

사전 학습된 VGGNet 모델을 이용한 비접촉 장문 인식

김민기[†]

Contactless Palmprint Identification Using the Pretrained VGGNet Model

Min-Ki Kim[†]

ABSTRACT

Palm image acquisition without contact has advantages in user convenience and hygienic issues, but such images generally display more image variations than those acquired employing a contact plate or pegs. Therefore, it is necessary to develop a palmprint identification method which is robust to affine variations. This study proposes a deep learning approach which can effectively identify contactless palmprints. In general, it is very difficult to collect enough volume of palmprint images for training a deep convolutional neural network(DCNN). So we adopted an approach to use a pretrained DCNN. We designed two new DCNNs based on the VGGNet. One combines the VGGNet with SVM. The other add a shallow network on the middle-level of the VGGNet. The experimental results with two public palmprint databases show that the proposed method performs well not only contact-based palmprints but also contactless palmprints.

Key words: Palmprint Identification, VGGNet, Deep Convolutional Neural Network

1. 서론

생체인식(biometrics)은 개인의 정적 또는 동적인 신체 정보를 토대로 개인을 식별하는 방법을 말한다. 지문, 홍채, 얼굴 등의 생체 정보에 비하여 장문(palmprint)은 상대적으로 뒤늦게 연구가 시작되었다. 초기의 장문인식 연구는 400dpi 이상의 고해상도 영상에 대하여 범죄수사(forensic)의 목적으로 진행되었으나, 최근의 연구들은 대부분 저해상도 영상을 대상으로 상업적인 응용을 목적으로 이루어지고 있다[1]. 장문은 지문이나 홍채에 비하여 유일성은 다소 떨어지지만 정보의 획득성이나 사용자 수용성이 높은 장점이 있다. 그리고 지문에 비하여 닳아 없어지지 않아 견고성이 높고, 식별 정보가 넓게 분포하

여 부분적인 손상에도 강인한 특성이 있다.

장문 인식에 대한 연구는 손바닥에 나타난 손금의 주획(principal lines), 주름(wrinkles), 능선(ridges) 등으로 구성된 장문의 특징을 효과적으로 추출할 수 있는 방법을 찾는데 집중되어 왔다. 장문 영상의 전체적인 명도 값 분포를 기반으로 특징을 기술하는 부영역(subspace) 방식은 주성분 분석(PCA, Principal Component Analysis)[2], 선형식별 분석(LDA, Linear Discriminant Analysis)[3], 불변 모멘트[4] 등을 활용하여 이루어져 왔으나, 이 방식은 장문 영상 전역의 명도 값을 이용하기 때문에 장문을 획득할 때의 조명 환경에 민감한 단점이 있다. 이러한 단점을 극복할 수 있는 방법으로 국부적인 텍스처 정보를 이용하는 방법들이 제안되었다. 손금의 주획, 주름,

※ Corresponding Author : Min-Ki Kim, Address: (660-701) Jinju-daero 501, Jinju, Gyeongnam, Korea, TEL: +82-55-772-1393, FAX: +82-55-772-1389 E-mail: mkkim@gnu.ac.kr

Receipt date : Oct. 31, 2018, Revision date : Nov. 21, 2018
Approval date : Nov. 28, 2018

[†] Dept. of Computer Science, Gyeongsang National University Engineering Research Institute

능선 등 장문에 나타나는 선의 방향 특징을 나타내는 PalmCode[5]가 제안된 이후, 여섯 방향의 Gabor 필터를 적용하여 우세 방향을 공간 효율적으로 기술한 CompCode[6], 직교하는 두 라인에서 명도 변화가 크게 나타나는 방향을 특징으로 하는 OLOF(Orthogonal Line Orientation Feature)[7], 수정된 유한 라돈 변환(Radon transform)을 토대로 생성한 방향 템플릿을 이용한 방법[8], 주황 중심의 라인 추출 방식[9], 라인의 방향 정보에 대한 히스토그램을 이용한 연구[10] 등 다수의 연구가 이루어졌다. Han 외[11]의 연구에 의하면 방향 코드를 비접촉 방식으로 획득한 장문에 적용할 때 성능이 크게 저하되는 것으로 나타났다. 이러한 결과는 방향 코드 방식은 화소 주위의 명도 값 분포에 의한 방향 특징을 추출하여 해밍 거리(Hamming distance)를 정합하는 방식으로 인식이 이루어지기 때문에 손의 기울어짐이나 손바닥의 굴곡에 의한 왜곡에 취약함을 나타내는 것이다.

