

論 文

다층 신경망을 사용한 항공기 인식 및 3 차원 방향 추정

正會員 金 大 映* 正會員 秦 成 -* 正會員 孫 錄*

Aircraft Identification and Orientation Estimation Using Multi-Layer Neural Network

Dae Young KIM*, Sung Il CHIEN*, Hyon SON* *Regular Members*

要 約 본 논문에서는 Backpropagation 학습 이론을 사용한 다층 구조 신경 회로망을 이용하여 3차원적으로 항공기 인식과 항공기의 3차원 회전 방향 추정을 검증니. 시뮬레이션을 통하여 수행하였다. 항공기 영상으로부터 2차원 영상에서 해부 불변(distortion invariant) 특성을 가지는 피자(L, Φ)를 추출하여 신경 회로망 항공기 인식 기의 학습(training)에 사용하였다. 그리고 신경 회로망 인식기 설계시 그 구조를 최적화 함으로써 높은 인식률을 가지는 항공기 인식기를 구성하였다. 신경 회로망 학습 과정에서 학습 이론으로는 멸점된 backpropagation 학습 이론을 도입하고 아울러 학습 수행중에 학습 변수(learning parameter)값을 변화 시키는 방법을 사용하여 전체 학습 시간을 효과적으로 단축 시킬 수 있었다.

ABSTRACT Multi layer neural network using backpropagation learning algorithm is used to achieve identification and orientation estimation of different classes of aircraft in the variety of 3-D orientations. In plane distortion invariant (L, Φ) feature was extracted from each aircraft image to be used for training neural network aircraft classifier. For aircraft identification the optimum structure of the neural network classifier is studied to obtain high classification performance. Effective reduction of learning time was achieved by using modified backpropagation learning algorithm and varying learning parameters.

I. 서 론

최근 컴퓨터 시각(computer vision) 기술 분야에서 컴퓨터를 이용하여 인간이 보유한 시각

정보 처리 능력과 같은 기능을 가지는 시각 시스템을 개발하기 위한 연구가 활발히 진행 되고 있다. 이러한 시각 기술에 관한 연구 분야중 시각 패턴 인식에 관한 연구는 그동안 많은 연구가 이루어져 인쇄된 문자와 같은 2차원 물체 인식 문제에 대해서는 상당히 성공적인 연구가 진행되었으나 상대적으로 3차원 물체 인식 문제

*慶北大學校 電子工學科
Dept. of Electronics, Kyungpook National Univ.
論文番號 : 91- 4 (接受1090. 10. 5)

에 대해서는 큰 진전을 나타내지 못하였다. 그러나 최근 공장 자동화에 따른 산업용 로보트에 의한 부품 식별, 항공기와 같은 복잡한 식별 등과 같이 산업, 군사, 항공 우주등 여러 분야에서 3차원 물체 인식에 대한 필요성이 증대됨에 따라 3차원 물체 인식에 관한 연구는 서서히 빠른 인식 분야에서 매우 중요한 연구 과제로 많은 연구가 진행되고 있다.

3차원 구조의 물체 인식 분야에서 항공기 인식 문제는 현재까지 여러 가지 기법으로 많은 연구가 수행되어 왔다. Dudani 등⁽¹⁾은 항공기 영상으로부터 항공기 기술 정보로 불변 모멘트(invariant moment)를 추출한 후 이 피쳐를 기반으로 Bayesian Classifier와 K nearest neighbor classifier를 설계하여 항공기 인식을 수행하였다. 또 Wallace와 Wintz⁽²⁾는 피쳐로 표준화된 fourier descriptor를 사용하여 항공기 인식 문제에 적용하였다. 이 방법들은 왜곡 불변 피쳐(distortion invariant feature)를 기반으로 하는 전동적 인식 방법으로 선택된 인식 기의 예측율을 개선시키는 방법에 한계가 있어서 진전 차수의 신축성 (flexibility)에 문제가 있다. 인식 기의 신축성을 더욱 높이고 인식 과정에 인간적 인식 추론을 도입한 새로운 AI 기법으로 Brooks⁽³⁾는 모델에 기반을 둔 시스템(model based system)을 Casasent와 Chien⁽⁴⁾, ⁽⁵⁾은 규칙에 기반을 둔 시스템(Rule Based System)을 도입하여 항공기 영상 인식 문제에 적용 시켰다. 그러나 이 방법들은 시스템이 신축성을 가지는 장점이 있으나 시스템이 매우 복잡하므로 시스템 설계시 상당한 시간과 노력이 필요하게 된다.

최근 왜곡 인식 분야에서 새로운 인식기로 매우 유용하게 사용되고 있는 신경 회로망은 대규모 병렬 처리 기능(massive parallel processing)에 의해 실시간 처리가 가능하고, 학습형 하습 능력(adaptive learning capability)과 결함수복 능력(fault tolerance capability)을 가지고, 위하는 목적에 적용하는데 비교적 개발 시간이 짧은 장점을 가지고 있다. 그래서 장차 VLSI화, 병렬 컴퓨터 기술 등에 대한 연구가 완료되어 하드웨어적인 구성이 실현되면 인식 과정에서 정식감 처리 또는 이에 준하는 처리 속도가 요구되는 항공기와 같은 이동성 물체 인식 문제에 신경 회로망 기법을 매우 적절하게 사용 가능성을 알 수 있다.

본 논문에서는 case study로 3차원 구조의 항공기를 2차원 영상에 투영시키 영상화한 후 항공기 영상으로부터 2차원 영상에서 이동(shift), 크기 변화(scale change), 회전(rotation) 변형에 불변(invariant)하는 특성을 가지는 왜곡 불변 피쳐를 추출하여 이 값을 입력으로 하고 항공기의 영상 분류 정보와 3차원적으로 회전된 항공기의 회전 각도 정보를 출력으로 하는 다중 구조 신경 회로망 인식기를 각각 설계해서 항공기 인식 및 항공기 회전 각도 추정에 대한 성능을 컴퓨터 시뮬레이션을 통하여 알아 보았다. 그 계량적인 과정은 그림 1과 같다. 그리고 항공기 인식기 설계시에는 신경 회로망 인식기의 최적 구조를 결정하였고 또한 신경 회로망 학습시 전체 학습 시간을 효과적으로 단축 시킬수 있는 학습 방법을 제안하고 다른 학습 방법들과 그 결과를 비교하였다.

