


속가속도계 (6)
속가속도계 (1)
항풍속계 (1)
항변위계 (1)



이 글에서는 다량의 위상최적 설계안을 병렬적으로 생성해 내는 제너레이티브 디자인과, 과거 데이터를 학습하여 새로운 설계안을 생성해 내는 딥러닝의 생성 모델을 소개한다. 또한 두 기술을 결합한 인공지능 기반 설계 자동화 연구의 사례를 소개한다.

인공지능과 최적설계

인공지능이 4차 산업혁명의 핵심동력으로 떠오르면서, 최근 기계공학 분야에서도 딥러닝을 접목한 연구들이 급증하고 있다. 역학을 바탕으로 해결해 오던 복잡한 기계공학적인 문제들을 데이터 기반으로 더 효율적으로 해결할 수 있음을 보여주고 있다. 특히 최적 설계 분야는 딥러닝과 동일하게 확률 및 최적화 이론을 바탕으로 하기 때문에 타분야에 비해 딥러닝의 접목이 매우 자연스럽다. 최적설계와 딥러닝의 결합에 대한 연구는 위상 최적화, 파라메트릭 디자인, CAE(Computer-aided Engineering) 시뮬레이션, 대리 모델, 재료 설계, 설계 선호도 모델링, 제너레이티브 디자인(Generative Design) 등 다양한 세부 영역을 중심으로 활발하게 진행되고 있다.

이러한 최적설계 연구들은 결국 “인공지능이 사람을 대신해서 설계를 할 수 있을까?”라는 궁극적인 질문에 도달하게 된다. 사람이 생각하지 못했던 새로운 설계 대안들을 인공지능이 자동으로 생성해 주고, 사람은 이 중에서 원하는 설계안을 선택해서 사용한다면 어떨까? 이러한 질문의 해답을 줄 것으로 가장 기대되는 최적설계 방법론 중 하나가 제너레이티브 디

제너레이티브 디자인의 핵심은 위상최적화 문제 정의를 다양화하는 것이다.

자인이다. 제너레이티브 디자인은 설계자가 설계 목적과 제약 조건의 종류와 레벨을 정의해 주면, 수천, 수만 가지의 위상최적 설계안들을 클라우드 컴퓨팅을 이용하여 병렬적으로 생성해 주는 기술이다. 최근 딥러닝의 생성 모델과의 결합을 통해 인공지능 기반의 설계 자동화 기술로서 발전 가능성이 높아지고 있다.

제너레이티브 디자인

전통적인 제너레이티브 디자인은 다양한 설계 탐색(design exploration) 방법론 중의 하나로서, 설계 지오메트리를 파라미터화하고 이를 변화시킴으로써 새로운 설계안들을 생성하고 평가하는 방법이며, 파라메트릭 디자인의 개념과 유사했다. 하지만 최근 제너레이티브 디자인은 다양한 위상최적화 설계안들을 클라우드 컴퓨팅 파워를 이용하여 병렬적으로 생성하는 기술을 지칭하고 있다. 현재 Autodesk에서 해당 컨셉트와 기술에 대한 제품화를 리드하고 있으며, 자동차, 건축, 가구, 비행기 등 다양한 구조 설계 분야에서 적용 예시들이 소개되고 있다.(그림 1)

제너레이티브 디자인은 위상최적설계 및 파라메트

표 1 제너레이티브 디자인과 유사 방법론들과의 차이

| 목적 | 제너레이티브 디자인 새로운 설계안 탐색 | 위상최적화 최적 설계안 도출 | 파라메트릭 디자인 새로운 설계안 탐색 |
|----|---|---|---|
| 방법 | 위상 최적화 문제 정의의 파라미터값을 다양화하여, 다량의 문제정의에 대한 다량의 구조 설계안들을 생성함 | 하나의 위상 최적화 문제 정의에 대한 하나의 최적 구조 설계안을 생성함 | 설계 지오메트리의 파라미터값을 다양화하여 다량의 구조 설계안들을 생성함 |



그림 1 제너레이티브 디자인 예시: 휠체어의 경량화 프레임 설계를 위해 제너레이티브 디자인으로 다량의 설계안을 병렬 생성한 후 선택하여 적용함(www.autodesk.com).

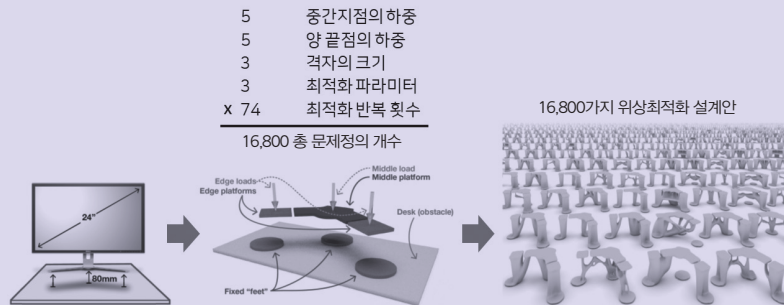


그림 2 제너레이티브 디자인의 문제 정의의 다양화 예시(Matejka et al., 2018)

릭 디자인과 밀접한 관계가 있기 때문에 이들과의 차이점을 정확하게 이해하는 것이 중요하다(표 1). 위상 최적화는 설계자가 목적함수와 하중 및 경계조건을 정의하면, 설계 가능 영역 안에서 최적의 재료 분배를 통해 최적화된 구조 설계안을 생성하는 방법이다. 설계 문제를 정의할 때, 목적함수는 보통 유연도 (compliance) 최소화로 하며, 하중 및 경계조건이 하

나로 주어지기 때문에 하나의 최적 설계안이 나오게 된다. 하지만 제너레이티브 디자인의 핵심은 문제 정의 자체를 변화시키면서, 다양한 문제 정의에 대해 각각의 최적 설계안을 생성하는 것이다.

구체적인 예를 들어보자. 그림 2와 같이 모니터 받침대를 설계할 때, 받침대 위치별로 작용하는 하중의 크기, 설계영역을 구성하는 격자의 크기, 최적화 알고리즘에 사용되는 파라미터와 반복 횟수를 불연속적인 레벨값으로 분할하고 모든 가능한 조합을 만들게 되면, 1만 6,800개의 다른 설계 문제를 정의할 수 있다. 그리고 각각의 문제에 대해 위상최적화를 병렬적으로 수행하게 되면 1만 6,800개에 해당하는 최적 설계안을 동시에 얻을 수 있게 된다. 이러한 제너레이티브 디자인의 전체적인 프로세스는 4단계로 정리할 수 있다.

- Step 1: 문제 정의를 다양화할 수 있는 속성의 종류와 레벨들을 정의한다.
- Step 2: 문제 정의의 조합에 따라 각각의 위상최적 설계안들을 생성한다.
- Step 3: 생성된 설계안들을 여러 가지 기준으로 평가하고, 가장 좋은 설계안을 선택한다.
- Step 4: 선택된 설계안을 3D 프린터로 출력하고 평가한다.

특히 3D 프린팅 기술의 발전으로 인해 위상최적화로 인한 복잡한 형상의 구조 결과물의 생산이 가능해

지면서 제너레이티브 디자인의 전망을 더 밝게 하고 있다. 하지만 제너레이티브 디자인에도 해결해야 할 이슈들이 많이 남아있다. 우선, 위상최적화를 넘어서 딥러닝과 같은 인공지능 기술과의 결합을 통한 데이터 기반의 설계 자동화로 나아가야 한다. 둘째, 시장을 위한 심미성을 고려한 설계안 생성이 필요하다. 공학적 목적함수만을 가진 위상최적화 결과물은 사람이 심미성을 고려해 설계한 결과들과는 차이가 크다. 셋째, 설계안의 다양성을 높여야 한다. 양적으로는 무한개의 설계안을 생성할 수 있지만, 의미 있게 다른 설계안들은 적은 경우가 발생한다. 넷째, 다량의 생성된 설계안 중에서 적절한 설계안을 설계자에게 추천하는 방법이 필요하다. 다섯째, 문제정의 다양화를 위한 체계적인 방법이 필요하다.

제너레이티브 디자인과 딥러닝의 생성 모델(Generative Models)은 서로의 단점을 보완할 수 있다.

이 빠르게 쏟아져 나오고 있다. GAN은 생성기(Generator)와 판별기(Discriminator)의 적대적인 네트워크로 구성되며, 생성기는 판별기를 속이기 위한 가짜 이미지를 만들어 내도록 학습하고, 판별기는 생성기가 만든 가짜 이미지와 진짜 이미지를 구분할 수 있도록 학습한다. 판별기가 더 이상 진짜와 가짜를 구분할 수 없을 만큼 생성기가 학습을 하게 되면, 생성기를 통해 기존 데이터에 없었던 새로운 이미지들을 무한으로 생성해 낼 수 있게 된다.

그림 3은 GAN의 한 종류인 BEGAN(Boundary Equilibrium GAN)을 차량휠 설계에 활용한 예시를 보여준다. BEGAN의 경우 판별기를 인코더와 디코더로 구성된 오토인코더(Autoencoder)를 사용한다. 생성기는 판별기의 디코더와 동일한 네트워크를 사용하며, 컨볼루션(Convolution) 레이어, 업샘플링(Up-sampling) 레이어, 풀리 커넥티드(Fully connected) 레이어를 통해 잠재변수 z 로부터 새로운

딥러닝의 생성 모델

생성 모델은 설계 탐색 방법으로서의 활용 가능성이 가장 높은 딥러닝 기술이다. 생성 모델은 실제 데이터의 확률분포를 학습한 후에 학습된 확률 분포에서 새로운 데이터를 추출해 생성해 내는 것을 목적으로 한다. 생성 모델의 대표적인 모델 들로는 VAE(Variational Autoencoder)와 GAN(Generative Adversarial Network)이 있으며, 특히 GAN은 성능이 매우 우수하며 새로운 모델들

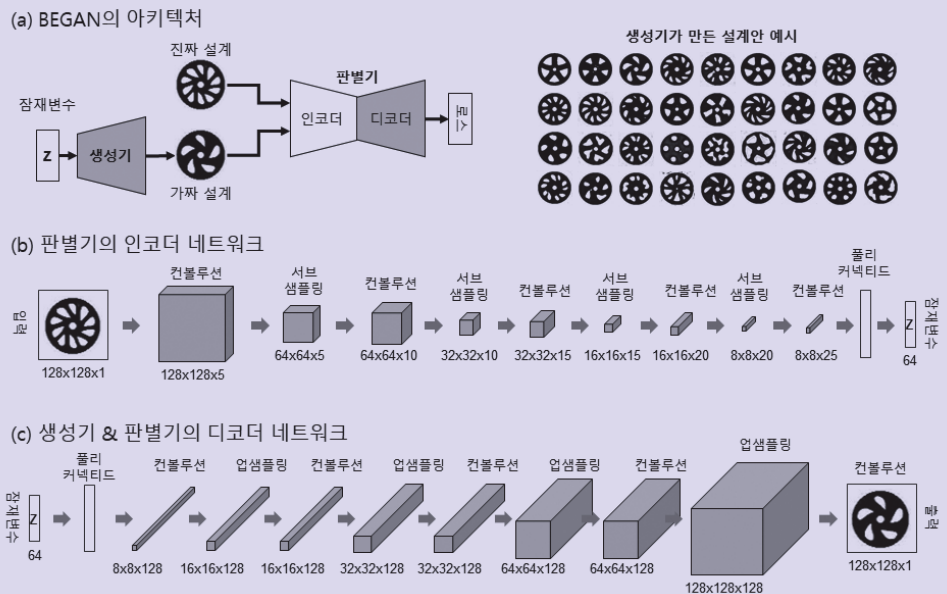


그림 3 BEGAN을 이용한 휠 설계안 생성 모델(Oh et al., 2019)

설계안을 생성할 수 있는 네트워크를 가진다.

