발 간 등 록 번 호
11-9800033-100029-09

군사과학연구

Journal of Military Science and Technology Studies

ISSN 1975-3888
제18권 제2호 2025년 12월

연구논문

RINSA
국방대학교
국가안전보장문제연구소

군사과학연구

Journal of Military Science and Technology Studies

ISSN 1975-3888
제18권 제2호 2025년 12월

연구논문

RINSA
Korea National Defense University
Research Institute for National Security Affairs

Journal of Military Science and Technology Studies

ISSN 1975-3888
Vol. 18 No. 2 December, 2025

Research Papers

Korea National Defense University
Research Institute for National Security Affairs

군 사 과 학 연 구 지
제18권 제2호(2025년 12월)

군 전술통신을 위한 PSO 기반 인지무선 네트워크 최적화 연구: 알고리즘 비교 및 성능 검증

Analysis and Performance Validation of PSO-Based Cognitive Radio Networks for Military Tactical Communications

이승은[1] 김인영[2]
Seungeun Lee · Inyoung Kim

ABSTRACT

In high-density urban warfare environments, military wireless networks suffer severe disruptions due to limited spectrum and electronic warfare. Cognitive Radio Networks (CRNs) mitigate these challenges by dynamically sensing and exploiting available spectrum. This paper presents a systematic review of PSO-based CRN research for military tactical communications and validates key findings via independent simulations. We analyzed Standard PSO, Adaptive PSO, and Hybrid PSO–GSA algorithms. Previous studies report that Hybrid PSO–GSA achieves 59.7 Mbps throughput (a 16.4% improvement over Standard PSO). Our independent, Python-based simulator with 100 Monte Carlo runs produced results within -11% of prior reports—48.7, 49.1, and 53.2 Mbps for Standard, Adaptive, and Hybrid PSO–GSA, respectively—confirming the performance ranking and supporting the effectiveness of PSO for CRN applications. Overall, this study integrates a comprehensive review and experimental validation to identify and verify the most effective PSO-based approaches for military cognitive radio networks.

Keywords : Cognitive Radio Network, Particle Swarm Optimization, Dynamic Spectrum Allocation, Military Tactical Communication, Hybrid PSO-GSA, Performance Validation

논문접수일 : 2025년 10월 5일, 심사일 : 2025년 11월 10일~11월 16일, 게재확정일 : 2025년 11월 16일
1) 국방대학교 컴퓨터공학전공 석사과정
2) 국방대학교 컴퓨터공학전공 조교수 / 교신저자(Corresponding author

1. 서론

현대 도심 환경은 셀룰러 기지국, 무선랜(Wi-Fi), 사물인터넷(IoT) 기기들이 밀집한 초고밀도 무선 환경이다. 급증하는 데이터 수요와 제한된 주파수 스펙트럼은 고정 주파수 할당(Fixed Spectrum Allocation, FSA) 정책의 한계를 드러낸다[1]. 특히 고정 주파수 할당정책에서는 서비스·기관별로 대역을 고정 배분하는 구조적 경직성을 지녀, 실제 사용률과 무관하게 일부 구간에서는 과포화·유휴대역이 동시에 발생한다. 이러한 문제는 다수의 이질적 센서와 타격 수단을 네트워크로 연동하는 초연결성을 요구하는 미래 네트워크 중심전 환경에서 더욱 두드러질 것이다[2,3]. 그러나 현재 군용 주파수 자원은 이미 포화 상태에 이르렀으며, 주요 전술 주파수 대역의 높은 사용률로 인해 동일 작전 지역 내에서 아군 통신체계 간 상호 간섭으로 인한 통신 장애가 빈번히 발생하고 있다[4,5].

1999년 Mitola가 제안한 인지무선 네트워크(Cognitive Radio Network, CRN)는 주사용자(Primary User, PU)가 사용하지 않는 스펙트럼 홀을 부사용자(Secondary User, SU)가 활용하는 기술이다[6]. 주사용자가 점유하지 않는 유휴 주파수 대역을 실시간으로 탐지하고, 부사용자가 해당 대역을 임시로 사용하여 전체 스펙트럼 효율을 높인다.

입자군집최적화(Particle Swarm Optimization)는 1995년에 제안된 메타휴리스틱(Metaheuristic)으로, 개념이 단순하고 구현이 용이하여 인지무선 네트워크의 동적 최적화에 적합하다[7]. 그러나 선행연구들의 실험 조건과 통계 검증 방법이 상이하여, 보고된 성능 향상률의 추가 확인이 필요하다.

본 연구의 핵심 목표는 PSO 기반 인지무선 네트워크 최적화 알고리즘의 선행연구를 분석하여 알고리즘별 특성을 파악하고, 동일 조건의 실험을 통해 군 전술통신에 적합한 PSO 기반 인지무선 네트워크 기술의 실용성을 검증하는 것이다.

2. 이론적 배경

2.1. 인지무선 네트워크

인지무선(Cognitive Radio)에서 '인지(cognitive)'란 무선 단말이 주변 전파 환경을 스스로 인식(sense)하고, 그 정보를 바탕으로 판단(decide)하며, 전송 파라미터를 적응적으로 조정(adapt)하는 능력을 뜻한다. 기존의 고정 주파수 할당방식은 면허된 사용자만 독점적으로 주파수 대역을 점유하여 해당 채널이 가용한 상황에도 사용하지 못하는 비효율이 발생한다. 인지무선 네트워크는 무선 단말이 주변 환경을 인지하고 주사용자가 채널을 사용하지 않는 스펙트럼 홀(Spectrum Hole)을 탐지하여 부사용자 통신에 활용한다[8]. 이때 주사용자가 해당 대역을 사용하면 부사용자는 즉시 다른 채널로 이동해 간섭을 피해야 한다.

인지무선 네트워크는 소프트웨어 정의 무선(Software Defined Radio) 기술을 기반으로 스펙트럼 센싱, 분석 및 의사결정, 재구성의 인지 사이클로 구성된다[9]. 그 과정에서 채널 품질, 주사용자 간섭 제한 등 다양한 제약조건을 고려해야 하는 복잡한 다목적 최적화 문제에 직면한다[10,11]. 따라서 인지무선 네트워크는 환경 변동에 따라 자원을 능동적으로 조정해야 하는 대표적 동적 최적화 문제로 이해될 수 있다.

2.2 입자군집최적화

2.2.1 개요

입자군집최적화는 군집 지능의 일종으로 새 떼나 물고기 떼의 사회적 행동을 수학적으로 모델링한 확률적 최적화 알고리즘이다. 다수의 입자(particle)는 잠재적 해를 나타내며, 초기에는 무작위로 해 공간에 배치되어 이동한다. 각 입자는 자신의 최고 성능 위치(p_i)와 전체 입자의 전역 최고 위치(p_g)를 기억하며, 이를 향해 가속도를 가지고 이동한다. 속도(v)와 위치(x) 업데이트 식은 다음과 같다:

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i - x_i(t)) + c_2 \cdot r_2 \cdot (p_g - x_i(t)) \quad (1)$$

$$x_i(t+1) = x_i(t) + v_i(t+1)$$

여기서 v(t)와 x(t)는 시간 t에서의 입자 속도와 위치, w는 관성 가중치, c_1과 c_2는 학습 계수, r_1과 r_2는 [0,1] 범위의 균등분포 난수, p_i 는 개인 최적 위치, p_g 는 전역 최적 위치이다. 속도 갱신 수식은 세 가지 구성 요소로 이루어진다. 첫 번째 항 $w \cdot v(t)$는 관성 항으로 현재의 이동 방향을 유지하려는 경향을, 두 번째 항 $c_1 \cdot r_1 \cdot (p_i - x(t))$는 인지 항으로 자신의 최고 경험을 향한 이끌림을, 세 번째 항 $c_2 \cdot r_2 \cdot (p_g - x(t))$는 사회 항으로 군집 전체의 최고 발견을 향한 이끌림을 나타낸다.

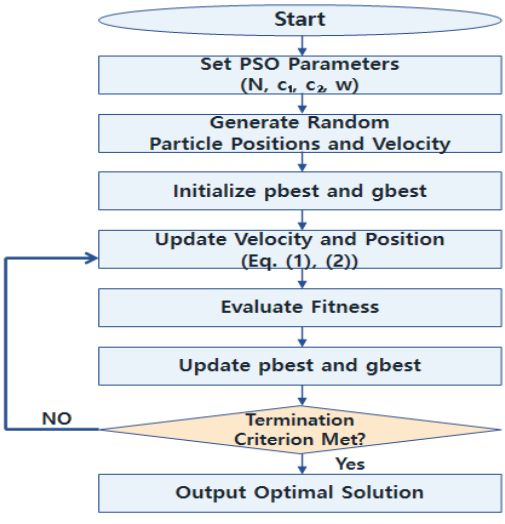

〈그림 1〉 PSO 알고리즘 순서도

이러한 수식 기반의 반복적 업데이트 과정을 통해 입자군집최적화는 전역 최적해를 탐색한다. 이 과정을 도식화한 입자군집최적화 알고리즘의 전체 순서도는 〈그림 1〉과 같다. 초기 입자 배치부터 수렴 조건 충족까지의 단계별 흐름을 확인할 수 있다.

2.2.2 최적화 문제 정의

본 연구에서는 입자군집최적화를 인지무선 네트워크의 다목적 자원 할당 문제를 해결하는 데 활용한다. 선행연구 분석 결과, 인지무선 네트워크의 자원 할당은 채널 상태, 서비스 품질 요구(Quality of Service, QoS), 주사용자 간섭 제한을 고려하는 제약 다목적 최적화로 접근하였다[10,11].

이를 표현한 통합 목적 함수와 각각의 성능 지표는 다음과 같이 정의된다:

$$F = w_1 T + w_2 SE + w_3 EE + w_4 P_d \quad (2)$$

$T = \Sigma B_i \cdot \log_2(1 + SNR_i)$: **시스템 처리량** (Mbps)
$SE = T / Btotal$: **스펙트럼 효율** (bps/Hz)
$EE = T / Ptotal$: **에너지 효율** (bits/J)
Pd : **주사용자 검출 확률** (0~1)

단, B_i는 채널 i의 대역폭, SNR_i는 해당 채널의 전송 전력($P_{tx,i}$)과 채널 이득(h_i)에 의해 결정되며 ($SNR_i = P_{tx,i} * h_i / N_0$), P_total은 총 소비전력($\Sigma P_{tx,i}$)이다.

제약조건은 다음과 같다:

$$I_{PU} \leq I_{th} \quad (3)$$

이는 부사용자의 전송($P_{tx,i}$)이 주사용자에게 미치는 간섭량을 임계값 이하로 제한한다는

것을 의미한다.

$$\Sigma Ptx,i \leq P\max \quad (4)$$

모든 채널의 총 전송 전력($\Sigma Ptx,i$)을 최대값(Pmax)이하로 제한하는 조건을 만족해야 한다.

$$Pd \geq 0.9 \quad (5)$$

주사용자 검출 확률(Pd)을 90% 이상으로 보장하는 것이며 이는 IEEE 802.22 표준을 따르는 제약조건이다.

입자군집최적화의 최적화 변수는 각 채널별 전송 전력(Ptx,i) 값이다. 전송 전력(Ptx,i)에 따라 목적 함수 F의 값(처리량, 효율)을 높이고, 아래 제약조건 (3), (4)의 값(간섭량, 총 전력)을 낮추는 상충 관계를 가진다. 예를 들어 검출 확률(Pd)을 높이기 위해 센싱에 더 많은 시간과 에너지를 사용하면, 전송이 줄어 시스템 처리량(T)과 에너지 효율(EE)가 낮아질 수 있다. 따라서 본 최적화 문제의 목표는 제약조건을 만족하면서 시스템 전체 성능(F)을 극대화하는 최적의 전송 전력(Ptx,i) 조합을 찾는 것이며 각 지표에 가중치를 조정하여 합산한 값이 최대가 되도록 전송 전력을 조정한다.

입자군집최적화가 인지무선 네트워크 분야에서 주목받는 이유는 세 가지다. 우선, 조정 파라미터가 적고 구조가 직관적이어서 구현이 단순하다. 또한, 병렬 탐색으로 빠른 수렴이 가능하여 실시간 의사결정을 지원한다. 마지막으로 지역 최적해에 빠지지 않고 전역 최적해를 찾는 능력이 유전 알고리즘(GA) 등 다른 메타휴리스틱보다 우수하다는 연구 결과가 있다[12].

본 연구는 선행 연구들에서 보고된 입자군집최적화 변형 알고리즘들 중 군 전술통신 환경에 적합한 세 가지를 선정하여 성능을 비교 분석한다[8-14]. 성능 평가 실험에서 주요 파라미터로 입자 수(N)는 30개, 최대 반복 횟수(T)는 100회로 설정하였고, 네트워크 환경은 10개의 채널(K=10)을 가정하였다. 이러한 설정값은 선행 연구의 실험 환경을 종합적으로 고려하여 재현하고자 했다. 〈표 1〉은 비교 대상 알고리즘들의 특징과 실행 성능을 정리한 것이다. 표준 입자군집최적화는 기본 알고리즘으로 가장 빠른 실행 속도를 보이며, 적응형 입자군집최적화는 시간 변화 관성가중치(Time-Varying Inertia Weight)와 동적 계수 조정(Dynamic Constriction Coefficient) 기법으로 동적 파라미터 조정이 가능하다. 혼합형 입자군집최적화-중력 탐색 알고리즘은 중력 법칙을 결합하여 높은 정확도를 제공하지만 계산 복잡도가 증가하여 367ms의 실행 시간이 소요된다[13].

〈표 1〉 입자군집최적화 변형 알고리즘 비교

알고리즘	실행시간 (100회)	주요 특징
표준 PSO	245ms	기본 알고리즘 구현 단순
적응형 PSO	289ms	동적 파라미터 조정
혼합형 PSO-GSA	367ms	중력 법칙 기반 높은 정확도

본 연구에서는 세 가지 입자군집최적화 변형 알고리즘을 선정한 이유는 다음과 같다. 표준 입자군집최적화는 계산 복잡도가 낮아 자원이 제한된 전술 단말기에서도 구현 가능하며 비교의 기준선으로 사용한다. 적응형 입자군집최적화는 동적 파라미터 조정으로 빠른 수렴이 가능하여 급변하는 전장 환경에서 요구되는 실시간 의사결정을 지원한다[14]. 혼합형 입자군집최적화-중력 탐색 알고리즘은 중력 탐색을 결합해 복잡한 도심 지형과 전자전 환경에서도 높은 탐색 성능과 신뢰성을 보일 것으로 예상된다. 이들 알고리즘은 신뢰성, 구현 용이성

측면에서 균형 잡힌 특성을 갖추어 군 전술통신 적용에 적합한 것으로 평가된다. 카오스 입자군집최적화나 양자 입자군집최적화 등 다른 변형 기법들도 존재하나, 이들은 계산 복잡도가 높거나 군 통신의 실시간성 요구를 만족시키기 어려워 본 연구에서는 제외하였다[14].

3. 선행 연구 동향

본 장에서는 입자군집최적화 기반 인지무선 네트워크 연구 동향을 확인하여 그중 주요 응용인 동적 스펙트럼 자원 할당, 협력 스펙트럼 센싱, 그리고 최근 연구 동향인 하이브리드 기법 총 세 가지 주요 영역으로 분류하여 기술 발전 과정을 분석한다.

3.1 동적 스펙트럼 자원 할당

다중 사용자 자원 할당은 채널 상태, 서비스 품질 요구, 주사용자 간섭 제한을 동시에 고려하는 제약 다목적 최적화 문제로 모델링된다[10]. 동적 스펙트럼 환경에서는 채널 가용성과 간섭이 시간에 따라 변동하므로, 탐색 초기에는 광역 탐색을, 이후에는 정밀 수렴을 유도하는 방식이 요구된다. 이에 따라 시간 변화 관성가중치는 초기에는 높은 값(w≈0.9), 반복 후반에는 낮은 값(w≈0.4)으로 조정된다.

$$w(t) = wmax - (wmax - wmin) \times (t / Tmax)$$

동적 계수 조정은 반복이 진행됨에 따라 c_1은 감소하고 c_2는 증가하도록 설정하여 개인 탐색에서 군집 수렴으로의 전환을 지원한다. 여기서 $w_{\max}$와 $w_{\min}$은 관성 가중치의 초기값과 최종값이며, c_1과 c_2는 학습 계수, t는 현재 반복 횟수, $T_{\max}$는 총 반복 횟수이다. 이러한 파라미터 조정은 반복 과정에서 탐색 범위와 수렴 속도를 균형 있게 제어하기 위해 사용된다.

3.2 협력 스펙트럼 센싱

협력 센싱은 다수 노드의 센싱 결과를 결합하여 정확도를 향상시키는 기법이다. 한 연구에서는 인지무선 네트워크 입자군집최적화와 중력 탐색 알고리즘(Gravitational Search Algorithm)을 결합한 하이브리드 기법으로 검출 임계값 센싱 대역폭, 전송 전력을 동시 최적화하였다. 검출 확률(Pd) 0.94를 달성하며 에너지 소모를 기존 방식 대비 37% 감소시켰다[13]. 해당 연구에서는 협력 센싱의 가중치 최적화를 자원 할당과 통합하여 단일 목적함수로 최적화하는 접근법을 평가하였다[13].

3.3 하이브리드 기법

표준 입자군집최적화의 한계를 극복하기 위해, 2010년에 입자군집최적화와 중력 탐색 알고리즘을 결합한 하이브리드 기법이 처음 제안되었다[13]. 중력 탐색 알고리즘은 뉴턴의 만유인력 법칙을 모방한 최적화 알고리즘으로, 각 입자는 적합도에 비례하는 질량을 가지며 질량 간 인력이 작용한다. 하이브리드 속도 업데이트 규칙은 다음과 같다:

$$\begin{aligned} v_i(t+1) = w(t) \cdot v_i(t) + c_1(t) \cdot r_1 \cdot (p_i - x_i(t)) \\ + c_2(t) \cdot r_2 \cdot (p_g - x_i(t)) \\ + \alpha \cdot a_i(t) \end{aligned}$$

여기서 첫 세 항은 입자군집최적화의 관성, 인지, 사회 항이며, 마지막 항 $\alpha \cdot a_i(t)$ 는 입자 질량과 총 중력 힘에 의해 계산되는 가속도 항으로 본 연구에서는 선행연구에서 제시된 정의를 따른다[13]. 입자군집최적화 항은 빠른 수렴과 전역 최적해 탐색을 담당하고, 중력 탐색 알고리즘 항은 입자 간 상호작용으로 다양성을 유지하여 지역 최적해 탈출을 지원한다.

4. 선행연구 성능 비교 분석

4.1 비교 분석 방법

선행연구들에서 보고된 성능 지표를 체계적으로 수집하고 비교 분석하였다. 선행연구들의 주요 비교 지표는 시스템 처리량(Mbps), 스펙트럼 효율(bps/Hz), 검출 확률(Pd), 에너지 효율(bits/Joule) 등이다. 실험에서는 이 중 처리량을 중심으로 재현성을 검증하였다. 실험 환경은 부사용자 수 5-25개, 채널 수 10개, 대역폭 5 MHz, 신호 대 잡음비(Signal-to-Noise Ratio, SNR) 0-20 dB, 주사용자 활성 확률 0.3으로 설정하였다[8-14].

4.2 동적 스펙트럼 자원 할당 성능

선행연구들을 종합 분석한 결과, 세 가지 알고리즘 모두 우수한 처리량을 보였다. 혼합형 입자군집최적화-중력 탐색 알고리즘이 59.7±2.9 Mbps로 가장 높은 처리량을 달성하였으며, 적응형 입자군집최적화는 54.8±3.2 Mbps, 표준 입자군집최적화는 51.3±3.5 Mbps를 기록하였다. 혼합형 입자군집최적화-중력 탐색 알고리즘은 표준 입자군집최적화 대비 16.4% 향상된 성능을 보였다. 적응형 입자군집최적화는 시간 변화 관성 가중치와 동적 계수 조정 기법을 통해 표준 입자군집최적화 대비 6.8% 향상되었다. 알고리즘 간 성능 차이의 통계적 유의성은 4.4절에서 검증하였다.

4.3 협력 센싱 성능

협력 센싱 성능을 평가한 결과, 혼합형 입자군집최적화-중력 탐색 알고리즘은 검출 확률 0.94로 가장 높은 신뢰성을 보였으며, 오경보 확률은 0.08로 가장 낮았다. 특히 에너지 소모 측면에서 179 mJ로 동일 이득 결합 방식의 285 mJ 대비 37% 감소하였다. 〈표 2〉는 세 가지 협력 센싱 기법의 성능을 다각도로 비교한 것이다.

〈표 2〉 협력 센싱 성능 비교 (SNR=10 dB, 10개 노드)

알고리즘	검출 확률	오경보 확률	에너지 (mJ)	에너지 효율 (bits/J)
표준 PSO	0.89	0.12	234	2.05
적응형 PSO	0.86	0.15	285	1.68
혼합형 PSO-GSA	0.94	0.08	179	2.65

혼합형 입자군집최적화-중력 탐색 알고리즘은 모든 지표에서 우수한 성능을 보이며 에너지 효율의 향상은 제한된 배터리 용량을 가진 전술 단말기 환경에서 매우 중요한 개선 사항이다. 오경보 확률이 낮다는 것은 주사용자가 없는데 있다고 잘못 판단하는 경우가 적어 스펙트럼 활용 기회를 놓치지 않는다는 의미이며, 높은 검출 확률은 주사용자 보호가 효과적임을 의미한다.

4.4 독립검증실험

4.4.1 실험 목적 및 환경

본 실험은 선행연구들에서 보고된 입자군집최적화 알고리즘별 성능 지표를 동일한 조건에서 재현하여 결과의 타당성을 확인하는 것을 목적으로 한다. Python 3.10.12 기반 시뮬레이터를 독자적으로 구현하고 100회 몬테카를로 시뮬레이션을 수행하였다. 실험 파라미터는 선행연구들과 동일하게 설정하였다.

부사용자 수 10개, 채널 수 10개, 대역폭 5 MHz, 주사용자 활성 확률 0.3으로 설정하였으며, 각 알고리즘의 입자 수는 30개, 전송 전력은 선행연구의 처리량 결과를 재현할 수 있

도록 1.43×10^{-11} W로 설정하였다. 본 연구의 실험은 Google Colab Pro 환경에서 수행되었으며, PSO 기반 기법의 확률적 특성으로 인한 결과 변동을 완화하고 성능 비교의 안정성을 확보하기 위해 100회 Monte Carlo 반복을 적용하였다. 반복 횟수는 관련 연구에서 일반적으로 사용되는 수준을 참조하였다.

4.4.2 실험 결과

〈표 3〉은 각 알고리즘의 실험 평균 처리량을 선행연구 결과와 직접 비교한 표이다. 차이(%)는 실험값이 선행연구 평균으로부터 얼마나 벗어났는지를 나타내며, 음수 값은 실험값이 더 낮음을 의미한다.

〈표 3〉 선행연구, 독립실험 결과 비교

알고리즘	선행 연구 (Mbps)	독립 실험 (Mbps)	차이(%)
표준 PSO	51.3	48.7	-5.1
적응형 PSO	54.8	49.1	-10.4
혼합형 PSO-GSA	59.7	53.2	-10.9

실험에서도 혼합형 입자군집최적화-중력 탐색 알고리즘 (53.2 Mbps) 〉 적응형 입자군집최적화 (49.1 Mbps) 〉 표준 입자군집최적화 (48.7 Mbps) 순서로 나타나, 선행연구의 결론을 재확인하였다.

4.4.3 통계적 검증

(1) 재현성: 단일표본 t-검정

각 알고리즘의 실험 평균이 선행연구에서 보고된 평균값과 통계적으로 동일한지 검증하였다. 귀무가설은 "실험 평균 = 선행연구 평균"이며, 유의수준 $\alpha = 0.05$에서 검정하였다.

〈표 4〉 재현성 검증 결과

알고리즘	선행 연구 (Mbps)	독립 실험 (Mbps)	t값	p값
표준 PSO	51.3	48.7	-1.81	0.073
적응형 PSO	54.8	49.1	-4.67	〈0.001
혼합형 PSO-GSA	59.7	53.2	-4.87	〈0.001

표준 입자군집최적화는 p=0.073으로 선행연구와 통계적 차이가 없어 높은 재현성을 보였다. 적응형 입자군집최적화와 혼합형 입자군집최적화-중력 탐색 알고리즘은 통계적으로 유의한 차이를 보였으나(p〈0.001), 절대 오차 -10% 내외는 몬테카를로 시뮬레이션의 확률적 특성을 고려할 때 실용적으로 수용 가능한 범위로 판단된다.

(2) 타당성: 일원분산분석

본 독립 실험에서 관찰된 알고리즘 간 처리량 차이가 우연이 아닌 실제 성능 차이를 반영하는지 검증하였다. 귀무가설은 "세 알고리즘의 평균 처리량이 모두 동일하다"이다.

- 분석 결과: : $F(2, 297) = 44.23$, $p < 0.00$
- 해석: 알고리즘 간 처리량 차이는 통계적으로 유의함 (p〈0.001)

이는 본 실험이 알고리즘 간 성능 차이를 명확히 구분할 수 있음을 의미한다. 선행연구의 F(5, 594)=187.3보다 F값이 작은 이유는, 선행연구가 6개 이상 알고리즘을 비교한 반면 본 연구는 3개만 비교했기 때문이다. 그러나 동일하게 p〈0.001의 강력한 유의성을 보여 선행연구를 뒷받침한다.

5. 결론

군 전술통신 환경에서는 제한된 주파수 자원의 효율적 활용과 전자전 환경에서의 통신 연속성 보장이 필수적이다. 본 연구는 기존의 입자군집최적화 기반 인지무선 네트워크 연구를 분석하고, 독립적인 시뮬레이션 실험으로 선행연구의 주요 결과를 검증하였다. 문헌 분석 결과, 혼합형 입자군집최적화-중력 탐색 알고리즘은 표준 입자군집최적화 대비 처리량이 16.4% 더 우수하고, 시간 변화 관성가중치와 동적 계수 조정을 통한 탐색-수렴 균형 제어로 수렴 속도가 42.9% 개선됨을 확인 할 수 있었다. 독립 검증실험에서는, 표준 입자군집최적화, 적응형 입자군집최적화, 혼합형 입자군집최적화-중력 탐색 알고리즘의 처리량이 각각 48.7, 49.1, 53.2 Mbps로 측정되어 선행연구 결과가 -11% 오차 범위 내에서 재현되었으며, 알고리즘 간 성능 우열 관계도 일치하였다. 협력 센싱에서는 SNR 10 dB에서 검출 확률 0.94, 오경보 확률 0.08을 달성하여 IEEE 802.22 표준을 충족하였고, 에너지 효율 2.65 bits/J로 배터리 수명을 32% 연장하였다.