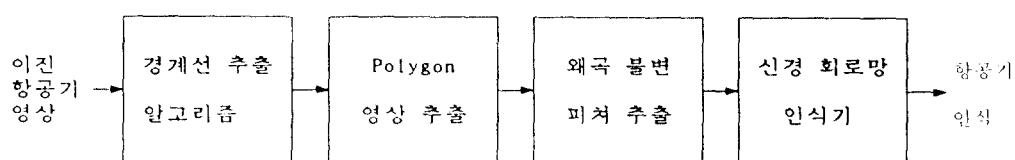


그림 1. 왜곡 불변 피쳐(L, Φ) 추출 및 항공기 인식 과정

Distortion-invariant Feature(L, Φ) Extraction and Aircraft Recognition Procedure

II. 왜곡 불변 피쳐(feature) 추출

항공기는 그 구조가 3차원적으로 복잡하고 위치를 이동하므로, 보는 각도에 따라 모양을 상당히 달리하고 그 영상 역시 다양하게 투영된다. 그래서 여러 종류 (multi-class)의 항공기 모양을 기술(description)하기 위해서는 상당히 방대한 영상 정보를 필요하게 된다.

어떤 물체를 인식하기 위해서는 그 물체의 영상 정보로부터 직접 인식기를 설계할 수 있으나 방대한 영상 정보를 저장 해야하는 문제점으로 인하여 실용성이 크게 저하된다. 그래서 일반적으로 저장한 영상 정보량을 줄이기 위해 어떤 물체의 영상 정보로부터 그 물체를 효과적으로 기술할 수 있고 2차원 영상 내에서 이동, 크기 변화, 회전에 불변인 왜곡 불변 피쳐(feature)를 추출한 후 이를 기준으로 인식기를 설계하는 방법이 많이 사용되고 있다.

본 논문에서는 항공기 영상으로부터 왜곡 불변 피쳐(L, Φ)를 추출하여 이 피쳐값을 기반으로 설계한 신경 회로망 인식기를 통하여 항공기 영상 인식 실험을 수행하였다. 왜곡 불변 피쳐 (L, Φ)는 그림 1의 전반부에서와 같이

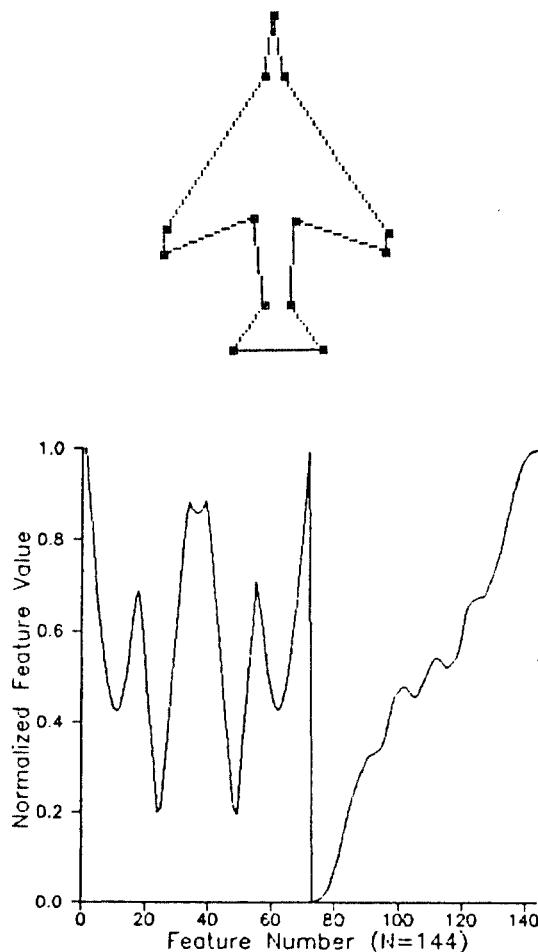
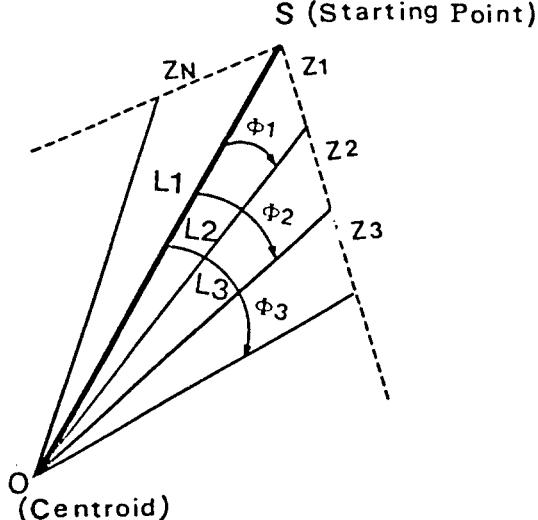


그림 2. (a) 피처(L, Φ) 공간 생성도
Schematic Diagram of Feature Space Generation
(b) Polygon 영상
Polygon Image
(c) 추출된 피처값 Feature Value



이진 항공기 영상으로부터 항공기 경계선(boundary) 영상과 polygon 영상^{4~6~7)}을 차례로 추출 한 후 다음에서 기술한 방법으로 구하였다. 피처의 구성 성분인 거리 L 과 각도 Φ 는 그림 2(a)에서와 같이 항공기 무게 중심(centroid)으로부터 항공기 polygon 영상의 경계선 성분을 등 간격으로 분할한 N개의 각 점에 대한 거리 L 과 N개 각 점에서 구한 거리중 가장 먼 거리에 있는 점을 출발점(S)으로 선택하여 무게

중심점 0과 출발점 S를 연결한 OS선을 기준으로 N개 각점에 대해 측정한 각도 Φ 로 정의 하였다. 그림 2(b)에 대하여 구한 폐처값은 그림 2(c)와 같이 표현할 수 있다. 그림 2(c)에서 전체 폐처값 144개의 반에 해당하는 처음 72번재 까지의 폐처값은 거리 L값을 나타내고 나머지 72개의 값은 각도 Φ 값을 나타낸다.

