

PCA와 입자 군집 최적화 알고리즘을 이용한 얼굴이미지에서 특징선택에 관한 연구

논문

58-12-34

A Study on Feature Selection in Face Image Using Principal Component Analysis and Particle Swarm Optimization Algorithm

김 옹 기* · 오 성 권† · 김 현 기**

(Woong-Ki Kim · Sung-Kwun Oh · Hyun-Ki Kim)

Abstract - In this paper, we introduce the methodological system design via feature selection using Principal Component Analysis and Particle Swarm Optimization algorithms. The overall methodological system design comes from three kinds of modules such as preprocessing module, feature extraction module, and recognition module. First, Histogram equalization enhance the quality of image by exploiting contrast effect based on the normalized function generated from histogram distribution values of 2D face image. Secondly, PCA extracts feature vectors to be used for face recognition by using eigenvalues and eigenvectors obtained from covariance matrix. Finally the feature selection for face recognition among the entire feature vectors is considered by means of the Particle Swarm Optimization. The optimized Polynomial-based Radial Basis Function Neural Networks are used to evaluate the face recognition performance. This study shows that the proposed methodological system design is effective to the analysis of preferred face recognition.

Key Words : Principal Component Analysis, Radial Basis Function Neural Network, Particle Swarm Optimization, Feature Selection, Face Recognition

1. 서 론

패턴인식 시스템에서 어떠한 특징을 선택할 것인가? 하는 결정 사항과 더불어 특징 벡터의 차원을 형성하는 특징의 개수를 선택하는 문제는 인식률에 결정적인 영향을 미친다. 패턴이 가진 정보가 특징 벡터의 형태로 표현되므로 상식적으로 생각해도 특징의 수가 적으면 적을수록 많은 경우와 비교하여 상대적으로 패턴 분류에 좋지 않은 영향을 미칠 것이라 예상된다. 그러나 그렇다고 해서 너무 많은 특징을 사용하는 것이 반드시 패턴인식에 도움이 되는 것도 결코 아니다. 다음은 특징 벡터의 차원이 높아짐에 따라 생길 수 있는 문제점들이다.

- 패턴 분류기에 의한 학습과 인식 속도가 느려진다.
- 모델링에 필요한 학습 집합의 크기가 커진다.

대부분의 패턴인식 시스템에서 패턴인식 성능은 차원을 올리면 어느 정도 인식률이 증가하다가 어느 지점에서부터 오히려 인식률이 감소되는 것을 확인할 수 있다. 패턴인식에서 이러한 현상을 '차원의 저주(curse of dimensionality)'라는 재미있는 용어로 표현하고 있다.

이렇듯 패턴인식 시스템에서 특징의 차원수를 결정하는 것은 계속해서 논의되고 있는 중요한 문제이다. 데이터의

양을 나타내고 특징벡터의 차원을 축소할 수 있는 PCA (Principal Component Analysis)는 패턴 인식과 컴퓨터 비전 분야 등에서 널리 이용되는 전통적인 특징 추출과 데이터 표현에 관한 기술이다. 특히 신경망, SVM(Support Vector Machines), Adaboost와 같은 여러 가지 대표적인 얼굴인식 단계들 중에 PCA가 포함되어 있다.

Sirovich와 Kirby[1]는 얼굴 영상을 효율적으로 표현하기 위해 처음으로 PCA를 적용하였다. 그들은 하나의 얼굴 영상은 얼굴의 기저 벡터와 평균 벡터로 정의되는 적은 수의 가중치 합으로 표현하였다. Turk와 Perland는 얼굴 인식을 위한 고유얼굴(Eigenface) 방법을 제안하였다[2].

PCA에서 구한 특징벡터는 얼굴인식에 사용되는 특징이다. 본 논문은 그 특징의 차원수에 따라 인식률에 어떠한 영향을 미치는지에 대해서 입자 군집 최적화 알고리즘에 feature selection 기능이 추가된 최적화 방법을 통해 알아본다.[3] 얼굴인식을 위한 분류기로서 학습능력과 일반화 능력이 우수한 다항식 기반 RBF 신경회로망을 설계하여 얼굴인식 결과를 분석한다[4][5][6].

본 논문의 구성은 2장에서 PCA를 이용한 얼굴인식 방법에 대하여 기술하고, 3장에서 얼굴인식을 위한 입자 군집 최적화 알고리즘과 다항식 기반 RBF 신경회로망에 대하여 설명한다. 4장에서는 전처리 모듈, 특징추출 모듈, 인식모듈과 같이 크게 3가지 모듈로 구성되는 보편적인 얼굴인식 시스템을 기반으로 본 논문의 전체적인 흐름에 대해 소개한다. 그리고 마지막으로 5장에서 Yale과 ORL 얼굴이미지 데이터를 가지고 실험을 통해 특징의 차원수와 인식률과의 관계를 보여주고 결론을 맺는다.

* 준 회원 : 수원대 공대 전기공학과 석사과정

† 시니어회원 : 수원대 공대 전기공학과 교수

E-mail : ohsk@suwon.ac.kr

** 정 회원 : 수원대 공대 전기공학과 교수

접수일자 : 2009년 8월 24일

최종완료 : 2009년 10월 9일

2. PCA를 이용한 얼굴이미지 특징벡터 추출

2.1 얼굴이미지 전처리

얼굴 이미지들은 각각 크기나 밝기정보, 회전각에 대한 정보에 따라 같은 얼굴이나 같은 환경이라고 할지라도 각기 다르다. 이러한 차이들은 얼굴인식에서 커다란 왜곡 현상이나 오류인식의 확률을 높이는데, 히스토그램 평활화, 이미지 정규화를 통해서 빛에 대한 요인을 보상해준다.

2.1.1 히스토그램 평활화

히스토그램 평활화 과정은 다음과 같다.

- [Step 1] 원시 입력영상의 밝기값에 대한 히스토그램을 생성
- [Step 2] 생성된 히스토그램을 정규화합 히스토그램으로 변형
- [Step 3] 정규화합 히스토그램을 이용하여 입력영상을 다시 매핑 정규화합의 계산을 위한 변환식은 식(1)과 같다.

$$h(i) = \frac{G_{\max}}{N_t} H(i) \quad (1)$$

여기서, $H(i)$ 는 원본 입력영상의 누적 히스토그램, $h(i)$ 는 정규화합 히스토그램, G_{\max} 는 영상의 최대 밝기값(일반적인 흑백영상에서 255), N_t 는 입력영상 내부에 존재하는 픽셀의 개수이다.




