

얼굴 표정 인식을 위한 방향성 LBP 특징과 분별 영역 학습

강현우[†], 임길택^{**}, 원철호^{***}

Learning Directional LBP Features and Discriminative Feature Regions for Facial Expression Recognition

Hyunwoo Kang[†], Kil-Taek Lim^{**}, Chulho Won^{***}

ABSTRACT

In order to recognize the facial expressions, good features that can express the facial expressions are essential. It is also essential to find the characteristic areas where facial expressions appear discriminatively. In this study, we propose a directional LBP feature for facial expression recognition and a method of finding directional LBP operation and feature region for facial expression classification. The proposed directional LBP features to characterize facial fine micro-patterns are defined by LBP operation factors (direction and size of operation mask) and feature regions through AdaBoost learning. The facial expression classifier is implemented as a SVM classifier based on learned discriminant region and directional LBP operation factors. In order to verify the validity of the proposed method, facial expression recognition performance was measured in terms of accuracy, sensitivity, and specificity. Experimental results show that the proposed directional LBP and its learning method are useful for facial expression recognition.

Key words: Directional Local Binary Pattern, Facial Expression Recognition, AdaBoost Learning, Support Vector Machine

1. 서 론

얼굴 표정은 사람의 감정과 의도를 드러내는 중요한 정보이며 표정의 자동인식은 사람과 로봇의 상호 작용, 컴퓨터애니메이션, 비즈니스를 위한 고객 분석 등 다양한 분야에서 활용되는 기술이다. 표정 인식은 눈, 입 등 얼굴을 구성하는 기하 특징 요소를 분석하는 방법[1,2]과 얼굴 영역에 적절한 필터를 적용하여 얼굴의 외양 영상 변화를 활용하는 방법[3-7]이 있다. 얼굴 특징점의 위치를 검출하고 움직임 분석하

여 표정을 인식하기 위해서 ASM(Active Shape Model), AAM (Active Appearance Model)[8]을 적용하는 것이 일반적이다[1][8]. 이 방법의 경우 얼굴 특징점을 정확하게 검출한다면 인식률이 높을 수 있다. 하지만 실제의 경우 많은 상황에서 얼굴 특징점 검출 정확도가 낮아지는 문제점이 있다. 최근의 얼굴 표정 인식에는 외양 영상 기반의 방법이 많이 적용되고 있다. 특히 얼굴 영상을 LBP(Local Binary Pattern)[10] 특징으로 표현하고 SVM[11], AdaBoost [12] 등의 분류 기법을 적용하는 연구들이 우수한 인

* Corresponding Author: Hyunwoo Kang, Address: (42994) 1, Techno sunhwan-ro 10-gil, Yuga-myeon, Dalseong-gun, Daegu, Korea, TEL: +82-53-670-8028, FAX: +82-53-670-8008, E-mail: hwkang@etri.re.kr
Receipt date: Mar. 24, 2017, Revision date: Apr. 14, 2017
Approval date: Apr. 24, 2017

[†] Smart Vision Research Section, ETRI

^{**} Smart Vision Research Section, ETRI
(E-mail: ktl@etri.re.kr)

^{***} Dept. of Biomedical Engineering, Kyungil University
(E-mail: chulho@kiu.ac.kr)

식 성능을 보여주고 있다. LBP 분석 방법은 Ojala 등에 의해 제안된 이후 연산이 간단하면서 조명 변화에 강인하고, 물체를 분별력이 높게 표현 가능한 장점이 있어 얼굴 인식, 표정 인식 등에 많이 사용되고 있다. LBP는 어떤 픽셀과 그 주변 픽셀들의 밝기값의 차이로서 계산되는데 해당 픽셀의 지역적 특성을 표현한다. LBP 특징은 픽셀단위로 사용되지 않고 다수의 픽셀을 포함하는 부분영역단위로 사용되는 것이 일반적이다. 얼굴 영상으로부터 추출된 LBP 맵을 다수의 부분영역으로 분할하고 각 부분영역별로 LBP 특징값들을 히스토그램함으로써 부분영역별 특징벡터를 구성하고 이를 분류기의 입력으로 활용한다. 또한 응용 분야에 따라 LBP 연산 방법을 변형한 CS-LBP(Center-Symmetric LBP)[13], 멀티스케일 LBP[6], Differential LBP[7] 등 다양한 수정 LBP가 제안되고 있다.

본 연구에서는 얼굴 표정 인식을 위한 방향성 LBP 특징과 표정 분별에 용이한 방향성 LBP 연산과 특징 영역을 찾는 방법에 대해서 제안한다. 방향성 LBP는 수직, 수평, 대각선 방향 등 다양한 방향의 미세패턴을 잘 묘사할 수 있으며, LBP 연산 마스크의 크기, 즉 LBP 연산의 범위를 변경함으로써 다양한 범위의 지역적 특성도 추출할 수 있다. 본 연구에서는 학습을 통하여 표정의 분별이 잘 되는 특징 영역과 방향성 LBP 연산 인자(연산 마스크의 방향과 크기)를 정의한다. 얼굴 표정 분류기는 학습된 분별 특징 영역과 방향성 LBP 연산 인자에 기반하여 SVM 분류기로 구현한다. 제안 방법의 유효성을 검증하기 위하여 정확도(accuracy), 민감도(sensitivity) 및 특이도(specificity) 관점에서 네 가지 종류의 얼굴 표정 인식 성능을 측정하였다. 실험 결과 제안한 방향성 LBP와 분별 영역 학습 방법이 얼굴 표정 인식에 유용함을 확인할 수 있었다.

