

基于神经网络与最小二乘法的车道线检测算法研究

贾会群^{1,2}, 魏仲慧¹, 何 昕¹, 李沐雨^{1,2}

(1. 中国科学院长春光学精密机械与物理研究所, 长春 130033; 2. 中国科学院大学, 北京 100049)

[摘要] 为提高车道线的检测精度和识别率, 在构建新的道路模型基础上提出了一种基于 BP 神经网络与最小二乘法曲线模型的车道线检测算法。该算法运用具有方向性的线检测器对道路图像进行边缘检测, 提取出道路边缘点; 接着利用 BP 神经网络估计新的道路模型参数确定模型函数; 根据新道路模型函数的上凸性, 以函数最大值为分界点, 分界点左侧为左车道线, 右侧为右车道线, 从而完成对左右车道线的检测; 最后利用最小二乘法实现左右车道线重构。实验结果表明, 所提出的算法的检测精度达到 92.8%, 适合多种道路状况下的车道线检测, 具有较好的鲁棒性。

关键词: 车道线检测; BP 神经网络; 最小二乘法; 道路模型

A Research on Lane Marking Detection Algorithm Based on Neural Network and Least Squares Method

Jia Huiqun^{1,2}, Wei Zhonghui¹, He Xin¹ & Li Muyu^{1,2}

1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033;

2. University of Chinese Academy of Sciences, Beijing 100049

[Abstract] In order to enhance the detection accuracy and recognition rate of lane markings, on the basis of the construction of a new road model, a lane marking detection algorithm based on BP neural network (BPNN) and least squares curve model is proposed. The algorithm uses directional line detectors to detect the edges of road image and extract the road edge points. Then BPNN is used for estimating the parameters of new road model to determine model function. According to the upward convexity of new road model function, the maximum value of the function becomes the demarcation point, which separates the left marking and right marking of the lane, to complete the detection of lane markings. Finally, the least squares method is utilized to reconstruct the left and right lane markings. The experimental results show that the algorithm proposed achieves a detection accuracy of up to 92.8% with good robustness, suitable for lane marking detection in a variety of road conditions.

Keywords: lane marking detection; BP neural network; least square method; road model

前言

基于视觉的人工智能导航是计算机视觉领域的一项重要应用^[1], 因其方法简单、可适应复杂的道路环境被广泛应用到自主车辆的道路识别系统中^[2-3]。目前基于视觉的车道线检测算法包括基于特征^[4-6]和基于模型^[7-8]两类。基于特征的算法主

要是利用颜色、纹理和形状等信息来提取车道线^[5], 但路面光照发生变化、标志线磨损、路面出现水渍和阴影等情况都将会影响检测效果^[6]。基于模型的算法首先估计道路模型, 然后利用图像信息确定模型参数。常用的道路模型有直线模型、抛物线模型和三次样条曲线模型^[7-10]。大量研究发现: 直线模型虽算法简单运行速度快, 但不适合弯曲的车道线检测, 应用范围窄; 抛物线模型易受复杂道路环境的影响,

原稿收到日期为 2017 年 4 月 13 日, 修改稿收到日期为 2017 年 5 月 11 日。

通信作者: 魏仲慧, 研究员, 博士生导师, E-mail: wzhlvp@sohu.com。

鲁棒性不好;三次样条曲线模型虽然检测效果较好,但算法复杂,计算量大。

为解决上述问题,本文中通过建立一种新的道路模型提出了一种基于 BPNN 与最小二乘法曲线模型的车道线检测算法,首先运用具有方向性的掩模对检测图像进行空域滤波,也即用图像滤波模板对图像的像素进行处理,检测出车道线的边缘点;其次运用 BP 神经网络进行道路模型参数估计,拟合出复杂的函数曲线;然后利用复杂曲线的函数上凸性在最大值处将曲线分为左右两部分即将左右车道线划分开,从而检测出左右车道线;最后运用最小二乘法对检测出的左右车道线进行拟合重构。该方法克服了直线模型和抛物线模型的缺点,适合不同的道路情况,具有较好的检测性能。

