

시계열 내부 구조 기반 그래프 생성을 통한 행동 분류 모델

최혁순¹, 양진환¹, 김시웅¹, 김성식¹, 문남미²

¹호서대학교 컴퓨터학과 석사과정

¹호서대학교 컴퓨터공학부 학부생

²호서대학교 컴퓨터공학과 교수

hyuksoon2001@naver.com, yjh970706@naver.com, kimsiung990811@gmail.com,
sungsik001004@gmail.com, nammee.moon@gmail.com

Behavior Classification Model Based on Graph Generation Using Time Series Structural Feature

Hyuksoon Choi¹, Jinhwan Yang¹, Siung Kim¹,

Sungsik Kim¹, Nammee Moon¹

¹Dept. of Computer Engineering, Hoseo University

요약

본 연구에서는 웨어러블 디바이스로부터 수집된 다변량 반려동물 행동 데이터를 처리하기 위해, GCN(Graph Convolutional Network)과 GRU(Gated Recurrent Unit)를 결합한 모델을 제안한다. 제안된 모델은 시계열 내부 구조를 활용하여 그래프 구조로 변환하고, DTW(Dynamic Time Warping) 유사도 분석을 통해 노드 간의 시간적 유사도를 기반으로 엣지를 생성한다. 실험결과로 DTW 기반 엣지 생성 방식이 유클리드 거리 및 선형 방식에 비해 더 높은 성능을 나타냈다. 본 연구는 반려동물의 행동을 정확히 분류하기 위한 효과적인 방법론을 제공한다.

1. 서론

최근 몇 년 동안, 센서 기술의 발전과 IoT(사물인터넷) 기기의 보급이 급속도로 증가하면서 생성되는 데이터의 양도 기하급수적으로 늘어나고 있다[1]. 이러한 대규모 센서 데이터를 효과적으로 처리하고 분석하는 것은 매우 중요해졌다. 전통적인 데이터 처리 방법들이 센서 데이터의 복잡성과 대규모 특성을 충분히 다루지 못하는 문제를 해결하기 위해 그래프 신경망(GNN, Graph Neural Networks) 계열의 데이터 처리 방법이 주목받고 있다[2].

반려동물의 행동 패턴은 다양한 센서를 통해 수집된 시계열 데이터에 복잡한 공간적 및 시간적 관계를 반영한다. 이러한 관계를 효과적으로 모델링하기 위해, 시계열 데이터의 내부 구조를 그래프로 변환하고, 이를 GCN으로 처리하여 공간적 특성을 학습한다. 또한, 시계열 데이터의 내부 구조를 활용하여 그래프화 시킨 방법론을 활용하여 GRU를 사용한다. 시계열 데이터의 시간적 특성을 분석함으로써, 반려동물의 다양한 행동을 정확히 분류할 수 있다.

따라서 본 연구에서는 다변량 반려동물 행동 데이터를 처리하기 위해 GCN과 GRU를 결합한 모델을 제안한다.

2. 관련 연구

2.1 GNN

GNN은 그래프 구조 데이터를 처리하기 위해 설계된 신경망의 한 유형으로, 노드와 에지 간의 관계를 모델링하는 데 특화되어 있다. GNN의 핵심 아이디어는 노드들이 그들의 이웃으로부터 정보를 수집하고, 이를 통합하여 각 노드의 새로운 표현을 생성하는 과정을 반복함으로써, 그래프 전체의 복잡한 패턴을 학습하는 것이다[3]. 이는 노드 분류, 링크 예측, 그래프 분류 등 다양한 작업에 활용되어 여러 분야에서 빠르게 발전해 왔다.

2.2 GRU

GRU는 RNN(Recurrent Neural Networks)의 한 변형으로, 시계열 데이터나 순차 데이터의 학습을 목적으로 설계되었다[4]. GRU는 LSTM(Long Short-Term Memory)의 단순화된 버전으로 업데이트와 리셋 게이트라는 두 가지 게이트를 사용하여 정보의 흐름을 조절한다. 이러한 구조 덕분에 GRU는 장기 의존성 문제를 효과적으로 해결하면서도 계산 비용을 줄일 수 있는 장점을 가진다. GRU는 언어 모델링, 시계열 예측 등 여러 분야에서 활용되고 있다.

