(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0098798
(43) 공개일자 2024년06월28일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) *B66C 13/06* (2006.01)
B66C 23/88 (2006.01)
(52) CPC특허분류
G06N 3/08 (2023.01)
B66C 13/066 (2013.01)
(21) 출원번호 10-2022-0180877
(22) 출원일자 2022년12월21일
심사청구일자 2022년12월21일

(71) 출원인
조선대학교산학협력단
광주광역시 동구 조선대길 126(서석동, 산학협력단)
(72) 발명자
성윤경
광주광역시 동구 필문대로 309 조선대학교
박영균
광주광역시 남구 서문대로701번길 21, 진월2차한신아파트 203동 508호
(74) 대리인
특허법인지원

전체 청구항 수 : 총 13 항

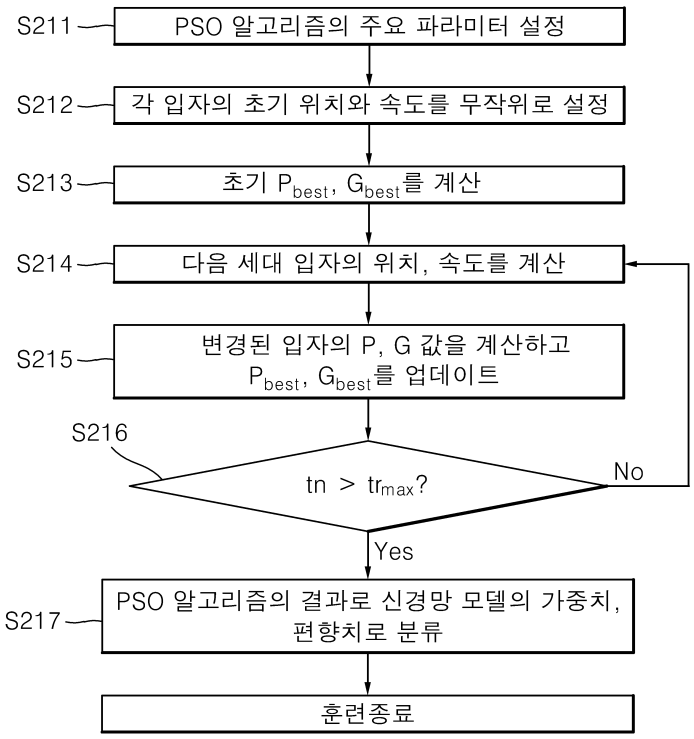
(54) 발명의 명칭 **타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템**

(57) 요 약

본 발명은 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템에 관한 것으로서, 상기 방법은 지주와, 상기 지주의 상단에 설치되는 지브와, 상기 지브의 길이방향을 따라 이동하는 트롤리와, 견인 케이블레 의해 상기 트롤리에 매달린 페이로드로 이루어진 싱글 펜듈럼 시스템

(뒷면에 계속)

대 표 도 - 도7



(Single Pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델 구축하는 방법에 있어서, 상기 신경망 모델을 구축하기 위한 훈련 데이터 세트를 획득하는 데이터 획득 단계와, 상기 데이터 획득 단계에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 모델 구축단계를 포함한다.

본 발명에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템은 PSO 알고리즘을 이용하여 타워 크레인의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하기 위한 신경망 모델을 훈련시키므로 타워 크레인 시스템에서의 보다 정확도 높은 작동을 제공할 수 있는 신경망 모델을 획득할 수 있는 장점이 있다.

(52) CPC특허분류

B66C 23/88 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345349992
과제번호	2021R1I1A3051420
부처명	교육과학기술부
과제관리(전문)기관명	한국연구재단
연구사업명	지역대학우수과학자지원사업
연구과제명	비선형 유연계를 위한 적응형 신경망 제어기술의 개발
기 여 율	1/1
과제수행기관명	조선대학교 산학협력단
연구기간	2022.06.01 ~ 2024.05.31

명 세 서

청구범위

청구항 1

지주와, 상기 지주의 상단에 설치되는 지브와, 상기 지브의 길이방향을 따라 이동하는 트롤리와, 견인 케이블에 의해 상기 트롤리에 매달린 페이로드로 이루어진 싱글 펜듈럼 시스템(Single Pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델 구축하는 방법에 있어서,

상기 신경망 모델을 구축하기 위한 훈련 데이터 세트를 획득하는 데이터 획득 단계; 및

상기 데이터 획득 단계에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 모델 구축단계;를 포함하는,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 2

제1항에 있어서,

상기 모델 구축 단계에서는, 상기 훈련 데이터 세트를 이용한 기계 학습 과정을 통해, 비용 함수(cost function)가 최소가 되도록 상기 신경망 모델의 가중치(weight)와 편향치(bias)를 계산하여 해당 신경망 모델을 구축하는,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 3

제2항에 있어서,

상기 모델 구축 단계에서는, 최적화 알고리즘을 이용항 상기 신경망 모델의 가중치와 편향치를 계산하는,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 4

제3항에 있어서,

상기 최적화 알고리즘은 PSO(Patricle Swarm Optimization) 알고리즘 인,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 5

제4항에 있어서,

상기 비용 함수는 상기 학습 데이터 세트의 입력 성형 정보와 기계 학습 과정에서 구축된 신경망 모델의 결과 값에 대한 제곱 오차의 합(SSE:Sum Square Error)인,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 6

제5항에 있어서,

상기 PSO 알고리즘은

기입력된 초기 파라미터를 토대로 신경망 모델의 가중치 및 편향치를 요소로 갖는 입자들을 기설정된 영역 내로 랜덤하고 생성하는 초기 생성 단계;

각 상기 입자의 초기 위치 및 속도를 랜덤하게 설정하는 초기 설정 단계;

상기 초기 설정 단계 이후에, 해당 초기 입자의 위치 및 비용함수를 계산하고, 계산된 초기 입자의 위치 및 비용함수 값을 최적 위치 및 최적 비용함수 값으로 설정하는 계산 단계;

기설정된 위치 결정 알고리즘에 따라 각 상기 입자의 새로운 위치 및 속도를 결정하는 재생성 단계;

상기 새로운 입자의 비용함수 값을 계산하고, 계산된 비용함수 값이 상기 최적 비용함수 값 미만이며, 상기 새로운 입자의 비용함 값 및 위치를 상기 최적 비용함수 값 및 최적 위치로 재설정하는 재설정 단계;

상기 재생성 단계 및 재설정 단계를 기설정된 훈련 횟수 만큼 반복하는 반복단계; 및

상기 반복 단계 이후에, 상기 최적 비용함수 값의 상기 입자의 요소를 상기 신경망 모델의 가중치 및 편향치로 설정하는 최종 설정 단계;를 포함하는,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 7

제1항에 있어서,

상기 입력 성형 정보는 상기 싱글 펜듈럼 시스템의 작동 중의 잔류 진동 감소를 위한 임펄스의 시간인,

타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법.

청구항 8

지주와, 상기 지주의 상단에 설치되는 지브와, 상기 지브의 길이방향을 따라 이동하는 트롤리와, 견인 케이블레의해 상기 트롤리에 매달린 페이로드로 이루어진 싱글 펜듈럼 시스템(Single Pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델 구축하는 신경망 모델 구축 시스템에 있어서,

상기 신경망 모델을 구축하기 위한 훈련 데이터 세트가 입력되는 입력모듈; 및

상기 입력모듈에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 모델 구축모듈;을 구비하는,

입력 성형기용 신경망 모델 구축 시스템.

청구항 9

상기 모델 구축 모듈은 상기 학습 데이터 세트를 이용한 기계 학습 과정을 통해, 비용 함수(cost funtion)가 최소가 되도록 상기 신경망 모델의 가중치(weight)와 편향치(bias)를 계산하여 해당 신경망 모델을 구축하는,

입력 성형기용 신경망 모델 구축 시스템.

청구항 10

제9항에 있어서,

상기 모델 구축 모듈은 최적화 알고리즘을 이용하여 상기 신경망 모델의 가중치와 편향치를 계산하는,

입력 성형기용 신경망 모델 구축 시스템.

청구항 11

제10항에 있어서,

상기 최적화 알고리즘은 PSO(Particle Swarm Optimization)알고리즘 인,

입력 성형기용 신경망 모델 구축 시스템.

청구항 12

제11항에 있어서,

상기 비용 함수는 상기 학습 데이터 세트의 입력 성형 정보와, 기계 학습 과정에서 구축된 신경망 모델의 결과값에 대한 제곱 오차의 합(SSE:Sum Square Error)인,

입력 성형기용 신경망 모델 구축 시스템.

청구항 13

제12항에 있어서,

상기 입력 성형 정보는 상기 펜듈럼 시스템의 작동 중의 잔류 진동 감소를 위한 임펄스의 시간인,

입력 성형기용 신경망 모델 구축 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템에 관한 것으로서, 더욱 상세하게는 PSO 알고리즘을 이용하여 타워 크레인 즉, 싱글 펜듈럼 시스템의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델을 훈련시키는 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템에 관한 것이다.

배 경 기 술

[0002] 산업 현장에서 타워 크레인은 비선형 동적 특성에 의해 입력 명령이 왜곡되며, 작업자에 의해 수동으로 조종되기 때문에 Hoisting Length등의 파라미터가 고정되지 않고 실시간으로 변화할 수 있다. 타워 크레인 시스템을 제어하는 입력성형기술은 feedforward 기술로서 시스템 제어에 효과적이지만 산업 현장의 모든 상황을 고려할 수 없는 점에서 한계가 존재한다. 이러한 문제에서 발생하는 동적 모델링 오류는 입력성형기 적용 시 잔류변위가 발생되어 이를 보상할 수 있는 입력성형기의 개선이 요구된다. 결론적으로 시스템의 실시간 파라미터에 적응하며 크레인의 동적 특성을 고려한 입력성형기의 개발이 필요하다.

