

論文2003-40SP-3-3

자동 목표물 인식 시스템을 위한 클러스터 기반 투영기법과 혼합 전문가 구조

(Cluster-based Linear Projection and Mixture of Experts Model for ATR System)

申鎬澈*, 崔海哲*, 李珍晟*, 曹周鉉*, 金聖大*

(Ho-Chul Shin, Hae-Chul Choi, Jin-Sung Lee, Ju-Hyun Cho, and Seong-Dae Kim)

요약

본 논문에서는 적외선 영상 기반의 자동 목표물 인식 시스템(ATR System: Automatic Target Recognition System)에 적합한 특징 추출(feature extraction) 기법과 분류(classification) 기법을 제안한다. 제안 특징 추출 기법은 조명 변화에 의한 밝기 변화에 강인한 기준의 Fisherfaces 기법을 다수의 클래스들의 분류 문제에 적용 가능하도록 확장한 클러스터(cluster - set of classes, class - set of image) 기반 Fisherfaces 기법을 중심으로 다수의 클래스를 소수의 클러스터로 묶는 클래스 클러스터링(class clustering)과 클러스터별 영상 투영(projection) 과정으로 이루어진다. 제안 특징 추출 기법과 연결되는 제안 분류 기법은 RBF(Radial basis function)와 MLP(Multilayer perceptron)를 함께 사용하는 혼합 전문가 구조(Mixture of experts)의 신경망(neural networks) 기반 기법으로 제안 특징 추출 기법의 효용성을 극대화한다. 제안 특징 추출 기법과 분류 기법은 기존 기법들과 비교하여 화소 별로 존재하는 센서 접 xúc과 국부적 혹은 전역적으로 존재하는 밝기 변화 오차에 강연하며 이를 적외선 자동차 영상 인식 실험을 통해 검증하였다.

Abstract

In this paper a new feature extraction and target classification method is proposed for the recognition part of FLIR(Forwar Looking Infrared)-image-based ATR system. Proposed feature extraction method is “cluster(-set of classes)-based” version of previous fisherfaces method that is known by its robustness to illumination changes in face recognition. Especially introduced class clustering and cluster-based projection method maximizes the performance of fisherfaces method. Proposed target image classification method is based on the mixture of experts model which consists of RBF-type experts and MLP-type gating networks. Mixture of experts model is well-suited with ATR system because it should recognize various targets in complexed feature space by variously mixed conditions. In proposed classification method, one expert takes charge of one cluster and the separated structure with experts reduces the complexity of feature space and achieves more accurate local discrimination between classes. Proposed feature extraction and classification method showed distinguished performances in recognition test with customized FLIR-vehicle-image database. Especially robustness to pixelwise sensor noise and un-wanted intensity variations was verified by simulation.

Keyword : ATR, Fisherfaces, PCA, FLD, cluster, Mixture of experts

* 正會員, 韓國科學技術院 電子電算學科
 (Visual Communications Lab., Department of EECS
 Korea Advanced Institute of Science and Technology,
 Teajon, Korea)

※ 본 연구는 한국과학기술원 전자광학특화연구센터를
 통한 국방과학연구소의 연구비 지원으로 수행되었
 습니다.

接受日字:2003年2月12日, 수정완료일:2003年4月25日

I. 서 론

자동 목표물 인식 시스템(Automatic Target Recognition System)은 다양한 종류의 센서로부터 입력된 여러 가지 형태의 신호들을 이용하여, 목표물을 검출(detection)하여 추적(tracking)하고 인식(recognition)하는 시스템이다. 특히 군용으로 야간에 적을 식별, 추적하기 위해 사용되는 적외선 영상 기반의 자동 목표물 인식 시스템에 대한 연구는 현재 선진국들을 중심으로 활발하게 진행중이다^[7]. 이러한 연구는 특히 모델 기반과 신경망 연구를 중심으로 지속적인 알고리즘 개선이 이루어지고 있지만 실전에 적용할만한 수준의 인식률을 보이지는 못하고 있으며, 여전히 하드웨어의 구현성 보다는 우수한 알고리즘 확립에 중점을 두고 있는 단계이다.

본 논문에서 다루고자 하는 ATR 시스템의 인식 부분(Recognition part)은 <그림 1>과 같이 검출 부분(Detection Part)에서 넘겨진 사각형 목표물 영상(Box-gated Targetchiptargetchip)을 입력으로 받아 목표물의 종류와 자세를 판별하여 내는 것을 목표로 한다. 이러한 인식 부분의 구현을 위해 다양한 종류의 특징 추출기법이 연구되었으며^[1-2, 19, 16-17], 분류기법은 특히 신경회로망을 이용한 기법이 과거와 현재에 많이 연구되고 있다^[4-5].

본 논문에서 다루고자 하는 적외선 영상 기반 ATR 시스템 인식 부분의 구현 상의 어려움은 다음의 세 가지 요인에 의해 야기된다.

- i) 온도 환경 변화에 따른 영상의 밝기값 변화가 비선형적이고 예측하기 어렵다.

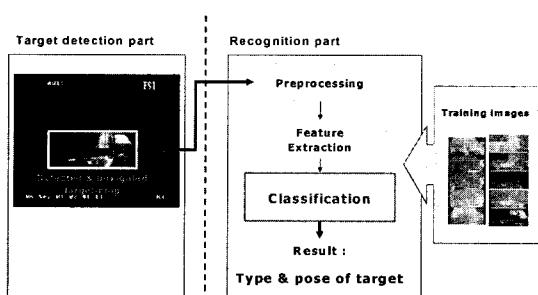


그림 1. 자동 목표물 인식 시스템의 인식 부분(그림의 오른쪽)

Fig. 1. Recognition Part of ATR system.

- ii) 구분해야 하는 목표물의 종류가 매우 다양하다.
- iii) 구분해야 하는 목표물들의 모양이나 밝기 분포는 서로 비슷한 경우도 있지만 크게 다른 경우도 많다.

i)의 밝기 변화의 문제를 해결하기 위해 적합한 특징 추출 기법으로는 얼굴 인식에서 연구된 FLD(Fisher Linear Discriminant) 기반의 Fisherfaces^[7] 기법을 들 수 있다. FLD 기법은 조명변화가 심한 영상의 인식을 위한 특징 추출기법으로서 가장 널리 쓰이고 있는 PCA(Principal Component Analysis) 기법에 비해 우수하다고 알려져 있다^[8]. 하지만, 기존 FLD 기법에서 학습 영상들이 조명변화의 경향을 드러내기에 그 수와 다양성이 충분하지 못한 경우, 이러한 장점이 발휘되기 어려우며, 또한 너무 많은 클래스들의 통계적(statistical) 정보로부터 특징 추출을 위한 기저 영상(basis image)을 획득해야 하는 경우, PCA의 선형성(linearity) 문제 및 확장성(scalability) 문제^[9]와 동일한 문제들이 발생하게 된다. 즉, ii)와 iii)의 문제로 인해 발생하는 특징 공간상에서의 복잡성과 비선형성이 앞에서 밝힌 FLD기법의 성능을 제한시키게 되어 적외선 영상 기반의 ATR시스템에 Fisherfaces 기법을 직접 적용하는 것이 어려워진다.

본 논문에서는 i), ii), iii)의 문제를 동시에 해결하면서 분별(discriminative) 특징 정보를 최적으로 추출할 수 있는 특징 추출 기법으로 클러스터 기반(Cluster-based) fisherfaces 기법을 제안한다. 제안 기법은 FLD 기법이 소수 클래스의 분류 문제에 더욱 적합하다는 사실에 기반하여, 전체 C 개로 구분되는 학습 패턴들의 분류 클래스를 K ($K < C$)개의 클러스터로 묶고 클러스터 별로 별도의 기저 영상을 fisherfaces 기법을 통해 찾아주는 방식이다. 즉, K 개의 국부적(local)인 클러스터에 최적화된 기저 영상들을 통해 입력 영상으로부터 보다 정확하고 각종 오차 요인에 강인한 특징을 추출한다.

III장에서 제안하는 분류 기법은 제안 특징 추출기법을 이용해 추출된 특징 정보 행렬과 투영 오차 벡터를 최적으로 활용하는 분류 기법이다. 특징 정보 행렬의 각 열(row)에 해당하는 국부적인 특징 정보(localized feature)들을 각 클러스터별로 학습된 RBFNs(Radial Basis Function Networks) 형태의 전문가(Expert)^[12]들을 통해 개별적으로 처리하고 투영 오차 벡터를 입력으로 하는 MLPNs(Multi-Layer Perceptron Networks)

형태의 게이팅 네트워크(gating network)를 통해 각 전문가 모듈의 비중을 조절한다. 이러한 구조는 전역적(global)인 전체 클러스터들간의 구분에는 전역적 특성이 우수한 MLP 구조를 사용하고 국부적(local)인 각 클러스터의 내부적 구분에는 국부적 특성이 우수한 RBFN을 사용하여 제안 특징 추출 기법인 클러스터 기반 fisherfaces 기법의 계층적 특성을 손실 없이 잘 활용하는 분류기법이다.