생성 모델만으로 공학적으로 의미있는 설계안을 생성하는 데는 한계가 존재하지만, 제너레이티브 디자인과의 결합을 통해 서로의 문제점을 보완할 수 있는 가능성이 보인다. 첫째, 생성

설계안의 생성/평가/추천에 이르는 전 과정의 자동화를 위해서는 인공지능 기반의 융합 연구가 필요하다.

결과물은 공학적

모델은 다량의 학습 데이터를 필요로 하지만, 다량의 과거 설계 데이터를 축적하고 있는 기업은 한정적이다. 이 때 제너레이티브 디자인이 다량의 학습 데이터를 생성할 수 있다. 둘째, 생성 모델의 성능을 보장하지 않는다. 이때 위상 최적화의 목적함수를 통해 성능 평가가 가능하다. 셋째, 생성 모델은 모드 붕괴(mode collapse)로 인해 특정 결과물만을 잘 생성해 내고 결과물의 품질이 고르지 못한 단점이 있다. 이때 제너레이티브 디자인으로 후처리를 하여 최종 품질을 향상시킬 수 있다.




그림 4 설계안 생성 예시: 최종 생성된 설계안에 딥러닝(pix2pix)을 이용하여 자동으로 재질을 입힘. 이는 설계안 추천 단계에서 설계안 선호도 평가 시에 현실감을 줄 수 있도록 함.

딥제너레이티브 디자인

앞에서의 소개와 같이 역학 기반의 제너레이티브 디자인과 데이터 기반의 딥러닝은 상호보완적인 성격을 가지고 있다. 이 글에서는 제너레이티브 디자인과 딥러닝을 결합한 딥제너레이티브 디자인(Deep Generative Design) 연구를 예시로 소개한다(Oh et al., 2019; Kim et al., 2019). 딥제너레이티브 디자인은 다음의 세 단계로 구성이 되며, 향후 각 단계의 성능을 심화하는 방향의 후속 연구들이 진행될 예정이다.




그림 5 설계안 평가 예시: 성능(유연도), 비용, 차별성에 대해 평가하고 파레토 곡선에 놓인 설계안들을 확인함(Oh et al., 2019).

- Stage 1 - 설계안 생성: 과거 설계 레퍼런스를 바탕으로 제너레이티브 디자인과 생성모델의 사용을 순차적으로 반복한다. 의미 있는 새로운 설계안이 생성되지 않을 때까지 반복하여, 소량의 과거 설계 레퍼런스에서 다량의 설계안으로 증폭시킬 수 있다.(그림 4)
- Stage 2 - 설계안 평가: 최종 생성된 설계안들의 성능, 비용, 차별성 등을 평가하여 비교한다. 이때 딥러닝의 이상치탐지 기술을 통해 새로운 설계안의 차별성(novelty)을 측정할 수 있도록 하며, 평가된 설계안들은 산점도로 나타내 평가요소별로 상충관계를 살펴볼 수 있도록 한다.(그림 5)
- Stage 3 - 설계안 추천: 평가된 설계안들에 대한 설계자 혹은 잠재 고객의 정성적인 선호도를 학습하여 선호도가 높은 순서로 설계안을 추천하는 단계이다. 이를 위해 설계안들에 대한 비교 설문을 진행하며, 응답 데이터를 바탕으로 머신러닝 기반 선호도 예측 모델을 구축한다.

맺음말

제너레이티브 디자인과 딥러닝의 생성모델은 인간을 대신하여 다량의 새로운 설계안을 생성해 낼 수 있는 기술들이다. 두 기술의 결합은 최적설계의 도메인 지식과 데이터 기반의 인공지능의 높은 성능이 시너지를 이룰 수 있게 한다. 설계안의 생성, 평가, 추천에 이르는 설계의 전 단계에서 인간을 대체하는 진정한 자동화를 이루기 위해서는 최적설계와 인공지능뿐만 아니라 인간을 연구하는 다양한 인문사회과학 분야와의 초학문적인 융합 연구가 필요하며, 이러한 연구들은 4차 산업혁명 시대의 새로운 설계 패러다임을 제시할 것으로 기대한다.

김 정 언 광주과학기술원 기계공학부 박사과정
오 현 석 광주과학기술원 기계공학부 조교수

| e-mail : kje20171100@gist.ac.kr
| e-mail : hsoh@gist.ac.kr

이 글에서는 공학 시스템 상태 파악의 필요성과 인공지능을 활용한 센서 네트워크 최적화 기술을 설명한다.

공학 시스템 상태 파악의 필요성

산업 IoT 기술, 정보 통신 ICT 기술, 딥러닝을 포함한 인공지능 기술 등의 급격한 발전으로 인해 공학 시스템들은 서로 연결되고, 스마트 해지고 있다. 이러한 기술적 진보는 공학시스템의 안전 및 신뢰성 확보, 유지보수비용 절감, 가용도 향상 측면에서 획기적인 변화를 이끌어 낼 수 있는 잠재력을 지니고 있다. 그러나 우리 일상에서 이러한 변화는 잘 와닿지 않는다. 대부분의 경우, 고안전성, 고신뢰성을 요구하는 사회 핵심 설비(예, 발전소, 플랜트, 항공, 선박, 중장비, 자동차 조립라인 등)에 해당하는 이야기이기 때문이다. 그럼에도 불구하고 우리 주변에서 쉽게 볼 수 있는 일례를 굳이 찾아 본다면, 가정 또는 사무실에 비치하고 있는 정수기의 유지 관리가 관련성이 있지 않을까 싶다.

최근 국내 L사는 정수기를 생산하는 제조업에 그치지 않고, 서비스업으로 사업 영역을 확장하고 있다. 그중 눈에 띄는 것이 “토탈 케어”라는 개념이다. “토탈 케어” 서비스를 살펴 보면 ① 직수관 매년 교체, ② 3개월마다 직접 방문하여 살균케어, ③ 10년 무상 보증 등이 있다. 이는 L사가 정수기의 제조, 판매에 그치지 않고, 유지보수까지 모두 책임을 지겠다는 것이다. 이러한 개념의 실현을 위해, 산업 IoT 및 정보통신 ICT 기술이 적용되고 있다. 예를 들면, 센서를 이



그림 1 스마트폰을 이용한 정수기 상태 및 필터 교체 여부 알림 (출처: 국내 L사)

용한 정수필터 상태 모니터링(산업 IoT 기술 적용) 또는 정수기 위생 상태를 스마트폰에서 확인할 수 있는 시각화(정보 통신 ICT 기술 적용) 등이 있다(그림 1). 그렇다면 토탈케어 서비스를 제공 받음으로써 소비자가 기존과는 다르게 새롭게 얻는 가치(즉, 행복 또는 만족)는 무엇일까? 과연 무엇 때문에 이 서비스가 정수기 소비자 종합 만족도 설문조사에서 높은 점수를 받은 것일까?

소비자들은 다양한 기준으로 정수기 ‘토탈케어’의 가치를 판단할 것이다. 요약하면 다음 두 가지 정도일 것이다. 우선, ‘청결함(안전) 확보’이다. 본인 또는 가족,

동료가 마시는 물인데, 깨끗해야 하지 않을까? 또는 날도 더운데 혹시 물 때문에 배탈이 나지는 않을까? 라는 생각이 들 것이다. 간혹 식당에 설치된 정수기 또는 그 주변이 지저분하면, 물을 마시기 꺼리게 되는 게 누구나 가지고 있는 생존 본능이다. 다음으로는 “귀찮음으로부터 해방”이다. 정수기의 성능은 항상 새 제품의 성능과 같을 수 없다. 시간이 지나면서 저하되기 마련이다. 그런데 사용자 입장에서 필터 교체, 세척과 같은 유지보수 작업은 매우 귀찮은 일이다. 현대인의 일상에서 본업에 집중하기도 바쁜데, 정수기 필터 교체 및 세척은 여간 성가신 일이 아니다. 물론, 이러한 유지보수 작업을 즐기는 사람도 있을 테지만 말이다.

그렇다면, 다시 이 글의 처음으로 돌아가서, 다음과 같이 질문 하고자 한다. 고안전성, 고신뢰성을 요구하는 사회 핵심 설비(예, 발전소, 플랜트, 이동/운송 수단, 자동차 조립라인 등)의 사용자는 어떤 서비스를 원하고 있을까? 혹시 정수기에 적용된 것과 같은 “토탈케어”를 원하지는 않을까? 이에 대한 정답은 없다. 하지만 지금까지의 흐름을 살펴보면 “앞으로는 대체로 그럴 것 같다”로 보인다. 미국 제너럴 일렉트릭(발전소, 플랜트), 록웰, 하니웰(기계 자동화), 캐터필러(건설장비), 독일의 지멘스(기계 자동화), 보쉬(기계 부품), 쿠카(로봇), 일본의 화낙(로봇), 미쯔비시 전기(설비) 등 전세계 선진 기업들이 이러한 “토탈케어”를 구현하기 위해 적극적으로 연구 개발을 하고 있다. 발전소 건설비 또는 전투기 초기 구매 비용보다, 유지보수비(평균 30년)가 몇 배 더 많다는 사실을 우리는 지금까지 너무 간과한 것이 아닐까?

