

ANN-based Evaluation Model of Combat Situation to predict the Progress of Simulated Combat Training

Soungwoong Yoon*, Sang-Hoon Lee**

Abstract

There are lots of combined battlefield elements which complete the war. It looks problematic when collecting and analyzing these elements and then predicting the situation of war. Commander's experience and military power assessment have widely been used to come up with these problems, then simulated combat training program recently supplements the war-game models through recording real-time simulated combat data. Nevertheless, there are challenges to assess winning factors of combat. In this paper, we characterize the combat element (*ce*) by clustering simulated combat data, and then suggest multi-layered artificial neural network (ANN) model, which can comprehend non-linear, cross-connected effects among *ces* to assess mission completion degree (*MCD*). Through our ANN model, we have the chance of analyzing and predicting winning factors. Experimental results show that our ANN model can explain *MCDs* through networking *ces* which overperform multiple linear regression model. Moreover, sensitivity analysis of *ces* will be the basis of predicting combat situation.

▶ Keyword: Simulated combat, Combat element, Mission Completion Degree, ANN-based prediction

I. Introduction

전쟁은 수많은 인적, 물적 요소들의 복합적인 영향으로 이루어지므로 전쟁의 요소들을 분석하여 승리 또는 패배의 이유를 연구하고 이에 따르는 전장상황을 예측하는 것은 매우 어려운 일이다. 그럼에도 불구하고 전쟁의 결과를 예측하고자 하는 시도는 계속되어 왔는데, 이는 전쟁의 결과가 정치, 경제, 사회 등 모든 분야에 지대한 영향을 미치기 때문이다. 따라서 지속적으로 “싸우지 않고 승리함을 추구하되 싸우면 반드시 승리하는 방법”을 찾는 연구가 진행되어 왔다[1].

최근 감지기술의 발전과 함께 실전 상황과 유사한 조건을 갖추고 훈련하여 자료를 축적, 분석할 수 있는 방법이 발전되어 왔다. 이를 모의전투훈련이라 하는데, 훈련 간 부대위치, 교전 피해 및 시간대별 전투력 추이 등을 수집하는 방법으로써 현재도 시행되고 있다[2]. 중요한 점은 훈련부대의 전투력을 어떻게 산정하는가 하는 것인데, 현재는 전투력 평가라 불리는 물리

적 전투력의 합산을 이용하여 상대적 우세를 판정한다. 그러나 환경적 요소를 포함한 종합적인 전투력 평가나 부대별 전투력의 산정요소를 지정하고 이들의 변화 추이를 측정하는 것은 현재의 평가체계에서는 매우 어려운 일이다.

수학적 또는 논리적 모델링을 통한 전투력 평가 시도는 계속 되었으나 관련 자료의 수집에 따른 규모나 재원 등의 문제로 제한적인 실험으로 실시되었으며, 고려할 요소가 많아질수록 소요 자원 및 모의시간이 증가하여 현재 전투력으로 가능한 임무수행의 정도를 실시간 예측하는 데는 제한이 따른다[1]. 따라서 현재까지는 측정된 자료들을 바탕으로 사후 토의를 통해 목표 성취도를 정성적으로 평가하여 왔다.

본 논문에서는 전술급 제대인 대대를 기준으로 한 모의전투 훈련의 결과 자료로부터 전투력을 측정하기 위한 요소와 그 변화를 측정하기 위한 기초 연구를 수행하였다. 특히 전투의 승리

*First Author: Soungwoong Yoon, Corresponding Author: Sang-Hoon Lee

*Soungwoong Yoon (ysw1209@gmail.com), Dept. of Computer Science, Korea National Defense University

**Sang-Hoon Lee (hoony@kndu.ac.kr), Professor, Dept. of Computer Science, Korea National Defense University

• Received: 2017. 05. 19, Revised: 2017. 06. 24, Accepted: 2017. 07. 25.

를 위한 임무달성의 요건을 결정하는 전장요소를 전투요소로 정의하고, 이 전투요소를 전투분야와 관련하여 임무달성요건을 구현할 수 있는 논리적 모델을 탐구하였다. 식별된 전투요소와 임무달성요건간의 복잡한 영향관계를 모의하기 위하여 인공지능망 분석모델을 제안하였으며, 실험 결과 기존 모델에 비하여 적응성이 높고 전투요소 상호간의 영향도를 정량적으로 제시할 수 있었다. 제안하는 임무달성모델은 모의전투훈련 평가의 한 방법으로서 향후 전쟁의 결과를 객관적으로 파악할 수 있는 방법으로 활용될 수 있으며, 실시간 전투모의의 평가기준으로 예측모델에 효율적으로 사용될 수 있다.

