

基于不确定性知识的实时道路场景理解

吴东晖 叶秀清 顾伟康

(浙江大学信息与通讯工程研究所, 杭州 310027)

摘要 由于室外机器人的工作环境非常复杂,因此机器人的视觉导航必须具有足够的智能和鲁棒性.为此,提出了一种基于不确定性知识的实时道路理解算法,该算法通过不确定性知识推理来融合多种信息和知识,以满足在复杂道路环境下的鲁棒性要求,它即使在有强烈阴影、水迹等干扰下也能给出比较好的结果;通过图象边缘信息的提取可以得到精确的道路边界,以满足视觉导航的精确性要求;同时在算法设计时,兼顾了实时性要求,使得算法得以实时实现,该算法已在实际的机器人上进行了测试,并得到了很好的结果.

关键词 计算机视觉导航 道路场景理解 不确定性知识推理

中图分类号: TP242.62 TP182 文献标识码: A 文章编号: 1006-8961(2002)01-0069-06

An Uncertain Knowledge Based Real Time Road Scene Understanding Algorithm

WU Dong-hui, YE Xiu-qing, GU Wei-kang

(Institute of Information & Communication Engineering Zhejiang University, Hangzhou 310027)

Abstract Because the environment of outdoor robot is very complicated, the visual navigation should be intelligent and robust enough. In order to improve the performance of computer vision navigation, a real time road scene understanding algorithm based on uncertain knowledge is presented in this paper. In this algorithm uncertain-knowledge reasoning is applied to fuse the various image information and application knowledge, which make the algorithm can recognize the road scene robustly, even with the noise such as strong shadow and water on the road. Color information is used to obtain a coarse road region at first. And then image edge information is used to provide the precise road edge, which can meet the accuracy need of the visual navigation task. And this algorithm is well designed for real-time application, which ensures that the visual navigation can make decisions in time. This algorithm has been applied on a real robot which has been tested in the real road environment for half a year. The experiment results are satisfying.

Keywords Computer-vision navigation, Road-scene understanding, Uncertain-knowledge reasoning

0 引言

计算机视觉导航使机器人可以工作于复杂环境中,而道路场景理解算法正是视觉导航中非常重要的一个环节.一个好的道路场景理解算法应该能够同时满足可实时实现、对环境变化的鲁棒性以及精确性的要求.其中,实时性要求是由于机器人的速度很快,因此要求算法能够及时给出理解结果,即要求算法必须能够实时实现;对环境变化鲁棒性要求则

是由于实际道路环境是非常复杂的,不可能事先预计到所有的情况,因此也就要求算法能够自动适应环境变化;精确性要求是指能够得到准确的道路区域,为路径规划提供详细可靠的信息.在上述3个要求中,实时性要求是最重要的,这是因为即使理解结果非常正确,若不能及时给出,也就没有实际意义;反之,即使某一帧理解结果有一些错误,但是只要能在一帧及时更正,那么对实际机器人性能影响也不会很大.在满足可实时实现的条件下,算法的鲁棒性比精确性更重要,这是因为即使路边的位置与实

际位置相差几十厘米,其在大部分情况下对路径规划影响不会很大;但是如果算法不够鲁棒,那么环境的变化将可能引起算法的结果和实际情况相差甚远,这样对路径规划影响就非常大了。

