

一种基于改进的马尔可夫链的交通状况预测模型

周明升¹, 刘抒扬²

(1.上海外高桥保税区联合发展有限公司, 上海 200131; 2.上海商学院 商务信息学院, 上海 201400)

摘要: 城市交通日益拥堵的今天, 为用户推荐最快行驶路线成为一个研究热点。行驶路线推荐的核心问题是对路线将来某段时间(途径这段线路时)交通状况的预测。交通状况受到路线本身状况、行驶时间、天气状况、驾驶员习惯等多种因素影响, 其变化快、变化方式复杂, 难以准确预测。对多阶马尔可夫链模型进行了改进, 提高了运算效率和响应速度, 建立一种高效的交通状况预测模型, 经北京市实际交通数据的检验, 得到了比较好的预测效果。

关键词: 马尔可夫链; 交通状况; 路线推荐; 预测模型

中图分类号: TP391

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211928

中文引用格式: 周明升, 刘抒扬. 一种基于改进的马尔可夫链的交通状况预测模型[J]. 电子技术应用, 2022, 48(5): 27-30, 36.

英文引用格式: Zhou Mingsheng, Liu Shuyang. A prediction model for traffic conditions based on an improved Markov chain[J]. Application of Electronic Technique, 2022, 48(5): 27-30, 36.

A prediction model for traffic conditions based on an improved Markov chain

Zhou Mingsheng¹, Liu Shuyang²

(1. Shanghai Waigaoqiao Free Trade Zone United Development Co., Ltd., Shanghai 200131, China;

2. Faculty of Business Information, Shanghai Business School, Shanghai 201400, China)

Abstract: With the growth of urban traffic jam, how to recommend the fastest driving route for end users has become a research focus. The core problem of route recommending is how to forecast the traffic condition of the route in future, when the user will drive on this route section. The traffic condition is influenced by many factors, like road condition itself, passing time, weather conditions and habits of the driver. Because traffic condition changes very fast and complicated, it is difficult to accurately predict directly. This paper proposed a traffic condition prediction model based on an improved M-order Markov chain, which is more efficient. The model was tested with the actual traffic data in Beijing, and got a good result.

Key words: Markov chain; traffic condition; routes recommending; prediction model

0 引言

确定了用户的出发地和目的地后, 准确预测各条可能路线未来某段时间(行驶到达路段时)的交通状况, 可以为用户推荐最优出行线路, 减少行驶时间, 也方便用户私家车与公共交通的选择。某段线路上的行驶时间应综合考虑以下几个因素: 路线本身的情况、行驶到该路线上时的交通流量和驾驶员的驾驶习惯等。当前对交通状况、路线推荐的研究主要有以下几类: (1) 基于交通分析的方法^[1-2]; 通过道路上的识别器及车流量信息, 通过“识别器-车流量-行驶方向”的范式来研究交通状况推荐路线, 这种方法准确性的前提是要有足够的识别器和车流量信息, 数据获取比较困难^[3]。通过获取车辆信息, 估计实时交通流量, 预测将来的交通状况^[4-6], 其基于路段的分析需要借助大量数据进行分析, 当采样率低、数

据稀疏时无法准确估计。(2) 基于交通模式学习的方法: 给出了概率为基础的方法, 通过用户历史 GPS 轨迹数据, 预测驾驶员的目的地和行车路径^[7-8]。其通过学习 GPS 轨迹数据来获取驾驶和速度模式计算最快路线^[9-10]。(3) 智能推荐: 试图挖掘驾驶员道路选择的倾向, 通过人机交互或推理模型推荐个性化路线, 其推荐路线没有随行驶时间而优化^[11]。其通过 GPS 轨迹数据, 寻找关键节点和关键路线, 结合用户行为, 推荐最快线路^[12-13]。

与之前的研究不同, 本文的研究通过配置了 GPS 的出租车作为交通状况的接收器, 获取历史交通路况和实时交通路况信息, 通过多阶马尔可夫链模型预测未来的交通状况。出租车的 GPS 日志信息既反映了不同时间、不同道路的交通状况, 也体现了出租车驾驶员的智慧, 可以体现驾驶员的行为习惯。本文不是直接从 GPS 轨迹

数据中直接分析道路行驶速度和驾驶员驾驶模式,而是通过马尔可夫链来预测某些路线将来某段时间的交通状况。预测过程中,将多阶马尔可夫链转化为一阶马尔可夫链,提高了运算效率和用户响应速度。