본 논문은 다음과 같이 구성된다. 먼저 2장에서는 관련연구를 살펴본다. 3장에서는 모의전투훈련의 내용을 전투요소와 임무달성지수로 정의하고, 이를 이용하여 4장에서 인공지능망 기반의 임무달성모델을 제시한다. 5장에서는 실험을 통해 연구모델의 유용성을 검증하고, 6장에서는 결론 및 향후 연구방향을 제시한다.

II. Preliminaries

1. Related works

1.1 Military Power Assessment

전투력 평가방법은 국가의 군사력을 어느 한 시점에서 비교 평가하는 정태적 방법과 국방 시뮬레이션 모델을 이용하여 피아 군사력간의 전투 진행과정을 시간대별로 묘사하고 결과를 측정하는 동태적 방법으로 구분된다[3]. 그림 1은 정량적 전투력 평가방법을 분류한 것이다.

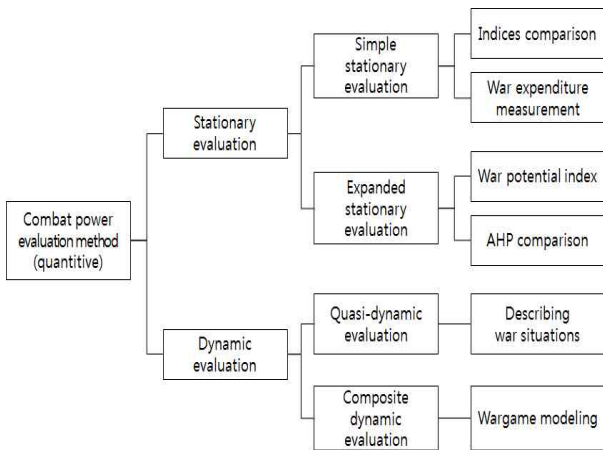


Fig. 1. Combat power evaluation methods

특히 단순히 병력과 전투장비 수량 또는 군사비 지출의 감가 상각을 고려하는 단순정태적 방법의 한계를 극복한 전력지수는 “다수의 전투장비를 복합적으로 보유하고 있는 부대의 전투능력을 개량화하기 위해 사용되는 각 무기의 수치”로 정의[4]되어 1960년대부터 미국에서 발전되었는데, 1994년 Rand 연구소에서 합동종합상황모델 (JICM: Joint Integrated Contingency Model) 무기점수로 개발, 활용되고 있으며[5] 한국에서는 이를 준용하여 전투력을 평가하는 다양한 방법을 연구하고

있다. 동태적 방법은 최초 전력으로부터 손실과 전선이동을 판단, 전장상황을 묘사하는 Kaufmann 모형과 군사적 상황을 게임규칙을 이용하여 모의하는 위게임모형방법이 있다.

한편 수학적 모델을 이용한 전투력 평가방법은 회귀모델을 이용한 기동분야 전투능력 산정[6], 인공지능망을 이용한 작전 지속능력 예측[1] 등의 최근 연구가 있으나 전투력 평가를 위한 전반적인 요소의 추출 및 이용이 아닌 특정 분야의 전투능력을 산정하는데 목표를 두었다. 특히 모델 적용을 위하여 설정한 측정 가능 요소들이 비교적 한정되어 있으며, 비교대상이 없는 절대치로서의 능력을 기준으로 전투력을 평가하였다.

본 연구에서는 논리 모델링에 근거한 통합적인 전투력 평가를 위하여 필요한 요소들을 산정하고 이들의 효과를 검증 및 예측하는데 주안점을 두었다.

1.2 Artificial Neural Network (ANN)

인공지능망(Artificial Neural Network)은 전통적인 통계 모형보다 미래 데이터를 예측하는 능력이 우수함이 수학적으로 증명되었으며[7,8], 특히 인공지능 및 빅데이터의 발전과 연관되어 최근 활발한 연구가 진행되고 있다[9,10,11]. 인공지능망 알고리즘은 입력변수간 상호 영향을 제한하지 않는 특성이 있는데, 이는 특정 원인의 다중적 영향을 모두 고려하면서 점증적인 분석모델의 확장과 검증을 병행할 수 있는 이점이 있다.

