(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0143123
(43) 공개일자 2024년10월02일

(51) 국제특허분류(Int. Cl.)
G05B 13/04 (2006.01) *B23Q 17/09* (2006.01)
G05B 19/416 (2006.01) *G06N 20/00* (2019.01)
G06N 3/12 (2023.01)
(52) CPC특허분류
G05B 13/048 (2013.01)
B23Q 17/0985 (2013.01)
(21) 출원번호 10-2023-0037997
(22) 출원일자 2023년03월23일
심사청구일자 2023년03월23일

(71) 출원인
경상국립대학교산학협력단
경상남도 진주시 진주대로 501 (가좌동)
(72) 발명자
김태호
부산광역시 강서구 미음산단5로41번길 71, 202호 (미음동)
도재혁
경상남도 진주시 가호로 26, 210동 707호 (가좌동, 진주가좌주공아파트)
(뒷면에 계속)
(74) 대리인
김종선

전체 청구항 수 : 총 13 항

(54) 발명의 명칭 **절삭가공 조건에 따른 딥러닝 기반 절삭력 및 온도 예측 시스템 및 방법**

(57) 요 약

본 발명은 절삭가공 조건에 따른 딥러닝 기반 절삭력 및 온도 예측 방법에 관한 것으로, 더욱 상세하게는 피삭재의 재료상수 범위를 선정하는 단계, 상기 재료상수를 최적화하기 위하여 최적화 시스템을 구축하는 단계, 상기 최적화 시스템을 이용하여 상기 재료상수의 전역 최적화(Global Opimization)를 수행하는 단계, 상기 전역 최적화된 상기 재료상수를 기반으로 최적의 재료상수를 획득하는 단계 및 딥러닝에 상기 최적의 재료상수를 인가하여 절삭 가공 조건에 대한 절삭력 및 온도를 예측하는 단계를 포함하며, 높은 정확도로 절삭 가공 공정에 대한 피삭재의 절삭력 및 온도를 예측할 수 있 있다.

대 표 도 - 도1

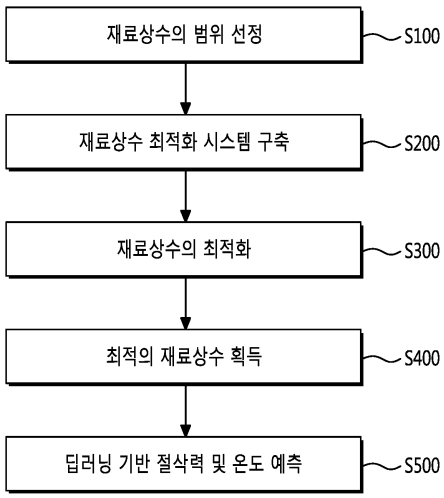

(52) CPC특허분류
G05B 13/041 (2013.01)
G05B 19/4163 (2013.01)
G06N 20/00 (2021.08)
G06N 3/126 (2023.01)
(72) 발명자
임기훈
경상남도 하동군 하동읍 산복2길 10, 101동 404호 (녹차마을)
이현승
경상남도 진주시 강남로189번길 27-13, 203호 (칠암동)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711177683
과제번호	KOITA-2022-1-148
부처명	과학기술정보통신부
과제관리(전문)기관명	(사단)한국산업기술진흥협회
연구사업명	연구산업육성
연구과제명	절삭가공조건에 따른 딥러닝 기반 절삭력 예측 모델 개발
기 여 율	1/1
과제수행기관명	경상국립대학교 산학협력단
연구기간	2022.09.23 ~ 2022.12.22

명 세 서

청구범위

청구항 1

피삭재의 재료상수 범위를 선정하는 단계;

상기 재료상수를 최적화하기 위하여 최적화 시스템을 구축하는 단계;

상기 최적화 시스템을 이용하여 상기 재료상수의 최적화를 수행하는 단계;

상기 최적화된 상기 재료상수를 기반으로 최적의 재료상수를 획득하는 단계; 및

딥러닝 알고리즘에 상기 최적의 재료상수를 인가하여 절삭 가공 조건에 대한 절삭력 및 온도를 예측하는 단계;

를 포함하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 2

제1항에 있어서,

상기 재료상수는 항복강도, 가공경화 상수, 변형률 속도 경화 상수, 변형률 속도 제어 상수 및 온도 연화 지수를 포함하며,

상기 항복강도 및 가공경화 상수는 S-K 구성방정식을 이용하여 획득하고, 상기 변형률 속도 경화 상수, 변형률 속도 제어 상수 및 온도 연화 지수는 존슨-쿡(Johnson-Cook) 구성방정식을 이용하여 획득하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 3

제1항에 있어서,

상기 재료상수는 시행 착오법으로 생성한 양수의 하한값 및 상한값 범위 내 임의의 값이 적용되도록 재료상수 파일을 생성하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 4

제1항에 있어서,

상기 최적화 시스템을 구축하는 단계는,

상기 피삭재를 실제 절삭하며 획득한 실험데이터에서 재료상수 테이블을 획득하는 단계;

상기 재료상수 테이블에서 절입부와 종료 직전 구간을 제외한 재료상수 데이터를 추출하는 단계; 및

상기 재료상수 데이터를 기반으로 미리 생성한 배치(Batch) 파일을 MATLAB에 적용하여 자동화 코드를 설계하는 단계;

를 포함하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 5

제4항에 있어서,

상기 MATLAB을 이용하여 복수의 상기 실험데이터 각각에서 상기 최적화를 수행하는 단계 및 최적의 재료상수를 획득하는 단계를 자동화하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 6

제1항에 있어서,

상기 최적화를 수행하는 단계는 국부 최적화(Local Optimization) 또는 전역 최적화(Global Optimization)를

이용하여 수행하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 7

제6항에 있어서,

상기 지역 최적화는 MATLAB의 내장함수인 Fmincon의 최적화 알고리즘으로 순차적 2차 계획법(Sequential quadratic programming, SQP)을 이용하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 8

제6항에 있어서,

상기 전역 최적화는 유전자 알고리즘(Genetic algorithm, GA)을 기반으로 수행하며,

상기 유전자 알고리즘은 인구수, 세대수 및 돌연변이(Mutation)를 기설정된 범위로 설정하고, 최적화 결과가 음수가 나오지 않도록 제한조건을 추가하여 최적화를 수행하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 9

제1항에 있어서,

상기 최적의 재료상수를 획득하는 단계는,

데이터 간 거리를 균일하게 배치하고 분산을 일정하게 선정하는 최적 라틴 방격법(Optimal latin hypercube design, OLHD)를 이용하여 각 공정조건 별로 기설정된 개수의 데이터를 샘플링하여 획득하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 10

제1항에 있어서,

상기 딥러닝 알고리즘은 다층 퍼셉트론(Multi-layer perceptron, MLP)을 활용한 DNN(Deep Neural Network)으로 구성되며, 상기 최적의 재료상수를 기반으로 학습 및 테스트를 수행하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 11

제1항에 있어서,

상기 딥러닝 알고리즘은 준비된 데이터 셋을 기설정된 비율로 훈련 데이터와 제1 테스트 데이터로 분리하고, 상기 훈련 데이터는 k겹 교차 검증(k-fold cross validation)을 적용해 기설정된 비율로 훈련 데이터와 제2 테스트 세트로 구분하여 학습 및 테스트를 수행하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 12

제11항에 있어서,

상기 딥러닝 알고리즘은 손실 함수(Loss function)로 평균 제곱 오차(Mean squared error, MSE)를 사용하여 학습 결과와 실제 데이터 값 간의 차이에 대한 가중치를 부여하며, 상기 손실 함수에 기반한 상기 딥러닝을 최적화하기 위하여 확률적 경사 하강법(Stochastic gradient descent)을 사용하고, 상기 딥러닝은 평균 절대 오차(Mean abosolute error, MAE)를 이용하여 모델을 검증하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법.

청구항 13

피삭재의 시뮬레이션의 절삭력을 도출하기 위하여 상기 절삭력 평균값의 상대 오차율을 최소로 하는 구성방정식 재료상수를 도출하는 재료상수도출부;

상기 재료상수의 범위를 설정하고, 상기 재료상수 범위를 기반으로 재료상수 최적화를 수행하며, 최적화된 재료상수를 이용하여 최적의 재료상수를 획득하는 재료상수 최적화부; 및

딥러닝 알고리즘에 상기 최적의 재료상수를 인가하여 절삭 가공 조건에 대한 상기 피삭재의 절삭력 및 온도를 예측하는 예측부;

를 포함하며,

상기 최적의 재료상수는 최적 라틴 방격법(Optimal latin hypercube design, OLHD)를 이용하여 각 공정조건 별로 기설정된 개수의 데이터를 샘플링하고,

상기 예측부는 상기 샘플링 데이터를 기설정된 비율로 훈련 데이터와 제1 테스트 데이터로 분리하고, 상기 훈련 데이터는 k겹 교차 검증(k-fold cross validation)을 적용해 기설정된 비율로 훈련 데이터와 제2 테스트 세트로 구분하여 학습 및 테스트를 수행하며, 평균 제곱 오차(Mean squared error, MSE), 평균 제곱근 오차(Root mean squared error, RMSE) 및 결정계수(R-squared, R^2)를 기반으로 성능을 평가하는 것을 특징으로 하는 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 절삭 가공 조건에 따른 절삭력 및 온도 예측 방법에 관한 것으로, 구체적으로는 딥러닝을 기반으로 절삭 가공 조건에 따른 피삭재의 절삭력 및 온도를 예측하는 방법에 관한 것이다.