在前人的工作^[1~10]中,为了满足实时性要求,采用的算法大多比较简单,且使用的道路环境模型也相对比较理想化,但由于实际的道路要复杂得多,因此它们在环境变化的时候效果会变差。根据采用的特征不同,道路场景理解算法一般可以分为基于点特征的区域方法和基于边缘特征的方法两大类。在区域方法中,Martin Marietta 公司的 VITS^[2]和 FMC 大学的 ALV^[3,4]通过对彩色信息的降维处理,把 R、G、B 变换到一维坐标上,这样把道路彩色分布的主要特征保留下来虽可以方便图象的分割,但是由于实际光照条件是不不断变化的,而且道路彩色分布的主要特征也是不断变化的,因此降维处理有时会跟不上实际的变化,而把主要特征丢失了。另外,强烈的阴影和水迹也会带来干扰。CMU 大学的 NavLab^[1,5]中,使用彩色模型库的方法来保存不同道路和非路的彩色特征,并利用基于模型匹配的投票表决方法来得到地图,但是由于模型库中只含有彩色特征,而实际光照条件的变化却使得即使是同一景物,在同一天不同时刻,其颜色也是不同的,因此它对于光照的变化也比较敏感。在边缘方法中,比较有代表性的方法有 Maryland 大学的基于跟踪窗口的 VaMoPs^[6],它主要适用于道路模型比较简单的场合,如高速公路等。在范成法的工作中,提出了基于产生式知识的道路理解算法^[11,12],就使用了一个事先定义的规则库来在边缘特征库中寻找道路边缘,由于利用的是规则,而不是固定特征,因此对于光照的变化可以更鲁棒。该算法的特点还包括灵活的道路模型和反馈机制。当规则发生冲突时,通过反馈可以一直回朔到低层图象处理,以便寻找更多的证据来决定使用哪条规则,由于这些特点,因此算法对道路环境变化比较鲁棒,但是因为反馈机制也使最坏情况下计算量非常大,所以该算法实际上不可能实时实现。

由于在道路场景理解中,景物往往比较复杂,同时光照条件变化也比较大、比较快,因此道路场景理解有如下一些自身的特点:①针对不同的识别目标(如道路、阴影、水迹)往往需要采用不同的特征和不同的处理方法,而且即使是同一个识别目标,在不同的光照条件下,它的特征和规律也是不同的,而用知识来描述它们是最方便,最灵活的;②在道路场景理

解中,识别结果往往具有不确定性;③在道路场景理解中,由于许多知识和规律本身也具有不确定性,因此采用不确定知识推理是很自然的选择,而且由于采用不确定推理的另外一个好处是可以回避规则冲突,因此结构相对就简单,且不需要范成法算法中的反馈机制^[13],且计算时间是可以预测的。目前不确定知识推理经常使用的有基于概率论的概率推理方法、基于证据理论的证据方法、基于模糊集理论的模糊推理方法等 3 种方法。对于本文的道路场景理解系统,可以把它分成推理层、融合层、分类器层 3 个层次(见图 1)。其中,最低层是分类器层,在这层中,不同的分类器分别从不同的特征出发,依照不同的分类准则工作;中间层是融合层,在这层中,融合不同分类器的结果;最高层是推理层,在这层中,用前两层的结果为证据,根据许多知识来进行推理。如果从这 3 个层次来看 3 种不确定的推理方法,可以看到:①概率推理比较适合于分类,因为大部分分类问题都可以很好地估计假设的概率,这时用概率推理比较准确;②证据理论则比较适用于融合层,因为分类器一般都可以准确估计分类结果的概率赋值,所以利用 D-S 公式融合很方便;③模糊推理则适用于推理层,因为这时的规则多而复杂,采用模糊规则才能比较好地描述和推理。在本文的算法中,这 3 种推理方法在不同的地方都得到了应用。




图1 道路场景理解系统

为方便下文的叙述,在介绍道路理解算法之前,有必要先介绍一些基本概念。首先,把颜色、边缘等图象特征简称为特征;将由若干个特征所组成的空间称为特征空间,并在这个空间中,把属于同一个识别目标点的集合称为一个类别。假设特征空间上的分类器把特征空间 X 分为 $\theta = \{\theta_i, 1 \leq i \leq N\}$ 个类别,并且对于每个类别 θ_i 给出条件概率函数 $P(x | \theta_i)$,用以反映 $x \in \theta_i$ 的不确定性,并称向量 $P = [P(x | \theta_1), P(x | \theta_2), \dots, P(x | \theta_N)]$ 为似然向量,然后即可得到似然向量的嵌入信任函数,用以反映对分类结果的信任程度,与嵌入信任函数对应的基本概率赋值函数如式(1)所示^[13]。