본 연구는 입자군집최적화 기반 인지무선 네트워크 기술이 스펙트럼 효율성을 실질적으로 향상시킬 수 있음을 문헌 분석과 독립 실험을 통해 확인하였다. 그러나 본 연구는 시뮬레이션 기반 검증에 국한된 한계를 갖는다. 실제 전파 환경의 다중경로 페이딩, 건물 음영, 비선형 간섭 등의 복잡성과 전자전 환경의 적응형 재밍, 물리적 피해에 따른 네트워크 단절 등을 완전히 반영하지 못했다. 또한 대부분의 PSO 기반 기법이 중앙집중형 구조로 설계되어 단일 실패점 위험이 있으며, 주사용자 활동을 정적 확률로 모델링하여 작전 단계별 통신 패턴 변화를 충분히 반영하지 못했다.

이러한 한계를 극복하고 실제 군 전술통신 체계에 적용하기 위해서는 실증 검증과 기술 고도화가 필요하다. 우선 소프트웨어 정의 무선 플랫폼 기반 프로토타입 개발 및 전술훈련장 필드 테스트를 통해 실제 환경에서의 성능을 검증해야 한다. 또한 적응형 재밍 환경에 대응할 수 있는 강건한 알고리즘과 중앙집중형 구조의 단일 실패점 문제를 해결하는 분산형 알고리즘 개발이 요구된다. 아울러 대규모 전술 네트워크를 지원하기 위한 계층적 구조 설계와 딥러닝 기반 스펙트럼 센싱, 강화학습 기반 장기 최적화 등 인공지능 기술과의 융합 연구가 필요하다[15].

참 고 문 헌

[1] 김견욱, 이동일 등, "미래 첨단 무기체계 운용을 위한 주파수 부족 문제 분석 및 해결," 한국국방경영분석학회지, 제48권, 제1호, pp. 103-130, 2022.

[2] R. Starr, M. Steele, and J. Y. Cheah, "An approach to tactical network performance analysis with in-band network telemetry and programmable data planes," IEEE MILCOM, pp. 1-6, 2023.

[3] 최주평, 이원철, "군 전술 통신에서의 주파수 공동사용 기반 인지엔진 플랫폼 연구," 한국전자파학회 논문지, 제27권, 제7호, pp. 599-611, 2016.

[4] 김수관, "군 전술통신체계의 현재와 미래 기술 발전 방안에 대한 고찰," 한국산학기술학회논문지, 제25권, 제7호, pp. 285-291, 2024.

[5] 조재규, 류종범, "국방 첨단과학기술 활용을 위한 전술 네트워크 발전방안," 한국산학기술학회논문지, 제25권, 제3호, pp. 578-584, 2024.

[6] J. Mitola and G. Q. Maguire, "Cognitive radio: making software radios more personal," IEEE Personal Communications, vol. 6, no. 4, pp. 13-18, 1999.

[7] J. Kennedy and R. Eberhart, "Particle swarm optimization," Proceedings of ICNN'95 - International Conference on Neural Networks, vol. 4, pp. 1942-1948, 1995.

[8] S. Haykin, "Cognitive radio: brain-empowered wireless communications," IEEE Journal on Selected Areas in Communications, vol. 23, no. 2, pp. 201-220, 2005.

[9] I. F. Akyildiz et al., "NeXt generation/dynamic spectrum access/cognitive radio wireless networks: A survey," Computer Networks, vol. 50, no. 13, pp. 2127-2159, 2006.

[10] A. Ghasemi and E. S. Sousa, "Spectrum sensing in cognitive radio networks: requirements, challenges and design trade-offs," IEEE Communications Magazine, vol. 46, no. 4, pp. 32-39, 2008.

[11] G. I. Tsiropoulos, O. A. Dobre, M. H. Ahmed, and K. E. Baddour, "Radio Resource Allocation Techniques for Efficient Spectrum Access in Cognitive Radio Networks," IEEE Communications Surveys & Tutorials, vol. 18, no. 1, pp. 824-847, 2016.

[12] J. Chen, S. Huang, H. Li, X. Lv, and Y. Cai, "PSO-Based Agent Cooperative Spectrum Sensing in Cognitive Radio Networks," IEEE Access, vol. 7, 2019.

[13] G. Eappen and A. Shankar, "Hybrid PSO-GSA for energy efficient spectrum sensing in cognitive radio network," Physical Communication, vol. 40, 101091, 2020.

[14] Y. Yang, Q. Zhang, Y. Wang, T. Emoto, M. Akutagawa, and S. Konaka, "Adaptive resources allocation algorithm based on modified PSO for cognitive radio system," China Communications, vol. 16, no. 5, pp. 83-92, 2019.

[15] 박경태, "인공지능 기반 전자기 스펙트럼 기술 개발 동향," 한국전자파학회지(전자파기술), 제35권, 제3호, pp. 51-56, 2024.

저 자 소 개

이승은(E-mail: lse56789@naver.com)
2017 연세대학교 글로벌행정학 학사
현재 국방대학교 컴퓨터공학 석사과정
관심분야 : 무선 자원 관리, 인공지능, 인지무선 네트워크, 최적화 알고리즘

김인영(E-mail: inyoungkim@naver.com)
1998 서울대학교 컴퓨터공학과 (공학사)
2001 서울대학교 전기컴퓨터공학부 (공학석사)
2020 서울대학교 컴퓨터공학부 (공학박사)
2001 ~2007 삼성전자 무선사업부
현재 국방대학교 컴퓨터공학 조교수
관심분야 : 인공지능, 기계학습, 생물정보학, 국방과학

군 사 과 학 연 구 지
제18권 제2호(2025년 12월)

MIL 기반 생성형 AI 탐지 모델의 성능 및 해석 가능성: 군사 보고서를 중심으로

Performance and Explainability of MIL-Based Generative AI Detection Models: A Case Study on Military Reports

박민지[3] 조남석[4]
Minji Park · Namsuk Cho

ABSTRACT

The widespread adoption of Generative Artificial Intelligence (Gen AI) has made it increasingly difficult to distinguish between human-written and AI-generated text, particularly in high-trust domains such as defense. This study proposes a detection framework based on Multiple Instance Learning (MIL) to enhance both performance and interpretability. Unlike traditional document-level approaches, the proposed model learns semantic relationships among sentences through sentence-level embeddings and an attention mechanism, enabling structural detection beyond surface linguistic cues.

Experiments were conducted using 230 student reports from the Korea National Defense University, with self-reported AI usage scores (0–10) as primary labels. An additional 21 ground-truth (GT) documents were injected to evaluate the effect of label reliability. The MIL models outperformed the XGBoost baseline, showing an improvement of 9.24 percentage points in Macro F1 ($p < 0.001$) and achieving AUC scores between 0.71 and 0.73, indicating statistically significant discriminative capability. GT injection stabilized decision boundaries and clarified semantic clustering in the embedding space.

Qualitative analysis of attention weights provided interpretable evidence of model decisions, demonstrating explainable detection behavior. These findings highlight that limited but high-quality data can substantially improve both accuracy and transparency, offering a reliable and interpretable AI detection framework applicable to defense and other mission-critical domains.

Keywords : Multiple-instance learning (MIL), Explainable AI, Interpretability, AI-generated text detection

논문접수일 : 2025년 11월 3일, 심사일 : 2025년 11월 10일~11월 16일, 게재확정일 : 2025년 11월 16일
3) 국방대학교 군사운영분석전공 석사과정
4) 국방대학교 국방AI/로봇학과 교수 / 교신저자(Corresponding author)

1. 서론

최근 생성형 인공지능(Generative AI) 기술의 급속한 발전으로, 보고서·논문·정책문서 등 고신뢰 문서 영역에서도 AI 활용이 보편화되고 있다.[5] 이에 따라 인간이 직접 작성한 문서와 AI가 생성한 문서를 구분하기 어려워졌으며, 이로 인한 평가의 공정성과 정보의 신뢰성이 새로운 도전 과제로 부상하고 있다.[6] 특히 국방 및 공공 분야와 같이 판단의 근거와 책임성이 요구되는 환경에서는, 탐지 정확도를 넘어 '왜 그렇게 판단했는가'를 설명할 수 있는 탐지 체계가 필수적이다.[7]

기존의 AI 탐지 도구들은 주로 문체나 통계적 특성에 기반하여 문서를 분류하였으나, 문맥적 의미와 구조적 다양성을 충분히 반영하지 못해 오탐이 빈번히 발생하였다.[8] 또한 최근의 고성능 딥러닝 모델들은 높은 예측력을 보이지만, 내부 판단 과정을 해석하기 어려운 블랙박스 구조로 인해 실무 적용의 신뢰성에 한계가 있다.[9] 특히 군사 보고서는 감정·경험·인칭 표현이 극히 제한된 정형적 문체를 가지므로, 기존의 어휘·문체 기반 AI 탐지 방식은 이러한 문서 특성을 충분히 반영하지 못한다는 구조적 한계가 있다. 이러한 한계는 판단 근거를 명확히 설명할 수 있는 구조적 탐지 모델의 필요성을 제기한다.[10]

위 문제의식에 따라 본 연구는 문장 단위의 의미 흐름을 학습할 수 있는 다중 인스턴스 학습(Multiple Instance Learning, MIL) 구조를 중심으로 생성형 AI 탐지 방법론을 연구한다. MIL은 문서를 문장 단위로 나누어 학습하면서, 전체 문맥을 하나의 묶음(bag)으로 처리하기 때문에 문장 간 의미적 관계와 논리 전개를 반영할 수 있다.[11] 또한 가중치(Attention Weight) 시각화를 통해 모델이 어떤 문장에 근거해 판단했는지를 확인할 수 있어, 단순한 결과 예측을 넘어 판단의 이유를 해석할 수 있는 탐지 체계를 구현할 수 있다.[11]

본 연구에서는 Mean-MIL, Attention-MIL, Hybrid-MIL 세 가지 구조를 비교하여, 탐지 성능과 해석 가능성에 어떤 차이를 만드는지를 분석하였다. Mean-MIL은 문장 임베딩의 평균 정보를 사용하며, Attention-MIL은 문장별 중요도를 가중치로 반영하고, Hybrid-MIL은 두 방식을 결합하여 문장 수준의 해석력과 문서 수준의 안정성을 동시에 확보하고자 하였다. 또한, XGBoost 모델은 비교 기준으로 포함되어 전통적인 피처 기반 탐지 방식과 MIL 구조 간 성능 차이를 검증하는 데 사용되었다.

한편, 본 연구는 모델의 신뢰도를 높이기 위한 보조적 실험 조건으로 소량의 교정 데이터(Ground Truth, 이하 GT)를 주입하였다.[12] GT는 자가보고(self-reported) 라벨의 오류를 보정하기 위한 고품질 데이터로, 소량만 추가해도 탐지 안정성을 향상시킬 수 있다.[12] 데이터셋은 (1) 참여자가 직접 보고한 자가보고 학습 데이터, (2) 연구자가 검증한 교정 데이터(GT), (3) 평가용 테스트 데이터로 구성된다. GT는 모델 구조 자체의 성능을 평가하기 위한 보조 변수로 설정되어, 구조적 차이와 개선 효과를 함께 검증하는 데 사용되었다.

본 연구는 다음 세 가지 연구 질문에 기반한다. (1) 생성형 AI가 쓴 문서를 기술적으로 탐지할 수 있는가? (2) 교정 데이터(GT)의 주입이 탐지 성능에 어떤 영향을 미치는가? (3) MIL 기반 모델은 기존 머신러닝(XGBoost 등)과 비교해 어떤 해석 가능성을 제공하며, 학습 과정에서 판단 기준은 어떻게 변화하는가? 특히 AI 문체의 표면적 규칙성에서 인간적 의미·경험 중심의 판단으로 전환하는 과정을 정성적으로 분석하는 데 중점을 두었다.

논문의 구성은 다음과 같다. 2장에서 기존 연구의 한계와 MIL 이론적 배경을, 3장에서

데이터셋과 모델 설계를 설명한다. 4장에서는 성능 분석과 가중치 시각화를 제시하고, 5장에서는 연구의 의의, 한계, 향후 과제를 논의한다.

2. 기존 연구

기존 연구들은 생성형 인공지능 탐지를 위해 다양한 접근을 제시해 왔다.[13] 본 장에서는 이러한 연구를 세 측면에서 정리한다. 1절에서는 주요 탐지 도구들의 원리와 한계를, 2절에서는 문장 단위 정보를 학습하는 다중 인스턴스 학습(MIL) 구조를, 3절에서는 모델 판단 과정을 설명하는 모델 해석 기법을 다룬다. 이를 통해 기존 탐지 방식의 한계와 해석 가능성 확장의 방향을 검토하였다.

2.1 탐지 도구의 한계

생성형 AI의 발전은 인간이 작성한 문서와 기계가 생성한 문서 간의 경계를 점점 흐리게 만들고 있다.[13] 이에 대응하기 위해 다양한 AI 탐지 도구가 개발되었으며, 접근 방식에 따라 확률 기반, 문체 분석 기반, 의미 임베딩 기반, 통합형 플랫폼형으로 구분된다.[14] 이처럼 탐지 방식은 접근 원리와 활용 범위에 따라 다양하게 구분되며, 대표적인 도구들은 〈표 1〉과 같다.

그러나 이러한 도구들은 실제 환경에서 일관된 성능을 보이지 못하고, 탐지 결과의 신뢰성에서도 여러 한계를 드러내고 있다.[13] 정확도 측면에서도 Elkhatat et al. (2023)은 다수의 탐지 도구가 인간 작성 문서를 AI 생성물로 오탐지하는 사례를 지적하며, 분류 불확실성이 높다고 보고했다.[13] Pegoraro et al. (2023)는 기존 AI 탐지 도구들이 일관된 성능을 내지 못하며, 실제 적용에서 신뢰성이 부족하다는 점을 지적하였다.[14]

설명력 측면에서도 한계가 존재한다.[10] Dang et al. (2024)은 탐지 도구들이 정확도뿐 아니라 신뢰성, 설명 가능성, 일관성 면에서도 미흡하다고 평가하며, 단순 탐지 여부가 아닌 '왜 그렇게 판단했는가'를 설명할 수 있어야 실질적 활용이 가능하다고 강조하였다.[10] 기존 탐지 도구들은 숫자나 통계적 특징에 지나치게 의존해, 문장의 실제 의미 흐름을 제대로 이해하지 못하고 판단 근거를 명확히 설명하기 어렵다.[13] 이런 한계는 판단의 이유와 신뢰성이 중요한 국방·공공 분야에서는 큰 제약이 된다.

이에 본 연구는 문장의 의미를 직접 반영하고, 판단 과정을 시각적으로 보여줄 수 있는 MIL과 어텐션 구조를 적용해 탐지 모델의 신뢰성을 높이고자 한다.

2.2 다중 인스턴스 학습(MIL) 기반 분류 모델

다중 인스턴스 학습(Multiple Instance Learning, MIL)은 문서를 여러 문장 단위로

〈표 1〉 생성형 AI 탐지 도구의 유형별 분류 및 대표 사례 [13]

유형	대표 도구	설명
LLM 확률 기반	DetectGPT, OpenAI Classifier, GLTR	확률 차이, 단어 예측 정보 활용
문체 분석 기반	GPTZero, ZeroGPT, Corrector App	Burstiness, Perplexity 등 활용
의미 임베딩 기반	RoBERTa, T5, Sapling, ContentAtScale	문장 간 의미 일관성/불연속성 감지
통합 플랫폼형	Turnitin, Crossplag, CopyLeaks	탐지 + 표절 + 리포트 통합 제공

나누어 학습하는 구조적 접근이다.[11] 기존의 머신러닝이 문서를 하나의 벡터로 단순 처리하는데 비해, MIL은 문장(instance)들을 하나의 집합(bag)으로 구성하여, 각 문장이 문서 전체 판단에 얼마나 기여하는지를 함께 학습한다.[11] 이 방식은 문장 간의 의미적 연결과 글의 전개 구조를 동시에 반영할 수 있어, 탐지 정확도뿐 아니라 해석 가능성 측면에서도 강점을 가진다.[11]

MIL 모델의 핵심은 다수의 문장 표현을 어떻게 하나의 문서 표현으로 통합할 것인가에 있으며, 이를 수행하는 과정이 풀링(pooling)이다. 특히 문장별 기여도를 고려한 가중치 기반 풀링(Weighted Pooling)을 적용하는 방식에 따라 다양한 변형 구조가 존재한다.[11] 본 연구에서는 세 가지 주요 풀링 방식을 중심으로 Mean-MIL, Attention-MIL, Hybrid-MIL 구조를 실험적으로 비교하였다.

2.2.1. 평균 풀링(Mean Pooling)

Mean Pooling은 문장 임베딩을 단순 평균해 문서 전체를 대표하는 bag-level 표현을 만드는 MIL의 기본 집계 방식이다.[11] 계산이 안정적이고 구현이 용이하지만, 문장 간 중요도를 반영하지 못해 핵심 문장의 영향력이 충분히 드러나지 않는 한계가 있다.[11] Ilse et al. (2018)은 이러한 한계를 보완하기 위해 문장별 가중치를 학습하는 Attention Pooling의 우수성을 제시하였다.[11]

2.2.2. 어텐션 풀링(Attention Pooling)

문장별 중요도를 학습하여 핵심 문장에 더 큰 가중치(Attention Weight)를 부여하는 방식이다.[10] 이를 통해 모델은 예측에 결정적 문장을 중심으로 판단하게 되며, '어떤 문장을 근거로 판단했는가'를 해석할 수 있다.

Ilse et al. (2018)은 병리 이미지 분석에 이 구조를 적용해 정확도와 해석성을 동시에 확보하였다.[11]

2.2.3. 하이브리드 풀링(Hybrid Pooling)

평균 풀링과 어텐션 풀링의 장점을 결합하여, 문서 전체 정보와 핵심 문장 정보를 함께 반영한다.[17] 이를 통해 정보 손실을 줄이면서 중요한 문장에 집중할 수 있다.[17]

Zhang et al. (2018)는 EEG(뇌파) 기반 감정 인식 연구에 하이브리드 MIL 구조를 적용하여 높은 예측 성능과 설명력을 확보하였으며, 본 연구 역시 이 구조를 채택해 MIL 모델의 안정성과 해석 가능성을 강화하였다.[17]

2.2.4. XGBoost 기반 분류 모델

XGBoost(eXtreme Gradient Boosting)는 결정 트리를 기반으로 한 앙상블 학습 기법이다.[18] 여러 약한 분류기를 순차적으로 결합해 잔여 오차를 보정하면서 학습하기 때문에, 빠른 학습 속도와 높은 예측 정확도를 동시에 확보할 수 있다.[18]

이 모델은 문서 전체에서 추출된 통계적·언어적 피처(문장 길이, 단어 빈도, 가독성 지수 등)를 입력으로 사용해 탐지를 수행한다.[18] 구조가 단순하고 안정적이지만, 문장 간의 의미적 관계나 논리 흐름을 반영하지 못한다는 한계를 지닌다.[18]

Chen & Guestrin (2016)은 XGBoost가 대규모 데이터에서도 높은 성능을 보인다고 보고하였으며, Liu et al. (2019)은 텍스트 진위 판별연구에서 효율적인 기준 모델로 활용하였다.[18-19]

본 연구에서는 XGBoost를 MIL 계열 모델의 성능 및 해석력 향상을 검증하기 위한 비교 모델로 사용하였다. 즉, XGBoost는 문서 전체 피처 기반 탐지와 문장 단위 구조 학습 기반 탐지(MIL)의 차이를 정량적으로 비교하

는 기준점으로 설정되었다.

2.3 모델 해석 기법(XAI)

모델 해석 기법(Explainable Artificial Intelligence, XAI)은 딥러닝 모델의 판단 근거를 인간이 이해할 수 있는 형태로 설명하기 위한 접근이다.[7] 블랙박스 구조의 특성상 내부 작동 원리를 직접 파악하기 어렵기 때문에, 예측 과정을 시각화하거나 수치화하여 설명하는 다양한 방법이 연구되어 왔다.[7] 본 절에서는 가중치와 혼동행렬(Confusion Matrix) 같은 기존의 대표적 해석 기법과, 최근 주목받는 문서 흐름 시각화(Convex Hull Volume, UMAP)접근을 함께 다룬다.

2.3.1. 가중치(Attention Weight)

가중치는 모델이 입력 중 어떤 부분에 집중했는지를 나타내는 값으로, MIL 구조에서는 각 문장의 중요도를 학습해 문서 분류에 미친 영향을 수치화한다.[11] 이를 통해 모델의 판단 근거를 시각적으로 해석할 수 있다.[11]

앞서 Attention-Pooling을 설명하며 소개했던 Ilse et al. (2018)은 같은 논문에서 attention based MIL을 통해 병리 이미지에서 종양 여부를 분류하며, 중요 패치를 근거로 모델의 판단을 설명하였다.[11] 또한, 자연어 처리(Natural Language Processing, NLP) 분야에서도 이 방법은 문장 단위 텍스트 분류 시 해석에 널리 활용된다.[11]

2.3.2. 혼동행렬 (Confusion Matrix)

혼동행렬은 모델의 예측 결과를 실제 정답과 비교하여, 각 범주별로 얼마나 정확하게 분류했는지를 시각적으로 보여주는 도구이다.[20] 이를 통해 단순 정확도 이상의 관점에서 모델의 오류 유형을 분석할 수 있다.[20]

Zellers et al. (2019)은 텍스트 생성 탐지 모델 GROVER를 평가하며, 인간 작성 텍스트를 AI 생성으로 오분류하는 비율이 높음을 확인하였다.[20]

2.3.3. 문서 흐름 시각화 기반 해석 (Convex Hull Volume, UMAP)

최근에는 단어나 문장의 임베딩을 저차원 공간으로 시각화해 모델이 텍스트를 어떻게 구분하는지를 분석하는 연구가 활발하다.[21]

UMAP(Uniform Manifold Approximation and Projection)은 고차원 데이터를 2D 또는 3D로 축소하면서 의미 구조를 보존하는 비선형 차원 축소 기법으로, 문장 간 의미적 거리와 흐름을 시각적으로 보여준다.[21]

Bolukbasi, T et al. (2023)은 문장 임베딩을 UMAP으로 시각화하여 의미적 패턴을 설명하였으며, 본 연구 또한 문장 간 연결 흐름을 색상 그래디언트로 표현해 MIL 모델이 인식하는 문서 구조의 전형성을 시각적으로 분석하였다.[21]

3. 실험 설계

본 장에서는 본 연구에서 수행한 탐지 실험의 전체 설계를 설명한다. 구체적으로, 실험에 사용된 데이터, 텍스트를 정량화하기 위해 정의한 문서·문장 단위 변수(feature), 생성형 AI 개입을 탐지하기 위해 채택한 다중 인스턴스 학습(MIL) 계열 모델과 XGBoost 비교 모델의 구조, 모델 학습에 사용된 평가 지표와 실험 환경 설정, 그리고 자가보고 라벨의 불확실성을 보정하기 위해 설계한 GT 주입 실험 조건을 순서대로 제시한다.

이를 통해 “어떤 데이터에 어떤 변수를 적용하고, 어떤 모델 구조와 환경에서, 어떤 기준으로 성능을 평가했는가”를 체계적으로 설명한다.

3.1 데이터

3.1.1. 원본 데이터셋 및 분할

본 절에서는 연구에 활용한 데이터의 일반적인 설명과 전처리 작업에 대한 설명을 한다.

본 연구는 실제 군 보고서 형식의 문서를 대상으로 탐지 모델을 학습하였다. 데이터는 2025년 전반기 국방대학교 「국가안보와 과학기술」 교과목 수강생들이 작성한 중간 및 기말 보고서를 기반으로 수집되었다. 보고서의 주제는 “군 생활 경험을 바탕으로 국방 발전에 필요한 아이디어” 또는 “과학기술과 국가안보의 연계”로 제시되었으며, 분량은 A4 5장 내외였다. 총 230건의 데이터가 수집되었다.

〈표 2〉는 군사 보고서 데이터의 구조 이해를 위해 서로 다른 AI 개입 수준을 가진 두 문서를 포함하였다. ‘502’와 ‘552’는 데이터 정리 과정에서 부여된 내부 식별번호이며, 보고서의 내용과는 무관하다. ‘001, 002…’는 해당 문서 내 문장 순서를 나타낸다.

특히 예시로 제시된 502번 문서는 자가보고 1점·Class 0(인간 작성 중심)에 해당하며, 552번 문서는 자가보고 10점·Class 2(AI 작성 비중이 매우 높은 문서)에 해당한다. 이를 통해 본 연구의 문서 유형의 범위와 AI 개입 강도의 차이를 직관적으로 확인할 수 있다.

데이터는 학습용, 교정용, 평가용으로 구분되며, 각각의 생성 방식과 신뢰도 수준은 〈표 3〉에 정리하였다.

학습 데이터는 학생들이 작성한 보고서에 대해 자가보고한 생성형 AI 활용 정도를 라벨로 부여한 문서 집합으로, 모델의 기본 학습에 활용되었다. GT는 연구자가 생성형 AI의 개입 수준을 직접 통제해 작성한 문서로, 자가보고 라벨의 불확실성을 보정하고 학습 신뢰도를 높이는 데 사용되었다. 평가 데이터는 GT와 동일한 통제 조건에서 별도로 작성된 문서로, 모델의 최종 성능 검증에 활용되었다. 일반적으로 평가 데이터는 학습 데이터의 일부를 분리하여 구성하지만, 본 연구에서는 평가 데이터

〈표 2〉 본 연구에 활용된 군사 보고서 데이터의 문장 단위 예시

문서-문장	내 용	자가보고 (1-10)	Class (0-2)
502-001	나는 해군 병기병과로 근무하며 융합의 중요성을 오래 느껴왔으며 이번 강의를 통해 그 의미가 더 크게 와 닿았다.	1	0
502-002	장비 몇 가지의 성능을 올리는 일만으로는 한계가 있고, 임무와 절차와 데이터와 정비와 군수와 교육과 예산이 서로 스며들듯 맞물릴 때 전투력이 제대로 살아난다는 생각이 분명해졌다.		
552-001	21세기 국방 환경은 과거와는 전혀 다른 양상으로 변화하고 있다.	10	2
552-002	전통적인 무기체계와 병력 중심의 전투력 강화 방식만으로는 더 이상 절대적 우위를 보장하기 어렵다.		

