

인공신경망을 이용한 대대전투간 작전지속능력 예측

심흥기
고려대학교 정보경영공학 전문대학원
(honggi0817@korea.ac.kr)

김승권
고려대학교 정보경영공학부
(kimsk@korea.ac.kr)

본 연구는 인공신경망을 이용하여 대대급 방어 작전에서 임의시점에서의 작전지속능력을 예측하는 데 있다. 전투결과에 대한 수학적 모델링은 이를 위한 많은 요인들이 가지는 시·공간적 가변성으로 인해 전투력을 평가하는데 많은 문제점이 있었다. 따라서 이번 연구에서는 대대 전투지휘훈련간 각 부대의 생존률을 전방향 다층 신경망(Feed-Forward Multilayer Perceptrons, MLP)과 일반 회귀신경망(General Regression Neural Network, GRNN)모형에 적용하여 임무달성 여부를 예측하였다. 실험 결과 매개변수들의 비선형적인 관계에도 불구하고 각각 82.62%, 85.48%의 적중률을 보여 일반회귀신경망 모형이 지휘관이 상황을 인식하고 예비대 투입 우선순위 선정 등 실시간 지휘결심을 하는데 도움을 줄 수 있는 방법임을 보여준다.

논문접수일 : 2008년 07월 게재확정일 : 2008년 08월 교신저자 : 김승권

1. 서론

인류의 역사는 전쟁의 역사라 할 만큼 전쟁의 결과는 정치, 경제 사회, 문화 등에 지대한 영향을 미쳐 왔다. 이에 따라 “싸우지 않고 승리함을 추구 하되 싸우면 반드시 이기기 위한 방법”으로 전쟁 결과에 대한 분석이 국가차원에서 연구되어졌다. 이러한 연구는 과학기술의 발전과 위게임 모델이 개발되면서 실제 전투상황과 유사한 실전적 모의 훈련이 가능하게 되어 전투 간 교전피해를 비롯한 부대 위치, 시간대별 전투력 추이를 실시간으로 알 수 있는 수준으로 발전하였다(부형욱, 1999). 뿐만 아니라 동일한 상황에서 상이한 무기체계의 성능이 전투에 미치는 효과를 모의할 수 있게 되어 무기효과분석을 통한 차세대 무기체계 개발에 기여하고 있다(한용섭, 2002).

하지만 각국의 연구 실적 또한 철저한 비밀로 부쳐져 민간차원의 활발한 연구가 이루어지는데 어려움이 있었다. 또한 전투에 대한 관련 데이터 확보에 대한 제한사항과 전투력을 결정하는 수많은 매개변수와 비선형성(Nonlinear)과 시변성(Time-variable)은 전투 결과 예측모델의 구성과 시뮬레이션에 있어서 큰 장애물로 작용하였다. 또한 작전 실시간 고려해야 할 입력변수가 많아질수록 데이터 입력 및 모의시간이 증가하여 현재 전투력으로 가능한 임무수행 정도를 실시간 예측하는 데는 제한이 있으며, 이에 대해 평가한 사례가 없었다. 기존의 비선형성과 시변성을 가지는 매개변수를 이용한 예측관련 민간분야의 연구를 살펴보면 Hsu(1995) 등은 지금까지 수문학적 예측을 위해 이용되어 온 선형적인 모형들과 신경망 이론을 적용한 모형과의 비교를 통하여 신경망 모형이 더욱

뛰어난 예측력을 보인다고 결론지었으며(Hsu et al., 1995; Thirumalaiah and Markarand 2000), Altman (1994) 등은 이용한 기업의 도산 원인의 성질이 비선형성임을 감안할 때 신경망 모형은 기업의 재무제표를 이용한 도산 예측에 적절한 모형임을 제시하였다(이건창 등, 1996; 조준희, 2006; 피종호와 김승권, 1997; Altman et al., 1994).

따라서 본 연구에서는 블랙박스(Black-box)모형인 인공신경망(Neural Network)모형 중 다층신경망과 일반화된 회귀신경망 모형을 적용하여 t 시점에서의 방어부대의 작전지속 능력과 이를 바탕으로 한 임무성공 가능성을 예측하고, 이에 따른 군사작전용 인공신경망 모형의 개발 가능성을 타진해 보고자 한다. 본 연구의 구성은 제 2장에서 과학화 훈련의 종류와 대대전투지휘훈련 소개, 제 3장에서는 인공신경망의 개념과 응용사례, 제 4장에서는 인공신경망을 이용한 모형의 구성, 제 5장에서는 시뮬레이션 결과분석으로 이루어져 있으며 인공신경망 모형이 대대급 전투결과를 예측함에 있어서 활용가능성이 어느 정도인지를 알아보고자 한다.

이를 위해 제 0000부대에서 2002년부터 2003년까지 위게임 모델(전투21)을 이용하여 실시한 대대전투지휘훈련 간 부대의 시간대별 생존률을 기초로 학습용 데이터와 검증용 데이터를 만들어 학습 및 검증을 실시하여 연구목적의 타당성을 도출하고 활용방안에 대해 논의하고자 한다.

2. 과학화 훈련의 종류와 대대전투 지휘훈련

2.1 과학화 훈련의 분류

과학화 훈련은 정보 통신과 과학기술의 발달추

세에 맞추어 교육훈련의 체계와 기법 및 지원 등에 첨단 과학기술을 적용한 훈련이다. 이는 현실적으로 전투경험을 축적하는 데 있어서 전투실험이 위험하고 비용이 크게 요구됨에 따라 필요성이 점차 증대되고 있으며 <그림 1>과 같이 전투지휘훈련(Constructive simulation), 모의장비 훈련(Virtual simulation), 실기동 모의훈련(Live simulation)으로 구분된다.

