

기계 학습 기반 VNF 관리 시스템 제안

김희곤, 이도영, Stanislav Lange, 유재형, 홍원기
포항공과대학교 컴퓨터공학과,

{sinjint, dylee90, stasl, jihyoo78, jwkhong}@postech.ac.kr

The VNF Management System using Machine Learning

Hee Gon Kim, Do Yeong Lee, Stanislav Lange, Jae Hyung Yoo, James Won Ki Hong

Department of Computer Science and Engineering, POSTECH

*Graduate school of Information Technology, POSTECH

요 약

본 논문은 기계 학습 기반의 VNF 관리 시스템을 제안하였다. 가상 네트워크 환경에서 기존의 관리 시스템은 네트워크의 동적인 변화에 빠르게 대응을 할 수 없으며 최적의 관리가 불가능하였는데, 이러한 문제점을 기계 학습 기반의 VNF 관리 시스템이 해결 할 수 있음을 서술하였다. 또한 단순히 추상적인 시스템 구조만을 표현한 것이 아니라 기존 연구들의 한계점을 지적하면서 구체적으로 어떠한 기계 학습 모델이 VNF 를 관리하는 데 적합한 지 설명하였다. 본 논문에서는 Graph Neural Network (GNN)를 사용하여 네트워크를 학습하는 것을 제안하였으며, 학습에 필요한 데이터 및 전체 VNF 관리 시스템 구조를 서술하였다.

I. 서 론

Software-Defined Networking (SDN) 과 Network Function Virtualization (NFV) 는 OPEX 와 CAPEX 를 감소시키며 네트워크를 동적이고 유연하게 만들어 준다. 기존의 네트워크는 실제 물리 네트워크 장치들이 연결된 구조를 가지고 있었으나 SDN 과 NFV 환경에서는 범용 서버들이 네트워크를 구성하고 있으며, 각 서버 위에 설치된 가상 네트워크 기능(Virtual Network Function: VNF) 들이 물리 네트워크 장치 기능들을 대신 수행한다. 이러한 네트워크 구조의 변화는 기존의 네트워크보다 빠르게 환경을 변화시킬 수 있는 장점을 가지는데, 한편으로는 네트워크의 복잡도와 동적 변화를 증가시켜 관리의 난이도를 증가시키기도 한다.

전통적으로 네트워크 관리 방법은 Integer Linear Programming (ILP) 을 기반으로 네트워크 환경을 수학적으로 계산하여 최적의 환경을 구성하였다. 하지만 SDN 과 NFV 도입으로 네트워크 환경들은 점점 더 복잡해졌고, ILP 계산의 소요시간이 길어지게 되었다. 또한 네트워크의 동적 변화가 자주 일어남에 따라 ILP 로 구한 관리 정책이 더 이상 변화된 네트워크에서 최적의 정책임을 보장할 수가 없게 되었다. 이러한 문제를 해결하기 위해 최근에는 빠른 계산 시간을 보장하는 기계학습 기반 네트워크 관리 연구가 주목을 받고 있다.

구축이다. 현재 이와 관련한 연구로 [1]은 기계 학습을 사용하여 Virtual Network Embedding 문제를 해결하고자 하였으며 [2]는 VNF Deployment 문제를 여러 기계학습 모델을 사용하여 해결하였다. 하지만 이러한 연구들이 실제 네트워크에 적용할 수 있다고 질문한다면 그렇다고 대답하기는 어렵다. [1]와 [2]와 같이 많은 연구들[3][4]은 기계 학습을 네트워크 환경에 적용하고자 노력을 하고 있기는 하지만 그들이 제안한 방법을 살펴보면 오직 한정된 환경(네트워크의 구조 변화가 없음)과 정해진 조건(요구되는 네트워크 서비스의 종류 및 양의 변화가 없음) 그리고 간단한 네트워크 정책(특정 VNF 의 개수 관리 등)에 대해서만 행해진 것을 확인 할 수 있다.