1 模型建立

1.1 变量定义

假设交通状况服从 m 阶马尔可夫链,模型中相关概念、变量定义如表 1 所示。

表 1 变量定义

变量	含义	变量	含义
τ	交通变化的最小时间间隔	φ	预测时间间隔(将来)
x_t	t 时刻的交通状况	X	交通状况空间
S	有限状态空间	m	马尔可夫链的阶数
S^m	$m \times m$ 的状态空间	$ S $	状态空间的维数
Y_i	S 中的一个随机变量	y_i	Y_i 的一个值
$P^{(k)}$	S 空间上的 m 阶马尔可夫链的 k 步状态转移矩阵	$P^{(k)}$	方阵矩阵 P' 自乘 k 次
$P^{(k)}$	S^m 空间上的 1 阶马尔可夫链的 k 步状态转移矩阵, P' 为 m 阶方阵	$P_{a \rightarrow b}^{(k)}$	马尔可夫链从状态 a 变到状态 b 的 k 步转移概率

1.2 问题描述

交通状况预测模型框架如图 1 所示。其中, H 表示历史交通状况, R 表示实时交通路况, F 表示将来的交通状况。本文要做的是用历史交通状况(H)和实时交通路况(R),预测将来某段时间的交通路况(F),即 $H+R \rightarrow F$ 。

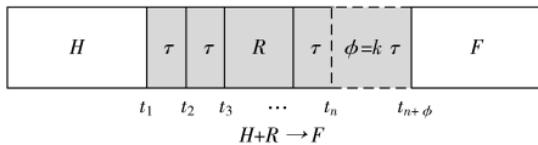


图 1 交通状况预测模型框架

时间间隔定义为:

$$\tau = t_{i+1} - t_i \quad i=1, 2, \dots, n-1 \quad (1)$$

根据实际交通状况,最小时间间隔 τ 通常是固定的(是外部变量,由交通系统自身决定,如 10 min、15 min、30 min 等)。预测间隔 φ 由用户查询时输入,为最小时间间隔 τ 的整数倍,即:

$$\varphi = k\tau \quad k=1, 2, \dots \quad (2)$$

根据上述定义,问题转换为已知历史交通状况和当前交通状况,如何预测第 k 段(即将来 $k\tau$ 时间)路况的问题。根据模型假设,如果已知历史交通状况和当前交通状况,求得初始转移概率矩阵和 k 步状态转移矩阵,便可求得时间间隔 φ 时的交通状况。于是, $\forall y_i \in S, i=1, 2, \dots, n$, 本文将问题转换为:根据已知分布集合 $\{Y_i\}_{i=1}^m$, 预测 Y_{m+k} 的分布,得到转移矩阵:

$$P(Y_{m+k}=y_{m+k} | Y_1=y_1, Y_2=y_2, \dots, Y_m=y_m) \quad (3)$$

其中, m 和 k 是关键指标, m 根据历史数据测算得出或事先给出, k 由用户输入的时间间隔决定。

1.3 实验模型

建模和计算过程如下:

(1)用贝叶斯概率模型计算 S 空间的 m 阶马尔可夫链的 1 步状态转移矩阵 $P^{(1)}$ 。

根据贝叶斯模型理论,状态转移矩阵 $P^{(1)}$ 可由下面公式求出:

$$P^{(1)} = P_{y_1, y_2, \dots, y_m \rightarrow y'_m}^{(1)} = \frac{P(Y_1=y_1, Y_2=y_2, \dots, Y_m=y_m | Y_{m+1}=y'_m) P(Y_{m+1}=y'_m)}{\sum_{z \in S} P(Y_{m+1}=z) P(Y_1=y_1, Y_2=y_2, \dots, Y_m=y_m | Y_{m+1}=z)} \quad (4)$$

举例说明如下,假设状态空间

$S=\{1, 2\}$ (其中 1 表示畅通, 2 表示拥堵),通过历史 GPS 数据可计算出某路线的初始转移概率,得到转移矩阵 $P^{(1)}$,如图 2 所示,其中第 1, 1 行第 2 列的值 $P_{1,1 \rightarrow 2} = 0.125$ 表示从状态 $\{Y_1=1, Y_2=1\}$ 到 $Y_3=2$ 的概率。 $P_{1,1 \rightarrow 2}$ 及 $P^{(1)}$ 中其他元素的值由贝叶斯概率公式求出。

