

논문 2010-47CI-2-3

DTW와 퓨전기법을 이용한 비유사도 기반 분류법의 최적화

(On Optimizing Dissimilarity-Based Classifications Using a DTW and Fusion Strategies)

김 상 운*, 김 승 환**

(Sang-Woon Kim and Seunghwan Kim)

요 약

본 논문에서는 동적시간교정법(dynamic time warping: DTW)과 다중퓨전기법(multiple fusion strategy: MFS)을 연속 적용하여 비유사도기반 분류법(dissimilarity-based classification: DBC)을 최적화시키는 방법의 실험결과를 보고한다. DBC란 샘플 패턴을 분류하기 위하여 샘플의 특징 값을 이용하는 대신에 샘플들 사이의 비유사도를 측정하여 분류기를 설계하는 방법이다. DTW에서는 다음과 같이 두 단계로 나누어 비유사도를 측정한다. 먼저 상관계수를 이용하여 객체 샘플들을 대응시키기 위한 최적의 대응경로를 찾을 수 있도록 샘플들을 조정한다. 그리고 기존의 거리측정법으로 조정된 샘플들 사이의 비유사도를 측정한다. MFS에서는 분류기결합 뿐만 아니라 비유사도 행렬생성에서도 퓨전기법을 적용한다. 즉, DTW 기법으로 작성한 다수의 비유사도 행렬들을 결합하여 새로운 비유사도 행렬을 생성한 다음, 이 행렬공간에서 여러 개의 베이스 분류기를 학습하여 다시 결합한다. 본 논문에서 제안한 방법을 벤치마크 영상 데이터베이스를 대상으로 실험한 결과, 기존의 방법과 비교하여 분류 성능을 향상시킬 수 있음을 확인하였다. 이와 같은 실험결과로 볼 때, 제안 방법을 멀티미디어 정보검색 등과 같은 다른 고차원 응용에도 활용할 수 있을 것으로 사료된다.

Abstract

This paper reports an experimental result on optimizing dissimilarity-based classification(DBC) by simultaneously using a dynamic time warping(DTW) and a multiple fusion strategy(MFS). DBC is a way of defining classifiers among classes; they are not based on the feature measurements of individual samples, but rather on a suitable dissimilarity measure among the samples. In DTW, the dissimilarity is measured in two steps: first, we adjust the object samples by finding the best warping path with a correlation coefficient-based DTW technique. We then compute the dissimilarity distance between the adjusted objects with conventional measures. In MFS, fusion strategies are repeatedly used in generating dissimilarity matrices as well as in designing classifiers: we first combine the dissimilarity matrices obtained with the DTW technique to a new matrix. After training some base classifiers in the new matrix, we again combine the results of the base classifiers. Our experimental results for well-known benchmark databases demonstrate that the proposed mechanism achieves further improved results in terms of classification accuracy compared with the previous approaches. From this consideration, the method could also be applied to other high-dimensional tasks, such as multimedia information retrieval.

Keywords : 비유사도기반 분류법(dissimilarity-based classification: DBC),
동적시간교정법(dynamic time warping: DTW),
다중퓨전기법(multiple fusion strategies: MFS), multimedia information retrieval

* 정희원-교신저자, ** 정희원-임시연구조원, 명지대학교 컴퓨터공학과
(Department of Computer Engineering, Myongji University)

※ 이 논문은 2008년도 한국학술진흥재단의 지원을 받아 수행된 연구임(KRF-2008-013-D00115).

이 논문의 초본(영문)은 학술회의(FIT2009, Sendai, Japan; ACIIDS2010, Hue, Vietnam)에서 발표되었음.

접수일자: 2009년12월11일, 수정완료일: 2010년3월10일

I. 서론

멀티미디어 정보검색 등의 응용에서 특징차원은 고차원이 되는 반면, 학습을 위한 샘플의 수는 충분치 못한 경우가 많다^[1]. 즉, 샘플벡터의 수가 특징차원에 비하여 적을 경우 변동행렬이 특이행렬이 되기 때문에 변별력이 떨어지게 되며, 이를 소규모 샘플 수에 기인한 회소성 문제(under-sampled problem)라 한다^[2].

최근, 샘플간의 비유사도(dissimilarity)에 기반 한 분류법(dissimilarity-based classification: DBC)^[3]을 이용하여 특징차원을 축소하는 방법으로 회소성 문제의 해결을 시도하였다^[4~6]. 참고문헌^[4]에서는 비유사도 측정을 위한 기준샘플을 적절히 선택하는 방법으로 DBC에 의한 회소성 문제의 해결을 시도하였으며, 참고문헌^[5]에서는 동적계획법으로 비유사도를 측정하여 DBC의 성능을 개선하였다. 또한, 참고문헌^[6]에서는 패턴인식을 위한 표현단계와 일반화단계에서 퓨전기법을 중복 적용하여 DBC의 성능을 최적화시켰다.

