

제한된 자원을 갖는 장치에서 효과적인 얼굴 인증 방법

(An Effective Face Authentication Method for
Resource-Constrained Devices)

이 경희 [†] 변 혜란 [‡]

(Kyunghee Lee) (Hyeran Byun)

요약 사용자를 인증하는데 생체인식(biometrics)을 사용하는 것은 보안성과 편리성에서 우수함에도 불구하고, 생체 정보를 사용하는 전형적인 인증 알고리즘은 스마트카드(smart cards)와 같은 자원이 한정된 장치에서는 실행되지 못할 수도 있다. 따라서, 제한된 자원을 갖는 장치에서 생체인식 과정이 수행되기 위해서는 적은 메모리와 처리 능력을 요구하는 가벼운 인증 알고리즘의 개발이 필요하다. 또한 생물학적 특징들 중에서 얼굴에 의한 인증은 인간에게 보다 친숙하고 얼굴 영상 획득이 비강제성을 떤다는 점에서 사용하기 가장 편리한 생체인식 기술이다.

본 논문에서는 생체인식 기술 연구의 일환으로 새로운 얼굴 인증 알고리즘을 제안한다. 이 얼굴 인증 알고리즘은 두 가지 면에서 새로운 특성을 갖는다. 그 하나는 유전자 알고리즘(GA: Genetic Algorithms)에 의해 추출된 특징 집합(feature set)을 입력벡터로 사용하는 Support Vector Machines(SVM)을 얼굴 인증에 이용함으로써 메모리 요구량을 감소시킨다는 것이다. 다른 하나는, 필요에 따라 특정 집합의 크기 조절에 대한 시스템 파라미터를 조절함으로써, 인식률은 다소 감소하더라도 인증 과정에 필요한 메모리양을 더욱 더 감소시킬 수 있다는 것이다. 이러한 특성은 메모리양이 한정된 장치에서 얼굴 인증 알고리즘을 수행할 수 있게 하는 데 상당히 효과적이다.

다양한 변화가 있는 얼굴 데이터베이스들에 대하여 실험한 결과, GA에 의해 선택된 식별력이 우수한 특징들을 SVM의 입력벡터로 사용하는 제안한 얼굴 인증 알고리즘이, GA에 의한 특징 선택 과정이 없는 알고리즘보다 정확성과 메모리 요구량에서 우수한 성능을 보임을 알 수 있다. 또한 시스템 파라미터의 변경 실험에 의해 선택될 특징의 개수가 조절될 수 있음을 보인다.

키워드 : 생체인식, 얼굴 인증, 에스브이엠(SVM: Support Vector Machines), 유전자 알고리즘, 자원 제약 장치

Abstract Though biometrics to authenticate a person is a good tool in terms of security and convenience, typical authentication algorithms using biometrics may not be executed on resource-constrained devices such as smart cards. Thus, to execute biometric processing on resource-constrained devices, it is desirable to develop lightweight authentication algorithm that requires only small amount of memory and computation. Also, among biological features, face is one of the most acceptable biometrics, because humans use it in their visual interactions and acquiring face images is non-intrusive.

We present a new face authentication algorithm in this paper. Our achievement is two-fold. One is to present a face authentication algorithm with low memory requirement, which uses support vector machines (SVM) with the feature set extracted by genetic algorithms (GA). The other contribution is to suggest a method to reduce further, if needed, the amount of memory required in the authentication at the expense of verification rate by changing a controllable system parameter for a feature set size. Given a pre-defined amount of memory, this capability is quite effective to mount our algorithm on memory-constrained devices.

The experimental results on various databases show that our face authentication algorithm with

[†] 비 회 원 : 한국전자통신연구원 정보보호연구단 생체인식기술연구팀 연구원
uniromi@etri.re.kr

hrbyun@cs.yonsei.ac.kr

^{‡‡} 종신회원 : 연세대학교 컴퓨터과학과 교수

논문접수 : 2003년 4월 17일
심사완료 : 2004년 6월 29일

SVM whose input vectors consist of discriminating features extracted by GA has much better performance than the algorithm without feature selection process by GA has, in terms of accuracy and memory requirement. Experiment also shows that the number of the feature to be selected is controllable by a system parameter.

Key words : biometrics, face authentication, support vector machines, genetic algorithms, resource-constrained devices

1. 서 론

최근 스마트카드(smart cards) 시스템을 비롯한 전자 또는 임베디드(embedded) 시스템의 보안성을 강화하기 위하여, 사용자 인증에 지문, 망막, 홍채, 음성, 얼굴 등 인간의 생물학적 특징을 참조하는 생체인식(biometrics)을 사용하는 방법에 관한 연구가 증가하는 추세이다. 4 자리수 또는 6자리수의 개인 식별 번호(PIN: Personal Identification Number)와 비교하여, 카드에 저장된 중요한 데이터는 생체 정보를 사용함으로써 더욱 안전하게 보호될 수 있다. 더욱이 카드 소유자의 지문, 홍채 패턴 등을 도난 되거나 막각되지 않는 장점이 있다.

스마트카드 또한 생체인식에서 중요한 역할을 한다. 실제로 인증 시스템에서의 생체 정보 템플릿들(biometrics templates)은 중앙의 데이터베이스에 종종 저장되는데, 이 경우 생체 정보의 소유자도 모르게 도용될 수 있는 문제점이 있다. 따라서 데이터베이스 저장 부분을 수백만 개의 스마트카드로 분산시켜 그것을 소유자에게 주어 보관하게 하여 이를 해결할 수 있다. 대부분의 이러한 시스템은 생체 정보 인증 과정이 스마트카드 프로세서의 외부에서 수행되는 공통적인 특성을 갖는다[1]. 예를 들면, 지문 인식 기반의 스마트카드 시스템인 경우, 카드 내부에 저장된 지문 마스터 템플릿(master template) 정보가 지문 인증을 수행하는 외부 지문 판독기에게 보안성이 결여된 채로 전해진다. 따라서 보안성을 강화하기 위하여, 지문 샘플과 마스터 템플릿의 비교 과정이 외부 판독기에 의해서가 아니라 카드 내부의 프로세서에서 수행될(즉, 매치 온 카드(match-on-card)) 필요가 있다. 그러나, 메모리 크기와 카드 내의 프로세서의 처리 능력은 매우 제한되어 있으므로, 적은 메모리와 처리 능력을 요구하는 가벼운 인증 알고리즘의 개발이 요구된다.

생물학적 특징들 중에서 얼굴에 의한 인증은 인간에게 보다 친숙하고 얼굴 영상 획득이 비강제성을 띤다는 점에서 사용하기 가장 편리한 생체인식 기술이다. 그러나, 얼굴 영상은 얼굴의 3차원 방향 변화, 빛의 방향 및 세기 변화, 머리모양, 표정 변화에 따라 차이가 현저하므로, 자동 얼굴 인식 개발은 해결하기 어려운 문제이다. 얼굴 인식에 관한 기존의 연구들은 전체적인(holistic

stic or transform) 접근 방법과 분석적인(analytic or attribute-based) 접근 방법으로 크게 분류해 볼 수 있다[2]. 전체적인 접근 방법은 패턴의 전역적인 특성을 고려하는 것으로, 얼굴 영상 영역을 정규 직교 기저 벡터(orthonormal basis vectors)의 집합을 사용하여 표현하는 것이다. 현재 가장 널리 알려진 기저 벡터는 Turk 등이 제안한 고유얼굴(eigenface)이다[3]. 각 고유 얼굴은 얼굴 영상 집단의 공분산(covariance)의 분석으로부터 얻어지고, 두 개의 얼굴이 고유얼굴 특징 공간에서 충분히 가깝다면 동일 얼굴로 간주된다. 이러한 접근 방법의 다양한 연구들이 많이 진행되고 있다. 얼굴 모델에 기반한 형판 정합 기반(template matching-based) 얼굴 인식 시스템이 이러한 전체적 접근 방법에 속한다고 할 수 있다. 분석적인 접근 방법은 눈, 코, 입 등과 같은 얼굴의 요소들을 얼굴 영상으로부터 추출하여, 이러한 얼굴의 요소 특징들 간의 지형적인 특성들의 차이를 인식에 사용하는 것이다[4,5]. 이러한 특징 기반 기법은 빠른 인식 속도와 적은 메모리를 요구한다는 장점을 가지는데 반해, 특징점 선택과 추출이 어렵다는 단점이 있다. Brunelli 등은 이와 같은 지형적 특징을 이용하여 90%의 얼굴 인식률을 이루었다[5]. 또한 최근의 연구에는 전체적인 방법과 분석적인 방법을 결합하여 사용한 연구[2]도 진행되고 있다.

