

신경망을 이용한 포병모의훈련체계 향상방안

(Enhancement of Artillery Simulation Training System by Neural Network)

류 혜 준(Hai Joon Ryu)* 고 호 현(Hyo Heon Ko)** 김 지 현(Ji Hyun Kim)***
김 성 식(Sung Shick Kim)****

초 록

본 연구에서는 다양하고 복잡한 변수간의 비선형적인 관계를 분석할 수 있는 신경망의 특성을 이용하여 곡사화기를 사용하는 포병의 모의훈련체계를 향상시킬 수 있는 방안을 제시하였다. 신경망 모델은 Conjugate Gradient 학습알고리즘을 사용하였고, 모델의 신뢰성은 모의실험을 통해 수학적 회귀분석모델과 신경망 모델의 예측오차를 비교하여 입증하였다. 신경망모델을 곡사화기 모의훈련체계 개선에 활용한다면, 보다 실전적인 모의훈련을 가능하게 하여 전투력 향상 및 예산절감에도 크게 기여할 것이다.

Abstract

A methodology for the improvement of simulation based training system for the artillery is proposed in this paper. The complex nonlinear relationship inherent among parameters in artillery firing is difficult to model and analyze. By introducing neural network based simulation, accurate representation of artillery firing is made possible. The artillery training system can greatly benefit from the improved prediction. Neural networks learning is conducted using the conjugate gradient algorithm. The evaluation of the proposed methodology is performed through simulation. Prediction errors of both regression analysis model and neural networks model are analyzed. Implementation of neural networks to training system enables more realistic training, improved combat power and reduced budget.

KeyWords: 포병(Artillery), 신경망(NeuralNetworks), 모의훈련체계(Simulation Training System)

* 고려대학교 정보경영공학전문대학원 정보경영공학과 석사과정
** 고려대학교 산업시스템정보공학과 박사과정
*** 고려대학교 정보통신연구소 연구교수
**** 고려대학교 산업시스템정보공학과 교수

직사화기로 무장한 전투요원은 앞에서 설명한 과학화 전투훈련 체계를 통해 실전적인 모의교전을 할 수 있게 된다. 하지만, 포병의 경우 과학화 전투훈련에서 뿐만 아니라, 풍익훈련과 같은 모의훈련에서도 포병부대의 병사들 보다는 참모장교나 지휘관을 대상으로 한 훈련을 실시하거나, 전 부대원이 참가하는 모의훈련이라고 해도 형식과 포탄사격절차위주의 모의훈련에 국한하여 실시되고 있다. 포병 모의훈련이 절차적인 수준에 국한된 것은 직사화기처럼 곡사화기의 탄도를 좀 더 실질적으로 묘사해 주는 모델이 없기 때문이다[5].

곡사화기를 사용하는 부대의 모의훈련 효과 및 과학화 전투훈련의 전사적 효과를 얻기 위해서는, 포병의 훈련 시스템도 MILES장비처럼 각각의 곡사화기 별로 탄도 및 탄착을 묘사하고 전투 부대와 유기적 연동이 가능한 시스템과 모델 개발이 필요하다.

따라서 본 연구에서는 박격포, 견인포, 자주포 같은 곡사화기로 무장한 부대나 팀의 모의훈련 효율성 증대를 위해, 곡사화기의 탄착점을 예측할 수 있는 방법을 제시하고 탄착점의 예측모델을 통해 실제 훈련체계에 적용하여 활용할 수 있는 방안을 제시하고자 한다.

2. 곡사탄도의 모델링

2.1 곡사탄도의 특징

곡사화기는 직사화기와는 달리 주로 원거리 표적에 대한 사격을 실시한다. 따라서 곡사화기의 경우 사격 후 탄두의 비파시간이 길어 탄두가 비행 중에 <표 1>같은 요소들에 의해 영향을 받아 탄두의 거리와 방향에 변화가 생긴다.

특히 <표 1>의 요소 중 기상변화는 정확한 탄착에 많은 영향을 준다. 따라서 곡사화기 사격의 특징을 잘 반영하고 실전 같은 상황묘사를

위해 곡사 탄도 및 탄착을 정확히 묘사할 수 있는 모델 개발이 선행되어야 한다.

