

WSN의 생존시간과 품질 보장을 위해 강화 학습을 이용한 감시상황 기반의 에너지 효율적인 센서 장벽 형성 기법

전 상 범*, 이 민 우°, 임 재 성*

Reinforcement Learning Based Energy-Efficient Sensor Barrier Formation Algorithm For Border Surveillance

Sangbeom Jeon*, Minwoo Lee°, Jaesung Lim*

요 약

경계 감시는 무선센서 네트워크(WSN)의 중요한 응용 중 하나이다. 네트워크 내의 무선센서들끼리 통신을 통해 센서 장벽을 형성하여 경계 감시 임무를 수행한다. 무선센서는 한정된 에너지와 센싱 능력을 갖기 때문에 요구되는 감시 품질을 보장함과 동시에 에너지 효율적으로 센서 장벽을 형성하는 것이 중요하다. 이를 위해 본 논문에서는 먼저 침입자의 침입 속도를 고려하여 센서 장벽의 감시 품질을 정의한 후, 강화학습을 이용하여 요구되는 감시 품질을 만족하면서 센서 장벽에 참여하는 센서 개수를 최소화하는 센서 장벽 형성 기법 (ESBF: Energy-Efficient Sensor Barrier Formation Algorithm)을 제안한다. 시뮬레이션을 통해 제안한 기법이 기존 기법보다 에너지 효율적임을 확인하였다.

키워드 : 무선센서 네트워크, 경계 감시, 센서 장벽, 강화 학습, 학습 자동화

Key Words : Wireless Sensor Network, Border Surveillance, Sensor Barrier, Reinforcement Learning, Learning Automata

ABSTRACT

Border Surveillance is one of the significant applications of wireless sensor networks (WSNs). Through communication between wireless sensors in the network, sensor barriers are formed to perform border surveillance. Since wireless sensors have limited energy and sensing capabilities, it is important to form sensor barriers energy-efficiently while guaranteeing the required surveillance quality. In this paper, we first define the surveillance quality of the sensor barrier by considering the maximum speed of the intruder and then propose a sensor barrier formation algorithm (ESBF: Energy-Efficient Sensor Barrier Formation Algorithm) that minimizes the number of sensors participating in the sensor barrier while satisfying the required surveillance quality using reinforcement learning. We perform a computer simulation to show that our algorithm is more energy-efficient than the existing one.

※ 이 논문은 2021년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No.NRF2021R1I1A1A0104791411)

• First Author : Ajou University Department of Military Digital Convergence, beom115@ajou.ac.kr, 정회원

° Corresponding Author : Ajou University Department of Military Digital Convergence, iminu@ajou.ac.kr, 종신회원

* Ajou University Department of Military Digital Convergence, jaslim@ajou.ac.kr, 종신회원

논문번호 : 202105-096-C-RN, Received April 30, 2021; Revised August 20, 2021; Accepted September 8, 2021

I. 서 론

고성능의 센서로 이뤄진 무선센서 네트워크 (WSN: Wireless Sensor Network)는 과학화 경계 시스템에 적용되어 인간의 접근이 어렵거나 상시 경계가 필요한 곳에서 유인 감시 시스템을 대체 또는 지원하는 역할을 하고 있다^[1]. WSN은 주로 원격 지역에 배치되어 센서들이 무선통신을 통해 센서 장벽 (Sensor Barrier)을 형성함으로써 경계 임무를 수행한다^[2]. 예를 들어 최근 증가하고 있는 드론을 이용한 주요 기반 시설 공격 사례에서 보듯이 WSN은 센서 장벽으로 활용될 수 있다.

하지만 WSN을 구성하는 무선센서들은 원격 지역에 설치되어 있으므로 전원 공급의 제한과 환경의 영향 등으로 인해 WSN을 장기간 운영하는 데에는 많은 어려움이 있다^[3]. 이러한 어려움을 극복하기 위한 여러 가지 방법 중에서 센서들을 효율적으로 운영하기 위한 스케줄링에 관한 연구가 많이 이뤄져 왔다^[4-7]. 예를 들어 센서 장벽에 참여하는 센서의 개수를 최소화하고 참여하지 않는 센서들은 휴면 상태를 유지함으로써 센서의 전력 소모를 최소화하는 방안이 다뤄지고 있다^[8-10].

이때 고려해야 할 점은 센서 장벽의 전체적인 감시 능력 또는 감시 품질 (SQ: Surveillance Quality)가 시스템의 요구 수준을 만족해야 한다는 것이다. 따라서 WSN을 장기간 운용할 수 있더라도 감시 품질이 낮으면 침입자 탐지 역할을 제대로 수행할 수 없다. 반면, 감시 품질이 높더라도 장기간 운용할 수 없다면 계속 관리해 줘야 하므로 효율적인 감시 시스템을 구축할 수 없다. 그러나 WSN의 센서들이 배치된 환경 변수들을 예측하기 어렵고 센서 장벽에서 탐지하는 침입자의 경로 또한 동적으로 변하기 때문에, 센서의 장기간 운영과 감시 품질의 충족을 동시에 만족시키는 것은 매우 어려운 문제이다. 따라서 이러한 문제들이 해결되어야 현실에서 적극적으로 유인 감시 시스템을 대체 또는 지원하는 용도로 WSN을 사용할 수 있을 것이다.

본 논문에서는 WSN의 감시 품질을 만족하면서 생존시간을 늘리는 방안으로 에너지 효율적인 센서 장벽 형성 기법 (ESBF: Energy-efficient Sensor Barrier Formation)을 제안한다. ESBF는 외부 환경 요인들을 고려하여 센서 장벽을 형성하기 위해 강화 학습의 한 종류인 학습 자동화 (LA: Learning Automata) 기법을 활용하였다. 또한, ESBF는 기존 연구와는 다르게 WSN의 감시 품질을 맞추기 위해 분산적으로 센서 장

벽을 형성한 후 센서 장벽 주변의 센서를 선택적으로 센서 장벽에 참여시키는 방안을 사용하였다.

