

패턴 인식문제를 위한 유전자 알고리즘 기반 특징 선택 방법 개발

Genetic Algorithm Based Feature Selection Method Development for Pattern Recognition

박창현 · 김호덕 · 양현창 · 심귀보

Chang-Hyun Park, Ho-Duck Kim, Hyun-Chang Yang, and Kwee-Bo Sim

중앙대학교 전자전기공학부

요 약

패턴 인식 문제에서 중요한 전처리 과정 중 하나는 특징을 선택하거나 추출하는 부분이다. 특징을 추출하는 방법으로는 PCA가 보통 사용되고 특징을 선택하는 방법으로는 SFS 나 SBS 등의 방법들이 자주 사용되고 있다. 본 논문은 진화 연산 방법으로써 비선형 최적화 문제에서 유용하게 사용되어 지고 있는 유전자 알고리즘을 특징 선택에 적용하는 유전자 알고리즘 특징 선택(Genetic Algorithm Feature Selection: GAFS)방법을 개발하여 다른 특징 선택 알고리즘과의 비교를 통해 본 알고리즘의 성능을 관찰한다.

Abstract

An important problem of pattern recognition is to extract or select feature set, which is included in the pre-processing stage. In order to extract feature set, Principal component analysis has been usually used and SFS(Sequential Forward Selection) and SBS(Sequential Backward Selection) have been used as a feature selection method. This paper applies genetic algorithm which is a popular method for nonlinear optimization problem to the feature selection problem. So, we call it Genetic Algorithm Feature Selection(GAFS) and this algorithm is compared to other methods in the performance aspect.

Key words : Feature Selection, Feature extraction, Genetic Algorithm, SFS, Pattern Recognition.

1. 서 론

음성 신호를 이용한 감성인식에서 사용하는 특징점은 크게 피치, 에너지, 포먼트, 말의 빠르기로 구성되어진다. 연구자에 따라 이 4가지 특징 점을 모두 선택하기도 하고 일부만 선택하기도 하며 각 특징 점들에서도 다양한 통계치를 추출하여 사용하는 게 일반적이다. 그래서 Dimitrios 와 Constantine은 5개의 감정을 구분하는데 피치, 에너지, 포먼트에서 87개의 특징점을 추출하여 분류하였고[1], Chul Min 과 Shrikanth는 남성과 여성을 구분하여 특징점을 추출하였고 피치, 에너지, 말의 빠르기 등으로부터 17개의 특징점을 추출하였다[2]. 이외에도 Healey는 11개의 특징점, Picard 는 40개, Haag et al. 은 13개 등으로 각 연구자들 마다 다양한 특징점들을 사용하고 있다[3]. 이렇듯 다양한 특징점들을 사용한다는 것은 다른 의미로 보면 아직 감성인식에 사용할 대상 특징점이 명확하게 정립되지 않았다는 것이고 이 부분에 대해서는 획기적인 결과를 보여 줄 수 있는 특징점이 정립되기 전까지는 이 분야의 연구자들이 항상 고민을 해야 하는 부분일 것이다. 이러한 선택의 문제에서 고민을 다소 해소

시켜 줄 수 있는 방법으로 GA를 이용한 방법, Floating search 방법들이 있다[4]. 특히 floating search 방법에는 sequential forward selection 혹은 sequential backward selection method가 자주 사용되고 있다. Chul Min 과 Shrikanth는 forward selection(FS) method를 사용하였고[2], Dimitrios 와 Constantine은 Sequential floating forward selection algorithm을 사용하여 87개의 feature set으로부터 10개의 best features를 선택하여 실험하였다. Yi-Lin 과 Gang 또한 Sequential forward selection을 사용하여 39개의 후보 Feature set에서 최적의 Feature subset을 선택하였고[5] Fabian et al.은 음악의 장르를 구분하는 문제에서 Genetic Programming을 이용하여 좋은 Feature set을 찾아내었다[6]. 이러한 Feature selection 방법들은 '차원의 저주'에 대한 좋은 해결책을 제시해 주었고, 패턴 인식 성능 향상에도 기여를 하였다. 또한, feature selection 방법들은 교사 값을 갖는 경우와 교사 값을 갖지 않는 경우로 나눌 수 있는데 보통의 경우 교사 값을 갖는 경우 들이 많다. 비교사 특징 선택 방법은 인지된 소리 외의 다른 것에 대응하는 결과를 보일 확률이 높기 때문에 교사 값을 갖는 방법을 많이 사용하는 것이다[7]. 그러나 실질적으로 Feature selection method를 사용해야하는 경우는 분명한 교사 값을 갖기 어려운 경우이기 때문에 비교사 값을 사용한 방법이 유용할 것이다. 이러한 두 방법의 문제점을 해결할 수 있는 방법으로 교사와 비교사 학습의 중간지점에 위치한 강화학습을 사용하는 방법을 제안한다.

