

文章编号:1005-0523(2019)02-0092-07

# 基于神经网络与马尔可夫链的换道次数预测方法

洪维伟,王元庆

(长安大学公路学院,陕西 西安 710064)

**摘要:**为在先验数据有限情况下较精确地预测道路换道次数,提出基于神经网络与马尔可夫链的组合预测模型。采集路段区间平均车速和车流密度,采用BP神经网络训练初步拟合模型;运用马尔可夫链方法,进一步给出换道次数在表示高估、正常、低估的3组区间内的分布及概率,改善BP神经网络误差。运用组合预测模型对西安市某道路的换道次数进行了预测分析,结果表明,实际换道次数均在模型给出的较大概率的预测区间内,表明模型能够根据路段区间平均车速和车流密度较好地预测换道次数。

**关键词:**换道行为;换道次数;神经网络;马尔可夫链

**中图分类号:**U491

**文献标志码:**A

车辆换道是描述行驶中的车辆因需要而变换车道的行驶行为,因其具有普遍性和常发性,成为交通行为研究的重点研究对象。车辆换道通常由于驾驶员为到达目标车道或获得优于当前车道的行驶条件造成。车辆的换道会对道路的安全性产生重要的影响,是引发交通事故的重要原因之一。在车辆行驶过程中,有将近一半的事故是由并线、车道变换和驶离车道行为造成的<sup>[1]</sup>。车辆换道还会影响后车行驶速度,降低通行效率,并引发更多的换道需求<sup>[2]</sup>。研究车辆换道行为对提升道路的安全水平和服务水平具有重要意义。

车辆换道模型是研究换道行为的关键。目前国内外对车辆换道模型的研究可以分为换道决策模型和换道实施模型<sup>[3]</sup>。换道决策模型包括基于规则的Gipps模型<sup>[4]</sup>、考虑驾驶人差异与驾驶状态的离散选择模型<sup>[5]</sup>、基于模糊逻辑的不同车型的换道模型<sup>[6]</sup>、基于神经网络的换道决策预测模型等<sup>[7]</sup>。换道决策模型还包括马尔可夫模型、生理—心理模型和生存模型等<sup>[8-10]</sup>。换道实施模型主要包括运动波混合模型和元胞自动机模型等<sup>[11-12]</sup>。

以上模型从驾驶人的心理、生理角度,从车辆的行驶特点角度等对车辆换道行为进行了较好地描述。但不同国家的交通组成、交通环境、道路状况有所不同,完全运用国外学者建立的模型不一定能够很好地解决我国的交通问题,且上述模型大多较为复杂,对数据的要求较高。本文提出基于神经网络与马尔可夫链的组合预测方法,选取道路的换道次数、车流密度、速度等参数建立模型。道路换道次数是某一选定路段上一定时间内所有车辆换道频次的累加,与道路的交通流密度和区间平均速度之间存在着密切的关系<sup>[13]</sup>。神经网络模型能够较好地把握参数之间的内在关系,且数据直观,易于采集;马尔可夫链能够缩小神经网络的预测区间,提升预测精度。基于神经网络和马尔可夫链的组合方法对参数进行拟合训练,能够得到数据直观、预测精准的换道次数预测方法,从而更好地应用于换道行为研究。

收稿日期:2018-08-31

基金项目:国家自然科学基金项目(51878062)

作者简介:洪维伟(1994—),男,硕士研究生,主要研究方向为交通运输规划与管理。

通讯作者:王元庆(1968—),男,教授,博士生导师,主要研究方向为交通运输规划与管理。

## 1 神经网络与马尔可夫链组合预测模型的构建

神经网络模型是人工智能趋势下广泛应用的模型方法。然而通常情况下训练神经网络模型需要数量较多的数据,否则训练结果容易出现较大的误差。马尔可夫链是在给定当前状态信息的情况下,根据系统状态的转移概率,预测未来时刻系统状态的预测方法<sup>[14]</sup>。当数据有限时,在神经网络模型预测结果的基础上,运用马尔可夫链分析误差波动趋势,调整神经网络预测结果,能够使最终的预测结果按一定概率落在几个范围较小的区间内,从而能够有效减少单一应用神经网络模型的误差。运用神经网络与马尔可夫链组合预测模型的步骤如下:

