

채널 전력 감지를 활용한 기계 학습 기반 데이터 수집형 수중 매체 접속 제어 기법

이종원, 박신영, 도은주, 조호신*
경북대학교

2048jw@knu.ac.kr, sarah7993@naver.com, ij020226@naver.com, *hscho@ee.knu.ac.kr

Machine Learning Based Data Gathering Underwater Medium Access Control Scheme Employing Carrier Sensing

Jong-Won Lee, Shin-Young Park, Eun-Ju Do, Ho-Shin Cho*
Kyungpook National Univ.

요약

본 논문은 수중에 임의로 배치된 다중 센서 노드로부터 해수면에 위치한 싱크 노드까지의 데이터 수집을 목표로 하는 수중 센서 네트워크에서의 매체 접속 제어 기법을 제안한다. 긴 전송 시간을 가지는 수중 음향 채널을 고려할 때, 싱크 노드에서의 성공적인 수신을 위한 노드들 사이의 제어 패킷 교환은 매우 비효율적이다. 따라서 본 논문에서는 기계 학습을 통해 학습된 센서 노드가 채널 전력 정보를 이용하여 올바른 데이터 송신 시점을 스스로 결정한다. 모의 실험 결과, 기계 학습을 활용한 접속 제어 기법은 제어 패킷 교환 없이도 높은 성능을 보이며, 기계 학습 모델 중 MLP(Multiple Layer Perceptron)가 대체로 가장 좋은 성능을 보인다.

I. 서론

수중 통신에 사용되는 음파는 지상의 라디오파와 달리 전송 지연이 매우 크므로 각 센서 노드들이 전송한 데이터 패킷이 싱크 노드에서 충돌되지 않기 위해서는 전송 시점뿐만 아니라 싱크 노드까지의 거리를 동시에 고려해야 한다. 해당 특성을 시공간 불확실성(Space-Time uncertainty)이라고 부르며 이를 극복하는 연구가 필요하다[1].

시공간 불확실성을 극복하기 위해, 제어 패킷을 교환하는 기존의 방식은 수중 음향 채널의 용량이 매우 제한적이고 전송 시간이 길다는 것을 고려할 때 비효율적인 방식이 된다. 따라서 본 논문에서는 학습된 기계 학습 기반 센서 노드가 채널 전력 정보를 감지하고, 이 정보를 바탕으로 스스로 전송 시점을 결정하는 새로운 매체 접속 제어 기법을 제안하고자 한다[2].

II. 시스템 모델

A. 시스템 구조

본 연구에서 고려된 데이터 수집 네트워크 구조는 1:N 트리 토폴로지 구조를 채택한다. 이 구조는 하나의 싱크와 임의로 배치된 N 개의 센서 노드로 구성된다. 각 센서 노드는 정보를 수집하며, 이 정보는 1-Hop 전송을 통해 싱크 노드로 전송된다.

B. 데이터 패킷 전송 결정 절차




그림 1. 데이터 패킷 전송 절차 시나리오

그림 1 은 본 연구에서 제시하는 데이터 패킷 전송 시나리오를 요약한 것이다. 각 센서 노드는 데이터 패킷이 발생하면 정해진 절차에 따라 싱크 노드로의 송신을 수행한다. 데이터 패킷이 발생하면 센서 노드는 사전에 고정된 기간 동안 채널의 전력을 감지하는데, 이 기간을 T_m 으로 정의한다. 센서 노드는 T_m 동안 감지한 채널 전력 정보를 바탕으로 데이터 패킷의 송신 여부를 결정하며, 적합하다고 판단되면 즉시 송신한다(그림 1의 ①). 송신이 부적합하다고 판단될 경우, 센서 노드는 추가적인 채널 전력 감지를 수행한다. 이 추가 전력 감지 기간은 T_a 로 정의한다. 센서 노드는 Sliding Window 기법을 사용하여 T_a 동안 측정된 추가 전력 정보로 기존의 채널 전력 정보를 갱신한다. 갱신된 채널 전력 정보를 바탕으로 센서 노드는 다시 데이터 패킷 송신 여부를 판단하며, 송신이 적합하다고 판단될 경우 즉시 송신한다(그림 1의 ②). 이 과정은 데이터 패킷이 송신될 때까지 반복된다.