배 경 기 술

[0002] 4차 산업혁명 시대에 맞춰 제조시스템은 제조업혁신 3.0 전략, 지역 위기 제조산업 활성화 방안, 스마트 산단 조성 및 제조 창업 공간 지원 등의 정책을 통해 시스템 변화를 시도하고 있다.

[0003] 그러나, 이러한 변화는 실무자의 경험을 기반을 두고 있는 절삭가공산업은 인력 부족과 글로벌 경쟁 심화로 인한 국내 제조업의 근간인 절삭산업 쇠퇴에 의해 국가적 경쟁력이 감소하고 지역경제 침체의 원인이 되고 있으며, 글로벌 선진기업들의 절삭공구 데이터 플랫폼은 자사의 공구만을 대상으로 하고 있어 현장 가공정보나 공작기계와 연계되지 않아 제조공정 지능화에 한계가 있다.

[0004] 절삭가공은 공구와 피삭재의 직접 접촉에 의한 가공으로 최종 결과물은 공구 형상, 공구 소재, 공구 코팅, 공구 수명에 따라 큰 영향을 받으며, 피삭재의 기계적 물성과 절삭성에 대한 정보는 공구 정보와 함께 최종적인 가공 품질을 좌우할 수 있는 중요한 요소로 인식되고는 있으나, 절삭공구와 피삭재의 특성을 포함한 가공 관련 데이터베이스(DB) 구축은 아직 요원하며, 이에 따라 유한요소해석을 위한 소재 물성이 존재하지 않는 경우 물성 제작에 고비용이 발생하기 때문에 이를 극복하기 위하여 절삭조건별로 절삭력을 제공하는 플랫폼이 요구되고 있다.

선행기술문헌

특허문헌

[0005] (특허문헌 0001) 대한민국 공개특허공보 제10-2022-0060921호 (2022년05월12일 공개)

발명의 내용

해결하려는 과제

[0006] 본 발명은 상기 기술적 과제에 대한 문제점을 해결하기 위한 것으로, 신경망을 이용하여 절삭 공구를 이용한 부품 가공공정에서 피삭재의 절삭력과 온도를 예측하는 방법을 제공하는데 그 목적이 있다.

[0007] 다른 측면에서 본 발명은 유한요소해석을 위한 소재 물성이 존재하지 않는 경우 발생하는 고비용 문제를 해결하

기 위하여 절삭 조건별로 절삭력을 제공하는 플랫폼을 제공하는데 그 목적이 있다.

과제의 해결 수단

[0008] 상기 기술적 과제를 해결하기 위한 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법은 피삭재의 재료상수 범위를 선정하는 단계, 상기 재료상수를 최적화하기 위하여 최적화 시스템을 구축하는 단계, 상기 최적화 시스템을 이용하여 상기 재료상수의 전역 최적화(Global Opimization)를 수행하는 단계, 상기 전역 최적화된 상기 재료상수를 기반으로 최적의 재료상수를 획득하는 단계 및 딥러닝에 상기 최적의 재료상수를 인가하여 절삭 가공 조건에 대한 절삭력 및 온도를 예측하는 단계를 포함할 수 있다.

[0009] 또한, 상기 재료상수는 항복강도, 가공경화 상수, 변형률 속도 경화 상수, 변형률 속도 제어 상수 및 온도 연화 지수를 포함하며, 상기 항복강도 및 가공경화 상수는 S-K 구성방정식을 이용하여 획득하고, 상기 변형률 속도 경화 상수, 변형률 속도 제어 상수 및 온도 연화 지수는 존슨-쿡(Johnson-Cook) 구성방정식을 이용하여 획득할 수 있다.

[0010] 또한, 상기 재료상수는 시행 착오법으로 생성한 양수의 하한값 및 상한값 범위 내 임의의 값이 적용되도록 재료상수 파일을 생성할 수 있다.

[0011] 또한, 상기 최적화 시스템을 구축하는 단계는, 상기 피삭재를 실제 절삭하며 획득한 실험데이터에서 재료상수 테이블을 획득하는 단계, 상기 재료상수 테이블에서 절입부와 종료 직전 구간을 제외한 재료상수 데이터를 추출하는 단계 및 상기 재료상수 데이터를 기반으로 미리 생성한 배치(Batch) 파일을 MATLAB에 적용하여 자동화 코드를 설계하는 단계를 포함할 수 있다.

[0012] 또한, 상기 MATLAB을 이용하여 복수의 상기 실험데이터 각각에서 상기 전역 최적화를 수행하는 단계 및 최적의 재료상수를 획득하는 단계를 자동화할 수 있다.

[0013] 또한, 상기 최적화를 수행하는 단계는 국부 최적화(Local Optimization) 또는 전역 최적화(Global Optimization)를 이용하여 수행할 수 있다.

[0014] 또한, 상기 지역 최적화는 MATLAB의 내장함수인 Fmincon의 최적화 알고리즘으로 순차적 2차 계획법(Sequential quadratic programming, SQP)을 이용할 수 있다.

[0015] 또한, 상기 전역 최적화는 유전자 알고리즘(Genetic algorithm, GA)을 기반으로 수행하며, 상기 유전자 알고리즘은 인구수, 세대수 및 돌연변이(Mutation)를 기설정된 범위로 설정하고, 최적화 결과가 음수가 나오지 않도록 제한조건을 추가하여 최적화를 수행할 수 있다.

[0016] 또한, 상기 최적의 재료상수를 획득하는 단계는, 데이터 간 거리를 균일하게 배치하고 분산을 일정하게 선정하는 최적 라틴 방격법(Optimal latin hypercube design, OLHD)를 이용하여 각 공정조건 별로 기설정된 개수의 데이터를 샘플링하여 획득할 수 있다.

[0017] 또한, 상기 딥러닝은 다층 퍼셉트론(Multi-layer perceptron, MLP)을 활용한 DNN(Deep Neural Network)으로 구성되며, 상기 최적의 재료상수를 기반으로 학습 및 테스트를 수행할 수 있다.

[0018] 또한, 상기 딥러닝은 준비된 데이터 셋을 기설정된 비율로 훈련 데이터와 제1 테스트 데이터로 분리하고, 상기 훈련 데이터는 k겹 교차 검증(k-fold cross validation)을 적용해 기설정된 비율로 훈련 데이터와 제2 테스트 세트로 구분하여 학습 및 테스트를 수행할 수 있다.

[0019] 또한, 상기 딥러닝은 손실 함수(Loss function)로 평균 제곱 오차(Mean squared error, MSE)를 사용하여 학습 결과와 실제 데이터 값 간의 차이에 대한 가중치를 부여하며, 상기 손실 함수에 기반한 상기 딥러닝을 최적화하기 위하여 확률적 경사 하강법(Stochastic gradient descent)을 사용하고, 상기 딥러닝은 평균 절대 오차(Mean abosolute error, MAE)를 이용하여 모델을 검증할 수 있다.

[0020] 본 발명의 또 다른 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 시스템은 피삭재의 시뮬레이션의 절삭력을 도출하기 위하여 상기 절삭력 평균값의 상대 오차율을 최소로 하는 구성방정식 재료상수를 도출하는 재료상수도출부, 상기 재료상수의 범위를 설정하고, 상기 재료상수 범위를 기반으로 재료상수 최적화를 수행하며, 최적화된 재료상수를 이용하여 최적의 재료상수를 획득하는 재료상수 최적화부, 딥러닝 알고리즘에 상기 최적의 재료상수를 인가하여 절삭 가공 조건에 대한 상기 피삭재의 절삭력 및 온도를 예측하는 예측부를 포함하며, 상기 최적의 재료상수는 최적 라틴 방격법(Optimal latin hypercube design, OLHD)를 이용하여 각 공정조건 별로 기설정된 개수의 데이터를 샘플링하고, 상기 예측부는 상기 샘플링 데이터를 기설정된 비율로 훈련

데이터와 제1 테스트 데이터로 분리하고, 상기 훈련 데이터는 k겹 교차 검증(k-fold cross validation)을 적용해 기설정된 비율로 훈련 데이터와 제2 테스트 세트로 구분하여 학습 및 테스트를 수행하며, 평균 제곱 오차(Mean squared error, MSE), 평균 제곱근 오차(Root mean squared error, RMSE) 및 결정계수(R-squared, R^2)를 기반으로 성능을 평가할 수 있다.

발명의 효과

[0021] 상기한 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법은 높은 정확도로 절삭가공 공정에 대한 피삭재의 절삭력 및 온도를 예측할 수 있다.

[0022] 또한, 자동화, 최적화 기반 최적 재료상수를 데이터화 함으로써 절삭가공 조건들의 재료상수 및 절삭력을 예측하여 제조회사의 시장 진입 문턱을 낮출 수 있다.

[0023] 또한, 절삭 가공 조건에 따른 실제 테스트를 수행하지 않고 절삭력 및 온도를 예측함으로써 공정 기한 단축 및 수익 향상에 도움을 줄 수 있다.

도면의 간단한 설명

[0024] 도 1은 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 및 온도 예측 방법의 순서도이다.

도 2는 본 발명의 일 실시예에 따른 재료상수 최적화 시스템을 구축하기 위한 재료상수 검출 자동화 방법에 대한 순서도이다.

도 3은 본 발명의 일 실시예에 따른 재료상수의 국부 최적화를 수행하는 방법에 대한 순서도이다.

도 4은 본 발명의 일 실시예에 따른 재료상수의 전역 최적화를 수행하는 방법에 대한 순서도이다.

도 5는 본 발명의 일 실시예에 따른 목적함수 및 설계변수에 관한 구성방정식 재료상수 최적화를 위한 수학식을 도시하는 도면이다.

