

分类号_____

密级_____

UDC _____

编号_____

中国科学院研究生院

硕士学位论文

基于图像的路面车辆检测算法研究

孔凡静

指导教师 焦建彬 教授

中国科学院研究生院

申请学位级别 硕士学位 学科专业名称 计算机应用技术

论文提交日期 2010年4月 论文答辩日期 2010年5月

培养单位 中国科学院研究生院

学位授予单位 中国科学院研究生院

答辩委员会主席 _____

独创性声明

本人郑重声明：所提交的学位论文，是本人在指导教师的指导下，独立进行研究工作所取得的研究成果。尽我所知，文中除特别标注和致谢的地方外，学位论文中不包含其他人或集体已经发表或撰写过的研究成果，也不包含为获得中国科学院研究生院或其它教育机构的学位或证书所使用过的材料。对本文的研究做出重要贡献的个人和集体，均已在文中以明确方式标明。本人完全意识到本声明的法律结果由本人承担。

签名：_____日期：_____

关于学位论文使用授权的说明

本人完全了解中国科学院研究生院有关保管、使用学位论文的规定，其中包括：①学校有权保管、并向有关部门送交学位论文的原件与复印件；②学校可以采用影印、缩印或其它复制手段复制并保存学位论文；③学校可允许学位论文被查阅或借阅；④学校可以学术交流为目的，复制赠送和交换学位论文；⑤学校可以公布学位论文的全部或部分内容。

（涉密的学位论文在解密后应遵守此规定）

签名：_____导师签名：_____日期：_____

摘要

随着车辆数目的急剧增加，交通事故给司机和行人带来了越来越多的危害。司机面临的主要威胁来自路面的其他车辆，因此越来越多的人开始注重智能交通系统，特别是车辆辅助驾驶系统的研究。通过车辆辅助驾驶系统可以提醒司机将要发生的危险，从而使其采取措施避免危险的发生。在车辆辅助驾驶系统中，车辆检测是关键的一步。

在本文中，我们采取假设产生和假设验证两个步骤来完成车辆检测的过程。

在假设产生阶段，本文采用多尺度方向（MSO）特征来对车辆进行表述，该特征将 Haar 小波特征和梯度方向直方图特征（HOG）结合了起来。并利用 Adaboost 学习算法进行特征的选择，组成一个级联分类器用于最后的检测。

在假设验证阶段，本文提出了一个新的特征集合—多尺度方向直方图（H-MSO），来用于车辆的表述和检测。通过将图像与不同尺度和方向的 Gabor 滤波器进行卷积运算，得到图像上各个像素点的多尺度方向。首先，我们将图像分成不同的小单元，分别统计每个单元内的多尺度方向的直方图。然后，对于四个相邻的单元组成的一个大的块内，将直方图的每一维的值进行归一化，并将整幅图像中所有区域的直方图连接起来，形成特征集合。最后，用这个特征集合来训练一个支持向量机（SVMs）分类器，用于路面车辆的检测。

通过两级的检测策略，不仅提高了检测的速度，而且提高了检测率，实验结果验证了本文提出的特征集合和所采用的检测方法的有效性。

关键词：车辆检测，Adaboost，级联分类器，Gabor 滤波器，SVMs

Abstract

Image-based On-Road Vehicle Detection

Kong Fan-Jing (Computer Application)

Directed by: **Jiao Jian-bin** (Professor)

Vehicle accidents have brought us increasing damages to both drivers and pedestrians. Accident statistics disclose that the main threats drivers are facing are those from other on-road vehicles. Recently, intelligent transportation systems, especially image-based driving assistance systems, which aim to alert drivers about vehicles in driving environments, are attracting more interests. In most of these systems, robust and effective vehicle detection, especially on-road vehicle detection, is a primary step.

In this paper, we follow the common vehicle detection method, which is classified into two steps: hypothesis generation and hypothesis verification.

In the stage of hypothesis generation, we use the feature set, entitled multi-scale orientation features, which combined the Haar wavelet features and histograms of oriented gradients, for vehicle representation, and employ Adaboost learning algorithm for feature selection, construct a cascade classifier for vehicle detection.

In the stage of hypothesis verification, we investigated a new feature set, called the histograms of multi-scale orientations (H-MSO), for vehicle representation and detection. The multi-scale orientations on image pixels are calculated using Gabor filters of different scale and orientation parameters. Firstly, we divide the image into cells, and calculate the histograms of multi-scale orientations in each cell by statistics. Then, the values of histogram bins are normalized in each four adjacent cells and are assembled to form the feature set. Finally, the feature set is used to train a support vector machines (SVMs) classifier for on-road vehicle detection.

Using this two-stage strategy, we have successfully improved the detection speed and detection rate. Experiments validate the proposed feature set and the detection algorithm.

Key words: Vehicle detection, Adaboost, Cascade classifier, Gabor filter, SVMs

目录

摘要.....	I
Abstract.....	II
目录.....	III
图目录.....	V
第一章 绪论.....	1
1.1 引言.....	1
1.1.1 人类视觉.....	1
1.1.2 计算机视觉.....	1
1.2 车辆检测研究的背景.....	2
1.3 车辆检测的一般方法及研究现状.....	3
1.4 本文的研究内容.....	7
1.5 本文的组织结构.....	8
第二章 假设产生过程.....	10
2.1 MSO 特征计算.....	10
2.1.1 Haar-Like 特征.....	10
2.1.2 HOG 特征.....	12
2.1.3 MSO 特征.....	13
2.2 Adaboost 分类器.....	16
2.2.1 Adaboost 学习算法.....	16
2.2.2 Cascade 级联分类器.....	19
2.2.3 级联 Adaboost 训练过程.....	20
2.3 假设产生阶段的车辆检测过程.....	21
2.4 本章小结.....	22
第三章 假设验证过程.....	23
3.1 H-MSO 特征.....	23
3.1.1 Gabor 滤波器.....	23
3.1.2 多尺度方向的计算.....	26
3.1.3 H-MSO 特征提取过程.....	27
3.2 特征提取过程中参数的选择.....	29
3.2.1 关于 Gabor 滤波器参数的选择.....	29
3.2.2 子区域的大小的选择.....	31
3.2.3 归一化方法的选择.....	32
3.3 SVMs 分类器.....	32
3.3.1 经验最小化原则.....	33
3.3.2 结构风险最小化原则.....	33
3.3.3 SVMs 的原理.....	34
3.4 假设验证阶段的车辆检测过程.....	39
3.5 本章小结.....	40

第四章 实验结果与对比分析.....	41
4.1 实验数据.....	41
4.1.1 训练数据集.....	41
4.1.2 测试数据集.....	41
4.2 检测效果和与其他方法的比较.....	43
4.2.1 检测效果.....	43
4.2.2 与其他方法的比较.....	46
4.3 本章小结.....	47
总结与展望.....	48
参考文献.....	49
发表文章目录.....	52
致谢.....	53

图目录

图 1-1 车辆检测算法框架.....	8
图 2-1 基本尺度函数和基本小波函数.....	11
图 2-2 垂直、水平、对角方向的二维 Haar 小波.....	11
图 2-3 拓展的 Haar-Like 特征	11
图 2-4 单个 MSO 特征的计算.....	14
图 2-5 矩形区域的灰度值求和.....	15
图 2-6 MSO 特征窗口的大小.....	16
图 2-7 AdaBoost 学习算法.....	18
图 2-8 级联分类器的示意图.....	19
图 2-9 训练样本在某一车辆代表特征上的分布.....	20
图 2-10 AdaBoost 训练流程图.....	21
图 2-11 车辆检测过程.....	22
图 3-1 频率带宽和方向带宽的关系图.....	25
图 3-2 5 个尺度 8 个方向上的 40 个滤波器.....	27
图 3-3 训练样本示例.....	27
图 3-4 训练样本的划分.....	28
图 3-5 滤波后的图像.....	29
图 3-6 H-MSO 特征提取过程.....	29
图 3-7 滤波器窗口大小的变化.....	31
图 3-8 真实风险界图.....	34
图 3-9 最优分类超平面.....	35
图 3-10 软间隔最优分类超平面.....	37
图 3-11 车辆检测过程.....	39
图 4-1 训练样本集.....	41
图 4-2 测试图片示例.....	42
图 4-3 假设产生阶段车辆检测结果.....	44
图 4-4 假设验证阶段车辆检测结果.....	45

图 4-5 视频中的路面车辆检测结果.....46

图 4-6 两种特征的比较.....47

第一章 绪论

1.1 引言

人们利用自己的眼、耳、鼻、嘴以及其他器官从周围的环境中获取信息，从而在纷繁的世界中生存与发展，因此，人们也希望计算机能够替代他们与周围的环境交换信息，从而导致了计算机视觉这门学科的产生与发展[1]。

1.1.1 人类视觉

感觉是人的大脑与周围世界联系的窗口，其任务是识别周围的物体，并判断这些物体之间的关系，感觉使人类的思维与周围世界建立某种对应关系。视觉是人的主要感觉来源，人类认识外界 80%的信息来自视觉。它是一种高度清晰的媒介，提供关于外部世界中各种物体和事件的丰富信息，因此视觉是思维的一种基本工具。

视觉对正常人来说是最基本的能力，但实际上视觉系统所完成的功能是十分复杂的，视觉本身就包含了思维的所有基本因素，因此，是一个复杂的感知和思维的过程。视觉器官接受外界的刺激信息，并通过大脑对这些信息复杂的机理进行处理和解释，使这些刺激信息具有明确的物理含义[2]。

1.1.2 计算机视觉

近年来，计算机越来越广泛地进入几乎所有领域。使用计算机的人群正在逐步扩大，而这些人的计算机能力是千差万别的，同时，计算机的功能越来越强大，使用方法越来越复杂。为了使更多的人能够使用功能复杂的计算机，利用计算机更加方便地完成自己想要的功能，迫切需要改变过去的思维方式，让计算机适应人的习惯和要求，以人所习惯的方式与计算机进行信息交换，让计算机具有视觉、听觉等能力。

计算机视觉就是用各种成像系统代替视觉器官作为输入手段，由计算机来代替大脑完成处理和解释[2]。计算机视觉的研究目标就是使计算机能像人那样

通过视觉认识和理解世界，具有自主适应环境的能力。人类视觉系统是迄今为止人们所知道的功能最强大和最完善的视觉系统之一，虽然人类的视觉过程和计算机视觉思维过程有一定的差异性，但是对人类视觉处理机制的研究将给计算机视觉的研究提供启发和指导。因此，用计算机信息处理的方法研究人类视觉的机理，建立人类视觉的计算理论，是一个非常重要的研究领域。

计算机视觉成为一门独立的学科，至少可以从美国麻省理工学院 Marr 教授这一代人所做的奠基工作开始，因此计算机视觉这门学科至少已有 20-30 年的历史[1]。计算机视觉是各个应用领域，如制造业、检验、文档分析、医疗诊断和军事等领域各种智能系统中不可分割的一部分。计算机视觉的挑战是要为计算机和机器人开发出具有与人类水平相当的视觉能力，它需要图像信号、纹理和颜色建模、几何处理和推理以及物体建模等方面的知识，因此计算机视觉一直是计算机学科中的一个热门学科，并吸引了许多从事心理学、神经科学、生理学、生物物理学、数学与计算机等各种学科研究人员的关注，从而把图像处理、模式识别、人工智能、数学、认知科学、机器学习、计算机图形学等各方面的研究成果融会进来[1]。

1.2 车辆检测研究的背景

车辆交通事故给司机和行人带来了越来越多的危害[3-4]。统计事故表明司机面临的主要危险来自路面的其他车辆[3]。因此，有必要开发智能交通系统（Intelligent Transportation Systems，简称 ITS）来解决这些问题，减少交通事故的发生。智能交通系统是二十世纪六十年代提出，在九十年代发展起来的，它是本世纪交通发展的方向，是新时代下科技和社会发展推动下的产物。

目前，世界各国根据本国国情制定了相应的交通发展计划，确定了本国的交通发展重心。美国将投资 6000 亿美元用于 ITS 的研究和开发利用，欧共体也将投资 1000 亿美元制定庞大的 ITS 未来五年发展计划，亚洲国家如日本、韩国、新加坡等也将大力发展 ITS 技术，我国也加入了研究和开发利用 ITS 的行列，以赶上发达国家 ITS 研究和开发水平，建立我们自己的智能交通产业[5]。

近年来，作为智能交通系统的一部分，车辆辅助驾驶系统受到了研究者的很大关注，这些系统致力于提醒驾驶者驾驶的周围环境[6]。在这样的系统中，有效的车辆检测，特别是路面车辆检测，是很重要的一个研究内容，它为智能交通系统提供了必要的数据来源。

在车辆检测中使用的传感器有两种类型：主动式和被动式。

激光测距仪、毫米波雷达、电磁感应线圈等为主动式传感器，使用主动式传感器进行车辆检测，算法实现简单，性能较好，但是仍然存在一些不足，如分辨率较低，传感器之间互有干扰，成本昂贵，以及可能带来的环境问题等[7-8]。

CCD 摄像机以及目前在军事、民事领域广泛使用的红外热象仪则属于被动式传感器。CCD 摄像机价格便宜，并且能够提供丰富的视频资料信息，通过采用计算机视觉技术对视频资料进行分析，在车辆行驶路线发生改变（如转弯）时，可以实现更有效的检测与跟踪，而且丰富的视频信息可以用来进行相关的应用，如道路检测、交通标识识别，以及行人、障碍物的检测与识别等[2]，但是最初的性能不稳定。随着计算机硬件和软件技术、图像处理技术、计算机智能技术的发展，解决了许多以往道路交通监视控制中和图像处理技术的许多难题，克服了存储量小、计算速度慢和模型泛化能力的局限性，提高了处理速度和检测精度，逐步满足了实际系统实时性、安全性、可靠性的要求。因此，被动式传感器得到了广泛的应用，基于计算机视觉的车辆检测方法也成为人们研究的重点。在本文中我们主要研究基于计算机视觉的路面车辆检测。

1.3 车辆检测的一般方法及研究现状

基于计算机视觉的车辆检测系统包括两个基本步骤：假设产生阶段和假设验证阶段。在假设产生阶段，图像中可能存在车辆的区域被假设出来；在假设验证阶段，采取一些测试措施来验证图像中的车辆区域[6]。

假设产生的方法大体分为三类：基于知识的方法，基于立体视觉的方法和基于运动信息的方法。基于知识的方法利用先验知识如对称性、颜色、阴影、角点和水平垂直边缘、纹理、车灯等来确定车辆在图像中的初始位置。该方法简

单、直观，易于编程实现，但需要估计多个经验阈值，例如车辆长宽的经验比值、车辆边缘的最小长度、车辆阴影与道路的灰度差异阈值等。经验阈值的准确与否，直接关系着系统性能的优劣[2]。基于立体视觉的方法建立在视差或频差理论上，运用两个或多个摄像机对同一景物从不同位置成像获得立体像对，通过各种算法匹配出相应像点，从而恢复深度（距离）信息，并使用这些信息利用逆投影变换[9]来估计车辆和其他障碍物在图像中的位置。但是这种方法要求对摄像机进行正确标定，这是非常困难的，因为不可避免地要受到车辆运动或天气等的影响。基于运动的方法主要利用序列图像之间存在的大量相关信息进行车辆的初始假设。主流算法有帧差法和光流法。

假设验证的方法主要有两类：基于模板的方法和基于外观的方法。基于模板的方法首先建立车辆类在不同情况下的各种模板，然后计算输入图像和模板之间的相关性，通过对相关性的分析来完成验证。基于外观的方法从大量的训练数据中学习车辆类的特性，首先，每一个训练样本都用一组局部或全局特征来表示，然后，通过训练一个分类器来学习到车辆和非车辆的决策边界，最后，利用该决策边界来对一个新输入的图像进行判断。对于训练数据，通常需要大量不同外观的车辆作为正例样本和许多不同的非车辆图像作为反例样本[6]。

特征提取方法和分类器的选择是基于外观的检测方法的核心问题。PCA (Principal Component Analysis, 简称 PCA)[10], 局部方向编码(Local Orientation Coding, 简称 LOC)[11], Haar 小波特征 [12], 梯度方向直方图特征(Histograms of Oriented Gradients, 简称 HOG)[13]都已经被用于特征表述。常用的基于统计的分类器包括神经网络 (Neural Network)[10-12], 支持向量机 (Support Vector Machines, 简称 SVMs) 和 Adaboost 分类器等[12]。

