

# A Specification-Based Methodology for Data Collection in Artificial Intelligence System

Donggi Kim<sup>†</sup> · Byunggi Choi<sup>††</sup> · Jaeho Lee<sup>†††</sup>

## ABSTRACT

In recent years, with the rapid development of machine learning technology, research utilizing machine learning has been actively conducted in fields such as cognition, reasoning and judgment, and action among various technologies constituting intelligent systems. In order to utilize this machine learning, it is indispensable to collect data for learning. However, the types of data generated vary according to the environment in which the data is generated, and the types and forms of data required are different depending on the learning model to be used for machine learning. Due to this, there is a problem that the existing data collection method cannot be reused in a new environment, and a specialized data collection module must be developed each time. In this paper, we propose a specification-based methodology for data collection in artificial intelligence system to solve the above problems, ensure the reusability of the data collection method according to the data collection environment, and automate the implementation of the data collection function.

Keywords : Intelligence System, Machine Learning, Data Collection, Automation, Reusability

## 명세 기반 인공지능 학습 데이터 수집 방법

김 동 기<sup>†</sup> · 최 병 기<sup>††</sup> · 이 재 호<sup>†††</sup>

## 요 약

최근 기계학습 기술이 빠르게 발전함에 따라 지능형 시스템을 구성하는 여러 기술 중에서 인지, 추론 및 판단, 행위와 같은 분야에서 기계학습을 활용한 연구가 활발히 이루어지고 있다. 이러한 기계학습을 활용하기 위해서는 학습을 위한 데이터의 구축이 필수적이다. 하지만 데이터가 생성되는 환경에 따라 생성되는 데이터의 종류가 다양하고, 기계학습에 활용할 학습모델에 따라 요구되는 데이터의 종류와 양식이 다르다. 이로 인해 새로운 환경에서 기존의 데이터 수집 방법을 재사용하지 못하고 매번 특화된 데이터 수집 모듈을 개발해야 한다는 문제가 있다. 본 논문에서는 위와 같은 문제를 해결하기 위해 명세 기반 인공지능 데이터 수집 방법을 제안하여 데이터 수집 환경에 따른 데이터 수집 방법의 재사용성을 확보하고, 데이터 수집 기능 구현을 자동화할 수 있는 방법을 제시하고자 한다.

키워드 : 지능형 시스템, 기계학습, 데이터 수집, 자동화, 재사용성

## 1. 서 론

최근 기계학습 기술이 빠르게 발전함에 따라 다양한 분야의 기술에 적용되고 있다. 특히 변화하는 환경을 인식하고 의사결정을 통해 선택된 행위를 수행하는 지능형 시스템과 같이 여러 종류의 기술을 유기적으로 통합하여 개발하여야 하는 분야에서 기계학습을 활용하여 각 기능을 구현하고자 하는 연구가 늘어나는 추세이다.

지능형 시스템에서 기계학습이 사용되는 주된 분야는 음성이나 이미지를 통해 사람을 구분하거나[1] 사람의 표정을 인지하고 나아가 감성 등을 추출하는 연구[2] 등이 대표적이다. 더 나아가, 최근에는 지능형 시스템의 의사결정 기능을 지원하기 위한 작업 관리 기능의 메타플래닝에 필요로 하는 정책 학습[3]이나 의사결정 기능을 위한 강화 학습[4] 등과 같은 연구도 진행되었다.

이처럼 지능형 시스템을 구성하는 기능에 기계학습을 활용하기 위해서는 이를 학습시키기 위한 학습 데이터의 구축이 필수적이다. 최근 기계학습 분야에서 주목받는 MLOps[5]에서는 기계학습 시스템의 개발을 위해서는 기계학습의 코드를 제외하고도 분석 도구, 프로세스 관리 도구, 특징 추출, 리소스 관리, 서비스, 모니터링 등 다양하고 복잡한 인프라가 요구된다고 말하고 있다. 그리고 이러한 MLOps에서는 데이터를 수집하는 것 또한 기계학습을 활용하는 데에 있어 중요한 부분임을 말하고 있다.

※ 본 연구는 2020년 국방과학연구소 미래도전국방기술 연구개발사업(912904601)의 지원을 받았음.

† 준 회 원 : 서울시립대학교 전자전기컴퓨터공학과 석사

†† 정 회 원 : 서울시립대학교 전자전기컴퓨터공학과 박사

††† 종신회원 : 서울시립대학교 전자전기컴퓨터공학과 교수

Manuscript Received : May 31, 2022

First Revision : July 13, 2022

Accepted : August 1, 2022

\* Corresponding Author : Jaeho Lee(jaeho@uos.ac.kr)

2021년 과학기술정보통신부에서 발간된 인공지능 학습용 데이터 품질관리 가이드라인[6]에 따르면 학습용 데이터를 구축하기 위해서는 임무 정의, 데이터 획득, 데이터 정제, 데이터 라벨링, 데이터 학습의 과정을 거쳐야 한다.

이중 데이터 획득 단계에서는 기계학습에 필요한 데이터를 현실 세계에서 직접 생성하거나, 이미 보유하고 있는 조직이나 시스템 등으로부터 학습에 필요한 데이터를 확보하는 활동을 수행한다. 하지만 이러한 데이터는 데이터를 획득하고자 하는 환경에 따라 다양한 종류의 데이터가 생성되어, 환경에 따라 특화된 데이터 수집 방법이 요구된다.

한편, 우리는 2020년부터 무인기 자율임무를 위한 BDI[7] 기반의 지능형 소프트웨어 프레임워크 개발을 위한 연구를 진행하고 있다. 자율임무를 수행하는 무인기는 기존의 임무 수행 기록을 바탕으로 개선된 임무를 수행할 수 있어야 하며, 이를 위해 임무 수행 정보를 학습을 위해 저장하고, 학습모델의 결과를 실시간으로 의사결정 기능에 반영할 수 있어야 한다. 이를 위해 지능형 시스템에서 생산되는 학습용 데이터를 수집할 수 있어야 하며, 무인기가 수행하는 임무에 따라 생산되는 데이터가 다르므로 각 임무에 특화된 데이터 수집이 필요하다. 하지만 임무별로 학습 데이터 수집기를 개발할 경우, 수집 대상 데이터가 변경됨에 따라 데이터 수집기를 매번 수동으로 개발해야 한다는 한계점을 가진다.

이와 같은 문제를 해결하기 위해 지능형 시스템 내에서 생성되는 학습용 데이터 수집 방법을 위한 요구사항은 다음과 같다.

- 1) 기존에 개발된 수집 방법과 유사한 수집 환경에서 기존의 방법을 재사용할 수 있는 방법이 필요하다. 무인기가 수행하는 임무는 정찰, 타격 등 다양한 종류가 존재하지만, 기본적인 작업 구조는 매우 유사해 임무 별로 공통적으로 생산되는 데이터가 존재한다. 이러한 공통으로 생산되는 데이터 수집을 위해 기존의 수집 방법을 재사용할 수 있어야 한다.
- 2) 데이터 수집 기능 구현의 자동화가 필요하다. 각 임무에서 생성되는 학습 데이터를 수집하기 위한 데이터 수집기를 별도로 개발하는 것이 아니라, 수집 대상 목록을 서술하는 명세를 통해 원하는 데이터를 수집할 수 있어야 한다.

