

弱监督分层深度学习的车辆识别算法

王海¹ 蔡英凤² 陈龙² 江浩斌¹

(1. 江苏大学汽车与交通工程学院, 镇江, 212013; 2. 江苏大学汽车工程研究院, 镇江, 212013)

摘要: 针对已有分类器在结构形式和训练方法的不足, 构建了一个以二维深度置信网络(2D deep belief networks, 2D-DBN)为架构的弱监督分层深度学习车辆识别算法。首先, 将传统一维的深度置信网络(Deep belief networks, DBN)扩展成 2D-DBN, 并构建相应分类器结构, 从而能够直接以二维图像像素矩阵作为输入; 其次, 在传统无监督训练的目标函数中, 引入了一个具有适当权重的判别度正则化项, 将原有无监督训练转化为带有较弱监督性的弱监督训练方式, 从而使提取的特征较传统无监督特征更具判别性。多组对比实验表明, 本文所提算法在识别率等指标上要优于已有深度学习算法。

关键词: 车辆识别; 深度学习; 弱监督训练; 特征提取

中图分类号: TP391.4 文献标志码: A

Vehicle Recognition Algorithm Based on Weakly Supervised Hierarchical Deep Learning

Wang Hai¹, Cai Yingfeng², Chen Long², Jiang Haobin¹

(1. School of Automotive and Traffic Engineering, Jiangsu University, Zhenjiang, 212013, China; 2. Automotive Engineering Research Institute, Jiangsu University, Zhenjiang, 212013, China)

Abstract: Focusing on the shortage of structure and training methods of existing classifier, a weakly supervised hierarchical deep learning vehicle recognition algorithm with 2D deep belief networks(2D-DBN) is proposed. Firstly, the traditional one-dimensional deep belief network(DBN) is expanded to 2D-DBN, thus the pixel matrix of the 2-D images is taken as the input. Then, a determination regularization term with proper weight is introduced to the traditional unsupervised training objective function. By this change, the original unsupervised training is transferred to the weakly supervised training, so that the extracted features have more discrimination ability. Multiple sets of comparative experiments show that the proposed algorithm is better than other deep learning algorithms in respect of recognition rate.

Key words: vehicle recognition; deep learning; weakly supervised training; feature extraction

引言

视觉车辆检测与识别对于汽车主动安全、智能车辆和交通监控系统等应用有着至关重要的作用^[1-3]。由于其重大的理论研究价值和实际应用价值, 使得车辆检测一直以来备受学术界以及工业界的

关注。但车辆识别检测工作中,由于车辆的姿态、遮挡、涂装、光照以及背景的不同,会导致车辆在图像中呈现出非常多样的表现,从而给车辆识别带来巨大的挑战。机器学习框架下的视觉感知的一个关键是对感知对象建立合适的表示方式,也就是常说的特征。一个优秀的特征可以更好地保留感知对象的相关信息而不易受到无关变化的影响。对于车辆识别任务,已有的工作也大部分集中于设计具有各种最具判别能力的特征上。现有的经典车辆识别方法均采用各种研究者人工设计的特征,如类 Haar 小波特征^[4]、Gabor 特征^[5]、方向梯度直方图(HoG)^[6]及其各种变体和组合,然后将所设计特征输入到一个可训练分类器中,如 SVM^[7]、Boosted 分类器^[8]或随机森林^[9],再通过某种有监督的训练方式获得最终车辆识别分类器。在上述传统机器学习的方法中,最为突出的特点是所有低级特征,实际上都是通过手工设计得到,缺乏理论的依据与支撑。此外,手工选取特征是否优秀很大程度上靠经验和运气,且其设计过程本身费时费力。因此,迫切需要一种方法能够自动设计出适合车辆识别任务的特征。令人欣喜的是,近年来深度学习的出现有望解决特征的自动设计这一难题^[10-12]。简略地说,深度学习是通过模仿人脑分析学习的机制来描述数据,如图像、声音和文本。它通过模拟人脑的复杂模型,将分级信息处理的思路用到特征表示上,即层级特征的概念。深度学习通过特征从低到高地逐层变换,将样本在原空间的特征表示变换到一个新特征空间,从而使分类或预测更加容易。相比于用人工规则构造特征的方法,由于特征是通过大量样本而自动学习生成,因此能够更深入地表达数据内部蕴含的丰富信息。作为机器学习一个新颖的重要分支,深度学习技术近年来引发了产业界和学术界的巨大关注。正是因为以上原因,本文选用深度学习框架下的深度置信网络(Deep belief networks, DBN)。作为深度学习常用模型之一,DBN 是一种生物启发式的训练架构,它避免了显式的特征取样,隐式地从训练数据中进行学习,这使得它明显有别于其他基于神经网络的分类器。