은닉층을 다양화한 심층신경망(Multilayer perceptron) 기반의 ANN은 스팸 탐지[10], 이미지 인식[11] 등 기존 컴퓨터 공학 분야뿐만 아니라 추세 예측[12], 원자로 관리[13], 나노 공학[14] 등 다양한 산업분야에서 연구 및 활용되고 있다. 군사 분야에서는 전투기 식별, 폭발물 탐지, 함정/소나 식별 등 인식분야와 항공기 조종 시뮬레이션, 화포 탄도계산 등 정보처리 분야에서 활용[1]되고 있으나, 군사 분야의 특성상 데이터의 보안 관계로 자체적인 분석능력을 갖추어야 하는 규모의 문제점을 안고 있어 ANN 기반 연구는 이제 시작단계에 있다.

III. Setting Parameters of Simulated Combat Training

기존의 전투력 측정방법을 기반으로 모의전투훈련의 자료와 제안하는 모델에 적합한 지수를 상정해야 하는데, 이는 공격, 방어 등 모든 전술적 상황을 망라할 수 있는 지표여야 한다. 본 연구에서는 대대급 전술에서 승리의 관건이 되는 핵심사형인 임무의 달성을 목표변수로 보고, 입력에 해당하는 요소들을 전투요소(Combat Element; ce), 결과에 해당하는 요소들의 지수를 임무달성지수(Mission Completion Degree; MCD)라 명명하고 식별하였다. 전투요소와 임무달성지수는 본 연구를 위하여 명명된 요소로서, 군의 공식적인 전투력 측정의 지표는 아니며 이를 근사하는 요소이다.

1. Combat Element (ce)

전투요소는 전투 임무의 달성을 좌우하는 요소들로서 직관적으로 그 종류가 많고 다양한 효과를 가지고 있다고 추정되며, 상호 독립적이지 않고 서로 연결되어 있다고 볼 수 있다. 그러나 이와 같이 추정 가능한 전투요소가 존재한다 하더라도 모의전투훈련을 통해 묘사 및 산정하기에는 다소 어려운 경우도 있으며, 특히 적 전술 및 정보에 대한 모의는 현재까지는 실제 모의전투훈련에 적용하기에 제한된다. 대대급 모의전투훈련에서 기록되는 모든 자료들을 검토하여 측정 가능하고 지수화된 전투요소를 추출한 결과 총 21개 요소가 선택되었으며, 그 결과는 표 1과 같다.

Table 1. ce analysis result for the battalion
(O: Count when observed)

| ID | ce | Category | Unit | Cycle |
|------|--|-------------------|------|-------|
| X01 | # of radio comm. | Command & Control | int | O |
| X02 | Duration of radio comm. | | time | O |
| X03 | # of information resources | Information | int | 5min |
| X04 | # of information elements | | int | 5min |
| X05 | Duration of overcoming obstacles | Movement | time | O |
| X06 | # of personal damage when overcoming obstacles | | int | O |
| X07 | # of firing personal weapons | Fire | int | O |
| X08 | # of supporting artillery weapons | | int | O |
| X09 | # of enemy casualties by X08 | | int | O |
| X10 | # of casualties harmed by NBC | Protection | int | O |
| X11 | # of devices harmed by NBC | | int | O |
| X12 | # of casualties (Commender) | Operation Support | int | O |
| X12a | # of minor injuries (Commender) | | int | O |
| X13 | # of casualties (Officers) | | int | O |
| X13a | # of minor injuries (Officers) | | int | O |
| X14 | # of casualties (NCO) | | int | O |
| X14a | # of minor injuries (NCO) | | int | O |
| X15 | # of casualties (Soldiers) | | int | O |
| X15a | # of minor injuries (Soldiers) | int | O | |
| X16 | Temperature | Climate | int | 5min |
| X17 | Rainfall | | int | 5min |

2. Mission Completion Degree (MCD)

임무달성지수는 모의전투훈련시 주어진 임무를 달성한 정도를 나타내는 지수인데, 이의 요건을 고려한다면 작전형태에 따라 그 산정방법이 달라져야 한다. 대표적인 예로 공격작전의 임무달성요건에는 적 지역으로의 진출 정도, 방어 작전에서는 적 진출 저지선과 같은 요소가 고려되어야 한다.

포괄적 임무달성요건의 산정은 매우 어려운 문제이다. 실제 자료에서 가용한 판단기준은 전투력 평가의 방법으로 수집된 모의전투훈련의 사후검토 결과인데, 본 연구에서는 이 사후검토결과를 이용하여 임무달성요건을 계량화하였다. 산정 기준으로는 공격작전의 진행 정도와 작전 수행 간 부대원의 생존율을 고려하여 0과 1 사이의 상대평가를 실시하였으며, 연구자와 훈

련담당관, 평가관과의 토론을 통하여 확정하였다. 이 과정에서 도출된 검토 기준의 예는 표 2와 같다.