그림 1 히스토그램 평활화
Fig. 1 Histogram Equalization

2.1.2 이미지 정규화

빛과 배경에 의하여 발생하는 에러를 줄이기 위하여 임의로 설정된 평균과 분산을 기준으로 이미지를 정규화 해준다. 이미지 정규화를 계산하기 위한 식(2)와 같다.

$$N(i) = \frac{(O_i - m_i) \bar{\sigma}}{\sigma_i + m} \quad (2)$$

여기서, $N(i)$ 는 정규화한 이미지, O_i 는 원 이미지, m_i 는 평균 이미지, σ_i 는 원 이미지 표준편차, $\bar{\sigma}$ 초기 설정된 표준편차, m 초기 설정된 평균이다.

2.2 PCA

Principal Component Analysis(PCA) 기법은 벡터표현의

통계학적 특성을 바탕으로 고차원의 데이터를 저차원의 데이터로 줄여 다루기 쉽게 하기 위한 알고리즘으로서 Karhunen-Loeve 근사 방법이라고도 한다. $N \times N$ 크기의 영상을 $N^2 \times 1$ 의 열 벡터로 표현하여 고차원 공간상에서 수행할때의 문제는 저차원 공간으로 이들 데이터를 축소하여 수행한다.

$N^2 \times 1$ 의 벡터로 표현되는 얼굴 영상의 각 픽셀은 해당 차원을 이루는 벡터공간을 이룬다. 이 벡터공간을 얼굴공간(face space)이라고 하면 모든 얼굴영상은 이 얼굴공간 상에 존재한다. 고유얼굴(eigenface)이란 얼굴공간을 구성하는 기저벡터로 인식 후보 얼굴의 공통적인 특징을 가장 잘 나타내게 된다. 즉, 고유얼굴은 모든 인식후보 얼굴영상의 평균얼굴 영상과 각 후보얼굴영상의 차 벡터에 대한 공분산 행렬의 고유벡터에 해당된다.

PCA를 이용한 얼굴이미지에서 특징벡터 추출 알고리즘은 다음과 같다.

- [Step 1] 인식후보 얼굴 벡터 집합(S)의 구성

인식 후보 얼굴영상의 개수가 M 개일 때, 각 후보 얼굴영상을 M 개의 $N^2 \times 1$ 열 벡터(column vector)로 인식후보 얼굴 벡터 집합(S)은 식(3)와 같이 구성한다.

$$S = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\} \quad (3)$$

- [Step 2] 평균얼굴 벡터(Ψ) 계산

인식후보 얼굴 벡터 집합(S)으로부터 식(4)을 이용하여 평균얼굴 벡터를 계산한다.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (4)$$

- [Step 3] 각 인식후보, 얼굴 벡터와 평균얼굴 벡터의 차 벡터(Φ_i) 계산

$$\Phi_i = \Gamma_i - \Psi \quad (5)$$

- [Step 4] $N^2 \times 1$ 벡터 Φ_i 로부터 공분산 행렬(C) 계산

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (6)$$

단계4의 결과, A 는 $N^2 \times M$ 행렬이 되며, 공분산 행렬(C)은 $N^2 \times N^2$ 의 고차행렬이 된다.

- [Step 5] 공분산 행렬(C)로부터 고유얼굴 계산

공분산 행렬(C)로부터 M 개의 N^2 개 고유치 λ_i 와 이에 대응하는 고유벡터 u_i 를 계산한다. 여기서, 고유치는 평균얼굴 영상에 대한 분산의 정도를 나타내며, 고유치로부터 얻어진 고유벡터를 $N \times N$ 로 재배열하면 얼굴의 모양과 닮아 보이므로 이를 "고유얼굴(eigenface)"이라고 한다. 고유얼굴의 개수는 M 개가 존재한다.

[Step 6] 주성분 선택

M 개의 고유벡터(고유얼굴) u_l 에서 가장 큰 고유치를 가지는 M' 개 만을 선택한다. 고유치가 크면 클수록 얼굴 특징을 고유벡터가 더 많이 표현하게 된다. 작은 고유치는 얼굴특징의 적은 부분만을 표현하므로 무시해 버린다. 일단, 이 단계가 완성되면 얼굴인식에 사용될 특징벡터 추출을 위한 학습단계는 끝나게 된다.

$$u_l = \frac{1}{M} \sum_{k=1}^M \lambda_{lk} \Phi_k \quad l=1,2,\dots,M \quad (7)$$

[Step 7] 특징벡터 추출

새로운 얼굴영상이 입력되면 고유얼굴 u_k 에 대한 사영을 취하여 그 성분값 ω_k 를 구한다. 사영을 취한다는 것은 내적을 의미한다. 결국 입력되는 얼굴영상에 대한 각 고유얼굴 성분값은 다음과 같이 계산된다.

$$\omega_k = u_k^T (\Gamma - \Psi) \quad k=1,2,\dots,M' \quad (8)$$

여기서, M' 는 아주 작은 고유치에 대응하는 고유얼굴을 제외한 M 보다 작거나 같은 것을 의미한다. 이렇게 얻어진 가중치를 이용하여 입력 얼굴영상을 표현하는 고유얼굴 특징 벡터(Ω)를 구할 수 있다.

$$\Omega^T = [\omega_1, \omega_2, \dots, \omega_{M'}] \quad (9)$$

3. 입자 군집 최적화 알고리즘과 다항식 기반 RBF 신경회로망 설계

3.1 입자 군집 최적화 알고리즘

Particle Swarm Optimization(PSO)는 Kennedy and Eberhart 에 의해 처음 소개된, 새 떼와 물고기 떼와 같은 생체군집의 사회적 행동양식을 바탕으로 한 최적화 알고리즘이다. 일반적으로 PSO는 이론의 간결성, 구현의 용이성, 연산의 효율성과 같은 특징을 보이며, 짧은 계산시간 안에 최적의 해를 생성할 수 있고, 다른 확률적 방법보다 안정적인 수렴특징을 나타낸다[7].

3.1.1 PSO 연산자

많은 논문에서 사용된 PSO의 기본요소와 연산자는 다음과 같다[8].