1 DBN 基本概念

DBN 是一个多层网络结构,其本质可视为多层神经网络的一种变形。DBN 的每一层都包含若干含有随机隐式变量的神经元,相邻层之间的各神经元通过权值矩阵相连接。DBN 的训练过程大致可以分为无监督特征抽取和有监督网络调整两个阶段。无监督特征抽取阶段主要通过大量无标记样本,通过层间特征抽取,初步确定网络权值;有监督网络调整阶段则将样本标签引入到网络中,以最大判别性为目标,对网络权值再次进行调整。例如,图 1 为典型的具有 1 个输入层 V_1 和 N 个隐层 H_1, H_2, \dots, H_N 的 DBN, x 是以向量形式输入的样本, y 是样本标签。在无监督特征抽取阶段, DBN 相邻层如 V_1 和 H_1 , H_1 和 H_2, \dots, H_{N-1} 和 H_N 可视为受限波尔兹曼机,并通过逐层重建方式将特征从底层松散特征抽象为高层紧凑特征^[13]。在有监督网络阶段, DBN 将采用“唤醒-休眠”的方法,通过基于梯度的全局优化策略进行网络权值调整。目前,由于出色的特征抽取能力, DBN 已经在包括字符检测、语音识别等应用中取得了很好的效果。但是,对于本文所涉及的车辆识别任务,传统 DBN 仍有不足:已有 DBN 在特征抽取阶段均选用了无监督的训练方式,以该方式获得的特征实质是抽取一种生成式的特征,其更侧重于对样本的全面表达,而针对车辆识别的二分类任务,则希望获得一种更具判别性的特征。本文为更好地满足车辆识别任务,针对以上不足,在已有 DBN 基础上




图 1 典型的 DBN 结构示意图

Fig. 1 Structure of typical DBN

进行了一些改进和创新,构建了一个以二维 DBN(2D-DBN)为架构的弱监督分层深度学习算法。其创新性具体体现在:(1)将传统一维的 DBN 扩展成 2D-DBN,并构建相应分类器结构,从而能够直接以二维图像像素矩阵作为输入;(2)在传统无监督训练的目标函数中,引入了一个具有适当权重的判别度正则化项,将原有无监督训练转化为带有较弱监督性的弱监督训练方式,从而使提取的特征较传统无监督特征更具判别性。

2 分层深度学习分类器

采用机器学习理论的视觉车辆识别是将道路图像或视频中待判断的子区域输入到一个训练完毕的分类器中,分类器对该待判断的子区域作出是否是车辆的判断。而其核心环节,即分类器的训练则是通过大量样本来实现。令 \mathbf{X} 为样本集合,其中共有 K 个包含车辆及非车辆的图像。不妨设 $\mathbf{x}_k \in \mathbf{R}^{P \times Q}$ 为第 k 个样本,则样本集可以表达为

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k, \dots, \mathbf{x}_K] \quad (1)$$

与之类似,令 \mathbf{Y} 为样本集 \mathbf{X} 所对应的标签集,并同样写成

$$\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_k, \dots, \mathbf{y}_K] \quad (2)$$

式中: \mathbf{y}_k 为样本 \mathbf{x}_k 对应的标签。此处,若 \mathbf{x}_k 属于车辆,则 $\mathbf{y}_k = [1, 0]$;反之, $\mathbf{y}_k = [0, 1]$ 则是非车辆样本的标签。依据车辆识别任务,本文设计的 2D-DBN 分类器结构如图 2 所示。该 2D-DBN 是一个相邻层完全互联的置信网络,包括 1 个可见的输入层 V^1 ,若干个隐层 H^1, \dots, H^N 以及 1 个位于顶层的标签层 L_a 。可视层 V^1 包含 $P \times Q$ 个神经元,其尺寸和输入样本的大小相等。顶层标签层仅含有两个单元,与待分类类别数量相等。多个隐层位于输入层和标签层之间,相邻层通过权值矩阵 θ 相连。