- 1) 采集包含模型自变量、因变量互相对应的数据,将数据划分为训练集、检验集和测试集;
- 2) 将训练集数据输入神经网络模型进行训练,通过迭代计算得到符合训练要求的神经网络模型;
- 3) 将检验集数据输入第 2) 步中得到的神经网络模型,分析结果的误差变动;
- 4) 运用马尔可夫链方法对神经网络模型进行修正;
- 5) 将测试集的数据输入修正后的组合预测模型,测试模型运行效果。

### 1.1 神经网络模型

神经网络模型起源于 1943 年 Warren McCulloch 和 Walter Pitts 提出的 M-P 模型。1958 年 Rosenblatt 提出了感知机,推动了神经网络模型的研究<sup>[15]</sup>。1986 年 David Rumelhart 以及 Geoffery Hinton 提出了反向传播(back propagation, BP)算法,带动了学界使用两层神经网络研究的热潮<sup>[16]</sup>。

BP 神经网络结构模型主要由输入层、隐含层和输出层组成,其表达式如下

$$\left\{ \begin{array}{l} \mathbf{Z}^{[1]} = \mathbf{W}^{[1]} \mathbf{A}^{[0]} + \mathbf{b}^{[1]} \\ \mathbf{A}^{[1]} = g_1(\mathbf{Z}^{[1]}) \\ \mathbf{Z}^{[2]} = \mathbf{W}^{[2]} \mathbf{A}^{[1]} + \mathbf{b}^{[2]} \\ \mathbf{A}^{[2]} = g_2(\mathbf{Z}^{[2]}) \\ \dots\dots \\ \mathbf{Z}^{[l]} = \mathbf{W}^{[l]} \mathbf{A}^{[l-1]} + \mathbf{b}^{[l]} \\ \mathbf{A}^{[l]} = g_l(\mathbf{Z}^{[l]}) \end{array} \right. \quad (1)$$

式中: $\mathbf{W}^{[1]}$ 为第 1 层的权重矩阵; $\mathbf{W}^{[2]}$ 为第 2 层的权重矩阵; $\mathbf{W}^{[l]}$ 为第  $l$  层的权重矩阵; $\mathbf{b}^{[1]}$ 为第 1 层的偏置向量; $\mathbf{b}^{[2]}$ 为第 2 层的偏置向量; $\mathbf{b}^{[l]}$ 为第  $l$  层的偏置向量; $\mathbf{Z}^{[1]}$ 为第 1 层激活前的输出矩阵; $\mathbf{Z}^{[2]}$ 为第 2 层激活前的输出矩阵; $\mathbf{Z}^{[l]}$ 为第  $l$  层的激活前的输出矩阵; $\mathbf{A}^{[0]}$ 为第 1 层的输入矩阵,即模型自变量矩阵  $\mathbf{X}$ ,  $\mathbf{X}$  为  $m \times n$  的矩阵,  $m$  代表样本自变量维度,  $n$  代表样本个数; $\mathbf{A}^{[1]}$ 为第 1 层激活后的输出矩阵,即第 2 层的输入矩阵; $\mathbf{A}^{[2]}$ 为第 2 层激活后的输出矩阵,即第 3 层的输入矩阵; $\mathbf{A}^{[l-1]}$ 为第  $l-1$  层激活后的输出矩阵,即第  $l$  层的输入矩阵; $\mathbf{A}^{[l]}$ 为第  $l$  层的激活后输出矩阵,即模型输出矩阵; $g_1$  为第 1 层的激活函数; $g_2$  为第 2 层的激活函数; $g_l$  为第  $l$  层的激活函数。

在构建 BP 神经网络的过程中,需要通过模型多次训练,得到网络中每一层最优的  $\mathbf{W}$ 、 $\mathbf{b}$ ,使模型输出的误差最小,此时即得到了输入变量和输出变量间的映射关系。