- *Particle-x(t)*: 집단(swarm) 안에 속해 있는 각각의 개체는 하나의 particle이다. swarm의 모든 particle들은 같은 체제 아래에서 개별적으로 동작한다. 이것은 하나의 해를 나타내며 n -차원 실수 벡터로 표현된다. 여기서 n 은 최적 파라미터의 수가된다. t 시간(generation)에, j 번째 particle $x_j(t)$ 는 $[x_{j1}(t), x_{j2}(t), \dots, x_{jn}(t)]$ 로 표현되며, $x_{jk}(t)$ 는 j 번째 particle의 k 번째 차원(파라미터)의 위치(값)를 나타낸다.
- *Swarm-S(t)*: swarm은 m 개 particle의 집합이다. 즉, $S(t)$

$$= [x_1(t), x_2(t), \dots, x_m(t)]^T.$$

- *Particle best-pbest(t)*: 탐색 공간을 움직이는 particle들은 현재 위치정보에 대한 적합도를 구하고 최적의 위치정보를 위해 비교된다. 최적의 위치정보를 가진 particle을 *pbest*라고 한다.

- *Global best-gbest(t)*: 최적의 위치정보를 가지는 particle들, 즉 *pbest*의 모든 particle 중 가장 최적의 위치정보를 나타내는 particle이다. 따라서 *gbest*는 주어진 문제의 최적해가 된다.

- *Particle velocity-v(t)*: $v(t)$ 는 PSO의 유일한 연산자이며, particle들의 이동속도를 나타내는 n -차원 실수벡터이다. t 시간의 j 번째 particle 이동 속도 $v_j(t)$ 는 $[v_{j1}(t), v_{j2}(t), \dots, v_{jn}(t)]$ 로 구성된다. 초기의 PSO 알고리즘은 식(10)에 의해 particle velocity를 계산하였다.

$$v_{jk}(t+1) = v_{jk}(t) + c \cdot r_1 \cdot (pbest_{jk}(t) - x_{jk}(t)) + c \cdot r_2 \cdot (gbest_k(t) - x_{jk}(t)) \quad (10)$$

여기서, c 는 가속상수(acceleration constant), r_1 과 r_2 는 [0 1]의 랜덤상수이다.

- *Inertia weight-w(t)*: 이것은 현재 velocity에 대한 기존 velocity의 영향을 조절하기 위한 제어 파라미터이다. 즉 particle의 전역탐색 능력과 지역탐색 능력 사이의 관계를 조절한다. 탐색과정의 초기에는 전역탐색의 강화를 위해 큰 관성하중(inertia weight) 값을 설정하고, 반대로, 탐색 후반부에는 좀 더 나은 지역탐색을 위해 관성하중을 감소시킨다. 전역탐색과 지역탐색 사이의 균형을 위해 적절한 w 의 선택은 필요하다. 최적 해를 탐색하는 동안 w 값은 0.9에서 0.4까지 선형적으로 감소시키는 식(11)과 같은 방법이 자주 이용되며 본 논문에서도 사용하였다.

$$w(t) = w_{\max} - \frac{w_{\max} - w_{\min}}{eT_{\max}} \times t \quad (11)$$

- *Stopping criteria*: 만약 종료조건을 만족한다면, 탐색과정을 종료한다.

3.1.2 PSO 알고리즘

PSO 알고리즘에서 swarm은 m 개의 particle을 가지며 이들은 주어진 문제의 해가 된다. 각 particle은 n 차원 실수 벡터로 구성된다. PSO 알고리즘은 다음과 같다.

[Step 1] *Initialization* - m 개의 particle을 탐색 공간 내에서 랜덤하게 생성한다. 이들은 초기 swarm이 된다. 마찬가지로 초기 particle velocity를 $[-v_{kmax}, v_{kmax}]$ 내에서 랜덤하게 생성한다. 초기 swarm의 각 particle은 목적함수를 이용하여 평가되고, 이들 모두는 *pbest*로 설정한다. 초기 particle 중 최적의 값은 다시 *gbest*로 선정된다.

[Step 2] *Inertia weight & velocity updating* - 관성하중 값을 계산하고, 식(11)을 이용하여 j 번째 particle velocity를 계산한다. 제한조건 $[-v_{kmax}, v_{kmax}]$ 을 확인한다.

[Step 3] *Position updating* - 식 (12)에 의해 particle의 위치정보는 조절된다.

$$x_{jk}(t) = v_{jk}(t) + x_{jk}(t-1) \quad (12)$$

여기서, $x_k^{\min} \leq x_{jk}(t) \leq x_k^{\max}$ 이다.

[Step 4] *Individual & global best updating* - 새로운 위치정보를 가진 particle들은 목적함수에 의해 평가된다. 각 particle의 적합도는 이전 *pbest*의 적합도와 비교되며 *pbest*를 재설정한다. *pbest*의 particle 중 최적 해를 가지는 particle의 적합도와 이전 *gbest*의 적합도를 비교하여 최적 위치정보를 가진 particle을 *gbest*로 재설정한다.

[Step 5] *Stopping criteria* - 종료조건을 만족하면 탐색과정을 종료하고, 그렇지 않으면 [Step 2]부터 반복한다.

[Step 6] *Optimal parameter* - 최종적으로 생성된 *gbest*는 최적의 위치정보를 가진다.

3.2 다항식 기반 RBF 신경회로망 설계

본 논문에서는 퍼지 추론 메커니즘에 기반한 Polynomial-based Radial Basis Function Neural Networks(P-RBF NNs)를 설계 한다. 제안된 다항식 기반 RBF 신경회로망 구조는 FCM 클러스터링에 기반한 분할 함수를 활성 함수로 사용하며, 다항식 함수로 구성된 연결가중치를 사용함으로써 기존 신경회로망 분류기의 선형적인 특성을 개선한다. 다항식 기반 RBF 신경회로망 구조는 언어적 해석관점에서 "If-then"의 퍼지 규칙으로 표현되며 퍼지 추론 메커니즘에 의해 구동된다. 즉 조건부, 결론부, 추론부 세 가지의 기능적 모듈로 나뉘어 네트워크 구조가 형성된다. 조건부는 FCM 클러스터링을 사용하여 입력 공간을 분할하고, 결론부는 분할된 로컬 영역을 다항식 함수로 표현한다. 마지막으로, 네트워크의 최종출력은 추론부의 퍼지 추론에 의한다. 제안된 다항식 기반 RBF 신경회로망은 다항식 기반 구조의 퍼지 추론 특성으로 인해 출력 공간상에 비선형 판별 함수(nonlinear discernment function)가 생성되어 분류기로서의 성능을 높인다.