[0003] 입력성형기는 입력을 크기와 시간에 따라 적절히 성형함으로서 시스템의 잔류 변위를 감소시켜 잔류변위를 제어한다. 입력성형기 중 가장 간단한 성형 방법인 ZV(Zero Vibration) Shaper는 감쇠비와 주파수만으로 이상적인 시스템에 대해 가장 간단하면서 효율적인 제어를 실현하였다. 하지만 산업 현장의 크레인은 주로 On-Off의 명령 형태로 정리되는 relay-deriven drive를 활용하며, 이러한 시스템은 속도가 존재하거나 존재하지 않는 2가지의 제한된 상태로만 작동할 수 있어 입력 크기에 제한이 존재한다. 이 조건에서 UMZV Shaper(Unit Magnitude Zero Vibration)는 입력 크기를 on과 off로 제한함으로서 개발되었으며 성능이 검증되었다. 이러한 On-Off시스템의 제어기법은 연료 최적 제어등으로 추가적인 조건을 고려하여 광범위하게 개발되었지만, shaper duration이 길어지는 문제나 최적화 계산시간의 상승 등의 문제가 발생되었다. 이처럼 입력성형기는 설계 과정에서 시스템의 조

건을 고려하는 등의 방법으로 다양하게 개발할 수 있지만 이에 따른 단점도 고려해야 한다.

[0004] 입력성형기는 정확한 잔류변위 제어를 위해 타겟 시스템에 대한 정확한 파라미터 값 등의 지식이 요구되며 약간의 오차로도 성능 저하가 발생된다. 이러한 적응 매커니즘의 한계 때문에 parameter가 변화하는 시스템의 잔류변위를 제어할 수 없어 넓은 범위의 파라미터를 고려한 연구가 진행되었다. Singhose는 넓은 범위 파라미터의 평균값을 활용한 AOF Shaper를 개발하였으며, 입력성형기의 feedforward 구조를 유지하며 높은 제어 성능을 보였다. 하지만 입력성형기의 구조적인 특성상 실시간으로 변화하는 파라미터를 모두 고려할 수 없어 개선이 요구된다.

[0005] 입력성형기의 구조적인 문제 해결과 실시간으로 파라미터를 업데이트하기 위하여 Feedback구조와의 조합을 고려할 수 있다. Closed-loop제어 전략으로서 선형 제어, 슬라이딩 모드 제어, 모델 예측 제어, 적응 제어, Fuzzy-losic 제어기법 등 다양한 잔류변위 제어 기술이 제시되었다. 그 중 Liyana Ramli는, 인공 신경망을 활용한 입력 성형기를 제시함으로서 파라미터가 변화하는 문제에 대해서 높은 잔류변위 감소율을 보임을 증명하였다. 하지만 인공 신경망은 수학적으로 완벽한 솔루션을 반환할 수 없기 때문에 비선형 시스템을 고려할 경우, 제어 성능을 확인하여야 한다. 결론적으로 실시간으로 변화하는 파라미터에 대응하도록 인공 신경망과 입력성형기를 동시에 활용하는 방법을 고려할 수 있다.

[0006] 타워크레인에 적용할 수 있는 입력 성형기술은 Gantry Crane등 동일한 single-pendulum에서 개발된 입력성형기를 활용함으로서 적용되었다. 그 중 크레인 액츄에이터의 비선형 동적 특성을 고려한 성형기는 동적 응답을 해석함으로서 개발되었다. 구동기의 비선형 동적 특성은 1st-order, 2nd-order의 동적 특성 혹은 ramp형 속도 프로파일을 가진 구동기[13]로 다양하게 고려되었으며, 이에 따른 입력성형기가 개발되어 제어 성능이 입증되었다. 이러한 비선형 입력성형기는 동적 특성을 중심으로 개발되었어 동일한 single-pendulum의 타워 크레인에 활용할 수 있다. 하지만 기존의 비선형 입력성형기는 파라미터가 변화할 경우 잔류변위 제어 성능이 낮아지는 문제가 존재하여 이에 대한 개선이 필요하다.

선행기술문헌

특허문헌

[0007] (특허문헌 0001) 공개특허공보 제10-2020-0007528호: 안드로이드 기반의 원격 입력성형장치

발명의 내용

해결하려는 과제

[0008] 본 발명은 상기와 같은 문제점을 개선하기 위해 창안된 것으로서, PSO 알고리즘을 이용하여 타워 크레인의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하기 위한 신경망 모델을 훈련시키는 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템을 제공하는데 그 목적이 있다.

과제의 해결 수단

[0009] 상기 목적을 달성하기 위한 본 발명에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법은 지주와, 상기 지주의 상단에 설치되는 지브와, 상기 지브의 길이방향을 따라 이동하는 트롤리와, 견인 케이블레 의해 상기 트롤리에 매달린 페이로드로 이루어진 싱글 펜듈럼 시스템(Single Pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델 구축하는 방법에 있어서, 상기 신경망 모델을 구축하기 위한 훈련 데이터 세트를 획득하는 데이터 획득 단계와, 상기 데이터 획득 단계에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 모델 구축단계를 포함한다.

[0010] 상기 모델 구축 단계에서는, 상기 훈련 데이터 세트를 이용한 기계 학습 과정을 통해, 비용 함수(cost function)가 최소가 되도록 상기 신경망 모델의 가중치(weight)와 편향치(bias)를 계산하여 해당 신경망 모델을 구축한다.

[0011] 상기 모델 구축 단계에서는, 최적화 알고리즘을 이용항 상기 신경망 모델의 가중치와 편향치를 계산할 수 있다.

[0012] 상기 최적화 알고리즘은 PSO(Patricle Swarm Optimization) 알고리즘이 적용된다.

[0013] 상기 비용 함수는 상기 학습 데이터 세트의 입력 성형 정보와 기계 학습 과정에서 구축된 신경망 모델의 결과값에 대한 제곱 오차의 합(SSE:Sum Square Error)인 것이 바람직하다.

[0014] 상기 PSO 알고리즘은 기입력된 초기 파라미터를 토대로 신경망 모델의 가중치 및 편향치를 요소로 갖는 입자들을 기설정된 영역 내로 랜덤하고 생성하는 초기 생성 단계와, 각 상기 입자의 초기 위치 및 속도를 랜덤하게 설정하는 초기 설정 단계와, 상기 초기 설정 단계 이후에, 해당 초기 입자의 위치 및 비용함수를 계산하고, 계산된 초기 입자의 위치 및 비용함수 값을 최적 위치 및 최적 비용함수 값으로 설정하는 계산 단계와, 기설정된 위치 결정 알고리즘에 따라 각 상기 입자의 새로운 위치 및 속도를 결정하는 재생성 단계와, 상기 새로운 입자의 비용함수 값을 계산하고, 계산된 비용함수 값이 상기 최적 비용함수 값 미만이며, 상기 새로운 입자의 비용함 값 및 위치를 상기 최적 비용함수 값 및 최적 위치로 재설정하는 재설정 단계와, 상기 재생성 단계 및 재설정 단계를 기설정된 훈련 횟수 만큼 반복하는 반복단계와, 상기 반복 단계 이후에, 상기 최적 비용함수 값의 상기 입자의 요소를 상기 신경망 모델의 가중치 및 편향치로 설정하는 최종 설정 단계를 포함한다.

[0015] 상기 입력 성형 정보는 상기 싱글 펜듈럼 시스템의 작동 중의 잔류 진동 감소를 위한 임펄스의 시간이 적용된다.

[0016] 본 발명에 따른 입력 성형기용 신경망 모델 구축 시스템은 지주와, 상기 지주의 상단에 설치되는 지브와, 상기 지브의 길이방향을 따라 이동하는 트롤리와, 견인 케이블레 의해 상기 트롤리에 매달린 페이로드로 이루어진 싱글 펜듈럼 시스템(Single Pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델 구축하는 신경망 모델 구축 시스템에 있어서, 상기 신경망 모델을 구축하기 위한 훈련 데이터 세트가 입력되는 입력모듈과, 상기 입력모듈에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 모델 구축모듈을 구비한다.

[0017] 상기 모델 구축 모듈은 상기 학습 데이터 세트를 이용한 기계 학습 과정을 통해, 비용 함수(cost funtion)가 최소가 되도록 상기 신경망 모델의 가중치(weight)와 편향치(bias)를 계산하여 해당 신경망 모델을 구축한다.

[0018] 상기 모델 구축 모듈은 최적화 알고리즘을 이용하여 상기 신경망 모델의 가중치와 편향치를 계산한다.

발명의 효과

[0019] 본 발명에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템은 PSO 알고리즘을 이용하여 타워 크레인의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하기 위한 신경망 모델을 훈련시키므로 타워 크레인 시스템에서의 보다 정확도 높은 작동을 제공할 수 있는 신경망 모델을 획득할 수 있는 장점이 있다.

도면의 간단한 설명

[0020] 도 1은 본 발명에 따른 입력 성형기용 신경망 모델 구축 시스템에 대한 블럭도이고,

도 2는 싱글 펜듈럼 시스템(Single Pendulum system)에 대한 개념도이고,

도 3은 UMZVF Shaper의 작동에 대한 개념도이고,

도 4는 본 발명에 의해 구축된 신경망 모델에 대한 개념도이고,

도 5는 신경망 모델을 활용한 입력 성형기가 적용된 실제 싱글 펜듈럼 시스템에 대한 개념도이고,

도 6은 본 발명에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법에 대한 순서도이고,

도 7은 도 6의 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법의 PSO 알고리즘에 대한 순서도이고,

도 8은 도 6의 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법의 모델 구축 단계에서 구축된 신경망 모델의 수렴 성능에 대한 그래프이고,

도 9는 NN-UMZVF Shaper와 NN-UMZV Shaper, UMZVF Shaper의 잔류변위 그래프이고,

도 10은 NN-UMZVF Shaper와 UMZVF Shaper, AOF-UMZV Shaper의 Hoisting length의 변화량에 따른 잔류변위 그래프이고,

도 11 및 도 12는 NN-UMZVF Shaper와 UMZVF Shaper, AOF-UMZV Shaper에 대하여 Neural Network의 입력인 최초 hoisting length 와 τ_a 혹은 τ_a와 τ_b에 따른 잔류변위 그래프이고,

도 13은 성능 시험을 위해 제작된 소형 타워 크레인에 대한 사진이고,

도 14는 상기 소형 타워 크레인을 구성하는 하드웨어 및 구성요소를 기재한 개념도이고,

도 15는 NN-UMZVF Shaper의 속도 명령 그래프와 실제 속도 명령의 오차 및 시간에 따른 Hoist Length의 변화에 대한 그래프이고,

도 16은 UMZVF Shaper와 AOF-UMZV Shaper, NN-UMZVF Shaper의 입력 명령이 종료된 후 잔류변위가 존재할 때 트롤리를 절대 좌표로 설정한 페이로드의 움직임에 대한 그래프이고,

도 17은 최초 hoisting length에 따른 세 shaper(UMZVF Shaper, AOF-UMZV Shaper, NN-UMZVF Shaper)의 잔류변위 그래프이고,

도 18은 UMZVF Shaper, AOF-UMZV Shaper, NN-UMZVF Shaper의 상승 시상수에 따른 잔류변위 그래프이다.

