

# 인공지능 기반 모빌리티 설계: Deep Generative Design

나니아랩스·한국과학기술원 | 신동주·권용민·강남우\*

## 1. 서론 - 인공지능 기반 설계 (Deep Generative Design)

자동차 산업이 모빌리티 산업으로 영역을 확장하고 자율주행과 전동화 시대로 전환되면서, 신개념의 모빌리티 개발을 위한 더 빠르고 더 스마트한 설계기술이 요구되고 있다. 특히 인공지능의 급속한 발전과 함께, 과거의 물리 및 경험 기반의 전통적인 설계 프로세스를 벗어난 데이터 주도의 설계기술들이 더욱 주목받고 있다.

<그림 1>과 같이 과거의 차량 설계는 시작/시험을 통해 성능을 평가하고 설계개선을 반복 수행하는 방법으로 진행이 되었지만, 현재의 차량 설계는 컴퓨터를 이용한 모델링 및 해석 시뮬레이션을 통해 시작차를 만들기 이전에 품질과 성능을 확인하고 최적화하여 시작/시험에 소요되는 비용과 시간을 크게 줄일 수 있었다. 최근에는 인공지능이 데이터 기반으로 기존의 모델링 및 해석 시뮬레이션 또는 시험에 소요되는 시간과 비용마저 최소화할 수 있게 되었으며, 설계/해석에 필요한 전문인력에 대한 의존성을 낮출 수 있게 되면서, 전문인력이 부족한 중소기업도 설계 프로세스를 혁신할 수 있을 것으로 기대되고 있다.

현재 많이 사용되고 있는 CAE(Computer-aided Engineering) 기반의 설계 프로세스는 다음과 같은 문제점을 가지고 있다.

- 디자인/설계/해석의 순차적이고 반복적인 프로세스에 의한 개발 시간과 비용의 증가
- 과거에 축적된 디자인/설계/해석 데이터를 효과적으로 활용하지 못함
- 과거 경험 바탕의 설계로 인해 새롭고 다양한 설계안을 탐색하고 평가하기 어려움
- 심미성, 가격 등 고객(시장)이 중요시하는 디자인

요구사항을 고려하지 못함

- 설계/해석 전문 인력에 대한 의존도가 높아 중소기업의 활용이 어려움

이러한 문제점을 해결하기 위해 데이터와 딥러닝을 통해 설계 프로세스를 혁신할 수 있는 인공지능 기반 제너레이티브 디자인(Generative Design) (Oh et al., 2019; Yoo et al., 2021; Jang et al., 2022) 기술들이 나타나고 있다. 제너레이티브 디자인은 컴퓨터를 이용하여 독창적이고 효율적이고 생산 가능한 디자인들을 자동 생성하는 모든 기술을 의미하며 (Shea et al., 2005; Krish, 2011), 최근 제너레이티브 디자인에 딥러닝 기술이 결합되어 새로운 인공지능 설계 패러다임이 열리고 있다. 인공지능 기반 제너레이티브 디자인은 공학설계의 도메인 지식을 기반으로 해야 하는 산업 인공지능 기술이며, 모빌리티 뿐 아니라 모든 제조산업의 신제품 개발을 위해 적용할 수 있는 데이터 기반의 가상제품개발(Virtual Product Development) 기술이다.

<그림 2>는 나니아랩스(Narnia Labs, 2022)에서 제시하는 Deep Generative Design 프로세스를 보여준다. Deep Generative Design은 설계안의 생성, 평가, 최적화, 추천의 4단계로 구성되며 단계별 목적과 효과는 아래와 같다.

- (1) 설계 생성 단계: 인공지능 기반 위상최적화, 파라메트릭 디자인, 생성모델(Generative Model)을 이용하여 대량의 새로운 설계안들을 자동 생성하는 과정이다. 인공지능이 과거 데이터와 닮으면서도 공학적으로 우수한 대량의 컨셉 설계안들을 제공하여 디자이너/설계자들에게 새로운 영감을 줄 수 있다.
- (2) 설계 평가 단계: 생성된 설계안들에 대해 인공지능 기반의 CAE/CAM 기술을 이용하여 공학적 성능, 제조 가능성, 제조 비용, 독창성 등을 실시간으로 예측하는 과정이다. 설계안들에 대한 성능을 실시간으로 평가할 수 있기 때문에, 해석/

\* 정회원




그림 1 차량 설계 패러다임 변화

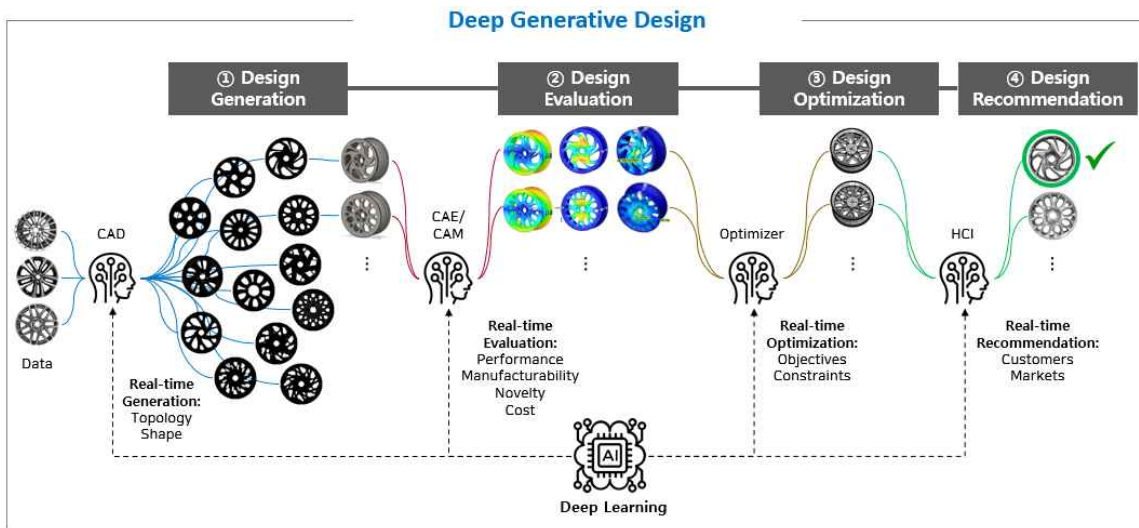


그림 2 Deep Generative Design (Narnia Labs, 2022)

시험에 소요되는 시간과 비용을 혁신적으로 단축할 수 있으며, 디자인/설계/해석의 순차적이고 반복적인 프로세스를 최소화할 수 있다.