$$\begin{cases}
 m^{(x)}(\theta) = K \prod_{i=1}^N P(x|\theta_i) \\
 m^{(x)}\left(\left(\theta - \bigcup_{1 \leq k \leq t} \{\theta_{ik}\}\right)\right) = K \prod_{j \notin I} P(x|\theta_j) \prod_{j \in I} (1 - P(x|\theta_j)) \\
 K = \left(1 - \prod_{i=1}^m (1 - P(x|\theta_i))\right)^{-1}
 \end{cases} \quad (1)$$

其中, $I = \{i_1, i_2, \dots, i_k\} \subset \{1, 2, \dots, N\}$, $1 \leq t \leq N-1$, $m^{(x)}(A)$ 反映了在特征 $X=x$ 的条件下, 分类 A 的基本概率赋值。

对于一些更复杂的知识, 用证据理论来表示和推理都很困难, 目前比较成熟的理论应该是模糊推理, 由于考虑到证据理论的信任度函数同时也是集合上的一个模糊测度, 因此从基本知识得到的分类结果可以通过模糊推理, 使其变更更好。

1 算法

1.1 图象特征选择

在大部分的道路场景理解算法中, 使用的图象特征一般有颜色、纹理和边缘。通过实验发现, 道路颜色一般是比较均匀的, 其分布基本上还是有规律可寻的。由于 R、G、B 分量相关性比较大, 直接在 RGB 空间上分割比较困难, 所以基本上都是在彩色变换以后才分割, 在文献 [2] 中, 即通过统计大量的道路图象数据来得到能代表道路颜色的彩色变换系数, 首先把 R、G、B 三维降到一维, 然后利用灰度图象分割, 把道路和非路分开, 这样就可以得到比较好的效果, 但是由于道路颜色受到道路的反光、阴影、水迹、灰尘以及光照方向, 时间、天气等的影响会发生变化, 在实验中, 也发现彩色变换的效果会随之变差, 这是由于彩色变换丢失了一部分彩色信息, 因此在本文的算法中采用了多种彩色变换, 并通过融合其结果来得到较好的结果。

在前人的工作中, 一般都假定道路区域纹理比较弱, 而非路(如草地等)纹理则比较丰富, 但是通过实验发现, 纹理的可靠性比较差, 其主要体现在如下两个方面: 首先, 上述假定将依赖于道路和非路是由什么物质构成的, 比如有些道路上纹理也很丰富, 而有些非路如泥地等, 纹理并不丰富; 其次, 当图象比较模糊时(在道路崎岖, 车辆颠簸的时候经常发生), 即使原来纹理很丰富的区域, 纹理也会变弱, 因此, 在本文的算法中不使用纹理作为特征。

因为道路是人工景物, 其轮廓一般比较规则, 而且

大部分情况下, 有比较明显的边缘影象, 所以边缘也是识别道路区域很有用的特征。但是, 由于图象上的边缘不仅仅是道路轮廓, 也可能由路面裂缝、阴影、周围环境等造成, 要在这么多的边缘中找到真实道路边缘是比较困难的, 因此一般都是利用道路轮廓比较规则的特点, 即用几何特征来检测真实道路边缘, 但是这样仍然不能保证得到的边缘是真实道路边缘, 比如路旁建筑物的阴影的边缘一般也很规则, 这时就容易和真实的道路边缘混淆。因为道路边缘是道路和非路的分界线, 所以道路边缘必然满足一侧的颜色接近道路, 而另一侧颜色接近非路这一条件, 这也就是说, 可以首先利用彩色信息初步检测出道路边缘, 然后再利用几何信息来进一步判断, 以得到精确的路边。

