

해상 레이더 데이터를 이용한 IMM-PDAF 기반 다중 객체 추적

Multi-Target Tracking Using IMM-PDAF with Marine Radar Data

유태훈 · 방현태 · 윤원근*
충남대학교 자율운항시스템공학과

Tae-Hoon Yoo · Hyeon-Tae Bang · Won-keun Youn*

Department of Autonomous Vehicle System Engineering, Chungnam National University, Chungcheongnam-do, 34134, Korea

[요약]

본 연구에서는 정확한 실시간 해상 표적 추적을 위해 여러 동적 모델을 통합하는 다중 표적 추적 알고리즘인 상호 작용 다중 모델-확률적 데이터 연관 필터(IMM-PDAF)를 소개한다. 해상에서의 다중 표적 추적은 복잡한 동적 환경과 다양한 움직임 패턴으로 인해 높은 정확도가 요구된다. 기존의 CV-PDAF(등속도 모델) 및 CT-PDAF(선회 모델)는 각각 일정한 움직임 패턴을 가정하지만, 이러한 단일 모델로는 다양한 해상 환경에서 발생하는 복잡한 움직임을 모두 처리하기 어렵다. 본 연구는 이러한 문제를 해결하기 위해 상호 작용 다중 모델-확률적 데이터 연관 필터(IMM-PDAF)를 제안하며 해상 RADAR 데이터에 적용된 본 논문의 결과는 제안된 IMM-PDAF가 CV-PDAF 및 CT-PDAF에 비해 상대적으로 낮은 RMSE 값을 보이며 복잡한 동적 환경에서도 강력한 위치 지정 성능을 가진다는 것을 보여준다. 따라서 이 연구 결과는 제안된 IMM-PDAF가 해상 감시 시스템의 신뢰성과 효율성을 개선하고 복잡한 추적 환경에 대한 다중 표적 추적 솔루션을 제공할 수 있는 잠재력을 강조한다.

[Abstract]

In this study, we introduce an interactive multi-model-probabilistic data association filter (IMM-PDAF), a multi-target tracking algorithm that integrates multiple dynamic models for accurate real-time maritime target tracking. Multi-target tracking in the maritime environment requires high accuracy due to the complex dynamic environment and various movement patterns. The existing CV-PDAF (constant velocity model) and CT-PDAF (circling model) each assume a constant movement pattern, but it is difficult to handle all the complex movements occurring in various maritime environments with these single models. To solve this problem, this study proposes an interactive multi-model-probabilistic data association filter (IMM-PDAF), and the results of this paper applied to maritime RADAR data show that the proposed IMM-PDAF has relatively lower RMSE values than CV-PDAF and CT-PDAF, and has strong positioning performance even in complex dynamic environments. Therefore, this study results highlight the potential of the proposed IMM-PDAF to improve the reliability and efficiency of maritime surveillance systems and provide a multi-target tracking solution for complex tracking environments.

Key word : Multiple target tracking (MTT), Interacting multiple model (IMM), Probabilistic data association filter (PDAF), Marine radar, Kalman filter.

<http://dx.doi.org/10.12673/jant.2024.28.5.640>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 24 September 2024; Revised 27 October 2024
Accepted (Publication) 29 October 2024 (31 October 2024)

*Corresponding Author; Wonkeun Youn

Tel: +82-42-821-6622

E-mail: wkyoun@cnu.ac.kr

1. 서론

다중-객체 추적을 위한 기존 알고리즘으로는 확률적 데이터 연관 필터 (PDAF; probabilistic data association filter)와 결합 확률적 데이터 연관 필터 (JPDA; joint-probabilistic data association) 등이 있다. 이는 센서로부터 측정된 값들을 객체에 연관시키고, 시간이 지나면서 객체를 지속해서 식별해 나가는 확률론적 구조를 제공한다[2]. 특히 JPDA 기법은 모든 실현 가능한 결합 사건의 경우의 수를 고려하여 데이터 연관확률을 계산한다. 이 때문에 여러 표적끼리 근접하거나 유효 측정치가 무수히 많을 경우 실현 가능한 결합 사건의 경우의 수가 기하급수적으로 증가하게 되므로 실질적으로 사용되기에는 매우 제한적이다. 따라서 이를 보완하고자 LBP (loopy belief propagation) 알고리즘을 활용하여 계산량을 줄이는 기법이 존재하며[3], k-means 알고리즘을 통해 측정값들을 군집화(clustering)하여 중앙값(centroid measurement)만을 사용하는 EC-JPDA (extended centroid-based jpda) 기법도 있다[4]. 또한, 단일-객체 연관 필터(PDAF)의 확장형인 MPDAF (multiple probabilistic data association)가 제안되어 복잡한 해상 환경에서 다중 객체 추적의 가능성을 입증하였다[5]. 이러한 기법들은 특히 레이더 데이터를 기반으로 실시간 위치 추적에 효과적이지만, 다양한 시나리오에서 발생할 수 있는 운동 패턴의 변화에 실시간으로 반영하는데 한계점을 드러낸다.

따라서 본 논문에서는 상호 작용 다중모델 필터(IMM; Interacting Multiple Model)에 PDAF를 접목한 IMM-PDAF를 제안한다. IMM은 모델링 불확실성을 다루기 위해 설계된 알고리즘으로, 시스템 또는 측정 모델에 대한 의존도를 조정하는 단계를 특징으로 하여 시스템 모델 오류에 대한 견고성을 향상한다[6]. 여기에 데이터 연관확률 필터를 더한 IMM-PDAF는 여러 가지 운동 모델을 동시에 고려함과 동시에 raw 레이더 데이터 중에서 유효한 레이더 데이터를 추출해 객체 추적을 하기 때문에, 다양한 동역학적 상황에 효과적으로 적용될 수 있는 장점이 있다[7]. 이 알고리즘은 다양한 추적 시나리오에서 유연성을 제공하며, 특히 클러터가 많은 환경에서도 높은 추적 정확도를 보장한다.

