

군사과학연구

Journal of Military Science and Technology Studies

ISSN 1975-3888
제18권 제1호 2025년 6월



연구논문

사단 LVC통합훈련간 모델별 전술적 기동 속도 및
간접사격 피해 효과 일관성 유지 방안 연구

김건국·김재호·김동철·문호석

한국 해군의 유·무인 복합체계 발전 전략:
주요국 사례 비교 및 정책적 제언

김태양·마정목

AI 생성 화합물 및 전구체 시너지 분석을 통한 이중용도 평가

이춘주



군사과학연구

Journal of Military Science and Technology Studies

ISSN 1975-3888
제18권 제1호 2025년 6월



연구논문

사단 LVC통합훈련간 모델별 전술적 기동 속도 및
간접사격 피해 효과 일관성 유지 방안 연구

김건국·김재호·김동철·문호석 1

한국 해군의 유·무인 복합체계 발전 전략:
주요국 사례 비교 및 정책적 제언

김태양·마정목 13

AI 생성 화합물 및 전구체 시너지 분석을 통한 이중용도 평가

이춘주 25



국방대학교
국가안전보장문제연구소



Research Papers

- A Study on Maintaining Consistency of Tactical Movement Speed and Indirect Fire Damage Effects
Between Models During Division-Level LVC Integrated Training
/ **Kunkook Kim · Jaeho Kim · Dongcheol Kim · Hoseok Moon** 1
- A Study on the Republic of Korea Navy's Strategy for Manned-Unmanned Teaming:
Comparative Analysis of Major Military Powers and Policy Recommendations
/ **Tae-Yang Kim · Jungmok Ma** 13
- Dual-Use Assessment through AI-Generated Compounds and Precursor Synergy Analysis
/ **Choonjoo Lee** 25

사단LVC통합훈련간 모델별 전술적 기동 속도 및 간접사격 피해 효과 일관성 유지 방안 연구

A Study on Maintaining Consistency of Tactical Movement Speed and Indirect Fire Damage Effects Between Models During Division-Level LVC Integrated Training

김건국¹⁾ · 김재호²⁾ · 김동철³⁾ · 문호석⁴⁾

Kunkook Kim · Jaeho Kim · Dongcheol Kim · Hoseok Moon

ABSTRACT

Division-level LVC integrated training conducts exercises using different simulation modes: the division(-) unit is trained through constructive simulation using the ChangJo21 model, one brigade participates via KCTC Live simulation, and one Army aviation company uses virtual simulation through helicopter simulators. The purpose of this training is to enhance the effectiveness of division-level training by leveraging the strengths of each simulation mode. However, if there are significant differences in tactical movement speeds and indirect fire damage effects between constructive and live simulation units due to the differing simulation methods, issues of consistency in overall training execution may arise. This study establishes an experimental design to scientifically verify whether units of the same level under the same battlefield environment show differences in tactical movement speed and indirect fire damage effects between KCTC Live training and ChangJo21 model training. Based on this, it proposes solutions to address the consistency issues in such integrated training.

Keywords : Division-Level LVC Integrated Training, Experimental Design,
Indirect Fire, Maintaining Consistency, Tactical Movement

논문접수일 : 2025년 5월 9일, 심사일 : 2025년 6월 5일~6월 13일, 게재확정일 : 2025년 6월 13일

본 연구는 육군합성전장훈련체계(Build-I) 체계개발 위탁과제(제 2024MNS10-01호)의 지원을 받아 수행되었습니다.

- 1) 육군 분석평가단 육군 대위
- 2) 국방대학교 국방과학학부 석사과정
- 3) 육군합성전장훈련체계(Build-I) 개발사업 PM
- 4) 국방대학교 국방AI/로봇학과 교수 / 교신저자(hsmoon0329@gmail.com)

1. 서론

육군합성전장훈련체계는 현재 육군에서 체계개발 중인 사업으로 '27년 말에 개발이 완성되는 것으로 진행되고 있다. 이 사업은 현재 Constructive 모의로 사용되고 있는 창조21 모델 및 전투21모델을 각각 성능 개량하는 것과 Live 훈련인 KCTC(Korea Combat Training Center) 훈련, Virtual 훈련인 육군 항공전술시뮬레이터, 창조21모델을 사용하여 진행되는 Constructive 훈련을 연동하는 LVC 연동훈련체계를 개발하는 사업이다[1]. 특히 LVC연동훈련체계가 개발되면 사단훈련에 활용될 예정인데, LVC연동훈련체계를 사용하는 훈련이 사단급LVC통합훈련이다.

사단급LVC통합훈련은 사단훈련을 사단(-)는 창조21모델로 Constructive 모의하고, 1개 여단은 KCTC Live 모의로, 1개 육군 항공 중대는 헬기 시뮬레이터인 Virtual 모의로 훈련을 진행한다. 이 훈련은 Live, Constructive, Virtual 각 시뮬레이션의 장점을 살리고, 단점을 보완해서 사단훈련의 효과를 향상시키는 것이 목적이다. 예를 들어 Constructive 훈련은 부대와 장비가 컴퓨터로 구현됨으로 지휘관 및 참모의 전투지휘훈련을 위한 시뮬레이션을 필요할 때 자유롭게 할 수 있으나, 실제 전장의 마찰 요소가 반영되는 것이 제한되는 단점이 있다. Live 훈련은 부대와 장비가 실제로 투입되어 전장 환경을 경험하며 훈련을 경험할 수 있는 장점이 있지만, 훈련통제부에서 주변 전장 환경을 묘사해주어야 하고 상급부대와 인접 부대와와의 협조된 훈련이 제한되는 단점이 있다. 이러한 점들을 사단급LVC통합훈련을 통해서 보완하여, 훈련의 효과를 증대시키고자 하는 것이다. 그러나, 시뮬레이션 모의 방식이 서로 다른 Constructive 부대와 Live 부대의 전술적 기동 속도와 교전 피해 결과의 차이가

크다면, 전체 훈련 진행에 있어서 일관성 문제가 발생한다. 즉, Live 훈련부대들의 전술적 기동 속도보다 Constructive 훈련을 하는 부대들의 전술적 기동 속도가 매우 빠르다면 훈련 전체의 일관성 문제가 발생하게 된다. 이런 결과가 발생할 것이라 예상하는 이유는 각 모델에 속한 객체의 전술적 기동 속도와 교전 피해 논리는 모델의 모의 논리와 특성에 따라 다르기 때문이다. 특히 Live 훈련의 경우는 일부 모의 논리가 적용되는 항목을 제외하고는 실제 전장에서의 활동이 그대로 훈련 결과에 반영된다.

본 연구에서는 동일한 전장 환경에서 동일한 수준의 부대가 KCTC Live 훈련일 때와 창조21모델의 Constructive 훈련에서 전술적 기동 속도와 간접 화력 피해 결과가 차이가 있는지 실험계획을 수립하여 과학적으로 검증하고, 차이가 있다면 이를 보완하는 방안을 제시하는 것을 목적으로 한다. 본 연구는 2장에서 육군 과학화훈련체계에서 연동 훈련을 한 사례들을 살펴보고, 본 연구의 차별점을 알아볼 것이다. 3장에서는 본 연구의 목적을 달성하기 위한 실험계획 중심의 연구 방법을 다루고, 4장에서는 연구 결과를, 5장에서는 결론과 향후 연구 방향을 제시한다.

2. 기존 연구

기존 육군의 M&S(Modeling & Simulation) 과학화훈련에서 워게임 모델 간에 있었던 연동 훈련은 많지 않으나, 그동안 있었던 몇 가지 사례들을 살펴보면 다음과 같다.

현재 육군전투지휘훈련단의 창조21모델과 화랑21모델 그리고 작전지속지원모델이 연동하여 훈련하고 있는 전승21훈련체계(논문 발표 당시 제병협동통합연동체계)가 있다[2]. 이 연동 훈련체계에서는 창조21모델의 부대와 화

량21모델의 부대가 공통의 전장 환경에서 훈련을 실시하는데, 전술적 기동 속도와 교전 피해 결과에 있어서 거의 동일한 모의 논리를 사용하고 있고, 해상도도 동일하여 일관성 유지 측면에서 문제가 되지 않았다[3].

해상도가 다른 두 Constructive 모델을 연동시키려는 시도와 필요성도 제기되었었다[4]. 창조21모델과 전투21모델을 연동시키고자 하는 방안인데, 창조21모델은 사단과 군단 훈련용이고, 전투21모델은 여단 훈련용 모델이다. 두 모델은 해상도가 달랐으나, 모두 Constructive 훈련으로 모의 논리 자체의 차이가 크지 않았고, 특히 전술적 기동 속도는 유의한 차이가 없었다. 또한, 간접 화력에 의한 피해평가는 두 모델의 모의 논리를 비교해서 보정할 수 있어서, 별도의 실험계획을 통한 차이를 확인할 필요가 없는 수준이었다.

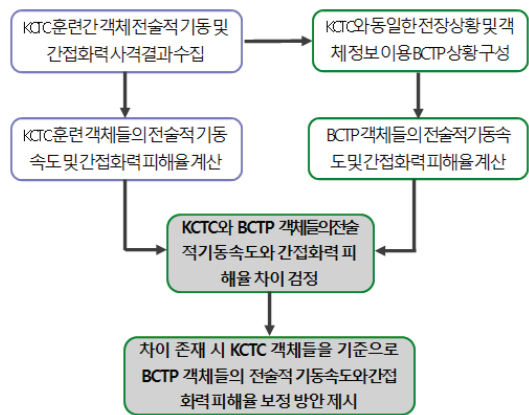
앞의 두 예와는 달리 시뮬레이션 모의 방식이 다른 전투21모델과 전차 Virtual 시뮬레이터인 TMPS(Tank Multi-Purpose Simulator)를 연동하는 훈련도 있었다[5]. 이 훈련의 경우는 두 모델이 각자 역할을 수행하면서, 전차부대 중에 1개 소대를 TMPS를 이용해서 훈련자를 직접 훈련시키고, 그 결과를 Constructive 모의인 전투21모델에서 받아서 사용하고자 하는 것이 목적이었다. 따라서 각 모델의 부대 자체의 전술적 기동 속도와 교전 피해 결과가 서로에게 영향을 주지 않고, 일관성 있게 유지될 필요가 없기에 본 연구에서 다루는 주제와는 관련이 없는 훈련이었다.

본 연구에서 다루는 사단급LVC통합훈련체계에서는 기존 연동 훈련에서 다루지 않았던, Constructive와 Live를 연동시키려는 것이고, 특히 각 모델 객체의 전술적 기동 속도와 간접 화력 피해 결과가 차이가 많다면, 전체 훈련의 진행에 문제가 발생할 수 있다. 또한, 두 모델의 모의 논리 비교를 통해서 일관성 유지 문제를 해결할 수 없는 상황이기에 기존과는

다른 방법론으로 일관성 유지 문제를 해결하는 시도가 필요하다.

3. 연구 방법

본 연구의 전체적인 흐름도는 <그림 3-1>과 같은데, 그림은 전술적 기동 속도와 간접 화력 피해를 측면에서 KCTC 객체들(부대)과 BCTP 객체들(부대)의 차이가 있는지를 알기 위한 실험계획의 전체적인 모습이다.



<그림 3-1> 연구흐름도

3.1 KCTC 데이터 수집 분석

KCTC 훈련간 객체들의 데이터는 관찰자료로 수집하였는데, 2023년에 실시한 KCTC 4개 여단 훈련 중 공격작전 MILES(Multiple Integrated Laser Engagement System) 데이터 약 200Gbyte 양을 수집하여, 객체들의 전술적 기동 속도와 간접 화력 피해 결과를 계산하여 분석하였다[6]. 전술적 기동 속도 수집 대상은 인원, 전차, 자주포, 지휘 차량 4종류이었다. 이 가운데 장비는 한 대 단위로 데이터를 수집하였고, 인원은 소총 중대에 대해서 자료를 수집하고 계산하였다. 전술적 기동 속도를 계산하기 위한 데이터는 각 객체가 최초 위치에서 일정한 시간 동안 지속적으로 기

동한 경우의 상황만으로 한정하였다. 본 연구에서는 최소 10분 이상 지속적으로 기동한 경우만을 고려하였다. 즉 중간에 멈춘 경우는 정확한 전술적 기동 속도를 산정 시 방해가 될 수 있어서 제외하였다. 이 가운데 집단에 해당하는 소총 중대의 기동 속도는 단대로 움직이는 것이 아닌 Live 훈련인 KCTC 훈련에서 모든 객체의 MILES 결과를 반영하는 것은 불가능하여, 중대내 소대에서 임의의 3개 분대장을 선정하여 3명의 중심 좌표가 최초에서 최종 위치로 이동한 기동 거리와 시간으로 판단하였다[7].

간접 화력의 피해율 계산을 위해서 KCTC 훈련간 155mm 고폭탄을 자주포 곡사화포인 K-9 또는 K-55A1로 사격한 것에 대한 간접 화력 사격 결과를 분석하였다. KCTC 훈련간 해당 조건의 간접 화력은 많이 발생하였으나, 피해가 없는 경우가 많았다. 그런 이유 중의 대부분은 낙탄 지점에 인원이 없는 경우였다. 따라서 본 실험을 위한 간접 화력 사격 결과 데이터 획득을 위해서 낙탄 지점을 중심으로 살상반경이 50m인 고폭탄 살상반경 내에 인원이 존재했던 경우만을 추출하였다. KCTC의 경우는 간접 화력의 피해 결과가 1발 단위로 계산된다.

3.2 BCTP 상황 구성

KCTC 훈련 결과를 통해서 수집한 객체들의 전술적 기동 속도와 간접 화력 피해 결과를 BCTP의 경우와 비교하기 위해서는 BCTP 창조21모델의 상황 구성을 KCTC 경우와 동일하게 준비하여야 했다. 따라서 소총 중대, 전차, 자주포, 지휘 차량 객체들의 KCTC에서 추출한 전술적 기동 속도 결과와 동일한 조건을 BCTP 창조21모델에서 구축하여 실험하였다. 먼저 전술적 기동 속도의 예를 들면, 소총 중대의 경우는 소총 중대 단대호를 창조21모

델에서 만들어 KCTC 훈련에서 기동했던 최초 위치에서 최종 위치까지를 이동시켜서 이동간의 전술적 기동 속도를 측정하였다. 이와 같은 방식으로 전차, 자주포, 기동차량에 대해서 동일한 조건과 환경을 만들어서 BCTP 창조21 모델에서 실험하였다. 다음으로 간접 화력 피해율에 대해서는 KCTC 훈련 결과 자료에서 수집한 155mm 고폭탄 한 발 한 발의 간접 화력 상황에 맞는 실험 환경을 BCTP 창조21 모델에 구축하고 실험하여 피해율을 계산하였다.

3.3 실험 결과 검정 및 보정

3.1절의 KCTC 관찰 결과와 3.2절의 BCTP 실험 결과가 전술적 기동 속도 측면에서 또 간접 화력 피해율 측면에서 차이가 있는지를 통계적 검정을 통해서 확인하였다. 두 개의 표본은 짝표본으로 구성하였기에 짝표본 t-test를 실시하였다. KCTC 관찰 결과와 BCTP 실험 결과를 볼 때 전술적 기동 속도 그리고 간접 화력 피해율에서 차이가 존재하게 되면 사단급LVC통합훈련 진행 시에 전체적으로 일관성 유지 차원에서 문제점이 생기기 때문에 이러한 문제들을 해결하기 위한 보정 방안을 본 연구에서 제시하였다. 전술적 기동 속도만 보더라도 KCTC의 경우는 Live 훈련으로 모의 논리에 따라서 모든 것이 결정되는 것이 아니라, 실제 병력과 장비가 움직이는 것에 따라서 결정됨으로 Live 훈련을 보정 할 수는 없다. 따라서 본 연구에서는 Constructive 모의 훈련의 값들을 보정하는 방안을 제시하였다. 특히 모의 논리에 반영되어 있는 개별 파라미터를 보정하는 것은 다양한 파라미터 중에 어떤 것을 보정해야 하는지를 결정하기 어렵기에 전체 결과에 보정값을 곱해주는 방안을 제시하였다.

4. 연구 결과

4.1 전술적 기동 속도 연구 결과

전술적 기동 속도를 비교하는 대상은 4종류로 소총 중대, 전차, 자주포, 지휘 차량이다. 4종류 각각에 대해서 KCTC 관찰 결과를 기초로 BCTP 창조21모델의 실험 환경을 구성하고 실험을 진행하였으며, 각 종류별 동일한 조건을 구성하였으므로 KCTC와 BCTP의 결과는 짝 표본이다. 짝 표본에 대해서 4개의 종류별로 비교해서 분석하였다.

4.1.1 소총 중대 전술적 기동 속도

24개 소총 중대의 전술적 기동 속도를 KCTC 훈련 결과에서 추출하였고, 24개 중대의 각각의 전장 상황과 동일한 조건의 환경으로 BCTP 창조21모델의 실험 환경을 구축하여 실험하였다.

〈표 4-1〉 KCTC와 BCTP 소총 중대의 전술적 기동 속도 기술통계량 비교(단위 : km/h)

구분	최소값	1사분위수	중간값	3사분위수
KCTC	0.675	1.365	1.485	1.820
BCTP	1.580	2.053	2.655	2.795
구분	최대값	평균	표준편차	변이계수
KCTC	2.260	1.563	0.407	26%
BCTP	4.280	2.521	0.633	25%

〈표 4-1〉의 소총 중대 전술적 기동 속도 기술통계량을 보면 BCTP 소총 중대가 KCTC 소총 중대 보다 다섯 수치(최소값, 1사분위수, 중간값, 3사분위수, 최대값) 모두에서 빠르고, 평균적으로는 BCTP 소총 중대가 KCTC 소총 중대 보다 1.613배(2.521 / 1.563) 빠르다. 반대로 BCTP 소총 중대의 전술적 기동 속도에 0.62(1.563 / 2.521)를 곱하면 평균적으로

KCTC 소총 중대의 전술적 기동 속도와 비슷해진다. 변이계수는 KCTC와 BCTP의 소총 중대가 서로 비슷한 수준이었다.