Morales 외[12]는 비접촉 방식으로 획득한 장문 영상에 나타나는 변형에 대응하기 위하여 Lowe[13]가 제안한 왜곡에 강인한 SIFT 키포인트를 이용하였다. 대응되는 SIFT 키포인트들 간의 유클리디안 거리로 정합을 수행한 결과 OLOF 방식보다 비접촉 장문 검증에 우수한 성능을 나타내었다. Wu 외[14]는 반복적인 RANSAC 알고리즘을 적용하여 위상 관계를 통해 SIFT 키포인트 정합을 정교화 하였다. 최근에는 심층 합성곱 신경망(DCNN)을 적용한 딥러닝(deep learning) 기술이 물체 인식 분야에서 괄목할 만한 성능 향상을 가져옴에 따라, DCNN을 생체 인식에 적용하는 연구들이 활발히 이루어지고 있다[15]. Zhao 외[16]는 하향식 비지도 학습으로 구축한 심층 신뢰망(Deep Belief Network)을 장문 인식에 적용하였으며, Sun 외[17]는 AlexNet 구조와 유사한 CNN-F 망을 이용하였다.

딥러닝 기술을 생체 인식에 적용할 때, 가장 큰 문제점은 DCNN을 학습시키는데 필요한 다량의 생체 데이터를 확보하는 것이다. 그런데 다량의 생체 데이터를 확보하는 것은 현실적으로 매우 어렵다. 이러한 이유로 장문 인식에 DCNN을 적용한 기존 연구들은 ImageNet 대회에 사용된 대용량 데이터로 훈련된 DCNN 모델을 이용하여 추가적인 훈련 없이 특정 DCNN 모델을 특징 추출을 위한 도구로 사용하거나 매우 제한적인 학습을 수행하고 있다.

본 연구에서는 소량의 장문 영상을 DCNN에 적용할 때 장문 인식의 성능을 향상시킬 수 있는 방법을 탐색한다. 사전 학습된 VGGNet의 합성곱 출력 층(layer)에서 추출한 특징 정보를 분석하고, 이를 기반으로 장문 인식을 수행하는 방법을 제안한다. 본 연구에서 사용한 VGGNet 버전은 VGG16이다. 본 논문의 구성은 다음과 같다. 2장에서는 본 연구에서 사용한 VGGNet 모델에 대하여 살펴보고, 3장에서는 VGGNet 모델을 이용한 장문 인식 방법을 설명한다. 4장에서는 접촉식과 비접촉식으로 장문 영상을 획득한 두 개의 공개된 장문 영상 데이터베이스를 이용한 장문 인식 실험 결과를 제시한다. 마지막으로 5장에서는 결론 및 향후 과제에 대하여 제시한다.

2. VGGNet 모델

심층 합성곱 신경망(DCNN)은 대용량의 학습 데이터를 필요로 할 뿐만 아니라 고성능의 컴퓨터를 사용하더라도 매우 긴 학습 시간이 요구된다. 특히 지문이나 장문과 같은 생체 영상을 대량으로 확보하는 것은 매우 어렵다. 이러한 경우 비록 학습에 사용된 데이터가 목적 데이터(target data)가 아니더라도 대용량 데이터로 훈련된 기존의 신경망을 이용하면 전이 학습(transfer learning)이나 미세 학습(fine tuning)을 통해 신경망을 효과적으로 구축할 수 있다[18]. DCNN을 이용하여 생체 인식을 수행한 기존의 연구들을 살펴보면 ImageNet 대회에서 선보인 DCNN 모델들이 사용되고 있다[15]. ImageNet 데이터베이스는 포유동물, 탈것, 가구, 꽃, 과일 등 12개의 서브트리로 계층적으로 구성되어 있으며, 총 3백만 개 이상의 영상들로 구성되어 있다[19].

Alex 외 연구[20]에서 제안된 AlexNet이라는 DCNN 모델은 2012년 ImageNet 대회에서 뛰어난 성능으로 우승을 차지하면서 DCNN에 대한 수많은 후속 연구들을 이끌었다. ZFNet, VGGNet, GoogleNet, ResNet 등을 비롯한 여러 DCNN 모델들이 제안되었고, 시각 처리에 의한 물체 인식 성능이 급격히 향상되는 결과를 가져왔다. AlexNet은 11×11 , 5×5 , 3×3 의 합성곱 층을 포함하여 7계층으로 구성된 반면, ResNet은 152계층을 갖는 매우 깊은 신경망이다. VGGNet[21]은 16개의 계층을 갖는 신경망으로, 전체적인 구조는 Fig. 1과 같다. 상대적으로 넓은 영역에 나타나는 특징을 추출하기 위하여 AlexNet은 11×11 , ZFNet은

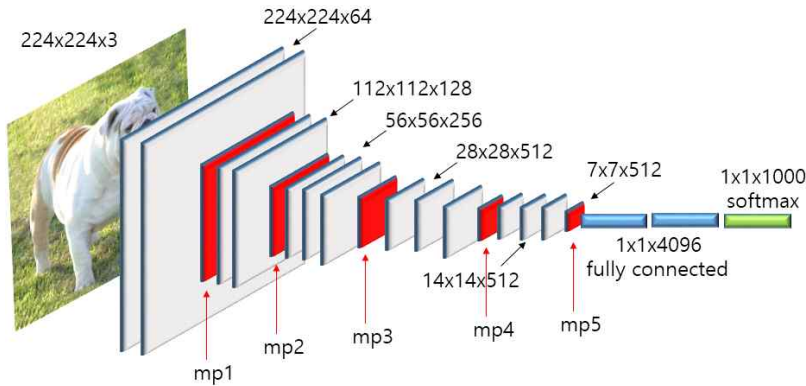


Fig. 1. Architecture of VGGNet [21].

