

基于自适应秩动态张量分析的短时交通流预测

何领朝, 林东, 冯欣欣

(福州大学物理与信息工程学院, 福建 福州 350108)

摘要: 在智能交通系统中, 短时交通流预测可以为路线规划、交通管理和公共安全等领域提供数据支撑。为了提高数据缺失和异常情况下的预测准确性, 提出了一种基于自适应秩动态张量分析的算法来进行短时交通流预测。首先构造了覆盖周、天、时间窗口和空间4个维度的张量, 以挖掘交通流数据之间的多模相关性。其次, 利用滑动窗口模型, 形成动态结构的张量流数据。然后将主成分分析算法扩展成可以接收张量输入的离线张量分析算法, 并引入自适应秩和遗忘因子形成自适应秩动态张量分析算法。最后将张量流数据输入自适应秩动态张量分析算法中, 实现对短时交通流数据的预测。实验结果显示, 即使在数据有缺失的情况下, 自适应秩动态张量分析算法也能实现良好的预测。

关键词: 短时交通流预测; 数据缺失; 动态张量分析; 多模信息

中图分类号: TN915

文献标识码: A

doi: 10.11959/j.issn.2096-3750.2019.00116

Short-term traffic flow prediction based on adaptive rank dynamic tensor analysis

HE Lingchao, LIN Dong, FENG Xinxin

School of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China

Abstract: Short-term traffic flow prediction in intelligent transportation system can provide data support in areas such as route planning, traffic management, public safety and so on. In order to improve the prediction accuracy with missing and abnormal data, a short-term traffic flow prediction method based on the adaptive rank dynamic tensor analysis was proposed. Firstly, a four dimensional tensor consisted of week, day, time and space was constructed, which could excavate the multimodal correlation of traffic flow data. Secondly, tensor flow data with dynamic structure was formed by using sliding window model. The principal component analysis (PCA) algorithm was extended to an offline tensor analysis algorithm that could accept tensor input. Then the adaptive rank and the forgetting factor were introduced to generate an adaptive rank dynamic tensor analysis algorithm. Finally, the tensor stream data was inputted into the adaptive rank dynamic tensor analysis algorithm to realize the short-term traffic flow prediction. The experimental results show that a good prediction can be achieved even with data missing.

Key words: short-term traffic flow prediction, data missing, dynamic tensor analysis, multimodal information

1 引言

作为互联网领域的延伸技术, 物联网正在时刻改变并影响着人们的日常生活。遍布世界各地不同形态的信息实体, 构成了一个复杂的万物互联的信

息体系, 为信息采集、数据分析、状态预测等不同需求提供了完善的支撑平台^[1]。传感器技术的发展和完善推动了物联网领域的发展。智能交通系统作为物联网的重要组成部分, 也相应得到了快速发展^[2], 物联网在智能交通领域中的应用是集数据感知、传

收稿日期: 2019-02-21; 修回日期: 2019-04-18

通信作者: 冯欣欣, fxx1116@fzu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61601126, No.61571129)

Foundation Items: The National Natural Science Foundation of China (No.61601126, No.61571129)

输和分析于一体的完整体系^[3]。

随着社会经济的发展，交通拥堵带来的经济损失已经成为全世界共同关注的问题，智能交通系统的出现为缓解这类问题提供了新思路^[4]。短时交通流预测作为智能交通的重要组成部分，具有重要的研究意义。如向驾驶员实时提供短时交通流量预测信息，可便于其做出更好的路线规划。研究表明，预测信息可以缓解交通拥堵并提高整个交通网络的性能^[5]。

基于机器学习的预测算法，虽然在精度上有很大提升，但需要庞大的历史数据作为支撑，同时也要消耗大量的计算资源和时间来进行参数训练，因此，在某些领域并不适用。基于矩阵或张量的填充算法可以用少量的历史数据、花费较少的时间进行填充预测，且消耗的计算资源相对较少。

利用矩阵构建的数据模型仅能挖掘两个维度（如空间和时间）之间的相关性，无法覆盖其他如周、天等多模信息。而利用张量构建的数据模型可以同时覆盖空间、时间窗口、天和周等多模信息，填充效果优于矩阵填充。