본 논문의 구성은 다음과 같다. 2장에서는 기존 연구의 센서 장벽의 센싱 모델과 WSN 환경의 모델링을 다룬다. 그리고 LA와 임의 환경(RE: Random Environment)과의 관계를 살펴보고, 이를 이용하여 센서 장벽에서 사용되는 최소 감지 확률과 침입 경로를 정의한다. 3장에서는 센서 장벽의 SQ를 수식으로 표현하고, 이를 이용한 센서 장벽 형성 과정을 제시함으로써 제안하는 ESBF 기법을 서술한다. 4장에서는 ESBF의 성능을 검증하기 위해 WSN의 생존시간을 기존 기법과 비교 분석한 시뮬레이션 결과를 제시하고 ESBF의 에너지 효율성을 살펴본다. 이후 5장에서 본 논문의 결론을 맺는다.

II. 관련 연구 및 WSN 환경 모델링

2.1 센서 장벽의 센싱 모델

에너지 효율적인 센서 장벽을 형성하는 주제를 다루는 기존 연구에서는 주로 이진 센싱 (binary sensing) 모델을 사용하였다^[7,11,12]. 이진 센싱 모델은 물체가 센서의 탐지 거리 내에 있으면 탐지 확률을 1, 그렇지 않으면 탐지 확률을 0으로 본다. 그러나 이러한 이분법적인 모델로는 과학화 경계 시스템에 사용되는 WSN의 물리적 특성을 반영하기가 어렵다. [7]은 LA를 활용하여 분산적으로 에너지 효율적인 센서 장벽을 형성하는 기법을 제안하였다. 앞서 언급한 이진 센싱 모델이 사용되며, 센서 장벽에 참여하는 센서의 개수를 최소한으로 줄이고 최대한 많은 센서 장벽을 형성하는 방식으로 WSN을 구축하였다. 하지만 침입자 탐지 확률이나 감시 품질은 고려되지 않는다.

이진 센싱 모델을 보완하는 것이 확률 센싱 모델이다. 확률 센싱 모델은 중앙 집중식 센서 장벽 형성 기법^[8]과 격자 기반으로 감시 확률을 계산하는 기법^[10]이 있다. [8]의 중앙 집중식 센서 장벽 기법에서는 중앙 노드에 크게 의존하기 때문에 WSN 구성의 유동성이 떨어지고 실제 상황에 적용할 때 많은 제약 사항이 따르게 된다. [10]의 격자 기반 센서 장벽 형성 기법에서는 침입자가 격자를 따라 침입한다고 가정하고 감시 품질을 계산했다. 하지만 격자를 이용한 방식은 WSN이 배치되는 환경에 따라 효율적인 격자의 크기를 찾아야 하는데, 이는 매우 어려운 일이다. 격자의 크기가 크면 실제 침입자가 침투하는 경로에 대한 현실 반영이 부족하다. 반면, 격자의 크기가 작으면 센서 장벽의 정확한 감시 품질을 계산할 수 있지만, 시

시스템 계산량이 비선형적으로 증가하여 감시 시스템을 구축하는데 드는 비용이 너무 크다. [13]은 [8]의 기법과 LA를 활용하여 센서 장벽 형성 기법을 제안하였지만 역시 중앙 집중식이고 센서 노드 추가 기법이 최적화되어 있지 않다.

2.2 학습 자동화(LA)의 임의 환경

LA는 $\langle A, B, Q, F(\cdot), G(\cdot) \rangle$ 로 정의된다. 여기에서 각 요소는 출력 또는 동작 집합 (A), 입력 또는 피드백 집합 (B), 상태 집합 (Q), 현재 상태와 입력을 다음 상태로 대응하는 함수 (F), 현재 상태 또는 입력을 현재 출력으로 대응하는 함수 (Q)를 의미한다^[14].

그림 1은 LA와 임의 환경과의 관계이다. 임의 환경은 LA의 출력을 입력으로 받아들인 후 그 입력을 평가하여 피드백되어 다시 LA의 입력으로 들어가는 환경이고, $E = \langle A, B, C \rangle$ 로 정의된다. 여기에서 각 요소는 입력 (A), 출력 (B), 페널티 확률 (C)를 의미한다. 입력 (A)과 페널티 확률 (C)은 서로 1 대 1 대응된다. 따라서 임의 환경은 특정 입력이 들어오면 그에 대응되는 페널티 확률을 참고하여 적절한 출력 (B)으로 대응한다.

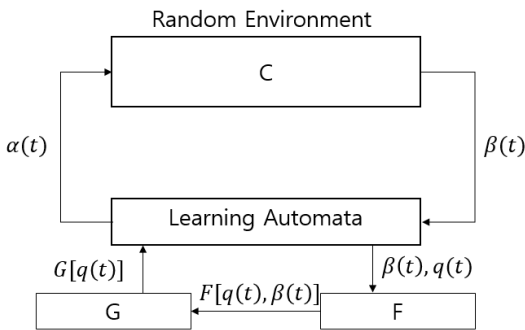


그림 1. 환경과 LA의 관계
Fig. 1. Relationship between Environment and LA

2.3 최소 감지 확률을 가지는 침입 경로

그림 2는 최소 감지 확률을 가지는 침입 경로 l_{min} 에 대한 예시이다. l_{min} 은 두 센서 사이의 수직 이등분선 위에 있다. 이때, 샘플링되는 지점들은 두 센서의 중심을 이은 선 기준으로 정확히 대칭되어야 하고, 두 센서가 서로 동기적으로 샘플링 한다^[8].

