

새로운 얼굴 특징공간을 이용한 모델 기반 얼굴 표정 인식

김 진 옥[†]

요 약

본 연구에서는 얼굴 그리드 각도를 특징공간으로 하는 새로운 모델 기반 얼굴 표정 인식 방법을 제안한다. 제안 방식은 6가지 얼굴 대표 표정을 인식하기 위해 표정 그리드를 이용하여 그리드의 각 간선과 정점이 형성하는 각도를 기반으로 얼굴 특징 공간을 구성한다. 이 방법은 다른 표정 인식 알고리즘의 정확도를 낮추는 원인인 변환, 회전, 크기변화와 같은 어파인 변환에 강건한 특성을 보인다. 또한, 본 연구에서는 각도로 특징공간을 구성하고 이 공간 내에서 Wrapper 방식으로 특정 부분집합을 선택하는 과정을 설명한다. 선택한 특징들은 SVM, 3-NN 분류기를 이용해 분류하고 분류 결과는 2중 교차검증을 통해 검증하도록 한다. 본 연구가 제안한 방법에서는 94%의 표정 인식 결과를 보였으며 특히 특정 부분집합 선택 알고리즘을 적용한 결과 전체 특징을 이용한 경우보다 약 10%의 인식율 개선 효과를 보인다.

키워드 : 얼굴 표정 인식, 특징 공간 생성, Wrapper 방식, 다중 교차검증

Model based Facial Expression Recognition using New Feature Space

Kim, Jin Ok[†]

ABSTRACT

This paper introduces a new model based method for facial expression recognition that uses facial grid angles as feature space. In order to be able to recognize the six main facial expression, proposed method uses a grid approach and therefore it establishes a new feature space based on the angles that each gird's edge and vertex form. The way taken in the paper is robust against several affine transformations such as translation, rotation, and scaling which in other approaches are considered very harmful in the overall accuracy of a facial expression recognition algorithm. Also, this paper demonstrates the process that the feature space is created using angles and how a selection process of feature subset within this space is applied with Wrapper approach. Selected features are classified by SVM, 3-NN classifier and classification results are validated with two-tier cross validation. Proposed method shows 94% classification result and feature selection algorithm improves results by up to 10% over the full set of feature.

Keywords : Facial Expression Recognition, Features Space Generation, Wrapper Approach, Multi-Tier Cross Validation

1. 서 론

사람과 컴퓨터간의 지능적 상호작용은 사람이 자연스럽게 컴퓨터를 이용하는 것을 목표로 발전하고 있다. 컴퓨터가 사람의 커뮤니케이션 기술로 사람과 의사소통하도록 하는 방법이 제시되고 있는데 이런 기술 중 하나가 사람의 감정 상태를 이해하는 능력이고 사람이 감정을 표현하는 가장 대표적인 방법은 얼굴 표정을 통해서이다[1]. 하지만 얼굴 표정을 해석하는 시스템을 개발하는 것은 어려운 일이다. 이를 위해서는 얼굴 표정 특징 추출과 얼굴 표정 분류, 두 가지 대표적 문제가 해결되어야 한다.

현재 표정 인식 알고리즘에서는 얼굴 표정을 해석하기 위해 고려하는 특징이 주로 눈, 입 그리고 이마와 같은 얼굴 영역으로 이 영역들은 얼굴 표정을 결정하는 대부분의 정보를 가지고 있다. 인터페이스 응용기술 측면에서 얼굴 특징 추출 시스템은 실시간에 낮은 비용으로 정확하고 강건하게 결과를 피드백해야 한다. 또한 특징 추출 시 특별한 조명이나 정적 배경조건 없이 얼굴이 보이도록 설정되어야 한다[2, 3].

얼굴 표정 추출 알고리즘들은 다양하며 또한 많은 차이점이 있지만 대부분의 표정 인식 알고리즘은 얼굴에서 표정을 추출하는 과정을 이미지 기반과 모델 기반, 두 가지 주요 분야로 나누어 인식한다[4]. 이미지 기반 방식은 관심 대상에 대한 구체적 지식에 의존하지 않고 이미지에서 특징을 추출하는 것으로 이 방식의 장점은 빠르고 간단하다는 점이다. 반면 데이터 이미지가 조명이나 시점 또는 머리자세 등으로 인해 다양해지면 이 방식은 산만해지거나 불만족스러

† 정회원: 대구한의대학교 국제문화정보대학 모바일콘텐츠학부 부교수
논문접수: 2010년 3월 11일
수정일: 1차 2010년 4월 13일
심사완료: 2010년 4월 13일

운 결과를 보인다. 한편 모델 기반의 방식은 얼굴의 주요 특징을 유지하는 모델을 적용, 얼굴 특징의 메타 데이터를 추출하여 이용한다. 모델기반의 기술이 신뢰성은 있지만 얼굴 모양과 표정의 범위를 맞추기 위해 얼굴 모델에 변형을 가하는 전처리 과정때문에 속도가 느려 실시간 환경에는 적합하지 않은 반면 이미지 기반 기술은 더 빠르지만 상대적으로 덜 정확하다. 다른 연구방식들은 이 두 가지 방식을 혼용하여 이용하고 있다.

추출된 얼굴 특징에서 표정 분류를 수행할 때 대표적으로 패턴, 신경망, 규칙기반 세 가지 분류 방법이 표정 인식에서 사용된다[5, 6]. 이 방법들의 대부분은 Ekman이 사람의 감정을 전달하기 위한 여섯 가지 주요 얼굴 표정을 이용한 감정 분류 방법을 따른다[7]. Ekman이 제안한 여섯 가지 표정은 분노, 놀람, 행복, 혐오, 두려움, 슬픔으로 이 표정을 통해 감정을 해석한다. 이외 무표정이 표정 변화의 기준치로 이용되고 있기 때문에 대부분의 얼굴 표정 인식 연구에서는 얼굴 표정을 대표적으로 6가지 표정과 무표정으로 설정한다.