그런데 DBC를 위해 얼굴영상과 같은 고차원 샘플간의 비유사도를 측정할 경우, 얼굴의 방향과 촬영거리, 조명상태 및 표정 등에 따라 측정결과가 달라진다^[7]. 예를 들어, 좌측을 바라보는 얼굴과 우측을 바라보는 얼굴의 비유사도를 계산할 경우, 대응되는 부분이 다르기 때문에 정확한 거리측정이 어렵다. 이러한 문제를 해결하기 위하여 서로 다른 길이의 시계열 패턴매칭을 위해 개발된 동적시간간조정법(dynamic time warping: DTW)^[8~9]을 응용할 수 있다. 즉, 서로 다른 크기의 영상을 부분영역으로 분할하여 수평 및 수직 방향에 따라 동적으로 대응시키는 방법이다.

한편, 퓨전기법이 분류기의 성능을 향상시킬 수 있다는 가능성 때문에 최근 활발한 연구가 진행되고 있다^[10]. 여기서 퓨전이란 서로 다른 환경에서 다수의 베이스 분류기를 학습한 다음, 이 분류기들을 다시 결합하여 식별오류를 줄이는 방법이다. 특히, 다중퓨전기법(multiple fusion strategy: MFS)^[6]은 분류시스템을 구성하는 표현단계와 일반화단계에서 퓨전규칙을 적용하는 방법이다. 즉, DBC에서 비유사도 공간의 생성과 분류기 학습에 DTW와 MFS를 연속 적용하는 방법이다.

본 논문에서는 먼저 DTW를 이용하여 방향과 크기가 다른 영상들의 비유사도를 측정하여 다수의 비유사도 공간을 생성한 다음, 이 비유사도 공간에서 다시 여러 개의 베이스 분류기를 학습하여 결합시키는 MFS로

DBC의 최적화를 시도한다. 예를 들어, DTW에서 영상 s 와 t 의 비유사도를 측정할 때, s 의 한 요소가 t 의 다수 요소에 대응되는 특이성 문제를 해결하기 위하여 경사 가중치 (또는 제한)를 이용하는 방법과 두 영상의 중요한 요소를 추출한 다음, 이를 이용하여 영상을 다수의 부분영역으로 나누어 대응시키는 방법을 검토한다. 또한, MFS의 분류기 퓨전에서는 베이스 분류기를 결합시키는 방법이 고정되어 있는 고정결합과 학습에 따라 결합을 달리하는 학습결합을 이용한다.

일반적인 분류 시스템은 표현단계와 일반화단계로 구성된다. 본 논문에서 DBC의 성능을 최적화시키기 위하여 DTW와 MFS를 도입하는 이유는 표현단계와 일반화단계 모두에서 최적화를 이루기 위해서 이다. 즉, DTW를 이용할 경우, 객체의 크기나 방향에 따라 기존의 방법으로는 측정하기 어려운 비유사도를 측정할 수 있게 된다. 또한, MFS를 이용할 경우, 서로 다른 식별 공간에서 독립적으로 학습한 분류기들을 결합하여 식별 특성을 개선할 가능성이 있다.

본 논문의 구성은 다음과 같다. 제 II장에서는 비유사도 표현 및 분류기법을 간단히 소개한다. 제 III장에서는 DTW를 이용하여 비유사도 공간행렬을 작성하는 방법을 설명한다. 그리고 제 IV장에서는 다중퓨전기법으로 DBC의 성능을 최적화시키는 방법을 설명하고, 기존 방법과의 차이점을 비교한다. 제 V장에서는 실제의 벤취 마크 영상 데이터를 대상으로 제안방법을 실험한 실험결과를 고찰하고, 제 VI장에서 결론을 맺는다.

II. 비유사도 표현 및 분류^[6]

클래스를 미리 알고 있는 n 개의 p -차원 벡터로 이루어진 샘플집합을 $T = \{x_1, \dots, x_n\} \in R^p$ 라 할 때, 문제는 T 를 이용하여 새로운 입력 z 를 검색 또는 식별하는 분류기를 설계하는 일이다.

