

An anthropomorphic driving decision model for intersection based on BP neural network

Bing ZHOU, Qianxi Pan, Peipei FU

State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha, China
Email: zhou_bingo@163.com, 471055862@qq.com, 1343380470@qq.com

Abstract: The decision-making model of the autonomous vehicle is crucial to the auto-driving performance of the car, and the anthropomorphic treatment scheme is safer and more reasonable. In this paper, based on the urban crossroad conditions, the FORUM8 driving simulator is used to build the intersection simulation scene. By collecting the experienced driver driving data in this scene, and using SPSS (Statistical Product and Service Solutions) to analyze the sample data, Several environmental factors with the highest correlation of driving output are obtained. Finally, the BP (Back Propagation) neural network is used to learn the filtered data, so as to obtain the anthropomorphic driving decision model which can output the driving decision of the end-to-end of the actual scene.

Keywords: anthropomorphic decision making; automatic driving; intersection; BP neural network

基于 BP 神经网络的十字路口拟人化驾驶决策模型

周 兵, 潘倩兮, 付沛沛

汽车车身先进设计制造国家重点实验室, 湖南大学, 长沙, 中国, 410000
Email: zhou_bingo@163.com, 471055862@qq.com, 1343380470@qq.com

摘 要: 自动驾驶车辆的决策模型对汽车自动驾驶性能影响至关重要, 其中拟人化处理方案更安全、更合理。本文针对城市十字路口工况, 运用 FORUM8 驾驶模拟器搭建十字路口模拟场景; 通过采集在该场景下有经验驾驶员驾驶数据, 并用 SPSS (Statistical Product and Service Solutions) 对样本数据进行相关性分析得到与驾驶输出相关性最高的几个环境因素; 最后通过 BP (Back Propagation) 神经网络对筛选后数据进行学习, 从而获得可对实际场景端对端输出驾驶决策的拟人化驾驶决策模型。

关键词: 拟人化决策; 自动驾驶; 十字路口; BP 神经网络

1 前言

自动驾驶汽车 (Autonomous vehicles; Self-piloting automobile) 又称无人驾驶汽车, 应用了毫米波雷达、激光雷达、GPS、计算机视觉等环境感知硬件设施及路径规划、路径跟踪等先进控制技术。自动驾驶技术能够降低交通风险, 提高驾驶安全性, 同时提高道路交通效率, 此外, 通过驾驶安全性以及效率的提升带来一系列潜在效益, 如油耗的降低、车辆保险维修费用的减少、环境污染排放物的降低以及停车空间需求下降等。然而, 无人驾驶技术不能仅关注驾驶的安全性和高效率, 乘客的体验感受也是人们能否接受无人驾驶汽车的一个重要因素。因此越来越多的自动驾驶汽车行为决策系统在考虑采用拟人化的处理方式以使人们更容易接受自动驾驶技术。

自动驾驶汽车的行为决策系统主要有基于学习和基于规则算法两大类^[1]。基于规则的行为决策代表方法为有限状态机法^[2-3], 其代表应用有 Junior^[4]、Talos^[5]、Bertha^[6]等, 其中, 麻省理工大学的 Talos^[7]无人车的行为决策系统总体采用了串联结构的有限状态机法, 具有问题求解精度高、规划推理能力强、逻辑明确等优点, 但其不足在于面对复杂问题时适应性差, 若某个子状态发生故障将导致整个决策链瘫痪。大众公司与斯坦福大学研发的 Junior^[8]无人车则采用了并联的行为决策系统结构, 将每一种工况单独划分成模块进行处理, 整个系统可快速、灵活的对输入进行响应, 然其难点主要体现于, 复杂工况下因遍历状态较多导致算法机构庞大, 以及状态间的划分与状态冲突难以解决。

