

基于能力区域的交通状态预测方法*

刘擎超[†] 陆建 陈淑燕

1) (东南大学城市智能交通江苏省重点实验室, 南京 210096)

2) (现代城市交通技术江苏高校协同创新中心, 南京 210096)

(2013年11月20日收到; 2014年3月6日收到修改稿)

交通状态预测是交通流诱导和交通信息发布系统的重要依据. 本文提出了一种基于能力区域的城市快速路交通状态预测方法, 该方法通过构建神经网络分类器的能力区域, 根据样本数据与交通状态类簇之间的空间距离, 预测道路交通状态等级. 神经网络分类器的能力区域能够有效融合时间、空间等多种特征, 并且不需要考虑各特征之间的相关性, 具有很强的适应性. 实验结果表明, 与经典的预测方法相比, 其预测误差明显降低, 均等系数增大, 基于能力区域的方法预测交通状态具有较高的准确性.

关键词: 交通状态, 预测, 交通参数, 聚类

PACS: 05.45.Tp, 45.70.Vn, 88.10.gc

DOI: 10.7498/aps.63.140504

1 引言

对城市道路交通状态进行预测是交通指挥、交通引导和交通控制的基础, 是出行信息服务系统的重要内容. 其中, 不仅为交通管理系统提供实时路网交通状态信息, 同时可以作为道路交通规划的参考^[1]. 随着社会经济不断发展, 机动车保有量急剧增加, 使得道路交通压力愈来愈大, 交通拥堵问题越来越突出. 如何对未来一段时间内交通流状态的变化趋势进行准确预测, 是制定拥堵缓解措施的重要基础之一^[2,3], 对于做到早发现、早预防、早处理具有重要的学术意义和实用价值^[4-7].

近年来国内外交通领域学者已形成了多种行之有效的交通流预测方法, 如指数平滑法(exponential smoothing, ES)^[8]、自回归模型(autoregressive, AR)^[9]、移动平均模型(moving average, MA)^[10]、自回归滑动平均模型(autoregressive moving average model, ARMA)^[11]、时间序列模型^[12]、多层前向反馈神经网络模型(multilayer feed forward neural network, MLFNN)^[13]、径向基函数神

神经网络模型(radical basis function neural network, RBFNN)^[14]等. 但对于出行者来说, 并不需要知道交通流的具体参数, 交通状态等级对于他们更有意义. 基于上述分析, 交通状态预测完全可以转换为一种模式分类问题, 有几种交通状态, 就分为几种类别^[15]. 这样可以引入强大的机器学习算法, 以提高预测的准确性. 本文基于这个思想提出了基于能力区域(region of competence, ROC)的交通状态预测方法.

2 交通运行状态的分级描述

美国的《道路通行能力手册》(Highway Capacity Manual, HCM)提出了描述车辆之间的运行条件及其驾驶员和乘客的主观感觉的质量测定标准——道路交通服务水平(level of service), 即从速度、行驶时间、驾驶自由度、交通间断、舒适、方便等方面所得到的服务程度. 我国公安部2002年公布的《城市交通管理评价指标体系》中规定, 用城市主干路上机动车的平均行程速度来描述其交通拥挤程度.

* 国家高技术研究发展计划(批准号: 2011AA110302)和江苏省普通高校研究生科研创新计划(批准号: CXZZ13_0119)资助的课题.

[†] 通讯作者. E-mail: uiodo@hotmail.com

本文采用北京城市道路交通运行评价指标体系的划分等级,按照 GB50220-1995 划分的道路等级,以不高于 15 min 为统计间隔,计算道路网中各路段的平均行程速度并将道路交通状态划分为五级,分别为:畅通、基本畅通、轻度拥堵、中度拥堵、严重拥堵.用 1 到 5 五个数字表示,每个数字代表一级即一个交通状态.如图 1 所示,其中 1 级交通状态表示交通运行水平最好的,而 5 级的交通运行状态是最差的达到严重拥堵的程度.路段交通运行等级的划分如表 1 所示.

3 基于能力区域的交通状态预测

3.1 基本思想及模型框架

该方法的主要思想是:首先,综合分析大量历史数据,抽取出其中能够对交通状态准确描述的特征量,形成特征数据库,该特征数据库包含道路的空间特征,以及各类交通状态变化趋势等典型的时间规律特征;其次在训练模型阶段,利用聚类技术

对训练样本空间进行划分,以此作为神经网络分类器的 ROC. 然后计算各个 ROC 的聚类中心并标注出这些 ROC 中预测性能最突出的神经网络分类器.最后在预测阶段,计算待预测样本与各个 ROC 的聚类中心之间的距离,选择距离最小的 ROC 对应的神经网络分类器对其进行预测.基于 ROC 的交通状态预测技术路线如图 2 所示.

