

신경 회로망 기반의 자료 연관 기법을 이용한 수중 표적 추적

차대웅*, 김주호*, 한동석°

Underwater Target Tracking Using Data Association Based on Neural Networks

Daewoong Cha*, Juho Kim*, Dong Seog Han°

요약

수중에서 표적을 추적하기 위하여 NNKF(nearest neighbor Kalman filter)와 PDAF(probabilistic data association) 표적 추적 기법이 많이 사용되고 있다. 그러나 이들 알고리즘은 해상 환경에 따라서 최적화된 Kalman 필터 특성을 찾아야 하는 문제점이 있다. 논문에서는 기존 알고리즘의 문제점을 해결하기 위해서 신경 회로망을 사용한 자료 연관 기법 기반의 표적 추적 기법을 제안한다. 컴퓨터 모의실험을 통하여 제안 알고리즘과 NNKF, PDAF 알고리즘의 표적 추적 성능을 비교하였다.

Key Words : Active Sonar, Kalman Filter, Tracking, Data Association

ABSTRACT

Nearest neighbor Kalman filter (NNKF) and probabilistic data association (PDAF) target tracking techniques are often used to track targets in under water. However, these algorithms have a problem of finding the optimum parameters for the Kalman filter according to the underwater environment. In this paper, we propose a target tracking algorithm based on data association technique using artificial neural network to solve this problem. Through computer simulations, we compared the target tracking performance of the proposed algorithm with the NNKF and PDAF algorithms.

I. 서론

최근 천해 환경에서 표적의 탐지, 추적, 식별에 대한 연구가 많은 관심을 받고 있다^[1]. 수중에서 표적의 탐지, 추적, 식별에는 수중 음파탐지기(sound navigation and ranging, SONAR)^[2]를 사용한다. 소나는 수중에서 음파를 사용하여 다양한 대상을 탐색하거나 탐지하는 기술이다. 소나에는 능동 소나와 수동

소나가 있다. 두 가지 소나의 주된 차이점은 수동 소나의 경우 수상함, 잠수함 등에서 방사되는 소음을 일방적으로 듣고 탐지를 하며^[3], 능동 소나의 경우에는 음파를 방사하여 물체에 부딪혀 돌아오는 반향음을 사용해서 물체의 방위와 거리를 찾아낸다^[4]. 최근에는 기술이 발전함에 따라 잠수함 등에서 나오는 방사소음이 감소하고 있기 때문에 주로 능동 소나에 대한 연구가 활발히 이루어지고 있다.

※ 본 연구는 방위사업청과 국방과학연구소의 지원으로 수행되었으며, 이에 대해 깊이 감사를 드립니다.(계약번호 UD160004DD)

♦ First Author : (ORCID:0000-0002-0611-1727)Kyungpook National University, dwcha5015@gmail.com, 정희원

° Corresponding Author : (ORCID:0000-0002-7769-0236)Kyungpook National University, dshan@knu.ac.kr, 종신희원

* (ORCID:0000-0002-5113-8590)국방과학연구소, lizard@add.re.kr

논문번호 : 201808-258-C-RN, Received August 22, 2018; Revised November 14, 2018; Accepted November 15, 2018

능동 소나를 사용한 천해 환경에서의 표적 탐지 및 추적은 천해 환경의 특성으로 인해 클러터 및 표적 이외의 신호가 탐지되는 문제점을 가진다. 표적을 추적하기 위해서는 여러 탐지 신호 중 하나를 선택하여 다음 상태로 갱신하는 자료 연관 기법이 필요하다. 흔히 사용되는 Kalman 필터^[5] 기반의 자료 연관 기법을 사용한 표적 추적 기법에는 NNKF(nearest neighbor Kalman filter)와 PDAF(probabilistic data association filter)가 있다. NNKF는 오 탐지 신호에 적용되어 추적에 실패하거나 오 추적을 일으킬 확률이 높고, 칼만 변수에 따른 추적 성능의 차이가 크다. 이러한 문제점을 해결한 알고리즘이 PDAF이다. PDAF는 NNKF보다 원하는 표적을 추적할 확률이 더 높지만 사용하는 클러터 분포에 따라 오 추적 경로가 많이 발생하는 단점이 있다.