在目标检测过程中,为目标物体选择一个适当的表述方法的最终目的就是在这个表述方法可以产生较大的类间散度,同时最小化类内散度[12]。由于同一物体内部也存在一定的差异性,因此,为了对一个物体类的结构进行编码,必须在一个特定的分辨率上来识别物体的特征,在这个特定的分辨率上,物体内部具有一定的一致性,同时可以抑制噪声。在某种分辨率下无法发现的特性在另一

种分辨率下将很容易被发现，由此有人提出了多分辨率理论，而小波变化就是多分辨率特性的一种实现，因此，越来越多的研究者开始通过小波变换对图像进行分析和表述。

Haar 小波是小波的一种。通过将图像进行 Haar 小波变换，将图像由像素空间变化为小波系数空间，产生一系列不同尺度上的小波系数，从而形成一个完备的特征字典，形成对图像的描述。它使用不同尺度的小波特征对图像进行了多分辨率的描述，获取了图像不同层次上的细节特征[12]。字典中的特征集可以反映图像局部区域在几个不同方向上的灰度差。Papageorgiou 等在行人检测中使用两个尺度上的小波函数对图像进行 Haar 小波变换，并在所有的小波系数中选择能够表现类内一致性的系数作为简单的特征[14]。后来，Viola 等人又对基本的 Haar 特征进行了拓展，实现了对图像更精细的描述，该特征在人脸检测上取得了好的效果[15]。

Gabor 小波是一种被高斯函数调制的带有特殊频率和方向的正弦波。它可以在捕获图像空间频率结构的同时保留空间关系信息，因此，它适用于提取方向依赖性较强的模式信息[16]。最初，它只用于一维的信号分解。自从 20 世纪 80 年代开始，由于生物学方面发现二维 Gabor 滤波器和视觉外皮神经细胞之间的相似性，大量的研究者开始在计算机视觉应用中使用 Gabor 滤波器作为空间和卷积滤波器[6]。Gabor 滤波器可以成功地应用于不同的图像分析领域包括边缘检测[17]，图像编码[18]，纹理分析[19-21]，手写数字识别[22]，人脸识别[23-24]，车辆检测[6,25,26]和图像检索[27]。尽管 Gabor 滤波器在模式识别系统中已广泛应用，但是它的主要应用领域是特征提取。它能够同时获取空间和频率信息，优于传统信号表达只能获取空间或频率信息的一种[12,18]。在[25]中，Sun 等使用 Gabor 滤波器的幅值响应作为特征用于车辆检测。在[6]中，他们结合遗传算法 (Genetic Algorithms) 来选择适当的 Gabor 滤波器，然后利用幅值响应的矩做为特征，提高了检测性能。以上的应用都是基于 Gabor 滤波器的幅值响应，Daugman 首先使用 Gabor 相位响应来识别人体，1993 年，他基于粗略量子化的 Gabor 相位特征，提出了一种虹膜识别方法，IrisCode[28]。在[16]中，张等人使

用 Gabor 相位特征用于鲁棒的人脸识别。相对于相位特征的使用，方向特征的使用更加有限。2004 年提出的竞争性编码 (The Competitive Code)，可能是唯一的完全基于 Gabor 方向特征的计量生物学算法[29]。在[28]中，Kong 提出了 Gabor 方向响应的概念，并且比较了在人脸识别中方向响应和幅值、相位响应的性能，说明方向响应更加鲁棒。尽管现在已经有很多关于 Gabor 滤波器的研究，但是怎样将这些响应值组织成一个有效的特征集仍有待继续研究。

直方图描述子已经被广泛地用于表述、分析和识别图像，因为它计算简便有效，并且对噪声和图像局部变化具有一定的鲁棒性[30-32]。在[13]中，Naveet Dalal 提出使用梯度方向直方图描述子用于人体检测。然而，由于一定程度上的不变性，HOG 特征对于一般的目标识别不可能同样有好的效果[33]。同时，直方图描述子丢失了物体的结构信息，对于很多应用来说，这种描述是不够精确的。因此，为了在不变性和敏感性两个方面达到一个平衡，多分辨率的直方图被提出来。通过将图像与高斯滤波器[34]、Gabor 滤波器[35]等进行卷积，从而可以对图像的结构信息进行编码。张等人[16]就提出了一种简洁有效的物体描述子：Gabor 相位模式直方图 (Histogram of Gabor Phase Pattern，简称 HGPP)，用于人脸识别。

Boosting 算法是一种利用简单的方式将一些粗糙的不精确的规则组合起来产生一个非常精确的预测规则的很有效的方法，它也是提高已有学习算法精确性的一种常见方法，它通常不会引发过学习的问题。1995 年，Freund 和 Schapire 提出了 Adaboost 算法，这个算法解决了早期 Boosting 算法中存在的一些实际困难[36]。在[15]中，Viola 提出了一种基于 Adaboost 学习算法的简单有效的分类器，该分类器使用 Adaboost 算法来从大量的初始特征集中选择数目较少的有效特征来进行目标物体的分类，并采用级联机制达到了实时检测的效果。之后，很多研究者开始采用 Adaboost 级联分类器用于各种目标物体的快速检测。在[37]中，Ayoub Khammari 等人采用 Adaboost 分类器用于车辆的检测。在[38]中，Zhang 等人对 Adaboost 分类算法进行改进，提出了 RealBoost 算法，在判别力和特征选择的有效性之间达到了平衡。

SVMs 分类器是目前使用最为广泛的一种分类器，它是建立在统计学习理论基础之上的、遵循结构风险最小化原则，根据有限样本信息，在模型的复杂性和学习能力之间寻求最佳折衷，以期获得最好泛化性能的新的机器学习方法。其基本思想是在样本空间或特征空间，构造出最优平面，使得超平面与不同类样本集之间的距离最大，从而达到最大的泛化能力。SVMs 它已经被证明是一种更系统的学习线性和非线性的分类边界的方法[39-41]，并且它们在目标检测[6,10,18]、性别分类[42-43]等应用中已表现出很好的性能。

虽然车辆检测的研究已经有四十多年，车辆检测依然是一个具有挑战性的任务。在路面环境下，关于车辆的信息是通过移动的摄像机获得，这些车辆可能在局部形状、颜色、视角上有很大的差异，并且可能会受到局部遮挡和光照的影响，这些因素都对现有的基于计算机视觉的车辆检测方法造成了威胁。因此，我们需要研究更有效的特征和检测方法来完成路面车辆的检测。

1.4 本文的研究内容

遵循车辆检测的一般方法，本文也采用假设产生和假设验证两个步骤来进行车辆检测。

在假设产生阶段，需要一种快速且有效的方法定位出车辆的候选区域，因此，在此阶段，我们需要采用计算相对简便的特征和较快的分类器。通过对 Haar-Like 特征进行改进，结合图像的梯度特征，我们采用多尺度方向特征[44] (Multi-Scale Orientations, 简称 MSO) 来对车辆进行表述，并利用 Adaboost 级联分类器进行车辆候选区域的检测。

在假设验证阶段，需要更有效，表述更精确的特征和更准确有效的分类器进行车辆区域的最后判别。通过对目前国内外所使用特征的分析，我们提出了一个新的特征集，多尺度方向直方图 (Histograms of Multi-Scale Orientations, 简称 H-MSO)，来用于车辆的表述，并采用 SVMs 分类器来进行分类判别。多尺度方向特征通过将图像与不同尺度和方向的 Gabor 滤波器卷积得到，这个特征集合将空间直方图和多尺度方向结合了起来。它是从 HOG 特征演化而来[13]，我

们用 Gabor 方向响应代替了梯度方向，从而获得了多尺度的方向，这使得我们的算法在路面车辆检测中更加鲁棒。

本文的检测算法的框架如图 1-1 所示。首先，所有的正例和反例的训练样本都用 MSO 特征集来描述，并对所有的样本经过 Adaboost 分类器进行训练，形成初始的分类模型，来完成车辆假设的产生过程。然后，所有的正例和反例的训练样本都用 H-MSO 特征集来描述，并对所有的样本用 SVMs 分类器进行训练，形成最后的分类模型。在车辆检测过程中，逐行逐列地扫描固定大小的图像块，然后将图像块依次用 Adaboost 分类器和 SVMs 分类器进行判别，来最终完成图像中车辆区域的检测。

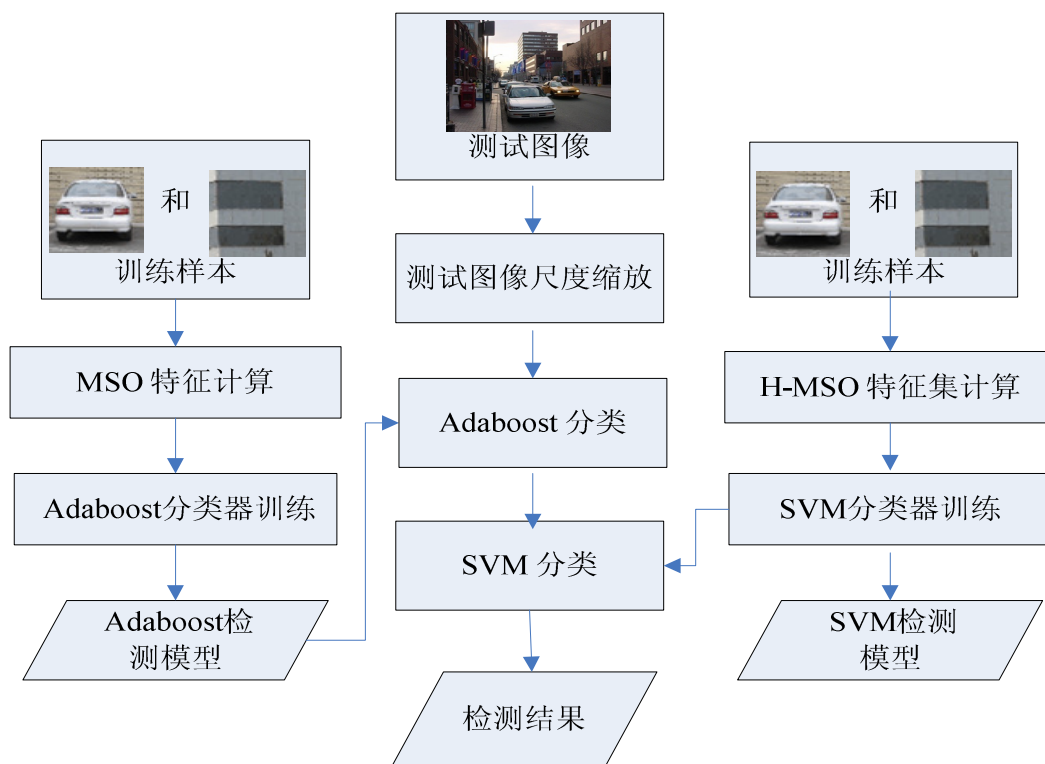


图 1-1 车辆检测算法框架

1.5 本文的组织结构

第一章，绪论。主要论述了路面车辆检测算法的研究背景和意义，分析了国内外的研究现状以及基于计算机视觉的路面车辆检测算法中存在的难题，列

出了本文的主要研究目的和研究内容，总结了本文的主要贡献。

第二章，车辆检测的假设产生过程。在该过程中采用 MSO 特征对车辆进行表述，并用 Adaboost 学习算法对特征进行选择，构成一个级联分类器用于车辆区域的判断，从而完成车辆区域的初始假设，并且满足了该阶段检测速度快的要求。

第三章，车辆检测的假设验证过程。主要论述了本文所提出的一种新的特征集：多尺度方向特征直方图（H-MSO），来对车辆进行表述，并采用 SVM 分类器进行分类判别，从而完成假设验证过程。对检测过程中的各个参数进行了优化，使得本文提出的算法达到了更好的性能。

第四章，实验结果对比与分析。主要论述了实验过程中所使用的训练数据和测试数据。将本文提出的方法与其他方法做了比较，并列举分析了一些实验结果。

最后是对现有工作的总结和对未来工作的展望，以及对如何进一步提高车辆检测算法的鲁棒性、准确性和实时性等研究难点的探讨。

第二章 假设产生过程

在假设产生阶段，我们需要以尽可能快的速度检测到可能存在车辆的区域，并且过滤掉大部分的非车辆区域。因此在假设产生阶段，我们采用多尺度方向特征（MSO）来对图像块进行描述，该特征结合了 Haar 小波特征和 HOG 特征的优缺点。利用 Adaboost 学习算法对特征进行选择 and 评估，将所选出来的特征构成级联分类器来进行车辆区域判别，完成车辆假设的产生过程。

2.1 MSO 特征计算

MSO 特征是在结合 Haar-Like 特征和 HOG 特征的基础上，为了完成快速检测的目标而形成的一种简单的特征。它即继承了 Haar-Like 特征计算简单的优点，又一定程度上反映了区域块的梯度方向，可以更好地检测边缘信息[44]。

2.1.1 Haar-Like 特征

小波提供了一种描述模式的自然、精确的结构，它可以描述物体的多分辨率特性。例如一系列逼近子空间 $V^0 \subset V^1 \subset V^2 \subset \dots \subset V^j \subset V^{j+1} \dots$ ，其中向量空间 V^{j+1} 可以比 V^j 描述更多的精细一层的细节，但是 V^j 的每一个元素也同样是 V^{j+1} 的元素。多分辨率的分析同时要求 V^j 空间中的一个函数可以用其在该向量空间的正交投影来近似估计[12]。

我们使用尺度函数作为向量空间 V^j 的基，如公式（2.1）所示：

$$\phi_i^j = \sqrt{2^j} \phi(2^j x - i), i = 0, \dots, 2^j - 1 \quad (2.1)$$

对于 Haar 小波来说，尺度函数为：

$$\phi(x) = \begin{cases} 1 & 0 < x < 1 \\ 0 & \text{其他} \end{cases} \quad (2.2)$$

下面定义向量空间 W^j 是两个连续的逼近子空间的正交补集， $V^{j+1} = V^j \oplus W^j$ 。 W^j 就是通常所说的小波空间，可以将它理解为子空间的细节描述。小波空间 W^j 的基函数如公式（2.3）定义：

$$\psi_i^j = \sqrt{2^j} \psi(2^j x - i), i = 0, \dots, 2^j \quad (2.3)$$

对于 Haar 小波来说，小波基函数为：

$$\psi(x) = \begin{cases} 1 & 0 \leq x \leq \frac{1}{2} \\ -1 & \frac{1}{2} \leq x \leq 1 \\ 0 & \text{其他} \end{cases} \quad (2.4)$$

所有的尺度函数都可以通过一个基本尺度函数的缩放和平移得到，同样，所有的小波函数也可以通过一个基本小波函数的缩放和平移得到。Haar 小波的基本尺度函数和基本小波函数如图 2-1 所示：




图 2-1 基本尺度函数和基本小波函数

垂直、水平和对角方向的三种非标准的二维 Haar 小波如图 2-2 所示：




图 2-2 垂直、水平、对角方向的二维 Haar 小波

Papageorgiou 等人用图 2-2 中的三种 Haar 小波作为特征进行行人的检测，特征值等于白色矩形框中所有像素的灰度值和减去灰色矩形框中的所有像素的灰度值[12,14]。(a)、(b) 为两个矩形的 Haar 特征，(c) 为四个矩形的 Haar 特征。

后来，Viola 等人又对上面基本的 Haar 特征进行了拓展，引入了旋转的 Haar 特征，便有了现在的“拓展的 Haar-Like 特征”，见图 2-3[44]：




图 2-3 拓展的 Haar-Like 特征

对于以上几种形式的 Haar-Like 特征，通过在图像中位置和大小变化，可以形成很多个 Haar-Like 特征，从而组成一个完备的特征集，形成对图像的完备描述。

Haar-Like 特征的计算只是块内像素灰度的加减运算，Viola 在其论文中引入了积分图的概念[15]，从而大大加快了特征值的计算速度，因此，计算简便便是 Haar-Like 特征的一个显著优点，但是它反映的仅仅是块内的灰度差，对于图像特征的描述还不够精细，处于比较原始的阶段。