1.2 算法结构

图 2 显示了算法的结构框图。




图 2 算法结构框图

1.2.1 彩色信息处理

在这个模块中, 主要利用了象素的彩色信息, 再通过融合不同分类器的结果, 给出每个象素属于道路或非路的信任度。图 3 是本模块的结构。




图 3 彩色信息处理模块结构

图 3 中, 彩色变换分类器是使用如式 (2) 所示的 3 个彩色变换来处理当前图象

$$\begin{cases}
 I_1 = R + G \\
 I_2 = B - R \\
 I_3 = B - G
 \end{cases} \quad (2)$$

其第 1 个彩色变换可以把道路和非路区分得比较清楚, 但是容易把阴影和水迹与非路混淆, 由于阴影处的颜色中蓝分量比较强, 因此通过第 2 和第 3 种彩色变换可以检测出道路上的阴影。水迹相对阴影来说, 颜色变化比较多, 因为它主要是反射周围的环境光, 但在大多数情况下, 还是可以通过第 2 和第 3 种彩色变换检测出来。据此, 在彩色变换分类器中, 首先利用 I_1 直方图阈值来分割得到基本道路区域, 然后利用 I_2 和 I_3 来检测道路阴影和水迹。

前帧相关分类器则是利用和前帧图象的相似性来得到当前图象的分类情况;分类时,首先分别在第 $n-1$ 帧图象最后得到的道路区域和非路区域中,统计各自的彩色直方图(图2中,统计道路/非路直方图模块),并以此作为概率 $P_{n-1}(I|\theta=0)$, $P_{n-1}(I|\theta=1)$ 的估计,再假设前后帧之间,颜色变化很小;然后在第 n 帧,也可以用它作为当前概率的估计,若象素的颜色为 I ,则分类器结果为 θ_0 ,它使得似然概率最大,如式(3)所示。

$$P_n(I|\theta=\theta_0) = \max_{0 \leq i \leq 1} P_n(I|\theta=i) \quad (3)$$

在上述两个分类器完成分类以后,再对所得到的结果做一些适当的后处理,如数学形态学处理和区域跟踪,就可以使得道路区域形状比较规则,然后分别在道路区域和非路区域中,统计彩色直方图。如对于某个颜色特征为 I 的象素,以 θ 作为该象素的类别, $\theta=1$ 表示该象素是道路, $\theta=0$ 表示该象素是非路,如果已知似然向量 $[P(I|\theta=0), P(I|\theta=1)]$, 就可以根据式(1)得到如式(4)所示的嵌入信任函数的基本概率赋值

$$\begin{aligned} m^{(I)}(\{\theta=0, \theta=1\}) &= P(I|\theta=0)P(I|\theta=1)K \\ m^{(I)}(\{\theta=0\}) &= P(I|\theta=0)(1-P(I|\theta=1))K \\ m^{(I)}(\{\theta=1\}) &= P(I|\theta=1)(1-P(I|\theta=0))K \end{aligned} \quad (4)$$

$K=(1-(1-P(I|\theta=0))(1-P(I|\theta=1)))^{-1}$ 并可以得到如式(5)所示的与它对应的信任函数 $B(A|I), A \subset \{\theta=0, \theta=1\}$

$$\begin{aligned} B(\{\theta=0\}|I) &= m^{(I)}(\{\theta=0\}) \\ B(\{\theta=1\}|I) &= m^{(I)}(\{\theta=1\}) \end{aligned} \quad (5)$$

这里,虽然无法得到似然向量的准确值,但是可以通过道路区域和非路区域中的彩色直方图来估计。对于两个分类器首先可以得到两个似然向量估计,以及两个不同的信任函数,然后利用 D-S 公式就可以得到融合后的信任函数。

1.2.2 边缘提取

考虑到道路轮廓大部分都是比较规则的,因此可使用4个方向模板(水平、45°、垂直、135°)来检测边缘,然后搜索边缘,并去除短边缘,即得到候选道路边缘,但由于在检测出的这些边缘中除了道路边缘外,还包含了许多其他边缘,因此需在候选道路边缘提取模块中,对这些边缘属于道路的可能性进行估计,才能提取出道路边缘。

