

# GroupMutual-Boost를 이용한 얼굴특징 선택 및 얼굴 인식

최학진<sup>1</sup> · 이종식<sup>†</sup>

## Face Feature Selection and Face Recognition using GroupMutual-Boost

Hak-Jin Choi · Jong-Sik Lee

### ABSTRACT

The face recognition has been used in a variety fields, such as identification and security. The procedure of the face recognition is as follows; extracting face features of face images, learning the extracted face features, and selecting some features among all extracted face features. The selected features have discrimination and are used for face recognition. However, there are numerous face features extracted from face images. If a face recognition system uses all extracted features, a high computing time is required for learning face features and the efficiency of computing resources decreases. To solve this problem, many researchers have proposed various Boosting methods, which improve the performance of learning algorithms. Mutual-Boost is the typical Boosting method and efficiently selects face features by using mutual information between two features. In this paper, we propose a GroupMutual-Boost method for improving Mutual-Boost. Our proposed method can shorten the time required for learning and recognizing face features and use computing resources more effectively since the method does not learn individual features but a feature group.

**Key words** : GroupMutual-Boost, Feature Selection, Face Recognition , Pattern Recognition

### 요 약

현재 일상생활에서 얼굴 인식은 신원확인, 보안 등의 목적으로 사용되고 있다. 얼굴인식의 과정은 첫 번째로 얼굴이미지의 특징을 추출해야 한다. 다음으로 추출된 특징을 학습하고 그 중 학습이 잘된 식별력 있는 특징을 선택하게 된다. 그 이후 식별력 있는 특징을 이용하여 얼굴이미지를 인식하게 된다. 얼굴인식을 위해 사용하는 얼굴이미지의 특징의 수는 매우 많다. 이 많은 특징을 학습 및 인식에 다 사용할 경우 학습 시간과 컴퓨팅 자원의 효율성이 떨어지는 문제점을 가지고 있다. 이러한 문제를 해결하기 위해서 최근 여러가지의 Boosting 기법이 소개되어왔다. Boosting 기법은 특징을 효율적으로 선택하여 학습 알고리즘의 성능을 좋게해주는 기법이다. 그 중 MutualBoost라는 기법이 있는데 이 기법은 특징간의 상호정보를 이용하여 특징을 효율적으로 선택하게 하는 기법이다. 본 논문에서는 MutualBoost의 효과를 더 증대시키기 위해서 개별적인 특징학습이 아니라 특징들을 Group화하여 특징학습을 하는 GroupMutual-Boost기법을 제안한다. 특징들을 Group화 함으로써 특징의 학습 및 선택 시간이 줄어들게 되고 컴퓨팅 자원을 보다 효율적으로 사용할 수 있다.

**주요어** : GroupMutual-Boost, 특징 선택, 얼굴 인식, 패턴 인식

## 1. 서 론

얼굴인식은 주로 신원확인, 보안 등을 목적으로 현재 많이 사용되고 있다. 얼굴 인식을 위해서 사람의 얼굴 사

진이나 이미지로부터 얼굴의 특징을 추출하여 특징을 학습하고, 학습된 특징들을 사용하여 입력된 이미지로부터 인식을 하게 된다. 하지만 얼굴이미지에서 추출되는 특징의 수는 매우 많다. 그리고 그 특징들 중 중복되는 특징과 학습 및 인식에 불필요한 특징들이 다수 포함되어 있다. 이렇게 중복되는 특징들과 불필요한 특징들을 학습 및 인식에 그대로 사용할 경우 낭비되는 데이터로 인해 학습 및 인식과정에서 컴퓨팅 시간의 낭비나 저장 공간의 낭비 등의 문제를 야기 할 뿐만 아니라 인식률에도 좋지 않은

접수일(2010년 10월 19일), 심사일(1차 : 2011년 3월 13일),  
게재 확정일(2011년 12월 8일)

<sup>1)</sup> 인하대학교 정보공학과

주 저 자 : 최학진

교신저자 : 이종식

E-mail: jslee@inha.ac.kr

영향을 미칠 수 있다. 이러한 문제를 해결하기 위해서 얼굴 이미지로부터 추출된 특징 중 중복되는 특징과 불필요한 특징을 제거하고 식별력 있는 특징을 선별하는 과정이 필수적으로 요구 된다.