본 논문에서는 기존 연관 기법을 이용한 추적 알고리즘의 단점을 해결하기 위하여 여러 환경에서의 표적과 클러터에 대한 데이터를 학습 시켜 놓음으로써 환경에 따른 칼만 변수의 영향을 줄일 수 있다. 또한 자료 연관 기법에 식별 기법을 추가함으로써 원하는 표적 신호를 연관시킬 확률을 높이고 오 추적 경로를 줄일 수 있는 신경 회로망을 이용한 자료 연관 알고리즘을 제안한다.

서론에 이어 본문에서는 기존의 칼만 필터를 사용한 표적 추적 알고리즘인 NNKF와 PDAF에 대하여 살펴보고, 3장에서는 신경 회로망을 사용한 표적 추적 기법을 제안한다. 4장에서는 기존의 자료 연관 알고리즘을 사용한 표적 추적 기법 및 제안한 신경 회로망을 사용한 표적 추적 알고리즘의 실험결과를 설명하고, 5장에서 결론을 맺는다.

II. 자료 연관 기법을 이용한 기존 수중 표적 추적 알고리즘

자료 연관 기법을 이용한 대표적인 추적 알고리즘으로는 NNKF^[7]와 PDAF^[9]가 있다. NNKF는 추정되는 측정값과 가장 가까운 탐지 신호를 다음 상태로 갱신하는 방법이다. 이 방법은 구현이 쉽고 많은 계산시간이 요구되지 않는다. 그러나 추적에 실패하거나 오 탐지 신호에 적용될 가능성이 다소 높다^[7].

NNKF는 선형 칼만 필터와 마찬가지로 다음의 방정식을 이용해서 다음 상태를 예측한다.

$$\tilde{\mathbf{x}}_{k|k-1} = \mathbf{F}\hat{\mathbf{x}}_{k-1|k-1} \quad (1)$$

여기서 $\hat{\mathbf{x}}_{k-1|k-1}$ 은 시각 $k-1$ 에서 시각 k 의 표적의 상태에 대해 추정된 값이고, $\tilde{\mathbf{x}}_{k|k-1}$ 는 시각 k 에서 표적에 대한 상태 예측 값이다. \mathbf{F} 는 전이행렬, \mathbf{x} 는 표적의 상태를 나타내는 값으로 다음과 같다.

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{x} = \begin{bmatrix} x \\ y \\ \dot{x} \\ \dot{y} \end{bmatrix} \quad (2)$$

여기서 x 와 y 는 각각 표적의 거리와 방위를 나타내며, \dot{x} 와 \dot{y} 는 거리와 방위에 대한 시간에 따른 변화량을 나타낸다. 이전의 추적 경로와 연관된 탐지 신호에 대한 분산 행렬 \mathbf{P} 는 다음과 같이 표현된다.

$$\tilde{\mathbf{P}}_{k|k-1} = \mathbf{F}\hat{\mathbf{P}}_{k-1|k-1}\mathbf{F}^T + \mathbf{Q}_k \quad (3)$$

여기서 $\mathbf{Q}_k = E\{v_k v_k^T\}$ 이다. 예측된 상태 $\tilde{\mathbf{x}}_{k|k-1}$ 로부터 표적 측정치에 대한 예측 값 $\tilde{\mathbf{z}}_{k|k-1}$ 을 얻을 수 있다.

