

인공신경망을 이용한 필기체 한글의 자동분류와 인식

조완현¹⁾

요 약

본 논문에서 우리는 인공신경망을 사용한 필기체 한글의 자동분류와 인식을 수행할 수 있는 새로운 인식방법을 제안한다. 먼저 새로운 학습방법으로 훈련된 RBF신경망을 사용하여 인식대상문자 전체를 몇 개의 대군집과 중 군집으로 자동분류하고, 다시 각 중 군집안에서 다층퍼셉트론 신경망을 이용하여 주어진 문자를 인식하는 계층적 인식방법을 사용하였다. 또한 제안된 방법을 우편물 주소의 문자열에서 많이 사용되는 총 352개의 문자에 적용하여 각 문자의 인식률을 알아보았다.

주요용어 : RBF신경망, 다층퍼셉트론 신경망, 필기체 한글, 군집분석, 방향성분 특징벡터, 차원축소기법

1. 서 론

컴퓨터의 눈부신 발달은 방대한 량의 정보를 신속하게 처리할 수 있게 되었으나 문서 데이터 입력은 아직까지도 조작자의 수 작업에 의해서 이루어지고 있어서 많은 시간과 인력을 필요로 하는 실정이다. 따라서 문서의 자동 입력기술이 강력히 요구되었으며 이러한 문제를 해결하기 위해서 많은 연구가 활발히 진행되고 있으며 특히 온라인 필기 문자열 인식에서는 통계적 인식 방법이나 동적 프로그래밍 매칭방법 또는 은닉 마코프 모델 등을 이용한 여러 가지 좋은 인식 시스템이 발표되고 있다.

그러나 한글이나 일본의 간지, 중국의 한자처럼 인식문자의 수가 많은 동양권 언어에서는 필기체 문자를 오프라인 방식으로 정확히 인식하는 것이 매우 어려운 문제중의 하나이다. 이는 유사한 모양을 갖는 서로 다른 문자들이 많이 존재할 뿐만 아니라 필기자의 고유의 필기습관으로 인하여 동일한 문자에 대해서도 여러 가지 변형된 패턴들이 존재하기 때문이다.

그러므로 기존의 온라인 필기 문자열 인식방법으로는 좋은 인식률을 얻기가 현실적으로 어렵고, 대안으로 여러 가지 인식기를 계층적으로 결합하여 첫 번째 단계에서는 문자들을 대 분류하고 단계적으로 대상문자를 축소하여 최종적으로 문자를 인식하는 다층 인식방법들이 많이 사용하고 있다. 대표적인 방법으로 Waizumi (1997) 등이 제안한 HLVQ (Hierarchical Learning Vector Quantization) 와 BP (Back Propagation) 신경망을 결합한 방법이 있으며, 김두식과 이성환(1998) 등은 대 분류기로 적응적 SOFM와 LVQ를 상세분류기로 LVQ를 사용하는 방법을 제안하였으며, 또한 통계적 군집방법과 신경망을 결합한 필기체 오프라인 인식방법으로는 김수형(1994) 등이 제안한 방법들이 있다.

따라서 본논문에서는 새로운 학습방법을 사용한 RBF 신경망을 이용하여 인식대상문자를 대 분류 및 중분류하고, 다층퍼셉트론 신경망을 사용하여 분류된 문자를 인식하는 새로운 계층적 인식방법을 제안하려고 한다. 제2절에서는 대분류와 중분류에서 사용된 RBF신경망의 구조와 학습방법, 제3절에서는 상세분류에서 사용된 다층퍼셉트론의 구조와 학습방법, 제4절은 문자의 인식방법, 제5절에서는 실험결과 및 분석, 제6절에서는 결론을 제시하였다.

1) 전남대학교 통계학과 교수, 광주시 북구 용봉동 300 전남대학교 통계학과

E-mail : whcho@chonnam.chonnam.ac.kr

2. 대 분류에서 사용된 RBF신경망의 구조와 학습방법

2.1 RBF 신경망의 구조

일반적으로 인공신경망의 구조는 입력벡터와 가중치간에 정의되는 유사도와 출력노드에서 사용되는 활성화함수로 결정되는데, 유사도로 유클리디안 거리를 갖고 계단함수나 가우시안 활성화함수를 갖는 신경망을 생각할 수 있는데 이것을 Radial Basis Function (RBF) 신경망이라고 부른다. RBF 신경망은 P 차원 입력벡터 \vec{x} 를 M개의 RBF 함수 $h(\cdot)$ 를 사용하여 출력벡터 \vec{y} 로 다음과 같이 대응시키는 관계를 말하며, 이를 그림으로 도식하면 그림 2.1 과 같이 주어진다

$$\vec{y} = \sum_{j=1}^M \omega_j h(|\vec{x} - \mu_j|)$$

이때 이 신경망의 은의층에서는 입력벡터에 대하여 고차원의 비선형변환을 실행하고, 출력층에서는 은의층의 출력값에 대한 선형변환을 실시한다. 또한 은의층에서 사용된 활성화 함수를 RBF 라고 하는데 가우시안 밀도함수가 가장 많이 이용된다.