- (3) 설계 최적화 단계: 목표 성능과 제약조건을 만족시키는 최적 설계안을 인공지능을 통해 도출하는 과정이다. 디자이너/설계자가 제품의 목표 성능 값들을 입력하면, 이를 최대화하는 최적 설계안들을 실시간으로 생성하고, 성능지표별로 상충되는 최적설계 결과를 비교 분석할 수 있다.
- (4) 설계 추천 단계: 최적화된 설계안들에 대해 인공지능으로 고객의 선호도를 예측하고 목표 시장에 맞는 설계안을 추천하는 과정이다. 공학성능, 비용, 고객의 선호도(심미성, 가격 등)의 상충관계를 분석 및 시각화하여 기업을 위한 최적의사결정을 할 수 있도록 한다.

다음 섹션부터는 앞에서 소개된 Deep Generative Design의 4가지 단계별 대표 연구들과 차량 시스템/부품 설계에 적용된 사례들을 소개한다.

## 2. 인공지능 기반 설계 생성 (Design Generation + AI)

설계 생성 단계에서는 역학 기반의 제너레이티브 디자인과 데이터 기반의 딥러닝의 장점을 결합하여 공학적이면서 심미적으로 의미 있는 대량의 디자인들을 자동 생성한다. 특히 공학설계의 위상최적화 및 파라메트릭 디자인 기술들은 딥러닝과 유기적으로 결합하여 시너지를 낼 수 있다.

Oh et al. (2019)는 과거 디자인 데이터를 레퍼런스로 입력하면, 주어진 볼륨 조건 내에서 구조물의 강성을 최대화함과 동시에 레퍼런스와의 거리를 최소화하여, 과거 디자인과 비슷하면서도 구조적으로 더 우수한 디자인을 생성한다 (그림 3). 이때 위상최적화에 필요한 파라미터를 다양화함으로써 하나의 레퍼런스 디자인에 대해 다양한 디자인을 생성할 수 있고, 생성된 데이터를 심층생성모델을 통해 학습하여 새로운 디자인을 재생성하면 이를 다시 위상최적화의 레퍼런스 디자인으로 활용하는 반복적인 생성과정을 거치게 된다. 이를 통해 소량의 디자인 데이터를 이용해서 대

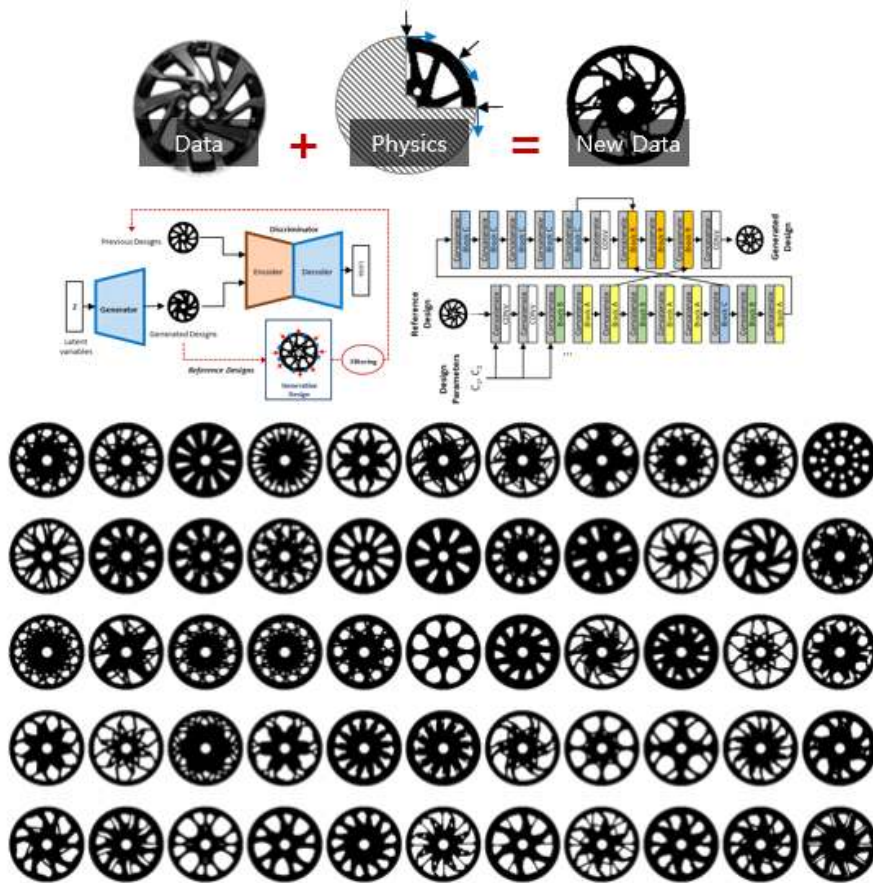


그림 3 위상최적화와 딥러닝의 결합을 통한 휠 디자인 생성 (Oh et al., 2019; Jang et al., 2022)

량의 새로운 디자인을 생성해낼 수 있다. Jang et al. (2022)은 제너레이티브 디자인의 중요한 목적인 설계 다양성을 최대화하기 위해 강화학습을 수행하였다. 위상최적화 알고리즘을 딥러닝 모델로 대체하고, 이를 환경으로 삼아 디자인 공간에서 다양성을 최대화할 수 있는 설계안들을 순차적으로 탐색해 나갈 수 있는 강화학습 프로세스를 제시하였다.