본 연구에서는 새로운 모델 기반의 표정 인식 기술을 제안한다. 제안 방식은 표정 인식의 주요 고려 대상인 특징 공간을 새롭게 구축한다는 점에서 기존 연구와 차별성을 보이며 별도의 전처리 과정이 필요하지 않아 모델 기반 방식의 문제점인 느린 처리 단계를 개선한다. 제안 방법에서는 먼저 얼굴 그리드 모델을 이용하여 그리드의 간선사이에 형성된 각을 기반으로 특징 공간을 구축한다. 특징 공간을 이용하는 기존 표정 인식 방식들은 정점 위치를 특징으로 이용하거나[8] 정점간의 유클리디안 거리를 이용하여 특징 공간을 구축[9]하는데 이 방법들의 문제점은 전이, 회전, 확대/축소와 같은 기본적 어파인 변환에 강건하지 않고 특징 추출 과정 전에 정규화 단계를 필요로 한다. 이 문제를 개선한 제안 방법은 각도 데이터를 이용, 모든 종류의 변환에 대해 강건하게 대응함으로써 표정 특징 추출 기술 발전에 기여한다. 또한 제안 방법은 새로운 멀티모달 사용자 인터페이스 방법을 개발하는 얼굴 표정 인식 시스템을 구축하는데 필요한 효과적인 표정 분류방법을 보여준다. 제안 얼굴 표정 인식 시스템은 문자기반의 인터페이스에 통합하여 효과적인 상호작용을 도모할 수 있다. (그림 1)은 제안 얼굴 표정 인식 알고리즘의 프레임워크를 설명하고 있다.

본 연구는 2장에서 특징공간의 구축에 대해 다루고 제안

특징공간에 대해 기술한다. 3장에서는 얼굴 데이터에 적용된 표정 특징 선택과정과 본 실험에서 적용한 표정 분류기를 설명한다. 4장에서는 분류기가 분류한 표정 특징을 검증하는 과정과 표정 인식 결과를 제시한다. 마지막으로 5장에서는 결론을 정리하고 얼굴 표정 인식 영역에서 향후 계속되어야 할 연구를 기술한다.

2. 특징 공간 구축

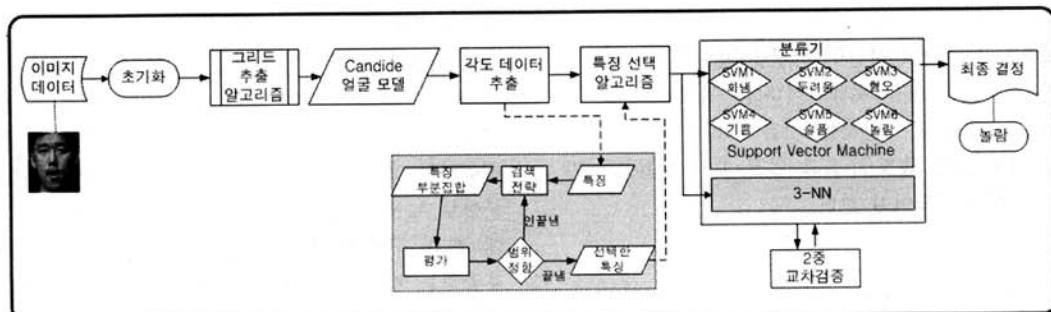
이 장에서는 제안 연구에서 이용하는 특징공간에 대해 설명한다. 먼저 얼굴에서 추출한 그리드를 제시하고 이 그리드에서 정점과 간선을 제거한 후 그리드를 간략화 시키는 방법과 그리드로부터 각도를 어떻게 계산하는지를 설명한 후 얼굴 표정 인식의 영역에서 특징 공간이 어떤 의미가 있는지를 제시한다. 특징 공간 구축을 위한 특징 선택 과정은 다음과 같다.

2.1 얼굴 그리드

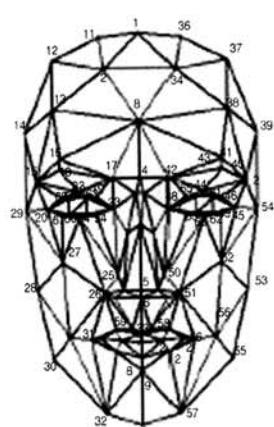
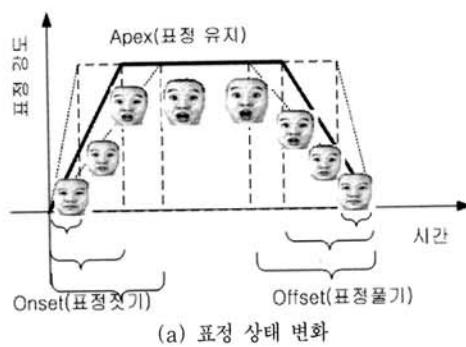
대부분의 표정 인식 알고리즘에서 일반적으로 취하고 있는 얼굴 표정 추출 방법들은 얼굴 표정이 동적이며 정적인 상태가 아니라는 사실을 기반으로 한다. 동적 변화과정은 (그림 2)-(a)에서 보여지는 것처럼 시간에 따라 onset(표정 짓기), apex(표정유지), offset(표정풀기), 이 세 가지 상태로 이루어진다[5].

제안 연구의 프레임워크에서 첫 번째 단계는 해당 얼굴에서 그리드를 추출하는 것이다. 이를 위해 (그림 2)-(b) Candide 얼굴 모델[10]을 이용한다. 원 Candide모델은 113개의 정점과 184개의 삼각형으로 구성된다. 그리드는 얼굴 표정의 각 정점에 두 개의 공간좌표를 할당하는데 얼굴마다 크기와 넓이가 달라 서로 다른 크기의 얼굴에 그리드를 적용하면 정점들이 완전히 다른 좌표의 시스템으로 변형될 수 있다. 이 문제는 보통 얼굴 크기를 정규화하여 해결하는데 [8] 본 연구에서는 우리가 사용하는 특징 공간인 정점의 각도로 인해 별도의 정규화 과정이 필요하지 않다.