폐처(L, Φ)는 무게 중심(centroid)을 중심점으로 선택하여 이동에 불변이고, 무게 중심에서 경계선상에 놓여 있는 N개의 점 중에서 가장 먼거리에 놓여 있는 점을 출발점(S)으로 선택하였으므로 회전에 불변인 성질을 가진다. 또 무게 중심으로부터 경계선 상의 N개 각 점까지의 거리 L과 각도 Φ 는 최대값을 각각 1.0으로 표준화(normalization)하여 크기 변화에 불변(invariant)인 성질을 가지도록 하였다.

III. 다층 신경 회로망의 학습 이론

논문에서 항공기 인식기(classifier)로 사용한 다층 신경 회로망은 그림 3과 같이 입력층(input layer)과 출력층(output layer) 사이에 하나 이상(hidden layer)을 가지는 2층 구조이다.

이러한 구조를 가진 신경 회로망에서의 학습(learning)이나 입력층의 입력뉴런을 통하여 입력되는 각각의 입력 패턴에 대하여 출력층의

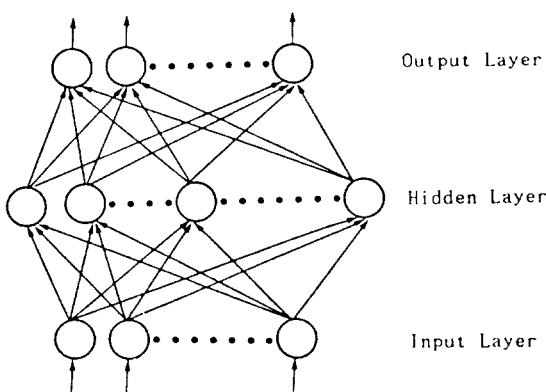


그림 3. 다층 신경 회로망 구조
Structure of Multi-layer Neural Network

출력 뉴런에서 구해지는 실제 출력값(actual output)이 기대된 출력값(target output)과 같도록 하기 위해 신경 회로망을 구성하는 각 층 사이의 뉴런 간의 연결 계수 즉 시냅스강도(synapse strength) 값을 조정하는 것이다. 최근 다중 신경 회로망의 학습이론으로 여러가지 방식이 제시되고 있으나 Generalized Delta Rule⁸을 이용한 Backpropagation 학습 이론이 일반적 으로 널리 이용되고 있다. 그러나 이 학습 방식은 학습 수행에 매우 많은 시간이 소요 되는 단점이 있다. 따라서 본 논문에서는 항공기 인식 기로 사용한 신경 회로망 인식기의 학습 과정에서 학습 시간을 단축시키기 위한 방법으로 Falchman¹⁰이 제안한 수정된 Backpropagation 학습 이론을 도입하고 학습 수행 중 적절한 시점에서 학습 변수(learning parameter) 값을 변화시키는 방법을 추가하여 학습 시간을 더욱 단축 시켜주는 개선된 학습 효과를 얻을 수 있었다. 자세한 내용은 다음 IV 장 컴퓨터 시뮬레이션에서 기술하기로 한다.

본 논문에서 사용한 다층 신경 회로망의 학습 과정을 요약하면 다음과 같다.

과정(1) 하위층의 뉴런 i에서 상위층의 뉴런 j로 연결되는 연결 계수 W_{ij} 와 임계값(Threshold old) Θ_j 는 임의의 값으로 초기화 한다.

과정(2) 주어진 입력 패턴에 대하여 각 뉴런에서의 실제 출력값을 다음과 같은 비선형 관계식에 의해 구한다.

$$O_j = 1 / (1 + e^{-Net_j}) \quad Net_j = \sum W_{ij} O_i + \Theta_j$$

과정(3) 각 입력 패턴에 대하여 모든 뉴런에서 기대 출력값(target output: T_j)과 실제 출력값(actual output: O_j) 사이의 오차 δ_j 를 구한다. $\delta_j = (\tanh^{-1}(T_j - O_j)) / (O_j(1 - O_j) + 0.1)$ (output layer)

$$\delta_j = O_j(1 - O_j) \sum \delta_k W_{kj} \quad (\text{hidden layer})$$

δ_k : output layer error

과정(4) 에러(error) 값을 줄이도록 각 연결 강도 값을 조절.

$$\Delta W_{ij}(n+1) = \epsilon \delta_j O_i + \alpha \delta_j(n)$$

과정(5) 전체 에러값이 학습시 정해진 한계값

까지 감소할 때까지 (2)~(4) 과정을 반복한다. 여기서 상수 ϵ 는 학습률(Learning rate)로서 이 값이 클수록 연결 강도값의 변화량이 커지게 된다. 이 값이 커지면 학습 속도가 증가하는 장점이 있으나 수렴하지 못하고 진동(oscillation)이 발생할 우려가 있으며 이 값이 너무 작을 경우 진동은 발생하지 않으나 학습 속도가 매우 늦어지는 단점이 생긴다. 또 상수 α 는 관성항(momentum)으로서 전 단계의 계산에서 구해진 각 연결 강도의 변화량을 다음 단계에 반영 시키는 역할을 함으로써 학습 수렴 속도를 증가 시키는 효과를 나타낸다. 그리고 E는 전체 입력 패턴에 대한 출력층에서의 전체 에러(total error)값을 나타내며 다음과 같이 정의된다. 여기에서 p 는 입력 패턴을 그리고 i 는 출력층의 출력 뉴런을 나타낸다.

$$E = \sum_p \sum_i (T_i - O_i)^2$$

수정된 Backpropagation 학습 이론은 출력층 뉴런에서 예상값 계산시 전술한 학습 과정(3)에서 나타낸 바와 같이 계산식의 첫번째 항에 Hyperbolic Arctangent 함수를 도입하여 기대 출력 값(T_j)과 실제 출력 값(O_j)사이의 차이를 더욱 더 잘 반영하도록 하였고 두번째 항에서는 원래의 Backpropagation 학습 이론의 예상 계산식에 상수항(0.1)을 더해줌으로써 실제 출력 값(O_j)이 0 또는 1의 값을 가질 때 예상값 δ_j 가 0이 되는 것을 방지 함으로써 원래의 Backpropagation 학습 이론에 의한 학습에 비해 학습 시간을 단축 시키는 효과를 얻을 수 있다.