〈표 3〉 본 연구에 활용된 Data Set 구성 요약표

명칭	생성 방식	주요 활용 목적	신뢰도 수준
훈련 데이터	참여자가 본인이 작성한 보고서에 대해 AI 사용 여부를 자가보고 형식으로 응답	주요 훈련용 데이터	낮음(오차 가능성)
교정 데이터	연구자가 보고서 작성자의 AI 활용 정도를 직접 통제하여 생성	자가보고 라벨의 오류 보정 및 모델 학습 보완	높음 (단, 연구자 개입에 따른 한계 존재)
평가 데이터		모델의 최종 성능 평가 및 객관적 비교	

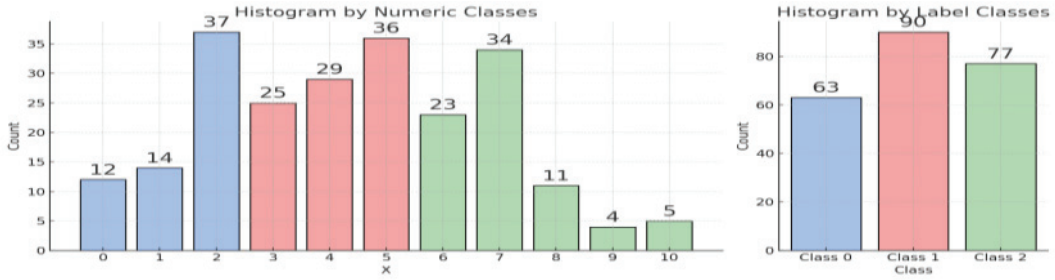

〈그림 1〉 11단계, 3단계 라벨 분포의 히스토그램

역시 GT로 확보하여 별도 구성하였다. 이는 모델의 검증 과정에서 자가보고 라벨의 불확실성이 개입되지 않도록 하고, 모델이 실제 정답(ground-truth)을 얼마나 정확히 식별하는지를 평가하기 위함이다. 따라서 여기서 '안정적 평가'란 데이터 분리의 의미가 아니라, 라벨 신뢰도에 기반한 평가의 일관성을 의미한다.

본 연구는 자가보고 데이터의 불균형성을 고려하여 균형 및 불균형 조건, 두 환경에서 실험을 진행하였다. 불균형 조건은 원본 데이터의 라벨 분포를 그대로 유지한 환경이며, 균형 조건은 소수 클래스에 대해 Oversampling 기법을 적용하여 각 Class의 문서 수를 동일하게 맞춘 환경이다.[22] 모든 실험은 재현성과 신뢰성 확보를 위해 각 조건별 30회 반복하였다.

3.1.2. 라벨 분포 및 단순화

〈그림 1〉의 좌측 히스토그램은 보고서 작성자가 자가보고한 생성형 AI 활용 정도(0-10점)의 분포를 나타낸다. 전체적으로 AI 활용도가 낮은 구간(0-3점)에 응답이 몰려 있으며, 이후 급격히 감소하는 비대칭 단봉형 분포를 보였다. 이는 응답자의 대부분이 생성형 AI보다는 직접 작성에 의존했음을 시사한다. 그러나 극단값(9~10점 구간)에서도 AI만을 사용했거나 그에 준하도록 활용한 소수의 응답자(약 4~5명)가 존재하였다. 이러한 분포는 단순한 사용 행태의 차이뿐 아니라, 성적 반영을 의식한 심리적 요인이 작용한 결과로 해석된다. 즉, 일부 학생은 보고서가 평가에 활용된다는 점을 무의식적으로 고려하여 'AI를 덜 사용했다'는 방향으로 응답했을 가능성이 있다.

이러한 편향적 분포를 보정하기 위해, 본 연구에서는 0-10의 세밀한 척도를 3단계(Class 0, 1, 2)로 단순화하였다. 구체적으로, Class 0은 인간 작성(0-3점), Class 1은 혼합형(4-6점), Class 2는 AI 작성(7-10점)에 해당한다.

단순화의 목적은 단순히 라벨의 개수를 줄이기 위한 것이 아니다. 11단계로 세분화된 점수를 3단계로 묶음으로써, 모델이 생성형 AI 개입 수준의 차이를 더 명확하게 구분하고 학습할 수 있도록 하기 위함이다. 또한, 중간 구간(4~6)에 응답이 집중되어 생긴 불균형 문제를 완화해, 학습 데이터의 분포를 보다 안정적으로 만들고자 하였다. 이 과정을 통해 이후 실험에서 균형 데이터와 불균형 데이터 조건을 구분할 수 있는 기반을 마련하였다.

3.1.3. 감정·경험 관련 변수의 탐색적 분석 (EDA)

본 절에서는 군사 보고서 전체 데이터(230건)를 대상으로 감정·경험 관련 언어적 표현의 분포를 탐색적으로 분석하였다. 분석 대상 변수는 1인칭·집단인칭 서술, 감정 표현, 강조 표현, 감탄 표현, 인지 표현 등으로 구성되었다. 이는 보고서 문체의 특성을 정량적으로 파악하고, 탐지 모델의 작동 방식 해석에 활용하기 위해 수행되었다. 탐색 결과, 감정·경험 관

〈표 4〉 문서 및 문장 단위 피처 구성표 [21]

구분	변수명	범주	설명	주요 목적
구조 기반 특성	length	구조	문장의 전체 토큰 수	문장 길이 분포 확인
	avg_word_len	구조	평균 어절 길이	간결성 / 복잡성 추정
	morph_count	구조	형태소 개수	문장 복잡성 지표
가독성 기반 특성	fkgl	가독성	Flesch-Kincaid Grade Level	읽기 난이도 지표
	lix	가독성	스웨덴식 가독성 점수	문장 복잡성 측정
의미 유사도 및 주제 일치도	tfidf_sim	의미	전체 문서에서 해당 문장의 TF-IDF 기반 유사도	문장 내 일관성 / 주제 관련성 평가
	domain_density	의미	전문 군사용어의 밀도	주제 집중도 추정
사전기반 경험 및 인지 특성	experience_score	경험	경험 관련 표현 비율	실제 경험 기반 문장 여부
	first_person_ratio	경험	1인칭 주어 표현 비율	주관적 진술의 정도
	example_flag	경험	예시 제시 여부	사례 진술 존재 여부
사전기반 인지 관련 특성	cognition_ratio	인지	인지 관련 어휘 비율	사고 관련 표현 여부
	domain_noun_cnt	인지	도메인 특화 명사 수	주제 밀접도 평가
	domain_verb_cnt	인지	도메인 특화 동사 수	행동 중심 문장 평가
	exp_cnt	인지	경험 관련 명시 표현 수	경험성 피처 보조값
	cog_verb_cnt	인지	인지 동사 수	사고 관련 표현 수
사전기반 감성 및 정서 특성	emo_pos	감성	긍정 감정 어휘 수	정서적 표현 탐지 감정 강도 및 방향
	emo_neg	감성	부정 감정 어휘 수	
	sentiment_raw	감성	문장의 전체 감성 점수 합	감정 방향성 평가
	sentiment_norm	감성	감성 점수 정규화 값	문장 간 비교
사전기반 강조 표현 및 표현 방식	intensifier_count	강조	강조 부사 수(매우, 정말)	강조 표현 강도
	exclam_count	강조	감탄사 수	문장 표현 방식 탐지
	emphasis_score	강조	강조 표현 종합 점수	문장 강조 정도 평가
언어 모델 기반 특성	ppl_kogpt2	언어 모델	KoGPT2 기반 문장 Perplexity	생성 여부, 유창성 추정
의미 기반 임베딩	SBERT(1024차원)		각 차원은 의미·맥락적 정보를 벡터로 표현	문장 간 의미적 유사도 및 표현 구조를 고차원 공간에서 비교하기 위함

예시문장	나는 국방대학교 학생으로서 굉장한 자부심과 사명감을 느끼며, 배운 지식을 바탕으로 국가안보 발전에 기여하고 싶습니다.

〈표 5〉 예시 문장에 대한 변수 계산 결과

구조 기반 특성		
길이	평균 어절 길이	형태소 개수
17	3.1	26
가독성 기반 특성	의미 및 주제 관련 특성	
읽기 난이도	주제 관련성	전문 군사용어 밀도
7.2	0.78	0.35
경험 및 인지 관련 특성		언어모델 기반 유창성
1인칭 주어 표현 비율	인지 관련 어휘 비율	KoGPT2 기반 문장 유창성
0.25	0.41	22.9

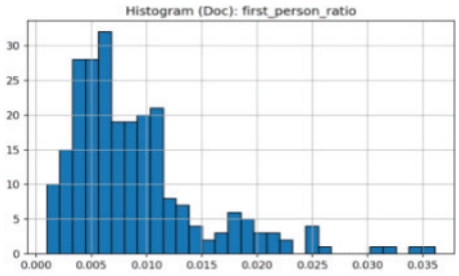

전체 문장 내 1인칭(나/우리 등) 사용 비중

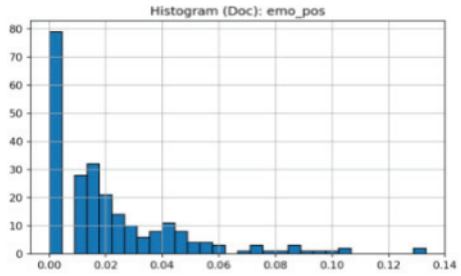

전체 문장 내 긍정 감정 단어 출현 수

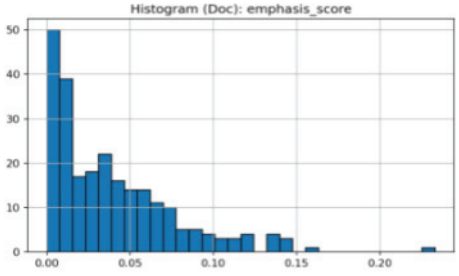

전체 문장 내 강조 표현 수

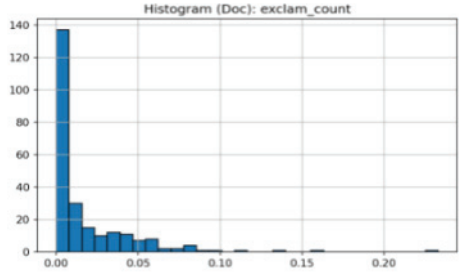

전체 문장 내 느낌표, 물음표 개수

〈그림 2〉 감정·경험 관련 변수에 대한 탐색적 데이터 분석 결과

련 표현의 전체 빈도는 매우 낮은 수준으로 나타났다. 특히 감정표현, 감탄표현, 강한 주관적 강조표현 등은 대부분 문서에서 거의 등장하지 않았으며, 1인칭·집단인칭 표현 역시 제한적인 수준에서 사용되었다. 이러한 경향은 군사 보고서가 공식적·정형적 문체를 기반으로 작성되는 문서의 특성과 일치한다. 즉, 보고서는 사실 기반 기술, 절차 중심 설명, 임무·조직·체계 관련 객관적 서술을 우선하며, 개인 감정이나 주관적 평가를 적극적으로 드러내지 않는 특징을 보인다.

〈그림 2〉는 감정·경험 관련 표현이 전체 데이터에서 낮은 수준으로 나타남을 시각적으로 보여준다. 본 절의 EDA 결과는 데이터의 문체적 특성을 이해하기 위한 기반 자료로 활용되며, 이후 장에서 제시되는 모델 분석 및 오류 패턴 검증의 기초 자료로 사용된다.

3.2 변수 구성

데이터 수집과 라벨 단순화 과정을 마친 다음 단계에서는, 전처리된 텍스트를 모델이 인식하고 예측할 수 있는 형태로 변환하기 위해 적절한 변수를 정의하는 과정이 필요하다.

〈표 4〉는 문서와 문장 단위의 피처 구성을 요약한 것으로, 각 변수는 총 9개 범주, 23개 세부 변수로 구성되어 탐지 모델이 문서의 형태적 복잡성부터 의미적 일관성, 감성 및 인지적 표현까지 다층적으로 분석할 수 있도록 설계되었다.[23] 구조 기반 특성(length, avg_word _len, morph_count)은 문장의 길이와 어절 구조를 통해 문체의 간결성이나 복잡성을 추정한다.[23] 가독성 특성(fkgl, lix)은 문장의 난이도와 복잡도를 수치화하여 AI가 생성한 문체의 일정한 패턴을 탐지하는 데 활용된다.[23] 의미 일치도 및 주제 집중도(tfidf_sim, domain_density)는 문장 간 주제의 일관성과 전문 용어 밀도를 분석해 인간이 쓴 글과 AI 생성 글의 의미적 차이를 포착한다.[23] 또한 경험 및 인지 관련 특성(experience_score, first_person_ratio,

cognition _ratio 등)은 '나', '우리' 등 1인칭 표현이나 경험 서술 비중을 반영해 실제 체험 기반 서술의 여부를 측정한다.[23] 감정 및 강조 표현 특성(sentiment raw, intensifier_count, exclam_count 등)은 문장의 감정 표현과 강조 강도를 수치화해 인간적 감성 표현의 존재를 분석한다.[23] 마지막으로 언어모델 기반 특성(ppl_kogpt2, sbert)은 KoGPT2 Perplexity와 SBERT 임베딩을 활용해 문장 자연스러움과 의미적 맥락을 벡터 단위로 정량화하였다.[23]

이와 같은 변수 구성은 단순한 통계적 차이를 넘어, 문체적·의미적·감정적·인지적 수준의 언어 특성을 종합적으로 반영함으로써 생성형 AI 탐지 모델의 학습과 해석력을 강화하도록 설계되었다.[23]

예를 들어, "나는 국방대학교 학생으로서 굉장한 자부심과 사명감을 느끼며, 배운 지식을 바탕으로 국가안보 발전에 기여하고 싶습니다."라는 문장은 구조·의미·경험·인지 등 여러 언어적 특성이 복합적으로 드러나는 사례이다.

〈표 5〉는 이 문장을 대상으로 각 변수가 어떻게 산출되는지를 보여준다. 구조 기반 변수에서 문장 길이(length)는 17, 평균 어절 길이(avg_word_len)는 3.1, 형태소 개수(morph_count)는 26으로, 비교적 간결하지만 의미 단위가 충분히 포함된 문장임을 나타낸다.가독성 지표인 Flesch-Kincaid 점수(fkgl)는 7.2로, 일반 성인 독자가 무리 없이 이해할 수 있는 중간 수준의 난이도를 의미하며, 이는 문장이 과도하게 복잡하지 않으면서도 내용적 깊이를 유지하고 있음을 보여준다. 의미 및 주제 관련 특성에서는 TF-IDF(Term Frequency Inverse Document Frequency) 기반 유사도(tfidf_sim)가 0.78, 군사용어 밀도(domain_density)가 0.35로 나타나, 문장 내에서 국방 관련 주제어가 적절히 활용되고 전문 영역과의 연관성이 있음을 보여준다. 경험 및 인지 관련 변수에서는 1인칭 표현 비율(first_person_ratio)이 0.25, 인지 관련 어휘 비율(cognition_ratio)이 0.41로 측정되어, 작성자가 자신의 경험과 생각을 적극적으로 반영하고 있음을 시사한다. 마지막으로, KoGPT-2 언어모델 기반 유창성 지표(ppl_kogpt2)는 22.9로, 일반 한국어 문장의 평균 범위(약 20–30)에 해당한다. 이는 문장이 자연스러운 어순과 문법적 완성도를 유지하고 있음을 보여준다.

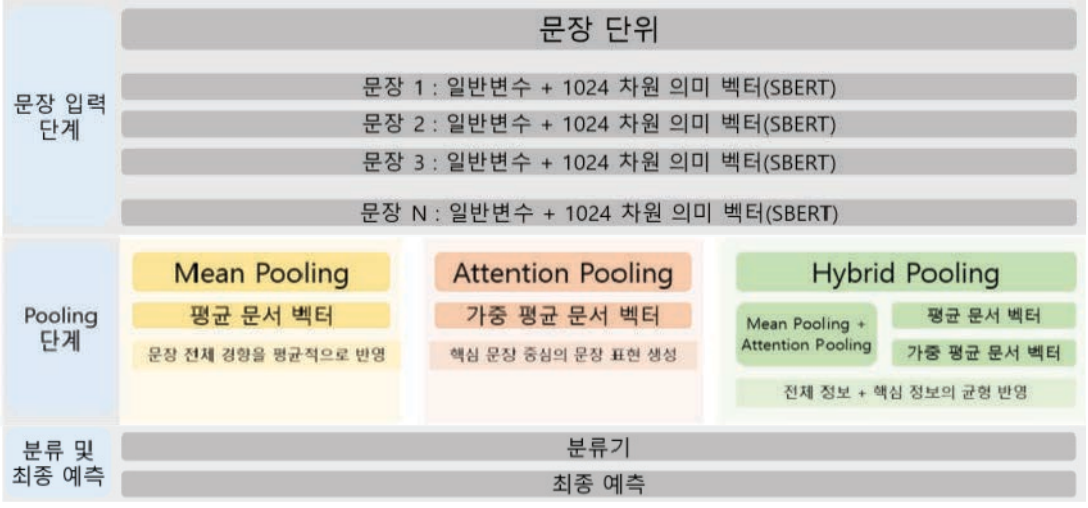

〈그림 3〉 MIL 구조 비교 워크플로우

이와 같이 각 변수의 수치는 문장의 구조적 형태, 의미적 집중도, 경험적 진정성, 언어적 유창성을 정량적으로 포착함으로써, 생성형 AI 탐지 모델이 문체적 특징뿐 아니라 의미 및 인지 차원까지 학습할 수 있도록 도와준다.

3.3 실험 모델

3.3.1 MIL 기반 모델과 XGBoost

본 연구에서는 문서를 문장 단위로 분리하여 다중 인스턴스 학습(MIL) 구조 내에서 모델별 입력 처리 방식과 해석적 특성을 비교하였다. 이를 위해 Mean-MIL, Attention-MIL, Hybrid- MIL 세 가지 구조와 전통적 머신러닝 모델(XGBoost)을 함께 실험하였다.

또한 〈그림 3〉은 세 가지 MIL 모델이 동일한 문서를 입력받았을 때 문장 입력 단계 → Pooling 단계 → 분류·예측 단계를 어떻게 서로 다르게 처리하는지를 시각적으로 정리한 구조 비교도이다. 이를 통해 각 모델이 문서 내 정보를 요약하고 의미적 단서를 활용하는 방식의 차이를 직관적으로 파악할 수 있다.

3.3.2 군사 보고서 입력 시 모델 작동 예시

군사 보고서는 공식적·정형적 문장이 반복되는 특성을 지니기 때문에, 문서 전체를 하나의 벡터로 요약하는 방식에서는 문장 간 의미 흐의 미세한 차이나 특정 문장의 부자연스러운 삽입을 충분히 반영하기 어렵다. 이러한 특성은 문서 단위 평균을 기반으로 하는 전통적 모델의 한계로 이어질 수 있다.

한 편의 군사 보고서가 모델에 입력되었을 때, MIL 모델과 XGBoost 모델은 정보를 처리하는 방식에서 뚜렷한 차이를 보인다. MIL 계열 모델은 보고서를 여러 문장으로 분할하여 각 문장을 하나의 인스턴스로 처리하고, 문장들 간의 의미적 관계를 종합해 전체 판단을 내린다. Mean-MIL은 각 문장의 임베딩을 평균하여 보고서의 전반적 문체와 어조를 요약하고, Attention-MIL은 특정 문장에 더 높은 중요도를 부여함으로써 AI 개입 가능성이 높은 문장을 강조한다. 예를 들어, “결론적으로 이러한 변화는 국가 안보에 기여할 것이다”와 같이 지나치게 일반적이거나 모범답안식 표현이 반복될 경우 해당 문장이 판단 근거로 선택될 수 있다. Hybrid-MIL은 평균 기반의 안정성과 문장별 가중치의 정밀함을 결합해 보고서의 논리흐름은 유지하면서도 특정 부분의 이상 패턴을 효과적으로 탐지한다.

반면 XGBoost 모델은 동일한 보고서를 문

〈표 6〉 평가 지표 및 분석 방법 요약

구분	세부 항목	내용	주요 활용 목적
정량적 분석	F1-Score	정밀도와 재현율의 조화 평균	성능 변화 분석
	AUC	클래스 간 경계를 얼마나 안정적으로 구분하는지 평가	모델의 판별력 및 안정성 비교
	Accuracy	전체 예측 중 정답 비율로, 기본 분류 성능을 확인하는 지표	보조적 성능 확인
정성적 분석 및 해석	Attention Heatmap	문서 내 문장별 가중치를 시각화해 모델의 가중치 집중 영역을 파악	판단 근거 해석 및 신뢰도 검증
	혼동행렬	실제 라벨과 예측 라벨을 비교하여 클래스별 오탐·미탐 패턴을 분석	오류 발생 경향 및 교정 효과 분석
	UMAP	임베딩 공간을 2차원으로 축소해 문서 간 의미적 일관성과 내용 전개 흐름을 시각화	클래스별 문서의 구조적 차이 시각화

장 단위로 처리하지 않고, 문서 전체를 하나의 수치 벡터로 요약하여 입력으로 사용한다. 피처에는 문서의 구조, 가독성, 의미적 일관성, 감성 및 인지 표현 등 다양한 언어적 특성이 포함되며, 이를 기반으로 문서가 AI의 영향을 받았을 가능성을 산출한다. 그러나 XGBoost는 문장 간 흐름이나 개별 문장의 영향력을 고려할 수 없어, 어떤 부분이 판단의 근거였는지를 구체적으로 설명하기 어렵다.

이에 본 연구에서는 XGBoost를 비교 기준 모델로 설정하고, MIL 구조가 갖는 문장 단위 해석 가능성과 구조적 신뢰성이 군사 보고서와 같은 정형적 텍스트에서 어떻게 우위를 갖는지 실험적으로 검증하였다.

3.4 평가 지표 및 실험환경

3.4.1 평가 지표

본 연구는 생성형 AI 개입 수준을 3단계(Class 0, 1, 2)로 분류하는 다중분류 문제로 설정하고, 모델의 성능을 정량적·정성적으로 평가하였다.

정량적 평가는 Accuracy, F1-Score, Macro F1, AUC(Area Under the ROC Curve)를 사용하였으며, 각 지표의 정의와 목적은 〈표 6〉에 요약하였다. Accuracy는 전체 예측 중 정답 비율로, 기본적인 분류 성능을 확인하기 위한 보조 지표로 사용하였다.[22] F1-Score는 정밀도(Precision)와 재현율(Recall)의 조화 평균으로, 데이터 불균형 환경에서도 단일 지표로 성능을 종합적으로 나타낼 수 있다.[24] Macro F1은 각 클래스의 F1을 평균한 값으로, 본 연구의 비균등한 데이터 분포를 고려할 때 핵심 평가 지표로 활용하였다.[24] AUC는 클래스 간 경계를 얼마나 안정적으로 구분하는지를 나타내며, 값이 1에 가까울수록 모델의 판별력이 높음을 의미한다.[24]

정성적 평가는 모델의 판단 근거를 해석하고 블랙박스 문제를 완화하기 위한 목적으로 수행하였다. 이를 위해 가중치, 혼동행렬, 그리고 UMAP 시각화를 병행하여, 각각 모델의 집중 영역, 예측 오류 유형, 문서 간 의미 구조를 시각적으로 분석하였다.

정량적·정성적 지표를 종합적으로 활용함으로써, 본 연구는 모델의 탐지 성능뿐 아니라 해석 가능성과 신뢰성까지 함께 평가하였다.

3.4.2 실험 환경

모든 실험은 Google Colab (Ubuntu 20.04) 환경에서 수행되었으며, GPU는 NVIDIA A100 (40 GB) 을 사용하였다. 실험 환경의 주요 설정 값은 〈표 7〉에 정리하였다.

모델 학습은 Python 기반으로 진행되었으며, 데이터 처리에는 오픈소스 라이브러리(Pandas, Scikit-learn, PyTorch 등)을 활용하였다.

Epoch 수는 20으로 고정하였으며, Batch 단위 학습 대신 각 문서(Bag)를 개별 입력 단위로 처리하였다.

모델의 일반화 성능과 통계적 신뢰도를 확보하기 위해 Stratified 5-Fold 교차검증을 적용하였고, 모든 조건(GT, Balanced)에 대해 총 30회 반복 실험을 수행하였다.

각 반복에서는 고유한 Seed(2023–2052)를 순차적으로 부여하여 데이터 분할과 모델 초기화를 일관되게 유지하였으며, 무작위성에 따른 편차를 최소화하였다. 모든 반복 결과는 평균과 표준편차를 기준으로 분석하여, 모델의 성능 안정성과 통계적 유의성을 함께 검증하였다.

3.5 교정 데이터(GT) 주입 실험

본 절에서는 탐지 모델의 학습 신뢰도와 예측 안정성에 영향을 미치는 GT 주입 실험에

대해 설명한다.

GT란 생성형 AI 개입 수준이 연구자가 직접 통제된 문서 집합을 의미하며, 자가보고라벨의 불확실성을 보정하고 모델이 실제 패턴을 보다 명확히 학습하도록 돕기 위해 활용되었다.[12] 즉, GT는 "정확히 어느 정도의 AI 개입이 있었는가"를 확실히 알고 있는 데이터로, 모델의 기준선 역할을 수행한다.

본 실험의 목적은 GT 주입 비율 변화가 모델의 학습 안정성과 예측 신뢰도에 미치는 영향을 분석하는 것이다. 특히 자가보고 데이터의 낮은 신뢰도를 고려하여 일정 비율의 GT를 학습 과정에 포함함으로써 모델이 더 명확한 경계와 판단 근거를 학습할 수 있는가를 검증하였으며, 이를 통해 실제 운용 환경에서도 안정적인 탐지가 가능한지를 추가적으로 살펴보았다.

모든 실험은 동일한 데이터와 모델 구조를 기반으로 수행하되, GT 주입량 gt(0), gt(3), gt(9), gt(15), gt21)을 달리하여 GT 비율 변화에 따른 모델 반응을 비교하였다. gt(0)은 자가보고 데이터만 사용하여 학습하며, gt(21)은 수집한 GT 데이터를 모두 활용하여 학습한다.

〈표 7〉 실험 환경의 주요 설정

구분	설정 내용
실행 환경	Google Colab (Ubuntu 20.04)
GPU 사양	NVIDIA A100 (40GB)
주요 라이브러리	Pandas, Scikit-learn, PyTorch
Epoch 수	20
교차 검증 방식	Stratified 5-Fold
반복 실험 횟수	30회
Seed 설정	2023~2052 (순차 증가)
분석 기준	평균값 및 표준편차 기반 통계 검증

이 절차를 통해 GT의 변화가 모델의 학습 안정성과 예측 신뢰도에 미치는 영향을 일관되게 관찰하였다.