접수일자 : 2006년 4월 13일

완료일자 : 2006년 7월 28일

감사의 글 : 본 논문은 서울시 산학연 협력사업(과제번호: 106876)에 의해 수행되었습니다. 연구비지원에 감사드립니다.

2. 특징 선택 방법

2.1 정의

특징 집합, $X = \{x_i | i = 1, 2, \dots, N\}$ 가 주어졌을 때, 목적 함수인 $J(Y)$ 은 최적화시키는 하위 집합, $Y_M = \{x_{i1}, x_{i2}, \dots, x_{iM}\}$, $M < N$ 을 찾는 방법.

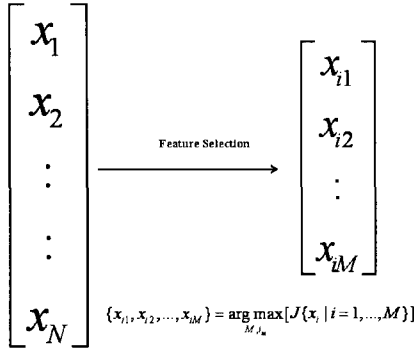


그림 1. 특징 선택의 개념
Fig.1. The feature selection

2.2 특징

- (1) 고차원 데이터보다 저차원 데이터가 시각화에 용이하다.
- (2) 저차원 데이터 분석이 계산 효율성면에서 좋다.
- (3) 특징 선택이 성공적인 경우에 SER이 증가할 것이고 그렇기 때문에 신호의 회복이 더 쉬워질 것이다.

2.3 구조

특징 선택은 두 부분으로 구성되어 있다.

- (1) 후보 하위 특징 집합(Feature subset)을 선택하는 탐색 전략
 - 하위 특징 집합을 모두 탐색하게 되면 $\binom{N}{M}$ 개의 조합을 살펴봐야 하고 M개가 최적화 되어야 한다면 2^N 개의 조합을 평가해야 한다.
 - 너무 많은 수의 조합을 평가해야 하게 되고 모든 후보 집합을 평가하는 것은 비실용적이므로 좋은 탐색 전략을 선택해야 한다.
- (2) 후보 하위 특징 집합을 평가하는 목적 함수
 - 목적함수는 후보 집합을 평가하고 점수를 반환하여 좋은 후보가 선택되도록 한다.

2.4 이론

좋은 하위 특징 집합이라면 해당 클래스와의 높은 상관성을 갖는다.

(1) Linear relation measures

변수들 간의 선형적 관계는 다음과 같이 구해질 수 있다.

$$J(Y_M) = \frac{\sum_{i=1}^M \rho_{ic}}{\sum_{i=1}^M \sum_{j=i+1}^M \rho_{ij}} \quad (1)$$

여기서 ρ_{ic} 는 특징 'i'와 class 간의 상관계수 이고, ρ_{ij} 는

특징 'i'와 'j'간의 상관계수이다.