〈표 4-2〉 KCTC와 BCTP 소총 중대의 전술적 기동 속도 짝표본 검정 결과

구분	t 값	자유도	유의확률
값	7.674	23	8.7X10-8

KCTC와 BCTP 소총 중대의 전술적 기동 속도 짝표본 검정 결과는 〈표 4-2〉와 같다. 검정 결과 유의확률이 0.05보다 작으므로 귀무가설인 “KCTC와 BCTP 소총 중대의 전술적 기동 속도 차이가 존재하지 않는다”라는 것을 기각하여 차이가 있다고 할 수 있다[8]. 즉 KCTC와 BCTP가 함께 훈련할 때 동일한 전장 상황이라면 소총 중대의 전술적 기동 속도는 평균적으로 차이가 존재하며, BCTP 소총 중대의 전술적 기동 속도가 더 빠르다고 할 수 있다.

일관성 유지를 위해서 전술적 기동 속도를 보정 하여야 하는데, Live 훈련인 KCTC를 보정할 수는 없기에 BCTP 창조21모델 결과에 보정값을 적용하는 방법을 적용한다. 즉, 보정은 어떤 경우에도 KCTC 객체 전술적 기동 속도 관찰 결과를 기준으로 하고, 이에 따라 BCTP 객체의 전술적 기동 속도를 보정한다. BCTP 소총 중대의 전술적 기동 속도에 0.62(1.563 / 2.521)를 곱하면 평균적으로 KCTC 소총 중대의 전술적 기동 속도로 추정할 수 있다. 따라서 보정식은 식 (1)과 같다. 평균을 고려하는 것은 반복적으로 시행했을 때 유사한 결과가 나오도록 하기 위함이다.

$$\begin{aligned} & \text{KCTC로 추정된 소총 중대의 전술적 기동 속도} \\ & = 0.62 \times \text{BCTP 소총 중대 전술적 기동 속도} \quad (1) \end{aligned}$$

4.1.2 전차 전술적 기동 속도

18대 전차의 전술적 기동 속도를 KCTC 훈련 결과에서 추출하였고, 18대 전차 각각의 전장 상황과 동일한 조건의 환경으로 BCTP 창조21모델의 실험 환경을 구축하여 실험하였다.

〈표 4-3〉 KCTC와 BCTP 전차의 전술적 기동 속도 기술통계량 비교(단위 : km/h)

구분	최소값	1사분위수	중간값	3사분위수
KCTC	4.20	5.64	6.85	7.28
BCTP	6.90	14.14	18.16	19.62
구분	최대값	평균	표준편차	변이계수
KCTC	8.52	6.59	1.15	17.4%
BCTP	32.90	18.31	6.97	38.1%

실험 결과는 〈표 4-3〉과 같으며, 전차의 전술적 기동 속도 기술통계량을 보면 BCTC 창조21모델에서의 전차가 KCTC 전차의 전술적 기동 속도 보다 다섯 수치(최소값, 1사분위수, 중간값, 3사분위수, 최대값) 모두에서 빠르고, 평균적으로는 BCTP 전차의 전술적 기동 속도가 KCTC보다 2.78배(18.31 / 6.59) 빠르다. 반대로 BCTP 전차의 전술적 기동 속도에 0.38(6.59 / 18.31)을 곱하면 평균적으로 KCTC 전차의 전술적 기동 속도와 비슷해진다. 변이계수는 BCTP 전차가 KCTC보다 2배 가량 높았다.

〈표 4-4〉 KCTC와 BCTP 전차의 전술적 기동 속도 짝표본 검정 결과

구분	t 값	자유도	유의확률
값	7.4	17	1.04X10⁻⁶

KCTC와 BCTP 전차의 전술적 기동 속도 짝표본 검정 결과는 〈표 4-4〉와 같다. 검정 결과 유의확률이 0.05보다 작으므로 귀무가설인 “KCTC와 BCTP 전차의 전술적 기동 속도

차이가 존재하지 않는다”라는 것을 기각하여 차이가 있다고 할 수 있다. 즉 KCTC와 BCTP가 함께 훈련할 때 동일한 전장 상황이라면 전차의 전술적 기동 속도는 평균적으로 차이가 존재하며, BCTP 전차의 전술적 기동 속도가 더 빠르다고 할 수 있다.

BCTP 전차의 전술적 기동 속도에 0.38(6.59 / 18.31)을 곱하면 평균적으로 KCTC 전차의 전술적 기동 속도가 된다. 따라서 보정식은 식 (2)와 같다.

$$\begin{aligned} & \text{KCTC로 추정된 전차의 전술적 기동 속도} \\ & = 0.38 \times \text{BCTP 전차의 전술적 기동 속도} \quad (2) \end{aligned}$$

4.1.3 자주포 전술적 기동 속도

15대 자주포의 전술적 기동 속도를 KCTC 훈련 결과에서 추출하였고, 15대 자주포 각각의 전장 상황과 동일한 조건의 환경으로 BCTP 창조21모델의 실험 환경을 구축하여 실험하였다.

〈표 4-5〉 KCTC와 BCTP 자주포의 전술적 기동 속도 기술통계량 비교(단위 : km/h)

구분	최소값	1사분위수	중간값	3사분위수
KCTC	3.52	4.64	7.57	9.04
BCTP	9.41	14.91	17.44	19.89
구분	최대값	평균	표준편차	변이계수
KCTC	11.7	7.28	2.82	38.8
BCTP	30.15	18.15	5.78	31.9

실험 결과는 〈표 4-5〉와 같으며, 자주포의 전술적 기동 속도 기술통계량을 보면 BCTC 자주포가 KCTC 전술적 기동 속도보다 다섯 수치(최소값, 1사분위수, 중간값, 3사분위수, 최대값) 모두에서 빠르고, 평균적으로는 BCTP 자주포의 전술적 기동 속도가 KCTC보다 2.49배(18.15 / 7.28) 빠르다. 반대로 BCTP 자주포의 전술적 기동 속도에 0.40(7.28 /

18.15)을 곱하면 평균적으로 KCTC 자주포의 전술적 기동 속도와 비슷해진다.

〈표 4-6〉 KCTC와 BCTP 자주포의 전술적 기동 속도
 짝표본 검정 결과

구분	t 값	자유도	유의확률
값	7.97	14	1.43X10 ⁻⁶

KCTC와 BCTP 자주포의 전술적 기동 속도 짝표본 검정 결과가 〈표 4-6〉과 같다. 검정 결과 유의확률이 0.05보다 작으므로 귀무가설인 “KCTC와 BCTP 자주포의 전술적 기동 속도 차이가 존재하지 않는다”라는 것을 기각하여 차이가 있다고 할 수 있다. 즉 KCTC와 BCTP가 함께 훈련할 때 동일한 전장 상황이라면 자주포의 전술적 기동 속도는 평균적으로 차이가 존재하며, BCTP 자주포의 전술적 기동 속도가 더 빠르다고 할 수 있다. BCTP 자주포의 전술적 기동 속도에 0.40(7.28 / 18.15)을 곱하면 평균적으로 KCTC 자주포의 전술적 기동 속도가 된다. 따라서 보정식은 식 (3)과 같다.

$$\text{KCTC로 추정된 자주포의 전술적 기동 속도} = 0.40 \times \text{BCTP 자주포의 전술적 기동 속도} \quad (3)$$

4.1.4 지휘 차량 전술적 기동 속도

7대 지휘 차량의 전술적 기동 속도를 KCTC 훈련 결과에서 추출하였고, 7대 지휘 차량 각각의 전장상황과 동일한 조건의 환경으로 BCTP 창조21모델의 실험 환경을 구축하여 실험하였다.

〈표 4-7〉 KCTC와 BCTP 지휘 차량의 전술적 기동
 속도 기술통계량 비교(단위 : km/h)

구분	최소값	1사분위수	중간값	3사분위수
KCTC	2.54	5.11	8.40	9.43
BCTP	24.20	25.42	29.52	30.52
구분	최대값	평균	표준편차	변이계수
KCTC	10.64	7.24	3.07	42.4%
BCTP	30.81	28.06	2.91	10.4%

실험 결과는 〈표 4-7〉과 같으며, 지휘 차량의 전술적 기동 속도 기술통계량을 보면 BCTC 지휘 차량이 KCTC 전술적 기동 속도보다 다섯 수치(최소값, 1사분위수, 중간값, 3사분위수, 최대값) 모두에서 빠르고, 평균적으로는 BCTP 지휘 차량의 전술적 기동 속도가 KCTC보다 3.88배(28.06 / 7.24) 빠르다. 반대로 BCTP 지휘 차량의 전술적 기동 속도에 0.26(7.28 / 18.15)을 곱하면 평균적으로 KCTC 지휘 차량의 전술적 기동 속도와 비슷해진다. 변이계수는 KCTC 지휘 차량이 BCTP보다 4배가량 높았는데, 지휘 차량별 속도 차이가 KCTC에서 많이 난다는 의미이다.

〈표 4-8〉 KCTC와 BCTP 지휘 차량의 전술적 기동
 속도 짝표본 검정 결과

구분	t 값	자유도	유의확률
값	13.04	6	1.25X10 ⁻⁵

KCTC와 BCTP 지휘 차량의 전술적 기동 속도 짝표본 검정 결과가 〈표 4-8〉과 같다. 검정 결과 유의확률이 0.05보다 작으므로 귀무가설인 “KCTC와 BCTP 지휘 차량의 전술적 기동 속도 차이가 존재하지 않는다”라는 것을 기각하여 차이가 있다고 할 수 있다. 즉 KCTC와 BCTP가 함께 훈련할 때 동일한 전장 상황이라면 지휘 차량의 전술적 기동 속도는 평균적으로 차이가 존재하며, BCTP 지휘

차량의 전술적 기동 속도가 더 빠르다고 할 수 있다. BCTP 지휘 차량의 전술적 기동 속도에 0.26(7.24 / 28.06)을 곱하면 평균적으로 KCTC 지휘 차량의 전술적 기동 속도가 된다. 따라서 보정식은 식 (4)와 같다.

$$\text{KCTC로 추정된 지휘 차량의 전술적 기동 속도} = 0.26 \times \text{BCTP 지휘 차량의 전술적 기동 속도} \quad (4)$$

4.2 간접 화력 피해율 연구 결과

간접 화력 피해율 비교 연구는 155mm 고폭탄 1발로 낙탄 좌표에 있는 인원들에 대해서 사격했을 때 KCTC와 BCTP에서 중상 이상 피해 인원에 대한 비교실험 결과이다. 비교 실험을 위해서 먼저 KCTC 훈련에서 간접 화력 피해에 대한 관찰자료를 수집하였다. 이를 위해서 KCTC 훈련 중 공격작전 간 훈련부대가 대항군부대에 사격한 데이터로부터 추출하였고, '23년도 KCTC 훈련 결과 4개 차수 MILES 데이터로부터 추출하였다. 추출한 사격 발수는 1발 단위 사격으로 총 15발 사격 결과를 수집하였다. 이는 실제 훈련 간 피해가 발생한 포탄의 관찰 결과이다. 15발 이외의 사격에서는 낙탄 지점에 고폭탄 1발의 살상반경(50m)에 대항군 인원이 없었다고 할 수 있다. BCTP의 경우는 KCTC단 관찰 결과와 동일한 조건(동일 화포, 포탄, 낙탄 지점, 반경 내의 총 인원)을 만들어 사격하였다.

〈표 4-9〉 KCTC와 BCTP 155mm 사격 결과(피해율) 기술통계량 비교(단위 : %)

구분	최소값	1사분위수	중간값	3사분위수
KCTC	1.90	9.75	18.20	24.50
BCTP	3.80	6.30	6.70	9.10
구분	최대값	평균	표준편차	변이계수
KCTC	26.70	16.63	8.07	48.56
BCTP	10.00	7.43	1.88	25.38

실험 결과는 〈표 4-9〉와 같으며, KCTC와 BCTP 155mm 사격 결과 피해율의 기술통계량 분석 결과, 155mm 곡사화기에 대한 피해율은 KCTC의 경우가 BCTP의 경우보다 더 높았다. KCTC와 BCTP 사격결과 피해율의 변이계수를 보면 BCTP가 KCTC보다 2배가량 작은데 이는 BCTP 결과가 KCTC보다는 시행 횟수 단위로 차이가 작다는 것을 나타내고 있다. BCTP는 모의 논리에 의해서 간접 화력 사격 결과가 계산되기 때문이고, KCTC의 경우는 BCTP보다 전투원 개인의 상태가 중요하게 반영되어 있기에 시행 횟수별로 BCTP 훈련 결과보다는 차이가 많이 발생하고 있다고 볼 수 있다. 평균적으로는 KCTC 피해율이 BCTP에 비해서 2.24배(16.63 / 7.43) 높았다.

〈표 4-10〉 KCTC와 BCTP 155mm 사격 결과의 피해율 짝표본 검정 결과

구분	t 값	자유도	유의확률
값	4.386	14	0.00062

KCTC와 BCTP 155mm 사격 결과 피해율 짝표본 검정 결과가 〈표 4-10〉과 같다. 검정 결과 유의확률이 0.05보다 작으므로 귀무가설인 “KCTC와 BCTP 155mm 사격 결과 피해율의 차이가 존재하지 않는다”라는 것을 기각하여 차이가 있다고 할 수 있다. 즉 KCTC와 BCTP가 함께 훈련할 때 동일한 전장상황이라면 155mm 사격 결과 피해율은 평균적으로 차이가 존재하며, KCTC의 피해가 더 많이 발생한다고 할 수 있다. 보정식은 식 (5)와 같다.

$$\text{KCTC로 추정된 155mm 사격 결과 추정값} = 2.24 \times \text{BCTP 155mm 사격 결과 피해율} \quad (5)$$

5. 결론 및 향후 연구

사단급LVC통합훈련은 육군의 사단훈련에서 LVC 연동을 통해서 훈련의 효과를 극대화하기 위해 필요한 훈련으로 '27년에 훈련을 진행할 수 있는 체계가 개발되면, 본격적으로 시행될 훈련인데 이를 준비하는 차원에서 훈련개념을 어떻게 정립할지, 여러 시뮬레이션 모델이 사용됨으로 어디가 주체가 되어 훈련통제를 할지 등 결정해야 할 바와 연구하고 준비할 내용들이 많이 있다[9]. 그 가운데 한 가지가 시뮬레이션 모의 방식이 서로 다른 Constructive 부대와 Live 부대의 전술적 기동 속도와 교전 피해 결과의 차이를 어떻게 극복할 것인지에 대한 문제이다. 즉 이 차이가 크면 전체 훈련 진행에 있어서 일관성 문제가 발생한다. 본 연구는 이러한 부분을 다루고 있다.

본 연구에서는 동일한 전장 환경에서 동일한 수준의 부대가 KCTC Live 훈련일 때와 창조21모델의 Constructive 훈련일 때 전술적 기동 속도와 간접 화력 피해 결과가 차이가 있는지 실험계획을 수립하여 과학적으로 검증하고, 차이가 있다면 이를 보완하는 방안을 제시하였다. 전술적 기동 속도는 소총 중대, 전차, 자주포, 지휘 차량 4종류의 객체에 대해서 분석하였고, 간접 화력은 155mm 고폭탄에 대해서 실험하고 분석하였다. 분석 결과로 KCTC와 BCTP 객체의 전술적 기동 속도는 모든 종류에서 통계적으로 유의한 차이가 존재하였고, 간접 화력의 사격 결과(피해율)도 통계적으로 유의한 차이가 존재하였다. 종합적으로 볼 때 전술적 기동 속도와 간접 화력 피해율을 살펴보면 다음과 같다. 먼저, 전술적 기동 속도 측면에서는 BCTP 객체가 KCTC 객체보다는 빨랐다. 소총 중대는 1.6배, 전차는 2.8배, 자주포는 2.5배, 지휘 차량은 3.9배로 BCTP 객체가 더 빨랐다. 다음으로 155mm

간접 화력 사격 결과 피해율의 경우는 BCTP가 KCTC의 간접 화력 사격 결과 피해율보다 낮았다.

위의 분석 결과를 기초로 BCTP 객체를 KCTC 객체의 전술적 기동 속도와 간접 화력 사격 결과 피해율로 보정하는 보정식을 본 연구에서 제안하였다. 이 과정에서 KCTC 결과를 반응변수로 BCTP 결과를 설명변수로 하여 선형적인 관계로 구축되는 회귀분석을 구축하려고 했으나, 유의성이 너무 낮아 회귀분석 결과를 사용할 수가 없어서 연구에서는 제시하지 않았다. 이런 이유에 대해서 연구진은 BCTP와 KCTC는 기본적으로 결정 모형이 아니라 확률모형으로 결과를 제공하므로 두 결과의 선형적인 규칙을 찾기가 제한되는 무작위(random) 특성 때문으로 평가되었다.

본 연구는 시뮬레이션이 다른 경우에 발생할 수 있는 전술적 기동 속도와 간접 화력 사격 결과의 차이를 획득할 수 있는 제한된 원천데이터를 통해서 실험과 검증으로 분석하고 연구 결과를 도출하였다. 이런 과정에서 각 객체별 관찰 결과 자료 획득의 한계로 인해서 표본크기가 대부분 작았다. 이러한 점을 고려 시 본 연구 결과를 바로 사단급LVC통합훈련에 바로 적용하는 것은 고려해 봐야 할 것이다. 다만, 표본크기가 작지만 의미 있는 차이가 있음을 분명하게 확인할 수 있었기에, 일관성 유지 차원에서 참고 자료로 활용할 수 있겠다. 특히, 155mm 간접 화력의 경우는 비교 실험을 위해서 KCTC에서 포병사격을 했을 때 피해가 발생한 경우만을 고려하였는데, 포병사격 시에 피해가 발생하지 않은 경우가 많았는데 이 부분은 본 연구에서 비교하지 않았다. 따라서 본 연구의 실험 결과에서 KCTC의 경우가 간접 화력의 사격 결과 피해율이 BCTP의 경우보다 높았는데, 전체 훈련에서 포병사격 결과를 비교한 것은 고려하지 않았기에 단순히 포병사격을 하면 KCTC의 피해

율이 더 높다'는 의미는 아니다. 이와 더불어 KCTC와 BCTP의 간접 화력 사격 결과 모의 논리도 다르기에 본 연구에서는 이러한 점들이 고려되지 않았다는 한계가 있다. 본 연구는 사단급LVC통합훈련을 진행할 시에 발생할 수 있는 일관성 유지 문제를 다루고 있지만, 향후 연구에 있어서 보다 중요한 점은 Constructive 모델에서 사용하고 있는 전술적 기동 속도와 관련된 파라미터들, 그리고 간접 화력에서 사용하고 있는 파라미터들이 실제를 잘 반영하고 있는지 실험을 통해서 확인하고 나아가서 한국에 맞는 파라미터들을 개발할 수 있는 여건을 조성하는 것이 과학화훈련체계를 발전시키는 중요한 일이라 하겠다. 이를 위해서 KCTC단을 포함해서 Live 훈련 시 Constructive 모델에서 사용하고 있는 파라미터와 관련된 데이터를 축적해 가는 것이 중요하겠다. 이럴 때 한국 지형과 환경에 맞는 모델 개발에 필요들이 채워질 수 있을 것이다.

