

混合种群多样性自适应遗传操作的 HMM 训练模型

王相海^{1,2,3} 丛志环¹ 方玲玲¹ 宋传鸣^{1,3}

¹(辽宁师范大学计算机与信息技术学院 辽宁大连 116029)
²(智能计算与信息处理教育部重点实验室(湘潭大学) 湖南湘潭 411105)
³(计算机软件新技术国家重点实验室(南京大学) 南京 210093)
(xhwang@lnnu.edu.cn)

HMM Training Model Using Blending Population Diversity Based Aaptive Genetic Algorithm Title

Wang Xianghai^{1,2,3}, Cong Zhihuan¹, Fang Lingling¹, and Song Chuanming^{1,3}

¹(College of Computer and Information Technology, Liaoning Normal University, Dalian, Liaoning 116029)
²(Key Laboratory of Intelligent Computing & Information Processing (Xiangtan University), Ministry of Education, Xiangtan, Hunan 411105)
³(State Key Laboratory for Novel Software Technology (Nanjing University), Nanjing 210093)

Abstract With the parameters sensibility problem of HMM model trained by GA method, this paper firstly introduces BPD-AGA algorithm based on blending population diversity. In order to make genetic iteration process enlarge the genetic searching space and improve quality of optimal solution, this algorithm adjusts the genetic parameters adaptively by individual genotype and phenotype which determine the population diversity. Secondly, HMM training model based on BPD-AGA has been proposed. This model selects the largest contribution to blending population diversity as the competition champion by BPD-AGA adaptive selection; On the other hand, HMM global optimal solution can be guaranteed by using BPD-AGA adaptive crossover and mutation, and enlarging the genetic searching space to protect the competition champion. Thirdly, this paper mixes Baum-Welch algorithm and BPD-AGA to increase the BPD-AGA training convergence speed, eventually produces a hybrid BPD-AGA/Baum-Welch model that can improve GA from external and internal. Fourthly, the process of the above model and training algorithm applied in traffic video vehicle driving status recognition has been presented. Experiment results prove the effectiveness of the proposed model and training algorithm.

Key words blending population diversity; adaptive genetic algorithm; HMM training model; vehicle driving status; real-time recognition

摘 要 针对传统 GA 方法训练 HMM 模型所存在的对遗传控制参数具有较强的敏感性的问题:1)提出一种以混合遗传种群多样性为原则的 BPD-AGA 算法,该算法依据决定种群多样性的基因型和表现型来自适应地调整遗传参数,使整个遗传迭代过程能够在扩大遗传搜索空间的同时提高最优解的质量;2)提出了一种基于 BPD-AGA 的 HMM 训练模型,该模型一方面利用 BPD-AGA 的自适应选择操作,选择对混合种群多样性贡献最大的个体作为竞争优胜者;另一方面利用 BPD-AGA 的自适应交叉变异

操作,在扩大算法搜索空间的同时保护对混合种群多样性贡献较大的个体,从而保证了 HMM 解个体的全局最优性;3)为了提高 BPD-AGA 训练的收敛速度,利用 Baum-Welch 算法从外部对 BPD-AGA 的收敛性进行了改善,提出了一个从外部和内部同时改善 GA 性能的 BPD-AGA/Baum-Welch 混合模型;4)给出了将所提出的模型和算法应用在交通视频车辆行驶状态判别中的实现过程.仿真实验验证了所提出模型和算法的有效性.

关键词 混合遗传种群多样性;自适应遗传算法;HMM 训练模型;车辆行驶状态;实时判别

中图法分类号 TP391

最大期望(EM)算法是针对不完整数据集确定相应参数的极大似然估计(ML)统计方法,极大似然估计算法属于一种局部搜索算法,主要通过爬山算法来寻找最优解.近年来,基于 Baum-Welch 算法的隐马尔可夫模型(HMM)成为交通车辆行驶状态判别的主要模型之一^[1-2],而 Baum-Welch 算法作为 EM 算法的一种具体实现形式同样也通过局部搜索来实现,对初值较敏感,且容易陷入局部极值而得不到整体的最优解.遗传算法(GA)是通过在给定的解空间中进行全局搜索来获得全局最优解^[3].利用 GA 的遗传过程进行 HMM 参数训练与 Baum-Welch 算法相比,能够扩大解个体的搜索空间而使迭代过程跳出局部范围.但 GA 在进化后期由于交叉变异操作引起的大范围随机搜索可能会导致其收敛速度和局部搜索能力的降低.因此可以考虑利用 Baum-Welch 算法快速收敛的局部搜索性能来改善 GA 的大范围搜索性能,即在 GA 的遗传操作中融合 Baum-Welch 算法构成 GA/Baum-Welch 混合算法.目前利用 GA/Baum-Welch 混合算法来改进基于 Baum-Welch 算法或 GA 算法的 HMM 模型训练已在很多领域得到应用,比如文献[4-5]将 GA/Baum-Welch 混合算法应用到语音识别系统中,文献[6-7]分别将其应用到手写字体识别和文本信息抽取中,均可以在得到全局最优解个体和收敛速度上有很大提高. GA/Baum-Welch 混合算法是 GA 和 Baum-Welch 算法以外部组合的形式互补各自的缺点,使其具有优于单一算法的最优解求解性能和更快的收敛速度.但是在利用 Baum-Welch 算法从外部改善 GA 算法的同时,GA 自身内部存在的缺点对混合算法整体性能的影响仍然不可忽略,其中 GA 的各项遗传控制参数是决定其能否准确快速收敛于全局最优解的关键因素,从而也势必影响到 GA/Baum-Welch 混合算法的求解性能.

针对 GA 的遗传控制参数敏感问题,本文首先对自适应遗传算法(AGA)遗传控制参数自适应变化的相关性进行了研究,提出由表现型与基因型共

同表示的混合种群多样性(BPD)概念,在此基础上提出了以混合种群多样性为度量原则的自适应遗传算法(BPD-AGA),并给出了基于 BPD-AGA 的 HMM 训练模型;进一步,为了提高 BPD-AGA 训练的收敛速度,利用 Baum-Welch 算法从外部对 BPD-AGA 的收敛性进行了改善,形成了从外部和内部同时改善 GA 性能的 BPD-AGA/Baum-Welch 混合模型,并将其应用于交通车辆行驶状态的判别.仿真实验验证了利用所提出的 BPD-AGA/Baum-Welch 混合模型进行 HMM 参数训练的有效性,同时也表明此混合模型更加适用于对实时性和准确性要求较高的智能交通车辆行驶状态的判别.