전투지휘훈련(Constructive simulation)은 지휘관 및 참모의 전투지휘 능력을 배양하고 제대별 통합전투 수행 능력을 향상시키기 위해 위게임 모델을 구축하여 실험해 봄으로써 실전과 유사한 상황에서 작전의 성공과 실패를 체험하여 부대의 취약점과 미비점을 발견하고 이를 보완하여 부대의 전투력을 향상시키는 훈련이다. 모의장비 훈련(Virtual simulation)은 실제 장비로 훈련할 때 제한을 받는 경우 실제 장비와 동일한 모의 장비를 활용하는 것으로 ‘비행 시뮬레이터’가 해당된다. 마지막으로 실기동 모의훈련(Live simulation)은 실제와 동일한 환경에서 실제 장비와 같은 성능을 가진 교전훈련 장비를 가지고 훈련하는 것으로 ‘육군 과학화 훈련장’이 이에 해당된다.



전투지휘훈련 모의장비훈련 실기동모의훈련

<그림 1> 과학화 훈련의 분류

2.2 대대전투지휘훈련

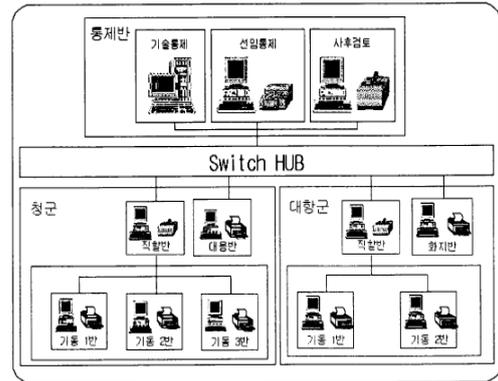
대대전투지휘훈련은 대대급 작전에서 훈련에 소

요되는 비용과 자산을 최소화 하면서 부대가 실전적으로 훈련할 수 있도록 하기 위해 지휘관 및 참모의 의사결정 과정에 대한 실제 활동과 예하부대의 기동, 화력, 정보기능에 대한 모의가 결합된 훈련의 형태이다. 이를 통해 중대 및 대대급 지휘관 및 참모에게 현대 전장의 복잡성과 치명성을 제공하고 부대의 취약점을 판단하여 이를 보완함으로써 전투력을 향상시킬 수 있다. 대대전투지휘훈련간 훈련부대는 다양한 상황에서 최선의 방책을 구하기 위해 부대지휘절차를 실시하고, 이는 작전지역에 대한 3차원 지형정보에 따라 관측과 사계, 은폐 및 엄폐, 기동속도, 무기성능, 화력효과에 따른 병력손실이 표현 가능한 위게임 모델(전투 21) 통해 모의된다. 또한 모의된 결과는 전장상황에 따른 방책을 발전시키기 위한 참모의 능력을 점검하고 상황에 따른 적절한 조치여부를 평가하는 데 활용된다.

전투 21에 의한 훈련편성은 총 12개 모의반으로 구성되어 있으며, 훈련을 통제하는 통제반과 훈련을 실시하는 청군(아군)과 홍군(적군)으로 구성되고, 각 군은 다시 예하부대의 기능에 따라 직할반, 기동반, 대응반으로 구성되어 있으며 <그림 2>와 같다. 또한 전투 21모델은 국제 시뮬레이션 표준연동체계 HLA(High Level Architecture)인증 최종 시험을 통과하고 국제 표준연동 인증목록에 공식 등록되어 그 우수성이 입증된 바 있다.

대대전투지휘훈련은 훈련 실시자에게 실제 전장환경에 근접한 훈련환경을 제공하는데 그 목적이 있다. 현재 기존의 대대전투지휘훈련에서는 현재 상황에 따른 상황조치를 위해 위게임 모형에서 구현되는 전장환경에서 적 교리에 근거한 예상 공격방향 및 기동로를 예측하고 이에 대한 방책을 발전시키는 훈련을 실시하고 있다. 현재 대대급에서는 적의 주공 및 조공부대의 방향에 대하여 교

리에 따라 분석하는 수준이며 현재 전투력으로 어느 정도의 방어임무를 수행할 수 있는지 평가할수 있는 시스템은 구축되어 있지 않은 상태이다. 따라서



<그림 2> 전투21 모델의 시스템 구성

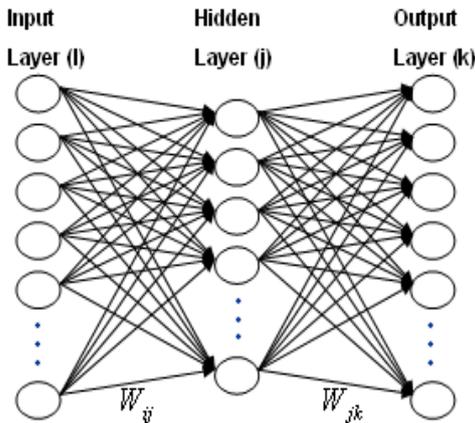
인공신경망 모형을 통한 예측기법을 이용한다면 아군의 방어를 위한 능력의 정도까지 예측하여 지휘관의 실시간 의사결정과 적 공격에 대한 방책 발전에 이용할 수 있을 것으로 판단된다.

3. 인공신경망의 개념과 응용사례

3.1 기존 연구 고찰

인공신경망 이론은 패턴 및 문자 인식, 음성분석, 기상예측, 로봇공학, 수자원 및 환경공학 등 광범위한 분야에서 이용되고 있는 분야로 미국/유럽/일본 등 선진국에서는 국가적인 차원에서 연구개발이 수행되고 있다. 인공신경망은 1943년 McCulloch와 Pitts에 의해 최초로 제안되었으나(McCulloch and Pitts, 1943) 실제로 다양한 분야에서 적용된 것은 <그림 1>과 같이 기존의 인공신경망의 입력층(Input Layer)과 출력층(Output Layer) 사이에 한 개 이상의 은닉층(Hidden layer)을 쓰는

새로운 모델들이 1980년대 중반에 제안된 이후이다. 특히 1986년 Rumelhart가 제안한 오차 역전파 신경망 알고리즘(Back-Propagation Algorithm)은 목표로 하는 결과값 (Desire Output)과 모델에 의해 계산된 결과값(Actual output)의 차이를 학습을 통해 계속 조정해 나감으로써 오차 값을 최소화 하도록 학습시키고 학습결과를 이용하여 예측대상에 검증을 실시하는 방법으로, 선형분리문제 뿐만 아니라 비선형분리 문제 등 여러 문제를 해결할 수 있는 계기를 마련하였다(김대수, 1993; Haykin, 1994).