최근 패턴 분류에서 주목을 받고 있는 이진 분류기(binary classifiers)인 Support Vector Machines (SVM)[6,7]을 이용하여 얼굴 탐지 및 얼굴 인식 분야에 적용하는 연구가 진행되고 있다. 실제로 SVM을 이용하여 영상에서 얼굴 탐지에 관한 연구[8], 얼굴의 포즈 인식에 관한 연구[9], 얼굴 인식에 관한 연구[10-12] 등이 제안되고 있다. 또한 Phillips는 PCA (Principal Component Analysis)기반 얼굴 인증 방법과 비교하여 SVM 기반 얼굴 인증 시스템이 더 좋은 성능을 나타냄을 보여주었다[13].

본 논문에서는 생체인식 기술을 이용한 연구의 일환으로 사용자 인증을 위한 얼굴 인증 방법에 관하여 중점적으로 연구한다. SVM의 입력벡터로 유전자 알고리즘(GA: Genetic Algorithms)[14]에 의해 선택된 특징들(features)을 사용하는 얼굴 인증 알고리즘을 제안하

고, 또한 메모리 요구량을 조절할 수 있는 방법을 제공한다. 제안하는 알고리즘은 [15]에서 일부 설명되었는데, 유전자 알고리즘에 의해 식별력이 우수한 특징들만을 선택하여 사용함으로써 메모리 요구량을 현저하게 감소시킨다. 또한 필요하다면 특징 집합(feature set)의 크기에 관한 시스템 파라미터를 조절함으로써, 인식률은 다소 감소하더라도 인증 과정에 필요한 메모리양을 더욱 더 감소시킬 수 있다.

Yale 얼굴 데이터베이스[16], ORL(Cambridge Olivetti Research Lab) 얼굴 데이터베이스[17], 포항공대 얼굴 데이터베이스[18]를 사용하여 실험한 결과, 유전자 알고리즘에 의해 선택된 식별력이 우수한 특징들을 SVM의 입력벡터로 사용하는 제안한 얼굴 인증 알고리즘이, 유전자 알고리즘에 의한 특징 선택 과정이 없는 알고리즈다 보다 정확성과 메모리 요구량에서 더 좋은 성능을 보였다. 또한 다른 실험들은 선택되는 특징의 개수가 시스템 파라미터에 의해 조절될 수 있음을 보여 준다. 이러한 특성들에 의해 스마트카드와 같은 자원이 한정된 장치에서 생체 데이터를 포함한 중요한 정보를 저장할 수 있고, 어떠한 데이터의 유출도 없이 장치 내부에서 안전하게 인증 과정을 수행할 수 있게 된다.

본 논문의 구성은 다음과 같다. 1장에서는 제한된 자원을 갖는 장치에서의 생체인식 연구의 필요성과 제안하는 얼굴 인증 시스템에 대해 간략하게 살펴보았고, 2장에서는 본 연구와 관련이 깊은 연구 배경들에 대해 간략하게 기술한다. 다음 3장에서는 본 논문에서 제안하는 얼굴 인증 시스템의 생성 과정과 인증 과정에 대하여 사용된 방법을 중심으로 구체적으로 살펴보고, 또 실제로 구현된 얼굴 인증 시스템에 대해서 살펴본다. 4장에서는 시스템 성능 실험 및 그 결과 분석을 기술하고, 마지막으로 5장에서 본 연구에 대한 결론을 서술한다.

2. 연구배경

이 장에서는 본 논문에 사용된 주요 알고리즘인 Support Vector Machines, 유전자 알고리즘에 대하여 간략하게 살펴보고, 또한 하나의 특징으로 사용된 주요 소분석(Principal Component Analysis)에 관하여 간략하게 기술한다.

2.1 Support Vector Machines(SVM)

SVM은 V. Vapnik과 그의 공동 연구자들에 의해 패턴 인식에서 효과적이고 일반화된 방법으로 최근에 제안되었다[6]. SVM은 구조적 위험 최소화(structural risk minimization)의 개념에 기반한 최적의 선형 결정 평면(optimal linear decision surface)을 찾는 이진 분류 방법이다. 결정 평면은 학습 집합의 원소들의 가중화된 조합(weighted combination)이다. 이러한 학습 집합

의 원소들을 *support vectors*라고 부르고, 이것은 두 클래스 간의 경계면을 나타낸다.

N 개의 학습 샘플들 (\mathbf{x}_i, y_i) 가 있다고 하자, 여기서 $\mathbf{x}_i \in R^d$ 이고 y_i 는 관련된 레이블이다($y_i \in \{-1, 1\}$). 선형 분리 데이터를 가정할 경우, 최대 여백 분류(maximum margin classification)의 목표는 support vectors의 거리가 최대화되는 초월면(hyperplane)에 의해 두 개의 클래스를 분리하는 것이다. 이러한 초월면은 최적 경계 초월면(OSH: optimal separating hyperplane)이라고 불린다. OSH는 식 (1)과 같이 나타낼 수 있다.

$$f(\mathbf{x}) = \sum_{i=1}^N \alpha_i y_i (\mathbf{x}_i^T \mathbf{x}) + b \quad (1)$$

여기서 계수들 α_i 와 b 는 2차 프로그래밍(quadratic programming) 문제의 해이다[6]. Support vectors에 대한 α_i 는 0이 아닌 값을 갖는다.

선형 분리가 불가능한 데이터인 경우에는, SVM은 입력벡터를 선형 초월면이 발견되는 고차원의 특징 공간 F 로 비선형 매핑을 할 수 있다. 다음의 식 (2)와 같은 고차원 매핑은 비선형 SVM을 형성하는 데 사용된다.

$$\phi : R^d \mapsto F \quad (2)$$

목표 함수(objective function)와 결정 함수(decision function) 두 가지 모두 데이터 벡터 \mathbf{x} 의 내적에 의해 표현됨에 따라, 계산적으로 복잡한 매핑 $\phi(\cdot)$ 는 명시적으로 계산할 필요가 없다. Mercer의 조건을 만족하는 커널(kernel) 함수 $K(\mathbf{x}, \mathbf{x}_i)$ 는, $(\mathbf{x} \cdot \mathbf{x}_i)$ 대신에 사용되는 $(\phi(\mathbf{x}) \cdot \phi(\mathbf{x}_i))$ 를 다시 치환할 수 있다[6]. 따라서 결정 평면은 다음 식 (3)과 같은 수식을 갖는다.

$$f(\mathbf{x}) = \sum_{i=1}^N \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (3)$$

다음의 커널 함수들이 SVM에 종종 사용되는데, 다항식 커널(polynomial kernels)은 다음의 식 (4)와 같이 주어진다.

$$K(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}^T \mathbf{x}_i + 1)^p \quad (4)$$

또한 RBF 커널(Radial Basis Function kernels)은 식 (5)와 같으며,

$$K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x} - \mathbf{x}_i\|^2\right) \quad (5)$$

tangent hyperbolic kernels은 다음 식 (6)과 같다.

$$K(\mathbf{x}, \mathbf{x}_i) = \tanh(\alpha \cdot \mathbf{x}^T \mathbf{x}_i + \beta) \quad (6)$$

2.2 유전자 알고리즘(GA: Genetic Algorithms)

유전자 알고리즘(GA: Genetic Algorithms)[14]은 자연계의 유전자 시스템의 기작을 본떠서 만든 적응적이

고 장인한 계산 과정이다. 유전자 알고리즘은 해결되어야 할 최적화 문제의 후보 해를 표현하는 개체들로 이루어진 일정수의 집단을 유지한다. 각 개체들은 전형적으로 n -비트 이진 벡터로 표현되며, 따라서 탐색 공간은 n -차원의 부울 공간에 해당되게 된다. 또한 각 후보 해들은 주어진 응용 분야에 관한 종합적인 적합도(fitness)에 기반하여 평가된다. 진화 알고리즘은 적합도에 의존하는 확률적 방법의 형식을 사용하여, 현 세대의 집단으로부터 개체들을 선택하여 다음 세대의 개체들을 생성한다. 유전자 연산자(genetic operators)는 선택된 개체들에 적용되어, 다음 세대를 구성할 새로운 개체들을 얻는데 사용된다. 유전자 알고리즘에 사용되는 일반적인 연산자는 돌연변이(mutation)와 교차(crossover)이다. 돌연변이 연산자는 하나의 스트링(string)에 적용되어 일반적으로 하나의 비트를 랜덤하게 바꾼다. 반면에 교차 연산자는 2개의 부모 스트링에 작용하여 2개의 자손을 생성한다. 적합도에 의존한 선택 과정과, 각 개체들의 다음 세대를 생성하는 데 유전자 연산자의 적용은 만족할만한 해가 발견될 때까지 반복된다. 최근에는 일반적인 분류 문제에 대하여 GA 기반 표현 변환(GA-based representation transformation)이 연구[19,20]되었는데, 해당 문제를 적절하게 표현하기 위하여 이에 적합한 특징들을 선택하고 생성할 수 있게 하였다.

