

# 인공지능 홍수에서 살아남기 Surviving the Flood of Artificial Intelligence

2016년 우리 시대 최고의 프로 바둑 기사인 이세돌과 구글 딥마인드가 개발한 인공지능 바둑 프로그램인 알파고(AlphaGo)의 대결 이후로 인공지능이나 Deep Learning이라는 키워드는 초등학교도 알게 되었다. 필자도 자못 정신적 충격을 받았다(그림 1 참조). “내가 벌써 세상의 발전에 뒤쳐지는 것이 아닌가”라는 갑작스러운 위기감을 느꼈다. 당시 KAIST 기계공학과 교직원 워크숍에서도 인공지능에 대한 진지한 토론이 벌어졌었다. 인공지능은 그냥 지나가는 시류의 하나일 뿐이라는 주장과 인공지능을 놓치면 기계공학이 무너질 수 있다고 생각하는 주장이 서로 엇갈렸다. 그 때는 도무지 답을 알 수 없었지만, 이제는 해답을 낼 수 있는 시간이 도래했다고 생각한다.

당시 KAIST 전산과와 전자과에서 인공지능에 대한 각종 수업을 빠르게 준비하였고 엄청나게 많은 학생들이 수업을 통해 인공지능을 접하게 되었다. KAIST에서는 학부 신입생들이 학과를 선택하지 않고 무학과로 입학하게 되고, 2학년 쯤에 학과를 선택한다. 알파고 충격 이후로 무학과 학생들의 학과 선택에 극심한 쏠림 현상이 생겨, 전체 무학과생들 중에 2/3가 전산과와 전자과를 선택하게 되었다. KAIST내 나머지 학과들은 전체 파이의 1/3로 연명하고 있다. 기계공학 덕후들만 기계공학과를 선택하는 참사가 지금까지도 지속되고 있다.



이 필 승

KAIST 기계공학과 교수



그림 1 구글 알파고와 경기에서 첫수를 두고 있는 이세돌 [동아사이언스 2016]


본 글에서 필자는 이 사태에 어떻게 대처해 왔는지 적어 보고자 한다. 2018년 초 인공지능에 대해 별로 아는 바 없었던 상태에서 한수원 과제로 양수터빈의 이상진단에 대한 연구를 덧석 수행하게 되었다. 학생 2명(현철규, 신소진)과 함께 과제를 하였는데 데이터를 얻는데 어려움이 있었지만 Deep Learning을 이용하여 만족스러운 결과를 얻게 되었다. “어! 이것 별거 아니네”하는 나름대로의 자신이 생기는 계기가 되었다. 당시 두 학생은 인공지능 수업을 수강하였고 필자는 유튜브 강의를 통하여 기본 개념을 빠르게 익혔다.

필자의 주 연구분야는 유한요소법(Finite Element Method)인데 인공지능이 유한요소법 연구에 적용될 수 있지 않을까 하는 기대를 품고 있었다. 마침 원자력연구원에 다니는 정재호 연구원이 파트타임 박사과정으로 연구실에 들어오게 되었고 이 학생과 함께 막연한 연구를 시작하게 되었다. 정재호 연구원은 놀라운 능력의 보유자였다. 우리가


가지고 있었던 어렵풋한 아이디어를 매우 빠르게 구체화시켰다. 맨 처음 도전한 주제는 FEM의 계산 방식을 신경망으로 표현하는 일이었고, 생각보다 쉽게 완성이 되었다. 선형 및 비선형 해석을 신경망을 이용하여 수행할 수 있었다. 그러나 행렬기반의 기존 방법에 비하여 속도가 느리다는 단점을 극복할 수 없었다. 이후 비선형 해석을 학습하여 빠르게 해를 얻는 연구를 하였으나 많은 수의 신뢰할 만한 데이터를 얻기가 무척 힘들었다. 이 때 얻은 교훈 중 하나는 FEM은 엄청나게 잘 설계된 수치해석기법이라는 사실이었다.