이와 유사한 문제를 해결하기 위해 연구된 다른 연구들로는 CREME[8], AUTODATA[9], 클라우드 서비스 인터페이스[10] 등이 있다.

CREME은 네트워크 공격의 탐지를 위한 학습용 데이터셋을 자동으로 수집할 수 있도록 지원하고 있지만, 네트워크 도메인에서의 데이터 수집을 목표로 하고 있으며, 새로운 데이터 수집을 위해 추가적인 시스템의 개발이 필요하다는 점에서 한계를 가진다.

AUTODATA는 온라인상의 데이터를 수집하여 학습 데이터셋을 구축하는 체계를 개발하였다. 하지만 이 연구에서 수집하고자 하는 데이터는 웹상의 데이터로 한정되며, 활용하고자 하는 학습모델의 종류가 고정되어 있어 다양한 학습모

델을 위한 데이터셋을 구축할 수 있어야 한다는 점에서 해당 방법은 우리 연구에 적합하지 않다.

모델 기반 클라우드 서비스 인터페이스에서는 모델 기반 인터페이스를 통해 데이터의 자동 변환 기능을 지원하고 있지만, 이 연구의 목적은 외부 서비스와의 연계를 위한 데이터 변환 기능으로 해당 방법은 데이터 수집을 목적으로 하는 우리 연구에 적합하지 않다.

따라서 위와 같은 요구사항을 만족하기 위하여 본 논문에서는 명세 기반 인공지능 학습 데이터 수집 방법을 제안한다. 명세 기반 인공지능 학습 데이터 수집 방법이란 1) 수집 대상 데이터를 학습 데이터 프로파일의 형태로 명세화하고, 2) 이를 활용하여 지능형 시스템 내에서 생성되는 데이터를 수집하는 방법으로, 이를 통해 학습 데이터 프로파일의 재사용성과 같은 장점을 가질 것으로 기대된다.

## 2. 관련 연구

### 2.1 CREME

데이터를 자동으로 수집하기 위한 연구로는 네트워크를 통한 보안 공격으로부터 네트워크 트래픽, 시스템 로그와 같은 데이터를 자동으로 수집하기 위한 프레임워크인 CREME이 있다. CREME은 IoT와 같은 현대 네트워크에서 보안 공격을 해결하기 위한 침입 탐지 시스템에서 활용되는 기계학습을 학습시킬 데이터셋의 구성을 위해 개발된 프레임워크이다. CREME은 네트워크 트래픽, 시스템 로그와 같은 여러 소스로부터 침입 탐지 시스템의 학습 데이터 수집을 위한 수집, 특징 추출, 데이터 레이블링, 평가 등의 단계를 자동화하기 위한 도구들로 구성되어 있다.

CREME에서는 랜섬웨어, 디스크 삭제, 리소스 하이재킹, DoS 공격 등 다양한 네트워크 공격을 모델링한 공격 시나리오를 제안하고, 이를 활용하여 네트워크 공격을 재연하고, 공격 도중 발생하는 네트워크 트래픽, 시스템 로그 등을 수집한다. 이러한 CREME의 구조는 Fig. 1과 같다.

CREME은 사용자의 설정에 따라 위에서 정의된 공격 시나리오를 실행하고, 공격 도중 발생하는 네트워크 패킷이나 시스템 로그를 수집한다. 이렇게 수집된 데이터에서 특징을 추출하고, 레이블링을 지정한 후, 이것들로 구성된 데이터셋을 평가한다.

위와 같은 방법을 통해 CREME은 자동으로 데이터를 수집할 수 있으며, 공격 시나리오를 통해 다양한 종류의 공격으로부터 데이터를 수집할 수 있도록 지원하고 있다. 하지만 해당 시스템의 방법은 새로운 데이터를 수집해야할 경우 추가적인 시스템의 개발이 필요하다. 또한 네트워크 도메인에서의 데이터 수집을 목표로 하고 있어, 지능형 시스템에서의 데이터 수집에는 적합하지 않다.

### 2.2 AUTODATA

딤러닝을 위해선 레이블이 지정된 데이터셋이 필수적이지만, 데이터에 레이블을 부여하는 것을 수동으로 작업하면 많

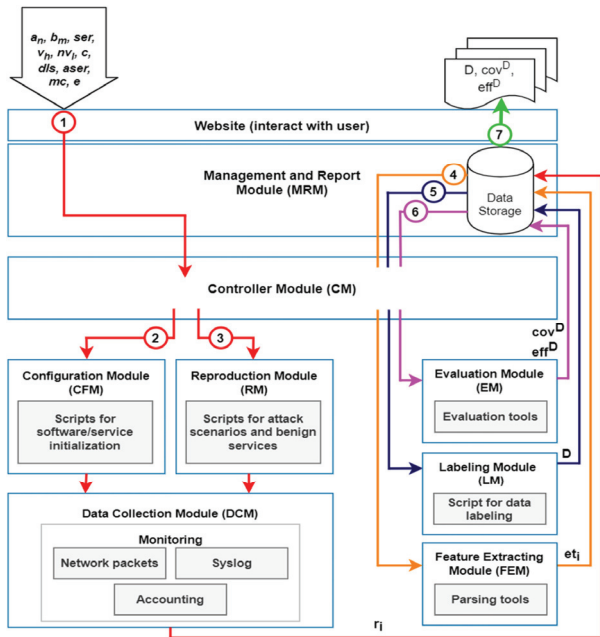


Fig. 1. CREME Architecture[8]

은 입력과 시간이 필요하다. AUTODATA는 이러한 데이터셋 구축 및 레이블 부여를 자동화하기 위해 설계된 시스템으로, 웹상에 존재하는 정보들을 활용하여 딥러닝을 위한 데이터셋을 자동으로 구축하여 AutoML에 제공하는 강화 학습 기반 자동 데이터 검색 시스템이다.

이 시스템을 활용하기 위해선 먼저 사용자가 학습시키고자 하는 레이블이 지정된 기본 데이터셋이 필요하다. 기본 데이터셋을 시스템에 입력하면, 강화 학습을 통해 해당 이미지와 유사한 데이터를 웹에서 수집하여 데이터셋을 구성한다. 그 후 구축된 데이터셋을 AutoML으로 학습하고 모델의 정확도를 평가하여 사용자가 원하는 정확도에 도달하였는지 측정한다. 정확도가 부족할 경우, 데이터를 추가로 수집하여 데이터셋을 구축하고 학습하는 것을 반복한다.

AUTODATA는 온라인상의 데이터를 수집하여 학습 데이터셋을 구축하고 이를 활용하여 학습을 수행하는 체계를 구축하였다. 하지만 이 시스템이 수집하고자 하는 학습 데이터는 웹상의 데이터로 한정되며, 활용하고자 하는 학습모델의 종류가 AutoML로 고정되어 있다. 하지만 지능형 시스템을 위한 학습 데이터 수집 방법은 다양한 학습모델을 위한 데이터셋을 구축할 수 있어야 하므로 본 방법은 적합하지 않다.