침입자의 최대 속도를 V_{max} 라하고, 센서의 샘플링 주기와 주파수를 각각 T 와 f 라 하자. 침입자가 V_{max} 로 l_{min} 을 지나가면 최소 감지 확률이 되므로 샘플링 지점 간의 거리는 V_{max}/f 가 된다. f 는 센서의 샘플링

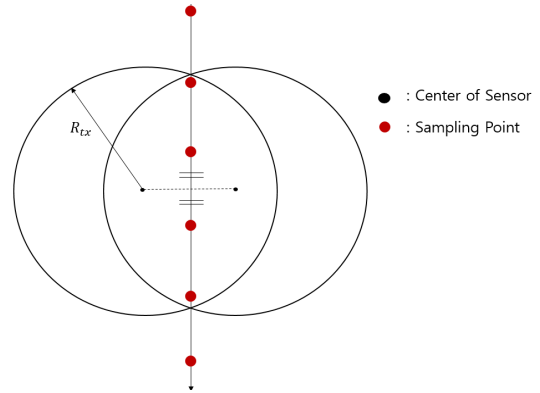


그림 2. l_{min} 에 대한 예시
Fig. 2. Example of l_{min}

주파수이다.

두 센서 사이의 l_{min} 이 정의되었으므로 해당 경로의 모든 샘플링 지점에 대한 결합 감지 확률을 구할 수 있고 이는 두 센서 사이의 최소 감지 확률이 된다. 여러 센서가 참여하는 센서 장벽도 해당 센서 장벽에 참여하는 모든 두 센서 사이의 최소 감지 확률을 구할 수 있으므로 센서 장벽의 최소 감지 확률을 구할 수 있다. 그리고 이는 해당 센서 장벽의 감시 품질이 된다.

감시 품질을 구할 때, 0과 1 사이의 값을 가지는 감지 확률 대신 0 이상의 값을 가지는 감지 이득 (detection gain)을 사용할 경우 선형적으로 감시 품질을 구할 수 있어 앞으로 감지 확률 대신 감지 이득이라는 용어를 사용하고 감지 이득은 다음과 같이 정의 된다.

$$\Phi_s(j) = \ln \frac{1}{1 - p_s(j)} \quad (1)$$

여기서 $p_s(j)$ 는 센서 s 의 특정 샘플링 위치 j 에 대한 센싱 확률이다. s 와 j 사이의 거리를 d 라 할 때, $p_s''(d) > 0$ 이어야 위에서 설명한 l_{min} 이 정의된다^[8].

이에 본 논문에서는 아래와 같은 센싱 모델을 사용한다.

$$p_s(d) = e^{-\alpha(d)^{\beta}} \quad (2)$$

여기서 α 와 β 는 무선센서의 신호 세기의 경로 감쇄 지수 (Path Loss Exponent)이며 센서의 물리적 특성을 나타낸다.

III. 감시 상황 기반 에너지 효율적인 센서 장벽 형성 기법

3.1 센서 장벽의 감시 품질

2.3절에서 정의한 l_{min} 에 대한 두 센서 i, j 의 최소 감지 이득을 $\psi(k)$ 라 하자. 이때, k 는 i 와 j 사이의 거리이고 m 은 l_{min} 내의 샘플링 지점이다. $\psi(k)$ 는 i 와 j 의 m 에 대한 감지 이득의 총합이 된다. 이때, m 과 i 의 거리와 m 과 j 와의 거리는 같으므로 $\Phi_i(m) = \Phi_j(m)$ 이므로 아래와 같이 정리된다.

$$\psi(k) = 2 \sum_{m \in L_{min}} \Phi_i(m) \quad (3)$$

이제 센서 장벽 BP의 감지 이득을 구해보자. BP에 참여하는 센서들 사이의 거리가 센서의 통신 거리 R_{tx} 보다 작으면 서로 연결돼 있다고 하자. 연결된 센서 간에 간선을 만들고 간선의 가중치는 두 센서의 $\psi(k)$ 라 하자. BP의 양 끝단에 있는 센서들을 각각 시작점, 종료점으로 두고 최소 절단 (minimum cut) 알고리즘을 사용하여 최대 용량을 구한다. 이는 BP의 최소 감지 이득, 즉 감시 품질이 된다.

3.2 센서 장벽 형성 과정

네트워크에 배치된 각 센서는 2.1절에서 설명한 LA를 활용하여 센서 장벽을 형성한다. 그림 3과 4는 센서 장벽 형성 과정에 대한 흐름도이다. 처음 센서들이 네트워크에 배치되게 되면 자기 주변 센서들을 찾는 초기화 과정을 거친다. 센서들은 자신의 위치 정보를 담은 메시지를 통신 거리 R_{tx} 내에 브로드캐스트한다.

이 메시지를 받은 센서들은 그에 대한 응답을 보내준다. 응답이 온 센서들에 대해서 자신의 이웃임을 기록해둔다. 이때, 각 센서는 자신의 이웃들에 대한 총합이 1이고 모두 같은 값을 가지는 행동 확률 벡터를 만든다.

예를 들어, 센서 S_i 의 이웃 센서 개수가 4개라면 S_i 의 행동 확률 벡터는 0.25, 0.25, 0.25, 0.25로 초기화되고 각 요소는 이웃 센서와 1 대 1 대응된다. 여기서 행동 확률이 의미하는 것은 해당 센서가 센서 장벽에 참여할 확률이다. 이후 학습 과정을 통해 에너지 효율적인 센서 장벽을 형성할 확률이 높은 행동은 확률값을 높이고 반대는 확률값을 낮추며 학습해 나간다.

