



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2025년05월19일
(11) 등록번호 10-2808845
(24) 등록일자 2025년05월13일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) G06N 3/04 (2023.01)
(52) CPC특허분류
G06N 3/08 (2023.01)
G06N 20/00 (2021.08)
(21) 출원번호 10-2021-0118315
(22) 출원일자 2021년09월06일
심사청구일자 2021년09월06일
(65) 공개번호 10-2023-0035834
(43) 공개일자 2023년03월14일
(56) 선행기술조사문헌
KR1020210066729 A*
Yeongmin Yoo 등, "Data Augmentation-Based Prediction of System Level Performance under Model and Parameter Uncertainties: Role of DGAN", Reliability Engine and System Safety 206, (2020.11.15.) 1부.*
KR1020210063151 A
KR1020210066730 A
*는 심사관에 의하여 인용된 문헌

(73) 특허권자
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 발명자
이중수
서울특별시 강남구 압구정로33길 70 현대아파트 53동 405호
유영민
서울특별시 도봉구 마들로 646 방학동삼성래미안 105-102
(74) 대리인
특허법인 플러스

전체 청구항 수 : 총 9 항

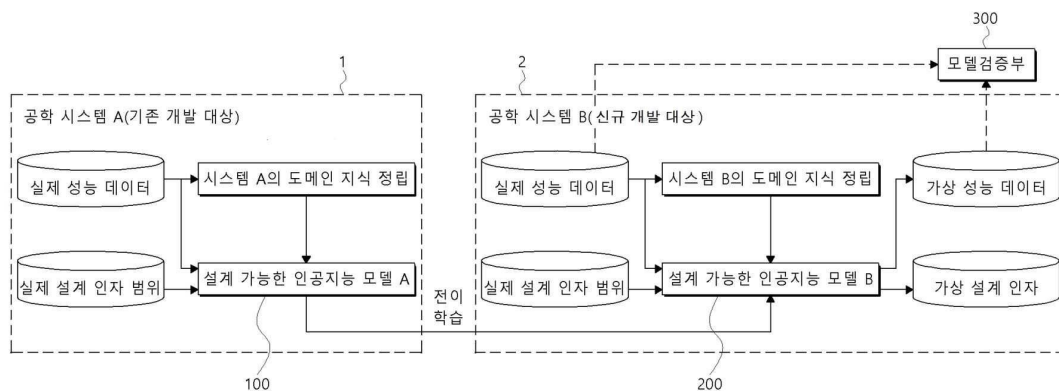
심사관 : 노지명

(54) 발명의 명칭 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템 및 그 방법

(57) 요약

본 발명은 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 관한 것으로서, 기존에 개발했던 제품과 유사하지만 새로운 제품을 개발하고자 할 때, 제품 개발 단계에서 CAE 모델의 설계 및 해석 과정 없이도 기존 성능 데이터를 이용한 가상 성능 데이터를 이용하여, 신규 개발 대상 제품의 향상된 성능 개선 및 새로운 설계안 도출을 수행할 수 있는 시스템 및 그 방법에 관한 것이다.

대표도 - 도1



(52) CPC특허분류
G06N 3/045 (2023.01)

명세서

청구범위

청구항 1

설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상의 공학 시스템(1)으로부터 수집한 실제 성능 데이터(actual data)를 적용하여 학습을 수행하는 전처리 학습부(100);

설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상과 유사한 또는 개선된 성능 수준을 갖는 신규 개발 대상의 공학 시스템(2)으로부터 수집한 실제 성능 데이터를 적용하여 학습을 수행하고, 상기 신규 개발 대상의 공학 시스템(2)으로부터 수집한 상기 실제 성능 데이터를 적용하여 학습을 수행한 DAI 모델로부터 추정된 가상 성능 데이터(virtual data)와 이에 대한 가상 설계 인자 데이터를 출력하는 본처리 학습부(200); 및

상기 본처리 학습부(200)에 의해 상기 학습을 수행한 DAI 모델을 통해서, 추정된 가상 성능 데이터와 학습에 적용한 상기 신규 개발 대상의 공학 시스템(2)으로부터 수집한 상기 실제 성능 데이터의 유사성을 판단하여, 상기 학습을 수행한 DAI 모델의 검증을 수행하는 모델 검증부(300);

를 포함하되,

상기 본처리 학습부(200)는

상기 모델 검증부(300)의 검증 결과에 따라, 판단한 유사성 정도가 기설정된 소정 기준값보다 낮을 경우, 상기 학습을 수행한 DAI 모델에 대한 학습 변수(parameter)를 변경하여 재학습을 수행하는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템.

청구항 2

삭제

청구항 3

삭제

청구항 4

제 1항에 있어서,

상기 본처리 학습부(200)는

상기 전처리 학습부(100)의 학습을 수행한 상기 DAI 모델의 가중치를 전이 학습한 후, 학습을 수행하는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템.

청구항 5

제 1항에 있어서,

상기 본처리 학습부(200)는

상기 DAI 모델로 설계 가능한 생성적 적대 신경망(DGAN, Designable Generative Adversarial Networks) 또는, 설계 가능한 변이형 오토인코더(DVAE, Designable Variational Auto-Encoder) 모델을 포함하되,

상기 DGAN 모델 및 상기 DVAE 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템.

청구항 6

제 5항에 있어서,

상기 본처리 학습부(200)의 상기 DGAN 모델은

임의의 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하는 생성기(210);

상기 신규 개발 대상의 공학 시스템(2)으로부터 수집한 상기 실제 성능 데이터와 상기 생성기(210)에 의해 생성된 상기 가상 성능 데이터를 입력받아 0 ~ 1 사이의 판별확률 값을 출력하는 판별기(220); 및

상기 가상 성능 데이터를 입력받아 가상 설계 인자 데이터를 출력하는 역생성기(230);

를 포함하는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템.

청구항 7

제 5항에 있어서

상기 본처리 학습부(200)의 DVAE 모델은

상기 신규 개발 대상의 공학 시스템(2)으로부터 수집한 상기 실제 성능 데이터를 입력받아 압축하여 잠재 변수 데이터로 출력하는 인코더(240);

상기 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하는 디코더(250); 및

상기 가상 성능 데이터를 입력받아 가상 설계 인자 데이터를 출력하는 역생성기(260);

를 포함하는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템.

청구항 8

컴퓨터로 구현되는 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 의해 각 단계가 수행되는 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법에 있어서,

전처리 학습부에서, 설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상의 공학 시스템으로부터 수집한 실제 성능 데이터(actual data)를 적용하여 학습을 수행하는 전처리 학습 단계(S100);

본처리 학습부에서, 설계 가능한 인공지능 모델을 이용하여, 기존 개발 대상과 유사한 또는 개선된 성능 수준을 갖는 신규 개발 대상의 공학 시스템으로부터 수집한 실제 성능 데이터를 적용하여 학습을 수행하는 본처리 학습 단계(S200); 및

모델 검증부에서, 상기 본처리 학습 단계(S200)에 의해 학습을 수행한 DAI 모델을 통해서 추정된 가상 성능 데이터와 학습에 적용한 실제 성능 데이터의 유사성을 판단하여, 상기 학습을 수행한 DAI 모델의 검증을 수행하는 검증 단계(S300);

를 포함하되,

상기 검증 단계(S300)의 검증 결과에 따라, 판단한 유사성 정도가 기설정된 소정 기준값보다 낮을 경우, 상기 학습을 수행한 DAI 모델의 학습 변수(parameter)를 변경하여 상기 본처리 학습 단계(S200)를 재수행하는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법.

청구항 9

제 8항에 있어서,

상기 본처리 학습 단계(S200)는

상기 전처리 학습 단계(S100)에 의해 학습을 수행한 DAI 모델의 가중치를 전이 학습하는 전이 학습 단계(S210);
 를 더 수행하는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법.

청구항 10

제 9항에 있어서,

상기 본처리 학습 단계(S200)는

상기 DAI 모델로 설계 가능한 생성적 적대 신경망(DGAN, Designable Generative Adversarial Networks) 모델을 포함하되,

상기 전이 학습 단계(S210)를 수행하고 난 후,

생성기에서, 임의의 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하는 생성 단계(S220);

판별기에서, 상기 신규 개발 대상의 공학 시스템으로부터 수집한 상기 실제 성능 데이터와 상기 생성 단계(S220)에 의해 생성된 상기 가상 성능 데이터를 입력받아 판별확률 값을 출력하는 판별 단계(S230); 및

역생성기에서, 상기 판별 단계(S230)에 의한 상기 가상 성능 데이터를 입력받아 이에 대한 가상 설계 인자 데이터를 출력하는 역생성 단계(S240);

를 더 포함하되,

상기 DGAN 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법.

청구항 11

제 9항에 있어서,

상기 본처리 학습 단계(S200)는

상기 DAI 모델로 설계 가능한 변이형 오토인코더(DVAE, Designable Variational Auto-Encoder) 모델을 포함하되,

상기 전이 학습 단계(S210)를 수행하고 난 후,

인코더에서, 상기 신규 개발 대상의 공학 시스템으로부터 수집한 상기 실제 성능 데이터를 입력받아 압축하여 잠재 변수 데이터로 출력하는 인코딩 단계(S250);

디코더에서, 상기 인코딩 단계(S250)에 의한 상기 잠재 변수 데이터를 입력받아 가상 성능 데이터(virtual data)를 출력하는 디코딩 단계(S260); 및

역생성기에서, 상기 디코딩 단계(S260)에 의한 상기 가상 성능 데이터를 입력받아 이에 대한 가상 설계 인자 데이터를 출력하는 역생성 단계(S270);

를 더 포함하되,

상기 DVAE 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는, 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법.

