

基于矩阵完整化的分块整合推荐算法

王 毅 金 忠

(南京理工大学计算机科学与工程学院 南京 210094)

摘 要 传统的推荐系统往往是通过使用协同过滤或基于内容的方式来实现的,而文中将矩阵完整化的方法应用到推荐系统中。由于数据的稀疏性,直接使用矩阵完整化的方法会给推荐结果带来不小的误差。考虑到使用用户中存在一些活跃用户,挖掘出这些特殊用户,由他们组成的数据会降低稀疏性,而且对活跃用户提高推荐质量,会产生更大的商业价值。提出了一种分块整合推荐的方法,实验结果表明该方法能够提升推荐精度。

关键词 推荐系统,矩阵完整化,活跃用户,分块整合

中图分类号 TP391 文献标识码 A DOI 10.11896/j.issn.1002-137X.2016.5.040

Split-Integration Recommendation Algorithm Based on Matrix Completion

WANG Yi JIN Zhong

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract The traditional recommendation system usually uses collaborate filtering or content-based recommendation as its method, but this paper applied matrix completion. Because of the sparsity of data, if matrix completion is used directly, error will be relatively large. Considering that some active users exist in all users, by means of finding these special users, the sparsity will be reduced by their integrated data. And improving recommendation quality for these users will be more likely to generate values. This paper proposed a split-integration recommendation algorithm, and the experimental results show that the proposed method can improve the accuracy of recommendation.

Keywords Recommendation systems, Matrix completion, Active users, Split-Integration

1 引言

互联网的普及和电子商务的发展越来越迅速,而推荐系统已经成为一项重要的研究内容,得到了越来越多研究者的关注。不管是搜索引擎(如 google, baidu)还是新闻门户网站(如 yahoo, sina),以及电子商务系统(如 amazon, eBay)等等,都不同程度地使用了各种形式的自动推荐系统。

目前推荐系统中常用的方法有两种:1)基于内容^[1]的推荐;2)基于协同过滤的推荐^[2]。这两种方法都有着各自的优缺点。协同过滤推荐系统可以处理视频以及音乐等复杂的非结构化的商品,拥有很好的自适应性,当用户的数量上升时,推荐精度会有着很好的提升,能够很容易地发现用户的兴趣。基于内容的推荐系统推荐的结论则比较容易理解且很直观,它不需要用户的历史数据,不存在数据冷启动和数据稀疏性的问题,拥有着许多现成的文本处理算法以及分类技术的支撑。

而矩阵完整化的问题是最近新出现的一个研究方向,主要讨论如何基于已知矩阵的部分元素来恢复该矩阵,其在系统辨识^[3]、计算机视觉^[4]、机器学习^[5]中均有应用。目前,也产生了许多优异的算法,比如 SVT^[6]、FPCA^[7]等等。本文使用一种 Dual-Primal PPA^[8]的矩阵完整化算法来对推荐系统

进行研究,并提出了一种分块整合的推荐方法,即把用户分为活跃用户与非活跃用户,对活跃用户与非活跃用户的评分矩阵分别进行矩阵完整化的计算,最后再与原评分矩阵的计算结果整合。实验结果表明本文提出的方法可以在一定程度上提高推荐质量。

定义 1 推荐系统中的数据可以分成 $U, I, R, U = \{User_1, User_2, \dots, User_m\}$ 表示由用户所组成的集合; $I = \{Item_1, Item_2, \dots, Item_n\}$ 表示由项目所组成的集合; R 是 $m \times n$ 阶矩阵,表示用户对各个项目的评分矩阵,其中元素 r_{ij} 表示第 i 个用户对第 j 个项目的评分。

由于随着时间的积累,推荐系统中的用户和项目的个数在不断增大,因此用户不可能对所有的项目进行评分。评分矩阵 R 中的元素将会有很多的空值,需要把这些空值恢复出来。

2 矩阵完整化

2.1 问题描述

设 M 是 $m \times n$ 阶矩阵,希望通过它的部分元素来恢复矩阵中的所有元素,此恢复过程可用下面秩最小化问题来描述:

$$\begin{aligned} \min \text{rank}(X) \\ \text{s. t. } P_{\Omega}(M) = P_{\Omega}(X) \end{aligned} \quad (1)$$

