

링 기반 라우팅 무선 센서네트워크에서 CNN 학습 기반 네트워크 수명 향상을 위한 가우시안 데이터 증강 기법

강민철, 빈경민, 김준수, 김수민*

한국공학대학교

E-mail: {swrkdalscjf, been1996, junsukim, *suminkim}@tukorea.ac.kr

A Gaussian Data Augmentation Method for CNN Learning-Based Network Lifetime Extension in a Wireless Sensor Network with Ring-Based Routing

Min Chul Kang, Gyoungmin Been, Junsu Kim, Su Min Kim*

Tech University of Korea

요약

본 논문에서는 링 기반 라우팅 (ring-based routing) 무선 센서 네트워크에서 네트워크 수명을 연장하기 위해 제안된 CNN 학습 기반 다중홉 무선 센서네트워크 수명 연장 기법에서 발생하는 과적합 문제를 해결하여 추가적으로 성능을 향상시킬 수 있는 가우시안 데이터 증강 기법을 제안한다. 시뮬레이션을 통해 제안 기법이 기존 기법 대비 추가적인 수명 향상 이득을 성취할 수 있음을 보이고, 다양한 센서 노드 분포에 대해 일반화하여 적용할 수 있음을 확인하였다.

I. 서론

무선 센서 네트워크(Wireless Sensor Network, WSN)에서 센서 노드는 일반적으로 배터리로 동작하며, 최대 전송 거리 밖의 노드의 경우 다중홉 협력 중계 전송을 통해 싱크 노드로 데이터를 전달한다. 이러한 중계 전송은 특정 센서 노드의 배터리를 불균형적으로 소진시켜 네트워크 내에서 에너지 홀 (energy hole) 문제를 유발한다 [1]. 이러한 문제를 해결하기 위해 네트워크를 두 개의 링 영역으로 나누고, 내부/외부 링에서의 전송방식을 달리하여 네트워크 수명을 연장시키는 ring based routing - simultaneous wireless information and power transfer (RBR-SWIPT) 기법이 제안되었다 [1]. 그러나 기존 RBR-SWIPT 기법에서는 고정 크기의 내부 링을 가정하고 성능을 분석하여 네트워크 내 센서 노드의 배치에 따라 네트워크 수명이 저하될 수 있었다. 이를 개선하기 위해 노드 분포를 이미지화하고, 노드 분포 이미지 데이터를 활용한 convolutional neural network (CNN) 학습을 통해 노드 분포에 따른 네트워크 내부 링의 크기를 조절하여 네트워크 수명을 연장한 CNN 학습 기반 다중홉 무선 센서네트워크 수명 연장 기법이 제안되었다 [2]. 하지만 이 기법에서는 매우 많은 경우의 수를 고려하기 때문에 과적합 (over-fitting) 문제가 발생하여 새로운 노드 분포에 대한 일반화가 어려웠다. 본 논문에서는 센서 노드 분포를 이미지화하는 과정에서 노드 좌표를 중심으로 가우시안 노이즈를 추가한 이미지 데이터 증강을 통해 과적합을 방지함으로써 네트워크 수명 성능을 향상시키는 가우시안 데이터 증강 기법을 제안하고, 시뮬레이션을 통해 성능을 비교 분석한다.

II. 시스템 모델

본 논문에서는 그림 1과 같이 네트워크 중심에 하나의 싱크 노드와 균일하게 분포된 센서 노드들로 이루어진 다대일 무선 센서네트워크 모델을 고려한다. 각 센서 노드는 배터리로 동작하고 수집한 센싱 데이터를 싱크 노드로 전송하는데 에너지를 소모한다. 따라서 노드 간의 최대 전송 거리가 제한되어 싱크 인접 노드가 아닌 경우, 협력 다중홉 중계 전송을 통해 데이터를 싱크 노드로 전송되도록 한다. 모든 센서 노드는 Round Robin 방식으로