발명의 설명

기술 분야

본 발명은 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템 및 그 방법에 관한 것으로, 더욱 상세하게는 기존 개발 대상 데이터의 공학적 도메인 지식을 반영하여 기존과 유사한 또는 개선된 가상 성능 데이터를 생성하고, 이에 대해서 역 생성기를 통하여 가상 설계 인자를 추정함으로써, 신규 개발 대상과 같

[0001]

이 실제 데이터가 부족한 공학 시스템에서도 성능을 예측하고, 설계안을 도출할 수 있는 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템 및 그 방법에 관한 것이다.

배경 기술

- [0002] 산업 현장에서 획득한 데이터를 기반으로 신규 개발 대상(제품 등)의 설계 시, 가상 모델 설계를 통해 신규 시스템의 성능을 사전에 예측하고 이를 평가하기 위해 컴퓨터 이용 공학(CAE, Computer Aided Engineering) 모델 또는 심층 신경망(DNN, Deep Neural Network) 모델이 이용되고 있다.
- [0003] CAE 모델을 이용한 성능 예측 과정은, 실제 공학 시스템에 대한 세세한 모델링이 요구되기 때문에, 설계 및 해석 과정에서 많은 연산량이 요구된다.
- [0004] DNN 모델을 이용한 성능 예측 과정은, 공학 시스템의 실제 성능 데이터만을 가지고 학습이 이루어지기 때문에, DNN 모델 안에 있는 수많은 은닉층의 변수들을 제대로 학습시키기 위해서는 다량의 학습 데이터가 필요하며, 충분한 학습 데이터를 확보하지 않으면, 성능을 저해하는 과적합 문제가 발생하기 쉽다. 이 때, 과적합이란, 학습 데이터에 대해서만 지나치게 적응하여, 새로운 데이터에는 제대로 반응하지 못하는 것을 의미한다. 이러한 이유로 다량의 학습 데이터로 DNN 모델을 학습시키는 것이 중요하지만, 실제 산업 현장에서 발생할 수 있는 불확실성 요인들로 인해 우수한 양질의 데이터를 확보하기에는 많은 어려움이 있다.
- [0005] 이에 따라, 최근들어, 학습 데이터의 부족 문제를 해결하기 위하여, 실제 데이터와 유사한 가상의 데이터를 생성할 수 있는 데이터 증강과 전이 학습을 이용하여 DNN 모델에 필요한 다량의 학습 데이터를 생성하는 사례가 많아지고 있다.
- [0006] 데이터 증강이란, 소량의 실제 데이터에 인위적인 변화를 가해 새로운 학습 데이터를 다량으로 확보하는 방법론을 의미하며, 증강시키고자 하는 데이터의 형태는 수치형 또는 이미지형이 될 수 있다.
- [0007] 학습이 종료되고 난 후, 실제 데이터와 가상 데이터를 모두 이용하여 분류 또는 예측을 위한 DNN 모델의 학습 데이터로 적용하게 된다.
- [0008] 상술한 바와 같이, 종래의 데이터 증강 방법을 이용하면, 실제 성능 데이터와 유사한 가상 성능 데이터를 생성하여, 학습 데이터의 양을 증가시킬 수 있으나, 가상 성능 데이터에 영향을 미치는 요소를 알기에는 어려움이 있다.
- [0009] 또한, 실제 산업 현장에서 얻어지는 데이터의 형태, 특성 등을 고려하지 않고 단순한 통계학적 전처리만을 거친 후 바로 학습 데이터로서 적용하였기 때문에, 학습 결과에 대한 신뢰도가 저하되는 경우도 발생한다.
- [0010] 그렇기 때문에, 신규 개발 대상 제품과 같이 소량의 데이터만을 확보할 수 있는 공학 시스템에서의 성능 예측 및 분석을 위해서는 실제 성능 데이터의 공학적 도메인이 반영되고, 이로부터 생성된 가상 성능 데이터에 영향을 미치는 설계 인자를 추정할 수 있는 모델을 정립하는 것이 필요하다.

선행기술문헌

특허문헌

- [0011] (특허문헌 0001) 국내등록특허 제10-2111733호(등록일자 2020.05.11.)
- (특허문헌 0002) 국내등록특허 제10-2123973호(등록일자 2020.06.11.)

발명의 내용

해결하려는 과제

- [0012] 본 발명은 상기한 바와 같은 종래 기술의 문제점을 해결하기 위하여 안출된 것으로, 본 발명의 목적은 신규 개발 대상(제품)과 같이 다량의 성능 데이터를 확보하기 어려운 공학 시스템에서도 기존에 개발이 이루어진 데이터의 공학적 도메인 지식을 반영하여, 기존 개발 대상과 유사한 또는 개선된 가상 성능 데이터를 생성시키고, 이에 대한 영향을 미치는 설계 인자를 추정함으로써, 신규 공학 시스템의 성능 예측 및 설계안 도출이 가능한 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템 및 그 방법을 제공하는 것이다.

과제의 해결 수단

- [0013] 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템은, 설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상의 공학 시스템 (1) 으로부터 수집한 실제 성능 데이터(actual data)를 적용하여 학습을 수행하는 전처리 학습부(100) 및 설계 가능한 인공지능 모델을 이용하여, 기존 개발 대상과 유사한 또는 개선된 성능 수준을 갖는 신규 개발 대상의 공학 시스템(2)으로부터 수집한 실제 성능 데이터를 적용하여 학습을 수행하는 본처리 학습부(200)를 포함하되, 상기 본처리 학습부(200)는 학습을 수행한 상기 DAI 모델에 상기 실제 성능 데이터를 적용하여, 추정된 가상 성능 데이터(virtual data)와 이에 대한 가상 설계 인자 데이터를 출력하는 것이 바람직하다.
- [0014] 더 나아가, 상기 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템은 상기 본처리 학습부(200)에 의해, 학습에 적용한 상기 실제 성능 데이터와 출력된 상기 가상 성능 데이터의 유사성을 판단하여, 학습을 수행한 상기 DAI 모델의 검증을 수행하는 모델 검증부(300)를 더 포함하는 것이 바람직하다.
- [0015] 더 나아가, 상기 본처리 학습부(200)는 상기 모델 검증부(300)의 검증 결과에 따라, 판단한 유사성 정도가 기설정된 소정 기준값보다 낮을 경우, 상기 DAI 모델의 학습 변수(parameter)를 변경하여 재학습을 수행하는 것이 바람직하다.
- [0016] 더 나아가, 상기 본처리 학습부(200)는 상기 전처리 학습부(100)의 학습을 수행한 상기 DAI 모델의 가중치를 전이 학습한 후, 학습을 수행하는 것이 바람직하다.
- [0017] 더 나아가, 상기 본처리 학습부(200)는 상기 DAI 모델로 설계 가능한 생성적 적대 신경망(DGAN, Designable Generative Adversarial Networks) 또는, 설계 가능한 변이형 오토인코더(DVAE, Designable Variational Auto-Encoder) 모델을 포함하되, 상기 DGAN 모델 및 상기 DVAE 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는 것이 바람직하다.
- [0018] 더 나아가, 상기 본처리 학습부(200)의 상기 DGAN 모델은 임의의 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하는 생성기(210), 상기 실제 성능 데이터와 상기 생성기(210)에 의해 생성된 상기 가상 성능 데이터를 입력받아 0 ~ 1 사이의 판별확률 값을 출력하는 판별기(220) 및 상기 가상 성능 데이터를 입력받아 가상 설계 인자 데이터를 출력하는 역생성기(230)를 포함하는 것이 바람직하다.
- [0019] 더 나아가, 상기 본처리 학습부(200)의 DVAE 모델은 상기 실제 성능 데이터를 입력받아 압축하여 잠재 변수 데이터로 출력하는 인코더(240), 상기 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하는 디코더(250) 및 상기 가상 성능 데이터를 입력받아 가상 설계 인자 데이터를 출력하는 역생성기(260)를 포함하는 것이 바람직하다.
- [0020] 본 발명의 또 다른 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법은, 컴퓨터로 구현되는 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 의해 각 단계가 수행되는 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법에 있어서, 전처리 학습부에서, 설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상의 공학 시스템으로부터 수집한 실제 성능 데이터(actual data)를 적용하여 학습을 수행하는 전처리 학습 단계(S100), 본처리 학습부에서, 설계 가능한 인공지능 모델을 이용하여, 기존 개발 대상과 유사한 또는 개선된 성능 수준을 갖는 신규 개발 대상의 공학 시스템으로부터 수집한 실제 성능 데이터를 적용하여 학습을 수행하는 본처리 학습 단계(S200) 및 모델 검증부에서, 상기 본처리 학습 단계(S200)에 의해 학습을 수행한 DAI 모델을 통해서 추정된 가상 성능 데이터와 학습에 적용한 실제 성능 데이터의 유사성을 판단하여, 상기 학습을 수행한 DAI 모델의 검증을 수행하는 검증 단계(S300)를 포함하되, 상기 검증 단계(S300)의 검증 결과에 따라, 판단한 유사성 정도가 기설정된 소정 기준값보다 낮을 경우, 상기 학습을 수행한 DAI 모델의 학습 변수(parameter)를 변경하여 상기 본처리 학습 단계(S200)를 재수행하 것이 바람직하다.
- [0021] 더 나아가, 상기 본처리 학습 단계(S200)는 상기 전처리 학습 단계(S100)에 의해 학습을 수행한 DAI 모델의 가중치를 전이 학습하는 전이 학습 단계(S210)를 더 수행하는 것이 바람직하다.
- [0022] 더 나아가, 상기 본처리 학습 단계(S200)는 상기 DAI 모델로 설계 가능한 생성적 적대 신경망(DGAN, Designable Generative Adversarial Networks) 모델을 포함하되, 상기 전이 학습 단계(S210)를 수행하고 난 후, 생성기에서, 임의의 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하는 생성 단계(S220), 판별기에서, 상기 실제 성능 데이터와 상기 생성 단계(S220)에 의해 생성된 상기 가상 성능 데이터를 입력받아 판별확률 값을 출력

하는 판별 단계(S230) 및 역생성기에서, 상기 판별 단계(S230)에 의한 상기 가상 성능 데이터를 입력받아 이에 대한 가상 설계 인자 데이터를 출력하는 역생성 단계(S240)를 더 포함하되, 상기 DGAN 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는 것이 바람직하다.

