

퍼지기반 Segment-Boost 방법을 통한 효과적인 얼굴인식

장원석^{1†} · 노창현¹ · 이종식¹

Fuzzy-based Segment-Boost Method for Effective Face Recognition

Won-Suk Chang · Chang-Hyeon Noh · Jong-Sik Lee

ABSTRACT

This paper suggests fuzzy-based Segment-Boost method and an effective method for face recognition using the fuzzy-based Segment-Boost. Fuzzy-based Segment-Boost eliminates the limitations of Segment-Boost, and it guarantees improved learning performance and the stability of the performance. By using the fuzzy theory, fuzzy-based Segment-Boost optimizes the selection number of sub-vectors, and leads the optimized learning performance. The fuzzy controller designed in this paper measures learning performance of the fuzzy-based Segment-Boost, and it controls the selection number of sub-vectors by inferring the optimized selection number. The simulation results show that the fuzzy controller inferred the selection number which is very approximate to the true optimized value. As a result, fuzzy-based Segment-Boost showed higher face recognition rate than compared boosting methods and it preserves the velocity of feature selection as fast as that of Segment-Boost. From the experimental results, it was proved that fuzzy-based Segment-Boost has improved and stable performances of learning, feature selection and face recognition.

Key words : Fuzzy-based Segment-Boost, Feature selection, Face recognition

요약

본 논문에서는 퍼지기반 Segment-Boost 방법을 소개하고, 이를 이용한 효과적인 얼굴인식 방법을 제안한다. 퍼지기반 Segment-Boost는 기존의 Segment-Boost가 갖고 있던 문제점과 성능의 한계요소들을 제거함으로써, 향상된 학습 성능뿐만 아니라 학습 성능의 안정성과 신뢰성을 보장하여 준다. 퍼지기반 Segment-Boost는 퍼지이론을 이용함으로써 서브벡터 선택개수를 최적화하고, 이를 통해 최상의 학습 성능이 유도될 수 있도록 설계되었다. 또한, 퍼지기반 Segment-Boost 내에서의 퍼지추론을 위해 본 논문에서 설계한 퍼지 제어기는 퍼지기반 Segment-Boost의 학습 성능을 측정하고, 최적화된 서브벡터 선택개수를 추론함으로써 서브벡터 선택개수를 제어한다. 시물레이션 결과, 본 논문에서 설계한 퍼지 제어기는 실제 최적의 서브벡터 선택개수에 매우 근접한 값을 추론하였다. 그 결과, 퍼지기반 Segment-Boost는 비교 실험한 boosting 방법보다 높은 얼굴인식률을 보여줌과 동시에 기존 Segment-Boost 만큼의 빠른 특징선택 속도를 유지하였고, 이러한 실험결과를 통해 퍼지기반 Segment-Boost의 학습 성능과 이를 이용한 특징선택 및 얼굴인식 방법에 있어서의 성능향상 및 안정성이 입증되었다.

주요어 : 퍼지기반 Segment-Boost, 특징선택, 얼굴인식

1. 서론

퍼지이론(fuzzy theory)^[8,13]은 수치화하기 어려운 모호한 정보에 대해 인간의 뇌가 처리하는 방법을 모사함으로써

문제 해결에 접근하는 이론이다. 퍼지이론의 장점은 이것이 수학적으로 접근하기 어려운 문제에 대해서도 매우 근사적인 해를 제공한다는 것이다. 이러한 장점으로 인해 퍼지이론은 인공지능, 패턴인식, 자동제어 등의 다양한 분야에 널리 응용되고 있다.

* 이 논문은 인하대학교의 지원에 의하여 연구되었음.

2008년 11월 11일 접수, 2009년 1월 28일 채택

¹⁾ 인하대학교 컴퓨터정보공학과

주 저자 : 장원석

교신저자 : 장원석

E-mail; wkddt@hotmail.com

본 논문에서는 퍼지이론을 Segment-Boost에 접목함으로써 Segment-Boost가 지닌 학습 성능의 불안정성을 보완하고 성능저해 요인들을 극복할 수 있는 새로운 boosting 방법을 제안하고자 한다.

Segment-Boost^[2]는 기계학습 방법의 성능을 향상시키기 위해 고안된 boosting 방법의 하나이다. Segment-Boost는 하나의 분류기(classifier)를 학습시키는 데 있어, 벡터 형태의 학습 패턴(pattern)을 특정 개수의 서브벡터(sub-vector)로 나누어 학습한 후에 그중 학습결과가 가장 우수한 서브벡터를 선별하고 선별된 서브벡터에 대해서 이러한 분할, 학습, 선별의 과정을 반복해 나가는 학습방식을 취하고 있다. 이러한 특징으로 인해 Segment-Boost는 효과적인 패턴학습이 가능하다. 실제로 얼굴특징 선택에 있어 Segment-Boost는 빠르고 우수한 특징선택 능력을 보여주었을 뿐만 아니라 비교 실험한 AdaBoost^[12]와 Mutual-Boost^[10] 기반의 특징선택 방법보다도 뛰어난 성능을 보여주었다^[2]. 그러나 이러한 Segment-Boost의 학습 성능은 벡터분할 조건, 즉 벡터분할 개수에 의해서 차이를 보이며, 더욱이 다른 boosting 방법 보다 향상된 학습 성능을 보장할 수 있는 벡터분할 조건을 찾는 것은 실험적인 방법 외에는 거의 불가능하다. 따라서 벡터분할 조건에 따라서는 Segment-Boost가 다른 boosting 방법 보다 저하된 학습 성능을 보일 수 있다. 뿐만 아니라 Segment-Boost는 분할된 서브패턴 중 학습결과가 가장 좋은 1개만을 취해나가는 방식을 사용하기 때문에, 선별된 서브벡터에 대해서는 세부적인 학습이 진행되지만 일단 제외된 나머지 서브벡터들은 현재의 분류기 학습이 끝날 때까지는 학습에서 배제가 된다. 그러나 하나의 패턴을 구성하는 수많은 패턴요소들 중, 패턴에 대해 가장 우수한 분류식별력을 지니는 패턴요소가 학습에서 배제된 나머지 서브벡터들에 존재할 가능성도 얼마든지 있다. 결과적으로 서브벡터 선별에 있어 Segment-Boost가 지니는 이러한 제약성은 다양한 패턴요소에 대한 학습을 제한하고 결국 학습 성능에 있어 한계 요소로 작용한다.