1 BPNN 与最小二乘法车道线检测




图 2 不同检测器检测效果

1.2 道路模型

实际道路状况千差万别,不利于车道线的检测,因此可根据先验知识采用适当的假设来简化道路模型^[12],本文中根据常用的道路假设提出一种新的道路模型:

- (1) 道路部分一般位于图像的下半部分;
- (2) 道路的左右车道线整体的几何模型可视为一复杂的曲线函数;
- (3) 左右两侧的车道线看作复杂曲线模型的左右两部分,且该曲线为上凸曲线存在最大值点,最大值点的左侧为左车道线,右侧为右车道线。

根据以上假设构建道路模型,如图 3 所示。



图 3 道路模型

1.3 BP 神经网络

1.1 车道线边缘检测

在道路图像中,车道线和灰色的路面连接处灰度值不连续,存在较大的变化量。利用这一性质通过对图像求导提取出灰度值突变的像素点,从而检测出车道线的边缘。常用的边缘检测器有 sobel 检测器、prewitt 检测器、canny 检测器和方向性线检测器等^[7-11]。由于在道路图中车道线和水平线存在一定的夹角,因此本文中采用具有方向性的线检测器如图 1 所示,图 2 示出不同检测器的检测效果。

-1	-1	4
-1	4	-1
4	-1	-1

(a) 45° 线检测器

4	-1	-1
-1	4	-1
-1	-1	4

(b) 135° 线检测器

图 1 方向性线检测器

BPNN 是一种按误差逆传播算法训练权值的多层神经网络,由数据流的正向传播和误差信号的反向传播两个过程构成。正向传播时,传播方向为输入层(input layer)→隐层(hidden layer)→输出层(output layer),如图 4 所示。当数据流正向从输出层输出的结果不是期望的结果时,则将两者之间的误差信号反向传播,不断更新权值直至误差信号达到最小^[13]。




图 4 BP 神经网络结构示意图

1.3.1 BP 神经元

图 5 示出最基本的 BP 神经元模型,具有加权、

求和与转移功能^[13]。其中 $x_1, x_2, \dots, x_i, \dots, x_n$ 分别代表来自神经元 1, 2, $\dots, i, \dots, n$ 的输入; $w_{j1}, w_{j2}, \dots, w_{ji}, \dots, w_{jn}$ 则分别表示神经元 1, 2, $\dots, i, \dots, n$ 与第 j 个神经元的连接强度, 即权值; b_j 为阈值; $f(\cdot)$ 为传递函数; y_j 为第 j 个神经元的输出。




图5 BP 神经元模型

神经元的净输入为

$$S_j = \sum_{i=1}^n w_{ji} \cdot x_i + b_j = \mathbf{W}_j \mathbf{X} + b_j \quad (1)$$

式中: $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$; $\mathbf{W}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]$ 。神经元的净输入 S_j 通过传递函数 $f(\cdot)$ 可得神经元的输出 y_j :

$$y_j = f(s_j) = f(\mathbf{W}_j \mathbf{X} + b_j) \quad (2)$$

式中 $f(\cdot)$ 是单调有界函数, 由生物细胞信号传递的性质定义。常用的 $f(\cdot)$ 函数曲线图如图6所示。其中, Log-sigmoid 型函数为