제품의 공학적 성능평가를 위해서는 3D 기반의 해석이 수행되어야 한다. 이를 위해 Shin et al. (2021)은 양산 휠의 단면 데이터를 자동 수집하여 이미지 변환 후 심층생성모델로 학습하여 새로운 휠 단면 이미지들을 생성하였다. 이후 휠 디스크 뷰 이미지와 휠 단면 이미지를 조합하여 3D CAD를 생성하는 3D 모델링 자동화 프로세스를 제시하였다 (그림 4). 또한 Shin et al. (2022)은 생성된 3D CAD 데이터를 3D 생성모델로 재학습하여 3D 데이터를 효과적으로 보간(Interpolation)할 수 있음을 보여주었다. 이러한 기술들을 통해 인공지능 학습을 위한 수천 개의 3D CAD 데이터를 자동 수집할 수 있으며, CAE 시뮬레이션을 통해 오토라벨링(Auto labeling)을 수행할 수 있

게 된다.

실제 산업 현장의 인공지능 도입 또는 디지털 전환에 있어 가장 큰 장벽 중 하나는 학습용 3D 데이터의 부족 현상이며, Deep Generative Design의 설계 생성 기술은 이에 대한 해결책을 보여주고 있다.

### 3. 인공지능 기반 설계 평가 (Design Evaluation + AI)

설계 평가 단계는 새로운 설계안이 만족해야 하는 다양한 설계 요구사항에 대하여 실시간으로 예측할 수 있는 딥러닝 모델을 구축하는 단계이다. 앞에서 생성된 컨셉 설계안에 대해서 공학적 성능, 제조성, 제조 비용, 독창성 등을 예측할 수 있다. 특히 해석/시험 결과 데이터를 학습한 딥러닝 모델은 기존의 해석/시험 과정에 소요되었던 시간과 비용을 혁신적으로 줄일 수 있다. 새로운 디자인/설계에 대한 공학성능이 실시간으로 예측되면, 디자이너와 엔지니어간의 순차적이고 반복적인 작업 프로세스 없이도 대량의 컨셉 설계안에 대한 빠른 검토가 가능해진다.

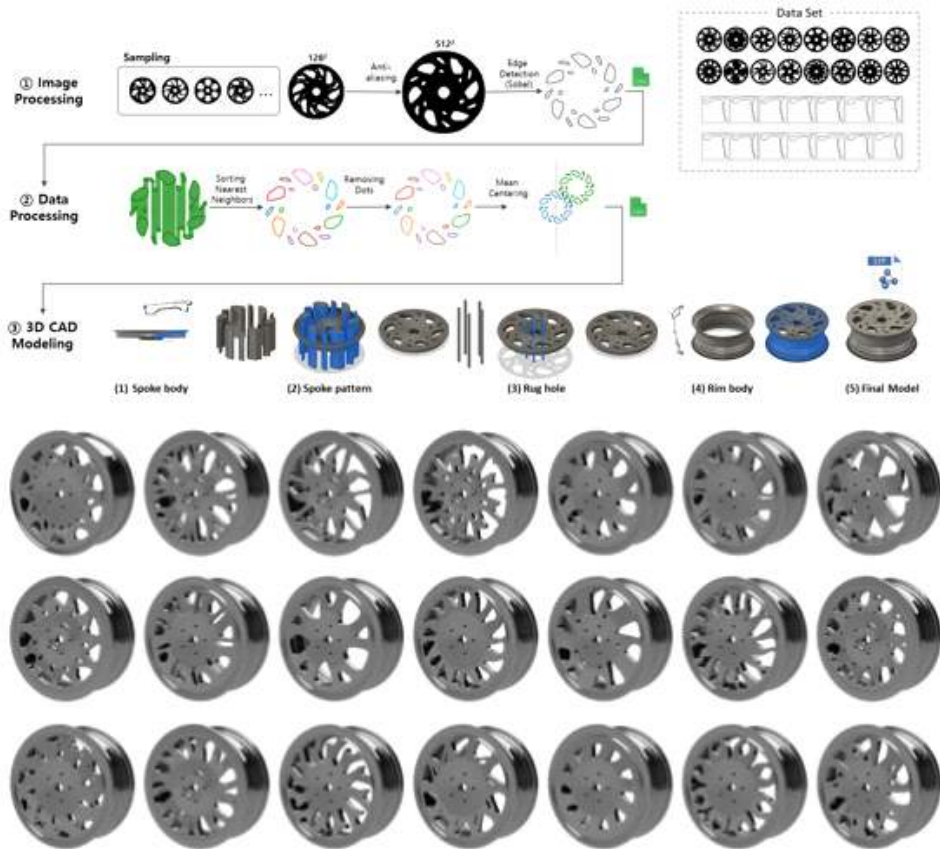




그림 4 데이터 기반 3D CAD 생성 자동화 프로세스 (Shin et al. 2021; Yoo et al., 2021)



(a) Visualization of latent space with natural frequency (red: high frequency, blue: low frequency)



(b) Result of Grad-CAM for natural frequency

그림 5 설명 가능한 인공지능을 이용한 딥러닝 예측 결과 시각화 (Yoo et al., 2021)

Yoo et al. (2021)는 자동차 휠의 고유진동수를 통해 강성을 예측하기 위한 딥러닝 프로세스를 제시하였다. 딥러닝의 정확도를 높이기 위해 휠 이미지 데이터의 형상을 비지도로 학습한 차원 축소 모델의 인코더를 전이

학습용으로 활용하였으며, 복수의 모델을 결합하는 앙상블을 사용하였다. 특히 설명 가능한 인공지능 기술을 통해, 데이터 주도 모델이 물리적 의미를 설명할 수 있음을 보여줌으로써 엔지니어의 딥러닝 사용에 대한 신