따라서 이러한 Segment-Boost의 단점을 극복할 수 있는 보다 효과적인 boosting 방법이 필요하다. 본 논문은 이러한 필요성에 의해 퍼지기반 Segment-Boost라는 새로운 boosting 방법을 제안한다. 퍼지기반 Segment-Boost의 특징은 우선, 기존의 Segment-Boost와는 달리 서브벡터의 선택개수에 유연성을 부여함으로써 보다 세부적인 학습이 가능하다는 것이다. 뿐만 아니라, 제안한 방법은 퍼지이론을 이용함으로써 주어진 벡터분할 조건에서 최적의 서브벡터 선택개수를 추론하여 최적의 학습 성능을 유도하고 벡터분할 개수의 영향을 최소화하여 안정적인 학습 성능을 발휘할 수 있다.

아울러 본 논문에서는 우리가 제안한 퍼지기반 Segment-Boost 방법을 통한 효과적인 얼굴인식 방법을 제안한다.

그리고 기존의 Segment-Boost와 최근 발표된 boosting 방법과의 얼굴인식 성능비교를 통해 우리가 제안한 방법의 향상된 학습 성능과 특징선택 및 얼굴인식 성능을 입증할 것이다.

본 논문의 나머지 부분은 다음과 같이 구성된다. 2장의 관련 연구에서는 퍼지이론에 대해 개괄적으로 서술하고 기존 boosting 기반의 얼굴특징 선택 방법에 대해 소개한다. 3장에서는 퍼지기반 Segment-Boost 방법과 이를 통한 효과적인 얼굴인식 방법을 제안하고 퍼지추론을 위한 퍼지 제어를 설계한다. 4장에서는 3장에서 설계한 퍼지기반 Segment-Boost와 퍼지 제어를 가지고 기존의 boosting 방법들과 학습 성능과 특징선택 및 얼굴인식 성능을 비교 시험하고 결과를 분석하며 5장에서 결론을 맺도록 한다.

2. 관련 연구

2.1 퍼지이론

퍼지이론은 퍼지 집합(fuzzy set)과 소속 함수(membership function), 그리고 제어 규칙(control rules)이라는 세 가지 개념으로 설명될 수 있다^[13]. 먼저, 퍼지집합은 전통적인 집합과는 다소 다른 개념이다. 퍼지집합에 속한 원소들에는 그 집합에 대한 소속도(degree of membership)가 부여되는데 소속도는 $[0,1]$ 범위의 실수 값을 갖는다. 그리고 이러한 소속도는 소속함수에 의해 정의되며 제어규칙은 퍼지입력으로부터 퍼지출력을 추론하여 주는 역할을 한다. 퍼지이론을 실제계의 문제에 적용하기 위해서는 퍼지화(fuzzification)와 퍼지추론(fuzzy inference), 역퍼지화(defuzzification)의 과정이 필요하다. 퍼지화는 입력된 실수 값을 퍼지집합과 소속함수에 의해 퍼지입력으로 변환하는 과정이다. 퍼지화를 통해 얻어진 퍼지입력은 제어 규칙들에 의해 퍼지출력으로 추론되고, 퍼지출력은 역퍼지화를 통해 다시 실수 값으로 변환된다.

2.2 Boosting 기반의 얼굴특징 선택

얼굴 이미지를 인식하기 위해서는 이미지로부터 특징(feature)들을 추출하는 특징 추출과정이 필요하다. 얼굴 특징 추출 방법 중 Gabor 필터^[3]를 이용한 방법은 얼굴 이미지에 나타난 얼굴 표정이나 회전, 크기, 조명 밝기 등의 변화에도 강인한 특징을 갖는다. 이러한 이유로 Gabor 필터를 이용한 특징 추출 방법은 얼굴 인식 관련 연구들에서 널리 채택되고 있으며^[4,7,10] 본 논문에서도 얼굴 특징 추출에 이 방법을 사용하였다. 특징 추출 과정을 통해서

하나의 얼굴 이미지로부터 추출된 다수의 특징들은 각각이 벡터성분을 이루어 하나의 특징벡터(feature vector)가 된다. 그리고 이렇게 얻어진 특징벡터를 가지고 얼굴 이미지를 식별하게 되는데 일반적으로 특징벡터는 매우 많은 특징들을 가지고 있으며 그중에는 얼굴 인식에 불필요하거나 중복된 특징들이 다수 포함되어 있다. 따라서 특징벡터의 모든 특징들을 얼굴인식에 그대로 사용하는 것은 얼굴인식 능력을 저하시킬 수 있으며 데이터 처리속도 면에서도 비효율적이다. 이러한 이유로, 보다 효과적인 얼굴 인식을 위해서는 특징벡터로부터 식별력이 우수한 일부 특징들만을 선별하는 특징 선택 과정이 필요하다.

