

論文99-36C-4-8

오프라인 필기체 전표용 한글 인식을 위한 부분 연결 다층 신경망과 결합

(Partially Connected Multi-Layer Perceptrons and their Combination for Off-line Handwritten Hangul Recognition)

白 永 穆 * , 林 吉 澤 ** , 秦 成 一 *

(Yung Mok Baek, Kil Taek Lim, and Sung Il Chien)

요 약

본 논문은 필기체 한글인식에 적합한 모듈화된 부분연결 다층신경회로망 구조를 제안한다. 세가지 특징 베타들에 대한 세 개의 부분연결 다층신경회로망 인식기를 구성하고 이를 통합하기 위한 또 하나의 부분연결 신경회로망을 결합시킴으로써 인식률을 높일 수 있도록 설계하였다. 각각의 부분연결 다층신경회로망은 한글의 이차원적 특징을 잘 반영할 수 있도록 입력층을 10개의 수용영역으로 분할하고 입력층과 은닉층 사이를 부분 연결하였다. 결합단계에서 새로운 부분연결 신경회로망을 도입하고 그 입력으로 이미 학습된 세 개 인식기의 은닉층 출력을 이용하여 재학습한다. 제안된 인식기의 성능을 평가하기 위해서 전표처리에 많이 사용되는 한글 문자 18개를 선정하여 평가하였다.

Abstract

This paper presents a study on the off-line handwritten Hangul (Korean) character recognition using the partially connected neural network (PCNN), which is based on partial connections between the input receptive fields and the hidden nodes. The hidden nodes of three PCNNs have ten receptive fields and different input feature sets. And we introduce modular partially connected neural network (MPCNN). The MPCNN combines three PCNNs with a merging network. The learning scheme of the proposed networks is composed of two steps: PCNN learning step and the merging step of combining three PCNNs. In the merging step, another merging PCNN network is introduced and trained by regarding the hidden output of each PCNN as a new input feature vector. The performance of the proposed classifier is verified on the recognition of 18 off-line handwritten Hangul characters widely used in business cards in Korea.

* 正會員, 慶北大學校 電子電氣工學部

(School of Electronics and Electrical Engineering,
Kyungpook National Univ.)

** 正會員, 韓國 電子通信研究院

(Electronics and Telecommunications Research
Institute)

接受日字:1998年8月10日, 수정완료일:1999年3月23日

I. 서 론

성공적인 필기체 한글 인식기를 구현하기 위해서는 인식기의 구조 설계 단계에서부터 한글의 고유한 특성들이 잘 반영되어야 한다. 한글 문자의 특성은 2, 3개 이상의 자소들이 2차원적으로 배치되어 있으므로 문자 내부에 국부적으로 위치하는 개별 자소들의 분포 특성을 파악하는 것은 상당히 유용하다. 만약 자소 영역의

추출이 매우 성공적이며 신뢰성이 보장된다면 자소 기반의 인식은 그 확장성과 효율성 측면에서 상당한 이점이 있다. 그러나 필기체 한글과 같이 다양한 변형이 존재할 때는 자소 추출 자체가 매우 어려워 인식률이 상당히 저하되게 된다. 다른 방법으로 각 문자를 완성형적으로 인식을 할 경우에는 자소 추출 오류로 인한 오인식은 없으나 인식 문자 대상의 수가 증가하게 된다면 인식기의 부담이 매우 커지게 되어 인식률의 저하를 초래할 것이다. 그러므로 이러한 특성을 적절히 감안하는 인식기를 설계하는 것이 타당할 것이다.