Table 2. Conversion Table of Mission Accomplishment Index

| MCD | Battle situation | Adjusted by survival ratio (sr) |
|-----|--------------------------------|---------------------------------|
| 1.0 | Reaching objectives | 0.9 when sr ≤ 00% |
| 0.9 | Reaching final trenches | 0.8 when sr ≤ 00% |
| 0.7 | Reaching intermediate trenches | 0.6 when sr ≤ 00% |
| 0.5 | Reaching front trenches | 0.4 when sr ≤ 00% |
| 0.3 | Starting with H-hour | 0.2 when sr ≤ 00% |
| 0.1 | Commit preparation fire | 0.0 when sr ≤ 00% |
| 0.0 | Reaching stand-by point | - |

IV. Proposed Model : ANN-based Mission Completion model

임무달성모델은 훈련 기간중 측정된 부대별 전투요소들이 사후 산정된 임무달성지수에 미치는 영향을 측정하는 모델이다. 모델링을 위하여 먼저 다수의 훈련부대별 전투요소와 임무달성지수를 측정하고 이를 정규화한 후 학습군과 검증군을 75%와 25%로 선정, 임무달성지수를 종속변수, 전투요소를 독립변수로 하는 변수셋을 구축하였다.

먼저 다중선형 회귀분석(Multi-layer Regression)을 실시, 제안모델과의 비교를 준비하였으며 인공신경망 기반의 심층신경망(Feed-forward Multilayer Perceptions; MLP)[1] 알고리즘을 이용하여 제안모델을 구성하였다. 두 모델의 효용을 비교하기 위해서는 평균절대오차 (Mean Absolute Error; MAE)를 사용하였다.

심층신경망에 적용한 임무달성모델은 개별 전투요소들의 임무달성지수와의 관계가 상호 독립적이지 않음을 반영하면서 전투요소별, 전투요소간 영향 분석을 동시에 시도하기 위한 것이다. 이를 관찰하기 위하여 다중신경망의 은닉층을 다양한 방법으로 변화시키면서 최적의 임무달성지수 예측결과를 도출하는 방법을 선택하였다.

심층신경망 분석시 전투요소의 성격에 따라 수집된 시계열 자료를 누적 또는 평균하여 입력하였는데, 이는 시간대별 전투요소에 대한 평가가 최종적인 임무달성요건을 결정한다는 가정에 따른 것이다. 이러한 시도는 모의전투훈련간 특정 시간대의 누적 전투요소 모델이 향후 임무달성요건을 결정하는 예측모델로 사용될 수 있음을 의미한다. 그러나 대대급 모의전투훈련 자료는 축적된 국면이 1일 이내로서 이때 전투요소는 그 변화가 매우 적거나 시간의 흐름에 따라 선형적으로 변화하는 경향을 보인다. 따라서 본 연구에서는 훈련기간 전체의 자료를 이용한 단일모델을 구성하고 평가하였으며, 심층신경망을 적용한 시계열 모델의 구성 및 평가는 향후 모의전투훈련의 충분한 자료를 확보한 후 실시하도록 한다.

V. Experiment

1. Experimental Setting

실험대상으로 모의전투훈련을 실시한 대대급 00개 부대를 선정하였으며, 각 부대의 공격전투 훈련기간간 자료를 수집, 분석하여 전투요소 및 임무달성지수를 산정하였다. 특히 모의전투훈련에서는 전투원의 경상은 생존한 것으로 처리되어 임무달성지수로의 효과 측정이 제한되므로 이를 반영하는 X12a, X13a, X14a, X15a 요소를 배제하고 총 17개 전투요소를 이용하여 분석하였다.

전체 000GB 분량의 자료로부터 17개 전투요소를 산정하기 위하여 이기종 DB 접속 및 프로세스 단위 분석이 가능한 i-STREAM[15]을 이용하였다. i-STREAM을 이용한 전투요소의 산정 프로세스 화면은 그림 2와 같다.

임무달성모델은 다중선형 회귀모델과 심층신경망 모델을 적용하였다. 심층신경망 모델은 R의 neuralnet 패키지를 적용하여 i-STREAM을 이용하여 분석하였으며, 최적화에 Back-propagation 알고리즘과 RPROP+ (Resilient PROPagation) 알고리즘을 구현하여 비교하였다. i-STREAM의 ANN 기반 모델 분석과정은 그림 3, 심층신경망 구성 예는 그림 4와 같다.