AdaBoost^[12]가 특징선택에 성공적으로 적용된 이후로 boosting 방법은 특징선택에 있어 탁월한 성능을 보여 왔으며, 여러 가지 개선된 boosting 방법을 기반으로 한 특징선택 방법들이 제시되어왔다^[6,10]. 대부분의 boosting 방법은 패턴분류에 있어 분류할 클래스를 2개로 한정하고 있다. 따라서 다중클래스(multi-class) 문제인 얼굴인식 문제에 boosting 방법을 적용하기 위해서는 일반적으로 intra/extra-personal^[9] 특징벡터 개념을 채용한다. 이를 통해, 특징벡터들로부터 2가지 클래스로 나뉘는 intra/extra-personal 특징벡터들을 얻을 수 있고, 이것들을 boosting 방법의 학습데이터로 사용하여 intra/extra 두 클래스에 대한 분별력을 가진 소정의 특징들을 선택해 낼 수 있다. 입력된 얼굴이미지와 가장 일치하는 이미지를 찾아내는 것이 얼굴인식의 목적이므로, 이상과 같이 intra/extra-personal 특징벡터로부터 선택된 특징들은 얼굴인식에 있어서도 유효한 식별력을 지니고 있다고 말할 수 있으며 얼굴인식에 있어서도 동일하게 사용될 수 있다^[10].

Segment-Boost를 이용한 특징선택 방법^[2]은 boosting 기반의 특징선택 기법 중의 하나이다. 특징선택에 있어 기존의 boosting 방법들은 특징벡터 상의 개별 특징들을 단위로 학습하고 그중 최상의 특징을 선택하는 방식이었다. 이에 반해, Segment-Boost는 특징벡터를 개별특징들의 집합인 서브벡터로 나누어 학습하고 그 중 최상의 서브벡터를 선별하여 재분할하는 방식을 취하고 있다. 이러한 특징으로, Segment-Boost는 기존의 boosting 방법 보다 매우 빠른 특징선택이 가능하다. 뿐만 아니라 개별특징이 갖는 식별력과 더불어 서브벡터 안에서 다른 특징들과의 상보성을 고려함으로써 패턴인식에 있어 보다 유용한 특징조합을 얻을 수 있다는 장점이 있다. 그러나 Segment-Boost는 선별된 서브벡터를 제외한 나머지 서브벡터들에 대해서는 더 이상 세분화된 학습을 진행하지 않기 때문에 학습에 있어서 이로 인한 구조적인 한계점을

안고 있다. 뿐만 아니라 Segment-Boost의 특징선택 또는 학습 성능은 특징벡터를 몇 개의 서브벡터로 분할하는지의 분할 조건에 따라 불규칙한 성능 편차를 보인다. 이는 실험적인 방법을 적용하지 않고서는 성능보장을 위한 적절한 벡터분할 조건을 찾기 어렵다는 것을 의미한다. 이것은 Segment-Boost 방법의 학습 성능에 대한 불안정 요소로서, Segment-Boost가 갖는 또 다른 한계점이다. 따라서 Segment-Boost의 이러한 한계점들을 극복할 수 있는 새로운 boosting 기반의 특징선택 방법이 요구된다.

3. 퍼지기반 Segment-Boost 학습

본 3장에서는 본 논문에서 제안하는 퍼지기반 Segment-Boost와 이를 통한 효과적인 얼굴인식 방법을 제안하고, 퍼지기반 Segment-Boost 방법 내에서의 퍼지추론을 위한 퍼지제어기를 설계한다.

3.1 퍼지기반 Segment-Boost

그림 1은 퍼지기반 Segment-Boost 방법을 서술하고 있다. 기존의 Segment-Boost에서 서브 벡터 선택을 1개로 제한함으로써 발생하는 학습 성능 상의 한계를 극복하기 위해 그림 1의 퍼지기반 Segment-Boost에서는 서브벡터 선택개수에 유연성과 확장성을 부여하고 있다. 그림 1에서 K 가 바로 선택할 서브벡터의 개수, 즉 선택할 분류기(classifier)의 개수이다. 서브벡터 선택개수에 있어서의 이러한 유연성과 확장성은 보다 많은 서브벡터에 대해 세분화된 학습이 가능하게 한다. 또한 이러한 유연성을 통해, 벡터분할 개수 등의 주어진 학습조건에서 boosting 학습 성능이 최적화되도록 서브벡터 선택개수를 적절히 설정하는 것이 가능해진다. 서론에서 언급한 바와 같이 퍼지이론은 수학적으로 정형화하여 모델링하기 어려운 문제에 대해서도 비교적 정확한 해를 제공한다는 장점이 있다. 퍼지기반 Segment-Boost 방법에서 서브벡터 선택개수 K 에 대한 최적 값을 찾는 문제는 여기에 퍼지이론을 적용함으로써 보다 효과적으로 매우 근사적인 해에 접근할 수 있다. 퍼지기반 Segment-Boost 방법에서는 퍼지이론을 적용함으로써 서브벡터 선택개수를 최적의 값으로 설정하고 이를 통해 최상의 학습 성능을 유도한다. 그리고 이를 통해 알고리즘의 패턴학습 및 특징선택에 있어서의 성능향상을 기대할 수 있다. 뿐만 아니라, 서브벡터 선택개수 K 에 대한 최적화를 통해 벡터분할 개수에 따른 학습 성능편차를 최소화할 수 있으며, 이것은 결국 boosting 학습 성능에 안정성과 신뢰성을 보장하여 준다. 결론

Input : N training examples (x_i, y_i) where
 $i = 1, 2, \dots, N, x_i \in \mathbb{R}^M, y_i \in \{0, 1\}$