현재 얼굴 이미지의 특징 중 불필요한 특징과 중복되는 특징을 제거하고 식별력 있는 특징을 선별하는 방법들이 다양하게 제시되어 왔다. 최근에는 boosting(Freund and Schapire, 1999)을 이용한 특징 선택 방법이 좋은 효과를 얻어 여러 종류의 boosting 방법들이 연구되고 있다. Boosting은 학습알고리즘의 성능을 향상시키는 기법이다(Freund and Schapire, 1999). 그 중 AdaBoost는 2D Gabor Filter를 이용하여 특징을 추출하여 그 특징을 학습하고 선택하는 방법을 사용하였다(Shen and Bai, 2004). 이후로 Adaboost방법을 기반으로 특징 선택에 있어 선택하려는 특징과 이전에 선택된 특징들간의 유사도를 이용하는 MutualBoost(Shen and Bai, 2006)방법과 AdaBoost에 Floating search(Somoe et al., 1999)기법을 접목한 FloatBoost(Li et al., 2002)방법 등 여러 가지의 boosting을 이용한 특징 선택 방법들이 제안되어 왔다. 하지만 지금까지 제안된 특징 선택 방법들은 특징을 학습하고 선택하는데 많은 컴퓨팅 자원이 요구되고 계산 시간 또한 많이 소요된다는 단점을 가지고 있다. 얼굴인식에서 특징 학습 및 선택에 소요되는 시간은 얼굴인식에서 성능을 평가하는 중요한 요소 중 하나이다. 따라서 기존의 boosting을 이용한 특징 선택방법들이 지니고 있는 특징 선택에 있어 많은 시간을 요구하는 단점을 보완할 필요성을 가지고 있다.

얼굴인식에서 특징학습 및 선택의 컴퓨팅 시간을 줄이기 위해 본 논문에서는 GroupMutual-Boost라는 새로운 boosting 기법을 제안한다. GroupMutual-Boost를 이용한 특징선택은 얼굴 특징의 전체의 특징들을 개별적인 특징이 아니라 특정한 크기의 group으로 묶어 하나의 특징이라 간주한다. 즉, 하나의 group내에는 여러개의 특징들이 모여있다. 여러 개의 특징을 하나의 group으로 묶음으로서 각각의 특징들을 학습하는 대신 각 group을 학습함으로써 특징의 학습 및 특징 선택의 컴퓨팅 자원을 줄일 수 있다. 또한 특징들을 group으로 묶음으로서 중복되는 특징과 불필요한 특징들을 보다 수월하게 배제시킬 수 있다.

본 논문에서는 우리가 제안한 특징선택 방법과 기존에 제안된 boosting 기반의 특징선택 방법을 시뮬레이션을 통해 비교할 것 이다. 시뮬레이션 과정은 첫 번째로 얼굴 이미지로부터 Gabor 필터(Daugman, 1988)를 이용하여 특징을 추출한다. 다음으로 Gabor 필터를 통해 얻어진 얼굴

이미지의 특징을 기존의 boosting 기반의 특징선택 방법과 우리가 제안 특징선택방법들을 각각 적용하여 특징을 학습하고 선택을 한다. 여기서 특징학습 및 선택에 소요되는 시간을 측정하여 제안한 방법의 성능을 시험하고 제안한 방법의 인식을 또한 어떠한 영향을 미치는지 비교해 본다.

본 논문의 구성은 다음과 같다. 2장에서는 관련연구를 소개하며, 3장에서는 본 논문에서 제안하는 특징선택 방법에 대한 소개가 이어진다. 4장에서는 제안된 특징선택 방법을 이용한 실험결과와 기존의 boosting을 이용한 방법들과의 성능을 비교해 본다.

## 2. 관련 연구

### 2.1 Gabor 필터

얼굴인식을 위해서는 얼굴이미지의 특징추출이 필수적이다. 지금까지 얼굴이미지의 특징추출을 위해 다양한 기법들이 개발되어 왔다. 그 중 얼굴 인식에 널리 사용되고 있는 방법 중 하나가 Gabor 필터(Daugman, 1988)이다. 얼굴인식에서는 얼굴이미지의 여러 조건에 영향을 많이 받는다. 여기서 말하는 조건은 얼굴이미지에 표현된 빛의 세기나 이미지의 회전 그리고 표현된 얼굴의 크기를 예로 들 수 있다. Gabor필터는 이러한 조건들에 영향을 적게 받아 얼굴인식 연구에 널리 사용되는 특징추출 기법 중의 하나이다(Yang et al., 2004). Gabor필터 방법이 이러한 조건에 영향을 적게 받는 이유는 다양한 회전각과 주파수를 갖는 여러 개의 Gabor 필터를 사용하기 때문이다.

### 2.2 Boosting

서론에서 언급하였듯이 얼굴인식은 얼굴이미지에서 추출된 특징벡터를 입력 데이터로 사용한다. 하지만 얼굴 이미지에서 추출된 특징벡터는 중복되는 특징과 불필요한 특징을 다수 포함하고 있다. 중복되는 특징과 불필요한 특징을 그대로 사용할 경우 얼굴인식 소요시간 뿐만아니라 저장 공간의 비효율성을 초래하게 된다. 이러한 컴퓨팅 시간과 저장 공간의 비효율성을 막기 위해서 얼굴이미지의 전체특징 중 중복되는 특징과 불필요한 특징을 제거하고 식별력 있는 특징만을 선별하여 사용하는 특징 선택 과정이 필수적으로 요구된다.

