

기계학습을 활용한 5G통신 동향

Research Trends on 5G Communications using Machine Learning

| | |
|-----------------|----------------|
| 김근영 (K.Y. Kim) | 5G 사업전략실 선임연구원 |
| 김용선 (Y.S. Kim) | 5G 사업전략실 책임연구원 |
| 남준영 (J.Y. Nam) | 5G 사업전략실 책임연구원 |
| 이우용 (W.Y. Lee) | 5G 사업전략실 책임연구원 |
| 서지훈 (J.H. Seo) | 5G 사업전략실 연구원 |
| 홍승은 (S.E. Hong) | 5G 사업전략실 책임연구원 |

* 본 연구는 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었음[16ZI1100, 다점대다 점 환경에서 이론적 한계 도달을 위한 무선전송기술 개발].

빅데이터를 통한 학습, GPU를 활용한 고속 컴퓨팅 및 다양한 알고리즘 개발과 더불어 기계학습은 다양한 분야에서 종래에 이루어지지 못한 뛰어난 성과를 달성하고 있다. 그동안 상용화된 통신 시스템에서 기계학습이 활성화되지 못했지만, 전례없는 다양한 서비스와 단말을 아우르는 5G 통신에서는 더욱 적극적으로 활용될 것으로 예상된다. 기계학습은 링크 적응 등 무선접속기술, 다양한 망이 혼재된 이종망 기술, 트래픽 분류 등을 위한 네트워크 기술, 침입 탐지를 위한 보안 기술 등 다양한 통신기술에서 연구됐다. 또한, 최근에는 유럽의 Public Private Partnership(5G PPP) 프로젝트를 비롯하여 다양한 그룹에서 활발히 연구되고 있으며, 컬컴/노키아/에릭슨 등 통신 관련 기업들도 적극적인 투자를 하고 있다. 본고에서는 기계학습 관련 통신기술, 연구그룹 및 기업 동향을 소개하고, 이를 통해 5G 통신 적용 가능성을 짚어본다.

5G 기가통신 기반기술 특집

- I. 머리말
- II. 기계학습 관련 5G 통신 기술 동향
- III. 기계학습 관련 통신 연구그룹 동향
- IV. 맺음말

I. 머리말

기계학습은 1940년대부터 소개된 기술로 인공지능을 연구를 위해 널리 활용됐다. 특히, 빅데이터로부터 신뢰성 있는 학습이 가능하고 GPU를 활용한 고속 컴퓨팅의 등장, 그리고 최적의 솔루션을 찾을 수 있는 다양한 기계학습 기법 연구로 인해 그동안 학계에서의 연구에 머물던 기술이 오늘날에는 공공, 개인, 산업에 널리 사용되게 되었다. 기계학습 기술은 통신 분야에도 다양하게 쓰이고 있는데 자가망 구성, DDOS공격 등 비정상 접근 검출, 트래픽 분류, 네트워크 관리 등에 적용되고 있다.

기계학습에서는 트레이닝 데이터와 검증 데이터를 이용해 어떤 응용에 적합한 모델을 만들어 내고 만들어진 모델을 실제 필드에 적용하고 다시 이를 업데이트하는 과정을 반복하여 정확도를 높이는 과정을 반복한다. 모델을 생성하기 위해서는 입력데이터로부터 특징을 추출하는 과정이 필요한데 기존에 널리 사용되어온 Bayesian Statistics, k-Nearest Neighbors(k-NN), Support Vector Machines(SVM) 등의 방법은 사람이 개입하여 특징을 찾아주는 과정이 필요하다[1]. 하지만, 딥러닝을 적용하는 경우에는 특징 추출 과정도 자동으로 진행되어 정확도와 소요시간을 줄여줄 수 있다. 최근 사진의 분류 성능을 경합하는 이미지넷 도전 대회에서의 결과를 보면 딥러닝을 적용한 방법이 주로 사용되고 있음을 알 수 있다. 그러나 기존의 방법들도 데이터가 부족하고 적은 계산량이 있어야 하는 응용에는 딥러닝보다 적합할 수 있으므로 딥러닝과 상호 보완적 관계라고 할 수 있다.

딥러닝은 1958년 Rosenblatt가 퍼셉트론 연구 이후로 수학적 한계와 이를 극복하는 역전파 기법 등장, 오류전파 사라짐 현상을 해결해주는 새로운 활성화 함수와 Long-Short Term Memory(LSTM) 기법 도입, Regularization 방법으로 등장한 Dropout 기법 등의 활발한 알고리즘 연구와 더불어 Big Data, GPU 병렬처리

등의 영향으로 컴퓨터비전, 음성인식, 자연어처리, 음성/신호처리 등의 분야에서 놀라운 성능 향상을 보여주고 있다.

통신 분야에서도 신호처리, 음성인식 분야보다는 활성화되어 있지 않지만, 이러한 딥러닝을 포함한 기계학습 기법을 도입하려는 시도가 최근에 많아지고 있다. 2020년경 상용화될 것으로 예상되는 5G 통신은 ‘언제 어디서나 환경의 제약없이 사람과 사물을 포함한 모든 사용자에게 지연없이 Gbps급 서비스를 비용/에너지 효율적으로 제공하는 통신’을 의미한다[2]. 이러한 5G 통신은 전례 없는 다양한 서비스와 단말을 아우를 것으로 예상되어, 최근 놀라운 성능을 보여주고 있는 기계학습이 이전 통신 방식에 비해 보다 적극적으로 사용될 것으로 예상된다.