到稿日期:2015-04-17 返修日期:2015-09-05 本文受国家自然科学基金:面向子空间学习的低秩矩阵恢复理论与算法研究(61373063)资助。

王 毅(1991-),男,硕士生,主要研究方向为推荐系统、机器学习, E-mail: xhdzwangyi@163.com; 金 忠(1961-),男,博士,教授,主要研究方向为模式识别、机器学习、数据挖掘。

其中, $X \in R^{m \times n}$, 指标集 $\Omega \subset \{1, 2, \dots, m\} \times \{1, 2, \dots, n\}$ 。

$P_\Omega(\cdot)$ 为投影算子, 即:

$$P_\Omega(X) = \begin{cases} X_{ij}, & \text{如果 } (i, j) \in \Omega \\ 0, & \text{其他情况} \end{cases}$$

然而矩阵的秩函数是非连续、非凸的, 故直接求解比较困难。根据 Candès 等人的工作^[9,10], 可以将秩函数松弛到核范数, 于是得到下面等式表示的线性约束凸优化问题:

$$\begin{aligned} \min & \|X\|_* \\ \text{s. t. } & P_\Omega(M) = P_\Omega(X) \end{aligned} \quad (2)$$

这样可以使得模型更加简单、利于计算, 可以使用一些现成的凸优化算法进行求解。

2.2 Dual-Primal PPA

问题的一般描述如下:

$$\begin{aligned} \min & \theta(x) \\ \text{s. t. } & Ax = b, x \in \mathcal{X} \end{aligned} \quad (3)$$

其中, $\theta(x)$ 为凸函数。

下面介绍一种 Dual-Primal PPA 的凸优化算法。其可以把式(3)这种有约束的凸优化问题转化为多次迭代的无约束凸优化问题。下面给出第 k 次迭代的子过程。

Step1 拉格朗日乘子预测点的生成

$$\tilde{\lambda}^k = \lambda^k - \frac{1}{s}(Ax^k - b)$$

Step2 解的预测点生成

$$\tilde{x}^k = \arg \min \{ \theta(x) + \frac{r}{2} \|x - [x^k + \frac{1}{r}A^T(2\tilde{\lambda}^k - \lambda^k)]\|^2 \mid$$

$x \in \mathcal{X} \}$

Step3 拉格朗日乘子与解的修正

$$\lambda^{k+1} = \lambda^k - \gamma(\lambda^k - \tilde{\lambda}^k)$$

$$x^{k+1} = x^k - \gamma(x^k - \tilde{x}^k)$$

其中, r, s, γ 为标量参数, $r \times s > \|A^T A\|$, $\gamma \in [1, 2]$ 。

2.3 基于 Dual-Primal PPA 的矩阵完整化算法

根据上面的子过程, 矩阵完整化这种具体的线性约束凸优化问题主要就是求解如下的子问题:

$$\tilde{X}^k = \arg \min \{ \frac{1}{r} \|X\|_* + \frac{1}{2} \|X - [X^k + \frac{1}{r}(2P_\Omega(\tilde{J}^k) - P_\Omega(J^k))]\|^2_F \}$$

则设 $A = X^k + \frac{1}{r}(2P_\Omega(\tilde{J}^k) - P_\Omega(J^k))$, 对 A 做 SVD 分解之后: $A = U\Lambda V^T$ 。

又因为 F-范数与矩阵的奇异值在正交变换下不变, 则:

$$\begin{aligned} & \frac{1}{r} \|\tilde{X}\|_* + \frac{1}{2} \|\tilde{X} - A\|_F^2 \\ &= \frac{1}{r} \|\tilde{X}\|_* + \frac{1}{2} \|\tilde{X} - U\Lambda V^T\|_F^2 \\ &= \frac{1}{r} \|U^T \tilde{X} V\|_* + \frac{1}{2} \|U^T \tilde{X} V - \Lambda\|_F^2 \end{aligned}$$

\tilde{X} 会使上式尽量小, 所以 $U^T \tilde{X} V$ 应是一个非负对角矩阵, 则设 $U^T \tilde{X} V = \tilde{\Lambda}$ 。

对于给定的非负对角矩阵 Λ , 有:

$$\min \{ \frac{1}{r} \|\tilde{\Lambda}\|_* + \frac{1}{2} \|\tilde{\Lambda} - \Lambda\|_F^2 \}$$

设 $f = \frac{1}{r} \|\tilde{\Lambda}\|_* + \frac{1}{2} \|\tilde{\Lambda} - \Lambda\|_F^2$, 其为凸函数, 要使其