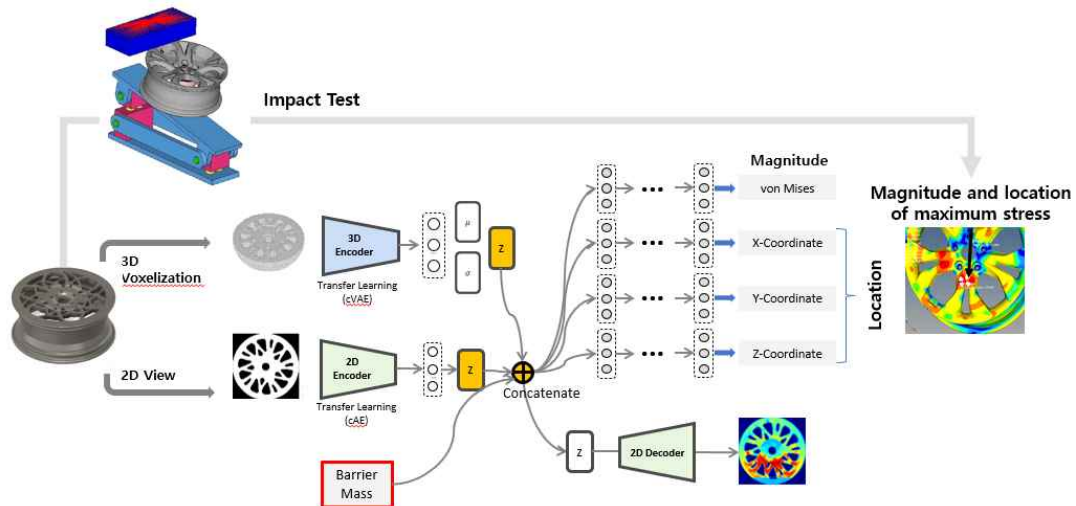


그림 6 3D 딥러닝 기반의 최대응력 위치 예측 (Jin et al., 2021)

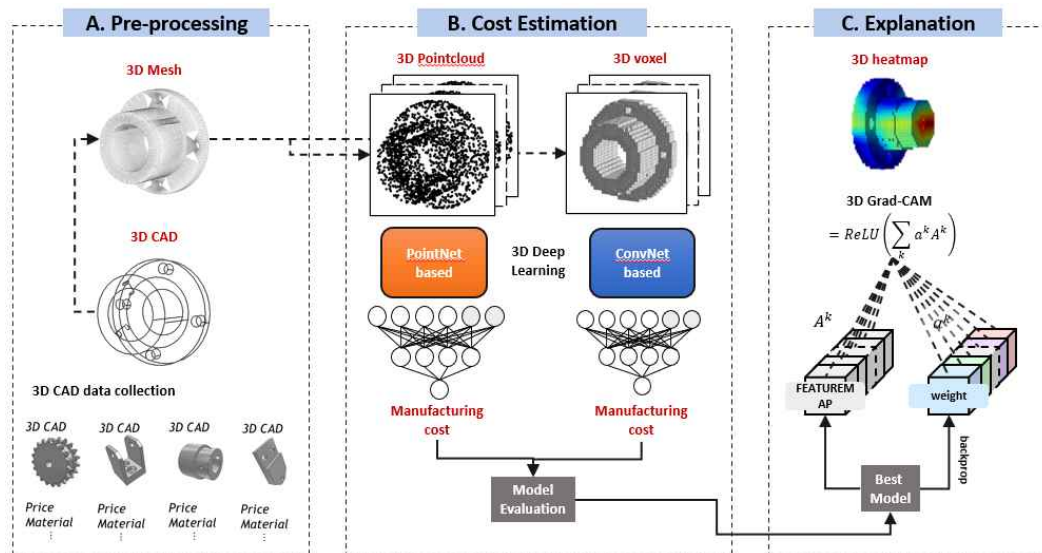


그림 7 3D 딥러닝 기반의 제조원가 예측 (Yoo & Kang, 2021)

력을 높여 주었다. 예를 들어 그림 5의 (a)에서 인코더의 잠재 공간에서 데이터가 공학성능에 따라 분포되어 있음을 통해, 딥러닝이 성능에 영향을 주는 형상 특징을 잘 추출했음을 보여주었다. 그림 5(b)에서는 고유진동수에 영향을 주는 위치를 Grad-CAM으로 시각화하였고, 실제 도메인 지식과 매칭됨을 확인할 수 있었다.

Jin et al., (2021)은 강도 예측 딥러닝 연구로써, 자동차 휠의 충격 해석을 대체할 수 있는 3D 딥러닝 모델을 제시하였다 (그림 6). 휠에 충격이 가해졌을 때 응력이 가장 크게 발생하는 위치와 크기를 확인하는 시뮬레이션을 하기 위해서는 상당한 모델링 및 해석 시간이 소요된다. 이 연구는 이러한 과정을 실시간으로 수행하기 위해, 해석 자동화를 통해 응력 분포 데이터를 생성하고, 3D 복셀 데이터와 2D 디스크 뷰 이

미지 데이터를 입력으로 하는 멀티모달 딥러닝 아키텍처를 구축하였다. 이때 딥러닝은 최대 응력값과 해당 위치의 x, y, z축 좌표를 예측하고, 전체적인 응력 분포 결과 이미지를 함께 생성한다. Park et al. (2022)은 휠의 성능을 예측하기 위해 3D Mesh 데이터와 Graph Neural Network(GNN)을 활용한 딥러닝 모델을 제시하였으며, Kwon et al. (2022)는 생성 휠 데이터 (Source domain)를 이용하여 실제 휠 데이터(Target domain)의 성능을 잘 예측할 수 있는 도메인 적응 기법들을 제시하고 성능 결과를 비교 분석하였다.