(2) Non-Linear relation measures

선형 관계를 측정하는 것보다 상호 정보(Mutual Information)를 측정하는 것이 더욱 효과적이다. 특징벡터와 클래스 간의 상호 정보는 클래스의 불확실성이 특징벡터에 의해 어느 정도 감소했는지를 측정한다.

$$J(Y_M) = I(Y_M; C) = H(C) - H(C|Y_M) \quad (2)$$

$$= \sum_{c=1}^C \int_{Y_M} P(Y_M | \omega_c) \lg \frac{P(Y_M | \omega_c)}{P(Y_M)P(\omega_c)} dx$$

여기서 $I(Y_M; C)$ 는 특징벡터와 클래스간의 상호 정보, $H(\cdot)$ 는 엔트로피 함수를 의미한다.

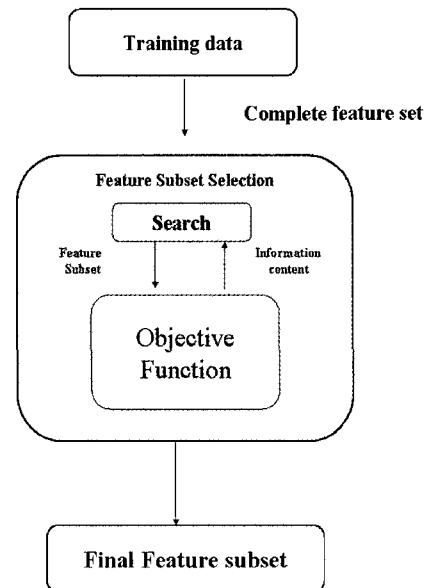


그림 2. 특징 선택 방법의 구조
Fig. 2. The structure of feature selection method

2.5 탐색 전략 종류

(1) Exponential algorithms

- 탐색 공간의 차원이 증가함에 따라 기하급수적으로 늘어나는 후보집합을 평가한다.
- Exhaustive Search, Branch and Bound, Approximate Monotonicity with Branch and Bound, Beam Search

(2) Sequential algorithms

- 순차적으로 features를 더하거나 빼는 방법, Local minima에 빠지는 경향이 있다.
- Sequential Forward Selection, Sequential Backward Selection, Plus-1 Minus-r Selection, Bidirectional Search, Sequential Floating Selection

(3) Randomized algorithms

- Local minima에서 빠져나오기 위해 기존의 탐색 방법에 무작위성을 첨가한 방법
- Random Generation plus Sequential Selection, Simulated Annealing, Genetic Algorithm

3. SFS, IFS, GAFS 방법

3.1 순차 전향 선택 (Sequential Forward Selection: SFS) 방법

SFS는 가장 간단한 greedy search algorithm이다. 비어 있는 특징 집합으로부터 시작해서 순차적으로 feature를 추가 하는데, 추가 시 목적함수의 결과가 제일 좋은 feature를 추가한다[2]. 그림 3은 SFS 알고리즘의 순서를 보여준다. 처음에는 비어있는 집합에서 시작하여 한 개씩 각각의 새로운 feature를 추가해본 뒤 평가하여 최적의 적합도를 보여주는 feature를 선택하고, 반복하면서 한 개씩 feature를 추가해가는 방법이다.

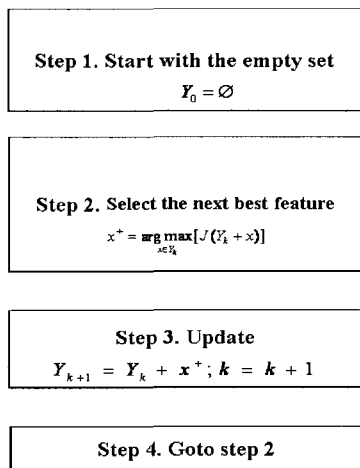


그림 3. SFS 알고리즘 흐름도
Fig. 3. SFS algorithm flowchart

3.2 유전자 알고리즘 기반 특징 선택 방법(Genetic Algorithm Feature Selection: GAFS)