그림2.1 RBF 신경망의 구조

2.2 RBF 신경망의 학습알고리즘

RBF 신경망의 학습방법은 Scofield(1988)등에 의하여 제안된 쿨롱 포텐셜 에너지 신경망의 학습이론을 이용할 수 있다. 이 학습방법은 각 층에서 생성되는 활성화 패턴의 집합에 대하여 오차함수로 포텐셜 에너지를 정의하여 이 함수를 각 레이어에서 독립적으로 최소화 한다. 이런 방식을 다층 레이어에서 축차적으로 사용하면 개체간의 유사성이 높은 패턴들은 같은 부류에 모이게 되고, 반면에 이질적인 개체들은 서로 다른 부류에 속하게 하여 각 부류간의 거리가 최대로 하는 새로운 패턴분포를 얻게된다.

먼저 P 차원 입력패턴, \vec{x} 를 M 개의 중심집합, $\theta = \{ \mu_1, \dots, \mu_M \}$ 으로 표현하는 RBF 신경망을 생각해 보자.

$$F(\vec{x}) = \sum_{i=1}^M \omega_i \cdot h(|\vec{x} - \mu_i|)$$

이때 RBF $h(\cdot)$ 를 가우시안함수로 택하고, 두 벡터간의 거리로 유클리디안거리를 사용하면 이것은 다음과 같이 표현된다.

$$F(\vec{x}) = \sum_{i=1}^M \omega_i \cdot \phi\left(-\frac{1}{2} \sum_{j=1}^P (x_j - \mu_{ij})^2\right)$$

그러면 우리는 RBF 신경망의 중심점 좌표 $\vec{\mu}_i = (\mu_{i1}, \dots, \mu_{ip})$ 를 다음과 같이 갱신할 수 있다.

첫번째 레이어에 P개의 노드를 갖는 N 개의 패턴부류의 입력벡터의 집합이 주어졌다고 하자.

$$\theta_1 = \{ \vec{x}^1(1), \dots, \vec{x}^1(N) \}, \quad \vec{x}^1(k) = (x_1^1(k), \dots, x_p^1(k))$$

그때 이들은 RBF 신경망에 의하여 두 번째 레이어의 M개의 노드에 K개의 활성화 패턴으로

다음과 같이 사상된다.

$$O_1 = \{ \vec{x}^2(1), \dots, \vec{x}^2(N) \}, \quad \vec{x}^2(k) = (x_1^2(k), \dots, x_M^2(k))$$

따라서 k 번째 패턴에 대하여 두 번째 레이어의 i 번째 노드의 활성화 값을 다음과 같이 주어지고,

$$x_i^2(k) = \phi \left(-\frac{1}{2} \sum_{j=1}^P (x_j^1(k) - \mu_{ij})^2 \right)$$

이 사상은 중심점의 좌표, μ_{ij} , $i=1, \dots, M$, $j=1, \dots, P$ 에 의하여 완전히 결정된다.

그러므로 만약 우리가 활성화 패턴의 집합, O_1 에 대한 콜롱 포텐셜 에너지함수로 두 패턴간의 거리의 역함수를 택하면 이것은 다음과 같이 주어진다.

$$\phi = \sum_{k=1}^N \sum_{k'=1}^N | \vec{x}^2(k) - \vec{x}^2(k') |^{-L}$$

따라서 우리는 이것을 최소화해야 되고, 이는 일반화 델타 학습법에 의하여 중심점의 변화량이 다음의 계산공식에 의하여 수정된다.

$$\begin{aligned} \Delta \mu_{ij} &\propto -\frac{\partial \phi}{\partial \mu_{ij}} \\ &\propto \sum_{k=1}^N \sum_{k'=1}^N | \vec{x}^2(k) - \vec{x}^2(k') |^{-(L+2)} \cdot \delta_{ij}(\vec{x}^2(k), \vec{x}^2(k')) \end{aligned}$$

여기서 값 $\delta_{ij}(\vec{x}^2(k), \vec{x}^2(k'))$ 는

$$\delta_{ij}(\vec{x}^2(k), \vec{x}^2(k')) = \beta \cdot (x_i^2(k) - x_i^2(k')) \left(\frac{\partial x_i^2(k)}{\partial \mu_{ij}} - \frac{\partial x_i^2(k')}{\partial \mu_{ij}} \right)$$

으로 주어지며, 편미분값은

$$\frac{\partial x_i^2(k)}{\partial \mu_{ij}} = (x_j^1(k) - \mu_{ij}) \cdot \exp \left\{ -\frac{1}{2} \sum_{j=1}^P (x_j^1(k) - \mu_{ij})^2 \right\}$$

으로 계산된다.