본 논문에서는 전표용 필기체 한글을 인식하기 위해 서 위해서 기본 인식기로 다중 특징을 사용하는 다중 신경회로망을 이용하고 다중 특징상에서 구현된 개별 인식기들을 결합하여 인식률을 향상시키고자 한다. 본 논문의 실험에 적용한 대상은 전표용 필기체 한글 문자로 전체 18자로 되어있다. 그러므로 개별 자소를 인식하도록 인식기를 구성하는 것이 반드시 필수적인 것은 아니다. 그러나 문자의 다양한 변화에 대응하고 한글 구조 특성을 반영하기 위해서는 문자 정보를 획득할 때 국부 영역 정보를 중요하게 고려해야 할 필요가 있다. 필기체 한글의 2차원적으로 배치된 국부 영역 특성을 감안하여 2차원으로 배치된 수용영역과 부분 연결전략을 신경회로망 인식기의 구조 설계에 도입한다. 기준의 부분 연결 방법을 적용하는 대표적 예로 Le Cun^[1] 등은 신경회로망의 가중치 수를 줄이기 위해 가중치 공유방식을 이용한 부분 연결구조를 채용하였다. 그들의 접근 방식은 국부 수용영역의 크기가 모두 같다는 점과 대규모 다중 신경회로망을 도입하고 별다른 특징 추출 단계를 두지 않았다는 점에서 우리의 접근 방식과 다르다. 한편 필기체 숫자 인식을 위하여 Lee 등은 Kirsch마스크를 이용한 방향성 특징을 이용하고 각 방향에 따라 부분 연결구조를 가지는 “multi-layer cluster neural network을 구성하였다”^[2]. 그러나 우리는 인식기 학습을 위해 다중 특징을 사용한다. 무제약 필기체 한글문자와 같이 변형이 심한 패턴을 인식하기 위해서는 단일 특징만 사용해 높은 인식률을 얻고자 하는 것은 부적절한 것으로 사료된다. 이 경우 다중 특징의 사용이 일반적인 접근법이 되는데 이들은 다중 인식기에 적용이 된다. 실제로 인식하기가 매우 어려운 인식 대상에 대해서 최근의 연구 방향은 다중 인식기를 구현하여 이들의 인식 결과를 결합함으로써 인식률을 향상하고자 하는 것이다.

이러한 접근법은 개별 인식기 자체에 대해 높은 인식률을 얻기 위해 많은 노력을 들이지 않아도 이들을 결합함으로써 향상된 인식률을 얻을 수 있으므로 많은 연구가 진행되고 있다^[3-7]. 개별 인식기는 다양한 방법으로 구현될 수 있는데 최근의 여러 연구에서는 신경회로망을 이용한 방법이 많이 채택되고 있다. 특히 다중 퍼셉트론 신경회로망은 우수한 인식 능력과 효율성으로 인해 많이 사용되어지고 있다.

본 논문에서는 부분 연결구조를 가지는 다중 신경망 개별 인식기들의 결합을 위해 신경망 자체의 특별한 성질을 이용한다. MLP에서의 은닉층은 출력층에서의 분별을 쉽게 하기 위하여 입력 패턴 벡터들을 특별한 벡터로 변환시키는 능력이 있다^[8-10]. 이러한 MLP의 특성은^[7, 11, 12]에서의 연구들에서 응용되어진 바 있다. Ballard^[11]는 신호 및 패턴의 표현(representation)의 관점에서 계층적 구조를 가지는 은닉층의 자기 연상(autoassociation)에 대한 연구를 하였고 Waibel 등^[12]은 음소 인식에서 스케일링의 측면에서 “glue term”이라는 은닉 노드들을 가지는 은닉층의 결합에 대한 연구로 우수한 성능을 얻었다. 류강수 등^[7]은 무제약 필기체 숫자 인식을 위해서 다중 특징을 이용하여 다중 신경망을 구현하고 은닉층을 결합함으로써 우수한 인식 성능을 얻었다.