<표 1> 포병 사표상의 표준 조건

<ul style="list-style-type: none"> • 기온 59°F (15°C)(지표면) • 공기 밀도 1,225g/m³ (지표면) • 무풍(無風)
<ul style="list-style-type: none"> • 화포와 표적, 기상측정지점이 동일 표고 • 정확한 거리 • 지구 회전 없음
<ul style="list-style-type: none"> • 표준 규격의 화포, 탄두, 신관 • 장약 온도 70°F 21.1°C • 포이수평, 정확한 제원 장비 • 사표 상에서의 표준 포구초속

* 육군본부, 야교 32-3 사격지휘, 2004

포병훈련에서 실제 포탄사격훈련이 비사격훈련과 다른 가장 큰 특징은 실제 사격부터 표적지역의 탄착까지의 모든 현상을 그대로 훈련 상황에 반영할 수 있다는 것이다. 곡사화기에서 탄착지점까지 이동하는 동안 탄두의 운동에 영향을 주는 여러 가지 물리적 작용이 모두 망라되어서 포탄 1발의 탄도가 결정된다.

탄도 모델을 개발하기 위해서는 <표 1>에서 보여주고 있는 탄도의 영향을 주는 제반 요소와 곡사화기에 입력하는 제원과의 관계를 규명할 수 있어야 한다. 그러나 현재까지 개발한 사격제원 계산체계로는 표준조건 하에서의 사격제원을 사격직전 <표 2>의 영향요소를 측정하여 일부 보정하여 제원을 계산한다.

탄도를 보정하는 것은 탄도의 비고정성 및 불확실성으로 인한 것이다. 탄도의 비고정성 및 불확실성이란 포탄사격 시 <표 2>에서 제시한 영향요소를 실험실처럼 정확하게 모두 계측하기 어렵기 때문이다. 탄도에 영향을 주는 요인들 중에는 사격 중에 실시간으로 계속해서 변화하는 요소들이 있는데 정확한 통제와 측정이 불가능하고, 탄도에 영향을 주는 요소와 사격 결과와의

상관관계를 알아내기도 어렵다. 따라서 야전에서
 는 포대별로 기준 포에 의한 수정사격 후 명중
 제원을 획득하여 모든 곡사화기에 동일하게 적
 용하여 사격을 실시한다[6].

<표 2> 탄도 영향 요소

영향 요소	
측정 가능 요소	도상제원(도상사거리, 도상편각, 표고차), 기상제원 (공기온도, 기압, 공기밀도, 풍향, 풍속), 탄약제원 (포탄무게, 장약온도), 포구초속오차
측정 불가 요소	포신 강내 표면상태, 탄약의 제조시 발생오차 장약연소속도 포신마모 약실공간의 축소 / 확대 포신 온도 부적절한 장전

* 육군본부, 야교 32-3 사격지휘, 2004

2.2 신경망을 이용한 탄도 예측

곡사화기 운용 시 수정사격을 실시하는 것은
 작전운용 측면에서 볼 때 비효율적이다. 수정사
 격은 적으로 하여금 아군 포격을 알게 하는 것
 이다. 따라서 포탄사격 시 효과를 상승시키기 위
 해서는 최소한의 수정사격으로 효력사를 할 수
 있어야 한다. 뿐만 아니라 포대단위(6문)로 제원
 을 산출하므로 각 곡사화기별 오차를 정확하게
 계측하고 조정하는 것도 필요하다. 이상의 문제
 에 대해 사격명중률을 향상시키고 포병 사격의
 효과를 증대시키기 위한 연구가 그동안 많이 진
 행되어 왔다.

수정사격을 최소화하기 위한 연구 중 대표적
 인 연구로 통계적 방법을 이용한 곡사화기 사격
 제원의 새로운 수정방법, 곡사화기의 탄착효과를
 극대화 하기위한 곡사화기의 포구초속오차의 허
 용한계 결정 방안이 있었다[7,8]. 이들 연구는 탄
 도를 직접적으로 모델링한 것이 아니라, 탄도에
 영향을 주는 요소 중 일부를 고려하거나, 이미
 사격된 결과를 통계적 분석을 통해 수정사격을

최소화하고 탄착 시 효과를 최대화하는데 그쳤
 다.