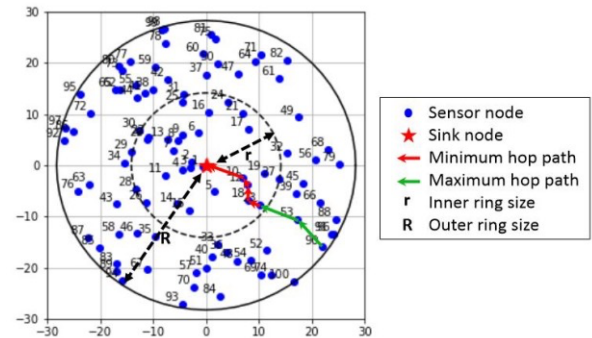


그림 1. 시스템 모델

순차적으로 데이터를 싱크로 전송하며, 데이터 전송 경로는 중앙집중식으로 싱크 노드가 결정한다. 데이터 라우팅은 링 기반 라우팅 방식에 배터리 용량을 고려한 에너지 전송 및 하베스팅을 수행하여 네트워크 수명을 연장하는 RBR-SWIPT 기법을 사용한다. RBR-SWIPT 모델은 네트워크를 두 개의 링으로 나누고 각각에 서로 다른 데이터 전송 방식을 적용하여 상대적으로 에너지를 많이 소비하는 내부 링은 전송거리를 줄이는 최다 홉 전송을 통해 에너지 소모를 최소화하고, 특정 노드의 에너지 소모가 적은 외부 링은 최소 홉 전송과 에너지 전송을 통해 네트워크 전체 관점에서 보다 효율적인 에너지 소모를 가능하도록 한다 [3].

III. 제안 가우시안 데이터 증강 기법

본 장에서는 기존 RBR-SWIPT 기법의 내부 링 크기를 센서 노드 분포에 대한 CNN 학습을 통해 결정하는 방식과 노드의 위치 정보를 가우시안 분포를 사용하여 이미지 데이터로 증강하는 기법을 설명한다. CNN 학습을 위한 훈련 데이터는 그림 2와 같다. 그림 2(a)는 센서 노드의 유무에 따라 1 또는 0으로 나타낸 비트맵 이미지이다. 생성된 이미지에서 각 노드의 상, 하, 좌, 우로 1~2픽셀만큼 랜덤하게 움직인 분포를 그림 2(a) 분포와 비교하면 네트워크 수명

(lifetime) 성능을 최대화 하는 링 크기는 변화가 없다. 여기서 네트워크 수명은 네트워크 내 처음으로 배터리 잔량이 0이 되는 노드가 발생하는 시점으로 정의한다. CNN 학습 과정에서 센서 노드가 위치한 곳을 제외한 영역을 0으로 표현하기 때문에 그림 2(a) 분포와 랜덤하게 움직인 분포의 컨볼루션(convolution) 연산 과정에서 필터가 가지는 매개변수 중 소수의 매개변수만을 사용하여 특징 맵을 생성하기 때문에 과적합(over-fitting)이 발생할 확률이 커진다. 이를 방지하기 위해 그림 2(b)와 같이 센서 노드가 존재하는 좌표를 중심으로 가우시안 분포를 따르는 노이즈를 추가하여 데이터가 증강된 이미지를 생성한다. 가우시안 노이즈를 추가하는 수식은 다음과 같다.

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2 + y^2)}{2\sigma^2}} + g(\sigma), \quad (1)$$

$$g(\sigma) = 1 - \frac{1}{2\pi\sigma^2}. \quad (2)$$

식 (1)에서 센서 노드의 위치를 중심으로 x 는 가로축, y 는 세로축으로 멀어지는 픽셀 수를 나타낸다. $g(\sigma)$ 는 센서 노드가 위치하는 중심 값을 1을 유지하기 위한 오프셋 값으로 식 (2)와 같다. 이렇게 생성된 그림 2(b)는 특정 링 사이즈에서 센서 노드가 위치할 수 있는 확률을 나타내는 이미지로 해석이 가능하다.




그림 2. CNN 학습 데이터: (a) 센서 유무 기반 노드 분포 이미지, (b) 가우시안 데이터 증강된 노드 분포 이미지

IV. 성능 평가

시뮬레이션 환경은 기존 RBR-SWIPT 기법 [1]과 동일하게 경로 감쇄 지수가 3인 path-loss 모델을 채택한다. 전체 네트워크 영역은 60m × 60m로 설정되었으며, 싱크 노드는 네트워크의 중앙 (30, 30)에 위치하여 데이터를 수집한다. 100개의 센서 노드는 각 시뮬레이션마다 균일하고 랜덤하게 배치된다. 각 센서 노드의 최대 전송거리 10m이며, 초기 배터리 용량은 0.05로 설정한다. 전송 대역폭은 0.1MHz이며, 각 타임슬롯은 100ms로 설정한다. 네트워크의 지속 시간은 배터리 잔량이 0인 첫 번째 노드가 발생하는 시점까지이며, 네트워크 수명 성능은 이 시간 동안 전송된 패킷 수인 네트워크 수명 수율 (lifetime throughput)로 측정한다 [4].