2.1.2 HOG 特征

1999 年，在[45]中，Lowe 提出了一种新的局部图像特征用于物体识别，叫做尺度不变特征变换（Scale Invariant Feature Transform，简称 SIFT），该特征对于图像尺度、变换和旋转，特别是对于光照的变化和仿射变换、三维投影等都具有不变性。在文中，他将图像变换成大量局部特征向量的集合，其中每一个向量都具有图像变换、尺度、旋转等不变性。2004 年，Lowe 进一步阐述了尺度不变特征的概念[46]，并且指出该特征具有很好的区分能力。该方法首先将图像与一系列不同的高斯函数卷积，然后相邻的滤波图像相减，得到高斯差分图像，若一个像素点与其分布在三个连续的高斯差分图像上的 26 个邻域点相比是最小值或最大值，则称其为局部极值点，从而成为关键点（Key Points）。之后需要对这些关键点进行描述。首先计算该关键点周围一个区域内所有像素点的梯度幅值和方向。区域每个点以高斯窗口进行权重的赋值。然后将区域分成四个子块，计算每个块内所有像素点的梯度方向直方图，从而形成对关键点的描述。

2005 年，Dalal 和 Triggs 提出了 HOG 特征用于人体检测，该特征提出的思想是基于一个基本观点：物体的局部外观和形状能够用局部像素的梯度值的分布或边缘信息来描述，即使不知道对应的梯度值或边缘位置的精确信息。HOG 特征是在边缘方向直方图、SIFT 描述子和形状纹理等的基础上提出的，不同之处在于它是在一个均匀分布的单元内进行计算的，并且为了提高性能，又将这些单元组成一些相互重叠的块[13]。HOG 特征有很多先驱和前导，但是直到 Lowe 等人在 SIFT 中引入了局部空间的直方图化和归一化，才使得该方法达到成熟，而 HOG 对于 SIFT 的进一步改进在于 HOG 特征引入了相互重叠的块（block），从而使特征描述更加鲁棒。

HOG 特征的提取过程为：首先将训练样本按照 8×8 个像素的单元 (cell) 进行划分。然后再将每相邻的 4 个 cell (田字形结构的 4 个 cell) 划分为 1 组 (block), block 的形成是按照每个 cell 进行滑动生成的。首先, 对于每个 cell 都按照 SIFT 的方法, 将其中的所有像素的梯度方向进行投影, 形成每个 cell 各自的梯度方向直方图。方向 bins 的数量被设定为 9, 即每 20 度一个 bin, 0-180 与 180-360 的方向采用对等角相等的方法进行归类划分。然后, 再将每个 block 中的 4 个 cell 的梯度直方图连接起来, 形成一个 36 维的向量。为了克服光照等的影响, 对于每一个 block 内的 36 维的向量进行归一化, 再将所有 block 的直方图向量依次连接起来, 形成了每个训练样本的 HOG 特征向量。

2007 年, Cong Hou 等人在 HOG 的基础上提出了其推广的特征: 扩展的 HOG (Extended Histograms of Oriented Gradients Features, 简称 EHOG), 并采用了树形结构的检测器作为向量提升算法对多视角的行人进行学习[47]。其中 EHOG 是在梯度方向中对方向角量化, 将梯度方向映射到几个主要的方向区间内, 从中选取 3 个主要的区间 (bin) 并对其进行归一化; 将两个 Block 作为一个 Block 对, 在区域上进行加或减运算, 从而形成一个新的不规则的特征区间 (形状)。Haga 采用了积分梯度直方图 (Integral HOG) 的方法[48], 并结合树形检测结构可以达到快速的检测速度, 取得了较好的多视角人体检测效果。

2.1.3 MSO 特征

在目标检测中, 对物体描述的好坏直接影响其最终的检测性能。Viola 的 Haar-Like 特征和 Dalal 提出的 HOG 作为物体的特征描述子, 都在人体检测上取得了很好的效果。Haar-Like 是基于灰度图像的一种特征描述方法, 相当于对一幅灰度图像在尺度、位置变化的基础上, 对其区域内部的像素灰度差值的概率统计[44]。而 HOG 描述的是 R、G、B 任意颜色通道上的最大梯度方向, 它反映的是物体的轮廓方向在某一区域内的一种概率统计[13]。然而, 这两种方法都存在着各自的不足, 前者对于光照变化很敏感, 后者由于是一种区域内的方向投票, 因此容易受到纹理的影响, 而且运算速度慢也是一个待于解决的问题。在[44]中, 作者将 Haar 特征与 HOG 特征结合起来, 提出了多尺度方向特征, 在描述区域梯度特征的同时, 降低了计算量。

MSO 特征以图像的灰度值作为基础, 通过对不同尺度的特征区域内像素的

灰度值进行累加换算，转换成相应的方向特征。由全部特征组合起来所形成的特征集反映的是图像在不同尺度上的方向特征[44]。

在固定尺度上的单个特征的计算如图 2-4 所示，其中每个特征区域都是一个 $m*m$ 的正方形，对于这个正方形特征的特征值的计算，可以分为两步：

- 1、计算正方形区域的毛梯度方向（因为是在大尺度上求解梯度，相对于原始定义的梯度来说更加粗糙，因此称其为毛梯度）。
- 2、将计算出来的毛梯度方向映射成固定的特征值编码[44]。

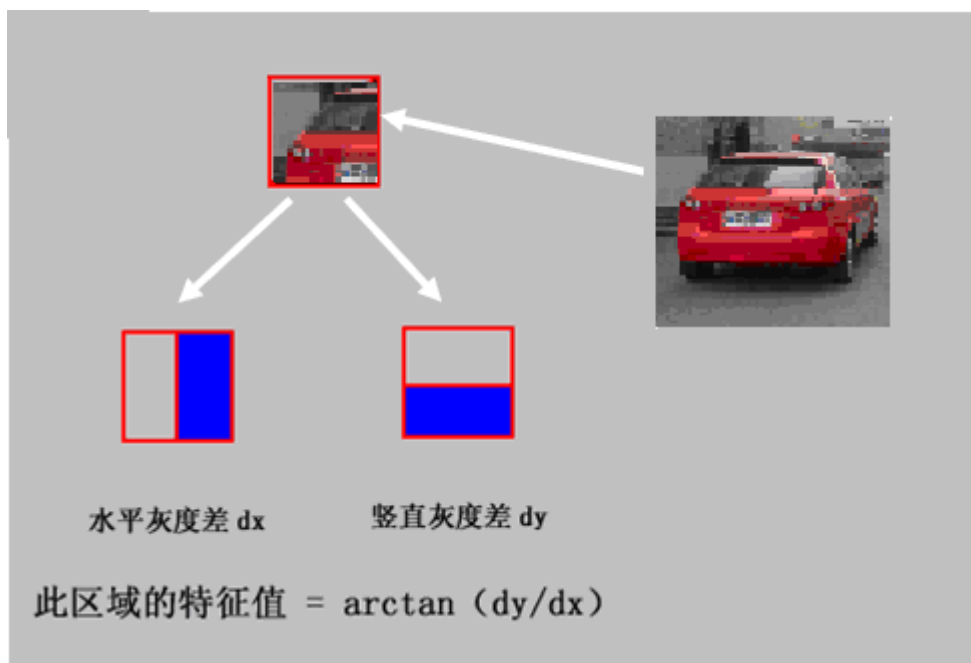


图 2-4 单个 MSO 特征的计算

首先，将正方形分为左右两个等份，计算左右两个小区域的所有像素的灰度值之和，分别记为 SUM_L 和 SUM_R ，得出水平灰度差 dx ，再将正方形分为上下两等份，计算上下两个小区域的所有像素的灰度值之和，分别记为 SUM_U 和 SUM_D ，得出竖直灰度差 dy [44]，如公式 (2.5) 所示：

$$\begin{aligned} dx &= SUM_R - SUM_L \\ dy &= SUM_D - SUM_U \end{aligned} \tag{2.5}$$

其中， SUM_R 、 SUM_L 、 SUM_D 和 SUM_U 分别表示为正方形特征区域的右半部、左半部、下半部和上半部的灰度值累加和。




图 2-5 矩形区域的灰度值求和

如图 2-5 所示，区域 A 的灰度值累加和 SUM_A 的计算公式为：

$$SUM_A = \sum_{x1 < x < x2, y1 < y < y2} PixelValue(x, y) \quad (2.6)$$

其中， $PixelValue(x, y)$ 表示坐标为 (x, y) 像素点的灰度值。按公式 (2.6) 中的方法，可以分别求出 SUM_L 、 SUM_R 、 SUM_U 和 SUM_D ，将其带入公式 (2.5)，便可以求出正方形特征的水平灰度差 dx 和竖直灰度差 dy 。

然后，先将 0~360 度等分为 18 个区间，对顶角区域属于同一区间。这样本文就可以根据所求出来的 dx 和 dy 计算出这个矩形区域的毛梯度方向 Ori_Rect ，如公式 (2.7) 所示：

$$Ori_Rect = F(\arctan(dy / dx)) \quad (2.7)$$

其中， F 为将角度转换为数值 0, 1, 2, ..., 8 的函数，如：当 $\arctan(dy / dx)$ 的值在 1~20° 之间时， Ori_Rect 的值为 0；当 $\arctan(dy / dx)$ 的值在 21~40° 之间时， Ori_Rect 的值为 1；依此类推。

MSO 特征吸取了 Viola 的 Haar-Like 特征可变尺度的特性，打破了 HOG 单一尺度特征上的束缚。在[44]中，作者将正方形特征区域的尺度规定为 6*6, 8*8,, 20*20 的大小，如图 2-6：




图 2-6 MSO 特征窗口的大小

与 Haar-Like 特征集合类似，对于某个特定尺度上的 MSO 特征来说，在图像上按照一定的水平和垂直步长由上到下由左到右顺序平移特征窗口，从而产生当前尺度上的所有特征。例如：当特征尺度为 6*6 时，在大小为 64*64 的训练样本上，可以得到 $((64-6)/2+1)*((64-6)/2+1)=900$ 个特征。当所有尺度上的特征都计算完后，将这些特征依次排列，便形成一个包含 5660 个特征的完备的特征集合。

2.2 Adaboost 分类器

由于 MSO 特征集中包含的特征数很多，即使假设每一个特征值都可以被快速地计算出来，要处理完整个完备集的特征还是要花费很多的时间的[44]。而且每个特征对分类的贡献大小是不一样的，甚至有些特征是无用的，如何对这些特征进行选择并组织成一个有效的特征集来进行车辆的判断成为要解决的主要问题，因此，我们利用 Adaboost 分类器来完成此阶段的特征的选择及车辆区域的判别。

2.2.1 Adaboost 学习算法

AdaBoost 是 adaptive boosting 算法的一种变形。其目的是根据已有的样本，融合多个弱分类器形成一个整体的强分类器，并提高分类准确率[49]。AdaBoost 具体解决两个问题：怎样处理训练样本和怎样合并弱分类器成为一个强分类器。AdaBoost 算法的一个主要思想就是令样本集中所有样本的权重形成一个分布。在第 t 次迭代中第 i 个训练样本的权重表示为 $D_t(i)$ 。初始时每个训练样本的权重都是一样的，在每轮迭代过程中，如果样本没有被正确分类，它的权重就会被提高，反之则降低。这样，AdaBoost 将更多的注意力放在难分的样本上。对于弱

分类器的组织形式，强分类器表示为若干弱分类器的线性加权和形式，准确率越高的弱分类器权重越高。

弱学习器的任务就是找到一个对应于分布 D_t 的弱假设 $h_t : X \rightarrow \{-1, +1\}$ 。它的好坏是用它的错误率来衡量的： $\varepsilon_t = \Pr_{i \sim D(t)} [h_t(x_i) \neq y_i] = \sum_{i: h_t(x_i) \neq y_i} D_t(i)$ [49]。

AdaBoost 算法的学习法则如下所示[49]:

- 输入 m 个样本图片 $(x_1, y_1), \dots, (x_m, y_m)$,

其中, $x_i \in X, y_i \in Y = \{+1, -1\}$

- 初始化样本权重 $D_1(i) = 1/m$.

- For $t = 1, \dots, T$:

1. 找到弱分类器 h_t , 并得到其分类误差

$$\varepsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i)$$

2. 计算分类器权重 $\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right)$

3. 更新样本权重.

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} e^{-\alpha_t} & \text{如果 } h_t(x_i) = y_i \\ e^{\alpha_t} & \text{如果 } h_t(x_i) \neq y_i \end{cases}$$

$$= \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t}$$

其中 Z_t 是归一化因子, 使得 $D_{t+1}(i)$ 成为一个分布.

- 最终的强分类器为:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right)$$

从以上算法中可以看出, 一旦选择了一个弱分类器之后, AdaBoost 选择一个参数 α_t , 做为弱分类器的权重。注意到, 当 $\varepsilon_t \leq \frac{1}{2}$ 时, $\alpha_t \geq 0$, 并且随着 ε_t 的减小, α_t 逐渐增大, 也就是说, 分类错误率越低的弱分类器, 它的权重越大。最终的假设 H 是 T 个弱假设的组合, 每个弱假设 h_t 对应一个权重 α_t [49]。

在本文中, 我们采用 AdaBoost 学习算法来对特征进行选择, 达到用少量的特征组成一个有效的分类器的目的。每一个弱学习算法都用来选择一个能最好地将正例和反例分开的矩形特征, 同时为每一个矩形特征确定一个最优的阈值, 以使错分的样本个数最少[50]。对于一个弱分类器函数 $h_j(x)$, 有一个特征 f_j , 一

个阈值 θ_j ，还有一个用来指示不等式方向的符号函数 p_j ，如公式 (2.8) 所示：

$$h_j(x) = \begin{cases} 1 & \text{if } (p_j f_j(x) < p_j \theta_j) \\ 0 & \text{otherwise} \end{cases} \quad (2.8)$$

这里的 x 是一幅图像中的一个 $64 * 64$ 像素大小的子窗口。

关于 AdaBoost 过程见图 2-7[15]：

- 给定一组样本图片 $(x_1, y_1), \dots, (x_n, y_n)$,
其中, $y_i = -1, 1$ 分别表示为反例样本和正例样本.
- 分别将 $y_i = -1$ 和 1 的样本的权重初始化为 $\omega_{1,i} = \frac{1}{2m}, \frac{1}{2l}$,
这里的 m 和 l 分别为反例样本和正例样本的数量.
- For $t = 1, \dots, T$:
 1. 归一化权重,

$$\omega_{t,i} \leftarrow \frac{\omega_{t,i}}{\sum_{j=1}^n \omega_{t,j}}$$
 由此, ω_t 服从概率分布.
 2. 对于每一个特征 j ,
 训练一个分类器 h_j 都要严格的遵守使用一个特征的原则.
 其误差可以通过按照下面的公式估算出来

$$\epsilon_j = \sum_i \omega_i |h_j(x_i) - y_i|$$
 3. 选择分类器中误差 ϵ_t 最小的.
 4. 更新权重:

$$\omega_{t+1,i} = \omega_{t,i} \beta_t^{1-e_i}$$
 其中, 如果分类正确则 $e_i = 0$;
 否则, $e_i = 1$, 并且 $\beta_t = \frac{\epsilon_t}{1-\epsilon_t}$.
- 最终的强分类器为:

$$h(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases}$$
 其中 $\alpha_t = \log \frac{1}{\beta_t}$.