최적의 임무달성지수 예측상황을 분석하기 위하여 은닉층은 최대 2단계, 각 단계별 뉴런을 최대 11개까지 변화시키며 비교하였으며, 학습군과 검증군을 무작위로 설정, 교차 분석(Cross validation)을 실시하였다. 평가방법은 학습군에 의해 산정된 임무달성조건 모델을 이용하여 검증군의 임무달성지수를 예측하고, 기 산정된 검증군의 임무달성지수와 비교하여 MAE가 가장 적은 경우를 최적모델로 선정하였다.

또한 각 전투요소의 입력치를 변화시켜 임무달성지수의 변동을 관찰하는 민감도분석(Significance test)를 실시하여 각 전투요소가 임무달성지수에 영향을 미치는 정도를 산정하였다. 민감도 분석은 최종 선택된 임무달성모델을 이용, 모든 전투요소가 평균인 가상의 부대를 산정하고 기준이 되는 임무달성지수를 산출한 후 각 전투요소를 최솟값과 최댓값으로 변화시키면서 임무달성지수의 변화 정도를 측정하는 방법으로 시행되었다.

2. Experimental Results

먼저 다중선형 회귀모델을 이용하여 임무달성모델을 산정하였는데, 이에 R의 lm() 함수를 이용하여 학습군의 데이터를 이용하여 회귀식을 산정하고, predict() 함수와 검증군의 데이터를 이용하여 회귀모델의 테스트를 실시하였다. 산정한 결과 아래와 같은 회귀식이 도출되었으며, 전투요소별 분석결과는 표 3과 같다.

$$y = 0.32831 X01 - 0.37270 X02 - 0.06111 X05 + 0.06377 X06 + 0.23255 X07 - 0.19878 X08 + 0.22076 X09 + 0.11128 X10 - 0.01173 X12 - 0.22079 X13 - 0.17913 X14 + 0.25432 X15 - 0.10360 X16 + 0.22361 X17 + 1.03323$$

Table 3. Multi-linear regression modeling result

| Variable | Regression Coefficient | Standard Deviation | t-value | p-value |
|-----------|------------------------|--------------------|----------|---------|
| Intercept | 1.03323 | 0.16806 | 6.14803 | 0.00866 |
| X01 | 0.32831 | 0.20802 | 1.57825 | 0.21261 |
| X02 | -0.37270 | 0.23803 | -1.56574 | 0.21538 |
| X03 | NA | NA | NA | NA |
| X04 | NA | NA | NA | NA |
| X05 | -0.06111 | 0.09562 | -0.63915 | 0.56818 |
| X06 | 0.06377 | 0.08246 | 0.77341 | 0.49563 |
| X07 | 0.23255 | 0.21970 | 1.05850 | 0.36751 |
| X08 | -0.19878 | 0.10889 | -1.82546 | 0.16542 |
| X09 | 0.22076 | 0.19344 | 1.14123 | 0.33662 |
| X10 | 0.11128 | 0.11743 | 0.94764 | 0.41322 |
| X11 | NA | NA | NA | NA |
| X12 | -0.01173 | 0.15058 | -0.07787 | 0.94283 |
| X13 | -0.22079 | 0.25036 | -0.88190 | 0.44277 |
| X14 | -0.17913 | 0.19720 | -0.90836 | 0.43066 |
| X15 | 0.25432 | 0.19816 | 1.28339 | 0.28951 |
| X16 | -0.10360 | 0.10602 | -0.97723 | 0.40053 |
| X17 | 0.22361 | 0.17453 | 1.28123 | 0.29017 |

다중선형 회귀모델에서 전투요소 X03, X04, X11의 실제 데이터 수집건수가 0으로 나타나 해당 요소는 분석에서 제외되었다. 잔차의 표준오차는 0.0910, 자유도는 3이며, 조정 결정계수(Adjusted R-Squared)는 0.3211, p-value는 0.39542였다. 모델간 비교 척도인 MAE는 0.21894로 측정되었다.

한편 심층신경망 모델은 먼저 은닉층의 변화시 효율을 측정하였으며, 그 효과는 표 4와 같다.

