



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0167544
(43) 공개일자 2024년11월27일

- (51) 국제특허분류(Int. Cl.)
 - F27B 9/40 (2006.01) B21B 37/58 (2006.01)
 - C21D 9/50 (2006.01) C21D 9/56 (2006.01)
 - F27B 9/28 (2006.01) F27D 19/00 (2006.01)
 - F27D 21/00 (2006.01) F27D 21/02 (2006.01)
 - G06N 3/0442 (2023.01) G06N 3/045 (2023.01)
 - G06N 3/08 (2023.01)
- (52) CPC특허분류
 - F27B 9/40 (2013.01)
 - B21B 37/58 (2013.01)
- (21) 출원번호 10-2023-0065104
- (22) 출원일자 2023년05월19일
 - 심사청구일자 2023년05월19일
- (71) 출원인
 - 포항공과대학교 산학협력단
 - 경상북도 포항시 남구 청암로 77 (지곡동)
- (72) 발명자
 - 김상우
 - 경상북도 포항시 남구 청암로 77
- (74) 대리인
 - 조민기
 - 경상북도 포항시 남구 청암로 77
- 특허법인이상


전체 청구항 수 : 총 20 항

(54) 발명의 명칭 인공지능망 기반 소둔로 예측 제어 방법 및 장치

(57) 요약

인공지능망 기반 소둔로 예측 제어 방법 및 장치가 개시된다. 예측 제어 방법은, 소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계, 시계열 입력 데이터에 기초하여 체인 구조의 인공지능망의 인공지능망 셀들을 통해 미래 출력값을 생성하는 단계, 및 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 출력하는 단계를 포함한다.

대표도 - 도1



(52) CPC특허분류

C21D 9/50 (2013.01)
C21D 9/563 (2013.01)
F27B 9/28 (2013.01)
F27D 21/0014 (2013.01)
F27D 21/02 (2013.01)
G06N 3/0442 (2023.01)
G06N 3/045 (2023.01)
G06N 3/049 (2023.01)
G06N 3/08 (2023.01)

명세서

청구범위

청구항 1

인공신경망 기반 소둔로 예측 제어 장치에 의해 수행되는 인공신경망 기반 소둔로 예측 제어 방법으로서,

소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 상기 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계;

상기 시계열 입력 데이터에 기초하여 체인 구조의 인공신경망의 인공신경망 셀들을 통해 미래 출력값을 생성하는 단계; 및

상기 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 상기 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 출력하는 단계;를 포함하고,

상기 입력값은 미리 정해진 관측 시간 동안 상기 인공신경망 셀들 중 일부에 각각 입력되는 과거 입력값들과, 미리 정해진 예측 시간 동안 상기 예측 시간의 흐름에 따라 상기 인공신경망 셀들 중 나머지에 각각 입력되는 현재 입력값들을 포함하는, 소둔로 예측 제어 방법.

청구항 2

청구항 1에 있어서,

상기 조업 데이터는 소둔로 내부의 현재 분위기 온도, 상기 소둔로에 투입된 철강의 종류, 두께, 너비 및 이동 속도에 대한 정보를 포함하는, 소둔로 예측 제어 방법.

청구항 3

청구항 2에 있어서,

상기 인공신경망은, 제1 층의 제1 인공신경망과 상기 제1 층에 중첩되는 제2 층의 제2 인공신경망을 구비하고, 상기 제1 인공신경망의 복수의 인공신경망 셀들에 의한 체인 구조와 상기 제2 인공신경망의 복수의 인공신경망 셀들에 의한 체인 구조는 동일하며, 상기 제2 인공신경망의 출력 개수는 상기 제1 인공신경망의 입력 개수의 절반 이하인, 소둔로 예측 제어 방법.

청구항 4

청구항 1에 있어서,

상기 인공신경망은 LSTM(Long Short-term Memory), 어텐션(Attention) 구비 순환신경망(Recurrent Neural Network, RNN), 그리드(Grid) LSTM, 게이트 순환 유닛(Gated Recurrent Unit, GRU), 깊이 게이트 LSTM(Depth-Gated LSTM) 중 적어도 어느 하나 이상을 포함하는, 소둔로 예측 제어 방법.

청구항 5

청구항 1에 있어서,

상기 소둔로의 내부의 분위기 온도에 대한 온도 제어 목표치 및 상기 소둔로에 투입되는 철강의 이동 속도에 대한 제어 목표치 중 적어도 하나를 포함하는 제어 입력을 상기 소둔로로 전달하는 단계를 더 포함하는, 소둔로 예측 제어 방법.