1. Initialize $K, \Delta K = K$.
2. Initialize weights of examples $w_i^1 = \frac{1}{N}$
3. Do for $t = 1, 2, \dots, T$
 - 3.1. Normalize the weights $w_i^t = \frac{w_i^t}{\sum_{n=1}^N w_n^t}$
 - 3.2. Divide x_i into $S(1 < S < M)$ sub-vectors,
 $x_i = [\mathbf{f}_i^{r,1} \mathbf{f}_i^{r,2} \dots \mathbf{f}_i^{r,j} \dots \mathbf{f}_i^{r,S}]$ where $r = 1$.
 - 3.2.1. For each sub-vector, $\mathbf{f}^{r,j}$,
 train a candidate classifier $h^{r,j}$ with distribution w^f .
 - 3.2.2. Calculate the training error

$$\varepsilon^{r,j} = \sum_{i=1}^N w_i^t |h^{r,j}(x_i) - y_i|.$$
 - 3.2.3. Choose K classifiers $h^{r,c_1}, h^{r,c_2}, \dots, h^{r,c_k}$
 with the lowest errors $\varepsilon^{r,c_1} \geq \varepsilon^{r,c_2} \geq \dots \geq \varepsilon^{r,c_k}$.

$$\mathbf{f}^{r,c} = [\mathbf{f}^{r,c_1} \mathbf{f}^{r,c_2} \dots \mathbf{f}^{r,c_k}].$$
 - 3.2.4. If the dimension of $\mathbf{f}^{r,c_1} \leq 1$

$$h_t = h^{r,c_1}, \varepsilon_t = \varepsilon^{r,c_1}.$$

 Go to 3.3.
 - Else
 Segment $\mathbf{f}^{r,c}$ into S sub-vectors,

$$\mathbf{f}^{r,c} = [\mathbf{f}^{r+1,1} \mathbf{f}^{r+1,2} \dots \mathbf{f}^{r+1,j} \dots \mathbf{f}^{r+1,S}].$$

 $r = r + 1.$
 Go to 3.2.1.
- 3.3. Update the weights of examples

$$w_i^{t+1} = w_i^t \beta_t^{1 - |h_t(x_i) - y_i|}, \text{ where } \beta_t = \frac{\varepsilon_t}{1 - \varepsilon_t}$$
4. The final strong classifier :

$$H(x) = \begin{cases} 1 & \text{if } \sum_{t=1}^T (\log \frac{1}{\beta_t}) h_t(x) \geq \frac{1}{2} \sum_{t=1}^T (\log \frac{1}{\beta_t}) \\ 0 & \text{otherwise} \end{cases}$$
5. If $\Delta K \neq 0$
 Get training error.
 Get ΔK through fuzzy inference.
 $K = K + \Delta K$
 Go to 2.

그림 1. 퍼지기반 Segment-Boost 알고리즘

적으로 퍼지기반 Segment-Boost 방법은 기존에 발표된 Segment-Boost의 단점과 한계요소들을 극복함으로써, 빠른 학습속도와 향상된 학습능력, 그리고 학습 성능의 안정성이라는 장점을 갖는다.

3.2 퍼지기반 Segment-Boost를 통한 얼굴인식 방법

본 절에서는 퍼지기반 Segment-Boost 알고리즘을 이용한 효과적인 얼굴인식 방법을 제안한다. 우선 얼굴특징 학습 및 선택 과정을 살펴보면, 알고리즘은 intra/extra-personal 특징벡터를 입력으로 하여 입력된 특징벡터를 S 개의 부분벡터(segment)로 분할하여 학습한다. 학습이 끝나면 학습오차가 적은 상위 K 개의 부분벡터를 선별하고 이들을 차례로 연결하여 하나의 벡터를 얻는다. 그리고 이 벡터를 다시 S 개의 부분벡터로 재분할하여 학습한다. 이러한 과정은 선별된 부분벡터의 차원이 1이 되어 그것으로 1개의 특징을 얻을 때까지 반복된다. 그리고 특징 1개를 얻기까지의 일련의 과정을 소정의 횟수만큼 반복함으로써 퍼지추론을 위한 소정의 특징들을 선택해낼 수 있다. 이러한 소정의 특징들이 선택되면 이들을 가지고 학습오차를 구한다. 학습오차는 학습 및 특징선택에 사용된 학습데이터를 그대로 분류시켜봄으로써 측정한다. 학습오차가 구해지면 이를 가지고 퍼지추론을 하여 서브벡터 선택개수 K 를 조정한다. 서브벡터 선택개수 K 에 대한 이와 같은 제어는 K 가 안정된 값에 도달할 때($\Delta K = 0$)까지 반복적으로 진행된다. 서브벡터 선택개수 K 가 안정된 값에 도달하면 퍼지제어 과정은 완료되며, 그 때의 K 값이 최적 값이 되고 이때 선택된 특징들을 얼굴인식에 사용되게 된다. 이와 같이 퍼지기반 Segment-Boost를 특징선택에 사용함으로써 기존 boosting 기반의 방법보다 얼굴이미지에 대해 향상된 식별력을 지닌 양질의 특징선택이 가능하여 진다.

2.2절에서 언급한 바와 같이, intra/extra-personal 특징 벡터들로부터 선택된 특징들은 얼굴인식에 있어서도 유효한 식별력을 지닌다. 그러므로 이와 같은 방법으로 선택된 특징들은 얼굴인식에 그대로 사용될 수 있으며, 별도의 분류기 학습이 필요 없이 특징선택 과정에서 학습된 퍼지기반 Segment-Boost를 얼굴인식에 사용하면 된다. 단, 특징선택 과정을 통해 학습된 퍼지기반 Segment-Boost는 intra/extra-personal 특징벡터 여부만을 구분할 수 있기 때문에, 이를 얼굴인식에 사용하기 위해서는 추가적인 조치가 필요하다. 이를 위해 본 논문에서는 인물에 따라 U 개의 클래스로 구분되는 얼굴이미지들로부터 각 인물을 대표할 수 있는 대표 특징벡터를 정하였다. 대표 특징 벡터는 동일 클래스에 속하는 특징벡터들의 평균이다. 얼굴인식을 위해 입력된 입력이미지의 특징벡터 I 와 클래스 $i(i = 1, 2, \dots, U)$ 에 속하는 U 개의 대표 특징벡터 R_i 사이에서 U 개의 intra/extra-personal 특징벡터 P_i 를 유도할

