

論文94-31B-5-17

신경망분류기와 선형트리분류기에 의한 영상인식의 비교연구

(A Comparative Study of Image Recognition by Neural Network Classifier and Linear Tree Classifier)

朴 榮 泰 *

(Young Tae Park)

要 約

다층 퍼셉트론에 의한 신경망분류기와 다단계의 선형결정함수를 사용한 선형트리분류기(Linear Tree Classifier)는 특징공간에서 임의의 복잡한 결정경계를 형성하는 분류능력을 가진 분류기들로서 매우 유사한 결정구조(decision structure)를 가지고 있다. 본 논문에서는 특징벡터에 따른 결정함수의 순차적 선택에 의한 선형트리분류기의 구조를 결정함수의 병렬적 선택에 의한 은닉층의 갯수가 한개 및 두개인 신경망분류기(three and four layer neural network classifier) 구조로 사상(mapping)함으로써 신경망분류기에서 필요한 뉴런의 수를 자동으로 결정하고 연결 가중치를 초기화하는 방식과 이론적 근거를 제시한다. 실제의 군함영상에서 추출된 데이터의 분류 실험 결과, 분류기 구조의 유사성을 이용한 뉴런수의 자동결정 방식이 효과적이고 사상에 의한 연결 가중치의 초기화에 따라 학습속도를 향상시킬수 있었으며 두가지 분류기의 인식률에는 큰 차이를 보이지 않았다.

Abstract

Both the neural network classifier utilizing multi-layer perceptron and the linear tree classifier composed of hierarchically structured linear discriminating functions can form arbitrarily complex decision boundaries in the feature space and have very similar decision making processes. In this paper, a new method for automatically choosing the number of neurons in the hidden layers and for initializing the connection weights between the layers and its supporting theory are presented by mapping the sequential structure of the linear tree classifier to the parallel structure of the neural networks having one or two hidden layers. Experimental results on the real data obtained from the military ship images show that this method is effective, and that there exists no significant difference in the classification accuracy of both classifiers.

I. 서론

* 正會員, 慶熙大學校 電子工學科

(Dept. Elec. Eng., Kyunghee Univ.)

※이 논문은 1993년도 한국학술진흥재단의 공모
과제 연구비에 의하여 연구되었음.

接受日字 : 1993年 8月 3日

오차역전파(error backpropagation) 학습에 의한
다층 신경망분류기(multi-layer neural network
classifier)가 제안된 아래 신경망분류기는 임의의 입
출력 데이터의 근사능력을 갖는 분류기로서 기존의

분류기와 달리 그 분류능력이 뉴런(neuron)이라 불리는 다수의 간단한 processing element 간의 연결 가중치(connection weight)들에 의해 발휘되며 우수한 일반화 능력, 적용학습능력, error-tolerance 등의 특성을 가지므로 패턴인식 분야에서 많은 연구가 진행되어 왔다. 한편 결정트리분류기(decision tree classifier)는 다단계 분류과정에 의한 특징(feature)의 효율적인 사용에 의해 특징공간을 분리하기 때문에 일단계 분류기에 비해 분류의 정확성을 유지하면서 사용 특징의 수를 최소화 함으로써 인식 과정의 고속화를 이룰수 있다. 선형트리분류기(Linear Tree Classifier)^[3]는 시작노드(root node), 중간 노드(nonterminal node) 및 종착 노드(terminal node)로 구성된 결정트리분류기의 일종으로서 각 노드마다 특징들의 선형 합(linear sum)에 의한 결정함수(decision function)를 사용하여 특징공간(feature space)을 단계적으로 분리함으로써 인식을 행한다.

다층 퍼셉트론에 의한 신경망 분류기와 다단계의 선형결정함수를 사용한 선형트리분류기(Linear Tree Classifier)는 특징공간에서 임의의 복잡한 결정경계를 형성하는 분류능력을 가진 분류기들로서 매우 유사한 결정구조(decision structure)를 가지고 있다. 역전파 알고리듬^[4]을 사용한 신경망분류기의 기본적인 구조는 선형트리분류기와 매우 유사하다. 즉 특징들의 선형합(linear sum)의 사그모이드 함수를 사용한 분류과정에 의해 특징공간을 분리한다. 따라서 신경망분류기를 사용한 특징공간에서의 결정경계(decision boundary)는 선형트리분류기에 의한 결정경계가 시그모이드 함수에 의해 비선형적으로 변형된 형태로 구성된다.