图 2-7 AdaBoost 学习算法

每一次的 boosting 循环都将会从多个备选特征中选出一个特征。实际上，没

有一个单一的特征能够完成低错误率的分类任务。在 boosting 过程的前期提取出来的特征的错误率是在 0.1 到 0.3 之间，而在之后的循环中所提取出来的特征，因为任务更加困难，所以错误率处于 0.4 到 0.5 之间[50]。

2.2.2 Cascade 级联分类器

在[15]中，Viola 提出了级联分类器的概念。通过分类器级联的形式，不仅可以提高检测的性能，还可以降低检测所需要花费的时间。主要思想是基于一种重要的现象：越简单、越小的提升（boosted），分类器可以达到更好的效果，它可以在检测几乎所有的正确实例的同时排除掉大量的无关子窗口。简单的分类器通常被用来排除大量的子窗口，在这之后再利用更加复杂的分类器来实现降低误检率的目标[15]。

级联分类器的每一级都是由 AdaBoost 选择训练出的一些弱分类器组成。级联分类器的第一级可以调节阈值到一个很低的水平，来达到提高检测率的目的，但是这种情况下误检率将会很高，因此在之后的几级分类器会逐渐过滤掉错误的实例。经过几级的处理，子窗口的数量将会明显的减少[15]。

从整体的结构来看，整个检测过程实质上就是一棵退化了的决策树，因此称之为级联（见图 2-8）。

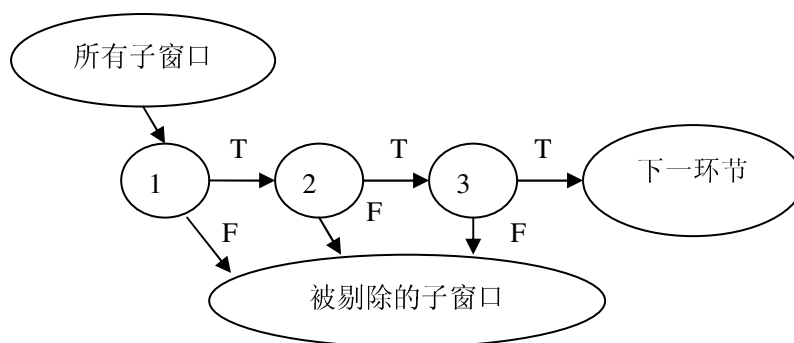


图 2-8 级联分类器的示意图

从第一级分类器中判断为正例的子窗口触发第二级分类器对其进行评估，并且此级分类器同样可以实现很高的检测率。而被第二级分类器判断为正例的子窗口又会触发第三级分类器，以此类推。相反，从任何一个结点输出的被否定了的结果都会导致对这个子窗口的检测立即停止[15]。

一般而言,一个弱分类器较低的阈值可以导致一个较高的检测率和一个较高的误检率[15]。由于该阶段车辆检测的目的是尽可能的在早些时候可以将大部分无用的子窗口排除掉。因此在此情况下级联的 AdaBoost 算法非常适用。

2.2.3 级联 Adaboost 训练过程

在 Adaboost 训练过程中主要完成两个任务,一是特征及其权重的选择,二是特征阈值的确定。弱分类器的选择算法如下:对于每一个特征,基于特征值可以将训练样本分类。然后 AdaBoost 通过为该特征选择一个最优的阈值,从而使得正例和反例样本能够利用该阈值被正确地分开。

由于特征值的离散性,本文没有采取 Viola 的 AdaBoost 中弱分类器的构造方法,而是根据[44],采用了一种特征区间的划分方法。这种方法的依据是:对于任何事物的特征描述,会产生大量的特征,然而并不是特征集中的所有特征对目标的判别都是有用的,本文所要求的是找出能够凸显车辆与非车辆区别的那些特征。当训练样本集非常巨大时,对于车辆的代表特征来说,出现在某一特定区域的密度会大一些,而这类特征在大量的反例(非车辆)样本上反映的则是近似符合均匀分布,见图 2-9。基于这个思想,在每次 Adaboost 的过程中选择满足该特性的特征,同时确定该特征的阈值。

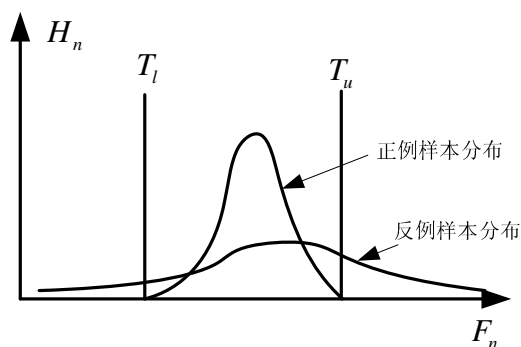


图 2-9 训练样本在某一车辆代表特征上的分布

对于某个特征 i 而言,纵坐标 H_n 表示所有训练样本在该特征的某一特征值上所占的比重;横坐标 F_n 表示将特征区域的特征值; T_l 和 T_u 分别记录特征选择时的左右阈值;正例样本和反例样本的分布情况如图 2-9 中所示。在训练过程中,如果一个特征满足所有正例样本集中分布在某一区域,则选择该特征,同时,对所有样本该特征的值进行统计,选择合适的阈值 T_l 和 T_u ,使得正例样本的特征值

尽可能多的分布在 T_l 和 T_u 之间[44]。

基于级联 AdaBoost 算法的训练流程见图 2-10[44]:

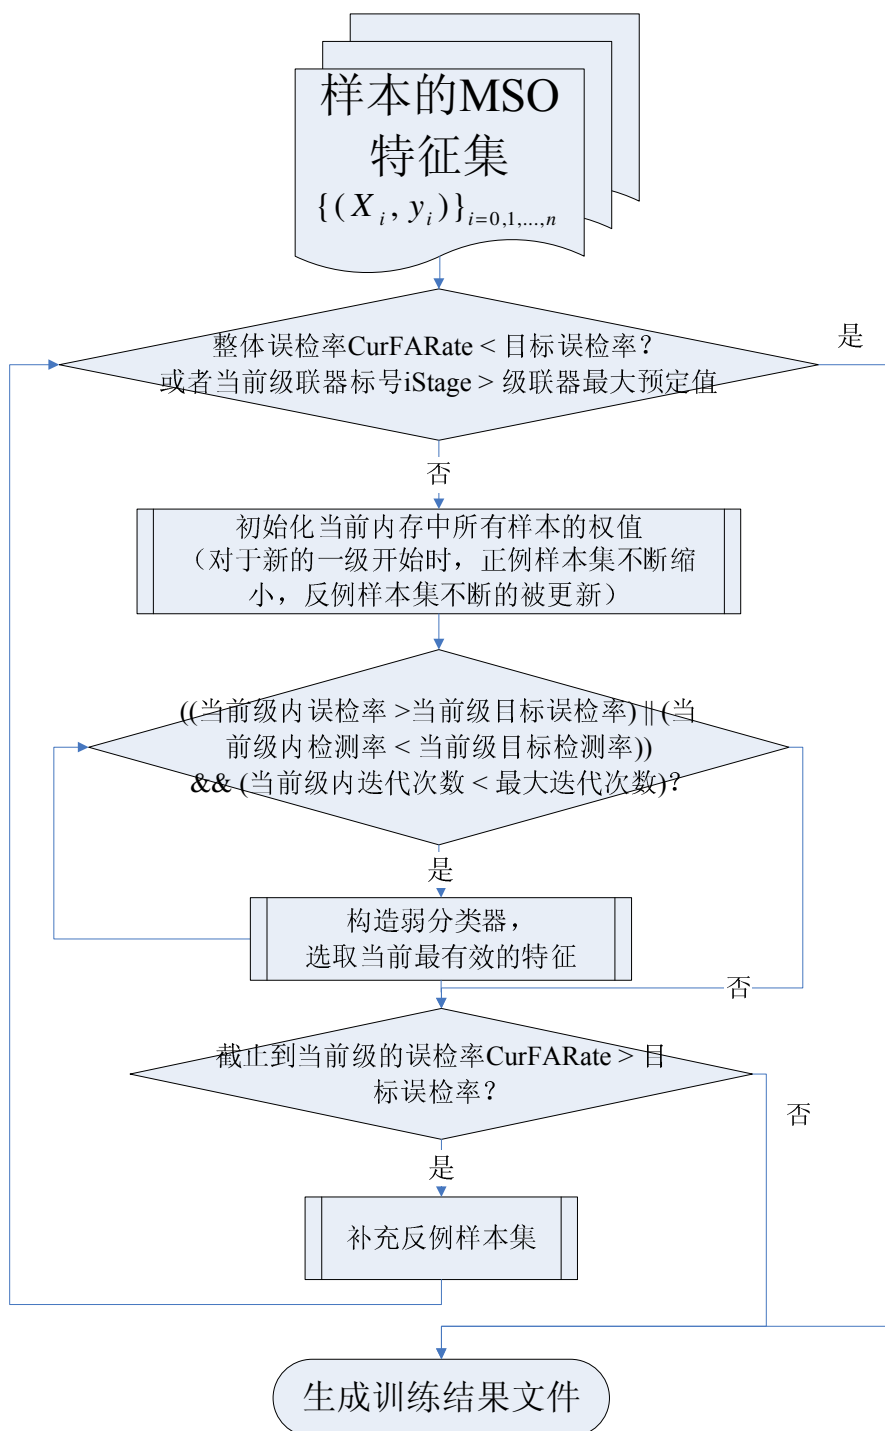


图 2-10 AdaBoost 训练流程图

2.3 假设产生阶段的车辆检测过程

对于输入的检测图像，我们逐像素地扫描整幅图像，利用已训练完成的

Adaboost 级联分类模型来判断每一个子图像块中是否存在车辆。为了检测不同大小的车辆，在对图像进行扫描前，还需对其进行不同尺度的缩放。检测过程如图 2-11 所示：

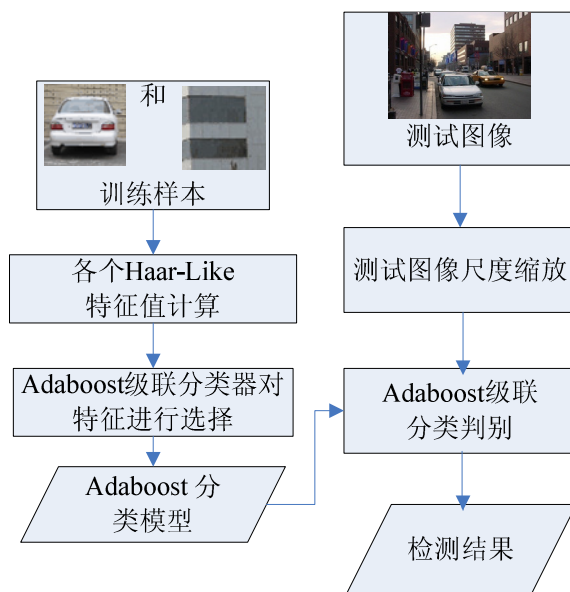


图 2-11 车辆检测过程

为了在提高检测速度的同时，尽量少的过滤掉正例子窗口，经过反复实验，发现将级联分类器的级数设为 6 是比较合适的，这样既可以加快检测速度，同时又保证所有的正确的子窗口都能被检测到，从而顺利进入到假设验证阶段。

2.4 本章小结

本章主要阐述了假设产生阶段的车辆检测过程。在本阶段需要尽量检测到所有的车辆区域，并且过滤掉大部分的非车辆区域，因此，本文采用 MSO 特征来对车辆进行描述，利用 Adaboost 学习算法对特征进行选择，最后形成级联分类器进行车辆区域的判别。

第三章 假设验证过程

在假设验证阶段,需要对前一阶段检测出来的车辆候选区域进行验证,最终确定该区域是否是车辆区域,我们需要更精确的特征描述和更准确的分类。因此,在假设验证阶段,我们采用一种新的 H-MSO 特征来对车辆进行描述,并利用 SVMs 分类器进行分类。

3.1 H-MSO 特征

Gabor 小波特征对垂直和水平边缘线比较敏感,而车辆的后部轮廓线可以概括为矩形框,因而利用 Gabor 滤波器对矩形特征的提取,可以把车辆从背景中提取出来。在假设验证阶段,我们通过将图像与不同尺度和方向的 Gabor 滤波器进行卷积计算得到各个像素点的多尺度方向,然后再统计局部区域的直方图,从而形成 H-MSO 特征集。使用 H-MSO 特征来对车辆进行描述,可以精确地描述不同尺度上的边缘轮廓信息。

3.1.1 Gabor 滤波器

Gabor 函数最早是由 Gabor 于 1946 年提出的,随着研究的深入,尤其是在研究人类视觉系统工作机理的过程中,Gabor 函数受到越来越多的研究者的关注[2]。研究发现,视觉神经细胞成对分布,工作时调谐到同一方向,但相位相差 90 度。Gabor 函数的特性可以较好地抽象视觉神经细胞的工作机理。Gabor 函数是唯一能够达到时频测不准关系下界的函数,它能够最好地兼顾信号在时域和频域中的分辨能力,而且它所提取的图像特征受光照影响比较小,对于一些形变也不敏感。基于此,Gabor 函数在图像纹理分析方面有着广泛的应用[19-21]。

用 Gabor 函数形成的二维 Gabor 滤波器有着优良的滤波器性能,并有着与生物视觉系统相近的特点。它具有易于调谐的方向和径向频率带宽以及易调谐的中心频率,在空间域和空间频率域同时达到了最佳分辨率[2]。

生物物理实验证明,人类视觉皮层中细胞对不同方向和频率的正弦波栅栏具有很窄范围的频率、方向的响应,也就是每一个滤波后图像刻画了视网膜图像在一个窄的频带和方向范围内的成分。在哺乳类动物的视觉皮层中呈现着一种机理,它把频率和方向结合在一起,调谐到一个很窄的区域,这种机理常称为通道

[22], 其实质等价于“带通滤波器”。多通道滤波器就是受视觉系统工作机理的启发而提出的, 车辆特征提取主要用的也就是二维 Gabor 滤波器构成的滤波器组。

Gabor 函数可以表示成一个被复合正弦信号调制的高斯函数[6]。一个二维的 Gabor 函数 $g(x, y)$ 可以为:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x'^2}{\sigma_x^2} + \frac{y'^2}{\sigma_y^2}\right)\right] \exp[-2\pi i(u_0x' + v_0y')] \quad (3.1)$$

其中

$$\begin{aligned} x' &= (x - x_0)\cos\alpha + (y - y_0)\sin\alpha \\ y' &= -(x - x_0)\sin\alpha + (y - y_0)\cos\alpha \end{aligned}$$

在二维 Gabor 滤波函数中共有 7 个自由度变量, (x_0, y_0) 是滤波器在空间的中心, σ_x 和 σ_y 决定了高斯函数的形状, α 是高斯函数的方向, $\omega_0 = \sqrt{u_0^2 + v_0^2}$ 是径向中心频率, $\theta = \tan^{-1}(v_0/u_0)$ 是正弦波和高斯函数的夹角, α 和 θ 共同决定了 Gabor 滤波器的方向[28]。令 $\lambda = \frac{\sigma_y}{\sigma_x}$, 则 λ 为高斯核的长宽比, 当 $\lambda = 1$ 时, 高斯核函数具有圆对称的不变形式[2]。

Gabor 函数的空间频率响应为[2]:

$$G(u, v) = \exp\left\{-2\pi\left[\frac{(u - u_0)^2}{\sigma_x^2} + \frac{(v - v_0)^2}{\sigma_y^2}\right]\right\} \quad (3.2)$$

由公式 (3.2) 可知, $G(u, v)$ 是一带通高斯函数。

通常用空间频率带宽和方向带宽来描述 Gabor 滤波器。Gabor 滤波器的频率带宽 B (单位: 倍频程) 和方向带宽 Ω (单位: 弧度) 均以半峰值的范围划定, 如图 3-1 所示。

对带宽定义为:

$$B = \log_2 \left[\frac{(n\omega_0\sigma_x + \alpha)}{(\pi\omega_0\sigma_x - \alpha)} \right] \quad (3.3)$$

$$\Omega = 2 \tan^{-1} \left(\frac{\alpha}{\pi\omega_0\sigma_y} \right) \quad (3.4)$$

其中, $\alpha = \sqrt{(\ln 2)/2}$ 。只要改变 B , Ω , ω_0 和 θ , 就可以产生任意中心频率、带宽和方向特性的 Gabor 滤波器, 覆盖频域内具有椭圆形状的任何区域, 这给不同纹理图像特征的提取带来了极大的方便[2]。




图 3-1 频率带宽和方向带宽的关系图

对于公式 (3.1), 在本论文中, 我们设定 $v_0 = 0$, 从而得到正弦波和高斯函数之间的夹角 θ 为 0° 。因此, 新的 Gabor 函数变为:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right] \exp(-2\pi i u_0 x') \quad (3.5)$$

在此函数中, 滤波器的中心频率 $\omega_0 = u_0$ 。

随着参数的变化, 我们可以得到不同的 Gabor 滤波器。在本文的研究中, 我们令 $x_0 = 0$, $y_0 = 0$, 也就是说滤波器在空间域的中心为 $(0,0)$, 这种情况是最常见的一种, 具有一般性。这样, 在新的 Gabor 滤波器中, 我们共有四个参数变量: σ_x , σ_y , u_0 和 α 。 σ_x 和 σ_y 决定了高斯函数的形状, u_0 描述了空间的频率, 也就是尺度, α 描述了高斯函数的方向。通过四个参数的变化, 可以导致 B , Ω , ω_0 等的变化, 从而可以产生任意中心频率、带宽和方向特性的 Gabor 滤波器。为了控制参数 u_0 和 α 的变化以便于后边对参数的选择, 我们定义:

$$u_0 = f_{\max} / k^{(u-1)} \quad (3.6)$$

$$\alpha = (v-1) \left(\frac{\pi}{v_{\max}} \right) \quad (3.7)$$

其中 $u = 1, 2, \dots, u_{\max}$, $v = 1, 2, \dots, v_{\max}$ 。 u_{\max} 和 v_{\max} 分别表示滤波器的最大尺度和最大方向。

