

구조해석을 위한 딥러닝

Deep Learning for Structural Analysis



이 재 흥*
Lee, Jaehong



이 승 혜**
Lee, Seung-Hye

1. 딥러닝 시대의 도래

우리는 아직도 2016년 3월의 바둑 대결, 구글 딥마인드 챌린지 매치(Google Deepmind Challenge match)¹⁾를 종종 대화에서 거론한다. 인공지능 바둑 프로그램과 인간 챔피언과의 총 5회에 걸친 대국에서 우리가 느낀 점은 인공지능 시대의 도래에 대한 큰 충격이었다. 하지만 그러한 시대는 갑자기 찾아온 것이 아니다. 이미 1950년, 앨런 튜링(Alan M. Turing)은 “Computing Machinery and Intelligence”라는 논문²⁾을 통해 생각할 수 있는 기계(Learning machine)를 제안하였다. 이후 다양한 분야의 많은 연구지들에 의해 기계학습(Machine learning)에 대한 연구가 지속되었고, 놀라운 속도의 컴퓨터 하드웨어(Hardware) 기술력의 진화를

토대로 더욱 발전되어왔다.

구글 딥마인드 챌린지 매치 이후, 대한민국 정부 산하 각 부처들은 제4차 산업혁명의 도래에 대한 대응책을 마련하기 위해 총력을 기울였고, 과학기술의 거의 모든 분야가 제4차 산업혁명이라는 큰 틀로 집결하는 듯 보였다. 제4차 산업혁명은 2016년 세계경제 포럼(World Economic Forum, WEF) 대회에서 주창된 용어로 정보통신기술(Information & Communication Technology, ICT)의 융합으로 이룬 시대를 뜻한다³⁾. 제4차 산업혁명의 핵심기술로 거론되는 것은 인공지능(Artificial intelligence), 로봇공학(Robotics), 사물인터넷(Internet of Things, IoT), 무인운송수단(Autonomous vehicles), 3D 프린터(3D printing), 나노기술(Nanotechnology), 생명공학(Biotechnology), 재료과학(Materials science), 에너지 저장(Energy storage), 양자 컴퓨팅(Quantum computing) 기술 등이다.

앞서 거론된 모든 핵심기술 중 건설 분야에 대한 언급이 없어 그 중요성이나 시급성이 떨어진다고 느끼지만 무언가 4차 산업혁명의 핵심기술을 도입

* 세종대학교 건축공학과 교수, 공학박사
Department of Architectural Engineering, Sejong University

** 세종대학교 건축공학과 조교수, 공학박사
Department of Architectural Engineering, Sejong University

해야 한다는 막연한 불안감에 휩싸이게 된다. 하지만 사람이 살아가는 필수 3대 요소인 의(衣), 식(食), 주(住) 중 한 가지인 건설 분야는 제4차 산업혁명의 핵심기술 거의 대부분과 연관되었다고 볼 수 있다. 특히 건축구조기술은 지금까지 컴퓨터를 통한 구조 해석과 수(數)를 다루는 것을 주로 해왔으며 인공지능과 접목하여 폭발적인 파급력을 미칠 수 있는 분야라고 할 수 있다. 또한 건물에 부착된 센서를 통해 얻을 수 있는 빅 데이터(Big data)들은 기계학습을 훈련시키기 위해 사용되어 추후 일어날 일에 대한 예측 및 대응에 큰 밑거름이 될 수 있다. 본 기사에서는 인공지능의 일환인 기계학습 혹은 딥러닝(Deep learning)에 대한 간략한 설명과 구조해석 분야에 적용할 수 있는 사례제시 등을 통해 딥러닝 기술의 진입장벽의 문을 낮추려 한다.

2. 정의

우리는 종종 인공지능과 기계학습, 딥러닝 이 3가지 용어를 혼용하여 사용한다. 인공지능의 용어는 1956년 다트머스 학회(Dartmouth conference)에서 존 매카시(Jhon McCarthy)에 의해 창안된 것으로, 인간의 학습 및 문제해결과 같은 일을 기계가 모방할 때 적용될 수 있다⁴⁾.

기계학습은 인공지능의 하위개념으로 학습을 할 수 있는 능력을 기계(Machine)에게 부여하는 컴퓨터과학의 분야라고 할 수 있으며, 여기서 기계란 프로그래밍 가능한 컴퓨터를 뜻한다. IBM의 연구원이었던 아서 사무엘(Arthur L. Samuel)이 발표한 논문⁵⁾에서 처음 사용된 용어인 기계학습은 예측에 초점을 둔 일종의 통계계산(Statistic computation)으로 수학적 최적화(Optimization)와 밀접한 관련이 있다.

