

그래프 신경망을 이용한 관망에서의 신호 소스 위치 예측 방법

고석갑, 김에덴, 이병탁

한국전자통신연구원

{softgear, kimed93, bytelee}@etri.re.kr

A Method for Signal Source Location Prediction in Pipe Networks Using Graph Neural Networks

SeokKap Ko, Eden Kim, and Byung-Tak Lee

Electronics Telecommunications Research Institute (ETRI)

요약

본 논문은, 관망(pipe network)에 특이 신호가 발생하였을 때, 관망에 설치된 센서들로부터 수집된 데이터를 이용하여 그 신호 소스의 위치를 예측하는 방법을 제안한다. 센서의 설치 위치와 관망의 구조정보를 이용하여 구성된 그래프 정보와 센서에서 측정된 값을 입력으로 하고, 각 센서로부터 신호 소스와의 거리를 출력으로 하는, 그래프 신경망을 구성 및 학습한 뒤, 신호 소스의 위치를 예측하는 방법을 제시한다. 시뮬레이션을 통하여 제안된 그래프 신경망을 이용한 신호 소스 위치 예측 모델의 유용성을 검증하였다.

I. 서론

우리 주변에는 상수도 공급망, 하수도 망, 가스 공급망, 석유 공급망 등 복잡한 파이프로 구성된 다양한 관망이 구축되어 있다. 최근 사물인터넷 기술이 도입되면서 관망의 상태를 모니터링하기 위한 센서들이 관망의 곳곳에 설치하고 있다. 부식 및 노후, 공사, 사고, 지각변동, 기상변화 등으로 인해 파이프의 특정 지점이 손상될 수 있다. 이 경우 손상 지점에서 특이 신호가 발생하며 이 지점을 신호 소스라고 한다. 신호 소스를 찾는 기존의 연구는 물리적 특성과 이론에 근거한 모델 기반 접근 방법이었다[1][2]. 비교적 단순한 구조에서는 모델 기반 접근 방법이 좋은 성능을 내지만, 복잡한 실제 환경에서는 성능저하가 발생할 수 있다. 복잡한 관망 구조 및 신호 전파 특성, 저전력 센서의 데이터 수집능력 한계 등으로 인하여 관망에 설치된 센서들의 데이터로부터 신호 소스 위치를 예측하는 문제는 어렵다.


최근 기계학습 기반의 인공지능 기법이 다양한 분야에 적용되고 있다. 기계학습 모델에는, 일반적인 분류 및 회귀분석에 사용되는 다계층 신경망 및 이미지 분류 문제에 사용되는 컨볼루션 네트워크, 시계열 예측에 사용되는 LSTM(Long Short Term Memory) 등이 있다. 기계학습 모델 중 그래프 신경망은 노드의 특징값에 추가로 노드의 연결 관계를 함께 학습할 수 있다. 그래프 신경망 중 그래프 컨볼루션 네트워크는 그래프상 인접 노드와의 관계를 동일 가중치를 이용하여 학습하여 예측 성능을 향상시킬 수 있다[3]. 본 논문에서는 관망의 구조와 관망 상에서의 센서의 위치를 그래프로 구성하여 그래프 컨볼루션 네트워크를 이용한다.

본 논문에서는 관망을 그래프로 변환하는 방법, 그래프 신경망을 이용하여 센서로부터 신호 소스 위치를 예측하는 방법에 대해 설명한다. 시뮬레이션을 통하여, 그래프 신경망을 이용한 신호 소스 예측 모델의 유용성을 검증하였다.