본 논문의 구성은 다음과 같다. II장에서는 얼굴 표정 인식을 위한 영상 표현 특징과 분류기 등 기존의 관련 방법에 대해서 설명한다. 제안하는 방향성 LBP 특징과 특징 영역 학습을 이용한 표정 분류 방법에 대해서는 III장, 실험 결과에 대해서는 IV장에서 설명한다. 마지막으로 V장에서 결론을 맺는다.

2. 얼굴 영상 표현 특징 및 분류기

2.1 LBP(Local Binary Patterns)를 이용한 표정 인식

Ojala에 의해 소개된 LBP는 물체에 대한 높은 식별능력과 조명 변화에 대한 강인성이 있으며 간단한 연산 때문에 영상인식 분야에 다양하게 적용되고 있으며 최근에는 표정 인식에 사용되고 있다[5-7]. 또한 LBP 히스토그램이 얼굴인식 분야에 널리 사용되면서 조명변화에 강인한 특성을 이용한 인식 방법이 연구되고 있다.

LBP 연산은 식 (1)과 같으며 현재 위치의 화소와 이웃 화소화의 차이를 0과 1로 나타낸다. 여기서 P, R, g_c, g_p 는 각각 인접 화소의 수와 원의 반경, 현재 화소, 이웃화소를 의미한다. Fig. 1에 LBP 연산 결과의 예를 그림으로 나타내었다.

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{p-1} s(g_p - g_c)2^p, s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (1)$$

LBP 연산 후의 LBP 인덱스는 해당 픽셀의 지역적 특징을 나타내며 얼굴 표정 분류를 위한 특징으로 유용하다. 얼굴 표정 분류기의 입력으로 사용되는 특징 벡터는, LBP 맵의 부분영역별로 LBP 인덱스 히스토그램을 계산한 후 히스토그램값들을 연결함으로써 구성된다[7]. LBP 특징벡터를 사용하는 대표적 분류 방법으로 템플릿 매칭 분류기와 SVM 분류기가 있다. 템플릿 매칭 유사도 측정에 사용되는 χ^2 방법[5]은 식 (2)와 같이 표현된다. 이 식에서 S, M 은 두 개의 LBP 특징 히스토그램 벡터이며 w_j 는 부분영역 j 의 가중치로 값이 클수록 유사도 측정에 중요한 부분영역으로 고려된다. 눈이나 입을 포함하는 부분영역의 가중치를 크게 하면 보다 나은 결과를 얻을 수 있다.

$$\chi_w^2(S, M) = \sum_{i,j} w_j \frac{(S_{i,j} - M_{i,j})^2}{S_{i,j} + M_{i,j}} \quad (2)$$

SVM은 데이터 분류를 위한 강력한 기계 학습 기법으로서 기본적으로 두 개의 클래스를 분류하는 분류기이다. SVM은 서로 다른 클래스의 샘플 벡터들

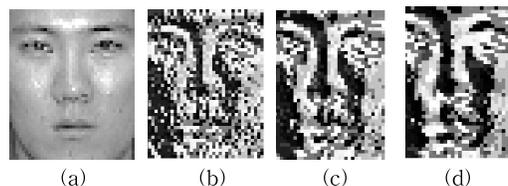


Fig. 1. Results of LBP operation, (a) original image (b) R=1 (c) R=2 (d) R=3.

을 분리하는 결정 경계면과 샘플 벡터들과의 거리가 최대가 되도록 하는 샘플 벡터들, 즉 서포트 벡터들을 찾고, 서포트 벡터들의 선형 가중합으로써 클래스 분리 경계면을 구한다[11]. SVM은 이진 분류기지만 다양한 표정의 분류를 위해서는 멀티 클래스 분류가 필요하며 이를 위해 본 연구에서는 One-against-all 방법을 사용한다. One-against-all 방법은 이진 분류 모형을 이용하여 다중 분류 문제를 해결하기 위해 사용된 방법이다[13]. k 개의 클래스를 분류하는 문제에 이 방법을 적용하면, k 개의 이진분류모형을 이용하여 i 번째 모형에서 분류결과에 따라 i 에 소속되는 데이터와 i 의 다른 클래스에 소속되는 데이터로 분류하는데, 동일한 단계를 k 번 학습한 다음 분류 단계에서 입력영상과 k 개의 이진분류 모형 중 가장 큰 거리값을 가지는 이진 분류모형의 표정으로 출력이 결정된다.

