

A Study on a Question and Answer Relevance Identification Model Handling Data Imbalance for Battlefield Analysis

Yukyung Shin*, Soyeon Jin**

*Engineer, SW(C4I) Team, Hanwha Systems Co., Seongnam, Korea

**Chief Engineer, SW(C4I) Team, Hanwha Systems Co., Seongnam, Korea

[Abstract]

This study proposes a multi-layer perceptron based regression-classification model for identifying the relevance between a given input question and its corresponding answer using data from the defense domain. First, an embedding vector method and pre-processing method are introduced to effectively handle input data. In the pre-processing method, if a class imbalance problem arises during the model input stage, a re-weighted sampling process is applied. And an additional algorithm is incorporated to identify and filter out contradictory data in advance. Furthermore, the relevance identification regression-classification model adopts a regression task structure while simultaneously transforming it into a classification task by introducing a regularization term in the model architecture. The experiments were conducted using a pre-constructed simulated dataset from the defense domain, and the inference results demonstrate the effectiveness and performance of the proposed model.

▶ **Key words:** Battlefield Analysis, Battlefield Awareness, Handling Data Imbalance, Multi-Layer Perceptron Regression

[요 약]

본 연구에서는 국방 도메인의 데이터를 기반으로 입력으로 받은 질문과 질문에 대한 답변의 관련성을 측정하는 다층 퍼셉트론 기반의 관련성 식별 회귀-분류 모델을 제안한다. 먼저, 입력 데이터를 효과적으로 처리하기 위한 임베딩 벡터 방법과 전처리 방법에 대해 수행한다. 전처리 방안에서는 모델 입력 단계에서 특정 클래스의 데이터 불균형 문제가 발생할 경우, Re-Weight 샘플링 과정을 거치고 모순되는 데이터를 사전에 식별하여 제거하는 알고리즘을 추가한다. 또한, 관련성 식별 회귀-분류 모델은 회귀 모델의 태스크 형태를 가지지만 동시에 분류 형태 태스크로 변환하여 풀 수 있는 정규화(regularization) 항을 추가한 모델 구조를 제안한다. 실험은 사전에 구축된 국방 도메인의 모의 데이터셋을 활용했으며 모델 추론 결과를 통해 모델의 성능을 입증하였다.

▶ **주제어:** 전장상황분석, 전장상황인식, 데이터 불균형 처리, 다층 퍼셉트론 회귀모델

-
- First Author: Yukyung Shin, Corresponding Author: Yukyung Shin
 - *Yukyung Shin (ykshin@hanwha.com), SW(C4I) Team, Hanwha Systems Co.
 - **Soyeon Jin (soyeon.jin@hanwha.com), SW(C4I) Team, Hanwha Systems Co.
 - Received: 2024. 12. 19, Revised: 2025. 02. 12, Accepted: 2025. 02. 18.

I. Introduction

국방에서의 인공지능 도입이 활발해지면서 전장상황에 대한 판단 및 인식을 위한 지능형 지휘통제체계 연구의 중요성이 높아지고 있다. 지능형 지휘통제체계[1]는 지휘관의 의사결정과 전장관리를 지원하는 핵심전력체계로, 다양한 감시·정찰 자산으로부터 중요 정보를 수신받아 이를 처리하고 분석하여 적절한 의사결정과 전장관리를 지원함으로써 합참, 작전사령부, 군단, 사단 등 지휘관의 작전지휘를 지원한다.

현재 지휘통제체계에는 많은 한계점이 있다. 전장상황의 경우 감시·정찰체계에서 초 단위로 다양하고 방대한 정보들이 들어오고, 상황이 갑자기 급변할 경우 다시 정보들을 재분석하여 처리 후 지휘관이 빠른 결정과 판단을 내리기에는 한계가 있다. 이에 따라 국내외에서는 복잡하고 다양한 체계의 데이터들을 빠르게 처리하고, 상황에 대한 정확한 정보와 지식을 제공하기 위해 인공지능 기술의 도움을 받아 처리하는 방안이 대두되어 연구가 활발하게 진행되고 있다. 국외에서는 지능형 지휘통제체계를 개발하기 위해 대표적인 프로젝트로 미국 국방성에서 개발한 COMPASS(Collection and Monitoring via Planning for Active Situational Scenarios)와 AIDA(Active Interpretation of Disparate Alternatives) 프로젝트가 있다[2, 3]. 국내에서도 국외의 대표 프로젝트를 벤치마킹한 지휘관의 의사결정을 지원하기 위한 AI 군 참모 기술 및 지능형 지휘통제체계를 개발하기 위한 판단 국방 인공지능 프로젝트들이 개발되고 있으며, 특히 최근 연구에서는 전장상황 모의 시나리오를 기반으로 한 가설 데이터셋 생성 방법 및 인공지능 기반 전장상황 인식 모델들이 제안되었다[4, 5, 6].