제안 특징 추출 기법과 분류기법의 ATR 시스템에의 적용 가능성을 검증하기 위해 “KAIST-ATR 적외선 차량 영상 DB”^[18]를 통해 인식 실험을 실시하였으며, 실험결과를 통해 제안 기법이 기존의 PCA나 FLD, Wavelet 변환 기반의 특징 추출 기법과 함께 일반적인 MLP기반의 분류기를 사용하는 기존 기법들에 비해 밝기 변화가 심하고 많은 클래스로 이루어진 목표물들의 인식 문제에 있어 그 성능이 우수함을 보였다.

II. 특징 추출 기법

FLD 기법은 영상 인식을 위한 특징 추출기법으로 사용하는데 있어 내부 분산 행렬(within-scatter matrix)이 대부분의 경우 정칙(singular)이 된다는 문제점을 가지고 있다. 이것은 현실적으로 학습 영상의 개수가 영상의 차원에 비해 부족한 경우가 대부분이기 때문에 Fisherfaces^[7] 기법은 PCA 기법을 이용해 영상의 차원을 충분히 줄여준 후 FLD 기법을 적용하는 방법으로 이러한 문제를 해결한다. Fisherfaces 기법은 내부 분산 행렬(Within-scatter matrix)의 정칙화 문제를 해결하는 것뿐만 아니라 PCA를 통한 일차적인 차원 감축 과정에서 영상 내의 잡음 성분들을 제거하는 효과가 있어, 잡음에 매우 민감한 FLD의 단점을 보완해 준다는 장점도 가진다.

얼굴 인식 등의 여러 인식 문제에서 특징 추출기법으로 사용되는 FLD 기반 기법들의 최대 장점은 다양한 조명 변화, 즉 영상 내에 존재하는 원치 않는 밝기 변화에 강인한 특징을 추출하는 것이 가능하다는 점이다. 이것은 FLD 기법이 내부 분산을 최소화하기 위해 내부적인 분산(variance)이 가장 큰 성분들을 제거할 때, 조명 변화에 의한 영상간의 밝기 변화가 최대 분산(max-variance) 성분으로 선택되어 제거되기 때문이다. 하지만, FLD 기법이 조명 변화가 심한 영상의 특징 추출 기법으로 사용되기 위해서는 중요한 전제 조건이

만족되어야만 하는데 그것은 조명 변화나 밝기 변화의 성향이 드러나기에 충분한 학습 영상들이 확보되어 있어야만 한다는 점이다. 만약 충분한 학습 영상이 갖춰지지 못한 경우에는 조명변화나 원치 않는 밝기 변화 성분이 최대 분산성분으로 선택되기 어려워진다. 이러한 FLD의 단점을 보완하기 위해 EFM^[8] 기법이 제안되기도 하였다. EFM 기법은 내부 분산 행렬의 백색화(whitening)를 통해 부족한 학습 표본의 개수를 보완하는 기법이다. 하지만, EFM 기법에도 잡음성분을 확대시킬 가능성이 있다는 문제점이 있다.

일반적으로 적외선 카메라를 이용해 촬영된 목표물의 영상은 영상이 촬영될 당시의 기온이나 물체의 가열 정도 등에 따라 그 밝기 값의 변화가 매우 심하다. 온도에 의한 밝기 변화는 <그림 3>과 같이 그 변화의 성향이 비선형적이고, 변화를 야기시키는 상황이 너무 다양하여 이를 변화를 보상할 수 있는 모델을 찾기 어렵다는 점에서 잘 알려진 조명 변화 상황 하에서의 얼굴 영상 인식 문제와 그 성격이 유사하다. 이러한 밝기 값 변화에 대응하여 통계적 특징 정보 추출 기법을 통해 변화가 적고 인식에 유리한 특징 정보 성분만을 추출해낼 수 있는 기법으로 연구된 것이 FLD 기법 기반의 Fisherfaces 기법이다.

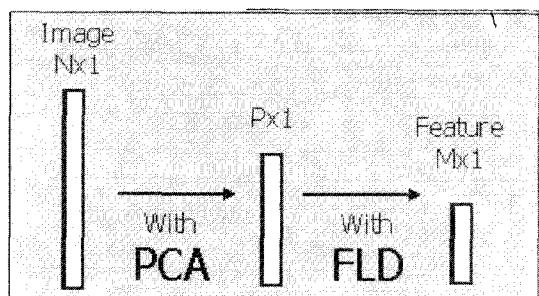


그림 2. Fisherfaces 기법의 개념
Fig. 2. The concept of Fisherfaces.



그림 3. 온도 환경 변화에 따른 적외선 목표물 영상의 변화
Fig. 3. Variations of FLIR-target-images caused by temperature condition changing.

1. FLD(Fisher Linear Discriminant)

FLD 기법은 학습 영상들의 분류 정보를 활용하여 가장 분별력 있는 특징 정보를 추출하는 PCA 기법에 비해 인식에 보다 적합한 특징 추출 기법이다. FLD 기법은 간단하게 식 (1)에서 식 (9)의 과정으로 이루어진다. 전체 학습영상의 개수를 M 이라 할 때, M 개의 $N \times 1$ 학습 벡터- 2차원의 학습 영상을 1차원으로 정렬한 벡터 Γ_k 들의 전체 모임 Ω 를 아래와 같이 정의하고, 이들 학습 벡터들은 각각의 분류 클래스 $\Omega_1, \dots, \Omega_c$ 으로 묶인다.

$$\Omega = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\} = \Omega_1 \cup \Omega_2 \cup \dots \cup \Omega_c \quad (1)$$

$$\Omega_1 = \{\Gamma_1^1\}_{k=1}^{M_1}, \Omega_2 = \{\Gamma_2^2\}_{k=1}^{M_2}, \dots, \Omega_c = \{\Gamma_c^c\}_{k=1}^{M_c} \quad (2)$$

$$\text{where } M = \sum_{i=1}^c M_i \quad (3)$$

아래의 식 (4)~식 (6)의 과정을 통해 구해진 내부 분산 행렬(S_w)과 상호 분산 행렬(S_b)로부터 찾아지는 식 (7)의 투영 변환 행렬(W_{fd})은 정의된 내부 분산 행렬과 상호 분산 행렬의 행렬식 값의 비를 최대화시키는 투영 변환으로 정의되는데, 이러한 투영 변환은 영상 인식에 유리한 분별적 정보를 추출해 내는 투영 변환이 된다.

$$\Psi_i = \frac{1}{M_i} \sum_{k=1}^{M_i} \Gamma_k^i, \quad \Psi = \frac{1}{M} \sum_{i=1}^c \Psi_i M_i \quad (4)$$

$$S_w = \sum_{i=1}^c \sum_{k=1}^{M_i} (\Gamma_k^i - \Psi_i)(\Gamma_k^i - \Psi_i)^T \quad (5)$$

$$S_b = \sum_{i=1}^c M_i (\Psi_i - \Psi)(\Psi_i - \Psi)^T \quad (6)$$

$$W_{fd} = \max_w \left(\frac{|W^T S_b W|}{|W^T S_w W|} \right) = \{w_1, w_2, \dots, w_R\} \quad (7)$$

$$S_w w_i = \lambda_i S_w w_i, i=1, 2, \dots, C-1 \quad (8)$$

$$S_w^{-1} S_b w_i = \lambda_i w_i, \quad \text{if } S_w \text{ is non-singular.} \quad (9)$$

이러한 FLD 투영 변환 W_{fd} 의 실제적인 결정은 식 (9)를 풀어 얻어지는 $\{w_i | i=1, 2, \dots, c-1\}$ 에서 가장 큰 R 개의 고유값 $\{\lambda_i | i=1, 2, \dots, R\}$ 에 대응되는 고유벡터들만을 선택함으로써 이루어진다.