얼굴 표정의 onset 상태에서 그리드의 7개 정점을 수작업으로 초기화한 후 Kanade-Lucas-Tomasi(KLT)[11]를 이용, 해당 노드 위치를 추적하여 표정 유지(apex)상태를 취한다. 이 과정에서 만들어진 메타데이터는 다음 처리 단계로 옮겨



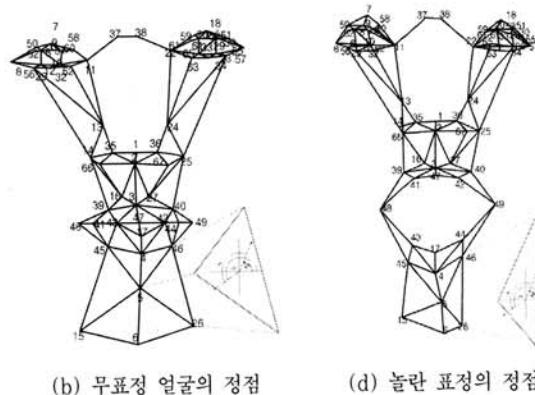
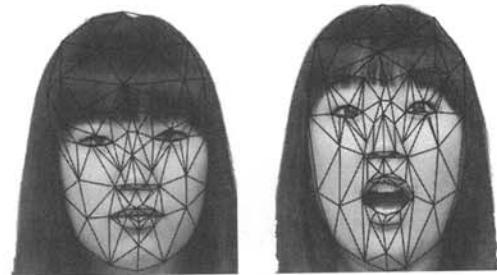
(그림 1) 얼굴 표정 인식 프레임워크



(그림 2) 표정 변화 상태와 Candide 모델

져 표정 인식에 무의미한 정점을 제외시킨다. (그림 3)과 같이 JAFEE[12]표정에 적용한 Candide 모델에서 표정 유지(apex)상태를 나타내는 정점은 눈, 코, 입 영역에 위치한 정점이므로 이 상태에서 FAU(Face Action Unit)에 기반한, 여섯개 대표 표정을 정의하는데 중요한 역할을 하는 정점만을 남기고 불필요한 다른 정점은 제거한다[13].

(그림 4)-(a)와 같이 무표정과 (c)의 놀란 표정에서 나타



(그림 4) 얼굴 표정을 평가하는데 사용하는 67개 정점

난 바와 같이 적용된 얼굴 표정의 의미 있는 영역은 입과 눈 주위 영역이다. (그림 4)의 (b), (d)가 보여주는 것처럼 이 영역에 해당하는 67개의 정점이 얼굴에서 얼굴 표정을 측정하는데 사용된다. 눈썹 역시 표정을 결정하는 중요한 얼굴 영역 중 하나이지만 머리카락 모양 때문에 눈썹을 가리는 경우가 많아 눈썹 부위는 배제한다.

얼굴 모양은 동일한 사람의 두 개 이미지에 대해 동일하다고 가정하고 얼굴 표정은 사용자의 무표정 이미지와 표정 짓고 있는 이미지간의 특징 매개변수인 정점간의 각도 변화로 나타낼 수 있다.

표정종류	무표정	화냄	혐오	두려움	기쁨	슬픔	놀람
표정 특징		입술 변화, 눈사이 거리 축소	입술 축소, 눈크기변화	눈과 입 크기 변화	입술 가로 및 세로확장, 눈크기변화	입술 끝 위치변화, 눈 축소	입술 세로 확장, 눈크기변화
표정							
Candide 모델							

(그림 3) 표정별 Candide 모델

2.2 각도 추출 과정

그리드 상의 정점에 대한 각도 추출 계산 과정은 그래프 이론을 바탕으로 한다. 방향이 없는 그래프에서 정점 d 의 크기는 이 정점을 향해 인접한 간선의 갯수이다. 방향이 없는 그래프의 인접 행렬 표현은 식 (1)과 같이 정의된다.

$$A(i,j) = \begin{cases} 1 & e_{ij} \in E \\ 0 & e_{ij} \not\in E \end{cases} \quad \text{식 (1)}$$

여기서 e_{ij} 는 정점 j 와 정점 i 를 연결하는 간선이다. 구축된 행렬은 대각대칭 행렬형태이다. A 를 그래프의 인접 행렬이라 하면 정점의 크기 d 는 식 (2)와 같이 정리된다.

$$d_i = \sum_{j=1}^n A(i,j) \quad \text{식 (2)}$$

n 은 해당 그래프에서의 정점 수이다. 그래프에서 형성된 각의 수는 정점에 인접한 간선에 대한 모든 조합의 합과 동일하다. d_i 을 이루는 간선에 인접한 정점 v_i 는 $C_2^{d_i}$ 각도를 형성한다. 그래서 식 (3)과 같이 그래프에서 형성된 전체 각의 수는 D 가 된다.

$$D = \sum_{i=0}^n C_2^{d_i} \quad \text{식 (3)}$$

D 는 그래프에서 추출한 전체 각의 수로써 D 각 수를 계산하기 위해 먼저 그리드의 간선으로 형성된 벡터를 계산해야 한다. 그리드의 간선 e_{ij} 는 각각 공간좌표 v_{i1}, v_{i2} 과 v_{j1}, v_{j2} 를 가진 두 개의 정점인 v_i 와 v_j 를 연결한 것이다. 벡터 x_p 는 식 (4)와 같이 두 개 정점의 좌표를 이용하여 만들어진다.

$$x_p = \begin{bmatrix} |v_{i1} - v_{j1}| \\ |v_{i2} - v_{j2}| \end{bmatrix} \quad \text{식 (4)}$$