도 6는 본 발명의 일 실시예에 따른 전역 최적화를 재정식화한 수학식을 도시하는 도면이다.

도 7은는 본 발명의 일 실시예에 따른 딥러닝 학습을 위한 훈련 데이터 생성자동화 방법에 대한 순서도이다.

도 8은 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법의 성능 평가에 대한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0025] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시 예를 가질 수 있는 바, 특정 실시 예들을 도면에 예시하고 상세하게 설명하고자 한다.

[0026] 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0027] 본 출원에서 사용한 용어는 단지 특정한 실시 예를 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, "포함하다" 또는 "가지다" 등의 용어는 명세서상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0028] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 가진 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0029] 이하, 첨부한 도면들을 참조하여, 본 발명의 바람직한 실시 예를 보다 상세하게 설명하고자 한다. 본 발명을 설명함에 있어 전체적인 이해를 용이하게 하기 위하여 도면상의 동일한 구성요소에 대해서는 동일한 참조부호를

사용하고 동일한 구성요소에 대해서 중복된 설명은 생략한다.

[0030] 본 발명의 일 실시예에서는 피삭재에 대한 절삭력 및 온도를 예측하기 위한 절삭 실험의 공정 조건인 절삭 깊이(Depth of cut), 이송 속도(Feedrate) 및 절삭 속도(Cutting speed)와 동일한 시뮬레이션 공정 조건을 설정 후 절삭력 비교를 진행하였으며, 절삭력은 주분력(Principal cutting force, Force-X) 및 배분력(Radical force, Force-Y)으로 구성될 수 있다.

[0031] 우선, 실험값을 따르는 시뮬레이션의 절삭력을 도출하여야 하며, 이를 위해 실험 및 시뮬레이션 절삭력 평균값의 상대 오차율을 최소로 하는 구성방정식 재료상수(A, B, C, D, E, m)을 도출하여야 하며, 재료상수는 S-K 구성방정식을 따르는 항복강도(A), 가공경화 상수(B, C)와 Johnson-cook 구성방정식을 따르는 변형률 속도 경화 상수(D), 변형률 속도 제어 상수(E) 및 온도 연화 지수(m)일 수 있다.

[0032] 본 발명의 일 실시예에서 적용되는 Johnson-Cook 구성방정식은 재료의 고변형률 시험에서 얻어지는 소성 유동 응력의 모델링을 진행하거나 예측하기 위해 사용되며, S-K 구성방정식은 재료상수 A, B, C 세 가지 함수를 분리하여 구성방정식을 만들었을 때 재료 유동 응력을 기술하는 데에 유리할 수 있다.

[0033] 본 발명의 일 실시예에 이용된 Johnson-Cook 구성방정식 및 S-K 구성방정식은 하기의 수학식 1로 표현할 수 있다.

수학식 1

[0034]

$$\sigma = [A + B\varepsilon^{n}][1 + C \cdot \ln(\frac{\dot{\varepsilon}}{\dot{\varepsilon}_0})][1 - (\frac{(T - T_{ref})}{(T_{melt} - T_{ref})})^{m}]$$

$$\sigma = [A + B(1 - \exp(-C\varepsilon))]$$

$$[D \cdot \ln(\frac{\dot{\varepsilon}}{\dot{\varepsilon}_0}) + \exp(E \cdot (\frac{\dot{\varepsilon}}{\dot{\varepsilon}_0}))][1 - \frac{(T - T_{ref})}{(T_{melt} - T_{ref})})]^{m}$$

[0035] 상기의 수학식 1에서 A, B, C, D, E, m은 재료상수이고, T는 온도이고, T_{melt}는 용융온도이고, T_{ref}는 기준온도이고, ε는 유효소성변형률이고, $\dot{\varepsilon}$는 변형률 속도이며, $\dot{\varepsilon}_0$는 단위 변형률 속도일 수 있다.

[0036] 다만, 재료상수를 구하기 위하여 본 발명의 일 실시예에서는 S-K 구성방정식 및 Johnson-cook 구성방정식을 이용하는 방법에 대해 개시하고 있으나, 이에 한정되지 않으며, 절삭력을 도출하기 위한 재료상수를 구하기 위하여 이용 가능한 모든 구성방정식을 포함한 다양한 기법을 적용하여 재료상수를 획득할 수 있다.

[0037] 도 1은 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 및 온도 예측 방법의 순서도이다.

[0038] 본 발명의 일 실시예에 따른 절삭력 및 온도 예측 방법은 피삭재에 대한 재료 상수의 범위를 선정할 수 있다(S100).

[0039] 재료상수의 범위는 음수 값이 기입되지 않도록 양수 중 임의로 선정한 범위일 수 있으며, 이에 음수 값이 되지 않도록 재료 상수의 하한값(Lower bound)와 상한값(Upper bound)의 범위를 설정할 수 있다.

[0040] 상기 하한값과 상한값의 범위는 시행 착오법(Trial and error)을 이용할 수 있으며, 시행 착오법은 수치 계산법의 일종으로서 조건 부족 등으로 문제 해결의 확실한 순서를 모를 경우에 적당하다고 생각되는 순서를 택하여 시험하고, 잘못이라고 생각되면 순서에 따라 적당하다고 생각되는 순서를 선택하여 시험하는 방법으로 여러 번 실험을 시행하면서 그 결과들의 인과관계를 추론하여 최적해를 도축하는 문제 방법이다. 이는 최적해에 도달하는 방법을 모를 경우, 시행과 착오를 되풀이하여 최적해를 도축할 수 있는 장점을 포함하고 있다.

[0041] 이에 본 발명의 일 실시예에서는 재료상수 범위 내의 최적 재료상수를 구하기 위해 실험을 반복하여 수행함으로써 시행 착오법으로 재료 상수의 범위를 설정할 수 있으며, 반복되는 실험에 대해 재료상수를 파일로 저장하여

활용할 수 있다.

[0042] 상기 S100 단계에서 획득한 재료상수의 범위를 기반으로 절삭력 예측을 위한 최적의 재료상수를 획득하기 위한 재료상수 최적화 시스템을 구축할 수 있다(S200).

[0043] 본 발명의 일 실시예에서는 시스템 자동화에 기반한 실험 및 절삭력(주분력, 배분력) 데이터의 평균값 상대 오차율이 최소가 되는 재료상수(최적의 재료상수) 도출을 위하여 코드에 기반한 시스템을 이용할 수 있다.

[0044] 코드에 기반한 시스템을 구현하기 위하여 배치(Batch)파일을 선행하여 생성할 수 있으며, 배치 파일은 윈도우(Window)에서 명령어 인터프린터(Command-line interpreter)에 의해 실행되게끔 고안된 명령어들이 나열되어 있는 텍스트(Text)파일로서 텍스트 파일 형식인 메모장(Notepad)에 시뮬레이션 실행 명령어를 입력한 후 배치파일 확장자(.bat)로 저장하여 바로 시뮬레이션 실행을 수행할 수 있도록 할 수 있다.

[0045] 또한, 시뮬레이션의 진행 여부를 확인하기 위하여 해석이 종료됨과 동시에 더미 파일을 생성할 수 있는 코드를 설계하고, 이에 자동화 실행 시 이전에 생성된 더미 파일을 삭제할 수 있는 코드를 추가로 입력하여 해석 시작 및 종료 여부를 확인할 수 있도록 할 수 있으며, 더미 파일은 텍스트 파일 등의 임시 파일로서 해석 동작의 시작 및 종료를 구분할 수 있는 방식이라면 그 방식을 제한하지 않고 이용될 수 있다.

[0046] 상기 해석을 수행하는 방법으로는 실험 및 시뮬레이션 절삭력(주분력, 배분력) 데이터를 보관하고 있는 결과값 파일에서 데이터를 추출하는 과정을 의미할 수 있다. 따라서, 결과값 파일에서 데이터를 추출하기 위하여 코드 설계가 필수적으로 필요하며, 결과값 파일은 시간에 따른 주분력, 배분력, 파워(Power, W), 토크(Torque, N-m) 및 온도(Temperature, T) 순서로 나열될 수 있으며, 일반적으로 걱 결과값 파일은 190000개의 행과 6개의 열을 포함하는 테이블 형태일 수 있다.

[0047] 상기와 같이 피삭재를 실제 절삭하는 실험을 통해 획득한 실험데이터(결과값 파일)에서 재료상수 테이블을 획득하면, 획득한 재료상수 테이블에서 추출 데이터 선정을 수행할 수 있다.

[0048] 결과값 파일에 대해 그래프 형태로 변환하면 일반적으로 절삭력 그래프는 절삭 수행 후 0.0001초가 되기 전 급격하게 증가하는 형태를 보이며 약 0.00045초부터 약 0.0009초까지 하나의 값으로 수렴하는 형태를 나타낼 수 있고, 이후 절삭 종료 전 급격하게 감소하는 형태를 포함할 수 있다.

[0049] 상기와 같은 그래프 형태에서 수렴하는 형태를 나타내는 이유로는 절삭 시 재료와 공구 사이에 열이 발생하며, 이러한 열에 의해 절삭력이 낮아지는 열연화 현상(Thermal Softening Effect)이 발생하기 때문이며, 이러한 정상적이지 않은 구간인 절입부와 종료 직전 구간 데이터를 제외한 구간의 절삭력 내에서 데이터를 추출하여야 정상적인 절삭력 데이터를 추출할 수 있다.

