

文章编号: 1002-0446(2001)03-0197-04

# 一种改进的神经网络道路跟踪方法

孙怀江 杨静宇

(南京理工大学计算机系 南京 210094)

**摘要:** ALVINN 是目前世界上性能最好的基于神经网络的智能车道路跟踪系统,但由于其道路跟踪摄像机是固定不变的,导致在转弯时可能丢失道路信息,从而使其性能下降,甚至不能完成这一任务.本文提出一种道路跟踪方法,使得在学习过程中和自主道路跟踪状态下,都能有效地控制道路跟踪摄像机的方位角,以保证道路尽可能处于摄像机采集的图像中央,在客观上为改进 ALVINN 的道路跟踪性能提供了可能,计算机仿真结果验证了这种方法的有效性.

**关键词:** 智能车;神经网络;道路跟踪

**中图分类号:** TP24 **文献标识码:** B

## AN IMPROVED ROAD FOLLOWER BASED ON NEURAL NETWORK

SUN Hua-jiang YANG Jing-yu

(Nanjing University of Science and Technology, Nanjing 210094)

**Abstract** ALVINN (Autonomous Land Vehicle in a Neural Network) is the best intelligent vehicle road follower based on neural network in the world. Road following camera is fixed on ALVINN, so information about road may be missed during steering and following performance may be decreased, even the task of road following cannot be completed. In this paper, an improved based on road follower always is proposed, in which the azimuth of road following camera is efficiently controlled so that the road is always in the center of image. This opens possibilities for improving road following performance. Performance improvement is verified by computer simulation results.

**Keywords:** intelligent vehicle, neural network, road following

### 1 引言 (Introduction)

近 20 年来,智能车辆 (IV, Intelligent Vehicle) 成为国际范围内的热门研究课题,80 年代以军方资助为主要特点,进入 90 年代,资助来源更加广泛,研究小组也不断增加.道路跟踪是一种最基本的 IV 自动驾驶功能,其技术要求是根据道路跟踪摄像机采集的车体前方场景图像,确定合适的转弯指令,以保证车辆始终行驶在道路上(尽可能在路中央).传统的做法是,首先提取道路边缘,然后规划出车辆行驶的局部路径,再由控制模块完成路径跟踪.由于天气、路况、光照、遮挡、道路类型等多种因素的影响,使得由图像提取道路边缘的工作非常困难,难以给出一个适用于各种情况下的检测门限.如果采用复杂的边缘检测算法,需要耗费较多时间,再加上路径

规划也需要一定的时间,从而限制了车速的提高.美国 Carnegie Mellon 大学机器人研究所研究了一种基于神经网络(多层感知机 MLP)的道路跟踪方法 ALVINN (Autonomous Land Vehicle in a Neural Network),取得了很大成功,其道路跟踪的性能创下了当时的世界记录.ALVINN 与传统的 IV 导航系统设计思路截然不同,驾驶员在驾驶车辆行驶的过程中,ALVINN 能学习到所需的导航策略,从而具有自动驾驶的功能.由于导航行为是通过学习得到的,因此更容易适应不同的道路环境.ALVINN 道路跟踪摄像机的架设姿态是固定不变的,因此当车辆要急转弯时可能丢失道路信息,从而使道路跟踪性能变差,为此文[2]中使用了全景摄像机.本文目的是提出一种道路跟踪摄像机主动控制方法来解决这一问题.