IV. 컴퓨터 시뮬레이션

1. 항공기 영상 데이터 베이스(data base)

본 논문에서 사용한 항공기 영상은 Purdue 및 Carnegie Mellon 대학에서 개발된 Model-based CAD System⁽¹⁰⁾을 이용하여 제작하였다. 제작된 항공기 영상 데이터 베이스는 128×12

8 이진 영상(binary image)이고 비행기 종류는 DC10, Phantom, Mig21 3종류이다.

일반적으로 항공기 영상은 3차원 구조의 항공기가 그림 4와 같은 3차원 좌표계 중심에 있다고 가정하고, x, y, z축 방향으로 각각 $\Delta\Theta$ 만큼 회전 시킨 후 z축 방향으로 투영시켜 만든다. 이렇게 만든 항공기 영상이 x, y, z축 방향으로 회전이 없을 때 초기의 항공기 위치는 그림 4의 좌표계에서 항공기 무게 중심은 좌표계 중앙에, Nose는 y축, 오른쪽 날개는 +x축, 그리고 관찰자의 방향은 z축(Top-down-view)에 놓이게 된다.

3차원 구조의 항공기는 바라보는 각도에 따라 모양이 상당한 변화를 나타내므로 한 기종(claas)의 항공기 모양을 적절하게 기술(description)하기 위해서는 비교적 많은 학습용 영상 세트(training image set)를 구성해야 한다. 그리고 3차원적으로 촬영된 항공기는 좌표계에서 x,y,z축 방향으로 각각 회전된 회전 각도의 범위로 나타낼 수 있다.

본 논문에서는 3차원적으로 촬영된 항공기를 기술하기 위해 x,y,z축 방향으로의 회전 각도 범위 범위는 x축은 $-60^\circ \leq \Theta_x \leq 60^\circ$, y축은 항공기가 y축에 대하여 대칭 이므로 양의 각도만 고려하여 $0^\circ \leq \Theta_y \leq 60^\circ$ 로 정하였고, z축은 외쳐(L, Φ)가 2차원 영상에서 회전에 불변인 성질을 가지므로 임의의 특정 각 $\Theta_z=60^\circ$ 로 고정한 후

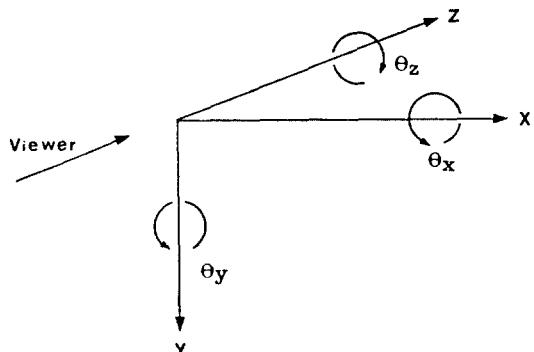


그림 4. 좌표계 시스템
Coordinate System

$\Delta\Theta_x = \Delta\Theta_y = 10^\circ$ 로 하여 한 종류의 항공기마다 서로 다른 72개의 회전 각도를 가진 전체 216 개의 학습용 영상 세트(training image set)를 구성하였다. 이렇게 구성한 학습용 영상 세트는 신경 회로망 인식기를 학습시키는데 사용하였다. 또 별도로 학습용 영상 세트에 비해 x, y축 방향으로는 각각 $\pm 5^\circ$ 의 회전 각 범위를 가지고 z축 방향의 회전 각도로는 임의의 두 정수 $\Theta_z = 240^\circ$ 을 가지는 216개의 검사용 영상 세트(testing image set)를 구성하여 설계된 신경 회로망 인식기의 인식 성능을 알아보았다. 그래서 항공기 인식 과정에는 전체적으로 432개의 항공기 영상 세트가 사용되었으며 x,y,z축 방향으로 각각 $\Delta\Theta$ 만큼 회전한 항공기 데이터 베이스(data base)에 예는 그림 5와 같다.

2. 신경 회로망 인식기 설계

본 논문에서는 그림 3과 같은 구조의 신경 회로망 인식기 설계와 신경 회로망 각 층(layer)의 구조 요소인 뉴런 수를 최적화 함으로써 인식기의 인식률을 향상 시켰다.

각 층에서의 뉴런 수 설정은 먼저 3종류의 항공기 분류를 3개의 2진 출력값으로 나타내기 위하여 출력층 뉴런의 수는 3개로 설정하였다. 여기서 3종류 항공기 각각에 대한 출력 뉴런에서의 기대값으로 DC10 항공기는 100, Phantom 항공기는 010, 그리고 Mig21 항공기는 001로 정하였다. 이렇게 출력 뉴런의 수를 3개로 먼저