수 있다. 이와 같이 유도된 P_i 를 퍼지기반 Segment-Boost로 분류시켜 보았을 때, intra-personal 클래스에 속할 확률이 가장 높은 특징벡터가 $P_m (m = 1, 2, \dots, U)$ 이고 그 확률이 0.5보다 크다면 입력이미지는 클래스 m 에 속하는 것으로 판단할 수 있으며, 확률이 0.5 이하라면 어떠한 클래스에도 속하지 않는 것으로 판단할 수 있다. 이와 같은 얼굴인식 방법은 얼굴인식을 위한 추가적인 학습알고리즘 또는 학습과정이 불필요할 뿐만 아니라, 얼굴특징 선택에 사용한 퍼지기반 Segment-Boost 방법을 얼굴인식에 그대로 이용함으로써 boosting의 효과를 최대로 활용하여 얼굴인식률을 향상시킬 수 있다는 장점이 있다.

3.3 퍼지 제어기 설계

퍼지기반 Segment-Boost 방법에서 퍼지이론을 통해 추론 및 제어하고자 하는 대상은 서브벡터 선택개수인 K 이다. 이때, 추론의 판단 근거로 삼을 수 있는 것은 서브벡터 선택개수 K 에 따른 학습 성능이다. 따라서 퍼지제어기는 학습 성능변화 추이를 관찰함으로써 학습오차가 최소가 되는 최적의 서브벡터 선택개수 K 를 적절히 추론/제어할 수 있도록 설계되었다.

본 논문에서 설계한 퍼지 제어기는 다음과 같은 퍼지 입/출력을 갖는다. 먼저 퍼지입력은 퍼지기반 Segment-Boost의 학습오차 변화 추이를 파악할 수 있는 정보로서, 서브벡터 선택 개수 K 의 변화량(ΔK)과 학습오차 감소율(d), 그리고 학습오차 감소율 d 의 변화량(Δd)이다. 서브벡터 선택개수 K 의 변화량 ΔK 는 현재의 제어 시퀀스(sequence) q 에서의 K 값을 K_q 라 할 때,

$$\Delta K = K_q - K_{q-1} \tag{1}$$

로 정의된다. 학습오차 감소율 d 는 $K=1$ 일 때의 학습오차를 기준으로 한 상대적인 오차감소율로서, e_j 를 $K=j$ 일 때의 퍼지기반 Segment-Boost의 학습오차라고 할 때,


$$d = \frac{e_1 - e_j}{e_1} \tag{2}$$

와 같이 정의된다. 한편, 학습오차 감소율 d 에 대한 변화량 Δd 는 현재 제어 시퀀스 q 에서의 학습오차 감소율을 d_q 라 할 때,


$$\Delta d = d_q - d_{q-1} \tag{3}$$

와 같이 정의 된다.


퍼지출력은 서브벡터 선택개수 K 에 대한 제어크기




(a) 퍼지 입력 ΔK 에 대한 소속 함수



(b) 퍼지 입력 d 에 대한 소속 함수



(c) 퍼지 입력 Δd 에 대한 소속 함수



(d) 퍼지 출력 ΔK 에 대한 소속 함수

그림 2. 퍼지 입/출력 소속 함수

(ΔK)이다. 퍼지출력에 의해 서브벡터 선택개수 K 값은 ΔK 만큼 증감된다. 퍼지 입/출력 변수에서 알 수 있듯 본 논문에서 설계한 퍼지제어기는 퍼지 출력 ΔK 를 다시 퍼지 입력으로 사용하는 피드백(feed-back) 제어요소를 포함하고 있다. 이는 피드백 제어를 통해 서브벡터 선택 개수 K 의 값이 보다 빨리 안정된 값에 도달하도록 하기 위한 조치이다.

본 논문에서 정의한 퍼지 소속 함수는 그림 2와 같다.

표 1. 퍼지 제어 규칙

Rule	퍼지 입력			퍼지 출력
	ΔK	d	Δd	
Rule 1	P	LN or N	N	LN
Rule 2			P	LP
Rule 3		P or LP	N	N
Rule 4			P	P
Rule 5	P or N	P or N	Z	N
Rule 6				LN
Rule 7		LP		Z
Rule 8		P or N		P
Rule 9	N	LN or N	P	LN
Rule 10			N	LP
Rule 11		P or LP	P	Z
Rule 12			N	P
Rule 13	Z	LN or N or P or LP	N or Z or P	Z

※ LN : Large Negative, N : Negative, Z : Zero, P : Positive, LP : Large Positive

그리고 제어 규칙은 표 1에 정리되어 있으며, 표 1에서 각각의 퍼지 입력들은 AND연산 관계에 있는 것이다. 한편, 퍼지 규칙을 이용한 출력 추론 방법으로는 일반적으로 널리 사용되는 min-max 합성법^[8]을 사용하였고, 역퍼지화에는 무게중심법(Center of Area)^[5]을 사용하였다.

4. 실험 및 결과 분석

본 장에서는 퍼지기반 Segment-Boost 방법을 가지고 퍼지제어 시뮬레이션과 특징선택 및 얼굴인식 시험을 수행할 것이다. 그리고 결과분석을 통해 3장에서 설계한 퍼지 제어기가 갖는 서브벡터 선택개수 K 에 대한 제어 성능을 평가하고, 퍼지기반 Segment-Boost가 갖는 학습 및 특징선택 성능과 이를 이용한 얼굴인식 성능을 검증할 것이다.