또한 데이터 분포의 편향이 학습 결과에 영향을 주지 않도록, 균형 조건과 불균형 조건을 병행하여 실험을 수행하였다. 불균형 조건은 단순화된 라벨(Class 0, 1, 2)의 실제 분포를 그대로 유지한 환경이며, 균형 조건은 소수 클래스의 문서 수를 보정하기 위해 오버샘플링(Over-sampling) 기법을 적용하여 각 클래스의 크기를 동일하게 맞춘 환경이다.

4. 실험 결과

본 장에서는 탐지 모델의 성능과 판단 기준 변화를 중심으로 정량적·정성적 결과를 제시한다.

수치 기반 결과 분석에서는 초기 모델 성능 비교를 시작으로 GT 주입 비율과 데이터 분포에 따른 모델별 성능 변화를 검증하였고 정성적 해석에서는 혼동행렬, 가중치, 그리고 UMAP 시각화를 통해 모델의 판단 근거와 문서 간 의미 구조 변화를 살펴보았다.

4.1 모델별 초기 성능 비교

〈표 8〉은 탐지 모델의 초기 학습 결과를 나타낸다. 전체적으로 AUC는 0.71~0.73 수준으로, 무작위 추측 기준(0.5)을 상회하였으며, Macro F1은 0.51(약 51%)으로, 3클래스 무작위 예측 기대값인 0.33보다 높은 성능을 보였다. 이는 모델이 의미적 패턴을 안정적으로 포착하여 절반 이상 수준의 유효한 탐지 성능을 확보했음을 의미한다.

반면 XGBoost의 Macro F1은 약 43.3%로 상대적으로 낮은 성능을 보였으며, 이는 문장 간 의미 전환이나 문체적 변화를 세밀하게 반

영하지 못한 결과로 해석된다. Hybrid-MIL과 Attention- MIL은 문서 내 표현적 다양성과 문장 간 전환 패턴을 더 정교하게 반영할 수 있었고, 그 결과 Macro F1 기준에서 XGBoost 대비 각각 약 7.6%p 및 10.3%p 높은 성능을 보였다.

초기 성능이 전반적으로 높지 않다는 점은 단순한 모델 한계만으로 설명되기 어렵다. 본 연구의 주요 라벨인 자가 보고 점서는 정확성이 낮을 수 있으며, 이러한 노이즈는 분류 경계를 불안정하게 만들 수 있다. 이는 기존 연구들에서도 보고된 바와 같이, 노이즈 라벨이 모델의 학습 경계와 중요도 분포를 왜곡한다는 결과가 반복적으로 보고된 바 있다.[1],[12] 이러한 배경을 고려할 때, GT 주입은 단순한 성능 향상이 아니라 모델 분류 경계를 안정화하기 위한 필수 과정으로 이해할 수 있다. 다음 절에서는 GT 주입에 따라 성능이 어떻게 변화하고 안정되는지에 대해 구체적으로 살펴본다.

4.2 GT 주입에 따른 성능 추이

앞서 모델별 초기 성능 비교 결과를 바탕으로, 탐지 정확도와 학습 안정성을 향상시키기 위해 GT 주입 실험을 수행하였다. GT 주입 결과 모델의 성능은 GT 주입량 증가와 함께 전반적으로 개선되는 경향을 보였으며, 그 추이는 〈표 9〉, 〈표 10〉, 〈그림 4〉에 정량적으로 제시하였다.

〈표 10〉에 따르면 Hybrid-MIL의 Macro F1은 0.51에서 0.602로 약 +9.24%p 상승하였고, AUC도 0.71에서 0.744로 +0.03 향상되었다. 이는 모델이 GT 주입을 통해 더 안정적인 판별 경계를 학습했음을 보여준다.

반면, GT가 일정 수준(gt(15) 이후) 이상 증가하면 추가적인 성능 향상은 완만해지는 포화 구간이 나타났다. 〈그림 4〉는 이러한 성능 변화의 패턴을 시각적으로 보여준다. GT 주입 gt(3)~gt(9) 구간에서 성능이 급격히 상승하고, 이후 gt(15)~gt(21)에는 완만한 안정세로 전환되는 경향을 보인다. 특히 Hybrid-MIL은 가장 안정적이고 지속적인 개선 추세를 보였으며, XGBoost는 트리 기반 구조의 특성상 GT 주입의 직접적 영향을 강하게 받아 Macro F1이 0.434에서 0.568(+13.42%p)로 상승하였다.

이러한 변화는 〈표 11〉의 p-value 검정 결과($p < 0.001$)로도 통계적으로 유의함이 입증되었다. 즉, GT는 단순한 정확도 향상 요소가 아니라 모델의 예측 변동성을 감소시키는 학습 안정화 기제로 기능했음을 의미한다.

4.3 데이터 균형, 불균형 비교

GT 주입 효과가 데이터 분포가 균형적인 경우와 불균형적인 경우에 따라 어떻게 달라지는지를 검증한 결과, 두 조건 간 성능 향상 폭이 다르게 나타남을 확인하였다. 〈표 12〉에 그 결과를 제시하였다.

Hybrid-MIL 기준으로 Macro F1은 균형 데이터에서 0.46에서 0.51로 약 0.05 상승하였고, 불균형 데이터에서는 0.51에서 0.60으로 약 0.09 상승하였다. AUC 또한 각각 균형

〈표 8〉 모델별 초기 성능 비교

모델	GT 조건	Macro F1 (±SD)	AUC (±SD)
XGBoost	gt(0)	0.4337 (±0.0000)	0.7151 (±0.0000)
Attention-MIL	gt(0)	0.5369 (±0.0543)	0.7315 (±0.0312)
Mean-MIL	gt(0)	0.4609 (±0.0671)	0.7203 (±0.0298)
Hybrid-MIL	gt(0)	0.5101 (±0.0670)	0.7151 (±0.0284)

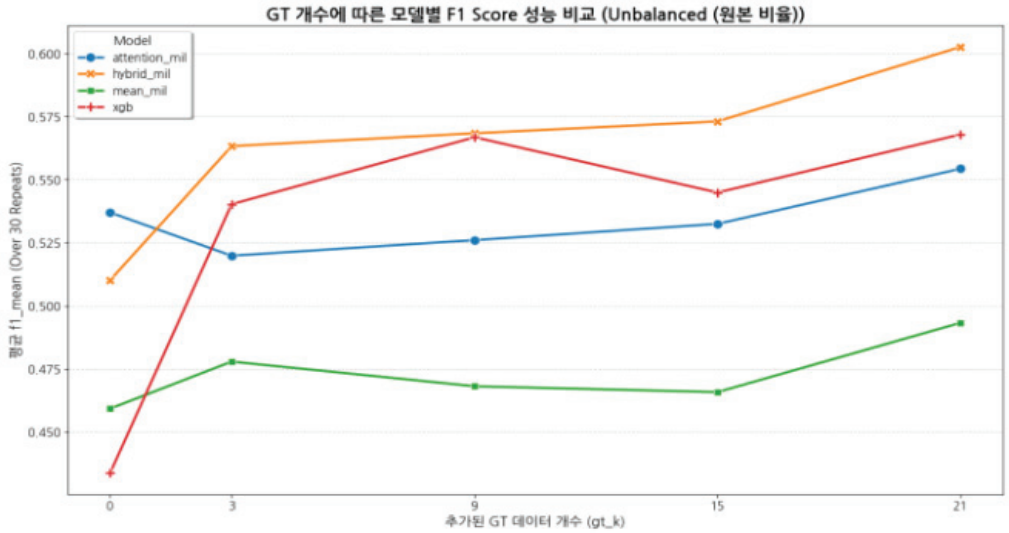

〈그림 4〉 GT 개수에 따른 모델별 F1-Score 성능 비교

〈표 9〉 Hybrid-MIL의 GT 주입량별 성능 변화

GT 조건	Macro F1	ΔF1- Score	AUC	ΔAUC (vs gt(0))
gt(0)	0.5101	-	0.7151	-
gt(3)	0.5632	+5.31%p	0.7099	-0.0052
gt(9)	0.5683	+5.82%p	0.7272	0.0121
gt(15)	0.573	+6.29%p	0.7386	0.0217
gt(21)	0.6025	+9.24%p	0.7445	0.0294

〈표 10〉 GT 주입량에 따른 성능 변화 요약 gt(0), gt(21)

구 분	Attention-MIL	Hybrid-MIL	Mean-MIL	XGBoost
Accuracy	0.5369 → 0.5542	0.5101 → 0.6025	0.465 → 0.508	0.4337 → 0.5679
Macro F1	0.5370 → 0.5540	0.5100 → 0.6030	0.4590 → 0.4930	0.4340 → 0.5680

〈표 11〉 gt(0) vs gt(21) 조건 간 모델별 성능 차이 및 p-value 결과

모델	ΔF1	p-value
Attention-MIL	0.0173	0.4612
Hybrid-MIL	0.0924	p<0.001
Mean-MIL	0.0340	0.0687
XGBoost	0.1342	p<0.001

〈표 12〉 균형과 불균형 성능 비교 (Hybrid-MIL 기준)

조건	gt(0)	gt(21)	ΔF1	ΔAUC
균형	0.4567	0.5129	0.0562	0.0157
불균형	0.5105	0.6025	0.0924	0.0334

〈표 13〉 GT 주입 전후 Attention-MIL의 문장별 가중치 변화 예시

예시 문장	가중치		Class 구분
	gt(0)	gt(21)	
따라서 세 요소가 상호 보완적으로 작동해야 한다.	0.24	0.02	Class 2(AI 작성)
국제사회와의 협력 속에서 합의된 규범을 만들어야 한다.	0.18	0.05	Class 2(AI 작성)
핵무기는 전후 세계 질서를 재편했다.	0	0.18	Class 2(AI 작성)
KCTC에서의 첫 경험은 충격이었다.	0	0.15	Class 0(인간 작성)

0.016과 불균형 0.03만큼 향상되었다. 이러한 결과는 불균형 데이터에서 GT가 모델의 분류 경계를 더 강하게 보정하는 방향으로 작용했음을 시사한다.

이러한 차이는 MIL 구조의 학습 방식과 GT 주입 과정이 결합된 결과로 보인다. 본 연구의 MIL은 문서 전체가 아닌 문장 단위 임베딩을 기반으로 학습하기 때문에, 클래스 비율 자체보다는 GT가 포함된 문장의 샘플링 비중 및 신뢰도가 표현 공간의 안정성에 영향을 미쳤을 가능성이 있다. 다만, 이 현상이 GT 주입으로 인한 데이터 비중 변화의 결과인지, 혹은 MIL의 attention 메커니즘 특성 때문인지는 본 연구의 데이터만으로 단정하기 어렵다. 향후에는 GT 주입량과 클래스 분포를 체계적으로 통제한 실험을 통해 두 요인의 영향을 분리 분석할 필요가 있다.

결과적으로, 데이터 균형 여부는 성능 향상에 일부 영향을 미쳤으나, GT의 품질과 주입 비율이 모델의 성능 향상에 더 근본적인 요인임을 확인하였다.

4.4 정성적 성능 분석

4.4.1. 문장 단위 가중치 패턴 분석

〈표 13〉는 Attention-MIL 모델에서 GT 주입 전후 문서 내 문장별 가중치의 변화를 보여준다. 그 수치는 문서 내에서 모델이 예측 시 '상대적으로 중요한 근거로 삼은 문장'을 수치로 표현한 것이며, 가중치가 특정 문장을 AI 또는 인간으로 직접 판단하는 지표는 아니며, 모델이 어떤 유형의 문장에 주목하는지를 보여주는 간접적 단서이다. 즉, 가중치의 절대적 크기가 아니라 어떤 유형의 문장에 주목이 이동했는가가 분석의 핵심이다.

GT 주입 이전 gt(0)에는 "따라서 세 요소가 상호 보완적으로 작동해야 한다.", "국제사회와의 협력 속에서 합의된 규범을 만들어야 한다." 등 형식적 연결어나 추상적 결론형 문장에 가중치가 집중되었다. 이는 모델이 의미보다는 표면적, 구조적 패턴에 의존했음을 시사한다. 이러한 경향은 Terčon and Dobrovoljc (2025)가 제시한 AI 생성 텍스트의 전형적 특징. 즉, 어휘 다양성 부족, 기능어 과다 사용, 추상적 진술 반복과 일치한다.[24]

반면 GT 주입 이후 gt(21)에는 "KCTC에서의 첫 경험은 충격이었다."처럼 의미적으로 구체적이거나 맥락적으로 풍부한 문장들의 가중치가 상승하였다. 이러한 변화는 모델이 '이 문장이 인간이 쓴 문장이다'라는 판단한 것이 아니라, 모델이 인간적 맥락(경험, 감정, 사실적 진술 등)을 탐지의 단서로 학습하기 시작했음을 의미한다. 윤원재(2024) 또한 생성형 AI가 감정은 표현할 수 있지만, 경험과 맥락을 담은 창작물에서의 한계를 명확히 지적했다.[2] 이는 모델의 주목 기준이 형식 중심에

서 의미 중심으로 전환되었음을 보여준다.

결국 Attention 가중치의 변화는 문장을 AI·인간으로 직접 분류하는 지표가 아니라, 모델의 판단 근거가 어떤 언어적 특징에 기반해 재구성되었는지 보여주는 해석 자료로 이해해야 한다. 이러한 변화는 모델이 단순한 예측기를 넘어, 문맥, 내용 기반의 '설명 가능한 탐지 체계'로 발전하고 있음을 시사한다.

4.4.2. 오류 패턴 분석 (Confusion Matrix Analysis)

〈그림 5〉는 Attention-MIL 모델의 gt(0)과 gt(21) 조건에서의 혼동행렬 비교 결과이다. 그림을 확인하면 크게 정분류 영역(**)과 오분류 영역(*)으로 나누어 해석할 수 있다. **영역은 모델이 실제 라벨과 예측 라벨을 일치시킨 구간으로, AI 개입 여부를 정확히 탐지한 경우를 의미한다. 반면 *영역은 오분류된 구간으로, 모델이 Class 0(인간 작성)을 Class 1(혼합형)으로, Class 1(혼합형)을 Class 2(AI 작성)으로 잘못 분류한 사례를 나타낸다.

GT 주입 이후 gt(21) 전체 오분류율은 감소하였으나, 그 개선 효과는 Class 2(AI 작성)에 집중되었다. 즉, 모델이 'AI 여부'를 판별하는 능력은 강화되었지만, Class 0(인간 작성)과 Class 1(혼합형) 사이에 경계는 여전히 모호하여 분류 안정성이 충분히 확보되지 않았다.

오류의 방향성 또한 일관되게 나타나, 인간 작성 문서일수록 혼합형으로, 혼합형은 AI 작성으로 잘못 분류되는 경향이 지속되었다. 이는 GT가 'AI 존재 여부'를 구분하는 데에는 효과적이지만, AI 개입 강도의 세부 단계 구분에는 여전히 한계가 있음을 시사한다.

이러한 결과를 단순히 'AI 과잉탐지'로 해석하기는 어렵다. 보고서 데이터의 특성상 인간이 작성한 문서에서도 공식적이고 분석적인 문체를 사용하기 때문에, 문법적·구조적 특징이 AI 텍스트와 유사하게 나타날 수 있다. 이를 보완하기 위해 본 연구에서는 experience_score, first_person_ratio, emo_pos, intensifier_count 등의 변수를 활용하여 "경험·감정·주관 표현"을 정량화하였으나, 보고서 특성상 해당 표현이 매우 낮아 모델의 주요 단서로 작용하지 못했다.

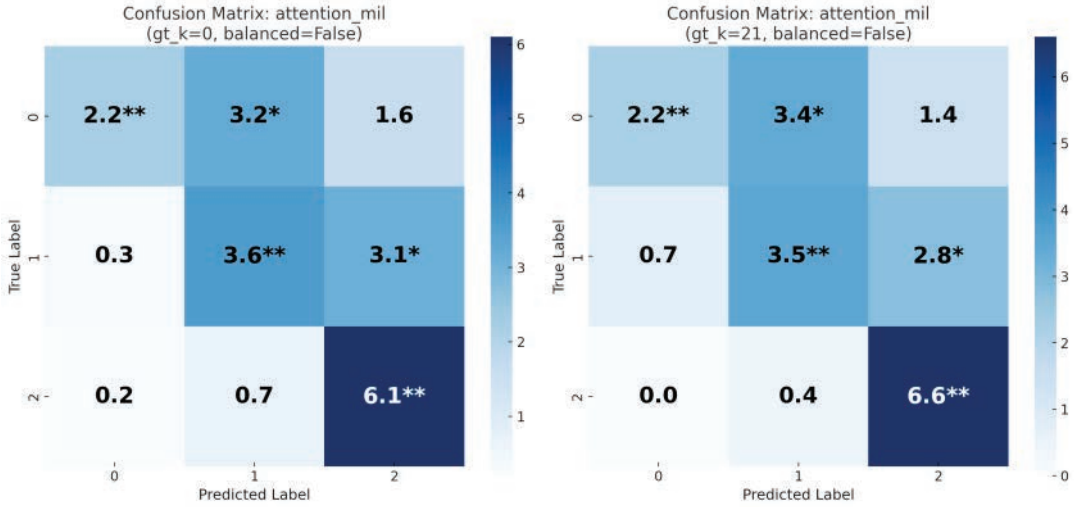

Attention-MIL gt(0) 혼동행렬 Attention-MIL gt(21) 혼동행렬

〈그림 5〉 Attention-MIL의 gt(0), (21) 혼동행렬 비교

이러한 현상은 선행연구의 결과와도 일치한다. Frangieh et al. (2024)는 AI가 생성한 텍스트가 인간이 작성한 텍스트보다 1인칭 대명사의 사용이 현저히 적다고 보고하였으며, 윤원재 (2024)에서는 AI 텍스트에서 긍정 감정 어휘는 비정상적으로 높게 나타나고 부정 감정은 억제되는 편향성이 존재함을 밝혔다.[25],[2] 또한 이찬영(2023)은 인간 번역문이 기계 번역문보다 문체적 변이가 풍부하며, 감탄적·강조적 표현에서도 일정 수준의 차이가 나타난다는 분석과 함께, 김미형(2004)은 한국어 텍스트에서 강조 부사('정말', '아주')와 감탄·의문 표지('!', '?')가 인간이 작성한 문서에서 더 다양하고 자연스럽게 나타난다고 보고하였다.[3-4]

이를 종합하면, 감정·경험·인칭 표현이 매우 제한된 군사 보고서에서는 단어 수준 신호보다 문장 배열·논리 흐름·의미적 일관성 등 상위 구조적 특징이 더 중요한 탐지 단서로 작용함을 알 수 있다. 따라서 단어 수준의 감정·경험 표현보다는 문맥의 전개 흐름, 의미적 안정성, 문장 간 연결 구조 등 상위 의미적 특성을 분석하는 접근(예: UMAP 기반 시각화)이 AI 개입 정도를 구분하는 데 더 유용할 수 있다.

앞서 3.1.3절에서 제시된 감정·경험 관련 변수의 탐색적 분석 결과 〈그림 2〉 또한 이러한 해석을 뒷받침한다. 해당 분석에서는 감정표현, 인칭표현, 강조·감탄 표지 등이 전체 데이

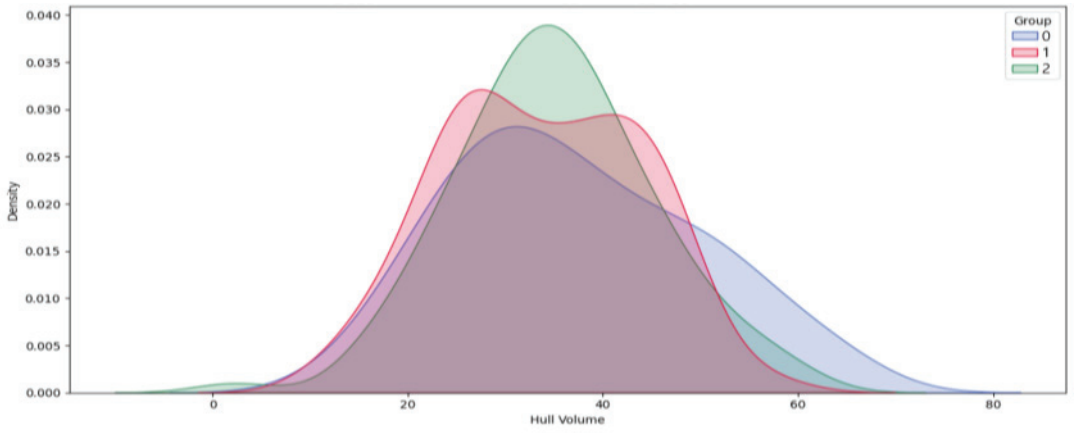

〈그림 6〉 클래스별 Convex Hull Volume 분포 비교 (Class 0-2)

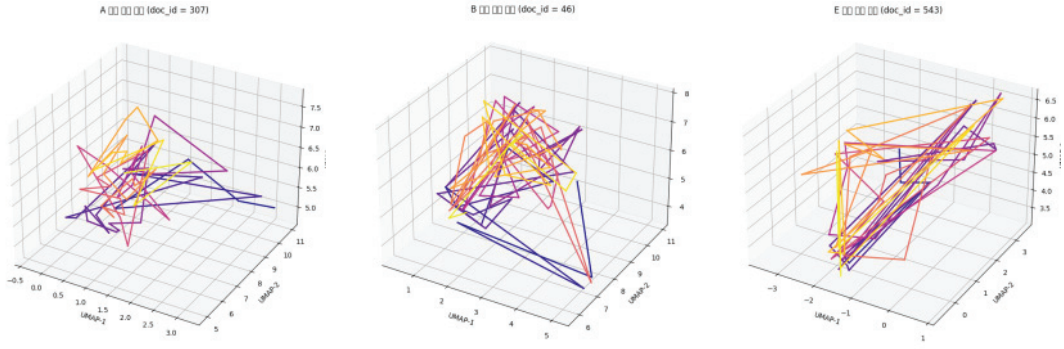

Class 0(인간 작성) Class 1(혼합형) Class 2(AI 작성)

〈그림 7〉 문서 전개 흐름 시각화(UMAP 궤적)

터에서 극히 낮은 수준으로 나타났으며, 이는 모델이 단어 수준의 감성·경험 표현보다는 문장 배열, 의미 전개 흐름, 논리 구조, 그리고 문장 간 일관성과 같은 상위 구조적 패턴을 중심으로 판단할 수밖에 없음을 의미한다.

4.4.3 문서 구조 및 의미 공간 시각화 (UMAP Analysis)

〈그림 6〉은 문서의 문장 임베딩을 계산해 Convex Hull Volume 분포를 나타낸 것이다. 각 문서는 의미 공간 상에서 문장들이 얼마나 넓게 퍼져 있는지를 부피로 수치화하였다. X축은 문서의 의미 확산 정도(Volume 크기), Y축은 해당 값을 가진 문서의 밀도(Density)를 의미한다. 볼륨이 클수록 문장 간 의미 변화가 크고, 글의 전개가 다양함을 뜻한다.

분포를 보면, Class 2(AI 작성) 문서(녹색)는 Class 0(인간 작성) 문서(청색)에 비해 훨씬 좁은 범위에 밀집되어 있다. 이는 AI가 유사한 어휘와 표현을 반복하며 제한된 의미 공간 안에서 문장을 구성하기 때문으로, 문장 간 변이가 작고 논리적 확장이 부족한 특징을 보여준다. 반면 인간이 작성한 문서는 다양한 주제 전환과 문체적 변화를 포함하여 의미 공간이 더 넓게 퍼져 있음을 확인할 수 있다. 흥미롭게도 Class 1(혼합형) 문서(적색)는 두 그룹의 중간 위치에 나타났다. 일부는 중심부가 비어 있고 가장자리가 퍼져 있었는데, 이는 사람이 AI가 작성한 글을 수정하거나 반대로 AI가 인간 문장을 보완한 경우처럼 두 스타일이 혼합된 특징을 반영한 결과로 해석된다.

〈그림 7〉은 UMAP을 이용해 문서 내 문장 간 의미 이동을 3차원 공간에 시각화한 것이다. 색의 변화는 문서의 시간적 전개(문장 순서)를 나타내며, 색이 부드럽게 이동할수록 글의 전개가 자연스러움을 의미한다. 각 점은 문장을, 선은 문장의 전개 흐름을 의미하며, 이 전체 궤적이 〈그림 6〉의 Convex Hull Volume을 구성한다. 궤적이 넓게 퍼질수록 의미 전개가 다양하고, 같은 지점을 반복해 순환할수록 단조로운 문장 구조를 보인다. Class 0(인간 작성)은 열린 형태의 확산 경로를 보이는 반면, Class 2(AI 작성)은 폐쇄형 경로로 수렴하는 패턴을 나타냈다. 이는 AI가 한정된 표현을 반복하며 의미 확장을 충분히 수행하지 못한다는 점을 시각적으로 보여준다.

5. 결론 및 향후 연구

본 연구는 생성형 AI가 작성한 문서를 단순히 구분하는 수준을 넘어, '왜 그렇게 판단했는가'를 설명할 수 있는 탐지 체계를 구축하기 위해 수행되었다. 이를 위해 문서 내 문장 단위 정보를 학습하는 다중 인스턴스 학습(Multiple Instance Learning, MIL) 구조를 중심으로, GT 주입 효과와 구조적 탐지 가능성을 함께 검토하였다. GT 데이터 주입 결과, Hybrid-MIL과 XGBoost 모델에서 탐지 신뢰도가 통계적으로 유의하게 향상되었다. ($p < 0.001$). 다만, Attention-MIL과 Mean-MIL은 성능 향상은 나타났으나 통계적 유의미성은 확보되지 않았다. 또한 MIL 모델은 문장을 독립된 단위로 학습하여 문맥의 흐름과 의미적 관계를 포착하였고, 그 결과 전통적인 머신러닝(XGBoost)보다 문서 구조와 논리 전개를 더 잘 반영하는 탐지가 가능했다.

이 연구의 시사점은 세 가지로 요약된다. 첫째, 데이터 신뢰도의 중요성이다. 소량의 고품질 교정 데이터만으로도 자가보고 라벨의 오류를 보정하고, 모델의 탐지 신뢰도를 높일 수 있었다. 둘째, 탐지 기준의 구조적·의미적 전환 가능성이다. MIL 모델은 단어 빈도나 문체적 표면 특징이 아니라, 문장 간의 논리적 연

결성과 의미적 일관성을 탐지 근거로 삼았다. 즉, 문서를 패턴으로 보는 수준을 넘어 이야기의 흐름으로 이해하는 탐지로 발전한 것이다. 셋째, 해석 가능한 탐지 체계의 실현이다. 가중치와 UMAP 시각화를 통해 모델이 어떤 문장에 주목해 판단했는지를 시각적으로 제시함으로써, 단순한 예측 결과가 아닌 판단의 근거를 함께 설명할 수 있었다.

