

신경회로망을 이용한 다층장갑의 방호성능 예측

A Terminal Ballistic Performance Prediction of Multi-Layer Armor with Neural Network

유요한*
Yoo, Yo-Han

김태정**
Kim, Tae-Jeong

양동열***
Yang, Dong-Yol

ABSTRACT

For a design of multi-layer armor, the extensive full scale or sub-scale penetration test data are required. In generally, the collection of penetration data is in need of time-consuming and expensive processes. However, the application of numerical or analytical method is very limited due to poor understanding about penetration mechanics. In this paper, we have developed a neural network analyzer which can be used as a design tool for a new armor. Calculation results show that the developed neural network analyzer can predict relatively exact penetration depth of a new armor through the effective analysis of the pre-existing penetration database.

주요기술용어 : Multi-Layer Armor(다층 장갑), Neural Network(신경망), Terminal Ballistic Performance Prediction(종말 탄도 성능 평가), Multi-Layer Perceptron(다층 퍼셉트론)

1. 머리말

인간 두뇌에 관한 탐구와 컴퓨터의 무한한 발달과 더불어 인간과 같이 계산하고 판단하며, 인식할 수 있는 인공지능의 구현을 위하여 많은 노력이 경주되고 있다. 1940년대부터 시작된 신경망 관련 연구^{1, 2}는 지난 50여년 동안 비약적인 발전을 이루어 최근에 여러 분야들에 널리 이용되기 시작했다. 시작적인

패턴인식, 음성분석, 로봇학 등 다양한 분야에 적용되고 있으며 기대 이상의 훌륭한 해결점을 제공하여 주었다.

신경망 모델의 시초는 1943년 맥컬록(McCulloch)과 피츠(Pitts)의 논문에서 찾을 수 있다. 그들은 인간의 두뇌를 수많은 신경세포들로 이루어진, 잘 정의된 컴퓨터라고 여겼다. 그들은 단순한 논리적 업무를 수행하는 모델을 보여주었다. 헵(Hebb)의 학습규칙은 두 뉴런 사이의 연결강도를 조정할 수 있는 최초의 규칙이었다. 이 규칙은 학습에 관한 연구를 발전시켰으며 적용적인 신경망 연구에 많은 영향을 끼쳤다. 로

* 국방과학연구소 선임연구원

** 한국과학기술원 기계공학과 대학원 박사과정

*** 한국과학기술원 기계공학과 교수

젠블러(Rosenblatt)은 1957년 퍼셉트론(perceptron)이란 최초의 신경망 모델을 발표하였는데, 여기서는 학습 프로세스에 알파강화 규칙을 사용하였다. 퍼셉트론에 대한 관심의 주된 이유는 어떤 타입의 패턴이 입력층에 주어졌을 때 이 모델이 반응하게 되는 연결강도의 집합을 스스로 발견하는 자동적인 절차에 있다. 학습은 현재 주어진 입력 행렬에 대하여 현재의 각 연결강도를 조정함으로써 얻어질 수 있다. 이러한 퍼셉트론 모델은 그 당시에는 매우 가능성이 큰 것으로 여겨졌으나, 그 후 XOR 함수와 같이 단순한 비선형 분리 문제도 풀 수 없는 것으로 여겨져 20년간 침체기를 맞이하였다.

그 후 1970년대 말과 1980년대 초반에 들어 코호넨(Kohonen), 홉필드(Hopfield), 커크패이트릭(Kirkpatrick), 힌턴(Hinton), 그로스버그(Grossberg), 레멜하트(Rumelhart)등이 신경망 연구를 다시 활성화시켰다. 퍼셉트론과 같이 하나의 조정층으로 구성된 모델들의 한계점들 때문에 입력층, 출력층 그리고 한 개 또는 그 이상의 은닉층(hidden layer)을 쓰는 새로운 모델들이 1980년대 중반에 제안되었다. 이 때 제안된 모델은 은닉층과 백프로파게이션 학습 알고리즘(back-propagation learning algorithm)을 사용함으로써 선형 분리 문제뿐만 아니라 여러 가지 문제점들을 해결할 수 있게 되어 현재까지 여러 분야에서 신경망 이론이 광범위하게 사용될 수 있는 토대를 마련하였다.

최근 컴퓨터의 눈부신 발전에 따라 컴퓨터 상의 가상공간 내에서 실험을 수행하는 수치실험(numerical experiment) 연구가 방탄 구조물의 설계에 일부 적용되기 시작했으나 컴퓨터의 계산능력 부족과 정교한 해석모델의 부재로 인하여 많은 제약을 받고 있는 실정이므로 경량 및 중량 방탄 구조물의 설계를 수행하

기 위해서는 많은 시간과 비용이 소요되는 실험의 수행 및 데이터 축적이 필요하다. 본 논문에서는 기존의 축적된 방탄 시험 데이터를 효과적으로 분석하여 새로운 구조물 설계에 활용할 목적으로 방탄 데이터 분석에 적합한 신경회로망 프로그램을 개발하여 활용성을 평가하여 보고자 한다.