본 연구에서는 기존 IMM-PDAF와는 달리, 가상 시뮬레이션 데이터가 아닌 실제 해상 환경에서 획득한 레이더 데이터를 기반으로 실험을 수행하였다[7]. 또한 본 연구에서는 레이더 전처리를 이용하여 측정치의 Raw data인 블롭(Blob)을 추출하고, 이를 측정값으로 변환한 후 IMM-PDAF 알고리즘을 적용하여 다중 객체 추적을 성공적으로 수행하였다. 이 과정은 기존 연구들에서 시도되지 않은 방법론으로, 특히 복잡한 해상 환경에서의 객체 추적에 대한 실질적인 해결책을 제시한다는 점 환경에서 레이더 데이터를 활용하여 효과적으로 객체를 추적하는 방법을 탐구하여, 기존 PDAF 알고리즘과의 성능을 비교하여 IMM-PDAF의 우수성을 입증할 것이다. 또한, 본 연구는 일반적인 IMM-PDAF 알고리즘과는 달리, 모델 혼합 및 전환 확률

계산, 게이팅 및 데이터 연관의 최적화, 그리고 실시간 적용을 위한 계산 복잡도 감소 등의 개선을 통해 해상 환경에서의 다중 객체 추적 성능을 향상시켰다. 기존 PDAF에서는 단일 시스템 운동 모델만을 이용하여 객체 추적을 한다면, 본 연구에서의 IMM-PDAF에서는 등속 운동 모델(CV; constant velocity)과 등속 선회 모델(CT; coordinated turn) 두 개의 모델의 혼합 확률을 결합하여 객체 추적을 하기에 높은 추적 성능을 보일 것으로 예상된다. 2장에서 IMM-PDAF 알고리즘에 관하여 클러터가 있는 환경에서 다중-객체 추적의 정확성을 향상시키기 위해 데이터 연관 방법과 모델을 혼합하는 방법을 설명할 것이다. 3장에서는 레이더 이미지 세트를 선박자동식별장치(AIS; automatic identification system) 데이터로 처리하는 방법과 raw 레이더 데이터를 이용하여 IMM-PDAF 알고리즘에 적용하는 과정까지 다뤄볼 예정이며, 4장을 결론으로 마무리할 것이다.

II. 다중 객체 추적 시스템

2-1 Interacting multiple model probabilistic data association filter algorithm (IMM-PDAF)

IMM-PDAF는 다중모델 접근 방식을 적용하여 객체 추적이 이루어지는 확장된 확률적 데이터 연관 필터이다. 이 방법은 PDAF의 기본 개념을 발전시켜, 다양한 운동 모델에 적합하도록 설계되었다. 또한, IMM-PDAF는 각 운동 모델에 따라 PDAF를 독립적으로 적용하고, 이를 통합하여 복잡한 상황에서의 센서 측정치 오류와 중복을 효과적으로 관리한다. 본 논문에서 PDAF 단계에서는 CV, CT 모델을 모델별로 각자 단계를 거쳐 Model probability update 단계에서 모델 간의 전환 확률에 따라 최적의 상태 추정치와 공분산을 계산하는 과정을 포함한다[8]. 이로 인해 센서의 고장이나 모호한 측정치로 인한 오류 상황에서도 정확한 대상 추적이 가능하며, 여러 대상에 대한 데이터를 동시에 처리할 수 있는 구조로써 PDAF보다 계산 요구량이 많지만, 그만큼 정밀한 추적이 가능하다.

IMM-PDAF의 구현은 기본적으로 칼만 필터에 기반하고 있으며, 대상의 시스템이나 측정 모델이 비선형일 경우 확장 칼만 필터(Extended Kalman Filter) 또는 무향 칼만 필터(Unscented Kalman Filter)를 적용할 수 있다[9]. 또한, Gating 단계와 Data association 단계를 거침으로써, 클러터 환경에서 측정치들과 아닌 것들의 구분이 가능해지며, 각 표적 상태의 확률적 추정치를 보다 정확하게 조정할 수 있다. 이는 각 표적의 운동 모델이 시간에 따라 변할 수 있는 다중표적 환경에 특히 적합하다. 전체 프로세스의 흐름은 그림 1에서 설명되어 있다. 크게 Interacting/mixing, PDAF, Model probability update, Combination 4단계로 나눌 수 있다. 2.1.1절부터 IMM-PDAF를 단계별로 설명한다.

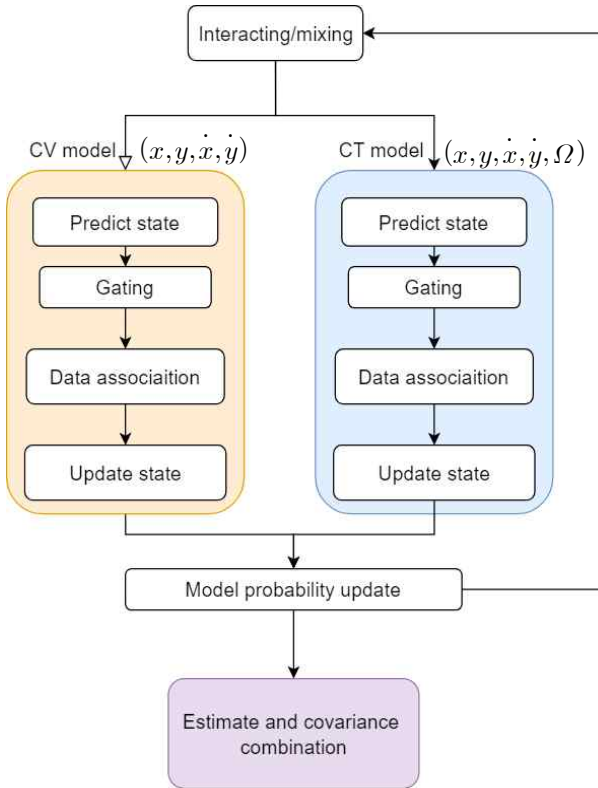


그림 1. IMM-PDAF의 흐름도
Fig. 1. Flow chart of IMM-PDAF.