본 논문에서 우리는 무제약 필기체 한글 인식에 적합한 부분 연결구조의 다중 신경회로망과 다중 특징으로 학습된 다중 인식기를 결합하여 무제약 필기체 한글 문자를 인식하는 방법을 제안한다. 제안된 다중 신경회로망의 입력층과 은닉층 사이의 연결은 두 가지 측면을 가진다. 제안되는 부분 연결 신경망 인식기는 한글 필기 문자의 국부적인 특성을 추출하기 위하여 몇 개의 국부 수용 영역을 가지며 전역적 특성을 반영하기 위한 하나의 전역 수용영역을 가진다. 또한 우리는 다중 특징 사용 전략을 위해 거리변환 특징, 교차 거리 특징, 교차수 특징의 세가지 특징을 사용하였다. 이 세가지 특징들을 사용하여 각각의 부분 연결 신경회로망이 학습하여 세 개의 독립된 개별 인식기를 구현하였다. 구현된 각 개별 인식기들을 결합하기 위해 은닉층들을 결합하고 이를 입력으로 사용하는 새로운 부분연결 신경망을 구현함으로써 최종 인식기를 구현하였다. 오프라인 필기체 전표용 한글 인식을 위해 제안한 부분 연결 신경망들은 완전 연결 신경망에 비해 훨씬 적은 수의 가중치만으로도 보다 우수한 인식

성능을 얻었고 이들을 결합함으로써 향상된 인식 성능을 얻을 수 있었다.

II. 부분 연결신경회로망

필기체 한글 문자는 사용자의 필기 특성에 따라 다양한 변형이 발생할 수 있다. 따라서 필기 문자에 대해 불변적인 특성을 얻어내기는 아주 어렵다. 하나의 해결책으로는 국부적인 정보를 추출하고 최종 의사결정에 반영하는 것이다. 역전파 오류 학습법에 의한 대량 신경회로망은 그러한 목적으로 많이 사용되고 또한 좋은 연구 성과들이 보고되어지고 있다. 그러나 하나의 디층 신경회로망 인식기만으로는 필기체 한글인식과 같은 복잡한 문제에 있어 만족할 만한 성과를 얻기 어렵다. 따라서 우리는 먼저 필기체 한글인식에 적합한 부분연결 신경회로망(PCNN: partially connected neural network) 구조를 제안한다. 그 구조는 그림 1에 나타나 있다. 한글 문자와 같은 2차원 구조의 입력 패턴에 대한 국부 정보를 얻기 위해 PCNN의 은닉 노드들은 고유한 수용 영역을 가진다. 수용 영역은 그림 1에서 흰색 사각형으로 표현되어 있다. 여기서 비수용 영역(음영이 들어간 영역)에서는 특징이 추출되지 않는다. 수용영역은 10개로 구성되고 한글 구조에 대한 사전정보에 의해서 이웃 수용 영역들과 조금씩 겹치도록 배치된다.

그림 2에 10개의 수용 영역 형태가 나타나 있다. 첫 번째 수용영역은 입력영상 전체를 포함하여 패턴의 전역적인 정보를 얻고자 하는 형태이다. 나머지 9개 수용영역은 입력 패턴을 9개의 부 영역으로 분할하고, 인접 수용 영역들과 조금씩 겹쳐진 형태이다. 이러한 연결구조를 통해 국부적인 정보가 특정 수용영역에서는 손실되더라도 다른 수용영역에서 다시 보상될 수 있다. 효율적인 학습과 인식을 위해 입력 패턴은 신경망 입력으로 들어가기 전에 특징 벡터로 변환된다. 필기 한글은 변형이 심하므로 복잡한 패턴에 대해서는 다양한 특징을 사용하고 각 특징에 적합한 여러 인식기를 구성하여 통합하는 것이 바람직하다. 디중 인식기 학습과 통합문제에 앞서 먼저 본 연구에서 사용한 특징에 대해서 간단히 서술한다. 특징 추출에 있어서 새로운 개념의 도입은 없지만 사용되는 특징은 인식기의 성능을 좌우하는 중요한 요소 중 하나이므로 분명히 설명할 필요가 있다.




그림 1. 학습단계의 PCNN구조
Fig. 1. PCNN structure of learning stage.