먼저, 각 클래스의 샘플집합 T 에서 추출한 프로토타입(prototype) 집합을 $Y = \{y_1, \dots, y_m\}$ 이라 한다. 이때, 두 샘플벡터 x_i, y_j 의 비유사도를 $d(x_i, y_j)$ 라고 하면, T 와 Y 의 비유사도로 이루어지는 행렬 $D(T, Y)$ 는 $n \times m$ 차원으로, D 의 열벡터(column vector)는

$$(d(x_i, y_1), d(x_i, y_2), \dots, d(x_i, y_m))^T, \quad 1 \leq i \leq n \quad (1)$$

이 된다. 즉, $D(x, Y)$ 는 벡터 x 와 프로토타입 집합 Y 와 비유사도를 측정한 값의 배열이 된다. 여기서, 식 (1)의 열벡터를 비유사도 벡터라 정의하고, 간단히 $\delta(x)$ 로 표기한다. 즉, $\delta(x)$ 는 p -차원 특징공간의 벡터 x 를 m -차원 유사도 공간으로 사상시킨 벡터가 된다. 따라서 DBC란 입력 특징공간의 p -차원 벡터 x 대신에 비유사도 공간의 m -차원 벡터 $\delta(x)$ 를 대상으로 하는 분류방법이다. 이 때, 학습샘플은 $\{\delta(x_i)\}_{i=1}^n$ 가 되고, k-NN 분류기를 비롯한 선형 분류기, 2차 분류기 등의 식별규칙을 이용할 수 있다^[3]. 또, 분류할 테스트 샘플 z 는 비유사도 공간의 m -차원 벡터 $\delta(z)$ 가 된다.

일반적인 DBC 알고리즘은 다음과 같다^[6]. 여기서 입력은 학습샘플집합 T 와 테스트 샘플 z 이고, 출력은 z 의 클래스 $class$ 이다.

1. 학습샘플집합 T 에서 프로토타입 Y 를 추출한다. 이 때, RandomC, KCentres, ModeSeek 등^[3]이나 CNN, PNN, HYB 등^[11]을 이용할 수 있다.

2. 식 (1)를 이용하여 주어진 비유사도 측정법으로 T 와 Y 로부터 비유사도 행렬 $D(T, Y)$ 를 생성한다. 또 테스트할 입력 벡터 z 에 대해 같은 방법으로 비유사도 열벡터 $\delta(z)$ 를 산출한다.

3. 비유사도 행렬 $D(T, Y)$ 에서 분류기를 학습하여 열벡터 $\delta(z)$ 를 식별한 결과를 $class$ 로 출력한다.

III. DTW에 의한 비유사도 측정

길이가 각각 p 와 q 인 두 영상 벡터(image vector) $s = (x_1, x_2, \dots, x_p)$ 와 $t = (y_1, y_2, \dots, y_q)$, $x_i, y_j \in R$ 에 대한 DTW는 $p \times q$ 행렬이 되며, 행렬 요소 (i, j) 는 두 화소 x_i, y_j 의 거리 $d(x_i, y_j)$ 이다^[8-9]. 이 때, s 를 t 로 사상시키는 대응경로는 $w = \{w(1), w(2), \dots, w(p)\}$ 로, 여기서 $j = w(i)$, ($i \in [1, p], j \in [1, q]$)는 s 의 i 번째 요소 x_i (화소의 그레이 값)을 t 의 j 번째 요소 y_j 로의 대응을 의미한다. s 의 요소를 모두 t 로 대응시키는 경로의 누적거리 $g(i, j)$ 는

$$g(i, j) = d(x_i, y_j) + \min \begin{cases} g(i-1, j) \\ g(i-1, j-1) \\ g(i, j-1) \end{cases} \quad (2)$$

의 점화식으로 구할 수 있다.

이 때, 최소 누적거리에 해당하는 경로 w 를 결정하

기 위하여 상관(correlation)^[5, 12]

$$\rho(s, t) = E[(s - \mu_s)(t - \mu_t)'] / \sigma_s \sigma_t \quad (3)$$

를 이용할 수 있다. 식 (3)에서 μ_s (또는 μ_t)는 s (또는 t)의 평균이고, σ_s (또는 σ_t)는 s (또는 t)의 표준편차이다. 또한 E 는 기대 값을 산출하는 함수이다. 여기서 x_i, y_j 는 1-차원 확률변수이기 때문에 추정된 상관은

$$\rho(s, t) = \begin{bmatrix} \rho_{xx} & \rho_{xy} \\ \rho_{yx} & \rho_{yy} \end{bmatrix} = \begin{bmatrix} 1 & \rho_{xy} \\ \rho_{yx} & 1 \end{bmatrix} \quad (4)$$

가 되고, ρ_{xy} (또는 ρ_{yx})는 두 확률변수의 상관계수(correlation coefficient)^[12]로서, 주어진 샘플분포의 상관관계를 나타낸다.

예를 들어, 길이 p 인 세 개의 벡터를 $s = \text{sort}(\text{randn}(p, 1))$; $t1 = \text{sort}(\text{randn}(p, 1))$; $t2 = \text{randn}(p, 1)$ 으로 생성한다. 여기서 randn 과 sort 는 각각 정규분포를 따르는 난수발생함수와 정렬함수(<http://www.mathworks.com> 참조)이다. 즉, 벡터 s 와 $t1$ 은 p 개의 난수를 생성하여 내림차순으로 정렬시킨 벡터인 반면, $t2$ 는 정렬시키지 않은 p 개의 난수로 구성된 벡터이다. 따라서 s 와 $t1$ 의 상관은 매우 높은 반면, s 와 $t2$ 의 상관은 상대적으로 낮게 된다. 실제로 100개($p = 100$)의 난수를 생성하여 구성한 세 벡터 $s, t1, t2$ 의 상관관계는 그림 1과 같다.