频率同样影响了高斯核函数的大小，也就是说， σ_x 和 σ_y 也会随着 u_0 的变化而变化，因此，我们定义：

$$\sigma_x = \frac{\sigma'_x}{2\pi u_0} = \frac{k^{(u-1)}}{2\pi f_{\max}} \sigma'_x \quad (3.8)$$

$$\sigma_y = \frac{\sigma'_y}{2\pi u_0} = \frac{k^{(u-1)}}{2\pi f_{\max}} \sigma'_y \quad (3.9)$$

由此，为了确定具体的 Gabor 滤波器的各种特性，我们只需确定 σ'_x , σ'_y , f_{\max} , k , u_{\max} 和 v_{\max} 的值，之后将会具体讨论各个参数的选择。

3.1.2 多尺度方向的计算

在我们的特征集中所使用的多尺度方向是通过将图像与不同尺度和方向的 Gabor 滤波器进行卷积计算得到的。

给定图像 $I(x, y)$ 的 Gabor 变换可以定义为图像与 Gabor 滤波器的卷积，如 (3.10) 所示：

$$r(x, y) = \iint I(\xi, \eta) g(x - \xi, y - \eta) d\xi d\eta \quad (3.10)$$

其中 $r(x, y)$ 是一个复合函数，可以表示成另外一种形式如下[51]：

$$r(x, y) = M(I, g) \cdot \exp(iP(I, g)) \quad (3.11)$$

其中包含一个幅值项 $M(I, g)$ 和一个相位项 $P(I, g)$ ，它们的定义如下：

$$M(I, g) = \sqrt{\left[\iint I(x, y) g_r(x, y) dx dy \right]^2 + \left[\iint I(x, y) g_i(x, y) dx dy \right]^2} \quad (3.12)$$

$$P(I, g_n) = \tan^{-1} \frac{\iint I(x, y) g_i(x, y) dx dy}{\iint I(x, y) g_r(x, y) dx dy} \quad (3.13)$$

$g_r(x, y)$ 和 $g_i(x, y)$ 分别表示了 Gabor 滤波器 $g(x, y)$ 的实部和虚部。

幅值和相位是 Gabor 滤波器的两个基本响应。实际上，还有另外一种新的 Gabor 响应，叫做 Gabor 方向响应。如果一组 Gabor 滤波器除了方向参数 α 之外，

其他的参数值都一样，那么利用这一组滤波器，我们可以提取出 Gabor 方向，如下所示[28]:

$$\alpha_{\max} = \arg \max_{\alpha_i} \left(M(I, g_{\alpha_i}) \right) \quad (3.14)$$

其中， g_{α_i} 是在这一组滤波器中方向参数为 α_i 的那个滤波器。也就是说，Gabor 方向是在同一尺度下所有的方向响应中对应最大幅值的那个方向，通过对滤波器组的尺度的变化，可以得到不同尺度上的方向响应，从而形成多尺度方向。

3.1.3 H-MSO 特征提取过程

如图 3-2，在论文中我们使用了 40 个 Gabor 滤波器来进行 H-MSO 特征的提取，其中包括 5 个尺度 ($u_{\max} = 5$) 和 8 个方向 ($v_{\max} = 8$)。每一个训练样本都被归一化为 $64*64$ 的固定大小，如图 3-3 所示:




图 3-2 5 个尺度 8 个方向上的 40 个滤波器



图 3-3 训练样本示例(a)为正例样本(b)为反例样本

首先，将每一个样本的都划分成 $16*16$ 大小的单元（如图 3-4 所示），共形成 16 个这样的单元。为了保证特征的鲁棒性，借鉴 HOG 特征提取的思想，我们将这 16 个单元重新组合成 9 个相互有重叠的 $32*32$ 大小的块。相邻行相邻列的四个单元组成一个块，如图 3-4，1、2、5、6 四个单元组成一个块，2、3、6、7 组成另一个，直到 11、12、15、16 四个单元组成最后一个块。




图 3-4 训练样本的划分

然后，将训练样本与每一个 Gabor 滤波器分别进行卷积，图 3-5 显示了卷积后的结果。在样本与同一尺度、方向参数不同的 8 个滤波器进行卷积时，对于样本中的每一个像素位置都可以产生一个 Gabor 方向响应和与该方向相对应的幅值响应（如公式 (3.14) 的定义），这样，对于所有的 40 个滤波器，在 5 个不同的尺度上，每个像素位置可以生成 5 个 Gabor 方向和与之对应的 5 个幅值。对于每一个单元，我们分别统计所有像素在每一个尺度上的方向直方图，形成一个 8 维的向量（每一个方向对应一个维数），直方图的每一维的值是所有与该维所表示的方向对应的幅值的和。然后再将所有 5 个尺度的直方图连接起来，形成一个 $8*5=40$ 维的向量。在一个块内，将每一个单元的 40 维的向量连接起来，形成一个 $40*4=160$ 维的向量，如下所示：

$$[w_{111}, w_{112}, \dots, w_{118}, w_{121}, \dots, w_{128}, w_{131}, \dots, w_{138}, w_{211}, \dots, w_{218}, w_{311}, \dots, w_{318}, w_{411}, \dots, w_{418}]$$

其中， $w_{p,u,v}$ 表示直方图的一维， $p=1,2,\dots,4$ 代表了块内的 4 个单元， $u=1,2,\dots,5$ 表示了 5 个不同的尺度， $v=1,2,\dots,8$ 表示了 8 个不同的方向。






图 3-5 滤波后的图像（以图 3-3（a）中的车辆样本为例）

最后，在每一个块内，将向量进行归一化。并将样本的 9 个块内的向量连接起来，形成一个 $160 \times 9 = 1440$ 的向量，也就是最终的特征向量集合。

图 3-6 描述了整个特征提取的过程：

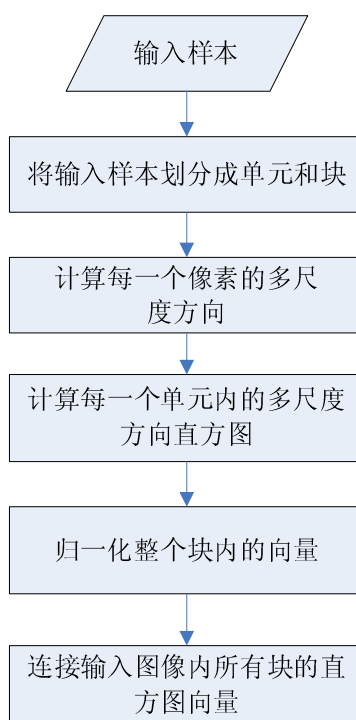


图 3-6 H-MSO 特征提取过程

3.2 特征提取过程中参数的选择

特征提取过程中的参数也会影响到特征的好坏，从而对检测结果造成影响，因此，本文对影响检测结果的几个参数如 Gabor 滤波器的参数、子区域大小的选择和归一化方法的选择等进行了讨论。

3.2.1 关于 Gabor 滤波器参数的选择

之前的论述已经表明，影响 Gabor 滤波器的参数共有 6 个： σ'_x ， σ'_y ， f_{\max} ， k ， u_{\max} 和 v_{\max} 。由于 u_{\max} 和 v_{\max} 已经事先确定，在此，我们只关注另外的几个参数 σ'_x ， σ'_y ， f_{\max} 和 k 。设定它们的初始值分别为： $\sigma'_x = \sigma'_y = 2\pi$ ， $f_{\max} = 1/4$ 和 $k = \sqrt{2}$ 。

我们使用三折交叉验证来评估不同参数下的检测性能, 然后选择检测性能高的那组参数。

首先, 优化 σ'_x 和 σ'_y 的值, 用交叉验证得到的不同值下的检测率如表 3-1:

表 3-1 σ'_x 和 σ'_y 值的比较

σ'_x, σ'_y	利用交叉验证得到的检测率
$\sigma'_x = \sigma'_y = \pi$	99.6%
$\sigma'_x = 2\pi, \sigma'_y = \pi$	99.5556%
$\sigma'_x = \pi, \sigma'_y = 2\pi$	99.5333%

由以上三组数据的对比发现 σ'_x 和 σ'_y 的值相同时检测率较高, 因此我们令 $\sigma'_x = \sigma'_y$, 又进行如下实验:

表 3-2 σ'_x 和 σ'_y 值的比较

σ'_x, σ'_y	利用交叉验证得到的检测率
$\sigma'_x = \sigma'_y = \pi/4$	99.5111%
$\sigma'_x = \sigma'_y = \pi/2$	99.6246%
$\sigma'_x = \sigma'_y = \pi$	99.6%
$\sigma'_x = \sigma'_y = 2\pi$	99.5333%
$\sigma'_x = \sigma'_y = 4\pi$	99.4407%

由表 3-2 看出检测率的变化曲线类似开口向下的抛物线的形状, 在 $\sigma'_x = \sigma'_y = \pi/2$ 时达到峰值, 因此我们最终确定 $\sigma'_x = \sigma'_y = \pi/2$ 。

在 $\sigma'_x = \sigma'_y = \pi/2$ 的情况下, 我们继续考察参数 f_{\max} 的值。在 $f_{\max} = 1/8$, $f_{\max} = 1/4$ 和 $f_{\max} = 1/2$ 三种情况下, 检测率如表 3-3 所示:

表 3-3 f_{\max} 值的比较

f_{\max}	利用交叉验证得到的检测率
$f_{\max} = 1/8$	99.4889%
$f_{\max} = 1/4$	99.6246%
$f_{\max} = 1/2$	99.6777%

因此, 我们选择 $f_{\max} = 1/2$ 。

最后，在 $\sigma'_x = \sigma'_y = \pi/2$ ， $f_{\max} = 1/2$ 的情况下，我们考虑参数 k 的值。 k 在不同情况下的检测率如表 3-4 所示：

表 3-4 k 值的比较

k	利用交叉验证得到的检测率
$k = \sqrt{2}/2$	96.9556%
$k = \sqrt{2}$	99.6777%
$k = 2\sqrt{2}$	99.4667%
$k = 4\sqrt{2}$	99.2222%

最终我们选择 $k = \sqrt{2}$ ，这样，Gabor 滤波器的所有参数的值都确定： $\sigma'_x = \sigma'_y = \pi/2$ ， $f_{\max} = 1/2$ 和 $k = \sqrt{2}$ 。

3.2.2 子区域的大小的选择

在本论文中所使用的训练样本的大小为 $64*64$ ，检测时也是以 $64*64$ 大小的图像块作为基本的检测单元。对于这个大小的图像块，我们需要相应地确定 Gabor 滤波器窗口的大小和图像块中与滤波器进行卷积的子窗口的大小。

对于之前确定好的滤波器的参数，我们选择了几个 Gabor 核函数的大小来进行比较。如图 3-7 所示：如果滤波器大小为 $8*8$ ，我们不能看到完整的 Gabor 核，这会影响滤波器的性能；如果滤波器大小为 $64*64$ ，可以看到窗口外围大部分黑色区域，这些区域反映的都是无效信息，而且在进行滤波运算时还要消耗大量的时间，因此，选择 $64*64$ 大小的滤波器窗口也是不合适的。通过比较，最终确定了滤波器窗口大小为 $12*12$ ，从图中也可以看出窗口中包含了完整的 Gabor 核，而且外围的无效信息很少。




图 3-7 滤波器窗口大小的变化

下一个需要解决的问题就是在 $64*64$ 大小的图像块中与 Gabor 滤波器进行卷积的子窗口的大小。如果我们将 $64*64$ 图像块中的每个 $16*16$ 大小的单元分别与

Gabor 滤波器进行卷积, 用交叉验证得到的检测率为 99.3999%, 如果直接将整个 64*64 大小的图像块与 Gabor 滤波器进行卷积, 得到的检测率为 99.6777%, 因此, 我们采用第二种方法, 直接将整个 64*64 大小的图像块与 Gabor 滤波器进行卷积。

3.2.3 归一化方法的选择

特征提取完成之后, 一个 32*32 的块能够用一个 160 维的特征向量来描述, 然后我们需要将该向量进行归一化, 在此, 我们研究一下归一化的方法。

我们使用 l_2 范式来归一化向量。 $w \leftarrow \frac{w}{\sqrt{\|w\|^2 + \varepsilon^2}}$, 其中, ε 是为了避免除数

为零而添加的一个很小的归一化常数[10]。

一种常见的归一化策略是对所有 160 维进行整体的归一化, 如下所示:

$$w_{p,u,v} = \frac{w_{p,u,v}}{\sqrt{\left(\sum_{p=1}^4 \sum_{u=1}^5 \sum_{v=1}^8 w_{p,u,v}^2\right) + \varepsilon^2}}, p=1,2,\dots,4, u=1,2,\dots,5, v=1,2,\dots,8$$

事实上, 当我们将图像与不同尺度上的滤波器进行卷积的时候, 幅值的变化是很大的, 因此, 我们考虑另外一种归一化策略: 对 5 个尺度上的向量维分别进行归一化, 例如, 对于第一个尺度, 也就是 $u=1$ 时所生成的向量各维, 进行如下的归一化:

$$w_{p,1,v} = \frac{w_{p,1,v}}{\sqrt{\left(\sum_{p=1}^4 \sum_{v=1}^8 w_{p,1,v}^2\right) + \varepsilon^2}}, p=1,2,\dots,4, v=1,2,\dots,8。$$

对于其他尺度也采用相同的归一化方法。

对于第一种归一化策略, 检测率为 99.4222%, 如果我们改用第二种策略, 检测率变为 99.5333%。因此, 我们采用第二种归一化策略, 在不同的尺度上分别进行向量维的归一化。

3.3 SVMs 分类器

SVMs 是在统计学习理论上开发出来的一种非常有效的机器学习方法[52], 它是在结构风险最小原则下, 实现复杂度和推广性的最佳折衷, 从而达到了很好的分类性能, 并且有效地解决了学习过程中的小样本问题, 对训练样本量的需求较小, 这为 SVMs 在车辆检测中的应用提供了可行性。因此, 我们采用

SVMs 分类器来实现此阶段车辆区域的判别。

3.3.1 经验最小化原则

传统的学习理论是假定已知变量 y 和输入 x 之间存在一定的规律，即存在一个未知的联合概率 $F(z)$ ，根据 l 个独立同分布样本数据，在一组函数 $\{f(x, \alpha)\}$ 中求解一个最优的函数 $\{f(x, \alpha_0)\}$ ，使得预测的期望风险 ($R(\alpha)$) 最小，即 $\text{Min}(R(\alpha))$ [39]。期望风险的公式为：

$$R(\alpha) = \int L(y, f(x, \alpha)) dF(z) \quad (3.15)$$

其中， $z_i = (x_i, y_i)$ 为样本数据集， $\{f(x, \alpha)\}$ 为预测函数集， $\int L(y, f(x, \alpha))$ 为损失函数，即用 $\{f(x, \alpha)\}$ 对 y 进行预测过程中所造成的损失。

经验风险是指训练样本集的损失函数的均值。经验风险最小化原则就是用对参数 α 求经验风险 $R_{emp}(\alpha)$ 的最小值代替求期望风险 $R(\alpha)$ 的最小值。如下所示：

$$R_{emp}(\alpha) = \frac{1}{l} \sum_{i=1}^l L(y, f(x_i, \alpha)) \quad (3.16)$$

这里 l 是训练样本数目， $L(y, f(x_i, \alpha))$ 表示为不同的损失函数。

传统的学习理论中，一味追求经验风险 $R_{emp}(\alpha)$ 最小。但是在现实生活中，由于训练样本数的限制，基于经验风险最小化准则的学习机器在实际应用中就普遍存在推广能力不足的问题[53]。