Gosh는 the point mass 모델, the modified
 point mass 모델, 자유도 6 모델 등의 수학적
 탄도 시뮬레이션을 통해 생성한 가상의 사격결
 과를 신경망으로 학습시켜 포병 탄도고의 예측
 모델을 개발하고 그 효과를 입증해 보였다[9].

Gosh의 연구는 탄도고의 패턴을 예측할 때
 탄도에 영향을 주는 비선형적 요인(기상, 진지수
 정량 등)들에 대해 신경망을 구성하여 포탄이
 날아가는 거리를 효과적으로 예측할 수 있었다.
 그러나 Gosh가 사용한 신경망은 포탄의 비거리
 (range) 예측에 한정된 것으로 본 연구의 목적
 인 탄착점에 대한 예측에 대해서는 좌우 편의오
 차를 예측을 하지 못한다는 점에서 한계가 있다.

따라서 본 연구에서는 Gosh의 연구를 개선하
 여 포탄의 비거리 뿐만 아니라 좌우 편의 오차
 까지 예측하여 실제 포탄사격 시 탄착지점을 예
 측할 수 있는 모델을 구성하고, 이를 포병 모의
 훈련체계에 적용해 보고자 한다.

3. 신경망 구성

3.1 신경망 모델 선정

신경망은 우리 인체의 뉴런을 컴퓨터의 네트
 워크에 응용한 것으로 분야에 따라 대단히 광범
 위하게 사용되고 있다. 신경망은 크게 지도학습
 모델과 자율학습모델로 구분되는데, 그중 지도학
 습모델이 보다 널리 사용되고 있다.

지도학습모델은 입력패턴과 그에 대한 목표
 출력으로 이루어지며, 목표출력은 정확한 해답
 또는 입력패턴에 대해 정확한 답을 줄 수 있도
 록 내부적인 변수조정을 통해 이루어진다. 신경
 망 모델은 분석대상 시스템의 특징을 인지하거
 나 분석대상 시스템의 모델링을 위한 알고리즘
 이나 프로그램 개발이 불필요하다는 이점이 있

으며, 앞서 말한 탄도 예측모델 개발 시 탄도에 영향을 주는 요소별로 별도의 관계식 설정이 또한 불필요하다.

하지만 신경망 모델을 사용할 경우 모델의 효과를 향상시키기 위해 비교적 많은 학습용 데이터를 필요로 하며, 네트워크의 훈련시간에 대한 예측 또한 어렵다는 단점이 있다[10].

따라서 신경망을 이용한 탄도모델링을 위해서는 발생 가능한 상황별 사격제원을 획득하는 과정이 필요하다.

3.2 CG알고리즘

신경망 학습 알고리즘은 CG(Conjugate gradient)방법을 사용한다. Gosh의 신경망 모델이나 기존에 사용되던 SBP(Standard back-propagation)는 CG에 비해 학습속도도 느리고, 학습된 네트워크도 지역해(Local Optimum)에 빠지는 경우가 많으며, 사용자가 몇 개의 핵심 모수(파라미터)를 지정해 주어야 하기 때문에 모델 최적화에 어려움이 많다. 반면 CG의 경우는 별다른 모수의 세팅이 필요 없고 SBP에 비하여 학습효율이 높고, 메모리의 사용량이 네트워크의 크기에 선형적으로 증가하기 때문에 큰 스케일의 네트워크에 적당한 이점이 있다[11].

또한 CG알고리즘은 운용방법에서 학습단계는 SBP와 유사하나 학습 시 신경망의 연결강도를 조정하는 부분에서 에러를 최소화하는 CG를 찾고, 찾은 방향으로 어느 정도 양을 이동할 지를 결정하는 부분이 있다는 것이 다르다.

CG알고리즘을 사용하는데 있어 방향을 결정하는 것은 Fletcher Reeves 제안식을 사용하였다.[12]

$$\beta_j = \frac{g_{j+1}^T g_{j+1}}{g_j^T g_j} \quad (1)$$

$$d_{j+1} = -g_{j+1} + \beta_j d_j \quad (2)$$

식(1)에서는 β_j 는 j번째 반복의 계수 값을 나타내며, g_j 는 j시점의 노드들의 기울기(gradient) 벡터를 의미한다. 식(2)에서 d_j 는 j시점에서의 공액방향을 의미한다.