Table 4. MLP modeling results by hidden layers

| Hidden Layers | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 |
|---------------|--------|--------|--------|--------|--------|--------|---------|---------|
| MAE | 0.587 | 0.466 | 0.709 | 0.208 | 0.673 | 0.299 | 0.254 | 0.257 |
| Hidden Layers | c(4,4) | c(5,4) | c(6,4) | c(7,4) | c(8,4) | c(9,4) | c(10,4) | c(11,4) |
| MAE | 0.220 | 0.124 | 0.203 | 0.131 | 0.405 | 0.233 | 0.333 | 0.170 |




Fig. 2. Measuring *ces* (by i-STREAM)

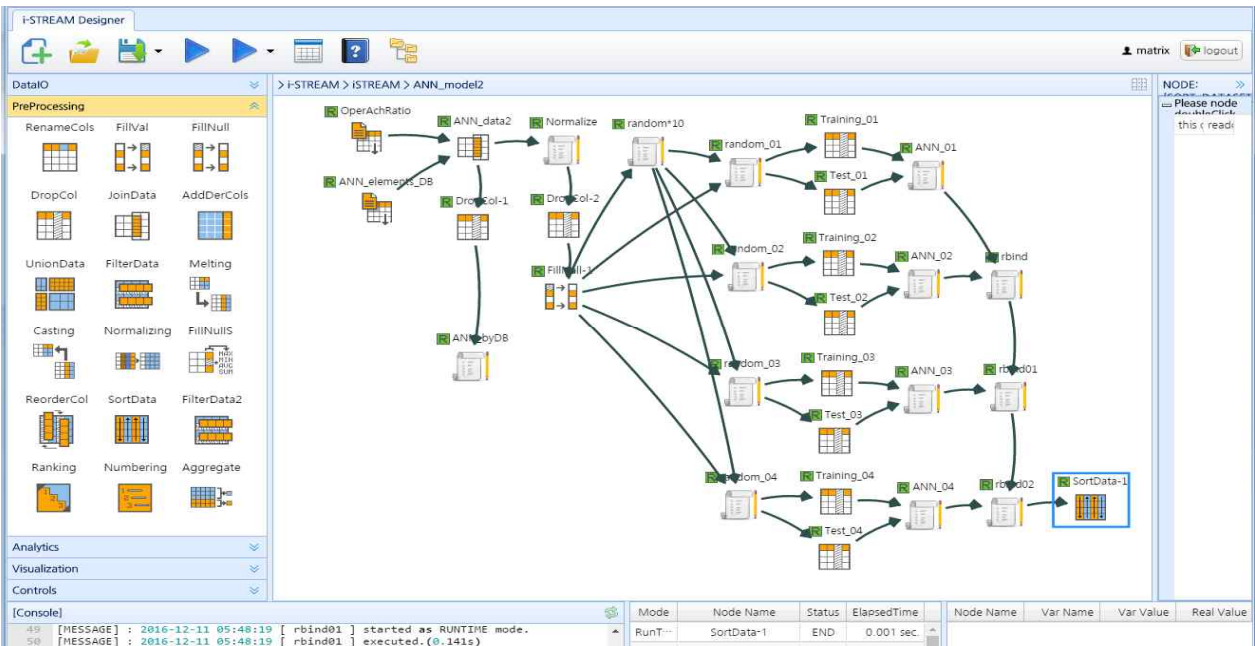


Fig. 3. ANN modeling (*MCD- c_e* , by i-STREAM)




Fig. 4. MLP (example)

특히 전투요소간 교차 효과가 존재하는 것을 확인할 수 있었으며, 전투요소를 이용한 임무달성지수 최적 모델은 누적오차 지수가 최소치를 보인 2계층 은닉층을 가진 c(5,4) 및 c(7,4)인 경우이다. 이는 전투요소를 직관적으로 분류할 수 있는 전투분야로의 연결 모델이 가장 높은 효율을 보인 것으로 볼 수 있는데, 은닉층이 7인 경우가 가장 높은 효율을 보였으며 이는 7개 전투분야를 상정한 경우에 해당한다. 따라서 전투분야를 고려한 최적의 심층신경망 모델은 c(7,4) 모델로 선정되었다.

최적화를 위하여 Backpropagation 알고리즘은 학습율을 0.001 ~ 1로 변화시키면서 실험하였다, 그 결과 학습율 0.001 ~ 0.03 구간에서 다중선형 회귀모델보다 우수한 결과를 보였으나 이후 급격하게 효율이 감소하는 경향을 보였다. 최적해로 알려진 RPROP+ 알고리즘을 적용한 경우에는 MAE가 상대적으로 높게 나타났으며, MLP 모델별 실험결과는 표 5와 같다.