그림 1(a)는 벡터 쌍 $(s, t1)$ 에서 수집한 요소 (x_i, y_i) 의 분포 예이고, 그림 1(b)는 벡터 쌍 $(s, t2)$ 에서 수집한 요소 (x_i, y_i) 의 분포 예이다. 그림 1(a)는 x_i 와 y_i 사이에 매우 큰 양의 상관이 존재하는 반면, 그림 1(b)는




그림 1. p 개의 쌍으로 구성된 난수집합 $\{(x_i, y_i)\}_{i=1}^p$ 의 분포: (a) 좌측과 (b) 우측

Fig. 1. Distributions of p paired random variables, $\{(x_i, y_i)\}_{i=1}^p$: (a) left and (b) right.

상관이 없음을 나타낸다.

이상에서 고찰한 바와 같이, 두 영상벡터에 대해 DTW를 위한 최적 경로를 탐색할 때, 두 벡터를 구성하는 요소들 사이에 존재하는 상관관계 즉, 상관계수를 이용할 수 있음을 알 수 있다. 이 때, 주어진 샘플 쌍의 집합 $\{(x_i, y_i)\}_{i=1}^p$ 의 상관계수 ρ_{xy} 를 추정하기 위하여 샘플상관계수법(sample correlation coefficient method)이나 최우수 추정법(maximum likelihood estimates) 등 다양한 방법을 이용할 수 있다^[12]. 본 논문에서는 주어진 샘플 쌍에서 직접 상관계수를 추정하는 샘플상관계수법을 이용한다*. 예를 들면, 그림 1의 두 벡터 쌍 $(s, t1)$ 과 $(s, t2)$ 에 샘플상관계수법을 적용할 경우, 상관계수 ρ_{xy} 는 각각 0.9833과 0.1730이 된다. 따라서 이들 ρ_{xy} 값을 비교하여 s 를 $t2$ 보다는 $t1$ 에 대응시킬 수 있다.

IV. MFS에 의한 성능 개선

퓨전이란 주어진 식별 문제를 해결할 수 있는 다수의 분류기(또는 특징)를 학습한 다음, 이 분류기(또는 특징)들을 식별 오차를 더욱 줄일 수 있는 방법으로 결합하는 방법이다. 기존의 퓨전기법은 주로 분류 시스템의 일반화단계에서 다수의 분류기를 학습한 다음, 적절한 퓨전기법을 적용하여 식별성능을 향상시키는 방법이었다. 그런데 참고문헌^[6]에서는 일반화단계 뿐만 아니라 샘플의 표현단계에서도 퓨전기법을 적용하는 다중퓨전기법 MFS를 제안하였다. 즉, 비유사도 표현단계와 분류기 학습을 위한 일반화단계에서 각각 다수의 비유사도 표현과 분류기를 다 단계로 결합시키는 방법이다.

먼저, 다수의 분류기를 학습하기 위하여 서로 다른 표현의 샘플벡터가 제공된다고 할 때, 각 샘플집합으로 학습한 분류기들을 결합하기 위하여 *Product*, *Sum*, *Max*, *Min*, *Median*, *Majority vote* 등과 같은 퓨전규칙을 이용할 수 있다**. 예를 들어, 클래스별 사진확률이 동일하다고 할 경우, *Majority vote* 규칙은 여러 개의 분류기가 만들어 낸 출력결과를 분석하여 다수표를 획득한 클래스를 최종결과로 출력하는 규칙이다. 또한, 서로 다른 비유사도 공간을 결합하여 새로운 공간을 생

성할 수 있으며, 퓨전규칙에는 *Average*, *Product*, *Min*, *Max*, *Cat* 등이 있다^[3]. 예를 들어, *Average*는 두 개의 비유사도 공간(행렬) $D^{(1)}(T, Y)$ 와 $D^{(2)}(T, Y)$ 를 평균하여 $D(T, Y) = \alpha_1 D^{(1)}(T, Y) + \alpha_2 D^{(2)}(T, Y)$ 을 생성하는 규칙이다. 여기서 α_1, α_2 는 정규화 가중치이다.

본 논문에서는 DTW를 이용하여 다양한 비유사도 공간행렬을 계산한 다음, 이들을 결합하여 새로운 비유사도 공간을 생성한다. 그리고 이 공간에서 다수의 베이스 분류기를 학습하여 다시 결합시키는 MFS로 DBC의 성능을 최적화시키는 방법(이하, DTW-MFS로 표기)을 제안한다. DTW-MFS를 이용한 DBC 알고리즘은 다음과 같다. 여기서 입력은 학습샘플집합 T 와 테스트 샘플 z 이고, 출력은 z 의 클래스 *class*이다.