2. Fisherfaces 기법

현실적으로 대부분의 영상 인식 문제에 있어서 학습 영상의 개수 M 은 영상의 차원 N 에 비해 훨씬 작은 경우가 대부분이므로 식 (5)의 S_w 는 대부분의 경우 정칙이 되어 식 (9)의 S_w^{-1} 계산이 어렵게 된다. 이러한 문제는 FLD 기법을 영상 인식에 적용하기 위해서는 반드시 해결해야만 하는 문제이다. Fisherfaces 기법은 이러한 문제를 PCA 기법을 통해 해결한다. 즉, 학습 영상들의 모임이 상당부분 선형적인 기우시안 분포를 따른다는 가정 하에 PCA 기법을 통해 내부 분산 행렬이 비정칙(nonsingular)이 될 수 있을 정도로 차원을 미리 감소시킨 다음 감축된 공간에서 FLD 기법을 적용한다.

먼저 PCA 기법을 살펴보면 전체 학습 영상의 개수를 M 이라 할 때 M 개의 학습 벡터들을 아래와 같이 정의하고 그 평균 벡터 Ψ 와 공분산 행렬 Σ 를 찾는다.

$$\Gamma = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\}, \quad \Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (10)$$

$$\Phi_n = \Gamma_n - \Psi, n=1, 2, \dots, M \quad (11)$$

$$\Sigma = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = \mathbf{A} \mathbf{A}^T, \quad \mathbf{A} = \frac{[\Phi_1 \Phi_2 \dots \Phi_M]}{\sqrt{M}} \quad (12)$$

공분산 행렬의 고유값(eigenvalue) λ_k 과 고유벡터(eigenvector) \mathbf{u}_k 를 구한다.

$$\Sigma \mathbf{u}_k = \lambda_k \mathbf{u}_k, \quad \mathbf{u}_k^T \mathbf{u}_n = \begin{cases} 1, & k=n \\ 0, & k \neq n \end{cases} \quad (13)$$

$$\Xi = [\mathbf{u}_1 \mathbf{u}_2 \mathbf{u}_3 \dots \mathbf{u}_N]$$

위의 Ξ 에서 고유 값이 가장 큰 순서대로 P 개의 고유 벡터만을 선정하여 Ξ_{pca} 를 만든다.

$$\Xi_{pca} = [\mathbf{u}_{a_1} \quad \mathbf{u}_{a_2} \quad \dots \quad \mathbf{u}_{a_P}] \quad (\lambda_{a_1} > \lambda_{a_2} > \dots > \lambda_{a_P}) \quad (14)$$

찾아진 PCA 변환 행렬(Ξ_{pca})을 통해 일차적인 차원 감축을 수행하고, 감축된 공간에 FLD 기법을 적용하여 얻어지는 Fisherfaces 변환 행렬(W_{opt}^T)은 식 (16)과 같아 W_{fd} 와 Ξ_{pca} 를 곱하여 완성된다. W_{opt}^T 의 컬럼(column) 벡터를 fisherfaces라고 부르고^[7], 이들이 특징 추출을 위한 기저 영상이 된다.

$$W_{\text{opt}} = \max_w \left(\frac{|W^T \Xi_{\text{pca}}^T S_B \Xi_{\text{pca}} W|}{|W^T \Xi_{\text{pca}}^T S_W \Xi_{\text{pca}} W|} \right) \quad (15)$$

$$W_{\text{opt}}^T = W_{\text{opt}}^T \Xi_{\text{pca}}^T \quad (16)$$

$$Z = W_{\text{opt}}^T \Phi_n = W_{\text{opt}}^T \Xi_{\text{pca}}^T \Phi_n \quad (17)$$

where, $\Phi_n = \Gamma_n - \Psi \cdot P \cdot (M - C), R (C-1)$

이렇게 얻어진 Fisherfaces 변환 행렬을 이용하는 식 (17)의 방식으로 N 차원의 영상 Γ_n 을 R 차원의 특징 벡터 Z 로 변환할 수 있다. 이러한 방식으로 내부 분산 행렬이 비정칙이 된다는 문제를 피할 수 있어 학습 영상이 영상의 차원보다 부족한 상황 하에서도 FLD 기법을 적용하는 것이 가능해진다.

3. 다수의 클래스 분류 문제에서 FLD 기반 기법의 한계

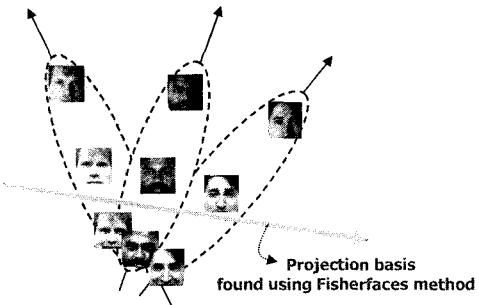
FLD 기반의 fisherfaces 기법을 ATR 시스템의 특징 추출 기법으로 사용하기 위해서는 ATR 시스템은 얼굴 인식과 달리 매우 많은 수의 매우 많이 다른 모양의 목표물 영상들을 분류해야만 한다는 문제를 해결해야 한다.

이러한 문제는 너무 많은 수의 서로 많이 다른 영상 클래스들을 분류하여야만 하는 경우, fisherfaces 기법의 장점인 밝기변화 성분의 제거 특성이 발휘되기 어려워지기 때문에 발생한다. 즉 <그림 5(b)>에서와 같이 몇몇 클래스들의 성향이 너무 많이 달라 이들의 차 이를 나타내기 위해서 사용되는 기저영상(<그림 5>에 투영 기저(projection basis)로 표시)들의 방향이 밝기 변화 성분을 제거하는 방향과 반드시 일치하지 않는 A 영역이 발생할 수 있기 때문이다. 결국 클래스들 간의 분산을 극대화하기 위한 힘으로 클래스의 내부분산을 최소화하기 위한 힘을 넘어서는 상황 하에서 찾아진 기저 영상들을 통해 얻어진 특징 정보로는 A 영역에 존재하는 클래스들은 특징 공간 상에서의 구분이 사실상 불가능하다.

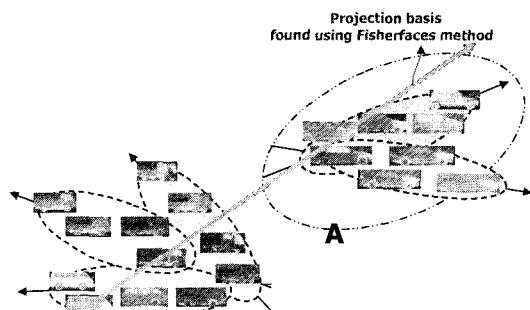


그림 4. 다양한 인식 대상 목표물의 예

Fig. 4. Examples of various target-images.



(a) FLD 기법을 통해 조명변화나 표정 변화 등의 주요한 변화 요인들을 최소화시키는 방향으로 기저 영상이 결정되는 경우.



(b) 성향이 복잡하고 비선형적인 class들을 분류해야만 하는 상황 하에서 FLD 기법을 통해서도 A 영역에서와 같이 주요한 변화 요인들을 제거하지 못하는 기저영상이 찾아질 수 있다.

그림 5. FLD 기법의 한계

Fig. 5. Limitations of general FLD.

4) 클러스터기반 fisherfaces 기법(Cluster-based Fisherfaces)

제안하는 Cluster-based fisherfaces 기법은 FLD 기법이 성향이 유사한 소수 클래스들의 분류 문제에 대해 그 성능이 극대화된다는 사실에 기반하여, <그림 6>과 같이 전체 클래스들을 서로 성향이 유사한 클래스들의 집합인 클러스터(cluster : set of classes)로 묶고 각 클러스터별로 개별적인 투영 변환 행렬(W_{opt}^T : projection basis matrix, 식 (16)을 찾는다. 이를 클러스터별 투영 행렬들을 통한 투영은 국부화된(localized) 특징 정보들의 추출을 가능케 하여 보다 세밀하고 정확한 영상의 분류를 위한 특징 정보의 추출을 가능케 하며, fisherfaces 기법의 성능을 극대화하여 인식 대상 내의 밝기 변화 성분에 의한 영향을 제거해 준다.

제안 cluster-based fisherfaces 기법은 <그림 7>과

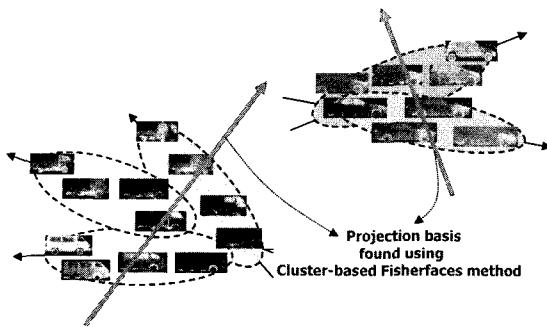


그림 6. Cluster-based Fisherfaces 기법의 개념
Fig. 6. The concept of cluster-based Fisherfaces method.

