



Received: 2025/08/23
Revised: 2025/09/07
Accepted: 2025/09/29
Published: 2025/09/30

***Corresponding Author:**

Dooyoung Kim

Dept. of Artificial Intelligence, Republic of Korea
Naval Academy
1 Jungwon-ro, Jinhae-gu, Changwon-si,
Gyungsangnam-do, 51704, Republic of Korea
Tel: +82-55-549-5624
E-mail: dykim07@navy.ac.kr

무인수상정의 해상 이동 표적 추적을 위한 접근 경로 계획 기법

Approach Path Planning for Maritime Moving Target Tracking by Unmanned Surface Vehicles

김두영*

해군 중령(진)/해군사관학교 인공지능학과 부교수

Dooyoung Kim*

CDR(Sel.), ROK Navy/Associate Professor, Dept. of Artificial Intelligence,
Republic of Korea Naval Academy

Abstract

본 연구에서는 무인수상정의 해상 이동 표적 추적을 위한 인공지능경망 기반 경로 생성 기법을 제안한다. 제안된 기법은 Hamilton-Jacobi-Bellman (HJB) 방정식을 신경망 모델로 근사하여, 추적자가 목표 선박의 함미 기준으로 제한된 방위 각도와 거리 내에서 접근하는 경로를 생성한다. 시뮬레이션을 통해 제안된 모델이 다양한 시나리오에서 유효하게 작동함을 확인하였다.

This study presents a neural network-based path generation method for maritime moving target tracking by unmanned surface vehicles (USVs). The proposed method approximates the Hamilton-Jacobi-Bellman (HJB) equation using a neural network model, which generates the pursuer's trajectory for approaching the target vessel within constrained bearing angles and distance, based on the target vessel's stern. Simulation results confirm that the proposed model operates effectively in various scenarios.

Keywords

무인수상정(Unmanned Surface Vehicle),
목표 추적(Target Tracking),
경로 계획(Path Planning),
신경망 근사(Neural Network Approximation),
미분 게임(Differential Game)

Acknowledgement

이 논문은 2025년 해군사관학교 해양연구소
학술연구과제 연구비 지원으로 수행된 연구임.

1. 서론

무인수상정(unmanned surface vehicle, USV)은 최근 해양의 다양한 분야에서 활용방안에 관한 연구가 활발하게 진행되고 있다. 군사 분야에서는 감시정찰, 대함전, 대잠전, 기뢰전 등의 임무에 적용하는 방안이 논의 중이며, 민간 분야에서는 해저 자원 탐사, 해양 환경 모니터링, 탐색 및 구조 등의 광범위한 활용방안이 연구되고 있다[1-3]. 다만 현재 현장에서 운용 중인 대부분의 USV는 원격조종에 의존하고 있어 최대 운용 역량에 한계를 가진다. 이에 따라 다수의 USV를 동시에 운용하는 미래 환경에서는 자율적인 임무 수행능력의 구비가 필수적이다.

이동 표적 추적(moving target tracking)[4,5]은 무인 체계를 이용하여 목표물과 일정 거리를 유지하며 관측하는 것을 말한다. 추적자의 생존성을 고려할 필요가 없는 비군사적 상황과는 다르게 군사 목적으로 활용하기 위해서는 목표물의 대응을 고려한 추적자의 이동 경로 계획이 필수적이다. 특히 기동 제한이 심한 USV의 경우 더 세밀한 경로 계획이 필요하다.

일반적으로 이동 표적 추적 문제는 크게 ① 목표물로 접근하는 단계와 ② 접근 이후 목표물과 동조 기동하는 단계로 구분할 수 있다. 이중 동조 기동은 목표물과 같은 침로와 속력으로 기동하는 단계로 구분할 수 있다. 이중 동조 기동은 목표물과 같은 침로와 속력으로 기동하는 형태 또는 장애물 회피하여 기동하는 형식으로 다양한 연구가 진행되었다[6]. 범용 알고리즘의 제안이 가능한 동조

기동 문제와 다르게, 목표물로 접근하는 단계는 USV의 임무 형태에 따라 다양한 상황을 고려해야 한다. 특히 군사 목적으로 활용할 경우 목표물의 반격 가능성, 무장 상황, 교전규칙 등을 고려하여 접근 경로를 계획해야 한다.