[0023] 더 나아가, 상기 본처리 학습 단계(S200)는 상기 DAI 모델로 설계 가능한 변이형 오토인코더(DVAE, Designable Variational Auto-Encoder) 모델을 포함하되, 상기 전이 학습 단계(S210)를 수행하고 난 후, 인코더에서, 상기 실제 성능 데이터를 입력받아 압축하여 잠재 변수 데이터로 출력하는 인코딩 단계(S250), 디코더에서, 상기 인코딩 단계(S250)에 의한 상기 잠재 변수 데이터를 입력받아 가상 성능 데이터(virtual data)를 출력하는 디코딩 단계(S260) 및 역생성기에서, 상기 디코딩 단계(S260)에 의한 상기 가상 성능 데이터를 입력받아 이에 대한 가상 설계 인자 데이터를 출력하는 역생성 단계(S270)를 더 포함하되, 상기 DVAE 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는 것이 바람직하다.

발명의 효과

[0024] 상기와 같은 구성에 의한 본 발명의 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템은 기존에 개발했던 제품과 유사하지만 새로운 제품을 개발하고자 할 때, 제품 개발 단계에서 CAE 모델의 설계 및 해석 과정 없이도 기존 성능 데이터를 이용한 가상 성능 데이터를 이용하여, 신규 개발 대상 제품의 향상된 성능 개선 및 새로운 설계안 도출을 수행할 수 있다.

[0025] 또한, 데이터 증강 및 전이 학습을 응용 적용하여, 소량의 데이터를 가지고 있는 신규 공학 시스템의 성능 설계 측면에서도 범용적으로 적용이 가능한 장점이 있다.

[0026] 이를 통해서, 개발 소요 시간 절감, 불필요한 과도 설계 방지 및 설계 비용을 절감시킬 수 있어, 다양한 경제적 가치를 향상시킬 수 있는 장점이 있다.

도면의 간단한 설명

[0027] 도 1은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템을 나타낸 구성 예시도이다.

도 2는 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 적용한 DGAN 모델의 구조 예시도이다.

도 3은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 적용한 DVAE 모델의 구조 예시도이다.

도 4는 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 적용한 도메인 지식 기반 학습 절차를 간략하게 나타낸 예시도이다.

도 5는 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 의한 성능 예측 결과를 나타낸 도면이다.

도 6은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에 의한 모델 검증 결과 및 설계 인자 추정 결과를 나타낸 도면이다.

도 7 및 도 8은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법을 나타낸 순서 예시도이다.

발명을 실시하기 위한 구체적인 내용

[0028] 이하 첨부한 도면들을 참조하여 본 발명의 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템을 상세히 설명한다. 다음에 소개되는 도면들은 당업자에게 본 발명의 사상이 충분히 전달될 수 있도록 하기 위해 예로서 제공되는 것이다. 따라서, 본 발명은 이하 제시되는 도면들에 한정되지 않고 다른 형태로 구체화될 수도 있다. 또한, 명세서 전반에 걸쳐서 동일한 참조번호들은 동일한 구성요소들을 나타낸다.

[0029] 이때, 사용되는 기술 용어 및 과학 용어에 있어서 다른 정의가 없다면, 이 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 통상적으로 이해하고 있는 의미를 가지며, 하기의 설명 및 첨부 도면에서 본 발명의 요지를 불필요하게 흐릴 수 있는 공지 기능 및 구성에 대한 설명은 생략한다.

[0030] 더불어, 시스템은 필요한 기능을 수행하기 위하여 조직화되고 규칙적으로 상호 작용하는 장치, 기구 및 수단 등

을 포함하는 구성 요소들의 집합을 의미한다.

- [0031] 도 1은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템을 나타낸 구성 예시도이다.
- [0032] 도 1을 참조로 하여 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템을 상세히 설명한다.
- [0033] 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템은 신규 개발 대상(제품)과 같이 다량의 성능 데이터를 확보하기 어려운 공학 시스템에서도 기존에 개발이 이루어진 데이터의 공학적 도메인 지식을 반영하여, 기존 개발 대상과 유사한 또는 개선된 가상 성능 데이터를 생성시키고, 이에 대한 영향을 미치는 설계 인자를 추정함으로써, 신규 공학 시스템의 성능 예측 및 설계안 도출하는 것으로, 도 1에 도시된 바와 같이, 전처리 학습부(100), 본처리 학습부(200) 및 모델 검증부(300)를 포함하여 구성되는 것이 바람직하다.
- [0034] 또한, 각 구성들은 컴퓨터를 포함하는 적어도 하나 이상의 연산처리수단에 각각 또는 통합 포함되어 동작을 수행하는 것이 바람직하다.
- [0035] 각 구성에 대해서 자세히 알아보자면,
- [0036] 상기 전처리 학습부(100)는 설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상의 공학 시스템(1)으로부터 수집한 실제 성능 데이터(actual data)를 적용하여 학습을 수행하는 것이 바람직하다.
- [0037] 상세하게는, 상기 전처리 학습부(100)는 다량의 실제 성능 데이터 취득이 가능한 기존 개발 대상의 공학 시스템(1, A)에서의 도메인 지식 함수값을 선정하는 것이 바람직하다.
- [0038] 상기 도메인 지식 함수값은 상기 공학 시스템(1, A)에서 취득하는 성능 데이터의 종류에 따라 정립할 수 있으며, 물리적인 수식으로도 표현이 가능하다.
- [0039] 일 예를 들자면, 차량 충돌 시스템에서, 충돌 시 부품에서 발생하는 하중 대 변형량 성능에 대한 값을 적분하여 에너지 값으로 구할 수 있으며, 충돌 도메인의 대표적인 성능값으로 선정할 수 있다.
- [0040] 상기 전처리 학습부(100)는 이렇게 선정된 도메인 지식 함수값을 미리 저장되어 있는 상기 DAI 모델의 제한 함수값으로 설정하고, 설정한 제한 함수값을 기반으로 가상 성능 데이터를 생성할 수 있도록 학습을 수행하는 것이 바람직하다.
- [0041] 상기 본처리 학습부(200)는 상기 전처리 학습부(100)와 마찬가지로, 상기 DAI 모델을 이용하여, 기존 개발 대상과 유사한 또는 개선된 성능 수전을 갖는 신규 개발 대상의 공학 시스템(2)으로부터 수집한 실제 성능 데이터를 적용하여 학습을 수행하는 것이 바람직하다.
- [0042] 상세하게는, 상기 본처리 학습부(200)는 상기 공학 시스템(1, A)에 비해 적은 소량의 실제 성능 데이터 취득이 가능한 신규 개발 대상의 공학 시스템(2, B)에서의 도메인 지식 함수값을 선정하는 것이 바람직하다. 상기 도메인 지식 함수값은 상술한 바와 같이, 상기 공학 시스템(2, B)에서 취득하는 성능 데이터의 종류에 따라 정립할 수 있으며, 물리적인 수식으로도 표현이 가능하다.
- [0043] 상기 본처리 학습부(200)는 선정된 도메인 지식 함수값을 미리 저장되어 있는 상기 DAI 모델의 제한 함수값으로 설정하고, 상기 공학 시스템(2, B)의 실제 성능 데이터와 실제 설계 인자 범위를 입력으로 하여 상기 DAI 모델의 학습 처리를 수행하는 것이 바람직하다.
- [0044] 이 때, 도 4는 도메인 지식 기반 학습 절차를 간략하게 나타낸 도면으로서, 도메인 지식 기반 학습이란, 산업 현장에서 유래되는 데이터의 부족 및 불확실성으로 인한 인공지능의 한계를 해결하기 위하여, 공학 시스템의 유의미한 성능 예측을 위해 DNN 모델의 학습을 더욱 효율적으로 진행하기 위한 기술이다.
- [0045] 즉, 분석하고자 하는 공학 시스템에 대한 실제 시험이나 해석 모델을 통해서 성능 데이터(실제 성능 데이터)를 추출하게 된다. 이러한 상기 성능 데이터를 공학적 도메인을 기반으로 다양하게 추출될 수 있기 때문에, 해당 도메인을 물리적인 수식으로도 표현할 수 있다. 이를 통해서, DNN 모델의 학습을 진행할 때, 단순히 입력 데이터의 특징만을 보고 학습시키는 것이 아니라, 데이터가 가지고 있는 도메인 정보를 같이 추가하여 좀 더 효율적인 학습이 가능하다. 이를 통해서, 도메인 지식 기반의 학습을 진행하게 된다면, DNN 모델을 통해 얻어지는 예

측 결과도 물리적으로 유효한 의미를 가질 수 있게 된다. 이러한 점을 고려하여, 상기 본처리 학습부(200)의 DAI 모델은 가상 성능 데이터를 생성할 때, 실제 성능 데이터에 대한 도메인 지식과 관련된 물리적인 표현을 제한 수식(제한 함수 값)으로 두어 이와 유사한 데이터(가상 성능 데이터)를 생성할 수 있도록 학습을 진행하는 것이 바람직하다.