$$\tilde{\mathbf{z}}_{k|k-1} = \mathbf{H}\tilde{\mathbf{x}}_{k|k-1} \quad (4)$$

또한 식 (4)로부터 모든 유효한 탐지 신호와 예측 값 사이의 거리를 나타내는 이노베이션 벡터 $\mathbf{v}_k(i)$ 는 다음과 같으며 m 은 유효한 탐지 신호의 개수이다.

$$\mathbf{v}_k(i) = \mathbf{z}_k(i) - \tilde{\mathbf{z}}_{k|k-1}, \quad i = 1, \dots, m \quad (5)$$

유효한 탐지 신호가 존재하지 않으면 다음 평으로 전과되어 유효한 탐지 신호의 여부를 다시 판단한다. 이노베이션 벡터 \mathbf{v}_k 를 사용해서 추정 값 $\hat{\mathbf{x}}_{k|k}$ 을 다음과 식을 이용해 갱신할 수 있다.

$$\hat{\mathbf{x}}_{k|k} = \tilde{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \mathbf{v}_k \quad (6)$$

여기서 \mathbf{K}_k 는 칼만 이득으로 다음과 같다.

$$\mathbf{K}_k = \tilde{\mathbf{P}}_{k|k-1} \mathbf{H}^T \hat{\mathbf{S}}_k^{-1} \quad (7)$$

여기서 $\hat{\mathbf{S}}_k$ 는 이노베이션 공분산 행렬로 다음과 같다.

$$\hat{S}_k = H\tilde{P}_{k|k-1}H^T + R_k \quad (8)$$

상태 공분산 행렬은 다음의 식에 의해 갱신된다.

$$\tilde{P}_{k|k} = (I - KH)\tilde{P}_{k|k-1} \quad (9)$$

NNKF 보다 원하는 표적을 추적할 확률을 높인 방법이 PDAF이다⁸⁾. PDAF는 게이트 임계치 안에 있는 유효한 탐지 신호들의 가중 합계를 다음 상태 갱신에 사용한다. 이 방법은 필터가 클러터나 잡음에 덜 민감하게 만들고 NNKF보다 원하는 표적을 추적할 확률이 더 높다⁹⁾.

PDAF 알고리즘도 NNKF와 동일하게 표적의 다음 상태를 예측하고 관련 공분산을 계산한다. 이후에 이 노베이션 및 공분산 행렬을 계산한다. PDAF는 게이트 임계치 안에 있는 모든 탐지 신호들의 관련 확률을 사용해서 다음과 같이 이노베이션을 계산한다.

$$v_k = \sum_{i=1}^m \beta_k(i)v_k(i) \quad (10)$$

임계치 안에 있는 유효한 탐지 신호들의 관련 확률은 Poisson의 클러터 모델⁷⁾을 따라 다음과 같이 계산할 수 있다.

$$\beta_k(i) = \begin{cases} \frac{e^{-0.5v(i)^T S^{-1}v(i)}}{P_{FA} \sqrt{2\pi S} \frac{(1-P_D)}{P_D} + \sum_{i=1}^m e^{-0.5v(i)^T S^{-1}v(i)}} & i = 1, 2, \dots, m \\ \frac{P_{FA} \sqrt{2\pi S} \frac{(1-P_D)}{P_D}}{P_{FA} \sqrt{2\pi S} \frac{(1-P_D)}{P_D} + \sum_{i=1}^m e^{-0.5v(i)^T S^{-1}v(i)}} & i = 0 \end{cases} \quad (11)$$

여기서 m 은 임계치 안의 탐지 신호의 개수이며, P_{FA} 는 오경보율, P_D 는 탐지 확률이다.