중복되는 특징과 불필요한 특징을 제거하고 식별력 있는 특징을 선별하고 선택하기 위해 다양한 기법들이 제시되었다. 최근 식별력 있는 특징을 선별하기 위한 기법으로 boosting을 기반으로 하는 특징 선택방법이 연구되어왔는

데 그 효과가 뛰어나다. Boosting 알고리즘은 감독학습 알고리즘의 성능을 향상시키기 위한 메타알고리즘이다. Boosting은 미리 주어진 학습데이터를 여러 개의 약한 분류기(weak classifier)에 순차적으로 학습한다. 학습데이터는 이전의 약한 분류기의 학습결과에 따라 도수분포가 달라지게 된다. 학습데이터의 도수분포는 약한 분류기의 결과로 학습이 잘 되지 않은 데이터에 상대적으로 많은 가중치를 부여하는 방식으로 조정된다. 이렇게 약한 분류기에서 나오는 결과를 취합하여 강한 분류기를 생성하게 된다. 실제 데이터의 분류는 강한 분류기를 통해 분류하게 된다.

### 2.2.1 AdaBoost

그림 1은 AdaBoost의 구성도이다. AdaBoost는 대표적인 boosting 방법으로서 boosting 알고리즘 중에서는 특징선택에 최초로 적용되었다(Viola and Jones, 2001). AdaBoost를 이용한 특징선택 방법은 얼굴이미지의 전체 특징에서 각 특징을 각각의 후보분류기(candidate classifier)에 학습시키며, 그 중에서 학습오차가 가장 적은 후보분류기를 하나의 약한 분류기로 선택하고 해당 특징을 하나의 지배특징으로서 선택한다. 이러한 과정을 선택하고자 하는 특징의 수에 따라 반복하게 된다.

### 2.2.2 MutualBoost

그림 2는 MutualBoost의 구성도이다. MutualBoost (Shen and Bai, 2006)는 AdaBoost에서 파생되어 나온




그림 1. AdaBoost 구성도

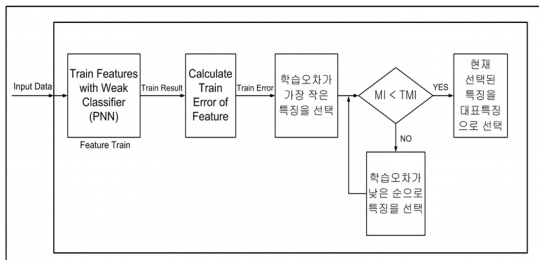


그림 2. MutualBoost 구성도

Boosting의 기법이다. AdaBoost와 동일하게 학습한 특징 중 학습오차가 가장 작은 특징을 식별력있는 특징으로 선택하는 과정에서 현재 식별력있는 특징이라고 가정하는 특징과 이전에 선택된 식별력있는 특징들간의 상호정보(mutual information) (Pluim *et al.*, 2003)을 이용하는 boosting 방법이다. MutualBoost는 현재 선택하고자 하는 특징이 이전에 선택된 특징과 유사한지 판단하여 유사하다고 판단되면 그 특징은 식별력있는 특징이라 판단하지 않고 새로운 특징을 식별력있는 특징으로 선택한다. 여기서 유사성을 판단하기 위해서 상호정보를 이용한다. 특징들간의 유사성 계산으로 MutualBoost는 AdaBoost보다 더 많은 계산비용을 요구한다. 하지만 MutualBoost는 선택하려는 특징이 중복을 피할 수 있기 때문에 AdaBoost보다 식별력 있는 특징을 선택하게 된다. 하지만 특징들간의 유사성을 판단할 때 최대의 비교횟수를 제한하게 된다. AdaBoost와 MutualBoost는 특징을 학습할 때 개별적인 학습을 하게 된다. 즉 특징의 크기가 1이다. 그러므로 특징을 학습하고 선택할 때 많은 컴퓨팅 자원을 요구하게 된다.

### 2.3 PNN

Boosting 기법은 특징 학습알고리즘의 성능을 향상시킬 수 있는 메타 알고리즘이다. Boosting 기법을 사용하기 위해서는 학습알고리즘이 사용 되어야 한다.

PNN(Probabilistic Neural Network) (Burrascano, 1991)은 데이터의 학습 및 분류를 확률적인 기법을 사용하는 알고리즘이다. PNN은 다 변수 패턴에 대한 학습 및 분류가 가능하고, 학습 속도가 빠른 것이 특징이다. PNN은 패턴 데이터를 통해 분포를 추정하고 그 후 추정된 분포를 통해 특정 클래스에 속할 확률을 구하게 된다. 패턴 분류 결과를 확률 값으로 산출하기 때문에 이전 값으로 패턴을 분류하는 단순 역치 함수에 비해 보다 신뢰성 있고 정확한 학습 오차를 얻을 수 있다. 정확하고 신뢰성 있는 학습 오차를 얻을 수 있으므로 boosting의 향상된 효과를 기대할 수 있다.