- [0046] 또한, 상기 본처리 학습부(200)의 DAI 모델은 상기 전처리 학습부(100)의 학습을 수행한 상기 DAI 모델의 가중치를 전이 학습한 후, 학습 처리가 이루어지는 것이 바람직하다.
- [0047] 즉, 상기 본처리 학습부(200)의 DAI 모델에서의 학습 시, 상기 전처리 학습부(100)에서 상기 공학 시스템(1, A)의 실제 성능 데이터를 기반으로 사전에 학습된 DAI 모델의 신경망 일부를 전이시켜, 가상 성능 데이터 생성 및 설계 인자 추정 학습을 수행하는 것이 바람직하다.
- [0048] 이러한 전이 학습을 통해서, 상기 본처리 학습부(200)에서 수집한 소량의 실제 성능 데이터만으로도 상기 공학 시스템(2, B)에서의 성능 예측 결과를 신속하게 도출할 수 있다.
- [0049] 여기서, 전이 학습(transfer learning)이란, 기존에 많은 학습 데이터를 사용한 신경망 가중치를 새로운 신경망(소량의 학습 데이터 셋)에 적용, 다시 말하자면, 기존 학습 신경망의 합성곱(convolutional layer)이 학습한 가중치를 새로운 신경망의 합성곱에 그대로 적용하여, 합성곱이 적은 학습을 하고 완전 연결 층(fully connected layer)만 학습하게 된다. 이 때, 가중치란, 다수 층으로 이루어진 신경망의 한 개 층의 최소 단위 구성 요소로서, 각 가중치는 연결된 노드의 계산에 사용된다. 이 노드는 입력에 가중치를 원소별로 곱한 후 총합하고 활성화 함수를 거쳐서 노드 출력값을 도출하게 된다. 신경망은 다량의 데이터 셋으로 가중치를 업데이트하면서 학습하는데, 이 가중치를 전이 학습으로 초기 보정을 받은 상태로 학습을 시행할 경우, 신규 데이터 확보 및 계산으로 인한 비용을 절감할 수 있다.
- [0050] 전이 학습은 통상적으로 상술한 바와 같이, 가중치를 통해서 지식을 전이하는 기술을 의미하지만, 지식 전이(knowledge transfer)와 같이 더 포괄적인 개념으로 혼용해서 사용하기도 한다. 지식 전이는 수행하고자 하는 과제의 효과성과 효율성을 향상시키기 위하여, 다른 학습에 이용된 지식을 가져오는 행위 모두를 포괄하는 개념으로서, 전이 학습, 도메인 적응을 포함하는 것이 바람직하다.
- [0051] 상기 본처리 학습부(200)는 학습을 수행한 상기 DAI 모델에 상기 실제 성능 데이터를 적용(입력)하여, 추정된 가상 성능 데이터(virtual data)와 이에 대한 가상 설계 인자 데이터를 추정하여 출력하는 것이 바람직하다.
- [0052] 상기 본처리 학습부(200)는 상기 DAI 모델로 설계 가능한 생성적 적대 신경망(DGAN, Designable Generative Adversarial Networks) 모델 또는, 설계 가능한 변이형 오토인코더(DVAE, Designable Variational Auto-Encoder) 모델을 이용하는 것이 바람직하다. 더불어, 상기 DGAN 모델과 DVAE 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되는 것이 바람직하다.
- [0053] 이 때, 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템은, 상기 본처리 학습부(200)에 저장되어 있는 DAI 모델이 소량의 실제 성능 데이터를 적용하여 가상 성능 데이터/가상 설계 인자 데이터의 추정에 활용되기 때문에, 도 2는 DGAN 모델이 적용된 상기 본처리 학습부(200)의 DAI 모델에 대한 설명이며, 도 3은 DVAE 모델이 적용된 상기 본처리 학습부(200)의 DAI 모델에 대한 설명이다.
- [0054] 상기 DGAN 모델과 DVAE 모델은 데이터 증강이 가능한 대표적인 모델인 생성적 적대 신경망(GAN, Generative Adversarial Networks)과 변이형 오토인코더(VAE, Variational Auto-Encoder) 모델에 각각의 역생성기를 추가하여, 생성된 가상 성능 데이터에 영향을 미치는 설계 인자를 추정할 수 있도록 구성된 모델이다.
- [0055] 먼저, 상기 본처리 학습부(200)의 DAI 모델로 DGAN 모델을 적용할 경우, 도 2에 도시된 바와 같이, 생성기(210), 판별기(220) 및 역생성기(230)를 포함하여 구성되게 된다.
- [0056] 간략하게는, 상기 생성기(210)는 임의의 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하고, 상기 판별기(220)는 실제 성능 데이터와 상기 가상 성능 데이터를 입력받아 판별확률 값을 출력하게 된다. 또한, 상기 역생성기(230)는 상기 가상 성능 데이터를 입력받아 설계 인자 데이터를 출력함으로써, 상기 가상 성능 데이터에 영향을 미치는 설계 인자를 추정하게 된다.
- [0057] 상세하게는, 상기 생성기(210)는 임의의 잠재 변수 데이터를 입력받아 실제 성능 데이터와 유사한 가상 성능 데이터를 출력하게 된다.

[0058] 상기 판별기(220)는 실제 성능 데이터와 상기 생성기(210)에서 생성된 상기 가상 성능 데이터를 입력받아 판별 확률 값을 출력하게 된다.

[0059] 이 때, DGAN 모델에서의 손실 함수는 상기 생성기(210)와 판별기(220)의 적대적인 학습을 위해 하기의 수학식 1과 같은 손실 함수가 이끌게 된다.

수학식 1

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))]$$

[0060]

(여기서, x는 실제 성능 데이터,

D(x)는 x를 입력 받았을 때의 판별 확률,

z는 잠재변수,

G(z)는 생성기에서 생성된 가상 성능 데이터,

D(G(z))는 G(z)를 입력 받았을 때의 판별 확률,

E[·]는 기댓값,

V는 손실함수 값을 의미함.)

또한, 상기 판별기(220)는 상기 손실 함수를 통해 상기 판별확률 값이 0.5가 되도록 학습을 수행하는 것이 바람직하며, 판별확률 식은 하기의 수학식 2와 같이 정의된다.

수학식 2

$$\text{Score} = \frac{E[D(x)] + E[1 - D(G(z))]}{2}$$

[0069]

(여기서, x는 실제 성능 데이터,

D(x)는 x를 입력 받았을 때의 판별 확률,

z는 잠재변수,

G(z)는 생성기에서 생성된 가상 성능 데이터,

D(G(z))는 G(z)를 입력 받았을 때의 판별 확률,

E[·]는 기댓값,

Score는 최종 판별확률 값을 의미함.)

상기 역생성기(230)는 상기 생성기(210)에서 생성된 상기 가상 성능 데이터를 입력받아, 이에 대한 설계 인자값들을 출력하게 된다.

상기 역생성기(230)에서의 손실은 하기의 수학식 3과 같은 평균 제곱 오차를 기반으로 계산된다.

수학식 3

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n \frac{1}{2} (\hat{z}_i - z_i)^2$$

[0079]

- [0080] (여기서, z 는 잠재 변수,
- [0081] z_{hat} 는 역생성기에서 추정된 잠재 변수,
- [0082] n 은 학습 데이터의 배치 크기,
- [0083] MSE는 평균 제곱 오차를 의미함.)
- [0084] 상기 역생성기(230)는 기존의 데이터 증강을 위한 모델에 추가된 구성으로서, 가상 성능 데이터를 생성하기 위해 입력 값으로 사용되는 잠재 변수 데이터와 상기 역생성기(230)를 통해 출력되는 추정 값(설계 인자값)의 차이가 최소화하는 쪽으로 학습이 진행된다.
- [0085] 최종적으로 학습이 완료되면 상기 역생성기(230)로부터 출력된 추정값을 하기의 수학적 식 4와 같이, 실제 설계 인자 범위에 맞추어 비정규화된 값(x_i)으로 변환된다.

수학적 식 4

$$x_i = \frac{(\hat{z}_i - S_{\min})x_{i,\max} + (S_{\max} - \hat{z}_i)x_{i,\min}}{S_{\max} - S_{\min}}$$

- [0086]
- [0087] (여기서, z_{hat} 는 추정된 잠재변수,
- [0088] x_{\max} , x_{\min} 은 실제 설계변수의 최대값, 최소값,
- [0089] S_{\max} , S_{\min} 은 표준 정규분포의 최대값, 최소값,
- [0090] x 는 추정된 설계 인자(또는 비정규화된 추정된 잠재 변수)를 의미함.)
- [0091] 또한, 상기 본처리 학습부(200)의 DAI 모델로 DVAE 모델을 적용할 경우, 도 3에 도시된 바와 같이, 인코더(240), 디코더(250) 및 역생성기(260)를 포함하여 구성되게 된다.
- [0092] 간략하게는, 상기 인코더(240)는 실제 성능 데이터를 입력받아 이를 압축하여 잠재 변수 데이터(z_i)를 출력하고, 상기 디코더(250)는 상기 잠재 변수 데이터를 입력받아 가상 성능 데이터를 출력하게 된다. 더불어, 상기 역생성기(260)는 상기 가상 성능 데이터를 입력받아 실제 인자 데이터를 출력함으로써, 상기 가상 성능 데이터에 영향을 미치는 설계 인자를 추정하게 된다.
- [0093] 상세하게는, 상기 인코더(240)는 상기 공학 시스템(2, B)의 소량의 실제 성능 데이터를 입력받아, 이를 압축함으로써 상기 잠재 변수 데이터로 출력하게 된다.
- [0094] 상기 잠재 변수 데이터는 가상 성능 데이터를 생성하는데 영향을 미치는 변수로서, 일반적으로 잠재 변수 데이터를 생성하는 가상 성능 데이터보다 적은 차원을 가지게 된다.
- [0095] 상기 디코더(250)는 압축된 실제 성능 데이터, 다시 말하자면 상기 잠재 변수 데이터를 입력받아, 상기 가상 성능 데이터를 출력하게 된다.
- [0096] 이 때, 상기 잠재 변수 데이터(z_i)는 상기 인코더(240)의 출력 값들의 평균(μ_i), 표준편차(σ_i), 가우시안 확률 분포에서 임의로 추출한 변수(ϵ_i)를 이용하여 생성되게 된다.
- [0097] 이 때, DVAE 모델에서의 손실 함수는 Evidence lower bound(ELBO) 손실이라고 하고, 하기의 수학적 식 5와 같이 두 개의 손실 항의 합으로 정의된다.