목표로서 최소화해야 하는 에러는 신경망의 예측이 목표(target)로 하는 실제 사격결과의 계측값과 신경망이 예측한 결과 값의 차이로서 식(3)과 같이 정의하였다.

$$E(\alpha) = \sum_{j=1}^m \left(\sum_{i=1}^n (t_{ij} - f_{ij}(\alpha))^2 \right) \quad (3)$$

식(3)에서 $E(\alpha)$ 는 α 값의 변화에 따른 전체 학습 데이터에 대한 신경망의 에러 값을 나타낸다. m은 학습 데이터 셋의 개수를 의미하며, n은 신경망의 출력노드 숫자를 의미한다. t_{ij} 는 j번째 학습 데이터 셋의 I번째 출력노드에서의 목표 값을 나타낸다. $f_{ij}(\alpha)$ 는 신경망의 연결강도를 식(2)의 결과 방향으로 α 만큼 이동시켰을 때 j번째 학습 데이터 셋의 i번째 출력노드에서의 예측된 출력 값을 의미한다. 식(3)과 같이 정의한 이유는 CG 방법을 사용하여 공액방향을 연결강도를 이동시킬 양(α)을 결정하기 위해서는 해당함수를 이차함수 형태로 근사시켜야 하기 때문이다.

결국 식(2)에서 구한 방향으로 각 연결강도의 값을 바꿔주게 되는데, 이때 해당 방향으로 어느 정도의 양을 변화시킬 것인가 하는 변화량을 계산해야 한다. 이때 CG방법에서는 변화량을 구하기 위한 서브 알고리즘으로 선 탐색(Line Search) 알고리즘을 필요로 한다.

3.3 선 탐색 알고리즘과 활성화 함수

Charalambous는 CG에 사용되는 범용적인 선 탐색 알고리즘들과 다르게, CG에 사용하기 위해서 특정화된 선 탐색 알고리즘을 제시한 바 있다. 선 탐색 알고리즘은 시작 포인트의 기울기가


감소 방향임을 가정하는 등 범용적으로 사용하기는 어렵지만, CG에서 서브 알고리즘으로 사용시 다른 선 탐색 알고리즘들 보다, 속도 및 해의 질 면에서 나은 성능을 보일 수 있다. 따라서 본 연구에서는 Charalambous가 제안한 선 탐색 알고리즘을 사용하였다[13].

신경망의 각 노드에는 노드 입력 값에 따른 노드 출력 값의 관계를 정의하는 활성화 함수(Activation function)가 정의되어야 한다. 이 활성화 함수로는 식(4)와 같은 Hyper tangent 함수를 사용하였다[14].

$$g(a) \equiv \tanh(a) \equiv \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (4)$$

a는 해당 노드의 입력 값의 합을 의미하며, g(a)는 해당 노드의 출력 값을 의미한다.

식(4)의 활성화 함수는 <그림 2>와 같은 입력력 관계를 가지는데 g(a)의 절대 값이 0.7보다 클 경우, a값의 변화에 따른 g(a) 값의 변화량이 그렇지 않은 경우에 비해 상대적으로 작은 것을 알 수 있다. 이는 입력 값이 많이 변화하더라도 출력 값의 구분이 모호하다는 의미로 해석될 수 있다. 때문에 본 연구에서는 학습 효율을 위해, 입력변수(사격제원, 도상제원, 기상제원)와 출력변수(사격결과)를 식(5)를 사용하여 -1~1로 정규화 하여 실험하였다.



<그림 2> tanh 활성화 함수 그래프

$$N(x) = 2 \times range \times \frac{x - \min}{\max - \min} - range \quad (5)$$

range는 현재 정규화 시킬 데이터의 정규화 범위(0~1), min은 데이터가 가질 수 있는 최소값, Max는 최대값을 의미한다.

4. 신경망 사용방안

4.1 모델 구성절차


앞에서 설명한 신경망이 구성이 되면, 이를 탄도의 영향을 주는 요소와 사격결과에 대한 변수들로 구성을 한 뒤, 이를 다음의 절차에 따라 사용하여 탄도예측 시스템을 구성한다.

먼저 변수선택(Variable Selection)을 통해 탄도에 영향을 주는 후보요인들(사격제원 산출을 위한 자원, 기상과 같은 환경요인 등)을 모두 취합하여 영향정도에 대한 검증과 주요요인을 선택한다.