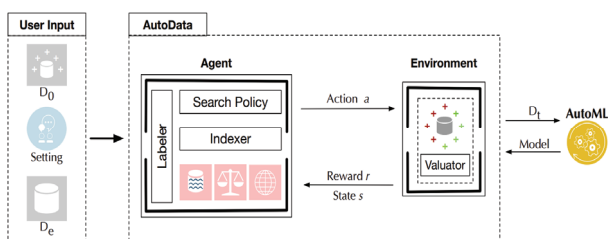


Fig. 2. The Architecture of AUTODATA[9]

### 2.3 지능형 서비스 로봇을 위한 모델 기반 클라우드 서비스 인터페이스

모델을 기반으로 데이터를 변환하는 기술에 관한 연구로는 지능형 서비스 로봇과 클라우드 서비스를 연계하기 위한 클라우드 서비스 인터페이스가 있다. 이 인터페이스는 모델을 기반으로 작동하는 것이 특징이며, 이를 통해 시스템의 변경 없이 모델의 교체 및 추가만으로 연계 가능한 서비스를 확장할 수 있는 기능을 제공한다.

클라우드 서비스 인터페이스에서는 서비스마다 다른 데이터 요구사항과 인증방식을 모델링한 클라우드 서비스 프로파일을 정의하였고, 이를 통해 클라우드 서비스 인터페이스는 모델의 교환만으로 쉽게 연계 대상 서비스와 연결할 수 있는 개방성 및 확장성을 확보할 수 있도록 지원하였다.

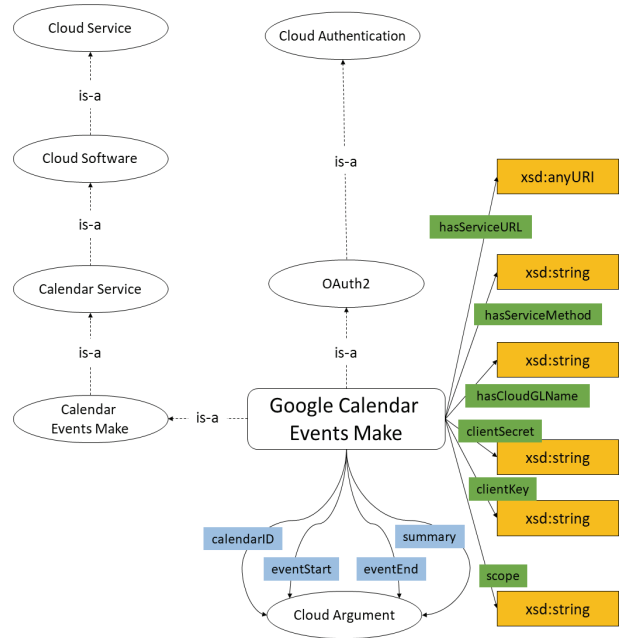


Fig. 3. Cloud Service Profile[10]

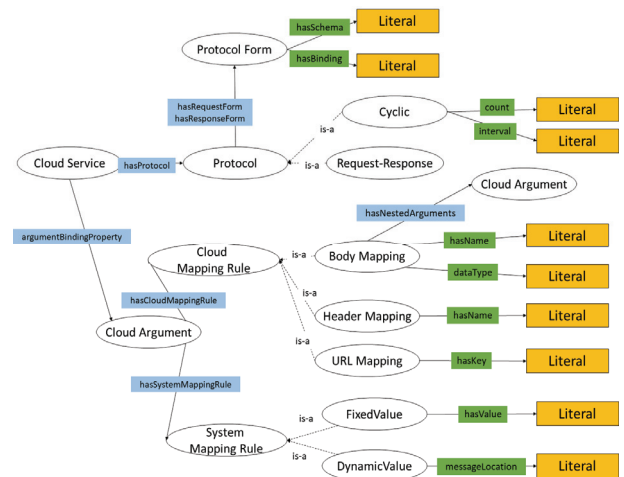


Fig. 4. Cloud Property Model[10]

그리고 클라우드 서비스 인터페이스에서는 지능형 서비스 로봇과 클라우드 서비스 간의 연계를 위해 요구되는 다양한 정보들을 모델링한 클라우드 프로퍼티 모델을 정의하였다. 이러한 클라우드 프로퍼티 모델에는 클라우드 맵핑 툴과 시스템 맵핑 툴을 정의하여 지능형 시스템의 프로토콜과 클라우드 서비스의 요청 간의 변환 기능을 제공하였다. 또한, 클라우드 리소스를 정의하여 클라우드 서비스에서 사용되는 리소스를 재사용할 수 있도록 지원하였다.

클라우드 서비스 인터페이스는 모델 기반 인터페이스를 통하여 재사용성을 확보하고, 지능형 시스템의 프로토콜과 클라우드 서비스의 요청 간의 자동 변환 기능을 지원하고 있다. 하지만 연구의 목적이 데이터를 수집하는 것이 아닌 외부 서비스와의 연계를 위한 데이터 변환 기능으로, 본 방법을 적용하여 데이터를 수집하는 것은 적합하지 않다.

2.4 인공지능 학습용 데이터 품질관리 가이드라인

과학기술정보통신부에선 2021년에 인공지능 학습용 데이터 품질관리를 위한 가이드라인을 발간했다. 해당 가이드라인은 학습용 데이터의 품질관리를 체계적으로 수행하는 방법을 정리한 것으로, 학습용 데이터 구축사업의 참여기관 및 품질관리 전문가 등의 의견 수렴을 통해 작성되었다.

해당 가이드라인에서는 인공지능 학습용 데이터 품질관리를 위한 인공지능 학습용 데이터의 구축과정을 Fig. 5와 같이 제시하였다.

인공지능 학습용 데이터의 구축과정은 다양한 유형의 데이터가 사전에 정의된 목적에 따라 구축되기 때문에 구축과정이 세부적으로 상이할 수 있으나, 일반적으로 임무 정의, 데이터 획득, 데이터 정제, 데이터 라벨링, 데이터 학습의 5단계로 진행된다. 임무 정의 단계에서는 인공지능이 기계학습을 통해 해결하고자 하는 문제 및 문제 해결에 필요한 학습용 데이터를 구체적으로 정의하고 설계하는 활동을 수행하여 수집 대상 데이터를 서술하는 구축계획서를 작성한다. 데이터 획득 단계에서는 기계학습에 필요한 데이터를 직접 생산하거나 혹은 이미 생산된 데이터를 수집하여 원시데이터를 확보하는 활동을 수행한다. 데이터 정제 단계에서는 이전 단계에서 획득한 원시데이터를 기계학습에 필요한 형식이나 크기로 맞추고, 데이터의 중복을 제거하여 원천 데이터로 가공한다. 여기서 원천 데이터란 라벨링 데이터가 부여되지 않은 상태의 데이터를 의미한다. 다음으로 데이터 라벨링 단계에서는 원천 데이터에 라벨링 데이터를 부여하여 기계학습에 활용할 수 있는 학습 데이터셋을 구축하는 활동을 수행한다. 마지막

으로 데이터 학습 단계에서는 학습데이터셋을 이용하여 학습 모델에 학습시키고 학습된 모델의 성능을 향상시키거나 보정하는 활동을 수행한다.

본 논문에서 제시하는 프로파일 기반 학습 데이터 수집 방법은 학습 데이터셋 구축과정 중 임무 정의 및 데이터 획득 단계에 해당한다. 학습 데이터 프로파일은 구축계획서에 맵핑되며, 명세 기반 수집 방법을 통해 수집된 데이터는 원시데이터에 해당한다.