## 3. GroupMutual-Boost를 이용한 특징선택 및 학습방법

본 논문에서는 얼굴인식에 사용되는 기존의 Mutual-Boost를 이용한 특징선택 방법보다 효과적으로 특징을 학습하고 선택하는 GroupMutual-Boost를 제안하고, 이를

이용하여 효과적으로 특징을 학습 및 선택하고 이를 이용하여 얼굴인식에 적용하는 방법을 제시한다.

### 3.1 GroupMutual-Boost의 대표특징 선택

기존의 Mutual-Boost를 이용한 특징선택 방법은 특징을 개별적으로 학습하여 특징들간의 상호보완성이 결렬되어 있으며 학습하고자 하는 이미지의 특징 학습시간이 오래 걸린다는 단점을 지니고 있다. 이러한 단점을 극복하기 위해서는 기존의 Mutual-Boost 방법 보다 개선된 방법이 필요하다. 새로운 boosting 기반의 특징선택 방법은 기존의 boosting의 가지고 있는 얼굴인식에 많은 시간이 소요되는 단점을 보완해야만 한다. 얼굴 인식에 소요되는 시간이 줄어든다고 하여도 인식률에는 변화가 없어야만 보다 나은 방법이라고 할 수 있다.

GroupMutual-Boost는 위에서 언급한 문제점을 해결하기 위해 설계되었다. 기존의 boosting기반의 얼굴인식 방법은 개별적인 학습으로 인해 학습 및 특징 선택 시간이 매우 오래 걸린다는 단점을 가지고 있다. 이러한 단점을 해결하기 위해 얼굴 이미지에서 추출되는 특징들을 개별적인 학습이 아니라 특정한 크기의 Group으로 묶어 그 Group을 하나의 특징으로 학습한다. 여러개의 특징을 하나의 Group으로 묶음으로서 학습해야할 특징의 수가 줄어들고 그만큼 학습에 필요한 시간이 줄어들게 된다. 하지만 식별력있는 특징을 선택하기 위해서는 Group에서 그 Group을 대표하는 특징이 필요하다. Group의 대표는 Group내의 특징들을 약한 분류기에 학습시켜 그 중 학습 오차가 가장 적은 특징을 Group의 대표라 하겠다. 이렇게 특징을 Group화 함으로써 특징들의 개별적인 학습방법의 문제점을 해결하였고 동시에 특징을 학습하는 시간도 줄어들게 된다.

그림 3은 얼굴이미지가 Gabor필터를 통해 추출된 특징을 Group화 하는 알고리즘이다. 초기의 특징은 M차원을 가지게 된다. 즉, 32768(128×128×2×1)차원의 특징벡터이고 32768개의 특징을 가지게 된다. 이러한 특징벡터를 특정한 크기의 GroupSize로 묶어  $\frac{M}{GroupSize}$  개의 Group으로 특징이 형성된다. 그림 4는 Gabor 필터에서 추출된 얼굴 이미지의 특징벡터를 Group화 한 그림을 나타낸 것이다. 이렇게 형성된 특징 Group들을 차례대로 학습하고 Group의 학습오차를 구하게 된다. 그 중 가장 작은 학습오차를 가지는 Group을 지배특징 Group이라 한다. 하지만 지배특징 Group이 식별력있는 특징이라 할 수 없다. 그 이유는 Group내에 여러개의 특징이 포함되어 있

#### Feature Grouping

$x_i = [f_i^1, f_i^2, \dots, f_i^j, \dots, f_i^M]$ ,  $x$  is feature vector

M is feature vector of dimension

while ( $j < M$ ), Initial  $j$  is 0

if ( $(j \bmod G) < G$ ,  $G$  is GroupSize

$x_{i,k} = [f_i^1, f_i^2, \dots, f_i^{j+j \bmod G}]$ , Initial  $k$  is 1

$j = j + 1$

else

$k = k + 1$

그림 3. Group화 과정 알고리즘




그림 4. 특징의 Group화

#### Select Lowest train error Group

while( $j \leq G$ ),  $G$  is GroupSize, initial  $j$  is 1

Calculate train error of each feature in Group

Choose  $x_i^j$  with lowest error

$j = j + 1$

그림 5. 지배특징 Group의 대표특징

기 때문이다. 그래서 지배특징 Group내에서 Group을 대표하는 대표 특징을 선별해야 한다.

그림 5는 지배특징 Group내의 대표 특징을 선별하는 알고리즘이다. 학습오차가 가장 작은 지배특징 Group을 선택하여 그 Group 내의 특징들을 각각 학습하여 학습오차를 계산한다. 그 중 가장 작은 학습오차를 가지는 특징을 지배특징 Group의 대표특징으로 선택하게 된다.