[0050] 본 발명의 일 실시예에서는 0.00045초 내지 0.0009초까지의 0.00045초 동안의 절삭력 내에서 데이터를 추출하였으며, 끝행에서 감소하는 5000개의 행 데이터들을 제거 후 남은 데이터로부터 50000개의 데이터를 추출하여 절삭력 예측을 위한 최적의 재료상수를 획득하기 위한 기본 데이터로 활용하였다.

[0051] 데이터 추출이 완료되면 추출된 데이터를 기반으로 배치 파일을 MATLAB에 적용하여 자동화 코드를 설계하며, 설계된 자동화 코드를 기반으로 최적화된 재료상수를 획득할 수 있다.

[0052] 본 발명의 일 실시예에서는 최적화 시스템 구축을 위하여 자동화 코드는 상용 프로그램인 MATLAB을 사용하여 설명하고 있으나, 이에 제한하지 않고 최적의 재료상수를 획득할 수 있는 방법이라면 모든 방법을 활용할 수 있다.

[0053] 도 2는 본 발명의 일 실시예에 따른 재료상수 최적화 시스템을 구축하기 위한 재료상수 검출 자동화 방법에 대한 순서도이다.

[0054] 도 2를 참조하면, 반복(While)문 코드를 기반으로 자동화 설계를 수행하였으며, 결과값 파일(case_01_wp.twn)이 인가되면 재료상수(A, B, C, D, E, m)의 범위를 불러올 수 있다.

[0055] 시뮬레이션 프로그램(AdvantEdge)에 의해 배치 파일이 실행되면 결과값 파일을 불러와 절삭력 예측을 위해 절입부와 종료 직전 구간 데이터를 제외한 구간의 데이터를 불러와 주분력(Principal cutting force, Force-X) 및 배분력(Radical force, Force-Y) 데이터를 추출하며, 실험 및 시뮬레이션의 평균 절삭력 상대 오차율이 3%하일 경우 시스템을 종료할 수 있다.

[0056] 상기와 같은 방법을 이용하여 절삭력(주분력, 배분력) 추출 데이터에 대해 평균값과 상대 오차율을 최소화하기

위하여 시간적 계산 비용(cost)을 고려해 최적화(Optimization)를 수행할 필요가 있다(S300).

[0057] 설계변수는 재료상수(A, B, C, D, E, m)이며, 이에 따른 실험 및 시뮬레이션에서 도출한 평균 절삭력의 상대 오차율 최소화를 목적함수(Objective function)로 선정할 수 있다. 또한, 배분력(Force-Y)보다 주분력(Force-X)이 절삭력에 영향을 주는 주 변수이므로, 주분력 및 배분력의 비중을 각각 80% 및 20%로 적용할 수 있다.

[0058] 이하 내용에서 주분력 및 배분력 상대 오차율은 각각 Obj. 1 및 Obj. 2로 개시하며, 최적화의 목적함수인 비중을 고려한 절삭력의 상대 오차율은 Obj로 개시할 수 있다. 주분력 및 배분력의 상대 오차율에 영향을 주는 제한조건(Constraint function)은 없기 때문에 제한조건을 제외하였으며, 이에 목적함수 및 설계변수에 관한 구성방정식 재료상수 최적화 문제를 정식화하면 도 5와 같이 정리할 수 있다.

[0059] 피삭재에 대한 재료상수를 최적화하는 방법으로는 전역 최적화 기법(Global Optimization method) 및 국부 최적화 기법(Local Optimization method)을 이용할 수 있다.

[0060] 도 3은 본 발명의 일 실시예에 따른 재료상수의 전역 최적화를 수행하는 방법에 대한 순서도로서, 국부 최적화 기법은 볼록 함수(Convex function) 문제 해결에 적합하며, 간단한 계산으로 최적값을 도출할 수 있다.

[0061] 국부 최적화 기법은 초기 최적화 구성 시 상대적 계산 비용이 적은 장점이 있으며, 절삭력(주분력, 배분력) 상대 오차율 최소화를 달성하기 위해 본 발명의 일 실시예에서는 MATLAB의 내장 함수(Function)인 Fmincon을 사용하여 결정론적 설계 최적화(Deterministic design optimization, DDO)를 수행할 수 있다.

[0062] 상기 Fmincon은 최적화 알고리즘(Algorithm)으로 순차적 2차 계획법(Sequential quadratic programming, SQP)을 사용하며, 이는 비선형 수학적 계획법의 일종이며 함수의 2차 미분 정보를 이용해 최적 탐사 방향을 결정하는 반복 기법이므로 비선형 지배방정식에 대해 접근하기 쉬운 장점을 가지고 있다.

[0063] 또한, 시간 단축 및 제약조건을 만족하지 않는 문제점을 해결하기 위하여 Active-set 최적화 알고리즘을 이용할 수 있다.

[0064] 도 4는 본 발명의 일 실시예에 따른 재료상수의 전역 최적화를 수행하는 방법에 대한 순서도로서, 전역 최적화 기법은 유전자 알고리즘(Genetic algorithm, GA)에 기반하여 최적화를 수행할 수 있다.

[0065] 유전자 알고리즘은 자연 세계의 진화과정에서 기초한 계산 모델로서 최적화 문제를 해결하는 기법 중 하나로서 실제 진화 과정에서 많은 부분을 차용하였으며, 생물학적 용어에 비유한 개념(Population, Generation, Chromosome, Gene 등)과 연산(Reproduction, Crossover, Mutation 등)이 알고리즘 내에서 수행될 수 있다.

[0066] 이에 전역을 탐색하여 최적값을 구하기 위해 MATLAB에서 GA 최적화를 국부 최적화와 동일하게 구성방정식 재료상수 범위 및 초기값을 선정한 후 코드 설계를 진행할 수 있으며, GA 연산 종류인 인구수(Population)와 세대수(Generation)가 크면 최적화 시간이 오래 걸리므로 최적화 진행의 시간 절약을 위해 인구수, 세대수를 기설정된 값으로 결정하여 진행하는 한편, 돌연변이(Mutation)를 10%로 설정하여 전역에서 최적값을 탐색할 수 있는 확률을 증가할 수 있다.

[0067] 또한, GA 최적화 진행 중 입력되는 재료상수 B, D, E, m 값이 음수로 도출되는 문제가 발생할 수 있으며, 이는 도 5에서와 재료상수 최적화 문제를 정식화한 값 중 재료상수의 선정 범위를 벗어난 값으로써 선정 범위에 위배되는 값이다. 이러한 문제를 해결하기 위하여 전역 최적화를 수행하는 알고리즘에 재료상수 B, D, E, m값이 음수로 도출하지 않도록 제한조건을 더할 수 있다.

[0068] 도 6은 본 발명의 일 실시예에 따른 전역 최적화를 재정식화한 수학식을 도시하는 도면으로서, 도 5와 비교하여 설명하면 재료상수 B, D, E, m 값이 음수가 되지 않도록 추가적인 제한이 설정되어 있음을 쉽게 확인할 수 있다.

[0069] 추가적으로, 최적화 진행 시간을 감소하기 위하여 본 발명의 일 실시예에서는 국부 최적화 기법 또는 전역 최적화 기법을 기반으로 재료상수 최적화를 수행하는 방법에 대해 개시하였으나, 이에 제한하지 않고 근사 최적 설계(Approximate design optimizaiton)를 적용한 구성방정식을 기반으로 최적화를 수행할 수도 있으며, 결과값을 기반으로 최적의 재료상수를 구하는 재료상수 최적화를 진행할 수 있다면 제한없이 모든 방법을 활용할 수 있다.

[0070] 국부 최적화 또는 전역 최적화 기법을 이용하여 재료상수의 최적화를 수행함으로써 최적의 재료상수를 획득할 수 있다(S400).

[0071] 최적의 재료상수는 일반적으로 최적화 진행 시 도출된 값 중 최소 상대 오차율을 가지는 재료 상수를 최적값(Optimum value)으로 선정할 수 있으며, 이는 실험 기반 주분력, 배분력 평균값의 상대 오차율이 최소인 값이 선정될 수 있다.

[0072] 최적의 재료상수를 획득하기 위하여 본 발명의 일 실시예에서는 실험계획법(Design of experiments, DOE)을 이용할 수 있으며, 실험계획법은 존재하는 변수로부터 정보를 수집하는 실험 방법을 계획하는 것을 의미한다. 이러한 실험계획법은 완전 배치법, 일부 실시법, 몬테-카를로 시뮬레이션 방법, 라틴 방격법(Latin hypercube design, LHD) 등이 있다.

[0073] 라틴 방격법은 다차원 분포에서 매개변수 값의 임의의 데이터를 생성하기 위한 통계적 방법으로서 이는 적은 실험 횟수로 측정치 분석이 가능하여 설계변수 증가에 따른 실험 횟수가 증가할 때 시간과 비용이 소비되는 것을 배제할 수 있는 장점을 갖는다.

[0074] 또한, 최적 라틴 방격법(Optimal latin hypercube design, OLHD)은 최적성 조건을 사용하여 데이터 간 거리를 균일하게 배치 및 분산이 일정하게 선정할 수 있는 장점이 있다. 본 발명의 일 실시예에서는 데이터의 복잡도를 줄이기 위해 일정

[0075] 하게 분산된 120개의 데이터를 딥러닝(Deep learning, DL) 훈련에 적용하기 적합한 OLHD를 이용하여 DOE를 수립하였다.

[0076] 상기에서 획득한 최적의 재료상수를 기반으로 OLHD를 사용하여 각 공정 조건마다 이동속도(Feedrate), 절삭속도(Cutting speed) 및 절삭 깊이(Depth of cut)에 대해 기설정된 개수의 데이터를 샘플링 하였으며, 상기 최적화 시스템을 기반으로 자동화 시스템을 구성할 수 있다.