2. 신경회로망

가. 신경망의 주요 모델 및 특성

신경망 모델은 응용 분야에 적합하도록 다양하게 개발되어 현재 그 종류가 수십 가지에 이른다. 신경망의 분류 방법은 입력의 형태에 따라 이진수와 연속 값으로 나누어지며, 이들은 훈련 방법에 따라 각각 지도 학습(supervised learning) 모델과 자율학습(unsupervised learning) 모델로 나누어진다.

가장 잘 쓰이는 학습 방법은 지도 학습인데 통상 입력패턴과 그에 대한 목표 출력으로 이루어진다. 목표출력은 대개 정확한 해답 또는 입력패턴에 대해 정확한 답을 줄 수 있도록 내부적인 변수들이 조정된다. 컴퓨터 프로그램은 프로그래머에 의해 미리 정해진 순서를 따라 수행되는데 비하여 신경망은 입력값과 출력값이 주어지면 원하는 결과를 낼 수 있도록 학습하는 것이므로 신경망 접근 방법은 사람이 분석 대상 시스템의 특징을 인지하거나 분석 대상 시스템의 모델링을 위한 알고리즘이나 프로그램을 개발할 필요가 없게되어 분석에 필요한 시간과 노력을 줄일 수 있다는 장점이 있다. 그렇지만 신경망 접근 방법에도 단점은 있다. 그 중의 하나는 네트워크를 훈련시키는데 시간이 얼마나 걸릴지 사전에 알 수 없다는 점과 효과적인 학습을 위해서는 비교적 많은 학습용 데이터가

필요하다는 점이다. 그럼에도 불구하고 신경망 접근 방법은 물리적 거동 및 작동 기구가 충분히 알려져 있지 못하여 정확한 이론적 해석 및 평가가 곤란한 금속 및 비금속 재료의 고속 충돌 및 파괴문제 분석에 효과적으로 사용될 수 있을 것으로 판단된다.


나. 방탄 데이터 분석을 위한 신경망 모델

방탄 데이터는 수많은 정보를 기초로 하는 실험을 통해 얻어진다. 이렇게 얻어진 자료는 무수한 조합으로 인해 결과 검색과 예측에 상당히 많은 시간을 소요하게 된다. 또한 다양한 실험 조합을 모두 실험해 볼 수는 없으며 행해진 실험을 토대로 임의의 방탄층 구성에 대해 그 결과를 예측해 내어야 한다. 이러한 맥락에서 선정될 수 있는 신경망 모델은 백프로 퍼게이션 학습 알고리즘을 가진 다층 퍼셉트론 (multi-layer perceptron) 모델이다.

1) 다층 퍼셉트론

다층 퍼셉트론은 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망으로 그림 1에 나타난 것과 같은 계층구조를 갖는다. 이 때 입력층과 출력층 사이의 중간층을 은닉층이라 부른다. 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며 각 층 내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향(feed forward)의 네트워크이다.

다층 퍼셉트론은 단층 퍼셉트론과 유사한 구조를 가지고 있지만 중간층과 각 유니트의 입출력 특성을 비선형으로 함으로써 네트워크의 능력을 향상시켜 단층 퍼셉트론의 여러 가지 단점들을 극복했다. 다층 퍼셉트론은 층의 개수가 증가할수록 퍼셉트론이 형성하는 결정 구역의 특성은 더욱 고급화된다. 즉 단층일



[그림 1] 다층 퍼셉트론의 구조

경우 패턴 공간을 두 구역으로 나누어주고, 2층인 경우 오목한 개구역 또는 오목한 폐구역을 형성하며, 3층인 경우에는 이론상 어떠한 형태의 구역도 형성할 수 있다.

시그모이드 비선형 활성화함수를 적용할 경우 결정 영역이 통상 직선이 아닌 완만한 곡선으로 경계지워 지므로 행위의 분석이 약간 복잡하지만 미분이 가능하므로 백프로퍼게이션 학습 알고리즘을 수행할 수 있다.

2) 백프로퍼게이션 학습 알고리즘

백프로퍼게이션 학습 알고리즘은 최소자승 알고리즘의 비선형적인 확장이며 알고리즘의 기본원리는 다음과 같다. 입력층의 각 유니트에 입력패턴을 주면, 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다.

러멜하트 등은 1980년대 후반에 일반화된 델타 규칙(generalized delta rule)이라고 불리는 백프로퍼게이션 알고리즘을 제안하였다. 응용분야에서 수많은

성공 사례가 보고 되었지만 나름대로의 단점도 있었다. 첫 번째 단점은 수렴에 종종 실패하고 지역 최소값에 봉착한다. 둘째, 백프로퍼게이션은 비지역성(nonlocality), 동시성(synchrony), 감독(supervision)과 긴 훈련 시간 등으로 생물학적 신경망과는 상당한 차이점이 있다. 셋째, 백프로퍼게이션은 불연속 시뮬레이션에서 항상 수렴하는 것은 아니다. 즉, 초기의 상태를 어떻게 선택하느냐에 따라 진동하거나 최악의 경우 발산하기도 한다.