基于张量的恢复方法有静态和动态两种。交通流数据在实时更新、张量尺寸固定的情况下，可以生成一系列张量流。静态张量填充算法只能挖掘单个张量各维度之间的相关性，而动态张量填充算法还可以挖掘相邻张量块之间的相关性。因此，在张量流模型中，动态张量分析算法的性能更好。

本文提出了一种基于自适应秩动态张量分析算法来进行交通流预测。首先，构造覆盖周、天、时间窗口和空间4个维度的张量，可以更好地挖掘交通流数据之间的多模相关性。其次，利用滑动窗口模型，形成动态结构的张量流数据。然后，将主成分分析（PCA, principal component analysis）算法扩展成可以接收张量输入的离线张量分析算法。接着，引入自适应秩和遗忘因子，形成自适应秩动态张量分析算法。最后，将张量流数据输入自适应秩动态张量分析算法中，实现对短时交通流数据的预测。

2 相关工作

目前，短时交通流预测方法按数据建模方式可以分为3种：第一种是基于向量的方法，即构造交通数据的一维历史数据，用来预测未来数据。Chen等^[6]通过研究PCA方法和核主成分分析方法，得出核主成分分析方法可以更好地挖掘交通因素与交

通数据潜在状况的联系。Qu等^[7]提出了基于贝叶斯主成分分析的数据填充方法，与传统填充方法相比，该方法恢复精度有很大提高。之后，Qu等^[7]又提出了基于概率的主成分分析的数据填充方法，与基于贝叶斯的主成分分析方法相比，恢复精度和运算速度都有提升。

第二种是基于矩阵的方法，即构造包含时间和空间两个维度的矩阵来完成预测。Zhang等^[8]构建矩阵形式的交通流数据，提出了基于最小二乘法支持向量机的数据填充方法，利用皮尔森相关系数衡量数据之间的相关性，提高了恢复精度。以上恢复方法，均利用了数据的时空特性，比单纯利用时间特性或空间特性的方法恢复精度要好。

第三种是基于张量的方法，即考虑数据的多模特性。2013年，Tan等^[9]提出了交通数据的张量模型构造方法，构建了包括周、天、时间窗口和空间4个维度的静态张量模型，在保留数据原始结构的同时，还可以挖掘数据之间的多模信息。Liu等^[10]最先提出张量迹范数概念，并构造了目标函数和求解方法。在此基础上，Tomioaka等^[11]利用交替方向乘子法来解决张量迹范数最小凸优化问题，恢复精度得到进一步提升。Signoretto等^[12-13]提出了Shatten- $\{p, q\}$ 范数的概念，并利用增强拉格朗日算法获得最优解。Shan等^[14]提出了张量参数化概率因子分解和贝叶斯概率因子分解，在恢复大面积数据丢失方面取得了较好的结果。Acar等^[15]在CP (canonical polyadic) 分解的基础上加权最优化，该方法可以规避张量展开，保留了张量最原始的结构。

算法预测准确性受构造历史数据相关性约束的影响，前两种方法用线与平面的方式构建数据模型，因此，预测精度通常不如第三种方法。而且当数据存在缺失时，第三种方法可以利用多模相关性，填充效果更佳。

上述基于张量的填充算法本质上属于静态张量填充算法，它们无法挖掘历史张量与实时张量的相关性。面对这一问题，Sun等^[16]在PCA的基础上，将二维矩阵扩展到多维张量，在挖掘实时张量的同时，考虑历史张量块的影响，提出了动态张量分析算法，并应用于网络流数据的异常检测中。随后，Hao等^[17]将此算法用于群智感知系统中志愿者轨迹数据的预测。

秩的大小对填充效果有很大影响。在交通流预

测场景中，数据的实时更新导致每个张量块的最佳秩并不一定相等。而 Sun^[16]提出的动态张量分析算法对于每个张量块都选用的是固定秩，并不适用于预测场景。

本文方法与上述方法的主要区别是：在构建覆盖周、天、时间窗口和空间的四模交通流数据张量的基础上，引入自适应秩算法，能更好地进行短时交通流预测。

3 张量基础介绍

张量是向量和矩阵的高阶扩展。本文用 $X \in R^{n_1 \times n_2 \times n_3 \times \dots \times n_N}$ 表示高阶张量，阶数为 N 。 X 的每一个维度称为模^[4]。下面介绍基于张量的相关计算。