3. 배경 연구

3.1 무인기 자율임무를 위한 지능형 소프트웨어 프레임워크

우리는 2020년부터 무인기 자율임무를 위한 지능형 프레임워크 및 응용 모델 연구 개발 과제를 통해 무인기 제어를 위한 지능형 소프트웨어 프레임워크의 연구를 진행하고 있다.

무인기가 동작하는 환경에는 임무에 필요한 다양한 정보들이 분포되어 있으며, 환경의 변화에 따라 적합한 행동을 수행할 필요가 있으며, 여기서 수행되는 행동은 야전교범과 같은 표준적인 작전 지침이 존재한다. 또한 무인기가 수행하는 임무는 정찰, 추적 등 환경이 다르더라도 실제로 수행하는 행위가 유사하다는 특징을 가진다. 더 나아가 무인기를 제어하는 시스템은 카메라, GPS 등 무인기 내부의 다양한 모듈을 통합하여 지능적으로 활용할 수 있어야 하며, 과거 임무 수행 기록을 바탕으로 임무 수행 능력을 개선할 수 있어야 한다.

위와 같은 무인기 동작 환경의 특징에 따라, 무인기 제어를 위한 지능형 소프트웨어 프레임워크는 다음과 같은 요구사항을 가진다. 임무 수행을 위해 환경의 다양한 정보를 인식, 추론, 기억 등 다양한 지능적 구성요소를 통해 이해할 수 있어야 한다. 실시간 환경의 변화에 따라 적합한 행동을 선택할 수 있어야 한다. 표준적인 작전 지침을 지식화하여 이를 지능형 소프트웨어 프레임워크에 적용할 수 있어야 한다. 유사한 임무를 개발할 때, 기존에 존재하던 임무를 활용할 수 있어야 하며, 임무 개발에 대한 확장성을 가져야 한다. 무인기 내 다양한 모듈의 통합 및 재사용을 지원하기 위해서는 개방적이고 확장 가능한 형태의 프레임워크 지원이 필요하다. 임무 수행 정보를 학습에 활용할 수 있도록 저장하여야 하며, 학습된 결과를 실시간 의사결정에 반영할 수 있어야 한다.

위와 같은 요구사항을 만족하는 프레임워크를 개발하기 위하여 우리는 BDI 기반의 지능형 소프트웨어 프레임워크를 연구하였다.

이 프레임워크는 상황추론 규칙을 기반으로 센서 또는 인식 기능으로부터 획득한 정보를 바탕으로 실시간 상황추론 기능을 제공하여 무인기가 실시간 환경을 이해할 수 있도록 지원하며, 절차적 추론 시스템을 구현한 작업 관리 기능을 통해 실시간 환경의 변화에 따라 적절한 작업을 선택한다. 또한 프레임워크에서 사용되는 모든 데이터는 온톨로지를 통해 지식화하였으며, 임무 수행을 위해 필요한 상황 및 작업으로 구성된 임무 패키지 단위 적용 및 수행을 할 수 있는 아키텍처를 적용하여 기존에 개발된 임무를 재사용하거나 확장하여

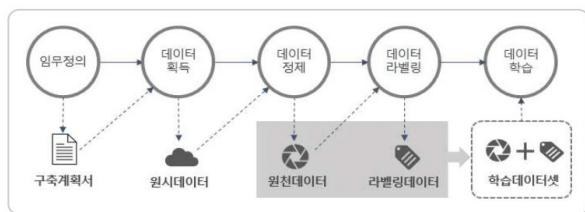


Fig. 5. Construction Process of Learning[6]

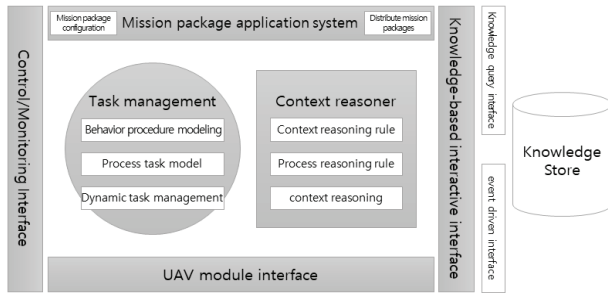


Fig. 6. Intelligent Software Architecture for UAV

적용할 수 있는 환경을 구축하였다. 더 나아가 무인기에 탑재된 다양한 센서 및 액추에이터와의 연계를 위한 외부 연계 인터페이스를 제공하며, 임무 수행 중 생성된 지식을 공유하거나 저장하기 위한 지식 저장소를 제공한다.

무인기가 임무를 수행하는 데 필요한 작업 및 상황 지식으로 구성된 임무 패키지는 메타 정보를 통해 다른 임무 패키지를 참조하여 임무를 구현할 수 있도록 지원하고 있다. 이를 활용하여 기존의 임무를 구성하는 지식 정보는 그대로 재사용하여 새로운 임무를 수행하기 위한 지식을 확장하는 방식으로 임무의 구성을 세분화하거나 구체화하는 방법을 제공한다. 이는 특정 임무를 구성하는 지식 정보가 이를 확장한 새로운 임무에서도 동일하게 활용되며, 임무 수행 중 해당 지식이 그대로 생산되는 것을 의미한다.

지능형 소프트웨어 프레임워크의 지식 저장소는 CRUD 기능을 지원하는 지식 질의 인터페이스와 실시간 이벤트 생성 및 전달을 수행하는 비동기 인터페이스로 구성되어 있다. 각각의 기능을 수행하기 위한 프로토콜은 Table 1과 같다.

프로토콜에는 지식을 저장하기 위한 assert, 질의하기 위한 match, retrieve, 제거하기 위한 retract, 수정하기 위한 update가 있다. 그리고 실시간 이벤트 생성 및 전달을 수행하기 위한 subscribe, notify가 있다. subscribe 프로토콜에는 규칙이 인자로 포함되는데, 이 규칙은 이벤트의 생성 조건과 이벤트가 생성되었을 때 전달받을 지식으로 구성되어 있다. 이러한 규칙을 통해 지식 저장소에 subscribe를 하면, 이벤트 생성 조건이 충족되었을 때 지식 저장소에서 새로운 지식을 생성하여 notify 프로토콜을 통해 전달한다.

우리가 연구한 지능형 프레임워크는 앞서 설명한 지식 저장소를 활용하여 다음과 같은 절차를 통해 학습모델을 활용한다.

먼저 센서를 통해 획득된 환경 데이터와, 이를 통해 지능형 프레임워크에서 생성된 고수준 상황 지식 데이터 중에서 학습에 필요한 원시데이터를 획득하고, 이를 기계학습에 필요한 형식이나 크기로 가공한다. 그리고 가공된 원천 데이터에 라벨링 데이터를 부여한 후 학습을 진행한다. 이렇게 학습된 모델은 지능형 프레임워크의 의사결정을 할 때 활용되고, 의사결정을 통해 행위가 결정되면 행위를 통해 환경에 변화를 발생시킨다. 해당 변화는 센서를 통해 감지되어 다시 지식의 형태로 가공되며, 앞서 설명하는 과정을 무인기가 임무를 수행하는 동안 실시간으로 반복한다.