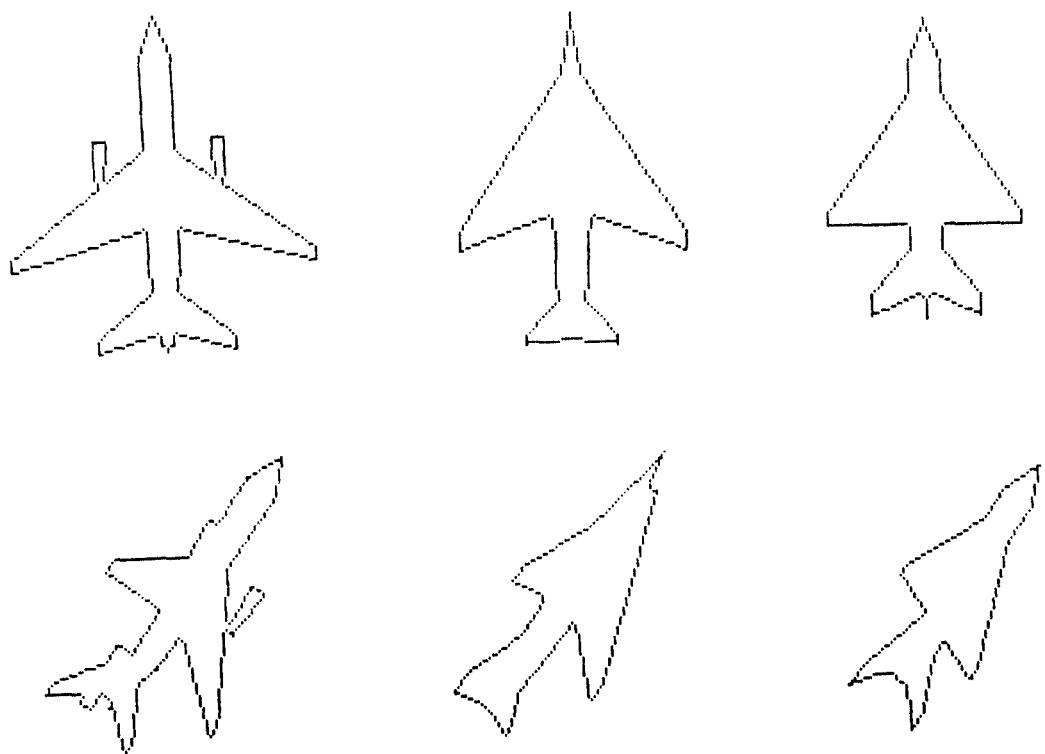


그림 5. 항공기 영상 데이터 베이스
Aircraft Image Data Base
(a) DC10, (b) phantom, (c) Mig21
($\theta_x=0^\circ, \theta_y=0^\circ, \theta_z=0^\circ$: Top down view)
(d) DC10, (e) phantom, (f) Mig21
($\theta_x=30^\circ, \theta_y=50^\circ, \theta_z=70^\circ$)

결정한 후 나머지 은닉층과 입력층에서의 최적 뉴런 수는 다음에 기술한 실험과정 2-1, 2-2를 통하여 차례로 결정하였다.

3개의 출력 뉴런을 통해서는 3종류의 항공기 분류를 위한 출력 결과값을 1) 각 출력 뉴런을 임계값 $T=0.5$ 로 Threshold 시킨 방법(Threshold 법), 2) 3개의 출력 뉴런 값 중 최대값을 가지는 뉴런의 출력값과 1의 값을 가지고 한 방법(최대값 선택법)으로 각각 구한 후 출력 결과값 결정 방법에 따른 인식률을 따로 측정하여 비교하였다.

2.1 은닉층 뉴런 갯수 변화에 따른 인식률 변화

출력 뉴런이 3개로 결정된 후 입력 뉴런과 은닉층 뉴런 수의 결정은 이 두 값이 상호 연관 관계에 있으므로 최적의 두 값을 구하기 위한 방법으로 일차적 시뮬레이션(simulation)에 의해 먼저 입력 뉴런수(N)를 N/M 의 비가 2/3인 144개로 결정한 후 은닉층 뉴런 수를 결정하였다. 여기서 N은 인식 실험에서 사용한 전체 학습용 영상 세트의 갯수로 216을 나타낸다. 출력 뉴런과 입력 뉴런이 각각 3개와 144개로 결정된 후 은닉층 뉴런 수를 1개에서 30개까지 변화시킴면서 216개의 학습용 영상 세트를 은닉층 뉴런의 수가 서로 다른 각 신경 회로망의 전체 에러값이 1.0 이하가 될 때까지 각각 학습 시킨 후 인식 실험을 통하여 최고의 인식률을 가지는 은닉층 뉴런 수를 인식층에서 최적의 뉴런 수로 결정하였다. 그리고 학습시 전체 에러의 한계값으로 1을 선택한 이유는 항공기 분류 출력값을 나타내는 3개의 출력 뉴런 값 중 어느 한 곳에서도 인식 에러가 발생하지 않도록 하기 위한 것이다.

일반적으로 학습 변수(learning parameter) 값은 학습시 여러가지 수행 과제의 경우에 따라 경험적으로 설정되는 것이 보편적인 현상이다. 본 실험에서 학습율 ϵ 는 일차적 시뮬레이션(simulation) 과정에서 ϵ 값이 0.01 이상에서는 진동이 발생하였으므로 진동이 발생하지 않는 범위내에서 가능한 큰 값인 0.005를 선택하였고

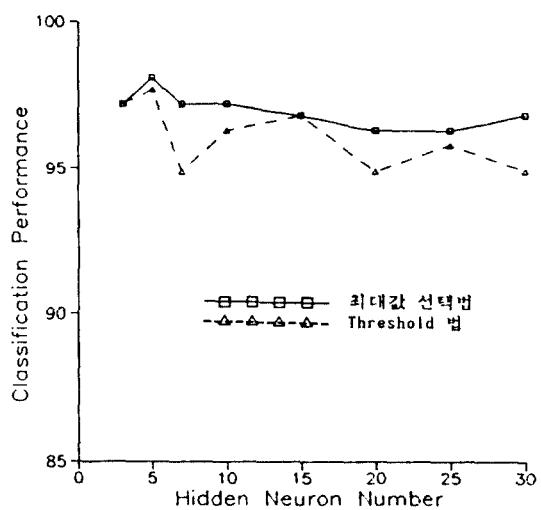


그림 6. 은닉층 뉴런 수 변화에 따른 인식률
Classification Performance V.s. Hidden Neuron Number

또 관성항 α 는 ϵ 값이 비교적 작은 값을 가지므로 학습 속도를 증가시키기 위해 0.9로 설정한 후 모든 학습을 수행하였다.