定理 1 (张量展开) 给定一个 N 阶张量 $X \in R^{n_1 \times n_2 \times n_3 \times \dots \times n_N}$ ，则张量按 p 模展开可以表示为 $(X, p) \in R^{n_p \times (n_{p+1} n_{p+2} \dots n_N n_1 n_2 \dots n_{p-1})}$ ，其中，每个元素的映射关系如下^[18]

$$j = 1 + \sum_{m=1, m \neq p}^N (i_m - 1) J_m, J_m = \prod_{k=1, k \neq m}^{m-1} I_k \quad (1)$$

定理 2 (p 模式积) 给定一个张量 $X \in R^{n_1 \times n_2 \times n_3 \times \dots \times n_N}$ 和一个矩阵 $W \in R^{l_1 \times n_p}$ ，则张量与矩阵的 p 模式积定义为 $(X \times_p W) \in R^{n_1 \times n_2 \times \dots \times n_{p-1} \times l_1 \times n_{p+1} \times \dots \times n_N}$ ，它有如下性质^[18]

$$Y = X \times_p W \Leftrightarrow Y_{(p)} = W X_{(p)} \quad (2)$$

定理 3 (Tucker 分解) 原始张量 A 、核心张量 T 和近似张量 \hat{A} 之间的关系如下

$$T = A \times_1 U_1^T \times_2 U_2^T \times \dots \times_n U_n^T \quad (3)$$

$$\hat{A} = S \times_1 U_1 \times_2 U_2 \times \dots \times_n U_n \quad (4)$$

其中， U_n 为单位正交基^[19]。

定理 4 (张量流) 给定一系列张量 $A_i \in R^{n_1 \times n_2 \times \dots \times n_N}$ ($1 \leq i \leq n$)，当 n 随着时间的增加而增加时，便形成张量流序列^[16]。

定理 5 (奇异值分解 (SVD, singular value decomposition)) 给定矩阵 $M \in R^{m \times n}$ ，则矩阵 M 的 SVD 为^[16]

$$M = U \Sigma V^T \quad (5)$$

其中，矩阵 U 和矩阵 V 是酉正交矩阵，分别称为矩阵 M 的左奇异向量空间和右奇异向量空间。 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k, \dots, \sigma_l)$ ， $l = \min\{m, n\}$ 。 Σ 是对角矩阵，由矩阵 M 的奇异值构成。

$$M_k = U_k \Sigma_k V_k^T \quad (6)$$

特别地，式(6)称为矩阵 M 的截断秩- k SVD。其中， $k < l$ ， $U_k = [u_1, \dots, u_k]$ ， $V_k = [v_1, \dots, v_k]$ ， $\Sigma_k = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k)$ 。

4 基于滑动窗口的动态张量流模型

4.1 静态矩阵模型

基于时空相关性的填充方法认为，需要预测的数据与相邻点历史数据有很强的相关性^[20]。

假定需要预测 m 个兴趣点 $\{s_i\}_{i=1}^m$ 在时间间隔 $(t_j, t_j + \beta_i, \dots, t_j + l\beta_i)$ 的交通量。兴趣点可选取在地标性建筑物附近的城市主干道交叉路口位置，交通流兴趣点如图 1 所示。 β_i 为时间间隔， l 为算法预测时间范围。 m 个兴趣点 $\{s_i\}_{i=1}^m$ 在时间间隔 $(t_j, t_j - \beta_i, \dots, t_j - n\beta_i)$ 的历史数据可以作为输入。这种方法旨在找到当前数据与未来数据之间的关系函数 f ，使得

$$A^W = f(A^{\bar{W}}) \quad (7)$$

其中， $A^W \in R^{m \times l}$ ， $A^{\bar{W}} \in R^{m \times n}$ 。 \bar{W} 是 W 的补集。

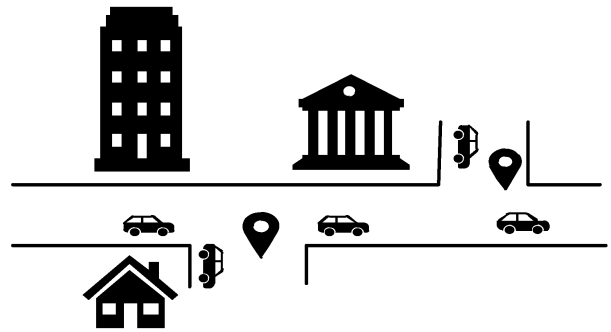


图 1 交通流兴趣点

从数据建模的角度看，这类预测方法的数据模型称为静态矩阵模型。静态矩阵模型仅覆盖交通流数据有限的信息，如数据的时间变动特性和空间相关性，并没有覆盖其他如周和天等多模相关性信息。