图 2 采用 2D-DBN 的车辆识别分类器结构
Fig.2 Structure of vehicle classifier with 2D-DBN

3 分层深度学习分类器训练

(1)传统无监督训练方法。无监督训练中,传统方法大多采用 Greedy-wise 重构算法进行可视层及隐层的任意两层之间的权值调整^[14]。以可视层 V^1 和隐层 H^1 为例进行简单说明。可视层 V^1 和隐层 H^1 可视为一个受限制玻尔兹曼机(Restricted Boltzmann machine, RBM)。RBM 中 V^1 和 H^1 任意两个节点间的状态能量 $(\mathbf{v}^1, \mathbf{h}^1)$ 可写为

$$E(\mathbf{v}^1, \mathbf{h}^1, \theta^1) = -(\mathbf{v}^1 \mathbf{A} \mathbf{h}^1 + \mathbf{b}^1 \mathbf{v}^1 + \mathbf{c}^1 \mathbf{h}^1) = - \sum_{i=1, j=1}^{i \leq M, j \leq M} \sum_{p=1, q=1}^{p \leq P, q \leq P} v_{ij}^1 A_{ij, pq}^1 h_{pq}^1 - \sum_{i=1, j=1}^{i \leq M, j \leq M} b_{ij}^1 v_{ij}^1 - \sum_{p=1, q=1}^{p \leq P, q \leq P} c_{pq}^1 h_{pq}^1 \quad (3)$$

式中: $\theta^1 = [\mathbf{A}^1, \mathbf{b}^1, \mathbf{c}^1]$ 为可视层 V^1 和隐层 H^1 节点间的权值参数; $A_{ij, pq}^1$ 为可视层 V^1 节点 (i, j) 和隐层 H^1 节点 (p, q) 的连接权值; b_{ij}^1 和 c_{pq}^1 为 V^1, H^1 对应节点间的偏移量。RBM 可视为联合概率分布,则有

$$P(\mathbf{v}^1, \mathbf{h}^1; \theta^1) = \frac{1}{Z} e^{-E(\mathbf{v}^1, \mathbf{h}^1; \theta^1)} = \frac{e^{-E(\mathbf{v}^1, \mathbf{h}^1; \theta^1)}}{\sum_{\mathbf{v}^1} \sum_{\mathbf{h}^1} e^{-E(\mathbf{v}^1, \mathbf{h}^1; \theta^1)}} \quad (4)$$

式中: Z 为归一化参数。此外,输入状态 \mathbf{v}^1 和隐状态 \mathbf{h}^1 间的条件概率分布可用 Logistic 函数表达为

$$p(\mathbf{x}_i^1) = p(\mathbf{h}^1 | \mathbf{v}^1) = \prod_{p, q} p(h_{pq}^1 | \mathbf{v}^1) \\ p(h_{pq}^1 | \mathbf{v}^1) = \sigma \left(\sum_{i=1, j=1}^{i \leq M, j \leq M} v_{ij}^1 A_{ij, pq}^1 + c_{pq}^1 \right) \quad (5)$$

式中 $\sigma(x) = 1/(1 + \exp(-x))$ 。该 RBM 对应的无监督训练目标函数为

$$L = - \sum_{i=1}^{|D_{\text{unlab}}|} \log p(\mathbf{x}_i') \quad (6)$$

式中: $D_{\text{unlab}} = \{\mathbf{x}_i'\}_{i=1}^{|D_{\text{unlab}}|}$ 表示第 l 层所有无标签样本。对于该目标函数, 可以通过 Hinton 提出的对比分歧(Contrastive divergence, CD)算法逐步更新参数 θ 中的连接权值和偏移量进行训练^[15]。