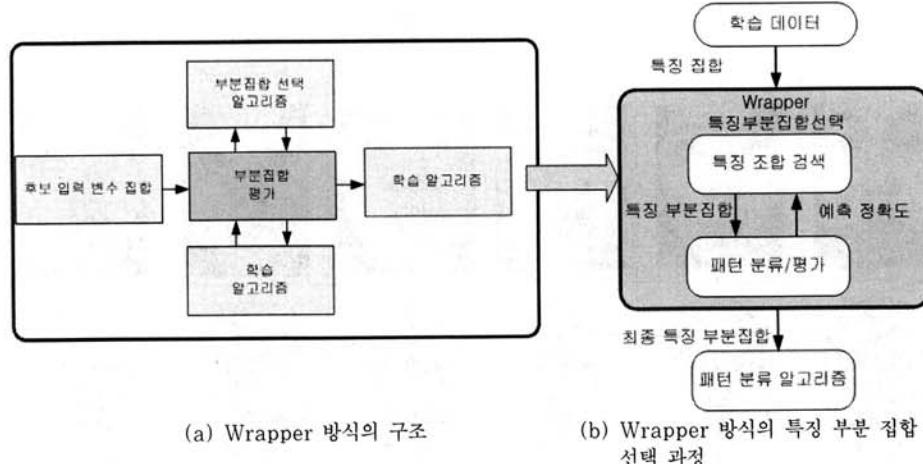
두 개 벡터 x_p 와 x_q 간의 각도의 크기는 (그림 4)-(b), (d) 간의 x 축을 중심으로 형성된 정점들의 각도의 차이와 같다. 그리드에는 π 보다 큰 각이 존재하기 때문에 두 벡터의 내적은 사용하지 않는다. 내적 식의 코사인 함수 때문에 잘못된 각도 계산이 나올 수 있기 때문이다. 대신 본 연구에서는 각도의 차이 값에 $\text{mod}(2\pi)$ 를 취하여 0과 2π 사이의 각도가 나오도록 한다.

표정 결정 영역의 그리드는 67개의 정점을 가지고 이 정점은 157개 간선을 갖는 그래프를 형성하므로 형성된 각도의 수는 총 642개가 된다. 이 각도가 특정 공간에서 각 특징 벡터의 크기이고 표정 특징을 결정하는 매개변수이다. 실제적으로 각도들의 많은 부분은 각도가 만들어 낸 삼각형 간의 관계를 이용하는 삼각함수의 탄젠트 각도로 계산하는데 642개 각을 처리 과정에서 모두 계산하는 것은 아니고 각도가 같은 삼각형도 있고 보각이거나 맞꼭지각 상태도 있으므로 이 각도간의 관계를 통해 필요한 값만을 효율적으로 계산하여 이용한다.

2.3 Wrapper 방식을 이용한 특징 선택

얼굴 표정에서 나타나는 642개 각도 중 대부분은 서로 강하게 연관되어 있어 특징이 다양하게 나타난다. 특징이 다양할수록 정보량이 많으며 정보량에 따라 분류 정확도가 달라진다. 본 연구에서는 모든 특징을 고려하기 어려워 특징 분류기의 성능을 최적화할 수 있도록 필요한 특징을 선택하는 과정을 먼저 수행한다.

본 연구에는 (그림 5)-(a)와 같은 Wrapper 접근 방식을 적용, 특징 선택 과정을 통해 특징 분류기의 성능을 최적화 한다[14]. Wrapper 방식은 필요한 특징 수를 줄이기 위해 먼저 특징들을 재정렬하고 (그림 5)-(b)와 같이 최적의 특징 부분집합에 대한 검색을 수행하기 위해 학습 알고리즘을 적



(그림 5) Wrapper 방식

용하여 적절한 부분집합을 선택하는 과정으로 이루어진다. 이 방식의 목적은 패턴 분류기에 적용하는 최적의 특징 집합을 선별하는 것으로, 분류기와 데이터 집합간의 특정 상호작용을 조정함으로써 더 나은 인식률을 보인다.

선택한 특징 부분집합의 유효성 결과는 교차검증 또는 통계적 리샘플링을 통한 테스트 데이터 인식률 즉 예측 정확도로 검증하여 훈련 집합에 적합한 분류기가 평가집합에서는 훈련 집합만큼의 성능을 보이지 않는 과적합(overfitting)을 피하도록 한다. 단 평가과정에서 사용되는 분류기의 편기 때문에 일반성이 부족한 단점은 여전히 있다.

본 연구의 경우 샘플의 크기와 다차원성간에 어느 쪽을 취할 것인가에 대해 고려해야 하기 때문에 Wrapper 방식의 특징 선택 알고리즘으로 특정 알고리즘을 한 가지 선택하는 대신 여러 가지 알고리즘 방식을 테스트하는 방법을 취한다. 그럼으로써 Wrapper 방식의 일반성 부족을 해결하여 본 연구의 일반적 성능을 설명할 수 있는 가장 적절한 접근방식을 찾도록 한다.

본 연구에서 적용한 특징 부분집합을 검색하여 선택하는 알고리즘 방식은 1) 최고 개별 순위(best Individual Ranking, IR)[15], 2) 연속적 진행 선택(Sequential Forward Selection, SFS)[16], 3)연속적 진행 부동 선택법(Sequential Forward Floating Selection, SFFS)[17] 세 가지이다. 특징들 간의 관계성은 고려하지 않는 IR은 최적 성능은 잘 나오지 않으나 불필요한 데이터까지 학습해 버리는 과적합(over fitting)에는 둔감하며, SFFS는 가장 강력하지만 과적합(over fitting)에 민감해 결과적으로 개별성을 보이는 데이터에 대해 낮은 검색 결과를 나타내는 단점이 있다. 이외에도 최적성능을 보이는 우수한 특징 선택 방법들이 있지만 차원은 높고 데이터 샘플 수는 적은 본 연구의 데이터 타입에 적용하기 어려워 위에서 제시한 3가지 방식만을 적용한다.