Table 1. Knowledge Store Protocol

| NAME        | DESCRIPTION  | DATA IN                       | DATA OUT                      |
|-------------|--|-------------------------------|-------------------------------|
| assert      | Insert knowledge to store  | (assert \$GL)                 |                               |
| match       | Query for values matching the given GL   | (match \$GL)                  | (binding \$binding)           |
| retrieve    | Query for knowledge matching a given GL  | (retrieve \$GL)               | (result \$returnGL)    (fail) |
| retract     | Delete knowledge matching a given GL from KS                                     | (retract \$GL)                | (ok)    (fail)                |
| update      | Update the knowledge matching the given GL to another knowledge                  | (update \$beforeGL \$afterGL) | (ok)    (fail)                |
| subscribe   | Subscription function to be notified when knowledge is inserted or updated       | (subscribe \$rule)            | (subscribeID \$subscribeID)   |
| unsubscribe | Delete subscription  | (unsubscribe \$subscribeID)   | (ok)    (fail)                |
| notify      | A protocol to notify when data that satisfies the subscription rule is generated |                               | (notify \$GL)                 |

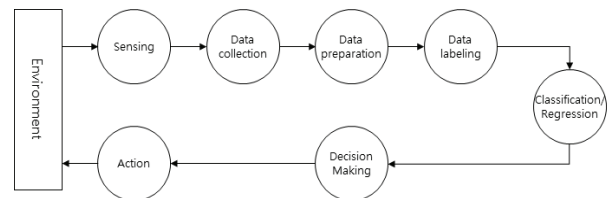


Fig. 7. Learning Data Life-cycle of Intelligent System

학습용 데이터셋을 구축하는 것 자체는 실시간으로 수행할 필요가 없으나, 학습모델을 활용한 의사결정을 수행하기 위해선 학습용 데이터가 실시간으로 수집될 필요가 있다. 이를 위해 본 논문에서는 명세 기반 인공지능 학습 데이터 수집 방법은 수집 대상 데이터를 서술하는 프로파일과 프로파일을 통해 지능형 시스템 내에서 데이터를 수집하는 프레임워크를 제시한다.

#### 4. 연구 내용

본 논문은 무인기 제어를 위한 지능형 시스템에서 생성되는 데이터를 활용한 데이터셋 구축을 위한 학습 데이터 프로파일 및 이를 활용한 학습 데이터 자동 수집을 수행하는 프레임워크를 제안한다.

학습 데이터 프로파일은 수집 대상 데이터를 서술하는 명

Table 2. Learning Data Profile Specification

| Name         | Description                             |
|--------------|---|
| ProfileID    | Identifier of profile                   |
| MissionID    | Mission to collect data                 |
| Dependencies | Reference relationship between profiles |
| Predicates   | Predicate contains data to be collected |
| Template     | Template to store data                  |
| Trigger      | Timing to collect data                  |
| Storage      | storage to store data                   |

세로, 임무 수행을 통해 생성되는 데이터 중 수집할 대상과 대상의 저장 형식을 지정할 수 있다. 학습 데이터 자동 수집 프레임워크는 학습 데이터 프로파일을 기반으로 지능형 시스템에서 지정된 데이터가 생성되면 해당 데이터를 자동으로 수집 및 저장한다.

4.1 학습 데이터 프로파일

학습 데이터 프로파일은 수집 데이터를 서술하는 명세로, 수집할 데이터가 어떠한 임무로부터 발생하는지와 수집 대상 데이터를 지정하고, 수집된 데이터를 언제, 어디에, 어떠한 형식으로 저장할지를 지정할 항목으로 구성되어 있다.

학습 데이터 프로파일의 명세는 Table 2와 같다.

Predicates는 Table 3의 예시와 같이 지능형 시스템에서 생성되는 데이터 중에서 수집할 데이터를 지정하기 위한 항목이다. 여기에는 변수가 포함된 지식이 서술될 수 있다.

Template는 Table 4의 예시와 같이 학습용 데이터의 형식을 지정하기 위한 항목이다. 여기에 서술될 데이터 형식은 JSON 타입으로, key는 프로파일 개발자가 직접 정의할 수 있으며, value에는 predicates에 포함된 변수가 들어갈 수 있다.

Trigger는 Table 5의 예시와 같이 event와 cyclic의 2가지 타입이 있다. 먼저 event 타입에서는 특정 데이터를 지정하기 위한 항목으로 구성되어, 해당 데이터가 생성되었을 때 데이터를 수집하고자 할 때 사용할 수 있다. 그리고 cyclic 타입에서는 데이터를 수집할 period를 서술하기 위한 항목으로 구성되어, 일정 주기마다 데이터를 수집하고자 할 때 사용될 수 있다.

Table 3. Predicates Example

```

"predicates" : [
  "(CurrentDanger $DangerType)",
  "(OwnshipPosition $msgID $timestamp $Latitude $Longitude $Altitude)"
]
    
```

Table 4. Template Example

```

"template" : {
  "dangerType" : "$DangerType",
  "Latitude" : "$Latitude",
  "Longitude" : "$Longitude"
}
    
```

Table 5. Trigger Example

| event  | cyclic  |
|--|---|
| <pre> "Trigger": {   "type": "event",   "predicate": "(CurrentDanger \$Type)" }                     </pre> | <pre> "Trigger": {   "type": "cyclic",   "period": 5 }                     </pre> |

마지막으로 Dependencies는 다른 프로파일과 참조 관계를 나타내기 위한 항목이다. 이러한 참조 관계를 기반으로 후술할 프레임워크에서는 프로파일에 직접 서술되어 있지 않더라도 Dependencies에 서술된 프로파일을 참조하여 관련된 데이터를 자동으로 수집할 수 있도록 지원한다. 이를 통하여 새로운 환경에서 데이터를 수집하고자 할 때 기존의 수집 방법을 재사용할 수 있도록 지원하였다.

4.2 학습 데이터 관리기

학습 데이터 관리기는 학습 데이터 프로파일을 기반으로 원하는 데이터를 자동으로 수집할 수 있도록 지원하는 프레임워크다. 이 프레임워크의 구조는 Fig. 8과 같다.

학습 데이터 관리기는 먼저 학습 데이터 프로파일에 서술된 MissionID를 참조하여 무인가가 수행 중인 임무에 따라 적합한 프로파일을 선택한다. 그리고 프로파일에 서술된 항목들을 바탕으로 적합한 데이터를 수집한다. 이때 Dependencies 항목에 프로파일이 서술되어 있다면 해당 프로파일 에 대한 데이터도 동시에 수집한다.

선택된 프로파일에 서술된 Trigger의 타입이 event라면 Trigger에 서술된 Predicates를 공용 지식 저장소에 subscribe 한다. 이를 통해 공용 지식 저장소에서 대상 데이터가 생성되면 이를 알려주고, 이때 학습 데이터 관리기는 관련된 데이터를 수집하게 된다. 그리고 Trigger의 타입이 cyclic이라면 Trigger에 서술된 period에 따라 일정 시간마다 데이터를 가져온다.

데이터를 수집할 때에는 Predicates에 서술된 지식을 공용 지식 저장소에서 retrieve 프로토콜을 통해 요청하고, 공용 지식 저장소는 요청받은 지식과 매칭되는 지식을 반환한다.