<그림 3> 인공신경망의 구조

또한 Hsu(1995) 등은 지금까지 수문학적 예측을 위해 이용되어 온 선형적인 모형들과 신경망 이론을 적용한 모형과의 비교를 통하여 신경망 모형이 더욱 뛰어난 예측력을 보인다고 결론지었으며(Hsu et al., 1995; Thirumalaiah and Markarand 2000), Sajikumar 등(1999)에 의해 발표된 결과에서는 결정계수의 값이 가장 뛰어난 모형의 경우 빈약한 자료에 신경망을 적용하여 좋은 결과를 보여주었다(Sajikumar and Thandaveswara, 1999).

국내 군사 분야 연구로는 임성빈(2003)은 군 지역 정보 전송 중계기 최적배치에 있어서 신경망 모형이 K-means 알고리즘보다 좋은 결과를 보여주었으며(임성빈, 2006), <표 1>에서 볼 수 있듯이 차세대 군사시스템에 적용하기위해 미국 등 선진국에서 활발한 연구가 진행되고 있다.

<표 1> 군사 분야 신경망 이론 응용사례

구분	분야	개발기관	응용시스템
인식	항공	(미)TRW사	전투기 식별
	폭발물	(미)SAIC사	폭발물 탐지
	소나	(미)존 홉킨스대학	소나표적식별
정보처리	소나	(일)방위청 기술연구본부	함정방사 소음 식별
	항공	(미)불 시스템사	항공기 조종 시뮬레이션
	화포	(미)뉴럴웨이사	탄도 계산

3.2 다층 신경망(Feed-Forward Multilayer Perceptrons, MLP)

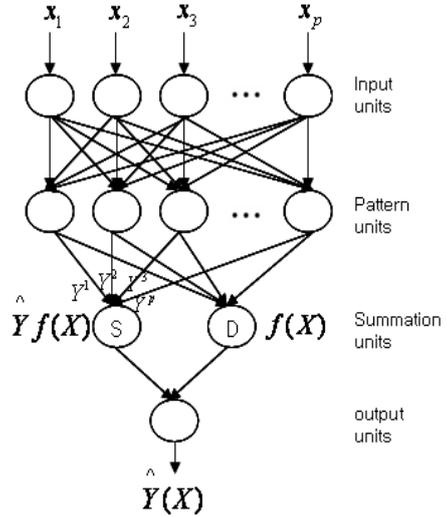
전방향 다층 신경망(MLP)은 각각의 입력에 대해 기대하는 출력과 동일하거나 유사한 출력을 얻기 위해 반복학습을 통하여 신경망의 연결강도의 값을 구하는 알고리즘이다. 일반적인 전방향 다층 신경망(MLP)은 입력층과 은닉층, 출력층의 3개층으로 구성되며 은닉층의 출력은 식 (1)과 같이 나타낼 수 있으며, 출력층에서는 출력된 Y가 주어진 실제출력 y와의 차이를 감소시키는 방향으로 망의 연결강도를 조절하여 학습을 실시하며 식 (2)와 같다.

$$h_j = \phi_1(r_j) = \phi_1\left(\sum_i W_{ij} x_i\right) \quad (1)$$

x_i : 입력자료
 h_j : 입력노드로부터 전달된 은닉층의 출력값
 W_{ij} : 입력층과 은닉층 사이의 연결강도
 ϕ_1 : 은닉층의 전달함수(Log-Sigmoid함수)

$$Y = \phi_2(\sum_j W_{jk} h_j) = \phi_2(\sum_j W_{jk} \phi_1(\sum_i W_{ij} x_i)) \quad (2)$$

x_i : 입력자료
 h_j : 입력노드로부터 전달된 은닉층의 출력값
 W_{ij} : 입력층과 은닉층 사이의 연결강도
 W_{jk} : 은닉층과 출력층 사이의 연결강도
 ϕ_1, ϕ_2 : 은닉층, 출력층의 전달함수(Log-Sigmoid함수)



<그림 4> 일반화된 회귀신경망(GRNN)

3.3 일반화된 회귀 신경망(General regression neural network)

일반화된 회귀신경망(GRNN)은 입력층, 패턴층, 합산층, 출력층의 4개층으로 구성되어진 비선형 회귀이론을 기초로 한 순방향 신경망으로 <그림 4>은 일반화된 회귀신경망 모형의 구조를 나타내고 있다. 이는 대부분의 신경망처럼 반복적으로 학습하지 않는 대신에 패턴층에서 각 입력패턴을 저장하고, 합산층에서 가중치들을 계산하는 방식으로 학습된다. 첫 번째 층은 입력층으로 입력층 노드수는 독립변수의 수와 동일하며 패턴층과 완전 연결되어 있다. 두 번째 층은 패턴층으로 각 입력패턴을 대표패턴으로 하는 노드들로 구성되고 입력자료와 각 대표패턴의 거리를 계산하며 i 번째 노드에서의 입력값은 식 (3)과 같다.