4.2 动态张量流模型

在静态矩阵模型的基础上，周期性选取几周数据，构建覆盖周、天、时间窗口和空间 4 个模式的张量 $A_i \in R^{m \times n \times w \times d}$ 。 w 表示张量块覆盖周的数目， $d = 7$ 表示一周 7 天。

将四阶张量 $A_i \in R^{m \times n \times w \times d}$ 在时间维度上设定固定窗口，缩小时间维度上的尺寸，按时间先后顺序排成一列，形成动态张量流数据

$A_t \in R^{m \times n \times w \times d} (1 \leq t \leq n)$, 窗口张量流构建示意图如图 2 所示, 其中, n 随时间的增加而增加。




图 2 窗口张量流构建示意图

实时输入的窗口张量 $A_n \in R^{m \times n \times w \times d}$ 包含当前时刻和需要预测的时刻, 在它之前的张量 $A_t \in R^{m \times n \times w \times d} (t < n)$ 属于历史张量。然后设计自适应秩动态张量分析算法, 通过挖掘历史张量和实时张量中当前时刻和未来时刻的相关性, 实现对未来时刻交通流数据的填充。

5 自适应秩动态张量分析算法

本节介绍自适应秩动态张量分析算法。首先引入 PCA 算法, 然后描述由 PCA 扩展的离线张量分析算法, 最后介绍由离线张量分析算法改进的自适应秩动态张量分析算法。

5.1 PCA

PCA 是一种最常用的降维方法, 目的是找到高维点到低维点的最佳线性映射。如给定 N 维空间中的 n 个向量 $x_i \in R^N (1 \leq i \leq n)$, PCA 可以通过投影矩阵 $U \in R^{N \times R}$, 将 x_i 从 N 维空间映射到 R 维空间 $y_i \in R^R (1 \leq i \leq n, R \leq N)$, 且均方误差

$e = \sum_{i=1}^n \|x_i - y_i U^T\|_2^2$ 最小。PCA 算法示意图如图 3 所示。




图 3 PCA 算法示意图

以学术论文数据集 (DBLP, digital bibliography & library project) 格式为例, 如果矩阵 X 的两个维度分别表示 DBLP 数据格式中的作者—关键词, 则经过 PCA 分解后, 得到的矩阵 Y 可以近似表示作者—标题矩阵, 投影矩阵 U 近似表示关键词—标

题矩阵^[16]。

由于 PCA 算法只能接收向量输入, 且向量只能单独表示交通流数据的时间变动特性或空间特性, 使得算法无法挖掘数据之间的时空相关性。

5.2 离线张量分析

下面介绍由 PCA 扩展的离线张量分析算法^[22]。首先把输入由向量扩展到多阶张量, 此时得到的输出也变为张量。因为映射空间只能沿单个维度投影, 而张量有多个维度, 所以映射空间也变为多个。三阶张量输入的离线张量分析如图 4 所示。




图 4 三阶张量输入的离线张量分析

图 4 可抽象为 $A \approx T \prod_{d=1}^M U_d$, 其中, M 是张量

A 的阶数, 该过程类似 Tucker 分解。由于动态张量流模型中, 输入的是一系列张量而非单个张量, 若对每个张量都单独进行 Tucker 分解, 势必会浪费巨大的计算资源, 还会导致每个张量彼此孤立, 无法挖掘张量之间的相关性。

在交通流数据中, 构成张量流 $A_i (1 \leq i \leq n)$ 的每个张量之间结构一致, 且张量块之间部分维度是重叠的。因此, 可以考虑利用交替投影法计算统一的投影空间。

张量 $A_i (1 \leq i < n)$ 表示历史张量块, 为已知数据。 A_n 表示当前时刻张量块, 时间维度包含需要预测的时刻, 未知数据可以用 0 或历史数据填充。当得到完整的张量流数据后, 首先初始投影矩阵 $U_l \in R^{N_l \times R_l} (1 \leq l \leq M)$, 然后分别对每个张量沿除 d 模外所有模依次投影得到张量 $A_i^d = A_i (\prod_{l \neq d} U_l U_l^T)$, 接着把每个张量 A_i^d 沿 d 模展开得到矩阵 $A_{i(d)}$, 对每个矩阵 $A_{i(d)}$ 的协方差求和得到 $C_d = \sum_{i=1}^n A_{i(d)} A_{i(d)}^T$ 。最后 C_d 对角化得到更新后的投影矩阵 U_d 。算法 1 给出了具体细节。

