

# 基于自适应蚁群优化算法的认知决策引擎

罗云月<sup>1</sup> 孙志峰<sup>2</sup>

(武汉理工大学国际教育学院 武汉 430070)<sup>1</sup> (华中科技大学光电子科学与工程学院 武汉 430074)<sup>2</sup>

**摘要** 认知决策引擎的设计是认知无线电系统中的一项关键技术,它的主要功能是依据通信环境的变化和用户需求动态地配置无线电工作参数。提出了一种基于自适应蚁群优化算法的认知决策引擎来实现工作参数的最优化配置。该算法在基本蚁群算法的基础上加入了路径选择机制和信息素挥发因子自适应调整机制,保证了算法的全局搜索能力和收敛速度,有效地避免了容易陷入局部最优解的缺陷。仿真结果表明,在不同的环境下基于该算法的认知引擎比 GA 和 ACO 算法具有更好的性能。

**关键词** 认知引擎,蚁群优化算法,自适应策略

中图分类号 TN929.5 文献标识码 A

## Cognitive Radio Decision Engine Based on Adaptive Ant Colony Optimization

LUO Yun-yue<sup>1</sup> SUN Zhi-feng<sup>2</sup>

(The School of International Education, Wuhan University of Technology, Wuhan 430070, China)<sup>1</sup>

(College of Optoelectronic Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)<sup>2</sup>

**Abstract** Cognitive decision engine is a key technology in cognitive communication system. Cognitive engine can dynamically configure its working parameters according to the changes of communication environment and users' requirement. An adaptive ant colony optimization (AACO) cognitive radio engine was proposed to achieve the optimal configuration working parameters. The novel algorithm based on the basic ant colony algorithm improves the path selection mechanism and adaptively adjusting pheromone decay parameter mechanism. Therefore, it can ensure the global search ability and convergence speed, and effectively avoid falling into local optimization result. Simulation results show that the AACO engine has better performance than GA and ACO engines in different scenarios.

**Keywords** Cognitive engine, Ant colony optimization (ACO), Adaptive strategy

## 1 引言

为了缓解频谱资源匮乏, Mitola 提出了认知无线电(Cognitive Radio, CR)的概念<sup>[1]</sup>, CR 通过周期性感知周围环境中频谱的工作状态,伺机占用空闲频谱,并根据环境变化和用户需求自适应调整传输参数,从而实现智能通信。认知无线电的智能主要来自于认知引擎(Cognitive Engine, CE),它的主要作用是根据环境的变化,对多目标参数例如发射功率、调制方式、帧长度、带宽、载波频率等通信参数进行优化,以提高通信效率。美国弗吉尼亚工学院无线电通讯技术中心(CWT)提出了一种基于遗传算法的认知引擎模型<sup>[2,3]</sup>,利用遗传算法对多个传输参数进行编码和种群优化,从而获得基于多约束条件的波形参数配置策略。遗传算法虽然利用其多维度并行计算能力可以得到可行解,但在实际应用中,认知引擎需要对多个认知用户配置传输参数,随着认知用户数的增加,遗传算法的染色体长度会线性增加,这将导致优化复杂度增大,而且遗传算法存在收敛速度慢、早熟等问题,导致优化的效率比较低,不能很好地适应复杂多变的认知环境。

蚁群优化(Ant Colony Optimization, ACO)算法是由意大利学者 M. Dorig 等<sup>[4]</sup>通过模拟自然界蚂蚁集体协作寻找食物的行为而提出的一种新的启发式算法,它已经在组合优化问题中得到广泛的应用<sup>[5]</sup>。文献<sup>[6]</sup>中提出了一种基于改进的蚁群优化算法的认知决策引擎,其性能优于基本的遗传算法,但是仍然存在早熟收敛和难以确定算法参数等问题。本文提出了一种基于自适应蚁群优化(Adaptive Ant Colony Optimization, AACO)算法的认知引擎,通过改良路径选择机制和信息素挥发因子自适应调整机制,保证了算法的全局搜索能力,加速了种群的收敛速度,有效地避免了陷入局部解。仿真结果表明,与遗传算法和基本蚁群算法相比,本文提出的算法具有较好的优化性能,更好地满足了认知无线电决策引擎对多目标优化决策的需要。