센서 네트워크 최적 설계

앞서 설명한 정수기의 예시에서 정수 필터의 상태를 모니터링을 위해 IoT 센서를 이용한다. 그렇다면, 고안전성, 고신뢰성을 요구하는 사회 핵심 설비에는

어떠한 센서들이 사용될까? 과거 성수대교 붕괴와 같은 고통스런 재난을 겪은 후 안전 확보에 대한 인식이 매우 높아졌다. 그 후 한강 교량 온라인 안전감시 시스템이 개발되어 현장에서 실제 사용되고 있다. 이러한 대형 구조물 건전성을 실시간으로 파악하기 위해 많은 센서가 부착되어 있다. 가속도계의 경우, 교각이나 케이블에 설치하여 차량하중, 바람, 지진 등에 의한 가속도를 측정하여, 교량의 고유진동수, 진동 모드를 파악한다. 변형률계의 경우, 교량의 응력이 크게 발생할 것으로 예상되는 위치에 설치하여 바람, 온도에 의한 변형률을 측정하여, 피로 파손 정도를 파악한다.

센서 설치 예시는 다음과 같다. 올림픽대교는 1989년 11월 15일 개통된 한강의 16번째 교량으로 1988년 개최된 서울 올림픽을 기념하기 위해 주탑 높이를 88미터로 시공했는데, 총 길이가 1,470미터이다. 단축 가속도계 12개, 3축 가속도계 4개, 처짐계 2개, 풍향 풍속계 2개, 경사계 1개 신축 변위계 2개, 온도계 3개가 부착되어 있다(그림 2). 다음으로 성산대교는 1980년에 준공된 한강의 12번째 교량으로 트러스 공법으로 시공되었으며, 총 길이가 1,415미터이다. 변형률계 6개, 온도계 2개, 광섬유 변형률계 42개가 설치되어 있다. 마지막으로 행주대교는 1995년(하행선), 2000년(상행선)에 준공되었고 총 길이가 1,460미터이다. 단축 가속도계 18개, 경사계 6개, 신축 변위계 2개, 변형률계 2개, 온도계 4개, 균열 게이지 2개가 설치되어 있다.

한강 교량들 예시들을 살펴 보았을 때, 많은 수량의 센서들이 설치되어 있음을 알 수 있다. 그렇다면, 필요한 센서의 수량은 어떻게 결정하였을까? 올림픽대교에 단축 가속도계 12개가 너무 많은 것은 아닐까? 두 개를 빼고 10개를 설치하면 안 될까? 일단 센서 수량은 12개로 하라고 누군가가 결정했다고 하자. 추가로 드는 의문은 과연 센서들의 설치 위치는 어떻게 결정하였을까? 왜 하필 그 위치에 센서를 설치하기로





그림 2 올림픽대교에 부착된 상태 감시용 센서 종류, 위치 및 수량(출처: 서울특별시 도시안전실 용역보고서)



(a)



(b)

그림 3 플랜트 배관계 (a) 현장, (b) 시뮬레이션 모델

결정하였을까? 이러한 궁금증에 대해 아마도 센서 네트워크 최적 설계 기술이 일부분 답을 제시할 수 있지 않을까 싶다.

공학 설비를 모니터링, 제어하기 위해 센서를 통한 데이터 획득이 이루어지고 있다. 많은 경우, 제한된 리소스, 지리적 접근성 한계, 설비의 복잡성으로 인해 충분한 양의 데이터 획득은 불가능하다. 소량의 센서를 통해 가능한 많은 정보를 획득하는 것이 센서 네트워크 최적 설계의 목표이다. 센서 네트워크 최적 설계를 위해 Shannon 정보 척도 이용, 효율 독립 (Effective Independence) 방법 등이 개발되었다. 이 중 한 가지인 Shannon 정보 척도를 이용한 접근법은 다음과 같다. 우선 센서 개수의 결정을 위해 센서 추가에 따른 정보량 증가를 정량화하고, 이때 추가로 요구되는 비용을 계산함으로써 둘 사이의 Trade-off를 통해 센서 수량을 결정하게 된다. 다음으로 센서 위치의 결정은 다양한 위치의 조합들을 시뮬레이션 하여 결정한다. 센서 위치 조합에 대한 모든 경우의 수를 계산하여, 최소의 비용으로 최대의 정보량을 얻을 수 있는 센서의 조합이 최적해로 도출 된다.

현실에서는 센서 위치 조합에 대한 모든 경우의 수를 계산하는 것이 어려울 때가 많다. 실험실 배관 시스템이 주어졌을 때, Reservoir에서 유체가 공급되어 일정한 압력이 유지된다고 하자. A 또는 B 지점의 파손으로 인해 유체가 빠져나가는 재난 상황을 가능한 빨리 탐지하기 위해 두 개의 센서를 달 수 있다고 하면, 과연 어디에 달아야 할까? 가장 쉬운 방법은 주어진 132개 노드에서 2개의 위치를 선택하는 경우의 수 (${}_{132}P_2 = 17,292$)에 대해 재난 탐지율을 정량화하여, 가장 높은 재난 탐지율을 보이는 위치 조합을 찾으려 할 것이다. 어렵지 않은 문제이다. 그렇다면, 실험실 배관 모델(132개 노드)이 아니라, 실제 플랜트 배관을 모사한 모델(10,000 노드)을 고려해 보자(그림 3). 센서 위치 두 곳을 선택해야 한다면 경우의 수(${}_{10000}P_2$)는 약 10^8 개이다. 세 곳을 선택하기 위한 경우의 수

$({}_{10000}P_3)$ 는 약 10^{12} , 네 곳의 경우 10^{16} 로, 센서 위치 개수가 늘어날수록 기하급수적으로 늘어나게 된다. 앞서 올림픽대교 예제의 경우, 열두 곳에 단축 가속도계가 하나씩 설치 되어 있다. 센서 위치 열두 곳을 선택하기 위한 경우의 수(${}_{10000}P_{12}$)는 거의 무한대(10^{48})이며 계산은 불가능해 진다. 참고로 관측 가능한 우주의 원자 개수가 약 10^{80} , 바둑의 모든 경우의 수가 약 10^{170} 으로 추정된다. 즉 센서 네트워크 최적 설계는 “Class NP-hard” 타입의 문제로 귀결된다. 그렇다면 이러한 “Class NP-hard” 타입 문제는 어떻게 풀까?

진화 알고리즘

한 그룹의 개체들이 제한된 자원 환경하에 생존 경쟁을 한다고 하자. 자연에서 경쟁의 결과는 찰스 다윈이 제안한 적자생존 개념으로 요약할 수 있다. 세대를 거치며 적자생존이 반복되어서 점차 환경에 더 잘 적응한 개체들로 개체군이 형성된다. 이러한 자연 원리를 컴퓨터 시뮬레이션을 통해 구현한 것이 진화 알고리즘(Evolutionary Algorithm)이다. 어떤 문제에서 다양한 솔루션이 존재하고, 주어진 목적함수를 극대화하는 최적 솔루션을 찾고 싶어 한다고 하자. 이 때, 진화 알고리즘을 이용한다면, 모든 경우의 수를 고려한 솔루션들의 목적함수를 일일이 다 계산해서 비교할 필요가 없이 효율적으로 최적 솔루션을 찾을 수 있다.

진화 알고리즘의 흐름이 그림 4에 잘 나타나 있다. 어떤 개체군(population)이 주어졌을 때, 자손을 낳길 부모(parent)를 선택한다. 선택된 부모들로부터 재결합(crossover), 돌연변이(mutation) 과정을 거쳐 자손(offspring)들이 생성된다. 개체군에 존재하는 부모와 자손들 중에서 적합도(fitness)가 높은 개체들을 생존 개체로 선택하여 다음 세대 개체군을 형성한다. 이러한 과정이 반복되면서 적합도가 더 높은 개체들로 개체군이 형성되게 된다. 진화 알고리즘의 대표적인 예로 유전 알고리즘(Genetic Algorithm),




그림 4 진화 알고리즘의 흐름도(출처: Eiben and Smith, 2015)

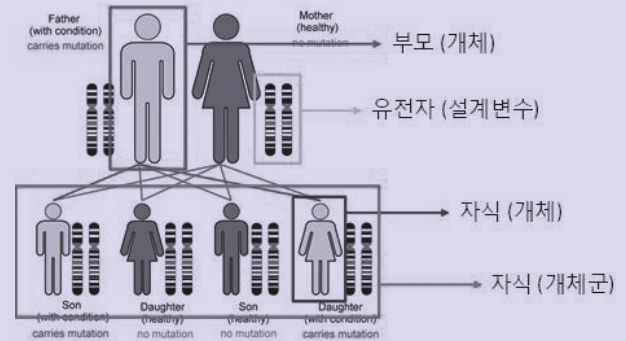


그림 5 유전 알고리즘의 개요

입자 군집 알고리즘(Particle Swarm Algorithm) 등이 있다. 유전 알고리즘은 1975년 존 홀랜드에 의해 개발 되었고, 세대를 걸쳐 교배, 돌연변이의 연산을 통해 낮은 적합도를 가진 개체군이 높은 적합도를 가진 개체군으로 진화한다(그림 5). 그 중 가장 높은 적합도를 가진 개체가 최적 솔루션으로 선택되는 전역 최적화 기법 중 하나이다.