입력 뉴런과 출력 뉴런이 각각 144개와 3개로 결정된 후 인식층 뉴런의 수가 1개에서 30개로 구성된 각 신경 회로망 인식기가 216개의 검사용 세트(testing set)에 대하여 앞에서 기술한 두 가지 출력 분류 방법으로 인식률을 구한 결과는 그림 6과 같다. 그림 6의 결과로부터 최적의 은닉층 뉴런 수는 5개로 결정하였고 이 때 최고 인식률은 98.6%였다. 또한 최적의 인식층 뉴런 수가 비교적 작은 5개로 설정되어 전체 신경 회로망 인식기의 규모가 커지는 것을 방지하여 1회의 학습에 소요되는 시간을 적절하게 감소시키는 효과를 얻을 수 있었다. 그리고 두 가지 출력 분류 방법에 의한 인식률을 각각 측정하여 비교한 결과 최대값 선택 방법이 Threshold 법에 의해 전반적으로 더 높은 인식률을 나타냄을 알 수 있었다.

인식층 뉴런 수를 달리하는 각 신경 회로망 학습 과정에서 은닉층 뉴런이 1개와 2개로 구성된 신경 회로망에서는 학습이 이루어지지 않았다. 그리고 인식층 뉴런 갯수가 3개 이상으로

구성된 모델은 신경 회로망 인식기는 전체 에러값이 1.0 이하로 학습되었을 경우 216개의 학습용 셋트(Training set)에 대한 인식률은 모두 100%입니다.

2.2. 입력 피쳐수(N)의 변화에 따른 인식률 변화

일반적으로 빠른 인식기는 어떤 문제를 기술하는 정보로 사용하는 피처의 수를 증가시킬수록 인식기에서의 인식률은 미래하여 증가하는 경향을 보이나 어떤 단계값이 주제하게 된다.

표 1의 실험 과정에서 훈련증과 테스트증 뉴런의 수가 각각 3개와 5개로 설정된 후 마지막으로 신경 회로망 인식기의 구성을 훈련 뉴런에 힐드되는 최적의 피처 수를 결정하여 높은 인식률을 가지는 피처수로 인식기를 구성하고자 한다. 최적의 인식률을 가지는 피처의 힐드 피처 수를 결정하기 위하여 헝龜가 영상으로부터 한 빠른의 헝龜가를 기술하기 위해 구출된 피처의 수인 N, M의 비율이 0.16(32 : 216)에서 1.0(216 : 216)까지 변화시켜면서 인식기의 인식률을 최대값 선택법을 이용하여 구현 결과는 그림 7과 같다. 그림 7의 결과에서 힐드 피처의 수 N은 N/M의 비가 2/3와 1 즉 N이 144개와 216개일 때 똑같이 98.6%의 최고 인식률을 나타내었다. 그러나 힐드 증의 뉴런 수가 증가하면서 신경 회로망 전체의 가중치 개수와 학습에 필요한 시간이 길어지는 문제점이 발생하는데도 우리는 최적 힐드 증 뉴런 피처 수로 144개 선택하였다.

표 1은 본 논문에서 설계한 최적 구조의 신경 회로망 인식기에 의한 3종류 216세트의 감자용 헝龜가 영상에 대한 인식 실험 결과이다. 이 결과에서 DC10 헝龜가의 72개 힐드 영상에 대해서 71개는 올바르게 DC10으로 인식 되었으나 나머지 1개에 대해서는 Mig21로 인식하는 에러를 발생 하였음을 알 수 있다.

3. 다중 구조 신경 회로망 학습 시간 개선 방법

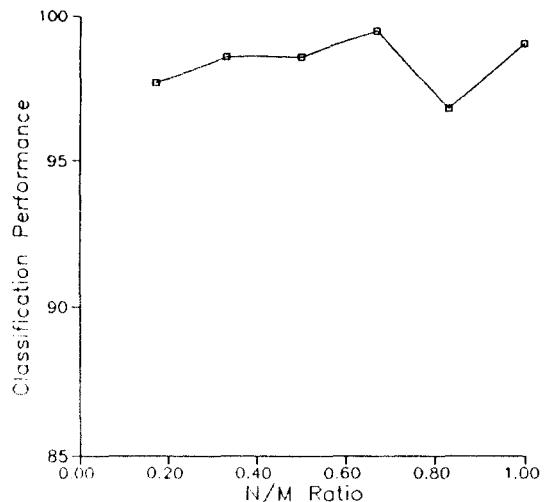


그림 7. 힐드 피처 수 변화에 따른 인식률
Classification Performance Vs. Input Feature Number.

표 1. 설계된 인식기의 인식기 에러 테이블
Classification Error Table for Designed Classifier

Out In	DC10	Phantom	Mig21	Classification Rate
DC10	71	0	1	98.6%(71 / 72)
Phantom	1	70	1	97.2%(70 / 72)
Mig21	0	0	72	100%(72 / 72)

일반적으로 Backpropagation 학습 과정에서 전해 에러(error)값은 학습 초기에는 끊임으로 감소하다가 에러 값이 어느정도 충분히 감소한 시점에서 부터는 매우 작은 폭으로 감소하면서 변화하므로 학습시 정해준 학습률 에러값에 포함되어 약해지는 많은 학습의 학습이 필요하게 된다. 따라서 후반부 학습은 전체 학습 학습 횟수의 많은 부분을 차지하게 되어 결과적으로 전체 학습에 많은 시간이 소요되는 원인이 된다.