델타 규칙은 입출력 함수가 선형의 유니트로부터 이루어진 네트워크에 대하여 모든 입력패턴으로부터 얻어지는 출력과 목표출력과의 오차의 제곱의 총합을 최소로 하도록 연결강도를 조정하는 것이다. 델타 규칙을 유도하는 방법은 여러 가지가 제안되어 있으나 본 논문에서는 최급하강법(steepest descent method)을 이용한다. 오차의 제곱의 총합을 최소로 하기 위한 연결강도의 변화량 Δw_{kj} 은 아래의 식(1)과 식(2)와 같다.

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (1)$$

$$E = \frac{1}{2} \sum_{k=1}^m (t_k - o_k)^2 \quad (2)$$

여기서 η 는 학습률, w_{kj} 는 입력층과 출력층 사이의 연결강도, 그리고 t_k 와 o_k 는 각각 참 값과 출력값을 나타낸다.

각각의 절점에 대해서 입력값 y_j 로부터 계산되는 출력값은 아래의 식(3)과 식(4)와 같이 계산된다.

$$net_k = \sum_{j=1}^n w_{kj} y_j \quad (3)$$

$$O_k = f(net_k) \quad (4)$$

위의 식(1)에서 우변은 아래와 같은 체인룰에 의해 계산되어질 수 있다.

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial w_{kj}} \quad (5)$$

또한 식(5)의 우변의 첫째 항은 아래와 같이 정의된다.

$$\begin{aligned} -\frac{\partial E}{\partial net_k} &= \delta_{ok} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \\ &= (d_k - o_k) f'_k(net_k) \end{aligned} \quad (6)$$

위의 식(3)으로부터 식(5)의 우변 두 번째항은 아래 식(7)과 같다.

$$\frac{\partial net_k}{\partial w_{kj}} = y_j \quad (7)$$

지금까지의 결과인 식(5), (6), (7)을 식(1)에 대입하면 아래 식(8)과 같은 최종적인 결과를 얻는다.

$$\Delta w_{kj} = \eta (d_k - o_k) f'_k(net_k) y_j \quad (8)$$

위의 식(8)에서 볼 수 있듯이 전달 함수 f 는 미분 가능해야 하므로 일반적으로 시그모이드 함수를 이용한다.

$$o_k = f(net_k) = \frac{1}{1 + e^{-(net_k + \theta_k)/\theta_0}} = \frac{1}{1 + e^{-\lambda net_k}} \quad (9)$$

지금까지의 식은 은닉층이 없는 단층 퍼셉트론에 대한 백프로퍼게이션 학습 알고리즘이며 은닉층이 있는 일반적인 경우에 대한 일반화된 델타 학습법은 다음과 같다.

입력층과 은닉층 사이의 연결강도를 v_{ji} 라 두고 은닉층과 출력층 사이의 연결강도를 w_{ji} 라고 하면 은닉층과 출력층 사이의 연결강도는 앞의 식(8)과 동일하다.

은닉층과 입력층의 연결강도의 증분은 아래 식(10)과 같다.

$$\Delta v_{ji} = -\eta \frac{\partial E}{\partial v_{ji}} \quad (10)$$

식(10)의 우변을 체인룰에 의해 전개하면 아래와 같다.

$$\frac{\partial E}{\partial v_{ji}} = \frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial v_{ji}} \quad (11)$$

$$net_j = \sum_{i=1}^n v_{ji} x_i \quad (12)$$

$$\Delta v_{ji} = \eta \delta_{yj} x_i \quad (13)$$

$$\delta_{yj} = -\frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial net_j} \quad (14)$$

$$\begin{aligned} \frac{\partial E}{\partial y_j} &= \frac{\partial}{\partial y_j} \left(\frac{1}{2} \sum_{k=1}^m [d_k - f(net_k(y))]^2 \right) \\ &= -\sum_{k=1}^m (d_k - o_k) f'(net_k) \frac{\partial (net_k)}{\partial y_j} \\ &= -\sum_{k=1}^m \delta_{ok} w_{kj} \end{aligned} \quad (15)$$

식(15)를 식(14)에 대입하면 다음과 같다.

$$\delta_{yj} = f'_j(net_j) x_i \sum_{k=1}^m \delta_{ok} w_{kj} \quad (16)$$

여기서, $\delta_{ok} = (d_k - o_k) f'_k(net_k)$ 이다.

이상의 결과를 종합하면 은닉층과 입력층 사이의 연결강도에 대한 증분은 아래의 식(17)과 같이 정리된다.

$$\Delta v_{ji} = \eta y_j (1 - y_j) x_i \sum_{k=1}^m \delta_{ok} w_{kj} = \eta \delta_{yj} x_i \quad (17)$$

연결강도의 변화에 대한 수식은 식(18)과 같다.

$$\Delta w_{ji}(t+1) = \eta \delta_{yj} x_i + \alpha \Delta w_{ji}(t) \quad (18)$$

여기서 t 는 학습의 횟수, η 는 학습률, α 는 상수이며 우변의 두 번째 항은 오차진동을 적게하여 수렴속도를 빨리하기 위하여 첨가한 모멘텀항이다.