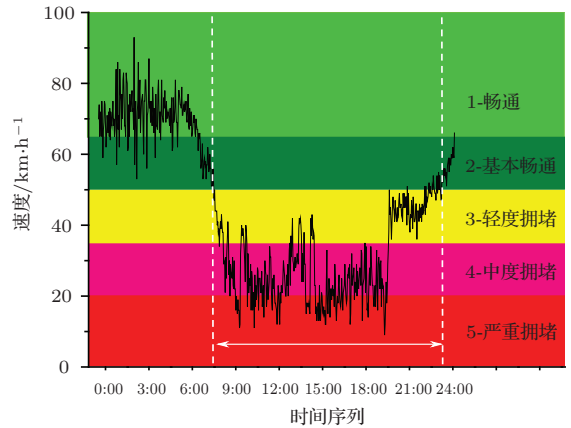


图 1 交通状态等级图示

表 1 路段交通运行等级划分 (V 表示路段平均行程速度,单位: km/h)

| 运行等级 | 畅通 | 基本畅通 | 轻度拥堵 | 中度拥堵 | 严重拥堵 |
|--------|----------|------------------|------------------|------------------|-------------|
| 快速路 | $V > 65$ | $50 < V \leq 65$ | $35 < V \leq 50$ | $20 < V \leq 35$ | $V \leq 20$ |
| 主干路 | $V > 40$ | $30 < V \leq 40$ | $20 < V \leq 30$ | $15 < V \leq 20$ | $V \leq 15$ |
| 次干路、支路 | $V > 35$ | $25 < V \leq 35$ | $15 < V \leq 25$ | $10 < V \leq 15$ | $V \leq 10$ |

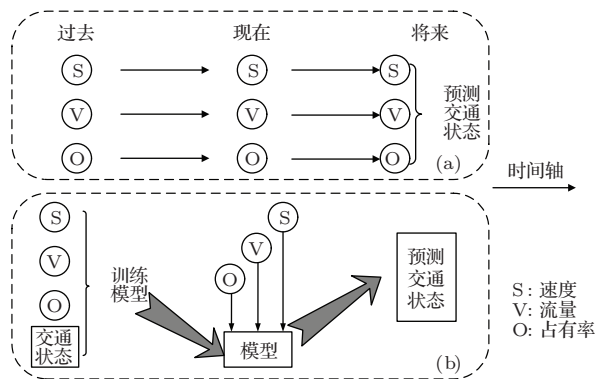


图 2 (a) 经典算法的技术路线; (b) 基于 ROC 的技术路线

3.2 基于能力区域的道路交通状态预测

假设神经网络分类器集合为 $D = \{D_1, \dots, D_L\}$, $\Omega = \{\omega_1, \dots, \omega_c\}$ 是一组交通状态标签 [16]. 因此交通状态预测的问题可以表示为分类器将特征向量 $x \in \mathfrak{R}^n$ 赋值为 Ω 中的一个类

标签,即 $D_i: \mathfrak{R}^n \rightarrow \Omega$. 在许多情形下,分类器输出为一个 c 维向量: $D_i(x) = [d_{i,1}(x), \dots, d_{i,c}(x)]^T$. 不失一般性, $d_{i,j}(x)$ 可以用后验概率 $P(\omega_j|x)$ 表示,即分类器 D_i 预测样本 x 属于类别 ω_j 的可能性. 现在假设特征空间 \mathfrak{R}^n 被划分为 $K (K > 1)$ 个 ROC, 标记为 R_1, \dots, R_K , 这些区域不是分类区域,也没有固定的大小和形状.

图 3 给出了特征空间被划分为四个 ROC 和两个“分类区域”的例子. 该特征空间内共有 15 个数据点,它们分别属于两个类别,用方块和雪花表示. 四个 ROC 分别为 R_1, R_2, R_3 和 R_4 . 在训练阶段,我们需要做的是为这些 ROC 标注出性能较好的神经网络分类器. 注意,神经网络分类器的个数 L 并不一定与 ROC 的个数 K 相同. 也就是说,一些分类器有可能永远不会被选中以用于待预测样本的预测,这样的分类器甚至可能包括在整个