본고에서는 이러한 기계학습 기법이 5G를 포함한 통신 분야에 어떻게 활용되고 있는지를 파악해 보고자 한다. 본고는 II장에서는 기계학습 관련 5G통신 기술 동향, III장에서는 기계학습 관련 통신 연구그룹 동향을 소개하고, 맺음말로 마무리한다.

II. 기계학습 관련 5G통신 기술 동향

1. 무선전송접속 기술

무선통신의 물리계층 및 다중접속계층에 적용된 기계학습의 대표적인 사례는 하향링크에서 링크적응(link adaptation)이다. 링크적응은 사용자들의 채널상태 변화에 따라 적응 변조 및 부호화(adaptive modulation and coding)를 수행하여 수신 품질을 유지하면서 시스템 전송효율을 최대화하는 기술이다. 하지만, 다중안테나 채널의 상태변화 및 다양한 시스템 손실 상황에 따른 각 단말의 수신오류를 정확히 예측하여 상위계층에서 요구되는 프레임 오류율을 만족시키는 변조 및 부호 레벨 및 스트림수를 정하는 것은 매우 어려운 작업이다. 종래 링크적응 방식은 이러한 링크적응 오류를 줄이기

위해 별도의 외부루프 링크적응(outer loop link adaptation)을 수행해야 한다.

상기 링크적응을 지도학습(supervised learning) 틀에서 수행하는 시도가 있다. [3]은 학습자료를 통해 MIMO-OFDM 채널상태 정보와 최적의 변조 및 부호 레벨 간의 맵핑을 feature 공간의 형태로 추출하는 지도 학습 방식을 제안한다. 이 과정에서 k-NN (k-nearest neighbor) 알고리즘을 통해 후처리 신호대잡음비(postprocessing signal-to-noise) feature를 추출하여 변조 및 부호 레벨로 맵핑한다. 또한, 제안한 지도학습 기반 방식의 링크적응이 IEEE 802.11n에서 종래의 유효 신호대잡음비 방식 대비 더 나은 성능을 나타냄을 보였다. 한편, SVM 기반 지도학습을 이용한 링크적응 방식이 제안되기도 하였다[4]. 다중사용자 MIMO통신에서 링크적응은 단일사용자 MIMO통신에 비해 사용자간 간섭의 불확실성으로 인해 매우 어려운 문제에 해당하고 외부루프 링크적응을 포함한 종래 방식은 좋은 품질의 링크적응에 한계가 있다. 이러한 문제를 해결하고자 지도학습 기반의 링크적응은[5]에서 다중사용자 MIMO-OFDM으로 확장되었다. 제안 링크적응 방식은 다중사용자, 단일/다중 MIMO 모드, 프리코딩, 변조 및 부호 레벨, 제한적인 피드백 모드에 대한 선택을 기계학습을 통해 수행한다.

기계학습을 물리계층에 적용한 다른 사례로 비면허대역을 공유하는 서로 다른 무선접속 규격을 갖는 신호를 추정하고 분리하여 간섭을 제거하여 자기 신호의 신호대잡음비를 높이는 연구가 있다. 일례로, [6]의 연구그룹은 자유도(Degrees of Freedom)라는 무선랜, Zigbee, 블루투스 등이 섞인 무선통신 신호를 SVM을 사용하여 분류하는 알고리즘을 제시하였다. 또한, Convolutional Neural Network(CNN)과 딥러닝을 이용하여 비면허대역 무선통신 신호를 추정하고 예측하는 방법도 연구되고 있다[7]. 한편, least mean square 필터를 이용한 적응간섭제거와 같은 종래 간섭 추정 및 제거 방식은 간섭

의 파일럿 신호를 수신하여 간섭채널을 추정할 수 있어야 동작하는 방식이다. 반면, CNN 타입의 딥러닝 간섭 제거 방식은 학습과정에서 feature 추출이 완료되면 간섭신호의 채널정보 필요없이 간섭 예측이 가능하다는 장점이 있고 간섭제거 성능도 종래 방식에 비해 뛰어남을 보였다.

2. 이종망 기술

폭증하는 트래픽과 다양한 서비스 요구사항으로 인해 통신 사업자의 망은 커버리지, 전송전력, 동작방식 등에 따라, 다양한 종류의 망이 섞여있는 이종망(Heterogeneous Networks)으로 진화 중이다. 이종망은 본격적인 동작 전 스스로 셀을 구성하는 자기 설정(Self-Configuration), 오동작을 발견하고 스스로 복구하는 자기 복구(Self-Healing), 네트워크 상황을 측정하여 스스로 설정을 최적화하는 자기 최적화(Self-Optimization)의 세 가지 특성이 필요한 자기 구성망(Self-Organization Networks) 기술을 통해 인간의 개입을 최소화하여 비용 절감을 달성할 수 있다. 이러한 이종망은 복잡하게 얽혀있어 망 구성/관리/최적화가 쉽지 않기 때문에, 성능 향상을 위해 기계학습 등 인공지능을 적용한 통신기술이 다양하게 연구되고 있다[8].