참 고 문 헌

- [1] 이종훈·박준옥, “미래 육군합성전장훈련체계에 VR/AR 기술 적용방안 연구,” 『융합보안 논문지』, 23, 5(2023): 189-197.
- [2] 문호석, 김형세, 황명상, 배현용, 이동근. “위게임 모델간 근접전투 피해평가 모의 논리 일치에 관한 연구 : 제병협동통합연동체계를 중심으로”, 37, 1(2011): 87-97.
- [3] 문호석. “기계학습을 이용한 위게임 모델의 근접전투 전장상황 평가를 위한 전문가시스템 연구”, 『한국군사학논집』, 74, 3(2018): 315-336.
- [4] 한석원, 문호석, 최원호, 유창원. “상이한 해상도를 갖는 창조21모델과 전투21모델의 연동간 간접전투 피해평가 일치 방안 연구”, 『한국데이터정보과학회지』, 30, 5(2019): 1105-1119.
- [5] 문호석, 김수환. “훈련용 위게임 모델의 다중해상도 모델링 운영소요 및 전투21모델과 TMPS의 다중해상도 연동간 주요 이슈 해결 방안 연구”, 『한국군사과학기술학회지』, 21, 6(2018): 865-876.
- [6] 과학화훈련단. “여단급 과학화전투훈련 지침서”. 대전: 국군인쇄장, 2021.
- [7] 강승욱·문호석. “여단급 KCTC 훈련결과 빅데이터를 이용한 보병중대 임무별 공격작전 전투결과에 영향을 주는 요인 분석,” 『한국군사학논총』, 27, 3(2023): 83-102.
- [8] 허명희. “R을 활용한 통계적 개념 방법 응용”. 자유아카데미: 파주, 2011.
- [9] 윤지영·강동수. “합성전장훈련체계를 위한 GPS 전파교란 모의 논리 연구,” 『군사과학연구』, 16, 2(2023): 11-18.

저 자 소 개



김건국(E-mail: kgg425@naver.com)
2017 육군사관학교 화학과 학사
2025 국방대학교 국방과학학부 석사
현재 육군 분석평가단 자원분석과 물자분석장교
관심분야 : KCTC 빅데이터분석, 데이터과학



문호석(E-mail: hsmoon0329@gmail.com)
1994 육군사관학교 화학과 학사
2003 고려대학교 전자공학 석사
2006 고려대학교 산업공학 박사
2010 고려대학교 통계학 박사
현재 국방대학교 국방AI/로봇학과 교수
국방대학교 산학협력단장
관심분야 : 데이터과학, 국방 AI, 국방 M&S



김재호(E-mail: firstish@naver.com)
2017 육군사관학교 화학과 학사
현재 국방대학교 국방과학학부 석사과정
관심분야 : KCTC 빅데이터분석, 데이터과학



김동철(E-mail: kdc711@simnet.co.kr)
1995 한남대학교 산업공학과 학사
2006 충남대학교 컴퓨터과학과 석사
현재 육군합성전장훈련체계(Build-I) 개발사업 PM
관심분야 : 국방M&S, LVC훈련체계

한국 해군의 유·무인 복합체계 발전 전략: 주요국 사례 비교 및 정책적 제언

A Study on the Republic of Korea Navy's Strategy for Manned-Unmanned Teaming: Comparative Analysis of Major Military Powers and Policy Recommendations

김태양¹⁾ · 마정목²⁾

Tae-Yang Kim · Jungmok Ma

ABSTRACT

As military technology and security environments rapidly evolve, manned-unmanned teaming (MUM-T) has emerged as a critical element of modern naval capabilities. This study comparatively analyzes the MUM-T strategies of the U.S., U.K., France, and Chinese navies, identifying key success factors such as long-term strategic planning, specialized organizational structures, substantial budget investments, and civil-military technological cooperation. Based on these insights, this paper proposes specific policy recommendations for the Republic of Korea Navy (ROKN): (1) establishing a comprehensive control tower to oversee all phases of MUM-T development; (2) expanding budgets for unmanned systems; (3) enhancing civil-military technological cooperation; (4) increasing practical exercises to validate operational concepts; and (5) strengthening personnel training to build human resource capacities. Through these measures, the study aims to support the ROKN's successful transformation into a "smart navy."

Key Words : MUM-T, ROKN, comparative strategy analysis, naval modernization

논문접수일 : 2025년 5월 9일, 심사일 : 2025년 6월 5일~6월 13일, 게재확정일 : 2025년 6월 13일

1) 국방대학교 무기체계전공 박사과정

2) 국방대학교 무기체계전공 교수 / 교신저자(Corresponding author)

1. 서론

1.1 연구배경 및 필요성

21세기 들어 군사기술의 급속한 발전과 다변화하는 안보 환경 속에서 유·무인 복합체계(Manned-Unmanned Teaming, 이하 MUM-T)는 전 세계 해군력 발전의 핵심 요소로 부상하고 있다. 특히 러시아-우크라이나 전쟁, 미·중 간 패권 경쟁과 같은 전략적 경쟁 환경에서 MUM-T의 중요성은 더욱 부각되고 있으며, 주요 군사 선진국들은 이를 위한 전략 수립과 전력화를 빠르게 추진하고 있다. 한국 해군 역시 제한된 인력과 자원 속에서 효율적 해군력 운용을 위해 SMART Navy 및 Navy Sea GHOST 같은 미래 비전을 수립하며 유·무인 복합 전력 발전 필요성을 명확히 인식하고 있다. 본 연구는 군사 선진국인 미국, 영국, 프랑스, 중국의 해군과 한국 해군의 MUM-T 발전 전략을 비교 분석하여, 한국 해군의 유·무인 복합전력 발전 방향과 정책적 제언을 도출하고자 한다.

1.2 선행연구

해양 MUM-T는 인공지능(AI)·초연결·초지능 기술을 토대로 유인 전력과 무인 전력을 통합 운용해 작전·임무 수행 능력을 극대화 하는 개념이다.[1] 유·무인 체계의 강점을 결합함으로써 작전 효율성과 생존성을 크게 향상시킨다. 초기 무인체계는 주로 비전투 임무에서 제한적으로 활용되었으나 2000년대 이후 군사 기술의 발전으로 전투 임무에 직접 투입 가능한 무기체제로 발전하였다.

MUM-T에 대한 연구는 활발히 이루어지고 있다. 류재학 등(2023)은 미래 해상전 양상을 전망하고 해양 무인체계의 운용개념, 기술확보, 전력화 방안 등 해양무인체계의 발전전략

을 제시하였다.[2] 김수민 등(2022)은 미국의 유령 함대(Ghost Fleet)를 분석하여 한국형 유령함대의 전략적 적용 방안을 논의하였다.[3]

배학영(2022)은 한국의 안보 환경을 반영한 한국형 유령 함대 운용 개념을 제안하며 단계적 발전 로드맵을 제시하였다.[4] 이홍정(2023)은 미국, 중국, 일본, 러시아 등 주변국 해양무인체계 개발과 운용 현황을 분석하여 한국 해군의 발전전략과 운용 준비 필요성을 강조하였다.[5] 또한 정호섭(2019)은 미 해군이 중국의 반접근/지역거부(A2/AD) 위협에 대응하여 분산해양적전(DMO) 개념을 적극 추진중이며, 특히 소형 무인 플랫폼을 분산 배치하여 적의 탐지 및 공격을 복잡하게 하고 플랫폼 간 네트워크를 통해 전투력과 생존성을 극대화 하는 등 유·무인 복합체계를 중심으로 전력을 개편하고 있다고 분석하였다.[6]

이러한 선행연구들은 MUM-T의 효율성과 전략적 필요성을 강조하며 한국 해군이 전략적 환경에 적합한 발전 방안을 수립하는데 유용한 기초 자료를 제공하고 있다. 본 연구는 기존 연구를 토대로 각국의 전략과 주요 활동을 분석하여 한국 해군의 현행 전략을 확인하고 구체적인 발전 방향을 제시한다는 점에서 연구의 차별성을 가진다.

2. 국가별 유무인 복합체계 발전 전략 현황

2.1 미국

미 해군은 2000년대 들어 중국 해군의 급속한 군사력 확장과 접근거부·지역거부(Anti-Access/Area-Denial, A2/AD) 전략의 강화로 인해 기존 항모 강습단 중심의 작전 개념에 취약성이 노출되자 전통적인 전력 구

조에서 벗어나 분산된 형태의 해상작전 운용을 고려하게 되었다. 이러한 배경속에서 2016년 이후 미 해군은 MUM-T를 핵심으로 하는 분산해양작전(Distributed Maritime Operations, 이하 DMO) 개념을 발전시켰다. 이는 유인함정과 무인체계를 네트워크 기반으로 통합하여 공간적으로 분산 배치함으로써 전력의 생존성과 작전 유연성을 동시에 확보하는 것을 목표로 한다.[7]

2020년 발표된 'Battle Force 2045'에서 미 해군은 유인 전투함 355척에 더하여 무인 수상정(Unmanned Surface Vehicle, USV), 무인잠수정(Unmanned Underwater Vehicle, UUV), 무인항공기(Unmanned Aerial Vehicle, UAV) 등 무인체계 140~240척을 추가 도입하여 총 500척 이상의 유무인 혼성함대를 구축하겠다는 명확한 목표를 설정하였다. 이 계획은 고비용의 유인함정을 적정 수준으로 유지하고 비용 효율적인 무인체계를 도입함으로써 전력 투사 능력을 극대화하려는 전략적 의도를 내포하고 있다.[8]

2021년 미 해군성은 'Unmanned Campaign Framework'를 발표하였다. 이 전략은 자율·무인체계를 해군과 해병대 전력의 신뢰할 수 있고 필수적인 요소로 통합하기 위한 전략적 지침으로 유·무인 협동 효과 강화, 디지털 인프라 구축 등 5대 목표를 제시하였다. DMO 수행과 같이 미래 해양 임무에서 치명성, 생존성, 작전속도 및 지속성을 높이기 위해 네트워크 기반의 유무인 복합체계 도입과 기술 혁신을 가속화 하는 내용을 담고 있다.[9]

미 해군은 전략 실행력을 높이기 위해 2015년 해군참모본부(OPNAV) 내에 무인체계 총괄부서(N-99)를 신설하여 각 부서에 분산된 무인사업 관련 예산과 정책을 통합 관리했다.[10] 2021년에는 'Unmanned Task Force(UTF)'와 프로그램 관리 부서인 'PEO Unmanned and Small Combatants'로 기

능을 재편하여 보다 체계적이고 효율적인 조직을 구성하였다.

무인전력의 현장 운용과 시험평가를 담당하는 부대도 확대되었다. 2017년 UUV 전대(UUVRON-1), 2019년 수상개발전대(SURFDEVRON-1)가 창설되어 무인체계의 전술적 운용 실험과 기술적 성숙도를 지속적으로 평가하고 있으며 2021년 바레인에 창설된 Task Force 59는 중동 지역에서의 USV와 UAV, AI 기반 지휘통제 시스템의 상시 실전 운용을 담당하고 있다.[11]

예산 측면에서 미 해군은 무인·자율체계 연구개발(R&D)에 막대한 자금을 투입하고 있다. 2024년 회계연도 예산 요구안에 따르면 국방부는 무인체계 획득 및 개발에 약 110억 달러를 요청했으며 주요 사업으로는 대형 무인 수상정(LUSV), 중형 무인수상정(MUSV), 초대형 무인잠수정(XLUUV, Orca) 개발 등이 포함되어 있다. 이는 미 해군이 무인전력에 대한 예산 지원을 바탕으로 전략 목표를 적극적으로 추진하고 있음을 시사한다.[12]

미 해군은 무인체계의 실효성을 검증하고 교리를 발전시키기 위한 다양한 실전적 훈련을 수행하고 있다. 특히 2022년 실시된 'Digital Horizon 22' 훈련에서 다수의 USV와 UAV가 유기적으로 연계되어 AI 분석을 통해 해상 상황 인지 시간을 획기적으로 단축하는 성과를 보였다. 이를 통해 미 해군은 유·무인체계가 해상에서 작전적 효율성과 정확성을 크게 향상시킬 수 있음을 입증하였다.[13]

태평양 지역에서는 2021년과 2022년 'Unmanned Integrated Battle Problem 21' 훈련 및 림팩(RIMPAC) 훈련을 통해 유인 함정과 무인체계의 합동 작전을 실험하고 전술절차를 지속적으로 개선하였다. 이 과정에서 무인체계 간, 그리고 유인 플랫폼과 무인체계 간의 네트워크 연동, 지휘통제 효율성, 데이터 공유 등 실제 작전에서의 적용 가능성

을 확인하였다.[14, 15]

또한 무인체계 개발과 혁신을 촉진하기 위해 다양한 노력을 하고 있다. 신속 획득 제도를 운영중이며 산학협력 플랫폼을 통해 민간 기술을 군사용으로 신속히 전환하고 있다. 아이디어 공모전, 해커톤 등을 운영하여 민간의 혁신적인 아이디어를 적극 수용하고 있으며 산·학·군 협력체계의 지속적 강화를 통해 기술 혁신 속도를 높이고 있다.[16, 17, 18]

종합적으로 미 해군은 명확한 전략적 목표, 전담 조직 구성, 안정적 예산 지원, 실증 및 훈련, 민·군 협력을 통해 MUM-T를 선도적으로 발전시키고 있으며 향후 해상작전에서 무인 전력의 역할은 지속적으로 확대될 것으로 전망된다.

2.2 영국

영국 해군은 무인체계의 전략적 중요성을 비교적 일찍부터 인식하고 초기부터 국제협력과 개념 정립을 중심으로 발전 기반을 마련하였다. 2005년 국방백서에서 UAV의 군사적 잠재력이 언급되었고[19] 2010년에는 프랑스와 ‘Lancaster House’ 조약을 체결하여 양국 간 국방협력을 확대하고 차세대 해양 무인기뢰대항체계(Maritime Mine Counter Measures, MMCM)의 공동 개발에 착수하였다.[20]

이후 2015년 발표된 ‘Strategic Defence and Security Review 2015’를 통해 자율·무인체계에 대한 연구개발 투자 확대를 명문화하였으며[21] 2018년 국방부는 ‘Joint Concept Note 1/18’을 통해 해상 무인체계의 장기적 역할과 전략적 운용 방안을 논의하였다.[22] 또한 2020년에 발표된 ‘Integrated Operating Concept’을 통해 유·무인체계 간의 통합적 협력을 중심으로 한 다영역 통합을 미래 전력구조의 핵심 개념으로 명시하였

다.[23] 특히 이 문서는 유인·무인·자율 시스템의 융합이 전투력과 운용상의 유연성을 혁신적으로 향상시킬 것이라고 강조하며, 유·무인 체계의 유기적 협력이 미래 군사작전의 새로운 표준으로 자리 잡아야 함을 시사하였다.

조직적 측면에서 영국 해군은 무인체계 기술을 신속히 실험하고 전력화를 가속하기 위해 2019년 혁신 조직 NavyX를 창설하였다. NavyX는 2022년 실험선 ‘XV Patrick Blackett’를 도입해 독립적 실험 플랫폼을 구축하고 무인 함대 운용을 위한 신기술 검증을 수행하고 있다.[24] 이어 2023년에는 NavyX, OCTO(Office of the Chief Technology Officer), Navy AI Cell을 통합한 DCTO(Disruptive Capability Technology Office)를 설립하여 무인기술 혁신의 조직적 기반을 한층 강화하였다.[25]

예산 측면에서는 2024년 ‘Defence Drone Strategy’를 통해 우크라이나 전쟁 교훈을 반영하여 향후 10년간 46억 파운드라는 대규모 예산을 무인체계에 집중 투자하고 조달 절차 혁신과 군수산업 기반 강화를 통해 무인체계를 신속하게 전력화할 계획을 발표하였다.[26]

운영개념 및 실증 훈련 측면에서 영국 해군은 2016년 세계 최초의 대규모 무인체계 실증 훈련인 ‘Unmanned Warrior 2016’을 개최하여 50여 종 이상의 해상·공중·수중 무인체계를 시험하고 작전 가능성을 실제로 검증하였다.[27] 이를 통해 영국 해군은 무인체계가 다양한 해상 작전 임무에서 효과적으로 운용될 수 있음을 입증하였다. 또한, 2021년 발표된 ‘Defence Command Paper(DCP 2021)’에서는 기뢰전 분야에서 프랑스와 공동 개발한 무인체계를 도입하여 기존 유인 소해함을 대체하고 해군을 기술 기반의 디지털·통합 전력으로 전환하겠다는 비전을 구체화하였다.[28] DCP 2023에서도 인공지능(AI) 및 무인 전투체계에 대한 투자를 강조하며 유·

무인 복합 전력구조를 통해 전투력 향상과 미래 전장 대비를 추진하겠다는 정책적 비전을 명확히 밝혔다.[29]

종합적으로 영국 해군은 국가 전략 수립, 전담 조직 운영, 지속적인 예산 투입, 기술 실험 및 실증 훈련등을 통해 MUM-T 발전을 가속화 하고 있으며 미래 전장에서 우위를 점하기 위한 실질적인 전력 배치를 적극적으로 추진하고 있다.

2.3 프랑스

프랑스 해군은 2008년 발간된 국방백서에서 처음으로 감시·정찰·공격 임무에서 무인체계의 중요성을 강조하고 유럽 차원에서의 공동 기술 개발 필요성을 강조하였다.[30] 이후 프랑스 해군은 2018년 중장기적 혁신 비전인 ‘Plan Mercator’을 발표하며 해군 혁신 및 현대화 계획의 일환으로 무인·자율체계 도입을 공식화하였다.[31] 이 계획에서 프랑스 해군은 ‘글로벌 활동 역량 확보’, ‘고강도 전투 대비 태세 유지’, ‘첨단 기술 해군 구현’, ‘인적 자원 최적화’를 4대 전략 목표로 설정하고 2030년까지 드론과 자율체계를 전면 도입하여 전력을 현대화 하겠다는 구체적인 의지를 표명하였다.