상태 추정 값은 식 (10)의 이노베이션과 칼만 이득 행렬을 이용해 갱신된다.

$$\hat{x}_{k|k} = \tilde{x}_{k|k-1} + K_k v_k \quad (12)$$

상태 공분산 행렬 $\hat{P}_{k|k}$ 는 다음 식에 의해 갱신된다.

$$\hat{P}_{k|k} = \beta_k(0)\tilde{P}_{k|k-1} + (1 - \beta_k(0))P_{k|k}^c + P_{k|k}^s \quad (13)$$

여기서 $P_{k|k}^c$ 와 $P_{k|k}^s$ 는 각각 다음과 같이 정의된다.

$$P_{k|k}^c = \tilde{P}_{k|k-1} - K_k S K_k^T \quad (14)$$

$$P_{k|k}^s = K \left(\sum_{i=1}^m \beta_k(i)v_k(i)v_k(i)^T - v_k v_k^T \right) K^T \quad (15)$$

III. 제안하는 자료 연관 기법

본 절에서는 기존의 자료 연관 기법의 문제점을 해결하기 위하여 신경 회로망을 사용한 표적 추적 기법¹⁰⁾을 제안한다. 기존의 기법들은 해상 환경에 따라서 추적에 실패하거나 추적 성능이 가변 하는 문제점을 가진다. 그러나 신경 회로망을 사용하면 다양한 환경에서 원하는 표적 및 어군, 해저지형 등의 클러터에 대한 데이터를 학습 시켜 놓음으로써 기존의 기법에 비해 환경에 강인한 추적 성능을 가진다.

그림 1은 신경 회로망을 사용한 자료 연관 알고리즘 기반의 표적 추적기법의 흐름도이다. 가장 먼저 처음 ping의 모든 탐지 신호들에 대하여 추적을 시작한다. 칼만 필터는 이전까지의 상태로 다음 상태를 추정하는 것으로 처음 ping의 신호를 수신하였을 때 이전의 데이터가 없으므로, 현재 탐지 신호들이 추정 값이 된다. 이후 추정 값에서 가까이 있는 신호들만을 다음 상태로 갱신할 후보로 고려하기 위한 게이팅을 수행한다. 이 때 게이트 임계치 내에 다음 ping의 탐지 신호가 존재하면 이 신호들을 유효한 신호라고 한다. 유효한 탐지 신호가 1개 있으면 신경 회로망을 거치지 않고 바로 다음 상태로 갱신한다. 유효한 탐지 신호가 2개 이상인 경우 각 탐지 신호의 SNR(signal to noise ratio), 거리, 표적의 너비 정보를 신경 회로망의 입력으로 넣고, 유효한 탐지 신호가 없으면 기존의 기법과 동일하게 다음 ping으로 전파하며 트랙 스코어가 감소한다. 트랙 스코어가 사전에 설정해 놓은 값부터 1씩 감소하다가 0이 되면 추적 경로는 사라진다. 각 탐지 신호들의 특징인자들은 원하는 표적으로 반사되어온 신호에서 추출 되어진 특징 인자들은 표적의 학습 데이터로 사용했으며, 그 외에 어군, 해저 지형 등에 의해 반사 되어진 신호들에서 추출된 특징 인자들은 클러터의 학습 데이터로 사용했다.

신경 회로망에 탐지 신호들의 특징 인자들을 입력하면 각 탐지 신호들이 표적일 확률과 클러터일 확률이 출력된다. 모든 탐지 신호에 대해서 출력으로 나온 표적일 확률 값이 다른 값을 가지는 경우 가장