II. 본론

(그래프구성방법) 그래프는 노드와 엣지로 구성된다. 노드는 특성 데이

터를 가지고 있는 지점이다. 엣지는 노드와 노드 사이를 연결하는 선이며 연결 강도를 나타내는 가중치 및 속성을 가질 수 있다. 관망 구조 및 센서의 위치를 그래프로 구성하는 방법은 그림1과 같다. 한 파이프 상에 연속




(그림1) 관망-그래프 구성 방법

적으로 센서가 배치된 경우, 센서를 노드로 하고 그 사이를 엣지로 연결한다. 엣지의 가중치는 노드 사이의 거리 및 파이프 속성(관중, 직경 등)을 고려하여 적용한다. 이 가중치는 나중에 그래프 신경망에 입력될 때 각 노드의 특성(feature) 데이터와 결합된다. 만약 파이프가 교차하는 경우, 교차 지점을 가상 노드로 만들고 교차지점 주변에 가까운 센서를 노드로 하고 엣지로 연결한다. 각 센서 노드에는 측정된 신호 데이터를 담게 된다. 교차점의 가상 노드는 측정 데이터가 없으므로, 관망에 따른 전파 함수(propagation function)를 이용하여 주변의 센서 노드로부터의 데이터를 취합하여야 한다. 본 논문에서는, 문제를 일반화 및 단순화 하기 위하여, 거리에 반비례하는 단순한 전파 함수를 이용하였다. 가상 노드의 특성 데이터는 다음 수식(1)과 같이 각 노드의 특성값(X)과 엣지의 가중치(w)를 곱한 값의 가중치 평균으로 계산된다.

$$X_{virtual} = \frac{1}{\sum_{neighbors} w_i} \sum_{neighbors} w_i X_i \quad \dots \quad \text{수식(1)}$$


(그래프컨볼루션네트워크적용) 이미지 분류에 널리 사용되는 컨볼루션

네트워크는 인접된 점들의 값에 학습 가능한 가중치를 곱하여 새로운 값을 만들어 내고 이를 반복하여 분류 또는 회귀 문제를 해결한다. 마찬가지로 그래프 컨볼루션 네트워크는 엣지로 연결된 인접된 노드들의 값에 학습 가능한 가중치를 곱하는 과정을 통하여 분류 또는 회귀 문제를 해결한다. 그래프 컨볼루션의 입력은 각 노드의 특성값 X 와 인접행렬 A 를 취한다. 본 논문에서 그래프 컨볼루션의 출력으로는 각 센서로부터 신호 소스까지의 거리를 이용하였다. 그림2는 본 논문에서 사용한 그래프 컨볼루션 네트워크의 구조를 보인다. 컨볼루션 네트워크에서와 마찬가지로 그래프 컨볼루션 네트워크에서도 Gated Skip Connection 기법을 사용할 수 있다. 이는 그래프 컨볼루션 블록의 결과와 입력에 가중치를 주어 취합하는 방법이다[4].



(그림2) 그래프 컨볼루션 네트워크 구조

(신호소스위치예측) 그래프 컨볼루션 네트워크의 출력은 각 센서 노드로부터 신호 소스 위치까지의 거리이다. 정확한 신호 소스 위치를 예측하기 위해서는 각 센서 노드로부터의 거리가 중첩되는 부분을 찾아야 한다. 예측 모델에는 오차가 있기 때문에, 이를 고려하여 신호 소스 위치에 대한 확률을 누적하여 전체 관망에서 확률이 가장 높은 부분을 신호 소스 위치로 예측한다. 모델의 예측 결과 평가를 통해 오차의 평균값과 표준편차를 구한다. 이를 가우시안 분포 함수에 넣어 거리에 따른 확률밀도 함수를 구하였다. 그림3은 신호 소스 위치에 대한 확률 분포를 보인다. 여기서 확률이 가장 높은 지점의 위치를 신호 소스 위치로 판별한다.