본 논문에서는 무장한 목표 선박(evader)이 접근 후 도주하는 상황에서 추적자 USV(pursuer)의 생존성을 고려한 목표 접근 경로 계획 기법을 제안한다. 먼저 예상되는 교전 시나리오를 기반으로 해당 문제를 미분 게임(differential game) [7]으로 모델링한 후 Hamilton-Jacobi-Bellman(HJB) 방정식으로 해를 수식화하였다. 이후 인공지능망을 이용한 가치 함수 근사(value function approximation)를 통해 HJB의 근사해를 도출하였다.

논문의 구성은 다음과 같다. 먼저 2장에서 상황 및 가정을 수립하고 문제를 수식화하여 정의하였다. 3장에서는 HJB 방정식의 근사해를 도출하기 위한 인공지능망의 정의와 학습 방법을 서술하였다. 4장에서는 시뮬레이션을 통해 제안한 방법을 검증하였다. 마지막으로 결론에서 논문의 의의와 향후 연구 방향을 제시하였다.

2. 문제 정의

2.1 상황 및 가정

Fig. 1은 본 논문에서 해결하고자 하는 문제를 도식화한 그림이다. 목표 선박이 추적을 회피하여 기동하는 상황에서, 추적자는 생존성 향상을 위해 목표 선박의 함수를 피하고 함미로 접근하려 한다. 추가적인 가정은 다음과 같다.

- (1) 목표 선박의 최대 속력은 추적자보다 느리다.
- (2) 추적자는 목표의 함수를 피하고 함미로 접근한다. 목표 선박은 자신의 함미를 노출하지 않도록 회피 기동한다.
- (3) 추적자와 목표 선박은 항상 최대 속력으로 기동한다.
- (4) 초기 위치는 임의의 위치이며, 추적자가 목표 선박의 일정 거리 안에 진입하면 LOS(line of sight) 추적으로 전환한다.




Fig. 1. Conceptual illustration of the approaching problem: the evader(red), the pursuer(blue), and the goal area(yellow arc).

2.2 동역학 모델

추적자를 p , 목표 선박을 e 라 할 때 선박 $i \in \{p, e\}$ 의 상태 s_i 는 식 (1)과 같이 정의한다.

$$s_i = [x_i, y_i, h_i]^T \in R^3 \quad (1)$$

여기서, x, y 는 선박의 2차원 좌표, h 는 침로를 의미한다. 식 (1)에 따라 시간 t 에서 전체 시스템의 상태는 식 (2)와 같다.

$$s(t) = [x_p(t), y_p(t), h_p(t), x_e(t), y_e(t), h_e(t)]^T \quad (2)$$

식 (2)에서 가정한 바에 따라 각 선박은 최대 속력으로 기동한다. 따라서 제어 입력은 선박 i 의 각속도 ω_i 로 정의하며 최대 각속도는 $\bar{\omega}$ 라 정의한다. 두 선박이 Dubins 모델을 따른다고 가정할 때 선박 i 의 동역학 모델 $f_i(s_i, \omega_i)$ 은 식 (3)과 같이 정의할 수 있다.

$$\dot{s}_i = f_i(s_i, \omega_i) = \begin{bmatrix} v_i \cos h_i \\ v_i \sin h_i \\ h_i \end{bmatrix} \quad (3)$$

상술한 내용을 바탕으로 한 시스템의 최종 동역학 모델은 식 (4)와 같다.