청구항 6

청구항 5에 있어서,

상기 제어 입력에 대한 플랜트 반응 응답과 상기 출력 목표값에 기초하여 피드백 제어기로 상기 소둔로의 정상 상태 오차가 최소화되도록 상기 소둔로로 전달되는 상기 제어 입력을 보정하는 단계를 더 포함하는, 소둔로 예

측 제어 방법.

청구항 7

인공신경망 기반 소둔로 예측 제어 장치에 의해 수행되는 인공신경망 기반 소둔로 예측 제어 방법으로서,

소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 상기 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계;

상기 시계열 입력 데이터에 기초하여 체인 구조의 인공신경망의 인공신경망 셀들을 통해 미래 출력값을 생성하는 단계;

상기 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 상기 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 계산하는 단계; 및

상기 인공신경망을 학습시키는 단계;를 포함하고,

상기 입력값은 미리 정해진 관측 시간 동안 상기 인공신경망 셀들 중 일부에 각각 입력되는 과거 입력값들과, 미리 정해진 예측 시간 동안 상기 예측 시간의 흐름에 따라 상기 인공신경망 셀들 중 나머지에 각각 입력되는 현재 입력값들을 포함하는, 소둔로 예측 제어 방법.

청구항 8

청구항 7에 있어서,

상기 학습시키는 단계는, 상기 소둔로 예측 제어 장치의 상기 인공신경망과 동일한 구조의 인공신경망을 가진 예측 모델을 상기 소둔로의 위치에서 상기 소둔로 예측 제어 장치에 연결하는 단계를 포함하는, 소둔로 예측 제어 방법.

청구항 9

청구항 7에 있어서,

상기 학습시키는 단계는,

상기 시계열 입력 데이터를 상기 예측 모델의 입력으로 전달하는 단계;

상기 소둔로 예측 제어 장치의 현재의 제1 제어 입력을 상기 예측 모델의 다른 입력으로 전달하는 단계; 및

상기 예측 모델로부터 상기 시계열 입력 데이터 및 상기 제1 제어 입력에 따른 출력 예측값을 받는 단계를 포함하는, 소둔로 예측 제어 방법.

청구항 10

청구항 9에 있어서,

상기 출력 예측값과 상기 출력 목표값에 기초하여 비용함수를 계산하는 단계; 및

상기 비용함수가 최소화되도록 상기 소둔로 예측 제어 장치를 학습시키는 단계를 더 포함하는, 소둔로 예측 제어 방법.

청구항 11

청구항 7에 있어서,

상기 인공신경망은, 제1 층의 제1 인공신경망과 상기 제1 층에 중첩되는 제2 층의 제2 인공신경망을 구비하고, 상기 제1 인공신경망의 복수의 인공신경망 셀들에 의한 체인 구조와 상기 제2 인공신경망의 복수의 인공신경망 셀들에 의한 체인 구조는 동일하며, 상기 제2 인공신경망의 출력 개수는 상기 제1 인공신경망의 입력 개수의 절반 이하인, 소둔로 예측 제어 방법.

청구항 12

인공신경망 기반 소둔로 예측 제어 장치로서,

소둔로 내부의 분위기 온도 및 소둔로에 투입되는 철강의 이동 속도 중 적어도 어느 하나를 제어하기 위한 프로그램 명령을 수행하는 프로세서를 포함하고,

상기 프로세서는, 상기 프로그램 명령에 의해,

소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 상기 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계;

상기 시계열 입력 데이터에 기초하여 체인 구조의 인공신경망의 인공신경망 셀들을 통해 미래 출력값을 생성하는 단계; 및

상기 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 상기 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 계산하는 단계;를 수행하며,

상기 입력값은 미리 정해진 관측 시간 동안 상기 인공신경망 셀들 중 일부에 각각 입력되는 과거 입력값들과, 미리 정해진 예측 시간 동안 상기 예측 시간의 흐름에 따라 상기 인공신경망 셀들 중 나머지에 각각 입력되는 현재 입력값들을 포함하는, 소둔로 예측 제어 장치.

청구항 13

청구항 12에 있어서,

상기 조업 데이터는 소둔로 내부의 현재 분위기 온도, 상기 소둔로에 투입된 철강의 종류, 두께, 너비 및 이동 속도에 대한 정보를 포함하는, 소둔로 예측 제어 장치.