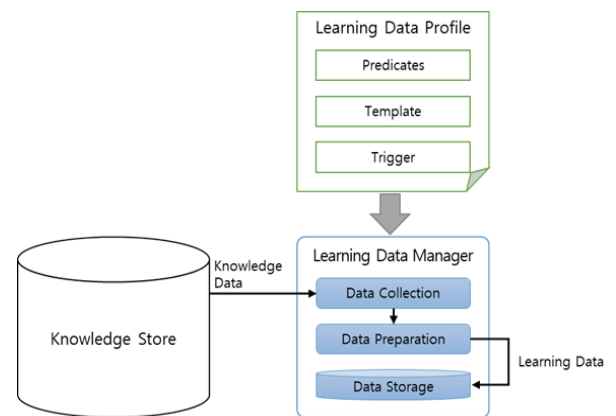


Fig. 8. Learning Data Manager Architecture

그리고 Predicates에 서술된 지식이나 Trigger에 서술된 predicates에 같은 이름의 변수가 있다면 해당하는 변수에는 전부 같은 값이 들어간 지식을 가져온다.

그리고 이렇게 수집된 지식에 포함된 데이터들과 Template에 서술된 데이터 양식을 활용하여 학습용 데이터를 만든다. 이때 Predicates에 포함된 변수와 Template에 포함된 변수 간의 맵핑을 통해 학습용 데이터를 생성한다. 이렇게 생성된 데이터는 Storage 항목에 서술된 정보를 바탕으로 저장소에 저장한다.

이러한 학습 데이터 관리기를 활용하면 학습 데이터를 수집하고자 할 때 수집 환경 및 학습모델에 따라 매번 데이터 수집 기능을 구현할 필요 없이 학습 데이터 프로파일을 추가함으로써 자동으로 원하는 데이터를 수집할 수 있도록 지원한다.

## 5. 실험

### 5.1 실험개요

본 논문에서 제안한 명세 기반 인공지능 학습용 데이터 수집 방법은 학습용 데이터셋 구축을 위해 필요한 정보들을 서술하는 프로파일과 이를 활용한 데이터 수집 프레임워크로 구성된다. 이러한 수집 대상 데이터를 서술하는 명세와 데이터를 수집하는 프레임워크의 분리를 통해 학습 데이터 프로파일의 재사용성 및 자동화된 데이터 수집 방법을 제공한다.

본 논문에서는 이를 검증하기 위하여 다음과 같이 실험을 구성하였다. 1) 무인기 기본 임무에서의 데이터 수집을 위한 프로파일 구성 및 학습 데이터 수집 수행. 2) 기본 임무에서 사용된 학습 데이터 프로파일을 재활용하여, 정찰 임무에서의 학습 데이터 수집 수행. 3) 기본 임무에서 사용된 학습 데이터 프로파일을 재활용하여, 추적 및 타격 임무를 위한 학습 데이터 프로파일 구성 및 데이터 수집.

이와 같은 세 단계의 실험을 통해 프로파일 기반 자동화된 학습 데이터 수집 및 학습 데이터 프로파일의 재사용성을 검증 진행하였다.

### 5.2 실험 환경

실험 환경에서는 각 임무의 개요, 임무 수행을 통해 생성되는 데이터 목록 및 임무별 학습 데이터 프로파일에 관해 서술한다.

#### 1) 무인기 기본 임무에서의 데이터 수집

무인기 기본 임무란 무인기에 탑재된 모듈을 활용하며 특정 지역을 비행하는 것으로, 본 실험에서 사용된 무인기의 모듈은 GPS, 카메라, 동압 센서, 정압 센서 및 지자기 센서이다. 다음 Table 6은 기본 임무 수행을 통해 생성되는 데이터를 정리한 것이다.

무인기가 임무를 수행하는 도중에는 기본적으로 무인기가 임무를 수행하는 시간을 GPS 시간으로 나타내는 GPS Time 이 생성된다. 그리고 무인기의 현재 위치 정보를 위도, 경도, 고도, 해발고도를 통해 나타내는 ownship position, 무인기의 속도 정보를 NED 형식으로 나타내는 ownship velocity,

Table 6. Data generated in UAV mission

| Predicate   | Description            |
|---|------------------------|
| (GpsTime \$msgid \$timestamp \$GpsTime)   | GPS time               |
| (OwnshipPosition \$msgid \$timestamp \$Latitude \$Longitude \$Altitude \$GroundAltitude)  | UAV position           |
| (Airdata \$msgid \$timestamp \$BaroAltitude \$AirTemperatureM \$CAS \$TAS \$GroundAltitude)                                     | Weather data           |
| (OwnshipVelocityNed \$msgid \$timestamp \$VelocityN \$VelocityE \$VelocityD)  | UAV velocity           |
| (OwnshipAttitude \$msgid \$timestamp \$RollAngleM \$PitchAngleM \$YawAngleM \$RollAngleAhmsM \$PitchAngleAhmsM \$YawAngleAhmsM) | UAV attitude           |
| (FlightDirection \$msgid \$timestamp \$FlightPathAngleM \$HeadingAngleM \$ClimbRate)  | UAV direction          |
| (DesignatedPosition \$msgid \$timestamp \$DesignatedLatitude \$DesignatedLongitude \$DesignatedAltitude \$DesignatedSlantRange) | Destination            |
| (CameraGimbal \$msgid \$timestamp \$CameraYawAngle \$CameraPitchAngle)  | camera angle           |
| (ObjectRecognized \$msgid \$timestamp \$objectID \$ObjectType \$Confidence)   | recognized object data |
| (CurrentDanger \$dangerType)  | UAV's current danger   |

비행 방향을 나타내는 flight direction, 무인기의 카메라 각도를 나타내는 camera gimbal과 같은 무인기의 상황 정보가 생성된다. 또한, 무인기 주변의 기온, 기압, 풍속과 같은 기상 데이터를 나타내는 Airdata, 무인기의 목적지를 고도, 위도, 경도로 나타낸 designated position, 무인기가 인식한 객체를 나타내는 object recognized, 그리고 무인기를 위협하고 있는 위협 정보를 나타내는 current danger와 같은 환경 정보들이 생성된다.

이 실험에서는 이러한 데이터로부터 임무 지역별 위협 발생 빈도를 학습하고, 이를 기반으로 위협 발생 확률이 높은 지역에서는 미리 위협을 예방하고자 하였다. 이를 위해서는 무인기가 위협을 받았을 때, 해당하는 위협 타입과 위협을 받은 시간, 장소에 대한 데이터를 수집해야 한다. 이러한 상황을 반영하여 다음 Table 7과 같은 학습 데이터 프로파일을 구성하였다.

#### 2) 정찰 임무에서의 데이터 수집

정찰 임무는 지정된 포인트를 따라 비행하며, 물체가 인식되거나 무인기에 위협이 가해졌을 때 이를 알리는 임무이다. 정찰 임무에서는 기존 임무와 비교하여 정찰 포인트에 대한 사전 지식이 추가로 존재한다.

이 실험에서는 기존의 임무를 확장한 새로운 임무에서도 기존의 학습 데이터 프로파일을 재사용할 수 있는지를 검증하기 위하여 구성되었다.