센서 네트워크 최적화를 위한 인공지능 진화 알고리즘의 응용

플랜트 배관계 센서 네트워크 최적화를 위한 개요는 그림 6에 나타나 있다. 플랜트 배관계의 파손 위치를 가능한 높은 탐지율로 찾아내는 것이 목표이다. 센

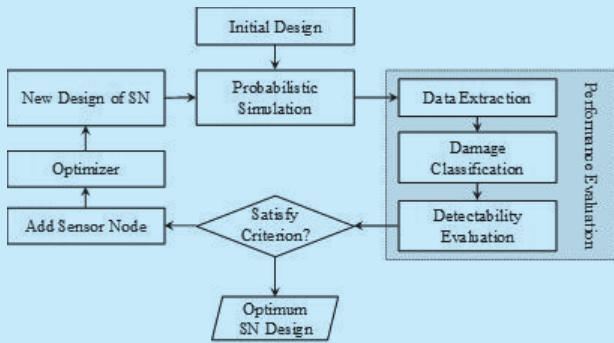


그림 6 인공지능 유전알고리즘을 이용한 센서 네트워크 최적 설계 흐름도

서 위치의 초기 설계안이 주어지면, 그 초기 설계안에 대해 재료, 형상, 환경 요소의 불확실성을 반영하여 탐지율을 계산할 수 있다. 목표 탐지율을 만족할 경우, 센서 네트워크 설계 위치가 결정이 되지만, 그렇지 못할 경우, 주어진 센서 개수를 만족하는 최적의 센서 설치 위치를 인공지능 유전 알고리즘을 통해 찾게 된다. 최적 해에 대해 다시 탐지율을 계산하고 목표 탐지율과 비교하게 된다. 목표 탐지율을 넘지 않으면, 센서 개수를 하나씩 늘리고, 탐지율을 만족할 때

까지 루프를 반복한다. 이를 통해 최적화된 센서 위치 및 센서 수량을 결정할 수 있다.

지금까지 공학 시스템 상태 파악의 필요성, 이를 위해 데이터 획득을 위한 센서 네트워크 설계, 인공지능 유전 알고리즘을 이용한 최적 설계안 도출에 대해 살펴 보았다. 마지막으로, 인공지능 기술개발의 선행 요소는 양질의 충분한 데이터 확보라는 점을 언급하고자 한다. 지금까지 보고된 인공지능 성공사례 중, 이미지 및 음성 인식 등의 분야에서는 딥러닝 알고리즘 훈련을 위해 엄청난 양의 데이터를 활용하였다. 최근 의료 분야에서는 우리나라 100만 명 분의 빅데이터를 구축하기로 결정하였다고 한다. 안타깝게도 공학 시스템 상태 파악 분야에서의 현실은 그렇지 않다. Industry 4.0의 구호하에 많은 데이터가 축적되고 기술 개발에 우호적인 환경이 조성되고 있음에도 불구하고, 각종 규제, 개별 정책으로 인해 사회 핵심 공학 설비의 센서 데이터는 거의 공개되지 않고 있다. 향후 이러한 현실적 난관들을 어떻게 극복하느냐가 앞으로 이 분야에서 세계적으로 경쟁력 확보를 좌우할 중요한 요소 중 하나일 것이라 판단한다.

딥러닝의 산업 적용을 위한 도메인 지식 기반 데이터 전처리 기술

| | | |
|-------|-----------------------|-------------------------------|
| 윤 병 동 | 서울대학교 기계항공공학부 교수 | e-mail : bdyoun@snu.ac.kr |
| 김 현 재 | 서울대학교 기계항공공학부 석박사통합과정 | e-mail : secutus07@snu.ac.kr |
| 고 진 욱 | 서울대학교 기계항공공학부 석박사통합과정 | e-mail : coolstyle@snu.ac.kr |
| 박 종 민 | 서울대학교 기계항공공학부 석박사통합과정 | e-mail : 20jmp02@naver.com |
| 공 현 배 | 서울대학교 기계항공공학부 석박사통합과정 | e-mail : vividsunmi@naver.com |
| 오 영 탁 | 서울대학교 기계항공공학부 석사과정 | e-mail : oyt9306@gmail.com |

이 글에서는 딥러닝을 이용한 산업인공지능 기술에서의 산업 도메인 지식을 이용한 데이터 전처리 기술의 중요성에 대해서 소개하고 연구 사례를 살펴본다.



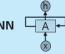



최근 빅데이터를 기반으로 한 인공지능 기술이 많은 현업의 문제를 해결하고 있다. 딥러닝을 필두로 한 인공지능 기술은 막대한 양의 데이터가 가지는 복잡한 탐색 공간에서 최적의 해답을 이끌어냄으로써 많은 분야에서 전문가 지식 기반의 알고리즘의 성능을 뛰어넘었다. 특히, 컴퓨터 비전과 자연어 처리 분야에서는 인간에 비견할 수준의 정확도를 보여주고 있다. 하지만 이러한 컴퓨터 비전, 자연어 처리 분야의 괄목할 만한 발전에는 해당 태스크(task)의 일반성(generality)이 크게 기여한다. 인공지능의 학습을 위한 이미지와 음성 데이터는 웹 크롤링, IT 기기로부터 대량으로 수집되며, 이는 인공지능 기술의 개발과 성능의 검증을 가속화하는 핵심 요소이다.

제조업 등의 산업 분야에서도 인공지능 기술을 활용하기 위한 논의가 활발하게 진행되고 있으며, 그중 가장 대표적인 분야는 설비나 공정의 이상을 탐지하고 진단하는 고장 진단 및 예측 기술(PHM: Prognostic and Health Management)이다. 하지만 산업계에서의 인공지능의 활용은 활용 가능한 데이

터 기반 방법론의 관점에서 좀 더 제한되는 측면이 있다. 예를 들어, 특정 설비의 상태를 진단하기 위한 인공지능 모델의 학습데이터는 해당 설비 또는 최소한의 유사성을 가지는 장비들로부터 제한적으로 취득되며 학습에 충분한 양을 확보하기 어렵다. 이는 인공지능이 풀고자 하는 태스크가 특수(specific)하기 때문에 발생하는 차이이며, 따라서 이를 일반 인공지능과 구분하여 '산업인공지능'으로 부른다. 산업인공지능은 기존의 인공지능에 산업 도메인의 지식을 다양한 형태로 적용한 기술을 일컬으며, 해당 산업 분야에 특히 높은 성능을 발휘하도록 개발된다. 고장 진단 및 예측 기술 분야에서도 산업인공지능을 활용한 연구가 활발히 진행되고 있다. 이 글에서는 특히, 딥러닝을 이용한 산업인공지능 기술에서의 산업 도메인 지식을 이용한 데이터 전처리 기술의 중요성에 대해서 소개하고 연구 사례를 살펴본다.

일반적으로 PHM기술은 그림 1과 같이 전처리(Preprocessing), 특성 인자 추출(Feature Extraction), 고장 진단(Diagnosis), 고장 예측

표 1 고장진단 및 예측 기술과 산업인공지능의 단계

| Category | | Preprocessing | Feature Extraction | Diagnosis | Prognosis |
|---------------|---------------------------------|--------------------------------|---|---|---|
| AI | | | | | |
| Industrial AI | Lv.3 (Industrial Deep Learning) | Domain Knowledge Preprocessing | DNN  | CNN  | RNN  |
| | Lv.2 | | | MLP  | SVM  |
| | Lv.1 | | | | PF  |
| Experience | | | | | |

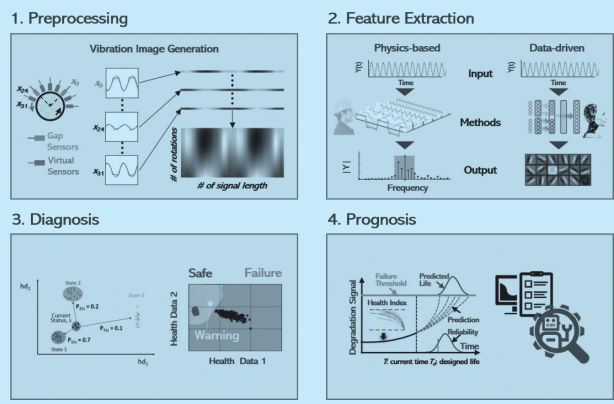


그림 1 고장진단 및 예측 기술의 4단계

(Prognosis)으로 나눌 수 있다. 전처리는 시스템의 특성 인자를 효과적으로 추출할 수 있도록 미리 데이터를 정돈하고 처리한다. 다음으로 특성 인자 추출 (Feature Extraction)을 통해 고차원의 데이터로부터 저차원의 특징벡터를 얻는데, 이는 보통 해당 분야의 물리적 지식을 통해 고장과의 연관성을 지을 수 있는 인자를 찾아내거나 통계적 분석을 통해 도출한다. 이렇게 추출된 특징들을 기반으로 시스템의 고장을 진단 또는 예측한다.

PHM에서 산업인공지능은 PHM의 과정에서 AI가 적용된 수준에 따라, 표 1과 같이 세 가지 수준으로 분류할 수 있다. 가장 기초적인 산업인공지능인 Level 1은 전처리, 특성 인자 추출, 진단 모두 도메인 지식 기반으로 수행하는 방식이다. 모든 과정이 물리적인 의미를 내포하기 때문에 결과의 해석이 용이하

지만, 개발 비용이 높으며 성능 최적화가 어렵다. Level 2는 전처리와 특성 인자 추출 단계를 인간 전문가가 직접 설계하고, 진단 및 예측을 인공지능 알고리즘으로 수행하는 방식으로, Neural Networks(NNs), Support Vector Machine(SVM), k-Nearest Neighbor(kNN), Decision Tree 등의 쉘러닝 (shallow learning)을 주로 사용한다. 마지막으로 산업인공지능의 Level 3은 고장 진단 및 예측 기술의 전반을 인공지능으로 구현하는 방식이며, 딥러닝을 통하여 특성 추출, 분류 및 예측을 한번에 학습할 수 있게 되면서 발전하였다. 따라서 Level 3의 산업인공지능을 산업딥러닝으로 부를 수 있다. 산업딥러닝은 딥러닝 기술이 특정한 분야에 대해 높은 성능을 지닐 수 있도록 인간 전문가의 도메인 지식을 통해 특수하게 개발되는 기술을 뜻한다. 특히, 딥러닝의 종단간 학습 (end to end learning) 기법에 도메인 지식을 이용한 전처리 기법을 사용함으로써 산업 딥러닝의 성능은 크게 향상될 수 있다. 산업 딥러닝에서 주로 사용되는 전처리 기법은 이미지 기반과 비이미지 기반, 그리고 또다시 시간주파수표현(TFR: Time-Frequency Representation) 기반과 비시간주파수표현 기반의 기법으로 나눌 수 있으며, 아래에서 원리와 사례를 소개한다.