백프로퍼게이션 학습 알고리즘은 기울기를 따라가는 방법의 하나인데 이 알고리즘의 단점중의 하나는 지역 최소값에 빠질 염려가 있다는 것이다. 이를 개선하기 위하여 은닉층의 수를 증가시키거나 모멘텀 항 α 와 학습률 η 를 조절해 나가는 방식을 사용한다.

3. 신경망 프로그램의 개발

가. 신경망 프로그램의 구성

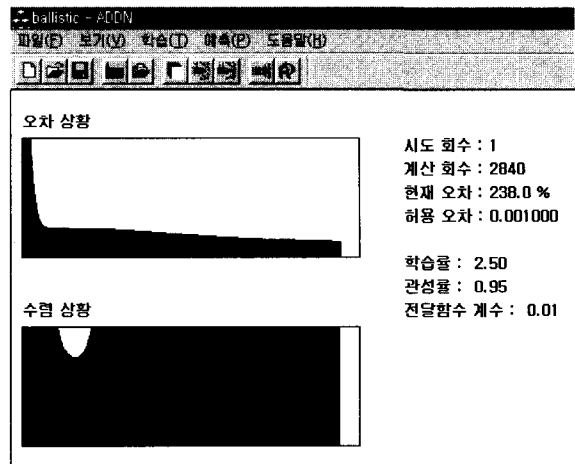
사용된 프로그래밍 언어는 PC 환경의 Windows 95/98/NT에서 사용가능한 Visual C++ 5.0을 이용하였으며 원활한 사용자 인터페이스를 고려하였고 객체

지향적인 프로그램을 구성하였다. 다층 퍼셉트론의 많은 학습 변수 중에서 학습률과 모멘텀 인자, 최대 반복횟수, 허용오차에 대한 값은 사용자가 학습을 시작하기 전에 적절한 값으로 선택할 수 있게 하였다.

학습을 위한 입력 자료가 저장된 파일을 선택하고 학습 변수를 설정하면 퍼셉트론은 자동적으로 입력 패턴을 분석하여 수렴시켜 나가게 된다. 이때 사용자의 입력 상황과 해석 시스템에 따라 수렴이 되지 않고 어느 이상 오차가 줄지 않은 경우가 발생하므로 이를 사용자가 감시하기 위하여 신경망의 오차분포와 오차 감소 속도를 화면상에 표시하였다. 이러한 감시창을 통해 사용자는 현재 신경망 모델의 수렴 여부와 수렴 예상 시간을 짐작할 수 있으며 이를 토대로 새로운 학습 변수를 설정할 수 있게 된다(그림 2 참조). 그림 2에서 위의 그래프는 신경망의 오차분포를 보여주고 있으며 아래 그래프는 오차 분포가 점점 감소하는지 여부를 보여주고 있다. 예를 들어 위의 그래프에 표시되는 오차 값이 비교적 큰 값이지만 아래 그래프에 표시되는 오차 감소 속도가 거의 0이면 이는 신경망이 수렴하고 있지 않기 때문이다. 이때에는 사용자가 적절히 프로그램을 멈추고 새로운 학습 변수를 주거나 모델링을 새로 해야 할 경우이다.

학습이 계속 진행되면서 신경망의 오차값이 지정된 허용오차보다 작아지면 계산을 멈추게 된다. 수렴된 신경망의 연결강도 값은 사용자가 저장할 수 있게 되어 있으며 필요하면 다시 읽어서 재 사용할 수 있다. 학습이 완료된 연결 강도 값을 이용하여 새로운 장갑 구조의 성능을 예측하려면 운동에너지탄과 화학에너지탄 각각에 대하여 사용자가 충돌속도와 탄과 표적의 이격거리를 입력하면 된다.

프로그램에서 고려되는 주요 입력 데이터는 탄종(소구경탄, 운동에너지탄, 화학에너지탄), 충돌속도, 탄



[그림 2] 신경망의 오차 경향과 오차 감소 속도 감시창

과 표적의 이격거리, 재료종류(금속재료, 취성재료, 복합재료 등), 재료배열순서, 재료의 두께 등이며 출력 데이터는 관통깊이 한 가지이다.


나. 단일 방탄 층에 대한 적용

개발된 프로그램을 이용하여 단일 방탄 층에 대한 학습을 수행하였다. 이 때 지정된 단일 방탄 재료에 대하여 여러 관통 속도에 따른 관통 깊이를 각각 입력 값과 출력 값으로 이용하여 학습을 수행하였다. 이 경우는 단일 입력값과 단일 출력값을 가지므로 실제로는 곡선 보간의 기능을 하게 된다. 입력층과 출력층의 값으로 실수를 사용하므로 여기에서는 입력층 절점 1개와 출력층 절점 1개를 가지며 은닉층의 절점의 수는 사용자의 판단에 따른다. 본 연구에서는 은닉층의 절점 수로서 5를 기본값으로 가지도록 하였다. 이 경우에 대한 학습 결과를 그림 3과 그림 4에 나타내었다. 입력 자료로는 Brooks and Erickson의 시험결과^[3]를 사용하였으며 이중 K-94 WC재료와 W-alloy 재료에 대한 두 가지 시험결과를 선택 검증


하여 보았다.