그림 2. 10개의 수용영역
Fig. 2. Ten receptive fields for PCNN.

거리변환 특징^[13]: 거리변환을 하기 위해서 배경영역의 한 점을 선택한다. 그리고 그 점으로부터 가장 가까운 글자 영역에 속하는 혹화소 간의 거리를 추출한다. 모든 혹화소에 대해서는 거리를 0으로 할당한다. 거리변환은 두개의 마스크를 이용하여 두 번의 래스터스캔으로 구현이 가능하다. 글자 '일'에 대한 거리변환 예가 그림 3에 나타나있다. 거리 변환영상을 14x12부 영역으로 분할하고, 부 영역 내부의 거리 값들을 적절한 크기 정규화를 통해 168 차원의 특징을 추출한다.




그림 3. 문자 '일'에 대한 거리변환 예
Fig. 3. Example of distance transform of character 'il'.

교차수 특징 [14] : 교차수는 세선화된 문자영상으로부터 구해진다. 세선화된 골격선의 한 점을 기준으로 주변 8방향 이웃 화소를 검색하여 다음 식을 이용하여 구할 수 있다.

$$\text{Crossing number} = \frac{\sum_{k=0}^7 |N(k+1) - N(k)|}{2} \quad (1)$$

여기서 $N(k)$ 는 화소값으로 0 또는 1의 값을 가진다. 따라서 교차수는 1, 2, 3 또는 4가 될 수 있다. 획득된 교차수는 끝점, 굴곡점, 연결점, 분기점을 의미한다. 교차수 특징은 각 수용 영역내에서의 끝점, 굴곡점, 연결점, 분기점의 수를 정규화하여 구성하였다. 문자 '일'에 대한 교차수 추출 결과 예를 그림 4에 나타냈다.




그림 4. 세선화된 문자 '일'에 대한 crossing number 특징

Fig. 4. Crossing numbers detected from the thinned image '일'.




그림 5. 교차거리 특징에 대한 수용영역과 거리 추출을 위한 방향성분

Fig. 5. Receptive fields for the cross distance feature and reference directions to measure cross distance.

교차거리 특징 : 수용영역 외부 경계선에서 내부의 혹 화소를 처음 만나는 지점까지의 거리를 특징으로 이용할 수 있다. 교차거리는 모든 경계선에서 추출할 수 있다. 교차거리를 추출하기 위한 검출선은 균등히 분포해 있고, 한글의 특징 추출에 적합하도록 그림 5와 같이 각 수용 영역 위치에 따라 고유한 방향으로 배치된다.

이상에서 언급된 세 가지 입력 특징들에 근거하여 서로 다른 특성을 나타내는 PCNN들을 구성하였다. PCNN의 은닉층은 10개의 은닉노드 그룹으로 구성되고 각 그룹은 그림 1에 나타난 것과 같이 입력 공간에서 고유한 수용 영역을 가진다. 각 은닉노드 그룹은 고유한 수용영역 사이에만 가충치 연결을 가지고 있고 다른 수용 영역들과는 연결되지 않는다. 10개의 수용 영역은 9개의 국부영역과 전 입력공간을 포함하는 하나의 영역으로 구성된다. 수용영역의 크기와 특징 벡터의 차원은 사용되는 특징에 따라 서로 다르다. 다양한 배치의 수용영역과 다중 특징을 사용하는 것은 한글문자의 2차원적 배치 형태와 필기 문자의 변형을 수용하고자 함이다. PCNN의 출력층과 은닉층 사이는 완전 연결구조를 가지고 있다.