본 논문에서는 이와같은 결정과정의 유사성을 이용하여 선형트리분류기의 결정구조를 신경망분류기의 결정구조로 사상하는 이론적 근거를 규명하고 이러한 사상에 의해 신경망분류기의 적절한 크기를 자동으로 결정하는 방식과 역전파 알고리듬 학습의 고속화와 일반적인 gradient descent algorithm의 단점인 국부최소치료의 수렴(local trapping)을 피할수 있는 연결 가중치의 초기화 방식을 제안하고자 한다. 제안된 방식을 적용하여 두가지 분류기를 실제의 군함영상에서 추출된 특징벡터에 적용시켜 각각의 분류능력과 특성을 비교분석하고 선형트리분류기에 의해 구성된 결정트리구조(decision tree structure)를 한개 및 두개의 은닉층을 가진 신경망회로의 구조에 사상하여 은닉층에서의 뉴런의 갯수와 적절한 초기 가중치를 자동으로 결정할수 있음을 보인다.

서로 다른 분류기의 사상에 의한 신경망분류기의 구조결정에 대한 타당성은 다음과 같은 이유로 설명될수 있다. 1) 분류기의 성능은 분류기의 종류에 관계없이 주어진 훈련데이터 분포의 효율적인 분리 및 균사능력에 의해 좌우된다. 2) 선형트리분류기는 Nearest-Neighbor 결정경계를 근사시키는 분별함수(discriminant function)의 수를 최소화함으로써 특징공간을 효율적으로 분리한다. 따라서 선형트리분류기에 의해 분리된 특징공간의 형태는 신경망분류기에 의해 분리될 특징공간의 기본 형태에 대한 중요한 정보로 사용될수 있다. 3) 선형트리분류기의 학습속도는 신경망분류기에게 비해 월등히 빠르므로 신경망분류기의 최적화를 위한 실행도구로 사용될수 있다. 훈련 데이터에 따라 적절한 구조를 선택하는 것은 분류기의 정확도를 결정하는 중요한 요인이며 일반적으로 역전파 알고리듬에 의한 훈련은 많은 시간을 소요하므로 구조선택의 자동화가 요구된다.

본 논문의 구성은 다음과 같다. 2장에서 선형트리분류기의 설계과정을 소개하고, 3장에서 선형트리분류기의 사상(mapping)에 의한 신경망분류기 구조의 결정법칙과 그 이론적 근거를 제시한다. 본 논문에서 사용한 군함영상 및 특징추출 방법을 4장에 요약하고, 실험결과 및 분류기의 특성을 5장에서 비교 분석한다.

II. 선형트리분류기의 훈련과정

일반적으로 다단계 분류기(hierarchical classifier)의 설계과정은 다음과 같은 세단계로 구성된다. (1) 각 노드에서 분리될 국부특징공간(local feature space)의 결정, (2) 각 노드에서 사용될 특징의 선택, (3) 각 노드에서 사용될 결정함수(decision function)의 훈련등이다. 다단계 분류기의 신뢰도 및 효율성을 결정하는 중요한 요인은 첫번째 단계인 국부특징공간 설정의 최적화이다. 국부특징공간 설정의 자동화 및 최적화를 위하여 선형트리분류기에서는 Tomek 링크^[4]의 개념을 도입한다. 서로 다른 부류(class)에 속하는 특징벡터를 X, Y 라 했을때 특징 공간에서 X, Y 의 중간점으로부터 최단거리에 있는 특징벡터가 X 와 Y 일때 X 와 Y 를 연결하는 선을 Tomek 링크라 부른다. Tomek 링크를 최대한으로 많이 자르는 선형함수를 초기 결정함수로 택하므로써 국부특징공간을 효율적이고 자동적으로 선택할수 있다. 일반적으로 분류대상의 종류가 많거나 훈련데이터의 혼재율이 심할경우 Tomek 링크의 갯수가 많아지고 분류기의 신뢰도를 저하시킬 우려가 있으므로

전처리 과정으로 군집화(clustering) 기법^[5]을 선행 한다. 즉, 군집화된 각각의 군집(cluster)의 중심을 기준으로 생성된 Tomek 링크를 사용하면 설계과정의 효율성 및 신뢰도를 향상시킬수 있다. 이와 같이 설정된 초기 결정함수는 훈련데이터의 서로 다른 부류에 속하는 국부적인 공간을 효율적으로 분리하며, 결정함수의 최적화를 위하여 윈도우 훈련(window training)과정^[6]을 사용하여 관련된 국부 특징벡터들에 대한 초기 결정함수를 훈련시킨다. 선형트리분류기의 전체적인 설계과정^[3]은 다음과 같다.

```

procedure Linear_Tree_Classifier
{
    clustering by k-means algorithm[5]:
    generate Tomek links:
    while (uncut Tomek links are left)
    {
        find an initial hyperplane that
        cuts the maximum number of
        Tomek links:
        create local training data:
        select features:
        optimize the initial hyperplane by
        window training[6]:
        mark the Tomek links cut by the
        optimized hyperplane:
        if (the local feature space
            divided by the hyperplane
            contains pure class members
            or it dose not contain any
            Tomek links)
        {
            label the local feature space:
        }
    }
}