이후 절치부심 끝에 유한요소의 강성행렬의 계산에 Deep Learning을 활용해 보고자 도전하였다. 물론 기존 방법에서 얻어진 강성행렬보다 더 정확한 해를 계산해 주어야 하고 계산 시간도 빨라야 한다. 이 연구의 핵심은 보다 정확한 해를 계산해 줄 수 있는 Reference Model을 만드는 것이었다. 요소 하나의 도메인을 많은 수의 요소로 모


Step 1. Data generation



Step 2. Network Training



Step 3. B-matrix generation



Step 4. Elemental K-matrix generation




그림 2 Construction of the neural network for deep learned finite elements




그림 3 Cook's skew beam problem ( $E = 1.0$ ,  $\nu = 1/3$ , thickness = 1.0)

델링하여 Reference Model을 만들고 이를 이용하여 임의의 모양에 대하여 변형률을 학습시켰다. 4절점 및 8절점 Deep Learned Finite Element (DLFE)를 만들어 냈다. 그림 2는 DLFE를 만들어 내는 과정을 보여준다. 특히, 8절점 요소는 현존하는 8절점 및 9절점 요소들 보다 월등히 정확한 결과를 도출해 냈다. 그러나 더 널리 쓰여지는 4절점 요소의 성능은 기대에 미치지 못했다. 그림 3에 보이는 2D 문제를 메쉬를 바꾸어 가며 해를 구하고 수렴정도를 그래프로 나타낸 것이 그림 4이다. 그래프가 아래쪽에 위치할수록 더 좋은 수렴성을 가지는 유한요소이다.

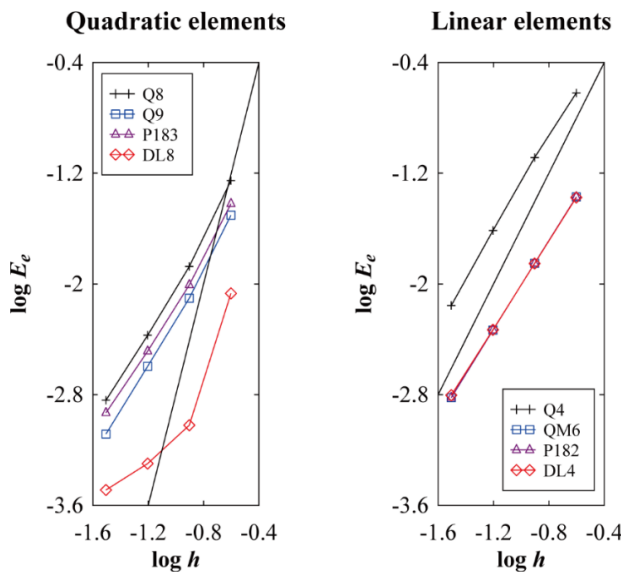


그림 4 Convergence curves in the Cook's skew beam problem

우리는 다음 연구로 4절점 요소의 성능 개선에 초점을 맞추기로 했다. 이전 방법과는 완전히 다른 아이디어를 만들어 내었다. 4절점 요소의 성능을 하락시키는 가장 큰 원인은 전단잠김(Shear Locking) 현상이다. 전단잠김은 4절점 요소가 휨거동을 할 때 생기는데, 휨의 방향의 경우는 셀 수없이 많다. 만일 휨의 방향을 알 수 있다면, 그 휨에 대응하는 전단 변형률을 제어하여 잠김현상을 해결할 수 있다. 해석하기 전에는 휨의 방향을 알 수 없으므로 우리는 그림 5와 같은 반복해석법을 설계하였다. 첫 해석에서 얻은 변위 모드를 분석하여 요소별로 휨 방향을 찾아내고 여기에 맞추어 전단 변형률을 제어하였다. 원래 선형 정적 FEM 해석은 1회의 연산으로 끝나지만 새로 고안한 방법은 몇번의 연산을 더하게 되는데, 단 1회 더 연산하는 것만으로 해의 정확성이 극적으로 높아지게 되었다.