2.1.1 Interacting/mixing 단계

Interacting/mixing 단계는 등속 운동 모델과 등속 선회 모델 간의 상호 작용과 정보의 혼합을 설명한다. 이 과정에서 각 모델의 추정 상태와 공분산 정보는 상호 영향을 주고받으며, 다양한 운동 모델 환경에서 더욱 정확한 예측이 된다. 각 모델의 가중치가 조정되며, 결과적으로 이 단계는 객체의 동적 특성을 고려한 보다 민감하고 정밀한 추정치를 제공한다. 식 (1) 및 식 (2)에서는 혼합확률 업데이트에 관한 식으로 이전 단계의 각 모델에 대한 사후 확률을 고려하여 계산된다. \bar{c}_j 는 정규화 상수 (Normalization constant)로, 여러 모드의 혼합확률을 합산하여 특정 모드의 혼합확률이 전체 확률 분포 내에서 적절히 비율을 가지도록 하는 값을 의미하며 모든 확률값들의 합이 1이 되게 한다. N 은 전체 모델의 개수이고, p_{ij} 는 시간 $k-1$ 에서 모드 i 에서 모드 j 로의 전환 확률을 의미한다. 식 (3) ~ 식 (4)에서는 혼합확률을 이용하여 추정값과 공분산을 모델 간 혼합을 계산한 식이다.

$$\mu_{k|k-1}^{ij} = \frac{1}{c_j} p_{ij} \mu_{k-1}^i \quad (1)$$

$$\bar{c}_j = \sum_{i=1}^N p_{ij} \mu_{k-1}^i \quad (2)$$

$$\mathbf{x}_{k-1|k-1}^{0j} = \sum_{i=1}^N \mu_{k-1|k-1}^{ij} \hat{\mathbf{x}}_{k-1|k-1}^i \quad (3)$$

$$\mathbf{P}_{k-1|k-1}^{0j} = \sum_{i=1}^N \mu_{k-1|k-1}^{ij} \cdot [\mathbf{P}_{k-1|k-1}^{i|k-1} + (\hat{\mathbf{x}}_{k-1|k-1}^i - \hat{\mathbf{x}}_{k-1|k-1}^{0j}) \times (\hat{\mathbf{x}}_{k-1|k-1}^i - \hat{\mathbf{x}}_{k-1|k-1}^{0j})^T] \quad (4)$$

2.1.2 Prediction 단계

본 연구에서 제안하는 IMM-PDAF의 Prediction 단계는 표준 칼만 필터를 기반으로 하되, 다중모델 구조를 적용하여 각 객체에 대해 더욱 정밀한 예측을 제공한다. 본 연구에서 사용된 시스템 모델 행렬은, 객체의 운동 상태를 묘사하기 위해 CV, CT 모델의 모델 행렬을 적용하였다. 이를 통해 선형 및 비선형 운동 패턴을 모두 포착할 수 있다. 측정 모델 행렬은 처리된 레이더 이미지의 동쪽(m) 및 북쪽(m) 위치 측정치만을 고려하여 구성하였다. 이는 센서 데이터에서 직접 관찰할 수 있는 위치 정보에 초점을 맞춘 선택이다. 샘플링 주기 T 는 데이터의 전송 주기와 동기화되어 1초로 설정되었다. 이는 실시간 위치 추적의 필요성을 반영한 설정이다. 상태변수는 선박의 2차원 위치 (x, y) 와 속도 (\dot{x}, \dot{y}) 를 포함하며, 각 객체의 운동 상태를 전체적으로 표현한다. 식 (5) ~ 식 (9)는 AIS 데이터에 기반한 초기 상태변수 값의 계산을 설명한다. 각 표적의 초기 상태변수 설정은 해당 표적의 초기 AIS 데이터를 사용하여 구성하였고, 이는 속도(Speed Over Ground, SOG)와 방향(Course Over Ground, COG) 정보가 단위 변환을 거쳐 포함되었다. CT 모델의 경우, 선회율 Ω 를 상태 변수에 포함하여 곡선 운동을 보다 정확하게 묘사할 수 있도록 하였다. 선회율은 객체의 회전 운동을 표현하는 데 필수적이므로, 이를 상태 변수에 포함시킴으로써 CV 모델과의 차별화를 명확히 하고, 더 정밀한 예측이 가능하도록 하였다.

$$x = \text{East of the AIS} \quad (5)$$

$$y = \text{North of the AIS} \quad (6)$$

$$\dot{x} = \text{SOG} \cdot \cos(\text{COG}) \quad (7)$$

$$\dot{y} = \text{SOG} \cdot \sin(\text{COG}) \quad (8)$$

$$\Omega = \text{rate [rad/s]} \quad (9)$$

식 (10) ~ 식 (15)는 Prediction 단계가 요약되어 있고, 초기 오차 공분산 \mathbf{P}_0 과 시스템 잡음 공분산 \mathbf{Q}_{k-1}^j , 그리고 F_{k-1}^j 는 3장에 정의되어 있다. 식 (10) 및 식 (11)을 보면 CT 모델은 비선형이기 때문에 F_{k-1}^{CT} 를 선형화하는 Jacobian 편미분 식을 사용하여 구하였다[10]. j 는 모델 CV, CT를 지칭하는 변수로 모든 단계에서는 모델별로 각각 진행된다.

$$\hat{\mathbf{x}}_{k|k-1}^j = \mathbf{F}_{k-1}^j \hat{\mathbf{x}}_{k-1|k-1}^{0j} \quad \dots \text{ (CV model)} \quad (10)$$

$$\hat{\mathbf{x}}_{k|k-1}^j = f(\hat{\mathbf{x}}_{k-1|k-1}^{0j}) \quad \dots \text{(CT model)} \quad (11)$$

$$\mathbf{F}_{k-1}^j = \frac{\partial f_k}{\partial x} \Big|_{x = \hat{x}_{kvertk-1}^{0j}} \quad \dots \text{(CT model)} \quad (12)$$

$$\mathbf{P}_{k|k-1}^j = \mathbf{F}_{k-1}^j \mathbf{P}_{k-1|k-1}^j \mathbf{F}_{k-1}^T + \mathbf{Q}_{k-1}^j \quad (13)$$

$$\hat{\mathbf{z}}_{k|k-1}^j = \mathbf{H}_k^j \hat{\mathbf{x}}_{k|k-1}^j \quad (14)$$

$$\mathbf{S}_k^j = \mathbf{H}_k^j \mathbf{P}_{k|k-1}^j \mathbf{H}_k^T + \mathbf{R}_k^j \quad (15)$$

2.1.3 Gating 단계

본 연구에서 제안하는 IMM-PDAF 모델은 여러 측정치 중에서 효과적으로 유효 측정치를 선별하기 위한 Gating 단계를 포함한다. 이 단계는 예측된 측정치와 레이더로부터의 모든 측정치 사이의 마할라노비스 거리(Mahalanobis distance)를 활용하여 게이트 임계값(Gate threshold) 이하일 때만 측정치를 유효 측정치로 식별한다. 이 과정은 불필요한 계산을 줄이고, 시간 복잡도를 관리하기 위한 중요한 절차이다. 유효 영역 γ 는 카이 제곱 분포의 역 누적분포 함수를 통해 결정된다.

$$\mathbf{M}_k = (\mathbf{z} - \hat{\mathbf{z}}_{k|k-1})^T \mathbf{S}_k^{-1} (\mathbf{z} - \hat{\mathbf{z}}_{k|k-1}) \quad (16)$$

$$\mathbf{M}_k \leq \gamma \quad (17)$$

그림 2에서 보듯이, 레이더로부터 얻은 raw 데이터 중 식 (17)의 조건을 충족할 때 유효한 측정값으로 간주한다. 이 조건을 충족하지 못한 측정값들은 분석에서 제외되며, 유효 측정값들만이 IMM-PDAF 알고리즘의 업데이트 단계에 사용된다. 이 과정을 통해 불필요한 데이터를 걸러내고, 추적의 정확도를 향상하는 데 중요한 기여를 한다.