기계학습 중에서 행동심리학에서 영향을 받은 강화학습(Reinforcement Learning)이라는 것은 각 개체가 특정 시간 동안 관측된 이득/보상을 최대화하는 방식을 찾는 것으로 무선접속 및 전송 전력 할당 등에 자주 사용되고 있다[8]. 제한된 정보하에서 각 사용자가 자신의 최적이득과 최적전략을 동시에 학습하는 강화학습 성능 분석과 게임역학(Game Dynamics)이 제시되었고, 불완전하고, 잡음 및 지연이 있는 측정값에서 이득이 있는 것이 확인되고 있다[9]. 또한, 강화학습은 이종망에서 맥락(context) 인지 이동성 관리[10] 및 자율 적응 재설정[11]에 효율적으로 적용될 수 있다.

강화학습의 한 예로 주어진 마코프 결정 과정(Markov

Decision Process)에 대해 행동결정방식의 최적 가치 값(Q-Value)을 찾는 Q-Learning이 있다. 이 Q-Learning은 이종망에서 대부분의 자기최적화 방식에 적용할 수 있다. 예를 들면, 반송파 집성시 위치정보를 활용하여 동적자원할당에 사용될 수 있다[12][13]. 이종망에는 다양한 형태의 많은 단말들로 인해 발생하는 간섭 관리를 위해 각각의 셀이 협력하여 시간 영역 적응 셀 간 간섭 조율을 하는 분산 Q-Learning을 이용할 수 있다[14]. 비슷한 접근 방식이 기지국이 위치 정보를 필요로 하지 않는 이종망에서 안테나 틸팅의 주파수/에너지 효율 향상을 위해 적용되었다[15]. 셀이 공동으로 자신의 효율성을 예측하고, 분산 방식으로 전략을 학습하는 폐쇄 루프 공간다중화 다중입력 다중출력 이종망에서 간섭 조율을 향상시키기 위한 regret-learning 기반 알고리즘도 연구되었다[16]. Orthogonal Frequency Division Multiple Access(OFDMA) 기반 이종망 배치시 계층 간 간섭 완화를 위한 분산 fuzzy Q-learning 연구[17] 및 이종망에서 부분 전력 제어를 통한 동적 자원 관리에 대한 최적화를 위한 fuzzy 강화학습[18]도 연구되었다.

인간 두뇌의 신경망을 본 딴 인공신경망(Artificial Neural Networks)을 적용한 연구도 있다. 인공신경망은 입력에 비중이 다른 값을 곱하여 뉴런들을 연결시킨 것으로 합수값을 예측하거나, 분류하는 경우 등에 적용할 수 있다. 강화학습 기반 fuzzy 신경망 최적화를 이용하여 안테나 틸팅과 전력의 자기 최적화 방식이 제안되었다[19]. 제안된 방식은 빠르게 수렴하기 때문에 동적 환경에서 자기 최적화를 위한 실용적인 방안이 될 것으로 기대된다. 인공신경망은 또한 사용자 Quality of Service(QoS) 향상 및 이종망 성능 향상을 위해 동적 파라미터 조정 알고리즘을 통해 사용자 최적 파라미터를 결정하여 이종망간 핸드오버 문제에 적용되기도 하였다[20].

기계학습 이외에 세포를 모방한 Genetic 알고리즘, 군집 지성의 대표적인 알고리즘인 개미 군락 최적화 (Ant Colony Optimization), fuzzy 시스템 등 인공지능을 활

용한 이종망 성능 향상 기술도 연구되고 있다[8].

3. 네트워크 기술

오래전부터 유/무선 통신사업자들은 QoS 제공, 비정상 탐지, 침입 탐지 등을 위해 자신들의 네트워크를 통해 전송되는 트래픽들을 감지/분류했으며, 그 방법으로는 포트 번호 감지, 패킷의 앱 종류 감지, Deep Packet Inspection(DPI) 등을 사용하였다. 하지만 앱 또는 사용자가 포트 번호를 임의로 변경하여 사용하는 경우 감지가 어렵고, 암호화 트래픽의 비율이 점점 올라가고 있어 패킷의 앱 종류를 감지하기 어려우며, 인터넷 사용량 증가와 스마트폰의 보급 등으로 인터넷 트래픽이 매달 증가하고 있어 많은 패킷을 대상으로 DPI를 수행하기에는 무리가 있을 것이다. 이러한 이유로, 5G 네트워크에서 기계학습 기법을 이용한다면 임의 포트 변경/암호화에도 불구하고 트래픽 감지/분류를 수행할 수 있을 것이고, 또한 모든 패킷에 대해 DPI를 수행할 필요없이 트래픽 플로우의 통계적 특성을 이용하여 플로우를 분류하고 애플리케이션을 인식할 수 있다.

트래픽 분류 및 앱 인식 방법으로 비감독형 기계학습을 이용한 방안이 제안되었다[21]. Feature 선택 기법을 사용하였으며, feature 선택이 성능에 미치는 영향을 분석하였다. 또한, 분산 QoS 관리를 위한 기계학습 기반의 트래픽 분류 기법이 제안되었다[22]. 컴퓨터 여러 대를 이용하여 분산적으로 트래픽 분류를 처리하기 때문에 시스템 규모를 키울 수 있다는 장점이 있다. 한 플로우 전체가 아닌 서브플로우(sub-flow)의 통계를 이용하는 기계학습 기반 트래픽 분류 기법도 제안되었다[23]. 서브플로우는 트래픽의 주기 내에서 추출한 몇 개의 패킷들로, 이를 바탕으로 기계학습 분류자(Classifier)가 학습된다. [24]에서는 기계학습을 이용하여 트래픽 추적을 ‘트래픽 클러스터’로 나누는 방법을 제안하였다. 각 클러스터는 서로 다른 트래픽 특성을 가지며, 클러스터의 예시로는 ‘벌크 전송 / 1~3회 교환 / 쌍방향 트래

픽' 등이 있을 수 있다.