본 논문은 VNF Migration 과 VNF deployment 모두를 고려하는 넓은 의미의 뜻에서 VNF 관리를 실시하며, 네트워크 구조가 고정되지 않고 동적으로 변화하는 환경에서 변화하는 네트워크 서비스 요구에 따라 최적의 관리 방법을 기계 학습이 계산하는 시스템을 제안한다. 또한 이러한 시스템 구현을 위해 우리는 기계 학습의 일종인 Graph Neural Network (GNN)[5]을 사용하는 것을 제안한다.

기계학습 기반의 네트워크 관리의 목표는 사람의 개입 없이 스스로 관리를 하는 자율 네트워크 시스템의




그림 1 물리 네트워크와 가상 네트워크 개념도

II. 본론

그림 1 은 물리네트워크와 가상네트워크의 개념을 간단히 나타낸 것이다. VNF 는 네트워크의 물리 서버 위에서 동작하며 사용자가 특정한 네트워크 서비스를 요구하면 그 서비스를 충족할 수 있는 VNF 들이 순차적으로 동작한다. 서비스를 제공하기 위해 동작하는 VNF 의 열들은 Service Function Chain (SFC) 라고 불리며 그림에서는 초록색으로 표현되었다. 네트워크 관리는 네트워크 서비스가 요구될 때 SFC 를 고려하여 VNF 최적의 위치로 Deploy 혹은 Migration 하는 것이며, 이때 네트워크 자원 사용을 최적화하면서 지연이나 실패 없이 서비스를 제공하는 것이다. 예시로 그림 1 을 살펴보면, 현재 서비스는 B->D->E->F->G->H 의 VNF 체인을 가지는 SFC 를 통하여 제공되고 있는데, VNF E 와 VNF F 가 위치한 물리 서버들 간에는 직접적인 연결이 존재하지 않기 때문에 VNF E 에서 VNF F 로 가기 위해서는 다른 서버를 거쳐야만 연결이 되는 것을 확인 할 수 있다. 이러한 경우에는 VNF E 를 VNF F 가 위치한 물리 서버로 Migration 하거나 Deploy 하는 방법으로 문제를 해결할 수 있다[6]. 또한 이러한 Migration 과 Deploy 정책 결정사항 시 대상이 되는 물리 서버와 전체 네트워크의 가용 자원이 해당 정책을 실시하기에 충분하며, 결정된 정책이 전체 네트워크 자원을 최적으로 사용하는 지 파악하여야 한다. 즉 네트워크 관리는 사용자의 서비스 요구 사항 정보와 네트워크의 구조 및 자원 상태 정보를 필요로 한다.

네트워크 관리에 있어 필요한 정보를 구체적으로 나타내면 다음과 같이 정의를 할 수 있다.

- 서비스 정보
 - 요구되고 있는 서비스의 종류
 - 요구되고 있는 서비스의 양
 - 요구되고 있는 서비스의 SLA
 - 서비스를 요구하는 노드 및 제공하는 노드의 위치
- 네트워크 정보
 - 물리 네트워크 토폴로지 연결 형태
 - 물리 서버 간의 Latency 및 Bandwidth
 - 물리 서버의 가용 자원
 - 물리 서버의 VNF 종류
 - VNF 의 가용 자원

본 논문에서는 위에서 정의된 서비스 정보와 네트워크 정보를 사용하여 VNF 관리하는 네트워크 관리 시스템을 제안한다. 전통적인 네트워크 관리 시스템에서는 ILP 를 사용하여 문제를 해결하였지만, 복잡한 네트워크에서 위의 정의된 모든 정보를 사용하여 빠르게 관리 방법을

찾는 것은 거의 불가능에 가까우며, 정답을 찾은 경우에는 이미 서비스 정보와 네트워크 정보가 변화한 상태에 직면하게 된다. 이러한 문제를 해결하기 위해 본 논문은 기계 학습을 사용하는 것으로 관리 정책을 결정하는 시스템을 제안하였다.