딥러닝은 기계학습의 패러다임 중 하나에서 파생된 것으로 1958년 로젠블랫(Rosenblatt)⁶⁾이 제안하고 지속되어 온 퍼셉트론(Perceptron)의 최신버전이라 할 수 있다. 그동안 신경망(Neural network)

의 층(Layer) 수가 늘어날 때마다 겪었던 수렴의 어려움이나 데이터 양이 증가할 때 마주하는 컴퓨터 성능의 한계 등의 문제가 해결되면서 최근 인공지능 분야에서 가장 각광을 받고 있는 분야가 이 딥러닝 기술이라 할 수 있다. 딥러닝의 용어를 신경망 분야에서 처음 사용된 것은 2000년에 출간한 한 저서에서였다⁷⁾. 이 책에서는 “많은 연구들이 딥러닝을 통해 퍼셉트론의 'XOR'을 극복하려고 했다”고 언급했다. 보통 대부분의 정의에서는 신경망의 수가 대략 3개 이상인 것을 딥러닝, 즉 심층학습이라고 부른다. 하지만 정확하게 말하면 인공신경망(Artificial Neural Network, ANN)을 기계, 즉 프로그램이 가능한 컴퓨터 속에 만든 후 이 인공신경망을 통해 기계학습의 정확도를 끌어올리려는 새로운 기계학습 방법론을 딥러닝이라 할 수 있다⁸⁾. 2000년대 중반 이후 이러한 기계학습의 정확도를 높이기 위한 새로운 기법이 발표되면서 딥러닝의 기술력은 점점 무서운 속도로 발전하여왔으며, 결국 우리는 구글(Google)의 알파고(AlphaGo)를 마주하고 놀랄 수밖에 없었던 것이다.

3. 구조해석을 위한 기계학습

3.1 적용 가능한 주제

1980년대 이후 기계학습을 구조해석 분야에 적용하려는 다수의 노력이 있었다. 1989년, 공학설계에 적용 가능한 기계학습 모델에 관한 논문⁹⁾을 시점으로 다양한 구조해석 문제에 신경망 기법을 적용하려는 연구를 찾아볼 수 있다. 이러한 움직임은 다음과 같은 주제로 분류할 수 있다¹⁰⁾.

- Pattern recognition and machine learning in structural analysis and design
- Design automation and Optimization
- Structural system identification
- Structural condition assessment and monitoring

- Structural control
- Finite element mesh generation
- Structural material characterization and modeling
- Parallel neural network algorithms for large-scale problems

위의 나열된 주제들에서 알 수 있듯이 기계학습 기법은 거의 대부분의 구조해석 문제에 적용할 수 있다. 그 이유는 구조해석 문제들이 입력 값을 넣어 결과 값을 얻는 패턴을 보이는데서 찾아볼 수 있다. 외부하중 혹은 영향에 의해 구조물에 일어나는 변형 혹은 움직임을 알아내는 일반 구조해석 기법은 그 알고리즘의 복잡함에 따라 해석시간에 큰 차이를 보인다. 다수의 연구들이 그동안 다양한 기법을 통해 알고리즘의 해석시간 단축 및 결과의 정확도 증가를 위해 노력해왔다. 만일 입력 값과 결과 값이 일정한 패턴을 보인다면 이 연관관계를 기계학습에 적용하여 신경망을 구축할 수 있다. 이렇게 구축한 신경망을 통해 해석시간을 요하는 구조해석 알고리즘의 도움 없이 특정 입력 값에 대한 결과 값을 예측할 수 있는 것이다. 그렇게 좋은 것이라면 왜 기계학습 기법을 꾸준히 구조해석 문제에 도입하여 발전을 거듭한 뒤에 현 시점에서 그럴듯한 결과를 보이는 연구결과를 우리는 찾아볼 수 없는 것일까? 그 이유는 다음에서 찾아볼 수 있다.

3.2 인공지능의 겨울

인공지능 분야는 총 2번의 침체기를 겪는데 그 시기를 인공지능의 겨울(AI winter)이라한다¹¹⁾. 첫 번째 겨울은 1974년부터 1980년 동안의 시기로 로젠블랫이 제안한 퍼셉트론의 한계점을 지적한 한저서¹²⁾에서부터 비롯되었다. 이것을 계기로 인공지능에 대한 학계의 관심이 사라지기 시작했고 결과적으로 연구비 지원도 줄게 되었던 것이다. 하지만 이후 미국 국방성을 중심으로 시작된 인공지능 및 고급 컴퓨터 개발 프로젝트 지원 및 기타 이유로 인

해 첫 번째 겨울은 종식될 수 있었다.