```

III. 선형트리분류기의 신경망분류기로의 사상

두가지 분류기의 구조상 유사점을 이용하여 은닉층의 수가 한개 및 두개인 신경망분류기의 구조를 자동으로 결정할수 있다. 은닉층의 수가 한개인 신경망분류기를 BPN1로, 은닉층의 수가 두개인 신경망분류기를 BPN2로, 선형트리분류기(linear tree classifier)를 LTC로 표기하기로 한다. 그림 1(c)에서와 같이 BPN2의 분류과정은 1) 공간분할

(partitioning), 2) 교집합에 의한 결정공간 (decision region) 형성(ANDing), 3) 결정공간의 합집합(ORing)에 의한 클래스의 분류등으로 구성되므로 두개의 은닉층만으로 특징공간에서 임의의 결정 경계를 형성할수 있다. 반면에 LTC에서는 특징벡터의 값에 따라 선형 결정함수를 다단계에 걸쳐 적용시킴으로써 특징벡터를 분류한다. LTC의 i 번째 선형 결정함수의 결정경계는 다음식에 의해 형성된다.

$$h_i(x) = a^T x + a_0 = 0. \quad (1)$$

식 (1)에서 x 는 특징벡터, a 와 a_0 는 선형결정함수의 결정 웨이트(weight)를 의미한다. $h_i(x)$ 에 의해 형성된 결정경계는 n 차원 특징공간에서 hyperplane 이라 불린다. LTC의 i 번째 hyperplane H_i 로부터 특징벡터 x 의 거리 $d_i(x)$ 는

$$d_i(x) = \frac{(a^T x + a_0)}{\|a\|} \quad (2)$$

로 주어진다. 여기서 $\|a\|$ 는 weight 벡터 a 의 Euclidean norm 을 나타낸다. $d_i(x)$ 는 은닉층의 i 번째 뉴런의 출력 $g_i(x)$ 와 유사하다.

$$g_i(x) = f(a^T x + a_0). \quad (3)$$

a 와 a_0 는 입력층과 은닉층간의 연결가중치를, $f(\cdot)$ 는 시그모이드 함수로서 소프트결정함수(soft decision function)를 나타낸다. 일반적인 시그모이드 함수는 다음과 같다.

$$f(y) = \frac{1}{(1 - e^{-y})}. \quad (4)$$

식 (2)와 (3)의 차이점은 $f(\cdot)$ 에 있다. 신경망분류기에서는 일단계에서 특징공간을 분할하는데 필요한 모든 소프트결정함수를 계산하고 다음 단계에서 이들 함수를 서로 다른 비중으로 선택함으로써 최종결정을 하는 반면, 선형트리분류기에서는 필요한 결정함수만을 선택적으로 계산하여 사용하므로 분류과정이 매우 빠르다. $f(\cdot)$ 대신 선형함수를 사용하면 식 (2)와 (3)은 동일한 동작을 한다. 그럼 1(c)에서와 같이 분할층과 교집합층, 교집합층과 합집합층을 연결하는 시냅시스(synapsis)는 완전결합의 형태가 아니고 성결결합(sparse connection)의 형태를 취한다.

이와같이 LTC는 결정과정의 유사성으로 BPN2로의 직접적인 사상이 가능하지만 이러한 사상기법이 최적의 신경망분류기 구조를 형성하지는 못한다. 그