변수선택을 완료하면 구성된 신경망에 입력 및 출력 값에 적합하게 요인들에 대한 값을 정규화하거나, 값을 가공처리 하는 전처리(Preprocessing)를 실시한다. 가령 도상제원의 경우 m단위로 사용되는 것을 각 평균과 편차를 고려하여 0에서 1사이의 값으로 변환하며, 사격결과에 대한 값의 경우 표적 반경 50m 이내의 값을 거리와 좌우 편의 상으로 표현하는 것을 각각 부호를 설정하여 0에서 1사이의 값으로 정규화해야 한다.

전처리를 마치면 정확한 신경망 모델 수립을 위해서는 데이터를 랜덤화(Randomization)하여 학습시킨 데이터에 과잉적합(Overfit)하지 않고 현상에 대한 일반적인 모델 수립이 되도록 데이터 분할(Data partition)을 실시한다.

모델 수립을 위해 데이터를 기반으로 신경망을 학습하는 단계로 학습의 정확성을 위하여 학습(Training)과 평가(Validation)를 동시에 수행하여 학습의 중단여부를 결정한다. 학습의 중단



<그림 3> 신경망의 학습과 중단점

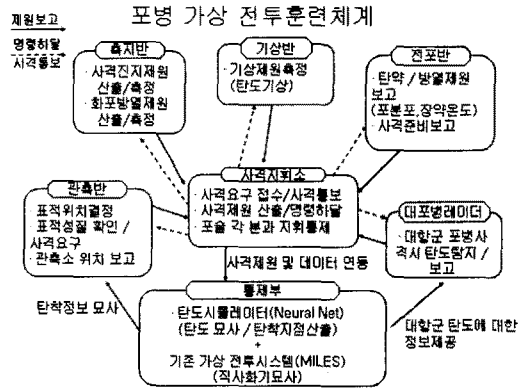
여부는 <그림 3>처럼 학습곡선과 평가곡선을 주시하여 평가결과를 바탕으로 평가 곡선의 예측 오차가 상승하게 되면 학습을 중단한다.

학습이 완료되면 구성된 신경망의 최종 검증을 실시한다. 본 연구에서는 신경망이 예측하는 탄착지점에 대해서 실제 사격한 제원을 비교하고 허용오차를 고려하여 수립된 모델과의 유사성 검증을 실시한다. 모델 수립의 유효성 판단은 ANOVA(Analysis of variance) 테스트를 사용한다. 만일 구성된 신경망 모델이 기본적인 한계를 벗어나지 않았다면 데이터 간 유사성을 판단하여 학습에서 발생한 오차와 테스트에서 발생한 오차의 차이유무를 판정하여, 오차의 차이가 존재하지 않다면 일반적인 모델이 수립된 것이므로 최종 모델수립을 완료하게 된다.

4.2 모델 적용방안

앞서 수립한 신경망 모델은 <그림 4>과 같이 육군 과학화 훈련단에서 운용중인 곡사화기 모의훈련체계에 적용한다.

신경망 모듈을 적용한 훈련체계는 다음과 같이 운용된다. 사격은 기존 곡사화기 묘사 훈련체계의 사격절차와 동일하게 진행되며, 통제부에 장착된 신경망 모듈이 각 곡사화기별 사격에 대해 실제 사격과 동일하게 탄도를 묘사해준다.



<그림 4> 신경망 모듈이 적용된 모의훈련체계

운용 절차를 간단히 알아보면, 포탄 사격을 위해 곡사화기에 장입하는 사격제원은 도상제원과 기상제원을 바탕으로 계산된다. 도상제원은 곡사화기와 표적까지의 거리, 방향, 표고차 등을 말하는 것으로 측지반과 관측반에 의해 측정된 표적위치와 사격진지위치를 통해 사격지휘소에서 계산한다. 산출된 제원은 전포반에 하달되며, 실제 사격과 동일한 절차에 의해 사격을 실시한다. 이때 각종 제원을 사격지휘소의 포병 전송통제 및 사격제원계산 시스템(BTCS : Battalion Tactical Control System)와 연동하여 통제부에 보고하면, 통제부에 있는 신경망 모듈에서 탄도를 묘사하고 탄착지점을 예측한다. 예측된 탄착지점 정보는 기존 가상 전투시스템에서 묘사하는 전장정보 묘사를 통해 실제 사격이 이루어진 것처럼 관측반과 대포병 레이더에 사격한 포탄의 파열효과(포탄 파열반경, 인마살상률 등)와 함께 전달된다.