1 AGA 遗传控制参数变化相关性分析

GA 初始群体规模、选择、交叉和变异控制参数的存在及其遗传操作过程总体上决定了遗传算法优于 Baum-Welch 算法的全局搜索性能.但这些遗传控制参数容易导致 GA 提早收敛于局部最优解,比如交叉变异概率过大,就会破坏已经产生的最优解,容易使算法陷入随机搜索,导致算法的收敛速度慢;而概率过小,则容易造成算法的过早收敛,最终产生局部最优解.所以在选择参数时既要控制 GA 的随机搜索,又要防止 GA 的早熟收敛.另外,采用固定的控制参数还会降低 GA 的鲁棒性,应用中通常需要人工修改参数才能取得好的效果.为了克服传统 GA 的缺点,文献[8-10]提出了改进的 AGA 算法.算法验证了多种自适应调整 GA 控制参数的方法,通过变化种群的规模,变化选择策略、交叉策略和变异策略等来改进参数固定的 GA,相应的算法在获得全局解和收敛速度方面均获得了一定程度的提高.

AGA 参数自适应变化的目的是在提高算法收敛速度的同时使获得的结果更接近于全局最优.但目前为止所研究的 AGA 参数自适应变化算法的一般原理均为通过对高适应度个体采用低交叉变异率以增加对高适应度个体的保护来保留最优解,而对

低适应度个体采用高交叉变异率以改变低适应度个体的染色体结构来增加种群的多样性,并且在选择策略的改进方面,也只是注重对选择方法自身的改进.所以目前方法中 AGA 参数自适应变化过程只是 AGA 选择、交叉、变异操作之间进行独立地自适应变化,忽略了它们三者所存在的内在相关性.实际上 GA 的选择、交叉、变异操作之间是既相互促进又相互矛盾的.交叉和变异操作增加了种群中个体的多样性,使种群中有机会出现更优的个体.与此同时选择操作使优秀个体有机会遗传到下一代,三者共同协作保证了 GA 在解空间的有效搜索.但随着 GA 遗传代数的增加,选择算法总是趋向于从不断收敛的种群中将结构相似的优秀个体选择至下一代,而在这种状态下交叉变异操作都是在结构相似个体之间进行的,这就导致选择操作降低了种群多样性,而交叉变异操作的作用也很难有效地增加种群的多样性,最终仍然会导致局部最优解的出现,因此选择策略与交叉变异之间又是一个相互制约的矛盾过程.可见,GA 的选择、交叉、变异操作之间是存在内在相关性的,并且这种相关性主要通过种群多样性得以体现,即选择、交叉、变异三者以矛盾统一关系共同影响着种群的多样性.基于此,本文将从选择、交叉和变异这 3 个遗传操作之间存在的内在联系出发,采用种群多样性的标准统一衡量它们的自适应变化.

2 混合种群多样性及自适应遗传操作

2.1 混合种群多样性

种群多样性作为一个关键因素在很大程度上影响着遗传算法的全局收敛性,这样在遗传操作的自适应变化中需要对其给予足够的重视.事实上,种群多样性可以从宏观和微观来度量:宏观上是种群中个体间的差异程度,称为表现型多样性,用个体的适应度来表示;微观上是种群个体基因位之间的差异程度,称为基因型多样性,用个体染色体的基因结构来表示.由于遗传过程中的每一项操作都与维持种群多样性有着重要的关联,即它们通过种群的多样性相互联系,因此为了在遗传进化过程中维持种群多样性,须采用多样性度量标准来衡量遗传过程中每一项操作的自适应变化程度.在目前描述自适应遗传操作的方法中,大多对选择、交叉和变异操作的自适应改进只是独立地从单方面的表现型间接考虑种群的多样性来获取全局最优解个体.然而事实上,基因型和表现型所表示的种群多样性对全局最优解

个体的获取是缺一不可的,具体表现在:若单独考虑基因型,虽然能从个体基因结构的角度增加种群的多样性,扩大遗传搜索范围,但却忽略了考虑解个体的质量,因为遗传的最终目的是要选择出适应度最优的个体,这样容易降低遗传过程的收敛速度;若仅从表现型考虑种群多样性,虽然能够提高收敛速度,但容易导致遗传过程过早收敛于局部.这样,若在衡量种群多样性的同时考虑基因型和表现型,即在用基因型多样性扩大遗传搜索空间的同时通过表现型多样性来保证解个体的质量,则可提高 GA 快速获取全局最优解个体的可能性.

本文基因型在微观上由种群个体各位基因的离散程度表示,离散程度越高,种群的基因型多样性越大;表现型在宏观上由个体的适应度值占群体中所有个体的适应度值之和的比例表示,个体之间比例值的差值程度越高,则种群的表现型多样性越大.本文把由基因型和表现型共同表示的种群多样性称为混合种群多样性 (blending population diversity, BPD).混合种群多样性的定义如下:

假设种群规模为 R ,种群中每个个体包含 N 位基因,其中个体 i 表示为 $G_i = (G_{i,1}, G_{i,2}, G_{i,3}, \dots, G_{i,N}), i = 1, 2, \dots, R$.

1) 计算个体适应度值,利用 HMM 前向概率 $P(O|\lambda)$ 作为衡量个体适应度的标准.由于前向概率值非常小,超出了计算机可以表示的精度,我们采用前向概率 $P(O|\lambda)$ 的对数来替代原值,适应度值的目标函数如式(1):

$$f_k = \sum_{q=1}^L \lg P(O_q | \lambda_k) / L, k = 1, 2, \dots, R, \quad (1)$$

其中, f_k 是种群中第 k 个 HMM 模型 λ_k 的适应度值, O_q 是 HMM 观察值序列, $O_q \in \{O_1, O_2, \dots, O_q, \dots, O_L\}$, L 是观察值序列的个数, $P(O_q | \lambda_k)$ 可由 HMM 前向算法得到.