이 방법의 단점은 요소별 휨 방향을 찾기 위해서 최적화 문제를 풀어야 하고, 이를 위한 계산 시간이 상당히 소요된다. 우리는 이 부분을 Deep Learning을 통하여 해결하였다. 미리 다양한 모양의 4절점 요소에 대하여 다양하게 가해지는 변위를 고려하여 최적화 문제를 풀고, Deep

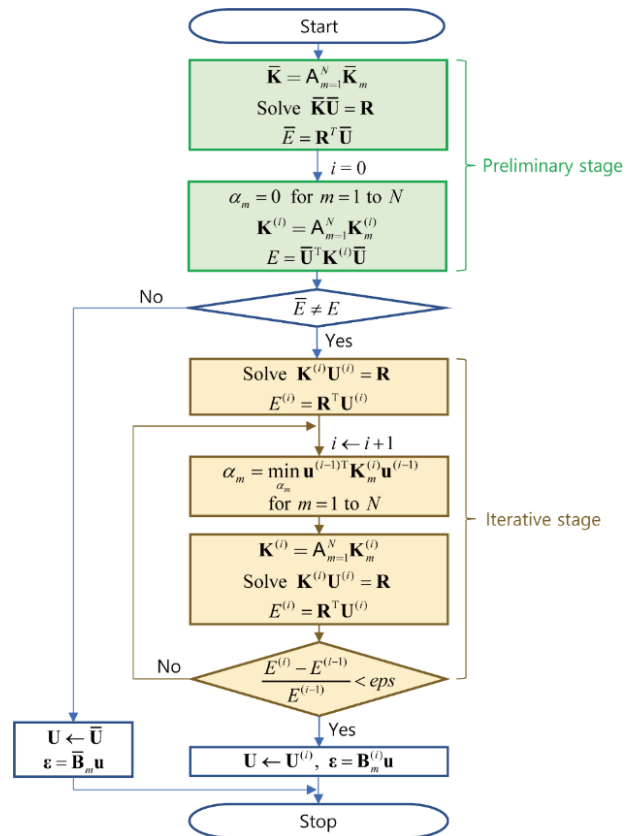


그림 5 Iterative solution procedure for SUFE

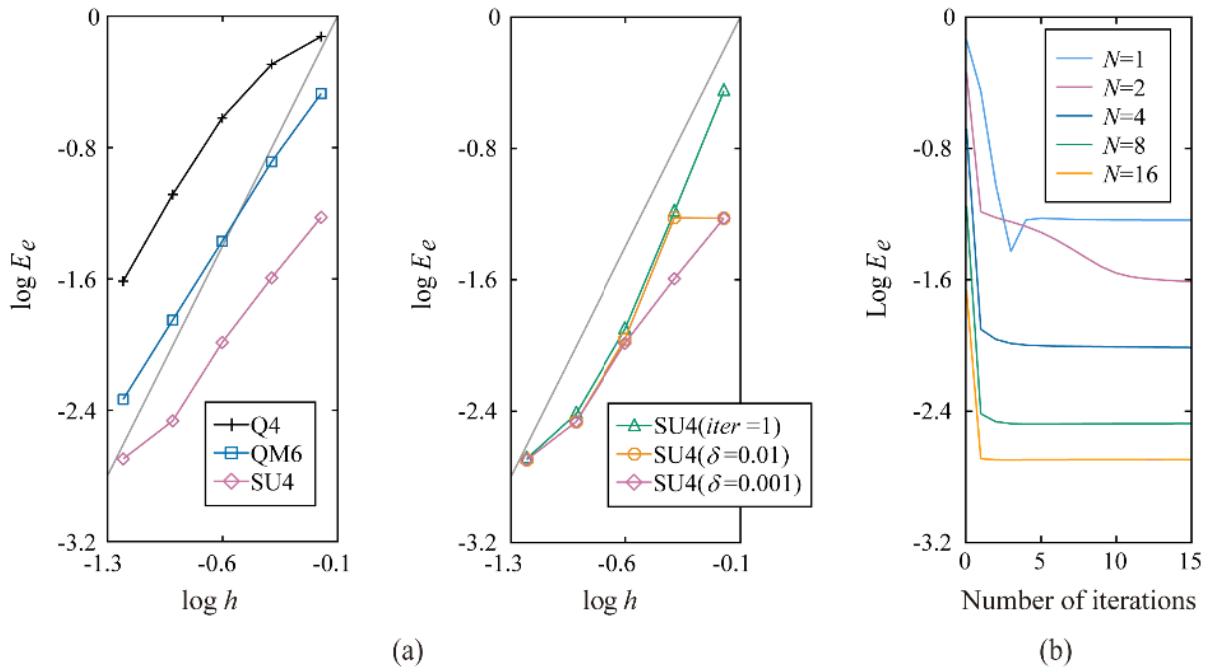


그림 6 Performance of SUFE in the Cook's skew beam problem

Learning을 통하여 신경망을 만들었다. 만들어진 신경망을 이용하면 아주 빠르게 요소별 휨 방향을 찾을 수 있었다. 그림 6은 이렇게 만들어진 SU4(Self-Updated 4-node Element)의 수렴 성능이 매우 우수하다는 것을 보여준다. 그림 7은 SU4가 몇 개 안되는 요소로 거의 정확해를 계산해 낸다는 사실을 보여준다. 필자는 이런 기술을 빔, 판, 셸 등 다양한 유한요소해 적용하고자 연구하고 있다.

2년 여전 어느 날 한국타이어에서 연락이 왔다. 타이어 생산공정에 사용되는 소모성 부품의 수명을 인공지능을 이용하여 예측하는 연구를 해보자는 제안이었다. 타이어가 어떻게 생산되는지도 모르는 상황에서 타이어 공장을 몇 차례 견학하면서 공정을 하나하나 관찰하였다. 내가 상상하고 있던 것 이상으로 공장은 자동화되어 있었고 모든 것이 신기하고 재미있었다. 한국타이어는 관련 데이터를 수 백만개 축적하고 있었지만 우리가 다루어야 하는 타이어의 종류가 수 천개이고 설비의 유형과 공정변수 또한 상당히 많아서 부품의 수명예측은 상당히 도전적인 일이었다. 