III. 모듈화된 부분 연결 신경회로망

이 절에서는 신경회로망으로 구현된 다중 인식기들을 결합하는 방법을 설명한다. 학습된 다중 신경회로망에 있어서 은닉 노드들은 특징 추출기 역할을 수행하므로 은닉층의 출력 값들은 새로운 특징 벡터로 간주될 수 있다^[1,8-10]. 만일 은닉 노드들의 수가 입력 차원 보다 적다면 은닉층 출력은 고차원 입력의 저차원 투영으로 볼 수 있다. 즉 입력벡터의 불필요한 정보들이 은닉층을 통과하면서 변환되어 중요한 정보들만 남기게 된다. 신경망의 은닉층은 "Discriminant Analysis"를 행하는 것으로 알려져 있어 입력 패턴 벡터들에 대한 새로운 특징추출기로 동작하며 출력층은 은닉층의 출력 벡터값을 최종 인식하는 역할을 한다고 볼 수 있다^[9,10]. 따라서 학습된 신경회로망의 출력층을 제거하고 은닉층에서 출력 벡터를 얻어내는 새로운 특징 추출기를 구성할 수 있다. 실제로 류강수^[7] 등은 이러한 은닉층의 출력 벡터들을 이용하여 다중 인식기를 결합하여 향상된 인식률을 얻을 수 있었다. 본 논문에서는 이와 같은 방법으로 입력 특징에

서 보다 향상된 특징을 추출한다.




그림 6. TSN구조: PCNN이 특징집합 x로 학습된 후 출력층이 제거된 형태

Fig. 6. Truncated sub-network (TSNx) structure after learning for a feature set x.

그림 6은 학습된 PCNN으로부터 얻어진 새로운 특징 추출기인 TSN(truncated sub-network) 구조를 보여준다. 한번 학습되고 출력층이 제거된 TSN들을 통합하기 위한 새로운 PCNN을 도입하는데, 이 새로운 PCNN은 여러 TSN들의 출력을 입력 벡터로 사용한다. 여러 개의 TSN모듈을 하나의 통합 PCNN에 연결시키는 이러한 구조를 우리는 모듈화된 부분연결 신경회로망(MPCNN: Modular Partially Connected Neural Network)으로 부르기로 한다.




그림 7. 세가지 특징을 병합하는 MPCNN 구조

Fig. 7. Structure of MPCNN combining three different feature sets.

그림 7에 묘사되어있듯이 MPCNN은 일반적인 3층 구조를 가진다. TSN내부 가중치들은 이미 한번 학습되어 있으므로 MPCNN학습시 더 이상의 가중치 변경은 없다. MPCNN의 은닉층의 노드들은 4개의 그룹으로 구성된다. 세 개의 그룹은 세 개의 TSN과 각각 연결되고 나머지 하나의 그룹은 세 개의 TSN출력과 모두 연결되는 구조를 가진다. 은닉층이 입력층과 부른 연결된데 반해, 출력층과 은닉층은 완전 연결된다.

따라서 제안된 구조는 국부적인 정보와 전역적인 정보를 잘 흡수하고 또한 다중 특징들을 잘 결합할 수 있다. 다중 인식기를 결합하는 기술들이 많이 연구되어 왔지만 제안한 MPCNN이 상대적으로 구조가 단순하고 구현이 용이하다. 또한 제안된 인식기는 부분 연결을 가지고 모듈화된 구조를 가지므로 가중치의 수가 작고 대규모 필기체 인식문제로의 확장도 쉬울 것으로 판단된다.

IV. 실험 결과 및 고찰

필기체 한글 인식대상으로 국내 은행 등에서 많이 사용되는 전표용 한글 18자를 선정하였다. 실험에 사용할 데이터 베이스로 360명에 대해 38880자를 수집하였다. 각 사람이 18자에 대해서 6번씩 필기 하였다. 학습용으로 200명의 데이터인 21600자를 사용하였고 나머지 160명의 17280자를 테스트 용으로 사용하였다.

일 이 삼 사 오 육 칠 팔 구
신 백 천 만 억 조 원 정 금
일 이 삼 사 오 육 칠 팔 구
십 백 천 만 억 조 원 정 금
일 이 삼 사 일 육 칠 팔 구
십 백 천 만 억 조 원 정 금

그림 8. 18개 한글 문자영상의 예

Fig. 8. Examples of three sets of 18 off-line handwritten Hangul characters.