선택한 알고리즘에서는 결과로 산출되는 특징 수를 선택하여 분류 정확도를 최대화하도록 한다. IR의 경우 각 특징을 개별적으로 평가하여 개별 값에 따라 특징을 내림차순으로 순위를 매긴 다음 $d \in \langle 1,642 \rangle$ 에 해당하는 첫 번째 d 특징의 각 부분집합을 평가한다. SFS와 SFFS의 경우에는 전체 차원에 도달할 때까지 알고리즘을 실행해 검색과정을 통해 중간 결과를 모두 저장한 후 가장 관련 있는 범위 값의 부분집합을 선택한다. SFS는 탐욕 알고리즘으로 빈 집합부터 시작해 이미 선택된 특징과 조합되었을 때 가장 높은 목적 함수 결과를 보이는 특징을 순차적으로 추가하고 SFFS는 빈 집합으로 시작해 각 순차 단계에서 최적 특징을 선택한 후 그 전 단계로 돌아가 최악의 특징을 선택하여 제거한다.

3. 표정 분류

본 연구에서는 6가지 주요 표정을 클러스터링하기 위해 사용하는 분류기로 벡터 머신 프레임워크(SVM)을 근간으로 하는 선형커널(Linear Kernel) 및 방사기저함수(Radial Basis Function) 두가지 방식과 3단계 최근접(3-Nearest Neighbor,

3-NN) 방식을 이용하여 제안 방법을 테스트한다. SVM과 3-NN 방식은 입력 매개변수와 출력 매개변수값이 [0,1]사이에 있을 때 최대성과를 내므로 모든 데이터 값을 [0,1]로 크기를 맞춘다.

SVM 방식을 이용한 학습과 테스트를 위해서는 일반적인 LibSVM 라이브러리[18]를 이용한다. SVM 성능은 매개변수 결정에 영향을 받기 때문에 데이터의 임의 부분집합에 기반한 값 범위에 단순 그리드 검색을 수행하면서 각 커널에 대해 한번만 SVM 매개 변수를 정한다.

3-NN 분류기는 일반적인 다수 투표(voting)방식을 이용하여 데이터의 범주가 결정되면 가장 많이 도출된 범주가 전체 범주가 되는 방식을 취한다. 분류할 각 샘플에 대해 3 개의 최근접 거리에 위치한 이웃 데이터를 확인하여 이웃이 많은 클래스로 할당한다. 데이터를 클러스터링 할 때는 먼저 도착한 데이터가 먼저 서비스를 반도록 처리한다.

4. 실험 결과

본 연구에 대한 실험은 특정 선택 결과를 평가한 후 전체 데이터 집합에서 분류기를 훈련한 훈련과 검증 데이터 외 별도의 데이터를 대상으로 분류 성능을 평가하도록 한다.

4.1 실험 데이터

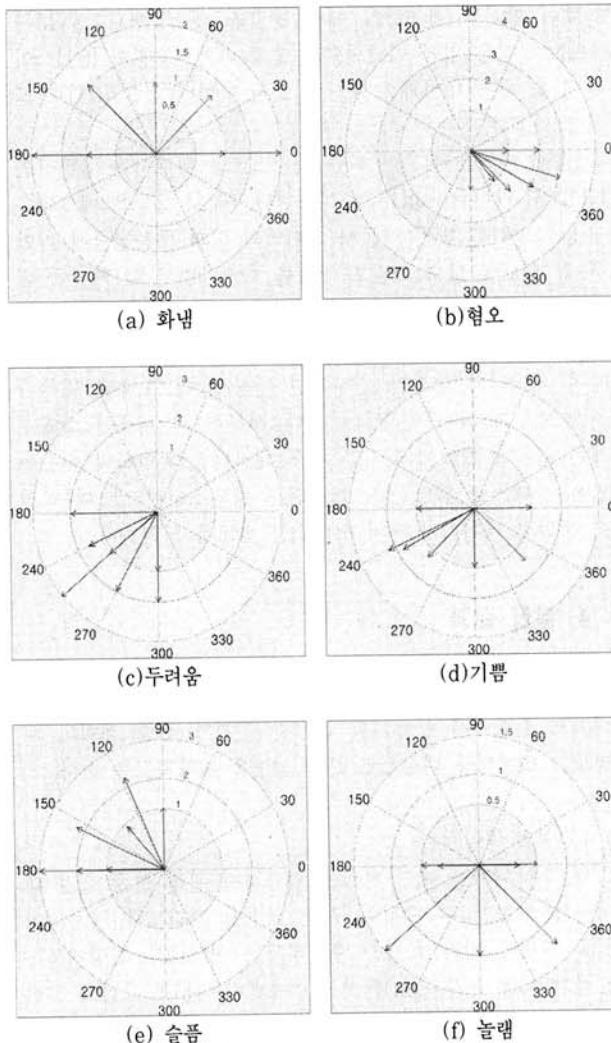
본 연구에서는 제안 방법을 검증하기 위해 얼굴 표정 데이터를 수집한 후 수집한 얼굴 표정에 그리드를 적용하여 얼굴 표정에 따라 특징을 추적하도록 한다[12]. 실험에서는 표정의 표정 유지(apex)단계를 이용한다. 440개 그리드 모델을 구축하여 35개는 화난 표정, 35개는 지루한 표정, 55개는 두려움, 90개는 기쁨, 65개는 슬픔, 70개는 놀란 표정에 대해 그리드 모델을 적용한다. 나머지 90개는 무표정에 대해 적용한다.