7×7 필터를 사용하는데 비하여, VGGNet은 3×3 필터를 연속적으로 적용하여 유사한 효과를 얻고 있다. VGGNet은 입력으로 224×224크기의 3채널 영상을 받아들여서 1,000개중 하나의 범주로 분류한다. Fig. 1에서 회색 사각형으로 표현된 부분이 합성곱과 ReLU 연산을 나타내고, 적색 사각형으로 표현된 mp1 ~ mp5 부분이 최대값 풀링, 그리고 청색 사각형은 완전연결과 ReLU 연산을 나타낸다.

3. VGGNet 모델을 이용한 장문 인식

본 연구에서는 사전 학습된 VGGNet에 의해 추출되는 특징 중 장문 인식에 효과적으로 사용할 수 있는 층을 탐색하고, 이를 토대로 전이 학습과 미세 학습을 통해 장문을 식별하는 방법을 사용한다. Fig. 1에 제시된 바와 같이 VGGNet은 합성곱과 ReLU 연산 후에 최대 풀링을 수행하고 있다. 총 5곳에서 최대값 풀링 연산이 이루어지고 있다. 일반적으로 DCNN의 앞쪽에 나타나는 합성곱 특징은 색상이나 가장자리와 같은 낮은 차원의 특징을 식별하고, 뒤쪽에서는 이런 낮은 차원의 특징을 결합한 모양이나 개체들을 식별한다. 따라서 중간 이후 계층이 입력 영상의 중요한 특징을 추출할 수 있는 능력을 갖는다고 볼 수 있다. 본 연구에서는 VGGNet 중간 이후 계층의 합성곱 특징을 이용하는 전이 학습과 VGGNet의 중간 이후 계층에 새로운 계층을 추가하여 미세 학습을 수행하는 두 가지 접근을 시도하였다.

3.1 전처리

장문의 획득 방식은 접촉식과 비접촉식으로 나누어진다.

접촉식 방식은 사용자가 평평한 판 위에 손을 올려놓거나 유도 막대(peg)에 손가락을 끼운 상태에서 영상을 획득하므로, 크기 및 회전 변형이 적어 인식에 용이하나 사용자에게 불편함과 위생적인 문제를 유발한다. 이에 반하여 비접촉식은 공간적 접촉 없이 사용자에게 최소한의 제약만을 들으로써 사용자의 편의성이 높아지나 접촉식에 비하여 회전 및 이동 변형이 크게 발생하게 된다. 본 연구에서는 접촉식으로 획득한 장문뿐만 아니라 비접촉식으로 획득한 장문도 효과적으로 인식할 수 있는 방법을 탐색한다.

전처리는 크게 두 부분으로 나누어진다. 첫 번째는 손바닥 영상으로부터 중심부의 장문 영역을 추출하는 것이고, 두 번째는 추출된 장문 영역에 대한 영상 개선을 수행하는 것이다. Fig. 2는 접촉식으로 획득한 손바닥 영상에서 중앙부의 장문 영역을 추출하는 과정을 나타낸 것으로, 비접촉식으로 획득한 영상도 동일한 과정을 거쳐 장문 영역을 추출한다. Fig. 2-(a)는 입력 영상, (b)는 이진화된 영상, (c)는 관심 영역(ROI)인 장문 영역을 추출한 결과를 나타낸 것이다. ROI의 추출은 이진 영상으로부터 검지와 중지 사이의 특징점 R_1 과 약지와 소지의 사이의 특징점 R_2 를 찾고, 이 두 점을 연결한 선분의 중점 P_m 을 찾아 여기서 범선을 그어 일정 거리에 떨어져 있는 점 P_c 를 중점으로 하는 정사각형을 구하는 방식으로 이루어진다. 마지막으로 추출된 ROI를 회전 정규화시켜 (d)의 ROI 영상을 얻게 된다.

ROI 영상을 장문 인식에 바로 이용할 수도 있으나, 장문에 나타나는 주름이나 주름의 특징이 보다 명확하게 나타나고 조명 변화에 따른 변화를 줄일




Fig. 2. ROI extraction: (a) input image, (b) binarized image, (c) feature points to extract ROI, (d) normalized ROI image.