청구항 14

청구항 12에 있어서,

상기 인공신경망은, 제1 층의 제1 인공신경망과 상기 제1 층에 중첩되는 제2 층의 제2 인공신경망을 구비하고, 상기 제1 인공신경망의 복수의 인공신경망 셀들에 의한 체인 구조와 상기 제2 인공신경망의 복수의 인공신경망 셀들에 의한 체인 구조는 동일하며, 상기 제2 인공신경망의 출력 개수는 상기 제1 인공신경망의 입력 개수의 절반 이하인, 소둔로 예측 제어 장치.

청구항 15

청구항 12에 있어서,

상기 인공신경망은 LSTM(Long Short-term Memory), 어텐션(Attention) 구비 순환신경망(Recurrent Neural Network, RNN), 그리드(Grid) LSTM, 게이트 순환 유닛(Gated Recurrent Unit, GRU), 깊이 게이트 LSTM(Depth-Gated LSTM) 중 적어도 어느 하나 이상을 포함하는, 소둔로 예측 제어 장치.

청구항 16

청구항 12에 있어서,

상기 프로세서는, 상기 소둔로의 내부의 분위기 온도에 대한 온도 제어 목표치 및 상기 소둔로에 투입되는 철강의 이동 속도에 대한 제어 목표치 중 적어도 하나를 포함하는 제어 입력을 상기 소둔로로 전달하는 단계를 더 수행하는, 소둔로 예측 제어 장치.

청구항 17

청구항 16에 있어서,

상기 인공신경망에 연결되는 피드백 제어기를 더 포함하고,

상기 프로세서는, 상기 제어 입력에 대한 플랜트 반응 응답과 상기 출력 목표값에 기초하여 상기 피드백 제어기로 상기 소둔로의 정상 상태 오차가 최소화되도록 상기 소둔로로 전달되는 상기 제어 입력을 보정하는 단계를 더 수행하는, 소둔로 예측 제어 장치.

청구항 18

청구항 12에 있어서,

상기 인공지능경망으로 구성되는 예측 제어 장치에 연결되어 상기 인공지능경망을 학습시키는데 사용되는 예측 모델을 더 포함하며,

상기 예측 모델은 상기 소둔로 예측 제어 장치의 상기 인공지능경망과 동일한 구조의 인공지능경망을 가지고 상기 소둔로의 위치에서 상기 소둔로 예측 제어 장치에 연결되는, 소둔로 예측 제어 장치.

청구항 19

청구항 18에 있어서,

상기 프로세서는, 상기 학습시키는 단계에서,

상기 시계열 입력 데이터를 상기 예측 모델의 입력으로 전달하는 단계;

상기 소둔로 예측 제어 장치의 현재의 제1 제어 입력을 상기 예측 모델의 다른 입력으로 전달하는 단계; 및

상기 예측 모델로부터 상기 시계열 입력 데이터 및 상기 제1 제어 입력에 따른 출력 예측값을 받는 단계를 더 수행하는, 소둔로 예측 제어 장치.

청구항 20

청구항 19에 있어서,

상기 예측 모델에 연결되는 비용함수 계산 모듈을 더 포함하고,

상기 프로세서는, 상기 학습시키는 단계에서,

상기 비용함수 계산 모듈을 통해 상기 출력 예측값과 상기 출력 목표값로부터 비용함수를 계산하는 단계, 및 상기 비용함수가 최소화되도록 상기 소둔로 예측 제어 장치를 학습시키는 단계를 더 수행하는, 소둔로 예측 제어 장치.

발명의 설명

기술 분야

[0001] 본 개시는 소둔로 제어 기술에 관한 것으로, 보다 상세하게는, 인공지능경망 기반 소둔로 예측 제어 방법 및 장치에 관한 것이다.

배경 기술

[0002] 고품질 철강을 생산하기 위해 소둔로를 통해 생산되는 철강의 온도를 보다 정확하게 유지하는 것은 매우 중요하다. 소둔로 온도를 제어하는 대부분의 종래 기술의 경우, 소둔로의 내부 분위기 온도가 높으면 단순히 연료량을 줄이고 온도가 낮으면 연료량을 높이는 방식의 단순 제어 방법(PID)과 조업자의 재량에 따라 제어 입력 적용 지점을 변경하는 방식을 사용하고 있다.