2.3 주요소 분석(PCA: Principal Component Analysis)

PCA는 모든 투영된 샘플들의 분산을 최대화하여 차원을 감소시키는 선형 투영(linear projection)을 선택하는 표준 기법이다. PCA의 기본 접근 방법은 공분산 행렬의 고유벡터(eigenvectors)를 계산하고, 상위 고유벡터의 선형 조합으로 원래 데이터에 근접해가는 것이다[3].

$N \times N$ 크기의 M 개의 얼굴 영상들의 학습 데이터 집합을 $\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M$ 로 나타낼 때, 이 데이터 집합의 평균 얼굴은 다음 식 (7)과 같이 나타낼 수 있다.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (7)$$

각각의 얼굴과 평균 얼굴과의 차영상은 벡터 $\Phi_i = \Gamma_i - \Psi$ 로 나타낸다.

벡터 Φ_k 와 스칼라 λ_k 는 각각 다음 식 (8)의 공분산 행렬의 고유벡터(eigenvectors)와 고유치(eigenvalues)이다.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (8)$$

여기서 행렬 $A = [\Phi_1 \Phi_2 \dots \Phi_M]$ 이다. 이러한 고유벡터들은 원영상과 같은 차원이고 얼굴과 비슷한 모양을 나타내기 때문에 고유얼굴(eigenface)이라고 불린다.

고유얼굴이 주어지면 각각의 얼굴은 가중치들의 벡터

로 표현될 수 있다. 가중치들은 얼굴 영상(Γ)을 고유얼굴(Φ_k) 성분에 대하여 투영하여 다음 식 (9)에 의하여 얻어진다.

$$\omega_k = \Phi_k (\Gamma - \Psi) \quad \text{for } k = 1, \dots, M' \quad (9)$$

여기서 상위 M' 개의 고유치에 해당하는 M' 개의 중요 고유얼굴($\Phi_1, \dots, \Phi_{M'}$)이 선택된다. 가중치들은 하나의 입력 얼굴 영상을 표현하는데, 고유얼굴 각각의 기여도를 나타내는 하나의 벡터 $\Omega^T = [\omega_1, \omega_2, \dots, \omega_{M'}]$ 를 생성한다.

3. GA와 결합된 SVM기반 얼굴 인증 시스템

이 장에서는 제안하는 얼굴 인증 시스템의 생성 과정과 생성된 얼굴 인증 시스템을 이용한 인증 과정에 대하여 상세히 설명하고, 자원 제약이 있는 USB 토큰 또는 스마트카드에 적용하여 구현된 얼굴 인증 시스템의 예를 살펴보기로 한다.

3.1 얼굴 인증 시스템의 생성 과정

본 논문에서 제안하는 얼굴 인증 시스템의 생성 과정의 처리 흐름도는 그림 1과 같다. 이 절에서는 처리 흐름도의 각 단계를 자세히 설명한다. 먼저 얼굴 인증 시스템의 생성은 전처리 과정으로 시작한다.

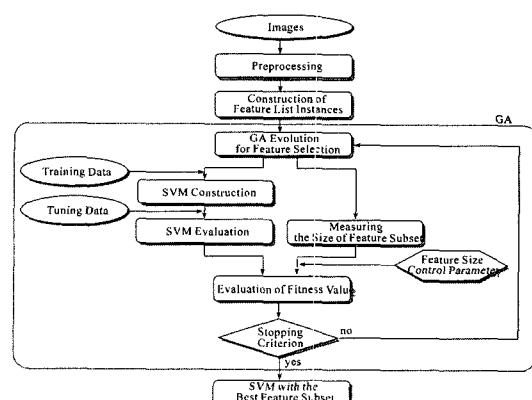


그림 1 제안하는 얼굴 인증 시스템의 생성 과정

3.1.1 전처리(Preprocessing)

영상으로부터 양쪽 눈의 거리를 기준으로 하여 얼굴 영역을 잘라낸 후, 64×64 크기의 얼굴로 다시 변환하여 인증 시스템이 얼굴의 크기에 영향을 받지 않도록 정규화 한다. 이러한 정규화 과정을 위해 입력 영상으로부터 눈을 찾는 방법은 기존의 어떠한 눈 텀지 알고리즘들도 사용될 수 있다. 또한 양쪽 눈을 연결한 선이 기울어져 있을 때에는 영상을 회전하여 기울기에 대한 보정도 수

행한다. 그 후 히스토그램 평활화(histogram equalization)를 적용하여 영상의 밝기(brightness)와 콘트라스트(contrast)의 영향을 감소하게 한다.

3.1.2 특징 목록 인스턴스들(Feature List Instances)의 생성

특징 목록(feature list)의 원소는 특징이 무엇인지를 나타내고, 특징 목록 인스턴스(feature list instance)는 특징 목록의 원소들의 값을 나타낸다. GA 과정 중의 반복적인 계산을 방지하기 위하여 특징 선택 과정에 사용될 특징 목록 인스턴스들을 미리 계산해 둔다. 본 논문에서는 두 가지 종류의 특징 목록을 사용하는데, 하나는 영상의 밝기값(intensity values)의 평균과 에지값(edge values)의 평균을 사용하는 것이고, 다른 하나는 PCA의 프로젝션 계수로 이루어진 것이다. 이러한 특징 목록 이외에도 다양한 특징 목록들이 제안된 시스템에 적용될 수 있다.

영상의 밝기값의 평균과 에지값의 평균으로 이루어진 특징 목록은 64×64 크기의 얼굴 영상으로부터 계산된다. 그림 2에서 보듯이 얼굴 영상에 대하여 8×8 크기의 윈도우를 4 팩셀(pixel)씩 오버랩하면서 차례로 스캔하면, 결국 225개의 스캔 윈도우가 생성된다. 각 영상에 대한 특징 목록 인스턴스는, 이러한 225개의 윈도우에 대하여 각 윈도우 내의 팩셀들의 밝기 평균과 소벨 에지 연산자(Sobel edge operator)[21]를 적용한 후의 평균을 계산한 값으로 구성된다.

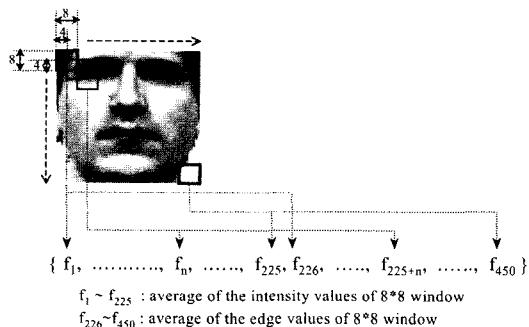


그림 2 밝기값과 에지값의 평균을 사용한 특징 목록

또 다른 특징 목록은 PCA 프로젝션 계수를 원소로 사용하는 것이다. 본 논문에서는 입력 영상을 상위 M' 개의 고유치에 대응되는 고유얼굴에 투영함으로써 얻어지는 식 (9)의 가중치 벡터 Ω^T 를 특징 목록으로 사용한다.