3.2.1 다항식 기반 RBF 신경회로망 구조

본 논문에서 제안한 다항식 기반 RBF 신경회로망은 입력층, 1개의 은닉층, 출력층으로 구성된 일반적인 신경회로망 구조에 기반을 둔다. 그러나 기존 기법들과는 달리, 입력 공간의 특성 반영을 위해 활성 함수로 FCM 클러스터링에 의한 분할 함수를 사용하며, 비선형 특성의 판정 경계를 위해, 상수항 연결가중치가 아닌 다항식 연결가중치 $w=f(\cdot)$ 를 이용한다. 뿐만 아니라 제안된 다항식 기반 RBF 신경회로망 구조는 기능적 모듈로 동작되며, 이는 퍼지 추론 메커니즘의 특징을 나타낸다.

본 논문에서 제안한 다항식 기반 RBF 신경회로망 구조는 FCM 클러스터링 분할 함수와 다항식의 적용으로부터 식 (13)의 퍼지 규칙 표현과 같이 언어적 관점에서 해석될 수 있다.

$$\text{If } \mathbf{x} \text{ is } A_i \text{ then } f_{ji}(\mathbf{x}) \quad (13)$$

여기서, \mathbf{x} 는 입력 벡터, A_i 는 FCM 클러스터링에 의한 i

($=1, \dots, c$)번째 그룹의 소속 함수(membership function or partition matrix), $f_{ji}(\mathbf{x})$ 는 $j(=1, \dots, s)$ 번째 출력에 대한 i 번째 퍼지 규칙의 다항식이다. "then" 이전의 조건부는 FCM 클러스터링을 이용함으로써 네트워크 구조 측면에서는 활성 함수를, 언어적 측면에서는 소속 함수의 기능을 수행한다. "then" 이후 결론부의 다항식은 네트워크의 연결가중치로, 퍼지 규칙의 로컬 모델로 동작된다. 추론부에서 네트워크의 최종출력이 퍼지 규칙의 추론 결과로서 구해진다. 이와 같이 제안된 다항식 기반 RBF 신경회로망 구조는 퍼지 규칙에 기반한 네트워크 구조를 가지며, 조건부, 결론부, 추론부와 같이 세 가지 기능적 모듈로 분리되어 동작한다. 그림 2는 기능적 모듈로서의 다항식 기반 RBF 신경회로망 구조를 보여준다.

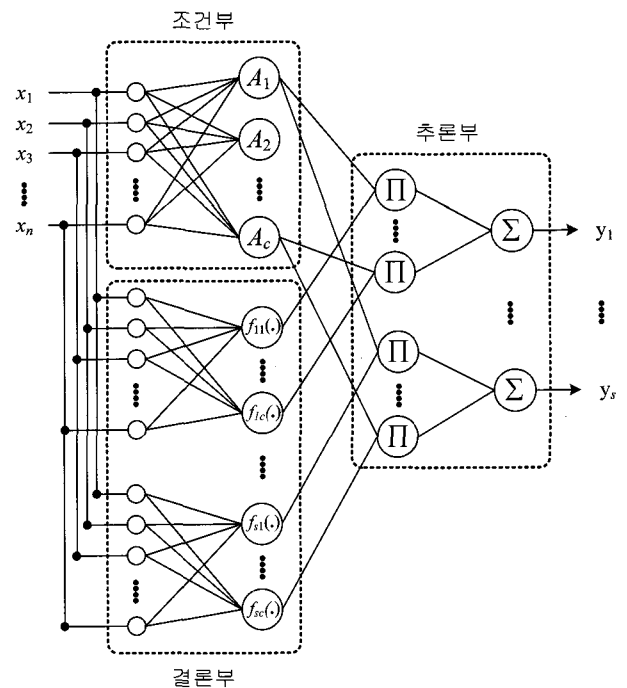


그림 2 다항식 기반 RBF 신경회로망의 구조
Fig. 2 Topology of P-RBF NNs

추론부에서는 "If-then" 퍼지 규칙 기반의 퍼지 추론에 의해 네트워크의 최종출력을 구하게 된다. 그림 5의 추론부의 "Π"로 표기된 뉴런은 각 퍼지 규칙의 소속 함수와 다항식 로컬모델의 곱을 의미하며, "Σ"으로 표기된 뉴런에 의해 입력신호들은 합하여져 그 결과를 출력층 뉴런의 최종 출력으로 내보낸다. 이와 같은 일련 과정은 퍼지 추론 과정과 같으며, Fuzzy Neural Networks[8]와 같은 형태를 갖게 된다. 결론적으로 제안된 다항식 기반 RBF 신경회로망 구조를 보인 그림 2에서 $j(=1, \dots, s)$ 번째 출력의 최종출력은 퍼지 추론에 의한 식 (14)와 같이 표현된다.

$$y_j = g_j(\mathbf{x}) = \frac{\sum_{i=1}^c u_{ji} f_{ji}(\mathbf{x})}{\sum_{k=1}^c u_{kj}} = \sum_{i=1}^c u_{ji} f_{ji}(\mathbf{x}) \quad (14)$$

여기서, u_i 는 그림 2의 $A_i(\mathbf{x})$ 와 같고 모든 클러스터에 대

한 총합은 1이다. 식(14)의 $g_j(\mathbf{x})$ 는 다항식 기반 RBF 신경 회로망의 j 번째 클래스에 대한 판별 함수가 된다.

3.2.2 판별 함수와 학습

본 절에서는 패턴인식시스템에 대한 분류기로서의 다항식 기반 RBF 신경회로망을 정의하고 판별 함수를 생성하기 위한 학습과정을 설명한다.

1) 판별 함수

패턴분류의 문제는 2부류 분류문제(two-class classification problem)와 다 부류 분류문제(multi-class classification problem)로 나눌 수 있다. 분류기를 표현하는 여러 방법이 있지만 일반적으로 많이 사용하는 방법으로는 두 부류 분류 문제에 대해 식(15)를, 다 부류 분류문제에 대해 식(16)과 같은 규칙을 이용한다[9].

$$w_1 \text{ 으로 판정 if } g(\mathbf{x}) > 0; w_2 \text{로 판정 otherwise} \quad (15)$$

$$w_i \text{ 으로 판정 if } g_i(\mathbf{x}) > g_j(\mathbf{x}) \text{ for all } i \neq j \quad (16)$$