지휘관의 요구나 질문에 관련된 정보를 빠르게 제공하는 것이 중요하다. 다양한 국방 체계에서 생성되는 데이터와 분석관들이 작성한 보고서의 자연어 문장을 토큰화하여 METT-TC 기반으로 적/아군, 상황, 장소 등에 대한 각 요소들을 추출하여 의미있는 단어와 그 외 정보들을 조합하여 최종적으로 AI 모델을 통해 신뢰도가 가장 높은 결과 정보를 지휘관에게 제공하는 것이 중요하다.

본 연구는 전장상황 파악을 위한 다양한 지휘관의 질문을 통해 실시간으로 이를 분석하고 여러 데이터 중 정답에 가까운 관련성을 파악하여 결과를 제공하는데 중점을 두고 연구를 진행한다. 전장상황 식별을 위해

입력으로 받은 정답 문장 정보와 질문 정보의 관련성을 식별하기 위해 벡터 임베딩 모델과 다층 퍼셉트론 회귀 모델을 병합한 구조를 제안한다. 벡터 임베딩 모델은 입력 데이터의 형식을 효과적으로 학습할 수 있고, 다층 퍼셉트론 회귀 모델을 이용하여 두 입력 사이의 관련성을 측정할 수 있다. 추가적으로, 본 논문에서 가장 중요한 제안 방법인 모델의 입력하기 전 데이터 불균형 문제가 발생할 경우, 3단계의 알고리즘을 거쳐 전처리하는 방안이 대해 깊게 설명한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에 관련된 배경지식 및 용어 설명, 3장에서는 제안하는 알고리즘 구조 설명, 4장에서는 제안 방법 구현 및 실험을 통한 검증, 마지막 장인 5장에서 결론을 맺는다.

II. Preliminaries

본 장에서는 연구를 위한 시뮬레이션의 배경과 설정, 데이터 용어에 대해 설명한다.

2.1 Related Works

본 연구는 지휘관의 질문과 보고서의 자연어들이 각 토큰화 작업을 통해 각 토큰들의 관련성이 높을수록 모델에서 정확히 판단하는 것을 목적으로 한다. 본 연구와 관련하여 사전 연구들이 존재한다. 관련된 연구 중 육군의 지휘체계 중 육군전술지휘정보 체계(ATCIS)를 국방 온톨로지를 활용하여 지휘 결함에 필요한 군사지식을 제공하여 지휘관의 빠르고 정확한 의사결정을 지원하도록 지능형 ATCIS에 대해 제안한 연구 및 국방 온톨로지를 구성하기 위한 작업에 가까운 데이터셋 구축 방안이 제시되었다[7]. 또한, 국방 온톨로지 방안을 이용하여 전장상황 분석 연구를 위한 모의 시나리오 기반 가설 데이터셋 생성 방안이 제시되었다[6]. 사전 연구를 통해 다양한 자연어 표현의 전장 지식요소로 분해하여 국방 온톨로지 및 인공지능 개발에 필요한 데이터셋을 생성할 수 있다. 이와 비슷한 연구로 전투 환경 인식을 위한 데이터셋을 구축하기 위해 전장상황을 정의하고, 장면 그래프 생성을 위한 잘 알려진 공개 데이터셋의 구조를 참고하여 AI 모델 개발을 가능케 하는 데이터 구조를 설계 방안이 제시되었다[8].

구축된 국방 데이터셋을 기반으로 한 다양한 머신러닝 및 인공지능 모델링 기법에 대한 여러 연구가 제안되었다. 머신러닝 방법으로는 사람의 의사결정과 판단을

기계적으로 지원하는 방법을 고찰하고 의사결정나무 방법론을 활용하여 의사결정지원체계의 데이터 모델링 방안을 제시되었다[9]. 또한, 자연어의 자동 생성 및 추론 기술을 활용하여 전장 지식베이스를 기반으로 복합적인 상황 판단을 지원하고, 해당 기술의 유효성을 다양한 전장상황에서 검증되었다[10]. AI 네트워크 기반의 국방 데이터셋을 활용한 연구에는 Siamese 네트워크 구조를 사용하여 현재 상황에 적합한 데이터를 추천하는 분석결과 추천/랭킹 모델을 제안한 연구와 입력 데이터의 계층적인 구조를 활용하여 두 개의 입력 데이터 간 관련성을 판단할 수 있는 신경망 상황 식별 학습모델을 설계한 연구 방안을 제시되었다[11, 12].