그림 3에서 볼 수 있는 바와 같이 K-94 WC의 학습결과에서는 만족할 만한 결과를 얻었다. 즉 입력 자료로 주어진 8개의 충격속도에 대한 관통 깊이가 지정된 오차 범위 안에서 잘 수렴하였다. 또한 입력 패턴으로 주어지지 않은 다른 값을 대입하여 예측 경향을 살펴본 결과 만족할 만한 결과를 얻었다. 이로 보아 신경망을 이용한 곡선 보간에서는 내삽기능이 상당히 뛰어난 것을 알 수 있다.

그림 4는 W-alloy의 자료를 이용하여 학습한 결과이다. 그림 3과 마찬가지로 주어진 학습 패턴에 대해서는 만족할 정도의 오차범위 안에 수렴하였지만 입력 패턴 이외의 값에 대해서는 이론적인 곡선 보간



[그림 3] K-94 WC의 관통깊이 예측 결과




[그림 4] W-alloy의 관통깊이 예측 결과


그래프에 비해서 상대적으로 오차가 큰 것을 알 수 있다. 물론 이론적인 곡선 보간 그래프가 정확한 경향이라고 할 수는 없으나 실제로 그림 4와 같이 진동하는 경향을 보이지는 않을 것으로 예상된다. 그러므로 이러한 오차를 줄이기 위해서 약간의 검증이 필요할 것으로 예상된다. 이러한 오차의 원인과 경향을 살펴 보기 위해서 은닉층의 절점 수를 변화시켜가며 학습시켜보았다. 즉 입력층과 출력층은 변화가 없고 은닉층의 절점 수를 각각 2개, 3개, 5개, 20개, 100개로 변화시켜 가며 학습하였다. 이의 결과를 그림 5에 나타내었다.

그림 5에서 볼 수 있는 바와 같이 은닉층의 절점 수가 커질수록 실제 관통깊이 분포와 잘 일치됨을 볼 수 있다. 이로 보아 은닉층의 수가 적을수록 진동이 발생하는 경향이 있고 은닉층의 수가 커질수록 직선 형태로 결과를 예측함을 알 수 있다. 그러므로 사용자가 은닉층의 절점 수를 결정할 때는 이를 잘 고려하여야 한다.

실제 적용시 내삽 기능뿐만 아니라 외삽의 기능도 수행해야 하므로 이에 대한 테스트 결과를 그림 6에 나타내었다. 재료는 K-94 WC이며 학습 패턴의 입력 값인 충돌 속도를 주어진 값보다 작게 혹은 크게 하



[그림 5] 은닉층의 절점수 변화에 따른 예측 경향



[그림 6] 학습된 신경망의 외삽에의 적용

여 테스트하여 본 결과 그림 6과 같이 비교적 타당한 결과를 얻었다. 하지만 신경망 모델이 모든 범위의 외삽에서 뛰어난 성능을 발휘하기는 어려우므로 대체적으로 주어진 학습 패턴 범위의 $\pm 10\%$ 범위 내에서만 사용하는 것이 타당할 것으로 보인다.

이상과 같이 다층 퍼셉트론을 이용한 단일 재료 방탄층에 대한 관통 깊이 예측은 만족할 만한 결과를 얻었으며 학습 변수와 각 층의 절점수에 따라 예측 경향이 다르게 나타남을 볼 수 있었다.

4. 다층장갑에 대한 신경망 프로그램의 적용

가. 고차 다항식의 학습 능력 검증

실제 방탄 실험결과에 대한 데이터가 많지 않으므로 가상의 데이터를 설정하여 개발된 신경망의 학습능력을 살펴보았다. 균일한 두께를 가지는 4개의 층으로된 방탄 구조의 특정한 타에 대한 관통깊이를 4개 층을 구성하는 재료의 물성치(x_1, x_2, x_3, x_4)의 다항식으로 표현할 수 있다고 가정 후 1차, 2차, 3차 4차 함수에 대한 신경회로망의 곡선보간 능력을 검증하였다.

계산에 사용된 각 차수의 다항식은 아래와 같이 구성되어 있다.

$$P_1 = ax_1 + bx_2 + cx_3 + dx_4 \quad (19-a)$$


$$P_2 = ax_1 + \dots + dx_4 + ex_1^2 + \dots + hx_4^2 + ix_1x_2 + \dots + nx_2x_4 + ox_3x_4 \quad (19-b)$$

$$P_3 = ax_1 + \dots + dx_4 + ex_1^2 + \dots + ox_2x_3x_4 + \dots + zx_3^2x_4 \quad (19-c)$$

$$P_4 = ax_1 + \dots + fx_2^2 + \dots + nx_1^4 + yx_1x_3^2x_4 + \dots + zx_3^2x_4^2 + \dots \quad (19-d)$$

다항식의 계수들인 a, b, c, d, \dots 는 임의로 정하고 변수인 x_1, x_2, x_3, x_4 는 난수를 이용해서 구한 후 다항식의 계산을 통해서 목적함수의 값인 P_1, P_2, P_3, P_4 를 계산하여 많은 학습데이터를 확보하였다.