IFS는 Feature의 상관성과 강화학습을 이용한 알고리즘이다. 강화학습은 에이전트와 환경이 존재하는 구조에서 에이전트를 사용자가 원하는 목적을 이루도록 학습하는 방법이다. 학습하는 방법은 주어진 환경에서 에이전트가 동작을 취하고 취한 동작에 대해 환경이 보상을 취하는 형태로 이루어진다. 이때 각 시간 step은 t , 각 단계에서 에이전트가 받게 되는 환경의 상태는 $s_t \in S$, S 는 가능한 환경 상태의 집합, 으로 표현되고 동작은 $a_t \in A(s_t)$, $A(s_t)$ 는 어떤 상태에서의 '동작들의 집합' 으로 표현 된다. 동작에 대한 보상을 r_t 라 하고 이 r_t 는 하나의 에피소드가 끝나면 다음과 같은 식으로 표현된다.

$$R_t = \sum_{k=0}^T \gamma^k r_{t+k+1} \quad (3)$$

여기서 γ 는 감쇠계수로서 Continuing task의 경우 $t = \infty$ 까지 정의가 되므로 보상 값의 합이 무한대가 되지 않도록 하기 위함이다. 또한 감쇠계수를 0으로 하면 현재 발생한 보상 값만을 인정한다는 의미이므로 감쇠계수에 따라 미래의 값에 대한 가중치를 다르게 줄 수 있다. 결론적으로 강화학습은 식(3)을 최대화 하는 방향으로 정책을 결정하는 방법이다. 그림 4는 알고리즘의 흐름도를 나타낸다[8].

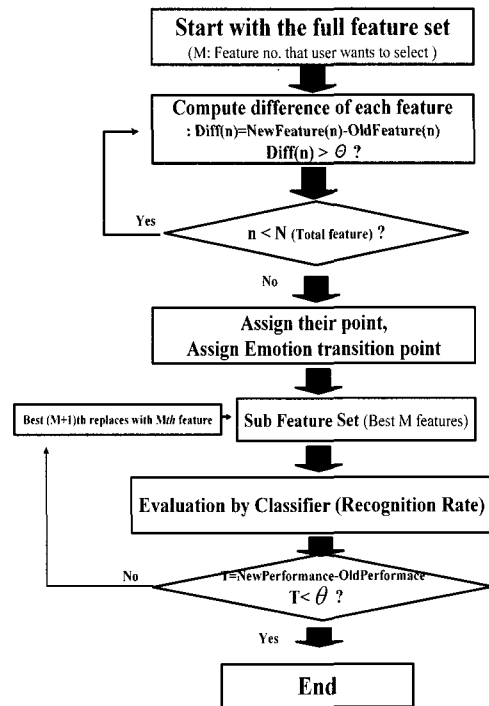


그림 4. IFS 알고리즘
Fig. 4. IFS algorithm flowchart

그림 4에서 보인 것과 같이 처음에는 모든 후보 특징 집합 으로부터 시작한다. 그러나 이 방법은 Sequential Backward Selection(SBS)에서 순차적으로 Feature를 빼가는 것과는 달리 단지 동일 클래스에 대해 높은 상관성을 갖는지, 혹은 서로 다른 클래스에 대해서는 어느 정도의 낮은 상관성을 갖는지를 측정한다. 동일 클래스인 경우에는 '+' 붙여줌으로써 '상(reward)'으로써 상관 정도가 평가에 적용되도록 하고 다른 클래스의 경우에는 '-'를 붙여줌으로써 '벌(penalty)'으로써 적용되도록 한다. 이렇게 1차적으로 전체 후보 집합 중 일부를 선정하고 목적함수에 의해 평가를 받는다. 이전의 적합도와 현재의 적합도의 차이를 비교하여 기준치 이하이면 선정된 후보 집합을 차선의 후보 집합으로 대체하여 평가를 받고 이러한 과정을 종료조건이 만족될 때 까지 반복한다. 다음의 그림 5는 이와 같은 과정에 대한 예를 보여준다[10].