	1	2
1, 1	0.875	0.125
1, 2	0.367	0.633
2, 1	0.563	0.437
2, 2	0.709	0.291

图 2 $P=P^{(1)}$

(2)通过变量的矢量化处理,将 m 阶马尔可夫链转换为 S^m 空间 1 阶马尔可夫链。

将 S 空间上的 m 阶马尔可夫链转换为 S^m 空间 1 阶马尔可夫链^[14],可以简化运算,转换过程如图 3 所示。

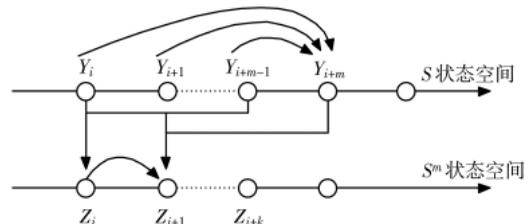


图 3 将 S 空间上的马尔可夫链转换为 S^m 空间的马尔可夫链

接下来,本文计算 S^m 空间上 Z_i 的 1 步状态转移矩阵,计算公式如下:

$$P_{y_1, y_2, \dots, y_m \rightarrow y'_1, y'_2, \dots, y'_m}^{(1)} = P(Z_{i+1}=\{y'_1, y'_2, \dots, y'_m\} | Z_i=\{y_1, y_2, \dots, y_m\}) = \begin{cases} P_{y_1, y_2, \dots, y_m \rightarrow y'_m} & \{y_1, y_2, \dots, y_m\} = \{y'_1, y'_2, \dots, y'_{m-1}\} \\ 0 & \text{其他} \end{cases} \quad (5)$$

其中, $P_{y_1, y_2, \dots, y_m \rightarrow y'_m}$ 是 S 空间中状态转移矩阵 $P^{(1)}$ 中第 y_1, y_2, \dots, y_m 和第 y'_m 列的值。步骤(1)中的状态转移矩阵变化如图 4 所示。

(3)计算 S^m 空间上数列 Z_i 的 k 步状态转移矩阵。

根据 Chapman-Kolmogorov 方程^[13], S^m 空间的 Z_i 的 k 步状态转移矩阵可以由矩阵 P' 自乘 k 次得到($P^{(k)}=P'^k$),即:

	1,1	1,2	2,1	2,2
1,1	0.875	0.125	0	0
1,2	0	0	0.367	0.633
2,1	0.563	0.437	0	0
2,2	0	0	0.709	0.291

图4 $P=P^{(1)}$

$$P'_{y_1, y_2, \dots, y_m \rightarrow y'_1, y'_2, \dots, y'_m} = P^{(k)}_{y_1, y_2, \dots, y_m \rightarrow y'_1, y'_2, \dots, y'_m} \quad (6)$$

如果 $k=4$, 则步骤(1)中在 S^m 空间的 k 步状态转移矩阵转换如图5所示。

	1,1	1,2	2,1	2,2
1,1	0.663	0.129	0.108	0.100
1,2	0.486	0.137	0.191	0.186
2,1	0.581	0.162	0.137	0.120
2,2	0.505	0.134	0.208	0.153

图5 $P^{(4)}=P^4$

(4)将步骤(3)的结果,转换为 S 空间中 m 阶马尔可夫链的 k 步状态转移矩阵 $P^{(k)}$ 。

这一步可以看作是步骤(2)的逆运算,状态转移矩阵计算方法为:

①当 $1 < k < m$ 时,

$$P'_{y_1, y_2, \dots, y_m \rightarrow y'_1, y'_2, \dots, y'_m} = \sum_{y'_{m-k+1}, \dots, y'_{m-1}} P^{(k)}_{y_1, \dots, y_m \rightarrow y_{k+1}, \dots, y_m, y'_{m-k+1}, \dots, y'_{m-1}} \quad (7)$$

②当 $k \geq m$ 时,

$$P'_{y_1, y_2, \dots, y_m \rightarrow y'_1, y'_2, \dots, y'_m} = \sum_{y'_1, \dots, y'_{m-1}} P^{(k)}_{y_1, \dots, y_m \rightarrow y'_{m-1}, \dots, y'_m} \quad (8)$$

根据上述公式,步骤(1)例子的 k 步状态转移矩阵($k=4$)如图6所示。

1.4 模型分析

根据上述模型过程,本文先根据历史记录计算 S 空间中马尔可夫链 $\{Y_i\}$ 的 1 步状态转移矩阵 $P^{(1)}$,当 $k > 1$ 时候,状态转移矩阵 $P^{(k)}$ 和 $P^{(k)}$ 可由上述步骤求得^[15-16]。