1.2.3 候选道路边缘提取

按照道路边缘在道路区域的位置分为如下4类:左路边、右路边、上路边、下路边。道路边缘的特

点是边缘两侧的区域,其中一侧是属于道路区域,而另一侧属于非路区域,比如左路边,因为是在道路的左侧,所以它的左侧是非路,右侧是道路。又由于道路左右边显然不会是水平边缘,而上下边则一定是水平边缘,因此对于非水平边缘只需要判断它是左路边还是右路边,而水平边缘只需要判断它是上路边还是下路边。对于某条边缘 E ,它两侧的区域分别为 R_1, R_2 ,称为边缘 E 的邻域。这样进行候选道路边缘提取时,首先在每个邻域内,统计所有象素属于道路区域的信任度均值,以及属于非路区域的信任度均值,记为 $m_{\text{road}}(R_i)$ 和 $m_{\text{non-road}}(R_i)$,并记

$$\begin{aligned} \mu(E)_{\text{road}} &= [m_{\text{road}}(R_1) \wedge m_{\text{non-road}}(R_2)] \vee \\ & [m_{\text{road}}(R_2) \wedge m_{\text{non-road}}(R_1)] \end{aligned}$$

为边缘 E 属于道路边缘的隶属度,同时还有下面两条规则。规则1只对非水平边缘有效,规则2只对水平边缘有效。

$$\text{定义:} \begin{cases} \mu(E)_{\text{Left}} = m_{\text{road}}(R_{\text{Left}}) \wedge m_{\text{non-road}}(R_{\text{Right}}) \\ \mu(E)_{\text{Right}} = m_{\text{road}}(R_{\text{Right}}) \wedge m_{\text{non-road}}(R_{\text{Left}}) \\ \mu(E)_{\text{Up}} = m_{\text{road}}(R_{\text{Up}}) \wedge m_{\text{non-road}}(R_{\text{Down}}) \\ \mu(E)_{\text{Down}} = m_{\text{road}}(R_{\text{Down}}) \wedge m_{\text{non-road}}(R_{\text{Up}}) \end{cases}$$

$\mu(E)_{\text{Left}}, \mu(E)_{\text{Right}}, \mu(E)_{\text{Up}}, \mu(E)_{\text{Down}}$ 分别代表边缘 E 属于道路左、右、上、下边的隶属度函数。

规则1 边缘 E 属于道路边缘,若 $\mu(E)_{\text{Left}} \gg \mu(E)_{\text{Right}}$, 则 E 属于左路边;若 $\mu(E)_{\text{Right}} \gg \mu(E)_{\text{Left}}$, 则 E 属于右路边;

规则2 边缘 E 属于道路边缘,若 $\mu(E)_{\text{Up}} \gg \mu(E)_{\text{Down}}$, 则 E 属于上路边;若 $\mu(E)_{\text{Down}} \gg \mu(E)_{\text{Up}}$, 则 E 属于下路边;又定义远大的隶属度函数为

$$\mu_{\text{Great}}(x, y) = \begin{cases} 0, & x \leq y \\ \frac{x-y}{y(a-1)}, & y \leq x \leq ay \\ 1, & x \geq ay \end{cases}$$

其中, $a > 1$, 在实验中 a 取 1.5。

其规则计算如式(6)所示。根据式(6)就可以得到边缘 E 属于上路边、下路边、左路边和右路边的隶属度。

$$\begin{cases} \mu(E)_{\text{Left-Road}} = \mu(E)_{\text{Road}} \wedge \mu_{\text{Great}}(\mu(E)_{\text{Left}}, \mu(E)_{\text{Right}}) \\ \mu(E)_{\text{Right-Road}} = \mu(E)_{\text{Road}} \wedge \mu_{\text{Great}}(\mu(E)_{\text{Right}}, \mu(E)_{\text{Left}}) \\ \mu(E)_{\text{Up-Road}} = \mu(E)_{\text{Road}} \wedge \mu_{\text{Great}}(\mu(E)_{\text{Up}}, \mu(E)_{\text{Down}}) \\ \mu(E)_{\text{Down-Road}} = \mu(E)_{\text{Road}} \wedge \mu_{\text{Great}}(\mu(E)_{\text{Down}}, \mu(E)_{\text{Up}}) \end{cases} \quad (6)$$