## 2 认知无线电决策引擎

设认知无线电需要调整的  $n$  个参数为  $a = [a_1, a_2, \dots, a_n]$ , 具体参数可以是发射功率、调制方式、中心频率、符号速率等。由于受各种制度、物理环境、硬件条件等各方面的

到稿日期:2010-09-06 返修日期:2010-11-30 本文受华中科技大学博士后基金资助。

罗云月(1990-),女,主要研究方向为通信工程、数字信号处理,E-mail:lillianyunyue@163.com;孙志峰(1980-),男,博士,主要研究方向为光传感、信号处理。

限制,认知无线电参数通常要满足一定的约束条件。为适应当前外部条件,认知无线电需要对某些目标函数进行优化,以满足环境要求或用户需求。设认知无线电需要优化的目标函数为  $f=[f_1, f_2, \dots, f_m]$ , 其中  $m$  为目标函数个数。目标函数的选择要求能反映当前链路质量,如平均发射功率、数据速率、误码率、带宽、频带效率、数据包延时等均可作为目标函数。不同链路条件、不同用户需求等导致不同目标函数的重要性不尽相同,本文用  $w=[w_1, w_2, \dots, w_m]$  表示各个目标函数的权重,  $w_i (1 \leq i \leq m)$  数值大小反映目标函数  $f_i (1 \leq i \leq m)$  的重要性程度。为使求解问题简单化,将目标函数分别进行归一化,并将多目标函数转化为如下单目标函数:

$$f = \sum_{i=1}^m w_i f_i \quad (1)$$

其中,权重需要满足  $w_i \geq 0 (1 \leq i \leq m)$ , 且

$$\sum_{i=1}^m w_i = 1$$

认知无线电决策引擎要完成的任务就是如何选择无线电参数实现式(1)所示目标函数的最大化。

Newman 在文献[7]中给出了多载波传输器的认知引擎应用,定义了3个目标函数:最小化发射功率函数、最小化误码率函数与最大化数据速率,其归一化形式如下:

$$f_{\min \text{ power}} = 1 - \bar{P}/P_{\max} \quad (2)$$

$$f_{\min \text{ ber}} = 1 - \frac{\log_{10} 0.5}{\log_{10} \bar{P}_{be}} \quad (3)$$

$$f_{\max \text{ data rate}} = \frac{\frac{1}{N} \sum_{i=1}^N \log_2 M_i - \log_2 M_{\min}}{\log_2 M_{\max} - \log_2 M_{\min}} \quad (4)$$

式中,  $\bar{P}$  为所有载波发射功率的平均值,  $P_{\max}$  为最大发射功率,  $\bar{P}_{be}$  为平均误码率,  $N$  为子载波数(子信道数),  $M_{\min}$  为最小调制进制数,  $M_{\max}$  为最大调制进制数,  $M_i$  为子载波  $i$  的调制进制数。同时,文献[7]还给出了3种通信模式(低功耗、应急通信、多媒体)下相对应的目标函数权重,如表1所列。本文的仿真分析即基于 Newman 提出目标函数和权重对多子载波参数进行调整。

表1 权重设置

权重	模式1(低功耗)	模式2(应急通信)	模式3(多媒体)
$w_1$	0.80	0.15	0.05
$w_2$	0.15	0.80	0.15
$w_3$	0.05	0.05	0.80