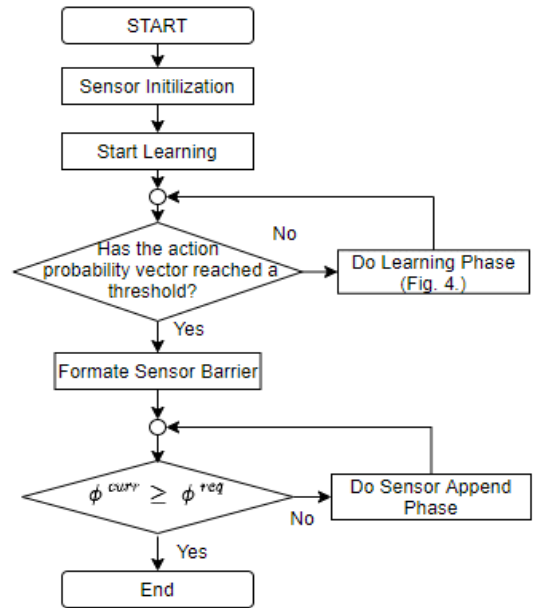


그림 3. 센서 장벽 형성 과정 흐름도
Fig. 3. Flow Chart of Sensor Barrier Formation

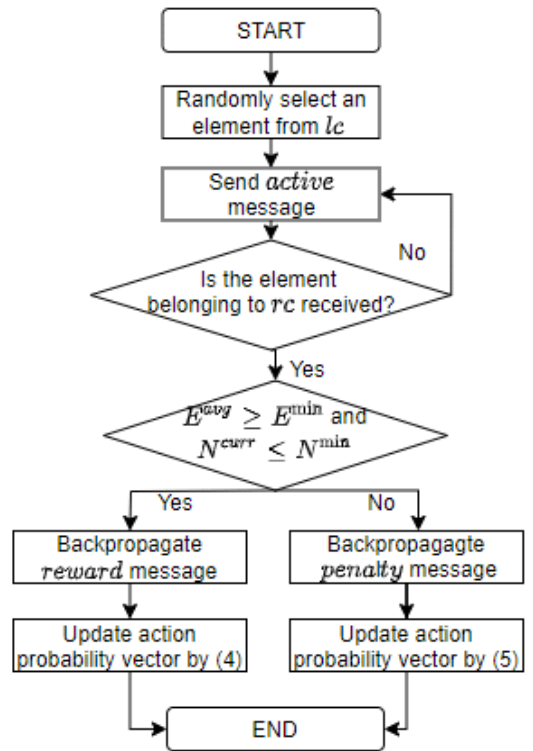


그림 4. LA를 이용한 학습 과정 흐름도
Fig. 4. Flow Chart of Learning Phase Using LA

예를 들어, 그림 5에서 센서 S_1 은 초기화 과정에서 S_2 와 S_3 로의 행동 확률을 0.5, 0.5로 초기화해둔다. S_2 와 센서 장벽을 형성할 경우 센서 장벽에 참여하는 센서 개수는 최소 4개이다. S_3 와 형성할 경우 최소 3개이므로 S_2 와 형성하는 것보다 훨씬 에너지 효율적이다. 따라서 학습 과정을 거치게 되면 S_3 로의 행동 확률은 점점 커지고 S_2 로의 행동 확률은 점점 낮아진다.

이제 앞서 언급한 학습 과정에 대해 설명한다. 센서 장벽에 참여하는 센서 노드 수가 적고 잔여 에너지의 평균이 높을수록 에너지 효율적인 센서 장벽이다. 센서들은 표 1에 정리된 정보들을 저장하고 이를 바탕으로 학습한다.

먼저 네트워크의 왼쪽 경계와 거리가 R_{tx} 보다 작은 센서들의 집합을 lc 라하고 오른쪽 경계와 거리가 R_{tx} 보다 작은 센서들의 집합을 rc 라 하자. lc 의 요소 중 하나가 랜덤하게 선택되어 자신의 행동 확률 벡터의 확률 분포에 따라 다음 행동을 정하고 해당 센서에 *active* 메시지를 전송한다. 이때, *active* 메시지를 전송받은 센서는 N^{curr} , E^{avg} 를 업데이트하고 다시 또 다음 행동을 정해 *active* 메시지를 전송한다.

위 과정은 rc 에 속해있는 센서가 *active* 메시지를 전달받을 때까지 반복된다. 이때 메시지를 전송하는

과정에서 무한 루프에 빠지지 않게 하도록 각 센서는 현재 자신의 위치보다 왼쪽에 있는 센서에는 *active* 메시지를 전송하지 않는다.

rc 에 속해있는 센서가 *active* 메시지를 전달받으면 현재 *active* 메시지를 전송한 모든 센서에 대해서 평가를 한다. $E^{avg} \geq E^{min}$ 이고 $N^{curr} \leq N^{min}$ 이면 *reward* 메시지를 그렇지 않을 경우 *penalty* 메시지를 전송한다⁷⁾.