그림 9. 은닉층 노드수에 따른 인식기의 성능 비교

Fig. 9. Comparison of recognition rate for the FCNNs and PCNN.

그림 8은 학습에 사용된 필기 문자 예를 보여준다.

표 1은 오류 역전과 학습법으로 구성된 일반적인 완전 연결 다중 신경회로망 인식기와 PCNN 인식기의 인식성능을 비교해 놓았으며 그림 9는 은닉층의 노드수를 다르게 했을 때 일반적인 완전 연결 신경망(FCNN: fully connected neural network) 인식기의 성능과 PCNN의 성능을 그래프로 표현하였다. 표 1과 그림 9를 참조해서 보면 PCNN이 전체 가중치는 훨씬 적고 인식률은 더 좋음을 알 수 있다. 표 1에서 PCNN이 세개의 FCNN에 비해서 각각 55.71%, 45.55%, 28.79%의 가중치로 구성되었지만 보다 나은 인식률을 나타내므로 제안한 구조의 PCNN이 상당히 효율적임을 알 수 있다.

표 1. PCNN과 FCNN의 인식률

Table 1. The recognition rates of PCNNs and FCNNs without rejection.

Features	Type of connection	No. of hidden nodes	No. of Weights	Recognition rate(%)
Cross distance Feature	FCNN	80	13698	89.9
	PCNN	129	7641	90.3
Crossing number Feature	FCNN	80	14978	90.4
	PCNN	108	6822	91.6
Distance transform Feature	FCNN	80	14978	91.9
	PCNN	94	4312	93.1
Hidden outputs of PCNNs	MPCNN	79	11293 (24056*)	95.3

(*: In the case that the number of all three TSNs weight is summed to that of MPCNNs weights.)

마지막으로 세 개의 각 PCNN과 이들의 은닉층을 결합한 MPCNN의 인식률을 보여준다. 여기서 MPCNN이 가장 우수한 인식률을 나타냄을 볼 수 있다.



그림 10. 오인식을 일으키는 문자 예

Fig. 10. Examples of missclassified handwritten Hangul characters.

그림 10에 오인식을 일으킨 문자의 예를 나타내었고 표 2에 인식기의 혼돈표(confusion table)를 나타내었다. 입력 문자 클래스가 '이', '사', '오', '구'의 경우 상당히 높은 인식률을 나타내는데 이는 글자 모양이 단순하고 2개의 자소만으로 구성되어 있어 문자의 복잡도가 상대적으로 낮기 때문인 것으로 보인다.

반면 인식률이 낮게 나타나서 전체 인식률에 영향을 많이 끼치는 입력 클래스로 '칠'과 '원'이 있다. '칠'의 경우 '천'과 '원' 그리고 '일'로 판정되는 경우가 많았는데 한글 문자의 형태상 매우 유사한 형태를 지니기 때문에 오인식의 확률이 높아진다. '원' 클래스의 문자가 입력되었을 경우 특히 '천'으로 오인식한 경우가 많았는데 이는 충분히 이해할 만하다.

다른 클래스들의 경우에서도 오인식의 유형은 문자의 형태가 비슷한 곳에서 많이 일어남을 알 수 있다. 이러한 경우 MPCNN의 인식결과에 이를 검증 및 보완 할 수 있는 부가적인 보조 인식기를 구현함으로써 보다 우수한 인식률을 충분히 얻을 수 있으리라 사료된다. 또한 오인식의 원인은 획이 비정상적으로 길거나 또는 자소가 아주 작게 필기된 경우 등, 필기자의 개인별 특성에 따라 다양한 형태로 나타난다. 몇몇 글자들은 사람이 보기에도 구분하기 어려울 정도이다.