여기서 $g_j(\mathbf{x})$, $j=1, \dots, m$ 은 j 번째 클래스에 대한 판별 함수이고 m 은 클래스 수이다. w_j 는 j 번째 클래스를 나타낸다. 2부류 분류문제는 출력층에 1개의 출력뉴런이 존재하고, 식(15)와 같이 1개의 판별 함수만을 사용하여 해당 클래스로 패턴을 분류한다. 다 부류 분류문제인 경우 m 개의 출력 뉴런이 존재하며, 식(16)과 같은 m 개의 판별 함수를 생성하고 해당 클래스로 분류한다. 제안된 다항식 기반 RBF 신경 회로망의 패턴 분류 문제 적용을 위한 판별 함수 표현을 위해 네트워크 최종 출력 식(14)는 식(17)과 같이 표현된다.

$$g(\mathbf{x}) = \mathbf{a}^T \mathbf{f}\mathbf{x} \quad (17)$$

여기서, \mathbf{a} 는 네트워크의 결론부 다항식 함수의 계수를 나타내는 벡터이다. $\mathbf{f}\mathbf{x}$ 는 네트워크 조건부의 소속행렬 U 와 입력 벡터 \mathbf{x} 로 구성된 벡터로 결론부 다항식 함수의 타입에 따라 다음과 같이 정의 된다.

i) Constant;

$$\mathbf{a}^T = [a_{10}, \dots, a_{c0}], \mathbf{f}\mathbf{x} = [u_1, \dots, u_c]^T$$

ii) Linear;

$$\mathbf{a}^T = [a_{10}, \dots, a_{c0}, a_{11}, \dots, a_{c1}, \dots, a_{cn}], \\ \mathbf{f}\mathbf{x} = [u_1, \dots, u_c, u_1x_1, \dots, u_cx_1, \dots, u_cx_n]^T$$

iii) Quadratic;

$$\mathbf{a}^T = [a_{10}, \dots, a_{c0}, a_{11}, \dots, a_{c1}, \dots, a_{cn}, \dots, a_{cnn}] \\ \mathbf{f}\mathbf{x} = [u_1, \dots, u_c, u_1x_1, \dots, u_cx_1, \dots, u_cx_n, \dots, u_cx_n^2]^T$$

iv) Reduced quadratic;

$$\mathbf{a}^T = [a_{10}, \dots, a_{c0}, a_{11}, \dots, a_{c1}, \dots, a_{cn}, \dots, a_{cnn}] \\ \mathbf{f}\mathbf{x} = [u_1, \dots, u_c, u_1x_1, \dots, u_cx_1, \dots, u_cx_n, \dots, u_cx_n^2]^T$$

다항식 기반 RBF 신경회로망의 최종 출력은 위에서 정의된 벡터의 선형결합으로서 구해지고 식(17)로 표현된 분류기의 판별 함수를 생성한다.

2) Gradient Descent Method를 이용한 학습

본 절에서는 다항식 기반 RBF 신경회로망의 식(17)의 판별 함수 $g_j(\mathbf{x})$ 를 생성하기 위한 다항식 기반 RBF 신경회로망 학습 과정을 설명 한다. 학습은 하나의 판별 함수를 가진(출력층 뉴런이 1개인) 2부류 분류문제를 기준으로 하며 다 부류 분류문제는 그림 5와 동일하게 첨자 j 의 추가(출력 뉴런의 추가)로 유도될 수 있다. 다항식 기반 RBF 신경회로망의 학습은 경사 하강법과 모멘텀 방법을 통해 이루어진다. 계수 동정을 위한 학습은 식(18)로 표현되는 오차를 모든 패턴에 대하여 최소화하도록 진행된다.

$$E_q = \frac{1}{2} (t_q - y_q)^2, \quad q=1, \dots, N \quad (18)$$

여기서, E_q 는 q 번째 패턴에 대한 오차, N 은 입력 패턴 수이다. t_q 는 q 번째 패턴에 대한 목표 값이다. y_q 는 q 번째 패턴에 대한 네트워크의 최종출력이며 식(19)와 같다.

$$y_q = \sum_{i=1}^c u_i f_i \quad (19)$$

다항식 기반 RBF 신경회로망의 학습은 f_i 의 네 가지 타입에 따라 식(20)~(23)와 같이 4가지의 경우로 나뉜다.

i) Constant;

$$a_{i0}(p+1) = a_{i0}(p) + \eta(t_q - y_q)u_i + \alpha(a_{i0}(p) - a_{i0}(p-1)) \quad (20)$$

ii) Linear;

$$a_{ij}(p+1) = a_{ij}(p) + \eta(t_q - y_q)u_i x_j + \alpha(a_{ij}(p) - a_{ij}(p-1)) \quad (21)$$

iii) Quadratic;

$$a_{ijk}(p+1) = a_{ijk}(p) + \eta(t_q - y_q)u_i x_j x_k + \alpha(a_{ijk}(p) - a_{ijk}(p-1)) \quad (22)$$

iv) Reduced quadratic;

$$a_{ijk}(p+1) = a_{ijk}(p) + \eta(t_q - y_q)u_i x_k^2 + \alpha(a_{ijk}(p) - a_{ijk}(p-1)) \quad (23)$$

여기서 η 는 학습률, α 는 모멘텀 계수, $p+1$ 은 새로운 값, p 는 현재 값, $p-1$ 은 이전 값을 나타낸다.

4. 얼굴인식 시스템

4.1 전처리 모듈

영상을 수집할 때 동일한 환경과 동일한 조건을 부여한다 하더라도 조명의 매우 예민한 특성과 촬영대상의 고유특성(피부색, 화장정도, 의상의 색조, 표정 등)으로 인해 수집된 영상들은 각각의 색조와 공간적 위치가 다르게 된다. 이와 같은 상황에서 영상들을 얼굴인식 시스템에 적용했을 경우 우수한 성능을 기대하기는 매우 어렵다. 따라서 인식률에 있어서의 우수한 성능을 보장하기 위해 전처리 모듈의 구현은 필수적인 과정이다. 또한 얼굴인식 시스템에서 어떠한

데이터베이스를 사용할 것인가는 중요한 문제이기예 영상복원, 화질개선 등의 전처리 과정의 중요성은 크다고 할 수 있다.

본 논문에서는 전처리 모듈로 앞에서 설명한 바와 같이 히스토그램 평활화와 정규화를 통해 화질개선을 한다.

4.2 특징추출 모듈

얼굴인식을 위한 분류기 설계시, 고차원의 입력 파라미터를 모두 사용할 경우에 생기는 학습과 인식속도의 느려짐의 문제를 해결하기 위해서 차원 축소 기법인 PCA를 사용한다. 이는 고차원 특징 벡터로 이루어진 데이터에 대하여 높은 차원에서의 정보를 유지하면서 낮은 차원으로 차원을 축소시키는 데이터 처리 기법 중의 하나이다.