이렇게 콜롱 에너지 신경망의 학습 알고리즘을 이용하여 중심점의 좌표가 조정되면 다음으로 은닉노드에서 출력노드간의 연결된 대한 가중치의 집합 $\Omega = \{ \omega_1, \dots, \omega_L \}$ 에 대한 학습도 중심점의 좌표에 대한 학습방법을 이용하여 수행할 수 있다.

3. 상세분류에서 사용된 다층 퍼셉트론 신경망

우리는 중 분류된 각 문자 군별로 최종 문자를 인식하기 위하여 3개의 레이어를 갖는 다층 퍼셉트론 신경망을 사용하였으며 이를 학습하기 위하여 일반화 델타법칙을 사용한 역전파(BP) 학습방법을 사용하였다.




그림3.1 상세분류에서 사용된 2계층 퍼셉트론 신경망

입력노드에는 문자영상으로부터 추출된 특징벡터에 대하여 Fisher의 정준판별분석을 실시하고, 이것으로부터 판별점수를 계산하여 이들을 사용하였으며 은닉노드와 출력노드에서 활성화 벡터값은 시그모이드 함수를 이용하여 계산하였다. 또한 신경망의 학습률은 일정한 상수값으로 고정하였다.

4. 문자인식 방법

전체 인식대상 문자를 RBF 신경망을 이용하여 계층적 트리구조로 분해하고, 마지막 노드에서 다층 퍼셉트론 신경망을 사용하여 최종적으로 인식후보문자를 선택한다.

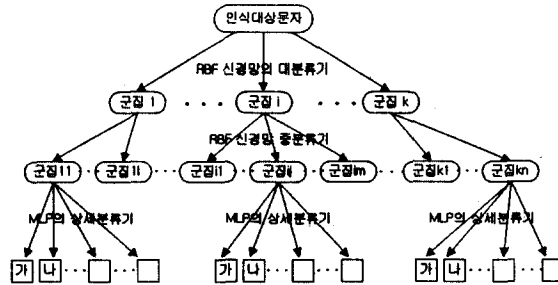


그림 4.1 계층적 분류기의 구조

예를들어 “각”이라는 하나의 인식문자가 들어오면 이를 RBF 신경망을 이용하여 분류를 실시하고 이때 출력노드에서 생성되는 활성화 벡터값중 최대값부터 차례로 몇 개의 군집을 택하고 이들 출력된 벡터값을 각 문자에 대한 인식점수로 택한다. 똑같은 방법을 반복적으로 적용하여 각 단계별로 인식점수를 계산하고 이들을 조합하여 이중 인식점수가 최대인 것부터 후보 인식문자로 선택한다. 이를 도식하면 다음 그림 4.2 와 같다.




그림 4.2 입력 문자의 인식과정

5. 실험결과 및 분석

5.1 실험환경 및 특징벡터

제안된 인식시스템의 성능평가를 위하여 실제 우편물상에 존재하는 주소열을 문자단위로 분리한 후에 각 문자영상에 대하여 Yamashita(1983) 등이 필기체 한자인식을 위하여 제안한 방향 성분 특징을 추출하여 사용하였다. 이 특징은 다음 그림 5.1 과 같이 주어진 입력문자 영상에 대한 9 * 7 차원의 비선형 메쉬상의 63 개 셀로부터 수평, 수직, 사선, 역사선의 네가지 방향성

분에 대한 특징값을 구한 후에 이를 사용하여 252(9*7*4) 차원 벡터를 사용하였다.

실험에 사용된 문자자료는 PE92 문자집합을 이용하였고, 이중 각 문자들에 대한 50 개의 자료는 인식시스템을 훈련하는데 이용하고, 50개는 인식률을 계산하는데 이용하였다. 각 문자영상은 200 dpc 해상도로 스캐닝 되어 특징을 추출하였고, 모든 계산은 Pentium 200 Mhz PC에서 행해졌다.




그림5.1 방향성분 특징

5.2 인식문자의 대분류와 중분류 결과

5.2.1 인식문자의 대군집 과 중군집

우편 주소열등에서 사용되는 352자의 문자집합에 대하여 대략적인 초기 군집모양을 파악하기 위하여 용집형 군집방법중 최장군집방법을 사용하여 군집분석을 실시하였고, 이들을 수형도로 표현한 결과가 다음과 같다.




그림5.2 352자의 문자집합에 대한 초기군집분석에 대한 수형도

또한 252차원의 각 문자의 특징벡터에 대하여 주성분분석을 실시하여 상위 20 개의 주성분에 대한 주성분 점수를 추출하고 이들을 이용하여 Chernoff 얼굴그림을 작성하여 이들 결과와 위의 초기 군집결과를 비교하는 작업을 여러 번 반복하여 최종적으로 대 군집과 중 군집으로 분류된 다음과 같은 군집형태를 얻었다.