3.1.3 GA를 사용한 식별력이 우수한 특징들의 선택
제안하는 얼굴 인증 시스템에서는 GA 과정을 통하여 주어진 특징 목록의 모든 부분집합들을 탐색하도록 한

다. 지금부터 주어진 특정 목록의 부분집합을 특정 부분집합(feature subset)이라고 표기한다. GA 과정이 진행되는 동안 우수한 분리 능력과 작은 크기의 특정 부분집합에 더 높은 선호도를 준다. 선택된 특정 부분집합 각각은 SVM을 이용하여 평가된다. 이러한 전체 과정은 가장 좋은 특정 부분집합을 찾을 때까지 반복을 통하여 진화해간다. 그림 3은 각각의 염색체가 특정 목록의 부분집합을 표현하는 일정한 길이의 이진열(binary string)로 나타낸을 보여준다. 염색체의 길이는 특정 목록의 크기(즉 전체 특징들의 개수)와 같고, 염색체의 각 비트는 그 비트에 대응되는 특징의 선택 여부를 표시한다. 비트의 값 “1”은 그 비트에 해당하는 특징이 선택되었음을 나타내고, “0”은 선택되지 않았음을 나타낸다. 진화 과정에서는 단순 교차 연산자(simple crossover operator)와 엘리트 보존 전략(the elitist strategy)을 사용하였다.

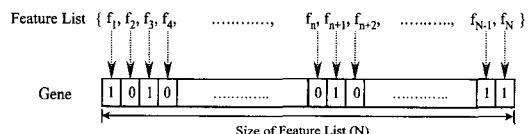


그림 3 특징 부분집합의 염색체 표현

3.1.4 SVM을 사용한 염색체의 평가

각각의 염색체(또는 특정 부분집합)를 평가하기 위하여, 학습 데이터 집합의 특징 목록 인스턴스들로부터 염색체로 표현된 특정 부분집합에 대응하는 특징 부분집합 인스턴스들을 추출하여 이를 입력벡터로 한 SVM을 생성한다. 각 염색체의 적합도(fitness value)는 염색체 별로 생성된 SVM에 투영 데이터 집합의 특정 부분집합 인스턴스들을 입력한 후의 분리 결과에 비례하고, 특정 부분집합의 크기에는 반비례하도록 정의한다. 즉 다음 식 (10)과 같이 정의한다.

$$\text{fitness} = \left(\frac{V_{self}}{T_{self}} \times \lambda + \frac{V_{other}}{T_{other}} \times (1 - \lambda) \right) \times (1 - \eta) + \eta \times F(N_s) \quad (10)$$

위 식 (10)에서 T_{self} 는 인증 대상자 본인 영상의 총 개수이고, V_{self} 는 본인으로 올바르게 인증한 본인 영상의 개수이고, T_{other} 는 타인 영상의 총 개수이고, V_{other} 는 타인 영상으로 올바르게 인증한 타인 영상의 개수이다. λ 는 False Reject Rate(FRR)와 False Acceptance Rate(FAR)를 조절하는 파라미터로, λ 가 증가함에 따라 FRR은 감소하고 FAR은 증가한다. 함수 $F(N_s)$ 는 다음 식 (11)과 같이 정의하여 특정 부분집합의 크기인 N_s 에 반비례하게 한다. 따라서 $F(N_s)$ 는 선택된 특정 부분집

합의 크기가 작을수록 더 큰 값을 얻어 적합도를 크게 한다.

$$F(N_s) = \begin{cases} 1.0 & \text{if } N_s \leq N_t / 4 \\ 1.0 - \frac{N_s - N_t / 4}{N_t / 4} & \text{if } N_t / 4 < N_s \leq N_t / 2 \\ 0.0 & \text{if } N_s > N_t / 2 \end{cases} \quad (11)$$

식 (11)에서 N_t 는 특징 목록의 크기이다. 식 (10)에서 η 는 에러율과 메모리 요구량의 트레이드-오프(trade-off) 파라미터로, η 가 클수록 작은 특징 부분집합이 더 높은 점수를 얻게 되므로 더 적은 메모리가 필요하게 된다. 즉 작은 η 를 사용하면 메모리 사용이 적은 경우보다 에러율이 작은 경우에 우선권을 주게 된다.

시스템은 이러한 적합도를 이용하여 가장 우수한 염색체의 적합도가 1.0이 되거나 세대수가 일정한 수에 이를 때까지 진화해 간다. 진화가 종료된 후, 가장 우수한 염색체에 대응되는 특징 부분집합 인스턴스를 입력벡터로 하는 SVM이 각 사람에 대한 얼굴 인증 시스템이 된다.

3.2 얼굴 인증 시스템을 통한 인증 과정

이 절에서는 3.1절에서 생성한 얼굴 인증 시스템을 이용하여 실제로 사용자를 인증하는 과정을 설명한다. 인증 과정의 처리 흐름도는 다음 그림 4와 같다. 인증 시스템 생성 과정에서 생성된 SVM을 저장하기 위하여, Support Vectors와 그에 대응되는 가중치를 기억시킨다. 또 GA 과정을 통하여 추출되어 SVM의 생성시 입력벡터의 형성에 사용된 최고의 특징 부분집합을 저장하여 인증 과정에서 이용할 수 있게 한다.

3.2.1 전처리와 특징 부분집합 인스턴스(Feature Subset Instance)의 추출

인증할 영상에 얼굴 인증 시스템의 생성 과정과 똑같은 전처리를 수행한 후, 저장된 특징 부분집합에 대응되는

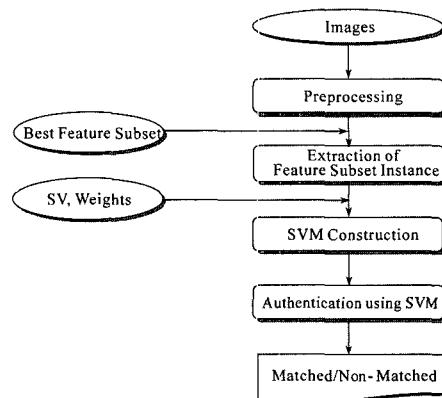


그림 4 제안하는 얼굴 인증 시스템의 인증 과정

는 인스턴스를 추출한다. 즉 인증 시스템 생성 과정에서 선택된 특징 부분집합에 해당하는 특징값을 구하는 것이다. 따라서 본 논문에서는 PCA의 프로젝션 계수들로 이루어진 특징 목록, 또는 64×64 크기의 얼굴 영상에 8×8 크기의 윈도우를 4 팩슬 씩 오버랩하면서 차례로 스캔한 225개의 윈도우 내의 픽셀들의 밝기값 평균과 에지값 평균들로 이루어진 특징 목록의 부분집합에 대응되는 인스턴스를 계산한다.

3.2.2 SVM을 이용한 얼굴 인증

저장된 Support Vectors와 그에 대응되는 가중치를 이용하여 얼굴 인증 시스템인 SVM을 구축한다. 생성된 SVM(즉 얼굴 인증 시스템)에 3.2.1절에서 구해진 특징 부분집합 인스턴스를 입력하여 그 결과값으로 인증 여부를 판정한다.

3.3 보안토큰용 얼굴 인증 시스템의 구현 예

이 절에서는 제안한 얼굴 인증 알고리즘을 사용하여 실시간 얼굴 인증 시스템의 구현 예를 보인다. 그림 5는 자원이 한정된 스마트카드 또는 USB 토큰 내에서 얼굴

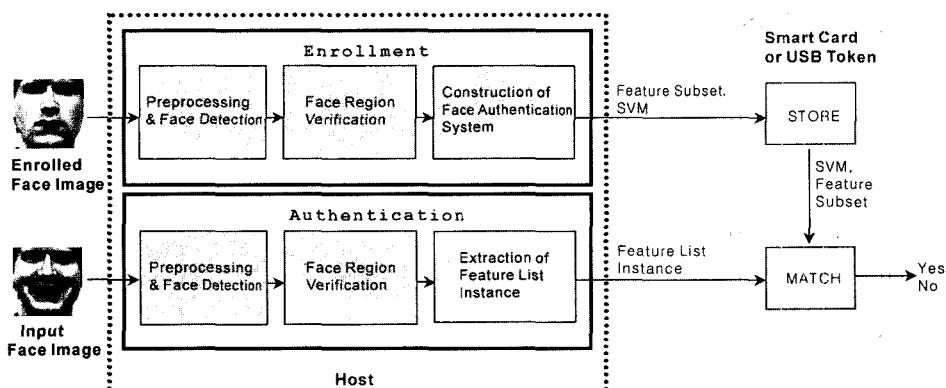


그림 5 Match-on-Token 얼굴 인증 시스템의 구현 예

인증을 수행하는 Match-on-Card 또는 Match-on-Token 시스템의 구현 예를 나타낸 것이다.