발명을 실시하기 위한 구체적인 내용

[0021] 이하, 첨부한 도면을 참조하여 본 발명의 실시예에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템에 대해 상세히 설명한다. 본 발명은 다양한 변경을 가할 수 있고 여러 가지 형태를 가질 수 있는 바, 특정 실시 예들을 도면에 예시하고 본문에 상세하게 설명하고자 한다. 그러나 이는 본 발명을 특정한 개시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다. 각 도면을 설명하면서 유사한 참조부호를 유사한 구성요소에 대해 사용하였다. 첨부된 도면에 있어서, 구조물들의 치수는 본 발명의 명확성을 기하기 위하여 실제보다 확대하여 도시한 것이다.

[0022] 제1, 제2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되어서는 안 된다. 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 본 발명의 권리 범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다.

[0023] 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 명세서 상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0024] 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 문맥 상 가지는 의미와 일치하는 의미를 가지는 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0025] 도 1에는 본 발명에 따른 입력 성형기용 신경망 모델 구축 시스템(100)이 도시되어 있다.

[0026] 도면을 참조하면, 상기 입력 성형기용 신경망 모델 구축 시스템(100)은 싱글 펜듈럼 시스템(10)(Single Pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 신경망 모델 구축하기 위한 훈련 데이터 세트가 입력되는 입력모듈(200)과, 상기 입력모듈(200)에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템(10)의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 모델 구축모듈(300)을 구비한다.

[0027] 여기서, 상기 싱글 펜듈럼 시스템(10)은 타워 크레인(Tower Crane)에 적용되는 것으로서, 도 2를 참조하면, 지주(11)와, 상기 지주(11)의 상단에 설치되는 지브(12)와, 상기 지브(12)의 길이방향을 따라 이동하는 트롤리(13)와, 견인 케이블(15)레 의해 상기 트롤리(13)에 매달린 페이로드(14)로 이루어진다. 여기서, 지주(11)는 산업현장에 설치되며, 상하방향으로 연장되며, 지브(12)는 좌우방향으로 연장되며, 단부가 지주(11)의 상단에 회동되게 설치된다. 트롤리(13)는 지브(12)에, 좌우방향으로 연장되게 마련된 가이드레일을 따라 이동하도록 설치

된다. 도면에 도시되진 않았지만, 트롤리(13)에는 해당 견인 케이블(15)을 감거나 풀 수 있는 권취수단이 마련되어 있으며, 해당 권취수단을 이용하여 해당 페이로드(14)를 승강시킨다. 도 2에서, x(t)는 지주(11)로부터 트롤리(13)의 이격된 거리이고, L(t)는 트롤리(13)에서 페이로드(14)까지의 거리이고, s(t)는 지주(11)에 대한 지브(12)의 회동 각도이다.

[0028] 상기 타워 크레인 즉, 싱글 펜듈럼 시스템(10)을 모델링하기 위해 페이로드(14)의 각 축방향 좌표를 정의한 다음 라그랑지 방정식(Lagrange equation)을 이용하여 운동방정식을 정리해야 하는데, 페이로드(14)의 각 축방향에 따른 위치를 정의하면 하기의 수학식 1 내지 3과 같다.

수학식 1

[0029] $$P_x = Lcos(\theta)\sin(\phi)$$

수학식 2

[0030] $$P_y = Lsin(\theta)$$

수학식 3

[0031] $$P_z = Lcos(\theta)\cos(\phi)$$

[0032] 상기 수학식에서, Θ는 트롤리(13)의 이동 후 또는 지주(11)의 회동 후 페이로드(14)의 최대 회동각도이고, Φ는 상기 페이로드(14)의 해당 최대 회동각도를 갖는 회동지점에서 원위치에 복귀시 페이로드(14)의 회동각도이고, L은 트롤리(13)에서 페이로드(14)까지의 거리이다.

[0033] 상기 수학식 1 내지 3에서 정의된 각 축방향 페이로드(14)의 좌표를 활용하여 페이로드(14)의 속도를 하기의 수학식 4를 이용하여 계산할 수 있다.

수학식 4

[0034] $$\dot{P} = \frac{\delta P}{\delta t} + wP$$

[0035] 상기 수학식에서 $w = \dot{s}\,\hat{z}$이고, $\dot{s}$는 지브(12)의 회동 방향 각속도이다. 상기 수학식 4에 대해 수학식 1 내지 3을 이용하여 지브(12)로부터 트롤리(13)까지의 거리(x)와 각 축방향에 따른 페이로드(14)의 속도를 각각의 단위 벡터(unit vector)로 정리하면 하기의 수학식 5와 같다.

수학식 5

[0036]
$$\dot{P} = [\dot{x} - \dot{L}\sin(\phi)\cos(\theta) - L(\dot{x}\sin(\theta) - \dot{\theta}\sin(\theta)\sin(\phi) + \dot{\phi}\cos(\theta)\cos(\phi))]\hat{x} + [\dot{L}\sin(\theta) + x\dot{s} + Lcos(\theta)(\dot{\theta} - \dot{s}\sin(\phi))]\hat{y} + [-\dot{L}\cos(\theta)\cos(\phi) + L(\dot{\theta}\sin\theta\cos\phi + \dot{\phi}\sin\phi\cos\theta]\hat{z}$$

[0037] 라그랑지 방정식을 활용하기 위하여 시스템의 운동 에너지(Kinetic energy)와 위치 에너지(Potential energy)의 계산식을 정의해야 하는데, 상기 수학식 5를 활용한 운동 에너지(Kinetic energy)의 계산식은 하기의 수학식 6과 같다.

수학식 6

[0038] $$K_E=\frac{1}{2}m[\dot{P}.\dot{P}]$$

[0039] 또한, 라그랑지 방정식 계산을 위한 위치 에너지의 계산식은 하기의 수학식 7과 같다.

수학식 7

[0040] $$P_E=-mgLcos(\theta)\cos(\phi)$$

[0041] 라그랑지 방정식은 $\mathcal{L}=K_E-P_E$이고, 수학식 6 및 7을 활용하여 계산할 수 있는데, 라그랑지 방정식을 통한 운동방정식 계산식은 하기의 수학식 8과 같다. 해당 운동방정식에 대하여 θ와 ϕ의 두 가지의 요소에 대해 정리해야 하므로 q_v에 대해 두 요소 각각에 대해서 대입하여($v=\theta$ or ϕ) 계산한다.

수학식 8

[0042] $$\frac{d}{dt}\left(\frac{\delta\mathcal{L}}{\delta\dot{q}_v}\right)-\frac{\delta\mathcal{L}}{\delta q_v}=0$$

[0043] 종래에는 입력 성형기가 모델링 오차에 민감하다는 특징이 존재하여 정확한 값을 활용하기 위해 시스템의 파라미터는 고정되어 있었다. 반면, 시스템의 불확실성에 대응하는 실험 조건 작성을 위하여 견인 케이블(15)의 길이가 변해야 하기 때문에 $\dot{L}$에 대해서 0을 대입하지 않고, 상기 라그랑지 방정식을 통해 타워 크레인의 비선형 방정식을 정리하면 하기의 수학식 9 및 10과 같다.

수학식 9

[0044] $$\ddot{\theta}+\frac{2}{L}\dot{L}\dot{\theta}+\frac{1}{L}\sin(\theta)\sin(\phi)\ddot{x}+\frac{g}{L}\sin(\theta)\cos(\phi)+\frac{1}{L}\cos(\theta)\ddot{s}x$$
$$+\frac{2}{L}\cos(\theta)\dot{s}\dot{x}-\cos(\theta)\cos(\phi)^2\sin(\theta)\dot{s}^2-\frac{2}{L}\dot{L}\sin(\phi)\dot{s}-\sin(\phi)\ddot{s}$$
$$-\frac{1}{L}\sin(\theta)\sin(\phi)\dot{s}^2+\cos(\theta)\sin(\theta)\dot{\phi}^2-2\cos(\theta)^2\cos(\phi)\dot{\phi}\dot{s}^2=0$$

수학식 10

[0045] $$\cos(\theta)\ddot{\phi}+\frac{2}{L}\dot{L}\cos(\theta)\dot{\phi}-\frac{1}{L}\cos(\phi)\ddot{x}+\frac{g}{L}\sin(\phi)+\frac{1}{L}\cos(\phi)\dot{s}^2x$$
$$+\frac{2}{L}\dot{L}\cos(\phi)\sin(\theta)\dot{s}-2\sin(\theta)\dot{\phi}\dot{\theta}+\cos(\phi)\sin(\theta)\ddot{s}$$
$$+2\cos(\theta)\cos(\phi)\dot{s}\dot{\theta}-\cos(\theta)\cos(\phi)\sin(\phi)\dot{s}^2=0$$

[0046] 상기 수학식 9,10을 통하여 페이로드(14)의 두 각도의 움직임을 제어하기 위하여 이동(slew) 방향 가속도, 트롤리(13) 방향 가속도, Hoisting 방향의 속도값이 입력으로서 필요한 것을 확인할 수 있으며, 타워크레인 페이로

드(14)의 두 각도(Θ, ϕ)가 서로 연결(Coupled)되어 있음을 확인할 수 있다.