신제품 개발 프로세스에서 원가 절감을 위한 재설계 과정은 많은 시간과 비용을 초래한다. 이를 해결하기 위해 Yoo & Kang (2021)은 절삭가공 부품 데이터를 이용하여 제조원가를 예측하는 3D 딥러닝 모델을

제시하였으며, 형상에 따른 원가 상승 위치를 설명 가능한 인공지능인 3D Grad-Cam으로 시각화하였다 (그림 7). 3D 카드 데이터를 포인트 클라우드와 복셀로 전처리하여 입력으로 사용하고, 네트워크 중간에 부피와 재료 물성치값을 입력해 최종적으로 제조원가를 예측하는 구조의 모델이 제시 되었다. 설명 가능한 인공지능으로 제조원가에 민감한 CNC 가공 특징을 잘 감지하는 것을 확인하였으며, 데이터 기반 모델의 결과가 CNC 도메인 지식과 매칭됨을 보여주었다.

이처럼 Deep Generative Design의 설계 평가 기술은 공학성능 및 제조원가 예측을 통해 개발 프로세스 초기에 빠르게 문제점을 찾고 개선할 수 있도록 함으로써, 개발 프로세스 말기에 발생하는 설계변동으로 인한 시간과 비용을 최소화할 수 있다.

#### 4. 인공지능 기반 설계 최적화 (Design Optimization + AI)

설계 최적화 단계는 인공지능이 최적설계안을 실시간으로 도출하는 단계이다. 기존의 순차적으로 해를 찾는 전통적인 최적설계 기법의 높은 계산비용을 줄이기 위해, 인공지능을 이용하여 실시간으로 해를 찾을 수 있는 딥러닝 기반 역설계 기법이 제시되고 있다 (Liu et al., 2018). 딥러닝 기반 역설계(Inverse Design) 기법은 성능 예측 모델과 반대로 목표 성능을 입력으로 주면 이를 만족하는 설계안을 결과물로 생성해낸다.

딥러닝 기반 역설계는 지도학습과 비지도학습의 두 가지 접근으로 가능하며, 설계 문제의 특성과 목적에 따라 적합한 방법을 선택해야 한다 (Jwa et al., 2021). Kim et al. (2021a)은 자동차 브레이크 시스템 설계에 대해 복수의 성능지표를 만족할 수 있는 다분야 통합 역설계 기법을 제시하였다 (그림 8). 브레이크 설계 파라미터에 대한 성능을 예측하는 Forward network를

학습 후에, 목표 성능을 만족하는 설계 파라미터를 생성하는 Inverse network를 Forward network 앞단에 붙여 재학습한다. 학습이 완료된 후에 Inverse network는 목표 성능을 입력하면 최적화된 설계 파라미터를 출력으로 생성할 수 있게 된다. Kim et al. (2021b)은 비지도학습인 Conditional generative adversarial network (cGAN)과 Variational autoencoder (VAE)를 Forward network와 결합한 브레이크 시스템 최적화를 수행하였다. 비지도학습의 구조에서는 목표 성능 값을 조건으로 입력하면 성능을 만족하는 최적설계안을 생성할 수 있으며, 이때 지도학습 기반 역설계와의 차이점은 동일 성능에 대해서 다양한 설계안을 생성할 수 있다는 점이다.

Jin et al. (2022)은 TV 스탠드를 위한 역설계 방법을 제안하였으며 이는 강도 평가가 필요한 다양한 자동차 부품에 확장 적용이 가능하다. TV 스탠드 설계 파라미터 값을 입력으로 하여 낙하 충격에 따른 최대 응력 값과 무게를 예측하는 Forward network를 학습한 후, 최대응력값이 허용응력을 넘지 않도록 하면서 스탠드의 무게가 최소가 될 수 있도록 최적화하는 Inverse network를 학습하였다.

이러한 Deep Generative Design의 설계 최적화 단계는 딥러닝 기반 역설계 기법을 통해, 높은 계산비용을 필요로 하는 전통적인 최적설계와 달리 실시간으로 설계 최적화 결과를 도출할 수 있도록 하며, 다양한 성능 예측 모델을 병렬로 활용하는 다분야 최적설계가 가능하다는 점에서 큰 확장성을 보여준다.

#### 4. 인공지능 기반 설계 추천 (Design Recommendation + AI)

설계 추천 단계에서는 공학적으로 최적화된 설계안들에 대한 고객의 선호도를 예측하고 타겟 고객에게

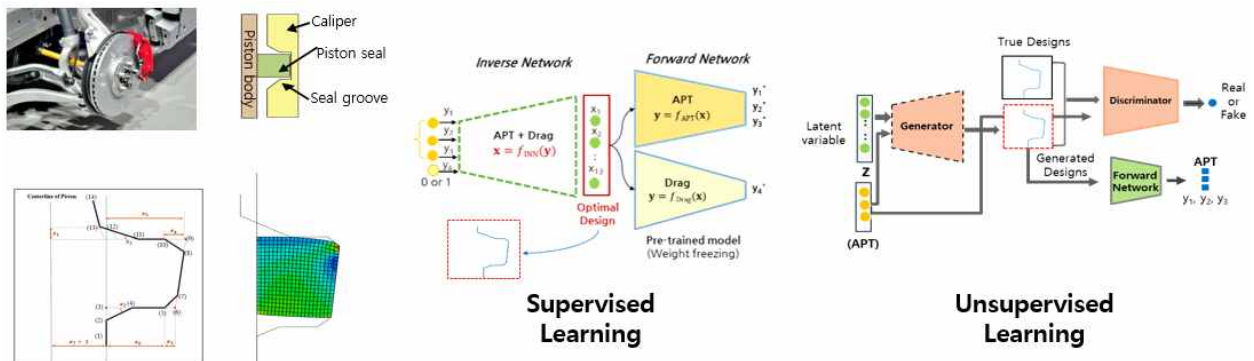


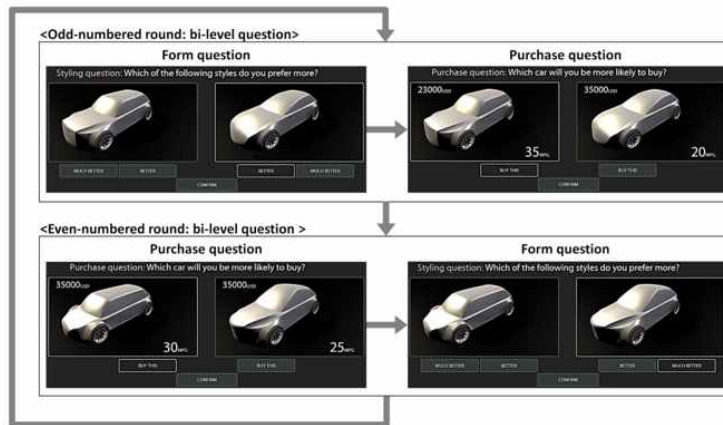
그림 8 딥러닝 기반의 디스크브레이크 시스템 역설계 (Kim et al., 2021b, 2021b)