그러나 본 연구에는 다음과 같은 한계가 존재한다. 첫째, 자가보고 라벨의 신뢰도 문제이다. 일부 응답자는 생성형 AI 활용 정도를 과소·과대 보고했을 가능성이 있어, 초기 라벨 자체의 불확실성이 존재했다. 둘째, 국방대학교 학생 보고서 중심으로 구성되어 주제·문체의 편향 가능성이 있었다. 특히 탐색적 분석 결과를 통해 감정·경험 관련 표현이 극히 낮게 나타나는 등 군사 보고서 특유의 정형적 문체가 확인되었으며, 이러한 문체적 일관성은 데이터 다양성을 제한하는 요인으로 작용한다. 이는 모델의 일반화 성능 평가에 구조적 한계를 초래한다. 셋째, 데이터(보고서와 GT 보고서)의 부족으로 인해 MIL 모델의 일반화 성능을 충분히 검증하기 어려웠다. 넷째, Attention 해석은 정성적 수준에 머물렀으며, 중요 문장과 예측 결과 간의 관계를 통계적으로 검증하지 못했다.

향후 연구에서는 이러한 한계를 보완하기 위해 세 가지 방향의 확장이 필요하다. 첫째, 데이터 출처와 문체적 구조의 다양성을 확보하기 위해 국방 이외의 다양한 문서 유형을 추가하여 모델의 적용 가능성을 체계적으로 검증해야 한다. 둘째, AI 모델별 문체 비교 분석을 수행하여 GPT, Claude, Gemini 등 주요 생성형 AI 간 언어적 차이를 정량적으로 규명할 필요가 있다. 셋째, 설명 가능한 탐지 체계(XAI + MIL)의 고도화를 통해 탐지 결과뿐 아니라 “왜 그렇게 판단했는가”를 시각적으로 명확히 제시할 수 있는 시스템으로 발전시켜야 한다. 또한 생성형 AI가 빠르게 고도화됨에 따라, 기존 탐지 모델이 시간이 지날수록 학습된 AI에 의해 무력화될 가능성도 존재한다. 따라서 탐지 기술의 목적은 완벽한 판별에 있지 않으며, 판단 과정과 근거를 투명하게 제시함으로써 신뢰 가능한 의사결정을 지원하는 데 핵심적 역할을 해야 한다. 이는 군사·안보 영역에서 문서의 신뢰성 평가와 판단 근거 제시를 강화하는 데 기여할 수 있으며, 향후 정보·심리전 환경에서도 활용 가능성을 제시한다.

결국 본 연구는 생성형 AI 탐지를 정확도 위주의 기술적 문제에서 벗어나, 문서의 구조적 · 의미적 단서를 활용하는 해석 가능 탐지 문제로 확장하였다. MIL 모델은 문서 내 문장 간의 배열, 연결 구조, 반복·전환과 같은 구조 기반 정보를 학습하였으며, GT 데이터는 자가보고 라벨의 불확실성을 보정하는 역할을 수행했다. 이를 통해 본 연구는 “정답을 맞히는 모델”을 넘어 “왜 그렇게 판단했는지 설명할 수 있는 모델”이 가능함을 실증적으로 확인하였다.

또한 본 연구는 제한된 규모와 정형적 문체라는 데이터 제약 속에서도 구조 기반 탐지 모델이 안정적으로 작동함을 확인하였으며, 보다 폭넓은 데이터 환경에서의 일반화 성능 검증은 향후 해결해야 할 과제로 남아 있다.

참 고 문 헌

국내 참고문헌

[1] 이재길. (2020). 심층 신경망을 활용한 라벨 노이즈에 강건한 학습법 연구. 석사학위 논문, 연세대학교.

[2] 윤원재. (2024). “이미지 생성형 AI의 감정 표현 한계와 비교 분석 – 영상 작업 AI ≠ A:I 중심으로”. 『조형미디어학 논문집』, 27(3), 23-34.

[3] 이찬영. (2023). “ChatGPT 등장 이후 기계번역과 인간번역의 문체 차이 변화”. 『번역학연구』, 29(4), 147-169.

[4] 김미형. (2004). “한국어 구어와 문어의 특징 연구”. 『한말연구』, 15, 23-73.

해외 참고문헌

[5] Yan, L., et al. (2023). Practical and ethical challenges of large language models in education: A systematic scoping review.British Journal of Educational Technology, 55(1), 90-112.

[6] Hu, G. (2023). Challenges for enforcing editorial policies on AI-generated papers.Accountability in Research, 31(6), 1-4.

[7] Samek, W., Wiegand, T., & Müller, K. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models.arXiv preprint arXiv:1708.08296.

[8] Kumarage, T., et al. (2023). "How Reliable Are AI-Generated-Text Detectors? An Assessment Framework Using Evasive Soft Prompts." In Findings of the Association for Computational Linguistics: EMNLP 2023, 1111-1124.

[9] Lipton, Z. C. (2018). The mythos of model interpretability.Communications of the ACM, 61(10), 36-43.

[10] Dang, Y., et al. (2024). Explainable and interpretable multimodal large language models: A comprehensive survey.arXiv preprint arXiv:2412.02104.

[11] Ilse, M., Tomczak, J., & Welling, M. (2018). Attention-based deep multiple instance learning.In Proceedings of the 35th International Conference on Machine Learning (ICML), PMLR 80, 2127-2136.

[12] Northcutt, C., Jiang, L., & Chuang, I. (2021). "Confident Learning: Estimating Uncertainty in Dataset Labels." Journal of Artificial Intelligence Research, 70, 1373-1411.

[13] Elkhatat, A., Elsaid, K., & Almeer, S. (2023). Evaluating the efficacy of AI content detection tools in differentiating between human and AI-generated text. International Journal for Educational Integrity, 19(1), 1-17.

[14] Pegoraro, A., et al. (2023). To ChatGPT, or not to ChatGPT: That is the question! arXiv preprint arXiv:2304.00045.

[15] Ippolito, D., et al. (2023). DetectGPT: Zero-shot detection of generated text.arXiv preprint arXiv:2301.11305.

[17] Zhang, X., et al. (2018). "Emotion Recognition Based on Electroencephalogram Using a Multiple Instance Learning Framework." In Intelligent Computing Theories and Application (ICIC 2018), LNCS 10955, 631-641.

[18] Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system.In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785-794.

[19] Liu, Y., et al. (2019). Fake news detection on social media: A data mining perspective. ACM Transactions on Intelligent Systems and Technology (TIST), 10(4), 1-20.

[20] Zellers, R., et al. (2019). Defending Against Neural Fake News.In Advances in Neural Information Processing Systems (NeurIPS 2019), 32, 9054–9065.
[21] Bolukbasi, T., et al. (2023). Visualizing linguistic diversity of text datasets synthesized by large language models.IEEE Transactions on Visualization and Computer Graphics, 30(1), 444–454.
[22] Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks.Information Processing & Management, 45(4), 427–437.
[23] Attia, M., Samih, Y., & Ehara, Y. (2023). Statistical measures for readability assessment. In Proceedings of the Joint 3rd NLP4DH and 8th IWCLUL, 153–161.
[24] Terčon, A., & Dobrovoljc, K. (2025). Linguistic characteristics of AI-generated text: A survey. Language Resources and Evaluation, 59(1), 1–28.
[25] Frangieh, C., Chocarro, R., & Miralles, I. (2024). Personal pronoun usage as an indicator of authorship: Human versus AI-generated text. Computational Linguistics and Applications, 15(2), 87–102.

저 자 소 개

박민지(E-mail: rungrungmjh@gmail.com)
현재 국방대학교 군사운영분석 석사과정
관심분야 : 국방 M&S, 생성형 인공지능

조남석(E-mail: ncho64@gmail.com)
2002 육군사관학교 전산학 학사
2007 미국 Air Force Institute of Technology 운영분석 석사
2016 미국 University of Wisconsin Madison 산업공학 박사
현재 국방대학교 국방AI/로봇학과 교수
국방로봇학회 사업 부회장
한국국방경영분석학회 이사/편집위원
관심분야 : 최적화, 시뮬레이션, 국방 M&S, 강화학습

군 사 과 학 연 구 지
제18권 제2호(2025년 12월)

신뢰성 기반 UAS 식별 프로토콜 표준화 동향 분석

Analysis of Standardization Trends in the Trustworthiness-Based UAS Identification Protocol

김한석[1] · 임효영[2]
Hanseok Kim · Hyoyoung Lim

ABSTRACT

The rapid growth of Unmanned Aircraft Systems (UAS) has increased the need for secure and trustworthy Remote Identification (RID). Conventional broadcast RID lacks authenticity guarantees and remains vulnerable to spoofing, especially in offline environments. To address these challenges, the Internet Engineering Task Force (IETF) developed the Drone Remote Identification Protocol (DRIP), enabling cryptographically verifiable and immediately actionable UAS identification. This paper analyzes the DRIP standards, including requirements (RFC 9153), cryptographic identifier structure (RFC 9374), system architecture (RFC 9434), and operational considerations (RFC 9575). We examine the DRIP Entity Tag (DET), offline trust validation, and crowdsourced RID mechanisms. The results highlight DRIP's potential to strengthen UAS security and interoperability, while identifying remaining challenges in scalability, privacy, and regulatory adoption.

Key Words : Unmanned Aircraft System (UAS); Remote Identification (RID); Drone Remote Identification Protocol (DRIP); DRIP Entity Tag (DET)

논문접수일 : 2025년 11월 7일, 심사일 : 2025년 11월 10일~11월 16일, 게재확정일 : 2025년 11월 16일
1) 육군
2) 국방대학교 사이버·컴퓨터공학과 교수

1. 서론

무인항공시스템(Unmanned Aircraft System, UAS)의 확산은 항공 교통 관리 뿐 아니라 공공 안전, 국가 안보 전반에 새로운 과제를 제기하고 있다. 특히 소형 무인항공기(Unmanned Aircraft, UA)는 레이더 반사면적(RCS)이 작아 탐지하기 어렵고, 고기동성 및 저고도 비행 능력을 통해 기존 감시 체계를 우회할 수 있기 때문에 신뢰 가능한 원격 식별(Remote Identification, RID) 체계의 필요성이 커지고 있다. 미국 연방항공청(FAA)과 유럽항공안전청(EASA)을 비롯한 주요 규제기관은 RID를 의무화했으나[1-3], 현행 브로드캐스트 기반 RID는 메시지의 무결성(Integrity)과 송신원(Source)에 대한 검증 기능이 부재하여 스푸핑(Spoofing) 공격에 취약하다는 한계가 있다[4]. 관찰자가 수신 정보의 진위를 현장에서 즉시 판별할 수 없다는 이러한 구조적 취약점은 공역 안보에 심각한 공백을 초래한다[7].

이러한 문제를 해결하기 위해 인터넷표준화기구(IETF)는 기존 인터넷 보안 아키텍처를 항공 식별 체계에 접목한 '드론 원격 식별 프로토콜(Drone Remote Identification Protocol, DRIP)'을 제안하였다[11]. UAS 식별·등록·검증의 전 과정을 암호학적으로 보호된 프레임워크 내에서 수행하도록 설계되었다. 이는 RFC 9153(요구사항), RFC 9374(식별자 구조), RFC 9434(아키텍처), RFC 9575(인증 포맷)등 일련의 표준 문서군으로 구체화되었으며, 로 구성되며, 오프라인 검증 가능성, 즉각적 대응성(Immediate Actionability), 프라이버시 보호, 그리고 글로벌 상호운용성 확보를 핵심 목표로 한다[5-8]. 특히 핵심 요소인 DRIP 엔티티 태그(DET)는 계층적 호스트 식별 태그(HHIT) 기반의 암호 식별자로, 저전력·저대역폭의 브로드캐스트 환경에서도 높은 신뢰성과 효율성을 동시에 달성할 수 있는 기술적 토대를 제공한다.

본 연구는 IETF DRIP 표준 문서군을 체계적으로 분석하여, 차세대 UAS 식별 체계가 요구하는 '신뢰성 기반 식별(Trustworthiness-based Identification)'의 설계 원리와 구현 요소를 고찰한다. 구체적으로 DET 기반의 식별자 구조, 계층적 신뢰 레지스트리(RAA/HDA), 경량 인증 포맷(Wrapper·Manifest), 그리고 군중 기반 식별(CS-RID) 등 핵심 기술의 보안성과 실용성을 평가한다. 나아가 이러한 기술적 구조가 공역 관리 및 국방 감시 체계에 미치는 정책적·운용적 함의를 탐색함으로써, 향후 신뢰 기반 통합 공역 관리 체계의 발전 방향을 제시하고자 한다.

본 연구의 주요 기여는 다음과 같다.

1. 기존 RID 체계의 보안적 한계를 규명하고, DRIP이 제공하는 신뢰성, 확장성, 오프라인 검증 능력의 기술적 우위를 분석한다.

2. DET 및 계층적 레지스트리(RAA/HDA) 구조가 국제 항공 규제 및 인터넷 표준 생태계와 상호 연동되는 메커니즘을 고찰한다.

3. 향후 대규모 UAS 통합 운용 환경에서 필수적인 보안, 프라이버시, 책임추적성(Accountability) 및 정책 정합성 측면의 잔존 과제를 도출하고, 이에 대한 후속 연구 방향을 제안한다.

DRIP은 단순한 식별 정보의 전송을 넘어, 민간·공공·국방 영역을 포괄하는 신뢰 기반 공역 안보의 핵심 표준으로 발전할 잠재력을 지닌다.

2. 기술 및 표준화 배경

UAS의 민간 상용화 확산과 공역 통합 논의가 본격화됨에 따라, 각국 규제기관과 국제

표준기구는 식별·등록·추적 체계의 제도화 및 기술 표준화를 병행하여 추진하고 있다. 이러한 흐름은 단순한 정적 기체 등록을 넘어, 운용중인 기체의 실시간 식별(Real-time Identification)과 전송 정보의 검증 가능성(Verifiability)을 공역 관리의 핵심 요건으로 격상시키는 정책적 변화를 반영한다. 특히 이기종 기체와 다양한 통신 수단을 포괄할 수 있는 기술 중립적(Technology-neutral) 접근이 요구되고 있으며, 이는 향후 국제적 상호운용성 확보를 위한 필수 기반으로 평가된다.

2.1 해외 정책 및 기술 동향 : 미국과 유럽

미국과 유럽은 드론 RID을 통해 공공 안전과 공역의 안전 및 효율성을 확보하려는 공통의 목표를 갖고 있으나, 구체적인 규제 접근 방식과 도입 우선순위에서는 차이를 보인다[14].

미국 연방항공청(FAA)은 드론의 보안성 확보를 최우선 목적으로 설정하고, 기술 성숙도가 높은 브로드캐스트 중심의 RID 모델을 채택해 규제를 확정했다. 이는 네트워크 인프라 의존성을 최소화하는 한편, 규정 준수 범위와 감시 단계를 점진적으로 확대하는 전략을 취하고 있음을 보여준다[1-2, 13-14].

반면 유럽항공안전청(EASA)은 드론의 보안을 위한 '직접 원격 식별(Direct Remote ID)'과 공역 통합 관리를 위한 'E-Identification'을 구분하여 추진하는 이원화된 전략을 취하고 있다. 보안 목적의 Direct Remote ID는 방송형 기술을 기반으로 하며, 유럽 규정(EU) 2019/945 및 947에 따라 오픈 카테고리(Open Category) 등 특정 등급의 드론에 의무화되어 있다. 이와 동시에 유럽은 드론교통관리 시스템인 'U-Space' 구현을 위해 네트워크 기반의 E-Identification을 별도로 고려하고 있다. 이는 단순 식별을 넘어 추적, 전술적 충돌 방지 등 고도화된 서비스를 제공하기 위한 것으로, U-Space 규정 및 표준화 범위 내에서 다루어지고 있다[14].

2.2 국내 정책 및 기술 동향

국내의 경우, 국토교통부를 중심으로 한국형 무인비행장치 교통관리체계인 'K-드론시스템(K-Drone System)' 개발이 추진되면서 드론 식별 체계에 대한 논의가 진행되고 있다[12]. 정책적으로는 「항공안전법」에 따라 최대이륙중량 2kg을 초과하는 드론과 영리 목적의 드론에 대한 기체 신고가 의무화되어 있으며, 특정 비행 금지 구역에서는 사전 승인이 요구된다. 그러나 미국(FAA)이나 유럽(EASA)이 RID 장치 장착을 의무화하고 실행 단계에 진입한 것과 달리, 국내에서는 아직 RID 시스템 장착이 법적으로 전면 의무화되지는 않은 상태이다

기술 개발 측면에서는 한국전자통신연구원(ETRI)을 중심으로 2019년부터 '저고도 소형 드론 식별·주파수 관리 기술 개발' 과제가 수행되어 왔으며, ASTM F3411 등 국제 표준을 분석하여 국내 실정에 맞는 식별 기술 기반을 마련하고 있다. 한국은 세계 최고 수준의 이동통신 인프라를 보유하고 있어 LTE/5G 기반의 네트워크 RID 기술 도입에 유리한 환경을 갖추고 있으나, 즉각적인 보안 식별이 가능한 방송형(Broadcast) RID 기술 또한 단계적으로 확보해 나가는 추세이다.

특히 국내 연구진에 의해 수행된 상용 UAV 탐지·식별 시스템(예: DJI Aeroscope)에 대한 보안 취약점 분석 결과에 따르면, 현재 널리 사용되는 비암호화 기반의 브로드캐스트 RID 기술은 재전송 공격(Replay Attack)을 통해 허위 드론 궤적을 생성하거나

시스템을 무력화시킬 수 있는 치명적인 취약점이 존재하는 것으로 확인되었다[16]. 따라서 단순한 식별 정보 전송을 넘어, DRIP과 같이 메시지의 기밀성과 인증을 보장하고, 재전송 공격을 방지할 수 있는 신뢰성 기반 식별 프로토콜의 도입이 시급하다.

2.3 기존 기술 표준의 현황과 한계

기술 표준화 측면에서, 미국 ASTM F3411-22a 표준은 브로드캐스트 및 네트워크 RID 메시지 형식과 전송 방식을 정의한 최초의 포괄적 산업 표준으로, FAA 규제의 기술적 준거를 제공한다[9]. 3GPP는 이동통신 인프라를 활용한 UAS 지원 아키텍처를 제시하며, 특히 네트워크 중심의 식별·추적 및 UTM(UAS Traffic Management) 연동을 중점적으로 다룬다[10]. 그러나 이들 표준은 각 통신 환경에 최적화된 전송 모델을 제공함에도 불구하고, 암호학적 기원 검증(Cryptographic provenance), 레지스트리 기반 신뢰사슬, 그리고 오프라인 환경에서의 데이터 무결성 보장 등 보안과 신뢰성(Trustworthiness)을 위한 핵심 컴포넌트 정의가 부재하거나 제한적이라는 공통적인 한계를 가진다.

2.4 IETF DRIP의 등장 및 역할

이러한 보안 공백을 해결하기 위해 IETF는 기존 인터넷 인프라와 보안 프로토콜을 UAS 식별 체계에 접목하는 표준화 활동을 수행하고 있다. DRIP(Drone Remote Identification Protocol)은 RID 시스템이 갖추어야 할 핵심 요구사항(RFC 9153[1])을 정의하고, 이를 바탕으로 인터넷 프로토콜 기반의 식별·검증·등록 프레임워크를 제시한다. DRIP은 단순한 위치 정보의 방송을 넘어, 오프라인 검증 가능성, 즉각적 대응성(Immediate Actionability), 글로벌 유효성, 계층적 책임 추적성을 보장하는 것을 목표로 한다. 이는 기존 RID 표준(ASTM 등)이 정의한 전송 계층 위에, 검증 가능한 신뢰(Verifiable Trust)를 부여하는 상위 보안 계층을 구현하는 접근 방식이다.

국제 RID 표준화는 규제, 통신, 보안 요구사항이 교차하는 지점에서 점진적으로 수렴하고 있다. 실시간 항공 교통 관리와 디지털 공역 서비스가 고도화됨에 따라, RID 체계는 단순 식별 정보 제공을 넘어 정책적 책임성과 기술적 무결성을 동시에 보장하는 구조로 발전해야 한다. 이러한 맥락에서 DRIP은 인터넷 신뢰 모델을 UAS 환경에 최적화하여 적용한 대표적 사례로, 기존 표준의 한계를 보완하고 글로벌 상호운용성을 지원하는 기술적 토대를 제공한다. 다음 장에서는 DRIP의 핵심 구성 요소인 DRIP 엔티티 태그(DET)와 암호 기반 식별 구조를 분석하여, 해당 체계의 구체적인 구현 원리와 기술적 특성을 검토한다.

3. DRIP 식별 체계 및 DRIP 엔티티 태그(DET) 구조

무인항공시스템(UAS) RID 환경에서 식별자는 단순한 기체 인식 수단을 넘어, 신뢰 기반 항공 교통 관리(UAS Traffic Management, UTM)를 지탱하는 핵심 인프라로 작용한다. 특히 네트워크 연결이 간헐적이거나 부재한 브로드캐스트 기반 RID 환경에서는, 수신된 데이터의 무결성(Integrity)과 원천(Origin)을 관찰자가 현장에서 즉시 검증할 수 있는 자가 검증(Self-verifying) 메커니즘이 필수적이다. 이에 IETF DRIP 워킹그룹은 암호학적 식별자(Cryptographically Generated Address, CGA) 개념을 도입하여, 식별자 내에 검증 경

로와 소유권 증명 요소를 내재화한 신뢰 모델을 제안하였다. 본 장에서는 DRIP 아키텍처의 핵심인 DRIP 엔티티 태그(DET)의 구조적 특성과 보안 메커니즘을 심층 분석한다.

3.1 DRIP 엔티티 태그(DET)의 개념 및 역할

DRIP 엔티티 태그(DET)는 UAS 및 운용 주체에 부여되는 암호 기반 식별자(CDI)로서, IETF RFC 9374에 정의된 EdDSA(Ed25519) 공개키와 cSHAKE128 해시 알고리즘을 결합한 계층적 호스트 식별 태그(Hierarchical HIT, HHIT) 규격을 따른다. 이는 단순 일련번호나 정적인 레지스트리 조회에 의존하는 레거시 식별 방식과 달리, 공개키 기반의 동적 신뢰 모델을 따른다. DET는 128비트의 IPv6 주소 형식과 호환되도록 설계됨으로써 기존 인터넷 라우팅 인프라와의 정합성을 확보하였으며, 대규모 군집 비행 등 미래 공역 환경이 요구하는 주소 공간의 확장성을 충족한다. [그림 1]은 DRIP RID 신뢰체계에서 DET가 수행하는 역할을 개략적으로 나타낸다.

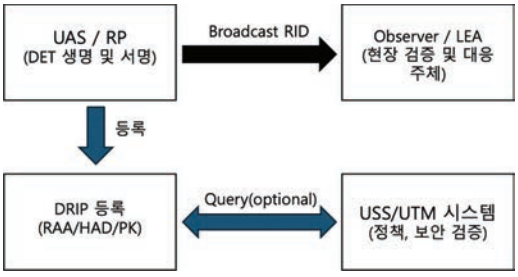

[그림 1] DRIP RID 신뢰 체계에서의 DET 기능 개요 (IETF RFC 9434[8] 기반 재구성)

DET의 핵심 기능은 기체 식별 기능을 넘어, '식별자–등록 정보–책임 주체' 간의 암호적 연계를 제공하는 데 있다. 이를 통해 위조(Forgery), 스푸핑(Spoofing), 신분 위장(Masquerading) 공격을 원천적으로 완화(Mitigate)할 수 있다. 이러한 특성은 신뢰 수준이 불확실한 비협력적 공역, 전술적 통신 제약 환경, 혹은 네트워크 단절 상황에서도 수신된 식별 정보를 독립적으로 검증해야 하는 국방의 작전 요구사항에 부합한다. 즉, DET는 운영자와 항공기의 신원을 수학적으로 증명할 수 있는 근거를 제공하며, 필요 시 법적·작전적 책임 추적성을 보장한다.

나아가 DET는 전통적 항공 분야의 피아식별(Identification Friend or Foe, IFF) 개념을 민·군 겸용 환경으로 확장한 형태적 유사성을 지닌다. 전통적인 군사 IFF 체계(예: Mode 4/5)는 질문기(Interrogator)가 암호화된 도전 값(Challenge)을 보내면 응답기(Transponder)가 이를 처리하여 응답(Reply)하는 '양방향 질문–응답' 방식을 통해 아군임을 입증한다. 반면, DRIP의 DET는 질문 과정 없이도 브로드캐스트된 메시지 자체에 포함된 전자서명과 식별자(DET) 간의 수학적 검증을 통해 송신자의 신원을 보증한다는 점에서 '수동적(Passive)이지만 검증 가능한' 피아식별 기능을 수행한다. 군사 적용 IFF와 동적 프로토콜은 상이하나, 안티 드론(counter-UAS, C-UAS) 체계, 중요 시설 방호, 영공 감시 작전 관점에서 DET는 검증 가능한 비인가 기체와 협력적 아군 자산을 신속히 분류하는 식별 수단으로 기능할 수 있다. 이는 회색지대 도발이나 비정규 위협에 대응하는 민·군 통합 감시 네트워크 구축에 있어 중요한 전략적 함의를 갖는다.

3.2 HHIT 기반 암호 설계와 구조

DET는 기술적으로 계층적 호스트 식별 태그(Hierarchical Host Identity Tag, HHIT) 규격을 따른다[6].기이는 [그림 2] 와 같이 평면적인 구조의 기존 Host Identity Tag(HIT)에 계층적 등록 권한 요소를 결합한 것으로,

[표 1] HHIT 기반 DRIP DET 구성 요소 및 기능 요약 (IETF RFC 9374[6] 기반 재구성)

필드명	비트길이	설명	예시 값 / 역할
IPv6 Prefix	28	DRIP용 특수 IPv6 주소 영역을 지정 (IANA 등록)	2001:30::/28
RAA (Registered Assigning Authority)	14	국가 단위의 등록기관 식별자 (예: FAA, EASA 등)	000001 → 미국 FAA
HDA (HHIT Domain Authority)	14	RAA 아래의 하위 등록기관 식별자 (예: UAS 서비스 공급자)	000010 → 특정 USS
HHIT Suite ID	8	사용된 서명 및 해시 알고리즘의 종류	0 5 (EdDSA/cSHAKE128)
ORCHID Hash	64	드론 공개키(Host Identity)에서 파생된 암호학적 해시	공개키의 요약값
총합	128 bits	IPv6 주소 형식의 고유한 DET 완성	2001:30:0001:0002:0 5:abcd:1234:5678

단순 식별을 넘어 정책 기반의 거버넌스와 책임 추적성을 아키텍처 레벨에서 지원하는 프레임워크다.