相比有限状态机，基于深度学习的决策方法在建模现实问题上具有更强的灵活性，近年来被许多专家应用于无人驾驶汽车决策系统。2015年普林斯顿大学研发的无人驾驶车辆决策系统通过车载相机获得周围环境的各帧图像，将图像输入到端到端卷积神经网络(Convolutional Neural Networks, CNN)，CNN将输入图像映射到少量的与驾驶决策输出直接相关的道路和交通状态指标，经卷积神经网络深度学习、决策后直接输出车辆的期望转向盘转角，使决策系统得到大幅度简化^[9]。2010年，卡耐基梅隆大学提出了一种基于预测和代价函数算法(Prediction and Cost function-Based algorithm, PCB)的离线学习机制，用来模拟人类驾驶员的行为决策^[10]。具体而言，该决策系统针对交通场景预测与评估问题建立模型，采集跟车场景下80秒的人类低速(<48km/h)驾驶数据，如自车速度、前车速度及两车之间的距离等，然后使用学习算法对这些数据进行学习，研究表明，在距离为120km的低速跟车测试实验中，PCB和人类跟车的车速差异仅为5%。2018年，Wang^[11]等提出了一种基于长短时记忆(LSTM)神经网络和条件随机场(CRF)模型的仿人机动决策方法，该模型基于NGSIM公共数据集进行训练，仿真结果表明所建立的模型具有类人推理的机动决策能力。2019年，Tsuyoshi Sakuma^[12]提出了一种基于人类认知机制和大脑结构的无监督强化学习驱动模型，即采用一个简单的行为-批评模型作为驾驶员模型，且设定的学习参数是从人脑的任务执行过程中衍生出来的特征。该模型能较好地预测变道决策，在实际驾驶数据验证试验中具有较高的准确率。Yu^[13]提出了一种基于博弈论的变道决策模型，该模型通过采集转弯信号、横向移动信息、与周围驾驶员互动信息来模拟人的行为作为机器学习的典型方法。

以上文献表明，学习算法在构建驾驶决策模型时有更强的灵活性，能更好的模拟人的决策过程。本文将研究十字路口这一具体场景的驾驶员拟人化决策，基于学习算法搭建拟人化驾驶决策模型。首先在驾驶模拟器中搭建城市十字路口场景，采集熟练驾驶员在该场景下的驾驶数据；而后用SPSS软件对有效数据进行相关性分析，得到与驾驶输出加速度相关性较大的几个环境因素；在此基础上，用BP神经网络对驾驶数据进行学习得到拟人化自动驾驶决策行为模型，如图1所示。最后通过PRESCAN和MATLAB/SIMULINK联合仿真对模型进行验证。

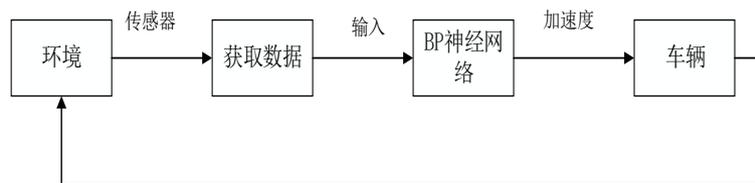


Figure 1. Decision model

图 1. 决策模型

2 搭建场景

通过观察长沙市岳麓区多个十字路口，发现绝大部分右转车道可不受信号灯控制直接通行。然而，在直行车辆放行的情况下，右转车辆可能与直行的车辆发生冲突，如图2、图3所示。若驾驶员操作不当将可能发生碰撞危险。在此背景下，考虑到驾驶员在进入十字路口前，会根据左侧直行车辆和自车的运动状态及位置信息进行预判：若前车速度大，且两车相对距离小，驾驶员会适当减速让直行车先行通过十字路口；若直行车辆速度较小或两车距离较大，驾驶员通过预判会先于他车通过十字路口，这个预判过程中驾驶员的决策行为正是本文研究分析的主要内容。本文以长沙市城市十字路口交通状况为表征，通过观察长沙市若干个十字路口各个时间段的交通流，估算得到城市十字路口工况的平均交通流约为500辆/小时。按照城市交通管理制度，该场景的最高车速一般为50km/h。以此为依据，在驾驶模拟器上搭建城市十字路口驾驶场景，车流设置为500辆/小时，环境车设置为不同类型的车辆，包括公交车、面包车、轿车等，并设置不同的驾驶风格，包括激进型、礼让型、谨慎型等三种，同时右转车道设置为不受信号灯限制。