2) 计算个体 i 的表现型大小,即个体 i 的适应度值占种群所有个体适应度值总和的比例:

$$\omega_i = f_i / \sum_{k=1}^R f_k, i = 1, 2, \dots, R. \quad (2)$$

3) 计算种群所有个体第 n 位等位基因的平均值:

$$G_n^{av, GWF} = \sum_{i=1}^R G_{i,n} / R, n = 1, 2, \dots, N. \quad (3)$$

4) 计算个体 i 基因型大小:

$$Dg_i = \sqrt{\sum_{n=1}^N (G_{i,n} - G_n^{av, GWF})^2 / N}, i = 1, 2, \dots, R, \quad (4)$$

即个体 i 基因型的大小是个体 i 的每位基因与相应基因位平均值的平均离散程度。

5) 以相应个体表现型作为权值, 用均方差计算种群中所有个体第 n 位等位基因的离散程度:

$$\sigma(G_n^{\omega, ave}) = \sqrt{\sum_{i=1}^R [\omega_i (G_{i,n} - G_n^{\omega, ave})]^2 / R}, \quad n = 1, 2, \dots, R. \quad (5)$$

6) 计算当前混合种群多样性:

$$D = \sum_{n=1}^N \sigma(G_n^{\omega, ave}) / N, \quad (6)$$

混合种群多样性是种群中所有个体 N 个等位基因离散程度之和。

2.2 基于混合种群多样性的自适应遗传操作

本节给出了以混合种群多样性为度量原则的 GA 各项遗传控制参数的自适应变化算法, 简记为 BPD-AGA。

2.2.1 自适应锦标赛选择操作

锦标赛选择算法的竞争规模大小是影响下一代种群多样性的重要因素, 因此本文通过使锦标赛选择算法的竞争规模随混合种群多样性自适应地变化来实现自适应锦标赛选择算法。基于混合种群多样性的自适应锦标赛选择法应满足当混合种群多样性低(收敛)时降低竞争规模, 以便为远离收敛中心的边缘个体提供继续生存的机会; 当混合种群多样性高(发散)时增加竞争规模, 以排除边缘个体促进种群收敛。这样根据混合种群多样性的变化自适应调整竞争规模, 在维持了混合种群多样性的同时提高了种群收敛速度。竞争规模随混合种群多样性变化的过程见式(7)。

$$Tsize = \left\lfloor \frac{D \times Tsize_{\max}}{B_D_{\max}} \right\rfloor, \quad i = 1, 2, \dots, R, \quad (7)$$

其中, $B_D_{\max}$ 是根据实验得到的混合种群多样性的最大值, $Tsize_{\max}$ 是自定义的竞争规模的最大值。当前混合种群的多样性程度由当前混合种群多样性 D 与混合种群最大多样性 $B_D_{\max}$ 的差值来衡量, D 与 $B_D_{\max}$ 相差越小, 说明混合种群多样性越高, 此时种群规模 $Tsize$ 的值越大; D 与 $B_D_{\max}$ 相差越大, 说明混合种群多样性越低, 此时种群规模 $Tsize$ 的值越小, 满足了竞争规模 $Tsize$ 随混合种群的多样性自适应变化。

在确定竞争规模后, 在个体选择上为了避免根据个体表现型大小进行逐代选择造成的种群中个体基因结构相似的现象, 本文自行设计式(8)来计算个体 i 对混合种群多样性的贡献, 并选择对混合种群多样性贡献最大的个体作为竞争优势者。

$$D_i^{P_n} = \omega_i Dg_i, \quad i = 1, 2, \dots, R. \quad (8)$$

式(8)把个体 i 的表现型作为基因型的权值, 其中 ω_i 可通过式(2)计算, Dg_i 可通过式(4)计算, 并由变量 P_n 记录当前遗传代数, D^{P_n} 表示第 P_n 代时个体 i 对混合种群多样性的贡献。

式(8)说明竞争优势者个体在种群中必须满足基因型多样性或表现型多样性均较大, 或者二者同时相对较大的特点。若个体的基因型多样性大, 则个体可为 GA 扩大搜索空间做贡献; 若个体的表现型多样性大, 则个体可为得到 GA 的最优解个体做贡献; 若二者同时相对较大, 则个体在表现出较高表现型的同时其基因结构也扩大了搜索空间。因此根据个体对种群多样性的贡献进行个体选择能够使自适应选择既保证解个体的质量又扩大搜索空间, 维持种群的混合多样性。这种自适应选择算法为 GA 获得全局最优解个体提供了较大可能性。

2.2.2 自适应交叉操作和变异操作

交叉变异操作的自适应变化仍然依据维持混合种群的多样性原则来定义。两个个体进行交叉操作时, 若对混合种群多样性贡献较大的个体接近混合种群多样性贡献的最大值, 则应降低两个个体交叉操作的概率, 以维持种群的多样性; 若与混合种群多样性贡献的最大值相差较大, 应激励两个个体进行交叉操作, 以增加混合种群的多样性。据此设计如下交叉参数的自适应变化方式:

$$P_c = \frac{D^{\max} - \max(D_i^{P_n}, D_j^{P_n})}{D^{\max} - D^{\min}}, \quad i, j = 1, 2, \dots, R, \quad (9)$$

其中, $D_i^{P_n}$ 和 $D_j^{P_n}$ 是通过自适应锦标赛算法选择得到的个体 i 和 j 对混合种群多样性的贡献, $D^{\max}$ 是个体对混合种群多样性贡献的最大值, $D^{\min}$ 是个体对混合种群多样性贡献的最小值。容易看出, 式(9)满足当两交叉个体对混合种群多样性的贡献的较大者接近 $D^{\max}$ 时 P_c 变小, 而与 $D^{\max}$ 值相差较大时, P_c 变大。