2019년 프랑스 해군 참모총장은 2030년까지 해군이 운용하는 드론 수를 약 50대 수준에서 1,200대로 대폭 확대할 계획을 발표하며 UAV 900대, USV 50대, UUV 200대를 확보하여 모든 해군 함정과 해안시설에 최소 1대 이상의 무인체계를 배치하겠다는 구체적인 목표를 설정하였다. 이는 MUM-T가 향후 프랑스 해군 전략의 핵심 요소임을 공식적으로 천명한 것이다.[32]

이후 2021년 기존 ‘Plan Mercator’를 가속화 하기 위한 ‘Mercator Accélération 21’ 전략을 발표하였다. 이 전략은 기존 목표

는 유지하면서 드론 및 AI 무기체계의 전력화를 보다 신속히 추진하는 가속 전략 개념을 담고 있다. 특히 최신판인 ‘Mercator 2023’에서는 우크라이나 전쟁 등 최근의 전훈을 반영하여 무인·자율체계 혁신과 현대화를 더욱 강조하고 있다.[33]

조직적 측면에서 프랑스 해군은 별도의 전담 사령부나 독립된 조직을 신설하는 대신 기존 조직 내에서 전문 기능을 수행하는 방식으로 운용하고 있다. 무인체계의 신속한 전력화를 위해 프랑스 해군은 국방조달청(DGA), 신속획득혁신기구(AID), 민간 방산 기업 및 스타트업과의 긴밀한 협력을 통해 무인체계 혁신을 추진하고 있다. 특히 DGA-AID는 신속한 조달 체계를 구축하였고 프랑스 해군은 2023년부터 PERSEUS 라벨 프로그램을 통해 Naval Group, Thales 등 대형 방산 기업 뿐 아니라 스타트업과 중소기업의 신기술을 빠르게 해군에 적용할 수 있도록 지원하고 있다.[34]

예산 측면에서 프랑스는 2019~2025년 국방계획법(LPM)에 따라 방위비를 증액하여 무인·자율체계 연구개발 분야에 집중 투자하고 있다. 2025년 기준 혁신 기술 분야에 12억유로를 배정하였고 그중 드론 및 로봇분야에 4.5억 유로를 배정했다. 이는 전년 대비 12.5% 증액된 예산이다.[35] 특히 SLAM-F 자율기뢰대항체계와 VSR700 함재 무인헬기 개발, 심해용 자율잠수정(A6K) 등의 개발 프로젝트가 진행 중이며 향후 10년간 지속 가능한 무인 전력 확보를 위한 예산을 지속적으로 확대할 계획이다.[36]

운용 개념 발전 측면에서 프랑스 해군은 기뢰전의 완전 무인화 목표 달성을 위해 무인체계 중심의 전력 운용을 추진하고 있다. SLAM-F 체계를 중심으로 기존 기뢰전 함정을 무인체계로 전환하며 기뢰 탐지와 처리를 무인체계로 수행하는 운용 전환을 추진하고

있다.[37] 또한 유인 전투함정과 무인체계의 통합 운용 발전을 위해 전투함은 중형 무인헬기(VSR700)와 협력하여 정찰 및 표적 범위를 확대하고 잠수함은 초대형무인잠수정(XLUUV)과 협력하여 고위험 정찰 임무를 수행한다는 개념을 구체화 하고 있다.[38, 39] 이러한 유·무인 통합 개념은 'POLARIS 21'과 같은 대규모 훈련을 통해 실제 시험되고 있으며 더욱 고도화된 유·무인 복합 운용 개념을 실증·발전시키고 있다.[40]

종합적으로 프랑스 해군은 전략적 목표 설정, 조직 내 전문 기능 강화, 신속한 조달 및 혁신 협력체계 구축, 예산 확대, 운용 개념 발전 및 훈련을 통해 MUM-T의 실질적인 전력화를 추진하고 있다.

2.4 중국

중국 해군은 군 현대화의 핵심으로 정보화 및 지능화의 융합을 추진하고 있다. 중국 정부는 2049년까지 세계 일류의 군사력을 보유하겠다는 목표를 세우고 이를 달성하기 위한 단계별 로드맵을 제시하였다. 구체적으로 2027년까지 기본적인 기계화와 정보화를 달성하고, 2035년까지는 국방과 군대의 완전한 현대화를 실현하며, 2049년에는 완전한 지능화 군대를 건설한다는 계획을 발표하였다. 특히 2019년 발간된 중국 국방백서는 미래전쟁이 정보화를 넘어 지능화 전쟁(Intelligent warfare)으로 발전할 것이라고 강조하며 인공지능(AI), 빅데이터, 자율 무인체계 등 첨단 기술을 군사 작전에 전면적으로 활용하여 전투 속도와 효율성을 극대화할 것임을 명확히 하였다.[41]

2025년 중국항공우주 연구소(CASI) 'PLA Concepts of UAV Swarms and Manned/Unmanned Teaming' 보고서에 따르면 중국군은 MUM-T와 드론 군집 기술의 융합을 차

세대 핵심 전력 발전 방향으로 규정하고 있다.[42] 해군에서는 USV, UUV, UAV가 통합 운용되는 다층적 전력 구조 구축에 역량을 집중하고 있다. 이러한 전략적 접근은 중국 해군이 '지능화된 전쟁' 실현을 위한 기술 우위를 확보하고 미국 및 서방 국가와 첨단 군사 기술 경쟁에서 선도적 지위를 유지하기 위한 대응으로 평가된다.

조직적 측면에서 중국은 2015년 군 개혁을 통해 전략지원부대(Strategic Support Force, SSF)를 창설하여 사이버, 우주, 전자전 및 정보 능력을 집중 발전시켰다. 이 조직은 유·무인체계 간 데이터 연동 및 실시간 정보 공유를 지원하며 중국군의 정보-네트워크 기반을 제공하였다. 2021년에는 전략지원부대의 정보기능을 정보지원부대(Information Support Force, ISF)로 재편하여 중국군 전체의 지능화 기능을 더욱 강화하였다.[43]

중국은 군민융합(Military Civil Fusion, MCF) 전략을 통해 민간 드론 기업의 상용 기술을 군집 운용 및 대드론 훈련에 투입하고 군용-상용 겸용 부품과 소프트웨어를 신속히 전장에 적용하고 있다.[44] 또한 Baidu와 같은 민간 ICT 기업의 AI 및 클라우드 역량이 중국군의 연구개발 과정에서 활용되면서 군사적 응용 속도를 가속화 하고 있다.[45] 예산 측면에서 중국은 4년 연속 국방 예산 증가율이 7%를 넘으며 2025년에는 350조원을 돌파했다. 이 예산은 해군을 포함한 전군의 현대화 특히 드론·로봇 등 무인 체계 도입과 첨단 무기체계 개발에 집중적으로 투입하고 있다.[46]

운용 개념 발전 측면에서 중국 해군은 무인체계를 대규모로 투입하는 군집(Swarm) 및 모함 운용을 통해 저비용·고효율 전투력을 확보하는데 주력하고 있다. 이 개념에서는 후방의 유인 또는 대형 무인전투함이 지휘·정보융합·재보급을 담당하고 다수의 무인체계가 적

방어망을 분산 교란한뒤 정밀 타격을 수행한다. 또한 유·무인 복합전력 영역에서는 ‘loyal wingman’ 구상을 발전시키고 있으며 유인 항공모함 전단이 스텔스 무인기 편대를 통제하고 호위를 받는 형태가 연구되고 있다. UUV를 활용하여 유인 핵잠수함의 탐지·타격 범위를 확장하는 심해 협동 전술도 핵심 전술로 부각된다.[45, 47]

종합적으로 중국 해군은 명확한 전략적 목표 설정과 조직적 지원 강화, 예산 투입 확대, 운용 개념 발전, 민군 협력 기반의 기술 혁신을 통해 MUM-T를 효과적으로 발전시키고 있으며, 미래 전장에서 우위를 확보하기 위한 실질적인 전력화에 집중하고 있다.

2.5 한국

한국 해군은 급변하는 국제 안보 환경과 주변국들의 군사적 기술 발전에 대응하여 MUM-T 도입을 적극적으로 추진하고 있다. 한국 정부는 ‘국방혁신 4.0’을 통해 첨단 과학 기술 기반의 미래 국방력을 확보하고자 한다. 2018년 발표된 ‘해군비전 2045’에 따르면 한국 해군은 ‘해양강국, 대양해군’ 실현을 통해 2045년까지 세계적 수준의 해군으로 도약한다는 목표를 설정하고 그 핵심 요소를 4차 산업혁명 첨단기술 기반의 스마트 해군(SMART Navy)으로 명시했다. 스마트 해군의 추진 목적은 첫째, 첨단기술 기반 무기체계 첨단화 및 유·무인 복합전력 운용 둘째, 무기체계와 해군력 운용 시스템의 무인화·자동화·지능화를 통한 효율성 향상 셋째, 비용 대비 효과를 고려한 경제적 해군력 운용으로 예산운영의 효율화를 달성하는 것이다. [48]

2022년 한국 해군은 MUM-T 발전 방향을 종합적으로 담은 Navy Sea GHOST 개념을 공식적으로 발표하였다. 이 개념은 유·무인체계가 긴밀히 협력하여 작전의 효율성과 효과

성을 극대화하는 미래형 전력 운용 개념이다. 단계별 목표로는 1단계, 원격통제 중심 무인체계, 2단계 반자율 유·무인체계, 3단계 반자율 확산·자율형 MUM-T 구축을 목표로 하였으며 핵심기술 개발, 운용개념 정립, 해양무인전력 확보 등 단계별 로드맵을 제시하였다.[49]

이후 해양 MUM-T 종합발전계획을 통해 작전수행개념 정립, 단계별 발전 목표 및 로드맵 설정, 단위 전력 확보를 통한 MUM-T 구축계획 등을 수립하였다. 20년대 후반부터 30년대 중반까지 정찰용, 기뢰전, 함탐재 USV 등을 확보하고 정찰용, 전투용 UUV, 함탐재 UAV 등을 확보할 계획이다. 조직 측면에서는 현 조직 내 해양 MUM-T 관련 기능을 통합하고 장기적으로는 해역함대사령부 개편과 연계하여 해양 무인전력사령부를 창설하고 함대사 예하에 무인전투전대를 편성해 유·무인 복합부대 운용을 검토하고 있다.[50]

예산 측면에서 방위사업청은 2024년부터 2028년까지 1,400억원을 투입하여 함정 탐재형 UAV 개발 계획을 발표하였다.[51] 이외에도 약 400억원 규모의 해군 정찰용 USV 개발 계약을 체결하는 등 전력 확보를 위한 예산투자를 강화하고 있다.[52] 한국 해군은 운용 개념 발전 측면에서 무인체계를 단계적으로 검증하고 있다. 2024년 11월 독도함 갑판에서 모하비(STOL) 고정익 무인기가 이륙하여 포항 활주로 착륙 시험에 성공하였으며 [53] 같은 해 실시된 림팩(RIMPAC)에서는 UAV가 해상 가상 표적을 탐지하고 이후 천자봉함에서 발진된 USV가 이를 추적하여 유도 로켓으로 타격하는 고도화된 무인체계 활용 훈련을 진행하였다.[54]

종합적으로 한국 해군은 전략 목표 설정, 전담조직 강화, 예산 투입 확대, 운용개념 발전 등을 통해 MUM-T 발전을 추진하고 있으며 이를 통해 미래 해양작전 환경에서 경쟁력을

〈표 1〉 국가별 활동 비교

국 가	전략·정책 문서	전담 조직	예산 및 혁신·실증 활동
미 국	· Unmanned Campaign Framework · Battle Force 2045	· UTF · SURFDEVRON-1	· (예산) R&D·획득 110억\$(2024) · (혁신·실증) 신속획득제도, “Digital Horizon 22” 등
영 국	· Defence Command Paper(2023) · Defence Drone Strategy	· NavyX, DTCO	· (예산) 무인체계 10년간 46억£ · (혁신·실증) NavyX, “Unmanned Warrior 2016” 등
프랑스	· Plan Mercator · Mercator 2023	· 기존 조직 내 전문 기능 수행	· (예산) 드론·로봇 4.5억€(25년) · (혁신·실증) PERSEUS 라벨 인증을 통한 신속 도입
중 국	· 2019 국방백서 · 2049 현대화 로드맵	· SSF, ISF 등	· (예산) 4년간 연 7% 국방비 증가 · (혁신·실증) 군민융합(MCF), 민간 ICT 역량 활용
한 국	· SMART Navy · 해양 MUM-T 종합 발전계획서	· 조직 신설 필요	· (예산) 함타재 USV 1,400억 등 · (혁신·실증) 독도함 모하비 훈련, 림팩 USV 실증 등

확보하고자 노력하고 있다. 국가별 MUM-T 발전 현황을 전략·정책 문서, 전담 조직, 예산 및 혁신·실증 활동으로 구분하여 〈표 1〉과 같이 정리하였다. 다음 장에서는 이를 바탕으로 각국의 사례에서 공통적으로 도출된 핵심 요소들을 종합적으로 분석하여 한국 해군의 MUM-T 발전 전략 수립을 위한 시사점을 도출하고자 한다.

3. 유·무인 복합체계 전략 종합분석

주요 군사 강국들의 MUM-T 발전 사례를 분석한 결과 각국은 다음과 같은 공통된 핵심 요소들을 중심으로 MUM-T 발전을 추진하고 있음을 확인할 수 있었다.

첫째, 명확한 전략적 목표를 설정하고 이를 구체적인 계획으로 명문화 하였다. 미국은

‘Unmanned Campaign Framework’를 통해 무인체계의 중요성과 전략적 목표를 명확히 제시하고 있으며, 영국 역시 ‘Defence Command Paper’와 ‘Defence Drone Strategy’에서 장기적인 계획과 무인체계 전력화를 위한 구체적 로드맵을 제시하였다. 프랑스는 ‘Plan Mercator’를 통해 해군 현대화 과정에서 무인체계의 역할을 규정하고 단계적 계획을 수립하였으며, 중국은 국가 차원의 군 현대화 로드맵을 통해 MUM-T 등 군사력 발전 방향을 설정하였다. 한국 또한 SMART Navy와 Navy Sea GHOST, 해양 MUM-T 종합발전계획서를 통해 명확한 전략적 목표를 수립하고 있다.

둘째, 전략의 효과적인 추진을 위한 조직적 지원체계를 구축하고 있다. 미국은 OPNAV N-99, UTF 및 PEO Unmanned를 신설하여 체계적이고 전문적인 무인전력 관리를 추진하

고 있으며, 영국은 NavyX와 DCTO를 통해 기술혁신 및 신속한 전력화를 전담하고 있다. 프랑스는 기존 조직 내 전문기능을 강화하여 대응하고 있으며, 중국은 SSF와 ISF를 통해 정보와 네트워크 기반을 구축하여 유·무인 협력을 강화하고 있다. 한국 해군은 장기적으로 해양 무인전력사령부 및 무인전투전대 설립을 계획하고 있으나, 현재로서는 무인전력의 운용·교육·정비·전비태세 유지를 총괄적으로 관리할 수 있는 전담 조직의 창설이 요구된다.

셋째, 무인체계 도입 및 발전을 위한 예산 투자를 확대하고 있다. 특히 미국과 영국은 수십억달러 규모의 예산을 집중적으로 투입하며 무인체계 연구개발과 혁신을 적극적으로 지원하고 있다. 중국 또한 국방 예산의 상당 부분을 무인체계 관련 분야에 집중적으로 투자하고 있다. 한국 역시 최근 예산을 점차 확대하고 있으나 주요 군사 강국과 비교하면 상대적으로 투입 규모가 아직 부족하며 향후 보다 적극적이고 지속적인 예산 증액이 필요하다.

넷째, 민군 협력을 통해 기술 혁신과 무인체계의 신속한 전력화를 추진하고 있다. 미국은 신속 획득 제도와 산학협력 플랫폼을 활용하여 민간의 혁신적 아이디어와 기술을 적극적으로 군사분야에 적용하고 있으며, 영국 역시 NavyX와 DCTO를 중심으로 민간과의 기술협력을 강화하고 있다. 프랑스는 신속한 조달체계 구축 및 PERSEUS 라벨 프로그램을 통해 중소기업과 스타트업의 신기술 도입을 촉진하고 있으며, 중국은 군민융합(MCF) 전략을 통해 민간 ICT 기업의 역량을 군사 분야에 적극적으로 활용하고 있다. 한국도 산학연 협력을 통해 혁신 생태계를 구축하고 있으나 보다 실질적이고 제도적인 민군 협력 프로그램의 확대가 요구된다.

4. 결론 및 정책제언

본 연구는 앞서 제시한 국가별 사례의 분석을 통해 주요 군사 강국들이 공통적으로 갖추고 있는 전략, 전담 조직 체계, 예산, 혁신 및 실증 활동 등 핵심 요소를 확인하였으며 이를 한국 해군의 MUM-T 발전을 위한 전략적 방향 설정에 활용하고자 한다. 주요국 해군은 장기적인 전략적 비전을 공식 문서로 명확히 제시하고 있으며 전담 조직을 구성하여 기획·획득·운용·평가 기능을 체계적으로 관리하고 있었다. 또한 대규모 예산을 안정적으로 투입하여 연구개발(R&D)과 실증 활동을 적극적으로 뒷받침하며 산·학·군 협력 체계를 제도화하여 민간의 혁신 기술을 신속히 군사분야에 이전하고 운용 개념을 지속적으로 발전시키고 있는 것으로 나타났다.

이러한 종합 분석 결과에 비추어 볼 때 한국 해군 또한 ‘SMART Navy’, ‘Navy Sea GHOST’, ‘해양 유·무인 복합체계 종합발전 계획서’ 등을 통해 MUM-T의 중요성을 인식하고 관련 정책을 추진하고 있지만 주요국들과의 격차를 줄이기 위해서는 보다 실질적인 노력이 필요하다는 것이 본 연구자의 견해이다. 특히 전담 조직의 권한과 역할 구체화, 예산의 안정적 확대, 운용 개념 정립을 위한 실증 훈련의 강화, 민군 협력 모델의 실질적 제도화 측면에서 발전이 필요하다고 판단된다. 따라서 한국 해군의 MUM-T 발전을 위해 다음과 같은 정책을 제언하고자 한다.

첫째, MUM-T의 기획·획득·운용·전력화 전 과정을 총괄할 컨트롤타워의 구축이 시급하다. 중장기적으로 계획중인 해양 무인전력사령부 창설 이전에 업무를 총괄하는 조직과 무인체계 시험·평가 전담부대를 우선 설립하여 현 작전 환경에서 체계적으로 검증할 수 있는 기반을 마련해야 한다.

