

論文94-31B-1-10

# 자소 인식 신경망을 이용한 한글 문자 인식에 관한 연구

## (A Study on Hanguel Character Recognition using GRNN)

張錫眞\*\*\*, 姜仙美\*\*, 金赫九\*, 盧宇埴\*, 金惠鎮\*

(Seok Jin Jang, Sun Mee Kang, Hyeog Gu Kim,  
Woo Shik Rho and Duck Jin Kim)

### 要約

본 논문에서는 자소 인식 신경망을 이용하여 인쇄체 한글 문자를 인식하는 방법을 제안하였다. 이 연구에서 신경망은 상세분류 과정에만 적용되며 대분류 과정은 원형 정합법을 사용하여 수행하였다. 신경망에 학습될 자소를 전체 문자 영상에서 분리시키기 위해 구조 해석법을 사용하였다. 자소 인식 신경망은 분리된 자소의 종류와 형태에 대응되도록 구성되었으며 각각의 신경망은 다층퍼셉트론으로 이루어져 있다. 학습알고리즘은 수정된 오류역전파 알고리즘을 사용하였다. 5개의 다중 폰트, 다중 크기의 한글 세트를 대상으로 수행한 실험에서 평균 94.95%의 인식율을 얻었다.

### Abstract

This paper describes the recognition of the printed Hanguel(Korean Character) using Neural Network. In this study, Neural network is used in only specific classification. Hanguel is classified globally by using template matching. Neural network is learned using the segmented grapheme. The grapheme of Hanguel is segmented using the structural method. Neural network is constructed, which is corresponded to the kind and the shape of graphemes. Each neural network is multi layer perceptron. The learning algorithm is the modified error back propagation using descending epsilon method. With five test character sets, the recognition rate of 94.95% is obtained.

### 1. 서론

신경망에 관한 연구는 원래 신경 생물학의 연구와

심리학에서의 여러 관찰들을 설명하기 위한 시도로부터 시작되었으며, 그 연구 과정에서 창출된 여러 모델이 패턴 인식을 비롯한 인공지능의 여러 분야에서 널리 사용되고 있다. 이와 같은 신경망의 일환으로서 인간 두뇌의 시각 시스템과 유사한 구조를 갖는 신경망 모델을 구성하여 문자 패턴을 인식하려는 연구가 여러 연구소와 대학등에서 이루어지고 있다. 이미 국외에서는 신경회로망을 사용하여 영문자, 숫자, 일본의 가나문자등을 대상으로 좋은 연구 성과가 발표되었고, 미국의 네스토(Nestor)사에서 개발한 한자 인식 시스템처럼 신경망을 이용한 문자 인식기가 구현

\*正會員, 高麗大學校 大學院 電子工學科  
(Dept. of Elec. Eng., Korea Univ.)

\*\*正會員, 高麗大學校 附設情報通信技術共同研究所  
(Korea Telecom. Roarch Institute)

\*\*\*正會員, 韓國電子通信研究所  
(Electronics Telecom. cation Rearch Institute)

接受日字: 1993年 2月 13日

되었다.<sup>11)</sup>

국내에서도 인쇄체 한글, 필기체 한글등을 대상으로 신경망 모델을 이용한 여러 연구 결과가 발표되었으며, 그 기본 모델을 중심으로 크게 3부류로 나뉘어 질 수 있다. 즉, BP(Back Propagation) 모델, 네오코그니트론 모델 그리고 이외의 독자 모델이라고 불릴 수 있는 모델이 이에 해당된다. 먼저 BP 모델은 모델 자체가 단순하면서도 여러 응용분야에서 좋은 결과가 보고 됨으로써 가장 광범위하게 사용되며, 현재까지의 연구는 주로 한글의 특성을 이용하는 방식을 선택하고 있다.<sup>2)</sup> 네오코그니트론을 기본 모델로 한 연구는 필기체 문자 인식에 주로 응용되고 있으며<sup>3)</sup>, 기존의 여러 모델을 계층적으로 연결하여 대규모 신경회로망을 구축하거나<sup>14)</sup> 혹은 한글 문자 인식에 적합한 새로운 모델을 생성하는 방법들이 소개되고 있다. 그러나 이러한 신경망들은 아직까지는 문자의 수가 방대한 한글을 분리해 내지 못하고 적은 수로 한정된 한글만을 대상으로 실험을 수행하였으며, 인식율도 기존의 인식방법으로 얻어낸 인식율보다 더 좋은 결과를 나타내지 못했다.<sup>12)</sup>