[0003] 최근 철강 제품 종류의 다양화로 인해 서로 다른 종류의 철강을 용접하여 연속 조업하는 경우가 많아졌다. 서로 다른 종류의 철강 소재들을 용접하여 소둔로에서 연속 조업하는 경우, 철강의 용접 부위 전후에서 목표 온도가 서로 다를 수 있다. 즉, 철강의 소둔로 작업 시에는 고품질의 철강 제품 생산을 위해 소둔로 내부의 각 지점을 지나는 철강 부위들에서 미리 설정된 목표 온도로 맞게 소둔로 내부의 온도 분위기를 제어할 필요가 있다.

[0004] 한편, 소둔로 내부의 각 구간별 온도 분위기는 통상 소둔로 내부에서 철강의 이동 경로를 따라 철강에 인접하게 위치하도록 배치된 복수의 라디에이터들을 사용하여 제어된다. 이때, 소둔로 내부의 구간별 분위기 온도를 철강 소재별로 즉각적으로 바꿀 수 없기 때문에, 철강 소재별로 미리 설정된 목표 온도를 고려하여 해당 철강 부분을 가열하기 시작하는 데까지 걸리는 시간을 예측하여 소둔로 내부 분위기 온도를 제어할 필요가 있다.

[0005] 하지만 종래 기술에서는 전술한 예측 과정과 온도 제어 타이밍을 조업자의 경험에 의존하여 진행하기 때문에 상대적으로 오차가 크고 정확하지 않은 문제가 있다. 따라서 정확하지 않은 온도 제어는 철강의 품질을 떨어뜨리

기 때문에 소둔로 내부 구간별로 보다 정확한 온도 제어 방안이 요구되고 있는 실정이다.

[0006] 또한, 스마트 팩토리가 주목을 받으면서 공장의 자동 제어에 대한 수요가 높아지고 있고, 철강 산업의 고도화로 인해 고품질 철강을 생산하기 위한 보다 정확한 제어 기술에 대한 수요도 높아지고 있는 환경에서, 조업자의 숙련도에 의존하는 기존의 수동 제어 방법으로 높은 예측 성능을 갖기 어렵다는 한계를 넘을 수 있는 새로운 제어 기술이 요구되고 있다.

발명의 내용

해결하려는 과제

[0007] 본 개시는 전술한 종래 기술의 요구에 부응하기 위한 것으로, 본 개시의 목적은 연속 조업에서도 철강 제품의 품질을 유지할 수 있도록 제어 오차를 최소화할 수 있는 소둔 공정 자동화를 위한 인공지능망 기반 소둔로 예측 제어 방법 및 장치를 제공하는데 있다.

[0008] 본 개시의 다른 목적은 인공지능망 기반 소둔로 예측 제어 방법 및 장치를 위한 인공지능 기반 예측 모델을 제공하는데 있다.

[0009] 본 개시의 또 다른 목적은 예측 모델을 이용하여 인공지능망 기반 소둔로 예측 제어 장치를 학습시키는 트레이닝 방법을 제공하는데 있다.

과제의 해결 수단

[0010] 상기 기술적 과제를 해결하기 위한 본 발명의 일 측면에 따른 인공지능망 기반 소둔로 예측 제어 방법은, 소둔로 내부의 현재 온도, 투입되는 철강의 특성, 및 목표 온도를 포함한 시계열 입력 데이터를 입력으로 받는 단계; 및 대상 소둔로의 제어 오차를 최소화하는 소둔로 내부 온도 제어 입력을 계산하는 단계를 포함한다.

[0011] 상기 방법은 상기 제어 오차를 최소화하는 철강 이동 속도를 계산하는 단계를 더 포함할 수 있다.

[0012] 상기 방법은, 상기 소둔로 내부 온도 제어 입력 및 철강 이동 속도 중 적어도 어느 하나를 이용하여 소둔로의 출력 온도를 원하는 값으로 예측 제어하는 단계를 더 포함할 수 있다.

[0013] 상기 방법은, 정상 상태 오차나 외부 노이즈 등의 가벼운 오차를 피드백 적분 제어기에 의해 보정하는 단계를 더 포함할 수 있다.

[0014] 상기 기술적 과제를 해결하기 위한 본 발명의 다른 측면에 따른 인공지능망 기반 소둔로 예측 제어 방법은, 인공지능망 기반 소둔로 예측 제어 장치에 의해 수행되는 인공지능망 기반 소둔로 예측 제어 방법으로서, 소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 상기 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계; 상기 시계열 입력 데이터에 기초하여 체인 구조의 인공지능망의 인공지능망 셀들을 통해 미래 출력값을 생성하는 단계; 및 상기 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 상기 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 출력하는 단계를 포함한다.