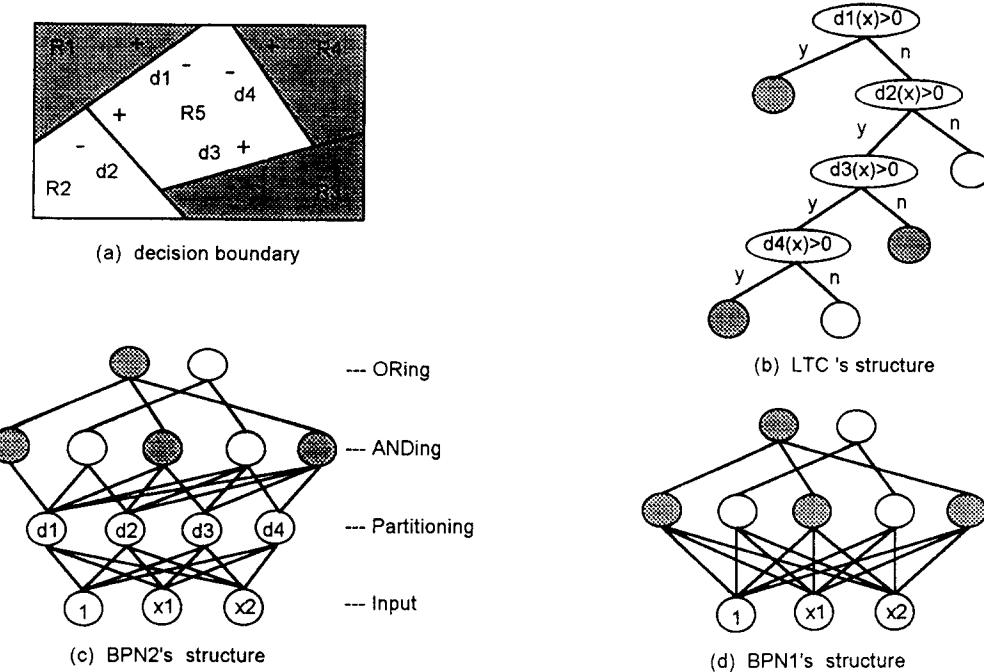


그림 1. LTC 의 BPN2 로의 사상 (a): 특징공간의 결정경계, (b): LTC의 구조, (c): BPN2의 구조, (d): BPN1의 구조.

Fig 1. Mapping from LTC to BPN2 (a): decision boundary, (b): LTC 's structure, (c): BPN2's structure, (d): BPN1 's structure.

주요 원인은 시그모이드 함수와 같은 비선형 함수의 사용에 있다. Villiers와 Barnard²에 의해 연구된 바와 같이 BPN1 으로도 임의의 복잡한 특징공간의 분할이 가능하며 BPN2 와 비교해서 분류능력상의 차잇점이 없다. LTC 의 BPN1 으로의 사상은 다음과 같은 정리에 따른 LTC 의 선형결정함수의 조합에 의해 가능해 진다.

정리:

LTC 의 hyperplane 들의 조합에 의해 형성된 k 번째 결정공간 R_k 는 R_k 에 속하는 모든 특징벡터에 대해 BPN1 은 닉총의 k 번째 뉴런 N_k 의 출력이 최대로 되는 BPN1의 구조를 LTC의 구조로 부터 사상 할수 있다.

증명:

그림 1 에 보인 전형적인 LTC 예에 대한 사상법을 제시함으로써 공식적인 증명을 대신하고자 한다. 그림 1(a) 는 선형결정함수 d_1, d_2, d_3, d_4 로 형성된 hyperplane 들에 의해 5개의 결정공간 R_1, R_2, R_3, R_4, R_5 로 분할된 특징공간의 예를 표시하고 그림 1 (b)는 LTC 의 결정트리 구조를 나타낸다. 각각의 결

정공간에 대한 소속함수(membership function) m_1, m_2, m_3, m_4, m_5 를 다음과 같이 정의한다.

$$\begin{aligned} m_1(x) &= a_1 d_1(x), \\ m_2(x) &= -a_1 d_1(x) - a_2 d_2(x), \\ m_3(x) &= -a_1 d_1(x) + a_2 d_2(x) - a_3 d_3(x), \\ m_4(x) &= -a_1 d_1(x) + a_2 d_2(x) + a_3 d_3(x) + d_4(x), \\ m_5(x) &= -a_1 d_1(x) + a_2 d_2(x) + a_3 d_3(x) - d_4(x). \end{aligned} \quad (5)$$

아래와 같은 과정에 의해 a_1, a_2, a_3 를 선택함으로써 LTC 와 동일한 결정논리를 갖는 소속함수를 LTC 의 선형결정함수로 부터 생성시킬수 있다.

- 1) R_1 영역에서 $d_1 > 0, R_5$ 영역에서 $d_4 < 0$ 이므로 R_4 와 R_5 는 d_4 에 의해 분리된다.
- 2) $R_1 \cup R_5$ 영역에서 $d_3 > 0, R_3$ 영역에서 $d_3 < 0$ 이므로 $R_4 \cup R_5$ 에서는 m_4 와 m_5 가 m_4, m_2 보다 크고 R_2 에서는 작게 되도록 임의의 큰 값을 가진 a_2 를 결 정할수 있다.
- 3) $R_3 \cup R_4 \cup R_5$ 영역에서 $d_2 > 0, R_2$ 영역에서 $d_2 < 0$ 이므로 $R_2 \cup R_3 \cup R_4 \cup R_5$ 에서는 m_3, m_4, m_5 가

m_2 보다 크고 R_2 에서는 작게 되도록 임의의 큰 값을 가진 a_2 를 결정할수 있다.

- 4) $R_2 \cup R_3 \cup R_4 \cup R_5$ 영역에서 $d_1 < 0$, R_2 영역에서 $d_1 < 0$ 이므로 $R_2 \cup R_3 \cup R_4 \cup R_5$ 에서는 m_2 , m_3 , m_4 , m_5 가 m_1 보다 작고 R_1 에서는 크게 되도록 임의의 큰 값을 가진 a_1 을 결정할수 있다.