2.2 CS-LBP와 Differential CS-LBP

LBP가 얼굴인식에 널리 사용되면서, 여러 가지 방법으로 다양하게 변화된 LBP 변형들이 제안되었다. CS-LBP[14]는 중심화소와 인근 화소값의 비교 과정을 통하여 이진패턴을 만들지 않고, 중심화소를 기준으로 대칭되는 이웃화소들과의 비교만을 통하여 이진패턴을 만드는 방법으로 식 (3)과 같이 계산된다.

$$CS-LBP(P, R) = \sum_{p=0}^{(P/2)-1} s(g_p - g_{p+(P/2)})2^p, \tag{3}$$

$$s(x) = \begin{cases} 1, & |x| \geq T \\ 0, & |x| < T \end{cases}$$

예를 들어, LBP(8,1)일 경우 값은 0에서 255까지의 값을 가지지만, CS-LBP에서의 가중치는 2^0 부터 2^3 까지이므로 패턴의 최대 인덱스값은 15가 된다. LBP의 최대값이 255인 것에 반해 CS-LBP는 15의 값을 갖는 것은 기존의 이진패턴 히스토그램을 이용한 얼굴 인식 방법에 있어서, CS-LBP가 히스토그램 특징벡터의 차원을 줄이는 의미를 가진다. LBP 히스토그램의 경우에 특징벡터의 차원을 감축하기 위해서 히스토그램되는 LBP 인덱스의 종류를 59개로 줄인 ULBP 히스토그램을 사용하기도 한다.

Differential LBP는 수직, 수평 및 대각선 방향의 미세패턴을 묘사할 수 있으며 기본 LBP와 CS-LBP 연산보다 우수한 결과를 나타낸다[7]. 수평과 수직방

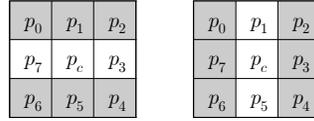


Fig. 2. Differential LBP of horizontal and vertical direction.

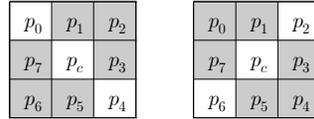


Fig. 3. Differential LBP of diagonal direction.

향 패턴을 묘사할 수 있는 Differential LBP를 Fig. 2와 식 (4), 대각선 방향의 Differential LBP를 Fig. 3과 식 (5)에 보였다.

$$Diff. LBP_{P_r, P_r, P_v} = S(p_0 - p_6)2^0 + S(p_1 - p_5)2^1 + S(p_2 - p_4)2^2 + S(p_0 - p_2)2^3 + S(p_7 - p_3)2^4 + S(p_6 - p_4)2^5 \tag{4}$$

$$Diff. LBP_{P_r, P_r, P_v} = S(p_1 - p_7)2^0 + S(p_2 - p_6)2^1 + S(p_3 - p_5)2^2 + S(p_7 - p_5)2^3 + S(p_0 - p_4)2^4 + S(p_1 - p_3)2^5 \tag{5}$$

2.3 LBP 특징과 AdaBoost 분류기

전역 템플릿 매칭 분류기(2.1절)의 경우 얼굴 표정 분류에 유용한 영역이라고 추정되는 부분영역은 가중치를 크게 주고 그렇지 않은 경우 작은 가중치를 직접 인위적으로 설정하였지만, 분별력이 높은 부분영역을 학습 과정을 통해 자동으로 찾아내는 방법 [6,7]도 있다. [6,7]에서는 분별력이 높은 부분영역을 찾기 위해 AdaBoost 학습 알고리즘을 이용하였다. 부분영역별 약분류기로 템플릿매칭 분류기를 도입하였으며, AdaBoost 학습을 통해 분별에 서로 도움이 되는 최적의 부분영역 조합을 찾을 수 있게 된다.

AdaBoost 학습 알고리즘은 성능이 우수하지 않은 다수의 약한 분류기들의 선형합으로 강력한 분류기를 구성한다. 학습은 일련의 라운드 $t=1, \dots, T$ 에서 약분류기와 그것의 가중치를 학습하는 것을 의미한다. 학습 샘플들은 학습 초기($t=1$)에 동일한 값으로 중요도를 가지지만, 각 라운드의 학습 후에 오인식되는 샘플의 학습 가중치는 증가하고 정인식되는 샘플의 학습 가중치는 감소한다. 매 라운드 샘플의 학습

가중치가 변경됨에 따라 다음 라운드에서 가중치가 큰 오인식된 샘플을 보다 더 많이 학습하도록 하여 이전에 학습된 약분류기들을 보완하는 약분류기가 추가적으로 구현된다. 이와 같은 학습을 통해 정확도가 낮은 약분류기들의 최적 조합을 찾아 강력한 분류기를 구성할 수 있다.