3. 모델 아키텍처

3.1 데이터셋

데이터셋은 IMU 센서를 사용하여 50Hz 주기로 수집되었으며 가속도, 자이로, 지자기 총 9축(센서별 X, Y, Z) 센서 데이터로 이루어져 있다[5]. 가속도 센서는 반력건의 빠르기과 방향 변화를 측정하여, 걷기, 뛰기 또는 점프와 같은 활동을 식별하는 데 사용된다. 자이로스코프는 회전과 관련된 움직임을 감지하여, 반력건이 어떤 방향으로 몸을 돌리는지 파악할 수 있게 한다. 지자기 센서는 지구의 자기장을 활용하여 반력건의 방향성을 정밀하게 추적할 수 있다. 데이터셋의 개수는 총 5가지(서다, 걷다, 앉다, 엎드리다, 먹다)의 행동 분류로 구성되었고, 총 데이터셋은 11,723으로 구성되어 있다. 각 행동별 데이터셋은 <표 1>과 같다.

<표 1> 데이터셋

행동	개수
서다	2,277
걷다	612
앉다	6,447
엎드리다	1,902
먹다	485
총합	11,723

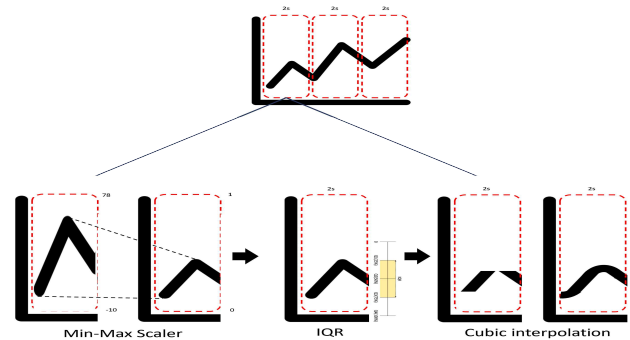
3.2 전처리

센서 데이터의 정확성과 신뢰성은 데이터 분석의 질을 결정하는 중요한 요소 중 하나이다. 그러나, 센서 데이터는 수집 과정에서 다양한 외부 요인, 예를 들어 전자기파나 자기장의 영향으로 인해 결측치나 이상치가 발생할 수 있다. 이러한 데이터의 오류는 분석 결과의 오류로 이어질 수 있으므로, 데이터를 모델에 입력하기 전에 적절한 전처리 과정을 거치는 것이 필수적이다. 본 연구에서는 이상치와 결측치를 처리하기 위해 다양한 전처리 과정을 거친다.

Min-Max 스케일러를 사용하여 데이터를 0과 1 사이의 값으로 정규화한다. 이 방법은 각 특성의 최솟값을 0, 최댓값을 1로 설정하고, 나머지 값을 이들 사이에 비례하게 조정한다. 이러한 정규화 과정은 모델이 다양한 범위의 데이터를 더 잘 이해하고 처리할 수 있게 돕는다. 이상치를 처리하기 위해 IQR(Interquartile Range) 이상치 처리 기법을 사용하여 이상치를 처리한다. IQR 방법은 데이터의 25%에 해당하는 하위 분위수(Q1)와 75%에 해당하는 상위 분위수(Q3)를 계산하고, 두 분위수의 차이를 이용하여 이상치를 판별한다. 구체적으로, 데이터 포인트가 $Q1 - 1.5 * IQR$ 보다 낮거나 $Q3 + 1.5 * IQR$ 보다 높은 경우, 해당 포인트를 이상치로 간주하고,

이를 결측값으로 처리한다. 식(1)과 이상치 제거를 진행한다. 결측치를 처리하기 위해 큐빅 스플라인 보간법을 사용한다. 큐빅 스플라인 보간법은 결측치를 포함하는 데이터 포인트의 앞뒤 데이터 포인트를 사용하여 결측치를 예측하는 방법으로, 곡선을 사용하여 데이터 포인트 사이를 부드럽게 연결한다. 시계열 데이터의 결측치를 보간하는 데 특히 유용하며, 데이터의 전반적인 패턴을 유지하면서 결측치를 효과적으로 채울 수 있다. 행동을 2초로 정의하기 위해 비중첩 슬라이딩 윈도우를 사용한다. 전처리 과정을 통해 데이터의 질을 개선하고 분석 과정에서 데이터 처리와 모델의 성능 향상에 기여했다. 전처리 과정은 (그림 1)과 같다.