个体变异操作时需要满足当个体 i 对混合种群多样性的贡献接近混合种群多样性贡献的最大值时, 降低对个体 i 变异的概率, 以维持混合种群的多样性, 否则提高对个体 i 变异的概率。据此设计如下个体变异参数的自适应变化方式:

$$P_m^i = \frac{D^{\max} - D_i^{P_n}}{D^{\max}}, \quad i = 1, 2, \dots, R, \quad (10)$$


其中, 满足当个体 i 对混合种群多样性的贡献接近 $D^{\max}$ 时, P_m^i 值变小, 以维持混合种群的多样性, 而当个体 i 对种群多样性的贡献与 $D^{\max}$ 值相差较大时, P_m^i 值变大。

3 基于 BPD-AGA 的 HMM 参数训练模型


3.1 遗传染色体编码

为了通过 AGA-BPD 训练 HMM 参数, 将 BPD-AGA 群体中的每个 HMM 模型编码成 BPD-


AGA 可操作的染色体形式. 由于 HMM 模型由初始状态概率矩阵 $\boldsymbol{PI}$ 、状态转移概率矩阵 $\boldsymbol{A}$ 和观察值概率矩阵 $\boldsymbol{B}$ 3 个实数参数矩阵表示, 将这 3 个矩阵按图 1 所示分别转换为对应的初始状态矩阵染色体、状态转移矩阵染色体和观察值矩阵染色体的一维数组 $\boldsymbol{CPI}$ 、 $\boldsymbol{CA}$ 和 $\boldsymbol{CB}$.



(a) The conversion of $\boldsymbol{PI}$ and $\boldsymbol{CPI}$



(b) The conversion of $\boldsymbol{A}$ and $\boldsymbol{CA}$



(b) The conversion of $\boldsymbol{B}$ and $\boldsymbol{CB}$

Fig. 1 HMM individual chromosome encoding.

图 1 HMM 个体染色体编码

CPI, CA 和 CB 以式(11)构成 HMM 染色体, 其中 N 是 HMM 的状态个数, M 是 HMM 观察值的个数. 这样就把 HMM 模型编码成了相应参数的基因串, 每个基因位对应原矩阵中概率值.

$$\begin{cases} C_{PI}^k(P_1^k, P_2^k, \dots, P_N^k), \\ C_A^k(a_{11}^k, a_{12}^k, \dots, a_{1N}^k, a_{21}^k, a_{22}^k, \dots, a_{2N}^k, \dots, a_{N1}^k, \\ \quad a_{N2}^k, \dots, a_{NN}^k), \\ C_B^k(b_{11}^k, b_{12}^k, \dots, b_{1M}^k, b_{21}^k, b_{22}^k, \dots, b_{2M}^k, \dots, b_{N1}^k, \\ \quad b_{N2}^k, \dots, b_{NM}^k), \end{cases} \quad (11)$$

$k=1, 2, \dots, R.$

3.2 HMM 参数训练过程

本文用于 BPD-AGA 操作的初代种群是通过随机初始化得到的 R 个 HMM 模型, 把 R 个 HMM 模型根据 3.1 节方法分别转换成相应的 HMM 染色体, 形成规模为 P 的 HMM 染色体个体种群. 参数训练的总体过程参见图 2 所示.

具体过程如下:

Step1. 根据式(6)~(8), 分别计算当前种群多样性, 选择操作的竞争规模和每个个体对种群多样性的贡献.

Step2. 选择操作. 根据自适应锦标赛选择算法, 选择出对种群多样性贡献最大的个体作为竞争优胜者, 直到选择出 R 个个体时, 结束选择操作. 通过自适应选择操作, 得到含有 R 个优秀个体的中间种群.

Step3. 交叉操作. 对于交叉参数 P_c (参见式(9)), 采取如下交叉原则: 使个体 i 与 j 的对应染色体相交叉, 即 C_{PI}^i 与 C_{PI}^j 交叉, C_A^i 与 C_A^j 交叉, C_B^i 与 C_B^j 交叉. 交叉时生成 $0 \sim 1$ 之间的随机概率 C_r , 若 $C_r \leq P_c$, 则生成一点交叉位, 对交叉位后的基因进行互换交叉运算; 若 $C_r > P_c$, 不对这两个个体做交叉运算, 直到中间群体中所有个体都被选择. 图 3 以个体 i 和 j 的状态转移矩阵染色体 C_A 为例, 在交叉位 $P_a=3$ 处产生互换交叉运算.




Fig. 2 Flow chart of BPD-AGA training.
图 2 BPD-AGA 训练 HMM 参数过程

Individual i	$a_{11}^{(1)}$	$a_{12}^{(1)}$	$a_{13}^{(1)}$	$a_{14}^{(1)}$	...	$a_{1N}^{(1)}$	$a_{21}^{(1)}$	...	$a_{2N}^{(1)}$	...	$a_{N1}^{(1)}$	...	$a_{NN}^{(1)}$
Individual j	$a_{11}^{(2)}$	$a_{12}^{(2)}$	$a_{13}^{(2)}$	$a_{14}^{(2)}$	...	$a_{1N}^{(2)}$	$a_{21}^{(2)}$	...	$a_{2N}^{(2)}$	...	$a_{N1}^{(2)}$	...	$a_{NN}^{(2)}$

(a) Intersection P_a is in the 3rd chromosome of the parent transition matrix

Individual i	$a_{11}^{(1)}$	$a_{12}^{(1)}$	$a_{13}^{(1)}$	$a_{14}^{(2)}$	...	$a_{1N}^{(2)}$	$a_{21}^{(2)}$	...	$a_{2N}^{(2)}$	...	$a_{N1}^{(2)}$	...	$a_{NN}^{(2)}$
Individual j	$a_{11}^{(2)}$	$a_{12}^{(2)}$	$a_{13}^{(2)}$	$a_{14}^{(1)}$	...	$a_{1N}^{(1)}$	$a_{21}^{(1)}$	...	$a_{2N}^{(1)}$	...	$a_{N1}^{(1)}$	...	$a_{NN}^{(1)}$

(b) Offspring individuals obtained after intersection

Fig. 3 Adaptive crossover operation.
图 3 自适应交叉操作

Step4. 变异操作. 对于种群中的个体 i , 已知其变异参数为 P_m^i , 变异时生成一个 $0 \sim 1$ 之间的随机概率 M_m^i . 若 $M_m^i \leq P_m^i$, 则在个体 i 的初始状态染色体、状态转移染色体和观察值染色体的基因串上随机选择一个基因位, 把该基因位作为变异位, 在该基因位处以一个随机数代替原值; 若 $M_m^i > P_m^i$, 则不对个体 i 进行变异操作.