算法 1 离线张量分析

输入

张量流 $A_i \in R^{N_1 \times N_2 \times \dots \times N_M} (1 \leq i \leq n)$

核张量 T_i 的维度

输出

投影矩阵 $U_l \in R^{N_l \times R_l} (1 \leq l \leq M)$

核张量 $T_i \in R^{R_1 \times R_2 \times \dots \times R_M}$

近似张量 $\hat{A}_i \in R^{N_1 \times N_2 \times \dots \times N_M}$

算法流程

初始化 $N_l \times R_l$ 大小的矩阵 U_l

for $d = 1 : M$

for $i = 1 : n$

$$A_i^d = A_i (\prod_{l \neq d} U_l U_l^T)$$

$$(A_i^d, d) \in R^{N_d \times (\prod_{j \neq d} R_j)}$$

end for

$$C_d = \sum_{i=1}^n A_{i(d)} A_{i(d)}^T$$

C_d 对角化计算 U_d

收敛条件: $\text{Tr}(\|U_l^T U_l\| - I) \leq \varepsilon$

end for

$$\text{计算核心张量 } T_n = A_n \prod_{d=1}^M U_d^T$$

$$\text{计算近似张量 } \hat{A}_n = T_n \prod_{d=1}^M U_d$$

整个过程相当于把张量沿每个模分别执行 PCA, 以找到该模下的投影矩阵, 此过程可能需要执行多次迭代。由于每个子问题都是凸优化问题, 所以迭代算法在有限步后趋于收敛。最后通过投影矩阵 U_l 和核心张量 T_n 得到的近似张量 \hat{A}_n 即为填充好的张量, 里面包含未知时刻的数据即预测结果。

本质上, 算法 1 需要获取所有张量块后才能计算, 这对于以交通流为背景的动态张量环境来说很难实现。即使是在得到有限个张量后就运用该算法, 也会耗费大量的计算资源。

5.3 自适应秩动态张量分析

本节介绍由离线张量算法改进的自适应秩动态张量分析算法。与离线张量分析算法不同, 自适应秩动态张量分析算法的协方差矩阵只由上一时刻的张量块更新, 即无须存储所有历史张量。

张量每个模的最佳秩不一定相同, 矩阵进行 SVD 后, 各奇异值对应矩阵中隐含的信息, 奇异值越大则对应的信息量越多, 一般情况下, 认为很小的奇异值对应的是噪声信息, 因此, 可以考虑通过矩阵 $A_{(d)}$ 奇异值和的占比来确定秩的大小^[23]。即矩

阵 $A_{(d)}$ 经奇异值分解后, 把得到的奇异值从大到小排序 $\sigma_1, \sigma_2, \dots, \sigma_l$, 依次计算前 r_d 个奇异值的和与全部奇异值和的比例 P_{r_d} 并与阈值 p 比较, 当 $P_{r_{d-1}} \leq p$ 且 $P_{r_d} \geq p$ 时, 认为 r_d 是张量 A 在 d 模下的最佳秩。阈值 p 在 0.1~1 取值。算法 2 给出了具体过程。

算法 2 计算 (A_n, d) 的自适应秩

输入

A_n 按 d 模展开 (A_n, d) , 阈值 p

输出

A_n 按 d 模展开后的最佳秩 r_d

算法流程

$$(A_n, d)_{\text{SVD}} = U \Sigma V^T$$

$$\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_l), \sigma_1 > \sigma_2 > \dots > \sigma_l$$

$$P_{r_d} = \sum_{i=1}^{r_d} \sigma_i / \sum_j \sigma_j, r_d = 1$$

while $P_{r_d} \leq p$

$$r_d = r_d + 1$$

$$P_{r_d} = \sum_{i=1}^{r_d} \sigma_i / \sum_j \sigma_j$$

end while

当新的张量 A_n 输入时, 沿 d 模展开得到矩阵 $A_{(d)}$, 由 $A_{(d)} A_{(d)}^T$ 与 λC_d^{n-1} 的和来更新协方差矩阵 C_d^n 。其中, C_d^{n-1} 是上一时刻的协方差矩阵, $\lambda \in [0, 1]$ 是遗忘因子。当 $\lambda = 0$ 时, 表示完全不考虑历史张量的影响; 当 $\lambda = 1$ 时, 表示历史张量和当前时刻的张量有相同的权重。

