

Decision Transformer와 동적 클러스터 헤드 선택을 활용한 WSN 클러스터링

오호민, 최영준*

아주대학교 인공지능학과

gom2553@ajou.ac.kr, choiyj@ajou.ac.kr*

WSN Clustering with Decision Transformer and Dynamic Cluster Head Selection

Homin Oh, Young-June Choi*

Department of Artificial Intelligence, Ajou University

요약

본 논문에서는 기존 WSN 모델에서 발생하는 생존 시간 관련 문제를 해결하기 위해, 강화학습 기반의 Decision Transformer(DT) 모델과 동적 클러스터 헤드 선택 기법을 결합하여 WSN 클러스터링을 최적화하는 방법을 제시한다. 제안된 방법은 네트워크의 첫 번째 노드 사망 시점(FND)뿐만 아니라 전체 노드 평균 생존 시간까지 동시에 고려하여, 초기 안정성과 장기 운영 성능을 모두 만족시키는 효율적인 클러스터링 전략을 제공한다. 또한, 각 라운드별 노드 개수, 위치, 통신 거리, 에너지 상태 등의 정보를 기반으로 클러스터 헤드를 동적으로 선택함으로써, 노드 간 에너지 불균형을 최소화하고 에너지 효율을 극대화할 수 있다. 실험 결과, 제안된 모델은 기존 WSN 클러스터링 모델과 비교하면 FND 성능과 평균 생존을 모두에서 우수한 성능을 나타냈으며, 특별한 모델 구조 변경이나 세부 파라미터 조정 없이 다양한 네트워크 환경에 범용적으로 적용할 수 있음을 확인하였다.

I. 서론

무선 센서 네트워크(WSN)는 제한된 에너지 자원을 가진 센서 노드로 구성되며, 데이터 처리와 전송 과정에서의 에너지 효율성이 네트워크 수명과 직결된다. 이를 개선하기 위한 대표적인 방법이 클러스터링으로, 네트워크를 여러 클러스터로 나누고 각 클러스터에 클러스터 헤드(CH)를 지정함으로써 트래픽 부하를 분산하고 에너지 소비를 최소화할 수 있다. 각 클러스터는 클러스터 멤버(CM)와 기지국(BS)으로 구성되며, CH는 데이터를 집계한 뒤 BS로 전송한다. 클러스터링 성능은 노드 분포와 CM 선택에 따라 크게 달라지며, 기존의 정적 클러스터링 모델은 동적 환경에서 적응력이 제한적이고, 에너지 비효율, 클러스터 간 간섭, 데이터 손실 등의 문제를 겪는다.

이에 본 연구는 강화학습 모델인 Decision Transformer [1]와 LEACH 모델에서 제안한 동적 클러스터링을 결합한 강화학습 기반 WSN 클러스터링 프레임워크를 제안한다[2]. DT 모델은 Experience Replay와 Target Network를 활용하여 학습 안정성을 확보하며, 동적 클러스터링을 통해 FND와 평균 생존 시간을 동시에 최적화한다. 주요 특징으로는, 모델 구조나 세부 파라미터 수정 없이 다양한 네트워크 환경에 범용적으로 적용할 수 있으며, FND 성능을 최적화하여 초기 네트워크 안정성을 강화하고, 전체 노드 평균 생존 시간을 고려하여 에너지 균형과 데이터 전송 효율을 향상시킨다. 또한, 각 라운드에서 노드 상태, 위치, 거리, 에너지 수준 등 다양한 정보를 기반으로 클러스터 헤드를 동적으로 선택하며, 강화학습 기반 DT 구조를 활용하여 학습 과정에서 안정적인 정책 탐색과 적응을 수행할 수 있다. 본 연구에서는 WSN 클러스터링 성능 비교를 위해 기존 LEACH-RLC와 DQN 기반 강화학습 모델을 분석하였다.

II. 방법

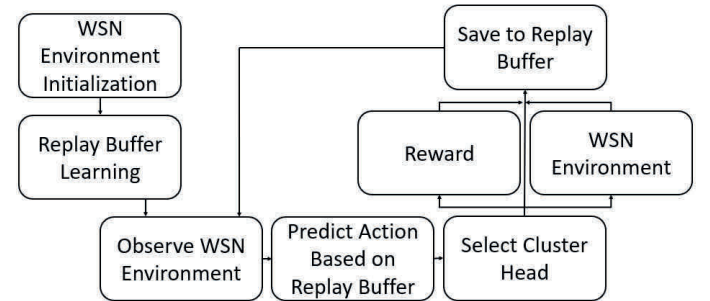


Fig. 1. Decision Transformer 프레임워크

Fig. 1의 경우 Decision Transformer 모델이 WSN 환경에서 작동하는 원리를 보여주는 그림으로 DT의 경우 여타 강화학습과 다르게 Replay Buffer를 활용한 사전 학습으로 초기의 탐험보다 정해진 결과값을 토대로 행동을 예측하고 그에 따른 보상을 받는 구조로 WSN과 같은 연속적인 상태 변화하는 상황에서 매우 높은 성능을 보여준다. 또한, 동적 클러스터 헤드 선택을 위한 수식으로 LEACH 모델에서 제안한 클러스터 헤드 선택 공식을 현재 상태에 맞춰 재계산 하도록 하며 수식은 다음과 같다.