3. 방향성 LBP 특징과 특징 영역 학습을 이용한 표정 분류

3.1 제안하는 방향성 LBP

기존의 LBP의 경우 방향성에 대한 정보가 결여되어 있어서 미세패턴의 방향성 정보를 표현하기에 어려움이 있다. CS-LBP의 경우 수직, 수평 및 대각선 방향의 정보가 있어 방향성 정보를 지닌 미세패턴을 기술할 수 있으나 방향벡터가 45° 혹은 135° 방향으로 제한되어 있었다. Differential LBP의 경우 수직과 수평 방향, 대각선 방향 이외의 다양한 각도의 비정방형의 LBP 연산이 가능하여 미세패턴을 더욱 잘 기술할 수 있었다. Differential LBP는 마주보는 수평 방향, 수직방향, 혹은 대각방향에 대한 세 쌍의 픽셀의 차와 이를 결합하여 표현한다. 본 논문에서는 Differential LBP의 표현 방법을 개선하여 보다 다양한 방향을 표현하는 방향성 LBP를 제안한다.

제안한 LBP 연산은 Fig. 4~Fig. 8과 같이 반경의 크기가 변하는 멀티스케일 LBP 마스크로 다양한 각도를 표현할 수 있는 방향성 LBP 연산이다. 수평과 수직의 방향성 LBP 마스크를 Fig. 4에 보였으며 수평과 수직방향에 대하여 25개의 연산을 수행하게 된다.

또한 LBP 연산의 수평반경 R_h 과 수직반경 R_v 이 1에서 5로 변함에 따라서 대각선 방향뿐만 아니라 다양한 각도의 방향성 LBP 연산을 수행하게 된다. 반경이 변화함에 따라서 LBP 마스크의 모양이 점차 기울어지게 된다. Fig. 5는 1사분면, Fig. 6는 2사분면 상에서 1행을 제외하고 20개의 수직으로 배열된 방향성 LBP 연산을 수행하여 다양한 방향성을 표현한다. Fig. 7은 1사분면, Fig. 8은 2사분면 상에서 1열을 제외한 20개의 다양한 방향성을 가지는 미세패턴을 표현한다. 따라서 기존의 LBP, CS-LBP 방법이 고정된 한 가지의 마스크만을 사용하는 데 비하여 125개의 방향성 미세패턴을 생성해 낼 수 있다.

3.2 제안한 방향성 LBP 연산 인자의 학습과 표정 인식 과정

제안한 방향성 LBP 특징의 연산 마스크와 분별 영역은 학습을 통해 결정된다. 이를 학습하기 위해서 이용한 표정분류 방법은 [6], [7]과 유사한 학습과정과 분류과정으로 구성되어 있다.

2.3절에서 서술하였듯이 얼굴 표정 분류에 유용한 분별력이 있는 부분영역은 AdaBoost 학습을 통해 자동으로 결정될 수 있다. AdaBoost 학습에서는 다양한 부분영역별 약분류기로 템플릿매칭 분류기를 도입하였으며 학습 라운드가 진행되면서 분별에 유용한 부분영역들이 선택되고 부분영역별 최적 LBP 연산 인자를 찾을 수 있다. 네 가지 종류의 표정 영상들에 대한 다양한 방향성 LBP 연산, 히스토그램 특징벡터 추출, AdaBoost 학습을 통해서 100개의 주요 LBP 연산 인자를 정의한다. 확장된 100개의 영역과 LBP 연산 인자를 이용하여 다중 클래스 SVM을 적용하여 최종 표정 인식기를 구현한다. 인식 과정에서는 학습 과정을 통해 생성된 SVM 모델과 추출된 입력 LBP 특징벡터와의 비교를 통하여 얼굴표정을 분류하게 된다. 크기 40×48 인 영상 하나에 대하여 총 47,380개의 특징 인자가 추출되었으며 이를 AdaBoost 학습을 통하여 각 감정별로 100개의 주요한 연산 인자를 결정한다. 기존의 일부 연구에서는 눈, 입 주변 등 표정 분별에 중요하다고 판단되는 영역을 임의로 가중치를 주는 방법을 사용하고 있으나, 본 연구에서는 학습을 통하여 분별에 용이한 부분 영역 뿐만 아니라 방향성 미세패턴 계산 마스크도 동시에 학습을 통해서 자동으로 찾아내게 된다. 즉, 분별 영역을 찾고 그 영역에 가장 적합한 방향성 LBP 마스크를 찾아내는 것이다.

마지막으로, 네 가지 표정에 대한 다중 클래스 분류에서는 one-against-all 방법을 사용하여 특정 표정 그리고 나머지 표정을 구분하여 학습시킨다.