## 2 ALVINN(ALVINN)

在训练过程中,需要有驾驶员驾驶车辆行驶,ALVINN 所采用的神经网络模型为单隐层的 MLP,ALVINN 首先将 CCD 摄像机采集的车体前方图像进行预处理,处理结果为  $32 \times 30$  的低分辨率图像并作为 MLP 的输入,MLP 的输出为转弯方向,与摄像机同步采集到的转弯方向作为 MLP 训练样本的期望输出,隐层包括 4 个单元.如果输出层仅有 1 个单元,则输出的数值对应于方向盘转动的角度,这样做理论上是可以的,但在实际使用中,网络只能给出方向盘需要转动的角度,没有办法表示相应指令的可靠性.如果输出层包括  $N$  个单元,则可以将方向盘可转动角度的范围量化为  $N$  个级,每个单元对应于一个量化级,输出值最大的单元对应于转弯指令,其数值的大小对应于可靠性的高低,训练时每个样本期望输出矢量中仅对应于实际方向盘转动角度的单元为 1,其余都为 0.这样做实际上把问题转换为一个硬分类问题,理论上也是可行的,存在的问题是,当期期望输出对应的单元从一个转到另一个相邻单元时,对应的输入只可能有很小的变化,即两个相似的输入对应于两个完全不同的类别,所以这是一个较难的分类问题,解决的办法是,假设  $h_i$  为第  $i$  个输出单元与实际转弯方向对应输出单元间的距离,则令第  $i$  个输出单元的期望输出为

$$d_i = \frac{h_i^2}{e^{\sigma^2}} \quad (1)$$

在 ALVINN 中  $\sigma = \frac{1}{10}$ . 经过这样的处理,两个差别很小的转弯指令对应期望输出矢量间的距离也很小,把难的硬分类问题转换为较容易学习的模糊分类问题.

人们都知道,用 BP 算法训练 MLP 成功解决问题的先决条件是,要有充分数量且合理分布的训练样本.虽然对于用神经网络代替人来驾驶车辆这一问题来说,充分数量的训练样本较容易得到,当人驾驶车辆在路上行驶时,可以以每秒 25 帧的速率获得大量的样本,但样本的分布难以合理,因为人驾驶车辆通常都能使车辆行驶的最佳路径上,得不到车辆在偏离最佳路径上的样本,这样训练结束后,网络在以后碰到这种情况下的反应难以预测.为了解决这个问题,ALVINN 使用了大量虚拟样本,利用每个实际样本产生 14 个虚拟样本,这些虚拟样本都对应于车辆在偏离最佳路径上行驶.为了给虚拟样本确定合适的期望转弯方向,ALVINN 使用了纯追踪(PP, Pure Pursuit)模型,该模型对 ALVINN 的成功起了

十分关键的作用.

参照图 1,当车体处于 A 点时,直线 AC 与车体纵轴重合,  $r_{AT}$  为转弯半径(与人驾驶车辆所用的转弯方向一一对应),行驶一定时间后,车体处于 T 点,直线 TC 垂直于直线 AC,如果转弯半径为无穷大即车辆一直向前行驶,则 T 与 C 重合.由于圆弧 AT 为车辆以转弯半径  $r_{AT}$  走过,因此在 A 点处直线 AC 与圆弧 AT 相切.

PP 模型认为,车体在 A 点时如果一直向前行驶 2~3 秒会到达 C 点,而驾驶员以他认为合适的转弯半径会使车体走过一个圆弧(T 为该圆弧与 TC 的交点,TC 垂直于 AC),且 T 点会在道路的中央,  $d_{AC}$  称为前视距离.当驾驶员驱车处于 A 点时,由摄像机采集的图像和同步采集的驾驶员转弯方向构成一个训练样本, B 点为 A 点平移旋转后的虚拟位置,平移量  $d_{AB} = s$ , 旋转量为  $\theta$ , 对应于虚拟位置的虚拟图像由 A 点的图像经变换、外推后得到.求车体处于 B 点的期望转弯半径时所采用的假定是,车体以该转弯半径所走过的圆弧也通过 T 点.