$$C_i = \sum_{j=1}^p |X_j - X_j^i| \quad (3)$$

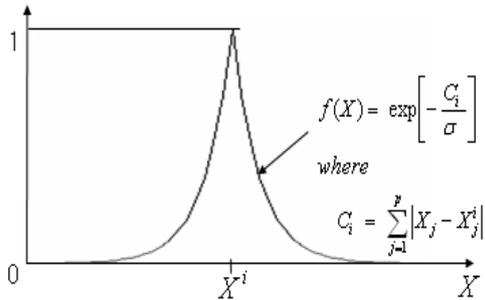
이때 X^i 는 i 번째 뉴런에 저장된 대표패턴이며

X 는 입력패턴이고, j 는 각패턴의 차원이다. 패턴층에서 계산된 입력패턴과 패턴층의 각 노드에 저장된 대표패턴간의 거리는 각 노드별 대표패턴 X^i 가 중심이고 폭 σ 를 가지는 지수함수 형태의 비선형 활성화함수식 (4)를 통해 거리가 가까울수록 1에 근접하고 멀수록 0에 근접한 값으로 저장된다.

$$f(X) = \exp\left(-\frac{C_i}{\sigma}\right), \quad C_i = \sum_{j=1}^p |X_j - X_j^i| \quad (4)$$

<그림 5>는 대표패턴 X^i 가 중심이고 폭 σ 를 가지는 지수함수형태의 비선형 활성화함수로 입력패턴 X 와 i 번째 노드의 대표패턴 X^i 간의 거리가 가까울수록 해당 노드는 1에 가까운 값을 가지게 되어 출력값에 미치는 영향이 크게 된다. 반대로 i 번째 노드의 대표패턴과 거리가 멀수록 해당 노드는 0에 가까운 값을 가지게 되어 출력값에 미치는 영향은 작게 된다. 따라서 각각의 대표패턴은 입력패턴과 거리가 가까울수록 출력값에 큰 영향을

미치게 된다. 이때 활성화함수의 너비상수 σ 는 GRNN의 성능을 결정하는 학습인자로 입력패턴과 대표패턴의 거리가 출력값에 미치는 영향을 조절하는 기능을 수행하며 관측값에 대한 출력값의 평균제곱오차를 최소화 하는 값을 선택한다. σ 값이 클수록 활성화함수는 완만하게 되어 입력패턴과 대표패턴간 거리의 영향이 감소하게 되고 σ 값이 0에 가까워질수록 입력패턴은 가장 가까운 대표패턴의 영향을 크게 받게 된다.



<그림 5> GRNN의 활성화함수

합산층에서 D-합산뉴런은 패턴층 각 뉴런에서 활성화된 값의 합산을 수행하며 S-합산뉴런은 패턴층에서 각 노드별로 활성화된 값과 해당 노드에서의 대표패턴의 관측값들 간 선형결합을 수행한다. 출력층에서는 각 S-합산뉴런의 출력값을 D-합산 뉴런의 출력값으로 나눈 값이 저장된다. 따라서 일반화된 회귀신경망의 출력값은 식 (5)과 같은 조건부평균이 된다.

일반적으로 일반회귀 신경망은 다층신경망 보다 훨씬 적은 입력 데이터(다층신경망의 1%)로 모형을 구성했을 때 다층신경망에 비하여 약 2배의 평균제곱오차를 보여 매우 작은 학습 데이터로도 만족할만한 결과를 보이며 학습속도가 빠른 것으로 알려져 있다(Specht).

$$\hat{Y}(X) = \frac{\sum_{i=1}^m Y^i \exp(-\frac{C_i}{\sigma})}{\sum_{i=1}^m \exp(-\frac{C_i}{\sigma})} \quad (5)$$

X : 각 패턴의 *input*

Y : 각 패턴의 *output*

C_i : 대표패턴으로부터 각 패턴간 거리

Y^i : C_i 에 포함된 패턴의 Y 값의 합

m : 패턴의 수

p : 패턴의 차원

σ : 너비 상수

4. 인공지능망을 이용한 학습 및 검증

4.1 입력 자료의 처리 및 구성

작전지속능력(Operational Continuous Ability)은 군사적 목표달성을 위한 작전 활동을 위해 요망되는 수준과 기간을 유지해주는 능력을 말한다. 방어작전에서 방어진지를 고수하는 임무를 부여 받은 특정부대가 t 시점에서의 전투력으로 n 시간 동안 현재 방어진지를 고수하였다면 해당부대는 n 시간 동안 방어임무수행이 가능하다고 할 수 있다. 따라서 t 시점에서의 작전지속능력(OCA_t)을 n 시간으로 평가 할 수 있으며 이는 식 (6)와 같다.

$$OCA_t = T_w - t \quad (6)$$

OCA_t : t 시점에서의 부대 전투력이 지니는 작전지속능력(hour)

T_w : 적의 강요에 의해 방어부대가 중심지역으로부터 철수하는 시점

t : 전투기간 내 임의 시점

만약 t 시점에서 부여받은 방어임무 완수기간보

다. 실제 방어임무 수행기간(n시간)이 길었다면 방어부대의 철수시점이 부여받은 임무수행기간 이후가 되므로 방어임무달성이 가능하나 n시간을 초과하여 현진지를 고수하는 임무였다면 임무 달성시점 이전에 방어부대가 철수를 강요받았기 때문에 방어작전은 실패하게 된다. 일반적으로 방어부대는 작전을 성공적으로 수행하기 위해 요구되는 작전지속능력 이상의 전투력을 보유해야 하므로 방어작전 성공 및 실패조건은 다음과 같다.

방어 작전 성공조건 :

$$OCA_t \geq ROCA_t \quad (7)$$

$ROCA_t$: t 시점에서의 요구 작전지속능력 (hour)

방어작전 실패조건 :

$$OCA_t < ROCA_t \quad (8)$$

작전지속능력에 대한 평가는 지휘관의 능력과 참모의 역량 병사들의 사기 등 인적 요소와 적을 찾기 위한 노력, 화력 및 병력의 집중, 병력의 훈련 정도 등 전술적 요소 및 정보획득의 정확성 등 다양한 평가항목이 종합적으로 분석되었을 때 더욱 타당성 있는 결론에 도출하게 된다. 하지만 지휘관의 역량과 병사들의 사기와 같은 질적 자료를 직접 정확히 평가하기는 매우 어렵고 해당 직위에서의 경험에 따른 상대성이 크며 평가자의 주관적 요인이 개입할 여지가 있으며 계량화하기가 어렵다는 단점이 있다. 또한 경제 경영분야의 관련연구를 살펴보면라도 기업경영의 성과분석 및 도산, 주가예측도 정량적 자료인 재무제표를 가지고 평가하는 것이 일반적이다(박정제과 신동령, 1987).