[0077] 자동화 시스템에서 상기 샘플링된 공정 조건(이동속도, 절삭속도 및 절삭 깊이)에 따른 절삭력(주분력, 배분력) 및 온도가 도출될 수 있도록 자동화 코드를 설계할 수 있으며, 도 7과 같이 딥러닝 훈련 데이터 생성 자동화 알고리즘을 생성할 수 있다.

[0078] 도 7을 참조하면, OLHD 기반의 데이터가 입력되면 결과값 데이터를 호출하여 최적의 재료상수(A, B, C, D, E, m)을 추출하고, 추출된 최적의 재료상수로부터 공정 조건을 계산할 수 있다.

[0079] 공정 조건이 계산되면 시뮬레이션(AdvantEdge)을 기반으로 배치파일을 실행하여 절삭력 및 온도를 도출하며, 이는 기설정된 횟수의 샘플링 개수를 만족할 때까지 반복할 수 있다.

[0080] DL은 데이터(Data)를 사용하여 분류(Classification) 및 회귀(Regression)분석 하는데 사용되는 방법으로서, 이는 여러 비선형 변환기법의 조합을 통해 다량의 복잡한 데이터 속에서 핵심적인 내용 또는 기능을 요약하는 작업을 시도하는 기계 학습(Machine learning) 알고리즘의 집합으로 정의할 수 있다.

[0081] DL 기술의 주요 알고리즘에는 순환 신경회로망(Recurrent neural network, RNN), 합성곱 신경회로망(Convolution neural network, CNN), 심층 신경회로망(Deep neural network, DNN) 등이 있으며, RNN은 시계열(Time series) 데이터와 같이 시간의 흐름에 따라 변화하는 데이터를 학습하기에 적합하며, CNN은 시각적 영상 및 음성 데이터를 학습하기에 적합하다. 또한, DNN은 데이터가 복잡한 비선형 관계(Non-linear relationship)를 가지고 있을 때 학습하기에 적합하고, 본 발명의 일 실시예에서는 DNN 알고리즘을 이용하여 동작을 수행하고 있으나, DL기술이라면 제한없이 활용할 수 있다.

[0082] 본 발명의 일 실시예에서의 DL은 파이썬(Python)을 활용하여 딥러닝 훈련 환경을 구축하였으며, 데이터의 복잡도를 줄이기 위해 OLHD로 3개의 각 공정 조건마다 기설정된 개수(120개)를 샘플링(Input)하였으며, 시뮬레이션 자동화를 기반으로 120개 샘플링 데이터에 대한 절삭력(주분력, 배분력) 및 온도 데이터(Output)를 각각 도출하였다.

[0083] 본 발명의 일 실시예에서는 이러한 Input 및 Output 데이터를 사용하여 Input의 변화에 따른 Output을 예측할 수 있는 DL 예측 모델을 활용할 수 있다. 이를 위해 파이썬(Python) 기반 환경의 텐서플로우(Tensorflow) 와 케라스(Keras) 등의 라이브러리(Library)를 활용하여 연구를 진행하였으며, 3개의 공정 조건 변화에 따른 절삭력(주분력, 배분력) 및 온도와 DL 예측 모델 간의 오차율 최소를 목표로 할 수 있다.

[0084] 모델 학습에 있어서 중요시되는 것은 훈련(Train)에 사용한 데이터를 잘 맞추는 것이 아닌 훈련에 사용하지 않은 새로운 테스트(Test) 데이터를 잘 맞추는 것이다. 따라서, 훈련 및 테스트 데이터를 분리하는 것이 선행된다. 이에 Scikit-learn 패키지에서 제공하는 Train test split 모듈(Module)을 사용하여 OLHD로 샘플링

된 120개의 데이터 중 훈련 및 테스트 데이터를 각각 100개 및 20개로 분리하여 사용하였다. 20개의 테스트 데이터 셋은 향후 최종 예측 모델의 성능을 평가하는 데에 사용될 수 있다.

[0085] 우선, Input 데이터의 각 변수 간 단위가 달라 학습에 미치는 중요도가 달라지는 문제를 방지하기 위한 스케일링(Scailing) 방법으로 표준화(Standardization)를 사용하였다. 이는 데이터의 평균을 0, 표준편차를 1인 표준정규분포로 이동시키는 방법이며, 회귀분석에서 이상치(Outlier)가 있다면 평균과 표준편차 사이로 재조정하여 이상치를 희미하게 하는 효과를 가져올 수 있다. 이러한 방법은 하기의 수학식 2와 같이 훈련 및 평가데이터에 적용할 수 있다.

수학식 2

[0086] $$Z = \frac{x - \mu}{\sigma}$$

[0087] 상기의 수학식 2에서 x는 실제 값(Actual value)이고, μ는 평균값(Mean value)이며, σ는 표준편차(standard deviation)일 수 있다.

[0088] DL 모델에 대해 고정된 평가 데이터를 통해 모델의 성능을 검증하고 수정하는 과정을 반복하게 되면 평가 데이터에만 정확도가 높은 모델이 될 수 있으므로 이는 평가 데이터에 과적합(Overfitting)하게 되어 일반화된 예측 모델을 개발할 수 없다.

[0089] 이러한 문제를 해결하기 위하여 본 발명의 일 실시예에서는 분리한 100개의훈련 데이터를 다시 훈련(Train) 및 검증(Validation) 데이터로 분리하여 검증 데이터 셋을 사용해 검증하는 교차 검증을 수행할 수 있다. 또한, 교차 검증 방법을 통하여 모든 데이터 셋을 사용하여 검증하기 때문에 데이터 부족으로 인한 과소적합(Underfitting)문제를 해결할 수 있는 장점이 있다.

[0090] 일반적으로 교차 검증은 k겹 교차 검증(k-fold cross validation)과 계층별 k겹 교차 검증(Stratified k-fold cross validation) 방식으로 나눌 수 있으며, k겹 교차 검증은 회귀(Regression) 문제에 사용되고, 데이터가 동일한 분포를 가지고 있을 때 주로 사용될 수 있고, 계층별 k겹 교차 검증의 경우 분류(Classification)문제에서 사용되며, Output 레이블(Label)의 집합을 위한 방식으로 사용될 수 있다.

[0091] k겹 교차 검증은 훈련 데이터 셋을 k개로 분리한 후 k-1개를 훈련 데이터 셋으로 사용하고, 나머지 1개를 검증용 데이터 셋으로 사용할 수 있으며, 이를 k번 반복하여 k개의 성능지표를 도출함으로써 모델들의 평균 정확도(R^2)를 검증모델의 최종 성능으로 판단할 수 있다.

[0092] 본 발명의 일 실시예에서의 DL 모델은 다층 퍼셉트론(Multi-layer perceptron, MLP)을 활용한 네트워크를 이용할 수 있다. MLP 네트워크는 입력층, 은닉층, 출력층으로 이루어져 있으며, 심층 신경망으로 구성되어 있는 각각의 노드들은 비선형성을 예측할 수 있는 전결합 계층(Fully connected layer)으로 구성될 수 있다.

[0093] 본 발명의 일 실시예에서 입력층 및 출력층의 노드 수는 공정 조건과 예측하고자 하는 절삭력 및 온도에 의해 결정되므로 각각 3, 3으로 성하였으며, 은닉층의 노드 수는 50, 200, 300 및 500 (4 Hidden layers)으로 구성하였고, 수치예측을 위해 출력층은 회귀를 위한 계층으로 구성하였으나, 이에 제한을 두지 않고 입력층, 은닉층 및 출력층으로 구성되며, 절삭력 및 온도를 예측할 수 있는 모델이라면 모두 활용할 수 있다.

[0094] MLP의 활성화 함수(Activation function)로 회귀를 위한 출력층을 제외한 나머지 계층을 향후 기울기 소실 문제(Vanishing gradient problem)를 방지하기 위해 ReLU (Rectified linear unit)를 사용할 수 있다.

[0095] 학습을 진행하면서 예측된 결과값과 실제 데이터 값 간의 차이에 대한 가중치를 부여하기 위한 손실 함수(Loss function)로 평균 제곱 오차(Mean squared error, MSE)를 사용할 수 있으며, 검증모델의 성능 평가 지표로 MSE 및 평균 절대 오차(Mean absolute error, MAE)를 사용할 수 있다.

[0096] MSE 및 MAE는 하기의 수학식 3, 수학식 4로 구현될 수 있다.

수학식 3

[0097] $$\mathbf{MSE} = \frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2$$

수학식 4

[0098] $$\mathbf{MAE} = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i|$$

[0099] 상기 수학식 3 및 수학식 4에서 n은 샘플링 수이고, $\hat{y}_i$는 예측값(prediction value)이며, y_i는 실제 값(Actual value)일 수 있다.

[0100] 도 8은 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법의 성능 평가에 대한 도면이다.

[0101] 모델의 최종 성능 평가는 상기와 같이 분리한 훈련에 사용되지 않은 평가 데이터를 이용하여 수행될 수 있으며, 이를 사용하여 실제 성능을 평가하기 위해 표준화(Standardization)된 데이터를 실제 데이터로 변환하는 작업이 필요할 수 있다.

[0102] 이를 위해 Scikit-learn에서 제공하는 inverse_transform을 적용하여 모델 예측값(주분력, 배분력, 온도)을 실제 데이터로 변환하여 사용되었으며, 평가 데이터 20개를 사용하여 도출한 최종 모델 성능 평가 지표로 MAE, RMSE (Root mean squared error) 및 R2를 사용할 수 있다.