[0047] 입력성형기는 일련의 임펄스 시퀀스에 의해 발생되는 잔류 진동을 해석하고 이전의 임펄스에 의해 발생된 잔류 진동을 이후의 임펄스로 취소시킬 목적으로 개발되었다. 해당 입력성형기 개발을 위해 각 임펄스를 통한 잔류진동은 하기의 수학식 11과 같다.

수학식 11

[0048] $$V(\omega,\zeta)=e^{-\zeta\omega t_n}\sqrt{C(\omega,\zeta)^2+S(\omega,\zeta)^2}$$

[0049] 상기 수학식에서, $C(\omega,\zeta)$와 $S(\omega,\zeta)$은 하기의 수학식 12,13과 같다.

수학식 12

[0050] $$C(\omega,\zeta)=\sum_{i=1}^{n}A_i e^{-\zeta\omega t_i}\cos(\omega_n t_i\sqrt{1-\zeta^2})$$

수학식 13

[0051] $$S(\omega,\zeta)=\sum_{i=1}^{n}A_i e^{-\zeta\omega t_i}\sin(\omega_n t_i\sqrt{1-\zeta^2})$$

[0052] 상기 수학식에서 Ai는 각 임펄스의 크기이고, ti는 임펄스의 스위치 타임(switch time)이고, n은 임펄스의 개수이다. 잔류진동이 0이 되어야 하므로 수학식 11의 값은 0이 되어야 하며, 시스템의 한계를 고려하여 각 임펄스의 합에 대하여 하기의 수학식 14와 같은 제약조건이 고려되어야 한다.

수학식 14

[0053] $$\sum_{i=1}^{n}A_i=1$$

[0054] Finite 시스템 제어를 위하여 네거티브(negative)한 임펄스 진폭을 고려한 제어 기술이 개발되었다. 시스템의 속도 입력을 고려하여 입력 성형기의 임펄스 크기는 1과 -1이 반복되도록 제한되었으며, 수학식 12,13과 진폭 조건을 활용한 UMZV shaper가 개발되었다. UMZV Shaper의 입력 시퀀스는 하기의 수학식 15와 같다.

수학식 15

[0055] $$\begin{bmatrix}A_i\\t_i\end{bmatrix}=\begin{bmatrix}1 & -1 & 1\\0 & t_2 & t_3\end{bmatrix}$$

[0056] 여기서, t_2, t_3은 하기의 수학식 16과 같다.

수학식 16

[0057] $$t_2=T/6,\quad t_3=T/3$$

[0058] 상기 수학식에서 T는 싱글 펜듈럼 시스템(10)의 주기를 의미한다.

[0059] 변수 파라미터(variable parameter)의 스윙을 억제하기 위하여 Singhose는 주파수 범위에서 평균 주파수를 기반으로 한 입력성형기를 제시하였다. AOF 입력성형기는 Basic 입력성형기의 주파수를 주파수 범위의 평균값을 활용함으로서 다양한 파라미터에서 개선된 성능을 보였다. AOF기반의 UMZV Shaper는 수학식(15)와 동일한 형태로 나타나지만 수학식(16)의 T는 파라미터 범위의 평균값을 활용함으로서 적용된다.

[0060] 입력성형기를 활용한 비선형 시스템의 제어는 시스템의 비선형성을 고려하여 모델링되는데, 그 중 가장 대표적인 1차 구동기를 장착한 시스템의 속도 식은 $v_f(t)=Av_d(1-e^{-t/\tau})$로 정의되며 A, τ, v_d는 각각 타워크레인의 작동을 위한 입력 명령의 크기, 시간 상수, 원하는 최대 속도이다. UMZVF Shaper는 기존의 UMZV Shaper와 같이 임펄스의 크기가 1과 -1로 제한되었으며, Vector Diagram Approach을 통해 계산된 입력 시퀀스는 하기의 수학식 17과 같다.

수학식 17

[0061] $$A_i=(-1)^{i+1}$$

[0062] $$t_2=\frac{1}{w_n}\left(\tan^{-1}\left(\frac{1}{w_{\tau_b}}\right)-\tan^{-1}\left(\frac{1}{w_{\tau_a}}\right)+\cos^{-1}\left(\frac{\beta_a}{2}\right)\right)$$

[0063] $$t_3=\frac{1}{w_n}\left(\cos^{-1}\left(\frac{\beta_a^2}{2}-1\right)\right)$$

[0064] $$t_4=t_p$$

[0065] $$t_5=t_p+\frac{1}{w_n}\left(\tan^{-1}\left(\frac{1}{w_{\tau_a}}\right)-\tan^{-1}\left(\frac{1}{w_{\tau_b}}\right)+\cos^{-1}\left(\frac{\beta_b}{2}\right)\right)$$

[0066] $$t_6=t_p+\frac{1}{w_n}\left(\cos^{-1}\left(\frac{\beta_b^2}{2}-1\right)\right)$$

[0067] 상기 수학식에서 t_p, τ_a, τ_b, w_n 은 각각 입력 명령이 종료되는 시간, 시스템의 상승 시상수, 하강 시상수, 자연주파수를 의미한다. 각 시상수에 따른 상승시 주파수 식 및 계산식 w_{τ_a} w_{τ_b} β_a β_b는 하기의 수학식 18,19와 같다.

수학식 18

[0068] $$w_{\tau_a}=w_n\tau_a,\quad w_{\tau_b}=w_n\tau_b$$

수학식 19

[0069] $$\beta_a=\sqrt{\frac{w_{\tau_a}^2+1}{w_{\tau_b}^2+1}},\ \beta_b=\sqrt{\frac{w_{\tau_b}^2+1}{w_{\tau_a}^2+1}}$$

[0070] 상술된 Solution을 활용한 UMZVF Shaper는 싱글 펜듈럼 시스템(10)에 적용되었을 때 도 3과 같다. 이상적인 펄스 형태의 입력 명령이 입력되었음에도 불구하고 1st-order 비선형 엑츄에이터 적용 시 입력의 모양이 왜곡형태

로 상승 및 하강하는 것을 확인할 수 있다.

[0071] 본 발명에 따른 입력 성형기용 신경망 모델 구축 시스템(100)의 입력모듈(200)은 상기 신경망 모델을 구축하기 위한 훈련 데이터 세트가 입력된다. 해당 입력모듈(200)은 상기 UMZVF Shaper로부터 해당 훈련 데이터 세트를 제공받는다.

[0072] 모델 구축모듈(300)은 상기 입력모듈(200)에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템(10)의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축한다.

[0073] 여기서, 상기 신경망 모델은 싱글 펜듈럼 시스템(10)(single pendulum system)의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하는 인공 신경망 모델이다. 도 4를 참조하면, 해당 신경망 모델은 입력 3개, 히든 뉴런(Hidden Neuron) 8개, 출력 3개로 구성된 3-8-3 구조의 Feed Forward 신경망으로 설계된다. 각 뉴런(neuron)의 입력은 레이어(layer)의 가중치(weight)와 편향치(bias)를 활용하여 전달함수를 통해 레이어의 출력이 계산된다.

[0074] 신경망 모델의 입력은 입력 성형기의 주요 파라미터인 트롤리(13)에서 페이로드(14)까지의 길이(Hoist Length), 가속 시상수(τ_a) 및 감속 시상수(τ_b)이고, 출력은 입력 명령의 최초 입력 시간인 t1과, 입력 명령 종료시간인 tp를 제외한 입력 성형 정보로서, 임펄스의 타임 즉, 각 임펄스의 스위치 타임(switch time)이 적용된다. 각 레이어는 각각의 가중치인 $w_{i,j}$, $w_{j,k}$와 편향치인 b_j,b_k를 통해 히든 레이어(hidden layer)와 아웃풋 레이어(output layer)로 연결된다. 신경망의 activation function은 1st 레이어에 연속형 데이터이면서 gradient exploding이 발생하지 않는 Sigmoid function을 사용하며, 2nd 레이어의 경우 output 값이 1을 초과하는 값이 발생함으로 Purelin function으로 구성한다. 신경망 모델에 의해 계산되는 각 Layer의 출력은 아래의 수학식 20, 21에 의해 계산된다.

수학식 20

[0075] $$y_j = sigmoid\left[\sum_{i=1}^{n} x_i w_{i,j} + b_j\right]$$

수학식 21

[0076] $$y_k = purelin\left[\sum_{j=1}^{n} x_j w_{j,k} + b_k\right]$$

[0077] 상기 수학식에서 n은 hidden layer의 총 뉴런 수이며, x_i와 x_j는 각 layer의 입력을, y_i와 y_j는 해당 layer의 출력이다.

[0078] 한편, 도 5에는 상기 신경망 모델을 활용한 입력 성형기가 적용된 실제 싱글 펜듈럼 시스템(10)에 대한 개념도가 도시되어 있다. 신경망 모델은 타워 크레인(Tower Crane)의 트롤리(13)에서 페이로드(14)까지의 길이(Hoist Length), 가속 시상수(τ_a) 및 감속 시상수(τ_b)를 실시간으로 입력 값으로서 활용하며, 각 switch time을 반환하여 입력 성형기를 업데이트한다.

[0079] 한편, 본 발명의 입력모듈(200) 및 모델 구축모듈(300)의 작동은 본 발명의 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법과 함께 보다 상세히 설명한다.

[0080] 도 6에는 본 발명에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법의 순서도가 게시되어 있다.

[0081] 도면을 참조하면, 상기 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법은 데이터 획득 단계(S100) 및 모델 구축 단계(S200)를 포함한다.