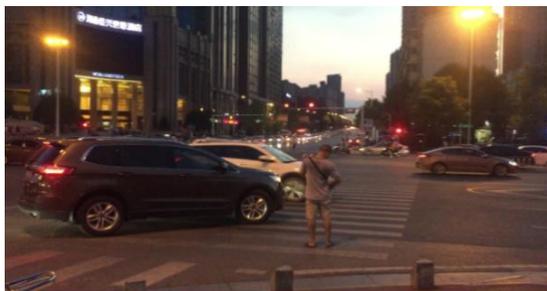


Figure 2. Dangerous conditions
图 2. 危险工况

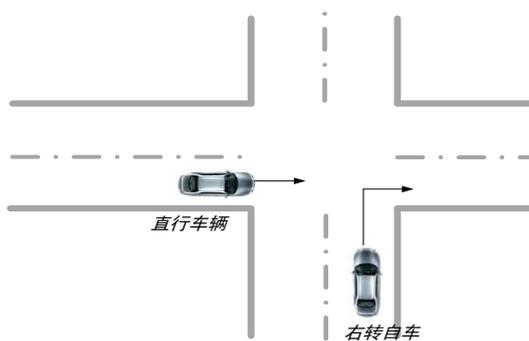


Figure 3. Conflict scenario
图 3. 冲突场景

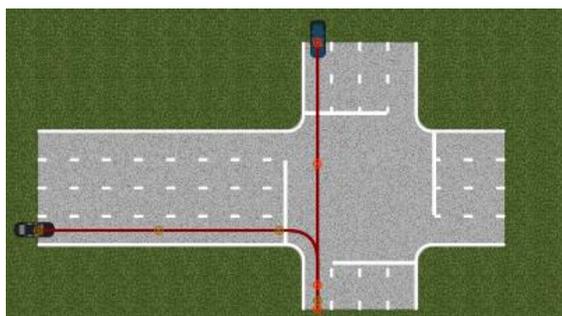


Figure 4. Conflict scenario in the Prescan
图 4. Prescan 设置的冲突场景

3 采集驾驶数据

学习算法的本质是人工神经网络，基本原理是通过神经网络结构进行低维到高维的映射，从而提取数据的特征。神经网络训练结果与采集数据样本的质量十分相关，因此使用学习算法要保证样本数据的质量。为得到优质合理的数据样本，本文邀请了 5 名驾驶经验丰富的驾驶员在搭建的十字路口场景下分别操作驾驶模拟器三个小时获取数据样本。本文使用的驾驶模拟器为 FORUM8 驾驶模拟器，其主要结构如图 5 所示。

FORUM8 驾驶模拟器主要由 UC-winRoad 软件和车辆动力学模型组成，广泛用于人因研究、车辆开发和研究、驾驶员培训及道路安全研究和培训等。该模拟器具有同真实汽车一样的操纵系统，底盘控制系统和电气系统，所采用的软件允许用户创建驾驶场景，并能在 VR-Design Studio 内或与 CarSim 或 TruckSim 等第三方产品协作设置单独的车辆动态。

图 6 为采集经验驾驶员在驾驶模拟器上进行十字路口通过测试的现场，观察发现驾驶员在驾驶过程中把大部分注意力放在与自车存在潜在碰撞危险的车辆，并根据他车和自车的运动状态及相对位置信息做出避险操作。在本文研究的场景中，经分析发现驾驶员会根据离自车最近的直行车辆的运动状态及与自车的相对位置进行驾驶操作，决定是正常通过还是减速让行。因此本文采集车辆进入十字路口前 100m 内的驾驶数据进行分析。

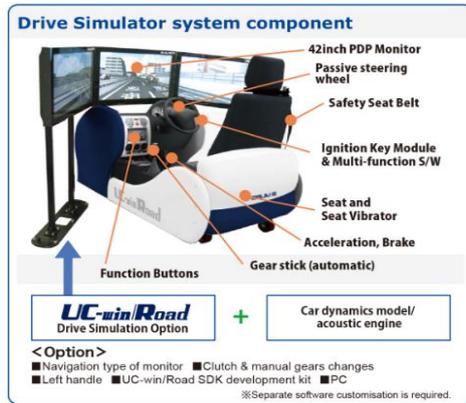


Figure 5. FORUM8 driving simulator
图 5. FORUM8 驾驶模拟器



Figure 6. The site where data is collected
图 6. 采集数据现场

4 相关性分析

通过驾驶模拟器采集的数据包含 41 个变量，若把每一个因素都纳入考虑范围，将导致巨大的计算量。因此可筛选掉不影响或者对驾驶操作影响很小的因素，将筛选后的因素作为 BP 神经网络的输入神经元。参考文献资料[14-15]，当前相关研究重点考虑的环境因素包括以下几个：两车横向相对速度 dd_x 、纵向相对速度 ddy 、横向相对距离 dx 、纵向相对距离 dy 、自车的横向速度 V_x 、自车的纵向速度 V_y 。