$$\dot{s} = f(s, \omega) = \begin{bmatrix} v_p \cos h_p \\ v_p \sin h_p \\ \omega_p \\ v_e \cos h_e \\ v_e \sin h_e \\ \omega_e \end{bmatrix} \quad (4)$$

동역학 모델을 시뮬레이션 간격 Δt 에 따라 전진 오

일러 기법으로 이산화한 결과는 식 (5)와 같다.

$$s_i^+ = s_i + \Delta t f_i(s_i, \omega_i) \quad (5)$$

$$s^+ = [s_p^+, s_e^+]^T \quad (6)$$

$$t^+ = t + \Delta t \quad (7)$$

2.3 비용함수 설계

추적자의 최종 목표는 목표 선박과 상대 거리 d 가 $R_{th} > 0$ 이내이고, 목표 선박의 함미를 기준으로 상대 방위 $\pm\phi_{th}$ 이내에 위치하는 것이다. Fig. 1의 노란색 영역은 최종 목표 영역을 도식화한 그림이다. 종말 비용함수 $\ell(s)$ 는 위 영역에 도달할 경우 0, 도달하지 못하였을 경우 거리 d 에 비례하는 식 (8)과 같이 정의할 수 있다.

$$\ell(s) = \begin{cases} 0, & d \leq R \text{ and } \phi \leq \phi_{th} \\ d, & \text{otherwise} \end{cases} \quad (8)$$

위 종말 비용함수를 통해 시간 t 에서 상태 s 일 때 잔여 비용함수 $V(s, t)$ 를 도출할 수 있다. 도출된 $V(s, t)$ 를 바탕으로 추적자는 $V(s, t)$ 를 최소화하는 ω_p 를, 목표 선박은 $V(s, t)$ 를 최대화하는 것을 최적화 목표로 한다.

이상의 내용은 최적화 목표는 미분 게임(differential game) 중 제로섬 게임의 대표적인 사례인 pursuer-evader 문제이다. 일반적인 pursuer-evader 문제는 HJC 방정식으로 해를 구할 수 있으나, 위에서 정의한 $V(s, t)$ 는 비선형의 복잡성을 가진 형태로 해를 직접 구하기 어렵다. 따라서 본 논문에서는 잔여 비용함수 $V(s, t)$ 를 인공신경망으로 근사하였다.

앞서 정의한 $\ell(s)$ 는 경계 불연속 함수로 인공신경망 학습이 어렵다. 따라서 sigmoid 함수를 이용하여 다음과 같이 완화하였다.

먼저 거리에 따른 비용함수 $\sigma_d(d)$ 는 식 (9)와 같다.

$$\sigma_d(d) = \frac{1}{1 + e^{k_d(d-R)}} \quad (9)$$

상대 방위에 따른 비용함수 $\sigma_\phi(\phi)$ 는 식 (10)과 같다.

$$\sigma_\phi(\phi) = \frac{1}{1 + e^{-k_\phi(\cos \phi - \cos \phi_{th})}} \quad (10)$$

최종적으로 완화된 함수는 식 (11)과 같다.

$$\ell(s) = (1 - \sigma_d(d) \cdot \sigma_\phi(\phi)) \cdot d \quad (11)$$

3. 기동경로 계획 기법

추적자와 목표 선박의 최적제어 값 ω_p^* , ω_e^* 은 식 (12), 식 (13)과 같다.

$$\omega_p^* = \arg \min_{\omega_p} \nabla_{s_p} V \cdot f(s_p, \omega_p) \quad (12)$$

$$\omega_e^* = \arg \max_{\omega_e} \nabla_{s_e} V \cdot f(s_e, \omega_e) \quad (13)$$

본 연구에서는 인공신경망의 하나인 다층 퍼셉트론으로 이용하여 잔여 비용함수 V 를 근사하였다. 근사함수 V_θ 는 주어진 상태와 시간에서 추적자의 잔여 비용을 추정하는 것을 목표로 한다. 제안한 인공신경망 모델은 총 여섯 개의 층(layer)으로 구성되며, 그 구조는 다음과 같다.

