j 共同评分的用户集合; $R_{v,i}, R_{v,j}$ 分别表示用户 v 对条目 i, j 的评分; $\bar{R}_v$ 表示用户 v 对条目的平均评分。

3) Pearson 相关相似性 条目 i, j 间的相似性通过 Pearson 相关系数度量,计算公式如下:

$$\text{sim}(i, j) = \frac{\sum_{v \in U_{i,j}} (R_{v,i} - \bar{R}_i) \times (R_{v,j} - \bar{R}_j)}{\sqrt{\sum_{v \in U_{i,j}} (R_{v,i} - \bar{R}_i)^2} \sqrt{\sum_{v \in U_{i,j}} (R_{v,j} - \bar{R}_j)^2}} \quad (3)$$

其中: $U_{i,j}$ 表示对条目 i, j 共同评分的用户集合, $\bar{R}_i, \bar{R}_j$ 分别表示条目 i, j 的所有评分的平均值。

1.3 产生推荐

条目的最近邻居集产生之后,可通过目标用户对邻居条目的评分预测目标用户对目标条目的评分,选择预测评分值最高的 N 个条目推荐给用户。

对任意待预测的目标条目 i , 预测评分的计算公式如下:

$$P_{u,i} = \bar{R}_i + \frac{\sum_{j \in \text{KNN}_i} \text{sim}(i, j) \times (R_{u,j} - \bar{R}_j)}{\sum_{j \in \text{KNN}_i} |\text{sim}(i, j)|} \quad (4)$$

其中: $P_{u,i}$ 表示目标用户 u 对目标条目 i 的预测评分, KNN_i 表示目标条目 i 的 K 个最近邻居集合^[14]。

2 自适应用户的 Item-based 协同过滤推荐算法

2.1 问题分析

传统 Item-based 协同过滤推荐算法缺乏对共评用户与目标用户的相似性对条目相似性影响的考虑,导致对于不同目标

用户同一个目标条目的最近邻居集都是一样的。但实际情况并非总是如此。例如,在表 3 中, $u_1 \sim u_5$ 是对条目 $I_1 \sim I_6$ 已评分的用户, u_6, u_7 是目标用户, I_6 是目标条目。使用余弦相似性计算 I_6 与其他条目的相似度,如表 2 所示。本文的目的是根据目标用户 u_6, u_7 对条目 I_6 的最近邻居的评分,预测这两个目标用户对目标条目 I_6 的评分。设定目标条目的最近邻居个数为 2, 从表 2 可以得出目标条目 I_6 的最近邻居是 I_1 和 I_5 。当目标用户是 u_7 (女性) 时,由于条目 I_1 和 I_5 不受女性用户喜欢,那么用户 u_7 对条目 I_6 的预测结果将会偏向不喜欢。实际上,条目 I_6 既受男性用户喜欢又受女性用户喜欢,因此对于目标用户 u_7 ,把条目 I_1 和 I_5 作为目标条目 I_6 的邻居不合适。如果把受女性喜欢的条目如 I_2, I_4 作为目标条目 I_6 的邻居,会使用户 u_7 对条目 I_6 的预测评分更准确。因此,在度量目标条目与其他条目间相似性时,应该考虑共评用户与目标用户的相似性对条目间相似性的影响。

2.2 算法改进

基于以上分析,本文提出了一种自适应用户的 Item-based 协同过滤 (user-adaptive Item-based collaborative filtering, UA-IBCF) 算法,该算法将目标用户与共评用户的相似性作为用户评分重要性的权重。这样,当目标用户与共评用户越相似,共评用户评分的重要性权重就越大;反之,当目标用户与共评用户越不相似,共评用户评分的重要性权重就越小。该方法有效地解决了不同目标用户,准确地选取目标条目的最近邻居,以达到用户对目标条目准确的预测评分。

针对传统 IBCF 算法中的余弦相似性、修正的余弦相似性和 Pearson 相关相似性,相应地,UA-IBCF 算法中的条目相似性度量方法将基于余弦相似性、修正的余弦相似性和 Pearson 相关相似性,其计算公式如式 (5) ~ (7) 所示。