그림 5에서 E_i 는 사용자의 감정 식별자를 나타내고 i 번째 입력으로 들어온 감정을 의미한다. f_{ij} 는 i 번째 입력에 대한 j 번째 feature를 의미한다. step 1에서는 i 번째 감정과 특징 집합을 입력 받는다. step 2에서는 다음에 들어온 E_{i+1} 과 E_i 가 동일한지 검사하여 동일하다면 ReturnSign을 -1로 다르다면 +1로 부여한다. step 3에서는 i 번째 특징 집합과 $i+1$ 번째 특징 집합의 대응되는 것들끼리 차이를 계산한다. 각각의 차에 step2에서 구한 ReturnSign을 부호로 붙여 각각 저장한다. step 4에서는 또 들어온 입력에 대해 step2,3의 과정을 반복하여 Pointstorage[n]에 각 특징요소들에 대한 점수를 누적한다. 더 이상 입력이 없게 되면 feature들 중 점수가 높은 것을 선택하여 목적함수에 의한 평가를 받는다. 두 번 이상의 평가이후 성능이 저하되는 경우에는 처음에는 일정 순위에 들지 못했던 것들 중 점수가 높은 feature를 입력하여 다시 평가한다. 이 또한 성능이 향상할 때까지 반복한다.

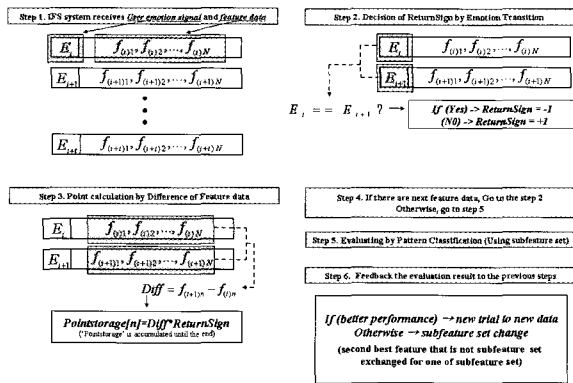


그림 5. IFS 알고리즘 설명도
Fig.5. A diagram of IFS algorithm

3.3 유전자 알고리즘 기반 특징 선택 방법(Genetic Algorithm Feature Selection: GAFS)

특징 선택은 비선형 최적화 문제이다. 특히, 감정 인식분야에서 특징 추출은 수십 차원에 이르는 특징 집합들 중 목적함수인 감정 인식 성능향상을 만족시키는 특징 집합을 찾아야 하는 매우 어려운 문제이다. 이러한 최적화 문제를 해결하기 위한 연구 중 하나인 Genetic Algorithm(GA)은 영역-독립적(domain-independent)인 조합 최적화라고 한다[9]. 이 말은 GA는 출력을 얻을 수 있는 함수가 정의되면 어디에서나 적용 가능하다는 의미이다.

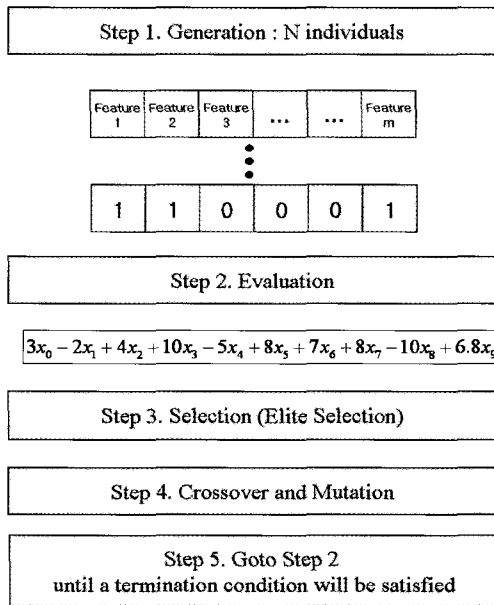


그림 6. GAFS의 설명도
Fig. 6. A diagram of GAFS

GA는 주어진 함수에 대한 모든 가능한 해의 탐색 공간에서 컴퓨터가 창조한 개체(Individuals)들의 집합인 개체군(population)으로부터 시작된다. 그리고 개체가 속한 환경에 얼마나 잘 맞는가를 측정하는 목적 함수를 이용하여 최적의 개체만이 선택되고 좀 더 나은 개체로 진화되는 과정을 반복함으로써 결국 최적 해에 도달하도록 하는 알고리즘이다.