수학적 식 5

ELBO loss = reconstruction loss + KLD loss

- [0098]
- [0099] 여기서, reconstruction loss(복원 손실)는 하기의 수학적 식 6과 같이 평균 제곱 오차(MSE, Mean Squared Error

r)를 적용하여, 상기 디코더(250)의 출력값(가상 성능 데이터)이 상기 인코더(240)의 입력값(실제 성능 데이터)과 얼마나 비슷한지 측정하게 된다.

[0100] 또한, 콜백-라이블러 발산 손실(KLD loss, Kullback-Leibler Divergence loss)은 하기의 수학적 식 7과 같이 두 확률 분포 간의 차이를 측정하게 된다.

[0101] 여기서, KLD loss를 최소화한다는 것은 학습된 평균 및 분산을 대상 분포의 평균 및 분산에 가능한 한 가까워지게 한다는 것을 의미한다.

수학적 식 6

$$\text{reconstruction loss} = \frac{1}{n} \sum_{i=1}^n \frac{1}{2} (\hat{x}_i - x_i)^2$$

[0102]

[0103] (여기서, x는 실제 성능 데이터,

[0104] x_hat는 가상 성능 데이터,

[0105] n은 학습 데이터의 배치 크기를 의미함.)

수학적 식 7

$$\text{KLD loss} = -\frac{1}{2} \sum_{i=1}^n (1 + \log(\sigma_i) - \mu_i^2 - \sigma_i^2)$$

[0106]

[0107] (여기서, μ 는 인코더 출력 값들의 평균,

[0108] σ 는 인코더 출력 값들의 표준편차,

[0109] n은 학습 데이터의 배치 크기를 의미함.)

[0110] 상기 역생성기(260)는 상기 디코더(250)에서 출력한 상기 가상 성능 데이터를 입력받아, 이에 대한 설계 인자 값들을 출력하게 된다.

[0111] 상기 역생성기(260)에서의 손실은 하기의 수학적 식 8과 같은 평균 제곱 오차를 기반으로 계산된다.

수학적 식 8

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n \frac{1}{2} (\hat{z}_i - z_i)^2$$

[0112]

[0113] (여기서, z는 잠재 변수,

[0114] z_hat는 역생성기에서 추정된 잠재 변수,

[0115] n은 학습 데이터의 배치 크기,

[0116] MSE는 평균 제곱 오차를 의미함.)

[0117] 상기 역생성기(260)는 기존의 데이터 증강을 위한 모델에 추가된 구성으로서, 가상 성능 데이터를 생성하기 위해 입력 값으로 사용되는 잠재 변수 데이터와 상기 역생성기(260)를 통해 출력되는 추정 값(설계 인자값)의 차이가 최소화하는 쪽으로 학습이 진행된다.

[0118] 최종적으로 학습이 완료되면 상기 역생성기(260)로부터 출력된 추정값을 하기의 수학적 식 9와 같이, 실제 설계 인자 범위에 맞추어 비정규화된 값(x_i)으로 변환된다.

수학식 9

$$x_i = \frac{(\hat{z}_i - S_{\min})x_{i,\max} + (S_{\max} - \hat{z}_i)x_{i,\min}}{S_{\max} - S_{\min}}$$

- [0119]
- [0120] (여기서, \hat{z} 는 추정된 잠재변수,
- [0121] x_{\max} , x_{\min} 은 실제 설계변수의 최대값, 최소값,
- [0122] S_{\max} , S_{\min} 은 표준 정규분포의 최대값, 최소값,
- [0123] x 는 추정된 설계 인자(또는 비정규화된 추정된 잠재 변수)를 의미함.)
- [0124] 상기 모델 검증부(300)는 상기 본처리 학습부(200)에 의해, 학습에 적용한 상기 실제 성능 데이터와 출력된 상기 가상 성능 데이터의 유사성을 판단하여, 학습을 수행하는 상기 DAI 모델의 검증을 수행하는 것이 바람직하다.
- [0125] 상기 모델 검증부(300)는 추정된 가상 설계 인자를 상기 공학 시스템(2, B)에 적용하여 성능 예측에 대한 정확도 평가를 통해 가상 성능 데이터/가상 설계 인자 데이터를 통해서 구성된 예측 방법의 검증을 진행하는 것이 바람직하다. 검증 척도로는 실제 성능 데이터와 생성된 가상 성능 데이터 간의 유사성으로 판단하는 것이 바람직하며, 미리 설정된 소정 기준값을 이용하여 소정 기준값보다 낮을 경우, 검증이 유효하지 않은 것으로 판단하여, 상기 본처리 학습부(200)의 DAI 모델에 대한 학습 변수(parameter)를 수정하여 재학습이 이루어지도록 하는 것이 바람직하다.
- [0126] 이 때, 소정 기준값은 개발이 이루어지는 대상에 따라 설정되는 것이 바람직하며, 이에 대해서 한정하는 것은 아니다.
- [0127] 또한, 상기 모델 검증부(300)는 상기 본처리 학습부(200)를 통해서 출력되는 상기 가상 설계 인자 데이터를 상기 공학 시스템(2, B)에 재입력하여, 학습된 DAI 모델을 검증하게 된다. 상기 본처리 학습부(200)를 통해서 추정되는 상기 가상 성능 데이터와 이에 대한 가상 설계 인자 데이터를 이용한 공학 시스템(2, B)의 성능 예측 및 모델 검증을 진행하는 것이 바람직하다.
- [0128] 도 5는 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에서의 DGAN 모델을 적용한 성능 예측 결과값과 DVAE 모델을 적용한 성능 예측 결과값을 나타낸 도면으로서, 전이 학습 및 도메인 지식 기반 학습의 적용 여부에 따른 성능 예측 결과를 비교하기 위하여 3가지 경우로 나누어 실험을 진행하였다.
- [0129] case 1은 전이 학습 및 도메인 지식 기반 학습 모두 미적용한 경우, case 2는 전이 학습 적용 및 도메인 지식 기반 학습 미적용한 경우, case 3은 전이 학습 및 도메인 지식 기반 학습 모두 적용한 경우이다.
- [0130] 학습 모델의 결과 예측 평가는 DGAN 모델에서는 Score, DVAE 모델에서는 ELBO 손실로 평가할 수 있으며, 100 % 정확도로 환산하기 위하여 가중 적분 인수(WIFac, Weighted Integrated Factor)를 이용하며, 하기의 수학식 10 과 같이 정의된다.

수학식 10

$$WIFac = 1 - \sqrt{\frac{\sum \max(f[n]^2, g[n]^2) \cdot \left(1 - \frac{\max(0, f[n] \cdot g[n])}{\max(f[n]^2, g[n]^2)}\right)^2}{\sum \max(f[n]^2, g[n]^2)}}$$