한국타이어 연구원들과 하나의 팀이 되어 관련 데이터를 분석하고 변수의 개수를 줄여 나갔다. 중국에는 꽤 잘 작동하는 신경망을 구축하였고 한국타이어 공장의 라인에 개발된 수명예측 시스템을 도입하게 되었다. 동시에 한국타이어 설비의 최적 셋팅 값들을 자동으로 추천해 주는 시스템도 Deep Learning을 통해 성공적으로 구축해 주었다.

인공지능을 여기저기 적용해 보면서 느낀 점이 많다. 첫째, 인공지능은 기존 기술을 확장하는데 꽤 효과적인 역할을 한다는 것이다. 우리가 이미 잘 알고 있는 Domain Knowledge에 접목하여 새로운 결과들을 기대할 수 있다. 둘째, 인공지능이 요술방망이는 아니라는 점이다. 이미 기존 기술들로 잘 해결이 되는 문제들에 적용하는 것은 별달리 장점이 없다. 충분한 Domain Knowledge가 있어야만 성공적으로 적용될 수 있다. 셋째, 공학자들이 50년 전에 FORTRAN을, 20년 전에는 MATLAB을 기본 도구로 익혀야 했던 것처럼 인공지능도 이제는 기본 도구가 되었다.

몇 일전 박사과정 입시 면접을 하면서 KAIST 기계공학과에 재학중인 수십명의 석사과정 학생들의 연구 토픽을 접할 수 있었다. KAIST 기계공학과에 50개가 넘는 연구실이 있는데 다들 서로 다른 연구를 한다. 거의 모든 연구실이 Deep Learning 정도는 기본적으로 어렵지 않게 연구에 적용하고 있다는 사실을 알게 되었다. 인공지능이나 Deep Learning이라는 것은 2016년에는 많은 사람들에게 나름 정신적인 충격을 주었지만, 5년이 지난 2021년에는 너무나 대중적인 기술이 된 것이다. 이는 KAIST에서 뿐만은 아닐 것이다. 이제 인공지능의 과잉이 느껴질 정도이다. 필자는 나름 이런 인공지능의 홍수에 살아 남았다고 위안하고 있다.