그리므로 이러한 특징을 가지는 Backpropagation 학습 과정에서 전해 학습 시간을 단축 시킬 수 있는 학습 방법을 제안하기 위하여 힐드 뉴런이 144개, 출력 뉴런이 3개, 그리고 은닉 뉴런이 5개로 구성되는 신경 회로망에서 216개의

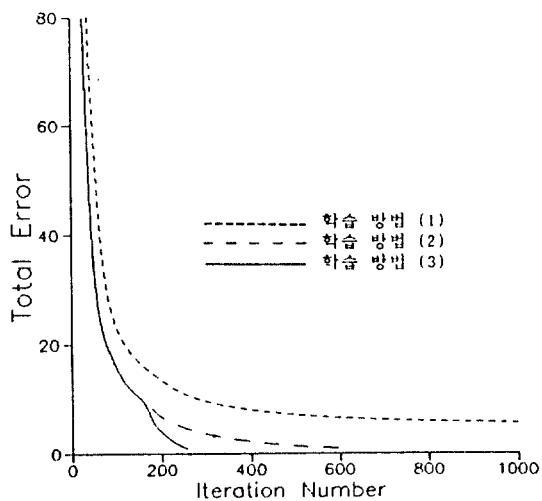


그림 8. 학습 방법에 따른 학습 횟수 비교도
Iteration Number Vs. Learning Method.

학습용 영상 세트를 전체 에러값이 1.0 이하가 될때까지 학습 되는 과정을 여러가지 방법으로 비교한 결과는 그림 8과 같다.

그림 8에서 학습 방법(1)은 원래의 Backpropagation 학습 이론에 의한 학습과정으로 후반부에서의 학습이 전체 학습의 대부분을 차지하게 됨을 알 수 있다. Fahlman은 학습 시간을 단축시키기 위한 방법으로 III절에서 언급한 수정된 Backpropagation 학습 방법을 제시하였다. 그림 8에서 Fahlman이 제시한 학습방법(2)에 의해서 전체 학습 시간은 매우 단축 시킬 수 있었으나 방법(1)에서와 같이 여전히 후반부에서 많은 횟수의 학습이 필요함을 알 수 있다. 따라서 본 논문에서는 학습 방법(2)을 개선하여 후반부에서의 학습 횟수를 크게 단축시킴으로써 전체 학습 시간을 단축시키기 위한 방법으로 학습 초기에 전체 에러값이 크게 감소된 후 에러값의 변화폭이 작게 감소하게 되는 시점(본 실험에서 epoch number=150)에서 초기 학습시 설정해 준 학습 변수값 중 관성항 α 값을 0.9에서 1.0으로 증가시키는 학습 방법(3)을 사용하여 그림 6의 결과에서와 같이 전체 학습 시간을 효과적으로 감소시키는 결과를 얻을 수 있었다. 그러므로

본 논문에서 제안한 학습 방법(2)는 전체 학습 과정이 그림 8과 같이 전동이 없이 매우 안정되게 수행되는 경우의 학습에서 관성항 α 값을 적절히 변화시킴으로써 전체 학습 주체 속도를 크게 증가시키는 효과를 얻을 수 있다.

시뮬레이션 과정에서 학습 방법(2)과 (3)은 각각 601회, 256회의 학습에서 전체 에러값이 1.0 이하가 되어 학습이 완료 되었으나 학습 방법(1)은 1,000회의 학습이 수행된 후에도 전체 에러값이 약 5의 값을 가짐으로써 전체 에러값이 1.0 이하가 되어 학습이 완료되기 위해서는 이전히 후반부에서의 많은 학습이 필요함을 알 수 있다. 모든 학습은 coprocessor를 장착한 80386 machine을 이용하였으며 개선된 학습 방법(3)에 의해 소요되는 수행 CPU 시간은 대략 1시간 정도였다.

4. 항공기 분류 및 회전 각도 추정

본 절에서는 항공기 분류에만 한정된 항공기 인식 문제에서 한층 더 발전하여 항공기 분류 정보와 더불어 3차원적으로 회전한 항공기의 회전 각도 정보를 출력으로 얻을 수 있는 신경회로망을 설계하여 그 성능을 알아보았다.

설계된 신경 회로망의 입력 뉴런 수는 앞의 2절 항공기 인식 실험에서 최적의 입력 피쳐 수로 결정된 144개를 사용하였고, 출력 뉴런은 75개로 결정하여 처음 3개의 뉴런을 통해서는 3종류의 항공기 분류 정보를 그리고 나머지 72개의 뉴런을 통해서는 한 종류의 항공기가 가지는 72가지의 서로 다른 회전 각도 중 어느 두 정 회전 각도 정보를 나타내도록 하였다. 또 출력 뉴런을 구성하는 두 출력 뉴런부에서의 출력값들은 최대값을 가지는 뉴런에서의 출력값만 각각 1의 값을 가지도록 하여 항공기 분류 정보와 회전 각도 정보를 동시에 나타내도록 하였다.

그리고 인너층 뉴런 수는 일차적 시뮬레이션을 통하여 입력 뉴런이 144개 출력 뉴런이 75개로 구성되는 인식기의 규모가 가능한 커지지 않는 범위 내에서 216개의 학습용 세트를 학습시킬 수 있는 30개로 구성하였다.

이렇게 구성된 신경 회로망의 구조는 그림 9와 같다. 전술한 바와 같이 75개의 출력값에서 차운 3개의 출력값은 항공기 분류 정보 즉 이 값이 100%인 인식된 항공기가 DC10일을 나타낸다. 그리고 나머지 72개의 출력값은 인식된 항공기의 3차원 회전 방향을 나타내는데 예를 들면 72개의 출력값 가운데 35번 째 값이 1이고 나머지 71개의 값이 0이면 이 값을 0° 회전 항공기가 x축, y축 그리고 z축 방향으로 각각 -10° , 40° , 60° 회전 하였음을 나타낸다.

이 신경 회로망에서의 학습은 출력 뉴런에서의 실제 출력값이 임계값 0.5를 넘는 경우에는 1의 값을 가지도록 하여 216개의 전체 패턴에 대한 출력 뉴런에서의 실제 출력값이 기대 출력값과 같은 값을 가지는 패턴 수의 비가 100%될 때까지 수행하였다. 학습이 완료된 후 신경 회로망 인식기에서의 전체 예리값(E)은 약 25%로 나타내었다.