2.1.4 Data association 단계

Data Association 단계는 센서로부터 수집된 측정치들이 실제 객체와 어떻게 관련되는지를 확정하는 과정이다. 이 과정은 각 측정치가 특정 객체에 속할 확률을 계산함으로써, 측정 데이터의 불확실성을 관리하고, 객체의 상태 추정치를 정확히 업데이트하는 데 필수적이다.

$$\beta_k^i = \begin{cases} \frac{\mathcal{L}_k^i}{1 - P_D P_G + \sum_{j=1}^{m_k} \mathcal{L}_k^j}, & i = 1, \dots, m_k \\ \frac{1 - P_D P_G}{1 - P_D P_G + \sum_{j=1}^{m_k} \mathcal{L}_k^j}, & i = 0 \end{cases} \quad (18)$$

식 (18)은 유효측정 영역 내에 존재하는 모든 유효 측정치들에 대해 표적에 의해 발생한 것이라고 가정된 후 이에 대한 확률 β_k^i 을 계산하는 식이다. P_D 는 객체가 탐지될 확률을, P_G 는




그림 2. 검증을 통과한 게이팅 프로세스 측정

Fig. 2. Gating process measurements that pass validation.

표 1. 각 DOF에 대한 상수

Table 1. Constant c_{n_z} for each DOF.

	$n_z = 1$	$n_z = 2$	$n_z = 3$
c_{n_z}	2	π	$\frac{4}{3}\pi$

탐지된 객체의 측정값이 게이트 기준 내에 있을 확률을 나타낸다. m_k 는 유효 측정치의 수를 의미한다. $i = 0$ 인 경우는 Gating 단계를 만족하는 측정치가 없고 객체가 탐지되지 않은 상황을 나타낸다.

$$\mathcal{L}_k^i = \frac{N(\mathbf{z}_k^i; \hat{\mathbf{z}}_{k|k-1}, \mathbf{S}_k) P_D}{\lambda} \quad (19)$$

식 (19)는 클러터가 아닌 표적으로부터 발생한 유효 측정값 \mathbf{z}_k^i 의 우도 비 \mathcal{L}_k^i (likelihood)를 나타낸다. λ 는 유효 영역 부피 V_k 당 유효 측정치 m_k 의 수, 즉 공간 밀도를 정의하고 이는 푸아송 분포를 따른다. 밀도 값은 따로 설정하지 않고, 다음과 같은 관계를 사용하여 밀도를 계산했다.

$$\lambda = \frac{m_k}{V_k} \quad (20)$$

$$V_k = c_{n_z} |\gamma \mathbf{S}_k|^{1/2} = c_{n_z} \gamma^{n_z/2} |\mathbf{S}_k|^{1/2} \quad (21)$$

본 연구에서는 자유도(DOF; degree of freedom) n_z 를 2차원으로 가정하였다. 여기서 V_k 는 n_z 차원에서 정의된 유효 영역의 부피를 나타낸다. 각 차원의 자유도 n_z 에 따라 변하는 상수 c_{n_z} 의 값은 표 1에서 제시되어 있다.

2.1.5 Update 단계

이 단계에서는 이전 단계에서 계산된 연관확률 β_k^i 를 사용하여 표준 칼만 필터의 구조와는 차별화된 접근 방식을 채택한다.

이 구조는 식 (22) ~ 식 (27)에 요약되어 있다.

$$\mathbf{v}_k^j = \sum_{i=1}^{m_k} \beta_k^i \mathbf{v}_k^i \tag{22}$$

$$\mathbf{K}_k^j = \mathbf{P}_{k|k-1}^j \mathbf{H}_k^T \mathbf{S}_k^{-1} \tag{23}$$

$$\hat{\mathbf{x}}_{k|k}^j = \hat{\mathbf{x}}_{k|k-1}^j + \mathbf{K}_k^j \mathbf{v}_k^j \tag{24}$$

$$\mathbf{P}_{k|k}^j = \beta_k^0 \mathbf{P}_{k|k-1}^j + [1 - \beta_k^0] \mathbf{P}_{k|k}^c + \tilde{\mathbf{P}}_k^j \tag{25}$$

$$\mathbf{P}_{k|k}^c = \mathbf{P}_{k|k-1}^j - \mathbf{K}_k^j \mathbf{S}_k \mathbf{K}_k^{jT} \tag{26}$$

$$\tilde{\mathbf{P}}_k = \mathbf{K}_k^j \left[\sum_{i=1}^{m_k} \beta_k^i \mathbf{v}_k^i (\mathbf{v}_k^i)^T - \mathbf{v}_k \mathbf{v}_k^T \right] \mathbf{K}_k^j \tag{27}$$

추정값 $\hat{\mathbf{x}}_{k|k}^j$ 은 칼만 이득 \mathbf{K}_k^j 와 측정 잔차 \mathbf{v}_k 의 곱으로 인해 업데이트된다. 사후 오차 공분산 $\mathbf{P}_{k|k}^j$ 는 측정값이 없을 때 업데이트되지 않는다. 이는 유효 측정값이 없음을 나타내는 확률 β^0 가 1일 때 해당하며, 이 시점에서는 새로운 측정치를 사용한 업데이트가 이루어지지 않는다. 반면, β^0 가 1이 아닐 경우, 즉 측정값이 존재할 때는 $\mathbf{P}_{k|k}^c$ 를 사용하여 공분산이 업데이트되며, 이는 새로운 데이터에 따라 조정된다. 나머지 공분산 요소인 $\tilde{\mathbf{P}}_k$ 는 유효한 측정값 중 실제 측정값을 정확히 알 수 없을 때 사후 오차 공분산 값을 증가시키는 역할을 한다.