基于余弦相似性的 UA-IBCF 为

$$\text{sim}^u(i, j) = \frac{\sum_{v \in U_{i,j}} \text{Usim}(u, v)^2 \times R_{v,i} \times R_{v,j}}{\sqrt{\sum_{v \in U_{i,j}} \{ \text{Usim}(u, v) \times R_{v,i} \}^2} \sqrt{\sum_{v \in U_{i,j}} \{ \text{Usim}(u, v) \times R_{v,j} \}^2}} \quad (5)$$

基于修正的余弦相似性的 UA-IBCF 为

$$\text{sim}^u(i, j) = \frac{\sum_{v \in U_{i,j}} \text{Usim}(u, v)^2 (R_{v,i} - \bar{R}_v)(R_{v,j} - \bar{R}_v)}{\sqrt{\sum_{v \in U_{i,j}} \{ \text{Usim}(u, v) (R_{v,i} - \bar{R}_v) \}^2} \sqrt{\sum_{v \in U_{i,j}} \{ \text{Usim}(u, v) (R_{v,j} - \bar{R}_v) \}^2}} \quad (6)$$

基于 Pearson 相关相似性的 UA-IBCF 为

$$\text{sim}^u(i, j) = \frac{\sum_{v \in U_{i,j}} \text{Usim}(u, v)^2 (R_{v,i} - \bar{R}_i)(R_{v,j} - \bar{R}_j)}{\sqrt{\sum_{v \in U_{i,j}} \{ \text{Usim}(u, v) (R_{v,i} - \bar{R}_i) \}^2} \sqrt{\sum_{v \in U_{i,j}} \{ \text{Usim}(u, v) (R_{v,j} - \bar{R}_j) \}^2}} \quad (7)$$

其中: $\text{sim}^u(i, j)$ 表示当目标用户是 u 时,条目 i 和 j 之间的相似性; $U_{i,j}$ 表示对条目 i, j 共同评分的用户集合 (共评用户集合); $\text{Usim}(u, v)$ 表示目标用户与共评用户之间的相似性。

$\text{Usim}(u, v)$ 的大小可以使用 Pearson 相关相似性计算,计算公式如下:

$$Usim(u, v) = \frac{\sum_{i \in (I_u \cap I_v)} (R_{u,i} - \bar{R}_u) \times (R_{v,i} - \bar{R}_v)}{\sqrt{\sum_{i \in (I_u \cap I_v)} (R_{u,i} - \bar{R}_u)^2} \times \sqrt{\sum_{i \in (I_u \cap I_v)} (R_{v,i} - \bar{R}_v)^2}} \quad (8)$$

其中: I_u 、 I_v 分别表示用户 u 、 v 已评分的条目集合; $R_{u,i}$ 和 $R_{v,i}$ 分别表示用户 u 、 v 对条目 i 的评分; $\bar{R}_u$ 和 $\bar{R}_v$ 分别表示用户 u 和用户 v 的平均评分。

对 2.1 节中提出的问題,使用本文提出的基于余弦相似性的 UA-IBCF 算法重新进行分析。用式(8)计算用户间的相似性,计算结果如表 1 所示;用式(5)计算条目间的相似性,计算结果如表 2 所示。设定目标条目的最近邻居个数为 2。当目标用户是 u_6 时, I_6 的最近邻居是 I_1 和 I_5 ; 当目标用户是 u_7 时, I_6 的最近邻居是 I_2 和 I_4 。出现这个结果的原因是传统的 IBCF 算法认为对于所有的目标用户,每个共评用户的评分是同等重要的。然而,本文提出的 UA-IBCF 算法认为对于目标用户 u_6 ,共评用户 u_1 、 u_2 和 u_4 的评分数据更重要;对于目标用户 u_7 ,共评用户 u_3 和 u_5 的评分数据更重要。