[0103] 상기와 같은 방법으로 학습 및 검증이 완료된 딥러닝 모델에 상기 S400 단계에서 획득한 최적의 재료상수를 인가하여 가공 조건에 대한 피삭재의 절삭력 및 온도를 예측할 수 있다(S500).

[0104] 상기 피삭재의 절삭력 및 온도는 MAE, RMSE (Root mean squared error) 및 R2를 사용하여 검증 및 확인함으로써

[0105] 이상에서와 같이 본 발명의 일 실시예에 따른 절삭가공 조건에 따른 딥러닝 기반 절삭력 예측 방법은 기존에 없던 유한요소해석 자동화, 딥러닝을 이용한 절삭력 예측 모델 훈련을 위한 데이터 셋(Data set) 생성으로 공구회사의 데이터 플랫폼으로 절삭력 예측의 향상을 기대할 수 있다.

[0106] 또한, 기업 컨설팅을 통해 국내 공구, 절삭 가공 관련 기업들은 자동화, 최적화 기반 최적 재료상수를 데이터 플랫폼에 적용하여 절삭공정조건들의 재료상수를 예측하고 딥러닝 기반 절삭력을 예측할 수 있는 모델을 개발할 수 있으며, 이를 통해 다양한 기업에 데이터 플랫폼을 제공함으로써 침체된 제조산업의 틈새 시장 진입성을 높이고 국가 경쟁력을 향상, 절삭 가공 기업에 납품하여 기업 이익 창출에 기여할 수 있다.

[0107] 상술한 실시 예에 설명된 특징, 구조, 효과 등은 본 발명의 적어도 하나의 실시 예에 포함되며, 반드시 하나의 실시 예에만 한정되는 것은 아니다. 나아가, 각 실시 예에서 예시된 특징, 구조, 효과 등은 실시예들이 속하는 분야의 통상의 지식을 가지는 자에 의하여 다른 실시예들에 대해서도 조합 또는 변형되어 실시 가능하다.

[0108] 따라서 이러한 조합과 변형에 관계된 내용들은 본 발명의 범위에 포함되는 것으로 해석되어야 할 것이다. 또한, 이상에서 실시 예들을 중심으로 설명하였으나 이는 단지 예시일 뿐 본 발명을 한정하는 것이 아니며, 본 발명이 속하는 분야의 통상의 지식을 가진 자라면 본 실시예의 본질적인 특성을 벗어나지 않는 범위에서 이상에 예시되지 않은 여러 가지의 변형과 응용이 가능함을 알 수 있을 것이다. 예를 들어, 실시 예들에 구체적으로 나타난 각 구성 요소는 변형하여 실시할 수 있는 것이다. 그리고 이러한 변형과 응용에 관계된 차이점들은 첨부한 청구 범위에서 규정하는 본 발명의 범위에 포함되는 것으로 해석되어야 할 것이다.

도면

도면1

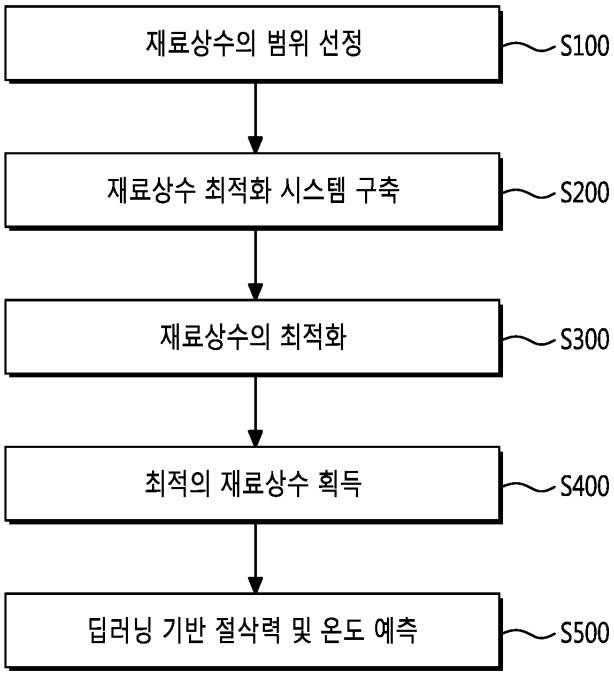
재료상수의 범위 선정
S100
재료상수 최적화 시스템 구축
S200
재료상수의 최적화
S300
최적의 재료상수 획득
S400
딥러닝 기반 절삭력 및 온도 예측
S500

도면2

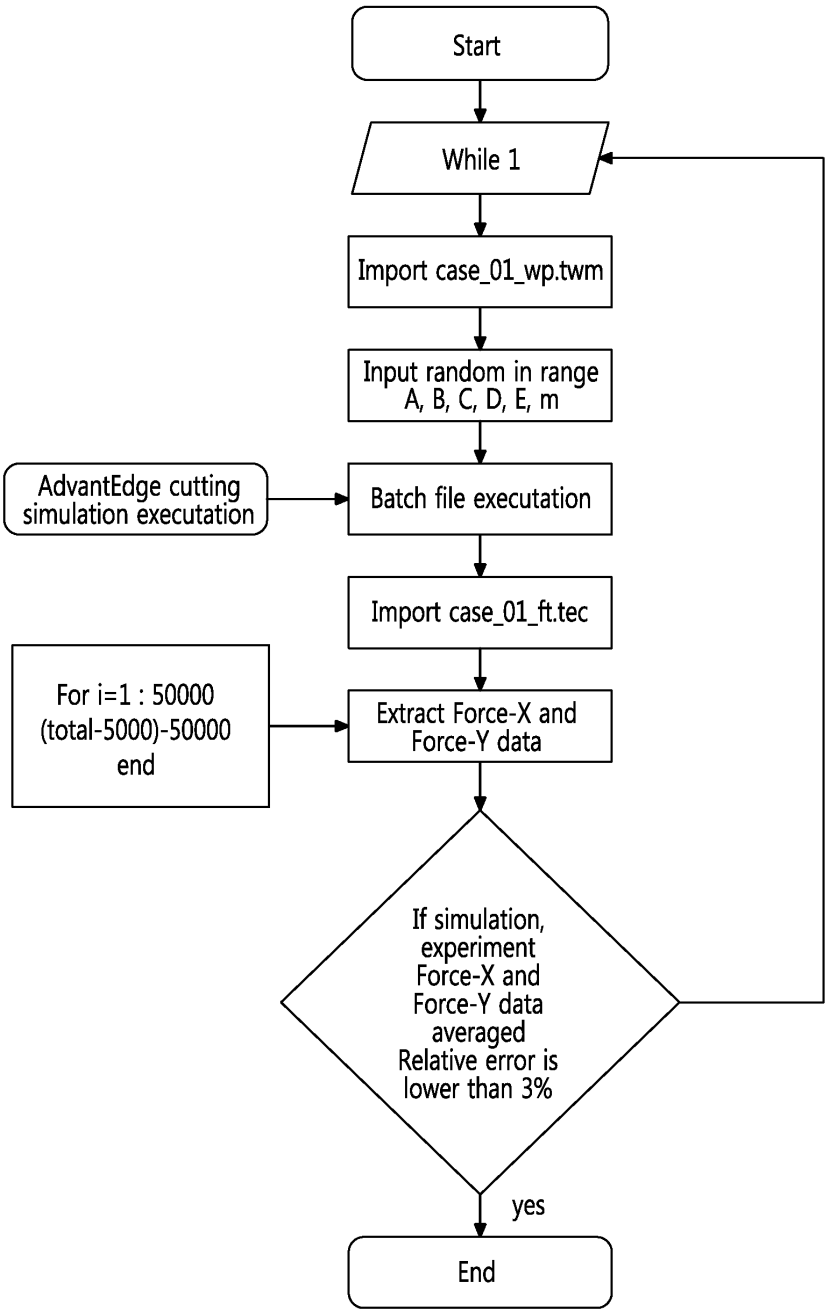
Start
While 1
Import case_01_wp.twm
Input random in range
A, B, C, D, E, m
AdvantEdge cutting
simulation executation
Batch file executation
Import case_01_ft.tec
For i=1 : 50000
(total-5000)-50000
end
Extract Force-X and
Force-Y data
If simulation,
experiment
Force-X and
Force-Y data
averaged
Relative error is
lower than 3%
yes
End