3.3.2 结构风险最小化原则

VC 维是描述学习机器学习能力的一个重要指标[54]，对于学习机器来说，VC 维越大，机器的学习能力就越强。学习能力越强的机器能够得到越复杂的最优分类面。然而，越复杂的分类面，就越依赖于训练数据分布的细节，这种对训练数据的过于严重的依赖，往往会导致学习机器的推广能力下降[55]。

推广能力也称推广性的界，是分析学习机器性能的基础[56]。其基本思想为：

对于指示函数集 $f(x, \alpha)$ ，如果损失函数 $Q(x, \alpha) = L(y, f(x, \alpha))$ 为一般的有界非负实函数，即 $0 \leq Q(x, \alpha) \leq B$ ，则对指示函数集中的所有函数，经验风险 $R_{emp}(\alpha)$ 和实际风险 $R(\alpha)$ 之间以至少 $1-\eta$ 的概率满足如下关系[57]：

$$R(\alpha) < R_{emp}(\alpha) + \sqrt{\frac{h(\ln(2l/h) + 1 - \ln(\eta/4))}{l}} \quad (3.17)$$

这里 h 为函数集的 VC 维， l 为训练样本数目。

从公式 (3.17) 可以看出，作为学习机器的真实风险界包含了两个部分，第一个是经验风险；另外一个是有了一定置信范围的风险，并且置信范围与 VC 维成正比。真实风险的变化图可见图 3-8:




图 3-8 真实风险界图

从图中可以直观地看到，随着 VC 维的增大，经验风险逐渐减小，而置信范围则逐渐增大，真实风险则表现出先减小后增大的趋势，并且在 h_m 位置，真实风险得到最小值，从而实现了对复杂度和推广性的最佳折衷[58]，因此使得期望风险达到最小，这就是所说的结构风险最小化原则[59-60]。结构风险最小化原则有效地解决了某些分类问题的小样本问题，并且成功避免了传统学习机器在学习过程中所遇到的过学习和欠学习现象[53]。

3.3.3 SVMs 的原理

传统的统计学常常会导致过学习现象[53]，因此，Vladimir N.Vapnik 等人在结构风险最小化原则的基础上创造了 SVMs 的学习方法。

假设有 l 个属于两个不同类的训练样本点的训练样本集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$ ，其中 $x_i \in R^N$ ， $y_i \in \{\pm 1\}$ ， $i = 1, 2, \dots, l$ 。它可以被

一个分类超平面 $w \bullet x + b = 0$ 分成两类, 并且使离超平面最近的数据与超平面间的距离最大, 这个分类超平面就被称为最优分类超平面。

线性二分类问题的最优分类超平面示图如图 3-9 所示, 训练样本点可以分作两类, 一类样本点用 “●” 来表示, 另外一类样本点用 “○” 来表示。




图 3-9 最优分类超平面

图中, H 平面代表最优分类超平面, H_1 和 H_2 代表超平面 H 两边与其距离最近的点所在的超平面, 在 H_1 和 H_2 上的各点就是支撑向量, 并且这些支撑向量确定了唯一的分类超平面 H 。

H 、 H_1 和 H_2 的方程可以表示为如下形式:

$$H: w \bullet x + b = 0, \quad H_1: w \bullet x + b = 1, \quad H_2: w \bullet x + b = -1 \quad (3.18)$$

全部样本点满足 $y_i(w \bullet x_i + b) \geq 1$ 的形式。

超平面 H_1 或 H_2 上任意一点距离最优分类超平面 H 的距离为:

$$\frac{|w \bullet x + b|}{\|w\|} = \frac{1}{\|w\|}, \text{ 因而超平面 } H_1 \text{ 和 } H_2 \text{ 之间的距离为 } \frac{2}{\|w\|}。 \text{ 使最优分类超平面距离}$$

这两类样本点最大化相当于求 $\|w\|^2$ 最小。因此, 求最优超平面可表示为下面的二次规划问题:

$$\text{Minimize } Q(w) = \frac{1}{2} \|w\|^2 = \frac{1}{2} (w^T w) \quad (3.19)$$

$$\text{Subject to } y_i(w \bullet x_i + b) \geq 1 \quad (3.20)$$

在引入 Lagrange 乘积因子 $\alpha_1, \alpha_2, \dots, \alpha_l \geq 0$, 利用 Lagrange 优化方法可以将

上述求解最优分类面问题转化为其对偶问题，即在如下约束条件：

$$\begin{cases} \sum_{i=1}^l y_i \alpha_i = 0 \\ \alpha_i \geq 0, i = 1, \dots, l \end{cases} \quad (3.21)$$

对 α_i 求解如下 Lagrange 函数的最大值：

$$L(w, b, a) = \frac{1}{2} w^T w - \sum_{i=1}^l \alpha_i (y_i (w \bullet x_i + b) - 1) \quad (3.22)$$

其中 $L(w, b, a)$ 为 Lagrange 构造函数。

分别求函数 $L(w, b, a)$ 关于 w 和 b 的一阶偏导数为零的点，可以得出：

$$w = \sum_{i=1}^l \alpha_i y_i x_i \quad (3.23)$$

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (3.24)$$

将 (3.23) 式和 (3.24) 式带入到方程 (3.22)，即可得到如下方程形式：

$$L_D = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i x_j \quad (3.25)$$

最终的优化问题及其约束条件如下：

$$\begin{aligned} \text{Maximize } Q(\alpha) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i x_j \\ \text{Subject to } &\begin{cases} \sum_{i=1}^l y_i \alpha_i = 0 \\ \alpha_i \geq 0, i = 1, \dots, l \end{cases} \end{aligned} \quad (3.26)$$

求解上述优化问题可以得到 α_i 的值，再据此算出 w 和 b 的值。对 SVMs 的训练过程实际上就是不断优化寻找最佳 w 和 b 的过程。最终的决策函数可以表示为：

$$f(x) = \text{sgn}(w \bullet x + b) = \text{sgn}\left(\sum_{i=1}^l \alpha_i y_i (x_i \bullet x) + b\right) \quad (3.27)$$

其中 $\text{sgn}(\bullet)$ 表示符号函数，指出参数的正负号。返回值 (\bullet) 如果大于 0，则 sgn 返回 1，等于 0，返回 0，小于 0，则返回 -1。

事实上，在求得的这些 Lagrange 乘积因子中，仅仅有一部分是非零的，每个非零的 Lagrange 乘积因子对应的样本点就是通过训练 SVMs 得到的支持向量。

构建最优超平面的过程就是找到所有非零 α_i 的过程。

若训练集不能严格地保证在超平面 H_1 和 H_2 之间没有训练点，可以采用一种是扩展的，允许有数据噪声数据的支持向量机。容许错分现象的分类超平面被称作软间隔分类超平面，如图 3-10 所示。

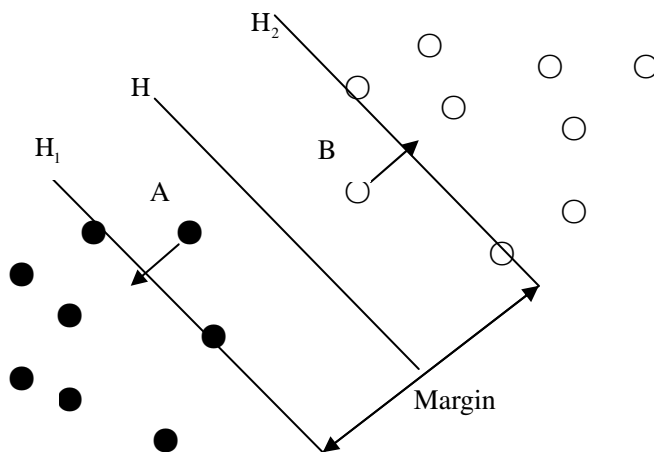


图 3-10 软间隔最优分类超平面

引入非负的松弛因子 $\varepsilon_i \geq 0$ 来容许错分样本的存在。即所有的样本不能都满足 $y_i(w \bullet x_i + b) \geq 1$ 的形式，而是全部样本点满足 $y_i(w \bullet x_i + b) \geq 1 - \varepsilon_i$ 的形式。

同时设置一个惩罚因子 $C (C > 0)$ 来控制学习机器模型复杂性与分类性能之间的平衡。表示对错分样本惩罚的程度， C 越大，对错分样本的约束程度就越大。优化问题及约束条件改写为如下形式：

$$\begin{aligned} \text{Minimize} \quad & Q(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \varepsilon_i \\ \text{Subject to} \quad & y_i(w \bullet x_i + b) \geq 1 - \varepsilon_i, C > 0 \end{aligned} \quad (3.28)$$

式中：

ε_i 为松弛变量，是对错误分类误差的度量。

C 为惩罚因子，是一个给定的常数，可根据数据的噪声来确定。

在另外一些情况下，给定的数据点在低维情况下是线性不可分的，SVMs 分类器对于这种情况的解决办法就是将数据点映射到高维空间，并在新的高维空间下实现线性可分。如何将低维数据映射到高维空间取决于所选择的核函数 $k(x_i, y_i)$ 。当 SVMs 采用核函数来解决非线性映射问题后，待优化问题及其约束条件描述如下：

$$\begin{aligned} \text{Maximize } Q(\alpha) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j x_i x_j k(x_i, x_j) \\ \text{Subject to } &\begin{cases} \sum_{i=1}^l y_i \alpha_i = 0 \\ 0 \leq \alpha_i \leq C, i=1, \dots, l \end{cases} \end{aligned} \quad (3.29)$$

式中： $k(\bullet)$ 为非线性映射对应的核函数。

最终的非线性最优分类函数描述为：

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i y_i k(x, x_i) + b \right) \quad (3.30)$$

通过使用不同的核函数, SVMs 可以实现很多不同的学习功能。可作为 SVMs 核函数的函数非常多, 但是常用的有三种核函数:

(1) 多项式核函数:

$$k(x, y) = (x \bullet y + \theta)^d, d = 1, 2, \dots \quad (3.31)$$

将多项式核函数带入到 (3.30) 式中, 得到多项式核支持向量机, 其分类函数为:

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i y_i ((x_i \bullet x) + \theta)^d + b \right) \quad (3.32)$$

(2) Sigmoid (双曲线正切) 核函数:

$$k(x, y) = \tanh(\lambda(x \bullet y) - \mu) \quad (3.33)$$

将 Sigmoid 核函数带入到 (3.30) 式中, 得到 Sigmoid 核支持向量机, 其分类函数为:

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i y_i \tanh(\lambda(x_i \bullet x) - \mu) + b \right) \quad (3.34)$$

(3) 高斯径向基核函数, 为最常见的径向基函数:

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) = \exp\{-\lambda\|x - y\|^2\} \quad (3.35)$$

将高斯径向基核函数带入到 (3.30) 式中, 得到高斯径向基核支持向量机, 其分类函数为:

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i y_i \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) + b \right) \quad (3.36)$$

在车辆检测分类模型的训练过程中，首先对所有的正例和反例的训练样本进行标号，正例样本标号为+1，反例样本的标号为-1。如下所示：

$$y_i = \begin{cases} +1 & \text{如果训练样本}i\text{为正例} \\ -1 & \text{如果训练样本}i\text{为反例} \end{cases} \quad i=1,2,\dots,l, l\text{为训练样本的总个数} \quad (3.37)$$

然后对所有的训练样本提取 H-MSO 特征，每个训练样本的特征记为 x_i ，这样 (x_i, y_i) ， $i=1,2,\dots,l$ 构成了整个的训练样本集，将这个训练样本集送入合适的模型求解，求出所有的支持向量及其相应的权重，从而可以求得最终的分类决策边界。

本文针对三种常用的核函数分别生成相应的 SVMs 模型，通过交叉验证得到的检测率与线性 SVMs 所生成模型的检测率进行比较，最终选择了线性 SVMs 模型。

3.4 假设验证阶段的车辆检测过程

对于输入的检测图像，我们逐像素地扫描整幅图像，利用已训练完成的 SVMs 分类模型来判断每一个子图像块中是否存在车辆。为了检测不同大小的车辆，在对图像进行扫描前，还需对其进行不同尺度的缩放。检测过程如图 3-11 所示：

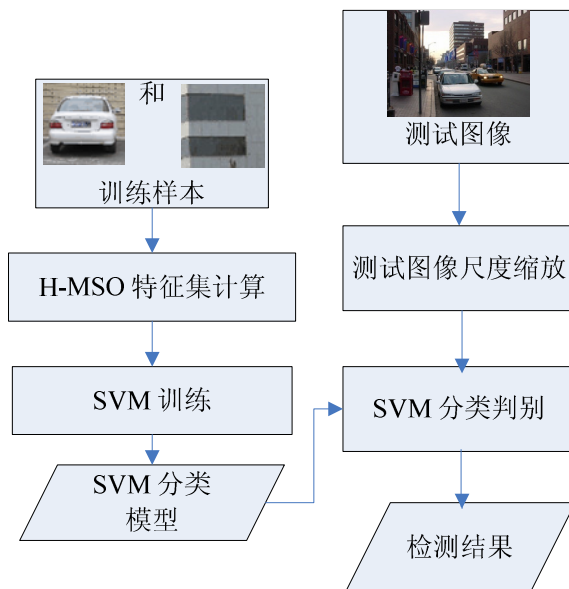


图 3-11 车辆检测过程

3.5 本章小结

本章主要阐述了假设验证阶段的车辆检测过程。在假设验证阶段，需要对前一阶段检测出来的车辆候选区域进行验证，最终确定该区域是否是车辆区域。因此，我们采用一种新的 H-MSO 特征来对车辆进行描述，H-MSO 特征通过将图像与不同尺度和方向的 Gabor 滤波器进行卷积得到，并利用 SVMs 分类器进行分类。本章对 Gabor 滤波器的特性进行了详细的介绍，并且对特征提取过程中各个参数的选择进行了说明。

第四章 实验结果与对比分析

在车辆检测过程中，训练数据影响着分类模型的好坏，从而影响了分类的性能，在本章中我们主要论述了实验过程中需要的训练和测试数据，并且将本文的算法与目前的其他检测方法进行了比较，用测试数据举例说明了本文提出算法的有效性。

4.1 实验数据

对于车辆检测来说，实验数据也起到了很重要的作用。训练数据的选择直接影响到分类器模型的好坏，而测试数据则用来评估算法的性能。

4.1.1 训练数据集

由于本文研究的路面车辆主要是正视的车辆，因此，在训练过程中，我们也主要使用正视的车辆作为正例样本。我们一共收集了 1500 多幅正视的车辆图像作为正例样本和多于 5000 幅的非车辆图像反例样本（如图 4-1 所示）。所有的训练样本都是手工进行收集和标定的。为了确保数据的多样性，我们分别在不同的时间和条件下收集了大量的样本。为了保证训练样本的一致性，训练集中的每一个样本都被归一化到 $64*64$ 的大小。




图 4-1 训练样本集 (a) 正例样本 (b) 反例样本

4.1.2 测试数据集

测试数据用于评估算法的性能。我们一共使用了 684 幅图片来定量地评估本文所提出方法的有效性，这些图片是从麻省理工学院 (MIT)，CBCL 实验室下载的测试集。这些图片包含了不同的形状、颜色、视角，并且有局部遮挡和光照

