

VNF 최적 배치를 위한 기계학습 모델 연구

박수현, 김희곤, 홍지범, 유재형, 홍원기
포항공과대학교 컴퓨터공학과

{sh.park11, sinjint, hosewq, jhyoo78, jwkong}@postech.ac.kr

A Study on Machine Learning Models for Optimal VNF Deployment

Suhyun Park, Hee-Gon Kim, Jibum Hong, Jae-Hyoung Yoo, James Won-Ki Hong
Computer Science and Engineering, Pohang University of Science and Technology

요약

본 논문은 동적으로 변화하는 네트워크를 효율적으로 관리하기 위한 네트워크 기능 가상화 (NFV: Network Function Virtualization) 환경에서, 가상 네트워크 기능 (VNF: Virtualized Network Function)의 배치를 최적화하는 기계 학습 모델을 제안한다. 서비스 비용과 품질 등의 조건을 고려하여 최적의 VNF 배치를 수행하는 것은 매우 복잡하고 어려운 문제이며, 결정된 배치를 실제 NFV 환경에 적용하는 데는 처리 시간이 소요되기 때문에 미래 시점의 상황을 예측하여 VNF 배치에 필요한 자원량을 결정하는 것이 필요하다. 본 논문에서는 시뮬레이션 데이터를 생성하고, ILP (Integer Linear Programming) 모델을 통해 각 상황에서의 VNF 최적 배치 정보를 얻은 후, 이를 기계학습 모델의 훈련데이터로 사용한다. 입력데이터의 네트워크 토플로지 정보를 학습하기 위한 GNN (Graph Neural Network) 구조와 시간대별 데이터의 문맥 (context) 정보 이용하기 위한 RNN (Recurrent Neural Network) 구조를 결합하여 모델을 만들고 훈련시킨다. MEC (Multi-access Edge Computing) 토플로지에서의 시뮬레이션 데이터로 5 분 이후의 미래 시점에 대해 예측 결과, ILP 솔루션 결과 대비 90% 이상의 정확도를 보였다.

I. 서론

전통적인 네트워크 환경에서는 하드웨어 기반의 미들 박스를 네트워크 상 적절한 위치에 설치하여 고정적으로 사용하였다. 한편, 네트워크 기능 가상화 (NFV: Network Function Virtualization) 기술은 전통적인 하드웨어 기반 미들 박스의 기능을 소프트웨어로 구현하여 가상 서버에 설치하고 필요에 따라 유동적으로 배치함으로써 동적인 서비스 요청에 대해 유연한 대응이 가능하다 [1]. 하지만 가상 네트워크 기능 (VNF: Virtualized Network Function)을 배치하고 SFC (Service Function Chaining)를 구성하는 작업을 네트워크 관리자가 수작업으로 수행하는 것은 매우 복잡하고 번거로운 일이다.

VNF 배치 결정 문제는 목적에 따라 다양하게 정의할 수 있다. 여러 관련 연구들은 운용 비용과 QoS (Quality of Service)를 최적화하는 것을 목적으로 하였다. 한편, VNF 배치 결정 문제는 스케일링 문제와 네트워크 토플로지 상의 위치 결정 문제로 나누어 생각할 수 있다. 스케일링은 배치할 각 타입의 VNF 인스턴스 개수에 대한 것이고, 위치 결정은 각 VNF 인스턴스의 정확한 설치 위치를 결정하는 것이다. 네트워크 토플로지 상의 위치 결정 문제가 포함되는 경우, SFC 라우팅 경로 최적화를 동시에 고려해야 한다. 각 서비스 요청에 대한 SFC 라우팅 경로가 고려되어야 VNF 배치 결과가 최적인지를 평가할 수 있는 한편, VNF 배치가 결정되어야 각 서비스 요청에 대한 SFC 라우팅 경로를 결정할 수 있다.