Table 7. Profile Example for Danger Data

```
{
  "profileID" : "profile001",
  "missionID" :
  "www.amad.com/demo/missionPackage/baseMission",
  "dependencies" : [],
  "predicates" : [
    "(CurrentDanger $DangerType)",
    "(OwnshipPosition $msgid $timestamp $Latitude
    $Longitude $Altitude $GroundAltitude)"
  ],
  "template" : {
    "dangerType" : "$DangerType",
    "timestamp" : "$timestamp",
    "Latitude" : "$Latitude",
    "Longitude" : "$Longitude"
  },
  "trigger" : {
    "type" : "event",
    "predicate" : "(CurrentDanger $DangerType)"
  },
  "storage" : {
    "type" : "MongoDB",
    "host" : "127.0.0.1",
    "port" : 27017,
    "databaseName" : "dangerDatabase",
    "collectionName" : "dangerCollection"
  }
}
```

이를 위해 기존 임무를 확장한 정찰 임무와 정찰 임무를 확장한 시가지 정찰, 숲 정찰 임무를 구성하였다. 또한 정찰 임무와 후술할 추적, 타격 임무를 동시에 참조하는 정찰-추적 임무, 정찰-타격 임무를 구성하였다. 여기서 각 임무는 기본적으로 정찰 임무를 수행하다가 특정 타겟이 발견되면 임무에 따라 타겟을 추적하거나 타격하도록 구성하였다. 이렇게 확장된 임무에서 표 8에 정의된 학습 데이터 프로파일과 후술할 정찰 및 타격 임무에서 정의된 학습 데이터 프로파일을 그대로 재사용하여 데이터 수집을 진행하였다.

3) 추적, 타격 임무에서의 데이터 수집

이 실험에서는 새로운 종류의 데이터를 수집하고자 할 때, 기존의 프로파일에서 관련된 데이터를 이미 수집 대상으로 지정하고 있다면 이를 재활용할 수 있는지를 검증하기 위해 구성하였다. 이를 위하여 기본 임무에서 확장된 추적, 타격 임무를 구성하였고, 각 임무에서 새롭게 생성되는 데이터를 활용하여 새로운 종류의 데이터를 수집할 때 기본 임무에서 정의한 프로파일을 참조하여 프로파일을 정의하고 데이터를 수집해보는 실험을 구성하였다.

먼저 추적 임무는 비행 도중 특정 타겟을 발견하였을 때 해당 타겟을 추적하는 임무이다. 그래서 기본 임무와 비교하여 무인기가 추적할 대상에 대한 사전 지식에 해당하는 tracking target, 무인기가 추적 타겟을 인식했을 때 발생하는 tracking target perceived, 무인기가 현재 추적 중인 대상을 나타내는 target tracked와 같은 데이터가 추가로 생성된다. 다음은 추적 임무 수행을 통해 생성되는 데이터를 정리하면 Table 8과 같다.

Table 8. Additional Data from Tracking Mission

| Predicate                      | Description                     |
|--------------------------------|---------------------------------|
| (TrackingTarget \$id)          | UAV's tracking target           |
| (TrackingTargetPerceived \$id) | UAV perceive target to tracking |
| (TargetTracked \$id)           | UAV's current tracking target   |

이 실험에서는 무인기가 타겟을 추적할 때 무인기의 위치를 기반으로 추적 경로를 수집하고, 이를 활용해 타겟의 타입에 따른 이동 경로를 학습하여, 추적 중인 대상을 잠시 놓쳤을 때 이동 경로를 예측하여 추적을 이어나갈 수 있도록 하고자 하였다. 이를 위해서는 무인기가 타겟을 추적 중일 때 타겟의 타입, 무인기의 위치, 시간 등의 데이터를 수집해야 한다. 이러한 상황을 반영하여 Table 9와 같은 학습 데이터 프로파일을 구성하였다.

앞서 서술한 수집 데이터에는 기존의 Table 7에서 정의한 프로파일에서 이미 수집하고 있는 데이터가 활용된다. 이렇게 기존에 존재하는 프로파일에서 이미 필요한 데이터를 수집하고 있기에 dependencies를 활용하여 기존의 프로파일을 일부분 재사용하여 프로파일을 구성하였다.

다음으로 타격 임무는 비행 도중 특정 타겟을 발견하였을 때 해당 타겟을 타격하는 임무이다. 그래서 기본 임무와 비교

Table 9. Profile Example for Moving Route Data

```
{
  "profileID" : "profile002",
  "missionID" :
  "www.amad.com/demo/missionPackage/areaTrackingMission",
  "dependencies" : ["profile001"],
  "predicates" : [
    "(TargetTracked $id)",
    "(ObjectRecognized $msgid $timestamp $id
    $ObjectType $Confidence)"
  ],
  "template" : {
    "ObjectType" : "$ObjectType",
    "timestamp" : "$timestamp",
    "Latitude" : "$Latitude",
    "Longitude" : "$Longitude"
  },
  "trigger" : {
    "type" : "cyclic",
    "period" : 1
  },
  "storage" : {
    "type" : "MongoDB",
    "host" : "127.0.0.1",
    "port" : 27017,
    "databaseName" : "movingRouteDatabase",
    "collectionName" : "movingRouteCollection"
  }
}
```



Table 10. Additional Data from Attack Mission

| Predicate                    | Description                   |
|------------------------------|-------------------------------|
| (AttackTarget \$id)          | UAV's attack target           |
| (AttackTargetPerceived \$id) | UAV perceive target to attack |
| (AttackResult \$id \$result) | Result of attack              |
| (TargetDistance \$id \$d)    | Distance from target          |

하여 무인기가 추적할 대상에 대한 사전 지식에 해당하는 attack target, 타격 타겟을 인식했을 때 발생하는 attack target perceived, 타겟과의 거리를 나타내는 target distance, 타격의 성공 여부를 나타내는 attack result와 같은 데이터가 생성된다. 다음은 추적 임무 수행을 통해 생성되는 데이터를 정리하면 Table 10과 같다.

이 실험에서는 무인기가 타겟을 타격할 때 타겟과의 거리, 타겟의 타입, 무인기의 위치, 기상 상태에 따라 타격의 성공 여부 데이터를 수집하고, 이를 활용해 타격 시 타격 성공률을 예측하여 명중률을 높일 수 있도록 하고자 하였다. 이를 위해서는 무인기가 타격하였을 때 무인기의 위치, 타겟의 타입, 타겟과의 거리 기상 데이터와 같은 데이터를 수집하여야 한다. 이러한 상황을 반영하여 Table 11과 같은 학습 데이터 프로파일을 구성하였다.

앞서 서술한 수집 데이터에서도 기존의 Table 7에서 정의한 프로파일에서 이미 수집하고 있는 데이터가 활용된다. 따라서 dependencies를 활용하여 기존의 프로파일을 일부분 재사용하여 프로파일을 구성해 보았다.

### 5.3 실험 결과

각 임무는 30분간 수행하였으며, 임무 별 생성된 지식의 수와 수집된 지식의 수는 Table 12와 같다.

본 실험을 통해 학습 데이터 프로파일에서 지정한 정보가 임무 수행 중 자동으로 수집된 것을 확인할 수 있었다. 또한 기존에 개발된 프로파일을 재사용하여 새로운 임무에 적용 하더라도 지정된 정보가 정상적으로 수집된 것을 확인할 수 있었다.