### 1.2 马尔可夫链预测模型

马尔可夫链预测模型可表示为

$$\mathbf{X}(n) = \mathbf{X}(0) \mathbf{P}^n \quad (2)$$

式中: $\mathbf{X}(0)$ 为初始时刻的状态概率向量; $\mathbf{X}(n)$ 为  $n$  时刻的状态概率向量; $\mathbf{P}$  为状态转移概率矩阵。

运用式(2),可以根据  $\mathbf{P}$  及  $\mathbf{X}(0)$  对第  $n$  步  $\mathbf{X}(n)$  进行预测。状态概率矩阵  $\mathbf{P}$  由式(3)确定

$$P_{ij} \approx \frac{N_{ij}}{N_i} \quad (3)$$

式中: $N_i$ 为状态*i*出现的次数; $N_{ij}$ 为由状态*i*转移到状态*j*的次数; $P_{ij}$ 为由状态*i*到状态*j*的转移概率。

分析BP神经网络预测结果误差的变化规律,根据式(3)可得到关于误差变化的马尔可夫链状态转移概率矩阵 $P$ ,从而可以修正BP神经网络预测结果<sup>[7]</sup>。

## 2 案例分析

选取西安市某道路作为案例分析对象。该道路为城市主干道,双向六车道,调查路段长度100 m,路段附近有出入口,路段内无公交车停靠站点,如图1所示。

调查时间选择为工作日的9:30—10:30。考虑到数据采集的难易程度及理论上可能与道路换道次数存在的关系,选择区间平均车速及路段车流密度作为模型自变量。每5 min统计一次通过路段的车辆数、车辆通过路段所需的时间及路段内车辆的换道总次数。通过式(4)得到区间平均车速

$$v = \frac{l}{\frac{1}{C} \sum_i t_i} \quad (4)$$

式中: $l$ 为调查的路段长度,本文中 $l=100$  m; $C$ 为通过路段的车辆数; $t_i$ 为车辆*i*通过路段所需的时间; $v$ 为区间平均车速。

由式(5)计算得到路段车流密度

$$k = \frac{C}{l} \quad (5)$$

式中: $k$ 表示路段车流密度。

调查获得数据共计50组。用*f*表示路段内车辆的换道总次数,数据的最大、最小及平均值如表1所示。

表1 调查参数特征表  
Tab.1 Survey parameters

参数	最大值	最小值	平均值
区间平均车速 $v/(km/h)$	49.48	30.45	39.62
路段车流密度 $k/(veh/km)$	43.94	25.74	33.39
换道次数 $f$ 次	253	153	209.6

将数据进行随机排列编号,将1~20号数据作为训练集训练神经网络模型;将21~40号数据作为检验集分析误差,标定马尔可夫链模型状态转移概率矩阵 $P$ ;将41~50号数据作为测试集,运用组合预测模型测试结果。

### 2.1 BP神经网络模型基准拟合

选取1~20号数据作为BP神经网络模型的训练样本,样本数据如表2所示。



图1 调查路段现场图

Fig.1 Picture of the survey section

表 2 西安市某道路速度  $v$ , 车流密度  $k$  和换道次数  $f$  的数据  
 Tab.2 Data of  $v$ ,  $k$  and  $f$  of a road in Xi'an

样本序号	区间平均车速 $v$ / (km/h)	路段车流密度 $k$ / (veh/km)	换道次数 $f$ / 次	样本序号	区间平均车速 $v$ / (km/h)	路段车流密度 $k$ / (veh/km)	换道次数 $f$ / 次
1	45.15	27.09	187	11	41.01	30.26	159
2	30.45	43.59	218	12	43.28	29.63	183
3	41.98	31.81	244	13	44.71	28.86	195
4	32.11	38.99	248	14	46.82	27.25	208
5	31.82	43.94	175	15	37.62	34.73	185
6	49.48	27.22	224	16	46.22	29.25	196
7	36.37	35.53	243	17	38.61	34.42	193
8	39.86	32.58	209	18	47.67	27.79	244
9	41.52	31.81	163	19	43.25	32.12	181
10	48.56	26.63	234	20	33.27	41.71	228