먼저 사용자 등록(enrollment) 과정을 살펴보면 다음과 같다. 호스트에서 카메라를 통해 입력된 영상으로부터 전처리 및 얼굴 탐지 과정을 수행하여 얼굴 영역을 추출한다. 다음으로, 추출된 얼굴 영역이 올바르게 추출되었는지 검증하는 단계로 SVM을 이용한 얼굴 영역 검증 과정(face region verification)을 수행한다. 이것은 얼굴 탐지 단계에서 잘못된 영역이 얼굴 영역으로 추출될 경우, 등록 과정 및 인증 과정에서 오류가 발생하여 시스템의 성능 저하를 가져오게 되는데 이를 방지하기 위한 과정이다. 32×32 크기의 150장의 얼굴(face) 영상들과 150장의 비얼굴(non-face) 영상들을 이용하여 SVM 얼굴 영역 검증기를 미리 학습시켜 두었다. 얼굴 영역 검증기 학습시 부트스트랩핑(bootstrapping) 방식을 이용하여 얼굴로 오인식되는 비얼굴 영상들과 비얼굴로 오인식되는 얼굴 영상들을 다시 입력에 추가하여 학습하였다. 얼굴 영역 검증 과정을 통해 검증된 얼굴 영상들을 사용하여 제안한 알고리즘인 GA와 SVM을 결합한 학습으로 얼굴 인증 시스템을 생성한다. 생성된 얼굴 인증 시스템은 스마트카드 또는 USB 토큰으로 전송되어 저장된다. 이 때 저장될 인증 시스템은 Support Vectors와 그에 대응되는 가중치, 선택된 특징 부분집합으로 이루어진다.

다음으로 사용자 인증(Authentication) 과정을 살펴보면, 우선 등록 과정과 똑같은 전처리 및 얼굴 탐지 과정과 얼굴 영역 검증 과정을 수행한다. 검증된 얼굴 영역 영상으로부터 특징목록 인스턴스를 추출하여 이를 스마트카드 또는 USB 토큰으로 전송한다. 스마트카드 또는 USB 토큰 내부에서는 저장된 Support Vectors와 그에 대응되는 가중치를 이용하여 SVM 얼굴 인증기를 구성한다. 그 후 호스트로부터 수신된 특징목록 인스턴스로부터, 기저장된 개인별 특징 부분집합에 대응되는 특징 부분집합 인스턴스를 추출하여, 이를 SVM 얼굴 인증기에 입력하여 인증을 수행한다.

4. 시스템 성능 실험 및 결과 분석

제안한 얼굴 인증 시스템의 인식률과 메모리양에 관한 성능을 분석하기 위하여 널리 알려진 얼굴 데이터베이스들에 대하여 세 가지 종류의 특징 목록을 사용하여 실험한다. 이 장에서는 각 실험에 사용된 얼굴 데이터베이스와 실험 내용 및 실험 결과에 대하여 자세히 살펴보기로 한다.

4.1 얼굴 데이터베이스

본 논문에서는 기존의 얼굴 인식 시스템에서 테스트 데이터로 널리 사용되어지고 있는 Yale 얼굴 데이터베

이스, ORL 얼굴 데이터베이스와 포항공대에서 제작한 한국인 얼굴 데이터베이스를 사용하여 제안한 시스템의 성능을 평가하였다. Yale 얼굴 데이터베이스[16]는 15명에 대하여 조명(중앙조명, 좌측조명, 우측조명), 표정(행복, 무표정, 슬픔, 즐럼, 놀람, 웅크), 안경(착용, 미착용) 등의 변화가 있는 320×243 크기의 11장의 영상으로 구성되어 있다. ORL 데이터베이스[17]는 40명에 대하여 조명의 변화는 적지만, 포즈 및 표정(눈을 뜨거나 감은 눈, 웃거나 웃지 않음)의 변화, 안경 착용/미착용 등의 변화가 있는 92×112 크기의 10장의 영상으로 이루어져 있다. 포항공대 데이터베이스[18]는 남자 56명, 여자 51명의 총 107명에 대하여 표준영상과 4장의 조명 변화(위측조명, 아래측조명, 좌측조명, 우측조명) 영상, 반시계방향으로 45도씩 증가하면서 얼굴을 회전한 8장, 4장의 표정변화(행복, 놀람, 짜증, 눈감음)가 있는 1280×960 크기의 17장의 영상으로 이루어져 있다. 그럼 6은 각 데이터베이스의 샘플 영상들을 보여 준다. 각 데이터베이스는 SVM을 생성하는데 사용할 학습 데이터 집합(training data set), 평가 함수의 계산을 위하여 SVM을 평가하는데 사용할 튜닝 데이터 집합(tuning data set), 학습이 끝난 뒤 생성된 최종 얼굴 인증 시스템의 성능을 평가할 때 사용할 테스트 데이터 집합(test data set)의 3가지로 나누어서 사용하였다.

Yale 데이터베이스는 다음과 같이 3가지 데이터 집합으로 분류하여 사용하였다.

- 학습 데이터 집합: 각 사람에 대하여 본인 영상 3장과 타인 5명에 대하여 각각 3장의 영상을 학습에 사용하였다.
- 튜닝 데이터 집합: 각 사람에 대하여 본인 영상 3장과 또 다른 타인 5명에 대하여 각각 3장의 영상을 튜닝에 사용하였다.
- 테스트 데이터 집합: 각 사람에 대하여 학습 및 튜닝에 사용하지 않은 본인의 영상 5장과 타인 14명의 영상 124장을 테스트에 사용하였다. 이 타인 영상을 중에서 44장의 영상은 학습 및 튜닝 과정에서 전혀 알려지지 않은 사람들의 영상이다.

ORL 데이터베이스도 다음과 같이 3가지 데이터 집합으로 분류하여 사용하였다.

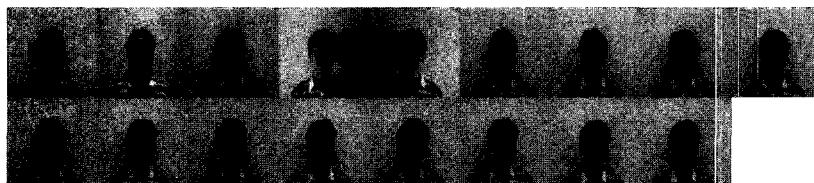
- 학습 데이터 집합: 각 사람에 대하여 본인 영상 3장과 타인 15명에 대하여 각각 1장의 영상을 학습에 사용하였다.
- 튜닝 데이터 집합: 각 사람에 대하여 본인 영상 3장과 또 다른 타인 15명에 대하여 각각 1장의 영상을 튜닝에 사용하였다.
- 테스트 데이터 집합: 각 사람에 대하여 학습 및 튜닝에 사용하지 않은 본인의 영상 4장과 타인 39명의 영



(a) Face Images from the Yale database



(b) Face Images from the ORL database



(c) Face Images from the Postech database

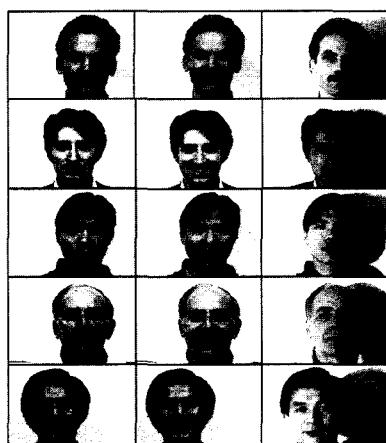
그림 6 Yale, ORL, Postech 얼굴 데이터베이스의 샘플 영상들



(a) 3 images of subject himself

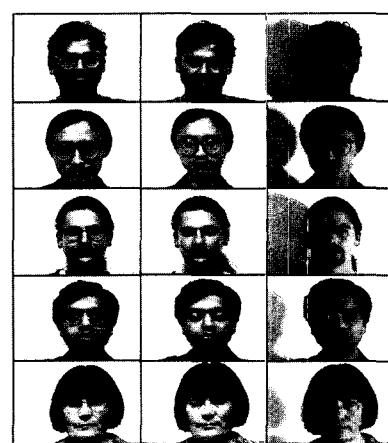


(a) 3 images of subject himself



(b) 3 images of other 5 people

그림 7 Yale 데이터베이스의 1번 사람에 대한 학습 데이터 집합



(b) 3 images of other 5 people

그림 8 Yale 데이터베이스의 1번 사람에 대한 투닝 데이터 집합

상 360장을 테스트에 사용하였다. 이 타인 영상들 중에서 90장의 영상은 학습 및 튜닝 과정에서 전혀 알려지지 않은 사람들의 영상이다.