### 3.2 GroupMutual-Boost의 대표특징 학습

그림 6은 GroupMutual-Boost의 한번의 과정을 순서대로 나타내었다.

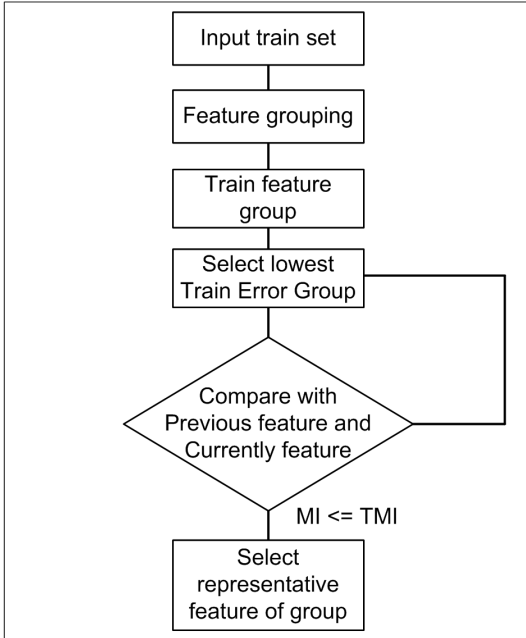


그림 6. GroupMutualBoost 구성도

위의 순서도에서 입력 값은  $M$ 차원의 벡터로 그 개수는  $N$ 개 인  $x_i$ 가 주어진다. 이 입력 값은 각각 0 또는 1이라는 클래스 인덱스(index)  $y_i$ 로 구분되어 있다. 그리고 초기의 가중치는  $1/N$ 으로 동일하게 부여한다. 다음 단계에서 학습데이터의 특징을 특정한 Group의 크기로 Group화하고 다음으로 생성된 각각의 특징Group들을 후보분류기(candidate classifier)로 학습하고 식 (1)에 따라 학습오차를 구하게 된다.

$$\mathcal{E}^{r,j} = \sum_{i=1}^N \omega^i |h^{r,j}(x_i) - y_i| \quad (1)$$

(Freund and Schapire, 1997)

식 (1)에서  $h^{r,j}$ 는  $j$ 번째 Group에 대한 후보분류기이며  $j=1,2,\dots,G$ 이다. 이렇게 각각의 Group에 대해 학습이 끝나고 각각의 Group에 대한 학습오차를 구하여 그 중 학습오차가 가장 작은 Group을 지배 특징 Group이라 한다. 하지만 하나의 Group은 여러 개의 특징을 포함하고 있기 때문에 Group이 지배특징이 될 수는 없다. 그리하여 지배 특징 Group 내의 특징들의 학습 오차를 각각 구하게 된다. 그 중 가장 작은 학습오차를 가지는 지배특징 Group내의 특징을 하나의 지배특징이라고 한다. 하나의

지배특징이 선택되게 되면 다음 과정으로 이전에 선택된 특징과 유사도를 계산한다. 유사성을 판단하기 위해 Mutual Information(Pluim *et al.*, 2003)을 이용한다. Mutual Information을 이용하여 선택된 지배특징과 이전에 선택된 지배특징과의 유사성을 구하게 된다. 이렇게 구해진 Mutual Information 값이 만약  $TMI$  값보다 작지 않으면 선택한 지배특징을 약한 분류기로 선택하지 않고 그 다음 Candidate list에서 다른 특징을 지배특징으로 선택하게 된다.  $TMI$ 는 유사도의 임계치이다. 여기서 Candidate list는 처음에 선택했던 지배특징 Group보다는 학습오차가 크지만 다른 Group보다는 학습오차가 작은 Group을 학습오차가 작은 순서대로 정렬 해놓은 것을 말한다. 선택하고자 하는 특징이 이전에 선택된 지배특징과 유사하다고 판단되면 Candidate list내에서 학습오차가 작은 Group 순서대로 다시 특징을 선택하게 된다. 이렇게 선택한 특징과 이전에 선택된 특징과의 유사도를 판단하여 지배특징을 선택하였으면 식 (2)에 의해서 각 학습데이터의 가중치를 재조정하고 다음 단계를 진행하게 된다.

$$w_i^{r+1} = w_i^r \rho_i^{1-h_r(x_i)-y_i} \quad (2)$$

(Freund and Schapire, 1997)

이러한 과정을 선택하고자하는 지배특징의 개수( $T$ )대로 반복과정을 거쳐 최종적으로  $T$ 개의 지배특징을 선택하여 강한 분류기를 얻게 된다.