본 논문에서는 특징 선택을 위해 위의 그림과 같은 방법으로 GAFS를 제안하였다[10]. 초기에 해집합을 생성할 때는 목적함수에서 필요한 변수의 개수에 맞춰 검색체 길이를 조정한다. 위의 그림에서는 목적함수가 8개의 feature들로 이루어져 있으므로 검색체의 길이를 10로 고정한다. 검색체 길이 10인 개체들을 미리 결정해둔 population size N만큼 생성함으로써 1단계가 완료된다. 2단계에서는 N개의 개체들을 목적함수에 대입하여 각각의 적합도(fitness)를 알아낸다. 이와 같이 결정된 적합도를 이용하여 elite selection 방법을 이용하여 선택을 한 뒤, 미리 정해진 교차율과 돌연변이율에 따라 교차와 돌연변이를 수행하여 적합도를 보고 종료조건이 만족될 때까지 step2에서 step 5의 과정을 반복한다.

4. 시뮬레이션 결과

4.1 SFS, IFS, GAFS의 성능 실험

앞 절들에서는 3가지 특징 선택 방법을 설명하였다. 본 절에서는 3가지 특징 선택을 다음의 함수에 적용하여 각각의 성능을 평가한다.

$$3x_0 - 2x_1 + 4x_2 + 10x_3 - 5x_4 + 8x_5 + 7x_6 + 8x_7 - 10x_8 + 6.8x_9$$

다음의 그림 7은 SFS를 이용하여 적합도를 평가한 각 세대 간 추세를 나타낸다. SFS의 특성대로 한 세대마다 Feature의 개수가 한 개씩 증가하고 적합도가 상승하여 6개의 특징들이 모아졌을 때 최고점에 다다른 뒤 더 이상 추가하면 감소하는 추이로 진행된다.




그림 7. SFS 알고리즘 성능 추이 그래프
Fig.7. Performance movement graph of SFS algorithm

다음의 그림 8은 IFS를 동일한 함수인 식 (4)를 적용하였을 때의 추세를 그린 것이다. 위의 선은 적합도를 나타내고 아래 선은 해당 세대에서 특징개수를 나타낸다. IFS는 알고리즘의 특성상 사용자가 목표로 하는 Feature의 개수를 미리 정할 수 있다. 그래서 그림 3-8에서 나타난 세대별 Feature의 개수는 사용자가 미리 결정한 것이고 위의 선은 그때의 적합도를 나타낸 것이다. 1개에서 2개로 늘렸을 때는 성능이 선형적으로 증가했으나 3개로 늘렸을 때는 3세대 동안 다른 특징 집합을 선정하는 작업을 거쳐서 좋은 적합도를 보이는 결과를 찾을 수 있었고 4개로 증가시켰을 때도 3세대 동안 다른 특징 집합을 선정하는 작업을 거쳐서 46.8에 가까운 값으로 증가하였다.




그림 8. IFS 알고리즘의 성능 천이 그래프
Fig. 8. The performance movement graph of IFS algorithm

또한, GAFS를 수행한 결과는 다음의 그림 9와 같다.