计算 $P^{(k)}$ 的时间复杂度为 $O(k \cdot |S|^m)$ (其中 $\epsilon < 2.376$), 这样要比全部用贝叶斯概率模型计算效率高。实际应用中,马尔可夫链的阶数 m 和状态空间 S 的阶数通常是比较小的(如 $m \leq 3, |S| \leq 5$), 所以,步骤(2)~步骤(4)的计算采用在线计算方式,以提高用户相应速度。

计算得出状态转移矩阵后,本文将得到未来某段时间($\varphi=k\tau$)的路况,结合用户的行为分析,可以计算通过某段线路的时间,进而进行最优路线推荐。

2 实验分析

2.1 数据来源及参数配置

(1)数据来源

本文使用的数据来自微软 GeoLife 项目的公开数据

集。它记录了北京市超过 33 000 辆出租车连续 3 个月的 GPS 日志数据,行驶里程超过 4 亿公里, GPS 日志点超过 7.9 亿个,平均间隔为 3.1 min,相邻点平均距离约 600 m^[12]。本文用前两个月的数据作为训练集,抽取第 3 个月的数据作为测试集。本文抽取了 10 个工作日、天气状况良好、5 条道路的所有 GPS 数据作为测试数据集,样本平均时间间隔 3.2 min,相邻点平均距离 627 m。

(2)参数配置

实验中,本文定义最小时间间隔 τ 为 15 min,预测时间间隔 φ 为 τ 的整数倍(如 15 min、30 min 等)(即 k 取 1, 2 等),马尔可夫链的阶数 m 取 1、2、3、4,分别进行测试。

2.2 模型评价

2.2.1 比较对象

本文的预测方法分别与 T-Drive 方法^[12]、ARIMA 方法^[13]进行比较。ARIMA 方法是著名的交通状况基础预测方法,它依靠当前交通状况信息(通过 GPS、高速公路探测器等获得),预测将来某段时间的交通状况;T-Drive 方法通过对历史 GPS 日志信息的分析,挖掘交通模式,然后根据其分布预测某时段、某路线的交通状况。

2.2.2 评价方法

本文用均方根误差(Root Mean Square Error, RMSE)来评价预测结果的准确性,定义:

$$RMSE = \sqrt{\frac{1}{N} \sum_i (x_i^* - x_i)^2} \quad (9)$$

其中, N 为预测个数, x_i^* 预测值, x_i 为真实值。

(1)预测时间:分别用本文的预测模型和其他预测模型来预测将来某时间段、某段路线(可以是道路的组合)的通过时间(x_i^*)。

(2)基准行驶时间:考虑到工作日与非工作日、时间段、天气状况、驾驶员经验等因素对行驶时间的影响,本文选择同一时间段、同一线路上所有出租车(配置了 GPS)的平均通过时间作为基准通过时间(x_i)。

2.2.3 评价结果

本文分别用时间段、不同时间间隔 φ (因为 $\varphi=k\tau$, τ 由外部因素决定, k 变化引起 φ 的变化)下 3 种方法的 RMSE 进行比较(根据 RMSE 的定义, RMSE 越低,预测的准确率越高),然后分析 m (马尔可夫链的阶数)取值不同,对本文的模型预测结果准确率的影响。

图7描述了时间间隔 φ 固定时(实验中 $\varphi=60$ min), 3 种方法在工作日不同时间段的 RMSE 值。结果显示,本文方法比 ARIMA 方法和 T-Drive 方法要优异,特别是高峰时段(AM7:30-AM9:30)。

图8描述了时间间隔 φ 对预测误差的影响。随着时间增加,3 种方法的误差都在增大,但本文的方法误差更小。换句话说,在相同的误差要求下,本文可以预测更长时间的交通状况。