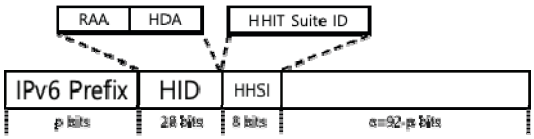

[그림 2] HHIT Format (IETF RFC 9374[6] 기반 재구성)

HHIT는 128비트 주소 공간 내에 암호 해시(Entropy)와 등록기관 식별자(RAA, HDA)를 구조적으로 캡슐화(Encapsulate)한다. 이러한 설계는 표준 IPv6 네트워크 스택을 그대로 활용하면서도, UAS 환경에 필수적인 경량성(Lightweight), 해시 충돌 저항성(Collision Resistance), 그리고 위조 방지(Unforgeability) 속성을 동시에 달성한다. 상세 구조는 [표 1]과 같다.

HHIT 기반 DET 생성 과정에 내제된 핵심 암호학적 요소와 그 효과는 다음과 같다. 첫째, 공개키 기반 해시 생성(public-key-derived hash) 메커니즘을 통해 식별자의 위조를 계산적으로 불가능하게 한다. 공격자가 임의로 유효한 DET를 생성하더라도, 이에 대응하는 개인키 소유를 증명할 수 없으므로 검증 과정에서 즉시 차단된다. 둘째, Ed25519와 같은 고효율 타원곡선 서명(EdDSA) 알고리즘을 채택하여 연산자원과 전력이 제한적인 소형 UAS 플랫폼에서도 실시간 서명 및 검증이 가능하도록 최적화하였다. 셋째, 확정적 해시 구조(deterministic hash construction)를 적용하여 식별자 재생성 및 검증의 일관성을 보장한다. 이는 저비용 상용(COTS) 기체부터 고가용성 국방 UAS 체계에 이르기까지 다양한 운용 환경에서 적용 가능한 확장성을 제공한다.

HHIT의 계층 구조는 정책 기반 필터링을 가능하게 하여 군사 및 보안 작전 측면에서 중요한 의미를 갖는다. 예를 들어 중요 인프라 방호 작전 시 특정 국가나 특정 기관에 소속된 기체만들 화이트리스트(Whitelist)로 식별하거나, 반대로 특정 그룹을 일괄 차단하는 식의 유연한 공역 통제가 가능하다. 이는 기존 RID 체계가 제공하지 못하는 권역별 우선대응, 우군·민간·비인가 기체 분리 식별, 그리고 전자전 상황하에서의 최소 식별 기능 유지와 같은 작전적 요구를 충족시킨다. 또한, 연

합작전 및 다국적 작전 환경에서 HHIT 기반 계층 구조는 상호 식별 및 정보 공유 정책의 표준화된 프레임워크를 제시할 수 있다.

4. 분석 및 향후 과제

4.1 DRIP의 신뢰 모델 및 핵심 요구사항 분석

DRIP은 기존의 브로드캐스트 기반 RID 체계가 스푸핑(spoofing) 공격이나 메시지의 진위(authenticity) 검증에 취약하다는 구조적 한계를 극복하기 위해 설계되었다. DRIP은 암호학적으로 생성된 식별자(Cryptographic Derived Identifier, CDI)를 기반으로, 식별자 자체에 검증 경로를 포함하는 자가 검증(self-verifying) 구조를 채택함으로써, 인터넷 연결이 불안정하거나 단절된 환경에서도 관찰자(Observer)가 메시지의 신뢰성을 독립적으로 확인할 수 있도록 한다.

RFC 9153에서는 DRIP의 다양한 요구사항을 정의하고 있으며, 이 중에서도 GEN-1, GEN-2, GEN-3, 그리고 ID-5는 DRIP 신뢰 모델을 구성하는 핵심 요소로 간주된다. 각 항목의 의미와 기술적 요건은 다음과 같다.

- GEN-1: Provable Ownership (소유권 입증)
  수신된 식별자가 실제로 메시지를 송신한 주체의 것임을 암호학적으로 입증할 수 있어야 한다. 이를 위해 송신자는 자신의 공개키(Host Identity, HI)를 사용하여 메시지에 서명하며, 관찰자는 이 서명을 통해 송신자 소유권을 검증할 수 있다. 이러한 검증은 인터넷 연결 없이도 로컬에서 오프라인으로 수행 가능해야 한다.
- GEN-2: Provable Binding (바인딩 입증)
  송신자가 전송하는 여러 유형의 메시지(예: 위치 정보, 시스템 상태, 운영자 ID 등)가 동일한 주체로부터 발신되었음을 입증할 수 있어야 한다. DRIP은 이를 위해 메시지 집합을 하나의 구조로 묶고 서명하는 Wrapper 또는 Manifest 형식을 통해 메시지 간 암호학적 바인딩을 제공한다. 이를 통해 메시지 위변조 및 송신자 가장(spoofing) 시도를 방지할 수 있다.
- GEN-3: Provable Registration (등록 입증)
  사용된 식별자가 신뢰 가능한 등록기관에 의해 사전 등록되었음을 입증할 수 있어야 한다. DRIP에서 사용하는 식별자인 DRIP Entity Tag(DET)는 그 내부 구조에 등록기관 정보를 내포하고 있으며, 이를 통해 상위 등록기관(RAA: Registered Assigning Authority) 및 하위 도메인 권한기관(HDA: HHIT Domain Authority)을 추적 가능하게 함으로써 등록 정보를 검증할 수 있다.
- ID-5: Non-spoofability (위조 불가성)
  DET는 송신자의 공개키에서 파생된 해시값을 포함하므로, 동일한 공개키 없이 동일한 DET를 생성할 수 없다. 이러한 구조는 DET의 고유성과 위조 불가능성을 보장하며, 최소한의 RID 메시지 세트 내에서도 송신자의 진정성을 유지할 수 있도록 한다.

이와 같이 DRIP의 신뢰 모델은 ▲ 소유권 입증(GEN-1), ▲ 메시지 간 바인딩(GEN-2), ▲ 등록기관 검증(GEN-3), ▲ 위조 불가성(ID-5)와 같은 상호 연계된 요구사항들을 기반으로 구성된다. 이 요구사항들은 DRIP 식별자 체계의 보안성과 신뢰성을 구성하는 기술적 기반이자, 향후 실질적인 원격식별 및 감시체계의 표준화 확장을 위한 핵심이라 할 수 있다.

4.2 DRIP 인증 포맷 및 오프라인 검증 기술

DRIP은 ASTM F3411-22a 표준[9]에서 정의된 Authentication Message(Type 0x2) 및 그 확장 형태인 Specific Authentication Method(SAM, Type 0x5)을 기반으로 다양한 인증 포맷을 정의하고 있다. 이러한 구조는 브로드캐스트 RID 환경에서의 메시지 진위 검증과 송신자 식별의 신뢰성을 확보하기 위한 것으로, 특히 인터넷 연결이 제한된 상황에서도 메시지의 자가 검증이 가능하도록 설계되었다.

DRIP은 SAM Type 0x5 하위에 다음과 같은 인증 포맷들을 정의하고 있으며[7], 각각은 고유한 기능과 구조를 통해 다양한 인증 요구사항을 충족시킨다.

- DRIP Link (SAM Type 0x01)
  DRIP Link는 등록 기관 간 신뢰 사슬(trust chain)을 전송하는 Broadcast Endorsement(BE) 포맷을 포함한다. 구체적으로, 상위 등록기관(예: RAA 또는 HDA)은 하위 엔티티(예: UA)의 DET 및 공개키(HI)에 대한 서명을 통해 해당 등록을 보증한다. 이러한 서명 기반 보증은 등록 계층의 유효성과 소유권을 동시에 입증하는 수단으로 활용된다.
  관찰자는 DRIP Link 메시지를 수신함으로써 상위 기관의 HI를 획득하고, 이를 로컬에 캐싱하여 이후 UA가 전송하는 다른 메시지들의 서명을 오프라인 환경에서도 검증할 수 있다. 이는 GEN-3(등록 입증) 요구사항과 오프라인 인증 지원을 동시에 만족시킨다.
- DRIP Wrapper (SAM Type 0x02)
  Wrapper는 UAS가 전송하는 복수의 ASTM 메시지(예: 위치·벡터, 시스템, 운영자 ID 등)를 단일 구조로 래핑(wrapping)하고, 여기에 단일 서명을 적용함으로써 전체 메시지 집합의 무결성과 진위를 보호하는 방식이다. RFC9575에 따르면, Wrapper는 최대 4개의 메시지를 포함할 수 있으며, 이들 메시지는 UA-Signed Evidence 구조 내에 포함되어 송신자의 개인키로 서명된다.
  이를 통해 관찰자는 메시지들의 상호 바인딩 관계를 검증할 수 있으며, 메시지 변조 및 스푸핑 공격을 방지할 수 있다. Wrapper는 특히 GEN-2(바인딩 입증) 요구사항을 충족시키는 핵심 메커니즘으로 작용한다.
- DRIP Manifest (SAM Type 0x03)
  DRIP Manifest는 보다 확장된 메시지 인증 구조로, 개별 메시지를 직접 포함하는 대신, 이미 전송된 메시지들의 해시 목록을 서명하는 방식으로 작동한다. 이를 통해 Wrapper의 메시지 수 제한(4개)을 극복하면서도 무결성을 검증할 수 있으며, 최대 11개의 메시지를 단일 Manifest에 포함할 수 있다.
  Manifest는 이전 및 현재 Manifest의 해시값(Previous Manifest Hash, Current Manifest Hash)을 연결함으로써, 일종의 메시지 원장(ledger) 구조를 형성하며, 이로써 메시지 연속성과 변경 불가능성(non-repudiation)을 보장한다. 또한 해시 연결 구조는 재전송 공격(replay attack) 및 위변조 탐지에도 효과적으로 작동한다.
- 오프라인 검증 메커니즘
  DRIP 인증 포맷은 관찰자가 네트워크 연결 없이도 메시지 진위를 검증할 수 있는 구조를 제공한다. 구체적으로, 관찰자는 DRIP Link 메시지로부터 획득한 상위 등록기관(HDA 또는 RAA)의 HI를 이용하여 UA가 전송한 Wrapper 또는 Manifest의 서명을

검증할 수 있다. 이후 해당 메시지에 포함된 정보(예: 위치 정보, ID 등)가 실제 관측값과 일치하는 경우, 송신자의 신뢰성과 메시지의 정당성을 현장에서 독립적으로 입증할 수 있다.

이와 같은 오프라인 검증은 관찰자가 상황에 신속하게 대응할 수 있도록 함과 동시에 스푸핑 및 재전송 공격에 대한 방어 수단으로 작용함으로써, DRIP의 근본적인 보안 목표를 실현하는 데 핵심적인 역할을 수행한다.

4.3 계층적 등록 기관 구조(RAA/HDA)와 DNS 연동 레지스트리

DRIP에서 사용되는 식별자인 DET(DRIP Entity Tag)는 계층적 구조의 HHIT(Hierarchical Host Identity Tag)를 기반으로 하며, 내부에 상위 및 하위 등록기관을 식별하는 두 개의 14비트 필드—RAA(Registered Assigning Authority) 및 HDA(HHIT Domain Authority)—를 포함한다. 이와 같은 계층적 구조는 등록기관 탐색(ID-2)을 가능하게 하며, 전 세계적으로 고유한 식별자 부여를 통해 충돌 방지와 책임 추적성(accountability)을 보장한다.

- 계층적 등록기관 구조

  RAA(Registered Assigning Authority): 국가 단위의 민간항공당국(CAA) 또는 그에 준하는 기관을 식별한다. 예를 들어, 미국의 FAA(Federal Aviation Administration), 유럽의 EASA(European Union Aviation Safety Agency), 일본의 JCAB(Japan Civil Aviation Bureau) 등이 RAA 역할을 수행할 수 있다.

  HDA(HHIT Domain Authority): RAA로부터 위임받은 하위 등록기관으로, UAS 서비스 공급자(UAS Service Supplier; USS), 인터넷 서비스 제공자(ISP), 또는 기타 신뢰기관이 해당 역할을 수행할 수 있다.

  이러한 이중 계층 구조는 각 DET의 발급 및 관리 권한을 명확히 하며, DRIP DIME(DRIP Identity Management Entity)을 통한 등록 데이터의 출처 확인 및 검증을 가능하게 한다. 이는 특히 GEN-3(등록 입증) 및 ID-2(등록기관 탐색 가능성) 요구사항의 실현에 중요한 역할을 수행한다.

- DNS 기반 공개 및 비공개 레지스트리 관리

  DRIP는 DET 관련 정보를 공개 정보 레지스트리와 비공개 정보 레지스트리로 분리하여 관리함으로써, 정보 접근성과 프라이버시 보호를 동시에 달성한다.

  공개 정보 레지스트리 (REG-1): DET는 IPv6 주소 형식을 채택하고 있으므로, 이를 도메인 이름 시스템(DNS)에 등록하여 공개키(HI)를 HIP 리소스 레코드(HIP RR) 형태로 제공할 수 있다. DNSSEC(DNS Security Extensions)을 적용함으로써 레코드의 무결성을 보장하며, 관찰자는 DET를 통해 등록기관의 HI를 검색하고, 이를 기반으로 서명을 검증할 수 있다.

  비공개 정보 레지스트리 (REG-2): 운영자의 개인정보(PII), 운용 정책, 비행 경로 등과 같이 민감한 정보는 강력한 접근 제어(AAA; Authentication, Authorization, Accounting)가 적용된 채널을 통해 제공된다. RDAP(Registration Data Access Protocol) 또는 WebFinger와 같은 표준 프로토콜이 사용되며, 이러한 비공개 레지스트리는 일반적으로 USS 또는 국가 CAA가 통합적으로 운영하며 법적·보안적 준거를 따른다.

5. 결론

본 연구에서는 차세대 무인항공시스템(UAS) 식별을 위한 글로벌 표준인 IETF DRIP(Drone Remote Identification Protocol)의 구조적 특성과 보안 메커니즘을 심층적으로 분석하였다. 연구 결과, DRIP은 기존 브로드캐스트 원격식별(RID) 기술이 가진 보안 취약점을 극복하기 위해 HHIT(Hierarchical Host Identity Tag) 기반의 암호학적 식별자(DET)와 경량 인증 프로토콜을 도입하여, 식별 정보의 무결성과 송신원 인증을 보장하는 신뢰 프레임워크를 제공함을 확인하였다.

특히, DRIP은 네트워크 연결이 불안정하거나 단절된 전술적 환경에서도 수신자가 메시지의 진위를 독립적으로 판별할 수 있는 자가검증(Self-verifying) 기능을 명시하였다. 또한, RAA(Registered Assigning Authority)와 HDA(HHIT Domain Authority)로 구성된 계층적 레지스트리 구조는 기체의 소속과 권한을 명확히 정의함으로써, 민·관·군이 혼재된 통합 공역에서 비인가 기체와 아군 자산을 신속히 분류하는 피아식별(IFF)의 보조 수단으로서 군사적 활용 가능성이 있을 것으로 평가된다.

그러나 본 연구는 IETF 표준 문서(RFC)에 기반하여 프로토콜의 설계 원리와 구조적 적합성을 이론적으로 분석하는 데 중점을 두었으며, 실제 비행 환경에서의 시스템 성능 검증이 수행되지 않았다는 한계가 존재한다. 특히 다수의 드론이 밀집된 고밀도 트래픽 환경에서 암호화 및 인증 처리에 따른 통신 오버헤드, 메시지 처리 지연시간(Latency), 그리고 패킷 손실률 등에 대한 정량적 데이터가 부족하다. 이러한 성능 지표는 실시간성이 필수적인 항공 관제 및 방공 작전에서 매우 중요한 요소이므로, 향후 실증 실험이나 시뮬레이션을 통한 구체적인 검증이 요구된다.

결론적으로 DRIP와 같은 네트워크 원격 식별 프로토콜의 연구는 단순한 식별 정보의 전송을 넘어, 미래 항공 모빌리티(AAM)와 한국형 K-드론시스템(K-Drone System)의 보안성을 강화하고 신뢰 기반의 공역 관리를 실현하기 위한 필수적인 과제라고 판단된다.

참 고 문 헌

[1] FAA, “Remote Identification of Drones,” 2021, Accessed: 2025-11-30. [Online]. Available: https://www.faa.gov/uas/getting_started/remote_id

[2] FAA, “Remote Identification (RID) Compliance,” 2023, Accessed: 2025-11-30. [Online]. Available: https://www.faa.gov/licenses_certificates/aircraft_certification/aircraft_registry/RID

[3] E. Commission, “Easy Access Rules for Unmanned Aircraft Systems” EU, Tech. Rep., May 2021, Accessed: 2025-11-30. [Online]. Available: https://www.dronespace.at/jart/prj3/dronespace/data/uploads/Easy%20Access%20Rules%202024.pdf

[4] Veara, Jason, et al. "TBRD: TESLA Authenticated UAS Broadcast Remote ID." arXiv preprint arXiv:2510.11343 (2025).

[5] Wiethuechter, A., R. Moskowitz, and A. Gurtov. "RFC 9153: Drone Remote Identification Protocol (DRIP) Requirements and Terminology." (2022).

[6] Moskowitz, R., et al. "RFC 9374: DRIP Entity Tag (DET) for Unmanned Aircraft System Remote ID (UAS RID)." (2023).

[7] Card, S., and R. Moskowitz. "RFC 9575: DRIP Entity Tag (DET) Authentication Formats and Protocols for Broadcast Remote Identification (RID)." (2024).

[8] Card, S., et al. "RFC 9434: Drone Remote Identification Protocol (DRIP) Architecture." (2023).

[9] Standard Specification for Remote ID and Tracking, ASTM Standard ASTM F3411-22a, 2022. Accessed: 2025-11-30. [Online]. Available: http://www.astm.org/f3411-22a.html

[10] 3GPP, “3GPP TR 36.777:study on enhanced support for aerial vehicles,” Accessed: 2025-11-30. [Online]. Available: https://lnkd.in/gR5fpdf

[11] “IETF – Drone Remote ID Protocol,” Accessed: 2025-11-30. [Online]. Available: https://datatracker.ietf.org/group/drip/documents/

[12] 국토교통부, 항공안전기술원. 2023, 「2023년 K-드론시스템 실증지원 사업」 공고, Accessed: 2025-11-30. [Online]. Available: https://www.kiast.or.kr/kr/cop/bbs/BBSMSTR_000000000031/selectBoardArticle.do?nttId=B00000002634fq5gN1hl

[13] 김희욱, 김대호. 2020.11.18. 드론 Remote ID 정책 및 기술표준화 동향. 한국항공우주학회 학술발표회 초록집, 제주.

[14] 김희욱, 강군석, 김대호. (2021). 드론 원격 식별 규정 및 표준화 동향 분석. 한국전자통신연구원. Accessed: 2025-11-30. [Online]. Available: https://ettrends.etri.re.kr/ettrends/193/0905193005/

[15] 김형석, 2025.7.9., [김형석 칼럼] 자동차처럼 드론에도 번호판을? 드론 원격식별 시스템의 필요성과 발전 방향. BEMIL 군사세계 전문가 코너. Accessed: 2025-11-30. [Online]. Available: https://bemil.chosun.com/nbrd/bbs/view.html?b_bbs_id=10158&pn=1&num=6752#

[16] 서승오, 이용구, 이세훈, 오승렬, and 손준영, "DJI UAV 탐지·식별 시스템 대상 재전송 공격 기반 무력화 방식," 항공우주시스템공학회지, Vol. 17, No. 4, pp. 133-143, 2023. https://doi.org/10.20910/JASE.2023.17.4.133

저 자 소 개

김한석(E-mail: 14.10083a@gmail.com)
2014 육군사관학교 국제관계학 학사
2024 국방대학교 컴퓨터공학 석사
현재 육군 5군단 105정보통신단
관심분야 : AI, 드론, 위성통신

임효영(E-mail: hyoyounglim1@gmail.com)
2009 육군사관학교 정보과학 학사
2015 일.나고야대학 정보과학 석사
2023 미.콜로라도 볼더 컴퓨터과학 박사
현재 국방대학교 사이버·컴퓨터공학과 조교수
관심분야 : AI-Native Network, FANET, MANET

군 사 과 학 연 구 지
제18권 제2호(2025년 12월)

AI 기반 M&S를 활용한 전장 환경 분석의 정책적 함의[1)]

Policy Implications of AI-based M&S for Battlefield Environment Analysis

박상중[2)]
Sangjung Park

ABSTRACT

The rapidly evolving future battlefield, characterized by the convergence of hyper-connectivity, hyper-intelligence, and hyper-reality technologies, is increasingly complex and uncertain. This study explores methods for optimizing the battlefield environment using Artificial Intelligence (AI)-based Modeling & Simulation (M&S) to address these challenges and overcome the limitations of traditional defense M&S. The research begins with an in-depth examination of future battlefield characteristics, the understanding of AI-based M&S, and complex systems theory. It then proposes key optimization areas for AI-based M&S, including the refinement of big data-driven modeling, the automation and diversification of intelligent scenario operations, and real-time battle command and decision-making support. Furthermore, the study suggests concrete strategies such as establishing robust big data governance, strengthening integration with the CJADC2 (Combined Joint All-Domain Command and Control) system, and ensuring the agility and reliability of AI-based M&S. Ultimately, this research emphasizes that AI-based M&S will contribute to future defense policy formulation, enhanced efficiency in force augmentation, and the innovation of military education and training systems, thereby providing practical solutions for effectively optimizing complex battlefield environments.

Key Words : AI-based M&S, Complex Systems, Battlefield Environment Optimization, CJADC2

논문접수일 : 2025년 11월 8일, 심사일 : 2025년 11월 10일~11월 16일, 게재확정일 : 2025년 11월 16일

1) 이 논문은 IAMSEC 2025에서 발제한 'AI 기반 M&S를 활용한 복잡한 전장 환경 시뮬레이션 자동화 및 최적화 방안 연구'를 수정·보완하였다.

2) 국방대학교 직무교육원 교수, 육군정책자문위원, 정책학박사, nicegift701@korea.kr

1. 서론

급변하는 21세기 전장 환경은 과거와는 비교할 수 없는 복합성과 불확실성을 내포하고 있다. 특히 초연결, 초지능, 초실감 기술의 융합은 전장의 패러다임을 근본적으로 변화시키고 있다[1]. 이러한 기술 발전은 미래 전장을 예측 불가능하게 만들며, 첨단 과학기술과 결합하여 물리적 공간을 넘어 사이버, 우주, 전자기 스펙트럼 등 다양한 영역으로 전장을 확장하고 복잡성을 증대시키고 있다[2]. 무인체계 및 유무인 복합체계의 등장은 전투의 양상을 근본적으로 변화시키고 있으며, 지상, 해상, 공중을 넘어 우주와 사이버 영역까지 포함하는 다영역에서 비선형적이고 광범위한 전장이 형성될 것이 예상된다[3-4]. 과거의 플랫폼 중심전(Platform Centric Warfare)이 특정 무기체계가 단독으로 작전을 수행하는 방식이었다면, 이제는 모든 전장 환경 요소들이 네트워크화되는 방향으로 전환되고 있다[5]. 이는 현대 군사작전이 단일 시스템의 성능보다는 전체 시스템 간의 연동성과 통합성을 중시하는 지휘통제 체계로의 전환을 의미한다.

미래 전장은 더욱 예측하기 어려운 영역으로 진화하고 있으며, 이러한 복잡성을 이해하고 대응하기 위한 노력이 절실하다. 특히 하이브리드전(Hybrid Warfare)과 인지전(Cognitive Warfare)과 같은 비전통적 위협의 증가는 미래 전장의 복잡성을 더욱 심화시키고 있다. 하이브리드전은 재래식 군사력뿐만 아니라 비국가 행위자, 정보전, 사이버 공격, 경제적 압력 등 다양한 비군사적 수단을 결합하여 전개되는 양상으로, 국가 안보에 복합적인 위협으로 작용하고 있다[6]. 인지전은 적국의 대중과 의사결정자의 인식, 정서, 행동에 영향을 미쳐 전략적 목표를 달성하려는 시도로, 첨단 정보통신 기술과 심리전이 결합되어 나타난다[7]. 이러한 복합적인 전장 환경은 단순한 물리적 파괴를 넘어 정보, 심리, 문화 등 비물리적 영역에서의 경쟁으로 확대되며, 데이터 폭증과 정보 과부하 문제 또한 심화될 것으로 예측된다. 따라서 미래 전장은 비선형적인 상호작용과 예측 불가능한 변수들로 가득 찬, 고도로 복잡한 적응 시스템의 특성을 보일 것으로 전망할 수 있다.

그동안 전통적인 국방 모델링 및 시뮬레이션(M&S)은 무기체계 획득, 전력 증강 분석, 군사 교육 및 훈련, 작전 계획 수립 등 국방 분야 전반에 걸쳐 핵심적인 의사결정 도구로 활용되어 왔다[8-9]. M&S는 실제 상황을 가상으로 구현하여 다양한 변수를 통제하며 실험할 수 있다는 점에서 그 중요성이 크다. 그러나 기존 국방 M&S는 정적이고 수동적인 운영 방식에 머무르며, 급변하는 미래 전장의 복잡성과 불확실성을 실시간으로 반영하고, 반복적으로 분석 및 대응을 효과적으로 시행하는 데 한계를 노정하고 있다[8]. 또한, M&S 결과의 신뢰도를 확보하기 위한 검증, 확인 및 인정(Verification, Validation, and Accreditation, VV&A) 절차가 국내외 다양한 분야에 적용되고 있으나, 복잡하고 방대한 시스템에 대한 효율적인 VV&A는 여전히 도전 과제로 남아있다[10-12]. 이는 급변하는 미래 전장의 요구사항을 충족시키기에는 역부족이라는 지적을 받고 있다.