본 연구는 기존 연구된 신경망을 이용한 인쇄체 한글인식 방법에서 나타난 결점들을 극복하기 위하여 다음 모델을 제안하였다. 입력 문자 영상의 자소별 위치를 일률적으로 정하여 학습시킨 기존의 방법<sup>15)</sup>과는 달리 입력 문자를 자소별로 분리시킨뒤 학습하였다. 또한 기존의 방법이 문자의 형식분류, 상세분류 과정 전부를 신경회로망을 이용하여 수행시킨 것과는 달리 본 연구는 대분류되어 분류된 적은 수의 후보 코드에 대해서만 신경망을 이용하여 상세분류를 수행함으로써 많은 문자 패턴을 분류해 내야하는 부담(load)을 줄였다.

### II. 특징소 추출 및 특징벡터 구성

본 장에서는 입력된 문자영상에서 특징소를 추출하여 특징벡터를 구성하는 방법에 대해 간략하게 소개하였으며, 참고문헌 [7] 에 상세한 내용이 기술되어 있다.

#### 1. 특징소의 추출

32×32의 크기로 정규화된 문자영상에 문자의 윤곽선 부분의 방향정보를 얻기 위하여 정의된 특징소 추출 템플리트를 적용시키면, 문자영상의 외곽 화소부터 위치 및 방향정보를 얻게된다. 사용되는 방향성 분은 수평, 수직, 사선, 역사선의 4종류로서 각 영역

에 따라 같은 종류의 방향성분들의 합이 특징소로 추출된다.

#### 2. 특징벡터의 구성

추출된 특징소에 대해 문자변위에 대처하기 위하여 다음과 같은 방법으로 특징벡터를 구성한다. 정규화된 입력문자가  $2^N \times 2^N$ 의 크기(본 연구에서는  $N=5$ )를 갖을때,  $2^N$ 길이만큼 중첩하여 9개의  $2^{N-1} \times 2^{N-1}$ 의 소영역을 만든다. 각 소영역을 다시  $2^{N-3}$ 길이만큼 중첩시켜 9개의  $2^{N-2} \times 2^{N-2}$ 의 소영역으로 만든다. 이와같은 절차를 소영역으로 분할 가능할 때까지 계속하여 문자영역을 9진트리에 대응시키면 9진트리의 뿌리(Root)는 정규화된 문자영역의 전체에, 잎(Leaf)은  $2^1 \times 2^1$ 의 소영역에 해당된다. 9진트리의 모든 노드(node)는 4방향의 특징소에 각 노드에 대응되는 가중치를 곱하여 얻은 4방향의 특징벡터를 갖으며, 임의 노드의 각 특징벡터는 그 노드에서 분기되는 9개의 부노드(Subnode)가 갖는 특징벡터의 합으로 만들어진다.

### III. 대분류 과정

입력된 문자영상과 대응될 수 있는 후보문자들을 전체 인식 대상문자에서 선택해내는 대분류 방법은 미지(未知)의 문자영상에서 추출된 특징벡터와 평균 특징벡터와의 거리 계산법으로 이루어진다. 거리 계산시 기준이 되는 평균특징벡터를 구하기 위해 표준용 문자세트들(DB 1-10)을 이용하였다. 실험에 사용된 문자세트들(표준용 및 시험용)은 명조체를 기본으로 다양한 프린터와 한글 워드프로세서에서 제공되는 폰트에 대한 것으로서, 일반적으로 많이 쓰이고 있는 문자크기 별로 프린트하여 스캐너(300dpi)로 읽어서 제작된 것이다. 표 1은 본 실험에서 이용된 한글 문자세트를 나타낸다.