图9描述了马尔可夫链的阶数选择对准确性的影

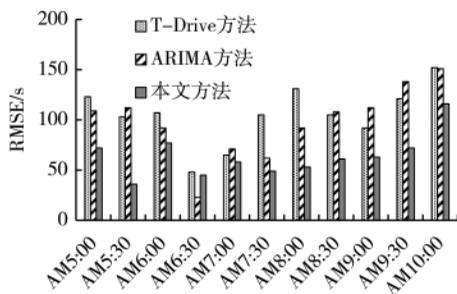


图7 $\varphi=60$ min 时, 3种方法的 RMSE 比较

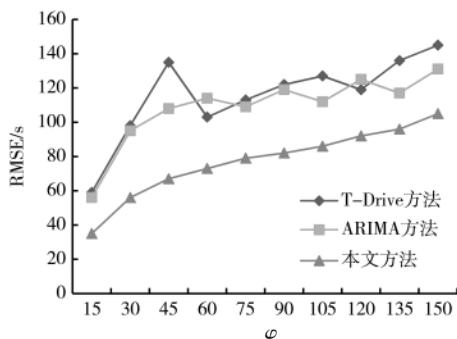


图8 φ 取不同值下 3种方法的 RMSE 比较 ($\tau=15$ min)

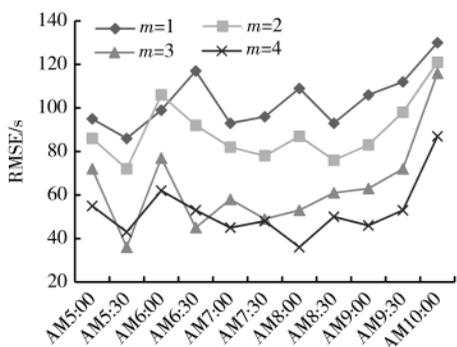


图9 m 的不同取值对 RMSE 的影响

响。结果显示,其他环境不变时, m 取值越大,结果越准确。这与时间情况是一致的,一段时间以后的交通状况不仅受到当前交通状况的影响,也受到之前若干时间交通状况的影响。但 m 取值越大,意味着计算的难度越大。

3 结论

准确预测未来某段时间的交通路况是进行路线推荐的前提和关键,本文提供了一种基于多阶马尔可夫链的交通状态预测方法。作为一个对实用效果要求很高的课题,为提高模型运算速度,提高对用户的响应速度,对历史数据进行预处理、预计算(初始状态转移矩阵等结果存放在服务器中),确定好用户的始发地和目的地后,本文对其各条可能路线、未来某段时间的交通路况进行在线运算。运算过程中,本文将多阶马尔可夫链转换为一阶马尔可夫链,进一步提高了运算效率。实验表明,即使采用较小的阶数,也可以得出比较准确的结果,因此本文的方法是行之有效的。

参考文献

- [1] KANOULAS E, DU Y, XIA T, et al. Finding fastest paths on a road network with speed patterns[C]//22nd International Conference on IEEE Computer Society, 2006.
- [2] PFOSE D, BRAKATSOULAS S, BROSCHE P, et al. Dynamic travel time provision for road networks[C]//International Symposium on Advances in Geographic Information Systems. ACM, 2008.
- [3] GUEHNEMANN A, SCHAEFER R P, THIESSENHUSEN K U, et al. Monitoring traffic and emissions by floating car data[C]//Institute of Transport Studies Working Paper, 2004.
- [4] CASTRO-NETO M, JEONG Y S, JEONG M K, et al. Online-SVR for short-term traffic prediction under typical and atypical traffic conditions[J]. Expert Systems with Applications, 2009, 36(3): 6164-6173.
- [5] BEJAN A I, GIBBENS R J, EVANS D, et al. Statistical modeling and analysis of sparse bus probe data in urban areas[C]//International Conference on Intelligent Transportation Systems. IEEE, 2010.
- [6] HERRERA J C, WORK D B, HERRING R, et al. Evaluation of traffic data obtained via GPS-enabled mobile phones: the Mobile Century field experiment[J]. Transportation Research, 2010, 18(4): 568-583.
- [7] ZIEBART B, MAAS A, DEY A, et al. Navigate like a cabbie: probabilistic reasoning from observed context-aware behavior[C]//10th International Conference. ACM, 2008.
- [8] KRUMM J, HORVITZ E. Predestination: inferring destinations from partial trajectories[J]. LNCS, 2006, 4206: 243-260.
- [9] ZHENG Y, CHEN Y, LI Q, et al. Understanding transportation modes based on GPS data for Web applications[J]. ACM Transactions on the Web, 2010, 4(1): 1-36.
- [10] GONZALEZ H, HAN J, LI X, et al. Adaptive fastest path computation on a road network: a traffic mining approach[C]//33rd International Conference on Very Large Data Bases, 2007.
- [11] LETCHNER J, KRUMM J, HORVITZ E. Trip router with individualized preferences (TRIP): incorporating personalization into route planning[C]. 18th Innovative Applications of Artificial Intelligence Conference DBLP, 2006.
- [12] YUAN J, ZHENG Y, ZHANG C, et al. T-drive: driving directions based on taxi trajectories[C]//18th International Symposium on Advances in Geographic Information Systems, ACM-GIS, 2010.
- [13] YUAN J, ZHENG Y, XIE X, et al. Driving with knowledge from the physical world[C]//Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2011: 316-324.
- [14] RAFTERY A E. A model for high-order Markov chains[J].