## 6. 결론 및 향후 연구 방향

주변 환경을 인식하고 자율적인 의사결정을 통해 임무를 수행하는 무인기를 위한 지능형 시스템은 기존 임무 수행 기록 등을 통해 개선된 임무 수행 능력을 갖춰야 하며, 이를 위해 시스템 내에서 생성되는 학습용 데이터 수집이 필요하다. 무인기가 수행하는 임무 목표는 정찰, 타격, 추적 등 다양한 종류가 존재하지만, 각 목표 달성을 위해 수행하는 작업 구조는 대체로 유사하다는 특징을 가지며, 이로 인해 각 임무 수행을 통해 대체로 비슷하지만 조금 다른 데이터가 생산된다. 하지만 임무별로 데이터 수집기를 개발하여 지능형 시스템 내 데이터 수집을 수행할 경우, 유사한 데이터의 수집을 위해 반복적인 개발이 필요하다는 한계점을 가진다.

Table 11. Profile Example for Attack Result Data

```

{
  "profileID" : "profile003",
  "missionID" :
  "www.amad.com/demo/missionPackage/attackMission",
  "dependencies" : ["profile001"],
  "predicates" : [
    "(TargetDistance $id $d)",
    "(ObjectRecognized $msgid $timestamp $id
    $ObjectType $Confidence)",
    "(Airdata $msgid $timestamp $BaroAltitude
    $AirTemperatureM $CAS $TAS $GroundAltitude)"
  ],
  "template" : {
    "ObjectType" : "$ObjectType",
    "timestamp" : "$timestamp",
    "Latitude" : "$Latitude",
    "Longitude" : "$Longitude",
    "$Altitude" : "$Altitude",
    "$distance" : "$d",
    "$airSpeed" : "$TAS",
    "$result" : "$result"
  },
  "trigger" : {
    "type" : "event",
    "predicate" : "(AttackResult $id $result)",
  },
  "storage" : {
    "type" : "MongoDB",
    "host" : "127.0.0.1",
    "port" : 27017,
    "databaseName" : "attackResultDatabase",
    "collectionName" : "attackResultCollection"
  }
}

```

Table 12. Number of Knowledge Generated and Collected in Experiment

| Mission         | Number of generated knowledge | Number of collected data |
|-----------------|-------------------------------|--------------------------|
| base            | 16,809                        | 11                       |
| patrol          | 16,794                        | 10                       |
| urban patrol    | 16,810                        | 11                       |
| forest patrol   | 16,725                        | 9                        |
| patrol-attack   | 16,897                        | 3                        |
| patrol-tracking | 18,055                        | 611                      |
| attack          | 16,720                        | 2                        |
| tacking         | 19,949                        | 1,776                    |

위와 같은 문제를 해결하기 위해 본 논문에서는 수집 대상 데이터를 서술하는 학습 데이터 프로파일과 이를 활용한 학습 데이터 자동 수집 프레임워크를 제안한다. 학습 데이터 프로파일은 임무 수행을 통해 생성되는 데이터 중 수집할 대상 및 대상의 저장 형식을 지정할 수 있도록 구성하였다. 학습 데이터 관리기는 학습 데이터 프로파일을 기반으로 지능형 시스템에서 지정된 데이터가 생성되면 해당 데이터를 자동으

로 수집 및 저장하는 기능을 지원하였다.

다양한 임무로 구성된 실험을 통해 학습 데이터 프로파일과 학습 데이터 관리기를 검증을 진행하였다. 기본 임무를 위해 개발된 학습 데이터 프로파일을 다른 임무에 재활용하여 프로파일의 재활용성을 검증하였으며, 다양한 임무에 대해 프로파일 기반 데이터 수집이 수행되는지 확인하였다.

본 논문에서는 지능형 시스템에서 학습모델을 활용하기 위해 필요한 학습 데이터를 수집하는 방법에 집중하였다. 하지만 수집된 데이터를 학습모델에서 활용하기 위해서는 추가적인 가공, 레이블링이 필요하다. 향후 연구에서는 학습 데이터 수집 프레임워크를 확장하여 수집된 데이터를 학습모델에 적용하기 위한 데이터의 가공 및 레이블링 기능을 개발하고 이를 검증할 것이다.

### References

[1] A. Goldhoorn, A. Garrell, R. Alquézar, and A. Sanfeliu, "Searching and tracking people with cooperative mobile robots," *Autonomous Robots*, Vol.42, No.4, pp.739-759, 2018.

[2] P. Rani, C. Liu, N. Sarkar, and E. Vanman, "An empirical study of machine learning techniques for affect recognition in human-robot interaction," *Pattern Analysis and Applications*, Vol.9, No.1, pp.58-69, 2006.

[3] C. Y. Park, H. S. Kim, and I. C. Kim, "Learning relational instance-based policies from user demonstrations," *Journal of KIISE : Software and Applications*, Vol.37, No. 5, pp.363-369, 2010.

[4] J. G. C. Zuluaga, J. P. Leidig, C. Trefftz, and G. Wolffe, "Deep reinforcement learning for autonomous search and rescue," *NAECON 2018-IEEE National Aerospace and Electronics Conference*, pp.521-524, 2018.

[5] J. G. C. Zuluaga, J. P. Leidig, C. Trefftz, and G. Wolffe, "Deep reinforcement learning for autonomous search and rescue," *NAECON 2018-IEEE National Aerospace and Electronics Conference*, IEEE, pp.521-524, 2018.

[6] Y. S. Ko et al., "Guideline of quality control for AI learning data v1.0," Ministry of Science and ICT, 2021.

[7] A. S. Rao and M. P. Georgeff, "BDI agents: From theory to practice," *ICMAS*, Vol.95, pp.312-319, 1995.

[8] H. K. Bui, Y. D. Lin, R. H. Hwang, P. C. Lin, V. L. Nguyen, and Y. C. Lai, "CREME: A toolchain of automatic dataset collection for machine learning in intrusion detection," *Journal of Network and Computer Applications*, Vol.193, pp.103212, 2021.

[9] J. Liu, F. Zhu, C. Chai, Y. Luo, and N. Tang, "Automatic data acquisition for deep learning," *Proceedings of the VLDB Endowment*, Vol.14, No.12, pp.2739-2742, 2021.

[10] B. Choi, J. Lee, S. Park, and J. Lee, "A Model-Based Interface to Cloud Services for Intelligent Service Robots," *KIPS Transactions on Software and Data Engineering*, Vol.9, No.1, pp.1-10, 2020.



김 동 기

<https://orcid.org/0000-0001-5384-3413>

e-mail : 7979us@gmail.com

2020년 서울시립대학교

전자전기컴퓨터공학부(학사)

2022년 서울시립대학교

전자전기컴퓨터공학과(석사)

관심분야 : 인공지능, 기계학습



최 병 기

<https://orcid.org/0000-0003-4202-2489>

e-mail : byunggi.choi@gmail.com

2010년 서울시립대학교

전자전기컴퓨터공학부(학사)

2012년 서울시립대학교

전자전기컴퓨터공학과(석사)

2020년 서울시립대학교 전자전기컴퓨터공학과(박사)

관심분야 : 인공지능, 소프트웨어 프레임워크, 작업관리



이 재 호

<https://orcid.org/0000-0002-3332-3207>

e-mail : jaeho@uos.ac.kr

1985년 서울대학교 계산통계학과(학사)

1987년 서울대학교 계산통계학과(석사)

1997년 University of Michigan(박사)

1998년 ~ 현 재 서울시립대학교

전자전기컴퓨터공학부 교수

관심분야 : 인공지능, 지능 로봇