식 (2), (5)에서와 같이 소속함수는 특징벡터의 선형변환식으로 표시되며 선형계수를 BPN1의 입력층과 은닉층 사이의 가중치로 사용할 경우, BPN1 은 은닉층의 k 번째 뉴런 N_k 는 LTC의 k 번째 결정공간 R_k 에 속하는 모든 특징벡터에 대해 최대의 출력을 가지게 된다. 시그모이드 함수는 단순증가함수이기 때문이다. 따라서 LTC의 종착노드는 BPN1의 은닉층 뉴런으로, 소속함수는 BPN1의 연결 가중치로 사상함으로써 동일한 결정논리를 갖는 BPN1을 설계할수 있다. BPN2 의 첫번째 은닉층(partitioning layer)의 공간분할 과정과 두번째 은닉층(ANDing layer)의 결정공간 형성 과정이 BPN1 에서는 한개의 은닉층에서 동시에 수행된다. 이경우 은닉층의 출력은 특징벡터의 결정공간(decision region)에 대한 소속정도(membership)를 나타낸다. 출력층에서는 은닉층에서 계산된 소속정도의 가중치에 의한 합산으로 최종적인 분류를 하며 결정공간의 클래스의 종류에 따른 합집합을 구성한다. 따라서 BPN1 의 은닉층 뉴런의 수는 특징공간에서 결정공간의 수와 같으며 은닉층 뉴런의 역할은 LTC 의 종착노드의 역할과 동일하다.

위의 정리를 사용하여 LTC 구조는 다음과 같은 사상 법칙(mapping rule)에 의해 다층 퍼셉트론의 구조로 재구성할수 있다.

은닉층이 한개인 경우(BPN1):

- 은닉층에서의 뉴런의 갯수는 선형트리분류기의 종착노드의 갯수와 같다. 즉, 특징공간의 전체 결정공간의 수는 두가지 분류기가 동일하다.
- 입력층과 은닉층 사이의 연결 가중치는 식 (6)의 계수에 의해 초기화한다.

$$m_k(x) = \sum_{j=1}^n \rho_j^{-1} s_{kj} d_j(x). \quad (6)$$

m_k 는 결정공간 R_k 의 소속함수를 나타내고 s_{ij} 는 R_k 의 hyperplane H_i 에 대한 좌우 위치정보를 나타낸다. 즉,

$$s_{kj} = \begin{cases} +1, & R_k \text{ 가 } H_i \text{의 정방향에 있을 때} \\ -1, & R_k \text{ 가 } H_i \text{의 부방향에 있을 때} \end{cases}$$

$\rho(0 < \rho < 1)$ 는 R_k 의 형성에 관련된 선형결정함수 d_1, d_2, \dots, d_n 에 대한 weighting factor

이다. ρ 값이 충분히 작을 경우, BPN1 은닉층의 k 번째 뉴런 N_k 는 LTC의 k 번째 결정공간 R_k 에 속하는 모든 특징벡터에 대해 최대의 출력을 가지게 된다. (5장의 실험에서는 0.5 를 사용하였다.)

은닉층이 두개인 경우(BPN2):

- 첫번째 은닉층(partitioning layer)에서의 뉴런의 갯수는 선형트리분류기의 중간노드의 갯수와 같다.
- 두번째 은닉층(ANDing layer)에서의 뉴런의 갯수는 선형트리분류기의 종착노드의 갯수와 같다.
- 입력층과 첫번째 은닉층(partitioning layer) 사이의 연결 가중치는 식 (2)의 계수에 의해 초기화한다.

IV. 군함영상의 특징추출

본 논문에서 실험한 영상은 비행기에서 적외선 카메라(FLIR: Forward Looking Infrared)에 의해 촬영된 8가지 종류의 군함영상들이며 90도 및 30도에서 촬영되었다. 표 1, 그림 2(a), 그림 2(b)에 그 종류와 세그멘트된 표본 영상을 표시한다. 이들 영상은 미 해군 무기연구소(U.S. Naval Air Warfare Center)에서 제공되었다. 인식시스템의 실용화를 위해서는 인식대상의 크기, 위치, 회전에 구애받지 않는 특징(feature)을 선택해야 된다. 인식에 적합한 특징으로서, 기하학적 특징, AR 모델(Autoregressive model)에 의한 파라메타^[7], 푸리에 묘사(Fourier descriptor)^[8], 모멘트 불변함수^[9] 등은 크기, 위치, 회전에 불변하는 특성과 함께 물체의 형태에 따른 인식능력을 가진 특징 벡터로서 사용될수 있다. 실험에서 사용한 특징벡터는 7가지의 모멘트 불변함수^[9]와 AR 모델^[7]에서 추출된 4가지의 파라메타로 구성된다.