4.3 인식 모듈

특징추출 이후에 테스트 이미지가 데이터 베이스의 어느 이미지와 유사한 지를 결정하는 작업이 필요하다. 일반적으로 이러한 매칭기법에는 거리 측정, 유사도 측정이 있다. 본 논문에서는 하나의 판별함수를 가진 다항식 기반 RBF 신경 회로망을 설계하여 트레이닝 데이터를 가지고 학습한 분류기를 통해 테스트 이미지에 대한 인식률을 측정한다. 여기서 학습이 진행되는 동안에는 PSO 알고리즘을 사용하여 설계된 분류기의 학습률, 모멘텀 계수, 퍼지화 계수, Feature selection 등 최적의 파라미터를 동조하게 된다.

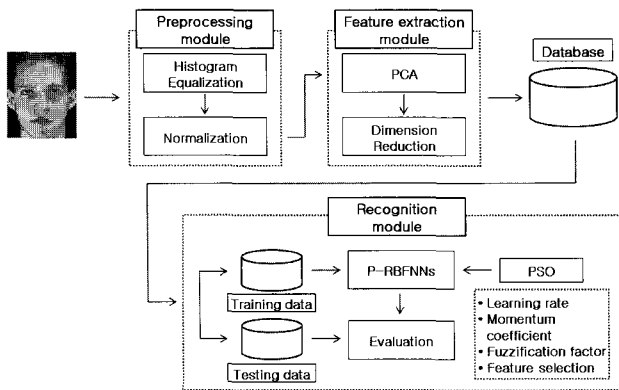


그림 3 얼굴인식을 위한 전체시스템 구성도
Fig. 3 Overall system diagram for face recognition

5. 실험 및 결과

본 장에서는 다항식 기반 RBF 신경회로망을 1:1 Verification 에 적용하여 분류기로서의 성능을 분석한다. 얼굴인식에 사용된 모델은 분류기 모델은 연결가중치가 1차식으로 표현되는 L-RBF 신경회로망이다. 실험은 Yale과 ORL 얼굴 데이터베이스를 사용하였다. 사용된 얼굴 이미지들은 PCA를 통하여 전 처리되어 각각 50, 400차원의 입력 패턴을 생성하게 된다. 50, 400차원의 PCA데이터를 곧바로 입력 데이터 패턴으로 사용하지 않고 큰 고유치를 가지는 순으로 임의의 차원수를 선택하여 에러율을 계산한다. 그 이

후에 에러율이 가장 낮은 차원수를 가지고 PSO를 이용하여 Feature Selection 을 수행한다. 이는 임의의 수의 변수를 갖는 연결가중치 1차식에서의 변수를 줄여주는 의미도 있지만 50개의 특징이 얼굴인식을 하는데 있어서 모두 필요하다고는 말 할 수 없기 때문에 꼭 필요한 특징들을 탐색하는 의미도 갖게 된다. 그림 4는 얼굴 데이터 실험에 사용된 PSO의 Particle의 구조를 보여준다.

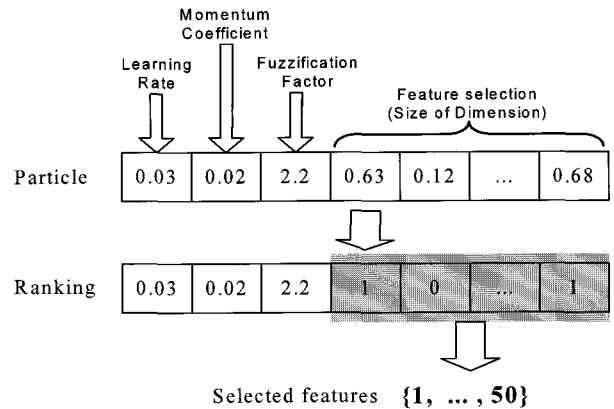


그림 4 얼굴인식에 사용된 PSO의 particle 예
Fig. 4 The example of a particle of PSO

그림 5는 실험에 사용된 Yale과 ORL 얼굴 데이터베이스를 보여준다.

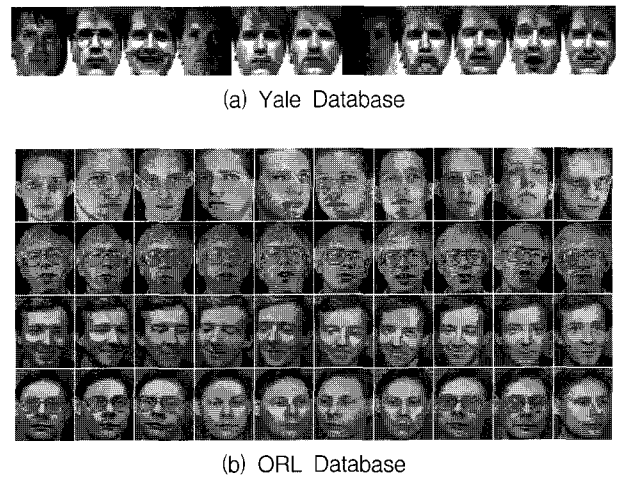


그림 5 얼굴 이미지 데이터
Fig. 5 The face image dataset

실험의 성능 지수는 각 사람 별로 FRR(False Rejection Rate)과 FAR(False Acceptance Rate)을 구하고 최종 성능은 TER(Total Error Rate)의 평균으로 결정 한다.

실험에 사용된 파라미터는 아래의 표 1과 같고 학습 데이터 집합과 Cross Validation 데이터 집합은 분류기를 학습시켜 PSO로 최적의 학습률과 모멘텀 계수를 동조하기 위하여 사용된다. 실험은 먼저 임의의 차원수를 선택하여 1:1인 중 실험을 시행하였고 Yale과 ORL 데이터 결과는 표 2와 같다.