从以上使用基于余弦相似性的 IBCF 算法和 UA-IBCF 算法分别为表 3 中的条目 I_6 选择最近邻居的结果来看,UA-IBCF 算法为目标条目选择最近邻居集时,会根据目标用户自适应地进行准确的选取。这主要是由于 UA-IBCF 算法在计算条目间相似性时,将共评用户与目标用户的相似性作为共评用户评分的重要性权重,从而为目标条目选择适合目标用户的最近邻居集。

表 1 用户相似性

目标用户 u_6	相似性	目标用户 u_7	相似性
u_6-u_1	0.9904	u_7-u_1	0.7860
u_6-u_2	0.9638	u_7-u_2	0.8483
u_6-u_3	0.8047	u_7-u_3	0.9946
u_6-u_4	0.9799	u_7-u_4	0.8554
u_6-u_5	0.8189	u_7-u_5	0.9795

表 2 条目相似性及排名

条目	IBCF		UA-IBCF (u_6)		UA-IBCF (u_7)	
	相似性	排名	相似性	排名	相似性	排名
I_6-I_1	0.9466	2	0.9506	2	0.9415	5
I_6-I_2	0.9460	4	0.9446	3	0.9502	2
I_6-I_3	0.9371	5	0.9316	5	0.9451	4
I_6-I_4	0.9463	3	0.9426	4	0.9544	1
I_6-I_5	0.9570	1	0.9650	1	0.9499	3

表 3 用户对条目的评分

	I_1	I_2	I_3	I_4	I_5	I_6
u_1 (男)	4	3	2	2	5	5
u_2 (男)	3	2	2	3	4	4
u_3 (女)	2	5	3	4	2	4
u_4 (男)	4	3	3	2	3	3
u_5 (女)	2	4	4	4	2	4
u_6 (男)	5	3	3	2	5	?
u_7 (女)	2	5	3	5	2	?

2.3 改进算法描述

输入: m 个用户对 n 个条目的评分数据,即用户一条目评分矩阵 R ; 目标条目的最近邻居数目 K ; 目标用户 u 。

输出: 目标用户 u 的 top- N 推荐列表。

计算过程:

a) 找出目标用户 u 没有评分的条目集合 I ,然后把任意一个条目 $i \in I$ 作为目标条目。

b) 根据用户一条目评分矩阵 R ,按式(8)计算目标用户 u 与其他任一用户 v 的相似度 $Usim(u, v)$ 。

c) 根据用户一条目评分矩阵 R 以及步骤 b) 中得到的用户相似性 $Usim(u, v)$,再根据系统需要选择式(5)~(7)中的公式计算目标条目与其他条目的相似度 $sim^u(i, j)$ 。最后,将 $sim^u(i, j)$ 按大小顺序排列,选取与目标条目相似度最大的前 K 个条目作为目标条目 i 的最近邻居,并输出最近邻居条目集合 KNN_i^u 。

d) 计算用户 u 对条目 i 的预测评分 $P_{u,i}$ 。通过用户 u 对条目 i 的最近邻居集合中条目的评分预测 $P_{u,i}$,计算公式如下:

$$P_{u,i} = \bar{R}_i + \frac{\sum_{j \in KNN_i^u} sim(i, j) \times (R_{u,j} - \bar{R}_j)}{\sum_{j \in KNN_i^u} |sim(i, j)|} \quad (9)$$

然后重复 c) 和 d),计算目标用户 u 对所有未评分条目的预测评分,然后选择评分最高的前 N 个条目推荐给目标用户,即目标用户的 top- N 推荐列表。

3 实验

3.1 实验数据集

为了验证本文提出算法的推荐质量,本文实验选取的数据集来自 Grouplens 提供的 MovieLens 数据集^[15]。MovieLens 是一个基于 Web 的研究型推荐系统,它根据用户对一部分电影的评分,预测该用户对其他电影的评分,并向用户提供推荐列表。MovieLens 有三种不同大小的数据集,本实验采用 MovieLens 提供的 100 K 数据集。该数据集包含 943 个用户对 1 682 部电影的 100 000 个评分数据。每个用户至少评价过 20 部电影,评分范围为 1~5,分值越大,表示用户对电影越喜欢。另外该数据集包括了所有用户的简单人口统计学信息及电影分类信息。