1. 학습샘플 T 를 모두 프로토타입 Y 로 선정한다.
2. DTW를 이용하여, T 와 Y 로부터 k 개의 서로 다른 비유사도 행렬 $D^{(1)}(T, Y), D^{(2)}(T, Y), \dots, D^{(k)}(T, Y)$ 를 계산한다.
3. l 개의 서로 다른 (비유사도 결합을 위한) MFS로 $\{D^{(i)}(T, Y)\}_{i=1}^k$ 를 결합하여 새로운 비유사도 행렬 $\{D^{(j)}(T, Y)\}_{i=1}^l$ 를 생성한다. 또 테스트 샘플 z 도 같은 방법으로 비유사도 열벡터 $\delta^{(j)}(z)$ 를 산출한다.
4. 비유사도 행렬 $\{D^{(j)}(T, Y)\}_{i=1}^l$ 에서 l 개의 베이스 분류기를 학습하여 열벡터 $\delta^{(j)}(z)$ 를 식별한 다음, 그 결과를 각각 *class*⁽¹⁾, *class*⁽²⁾, ..., *class*^(l)로 한다.
5. (분류기 결합을 위한) MFS로 단계 4의 베이스 분류기들을 결합하여 *class*^(j), ($j = 1, \dots, l$)로부터 최종 결과 *class*를 얻는다. 이 때, 베이스 분류기 결합에는 고정 및 학습 결합기를 이용한다.

V. 실험

1. 실험 데이터

본 논문의 실험에서는 벤취마크 얼굴영상 데이터베

* 샘플상관계수법의 구현 예로 MATLAB의 응용 패키지 $R = \text{corrcoef}(s, t)$ 를 이용할 수 있다. 여기서 R 은 두 열 벡터 s 와 t 의 상관을 나타내는 2×2 상관계수 행렬이다.

** 여기서는 분류기 퓨전규칙에 대한 설명을 생략한다. 각 퓨전규칙에 이론적-실험적 고찰과 최근의 연구동향은 잘 알려진 관련 문헌^[10]을 참조할 수 있다.

표 1 실험 데이터의 특성
Table 1 Characteristics of experimental data.

영상 데이터	벡터차원 (영상의 크기)	클래스 수	클래스별 패턴 수	패턴벡터 총 수
AT&T	10304 (112x92)	40	10	400
Yale	42008 (178x236)	15	11	165
Yale2	4992 (64x78)	15	11	165

이스인 AT&T*와 Yale**를 이용한다. AT&T는 40명의 얼굴을 조금씩 다르게 10번씩 촬영한 것이고, Yale은 15명에 대해 한 사람 당 11장씩 촬영한 데이터이다. 또한, Yale 영상에서 얼굴요소만을 추출하여 실험영상을 구성하였고, 이를 Yale2로 표기한다. 이들 세 영상 데이터베이스의 특성은 표 1과 같다.

2. 실험방법

본 실험에서는 기존 DBC와 DTW-MFS를 이용한 DBC의 식별성능을 비교한다. 기존 DBC의 실험에서는 유클리드거리(ED)와 국부적인 거리(regional distance: RD)^[7]로 서로 다른 비유사도 행렬을 작성하여 DBC의 식별성능을 실험(이하, Ex-1이라 표기)한다. Ex-1에서 비유사도 행렬을 작성할 때, 전체 영상을 평균한 평균 얼굴로 영상들을 정규화하여 비유사도를 측정한다.

또한, 본 실험에서는 ED나 RD 등의 거리로 비유사도를 측정할 때 DTW기법만을 이용하여 영상 샘플들을 보정하여 분류한다(이하, 이 실험을 Ex-2로 표기한다).



그림 2. 서로 다른 방향을 응시하는 두 얼굴영상에서 굵은 수직선으로 표시된 수직벡터들 사이의 상관계수를 계산하는 예: (a) 좌측; (b) 중앙, 그리고 (c) 우측

Fig. 2. An example of computing the correlation coefficients between two column vectors marked with bold vertical bars of the two faces which are different from each other in their pose(directions): (a) left; (b) middle; and (c) right.

즉, Ex-2에서는 비유사도 거리를 측정할 때, 두 영상을 대상으로 수직벡터나 수평벡터 쌍으로 상관계수를 추정하여 최적 또는 준 최적 대응을 검색한다. 예를 들어, 서로 다른 방향의 두 얼굴영상 s 와 t 의 행벡터들 사이의 상관계수를 계산하는 예는 그림 2와 같다.