2.2 Description of Terms

지휘관은 분석관이 분석한 보고서를 토대로 전장상황에 대한 각 정보를 이용하여 많은 정보간 관련한 정도를 빠르게 파악하고, 여러 지표를 활용하여 지휘결심을 해야 한다. 지휘관의 의사결정을 지원하기 위한 모의용 배경 전장상황을 구성하여 이를 바탕으로 과거의 훈련 내용을 바탕으로 하여 모의 시나리오를 구축하였다[6, 13].

모의 시나리오는 여러 개의 토픽으로 구성되어 있으며, 각각의 토픽에는 목적, 아/적군의 부대 정보, 모의 장비 및 편성 계획, 조건, 지역, 일시 등이 포함되어 있다. 선행 연구 [6, 13]에서 설명하는 가설 데이터셋의 기본 단위는 전장 지식요소로 표현하는 사건(Event)과 개체(Object)이다. 일반적으로 온톨로지나 지식그래프 상에서 사건과 개체는 노드(Node)로 표현되며 둘 사이의 관계(Relation)는 엣지(Edge)로 표현된다. 또한, 지식그래프를 이용하여 하나의 데이터셋을 구성할 수 있는데 이를 가설이라고 한다.

Table 1. Description of Terms and Datasets

Item	Contents
Unit Hypothesis	A hypothesis consisting of one event and one or more objects, and an event-object relation
Candidate Hypothesis	A hypothesis that merged overlapping or similar unit hypotheses from multiple unit hypotheses

가설 데이터셋은 수많은 사건과 개체가 노드 및 엣지로 표현되어 연결된 지식그래프로 표현된다. 각 가설에 대한 설명은 Table 1. 과 같다. 본 연구에서 고려하는 가설 데이터셋은 전장상황 파악의 단계 및 범주에 따라

단위가설, 후보가설로 구분된다[6, 13]. 단위가설은 사건과 하나 이상의 개체 그리고 사건과 개체를 연결하는 관계로 구성되며 후보가설은 같은 토픽 내 단위가설 중 사건이 동일할 경우 병합되는 가설을 의미한다.

지식그래프를 통해 후보가설로 변환도 가능하며 후보가설이나 지식그래프를 통해 관련성이 높거나 낮은 또다른 가설을 생성할 수 있다. 보고서를 통해 지휘관이 작성한 요구나 질문은 질의(또는 사용자 질의) 가설이라고 한다. 지휘관은 사용자 질의에 관련된 주요한 사건이 포함된 후보가설 데이터의 관련한 정도를 파악하여 분석한 결과를 제시할 수 있어 신속한 의사결정이 가능하다.