하지만 또다시 1980년대 말부터 인공지능에 대한 관심과 연구비가 줄기 시작한 두 번째 겨울이 시작하였다. 이는 기계학습의 정확도가 크게 증가하지 못했다는 점과 이를 위해 인공신경망을 구축하기에는 컴퓨터 성능이 너무 열악했던 것이다. 앞서 기술한 다양한 구조해석 문제에 신경망 기법을 적용하려는 연구 움직임 또한 1990년대 후반 이후 자연스럽게 줄어들어 어느 순간 인공신경망 관련 논문이 찾기 힘들게 되었다. 하지만 이대로 포기하기 이른 새로운 움직임이 인공지능 분야에서 지속되고 있었다.

3.3 인공지능 분야의 새로운 기법

1986년, 역전파(Backpropagation) 알고리즘이 다층 신경망의 학습모델 방법으로 유용하게 쓰일 수 있다는 것을 실험적으로 증명한 중요한 논문¹³⁾이 발표되었다. 역전파는 인공신경망에서 데이터가 처리된 후 각 뉴런의 오류 기여도를 계산하는데 사용되는 알고리즘으로 이 때 경사감소법(Gradient descent method)을 사용하여 오류를 감소시킨다. 여기서 경사감소법은 에러(Error)의 최소평균제곱이라는 목적함수를 최적화하는 델타 룰을 기반으로 한다.

경사감소법이 함수의 최소값을 잘 찾아낸다면 좋겠지만 일반적인 문제의 손실(Loss) 함수는 매우 복잡하다. 따라서 다수의 신경망 학습과정, 즉 학습세대(Epoch)를 반복한다고 할 때 한 번의 학습으로 얼마만큼을 학습해야 하는지를 지정하는 학습률(Learning rate) 등의 매개변수 등이 필요하다. 결국 인공지능의 겨울에서 마주하였던 기계학습의 한계는 학습이 빠르고 정확하게 이루어지는가에 대한 문제였던 것이다.

2006년, 캐나다 토론토 대학에 재직 중이었던 제프리 힌튼(Geoffrey E. Hinton) 교수는 심층신뢰망(Deep belief nets)이라는 딥러닝에 매우 효과적인 알고리즘을 발표하였다¹⁴⁾. 이 논문이 인공지능의 부활에 기점이 된 논문이라는 점에 이견은 없다. 이후

2010년대에 들어서면서 인공지능에 효과적인 다양한 기법들이 발표되었는데, 딥러닝의 발전을 가속화 한 것은 ReLU(Rectified Linear Unit)이라는 활성화함수(Activation function)와 드롭아웃(Dropout) 기법이었다. 이처럼 혁신적인 알고리즘의 개발과 컴퓨터 하드웨어의 발전에 힘입어 인공지능 분야는 급속도로 발전하게 되었다. 하지만 여기서 주목할 것은 구조해석 분야의 움직임이다.

3.4 구조해석 분야의 과제

그동안 효과적인 기계학습 알고리즘의 부재로 신경망 학습모델의 정확도를 높이지 못했던 구조해석 분야의 모든 문제들은 이제 새로운 알고리즘의 도움으로 돌파구를 찾을 수 있다. 또한 처음 딥러닝 알고리즘을 도입하려는 연구자들은 일단 목표로 삼는 구조해석 문제의 패턴을 파악하여야 한다.

기계학습은 학습 데이터에 레이블(Label) 즉, 우리가 정의하는 정답이 있는 경우와 없는 경우에 따라 지도 학습(Supervised learning)과 비지도 학습(Unsupervised learning)으로 나눌 수 있다. 연구자들은 우선 학습 데이터가 필요하며(때에 따라 학습 데이터가 존재하지 않는 경우도 있다), 해결하려는 문제의 패턴이 지도 학습인지 비지도 학습인지, 또는 각 학습의 경우에도 어떤 문제 유형인지를 파악하여야 한다. 다음 장에서는 기계학습의 분류에 따라 대응할 수 있는 구조해석 문제의 유형들을 제시해 보기로 한다.