C_d^n 对角化得到投影矩阵 U_d , 即 U_d 无须通过交替投影法计算, 节省了大量的计算成本, 然后将投影矩阵 U_d 按秩 r_d 截断。算法 3 给出了具体细节。其中, A_n 表示当前时刻张量块, 时间维度包含需要预测的时刻, 近似张量 \hat{A}_n 即填充好的张量。

算法 3 自适应秩动态张量分析

输入

新输入张量 $A_n \in R^{N_1 \times \dots \times N_M}$

前一时刻的协方差矩阵 $C_d^{n-1} (1 \leq d \leq M)$

输出

新协方差矩阵 C_d^n

近似张量 $\hat{A}_n \in R^{N_1 \times \dots \times N_M}$

算法流程

for $d = 1 : M$

$(A_n, d) \in R^{N_d \times (\prod_{j=1}^d N_j)}$
 $C_d^n \leftarrow \lambda C_d^{n-1} + A_{(d)} A_{(d)}^T$
 对角化协方差矩阵 $C_d^n = U_d S_d U_d^T$
 按算法 2 计算自适应秩 r_d
 按秩 r_d 截断 U_d
 end for
 计算核张量 $T_n = A_n \prod_{d=1}^M \times U_d^T$
 计算近似张量 $\hat{A}_n = T_n \prod_{d=1}^M \times U_d$

6 实验仿真

6.1 测量指标

本文采用平均绝对百分比误差 (MAPE, mean absolute percentage error) 和平均绝对误差 (MAE, mean absolute error) 作为衡量交通流的预测指标。计算如下

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|x_i - \hat{x}_i|}{x_i} \times 100\% \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (9)$$

其中, \hat{x}_i 是预测值, x_i 是真实值, n 是预测值的数量。

6.2 交通数据集

本文采用美国加州高速公路管理系统 (PeMS) 提供的 I405-S 高速公路 7 个路段, 从 2018 年 9 月 3 日~2018 年 10 月 7 日的数据作为测试数据集。这 7 个路段的编号分别是 718262、717746、71826、716674、764604、717751 和 717753。其中, 以 9 月 3~30 日的数据作为历史数据, 10 月 1~7 日的数据作为预测数据, 采样间隔是 5 min。

6.3 实验结果

本文选用高精度低秩张量填充 (HaLRTC, high accuracy low rank tensor completion) [23] 算法、Tucker-als 算法、三阶动态张量分析算法 [16] 和四阶动态张量分析算法作为对比算法。

三阶张量大小设为 7 (空间) × 7 (天) × 4 (周)。四阶张量模型是在三阶张量模型的基础上, 加入滑动窗口维度。经过对窗口维度大小从 1 到 10 验证后, 发现窗口维度设为 2 时算法预测效果最好, 不同滑动窗口尺寸下的预测性能如图 5 所示。

此时窗口张量在时间维度仅包含两个相邻时刻, 因此, 四阶张量的大小设为 7 (空间) × 7 (天) ×

4 (周) × 2 (时间窗口)。固定秩设为 [2, 2, 1] 和 [2, 2, 1, 1]。

为了确定自适应秩算法中的最优阈值 p , 在不同阈值 p 下分别输入缺失率 0~50% 的数据, 得到不同缺失率下各阈值 p 性能比较如图 6 所示。由图 6 可知, 曲线整体呈上升趋势, 说明数据缺失率越高, 则算法对 p 值的依赖性越大。大部分曲线在缺失率为 0 附近汇集, 说明算法在数据没有缺失的情况下, 对 p 值的依赖度低。当阈值 p 从小到大变化时, 可以看到 0.2~0.6 效果最好。当 p 值过大时, 算法计算出来的秩越逼近原始张量的维度, 不易挖掘各维度之间的相关性; 当 p 值过小时, 得到的各维度秩趋于一致, 不利于挖掘相邻张量块之间的相关性。综上所述, 将四阶自适应动态张量的阈值 p 设为 0.3。