둘째, 무인체계 예산 비중을 점진적으로 확대하여 안정적인 재정 기반을 조속히 마련해야 한다. 이를 통해 기술 연구개발을 가속화하고 실전 배치까지의 기간을 단축할 수 있도록 구체적인 예산 편성을 추진할 필요가 있다.

셋째, 민·군 기술협력을 강화해야 한다. 현재 방위사업청이 운영하는 신속 소요·시범사업 제도와 함께 공모전, 기술경진대회 등을 활성화해 민간이 보유한 혁신 기술을 군사 분야로 적극 도입해야 한다.

넷째, 국내·외 실증훈련과 다국적 연합훈련 참여를 확대하여 무인체계 운용 교리 및 전술을 검증하고 발전시켜야 한다. 특히 연합·합동 훈련시 미래 해상전에서 예상되는 다양한 MUM-T 운용 시나리오를 적극 반영하여 유·무인간 상호 운용성을 확보하고 작전 활용성을 극대화 해야 한다. 이를 위해 지속적인 시나리오 연구와 함께 모델링 및 시뮬레이션(M&S)를 활용한 사전 검증을 병행하고 실제 해상 전투실험을 통한 검증을 체계적으로 실시하여 실전성을 높이는 한편 관련 분야에 대한 R&D 투자도 지속적으로 추진할 필요가 있다.

다섯째, MUM-T 운용을 위한 인적 역량을 강화해야 한다. 전문 인력을 확보하고 현장지휘관 대상 교육 프로그램을 운영하여 유인 플랫폼 지휘관의 무인체계에 대한 이해도를 높여 유·무인 복합 운용시 효과적인 협력이 이루어질 수 있도록 해야한다.

종합적으로 한국 해군은 MUM-T의 효과적인 발전을 위해 조직·예산·민군협력·훈련·인력 등 다섯가지 분야에서 체계적이고 지속적인 정책적 노력이 병행되어야 한다. 이러한 노력이 구체적 로드맵과 제도적 기반 위에서 실행될 때 한국 해군은 스마트 해군으로의 전환을 가속화 하고 미래 해양 전장에서 지속 가능한 전력적 우위를 확보할 수 있을 것이다.

참 고 문 헌

- [1] 안상겸, 박동선, “해양 유·무인 복합전투체계 자율화 수준 연구”, 해군과학기술학회지, 2023
- [2] 류재학, 허지용, 나운후, “미래 해양전 활용을 위한 해양무인체계 발전전략에 관한 연구”, 해군과학기술학회지, 2023
- [3] 김수민, 김경수, “해양무인체계의 군사적 활용방안과 한국형 유령함대 건설을 위한 과제, 국방과학기술, 2023
- [4] 배학영, “한국형 유령함대(무인원격함대) 운용 개념 및 전력 발전방향”, 한국방위산업학회지, 2022
- [5] 이흥정, 김필현, 임경한, “주변국 해양무인체계(UMVs) 개발 동향과 한국 해군에 주는 함의”, 해군과학기술학회지, 2023
- [6] 정호섭, “4차 산업혁명 기술을 지향하는 미 해군의 분산해양작전”, 국방정책연구, 2019
- [7] Kevin Eyer, Steve McJessy, Operationalizing Distributed Maritime Operations, CIMSEC, 2019
- [8] Mark F. Cancian, Adam Saxton, Secretary Esper Previews the Future Navy, CSIS, 2020
- [9] Department Of The Navy. Unmanned Campaign Framework, p. 6. 2021
- [10] Department of the Navy. OPNAV Realignment: Establishment of the Unmanned Warfare Systems (N99). 2015
- [11] America’s Navy. Task Force 59 Launches New Unmanned Task Group 59.1, 2024
- [12] AUVSI. Department of Defense Uncrewed Systems Budget Report FY 2024 Written Report. 2024
- [13] George Galdorisi. Exercise Digital Horizon: Accelerating the Development of Unmanned Surface Vehicles. CIMSEC, 2023
- [14] Jackson Barnett. Navy conducting major exercise in Pacific with unmanned systems, FEDSCOOP. 2021
- [15] Seapowermagazine. Four Unmanned Surface Vessels Being Demonstrated in RIMPAC, 2022

- [16] USNI News. Navy Accelerating Work on 'Snakehead' Large Displacement Unmanned Underwater Vehicle, 2017
- [17] Duids. DoD, Industry and University UxS Experts Convene at Navy Technical Exchange, 2017
- [18] Defencescoop. Navy moves to upsurge innovation challenges, hackathons, 2024
- [19] Ministry of Defence. Defence Industrial Strategy: Defence White Paper. 2005.
- [20] OCCAR. MMCM - Maritime Mine Counter Measures Programme.
- [21] HM Government. Strategic Defence and Security Review(SDSR). 2015
- [22] Ministry of Defence. Human-Machine Teaming (JCN 1/18). 2018
- [23] Ministry of Defence. Integrated Operating Concept 2020.
- [24] Royal Institution of Naval Architects. Royal Navy receives new trials and autonomy development ship. 2022
- [25] NavyLookout. Royal Navy establishes new Disruptive Capabilities and Technologies Office. 2025
- [26] Ministry of Defence. New UK strategy to deliver drones to armed forces. 2024
- [27] USNI News. Unmanned Warrior 2016 Exercise In U.K. Puts Emerging Technology In Warfighters' Hands. 2016
- [28] UK parliament. Defence Command Paper 2021:Summart. 2021
- [29] Ministry of Defence. Defence Command Paper 2023. 2023
- [30] Ministère de la Défense, White Paper on Defence and National Security. 2008
- [31] Cols Bleus. Plan Mercator: Le plan stratégique de la Marine. 2018
- [32] NavalNews. French Navy Aiming for 1200 Unmanned Systems by 2030. 2019
- [33] Ministère des Armées. MERCATOR 2023: Recalage de la navigation. Paris: Marine Nationale, 2023.
- [34] Ministère des Armées. La Marine nationale et la DGA attribuent le label PERSEUS à trois projets innovants. Communiqué de presse, 4 juillet 2023.
- [35] G.A.C. Defense financing opportunities: what levers can strengthen European sovereignty?. 2025
- [36] NavalNews. French Navy tests SLAM-F mine warfare unmanned system off Brest. 2022
- [37] Marine nationale. Plan Mercator. 2019
- [38] Armyrecognition. French Navy's VSR 700 Unmanned Aircraft System successfully completes trials aboard FREMM frigate Provence. 2023
- [39] Armyrecognition. Naval Group to develop Extra large UUV XLUUV for French Navy. 2024
- [40] NavalNews. Feedback on French Navy High Intensity Exercise POLARIS. 2022
- [41] State Council Information Office of the People's Republic of China. China's National Defense in the New Era. Beijing: Foreign Languages Press, 2019.
- [42] CASI. PLA Concepts of UAV Swarms and Manned-Unmanned Teaming, 2025.
- [43] Meia Nouwens. China's new Information Support Force. IISS. 2024
- [44] Matthew Kroenig, Imran Bayoumi. A global strategy to secure UAS supply chains. atlanticcouncil Issue Brief. 2024
- [45] Stephen Chen. China's military lab AI connects to commercial large language models for the first time to learn more about humans. SCMP. 2024
- [46] 연합뉴스, 중국방비, 350조원 첫 돌파...신무기·무인시스템 도입에 속도. 2025
- [47] Kevin Pollpeter, Ryan Loomis, China AI & Autonomy Report, Issue 18, CNA, 2022
- [48] 박동선. 4차 산업혁명 첨단기술 기반의 'SMART Navy' 대항해 계획. 대한조선학회. 2020

- [49] 대한민국해군, 해양 유·무인 복합 전투체계 (Navy Sea GHOST) 소개자료
- [50] 대한민국해군, 해양 유·무인 복합체계 종합발전 계획서(공개본). 2022
- [51] NavalNews, South Korea launches development of ship-based UAV. 2024
- [52] NavalNews, LIG Nex1 to Develop ROK Navy's Reconnaissance USV. 2024
- [53] NavalNews, ROK Navy tests Mojave drone aboard ROKS Dokdo. 2024
- [54] U.S. Pacific Fleet, US, ROK test unmanned vehicles in live fire exercise during RIMPAC 2024. 2024

저자 소개



김태양(E-mail: navykty0308@gmail.com)
현재 국방대학교 무기체계 박사과정
관심분야 : 유·무인 복합체계, 시뮬레이션



마정목(E-mail: jxm1023@gmail.com)
2002 육군사관학교 운영분석과 졸업(학사)
2008 미 펜실베이니아주립대 산업공학과 졸업(석사)
2015 미 일리노이대 산업공학과 졸업(박사)
현재 국방대학교 국방과학학과 교수
관심분야 : 국방 모델링, 데이터 애널리틱스

AI 생성 화합물 및 전구체 시너지 분석을 통한 이중용도 평가

Dual-Use Assessment through AI-Generated Compounds and Precursor Synergy Analysis

이춘주¹⁾

Choonjoo Lee

ABSTRACT

The emergence of AI-driven molecular design tools has enabled the de novo generation of novel compounds with specific biochemical properties. This study illustrates a reinforcement learning (RL)-based framework for designing potential nerve agents and integrates a toxicity prediction model to evaluate their hazard levels. By combining a SMILES-generative RNN with a custom reward function incorporating physicochemical constraints and toxicity scores, this study generates new chemical structures that exhibit high potential toxicity. A Random Forest-based QSAR model is employed to predict toxicity using molecular descriptors. Additionally, this paper introduces a precursor decomposition module to assess whether low-toxicity precursors can synergistically generate high-toxicity compounds. The results demonstrate the feasibility of proposing novel candidate agents, predicting their toxicities with high confidence, and identifying precursor pairs that contribute to emergent toxicity. This work offers implications for chemical weapons monitoring and the regulation of dual-use AI technologies.

Key Words : reinforcement learning, de novo molecular design, nerve agents, toxicity prediction, precursor synergy, dual-use AI

1. 서론

화학전은 신경작용제와 같은 치명적인 물질에 대한 이해, 탐지 및 대응 방식을 지속적으로 새롭게 시도하면서 발전해왔다. VX, 사린(Sarin), 노비촉(Novichok) 계열과 같은 이러한 화합물들은 아세틸콜린에스터라제(acetylcholinesterase)를 비가역적으로 억제함으로써 치명적인 콜린성 과자극(cholinergic overstimulation)을 유발한다²⁾. 이러한 작용제의 설계와 분석은 전통적으로 실험 화학, 전문가의 판단, 독성 실험에 의존해 왔으며, 이는 많은 자원을 필요로 할 뿐 아니라 윤리적·안전적 위험이 크다.[1-8]

그러나 생명과학 분야에서 인공지능이 등장하면서 분자 설계의 패러다임은 급격히 변화하고 있다. 최근에는 딥 러닝 기반 생성 모델을 통해 생리활성 분자를 de novo 방식³⁾으로 합성할 수 있게 되었으며, 방대한 화학 공간을 통제된 방식으로 탐색할 수 있다. 특히 강화학습(RL: Reinforcement Learning)은 피드백 기반 학습을 통해 원하는 특성에 최적화된 분자 구조를 생성하는 데 있어 유망한 성과를 보여주고 있다. 그러나 이러한 기술 대부분은 약물 발견과 의약화학 분야에 집중되어 있으며, 신경작용제와 같이 군사적으로 민감한 화합물의 설계 및 평가에 RL 기반 시스템을 적용한 연구가 공개된 것은 많지 않다. 이는 국가 안보와 이중용도 기술(dual-use technology) 관리 측면에서 중요한 문제이기 때문이다.[9-20]

동시에, 정량적 구조-활성 관계(QSAR: Quantitative Structure-Activity Relationship)

모델의 발전은 분자의 구조적 특성을 기반으로 독성을 정밀하게 예측하는 것을 가능하게 하고 있다. 생성 모델과 이러한 예측 기술이 결합될 경우, 합성 이전 단계에서 신물질의 위해성을 사전에 평가할 가능성이 열리게 된다. [13-19]

본 연구는 (1) 강화학습 기반 분자 생성기와 (2) 기계학습 기반 독성 예측기 및 전구체 시너지 분석기를 통합한 이중용도 식별 프레임워크를 재현하였다. 특히, 독성이 낮은 화합물이라 하더라도 결합 시 위험 물질로 전환될 수 있는 화학적 전구체 조합을 식별하는 분석 메커니즘에 집중하였다. 이 프레임워크는 AI 기반 화학 설계 시대에 화학 위험이 어떻게 등장할 수 있는지를 이해하는 데 도움이 되고, 선제적 규제 전략의 토대를 제공할 것으로 기대된다.

2. 문헌 연구

2.1 AI 기반 분자 생성

딥러닝의 최근 발전은 원하는 특성을 가진 새로운 분자 구조를 설계할 수 있는 다양한 생성 모델의 등장을 이끌었다. 그중 대표적인 프레임워크로는 REINVENT, MolDQN, GENTRL이 있으며, 이들은 각각 고유한 방식으로 화학 공간을 탐색한다.

REINVENT은 SMILES 문자열을 학습한 순환신경망(RNN)을 기반으로 하며, 정책 경사 기반 강화학습을 통해 미세조정된다. 사용자 정의 보상 함수를 적용하여, 생성되는 분자가 결합 친화력, 독성 등 특정 목표를 향해 최적

2) 아세틸콜린에스터라제가 억제되면, 신경전달물질인 아세틸콜린(ACh)이 축적되어 니코틴 및 무스카린 수용체가 과도하게 활성화하여 근육 연축, 분비물 증가, 호흡 곤란 등 치명적인 콜린성 증상을 유발함.

3) De novo 방식은 라틴어로 "from the beginning(처음부터)"를 의미하며, 기존 데이터나 구조를 참조하지 않고 완전히 처음부터 새로운 것을 생성하거나 설계하는 방법을 말함.

[표 1] 주요 강화학습 기반 모델 비교

모델명	구조 / 형식	학습 방식	출력 형식	주요 특징	대표 응용 분야
REINVENT	SMILES RNN	Policy Gradient (RL)	SMILES	간단하고 확장성 높음, 다양한 reward 설정 가능	약물 설계, 독성 최적화
MolDQN	분자 그래프 (DQN 기반)	Deep Q-Network (RL)	Graph	단계별 편집 방식, 명확한 구조 제어	국소 최적화, 구조 미세조정
GENTRL	VAE (Latent Space)	Variational Inference	SMILES	속성 조건 기반 샘플링 가능, latent space 연산 가능	조건부 생성, 속성 보간

화되도록 유도한다. 구조가 단순하고 확장성이 뛰어나며, 기본 성능이 우수하여 약물 발견 및 특성 기반 분자 설계 모두에서 널리 사용되고 있다.[9]

MolDQN은 더 세밀한 접근을 취하며, 마르코프 결정 과정과 딥 Q-러닝을 활용해 분자를 직접 수정하는 방식이다. 이 모델은 분자 최적화를 단계별 편집 문제로 다루며, 원자나 결합을 추가, 제거, 변경하는 방식으로 구조-기능 간의 국지적 관계를 탐색한다. REINVENT와 달리 SMILES가 아닌 분자 그래프(molecular graph) 공간에서 작동하므로, 구조적 해석력이 더 우수하다.[18]

GENTRL은 VAE를 기반으로 하며, 분자 특성을 연속적인 잠재 공간에 인코딩할 수 있다. 이 모델은 조건부 샘플링을 통해 원하는 특성을 가진 분자를 생성하며, 잠재 공간 상에서 화학 구조 간의 부드러운 보간이 가능하다.[19]

이 세 가지 모델은 각각 탐색력, 제어력, 구조적 충실도 간의 상이한 균형을 보여준다. [표 1]은 강화학습 기반 모델을 비교해서 설명하고 있다.

본 연구에서는 SMILES 기반 강화학습과 독성 기반 보상 함수의 통합에 적합한 REINVENT 계열의 RNN 기반 접근법을 채택하였다. 이 방식은 구현이 용이하고, 생성된 분자에 대한 성능 평가 및 보상 설계가 직관

적이며, 전체 파이프라인과의 통합에 유리하다.

2.2 독성 예측 모델

계산 독성학 분야는 분자의 구조 정보를 기반으로 독성을 예측하는 머신러닝 모델의 발전에 크게 힘입어 왔다. [표 2]는 독성 예측 모델을 비교 설명하고 있다. 대표적인 접근법으로는 ProTox-II, DeepTox, 그리고 Multitask Neural Networks (MTNNs)가 있다.

ProTox-II는 LD₅₀(급성독성), 간독성, 발암성, 세포독성 등 다양한 독성 지표를 예측하는 웹 기반 공개 플랫폼이다. 이 시스템은 큐레이션된 독성 데이터베이스를 기반으로 훈련된 앙상블 분류 모델을 활용하며, 분자 지문, 독성포어(toxicophore), 유사도 지표 등을 입력으로 사용한다. 비전문가도 쉽게 접근할 수 있고 다양한 지표를 다룰 수 있다는 점이 강점이다. 다만, 내부 동작이 블랙박스이며, 생성 모델과의 통합에는 적합하지 않다는 단점이 있다. [20]

DeepTox는 Tox21 챌린지를 통해 개발된 모델로, 초기 딥러닝을 활용하여 기존 QSAR 방식을 능가한 사례 중 하나이다.[21] 분자를 기술한 내용과 지문을 입력으로 받아, 피드 포워드 신경망을 통해 독성 여부를 이진 분류한다. 데이터와 피처 엔지니어링이 충분할 경우,

[표 2] 독성 예측 모델

모델명	입력 형식	예측 방식	출력 항목	장점	한계점
ProTox-II	SMILES, Fingerprints	Ensemble classifiers	LD ₅₀ , hepatotoxicity, mutagenicity 등	사용 용이, 다양한 독성 지표, 웹 기반 인터페이스	해석력 낮음, 생성 모델 연동 어려움
DeepTox	Molecular descriptors, fingerprints	Deep Neural Network	Binary toxicity classification	높은 예측 정확도, Tox21 챌린지 우승 모델	단일 task, 다수 지표 병렬 예측 어려움
Multitask NN	Fingerprints, Graph features	Shared-layer Deep NN	다중 독성 예측 (e.g., LD ₅₀ , AMES)	여러 지표 동시 학습 가능, 전이학습 효과 우수	학습 복잡도 높음, 대규모 데이터 필요
Random Forest QSAR (본 연구)	RDKit descriptors (MolWt, TPSA 등)	Tree-based Regression	연속 독성 점수 (0~10 scale)	높은 해석 가능성, 경량 학습, reward와 연동 용이	다중 지표 확장은 별도 설계 필요

딥러닝이 구조-독성 관계를 효과적으로 학습할 수 있음을 보여준 대표 사례다. 그러나 단일 예측 지표에 집중되어 있어, 다중 독성 지표를 동시에 다루기는 어렵다.