Table 5. MLP model analysis results

| Algorithm | Learning Ratio | Error | Reached Threshold | Steps | MAE |
|------------------|----------------|---|-------------------|-------|----------|
| Back-propagation | 0.001 | 0.068897 | 0.009999 | 25219 | 0.137297 |
| | 0.003 | 0.068898 | 0.009999 | 8408 | 0.137298 |
| | 0.01 | 0.068904 | 0.009999 | 2524 | 0.137300 |
| | 0.03 | 0.068922 | 0.009999 | 845 | 0.137288 |
| | 0.10 | 0.066489 | 0.009983 | 336 | 0.119756 |
| | 0.30 | Error in if (reached threshold < min reached threshold) | | | |
| RPROP+ | - | 0.0007893 | 0.006741 | 63 | 0.135394 |

최종적인 임무달성모델은 Backpropagation 기반 심층신경망 모델 (학습율 0.10)이 선정되었다. 본 연구결과는 정성적 분석과 제한적인 정량모델링으로 측정되던 훈련간 임무달성 정도를 모델을 통하여 전체적으로 구현, 그 결과를 제시한 첫 모델로 의의를 가진다고 할 수 있다.

3. Sensitivity Analysis of ces

전투요소가 임무달성요건에 복합적으로 영향을 미친다고 한다면, 전투요소별 영향력 정도를 평가하기 위해서는 전투요소 자체의 변화에 따른 임무달성지수의 변화를 관찰하는 것이 바람직하다. 민감도 분석을 통한 부대별 임무달성지수 변화를 분석한 결과는 표 6과 같다.

분석결과 전투요소의 민감도는 X13. 장교 중상이상 피해발생 여부와 X09. 곡사화기의 적 피해인원수가 가장 높은 증감 민감도를, X02. 무선통신망 사용시간이 가장 높은 감소 민감도를 가진 것으로 나타났다. 전체적으로 전투요소에 따른 임무달성지수의 민감도는 그 변화도가 0.1 수준으로서 이는 전투요소의 성취도에

Table 6. ce sensitivity

| ID | ce | Changes of MCD (Min. ~ Max. ce) |
|-----|--|---------------------------------|
| X01 | # of radio comm. | -0.067 ~ -0.033 |
| X02 | Duration of radio comm. | -0.074 ~ -0.055 |
| X03 | # of information resources | 0 ~ 0 |
| X04 | # of information elements | 0 ~ 0 |
| X05 | Duration of overcoming obstacles | 0.090 ~ -0.033 |
| X06 | # of personal damage when overcoming obstacles | -0.009 ~ -0.020 |
| X07 | # of firing personal weapons | -0.023 ~ -0.031 |
| X08 | # of supporting artillery weapons | 0.159 ~ -0.007 |
| X09 | # of enemy casualties by X08 | -0.090 ~ -0.082 |
| X10 | # of casualties harmed by NBC | -0.007 ~ -0.051 |
| X11 | # of devices harmed by NBC | 0 ~ 0 |
| X12 | # of casualties (Commender) | 0.001 ~ -0.020 |
| X13 | # of casualties (Officers) | 0.020 ~ 0.085 |
| X14 | # of casualties (NCO) | -0.037 ~ -0.036 |
| X15 | # of casualties (Soldiers) | 0.049 ~ -0.015 |
| X16 | Temperature | -0.045 ~ -0.006 |
| X17 | Rainfall | -0.010 ~ -0.031 |

따라 임무 달성의 정도가 일정 수준 이상 변화할 수 있음을 나타내는 것으로서 그 중요도가 상당하다고 볼 수 있다. 또한 전투요소의 지수 증가에 따라 임무달성지수가 상승하는 지수도 있는 반면 반대의 경우도 있으므로 훈련 수행중 작전상황의 변화에 따른 전황의 엄두판단을 위한 자료로 유용하다.

VI. Conclusions

본 논문에서는 전투의 성패를 결정하는 임무달성요건을 설정하고, 이를 추정하기 위하여 전투요소와 임무달성지수를 정의하고 인공신경망 기반의 논리 모델을 제시하였다. 실험을 위하여 대대급 모의전투훈련에서 산출 가능한 자료를 바탕으로 전투요소와 임무달성지수를 산정하고, 이들의 영향을 제안모델을 이용하여 분석하였다. 실험결과 임무달성지수는 전투분야를 바탕으로 한 전투요소에 의하여 효과적으로 추정될 수 있었으며, 기존의 다중선형 회귀모델에 비하여 높은 예측력을 나타냈다. 또한 전투요소의 민감도 분석을 통하여 전투요소의 임무달성지수로의 영향력을 식별할 수 있었다.

향후 연구에서는 전투요소 및 임무달성지수에 관한 보다 심도 있는 고찰이 필요하며, 특히 전장상황을 판단할 수 있는 수많은 전투요소들을 유연하게 추출하고 최적화할 수 있는 모델을 탐구해야 하겠다. 또한 산정된 모델을 훈련 및 실전에 적용함으로써 미지의 전투요소들을 발견하고 새로운 분석모델을 적용할 수 있도록 해야 한다.