GroupMutual-Boost를 이용한 특징선택방법은 다음과 같은 효과를 기대할 수 있다. 기존의 MutualBoost 방법의 특징 학습에서는 특징을 개별적으로 학습하기 때문에 특징 학습에 많은 시간이 소요된다. 이러한 문제점을 보완하기 위해 특징을 Group화 하였고 특징을 Group화 함으로서 특징 학습 시간을 상당히 줄일 수 있을 것이다. 뿐만 아니라 특징을 Group화 함으로서 컴퓨팅 자원의 낭비도 줄일 수 있고 개별적인 특징을 Group으로 묶었기 때문에 중복되는 특징과 불필요한 특징을 보다 효율적으로 제거할 수 있다. 이러한 특성으로 인해 특징 학습 시간을 줄이고 인식률 또한 높일 수 있다.

결론적으로, GroupMutual-Boost를 이용한 얼굴특징 선택 방법으로 기존의 boosting 방법의 얼굴특징 선택 방법보다 특징을 학습하고 선택할 때 소요되는 수행시간과 컴퓨터의 자원을 효율적으로 사용할 수 있고 인식률 또한 개선할 수 있다.

## 4. 실험 결과

이 장에서는 GroupMutual-Boost의 특징 선택 방법이 얼굴인식에 어떠한 성능과 효과를 얻게 되는지 실험을 통해 평가해 볼 것이다. GoupMutualBoost를 이용한 특징 선택방법의 성능과 효과를 알아보기 위해 기존에 제안된 다른 boosting기반의 특징선택 방법과 비교하여 실험 할 것이다. 비교 대상은 boosting기반의 특징선택에 있어 대표적인 AdaBoost와 특징간의 상호정보를 이용한 MutualBoost를 선택하였다. 보다 정확한 성능과 효과를 비교하기 위해 동일한 입력데이터를 사용하였고 특징을 선택하는 과정을 제외하고는 특징 추출과 학습방법 및 다른 조건들은 동일하게 적용하여 실험하였다.

### 4.1 목적 및 설계

본 논문에서는 기존의 boosting을 통한 특징선택 방법과 GroupMutual-Boost를 통한 특징선택 방법의 성능차이를 비교하여 평가하기 위해 실험을 구성하였다. 실험에 사용할 이미지 데이터는 ‘Yale Face Database’(Bellhumer et al., 1997)이고 한사람당 8개의 포즈가 있고 총 인원수는 15명이다. 하나의 이미지의 크기는  $128 \times 128$  픽셀이다. 총 120개의 이미지(15명  $\times$  8개의 포즈) 중 60개의 이미지(한사람의 8개 포즈 중 4개의 포즈, 15명  $\times$  4개 포즈)를 학습에 사용하였고, 나머지 60개의 이미지(한사람당 4개의 포즈, 15명  $\times$  4개 포즈)를 인식을 위한 테스트 이미지로 사용하였다. 먼저 얼굴이미지의 특징 추출을 위하여 Gabor 필터의 과정을 거친다. 서로 다른 주파수를 가지는 2가지 Gabor 필터를 사용하여 각 이미지로부터  $32768 (= 128 \text{ pixel} \times 128 \text{ pixel} \times 2 \text{ 가지 필터})$  차원을 갖는 특징벡터를 추출한다. 이렇게 추출된 특징벡터를 랜덤하게 조합하여 두 개의 클래스로 구분하였다. 같은 인물의 다른 포즈의 클래스(15명  $\times$  4개의 포즈)와 서로 다른 인물의 이미지로부터 추출된 특징벡터간의 벡터차로 만들어진 클래스(15명  $\times$  4명  $\times$  4개의 포즈)로 나누어진다. 이러한 동일한 데이터를 이용하여 AdaBoost와 MutualBoost 그리고 GroupMutual-Boost로 각각 다른 특징 선택방법으로 얼굴의 특징을 학습하고 지배 특징 벡터를 선택하게 된다. 이렇게 얻어진 각각의 지배 특징 벡터를 사용하여 테스트에 사용할 이미지에 각각 적용하여 인식과정을 거친다. 얼굴 특징을 학습하고 선택하는 과정에서 AdaBoost와 MutualBoost의 차이점인 선택하려는 특징과 이전에 선택된 특징과의 유사도를 비교하게 되는데 MutualBoost는 최대 비교횟수를 가진다고 하였다. 본 실험에서는 MutualBoost와 GroupMutual-




그림 7. GoupMutual-Boost 구성도

Boost의 최대 비교 횟수는 3번으로 제한하였다. 즉, 이전에 선택된 특징과 유사하다면 최대 3번 다른 특징을 선택하게 된다.