표 1. 실험을 위해 사용된 한글 문자세트

Table 1. Hanguel character sets for experiment.

| 사용용도 | 문자세트     | Font / 프린트 기종   | 문자크기(화소)     |
|------|----------|-----------------|--------------|
| 표준용  | DB 1, 2  | 명조체 (삼성)        | 56×56, 56×56 |
|      | DB 3, 4  | 명조체 (삼보)        | 40×40, 40×40 |
|      | DB 5, 6  | 명조체 (H.P)       | 45×45, 45×45 |
|      | DB 7, 8  | 명조체 (Macintosh) | 46×46, 54×54 |
|      | DB 9, 10 | 명조체 (Macintosh) | 46×46, 54×54 |
| 시험용  | DB 11    | 명조체 (삼성)        | 52×52        |
|      | DB 12    | 명조체 (삼보)        | 40×40        |
|      | DB 13    | 명조체 (H.P)       | 45×45        |
|      | DB 14    | 명조체 (Macintosh) | 50×50        |
|      | DB 15    | 명조체 (Macintosh) | 50×50        |

거리 계산을 위해서는 패턴 인식에서 기본적으로 가장 많이 쓰이는 유클리드 거리(Euclidean distance)를 이용하였다. 표 2는 시험용 문자 데이터베이스에 대한 누적 분류실험 결과로서 후보문자 5위 이내에 분류될 평균 누적 분류율은 98.65%을 나타내고 있다. 시험용 데이터베이스 11에 대한 실험 결과는 제시하지 않았다. 그 이유는 문자영상 데이터베이스의 일부가 손상되어 대상문자 2350자에 대한 정확한 분류결과를 얻을 수 없었다.

표 2. 각 문자 세트별 누적 분류율(대상문자: 2350자)

Table 2. The classification rate of each character set.

(단위: %)


| DB | 후보문자순위 | 1     | 2     | 3     | 4     | 5     |
|----|--------|-------|-------|-------|-------|-------|
| 12 |        | 87.06 | 96.26 | 97.96 | 98.81 | 99.19 |
| 13 |        | 72.98 | 88.21 | 93.57 | 95.74 | 97.15 |
| 14 |        | 83.40 | 94.77 | 98.17 | 98.81 | 99.11 |
| 15 |        | 83.11 | 95.23 | 98.00 | 98.81 | 99.15 |

#### IV. 신경망을 이용한 문자 인식


##### 1. 자소 인식 신경망(GRNN)의 구성

단순한 BP 모델을 문자인식에 그대로 적용할 경우 많은 수의 문자 학습이 어렵다는 것이 실험적으로 나타났다.<sup>5)</sup> 본 연구는 이러한 어려움을 극복하기 위하여 각 자소별로 학습되고 자소별로 인식하는 자소 인식 신경망(Grapheme Recognition Neural Network)을 구성하였다. 한글은 구조적 특성상 초성, 중성, 종성의 3가지 종류의 자소로 구성되어 있으며, 그림 1은 한글의 형태와 6가지 유형을 나타내었다.

초성인 경우 수평모음의 유무에 따라 1형식과 3형식의 자소 형태가 비슷하고 2, 4, 5, 6형식끼리 자소 형태가 닮았다. 따라서 초성을 인식하는 신경망은 초성 인식 신경망 I (1,3형식), II (2,4,5,6형식)로 구분된다. 중성은 1형식과 3형식(나, 내, 나, 비, 기, 케, 키, 케, 리), 2형식과 4형식(나, 내, 나, 너, 네, 너, 니), 5형식과 6형식(나, 너, 나, 너, 네, 너, 니)끼리 사용되는 모음의 종류가 정해져 있다. 따라서 중성을 인식하는 신경망은 중성 인식 신경망 I (1,3형식), II (2,4형식), III (5,6형식)로 구분된다. 종성은 받침이 없는 1, 2, 5



(a)



(b)

그림 1. 한글의 형태 및 유형

(a) 한글의 형태 (b) 한글의 유형

Fig. 1. The format and the type of Hangeul.

(a) the format of Hangeul.

(b) the type of Hangeul.

형식을 나타내는 종성 인식 신경망과 받침이 있는 3, 4, 6형식의 받침형태를 구별해내는 종성 인식 신경망 II로 구분된다. 그림 2는 분리된 자소를 자소의 종류와 문자의 유형에 따라 학습하는 전체 모습을 나타냈다.