기계 학습을 사용하여 네트워크를 관리하려는 시도는 새로운 것은 아니다. 하지만 기존의 시도들은 특정한 네트워크 환경에서만 관리 모델이 작동한다는 고질적인 문제점을 벗어나지 못했다. 기계 학습은 데이터를 사용하여 학습하고 학습 결과를 바탕으로 주어진 문제를 푸는 모델이다. 결국 기계 학습은 주어진 데이터에 종속적이게 되는 데, 기계 학습 기반 네트워크 관리 모델은 학습에 사용된 네트워크 환경에 종속되게 된다. 따라서 많은 기계 학습 기반 네트워크 연구들은 오직 한정된 환경과 목적에서만 정상적으로 작동을 하게 된다. 특히 치명적인 것은 네트워크는 주로 동적으로 계속 변화하기 때문에, 현재 모델이 정상적으로 작동하고 있다 할지라도 언제 모델이 정상적으로 작동하지 않을 지 모른다는 것이다.

기계 학습 모델이 한정된 데이터에 종속적이라면 여러 다양한 환경의 네트워크 데이터를 학습하는 것으로 모델이 범용성을 갖추게 할 수도 있다. 하지만 기존의 기계 학습 기반 네트워크 관리 모델은 다양한 환경의 네트워크 데이터를 사용하고 싶어도 학습 모델의 성능 저하로 인해 데이터를 사용을 할 수 없었다. 다양한 네트워크 환경의 데이터를 적용할 수 없는 이유는 네트워크 데이터가 가지고 있는 고유한 특징때문이다. 기계 학습 모델은 일련의 간단한 벡터 형태의 숫자 데이터를 입력으로 받고 결과 데이터로 다시 숫자 데이터를 생성하는데, 네트워크 데이터를 입력 데이터로 사용하기 위해서는 먼저 네트워크 정보를 일련의 숫자 데이터로 표현을 해야한다. 이때 앞서 정의했던 서비스 정보와 네트워크 정보를 숫자로 표현한다고 할 때, 서비스의 양, SLA, Latency, Bandwidth 의 경우는 직접적인 수치로 간단히 표현이 가능하다. 또한 요구되고 있는 서비스의 종류나 물리 서버의 VNF 종류와 같은 정보도 one-hot-encoding 이나 embedding vector 를 사용하는 것으로 일련의 숫자로 분류되는 표현이 가능하다[7]. 하지만 물리 네트워크 토폴로지 연결 형태와 같은 정보는 표현이 어렵다. 네트워크의 각 물리 서버들 간의 연결 정보를 나타내기 위해서는 앞선 SLA 나 VNF 종류와는 달리 고차원의 벡터가 필요하며 복잡한 형태의 데이터로 표현이 된다. 이러한 문제로 기존의 연구들은 네트워크 토폴로지 구조를 학습 데이터에서 제외하였다. 그런데 이렇게 토폴로지 구조가 학습 데이터에서 제외되면, 학습 모델은 여러 다양한 환경의 네트워크 데이터를 학습 할 때 토폴로지를 구분할 수 없어 혼란을 겪게 되고 제대로 된 관리 정책을 내릴 수 없게 된다. 즉 모델은 토폴로지 정보를 가지지 않기 때문에 학습에 사용된 네트워크 데이터가 Star-토폴로지 네트워크인지 Link-토폴로지 네트워크인지, 물리 서버 간의 링크가 복잡하게 많이 형성된 네트워크인지, 간단한 네트워크인지 구분할 수 없게 된다.

본 논문은 네트워크 학습 모델이 범용성을 갖출 수 있도록 Graph Neural Network (GNN)을 사용하는 것을 제안한다. GNN 은 그래프 형태의 데이터를 입력으로 받아 그래프를 더 적은 형태의 그래프로 압축하거나 더 큰 형태의 그래프로 생성할 수 있으며 그래프 전체를 하나의 특정한 형태의 정보로 표현을 할 수 있다. 우리는 전체 네트워크 정보를 그래프 형태 데이터로 나타내어 GNN 에 입력 데이터로 사용을 하였는데, 네트워크