$$f(s) = \frac{1}{1 + e^{-s}} \quad (3)$$

式中: $s \in (-\infty, +\infty)$; $f(s) \in (0, 1)$ 。tan-sigmoid 型传递函数为

$$f(s) = \frac{2}{1 + e^{-2s}} - 1 \quad (4)$$

式中: $s \in (-\infty, +\infty)$; $f(s) \in (-1, 1)$ 。




图6 BP 神经元常用的传递函数

1.3.2 BP 神经元正向传播

图7示出一3层BPNN拓扑结构, 其隐层的输出为

$$z_k = f_1\left(\sum_{i=0}^n v_{ki} x_i\right) \quad (5)$$

式中: $k = 1, \dots, q$; x_0 为阈值; v_{k0} 为阈值和隐层节点的




图7 3层神经网络拓扑结构

连接权值。输出层节点的输出为

$$y_j = f_2\left(\sum_{k=0}^q w_{jk} z_k\right) \quad (6)$$

式中: $j = 1, 2, \dots, m$; z_0 为阈值; w_{j0} 为阈值和输出层节点的连接权值。至此BPNN就得到了 n 维数据向量和 m 维数据向量的近似映射关系, 因此一个3层的BPNN即可描述任意复杂的数学模型。

2.3.3 BP神经网络反向传播

(1) 定义误差函数

输入 P 个学习样本, 用 $x^1, x^2, \dots, x^p, \dots, x^P$ 来表示。第 p 个样本输入到网络后得到输出 y_j^p ($j = 1, 2, \dots, m$)。于是定义第 p 个样本的误差 E_p :

$$E_p = \frac{1}{2} \sum_{j=1}^m (t_j^p - y_j^p)^2 \quad (7)$$

式中 t_j^p 为期望输出。对于 P 个样本, 全局误差为

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{j=1}^m (t_j^p - y_j^p)^2 = \sum_{p=1}^P E_p \quad (8)$$

(2) 输出层权值的变化

采用梯度下降法, 更新权值 w_{jk} , 使全局误差 E 最小, 即

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial}{\partial w_{jk}} \left(\sum_{p=1}^P E_p \right) = \sum_{p=1}^P \left(-\eta \frac{\partial E_p}{\partial w_{jk}} \right) \quad (9)$$

式中 η 为学习率。定义误差信号为

$$\delta_{yj} = -\frac{\partial E_p}{\partial S_j} = -\frac{\partial E_p}{\partial y_j} \cdot \frac{\partial y_j}{\partial S_j} \quad (10)$$

式中第1项为

$$\frac{\partial E_p}{\partial y_j} = \frac{\partial}{\partial y_j} \left[\frac{1}{2} \sum_{j=1}^m (t_j^p - y_j^p)^2 \right] = - \sum_{j=1}^m (t_j^p - y_j^p) \quad (11)$$

第2项

$$\frac{\partial y_j}{\partial S_j} = f_2'(S_j) \quad (12)$$

是输出层传递函数的偏微分。于是:

$$\delta_{yj} = \sum_{j=1}^m (t_j^p - y_j^p) f_2'(S_j) \quad (13)$$

由链定理得

$$\frac{\partial E_p}{\partial w_{jk}} = \frac{\partial E_p}{\partial S_j} \cdot \frac{\partial S_j}{\partial w_{jk}} = -\delta_{yj} z_k = -\sum_{j=1}^m (t_j^p - y_j^p) f_2'(S_j) \cdot z_k \quad (14)$$

将式(14)代入式(9)整理后,得到隐层和输出层各神经元之间的连接权值更新公式为

$$\Delta w_{jk} = \sum_p \sum_{j=1}^m \eta (t_j^p - y_j^p) f_2'(S_j) z_k \quad (15)$$

(3) 隐层权值的变化

$$\Delta v_{ki} = -\eta \frac{\partial E}{\partial v_{ki}} = -\eta \frac{\partial}{\partial v_{ki}} \left(\sum_{p=1}^P E_p \right) = \sum_{p=1}^P \left(-\eta \frac{\partial E_p}{\partial v_{ki}} \right) \quad (16)$$

定义误差信号为

$$\delta_{zk} = -\frac{\partial E_p}{\partial S_k} = -\frac{\partial E_p}{\partial z_k} \cdot \frac{\partial z_k}{\partial S_k} \quad (17)$$