### 3 基于自适应蚁群优化算法的 CE

#### 3.1 问题描述

在本文中由于存储空间限制,可调参数仅选择发射功率和调制方式。假设子载波数目为32,每个子载波发射功率范围是0~25.2dBm,间隔0.4dBm,共有64种可能取值;调制方式包括BPSK、QPSK、16QAM和64QAM共4种可能取值。因此该认知引擎系统总的搜索空间为 $2^{256}$ 。认知无线电参数优化问题可以看成是经典的旅行商问题(TSP),可以用蚁群算法来解决。问题中总共有64个城市需要遍历(其中前32个是32个子载波的发射功率,另外32个是32个子载波的调制方式),蚂蚁群体从第一个城市走到第64个城市,前32个城市每个城市有64种值可以选择,后32个城市每个有4种值可供选择。因此,这个TSP问题要解决的就是找出一条遍历了这64个城市的路径,实现式(1)所示的目标函数最

大化。

#### 3.2 自适应的蚁群优化(AACO)算法

设蚁群中蚂蚁的数目为  $M$ ,城市总数为  $K$ ,  $\tau_{kj}(t)$  表示  $t$  时刻第  $k$  个城市的第  $j$  个取值(路径  $(k, j)$ ) 上信息素的浓度,初始时刻每条路径上的信息素浓度相同,  $\tau_0 = C$  ( $C$  为常数)。蚂蚁  $m (m=1, 2, \dots, M)$  在运动的过程中根据各个城市的每个取值上面信息素的浓度来决定转移方向,  $p_{kj}^m(t)$  表示  $t$  时刻蚂蚁  $m$  在第  $k$  个城市上选择路径  $(k, j)$  的概率。其计算公式为:

$$p_{kj}^m(t) = \frac{\tau_{kj}(t)}{\sum_{i \in S_k} \tau_{ki}(t)} \quad (5)$$

式中,  $S_k$  表示第  $k$  个城市的所有可能的值的集合,  $k=1, 2, \dots, K, j \in S_k$ 。

为了克服蚁群算法容易陷入局部最优解的缺点,对蚁群优化算法的选路规则进行一定的调整,加入了一定程度的随机探索操作,这样既保证空间的全局搜索,又有效地克服了收敛速度慢和易于陷入局部最优解的缺陷。该算法采用伪随机比率选择规则进行选路,对于在第  $k$  个城市上的蚂蚁按照式(6)选择路径  $(k, j)$ :

$$s = \begin{cases} \arg \max \{ |\tau_{kj}(t)|, j \in S_k \}, & q \leq q_0 \\ S, & \text{otherwise} \end{cases} \quad (6)$$

式中,  $S$  是根据式(5)的概率分布选出的一个随机变量。  $q$  是一个在  $[0, 1]$  区间均匀分布的随机数,  $q_0$  是一个随着迭代次数增加而逐渐增大的动态参数,它的大小决定了利用先验知识和探索新路径之间的相对重要性。当位于第  $k$  个城市上的蚂蚁选择路径时,它选取一个随机数  $q$ , 如果  $q \leq q_0$ , 根据先验知识选择城市  $k$  上信息素浓度最高的取值(路径), 否则就按照式(5)的概率选择一个取值。其中  $q_0$  的计算公式如下:

$$q_0 = E + (t \times F) / Nc \quad (7)$$

式中,  $t$  为当前求解的代数,  $E, F$  为固定参数,一般取  $E=0.2, F=0.7$ 。  $Nc$  为算法的迭代次数,因此  $q_0$  得取值范围是:  $[E, E+F]$ 。这样随着迭代次数自适应地调整  $q_0$ , 消除了它对算法的影响。在开始阶段  $q_0$  小,有利于算法展开对新路径的探索,避免过早陷入局部最优,在结束阶段  $q_0$  大,有利于算法的全局收敛。  $q_0$  的变化范围越大,算法的搜索范围越大。

随着时间的推移,留在各条路径上的信息素将逐渐消失,蚂蚁走完所有的城市,完成一次循环之后,需要对路径上的信息量进行更新。信息量的调整公式如下:

$$\tau_{kj}(t+1) = (1-\rho) \cdot \tau_{kj}(t) + \Delta\tau_{kj} \quad (8)$$

$$\Delta\tau_{kj} = \begin{cases} (C_n + Q)/r, & (k, j) \in S_{\text{best}} \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