取最优解, $\tilde{\Lambda}$ 中的每个对角元 $\tilde{\lambda}_i$ 满足 $\frac{\partial f}{\partial \tilde{\lambda}_i} = 0$, 即 $\tilde{\lambda}_i = \lambda_i - \frac{1}{r}$;

又 $\tilde{\lambda}_i$ 非负, 则有 $\tilde{\lambda}_i = \lambda_i - \min(\lambda_i, \frac{1}{r})$ 。

因此 Dual-Primal PPA 对于具体的矩阵完整化问题的第 k 次迭代子过程如下:

Step1 拉格朗日乘子预测点的生成: $\tilde{J}^k = J^k - \frac{1}{s}(P_\Omega(X^k) - P_\Omega(M))$ 。

Step2 设 $A = X^k + \frac{1}{r}(2P_\Omega(\tilde{J}^k) - P_\Omega(J^k))$, 对 A 做 SVD 分解: $A = U\Lambda V^T$ 。

Step3 解的预测点生成 $\tilde{\Lambda}$ 为一对角矩阵, 其对角元 $\tilde{\lambda}_j = \lambda_j - \min(\lambda_j, \frac{1}{r})$, 其中 λ_j 为 Λ 的对角元。

则 $\tilde{X} = U\tilde{\Lambda}V^T$ 。

Step4 拉格朗日乘子与解的修正:

$$J^{k+1} = J^k - \gamma(J^k - \tilde{J}^k)$$

$$X^{k+1} = X^k - \gamma(X^k - \tilde{X}^k)$$

其中, r, s, γ 为标量参数, $r \times s > 1$, $\gamma \in [1, 2]$, X 为恢复出来的矩阵, J 为对应的拉格朗日乘子矩阵, M 为部分元素已知而需要恢复的矩阵, Ω 为已知元素的指标集。

当运用矩阵完整化算法到推荐系统中时, 会出现恢复出来的矩阵的某些元素的值越界的情况。对此, 在算法恢复出结果之前采用如下方法:

设 Φ 为评分矩阵的取值集合; X 为 $m \times n$ 的矩阵, 其为通过矩阵完整化算法恢复得到的矩阵; \hat{X} 也为 $m \times n$ 的矩阵, 其为最终得到的修正评分矩阵, 各个元素的取值如下:

$$\hat{X}_{ij} = \begin{cases} \min(\Phi), & \text{如果 } X_{ij} < \min(\Phi) \\ \max(\Phi), & \text{如果 } X_{ij} > \max(\Phi) \\ X_{ij}, & \text{其他情况} \end{cases}$$

3 基于矩阵完整化的分块整合推荐算法

在推荐系统中, 由于用户对某个项目的评分往往受很少因素影响, 比如一个用户对一部电影的喜好程度可能就是由影片中的演员、导演、类型等所决定的, 因此评分矩阵应该是一个低秩矩阵, 所以推荐系统可以通过矩阵完整化的方法进行研究。但当一个矩阵十分稀疏时, 通过矩阵完整化的算法恢复出来的结果的误差往往是比较大的, 而且矩阵中的数据稀疏性越高效果就越不好。而我们研究的推荐系统所对应的矩阵就是这样一个稀疏矩阵。

由于在互联网之中常常存在一种长尾分布, 比如一条热门的新闻往往被更多的人进行评论, 冷门的新闻则相反; 在电影推荐系统中也很常见, 热门的电影被更多的人看过并且评分过, 相似地, 也会存在活跃用户, 他们更加热衷于对新闻以及电影等进行评分评价。挖掘出这些活跃用户对推荐系统的研究具有很好的效果。下面将给出本文算法的思想, 算法分为两个步骤, 分别是基于活跃用户的阈值分块与加权整合推荐。

3.1 基于活跃用户的阈值分块

定义 2 设 R 为推荐系统中 $m \times n$ 阶评分矩阵, S 为 $m \times n$ 阶标识矩阵, 定义如下:

$$S_{ij} = \begin{cases} 1, & \text{如果 } R_{ij} \text{ 的值不为空值} \\ 0, & \text{其他情况} \end{cases}$$

如果 $i \in \{1, 2, \dots, m\}$, $\sum_{j=1}^n S_{ij} \geq L$ (L 为设定的一个阈值), 则称 $User_i$ 为属于推荐系统 U 的活跃用户, 这些所有满足要求的 $User$ 下标组成的向量 I_1 为活跃用户指标集, 其它所有 $User$ 的下标组成的向量 I_2 为非活跃用户指标集。