4.1.1 볼록 데이터 형태

2장에서 설명한 특징 공간은 주어진 두 개 벡터간의 각도를 통해 이루어지는데 (그림 6)과 같이 6개 주요 표정별로 특징 공간을 결정하는 주요 벡터들의 특성이 다르게 나타난다. (그림 6)의 각 특징 벡터는 눈과 눈 사이, 눈과 입 사이, 코와 입 사이, 입 양끝 사이, 입과 턱 사이간의 벡터이다. 두 특징 벡터 간의 각 θ 의 각도는 오목 또는 볼록 형태로 나타날 수 있다. 이 때 각도 데이터가 볼록 형태로 정규화 되면 분류 성능이 개선 가능하다. 180도가 넘는 크기의 내각을 갖지 않는 다각형이 볼록다각형이므로 모든 특징 각도 값에 식 (5)와 같은 변환을 적용하면,

$$\text{만약 } \theta > \pi \text{라면 } \theta = 2\pi - \theta \quad \text{식 (5)}$$

각도 데이터는 볼록 형태로 만들어진다. 특징 선택 방법을 적용한 대부분의 분류기에서 데이터의 볼록 형태는 분류 정확도를 더 높이도록 해 준다[18].



(그림 6) 표정별 주요 특징의 평균 각도 벡터

4.2 2중 교차 검증

데이터 집합의 다차원성 대비 사용 가능한 샘플 수의 비율이 클수록 어려운 문제를 훈련하는 분류기를 더 신뢰성있게 한다. 또한 분류기 구축과 특징 선택 방법은 과도한 훈련의 위험을 막으면서 수행되어야 한다[19]. 본 연구에서는 다양한 특징 선택을 테스트하고 훈련 데이터 외 익숙하지 않은 데이터에서도 분류기 성능이 유지될 수 있도록 분류기 생성

<표 1> 실험 데이터 집합

데이터 집합	표정 데이터 수
훈련	300
테스트	140

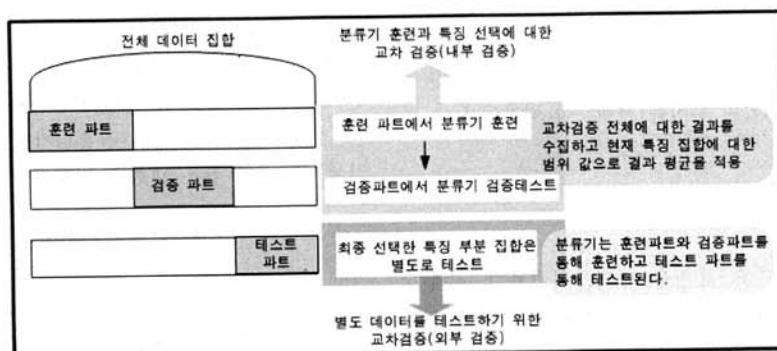
능력에서 가능한 한 특징 선택 결과를 더 정확하게 평가하기 위해 2중 교차 검증을 수행한다. 특징 선택에 적용한 데이터 집합은 <표 1>과 같으며 교차 검증 과정은 (그림 7)과 같다.

먼저 전체 데이터 집합을 3개 파트 즉, 훈련, 검증, 테스트 파트로 나눈다. 훈련 파트는 훈련하는데 사용되는 데이터로 분류기 매개변수 수와 맞춘다. 검증 파트는 분류기의 매개변수를 조정하는데 사용되는 데이터 집합이다. 테스트 파트는 일차 검증으로 훈련된 분류기의 성능을 테스트하고 확인하는데 사용한다. 훈련파트로는 분류기를 훈련시키고 검증 파트를 통해 같은 데이터로 훈련한 분류기를 검증한 다음 데이터 특징 집합에 대한 범위 값으로 특징 데이터 평균값을 산출한다. 교차 검증을 한 분류기는 테스트 파트 데이터를 통해 2중으로 한번 더 테스트한다. 각 검증 과정에서는 오류율이 결과 값으로 산출되는 데 전체 교차검증 후 실제 오류 E 는 테스트를 담당한 두 개의 데이터 파트에 대한 평균 오류율 $E = \frac{1}{N} \sum_{i=1}^N E_i$ 이 되므로 2중 교차 검증의 경

우 개별 검증 단계에서 산출된 오류율을 2로 나누어 더해 전체 평균율을 계산하면 이 결과가 특징 데이터를 분류하는 분류기의 성능이 된다. 본 연구에서는 내외부 교차 검증 과정을 각각 3번씩 수행한다. 더 상세하게 데이터 집합을 나누어 더 많이 테스트 할수록 더 많은 계산시간 비용이 소요된다.

4.2.1 편기 감소(bias reduction)

특징 부분 집합 선택 시, 분류기의 훈련과 검증과정에 적용한 표정 데이터가 원래 표정 모집단과 달라 나타나는 편기로 인해 분류기를 통해 출력되는 출력 값의 기대치에 그 영향이 반영될 수 있으므로 이 편기 오차를 줄이는 과정이 필요하다[20]. 특징 선택 과정을 통해 구한 특징으로 훈련 파트에서 훈련받은 분류기는 검증 파트에서도 테스트를 하고 훈련 파트에서도 다시 테스트한다. 이 때 테스트한 각 파트별 분류기의 정확도 차이를 편기 오차 예측치라고 간주한다. 일차 교차 검증 과정 후 특징 선택 범위 값을 결정하기 전에 다



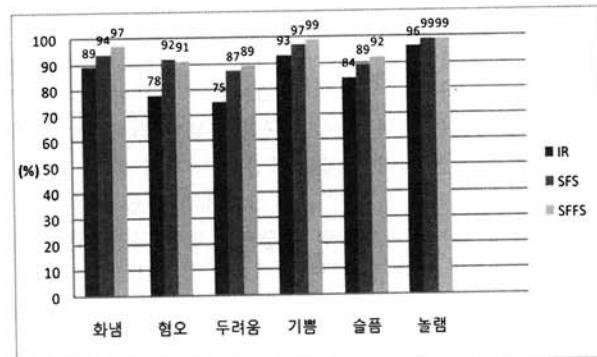
(그림 7) 2중 교차 검증 과정

시 한번 훈련과 검증 파트를 이용하여 분류기를 훈련시키고 테스트한 후 산출한 분류기의 정확도에서 평균 편기 오차 예측치를 감소시켜 현재 특징 부분집합의 범위 값을 정하도록 한다. 이렇게 하면 편기 오차가 감소되어 2중 교차 검증에서 특히 규모가 작은 데이터 샘플로 인한 오류를 줄일 수 있다.