토폴로지 구조 자체가 그래프 형태의 데이터이기 때문에, 기존의 기계 학습 모델과는 달리 학습 모델이 네트워크 토폴로지 구조를 학습할 수 있게 되었다. 그래프로 표현된 네트워크 데이터는 GNN 학습 이후 일련의 숫자 데이터로 표현이 되고, 우리는 이렇게 표현된 숫자 데이터를 다시 서비스 정보 데이터와 합쳐 일반적인 기계 학습 모델 방법인 Feed Forward Neural Network (FNN) 을 사용하는 것으로 최적의 관리 모델을 찾을 수 있게 된다. GNN 을 사용하는 것으로 얻을 수 있는 또 하나의 장점은 네트워크 그래프 전체에 대해 학습이 이루어지기 때문에, 하나의 개별 물리 서버만을 대상으로 VNF Deployment 최적화 정책만을 얻는 것이 아니라 전체 네트워크의 모든 환경을 고려하여 모든 물리 서버를 대상으로 VNF Deployment 정책을 얻으며 물리 서버 간의 VNF Migration 정책을 얻을 수도 있다는 점이다. 즉 제안하는 기계 학습 방법은 서비스 정보와 네트워크 정보를 고려하여 모든 VNF 에 대해서 어느 위치에 어떠한 VNF 어떠한 VNF 관리 정책을 따라야하는 지 학습하는 것이 모두 가능하다.

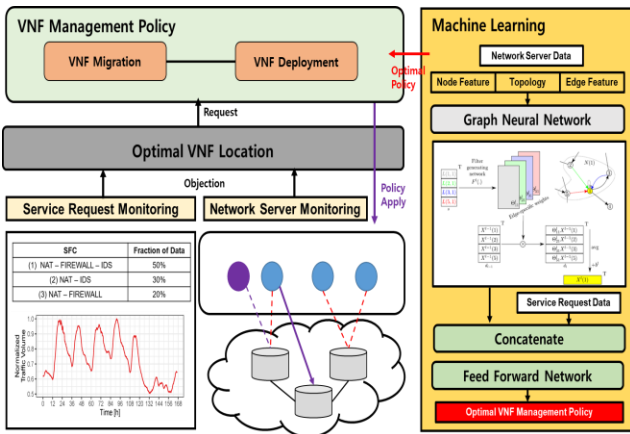


그림 2 기계학습 기반 VNF 관리 시스템

그림 2 는 제안한 기계학습 기반 VNF 관리 시스템을 간단히 도식화 한 것이다. 시스템은 VNF 들이 최적의 위치에 설치되는 것을 목표로 하면서 서비스 정보와 네트워크 정보를 모니터링하고 수집한다. 시스템의 목표는 VNF Migration 과 VNF Deployment 정책을 요구하며, 요구된 정책은 기계 학습을 통해 결정이 된다. 기계 학습은 그래프 형태로 표현된 네트워크 정보 데이터를 GNN 을 사용하여 일련의 숫자 벡터로 학습시킨 이후, 서비스 정보를 Concatenate 하여 FNN 에 학습 시킨다.

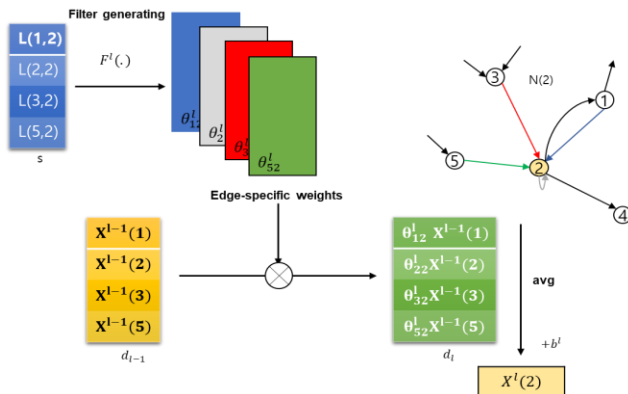


그림 3. Edge-conditioned Filters in Convolutional Neural Network

III. Edge-conditioned Filters in Convolutional Neural Network

본 논문은 GNN 모델 중 Edge-conditioned Filters in Convolutional Neural Network[8] 를 사용하는 것을 제안한다. Edge-conditioned Filters in Convolutional Neural Network 는 그래프의 노드와 엣지가 가지고 있는 정보를 활용하여 새로운 정보를 생성한다. 그림 3 은 이 GNN 모델이 어떻게 이웃 노드와 엣지를 이용하여 학습을 하는 지 표현하고 있다. 다섯 개의 노드가 존재하는 그래프를 주고, 노드 정보를 X, 엣지 정보를 L 라고 정의했을 때, 2 번 노드와 연결된 엣지들은 FNN 을 통해 엣지 정보의 특징을 가지고 있는 필터(θ)로 변환이 되며, 필터는 2 번 노드를 포함한 이웃 노드 정보와 곱셈을 하고 평균이 되어 새로운 정보가 된다.