- [0131]
- [0132] (여기서, WIFac은 가중 적분 인수,
- [0133] n 은 데이터 샘플 수,

- [0134] f[n]은 실제 성능 데이터,
- [0135] g[n]은 생성된 가상 성능 데이터를 의미함.)
- [0136] 상세하게는, 실험 진행은, A 차량과 B 차량의 각각에 관한 장애물과 충돌 시 차량 전방에 구비되는 범퍼에서 발생하는 하중 대 변형량 데이터가 실제 성능 데이터이고, A 차량 시스템은 다량의 성능 데이터인 186개의 실제 성능 데이터를 확보할 수 있는 시스템이고, B 차량 시스템은 소량의 성능 데이터인 20개의 실제 성능 데이터를 확보할 수 있는 시스템이며, A 차량 시스템을 이루는 설계 인자는 14개이며, 상B 차량 시스템을 이루는 설계 인자는 8개라고 가정한다.
- [0137] 상기 전처리 학습부(100)에서는 A 차량 시스템에 대한 사전 학습을 수행하게 되고, 상기 본처리 학습부(200)에서는 상기 전처리 학습부(100)의 사전 학습이 완료된 후, 전이 학습을 수행하게 된다.
- [0138] 상기 본처리 학습부(200)는 전이 학습을 수행하고 난 후, 출력되는 가상 성능 데이터에 대한 도메인 지식을 반영하기 위해 하중 대 변형량 성능에 대한 값을 적분하여 에너지 값으로 변환하고, 제한 함수값으로 지정하여 학습을 진행하게 된다.
- [0139] 실험 진행 결과, 각 모델에서의 성능 예측 결과를 비교해보았을 때, 전이 학습 및 도메인 지식 기반 학습을 모두 적용한 case 3에서 가상 성능 데이터의 생성 소요 시간, 정확도 결과가 개선됐음을 알 수 있다.
- [0140] 도 6은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 시스템에서의 모델 검증 결과 및 설계 인자 추정 결과를 나타낸 도면이다.
- [0141] 모델 검증은 상술한 바와 같이, 출력되는 상기 가상 설계 인자 데이터를 상기 공학 시스템(2, B)에 재입력하여 도출되는 성능 예측 정확도를 이용하게 된다.
- [0142] 실험 진행 결과, 검증 정확도(또는 WIFac)는 DGAN 모델은 94.6%, DVAE 모델은 96.3%로 성능 예측 결과에 대한 검증을 진행할 수 있었으며, 각 모델에서 추정된 설계 인자 값과 추정 범위는 실제 설계 인자의 95% 신뢰구간을 만족함으로써, 결과적으로 유효한 성능 예측이 가능함을 확인할 수 있다.
- [0143] 도 7 및 도 8은 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법을 나타낸 순서 예시도이다.
- [0144] 도 7 및 도 8을 참조로 하여 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법을 상세히 설명한다.
- [0145] 본 발명의 일 실시예에 따른 도메인 지식 기반 설계 가능한 인공지능 모델을 이용한 성능 예측 방법은 컴퓨터로 구현되는 도메인 지식 기반 가능한 인공지능 모델을 이용한 시스템에 의해 각 단계가 수행되며, 도 7 및 도 8에 도시된 바와 같이, 전처리 학습 단계(S100), 본처리 학습 단계(S200) 및 검증 단계(S300)를 포함하여 구성되는 것이 바람직하다.
- [0146] 각 단계에 대해서 자세히 알아보자면,
- [0147] 상기 전처리 학습 단계(S100)는 상기 전처리 학습부(100)에서, 설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상의 공학 시스템(1)으로부터 수집한 실제 성능 데이터(actual data)를 적용하여 학습을 수행하게 된다.
- [0148] 즉, 상기 전처리 학습 단계(S100)는 다량의 실제 성능 데이터 취득이 가능한 기존 개발 대상의 공학 시스템(1, A)에서의 도메인 지식 함수값을 선정하고, 선정된 도메인 지식 함수값을 미리 저장되어 있는 상기 DAI 모델의 제한 함수값으로 설정하고, 설정한 제한 함수값을 기반으로 가상 성능 데이터를 생성할 수 있도록 학습을 수행하게 된다.
- [0149] 상기 본처리 학습 단계(S200)는 상기 본처리 학습부(200)에서, 설계 가능한 인공지능(DAI, Designable Artificial Intelligence) 모델을 이용하여, 기존 개발 대상과 유사한 또는 개선된 성능 수전을 갖는 신규 개발 대상의 공학 시스템(2)으로부터 수집한 실제 성능 데이터를 적용하여 학습을 수행하게 된다.
- [0150] 상세하게는, 상기 본처리 학습 단계(S200)는 상기 공학 시스템(1, A)에 비해 적은 소량의 실제 성능 데이터 취득이 가능한 신규 개발 대상의 공학 시스템(2, B)에서의 도메인 지식 함수값을 선정하고, 선정된 도메인 지식 함수값을 미리 저장되어 있는 상기 DAI 모델의 제한 함수값으로 설정하고, 상기 공학 시스템(2, B)의 실제 성능 데이터와 실제 설계 인자 범위를 입력으로 하여 상기 DAI 모델의 학습 처리를 수행하게 된다.

- [0151] 상기 본처리 학습 단계(S200)는 도 7에 도시된 바와 같이, 상기 DAI 모델로 DGAN 모델을 적용할 경우, 전이 학습 단계(S210), 생성 단계(S220), 판별 단계(S230), 역생성 단계(S240)를 포함하여 구성되는 것이 바람직하다.
- [0152] 이 때, 저장되어 있는 DAI 모델은 상술한 바와 같이, 설계 가능한 생성적 적대 신경망(DGAN, Designable Generative Adversarial Networks) 모델을 이용하는 것이 바람직하며, 상기 DGAN 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되게 된다.
- [0153] 상기 DGAN 모델은 데이터 증강이 가능한 대표적인 모델인 생성적 적대 신경망(GAN, Generative Adversarial Networks) 모델에 역생성기를 추가하여, 생성된 가상 성능 데이터에 영향을 미치는 설계 인자를 추정할 수 있도록 구성된 모델이다.
- [0154] 상기 전이 학습 단계(S210)는 상기 전처리 학습 단계(S100)에 의해 학습을 수행한 상기 DAI 모델의 가중치를 전이 학습한 후, 상기 본처리 학습부(200)에서의 학습 처리가 이루어지게 된다.
- [0155] 즉, 상기 본처리 학습부(200)의 DAI 모델에서의 학습 시, 상기 전처리 학습부(100)에서 상기 공학 시스템(1, A)의 실제 성능 데이터를 기반으로 사전에 학습된 DAI 모델의 신경망 일부를 전이시켜, 가상 성능 데이터 생성 및 설계 인자 추정 학습을 수행하는 것이 바람직하다.
- [0156] 이러한 전이 학습을 통해서, 상기 본처리 학습부(200)에서 수집한 소량의 실제 성능 데이터만으로도 상기 공학 시스템(2, B)에서의 성능 예측 결과를 신속하게 도출할 수 있다.
- [0157] 상기 생성 단계(S220)는 상기 생성기(210)에서, 임의의 잠재 변수 데이터를 입력받아 상기 공학 시스템(2, B)의 실제 성능 데이터와 유사한 가상 성능 데이터를 출력하게 된다.
- [0158] 상기 판별 단계(S230)는 상기 판별기(220)에서, 상기 공학 시스템(2, B)의 실제 성능 데이터와 상기 생성기(210)에서 생성된 가상 성능 데이터를 입력받아 0 ~ 1 사이의 판별확률 값을 출력하게 된다.
- [0159] 여기서, DGAN 모델에서의 손실 함수는 상기 생성기(210)와 판별기(220)의 적대적인 학습을 위해 상기의 수학적 식 1과 같이 손실 함수가 이끌게 된다.
- [0160] 또한, 상기 판별 단계(S230)는 상기 손실 함수를 통해 상기 판별확률 값이 0.5가 되도록 학습을 수행하는 것이 바람직하며, 판별확률 식은 상기의 수학적 식 2와 같이 정의된다.
- [0161] 상기 역생성 단계(S240)는 상기 역생성기(230)에서, 상기 생성 단계(S220)에 의한 상기 가상 성능 데이터가 입력받아, 이에 대한 설계 인자 값들을 출력하게 된다.
- [0162] 이 때, 상기 역생성기(230)에서의 손실은 상기의 수학적 식 3과 같은 평균 제곱 오차를 기반으로 계산된다.
- [0163] 상기 역생성기(230)는 기존의 데이터 증강을 위한 모델에 추가된 구성으로서, 가상 성능 데이터를 생성하기 위해 입력 값으로 사용되는 잠재 변수 데이터와 상기 역생성기(230)를 통해 출력되는 추정 값(설계 인자값)의 차이가 최소화하는 쪽으로 학습이 진행된다.
- [0164] 최종적으로 학습이 완료되면 상기 역생성기(230)로부터 출력된 추정값을 상기의 수학적 식 4와 같이, 실제 설계 인자 범위에 맞추어 비정규화된 값(x_i)으로 변환된다.
- [0165] 상기 본처리 학습 단계(S200)는 도 8에 도시된 바와 같이, 상기 DAI 모델로 DVAE 모델을 적용할 경우, 전이 학습 단계(S210), 인코딩 단계(S250), 디코딩 단계(S260) 및 역생성 단계(S270)를 포함하여 구성되는 것이 바람직하다.
- [0166] 이 때, 저장되어 있는 DAI 모델은 상술한 바와 같이, 설계 가능한 변이형 오토인코더(DVAE, Designable Variational Auto-Encoder) 모델을 이용하는 것이 바람직하며, 상기 DVAE 모델은 합성곱 신경망(CNN, Convolutional Neural Network) 구조로 구성되게 된다.
- [0167] 상기 DVAE 모델은 데이터 증강이 가능한 대표적인 모델인 변이형 오토인코더(VAE, Variational Auto-Encoder) 모델에 역생성기를 추가하여, 생성된 가상 성능 데이터에 영향을 미치는 설계 인자를 추정할 수 있도록 구성된 모델이다.
- [0168] 상기 전이 학습 단계(S210)는 상기 전처리 학습 단계(S100)에 의해 학습을 수행한 상기 DAI 모델의 가중치를 전이 학습한 후, 상기 본처리 학습부(200)에서의 학습 처리가 이루어지게 된다.
- [0169] 즉, 상기 본처리 학습부(200)의 DAI 모델에서의 학습 시, 상기 전처리 학습부(100)에서 상기 공학 시스템(1,

A)의 실제 성능 데이터를 기반으로 사전에 학습된 DAI 모델의 신경망 일부를 전이시켜, 가상 성능 데이터 생성 및 설계 인자 추정 학습을 수행하는 것이 바람직하다.