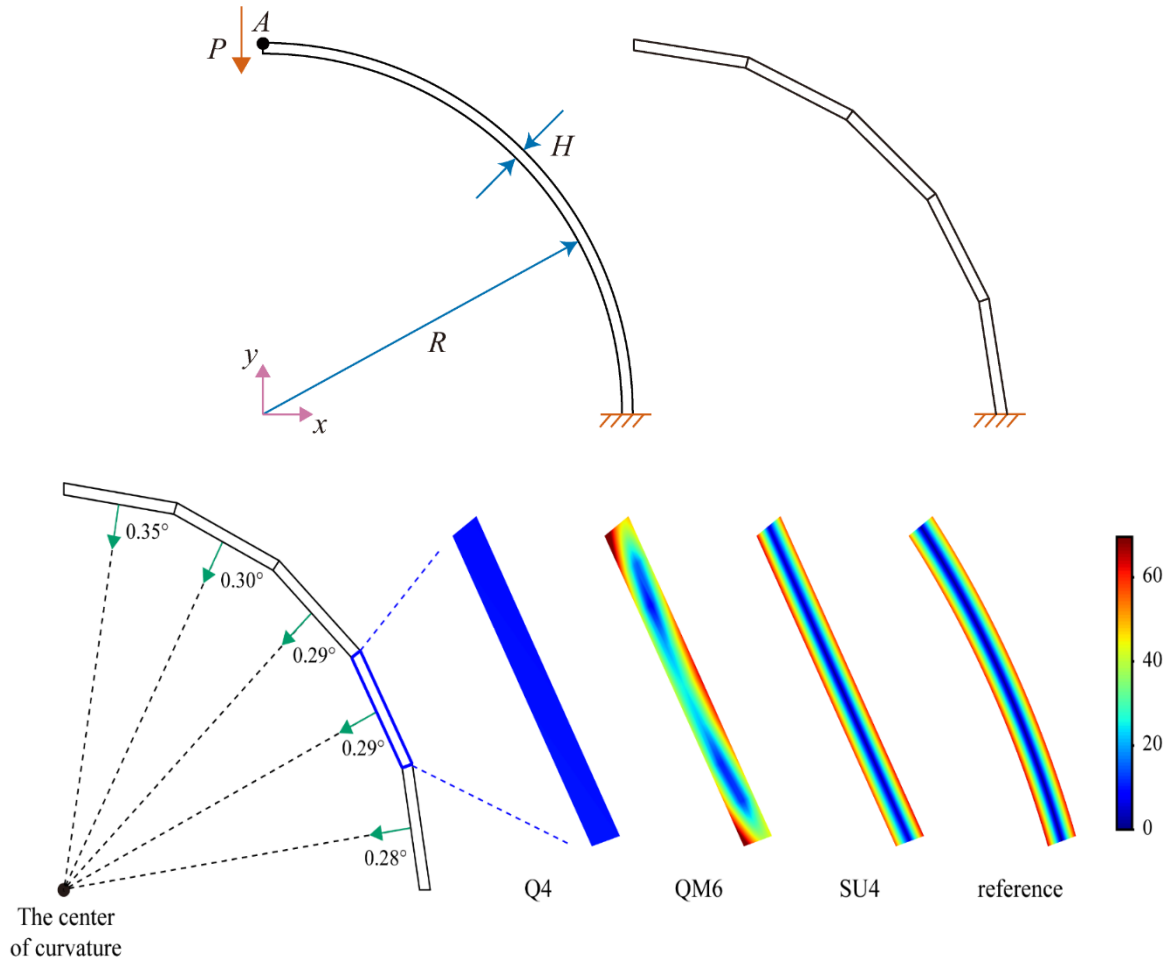


그림 7 Calculated stress distributions in the curved beam problem

“인공지능은 그냥 지나가는 시류의 하나일 뿐일까? 인공지능을 소홀히 하면 기계공학이 무너질까?” 라는 물음에 대해 필자의 답변을 말하고자 한다. 수학과 역학이 공학이 주요한 도구인 것처럼 인공지능 또한 우리의 새로운 도구일 뿐이다. 공학의 본질은 변하지 않을 것이며 인공지능의 시대에도 기존의 기계공학은 무너지지 않는다. 수학과 역학 또한 기존의 자리를 내려 놓지는 않을 것이다. 인공지능의 기술들은 그냥 누구나 쉽게 배우고 유용하게 쓰면 되는 것이다. 숟가락과 젓가락을 쓰는 우리 밥상에 포크가 하나 더 올라온 것이다.

## 참고문헌

1. PS Lee, Development, success and vision in FEM (FEM의 발전, 성공과 비전), 한국전산구조공학회 학회지 Vol. 33 No.2,

2020.

2. 동아사이언스 2016, <https://www.dongascience.com/news.php?idx=10919>
3. Jung J, Yoon K, Lee PS. Deep learned finite elements, Computer Methods in Applied Mechanics and Engineering, Volume 372, 113401. 2020.
4. Jung J, Jung H, Lee PS. Self-updated four-node finite element using deep learning, Computational Mechanics. 2021.
5. Ko Y, Lee PS, Bathe KJ. A new 4-node MITC element for analysis of two-dimensional solids and its formulation in a shell element, Computers & Structures, 192: 34-49. 2017.
6. Lee C, Lee PS. A new strain smoothing method for triangular and tetrahedral finite elements, Computer Methods in Applied Mechanics and Engineering, 341: 939-955. 2018.
7. Kim S, Lee PS. A new enriched 4-node 2D solid finite element free from the linear dependence problem, Computers

- & Structures, 202: 25-43. 2018.
8. Ko Y, Lee PS. A 6-node triangular solid-shell element for linear and nonlinear analysis, International Journal for Numerical Methods and Engineering, 111: 1203-1230. 2017.