이 피드백은 역전파 (back propagation) 되어 맨 처음 *active*를 전송한 센서까지 전달된다. *reward*를 받으면 수식 (4), *penalty*를 받으면 수식 (5)를 통해 자신의 행동 확률 벡터를 업데이트한다. 만약 *reward*가 전송될 경우 E^{min} , N^{min} 값은 새로 갱신되고 모든 센서에 전달된다.

$$p_j(t+1) = \begin{cases} p_j(t) + a(1-p_j(t)), & j = i \\ (1-a)p_j(t) & \forall j, j \neq i \end{cases} \quad (4)$$

$$p_j(t+1) = \begin{cases} (1-b)p_j(t), & j = i \\ \frac{b}{r-1} + (1-b)p_j(t) & \forall j, j \neq i \end{cases} \quad (5)$$

여기서 r 는 행동 확률 벡터의 크기고, a 와 b 는 학습률이다. i 는 자신이 *active* 메시지를 전송한 센서에 대응되는 행동 확률 벡터 요소이고 j 는 모든 요소이다. 즉 $p_j(t)$ 는 업데이트 전 j 에 대한 행동 확률이고 $p_j(t+1)$ 은 업데이트 후의 j 에 대한 행동 확률이다.

그림 5를 이용하여 학습 과정을 살펴보자. 그림 5의 WSN이 이제 막 초기화 과정을 끝냈다고 가정하면, S_1 과 S_2 는 lc 에 속하게 되고 두 센서 중 하나를 임의로 선택한다. 만약 S_1 이 선택되었다고 할 때, S_1 은 자신의 행동 확률 벡터의 확률 분포에 따라 다음 행동을 정한다. 만약 S_3 이 선택되었다고 했을 때, S_1 은 S_3 에게 *active* 메시지를 전송한다.

S_3 이 위 과정을 반복하여 S_5 에게 *active* 메시지를 전송했다고 할 때, S_5 는 rc 에 속하므로 평가가 시작된다. 현재 E^{min} , N^{min} 모두 초깃값이므로 *reward* 메시지가 S_3, S_1 순으로 역전파 된다. 두 센서 모두 수식 (4)를 통해 자신의 행동 확률 벡터와 E^{min} , N^{min} 를 최신화한다.

위 학습 과정은 센서 장벽에 참여하는 센서들의 행동 확률 벡터가 특정 임계값에 도달할 때까지 지속한다. 여기서 임계값은 0.9로 둔다. 센서 장벽이 완성된

표 1. 센서들이 저장하는 정보
Table 1. Data that sensors store

Variable	Definition
Φ^{curr}	형성된 센서 장벽의 총 감지 이득
Φ^{req}	요구되는 감지 이득
E^{avg}	선택된 센서들의 평균 잔여 에너지
E^{min}	평균 잔여 에너지의 최솟값
N^{curr}	선택된 센서 개수
N^{min}	센서 개수의 최솟값




그림 5. 센서 네트워크 예시
Fig. 5. Example of Sensor Network

후 Φ^{curr} 값이 최신화되고 센서 장벽에 참여하지 않는 센서들은 휴면 상태가 되어 에너지를 아끼게 된다. 이후 Φ^{curr} 이 Φ^{req} 보다 작거나 현재 센서 장벽 내 센서들의 수명이 다하여 새로 센서 장벽을 형성해야 할 때 깨어날 수 있다.

3.3 센서 추가 과정

만약 앞 절에서 형성된 센서 장벽의 감지 품질 Φ^{curr} 이 요구되는 감지 품질 Φ^{req} 보다 작을 경우에는 그림 6과 같은 센서 추가 과정이 진행된다. 센서 추가 과정은 센서 장벽 주변의 휴면 센서를 깨워 센서 장벽에 참여하게 함으로써 Φ^{curr} 값을 높이는 과정이

```

Adding Sensors
1:   Select nodes  $S_1, S_2$  by using minimum
    cut algorithm
2:   for node  $s$  in  $S_1$ 's neighbor do
3:     if  $s$  in  $S_2$ 's neighbor and
         $s$  is not activate
4:       append  $s$  to  $CN$ 
5:     end if
6:   end for
7:   for node  $cn_i$  in  $CN$  do
8:     calculate  $ohm_i$  which is number of nodes
        participating in BP among  $cn_i$ 's neighbor
9:   end for
10:  find maximum value in  $ohm$ 
11:  if maximum value appears once in  $ohm$  then
12:    wake node  $cn_i$  corresponding to  $ohm_i$ 
        which is maximum value of  $ohm$ 
13:  else
14:    for element  $ohm_i$  in  $ohm$  do
15:      if  $ohm_i$  equals to maximum
        value of  $ohm$  then
16:        append node  $cn_i$  corresponding to
         $ohm_i$  to  $P$ 
17:      end if
18:    end for
19:    for node  $p_i$  in  $P$  do
20:      calculate  $m_i$  which is  $\max_{s \in S} D(p_i, s)$ 
        where  $S$  is nodes participating in BP
21:    end for
22:    wake node  $p_i$  corresponding to  $m_i$ 
        which is minimum value of  $M$ 
23:  end if
    
```

그림 6. 센서 추가를 설명하는 의사 코드
Fig. 6. Pseudo code of adding sensors

다. 이 과정은 $\Phi^{curr} \geq \Phi^{req}$ 을 만족할 때까지 반복된다.

센서 장벽의 감지 이득은 최소 절단 알고리즘을 통해 구해진다. 따라서 최소 절단 알고리즘에 의해 선택된 간선 주변의 센서들을 깨워야 Φ^{curr} 값을 높일 수 있다. 이때, Φ^{curr} 값을 가장 크게 높일 수 있는 센서 하나를 선택하여 깨운다.

먼저 선택된 간선에 대응되는 센서들의 공통 이웃 센서 집합 CN 을 구한다. CN 의 요소 cn_i 의 이웃 중 센서 장벽에 참여하고 있는 센서의 개수를 ohm_i 라 하자. cn 중 ohm 가 가장 큰 센서를 선택하여 깨워야 한다. 이 방법은 네트워크에 센서들이 균일하게 분포된 경우, 최소한의 센서로 최대의 추가 감지 품질을 얻는 방법이다.