각각의 자소 인식 신경망은 다층 퍼셉트론으로 이루어져 있으며 입력층 노드의 수는 100개, 은닉층의 수는 1개, 출력층 노드의 수는 30개 그리고 출력층




그림 2. 신경망의 자소별 학습을 위한 전체적인 과정

Fig. 2. The overall course for grapheme learning of neural network.

노드의 수는 각 자소 인식 신경망에 따라 2개에서 27개까지 이루어져 있다. 본 연구에서는 활성화 함수(activation function)로 BP 신경망 모델에서 많이 사용되는 시그모이드(sigmoid) 함수를 사용하였다.<sup>[5]</sup>

2. 자소의 분리

각 신경망이 자소별로 학습과 인식을 하기 위하여 입력된 문자 영상을 초성, 중성, 종성별로 분리해 내는 과정이 필요하다. 문자 영상의 자소 분리 방법은 문자 영상을 6가지의 유형으로 분류해 내고, 거기에서 얻은 정보를 이용하여 자소를 분리해내는 2단계로 구성된다. 그림 3은 유형 결정을 위한 판별 트리를 나타내며 그림 4는 입력 문자의 분리된 자소 형태를 보여주고 있다.<sup>[5, 10]</sup>




그림 3. 유형 결정을 위한 판별 트리  
Fig. 3. The decision tree for the determination of the type.



그림 4. 분리된 자소의 예  
Fig. 4. The example of the segmented grapheme.

3. 자소별 학습

(1) 분리된 자소의 방향 벡터 추출

본 절에서는 신경망에서 요구되는 입력값들을 얻기

위해 분리된 자소에서 방향 벡터를 추출하는 방법을 보이고 있다. 분리된 자소를 5×5 화소 크기의 소영역으로 분할함으로써, 전체 패턴을 25개 소영역으로 구성한다. 각각의 소영역은 사선, 수직, 역사선, 수평 방향의 4개 방향에 대한 방향 벡터를 갖게되며 그 방향 벡터가 신경망 모델의 입력으로 사용된다. 그림 5는 분리된 자소에서 추출된 방향 벡터를 보이고 있다.




그림 5. 자소에서 추출된 방향 벡터  
Fig. 5. The directional vector extracted from the grapheme.

(2) 학습 알고리즘

식 1)로 표시되는 시스템 오차의 값을 최소로 하는 오류 역전파 알고리즘에 의해 신경망을 학습시키면 전체 입력 문자와 학습 방향이 다른 소수의 입력이 제대로 학습되지 못하여 전체 신경망의 인식율을 저하시키는 원인으로 작용한다. 또한, 비록 출력 노드 전체의 오차는 적은 값을 갖도록 학습되었더라도 일부 출력 노드의 오차는 큰 상태로 학습이 끝나는 수가 있다. 신경망을 이용하여 다중 활자체 한글을 인식하는 경우와 같이 하나의 출력 노드에 대응될 입력이 상호 큰 차이를 보이는 경우에는 유사한 다른 자소를 해당 자소의 변형으로 부터 확실히 구분할 수 있어야 한다. 또한 이러한 많은 변형종의 일부가 학습되지 않은 입력으로 존재할 가능성이 높으므로 이를 처리할 수 있는 방법이 고안되어야 한다. 이와같은 문제는 오류 역전파 알고리즘에 descending epsilon 기법을 적용시킴으로써 해결이 가능함을 보였다.<sup>[5, 6]</sup> 본 연구에서도 descending epsilon 기법을 적용한 수정된 오류 역전파 알고리즘을 학습 알고리즘으로 채택하였으며, 시스템 오차는 식 2)를 사용하였다.

$$E = \frac{1}{2} \sum_{p=1}^m \sum_{k=1}^n (t_{pk} - O_{pk})^2 \quad (1)$$

$$E = \frac{1}{2} \cdot \sum_{p=1}^m \sum_{k=1}^n (\text{number of } (|t_{pk} - O_{pk}| > \epsilon)) \quad (2)$$

- 단.  $p$  : 입력패턴의 개수
- $k$  : 출력층에 있는 노드의 개수
- $t_{pk}$  : 기대되는 출력값
- $O_{pk}$  : 출력층에 있는 노드의 출력값

즉, 기대되는 출력값과 실제적인 출력값 사이의 오차가 어느 임계값 이상되는 것만을 총 오차 값에 포함시킨다. Descending epsilon 기법의 전체적인 알고리즘은 다음과 같다. 먼저, 적당한 임계값을 선정한다. 학습과정에서 출력층 노드의 오차가 이 임계값보다 작으면 그 노드에서의 오차값을 0으로 가정하여 학습에 영향을 미치지 않게한다. 이 임계값을 가지고 모든 입력 패턴의 학습이 끝났으면 임계값의 크기를 낮추고 학습을 다시 시작한다. 임계값이 적당한 값으로 낮춰 졌을때까지 이상과 같은 과정을 반복한다.