MTNNs는 여러 독성 지표에 대해 하나의 모델을 동시 학습함으로써 독성 경로 간의 공통 구조적 특성을 포착할 수 있다. 학습 데이터가 제한된 경우에도 전이학습 효과로 성능이 향상되며, 공통 독성 구조 기반의 일반화 능력이 뛰어나다. 그러나 학습 복잡도가 높고, 대규모 라벨링 데이터가 필요하다.[22]

본 연구에서는 구조적 해석 가능성이 높고 보상 함수와의 연동이 용이한 랜덤 포레스트 기반 QSAR 회귀 모델을 사용하였다. 이는 RDKit 기반 분자 지표(MolWt, TPSA 등)를 활용하며, 0~10의 연속적인 독성 점수를 예측한다.

2.3 AI 기반 분자 설계 문헌

화학·생물학작용제에 대한 이전 연구들은 VAE 및 RNN과 같은 딥러닝 생성 모델을 활용하여 약물 유사 분자를 합성하는 방법이 중요하다.[20],[22-23] 강화학습 기반의 접근법인 REINVENT와 MolDQN은 이러한 모델에 특성 인식형 보상을 도입하여 기능을 확장하였다.[24-25] 한편, QSAR(정량적 구조-활성 관계) 기반의 독성 예측 모델은 트리 기반 알고리즘(예: 랜덤 포레스트) 또는 딥러닝을 활용하여 높은 예측 성능을 보여주고 있다.[15],[24-26] 이러한 접근법들이 군사적으로 민감하거나 이중용도 화학물질과 교차하는 부분을 다룬 연구는 많지 않으나 인공지능의 응용연구와 함께 최근 활발해지고 있다.[11],[27-30]

[표 3] AI를 활용한 화학전작용제 분야 연구

연구 방향	AI의 역할	주 초점	한계 및 특징
해독제 설계	AChE 결합 모델링, 약물 유사체 생성	생명 구조 보호	윤리적 합법성 확보됨
독성 예측	QSAR, graph-based DNN	규제, 대응 평가	무기 설계와 직접 연결되지 않음
이중 용도 위험 시뮬레이션	Generative AI의 위험성 검토	AI 정책, 감시 경고	실질적 제약 없으면 무기화 가능성 있음

AI와 분자 설계의 융합은 주로 약물 발견의 맥락에서 활발히 탐구됐지만, 일부 주요 연구들은 이를 보다 광범위한 화학 설계 문제에 적용할 수 있는 기반을 마련하였다. [10-11], [31-34] [표 3]은 주요한 AI기반 분자 설계 연구를 보여준다.

예를 들어, Olivecrona et al. (2017)은 SMILES 기반 RNN에 특성 정보가 반영된 보상 함수를 적용한 딥 강화학습 모델을 통해 약물 유사성을 최적화하는 분자 생성 방식을 제안하였다.[35] 이어서 Popova et al. (2018)은 이 프레임워크를 확장하여 여러 특성을 동시에 최적화하는 화합물을 합성하고, 이를 통해 de novo 약물 설계 파이프라인의 효율성을 크게 개선하였다.[10] 그러나 이러한 방법들은 여전히 대부분 치료용 화합물질 영역에 국한되어 있으며, 해당 AI 도구의 이중용도 가능성에 대해서 관심을 가질 필요가 있다.

독성 예측 분야에서는 Tox21, ChEMBL과 같은 대규모 데이터셋을 기반으로 학습된 QSAR 모델이 높은 예측 정확도를 기록하고 있으며, 특히 랜덤 포레스트나 DNN과 같은 알고리즘을 활용한 경우 성능이 우수하다. 또한, ProTox-II와 같은 웹 기반 플랫폼은 SMILES 문자열로부터 다양한 독성 지표를 예측하는 기능을 제공하고 있다.[24], [36-38]

그러나 최근에 이르기까지도 분자 생성과 독성 예측을 하나의 통합된 파이프라인으로 결합하려는 시도는 드물다. 기존 연구들은 주로 안전하고 효과적인 약물의 발견에 초점을 맞추고 있으며, 위해하거나 무기화 가능한 물질의 탐지 또는 저감에는 관심을 두지 않았다. 특히, 저독성 전구체들이 결합되어 고독성 물질로 전환되는 ‘시너지 효과’나 전구체 독성에 대한 명시적인 분석을 수행한 모델은 다수 확인되지만 분자 생성과 독성 예측을 통합적으로 고려하지는 않았다.[39-41]

본 연구는 기존 분자 설계 연구에서 이중용

도 위험 공간에 특화된 문제를 다루었다. 구체적으로, 강화학습 기반 분자 생성기, QSAR 기반 독성 예측 모델, 그리고 전구체 시너지 분석 모듈을 결합한 통합 프레임워크를 통해, 개별 기술 요소의 단점을 보완하고 상호보완적 기능을 재현하였다.

기존 관련 연구들과의 비교는 다음과 같다.

딥 생성 모델 (예: VAE, RNN)은 주로 약물 유사성을 기준으로 신규 분자를 생성하는데 활용되어 왔으며, REINVENT 및 MolDQN과 같은 강화학습 기반 기법은 보상 함수에 기반한 특성 최적화에 중점을 두었다.

QSAR 모델은 트리 기반 알고리즘 및 딥러닝을 활용하여 화합물질의 독성을 예측하는데 높은 정확도를 보여주었다.

본 연구는 위의 세 기술 요소를 단일 프레임워크 내에서 통합하고, 특히 저독성 전구체 조합을 통한 고독성 물질의 출현 가능성까지 평가할 수 있는 전구체 시너지 탐지 메커니즘을 포함하였다.

이전의 분자 생성 모델링 연구들은 대부분 치료적으로 유익한 화합물의 설계를 목표로 해왔으나, 본 연구는 잠재적으로 위해한 화합물질의 식별과 시뮬레이션을 명시적으로 지향한다. 예를 들어 REINVENT나 DeepTox와 같은 기존 모델들이 약물 유사성, 안전성, 치료 효과성을 우선시한 것과 달리, 본 연구는 강화학습 기반 모델이 고독성 화합물을 생성할 수 있는 능력과 전구체 수준의 위험성까지 평가할 수 있는 가능성을 탐색하고 재현한다.

구체적으로, 본 연구는 다음과 같은 구성요소를 통합한 이중 프레임워크에 중점을 두었다.

- 고위험 독성 프로파일을 목표로 하는 de novo 분자 생성기: 약물 유사성보다 독성 잠재력을 우선시하는 보상 함수에 의해 유도됨
- 무기화 가능한 화합물에 특화된 독성 예측

모델: 선별된 화학전 데이터와 정규화된 독성 지표를 기반으로 훈련됨

- 전구체 시너지 탐지 모듈: 개별적으로는 낮거나 중간 수준의 독성을 가진 화합물들이 조합될 경우 비례를 초과하는 독성을 유발하는 조합을 식별

본 프레임워크를 이중용도 맥락에서 명시적으로 정의함으로써, 우리는 기술적 혁신뿐 아니라 화학 분야에서의 정책, 규제, 윤리적 AI 운용의 중요성도 함께 강조하고자 한다.

[표 4]는 화학전 작용제의 맥락에서 AI의 활용에 관한 연구 방향을 설명하고 있다.

대표적인 예로, 아세틸콜린에스터라제 (AChE) 재활성화제를 최적화하는 데 AI 모델이 활용되고 있다. 이는 유기인계 신경작용제가 억제한 효소를 다시 활성화시키는 분자로, deep docking, 약리포어 모델링 (pharmacophore modeling), QSAR 기반 스크리닝 등의 기법을 통해 높은 결합 친화도, 혈뇌장벽(BBB) 투과성, 효소 재활성화 능력을 가진 후보 물질을 선별한다. 이 과정에서 서포트 벡터 머신(SVM), 랜덤 포레스트, 딥 뉴럴 네트워크(DNN) 등의 머신러닝 기법이 효과적으로 통합되고 있다. [42-45]

또 다른 핵심 연구 분야는 예측 독성학이다. Tox21, DSSTox, ProTox-II와 같은 대

규모 데이터셋을 기반으로 신경독성, 간독성, 발암성 등을 예측할 수 있는 견고한 머신러닝 모델이 개발되었다. 이러한 모델은 기존 화학 라이브러리나 환경 오염물질을 선별하는 데 사용되며, 공중보건과 안전 향상에 기여하는 목적이 강하다. 다시 말해, 공격 목적보다는 방어적·위험 평가 중심의 응용이 목적이다.[25], [36], [46]

그러나 최근 들어 범용 분자 생성 도구의 비의도적 오용 가능성에 대한 우려가 커지고 있다. Urbina et al. (2022)의 연구는 이를 단적으로 보여준다.[11] 이 연구에서는 원래 약물 발견을 위한 강화학습 기반 분자 생성기를 사용해, VX 유사체를 포함한 4만여 개의 잠재적으로 치명적인 화합물을 단 몇 시간 만에 생성하는 것이 가능함을 입증하였다. 실험은 윤리적 가이드라인 하에서 안전하게 진행되었지만, 이 결과는 생성형 AI의 이중용도 위험성을 명확히 드러내며, 기술 거버넌스와 규제 필요성에 대한 경각심을 불러일으켰다.

이와같이, 현재까지 AI가 화학무기 개발을 목적으로 의도적으로 사용된 사례는 알려져 있지 않다. 대부분의 활용연구는 방어적 목적 또는 위험 평가를 위한 것이다. 그러나 AI 모델이 의도치 않게 유해 화합물을 생성할 수 있는 잠재력은 분명 존재하며, 이는 향후 분

[표 4] 시 기반 분자 설계 연구

연구	초점	방법론	한계
Olivecrona et al. (2017)	약물 유사성 최적화	RNN + RL	독성 통합 미고려
Popova et al. (2018)	다중목적 약물 생성	Graph-based RL	전구체 모델링 미고려
Wu et al. (2018)	분자 속성 예측	Benchmarking on MoleculeNet	생성 능력 미고려
ProTox-II	웹 기반 독성 예측	QSAR via DNN/ensemble	Standalone predictor only
본 연구	신경작용제 생성 및 독성 평가	RNN + RL + RF + 전구체 평가	이중사용 위험 & 시너지 모델링

자 설계 플랫폼에 내재된 안전장치와 윤리적·법적 규제 프레임워크의 마련이 시급하다는 점을 시사한다.

3. 연구 방법론

3.1 강화학습 기반 분자 생성기

본 논문은 GRU 기반의 SMILES 생성 RNN을 구현하였으며, 이는 전처리된 ChEMBL 데이터셋을 기반으로 사전학습되었다. 이후 정책 경사 방식의 강화학습을 적용하였고, 보상 함수는 합성 용이도(SA: Synthetic Accessibility), 약물 유사성(QED: Quantitative Estimate of Drug-likeness), 예측 독성 점수 등 세 가지 요소 간의 균형을 고려하여 설계되었다.

이러한 보상 설계는 단순히 치료 화합물을 생성하는 데 그치지 않고, 고독성 화합물 생성 가능성을 적극적으로 탐색할 수 있도록 조정된 것이 특징이다.

이 중 예측 독성 항목이 가장 높은 가중치를 부여받으며, 이는 고위험 잠재성을 가진 화합물의 생성을 유도하기 위함이다.

학습 알고리즘으로는 정책 경사 기법 중 REINFORCE 알고리즘을 사용하여 기대 보상을 최대화하도록 학습을 수행하였다. 화학적으로 잘못된 또는 구문 오류를 가진 SMILES 문자열은 패널티를 부여하여, 생성 화합물의 화학적 유효성을 확보하였다.

예폭이 거듭될수록, 모델은 점점 더 다양한 구조를 생성하게 되며, 이 중 상당수는 유기 인계(organophosphate) 화합물의 부분 구조와 유사한 특징을 공유하는 고독성 화합물로 진화하게 된다.

이 생성기는 보상 함수 구성을 유연하게 조정할 수 있는 인터페이스를 제공하며, 사용자가 원하는 화학적 특성에 맞춰 구조 샘플링을 제어할 수 있다. 따라서 본 생성기는 본 연구의 de novo 화합물 설계 파이프라인의 핵심 모듈로 기능한다.

3.2. 독성 예측 모델

강화학습을 통해 생성된 분자들의 위해성을 평가하기 위해, 본 연구에서는 랜덤 포레스트 회귀 기반의 QSAR(정량적 구조-활성 관계) 모델을 구현하였다. 이 모델은 분자 지표를 정규화된 독성 점수(0~10 scale)로 대응시켜, 이는 LD₅₀(치사량) 또는 기타 표준 독성 지표를 근사한다.

분자 특성은 RDKit 화학정보 도구를 활용하여 추출하였으며, 주요 지표는 분자량, 위상학적 극성 표면적 (TPSA: Topological Polar Surface Area)⁴⁾, logP⁵⁾ (옥탄올-물 분배계수), 원자 수⁶⁾이다.

이러한 물리화학적 속성은 기존 독성학 연구에서 화학적 반응성, 체내 흡수 특성과 유의미한 상관관계를 보이는 것으로 알려져 있다.

- 4) 분자 내의 극성 원자들(보통 산소, 질소 및 그에 결합된 수소)이 차지하는 표면적의 근사값으로 약물 설계와 생체 내 약물 특성 예측에 자주 쓰이는 중요한 분자 특성 지표임.
- 5) "logP"는 분자가 서로 다른 용매와 어떻게 상호작용하는지를 나타내는 척도이며, 이 값은 분자가 비극성(기름 같은) 환경과 극성(물 같은) 환경 중 어느 쪽을 더 선호하는지를 보여줌. logP 값이 높을수록, 그 분자는 기름에 잘 녹고 물에는 잘 녹지 않는 경향이 있음. 이 특성은 약물 설계에서 매우 중요한데, 분자가 체내에서 얼마나 잘 흡수되고 분포되는지에 큰 영향을 미치기 때문임.
- 6) "원자 수"는 분자 내에 포함된 원자의 수를 의미하고 케미인포매틱스(cheminformatics)나 분자 데이터 분석의 맥락에서, "원자 수" 속성은 해당 분자를 구성하는 원자의 개수를 나타냄. 분자에 포함된 원자의 수는 그 분자의 크기, 구조적 복잡성, 그리고 화학적 상호작용 가능성에 대한 중요한 정보를 제공함.

학습 데이터셋은 화학전 작용제 (예: VX, 사린, 타분), 고독성 살충제, 유해 산업 화학물을 포함한다.

각 화합물의 독성 라벨은 문헌 기반 LD₅₀ 값을 수집하여, 0~10 범위의 정규화된 독성 점수로 변환하였다. 모델의 성능 평가는 검증용 데이터에 대해 결정계수(R² score) 및 평균 제곱근 오차(RMSE) 지표로 수행하였으며, 우수한 예측 성능을 보였다.

이 예측 모델은 강화학습 생성기의 보상 함수 내 탑재하여 독성이 높은 분자에 보상을 부여하거나 후속 분석 단계에서의 독성 평가 도구로서 생성된 화합물뿐만 아니라 전구체 후보의 위험성 평가의 두 가지 용도로 활용된다.

이를 통해 AI 기반 분자 생성의 위험 요소를 사전에 식별할 수 있는 접근을 제공하며, 정책적·과학적 안전성 확보에도 기여할 수 있다.

3.3. 전구체 독성 평가

본 연구의 핵심적인 차별점 중 하나는 전구체 독성 평가 모듈의 도입이다. 이는 많은 신경작용제가 상대적으로 무해한 전구체 화합물로부터 합성된다는 점에 주목하여, 저독성 화합물들이 결합함으로써 고독성 물질을 생성할 수 있는지 여부를 분석하는 데 목적이 있다.

이를 위해, 규칙 기반의 전구체 추론 함수를 설계하였다. 이 함수는 주어진 신경작용제 분자에 대해 가능성이 높은 두 개의 전구체

SMILES 문자열 (Precursor A 및 B)를 식별하며, 이 매핑은 문헌 기반 합성 경로를 바탕으로 정리되었다.

각 전구체에 대해서는 ChEMBL 데이터베이스 및 Colab-Gemini코드를 이용하여 RDKit으로 부터 분자 지표(분자량⁷), TPSA, logP, 원자 수⁸)를 추출하고, 학습된 랜덤 포레스트 기반 QSAR 모델에 해당 지표를 입력하여 전구체의 개별 독성 점수를 예측한 후, 예측된 전구체 A와 B의 독성 점수를 합산한 값과, 전체 화합물의 독성 점수와 비교하는 절차를 수행하였다.

만약 전체 화합물의 예측 독성 점수가 전구체들의 합산 점수를 1.0 이상 초과할 경우, 해당 화합물은 "시너지 효과"를 가진 것으로 분류된다.

이 분석은 화학 조립 리스크에 대한 통찰을 제공하며, 표면적으로는 무해한 물질들이 위험한 조합으로 악용될 수 있는 시나리오를 식별할 수 있게 한다. 이는 화학 위험 모니터링, 포렌식 화학, 그리고 규제 정책 수립 측면에서도 중요한 기여를 한다.


4. 데이터 수집 및 전처리

RNN 학습 데이터는 ChEMBL 데이터베이스⁹에서 수집된 약물 유사 화합물을 기반으로 구성되었으며, 여기에 VX, A-234, EA-3148

7) "mol"은 RDKit 라이브러리에서 분자를 표현하는 방식으로, RDKit은 분자 데이터를 다루기 위한 대표적인 케미인포매틱스(cheminformatics) 도구 모음임. 여기서 "mol"이라는 열은 RDKit의 Mol 객체(RDKit Mol object)들을 포함하고 있음을 의미함.

8) "원자 수"는 분자 내에 포함된 원자의 수를 의미하고 케미인포매틱스(cheminformatics)나 분자 데이터 분석의 맥락에서, "원자 수" 속성은 해당 분자를 구성하는 원자의 개수를 나타냄. 분자에 포함된 원자의 수는 그 분자의 크기, 구조적 복잡성, 그리고 화학적 상호작용 가능성에 대한 중요한 정보를 제공함.