Step5. 对经过 Step1~Step4 形成的新一代种群中的 P 个 HMM 个体进行参数修正. 由于 HMM 参数染色体的交叉变异操作会导致 HMM 参数局部状态的改变, 破坏了 HMM 的参数约束条件^[11], 需要对种群中每个个体的 HMM 参数进行“规正”, 使其符合 HMM 模型的参数约束条件:

1) CPI 染色体的规正

种群中个体规正后的 CPI 染色体每一位的基因值是该位基因与个体 CPI 染色体的所有基因位之和的比值:

$$\overline{PI}_n^k = PI_n^k / \sum_{i=1}^N PI_i^k, k = 1, 2, \dots, R. \quad (11)$$

2) CA 染色体的规正

规正后的 CA 染色体每一位的基因值是该位基因与相应状态 i 的 N 个基因位之和的比值:

$$\bar{a}_{ij}^k = a_{ij}^k / \sum_{n=1}^N a_n^k; k = 1, 2, \dots, R; i = 1, 2, \dots, N. \quad (12)$$

3) CB 染色体的规正

规正后的 CB 染色体每一位的基因值是该位基因与相应状态 i 的 M 个基因位之和的比值:

$$\bar{b}_{ij}^k = b_{ij}^k / \sum_{m=1}^M b_m^k; k = 1, 2, \dots, R; i = 1, 2, \dots, N. \quad (13)$$

Step6. 将规正后的种群作为新一代种群, 若遗传迭代结束, 选出当前种群中对混合种群多样性贡献最大的个体, 作为最优解个体; 否则返回 Step1 执行 Step1~Step6.

上述基于 BPD-AGA 的 HMM 参数估计中, 一方面利用 BPD-AGA 的自适应选择操作, 根据种群多样性调整竞争规模, 并选择对混合种群多样性贡献最大的个体作为竞争优胜者, 为 HMM 解个体的全局性和最优性提供了可能性; 另一方面利用 BPD-AGA 的自适应交叉变异操作, 在扩大算法搜索空间的同时保护对种群多样性贡献大的个体, 则在自适应选择操作的基础上又进一步维持了 HMM 解个体的全局最优性.

3.3 HMM 参数训练过程的进一步优化

BPD-AGA 的自适应操作过程通过种群多样性扩大了 HMM 最优解个体的搜索范围, 但同时维持种群的多样性也在一定程度上降低了 BPD-AGA 算法的收敛速度. 为了进一步提高算法的收敛速度, 可将 Baum-Welch 算法的局部寻优能力与 BPD-AGA 的大范围搜索能力相结合来训练 HMM 参数, 在获得全局最优解的情况下, 可很大程度提高算法的收敛速度. 具体过程包括:

1) 在图 2 所示的对 HMM 参数进行训练的过程中, 每得到 n 代群体, 就对群体中每个个体进行 t_1 次 Baum-Welch 算法迭代, 以加快 BPD-AGA 算法的收敛速度;

2) 对经过 BPD-AGA 算法得到的每一代群体, 都对群体中的个体进行 t_2 次 Baum-Welch 算法迭代, 以弥补 BPD-AGA 进化过程中子代个体未能得到优化的不足, 从而使 BPD-AGA 算法在加快收敛速度的同时提高群体中个体的质量.

4 新模型在车辆行驶状态判别中的应用

4.1 HMM 轨迹模式训练

交通规则约束下的每个道路路段所允许的车辆行驶状态模式数是确定的. 本文根据当前视频场景中交通规则所允许的车辆行驶状态进行轨迹模式类划分, 并为每一个轨迹模式类进行基于所提出模型的 HMM 参数训练. 训练集由车辆按照交通场景所允许的轨迹模式行驶形成的实际轨迹段构成, 若无车辆按照某一轨迹模式类行驶, 则采用虚拟轨迹构成训练集.

具体的轨迹模式类训练过程如下:

Step1. 根据观察轨迹模式 c_1 是属于直行模式还是转向模式来确定 HMM 个体的状态数 N .

Step2. 对于特定交通场景下的轨迹模式类 c_1 , 为其初始化规模为 R 的用于 BPD-AGA 算法操作的初代种群. 初代种群由 P 个通过随机初始化得到的 HMM 个体 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 组成. P_n 记录种群的遗传代数, 初始 $P_n = 1$ 代表初代种群.

Step3. 根据式(8)计算个体 $\lambda_k^{P_n}$ ($k = 1, 2, \dots, R$) 对当前代种群多样性的贡献.

Step4. 把种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 中第 k 个个体 $\lambda_k^{P_n}$ 的参数 $\mathbf{PI}^k$, $\mathbf{A}^k$ 和 $\mathbf{B}^k$ 按照 3.1 节所示方式进行编码转换成如式(11)所示的染色体 C_{PI}^k , C_A^k 和 C_B^k ($k = 1, 2, \dots, R$) 的形式.

Step5. 根据式(6)(7)分别计算当前种群多样性,

选择操作的竞争规模。

Step6. 进行自适应锦标赛选择操作, 选择出 P 个 HMM 优秀个体作为竞争优胜者。

Step7. 在 P 个 HMM 个体中, 随机选择两个个体 λ_i 和 λ_j ($i, j=1, 2, \dots, R$), 根据式(9)计算其交叉参数 P_c , 并使 λ_i 和 λ_j 的 C_{PI}^i 与 C_{PI}^j , C_A^i 与 C_A^j 和 C_B^i 与 C_B^j 染色体分别进行交叉操作(参见图 3), 直到种群中所有 HMM 个体都被选择一次。

Step8. 对于个体 $\lambda_k^{P_n}$, 对其 C_{PI}^k , C_A^k 和 C_B^k ($k=1, 2, \dots, R$) 分别进行变异操作(参见 3.2 节 Step4)。