따라서 본 연구에서는 대대전투지휘훈련 사후 분석간 활용되는 대표적인 양적 자료인 각 부대의

전투 시간대별 보직인원 대비 생존인원으로 계산된 부대별 병력의 생존률과 장비가동률 및 부대병력의 계급별 분포에 대해 정규성 검정 및 t-검정 결과 작전지속능력에 따른 임무 성공 및 실패를 예측하는 데 있어서 신뢰성 있고 유의한 자료로 평가된 아군과 적군 예하의 16개 부대의 생존률을 입력 자료로 선정하였으며 세부 내용은 <표 2>와 같다.

$$S_d^n = \frac{n\text{시점에서의 } d\text{부대의 생존인원}}{\text{전투에 참가한 } d\text{부대의 보직인원}} * 100 \quad (9)$$

S_d^n : d부대의 n시점에서의 생존률

<표 2> 작전지속능력 평가에 사용된 입력변수

구 분	아 군		적 군	
입력변수 선정 부대 (생존률)	1	전투지역 전단 방어부대(1)	1	주요방향 공격부대
	2	전투지역 전단 방어부대(2)	2	차요방향 공격부대
	3	예비대	3	후속부대
	4	화기중대	4	련포군 (화력지원)
	5	대대본부중대	5	본부중대
	6	대대본부	6	대대본부
	7	배속부대	7	배속부대
	8	연대본부	8	연대본부

이를 위한 표본 대상은 제 0000부대에서 2002년부터 2003년까지 위게임 모형을 이용하여 실시한 21개 대대 중에서 전투지휘훈련간 대대중심지역 전투간 적의 우세로 중심지역 방어가 불가능하여 중심지역으로부터 철수를 실시한 14개 대대를 대상으로 하였다. 또한 각각의 전투지휘훈련에서 철

수를 실시하는 시점을 기준시간 t 로 하여 $t-3h$ 부터 $t-9h$ 까지의 단위시간별 입력변수로 선정된 각 부대의 보직인원대비 생존률 데이터 98개를 이용하여 학습 및 검증용 데이터를 구성하였다.

모형에 적용하기 위해 선별된 자료들은 모두 전처리 과정(pre-processing)을 거치게 되는데, 이 과정은 신경망의 수렴속도를 빠르게 하고 잡음(noise)이나 왜곡(skewness)에 의해 변형된 것을 바로 잡는 기초적인 연산처리 과정이다. 본 연구에서는 각 입력변수별 생존률이 가장 높은 수준과 가장 낮은 수준을 각각 1과 0으로 하고 그 사이에서 정규화(Normalizing)하였으며 정규화에 사용한 식은 식 (10)과 같다.

$$Norm(S_d)_p = ((S_d)_p - Min(S_d)) / (Max(S_d) - Min(S_d)) \quad (10)$$

여기서 $Norm(S_d)_p$ 은 p 번째 패턴의 부대 d 의 생존률 S 의 정규화 값, $(S_d)_p$ 는 p 번째 패턴의 부대 d 의 생존률, $Max(S_d)$, $Min(S_d)$ 는 각각부대 d 의 생존률 S 의 최대값, 최소값이다.

실험용 데이터 전체는 미리 정규화 하여 이를 기준으로 학습용 데이터 셋과 검증용 데이터 셋으로 하였는데 이는 학습용 데이터와 검증용 데이터를 별도로 노멀라이징 함으로써 발생하는 데이터의 왜곡을 없애고자 한 것이다(Samarasinghe, 2006).

4.2 모형의 구성

일반적으로 다층 신경망의 구성에서 은닉층의 개수가 하나 이상이더라도 정확도에 큰 영향을 미치지 않고, 단지 은닉층이 있는 신경망 모형이면 충분한 정확도를 보이므로(Altman et al., 1994) 각

각 1개의 입력층, 은닉층, 출력층으로 구성하되 각 층에서의 노드수는 16개, 16개, 1개를 가지는 MLP 모형을 구성하였다. 또한 GRNN 모형의 경우 패턴층의 노드수는 학습데이터 수와 동일하도록 구성하였다. 이때 입력 자료는 t 시점에서의 각 부대별 생존률을 사용하였으며 식 (11)과 같다.

$$OCA_t = f \left[\begin{matrix} F_{m1}(t), F_{m2}(t), \\ F_r(t), F_{hq}(t), \\ F_{hc}(t), F_{fc}(t), \\ F_a(t), F_{rhq}(t), \\ R_{m1}(t), R_{m2}(t), \\ R_r(t), R_{hq}(t), \\ R_{hc}(t), R_{fc}(t), \\ R_a(t), R_{rhq}(t), \end{matrix} \right] \quad (11)$$