4. 실험 결과

본 실험에 사용된 포항공대 데이터베이스는 남녀 각 100명에 대하여 네 가지 감정의 얼굴 영상으로서 40×48 의 크기이다. 감정 각각에 대하여 3,200장, 전체 영상의 개수는 12,800장으로서 학습과 분류에 절반씩 나누어서 사용하였다. 제안한 방법과 기존 방법과의 비교평가는 식 (6)의 정확도, 민감도와 특이도를

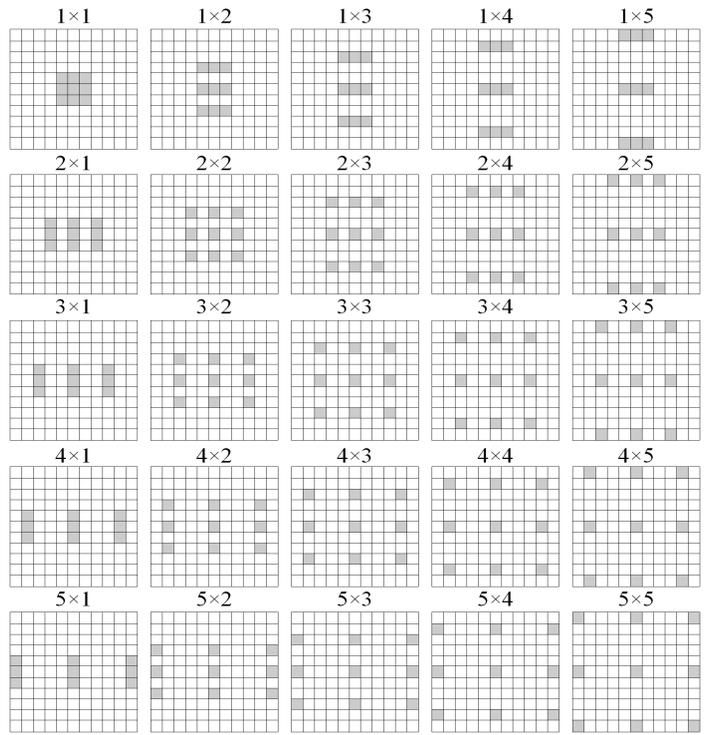


Fig. 4. LBP masks not skewed.

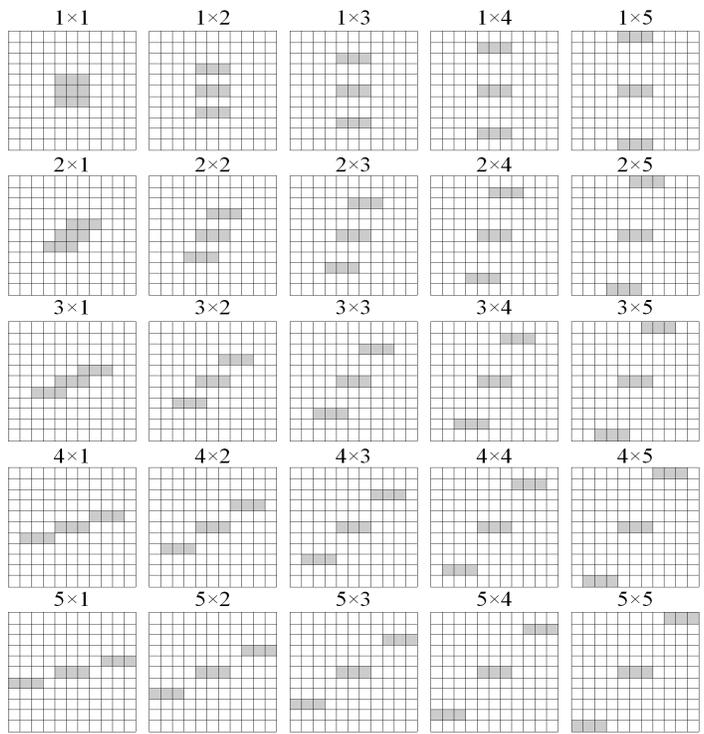


Fig. 5. Horizontally skewed LBP masks at first quadrant.

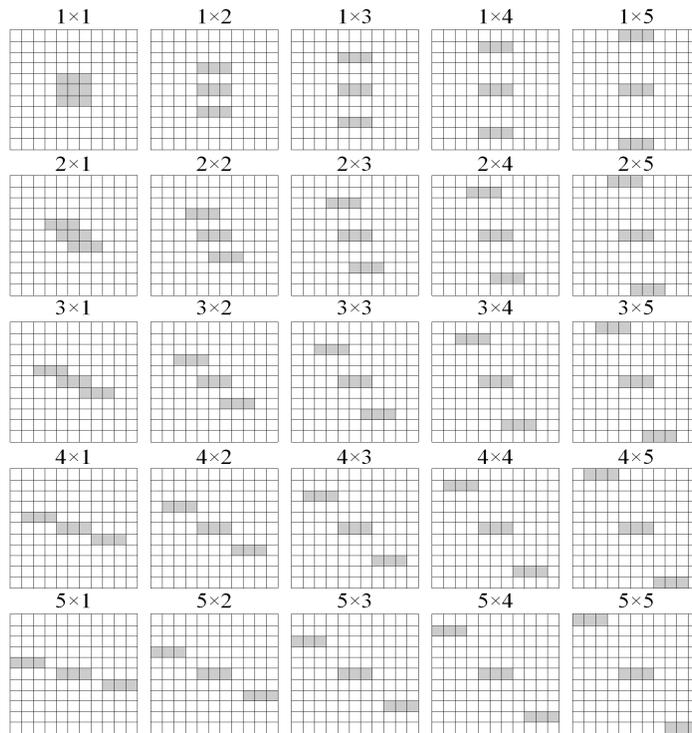


Fig. 6. Horizontally skewed directional LBP masks at second quadrant.