[25]에서는 위와 같이 IP 트래픽 분류에 기계학습을 사용하는 연구들에 대해 정리하였다. 2004~2007년에 발표된 18개의 논문을 대해 조사하였으며, 기계학습 기반 트래픽 분류 도입에 필요한 요구사항에 관해 서술하고 각 연구들이 요구사항을 만족하는지 분석하였다.

네트워크 분야에 기계 학습 적용에서 그래프 이론 기반 분산 학습 알고리즘을 발전시키고 있다[26]. 목적 병렬의 자유도(Degree of Parallelization)를 얻기 위하여 적용하는 교차 방향 승산 기법(Alternating Direction Method of Multipliers)은 일반 기계학습 문제를 병렬 처리 문제(separable form)로 변환시키는 반복적 최소화 기법이다. 이 기법은 분산 훈련 세트의 요소에 대한 교환 없이 허용 범위 내에서 노드 간 통신을 유지하면서, 지역(per-node) 학습자(learners)는 네트워크 전체의 훈련 세트를 가지고 추론하는 중앙집중식의 목표값을 찾도록 하는 것이다. 현대 무선 통신 및 네트워킹 분야 적용을 위한 분산 학습 프레임워크는 무선 센서 네트워크 관리, 인터넷 이상 트래픽 추적, 전력 시스템 상태 추정뿐만 아니라, 인지 무선 네트워크에 대한 스펙트럼 지도 제작 등에도 응용될 것이다.

4. 보안 기술

현재 많은 네트워크에서는 보안을 위해 침입 탐지를 시행하고 있고, 그 방법으로는 시그니처 기반 네트워크 공격 탐지를 주로 사용하고 있다. 하지만 이는 다각적인 침입에는 효과적이지 않다고 알려져 있고, 제로데이 공격, 예고없는 공격은 감지할 수 없다[27]. 이와 같은 문제점을 극복하기 위해, 특히 예고없는 공격을 감지하기 위해 기계학습을 이용한 침입 탐지에서의 데이터 셋을 업데이트하는 방법을 제안하고 기존 방법과의 성능을 비교/분석하였다.

침입 탐지에 기계학습을 사용하면서 한 가지의 기계 학습 기법을 사용하는 것보다는 여러 가지의 기계학습

기법을 사용하는 hybrid learning/ensemble learning이 더 좋은 성능을 낸다는 것에 착안하여, Triangle Area Based Nearest Neighbors(TANN) 기반의 hybrid learning 모델을 제안하였다[28]. TANN에서는 k-means clustering 과 k-NN 분류자가 사용되었다.

[29]에서는 네트워크 침입 탐지에 단일/다중 기계 학습 기법을 사용한 460개의 논문 중에서, 2000~2013년에 발표된 105개 이상의 논문을 소개하였다. 다양한 연구들의 디자인, 데이터셋, 실험 설정 등을 비교하고, 연구들의 성과/한계에 대해 논의한 뒤 향후 연구 방향에 대해 제안하였다.

한편, [30]에서는 위와 같이 기계학습 기반의 네트워크 침입 감지에 대한 연구가 많이 이루어졌음에도 불구하고 실제 시스템에 널리 도입되지 않는 것에 주목하여, 네트워크 침입 탐지 문제를 기계학습이 성공적으로 도입된 다른 연구분야와 비교하였다. 네트워크 공격을 감지하는 것은 다른 응용들과는 확연히 달라서 침입 탐지에 기계학습을 도입하기가 매우 어렵다고 주장하였으며, 네트워크 침입 탐지에 기계학습을 도입하는 것에 대해 몇 가지 가이드라인을 제시하였다.

III. 기계학습 관련 통신 연구그룹 동향

1. 5G PPP 프로젝트

5G Infrastructure Public Private Partnership(5G PPP) 프로젝트는 유럽에서 진행된 5G 연구 프로젝트로서 2015년 7월에 19개의 프로젝트를 시작으로 Phase 1이 진행 중이다. 2016년 6월말 개최된 European Conference on Networks and Communications(EuCNC) 2016 행사에서는 이러한 19개 프로젝트의 연구 현황이 소개되었다. 이들 프로젝트 중에서 기계학습과 5G를 직접 연구주제로 진행하는 프로젝트(CogNet)와 세부 연구분야에서 기계학습을 응용하고 있는 프로젝트(SPEED-5G, SELFNET)가 있어 이를 소개하고자 한다.