도면3

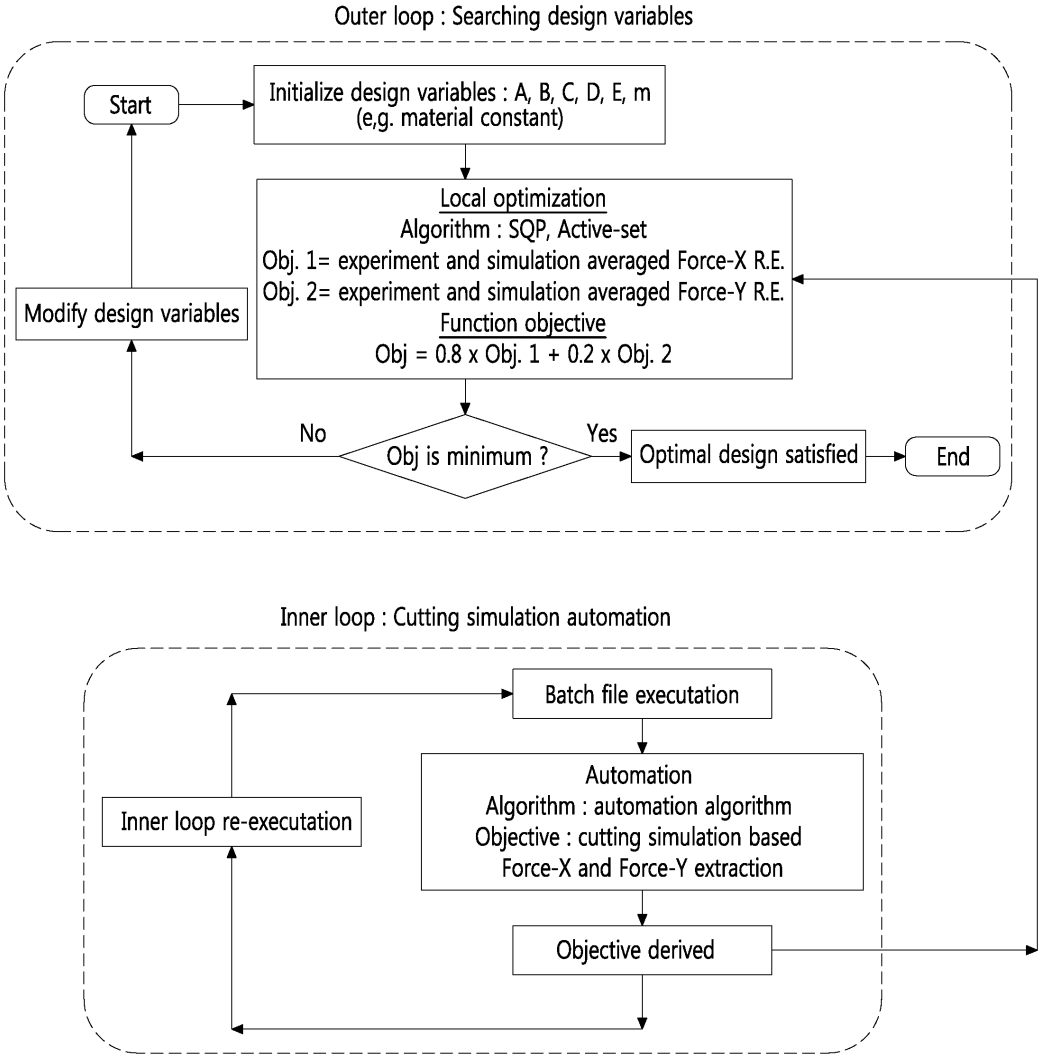
Outer loop : Searching design variables
Start
Initialize design variables : A, B, C, D, E, m
(e,g. material constant)
Local optimization
Algorithm : SQP, Active-set
Obj. 1= experiment and simulation averaged Force-X R.E.
Obj. 2= experiment and simulation averaged Force-Y R.E.
Function objective
Obj = 0.8 x Obj. 1 + 0.2 x Obj. 2
Modify design variables
No
Obj is minimum ?
Yes
Optimal design satisfied
End
Inner loop : Cutting simulation automation
Batch file executation
Automation
Algorithm : automation algorithm
Objective : cutting simulation based
Force-X and Force-Y extraction
Objective derived
Inner loop re-executation

도면4

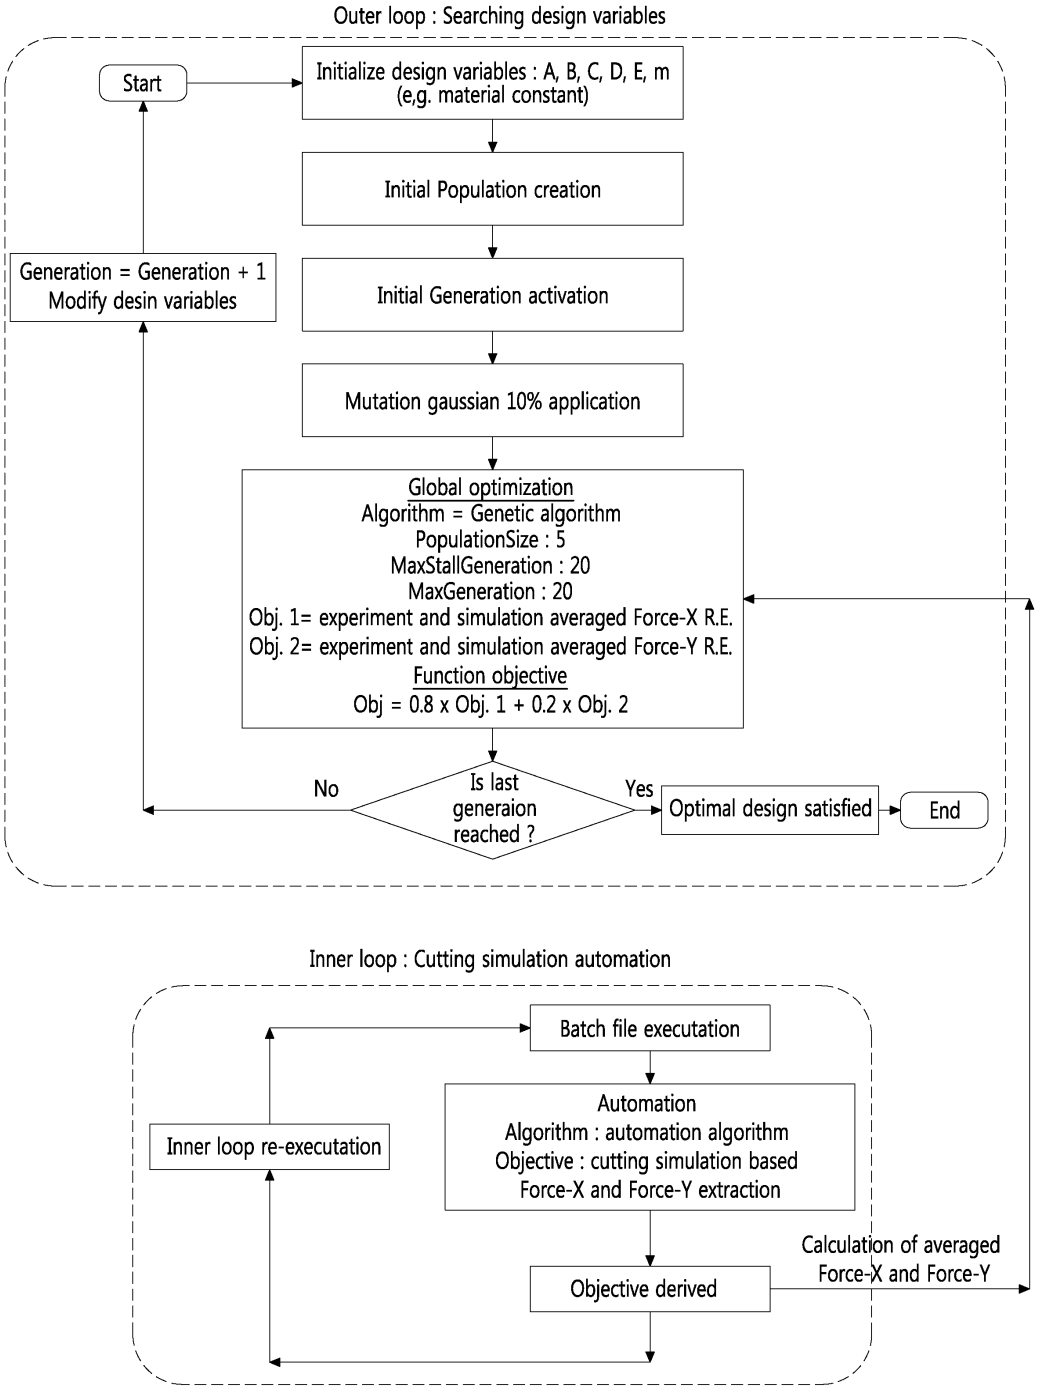
Outer loop : Searching design variables
Start
Initialize design variables : A, B, C, D, E, m
(e,g. material constant)
Initial Population creation
Initial Generation activation
Mutation gaussian 10% application
Global optimization
Algorithm = Genetic algorithm
PopulationSize : 5
MaxStallGeneration : 20
MaxGeneration : 20
Obj. 1= experiment and simulation averaged Force-X R.E.
Obj. 2= experiment and simulation averaged Force-Y R.E.
Function objective
Obj = 0.8 x Obj. 1 + 0.2 x Obj. 2
Is last generaion reached ?
No
Yes
Optimal design satisfied
End
Generation = Generation + 1
Modify desin variables
Inner loop : Cutting simulation automation
Batch file executation
Automation
Algorithm : automation algorithm
Objective : cutting simulation based
Force-X and Force-Y extraction
Objective derived
Calculation of averaged
Force-X and Force-Y
Inner loop re-executation

도면5

Find : $x=[A, B, C, D, E, m]^T$

Min. Relative error (R.E.)

R.E. = Obj = $w_1 \times$ Obj. 1 + $w_2 \times$ Obj. 2

Where:

$w_1 + w_2 = 1$

$w_1 = 0.8,\ w_2 = 0.2$

$f_{x_sim} = f(A, B, C, D, E, m)$

F(X) = [Averaged Force-X]

F(Y) = [Averaged Force-Y]

$$\text{Obj. } 1 = \left|\frac{F(X)_{f_{x_sim}} - F(X)_{exp}}{F(X)_{exp}}\right| \times 100\%$$

$$\text{Obj. } 2 = \left|\frac{F(Y)_{f_{x_sim}} - F(Y)_{exp}}{F(Y)_{exp}}\right| \times 100\%$$

Subject to :

$300 \le A \le 600$ (MPa)

$300 \le B \le 900$ (MPa)

$10 \le C \le 15$

$0.001 \le D \le 0.1$

$1e-6 \le E \le 1e-3$

$1 \le m \le 2$

Initial parameter :

[A, B, C, D, E, m] = [5.0e8, 7.0e8, 10, 0.001, 1e-6, 1]

도면6

Find : $x=[A, B, C, D, E, m]^T$

Min. Relative error (R.E.)