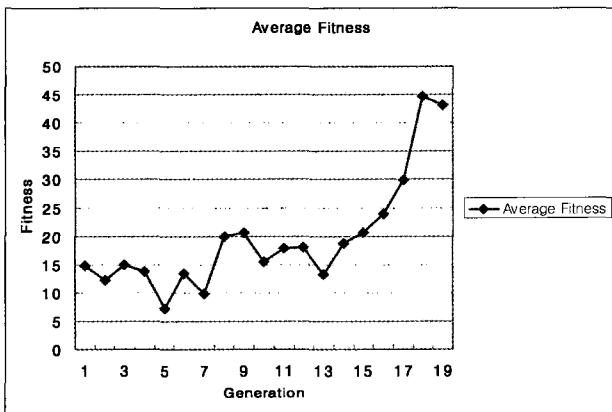
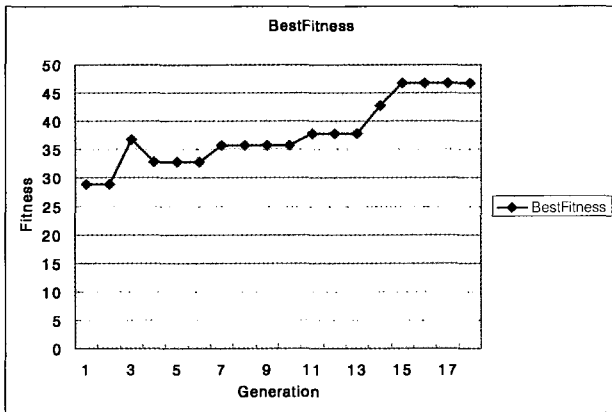


그림 9 GAFS 수행 결과 (Best and average fitness)
Fig.9 The performance graph of GAFS (Best and average fitness)

(Crossover Rate: 0.4, Mutation Rate:0.03, Chromosome Length:10, Population No.:10)

GA의 파라미터는 교차율(Crossover Rate): 0.4, 돌연변이율(Mutation Rate):0.03, 염색체 길이(Chromosome Length):10, 개체 수(Population No.):10 로 하였고, 평가함수는 식 (4)를 이용하였다. 약 46.8까지 수렴하는데는 16세

대 정도의 시간이 걸려서 SFS나 IFS보다는 좀 더 많은 세대가 걸렸으나 개체군이 10개로 GA로써는 매우 작은 개체군을 사용하였기 때문이다. 실제로 100개의 개체군으로 했을 때는 1세대 만에 최적해에 도달하였다.

그림 10은 3개 특징 선택 방법에 대해 식 (4)를 평가함수로 사용하였을 때 최고 적합도를 비교한 그래프이다. 보는 바와 같이 SFS가 가장 낮았고 IFS와 GAFS는 거의 동일한 결과를 나타낸다. 이는 SFS의 단점이기도 한데, 개별적으로 나뉠 성능을 갖는 Feature라도 다른 Feature와 조합이 될 경우 더욱 좋은 성능을 보여줄 수 있다는 점을 간과한 결과이다.




그림 10. 최고 적합도 비교
Fig. 10. Best Fitness Comparison

그림 11은 각 알고리즘을 사용하였을 때 수렴하는데 걸린 세대를 비교한 것이다. 그림에서 나타난 수렴 세대가 가장 짧은 것은 SFS이고 다음으로 IFS인데, GAFS의 경우는 개체군의 개수에 따라 수렴 세대가 매우 달라질 수 있다.




그림 11. 수렴 시간의 비교
Fig. 11. Convergence duration comparison

5. 결론 및 향후과제

본 논문에서는 3가지의 특징 선택 방법을 다루었다. 일반적으로 많이 쓰이는 방법인 SFS와 본 논문에서 제안하는 IFS 및 GAFS의 알고리즘을 설명하였고 특정 함수를 평가함수로 적용하여 각 알고리즘별 적합도 추이를 살펴보았다.

그 결과 최고 적합도는 IFS와 GAFS가 SFS 보다 좋았고 수렴까지의 세대수는 SFS가 가장 짧았다. 그러나, GAFS의 경우 개체군의 수를 늘린 경우 SFS보다도 훨씬 빠른 세대수에서 수렴하였고 이러한 결과로 미루어 GAFS와 IFS의 성능이 성능과 속도면에서 꽤 높은 장점을 보임을 확인할 수 있었다. 하지만, 문제점도 있는데 GAFS나 SFS의 경우 평가 함수에 특징들을 적용하여 적합도를 계산할 경우 함수식이 정해져 있는 경우에는 문제가 없으나 적용하려고하는 패턴 인식 문제에서는 인식율이 적합도를 의미한다. 인식율의 계산이 학습과 테스트라는 과정을 거쳐야 하므로 수많은 특징들의 조합에 대한 인식율을 미리 해놓지 않는 한은 하나의 후보 특징 집합이 선정될 때마다 인식율을 수동으로 계산해야 하는 번거로움이 있다. IFS의 경우는 filter 와 wrapper 방식의 혼용으로써 전자의 경우에는 앞의 문제에서 자유로울 수 있으나 두 번째 단계에서는 마찬가지로의 문제가 있다. 차후 이 문제에 대한 해결 방안이 필요할 것이다.