变化的影响等。我们所使用的一些测试图片如图 4-2 所示：



图 4-2 测试图片示例

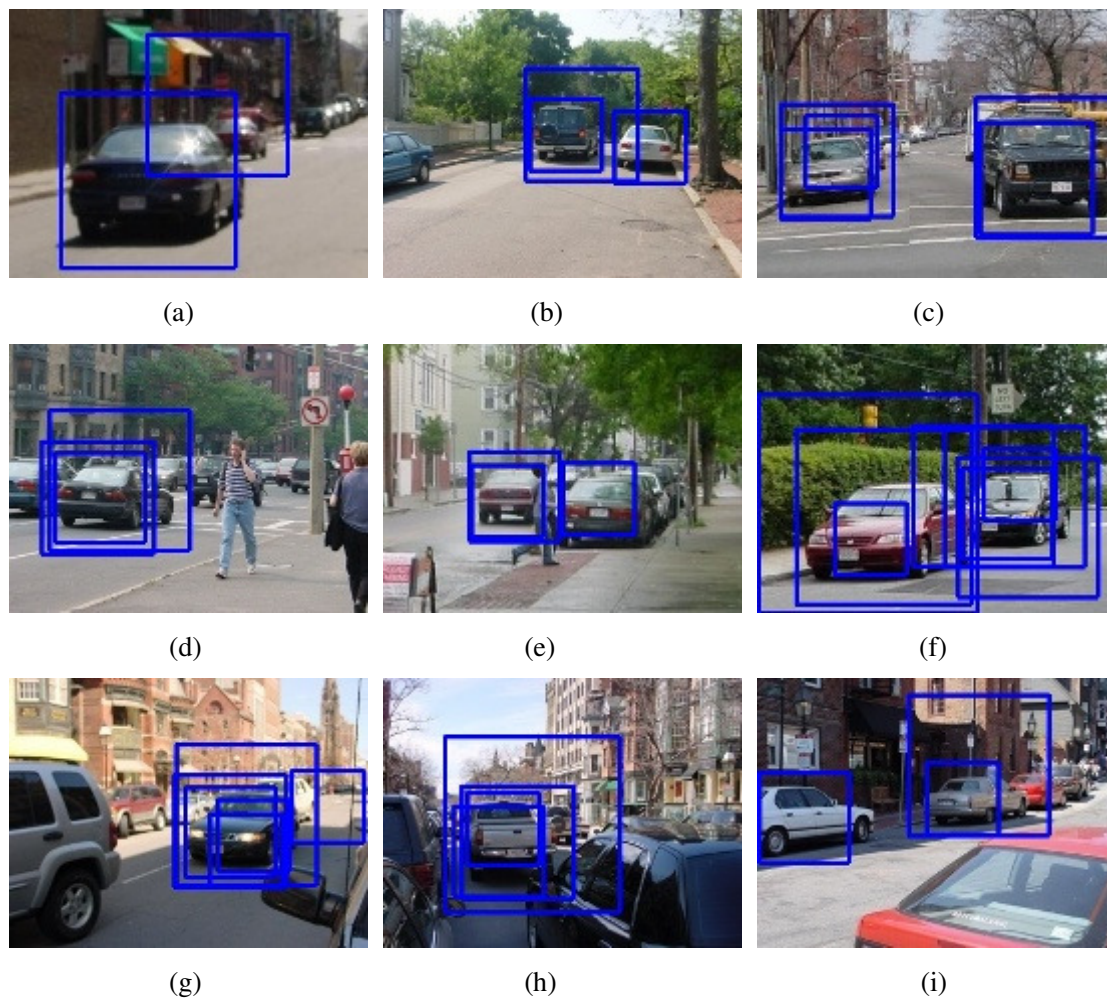
4.2 检测效果和与其他方法的比较

为了验证本文所提出的算法，我们对测试集中的所有图片进行了检测，并且在路面环境下验证了算法的有效性，最后与 HOG 特征进行了比较。由于不同视角以及不同类型的车辆在外观轮廓上会存在一定的差异性，所提取的特征也有所不同，我们所使用的正例训练样本均为正视轿车车型，因此，只针对正视角的轿车的检测。

4.2.1 检测效果

1、假设产生阶段的检测结果

假设产生阶段主要是在保证检测到所有车辆的同时，快速地过滤掉大部分的非车辆区域，使用本文的检测方法得到的检测结果如图 4-3 所示，可以看到该方法达到了此阶段的要求，在滤掉了大部分的非车辆区域的同时，所有的车辆区域都被正确地检测到，并且速度很快。



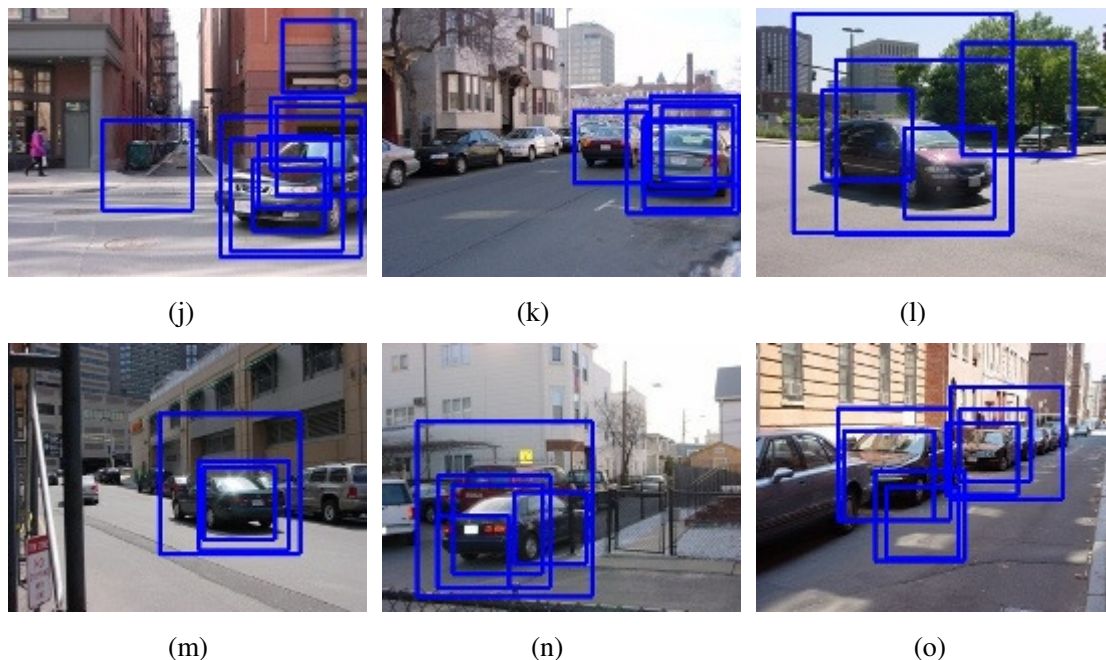



图 4-3 假设产生阶段车辆检测结果

2、假设验证阶段的检测结果

图 4-4 显示了用本文的算法进行假设验证过程的结果，可以看到在假设产生阶段的基础上，验证阶段又过滤掉了大量的误检区域。(a)图表明本算法对一定程度的光照变化具有鲁棒性。(b)图表明算法可以检测到不同类型的车辆。在(c)图中，存在一定视角变化的车辆和不同形状的车辆都被检测到了。(d)图、(f)图、(i)图、(j)图和(l)图等表明了本算法对视角变化具有一定的鲁棒性。并且在(d)图所处的复杂背景下，没有错误的检测发生。(e)图说明算法对部分遮挡具有一定的鲁棒性。所有的检测结果可以表明，本文使用的算法在各种复杂的背景下，对正视车辆都具有很好的效果，并且对于视角的轻微变化具有一定的鲁棒性，对于轮廓与轿车类似的其他车型，也可以检测到。



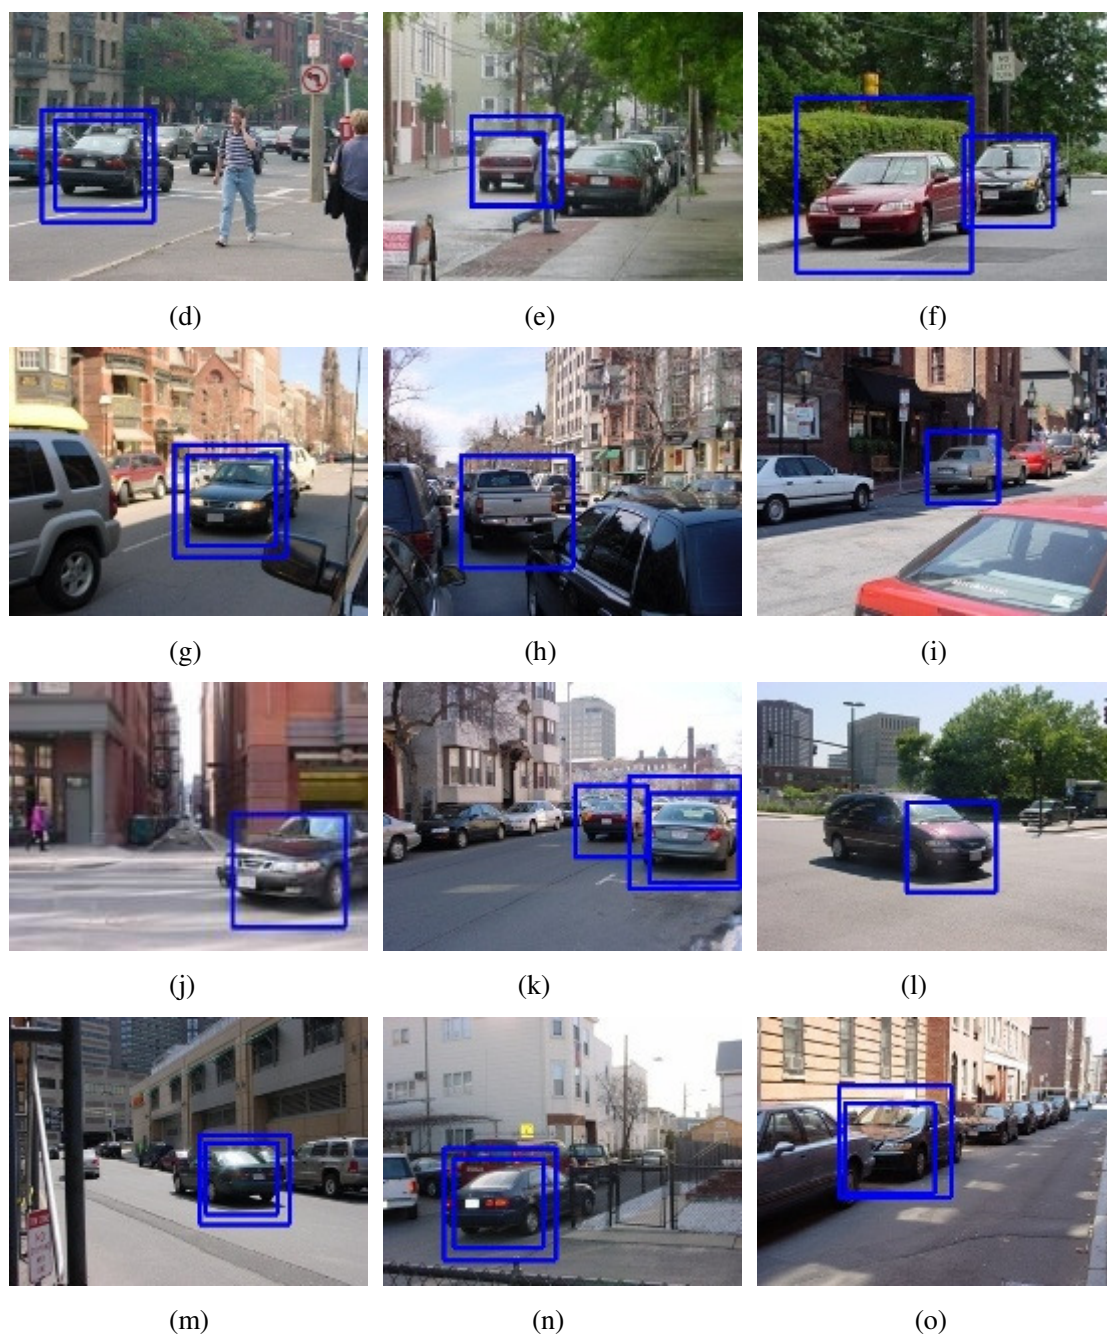


图 4-4 假设验证阶段车辆检测结果

由图 4-4 的结果可以看出，在各种复杂的情况下，本文提出的算法都能够很好的检测到车辆，为了验证本文提出的算法是否能够满足实时的路面车辆的检测，我们对在路面环境下拍摄的视频中的图像进行了检测，检测结果如图 4-5 所示：

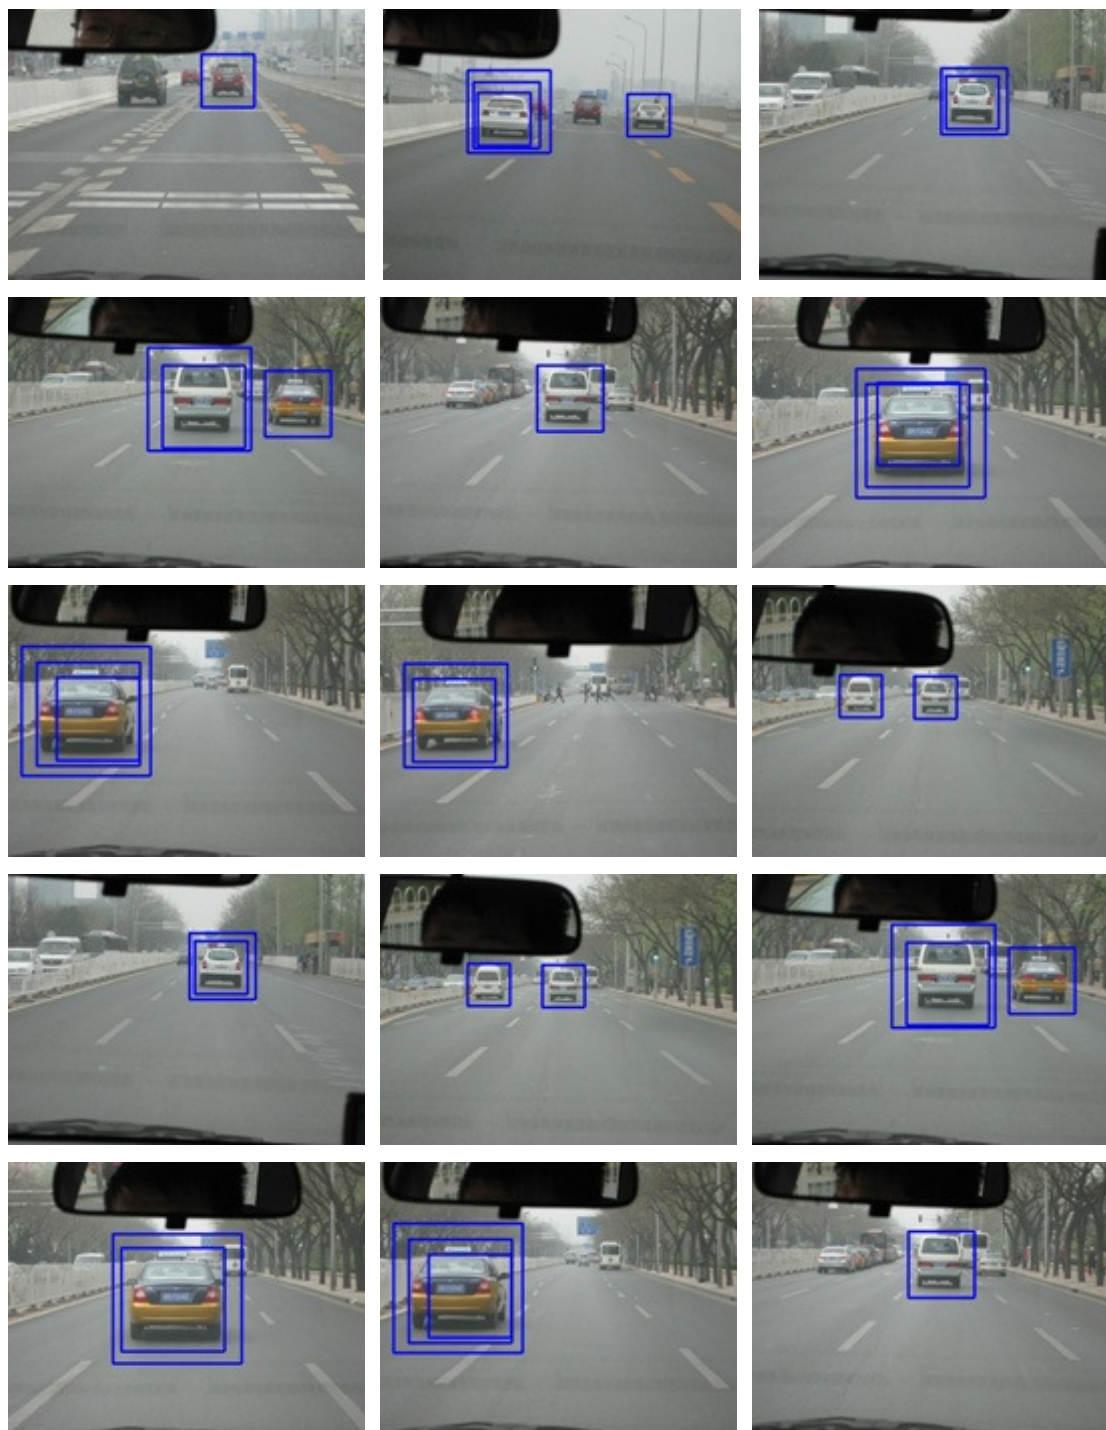


图 4-5 视频中的路面车辆检测结果

由图 4-5 可以看出,使用本文的算法基本上可以检测到前方的所有正视车辆,说明本文的算法可以满足路面车辆实时检测的需求,从而可以在检测到危险时及时报警,提醒驾驶员,达到辅助驾驶的功能。