6. 결론

본 논문은 대용량 인식문자의 군집화 및 인식방법에 대한 새로운 인식시스템을 제안하였다. 제안된 인식시스템은 중심점과 가중치에 대한 새로운 학습방법을 이용한 RBF 신경망과 다층 퍼셉트론 신경망을 결합하여 구성하였다.

표5.2 대분류 및 중분류에서 각 문자의 균집형태

대분류	중분류	글 자
대분류1(38)	중분류1(28)	곡 구 국 극 녹 녹 독 독 독 독 류 류 록 록 록 속 속 옥 옥 옥 옥 죽 죽 축 축 후 후 휴 휴
	중분류2(10)	규 누 두 무 북 부 복 수 우 유
대분류2(68)	중분류3(23)	각 격 낙 덕 탁 락 력 막 박 삭 색 석 식 약 약 역 의 작 적 직 책 최 택 학
	중분류4(23)	과 꺾 괴 귀 기 라 쇠 여 와 의 위 의 좌 지 치 퇴 파 피 하 화 회 회 회 회
	중분류5(22)	내 대 래 러 레 리 매 텍 미 배 백 벽 비 쇠 에 어 예 왜 이 태 패 해
대분류3(22)	중분류6(22)	가 개 거 게 나 니 다 마 사 서 세 시 아 야 자 제 저 조 차 체 체 해
대분류4(54)	중분류7(8)	길 절 길 설 실 절 철 철 철
	중분류8(27)	갈 달 말 민 밀 만 발 벌 벌 빈 살 생 선 성 신 심 심 알 엄 엄 열 엄 엄 인 일 임 입
	중분류9(19)	냉 년 념 린 명 면 명 번 범 법 변 병 빙 영 언 연 영 검 검
대분류5(25)	중분류10(25)	건 검 견 경 경 원 권 김 련 림 원 건 정 진 집 정 천 침 팔 팔 환 환 팔 팔 팔
대분류6(64)	중분류11(21)	동 렴 령 룡 룡 룡 율 증 청 충 통 팽 팽 품 품 헌 헌 열 열 흥 흥 흥
	중분류12(17)	돈 른 른 손 은 응 은 존 중 줄 증 존 춘 출 흘 른 른 른
	중분류13(26)	관 팔 궁 근 은 능 능 둔 동 풍 문 분 봉 분 봉 송 순 승 승 음 용 운 용 음 음 음
대분류7(46)	중분류14(5)	합 합 함 행 항
	중분류15(18)	감 감 관 광 란 랑 량 삼 양 완 왕 잠 장 창 탄 탐 탐 탐
	중분류16(23)	간 강 난 남 남 나 낭 단 담 담 당 만 망 방 산 삼 상 쌍 안 압 압 안 잔
대분류8(35)	중분류17(17)	고 곳 교 노 느 도로 모 소 오 조 초 토 포 표 호 후
	중분류18(18)	곳 군 굴 궁 굴 굴 늘 들 뉘 물 보 볼 술 요 율 윤 울 울 울

참고문헌

- [1] 김두식, 이성환 (1998), "계층적 신경망 분류기를 이용한 다양한 언어, 활자체 및 크기의 대응량 문자 인식", 정보과학회 논문집(B), 제25권 제5호, 792-800.
- [2] 김수형, 도정인, 김준호, 이상규(1994), "통계적 균집화 및 신경망 기법을 이용한 필기체 문자의 오프라인 인식", 문자인식 워크샵,
- [3] Karayiannis, N.B. (1997), "Gradient Descent Learning of Radial Basis Neural Networks", Proceedings of IEEE International Conference on Neural network, vol 3, pp 1815-1820.
- [4] Morgan, D.P. and Scofield, C.L. (1991), "Neural Network and Speech Processing", Kluwer Academic Publishers, Boston .
- [5] Poggio, T. and Girosi, F.(1994), "A Theory of Networks for Approximation and Learning", C.B.I.P. Paper No. 31, Massachusetts Institute of Technology.
- [6] Scofield, C. L. (1988), " Learning Internal Representations in the Coulomb Energy Network", Proceedings of IEEE international Conference on Neural Networks, vol 1, 271 - 274.
- [7] Schuermann, J. and Doster, W.(1984), "A Decision Theoretic Approach To Hierarchical Classifier Design", Pattern Recognition, Vol 17, No 3, pp 359 -369.
- [8] Waizumi, Yuuji and etc (1997), "High Speed Classification for Handwritten Characters using Hierarchical Learning Vector Quantization",
- [9] Yamashita, Y. and etc (1983), "Classification of handprinted Kanji characters by the structured segment matching method, PRL 1, pp 475-479.