그림 7은 GroupMutual-Boost의 시뮬레이션 구성도를 나타낸 것이다. 학습 이미지의 학습 데이터가 입력값으로 들어오면 특징벡터의 특징들을 Group화 하는 과정을 거치게 되고 그 Group들을 차례대로 학습하게 된다. 학습 과정이 끝나고 나온 각 Group들의 학습오차(error) 가장 작은 특징 Group을 지배특징 Group이라고 한다. 그리고 지배특징 Group내의 각 특징들의 특징 들 중 학습오차가 가장 작은 특징을 지배특징으로 선택하게 된다. 이렇게 선택된 지배특징을 Mutual Information을 이용하여 이전에 선택된 특징과 비교를 하게된다. MI값이 TMI값보다 그 특징을 지배특징으로 선택하게 된다. 본 실험에서 Group의 사이즈는 4로 설정하였다. 즉 4개의 특징이 하나의 Group을 이루고 그 Group이 하나의 특징이 되는 것이다.

### 4.2 결과 및 분석

본 실험은 서로 다른 방법으로 특징을 선택하여 그 중 어떠한 방법이 더 효율적으로 식별력있는 특징을 선택하는지 성능을 측정 할 수 있다. 얼굴 인식률과 수행시간을 통하여 각각의 특징 선택방법이 효율적인 식별력 있는 특징을 선택하느냐의 성능을 비교 분석할 수 있다.

그림 8은 AdaBoost, MutualBoost, GroupMutual-Boost를 이용한 각각의 특징 선택 방법에 따른 얼굴인식률을 보여준다. 전체 32768개(=128pixel  $\times$  128pixel  $\times$  2개의 필터)의 특징 중 식별력 있는 특징을 최소 30개에서 최대 80개 까지 선택하여 선택한 특징 개수에 따른 인식률의 변화를 보여준다. 그림 8의 그래프에서 알 수 있듯이 GroupMutual-Boost의 특징 선택 방법으로 식별력있는 특징을 65개 선택하여 인식을 하였을 때 AdaBoost의 인식률은 약 88.3%, MutualBoost의 인식률은 약 86.6%로 측정되었지만 GroupMutual-Boost는 약 95%로 MutualBoost와 AdaBoost




그림 8. 특징 선택 개수에 따른 인식률

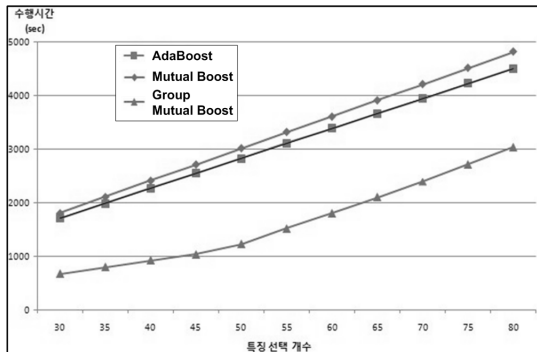


그림 9. 특징 선택 개수에 따른 수행시간

의 인식률보다 항상 되었다. 특징의 개수가 30개부터 80개까지 구간모두 GroupMutual-Boost의 특징선택방법이 MutualBoost나 AdaBoost보다 높은 인식률이 나왔고 각각의 최대 인식률은 GroupMutual-Boost는 약 95%, MutualBoost는 약 90%, AdaBoost도 약 90%로 측정되었다. 이러한 각각의 인식률 결과를 통하여 GroupMutual-Boost를 통한 특징선택 방법이 MutualBoost나 AdaBoost의 특징선택 방법보다 식별력있는 특징을 선택하여 인식률에서도 보다 좋은 성능을 보인다.

그림 9는 AdaBoost와 MutualBoost, 그리고 GroupMutual-Boost를 이용한 각각의 특징 선택 방법에 따른 지배특징 선택에 필요한 소요시간을 측정된 결과이다. 그래프에서 알 수 있듯이 AdaBoost와 MutualBoost를 통한 특징 선택 방법으로 80개의 지배특징을 선택하는데 소요된 시간은 AdaBoost는 약 4500초, MutualBoost는 약 4800초이고 GroupMutual-Boost를 통한 특징 선택 방법으로 80개의 지배특징을 선택하는데 소요된 시간은 약 3000초 정도이다. 그리고 구간별로 시간을 측정된 결과 5개의 특징을 선택할 때 AdaBoost는 약 270초, MutualBoost는 약 300초, GroupMutual-Boost는 약 100초 정도 소요된다. 이런 결

과를 통해 GroupMutual-Boost를 통한 특징 선택방법으로 지배 특징을 선택하는데 소요되는 시간이 MutualBoost와 AdaBoost를 통한 특징 선택 방법 보다 약 1.5배 정도 빠르다는 것을 알 수 있다. 이러한 결과가 나온 이유로는 AdaBoost와 MutualBoost는 32768개(=64 pixel × 64 pixel × 2개의 필터)의 특징을 각각 하나씩 학습하여 총 32768번의 학습과정을 거치게 되지만 GroupMutual-Boost는 32768개의 특징을 8192개의 Group으로 나누어 학습하기 때문에 AdaBoost와 MutualBoost보다 1/4번의 학습과정인 8192번의 학습과정을 거치게 된다. 그렇기 때문에 하나의 이미지를 학습하는데 소요되는 시간과 비용이 줄어든다는 것을 알 수 있다.