(2)改进的半监督训练方法。第(1)节给出了传统无监督的学习方法。如引言中所述, 以该传统无监督方式获得的特征实质是抽取一种生成式的特征, 其更侧重于对样本的全面表达, 而针对车辆识别的二分类任务, 则希望获得一种更具判别性的特征。因此对训练目标函数进行调整, 引入样本标签信息, 添加样本判别度正则项, 并赋予一定的权值。新目标函数为

$$L = (1 - \mu) \left(- \sum_{i=1}^{|D_{\text{unlab}}|} \log p(\mathbf{x}_i') \right) + \mu \left(- \sum_{i=1}^{|D_{\text{lab}}|} \log p(y_i' | \mathbf{x}_i') \right) \quad (7)$$

对比式(6,7)中增加了判别度正则化项 $-\sum_{i=1}^{|D_{\text{lab}}|} \log p(y_i' | \mathbf{x}_i')$, 并赋予权值 μ 。对于新的目标函数, 同样可以通过 Hinton 提出的对比分歧算法进行训练。

(3)有监督深度网络参数局部寻优。在弱监督训练的基础上, 将该二维深度置信网络视为普通的多层神经网络并采用反向传播的方法, 引入标签层信息对网络权值 $\theta = [\mathbf{A}, \mathbf{b}, \mathbf{c}]$ 进行进一步的微调, 获得局部最优参数。其目标函数为

$$\min \left\{ - \sum_i \mathbf{y}_i \log \hat{\mathbf{y}}_i \right\} \quad (8)$$

式中: \mathbf{y}_i 和 $\hat{\mathbf{y}}_i$ 为某个输入样本 \mathbf{X}_i 的真实标签和计算标签。至此, 即可获得用于车辆识别判断的分层深度学习分类器。

4 实验与分析

4.1 实验准备

本节将通过实验来评价和分析本文所提的弱监督分层深度学习车辆识别分类器。实验中所采用的训练正样本图库是 Caltech 1999 数据图库中的车辆后视图, 共 126 幅; 此外, 还有项目组从所记录的道路视频中选取的车辆图约 600 幅。负样本图库来自于 1 000 幅不包含车辆的图片构成, 从中随机选取 10 000 张子图片, 并以其中 5 000 幅作为训练负样本, 另外 5 000 幅作为测试样本。图 3 为部分代表性的正负训练样本。测试正样本图片来自于 KITTI 标准道路图库, 包含多种路况, 共 1 800 幅, 其中含有车辆 2 785 辆^[16]。用于车辆检测器性能评价的实验平台为惠普工作站, 其主要参数为 Intel 酷睿 2 双核



(a) 正样本
(a) Positive samples

(b) 负样本
(b) Negative samples

图 3 正负训练样本示例

Fig. 3 Positive and negative training samples

2.67 GHz处理器,8 GB内存,操作系统为 Windows 7,编程软件为 Microsoft Visual 2008+OPENCV2.3。

4.2 实验结果和分析

(1)传统方法和本文方法的对比。实验1中,采用同样的深度网络层数和神经元个数,对传统深度学习车辆识别分类器(无监督训练2D-DBN)和本文所提弱监督分层深度学习分类器的识别能力进行实验和比较。实验中,两组分类器的结构保持一致,均含有1个可见的输入层、1个可见的输出层及5个隐层。输入层神经元数目为 32×32 ,和输入图像样本的维数相等;5个隐层的神经元个数分别为 $64 \times 64, 32 \times 32, 32 \times 32, 16 \times 16$ 和 16×16 ;输出层大小均为 2×1 。同时,式(6)中的权重系数 μ 从0.1取至0.9,以0.1为间隔递增进行实验。此外,试验还与SVM等传统浅层结构的分类器进行了比较。实验1的结果如表1所示。表1中给出了SVM等传统浅层结构的分类器、无监督训练2D-DBN分类器和本文所提不同类型的2D-DBN分类器在测试样本中的检测率和误检率。