또한 포항공대 데이터베이스도 다음과 같이 3가지 데이터 집합으로 분류하였다.

- 학습 데이터 집합: 각 사람에 대하여 본인 영상 5장과

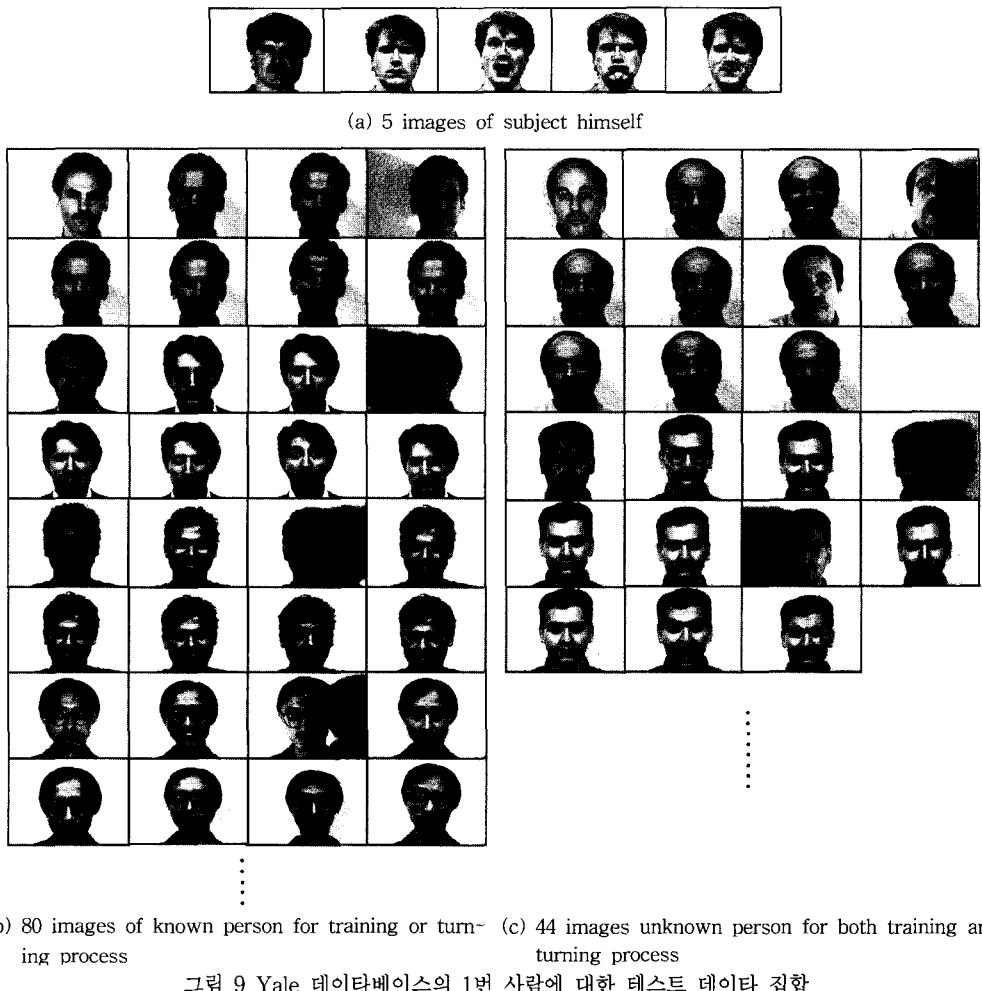


그림 9 Yale 데이터베이스의 1번 사람에 대한 테스트 데이터 집합

타인 6명에 대하여 각각 5장의 영상을 학습에 사용하였다.

- 퓨닝 데이터 집합: 각 사람에 대하여 본인 영상 5장과 또 다른 타인 6명에 대하여 각각 5장의 영상을 퓨닝에 사용하였다.
- 테스트 데이터 집합: 각 사람에 대하여 학습 및 퓨닝에 사용하지 않은 본인의 영상 7장과 타인 106명의 영상 1742장을 테스트에 사용하였다. 이 타인 영상들 중에서 1598장의 영상은 학습 및 퓨닝 과정에서 전혀 알려지지 않은 사람들의 영상이다.

그림 7, 그림 8, 그림 9는 Yale 데이터베이스에서 1번 사람에 대한 학습 데이터 집합, 퓨닝 데이터 집합, 테스트 데이터 집합 각각의 예를 보여 준다. 이와 같은 방법으로 데이터베이스 내의 모든 사람에 대하여 각각 3가지의 데이터 집합을 생성한 후, 이 중 학습 데이터 집합과 퓨닝 데이터 집합을 사용하여 각 사람에 대하여 본

인 얼굴 인증 시스템을 생성한다. 제안한 얼굴 인증 시스템의 성능 평가는 개인별 테스트 데이터 집합을 이용하여 수행한다.

4.2 특징 목록(Feature List)

본 논문에서는 3가지 종류의 특징 목록들을 이용하여 실험하였다. 각 실험은 각 영상에 대하여 다음과 같은 특징 목록을 사용하였는데, $E_p(W_k)$ 는 얼굴 영상의 k번째 윈도우의 밝기값들의 평균값을 표시하고, $E_e(W_k)$ 는 얼굴 영상의 k번째 윈도우의 에지값들의 평균값을 나타낸다. $\omega_{M'}$ 는 영상의 PCA 프로젝션 계수들을 나타내는데, 식 (9)에 의해 $\omega_{M'}$ 은 이미 정의되었다.

- 특징 목록 1:

$$\{ \omega_{M'} \mid M' = 1, \dots, 50 \} \quad (12)$$

- 특징 목록 2:

$$\{ E_p(W_k), E_e(W_k) \mid k = 1, \dots, 225 \} \quad (13)$$

• 특징 목록 3:

$$\{E_p(W_k), E_e(W_k), \omega_{M'} \mid k=1, \dots, 225, M'=1, \dots, 50\} \quad (14)$$

제안한 알고리즘의 효율성을 평가하기 위하여, 3가지 특징 목록을 이용한 실험 각각에 대하여 2가지 경우를 고려하여 비교 실험하였다. 하나는 특징 목록 인스턴스들로 이루어진 입력벡터를 사용하는 SVM 만 사용한 경우와, 다른 하나는 GA를 통하여 선택된 특징 부분집합 인스턴스들을 SVM의 입력벡터들로 사용하는 GA 특징 선택 과정이 포함된 경우이다.

4.3 실험 결과 및 분석

비선형인 경우 표준 SVM 학습은 전체의 오분류율(misclassification rate)를 최소화하기 때문에, 생체인식 시스템의 성능 평가에 주로 사용되는 EER(Equal Error Rate) 측정에 적합하지 않다[22]. 따라서 본 논문의 실험에서는 다음의 식 (15)과 같이 FAR(False Accept Rate)과 FRR(False Reject Rate)의 합을 이용한 TER

(Total Error Rate)을 이용하여 각 실험 결과들을 비교하였다.

$$TER = FAR + FRR \quad (15)$$

표 1, 표 2, 표 3은 Yale 데이터베이스와 ORL 데이터베이스, 포항공대 데이터베이스에 대하여 식(13),(14), (15)의 3가지 특징목록으로 실험한 결과로, GA 특징 선택(feature selection) 과정이 포함된 SVM 기반 얼굴 인증 알고리즘의 성능과 GA 과정이 없는 경우를 비교하여 나타내고 있다. 데이터베이스 내의 각 사람들에 대하여 인증 시스템을 생성한 후, 사람별로 실험한 결과를 평균하여 나타낸 것이다. GA 특징 선택 과정이 포함된 실험에서 GA 과정에 관련된 파라미터들은 다음과 같은 값들을 사용하였다. 세대수는 3000세대이고, 식 (10)에서 정의된 λ, η 의 값은 각각 $\lambda=0.45, \eta=0.01$ 이다. 이는 여러 실험을 통하여 에러율을 가장 작게 하는 파라미터 값을 알아내어 사용한 것이다. 또한 SVM에 RBF(Radial Basis Function) 커널을 사용하였다.