- 입력층: 입력 차원은 6차원의 상태벡터와 1차원의 시간 변수를 포함한 7차원이다. 출력은 128차원이며, 활성화 함수로 tanh 함수를 사용하였다.
- 은닉층(2~5층): 각 층은 128차원의 입력과 출력을 가지며, 활성화 함수로 tanh 함수를 적용하였다.
- 출력층: 128차원의 입력을 받아 최종적으로 1차원의 스칼라값을 출력한다. 별도의 활성화 함수는 없다.

근사함수 V_θ 를 식 (12)와 식 (13)에 적용한 최적 제어식은 식 (14), 식 (15)와 같다.

$$\omega_p^* = \arg \min_{\omega_p} \nabla_{s_p} V_\theta \cdot f(s_p, \omega_p) \quad (14)$$

$$\omega_e^* = \arg \max_{\omega_e} \nabla_{s_e} V_\theta \cdot f(s_e, \omega_e) \quad (15)$$

식 (14), 식 (15)를 완화하여 실제 구현에서는 $\nabla_{s_i} V_\theta$ 의 방향과 현 침로 방향의 차이를 기준으로 비례제어를 적용한 Algorithm 1(Fig. 2 참조)을 사용하여 ω_i 를 구하였다. 이때 k_ω 는 제어 상수, $warp(\alpha)$ 는 각도를 $(-\pi, \pi)$ 로 변환하는 함수이며 식 (16)과 같다.

Input: $s, g_p = \nabla s_p V_\theta, g_e = \nabla s_e V_\theta$
Output: ω_p, ω_e

```

 $\psi_p \leftarrow \text{atan2}(g_{py}, g_{px}); \delta h_p \leftarrow \text{warp}(\psi_p - h_p)$ 
 $\omega_p \leftarrow \text{clip}(-k_\omega \cdot \delta h_p, -\bar{\omega}, \bar{\omega})$ 
 $\psi_e \leftarrow \text{atan2}(g_{ey}, g_{ex}); \delta h_e \leftarrow \text{warp}(\psi_e - h_e)$ 
 $\omega_e \leftarrow \text{clip}(-k_\omega \cdot \delta h_e, -\bar{\omega}, \bar{\omega})$ 
return  $[\omega_p, \omega_e]$ 

```

Fig. 2. Algorithm 1: approximate feedback controls

$$\text{warp}(\alpha) = (\alpha + \pi) \bmod 2\pi - \pi \quad (16)$$

근사함수 V_θ 를 학습하는 절차는 Algorithm 2와 같다(Fig. 3 참조). 총 에폭(epoch) 수 E 에 대해 매 에폭마다 B 개의 미니 배치 샘플을 추출한다. 각 샘플은 임의의 s 와 t 로 구성되며 s 는 상태 공간 S 에서, t 는 $[0, T]$ 에서 균등 분포로 추출한다.

```

Initialize  $\theta$ 
for epoch = 1 ... E
  sample mini-batch  $(s_n, t_n)$ 
  for each  $n$ 
     $V_n \leftarrow V_\theta(s_n, t_n)$ 
     $g_n \leftarrow \nabla s V_\theta(s_n, t_n)$ 
     $(\omega_p^n, \omega_e^n) \leftarrow \text{Algorithm 1}(s_n, g_n)$ 
     $s_p^+ \leftarrow s_p^n + \Delta t f_p(s_p^n, \omega_p^n)$ 
     $s_e^+ \leftarrow s_e^n + \Delta t f_e(s_e^n, \omega_e^n)$ 
     $s_n^+ \leftarrow [s_p^+, s_e^+]^T; t_n^+ \leftarrow t_n + \Delta t$ 
    if  $t_n^+ < T$ 
       $y_n \leftarrow V_\theta(s_n^+, t_n^+)$ 
    else
       $y_n \leftarrow \ell(s_n^+)$ 
    endif
   $L \leftarrow (1/B) \sum (V_n - y_n)^2$ 
   $\theta \leftarrow \theta - \text{Adam}(\nabla_\theta L, \eta)$ 
end for