Step9. 经过 Step5 ~ Step8 形成新种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$, 并对其中 R 个 HMM 个体按照式(11)~(13)进行参数修正, 得到修正后的种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 。

Step10. 将种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 中个体 $\lambda_k^{P_n}$ 的染色体 C_{PI}^k , C_A^k 和 C_B^k ($k=1, 2, \dots, R$) 还原成 HMM 参数 $\mathbf{PI}^k$, $\mathbf{A}^k$ 和 $\mathbf{B}^k$ 的矩阵形式, 用于在下一代的遗传操作时计算个体对种群多样性的贡献值。并根据基于 Baum-Welch 算法的车辆轨迹模式训练过程^[12]对 $\lambda_k^{P_n}$ ($k=1, 2, \dots, R$) 进行 t_2 次迭代训练, 迭代后生成新的种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 。

Step11. 遗传代数 P_n 加 1。如果 P_n 是 n 的倍数, 则对种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 中的个体 $\lambda_R^{P_n}$ 进行 t_1 次迭代训练, 迭代后生成新的种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 作为新一代的种群, 并记为 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$; 否则把种群 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 记为 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 。

Step12. 记录 $(\lambda_1^{P_n}, \lambda_2^{P_n}, \dots, \lambda_k^{P_n}, \dots, \lambda_R^{P_n})$ 中对种群多样性贡献最大的 HMM 个体 $\lambda_k^{P_n}$ 及其对种群多样性的贡献值 $D_k^{P_n}$, $k=1, 2, \dots, R$ 。

Step13. 比较 $D_k^{P_n-1}$ 与 $D_k^{P_n}$ 的值, 若 $|D_k^{P_n-1} - D_k^{P_n}| \geq \delta$, 则返回 Step3; 否则结束对轨迹模式类 c_1 的训练, 把个体 $\lambda_k^{P_n}$ 作为 c_1 的最优 HMM 模型记为 λ_{c_1} , 并转向 Step1 训练该场景中下一个轨迹模式类。当训练得到所有轨迹模式类的最优 HMM 模型 $(\lambda_{c_1}, \lambda_{c_2}, \dots)$ 后, 训练结束。

4.2 车辆行驶状态实时判别

测试集由车辆的实时行驶轨迹段构成, 即对进入视频的 vehicle, 每行驶一段就获取该段的轨迹点序列作为待测试轨迹段。对其进行实时预处理和方向区域编码形成观察值序列, 最后与经由 4.1 节训练得到的该交通场景下所有轨迹模式类的最优 HMM 模型进行匹配完成对该车辆行驶状态的判别^[12]。

具体判别过程如下:

Step1. 初始化。用 G_s 记录当前车辆的所有采

样点数, T_s 记录当前待识别轨迹段的采样点数, 初始化 $T_s = G_s = 0$;

Step2. 采集轨迹点。累计当前视频中特定车辆的轨迹采样点数 T_s 和 G_s , 如果 T_s 满足观察值序列的个数 T , 则对当前 G_s 个点做最小二乘拟合处理, 否则继续采集轨迹点。

Step3. 生成观察值序列。以第 $G_s - T_s + 1$ 采样点作为起始点, 提取拟合轨迹方程上的 T_s 个点 $\{(x_{G_s-T_s+1}, f(x_{G_s-T_s+1})), (x_{G_s-T_s+2}, f(x_{G_s-T_s+2})), \dots, (x_{G_s}, f(x_{G_s}))\}$, 对这 T_s 个点计算方向角并编码, 形成该待识别轨迹段的观察值序列 $V = \{V_1, V_2, \dots, V_{T_s}\}$ 。

Step4. 根据式(1)计算该观察值序列 $V = \{V_1, V_2, \dots, V_{T_s}\}$ 与训练好的所有模式类的最优 HMM 模型 $(\lambda_{c_1}, \lambda_{c_2}, \dots)$ 的适应度值 $P(V|\lambda_i)$, $i=c_1, c_2, \dots$ 。

Step5. 寻找适应度值最大的 $P(V|\lambda_i)$, 并将 λ_i 的下标索引 i 所代表的轨迹模式类作为该段轨迹所属的模式类别, 至此完成对该车辆当前行驶状态的一次判别。

Step6. 若 T_s 未满足 T 时, 当前车辆已行驶出视频区域, 则结束对该车辆的判别工作。否则轨迹段累计点数 T_s 清零, 返回 Step2, 继续该车辆的下一次行驶状态判别。

5 实验结果与分析

5.1 实验结果

为了验证所提出模型在车辆行驶状态实时判别中的有效性, 我们对大连市内 3 个路口的交通视频车辆行驶场景(参见图 4)进行了仿真实验, 其中视频的大小为 320×240 像素, 帧率为 15 fps, 编码 XVID。实验中每隔 30 帧做一次质心坐标点采样, 利用基于 mean-shift 的卡尔曼粒子滤波车辆跟踪算法^[13]来确定车辆在不同帧的质心坐标点。实验中分别采用 BPD-AGA/Baum-Welch, BAP-AGA, GA/Baum-Welch 和 Baum-Welch 算法训练 HMM 轨迹模式参数, 并通过算法迭代终止时得到的最优 HMM 解个体的全局适应度、算法训练的平均收敛速度以及车辆行驶状态的实时判别正确率 3 个指标来评价所提出模型在车辆行驶状态实时判别应用中的有效性。

在轨迹模式的训练中, GA 的交叉概率 $p_c = 0.6$ 、变异概率 $p_m = 0.05$; BPD-AGA 和 GA 的种群规模 $P = 10$, 二者的混合方式与 Baum-Welch 算法相同, 将其中的参数 n, t_1 和 t_2 均取值为 10, 3 和 8;




Fig. 4 Traffic video scene.

图 4 交通视频场景

$Tsize_{max}$ 取值大小与种群规模 P 相同,并根据 BPD 的数值计算特点将 $D^{max}=0.001, D^{min}=-1$. HMM 状态数 N 和观察值个数 M 的设定参见文献[11],直行的轨迹模式 HMM 状态数为 1,转向的轨迹模式为 4,观察值个数 $M=8$. 在车辆行驶状态判别中,观察值序列长度 $T=25$.