式中第1项为

$$\frac{\partial E_p}{\partial z_k} = \frac{\partial}{\partial z_k} \left[\frac{1}{2} \sum_{j=1}^m (t_j^p - y_j^p)^2 \right] = -\sum_{j=1}^m (t_j^p - y_j^p) \frac{\partial y_j}{\partial z_k} \quad (18)$$

由链定理得

$$\frac{\partial y_j}{\partial z_k} = \frac{\partial y_j}{\partial S_j} \cdot \frac{\partial S_j}{\partial z_k} = -\delta_{yj} z_k = f_2'(S_j) \cdot w_{jk} \quad (19)$$

第2项

$$\frac{\partial z_k}{\partial S_k} = f_1'(S_k) \quad (20)$$

是隐层传递函数的偏微分。于是:

$$\delta_{zk} = \sum_{j=1}^m (t_j^p - y_j^p) f_2'(S_j) w_{jk} f_1'(S_k) \quad (21)$$

由链定理得

$$\frac{\partial E_p}{\partial v_{ki}} = \frac{\partial E_p}{\partial S_k} \cdot \frac{\partial S_k}{\partial v_{ki}} = -\delta_{zk} x_i = -\sum_{j=1}^m (t_j^p - y_j^p) f_2'(S_j) \cdot w_{jk} f_1'(S_k) \cdot x_i \quad (22)$$

将式(22)代入式(16)整理后,得到输入层和隐层各神经元之间的连接权值更新公式为

$$\Delta v_{ki} = \sum_{p=1}^P \sum_{j=1}^m \eta (t_j^p - y_j^p) f_2'(S_j) w_{jk} f_1'(S_k) x_i \quad (23)$$

1.4 最小二乘法

存在一组数据 $(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)$ 满足某一函数原型 $g(x)$ 。找到满足各个观测值 y_i 与 $g(x_i)$ 的偏差平方和最小的曲线是最小二乘法的目标。通过对偏差平方和分别求取其对参数 $a_0, a_1, \dots, a_i, \dots, a_n$ 的偏导数,并令各偏导数为0,得到 $n+1$ 个方程,以式(26)矩阵方程表示,据此解出所需的 n 次曲线参数。

$$g(x) = a_0 + a_1 x + a_2 x^2 + \dots + a_n x^n \quad (24)$$

$$\sum_{i=0}^n (y_i - g(x_i))^2 = \sum_{i=0}^n (y_i - (a_0 + a_1 x_i + a_2 x_i^2 + \dots + a_n x_i^n))^2 \quad (25)$$

$$\begin{pmatrix} \sum_{i=0}^n 1 & \sum_{i=0}^n x_i & \dots & \sum_{i=0}^n x_i^n \\ \sum_{i=0}^n x_i & \sum_{i=0}^n x_i^2 & \dots & \sum_{i=0}^n x_i^{n+1} \\ \vdots & \vdots & \dots & \vdots \\ \sum_{i=0}^n x_i^n & \sum_{i=0}^n x_i^{n+1} & \dots & \sum_{i=0}^n x_i^{2n} \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} \sum_{i=0}^n y_i \\ \sum_{i=0}^n x_i y_i \\ \vdots \\ \sum_{i=0}^n x_i^n y_i \end{pmatrix} \quad (26)$$

2 实验结果与分析

为验证算法的有效性和稳定性,将本文中提出的算法在 MATLAB2014a 软件平台上使用真实的道路图片(可见光相机图片和彩色相机图片)进行测试。这些道路图片中包含直线道路、曲线道路、有阴影道路图片和无阴影道路图片。实验结果表明,本算法的检测精度在 90% 以上,对于含有阴影的道路状况该算法依然可以很好地提取车道线,部分实验结果如图 8 和图 9 所示。其中图 8 是 BP 神经网络利用所提道路模型对车道线进行检测和重构的结果,图中的小圆圈表示所拟合曲线的最大值,也是左右车道线的分界点。图 9 是最小二乘法对 BP 神经网络所检测出的左右车道线进行重构的结果,包含直线道路、弯曲道路、有阴影道路和无阴影道路的检测结果。