- [0170] 이러한 전이 학습을 통해서, 상기 본처리 학습부(200)에서 수집한 소량의 실제 성능 데이터만으로도 상기 공학 시스템(2, B)에서의 성능 예측 결과를 신속하게 도출할 수 있다.
- [0171] 상기 인코딩 단계(S250)는 상기 인코더(240)에서, 상기 공학 시스템(2, B)의 실제 성능 데이터를 입력받아, 이를 압축함으로써 상기 잠재 변수 데이터(z_i)로 출력하게 된다. 상기 잠재 변수 데이터는 가상 성능 데이터를 생성하는데 영향을 미치는 변수로서, 일반적으로 잠재 변수 데이터는 생성하는 가상 성능 데이터보다 적은 차원을 가진다.
- [0172] 상기 디코딩 단계(S260)는 상기 디코더(250)에서, 상기 인코딩 단계(S250)에 의한 압축된 실제 성능 데이터, 다시 말하자면, 상기 잠재 변수 데이터를 입력받아, 상기 가상 성능 데이터를 출력하게 된다.
- [0173] 이 때, 상기 잠재 변수 데이터(z_i)는 상기 인코더(240)의 출력 값들의 평균(μ_i), 표준편차(σ_i), 가우시안 확률 분포에서 임의로 추출한 변수(ϵ_i)를 이용하여 생성되게 된다.
- [0174] 또한, DVAE 모델에서의 손실 함수는 Evidence lower bound(ELBO) 손실이라고 하고, 상기의 수학적 식 5와 같이 두 개의 손실 항의 합으로 정의된다.
- [0175] 하나의 손실 항인 reconstruction loss(복원 손실)는 상기의 수학적 식 6과 같이 평균 제곱 오차(MSE, Mean Squared Error)를 적용하여, 상기 디코더(250)의 출력값(가상 성능 데이터)이 상기 인코더(240)의 입력값(실제 성능 데이터)과 얼마나 비슷한지 측정하게 된다.
- [0176] 또다른 손실 항인 콜백-라이블러 발산 손실(KLD loss, Kullback-Leibler Divergence loss)은 상기의 수학적 식 7과 같이 두 확률 분포 간의 차이를 측정하게 된다. 여기서, KLD loss를 최소화한다는 것은 학습된 평균 및 분산을 대상 분포의 평균 및 분산에 가능한 한 가까워지게 한다는 것을 의미한다.
- [0177] 상기 역생성 단계(S270)는 상기 역생성기(260)에서, 상기 디코딩 단계(S260)에 의한 상기 가상 성능 데이터가 입력받아, 이에 대한 설계 인자 값들을 출력하게 된다.
- [0178] 이 때, 상기 역생성기(260)에서의 손실은 상기의 수학적 식 8과 같은 평균 제곱 오차를 기반으로 계산된다.
- [0179] 상기 역생성기(260)는 기존의 데이터 증강을 위한 모델에 추가된 구성으로서, 가상 성능 데이터를 생성하기 위해 입력 값으로 사용되는 잠재 변수 데이터와 상기 역생성기(260)를 통해 출력되는 추정 값(설계 인자값)의 차이가 최소화하는 쪽으로 학습이 진행된다.
- [0180] 최종적으로 학습이 완료되면 상기 역생성기(260)로부터 출력된 추정값을 상기의 수학적 식 9와 같이, 실제 설계 인자 범위에 맞추어 비정규화된 값(x_i)으로 변환된다.
- [0181] 상기 검증 단계(S300)는 상기 모델 검증부(300)에서, 상기 본처리 학습 단계(S200)에 의해 학습을 수행한 DAI 모델을 통해서 추정한 상기 가상 성능 데이터와 학습에 적용한 상기 실제 성능 데이터의 유사성을 판단하여, 상기 학습을 수행한 DAI 모델의 검증을 수행하게 된다.
- [0182] 이 때, 추정한 가상 설계 인자를 상기 공학 시스템(2, B)에 적용하여 성능 예측에 대한 정확도 평가를 통해 가상 성능 데이터/가상 설계 인자 데이터를 통해서 구성된 예측 방법(학습을 수행한 DAI 모델)의 검증을 진행하는 것이 바람직하다. 검증 척도로는 실제 성능 데이터와 생성된 가상 성능 데이터 간의 유사성으로 판단하는 것이 바람직하며, 미리 설정된 소정 기준값을 이용하여 소정 기준값보다 낮을 경우, 검증이 유효하지 않은 것으로 판단하여, 상기 본처리 학습부(200)의 DAI 모델에 대한 학습 변수(parameter)를 수정/변경하여 상기 본처리 학습 단계(S200)를 재수행하게 된다.
- [0183] 다양한 실험을 통한 상기 검증 단계(S300)의 진행 결과, 전이 학습 및 도메인 지식 기반 학습을 모두 적용한 case 3에서 가상 성능 데이터의 생성 소요 시간, 정확도 결과가 개선됐음을 알 수 있으며, DGAN 모델을 적용한 경우에는 94.6%, DVAE 모델을 적용한 경우에는 96.3%로 성능 예측 결과에 대한 검증을 진행할 수 있었으며, 추정된 설계 인자 값과 추정 범위는 실제 설계 인자의 95% 신뢰구간을 만족함으로써, 결과적으로 유효한 성능 예측이 가능함을 확인할 수 있다.
- [0184] 이상과 같이 본 발명에서는 구체적인 구성 요소 등과 같은 특정 사항들과 한정된 실시예 도면에 의해 설명되었

으나 이는 본 발명의 보다 전반적인 이해를 돕기 위해서 제공된 것 일 뿐, 본 발명은 상기의 일 실시예에 한정되는 것이 아니며, 본 발명이 속하는 분야에서 통상의 지식을 가진 자라면 이러한 기재로부터 다양한 수정 및 변형이 가능하다.

[0185] 따라서, 본 발명의 사상은 설명된 실시예에 국한되어 정해져서는 아니 되며, 후술하는 특허 청구 범위뿐 아니라 이 특허 청구 범위와 균등하거나 등가적 변형이 있는 모든 것들은 본 발명 사상의 범주에 속한다고 할 것이다.