기존 훈련체계와 다른 점은 신경망에 의해 포탄사격을 기존의 사표체계나 선형모델 보다 좀더 실제와 근사하게 묘사해 줄 수 있다는 것이다. 즉 모의훈련 상으로도 실제 사격처럼 수정사격을 해야 하는 상황을 부여할 수 있다. 기존 훈련에서는 포탄사격 피해를 확률적으로 적용할 수 밖에 없었지만, 신경망 모델을 사용하면 모델

에서 예측한 탄착지점의 묘사에 따라 그 피해가 달라 질 수 있다.

5. 모의실험 및 결과분석

5.1 모의 실험

본 연구에서 제시한 신경망 모델의 수행성을 평가하고, 구성된 신경망의 타당성을 검증하기 위해 모의실험을 실시하였다. 검증은 실제 포탄사격을 통해 획득한 데이터를 기초로 실시하는 것이 좋으나 현실적 데이터 조건상 불가능하다. 신경망을 학습하기 위해선 조건별 실험된 데이터가 필요하나 실험데이터수집을 위한 실제 포탄사격 실시에 많은 비용이 소요되고, 훈련상의 데이터 수집은 훈련장의 특성과 훈련주기의 특성에 따라 데이터의 종류가 한정되어 실험에 필요한 다양한 데이터 수집에 어려움이 따른다. 따라서 기존 연구들에서 실시했던 수행성 평가방법을 참고하여 모의실험을 실시하도록 한다.

신경망 모델을 사용한 Gosh의 경우 실제 포탄사격을 통해 데이터를 수집하지 않고, 앞서 소개한 수학적 탄도 모델을 통해 생성한 가상의 사격 결과를 신경망에 학습시켜 모델을 구성하고 효과를 검증하였다[4].

본 연구도 Gosh와 동일하게 실제 포탄사격과 유사하면서 발생 가능한 다양한 사격 결과를 묘사하는 Military Ballistics의 탄도방정식을 기초로 가상의 탄도 시뮬레이션을 만들고, 이를 이용하여 신경망을 구성하여 모의실험을 실시한다 [15].

탄도에 영향을 주는 요소 중에 본 실험에서는 영향관계가 비교적 명확한 표고차, 사각, 편각, 풍향, 풍속, 기온, 습도, 포구초속 등을 입력변수로 하고, 출력변수는 표적위치 대비 사거리오차, 편의오차가 있다.

표고차는 표적과 곡사화기간의 고도의 차이를

말하는 것이고, 편각과 사각은 사격 시 곡사화기에 장입하는 좌우, 상하 조정 값이다. 편각과 사각의 경우 실제 곡사화기와 동일하게 데이터 생성 시 좌우, 상하한계를 고려하여 적용한다. 기상제원도 일반 포탄 사격 시 사용하는 제원과 동일한 단위로 구성하고 위의 제원들은 실제와 최대한 근접한 묘사를 할 수 있게 변수별로 잡음(White Noise)을 적용한다.

기존의 탄도모델은 선형회귀모델로 구성되어 있다. 본 실험에서는 탄착지점을 표현한 탄도방정식을 임의의 모델(Unknown System)이라 가정하고 노이즈를 추가한 데이터를 생성시켜 실험에 필요한 학습데이터를 수집한다. 또한 신경망 모델의 비교대안으로 발생시킨 데이터에 선형회귀분석 방법을 이용하여 모델을 구성하고 성능비교를 실시한다.

데이터 생성과 회귀분석 모델 및 신경망 모델 구성은 통계 프로그램인 SAS 9.0을 활용하여 실험한다.

5.2 실험결과

각 모델별 예측오차를 SAS 9.0을 통해 구하였다. 모델을 적용하지 않았을 때의 오차를 기준으로 하였을 때, 각 모델별 오차는 <표 3>과 같다.

<표 3> 모의실험에 의한 모델별 오차

	사거리 오차	편의 오차
모델 미 적용시	1.00	1.00
회귀분석모델	0.86	0.98
CG NeuralNet	0.84	0.87

실험결과 표적에 대한 사거리 오차는 모델 적용 시 오차를 15%정도 감소시킬 수 있음을 알 수 있었다. 수학적 회귀모델과 신경망 모델간의 오차는 2%로 큰 차이가 없어 보이지만, 장사정포의 경우 사거리에 따라 오차의 절대량이 커짐을 고려할 때 그 차이는 크다고 할 수 있다.