4.2.2 与其他方法的比较

HOG 特征由于其良好的性能受到很多研究者的重视,在此,我们将本文的

提出的 H-MSO 特征与 HOG 特征进行了比较。具体方法为：对于 HOG 特征也采用本文所提出的二级检测策略，假设产生阶段的检测方法与本文一致，在假设验证阶段，采用 HOG 特征进行描述，用 SVM 分类器进行判别。这种情况下，可以比较 H-MSO 特征和 HOG 特征的性能。

我们用测试集图片的覆盖率和误检率来图对检测效果进行评估。覆盖率是指检测到的车辆数与实际的所有车辆数的比值。误检率是指所有错检的窗口数目与所有测试图片中所扫描的所有窗口的数目的比值。从图 4-6 中可以看出 H-MSO 特征的性能要优于 HOG 特征。

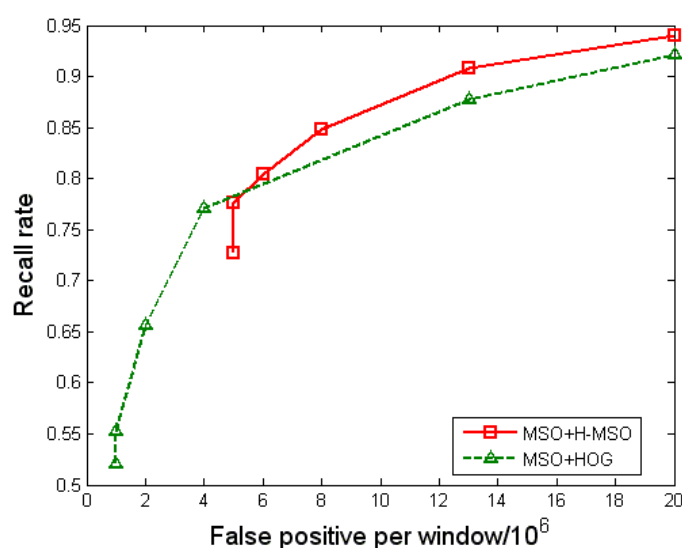


图 4-6 两种特征性能的比较

4.3 本章小结

在本章中我们主要论述了实验过程中需要的训练和测试数据，并且将本文的算法与目前的其他检测方法进行了比较，用测试数据举例说明了本文提出算法的有效性。可以看出，本文使用的算法取得了很好的性能，对光照、车辆的视角变化和遮挡等具有一定的鲁棒性，并且可以满足路面车辆检测的要求。

总结与展望

基于路面的车辆检测是车辆辅助驾驶系统和智能交通系统中一个非常重要的研究课题。本文基于车辆检测的一般方法，采用假设产生和假设验证两个步骤完成基于计算机视觉的路面车辆检测过程。在假设产生阶段采用 MSO 特征对车辆进行描述，并利用 Adaboost 学习算法对特征进行选择，最后将选出的特征构成一个级联分类器用于车辆区域的检测。在假设验证阶段，提出了一个新的特征集合，多尺度方向直方图 H-MSO 特征，用于车辆的描述，并采用 SVM 分类器对其进行分类判别。经过这两个阶段的检测，完成最终的车辆检测过程。实验结果验证了本文所提出算法的快速性和有效性。

本文涉及的概念和技术主要包括：采用二级检测策略进行车辆检测，在提高检测速度的同时保证了检测的有效性。提出了一个新的特征集合—多尺度方向直方图 H-MSO。采用多个尺度和方向的 Gabor 滤波器对图像进行滤波，从而得到各个像素点的多尺度方向，然后进行局部的直方图统计，并且用实验证明了该特征的有效性。

本文所提出的车辆检测方法虽然在一定程度上满足了需求，但是在研究的过程中，还是发现了一些问题，需要进一步的深入研究：

- 1、现有的检测方法只是针对轿车的检测，还不能实现对其他不同类型的车辆的检测。
- 2、在路面环境中，现有的检测方法只适用于正视角的车辆检测，对于其他的不同视角，由于车辆模式发生了很大的形变，还存在一定的困难。
- 3、作者未对 Gabor 滤波的理论进行深入的研究并对其进行改进以使其对目标特征的描述更加精确，因此，在某些情况下，所得到的检测结果也并不令人满意。而且受到 Gabor 滤波本身的限制，检测速度还有待进一步的提高。

在将来的工作中，我们将会对现有的特征进行改进，进一步提高检测速度。同时，将解决多视车辆的检测问题。

参考文献

- [1] D.A. Forsyth, J. Ponce. 计算机视觉——一种现代方法. 第一版.北京: 电子工业出版社, 2004. 1-2.
- [2] 赵云峰. 基于Gabor滤波特征的车辆检测系统的研究.燕山大学硕士学位论文, 2006.
- [3] Z. Sun, B. George, and M. Ronald. On-Road Vehicle Detection: A Review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, 2006(28).
- [4] W. Jones. Building Safer Cars. *IEEE Spectrum*, 2002(39): 82-85.
- [5] 彭仁明. 基于视频的车辆检测. 重庆大学工程硕士学位论文, 2004.
- [6] Z. Sun, B. George, and M. Ronald. On-Road Vehicle Detection Using Evolutionary Gabor Filter Optimization. *IEEE Transactions on Intelligent Transportation Systems*, June 2005(6): 125-137.
- [7] 王水清. 高速公路车辆检测系统.测控技术, 2001(20).
- [8] 张晓峰等. 车流信息的超声波检测系统.冶金自动化, 2001(3).
- [9] A. Broggi, M. Bertozzi, A. Fascicli, C. Guanrino Lo Bianco and A. Piazzzi. Visual Perception of Obstacle and Vehicle for Platooning. *IEEE Transactions on Intelligent Transportation Systems*, 2000(1): 164-176.
- [10] N. Matthews, P. An, D. Charnley and C. Harris. Vehicle Detection and Recognition in Greyscale Imagery. *Control Eng. Pract.*, 1996(4): 473-479.
- [11] C. Georick, N. Detlev, and M. Werner. Artificial Neural Networks in Real-time Car Detection and Tracking Applications. *Pattern Recognition Letters*, 1996(17): 335-343.
- [12] C. Papageorgiou, and T. Poggio. A Trainable System for Object Detection. *International Journal of Computer Vision*, 2000(38): 15-33.
- [13] D. Navneet, and T. Bill. Histograms of Oriented Gradients for Human Detection. *Computer Vision and Pattern Recognition*, June 2005(11): 886-893.
- [14] C. Papageorgiou, T. Evgeniou, and T. Poggio. A Trainable Pedestrian Detection System. *Proceedings of Intelligent Vehicles*, 1998(10): 15-33.
- [15] P. Viola. Robust Real-Time Face Detection. *International Journal of Computer Vision*, 2004(57): 137-154.
- [16] B. Zhang, S. Shan, X. Chen, and W. Gao. Histogram of Gabor Phase Patterns (HGPP): A Novel Object Representation Approach for Face Recognition. *IEEE Transactions on Image Processing*, 2007(16):57-68.
- [17] R. Mehrotra, K. Namuduri and N. Ranganathan. Gabor filter-based edge detection. *Pattern Recognition*, 1992(25): 1479-1493.
- [18] J. Daugman. Complete discrete 2-D Gabor Transforms by Neural Network for Image Analysis and Compression. *IEEE Transactions on Acoust. Speech Signal Process*, Jul. 1988(36): 1169-1179.
- [19] T. Weldon, W. Higgins and D. Dunn. Efficient Gabor Filter Design for Texture Segmentation. *Pattern Recognition*, 1996: 2005-2015.
- [20] A. Jain and F. Farrrokhnia. Unsupervised Texture Segmentation using Gabor Filters. *Pattern Recognition*, 1991(23): 1167-1186.
- [21] T. Hofmann, J. Puzicha and J. Buhmann. Unsupervised Texture Segmentation in a Deterministic Annealing Framework. *IEEE Transactions on Pattern Analysis*, May 1998(20): 803-818.

- [22] Y. Hamamoto, S. Uchimura, M. Watanave, T. Yasuda, Y. Mitani and S. Tomota. A Gabor Filter-based Method for Recognizing Handwritten Numerals. *Pattern Recognition*, 1998(31): 395-400.
- [23] R. Wurtz. Object Recognition Robust under Translations, Deformations, and Changes in Background. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997(19): 769-775.
- [24] K. Chung, S. Kee and S. Kim. Face Recognition using Independent Component Analysis of Gabor Filter Responses. *IAPP Workshop Machine Vision Applications*, 2000(11): 331-334.
- [25] Z. Sun, B. George, and M. Ronald. On-Road Vehicle Detection using Gabor Filters and Support Vector Machines. *Proceedings of IEEE International Conference on Digital Signal Processing*, 2002.
- [26] Z. Sun, B. George, and M. Ronald. Improving the Performance of On-Road Vehicle Detection by Combining Gabor and Wavelet Features. *IEEE 5th International Conference on Intelligent Transportation Systems*, 2002(9): 130-135.
- [27] B. Manjunath and W. Ma. Texture Features for Browsing and Retrieval of Image Data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996(18): 837-842.
- [28] K. Adams. An Evaluation of Gabor Orientation as a Feature for Face Recognition. *IEEE International Conference on Pattern Recognition*, 2008.
- [29] A.W.K.Kong and D.Zhang. Competitive Coding Scheme for Palmprint Verification. *IEEE International Conference on Pattern Recognition*, 2004(1): 520-523.
- [30] M.J. Swain and D.B.Ballard. Color indexing. *International Journal of Computer Vision*, 1991(17): 11-32.
- [31] C. Schmid, and R. Mohr. Local Grey Value Invariants for Image Retrieval. *IEEE Transactions on Pattern Analysis*, May 1997(19): 530-534.
- [32] M. Stricker and A. Dimai. Color Indexing with Weak Spatial Constraints. *Proc. SPIE, Storage and Retrieval for Still Image and Video Database IV*, 1996(26): 29-40.
- [33] S. Thomas, W. Lior, B. Stanley, et al. Robust Object Recognition with Cortex-Like Mechanisms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007(29): 694-711.
- [34] E. Hadjidemetriou, M.D. Grossberg, and S.K.Nayar. Multiresolution Histograms and Their Use for Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004(26): 831-847.
- [35] W. Zhang, S. Shan, W. Gao, X. Chen, and H.Zhang. Local Gabor Binary Pattern Histogram Sequence (LGBPHS): A novel non-statistical model for face representation and recognition. *Proceedings of 10th IEEE International Conference on Computer Vision*, 2005: 786-791.
- [36] Y.Freund and R.E.Schapire. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 1997(55): 119-139.
- [37] A Khammari, F Nashashibi, Y Abramson and C Laugeau. Vehicle Detection Combining Gradient Analysis and AdaBoost Classification. *Proceedings of IEEE Intellination Transp. Syst.*, 2005: 66-71.
- [38] W. Zheng and L. Liang. Fast Car Detection Using Image Strip Features. *IEEE Computer Vision and Pattern Recognition*, 2009: 2703-2710.

- [39] V. Vapnik. *The Nature of Statistical Learning Theory*. Springer Verlag, 1995.
- [40] V. Vapnik, E. Levin. The VC-dimension of a Learning Machine. *Neural Computation*, 1994(6): 851-876.
- [41] C. Burges. Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 1998(2): 955-974.
- [42] B. Moghaddam and M. Yang. Gender Classification using Support Vector Machines. *IEEE International Conference on Automatic Face and Gesture Recognition*, 2000: 306-311.
- [43] Z. Sun, X. Yuan, G. Bebis, and S. Louis. Genetic Feature Subset Selection for Gender Classification. A Comparison Study. *IEEE International Conference on Image Processing*, 2002.
- [44] 杨志辉. 基于多尺度方向特征的行人检测算法. 哈尔滨工程大学工学硕士学位论文, 2009.
- [45] D.G. Lowe. Object Recognition from Local Scale-invariant Features. In *International Conference on Computer Vision*, 1999: 1150-1157.
- [46] D.G. Lowe. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, 2004(60): 91-110.
- [47] H. Cong, A. Zhou, L. Hong. Multiview Pedestrian Detection Based on Vector Boosting. *Proceedings of Asian Conference on Computer Vision*, 2007: 210-219.
- [48] T. Haga, et al. Human Detection in Outdoor Scene using Spatio-temporal Motion Analysis. *Institute of Electrical and Electronics Engineers Inc.*, 2004: 331-334.
- [49] Y. Freund and R.E. Schapire. A Short Introduction to Boosting. *Journal of Japanese Society for Artificial Intelligence*, 1999(14): 771-780.
- [50] P. Viola, M. Jones. Rapid Object Detection using a Boosted Cascade of Simple Features. *IEEE conference of Computer Vision and Pattern Recognition*, 2001.
- [51] L. Wiskott, J.-M. Fellous, N. Kruger, and C. von der Malsburg. Face Recognition by Elastic Bunch Graph Matching. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997(19): 775-779.
- [52] 张学工. 关于统计学习理论与支持向量机. *自动化学报*, 2000(26): 32-42.
- [53] 刘清泉. 基于混合支持向量机多分类器的交通事件检测方法研究. 长沙理工大学硕士学位论文, 2009.
- [54] 邓乃扬, 田英杰. *数据挖掘中的新方法. 支持向量机*. 北京: 科学出版社, 2004.
- [55] N. Cristianini, T. J. Shawe. *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. UK: Cambridge university press, 2000.
- [56] V. Cherkassky, F. Mulier. Vapnik-Chervonenkis(VC) Learning Theory and its Applications. *IEEE Transactions on Neural Networks*, 1999(10): 985-987.
- [57] M. Vidyasagar. *A Theory of Learning and Generalization*. Springer Verlag, 1997.
- [58] V. Vapnik. *Statistical Learning Theory*. John Wiley & Sons, 1998.
- [59] B. Boser, I. Guyon, V. Vapnik. A Training Algorithm for Optimal Margin Classifiers. *Proceedings of the 5th Annual Workshop on Computational Learning Theory*, 1992: 144-152.
- [60] B. Scholkopf, C. Burges, V. Vapnik. Extracting Support Data for a Given Task. *Proceedings of the 1th International Conference on Knowledge Discovery & Data Mining*, 1995: 262-267.

发表文章目录

已发表文章目录

- **Fanjing Kong**, Qixiang Ye, Ning Zhang, Ke Lu, Jianbin Jiao. “On-Road Vehicle Detection Using Histograms of Multi-Scale Orientations”. Proceedings of IEEE International Youth Conference on Information, Computing and Telecommunications, 2009: 212-215.

致谢

在攻读硕士学位三年的学习生活中，我经历了诸多坎坷，也付出了艰辛的努力，同时也得到了很大的收获。在毕业论文完成之际，由衷地感谢这三年来曾经给予我无数帮助的老师、同学、朋友和家人。

首先，本课题的研究工作是在导师焦建彬教授的悉心指导下完成的。焦建彬教授在我的学习中，从理论和实验方面给予了大量的、极其有益的建议和具体的指导，并在论文的撰写和审稿中倾注了大量的心血，他诲人不倦的精神和对我的谆谆教导，使我从恩师身上学到了不少可贵的东西，让我受益匪浅。此外，他还在生活和思想上关心我、照顾我，再次表示万分的感谢！尤其是恩师严谨的治学态度、积极的进取精神、平易近人的工作作风将使我终身受益。

其次，特别要感谢叶齐祥老师在三年的学习与生活中对我的极大帮助和支持，他渊博的专业知识和精益求精的动手能力，在理论学习和项目开发过程中给我提供了耐心的引导和帮助。

再次，感谢同实验室的各位同学，他们在我的论文工作和撰写中，给予了我巨大的支持和帮助。

本项目的完成离不开国内外的技术资料，在此对参考文献的作者、译者以及出版单位表示感谢！

最后，向在学习、工作和生活中给予过自己关心、支持与鼓励的所有老师、同学、朋友们表示最诚挚的谢意！