그림 3은 네트워크 수명 수율 성능 결과를 보여준다. 그림 2(a)의 노이즈가 추가되지 않은 base 이미지, 가우시안 노이즈의 분산에 따라 $\sigma^2 = 0.25$, $\sigma^2 = 0.5$ 인 이미지를 훈련 데이터 수를 변화시키면서 살펴본 것이다. RBR-SWIPT 기법에서 최대 성능은 optimal로 표기한다. 원본 base 이미지의 경우, 훈련 데이터 수가 증가함에 따라 수명 수율이 소폭 증가한다. 이는 과적합이 발생하여 훈련 데이터 수가 증가시키더라도 성능 향상에 크게 도움이 되지 않음을 보여준다. $\sigma^2 = 0.25$ 이미지의 경우, 훈련 데이터 수가 많아짐에 따라 과적합 현상이 줄어들어 성능이 좋아짐을 확인할 수 있다. $\sigma^2 = 0.5$ 이미지의 경우, 훈련 데이터 수가 5,000개에서 가장 우수한 성능




그림 3. 네트워크 수명 수율 (lifetime throughput) 성능

을 보이지만 훈련 데이터 수가 증가함에 따라 $\sigma^2 = 0.25$ 이미지 대비 성능 개선이 크지 않다. 분산이 큰 노이즈 분포를 사용하게 되면 센서 노드가 존재하는 좌표 주변의 픽셀 값이 커지게 되는데, 이는 주변 센서 노드 분포 확률을 증가시켜 훈련 데이터 양이 적은 경우에는 도움이 되지만 훈련 데이터 수가 증가함에 따라 노이즈가 추가된 이미지에 오히려 과적합을 더 발생시켜 성능을 열화시킬 수 있음을 의미한다.

V. 결론

본 논문에서는 링 기반 무선 센서네트워크에서 센서 노드의 분포에 대한 CNN 학습을 위한 이미지 데이터 생성 과정에서 과적합을 줄이기 위해 노드 좌표 주변에 가우시안 노이즈를 추가하여 데이터를 증강하는 기법을 제안하였다. 시뮬레이션 결과, 센서 노드의 유무에 따른 비트맵 이미지로 학습한 결과보다 제안 가우시안 데이터 증강 기법은 과적합을 감소시켜 네트워크 수명 성능을 향상시킬 수 있음을 확인하였다. 또한, 훈련 데이터 수에 따라 분산 값을 적절히 조절하면 다양한 센서 노드 분포에 대해서 적극적으로 동작하면서 네트워크 수명을 연장시킬 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 ICT혁신인재4.0 사업 (IITP-2024-RS-2022-0156326)과 과학기술정보통신부의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2022R1F1A1074556).

참고 문헌

- [1] G. Been, S. M. Kim, and J. Kim, "SWIPT-Based Routing Protocol for Lifetime Extension of Wireless Sensor Networks," in Proc. *IEEE ICUFN*, July 2023.
- [2] G. Been, M. C. Kang, S. M. Kim, and J. Kim, "CNN based Lifetime Extension for Multihop Wireless Sensor Networks," in Proc. *JCCI*, Apr. 2024.
- [3] I. Krikidis, S. Timotheou, S. Nikolaou, G. Zheng, D. Wing, and R. Schober, "Simultaneous Wireless Information and Power Transfer in Modern Communication Systems," *IEEE Commun. Magazine*, vol. 52, no. 11, pp. 104-110, Nov. 2014.
- [4] L. Lin, N. B. Shroff, and R. Srikant, "Asymptotically Optimal Energy-Aware Routing for Multi Hop Wireless Networks with Renewable Energy Sources," *IEEE/ACM Trans. Networking*, vol. 15, no. 5, pp. 1021-1034, Oct. 2007.