본 연구에서는 MEC (Multi-access Edge Computing) 환경에서 최적의 VNF 배치를 결정하는 기계학습 모델을 제안한다. 기계학습 모델은 네트워크 토플로지의 구조, 각 서버의 CPU 할당, 각 링크의 대역폭 할당과 같은 고정 정보와 각 시점의 서비스 요청에 따라 주어지는 각 서버의 CPU 사용량, 각 링크의 대역폭 사용량과 같은 변동 정보를 입력으로

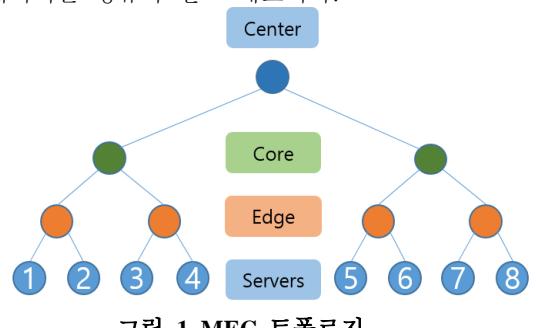
받아, 각 시점의 최적 배치를 결정한다. 모델의 훈련을 위해 사용되는 데이터는 무작위로 생성한 서비스 요청 정보를 ILP (Integer Linear Programming) 솔루션 [2]이 입력으로 받아 생성하는 시뮬레이션 데이터이다.

II. 본론

본 연구에서 제안하는 방법은 무작위로 생성한 서비스 요청에 대한 ILP 솔루션을 구해 데이터를 생성하는 단계, GNN (Graph Neural Network)의 입력 데이터 형태로 데이터를 전처리 하는 단계, GNN 과 RNN (Recurrent Neural Network)을 이용하여 예측 모델을 훈련시키는 단계로 구성된다.

2.1. 데이터 생성

본 연구에서는 선행 연구 [3]에서 고안한 방법을 사용해 데이터를 생성한다. 먼저, 무작위로 서비스 요청 데이터를 생성하기에 앞서, 그림 1 과 같은 MEC 토플로지를 네트워크 토플로지로 정하고, 그림 2 와 같은 1 주일 간의 트래픽 사용 패턴을 가정한다. 그림 1 에서 1 부터 8 까지 숫자가 적힌 노드만이 서비스 요청의 출발지나 목적지, 또는 VNF 가 설치되는 서버이고, 나머지 노드들은 스위치 노드이다. 그림 2 의 트래픽 패턴은 관련된 연구들에서 사용된 일주일간의 트래픽 패턴 데이터를 정규화 한 그래프이다.



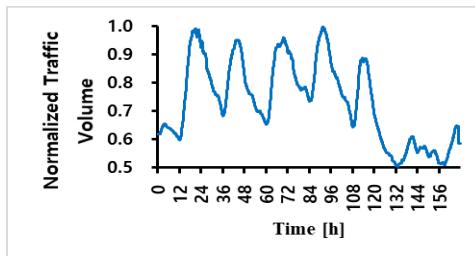


그림 2. 일주일 트래픽 사용 패턴 데이터

생성되는 서비스 요청 정보는 요청의 발생 시각과 요청의 지속시간, 출발지 노드와 목적지 노드, 사용 대역폭, 최대 지연 등의 정보와 순서대로 거쳐야 하는 VNF 탑재의 정보를 포함한다.

ILP 솔루션 [2]을 통해 각 서비스 요청이 들어온 시점의 VNF 배치와 SFC 구성정보를 통해 각 서버의 자원 사용 및 링크의 트래픽 사용 데이터를 계산할 수 있다. 또한 생성된 데이터셋에서 각 시점 기준 5 분 이후 미래 시점의 VNF 배치 결과를 최적 배치 모델의 훈련을 위한 레이블 데이터로 사용한다.

2.2. GNN 인코딩을 위한 데이터 전처리

본 연구에서는 GNN 알고리즘의 한 종류인 ECC (Edge-Conditioned Convolution) [14] 알고리즘을 사용하여 네트워크 데이터를 그래프 표현 형태로 변환한다. 정의하는 입력 데이터는 그림 3 과 같다. (N : 노드의 수, F : 노드 피처의 차원 수, S : 엣지 피처의 차원 수, V : VNF 종류 수)

- 노드 피처: 할당된 CPU와 CPU 사용과 관련된 정보 ($N \times F$ 행렬)
- 토폴로지: 네트워크 토폴로지 ($N \times N$ 행렬)
- 엣지 피처: 할당된 대역폭과 지연, 트래픽 사용과 관련된 정보 ($N \times N \times S$ 행렬)

$N \times V$ 행렬로 표현되는 예측 시점의 VNF 최적 배치를 레이블 데이터로 사용한다.