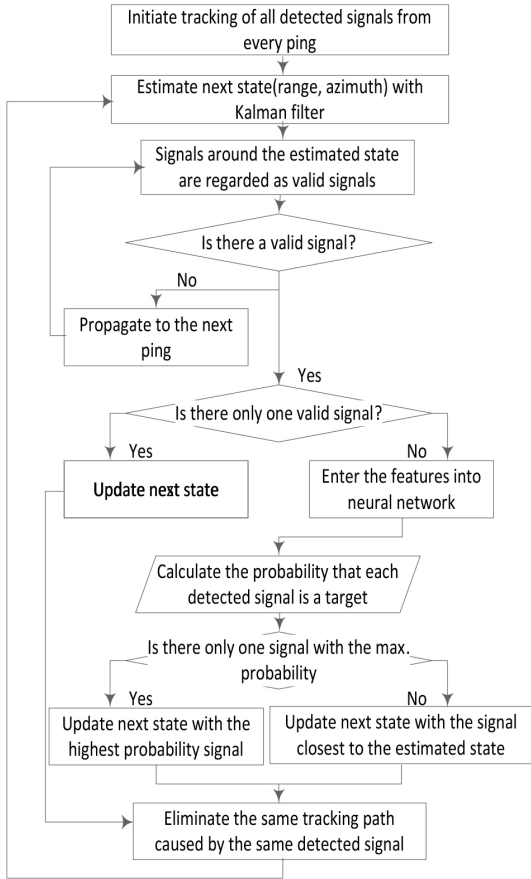


그림 1. 제안하는 알고리즘 흐름도
Fig. 1. Flow chart of proposed algorithm

큰 확률 값을 가지는 탐지 신호를 다음 상태로 갱신한다. 또한 탐지 신호 중에서 표적일 확률의 최댓값이 동일한 값이 존재하는 경우에는 추정 값에서 가장 가까운 탐지 신호를 다음 상태로 갱신하는데 사용한다. 매 핑에서 모든 탐지 신호에 대해서 추적을 시작하기 때문에 동일한 탐지 신호에 의한 동일한 추적 경로가 여러 개 발생한다. 동일한 추적 경로를 제거해 주기 위해서 가장 최근에 갱신된 값을 포함한 이전 3개의 신호들을 비교하여 3개의 신호가 모두 동일하다면 최근에 발생한 추적 경로를 제거해줌으로써 동일한 추적 경로가 생기는 것을 방지한다.

IV. 실험결과

본 장에서는 실험에 사용한 신경 회로망에 대해 설명한다. 또한 한 개와 두 개의 표적이 기동하는 상황에 대하여 기존 자료 연관 기법과 제안한 자료 연관

기법을 이용한 추적기법의 추적 성능을 비교한다.

그림 2는 실험에 사용된 신경 회로망의 블록도이다. 신경 회로망의 입력으로는 표적의 식별에 사용되는 특징 인자인 SNR(signal to noise ratio), 거리, 표적의 너비 정보가 들어간다. 이 정보들은 원하는 표적에 의해 반사되어진 신호에서 얻어진 특징인자를 표적 데이터로 학습을 했으며, 어군, 해저 지형 등의 클러터로부터 반사되어진 신호에서 얻어진 특징인자를 클러터 데이터로 학습하였다. 4개의 히든 레이어를 사용했으며 출력으로는 표적일 확률과 클러터일 확률이 나온다.

그림 3은 히든 레이어의 개수에 따른 학습율의 변화를 보여준다. 1개의 히든 레이어를 사용했을 때는 학습 결과가 72.3%가 나왔다. 클러터는 78.8%의 학습율을 가졌지만 표적의 학습율이 64%로 낮았기 때문에 전체 학습율이 우수하지 않다. 2개의 레이어를

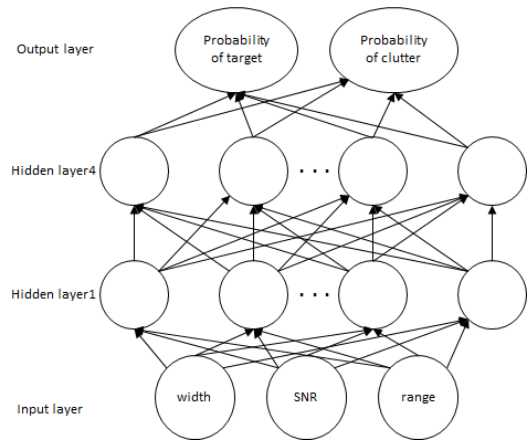


그림 2. 신경 회로망 구조
Fig. 2. Architecture of neural network




그림 3. 히든 레이어 개수에 따른 학습 성능
Fig. 3. Training performance according to the number of hidden layers