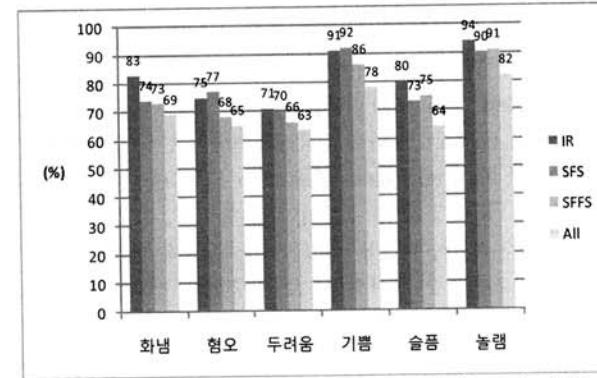
4.3 결과

본 연구를 통해 획득한 표정 분류 결과를 <표 2>와 같이 정리한다. 두 가지 분류기와 세 가지 특징 선택 방법을 통해 분류기의 정확성을 설명하고 있다. 내부 교차 검증의 경우 전체 데이터에서 훈련에 사용된 데이터를 대상으로 하고 외부 교차 검증은 훈련데이터와 테스트 데이터 전체를 대상으로 한다. 특징 선택 최적화 과정의 결과인 정확도는 특징 선택 방법을 통해 나타난 최고 Wrapper 범위 값을 이용하여 분류기를 통해 표정 분류를 한 결과이다. 내부 교차 검증을 통해 선택된 특징 결과는 익숙하지 않은 데이터에 대해서는 편기되어 있어 편기되지 않은 예측치를 얻기 위해 외부 교차 검증을 수행한다. 외부교차 검증한 결과 최고 분류 정확도는 85.1%로서 선형 커널 SVM와 IR 특징 선택 방법을 적용했을 때 가장 높은 결과를 보인다. Wrapper 특징 선택 과정을 통해 획득한 최고 정확도는 94.5%로 내부 교차 검증 과정에서 커널 SVM과 SFFS 방법을 이용했을 때이다. 익숙한 얼굴 데이터를 대상으로 하는 내부 교차검증에서는 SFFS를 이용한 결과와 같이 의미있는 주요 특징으로도 표정 분류가 정확하게 이루어지지만 생소한 얼굴 데이터를 분류 대상으로 하는 외부 교차검증의 경우 많은 특징을 선택하는 IR 특징선택 방법이 더 유효하다. 특징 선택 방법으로 특징을 선택하여 표정을 분류한 결과 모든 특징을 이용한 것보다 약 10% 정확도가 상승하여 정확한 특징을 선택해서 분류한 결과가 더 나음을 알 수 있다.

각 표정 인식 결과는 (그림 8)과 같다. (a)는 IR, SFS, SFFS를 특징 선택방법으로 하고 선형 커널 SVM 분류기를 이용하여 내부 검증으로 표정을 인식한 결과이고 (b)는 특징 선택 방법에 전체 표정 특징을 포함하여 3-NN 분류기로



(a) 선형커널 분류기를 이용한 표정 인식 결과 (내부 검증)



(b) 3-NN분류기를 이용한 표정 인식 결과 (외부 교차 검증)

(그림 8) 검증 방법 및 분류기 별 표정 인식 결과

외부 교차 검증하여 감정을 인식한 인식률 결과이다. 전반적으로 내부 검증 결과가 더 나은 인식 결과를 보임을 알 수 있다. 전체 특징을 모두 사용하여 외부 검증한 경우가 가장 낮은 인식 결과를 보인다.

5. 결 론

본 연구에서는 얼굴 표정 이미지에 그리드 추출과 CANDIDE

<표 2> 실험 결과

분류기	특징선택 방법	내부 교차 검증 (특징 선택 최적화 범위)		외부 교차 검증 (별도 테스트)		선택된 특징 크기	
		평균 분류 정확도(%)	표준편차	평균 분류 정확도(%)	표준편차	평균	표준편차
3-NN	IR	84.3	1.48	82.3	3.22	78	17.1
	SFS	94.2	0.39	79.3	4.78	59.3	4.1
	SFFS	92.3	2.18	76.5	3.54	25.3	2.1
	모든 특징	-	-	70.2	4.57	642	-
선형커널 SVM	IR	85.8	0.98	85.1	0.36	57.3	11.8
	SFS	93	1.58	81.1	2.42	41	9.2
	SFFS	94.5	0.73	82.5	2.53	26.3	5.2
	모든 특징	-	-	74.8	2.86	642	-
RBF SVM	IR	78	1.40	79.1	2.50	281	53.5
	SFS	80.8	4.58	73.6	1.73	58.3	1.7
	SFFS	91	1.34	76.8	4.22	41.3	1.7
	모든 특징	-	-	76.5	4.23	642	-

모델을 적용, 그리드 간선과 정점의 각도를 이용해 새로운 특징공간을 구성함으로써 자동으로 얼굴 표정을 인식하는 기술을 제안한다. 본 연구에서 제안하는 모델방식의 얼굴 표정 인식 방식은 빛과 자세 정규화 단계가 없어 모델방식의 문제점인 느낌 처리 단계를 개선한다. 특히 본 연구에서 적용한 각도 데이터 특징 공간은 모델기반의 얼굴 표정 인식 방법에서 제시되지 않았던 특징으로 얼굴 표정 이미지의 회전, 변환, 크기 변화 등 어파인 변환에 강건하다.