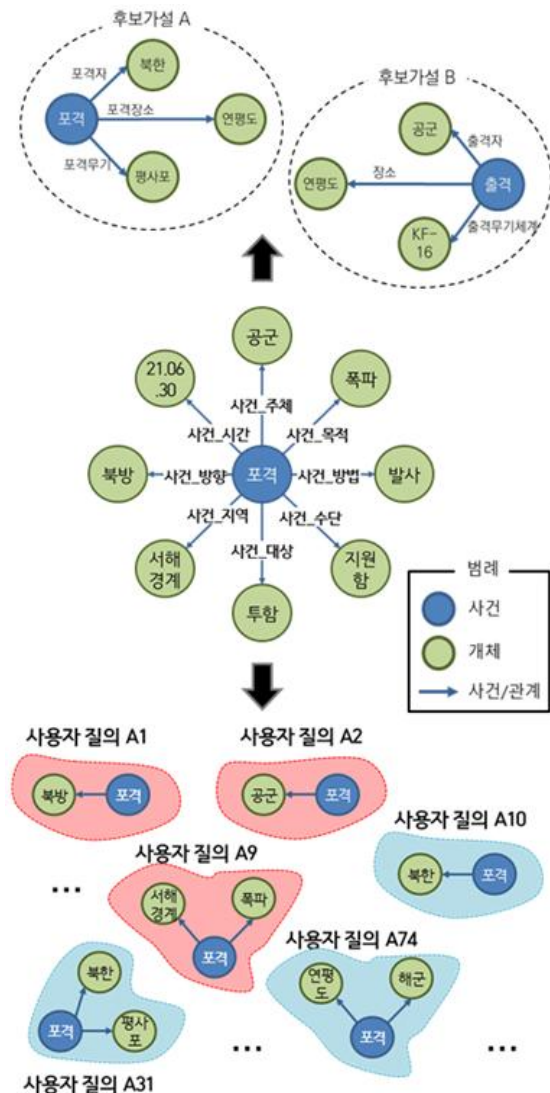


Fig. 1. Candidate Hypothesis and User Question

사용자가 직접 모의 시나리오의 여러 토픽에 사건, 개체, 관계 정보를 식별할 수 있으며, Fig. 1. 과 같이

하나의 사건과 여러 개체로 이뤄진 후보가설을 통해 질의 가설 데이터셋을 생성할 수 있다. 질의 데이터셋에 대해 예시는 다음과 같다. ‘24년 12월 1일, A전투기가 청주에서 출발 후 어디로 이동했는가?’라는 질의는 {사건 : 비행, 시간 : 12월 1일, 주제 : A전투기, 출발위치 : 청주, 도착위치 : ?}인 사건과 주변 개체(시간, 주제, 장소)와 사건-개체 간 관계로 변환할 수 있다. 도착위치에 대해 예측하기 위해 질의와 사건, 개체, 관계 정보로 변환한 데이터를 활용하여 AI 또는 머신러닝 방법으로 학습 후 예측할 수 있다. 본 연구에서는 후보가설을 분석하여 사용자 질의와의 관련성을 예측하는 데에 초점을 맞춘다.

후보가설과 사용자 질의의 관련성을 부여하는 기본 조건은 다음과 같다. 관련성이 있을 경우는 1과 0.5로 부여하고, 관련성이 없는 경우는 0.3과 0으로 부여한다. 또한, 하나의 토픽을 고려하는 것이 아닌 전체 토픽을 고려하여 하나의 후보가설은 사용자 질의와 매칭하도록 구성한다. 세부적인 조건은 다음과 같다. 조건 ①은 같은 토픽 내 같은 후보가설에서 분해된 사용자 질의는 관련성 1 부여한다. 조건 ②는 같은 토픽 내 다른 후보가설에서 분해된 사용자 질의는 관련성 0.3 부여한다. 조건 ③은 다른 토픽 내 어떤 후보가설에서 분해된 사용자 질의는 관련성 0 부여한다.

III. Algorithm Description

학습모델 데이터셋 생성을 위해 학습 및 추론 단계 모델 구조는 Fig. 2. 와 같이 설계한다.




Fig. 2. Model Architecture

학습 과정은 입력 데이터는 후보가설 및 사용자 질의를 입력하여 임베딩을 수행 후 각 임베딩값을 회귀 모델에 입력하여 후보가설과 질의가 얼마나 관련있는지에 대한

관련성 정도인 0, 0.3, 0.5, 1를 추론하여 결과를 제시한다.

3.1 Vector Embedding

후보가설 및 사용자 질의 데이터들을 학습모델의 입력값으로 활용하기 위해 먼저 가설을 벡터 형태로 임베딩하는 방안을 제안한다. 본 연구에서는 후보가설이 갖는 각각의 개체 정보를 보존하기 위한 방안으로 온톨로지 정보를 벡터 형태로 임베딩하는 Owl2Vec 알고리즘을 사용한다[14]. 하나의 후보가설을 입력으로 받았을 때 시간 개체를 제외한 사건 개체 및 관계 개체들을 50차원의 벡터 형태로 임베딩 후, 추가적으로 시간 개체의 경우 Positional Embedding을 통해 임베딩을 진행한다. 최종적으로 변환된 개체 벡터들을 결합(Concatenate)하여 하나의 후보가설 벡터 임베딩을 생성한다. 사용자 질의의 경우에도 후보가설과 동일한 방안으로 벡터 임베딩을 생성하여 두 임베딩 벡터의 차원을 맞춘다. 각 사용자 질의가 후보가설의 부분 그래프로 이루어져 있기 때문에 개체가 존재하지 않는 경우에 대해서는 벡터값에 0으로 대체한다. Fig. 3. 은 후보가설의 사건과 각 개체의 임베딩하는 과정이다.

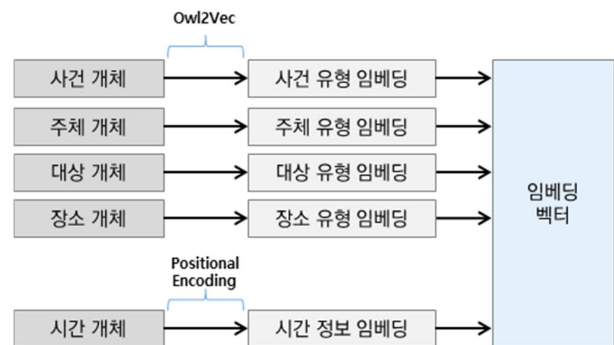


Fig. 3. Embedding Method

3.2 Learning Model

지휘관에게 사용자 질의에 대한 관련성을 측정하여 결과를 제공하는 관련성 식별 학습모델의 구조에 대해 설명한다. 학습모델은 입력으로 받은 사용자 질의 정보와 후보가설에 대한 최종 관련성 값을 도출하게 된다. 본 연구에서는 제안하는 후보가설 학습모델은 다층 퍼셉트론 회귀 신경망 모델 구조를 따른다.