特征空间上具有最高平均准确率的分类器. 反过来, 有可能一个分类器被不止一次选中. 假设 D^* 表示的是神经网络分类器集合 D 中在整个特征空间 \mathfrak{R}^n 上具有最高平均准确率的分类器. $P(D_i|R_j)$ 是分类器 D_i 在能力区域 R_j 上的正确分类的概率. $D_{i(j)} \in D$ 是负责能力区域 R_j ($j = 1, \dots, K$) 的基分类器, 则整个分类器选择方法的正确分类概率为^[17]

$$P_c = \sum_{j=1}^K P(R_j)P_c(R_j) = \sum_{j=1}^K P(R_j)P(D_{i(j)}|R_j), \quad (1)$$

$P(R_j)$ 是样本 x 落入“能力区域” R_j 中的概率, 为了最大化 P_c , 需要 $D_{i(j)}$ 满足:

$$P(D_{i(j)}|R_j) \geq P(D_t|R_j) \quad \forall t = 1, \dots, L. \quad (2)$$

根据 (1) 和 (2) 式, 容易得出:

$$P_c \geq \sum_{j=1}^K P(R_j)P(D^*|R_j) = P(D^*). \quad (3)$$

从 (3) 式不难看出, 不管特征空间怎么划分, 分类器选择方法的性能总是要好于神经网络分类器集成 D 中平均性能最优的分类器, 只要 $D_{i(j)}$ 是能力区域 R_j 上分类性能最优的基分类器. 上述条件的满足程度决定了分类器选择方法的成功与否. 一般而言, 能力区域可以通过竞争学习 (competitive learning)^[18] 或简单的 c 均值聚类算法来实现.

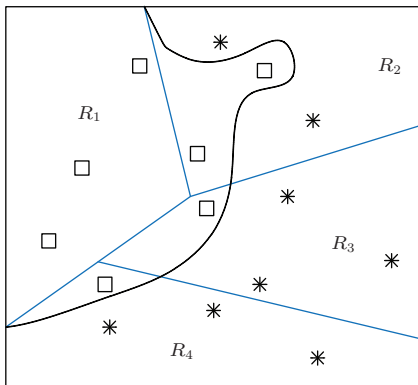


图3 特征空间被划分为四个“能力区域”和两个“分类区域”^[16]

3.3 距离度量

距离度量即衡量个体在空间上存在的距离, 常用于衡量个体之间的差异性大小, 距离越远说明个体间的差异越大. 距离度量常用于计算多维空间

各个点之间的绝对距离, 一般不加单位量纲. 常见距离度量有3种: 欧式距离、曼哈顿距离、切比雪夫距离.

1) 欧氏距离 (Euclidean distance)

欧几里德距离即欧氏距离是最常见的距离度量, 计算基于各维度特征的绝对数值, 所以欧氏度量需要保证各维度指标在相同的刻度级别. 欧氏距离 $\text{Distance}_E(X, Y)$ 计算公式下

$$\text{Distance}_E(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}. \quad (4)$$

2) 曼哈顿距离 (Manhattan distance)

曼哈顿距离来源于城市区块距离, 是将多个维度上的距离进行求和后的结果, 计算曼哈顿距离 $\text{Distance}_M(X, Y)$ 的公式如下:

$$\text{Distance}_M(X, Y) = \sum_{i=1}^n |x_i - y_i|. \quad (5)$$

3) 切比雪夫距离 (Chebyshev distance)

切比雪夫距离起源于国际象棋中国王的走法. 切比雪夫距离 $\text{Distance}_C(X, Y)$ 计算公式为

$$\begin{aligned} \text{Distance}_C(X, Y) &= \lim_{p \rightarrow \infty} \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \\ &= \max_{i=1}^n |x_i - y_i|. \end{aligned} \quad (6)$$

4 实验验证及其效果分析

本文选取北京市东三环路网中的重要路段, 时间从2012年7月至2012年8月的交通流数据作为训练样本和验证样本. 选取路网中路段: 北太平庄(外环)→安贞桥东, 2012年8月8日全天716个交通状态数据作为测试样本. 其下一时刻交通状态预测的可行性和可靠性不仅对交通信号的实时控制决策具有关键的作用, 而且对交通诱导具有很大的影响, 因此, 利用安装在路段上的微波检测器所提供的平均车流量 {volume}、平均占有率 {occupancy}、平均车速 {speed} 三个参数时间序列为研究对象, 研究该路段在相同时间序列内的交通状态的变化趋势, 以便于及时采取措施, 避免交通拥堵.