4.1 실험 목적 및 설계

본 절에서는 본 논문에서 제시한 퍼지기반 Segment-Boost 방법의 학습 및 특징선택 효과를 실험을 통해 확인해 보고자 한다. 이를 위해 퍼지기반 Segment-Boost 방법과 3장에서 설계한 퍼지제어기를 가지고, 얼굴이미지로부터 추출된 특징벡터에서 소정의 특징들을 선택하고 최종적으로 얼굴인식 실험을 통해 제안한 방법의 성능을 검증하여 볼 것이다.

실험을 위해 본 논문에서는 ‘The Yale Face Database’^[11]의 얼굴이미지로부터 얼굴영역에 해당하는 128×128 픽




그림 3. 퍼지제어 시뮬레이션 구성도

셀 크기의 다양한 얼굴이미지 120개(=15명×8개)를 얻어 실험에 사용하였다. 그리고 얼굴특징 추출을 위해 2가지 주파수를 갖는 Gabor 필터를 사용하였다. 퍼지기반 Segment-Boost 방법의 학습 및 얼굴특징 선택을 위한 intra/extra 학습데이터는 60개(15명×4개)의 이미지로부터 추출하여 얻었다. 먼저, 60개의 이미지로부터 32,768(=128픽셀×128픽셀×2개 필터) 차원을 갖는 60개의 특징벡터들을 추출한 후, 이들을 무작위(random)로 조합하여 60개의 intra-personal 특징벡터와 840개의 extra-personal 특징벡터를 만들어 학습데이터로 사용하였다.

그림 3은 퍼지제어 시뮬레이션 구성을 나타낸다. 퍼지기반 Segment-Boost는 입력된 학습데이터를 이용하여 소정의 얼굴특징을 선택해 내고 선택된 특징들을 바탕으로 학습데이터와 동일한 데이터를 분류해 본다. 그 결과 학습오차가 산출되고, 학습오차는 퍼지 입력으로 변환되어 퍼지 제어기에 입력된다. 퍼지 제어기는 입력된 퍼지 입력들을 가지고 퍼지출력 값을 추론하며, 추론된 퍼지 출력 값에 따라 퍼지기반 Segment-Boost에서의 서브벡터 선택개수 K 를 조정한다. 이러한 제어 과정은 서브벡터 선택개수 K 가 안정된 값에 도달할 때까지 반복된다. 초기에 유효한 퍼지 입력 값들을 얻을 수 없는 $K=1$ 부터 $K=3$ 까지는 퍼지 제어 없이 순차적으로 시뮬레이션이 진행되고 그 이후부터는 퍼지 제어에 의해 시뮬레이션이 진행된다.

서브벡터 선택개수 K 가 최적화되면 최적화된 상태에서 동일한 학습데이터를 가지고 얼굴특징 50개를 선택하고 이를 가지고 얼굴인식률을 시험해 볼 것이다. 얼굴인식률 시험을 위한 시험데이터는 학습에 사용되지 않은 나머지 60개(15명×4개)의 얼굴이미지로부터 얻었다. 한편, 실험에 사용한 boosting 알고리즘의 분류기(classifier)로는 Segment-Boost를 이용한 얼굴특징 선택 연구^[2]에서와 마찬가지로 학습속도와 학습능력이 우수한 PNN(Probabilistic Neural Networks)^[11]을 사용하였다.

표 2. 퍼지제어 시뮬레이션 결과

Control Sequence	1	2	3	4	5	6
K	1	2	3	7	10	9
d	-	-2.5	17.7	37.3	35.4	35.4
Δd	-	-	+20.3	+19.6	-1.9	0
ΔK	-	-	+4	+3	-1	0
Simulation Time(s)	72	144	216	288	359	431

※ K : 서브벡터 선택 개수, ΔK : K 에 대한 제어크기

4.2 결과 및 분석

표 2는 3장에서 설계한 퍼지 제어를 통한 퍼지기반 Segment-Boost의 시뮬레이션 결과를 보여준다. 각 제어 시퀀스에서는 주어진 서브벡터 선택개수 K 를 가지고 학습데이터로부터 5개의 얼굴특징을 선택한 후, 이를 가지고 학습데이터와 동일한 데이터를 분류하여 학습오차를 산출하였다. 유효한 퍼지 입력 값이 얻어지기 전인 $K=3$ 까지는 퍼지출력 ΔK 를 얻을 수 없으므로 K 값을 순차적으로 1씩 증가시키며 시뮬레이션이 진행되었다. 그리고 $K=3$ 부터는 퍼지 제어기로부터 출력된 퍼지 출력 ΔK 에 의해 K 값이 제어되었다. 표 2에서 보여 지는 바와 같이 시뮬레이션은 총 6회의 제어 시퀀스를 거쳐 $K=9$ 에서 안정된 값에 도달하였다. 이는 4.1 절에서 서술된 시뮬레이션 조건에서 퍼지 제어가 찾아낸 최적의 서브벡터 선택개수 K 가 9라는 것을 의미한다. 그리고 시뮬레이션 시간은 해당 제어 시퀀스까지의 누적 경과시간이다. 최적의 서브벡터 선택개수 K 를 찾아내는데 약 7분의 시간이 소요되었다.