式中,  $\rho$  表示信息素挥发因子,  $\Delta\tau_{kj}$  表示蚁群在本次循环中留在路径  $(k, j)$  上的信息量。  $S_{\text{best}}$  表示当前全局的最优遍历路径,  $C_n$  表示最优路径下对应的目标函数值,  $Q$  是一个正常数,用以保证  $C_n + Q \geq 0$ ,  $r$  是一个常数,用来调整  $\Delta\tau_{kj}$  的大小。

信息素的挥发因子  $\rho$  的大小直接关系到蚁群算法的全局搜索能力及其收敛速度。固定的  $\rho$  值存在难以确定的缺点,本文采用自适应的策略来调整  $\rho$  值。其调整公式如下:

$$\rho(t+1) = \begin{cases} \xi \cdot \rho(t), & \xi \cdot \rho(t) \geq \rho_{\min} \\ \rho_{\min}, & \text{otherwise} \end{cases} \quad (10)$$

式中,  $\xi \in (0, 1)$  为挥发因子调节系数,  $\rho_{\min}$  为  $\rho$  的最小值,以防止  $\rho$  过小而降低算法的收敛速度。在算法初期设置一个较大

的初始值  $\rho_0$ , 路径搜索倾向于当前的较优路径, 后期通过不断地减少  $\rho$  值, 来扩大算法的搜索空间, 避免过度集中在某些较优的路径上。

### 3.3 基于 AACO 算法的 CE

在本文中, 上述的 AACO 算法被应用到认知决策引擎中。其算法流程描述如下:

1) 初始化各个参数, 包括迭代次数  $N_c$ , 城市的数目  $K$ , 蚂蚁的数目  $M$ , 信息素挥发因子初始值  $\rho_0$  及最小值  $\rho_{\min}$ , 初始的信息素  $\tau_0$ , 挥发因子调节系数  $\xi$ , 以及信息量增量  $\Delta\tau_{kj}$  的参数  $Q, r$ , 时间  $t=1$ 。

2) 蚂蚁根据式(5), 式(6)选择下一个路径, 直至遍历所有的城市, 当  $M$  只蚂蚁全部完成本次循环, 共产生  $M$  条遍历路径。

3) 根据式(1)计算  $M$  条遍历路径的目标函数值, 通过比较得到本次循环的最优路径和最大目标函数值。若  $t=1$ , 则将最优路径保存到  $S_{rbest}$ , 对应的最大的目标函数值为  $C_n$ 。若  $t \geq 2$ , 则将本次循环的最大目标函数值与  $C_n$  进行比较, 若大于  $C_n$ , 则更新  $C_n$  以及对应的  $S_{rbest}$ , 否则  $C_n, S_{rbest}$  不变。

4) 根据式(8), 式(9)更新路径上的信息素。

5) 如果  $t < N_c$ , 则令  $t=t+1$ , 跳转到 2); 否则执行 6)。

6) 输出当前的全局最优解, 退出。

### 4 仿真分析

本文对基于 GA, ACO, AACO 算法的认知引擎的性能进行了仿真分析。本文采用的多子载波系统具有 32 个子载波, 因此本文的 TSP 问题有 64 个城市需要访问。每个子载波的发射功率范围设置为  $0 \sim 25.2$  dBm, 间隔  $0.4$  dBm, 调制方式包括 BPSK, QPSK, 16QAM 和 64QAM 4 种。对于 GA, ACO, AACO 算法的迭代次数为 1000。GA 算法种群代数数为 100, ACO 和 AACO 算法中蚂蚁的数目也为 100。