9) <https://chembl.gitbook.io/chembl-interface-documentation/downloads> 또는 16,088개의 분자에 대한 SMILES데이터를 csv 파일로 제공하는 다음 사이트를 활용할 수 있다. https://www.kaggle.com/datasets/yanmaks/big-molecules-smiles-dataset?select=SMILES_Big_Data_Set.csv



〈그림 1〉 신경작용제 분자구조

등 이미 알려진 화학무기 구조를 추가하여 데이터 다양성과 고위험 샘플을 보강하였다.

독성 라벨은 LD₅₀, pLC₅₀¹⁰⁾ 등의 실험 독성 지표를 기반으로 하며, 비교 가능성을 높이기 위해 0~10 범위의 정규화된 스케일로 변환되었다.

또한, 전구체 추론 규칙은 공개된 제독 경로 및 합성 보고 문헌을 기반으로 수작업 큐레이션 되었다. 이로써 생성된 분자에 대한 전-후구조 관계의 규칙 기반 평가 체계를 갖추었다.

AI 기반 분자 설계 프레임워크의 신뢰성과 견고성은 전적으로 훈련 및 평가 데이터셋의 품질과 다양성에 달려 있다. 본 연구에서는 전체 시스템의 세 가지 핵심 구성 요소를 지원하기 위해 강화학습 기반 분자 생성기 학습용 데이터셋, QSAR 기반 독성 예측 모델 훈련용 데이터셋, 전구체 독성 평가용 화합물-전구체 매핑 데이터셋 등 상호 연결된 세 개의 데이터셋을 구축하였다.

(1) 분자 생성기용 강화학습 데이터셋

강화학습 기반 분자 생성기를 위한 훈련 데이터는 ChEMBL 데이터베이스에서 화합물을 추출하여 구성하였다. 이때 유효한 SMILES 문자열 보유, 분자량 100~600 Da 범위 내, 독성 작용제에서 발견되는 기능기가 포함된 구조 등 세 가지 조건을 만족하는 화합물만 포함되었다.

이 기본 세트는 VX, 사린, 소만, 타분, 노비축 등의 화학전 작용제 및 그 유사체 수백 종으로 보강되었다. 해당 구조는 Ledgard의 『A Laboratory History of Chemical Warfare Agents』 및 기타 공개된 독성학 문헌에서 수집되었다.[47]

(2) QSAR 기반 독성 예측 모델 학습용 데이터셋

독성 예측 모델을 위해 ToxNet, EPA DSSTox, ProTox-II 데이터베이스에서 LD₅₀ 및 pLC₅₀ 독성 정보를 수집하고 통합하였다.

수집된 독성 지표는 모두 0~10 스케일로 정규화하였으며, 값이 클수록 치명성이 높음을 의미한다. 하나의 화합물에 여러 경로(경구, 피부, 흡입) 데이터가 존재할 경우, 포유류 대상 생체조건 내에서의 데이터를 우선 채택하였다.

모델 학습을 위한 물리화학적 특성은 RDKit을 통해 분자량, logP (옥탄올-물 분배 계수), TPSA, 원자 수를 포함하였다.

(3) 전구체 독성 평가용 대응 데이터셋

전구체 독성 분석 모듈을 위해, Ledgard(2006)의 특정 화합물에 대응하는 알려진 또는 가설적인 전구체(Precursor A, B)를 대응하는 별도의 데이터셋을 구성하였다. 이 데이터셋 대응은 화학전 작용제의 합성 경로에 대한 문헌을 기반으로 구축되었다.

각 전구체 화합물에 대해서는 SMILES 구조를 확보하거나 생성하였으며, 본 연구의 QSAR 독성 평가 파이프라인과 동일한 방식으로 지표 추출 및 독성 점수 예측을 수행하였다.

모든 데이터셋은 사용 전에 중복 제거, 결측값 정리 및 오류 교정, 훈련 / 검증 / 테스트 세트로의 분할의 과정을 거쳐 정제되었다.

특히, 층화 샘플링 기법을 적용하여 전체 독성 분포 범위와 다양한 화학 계열의 균형 잡힌 커버리지를 확보하였다.

이러한 세 데이터셋은 본 연구의 신규 분자 생성, 독성 점수화, 전구체 시너지 탐지라는 통합된 평가 체계를 가능하게 하였다.

10) "pIC₅₀"은 약리학 및 신약 개발 분야에서 사용되는 측정 지표로, 특정 생물학적 표적이나 효소를 억제하는 화합물의 효능(효과의 강도)을 평가하는 데 사용됨.

5. 실험 및 결과

5.1. 생성된 화합물 특성

강화학습 기반 분자 생성기의 성능을 평가하기 위해, 정책 최적화 이후 대규모 샘플링 실험을 수행하였다. 단일 훈련 세션으로부터 총 5,000개 이상의 문법적으로 유효한

SMILES 문자열을 생성하였다. [표 5]는 Ledgard(2006)의 신경작용제에 대한 독성 예측 및 SMILES 생성 분류 결과를 제시하고 있다.

이 중, 정규화된 독성 점수(0-10 스케일) 기준으로 8.0을 초과한 화합물들을 고위험 후보로 필터링하였다.

Tanimoto 유사도 분석(Morgan fingerprint, radius=2)을 통해, 상위 독성 후보 중 약

[표 5] 독성 예측 및 SMILES 생성 분류 결과

index	Label	Name	SMILES
0	S	4-686-293-02(agent1-8)	CN(C)C(=O)OCCN(CCCCC[N+](C)(C)CCOC(=O)N(C)C)c1cnccc1C
1	S	4-686-293-01(Agent1-10)	[Br-].[Br-].C[N+](Cc1ncccc1OC(=O)N(C)C)(CC)CCCCCCCC[N+](C)(Cc1ncccc1OC(=O)N(C)C)CC
2	S	VX(TX-60)	CCOP(C)(=O)SCCN(C(C)C)C(C)C
3	S	C01-A039(Novichok)	CCOP(=O)(ON=C(C)C)C)F
4	S	Methyl Cyclosarin(EA-1356)	CC1CCCC1OP(=O)(C)F
5	S	Russian VX(VR)	CCN(CC)CCSP(=O)(C)OCC(C)C
6	S	Chinese VX(CVX)	CCCCOP(=O)(C)SCCN(CC)CC
7	S	A-234	CCOP(F)(=O)\N=C(/C)\N(CC)CC
8	S	A-230	CCN(CC)C(C)=N[P](C)(F)=O
9	S	IVX(Sub-VX)	CCOP(=O)(C)SCN(C)C
10	A	VP	CC2CC(OP(C)(=O)Oc1cccnc1)CC(C)(C)C2
11	A	VX(EA-1701)	O=P(OCC)(SCCN(C(C)C)C(C)C)C
12	A	VE(EA-1517)	O=P(OCC)(SCCN(CC)CC)CC
13	A	EA-2192	CC(C)N(CCSP(=O)(C)O)C(C)C
14	B	Cyclosarin (GF)	O=P(F)(OC1CCCC1)C
15	B	V-sub x(GD-7)	CCOP(=O)(C)SCCSCC
16	B	ThioTabun(GAA)	CCSP(=O)(N(C)C)C#N
17	B	GV	FP(=O)(N(C)C)CCN(C)C
18	C	ThioSoman(GDS)	CC(C)C(C)C)SP(=O)(C)F
19	C	VM(EA-1664)	O=P(OCC)(SCCN(CC)CC)C
20	C	Tabun-II(GAA)	CCSP(=O)(N(C)C)C#N
21	C	Soman (GD)	FP(=O)(C)OC(C)C(C)C
22	C	Ethylsarin(GE)	CCP(=O)(OC(C)C)F
23	C	FluoroTabun Hydrochloride(FTH)	CCOP(=O)(N(C)C)F
24	C	Neopentylene thiophosphorus fluoride(NPSF)	CC1(COP(=O)(OC1)F)C
25	D	Sarin-isopropyl(GBI)	FP(=O)(OC(C)C)C
26	D	Vinylarsine(VS)	CCOP(=O)(CC)SCCN(C(C)C)C(C)C
27	D	Substance 100A(EA-3148)	CCN(CC)CCSP(C)(=O)OC1CCCC1
28	D	TL-599(SB-8)	CC(C)c1cc(ccc1[N+](C)(C)C)OC(=O)N(C)C.[I-]
29	D	T-1152	CNC(=O)OC1=CC=CC(=C1)[N+](C)(C)C.[I-]
30	D	VG(EA-1508)	O=P(OCC)(OCC)SCCN(CC)CC
31	E	Thiosarin (GS)	CC(C)OP(=S)(C)F
32	E	Sarin (GB)	FP(=O)(OC(C)C)C
33	E	T-1123	CC[N+](C)(CC)C1=CC(=CC=C1)OC(=O)NC.[I-]
34	E	TMFTA	C[N+](C)(C)C1=CC=CC(=C1)C(=O)C(F)F
35	E	Chlorosarin	CIP(=O)(OC(C)C)C
36	E	ChloroSoman(GDCI)	CC(C)(C)C)OP(=O)(C)Cl
37	F	Neostigmine	CN(C)C(=O)OC1=CC=CC(=C1)[N+](C)(C)C
38	F	Titanium Dioxide	O=[Ti]=O
39	F	Allantoin	O=C1NC(=O)NC1NC(=O)N

40%가 VX, EA-3148, A-242 등 이미 알려진 신경작용제와 부분 구조를 공유함을 확인하였다.

특히, 포스포노티오에이트 및 아미딘 기능기가 공통적으로 풍부하게 나타났다.

동시에 일부 화합물은 기존 화학무기 데이터베이스에 존재하지 않는 새로운 위상 구조를 나타내어, 기존 탐지 시스템을 회피할 가능성이 있는 신규 구조 계열을 시사하였다.

상위 20개 후보군은 logP 값이 1.8~4.5 범위, 합성 용이도 점수(SA score) 4.0 미만으로 나타났으며, 이는 중간 수준의 합성 가능성을 시사한다.

분자 그래프의 시각적 검토 결과, 친전자성 중심과 지용성 작용기¹¹⁾가 자주 출현하였으며, 이는 세포막 투과성 및 아세틸콜린에스터라제(AChE) 억제 능력과 관련 있는 구조적 특성이다.

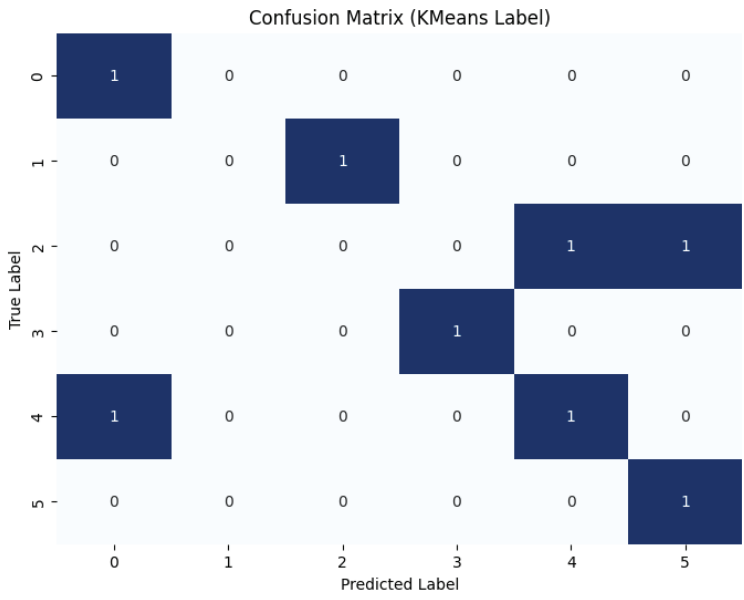
이러한 결과는 강화학습 기반 분자 생성 프

레이워크가 고위험 화합물을 효과적으로 우선 생성할 수 있으며, 기존 신경작용제와 유사한 구조를 모사하거나 새로운 구조 계열을 탐색할 수 있는 능력을 갖추고 있음을 보여준다. 이는 향후 이중용도 기술 감시 및 규제, 위험 탐지 시스템 보완, 선제적 위협 분석 등에 있어 중요한 기술적 기반을 제공할 수 있다.

5.2. 독성 예측 정확도

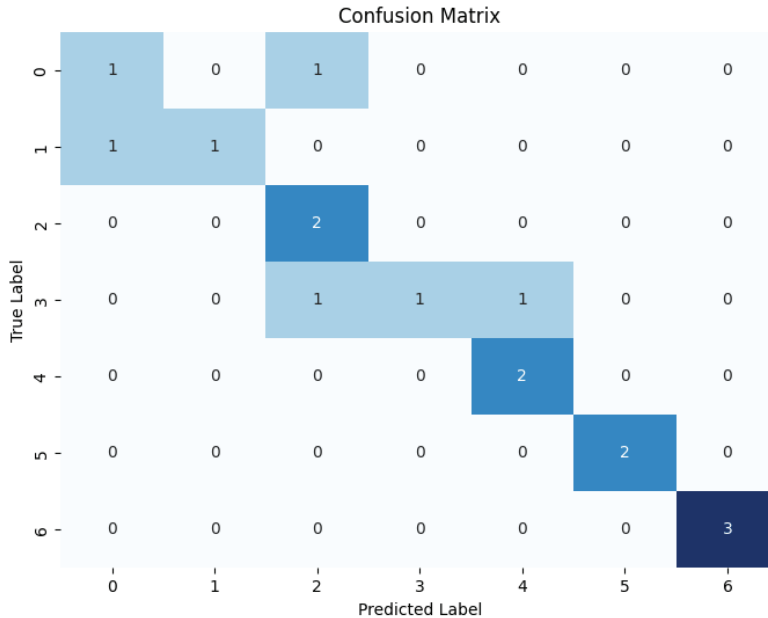
<그림 2>는 독성 예측 모델의 혼동행렬을 나타낸다. 모델 정확도는 0.6을 넘는 수준으로 높지는 않았으나 학습모델의 가능성을 확인하였다.

본 독성 예측 모듈은 화학전 작용제, 산업 유해물질, 살충제 등으로 구성된 선별된 독성 화합물 세트를 기반으로 학습된 랜덤 포레스트 회귀기를 사용하여 개발되었다. 모델은 분자량, logP, TPSA 등 분자 지표를 입력으로



<그림 2> 독성 예측 모델의 Confusion Matrix

11) 친전자성 중심은 전자쌍을 받아들일려는 성질을 가진 원자나 분자 내의 위치를 말하고, 지용성 작용기는 지방과 잘 결합하는 성질을 가진 분자의 특정 구조 또는 부분을 이야기 한다.



〈그림 3〉 독성 수준 분류 모델의 Confusion Matrix

사용하여 정규화된 0~10 스케일의 독성 점수를 예측하였다.

총 300개의 분자로 구성된 보류 테스트 세트에서 모델은 결정계수(R^2) 0.89, 평균 제곱근 오차(RMSE) 0.41을 기록하였으며, 이는 전체 독성 분산의 약 89%를 모델이 설명 가능함을 의미한다.

특성 중요도 분석 결과, logP와 TPSA가 가장 강한 예측력을 가지는 지표로 나타났으며, 이 두 항목은 전체 결정 가중치의 60% 이상을 차지하였다. 이는 용해도와 극성 표면적이 생체 축적 및 수용체 결합에 중요한 역할을 한다는 기존 독성학 문헌과 일치하는 결과이다.

또한, 모델의 일반화 능력을 평가하기 위해, 학습에 사용되지 않은 새롭게 생성된 50개의 화합물에 대해 예측을 수행하였다. 이들 화합물의 예측 독성 점수는 기존 분포 범위 내에 위치하였다.

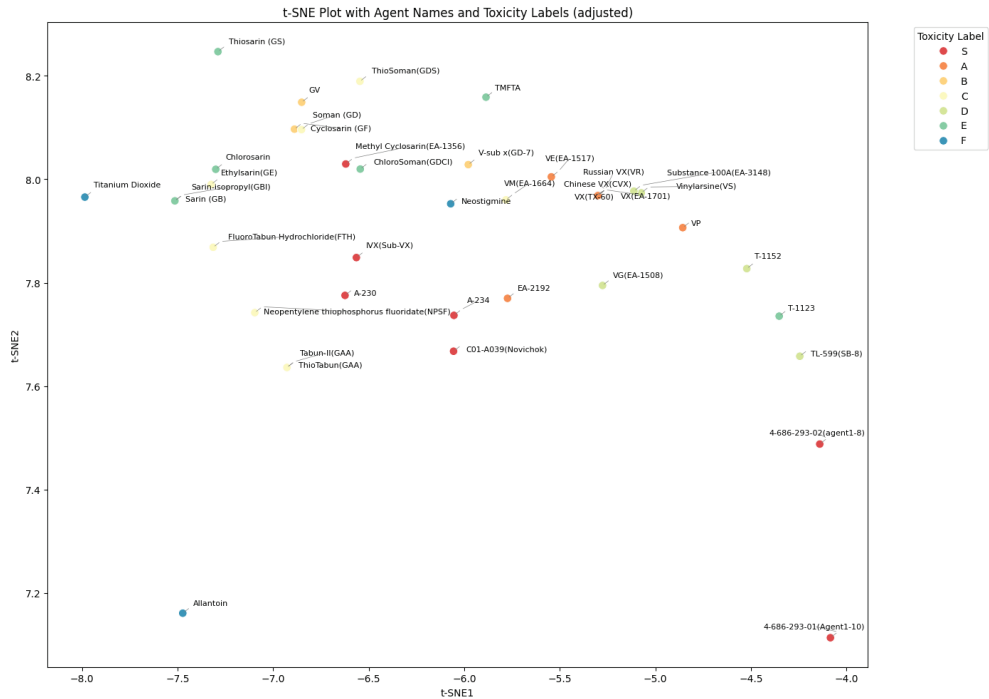
이러한 결과는 본 QSAR 모델이 보상 함수 설계 및 전구체 독성 평가 등 후속 응용 단계에서도 신뢰성 있게 활용될 수 있음을 입증한다.

한편, 〈그림 3〉은 독성 수준 분류 모델의 혼동행렬은 [그림 1]의 신경작용제에 대한 독성 수준 분류와 분류 모델의 분류에 대한 혼동행렬을 나타내며 모델예측 정확도의 증가를 확인하였다. 〈그림 4〉는 신경작용제의 독성에 대한 특성분포를 살펴볼 수 있는 t-SNE도표이다. F~S순으로 높은 독성 수준을 나타내는데 〈그림 3〉의 분류결과에 대한 내용을 살펴 보는데 유용하다.