벡터 형태로 임베딩된 사용자 질의 정보와 후보가설 정보를 입력으로 받아 각각에 대한 feed-forward 신경망 학습을 진행한다. 최종적으로 각각의 신경망의 출력값을 결합하여 한 번 더 회귀 모델 학습을 진행하여 최종적으로

0~1 사이의 관련성 값을 얻는다. 각각의 임베딩 벡터의 특성을 파악하는 신경망 네트워크로 Fig. 4. 와 같이 3-Layer MLP(Multi-Layer Perceptron) 모델을 활용하며 출력 레이어는 10차원의 형태로 학습을 진행한다. 최종적으로 두 개의 정보를 결합하는 네트워크로는 2-layer MLP 모델을 활용한다.

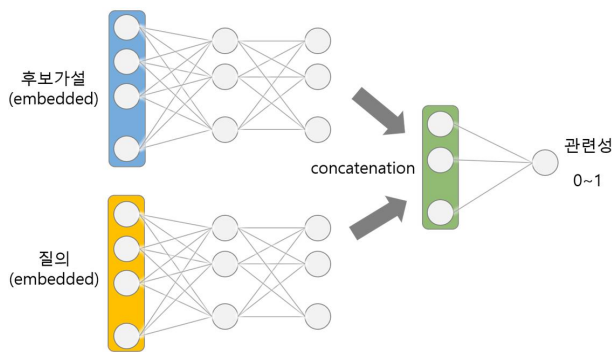


Fig. 4. 3-Layer MLP Regression Model

3.3 Data Preprocessing

모델의 학습 성능 및 추론의 정확성 향상을 위해 추가적으로 진행한 데이터의 가중치 부여 전처리 과정에 대해 서술한다. 입력값 중 사용자 질의 데이터를 고정하였을 때, 추가적으로 입력되는 후보가설 데이터는 질의와 관련성이 없을 경우의 수가 관련성이 높은 경우의 수보다 훨씬 많다. 이를 데이터 레이블 값으로 설명하면 레이블이 0.3인 경우의 수가 레이블이 0.5, 1인 경우의 수보다 최소 100배 이상 많은 현상이 발생한다. Table 2.는 데이터 불균형 문제가 발생하게 되는 예시이다. 이를 그대로 모델 학습에 적용할 경우, 레이블 0.3인 데이터에 대해서는 학습이 원활히 진행되지만, 나머지 경우에 대해서는 제대로 된 학습이 이루어지지 않는 문제점이 발생하여 클래스 불균형 문제가 발생한다.

Table 2. Description of Label Before Preprocessing

Topic ID	# of label 0.3	# of label 0.5	# of label 1
1	30,294	198	198
2	351,348	1,748	1,748
3	62,496	134	134
4	117,760	368	368

이러한 데이터 불균형 현상을 보완하기 위해 몇몇 데이터 전처리 과정을 적용한다. 먼저 데이터가 불균형한

레이블 0.5, 1인 데이터에 대해서는 가중치 재부여 (Re-weight) 방법을 적용한다. 각각의 데이터에 각 토픽 별 개수에 해당하는 가중치 적용하여 학습 과정에서 부족한 레이블 데이터에 대한 학습의 비중을 늘린다.

데이터가 충분히 많은 레이블 0.3 데이터에 대해서는 가중치 재부여가 아닌 다운 샘플링(Down-Sampling) 방법을 적용한다. 해당 방법은 충분한 데이터 레이블에 대한 학습 비중을 낮춤과 동시에 데이터가 충분한 상황에서 중복된 형태의 데이터를 학습 과정 이전에 제거하여 모델 학습 시간을 비약적으로 단축할 수 있다. 데이터의 개수는 재가중치 수치에 비례하여 (레이블 1인 데이터의 수)×(토픽 별 다운 샘플링 비율) 가중치 수만큼 수행한다.

마지막으로 사용자 질의 데이터 생성 과정에서 발생하는 모순되는 데이터에 대한 제거 과정을 추가한다. 사용자 질의 데이터를 후보가설에서 추출하는 과정에서 Fig. 5. 와 같이 서로 다른 후보가설에서 동일한 질의가 생성되는 경우가 발생한다. 이 경우 동일한 질의와 후보가설에 대하여 서로 다른 레이블 값을 갖는 데이터가 발생한다. 이러한 모순된 데이터의 학습을 방지하기 위해 전체 데이터 검색을 통해 문제가 발생할 수 있는 데이터를 사전에 제거하는 전처리 과정을 진행한다.