在基于 AACO 的认知引擎中, 信息素挥发因子初始值  $\rho_0$  设为  $0.9$ , 挥发因子调节系数  $\xi$  设为  $0.98$ ,  $\rho_{\min}$  设为  $0.5$ 。初始信息素  $\tau_0$  设为  $0.5$ , 令  $Q$  等于  $1$ ,  $r$  等于  $2$ 。基于 ACO 的认知引擎中参数的设置如下: 信息素挥发因子  $\rho$  设为  $0.8$ , 初始信息素  $\tau_0$  设为  $0.5$ 。基于 GA 的认知引擎的参数设置如下: 每个染色体采用二进制编码, 信道类型为 AWGN 信道, 噪声功率为  $0$  dBm, 通过给每个子载波分配一个  $0 \sim 1$  之间的随机数, 模拟信道衰落因子, 采用锦标赛选择, 两点交叉和基本位变异, 交叉率为  $0.8$ , 变异率为  $0.1$ 。

本文的目标函数采用 Newman 提出的 3 个目标函数, 权重的设置采用表 1 所示的 3 种模式。为了比较 GA, ACO, AACO 算法的认知引擎的优化性能, 分别对 3 种算法在 3 种模式下面进行了 10 次独立的实验, 挑选出每一次迭代中具有最大适应度的个体(路径), 计算器目标函数值, 再对 10 次试验结果取平均, 所得的平均目标函数值随着迭代次数的变化如图 1 所示。从图可以看出 AACO 算法在进化过程中优化得到的平均目标函数值明显大于其他优化算法, ACO 算法在初期收敛速度很快, 但是平均目标函数值比较小, 在算法的后期其性能差于 GA 算法。基于 AACO 的认知引擎在迭代次数为 300 时, 其平均目标函数值已经大于  $0.9$ , 明显高于基本的 ACO 算法, 这表明 AACO 算法搜索效率高, 收敛能力强, 同时有效地克服了 ACO 算法易于陷入局部最优解的缺点。在

进化后期, AACO 算法的目标函数值达到了  $0.95$ , 远高于 GA 算法, 这表明基于 AACO 算法的认知引擎在寻优后期具有更好的爬山能力。

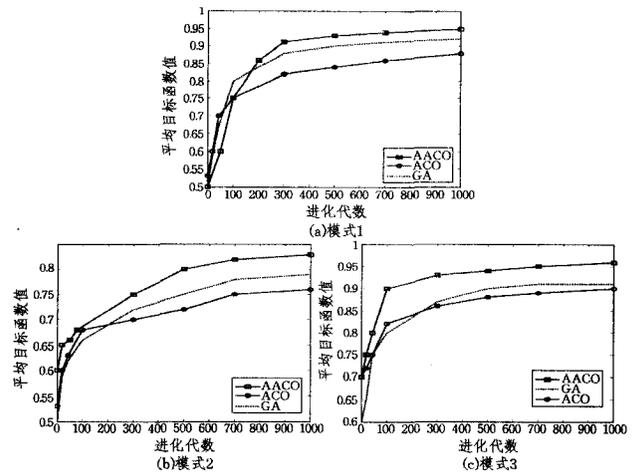


图 1 AACO 与 GA, ACO 性能比较

图 2 描述了在 3 种模式下, 基于 AACO 算法的认知引擎的参数优化结果。在图 2(a)中, 各个子载波的平均发射功率为  $5.1$  dBm, 说明 AACO 算法实现对最小发射功率目标函数的优化。在图 2(b)中平均的发射功率为  $9.2$  dBm, 调制方式基本上为 BPSK, 从而实现了低比特误码率, 同时兼顾了最小发射功率的要求。在图 2(c)中有 19 个子载波采用 64QAM 的调制方式, 实现了数据速率的最大化。