$$(Q1 - 1.5 * IQR) > x(data) > (Q3 + 1.5 * IQR) \quad (1)$$



(그림 1) 전처리 아키텍처

3.2 시계열 내부 구조 그래프 생성

시계열 데이터를 효과적으로 분석하고 예측하기 위해서는 데이터의 구조적 및 시간적 패턴을 정확히 파악하는 것이 중요하다. 특히 GNN 계열의 모델은 데이터 간의 관계를 그래프 형태로 모델링하여 복잡한 패턴을 학습하는 데 탁월한 능력을 보인다. 그러나 시계열 데이터는 기본적으로 그래프 구조를 가지고 있지 않기 때문에, 이를 GNN 모델에 적용하기 위해서는 시계열 데이터를 그래프로 변환하는 과정이 필요하다. 본 연구에서는 시계열 데이터를 그래프로 변환하기 위해 기존에 사용하던 가시성 그래프(Visibility Graph)와 센서 임베딩 기법을 사용하는 방법이 아닌 시계열 내부 구조 기반 그래프 생성 방식을 제안한다[6,7]. 기존의 방법은 두 번의 학습을 거쳐야 하기 때문에 학습 리소스가 많거나 시계열 데이터의 형태를 변경하여 그래프화 시켜 시계열 특성을 잃게 된다.



(그림 2) GCN-GRU 행동 분류 모델

시계열 내부 구조 기반 그래프 생성 방식은 시계열 데이터를 그래프로 변환하기 위해 가시성 그래프나 센서 임베딩 기법을 사용하지 않고, 시계열 내부 구조 기반의 새로운 그래프 생성 방식이다. 기존의 방법처럼 2차 학습을 거치지 않아 학습 리소스를 절약하며, 데이터의 형태를 변경하지 않아 시계열의 특성을 유지할 수 있다. 각 행동의 시퀀스를 모두 노드 취급을 한다. 본 연구에서는 50Hz로 수집된 데이터에서 2초로 행동 정의를 진행하였기에 100개의 시퀀스는 100개의 노드로 취급을 진행한다. 이러한 과정을 9축 센서에 대해 모두 진행한다.

노드화된 시퀀스 간의 유사도를 평가하기 위해 DTW를 적용한다[8]. 구체적으로 가속도, 지자계, 자이로스코프 센서로부터 수집된 9축 데이터는 각각의 센서 유형 별로 유사한 시간적 패턴을 보이는 경향이 있다. 이러한 패턴의 유사성 때문에, 각 센서 데이터 시퀀스를 개별적인 노드로 취급하고, 이 노드들 사이에서 DTW 통해 유사도를 측정하여 그래프의 엣지를 생성한다. 이 접근 방식은 시계열 데이터의 시간적 변동성을 고려하여 보다 정밀한 그래프 구조를 만들어내는 데 기여한다.

3.3 GCN-GRU 행동 분류 모델

본 연구에서는 시계열 데이터의 복잡한 시간적 및 구조적 패턴을 효과적으로 모델링하기 위해 GCN-GRU 아키텍처를 제안한다. 이 아키텍처는 먼저, 센서 데이터로부터 시계열 내부 구조 그래프를 생성하는 과정을 포함한다. 이 과정에서 수집된 시계열 데이터는 노드화 과정을 거쳐 각 시퀀스가 독립적인 노드로 변환된다. 이후, DTW를 적용하여 노드 간의 시간적 유사도를 계산하고, 높은 유사도를 가진 노드 쌍에는 엣지를 형성하여 그래프를 완성한다. 그래프 데이터를 처리하기 위해, GNN 계열의 모델 GCN이 도입된다. GCN 층은 노드의 특성과 그 이웃의 정보를 통합하여 고차원적인 특성을 추출하는 역할을 수행한다. GRU 층은 GCN과 병렬구조

로 구성되어 노드를 학습을 진행한다. GRU는 시퀀스 내 정보의 흐름을 조절함으로써 중요한 정보를 유지하고 불필요한 정보를 필터링한다. 마지막으로, GRU 층의 출력은 분류기로 전달되어 최종적인 분류 또는 예측 작업을 수행한다. 최종적인 아키텍처는 (그림 2)와 같다.

4. 실험

실험 절차는 DTW 기반 엣지 생성 방식의 효율성을 검증하기 위해 다른 엣지 생성 방식과의 비교 실험을 진행한다. 비교 대상은 유클리드 거리를 기반으로 한 엣지 생성, 선형 엣지 생성 그리고 DTW를 이용한 엣지 생성 방식이다. 본 연구는 가장 효과적인 그래프 구성 방식을 식별하고자 한다. 모든 방식은 동등한 기준에서 평가되기 위해 동일한 실험 환경과 하이퍼파라미터를 공유한다. 실험에 사용된 하이퍼파라미터 설정은 <표 2>와 같다

<표 2> 실험 환경

Hyper parameter	Value
Epoch	150
Batch	16
Loss Function	Cross Entropy
Learning Rate	1e-4

실험을 통해 각 엣지 생성 메커니즘이 GCN-GRU 모델의 성능에 미치는 영향을 정량적으로 평가하고자 하였다. 이를 통해 시계열 데이터에 대한 내부 구조 기반 그래프의 최적화된 구조를 탐색하는 것이 본 실험의 주된 목적이다.