由图 1 容易看出,  $\frac{0.5 d_{BT}}{r_{BT}} = \cos(\angle O'BT) = \cos(\angle BTD) = \frac{d_{TD}}{d_{BT}}$ , 因此

$$r_{BT} = \frac{d_{BT}^2}{2d_{TD}} = \frac{d_{TD}^2 + d_{BD}^2}{2d_{TD}} \quad (2)$$

图 1 中 BE 平行于 AC, EF 平行于 BA, 因此

$$d_{BE} = d_{AC} - d_{TC} \tan(\theta) - s \tan(\theta) \quad (3)$$

而

$$d_{BD} = d_{BE} \cos(\theta)$$

$$d_{TD} = \frac{d_{TC}}{\cos(\theta)} + \frac{s}{\cos(\theta)} + d_{BE} \sin(\theta) \quad (4)$$

$$d_{TC} = r_{AT} - \sqrt{r_{AT}^2 - d_{AC}^2} \quad (5)$$

由式(2)至式(5)便可以求出  $r_{BT}$ . 文[1]的研究表明,当  $d_{AT}$  取为车体在 2-3 秒钟时间走过的距离时,与人的驾驶行为非常接近,这也是这种模型取得较好结果的一个原因.

## 3 主动控制 ALVINN 道路跟踪摄像机(Active control of ALVINN's road following camera)

在文[1]中 PP 模型主要用于产生虚拟训练样本,文[3]中利用该模型在不改变 ALVINN 学习过程的前提下,来控制自主行驶时 ALVINN 的道路跟踪摄像机方位角(俯仰角不变),但由于在训练时道路跟踪摄像机是固定不变的,因此在自主行驶状态

需要对转弯指令进行补偿.




图 1 求虚拟图像的期望转弯半径

Fig. 1 Determination of desired steering radius for virtual image

参见图 2, 假定车体处于 B, 俯视时摄像机光轴与车体纵轴夹角为  $\varphi$  即车体纵轴与  $BD$  重合, 俯视时摄像机光轴与  $BD'$  重合, 从而  $\varphi = \angle DBD'$ , 圆弧  $BT$  (实线) 为正确的行驶路径,  $r_{BT}$  为相应的转弯半径,  $O$  为对应的圆心. 由于摄像机的偏转, ALVINN 给出的转弯半径为  $r'$ , 此值与摄像机不偏转而车体转过角度  $\varphi$  时 ALVINN 给出的转弯半径相同 (如虚线所示), 如果不加补偿, 车体行驶的路径如图中粗线所示, 粗线部分由虚线部分绕  $B$  点逆时针转动  $\angle O'B O$  得到. 于是问题等价, 已知车体在  $B$  点, 纵轴与  $BD'$  重合时的转弯半径 (由 ALVINN 根据图像给出的转弯方向得到), 求车体在  $B$  点, 纵轴与  $BD$  重合时的转弯半径, 这可以利用  $pp$  模型与上一节求虚拟图像期望转弯半径相同的方法得到, 取  $d_{BD'}$  为前视距离,  $TD'$  垂直与  $BD'$ , 再由已知的  $r'$  可以求得目标点  $T$  的位置, 就可求得真正的转弯半径  $r_{BT}$ , 求法与上一节相同, 只是用  $\varphi$  代替  $\theta$ , 具体公式如下

$$r_{BT} = \frac{d_{BT}^2}{2d_{TD}} = \frac{d_{TD}^2 + d_{BD}^2}{2d_{TD}} \quad (6)$$

此式与式 (2) 相同, 其中

$$d_{BD} = d_{BD'} \cos(\varphi) - d_{TD'} \sin(\varphi) \quad (7)$$

而

$$d_{TD} = \cos(\varphi) [d_{TD'} + d_{BD} \tan(\varphi)] \quad (8)$$

其中

$$d_{TD'} = r' - \sqrt{(r')^2 - d_{BD'}^2} \quad (9)$$

其中  $d_{BD'}$  取为前视距离. 文 [3] 中控制道路跟踪摄像机方位角的方法是, 使俯视时摄像机光轴与直线  $BT$  重合, 而

$$\angle TBD = \tan^{-1} \left| \frac{d_{TD}}{d_{BD}} \right| \quad (10)$$

其中  $d_{TD}$  与  $d_{BD}$  由式 (8) 与式 (7) 得到.