센서들이 균일하게 분포되었다면 센서 장벽을 형성했을 때, 각 센서 사이의 거리는 거의 같다. 이는 각 센서 사이의 감지 이득이 거의 비슷하다는 의미이고 여러 간선에 대해서 추가 감지 이득을 가지는 센서를 추가해야 해당 센서 장벽의 감지 품질을 최대 높일 수 있다.

그림 7을 예로 들어 보자. S_1, S_3, S_5 가 센서 장벽을 형성 중이고 S_1 과 S_3 사이의 간선이 최소 절단 알고리즘에 의해 선택된 간선이라 하자. 이때, S_2 와 S_4 가 CN 에 속하게 되고 각각의 ohm 값은 2와 3이 된다. 따라서 S_4 를 깨워야 Φ^{curr} 값을 가장 높일 수 있다.

만약 가장 큰 ohm 값을 가지는 센서가 한 개일 경우 해당 센서를 깨우면 되지만 두 개 이상일 경우 그 중 하나를 선택해야 한다. 두 개 이상일 경우 해당하는 센서들의 집합을 P 라 하자. 이때 센서를 선택하는 과정은 다음과 같이 진행된다.

P 의 요소 p_i 와 BP 에 참여하는 센서 집합 S 의 각

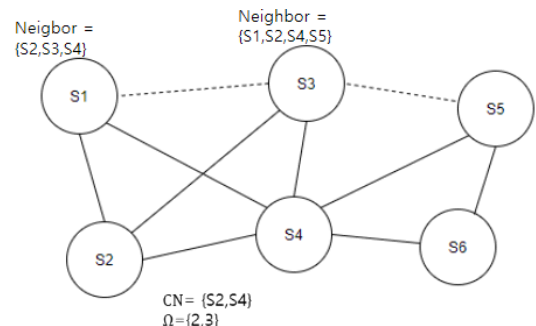


그림 7. 센서 추가 예시
Fig. 7. Example of Appending Sensor

요소와의 거리를 구하고 그중 최댓값을 m_i 라 하자. 즉 m_i 는 다음과 같이 구해진다.

$$m_i = \max_{s \in S} D(p_i, s) \quad (6)$$

여기서 $D(p_i, s)$ 는 유클리드 거리이고 p_i 와 m_i 는 1 대 1 대응된다. 가장 최솟값을 가지는 m_i 에 대응하는 센서 p_i 가 깨워야 할 센서가 된다. 깨워야 할 센서가 정해지면 해당 센서를 깨워 센서 장벽에 참여시키고 Φ^{curr} 값을 최신화한다. 위 방법이 왜 Φ^{curr} 값을 가장 높이는지에 대한 증명은 다음과 같다.

$S = \{s_1, s_2\}$, $P = \{p_1, p_2, \dots, p_n\}$ 인 경우를 고려해보자. s_1 과 s_2 사이의 감지 이득을 α 라하고 추가 되는 센서 p_i 와 s_1, s_2 사이의 감지 이득을 각각 β_i, γ_i 라 하자. 이때, $\alpha + \beta_i$ 와 $\alpha + \gamma_i$ 중 더 작은 값이 해당 센서 장벽의 새로운 Φ^{curr} 이 된다. 감지 이득은 센서 사이의 거리와 반비례하므로 m_i 는 수식 (6)과 같이 정의되고 가장 작은 m 을 가지는 센서가 깨워져야 감지 이득을 가장 높일 수 있다.

IV. 실험 결과

본 장은 ESBF와 MWBA^[8]를 시뮬레이션을 통해 성능을 비교한다. 파이썬의 NETWORKX 패키지를 활용해 시뮬레이션을 진행했고 시뮬레이션에 사용된 환경 및 파라미터들은 표 2에 정리했다. 무선센서들은 세로 2m, 가로 50m인 곳에 임의로 배치되어 WSN을 구성한다. 각 센서의 통신 거리 (R_{tx})는 4m이고 수식 (4), (5)에서 사용할 학습률 0.1이다. 네트워크에 배치된 센서들은 모두 20의 에너지를 가지고 배치되고 센서가 장벽에 참여하게 되면 1타임 슬롯 당 1의 에너지를 소모한다.

표 2. 시뮬레이션에 사용된 파라미터
Table 2. Simulation Parameters

Parameter	Value
Network Width (W)	2m
Network Length (L)	50m
R^{tx}	4m
Learning rate (a, b)	0.1
Energy (E)	20
Φ^{req}	[3,5,7,9]
Number of Sensors (N)	[90,100,110,120]

다양한 감시상황에서의 성능을 보여주기 위해 요구되는 감시 품질 (Φ^{req})과 네트워크에 배치되는 무선센서들의 개수에 변화를 주어 성능을 측정하였다.

특정 상황에서만 ESBF가 MWBA보다 성능이 높은 것이 아님을 보여주기 위해 시뮬레이션 결과값은 총 200회 반복한 결과의 평균이며 매회 센서들을 임의로 배치하였다. 또한, 파라미터값에 변화를 주어 다양한 상황에서 성능을 비교하였다.

성능 비교 지표로는 센서 장벽에 참여하는 센서 개수와 네트워크의 생존시간을 사용하였다. 요구되는 감시 품질이 똑같다는 가정하에 센서 장벽에 참여하는 센서 개수를 줄일수록 전체 WSN에서 소모하는 에너지가 적어지기 때문에 더 에너지 효율적인 센서 장벽을 형성할 수 있다. 센서 장벽에 참여하는 센서 개수가 더 적은 기법이 에너지 효율적임을 보이기 위해 네트워크 생존시간 또한 비교하였다.