사용했을 때는 표적의 학습율이 60.6%, 클러스터의 학습율이 77.1%이다. 1개의 레이어를 사용했을 때 보다 표적과 클러스터의 학습율이 낮아졌기 때문에 전체 식별 결과가 70.1%로 낮아졌다. 3개를 사용했을 때는 클러스터의 학습율은 78.3%, 표적 학습율은 64.7%로써 총 학습율은 72.5%이다. 레이어 4개를 사용했을 때 클러스터 학습율은 78.6%, 표적의 학습율은 66.2%로써 총 학습율은 73.4%로 가장 높았다. 레이어가 5개일 때는 총 학습율이 72.2%로 4개를 사용한 경우보다 낮았으며 5개 이상을 사용했을 때는 학습율이 좋아지지 않았다. 따라서 본 실험에서는 표적, 클러스터, 전체 학습율이 가장 좋은 4개의 레이어를 가진 신경 회로망을 사용하였으며 각 레이어의 히든 노드 개수는 100개를 사용했을 때 학습율이 가장 좋았으며 100개보다 많은 경우 성능의 변화가 없었다.

본 실험에서는 표적이 이동하는 두 가지의 시나리오에 대해서 표적이 한 평 동안 움직일 수 있는 거리를 고려하여 상태 공분산을 나타내는 Q는 1, 측정 공분산을 나타내는 R은 0.01, 초기 게이트 임계치는 1.5 m로 동일한 칼만 변수와 유효한 탐지 신호가 존재하지 않는 경우 다음 평으로 전파할 횡수인 트랙 스코어 임계값은 5를 사용했다.

그림 4는 표적이 이동하는 첫 번째 시나리오에서 표적의 이동 경로만을 나타낸 그림이다. x축은 소나로부터 표적까지의 거리, y축은 방위를 나타낸다. 그림 3에서 볼 수 있듯이 표적이 약 530 m에서 410 m 까지 이동한 상황이다. 클러스터의 경우 랜덤하게 탐지 신호가 분포하며, 해저 지형의 경우 거의 동일한 방위와 거리에서 탐지 신호들이 누적되어 나타난다. 그림 5 부터 그림 7 까지는 첫 번째 시나리오에서 각 알고




그림 4. 첫 번째 시나리오에서 표적의 이동 경로
Fig. 4. The target movement path in the first scenario

리즘의 추적 결과를 나타낸다. 세모에 의한 경로는 원하는 표적에 의해 생긴 추적 경로이며, 점에 의해 생긴 추적 경로들은 클러스터에 의해 생긴 추적 경로들이다. 그림 5의 NNKF를 이용한 추적 결과에서 원하는 표적 정보가 제대로 추적되었다. 하지만 해저 지형으로 판단되는 125°, 500 m에서 550 m 부근과 약 150°, 420 m 근처의 탐지 신호가 많은 부분에서 오 추적 경로가 발생했다. 그림 6은 PDAF의 추적 결과를 나타낸다. 표적은 제대로 추적했지만 모든 거리, 방위상에 클러스터에 의한 오 추적 경로들이 많이 발생했다. 그림 7은 신경 회로망을 이용한 추적 결과이다. 원하는 표적에 의한 추적 경로만 존재하고 클러스터에 의한 오 추적 경로는 발생하지 않았다. 첫 번째 시나리오에서는 NNKF의 경우 예측 값에서 가장 가까운 탐지 신호를 다음 상태로 갱신하기 때문에 매 평마다 동일한 위치에 탐지 신호가 나타나는 경우 오 추적 경로가 생길 수밖에 없다. 하지만 동일한 상황에서 신경 회로망을 사용한 추적 알고리즘의 경우 오 추적 경로가 발생하지 않은 이유는 매 평마다 동일한 위치에 동일한 탐지