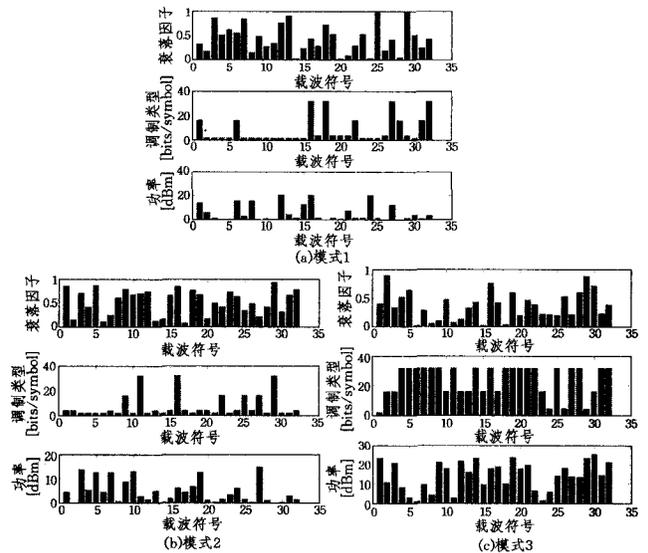


图 2 基于 AACO 算法的认知引擎参数调整结果

**结束语** 本文提出了一种基于自适应蚁群优化(AACO)算法的认知引擎, 在基本的蚁群算法中, 加入了路径选择机制和信息素挥发因子自适应调整机制, 既保证了算法的全局搜索和收敛速度, 又有效地克服了 ACO 算法参数难以确定和易于陷入局部最优解的缺陷。通过仿真表明, 基于 AACO 算法的认知决策引擎性能优于 ACO 和 GA。

### 参考文献

[1] Mitola J. Cognitive radio for flexible mobile multimedia communications[C]//Diego S C A. Proceedings of the Sixth IEEE International Workshop on Mobile Multimedia Communications.

[2] Rieser C J. Biologically Inspired Cognitive Radio Engine Model Utilizing Distributed Genetic Algorithms for Secure and Robust Wireless Communications and Networking [D]. Blacksburg, Virginia; Dept of Electrical Engineering in Virginia Tech, 2004

[3] Zhang X Q, Huang Y Q, et al. Design of cognitive radio node engine based on genetic algorithm[C]// WASE. ICIE'09, IEEE, Taiyuan, China, 2009; 22-25

[4] Dorigo M, Birattari M, Stützle T. Ant colony optimization [J]. IEEE Computational Intelligence Magazine, 2006, 1(4): 28-39

[5] 史恒亮, 白光一等. 基于蚁群优化算法的云数据库动态路径规划[J]. 计算机科学, 2010, 37(5): 143-145, 213

[6] Zhao N, Li S Y Z L. Cognitive Radio Engine Design Based on Ant Colony Optimization [J]. Wireless Personal Communications, 2011, 1(10): 1-10

[7] Newman T R, B A B, Wyglinski A M. Cognitive engine implementation for wireless multicarrier transceivers [J]. Wireless Communications Mobile Computing, 2007, 7(9): 1129-1142

[8] 王越, 许全文, 黄丽丰. 基于改进遗传算法的连续函数优化[J]. 重庆理工大学学报: 自然科学版, 2011, 25(2): 62-67

(上接第 213 页)

该数据库的重要特征。同理, 对于 Berlin 数据库, 在最终选择出的 10 组特征集中, 出现 5 次以上的特征被认为是该数据库的重要特征。这样就得到了两组针对不同数据库选择的特征集合。为了找到一组鲁棒性强的特征集, 将这两组重要特征取交集, 得到的特征子集包含 9 种特征。EMR 数据库和 Berlin 数据库各自重要的特征, 以及取交集后得到的稳定特征集, 如表 2 所列。

表 2 两个数据库的特征选择结果及它们的交集

数据库	特征种类
两数据库 共同特征	基音频率: 最小值、R <sub>3</sub> 能量: 均值 第二共振峰: 均值、中值 第三共振峰: 中值、最大值、R <sub>2</sub> 第四共振峰: R <sub>2</sub>
Berlin 数据库特征	基音频率: 标准差、最小值、变化范围、R <sub>3</sub> 、一阶差分标准差 能量: 均值、一阶差分中值 第一共振峰: R <sub>2</sub> 第二共振峰: 均值、中值、最大值 第三共振峰: 最大值、中值、最小值、R <sub>2</sub> 第四共振峰: R <sub>2</sub> 、变化范围
EMR 数据库特征	基频: 最小值、R <sub>3</sub> 能量: 均值、变化范围、R <sub>1</sub> 、R <sub>2</sub> 、R <sub>3</sub> 、最大正斜率、正斜率标准差、负斜率标准差、正斜率所占比率 第一共振峰: 中值、最大值 第二共振峰: 最大值、均值、中值、变化范围 第三共振峰: 最大值、中值、变化范围、R <sub>2</sub> 第四共振峰: 变化范围、R <sub>2</sub> 、R <sub>3</sub> 信噪比: 均值