交通流检测数据每2 min 一组, 每组数据每天产生716个记录, 绘制其一天的实测参数时间序列及其对应的交通状态如图4(a)—(c)所示, 分别为车道1、车道2、车道3交通状态时间序列的变化. 显

然, 不同车道描述交通状态存在差异, 且不能全面准确地反映实际情况, 所以尝试不同车道独立估算交通流状态.

按照上述交通状态预测算法对其进行分析. 构建交通流数据库, 每个断面的交通流数据以流量、速度和占有率的顺序依次存放. 如矩阵 (7) 所示, D 为交通流三参数数据, Ω 为交通状态.

$$D = [d_1 \ d_2 \ d_3] = \begin{bmatrix} \text{流量}_1 & \text{速度}_1 & \text{占有率}_1 \\ \text{流量}_2 & \text{速度}_2 & \text{占有率}_2 \\ \text{流量}_3 & \text{速度}_3 & \text{占有率}_3 \\ \vdots & \vdots & \vdots \\ \text{流量}_n & \text{速度}_n & \text{占有率}_n \end{bmatrix},$$

$$\Omega = \begin{bmatrix} \Omega_1 \\ \Omega_2 \\ \Omega_3 \\ \vdots \\ \Omega_n \end{bmatrix} = \begin{bmatrix} \text{交通状态}_1 \\ \text{交通状态}_2 \\ \text{交通状态}_3 \\ \vdots \\ \text{交通状态}_n \end{bmatrix}. \quad (7)$$

依据速度属性采用 K -means 聚类算法对采集到的历史数据进行交通状态等级划分. 如图 5 (a) 和 (b) 所示, 不同的颜色代表不同的交通状态, 聚类后随着速度的降低, 呈现出的趋势与交通流理论

相符合, 这为进一步分析预测交通状态等级提供了基础.

根据 K -means 算法聚类后, 计算不同车道数据 (车道 1, 2, 3 为上行车道, 车道 4, 5, 6 为下行车道) 的交通状态类簇中心, 如表 (2) 所示, 中心点的维度为三维, 分别表示流量、速度和占有率三个交通流参数.

从五种不同交通状态类簇中, 分别构建神经网络分类器, 并采用验证集样本进行分类器选择. 从中选取预测精度最高的神经网络分类器作为该交通状态类簇的最优分类器. 以上行车道 1, 2, 3 为例, 选择欧氏距离公式计算待预测样本与各个交通状态的之间的距离, 选取与对应交通状态簇中心距离最近的交通状态作为预测状态. 图 6 (a), (b) 分别为车道 1 数据待预测样本与五种交通状态的距离时序图, 其中图 6 (b) 为距离小于 25 的局部时序图, 图 6 (c) 和 6 (d), 6 (e) 和 6 (f) 依次为车道 2 和车道 3. 从图 6 (a), (c) 和 (e) 中可以看出, 早高峰时段车道 1 和车道 2 的运行状态为畅通, 车道 3 的状态为基本畅通; 从图 6 (b), (d) 和 (f) 中可以看出, 晚高峰时段三个车道都处于拥堵的状态, 车道 1 基本是处于严重拥堵的状态, 车道 2 是三种拥堵状态交替, 车道 3 是先中度拥堵后严重拥堵.