4. 상세 분류 과정

본 연구에서는 대분류과정에서 얻어진 후보 문자들에 상세분류를 적용하여 최종 인식 문자를 선정한다. 상세분류과정에서는 학습된 신경망을 이용하였으며 다음과 같은 순서로 진행된다.

- 첫째:** 입력된 문자 영상의 자소를 분리해 낸다.
- 둘째:** 대분류된 후보 코드들을 자소별로 분리해 낸다. 자소별 분리를 위해서는 완성형으로 표시된 후보 코드들을 조합형으로 변환 시키는 과정이 필요하다. 본 연구에서는 후보 코드 2위 까지 사용하였으며 표 3에서는 완성형 코드를 조합형 코드로 바꾸어 자소의 정보를 표현하였다.
- 셋째:** 입력 문자에서 분리된 초성영역을 초성 인식 신경망에 대입하여 얻어진 출력값들 중 두 후보 코드의 초성 부분에 대응되는 두 출력 노드의 값을 비교하여 출력값이 더 큰 후보 코드를 선정해 낸다. 예를들어 '너' 와 '령' 이 두 후보 코드로 대분류 되었을 경우 초성 인식 신경망의 출력층 노드에서 'ㄴ' 과 'ㄹ' 에 대응되는 노드의 값을 비교하여 노드 값이 더 클 경우에 해당되는 코드를 인식 후보 코드로 선정한다.

**네째:** 선정된 후보 코드의 유형과 중성모음을 조사한다. 유형분류 알고리즘과 중성 인식 신경망으로 입력 문자 영상의 유형 정보와 중성 모음을 알아내어 그 후보 코드와 일치하는지 비교한다. 일치하면 다섯째 과정으로 가며, 일치하지 않을 경우 1위 후보 코드를 최종 코드로 출력한다. 단, 유형이 일치하지 않은 후보가 1위 후보일 경우 2위 후보에 대

해서 네째 과정을 수행한다.

**다섯째:** 후보 코드의 중성과 입력 문자의 중성영역이 일치하는지를 중성 인식 신경망을 이용하여 조사한다. 일치할 경우 그 후보 코드를 최종 코드로 출력해내며, 일치하지 않을 경우 1위 후보 코드를 최종 코드로 출력해낸다. 단, 일치하지 않은 후보가 1위 후보일 경우 2위에 대해 네째 과정을 수행한다.

표 3. 후보 코드의 자소 분리

Table 3. The grapheme segmentation of candidate code.

| 완성형 코드      | 조합형 코드         |                |                |
|-------------|----------------|----------------|----------------|
|             | 초성             | 중성             | 중성             |
| b0a1<br>(가) | 00010<br>( 7 ) | 00011<br>( 1 ) | 00000<br>( )   |
| b7db<br>(원) | 00111<br>( 2 ) | 01110<br>( 4 ) | 00011<br>( 1 ) |
| c8aa<br>(홍) | 10100<br>( 8 ) | 01101<br>( 1 ) | 10111<br>( 0 ) |

V. 실험 및 결과

본 장에서는 저자들이 제안한 신경회로망을 이용하여 인식 실험을 한 결과를 나타내었다. 전체 실험 시스템은 IBM-PC 386 DX 상에서 C언어로 구현하였다. 신경망의 학습과정을 위해서는 많은 처리 시간이 필요하게 되는데 이를 위해 TMS 320C30 DSP 칩(Chip)을 장착한 SPIRIT-30 보드를 이용하였다. 본 실험에서는 II장에서 나탄낸 15개의 한글 문자 세트 중 5개의 시험용 세트로 인식 실험을 하였다. 신경망의 학습 대상 문자는 총 550개의 문자를 선택했으며 각 시험용 문자 세트당 110개씩 문자를 선택했다. 대분류 과정에서 선택된 후보 문자에 상세분류 과정을 적용하여 나타난 결과의 예를 표 4에 나타내 보았다.