2.1.6 Models probability update 단계

IMM 접근법은 여러 가지 모델을 동시에 사용하여 표적의 동적인 상태를 추정한다. 이 방법은 각기 다른 운동 모델을 가진 여러 상태 추정치들을 조합하여, 실제 표적의 동작을 더 정확히 예측할 수 있도록 한다. 식 (28) ~ 식 (30)까지 각 모델의 확률을 업데이트하고, 추정치와 공분산을 모델 변환 확률의 가중치에 따라 계산한다. $\Lambda_k^{(i)}$ 는 식 (28)으로 주어지는 클러터가 존재하였을 때 측정 잔차의 결합 확률 밀도 함수이다.

$$\Lambda_k^j = p[\mathbf{v}_k^j | \mathbf{m}_{k^j}^j, \mathbf{Z}^{j-1}] \tag{28}$$

$$= \mathbf{V}_k^j (1 - \mathbf{P}_D \mathbf{P}_G) + \frac{\mathbf{V}_k^j \mathbf{P}_D \sum_{i=1}^{m_k^j} \mathbf{e}_k^i}{m_k \sqrt{|2\pi \mathcal{S}_k|}}$$

$$\mathbf{e}_k^j = \exp \left\{ -\frac{1}{2} (\mathbf{v}_k^j)' (\mathcal{S}_k^j)^{-1} \mathbf{v}_k^j \right\} \tag{29}$$

$$\mu_k^j = \frac{\mu_{k-1}^j \Lambda_k^j}{\sum_{j=1}^N \mu_{k-1}^j \Lambda_k^j} \tag{30}$$

2.1.7 Estimate and covariance combination 단계

이 단계에서는 모델의 추정치와 공분산을 결합하여 최종 상

태를 추정한다. 각 모델의 상태 추정치와 공분산은 모델 확률을 가중치로 하여 결합 된다. 이는 식 (31) ~ 식 (32)로 표현된다.

$$\hat{\mathbf{x}}_{k|k} = \sum_{j=1}^N \hat{\mathbf{x}}_{k|k}^j \mu_k^j \tag{31}$$

$$\mathbf{P}_{k|k} = \sum_i \left[\mathbf{P}_{k|k}^{(i)} + (\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k}^{(i)}) (\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k}^{(i)})^T \right] \mu_k^{(i)} \tag{32}$$

III. 다중 객체 추적 성능 검증

3.1 Radar 데이터 세트

이 장에서는 독일 항공우주센터(Deutsches Zentrum für Luft- und Raumfahrt e.V., DLR)의 두 종류 레이더 데이터 세트를 설명한다. 그림 3은 발트해 인근에서 수집한 선박의 AIS 데이터 궤적 중 일부를 찍은 위성 이미지다. 데이터는 DARC(data association with RACON), MANV(manoeuvres) 두 가지 주요 세트로 구성되어 있다. 각 데이터 세트에 대한 자세한 정보는 표 2에 요약되어 있으며, 레이더 이미지의 해상도는 MANV가 6미터, DARC는 11미터로 설정되었다.

그림 3. 발트해 주변 각 선박의 AIS 기록 경로
Fig. 3. AIS-recorded paths of each ship of the Baltic sea.

표 2. 목표 AIS 데이터 요약
Table 2. Summary of target AIS data.

Dataset	Target	Frame	Time [s]
MANV	6	976	1000
DARC	2	527	540

표 3. 각 AIS 데이터에 대한 선박 크기 사양

Table 3. Vessel size specifications for each AIS data.

Dataset	Participating targets	Length [m]	Width [m]
MANV	Target 2	29	7
	Target 3	23	6
DARC	Target 2	180	28

MANV 데이터 세트의 표적은 총 6개이지만 움직이지 않는 정적 객체로 판단하여 본 논문에서는 2개의 표적만을 다루었다. 마찬가지로 DARC 데이터 세트도 자선을 제외한 하나의 표적만을 다루었다. 동적 표적의 크기에 관한 데이터는 표 3에 기록되어 있다.

실험에 사용된 데이터 세트는 X-band 레이더를 사용하여 1 Hz의 주기로 측정되었다. 데이터 일부가 무작위로 손실된 것은 표 2에 나열된 프레임 수와 지속 시간을 통해 확인할 수 있다. 모든 이미지는 시간 순서에 따라 처리되었으며, 그 과정은 그림 4에 나타나 있고, 그에 대한 설명은 다음과 같다.

- (1) 레이더 이미지에서 불필요한 인터페이스 정보를 제거한 후 이미지를 그레이 스케일로 변환.
- (2) 설정된 임계값 이하의 불명확한 이미지 blob들을 제거하여 클러스터를 최소화.
- (3) DOH(determinant of Hessians)를 사용하여 남은 blob들을 정확히 탐지.
- (4) 각 blob의 거리와 베어링을 측정하여 ENU(East North Up) 좌표계로 변환하여 저장.

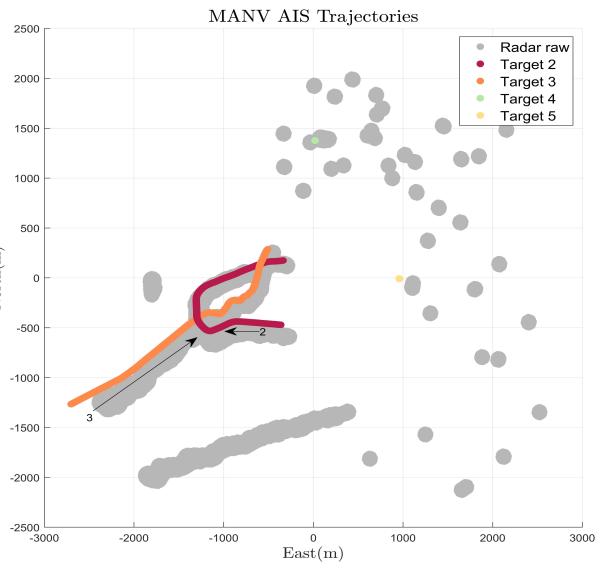
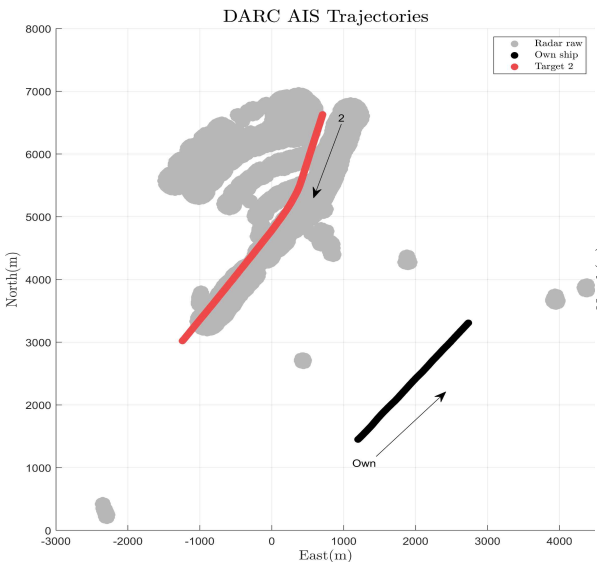