맞춤형 디자인을 추천한다. 특히 제품의 심미성은 소비자의 제품 선택에 영향을 주는 가장 중요한 요인 중 하나이며, 디자인과 성능의 상충 문제를 해결하고 최적의 디자인 컨셉을 결정하기 위해 고객의 디자인 선호도 반영은 필수적이다. 하지만 고객의 선호도는 인간의 주관적인 감성의 영역이기 때문에 비선형적일 뿐 아니라 같은 디자인에 대해 개인별로 다르게 나타나기 때문에 학습의 난이도가 매우 높다.

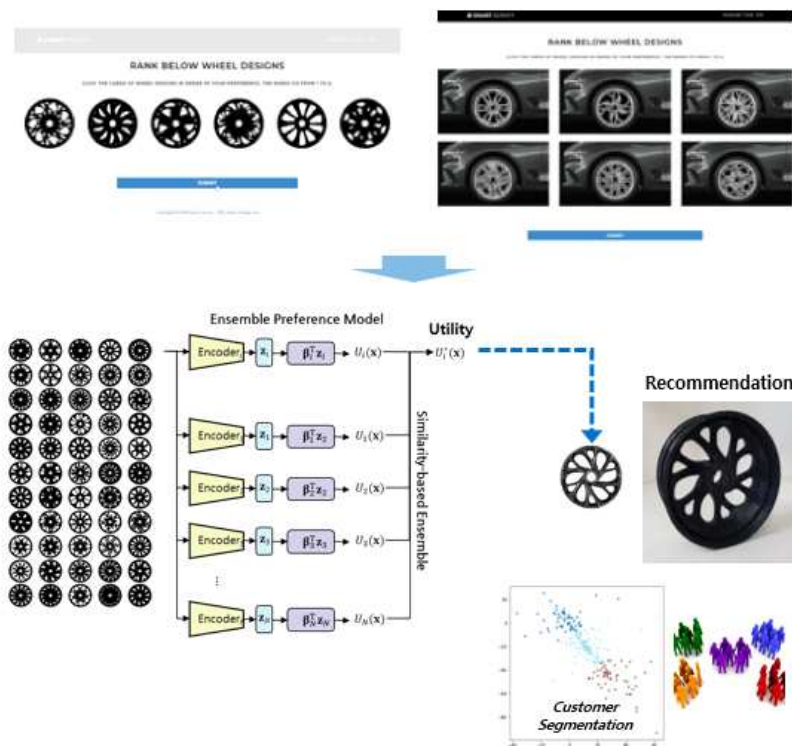
Kang et al. (2019)는 차량의 스타일과 기능에 대한 고객의 선호도를 하나의 모델로 학습할 수 있는 머신

러닝 기법을 제시하였다. 온라인으로 3D 자동차 디자인을 생성하여 고객에게 제시하고, 고객의 선택에 따라 다음 3D 디자인을 생성하여 고객의 선호도를 학습해 나가는 액티브 러닝(Active learning) 기법을 구현하였다 (그림 9(a)). 이를 통해 고객별 가격, 성능, 디자인 등의 요소에 대한 선호도를 예측할 수 있고, 목표 시장을 위한 최적의 디자인을 추천할 수 있다.

Lee & Kang (2020)은 심미성 학습에 딥러닝을 적용하여, 휠에 대한 고객의 선호도를 예측하고 추천하는 프로세스를 제안하였다 (그림 9(b)). 2D 휠에 대한



(a) Active Learning Process



(b) Recommendation System

그림 9 딥러닝/머신러닝 기반 개인별 선호도 학습과 추천 시스템 (Kang et al., 2019; Lee & Kang, 2020)

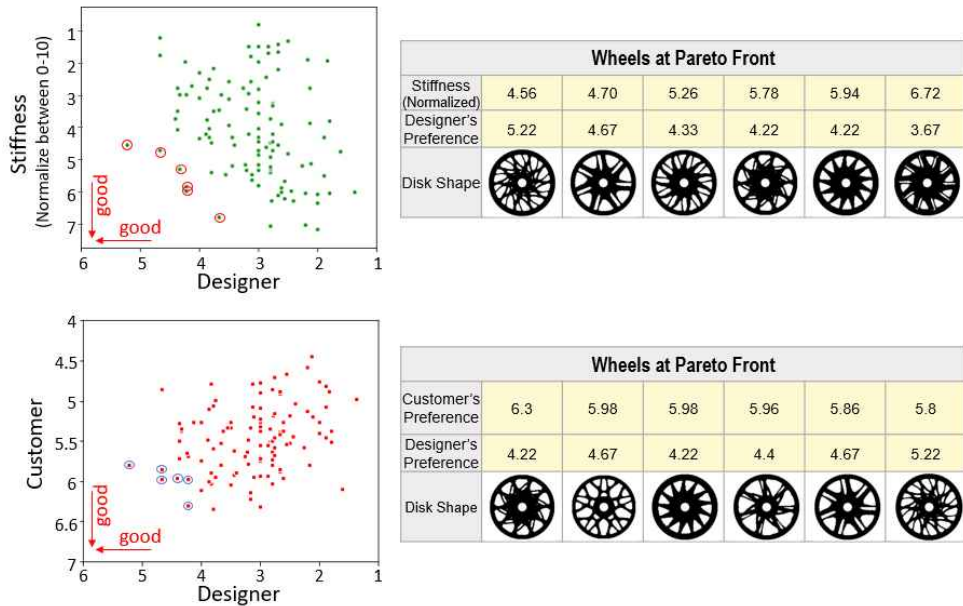


그림 10 디자인 선호도와 공학적 성능의 상충 관계 분석 (Shin et al., 2021)