이러한 일련의 과정은 노드 정보가 이웃 노드 정보와 엣지 정보를 포함하게 하는 효과가 있다. 네트워크에서 노드를 물리서버라고 정의를 하고 엣지를 노드 간의 연결이라고 정의를 한다면, 원래 노드들은 물리 서버의 가용 자원과 같이 오직 하나의 물리 서버 정보만을 가지고 있지만 그림 3 의 과정을 진행하게 되면, 노드 정보가 이웃 노드, 즉 이웃 물리 서버의 정보와 서버 간의 링크 정보를 가지게 된다. 모든 노드에 대해서 그림 3 의 과정을 진행하면 노드들의 정보만으로도 엣지 정보와 그래프 전체 정보를 알 수 있게 된다. 즉 GNN 을 사용하면 노드와 엣지로 구성된 고차원의 그래프 형태의 데이터를 노드 단위의 기계 학습이 쉽게 이해할 수 있는 데이터로 변환을 할 수 있다.

IV. 결론

본 논문에서는 기계학습 기반 VNF 관리 시스템을 제안하였다. 제안한 시스템은 GNN 을 이용하여 동적으로 변화하는 네트워크를 학습하며, 최적의 VNF 위치를 찾을 수 있다. 제안한 모델은 기존의 연구와 달리 네트워크 데이터를 그래프 형식의 데이터로 사용하여 네트워크의 동적 변화를 모델이 학습할 수 있으며 학습 결과로 어떠한 VNF 가 네트워크의 어느 물리 서버에 위에 Deploy 되거나 제거되어야 하는 지 구체적인 관리 정책을 제공할 수 있다. 본 논문에서는 구체적인 모델과 학습에 필요한 데이터를 제안하였으며, 제안한 모델을 구현하는 것으로 인공지능 기반의 자율 VNF 관리 시스템을 개발할 수 있을 것이다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획 평가원의 대학 ICT 연구센터지원사업의 연구결과로 수행되었음 (IITP-2020-2017-0-01633)

참고 문헌

[1] Blenk, Andreas, et al. "Boost online virtual network embedding: Using neural networks for admission control." *2016 12th International*

- Conference on Network and Service Management (CNSM)*. IEEE, 2016.
- [2] Lange, Stanislav, et al. "Predicting VNF Deployment Decisions under Dynamically Changing Network Conditions." *2019 15th International Conference on Network and Service Management (CNSM)*. IEEE, 2019.
- [3] Rahman, Sabidur, et al. "Auto-scaling vnfs using machine learning to improve qos and reduce cost." *2018 IEEE International Conference on Communications (ICC)*. IEEE, 2018.
- [4] Jeong, Seyeon, et al. "Machine Learning based Link State Aware Service Function Chaining." *2019 20th Asia-Pacific Network Operations and Management Symposium (APNOMS)*. IEEE, 2019.
- [5] Gori, Marco, Gabriele Monfardini, and Franco Scarselli. "A new model for learning in graph domains." *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005.*. Vol. 2. IEEE, 2005.
- [6] Bari, Md Faizul, et al. "On orchestrating virtual network functions." *2015 11th International Conference on Network and Service Management (CNSM)*. IEEE, 2015.
- [7] Rodríguez, Pau, et al. "Beyond one-hot encoding: Lower dimensional target embedding." *Image and Vision Computing* 75 (2018): 21–31.
- [8] Simonovsky, Martin, and Nikos Komodakis. "Dynamic edge-conditioned filters in convolutional neural networks on graphs." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.