이미지 기반 전처리: TFR 기반

산업딥러닝에서 사용되는 기술은 다층퍼셉트론 (MLP: Multilayer Perceptron), 합성곱 신경망 (CNN: Convolutional Neural Network) 등과 같은 깊은 신경망이며, 이 중에서도 CNN은 가장 현장 적용성이 높은 기술로 평가 받고 있다. CNN은 영상인식(얼굴인식, 물체인식, 텍스트인식 등), 자연어 처리 등의 영역에서 높은 성능을 내는 기술이며, 고장 예측 및 진단 분야 연구자들은 이러한 CNN의 높은 성능을 활용하기 위하여 공학데이터에 대한 이미지 기반 고장진단

연구에 많은 관심을 보이고 있다. 따라서 공학시스템에서 취득된 데이터를 이미지로 변환하여 딥러닝을 통해 학습하고자 하는 연구가 많이 진행 중이다. 최근에는 베어링, 기어박스, 회전체 등의 주요 기계 시스템들에 대하여 연구가 이루어지고 있으며, 해당 기계 시스템으로부터 취득되는 1차원 데이터 (e.g. 진동 신호, 음향 신호 등)를 2차원 이미지 형태로 변환한 후 이를 CNN의 입력 데이터로 사용하는 연구 사례들이 등장하고 있다.

시간주파수분석을 통한 1차원 데이터의 이미지화는 그림 2(a)와 같이, 1차원 신호의 시간에 따른 변화를 주파수 대역에서 함께 고려함으로써 신호의 특성을 잘 표현할 수 있는 동시에 2차원의 이미지로 변환할 수 있어 가장 흔하게 사용되는 방법이다. 가장 대표적인 시간주파수 방법은 spectrogram(STFT: Short-Time Fourier Transform)과 scalogram(WT: Wavelet Transform)으로 구분할 수 있으며, CNN을 통해 TFR 이미지 상에서 나타나는 정상과 고장 신호의 차이를 효과적으로 구분할 수 있음이 여러 문헌을 통해 검증되었다.

이미지 기반 전처리: 비TFR 기반

일반적으로, 고장에 따른 진동신호의 중요 특징은 시간에 따른 주파수 성분이고, TFR은 이를 신호처리를 활용해 이미지로 표현하는 기법이다. 하지만, 시

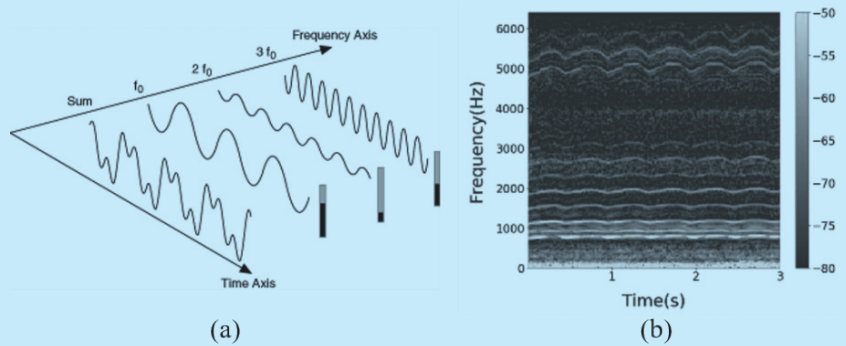


그림 2 (a) 푸리에 변환, (b) STFT 변환된 진동신호

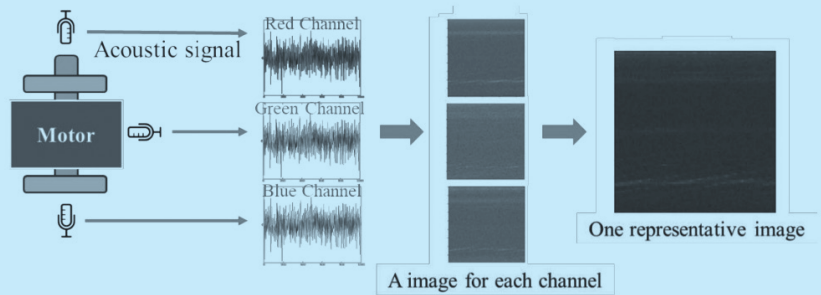


그림 3 음향신호 스펙트럼을 이용한 이미지화




그림 4 신호의 센서위치 불변성 확보를 위한 ODR 기반 이미지화

간-주파수 성분 외에, 고장에 따른 특징을 잘 보여주는 이미지화 기법들도 연구되었다.

대표적으로 그림 3과 같이 회전체로부터 획득된 음향 신호의 스펙트럼을 일정한 간격으로 나누어 쌓아 이미지를 만드는 방식이 있다. 만들어진 이미지가 주파수 성분 간의 상관성을 잘 반영하게 하기 위하여 스펙트럼은 회전체의 회전속도 또는 그 배수로 나누어진다. 또한, 기존의 이미지 판별 모델과의 호환성을




그림 5 변압기 유증가스 조성비를 이용한 전처리

위하여 3채널로 측정된 음성신호를 각각 RGB에 대응시켜 이미지를 생성할 수 있다.

진동신호 이미지화의 특수한 경우로 회전체 시스템의 센서 위치에 대한 데이터 불변성(invariance)을 확보하기 위한 스템 터빈의 로터 등에서 진동 신호는 90도 간격으로 위치한 두 개의 근접센서로 측정된다. 이 경우 로터 축의 진동 방향에 따라 동일한 상태에서 발생하는 신호일지라도 그 형태는 달라져 높은 진단 정확도를 달성하기 힘들다. 이러한 문제를 해결하기 위해서, ODR(Omnidirectional Regeneration) 이미지화 기법(그림 4)이 제안되었으며, 이 기법은 raw 신호를 일정 각도 간격으로 회전 변환하여 가상의 신호를 생성하여 2차원 이미지를 구성한다. 이렇게 만들어진 이미지는 시각적인 관점에서 고장에 따른 특징을 더욱 명확히 보여주어 CNN을 통한 고장 진단의 성능을 향상시킨다.

비이미지 기반 전처리

앞서 소개된 사례들과 같이, 이미지 형태의 입력데이터를 이용한 2D-CNN 모델은 좋은 성능과 높은 학습 안정성으로 인해 가장 널리 사용되는 방법이다. 하

지만 데이터의 이미지 형태로의 변환 과정이 아닌 전처리 방법들도 많이 연구되고 있다. 도메인 지식을 활용하여 고장과 직접 관련이 있는 성분으로 변환하는 전처리 과정을 거친 후 입력으로 사용해 높은 정확도를 보이는 사례들도 존재한다. 예를 들어, 등속 조건하의 회전체 시스템에서는 일반적인 주파수 분석 또는 제한된 길이의 시간 주파수 분석으로 진단을 수행하기 어렵다. 그래서 변속 조건하의 베어링과 기어박스 진단을 위해, 엔코더 정보에 기반한 차수 스펙트럼(order spectrum)¹⁾을 학습하거나 순간 각속도를 계산하여 변속 조건을 보정하는 전처리 방법들이 제안되었다.

진동신호 이외의 공학 데이터에 대한 연구들도 진행되고 있는데, 예를 들어 변압기의 절연유에 녹아 있는 가스의 성분인 유증가스²⁾ 값을 기반으로 구축된 고장 진단 모델 연구가 있다. 위 연구에선, 고장과 밀접한 관련을 갖는 조성 기체의 농도값을 그대로 학습하지 않고 기체끼리의 비율을 계산하여 딥러닝을 통해 학습시켜 더 높은 진단 성능을 얻었다. 이는 기체 간의 비율을 통해 변압기 간의 편차를 줄이고 입력값 간의 편차를 줄임으로써 도메인 지식을 활용하여 성공적으로 딥러닝의 학습 성능을 높인 사례로 꼽힌다.

산업계에서의 활용

최근까지도 산업계에서는 공장 등에서 수집된 데이터를 단순한 통계학적 전처리만을 거친 후 바로 딥러닝에 학습하는 방법이 주로 사용되어 왔으나, 업계마다 판이하게 다른 데이터의 형태, 특성 등에 의해 딥러닝의 사용에 어려움을 겪고 있다. 따라서 기계, 철강, 화학 등의 제조업을 중심으로 딥러닝을 더욱 효율적으로 활용하기 위한 도메인 지식 기반의 전처리

1) 회전체의 회전수의 역수 단위의 주파수 도메인을 가지는 스펙트럼

2) 변압기나 OLTG의 절연재료 연소로 인해 절연유에 용해된 CO₂, CH₄, C₂H₂ 등의 탄화수소가스

의 필요성이 부각되고 있다. General Electric은 자사 클라우드 플랫폼 예측 솔루션인 Predix에서 사용자의 제안에 따라 예측할 데이터의 종류를 추가하거나 제거할 수 있는 기능을 제공하고 있으며, IBM의 Watson Deep Learning 플랫폼에서는 기본적인 상관성/주성분 분석을 통해 유용한 데이터를 골라내고 딥러닝에 학습시킬 수 있도록 하고 있다. 또한, 국내의 경우에는 서울대에서 창업된 벤처기업인 원프레딕트에서 자사의 소프트웨어인 GuardiOne 제품군에서 모터, 발전터빈 등을 비롯한 회전체에서의 고장을 더욱 효율적으로 진단하기 위하여 음향/진동 신호를 시간주파수기법 또는 ODR 기술을 기반으로 이미지로 변형하는 기술을 사용 중에 있으며, 유증가스 조성비 전처리를 이용한 변압기 진단 솔루션을 개발하였다.

맺음말

이 글에서는 인공지능의 산업 적용의 어려움을 짚

고, 이를 해결하기 위한 다양한 데이터 전처리에 대한 접근, 그리고 이를 묶은 산업인공지능의 개념을 제시하였다. 최근 십수 년간, 딥러닝의 발전은 원시 데이터(raw data)로부터 바로 태스크를 학습하여 도메인 지식을 거의 필요로 하지 않는 종단간 학습을 가능케 하였다. 불과 수년 전만 하더라도 이러한 종단간 학습은 산업계에서도 바로 적용될 수 있을 것으로 예상되었다. 하지만 산업현장에서 유래되는 데이터의 부족 및 태스크의 특수성은 인공지능의 한계를 보여주었으며, 이를 해결하기 위한 전문가 지식의 필요성을 시사하였다. 원시 데이터의 적절한 전처리는 효과적으로 인공지능이 목표를 학습할 수 있도록 탐색 공간을 조절하고 학습을 가속할 수 있다. 인공지능 기술은 산업계의 새로운 문제 해결 도구이며, 인공지능의 시대를 맞아 각 분야의 전문가들에게 인공지능 기술의 특성을 파악하고 분야에 적용하기 위한 각별한 노력이 필요한 바이다.