BP 神经网络输入层节点数为 2, 表示区间平均车速  $v$ 、路段车流密度  $k$ ; 输出层节点数为 1, 即换道次数  $f$ 。采用含有一个隐含层的网络, 通过经验及试算得到最优的隐含层的节点个数为 13, 通过模型训练得到:

1) 输入层到隐含层的参数矩阵

$$W_1 = \begin{bmatrix} -2.184 & 3 & 4.700 & 0 \\ -0.773 & 9 & 4.640 & 4 \\ -3.031 & 6 & 4.230 & 8 \\ -3.175 & 4 & -3.456 & 1 \\ -3.905 & 6 & 3.417 & 2 \\ -3.683 & 6 & 4.147 & 3 \\ 5.485 & 3 & -0.386 & 3 \\ -4.374 & 7 & 4.506 & 6 \\ -0.636 & 8 & -1.369 & 4 \\ -8.119 & 6 & 0.635 & 7 \\ 3.238 & 2 & -7.320 & 1 \\ -0.336 & 5 & -0.098 & 9 \\ 9.676 & 7 & 8.107 & 3 \end{bmatrix} \quad (6)$$

$$b_1 = \begin{bmatrix} 5.865 & 2 \\ 5.381 & 7 \\ 3.019 & 3 \\ 4.602 & 5 \\ 1.350 & 4 \\ 2.643 & 6 \\ -0.403 & 1 \\ 1.294 & 8 \\ -0.002 & 5 \\ -6.287 & 0 \\ -0.500 & 0 \\ 9.023 & 1 \\ 2.953 & 1 \end{bmatrix} \quad (7)$$

## 2) 隐含层到输出层的参数矩阵

$$W_2 = \begin{bmatrix} 1.927 & 0 & -1.992 & 9 & 0.039 & 3 & -0.275 & 3 & -0.823 & 6 & 0.920 & 2 & -0.913 & 3 \\ -1.580 & 2 & 4.134 & 5 & 1.365 & 7 & -1.408 & 0 & 0.034 & 6 & 1.392 & 1 \end{bmatrix} \quad (8)$$

$$b_1 = [0.181 \ 7] \quad (9)$$

利用训练后的 BP 神经网络对车道换道次数的第 21~40 号数据进行拟合, 得到换道次数神经网络基准拟合结果, 拟合值与实际值比较后的误差分析如表 3 所示。

表 3 实测结果与模拟结果表  
Tab.3 The measured and the simulated results

编号	实际值	模拟值	误差值	误差百分比/%	编号	实际值	模拟值	误差值	误差百分比/%
21	220	200	20	9.1	31	207	213	-6	-2.9
22	244	230	14	5.6	32	193	210	-17	-8.6
23	226	210	16	7.3	33	234	215	19	8.3
24	218	234	-16	-7.5	34	229	208	21	9.3
25	217	231	-14	-6.6	35	237	220	17	7.1
26	154	162	-8	-5.4	36	228	208	20	8.9
27	228	233	-5	-2.4	37	197	184	13	6.5
28	249	225	24	9.7	38	198	200	-2	-1.1
29	249	232	17	6.9	39	195	188	7	3.3
30	153	160	-7	-4.3	40	174	165	9	5.4

从表 3 可以看出, 第 21~40 号数据拟合误差百分比绝对值的平均数为 6.315%, 最大误差为 9.7%。

## 2.2 基于马尔可夫链的车道换道次数预测结果修正

根据表 2 中 BP 模拟值和实际值的误差百分比及误差幅度, 将马尔可夫状态区域划分为以下 3 种状态:

1) 高估状态( $\alpha$ ), 即误差百分比在 $[-10\%, -3\%]$ 内。此种状态在第 21~40 号数据中出现 6 次, 见表 3 的编号 24, 25, 26, 30, 31, 32。

2) 正常状态( $\beta$ ), 即误差百分比在 $[-3\%, 3\%]$ 内。此种状态在第 21~40 号数据中出现 2 次, 见表 3 的编号 27, 38。