### 3.5 特征子集的贡献

针对以上两个数据库, 分别提取上节中取交集得到的这 9 维情感特征, 以 SVM 为分类器, 分别作 8 交叉验证和 10 交叉验证, 平均识别结果如表 3 所列。相比较 85 维特征全部使用所得识别率, 可以看到这 9 维情感特征对识别率确实起了很大作用。

表 3 9 维情感特征与 85 维情感特征识别率比较

	9 维	85 维
EMR 数据库	57.58%	69.23%
Berlin 情感语音数据库	47.39%	69.39%

### 3.6 9 维情感特征的鲁棒性检验

本文在 CESD 数据库上, 选用 BP 神经网络 (BP-ANN)、高斯混合模型 (GMM) 和 SVM 3 种不同的分类器, 进行了男女性别的交叉实验, 实验结果如表 4 所列。从实验结果中看到, 利用 PCA 方法选择出的 9 维情感语音特征, 对于不同识别器识别性能差异不大, 这说明 9 维情感特征对识别器

是稳定的, 而且与 85 维特征全部使用后的识别结果相当, 说明了利用 PCA 进行特征选择的方法是可行的。

表 4 9 维特征选用不同分类器的识别结果比较

训练	测试	PCA 特征选择算法			无特征选择
		BP-ANN	GMM	SVM	SVM
女	男	66.73%	67.79%	67.50%	67.70%
男	女	65.06%	63.53%	63.99%	66.49%

**结束语** 本文利用 PCA 方法对语音情感识别的声学特征进行选择。实验结果表明, 最终选择出来的特征子集对识别精度具有较大的贡献, 证明该特征选择方法是有效的、可行的。多个数据库上的交叉实验表明本文利用的基于 PCA 的特征选择方法选择出的特征集对不同人、不同分类器具具备鲁棒性。另一方面, 本文所提取的 85 维全局统计特征与迄今发现的情感特征总数相比并不十分全面, 所涉及到的情感种类也比较有限。因此, 今后的研究工作将在更大的特征集、更多的情感种类、更多的语音种类上来研究本方案的有效性。

### 参考文献

[1] Clavel C, Vasilescu I, Devillers L, et al. Fear-type emotion recognition for future audio-based surveillance systems [J]. Speech Communication, 2008, 50: 487-503

[2] Anagnostopoulos C N. Feature selection in acted speech for the creation of an emotion recognition personalization service [C]// Third International Workshop on Semantic Media Adaptation and Personalization, 2008: 116-121

[3] 扈浩. 汉语语音情感识别研究 [D]. 北京: 清华大学, 2007

[4] 毛勇. 基于支持向量机的特征选择方法的研究与应用 [D]. 杭州: 浙江大学, 2006

[5] 郑发泰. 基于神经网络故障诊断主特征量提取的应用研究 [J]. 煤矿机械, 2007, 28: 188-190

[6] Ververidis D, Kotropoulos C. Fast and accurate sequential floating forward feature selection with the Bayes classifier applied to speech emotion recognition [J]. Signal Processing, 2008, 88: 2956-2970

[7] Hassan A, Damper R I. Emotion Recognition from Speech using Extended Feature Selection and a Simple Classifier [C]// Interspeech. 2009: 2043-2046

[8] 徐露, 徐明星, 杨大利. 面向情感变化检测的汉语情感语音数据库 [J]. 北京: 清华大学学报: 自然科学版, 2009: 1413-1418

[9] Burkhart F, Paeschke A, Rolfes M, et al. A Database of German Emotional Speech [C]// Interspeech. 2005: 1517-1520