가상 제품 개발을 위한 인공지능 활용

이 용 빈 ㈜피도텍 기반기술팀 팀장

| e-mail : eyongbin@pidotech.com

손 석 호 ㈜피도텍 기반기술팀 책임연구원

| e-mail : seokho.son@pidotech.com

이 승 철 포항공과대학교 교수

| e-mail : seunglee@postech.ac.kr

이 글에서는 공학설계 기술 중 가상 제품 개발(VPD: Virtual Product Development)을 위한 핵심 기술 중 하나인 ‘메타모델 자율 생성’ 인공지능을 소개하고자 한다.

공학설계 기술의 메가트렌드

공학설계란 “기초/응용 과학 및 공학 기술을 적용하여, 주어진 자원을 최적으로 변환함으로써 설계 목표를 달성하는 의사결정 과정”이라고 정의할 수 있다. 전 세계의 산업체들은 경쟁력 있는 제품 개발을 위하여 반드시 활용하여야 하는 공학설계 기술을 발전시켜 왔다. 공학설계 기술의 발전은 크게 다음의 세 단계를 거쳐 왔다: 실험 기반 설계(EBD: Experiment-based Design); 시뮬레이션 기반 설계(SBD: Simulation-based Design); 데이터 기반 설계(DDD: Data Driven Design). 오래전부터 활용하였던 EBD는 근래 급속히 발전한 컴퓨터 및 CAE 기술을 적극적으로 이용하는 SBD로 대체되고 있다. EBD 대비, 제품 개발 기간 단축 및 원가 절감을 위하여 매우 유용한 것으로 판명된 SBD는 실험이 어려운 항공 우주 분야에서 적용을 시작한 후, 이제는 실험이 비교적 쉬운 가전/전자 분야까지 적용 범위를 넓혀 가고 있다. 이러한 SBD는 꽤 오랜 기간 공학설계를 위한 주된 기술로 자리매김할 것으로 예상된다. 최근 각 분야에 긍정적인 큰 변화를 일으키고 있는 4차 산업혁

명의 물결이 공학설계 분야에도 영향을 미쳐, 축적된 데이터와 인공지능을 활용하는 DDD 시대를 열었다. 그러나 실용성이 확인되어 큰 각광을 받고 있는 딥러닝(deep learning)을 이용한 이미지/음성 인식 및 자연어 처리 분야 대비 공학설계 분야를 위한 인공지능의 활용은 현재 시작 단계에 있다. 그런데 산업체에서 생산하는 제품의 경쟁력을 결정하는 공학설계 기술은 매우 중요하므로, 주된 기술인 SBD의 확산과 함께 DDD도 빠른 속도로 발전할 것으로 예상된다.

가상 제품 개발

자동차 업계 및 대학 교수들로 구성된 유럽연합 자동차 기술 개발 협력단에서 2008년 4월에 발표한 VPD 관련 자료를 그림 1에서 볼 수 있다. 자동차의 개념 설계부터 상세 설계까지 모두 가상 환경에서 개발하는 내용으로, 개념 설계 단계에서는 자동차 스타일링 후 가상 개념 모델(virtual concept models)을 이용한 개념 설계용(conceptual) CAE와 통합최적 설계(MDO: Multidisciplinary Design Optimization) 기술을 사용하여 가상 개념 개발(virtual concept

development)을 완수한다. 그리고 개념 설계 단계에서 도출된 기하학적 형상을 사용하여 상세 설계를 위한 CAD 모델을 만들고, 이를 기반으로 한 가상 프로토타이핑(VP: Virtual Prototyping)을 이용한 상세 설계용(detailed) CAE와 MDO 기술을 사용하여 버추얼 시리즈 개발(virtual series development)을 완수하자는 것이다. 이러한 VPD의 핵심은 상세 설계 단계에서는 물론이고, 개념 설계 단계부터 개념 설계용(conceptual) CAE와 MDO를 사용하자는 것으로서 이를 선행 시뮬레이션(up-front simulation) 또는 지식 프론트로딩(knowledge front-loading)이라고 한다. 또한, 그림 1에서 향후 DDD를 위하여 시뮬레이션 데이터 관리(SDM: Simulation Data Management)를 통해 데이터를 축적하자는 것도 매우 중요한 개념이다.

자동차 분야는 물론, 전 세계의 산업체들은 프론트로딩(front-loading)을 적극적으로 구현하자고 한다. 이는, 그림 2에 도시한 바와 같이 제품 개발 절차가 진행됨에 따라 설계 변경 가능성은 급격히 감소하고 변경 비용은 급격히 상승하기 때문이다. 현재 많은 산업체에서는 문제 해결 부하를 상세 설계 단계에 집중하고 있기 때문에 설계 변경 가능성이 낮을 수밖에 없고 이로 인해 설계의 질을 향상 시키는 데 한계가 있으며 변경 비용도 비쌀 수밖에 없다. 이를 개선하기 위하여 개념 설계 단계로 문제 해결 부하를 프론트로딩(front-loading)함으로써 제품 개발 기간 단축과 원가 절감을 실현하고자 하는 것이다.

그런데 VPD를 구현하는 과정에 장애물이 있다. 개념 설계 단계에서는 CAD 모델이 없는 상태에서 다양

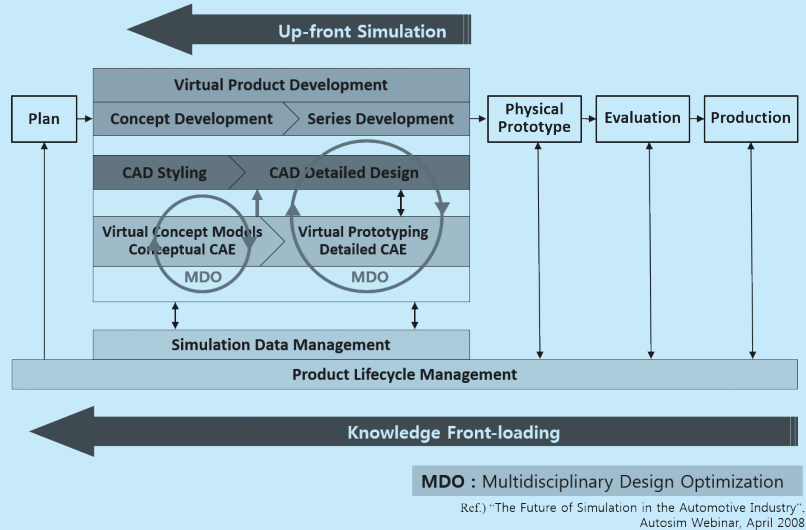


그림 1 VPD(Virtual Product Development) process




그림 2 Front-loading

한 개념 설계안을 빨리 평가하기 위한 매개변수화된 가상 개념 모델(parameterized virtual concept models)을 만들어야 하고, 상세 설계 단계에서는 매개변수화되어 신속한 변경이 가능한 시뮬레이션 모델(parameterized rapid simulation models)을 만들어야 하는데, 이러한 모델 생성이 만만치 않다. 여기서 '매개변수화된 모델(parameterized model)'이란 설계 변수의 변경을 자동적으로 반영하는 기능을 가진 모델을 뜻한다. 가상 개념 모델(Virtual concept models)을 만드는 방법으로는 다음의 네 가지가 있다: ① 물리 기반 일차(first-order) 모델 구축 방법; ② 경험 기반 단순화된 해석 모델 구축 방법; ③ 실제 실험 기반 모델 구축 방법; ④ 축적된 데이터 기반 메

타모델 생성 방법. 처음 두 방법은 물리적인 개념이 반영된 모델이라는 장점이 있으나, 물리적 개념이 확실한 공학자 또는 오랜 기간 경험이 쌓인 공학자만이 만들 수 있어 적용 범위가 제한적이라는 단점이 있다. 세 번째 방법은 실험 결과를 실험식으로 표현하여 실험한 범위 내에서 편리하게 사용할 수 있는 장점이 있으나, 시간과 비용이 많이 드는 문제와 실험할 수 없는 경우에는 적용할 수 없다는 단점이 있다. 네 번째 방법은 기존의 축적된 데이터가 있다면 다양한 지도학습(supervised learning) 기법을 이용하여 해당 데이터의 메타모델(metamodel; surrogate; regression model, approximate model)을 생성하는 방법으로 어느 경우에도 적용할 수 있다는 장점이 있으나, 입력 변수(설계 변수)에 따른 출력 변수(성능지수)가 쌍으로 주어진 레이블된 데이터(labeled data)를 수집한 후 이를 의미 있는 데이터로 가공하는 데이터 전처리(data pre-processing)를 거친 정제된 데이터가 있어야 한다는 전제가 있다. 현재 4차 산업혁명 시대의 도래와 함께 데이터 수집 및 전처리 기술이 크게 발전하고 있으므로, 앞으로는 네 번째 방법인 축적된 데이터 기반 메타모델 생성 방법이 널리 사용될 것으로 예측된다. 한편, 상세 설계 단계에서는 이미 산업체에서 VP를 통한 상세 설계용(detailed) CAE를 활발히 수행하고 있으나, 1회의 상세 설계용(detailed) CAE가 일반적으로 긴 해석 시간을 요구한다는 문제점이 있다. 따라서 설계 변경에 따른 성능의 변화를 빠른 시간 내에 평가해야 하는 설계부서를 위하여 빠르고 정확하게 매개변수화되어 신속한 변경이 가능한 시뮬레이션 모델(parameterized rapid simulation models)을 구축하여야 한다. 이를 위한 방법은 병렬 연산 활용 실험계획법을 적용하여 얻어진 시뮬레이션 데이터 또는 이미 축적된 데이터에 적합한 지도학습 기법을 적용하여 메타모델을 생성하는 방법이 유

일한 방법이다. 즉 개념 설계와 상세 설계 단계 모두의 VPD를 위해 유용하게 사용될 수 있는 방법이 데이터 기반 메타모델 생성 방법이다. 문제는 정확한 메타모델을 생성하여야 하는데, 메타모델 생성 방법은 무수히 많으며, 주어진 데이터에 따라 적합한 메타모델 생성 방법이 다르다는 점이다. 따라서 주어진 데이터에 적응적(adaptive)으로 정확한 메타모델을 생성하려면, 이 분야에 대한 깊은 지식과 전문성이 요구된다. 이러한 인간의 전문성을 컴퓨터로 구현한 ‘메타모델 자율 생성’ 인공지능을 다음 절에 소개한다.