候选道路边缘提取模块如图4所示,输入的是4个方向的边缘,首先通过道路边缘检验后来得到每条边缘属于道路边缘的隶属度,然后再根据式(6)




图4

分别计算其属于上下路边或左右路边的隶属度,并根据 4 个隶属度从高到低排序,可以得到 4 个队列,比如得到 E_1, E_2, E_3, E_4, E_5 5 条边,按 4 个隶属度排序就可以得到 5 条边 4 种不同的队列。

1.2.4 道路边缘提取

在候选道路边缘提取中,只利用了边缘附近局部的信息,并没有利用边缘之间相互位置关系。而在本模块中,将利用边缘之间的位置关系,从不连续的各段边缘中提取出连续的道路边缘。首先需要定义如下一些基本概念:

(1) 点到边缘的距离定义为,该点和边缘上所有点的距离的最小值。

(2) 连接关系 $C(E_1, E_2)$ 定义为, E_1, E_2 满足 E_1 的一个端点和 E_2 距离很近,而另一个端点和 E_2 距离很远;

(3) 同侧约束定义为,如果两条道路边缘是连接的,那么道路区域应该位于道路的同侧;

由上述定义可以看到,连接关系是一种模糊关系,因此需要定义如下一个距离远近的隶属度函数:

$$\mu_{Near}(x) = \begin{cases} 1 - x/d, & 0 \leq x \leq d \\ 0, & x > d \end{cases}$$

式中 x 为两点间的欧氏距离, d 为参数,如果距离大于该参数,则认为两点距离很远,即 $\mu_{Near}(\cdot)$ 函数为 0。

由于左右路边的搜索是相似的,因此下文以左路边的搜索为例进行介绍。

寻找左路边可以形式化为:在边缘集合 E 中,搜索边缘序列 $\{e_1, e_2, \dots, e_n\}$,由于该序列中相邻的任意两个边缘都是连接的,并且道路都在边缘的右侧,而且属于道路边缘的隶属度 μ_{Road} 满足

$$\mu_{Road}(\{e_1, e_2, \dots, e_n\}) = \frac{1}{n} \sum_i \mu_{Road}(e_i) > T$$

因此,问题就转化为一个组合问题。由于候选路边的数量并不多,而且实际上能够满足同侧约束的连接也是很少的,因此即使是穷举,也没有很多计算量;然后用同样方法寻找右路边,在得到右路边之后,道路区域就在这两条路边之间;最后在道路区域和非路区域


中分别统计彩色直方图,并在下一帧图象处理时,作为前帧图象的直方图提供给彩色信息处理模块。

1.2.5 总结

当采集到新的一帧图象以后,首先在彩色处理模块中,利用彩色信息进行初步分割,以估计道路和周围环境的彩色特性;然后在边缘提取模块中提取边缘,并在候选道路边缘模块中,根据道路边缘周围的彩色分布特性来得到候选道路边缘。由于这时这些候选边缘中仍然可能包含了一些非道路边缘,而且是不连续的,因此在道路边缘提取模块中,应根据同侧约束,来连接候选道路边缘,这样也就得到了连续的左、右路边,而被左、右路边包含的中间区域就是道路区域。这样左右路边即作为最后的输出结果,交给后面的其他模块(如局部路径规划等)作进一步应用。


2 算法实现和实验结果

由于计算量主要集中在图象的低层处理上,而随着 Intel MMX 技术的出现,使得图象处理的速度大大提高,因此算法得以实时实现。目前输入图象是每 200ms 一帧,实际处理时间为 100ms 左右。通过对装载在实际机器人上的摄像机拍摄得到的道路图象进行测试,基本上都可以得到良好的结果。图 5~图 8 是一些典型的道路图象的检测结果。