표 1 얼굴 인식에 사용된 실험 파라미터

Table 1 The experiment parameters of face recognition

| 파라미터 | | 설정값 |
|------------|------------------|--------------------------------------|
| 학습 횟수 | | 300 |
| 규칙 수 | | 2 |
| pRBF NN | Training dataset | Yale: 본인4 / 타인42 ORL: 본인4 / 타인78 |
| | CV dataset | Yale: 본인2 / 타인42 ORL: 본인2 / 타인117 |
| | Test dataset | Yale: 본인5 / 타인70 ORL: 본인4 / 타인195 |
| 세대수 | | 10 |
| particle 수 | | 100 |
| PSO | 학습률 | [1e-8, 0.01] |
| | 탐색 범위 모멘텀 계수 | [1e-8, 0.01] |
| | 퍼지화 상수 | [1.1, 3.0] |

표 2 임의의 특징 수에 따른 얼굴인식 결과

Table 2 Result of face recognition with random feature size

| Dataset | No. of features | FRR | FAR | TER |
|---------|-----------------|--------------|--------------|--------------|
| Yale | 20 | 0.413 | 0.008 | 0.035 |
| | 30 | 0.391 | 0.008 | 0.031 |
| | 40 | 0.354 | 0.005 | 0.024 |
| | 50 | 0.342 | 0.006 | 0.021 |
| ORL | 20 | 0.403 | 0.008 | 0.022 |
| | 30 | 0.363 | 0.006 | 0.020 |
| | 40 | 0.305 | 0.005 | 0.011 |
| | 50 | 0.291 | 0.004 | 0.009 |
| | 100 | 0.358 | 0.002 | 0.008 |
| | 200 | 0.567 | 0.001 | 0.012 |
| | 400 | 0.692 | 0.001 | 0.019 |

결과를 통해 FRR 값이 가장 적은 50개의 특징을 가지고 다시한번 feature selection 기능이 추가된 PSO를 이용하여 실험을 시행하였고 Yale과 ORL 데이터 결과는 각각 표 3과 표 4와 같다.

표 3과 표 4의 No. of features는 해당 사람에 대한 분류기를 학습시키는데 사용된 PCA의 특징개수이며, 약 50개의 특징 중 약 40개 가까이 특징을 선택하여 입력 벡터를 구성하여 얼굴 인식을 수행한다. 위의 2개표의 결과에서 알 수 있듯이 두 가지 얼굴 데이터 모두 FAR의 성능이 FRR보다 더 좋게 나타났다. 이는 학습되어지는 타인의 이미지는 충분하고 본인의 이미지는 4장 밖에 없기 때문에 네트워크의 학습이 충분이 이루어 지지 않은 결과라 할 수 있다.

그림 6은 Yale 데이터는 20, 30, 40, 50개의 특징 ORL 데이터는 20, 30, 40, 50, 100, 200, 300, 400개의 특징을 각각 사용하여 얼굴 인식을 수행하였을 경우와 feature selectin 기능을 추가 한 경우의 비교표이다. feature selection은 1가지 경우이므로 직선으로 표현되었으며 임의의 갯수의 특징을 사용한 결과보다 비슷하거나 더 좋은 성능을 보임을 알 수 있었다.

표 3 Yale 얼굴 데이터 실험결과

Table 3 The result of Yale dataset

| Person | FRR | FAR | TER | No.of features |
|------------|--------------|--------------|--------------|----------------|
| 1 | 0.000(0/3) | 0.000(0/56) | 0.000(0/59) | 40 |
| 2 | 0.333(1/3) | 0.000(0/56) | 0.017(1/59) | 40 |
| 3 | 1.000(3/3) | 0.018(1/56) | 0.068(4/59) | 37 |
| 4 | 0.000(0/3) | 0.000(0/56) | 0.000(0/59) | 36 |
| 5 | 0.333(1/3) | 0.000(0/56) | 0.017(1/59) | 46 |
| 6 | 0.000(0/3) | 0.000(0/56) | 0.000(0/59) | 38 |
| 7 | 0.667(2/3) | 0.000(0/56) | 0.034(2/59) | 42 |
| 8 | 0.000(0/3) | 0.000(0/56) | 0.000(0/59) | 33 |
| 9 | 0.667(2/3) | 0.000(0/56) | 0.034(2/59) | 39 |
| 10 | 0.333(1/3) | 0.000(0/56) | 0.017(1/59) | 37 |
| 11 | 0.000(0/3) | 0.018(1/56) | 0.017(1/59) | 40 |
| 12 | 0.667(2/3) | 0.000(0/56) | 0.034(2/59) | 39 |
| 13 | 0.000(0/3) | 0.000(0/56) | 0.000(0/59) | 43 |
| 14 | 0.000(0/3) | 0.018(1/56) | 0.017(1/59) | 41 |
| 15 | 0.667(2/3) | 0.036(2/56) | 0.068(4/59) | 39 |
| AVG | 0.311 | 0.006 | 0.021 | 39.3 |

표 4 ORL 얼굴 데이터 실험 결과

Table 4 The result of ORL dataset

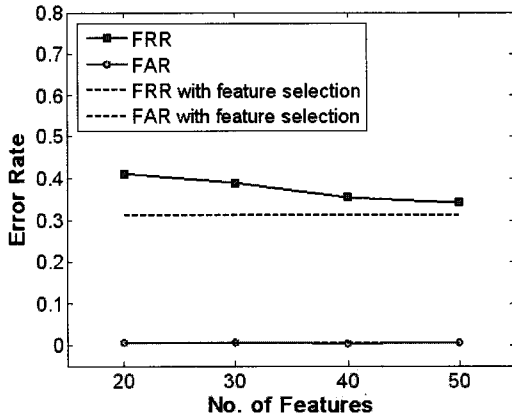
| Person | FRR | FAR | TER | No.of features |
|------------|--------------|--------------|--------------|----------------|
| 1 | 0.500(2/4) | 0.010(2/195) | 0.020(4/199) | 41 |
| 2 | 0.000(0/4) | 0.000(0/195) | 0.000(0/199) | 44 |
| 3 | 0.000(0/4) | 0.000(0/195) | 0.000(0/199) | 44 |
| 4 | 0.250(1/4) | 0.005(1/195) | 0.010(2/199) | 43 |
| 5 | 0.750(3/4) | 0.000(0/195) | 0.015(3/199) | 45 |
| 6 | 0.250(1/4) | 0.005(1/195) | 0.010(2/199) | 45 |
| 7 | 0.000(0/4) | 0.000(0/195) | 0.000(0/199) | 38 |
| 8 | 0.000(0/4) | 0.005(1/195) | 0.005(1/199) | 44 |
| 9 | 0.250(1/4) | 0.000(0/195) | 0.005(1/199) | 34 |
| 10 | 0.500(2/4) | 0.000(0/195) | 0.010(2/199) | 41 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 35 | 0.000(0/4) | 0.000(0/195) | 0.000(0/199) | 40 |
| 36 | 0.000(0/4) | 0.000(0/195) | 0.000(0/199) | 41 |
| 37 | 0.000(0/4) | 0.005(1/195) | 0.005(1/199) | 41 |
| 38 | 0.500(2/4) | 0.000(0/195) | 0.010(2/199) | 45 |
| 39 | 0.500(2/4) | 0.015(3/195) | 0.025(5/199) | 45 |
| 40 | 0.250(1/4) | 0.005(1/195) | 0.010(2/199) | 45 |
| AVG | 0.256 | 0.003 | 0.008 | 42 |