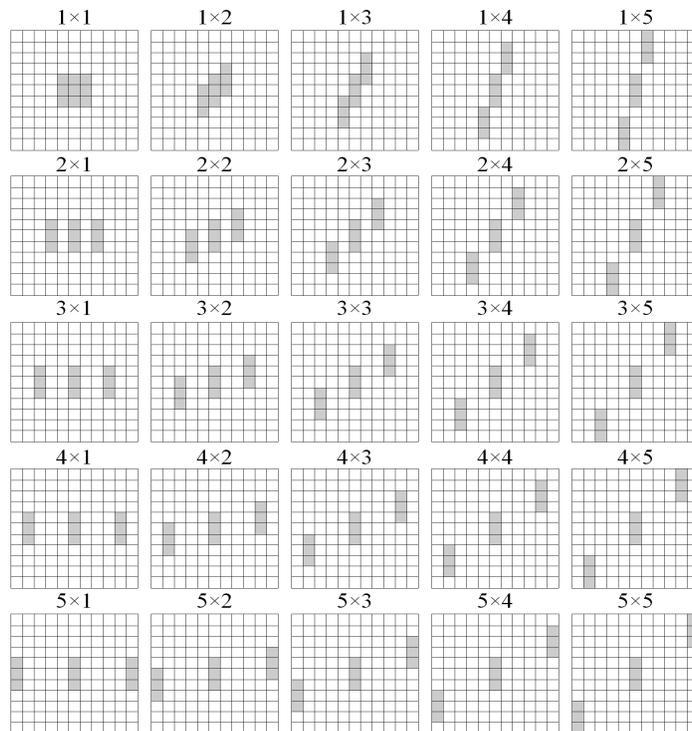


Fig. 7. Vertically skewed directional LBP masks at first quadrant.

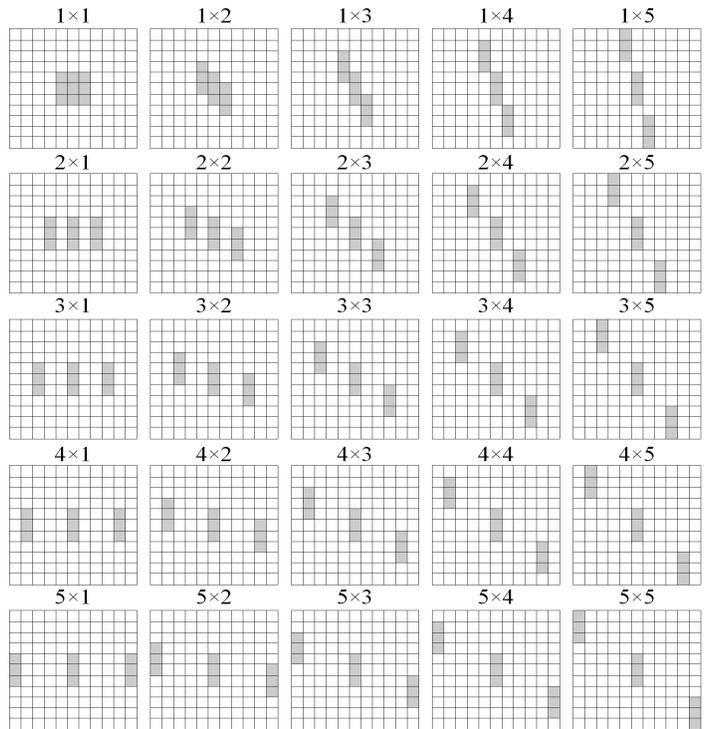


Fig. 8. Vertically skewed directional LBP masks at second quadrant.

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + False\ Positive + True\ Negative + False\ Negative}$$

$$Sensitivity = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

$$Specificity = \frac{True\ Negative}{True\ Negative + False\ Positive}$$

사용하였다.

정방향 LBP, CS-LBP, differential LBP와 제안한 LBP 연산의 정확도 비교 결과를 Table 1에 보였다. 정방향 LBP 93.47%, CS-LBP 92.08%, Differential LBP 95.5% 그리고 제안한 방향성 LBP 연산의 경우 정확도가 95.7%로서 가장 우수한 결과를 보였다.

Table 2와 Fig. 9의 각 표정에 대한 민감도 비교에서 ‘무표정’, ‘행복’, 및 ‘화냄’의 경우 제안한 방법의 결과가 가장 우수하였다. ‘놀람’의 경우에는 differ-

ential LBP가 제안한 방법보다 우수한 결과를 보였지만 차이는 크지 않다.

Table 3과 Fig. 10의 특이도 비교의 경우 제안한 방법이 ‘무표정’, ‘놀람’ 및 ‘화냄’ 표정에 대하여 가장 우수한 결과를 나타내었다. ‘행복’ 표정에 대해서는 differential LBP가 우수한 결과를 보였지만 전반적으로 제안한 방향성 LBP가 가장 우수한 결과를 보임을 알 수 있다.