  9. Lee Y, Lee PS, Bathe KJ. The MITC3+ shell finite element and its performance. Computers & Structures, 138, 12-23. 2014.
  10. Lee C, Lee PS. The strain-smoothed MITC3+ shell element. Computers & Structures, 223, 106096. 2019.
  11. Lee C, Lee PS. A new strain smoothing method for triangular and tetrahedron finite elements. Computer Methods in Applied Mechanics and Engineering, 341, 939-955. 2018.
  12. Lee Y, Jeon HM, Lee PS, Bathe KJ. The modal behavior of the MITC3+ triangular shell element. Computers & Structures, 153, 148-164, 2015.
  13. Yoon K, Lee PS. Nonlinear performance of continuum mechanics based beam elements focusing on large twisting behaviors. Computer Methods in Applied Mechanics and Engineering, 281, 106-130, 2014.
  14. Yoon K, Lee PS. Modeling the warping displacement fields for discontinuously varying arbitrary cross-section beams. Computers & Structures, 131, 56-69, Jan 2014.
  15. Shin S, Lee S, Hyun C, Kim JY, Lee PS. Lifetime prediction of bladder for tire curing using deep learning (딥러닝을 이용한 타이어용 가류 브라다의 수명 예측). COSEIK 2021 학술 심포지움. 2021.
  16. Kim Y, Lee PS. Prediction of sea condition in southwest Jeju sea using machine learning (파랑장 스냅샷을 이용한 기계 학습을 통한 해상상태 예측). COSEIK 2021 학술 심포지움. 2021.
  17. Lee S, Hyun C, Shin S, Yoon J, Lee PS. Automatic setting of process parameters using deep learning (딥러닝을 이용한 공정 변수 자동 설정). COSEIK 2021 학술 심포지움. 2021.
  18. Shin S, Lee PS. An internal crack detection method using machine learning algorithm. 2019 World Congress on Advances in Structural Engineering and Mechanics (ASEM2019). 2019. 