III. 기계 학습 모델 설계 및 결과

A. 학습 데이터 추출

기계 학습을 위한 데이터 세트는 실제 수중 환경과 유사한 모의 실험 환경을 통해 추출한다.

표 1. 모의 실험 환경 변수

Parameter	Values
T_m	6 sec
T_a	1 sec
Transmission time	3 sec
Propagation speed	1500 m/s

표 2. 노드의 위치

Node	Location[x,y,z](Unit:m)
Sink node	[0,0,0]
Sensor A	[0,-750,750 $\sqrt{3}$]
Sensor B	[0,750,-750 $\sqrt{3}$]
Sensor C	[-500 $\sqrt{3}$,0,-500 $\sqrt{3}$]

표 1 은 모의 실험에 사용된 환경 변수이며, 표 2 는 노드들의 위치이다. 데이터 패킷은 포아송 과정으로 생성되며, 센서 노드 B 와 C 는 생성 즉시 싱크 노드로 전송한다. 센서 노드 A 는 각 데이터 패킷 생성 시 T_m 동안 채널 전력을 감지한 후 즉시 전송한다. 측정된 채널 전력 정보와 싱크 노드에서의 패킷 수신 여부는 데이터 세트로 저장된다.

B. 기계 학습 모델

추출한 데이터 세트는 기계 학습 모델의 학습 데이터로 활용된다. 학습된 모델은 제안된 기법에 따라 모의 실험 환경에서 구현되며, KNN(K-Nearest Neighbor), DTC(Decision Tree Classification), SVM(Support Vector Machine), MLP(Multiple Layer Perceptron)를 포함한 총 4 가지 지도 학습 모델이 사용된다.

C. 성능 지표

센서 노드의 예측 결과가 정확한 경우를 'T(True)', 부정확한 경우를 'F(False)'라 분류하고, 센서 노드가 전송 시점을 적합하다고 예측한 경우를 'P(Positive)', 부적합하다고 예측한 경우를 'N(Negative)'로 구분한다.

표 3. 전송 시점 예측 및 수신 성공 여부에 대한 4 가지 경우

실제 : 싱크 수신 가능	TP (True Positive)	FN (False Negative)
실제 : 싱크 수신 불가능	FP (False Positive)	TN (True Negative)
	예측 : 중신, 싱크 수신 가능	예측 : 미중신, 싱크 수신 불가능

이에 따라 표 3 과 같이, 전송 시점 예측과 수신 성공 여부를 기반으로 센서 노드의 예측 결과를 4 가지 경우로 분류한다. 모의 실험에서 각각의 경우가 발생하는 횟수를 N_{TP} , N_{FN} , N_{FP} , N_{TN} 로 정의하고, 이를 바탕으로 성능 지표는 다음과 같이 정의한다.

$$Accuracy (정확도) = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FP} + N_{TN}} \quad (1)$$