Table 4는 제안한 방법의 오차 행렬(confusion

Table 1. Accuracy comparison of classification using Square LBP, CS-LBP, differential LBP, and proposed LBP

	Square LBP	CS-LBP	Differential LBP	Proposed LBP
True Positive	5982	5893	6112	6125
Accuracy(%)	93.47	92.08	95.50	95.70

Table 2. Sensitivity(%) comparison of four expressions classification

	Neutral	Happiness	Surprise	Anger
Square LBP	93.31	99.25	96.50	84.81
CS-LBP	93.75	99.13	95.69	79.75
Differential LBP	96.00	99.44	97.44	89.13
Proposed LBP	96.06	99.69	97.31	89.75

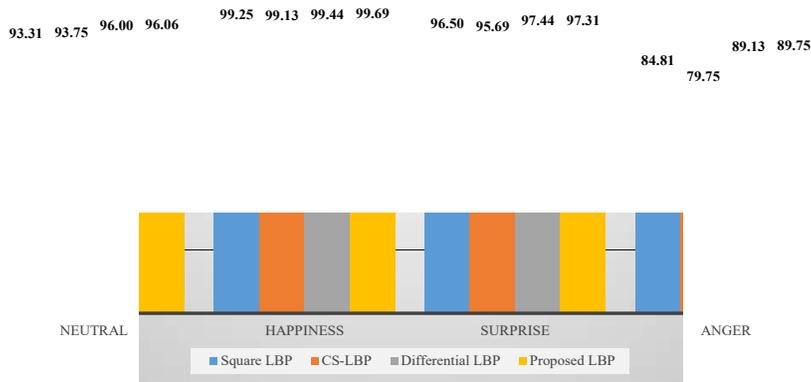


Fig. 9. Sensitivity(%) comparison of four expressions classification,

Table 3. Specification(%) comparison of four expressions classification

	Neutral	Happiness	Surprise	Anger
Square ULBP	96.52	97.33	98.27	99.17
CS-LBP	95.23	96.44	98.40	99.38
Differential LBP	97.54	98.10	98.92	99.44
Proposed LBP	97.77	98.00	99.02	99.48

matrix)을 보여주고 있다. ‘행복’의 경우 TP 비율이 99.69%로 가장 좋은 결과를 보였다. ‘무표정’의 경우 96.06%의 TP 비율을 보여주며 ‘행복’과 ‘놀람’에 각각 1.88%와 1.19%로 분류되었다. ‘화남’의 경우 TP 비율이 89.75%로 가장 낮으며 ‘무표정’에 5.63%, ‘행복’에 2.88% 등으로 분류되었다.

5. 결 론

본 연구에서는 얼굴 표정 인식을 위한 방향성 LBP 특징을 제안하였으며, 또한 표정 분별에 용이한 방향성 LBP 연산과 특징 영역을 찾는 방법에 대해서 제안하였다. 얼굴의 미세한 마이크로패턴을 잘 묘사할

수 있도록 제안된 방향성 LBP 특징에 대해 Ada Boost 학습을 실시하고 이를 통해 LBP 마스크의 방향과 크기 등의 LBP 연산인자, 분별 부분영역을 정의하였다. LBP 특징과 분별 부분영역을 학습하기 위한 AdaBoost 학습 과정에서는 템플릿 매칭 분류기를 사용하였다. 최종 얼굴 표정 인식기는 학습된 분별 부분영역과 방향성 LBP 연산 인자에 기반 하여 SVM 분류기로 구현하였다.

제안 방법의 유효성을 검증하기 위하여 정확도, 민감도 및 특이도 관점에서 얼굴 표정 인식 성능을 측정하였다. 실험 결과 제안한 방향성 LBP 특징을 사용한 방법은 정확도가 95.7%로 정방향 LBP 93.47%, CS-LBP 92.08%, Differential LBP 95.5%에 비

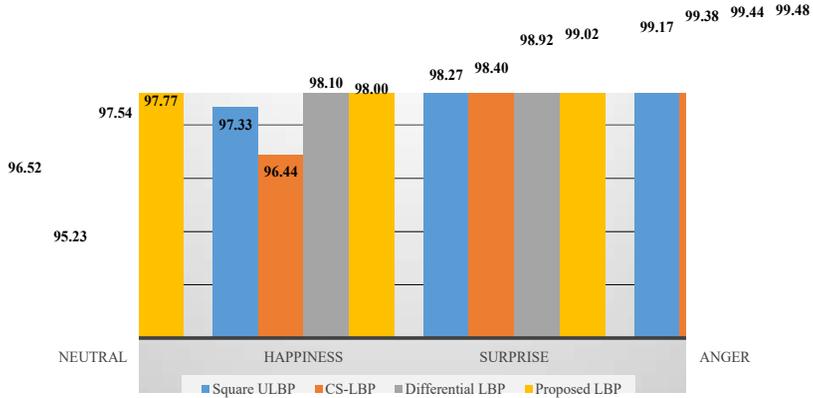


Fig. 10. Specification(%) comparison of four expressions classification.