그림 5. 레이더 데이터(회색 점)를 포함한 궤적(색상) 시각화

Fig. 5. Trajectory(coloured) visualization including radar data(gray dots).

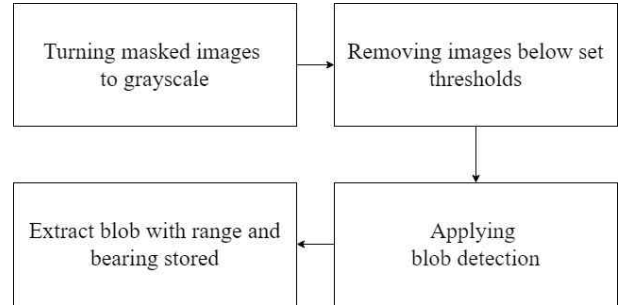


그림 4. 방위 및 범위 값을 포함한 레이더 이미지 처리 흐름도
Fig. 4. Flow chart of radar image processing with bearing and range values.

AIS 데이터는 선박의 속도에 따라 전송 주기가 변화하는 특성이 있어, 빠른 선박일수록 데이터 전송 주기가 짧아진다. 본 연구에서는 AIS 데이터를 레이더 데이터 주기와 일치시키기 위해 선형 보간 방법을 사용하였다. 사용된 AIS 데이터에는 위치, COG, SOG, 헤딩 각이 포함되어 있으며, 위치 데이터는 동쪽과 북쪽의 미터 단위로 변환되어 처리되었다.

그림 5는 각 데이터 세트별 AIS 궤적을 시각적으로 나타낸 것이고, 그림 6은 레이더 데이터를 처리하는 순서도이다. 그림 5에서 Target 4와 Target 5는 AIS 데이터에 포함되어 있는 정박해있는 선박을 나타낸다. 본 논문에서는 동적 객체를 표적으로 다루기로 하였기에 추적 대상에서 제외하였다.

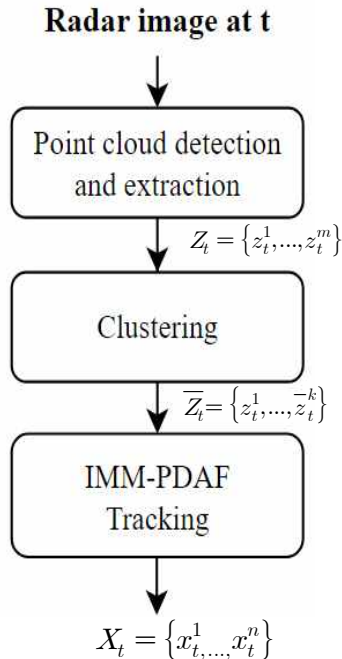


그림 6. 관찰 단계 t에서 처리 체인의 블록에 대한 설명.
 Fig. 6. Illustration of blocks in the processing chain at observation step t

또한, 그림 5의 DARC AIS trajectories를 보면 추적되는 선박의 크기가 크기 때문에(180 m × 28 m) AIS 안테나가 선박의 중심을 나타내지 않을 수 있다는 점을 고려해야 한다. 목표물 표면에서 발생하는 탐지로 인해 중심값이 크게 변동할 수 있으며 시간별 레이더 이미지가 들어오면 목표가 될 수 있는 신호를 감지하여 이미지를 처리하고 목표를 나타내는 blob을 식별하여 raw 데이터 집합 Z_t 를 추출한 후, k-means 클러스터링 알고리즘을 사용하여 클러스터의 중심을 계산하여 목표물의 측정치 집합 \bar{Z}_t 를 선정한다. AIS 데이터는 객체의 초기 위치 및 속도 값을 입력하는 용도로 활용된다. AIS 데이터로 초기화를 한 후, 측정치 집합 \bar{Z}_t 이 들어왔을 때, IMM-PDAF 알고리즘을 적용, 객체의 위치 및 속도를 추정하게 된다.

3.2 실험 결과

IMM-PDAF, CV-PDAF, CT-PDAF의 세 가지 추적 알고리즘을 DARC, MANV에 적용하여 위치 오차를 비교 분석하였다. 본 연구에서는 위치 오차 플롯을 궤적 플롯보다 먼저 제시함으로써, IMM-PDAF 알고리즘의 정밀도를 강조하고자 하였다. 그림 7-(a) 및 그림 7-(b)에서는 추정한 선박의 위치와 AIS 데이터에서 받은 위치를 Euclidean distance의 차이를 구하는 것으로, 그 식을 식 (33)에 정의하였다. 그림 7-(c) 및 그림 7-(d)에서는 선박의 위치를 추정한 결과를 그림으로 나타내었다.

$$\text{Position Error} = \sqrt{(Z_{\text{AIS},x} - \hat{X}_x)^2 + (Z_{\text{AIS},y} - \hat{X}_y)^2} \quad (33)$$

본 실험에서는 각 데이터 세트의 정적 장애물이나 자선의 상태는 고려하지 않고 오직 동적 표적의 위치만을 추정하였다. 사용된 매개변수는 표 6에 기록되어 있으며, 측정 잡음 공분산 R_k 와 공정 잡음 공분산 Q_k 는 데이터 세트에 따라 반복된 실험을 통해 조정되었다.