图 5 不同滑动窗口尺寸下的预测性能




图 6 不同缺失率下各阈值 p 性能比较

张量流数据分别输入 5 个不同的算法中, 对星期一 288 个时刻的数据依次进行预测, MAPE 和 MAE 取均值后, 得到各算法预测精度如表 1 所示, 不同缺失率下各算法 MAPE 比较如图 7 所示。

从表 1 可以看出, 在相同条件下, 四阶自适应秩动态张量分析算法的 MAPE 比 HaLRTC 算法和

Tucker-als 算法分别低 68%和 70%，MAE 低 70%和 77%。这是引入遗忘因子的结果，每次新的张量块输入，计算时都会考虑上一时刻张量块的影响，而 Tucker-als 算法和 HaLRTC 算法只能对现时刻输入张量块做运算，无法考虑历史张量块的影响。预测数据在原始张量块中相当于整列缺失，这极大地破坏了原有数据结构之间的相关性，若单纯只对输入张量分解，不考虑历史张量块，将极大影响预测精度。

表 1 各算法预测精度

算法	MAPE	MAE
四阶自适应秩动态张量分析	0.082	23.25
四阶动态张量分析	0.084	26.79
三阶动态张量分析	0.175	63.01
HaLRTC	0.269	90.78
Tucker-als	0.298	103.2




图 7 不同缺失率下各算法 MAPE 比较

从表 1 中还可以看出，四阶动态张量分析算法的 MAPE 和 MAE 比三阶动态张量分析算法低 52% 和 57.48%，这是引入滑动窗口的结果，四阶动态张量分析算法可以挖掘两个相邻时刻间的相关性。四阶自适应秩动态张量分析算法的 MAPE 和 MAE 比四阶动态张量分析算法低 2.38% 和 13.21%，这是由于秩的大小对张量分析算法性能影响很大，自适应秩的引入使动态分析算法性能得到进一步提升。

实际生活中，存在各种不可控因素，使得获取的数据存在缺失。但是预测和缺失对于张量块而言，并无太大区别，所以基于张量的填充预测算法的另一大优势是在有数据缺失的情况下

进行预测。由图 7 可知，同等缺失条件下，四阶自适应秩动态张量分析算法预测精度比其他 4 种算法更好，即使是在数据存在 30% 缺失率的情况下，其也能有 0.309 的预测精度。四阶动态张量分析算法、三阶动态张量分析算法、HaLRTC 算法和 Tucker-als 算法的预测精度分别是 0.319、0.358、0.373 和 0.513。

7 结束语

智能交通系统对物联网的应用和发展具有重要意义。本文针对智能交通系统中的数据分析领域，提出了基于自适应秩动态张量分析的短时交通流预测方法。通过构造覆盖周、天、时间窗口和空间的四模张量，在保留原始数据结构的同时，更好地挖掘交通数据之间的多模相关性。设置遗忘因子考虑历史张量对实时张量的影响，通过自适应秩的计算实现张量秩的实时更新。实验结果显示，四阶自适应秩动态张量分析算法的预测效果优于其他填充算法，并且在数据缺失的情况下，也能得到满意的预测结果。

参考文献:

- [1] 张彦, 张科, 曹佳钰, 等. 边缘智能驱动的车联网[J]. 物联网学报, 2018, 2(4): 40-48.
ZHANG Y, ZHANG K, CAO J Y, et al. Internet of vehicles empowered by edge intelligence[J]. Chinese Journal on Internet of Things, 2018, 2(4): 40-48.
- [2] 余辰, 张丽娟, 金海. 大数据驱动的智能交通系统研究进展与趋势[J]. 物联网学报, 2018, 2(1): 56-63.
YU C, ZHANG L J, JIN H. Research progress and trend of big data-driven intelligent transportation system[J]. Chinese Journal on Internet of Things, 2018, 2(1): 56-63.
- [3] 熊建芳. 浅谈物联网在智能交通中的应用[J]. 智能计算机与应用, 2018, 8(6): 177-179.
XIONG J F. The application of the Internet of things in the intelligent transportation[J]. Intelligent Computer and Applications, 2018, 8(6): 177-179.
- [4] ZHANG J, WANG F Y, WANG K, et al. Data-driven intelligent transportation systems: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(4): 1624-1639.
- [5] RAN B, JIN P J, BOYCE D, et al. Perspectives on future transportation research: impact of intelligent transportation system technologies on next generation transportation modeling[J]. Journal of Intelligent Transportation Systems, 2012, 16(4): 226-242.
- [6] CHEN Y, HU J, ZHANG Y, et al. Traffic data analysis using kernel PCA and self-organizing map[C]//Intelligent Vehicles Symposium. IEEE, 2006.
- [7] QU L, ZHANG Y, HU J, et al. A BPCA based missing value imputing