Table 4. Confusion matrix of the proposed method

		Classification(%)			
		Neutral	Happiness	Surprise	Anger
True Class	Neutral	96.06	1.88	1.19	0.88
	Happiness	0.13	99.69	0.00	0.19
	Surprise	0.94	1.25	97.31	0.50
	Anger	5.63	2.88	1.75	89.75

하여 우수한 성능을 보였다. 민감도 측면에서도 ‘무 표정’, ‘놀람’ 및 ‘화남’ 표정에 대하여 비교한 방법들에 비하여 가장 우수한 결과를 나타내었다. 또한, 특이도 관점에서도 다른 방법들에 비하여 우수한 성능을 보였다. 특히, ‘행복’ 표정 인식의 경우 TP 비율이 99.69%로 매우 좋은 결과를 보였다. 따라서 제안한 방법이 모든 관점에서 평균적으로 가장 우수한 성능을 보여 얼굴 표정 인식에 유용함을 확인할 수 있었다.

REFERENCE

[1] Y. Cheon and D. Kim, “A Natural Facial Expression Recognition Using Differential-AAM and k-NNS,” *Journal of Pattern Recognition*, Vol. 42, No. 7, pp. 1340-1350, 2008.

[2] Y. Tian, T. Kanade, and J. Cohn, “Recognizing Action Units for Facial Expression Analysis,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 2, pp. 97-115, 2001.

[3] N.D. Matthew, W. Garrison, P. Curtis, and A. Ralph, “EMPATH: A Neural Network that Categorizes Facial Expressions,” *Journal of Cognitive Neuroscience*, Vol. 14, No. 8, pp. 1158-1173, 2002.

[4] C.L. Lisetti and D.E. Rumelhart, “Facial Expression Recognition Using a Neural Network,” *Proceeding of The 11th International Flairs Conference*, pp. 323-332, 1998.

[5] C. Shan, S. Gong, and P.W. McOwan, “Facial Expression Recognition Based on Local Binary Patterns: A Comprehensive Study,” *Journal of Image and Vision Computing*, Vol. 27, No. 6, pp. 803-816, 2009.

[6] C. Won, “Recognition of Facial Emotion Using Multi-scale LBP,” *Journal of Korea Multimedia Society*, Vol. 17, No. 12, pp. 1383-1392, 2014.

[7] K.T. Lim and C. Won, “Face Image Analysis

Using Adaboost Learning and Non-Square Differential LBP,” *Journal of Korea Multimedia Society*, Vol. 19, No. 6, pp. 1014-1023, 2016.

[8] T.F. Cootes, G.J. Edwards, and C.J. Taylor, “Active Appearance Models,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 6, pp. 681-685, 2001.

[9] A.B. Ashraf, K. Prkachin, T. Chen, S. Lucey, P. Solomon, Z. Ambadar, et al., “The Painful Face-Pain Expression Recognition Using Active Appearance Models,” *Journal of Image and Vision Computing*, Vol. 12, No. 3, pp. 1788-1796, 2009.

[10] T. Ojala, M. Pietikäinen, and T. Mäenpää, “Multi-resolution Gray-scale and Rotation Invariant Texture Classification with Local Binary Patterns,” *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 24, No. 7, pp. 971-987, 2002.

[11] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Journal of Machine Learning*, Vol. 20, No. 3, pp. 273-297, 1995.

[12] Y. Freund and R.E. Schapire. “A Short Introduction to Boosting,” *Journal of Japanese Society for Artificial Intelligence*, Vol. 14, No. 5, pp. 771-780, 1999.

[13] C.W. Hsu and C.J. Lin, “A Comparison of Methods for Multiclass Support Vector Machines,” *IEEE Transactions on Neural Networks*, Vol. 13, No. 2, pp. 415-425, 2002.

[14] S. Junding, Z. Shisong, and W Xiaosheng, “Image Retrieval Based on an Improved CS-LBP Descriptor,” *Proceeding of The 2nd IEEE International Conference on Information Management and Engineering*, pp. 115-117, 2010.



강 현 우

2005년 경북대학교 컴퓨터공학
공학사
2009년 경북대학교 컴퓨터공학
공학석사
2017년 경북대학교 컴퓨터공학
공학박사

현재, 한국전자통신연구원 대경권연구센터 선임연구원
관심분야: 컴퓨터비전,비디오보안



임 길 택

1993년 경북대학교 전자공학
공학사
1995년 경북대학교 전자공학
공학석사
1999년 경북대학교 전자공학
공학박사

현재, 한국전자통신연구원 대경권연구센터 책임연구원
관심분야: 머신러닝,컴퓨터비전,비디오보안



원 철 호

1992년 경북대학교 전자공학
공학사
1995년 경북대학교 전자공학
공학석사
1998년 경북대학교 전자공학
공학박사

현재, 경일대학교 의용공학과 교수
관심분야: 컴퓨터비전, 의용신호처리