F : 아군

$F_{m1}(t)$: t 시점에서 주방어제대 1(적 주요방향)의 생존율

$F_{m2}(t)$: t 시점에서 주방어제대 2(적 주요방향)의 생존율

$F_r(t)$: t 시점에서 예비대의 생존률

$F_{hq}(t)$: t 시점에서 대대중대의 생존률

$F_{hc}(t)$: t 시점에서 본부중대의 생존률

$F_{fc}(t)$: t 시점에서 화기중대의 생존률

$F_a(t)$: t 시점에서 지원배속부대의 생존률

$F_{rhq}(t)$: t 시점에서 상급부대 지휘부의 생존률

E : 적군

$E_{m1}(t)$: t 시점에서 주요방향의 생존률

$E_{m2}(t)$: t 시점에서 차요방향의 생존률

$E_r(t)$: t 시점에서 후속부대의 생존률

$E_{hq}(t)$: t 시점에서 대대본부의 생존률

$E_{hc}(t)$: t 시점에서 본부중대의 생존률

$E_{fc}(t)$: t 시점에서 련포군의 생존률

$E_a(t)$: t 시점에서 배속부대의 생존률

$E_{rhq}(t)$: t 시점에서 상급부대 지휘부의 생존률

또한 검증의 타당성을 높이기 위해 모든 입력자료를 5번씩 및 검증에 이용하기 위해 학습용과 검증용으로 구분 조합하는 방법에 따라 각각 10개의 데이터 셋을 구성하고 학습 및 검증을 실시하였다. 각각의 학습 및 검증용 데이터 구성 비율과 각 데이터 셋에서의 임무달성 및 실패 데이터 비율을 1 : 1로 하였다. 실험에 사용된 Software는 Matlab 7.0을 이용하였다. 학습에 사용된 인공신경망 구성 방법은 <표 3>과 같다.

<표 3> 학습에 사용된 인공신경망 구성방법

구분	다층신경망	일반화된 회귀신경망
사용 패키지	Matlab 7.0 neural network toolbox	
입력층	16개노드	16개노드
은닉층	1개층 24개노드(은닉층)	2개층 (패턴층 : 42개, 합산층 : 2개노드)
입력패턴수	84개 패턴(학습용+검증용)	
출력층	1개(1 : 방어작전성공, 0 : 방어작전실패)	

5. 실험 및 결과

인공신경망을 이용하여 데이터의 학습 및 검증을 실시한 결과 요구 작전지속능력($ROCA_t$)이 6시간일 때와 7시간 일 때 방어작전 성공 및 실패에 대한 예측 결과 일반회귀 신경망(GRNN)의 예측적중률은 각각 84.76%, 85.48%였으며 다층신경망(MLP)의 경우는 82.38%, 82.62%였다. 예측결과를 비교할 수 있는 선행연구가 부족한 관계로 본 연구의 실험 결과를 민간분야에서 재무제표를 이용

한 민간기업의 도산예측 관련 선행연구자들이 연구했던 연구결과<표 4>와 비교하였다. 재무제표를 이용하여 기업의 도산을 예측함에 있어 인공신경망 모형을 적용한 경우 예측정확도가 82.2%~94.2%였던 것에 비추어 볼 때 군사분야에서 예하부대의 생존률로 방어지속능력 및 전투결과를 예측하는 데 있어서 인공신경망 모형을 적용하는 것은 하나의 방법이 될 수 있다고 판단된다. 또한 인공신경망을 이용한 각각의 경우의 데이터 셋별 예측적중률은 <표 5>~<표 8>과 같다.

<표 4> 재무제표를 이용한 도산예측 관련 선행 연구자들과의 예측적중률 비교

연구자	표본대상 기간	표본수	연구방법	예측률
조흥규 (1994)	1991~1993	544	인공신경망 판별분석 AR모형	83.7 82.2 81.5
이건창 (1996)	1991~1995	93	인공신경망 판별분석	82.2 78.1
김영일 (2000)	1995~1998	121	인공신경망 판별분석	94.2 76
조준희, 강부식 (2006)	1999~2005	98	인공신경망	89.6
이정인 (2007)	1999~2001	216	인공신경망	85.7
본 연구	2002~2003	84	인공신경망	85.1

<그림 5>, <그림 6>의 데이터 셋별 GRNN과 MLP 모형간 예측력을 비교한 내용을 살펴보면 <그림 5>에서 알 수 있듯이 10개의 데이터 셋 중에서 데이터셋 5, 9의 경우를 제외한 8개의 데이터셋을 이용한 경우 GRNN의 예측력이 보다 나은 것으로 나타났다.

또한 <그림 6>의 경우 데이터 셋 8을 제외한 9개의 데이터 셋에서 GRNN의 예측력이 보다 나은 예측력을 보여 총 20번의 시뮬레이션 결과 17개의

<표 5> $ROCA_t = 6$ 인 경우 데이터 셋별 예측적중률(GRNN)

데이터	적 중	비적중	예측율 (%)
데이터셋1	38	4	90.48
데이터셋2	33	9	78.57
데이터셋3	39	3	92.86
데이터셋4	40	2	95.24
데이터셋5	33	9	78.57
데이터셋6	36	6	85.71
데이터셋7	31	11	73.81
데이터셋8	39	3	92.86
데이터셋9	35	7	83.33
데이터셋10	32	10	76.19
평균	35.6	6.4	84.76

<표 6> $ROCA_t = 7$ 인 경우 데이터 셋별 예측적중률(GRNN)

데이터	적 중	비적중	예측율 (%)
데이터셋1	35	7	83.33
데이터셋2	35	7	83.33
데이터셋3	36	6	85.71
데이터셋4	36	6	85.71
데이터셋5	38	4	90.48
데이터셋6	36	6	85.71
데이터셋7	37	5	88.10
데이터셋8	34	8	80.95
데이터셋9	36	6	85.71
데이터셋10	36	6	85.71
평균	35.9	6.1	85.48

<표 7> $ROCA_t = 6$ 인 경우 데이터 셋별 예측적중률(MLP)

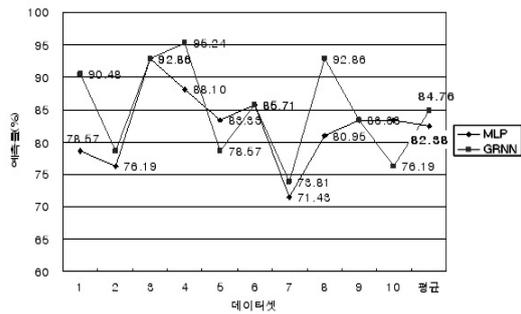
데이터	적 중	비적중	예측율 (%)
데이터셋1	33	9	78.57
데이터셋2	32	10	76.19
데이터셋3	39	3	92.86
데이터셋4	37	5	88.10
데이터셋5	35	7	83.33
데이터셋6	36	6	85.71
데이터셋7	30	12	71.43
데이터셋8	34	8	80.95
데이터셋9	35	7	83.33
데이터셋10	35	7	83.33
평균	34.6	7.4	82.38