편의오차의 경우 기상에 따른 영향이 큰 요소로 작용한다. 비선형관계 분석에 우수한 신경망 모델이 모델을 적용하지 않은 것이나 회귀분석 모델을 적용했을 때에 비해 월등하게 우수한 것으로 나타났다. 모델을 적용하지 않은 것과 회귀분석모델간의 차이는 2%이고 신경망모델과의 차이는 13%에 이르는 실험결과는 기상영향요소와 편의오차간의 관계를 회귀분석모델 보다는 신경망 모델로 예측하는 것이 더 우수함을 보여준다.

<표 3>과 같이 회귀분석모델이 사거리오차에서 비교적 좋은 성능을 보였으나 편의 오차에서 모델을 적용하지 않은 것과 유사한 결과가 나온 이유는 야전부대에서 기상수정량 계산시 적용하는 사표상의 보정 값처럼, 포탄사격 시 사거리 결정요소는 변동성이 큰 온도, 풍향, 풍속, 공기 밀도 등과 같은 기상요소보다는 사각이나 장약(포구초속) 등의 상대적으로 변동성이 작은 요인의 영향을 더 많이 받고, 편의 오차의 경우는 포탄사격 시 포탄이 좌측 또는 우측으로 빗나가는 것에 대해 영향 요인의 변동성이 크고, 선형관계 설정이 복잡한 기상요소의 영향을 많이 받기 때문이다.

한편 본 연구에서 제시한 신경망 모델은 비선형적인 특성을 갖는 요인에 대해 선형관계적인 인식 보다는 패턴화된 인식을 하기 때문에 편의 오차에서 회귀분석모델이나 모델을 적용하지 않았을 때 보다 오차발생률이 낮게 나왔다.

따라서 신경망을 이용한 탄도예측 모델 구성 시 모델을 미적용하거나, 수학적 회귀분석을 사용했을 때보다 우수하다고 볼 수 있다.

6. 결론 및 추후연구

본 연구에서는 신경망을 이용한 포병 탄도예측 모델을 통해 포병부대의 모의훈련체계를 개선할 수 있는 방안을 제시했다.

신경망 모델을 현재 직접 적용할 수 있는 방안으로서 육군 과학화 훈련단에서 실시하고 있는 과학화 전투훈련에 적용하는 방안이 있다. 기존의 과학화 전투훈련 모델에 곡사화기 탄도를 묘사할 수 있는 모듈을 추가 탑재하면 실제 포탄사격과 동일한 훈련 상황과 무기효과를 묘사할 수 있을 것이다. 기동부대나 직사화기 위주의 모의훈련이 아닌 포병과 곡사화기까지 모든 화기를 묘사한 실질적인 제병협동훈련으로서의 모의훈련체계 구성을 현실화 할 수 있을 것이다.

특히 포병 사격훈련에 소모되는 국방예산만큼 M&S를 통한 훈련을 실시한다면 육군에서 교육훈련용 탄약(교탄)구입 비용을 보다 효율적으로 사용할 수 있다. 모의훈련체제로 실제 포탄사격과 유사한 훈련을 실시한 다음 포탄사격을 실시할 수 있기 때문이다. 실제 포탄사격 없이도 현재 관측반 및 기동부대의 화력요청 팀을 위한 TSFO(Training Set Fire Observation)훈련처럼, 포병 사격지휘 팀이나 포술종합 팀 훈련 시 실제 포탄사격과 유사한 훈련을 가능하게 할 수 있을 것이다[16].

사격장이나 훈련장 여건이 불비하여 포탄 사격훈련이 제한되는 후방지역 포병부대의 경우 앞서 제시한 훈련체계를 적용한다면 포탄사격훈련 시 발생하는 포병부대의 사격장으로의 이동소요를 줄일 뿐만 아니라 사격 훈련으로 인한 소음, 화재 등 각종 민원발생을 사전에 차단할 수 있고, 낙탄 사고의 위험성을 감소시킬 것이다.