[0082] 데이터 획득 단계(S100)는 상기 신경망 모델을 구축하기 위한 훈련 데이터 세트를 획득하는 단계이다. 입력모듈

(200)은 입력 성형기 즉, 상기 UMZV Shaper로부터 상기 학습 데이터 세트를 제공받는다. 여기서, 작업자는 신경망 모델의 오프라인 훈련(offline training)을 위하여 기존 비선형 입력성형기의 솔루션(solution)을 활용한 학습 데이터 세트를 제작한다.

[0083] 상기 훈련 데이터 세트는 입력(input)과 데이터 아웃풋(Data output)으로 구성되며, 입력은 하기의 표1과 같이 각각의 파라미터의 범위에 따른 단위 크기로 설정하고, 데이터 아웃풋은 표 1의 각각의 파라미터를 활용하여 수학식 17을 통해 산출된 입력 성형 정보 즉, switch time이 설정된다.

표 1

[0084]

L		τ_a		τ_b	
범위	단위 크기	범위	단위 크기	범위	단위 크기
[20 30]	0.5m	[0.01 0.05]	0.005 sec	[0.01 0.05]	0.005 sec

[0085] 상기 표 1은 신경망 훈련 파라미터 범위(Neural Network training parameter range)에 관한 것이다. 일예로, L의 경우, 20m에서 0.5m 만큼 증가하되, 30m까지 그 값을 변경하며 UMZV Shaper에 입력하여 데이터 아웃풋 값을 획득한다. 입력모듈(200)은 UMZV Shaper로부터 학습 데이터 세트를 제공받고, 제공받은 학습 데이터 세트를 모델 구축모듈(300)에 전송한다. 모델 구축 단계(S200)는 데이터 획득 단계(S100)에서 획득한 훈련 데이터 세트를 토대로 상기 싱글 펜듈럼 시스템(10)의 입력 성형 정보를 산출하기 위한 상기 신경망 모델을 구축하는 단계이다. 여기서, 모델 구축모듈(300)은 상기 훈련 데이터 세트를 이용한 기계 학습 과정을 통해, 비용 함수(cost funtion)가 최소가 되도록 상기 신경망 모델의 가중치(weight)와 편향치(bias)를 계산하여 해당 신경망 모델을 구축한다. 여기서, 비용함수는 상기 학습 데이터 세트의 입력 성형 정보와 기계 학습 과정에서 구축된 신경망 모델의 결과 값에 대한 제곱 오차의 합(SSE:Sum Square Error)이 적용된다.

[0086] 이때, 모델 구축모듈(300)은 최적화 알고리즘을 이용하여 상기 신경망 모델의 가중치와 편향치를 계산하는데, 상기 최적화 알고리즘은 PSO(Particle Swarm Optimization)알고리즘이 적용되는 것이 바람직하다.

[0087] 한편, 도 7을 참조하면, 신경망의 훈련을 위한 PSO 알고리즘은 초기 생성 단계(S211), 초기 설정 단계(S212), 계산 단계(S213), 재생성 단계(S214), 재설정 단계(S215), 반복단계(S216) 및 최종 설정 단계(S217)를 포함한다.

[0088] 상기 초기 생성 단계(S211)는 기입력된 초기 파라미터를 토대로 신경망 모델의 가중치 및 편향치를 요소로 갖는 입자들을 기설정된 영역 내로 랜덤하고 생성하는 단계이다. 상기 PSO 알고리즘에서 각 입자는 신경망 모델의 요소인 가중치(weight)와 편향치(bias)를 의미한다. PSO 알고리즘의 초기 파라미터는 작업자에 의해 모델 구축모듈(300)에 기입력되는, 신경망 훈련을 위한 최적의 값으로서, 하기의 표 2와 같다.

표 2

[0089]

tr_{max}	Swarm Size	I	I_{max}	I_{min}	c_1, c_2
3000	40	0.9	0.9	0.4	1.5

[0090] 여기서, tr은 현재 입자의 세대를 나타내는 값이면서, 훈련 횟수를 의미하며, tr_{max}는 Training의 최대 시행회수이다. I는 이전 세대의 입자의 속도에 대한 관성력이며, I_{max}과 I_{min}는 I의 최대 최소 범위, c_1과 c_2는 각각 입자와 swarm의 가속상수이다. 한편, 여기서, 모델 구축모듈(300)에서 비용함수도 설정하는 것이 바람직하다. 상기 비용함수는 훈련 데이터 세트의 데이터 아웃풋 값과, 기계학습 과정에서 구축된 신경망 모델의 결과(output)값에 대한 Sum Square Error(SSE)로 설정된다. 상기 비용함수는 하기의 수학식 22로 정의된다.

수학식 22

[0091]

$$J=\frac{1}{mn}\sum_{j=1}^{m}\sum_{i=1}^{n}(y'_{i,j}-y_{i,j})^2$$

[0092] 상기 수학식에서, 상기 J는 비용함수 값이고, 상기 i는 입자가 생성된 차례이고, 상기 $y_{i,j}$는 상기 학습 데이터 세트의 임의의 입력 값에 대한 실제 타겟 값이고, 상기 $y'_{i,j}$는 상기 학습 데이터 세트의 입력 값을 기계학습 과정에서 구축된 신경망 모델에 적용하여 출력된 결과 값이다.

[0093] 상기 초기 설정 단계(S212)는 각 상기 입자의 초기 위치 및 속도를 랜덤하게 설정하는 단계이다. 모델 구축모듈(300)은 입자들의 위치 및 속도를 무작위로 설정하여 swarm을 형성한다.

[0094] 계산 단계(S213)는 상기 초기 설정 단계(S212) 이후에, 해당 초기 입자의 위치 및 비용함수를 계산하고, 계산된 초기 입자의 위치 및 비용함수 값을 최적 위치 및 최적 비용함수 값으로 설정하는 단계이다. 각 입자의 요소로 기계학습된 신경망 모델과, 학습 데이터 세트를 상기 수학식 22에 적용하여 각 입자의 비용함수(G)를 산출한다. 이때, 입자들의 비용함수 중 가장 낮은 값의 입자의 비용함수를 최적 비용함수 값(G_{best})으로 설정하고, 해당 입자의 위치를 최적 위치(P_{best})로 설정한다.

[0095] 재성성 단계는 기설정된 위치 결정 알고리즘에 따라 각 상기 입자의 새로운 위치 및 속도를 결정하는 단계이다. 상기 입자의 새로운 위치 및 속도는 하기의 수학식 23, 24에 의해 계산된다.

수학식 23

[0096] $$v_i^{tr+1}=I\cdot v_i^{tr}+c_1 r_1^{tr}[Pbest_i^{tr}-x_i^{tr}]+c_2 r_2^{tr}[Gbest_i^{tr}-x_i^{tr}]$$

수학식 24

[0097] $$x_i^{tr+1}=x_i^{tr}+v_i^{tr+1}$$

[0098] 상기 수학식에서, x_i와 v_i 는 i번째 입자의 위치와 속도이고, c_1과 c_2는 각각 입자와 swarm의 가속상수이고, r_1과 r_2는 0과 1 사이의 난수이며, Gbest는 최적 비용함수 값이고, Pbest는 최적 비용함수 값을 갖는 입자의 최적 위치이다.

[0099] 또한, 재생성 단계(S214)에서는 입자의 속도에 대한 관성력(I)를 업데이트할 수 있다. 업데이트된 관성력 값은 하기의 수학식 25에 의해 산출된다. 이후, 업데이트된 관성력 값을 토대로 새로운 입자를 생성하는 것이 바람직하다.

수학식 25

[0100] $$I^{tr+1}=I_{\max}-\left(\frac{I_{\max}-I_{\min}}{tr_{\max}}\right)tr$$

[0101] PSO 알고리즘의 변수 중 가속 상수(c_1,c_2)와 관성력(I)은 입자의 움직임을 제한하기 위해 필수적인 요소로서 작업자가가 P_{best}와 G_{best}의 중 어느 값을 중점적으로 판단하는지와 입자를 얼마나 빠르게 움직일것인지의 의미를 갖는다. 이 값은 관성력(I)값이 클 경우 Global 탐색능력을 강화하고, 작을 경우 Local 탐색능력을 강화시키는 특성이 있다. 이러한 특징 때문에 반복 초반에는 큰 관성력을 활용하다가 점차 작은 관성력을 활용하여 Global과 Local 둘 다 만족하는 결과를 탐색해야 한다. 관성력의 범위는 Eberhart와 Shi에 의해 관성력의 최대값과 최소값을 I_{max}과 I_{min}로 제한하는 것이 더 나은 접근 방식임이 증명되어 각각의 상수로서 제한된다.

[0102] 재설정 단계(S215)는 새로운 입자로부터 회적 비용함수 값, 최적 위치 값을 갱신하는 단계이다. 여기서, 모델 구축모듈(300)은 재생성 단계(S214)에서 생성된 새로운 입자의 요소로 기계학습된 신경망 모델과, 학습 데이터 세트를 상기 수학식 22에 적용하여 각 입자의 비용함수(G)를 산출한다. 다음, 모델 구축모듈(300)은 산출된 새

로운 비용함수 값이 상기 최적 비용함수 값 미만이면, 상기 새로운 입자의 비용함수 값 및 위치를 상기 최적 비용함수 값(G_{best}) 및 최적 위치(P_{best})로 재설정한다.

[0103] 반복 단계는 상기 재생성 단계(S214) 및 재설정 단계(S215)를 기설정된 훈련 횟수(tr_{max}) 만큼 반복하는 단계이다. 모델 구축모듈(300)은 해당 재생성 단계(S214) 내지 재설정 단계(S215)를 반복하여 기계학습 훈련을 다수회 수행한다.

[0104] 최종 설정 단계(S217)는 상기 반복 단계 이후에, 상기 최적 비용함수 값의 상기 입자의 요소를 상기 신경망 모델의 가중치 및 편향치로 설정하는 단계이다. 기계학습 훈련 횟수(tr)이 기설정된 훈련 횟수(tr_{max})를 초과할 경우, 각 입자가 의미하는 가중치(weight) 및 편향치(bias)를 반환하여 기계학습 훈련을 종료한다. 기계학습 훈련 종료 후 구축된 신경망 모델의 목표 오차가 0.01s이하의 오차를 갖는다면 훈련이 성공한 것으로 가정한다.