그림 2(a), (b), (c)에서 세 얼굴영상위에 굵은 수직선으로 표시된 벡터를 각각 x_{15} , x_{15} , x_{35} 로 표기한다. 여기에 $R=corrcoeff(s,t)$ 를 이용하여 추정된 상관계수 $\rho^1 = \rho(x_{15}, x_{15})$ 와 $\rho^2 = \rho(x_{15}, x_{35})$ 는 각각

$$\rho^1 = \begin{bmatrix} 1 & 0.1765 \\ 0.1765 & 1 \end{bmatrix}, \rho^2 = \begin{bmatrix} 1 & 0.7114 \\ 0.7114 & 1 \end{bmatrix}$$

이 된다. 즉, ρ^1_{xy} 와 ρ^2_{xy} 를 비교해 보면, 그림 2(a)의 수직 벡터 x_{15} 는 같은 위치에 놓인 (b)의 x_{15} 보다는 (c)의 x_{35} 에 대응되어야 함을 알 수 있고, 이는 시각적인 판단과도 일치한다. 따라서 본 실험에서는 DTW를 이용하여 먼저 x 축 방향(수평)으로 최적 대응경로를 추정한 다음, 다시 y 축 방향(수직)으로 최적 경로를 추정하여 방향 또는 크기가 다른 두 영상벡터의 비유사도를 산출한다.

끝으로, 본 실험에서는 먼저 ED와 DTW 또는, RD와 DTW로 거리를 측정하여 각각 비유사도 공간 $D^{(1)}$ 와 $D^{(2)}$ 를 생성한다. 그리고 이들 두 비유사도 공간을 퓨전기법(평균)으로 결합하여 새로운 하나의 비유사도 공간 $D^{(3)} = \alpha_1 D^{(1)} + \alpha_2 D^{(2)}$ 를 생성한 다음, 이 공간에서 분류실험(이하, Ex-3라 표기)을 수행한다. 여기서 α_1, α_2 는 두 공간의 결합비율이다.

본 실험에서는 Ex-1, Ex-2, Ex-3의 방법으로 생성한 비유사도 공간에서 각각 세 개의 베이스 식별기를 학습한 다음, 다시 고정결합과 학습결합으로 퓨전시킨 분류기의 성능을 실험한다. 이 때, 베이스 식별기로는 PRTools(<http://prtools.org/참조>)에 구현되어 있는 nearest mean classifier(nmc), linear Bayes normal classifier(ldc), k -nearest neighbor classifier(knnc)로 실험한다. 그리고 식별기 고정결합과 학습결합은 각각 product combining classifier(prodcc)와 mean combining classifier(meanc)로 실험한다.

또한, 본 실험에서는 분류기의 식별성능을 측정하기 위하여 leave-one-out (LOO)법을 이용한다. 즉, n 개의 학습 데이터 중에서 $n-1$ 개의 샘플을 이용하여 분류기

* <http://www.cl.cam.ac.uk/Research/DTG/attarchive/facedatabase.html>

** <http://www1.cs.columbia.edu/~belhumeur/pub/images/yalefaces>

를 학습하고, 나머지 1개로 식별성능을 측정한다. 이와 같은 실험을 모든 학습샘플에 대하여 반복(n 회 반복)하여 얻은 식별결과와의 평균으로 최종 성능을 측정한다.

3. 실험 결과 및 고찰

본 실험에서 DTW로 생성한 비유사도 공간을 퓨전기법으로 결합하여 새로운 식별공간을 생성한 다음, 이 식별공간에서 학습한 세 개의 베이스 분류기를 결합한 결합기의 식별성능을 실험하였다. AT&T, Yale, Yale2에 대해 Ex-1, Ex-2, Ex-3의 고정결합 및 학습결합 DBC의 분류성능(바르게 분류한 비율(%))과 표준편차를 LOO법으로 측정한 실험결과는 표 2와 같다.

표 2에서 영상데이터 AT&T에 대한 비유사도 측정법 ED의 경우, Ex-1, Ex-2, Ex-3에 대한 고정결합기 prodc의 식별률은 각각 95.10, 89.40, 97.00(%)를 얻었다. 이 결과는 Ex-3(RD거리와 DTW로 두 개의 비유사도 공간을 생성하여 결합하는 방법)의 식별률이 기존의

표 2. DTW-MFS법으로 학습한 결합 DBCs의 분류성능(%). 여기서 괄호 안에 표시한 숫자는 표준편차임

Table 2. Classification accuracies(%) of the combined DBCs built with the DTW-MFS method. Here, the numbers in the brackets are the standard deviations.