在 BP 神经网络中，输入神经元的选择非常重要，对最终的输出结果有很大的影响。如果选择的输入与输出相关性不强，则很可能得不到理想的训练模型，因此，在进行 BP 神经网络训练之前，有必要对以上参数进行相关性分析。本文用 SPSS 软件把采集的数据与车辆加速度值进行相关性分析，SPSS 是 IBM 公司推出的一系列用于统计学分析运算、数据挖掘、预测分析和决策支持任务的软件。通过相关性分析得到 dx 、 dy 、 ddx 、 ddy 这四个因素与输出加速度的相关性最大，分析结果如表 1 所示。相关性可分为正相关和负相关，分析结果在正负 0-0.3 之间表示相关性较弱，正负 0.3-0.6 之间表示相关性较强，正负 0.6-1 表示相关性非常强。由表可知， dx 、 ddx 、 ddy 与加速度 a 的相关性都在 0.4 以上，显示为较强的相关性， dy 相关性相对弱，但是也在 0.3 左右。因此本文把 dx 、 dy 、 ddx 、 ddy 这四个因素作为 BP 神经网络学习的输入神经元，输出神经元为右转车辆的加速度 a 。

Table 1. Analysis results of correlation

表 1. 相关性分析结果

变量	dx	dy	ddx	ddy	a
dx	1.000	0.507	-0.076	-0.028	0.498
dy	0.507	1.000	-0.293	-0.550	0.291
ddx	-0.076	-0.293	1.000	0.198	0.415
ddy	-0.028	-0.550	0.198	1.000	0.330
a	0.498	0.291	0.415	0.330	1.000

5 基于 BP 神经网络的驾驶决策模型

BP 神经网络算法由 Rumelhart 和 McClelland 为首的科学家在上世纪九十年代提出，该算法是一种按照误差逆向传播算法训练的多层前馈神经网络，目前应用非常广泛。BP 神经网络具有非线性映射能力，实质上实现了一个从输入到输出的映射功能，这使得其特别适合于求解内部机制复杂的问题。在训练时，BP 神经网络能够通过学习数据自动提取输出、输出数据间的“合理规则”，并自适应的将学习内容记忆于网络的权值中，具有高度自学习和自适应的能力；此外，BP 神经网络在其局部的或者部分的神经元受到破坏后不会对全局的训练结果造成很大影响，具有一定的容错能力。

本文通过 MATLAB 搭建 BP 神经网络，如图 7 所示，输入神经元有四个分别为 dx (m)， dy (m)， ddx (m/s)， ddy (m/s)，输出神经元为右转车辆的加速度 a (m/s²)，中间有两层隐藏层。BP 神经网络分为两个过程：工作信号正向传递子过程和误差信号反向传递子过程。

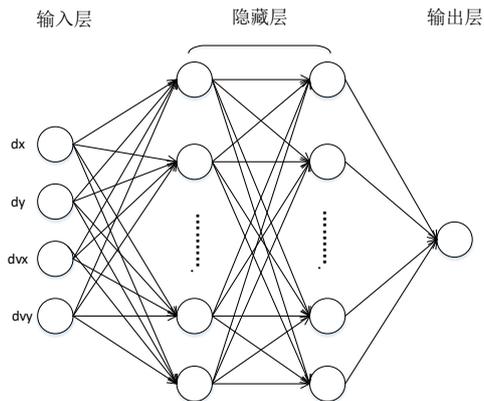


Figure 7. BP neural network structure

图 7. BP 神经网络结构

(1) 工作信号正向传递子过程

所搭建的 BP 神经网络输入层有 4 个节点数，第一层隐含层有 50 个节点数，第二层隐含层有 60 个节点数，输出层的节点个数为 1。输入层到第一层隐含层的权重为 ω_{ij} ，偏置为 b_j ；第一层隐含层到第二层隐含层的权重为 ω_{jk} ，偏置为 b_k ；第二隐藏层到输出层的权重为 ω_{kl} ，第二隐含层到输出层的偏置为 b_l 。学习速率为 η ，激励函数 $g(x)$ 为交叉熵函数。