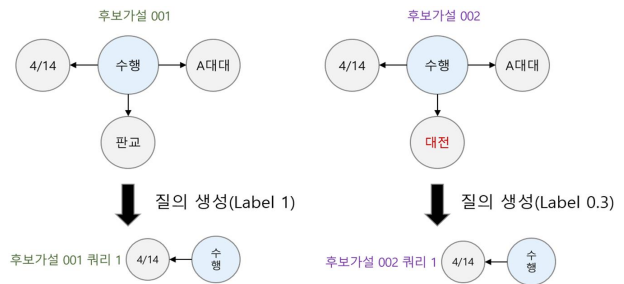


Fig. 5. Generate User Question from Candidate Hypo

3.4 Fairness Measure

일반적으로 많이 사용하는 회귀 모델로 학습을 진행할 경우, 질의와 관련성이 높지 않은 레이블 0.3 데이터에 대한 분류가 제대로 되지 않는다. 이 문제점을 해결하기 위해 앞서 입력 데이터 임베딩 방법과 제안한 모델, 데이터 가중치 부여 방법을 서술하였다. 그리고 특정 클래스(레이블 0.3)에 대한 정확도 감소 문제를 해결하기 위한 정규화(Regularization) 방안을 추가적으로 제시한다.

고려하는 모델은 기본적으로 회귀 모델의 형태를 가짐과 동시에 레이블이 크게 세 종류로 구분되는 분류

형태를 가진다. 이러한 특성을 제대로 활용하기 위해 회귀 모델의 정규화(Regularization) 항을 추가하여 본 연구에서는 클래스별 정확도를 ‘공평’하게 만들어 분류 모델 형태의 제약 조건(Constraint)을 도입하는 아이디어를 제안한다. 즉, 회귀 형태의 학습모델에 분류 형태의 정규화를 진행하는 방식이며 수식 (1)과 같다.

$$Loss = MSE(y, \hat{y}) - \lambda \min_{class \in \{0.3, 0.5, 1\}} Accuracy(class) \quad (1)$$

현재의 학습모델이 특정 클래스의 데이터를 지나치게 학습하지 못하고 있기 때문에 딥러닝에서 Fairness를 위해 수식 (1)과 같이 max-min accuracy 형태의 정규화를 거친 손실 함수를 사용하여 모든 클래스의 데이터셋들이 공평하게 학습이 잘 되는 현상을 확인할 수 있다. 해당 수식에서 첫 번째 항에서 일반적인 회귀 모델에서의 MSE 함수를 최소화하여 회귀 정확성을 높이며 두 번째 항은 세 개의 클래스 중 가장 낮은 예측 정확도 값을 최대화하여 모든 클래스에서의 분류 정확성을 높일 수 있다.

IV. Experimental Result

본 장에서는 제안한 4단계의 알고리즘을 바탕으로 수행한 실험을 수행하며 실험에 필요한 학습 데이터 및 실험 설정 그리고 실험 결과에 대해 서술한다.

4.1 Dataset & Experiment

실험을 위한 모의 시나리오는 생성된 토픽 중에서 일부 Topic ID를 활용한다. 전체 시나리오에서 후보가설 및 사용자 질의 데이터 구조에 맞게 자동화 및 수집하여 각각의 모의 시나리오에서 가설 조합 쌍을 9:1 비율로 나누어 학습 데이터와 테스트 데이터로 사용한다. Topic ID 1에서 4까지 해당되는 내용은 육/해/공/연합으로 이루어진 훈련 보고서로 이루어져 있다. 해당 토픽에 대해 군사 전문가가 직접 수동으로 후보가설 레이블 생성 작업을 수행하였고, 사용자 질의는 앞서 설명한 사용자 질의 생성 조건에 따라 자동화하여 후보가설과의 관련성 지표를 생성하였다. 이후, Table 2.와 같이 불균형인 데이터셋을 레이블 ‘0.5’와 ‘1’에 대해서는 가중치 재부여 방안, 레이블 ‘0.3’에 대한 데이터셋에 대해서는 다운 샘플링과 모순 데이터셋에 대해 특정 데이터셋을

제거하는 전처리 방안을 거친다. 각 토픽에 대한 데이터의 세부사항은 Table 3.과 같다.

Table 3. Description of Label After Preprocessing

Topic ID	# of label 0.3	# of label 0.5	# of label 1
1	1,352	1,352	1,352
2	1,748	1,748	1,748
3	4,156	4,156	4,156
4	2,798	2,798	2,798

모델의 성능 지표로는 Confusion Matrix를 활용한다. 0~1 사이의 값으로 된 모델의 출력값을 0.3, 0.5, 1 중 가장 가까운 값을 임계값(Thresholding)으로 진행하고 예측된 레이블과 실제 레이블의 분포가 유사한 지에 대해 3×3 크기의 Confusion Matrix로 검증한다.