영상 데이터	비유사도 측정방법	비유사도 결합방법	결합 DBC의 분류성능	
			고정결합기	학습결합기
AT&T	ED	Ex-1	95.10(2.71)	95.10(2.71)
		Ex-2	89.40(5.62)	89.40(5.62)
		Ex-3	97.00(2.00)	97.00(2.00)
	RD	Ex-1	98.60(1.96)	98.60(1.96)
		Ex-2	93.90(4.33)	93.90(4.33)
		Ex-3	98.70(1.87)	98.70(1.87)
Yale	ED	Ex-1	92.56(3.70)	88.00(4.04)
		Ex-2	92.56(4.96)	87.00(4.96)
		Ex-3	93.56(3.13)	89.22(4.16)
	RD	Ex-1	94.67(3.18)	86.56(3.57)
		Ex-2	93.89(3.67)	87.11(3.86)
		Ex-3	96.33(2.63)	87.00(3.62)
Yale2	ED	Ex-1	80.67(4.73)	80.67(4.73)
		Ex-2	80.22(6.03)	80.11(5.97)
		Ex-3	81.33(5.32)	81.44(5.26)
	RD	Ex-1	86.27(4.06)	86.36(4.07)
		Ex-2	84.36(5.35)	84.36(5.45)
		Ex-3	87.09(3.00)	87.18(2.86)

Ex-1이나 Ex-2보다 우수함을 나타낸다. 같은 방법으로, AT&T의 RD의 경우, 최고 식별률은 98.70(%)이며, Ex-3로 부터 얻었다. 또한 나머지 실험데이터 Yale과 Yale2에서도 (굵은 글씨체로 표시한) 최고 식별률은 모두 Ex-3로부터 결과 되었음을 보인다. 이상에서 고찰한 바와 같이, 본 논문에서 제안한 DTW-MFS를 이용한 DBC의 실험(Ex-3)이 일반 DBC의 분류실험(Ex-1)이나 DTW를 이용하지 않는 분류실험(Ex-2)보다 우수하다. 따라서 제안한 방법이 DBC의 성능향상에 유용하다는 것을 알 수 있다.

표 2의 실험결과에서 얻을 수 있는 또 다른 고찰은 다음과 같다. 먼저, RD에 대한 Ex-3 실험결과는 모든 실험데이터에 대하여 ED의 결과보다 우수함을 보였다. 이와 같은 고찰로부터, RD의 측정법이 ED법보다 우수한 비유사도 측정법임을 알 수 있다. 또한 실험결과, 고정결합 (또는 학습결합) DBC의 식별성능은 학습한 베이스 분류기의 식별결과 중 가장 우수한 결과와 일치하였다. 따라서 제안방법에서 결합기는 하나의 선택기(selector) 역할을 하였고, 이로 인하여 분류시스템은 더욱 견고하게 되었음을 알 수 있다. 그리고 괄호 안에 표기한 표준편차는 비유사도 측정법과 결합방법에 따라 변화하였다. 그러나 Ex-3의 표준편차가 전체적으로 Ex-1이나 Ex-2 보다 적었으며, 이는 제안 방법이 시스템의 안정화에 기여함을 의미한다.

끝으로, 세 실험데이터 AT&T, Yale, Yale2에 대한 실험에서 ED 측정의 경우, 두 비유사도 공간(행렬)의 결합을 위한 결합비율 ($\alpha_1 : \alpha_2$)는 각각 (0.75 : 0.25), (0.55 : 0.45), (0.35 : 0.65)으로 하였다. 이와 같은 비율 선정은 실험적으로 이루어졌으며, 따라서 이를 자동화시키는 연구는 앞으로의 과제가 된다.

한편, 비유사도 공간을 생성할 때, 객체샘플이 훼손되거나 또는 샘플 자체의 특성으로 응용에 따라 공간 행렬이 비정의적(indefinite)인 특성을 갖게 된다는 최근 보고가 있다^[13]. 즉, 새로 생성된 (또는 결합된) 공간 행렬이 대칭특성이나 삼각부등(triangle inequality)의 메트릭을 만족하지 못하게 된다. 따라서 세 비유사도 공간을 의사 유클리드 공간(a pseudo-Euclidean space)으로 임베딩시키는 방법으로 식별성능을 더욱 향상시킬 수 있는 가능성이 있으며, 이를 구현하는 연구도 앞으로의 과제로 남게 된다.

VI. 결 론

본 논문에서는 멀티미디어 검색 등과 같은 고차원 분류문제에서 샘플벡터의 수가 벡터차원 보다 적은 경우에 발생하는 희소성 문제를 해결하기 위하여 비유사도 기반 분류기(DBC)의 성능개선 방법을 검토하였다. 특히, 본 논문에서는 비유사도 표현단계와 분류기 학습단계에서 동적시간교정법(DTW)과 다중퓨전기법(MFS)을 연속 적용하여 DBC를 최적화시키는 DTW-MFS 방법을 제안하였다. 제안 방법을 벤취마크 얼굴영상 데이터베이스를 대상으로 실험한 결과, 비유사도 식별단계에서의 결합뿐만 아니라 비유사도 표현단계에서 샘플영상의 방향과 크기를 조정된 다음 비유사도 표현을 결합시키는 DTW-MFS로 식별성능을 더욱 개선할 수 있음을 확인하였다. 따라서 본 논문의 DTW-MFS에 의한 DBC를 데이터 마이닝이나 멀티미디어 정보검색 등과 같은 고차원 패턴처리에 응용할 경우, 차원축소 문제를 획기적으로 단순화시킬 수 있고, 따라서 희소성 문제를 회피할 수 있을 것으로 사료된다.