표 2는 설계된 인식기의 학습이 완료된 후 216개의 학습용 영상 세트와 216개의 검사용 영상 세트에 대하여 항공기 인식과 항공기 회전 방향 실험을 각각 수행한 결과이다. 표 2의 결과에서 216개의 학습용 세트에 대해서는 항공기 인식과 항공기 회전 방향 추정이 모두 100% 이루어졌음을 알 수 있고 216개의 검사용 세트에 대해서는 항공기 인식률이 96.3% 그리고 ±5°의 해상도 범위에서 항공기 회전 방향 추정률은 89.4%이 있다.

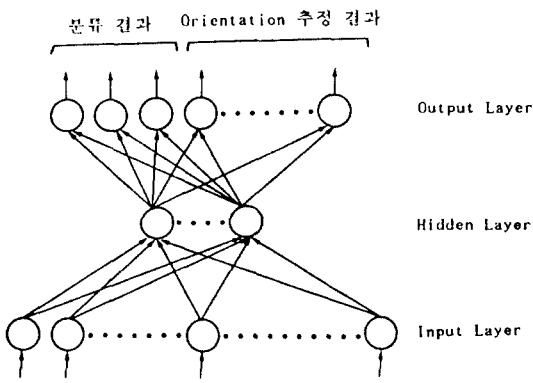


그림 9. 다중 신경 회로망 인식기 구조
Structure of Multi-layer Neural Network Classifier

표 2. 항공기 인식 및 회전 방향 추정 결과
Results of Aircraft Identification and Orientation Estimation

대상	항공기 종류	항공기 인식률	회전방향 추정률
총	DC10	93.1%	79.2%
	Phantom	98.6%	95.8%
	Mig21	97.2%	91.7%
나마자	DC10	100%	100%
	Phantom	100%	100%
	Mig21	100%	100%

V. 결 론

본 논문에서는 항공기 영상 인식기로서 최근 활발히 연구되고 있는 Backpropagation 학습 방법을 이용해 다음 구조 신경 회로망을 도입하였다. 항공기 영상으로부터 항공기 기술 정보로 해상도 분류 범위에서 항공기 회전 방향 추정률은 89.4%이 있다.

또 3차원적으로 회전된 항공기에 대한 회전 방향 추정 실험에서는 ±5°의 해상도(resolution) 범위에서 89.4%의 신뢰도를 가지는 회전 각도 정보를 추정할 수 있었다. 그리고 신경 회로망 학습과 학습 시간을 단축시키기 위한 방법으로 수성된 Backpropagation 학습 방법을 도입하고 학습 과정에 학습 변수값을 변화시키는 방법을 추가하여 후반부에서의 학습 시간을 크게 단축시킴으로써 전체 학습을 매우 효과적으로 수행하였다.

参考文献

1. S.D. Dudani, K. Breeding and R. McGhee, "Aircraft Identification by Moment Invariants", IEEE Trans. on Computers, Vol. c-26, No. 1, pp.38~45, Junuary, 1977.
2. T. Wallace and P. Wintz, "Algorithm Using Normalized Fourier Descriptor", Computer, Vision, Graphics, and Image Processing, Vol. 13, pp. 99~126, 1977.
3. R.A. Brooks, "Model-Based Three Dimensional Interpretation of Two Dimensional Images", IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 5, pp. 140~150, March, 1983.
4. D. Casasent and Sung Il Chien, "Rule Based Processing for String Code Identification : on Aircraft Case Study", SPIE Proc, Vol. 974, August, 1988.
5. 金大映, "Target Recognition Using Neural Networks", 89 신경 회로망 응용 workshop, 한국정보과학회, pp. 111~127, Nov. 1989.
6. U. Ramer, "An Iterative Procedure for the Polygonal Approximation of Plane Curve", Computer Vision,
- Graphics and Image Processing, Vol. 1, No. 3, pp. 244~256, Nobember, 1972.
7. D. Casasent and Sung Il Chien, "Efficient (Φ , S) String Code Symbolic Feature Generation", Optics Communications, Vol. 67, No. 2, pp. 103~106, June, 1988.
8. D.C. Plaut, S.J. Nowlan, and G.E. Hinton, "Experiment On Learning by Back Propagation", CMU CS Report, CMU-CS-86-126, 1986.
9. D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation", Parallel distributed Processing : Explorations in the Microstructures of Conition, Vol. 1, MIT Press, pp. 318~362, 1986.
10. Scott E. Fahlman, "Faster-Learning Variations on Back Propagation : An Empirical Study", Proceedings of the Connectionist Models Summer School, pp. 38~51, June, 1988.
11. D. Casasent and S. Liebowitz, "Model-based Knowledge-based Optical Processors", Applied Optics, Vol.26, No. 10, pp. 1,935~1,942, May, 1987.



金 大 映(Dae Young KIM) 正会員
1960年 5月 30日生
1983年 2月 : 慶北大學校 電子工學科
卒業(工學士)
1985年 2月 : 慶北大學校 大學院 電子工學科 卒業(工學碩士)
1989年 8月 : 慶北大學校 大學院 電子工學科 博士課程修了
1985年 1月 ~ 1986年 1月 : 金星電氣(株)
勤務
1986年 4月 ~ 1990年 2月 : 慶北大學校 電子工學科 助教



秦 成 一(Sung Il CHIEN) 正会員
1955年 4月 28日生
1977年 2月 : 서울대학교 電子工學科
卒業(工學士)
1981年 2月 : 韓國科學技術院 電子工學科
卒業(工學碩士)
1988年 8月 : Carnegie Mellon University
卒業(工學博士)
1981年 3月 ~ 現在 : 慶北大學校 電子工學
科 助教授



孫 縱(Hyon SON) 正会員
1935年 5月 27日生
1960年 9月 : 延世大學校 電氣科 卒業
1960年 8月 : 漢陽大學校 大學院 卒業
1960年 9月 ~ 1977年 4月 : 駐韓美陸軍
戰略通信隊 勤務
1977年 4月 ~ 現在 : 慶北大學校 電子工學
科 教授(工學博士)