이러한 상황에서 인공지능(AI) 기술은 국방 M&S의 한계를 극복하고 미래 전장 환경을 효과적으로 분석하고 대응할 수 있는 강력한 대안으로 부상하고 있다. AI와 디지털 트윈(Digital Twin) 기술의 융합은 실제 물리적 시스템의 가상 모델을 구축하여 실시간으로 연동하는 기술로서 국방 M&S 체계의 구조적 전환을 이끌 핵심 방향으로 주목받고 있다. AI는 방대한 데이터 학습을 통해 복잡한 패턴을 인식하고, 예측 분석 능력을 기반으로 의

사결정을 지원하며, 심지어 자율적인 시나리오 생성 및 대응 전략 도출까지 가능하다[8][12]. 따라서 AI 기술을 M&S와 융합함으로써 미래 전장의 불확실성을 관리하고, 다영역 작전의 효과를 극대화하며, 전력 증강 및 운용 효율성을 획기적으로 향상시킬 수 있는 방안을 모색하는 것은 국가 안보에 있어 매우 시급하고 중요한 과제이다.

본 연구는 AI 기반 M&S를 활용하여 미래 전장 환경을 효과적으로 분석하고, 작전 수행 능력을 효율적으로 지원할 수 있는 구체적인 방안을 제시하는 것을 목적으로 한다. 이를 통해 국방 M&S 분야의 기술적 발전 방향을 모색하고, 실제 국방 환경에 적용 가능한 전략적 함의를 도출하여, 궁극적으로 우리 군의 국방력 강화 및 미래 전장에 대한 대비 태세 확립에 기여하고자 한다.

연구의 구성은 다음과 같다. 2장에서는 미래 전장 환경의 특성과 AI 기반 M&S의 기본 개념, 전장 환경을 복잡계의 관점에서 분석하는 이론적 고찰을 진행한다. 3장에서는 AI 기반 M&S가 전장 환경 분석 및 대응능력 강화를 위해 활용될 수 있는 핵심 분야들을 빅데이터 기반 모델링, 지능형 시나리오 운용, 실시간 전투지휘 3가지 관점에서 심층적으로 다룬다. 4장에서는 이러한 접근 방안을 실현하기 위한 구체적인 전략으로서 빅데이터 거버넌스 구축, CJADC2 체계 연동 강화, AI 기반 M&S의 민첩성 및 신뢰도 확보 방안을 제시한다. 마지막 5장에서는 본 연구의 정책적 함의를 도출하고, AI 기반 M&S 분야의 향후 연구 방향을 제언하였다.

2. 이론적 고찰

2.1 미래 전장환경

미래 전장 환경은 과학기술의 발전에 힘입어 전례 없는 수준의 복잡성, 불확실성, 모호성을 보이며, 예측 불가능한 특성인 비선형성을 내포하고 있다[2]. 이러한 특성 변화의 핵심 동력은 초연결, 초지능, 초실감 기술의 융합이다[1].

미래 전장의 주요 특성은 첫째, 초연결성에서 나타난다. 모든 전장 요소들이 센서 네트워크, 인공위성, 통신망 등을 통해 실시간으로 연결되어 방대한 데이터가 생성 및 공유됨을 의미한다. 이는 상황 인식 능력을 극대화하는 동시에, 사이버 공격의 표면을 확장하고 정보 과부하를 초래할 수 있다. 전장은 물리적 공간을 넘어 사이버, 우주, 전자기 스펙트럼까지 포괄하는 다영역으로 확장되며, 모든 자산이 네트워크화되어 통합적으로 운용되는 지휘통제 개념인 CJADC2(Combined Joint All-Domain Command and Control, 연합·합동 전영역 지휘통제)가 필수적으로 요구된다[3][5]. 참고로, CJADC2는 미국 전쟁부(Department of War)가 미국의 국방전략에 맞춰 동맹군과의 상호운용성을 강조하기 위해 발전시키고 있는 체계로, 인도·태평양 지역의 경우 중국, 북한 등 적성국에 대한 동맹의 효과적인 대응을 추구한다.

둘째, 초지능성이다. 인공지능(AI), 머신러닝(ML), 딥러닝(DL) 등 첨단 AI 기술이 전장 관리, 의사결정 지원, 무인체계 제어 등 전 분야에 적용되어 전투력의 획기적 발전을 촉진하고 있다. 그러나, AI 기반 분석이 인간의 인지 능력으로는 처리하기 어려운 대량의 정보를 신속하게 분석하고 예측하여 의사결정의 질을 높일 수 있지만, AI의 오류나 오용, 윤리 문제는 새로운 도전 과제이다.

셋째, 초실감성이 강조된다. 가상현실(VR), 증강현실(AR), 혼합현실(MR) 등의 기술이 훈련, 작전 시뮬레이션, 원격 작전 수행에 활용되어 현실과 거의 동일한 몰입감과 정보 제공

이 가능하다[4]. 이는 훈련 효과를 극대화하고 전장 상황에 대한 이해를 심화시키지만, 가상 공간에서의 위협과 기술적 제약 또한 수반한다.

이러한 기술적 특성은 미래 전장에 다음과 같은 변화를 요구하고 있다. 먼저, 다영역 작전(Multi-Domain Operations, MDO)의 보편화가 있다. 기존의 지상, 해상, 공중 영역에 추가하여 우주, 사이버, 정보 영역이 통합되어 유기적인 작전을 수행한다. 이는 모든 영역에서 정보가 실시간으로 공유되고 통합되는 CJADC2 개념의 구현을 통해 달성되며, 각 영역의 전력 간 상호운용성이 핵심적인 성공 요인으로 작용한다.

다음으로 무인체계 및 유무인 복합체계(Manned-Unmanned Teaming, MUM-T)의 확대이다. AI 기반 무인체계는 정찰, 감시, 타격 등 다양한 임무에 투입되며, 유인체계와의 협력을 통해 시너지를 창출한다. 이는 인명 손실을 최소화하고 작전 효율성을 높이지만, 무인체계의 자율성 수준, 인간의 통제 범위, AI 무기 윤리 문제 등 새로운 도전 과제를 제시하고 있다.

마지막으로 하이브리드전 및 인지전의 고도화가 두드러진다. 미래에는 군사적 충돌 외에도 정보 조작, 심리전, 사이버 공격, 경제적 압력 등 비군사적 수단을 동원한 회색지대(Gray Zone) 분쟁이 확산될 전망이다[6-7]. 특히 인지전은 적의 의사결정 시스템과 대중의 인식을 교란하여 전쟁의 양상을 근본적으로 변화시킬 수 있어, 이에 대한 대응 능력이 필수적이다. 이러한 미래 전장 환경의 특성을 종합적으로 이해하는 것은 효과적인 국방 M&S 시스템 개발의 출발점이 된다. 미래 전장 환경의 주요 특성을 요약하면 〈표 1〉에서 보는 바와 같다.

〈표 1〉 미래 전장 환경의 주요 특성

구분	세부내용	주요 영향
초연결성	모든 요소의 실시간 네트워크 연결	다영역 작전 가능, 사이버 위협 증대
초지능성	AI/ML/DL 기반 의사결정 및 자율성 증대	전투력 향상, AI 윤리 및 오류 문제 제기
초실감성	VR/AR/MR 활용 훈련 및 작전 몰입감 증대	훈련 효율화, 가상 공간 위협 발생
다영역 작전	우주, 사이버, 정보 영역의 통합 작전	CJADC2의 중요성 증대, 상호운용성 필수
무인체계	AI 기반 무인/유무인 복합체계 확대	인명 손실 최소화, AI 자율성 통제 문제
하이브리드	비군사적 수단 결합된 복합적 위협	예측 불가능성 증대, 인지전 고도화

2.2 AI 기반 M&S

M&S는 실제 시스템이나 현상을 가상 환경에서 모델링하여 특정 목적에 따라 모의 실험하고 분석하는 과학 기술이다. 국방 M&S는 무기체계 획득, 전력 증강 분석, 군사 교육 및 훈련, 작전 계획 수립 등 다양한 군사 분야에서 핵심적인 역할을 수행해왔다. 예를 들어, 무기체계 성능 평가, 신개념 무기체계의 개발 타당성 분석, 작전 계획의 효과 검증, 실제 훈련이 불가능하거나 위험한 상황을 가상으로 체험하는 데 활용되어 왔다[9].

그러나 전통적인 국방 M&S는 다음과 같은 한계에 직면해 있다. 첫째, 데이터 처리 능력의 한계이다. 대량의 실시간 데이터 처리와 복잡한 비선형적 상호작용을 반영하는 데 어려움이 있다. 둘째, 모델의 현실성 및 적응성 부족이다. 고정된 시나리오와 모델로 인해 급

변하는 전장 환경의 불확실성을 완벽히 반영하기 어려우며, 모델 자체가 새로운 상황에 자율적으로 적응하거나 진화하지 못하고 있다[8]. 셋째, VV&A 과정의 비효율성이다. M&S 모델의 복잡도가 증가하면서 검증, 확인 및 인정 과정에 많은 시간과 자원이 소요되어, 최신 기술 및 전장 변화를 적시에 반영하기 어렵다[10][11][12]. 넷째, 자율적 상황 생성 및 의사결정 지원의 제한이다. 시뮬레이션 환경 내에서 자율적인 행위자의 지능적인 행동이나 복합적인 시나리오를 자동 생성하고, 최선의 의사결정을 지원하는 데 제한적이다.

이러한 한계를 극복하기 위해 AI 기술이 국방 M&S 분야에 적극적으로 도입되고 있다. AI 기반 M&S는 AI 기술(머신러닝, 딥러닝, 강화학습, 생성형 AI 등)을 M&S의 각 단계(자료 수집, 모델링, 시뮬레이션 실행, 분석 및 보고)에 통합하여 기존 M&S의 성능을 향상시키고 새로운 기능을 추가하는 개념이다[12].

특히 AI와 디지털 트윈 기술의 융합은 국방 M&S 체계의 구조적 전환을 이끌 핵심 방향으로 주목받고 있다[8]. 디지털 트윈은 실제 물리적 시스템(무기체계, 전장 환경 등)의 가상 복제본을 만들고, 이 둘을 실시간으로 연동하여 실제 시스템의 상태를 모니터링, 분석, 예측, 제어하는 기술이다. AI 기반 디지털 트윈은 몇 가지 중요한 이점을 제공한다. 먼저, 현실성 및 정확도 향상을 통해 실제 전장 데이터를 기반으로 모델을 지속적으로 학습하고 업데이트하여 시뮬레이션의 현실성을 극대화한다. 둘째, 예측 및 대응능력을 강화하여 AI가 과거 및 실시간 데이터를 분석하여 미래 전장 상황을 예측하고, 다양한 작전 시나리오 중 최선의 대안을 도출하는 데 기여한다. 셋째, 자율성 및 적응성을 높여 AI 기반 에이전트가 시뮬레이션 환경에서 자율적으로 학습하고 행동하며, 예상치 못한 상황에 능동적으로 대처하는 시나리오를 생성할 수 있다. 마지막으로 효율적인 VV&A가 가능하여 AI를 활용한 자동 검증 및 이상 감지 기능을 통해 VV&A 과정의 효율성을 높이고, 모델의 신뢰도를 빠르게 확보할 수 있다.

AI 기반 M&S는 지능형 시나리오 자동 생성, 실시간 상황 인식 및 예측, 향상된 의사결정 지원 등을 통해 전장의 상황 인식, 지휘통제, 무기체계 운용, 군수지원 등 다양한 영역에 혁신을 가져올 잠재력을 가지고 있다[13]. 이러한 기술적 혁신은 국방 R&D의 속도 및 효율성 향상, 기술 진보 적시 대응을 위해 적극적으로 활용될 필요가 있다. 전통 M&A와 AI 기반 M&A를 주요 특성을 비교하면 〈표 2〉에서 보는 바와 같다.

〈표 2〉 전통 M&S와 AI 기반 M&S 비교

구 분	전통적 M&S	AI 기반 M&S
모델 현실성	고정된 시나리오, 수동적 업데이트	실시간 데이터 기반 학습, 자율 업데이트, 현실성 증대
데이터 처리	제한적인 실시간/빅데이터 처리	빅데이터 실시간 처리, 비정형 데이터 분석
시나리오	수동 생성, 규칙 기반, 다양성 제한	AI(강화학습, 생성형 AI) 기반 자동 생성, 비선형적, 다양성 극대화
의사결정	분석가/지휘관의 직관적 판단	AI 기반 예측 분석 및 대응 방안 제시, 의사결정 지원
VV&A	시간/자원 소모, 수동적 검증	AI 기반 자동 검증, 이상 탐지, 효율성 증대
활용 분야	무기체계 획득, 전력 분석, 정형화된 훈련	다영역 작전 시뮬레이션, 복합 시나리오 훈련, 실시간 지휘결심 지원
주요 기술	물리 모델, 통계 모델	머신러닝, 딥러닝, 강화학습, 생성형 AI, 디지털 트윈

2.3 복잡계

복잡계(Complex System)는 수많은 구성 요소들이 상호작용하며 나타나는 비선형적이고 예측 불가능한 시스템의 행동 양식이다[12]. 이러한 시스템들은 환경 변화에 따라 스스로 조직을 재구성하는 자기조직화(Self-organization) 특성과 함께 끊임없이 변화에 적응하는 적응성(Adaptability)을 가지고 있다. 복잡계는 시스템의 부분들이 모여 전체를 구성하지만, 그 전체는 부분의 단순한 합 이상이라는 창발(Emergence)을 강조한다.

전장 환경은 이러한 복잡계 시스템의 대표적인 예시로 이해할 수 있다. 전장은 단순히 무기와 병력의 물리적인 충돌이 아니라, 물리적 요소, 인적 요소, 기술적 요소, 정보적 요소, 정치·경제적 요소 등 수많은 요소가 비선형적으로 상호작용하는 시스템이다. 물리적 요소는 지형, 기상, 무기체계, 인프라 등이며, 인적 요소는 병력의 심리, 사기, 지휘관의 리더십, 의사결정 등이다. 기술적 요소는 통신망, 센서, 전자전, 사이버 역량 등을 포괄하며, 정보적 요소는 정보의 흐름, 오정보, 기만, 인식 작용 등과 관련된다. 마지막으로 정치·경제적 요소는 국제 관계, 동맹국의 지원, 경제 상황 등을 포함한다.

이러한 요소들은 서로 독립적으로 작용하는 것이 아니라, 복잡한 네트워크를 형성하며 끊임없이 영향을 주고받는다. 이로 인해 작은 변화가 시스템 전체에 예상치 못한 큰 파급효과를 일으키는 나비효과가 발생할 수 있으며, 이는 전장의 예측 불가능성을 심화시킨다[10]. 복잡계에 기반한 전장 분석은 기존의 선형적이고 정량적인 군사 분석 방식이 간과했던 요소들을 파악하고, 시스템 전체의 동태적 특성을 이해하는 데 도움을 준다[25].

AI 기반 M&S는 이러한 복잡계로서의 전장 환경을 효과적으로 모델링하고 시뮬레이션하는 데 핵심적인 역할을 수행한다. AI는 대규모 상호작용을 처리하며 복잡계에서 발생하는 대규모의 비선형적 상호작용 데이터를 분석하고, 과거 패턴을 학습하여 미래의 다양한 시나리오를 생성하는 데 탁월하다[13]. 또한, AI는 패턴 인식 및 예측 기능을 통해 복잡계의 자기조직화와 적응적 행동에서 나타나는 미묘한 패턴을 인식하고, 이를 기반으로 미래 상태를 예측하는 데 기여한다. 더 나아가 동태적 의사결정 지원을 가능하게 하는데, 이는 AI 기반 M&S가 예측 불가능한 상황에 대한 대응 방안을 제시하고, 지휘관이 실시간으로 변화하는 복잡계 전장에서 유연하고 효과적인 의사결정을 내릴 수 있도록 돕는 것을 의미한다.

결과적으로 AI 기반 M&S는 복잡계 이론이 제공하는 통찰력을 실질적인 전장에 관한 대응 능력 강화 방안으로 전환하는 가교 역할을 하며, 이를 통해 미래 전장의 예측 불가능한 양상을 이해하고 효과적으로 대응할 수 있는 능력을 강화한다.

3. AI 기반 M&S 최적화 분야

3.1 Big Data 기반 모델링

AI 기반 M&S를 활용한 전장 환경의 효과적인 분석 및 대응의 핵심은 방대한 국방 빅데이터를 효과적으로 수집, 분석, 활용하여 모델링을 정교화하는 데 있다. 미래 전장에서는 센서 네트워크, 무인체계, 통신 시스템 등으로부터 지리 정보, 기상, 센서 데이터, 통신 기록, 전술 데이터, 인적 데이터 등 이질적이고 복합적인 대량의 정보가 실시간으로 생성될 것이다. 이러한 빅데이터를 기반으로 모델링을 정교화하는 것은 M&S의 현실성과 예측력을 비약적으로 향상시킬 수 있는 기반이 된다.

AI 시대에는 데이터 확보 및 관리가 AI 학습에 필요한 양질의 데이터를 확보하고 체계적으로 관리하는 데 가장 중요하며, 이는 성공적인 AI 모델 개발의 첫 번째 조건이다.

AI는 전장 데이터의 전처리 및 분석 과정에서 매우 중요한 역할을 수행한다. 빅데이터의 4V(Volume, Velocity, Variety, Veracity) 특성은 기존 방식으로는 처리하기 어려운 복잡성을 내포한다. AI 알고리즘은 데이터 정제 및 노이즈 제거를 통해 대량의 비정형 데이터 내에서 오류, 중복, 불일치성 등을 탐지하고 제거하여 데이터 품질을 향상시킨다. 특히, 다양한 소스에서 수집되는 전장 데이터의 신뢰성을 확보하는 데 필수적이다. 또한, 특징 추출 및 패턴 인식 기능을 수행하는데, AI는 딥러닝 기반의 기술을 활용하여 정제된 데이터에서 의미 있는 특징을 자동으로 추출하고, 복잡한 전장 상황이나 적의 행동 패턴을 인식한다. 이는 단순한 데이터에서 고도로 추상화된 '정보'를 생성하는 과정이다. 나아가 데이터 융합 및 통합을 통해 이질적인 센서 데이터, 정보 보고, 시뮬레이션 데이터 등을 AI 기반 데이터 융합 기술을 통해 통합하여 일관되고 완전한 전장 상황 모델을 구축한다.

또한, AI 기반 M&S는 실시간 데이터 연동을 통해 모델의 현실성을 극대화한다. 센서와 무인체계로부터 실시간으로 유입되는 데이터를 M&S 모델에 즉각적으로 반영함으로써, 가상 환경이 현실 전장 상황과 거의 동일하게 움직이도록 만든다. 이는 단순한 데이터 처리 속도를 넘어, 급변하는 전장 상황에 대한 M&S 모델의 적응성과 반응성을 높이는 핵심 요소이다. 참고로, 세미파이브는 메티스엑스와 협력하여 CXL(컴퓨트 익스프레스 링크) 기반 메모리 가속기 칩을 개발하고 있으며, 메티스엑스(XCENA)와 사이오닉AI는 HW 기반 벡터 검색 가속 기능과 벡터 데이터베이스(DB) 개발 역량을 결합하여 생성형 AI의 벡터 DB 가속 솔루션을 개발하기 위해 협업하고 있다. 이러한 첨단 하드웨어 및 소프트웨어 기술은 대규모 국방 데이터의 실시간 처리 및 모델 연동을 가능하게 한다.

정교하게 모델링된 빅데이터는 예측 분석 및 이상 탐지에도 활용된다. AI는 과거 전장 데이터와 실시간 데이터를 학습하여 적군의 행동 패턴, 전력 운용 방식, 주요 취약점 등을 예측하고, 예상치 못한 상황이나 이상 징후를 조기에 탐지하는 데 기여한다. 이러한 예측 분석 능력은 지휘관이 선제 대응 전략을 수립하고, 위기 발생 시 피해를 최소화하는 데 결정적인 정보를 제공한다[4]. 결과적으로, AI 기반의 빅데이터 모델링은 미래 전장의 불확실성을 줄이고, 아군의 작전 우위를 확보하는 데 필수적인 요소로 평가할 수 있다.

3.2 지능형 시나리오 운용

미래 전장 환경의 복잡성은 인간의 직관만으로는 모든 가능성을 예측하고 대비하는 것이 불가능하게 만들었다. 따라서 AI 기반 M&S는 지능형 시나리오의 자동 생성 및 운용을 통해 훈련 및 작전 계획 수립의 혁신을 가져올 수 있다. 국방 분야 워게임 모델의 AI 적용 연구에서는 실제 훈련 지역을 3D 디지털 트윈으로 재현하여 전투 훈련의 실감도를 향상시키고 평소 훈련하기 어려운 전장 환경을 갖추어 몰입감 높은 전장 환경을 구성할 수 있다고 강조하였다[6].

AI, 특히 강화학습(RL)이나 생성형 AI 모델은 미리 정해진 규칙이 아닌, 시뮬레이션 환경과의 상호작용을 통해 스스로 학습하고 진화하며 다양한 전술적 상황과 적군의 행동 패턴을 포함하는 시나리오를 자동 생성할 수 있다[13]. RL 기반 에이전트는 시뮬레이션 환경에서 시행착오를 통해 최선의 행동 정책을 학습하며, 이를 통해 복잡하고 예측 불가능한

적의 행동 모델을 생성하거나 새로운 전술 시나리오를 자율적으로 도출할 수 있다. 생성형 AI 모델(예: 생성적 적대 신경망(GANs), 트랜스포머 기반 모델)은 기존 데이터를 학습하여 새로운, 현실적이고 다양한 시나리오를 생성하는 데 탁월한 능력을 보인다. 이러한 지능형 시나리오는 인간 설계자가 상상하기 어려운 독창적이고 예측 불가능한 상황을 포함하여, 훈련의 현실성과 도전 과제를 한층 높힌다[13].

AI는 생성된 시나리오의 유효성을 스스로 평가하고 효과적인 대응 방안을 모색하는 기능도 제공한다. 시뮬레이션 결과를 분석하여 어떤 작전 계획이 가장 효과적인지 도출하고, 아군 전력의 취약점이나 개선이 필요한 부분을 식별해낸다. 이는 끊임없이 변화하는 전장 상황에 맞춰 전술과 전략을 유연하게 조정할 수 있는 기반을 제공한다. 게임 산업에서도 AI는 게임 콘텐츠 개발에 적극적으로 활용되고 있으며, 딥러닝 기반 AI 창작 도구는 캐릭터, 환경, 스토리 등 다양한 요소의 시나리오를 생성하는 데 기여한다. 이러한 AI 기반 창작도구는 군사 시뮬레이션 시나리오 생성에도 응용될 수 있으며, 보다 현실적이고 복합적인 훈련 환경을 제공할 것이다.

이처럼 지능형 시나리오 운용은 군사 교육 및 훈련의 혁신적인 변화를 가져온다. 실제 전장과 유사한 복잡한 가상 환경에서 지휘관을 포함한 모든 전투원이 다양한 상황을 경험하고 의사결정 훈련을 반복함으로써 실전 역량을 극대화할 수 있으며[13], 이는 군사 훈련 비용과 시간을 획기적으로 절감하는 효과를 가져온다. 궁극적으로 지능형 시나리오 운용은 정책 결정자들에게 다양한 정책 및 전략의 효과를 예측하고 효과적인 대응 방안을 선택할 수 있는 과학적인 근거를 제공하며, 이는 국방 전반의 효율성 향상으로 이어진다.

3.3 실시간 전투지휘

미래 전장의 특징 중 하나는 실시간성과 속도이다. 급변하는 전장 상황 속에서 지휘관은 순식간에 복합적인 정보를 분석하고 중요한 결정을 내려야 한다. AI 기반 M&S는 이러한 실시간 전투지휘 환경에서 지휘관의 의사결정을 돕는 강력한 지원 도구가 된다.

AI는 M&S를 통해 수집된 다양한 전장 정보를 통합하고 분석하여 아군 및 적군의 위치, 의도, 전력 상태, 주변 환경 변화 등을 실시간으로 인지하고 이를 종합하여 고도로 정확하고 통합된 전장 상황도를 제공한다. CJADC2는 지상, 해상, 공중, 우주, 사이버 등 모든 영역을 하나의 거대한 신경망으로 엮어 찰나의 순간에 최선의 결정을 내리고 행동에 옮기는 것을 목표로 한다[3]. AI 기반 M&S는 이러한 CJADC2 체계를 통해 실시간 전장 정보 통합 및 상황 인식 고도화에 기여할 수 있다[11]. 이는 지휘관이 광범위한 정보를 신속하게 이해하고 상황을 정확히 판단하는 데 필수적이다.

나아가 AI 기반 M&S는 지휘결심 지원 시스템(DSS)으로서의 역할을 수행한다. AI는 실시간으로 변화하는 전장 데이터와 시뮬레이션 결과를 바탕으로 가능한 작전 시나리오와 그에 따른 효과를 분석하고, 최선의 대응 방안을 제시한다. 이는 지휘관의 인지적 부담을 경감하고, 한정된 시간 내에 최선의 결정을 내릴 수 있도록 돕는다. 예를 들어, IBM은 AI와 IoT 기술을 바탕으로 전력망과 발전 설비에 대한 관리 및 예측 서비스를 제공하고, 구글은 DeepMind의 AI 기술을 자체 데이터 센터 냉방 제어에 적용하는 등 AI를 통한 의사결정 지원의 실제 사례들은 이미 존재한다. 이처럼 AI의 예측 분석 능력은 군사작전에서도 효과적인 경로, 자원 할당, 공격 및 방어 전략 등을 제안하며, 지휘관의 결정 과정을

지원한다.

또한, AI는 변화하는 전장 상황에 맞춰 실시간으로 전술을 수정하고, 새로운 위협에 대한 적응형 전술(Adaptive Tactics)을 제안하는 능력을 갖추고 있다[6]. 이러한 AI의 역량은 아군이 전장에서 기동성과 유연성을 확보하는 데 크게 기여한다. AI 기반 M&S는 전투 모의 시뮬레이션을 통해 다양한 전술을 빠르게 탐색하고, 실전에서 발생할 수 있는 복합적인 변수를 고려하여 가장 효과적인 전술을 학습하고 발전시킨다.

중요한 점은 인간 지휘관과 AI의 협업(Human-on-the-Loop/Human-in-the-Loop)이다. AI는 방대한 데이터를 처리하고 복잡한 계산을 수행하며 최선의 선택지를 제시하지만, 최종적인 작전 결정은 인간 지휘관의 경험, 직관, 윤리적 판단에 따라 이루어져야 한다. AI 기반 M&S는 지휘관에게 '강화된 인지'를 제공하며, 인간 지휘관이 보다 현명하고 신속한 결정을 내릴 수 있도록 지원하는 상호 보완적인 지휘체계 구축이 미래 전장의 핵심이 될 것이다.