목표 고객의 선호도 데이터를 다양한 방식의 온라인 설문을 통해 수집하고, 마케팅에 사용되는 효용 이론 (Utility theory)과 딥러닝을 결합하여 개인별 선호도 예측 모델을 구축하였다. 심미성은 주관적인 영역이며 개인마다 상이하므로 개인별 선호도 모델을 이용하여 개인이 가장 선호하는 디자인을 도출해야 하며, 이를 통해 고객의 특성별로 시장을 세분화할 수 있고 목표 시장별 디자인 추천이 가능하다.

Shin et al. (2021)은 휠 디자인에 대해 성능, 심미성을 고려한 상충 관계를 분석하였다 (그림 10). 공학성을 예측하는 딥러닝 모델을 활용하여, 디자이너와 고객이 느끼는 심미성과 공학성 간의 상충관계를 파레토 프론트를 통해 시각화하였다.

이러한 Deep Generative Design의 설계 추천 단계는 다수의 컨셉 설계안에 대해서 고객의 선호도를 예측하여 시장에서의 성공확률을 높일 수 있는 제품개발이 가능하게 한다. 또한 본 기술은 디자이너, 엔지니어, 마케터가 정량적인 근거를 바탕으로 효과적으로 커뮤니케이션하고 최적의 의사결정을 할 수 있도록 돕는다.

## 5. 결론 - 미래의 설계 패러다임

물리/경험 중심의 설계기술과 데이터/고객 중심의 설계기술이 결합된 Deep Generative Design 기술이 모빌리티 및 제품 설계의 새로운 패러다임을 열고 있다. <그림 11>과 같이 현재의 설계 프로세스는 디자이너/

엔지니어/마케터가 소량의 디자인을 가지고 오랜 기간 반복적인 과정을 통해 최종 제품을 설계한 후 시장에 나가서 고객의 평가를 받는다. 하지만 미래의 설계 프로세스에서는 인공지능이 스스로 공학적이고, 경제적이고, 고객이 좋아할 수 있는 대량의 디자인을 생성하면, 디자이너/엔지니어/마케터가 한자리에 모여서 정량적인 예측값들을 바탕으로 합리적인 의사결정을 하고, 최적의 제품을 시장에 빠르게 출시할 수 있게 될 것이다.

이렇듯 Deep Generative Design 제조업 신제품 설계의 게임 체인저가 될 것이다. 본 기술이 가져올 것으로 기대되는 변화와 효과는 다음과 같다.

첫째, 제조기업의 데이터 주도의 가상제품개발 및 디지털 전환을 가속화 할 것이다. 기업의 제품에 특화된 설계 빅데이터와 인공지능 솔루션을 확보하고 이를 통해 기업의 다양한 업무와 비즈니스에 적극적으로 활용할 수 있게 될 것이며, 데이터 표준을 정립하여 미래에 축적될 데이터의 효율적인 관리가 가능하게 될 것이다.

둘째, 제품개발시간 단축 및 제품 경쟁력의 향상을 가져올 것이다. CAE 및 최적설계에서 발생하는 반복적인 업무를 인공지능으로 대체하여, 개발시간과 비용을 혁신적으로 줄일 수 있다. 이를 통해 사람은 더욱 창의적인 업무에 집중할 수 있게 된다. 또한 인공지능이 스스로 설계안을 생성, 평가, 최적화, 추천하여 시장성 높은 제품 개발 기회를 제공할 것이다.

셋째, 전문가에 대한 의존도가 감소될 것이다. 엔지니어링 SW가 필요한 반복적인 업무를 인공지능으로 대체하고, 클라우드를 통해 다수의 작업자가 최신 인공



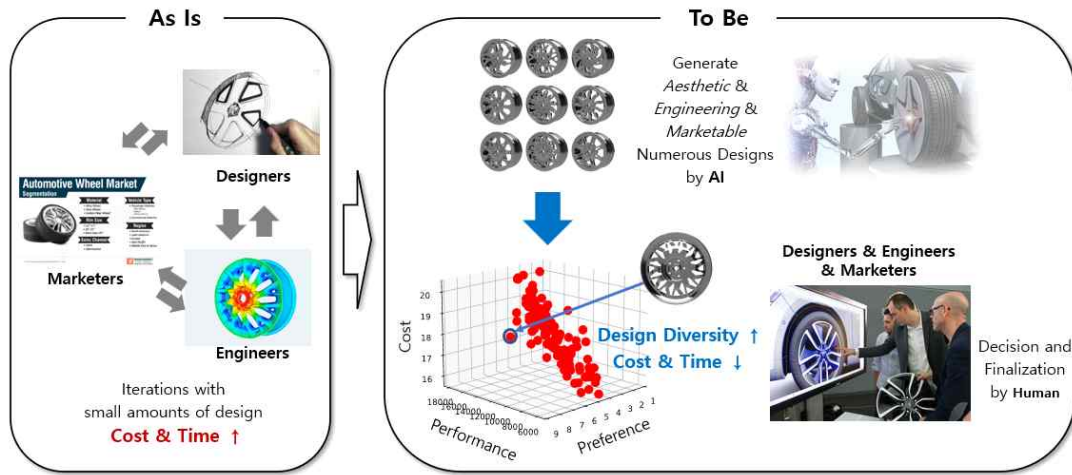


그림 11 인공지능 기반 설계(Deep Generative Design)를 통한 설계 패러다임의 혁신

지능 모델을 공유하고 쉽게 사용할 수 있게 될 것이다. 전문가의 도움 없이 누구나 엔지니어링 업무(설계, 해석, 및 최적화)를 쉽게 수행할 수 있게 될 것이다.