$$Recall (재현율) = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (2)$$

$$Precision (정밀도) = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (3)$$

D. 결과

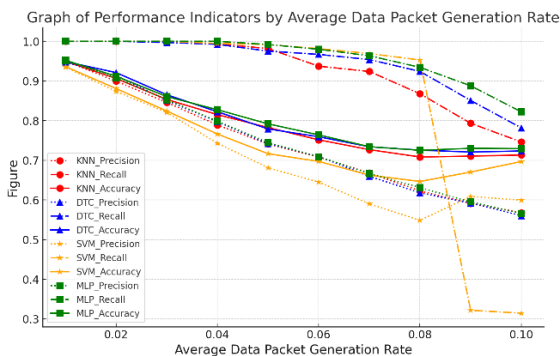


그림 2. 평균 데이터 패킷 발생률에 따른 성능 지표

그림 2 는 본 연구에서 수행된 모의 실험을 통해 관찰된 기계 학습 기반 예측 모델의 성능을 요약한 것이다. 모든 모델의 성능 지표는 평균 데이터 패킷 생성률 증가에 따라 감소하는 경향을 보였다. 이는 데이터 생성률 증가가 채널 경쟁을 심화시키며 모델의 송신 시점 예측을 어렵게 만들었음을 의미한다. 특히, 평균 데이터 패킷 생성률 0.1 은 평균 10 초간 1 개의 데이터 패킷이 생성되므로 센서 노드 3 개가 채널을 공유함에 따라 싱크 노드는 평균 10 초간 3 개의 패킷을 수신해야 한다. 개별 데이터 패킷이 3 초(Transmission time) 동안 채널을 점유하므로 연속적인 데이터 패킷 수신 간의 가드 타임을 고려하면 10 초간 충돌 없이 수신 가능한 데이터 패킷은 3 개이다. 즉, 평균 데이터 패킷 생성률 0.1 은 10 초간 수신 가능한 데이터 패킷이 3 개일 때, 평균 3 개의 데이터 패킷을 수신해야 함을 의미한다. 이러한 환경에서 SVM 모델을 제외한 모든 모델은 정확도 71%, 재현율 75%, 정밀도 56% 이상의 수치를 달성했다. 그 중 MLP 모델은 정확도 72.9%, 재현율 82.2%, 정밀도 56.6%로 가장 높은 수치를 보였다. 이는 MLP 의 DNN(Deep Neural Network)을 이용한 학습 구조 특성이 송신 시점 결정에 더 적합했으며, 제어 패킷 없이도 효율적인 데이터 수집이 가능함을 시사한다. SVM 모델은 다른 모델에 비해 재현율을 제외한 성능 지표에서 낮은 수치를 보이지만, 96%이상의 가장 높은 재현율을 가진다. 그러나 평균 데이터 패킷 생성률이 0.08 보다 증가함에 따라 재현율이 급격히 저하되는 동시에 60%이상의 가장 높은 정밀도 값을 보인다. 이는 SVM 이 특정 조건에서 성능이 변함을 나타낸다.

IV. 결론

본 논문에서는 센서 노드가 채널 전력 감지를 통해 전력 정보를 측정하고, 이 데이터를 바탕으로 데이터 전송 시점을 결정하는 기계 학습 기반 시스템 모델을 제안하였다. 실제 수중 환경과 유사한 모의 실험 환경을 구성하여 측정된 데이터를 학습에 활용하였다. 4 가지 종류의 기계 학습 모델을 비교한 결과, MLP 모델이 대체로 가장 높은 성능을 보이지만 특정 조건에서 SVM 모델이 더 좋은 성능을 보인다. 이러한 결과는 주어진 환경에서 적절한 기계 학습 모델을 이용하여 효율적인 데이터 수집형 구조의 매체 접속 제어 가능함을 시사한다.

참고 문헌

- [1] J.H. Kim, T.H. Im, T.G. Chung, S.Y. Kim, and H.L. Ko, "A Study on the trends of recent underwater communication network systems," in Proceedings of Symposium of the Korean Institute of communications and Information Sciences, pp.678-679 (Nov.2011)
- [2] D.H. Shin, S.J. Lee, and C.H. Kim, "Considerations and Issues for Applying the Existing Network Security to Underwater Acoustic Sensor Networks," Journal of Korea Multimedia Society, vol 20, no.12, pp.1941-1943 (Dec.2017)
- [3] S. Park, J. Byun, K. -S. Shin and O. Jo, "Ocean Current Prediction Based on Machine Learning for Deciding Handover Priority in Underwater Wireless Sensor Networks," 2020 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC), Fukuoka, Japan, 2020, pp. 505-509