그렇다면 이제, 퍼지 제어가 찾아낸 최적의 서브벡터 선택개수가 실제 최적 개수와 얼마나 일치하는지를 확인해 볼 필요가 있다. 그림 4는 서브벡터 선택개수 K 에 따른 퍼지기반 Segment-Boost의 성능 변화를 학습오차 감소율 d 를 통해 보여준다. 여기에서도 학습오차는 앞의 시뮬레이션과 동일한 조건에서 측정하였다. 3장에서 정의한 바와 같이 학습오차 감소율 d 는 $K=1$ 일 때에 대한 상대적인 학습오차 감소율을 의미하므로 d 의 값이 가장 클 때가 학습오차가 최소가 된다. 도표에 나타난 바와 같이 학습오차는 꾸준히 감소하여 $K=7$ 부터는 큰 변화를 보이지 않고 있다. 한편, 이론적으로 볼 때 서브벡터 선택개수 K 의 값이 증가할수록 선택하는 부분벡터의 수가 증가하고 이는 계산량의 증가로 이어진다. 따라서 $K=7$ 부근을


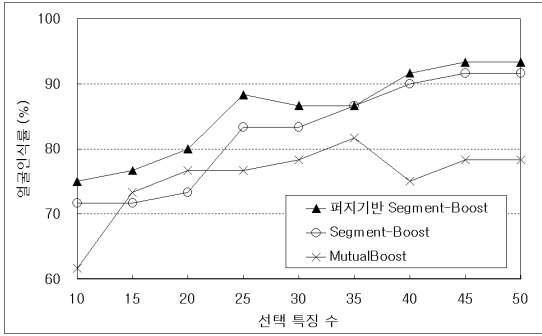


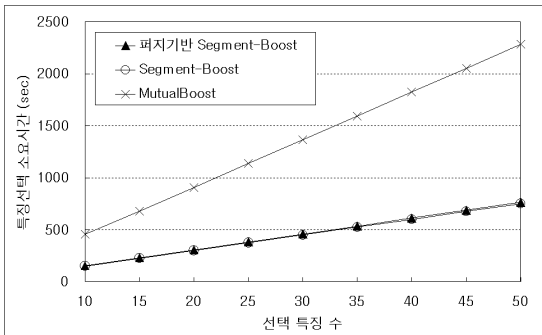
그림 4. 퍼지기반 Segment-Boost에서의 서브벡터 선택개수 K 에 따른 학습오차 감소율

boosting 성능을 최적화시킬 수 있는 적절한 파라미터 값으로 판단할 수 있다. 그러므로 본 논문에서 설계한 퍼지 제어가 찾아낸 최적의 서브벡터 선택개수인 $K=9$ 는 실제 최적 값에 매우 근사한 값으로 볼 수 있다.

다음으로, 퍼지기반 Segment-Boost 방법의 학습 성과 이를 이용한 얼굴인식 방법의 특징선택 및 얼굴인식 성능을 얼굴인식률과 특징선택 소요시간을 통해 확인해 보기로 한다. 그림 5는 최근 발표된 boosting 방법인 Mutual-Boost 방법과 Segment-Boost(서브벡터선택개수(K)=1, 벡터분할개수(S)=8192), 그리고 퍼지기반 Segment-Boost(서브벡터선택개수(K)=9, 벡터분할개수(S)=8192)에 대한 각각의 얼굴인식률 및 특징선택 소요시간을 특징선택 개수에 따라 나란히 비교하여 보여주고 있다. 그림 5.(a)에 나타난 바와 같이 얼굴특징을 최대 50개까지 선택하였을 때, MutualBoost에서 최대 81.7%였던 얼굴인식률은 Segment-Boost에서 최대 91.7%로 증가하였고, 퍼지기반 Segment-Boost에서는 최대 93.3%까지 향상되었다. 실험 결과를 통해, 퍼지기반 Segment-Boost 방법은 기존의 Segment-Boost를 비롯하여 비교 실험한 기존 boosting 방법에 비해 식별력 있는 양질의 얼굴특징들을 보다 효과적으로 선택해내었다는 것을 알 수 있고, 이를 통해 퍼지기반 Segment-Boost의 향상된 특징 학습 및 선택 능력과 이를 이용한 얼굴인식 방법의 향상된 인식효과를 확인할 수 있다. 뿐만 아니라 8192로 임의 설정된 벡터분할 개수 S 에 대해서, Segment-Boost는 일부 구간에서 Mutual-Boost 보다 낮은 인식률을 보이고 있는데 반해, 퍼지기반 Segment-Boost는 모든 구간에서 향상된 성능을 보이고 있다. 이는 퍼지기반 Segment-Boost의 보다 안정된 학습 및 인식 성능을 확인시켜 준다. 한편, 그림 5.(b)는 각 특징선택 방법들을 이용하여 얼굴특징을 선택하는데 소요되는 시간



(a) 선택한 특징 수에 따른 특징선택 방법별 얼굴인식을 비교



(b) 선택한 특징 수에 따른 특징선택 방법별 특징선택 소요시간 비교

그림 5. 선택한 특징 수에 따른 특징선택 방법별 얼굴인식률 및 특징선택 소요시간 비교

을 선택한 특징 수에 따라 보여준다. 도표에서 확인할 수 있듯, 실험에서 설정한 벡터분할개수 상에서 퍼지기반 Segment-Boost는 기존의 Segment-Boost와는 특징선택 소요시간에서 차이를 보이지 않으며 MutualBoost보다는 3배가량 빠른 특징선택 속도를 보여주고 있다. 또한, 표 2의 퍼지제어에서 소요된 약 7분의 시간을 특징선택 소요 시간에 포함시키더라도, 퍼지제어에 소요된 시간은 선택 특징 수와 무관하게 1회적으로 소요되며 일반적으로 실제 얼굴인식을 위해 선택하는 특징 수가 수백 개임을 감안할 때 전체 특징선택 소요시간에서 퍼지제어 소요시간은 무시될 수 있을 것이다. 따라서 퍼지기반 Segment-Boost는 기존의 Segment-Boost가 지니고 있는 상대적으로 빠른 특징선택 속도라는 장점을 동일한 수준으로 유지한다고 말할 수 있다.