第一隐含层的输出为：

$$H_j = g(\sum_{i=1}^4 \omega_{ij} x_i + b_j) \quad (1)$$

第二隐含层的输出为：

$$H_k = g(\sum_{j=1}^{50} \omega_{jk} H_j + b_k) \quad (2)$$

输出层的输出为:

$$O_l = \sum_{k=1}^{60} \omega_{kl} H_k + b_l \quad (3)$$

(2) 误差信号反向传递子过程

输出层的所有结果为 Y_k , 期望输出值为 O_k , 误差函数为:

$$E = \frac{1}{2m} \sum_{k=1}^m (Y_k - O_k)^2 \quad (4)$$

记 $e_k = Y_k - O_k$, 用梯度下降法, 反复修正权值和阈值, 使得误差函数值达到最小。权重更新公式为:

$$\frac{\partial E}{\partial \omega_{kl}} = \sum_{l=1}^m (Y_k - O_k) \left(-\frac{\partial O_l}{\partial \omega_{kl}} \right) = (Y_k - O_k)(-H_k) = -e_k H_k \quad (5)$$

$$\begin{cases} \omega_{ij} = \omega_{ij} + \eta_1 H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{kl} e_k \\ \omega_{jk} = \omega_{jk} + \eta_1 H_j e_k \\ \omega_{kl} = \omega_{kl} + \eta_3 H_k e_k \end{cases} \quad (6)$$

偏置更新公式:

$$\begin{cases} b_j = b_j + \eta_1 H_j (1 - H_j) \sum_{k=1}^m \omega_{kl} e_k \\ b_k = b_k + \eta_2 e_k \\ b_l = b_l + \eta_3 e_k \end{cases} \quad (7)$$

式(6)、(7)中, η_1 为输入层与第一隐藏层之间的学习率; η_2 为第一隐藏层与第二隐藏层之间的学习率; η_3 为第二隐藏层与输出层之间的学习率。一般在 BP 神经网络的训练过程中, 学习率 η 统一设定为 0-1 之间的定值, 这使训练过程容易陷入局部最小值。因此加入自适应调整学习速率的梯度下降算法使神经网络跳出局部最小, 在训练的过程中, 力图使算法稳定, 同时又使学习的步长尽量地大, 学习速率则是根据局部误差曲面做出相应的调整。当误差以减小的方式趋于目标时, 说明修正方向正确, 于是步长 (学习速率) 增加, 因此学习速率乘以增量因子 Ir_inc , 使学习速率增加; 而当误差增加超过设定的值 C 倍时, 说明修正过头, 应减小步长, 因此学习速率乘以减量因子 Ir_dec , 使学习速率减少; 其他情况下学习速率则保持不变。通过查阅资料^[16]确定增量因子 Ir_inc 为 1.1, 减量因子 Ir_dec 为 0.8, 学习率自适应更新的过程如式 (8) 所示, η_1 、 η_2 、 η_3 分别进行自适应更新学习率后, 训练过程跳出局部最小值, 误差得到降低。

$$\begin{cases} \eta = \eta \times 0.8 & error_i > error_{i-1} \\ \eta = \eta \times 1.1 & error_i < error_{i-1} \\ \eta = \eta & error_i = error_{i-1} \end{cases} \quad (8)$$

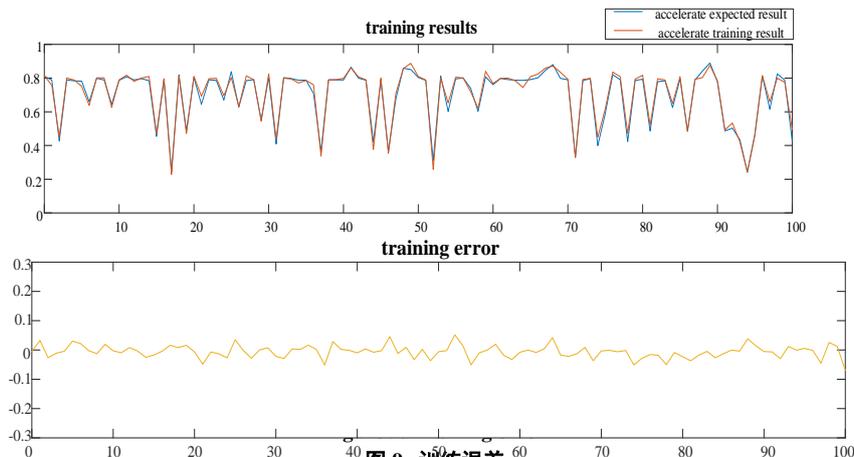


图 9. 训练误差

在加入自适应调整学习速率的梯度下降算法后，该模型训练结果的误差在 6% 以内，结果如图 8、图 9 所示。图中横坐标是从训练结果中随机抽取的 100 个样本，误差值对应公式 (4) 中的 E 值。由图 8-9 可知，BP 神经网络训练输出的加速度与期望加速度一致，误差在 -0.1 至 +0.1 之间，训练效果较好。