6. 결 론

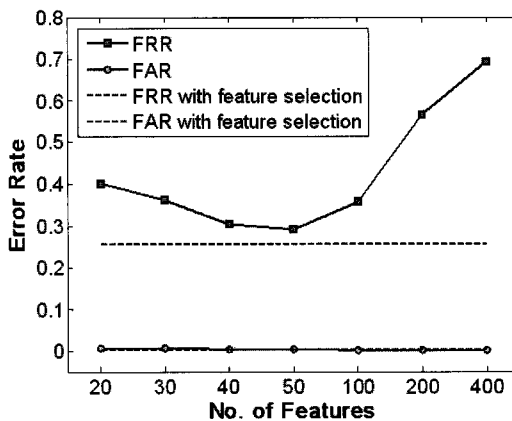
본 논문에서는 얼굴 인식을 수행할 때 PCA와 입자 군집 최적화 알고리즘을 이용한 얼굴이미지에서 특징선택 방법을 제안하였다. 그리고 얼굴인식을 위한 알고리즘으로는 다항식 기반 RBF 신경회로망을 이용하였다. 이는 고차원으로 이루어진 입력 파라미터의 학습에 대한 문제를 해결할 수 있는 패턴 분류기이다.

입력 데이터 형성을 위해서 Yale과 ORL 얼굴 데이터 베

이스를 가지고 이미지 전처리과정을 거쳐 화질개선을 하고 PCA 변환을 통한 고차원의 얼굴이미지 데이터를 차원 축소하여 특징벡터를 추출하였다. 여기서 추출된 특징벡터에서 설계자 임의대로 특징의 차원수를 나누고 인식을 수행한 결과에서 인식률이 가장 높은 차원수를 발견하였고, 본 논문에서 제안한 입자 군집 최적화 알고리즘의 feature selection 기능을 이용하여 다시 인식을 수행한 결과 최적화된 특징의 차원수에서 좀 더 좋은 성능을 보임을 증명하였다.



(a) Yale Database



(b) ORL Database

그림 6 Feature selection의 유무에 따른 성능 비교

Fig. 6 Performance comparison between feature selection and arbitrary selection


감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음 [GRRC 수원2009-B2, U-city 보안감시 기술협력센터] 그리고 2009년도 정부 (교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2009-0074928).

참 고 문 헌

- [1] Kirby, M. and Sirovich, L., "Application of the KL Procedure for the Characterization of Human Faces," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 12, No. 1, pp. 103-108, 1990.
- [2] Turk, M. and Pentland, A., "Eigenfaces for Recognition," J. Cognitive Neuroscience, Vol. 3, No. 1, pp. 71-86, 1991.
- [3] J. Kennedy and R. Eberhart, "Particle swarm optimization," Proc. IEEE Int. Conf. Neural Networks, vol. 4, pp. 1942-1948, 1995.
- [4] M.J. Er, S.Q. Wu, J.W. Lu, H.L. Toh, "Face recognition with radical basis function (RBF) neural networks," IEEE Trans. Neural Networks, vol. 13, No. 3, pp. 697-710, 2002.
- [5] Zhou, W. ; Pu, X. & Zheng, Z. "Parts-Based Holistic Face Recognition with RBF Neural Networks," In Lecture Notes in Computer Science, (110-115), 3972, 2006.
- [6] Park, C. ; Ki, M. ; Namkung, J. & Paik, J.K. "Multimodal Priority Verification of Face and Speech Using Momentum Back-Propagation Neural Network," In Lecture Notes in Computer Science, (140-149), 3972, 2006.
- [7] J. Kennedy, "The particle swarm: Social adaptation of knowledge," Proc. IEEE Int. Conf. Evolutionary Comput., pp. 303-308, 1997.
- [8] K. E. Parsopoulos and M. N. Vrahatis, "On the Computation of All Global Minimizers Through Particle Swarm Optimization," IEEE Trans. Evolutionary Computation, vol. 8, no. 3, pp. 211-224, 2004.
- [9] R.O. Duda, P.E. Hart, D.G. Stork, "Pattern Classification," 2nd ed., Wiley-Interscience, 2000.

저 자 소 개



김 응 기 (金 雄 基)

2007년 : 수원대 컴퓨터학과 졸업.
 2007년~현재 : 동 대학원 전기공학과 석사과정.
 관심분야 : 패턴인식, 컴퓨터 비전, 퍼지 논리시스템 등
 Tel : (031) 222-6544
 E-mail : wgkim@suwon.ac.kr



오 성 권 (吳 聖 權)

1981년 : 연세대학교 전기공학과 졸업.
1983년 : 동 대학원 전기공학과 졸업(석사). 1983~1989년 : 금성산전연구소(선임 연구원). 1993년 : 연세대 대학원 전기공학과 졸업(공학박사). 1996~1997년 : 캐나다 Manitoba대학 전기 및 컴퓨터공학과

Post-Doc. 1993~2005년 : 원광대 전기전자 및 정보공학부 교수 2005년~현재 : 수원대 전기공학과 교수. 2002년~현재 : 대한전기학회, 퍼지및지능시스템학회 및 제어자동화시스템 공학회 편집위원.

Tel : (031) 229-8162

Fax : (031) 220-2667

E-mail : ohsk@suwon.ac.kr



김 현 기 (金 賢 起)

1977년 : 연세대학교 전기공학과 졸업.
1985년 : 동 대학원 전기공학과 졸업(공학석사).

1991년 : 동 대학원 졸업(공학박사).

1997년~현재 : 경기지역 산학연 기술지원단 단장. 1998년~현재 : 산업기술정책

연구소 심의위원. 2000년~현재 : 사단법인 산학연 권소사업 전국협의회 회장. 1989년~현재 : 수원대학교 전기공학과 교수. 관심분야 : 시스템자동화 및 감시제어, 지능형모델링 및 제어 등.

Tel : (031) 220-2666

Fax : (031) 220-2667

E-mail : hkkim@suwon.ac.kr