본 논문에서는 DTW-MFS의 방법을 식별성능의 관점에서만 고찰하였다. 따라서, 앞으로 제안 방법을 실시간 멀티미디어처리에 응용할 수 있도록 처리시간을 분석하고, 이를 단축시키기 위한 연구가 필요하다. 또한, 본 논문에서는 ED와 DTW 또는 RD와 DTW로만 비유사도를 측정하였다. 따라서 해밍거리를 포함하여 다양한 거리측정법에 DTW를 적용하고, 더 나아가 ED와 RD의 결합에 DTW를 적용하는 연구는 앞으로의 과제이다. 그리고 비유사도 공간의 결합 비율을 자동적으로 선정할 수 있도록 하는 연구도 앞으로의 과제이다. 끝으로, 비유사도 공간을 결합할 때 발생하는 비정의적인 특성에 기인하는 문제를 해결하기 위하여 결합 비유사도 공간을 의사 유클리드 공간으로 임베딩시키는 방법에 관한 연구도 앞으로의 과제이다.

참 고 문 헌

- [1] K. Fukunaga, *Introduction to Statistical Pattern Recognition, Second Edition*, Academic Press, San Diego, 1990.
- [2] J. Ye, R. Janardan, C. H. Park and H. Park, "An optimization criterion for generalized discriminant analysis on undersampled problems," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 26, no. 8, pp. 982-994, 2004.
- [3] E. Pekalska and R. P. W. Duin, *The Dissimilarity Representation for Pattern Recognition: Foundations and Applications*, World Scientific Publishing, Singapore, 2005.
- [4] S. -W. Kim, "On solving the small sample size problem using a dissimilarity representation for face recognition," in *Proc. of Advanced Concepts for Intelligent Vision Systems*, Antwerp, Belgium, vol. LNCS-4179, pp. 1174-1185, 2006.
- [5] S. -W. Kim and J. Gao, "A dynamic programming technique for optimizing dissimilarity-based classifiers," in *Proc. of Joint IAPR International Workshops SSPR2008 and SPR2008 (SS+SPR2008)*, Orlando, USA, vol. LNCS-5342, pp. 664-673, 2008.
- [6] 김상운, 로버트 듀인, "다단계 퓨전기법을 이용한 비유사도 기반 식별기의 최적화," *대한전자공학회 논문지*, 제45권 CI편, 제5호, 15-24쪽, 2008년 9월
- [7] Y. Adini, Y. Moses, and S. Ullman, "Face recognition: the problem of compensating for changes in illumination direction," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 19, no. 7, pp. 721-732, 1997.
- [8] A. L. Ratan, W. E. L. Grimson, and W. M. Wells III, "Object detection and localization by dynamic template warping," *Int'l Journal of Computer Vision*, vol. 36, no. 2, pp. 131-147, 2000.
- [9] H. Sahbi and N. Boujemaa, "Robust face recognition using dynamic space warping," in *Proc. of Biometric Authentication*, vol. LNCS-2359, pp. 121-132, 2002.
- [10] L. I. Kuncheva, *Combining Pattern Classifiers - Methods and Algorithms*, John Wiley & Sons, New Jersey, 2004.
- [11] S. -W. Kim and B. J. Oommen, "On using prototype reduction schemes to optimize dissimilarity-based classification," *Pattern Recognition*, vol. 40, pp. 2946-2957, 2007.
- [12] J. Kim and J. A. Fessler, "Intensity-based image registration using robust correlation coefficients," *IEEE Trans. Medical Imaging*, vol. 23, no. 1, pp. 1430-1444, 2004.
- [13] R. P. W. Duin, E. Pekalska, A. Harol, W. -J. Lee, and H. Bunke, "On Euclidean corrections for non-Euclidean dissimilarities," in *Proc. of Joint IAPR International Workshops SSPR2008 and SPR2008 (SS+SPR2008)*, Orlando, USA, vol. LNCS-5342, pp. 664-673, 2008.

저 자 소 개

김 상 운(정회원)-교신저자
대한전자공학회 논문지
제45권 CI편 제5호 참조



김 승 환(정회원)-임시연구조원
2004년 9월~2009년 5월 캐나다
University of Waterloo,
Electrical Engineering
(Co-op program) 졸업.
<주관심분야: 패턴인식, 안테나설
계 연구>