‘메타모델 자율 생성’ 인공지능

통합최적설계(MDO), 실험계획법 이용 최적설계 등을 포함한 공학설계 기술 전문회사인 (주)피도텍은 메타모델 생성 분야에 대한 깊은 지식과 전문성을 바탕으로, 머신러닝 기법 중 지도학습(supervised learning) 기법을 활용하여 ‘메타모델 자율 생성’ 인공지능을 개발하였다. 이 인공지능은 산업체 엔지니어가 정제된 데이터만 제공하면, 제공된 데이터에 가장 적합한 메타모델을 자율적으로 생성해 주는 인공지능으로, ‘BruceMentor for metamodeling’(이하 BruceMentor)이라고 명명하고, PIAAnO¹⁾ 2019에 탑재하였다. 타 PIDO 소프트웨어에서 유사한 기능을 제공한 경우가 있기는 하나, 이는 규칙 기반(rule-based) (또는 지식 기반(knowledge-driven)) 방식의 초기 인공지능 형태이다. 이러한 기능은 개발자가 경험해 본 범위 내에서만 정상적인 작동이 가능하기 때문에, 광범위한 공학설계 상황에 모두 대응할 수 없다는 치명적인 단점을 가지고 있다. 이와 달리, BruceMentor는 다양한 공학설계 상황을 고려하여 방대한 양의 학습 데이터(training data)를 준비하고, 이를 바탕으로 머신러닝 기반의 데이터 기반(data-driven) 방식의 인공지

1) PIAAnO(Process Integration, Automation, and Optimization): (주)피도텍에서 개발한 상용 PIDO(Process Integration and Design Optimization) 소프트웨어

능으로 개발되었다. BruceMentor는 학습 데이터에 없는 공학설계 상황에 대해서도 추론을 통해 가장 적합한 메타모델을 제공해 주므로, 광범위한 공학설계 상황에 모두 대처할 수 있는 진정한 의미의 인공지능이라고 할 수 있다.

주어진 데이터에 가장 적합한 메타모델을 생성할 수 있는 전문성은 다음의 두 가지로 구성된다: 매우 다양한 메타모델 생성 기법 중 적합한 기법을 선택하는 전문 지식; 각 메타모델에 내재된 사용자 지정 파라미터(user-defined parameters; hyperparameters)를 결정하는 전문 지식. 그런데 이 두 전문 지식은 상관성을 가지고 있다. 즉 주어진 데이터에 가장 적합한 메타모델 생성 기법을 선택하였다고 해도 사용자 지정 파라미터를 잘못 설정하면 해당 메타모델의 예측 정확도는 떨어질 수밖에 없다. 반대로 선택한 메타모델 생성 기법의 사용자 지정 파라미터를 아무리 잘 설정하였다고 해도, 메타모델 생성 기법 자체를 잘못 선택하였다면 그 예측 정확도를 더 이상 향상시킬 수 없게 된다. 따라서 최적의 기법과 최적의 사용자 지정 파라미터를 동시에 결정하여야 한다. 최적의 사용자 지정 파라미터를 결정하기 위하여, BruceMentor는 (주)피도텍에서 자체 개발한 ‘하이퍼파라미터 최적화 기법’을 이용하고 있다.

BruceMentor의 핵심 기술 중 하나는 학습 데이터의 특징을 대표할 수 있는 특성(features)을 추출하는 것이다. 이를 위하여, 주어진 데이터에 적합한 메타모델 생성에 영향을 미치는 다양한 통계량을 특성(features)의 후보로 선정한 후, 미미한 영향을 미치는 특성(features)을 포함시킴으로써 야기되는 정확도의 악화를 방지하기 위하여, 머신러닝 기반의 차원 축소(dimensionality reduction)를 수행하여 최종 특성(features)을 결정하였다.

PIAnO 2019에 탑재된 BruceMentor는 476,585개의 레이블된 데이터(labeled data)를 활용하여 개발된 것이다. 광범위한 공학설계 상황을 모두 대처하

기 위하여, 이들은 매우 다양한 수학/공학 함수 및 산업체에서 실제로 사용하고 있는 CAE 해석 모델로 구성되어 있다. 또한 데이터가 어느 한 특성으로 편중되는 것을 방지하기 위하여, 다양한 설계변수 개수와 다양한 샘플링(sampling) 방법으로 지정한 다양한 실험점 개수를 사용함은 물론, 함수 및 CAE 모델의 선택에도 신중을 기하였다. PIAnO 2019에 탑재된 BruceMentor는 학습 데이터(training data)의 경우 99.8%의 정확도를, 그리고 시험 데이터(test data)의 경우 87.1%의 정확도를 보였다. 정제된 데이터를 가지고 있는 산업체 엔지니어가 이러한 성능을 가진 BruceMentor를 활용하면 가상 제품 개발(VPD)을 수행하는 데 도움이 될 것으로 기대한다.

요약 및 향후 개발 방향

이 글은 공학설계 기술의 메가트렌드와 공학설계 기술 발전에 따라 대두된 가상 제품 개발(VPD)의 중요성과 장애물, 그리고 VPD의 장애물을 넘을 수 있는 핵심 기술 중 하나로 산업체 엔지니어들이 손쉽게 사용할 수 있도록 개발된, ‘메타모델 자율 생성’ 인공지능 ‘BruceMentor for Metamodeling’을 소개하였다.

현재 (주)피도텍에서는 1,244,756개의 데이터를 활용하여 ‘BruceMentor for Metamodeling’의 정확도를 더 높이는 작업을 하고 있다. 또한, 공학설계를 위하여 중요한 ‘BruceMentor for Sampling’과 ‘BruceMentor for Optimization’도 개발할 계획이다. 그리고 궁극적으로 다양한 공학설계 기법을 적재적소에 배치하여 설계자가 원하는 설계 요구 조건을 모두 만족시키는 최적의 설계안을 자동으로 도출해주는 인공지능을 개발함으로써, 공학설계 분야에서 인간의 전문성을 잘 반영한 진정한 의미의 인공지능을 산업체 엔지니어를 위하여 제공하고자 한다.

위상최적설계와 인공지능망을 이용한 골격계 의료영상 해상도 향상법

김 정 진 한국과학기술원 조천식녹색교통대학원 연구조교수

| e-mail : kjj4537@kaist.ac.kr

유 용 균 한국원자력연구원 미래전략연구부 선임연구원

| e-mail : ygju@kaeri.re.kr

장 인 권 한국과학기술원 조천식녹색교통대학원 부교수

| e-mail : igjang@kaist.edu

이 글에서는 위상최적설계와 인공지능망을 이용하여, 정확성과 신속성이 개선된 골격계 의료영상 해상도 향상법에 대해 간략히 소개한다.

고해상도 골격계 의료영상은 환자의 골밀도(골량)뿐만 아니라 골 미세구조(골질) 정보까지 제공 가능하여 높은 정확도의 골 건강 진단을 가능케 한다. 특히, 유한요소 해석과 연계한 고해상도 골 미세구조 영상 기반의 골 강도 측정법은 정량적인 골 강도를 제시할 수 있어 임상에서 큰 관심을 받고 있다. 일반적으로 골 미세구조를 촬영하기 위해서는 미세구조의 평균 두께인 $100\mu\text{m}$ 이상의 높은 공간 해상도가 요구된다. 하지만, 임상에서 촬영 가능한 영상의 해상도는 방사선 노출량 때문에 $300\text{--}600\mu\text{m}$ 로 제한되어 있어, 골 건강 진단 시 골 미세구조 정보의 고려가 불가능한 상황이다.

인공지능망 기반 골격계 의료영상 해상도 향상법

최근 하드웨어의 발전 및 새로운 알고리즘 개발에 따라 인공지능망 기반 영상처리법의 비약적인 발전

인공지능망은 충분한 학습을 통해 신속한 해상도 향상을 구현할 수 있지만, 골격계 영상 해상도 향상의 경우에는 부족한 학습 데이터로 인해 낮은 정확도를 가진다.

이 이루어져 왔다. 특히, 합성곱 인공지능망(convolutional neural network)의 고해상화 능력은 여러 분야에서 입증되어 활발히 사용되고 있다. 저해상도 입력 영상과 고해상도 출력 영상이 충분히 학습된 합성곱 인공지능망은 저해상도 영상을 매우 신속하게 고해상화할 수 있다. 다만, 신경망 학습에 필요한 고해상도 임상 영상 부족으로 이 기술을 통한 골격계 영상의 해상도 향상법은 임상 분야에서 직접적인 활용이 어려운 상황이다.

위상최적설계 기반 골격계 의료영상 해상도 향상법

최근 $600\mu\text{m}$ 급 임상 영상으로부터 $50\mu\text{m}$ 급 골 미세구조 영상을 재구성할 수 있는 위상최적설계 기반 골격계 의료영상 해상도 향상법이 개발되었다. 이 방법은 기존의 영상처리기법 기반 해상도 향상법들과 달리, 구조적 거동 정보 바탕의 영상 픽셀값(골밀도)

들의 반복적인 재분배를 통해 주어진 질량 조건 하에서 최대의 강성을 가지는 골 미세구조를 결정하는 기술이다. 이 해상도 향상법은 2차원 600 μm 인공 근위 대퇴골 영상을 50 μm 급 골 미세구조 영상으로 고해상도화하여 원본 영상 대비 최소 94% 이상의 구조적 유사성을 보인다(그림 1). 하지만 반복적 구조적 거동 계산으로 인한 과도한 처리 시간은 이 방법의 임상 분야로의 적용을 어렵게 하고 있다.

위상최적설계와 인공지능망을 이용한 골격계 의료영상 해상도 향상법

위상최적설계와 인공지능망은 골격계 의료영상 해상도 향상에서 상호보완적인 관계를 가지고 있다. 위상최적설계는 높은 고해상도 정확성을 가지지만 낮은 계산 효율을 가진다. 반면, 인공지능망은 높은 계산 효율을 갖지만 낮은 고해상도 정확성을 가진다. 이 글에서는 위상최적설계와 인공지능망의 상호보완적인 관계를 이용한 골격계 의료영상 해상도 향상법에 대해 간략히 소개하고자 한다.