표 1. 군함영상의 종류

Table 1. Types of military ship images.

클래스	군함종류
1	Destroyer
2	Container
3	Civilian Freighter
4	Auxiliary Oil Replenishment
5	Landing Assault Tanker
6	Frigate
7	Cruiser
8	Destroyer with Guided Missile

AR 모델에 의한 특징추출방식은 다음과 같다. 세그멘트된 군합영상을 X 축으로 사상(projection)하여 1차원 함수의 데이터로 구성하고 이를 AR 모델에 맞도록 최소자승오차 기법(least squares estimation)에 의하여 파라메타를 구한다. X축으로 사상된 군합영상의 높이를 $r(i)$ 로 표시하면 AR 모델은 다음과 같이 설정된다

$$r(i) = \sum_{j=1}^m \theta_j r(i-j) + \alpha + \sqrt{\beta} \varepsilon(i). \quad (7)$$

여기서 m 은 파라메타의 개수를 나타낸다. 최소자승오차 기법에 의하여 구해진 파라메타 ($\theta, \alpha, \sqrt{\beta}$)은 물체의 크기, 위치, 회전에 무관하며 물체의 모양을 묘사하는 특징 벡터로서 사용될수 있다.^[7]

V. 실험 결과 및 고찰

2541개의 군합영상에서 추출된 특징벡터는 각각 11개의 특징들로 구성되며 전체 데이터를 무작위로 이등분하여 한쪽 데이터는 분류기의 훈련과정에 사용하고 나머지 데이터는 분류기의 인식률을 측정하는데 사용하였다. 이러한 인식률 평가방식은 홀드-아웃(hold-out)방식으로 불린다. 인식률의 측정에 훈련데이터를 재사용할 경우의 인식률 평가방식은 재삽입(resubstitution) 방식으로 불리며 홀드-아웃(hold-out)방식에 비해 인식률 측정의 바이어스가 크다.^[5] 이등분된 훈련데이터에 대해 훈련된 선형트리분류기는 모두 23개의 선형결정함수와 24개의 종착노드로 구성된 단단계 분류기를 생성하였다. 3절에서 제시한 뉴런수의 결정법칙에 따라 BPN1의 은닉층 뉴런수는 24개로 정하고 BPN2의 첫번째와 두번째 은닉층의 뉴런수는 각각 23개, 24개로 정했다. 또한 사상에 의한 신경망분류기의 연결 가중치 초기화 방식의 타당성을 실험하기 위하여 BPN1과 BPN2의 가중치를 random initialization에 의한 방식과 LTC의 사상에 의한 방식에 의하여 실험을 하였다. 역전파 알고리듬의 학습율(learning rate)은 0.1. 모멘텀은 0.9로 하고 입력층과 은닉층을 연결하는 웨이트의 평균 변화가 0.05 이하로 수렴할때까지 학습을 계속하였다. 표 2에 분류기의 인식률, 훈련속도, 분류속도 등의 결과를 나타낸다. 사용한 컴퓨터는 삼보 SDT-250 워크스테이션이다.

재삽입 방식에 의한 인식률은 BPN1, 사상에 의한 BPN1, BPN2, 사상에 의한 BPN2, LTC의 경우 각각 97.8%, 98.3%, 98.4%, 98.3%, 96.1%이고, 홀드-아웃 방식에서는 각각 94.1%, 94.6%,

93.5%, 94.1%, 92.2%의 인식률을 얻었다. BPN1과 BPN2의 경우^[2]에서 발표된 바와 같이 인식률의 차이가 거의 없었고 LTC의 경우 신경망분류기와 비교해서 1~2% 정도의 인식률의 차이를 보였다. 그 이유는 LTC의 결정과정에서 부모노드(parent node)에서 발생한 착오(error)를 자식노드(child node)에서 복구하는 것이 불가능하기 때문이다. 이에 비해 신경망분류기에서는 모든 뉴런의 결정함수를 출력층에서 최종적으로 취합함에 따라 모든 뉴런의 분류능력(discriminating power)을 공유함으로써 전체적인 인식률을 향상시킨다. 사상에 의해 연결 가중치를 초기화한 경우 인식률은 큰차이가 없으나 학습속도는 월등히 빠르다. 그림 3에 두가지 방식에 따른 BPN1과 BPN2의 학습속도를 보인다. 여기서 한번의 순환(iteration)은 1271개의 전체 훈련 특징벡터가 학습에 사용되었음을 의미한다.