3) 低估状态( $\gamma$ ), 即误差百分比在 $[3\%, 10\%]$ 内。此种状态在第 21~40 号数据中出现 12 次, 见表 3 的编号 21, 22, 23, 28, 29, 33, 34, 35, 36, 37, 39, 40。

根据第 21~40 号数据预测误差的变化情况, 可以得到马尔可夫链状态转移表, 如表 4 所示。

表 4 21~40 号数据预测结果的马尔可夫状态转移表  
Tab.4 Markov state transition for prediction results of data No.21~40

状态	$\alpha$	$\beta$	$\gamma$	合计
$\alpha$	4	1	1	6
$\beta$	0	0	2	2
$\gamma$	2	1	8	11
合计	6	2	11	19

根据式(3)得到

$$P = \begin{bmatrix} 0.666\ 6 & 0.166\ 7 & 0.166\ 7 \\ 0 & 0 & 1 \\ 0.181\ 8 & 0.090\ 9 & 0.727\ 3 \end{bmatrix} \quad (10)$$

根据式(2),得到第 41~50 号数据的状态概率向量,如表 5 所示。

表 5 第 41~50 号数据状态概率向量  
Tab.5 State probability vector of data No.41~50

数据状态	41	42	43	44	45	46	47	48	49	50
$\alpha$	0.181 8	0.253 4	0.287 2	0.302 6	0.309 7	0.313 0	0.314 5	0.315 2	0.315 5	0.315 7
$\beta$	0.090 9	0.096 4	0.101 3	0.103 5	0.104 5	0.104 9	0.105 1	0.105 2	0.105 2	0.105 3
$\gamma$	0.727 3	0.650 2	0.611 5	0.593 9	0.585 8	0.582 1	0.580 4	0.579 6	0.579 3	0.579 0

综上,得出该车道第 41~50 号数据的换道次数最终预测结果,如表 6 所示。

表 6 第 41~50 号数据换道次数最终预测结果  
Tab.6 Final forecast result of lane changing frequencies of data No.41~50

编号	实际值	神经网络 拟合值	马尔可夫链改进结果		编号	实际值	神经网络 拟合值	马尔可夫链改进结果	
			预测区间	概率				预测区间	概率
41	226	210	[189.00, 203.70]	0.181 8	46	197	190	[171.00, 184.30]	0.313 0
			[203.70, 216.30]	0.090 9				[184.30, 195.70]	0.104 9
			[216.30, 231.00]	0.727 3				[195.70, 209.00]	0.582 1
42	230	222	[199.80, 215.34]	0.253 4	47	204	198	[178.20, 192.06]	0.314 5
			[215.34, 228.66]	0.096 4				[192.06, 203.94]	0.105 1
			[228.66, 244.20]	0.650 2				[203.94, 217.80]	0.580 4
43	190	182	[163.80, 176.54]	0.287 2	48	192	180	[162.00, 174.60]	0.315 2
			[176.54, 187.46]	0.101 3				[174.60, 185.40]	0.105 2
			[187.46, 200.20]	0.611 5				[185.40, 198.00]	0.579 6
44	195	189	[170.10, 183.33]	0.302 6	49	238	231	[207.90, 224.07]	0.315 5
			[183.33, 194.67]	0.103 5				[224.07, 237.93]	0.105 2
			[194.67, 207.90]	0.593 9				[237.93, 254.10]	0.579 3
45	188	174	[156.60, 168.78]	0.309 7	50	253	242	[217.80, 234.74]	0.315 7
			[168.78, 179.22]	0.104 5				[234.74, 249.26]	0.105 3
			[179.22, 191.40]	0.585 8				[249.26, 266.20]	0.579 0

马尔可夫链改进后的预测结果按一定概率分布在表示高估、正常和低估的3组预测区间内,符合道路换道次数呈随机变化的特性,通过最大概率的预测区间可以较为准确地预测车道的换道次数。由表6可以看出,第41~50号数据的实际换道次数均落在组合预测模型给出的概率最大的预测区间内,表明基于神经网络与马尔可夫链的换道次数组合模型能够通过输入区间平均车速 $v$ 及路段车流密度 $k$ 输出道路换道次数 $f$ 的预测值,且具有较好的可靠性。