```

Fig. 3. Algorithm 2: Training V_θ

샘플 (s_n, t_n) 은 신경망 V_θ 를 통과하여 출력값 V_n 을 얻을 수 있으며, 자동 미분을 통해 기울기 g_n 을 계산할 수 있다. Algorithm 1을 통해 각 샘플의 제어 입력을 유도한 후 이를 이산 동역학 모델에 입력하여 시간 t^+ 에 대한 상태 s^+ 를 도출한다.

1-step temporal difference를 적용하기 위해 목적 함수를 다음과 같이 정의하였다. 만약 t^+ 가 T 이내이면 V_θ 의 값을 목적 값(target value)으로 설정하고, T 를 초과하는 경우 $\ell(s^+)$ 를 목적 값으로 한다. 최종 식은 식 (17)과 같다.

$$y(s, t) = \begin{cases} V_\theta(s^+, t^+), & t^+ < T \\ \ell(s^+), & t^+ \geq T \end{cases} \quad (17)$$

미니 배치의 각 샘플에 대해 목적 값을 결정한 후 해당 미니 배치는 MSE(mean squared error) 손실 함수(loss function)를 적용하여 손실 값(loss value) L 을 계산한다. 이후 Adam 최적화 기법을 학습률 η 로 적용하여 V_θ 의 매개변수 θ 를 갱신(update)한다.

4. 실험 및 결과

실험 환경 구성은 다음과 같다. 미니 배치 샘플은 매 에폭마다 128개씩 랜덤하게 생성하였으며 생성 시 위치 좌표는 $[-3, 3]$, θ 는 $[0, 2\pi]$ 범위에서 추출하고 T 는 1을 적용하였다. 시뮬레이션 시간 간격 Δt 는 0.05를 사용하였다. k_ω 는 2.0, $\bar{\omega}$ 는 1 rad를 적용하였으며, 추적자의 속도는 목표 선박 대비 1.2배 빠른 상황을 가정하였다. 종말 비용함수에서 R 은 1, ϕ_{th} 는 30° 를 사용하였다. 학습 시 총 에폭은 10,000회를, 학습률 η 은 0.001을 적용하였다. 모든 매개변수는 실험을 통해서 최적값을 도출하였다. 또한 구글 코랩(Google Colab)의 NVIDIA T4 GPU를 사용하였다.

Fig. 4는 학습 과정에서의 손실 값의 변화를 도식화한 그림이다. 학습 초기에는 손실 값이 크게 변화하였으나, 에폭이 진행됨에 따라 점차 안정적으로 감소하여 약 4,000에 폭 이후에는 학습이 수렴됨을 확인할 수 있다. 이 결과는 인공지능망 기반의 잔여 비용함수가 근사해를 정상적으로 학습하였음을 의미한다.

Fig. 5는 학습이 완료된 V_θ 를 이용하여 다양한 초기조건에서 추적자와 목표 선박의 기동 경로를 도식화한 그림이다. 그림에서 청색 점선은 추적자를 적색 실선은 목표 선박을 의미하며 각 점은 시작 위치를 표현한다.

먼저 Fig. 5(a)는 서로 마주 보는 상황으로 추적자와 목표 선박 모두 생존확률이 낮은 최악의 상황을 가정한다. 시작 시 목표 선박은 좌현으로 추적자는 우현으로 변침하였다. 추적자는 우현에 있는 목표 선박과의 거리를 좁히기 위해 지속해서 우회두하였으며 목표 선박은 좌회두로 반전하여 추적자로부터 이탈을 시도하였다. 최종적으로 추적자는 목표 선박의 변침을 강요하여 기동을 제한함과 동시에 목표 선박에 함미에 위치함을 확인할 수 있다.