定义 3 设 A 为一个 $m \times n$ 阶的矩阵, $I \subseteq \{1, 2, \dots, m\}$, $A(I, :)$ 表示根据 I 的元素值从 A 中取出对应行所组成的矩阵。

若 R 为推荐系统中的评分矩阵, I_1 为活跃用户指标集, I_2 为非活跃用户指标集, 则 $R(I_1, :)$ 为活跃用户评分矩阵, $R(I_2, :)$ 为非活跃用户评分矩阵。

(1) 分块阶段

设置一个阈值 L , 根据定义 2 可以在评分矩阵 R 中找出所有的活跃用户, 则所有活跃用户的编号为指标集 I_1 , 非活跃用户的编号为指标集 I_2 , 以此把评分矩阵 R 分为两个部分: 活跃用户评分矩阵 $R(I_1, :)$, 非活跃用户评分矩阵 $R(I_2, :)$ 。

3.2 加权整合推荐

定义 4 设 $F(\cdot)$ 为一个矩阵完整化算子, R 为 $m \times n$ 阶评分矩阵, 则 $F(R)$ 表示为对评分矩阵 R 进行矩阵完整化计算后得到的矩阵。

(2) 整合阶段

设 \tilde{R} 为最后恢复出来的矩阵, 我们是通过原评分矩阵 R 、活跃用户评分矩阵 $R(I_1, :)$ 及非活跃用户评分矩阵 $R(I_2, :)$ 都进行矩阵完整化的计算, 分别求出 $F(R)$ 、 $F(R(I_1, :))$ 及 $F(R(I_2, :))$, 然后进行整合得到的。具体如下式所示:

$$\tilde{R}(I_1, :) = (1 - \omega_1) * [F(R)(I_1, :)] + \omega_1 F(R(I_1, :)) \quad (4)$$

$$\tilde{R}(I_2, :) = (1 - \omega_2) * [F(R)(I_2, :)] + \omega_2 F(R(I_2, :)) \quad (5)$$

其中, ω_1 为活跃用户权重系数, ω_2 为非活跃用户权重系数, 其取值范围为 0 到 1。

之所以做这样的修正, 是因为通过这样的方法对矩阵进行恢复, 可以既保证所有用户评分数据之间的相关性, 对于活跃用户又可以降低数据之间的稀疏性, 以此来提高推荐的质量。这里使用的矩阵完整化算法为上文提到的 Dual-Primal PPA, 因为在实验中发现其应用于推荐系统时的精度比其他几种算法的更高, 其有着更高的推荐质量。

3.3 算法步骤

输入评分矩阵 R , 设置参数 L, ω_1, ω_2 。

Step1 根据 3.1 节的方法, 把 R 分为活跃用户评分矩阵 R_1 、非活跃用户评分矩阵 R_2 ;

Step2 分别对 R, R_1, R_2 进行矩阵完整化的计算, 得到 $F(R), F(R_1), F(R_2)$;

Step3 根据 3.2 节的式 (4) 与式 (5), 通过对 $F(R), F(R_1), F(R_2)$ 进行加权整合得到最后的结果 \tilde{R} 。

4 实验结果与分析

4.1 数据库介绍

GroupLens^[12] Research 采集了一组从 20 世纪 90 年末到 21 世纪初由 MovieLens 用户提供的电影评分数据。文中实

验所采用的数据集是 MovieLens 100k。数据中包括了 100000 个评分, 共有 943 个用户与 1682 个物品。评分的取值范围是 1~5, 其中 5 表示最喜欢, 1 表示最不喜欢, 0 则表示用户没有评分。

4.2 实验设计

首先从数据集中随机抽取 80% 作为训练集, 20% 作为测试集, 先对方法的参数 L 以及 ω_1, ω_2 进行测试, 找出其对算法精度的影响, 从而发现最优参数。然后将对比实验重复 5 次, 以比较所提方法与 Dual-Primal PPA 以及 FPCA^[7]、ADM^[11] 和 APGL^[13] 在推荐系统上的精度。最后给出所提方法与 Dual-Primal PPA 相比在活跃用户评分矩阵上的推荐精度。