### 3 结论

1) 基于神经网络与马尔可夫链的组合预测模型具有较严密的理论和实际基础。该模型能够综合利用两种方法的优势,减少神经网络模型单一方法预测在样本数量较少情况下的误差。对西安市某道路换道次数的计算分析表明,该方法预测结果为换道次数的区间及概率,符合车辆换道具有一定随机性的特性;预测结果均落在概率最大的区间内,表明该方法具有较好的可靠性。

2) 基于神经网络与马尔可夫链的组合预测模型具有较好的推广应用价值。本文运用神经网络与马尔可夫链的组合预测模型,基于区间平均车速,车流密度预测道路换道次数,并能够给出换道次数高估、正常和低估的3组预测区间及概率,对道路安全风险评估有较好的应用价值。根据神经网络的迁移学习理论,当预测参数改变时,只需采集新参数的数据输入组合模型重新进行训练,即可得到适用于新参数的预测模型,模型能够较好地应用和推广。

#### 参考文献:

- [1] 李鹏飞,石建军,刘小明. 城市快速路竞争与协作换道行为特征分析[J]. 公路交通科技,2016,33(12):130-139.
- [2] 徐良杰,刘志. 基于车道选择的交叉口进口道导向系统改善方法[J]. 华东交通大学学报,2018(1):14-19.
- [3] 陆建,李英帅. 车辆换道行为建模的回顾与展望[J]. 交通运输系统工程与信息,2017,17(4):48-55.
- [4] GIPPS P G. A model for the structure of lane-changing decisions[J]. Transportation Research Part B,1986,20(5):403-414.
- [5] AHMED K I, BEN-AKIVA M, KOUTSOPOULOS H N, et al. Models of freeway lane changing and gap acceptance behavior[J]. Transportation and Traffic Theory,1996(13):501-515.
- [6] SARA M, MAJID S, GEOFF R, et al. Lane-changing decision model for heavy vehicle drivers[J]. Journal of Intelligent Transportation Systems,2012,16(1):24-35.
- [7] HUNT J G, LYONS G D. Modelling dual carriageway lane changing using neural networks[J]. Transportation Research Part C Emerging Technologies,1994,2(4):231-245.
- [8] WORRALL R D, BULLEN A G, GUR Y. An elementary stochastic model of lane-changing on a multilane highway[J]. Highway Research Record,1970(308):1-12.
- [9] WIEDEMANN R, REITER U. Microscopic traffic simulation: the simulation system mission, background and actual state[J]. Project ICARUS (V1052) Final Report,1992,2:1-53.
- [10] HAMDAR S H. Modeling driver behavior as a stochastic hazard-based risk-taking process[D]. Evanston: Northwestern University,2008:158-168.
- [11] JIN W L. A multi-commodity Lighthill - Whitham - Richards model of lane-changing traffic flow[J]. Transportation Research Part B Methodological,2013,57(11):361-377.
- [12] 李娟,曲大义,刘聪,等. 基于元胞自动机的车辆换道行为研究[J]. 公路交通科技,2016,33(11):140-145.
- [13] 谢寒,蒋阳升,蒋若曦,等. 城市快速路交织区换车道次数与车速、密度的关系实证研究[J]. 武汉理工大学学报,2012,34(8):75-81.
- [14] 刘克. 实用马尔可夫决策过程[M]. 北京:清华大学出版社,2004:1-12.
- [15] ROSENBLATT F. The perceptron: A probabilistic model for information storage and organization in the brain[J]. Psychological Review,1958,65(6):386-408.
- [16] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature,1986,323(6088):399-421.
- [17] 杨励雅,邵春福. 基于BP神经网络与马尔可夫链的城市轨道交通周边房地产价格的组合预测方法[J]. 吉林大学学报:工学版,2008,38(3):514-519.