<표 8> $ROCA_t = 7$ 인 경우 데이터 셋별 예측적중률(MLP)

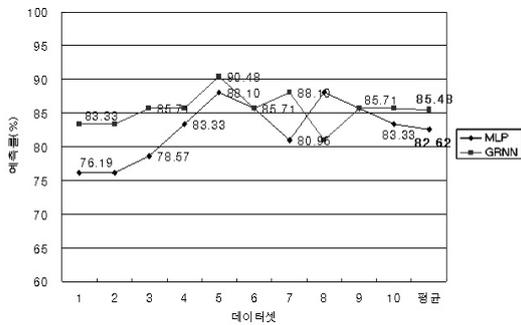
데이터	적 중	비적중	예측율 (%)
데이터셋1	32	10	76.19
데이터셋2	32	10	76.19
데이터셋3	33	9	78.57
데이터셋4	35	7	83.33
데이터셋5	37	5	88.10
데이터셋6	36	6	85.71
데이터셋7	34	8	80.95
데이터셋8	37	5	88.10
데이터셋9	36	6	85.71
데이터셋10	35	7	83.33
평균	34.7	7.3	82.62

데이터 셋에서 GRNN 모형이 더 나은 예측정

확도를 보였다. 하지만 MLP을 이용한 예측결과가 우수한 데이터 셋도 무시할 수 없으며 두 가지 모형을 비교하여 좋은 예측력을 보이는 모형을 사용하는 것이 바람직할 것이다.



<그림 5> $ROCA_t=6(H)$ 일 때 GRNN과 MLP 모형 간 예측정확도 비교



<그림 6> $ROCA_t=7(H)$ 일 때 GRNN과 MLP 모형 간 예측정확도 비교

하지만 일반 회귀 신경망(GRNN)은 다층신경망(MLP)처럼 학습과정에서 반복적인 계산 없이 각 학습패턴별 단 한 번의 계산으로 학습이 이루어져 학습처리 과정이 빠르고 지역 최소점에 수렴하지 않는다는 장점이 있다. 위 실험에서 42개 패턴으로 학습을 실시했을 때 다층신경망(MLP)은 패턴별

평균 239회의 계산이 요구되었으며 데이터 셋별 평균 10,038번의 계산 후 학습이 종료되었다. 반면 일반 회귀 신경망(GRNN)은 학습 패턴수와 동일한 42번의 계산으로 학습이 종료되었다. 또한 위 실험의 경우 다층신경망 보다 최소 7배 이상 빠른 처리능력을 보였다(<표 9> 참조). 따라서 빠른 정보처리가 요망되는 전장상황을 고려할 때 일반 회귀 신경망(GRNN)이 지휘관이 현 상황을 인식하고 실시간 지휘결심을 하는데 보다 나은 방법이 될 수 있다고 판단된다.

<표 9> 인공신경망 모형비교

신경망 모형	MLP	GRNN
20회 실험간 예측률 우수횟수	3회	17회
학습간 패턴별 계산횟수(평균)	239회	1회
학습속도(sec)	15~24	2

6. 결론 및 향후 적용방향

본 연구에서는 대대 전투지휘훈련간 대대의 작전지속능력을 사전에 예측하기 위해 전투훈련간 교전에 따른 시간대별 부대원의 생존률을 이용한 인공신경망 모형을 도출하고, 모형의 예측력과 유용성을 연구해 보고자 하였다. 작전지속능력을 예측한 결과 일반회귀신경망이 다층신경망보다 7배 이상 빠른 처리속도와 높은 예측적중률을 보여 짧은 시간에 여러 가지 판단을 해야 하는 전장환경에 보다 적합한 모델임을 알 수 있었다.

인공신경망을 이용하여 예측된 각 부대별 작전지속능력은 작전부대 지휘관이 방어작전에서 철수작전 및 역습 등 작전변경에 대한 고려요소로

활용할 수 있다. 또한 각 부대별 예비대 투입 소요 시간과 작전지속능력 및 요구 작전지속능력을 고려한 예비대 투입 우선순위 선정, 임무수행을 위한 상급부대 추가 전투력 지원 요구 등 다른 요소와 결합된 작전간 지휘관의 의사결정지원에 관한 추가적인 연구가 요망된다. 끝으로 방어부대에 대한 작전지속능력 예측은 여러 가지 모형을 적용하여 분석한다고 해도 현실적으로 미래를 정확히 예측하는 것을 매우 어려운 일이다. 따라서 계량적인 평가의 한계를 극복하기 위해서는 전투력의 무형적 부분(사기, 조직의 단결력, 병사의 피로도)와 같은 무형적인 부분까지도 함께 고려되어야 하나 현재 훈련에서는 이에 대해 평가한 사례가 없다. 따라서 대대전투지휘훈련 참가부대에 대한 무형적 요소에 대한 사전 평가가 선행되어야 하며 이를 위해 평가기준 또한 마련되어야 할 것으로 판단된다.

또한 실험에 이용된 부대별 생존률은 시뮬레이션 결과를 이용한 것이다. 따라서 대대전투지휘훈련에서 제공하는 환경에서는 사용 가능하나 실제 전투에 적용하는 데에는 한계가 있으며 이를 극복하기 위해서는 실제 전장상황과 더욱 유사한 기동과 화력이 이루어지는 환경에서 입력자료를 획득하여야 할 것이다. 육군 과학화 전투 훈련단에서 2007년부터 실시하고 있는 대대급 훈련에서는 병력이 실제 기동하며 실제 무기와 같은 수준의 모의 가능한 장비로 훈련을 실시함으로써 실제 지형에서의 실전적 전투가 가능하며 전장피로 및 사기와 같은 무형적 요소에 대한 반영이 가능하다. 또한 2014년부터 연대급 훈련을 실시하게 됨에 따라 전투결과 예측에 대한 연구기반이 확대될 것으로 기대된다. 향후 산악, 하천, 도시지역 작전 등 작전 유형별로 세분화하여 모형을 구축하면 유형별 작전교리 발전에 기여할 수 있을 것이라 판단된다.