그림 5. NNKF 추적 결과
Fig. 5. Tracking result of NNKF




그림 6. PDAF 추적 결과
Fig. 6. Tracking result of PDAF




그림 7. 신경 회로망 사용 추적 결과
Fig. 7. Tracking result using neural network

신호가 있더라도 주변의 탐지 신호가 원하는 표적 신호와 더 비슷한 특징 인자 값을 가져서 표적일 확률이 높기 때문에 그 탐지 신호를 따라가다가 더 이상 연관될 탐지 신호가 존재하지 않아서 추적 경로가 사라진 것으로 판단된다.

그림 8은 두 개의 표적이 기동하는 시나리오에서 두 개의 표적이 이동한 경로를 나타낸 그림이다. 하나의 표적은 약 150°, 390 m에서 440 m까지 이동했고, 다른 하나의 표적은 440 m에서 490 m까지 이동했다. 그림 9는 두 번째 시나리오에서 NNKF의 추적 결과를 나타낸다. 두 개의 표적이 하나의 추적 경로로 나타났으며, 120°, 460 m 부근의 탐지 신호가 누적된 부분과 그 외의 클러스터 신호로 인한 오 추적 경로가 발생했다. 그림 10은 PDAF 추적 결과이다. 두 개의 표적에 대해서 각각 추적은 되었지만 오 추적 경로가 많이 발생했다. 그림 11은 신경 회로망을 이용한 추적 기법의 결과이다. 110°와 120°사이 약 450 m 지점과 표적 근처와 같이 오 탐지 신호가 이동하는 것처럼 분

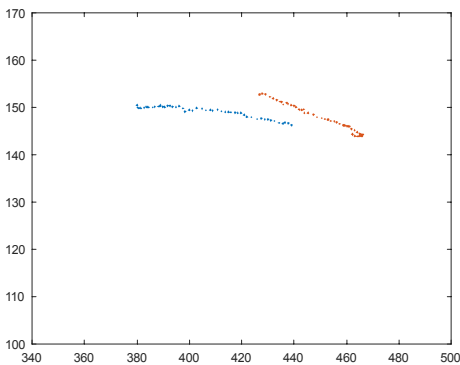


그림 8. 두 번째 시나리오에서 표적의 이동 경로
Fig. 8. The target movement path in the second scenario




그림 9. NNKF 추적 결과
Fig. 9. Tracking result of NNKF




그림 10. PDAF 추적 결과
Fig. 10. Tracking result of PDAF




그림 11. 신경 회로망 사용 추적 결과
Fig. 11. Tracking result using neural network

포되어 있기 때문에 표적일 확률과 상관없이 오 추적 경로가 생긴 것으로 판단된다. 두 번째 시나리오에서

도 신경 회로망을 이용한 표적 추적 기법이 가장 좋은 성능을 갖는다.

V. 결 론

본 논문에서는 칼만 필터를 사용한 표적 추적 기법에 사용되는 자료 연관 기법인 NNKF와 PDAF의 성능에 대해서 다루었다. 또한 신경 회로망을 사용한 자료 연관 기법에 대해 제안하였다. 제안한 알고리즘은 식별에 사용되는 신경 회로망을 표적 추적 기법에 적용하여 여러 환경에서의 데이터를 학습 시켜놓음으로써 환경에 강인함을 갖는 알고리즘이다. 실험 결과에서 볼 수 있듯이 표적이 이동하는 상황에서 제안한 알고리즘이 원하는 표적 추적 성능과 클러스터에 의한 오추적 경로에 대해 가장 좋은 성능을 보였다. NNKF의 경우 모든 시나리오에서 동일한 위치에 매 핑마다 탐지 신호가 누적 되어 있으면 오추적 경로가 발생했다. 그러나 신경 회로망을 이용한 표적 추적의 경우에는 근처에 표적일 확률이 더 높은 탐지 신호에 의해 연관 지어져서 추적을 이어가다가 더 이상 연관 지어질 탐지 신호가 존재하지 않아서 오추적 경로가 발생하지 않은 것으로 판단된다. 그러나 오추적 경로가 발생한 부분에서는 사용된 특징 인자의 수와 학습에 사용된 데이터의 수가 너무 적고 학습에 사용된 데이터의 부정확성으로 인한 학습 결과가 좋지 않아서 오추적 경로가 발생한 것으로 판단된다. 따라서 표적과 클러스터를 식별하는데 있어서 더 분별력 있는 특징 인자를 사용해서 식별 결과가 좋아지면 신경 회로망의 출력인 표적일 확률에 임계치를 걸어서 클러스터에 의한 오추적 경로를 줄임으로써 더 좋은 추적 성능을 얻을 것이다.