此外,在评价指标中最优 HMM 个体的全局适应度计算通过式(1)获得;对于一个特定的轨迹模式类,车辆行驶状态的判别正确率是指被准确识别为该类的轨迹点序列数与所有属于该类的轨迹点序列数的比值,正确率 μ 的计算公式为: $\mu=T_a/(T_a+T_b)$,

其中 T_a 是所有被识别为该类并且实际也确实属于该类的轨迹点序列数, T_b 是被识别为该类但实际并不属于该类的轨迹点序列数;收敛速度是对于特定交通场景下的某一模式类,在相同的迭代终止条件下各个算法迭代结束时所迭代的次数. 平均收敛速度是特定场景下所有模式类训练迭代次数的平均值.

1) 场景 1 仿真实验

场景 1(图 4(a))中 4 个箭头方向表示此路口按照交通规则所允许的 P1~P4 四种轨迹模式类. 用于训练 P1~P4 四种轨迹模式类的训练集分别由 20 个车辆实际运行的轨迹构成. 表 1 是对比结果.

Table 1 The Comparison of Four Algorithms for Traffic Scene 1

表 1 4 种算法对交通场景 1 的对比结果

Track Mode	BPD-AGA/Baum-Welch			BPD-AGA		
	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%
P1	-2.533	8	98.5	-2.533	9	98.5
P2	-3.726	9	99	-4.067	12	97.38
P3	-1.336	2	76.8	-1.336	4	76.8
P4	-2.086	2	100	-2.086	8	100
Mean Iteration Times		5			8	

Track Mode	GA/Baum-Welch			Baum-Welch		
	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%
P1	-2.808	7	98.2	-11.73	14	96.5
P2	-4.085	7	97	-4.099	9	97
P3	-1.341	7	75.9	-1.349	7	75.9
P4	-2.086	7	100	-2.086	9	100
Mean Iteration Times		7			10	

2)场景 2 仿真实验

场景 2(图 4(b))中 C1,C2 模式训练集包括 20 条轨迹,C3 模式训练集包括 10 条轨迹,C4 模式训练集和测试集均包括 20 条虚拟轨迹. 表 2 是基于 4 种算法的对比结果.

3) 场景 3 仿真实验

场景 3(图 4(c))中 S1,S2 模式训练集包括 20 条轨迹,S3 模式训练集包括 10 条轨迹,S4~S6 模式训练集和测试集均包括 20 条虚拟轨迹. 表 3 给出了基于 4 种算法的对比结果.

Table 2 The Comparison of Four Algorithms for Traffic Scene 2
表 2 4 种算法对交通场景 2 的对比结果

Track Mode	BPD-AGA/Baum-Welch			BPD-AGA		
	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%
C1	-3.844	6	98	-3.848	6	97.8
C2	-4.244	8	98.3	-4.174	26	98
C3	-2.488	4	77.3	-2.485	5	77.3
C4	-4.114	8	80.6	-4.117	37	80.6
Mean Iteration Times	7			19		

Track Mode	GA/Baum-Welch			Baum-Welch		
	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%
C1	-3.851	7	97.8	-3.863	16	97.8
C2	-4.310	7	97.8	-4.322	10	97.8
C3	-2.504	7	76.4	-2.511	11	76.4
C4	-4.198	7	80	-4.285	55	80
Mean Iteration Times	7			23		

Table 3 The Comparison of Four Algorithms for Traffic Scene 3
表 3 4 种算法对交通场景 3 的对比结果

Track Mode	BPD-AGA/Baum-Welch			BPD-AGA		
	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%
S1	-3.203	5	100	-3.386	6	100
S2	-1.334	2	100	-1.339	3	100
S3	-3.022	12	100	-3.039	48	100
S4	-3.785	4	99.6	-4.032	18	98.3
S5	-1.986	5	97	-1.998	4	96.1
S6	-4.543	6	98.5	-4.547	14	98.5
Mean Iteration Times	6			16		

Table 3 (Continued)

Track Mode	BPD-AGA/Baum-Welch			BPD-AGA		
	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%	Individual Fitness of HMM Optimal Solutions	Iteration Times of Same Termination Conditions	Discrimin-ation Correct Rate of Vehicle Steering Status/%
S1	-3.392	7	100	-3.410	13	100
S2	-1.340	7	100	-1.340	6	100
S3	-3.239	7	100	-3.239	38	100
S4	-4.351	7	98	-10.69	9	96.8
S5	-2.038	7	96.1	-2.109	6	96
S6	-4.652	7	98	-4.671	33	98
Mean Iteration Times		7			18	

5.2 分 析

从表 1~3 的实验结果可以看出：

1) BPD-AGA/Baum-Welch 算法与 BPD-AGA 相比较,在平均收敛速度上有了显著提高,这是由于本文利用 Baum-Welch 算法的快速局部收敛性从外部改善了 BPD-AGA 的全局大范围搜索,以此提高了算法的平均收敛速度.

2) BPD-AGA/Baum-Welch 算法与 GA/Baum-Welch 算法相比,在平均收敛速度方面高于后者或与其持平,在最优 HMM 个体适应度和轨迹判别正确率方面高于后者,说明了本文提出的 BPD-AGA 算法改善传统参数固定的 GA 方法训练 HMM 参数的有效性.

3) BPD-AGA 与 GA/Baum-Welch 算法相比,虽然在平均收敛速度方面不如后者,但在最优 HMM 个体适应度和轨迹判别正确率方面却有所提高,这是由于 BPD-AGA 方法很好地改善了传统 GA 对控制参数的敏感问题,至于 GA/Baum-Welch 算法速度的提高也体现了 Baum-Welch 算法对于改善 GA 收敛速度的有效性.

4) BPD-AGA 算法与 Baum-Welch 算法相比,能够获得更优的 HMM 解个体,同时具有更快的平均收敛速度和更高的判别正确率,其原因是 Baum-Welch 爬山式的迭代方式会导致其训练结果收敛于局部最优,而 BPD-AGA 算法的遗传控制参数的自适应变化方式可以使遗传迭代不断地扩大进化搜索范围,并在扩大范围搜索的同时注意保持优秀的种群个体,使整个遗传过程兼顾了搜索的全局性和解个体的质量,从而保证了最优解个体的全局性和收敛速度. 同样 BPD-AGA/Baum-Welch 算法自然也

能够得到比 Baum-Welch 算法更优的 HMM 个体,更高的平均收敛速度和判别正确率.