图 4 不同车道的交通状态时间序列变化趋势

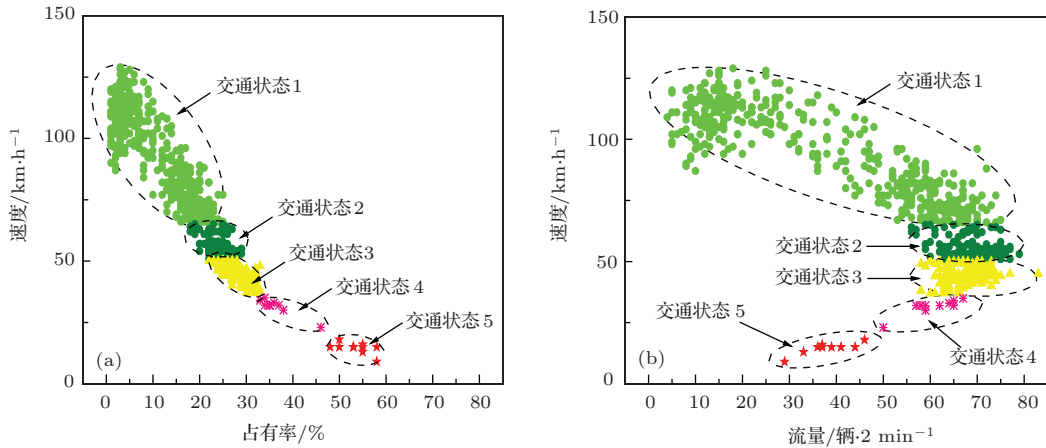


图 5 (a) 交通流速度-占有率; (b) 交通流速度-流量

表2 欧氏距离度量下的交通状态簇中心点

| 车道编号 | 交通状态簇中心点 | | | | |
|------|------------|------------|------------|------------|------------|
| | 状态 1 | 状态 2 | 状态 3 | 状态 4 | 状态 5 |
| 车道 1 | (4,99,1) | (66,60,23) | (31,40,23) | (42,24,41) | (18,8,57) |
| 车道 2 | (18,112,4) | (77,55,25) | (58,49,23) | (59,30,38) | (29,9,58) |
| 车道 3 | (1,91,1) | (59,59,12) | (35,50,9) | (54,28,31) | (40,10,60) |
| 车道 4 | (1,95,1) | (39,63,7) | (60,50,14) | (45,29,39) | (22,9,70) |
| 车道 5 | (11,91,3) | (66,65,18) | (43,44,26) | (57,29,36) | (42,20,45) |
| 车道 6 | (2,81,1) | (14,52,5) | (36,49,13) | (50,26,33) | (21,4,60) |