[0105] 한편, 도 8에는 모델 구축 단계(S200)에서 구축된 신경망 모델의 수렴 성능이 게시되어 있다. 신경망 모델의 성능지표는 SSE(Sum Square Error)을 활용하였으며, 입력 성형 정보 즉, 각 switch time이 평균적으로 0.01 이하의 오차를 갖는 것을 목표로 기계학습 훈련이 완료되었다.

[0106] 신경망 모델의 정확성 평가 방법으로 학습 데이터 세트의 입력 값의 범위 내의 임의의 값을 활용하여 상대 오차(e) 값을 산출하여 평가한다. 상대 오차 평가식은 하기의 수학식 26과 같다.

수학식 26

[0107] $$e=\left|\frac{y'_{i,j}-y_{i,j}}{y_{i,j}}\right|*100\%$$

[0108] 상기 $y_{i,j}$는 상기 학습 데이터 세트의 임의의 입력 값에 대한 실제 타겟 값이고, 상기 $y'_{i,j}$는 상기 학습 데이터 세트의 입력 값을 기계학습 과정에서 구축된 신경망 모델에 적용하여 출력된 결과 값이다. 산출된 상대 오차 값은 하기의 표 3과 같다. 상기 표 3을 참조하면, 구축된 신경망 모델의 오차율이 적어 정확도가 비교적 높음을 알 수 있다.

표 3

[0109]

test no.	t_2	t'_2	e	t_3	t'_3	e
1	1.7493	1.7554	0.3458%	3.5560	3.5671	0.3138%
2	1.7719	1.7554	0.1964%	3.5666	3.5720	0.1502%
3	1.7902	1.7866	0.2005%	3.5849	3.5865	0.0434%
4	1.7494	1.7554	0.3436%	3.4908	3.4995	0.2503%
test no.	t_5	t'_5	e	t_6	t'_6	e
1	1.8061	1.8069	0.0451%	3.5549	3.5580	0.0889%
2	1.7945	1.7920	0.1409%	3.5662	3.5631	0.0890%
3	1.7947	1.8057	0.6116%	3.5848	3.5985	0.3836%
4	1.7415	1.7368	0.2683%	3.4909	3.4846	0.1794%

[0110] 한편, 본 발명의 신경망 모델 구축 방법으로 구축된 신경망 모델을 적용한 입력 성형기(NN-UMZVF Shaper)의 성능을 평가하면 다음과 같다. 인공 신경망 모델의 오차가 비선형 입력성형기의 비선형 고려 성질을 해칠 수 있는지 평가하기 위하여 NN-UMZV와의 성능을 비교한다. 잔류변위 제어 선능 비교를 위하여 종래의 UMZVF Shaper와 AOF-UMZV(Average Of Frequency UMZV) Shaper를 비교한다. 평가를 위해 UMZVF Shaper는 최초 입력시의 Hoisting Length를 기준으로 주파수를 계산하며, AOF-UMZV Shaper는 실험중 Hoisting Length가 변화하는 범위를 고려하여 실험한다. 성능 비교를 위하여 AOF-UMZV Shaper와 UMZVF Shaper는 Feed-forward구조로 설계되었으며, NN-UMZVF Shaper와 잔류변위를 평가한다. 시뮬레이션에 활용될 타워 크레인의 파라미터는 하기의 표 4와 같다.

표 4

$L(m)$	$x(m)$	τ_a(sec)	τ_b(sec)	$s_v(rad/s)$	$L_v(m/s)$	$L_{move}(m)$	t_p(sec)
25	25	0.03	0.045	0.08	0.5	1	10

[0111]

[0112] 상기 표4에서 s_v는 이동(slewing)방향으로 움직이는 최대속도이며, L_v는 Hoisting length가 늘어나는 속도, L_{move}는 Hoisitng length가 늘어나는 거리, t_p는 입력명령이 정지하는 시간이다.

[0113] 도 9에는 NN-UMZVF Shaper와 NN-UMZV Shaper, UMZVF Shaper의 잔류변위 그래프가 게시되어 있다. 입력 파라미터의 모든 범위에서 NN-UMZVF Shaper는 훈련 데이터 세트로로 활용된 UMZVF Shaper와 비선형성이 고려되지 않은 NN-UMZV shaper와 비교하여 잔류변위 제어 성능이 뛰어난 것으로 나타난다. 비선형 변수의 제어에서 NN-UMZVF Shaper는 넓은 τ_a범위에서 최대 10%의 잔류변위 상승률을 보였으나, NN-UMZV Shaper의 경우 평균적으로 20%의 잔류변위 상승률을 보였다. 이는 신경망 모델이 1st-order input shaper의 비선형성 제어 성능을 보장하는 것을 증명한다.

[0114] 도 10에는 NN-UMZVF Shaper와 UMZVF Shaper, AOF-UMZV Shaper의 Hoisting length의 변화량에 따른 잔류변위 그래프가 게시되어 있다. 시뮬레이션 중 hoisting length는 표 4의 hoisting 상승속도를 유지하며 원하는 거리만큼 상승하였으며, AOF-UMZV는 상승을 모두 고려한 주파수를 활용하여 시뮬레이션되었다. 신경망 모델을 활용한 입력성형기는 신경망 모델을 활용하지 않은 다른 두 Shaper와 비교하여 hoisting length의 증가량에 따른 잔류변위 상승 폭이 적은 것으로 나타났다. 위 결과는 신경망 모델을 활용한 적응형 입력성형기는 파라미터의 실시간 변화량이 많을수록, 더욱 높은 잔류변위 제어 성능을 보여준다는 것을 입증한다.

[0115] 도 11 및 도 12에는 NN-UMZVF Shaper와 UMZVF Shaper, AOF-UMZV Shaper에 대하여 Neural Network의 입력인 최초 hoisting length 와 τ_a 혹은 τ_a와 τ_b에 따른 잔류변위 그래프가 게시되어 있다. Feedforward 구조의 넓은 파라미터 범위에서 잔류변위 제어 성능을 확보한 AOF-UMZV shaper는 비선형을 고려하지 않았음에도, UMZVF Shaper보다 잔류변위 제어 성능이 뛰어난 것으로 나타난다. NN-UMZVF Shaper는 잔류변위를 완벽하게 제거하지 못했지만, 기존에 개발된 Shaper들과 비교하여 잔류변위 제어 성능이 뛰어난 것으로 나타나며, 훈련 데이터 세트로서 활용된 UMZVF Shaper와 비교하여 평균적으로 30%이상의 잔류변위 감소율을 확보하였다. 결론적으로 신경망 모델을 활용한 입력성형기는 운용중 실시간으로 파라미터가 변화하는 시스템에 대해 개선된 잔류변위 제어 성능을 확보할 수 있다.

[0116] 한편, 소형 타워 크레인(Mini-scale Tower Crane)을 제작하여 본 발명에 따라 구축된 신경망 모델이 적용된 입력 성형기(NN-Input Shaper)의 성능 시험을 실시하였다. 도 13은 상기 소형 타워 크레인에 대한 사진이고, 도 14는 상기 소형 타워 크레인을 구성하는 하드웨어 및 구성요소를 기재한 개념도이다.

[0117] 개발된 NN 입력성형기는 소형(mini scale)의 파라미터의 범위에 적용할 수 있도록 기계학습을 다시 실행한다. 기계학습에 활용된 파리미터는 하기의 표 5와 같으며, 소형 타워크레인의 파라미터는 하기의 표 6과 같다.

표 5

$L(m)$	τ_a(sec)	τ_b(sec)
[0.5 1.0], 0.05	[0.01 0.05], 0.005	[0.01 0.05], 0.005

[0118]

표 6

$L(m)$	$x(m)$	τ_a(sec)	τ_b(sec)	$s_v(rad/s)$	$L_v(m/s)$	$L_{move}(m)$	t_p(sec)
0.7	0.7	0.04	0.03	0.35	0.05	0.1	3

[0119]

[0120] 여기서, Programmable Logic Controller(PLC)에 의해 생성된 명령이 Slew, Trolley, Hoist의 세 모터 드라이브로 전송되며, 컴퓨터와 무선 로컬 영역 네트워크(LAN)를 활용하여 연결된다. Desktop PC는 WinCC, CFC, SCL소프트웨어를 활용하여 컨트롤 박스에 입력 속도값 등을 업로드 및 다운로드한다. 모터 드라이브는 Siemens사의 synchronous AC 모터를 활용하며 통신 모듈 및 모터용 제어 드라버로 구성된다. 비전 카메라는 VS 720계열로서 Spectation 소프트웨어를 활용하여 Payload를 감지하여 잔류진동의 크기를 측정한다. UMZVF Shaper와 AOF-UMZV Shaper, NN-UMZVF Shaper의 세 Shaper 모두 동일한 초기 파라미터 및 Hoisting Length의 변화량을 가정하여 실험을 진행한다.

[0121] 도 15에는 NN-UMZVF Shaper의 속도 명령 그래프와 실제 속도 명령의 오차 및 시간에 따른 Hoist Length의 변화에 대한 그래프가 게시되어 있다. 속도 명령이 실제 시스템에서 적용될 때 시스템의 관성 등에 의해 영향을 받아 약간의 오차가 발생하였으나, 그 수치가 미미하여 실제 시스템의 잔류변위 출력에 미치는 영향은 적다.

[0122] 도 16에는 UMZVF Shaper와 AOF-UMZV Shaper, NN-UMZVF Shaper의 입력 명령이 종료된 후 잔류변위가 존재할 때 트롤리(13)를 절대 좌표로 설정한 페이로드(14)의 움직임에 대한 그래프가 게시되어 있다. 타워 크레인의 움직임이 이동(Slew)방향의 한 방향으로 움직였음에도 불구하고 페이로드(14)가 타원형으로 움직이고 있는 특징이 AOF-UMZV Shaper와 UMZVF Shaper에서 크게 나타난다. 이를 제어하기 위하여 radial 방향의 새로운 입력이 필요할 수 있지만, slewing 방향의 적절한 입력으로 타원의 반경을 줄일 수 있는 것으로 보여준다.