표 1 Yale 얼굴 데이터베이스를 사용한 실험 결과

Feature List Performance	Feature List 1 (PCA)		Feature List 2 (Avg. of Intensity & Edge)		Feature List 3 (Avg. of Intensity & Edge, PCA)	
	SVM	GA+SVM	SVM	GA+SVM	SVM	GA+SVM
FAR	0.104	0.072	0.142	0.099	0.142	0.099
FRR	0.133	0.120	0.107	0.107	0.107	0.120
TER	0.237	0.192	0.249	0.206	0.249	0.219
No. of Features	50.000	15.000	450.000	188.733	500.000	209.733
No.of Support Vectors	18.000	17.733	18.000	18.000	18.000	18.000

표 2 ORL 얼굴 데이터베이스를 사용한 실험 결과

Feature List Performance	Feature List 1 (PCA)		Feature List 2 (Avg. of Intensity & Edge)		Feature List 3 (Avg. of Intensity & Edge, PCA)	
	SVM	GA+SVM	SVM	GA+SVM	SVM	GA+SVM
FAR	0.096	0.044	0.100	0.086	0.100	0.090
FRR	0.088	0.125	0.088	0.069	0.088	0.081
TER	0.184	0.169	0.188	0.155	0.188	0.171
No. of Features	50.000	15.350	450.000	180.050	500.000	202.225
No.of Support Vectors	18.000	17.950	18.000	18.000	18.000	18.000

표 3 포항공대 얼굴 데이터베이스를 사용한 실험 결과

Feature List Performance	Feature List 1 (PCA)		Feature List 2 (Avg. of Intensity & Edge)		Feature List 3 (Avg. of Intensity & Edge, PCA)	
	SVM	GA+SVM	SVM	GA+SVM	SVM	GA+SVM
FAR	0.118	0.082	0.135	0.120	0.135	0.119
FRR	0.216	0.298	0.170	0.171	0.168	0.168
TER	0.334	0.380	0.305	0.291	0.303	0.287
No. of Features	50.000	15.551	450.000	194.009	500.000	218.514
No.of Support Vectors	35.000	34.028	35.000	35.000	35.000	35.000

표 1, 표 2에서 보듯이 Yale 데이터베이스와 ORL 데이터베이스에 대한 실험에서는 제안한 얼굴 인증 알고리즘이 3가지 특징 목록 모두에 대하여, 특징 목록 크기의 평균 30.0%~41.9%의 특징 개수(즉 특징 부분집합의 크기)만을 사용함에도 불구하고, SVM만 사용한 경우보다 더 낮은 에러율을 보이고 있다. Yale 데이터베이스에 대한 실험 결과에서 제안한 방법이 특징목록 크기의 30.0%, 41.9%, 41.9%의 특징만을 사용하여 4.5%, 4.3%, 3.0%의 TER 감소가 있었다. ORL 데이터베이스인 경우에도 제안한 방법이 특징목록 크기의 30.7%, 40.0%, 40.4%의 특징만을 사용하여 1.5%, 3.3%, 1.7%의 TER 감소가 있었다.

포항공대 데이터베이스를 사용한 실험 결과는 표 3에서 보듯이, 다른 데이터베이스의 결과에 비해 전반적으로 전체 에러율이 높았다. 이는 그림 6의 데이터베이스의 샘플 영상들에서 보듯이, 표정변화와 더불어 급격한 조명변화와 얼굴의 회전변화가 있는 영상들로 이루어져 있기 때문이다. 특히 얼굴 각도 변화가 큰 8개의 영상에 대해서는 좋지 않은 결과를 얻었다. 비교 실험을 한 결과, 특징 목록 2와 특징목록 3을 사용한 경우에는 특징 목록 크기의 43.1%, 43.7%의 특징만을 사용하여 1.4%, 1.6%의 TER 감소가 있었고, PCA계수만으로 이루어진 특징 목록 1에 대해서는 4.6% TER 증가로 성능이 개선되지 않았다. 이는 PCA 계수인 경우 조명의 영향보다 얼굴 각도의 회전에 더욱 영향을 크게 받는 것을 나타낸 것이다. Yale 데이터베이스인 경우는 조명변화와 표정변화가 큰 영상들이지만 3가지 특징 목록 모두에 대해 좋은 성능을 내었고, ORL 데이터베이스인 경우는 약간의 표정변화, 얼굴 회전이 있는 영상들로 구성되어 있는데 좋은 결과를 얻었다. 따라서 조명변화와 표정의 변화보다 얼굴의 회전 변화가 얼굴 인식 시스템에 더 큰 영향을 끼침을 알 수 있었다.

또한 실험 결과를 잘 살펴보면 3가지 데이터베이스 모두에 대하여, 450개의 평균값을 이용한 특징 목록 2와, 450개의 평균값과 50개의 PCA계수를 하나의 특징 벡터로 연결하여 사용한 특징 목록 3을 이용하여 SVM만으로 인증 실험한 결과값은 거의 똑같음을 알 수 있었다. 이는 SVM 생성시 사용하는 특징벡터들의 갯수는 18개 또는 35개로 매우 작은 반면에 특징 벡터의 차원은 450 또는 500으로 상대적으로 매우 커서, 450개의 특징값으로 이루어진 특징벡터와 450개의 특징값 뒤에 50개의 특징값을 연결한 특징벡터는 계산과정에서 유사한 벡터로 다루어져서 SVM의 생성과 인증 결과에 별다른 차이를 주지 못했기 때문이다.

다양한 실험 결과들을 종합하여 볼 때 제안한 알고리즘에 의해 추출된 식별력이 우수한 특징들을 사용함으

로써 에러율 뿐만 아니라 메모리 요구량도 개선되었음을 알 수 있다.

다음으로 Yale 얼굴 데이터베이스를 사용하여 2개의 조절 파라미터의 효과를 살펴보기 위한 실험을 하였다. 첫번째 파라미터 λ 는 FRR과 FAR를 조절한다. 즉 λ 가 증가함에 따라 FRR은 감소하고 FAR은 증가한다. 그림 10은 λ 의 변화에 따라 FRR과 FAR의 트레이드오프를 보여주는 실험 결과 그래프이다. 이 실험에서 $\eta = 0.01$ 이고 세대수는 3000이며 4차의 Polynomial 커널 SVM을 사용하여 실험하였다. λ 값이 0.00에서 1.00까지 증가함에 따라, FRR은 0.15에서 0.08로 감소하였고 FAR은 0.05에서 0.08로 증가하였다. 따라서 시스템 디자인 과정에서 적절한 λ 를 선택함으로써 FAR과 FRR에 대한 시스템 요구사항을 반영할 수 있다.