综上,本文提出的以混合种群多样性为度量原则的自适应遗传算法(BPD-AGA),以及基于该算法的混合优化算法 BPD-AGA/Baum-Welch 能很好地满足快速收敛于全局最优 HMM 解个体的要求,更适合应用于同时对实时性和准确性要求较高的智能交通车辆行驶状态实时判别中.

6 结 论

本文从 Baum-Welch 算法存在的缺点以及应用传统 GA 算法训练 HMM 存在的控制参数敏感问题的角度出发,提出了一种遗传操作之间以种群多样性来相互联系的自适应遗传 BPD-AGA 算法,算法根据个体的基因型和表现型对种群多样性的贡献自适应调整遗传操作,使整个遗传过程通过维持种群的多样性达到全局搜索并提高 HMM 个体质量的目的;此外,BPD-AGA 算法从内部改善了传统 GA 对控制参数的敏感性,使得基于该算法的 HMM 参数训练可以获得优于 Baum-Welch 算法的 HMM 解个体. 进一步,针对 BPD-AGA 的遗传过程由于始终保持种群多样性会不同程度地影响收敛速度的问题,本文提出了 BPD-AGA/Baum-Welch 混合算法,该算法利用 Baum-Welch 算法的快速局部收敛性,从外部提高了整体算法的收敛速度. 车辆行驶状态实时判别的仿真实验,验证了所提出模型和算法的有效性.

致谢 感谢大连市西岗区交通大队在实验交通视频图像方面所给予的帮助!

参 考 文 献

[1] Jiang Y S. An HMM based approach for video action recognition using motion trajectories [C] //Proc of IEEE ICICIP'10. Piscataway, NJ: IEEE, 2010: 359-364

[2] Hao J Y, Hao S, Li C, et al. Vehicle behavior understanding based on movement string [C] //Proc of IEEE ITSC'09. Piscataway, NJ: IEEE, 2009: 243-248

[3] Lin Jianning, Wu Huizhong. Scheduling in grid computing environment based on genetic algorithm [J]. Journal of Computer Research and Development, 2004, 41(12): 2195-2199 (in Chinese)
(林剑柠, 吴慧中. 基于遗传算法的网格资源调度算法[J]. 计算机研究与发展, 2004, 41(12): 2195-2199)

[4] Mosleh M, Setayeshi S, Kheyrandish M. Accelerating speech recognition algorithm with synerqic hidden Markov model and genetic algorithm based on cellular automata [C] //Proc of IEEE ICSPS'09. Piscataway, NJ: IEEE 2009: 3-7

[5] Oudelha M, Ainon R N. HMM parameters estimation using hybrid Baum-Welch genetic algorithm [C] //Proc of IEEE ITSIm'10, vol 2. Piscataway, NJ: IEEE, 2010: 542-545

[6] Bhowmik T K, Parui S K, Roy U. Discriminative HMM training with GA for handwritten word recognition [C] //Proc of IEEE ICPR'08. Piscataway, NJ: IEEE, 2008: 1-4

[7] Li R, Zheng J H, Pei C Q. Text information extraction based on genetic algorithm and hidden Markov model [C] //Proc of IEEE ETCS'09, vol 1. Piscataway, NJ: IEEE, 2009: 334-338

[8] Sun Z Y, Guan Z L, Wang Q. An improved adaptive genetic algorithm for vehicle routing problem [C] //Proc of IEEE LSIM'10, vol 1. Piscataway, NJ: IEEE, 2010: 116-120

[9] Zhang L, Zhang B F, Yu J F. Improvement of adaptive genetic algorithm and its application in examination timetabling optimization problem [C] //Proc of IEEE CSSS'11. Piscataway, NJ: IEEE, 2011: 1326-1329

[10] Li Xin. Improved adaptive genetic algorithm and its application research [D]. Nanjing: Nanjing University of Information Science and Technology, 2008 (in Chinese)
(李欣. 自适应遗传算法的改进与应用研究[D]. 南京: 南京信息工程大学, 2008)


[11] Kwong S, Chan C, Man K, et al. Optimisation of HMM topology and its model parameters by genetic algorithms [J]. Pattern Recognition, 2001, 34(2): 509-522

[12] Wang Xianghai, Cong Zhihuan, Fang Lingling. Research on realtime vehicle driving status determination using HMM [J]. Acta Automatica Sinica, 2012, 38(1): 139-144 (in Chinese)
(王相海, 丛志环, 方玲玲. 基于 HMM 的车辆行驶状态实时判别方法研究[J]. 自动化学报, 2012, 38(1): 139-144)

[13] Wang Xianghai, Fang Lingling, Cong Zhihuan. Research on video vehicle tracking algorithm based on kalman and particle filter [J]. Journal of Image and Graphics, 2010, 15(11): 1616-1622 (in Chinese)
(王相海, 方玲玲, 丛志环. 卡尔曼粒子滤波的视频车辆跟踪算法研究[J]. 中国图像图形学报, 2010, 15(11): 1616-1622)




Wang Xianghai, born in 1965. PhD. Professor of the College of Computer and Information Technology of Liaoning Normal University. Senior member of China Computer Federation. His research interests include computer graphics and multimedia information processing.



Chong Zhihuan, born in 1987. Master in computer applied technology from Liaoning Normal University. Her research interests include intelligent traffic images processing (czhwork@163.com).



Fang Lingling, born in 1985. Received her PhD at the School of Computer Science and Technology, Soochow University. Her research interests include image and video retrieval and mining (fanglingling1985@163.com).



Song Chuanming, born in 1980. Lecturer of the College of Computer and Information Technology of Liaoning Normal University. Received his PhD at the Department of Computer Science & Technology of Nanjing University. Member of China Computer Federation. His main research interests include image and video coding, and digital watermarking of multimedia (chmsong@163.com).