표 4. 상세분류된 후보 코드의 결과

Table 4. The result of candiadate classified specifically.

| 입력 코드       | 후보 코드       |             | 인식 결과       |
|-------------|-------------|-------------|-------------|
|             | 1위          | 2위          |             |
| b4ab<br>(눈) | b5da<br>(댕) | b4ab<br>(눈) | b4ab<br>(눈) |
| b7c9<br>(령) | b4a9<br>(누) | b7c9<br>(령) | b7c9<br>(령) |
| babc<br>(불) | baaf<br>(변) | babc<br>(불) | babc<br>(불) |
| b3e0<br>(너) | b1fa<br>(개) | b3e0<br>(너) | b3e0<br>(너) |

대분류 후에 선정된 후보 코드를 살펴보면 표 4에 나타난 것처럼 서로 다른 한글 구조를 갖은 후보문자들도 있는데, 이는 대분류 과정에서 원형정합법을 사용한 결과이다. 일반적으로 원형 정합법은 패턴에서 추출된 특징들의 통계적 유사도에 의해 유사 패턴들을 분리해 내기때문에 후보 코드들의 영상 구조가 서로 다를 수 있다. 표 5는 학습된 신경회로망을 이용하여 시험용 문자세트를 대상으로 수행한 인식 결과이다. 각 시험 세트당 찾기 순서 상위 522자를 대상으로 실험을 하였다.

표 5. 각 시험 세트별 인식율(인식대상문자: 522자)  
Table 5. The recognition rate of each test set.

(단위: %)

| DB | 대 분류율 |       | 형식 분류율 | 최종 인식율 |
|----|-------|-------|--------|--------|
|    | 1위    | 2위    |        |        |
| 11 | 95.01 | 98.85 | 95.59  | 96.36  |
| 12 | 96.93 | 99.80 | 95.79  | 97.13  |
| 12 | 85.44 | 96.17 | 92.72  | 90.04  |
| 13 | 96.93 | 99.81 | 91.95  | 96.74  |
| 14 | 91.18 | 98.47 | 93.68  | 94.49  |

VI. 결 론

통계적인 인식방법의 일반적인 장점은 확실하게 후보문자를 확보할 수 있다는 점이며, 반면에 유사한 후보문자들 중에서 정확하게 인식문자를 선정하는 것은 매우 어렵다는 단점을 지니고 있다. 이와같은 점을 고려하여 통계적인 대분류 방법을 사용하여 확실하게 후보문자를 선정한 후에, 제한된 후보문자들에 대한 자소 인식 신경망을 적용하여 상세분류를 행함으로써 신경망 학습에 있어서와 인식에서의 새로운 방법을 제안하였다. 한글 구성의 특징을 이용한 형식 분류 후에 각 자소별 신경회로망을 각각 구축하였다. 학습 및 인식의 과정에서 형식에 의해 분리된 자소를 이용하였으며, 인식 대상 문자를 모두 고려하지 않고 인식 후보 문자만을 고려한 방법을 사용하였다.

제안된 방법으로 수행된 인식결과는 다중 폰트, 다중 크기의 인쇄체 한글 522자를 대상으로 평균 94.95%의 인식율을 얻었고 이는 1위의 대분류율(93.09%) 보다 1.86%의 인식율 향상을 나타냈다. 이때 사용된 신경 회로망은 550개의 인식 대상 문자로 학습하였다. 본 실험에서 얻어진 인식 속도는 V장에서 설명된 실험 환경하에서 초당 12자에서 13자를 나타냈다. 실험상 나타난 문제점은 다음과 같다. BP 모델의 단점 중의 하나인 느린 수렴 속도로 인해 인식