图 2 补偿转弯指令

Fig. 2 Compensation of steering command

这种方法的特点是对 ALVINN 的学习过程不做任何改动. 我们认为, ALVINN 的导航策略虽然是通过学习得到的, 但隐含的前提是, 道路跟踪摄像机采集的图像中必须包含足够多的道路信息, 因为这是实现道路跟踪的主要特征. 如果在学习过程中, 道路跟踪摄像机固定不变, 则当转弯较急时, 所采集到的图像可能不满足这一条件, 由此产生的虚拟样本也是如此, 这些样本将会影响 ALVINN 的学习过程, 并使其推广能力变差. 因此我们提出, 在 ALVINN 学习过程中也不断调整道路跟踪摄像机方位角, 使得道路尽可能处于其视场中央, 调整的方法有两种, 一种是在学习过程中由另外一个人手动调整, 同时由传感器同步记录调整的角度, 以便由驾驶员给出的转弯指令, 根据  $pp$  模型计算所采集图像

的期望转弯方向, 计算方法与求虚拟样本期望转弯方向类似. 另一种调整方法是, 根据驾驶员给出的转弯指令, 由专门的算法来控制摄像机的方位角, 参见图 3.






图 3 学习过程中控制摄像机方位角

Fig. 3 Control of azimuth angle during learning

假定车体处于 A 点时, 与驾驶员给转弯指令相对应的转弯半径为  $r_{AT}$ , 利用  $pp$  模型确定 T 点的位置, 控



(a)



(b)

图 4 道路跟踪结果

Fig. 4 Results of road following

对道路跟踪任务而言, 图像中的道路信息至关重要, 驾驶员能在各种复杂的情况下使车体行驶在最佳路径上, 得益于人的眼睛能灵活地获取道路信息, 本文提出的主动控制道路跟踪摄像机的方法无疑能使智能车的行为与人的行为更加接近. 另外, 由实际训练样本产生虚拟训练样本是 ALVINN 中十分关键的步骤, 高质量的实际样本才能产生高质量的虚拟样本, 在学习过程中主动控制摄像机方位角为获得高质量实际样本提供了保障, 从而获得更好的整体性能.

制算法使得俯视时摄像机光轴与直线 AT 重合, 而

$$\angle TAC = \tan^{-1} \left| \frac{d_{TC}}{d_{AC}} \right| \quad (11)$$

其中  $d_{AC}$  取为前视距离,  $d_{TC}$  计算方法与式(5)相同. 自动驾驶状态下摄像机方位角的控制方法由式(10)实现.

#### 4 计算机仿真结果及结束语(Computer simulation results and conclusions)

为了比较文[1]、文[3]中和本文提出的道路跟踪方法的性能, 我们进行了大量的计算机仿真研究, 总的结果是当转弯较缓时三者的差别较小, 当转弯变急时文[3]方法比文[1]方法性能稳定, 而本文方法比文[3]方法性能稳定. 学习过程中控制摄像机方位角的方法采用第二种方法, 即利用  $pp$  模型由算法实现. 图 4(a) 为按文[3]中方法得到的道路跟踪结果, 图 4(b) 为本文方法给出的道路跟踪结果, 容易看出前一情况下已不能完成道路跟踪任务, 而后一情况下车体仍能在正确的路径上行驶.

#### 参考文献 (References)

- 1 Pomerleau D A. Neural Network Perception for Mobile Robot Guidance. Kluwer Academic Publishing, Boston, 1993
- 2 Zhu Z, Yang S, Xu G, Lin X, Shi D. Fast Road Classification and Orientation Estimation Using Omni-view Images and Neural Networks. IEEE Trans. IP, 1998, 7(8): 1182- 1197
- 3 Sunkthankar R, Pomerleau D A, Thorpe C E. Panacea: An Active Sensor Controller for the ALVINN Autonomous Driving System. Report CMU-RI-TR-93-09, Robotics Institute, Carnegie Mellon University, 1993

作者简介:

孙怀江 男. 研究领域: 智能车, 神经网络道路跟踪.