4. AI 기반 M&S 최적화 전략

4.1 Big Data 거버넌스 구축

AI 기반 M&S를 활용하여 전장 환경을 분석하고 효과적으로 대응하기 위해서는 방대한 국방 빅데이터를 효과적으로 관리하고 활용할 수 있는 견고한 거버넌스 체계 구축이 필수적이다. 미래 전장은 예측 불가한 요소들로 가득하며, 이 불확실성을 해소하고 효과적인 대응을 달성하기 위해서는 모델링과 시뮬레이션을 통해 다양한 시나리오를 예측하고 대응해야 한다. 이를 위해선 이질적인 형태로 존재하는 다양한 국방 데이터(센서 데이터, 위성 영상, 통신 기록, 병력 정보, 무기체계 성능 등)를 일관된 형식으로 표준화하고 통합하는 것이 선결 과제이다. 인공지능 시대의 군사 전략은 AI 학습에 필요한 양질의 데이터를 확보하고 체계적으로 관리하는 것의 중요성을 강조한다.

데이터 수명 주기 관리는 데이터 수집부터 저장, 처리, 활용, 폐기에 이르는 전 과정을 체계적으로 관리하여 데이터의 가치를 극대화하고 효율성을 높인다. 특히 AI 모델의 정확성과 신뢰도를 보장하기 위해서는 데이터 품질 확보가 매우 중요하다. M&S 체계에서 사용되는 데이터의 일관성, 처리 속도, 다양한 모듈 간의 데이터 교환이 원활한지 평가하는 것은 M&S의 신뢰성을 높이는 데 필수적이다[9]. AI 기반 M&S는 입력 데이터의 정확성과 완전성에 크게 의존하므로, 오류나 불완전한 데이터는 시뮬레이션 결과의 신뢰도를 저하시킬 수 있다. 따라서 데이터의 정확성, 완전성, 일관성을 유지하기 위한 지속적인 검증 및 정제 과정이 필요하다.

더불어, 국방 데이터는 민감하고 보안이 중요하므로 데이터 보안 및 프라이버시 보호를 위한 엄격한 정책과 기술적 장치 마련이 필수적이다. 워게임 시뮬레이션 시스템은 군사적으로 보호되어야 할 자료들을 다루므로 보안 시스템 설계 및 구현이 중요하다[9]. 데이터 유출이나 오남용을 방지하기 위한 암호화, 접근 제어, 감사 시스템 등의 보안 기술을 적용하고, 데이터 사용에 대한 윤리적, 법적 프레임워크를 수립해야 한다. 마지막으로, 군 내부 및 유관 기관 간 데이터 공유 및 협력 체계 구축은 AI 기반 M&S 모델의 고도화를 촉진한다. 효율적인 데이터 공유 플랫폼을 통해 연구 기관, 방위 산업체, 군사 부서 간의 협력을 강화하고, AI 기반 M&S 역량을 집단적으로 향상시켜야 한다. 최근 메티스엑스와 사이오닉AI의 협력 사례처럼, HW 기반 벡터 검색

가속 기능과 벡터 DB 개발 역량을 결합하여 생성형 AI의 벡터 DB 가속 솔루션을 개발하는 것은 대규모 국방 데이터의 실시간 처리 및 공유에 기여할 수 있다. 이러한 노력들이 유기적으로 결합될 때 AI 기반 M&S는 미래 전장을 분석하고 효과적으로 대응하기 위한 강력한 동력으로 작용할 것이다. 빅데이터 거버넌스 구축의 핵심 요소는 〈표 3〉에서 보는 바와 같다.

〈표 3〉 빅데이터 거버넌스 구축의 핵심요소

구분	세부내용	기대 효과
데이터 표준화 및 통합	이질적 국방 데이터의 일관된 형식화 및 통합 플랫폼 구축	상호운용성 보장, AI 학습 효율 증대
데이터 품질 확보	데이터 정제, 정확성, 완전성, 일관성 유지	M&S 및 AI 모델의 신뢰도 및 예측력 향상
데이터 수명 주기 관리	수집-저장-처리-활용-폐기 전 과정의 체계적 관리	데이터 가치 극대화, 자원 효율성 증대
데이터 보안 및 프라이버시	암호화, 접근 제어, 윤리적/법적 프레임워크 마련	민감 정보 보호, AI 모델 오용 방지
데이터 공유 및 협력	산·학·연·군 간 데이터 공유 플랫폼 및 협력 체계 강화	AI M&S 역량 집단 향상, 국방 생태계 발전

4.2 CJADC2 체계 연동 강화

AI 기반 M&S를 통한 전장 환경 분석 및 대응능력 강화는 CJADC2 체계와의 긴밀한 연동을 통해 그 시너지를 극대화할 수 있다. CJADC2는 육·해·공·우주·사이버 등 모든 영역의 정보를 통합하고 공유하여 신속하고 정확한 의사결정을 지원하는 지휘통제체계를 목표로 한다[5]. 미래 전장이 다영역에서 복합적으로 전개됨에 따라, CJADC2는 아군의 전력을 효율적으로 통합하여 운용하고, 적군보다 더 빠르게 상황을 인지하며 의사결정을 수행하는 핵심적인 체계로 부상하고 있다[15]. 미군의 JADC2 추진을 통해 한국군 지휘통제 발전방향을 제시한 연구에서는 CJADC2의 목표를 전 영역의 센서와 사수를 연결하여 복잡하고 급변하는 전장에서 신속하고 효과적인 작전을 수행하는 것이라고 설명한다[22].

AI 기반 M&S는 CJADC2 체계의 핵심적인 '뇌'이자 '시뮬레이터'로서 기여할 수 있다. M&S 시뮬레이션 결과를 CJADC2 체계에 실시간으로 연동함으로써, 전장 상황에 대한 정확하고 예측적인 분석 정보를 제공하여 지휘관의 의사결정을 고도화할 수 있다[11]. 즉, M&S를 통해 생성된 다양한 작전 시나리오의 결과와 효과를 실시간으로 CJADC2 화면에 투영하여, 지휘관이 최선의 전략을 선택할 수 있도록 돕는 것이다. AI 시대 국방 M&S는 디지털 트윈 기술 중심으로 발전할 것이며, 이는 M&S가 현실 세계의 상황을 가상세계에 구현하여 실시간으로 분석하고 예측하는 능력을 CJADC2에 제공할 수 있음을 의미한다.

특히 다영역 전력 간 상호운용성 확보는 CJADC2의 가장 중요한 목표 중 하나이며, AI 기반 M&S가 이를 뒷받침할 수 있다. M&S는 각 영역(육상, 해상, 공중, 우주, 사이버)의 전력을 가상으로 통합하여 운용하고, 이들 전력 간의 상호작용 효과를 시뮬레이션하여 최선의 합동 작전 수행 방안을 제시할 수 있다. 하이퍼스케일 AI와 IoMDT(Internet of Military Digital Twins)를 통합하여 한국의 국방 모델링 및 시뮬레이션(M&S) 분야에서의 발전을 다루는 연구는 이러한 다영역 통합 시뮬레이션의 가능성을 보여준다. 이러한 분석 결과는 CJADC2의 다영역 작전 계획 수립 및 실행에 직접적인 통찰력을 제공한다.

CJADC2와 AI 기반 M&S의 성공적인 연동을 위해서는 데이터 및 시스템 연동 표준화가 필수적이다. 서로 다른 시스템과 플랫폼 간에 데이터가 원활하게 교환되고 해석될 수 있도록 공통된 인터페이스와 데이터 포맷을 확립해야 한다 [11]. JADC2 구현을 위해서는 클라우드 환경을 활용한 데이터 통합 플랫폼 구축이 필수적이다 [11]. 또한, CJADC2 환경에서 AI 기반 M&S의 효용성을 검증하고 개선점을 도출하기 위한 지속적인 실증 및 검증(VV&A) 과정이 반복적으로 이루어져야 한다 [9-12]. 이를 통해 CJADC2는 AI 기반 M&S의 예측력과 효과적인 분석 및 대응 능력을 기반으로 더욱 강력하고 유연한 지휘통제 역량을 확보하게 될 것이다.

4.3 민첩성 및 신뢰도 확보

AI 기반 M&S가 미래 전장에서 효과적인 분석 및 대응 도구로 기능하기 위해서는 그 시스템 자체의 민첩성과 신뢰도를 지속적으로 확보하는 전략이 필요하다. 미래 전장은 끊임없이 진화하며, 기술적 우위는 일시적일 수 있다. 따라서 AI M&S 시스템 역시 변화에 빠르게 대응하고 끊임없이 개선되어야 한다.

애자일(Agile) 개발 방법론 도입은 AI M&S 시스템의 민첩성을 높이는 데 기여한다. 이는 빠르게 변화하는 전장 환경과 기술 발전에 맞춰, 짧은 개발 주기를 통해 AI M&S 시스템을 개발하고 업데이트하는 방식이며, 시스템의 유연성과 적응성을 보장한다. 사용자 요구사항의 변화에 신속하게 대응하고, 새로운 위협 요소를 M&S 모델에 즉각적으로 반영할 수 있어야 한다.

AI 모델의 설명 가능성(XAI)은 인공지능의 결정 과정을 사람이 이해할 수 있도록 설명하는 기술로서 신뢰도 확보의 핵심 요소이다. AI 기반 M&S가 아무리 뛰어난 예측이나 효과적인 대응 방안을 제시하더라도, 지휘관이 그 결정의 근거를 이해하고 신뢰할 수 없다면 실제 작전에 적용하기 어렵다. AI가 왜 특정 시나리오를 예측했는지, 특정 전략을 추천했는지 그 추론 과정을 투명하게 공개하는 XAI 기술은 지휘관의 시스템에 대한 신뢰를 높이고, 오류 발생 시 원인을 분석하고 개선하는 데 필수적이다[6]. XAI는 AI 모델의 '블랙박스' 문제를 해결하고, 지휘관이 AI의 제안을 비판적으로 검토하며 최종 의사결정에 반영할 수 있도록 돕는다.

더불어, VV&A를 통한 시뮬레이션 결과의 검증 및 타당성 확보는 AI 기반 M&S 시스템의 신뢰성을 담보하는 중요한 과정이다[9-12]. M&S 결과가 실제 전장 상황을 얼마나 정확하게 반영하는지, AI 모델이 도출한 효과적인 분석 및 대응 방안이 얼마나 효과적인지 지속적으로 검증하고 타당성을 확보해야 한다. 스웨덴 국방과학연구소(FOI)는 위험 분을 사용하여 V&V가 집중되어야 할 분야의 효율성을 결정한다[9]. VV&A 활동은 M&S가 실체계의 모습대로 구현되고, 사용 목적과 의도에 대한 신뢰성이 보장되었는지 검증, 확인하여, 인정하는 과정을 포함한다[10][12]. 이러한 과정에는 적극적인 사용자 피드백 반영이 필수적이다. M&S 시스템 개발 초기부터 실제 전장에서 운용할 지휘관 및 병력의 의견을 수렴하여 시스템의 실용성과 활용성을 높여야 한다. 현장 사용자들의 경험과 통찰력은 AI 모델의 현실성을 보강하고, 시스템의 개선점을 식별하는 데 결정적인 역할을 한다.

마지막으로 보안 강화는 AI 기반 M&S 시스템의 신뢰도를 유지하는 데 필수적이다. AI 모델 및 학습 데이터에 대한 사이버 공격으로부터 보호하고, 시스템의 조작 및 오용을 방지하기 위한 강력한 보안 체계를 구축해야 한다[8]. 워게임 시뮬레이션 시스템은 군사적으로 보호되어야 할 자료들을 운용하므로 보안

시스템 설계 및 구현이 중요하다[9]. 민감한 국방 정보를 다루는 만큼, 보안 취약점을 최소화하고 비인가 접근을 철저히 차단하는 노력이 상시적으로 요구된다. 이러한 민첩하고 신뢰할 수 있는 AI 기반 M&S는 미래 전장에서 아군의 결정적 우위를 확보하는 핵심 동력이 될 것이다.

5. 결론 및 향후 연구

5.1 정책적 함의

본 연구는 초연결, 초지능, 초실감 기술이 융합된 미래 전장 환경의 복합성과 불확실성에 대응하고, 기존 국방 M&S의 한계를 극복하기 위해 AI 기반 M&S를 활용한 전장 환경의 효과적 분석 및 대응 방안을 모색하였다. 미래 전장이 예측 불가능하며, 첨단 과학기술과 결합하여 전장이 확장되고 복잡해지는 양상을 보임에 따라, AI 기반 M&S는 미래 국방 전략 수립에 있어 핵심적인 정책적 함의를 제공한다.

첫째, AI 기반 M&S는 국방 정책 및 전략 수립에 기여함으로써 미래 전장 변화에 대한 선제적 대응 능력을 강화한다. AI 기반 M&S가 제공하는 정교한 시뮬레이션과 예측 분석은 국방 예산의 효율적인 배분, 전력 증강 사업의 타당성 검토, 새로운 위협에 대한 전략적 대응 방안 마련에 필요한 과학적 근거를 제시한다. 워게임 시뮬레이션 시스템의 AI 적용은 전력 증강 사업 및 전략 수립에 중요한 영향을 미칠 수 있다. 이는 AI 기반 분석을 통해 전략적 우선순위를 명확히 하고, 잠재적 리스크를 사전에 식별하여 보다 효과적인 국방 정책을 수립하는 데 필수적인 통찰력을 제공한다.

둘째, 국방 예산의 효율적 집행에 이바지한다. 고비용의 실제 훈련이나 무기체계 개발 이전에 AI 기반 M&S를 통해 다양한 시나리오를 가상으로 시뮬레이션함으로써, 불필요한 시행착오를 줄이고 최선의 투자 방안을 모색할 수 있다[6][13]. 이는 한정된 국방 예산을 효율적으로 운용하고, 투자 대비 효과를 극대화하는 데 결정적인 역할을 한다. 개발 초기 단계에서부터 AI M&S를 활용하여 설계 검증 및 성능 예측을 수행함으로써, 실제 시제품 제작 및 시험에 드는 비용과 시간을 크게 절감할 수 있다.

셋째, 군사 교육 및 훈련 시스템을 혁신하여 지휘관뿐만 아니라 모든 전투원의 실전 역량을 강화한다. AI 기반 M&S는 실제와 거의 동일한 복잡한 가상 환경에서 다양한 작전 상황을 구현하여, 모든 전투원이 반복적인 훈련을 통해 숙련도를 높이고 지휘관이 실시간 의사결정 능력을 함양할 수 있도록 돕는다[6][13]. 훈련 M&S 분야 인공지능 적용 사례와 발전 방안 연구는 이러한 AI의 훈련 분야 활용 가능성을 제시한다[13]. 이는 시간과 공간의 제약 없이 고품질의 훈련을 가능하게 하여 전투력을 획기적으로 향상시킬 수 있다. 특히, AI가 생성하는 예측 불가능한 시나리오와 적응형 가상 적군은 훈련생들의 문제 해결 능력과 대응 능력을 한 차원 높인다.

마지막으로, AI 기반 M&S의 도입 및 발전은 첨단 기술 기반의 국방 생태계 조성을 촉진한다. 이는 AI 및 M&S 관련 연구개발 투자를 확대하고 전문 인력을 양성하며, 산·학·연·군 간의 협력을 강화하는 정책적 노력을 수반한다. AI 시대 국방 M&S는 디지털 트윈 기술 중심으로 발전해야 하며, 안정적 정착을 위해서는 전문인력 양성 등 단계적 실현 방안이 요구된다[8][14]. 이를 통해 국방 분야의 기술 자립도를 높이고, 혁신적인 방위 산업 생태계를 구축하여 국가 안보와 경제 발전에 동시에 기여할 수 있을 것이다.

5.2 향후 연구

AI 기반 M&S를 활용한 전장 환경의 효과적인 분석 및 대응 방안은 개발 초기 단계에 있으며, 앞으로 해결해야 할 과제와 확장될 연구 분야가 많다. 본 연구에서 제시된 논의를 바탕으로 향후 연구는 다음과 같은 방향으로 진행될 수 있다.

첫째, 하이퍼 리얼리티 기반 M&S 기술 개발이다. 가상현실(VR), 증강현실(AR), 혼합현실(MR) 기술을 M&S에 접목하여 더욱 몰입감 있고 현실적인 시뮬레이션 환경을 구축하는 연구가 필요하다. 이는 훈련 효과를 극대화하고, 지휘관의 전장 인식을 향상시키는 데 크게 기여할 것이다. 실제 전장의 미세한 변화까지 반영하는 초실감형 M&S 환경 구현은 훈련의 질을 한 단계 더 높일 것이다.

둘째, 인간-AI 협력의 효과적인 대응 모델 연구이다. AI의 자율성과 인간의 통제 및 윤리적 판단이 조화를 이루는 최선의 의사결정 시스템 및 지휘 모델을 개발해야 한다. AI가 제공하는 정보와 분석 결과를 인간 지휘관이 어떻게 효과적으로 활용하고 통합할 것인가에 대한 심도 깊은 연구가 필요하다. 인간과 AI 간의 신뢰 구축, 효과적인 정보 공유 방식, AI의 제안에 대한 인간의 비판적 수용 태도 등을 포괄하는 연구가 요구된다.

셋째, 윤리적 및 법적 고려사항 심화 연구이다. AI 기반 무기체계의 자율성 수준, 책임 소재, 의사결정 과정의 투명성 등 복합적인 윤리·법적 문제에 대한 지속적인 논의와 국제적 합의가 필수적이다. 특히 자율살상무기(LAWS: Lethal Autonomous Weapons Systems)에 대한 국제사회의 규범 형성 노력과 발맞춰, 국방 AI의 윤리적 사용 가이드라인 마련이 시급하다.

넷째, 국방 특화 AI 모델 및 데이터셋 구축이다. 일반적인 AI 모델이 아닌, 국방 분야의 특수성(데이터 희소성, 민감성, 실시간성, 보안 등)을 반영한 전용 AI 모델과 대규모 고품질 데이터셋을 개발해야 한다]. 특히 다영역 통합 데이터셋 구축은 AI 기반 M&S의 성능을 비약적으로 향상시킬 수 있다.

마지막으로 국제 협력 및 표준화이다. 동맹국 및 우방국과의 AI 기반 M&S 기술 교류를 활성화하고, 관련 시스템의 상호운용성 확보를 위한 국제 표준화 논의에 적극적으로 참여해야 한다. 이는 글로벌 안보 환경 변화에 공동으로 대응하고, 기술적 우위를 확보하는 데 중요한 역할을 할 것이다.

이러한 향후 연구들을 통해 AI 기반 M&S는 미래 전장에서 단순히 분석 도구를 넘어, 전력 운용의 혁신을 이끌고 국가 안보를 수호하는 핵심 동력으로 발전할 수 있을 것이다. 본 연구가 미래 국방 기술 발전에 대한 중요한 토론을 촉발하고, 실제적인 해결책을 모색하는 데 기여하기를 기대한다.

참 고 문 헌

[1] 국방기술진흥연구소. (2024). ('24-'38) 국방기술기획서: 일반본. 국방기술진흥연구소.

[2] 최진. (2021). 지휘관들의 의사결정지원을 위한 AI 군참모 기술동향. 융합보안 논문지, 21(3), 107-113.

[3] 최종건·강명주·이경근·조영수. (2024). JADC2 구현을 위한 국방 AI 파운데이션 모델 적용 전략. 국방정책연구, 40(2), 1-28.

[4] 백지원·임정우·박수정. (2023). 한국 해군 함정에서의 디지털 트윈과 MR 기술 적용 방안: 미래 해군 작전 및 훈련의 혁신. 융합보안 논문지, 23(6), 189-197.

[5] 이용철. (2021). AI 시대 국방 M&S의 발전 방향: 디지털 트윈 기술 중심으로. 국방기술진흥연구소 이슈페이퍼.

[6] 송승종. (2017). 러시아 하이브리드 전쟁의 이론과 실제. 한국유럽학회보, 35(2), 27-56.

[7] 김성철. (2023). 인지전과 윤리적 문제에 대한 연구: 정의전쟁론을 중심으로. 철학탐구, 65(3), 209-236.

[8] Youngjoon Lee, Taehyun Park, Yeongjoon Kang, Jonghoe Kim, Joonhyuk Kang. (2023). ROK Defense M&S in the Age of Hyperscale AI: Concepts, Challenges, and Future Directions. Journal of Convergence Security, 23(5), 189-197.

[9] 이태호·박태호·김창호. (2013). 국방 M&S의 특징 분석과 이를 통한 VV&A 방향. 한국군사과학기술학회지, 16(3), 405-412.

[10] 변수봉·최정식·오경택. (2019). 시험평가용 M&S에 대한 V&A(Verification and Validation) 프로세스 연구. 한국군사과학기술학회지, 22(4), 481-490.

[11] 권민성. (2015). 검증 및 확인(V&V) 절차를 통한 무기체계 M&S 신뢰도 향상 방안 연구. 한국산업경영시스템학회지, 38(3), 11-19.

[12] 김태호. (2018). 인공지능의 국방 M&S 분야 활용방안. 한국국방과학기술학회지, 1(2), 33-40.

[13] 문호석. (2021). 훈련 M&S 분야 인공지능 적용 사례와 발전 방안. 한국국방M&S학회지, 11(1), 22-31.

[14] 김성환·이재형·정원영. (2023). AI·디지털 트윈으로 국방 디지털 전환 논의. 국방정책연구원.

[15] 오경록·윤지훈·이성종. (2024). 미군의 JADC2 추진을 통해 보는 한국군 지휘통제 발전방향. 국방정책연구, 40(1), 1-26.

저 자 소 개

박상중(E-mail: nicegift701@korea.kr)
서울과학기술대학교 IT정책전문대학원 정책학박사
국방대학교 전자계산학 석사
육군사관학교 전자공학사
현재 국방대학교 직무교육원 교수
관심분야: 복잡계, AI, M&S, 빅데이터, 자율살상무기(LAWS), 실시간 전투지휘 등

군 사 과 학 연 구 지
제0권 제0호(0000년 00월)

한 글 제 목(굴림 16)

영 문 제 목(신명조 12)

이센터[1] · 김센터[2](굴림 11)
Cen-Ter Lee · Cen-Ter Kim (신명조 11)

ABSTRACT(견명조 10)

abstract abstract abstract abstract abstract abstract(신명조 10)

Keywords : Keywords, Keywords, Keywords, Keywords, Keywords, Keywords, Keywords,

1) 00대학교 0000전공 석사과정(바탕 9)
2) 00대학교 0000전공 교수

1. 서 론(HY중고딕 14)

현대사회에서 국방기술은 ~~~~~~~~~~~~~~ 연구방안 수립과 추진이 필요하다.

국내외의 ~~~~~~~~필요성의 증대로 귀결된다.

이처럼 ~~~~~~~~~~~~~~~~~~~~~~~~~~ 하고 있다.

또한 과학기술의 ~~~~~~~~~~~~~~ ‘Scientometrics’라 한다.[8] ~~~~~~~연구를 의미한다.(신명조 10)

2. 000 고찰

2.1 0000000(휴먼고딕 13)

과학기술 연구활동의~~~~~~~~~~~~~ 정보이다.

이런 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~부분이다.[7]

그러므로, ~~~~~~~~~~~~~~~필요하다. <그림 1>은 ~~~~~~~~~~~~~~~ 보여준다.

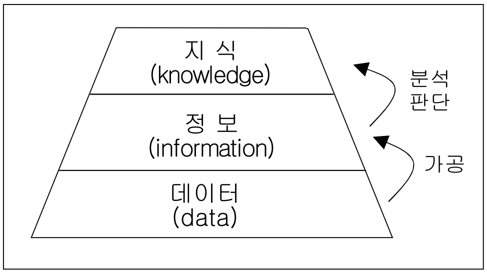

<그림 1> 데이터, 정보, 지식의 계층 구조

데이터는 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~올라가게 된다.[6]

2.2 0000

최근의 ~~~~~~~~~~~~~~~~~~~~~과정이라 할 수 있다.

최근 ~~~~~~~~~~~~~~~~~~~~~~~개괄적인 비교는 <표 1>과 같다.

<표 1> 000000 비교

3. 00000

현재 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~ 있다.

4. 000 방법

연구동향을 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~같다.

4.1 00000

1차 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~~있다.

4.2 00000

1차 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~ 수집하였다.

5. 00결과

5.1 0000000

자율주행~~~~~~~~~~~~~~~~~~사용하였다.

5.2 00000

지형/물체 ~~~~~~~~~~~~~~~~~~입력하였다.

5.3 00000

상위 ~~~~각주3)~~~~~~~~~~~~~~~~~~~~~~ 있다.

6. 결 론

지금까지 ~~~~~~~~~~~~~~~~~~~~~~~~~~기대된다.

그러나 ~~~~~~~~~~~~~~~~~~~~~~~~~~~~필요하다.

참 고 문 헌(휴먼고딕 16)

[1] 국방기술품질원,『2007 국방과학기술조사서(일반본) 제4권』, 국방기술품질원, 2012
[2] 이주장・김현진・이민철・강정원・권인소・송재복, "자율주행기술", 기계저널 제47권, 2007
[3] 박용태, 『기술과 경영』, 생능출판사, 2005
[4] 임치환, "Knowledge Map의 활용에 관한 연구", 한국외국어 대학교 석사학위논문, 2006
[5] 윤문섭・이우형・김윤명・오해영・손성혁, "신기술 연구기획 사전 타당성 분석을 위한 지식맵 작성 방법론 개발 및 활용방안", STEPI, 2003

3) 각주내용.

저 자 소 개(HY신명조 13)

증명
사진

000(E - mail: 0000000@naver.com)
2000 0000000 졸업(문학사)
현재 00대학교 0000전공 석사과정
관심분야 : 데이터마이닝, OR/SA,

증명
사진

000(E - mail: 0000000000@000000)
1991 00000학교 졸업(이학사)
1997 미국 UC. Berkeley 졸업(0000 석사)
2005 KDI 00대학원 졸업(000000 석사)
2006 00대학교 졸업(0000 박사)
관심분야 :

| 발행인 |

김영호(국방대학교 총장직무대리)

| 편집인 |

박영준(국가안보문제연구소장)

군사과학연구 제18권 제2호

2025년 12월 31일 인쇄
2025년 12월 31일 발행

발행처 : 국방대학교 국가안전보장문제연구소
TEL. (041) 831-6415
E-mail. rinsakj@kndu.ac.kr

인 쇄 : 청맥기획 (042) 487-2589

ISSN 1975-3888

Journal of Military Science and Technology Studies

ISSN 1975-3888
Vol. 18 No. 2 December, 2025

Research Papers

RINSA
Korea National Defense University
Research Institute for National Security Affairs