4.2 Experiment Result

실험에서는 데이터 분할을 통해 90%의 데이터를 4단계의 알고리즘을 반영한 회귀 학습모델에 각 시나리오 별 10%의 테스트 데이터를 입력하여 분류 모델 추론 실험을 진행한다. 실험한 수행한 학습 및 테스트 결과는 아래와 같다. Fig. 6. 의 train loss curve 그래프를 참고하면 약 100 epoch을 거친 이후에는 train loss가 0.1 이하로 수렴한다는 것을 확인할 수 있고, 이를 통해 구현한 모델 네트워크에서의 학습이 잘 동작하고 있음을 파악할 수 있다.




Fig. 6. Train Loss curve with 200 epochs

또한 Table 4. 의 Train/Test 정확도 값이 90% 이상이 나온다는 점에서 본 모델이 후보가설과 질의의 가장 중요한 사건 정보의 관련성을 제대로 예측하는 것을 확인할 수 있다.

일부 데이터셋에 대한 Confusion Matrix의 측정 결과는 Table 5. ~ Table 8. 의 결과와 같다. 표에서 열은 실제 레이블 값, 행은 예측한 레이블 값을 의미한다. 즉 행렬의 대각선 셀의 값이 높을수록 정확한 예측을 하고 있음을 의미한다. 표에서 확인할 수 있듯이 대부분 레이블에서 0.8 이상의 정확도를 보였으며, 특히 레이블 '1'에 해당하는 데이터에 대해서는 0.9 이상의 예측 정확도를 확인하였다.

Table 4. Train/Test Accuracy

Topic ID	train acc.	test acc.
1	0.8473	0.7593
2	0.9738	0.9765
3	0.9427	0.9392
4	0.9765	0.9811

Table 5. Confusion Matrix for Topic 1

	0.3	0.5	1
0.3	0.827	0.068	0.109
0.5	0.154	0.830	0.016
1	0.003	0.074	0.923

Table 6. Confusion Matrix for Topic 2

	0.3	0.5	1
0.3	0.740	0.160	0.099
0.5	0.153	0.820	0.027
1	0	0.066	0.934

Table 7. Confusion Matrix for Topic 3

	0.3	0.5	1
0.3	0.663	0.210	0.128
0.5	0.288	0.712	0
1	0.003	0.085	0.915

Table 8. Confusion Matrix for Topic 4

	0.3	0.5	1
0.3	0.756	0.155	0.087
0.5	0.284	0.707	0.008
1	0.003	0.111	0.889

V. Conclusions

본 논문은 다양한 국방 체계에서 생성되는 데이터 및 보고서의 자연어 문장을 토대로 지휘관의 요구에 따라 관련된 정보를 빠르게 제공하여 지휘결심을 지원하기 위해 연구를 수행하였다. 주요 용어인 사용자 질의와 후보가설에 대해 생성하는 조건 및 용어 정의에 대해 서술하였고, 질의와 후보가설 사이의 관련성을 측정하여 제공하는 4단계의 아키텍처 딥러닝 모델을 제안하였다. 주어진 입력 데이터셋을 효과적으로 처리하기 위한 문자를 벡터 임베딩으로 전처리 방안을 제안하였고 모델의 아키텍처를 다층 퍼셉트론 회귀 신경망 구조로 변환하여 2개의 정보를 결합하였다. 학습모델에 입력하기 전, 데이터 불균형이 발생할 경우, 모델 입력 단계에서 Re-Weight 샘플링 과정을 거쳐 데이터 불균형 문제를 해결하였고, 모순되는 데이터를 사전에 식별하여 제거하는 알고리즘을 추가하였다. 회귀 모델의 구조를 분류 형태로 학습할 수 있도록 손실함수의 제약조건을 추가하여 실험을 통해 Confusion Matrix 형태의 모델의 성능을 측정하였다.

실험 결과를 통해 해당 모델의 측정값을 보면, 레이블 '1'에 대해서는 0.9에 가까운 정확도를 출력하지만 레이블 '0.3'과 '0.5'에 대해서는 0.9 이상의 성능을 만족하지는 않았으나 각 토픽의 평균 0.7 이상을 만족하는 것을 확인하였다. 레이블 '1'에 비해 성능이 낮은 이유는 3단계의 모순 데이터 제거 부분에서 레이블 '0.3'이 제대로 할당되지 않았고, 레이블 '0.3'과 '0.5'은 서로 중복되는 데이터가 많아 각 레이블에 서로 영향성이 있어서 레이블 '1'에 비해 성능이 낮게 나오는 것을 확인하였다. 후속 연구에서는 해당 문제점에 대한 방안을 연구 및 데이터셋의 품질에 대해 개선할 예정이다.