4.3 评判准则

采用 MAE 作为实验的评判标准。MAE 的公式如下:

$$MAE = \frac{\sum_{u \in T} |\tilde{R}_u(t) - R_u(t)|}{|T|}$$

其中, $\tilde{R}_u(t)$ 是用户对项目的预测打分, $R_u(t)$ 是用户对项目的实际打分, T 代表测试集, $|T|$ 代表测试集的大小。MAE 数值越小, 表明推荐质量越高。

4.4 参数选择

本文所有实验中使用到 Dual-Primal PPA 算法时, 相应的各个参数均为: $r = 0.0008, s = 1.05/0.0008, \gamma = 1.5, X$ 与 Y 的初始值都为全零矩阵, 迭代次数为 38。

阈值与权值的选择:

对阈值 L 选取的实验设计为从 0 到 570 每隔 10 选一个阈值, 如: 0, 10, 20, ..., 570, 然后对每个阈值进行实验以比较其 MAE 的大小。

图 1 为文中方法在取不同阈值时算法的精度, 横坐标为阈值 L , 纵坐标为 MAE 的值。其中, 权值选取的是 $\omega_1 = 0.7, \omega_2 = 0.05$ 。




图 1 阈值参数的影响

表 1 为选取不同阈值 L 时活跃用户数的变化情况。

表 1 活跃用户数的变化

阈值 L	0	100	200	300	400	500	570
活跃用户人数	943	291	92	23	5	2	0

从图 1 可以看出, 文中提出的方法在取不同的阈值时, 所得出的结果相差比较大。阈值为 110 左右时, 可以使得实验结果最优。当阈值的取值大于 110 时, 实验的结果会慢慢变差, 这是由于随着阈值的增大, 从表 1 可以知道活跃用户的个数在快速减少, 非活跃用户的个数则在快速增加, 而我们的算法在处理活跃用户时, 比较注重活跃用户内部之间的关联性, 而忽略了与大量非活跃用户数据之间的关联性, 所以实验结果会有变差的趋势。当阈值大到一定的阶段时, 实验结果又会有所提升, 这是由于随着阈值的进一步增大, 活跃用户的个

数已非常稀少趋向为零,算法几乎退化为直接使用 Dual-Primal PPA。

选取权值 ω_1 与 ω_2 的实验设计为分别从 0 到 1 每隔 0.1 选取一个权值的比较不同权值时 MAE 的大小。

图 2 为所提方法在取不同权值时算法的精度,横坐标为活跃用户权重系数,纵坐标为非活跃用户权重系数,竖坐标为 MAE 的值。其中,阈值 L 取为 110。




图 2 权值参数的影响

从图 2 可以看出, ω_2 的取值越小越好,当取 0 时,实验效果是最好的,这是由于非活跃用户评分矩阵中的数据是比较稀疏的,通过这些数据所恢复出来的矩阵得到的效果是很差的,还不如直接对原评分矩阵进行恢复,然后进行投影。而 ω_1 的取值为 0.6 时,实验的效果是最好的,这样可以既保证活跃用户之间数据比较多的优点,又能够在对活跃用户恢复矩阵时考虑到与全体数据之间的关联性。

4.5 实验结果

为了评价所提出的方法,将其与 Dual-Primal PPA 以及其他 3 种矩阵完整化的算法 FPCA、ADM 与 APGL 进行比较。根据上面参数选择部分的实验,本次实验的各个参数选为: $L=110, \omega_1=0.6, \omega_2=0$ 。

图 3 为 5 个算法在 5 次独立实验中的精度比较,横坐标为实验编号,纵坐标为 MAE 的值。




图 3 对比实验

一般的基于用户(或项目)的协同过滤算法的 MAE 值在 0.83 左右,从图 3 可以发现,除了实验中的 FPCA 算法效果不是很好外,其他 3 种均有不错的精度,因此矩阵完整化算法应用到推荐系统中是很不错的。而把 Dual-Primal PPA 算法应用到推荐系统中时,发现其与其他 3 种矩阵完整化算法相比有着更高的推荐质量,这就是本文使用 Dual-Primal PPA 作为矩阵完整化算法的原因。而文中提出的方法的性能还可以在 Dual-Primal PPA 算法的基础上再次得到更大的提升。从结果来看提升还是比较明显的,这表明提出的分块整合推荐方法有着很好的效果。

图 4 为提出的分块整合推荐算法与 Dual-Primal PPA 在活跃用户评分矩阵上的精度比较,实验独立执行 5 次,横坐标为实验编号,纵坐标为 MAE 的值。