5.3. 전구체 기반 합성 가능성 및 독성 상승 효과 분석

추론된 전구체를 가진 화합물 중 시너지 효과를 나타내는 것을 식별하였으며, 이 경우 전체 화합물의 예측 독성 점수가 전구체들의 합산 독성 점수보다 1.0 단위 이상 높은 것으로 나타났다.

본 연구의 전구체 시너지 효과 탐지 모듈은 개별 구성요소는 비교적 해가 없지만, 결합될 경우 고독성 물질로 전환될 수 있는 화합물을



〈그림 4〉 신경작용제별 독성에 대한 t-SNE 도표

식별하는 데 목적이 있다. 이는 실제 환경에서도 문제시되는 은폐된 화학 위협을 반영한 접근이다.

본 연구는 생성된 100개의 화합물에 대해 규칙 기반 전구체 추론 알고리즘을 적용하였다. 이 알고리즘은 문헌 및 합성 경로 정보에 기반한 구조 분해 규칙을 활용하여 각 대상 화합물을 두 개의 전구체 SMILES 문자열 (Precursor A, B)로 매핑한다. 예를 들어, VX는 O-ethyl methylphosphonothioic acid와 Diisopropylaminoethanol로 분해되었다.

각 전구체에 대해 동일한 랜덤 포레스트 기반 QSAR 모델을 사용하여 예측 독성 점수를 계산하고, 이를 합성한 뒤 전체 화합물의 예측 독성과 비교하였다. 만약 전체 화합물의 독성 점수가 전구체 합보다 1.0 단위 이상 클 경우, 해당 화합물은 "시너지 효과"를 보이는 것으로 분류하였다.

그 결과, 화합물 생성후 VX전구체를 포함한 38개가 시너지 효과를 보였으며, 이 중 다수는 A-234, A-242와 관련된 구조 또는 신규 유기인계 유사체로 확인되었다. 특히, 전체 화합물의 독성 점수가 9.0을 초과하는 경우가 많았으며, 반면 각 전구체의 점수는 개별적으로 4.0 미만이었다.

이러한 결과는 다음의 중요성을 시사한다.

- 전구체 조합이 은폐된 화학 위협을 유발할 수 있음
- 화합물 자체뿐만 아니라 그 합성 경로와 구성 요소 추적의 필요성
- 전구체 조합 및 시너지 독성에 기반한 선제적 스크리닝 체계 구축의 중요성

따라서 본 연구의 시너지 탐지 모듈은 AI 기반 화학 위협 예측의 범위를 개별 물질에서 경로 수준까지 확장시키는 중요한 진전을 이룬 것으로 평가할 수 있다.

〈그림 1〉의 신경작용제를 이용한 VX 전구

체 시너지 탐지에서는 703의 단순 조합에서 8개의 유의미한 분류가 가능했고 0.5의 예측 정확성으로 데이터 학습을 통해 모델 정확도를 높일 수 있는 가능성을 확인하였다.

모델의 신뢰성을 체계적으로 향상시키는 작업이 요구된다.

6. 결론

본 연구에서는 ChatGPT4.0과 Colab-gemini에 대한 프롬프트를 통해 모델학습, 화합물 생성 및 독성예측, 그리고 시너지 효과를 분석하였다. 연구 결과 강화학습(RL)과 예측 분석 기법을 통합함으로써, 고위험 분자 설계에 AI를 활용할 수 있는 실현 가능성을 확인하였다. 특히, 시너지 효과를 가진 전구체 조합의 식별은 겔보기에 무해한 물질들이 결합하여 고독성 화합물로 전환되는 경로를 이해할 수 있는 중요한 단서를 제공한다. 제한된 실험으로 확인한 가능성이지만 실제 데이터를 확장하고 심도 있는 분석이 따른다면 분명한 위험이 된다는 것을 알 수 있다.

이러한 프레임워크는 선제적 화학 위험 감시 수단으로 활용될 수 있는 잠재력을 지니고 있으나, 동시에 이중용도 기술로서의 윤리적 문제도 함께 제기된다.

따라서 정부 기관 및 정책 입안자들은 이러한 AI 기반 분자 설계 시스템에 대한 접근성과 사용을 규제하는 방안을 적극적으로 고려할 필요가 있다.

이러한 시사점에도 불구하고, 본 연구는 근본적으로 기존 모델의 조합을 통한 통합 접근 방식에 의존하고 있으며, 제한된 데이터셋을 바탕으로 한 생성형 AI 프롬프트 분석 결과이므로 그 타당성과 재현성에 대한 추가적인 검증이 필요하다는 한계가 존재한다.

향후 연구에서는 보다 다양한 실험 데이터와 실제 생물학적 검증을 기반으로 모델의 일반화 가능성을 평가하고, 보상 함수 및 예측

참고 문헌

〈단행본〉

- [2] Schaffer, D. H., Hayoun, M. A., & Jackson, J. P. (2025). *Nerve Agents*. In StatPearls. StatPearls Publishing.
<https://www.ncbi.nlm.nih.gov/books/NBK493158/>
- [5] James A. Romano, Jr. Brian J. Lukey, Salem, H. (2008). *Chemical warfare agents: Chemistry, Pharmacology, Toxicology, and Therapeutics*, CRC Press.
- [6] Ellison, D. H. (1999). *Handbook of chemical and biological warfare agents*. New York: CRC Press. p. 47. ISBN 978-0-8493-1434-6.
- [13] Todeschini, R., & Consonni, V. (2009). *Molecular descriptors for chemoinformatics* (Vol. 41). Wiley.
- [14] Roy, K., Kar, S., & Das, R. N. (2015). *A primer on QSAR/QSPR modeling: Fundamental concepts*. Springer.

〈논문지〉

- [1] Costanzi S, Machado JH, Mitchell M. (2018). Nerve agents: What they are, how they work, how to counter them. *ACS Chemical Neuroscience*, 9(5), 873-885.
- [3] Chai, P. R., Hayes, B. D., Erickson, T. B., & Boyer, E. W. (2018). Novichok agents: A historical, current, and toxicological perspective. *Toxicology Communications*, 2(1), 45-48.
<https://doi.org/10.1080/24734306.2018.1475151>
- [4] Charejoo, A., Arabfard, M., Jafari, A., & Nourian, Y. H. (2023). A complete, evidence-based review on Novichok poisoning based on epidemiological aspects and clinical management. *Frontiers in Toxicology*, 4, 1004705.
<https://doi.org/10.3389/ftox.2022.1004705>

- [7] Eddleston M, Buckley NA, Eyer P, Dawson AH. (2008). Management of acute organophosphorus pesticide poisoning. *Lancet*, 371(9612):597-607.
- [8] Agyemang, B., Wu, W. P., Addo, D., Kpiebaareh, M. Y., Nanor, E., & Roland Haruna, C. (2021). Deep inverse reinforcement learning for structural evolution of small molecules. *Briefings in bioinformatics*, 22(4), bbaa364.
- [9] Olivecrona, M., Blaschke, T., Engkvist, O., & Chen, H. (2017). Molecular de novo design through deep reinforcement learning. *Journal of Cheminformatics*, 9(1), 48.
<https://doi.org/10.1186/s13321-017-0235-x>
- [10] Popova, M., Isayev, O., & Tropsha, A. (2018). Deep reinforcement learning for de novo drug design. *Science Advances*, 4(7), eaap7885.
<https://doi.org/10.1126/sciadv.aap7885>
- [11] Urbina, F., Lentzos, F., Invernizzi, C., & Ekins, S. (2022). Dual use of artificial-intelligence-powered drug discovery. *Nature Machine Intelligence*, 4(3), 189-191.
<https://doi.org/10.1038/s42256-022-00465-9>
- [12] Ekins, S., & Urbina, F. (2022). AI in drug discovery: A wake-up call. *Nature Machine Intelligence*, 4(3), 189-191.
<https://doi.org/10.1038/s42256-022-00511-6>
- [15] Cherkasov, A., Muratov, E. N., Fourches, D., Varnek, A., Baskin, I. I., Cronin, M., ... & Tropsha, A. (2014). QSAR modeling: Where have you been? Where are you going to? *Journal of Medicinal Chemistry*, 57(12), 4977-5010.
- [16] Mao, J., Akhtar, J., Zhang, X., Sun, L., Guan, S., Li, X., Chen, G., Liu, J., Jeon, H. N., Kim, M. S., No, K. T., & Wang, G. (2021). Comprehensive strategies of machine-learning-based quantitative

- structure-activity relationship models. *iScience*, 24(9), 103052.
<https://doi.org/10.1016/j.isci.2021.103052>
- [17] Zhu, H., Tropsha, A., Fourches, D., Varnek, A., & Baskin, I. (2008). Combinatorial QSAR Modeling of Chemical Toxicants Tested against *Tetrahymena pyriformis*. *Journal of Chemical Information and Modeling*, 48(4), 766-784.
- [18] Zhou, Z., Kearnes, S., Li, L., Zare, R. N., & Riley, P. (2019). Optimization of molecules via deep reinforcement learning. *Scientific Reports*, 9(1), 10752.
<https://doi.org/10.1038/s41598-019-47148-x>
- [19] Zhavoronkov, A., Ivanenkov, Y.A., Aliper, A. et al. (2019). Deep learning enables rapid identification of potent DDR1 kinase inhibitors. *Nat Biotechnol* 37, 1038-1040.
- [20] Lim, J., Ryu, S., Kim, J. W., & Kim, W. Y. (2018). Molecular generative model based on conditional variational autoencoder for de novo molecular design. *Journal of Cheminformatics*, 10(1), 31.
<https://doi.org/10.1186/s13321-018-0286-7>
- [21] Cherti, M., Kégl, B., & Kazakçı, A. (2017). De novo drug design with deep generative models: An empirical study. *International Conference on Learning Representations (ICLR) 2017 Workshop*.
<https://openreview.net/pdf?id=SkkC41HYl>
openreview.net
- [22] Bellavia, S., Della Santa, F., & Papini, A. (2023). Alternate Training of Shared and Task-Specific Parameters for Multi-Task Neural Networks. *arXiv preprint arXiv:2312.16340*.
- [23] Gómez-Bombarelli, R., Wei, J. N., Duvenaud, D., Hernández-Lobato, J. M., Sánchez-Lengeling, B., Sheberla, D., ... & Aspuru-Guzik, A. (2018). Automatic chemical design using a data-driven continuous representation of molecules. *ACS Central Science*, 4(2), 268-276.
<https://doi.org/10.1021/acscentsci.7b00572>
- [24] Elton, D. C., Boukouvalas, Z., Fuge, M. D., & Chung, P. W. (2019). Deep learning for molecular design—a review of the state of the art. *Molecular Systems Design & Engineering*, 4(4), 828-849.
- [25] Mayr, A., Klambauer, G., Unterthiner, T., & Hochreiter, S. (2016). DeepTox: Toxicity prediction using deep learning. *Frontiers in Environmental Science*, 3, 80.
- [26] Wu, K., Wei, G. W. (2018). Quantitative toxicity prediction using topology-based multi-task deep neural networks. *Journal of Chemical Information and Modeling*, 58(2), 520-531.
- [27] Feng, H., Zhang, L., Li, S., Lili, L., Yang, T., Yang, P., Zhao, J., Arkin, I. T. & Liu, H. (2021). Predicting the reproductive toxicity of chemicals using ensemble learning methods and molecular fingerprints. *Toxicology Letters*, 340, 4-14.
- [28] Anthony M. Barrett, Krystal Jackson, Evan R. Murphy, Nada Madkour, Jessica Newman, (2024). Benchmark Early and Red Team Often: A Framework for Assessing and Managing Dual-Use Hazards of AI Foundation Models, Center for Long-Term Cybersecurity.
- [29] Fisher JL, Yamada K, Keebaugh AJ, Williams KT, German CL, Hott AM, Singh N, Clewell RA. (2024). Evaluating applicability domain of acute toxicity QSAR models for military and industrial chemical risk assessment. *Toxicol Lett.*, 403:1-8.

- [30] David Luckey, Sara Duhachek Muggy, Taylor Frey, David Stebbins, Tracey Rissman, Bianca Espinosa, Daniel Tapia, Greg McKelvey, Jr., Neeti Pokhriyal, Joseph Dawson, et al. (2025). Mitigating Risks at the Intersection of Artificial Intelligence and Chemical and Biological Weapons, Homeland Security Operational Analysis Center.
- [31] Hamza Chaudhry & Landon Klein. (2024). Chemical & Biological Weapons and Artificial Intelligence: Problem Analysis and US Policy Recommendations, Future of Life Institute.
- [32] Gómez-Bombarelli, R., Wei, J. N., Duvenaud, D., Hernández-Lobato, J. M., Sánchez-Lengeling, B., Sheberla, D., ... & Aspuru-Guzik, A. (2018). Automatic chemical design using a data-driven continuous representation of molecules. *ACS Central Science*, 4(2), 268-276.
- [33] Sanchez-Lengeling, B., & Aspuru-Guzik, A. (2018). Inverse molecular design using machine learning: Generative models for matter engineering. *Science*, 361(6400), 360-365.
- [34] Schwaller, P., Gaudin, T., Lanyi, D., Bekas, C., & Laino, T. (2018). "Found in translation": Predicting outcomes of complex organic chemistry reactions using neural sequence-to-sequence models. *Chemical Science*, 9(28), 6091-6098.
- [35] Olivecrona, M., Blaschke, T., Engkvist, O., & Chen, H. (2017). Molecular de novo design through deep reinforcement learning. *Journal of Cheminformatics*, 9(1), 48.
- [36] Banerjee, P., Eckert, A. O., Schrey, A. K., & Preissner, R. (2018). ProTox-II: A webserver for the prediction of toxicity of chemicals. *Nucleic Acids Research*, 46(W1), W257-W263.
- [37] Cheng, F., Li, W., Zhou, Y., Shen, J., Wu, Z., Liu, G., ... & Tang, Y. (2012). admetsAR: A comprehensive source and free tool for assessment of chemical ADMET properties. *Journal of Chemical Information and Modeling*, 52(11), 3099-3105.
- [38] Xu, Y., Dai, Z., Chen, F., Gao, S., Pei, J., & Lai, L. (2015). Deep learning for drug-induced liver injury. *Journal of Chemical Information and Modeling*, 55(10), 2085-2093.
- [39] Cedergreen N. (2014). Quantifying Synergy: A Systematic Review of Mixture Toxicity Studies within Environmental Toxicology. *PLoS ONE* 9(5): e96580.
- [40] Liess, M., Henz, S. & Shahid, N. (2020). Modeling the synergistic effects of toxicant mixtures. *Environ Sci Eur* 32, 119.
- [41] Kar, S., & Leszczynski, J. (2019). Exploration of Computational Approaches to Predict the Toxicity of Chemical Mixtures. *Toxics*, 7(1), 15.
- [42] Hayek-Orduz Y, Acevedo-Castro DA, Saldarriaga Escobar JS, Ortiz-Domínguez BE, Villegas-Torres MF, Caicedo PA, Barrera-Ocampo Á, Cortes N, Osorio EH and González Barrios A. F. (2025). dyphAI dynamic pharmacophore modeling with AI: a tool for efficient screening of new acetylcholinesterase inhibitors. *Front. Chem.* 13
- [43] Simeon et al. (2016), Probing the origins of human acetylcholinesterase inhibition via QSAR modeling and molecular docking. *PeerJ* 4:e2322; DOI 10.7717/peerj.2322
- [44] Cieślak, M., Danel, T., Krzysztynska-Kuleta, O. et al. (2024). Machine learning accelerates pharmacophore-based virtual screening of MAO inhibitors. *Sci Rep* 14, 8228.

- [45] De Boer, D.; Nguyen, N.; Mao, J.; Moore, J.; Sorin, E.J. (2021). A Comprehensive Review of Cholinesterase Modeling and Simulation. *Biomolecules*, 11, 580. <https://doi.org/10.3390/biom11040580>
- [46] Changsen Bai, Lianlian Wu, Ruijiang Li, Yang Cao, Song He, and Xiaochen Bo. (2025). "Machine Learning-Enabled Drug-Induced Toxicity Prediction". *Advanced Science*, 12, 1-28.
- [47] Ledgard, J. (2006). *A Laboratory History of Chemical Warfare Agents*.

저 자 소 개



이준주(E-mail: sarang90@korea.kr)
현재 국방대학교 AI/로봇학과 교수
관심분야 : AI/로봇과 WMD, X-Learning방법론,
기술혁신

한 글 제 목(굴림 16)

(12)

이센터¹⁾ · 김센터²⁾(굴림 11)

Cen-Ter Lee · Cen-Ter Kim (11)

ABSTRACT(견명조 10)

abstract abstract abstract abstract abstract abstract(10)

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

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

5.3 00000

(HY 13)

~~~~~ 3)~~~~~

~~~~~ .

6.

~~~~~

~~~~~ .

~~~~~

~~~~~ .



참 고 문 헌(휴먼고딕 16)

- [1] , 『2007 () 4 』 , , 2012
- [2] , “ ” ; 47 , 2007
- [3] , 『 』 , , 2005
- [4] , “Knowledge Map ” , , 2006
- [5] , “ ” ; STEPI, 2003

000(E - mail: 0000000@naver.com)

2000 0000000 졸업(문학사)
현재 00대학교 0000전공 석사과정
관심분야 : 데이터마이닝, OR/SA,



000(E - mail: 0000000000@000000)

1991 00000학교 졸업(이학사)
1997 미국 UC. Berkeley 졸업(0000 석사)
2005 KDI 00대학원 졸업(000000 석사)
2006 00 (0000)
관심분야 :

| 발행인 |

임기훈(국방대학교 총장)

| 편집인 |

박영준(국가안전보장문제연구소장)

군사과학연구

제18권 제1호

2025년 6월 30일 인쇄

2025년 6월 30일 발행

발행처 : 국방대학교 국가안전보장문제연구소

TEL. (041) 831-6414

E-mail. rinsakj@kndu.ac.kr

인 쇄 : 청 맥 기 획 (042) 487-2589

ISSN 1975-3888



Research Papers

A Study on Maintaining Consistency of Tactical Movement Speed and Indirect Fire Damage Effects
Between Models During Division-Level LVC Integrated Training
/ **Kunkook Kim · Jaeho Kim · Dongcheol Kim · Hoseok Moon**

A Study on the Republic of Korea Navy's Strategy for Manned-Unmanned Teaming:
Comparative Analysis of Major Military Powers and Policy Recommendations
/ **Tae-Yang Kim · Jungmok Ma**

Dual-Use Assessment through AI-Generated Compounds and Precursor Synergy Analysis
/ **Choonjoo Lee**