- method for traffic flow volume data[C]//Intelligent Vehicles Symposium. IEEE, 2008.
- [8] ZHANG Y, LIU Y. Missing traffic flow data prediction using least squares support vector machines in urban arterial streets[C]//2009 IEEE Symposium on Computational Intelligence and Data Mining. IEEE, 2009: 76-83.
- [9] TAN H, FENG G, FENG J, et al. A tensor-based method for missing traffic data completion[J]. Transportation Research Part C: Emerging Technologies, 2013, 28: 15-27.
- [10] LIU J, MUSIALSKI P, WONKA P, et al. Tensor completion for estimating missing values in visual data[J]. IEEE transactions on pattern analysis and machine intelligence, 2012, 35(1): 208-220.
- [11] TOMIOKA R, HAYASHI K, KASHIMA H. On the extension of trace norm to tensors[C]//NIPS Workshop on Tensors, Kernels, and Machine Learning. 2010: 7.
- [12] SIGNORETTO M, DE LATHAUWER L, SUYKENS J A K. Nuclear norms for tensors and their use for convex multilinear estimation[J]. Submitted to Linear Algebra and Its Applications, 2010: 43.
- [13] SIGNORETTO M, DINH Q T, DE LATHAUWER L, et al. Learning with tensors: a framework based on convex optimization and spectral regularization[J]. Machine Learning, 2014, 94(3): 303-351.
- [14] SHAN H, BANERJEE A, NATARAJAN R. Probabilistic tensor factorization for tensor completion[J]. Department of Computer Science and Engineering, 2011: 1-4.
- [15] ACAR E, DUNLAVY D M, KOLDA T G, et al. Scalable tensor factorizations for incomplete data[J]. Chemometrics and Intelligent Laboratory Systems, 2011, 106(1): 41-56.
- [16] SUN J, TAO D, FALOUTSOS C. Beyond streams and graphs: dynamic tensor analysis[C]//Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2006: 374-383.
- [17] HAO F, JIAO M, MIN G, et al. A trajectory-based recruitment strategy of social sensors for participatory sensing[J]. IEEE Communications Magazine, 2014, 52(12): 41-47.
- [18] TAN H, WU Y, SHEN B, et al. Short-term traffic prediction based on dynamic tensor completion[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(8): 2123-2133.
- [19] DE LATHAUWER L, DE MOOR B, VANDEWALLE J. A multilinear singular value decomposition[J]. SIAM Journal on Matrix Analysis and Applications, 2000, 21(4): 1253-1278.
- [20] MIN W, WYNTER L. Real-time road traffic prediction with spatio-temporal correlations[J]. Transportation Research Part C: Emerging Technologies, 2011, 19(4): 606-616.
- [21] BRIN S, PAGE L. The anatomy of a large-scale hypertextual web search engine[J]. Computer Networks and ISDN Systems, 1998, 30(1-7): 107-117.
- [22] LIU J, MUSIALSKI P, WONKA P, et al. Tensor completion for estimating missing values in visual data[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 35(1): 208-220.
- [23] CHEN X, HE Z, WANG J. Spatial-temporal traffic speed patterns discovery and incomplete data recovery via SVD-combined tensor decomposition[J]. Transportation Research Part C: Emerging Technologies, 2018, 86: 59-77.

[作者简介]



何领朝(1991-), 男, 河南林州人, 福州大学物理与信息工程学院通信与信息系统专业硕士生, 主要研究方向为车联网数据采集与分析和张量数据分析。



林东(1969-), 男, 福建福州人, 博士, 福州大学物理与信息工程学院通信工程系副教授, 主要研究方向为视频信号处理、移动通信和信息安全。



冯心欣(1983-), 女, 福建福州人, 福州大学物理与信息工程学院通信工程系副教授, 主要研究方向为经济学理论及其在通信网络中的应用、机器学习理论及其在数据处理中的应用。