[0123] 도 17에는 최초 hoisting length에 따른 세 shaper(UMZVF Shaper, AOF-UMZV Shaper, NN-UMZVF Shaper)의 잔류변위 그래프가 게시되어 있다. 모든 범위에서 신경망 모델을 활용한 Shaper가 기존의 Shaper들보다 잔류변위 제어 성능이 뛰어난 것으로 나타난다. 시뮬레이션 결과와 동일하게 hoisting length position에 따라 NN-UMZVF Shaper, AOF-UMZV Shaper, UMZVF Shaper의 잔류변위가 크게 차이나는 것이 실험적으로 검증되었으며, 특히 AOF-UMZV Shaper의 경우 일부 구간에서 UMZVF Shaper와 거의 동일한 결과를 나타낸다.

[0124] 도 18에는 UMZVF Shaper, AOF-UMZV Shaper, NN-UMZVF Shaper의 상승 시상수에 따른 잔류변위 그래프가 게시되어 있다. 모든 범위에서 신경망 모델을 활용한 Shaper가 기존의 Shaper들보다 잔류변위 제어 성능이 뛰어난 것이 실험적으로 검증되었으며, 시뮬레이션 결과보다 mini-scale일 때 비선형성에 따른 Shaper의 제어 성능 편차가 큰 것으로 나타난다. 게다가 mini-scale에서 Neural Network를 활용한 비선형 Shaper가 고정 Parameter에 대해 설계된 Shaper보다 최대 60%의 잔류변위 제어 성능 상승 효과가 있음이 실험적으로 검증되었다.

[0125] 상술된 바와 같이 본 발명에 따른 타워 크레인의 비선형에 대한 입력 성형기용 신경망 모델 구축 방법 및 입력 성형기용 신경망 모델 구축 시스템(100)은 PSO 알고리즘을 이용하여 타워 크레인의 작동 중 잔류 진동 감소를 위한 입력 성형 정보를 산출하기 위한 신경망 모델을 훈련시키므로 타워 크레인 시스템에서의 보다 정확도 높은 작동을 제공할 수 있는 신경망 모델을 획득할 수 있는 장점이 있다.

[0126] 제시된 실시예들에 대한 설명은 임의의 본 발명의 기술분야에서 통상의 지식을 가진 자가 본 발명을 이용하거나 또는 실시할 수 있도록 제공된다. 이러한 실시예들에 대한 다양한 변형들은 본 발명의 기술 분야에서 통상의 지식을 가진자에게 명백할 것이며, 여기에 정의된 일반적인 원리들은 본 발명의 범위를 벗어남이 없이 다른 실시예들에 적용될 수 있다. 그리하여, 본 발명은 여기에 제시된 실시예들로 한정되는 것이 아니라, 여기에 제시된 원리들 및 신규한 특징들과 일관되는 최광의의 범위에서 해석되어야 할 것이다.

부호의 설명

[0127] 100: 입력 성형기용 신경망 모델 구축 시스템

110: 입력모듈

120: 모델 구축모듈

S100: 데이터 획득 단계

S200: 모델 구축 단계

S211: 초기 생성 단계

S212: 초기 설정 단계

S213: 계산 단계

S214: 재생성 단계

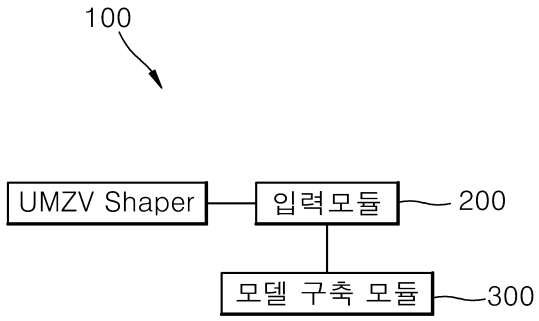
S215: 재설정 단계

S216: 반복단계

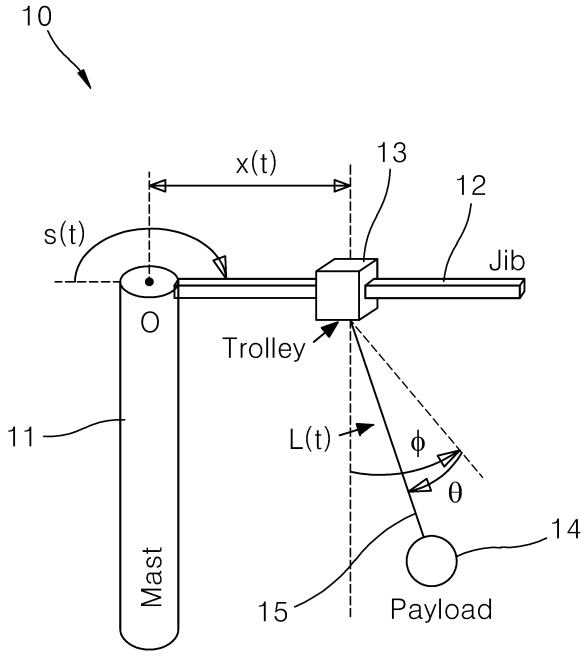
S217: 최종 설정 단계

도면

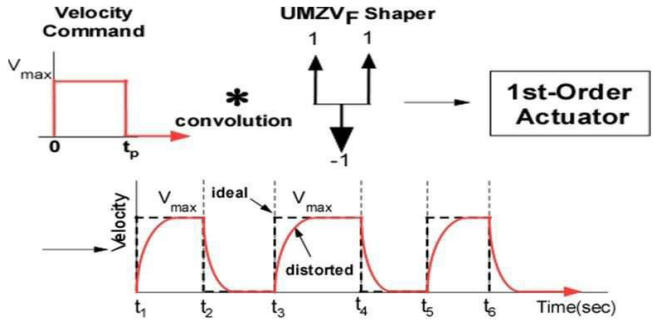
도면1



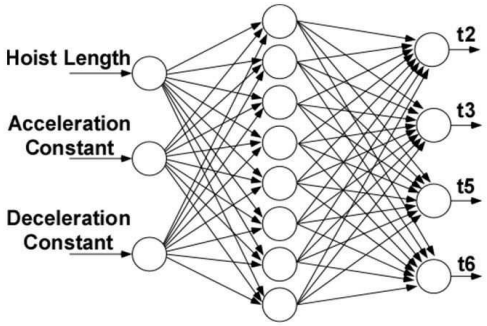
도면2



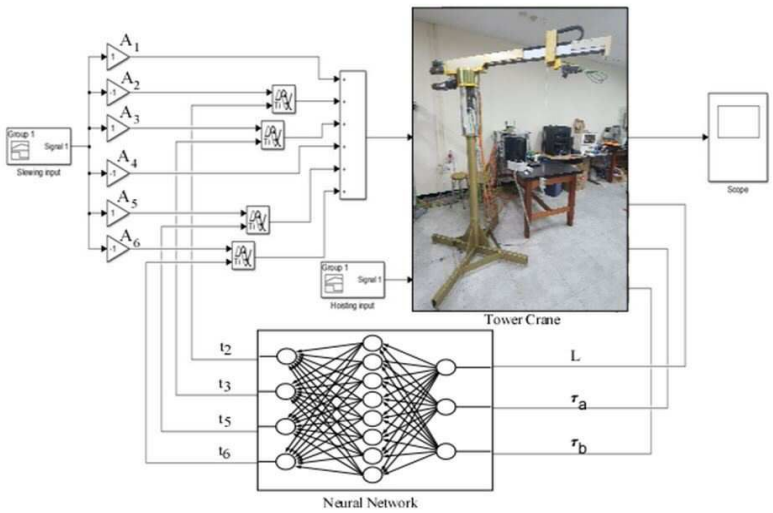
도면3


Velocity Command
UMZV_F Shaper
1
1
-1
V_max
0
t_p
convolution
1st-Order Actuator
Velocity
V_max
ideal
V_max
distorted
t1
t2
t3
t4
t5
t6
Time(sec)