MWBA는 중앙 집중식 알고리즘으로 중앙 노드인 시작점 (source)와 종료점 (terminal)이 필요하다. 하지만 ESBF는 분산형 기법으로 중앙 노드가 따로 필요하지 않다. 시뮬레이션의 형평성을 위해 센서 장벽에 참여하는 센서 개수를 비교할 때 MWBA는 중앙 노드 개수인 2를 뺀 값을 사용하였다. 시작점 (source)는 좌표로 (0, L/2)에 위치하고 종료점(terminal)은 (W, L/2)에 위치한다.

4.1 Φ^{req} 변화에 따른 성능 비교

무선센서 네트워크가 배치되는 환경에 따라 요구되는 감시 품질은 다양할 수 있다. 따라서 다양한 Φ^{req} 값에서 ESBF와 MWBA의 성능을 비교하였다.

그림 8과 9는 각각 Φ^{req} 값에 따른 센서 장벽에 참여하는 센서 개수와 전체 네트워크의 생존시간이다.

그림 8을 보면 Φ^{req} 이 증가할수록 센서 장벽에 참여하는 센서 개수는 늘어남을 알 수 있다. 또한, 모든 Φ^{req} 에 대해서 ESBF가 MWBA보다 적은 센서를 가지고 센서 장벽을 형성할 수 있음을 알 수 있다. Φ^{req} 이 3일 때는 거의 차이가 없지만, 그 이상부터는 평균 9.2% 정도의 차이가 난다.

그림 9를 보면 알 수 있듯이 센서 장벽에 참여하는 센서 개수가 늘어날수록 네트워크 생존시간은 줄어든다. 그림 8과 마찬가지로 Φ^{req} 이 3일 때는 거의 차이가 없지만, 그 이상부터는 평균 10.12% 차이가 난다. 즉 ESBF가 MWBA보다 에너지 효율적으로 센서 장벽을 형성한다는 것이다.

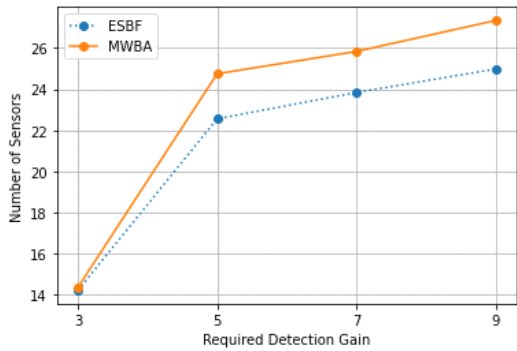


그림 8. ϕ^{req} 에 따른 센서 장벽에 참여하는 센서 개수
Fig. 8. Number of Sensors in Sensor Barrier with different ϕ^{req}

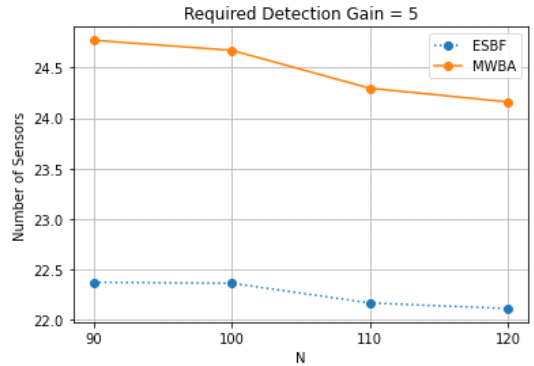


그림 10. 센서 N에 따른 센서 장벽에 참여하는 센서 개수
Fig. 10. Number of Sensors in Sensor Barrier with different N




그림 9. ϕ^{req} 에 따른 네트워크 생존 시간
Fig. 9. Network Lifetime with different ϕ^{req}

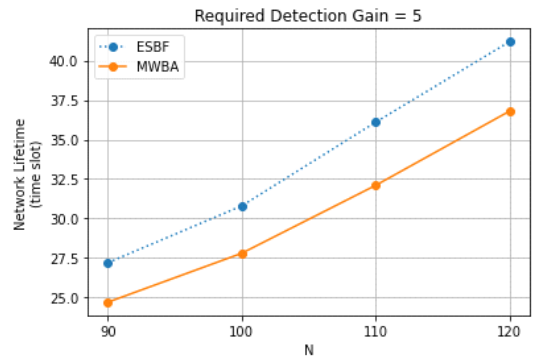


그림 11. 네트워크에 배치된 센서 N에 따른 네트워크 생존 시간
Fig. 11. Network Lifetime with different N

4.2 N 변화에 따른 성능 비교

이번에는 네트워크 내에 배치되는 센서 개수에 변화를 주어 성능을 비교해보았다. 네트워크에 배치할 센서 개수는 상황이나 여건에 따라 달라질 수 있다. 센서 개수가 늘어날수록 각 센서는 선택할 수 있는 선택지가 많아져 적을 때보다 더 에너지 효율적인 센서 장벽을 형성할 수 있다. 이는 곧 센서 장벽에 참여하는 센서 개수는 줄어들고 네트워크의 생존 시간은 늘어나는 것을 의미한다.

그림 10과 그림 11은 ϕ^{req} 이 5인 상황에서 센서 개수 증가에 따른 성능을 비교한 것이다. 그림 10에서 모든 N에 대해서 ESBF가 MWBA보다 평균 9.96% 적은 센서 수를 가지고 센서 장벽을 형성하는 것을 확인할 수 있다.

그림 11에서는 모든 N에 대해서 ESBF가 MWBA보다 평균 11.33% 더 오래 생존함을 확인할 수 있다. 시뮬레이션 결과 모든 N에 대해서 ESBF가 MWBA보다 에너지 효율적인 센서 장벽을 형성함을 알 수 있다.