다음으로 두번째 파라미터 η 는 메모리 요구량과 에러율을 조절할 수 있다. 그림 11과 그림 12는 η 값의 변화에 따른 에러율과 메모리 요구량 사이의 트레이드오프를 보여준다. 이 실험에서 $\lambda = 0.45$ 이고 세대수는 3000이다. 역시 Yale 얼굴 데이터베이스를 사용하였고 4차의 Polynomial 커널 SVM을 사용하였다. η 가 0.00

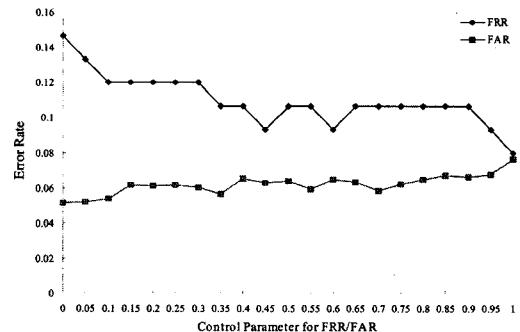


그림 10 조절 파라미터 λ 의 변화에 따른 FRR과 FAR의 변화

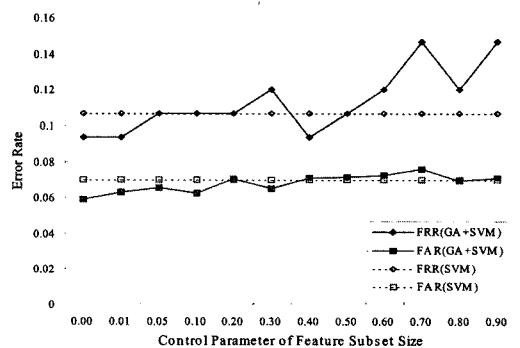


그림 11 조절 파라미터 η 의 변화에 따른 FRR과 FAR의 변화

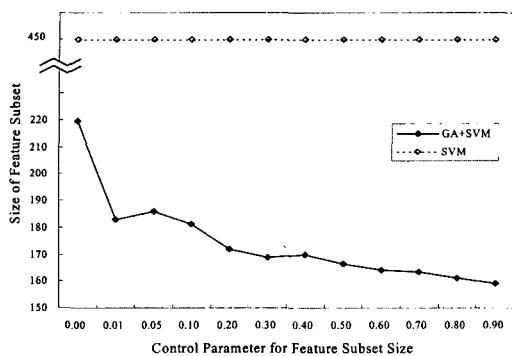


그림 12 조절 파라미터 η 의 변화에 따른 특징 부분집합의 크기 변화

에서 0.90으로 증가함에 따라, FRR은 0.09에서 0.15로 증가하였고 또한 FAR도 0.06에서 0.07로 증가하였다. 반면에 선택된 특징 부분집합의 크기는 평균적으로 220에서 159로 감소하였다. 따라서 제안한 알고리즘은 메모리 제약이 있는 시스템에서, 적당한 η 를 선택함으로써 비록 인식률은 감소하더라도 사용 메모리양을 줄여 동작 가능하게 할 수 있음을 보였다.

5. 결 론

스마트카드를 비롯한 보안토큰은 보안성이 뛰어난 모델이고, 생체인식은 사용자 인증을 위한 최고의 기술이다. 이러한 두 가지를 결합하여 다양한 응용 분야에서 보안성과 인증 성능을 증진하기 위하여 사용할 수 있다. 그러나 스마트카드와 같은 보안토큰은 매우 제한된 자원을 갖기 때문에, 생체인식 기술을 통합하기 위해서는 주의 깊은 설계와 구현이 필요하다.

본 논문에서는 SVM에 GA를 통합한 메모리 사용이 효율적인 얼굴 인증 방법을 제안하였다. 비교 실험에 의하여, GA에 의해 추출된 식별력이 우수한 특징들로 이루어진 입력벡터를 사용하는 SVM 기반 얼굴 인증 알고리즘이, GA에 의한 특징 선택 과정이 없는 알고리즘보다 더 우수한 성능을 보임을 알 수 있었다. 얼굴인식 분야에서 널리 사용되고 있는 Yale 얼굴 데이터베이스, ORL 얼굴 데이터베이스와 한국인 얼굴로 구성된 포함공대 얼굴 데이터베이스에 대하여 3가지 특징 목록을 사용하여 실험하였다. 제안한 알고리즘이 전체 특징 개수의 평균 30.0%~41.9%만을 사용하였음에도 불구하고, GA 특징 선택 과정이 없는 SVM 기반 얼굴 인증 알고리즘보다 TER이 더 작은 결과를 얻었다.

또한 필요에 따라 시스템 파라미터를 조절함으로써, 인식률은 다소 감소하더라도 인증 과정에서 필요한 메모리양을 감소시킬 수 있는 방법을 제안하였다. 밖기값

과 예지값의 평균을 사용한 특정 목록인 경우, 시스템 파라미터의 조절에 의해 필요한 메모리양을 35%가량으로 줄일 수 있었다.

따라서 제안한 방법의 적은 메모리 요구량은 대용량의 얼굴 인식 시스템 또는 지원 체약이 있는 스마트카드 등의 보안토큰에 적용 가능하게 한다. 이것은 현재 사용되고 있는 전통적인 PIN 인증 방법에 비해, 많은 새로운 응용 분야에 스마트카드를 포함한 보안토큰을 적용함으로써 보안성을 훨씬 더 강화시킬 수 있게 한다.

참 고 문 헌

- [1] C. Mearns, and D. Jones, *The Smart Card*. SJB Research, 1999.
- [2] K. Lam and H. Yan, "An Analytic-to-Holistic Approach for Face Recognition based on a Single Frontal View," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 29, No. 7, pp. 673-686, 1998.
- [3] M. Turk and A. Pentland, "Face Recognition using Eigenfaces," *Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition*, pp. 586-591, 1991.
- [4] C. Wu and J. Huang, "Human Face Profile Recognition by Computer," *Pattern Recognition*, Vol. 23, No. 3/4, pp. 255-259, 1990.
- [5] R. Brunelli and T. Poggio, "Face Recognition: Features versus Templates," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 15, No. 10, pp. 1042-1052, 1993.
- [6] V. Vapnik, *Statistical Learning Theory*, John Wiley & Sons, New York, 1998.
- [7] Vladimir N. Vapnik, *The Nature of Statistical Learning Theory*, Springer-Verlag New York, 2000.
- [8] E. Osuna, R. Freund, and F. Girosi, "Training Support Vector Machines: an Application to Face Detection," *Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition*, pp. 130-136, 1997.
- [9] J. Huang, X. Shao, and H. Wechsler, "Face Pose Discrimination using Support Vector Machines," *Proceedings of International Conference on Pattern Recognition*, pp. 154-156, 1998.
- [10] G. Guo, S. Z. Li, and K. L. Chan, "Support vector machines for face recognition," *Image and Vision Computing* 19, pp. 631-638, 2001.
- [11] K. Jonsson, J. Matas, J. Kittler, and Y. Li, "Learning Support Vectors for Face Verification and Recognition," *Proceedings of International Conference on Automatic Face and Gesture Recognition*, pp. 208-213, 2000.
- [12] Y. Li, S. Gong, and H. Liddell, "Support Vector Regression and Classification based Multi-View

- Face Detection and Recognition," *Proceedings of International Conference on Automatic Face and Gesture Recognition*, pp. 300-305, 2000.
- [13] P. Jonathon Phillips, "Support Vector Machines Applied to Face Recognition," *Advances in Neural Information Processing Systems 11*, MIT Press, pp. 803-809, 1999.
 - [14] David E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, 1989.
 - [15] Kyunghee Lee, Yongwha Chung, and Hyeran Byun, "SVM-based face verification with feature set of small size," *IEE Electronics Letters*, Vol.38, No.15, pp.787-789. 2002.
 - [16] Yale Face Database, <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
 - [17] ORL Face Database, <http://www.cam-orl.co.uk/facedatabase.html>
 - [18] Postech Face Database, <http://nova.postech.ac.kr>
 - [19] Jihoon Yang and Vasant Honavar, "Feature Subset Selection using A Genetic Algorithm," *Feature Extraction, Construction and Selection: A Data Mining Perspective*, Kluwer Academic Publishers, pp. 117-136, 2001.
 - [20] H. Vafaei and K. DeJong, "Feature Space Transformation Using Genetic Algorithms," *IEEE Intelligent Systems*, March/April, pp. 57-65, 1998.
 - [21] Rafael C. Gonzalez, and Richard E. Woods, *Digital Image Processing*, Addison Wesley Longman, 1992.
 - [22] C. Sanderson. Information Fusion and Person Verification Using Speech and Face Information, *IDIAP Research Report 02-33*, 2002.



이 경희

1993년 연세대학교 전산과학과(학사). 1993
년~1996년 LG소프트(주) 연구원 1998
년 연세대학교 컴퓨터과학과(석사) 2004
년 연세대학교 컴퓨터과학과(박사) 2000
년~현재 한국전자통신연구원 선임연구
원. 관심분야는 패턴인식, 컴퓨터비전, 영
상처리, 인공지능 등

변 혜 란

정보과학회논문지 : 소프트웨어 및 응용
제 31 권 제 1 호 참조