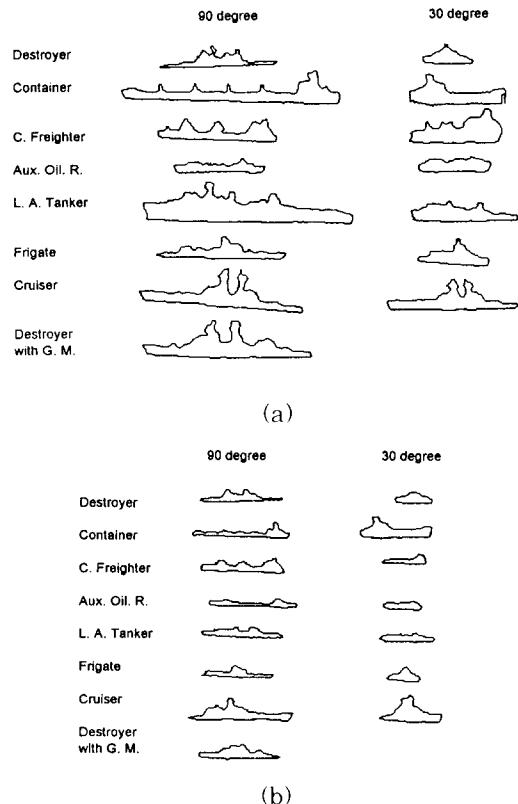


그림 2. 세그멘트된 군합영상의 예 (a): 근거리의 군합영상 (b): 원거리의 군합영상
Fig. 2. Example of segmented ship images (a): images at short distances (b): images at long distances.

k -NN 분류기^[10] 와의 인식률 비교를 위해 k 값을 1에서 17까지 변화시키면서 인식률을 측정하였다. 최대의 정인식률은 k 가 3일때 88.3%를 나타냈다. 1-NN의 오인식률은 훈련데이터가 충분할경우 오인식률의 상한치(upper bound)는 Bayes 오인식률의 2배이다.^[10] 따라서 LTC 와 신경망분류기의 인식률은 Bayes 최대 인식률에 접근함을 알수있다. 이는 3절에서 제시한 LTC 의 사상에 의한 신경망분류기의 구조결정법칙이 효과적임을 간접적으로 나타낸다.

표 2. 분류기의 성능비교

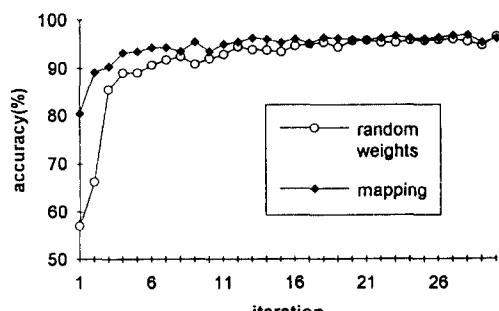
Table 2. Performance comparison of classifiers .

분류기	인식률		훈련시간	분류시간	뉴런수	결정함수수
	재삽입	홀드-아웃				
BPN1 (random)	97.8%	94.1%	2526.1초	3.2초	24	-
BPN1 (mapping)	98.3%	94.5%	2670.5초	3.4초	24	-
BPN2 (random)	98.4%	93.5%	6816.7초	6.7초	첫째: 23 둘째: 24	-
BPN2 (mapping)	98.3%	94.1%	3711.6초	6.8초	첫째: 23 둘째: 24	-
LTC	96.1%	92.2%	97.6초	0.3초	-	23
k -NN($k=3$)	-	88.3%	-	55.7초	-	-

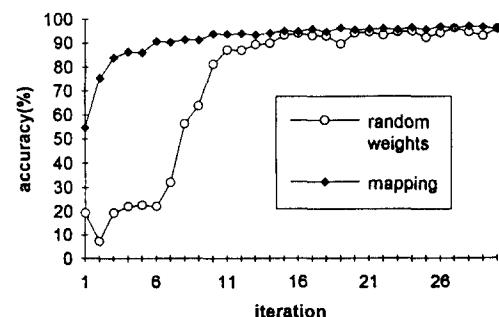
(주) 분류시간은 1271개의 전체 특징벡터를 분류했을 때의 시간이다.