Fig. 3. Image enhancement: (a) ROI image, (b) Gabor filtered image, (b) equalized image, (c) smoothed image.

수 있도록 영상을 개선하면 장문 인식의 성능을 향상시킬 수 있다[22]. Fig. 3은 영상 개선 과정을 나타낸 것으로, Fig. 3-(a)는 입력 영상에서 추출한 ROI 영상이고, (b)는 Gabor 필터를 적용하여 장문에 나타난 선의 방향 특징을 강조시킨 영상이다. (c)는 평활화를 통해 명도 대비를 개선한 영상이고, (d)는 스무딩을 통해 영상을 흐릿하게 나타낸 것이다.

3.2 전이 학습

전이 학습을 통해 장문 인식을 수행하기 위하여 VGGNet의 중간 이후 계층에 나타나는 mp3, mp4, mp5의 합성곱 특징 중 어떤 것이 장문을 식별하는데 적합한지 실험을 통해 장문 인식 식별력을 비교해

보았다. 실험 결과 3개의 합성곱 특징 중 mp4 합성곱 특징이 장문 식별에 가장 효과적인 것으로 파악되었다. 그런데 mp4 합성곱 특징은 $14 \times 14 \times 512$ 크기의 매우 큰 차원을 갖기 때문에 합성곱 특징을 그대로 이용할 경우 특징 저장 공간을 많이 차지할 뿐만 아니라 정합을 위한 처리 시간도 문제가 된다. 차원 축소를 위하여 풀링(pooling)을 사용할 수 있으나, 풀링만으로는 합성곱 특징의 식별력이 유지되기 어렵다. 이러한 문제를 해결하기 위하여 주성분분석(PCA)을 통해 차원을 축소시킨 후 이들로부터 장문을 식별하기 위하여 지지벡터머신(SVM)을 사용하였다. 본 논문에서는 VGGNet의 mp4 합성곱 특징을 이용하므로 이 방법을 VGGmp4Svm이라고 명명한다. Fig. 4




Fig. 4. Overview of the proposed VGGmp4Svm.

는 제안된 ImageNet 데이터로 훈련된 VGGNet을 이용하여 전이 학습이 이루어지는 과정을 나타낸 것이다. 장문 영상을 VGGNet에 입력시켜 mp4 합성곱 특징을 구한 후 2×2 평균값 풀링으로 7×7×512 크기의 특징 벡터를 생성한다. 이후 PCA에 의해 N차원으로 축소시킨 특징 벡터를 이용하여 SVM을 학습시킨다.

3.3 미세 학습

VGGNet의 앞단은 특정 물체의 특징에 종속되지 않는 일반적인 특징을 추출하므로, VGGNet 앞단의 출력 값을 입력으로 하여 장문 인식을 수행하기 위한 얇은 신경망을 추가한다. 학습된 VGGNet의 앞단은 그대로 두고, 새로 추가된 뒷단만을 학습시키면 상대적으로 소량의 데이터로도 신경망을 학습시킬 수 있다. 본 연구에서 새로 추가한 얇은 신경망의 구조는 Table 1에 제시된 바와 같이 1개의 합성곱 신경망, 2개의 완전연결 신경망으로 이루어진 매우 단순한 구조로 되어 있다. 합성곱 신경망의 커널 크기는 3×3 이고, 활성화 함수는 최종 단계에서 softmax를, 그 이전 단계에서는 ReLU를 사용하였다. 그리고 신경망의 과적합(over fitting) 문제를 해결하기 위하여 드롭아웃 비율은 0.5로 설정하였다. 본 논문에서는 VGGNet에 제안된 얇은 신경망을 결합한 신경망을 VGGPalmNet이라고 명명한다.

장문 인식을 위해 신경망을 학습시키는데 필요한 다량의 학습데이터를 확보하는 것은 현실적으로 매우 어려운 문제이므로, 확보된 장문 영상을 회전 및 이동 변환을 이용하여 학습데이터를 확장시켜 학습을 수행하였다. 전처리 과정에서 아파인 변형에 강인한 손가락 사이의 특징점을 기반으로 ROI를 추출하고, 추출된 ROI 영상에 대한 회전 정규화가 이루어지고 있기 때문에 ±5도 이내의 회전 변형과 ±5% 이내의 이동 변환을 수행하여 학습 데이터를 확장하였다.