V. 결론

본 논문에서는 WSN으로 구성된 센서 장벽에서 WSN의 생존시간을 늘리고 요구되는 감시 품질을 충족시키기 위해 확률 센싱 모델과 자동 학습 기법을 이용하는 강화학습을 이용한 감시상황 기반의 ESBF를 제안하였다.

시뮬레이션을 통해 분산형 기법인 ESBF와 중앙 집중식 기법인 MWBA를 비교하였다. 다양한 감시상황을 가정하여 요구되는 감시 품질과 네트워크에 배치되는 센서 개수에 변화를 주어 성능을 측정하였고, 모든 상황에서 MWBA보다 ESBF의 에너지 효율성이 더 높아 생존시간이 증가하고, 더 적은 수의 센서를 이용해서 요구되는 감시 품질을 충족시킬 수 있음을 확인하였다.

제안하는 ESBF는 증가하는 위협에 대비해 에너지 효율적인 센서 장벽 개발에 기여할 수 있을 것으로 기대된다.

References

[1] S. Moon and W. Cho, "Design for improved boundary security system using multiple complex sensors and proving performance with constructing testbed," *J. KICS*, vol. 44, no. 1, pp. 148-157, Jan. 2019.

[2] S. Kumar, T. Lai, and A. Arora, "Barrier coverage with wireless sensors," in *Proc. Int. Conf. Mobile Comput. Netw.*, pp. 284-298, Aug. 2005.

[3] J. Amutha, S. Sharma, and J. Nagar, "WSN strategies based on sensors, deployment, sensing models, coverage and energy efficiency: Review, approaches and open issues," *Wireless Pers. Commun.*, vol. 111, pp. 1089-1115, Mar. 2020.

[4] M. Elhoseny, A. Tharwat, A. Farouk, and A. E. Hassanien, "K-coverage model based on genetic algorithm to extend WSN lifetime," *IEEE Sens. Lett.*, vol. 1, no. 4, Aug. 2017.

[5] H. P. Gupta, S. V. Rao, and T. Venkatesh, "Sleep scheduling protocol for k-coverage of three-dimensional heterogeneous WSNs," *IEEE Trans. Veh. Technol.*, vol. 65, no. 10, pp. 8423-8431, Oct. 2015.

[6] H. Mostafaei, M. Shojafar, B. Zaher, and M. Singhal, "Barrier coverage of WSNs with the imperialist competitive algorithm," *J. Supercomput.*, vol. 73, no. 11, pp. 4957-4980, Nov. 2017.

[7] H. Mostafaei, M. U. Chowdhury, and M. S. Obaidat, "Border surveillance with WSN systems in a distributed manner," in *IEEE Syst. J.*, vol. 12, no. 4, pp. 3703-3712, Dec. 2018.

[8] J. Chen, J. Li, and T. H. Lai, "Energy-efficient intrusion detection with a barrier of probabilistic sensors: Global and local," in *IEEE Trans. Wireless Commun.*, vol. 12, no. 9, pp. 4742-4755, Sep. 2013.

[9] P. Si, J. Ma, F. Tao, Z. Fu, and L. Shu, "Energy-efficient barrier coverage with probabilistic sensors in wireless sensor networks," *Sensors J. IEEE*, vol. 20, no. 10, pp. 5624-5633, Jan. 2020.

[10] P. Xu, J. Wu, C. Shang, and C. Chang, "GSMS: A barrier coverage algorithm for joint surveillance quality and network lifetime in WSNs," in *IEEE Access*, vol. 7, pp. 159608-159621, Oct. 2019.

[11] H. Mostafaei and M. S. Obaidat, "Learning automaton-based self-protection algorithm for wireless sensor networks," *Netw. IET*, vol. 7, no. 5, pp. 353-361, Sep. 2018.

[12] H. Mostafaei, A. Montieri, V. Persico, and A. Pescape, "A sleep scheduling approach based on learning automata for WSN partial coverage," *J. Netw. Comput. Appl.*, pp. 67-78, Feb. 2017.

[13] S. Jeon, M. Lee, and J. Lim "Reinforcement learning based WSN system for assured surveillance quality," in *Proc. KIMST Annu. Conf.*, pp. 376-377, Jul. 2020.

[14] J. Oommen and S. Misra, "Cybernetics and learning automata," Springer Handbook of Automation, Springer, pp. 221-235, 2009.

전 상 범 (Sangbeom Jeon)



2021년 2월 : 아주대학교 국방
디지털융합학과 졸업
<관심분야> 인공지능, 무선네
트워크, 강화학습
[ORCID:0000-0002-1957-4544]

이 민 우 (Minwoo Lee)



1998년 2월 : 한국항공대학교 항
공통신정보공학과 졸업
2013년 2월 : 아주대학교 일반대
학원 NCW공학 박사 졸업
2019년 3월 : 아주대학교 국방디
지털융합학과 대우부교수
<관심분야> 위성통신, 네트워크
보안, 사이버전

[ORCID:0000-0001-7109-4700]

임재성 (Jaesung Lim)



1983년 2월 : 아주대학교 전자
공학 학사

1985년 2월 : KAIST 영상통신
석사

1994년 8월 : KAIST 디지털통
신 박사

1995년 9월~1998년 2월 SK 텔레
콤 중앙연구원 책임연구원

1998년 3월~현재 : 아주대학교 국방디지털융합학과 정
교수

2006년 8월~현재 : 아주대학교 국방전술네트워크 연구
센터장

<관심분야> 이동 및 위성통신, 무선네트워크, 국방전술
통신

[ORCID:0000-0003-0080-9398]