R.E. = Obj = $w_1 \times$ Obj. 1 + $w_2 \times$ Obj. 2

Where:

$w_1 + w_2 = 1$

$w_1 = 0.8,\ w_2 = 0.2$

$f_{x_sim} = f(A, B, C, D, E, m)$

F(X) = [Averaged Force-X]

F(Y) = [Averaged Force-Y]

$$\text{Obj. } 1 = \left|\frac{F(X)_{f_{x_sim}} - F(X)_{exp}}{F(X)_{exp}}\right| \times 100\%$$

$$\text{Obj. } 2 = \left|\frac{F(Y)_{f_{x_sim}} - F(Y)_{exp}}{F(Y)_{exp}}\right| \times 100\%$$

Subject to :

$$\frac{300}{g_B} - 1 \le 0 \text{ and } 1 - \frac{900}{g_B} \le 0$$

$$\frac{0.001}{g_D} - 1 \le 0 \text{ and } 1 - \frac{0.1}{g_D} \le 0$$

$$\frac{1e-6}{g_E} - 1 \le 0 \text{ and } 1 - \frac{1e-3}{g_E} \le 0$$

$$\frac{1}{g_m} - 1 \le 0 \text{ and } 1 - \frac{2}{g_m} \le 0$$

$300 \le A \le 600$ (MPa)

$300 \le B \le 900$ (MPa)

$10 \le C \le 15$

$0.001 \le D \le 0.1$

$1e-6 \le E \le 1e-3$

$1 \le m \le 2$

도면7

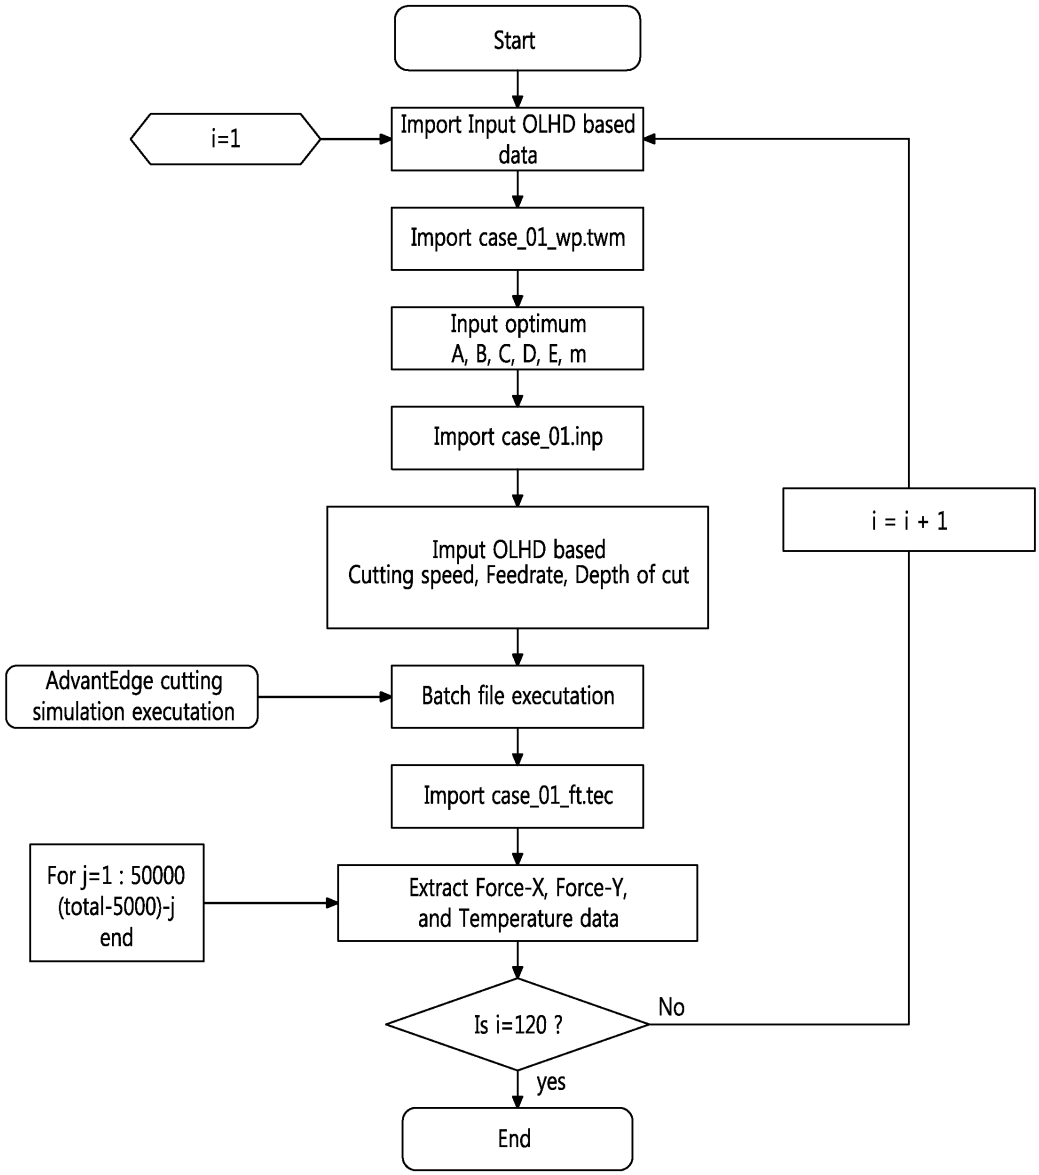
Start
i=1
Import Input OLHD based data
Import case_01_wp.twm
Input optimum A, B, C, D, E, m
Import case_01.inp
Imput OLHD based Cutting speed, Feedrate, Depth of cut
i = i + 1
AdvantEdge cutting simulation executation
Batch file executation
Import case_01_ft.tec
For j=1 : 50000 (total-5000)-j end
Extract Force-X, Force-Y, and Temperature data
Is i=120 ?
No
yes
End

도면8

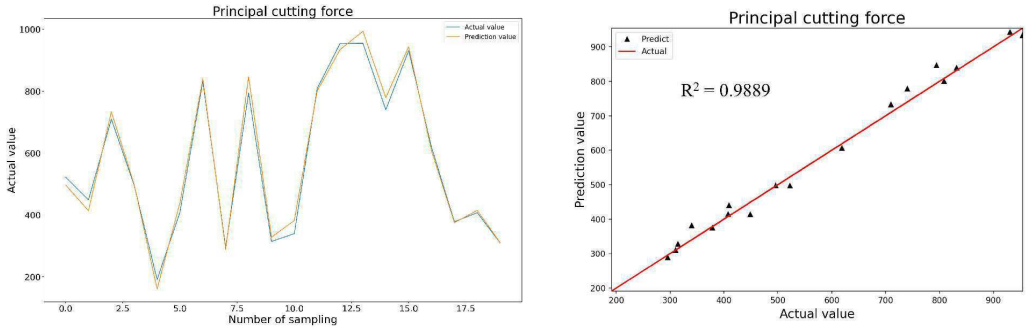

(a) Force-X

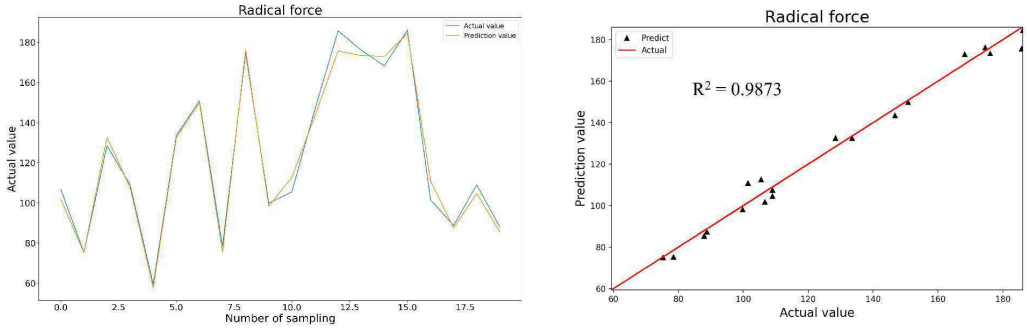

(b) Force-Y

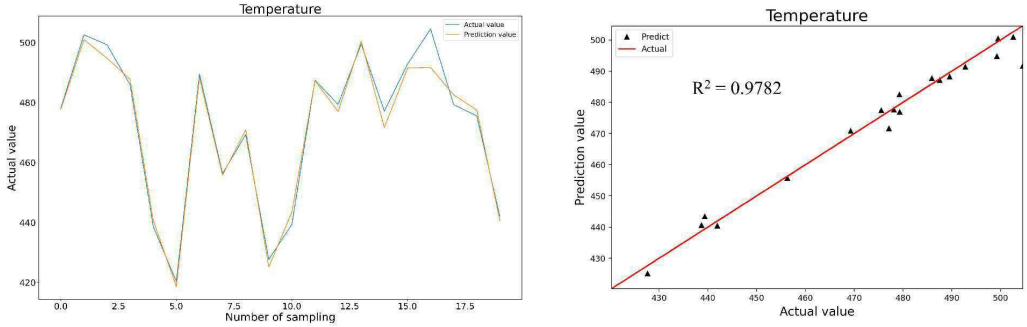

(c) Temperature