가. CogNet 프로젝트

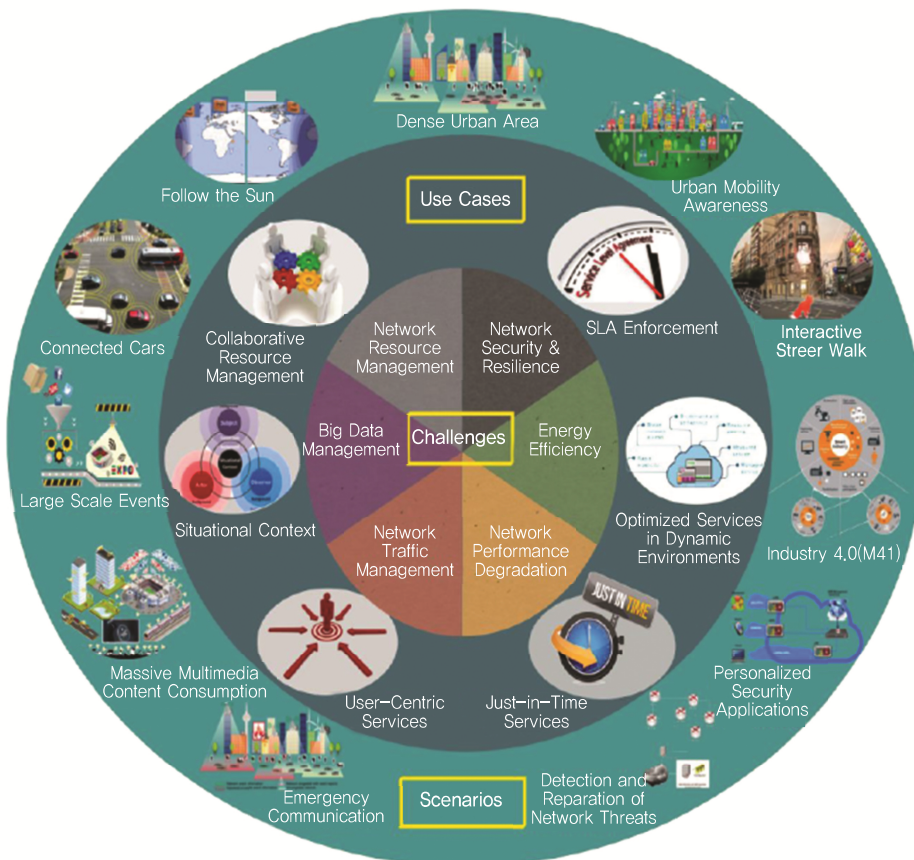
CogNet 프로젝트는 19개의 5G-PPP 프로젝트 중 하나로 기계학습 기반 5G 네트워크 관리 분야를 주요 연구 주제로 하고 있다.

특히, CogNet 프로젝트에서는 인지 네트워크 관리, 5G 네트워크 보안과 무결성, 가상 네트워크 플랫폼과 소프트웨어 네트워크 분야에 기계학습을 적용하고 있다. 5G는 네트워크 크기와 연결되는 장치의 수의 증가로 인해 가용한 라디오 스펙트럼과 QoS를 위한 대역폭을 최대한 이용할 수 있도록 최적화되는 네트워크가 될 것이다.

기계학습기반의 자동 네트워크 관리 기술은 스펙트럼과 대역폭 최적화 관점에서 자기관리 및 자기 운영 네트워크를 가능하게 해준다. 또한, 기계학습기반 네트워

크 소프트웨어는 사용량, 오류 조건 인지, 보안 조건, 이상점 발생을 예측하여 적절한 조치를 할 수 있다. CogNet 프로젝트는 이러한 도메인에 기계학습을 적용하여 네트워크 관리 수준을 높여 5G 요구사항이 용이하게 해줄 수 있다.

CogNet에서는 기계학습이 적용될 수 있는 5G use case와 시나리오 그리고 이의 실현을 위해 도전해야 할 기술을 그림 1과 같이 제시하고 있다. 5G use case와 시나리오 실현을 위해 필요한 요소 기술로서 CogNet에서 제시하고 있는 6가지 도전 기술은 Big Data 관리, 네트워크 트래픽 관리, 네트워크 성능 하락 방지 기술, 에너지 효율 달성 기술, 네트워크 보안 및 복구 기술, 네트워크 자원 관리 기술이다. 이러한 도전 기술은 상황 맥락 (Situational Context), 사용자 중심 서비스 등 6가지



(그림 1) CogNet 프로젝트 Challenges, Use Case 및 시나리오[31]

use case와 Connected Car, 네트워크 공격 방어 및 복원, 상호작용 보행, 대규모 이벤트 등의 11개의 시나리오를 구현하는 바탕이 된다.

나. SPEED-5G 프로젝트

SPEED-5G 프로젝트는 이종망에서 스펙트럼 효율을 최적화하는 기술 개발을 목표로 하고 있다. 이러한 목표 달성을 위해 일부 자원관리 분야에서 기계학습 방법을 적용하는 연구를 진행하고 있다.

SPEED-5G 프로젝트에서는 5G서비스 요구사항과 Key Performance Index(KPI)를 만족시키기 위해 기계학습 기반 예측을 통해 복잡한 문제를 해결하고자 한다.

기계학습 기반 무선자원관리 기술은 SPEED-5G에서 진행하고 있는 연구 중 하나로, 고속 이동 차량에서 주변 기지국 장치와 차량 통신, 이동 차량 간 통신 등에 요구되는 무선 자원을 기계학습을 통한 예측 모델을 통해 효율적인 자원 관리를 제공한다. 또한, 다양한 라이선싱 기법, 넓은 주파수 대역에서 자동화된 동적 스펙트럼 할당 기법 등에 기계학습 기법을 도입하고 있다.