4. 실험 결과 및 분석

4.1 실험 환경 및 데이터

본 연구에서는 별도의 GPU없이, 인텔 CPU(Core i7-7700, 3.6GHz), 메모리 8GB, 윈도우 10 환경에서 실험을 수행하였으며, 딥 러닝을 위한 기반 환경으로 Keras, 백엔드로 텐서플로우를 사용하였다. 실험에 사용된 데이터는 접촉식으로 장문을 획득한 PolyU 데이터세트와 비접촉식으로 장문을 획득한 Tongji 데이터세트를 사용하였다. 두 데이터세트 모두 두 세션에 걸쳐 손바닥을 촬영하였으며, 세션간의 간격은 약 2개월이다. PolyU 데이터세트는 193명으로부터 획득한 7,752개의 영상으로 구성되어 있으며, 영상의 해상도는 384×284이다[8]. Tongji 데이터세트는 300명으로부터 획득한 12,000개의 영상으로 구성되어 있으며, 영상의 해상도는 800×600이다[23]. Tongji 데이터세트는 세션별로 한 명당 왼손과 오른손을 구분하여 10개씩의 장문으로 구성되어 있는데, 본 실험에서는 왼손에서 획득한 장문 총 6,000개를 실험에 사용하였다. PolyU 데이터세트는 왼손과 오른손을 구분하지 않고 구축되었으며, 한 명당 획득한 장문의 개수도 동일하지 않다. 본 실험에서는 한 개의 클래스 당 장문 10개가 확보되지 않은 일부 데이터를 제외하고, 클래스 당 10개씩 총 7,560개의 장문을 실험에 사용하였다. Fig. 5-(a)와 (b)는 PolyU 데이터세트에서 첫 번째 세션과 두 번째 세션에서 취득한 동일인의 장문 영상으로 변형이 적음을 알 수 있다. (c)와 (d)는 Tongji 데이터세트에서 첫 번째 세션과 두 번째 세션에서 취득한 동일인의 장문 영상으로 비접촉식으로 장문을 획득하였기 때문에 상대적으로 변형이 크게 나타나 있음을 알 수 있다.

4.2 VGGNet의 합성곱 특징

VGGNet의 중간 이후 계층에 나타나는 mp3, mp4,

Table 1. Architecture of the newly added back-end of the VGGPalmNet

Input	7×7×512
Convolution	filters: 64, kernel_size: 3×3, activation: ReLU
Pooling	Average pool_size: 2×2
Fully connected	units: 256, activation: ReLU
Dropout	rate: 0.5
Fully connected	units: n_classes, activation: softmax




Fig. 5. Palmprint sample images selected at PolyU and Tongji dataset.

mp5의 합성곱 특징 중 어떤 것이 장문을 식별하는데 보다 효과적인지 파악하기 위하여 각각의 합성곱 특징을 추출하여 장문 인식 실험을 수행하였다. 첫 번째 세션에서 획득한 영상에 대하여 각 클래스별로 첫 번째 영상을 참조 데이터로, 나머지 영상들을 질의 데이터로 사용하였다. Table 2는 장문 영상에서 추출한 합성곱 특징을 유클리디안 거리로 정합하여 최근접 이웃 분류기로 얻은 결과이다. 장문에 대한 식별 성능은 식 (1)에 제시된 정인식률(Correct Recognition Rate, CRR)로 측정하였다. N 은 전체 질의 영상의 개수, C 는 올바르게 식별된 장문의 개수를 나타낸다. Table 2에서 [mp4 Max pooling]와 [mp4 Avg pooling]은 mp4 합성곱 특징을 2×2 최대값 풀링과 평균값 풀링으로 얻은 특징으로, 특징 벡터의 차원이 축소되면서도 장문 인식 식별력은 향상되는 것으로 나타났으며, 평균값 풀링으로 구한 특징이 장문 인식에 보다 적합한 것으로 나타났다.

$$CRR(\%) = \frac{C}{N} \times 100 \quad (1)$$

Table 3은 첫 번째 세션에서 획득한 장문 영상 중 각 클래스별로 첫 번째 영상을 참조 데이터로 사용하고, 두 번째 세션에서 획득한 모든 장문 영상들을 질의 데이터로 사용하여 실험한 결과이다. 이러한 실험 설정은 장문 인식을 이용하여 개인을 식별할 때, 먼

Table 2. Palmprint identification results with the data of the first session

Features \ Dataset	PolyU (%)	Tongji (%)
[mp3] 28×28×256	96.03	89.89
[mp4] 14×14×512	98.62	95.96
[mp5] 7×7×512	85.77	87.26
[mp4 Max pooling] 7×7×512	99.29	97.19
[mp4 Avg pooling] 7×7×512	99.47	97.96

저 식별 대상이 되는 사람들의 장문을 등록하고 나중에 새로 입력된 장문을 등록된 장문과 비교하여 개인을 식별하기 때문이다. 질의 영상과 참조 영상에서 추출한 합성곱 특징을 유클리디안 거리로 정합한 후 최근접 이웃 분류기를 사용하였다. 예상한 바와 같이 점접촉식으로 장문을 획득한 PolyU 데이터세트에 비하여 비접촉식으로 획득한 Tongji 데이터세트에서 장문 인식률이 크게 저하되는 것으로 나타났다.