## 5. 결 론

본 논문에서는 기존의 MutualBoost의 특징선택방법에서 각 특징들을 Group화 하는 GroupMutual-Boost 특징선택방법을 제안하였다. 기존의 Boosting기법들인 AdaBoost나 MutualBoost는 각각의 특징의 학습 및 선택을 하기 때문에 컴퓨팅자원이 많이 소요되고 또한 학습 및 선택과정에서 많은 시간을 요구한다. 하지만 제안한 GroupMutual-Boost 방법은 특징을 Group화 하기 때문에 컴퓨팅 자원과 시간을 보다 효율적으로 사용할 수 있다. 또한 특징을 개별적으로 학습하는 것이 아니라 여러개의 특징을 Group화 하여 학습하여 중복되는 특징과 불필요한 특징을 효율적으로 제거하여 보다 식별력있는 특징을 선별해 낼 수 있다. 이러한 결과를 통해서 본 논문에서 제안한 GroupMutual-Boost를 이용한 얼굴 특징 선택 및 얼굴인식 방법이 컴퓨팅 시간뿐만 아니라 식별력있는 특징을 효율적으로 선별해 내 인식률에서도 우수한 성능을 보인다고 할 수 있다.

## 참 고 문 헌

1. J. P. W. Pluim, J. B. A. Maintz, and M. A. Viergever (2003), "Mutual-information-based registration of medical images: A survey," *IEEE Trans. Med. Imag.*, Vol. 22, No. 8, pp. 986-1004.
2. John G. Daugman (1988), "Complete discrete 2D Gabor transforms by neural networks for image analysis and compression," *IEEE Trans. Acoust., Speech, Signal Processing*, Vol. 36, No. 7, pp. 1169-1179.
3. L. Shen and L. Bai (2004), "Adaboost gabor feature selection for classification," *Proc. of Image and Vision Computing*, New Zealand, pp. 77-83.

4. L. Shen and L. Bai (2006), "MutualBoost Learning for Selection Gabor Features for Face Recognition", *Pattern Recognition Letters*, Vol. 27, pp. 1758-1767.
5. P. Burrascano (1991), "Learning vector quantization for the probabilistic neural network," *IEEE Trans. Neural Networks*, Vol. 2, pp. 458-461.
6. P. N. Bellhumer, J. Hespanha and D. Kriegman (1997), "Eigenfaces vs Fisherfaces: Recognition using class specific linear projection", *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 17, pp. 711-720.
7. P. Somol, P. Pudil, J. Novovicova, and P. Paclik (1999), "Adaptive floating search methods in feature selection," *Pattern Recogn. Lett.*, Vol. 20, No. 11-13, pp. 1157-1163.
8. P. Viola and M. Jones (2001), "Rapid Object Detection Using a Boosted Cascade of Simple Features," *In Proc. Of IEEE Conference on Computer Vision and Pattern Recognition*, pp. 511-518.
9. P. Yang, S. Shan, W. Gao, S. Li, and D.Zhang (2004), "Face recognition using Ada-boosted Gabor features," *In Proc. Conference on Automatic Face and Gesture Recognition*, pp. 356-361.
10. S. Z. Li and Z. Q. Zhang (2004), "FloatBoost Learning for Selection Gabor Features for Face Recognition", *Pattern Recognition Letters*, Vol. 27, pp. 1758-1767.
11. S. Z. Li, Z. Zhang, H. Shum (2002), and H. Zhang, "FloatBoost Learning for Classification", *In Proc. NIPS*, pp. 993-1000.
12. Y. Freund. and R. Schapire (1999), "A short introduction to boosting," *J. Japanese Soci. Artific. Intell.* Vol. 14, pp. 771-780.



**최 학 진** (hak-jins@hanmail.net)

2009 인하대학교 컴퓨터공학부 학사  
2009~현재 인하대학교 정보공학과 석사과정

관심분야 : 시스템 모델링&시뮬레이션, 패턴인식, 분산 컴퓨팅



**이 종 식** (jslee@inha.ac.kr)

1993 인하대학교 전자공학과 학사  
1995 인하대학교 전자공학과 석사  
2001 미국 애리조나대 전기·컴퓨터공학과 박사  
2001~2002 캘리포니아 주립대학교 전기·컴퓨터공학과 전임강사  
2002~2003 클리블랜드 주립대학교 전기·컴퓨터공학과 조교수  
2003~2006 인하대학교 컴퓨터공학부 조교수  
2006~현재 인하대학교 컴퓨터정보공학부 부교수

관심분야 : 시스템 모델링&시뮬레이션, 그리드 컴퓨팅, 소프트웨어공학