### 참고문헌

- [ 1 ] Jang, S., Yoo, S., & Kang, N. (2022). Generative design by reinforcement learning: enhancing the diversity of topology optimization designs. *Computer-Aided Design*, 146, 103225.
- [ 2 ] Jin, A., Lee, S., Yoo, S., Shin, S., Kim, C., Heo, S., and Kang, N. (2021). 딥러닝 기반의 최대응력과 위치 예측 기법: 로드 휠 충격 테스트 예시. *대한기계학회 CAE 및 응용역학부문 2021년도 춘계학술대회*.
- [ 3 ] Jin, A., Shin, S., Yoo, S., Kim, J., Myung, J., Hong, C., Han, I., Cho, G., Kim, S., and Kang, N. (2022). TV 스탠드를 위한 딥러닝 기반 제너레이티브 디자인 프로세스. *한국CDE학회 2022년도 동계학술대회*.
- [ 4 ] Jwa, M., Jin, A., Shin, D., Shin, S., and Kang, N. (2021). 딥러닝 기반 역설계와 최적 설계의 비교. *대한기계학회 CAE 및 응용역학부문 2021년도 춘계학술대회*.
- [ 5 ] Kang, N., Ren, Y., Feinberg, F., & Papalambros, P. (2019). Form+ function: Optimizing aesthetic product design via adaptive, geometrized preference elicitation. *arXiv preprint arXiv:1912.05047*.
- [ 6 ] Kim, S., Jwa, M., Lee, S., Park, S., & Kang, N. (2021a). Multidisciplinary inverse design using deep learning: a case study of brake systems. In *Asia Pacific Conference of the Prognostics and Health Management Society (PHMAP2021)*.
- [ 7 ] Kim, S. and Kang, N. (2021b). Inverse design of automotive brakes using generative models. *2021년 한국전산구조공학회 학술심포지엄*
- [ 8 ] Krish, S. (2011). A practical generative design method. *Computer-Aided Design*, 43(1), 88-100.
- [ 9 ] Kwon, Y., Yoo, S., and Kang, N. (2022). 도메인 적응을 이용한 상세 설계 회의 강성 예측 연구. *대한기계학회 CAE 및 응용역학부문 2022년도 춘계학술대회*.
- [10] Lee, S. and Kang, N. (2020). 딥러닝 기반 디자인 선호도 예측 및 추천시스템: 자동차 휠 설계 사례. *대한기계학회 2020년 학술대회*.
- [11] Liu, D., Tan, Y., Khoram, E., & Yu, Z. (2018). Training deep neural networks for the inverse design of nanophotonic structures. *ACS Photonics*, 5(4), 1365-1369.
- [12] Narnia Labs (2022). <https://www.narnia.ai>
- [13] Oh, S., Jung, Y., Kim, S., Lee, I., & Kang, N. (2019). Deep generative design: Integration of topology optimization and generative models. *Journal of Mechanical Design*, 141(11).
- [14] Park J., Shin, D., Yoo, S., & Kang, N. (2022). 그래프 신경망을 이용한 3D 휠 성능 예측 기초 연구. *대한기계학회 CAE 및 응용역학부문 2022년도 춘계학술대회*.
- [15] Shea, K., Aish, R., & Gourtovaia, M. (2005). Towards integrated performance-driven generative design tools. *Automation in Construction*, 14(2), 253-264.
- [16] Shin, D., Yoo, S., Lee, S., Kim, M., Hwang, K. H., Park, J. H., & Kang, N. (2021). How to trade off aesthetics and performance in generative design?. In *The 2021 World Congress on Advances in Structural Engineering and Mechanics (ASEM21)*.
- [17] Shin S., Kwon, Y., and Kang, N. (2022). SDF 기반 3D 제너레이티브 디자인 기초연구. *대한기계학회 CAE*

및 응용역학부문 2022년도 춘계학술대회.

- [18] Yoo, S., & Kang, N. (2021). Explainable artificial intelligence for manufacturing cost estimation and machining feature visualization. *Expert Systems with Applications*, 183, 115430.
- [19] Yoo, S., Lee, S., Kim, S., Hwang, K. H., Park, J. H., & Kang, N. (2021). Integrating deep learning into CAD/CAE system: generative design and evaluation of 3D conceptual wheel. *Structural and Multidisciplinary Optimization*, 64(4), 2725-2747.

## 약 력



### 신 동 주

2021 숙명여자대학교 기계시스템학부 졸업 (학사)  
2021~현재 KAIST 조천식모빌리티대학원 재학 (석사)  
2022~현재 (주)나니아랩스 AI Researcher  
관심분야: 제너레이티브 디자인, 인공지능 기반 설계 평가 및 최적설계  
Email : dongju.shin@narnia.ai



### 권 용 민

2022 인하대학교 기계공학과 졸업 (학사)  
2022~현재 KAIST 조천식모빌리티대학원 재학 (석사)  
2022~현재 (주)나니아랩스 AI Researcher  
관심분야: Implicit Neural Representation, 도메인 적응(Domain Adaptation), 최적설계  
Email : yongmin.kwon@narnia.ai



### 강 남 우

2005 서울대학교 기계항공공학부 졸업 (학사)  
2007 서울대학교 기술경영대학원 졸업 (석사)  
2014 University of Michigan, Design Science 졸업 (박사)  
2007~2010 현대자동차 연구원  
2018~2021 숙명여자대학교 기계시스템학부 조교수  
2021~현재 KAIST 조천식모빌리티대학원 조교수  
2022~현재 (주)나니아랩스 대표이사  
관심분야: 제너레이티브 디자인, 데이터 주도 설계, 최적설계, 인공지능  
Email : nwkang@narnia.ai