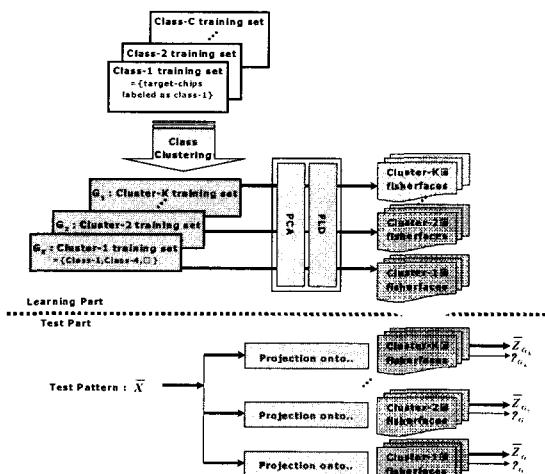


그림 7. 제안 cluster-based Fisherfaces 기법의 블록 다이어그램
Fig. 7. Block diagram of proposed cluster-based Fisherfaces method.

같이 크게 학습 과정과 테스트 과정으로 구분될 수 있으며, 학습 과정은 다시 클래스 클러스터링(class clustering) 과정과 클러스터별 투영행렬 찾기 과정으로 이루어지고, 테스트 과정은 클러스터별 투영 과정으로 이루어진다.

① 학습과정 I : 클래스 클러스터링

하나의 클러스터로 묶여야 하는 클래스들은 공간적으로 가까이에 있어서 만약 부적절한 선형 투영이 적용될 경우에 클래스 상호간의 겹침이 심화될 수 있는 클래스들이어야 한다. 즉, 동일한 투영행렬이 적용될 각 클러스터들은 물리적 거리상으로 최대한 멀어질수록 좋다고 볼 수 있고 이것은 다시 한 클러스터내에 속한

클래스들간의 거리는 최소화하고 클러스터들간의 거리는 최대화시키는 FLD 기법 개념과 유사하다.

클래스 클러스터링의 실제적 구현은 식 (18)에서 정의한 J 를 최대화하는 과정으로 한 클러스터 내의 임의의 클래스를 J 값이 증가하도록 다른 클러스터로 이동시키는 작업을 반복하는 방법으로 한 클래스가 소속되어야 할 최적의 클러스터를 결정해 준다. <그림 8>의 블록 다이어그램은 이러한 반복 알고리즘을 보인 것이다. 여기서, i 번째 클러스터를 G_i 로 정의하고, G_i 에 속하는 j 번째 클래스를 $C_{(i,j)}$ 로 정의하며, $C_{(i,j)}$ 포함된 k 번째 학습 영상을 $X_{(i,j,k)}$ 로 정의한다. $tr[\cdot]$ 은 행렬의 고유 값들의 합을 의미한다.

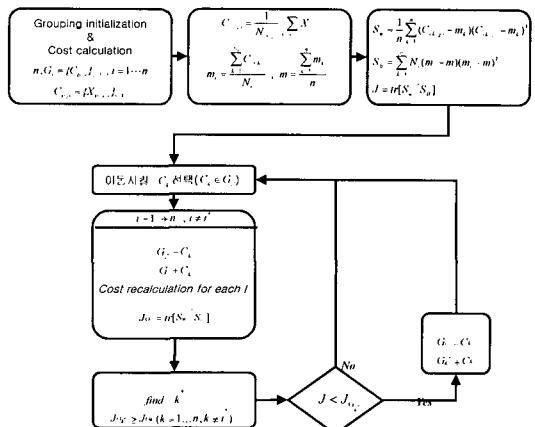


그림 8. 클래스 클러스터링 알고리즘의 블록다이어그램
Fig. 8. Block diagram of class-clustering algorithm.

$$G_i \supset C_{(i,j)},$$

$$C_{(i,j)} = \{X_k\}_{k=1}^{N_i}$$

$$J = tr[S_w^{-1} S_b]$$

$$S_w = \sum_{i=1}^n [\text{within-scatter of } G_i]$$

$$S_b = [\text{between-scatter of } \{G_i\}_{i=1}^n] \quad (18)$$

② 학습과정 II : 클러스터별 fisherfaces 찾기

C 개의 클래스들을 K 개의 클러스터로 묶은 후, 각 클러스터별로 별도의 투영 기저 영상들을 획득한다. 클러스터별로 기저영상을 찾는 과정은 일반적인 fisherfaces 기법과 동일하게 PCA + FLD 과정을 통해 이루어진다. 이렇게 찾아진 클러스터 별 기저 영상들은 같은 클러스터 내에 포함된 클래스들을 잘 구분하도록

최적화된 특징 정보를 추출해 낼 수 있는 기저 영상들이다.

For i=1, ...,

get $\mathbf{W}_{fld,G_i}^T, \Xi_{pca,G_i}$ from cluster \mathbf{G}_i

$$\mathbf{W}_{opt,G_i}^T = \mathbf{W}_{fld,G_i}^T \Xi_{pca,G_i}^T, \dots, \mathbf{W}_{opt,G_K}^T = \mathbf{W}_{fld,G_K}^T \Xi_{pca,G_K}^T \quad (19)$$

③ 테스트 과정: 임의 입력 패턴으로부터 특징 정보의 추출 과정

임의의 입력 영상으로부터 특징 정보를 추출하는 테스트 과정은 입력 영상을 각 클러스터별 기저 영상으로 선형 투영시키는 과정이다. <그림 9>는 이러한 과정의 블록다이어그램을 보인 것이다. \mathbf{F}_k 와 \mathbf{F}_n 은 각각 k 번째와 n 번째 클러스터에 의해 전개(span)되는 특징 공간(feature space)이며, $\bar{\mathbf{F}}_k$ 와 $\bar{\mathbf{F}}_n$ 는 투영 과정에서 버려지는 성분들의 공간들이다.

입력 패턴 X 를 각각의 클러스터들의 특징 공간으로 선형 투영시킨 결과로 $Z_{\bar{\mathbf{F}}_k}$ 와 $Z_{\bar{\mathbf{F}}_n}$ 이 얻어지며, 투영 과정에서 발생하는 투영 오차(projection error)는 ϵ_k 와 ϵ_n 으로 정의한다. 이러한 과정을 모든 클러스터에 대해 수행하면 식 (22)와 같이 $K \times R$ 크기의 특징 정보 행렬 \mathbf{F}_x 과 $K \times 1$ 차원의 투영 오차 벡터 \mathbf{E}_x^2 를 획득할 수 있다. 아래의 수식에서 전체 클래스의 개수는 C , 전체 학습 영상의 개수는 M , PCA 투영 차원이 P , FLD 투영 차원이 R 이다.

$$Z_{\bar{\mathbf{F}}_k} = \mathbf{W}_{opt,G_k}^T \Phi_{X,G_k}, \dots, Z_{\bar{\mathbf{F}}_n} = \mathbf{W}_{opt,G_n}^T \Phi_{X,G_n} \quad (20)$$

where $P=M-C, R=C-1$

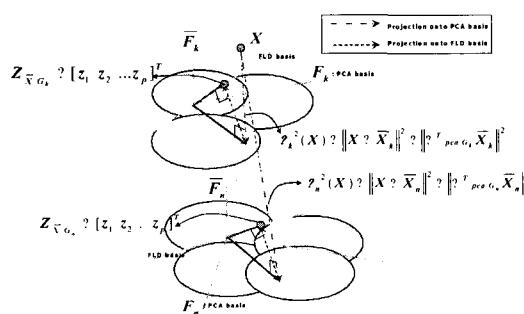


그림 9. 입력 패턴 X로부터의 특징 정보($\{Z_{\bar{F}_k}, \epsilon_k$
 $k=1, \dots, N\}$) 추출 과정

Fig 9. Feature extraction from test pattern.

$$\epsilon_i^2(X) = \|X - \Psi_{G_i}\|^2 - \|\Xi_{pca,G_i}^T X\|^2, \dots, \epsilon_k^2(X) = \|X - \Psi_{G_k}\|^2 - \|\Xi_{pca,G_k}^T X\|^2 \quad (21)$$

$$\mathbf{F}_x = \begin{bmatrix} \mathbf{Z}_{X,G_1}^T \\ \mathbf{Z}_{X,G_2}^T \\ \mathbf{Z}_{X,G_3}^T \\ \vdots \\ \mathbf{Z}_{X,G_K}^T \end{bmatrix} \quad \mathbf{E}_x^2 = \begin{bmatrix} \epsilon_1(X)^2 \\ \epsilon_2(X)^2 \\ \epsilon_3(X)^2 \\ \vdots \\ \epsilon_k(X)^2 \end{bmatrix} \quad (22)$$