비록 무제약 필기체 문자에 대해서 상당히 좋은 인식률을 얻었지만, 더 많은 문자들을 인식할 수 있고 상업적으로 가치가 있도록 하기에는 아직 더 많은 연구가 뒤따라야 할 것이다. 부분 연결구조와 다중 인식기를 모듈화하여 통합하는 방식이 필기체 한글과 같이 복잡하고 인식대상의 수가 많을 때 아주 적합한 모델이 될 것으로 판단된다.

V. 결 론

본 논문에서는 오프라인 필기체 한글 문자 인식에 적합한 부분연결 신경회로망과 여러 인식기를 통합할 수 있는 모듈화된 부분 연결 신경회로망 구조를 제안하였다. 모듈화된 부분 연결 신경회로망의 입력으로는 여러 인식기의 출력층을 제거한 TSN 구조를 도입함으로써 기존의 입력특징 벡터로부터 새로운 특징을 자동으로 추출할 수 있도록 하였다. PCNN과 MPCNN 구조는 부분 연결구조를 가지므로 적은 수의 가중치로 높은 인식률을 보장하도록 하였다. 실험결과에서 부분 연결 신경망 구조가 일반적인 다중 신경망 보다 필기

표 2. 제안된 MPCNN에 의한 개별글자에 대한 인식결과

Table 2. The recognition result of 18 characters using the MPCNN.

Output Input	일	이	삼	사	오	육	칠	팔	구	십	백	천	만	억	조	원	정	금	Recog. rate(%)
일	905	2	1	1	7	0	7	11	0	6	0	0	7	2	1	9	0	1	94.2
이	0	948	0	0	0	0	0	0	1	0	0	0	0	10	1	0	0	0	98.9
삼	4	0	885	6	1	1	2	5	0	36	1	5	9	0	2	0	0	3	92.2
사	2	4	3	938	0	2	0	0	5	5	0	0	0	0	1	0	0	0	97.7
오	2	0	1	0	947	3	0	0	1	0	0	0	0	0	6	0	0	0	98.6
육	2	0	0	0	2	936	0	3	3	0	0	0	0	3	1	2	0	8	97.5
칠	11	0	0	2	0	1	849	16	1	1	0	49	0	1	0	19	6	4	88.4
팔	1	0	2	0	0	1	8	921	0	1	0	4	14	0	4	2	1	1	95.9
구	0	0	0	6	0	8	1	0	938	0	0	0	0	0	4	0	0	3	97.7
십	4	0	12	1	0	0	2	0	0	925	0	4	0	0	0	1	11	0	96.4
백	0	2	0	0	0	3	1	1	0	0	927	6	2	15	0	0	3	0	96.6
천	0	1	1	4	1	0	16	0	0	4	0	892	0	1	1	19	16	4	92.9
만	10	1	5	6	2	0	0	17	1	2	0	2	911	1	0	2	0	0	94.9
억	7	7	0	1	1	15	0	0	3	0	16	0	0	906	0	2	2	0	94.4
조	0	0	3	0	8	1	1	4	0	2	0	0	0	1	934	0	0	6	97.3
원	7	0	0	0	0	2	8	6	0	2	0	53	3	1	1	876	1	0	91.3
정	0	2	4	4	0	0	4	4	2	12	1	19	0	2	1	0	902	3	94.0
금	0	0	1	0	1	1	2	1	3	2	0	0	0	1	7	3	3	935	97.4
Recognition rate: 95.3% (16475/17280)																			

체 한글 문자 인식에 있어서 좀더 효율적임을 알 수 있다. 제안된 MPCNN은 서로 다른 특성을 나타내는 3개의 부인식기를 성공적으로 결합하였고, 개별 인식기보다 향상된 인식률을 나타내었다.