References

[1] B. J. Bunin, A. Sutin, and M. S. Bruno, "Maritime security laboratory for maritime security research," in *Proc. SPIE-The Int. Soc. for Optical Eng.*, vol. 6540, May 2007.

[2] J. Y. Kim, C. H. Shin, and K. H. Kim, "A system design method of mine warfare using information for sonar and mdv," *J. KICS*, vol. 39, no. 12, pp.1243-1249, Dec. 2014.

[3] D. Havelock, S. Kuwano, and M. Vorlander, *Handbook of Signal Processing in Acoustics*, Springer, 2008.

[4] J. L. Stewart and E. C. Westerfield, "A theory of active sonar detection," *Proc. IRE*, vol. 47, no. 5, May 1959.

[5] G. S. Park and D. M. Lee, "Localization algorithm mixing kalman and particle filters for moving object in indoor wi-fi environment," *J. KICS*, vol. 42, no. 8, pp. 1695-1701, Aug. 2017.

[6] D. W. Kim, W. J. Kang, Y. P. Koo, J. H. Bang, K. H. Son, D. Hostallero, S. E. Yoon, H. H. Yeo, J. H. Na, N. S. Seo D. S. Han, and Y. Yi, "Ai-based drone object tracking system: design and implementation," *J. KICS*, vol. 42, no. 12, pp. 2391-2401, Dec. 2017.

[7] V. Naidu, G. Girija, J. Raol, and R. R. Appavu, "Data association and fusion algorithms for tracking in presence of measurement loss," in *Symp. Modern Trends in Radar Technol.*, vol. 86, pp. 17-28, 2002.

[8] A. Rodningsby and Y. Bar-Shalom, "Tracking of divers using a probabilistic data association filter with a bubble model," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 45, no. 3, pp. 1181-1193, 2009.

[9] Y. Bar-Shalom, F. Daum, and J. Huang, "The probabilistic data association filter," *IEEE Control Syst. Mag.*, vol. 29, no. 6, pp. 82-100, Dec. 2009.

차 대 응 (Daewoong Cha)



2016년 8월: 경북대학교 전자공학과 졸업
 2018년 8월: 경북대학교 모바일통신공학과 석사
 <관심분야> 능동소나, 신호처리

김 주 호 (Juho Kim)



2010년 2월 : 제주대학교 해양
시스템공학과 학사
2012년 2월 : 제주대학교 해양
시스템공학과 석사
2016년 2월 : 제주대학교 해양
시스템공학과 박사
2016년 10월~현재 : 국방과학연
구소 선임연구원

<관심분야> 능동소나, 신호처리

한 등 석 (Dong Seog Han)



1987년 : 경북대학교 전자공학
과 졸업
1989년 : 한국과학기술원 전기
및 전자공학과 공학 석사
1993년 : 한국과학기술원 전기
및 전자공학과 공학 박사
1996년~현재 : 경북대학교전자
공학과 교수

<관심분야> 통신 신호처리, 차량 통신용 네트워크,
레이더 및 소나 신호 검파