다. SELFNET 프로젝트

SELFNET 프로젝트는 5G PPP 프로젝트 중 하나로 Software Defined Network(SDN), Network Function Virtualization(NFV), Cloud Computing, 인공지능 등의 기술을 사용하여 비용 효율적인 실시간 자동 5G 네트워크 관리를 추구한다. 특히, 현재 네트워크 관리자에 의해 수동으로 진행되고 있는 일반적인 네트워크 문제를 자기 구성(self-organizing) 기술을 활용해 운용 비용을 줄이고 사용자 경험을 향상시키기 위한 지능화 네트워크 프레임워크 설계 및 구현에 초점을 맞추고 있다.

SELFNET 프로젝트는 2015년부터 2018년까지 진행되고 Eurescom(독일), West of Scotland 대학(영국), de Murcia 대학(스페인), Portugal Telecom Research &

Inovacao(포르투갈), Nextworks(이탈리아) 등 12개의 유럽 연구 단체가 공동으로 진행하고 있다.

2. 표준관련 그룹 동향

가. IRTF NMLRG 동향

Internet Research Task Force(IRTf)는 Internet Engineering Task Force(IETF)의 자매 조직으로 인터넷 프로토콜, 응용, 아키텍처를 다루는 장기 연구그룹이다. IRTf Network Machine Learning(NML) Research Group(RG)은 NMLRG는 기계학습을 통해 네트워크 상의 복잡한 일을 쉽게 풀어주고 자동화할 수 있도록 연구하는 그룹이다. 연구 아이টে이프로 기계학습 기반 플로우 모니터링, 라우터에서의 이상 트래픽 감지, 광역 네트워크에서의 기계학습 기반 정책 도출, 기계학습 기반 DNS 트래픽 분석을 통한 malware 등의 자동 감지, HTTPS 트래픽 분류 등이 있다. 현재 Talaia Networks(스페인), Inria(프랑스), Huawei(중국) 등 여러 기업에서 본 연구그룹 내에서 연구를 진행하고 있다.

나. IETF ANIMA 동향

Internet Engineering Task Force(IETF) Autonomic Networking Integrated Model and Approach(ANIMA) WG에서는 self-management(self-configuration, self-optimization, self-healing, self-protection 포함)를 목적으로 연구그룹을 운영하고 있다. ANIMA WG은 자동화된 네트워크의 인프라스트럭처 연구를 목적으로 IETF에 의해 2014년에 만들어졌다. 주요 연구 주제는 자동화된 네트워크 정의/갭분석, Use Case, 공통 요구사항, 문제정의 등이다.

다. ETSI NGP ISG 동향

Next Generation Protocol(NGP) Industry Specification Group(ISG)는 차세대 통신 프로토콜, 네트워크 아키텍

처 요구사항을 연구하는 그룹이다. 본 그룹에서는 Self-organizing Control & Management Planes 워크아이템에 자율결정을 위한 기계학습 도입이 다루어지고 있다.

3. 산업계 동향

2014년 이후 컬킴은 Zeroth라는 이름으로 인간의 두뇌에서 영감을 받은 컴퓨팅 기술과 딥러닝 기술 개발을 시작하였다[32]. 그동안 딥러닝은 CPU와 GPU를 연결하는 클라우드 또는 클러스터에서 주로 논의됐다. 컬킴은 딥러닝이 모바일 SOC인 Snapdragon에서 효율적으로 동작할 수 있도록 하였으며, 이를 통해 일상 속에서 스마트폰, 로봇, 자동차, 드론 등에서 딥러닝 활용이 가능하다. 딥러닝의 학습을 위해서는 많은 데이터로 거대한 CPU와 GPU의 클러스터가 필요하지만, 학습된 딥러닝 네트워크는 Snapdragon이 탑재된 단말을 통해, 이미지 분류, 물체/얼굴 인식 등의 작업을 할 수 있다. 2015년 말에는 Snapdragon Cargo라는 딥러닝 기반 분류 기술을 이용한 로봇으로 장난감을 인식/분류/정리하는 시연을 실시하였다.

컬킴은 Convolutional Neural Network(CNN)를 통해 거의 실시간으로 얼굴 인식이 가능한 Snapdragon Rover라는 로봇을 선보였으며, 전체 CNN에 대한 재학습없이 일부의 재학습으로 새로운 얼굴인식이 가능한 것을 선보였다. 시간 영역 요소를 가진 영상 동작 인식, 필기 인식, 음성/자연어 처리 등이 가능한 Recurrent Neural Network(RNN) 기술도 연구 중이다.

또한, 컬킴은 2016년 5월 딥러닝 소프트웨어 개발 키트를 발표했다[33]. 이 개발 키트는 Snapdragon 820 코어에서 CNN/RNN 실행, Caffe/CudaConvNet 등 상용 딥러닝 프레임워크 지원, 다양한 Snapdragon 코어 지원이 가능한 경량 플랫폼을 특징으로 한다.

컬킴은 Zeroth를 통해 일상생활에서 인간의 인식이 단말에서 가능해지도록 하는 연구를 진행 중이다.

노키아는 2020년 기술 비전으로 기계학습을 이용한 자기인지(self-aware) 네트워크를 제공하는 것을 목표로 하고 있다[34]. 2000년 대에는 소프트웨어 업그레이드가 있을 때마다 차량 운전을 통한 시험을 수행하였는데, 2020년에는 10-100배 가량 많은 셀이 배치될 것으로 예상되어 인간이 감당하기 어려운 수준에 이를 것으로 전망된다. 노키아는 이에 대한 해결방안으로 Self-Organizing Network(SON) 자동화와 더불어 빅데이터 분석과 기계학습을 활용하여 네트워크가 자기인지 하도록 학습해야 한다고 제시하고 있다.