III. 분류 기법

여러 다양한 패턴 분류 기법들 중에서 패턴들의 분포 모델을 추정하는 것이 불가능한 경우 직접적으로 판단 경계를 설정해 주는 대표적인 기법으로 신경 회로망(Neural Networks) 기반의 분류 기법이 있다. 이러한 신경 회로망 기반의 기법 중 혼합 전문가(mixture of experts) 구조^[12]는 서로 다른 영역에 최적화된 전문가(Expert)들을 두고 각 전문가들의 판단 결과의 비중을 게이팅 네트워크(gating networks)를 통해 조절하는 방식이다. 이러한 혼합 전문가 구조에서 각 전문가의 영역을 앞에서 정의한 클러스터로 보고 제안한 클러스터 기반 특징 추출 기법과 연결한 구조가 <그림 10>이다. 이러한 구조에서 각 클러스터 별 전문가는 국부적인 성능이 우수하다고 알려진 RBFNs(Radial Basis Function Networks)를 사용하여, 모든 전문가들의 의견을 통합하여 조율하는 게이팅 네트워크(Gating Networks)에는 전역적인 성능이 우수한 2-계층 혹은

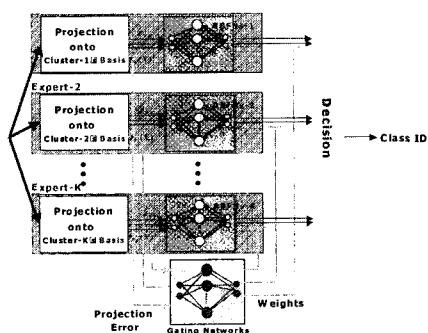


그림 10. 제안 특징 정보 추출기법과 연결된 혼합 전문가(mixture of Experts) 방식의 분류기

Fig. 10. Classifier based on mixture of expert structure.

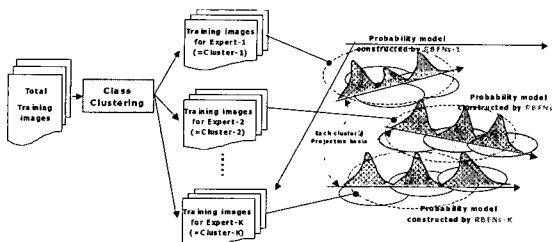


그림 11. 클러스터 별 전문가들의 학습

Fig. 11. Learning of RBF-type-experts.

3-계층의 MLPNs(Multi-Layer Perceptron Networks)를 사용한다.

1. RBFNs 기반의 전문가들(Experts)

RBFNs로 구성되는 <그림 10>의 “Expert-1”~“Expert-K”로 표시된 각 전문가는 한 개씩의 클러스터를 담당하여 클러스터 내부적인 클래스들의 구분(dis-crimination)을 위해 최적화된다. 이것을 위해 각 전문가들은 각각 자신들이 담당하는 클래스들로만 학습되어 국부적인 영역에 최적화시킨다.

2. MLPNs(Multi-Layer Perceptron Networks) 기반의 게이팅 네트워크(Gating Networks)

게이팅 네트워크의 역할은 각 전문가들의 비중을 조절하는 것이다. 이러한 비중의 조절은 해당 입력이 어느 클러스터에 속하는 것이 적합한지에 대한 대략적인 결정 과정으로 볼 수 있다. 실제 게이팅 네트워크는 입력으로 식 (21)의 각 클러스터로의 투영 오차 값을 받아들인다. 투영오차는 각 클러스터 별 기저 영상들로의 중간 과정인 PCA 투영 과정에서 발생하는 오차 값으로 입력 영상이 각각의 클러스터의 성향에 얼마나 유사한가를 나타내는 척도이다. 게이팅 네트워크는 이러한 투영오차를 MLPNs에 통과시켜 얻어지는 각 전문

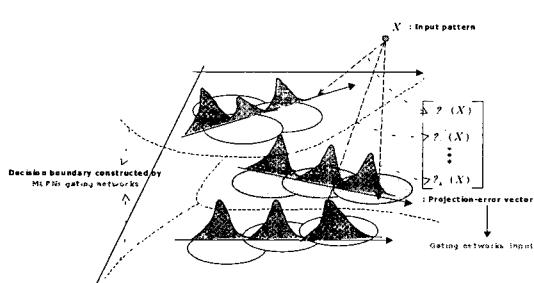
가들의 비중을 출력으로 내놓게 된다. 게이팅 네트워크에 전역적인 특성이 우수한 MLP 타입의 신경망을 사용하는 것은 게이팅 네트워크가 <그림 12>와 같이 전체적인 전문가들간의 영역 구분의 역할을 수행하기 때문이다. MLP 타입의 신경망을 사용하는데 있어 신경망의 크기와 복잡도를 얼마나 줄 것인가가 중요하다. 본 연구에서는 계층(layer)의 개수와 뉴론의 개수를 다양하게 변화시키며 성능을 평가하고 이를 통해 최적의 신경망 크기를 결정하였다. 이러한 실험 결과는 IV장의 결과에서 보였다.

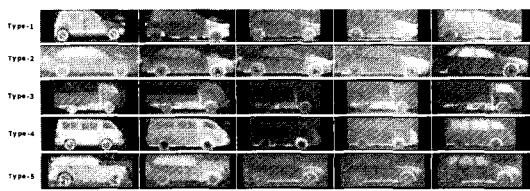
IV. 실험 결과

실험 결과는 크게 학습 결과와 테스트 결과(인식실험 결과)로 나뉘는데 학습 결과는 제안한 특징 추출기법과 분류기법을 학습 패턴들을 통해 학습시키는 과정에서 얻어진 중간 결과들이고 테스트 결과는 주어진 학습 패턴들에 대해 최적으로 학습된 전체 알고리즘에 각종 오차 요인들을 첨가하면서 인식률을 측정하여 기준의 기법들과의 성능을 비교한 결과이다.

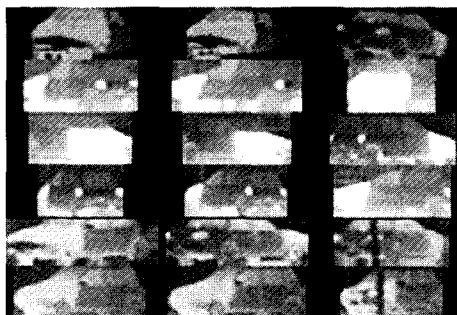
1. 실험 영상

일반적으로 ATR 시스템은 군용 혹은 민간용으로 적외선 센서를 통해 획득한 영상에서 차량 등의 목표물을 식별하는 것을 목적으로 한다. 이러한 ATR 시스템의 인식 부분(Recognition part)의 성능을 검증하기 위해 만들어진 것이 “KASIT-ATR 적외선 차량 영상 데이터베이스(KAIST-ATR FLIR-based vehicle image DB)”^[18]이다. 데이터베이스는 목표물 영상(target-chip)으로 정의되는 목표물을 포함하는 최소 사각형 영상들로 이루어져 있다. 학습을 위한 영상들은 5가지 종류의 차량을 5가지 다른 온도 환경 하에서 36가지 자세 pose : 목표물의 자세는 목표물이 보이는 부분의 각도를 의미함)에 대해 목표물과 카메라 시점의 높이를 일치시킨 상태에서 획득한 900장의 목표물 영상들이고, 테스트를 위한 영상들은 실제 필드(field)에서 얻어진 각종 잡음 - 센서 잡음, 작은 가려짐(occlusion)이나 소실(missing part) - 이 존재하는 더욱 다양한 온도환경과 다양한 거리에서 얻어진 목표물 영상들이다. 실제 시스템의 학습을 위해서는 900장의 기본 영상에 무게 중심을 축으로 한 미세한 회전(rotation) 및 이동(shift) 오차를 첨가하여 확장한 70000장의 영상을 사용하였다.

그림 12. 클러스터 별 구분을 담당하는 게이팅 네트워크
Fig. 12. Gating networks : Discriminating each cluster using projection errors.



(a) 학습을 위한 목표물 영상들의 예



(b) 테스트를 위한 목표물 영상들의 예

그림 13. KASIT-ATR 적외선 차량 영상 데이터베이스
Fig. 13. KAIST-ATR FLIR-based vehicle image DB^[18].

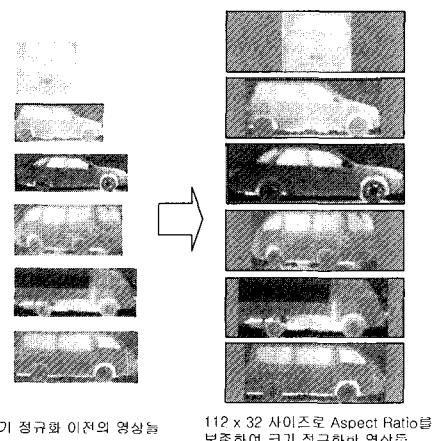


그림 14. 학습 영상들의 크기 정규화 예
Fig. 14. Size-normalization of learning patterns.