VII. 결론

신경망분류기와 선형트리분류기의 근본적인 차이점은 특징공간을 분할하는 결정함수들의 사용방식에 있다. 즉 신경망분류기에서는 일단계로 인식대상에 관계없이 전체 특징공간을 분할하는데 필요한 모든 결정함수를 계산하고 이단계로 전단계에서 계산된 결정함수를 선택적으로 취합함으로써 인식대상을 분류하는 반면. 선형트리분류기에서는 추출된 특징값에 따라 필요한 결정함수만을 선택적으로 계산하여 사용하는데 근본적인 차이점이 있다. 또한 시그모이드 함수의 사용에 따라 신경망분류기에서의 특징공간 분할은 비선형적이며 선형트리분류기에서의 특징공간 분할은 다단계 선형함수의 사용에 따라 단계적 선형(piecewise linear) 형태를 취하게 된다. 선형트리분류기의 구조를 은닉층의 갯수가 한개(BPN1), 및 두개(BPN2)인 신경망분류기로 사상하는 이론적 근거를 제시하였고 이러한 사상에 의하여 뉴런의 수를 자동으로 결정하고 연결 가중치를 초기화 하는 방식을 제안하였다. 실험결과 이러한 방식이 효과적이며 학습속도를 향상시킬수 있는 것으로 나타났다.



(a)



(b)

그림 3. 역전파 알고리듬의 학습속도의 비교 (a): random initialization 에 의한 BPN1 과 사상에 의한 BPN1, (b): random initialization 에 의한 BPN2 과 사상에 의한 BPN2

Fig 3. Comparison of learning rates of the backpropagation algorithm (a): BPN1 with random initialization and BPN1 with mapping, (b): BPN2 with random initialization and BPN2 with mapping.

근함영상에 대한 실험결과에 의하면 인식률에서는 신경망분류기가 약간 우수한 것으로 나타났으나 큰 차이는 없었다. 이것은 두가지 분류기의 기본 동작원리가 매우 유사하기 때문이다. 훈련속도 및 인식속도에서는 선형트리분류기가 월등히 우수하며 특히 특징선택의 기능에 의한 특징수의 최소화와 결정함수의 선택적 사용에 따른 인식의 고속화는 패턴인식의 실용화를 위하여 매우 중요한 특성이다. 따라서 실용적

인 면에서 훈련 데이터가 충분할 경우 신경망분류기의 사용이 기존의 선형트리분류기에 비교하여 특별한 이점은 없다. 그러나 훈련 데이터가 불충분하고 새로운 데이터가 계속 추가될 경우 간단한 억전파 알고리듬에 의한 분류기의 성능 향상을 피할수 있다는 점, 즉 적응훈련능력에 있어서는 신경망분류기가 우수하다. 또한 특징의 부분 손실에 대해 민감하지 않은 특성은 기존의 분류기 보다 우수한 기능이다.

参考文献

- [1] D.E. Rumelhart, G.E. Hinton, R.J. Williams: "Learning internal representation by error back propagation", *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 1: Foundations. MIT Press (1986)
- [2] J.D. Villiers, E. Barnard: "Backpropagation Neural Nets with One and Two Hidden Layers", *IEEE Trans. Neural Networks*, Vol. 4, No. 1, pp. 136-141 (1992)
- [3] Y. Park, J. Sklansky: "Automated Design of Linear Tree Classifiers", *Pattern Recognition* Vol. 13, No. 12, pp.1393-1412 (1990)
- [4] Y. Park, J. Sklansky: "Automated Design of Multiple Class Piecewise Linear Classifiers", *Journal of Classification* 6, pp. 195-222 (1989)
- [5] P.A. Devijver, J. Kittler: "Pattern Recognition - A Statistical Approach", Prentice-Hall (1982)
- [6] J. Sklansky, G.S. Wassell: "Pattern Classifiers and Trainable Machines", Springer-Verlag, New York (1979)
- [7] S.R. Dubois, F.H. Glanz: "An Autoregressive Model Approach to Two-Dimensional Shape Classification", *IEEE Trans. Pattern Anal. Machine Intell.*, PAMI-8, No. 1, pp.55-65 (1986)
- [8] C.T. Zahn, R.Z. Roskies: "Fourier Descriptors for Plane Closed Curves", *IEEE Trans. Comput.* C-21, pp. 269-281 (1972)
- [9] M.K. Hu: "Visual Pattern Recognition by Moment Invariants", *IRE Trans. Inform. Theory* IT-8, pp. 179-187 (1962)
- [10] R.O. Duda, P.E. Hart: "Pattern Classification and Scene Analysis", John Wiley & Sons (1973)

著者紹介



朴榮泰(正會員)

1979年 2月 서울대학교 전자공학과
(학사). 1981年 8月 한국과학기술원
전기 및 전자공학과(석사). 1989年
12月 University of California,
Irvine 전기 및 컴퓨터공학과(Ph.
D.). 1990年 1月 ~ 1990年 7月

University of California, Irvine (Post Doc.).
1990年 7月 ~ 1991年 2月 Innovision Medical Inc.
1991年 6月 ~ 1992年 1月 대우통신 중앙 연구소.
1992年 3月 ~ 현재 경희대학교 전자공학과(조교수).
주관심 분야는 컴퓨터 비전, 패턴인식, 신경회로망 학
습이론 등임.