에릭슨은 사용자, 네트워크, 트래픽 데이터를 이해/분석하고 서비스 부양을 위해 기계학습을 활용하는 것을 제안하고 있다[35]. 또한, 기계학습을 활용한 사업모델로 추천, 개인화, 미디어 인식을 제시하고 있다. 데이터 추출의 경우에 일반적인 기계학습 알고리즘뿐 아니라 해당 영역 고유의 정보도 중요하기 때문에, 에릭슨은 보유한 고객 정보 등을 활용할 수 있어서 기계학습에 강점이 있다고 주장한다.

IV. 맺음말

본고에서는 기계학습을 통신에 접목하여 진행하고 있는 기술 연구, 관련 그룹 동향에 대해 살펴보았다. 기계학습은 유럽의 5G 연구그룹과 IETF 등과 같은 통신관련 국제 표준화 단체에서도 연구 및 표준화 테마로 선정하여 활발한 활동을 해오고 있다. 또한 컬킴을 비롯한 기업에서도 기계학습을 도입하기 위한 연구를 진행하고 있다.

기계학습은 무선전송접속기술, 이종망 기술 등의 각 요소에 적용 시 연구초기단계임에도 불구하고 효율적임을 알 수 있으며, 네트워크 자가 진단, 사이버 공격 인지 등 다양한 응용 분야에 활용 할 수 있다. 또한, 빅데이터를 이용하여 트래픽 분류, 서비스 분류, 응용 분류를 효율적으로 가능하게 하여 사용자 맞춤형 가상 네트워크

의 실현에 기여할 수 있다. 기계학습은 추가적인 연구를 통해 통신 분야 기술을 크게 개선할 여지가 있으며 통신에 유연성을 부여하여 활용도를 높여줄 수 있을 것으로 기대된다.

다양한 서비스와 단말을 아우를 것으로 예상되는 5G 통신은 최대 10-50 Gbps 전송율, 100Mbps-1Gbps사용자당 체감 전송율, 500km/h의 이동성 지원, 무선구간 1ms 이내 전송지연, 제곱 킬로미터 당 백만개의 연결 밀도 지원 등 어려운 요구사항을 에너지 효율적이고 주파수 효율적으로 만족해야 한다. 이러한 복잡하고 다양한 요구사항을 충족하기 위해 기계학습은 필수적 도구가 될 것으로 예상된다.

약어 정리

| | |
|--------|--|
| 5G PPP | 5G Infrastructure Public Private Partnership |
| CNN | Convolutional Neural Network |
| CPU | Central Processing Unit |
| DPI | Deep Packet Inspection |
| EuCNC | European Conference on Networks and Communications |
| GPU | Graphic Processing Unit |
| k-NN | k-Nearest Neighbors |
| KPI | Key Performance Index |
| NFV | Network Function Virtualization |
| OFDMA | Orthogonal Frequency Division Multiple Access |
| RNN | Recurrent Neural Network |
| SDN | Software Defined Network |
| SON | Self-Organizing Network |
| SVM | Support Vector Machine |
| QoS | Quality of Service |

참고문헌

- [1] C. Cortes and V. Vapnik, "Support-Vector Networks," *Machine Learning*, vol. 20, 1995, pp. 273-297.
- [2] 한국전자통신연구원, "5G Insight White Paper: 5G Vision &

Enabling Technologies," 2015. 12.

- [3] R.C. Daniels, C.M. Caramanis, and R.W. Heath, "Adaption in Convolutionally-Coded MIMO-OFDM Wireless Systems through Supervised Learning and SNR Ordering," *IEEE Trans. Veh. Technol.*, vol. 59, no. 1, pp. 114-126, Jan. 2010.
- [4] R.C. Daniels and R.W. Heath, "An Online Learning Framework for Link Adaptation in Wireless Networks," *Proc. Inf. Theory Appl. Workshop*, Feb. 2009, pp. 138-140.
- [5] A. Rico-Alvarino and R.W. Heath, "Learning-Based Adaptive Transmission for Limited Feedback Multiuser MIMO-OFDM," Submitted to *IEEE Transactions on Wireless Communications*, 2013.
- [6] S.S. Hong and S.R. Katti, "Dof: A Local Wireless Information Plane," *ACM SIGCOMM*, vol. 41, no. 4, Aug. 2011, pp. 230-241.
- [7] K. Joshi, S. Hong, and S. Katti, "PinPoint: Localizing Interfering Radios," *Proc. USENIX Symposium on Networked Systems Design and Implementation (NSDI)*, 2013.
- [8] X. Wang, X. Li, and V. C.M. Leung, "Artificial Intelligence-Based Techniques for Emerging Heterogeneous Networks: State of the Arts, Opportunities, and Challenges," *IEEE Access*, vol. 3, Aug. 2015, pp. 1379-1391.
- [9] M.A. Khan, H. Tembine, and A.V. Vasilakos, "Game Dynamics and Cost of Learning in Heterogeneous 4G Networks," *IEEE J. Sel. Areas Commun.*, vol. 30, no. 1, Jan. 2012, pp. 198-213.
- [10] M. Simsek, M. Bennis, and I. Güvenc, "Context-Aware Mobility Management in HetNets: A Reinforcement Learning Approach," in *Proc. Netw. Internet Archit.*, May 2015.
- [11] Z. Zhao, J. Chen, and N. Crespi, "A Policy-Based Framework for Autonomic Reconfiguration Management in Heterogeneous Networks," *Proc. 7th Int. Conf. Mobile Ubiquitous Multimedia*, 2008, pp. 71-78.
- [12] P.T. Semov et al., "Use of Positioning Information for Performance Enhancement of Uncoordinated Heterogeneous Network Deployment," *Proc. 3rd Int. Conf. VITAE*, June 2013, p. 16.
- [13] P.T. Semov et al. "Increasing Throughput and Fairness for Users in Heterogeneous Semi Coordinated Deployments," *Proc. IEEE WCNC*, Apr. 2014, pp. 40-45.