학습을 위해서는 먼저 영상들의 크기를 가로 세로의 비율을 유지하면서 112×32 크기의 사각형 안에 들어가도록 크기를 정규화하였다. <그림 14>는 이러한 크기 정규화의 예를 보인 것으로, 가로 세로의 비율을 유지하는 정규화의 이유는 이러한 비율 정보가 목표물의 자세나 종류의 결정에 있어서 중요한 정보이므로 이를 보존하여 인식 과정에 반영되도록 하기 위함이다.

2. 특징 정보 추출 부분 학습 결과

① 클래스 클러스터링 결과

II장의 클러스터링 기법에서 정의한 J 값(식 (18))의 변화를 다양한 클러스터 개수에 대해 반복횟수를 증가시켜가면서 측정하였다.

실험 결과 클러스터의 개수를 많이 할수록 J 값이 커졌고, 대략 800번 이상의 반복에서는 값이 일정하게 수렴하였다. 클러스터의 개수가 25개 이상일 경우 더 이상 큰 폭의 증가가 이루어지지 않았으며, 이러한 결과를 바탕으로 실험에 사용한 적외선 차량 영상 데이터베이스 전체 180(36자세 * 5차종)개 클래스를 20~25개의 클러스터로 분류하는 것이 적합하다는 결론을 내렸다. 이하의 실험에서는 최적 클러스터의 개수를 25개로 보고 이러한 클러스터링 결과를 바탕으로 모든 실험을 수행하였다.

② 클러스터 기반 기저영상의 획득 결과

비교를 위해 클래스 클러스터링을 하지 않고 학습 영상 전체에 대해서 각각 PCA 기법과 Fisherfaces 기법을 적용해 얻은 기저 영상들을 <그림 15>에서 보였다. 가장 큰 10개의 고유 값에 대응되는 기저 영상들을 보인 것으로, PCA를 통해 획득한 기저 영상인 Eigenfaces와 PCA+FLD를 통해 획득한 기저 영상인 Fisherfaces이다. <그림 15>의 Eigenfaces나 Fisherfaces에서 좌우 상하에 걸쳐 밝기 값이 큰 폭으로 변화하는 것을 확인할 수 있는데, 이러한 변화 성향은 이들 기저 영상들이 전역적인 밝기 변화에 매우 민감할 것임을 예상케 한다. 실제로 Fisherfaces 기법을 사용한 경우 밝기 변화에 덜 민감한 기저 영상이 찾아지는 것으로 알려져 있으나 이처럼 성향이 다른 많은 수의 클래스가 존재하는 상황에서 전체에 FLD 기법을 적용하

표 1. 클러스터 개수와 반복 횟수에 따른 J 값의 변화

Table 1. Result of class clustering : Variations of cost J .

클러스터 개수	반복횟수에 따른 J 값				
	200	400	600	800	1200
10	0.31	0.44	0.97	0.971	0.971
15	0.32	0.541	1.12	1.32	1.33
20	0.5712	0.831	1.25	1.54	1.55
25	0.4308	0.6059	1.24	1.5815	1.5815
30	0.4103	0.61	1.241	1.59	1.6

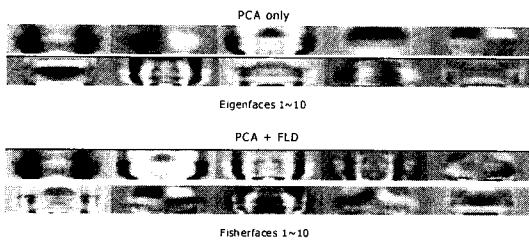


그림 15. 학습 영상 전체에 PCA기법과 Fisherfaces (PCA+FLD) 기법을 적용하여 얻어진 고유 영상들 중 고유값이 큰 순서대로 1~10번째에 대응되는 고유 영상들

Fig. 15. Eigenfaces & Fisherfaces got by general PCA & FLD method.

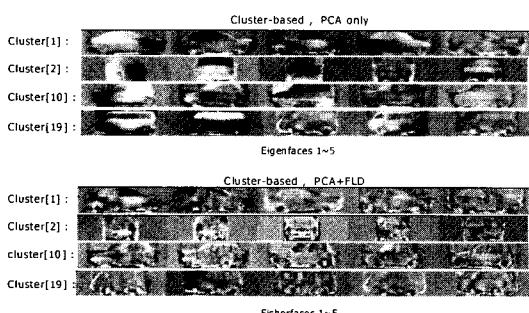


그림 16. 전체 25개의 클러스터들 중 1,2,10,19번째 클러스터에 각 클러스터별로 PCA와 fisherfaces (PCA+FLD)기법을 적용하여 얻어진통하여 획득한 고유 영상들 중 고유값이 큰 순서대로 1~5번째에 대응되는 고유 영상들

Fig. 16. Eigenfaces & fisherfaces got by proposed cluster-based method.

는 것은 PCA 기법을 사용하는 경우와 비교하여 이점이 없음을 확인할 수 있다.

<그림 16>은 앞의 클래스 클러스터링을 통해 결정된 클러스터링 결과를 바탕으로 각 클러스터 별로 별도의 Eigenfaces와 Fisherfaces를 찾은 획득한 결과의 일부를 보인 것이다. Eigenfaces의 경우 여전히 큰 폭의 밝기 변화 성향이 드러나 있지만, Fisherfaces의 경우 밝기 변화 성향은 거의 없어지고, 윤곽선이나 내부 경계선과 같은 모양 정보적 성분이 강조된 것을 확인할 수 있다. 이러한 모양 정보적 성분들은 밝기 값 변화에 덜 민감한 성분들로서 적외선 영상과 같이 밝기 값의 변화가 심한 영상의 인식을 위해 적합한 특징 정보이다.

3) 분류기 학습 결과

① 게이팅 네트워크(Gating Networks) 학습

분류기 부분에서 각 전문가(Expert)들의 비중을 조절해 주는 게이팅 네트워크는 2-계층의 MLPNs을 사용하였다. 2-계층은 입력층과 숨겨진 중간층 그리고 출력층으로 구성된다. 이러한 2-계층 구조의 선택은 게이팅 네트워크의 역할이 각 클러스터들 간의 선형적인 구분이기 때문이다. <표 2>는 게이팅 네트워크의 중간층의 뉴론의 개수를 결정하기 위한 실험의 결과이다. 뉴론의 개수를 늘려가면서 평균 MSE(Mean Squared Error)를 관찰하였으며, 학습 성공율을 측정하였다. 학습 성공률은 동일한 횟수의 반복 학습을 통해 학습 패턴들에 대해 100%의 성공률을 보장하도록 학습이 된 경우 성공한 것으로 보고, 각 뉴론의 개수별로 10번의 학습을 실시하여 그중 성공한 횟수의 비율을 표시한 것이다. 확인할 수 있듯이 최소 20개의 뉴론을 사용한 경우에서도 성공한 경우가 있었으며, 30개 이상의 뉴론에서는 MSE가 크게 감소하여 거의 일정해 지는 것을 확인할 수 있었다. 이러한 결과를 바탕으로 주어진 학습 패턴들에 대해 게이팅 네트워크의 최적 중간층 뉴론의 개수를 30개로 결정하였다.

② 클러스터별 전문가들의 학습

앞의 클래스 클러스터링 과정을 통해 만들어진 각 클러스터들은 대략 4~10 개의 클래스들을 포함하게 되고, 결국 분류기의 각 전문가(Expert)들은 4~10개의 클래스를 책임지게 된다. 이러한 각 전문가의 RBFNs를 학습시키는 과정에서 뉴론들의 초기값은 각 전문가들이 담당하는 클래스들의 학습 패턴의 평균과 분산을 구해 이용하였다. 각 전문가의 중간층 뉴론의 초기 개수는 해당 전문가가 담당하는 클래스의 개수로 하고, 뉴론을 증가시키면서 MSE를 관찰하여 뉴론의 개수를 결정하였다. 이러한 결과는 25개의 클러스터 별로 얻어져 지면상 생략한다. 실제 각 전문가별 RBFNs의 뉴론의 개수는 대략 5~15개에서 결정되었다.