3.2 评价指标

评价推荐系统推荐质量的指标主要有统计精度指标和决策支持精度指标^[9]两类。本文选取统计精度指标中的平均绝对误差(mean absolute error, MAE)作为度量标准。MAE 是最常用的评价预测评分准确率的指标,通过计算用户对条目的预测评分与实际评分的偏差来度量预测的准确性。MAE 的值越小,预测准确性就越高,推荐效果就越好。MAE 的定义如下:

$$MAE = \frac{\sum_{i=1}^N |P_{u,i} - R_{u,i}|}{N} \quad (10)$$

其中: $P_{u,i}$ 为用户 u 对电影 i 的预测评分; $R_{u,i}$ 为用户 u 对电影 i 的真实评分; N 为测试集中用户 u 已评分的电影数量。

3.3 实验及结果分析

为了验证本文提出的算法,进行了四组实验,将 IBCF 算法和 UA-IBCF 算法的推荐结果进行了对比。实验中用户相似性采用 Pearson 相关相似性进行度量。

实验 1 测试不同数据稀疏度对推荐结果的影响,为后续实验选取合适的训练集比例,实验中条目邻居数 K 取 40,条目相似性采用 Pearson 相关相似性度量,实验结果对比如图 1 所示。

从图 1 可看到,当训练集所占的比例越大,即数据集越稠密时,两种算法的 MAE 都在逐渐减小,说明数据集越稠密,推荐系统的推荐效果越好,且数据集的稠密性对本文提出的 UA-IBCF 算法的推荐质量影响更大。在后续使用不同相似性度量方法比较 IBCF 和 UA-IBCF 算法推荐质量的实验中,随机选取

数据集90%的评分数据作为训练集,其余10%的评分数据作为测试集。

实验2 测试条目相似性的度量基于余弦相似性时,比较 IBCF 算法 (IBCF_C) 和 UA-IBCF 算法 (UA-IBCF_C) 的推荐质量,即 IBCF 算法的相似性计算方法采用式(1),UA-IBCF 算法的相似性计算方法采用式(5)。实验结果对比如图2所示。




图1 不同数据稀疏程度对推荐质量的影响




图2 基于余弦相似性的推荐质量比较

实验3 测试条目相似性的度量基于修正的余弦相似性时,比较 IBCF 算法 (IBCF_AC) 和 UA-IBCF 算法 (UA-IBCF_AC) 的推荐质量,即 IBCF 算法的相似性计算方法采用式(2),UA-IBCF 算法的相似性计算方法采用式(6)。实验结果对比如图3所示。




图3 基于修正的余弦相似性的推荐质量比较




图4 基于Pearson相关相似性的推荐质量比较

从以上实验结果可以看出,无论条目相似性度量采用余弦相似性、修正的余弦相似性,还是 Pearson 相关相似性中的哪一种,使用本文提出的 UA-IBCF 算法得到的 MAE 值都比使用 IBCF 算法得到的 MAE 值要小,由此可知,本文提出的 UA-IBCF 算法比传统 IBCF 算法的推荐质量要好。这主要是由于将共评用户与目标用户间的相似性作为共评用户评分重要性的权重能更准确地度量条目间的相似性,从而提高推荐质量。另外从图1结果可知,本文提出的改进算法在数据集稠密的情况下,推荐效果会更好。

4 结束语

本文对 Item-based 协同过滤算法的核心——条目相似性计算进行改进。传统 Item-based 协同过滤算法没有考虑共评

用户与目标用户的相似性对条目相似性的影响,为此,提出了一种自适应用户的 Item-based 协同过滤的改进算法。该算法计算条目间相似性时,首先计算目标用户与共评用户的相似性,然后用得到的用户相似性作为共评用户评分的权重以计算目标条目与其他条目的相似性。实验结果表明,本文提出的改进算法能达到较好的推荐效果。但本文提出的算法对数据稀疏性比较敏感,如何处理稀疏数据是下一步的工作重点。

参考文献:

- [1] 王国霞,刘贺平.个性化推荐系统综述[J].计算机工程与应用,2012,48(7):66-76.
- [2] 刘建国,周涛,汪秉宏.个性化推荐系统的研究进展[J].自然科学进展,2009,19(1):1-15.
- [3] BALABANOVIC M, SHOHAM Y. Fab: content-based, collaborative recommendation[J]. Communications of the ACM, 1997, 40(3): 66-72.
- [4] HERLOCKER J L, KONSTAN J A, TERVEEN L G, et al. Evaluating collaborative filtering recommender systems[J]. ACM Trans on Information Systems, 2004, 22(1): 5-53.
- [5] SU X, KHOSHGOFTAAR T M. A survey of collaborative filtering techniques[J]. Advances in Artificial Intelligence, 2009(4): 421-445.
- [6] BOBADILLA J, SERRADILLA F, BERNAL J. A new collaborative filtering metric that improves the behavior of recommender systems[J]. Knowledge-Based Systems, 2010, 23(6): 520-528.
- [7] 杨引霞,谢康林,朱杨勇,等.电子商务网站推荐系统中关联规则推荐模型的实现[J].计算机工程,2004,30(19):57-59.
- [8] De CAMPOS L M, FERNANDEZ-LUNA J M, HUETE J F, et al. Combining content-based and collaborative recommendations: a hybrid approach based on Bayesian networks[J]. International Journal of Approximate Reasoning, 2010, 51(7): 785-799.
- [9] ZHOU T, REN J, MEDO M, et al. Bipartite network projection and personal recommendation[J]. Physical Review E, 2007, 76(4): 6116-6123.
- [10] 王茜,段双艳.一种改进的基于二部图网络结构的推荐算法[J].计算机应用研究,2013,30(3):771-774.
- [11] 黄正.协同过滤推荐算法综述[J].价值工程,2012,31(21):226-228.
- [12] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms[C]//Proc of the 10th International Conference on World Wide Web. New York: ACM Press, 2001: 285-295.
- [13] 邓爱林.电子商务推荐系统关键技术研究[D].上海:复旦大学,2003.
- [14] 李春,朱珍民,高晓芳,等.基于邻居决策的协同过滤推荐算法[J].计算机工程,2010,36(13):34-36.
- [15] GroupLens Research Lab. MovieLens data sets[EB/OL]. [2013-04-02]. <http://www.grouplens.org/node/12>.

(上接第3599页)

- [6] LI Hong-ze, GUO Sen, ZHAO Hui-ru, et al. Annual electric load forecasting by a least squares support vector machine with a fruit fly optimization algorithm[J]. Energies, 2012, 2(11): 4430-4445.
- [7] 李轩,李建宏,何玉珠,等.基于遗传优化最小二乘支持向量机的导引头故障诊断[J].计算机应用研究,2011,28(3):899-901.
- [8] ZHU Bang-zhu, WEI Yi-ming. Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology[J]. Omega, 2013, 41(3): 517-524.
- [9] 周子英,段建南,李萍,等.基于最小二乘支持向量机的耕地面积预测研究[J].计算机应用研究,2012,29(3):873-876.
- [10] LI Ying-wei, MA Pei-pei, YU Li-na. LS-SVM soft sensing based on

hybrid particle swarm optimization[J]. International Review on Computers and Software, 2012, 7(1): 283-289.

- [11] 蒋刚.核函数理论与信号处理[M].北京:科学出版社,2013:57-60.
- [12] 向昌盛,周子英,余喜林,等.遗传算法在混沌时间序列预测中的应用研究[J].计算机应用研究,2011,28(8):2831-2834.
- [13] 吴昊,左洪福.基于最小二乘支持向量机的疲劳裂纹扩展预测[J].机械科学与技术,2008,27(11):1346-1350.
- [14] 董杰,陈学东,范志超,等.基于微裂纹扩展的疲劳蠕变寿命预测方法[J].金属学报,2008,44(10):1167-1170.
- [15] YANG Tao, WANG Hong-yan. Research on fatigue crack growth life prediction technique for the armored hull[J]. Binggong Xuebao/Acta Armamentarii, 2010, 31(2): 129-134.