그림 7-(c) 및 그림 7-(d)에서 raw 레이더 데이터 중에서 데이터 연관 단계를 통해 유효한 레이더 데이터를 추출하여 안정적인 객체 추적이 이루어진 것을 알 수 있다. 이는 IMM-PDAF가 다양한 동적 모델을 효과적으로 관리하고, 복잡한 환경에서도 강건한 위치 추적 성능을 가지고 있음을 뜻한다. 그림 7-(c)에서 볼 수 있는 DARC는 클러스터가 다른 데이터보다 많이 관찰되었음에도, 위치 추정의 안정성을 확인할 수 있다.


관찰된 오차는 그림 7-(a)에서 볼 수 있듯이 상대적으로 높은 편이며, 이는 데이터 처리 과정에서 발생한 것으로 추정된다. 특히 DARC의 Target 2는 다른 대상들과는 다르게 길이와 폭이 긴 특성이 있고, AIS 안테나가 선박의 중앙이 아닌 다른 위치에 설치되어 있어 위치 추정 오차가 좀 더 크게 발생한 것으로 볼 수 있다. 그림 7-(d)를 보았을 때, MANV의 두 객체 Target 2, Target 3의 위치 추정을 보면 추정 궤적이 교차하는 데 이를 적절한 잡음 공분산 값을 정하여 조정해 정확한 위치 추정이 이루어지는 것을 확인할 수 있다. 그림 7-(d)의 초록색 선을 보면 AIS 데이터를 통해 초기화하여 초기 위치를 정하고 추적을 시작하는데, 레이더 측정값(Measurement)이 즉시 들어오지 않아, 예측(Prediction)만을 통해 타겟의 위치를 업데이트하다가 측정값이 들어오면 IMM-PDAF 알고리즘이 적용되어 실제 경로를 따라 추적되게 된다. 또한, MANV의 오차 그래프 그림 7-(b)를 보게 되면 DARC 세트와 다르게 IMM-PDAF와 CV-PDAF, CT-PDAF 사이에 낮은 오차 차이를 보이는데 이는 MANV의 두 객체 길이와 폭이 작고, Radar의 해상도가 정밀하기 때문이다. 본 연구에서 IMM-PDAF는 CV 모델과 CT 모델의 모델 변환 확률의 가중치를 계산하여 표적의 동적 변화를 정밀하게 추적하기 때문에 기존의 단일 모델 기반 알고리즘보다 우수한 성능을 제공하며, 실시간 해상 환경에서의 추적 시나리오에서 효과적임을 입증하였다. 표 4는 RMSE (root mean square error)값을 나타낸 것이다. RMSE는 식 (34)에 정의된 대로 계산되며, 이는 추적된 위치의 예측값과 실제 값 사이의 평균 제곱근 오차를 측정하는 방법이다. 여기서 n은 측정된 데이터의 수, \mathbf{x}_i , \mathbf{y}_i 는 실제 위치, $\hat{\mathbf{x}}_i$, $\hat{\mathbf{y}}_i$ 는 예측된 위치를 나타낸다. RMSE는 모델의 예측 정확도를 평가하는 데 효과적인 지표로, 값이 작을수록 추적 정확도가 높음을 의미한다.

$$RSME = \sqrt{\frac{1}{n} \left\{ \sum_{k=1}^n (\mathbf{x}_k - \hat{\mathbf{x}}_k)^2 + (\mathbf{y}_k - \hat{\mathbf{y}}_k)^2 \right\}} \quad (34)$$

표 5에서는 알고리즘 실행 시간을 측정하여 계산 복잡도를 추정하였다. IMM-PDAF는 모델 간 혼합 확률을 계산하는 과정에서 많은 연산을 필요로 하지만, CV 및 CT 모델과 비교한 결과, 실행 시간에서 큰 차이가 나타나지 않았다. 이는 IMM-PDAF의 복잡한 연산 구조에도 불구하고, 효율적인 계산 성능을 유지하고 있음을 보여주며, 본 연구에 중요한 성능 지표로 작용한다.

표 4. IMM-PDAF, CV-PDAF 및 CT-PDAF의 RMSE 비교
Table 4. Comparison of RMSE between IMM-PDAF, CV-PDAF, and CT-PDAF.


RMSE(m)	IMM-PDAF	CV-PDAF	CT-PDAF
DARC	422.94	524.58	529.63
MANV (target1)	117.06	120.26	121.22
MANV (target2)	98.52	101.87	107.74




(a)



(b)



(c)



(d)

그림 7. 레이더 데이터(회색 점)를 포함한 데이터 세트의 궤적(색상) 설명 및 IMM-PDAF, CV-PDAF 및 CT-PDAF 간 위치 오류 비교
Fig. 7. Trajectory(coloured) description of data sets including radar data (gray dots) and comparison of position errors between IMM-PDAF, CV-PDAF, and CT-PDAF.

표 5. IMM-PDAF, CV-PDAF 및 CT-PDAF의 평균 알고리즘 실행 시간 비교

Table 5. Comparison of average algorithm execution times of IMM-PDAF, CV-PDAF, and CT-PDAF.

Time(s)	IMM-PDAF	CV-PDAF	CT-PDAF
DARC	3.38	2.89	3.02
MANV	12.4	11.6	10.8

표 6. 매개변수 사양 및 초기 설정

Table 6. Parameter specifications and initial settings.

Definition	Parameter	Value
Detection probability	P_D	0.95
Gate probability	P_G	0.99
Gate threshold	γ	13.074
Constant	c_{n_s}	π
Initial error covariance	P_0	$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$
System model matrix(CV)	F_{CV}	$\begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$
System model matrix(CT)	F_{CT}	$\begin{bmatrix} 1 & \frac{\sin(\omega T)}{\omega} & 0 & -\frac{1-\cos(\omega T)}{\omega} \\ 0 & \cos(\omega T) & 0 & -\sin(\omega T) \\ 0 & \frac{1-\cos(\omega T)}{\omega} & 1 & \frac{\sin(\omega T)}{\omega} \\ 0 & \sin(\omega T) & 0 & \cos(\omega T) \\ 0 & 0 & 0 & 1 \end{bmatrix}$
Measurement model matrix	H_k	$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$
Noise gain matrix	G	$\begin{bmatrix} \frac{1}{2}T & 0 & 0 \\ 0 & \frac{1}{2}T & 0 \\ T & 0 & 0 \\ 0 & T & 0 \\ 0 & 0 & T \end{bmatrix}$
Process noise covariance	Q_k	$10G \cdot \begin{bmatrix} 0.1^2 \\ 0.1^2 \end{bmatrix} \cdot G^T$
Measurement noise covariance	R_k	$\begin{bmatrix} 10^2 & 0 \\ 0 & 10^2 \end{bmatrix}$
Mode transition probability	p_{ij}	$\begin{bmatrix} 0.8 & 0.2 \\ 0.2 & 0.8 \end{bmatrix}$
Dense clutter	λ	10^{-7}