표 2. 중간 계층의 뉴론(neuron)의 개수에 따른 평균 MSE(Mean Squared Error)와 학습 성공률

Table 2. Average MSE and learning success rate in gating networks

	#of Hidden neuron						
	5	10	15	20	25	30	35
Average MSE	0.00875	0.00742	0.00572	0.00341	0.00302	0.00098	0.00081
Training Success rate	0	0	0	0.1	0.3	0.8	0.9

4. 인식 실험 결과

인식 실험은 다음의 세 가지 상황에 대하여 실시하였다.

i) 화소 별 가우시안(Gaussian) 잡음의 첨가

영상 획득시에 화소별로 발생하는 센서 잡음을 가우시안 형태로 모델링함. 특히 적외선 영상 센서의 경우 이러한 센서 노이즈가 매우 심함. 학습 영상의 전체에 고르게 가우시안 노이즈를 첨가함.

ii) 밝기 값 편향 첨가

조명 변화나 적외선 영상의 온도 변화에 따른 밝기 변화 상황을 밝기 값 편향을 첨가하는 방법으로 모사하였음(<그림 18>).

iii) 다양한 오차를 포함하는 테스트 영상들

테스트 영상들은 실제 필드에서 촬영한 목표물을 포함하는 영상으로부터 배경 추정 기반의 목표물 검출 기법^[19]을 통해 획득한 목표물 영상들로 학습 영상들에 비해 화질이 매우 떨어지고 미세한 소실이나 가려짐이 존재하며 밝기 변화가 심함.

위의 세 가지 상황에 대해 특징 추출 기법 3가지

표 3. 가우시안 잡음 첨가 비율에 따른 기법별 인식률

Table 3. Recognition rates of various methods: Gaussian noise added case.

Feature extraction & classification method	(Noise variance) 25% ~ 100%					
	5%	10%	15%	20%	25%	(%)
PCA+Nearest neighbor	83	72	65	51	43	
PCA(atwithout first-3)+ Nearest neighbor	95	81	68	55	40	
Fisherfaces + Nearest neighbor	80	72	63	52	39	
PCA+2-layer MLP	85	70	68	49	41	
PCA(atwithout first-3)+ 2-layer MLP	94	79	70	50	43	
Fisherfaces + 2-layer MLP	81	71	58	48	37	
cluster-based PCA + RBFNs-based ME	100	83	77	68	63	
cluster-based Fisherfaces + RBFNs-based ME	100	98	93	88	80	

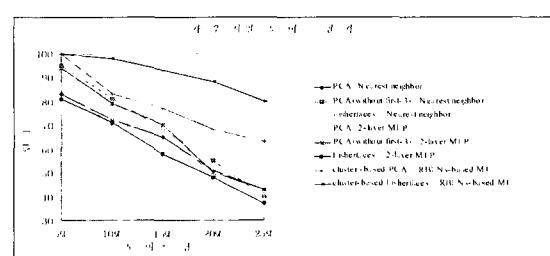


그림 17. 가우시안 잡음 첨가 비율에 따른 기법별 인식률의 변화

Fig. 17. Graph of recognition rates of various methods : Gaussian noise added case.

(PCA, PCA without first-3(PCA 기법을 통해 얻은 기저 영상 중 밝기 변화에 민감한 고유 값이 큰 1~3번째를 제외하고 사용하는 기법), Fisherfaces)와 분류 기법 3가지(Nearest Neighbor classifier, 2-Layer MLP classifier)를 조합한 6가지 기법과 제안한 클러스터 기반 특징 추출 기법에서 fisherfaces 기법을 PCA로 대체하여 제안 분류기법을 적용한 경우 1가지를 포함하여 총 7가지의 기법들과 제안 기법의 성능을 인식 성능 테스트 실험을 통해 비교하였다.

① 가우시안 잡음 첨가 비율에 따른 인식 성능 비교 학습 영상들에 각 화소별로 가우시안 잡음을 다양한 비율로 첨가하여 이에 따른 인식률의 변화를 측정하였다.

잡음의 크기를 증가시킬수록 인식률이 떨어져 잡음의 분산이 전체 신호 분산의 최대 25% 이상일 경우 대부분의 기법이 50% 이하의 인식률을 보였다. 하지만, 제안한 분류기법을 사용한 경우에는 인식률이 상대적으로 높았으며, 특히 제안 특징 추출 기법과 제안 분류기법을 함께 사용한 경우에는 25% 이상의 가우시안 잡음에서도 80% 이상의 높은 인식률을 보였다. 이러한 결과는 RBF 모델 자체가 가우시안 형태의 모델이기 때문에 RBF 기반의 분류기가 화소별로 존재하는 가우

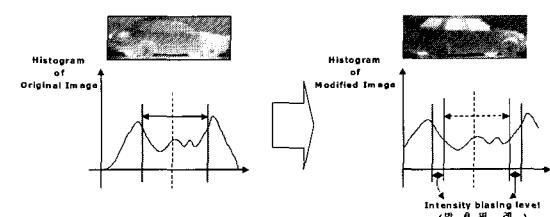


그림 18. 밝기값 편향 첨가

Fig. 18. Adding intensity bias.

표 4. 밝기 편향 첨가 레벨에 따른 인식률 비교

Table 4. Recognition rates of various methods : Intensity bias added case.

Feature extraction & classification method	밝기 편향 레벨 (max, 255, min, 0)					
	0	10	20	30	40	50
PCA+Nearest neighbor	100	83	65	53	47	44
PCA(atwithout first-3)+ Nearest neighbor	100	95	88	82	76	53
Fisherfaces + Nearest neighbor	100	92	86	79	71	48
PCA+2-layer MLP	100	85	69	65	48	41
PCA(atwithout first-3)+ 2-layer MLP	100	94	87	83	78	56
Fisherfaces + 2-layer MLP	100	91	85	77	69	40
cluster-based PCA + RBFNs-based ME	100	86	70	62	53	47
cluster-based Fisherfaces + RBFNs-based ME	100	98	91	88	80	72

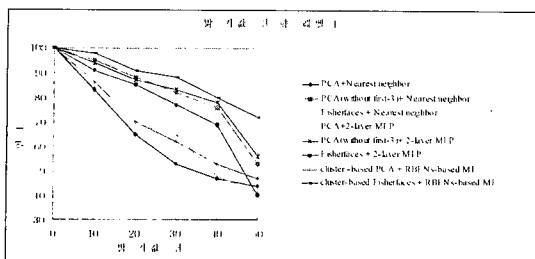


그림 19. 첨가된 밝기값 편향 크기에 따른 기법별 인식률의 변화

Fig. 19. Graph of recognition rates of various methods: Intensity bias added case.

시안 잡음에 대해 강인한 특성을 가지기 때문인 것으로 추정된다.

② 밝기값 편향 첨가 비율에 따른 인식 성능 비교
밝기값 편향 첨가는 영상의 히스토그램을 밝은 쪽과 어두운 쪽의 두 부분으로 나눈 후, 두 부분의 평균의 차이를 임의의 편향 값만큼 늘려주는 작업이다. 이러한 작업은 영상 전체에서 어두운 부분과 밝은 부분의 밝기 차이를 심화시키는 것으로 조명변화나 온도 환경 변화에 따른 적외선 영상의 밝기 변화 상황을 모사한다. 이러한 밝기값 편향을 다양한 크기로 실험 영상에 첨가한 후 인식률을 측정하였다. 결과로 제안 기법은 영상 내 밝기 값의 최대 범위인 255의 20% 수준인 50의 밝기 편향이 첨가된 상황 하에서도 70% 이상의 인식률을 보였다. 그 밖에 밝기 변화 성분에 덜 민감하도록 고유 영상을 조정한 PCA without first-3나 Fisherfaces 기법이 좋은 성능을 보였으며, 일반 PCA의 경우 심각한 성능 저하를 보였다.

③ 다양한 오차를 포함하는 테스트 영상들에 대한 인식 성능 비교

다양한 오차를 포함하는 테스트 영상들은 실제 필드에서 촬영한 목표물을 포함하는 동영상으로부터 배경 추정 기반의 목표물 검출 기법^[19]을 통해 추출한 목표물 영상들이다. 이러한 테스트 영상들에 대한 인식 결과에서 제안 기법은 76%의 인식 성공률을 보였다. 대부분의 비교 대상 기법들의 인식률이 60% 이하에 머물렀으며 클러스터 기반으로 PCA를 적용하고 제안 혼합 전문가 구조를 사용한 경우 70%를 약간 상회하는 인식률을 보였다. 인식률이 전체적으로 낮은 것은 테스트 영상들에 일부분이 가려지거나 목표물의 일부분이 잘려져 나간 경우와 각종 잡음이 심각한 경우가 테스트 영상들에 모두 포함되어 있기 때문이다. 이러한 다양한

표 5. 테스트 영상들에 대한 기법별 인식률
Table 5. Recognition rates for the various test patterns acquired in real field.