그러나 본 논문에서 제시한 방법은 훈련 또는 모델 구성을 위한 실제 포탄사격을 실시한 데이터를 활용하지 못했다. 따라서 실제 포탄사격에 대한 데이터를 수집하여 적용해 봄으로서 과학화 훈련에 시스템 구현을 검증해볼 필요가 있고, 탄착지점 예측을 통한 곡사화기의 사격 명중률 향상을 위한 추후 연구가 필요하다.

더 나아가 신경망 모델을 곡사탄도가 아닌 미

사일탄도의 영역으로 추가적인 연구를 한다면 탄도미사일 방어체계 개발에도 활용할 수 있을 것이다.

참고문헌

- [1] FY 2003 미 국방 연례보고서(Annual Report), 국방정보본부, 2002, p.11
- [2] 윤상윤, 우리 군의 M&S 비전과 과제, 국방정책연구, 2005, pp.9~36
- [3] 육군 과학화 훈련단, 육군 과학화 훈련단 홈페이지, 2007, <http://www.kctc.mil.kr>
- [4] 임영헌, MILES 장비 운용체계 소개, 전투발전, 1999, 제 96권, pp.42~60
- [5] 김기호, BTCS 연동 3차원 위게임 시뮬레이션(풍익모델), 한국시뮬레이션학회 추계학술대회 논문집, 2000, pp.248~254
- [6] 육군본부, 야교 32-3 사격지휘, 2004, pp.2-6~2-17
- [7] 민계료, 야전포병무기체계의 목표제압을 위한 속도오차의 허용한계 결정, 한국과학기술원(석사논문), 1976,
- [8] 서완석, 홍성훈, 화포사격제원의 새로운 수정 방법, 공학연구 제 25권, 1994
- [9] A. K Ghosh, Modeling of Performance of an Artillery Shell Using Neural Networks, Journal of spacecraft and rockets, 2002. Vol. 39, No. 3, pp.470~472
- [10] 유요한, 신경회로망을 이용한 다층장갑의 방호성능 예측, 한국군사과학기술학회지, 2001, 제4권 2호, pp. 189~201
- [11] 박상훈, 신경망을 이용한 반도체 공정 모델링 : 포토공정 오버레이 사례연구, 고려대학교 대학원(석사논문), 2005
- [12] Fletcher, R, Reeves, CM, Function Minimization by conjugate Gradients, Computer Journal, 1964, Vol. 7, pp. 149~154
- [13] Ji hyun Kim, Neural Network Fusion to Overlay Control System for Lithography Process, Lecture Notes in Computer Science, 2006, December, Vol. 4304, pp 587-596
- [14] Barnard, E. Optimization for Training Neural Nets. IEEE Transactions on Neural Networks, 1992, pp.232~240
- [15] C. L. Farrar, Military Ballistics, Royal Military College of Science. UK, 1983, pp.104~133
- [16] 육군본부, 야전포병 대포포술 (관측), 1998. pp. 부6-1~6-2

■ 저자소개 ■

류 해 준 (E-mail : cl3687@hanmail.net)

2001 육군사관학교 무기공학과 졸업(학사)
현재 고려대학교 정보경영공학전문대학원 정보경영공학과 석사과정
관심분야 일정계획, 인공지능

고 효 현 (E-mail : swish17@korea.ac.kr)

2002 명지대학교 산업공학과 졸업(학사)
2004 고려대학교 산업공학과 졸업(석사)
현재 고려대학교 산업시스템정보공학과 박사과정
관심분야 경영정보시스템, 생산관리, APC

김 지 현 (E-mail : jihyunk@korea.ac.kr)

1993 고려대학교 산업공학과 졸업(학사)
1995 고려대학교 대학원 산업공학과 졸업(석사)
2004 미국 University of Michigan 산업공학과 졸업(박사)
현재 고려대학교 정보통신기술연구소 연구교수
관심분야 Advanced Process Control, Quality Control, Neural Network

김 성 식 (E-mail : sungskim@korea.ac.kr)

1972 고려대학교 기계공학과 졸업(학사)
1974 고려대학교 대학원 산업공학과 졸업(석사)
1976 미국 Southern Methodist University 산업공학과 석사
1979 미국 Southern Methodist University 산업공학과 박사
현재 고려대학교 산업시스템정보공학과 교수
관심분야 Advanced Process Control, Modeling, System Optimization