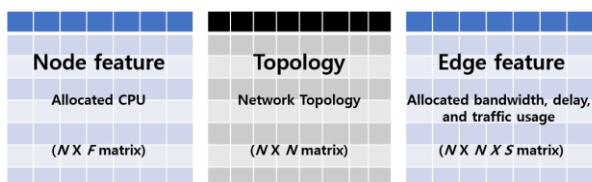


그림 3. GNN 인코딩을 위한 입력 데이터 형식

2.3. GNN 과 RNN 을 결합하는 모델 구조

입력데이터는 네트워크 토폴로지 그래프의 각 노드와 엣지에 맵핑되는 형태로 나타내어지며, 이러한 그래프 구조 정보를 훈련 데이터에 포함시키기 위해 GNN을 사용해 인코딩한다. 본 연구에서 사용하는 ECC 알고리즘은 각 엣지 피처 상의 필터링 가중치를 지정하고, 각 노드를 인접 노드의 가중치 합으로 계산한다. 이러한 통합적인 접근은 노드 별 데이터 항목을 독립적으로 나열하여 입력 데이터로 사용할 때 노드의 순서가 한 가지로 정해지지 않는 문제를 해결할 뿐만 아니라, 그래프의 구조 정보를 누락하지 않는다 [4].

한편, 서비스 요청이 발생하는 매 시점에 대해 그림 3 과 같은 데이터 셋이 존재하며, 전처리된 전체

데이터는 시계열 데이터로 구성된다. 시계열 데이터에 대한 예측 모델은 일반적으로 RNN 기반의 알고리즘을 사용하여 문맥 (context) 정보를 학습한다. 본 연구에서는 LSTM (Long Short-Term Memory) [5]을 사용하여 GNN 인코딩을 거친 시간대별 입력데이터로 모델을 훈련시킴으로써 시간 간격이 긴 입력 데이터와 출력 데이터 간의 연관관계를 학습하도록 한다.

각 시점에 대한 그림 3 과 같은 형식의 데이터를 ECC로 인코딩하여 LSTM의 입력데이터로 사용하도록 모델을 구성하고, 입력 데이터 기준 5 분 이후 시점의 VNF 최적 배치를 예측하도록 모델을 훈련시킨 결과, ILP 솔루션 대비 전반적인 정확도는 93%를 달성하였다. 이는 선행 연구에서 LSTM을 사용하지 않고, 모니터링 시간 구간에서의 통계치를 이용하여 일반적인 FNN (Feedforward Neural Network)을 사용했을 때의 평균 정확도 (84%) 대비 10% 가량 향상된 결과이다.

III. 결론

본 연구에서는 네트워크 환경 정보와 실시간으로 변화하는 서비스 요청 정보를 바탕으로, 처리 시간을 고려하여 미래 시점의 VNF 최적 배치를 예측하였다. 이를 위해 ILP 솔루션을 통해 구한 VNF 배치 결과를 정답으로 사용하여, GNN 인코딩 방법과 RNN을 사용하여 기계학습 모델을 훈련시켰다.

실험의 결과로 5 분 이후 시점의 ILP 솔루션 대비 전반적인 정확도 90% 이상의 모델을 도출하였다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터지원사업의 연구결과로 수행되었음 (IITP-2020-2017-0-01633)

참고문헌

- [1] B. Li, W. Lu, S. Liu, and Z. Zhu, "Deep-learning assisted network orchestration for on-demand and cost-effective VNF service chaining in inter-DC elastic optical networks," IEEE/OSA Journal of Optical Communications and Networking, vol. 10, no. 10, pp. D29–D41, Oct. 2018.
- [2] M. F. Bari, S. R. Chowdhury, R. Ahmed, and R. Boutaba, "On Orchestrating Virtual Network Functions," in 11th International Conference on Network and Service Management, pp. 50–56, Nov. 2015.
- [3] S. Lange, H. G. Kim, S. Y. Jeong, H. Choi, J. H. Yoo, J. W. K. Hong, "Predicting VNF Deployment Decisions under Dynamically Changing Network Conditions," in 2019 15th International Conference on Network and Service Management, pp.1-9, Oct.2019.
- [4] M. Simonovsky and N. Komodakis, "Dynamic edge-conditioned filters in convolutional neural networks on graphs," In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 3693– 3702, Aug. 2017.
- [5] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," In Neural Computation 9(8), pp.1735-1780, 1997