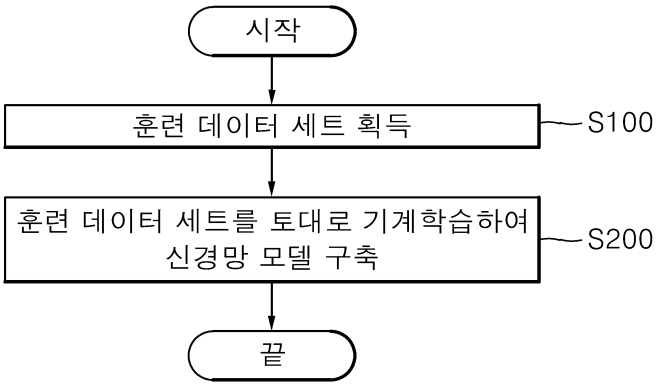
도면4


Hoist Length
Acceleration Constant
Deceleration Constant
t2
t3
t5
t6

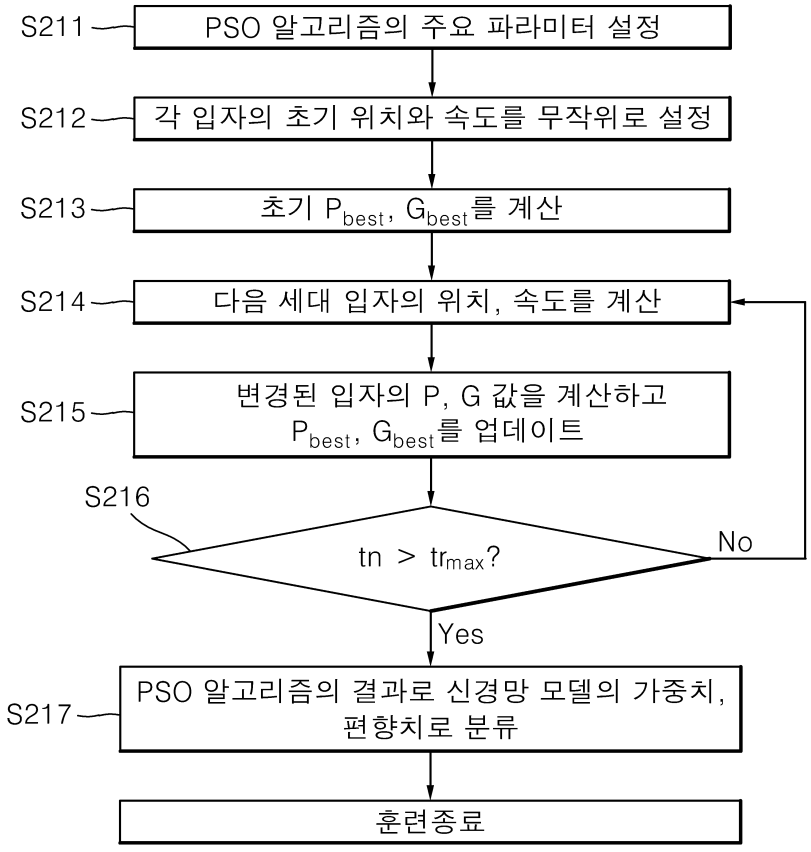
도면5


A1
A2
A3
A4
A5
A6
Group 1
Signal 1
Slewing input
Hoisting input
Tower Crane
Scope
t2
t3
t5
t6
L
τa
τb
Neural Network

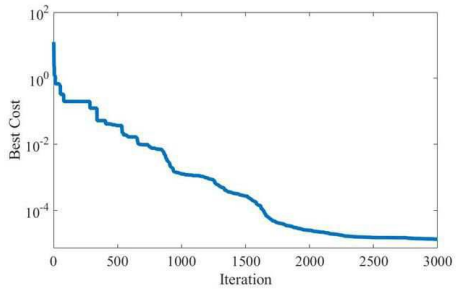
도면6


시작
훈련 데이터 세트 획득
S100
훈련 데이터 세트를 토대로 기계학습하여 신경망 모델 구축
S200
끝

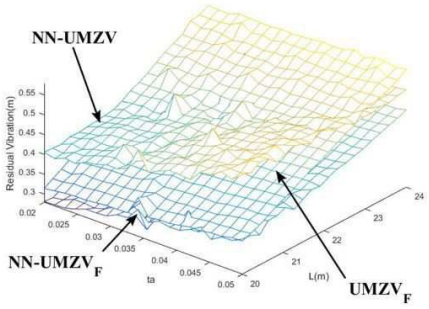
도면7


S211
PSO 알고리즘의 주요 파라미터 설정
S212
각 입자의 초기 위치와 속도를 무작위로 설정
S213
초기 P_{best}, G_{best}를 계산
S214
다음 세대 입자의 위치, 속도를 계산
S215
변경된 입자의 P, G 값을 계산하고 P_{best}, G_{best}를 업데이트
S216
tn > tr_{max}?
No
Yes
S217
PSO 알고리즘의 결과로 신경망 모델의 가중치, 편향치로 분류
훈련종료

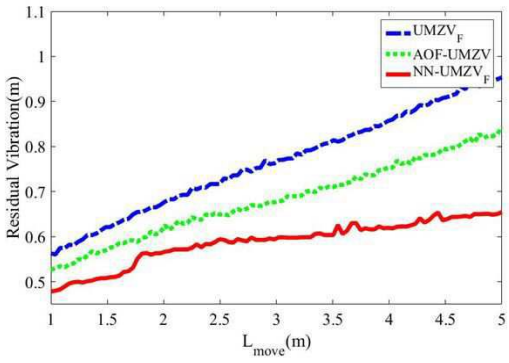
도면8



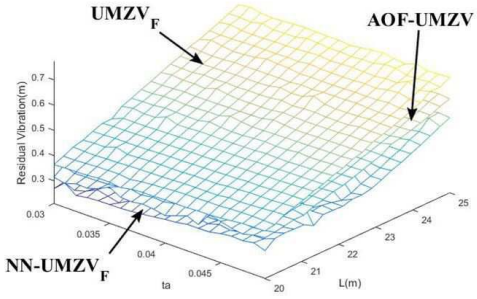
도면9



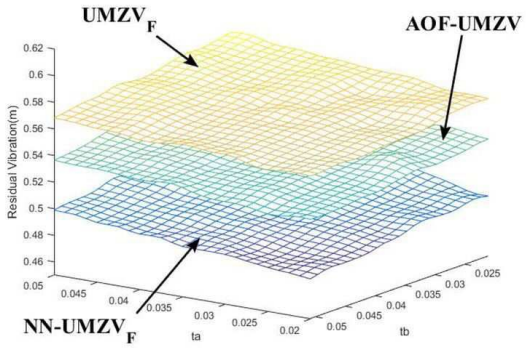
도면10



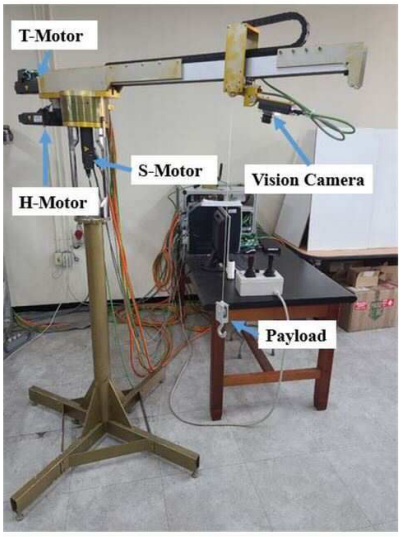
도면11



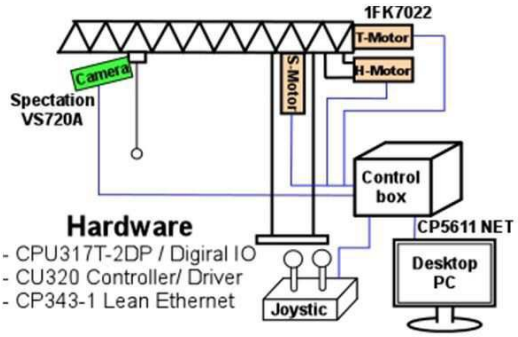
도면12



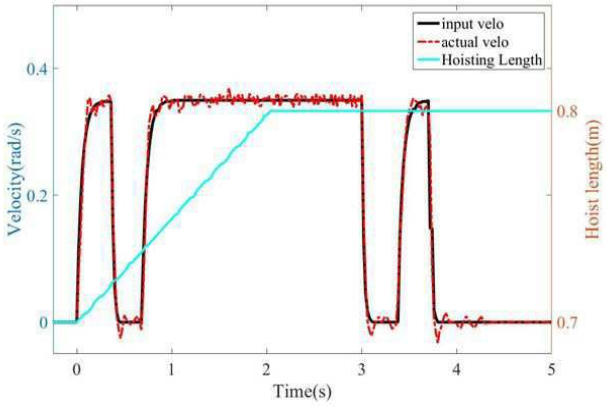
도면13



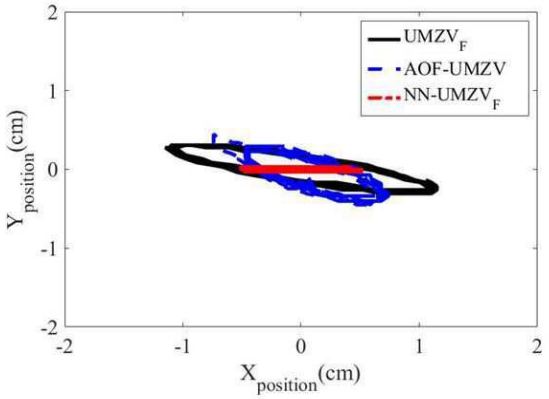
도면14



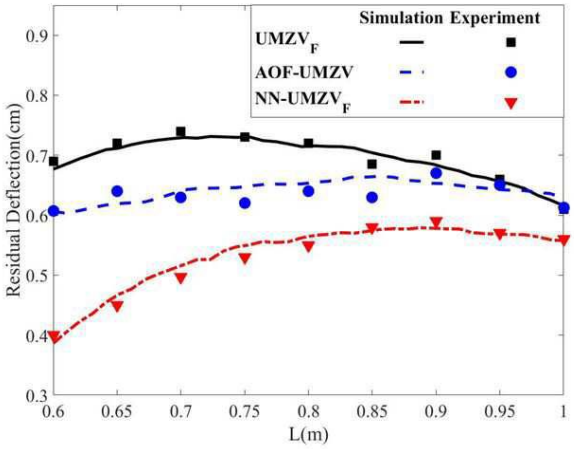
도면15



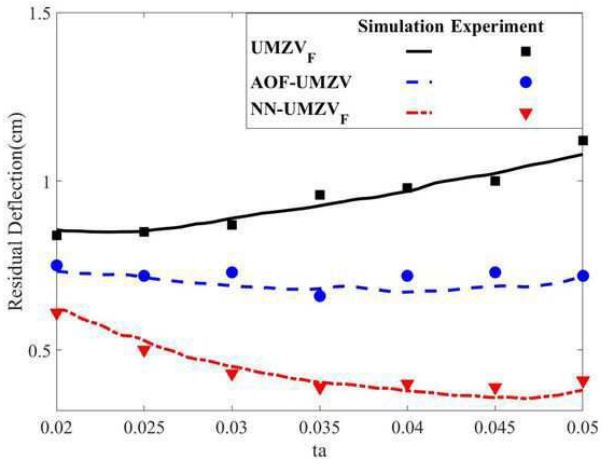
도면16



도면17



도면18


Simulation Experiment
UMZV_F
AOF-UMZV
NN-UMZV_F
Residual Deflection(cm)
1.5
1
0.5
0.02
0.025
0.03
0.035
0.04
0.045
0.05
ta