학습데이터로 학습을 마친 후 새로운 입력에 대한 신경회로망의 예측결과와 다항식에 의해 계산된 참값을 비교하였다. 이런 방법으로 계산된 1차 다항식에 대한 학습 경향은 그림 7과 같다.




[그림 7] 은닉층의 절점 수에 따른 1차 다항식의 학습 경향

위의 그림에서 볼 수 있는 바와 같이 주어진 학습 데이터에 대해서는 잘 수렴하였지만 검증을 위하여 다른 입력값을 대입했을 때는 비교적 큰 오차가 발생함을 알 수 있다. 이러한 오차는 은닉층의 절점 수를 증가시켜도 크게 개선되지 않았으며 은닉층의 절점 수가 많아지면 오히려 오차가 커졌다. 그림 8은 허용 오차의 값을 감소시켜 2차 다항식을 학습하여 본 결과이다. 결과에서 볼 수 있는 바와 같이 허용오차가 작을수록 예측은 잘하지만 효과가 그다지 크지 않다.

지금까지의 결과는 학습 데이터의 수를 10개로 하여 학습시킨 결과이다. 학습 데이터의 수에 따른 학습 경향을 살펴보기 위하여 좀 더 많은 학습 데이터로



[그림 8] 임계오차의 값에 따른 2차 다항식의 학습 경향




[그림 9] 학습 데이터 수에 따른 1차 다항식의 수렴 경향


학습시켜 보았다. 그림 9는 1차 함수에 대해 학습 데이터를 10개, 50개, 100개로 설정하여 학습시킨 결과이다.

그림 9에서 데이터의 수가 10개일 때는 비교적 오차가 컸으나 점점 증가시켜 데이터의 수가 100개일 때는 참값과 거의 일치하는 경향을 보였다. 즉 학습에 사용될 패턴 수가 많을수록 수렴속도도 빠르고 예측도 잘 되었다.


다항식의 차수가 증가할 때의 경향을 살펴보기 위하여 같은 방법으로 2차 함수와, 3차 함수, 4차 함수에 대해서도 검증하여 보았다. 그 결과를 그림 10, 그림 11, 그림 12에 표시하였다. 그림에서 다항식의 차수가 증가할수록 학습 오차가 상대적으로 크게 나타



[그림 10] 학습 데이터 수에 따른 2차 다항식의 수렴 경향



[그림 11] 학습 데이터 수에 따른 3차 다항식의 수렴 경향



[그림 12] 학습 데이터 수에 따른 4차 다항식의 수렴 경향

나고 학습 데이터를 증가시킬수록 오차가 많이 감소하고 있음을 볼 수 있다.

그림 9, 10, 11, 12를 통하여 다항식의 차수가 증가할수록 신경망의 예측능력이 점점 떨어지는 것을 볼 수 있는데 이것은 차수가 증가할수록 함수가 가질 수 있는 값의 범위가 점점 증가하여 분해능이 상대적으로 감소하기 때문이라고 판단된다.

이상의 분석을 통하여 4개의 변수로 구성된 4차의 다항식까지는 구성된 신경망 모델을 이용하여 허용 오차 범위이내에서 안정되게 학습시킬 수 있음을 알았다. 그러나 차수가 높아질수록 학습에 필요한 데이터 수가 기하급수적으로 증가하므로 관통특성이 복잡한 비선형 거동을 보이는 경우 소수의 실제 방탄 데이터로 새로운 장갑구조의 성능을 정확하게 평가하기 어려울 것으로 판단된다.

나. 방탄 실험자료의 학습 능력 검증

1) 금속계 유격장갑구조 성능 예측


개발된 신경망 구조가 실제 시험에서 얻어진 방탄 실험자료를 얼마나 잘 예측하는 지를 살펴보기 위해서 이미 발표되어 있는 시험결과를 토대로 검증하여 보았다.

K. Weimann 등^[4]은 동일한 무게를 가진 폭발 성형 탄자(Explosive Formed Projectile)의 길이 대 직경 비(L/D)가 관통능력에 어떠한 영향을 미치는 지에 대해 살펴보았다. 이에 대한 자료를 토대로 입력 데이터를 구성하고 참고문헌[4]의 결과와 본 연구를 통해 예측된 결과치를 비교하여 보았다. 참고문헌[4]에서 주어진 자료는 L/D, 충돌속도, 전면 방탄층의 두께, 전면 방탄층의 재료 종류, 후면재료의 관통깊이 등이다. 전면 방탄재료가 주어진 두께로 설치되어 있으며 뒷부분에는 후면재료로 철판(M190)이 적정 두께만큼 설치되어 있고 그 사이에 공기층이 10 mm 두께로 존재한다. 이 때 전면 방탄재료의 종류와 두께를 변화시켜가며 실험한 결과를 정리하면 아래 표 1과 같다.