4. 구조해석을 위한 학습의 패턴

4.1 지도 학습

지도 학습은 정답을 알고 있는 데이터를 이용해 기계를 학습시킨다. 기계는 자신이 낸 답과 정답과의 차이를 통해 지속적으로 학습을 하게 된다. 지도 학습은 분류(Classification)와 예측(Prediction) 모델로 나눌 수 있다. 분류 모델은 레이블의 값이 그룹명이 되며, 최종적으로 구축된 학습모델을 통

해 입력 값이 고정되어있는 그룹명 중 1개에 속한다는 결과를 얻을 수 있다. 예측은 이와 다르게 그 결과 값이 범위 내 어떠한 값도 가능하다. 예측의 결과는 데이터 세트를 통해 얻은 함수식(회귀식)으로 계산한 임의의 값이다. 예측에서는 대표적인 것이 회귀(Regression) 모델이며, 따라서 예측 모델을 회귀 모델로 부르기도 한다.

회귀 모델은 구조해석 문제에 전반적으로 사용할 수 있다. 구조물의 특성 값(Property)과 외부 하중 등이 입력 값이고 그 응답, 즉 처짐과 응력 등을 결과 값으로 대응하는 데이터 세트를 보유하였다면 회귀 모델을 훈련시킬 수 있다. 잘 훈련된 회귀 모델은 추후 구조해석 프로그램의 도움 없이 입력 값에 대한 결과 값을 예측할 수 있다. 이는 시스템 식별(System identification) 문제나 선형(Linear) 혹은 비선형(Non-linear) 문제 등에 다양하게 적용할 수 있다.

이에 비하여 분류 모델은 특정 그룹으로 분류되어 있는 데이터 세트를 통해 모델을 훈련시키며 추후 어떤 입력 값이 고정된 그룹 중 어디에 속하는지를 결과 값으로 얻는 문제에 적용할 수 있다. 예를 들어 위상최적화(Topology optimization) 문제에서 잘게 나눈 요소가 일정 값 이하가 되면 유효한 값이 아니라고 분류해내고 이를 통해 노이즈(Noise)를 걸러낼 수 있는 알고리즘을 구축할 수 있다. 또한 특성 값을 통해 구조재료를 분류하는 문제나 적합한 구조부재를 분류하는 문제에도 분류 모델을 사용할 수 있다. 결국 이 모든 문제가 레이블이 잘 달린 다량의 유효한 데이터 세트를 보유하는 것이 선행되어야 하며, 다량의 데이터 세트는 학습의 오류를 줄일 수 있는 바탕이 되는 것이다.

4.2 비지도 학습

레이블 없이 주어진 데이터 세트를 사용하는 비지도 학습은 대표적으로 군집화(Clustering)가 이에 해당한다. 비슷한 성향의 결과 값끼리 묶거나 특성에 따라 데이터 세트를 나누는 것을 군집화라 한

다. 군집 모델은 학습 데이터가 레이블을 가지고 있지 않으므로 어떤 형태로 그룹을 나누는가가 핵심이다. 군집 문제는 일상생활에서 다양하게 찾아볼 수 있는데, 통화음질 개선을 위해 노이즈와 사람의 음성을 구분해내는 문제, 의학 분야에서 질병군과 환자군을 구별하는 문제, 또는 영업을 위해 고객을 세분화 하는 문제를 예로 들 수 있다.

구조해석 단계에서 레이블을 가지고 있지 않은 데이터를 다량으로 보유하고 있다면 비지도 학습의 군집 모델로 이를 해결할 수 있다. 앞서 언급한 구조물의 센서에서 얻은 다량의 빅데이터는 이러한 데이터 세트에 사용할 수 있으며, 군집 모델을 통해 설계자의 목적에 맞게 데이터를 분류할 수 있다. 이는 지도 학습의 분류의 형태와 유사하며, 레이블의 유무에 따라 지도 학습의 분류 학습과 비지도 학습의 군집 모델 중 하나를 선택하면 된다.

군집 모델은 특성(Feature)에 따라 데이터를 분류하는 것이 관건이며, 특성의 적절한 선정은 기계 학습의 정확성 및 효율성을 좌우한다. 그렇다면 앞서 예시로 제시한 구조물의 빅데이터는 특성 값을 어떻게 설정할지를 결정하는 것이 선행되어야 하며 학습의 성과를 좌우하는 것이다. 구조해석 분야에서 데이터를 군집화 하는 형태는 다양하게 접근할 수 있으며, 결국 지도 학습과 마찬가지로 유효한 데이터 세트의 보유와 동시에 특성 값의 설정이라는 문제가 제일 중요하고 시급하다 할 수 있다.