IV. 결론

본 연구에서는 해상 환경에서 수집한 레이더 데이터를 활용하여 IMM-PDAF 알고리즘을 통한 객체-추적을 수행하였다. 이 알고리즘은 복잡한 해상 환경에서 다양한 선박의 동적 변화에 효과적으로 대응할 수 있도록 설계되었다. 특히, IMM-PDAF는 CV 모델과 CT 모델의 모델 확률 가중치를 결합하여 사용함으로써, 단일 시스템 모델을 사용한 기존 PDAF보다 더 높은 추적 성능을 가짐을 확인하였다. 이 연구를 통해 얻은 결과는 IMM-PDAF가 CV-PDAF와 CT-PDAF에 비해 상대적으로 낮은 RMSE 값을 보여주며, 복잡한 동적 환경에서도 강건한 위치 추적 성능을 가지고 있음을 입증한다. 향후 연구에서는 IMM-JPDA 알고리즘으로 다중-객체 추적을 발전시킬 계획이다. 이 알고리즘은 여러 표적의 존재 시 각 측정치에 대한 할당 확률을 계산하는 데 유용하여, 다중-객체 추적에 더욱 합리적인 알고리즘이다. IMM-JPDA를 통해 표적 식별의 정확성을 개선하고 처리 속도를 향상하는 방안을 모색한다면 이번 연구에서 진행하였던 IMM-PDAF 알고리즘보다 더 나은 추적 성능을 보일 것으로 기대 된다.

Acknowledgments

이 연구는 2024년 국방과학연구소 미래도전국방기술 연구개발사업 (No.915071101)의 지원을 받아 수행된 연구임.

References

- [1] R. Lionel, H. Song, S. Sun, W. Zhang, and Y. Yang, "Data association in multiple object tracking : A survey of recent techniquess," *Expert Systems with Applications*, Vol. 192, No. 15, Apr. 2022 DOI: <https://doi.org/10.1016/j.eswa.2021.116300>.
- [2] Y. Bar-Shalom, F. Daum, and J. Huang, "The probabilistic data association filter," *IEEE Control Systems Magazine*, Vol. 29, Issue 6, pp. 82-100, Nov. 2009. DOI: 10.1109/MCS.2009.934469.
- [3] M. Rutten, J. Williams, N. Gordon, M. Jah, J. Baldwin, and J. Stauch, "A comparison of JPDA and belief propagation for data association in SSA," in *Advanced Maui Optical and Space Surveillance Technologies Conference (AMOS)*, Vol. 2014, pp. 1-12, Sep. Retrieved from <https://amostech.com/>
- [4] J. S. Fowdur, M. Baum, and F. Heymann, "Real-world marine radar datasets for evaluating target tracking methods," *Sensors*, Vol. 21, No. 14, pp. 4641, Jul. 2021. DOI: <https://doi.org/10.3390/s21144641>.

- [5] J. H. Choi, J. H. Park, M. J. Kang, H. J. Kim, and W. K. Youn, "Multiple PDAF algorithm for estimation states multiple of the ships," *Journal of the Society of Naval Architects of Korea*, Vol. 60, No. 3, pp. 248-255, 2023. DOI: 10.3744/SNAK.2023.60.4.248.
- [6] Z. Liu, Y. Fang, L. Zhang, J. Li, and J. Hu, "A robust videoSAR single target tracker by integrating correlation filter and IMM-PDAF," *IEEE Geoscience and Remote Sensing Letters*, Vol. 19, Article No. 3206835, Sep. 2022. DOI: <https://doi.org/10.1109/LGRS.2022.3206835>.
- [7] J. J. Yoo and Y. S. Kang, "Performance analysis on the IMM-PDAF method for longitudinal and lateral maneuver detection using automotive radar measurements," *Journal of Institute of Control, Robotics, and Systems*, Vol. 21, No. 3, pp. 224-232, Mar. 2015. DOI : 10.5302/J.ICROS.2015.14.9015.
- [8] W. J. Park, C. H. Kang, S. Y. Kim, and C. G. Park, "Asynchronous multi-sensor data fusion with decentralized IMM-PDAF," in *IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, pp. 205-210, Dec. 2018. DOI: 10.1109/IEEM.2018.8607592.
- [9] C. W. Han, S. W. Lee, and E. S. Jin, "Tracking of ARPA radar signals based on UK-PDAF and fusion with AIS data," *Journal of Ocean Engineering and Technology*, Vol. 37, No. 1, pp. 38-48, Feb. 2023. DOI: <https://doi.org/10.26748/KSOE.2022.046>.
- [10] W. K. Youn and H. Myung, "Robust interacting multiple model with modeling uncertainties for maneuvering target tracking," *IEEE Transactions on Instrumentation and Measurement*, Vol. 69, No. 7, pp. 5166-5180, July 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2915506>.



유 태 훈 (Tae-Hoon Yoo)

2023년 8월 : 충남대학교 선박해양공학과 (공학사)
 2023년 9월 ~ 현재 : 충남대학교 자율운항시스템공학과 (석사과정)
 ※ 관심분야 : 위성통신, Kalman Filter, Marine radar



방 현 태 (Hyeon-Tae Bang)

2019년 2월 : 한밭대학교 건설환경공학과(공학사)
 2021년 2월 : 한밭대학교 토목공학과(공학석사).
 2022년 3월 ~ 현재 : 충남대 자율운항시스템공학과(박사과정)
 ※ 관심분야 : 무인 이동체 자율주행 시스템 및 검증 시뮬레이션



윤 원 근 (Won-keun Youn)

2008년 2월 : 한동대학교 기계제어공학부 (공학사),
 2011년 9월 : KAIST 응용과학연구소 연수연구원,
 2021년 2월 : 한국항공우주연구원 선임연구원
 2021년 3월 ~ 현재 : 충남대 자율운항시스템공학과, 조교수
 ※ 관심분야 : 자율제어 및 항법

2010년 8월 : KAIST 기계공학과 (공학석사)
 2020년 8월 : KAIST 로봇공학과 (공학박사)