表1 不同深度学习分类器的分类效果

Tab. 1 Classification effect of different deep classifiers

分类器	正样本检测数	检测率/%	负样本误检数	误检率/%
SVM ^[7]	2 463/2 785	88.44	52/5 000	1.04
Boosting ^[8]	2 518/2 785	90.41	86/5 000	1.72
随机森林 ^[9]	2 539/2 785	91.17	41/5 000	0.82
无监督训练2D-DBN	2 667/2 785	95.76	13/5 000	0.26
弱监督训练2D-DBN($\mu = 0.1$)	2 673/2 785	95.98	10/5 000	0.20
弱监督训练2D-DBN($\mu = 0.2$)	2 692/2 785	96.67	7/5 000	0.14
弱监督训练2D-DBN($\mu = 0.3$)	2 675/2 785	96.05	8/5 000	0.16
弱监督训练2D-DBN($\mu = 0.4$)	2 654/2 785	95.32	7/5 000	0.14
弱监督训练2D-DBN($\mu = 0.5$)	2 632/2 785	94.50	8/5 000	0.16
弱监督训练2D-DBN($\mu = 0.6$)	2 624/2 785	94.22	11/5 000	0.22
弱监督训练2D-DBN($\mu = 0.7$)	2 599/2 785	93.32	15/5 000	0.30
弱监督训练2D-DBN($\mu = 0.8$)	2 550/2 785	91.56	21/5 000	0.42
弱监督训练2D-DBN($\mu = 0.9$)	2 428/2 785	87.18	35/5 000	0.70

从表2中可以看出,深度结构下的车辆分类器分类能力远远优于传统浅层结构分类器。另一方面,总的来说,大部分弱监督训练的分类器在检测效果上要优于无监督训练的分类器。因此,可以认为由于判别度正则项的引入,在原有特征抽取的基础上提升了所抽取特征的判别度,并反映在最终分类能力上。此外,当 $\mu = 0.2$ 时,所对应的弱监督训练2D-DBN分类器具有最佳的分类能力。最后,还需要注意,当 $\mu > 0.3$ 时,所训练分类器的分类能力出现显著的下降,甚至低于非监督训练的分类器。可以认为,当监督权重 μ 过大时,分类器训练就从弱监督转为强监督,从而使得分类器效果降低。此外,该实验中固定无标记样本数,并采用了不同个数的有标样本 $|D_{\text{lab}}|$,结果表明当有标样本数和无标样本数比例超过20%时,识别率较为稳定,变化波动在0.05%以内。

(2)不同2D-DBN结构的对比。实验2中,为了探索不同的深度网络层数对该分类器分类能力的影响,对于所提弱监督分层深度学习车辆识别分类器,本文采用了3种不同的2D-DBN结构进行实验。该实验设计了8种不同隐层数的分类器,隐层数取2~10,各隐层神经元数如表2所示。此外,7种不同隐层数的分类器的监督权重 μ 均设为0.2。

实验2的结果如图4所示。图4中给出了不同隐层数分类器在测试样本中的检测率。不难发现,就本文所提车辆识别应用而言,分类效果首先随着隐层数的增加而提升,当层数为7时具有最佳的分类效果。随着隐层数的进一步增加,分类效果出现了小幅下降。采用滑动窗口检测法将本文构建的弱监

表 2 不同隐层数分类器的各层神经元数目

Tab. 2 Neural number of classifiers with different hidden layers

隐层数	各层神经元数目
2	64×64, 32×32
3	64×64, 32×32, 16×16
4	64×64, 32×32, 32×32, 16×16
5	64×64, 32×32, 32×32, 16×16, 16×16
6	64×64, 32×32, 32×32, 32×32, 16×16, 16×16
7	64×64, 64×64, 32×32, 32×32, 32×32, 16×16, 16×16
8	64×64, 64×64, 32×32, 32×32, 32×32, 16×16, 16×16, 8×8
9	64×64, 64×64, 64×64, 32×32, 32×32, 32×32, 16×16, 16×16, 8×8,
10	64×64, 64×64, 64×64, 32×32, 32×32, 32×32, 16×16, 16×16, 8×8, 8×8

督分层深度学习车辆识别分类器在项目组实际采集的道路视频图片中进行车辆识别实验。实验中,对图片下 2/3 部分采用滑动窗口的搜索方法,搜索框大小为 24 像素×24 像素至 195 像素×195 像素,缩放比例为 1.1。部分车辆识别结果如图 5 所示,实线矩形框中为成功识别车辆,虚线矩形框为漏识别车辆。其中,所有图片分辨率为 640 像素×480 像素,平均每幅图片的处理时间约为 173 ms。