4.3 장문 인식 성능 측정 및 비교

VGGNet의 중간 계층에서 추출한 합성곱 특징을 PCA에 의하여 차원을 축소한 후 SVM 분류기의 입력으로 사용하는 VGGmp4Svm의 SVM 분류기를 학습시키기 위하여 첫 번째 세션에서 획득한 데이터의 80%를 이용하고, 나머지 20%의 데이터를 학습이 제대로 이루어졌는데 평가(validation)하기 위한 데이터로 사용하였다. 실험 결과 PCA에 의해 합성곱 특징을 1,000개로 하였을 때 두 데이터세트 모두 100%의 정인식률을 나타냈으며, 100개까지 축소하여도 인식률의 저하는 나타나지 않았다. 합성곱 특징의 차원을 PCA에 의해 1,000개의 요소를 갖는 벡터로 변환하였을 때, 두 번째 세션에서 획득된 장문을 테스트 데이터로 하여 SVM 분류기로 인식한 결과 PolyU 데이터세트에 대하여 99.13%, Tongji 데이터세트에 대하여 98.37%의 정인식률을 얻을 수 있었다.

VGGNet에 제안된 얇은 신경망을 결합한 VGG

Table 3. Palmprint identification results with the data of the second session

Features \ Dataset	PolyU (%)	Tongji (%)
[mp4] 14×14×512	91.43	79.77
[mp4 Max pooling] 7×7×512	92.99	82.40
[mp4 Avg pooling] 7×7×512	95.21	86.53

Table 4. Performance comparison among the proposed methods

Dataset Approach	PolyU CRR (I_{CRR})	Tongji CRR (I_{CRR})
VGGNet(mp4)	91.43%	79.77%
VGGPalmNet	87.54% (-4.3%)	86.00% (7.8%)
VGGmp4Svm	99.13% (8.4%)	98.37% (23.3%)

PalmNet에 대한 실험도 동일한 조건으로 실행되었다. 첫 번째 세션에서 획득한 데이터 중 80%를 학습 데이터로 이용하고, 나머지 20%의 데이터를 평가 데이터로 사용하였을 때, PolyU 데이터세트에 대해서는 99.74%, Tongji 데이터세트에 대해서는 100%의 정인식률을 나타냈다. 두 번째 세션에서 획득한 장문을 테스트 데이터로 하여 수행한 실험에서는 PolyU, Tongji 데이터세트에 대하여 각각 87.54%, 86.00%의 정인식률을 보였다.

Table 4는 첫 번째 세션에서 획득한 장문을 학습 데이터로 사용하고, 두 번째 세션에서 획득한 장문을 테스트 데이터로 설정한 실험 조건에서 제안된 방법들의 성능을 비교하기 위하여 실험 결과를 정리한 것이다. 제안된 방법 중 PCA에 의해 특징 벡터의 차원을 축소하여 SVM 분류기를 학습시킨 VGGmp4Svm이 가장 우수한 성능을 나타내었다. Table 4에서 I_{CRR} 은 성능 향상도를 나타낸 것으로, VGGNet의 mp4 합성곱 특징을 유클리디안 거리로 정합하여 최근접 이웃 분류기를 사용한 방식을 기준으로 VGG PalmNet과 VGGmp4Svm의 장문 인식 성능 향상도를 식 (2)로 계산한 것이다. B_{CRR} 은 기준이 되는 장문 인식 방법의 정인식률을 나타내고, N_{CRR} 은 비교 대상이 되는 장문 인식 방법의 정인식률을 나타낸다. PolyU 데이터세트에 VGGPalmNet을 적용한 경우

87.54%의 정인식률을 보여 성능 향상도가 -4.3%로 나타났다. 이것은 VGGNet(mp4)보다 오히려 인식률이 저하된 것을 의미한다. 이것은 접촉식으로 장문 영상이 획득되어 이동 및 회전 변형이 그다지 크지 않음에도 불구하고, VGGPalmNet을 학습시킬 때 인위적으로 이동 및 회전 변형을 가한 데이터를 학습시켰기 때문인 것으로 판단된다.