표 1의 입력 데이터를 학습패턴으로 이용하여 학습

[표 1] EFP 탄자의 관통시험 결과^[4]

번호	길이/직경 (L/D)	충돌속도 (m/s)	전면 방탄층의 두께(mm)	전면 방탄 재료	관통 깊이 (mm)
1	4	2113	8	M240	21.3
2	4	2088	0	M190	23.8
3	6	2101	8	M240	26.2
4	6	2100	5	M190	26.6
5	6	2103	5	M300	26.9
6	6	2086	5	M240	27.4
7	6	2115	5	XC18	27.6
8	6	2107	5	XC48	28.5
9	6	2106	0	M190	29.3
10	8	2086	12	M240	30.5
11	8	2139	4	M240	31.8
12	8	2100	0	M190	34.7



[그림 13] EFP 탄자의 관통깊이 예측 결과

을 수행하였다. 입력 절점은 [L/D, 충돌속도, 전면판 두께, 전면판 물성, 공기층 두께, 공기층 물성, 후면판 두께, 후면판 물성]의 순서로 구성하였으며 출력 절점은 관통깊이를 사용하였다. 1번에 대해 예측할 때에는 1번 자료를 제외한 나머지 데이터로 학습시키고, 2번에 대해 예측할 때에는 2번 자료를 제외한 나머지 데이터로 학습시켰다. 학습결과를 정리하면 그림 13과 같다. 그림 13에서 볼 수 있는 바와 같이 입력 절점이 8개이고 은닉 절점을 20개 사용하는 경우 11개의 패턴으로 학습시키면 약 4%정도의 오차 범위 내에서 잘 수렴함을 알 수 있다. 개발된 신경망 프로그램을 사용하면 금속계 유격장갑구조의 방탄성능을 비교적 정확히 예측할 수 있을 것으로 판단된다.

2) 세라믹재료의 방탄 성능 예측

Z. Rosenberg 등^[5]은 운동에너지탄자에 대한 SiC와 TiB₂재료의 DOP(Depth of Penetration)시험을 수행한 후 2차원 하이드로코드로 해석하여 시험시 관찰되는 세라믹 두께 증가에 따른 방호력 감소현상을 수치해석적으로 재현하려는 연구를 실시하였다. 시험결과 얻어진 시험 데이터는 아래 표 2와 같다. 시험구조는 세라믹 재료를 전면에 설치하고 그 뒤에 후면 재

[표 2] 세라믹 방탄층의 구성[5]

번호	세라믹 재료의 두께(mm)	세라믹 재료 종류	관통깊이 (mm)
1	60.4	SiC	12.5
2	50.7	SiC	21.4
3	40.4	SiC	28.5
4	30.6	SiC	32.6
5	20.6	SiC	40.8
6	59.4	TiB ₂	6.2
7	50.3	TiB ₂	8.0
8	39.6	TiB ₂	19.6
9	19.8	TiB ₂	34.5

료로 적정 두께의 철판을 설치하였으나 공기층은 존재하지 않는다.

표 1의 처리와 같은 방법으로 학습을 수행하였다. 입력 절점은 [세라믹 재료의 두께, 세라믹 재료의 밀도, 세라믹 재료의 압축강도, 세라믹 재료의 탄성계수, 후면판 두께, 후면판 물성]의 순서로 구성하였으며 출력 절점은 관통깊이를 사용하였다. 은닉 절점은 10개 사용하였으며 8개의 패턴으로 학습을 수행하였다.

학습에 사용될 세라믹 재료 물성치 조합의 변화에 따른 예측결과의 차이를 살펴보기 위하여 밀도, 압축강도, 탄성계수를 조합하여 입력 절점의 구성을 변화시켜보았다. 학습에 사용된 조합은 아래의 7가지이다.


- (1) 밀도(D)만 사용
- (2) 압축강도(CS)만 사용
- (3) 탄성계수(E)만 사용
- (4) 밀도+압축강도 사용
- (5) 밀도+탄성계수 사용
- (6) 압축강도+탄성계수 사용

(7) 밀도+압축강도+탄성계수 사용


위의 세라믹 재료의 방탄 실험결과를 바탕으로 분석된 결과가 아래의 그림 14와 그림 15이다.

그림 14와 그림 15에서 볼 수 있는 바와 같이 관통 깊이에 있어서 입력값으로 사용된 세라믹 재료의 물성치 조합에 따라 약간의 차이가 있음을 볼 수 있다.