참고문헌

- 김대수, “신경망 이론과 응용”, 하이테크정보, 1993.
- 김영일(2000), “도산예측모형의 예측력 검정에 관한 실증적 연구 : 우리나라의 주요 도산예측모형 비교를 중심으로”, 서강대 대학원 박사학위논문.
- 김진백, 이진섭(2000), “인공지능 기법을 이용한 중소기업 부도예측에 있어서 현금흐름변수의 유용성 검증”, *대한경영학회지*, 26권, 229~250.
- 박정제, 신동령 “현대경영분석” 다산출판사, 1987.
- 부형욱, “군사력 비교평가방법론 국방정책연구”, 1999, 272~273.
- 이건창, 한인구, 김명중, “기업도산예측을 위한 귀납적 학습지원 인공신경망 접근방법”, *한국경영학회, 경영학 연구*, 36권(1996), 109~144.
- 임성빈, “인공신경망을 이용한 군 지역정보 전송중계기 최적배치에 관한 연구”, 국방대학교 석사학위논문, 2006.
- 조준희, “코스닥기업의 도산예측에 관한 연구”, *산업경제연구*, 20권 1호(2006), 141~160.
- 피종호, 김승권, “한정된 데이터 하에서 인공신경망을 이용한 기업도산예측 : 섬유 및 의류산업을 중심으로”, *경영과학*, 14권 2호(1997), 91~111.
- 한용섭, “동태적 분석 모델을 활용한 남북한 군사력 균형분석 및 대책 국방대학교 안보문제연구소”, 2002. 22~23.
- Altman, E. I., Marco G., and Varatto F., “Corporate distress diagnosis : Comparisons using linear discriminant analysis and neural networks”, *Journal of Banking and Finance*, Vol.18(1994), 505~529.
- Clausewitz, “On War : New and Revised Edition by F. N. Maude, C. B.”, Lowe and Brydone LTD, 1968.
- MacCulloch, W. S. and W. H. Pitts, “A logical calculus of ideas immanent in nervous activity”,

- Bulletin of Mathematical Biophysics*, Vol.9 (1943), 115~133.
- Hargan, M. T. and H. B. Demuth, "Neural Network Design", Mark Beale, MHB, Inc., 1996.
- Haykin, Simon., "Neural Networks -A Comprehensive Foundation", Macmillan, College Publishing Company, Inc., 1994.
- Hsu, K.-L., H. V. Gupta, and S. Sorooshoan, "Artificial neural network modeling of the rainfall-runoff process", *Water Resource Research*, Vol.31, No.10(1995), 2517~2530.
- Sajikumar, N. and B. S. Thandaveswara, "A Non-linear rainfall-runoff model using an artificial neural network", *Journal of Hydrology*, Vol.216(1999), 32~55.
- Samarasinghe, Sandhya. "Neural Networks for Applied Sciences and Engineering : From Fundamentals to Complex Pattern Recognition, Auerbach Publications", 2006, 253~259.
- Specht, D. F., "A General Regression Neural Network, IEEE Transaction on Neural Networks", Vol.2, 568~576.
- Thirumalaiah K., Markarand Deo, "Hydrological forecasting Using Neural Networks", *Journal of Hydrologic Engineering*, 2000, 180~189.
- <http://www.add.re.kr/국방과학기술소개>, 통신/정보/전자전 무기체계.
- <http://www.kctc.mil.kr> 육군 과학화 전투 훈련단.
- <http://www.tradoc.mil.kr/>육군 교육사령부.

Abstract

A study on Forecasting The Operational Continuous Ability in Battalion Defensive Operations using Artificial Neural Network

Hong-Gi Shim* · Sheung-Kown Kim**

The objective of this study is to forecast the operational continuous ability using Artificial Neural Networks in battalion defensive operation for the commander decision making support. The forecasting of the combat result is one of the most complex issue in military science. However, it is difficult to formulate a mathematical model to evaluate the combat power of a battalion in defensive operation since there are so many parameters and high temporal and spatial variability among variables. So in this study, we used company combat power level data in Battalion Command in Battle Training as input data and used Feed-Forward Multilayer Perceptrons(MLP) and General Regression Neural Network (GRNN) to evaluate operational continuous ability. The results show 82.62%, 85.48% of forecasting ability in spite of non-linear interactions among variables. We think that GRNN is a suitable technique for real-time commander's decision making and evaluation of the commitment priority of troops in reserve.

Key Words : Multilayer Perceptrons(MLP), General Neural Network(GRNN), Wargame Simulation, Operational Continuous Ability, Battalion Command in Battle Training

* The Graduate school of Information Management and Security, Korea University

** Division of Information Management Engineering, Korea University

저자 소개



심흥기

육군사관학교 전자공학과 졸업 후 보병장교로 임관하여 복무하고 있으며 현재 고려대학교 정보경영공학 전문대학원에서 산업시스템 석사과정을 수학하고 있다. 관심 연구분야는 다기준 의사결정 분석, 위게임, 인공신경망 등이다.



김승권

현재 고려대학교 공과대학 정보경영공학부 교수로 재직 중이다. 서울대학교 기계공학과를 졸업하고 Stanford University에서 Industrial Engineering 석사, UCLA에서 Systems Engineering 박사학위를 취득하였다. HARZA Engineering Co., Chicago에서 System Analyst로 약 3년간 재직하였으며 Cornell University 방문교수로 1년간 재직하였다. 주요 관심분야로는 다기준 의사결정 분석, SCM, 수자원/환경 및 에너지 시스템 분석 등이다.