REFERENCES

- [1] H. Shim and S. Kim, "A study on Forecasting The Operational Continuous Ability in Battalion Operations using Artificial Neural Network," *Journal of Intelligence and Information System*, Vol. 14, No. 3, pp. 25-29, Sep. 2008. (in Korean)
- [2] H. Bu, "Study of Military Strength Comparison," *The Quarterly Journal of Defense Policy Studies*, Vol. 45, pp. 272-273, Sep. 1999. (in Korean)
- [3] H. Jeong and M. Sin, "Military Strength Assessment by TNDM," *Defense & technology*, Vol. 402, No. 8, pp. 68-75, Aug. 2012. (in Korean)
- [4] O. Kwon and J. Cho, "A Study on the Development Direction of Military Force Evaluation Process," *The Quarterly Journal of Defense Policy Studies*, Vol. 107, pp. 106-132, 2015. (in Korean)
- [5] J. Ong and M. F. Ling, "Using the Joint Integrated Contingency Model for Campaign Analysis," *Defense Systems Analysis Division, Electrons and Surveillance Research Laboratory, DSTO-TR-1307*, May 2002.
- [6] G. Kim and D. Kim, "Development and Application of Effect Measurement Tool for Victory Factors in Offensive Operations Using Big Data Analytics", *Journal of KORMS*, Vol. 39, No. 1, pp. 111-130, June 2014. (in Korean)
- [7] K. Hornik, M. Stinchcombe and H. White, "Multilayer Feedforward Networks are Universal Approximators," *Neural Networks*, Vol. 2, pp. 359-366, 1989.
- [8] J. Schmidhuber, "Deep Learning in Neural Networks: An Overview," *Neural Networks*, Vol. 61, pp. 85-117, Jan. 2015.
- [9] J. Tang, C. Deng, and G. B. Huang, "Extreme learning machine for multilayer perceptron," *IEEE transactions on neural networks and learning systems*, Vol. 27, No. 4, pp. 809- 821, 2016.
- [10] K. Hans, L. Ahuja and S. K. Muttoo, "Detecting Redirection Spam Using Multilayer Perceptron Neural Network," *Journal of Soft Comput.*, Vol. 21, No. 13, pp. 3803-3814, July 2017.
- [11] A. Thakur and D. Mishra, "Hyper spectral image classification using multilayer perceptron neural network & functional link ANN," *7th conference of Cloud Computing, Data Science & Engineering*, pp. 639-642, Jan 2017.
- [12] S. Yoo, J. Kjm, J. Jeong and J. Jeong, "Maritime Traffic Volume using Artificial Neural Network and Time Series Analysis," *Journal of the Korean Society of Marine Environment & Safety*, Vol. 20, No. 1, pp. 33-41, Feb. 2014. (in Korean)
- [13] A. M. Ghahddarijani, F. Hormozi and A. H. Asl, "Convective heat transfer and pressure drop study on nanofluids in double-walled reactor by developing an optimal multilayer perceptron artificial neural network," *International Communications in Heat and Mass Transfer*, Vol. 84, pp. 11-19, 2017.
- [14] E. Heidari, M. A. Sobati and S. Movahedirad, "Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN)," *Chemometrics and Intelligent Laboratory Systems*, Vol. 155, pp. 73-85, 2016.
- [15] <http://www.bimatrix.co.kr/product/i-stream01.html>

Authors



Soungwoong Yoon received the B.S. degree in Engineering from Hanyang University in 1992 and M.S. degree in Computer Science and Engineering from Korea National Defense University (KNDU), Korea, in 2004, respectively.

Mr. Yoon joined the Ph.D course of the Department of Computer Science at KNDU, Seoul, Korea, in 2015 and currently Ph.D candidate. He is interested in knowledge discovery, information retrieval, big data and social network analysis.



Sang-Hoon Lee received the B.S. degree in Electronics from Sungkyunkwan University in 1978, M.S. degree in Computer Science from Yonsei University, Korea, in 1989 and Ph.D. degree in Computer Science from Kyoto University, Japan, in 1997, respectively.

Dr. Lee joined the faculty of the Department of Computer Science and Engineering at KNDU, Seoul, Korea, in 2000. He was the head of KNDU Computing Center, the director of KNDU library, the graduate school president and currently a Professor in the Department of Computer Science, KNDU. He is interested in database, information retrieval, big data and social network analysis.