Fig. 4. Training loss curve over epochs with 100-step moving average smoothing

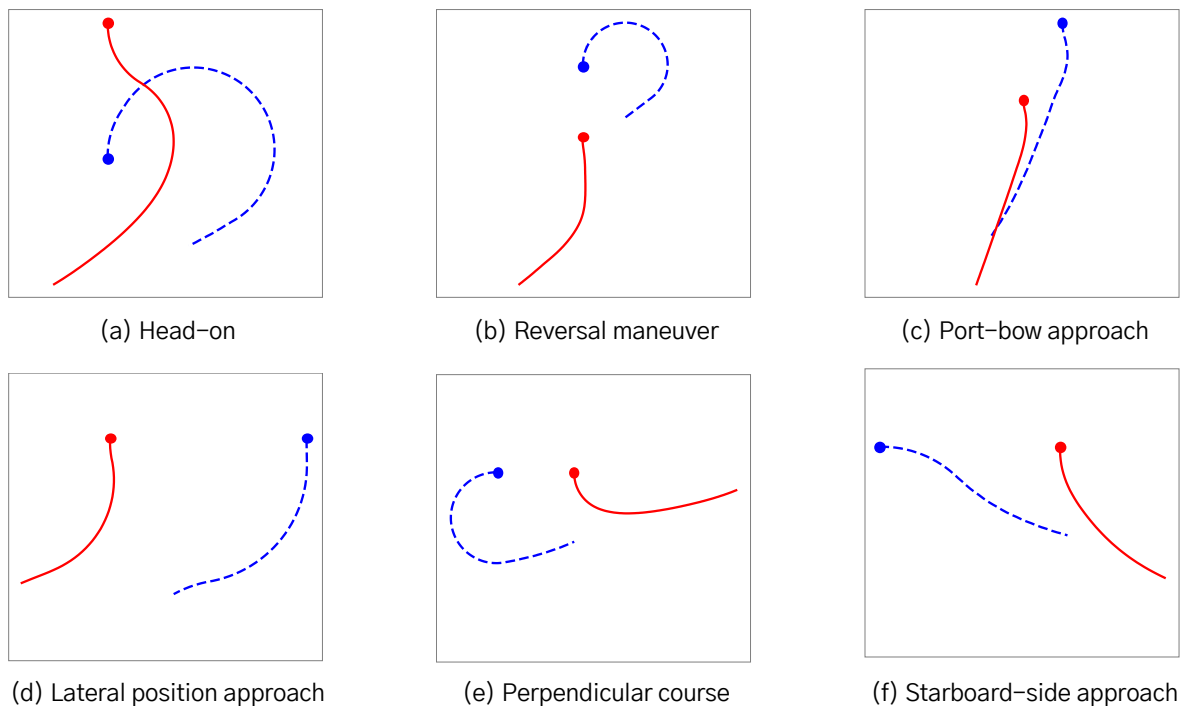


Fig. 5. Sample trajectories of the pursuer(blue, dashed) and the evader(red, solid) under different initial conditions (filled circles: denote starting position)

Fig. 5(b)는 반대 상황으로 시작과 동시에 추적자가 우현 급변침하여 목표 선박 방향으로 반전하였으며, 목표 선박은 최초 180° 방향으로 기동하다 추적자의 반전을 확인 후 200° 방향으로 변침하여 이탈을 시도하였다.

Fig. 5(c)는 추적자가 목표선박의 좌현 함수에서 접근하는 상황으로 추적자는 목표선박 쪽으로 좌현 변침 후 목표선박의 함수에 위치하였다.

Fig. 5(d)는 목표 선박의 측면에 있는 상황으로 추적자는 목표 선박 방향으로 완만하게 변침, 목표 선박의 변침을 유도하여 최종적으로 목표 선박의 함수에 위치함을 확인할 수 있다.