참 고 문 헌

- [1] Y. Le Cun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, "Handwritten Digit Recognition with a Back-Propagation Network," Advances in Neural Information Processing System 2 (D. S. Touretsky, ed.), pp. 396-404, San Mateo, CA: Morgan Kaufmann, 1990.
- [2] S. W. Lee, Y. J. Kim, and M. W. Kim, "Multilayer Cluster Neural Network for Off-line Recognition of Totally Unconstrained Handwritten Numerals," the 4th IWFHR, Taipei, Taiwan, Republic of China, pp. 115-124, Dec. 1994.
- [3] L. Xu, A. Krzyzak, and C. Y. Suen, "Methods of Combining Multiple Classifiers and Their Applications to Handwriting Recognition," IEEE Trans. Systems, Man, and Cybernetics, Vol. 22, No. 3, pp. 418-435, 1992.
- [4] D. Lee and S. N. Srihari, "A Theory of Classifier Combination: the Neural Network Approach," in Proc. of the Third International Conference on Document Analysis and Recognition, Montreal, Canada, Vol. 1, pp. 42-45, 1995.
- [5] T. K. Ho, J. J. Hull, and S. N. Srihari, "Decision Combination in Multiple Classifier Systems," IEEE Trans. Pattern

- [6] Analysis and Machine Intelligence, Vol. 16, pp. 66-75, 1994.
- [6] 백종현, 조성배, 이관용, 이일병, “이중 결합 구조를 갖는 다중 인식기 시스템,” 한국정보과학회 '96 봄학술발표논문집, pp. 281-284, 1996
- [7] 류강수, 진성일, “모듈화된 신경회로망 중간층 출력의 재학습에 의한 필기체 숫자 인식,” 한국정보과학회 논문지, 제23권, B편, 제9호, pp. 931-940, 1996
- [8] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning Internal Representation by Error Propagation,” In Parallel distributed processing: Explorations in the Microstructure of Cognition (D. E. Rumelhart and J. L. McClelland, eds.), Vol. 1, Chapter 8, Cambridge, MA: MIT Press, 1986.
- [9] A. R. Webb and D. Lowe, “The Optimised Internal Representation of Multilayer Classifier Networks Performs Nonlinear Discriminant Analysis,” Neural Networks, Vol. 3, pp. 367-375, 1990.
- [10] P. Gallinari, S. Thiria, F. Badran, and F. Fogelman-Soulie, “On the Relations Between Discriminant Analysis and Multilayer Perceptrons,” Neural Networks, Vol. 4, pp. 349-360, 1991.
- [11] D. H. Ballard, “Modular Learning in Neural Networks,” Proc. Of the Sixth Annual Conference on Artificial Intelligence, Seattle, WA, pp. 279-284.
- [12] A. Waibel, H. Sawai, and K. Shikano, “Modularity and Scaling in Large Phonemic Neural Networks,” IEEE Trans. Acoustics, Speech, and Signal Processing, Vol. 37, pp. 1888-1898, 1989.
- [13] G. Borgefors, “Distance Transformations in Digital Images,” Computer Vision, Graphics, and Image Processing, Vol. 34, pp. 344-371, 1986.
- [14] 김기철, 김영식, 이성환, “필기체 한글의 오프라인 인식을 위한 회 정합 방법,” 대한전자공학회논문지, 제30권, B편, 제6호, pp. 604-613, 1993

저자 소개



白永穆(正會員)

1968년 10월 26일생. 1993년 2월 경북대학교 전자공학과 졸업(공학사). 1995년 2월 경북대학교 대학원 전자공학과 졸업(공학석사). 1999년 2월 경북대학교 대학원 전자공학과 졸업(공학박사). 1999년 3월 ~ 현재 국방과학연구소 선임연구원. 주관심 분야는 컴퓨터 비전, 패턴인식, 영상처리

林吉澤(正會員) 第 35 卷 C 編 第 6 號 參照

한국전자통신연구원 우정기술연구부
선임연구원

秦成一(正會員) 第 32 卷 S 編 第 9 號 參照

경북대학교 전자전기 공학부 교수