참 고 문 헌

- [1] D. Ververidis and C. Kotropoulos, "Emotional speech classification using Gaussian mixture models," Proceedings of ISCAS, vol. 3, pp. 2871-2874, May, 2005.
- [2] C.M. Lee and S.S. Narayanan, "Toward detecting emotions in spoken dialogs," IEEE Transactions on Speech and Audio Processing, vol.13, pp. 293-303, March, 2005.
- [3] J. Wagner, J.H. Kim, and E. Andre, "From Physiological Signals to Emotions: Implementing and Comparing Selected Methods for Feature Extraction and Classification," Proceedings of ICME, pp.940-943, July, 2005.
- [4] P. Pudil and J. Novovicova, "Novel Methods for Subset Selection with Respect to Problem knowledge," IEEE Intelligent Systems, pp. 66-74, March,1998.
- [5] Y.L. Lin and W. Gang, "Speech Emotion Recognition based on HMM and SVM," Proceedings of Machine Learning and Cybernetics, Vol.8, pp. 4898-4901, Aug, 2005.
- [6] F. Morchen, A. Ultsch, M. Thies and I. Lohken, "Modeling Timbre Distance With Temporal Statistics From Polyphonic Music," IEEE transaction on Audio,Speech and Language Processing, Vol.14, Issue 1, pp. 81-90, Jan. 2006.
- [7] E.F. Combarro, E. Montanes, I. Diaz, J. Ranilla, and R. Mones, "Introducing a Family of Linear Measures for Feature Selection in Text Categorization," IEEE transactions on Knowledge and Data Engineering, Vol.17, No.9, pp. 1223-1232, Sept., 2005.
- [8] R.S. Sutton and A.G. Barto, Reinforcement Learning :An Introduction, A bradford book,London, 1998.
- [9] Z. Michalewicz, Genetic Algorithms + Data Structures = Evolution Programs, Springer, North

Carolina, 1999

- [10] C.H. Park and K.B. Sim, "The Implementation of the Emotion Recognition from Speech and Facial Expression System," Proc. of ICNC'05-FSKD'05, pp. 85-88, Aug. 27-29, 2005.

저 자 소 개



박창현 (Chang-Hyun Park)

2001년 : 중앙대학교 전자전기공학부 졸업
 2003년 : 중앙대학교 대학원 공학석사
 2006년 8월 : 중앙대학교 대학원 공학박사

관심분야 : 패턴 인식, 기계학습, 진화 연산 등



김호덕 (Ho-Duck Kim)

2005년 : 중앙대학교 전자전기공학부 졸업
 2006년 : 동대학원 전기전자공학부 석사과정 재학 중

관심분야 : 지능시스템, 임베디드 시스템, 유비쿼터스 로봇 등



양현창 (Hyun-Chang Yang)

2006년 : 중앙대학교 대학원 전자전기공학부 박사과정 재학 중

관심분야 : 로봇정책, 스마트 홈, 유비쿼터스 센서네트워크 등



심귀보 (Kwee-Bo Sim)

1990년 : The University of Tokyo 전자공학과 공학박사
 1991년 ~ 현재 : 중앙대학교 전자전기공학부 교수

[제16권 6호(2006년 6월호) 참조]

2006년 ~ 현재 : 한국퍼지 및 지능시스템학회 회장

E-mail : kbsim@cau.ac.kr
 Homepage URL : http://alife.cau.ac.kr
 Phone : +82-2-820-5319