图 4 活跃用户评分矩阵推荐精度的比较


由于方法中参数 $\omega_2 = 0$,因此其与 Dual-Primal PPA 相比,非活跃用户评分矩阵的恢复结果是一样的,而本文主要是给活跃用户评分矩阵的恢复结果带来了提升。从图 4 可以发现所提方法在活跃用户评分矩阵上的推荐精度相比 Dual-Primal PPA 有着很大的改善,而在实际应用中,活跃用户更可能对我们推荐的结果有所反应,比如喜欢购物的用户往往更有可能去买新的商品,所以我们的方法有很好的应用前景。

结束语 在把矩阵完整化算法运用到推荐系统中时,往往都是直接把评分矩阵作为一个整体来进行恢复的^[14,15],并没有对活跃用户与非活跃用户进行区别,而文中提出的算法挖掘出了活跃用户这一信息。首先将用户进行分类,然后对两类用户的评分矩阵分别进行恢复,最后与原评分矩阵的计算结果进行加权整合。实验结果表明,所提方法可以明显提高推荐质量。不过矩阵完整化的研究起步比较晚,现阶段把其应用到推荐系统之中,与基于矩阵分解模型的算法相比还没有得出更好的结果,所以这还需要我们做进一步的研究,以提升推荐的精度。但矩阵完整化的研究目前已经开始深入,把其作为一种模型应用到推荐系统中有着很好的前景。


参考文献

- [1] Pazzani M, Billsus D. Learning and revising user profiles: The identification of interesting Web sites[J]. Machine Learning, 1997,27:313-331
- [2] Rich E. User modeling via stereotypes [J]. Cognitive Science, 1979,3(4):329-354
- [3] Liu Zhang, Hansson A, Vadenberghe L. Nuclear norm system identification with missing inputs and outputs[J]. Systems & Control Letters, 2013, 62(8): 605-714
- [4] Jing Guo-dong, Shi Yun-hui, Yin Bao-cai. Image super-resolution reconstruction based on sparse representation and low-rank matrix completion[J]. Journal of Information & Computational Science, 2012, 9(13): 3859-3866
- [5] Cabral R S, Torre F D, Costeira J P, et al. Matrix completion for multi-label image classification[C]// Proceedings of Neural information Processing System(NIPS). 2011:190-198
- [6] Cai Jian-feng, Candès E J, Shen Zuo-wei. A singular value thresholding algorithm for matrix completion[J]. SIAM Journal on Optimization, 2010, 20(4): 1956-1982
- [7] Ma Shi-qian, Goldfarb D, Chen Li-feng. Fixed point and Bregman iterative methods for matrix rank minimization[R]. Technical Report, 2008
- [8] He Bing-sheng, Yuan Xiao-ming, Zhang Wen-xing. A customized proximal point algorithm for convex minimization with linear constraints[J]. Computational Optimization and Application, 2013, 56(3): 559-572

(下转第 237 页)



(a) EarthQuake 原始序列



(b) EarthQuake 拟合序列(压缩率 80%)

图 2

结束语 时间序列具有海量性、高维性等特点,因此在进行时间序列数据挖掘之前需要选择一种合适的方法对原始序列进行预处理,从而降低其复杂度并提高其数据挖掘结果的准确性。预处理的主要目标有两个:降低维度和消除噪声。

本文基于综合考虑已有的时间序列选取分段点的思想,提出了一种结合时间跨度和振幅变化选取关键点的方法,并基于关键点对时间序列进行线性表示。该方法通过引入一种改进的筛选分段点的机制,在保留原始时间主要趋势的前提下降低了拟合误差。该方法对于短时间内变化平缓的时间序列拟合效果较好。下一步的研究重点是对于短时间内波动频率比较高的时间序列寻找有效的拟合方案。

参考文献

[1] Pan Ding, Shen Jun-yi. Similarity Discovery Techniques in Temporal Data Mining[J]. Journal of Software, 2007, 18(2): 246-258 (in Chinese)
潘定, 沈钧毅. 时态数据挖掘的相似性发现技术[J]. 软件学报, 2007, 18(2): 246-258

[2] Keogh E. Fast similarity search in the presence of longitudinal scaling in time series databases[C]//Proceedings of the International Conference on Tools with Artificial Intelligence, 1997. Washington: IEEE Computer Society, 1997: 578-584