6 仿真测试与验证

通过 Prescan 和 MATLAB/Simulink 进行联合仿真，搭建图 10 所示的测试平台对驾驶决策模型进行测试验证。在 Prescan 软件中搭建十字路口驾驶场景，获取驾驶数据并输入决策模型，决策模型决策输出的加速度值输入主车以形成闭环控制。

一般情况下，驾驶员在右拐通过十字路口时会适当降低车速，决策模型针对危险程度不同的来车会输出不同的加速度来躲避危险。本文根据驾驶员驾驶风格的不同，将来车驾驶员的驾驶操作分为激进型和保守型。在 Prescan 中分别设置激进型和保守型驾驶员来车的运动状态：激进型驾驶员设定以 10m/s 的初速度， 1m/s^2 的加速度直行通过十字路口；保守型驾驶员则设定以 10m/s 的初速度进入路口前以 1m/s^2 进行适当减速，然后以匀速状态行驶。

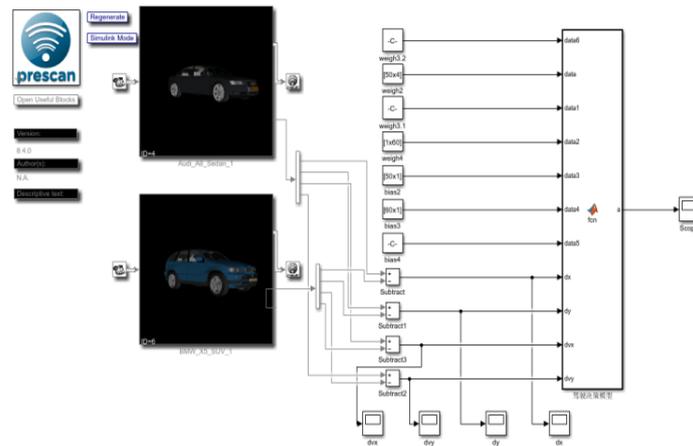


Figure 10. Co-simulation platform

图 10. 联合仿真平台

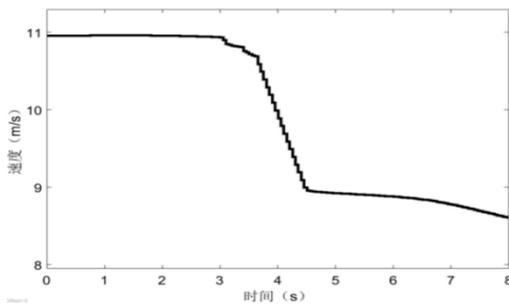


Figure 11. Curve of dangerous conditions

图 11. 危险工况曲线

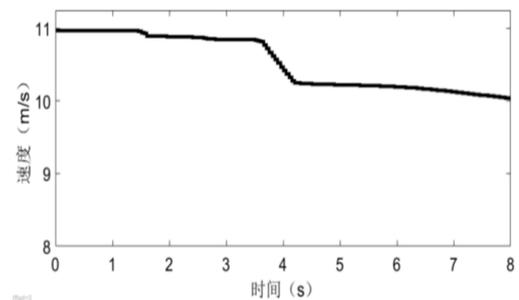


Figure 12. Curve of normal conditions

图 12. 正常工况曲线

图 11 表示驾驶员模型在十字路口场景面对激进型来车时的速度曲线。当来车驾驶员驾驶操作行为比较激进时，模型预判存在危险工况，将控制自车车速适当减速来保证驾驶安全。由图 11 可知，自车以 11m/s 的初速度驶入十字路口，在 3s 时自车开始减速，最终以 9m/s 的速度安全通过路口。图 12 表示驾驶员模型在十字路口场景面对正常来车时的速度曲线，决策模型会根据当时的环境状况输出适当的加速度，让自车平稳通过路口。由图 12 可知，在 3s 时自车判断与来车冲突，相比激进型来车，面对正常型来车，模型根据自车与来车的交互情况，判断没有危险产生，输出较小的减速度使车平顺通过交叉路口。综上所述，所提出的基于 BP 神经