(그림3) 신호 소스 위치에 대한 확률 분포

(관망신호소스위치시뮬레이션) 제안하는 그래프 신경망을 이용한 신호 소스 예측 모델을 평가하기 위하여, 시뮬레이션을 이용하였다. 시뮬레이션은 100mx100m 평면에서 4개의 직선관으로 구성된 관망을 임의로 생성한다. 파이프들은 서로 3지점 또는 4지점에서 서로 연결된다. 4 지점에서 연결된 경우, 루프를 형성하게 된다. 각 파이프 별로 3개의 센서가 임의의 위치에 배치된다. 그리고 관망상의 임의의 위치에 신호 소스가 위치한다. 신호 소스에서의 신호 출력 세기는 임의로 결정된다. 신호 소스로부터의 신호는 파이프를 이동하며 거리에 따라 감쇄한다. 분기점에서는 분기수에

맞게 감쇄한다. 각 센서들은 각 지점에서의 신호의 세기를 측정한다. 그림 4는 한 시뮬레이션 시나리오에서의 관망 구조 정보를 토대로 그래프를 구성한 예시를 보인다. 파란색 노드는 센서 노드를 나타내며, 회색 노드는 파이프 연결 지점의 가상 노드를 나타낸다.

이와 같은 시뮬레이션 환경에서 10만 개의 시나리오 데이터셋을 구축하였다. 8만 개는 학습용으로, 1만 개는 검증용으로, 1만 개는 평가용으로 구성하였다. 다음 표는 실험결과를 나타낸다. 표의 값은 예측한 신호 소스 위치와 실제 신호 소스 위치와의 거리를 나타낸다. 신호 소스 위치 후보 상위 1개(first)의 평균 예측 오차는 13m이며, 오차 상위 3개 이내(within-third)의 평균 예측 오차는 9m였다.



(그림4) 관망 구조 정보를 그래프로 구성한 예시

prediction	mean	std	min	max
first	13.9	11.2	0.0	73.0
second	14.3	11.4	0.0	75.0
third	14.4	11.7	0.0	77.0
within-third	9.7	9.3	0.0	66.0

표 1. 시뮬레이션을 통한 평가결과(신호 소스 위치 오차 거리)

III. 결론

본 논문에서는 그래프 신경망(그래프 컨볼루션 네트워크)을 이용한 관망에서의 신호 소스 위치 예측 방법을 제안하였다. 일반적인 기계학습과 달리 그래프 신경망은 기본적인 데이터 이외에 추가적인 형상(topology) 정보를 같이 입력할 수 있기 때문에, 관망에서의 신호 소스 위치 예측이 가능하다. 본 기술은, 관망 상의 누수 위치 탐지, 파손 위치 예측, 공사 지점 예측, 충격 지점 예측, 고장 위치 예측 등에 활용될 수 있을 것이다.

추가적으로, 다른 기계학습 모델과의 성능 비교 및 그래프 구성시 엣지의 가중치 설정 방법 개선, 그래프 컨볼루션 네트워크 내에서 인접행렬과 특성행렬의 단순곱이 아닌 다차원 함수 적용, 물리 모델과의 결합, 신호 소스 위치를 직접 예측하는 모델 개발 등의 연구를 통한 성능 개선이 필요하다.

ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. 20181210301570)

참 고 문 헌

- [1] Yazdekhaesti, S., Piratla, K.R., Matthews, J.C., Khan, A. and Atamturktur, S. (2018), "Optimal selection of acoustic leak detection techniques for water pipelines using multi-criteria decision analysis", Management of Environmental Quality, Vol. 29 No. 2, pp.

255-277. <https://doi.org/10.1108/MEQ-05-2017-0043>

- [2] Ling Ling Ting, Jing Yuen Tey, Andy Chit Tan, Yeong Jin King, Faizd Abd Rahman, "Water leak location based on improved dual-tree complex wavelet transform with soft thresholding de-noising", *Applied Acoustics*, Volume 174, 021, 107751, ISSN 0003-682X, <https://doi.org/10.1016/j.apacoust.2020.107751>.
- [3] Zhang, S., Tong, H., Xu, J. et al. "Graph convolutional networks: a comprehensive review". *Comput Soc Netw* 6, 11 (2019). <https://doi.org/10.1186/s40649-019-0069-y>
- [4] Seongok Ryu, et al., "Deeply learning molecular structure-property relationships using attention- and gate-augmented graph convolutional network", *arXiv:1805.10988*, (2018).