차이를 자세히 살펴보기 위해서 모든 학습패턴의 영향을 고려한 참값에 대한 평균 상대오차와 평균 절



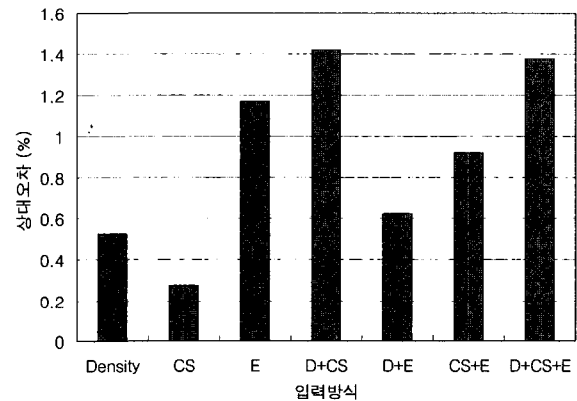
[그림 14] 밀도, 압축강도, 탄성계수에 따른 예측 결과 비교




[그림 15] 밀도, 압축강도, 탄성계수의 조합에 따른 예측 결과 비교

대오차를 그림 16과 그림 17에 표시하였다.

그림 16과 그림 17을 살펴보면 상대오차는 밀도(D)와 압축인장강도(CS)를 사용했을 때 비교적 작은 값을 가지고 절대오차는 밀도(D)와 D+E, D+CS+E를 사용했을 때가 비교적 작은 값을 가지는 것을 알 수 있다. 상대오차와 절대오차를 동시에 고려해 보면 밀도만을 사용했을 때 가장 오차가 작으므로 세라믹재료의 물성치로 밀도만을 고려하는 것이 합리적이라고 판단된다. 이것은 고려된 재료 물성치 중 관통역학관



[그림 16] 입력 물성치 변경에 따른 예측 결과의 상대오차



[그림 17] 입력 물성치 변경에 따른 예측 결과의 절대오차

점에서 밀도가 가장 연관성이 높다는 사실과도 일치하는 면이 있다. 또한 입력에 사용된 변수와 출력으로 나오는 값 사이에는 비선형적인 관계식이 있으나 입력의 선택을 효율적으로 하면 이러한 관계를 최대한 선형화시켜 신경회로망의 예측 결과가 개선되는 것으로도 생각해 볼 수 있다.

그림 16을 살펴보면 밀도만을 사용하는 경우 SiC재료와 TiB2재료에 대해서 평균 0.5%정도로 예측 능력이 매우 우수한 것으로 나타났다.

이상에서 살펴본 바와 같이 개발된 신경망 프로그램은 금속 및 세라믹 재료로 구성된 다양한 방탄구조의 방호 성능을 비교적 정확하게 예측할 수 있는 것으로 판명되었으며 기존의 축적된 데이터를 효율적으로 분석하여 새로운 형태의 장갑설계에 적용할 수 있는 가능성을 제시하였다. 그러나 효과적인 입력 절점의 구성방법과 재료 물성치의 최적조합 방법에 대해서는 좀더 많은 연구가 필요하다.

5. 맺음말

본 연구에서는 많은 비용과 인력이 요구되는 방탄 실험의 최소화를 위하여, 기존의 방탄 실험 결과를 효과적으로 분석하여 새로운 방탄 구조물의 설계에 활용할 수 있는 시스템을 개발하였다. 방탄 구조의 여러 가지 설계변수들인 방탄재료종류와 재료두께, 적층순서 등을 입력으로 하고 관통깊이를 출력으로 하는 시스템을 설정하고 이들간의 관계를 규명하기 위하여 일반적으로 사용되는 신경회로망 이론을 적용하였다.

구성된 신경회로망을 이용하여 기존의 방탄 실험 결과에 대한 검증을 수행하여 본 시스템의 안정성과 적용성을 살펴보았으며 신경회로망을 구성하는 여러

가지 인자들을 변화시켜가며 신경회로망의 특성을 살펴보았다. 개발된 신경회로망 예측 시스템을 사용하여 특정 방탄 구조물을 분석하여 본 결과 전체적으로 10%이내의 오차가 발생함을 알 수 있었다. 이는 방탄 실험 자체가 가지는 결과의 편차에 미루어볼 때 만족할 만한 결과라 할 수 있다.

이상의 연구결과를 토대로 개발된 신경망 프로그램을 효과적으로 활용하면 금속 및 세라믹 재료로 구성된 복잡한 방탄구조물의 설계시 개발 비용 및 기간 단축에 크게 기여할 것으로 판단된다.

참 고 문 헌

1. 김대수, "신경망 이론과 응용", 하이테크정보, 1992
2. Zurada, J. M., "Introduction to Artificial Neural System", WEST Publishing Co. 1992
3. Anderson, C. E., Morris, B. L. and Littlefield, D. L., "A Penetration Mechanics Database", Southwest Research Institute, SwRI Report 3593/001, 1992, A-18, Brooks and Erickson(1971)
4. Weimann, K., Blache, A., Cauret, M., Laurensou, R., Gil, F. and Rondot, F., "Terminal Ballistics of EFPs with High L/D - Ratio", 17th International Symposium on Ballistics, Vol. 3, 1998, PP. 215~224
5. Rosenberg, Z., Dekel, E., Hohler, V., Stilp, A. J. and Weber, K., "More on the Ballistic Performance of Ceramic Tiles against Long-Rod Penetrators", 17th International Symposium on Ballistics, Vol. 3, 1998, PP. 451~458