Feature extraction & classification method	인식률
PCA+Nearest neighbor	55
PCA (without first-3)+ Nearest neighbor	58
Fisherfaces + Nearest neighbor	59
PCA+2-layer MLP	57
PCA (without first-3)+ 2-layer MLP	57
Fisherfaces + 2-layer MLP	59
cluster-based PCA + RBFNs-based ME	72
cluster-based Fisherfaces + RBFNs-based ME	76

오차 요인을 포함한 영상들에 대해서도 제안 기법은 비교된 다른 기법들에 비해 상대적으로 우수한 성능을 보였다.

V. 정리 및 향후 과제

본 연구에서는 적외선 영상 기반의 ATR 시스템에 적합한 특징 정보 추출 기법과 분류기법으로 기존의 Fisherfaces 기법을 매우 많은 수의 클래스들로 구성되는 학습 패턴들의 분류 문제에 적합하도록 확장한 클러스터 기반 Fisherfaces 기법과 RBFNs 기반의 혼합 전문가 구조를 사용한 신경망 형태의 분류기를 제안하였다. 제안 기법은 “KAIST-ATR 적외선 자동차 영상 DB”를 통해 테스트되었고, 다양한 기존의 기법들과 비교되었다. 비교 실험 결과 제안 기법이 화소별로 존재하는 센서 잡음이나 온도 환경 변화에 따른 적외선 영상내의 밝기 변화와 같은 전역적인 밝기 편향 등의 다양한 오차 요인들에 대해 강인함을 검증하였다.

향후 과제로는 현재의 기법에서 클래스 클러스터링 과정에서 클러스터의 개수를 자동적으로 결정할 수 있는 기법에 대한 연구와 새로운 클래스가 추가될 경우 전체 알고리즘을 어떤 식으로 재학습시킬 것인가에 대한 연구가 필요하다. 또한 현실적으로 인식률을 높이기 위해 가장 필요한 연구로 정확한 목표물 탐지 및 목표물 분할 기법에 관한 연구가 더 많이 이루어져야 하며 가려지거나 잘려져 나간 목표물 영상에 대한 대응 방안이 고려되어야만 할 것이다.

참고 문헌

- [1] Baoxin Li, Qinfen Zheng, Sandor Der, Rama Chellappa, Nasser M. Nasrabadi, Lipchen

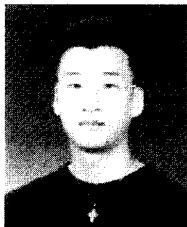
- A.Chan and linCheng Wang, "Experimental Evaluation of Neural, Statistical and Model-Based Approaches to FLIR ATR," Part of the SPIE Conference on Automatic Target Recognition VIII, Vol. 3371, pp. 388~397, 1998.
- [2] James A. Ratches, C.P. Walters, Rudolf G. Buser and B.D. Guenther, "Aided and automatic target recognition based upon sensory inputs from image forming systems," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 19, No.9, pp. 1004~1019, 1997.
- [3] Mohamed A. KHabou, "Morphological Shared-Weight Neural Networks : a Tool for Automatic Target Recognition Beyond the Vision Spectrum," Computer Vision Beyond the Visible Spectrum: Methods and Applications, 1999. (CVBVS '99) Proceedings. IEEE Workshop on, 1999.
- [4] David Gross, "A Neural Network ATR for High Range Resolution Radar Signature Recognition of Moving Ground Targets," Signals, Systems, and Computers, 1999. Conference Record of the Thirty-Third Asilomar Conference on, Volume: 2 , 1999.
- [5] Vasconcelos, G.C., "Neural network based automatic target processing and recognition," Image Processing And Its Applications, 1999. Seventh International Conference on(Conf. Publ. No. 465), Volume : 1, 1999.
- [6] Baback Moghaddam and Alex Pentland, "Probabilistic Visual Learning for Object Representation," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 19, No. 7, 1997.
- [7] Peter N.Belhumeur, Joao P.Hespanha, and David J.Kriegman, "Eigenfaces vs. Fisherfaces : Recognition Using Class Specific Linear Projection," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 19, No.7, pp. 713~714, JULY 1997.
- [8] Chengjun Liu, and Harry Wechsler, "A Shape-and Texture-Based Enhanced Fisher Classifier for Face Recognition," IEEE Trans. Image Processing, Vol. 10, No. 4, pp. 602~604, APRIL 2001.
- [9] Cappelli, R; Maltoni, D, "Multispace KL for pattern representation and classification," Pattern Analysis and Machine Intelligence, IEEE Transactions on , Volume : 23 Issue : 9, pp. 977~996, Sep 2001.
- [10] M. Turk and A. Pantland, "Eigenface for Recognition," Journal of Cognitive Neuroscience, Vol.3, No.1, pp. 71~86, 1991.
- [11] Zhujie, Y.L.Yu, "Face Recognition with Eigenfaces," Proceeding of the IEEE International Conference on Industrial Technology, pp. 434~438, 1994.
- [12] Simon Haykin, "NEURAL NETWORKS - A Comprehensive Foundation - Second Edition," Prentice Hall International, Inc., pp. 368~381, 1999.
- [13] Ahuja, N., Kriegman, D., Yang, M.-H, "Face recognition using kernel eigenfaces," Image Processing, 2000, Volume: 1, pp. 37~40 vol.1, MARCH 2000.
- [14] M. Sonka, V. Hlavac, R. Boyle, "Image Processing, Analysis, and Machine Vision," PWS publishing, 1999.
- [15] 권재환, 이광연, 김성대, "적외선 영상에서의 불변 특징 정보를 이용한 목표물 인식," 23회 대한전자 공학회 추계합동 학술대회 논문집 IV, Vol.23, No.2, pp. 65~68, 2000
- [16] 신호철, 최해철, 이진성, 조주현, 김성대, "밝기-윤곽선 정보 기반의 목표물 인식 기법," 제140회 신호처리 학술대회 논문집, pp. 411~414, 2001
- [17] 신호철, 최해철, 최학훈, 김성대, "DCT 기법을 활용한 불록 기반의 적외선 영상 차원 감축 및 인식 기법," 한국군사과학기술학회 2002년도 종합학술 대회 논문집, Vol.2, pp. 659, 2002
- [18] <http://sdvision.kaist.ac.kr/~horse/ATRDB>
- [19] 조주현, 최해철, 이진성, 신호철, 김성대, "다중 센서 융합과 배경 추정을 이용한 물체 영역 검출", 14회 신호처리 학술대회, 제14권, 제1호, pp. 443~446, 2001

저자소개



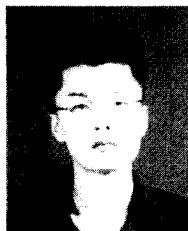
申鎬澈(正會員)

2000년 2월 : 한국과학기술원 전기 및 전자공학과(공학사). 2002년 2월 : 한국과학기술원 전자전산학과 전기 및 전자공학전공(공학석사). 2003년~현재 : 한국과학기술원 전자전산학과 전기 및 전자공학전공 박사과정. <주관심분야 : 영상 처리, 패턴 인식, 컴퓨터 비전>



曹周鉉(正會員)

1999년 8월 : 한국과학기술원 전기 및 전자공학과(공학사). 2002년 2월 : 한국과학기술원 전자전산학과 전기 및 전자공학전공(공학석사). 2003년~현재 : 한국과학기술원 전자전산학과 전기 및 전자공학전공 박사과정. <주관심분야 : 영상처리, 컴퓨터 비전>



崔海哲(正會員)

1997년 2월 : 경북대학교 전자공학과(공학사). 1999년 2월 : 한국과학기술원 전기 및 전자공학과(공학석사). 2003년~현재 : 한국과학기술원 전자전산학과 전기 및 전자공학전공 박사과정. <주관심분야 : 컴퓨터 비전, 영상 처리, 패턴 인식>



金聖大(正會員)

1977년 : 서울 대학교 전자공학과(공학사). 1979년 : 한국과학기술원 전기 및 전자공학과(공학석사). 1983년 : 프랑스 INPT ENSEEIHT (공학박사). 1984년~현재 : 한국과학기술원 전자전산학과 전기 및 전자공학 전공 교수. <주관심분야 : 영상 처리, 영상 통신, 컴퓨터 비전, VLSI구현 등>



李珍晟(正會員)

1998년 2월 : 한국과학기술원 전기 및 전자공학과(공학사). 2000년 2월 : 한국과학기술원 전자전산학과 전기 및 전자공학전공(공학석사). 2003년~현재 : 한국과학기술원 전자전산학과 전기 및 전자공학전공 박사과정. <주관심분야 : 영상 처리, 컴퓨터 비전>