실험 결과를 통해, 퍼지기반 Segment-Boost는 비교 실험한 기존의 boosting 방법들보다 향상된 학습 성능과 특징선택 및 얼굴인식 성능을 보이며, 기존의 Segment-

Boost가 지닌 빠른 특징선택이라는 장점을 유지하고 있음을 확인할 수 있다.

5. 결론

본 논문에서는 퍼지기반 Segment-Boost 방법을 소개하고 이를 이용한 효과적인 얼굴인식 방법을 제시하였다. 퍼지기반 Segment-Boost는 서브벡터 선택에 있어 유연성과 확장성을 제공하고 퍼지추론을 통해 최적의 서브벡터 선택개수를 적절히 설정함으로써, 기존 Segment-Boost가 갖는 학습 성능상의 한계점을 극복하고 학습 성능 향상은 물론 성능의 안정성과 신뢰성을 보장하여 준다. 뿐만 아니라, 기존 Segment-Boost가 지닌 빠른 특징선택 능력이라는 장점을 유지한다. 한편, 본 논문에서는 퍼지기반 Segment-Boost 방법에서 최적의 서브벡터 선택개수를 추론 및 제어할 수 있는 퍼지 제어를 설계하였다. 시뮬레이션 결과, 본 논문에서 설계한 퍼지 제어기는 퍼지기반 Segment-Boost의 학습 성능이 최적화될 수 있는 실제 최적의 서브벡터 선택개수에 매우 근접한 값을 추론해내었다.

그리고, 퍼지기반 Segment-Boost를 이용한 얼굴인식 실험에서 퍼지기반 Segment-Boost는 비교 실험한 기존 boosting 방법보다 특징선택 및 얼굴인식에 있어 향상된 성능을 보여주었다. 최소 10개에서 최대 50개의 특징을 선택하여 보았을 때, 퍼지기반 Segment-Boost는 비교 실험한 기존 boosting 기반의 특징선택 방법보다 얼굴인식률에 있어 전 구간에서 우위를 보였으며, 기존 Segment-Boost 보다는 최대 6.7%, MutualBoost보다는 최대 16.7%의 인식률 향상을 보였다. 더욱이, 이러한 학습 및 인식 성능 향상에도 불구하고 퍼지기반 Segment-Boost는 기존의 Segment-Boost가 지닌 빠른 특징선택 성능을 유지하였다.

결론적으로, 본 논문에서 수행한 시뮬레이션 결과는 퍼지기반 Segment-Boost 방법이 갖고 있는 개선된 학습 성능과 이를 이용한 얼굴인식 방법이 지닌 향상된 특징선택 및 얼굴인식 성능, 그리고 이러한 성능에 대한 안정성과 신뢰성을 입증하여 주었다.

참고 문헌

1. Bellhumer, P. N., Hespanha, J. and Kriegman, D., "Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection", IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 17, pp. 711-720, 1997.

2. Chang, W. S., Lee, J. S., "Segment-Boost Learning for Facial Feature Selection", In Proc. of International Conference on Convergence and hybrid Information Technology, Vol. 1, pp. 358-363, 2008.
3. Daugman, J. G., "Two-dimensional Spectral Analysis of Cortical Filters", Vision Research, Vol. 20, pp. 847-856, 1980.
4. Kyrki, V., Kamarainen, J. K. and Kalviainen, H., "Simple Gabor Feature Space for Invariant Object Recognition", Pattern Recognition Letters, Vol. 25, pp. 311-318, 2004.
5. Lee, C. C., "Fuzzy Logic in Control Systems: Fuzzy Logic Controller", IEEE Trans. Systems, Man and Cybernetics, Vol. 20, pp. 404-435 1990.
6. Li, S. Z. and Zhang, Z. Q., "FloatBoost Learning and Statistical Face Detedtion", IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 26, pp. 511-518, 2004.
7. Liu, C. J. and Wechsler, H., "Gabor Feature Based Classification Using the Enhanced Fisher Linear Discriminant Model for Face Recognition", IEEE Trans. Image Process, Vol. 11, pp. 467-476, 2002.
8. Mamdani, E. H., Assilian, S., "An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller", International Journal of Man-Machine Studies, Vol. 7, pp. 1-13, 1974.
9. Moghaddam, B., Wahid, W. and Pentland, A., "Beyond Eigenfaces: Probabilistic Matching for Face Recognition", In Proc. of IEEE International Conference on Automatic Face and Gesture Recognition, pp. 30-35, 1998.
10. Shen, L. and Bai, L., "MutualBoost Learning for Selection Gabor Features for Face Recognition", Pattern Recognition Letters, Vol. 27, pp. 1758-1767, 2006.
11. Specht, D. F., "Probabilistic Neural Networks", Neural Networks, Vol. 3, pp. 109-118, 1990.
12. Viola, P. and Jones, M., "Rapid Object Detection Using a Boosted Cascade of Simple Features", In Proc. of IEEE Conference on Computer Vision and Pattern Recognition, pp. 511-518, 2001.
13. Zadeh, L. A., "Fuzzy Sets", Information and Control, Vol. 8, pp. 338-353, 1965.



장 원 석 (wkddt@hotmail.com)

2005 인하대학교 전자공학과 학사
2009 인하대학교 컴퓨터정보공학과 석사

관심분야 : 시스템 모델링&시뮬레이션, 패턴인식



노 창 현 (cromirak@hanmail.net)

2006 수원대학교 인터넷 정보공학과 학사
2008 인하대학교 정보공학과 석사
2008~현재 인하대학교 정보공학과 박사과정

관심분야 : 그리드 컴퓨팅, 온톨로지, 시스템 모델링 및 시뮬레이션



이 종 식 (jslee@inha.ac.kr)

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

관심분야 : 시스템 모델링&시뮬레이션, 그리드 컴퓨팅