5. 실험 결과

본 실험에서 세 가지 엷지 생성 방식에 따른 모델의 성능을 비교한 결과는 다음과 같다. DTW 기반 엷지 생성 방식은 정밀도가 0.7831, 재현율이 0.7998, F1-점수가 0.7894, 그리고 정확도가 0.8048로 제일 높은 성능을 보였다. 전체 실험 결과는 <표 3>과 같다.

<표 3> 실험 결과

엷지 생성	정밀도	재현율	F1-점수	정확도
DTW	0.7831	0.7998	0.7894	0.8048
유클리드	0.7902	0.8054	0.7936	0.7934
선형	0.6162	0.6809	0.5882	0.5701

또한, DTW 기반 엷지 생성 방식의 학습 진행 과정과 성능 평가 결과는 혼동 행렬(Confusion Matrix) 및 학습 과정에서의 손실과 정확도의 변화 추이를 통해 시각적으로 확인할 수 있다. 시각화는 (그림 3)과 같다.



(그림 3) 실험 결과 시각화

실험 결과로부터, DTW 기반 엷지 생성 방식과 유클리드 거리 기반 방식이 비슷한 수준의 높은 성능을 나타냈지만, DTW 기반 엷지 생성 방식이 더 높은 정확도를 보임으로써 시계열 데이터에 대한 내부 구조적 관계를 반영하는데 우위에 있는 것으로 관찰된다. 선형 방식은 이들 두 방식에 비해 상당히 떨어지는 성능을 보임으로써, 본 연구의 방식에서는 선형 방식이 시계열 데이터의 복잡성을 효과적으로 캡처하지 못하는 것으로 해석될 수 있다. 연구 결과는 DTW 기반 엷지 생성 방식 및 유클리드 거리 기반 방식이 시계열 데이터의 그래프 표현에 더 적합하다는 점을 나타내며, 또한 복잡한 시계열 데이터를 분석할 때 선형 방식보다는 비선형적 접근이 더 유리할 수 있음을 알 수 있다.

6. 결론

본 연구는 IoT 발전에 따라 증가하는 복잡한 센서 데이터를 효과적으로 분석하기 위해, GCN과 GRU를 결합한 새로운 모델을 제안한다. 제안된 GCN-GRU 행동 분류 모델은 반려동물 행동 분류뿐만 아니라, 다양한 시계열 분석 분야에 있어 중요한 기여를 할 것으로 기대된다.

ACKNOWLEDGEMENT

본 연구는 과학기술정보통신부와 정보통신기획평가원의 SW중심대학사업의 연구결과로 수행되었음 (2019-0-01834)

참고문헌

[1] Liu, M., Li, D., Chen, Q., Zhou, J., Meng, K., & Zhang, S. (2018). Sensor q q information retrieval from Internet of Things: Representation and indexing. *IEEE Access*, 6, 36509–36521

[2] Romanova, A. (2023, November). Enhancing Time Series Analysis with GNN Graph Classification Models. In *International Conference on Complex Networks and Their Applications* (pp. 25–36). Cham: Springer Nature Switzerland.

[3] Scarselli, F., Gori, M., Tsoi, A. C., Hagenbuchner, M., & Monfardini, G. (2008). The graph neural network model. *IEEE transactions on neural networks*, 20(1), 61–80

[4] Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.

[5] Kim, H., & Moon, N. (2023). TN-GAN-Based Pet Behavior Prediction through Multiple-Dimension Time-Series Augmentation. *Sensors*, 23(8), 4157.

[6] Cheng, L., Zhu, P., Sun, W., Han, Z., Tang, K., & Cui, X. (2023). Time series classification by Euclidean distance-based visibility graph. *Physica A: Statistical Mechanics and its Applications*, 625, 129010

[7] Deng, Ailin, and Bryan Hooi. "Graph neural network-based anomaly detection in multivariate time series." *Proceedings of the AAAI conference on artificial intelligence*. Vol. 35. No. 5. 2021

[8] Bellman, R. (1958). *Dynamic programming*. Princeton University Press, Princeton, NJ, USA, 1, 3–25