학습 데이터 구성

첫째, 학습 데이터 구성을 위해 위상최적설계는 서로 다른 하중 조건과 질량 제한 조건 내에서 고해상도 골 미세구조 영상들을 생성한다. 예를 들어 다양한 환자에 따른 걸음걸이와 골량을 고려한 영상들을 생성한다. 이어서 효율적 고해상도화를 위해 생성된 고해상도

위상최적설계는 해상도 향상을 통해 정확도 높은 고해상도 골 미세구조 영상을 제공할 수 있지만, 과도한 처리 시간을 문제점으로 가진다.

영상들을 관심영역 영상들로 분할하고 고해상도 학습 데이터를 구성한다. 또한 고해상도 관심영역 영상들을 다운스케일링(down-scaling)하여 해당 저해상도 학습 데이터로 구성한다. 이 글에서는 서로 다른 11개의 근위 대퇴골 고해상도(50 μm 해상도) 영상들을 위상최적설계를 통하여 생성하고, 1.5cm \times 1.5cm 크기의 관심영역 영상들로 분할하여 총 11,000개의 영상 데이터를 구성하였다(그림 2). 이어서 고해상도 영상 데이터를 12배 다운스케일링하여 저해상도 영상(600 μm 해상도) 데이터로 구성하였다. 총 11,000개의 데이터 중 10,000개는 학습 데이터로 할당하고 1,000개는 검증 데이터로 할당하였다.




그림 1 위상최적설계 기반 골격계 의료영상 해상도 향상법 적용 예

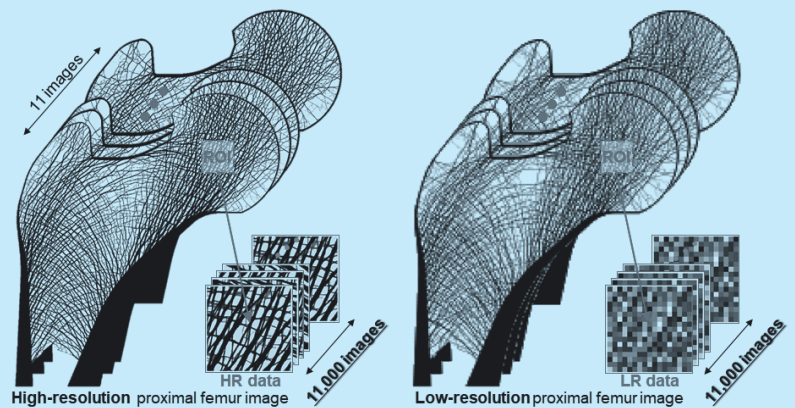


그림 2 고해상도와 저해상도 학습 데이터 구성의 예

인공신경망 구성

둘째, 생성된 데이터를 학습하기 위한 인공신경망을 구성한다. 이 글에서는 새로운 인공신경망 개발 대신 기존의 간단한 U-net 합성곱 인공신경망 활용하여 구성하였다(그림 3). U-net 합성곱 인공신경망은 오토인코더(autoencoder) 인공신경망의 확장된 구조로 입력 데이터의 인코딩(encoding) 단계에서 추출되는 특징점들을 디코딩(decoding) 단계에서 사용하는 것이 특징이다. 다시 말해, 인코딩을 통해 최종적으로 차원 축소된 저해상도 정보부터 고

골격계 영상 해상도 향상법의 높은 정확성과 신속성은 위상 최적설계와 인공신경망의 상호보완적인 관계를 이용하여 구현할 수 있다.

해상도 영상으로 복원할 시 이전의 차원 축소 단계들에서 추출된 정보를 이용하는 것을 의미한다. 이는 차원 축소로 인한 공간 정보 손실을 방지하여 인공신경망을 통한 해상도 향상의 능력을 극대화할 수 있다.

인공신경망 학습 및 검증

셋째, 생성된 데이터를 인공신경망에 학습을 시킨다. 이 글에서는 신경망의 과적합(overfitting)을 피하기 위해 배치 정규화(batch normalization)와 드롭아웃(dropout)을 사용하였다. 또한 학습 기울기 소실 문제(gradient vanishing problem)를 피하기 위해 활성화 함수로 Rectified linear unit (Relu)을 사용하였다. 손실 함수로는 평균 절대 오차를 사용하였다. 학습된 인공신경망 성능 검증은 학습에 관여하지 않은 이전에 생성한 1,000개의 검증 데이터로 수행하였다.

이 글에서 소개하는 방법은 위상최적설계를 통해 학습 데이터를 구성하고, 이를 인공신경망으로 충분히 학습시켜 정확하고 신속한 골격계 의료영상 해상도 향상을 구현한다. 실례로 이 방법은 인공신경망 학습에 사용되지 않은 1.5cm×1.5cm 크기의

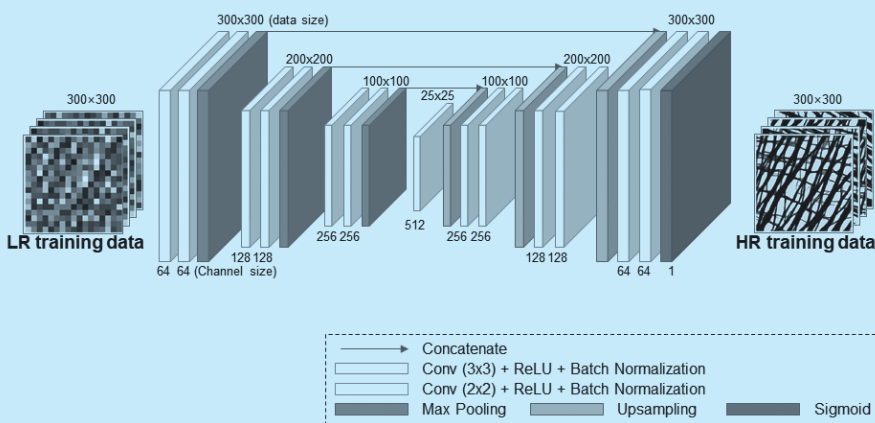


그림 3 골격계 의료영상 해상도 향상법을 위한 인공신경망의 예: U-Net Convolution Neural Network

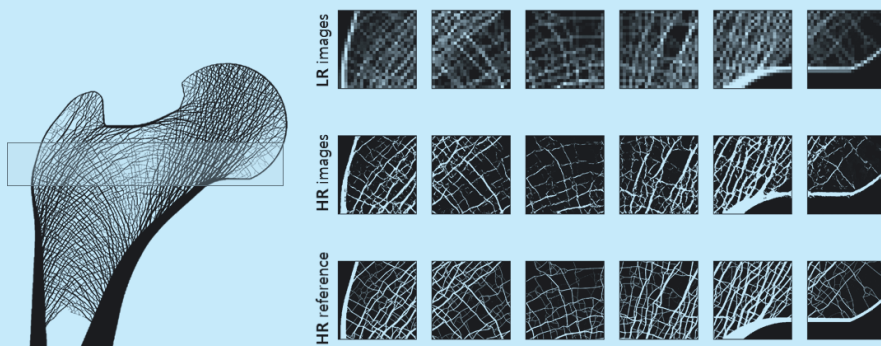


그림 4 위상최적설계와 인공신경망을 이용한 골격계 의료영상 해상도 향상법의 예

1,000개의 저해상도 영상에 대해 94% 이상의 높은 유사성을 가지고 해상도 향상을 실현하였다(그림 4). 또한 해상도 향상 처리 시간이 최대 10초로, 기존(최소 1시간) 대비 상당한 계산 효율성의 개선을 보였다. 이러한 결과들은 위상 최적설계와 인공지능망의 상호보완적 관계를 통해 골격계 영상 해상도 향상법의 정확성과 신속성을 개선할 수 있음을 의미한다.

기대효과

골다공증성 골절의 유병률은 사회 고령화에 따라 지속적으로 증가하고 있으며, 이에 따른 막대한 사회·경제적 손실이 주요 사회문제로 대두되고 있다. 미국의 경우, 골다공증성 골절에 의한 의료비용이 매년 180억 달러에 달하며, 골절 위험군의 수는 2040년까지 전 세계적으로 3억 명이 넘어설 것으로 보고되고 있다. 이 글에서 소개한 해상도 향상법을 통해 정확하고 신속한 골 강도의 진단이 가능할 경우, 골절에 따른 사회·경제적 지출비용의 감소 및 과진단/오진단에 따른 의료비용 절감을 기대할 수 있다.

세계 의료기기 시장의 급성장에 따라, 선진국들은 관련 산업을 전략적으로 육성하고 있으며, 법률 제정 등을 통해 후발국가 및 업체의 진입을 견제하고 있다. 국내 역시 의료기기를 고부가가치 산업으로 인식하고, 차세대 성장 동력 산업의 중점육성기술로 선정하

사회 고령화 시대에서 신속성 및 정확성이 개선된 골격계 의료영상 해상도 향상법은 의료영상기기 시장에서 차세대 핵심기술로 발전할 수 있다.

여 경쟁력을 향상시키고자 추진하고 있다. 다만, CT 및 MRI 관련 분야는 기술 경쟁력이 낮은 상황(세계 최고 수준 대비 3.8년)으로 95% 가량을 수입에 의존하고 있는 실정이다. 하지만 위상최적설계와 인공지능망으로 신속성 및 정확성이 개선된 골격계 의료영상 해상도 향상법은 IT와 BT의 융합형 원천 기술로, 실용화할 경우 의료영상기기 시장에서 차세대 핵심 기술로 부각될 수 있다.

맺음말

이 글에서는 위상최적설계와 인공지능망을 이용하여 높은 정확성과 신속성을 가지는 골격계 영상 해상도 향상법에 대해 소개하였다. 다만 이 글에서 예제로 사용한 U-net 합성곱 인공지능망은 간단한 구조임에도 불구하고 높은 영상 고해상화 성능을 보였다. 추후 인공지능망 구조와 손실함수에 대한 개발이 이루어진다면 더욱 신속성 및 정확성이 개선된 해상도 향상법을 통해 골 건강 진단의 정확도를 크게 향상시킬 수 있을 것으로 기대한다.

감사의 글

본 연구는 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2017R1A2B4011760).