- [14] Q. Li et al., "Dynamic Enhanced Inter-Cell Interference Coordination Using Reinforcement Learning Approach in Heterogeneous Network," *Proc. IEEE ICCT*, Nov. 2013, pp. 239-243.
- [15] W. Guo et al., "Spectral- and Energy-Efficient Antenna Tilting in a HetNet Using Reinforcement Learning," *Proc. IEEE WCNC*, Apr. 2013, pp. 767-772.
- [16] M. Simsek, M. Bennis, and A. Czyliwłk, "Coordinated Beam Selection in LTE-Advanced HetNets: A Reinforcement Learning Approach," *Proc. IEEE Globecom Workshops*, Dec. 2012, pp. 603-607.
- [17] M. Simsek and A. Czyliwłk, "Improved Decentralized Fuzzy Q-Learning for Interference Reduction in Heterogeneous LTE-Networks," *Proc. Int. OFDM Workshop*, Aug. 2012, pp. 1-6.
- [18] M. Dirani and Z. Altman, "Self-Organizing Networks in Next Generation Radio Access Networks: Application to Fractional Power Control," *Computer Networks*, vol. 55, no. 2, Feb. 2011, pp. 431-438.
- [19] S. Fan, H. Tian, and C. Sengul, "Self-Optimization of Coverage and Capacity Based on a Fuzzy Neural Network with Cooperative Reinforcement Learning," *EURASIP J. Wireless Commun. Netw.*, vol. 2014, no. 1, pp. 57:1-57:14, Apr. 2014.
- [20] R. Chai et al., "Neural Network based Vertical Handoff Performance Enhancement in Heterogeneous Wireless Networks," *Proc. WiCOM*, Sept. 2011, pp. 1-4.
- [21] Zander, S., Nguyen, T., & Armitage, G., "Automated Traffic Classification and Application Identification Using Machine Learning," *IEEE Conf. Local Computer Networks 30th Anniversary*, Nov. 2005, pp. 250-257.
- [22] S. Zander and G. Armitage, "Practical Machine Learning based Multimedia Traffic Classification for Distributed QoS Management," *Local Computer Networks(LCN) IEEE 36th Conference*, Oct. 2011, pp. 399-406.
- [23] T.T. Nguyen et al., "Timely and Continuous Machine-Learning-based Classification for Interactive IP Traffic," *IEEE/ACM Transactions on Networking (TON)*, vo. 20, no. 6, 2012, pp. 1880-1894.
- [24] A. McGregor, "Flow Clustering Using Machine Learning Techniques," *International Workshop on Passive and Active Network Measurement Springer Berlin Heidelberg*, Apr. 2004, pp. 205-214.
- [25] T.T. Nguyen and G. Armitage, "A Survey of Techniques for Internet Traffic Classification using Machine Learning," *IEEE Communications Surveys & Tutorials*, vol. 10, no. 4, 2008. pp. 56-76.
- [26] <http://arxiv.org/abs/1503.08855>
- [27] J. Cho et al., "Dynamic Learning Model Update of Hybrid-Classifiers for Intrusion Detection," *Journal of Super-computing*, vol. 64, no. 2, 2013, pp. 522-526.
- [28] C.F. Tsai and C.Y. Lin, "A Triangle Area based Nearest Neighbors Approach to Intrusion Detection," *J. Pattern Recognition*, vol. 43, no. 1, Jan. 2010, pp. 222-229.
- [29] K.K. Patel and B.V. Buddhadev, "Machine Learning based Research for Network Intrusion Detection: A State-of-the-Art," *International Journal Information and Network Security (IJINS)*, vol. 3, no. 3. 2014.
- [30] R. Sommer and V. Paxson, "Outside the Closed World: on Using Machine Learning for Network Intrusion Detection," *IEEE Symposium on Security and Privacy*, May. 2010, pp. 305-316.
- [31] CogNet, "Initial Use Cases, Scenarios and Requirement," 2015.11.
- [32] <https://www.qualcomm.com/news/onq/2015/03/02/qualcomm-zeroth-advancing-deep-learning-devices-video>
- [33] <https://www.qualcomm.com/news/releases/2016/05/02/qualcomm-helps-make-your-mobile-devices-smarter-new-snapdragon-machine>
- [34] <https://blog.networks.nokia.com/mobile-networks/2015/11/11/machine-learning-teach-networks-self-aware/>
- [35] M. Svensson, and J. Söderberg, "Machine-Learning Technologies in Telecommunications," *Ericsson Review*, 2008.