(a) 图象 (b) 检测到的道路边界

图 5 有大片阴影时的道路图象检测结果



(c) 图象 (d) 检测到的道路边界

图 6 有大片水迹时的道路图象检测结果




图7 中午时的道路图象检测结果




图8 傍晚侧光光线偏红时的道路图象检测结果

从图5和图6可以看到,用本文方法,即使检测在强烈阴影和水迹下拍摄的道路,仍然可以得到比较好的结果。从图7和图8可以看到,用本文算法检测在强光下和偏光下拍摄的道路也仍然可以得到很好的结果。

3 展 望

未来的工作主要集中在对三维信息的利用,可以通过运动序列图象的处理来恢复场景的三维信息,这样对于道路的识别可以更加精确,也更容易和其他传感器(如激光雷达和超声传感器)获得的图象信息进行融合,最后得到的是道路可行区域,这样可以更加方便局部路径规划。

参 考 文 献

- 1 Charles Thorpe, Martial Herbert, Takeo Kanade *et al.* Toward autonomous driving: The CMU navlab, part I-Perception[R]. In: IEEE Expert[M], August 1991.
- 2 Turk M A, Morgenthaler D G, Gremban K D *et al.* VITS—A vision system for autonomous land vehicle navigation[J]. IEEE Trans. on PAMI, 1988,10(3):342~361.
- 3 Kuan D, Phipps G, Hsuen A C. Autonomous robotic vehicle road following[J]. IEEE Trans. PAMI, 1988,10(5):648~658.
- 4 Kuan D, Sharma U K. Model based geometric reasoning for autonomous road following[J]. IEEE Trans. on Robotics and Au-

- tomation, 1987,4(1):416~423.
- 5 Crisman J D, Thorpe C E. SCARF: A color vision system that tracks road and intersections[J]. IEEE Trans. on Robotics and Automation, 1993,9(1):49~58.
- 6 Maurer VaMoRs-P M. An advanced platform for visual autonomous road vehicle guidance[J]. SPIE Mobile Robots, 1994, 2352:239~248.
- 7 Alberto Broggi. Parallel and local feature extraction: A real-time approach to road boundary detection[J]. IEEE Trans. on Image Processing, 1995,4(2):217~223.
- 8 Spiegle, Part McIngvale, Keith Olson *et al.* Autonomous road navigation for unmanned ground vehicles[J]. SPIE Mobile Robots X, 1995,2463:206~216.
- 9 John Gilmore F, Harold Forbes, Kevin Payne *et al.* The unmanned guided vehicle system [J]. SPIE Mobile Robots X, 1995,2463:217~225.
- 10 Vittorio Murino, Carlo S Regazzoni, Gian Luca Foresti *et al.* A multilevel fusion approach to object identification in outdoor road science[J]. International Journal of Pattern Recognition and Artificial Intelligence, 1995,9(1):23~65.
- 11 Fan C F, Li Z M, Ye X Q *et al.* An adaptive method of color road segmentation[A]. In: Proceedings of CAIP'97[C], Kiel, Germany, 1997.
- 12 范成法,叶秀清,顾伟康. KRUS: 一个基于知识的道路图象理解系统[J]. 计算机研究与发展, 1999,36(9):36~40.
- 13 张尧庭,杜劲松. 人工智能中的概率统计方法[M]. 北京: 科学出版社, 2000.

吴东晖 1973年生,1996年获浙江大学信电系学士学位,现为浙江大学信电系博士研究生,目前研究方向为计算机视觉、自主陆地车辆(ALV)、模式识别。

叶秀清 现为浙江大学信息与通讯研究所教授,研究方向为计算机视觉、图象处理。

顾伟康 浙江大学信息与通讯研究所教授,博士生导师,研究方向为计算机视觉、图象处理、模式识别、智能机器人。