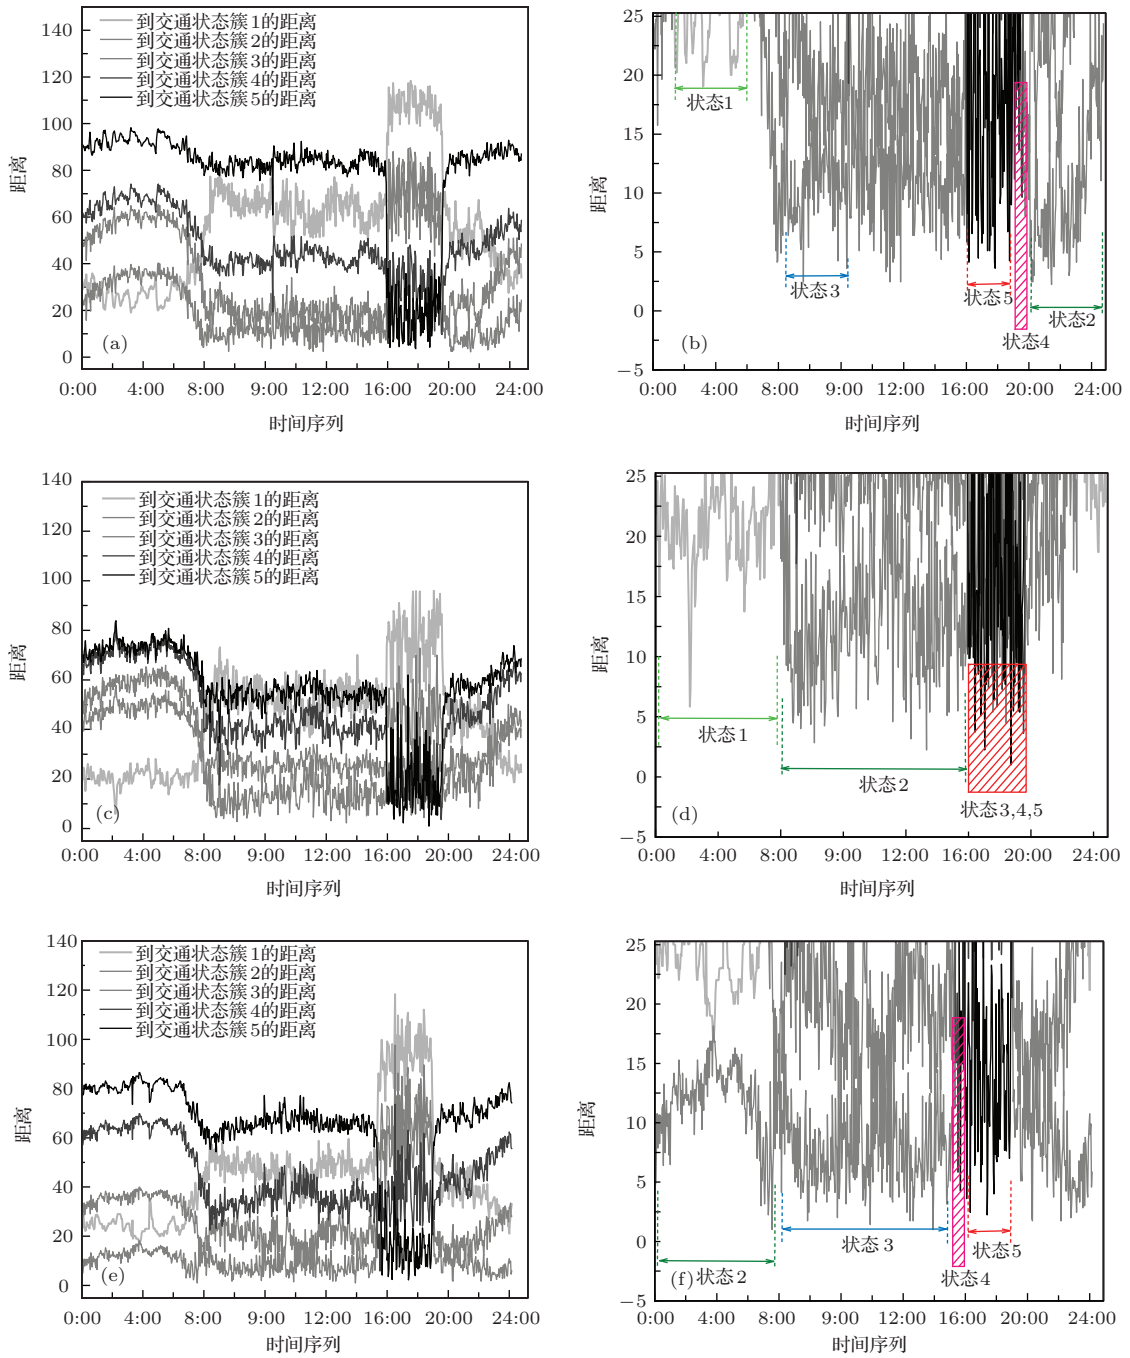


图6 (a), (b) 车道 1 的距离时序; (c), (d) 车道 2 的距离时序; (e), (f) 车道 3 的距离时序

为了进行对比分析,采用MAPE (mean absolute percentage error)、EC (equality coefficient) 指标来评价道路交通状态的预测精度. MAPE采用了百分比误差,其误差值与实际测量值的单位和量值大小无关. EC表示预测值与实际值的拟合度,一般0.9以上为较好拟合. 表达式(8), (9)为MAPE, EC的对应的计算公式. 通过三种不同的距离度量方法,对预测值和实际值进行比较,实例预测性能的检测结果见表3—5,表3采用Euclidean度量,表4采用Manhattan度量,表5采用Chebyshev度量.

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(Y_i - \hat{Y}_i)/Y_i|, \quad (8)$$

$$EC = 1 - \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\left(\sqrt{\sum_{i=1}^n Y_i^2} + \sqrt{\sum_{i=1}^n \hat{Y}_i^2}\right)}}. \quad (9)$$

在表3—5中,偏1表示预测的交通状态与实际的交通状态相差1个等级,以此类推,偏3表示预测的交通状态与实际的交通状态相差3个等级. 从表3—5中的EC值可以看出,车道6的偏0分布最

少,也就是预测精度最低,车道2, 3, 6中的偏3分布为0,其对应的EC值要高于其他车道的EC值,但是车道6由于偏2的预测多于车道2, 3,所以影响了EC值,也就是说提高预测精度需要减少偏2、偏3的概率. 再看MAPE值,不管是上行车道还是下行车道,MAPE的值在4.9%—8.3%之间波动,反映了基于能力区域的神经网络分类器选择方法的有效性.

通过以上实验表明,不同的距离度量方法的预测结果偏差不是很大,相对优秀的是Manhattan度量方法. 表6列举了6种常见的预测算法,其中ES, AR, MA, ARMA为近年来学者采用较多的交通状态时间序列预测方法,MLFNN和RBFNN为学者们采用较多的神经网络预测方法. 实验采用车道1数据,并选取Manhattan度量. ROC-NN在MAPE有优势,EC值ARMA方法结果最好,ROC-NN相对ES, AR, MA, ARMA预测算法处于弱势. 从神经网络层面分析,ROC-NN又高于MLFNN和RBFNN. 综合以上实验可知,ROC-NN预测结果能够很好地反映交通流量变化的趋势和规律,预测精度高,可以用于交通状态预测,具有很强的竞争力.