(下转第 36 页)

非期望方向上的干扰语音抑制更加明显,也因此识别率结果更好。

4 结论

本文针对多说话人分离场景,以期望方向语音信号的FFT-log-magnitude作为目标,用来训练出模型在期望方向上的空间传输特性。分别在仿真数据和实测数据测试下与传统波束形成算法对比,本文所提深度学习波束形成器具有更好的波束形成能力,不同信干比和混响条件下语音识别率更高,在非期望方向上展现了更好的干扰抑制效果,验证了深度学习波束形成提高多说话人分离效果的有效性。

也需要指出,由于当前尚缺乏具有一定代表性、数量较大的麦阵数据库,本文模型训练数据较少,影响了所提方法性能改善的充分发挥及评估。下一步将以不同方式进一步扩充训练数据,提高模型泛化性。

参考文献

- [1] 朱民雄, 闻新. 计算机语音技术[M]. 北京: 北京航空航天大学出版社, 2002.
- [2] KHALIL F, JULLIEN J P, GILLOIRE A. Microphone array for sound pickup in teleconference systems[J]. Journal of the Audio Engineering Society, 1994, 42(9): 691-700.
- [3] JIANG Y, WANG D L, LIU R S, et al. Binaural classification for reverberant speech segregation using deep neural networks[J]. IEEE/ACM Transactions on Audio Speech & Language Processing, 2014, 22(12): 2112-2121.
- [4] XIAO X, WATANABE S, ERDOGAN H, et al. Deep beam-forming networks for multi-channel speech recognition[C]// IEEE International Conference on Acoustics, Speech and Signal Processing, 2016: 5745-5749.
- [5] RAVANELLI M, BRAKEL P, OMOLOGO M, et al. A network of deep neural networks for Distant Speech Recognition[C]//

2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2017.

- [6] HUANG P S, KIM M, HASEGAWA-JOHNSON M, et al. Deep learning for monaural speech separation[C]// ICASSP IEEE International Conference on Acoustics, 2014.
- [7] KOLBK M, Yu Dong, Tan Zhenghua, et al. Multitalker speech separation with utterance-level permutation invariant training of deep recurrent neural networks[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2017, 25(10): 1901-1913.
- [8] WANG D L, CHEN J. Supervised speech separation based on deep learning: An overview[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 26(10): 1702-1726.
- [9] 章宇栋. 面向语音交互的麦克风阵列声源定位及波束形成研究[D]. 厦门: 厦门大学, 2019.
- [10] ALLEN J B, BERKLEY D A. Image method for efficiently simulating small-room acoustics[J]. The Journal of the Acoustical Society of America, 1998, 65(4): 943-950.
- [11] HONG Q, LI L, LI M, et al. Modified-prior PLDA and score calibration for duration mismatch compensation in speaker recognition system[C]// Interspeech, 2015.

(收稿日期: 2021-11-29)

作者简介:

张家扬(1998-), 男, 硕士研究生, 主要研究方向: 麦克风阵列、语音增强。

董峰(1973-), 通信作者, 男, 博士, 教授, 主要研究方向: 水声通信与网络、声探测与感知、智能语音处理, E-mail: ftong@xmu.edu.cn。

陈东升(1975-), 男, 硕士, 助理教授, 主要研究方向: 水声通信、声信号处理。



扫码下载电子文档

(上接第 30 页)

Journal of the Royal Statistical Society, 1985, 47(3): 528-539.

- [15] KARLIN S, TAYLOR H M. A first course in stochastic processes[M]. Second Edition Academic Press, 1975: 15-30.
- [16] COPPERSMITH D, WINOGRAD S. Matrix multiplication via arithmetic progressions[J]. Journal of Symbolic Computation,

1990, 9(3): 251-280.

(收稿日期: 2021-07-09)

作者简介:

周明升(1981-), 男, 博士, 高级工程师, 主要研究方向: 智慧城市、决策支持。

刘抒扬(2000-), 男, 本科, 主要研究方向: 大数据、数据分析和预测。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所