4.3 강화 학습

기계학습은 위의 지도 학습과 비지도 학습 이외에 강화 학습(Reinforcement learning)이라는 또 하나의 모델을 정의할 수 있다. 강화 학습은 행동심리학의 ‘시행착오’를 기계학습에 적용한 것으로 모든 행동에 대한 보상과 벌칙을 기억해서 최선의 결정을 내리도록 학습하는 것이다. 강화 학습의 최대 장점은 환경에 대한 사전지식이 없어도 학습한다는 것이다. 강화 학습을 통해 스스로 학습하는 컴퓨터를 에이전트(Agent)라고 하며, 이 에이전트는 시행

착오를 통해 특정한 기능을 학습한다. 따라서 강화 학습은 결정을 순차적으로 내려야 하는 문제에 적용될 수 있다. 강화 학습 문제를 해결하기 위해서는 벨만 방정식(Bellman equation)이 필요하며 최적화와 관련된 다이내믹 프로그래밍(Dynamic programming)¹⁵⁾으로 그 방정식을 풀 수 있다.

강화 학습은 최적화(Structural optimization) 문제에 적용하기에 적합하다. 건설 산업 전반에 산재한 최적화 문제들은 보상과 벌칙을 기억해서 최선의 결정을 내리도록 유도하는 강화 학습의 맥락과 일맥상통한다. 기본적인 구조 최적화 문제부터 설계 자동화 문제까지 광범위하게 적용할 수 있으며, 실제로 구글의 알파고는 이 강화 학습을 토대로 학습한 결과물로 방대한 상태를 가진 문제에서 뛰어난 성능을 입증하였다.

5. 결론

제4차 산업혁명의 큰 흐름 앞에서 건설 분야의 연구자들은 전공 지식의 한계로 인하여 딥러닝 기술을 도입하려는 시도를 쉽게 결정하지 못하고 있다. 하지만 막상 그 뚜껑을 열어보면 데이터 세트를 다루는 컴퓨터 공학 기술이 구조해석에서 다루는 기술의 맥락과 상통한다는 것을 알게 될 것이고 처음의 진입장벽만 통과한다면 그 뒤로는 아주 쉽게 접근할 수 있게 된다. 이를 위해서 초기에 많은 공부와 필요하며 딥러닝 해석을 위해 갖추어야 하든 웨어적인 요소도 있을 것이다. 제4차 산업혁명의 흐름에 대한 발 빠른 대처야 말로 건설 분야에서 가장 시급한 과제이며 인공지능과 구조해석 분야의 협업의 파급력 있는 결과를 우리는 가까운 미래에 마주할 수 있을 것이다.

References

1. https://en.wikipedia.org/wiki/AlphaGo_versus_Lee_Sedol
2. Turing, A. M., "Computing machinery and

- intelligence”, *Mind*, 59(236), pp.433–460, 1950
3. Schwab, Klaus., “The Fourth Industrial Revolution: what it means, how to respond”, *World Economic Forum*, 2016
 4. Russell, S. (2009). *Artificial intelligence: A modern approach* author: Stuart russell, peter norvig, publisher: Prentice hall pa.
 5. Samuel, A. L., “Some studies in machine learning using the game of checkers. II—recent progress”, *IBM Journal of research and development*, 11(6), pp.601–617, 1967
 6. Rosenblatt, F., “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychological review*, 65(6), pp.386, 1958
 7. Aizenberg, I., Aizenberg, N. N., & Vandewalle, J. P., “Multi-Valued and Universal Binary Neurons: Theory, Learning and Applications”, *Springer Science & Business Media*, 2013
 8. <http://it.donga.com/26447/>
 9. Adeli, H., & Yeh, C., “Perceptron learning in engineering design”. *Computer-Aided Civil and Infrastructure Engineering*, 4(4), pp. 247–256, 1989
 10. Adeli, H., “Neural networks in civil engineering: 1989–2000”, *Computer-Aided Civil and Infrastructure Engineering*, 16(2), pp. 126–142, 2001
 11. https://en.wikipedia.org/wiki/AI_winter
 12. Minsky, M., & Papert, S., “Perceptrons”, 1969
 13. Williams, D. R. G. H. R., & Hinton, G., “Learning representations by back-propagating errors”, *Nature*, 323(6088), pp.533–538, 1986
 14. Hinton, G. E., Osindero, S., & Teh, Y. W., “A fast learning algorithm for deep belief nets”, *Neural computation*, 18(7), pp. 1527–1554, 2006
 15. Bellman, R., “Dynamic programming”, *Courier Corporation*, 2013