$$I_{CRR}(\%) = \frac{N_{CRR} - B_{CRR}}{B_{CRR}} \times 100 \quad (2)$$

Table 5는 본 연구에서 제안한 방법과 다른 연구자가 제안한 방법의 장문 인식 성능을 비교하기 위하여 가급적 유사한 실험 조건하에서 실험을 수행한 연구들의 실험 결과를 정리한 것으로, 제안된 장문 인식 방법이 효과적임을 확인할 수 있다. 장문 인식에 대한 응용을 고려할 때, 첫 번째 세션에서 획득한 데이터를 참조 데이터로 사용하고, 두 번째 세션에서 획득한 데이터를 질의 데이터로 설정하여 실험을 수행하는 것이 합리적이다. 즉, 한 번도 본 적인 없는 장문 영상을 입력하였을 때 이것이 어떤 사람의 것인지 식별할 수 있어야 한다. [9]와 [17]의 연구 결과가 높은 정인식률을 보여주고 있으나, [9]의 실험은 각 클래스 당 첫 번째 세션에서 2개와 두 번째 세션에서 1개의 데이터를 학습데이터로 이용하였고, [17]의 실험은 첫 번째 세션만을 대상으로 학습과 테스트를 수행하였기 때문에 본 연구와 동일한 조건에서 실험한다면 정인식률이 저하될 것으로 예측된다. [23]은 비접촉식 장문 데이터세트로 실험을 수행하여, 본 연구에서 제안한 방법의 정인식률을 약간 상회하는 결과를 보여주고 있으나, 파라미터 튜닝을 위하여 추가로 100명으로부터 획득한 2,000개의 장문 영상을 이용하였음을 밝히고 있다. 접촉식과 비접촉식 장문 영상 데이터세트에 대한 실험 결과를 제시한 연구[10]

Table 5. Performance comparison with different researches

Methods	Dataset	Contact-based Palmprint		Contactless Palmprint	
	Dataset	CRR(%)	Dataset	CRR(%)	
Ekinici & Aykut[2]	PolyU	95.17	NA	NA	
Kalluri & Prasad[9]	PolyU	99.15	NA	NA	
Arunkumar & Valamathy[10]	PolyU	97.00	COEP[24]	82.21	
Sun et al.[17]	PolyU	99.62	NA	NA	
Zhang et al.[23]	NA	NA	Tongji	98.78	
Proposed VGGmp4Svm	PolyU	99.13	Tongji	98.37	

에 비해서도 제안된 방법이 더 나은 성능을 보여주고 있다.

5. 결 론

장문은 생체인식을 위한 여러 생체 정보 중 하나로 지문이나 홍채 등에 비하여 일반 카메라로 촬영한 저해상도 영상으로 식별이 가능하고, 생체 정보 수집에 수반되는 사용자의 거부감이 상대적으로 적은 장점이 있다. 본 연구에서는 접촉식으로 획득한 장문뿐만 아니라 비접촉식으로 획득한 장문도 효과적으로 인식할 수 있는 방법을 제안하였다. 사용자의 편의성 확대를 위해서는 비접촉식으로 장문을 획득하여야 하나, 이 경우 획득된 장문의 변형이 크게 나타나는 문제를 해결하여야 한다. DCNN은 영상에 나타나는 다양한 변형에 대처할 수 있는 능력을 갖고 있지만, DCNN을 학습시키기 위한 방대한 양의 장문 데이터를 확보하는 것을 현실적으로 매우 어려운 일이다. 따라서 본 연구에서는 VGGNet에 전이 학습과 미세 학습을 도입하여 장문을 인식하는 방법을 제안하였다. 접촉식으로 장문을 획득한 PolyU 데이터세트와 비접촉식으로 장문을 획득한 Tongji 데이터세트로 실험한 결과 VGGNet의 중간 계층 합성곱 특징 중 mp4 합성곱 특징이 다른 합성곱 특징에 비하여 장문의 특징을 효과적으로 나타내는 것을 확인하였다. 그리고 mp4 합성곱 특징에 대한 평균값 풀링이 특징 벡터의 차원을 줄이면서도 장문의 식별 성능을 향상시킬 수 있었다. VGGNet에서 생성된 특징을 기반으로 전이 학습과 미세 학습을 수행한 결과, 새로 추가한 얇은 신경망을 학습시킨 VGGPalmNet 보다는 SVM 분류기를 학습시킨 VGGmp4Svm이 장문 인식에 보다 효과적이었다. 향후 연구에서는 VGGNet 이외의 다른 사전 학습된 DCNN의 합성곱 특징을 분석하여 장문 인식의 성능을 개선할 수 방법을 탐색할 계획이다.