$$K_{opt} \approx \sqrt{\frac{N_{alive}}{2}} \cdot \sqrt{\frac{E_{fs}}{E_{mp}}} \cdot \frac{M}{d_{BS}} \quad (1)$$

이때, 현재 노드에 따른 네트워크 크기 M 은 다음 공식을 따른다.

$$M = \sqrt{M_x \cdot M_y} \quad (2)$$

$$M_x = 2\max_i |x_i - x_{BS}|, M_y = 2\max_i |y_i - y_{BS}| \quad (3)$$

K_{opt} 는 클러스터 헤드의 개수를 뜻하며 이는 N_{alive} 의 현재 생존 노드의 수와 M 의 현재 노드에 따른 네트워크 크기, d_{BS} 의 노드와 BS 간의 평균 거리에 의해 실시간으로 변경되며 이는 시간이 지남에도 WSN 클러스터링 효율이 유지 되도록 하는 중요한 공식이다.

노드 집합 $N = \{1, 2, \dots, n\}$, 각 노드의 에너지 E_i , 패킷 크기 S_i , 싱크 노드 위치 (x_i, y_i) 라고 하면, 각 노드의 전송에 필요한 에너지는 다음과 같다.

$$E = \begin{cases} E_i S_i + E_{fs} S_i D_i^2, & D_i \leq d_0 \\ E_i S_i + E_{mp} S_i D_i^4, & D_i > d_0 \end{cases} \quad (4)$$

$$D_i = \sqrt{(x_i - x_{bs})^2 + (y_i - y_{bs})^2} \quad (5)$$

이후 강화학습 보상 함수는 에너지 밸런스와 효율을 토대로 하며 공식은 다음과 같다.

Energy balance: 각 노드 간의 에너지 밸런스는 FND 측면에서 매우 중요한 문제이다. 단순히 에너지의 효율만을 고려한다면 FND 성능이 급격히 감소할 가능성이 존재한다.

$$E_{balance} = Var(E_i) + \max(E_i) - \min(E_i) \quad (6)$$

Energy efficiency: WSN 클러스터링의 핵심은 노드의 평균 수명 연장이다. 그렇기에 각 클러스터 헤드가 적절한 위치에 배치되어 에너지 효율을 높일 수 있도록 유도해야 한다.

$$\Delta E_{avg} = \bar{E}_{prev} - \bar{E}_{current}, \frac{1}{N} \sum_{i=1}^N E_i \quad (7)$$

전체적인 보상 함수를 공식화하면 다음과 같다.

$$R = 100 - (E_{total} + \omega_{balance} E_{balance}) \quad (8)$$

III. 실험

Fig. 2와 Fig. 3에서 확인할 수 있듯이, 기존 DQN 모델은 노드가 초기에 죽지 않을 정도로 작은 공간에서는 제안한 모델과 유사한 수준의 FND(First Node Death)와 평균 생존율을 보였지만, 노드가 초기 단계에서도 사망할 수 있는 상대적으로 넓은 공간에서는 FND 성능이 급격히 저하되는 것을 관찰할 수 있다. 한편, LEACH-RLC 모델은 작은 공간에서는 에너지 효율이 낮아 성능이 제한적이지만, 공간 크기가 커지더라도 최소한의 FND 성능을 유지하는 특징을 보였다. 반면, 제안한 모델은 공간의 크기와 관계없이 안정적으로 높은 FND와 평균 생존율을 달성함을 확인할 수 있었으며, 이는 동적 클러스터링과 에너지 균형 기반 보상 설계를 통해 다양한 네트워크 조건에서도 노드 생존 가능성과 네트

워크 수명을 동시에 최적화할 수 있음을 의미한다.




Fig. 2. 제안한 모델의 기본 성능 비교 그래프로 보편적 환경(노드 수 100개, 영역 $100 \times 100 \text{ m}^2$, 초기 에너지 0.5 J)에서의 시간에 따른 Round 수 대비 생존 노드의 변화를 나타내는 그래프.




Fig. 3. 대규모 WSN 환경(1000개의 노드, $500 \times 500 \text{ m}^2$ 영역, 초기 에너지 2.0 J)에서 각 모델의 적응성 및 실용성 비교 그래프로 기존보다 넓은 영역과 많은 노드를 구성하여, 각 모델의 적응성 및 확장성 평가 결과 그래프.

IV. 결론

본 연구에서는 강화학습 기반 WSN 클러스터링 프레임워크를 제안하여, 기존 정적 클러스터링 모델과 DQN 기반 모델의 한계를 극복하고 에너지 효율성과 네트워크 수명을 동시에 향상시켰다. Decision Transformer 기반 동적 클러스터 헤드 선택과 다중 목표 보상 구조를 활용하여 FND와 평균 생존 시간을 안정적으로 개선하였으며, 다양한 동적 환경에서도 클러스터링 성능이 유지됨을 확인했다.

V. 참고 문헌

- 1) Lili Chen, Kevin Lu, Aravind Rajeswaran, Kimin Lee, Aditya Grover, Michael Laskin, Pieter Abbeel, Aravind Srinivas, Igor Mordatch, "Decision Transformer: Reinforcement Learning via Sequence Modeling," Advances in Neural Information Processing Systems 34 (NeurIPS 2021)
- 2) W. R. Heinzelman, A. Chandrakasan, H. Balakrishnan, "Energy-Efficient Communication Protocol for Wireless Microsensor Networks," Proceedings of the 33rd Hawaii International Conference on System Sciences (HICSS), Jan. 2000