以上所述验证了所提出的方法对静态车道图像有较好的检测性能,而实际行车得到的是动态序列图像且道路环境要复杂得多,为进一步验证该算法对车道线动态序列图像检测的有效性,本文中




图8 BP神经网络道路检测



图9 最小二乘法左右车道线检测

DSP 为硬件平台,使用大众轿车,在吉林省长春市东南湖大路进行实验。平台处理速度达 25 帧/s,满足了实时性的要求,部分实验结果如图 10 和图 11 所示。由图可见,在路口这样复杂的道路环境如人行道、行人、车辆和存在其它道路标志线的情况下,所提方法依然可以有效地对车道线进行检测和重构。

3 结论

针对采用直线模型、抛物线模型和三次样条曲

线模型检测车道线时所存在的缺点,本文中通过建立自己的道路模型提出了一种基于 BP 神经网络与最小二乘法曲线模型的车道线检测算法。算法利用所提取的道路边界点,进行神经网络曲线模型拟合,检测出左右车道线,最后利用最小二乘法对左右车道线进行检测和重构。不同相机所拍图像和不同道路状况下的车道线检测结果表明,所提出的算法能有效地对不同类型的车道线进行检测。动态序列图像的车道线检测结果表明,所提算法满足了实际行车的实时性要求。




图10 神经网络车道线序列图像检测



图11 最小二乘法车道线序列图像检测

参考文献

- [1] KHALIFA O O, KHAN I M, ASSIDIQAA M. A hyperbola-pair based lane detection system for vehicle guidance [C]. Proceedings of the World Congress on Engineering Computer Science 2010:20-22.
- [2] YU B, JAIN A K. Lane boundary detection using a multiresolution Hough transform [C]. Proceedings of International Conference on Image Processing 2010:748-751.
- [3] CHENG H Y, JENG B S. Lane detection with moving vehicles in the traffic scene [J]. IEEE Transactions on Intelligent Transportation Systems 2006, 7(4):571-582.
- [4] GAO S, QIN L, CHEN C B. Structured road lane marking identification algorithm [J]. Journal of Xi'an Technological University, 2013, 33(1):14-19.
- [5] LI Q, ZHENG N N. A prototype autonomous vehicle and its algorithms for lane detection [J]. IEEE Transactions on Intelligent Transportation Systems 2004, 5(4):300-308.
- [6] SHARMA U K, DAVIS L S. Road boundary detection in range imagery for an autonomous robot [J]. IEEE Transactions on Robotics and Automation 2009, 4(5):515-523.
- [7] LUTZELER M, DICKMANN S E D. Recognition of intersections on unmarked road networks [C]. Proceedings of the IEEE Intelligent Vehicles Symposium 2009:302-307.
- [8] WANG Y. Lane detection using spline model [J]. Pattern Recognition Letters 2004, 21(3):677-689.
- [9] 魏新国, 徐佳, 张广军. 星敏感器质心定位的s曲线误差补偿 [J]. 光学精密工程 2013, 21(4):849-857.
- [10] 陈洪波, 王强, 徐晓蓉, 等. 用改进的Hough变换检测交通标志图像的直线特征 [J]. 光学精密工程 2009, 17(15):1112-1118.
- [11] YOO Hunjae, YANG Ukil. Gradient-enhancing conversion for illumination-robust lane detection [J]. IEEE Transactions on Intelligent Transportation Systems 2013, 14(13):1192-1202.
- [12] 徐春友. 智能车辆视觉与GPS综合导航方法的研究 [D]. 长春:吉林大学 2001.
- [13] 魏海坤. 神经网络设计的理论与方法 [M]. 北京:国防工业出版社 2005.2.