얼굴에서 각도 데이터를 추출하기 위해 얼굴 표정에 Candide 모델을 이용하여 표정 그리드를 추출한다. 그 다음 그래프 이론을 바탕으로 그리드의 정점 벡터간의 각도를 계산하여 이 각도를 특징 공간으로 구성한다. 너무 많은 각도 매개 변수를 줄이기 위해 Wrapper 방식을 이용, 표정을 결정하는 특정 부분집합을 선택한다. Wrapper 방식에서 특징을 검색하여 선택하는 방법으로 IR(Best Individual Ranking, IR), 연속적 진행 선택(Sequential Forward Selection, SFS), 연속적 진행 부동 선택법(Sequential Forward Floating Selection, SFFS)을 적용한다. 분류기로는 SVM과 3-NN을 선택하여 각 분류기별로 각각의 특징 선택 방법을 적용하여 특징 데이터를 분류하도록 한다.

분류 결과는 2중 교차검증으로 검증하여 전체 표정 데이터를 훈련, 검증, 테스트 파트로 나눈 후 분류기를 훈련, 검증 파트에서 훈련시킨 후 테스트 파트에서 그 결과를 테스트하도록 한다. 실험 결과, SVM 분류기와 SFFS 특징 선택 방법이 평균 94%의 분류율로 가장 좋은 결과를 보여준다. 향후에는 각도 특징 공간 외 다른 특징 공간을 구성하여 더 다양한 특징공간을 통해 정확하고 빠른 얼굴 표정 인식에 대한 연구를 지속할 계획이다.

참 고 문 헌

- [1] M. Turk, M. Kolsch, "Perceptual Interfaces," Emerging Topics in Computer Vision, Prentice Hall, 2005.
- [2] W. Zhao, R. Chellappa, P. J Phillips, A. Rosenfeld, "Face Recognition: A Literature Survey," ACM Computing Surveys, Vol.35, No.4, pp.399-458, 2003.
- [3] "빛 보상과 외형기반의 특징을 이용한 얼굴 특징 검출", 한국인터넷정보학회논문지, 7권 3호, pp.143-153, 2006.
- [4] M. Partic, L. J. M. Rothkrantz, "Automatic analysis of facial expressions: the state of the art," Pattern Analysis and Machine Intelligence, IEEE Transactions on, Vol.22, No.12, pp.1424-1445, 2000.
- [5] I. Cohen, F. G. Cozman, N. Sebe, M. C. Cirelo, T. S. Huang, "Semi-supervised Learning of Classifiers: Theory, Algorithms and their Applications to Human-Computer Interaction," IEEE Trans. on PAMI, Vol.26, pp.1553-1567, 2004.
- [6] 김진옥, "상황에 민감한 베이지안 분류기를 이용한 얼굴 표정 기반의 감정 인식", 한국정보처리학회논문지B, 13-B권, pp.653-662, 2006.
- [7] P. Ekman, "Facial expression and emotion," Personality: Critical Concepts in Psychology, Vol.48, pp.384-92, 1998.
- [8] I. Kotsia, I. Pitas, "Facial Expression Recognition in Image Sequences Using Geometric Deformation Features and Support Vector Machines," IEEE Trans. on Image Processing, Vol.16, No.1, pp.172-187, 2007.
- [9] K. Kahler, J. Haber, H.P. Seidel, "Geometry based Muscle Modeling for Facial Animation," Proceedings of Graphics Interface 2001, pp.37-46, 2001.
- [10] M. Rydfalk, "Candide: a parameterised face," Linkoping University, 1978.
- [11] C. Tomasi, T. Kanade, "Detection and Tracking of Point Features," Carnegie Mellon University Technical Report CMU-CS-91-132, 1991.
- [12] Michael J. Lyons, Shigeru Akamatsu, Miyuki Kamachi, Jiro Gyoba, "Coding Facial Expressions with Gabor Wavelets," Proceedings of third IEEE International Conference on Automatic Face and Gesture Recognition, pp.200-205, 1998.
- [13] G. Donato, M.S. Bartlett, J.C. Hager, P. Ekman, T.J. Sejnowski, "Classifying Facial Actions," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.21, No.10, pp.974-989, 1999.
- [14] R. Kohavi, G. H. John, "Wrappers for Feature Subset Selection," Artificial Intelligence, Vol.97, No.1-2, pp.273-324, 1997.
- [15] C. Schmidt, J. Brankel, S. E. Chick, "Integrating Techniques from Statistical Ranking into Evolutionary Algorithms," Lecture Notes in Computer Science, Vol.3907, pp.752-763, 2006.
- [16] P. A. Devijver, J. Kittler, "Pattern Recognition: A Statistical Approach," Prentice Hall, 1982.
- [17] P. Pudil, J. Novovicova, J. Kittler, "Locating Search Methods in Feature Selection," Pattern Recognition Letter, Vol.15, No.11, pp.1119-125, 1994.
- [18] C. Chang, C. Lin, LIBSVM: a library for support vector machines, <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>, 2009.
- [19] J. Reunanen, "Overfitting in Making Comparisons between Variable Selection Methods," Journal of Machine Learning, Vol.3, pp.1371-382, 2003.
- [20] D. J. Hand, H. Mannila, Padhraic Smyth, "Principles of Data Mining," MIT Press, 2001.



김 진 옥

e-mail : bit@dhu.ac.kr

1989년 성균관대학교(학사)

1998년 성균관대학교(석사)

2002년 성균관대학교 전기전자및컴퓨터공학
과(박사)

1992년~1994년 현대전자산업(주) 정보통신
사업부

1994년~1999년 현대정보기술(주) 인터넷사업부

2004년~현 대구한의대학교 국제문화정보대학 모바일콘텐츠
학부 부교수

관심분야: 멀티미디어공학, 패턴인식, 영상처리, 유비쿼터스 컴퓨
팅, 웹서비스 등