부호의 설명

[0186] 1 : 기존 개발 대상의 공학 시스템

100 : 전처리 학습부

2 : 신규 개발 대상의 공학 시스템

200 : 본처리 학습부

210 : 생성기

220 : 판별기

230 : 역생성기

240 : 인코더

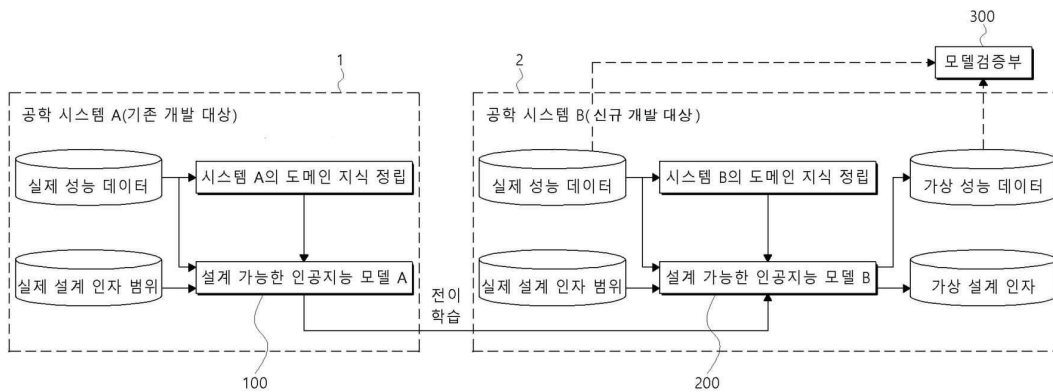
250 : 디코더

260 : 역생성기

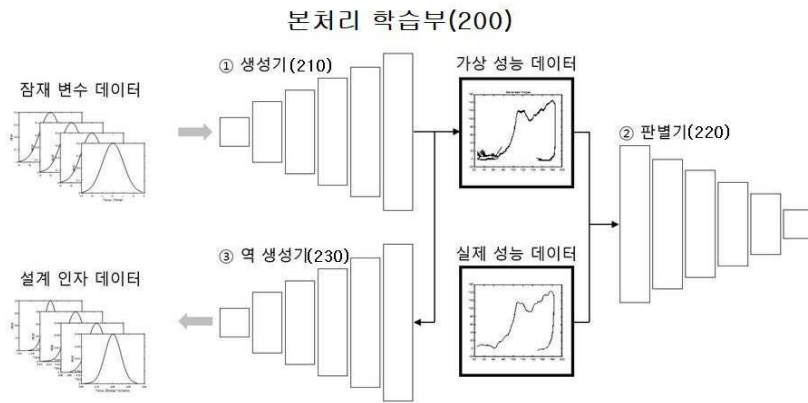
300 : 모델 검증부

도면

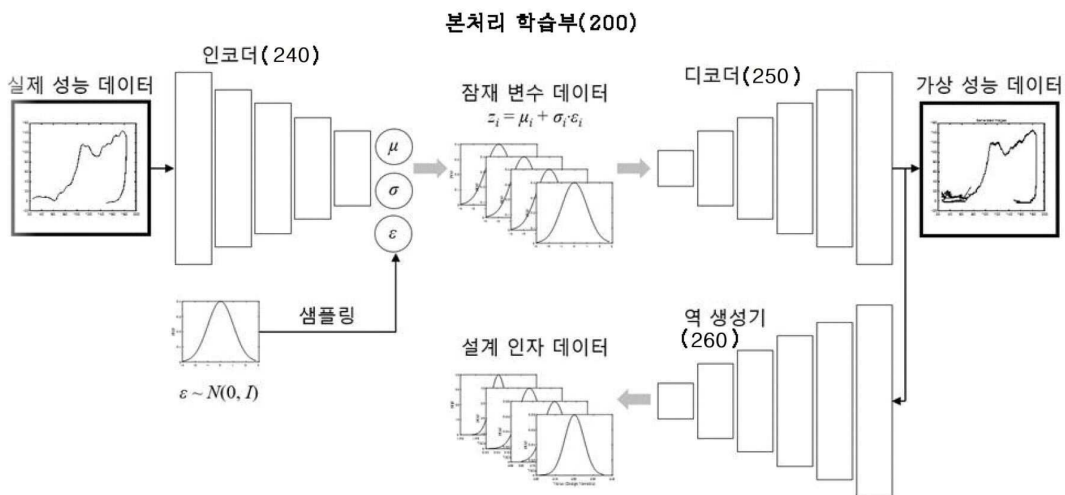
도면1



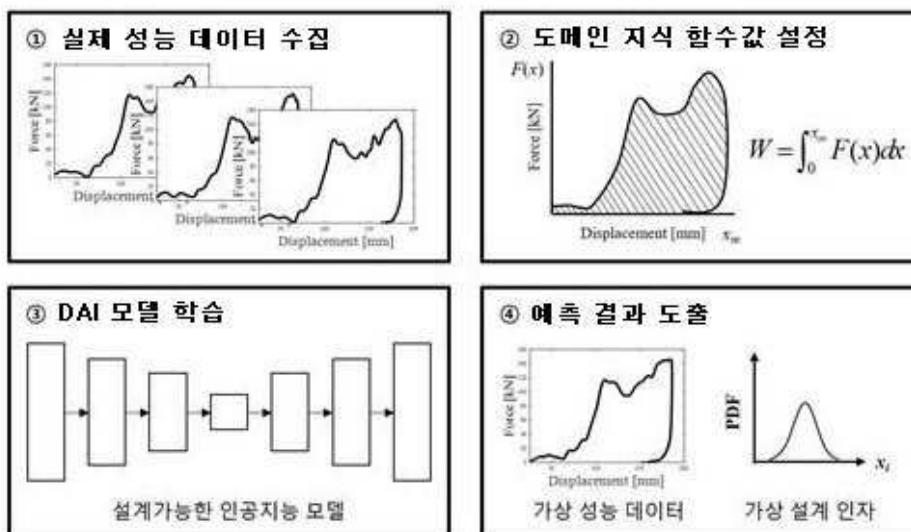
도면2



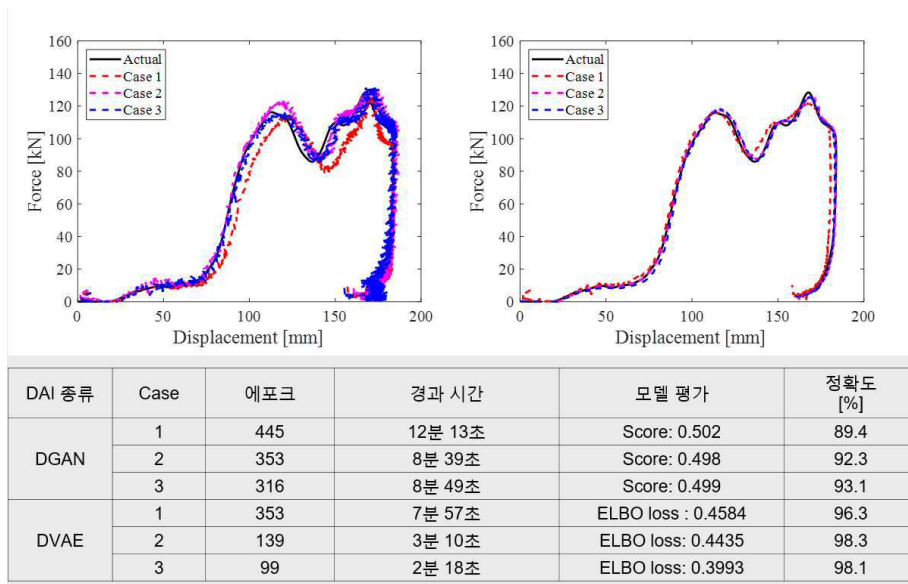
도면3



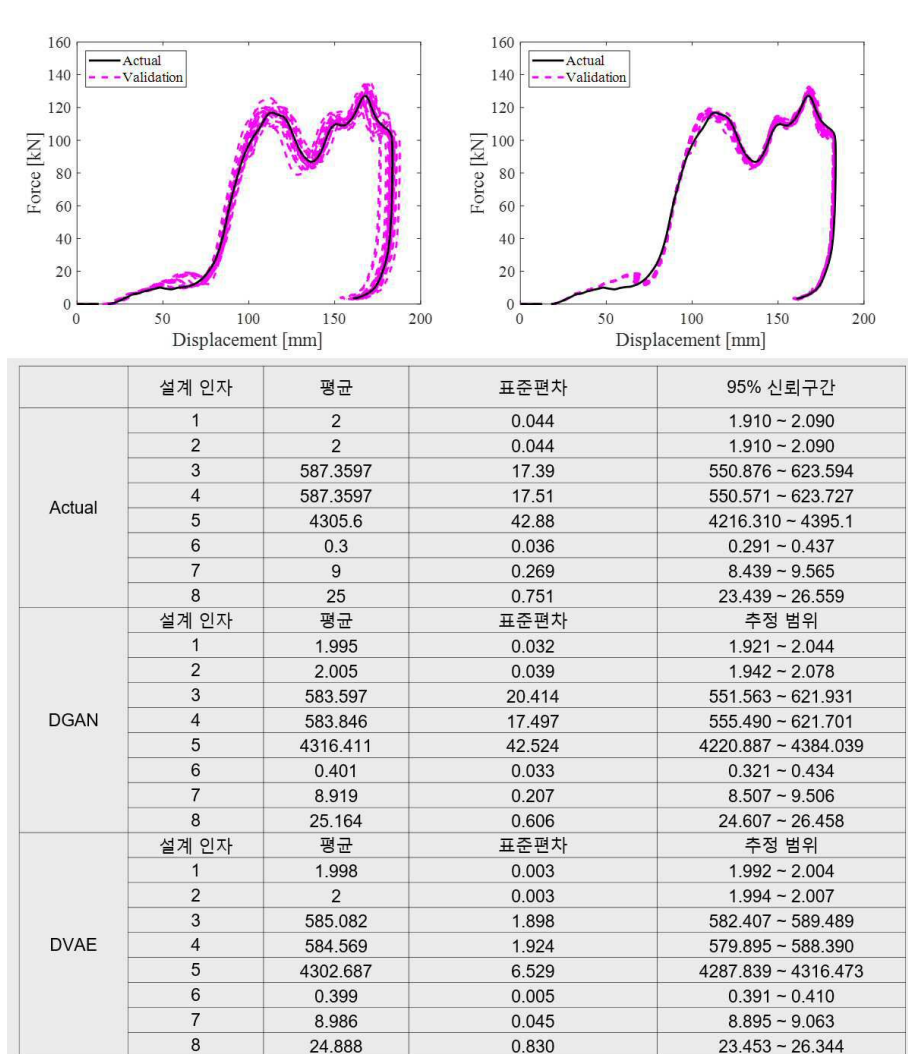
도면4



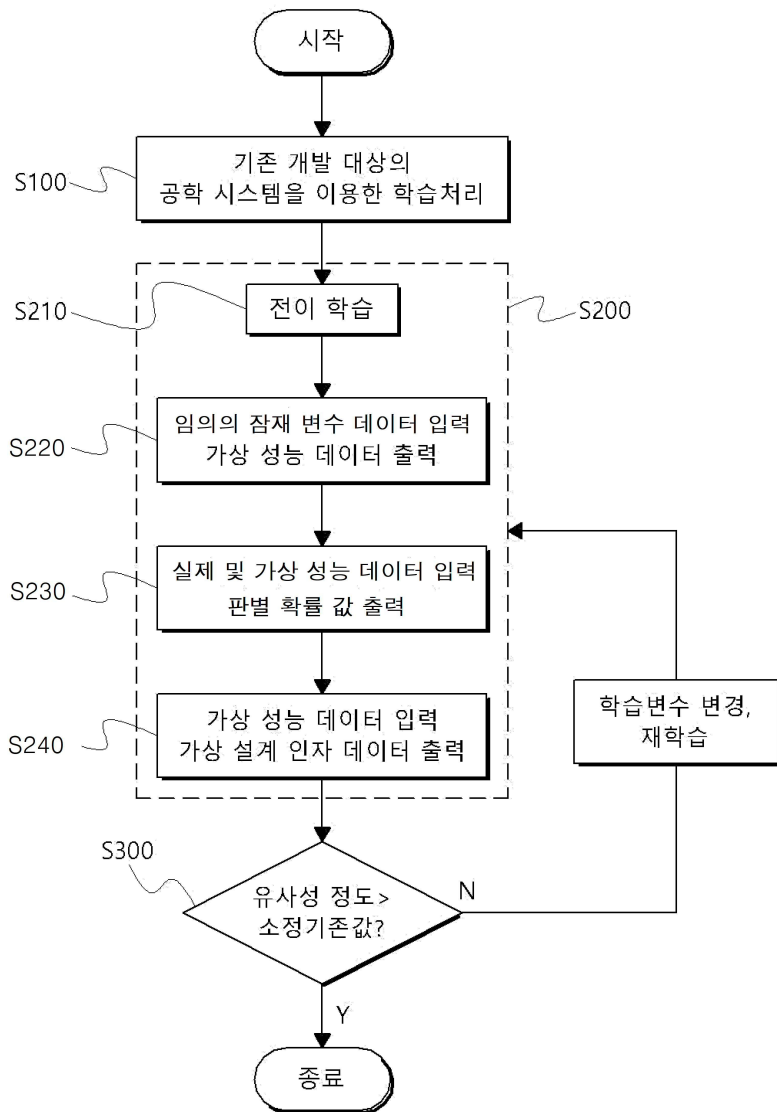
도면5



도면6



도면7



도면8