表3 基于Euclidean度量的预测误差分析

| 车道编号 | MAPE/% | 预测误差的分布/% | | | | EC/% |
|------|--------|-----------|--------|-------|-------|--------|
| | | 偏0 | 偏1 | 偏2 | ≥偏3 | |
| 车道1 | 6.724 | 90.542 | 9.179 | 0.139 | 0.139 | 99.141 |
| 车道2 | 5.013 | 89.707 | 10.013 | 0.278 | 0 | 99.234 |
| 车道3 | 6.334 | 89.539 | 10.321 | 0.139 | 0 | 99.306 |
| 车道4 | 6.073 | 87.204 | 4.728 | 0 | 8.066 | 95.703 |
| 车道5 | 7.818 | 86.926 | 2.642 | 7.510 | 2.921 | 95.839 |
| 车道6 | 8.203 | 77.272 | 13.920 | 8.806 | 0 | 98.503 |
| 平均 | 6.694 | 86.865 | 8.467 | 2.812 | 1.854 | 97.954 |

表4 基于Manhattan度量的预测误差分析

| 车道编号 | MAPE/% | 预测误差的分布/% | | | | EC/% |
|------|--------|-----------|--------|-------|-------|--------|
| | | 偏0 | 偏1 | 偏2 | ≥偏3 | |
| 车道1 | 6.724 | 90.542 | 9.179 | 0.139 | 0.139 | 99.141 |
| 车道2 | 4.944 | 89.847 | 9.875 | 0.278 | 0 | 99.244 |
| 车道3 | 6.055 | 89.958 | 9.763 | 0.279 | 0 | 99.309 |
| 车道4 | 6.240 | 87.204 | 4.311 | 0 | 8.484 | 95.484 |
| 车道5 | 7.541 | 87.065 | 2.643 | 7.371 | 2.921 | 95.874 |
| 车道6 | 8.146 | 77.273 | 14.205 | 8.523 | 0 | 98.531 |
| 平均 | 6.608 | 86.982 | 8.329 | 2.765 | 1.924 | 97.931 |

表5 基于 Chebyshev 度量的预测误差分析

| 车道编号 | MAPE/% | 预测误差的分布/% | | | | EC/% |
|------|--------|-----------|--------|-------|-------|--------|
| | | 偏0 | 偏1 | 偏2 | ≥ 偏3 | |
| 车道 1 | 6.655 | 90.681 | 9.179 | 0 | 0.139 | 99.187 |
| 车道 2 | 5.013 | 89.707 | 10.013 | 0.278 | 0 | 99.234 |
| 车道 3 | 6.055 | 89.818 | 10.041 | 0.139 | 0 | 99.323 |
| 车道 4 | 5.915 | 87.343 | 4.868 | 0 | 7.789 | 95.858 |
| 车道 5 | 8.131 | 86.509 | 2.921 | 7.788 | 2.781 | 95.814 |
| 车道 6 | 8.125 | 77.556 | 13.494 | 8.949 | 0 | 98.497 |
| 平均 | 6.649 | 86.936 | 8.419 | 2.859 | 1.785 | 97.986 |

表6 不同交通状态预测方法比较

| 评价指标 | 交通状态预测方法 | | | | | | |
|--------|----------|--------|--------|---------------|--------|--------|--------------|
| | ES | AR | MA | ARMA | MLFNN | RBFNN | ROC-NN |
| MAPE/% | 8.874 | 9.870 | 13.602 | 8.743 | 11.968 | 13.751 | 6.724 |
| EC/% | 99.886 | 99.882 | 99.211 | 99.891 | 98.993 | 98.814 | 99.141 |

5 结 论

交通状态预测在城市交通管理和诱导中起着十分重要的作用. 本文提出了基于能力区域的神经网络分类器的交通状态预测方法, 基于历史和现在的道路交通信息预测将来某一时间的交通状态等级. 该方法能够有效融合时间、空间等多种特征, 具有很强的适应性. 实验结果表明, 依据待预测实例与五种交通状态类簇中心的距离, 动态地选择最优神经网络分类器, 该模型能够更好地预测交通状态, 其预测性能和精度都有所提高, 在交通状态预测中具有良好的推广价值.