[3] Das G, Lin K I, Mannila H, et al. Rule Discovery from Time Series[C]//KDD-98. New York: KDD, 1998: 16-22

[4] Debrégeas A, Hébrail G. Interactive Interpretation of Kohonen Maps Applied to Curves[C]//KDD-98. New York: KDD, 1998: 179-183

[5] Hellerstein J M, Koutsoupias E, Papadimitriou C H. On the analysis of indexing schemes[C]//Proceedings of the ACM SIGACT-SIGMOD-SIGART Symposium on Principles of Database Systems-PODS, 1997. Tucson: ACM, 1997: 249-256

[6] Agrawal R, Faloutsos C, Swami A. Efficient similarity search in sequence databases[C]//Proceedings of the 4th International Conference on Foundations of Data Organization and Algorithms, 1993. London: Springer Berlin Heidelberg, 1993: 69-84

[7] Chan K P, Fu A W C. Efficient time series matching by wavelets [C]//Proceedings International Conference on Data Engineering, 1999. Sydney: IEEE, 1999: 126-133

[8] Keogh E, Chakrabarti K, Pazzani M, et al. Dimensionality reduction for fast similarity search in large time series databases[J]. Knowledge and Information Systems, 2001, 3(3): 263-286

[9] Yi B K, Faloutsos C. Fast time sequence indexing for arbitrary Lp norms [C]//Proceedings of the 26th VLDB Conference, 2000. Cairo: VLDB, 2000: 385-394

[10] Wu D, Singh A, Agrawal D, et al. Efficient retrieval for browsing large image databases[C]//International Conference on Information and Knowledge Management, 1996. Rockville: ACM, 1996: 11-18

[11] Pratt K B, Fink E. Search for patterns in compressed time series [J]. International Journal of Image and Graphics, 2002, 2(1): 89-106

[12] Xiao H, Feng X F, Hu Y F. A new segmented time warping distance for data mining in time series database[C]//Proceedings of 2004 International Conference on Machine Learning and Cybernetics, 2004. Shanghai: IEEE, 2004: 1277-1281

[13] Liu Shi-yuan, Jiang Hao. A Review on Time Series Representation for Similarity-based Pattern Search[J]. Computer Engineering and Applications, 2004, 40(27): 53-59 (in Chinese)
刘世元, 江浩. 面向相似性搜索的时间序列表示方法述评[J]. 计算机工程与应用, 2004, 40(27): 53-59

[14] Zhan Yan-yan, Xu Rong-cong, Chen Xiao-yun. Time Series Piecewise Linear Representation Based on Slope Extract Edge Point [J]. Computer Science, 2006, 33(11): 139-142 (in Chinese)
詹艳艳, 徐荣聪, 陈晓云. 基于斜率提取边缘点的时间序列分段线性表示方法[J]. 计算机科学, 2006, 33(11): 139-142

[15] Perng C S, Wang H, Zhang S R, et al. Landmarks: a new model for similarity-based pattern querying in time series databases[C]//Proceedings International Conference on Data Engineering, 2000. San Diego: IEEE, 2000: 33-42

(上接第 222 页)

[9] Candès E J, Tao T. The power of convex relaxation: Near-optimal matrix completion[J]. IEEE Transaction on information, 2010, 56(5): 2053-2080

[10] Candès E J, Recht B. Exact matrix completion via convex optimization[J]. Foundation of Computational Mathematics, 2008, 9: 717-772

[11] Chen Cai-hua, He Bing-sheng. Matrix completion via alternating direction method[J]. IMA Journal of Numerical Analysis, 2012, 32: 227-245

[12] Konstan J A, Miller B N, Mahz D, et al. GroupLens: Applying collaborative filtering to usenet news[J]. Communications of the

ACM, 1997, 40(3): 77-87

[13] Toh K C, Yun S. An accelerated proximal gradient algorithm for nuclear norm regularized least squares problem[J]. Pacific Journal of Optimization, 2010, 6: 615-640

[14] Gang Wu, Swaminathan, Mitra, et al. Online video session progress prediction using Low-Rank matrix completion[C]//IEEE International Conference on Multimedia and Expo Workshops (ICMEW). 2014: 14-18

[15] Anupriya G, Angshul M. SVD free matrix completion with online bias correction for Recommender Systems[C]//International Conference on Advances in Pattern Recognition(ICAPR). 2015: 4-7