网络的驾驶决策模型比较符合普通驾驶员通过交叉路口的驾驶行为与驾驶习惯，能够较好的避免十字路口的车车冲突。

7 结束语

基于学习算法的建模方法在搭建模型的过程中具有更强的灵活性。根据环境感知系统获取的数据实现端对端输出当前场景下驾驶车辆应有的加速度值，运动控制系统根据决策系统的输出计算出当前场景所需的节气门开度或刹车力矩。通过学习有经验驾驶员的驾驶数据，自动驾驶汽车可实现在确保安全的同时也保证乘客乘坐的舒适性。

本文主要搭建了进入十字路口前的驾驶员预判决策模型，并且根据最危险环境车和自车的驾驶状态进行分析。后续应考虑多辆环境车，使决策模型更符合人类的驾驶习惯，今后的工作将重点分析进入十字路口后的复杂工况，这涉及到更多的驾驶操作，对模型准确度有更高的要求。

致谢

本论文得到国家重点研发计划项目（2016YFB0100903-2）——智能电动汽车的感知、决策与控制关键基础问题研究的资助，在此予以感谢。

参考文献(References)

- [1] 熊璐, 康宇宸, 张培志, et al. 无人驾驶车辆行为决策系统研究[J]. 汽车技术.
- [2] Ziegler J, Bender P, Schreiber M, et al. Making Bertha Drive—An Autonomous Journey on a Historic Route[J]. IEEE Intelligent Transportation Systems Magazine, 2014, 6(2):8-20.
- [3] Ross S, Melik-Barkhudarov N, Shankar K S, et al. Learning Monocular Reactive UAV Control in Cluttered Natural Environments[J]. 2012.
- [4] Bojarski M, Del Testa D, Dworakowski D, et al. End to End Learning for Self-Driving Cars[J]. 2016.
- [5] Santana E, Hotz G. Learning a Driving Simulator[J]. 2016.
- [6] Shalev-Shwartz S, Shammah S, Shashua A. Safe, Multi-Agent, Reinforcement Learning for Autonomous Driving[J]. 2016.
- [7] Leonard J, How J, Teller S, et al. A perception-driven autonomous urban vehicle[J]. Journal of Field Robotics, 2008, 25(10):727-774.
- [8] Autonomous driving in urban environments: Boss and the Urban Challenge[J]. Journal of Field Robotics, 2008, 25(8):425-466.
- [9] Chen C, Seff A, Kornhauser A, et al. [IEEE 2015 IEEE International Conference on Computer Vision (ICCV) - Santiago, Chile (2015.12.7-2015.12.13)] 2015 IEEE International Conference on Computer Vision (ICCV) - DeepDriving: Learning Affordance for Direct Perception in Autonomous Driving[J]. 2015:2722-2730.
- [10] Wei J, Dolan J M, Litkouhi B. A Learning-Based Autonomous Driver: Emulate Human Driver's Intelligence in Low-speed Car Following[J]. Proceedings of SPIE - The International Society for Optical Engineering, 2010, 7693.
- [11] Wang X, Wu J, Gu Y, et al. Human-Like Maneuver Decision Using LSTM-CRF Model for On-Road Self-Driving[C]//2018 21st International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2018: 210-216.
- [12] Sakuma T, Miura S, Miyashita T, et al. Development of Human-Like Driving Decision Making Model based on Human Brain Mechanism[C]//2019 IEEE/SICE International Symposium on System Integration (SII). IEEE, 2019: 770-775.
- [13] Yu H, Tseng H E, Langari R. A human-like game theory-based controller for automatic lane changing[J]. Transportation Research Part C: Emerging Technologies, 2018, 88: 140-158.
- [14] Li L, Ota K, Dong M. Human-Like Driving: Empirical Decision-Making System for Autonomous Vehicles[J]. IEEE Transactions on Vehicular Technology, 2018:1-1.
- [15] Tram T, Jansson A, Grönberg, Robin, et al. Learning Negotiating Behavior Between Cars in Intersections using Deep Q-Learning[J]. 2018.
- [16] 何正风. MATLAB R2015b 神经网络技术[M]. 清华大学出版社, 2016.
- [17] He zhengfeng. Matlab R2015b neural network technology[M]. Tshinghua university press, 2016.