REFERENCE

- [1] D. Zhang, W. Zuo, and F. Yue, "A Comparative Study of Palmprint Recognition Algorithms," *ACM Computing Surveys*, Vol. 44, No. 1, pp. 1-37, 2012.
- [2] M. Ekinici and M. Aykut, "Gabor-based Kernel PCA for Palmprint Recognition," *Electronics Letters*, Vol. 43, No. 20, pp. 1077-1079, 2007.
- [3] X. Wu, D. Zhang, and K. Wang, "Fisherpalms Based Palmprint Recognition," *Pattern Recognition Letters*, Vol. 24, No. 15, pp. 2829-2838, 2003.
- [4] Y. Li, K. Wang, and D. Zhang, "Palmprint Recognition Based on Translation Invariant Zernike Moments and Modular Neural Network," *Lecture Notes on Computer Science*, Vol. 3497, pp. 177-182, 2005.
- [5] D. Zhang, W. Kong, J. You, and M. Wong, "Online Plamprint Identification," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 25, No. 9, pp. 1041-1050, 2003.
- [6] A. Kong and D. Zhang, "Competitive Coding Scheme for Palmprint Verification," *Proceedings of the 17th International Conference on Pattern Recognition*, pp. 520-523, 2004.
- [7] Z. Han, T. Tan, Y. Wang, and S.Z. Li, "Ordinal Palmprint Representation for Personal Identification," *Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition*, pp. 279-284, 2005.
- [8] W. Jia, D. Huang, and D. Zhang, "Palmprint Verification Based on Robust Line Orientation Code," *Pattern Recognition*, Vol. 41, No. 5, pp. 1504-1513, 2008.
- [9] H.K. Kalluri and M. Prasad, "Palmprint Identification Using Gabor and Wide Principal Line Features," *Procedia Computer Science*, Vol. 93, pp. 706-712, 2016.
- [10] M. Arunkumar and S. Valarmathy, "Palm Print Identification Using Improved Histogram of Oriented Lines," *Circuits and Systems*, Vol. 7, No. 8, pp. 1665-1676, 2016.
- [11] Y. Han, T. Tan, and Z. Sun, "Palmprint Recognition Based on Directional Features and Graph Matching," *Proceedings of International Conference on Advances in Biometrics*, pp. 1164-1173, 2007.

- [12] A. Morales, M.A. Ferrer, and A. Kumar, "Towards Contactless Palmprint Authentication," *IET Computer Vision*, Vol. 5, No. 6, pp. 407-416, 2011.
- [13] D.G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," *International Journal of Computer Vision*, Vol. 60, No. 2, pp. 91-110, 2004.
- [14] X. Wu, Q. Zhao, and W. Bu, "Contactless Palmprint Verification Based on SIFT and Iterative RANSAC," *Proceedings of IEEE International Conference on Image Processing*, pp. 4186-4189, 2013.
- [15] K. Sundararajan and D.L. Woodard, "Deep Learning for Biometrics: A Survey," *Journal of ACM Computing Surveys*, Vol. 51, No. 3, pp. 65:1-65:34, 2018.
- [16] D. Zhao, X. Pan, X. Luo, and X. Gao, "Palmprint Recognition Based on Deep Learning," *Proceedings of IEEE International Conference on Wireless, Mobile and Multi-Media*, pp. 214-216, 2015.
- [17] Q. Sun, J. Zhang, A. Yang, and Q. Zhang, "Palmprint Recognition with Deep Convolutional Features," *Advances in Image and Graphics Technologies*, pp. 12-19, 2017.
- [18] K. Weiss, T.M. Khoshgoftaar, and D. Wang, "A Survey on Transfer Learning," *Journal of Big Data*, Vol. 3, No. 9, pp. 1-40, 2014.
- [19] D. Jia, D. Wei, S. Richard, L-J. Li, K. Li, and F-F. Li, "ImageNet: A Large-Scale Hierarchical Image Database," *Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition*, pp. 248-255, 2009.
- [20] A. Krizhevsky, I. Sutskever, and G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Proceedings of International Conference on Neural Information Processing System*, Vol. 1, pp. 1097-1105, 2012.
- [21] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *Proceedings of International Conference on Learning Representations*, pp. 1-14, 2014.
- [22] M. Kim, "Personal Identification Using Inner Face of Fingers from Contactless Hand Image," *Journal of Korea Multimedia Society*, Vol. 17, No. 8, pp. 937-945, 2014.
- [23] L. Zhang, L. Li, A. Yang, Y. Shen, and M. Yang, "Towards Contactless Palmprint Recognition: A Novel Device, A New Benchmark, and A Collaborative Representaton Based Identification Approach," *Pattern Recognition*, Vol. 69, pp. 199-212, 2017.
- [24] COEP Palm Print Database (College of Engineering Pune), available at <http://www.coep.org.in/resources/coeppalmprintdatabase>. (accessed Aug., 2, 2018).

김민기



1989년 2월 중앙대학교 전자계산학과 이학사
 1994년 8월 중앙대학교 전자계산학과 이학석사
 1998년 2월 중앙대학교 컴퓨터공학과 공학박사

1998년~1999년 KRIC 선임연구원
 1999년~2000년 KERIS 책임연구원, 연구위원
 2000년~2010년 경상대학교 컴퓨터교육과 부교수
 2011년~현재 경상대학교 컴퓨터과학과 교수
 2013년~2014년 미국 University of Notre Dame 방문학자
 2014년~현재 경상대학교 공학연구원(ERI) 자동화·컴퓨터연구센터 책임연구원
 관심분야 : 딥 러닝, 생체인식, 패턴인식, 영상처리