Fig. 5(e)는 추적자와 목표 선박의 시작 침로가 시

계방향으로 90° 차이가 나는 상황으로 추적자는 목표 선박 방향으로 좌현 변침하여 목표 선박의 변침을 유도, 최종적으로 목표 선박의 함수에 위치하였다.

Fig. 5(f)는 목표 선박의 우현으로 추적자가 접근하는 상황으로 목표 선박은 좌현 변침하여 이탈을 시도하였고, 추적자는 우현 변침하여 목표 선박의 침로에 맞추어 접근하는 모습을 보인다.

Fig. 5의 모든 경우에서 확인할 수 있듯이, 추적자는 V_θ 의 기울기 값을 이용하여 안정적인 변침각으로 목표 선박에 접근하는 전략을 취하고 있으며, 목표 선박은 추적자의 전략에 따라 변침을 하며 회피하는 모습을 보인다. 목표 선박은 이탈을 위해 계속해서 회피를 시도하지만 결국 추적자의 함미 근접을 허용하는

모습을 보인다. 이러한 결과를 통해 제안한 기법이 다양한 교전 상황에서 일관된 성능을 보임을 확인할 수 있다.

5. 결론

본 논문에서는 USV가 이동 표적을 추적하는 과정에 적용 가능한 인공신경망 기반의 근사 경로 계획 기법을 제안하였다. 제안한 기법은 HJB 방정식을 인공신경망 모델로 근사하는 방법으로 추적자 USV가 목표 선박에 접근하는 경로를 생성하는데 중점을 두었다. 제안한 기법은 거리가 방위가 제한된 접근 조건을 만족하는 경로를 안정적으로 생성하였으며, 초기 조건을 다양하게 설정한 시뮬레이션을 통해 생성된 경로의 전술적 타당성을 검증하였다.

향후 연구에서는 다수의 USV가 협력하는 상황에서 복수의 목표 선박을 효율적으로 추적하는 방법 및 PINN(physical informed neural network)를 적용하여 모델의 외삽 능력을 확장하고자 한다.

참고문헌

[1] H. J. Lee, P. H. Kim, and K. H. Lim, "Development of the Unmanned Maritime System (UMVs) in Neighboring

Countries and Its Implications for the Republic of Korea Navy," *Journal of the KNST*, Vol. 6, No. 3, pp. 314–319, 2023.

[2] K.M. Kim and Jungmok Ma, "A Study on the Research Trends in Unmanned Surface Vehicle using Topic Modeling," *Journal of the Korea Academia-Industrial cooperation Society*, Vol. 21, No. 7, pp. 597–606, 2020.

[3] Dooyoung Kim, "Path Planning for Autonomous Unmanned Surface Vehicle Recovery: A Potential Field Approach," *Journal of the KNST*, Vol. 7, No. 4, pp. 428–432, 2024.

[4] Kyunghwan Son et al., "On the Efficiency of Running Machine Learning Tasks for Drone-Based Target Tracking: Cloud-Based vs. Drone-Based," *The Journal of Korean Institute of Communications and Information Sciences*, Vol. 43, No. 1, pp. 143–151, 2018.

[5] Daewoo Kim et al., "AI-based Drone Object Tracking System: Design and Implementation," *The Journal of Korean Institute of Communications and Information Sciences*, Vol. 42, No. 12, pp. 2391–2401, 2017.

[6] Minsung Park and Bo Woo Nam, "Optimal Coverage Path Planning for Unmanned Surface Vehicles Using Flexible Formation Tracking Control," *Journal of Ocean Engineering and Technology*, Vol. 39, No. 3, pp. 287–298, 2025.

[7] R. Isaacs, *Differential Games: A Mathematical Theory with Applications to Warfare and Pursuit, Control and Optimization*. New York, NY: Wiley, 1965.