율 증가가 포화되는 점을 정확히 파악하기 힘들어 최적의 신경망 구조를 구성할 수 없었으며, 임계값과 인식율, 수렴 시간과의 관계등을 정확하게 파악할 수 없었다. 또한 한글 구조의 특성상 비슷한 자소(예: 口, 卍)를 구별해 내기 어려웠으며, 자소 분리시 오분리(예: '너' 에서 ㄱ -> ㄱ)로 인해 자소의 오인식을 초래했으며 많은 수의 후보문자들에 대한 고려를 하지 못했다. 이러한 문제들 중 느린 수렴 속도에 대한 문제의 해결을 위해 현재 많이 연구되는 '오류 역전파 학습 알고리즘에서 수렴 속도 향상 기법'<sup>[1]</sup>의 적용이 문자 인식 분야에서 타당한지를 검토해야 하며, 유형 분류율의 향상과 폰트의 조밀한 연결에서 생기는 자소의 오분리 문제를 해결할 경우 많은 문자 패턴에 대해 높은 인식율을 얻을 것으로 기대된다.

參 考 文 獻

[1] 이 승호 외, "문자 인식에서의 신경망", 전자계산연구회 컴퓨터 기술 vol.6 no.1 pp.39-44 1989.6.

[2] 이 희건 외, "신경회로망을 이용한 오프라인 문자인식 연구 동향", 정보과학회지 vol.9 no.1 pp.33-43 1991. 2.

[3] Yillbyung Lee, Tae Cheon Kim, Eun Jin Kim, "Hanguel Recognition using Neocognitron", IJCNN-90-Wash-DC vol.1 pp.416-419 1990.

[4] 최 동혁 외, "계층구조 신경망을 이용한 문자 인식", 제 4회 신호처리합동학술대회논문집 vol.4 no.1 pp.131-136 1991.

[5] Sung-Bae Cho, Jin H. Kim, "Net eye: A Neural Network System for Recognizing Multi-font/Multi-size Hangul (Korean Script) Documents", ICDAR vol.1 no.1 pp.812-820 1992.

[6] 권 재욱 외, "계층적 신경망을 이용한 다중크기의 다중활자체 한글 문서 인식", 정보과학회지 vol.19 no.1 pp.69-78 1992. 1.

[7] 김 덕진 외, "고속 문자 인식을 위한 特徵量 추출에 관한 연구", 전자공학회지 제 29권 제 11호 pp.102-109 1992. 11.

[8] 김 창윤 외, "신경망 모델을 이용한 인쇄체 한글 문자의 인식", 92 신경회로망연구회 학술발표대회 pp.31-34 1992. 5.

[9] 도 정인 외, "다중 활자체의 한글 문서 인식을 위한 한글 유형 분류에 관한 연구", SAITEC

vol.2 no.2 1989. 10.

[10] 도 정인. "인쇄체 한글 문자의 인식을 위한 자소분리에 관한 연구", 한국정보과학회 가을학술발표논문집 vol.17 no.2 pp.175-178 1990.

[11] Sung-Bae Cho and Jin H. Kim, "An Accelerated Learning Method with Backpropagation", IJCNN-90-Wash-DC vol.1 pp.605-608 1990.

著者紹介



張錫眞(正會員)

1969年 2月 13日生. 1991年 2月 고려대학교 전자공학과 졸업(학사). 1993年 2月 동대학원 졸업(석사). 현재 한국전자통신연구소 연구원.



金赫九(正會員)

1961年 3月 19日生. 1984年 2月 금오공대 전자공학과 졸업(학사). 1990年 8月 고려대학교 산업대학원 전자통신공학과 졸업(석사). 1994年 2月 고려대학교 대학원 전자공학과 박사과정 졸업예정. 주관심 분야는 문서인식 및 컴퓨터 구조 등임.

姜仙美(正會員) 第 29卷 B編 第 11號 參照

현재 고려대학교 정보·통신기술공동연구소 연구조교수. 주관심 분야는 패턴인식, 영상처리, 멀티미디어 등임.



盧宇埴(正會員)

1960年 3月 7日生. 1986年 5月 Virginia Commonwealth Univ. 전산전공졸업(학사). 1987年 12月 동대학원 전산전공 졸업(석사). 1989年 9月 ~1991年 7月 삼성전자 컴퓨터부문 근무. 1992年 3月 ~ 현재 고려대학교 전자공학과 박사과정 (컴퓨터 전공). 주관심 분야는 패턴인식, 네트워킹 등임.

金惠鎮(正會員) 第 29卷 A編 第 8號 參照

현재 고려대학교 전자공학과 교수