5 结 论

在深入研究深度学习理论及已有深度学习分类器设计方法的基础上,为更好地满足车辆识别应用,本文针对已有训练方法的不足,构建了一个以 2D-DBN 为架构的弱监督分层深度学习车辆识别算法。对比实验表明:(1)深度结构下的车辆分类器分类能力远远优于传统浅层结构分类器;(2)本文所提算法较已有无监督的深度学习算法有优势。此外,本文还以实验的方式探讨了深度神经网络隐层数和分类效果之间的关系,实验结果表明当层数为 7 时具有最佳的分类效果。




图 4 不同隐层数分类器识别效果

Fig. 4 Vehicle recognition effect of classifiers with different hidden layers



图 5 部分实际道路图片车辆识别结果

Fig. 5 Vehicle recognition results of some road images

参考文献:

- [1] Broggi A, Cardarelli E, Cattani S, et al. Vehicle detection for autonomous parking using a soft-cascade AdaBoost classifier [C]// 2014 IEEE Intelligent Vehicles Symposium Proceedings. Dearborn, USA:IEEE, 2014: 912-917.
- [2] Li Y, Li B, Tian B, et al. Vehicle detection based on the AND-OR graph for congested traffic conditions[J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(2): 984-993.
- [3] García F, de la Escalera A, Armingol J M. International technology robotics applications[M]. Oviedo, Spain:Springer International Publishing, 2014: 79-88.
- [4] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features[C]// 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai, USA: IEEE, 2001: 511-518.
- [5] 黄兵,郭继昌.基于 Gabor 小波与 LBP 直方图序列的人脸年龄估计[J].数据采集与处理,2012,27(3):1-6
Huang Bing, Guo Jichang. Age estimation of facial images based on Gabor wavelet and histogram sequence of LBP[J]. Journal of Data Acquisition and Processing, 2012,27(3):1-6
- [6] Dalal N, Triggs B. Histograms of oriented gradients for human detection[C]// 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego, USA: IEEE, 2005:886-893.
- [7] Yuan Q, Thangali A, Ablavsky V, et al. Learning a family of detectors via multiplicative kernels[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(3): 514-530.
- [8] Caraffi C, Vojir T, Trefny J, et al. A system for real-time detection and tracking of vehicles from a single car-mounted camera[C]// 2012 15th International IEEE Conference on Intelligent Transportation Systems. Anchorage, USA: IEEE, 2012: 975-982.
- [9] Gall J, Lempitsky V. Class-specific hough forests for object detection[M]. Decision Forests for Computer Vision and Medical Image Analysis. London:Springer,2013: 143-157.
- [10] Bengio Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009,2(1): 1-127.
- [11] Bengio Y, Boulanger N, Pascanu R. Advances in optimizing recurrent networks[C]//IEEE International Conference on Acoustics. Kyoto, Japan:IEEE,2012:8624-8628.
- [12] Bengio Y, Boulanger-Lewandowski N. Advances in optimizing recurrent networks[C]// 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver, USA: IEEE, 2013: 8624-8628.
- [13] Zhang C X, Zhang J S, Ji N N, et al. Learning ensemble classifiers via restricted Boltzmann machines[J]. Pattern Recognition Letters, 2014, 36: 161-170.
- [14] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [15] Hinton G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800.
- [16] Geiger A, Lenz P, Stiller C, et al. Vision meets robotics: The KITTI dataset[J]. The International Journal of Robotics Research, 2013: 32(11):1231-1237.

作者简介:



王海(1983-),男,博士,副教授,研究方向:机器视觉、机器学习及其在智能车中的应用,E-mail:wang-hai1019@163.com.



蔡英凤(1985-),女,博士,讲师,研究方向:机器视觉、机器学习及其在智能交通中的应用。



陈龙(1958-),男,博士,教授,研究方向:车辆动力学仿真和控制、智能交通技术。



江浩斌(1969-),男,博士,教授,研究方向:道路车辆智能控制技术。