REFERENCES

- [1] C. Lee, J. Son, H. Park, S. Lee, S. Park, and Y. Lee, "Technical Trends of AI Military Staff to Support Decision-Making of Commanders," *Electronics and Telecommunications Trends*, vol. 36, no. 1, pp. 89-98, Feb. 2021. <https://doi.org/10.22648/ETRI.2021.J.360110>.
- [2] F. Barlos, et al. "Collection and Monitoring via Planning for Active Situational Scenarios (COMPASS)(Strategic Multi-Layer Assessment Report) (No. SAND-2020-0136R)," STRATEGIC TECHNOLOGY OFFICE, Jan. 2020. <https://doi.org/10.2172/1592839>.
- [3] Defense Advanced Research Projects Agency, AIDA: Active Interpretation of Disparate Alternatives, <https://www.darpa.mil/program/active-interpretation-of-disparate-alternatives>.
- [4] C. Han and J. Lee, "A Methodology for Defense AI Command & Control Platform Construction," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 44, no. 4, pp. 774-781, Apr. 2019. <https://doi.org/10.7840/kics.2019.44.4.774>.
- [5] C. Han, "A Methodology for Constructing Intelligent-Machine FDC Commander Using Decision-Making Tree," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 45, no. 2, Korea Information and Communications Society, pp. 355-363, Feb. 2020. <https://doi.org/10.7840/kics.2020.45.2.355>.
- [6] E. Cho, S. Jin, Y. Shin, and W. Lee, "A Virtual Battlefield Situation Dataset Generation for Battlefield Analysis based on Artificial Intelligence," *Journal of the Korea Society of Computer and Information*, vol. 27, no. 6, pp. 33-42, Jun. 2022. <https://doi.org/10.9708/JKSCI.2022.27.06.033>.
- [7] D. Yu, M. Ra, C. Han, J. Shin, and S. No, "Intelligent Army Tactical Command Information System based on National Defense Ontology," *Journal of the Korea Society of Computer and Information*, vol. 18, no. 3, pp. 79-89, Mar. 2013. <https://doi.org/10.9708/JKSCI.2013.18.3.079>.
- [8] J. Baek, S. Do, S. Jun, and C. Lee, "Definition of battlefield situation and implementation of dataset for combat environment recognition", Summer Annual Conference of IEIE 2022, vol. 45, no. 1, pp. 2623-2624, Jun. 2022.
- [9] C. Han, K. Shin, S. Choi, S. Moon, C. Lee, and J. Lee, "A Methodology of Decision Making Condition-based Data Modeling for Constructing AI Staff," *Journal of Internet Computing and Services*, vol. 21, no. 1, pp. 237-246, Feb. 2020. <https://doi.org/10.7472/JKSII.2020.21.1.237>.
- [10] S. Jin, W. Lee, H. Kim, S. Jo, and Y. Kang, "A Study on Multiple Reasoning Technology for Intelligent Battlefield Situational Awareness," *The Journal of Korean Institute of Communications and Information Sciences*, vol. 45, no. 6, Korea Information and Communications Society, pp. 1046-1055, Jun. 2020. <https://doi.org/10.7840/kics.2020.45.6.1046>.
- [11] G. Suh, Y. Shin, S. Jin, W. Lee, J. Ahn, and C. Suh, "Recommendation Model for Battlefield Analysis based on Siamese Network," *Journal of the Korea Society of Computer and Information*, vol. 28, no. 1, pp. 1-8, Jan. 2023. <https://doi.org/10.9708/JKSCI.2023.28.01.001>.
- [12] H. Cho, H. Choo, S. Jin, Y. Shin, W. Lee, and K. Shin, "Hierarchical Graph Neural Network for Identifying Relevance between Hypotheses that Describe Battlefield Situation," *Database Research*, vol. 38, no. 2, pp. 18-28, 2022.
- [13] Y. Shin, S. Jin, and J. Ahn, "A Study on Construction Method of AI based Situation Analysis Dataset for Battlefield Awareness," *Journal of the Korea Society of Computer and Information*, vol. 28, no. 10, pp. 37-53, Oct. 2023. <https://doi.org/10.9708/JKSCI.2023.28.10.037>.
- [14] J. Chen, P. Hu, E. Jimenez-Ruiz, O. M. Holter, D. Antonyrajah, and I. Horrocks, "OWL2Vec*: embedding of OWL ontologies," *Machine Learning*. Springer Science and Business Media LLC, vol. 110, no. 7, pp. 1813-1845, Jun. 2021. <https://doi.org/10.1007/s10994-021-05997-6>.

Authors



Yookyung Shin received the M.S. degree in Data Science from Ajou University, Korea, in 2019. Yookyung Shin is currently an engineer in Hanwha Systems. She is interested in Deep Learning, Recommender System, Military Communications and Network.



Soyeon Jin received the B.S. degree in Computer Engineering from Chonbuk National University, Korea, in 2003. Soyeon Jin is currently a chief engineer in Hanwha Systems. She is interested in data links, machine learning, military communications, and unmanned systems.