参考文献

[1] Wang X Y 2010 *Ph. D. Dissertation* (Changchun: Jilin University) (in Chinese) [王新颖 2010 博士学位论文(长春: 吉林大学)]
 [2] Zhang H B, Sun X D, He Y L 2014 *Acta Phys. Sin.* **63** 040505 (in Chinese) [张洪宾, 孙小端, 贺玉龙 2014 物理学报 **63** 040505]
 [3] Zhang Y M, Wu X J, Bai S L 2013 *Acta Phys. Sin.* **62** 190509 (in Chinese) [张玉梅, 吴晓军, 白树林 2013 物理学报 **62** 190509]
 [4] Ma Q L, Liu W N, Sun D H 2012 *Acta Phys. Sin.* **61** 169501 (in Chinese) [马庆禄, 刘卫宁, 孙棣华 2012 物理学报 **61** 169501]

[5] Bi J, Guan W 2012 *Chin. Phys. B* **21** 068901
 [6] Zhang Y, Guan W 2009 *Acta Phys. Sin.* **58** 756 (in Chinese) [张勇, 关伟 2009 物理学报 **58** 756]
 [7] Cong R, Liu S L, Ma R 2008 *Acta Phys. Sin.* **57** 7487 (in Chinese) [从蕊, 刘树林, 马锐 2008 物理学报 **57** 7487]
 [8] Qi C, Hou Z S 2012 *Cont Theo. Applic* **29** 465 (in Chinese) [齐驰, 侯忠生 2012 控制理论与应用 **29** 465]
 [9] Yao Z S, Shao C F 2007 *China J. High. Trans.* **20** 113 (in Chinese) [姚智胜, 邵春福 2007 中国公路学报 **20** 113]
 [10] Xie J, Wu W 2011 *J. Tongji Univ. (Nature Science)* **39** 1297 (in Chinese) [谢军, 吴伟 2011 同济大学学报(自然科学版) **39** 1297]
 [11] Ma L C, Xu W L 2011 *Cont. Deci.* **26** 789 (in Chinese) [马林才, 许玮珑 2011 控制与决策 **26** 789]
 [12] Zang L L, Jia L 2007 *China J. High. Trans.* **20** 95 (in Chinese) [臧利林, 贾磊 2007 中国公路学报 **20** 95]
 [13] Shen G J, Wang X H, Kong X J 2011 *Sys. Eng. Theor. Pract.* **31** 561 (in Chinese) [沈国江, 王啸虎, 孔祥杰 2011 系统工程理论与实践 **31** 561]
 [14] Ding H, Zhang W H, Zheng X Y 2012 *China J. High. Trans.* **25** 126 (in Chinese) [丁恒, 张卫华, 郑小燕 2012 中国公路学报 **25** 126]
 [15] Don H H, Jia L M 2010 *J. Trans. Sys. Eng. Info. Tech.* **10** 112 (in Chinese) [董宏辉, 贾利民 2010 交通运输系统工程与信息 **10** 112]
 [16] Kuncheva L I 2000 *Proceedings of 4th International Conference on Knowledge Based Intelligent Engineering Systems and Allied Technologies* Brighton, UK, Aug 30–Sept 1, 2000 p185
 [17] Kuncheva L I 2002 *IEEE Trans. Sys. M. and Cyber. Part B: Cyber.* **2** 146
 [18] Verikas A, Lipnickas A, Malmqvist K 1999 *Patt. Recog. Lett.* **4** 429

Traffic state prediction based on competence region*

Liu Qing-Chao[†] Lu Jian Chen Shu-Yan

1) (*Jiangsu Key Laboratory of Urban ITS, Southeast University, Nanjing 210096, China*)

2) (*Jiangsu Province Collaborative Innovation Center of Modern Urban Traffic Technologies, Nanjing 210096, China*)

(Received 20 November 2013; revised manuscript received 6 March 2014)

Abstract

Traffic state prediction is a key basis of traffic flow guidance system and traffic information publishing system. This paper presents a new method of forecasting the traffic state of urban expressway based on competence region. This method can predict the traffic state grade of road based on the distance between the sample data and the traffic state cluster center by creating a competence region of neural network classifier. And this method can effectively integrate the temporal and spatial features together without considering the correlation between the different features, and thus it has a strong adaptability. The experimental results show that this traffic state prediction method can reduce the prediction error and improve the equality coefficients compared with the classical algorithms. The prediction method used in this paper is effective and accurate for forecasting traffic state based on the competence region.

Keywords: traffic state, prediction, traffic parameter, cluster

PACS: 05.45.Tp, 45.70.Vn, 88.10.gc

DOI: [10.7498/aps.63.140504](https://doi.org/10.7498/aps.63.140504)

* Project supported by the National High Technology Research and Development Program of China (Grant No. 2011AA110302), the Fundamental Research Funds for the Central Universities of Ministry of Education of China (Grant No. CXZZ13_0119).

[†] Corresponding author. E-mail: uiodo@hotmail.com