[0015] 상기 입력값은 미리 정해진 관측 시간 동안 상기 인공지능망 셀들 중 일부에 각각 입력되는 과거 입력값들과, 미리 정해진 예측 시간 동안 상기 예측 시간의 흐름에 따라 상기 인공지능망 셀들 중 나머지에 각각 입력되는 현재 입력값들을 포함할 수 있다.

[0016] 상기 조업 데이터는 소둔로 내부의 현재 분위기 온도, 상기 소둔로에 투입된 철강의 종류, 두께, 너비 및 이동 속도에 대한 정보를 포함할 수 있다.

[0017] 상기 인공지능망은, 제1 층의 제1 인공지능망과 상기 제1 층에 중첩되는 제2 층의 제2 인공지능망을 구비하고, 상기 제1 인공지능망의 복수의 인공지능망 셀들에 의한 체인 구조와 상기 제2 인공지능망의 복수의 인공지능망 셀들에 의한 체인 구조는 동일할 수 있다. 여기서, 상기 제2 인공지능망의 출력 개수는 상기 제1 인공지능망의 입력 개수의 절반 이하일 수 있다.

[0018] 상기 인공지능망은 LSTM(Long Short-term Memory), 어텐션(Attention) 구비 순환신경망(Recurrent Neural Network, RNN), 그리드(Grid) LSTM, 게이트 순환 유닛(Gated Recurrent Unit, GRU), 깊이 게이트 LSTM(Depth-Gated LSTM) 중 적어도 어느 하나 이상을 포함할 수 있다.

[0019] 상기 소둔로 예측 제어 방법은, 상기 소둔로의 내부의 분위기 온도에 대한 온도 제어 목표치 및 상기 소둔로에

투입되는 철강의 이동 속도에 대한 제어 목표치 중 적어도 하나를 포함하는 제어 입력을 상기 소둔로로 전달하는 단계를 더 포함할 수 있다.

- [0020] 상기 소둔로 예측 제어 방법은, 상기 제어 입력에 대한 플랜트 반응 응답과 상기 출력 목표값에 기초하여 피드백 제어기로 상기 소둔로의 정상 상태 오차가 최소화되도록 상기 소둔로로 전달되는 상기 제어 입력을 보정하는 단계를 더 포함할 수 있다.
- [0021] 상기 기술적 과제를 해결하기 위한 본 발명의 또 다른 측면에 따른 인공지능망 기반 소둔로 예측 제어 방법은, 인공지능망 기반 소둔로 예측 제어 장치에 의해 수행되는 인공지능망 기반 소둔로 예측 제어 방법으로서, 소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 상기 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계; 상기 시계열 입력 데이터에 기초하여 체인 구조의 인공지능망의 인공지능망 셀들을 통해 미래 출력값을 생성하는 단계; 상기 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 상기 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 계산하는 단계; 및 상기 인공지능망을 학습시키는 단계를 포함한다.
- [0022] 상기 학습시키는 단계는, 상기 소둔로 예측 제어 장치의 상기 인공지능망과 동일한 구조의 인공지능망을 가진 예측 모델을 상기 소둔로의 위치에서 상기 소둔로 예측 제어 장치에 연결하는 단계를 포함할 수 있다.
- [0023] 상기 학습시키는 단계는, 상기 시계열 입력 데이터를 상기 예측 모델의 입력으로 전달하는 단계; 상기 소둔로 예측 제어 장치의 현재의 제1 제어 입력을 상기 예측 모델의 다른 입력으로 전달하는 단계; 및 상기 예측 모델로부터 상기 시계열 입력 데이터 및 상기 제1 제어 입력에 따른 출력 예측값을 받는 단계를 더 포함할 수 있다.
- [0024] 상기 학습시키는 단계는, 상기 출력 예측값과 상기 출력 목표값에 기초하여 비용함수를 계산하는 단계; 및 상기 비용함수가 최소화되도록 상기 소둔로 예측 제어 장치를 학습시키는 단계를 더 포함할 수 있다.
- [0025] 상기 기술적 과제를 해결하기 위한 본 발명의 또 다른 측면에 따른 인공지능망 기반 소둔로 예측 제어 장치는, 소둔로 내부의 분위기 온도 및 소둔로에 투입되는 철강의 이동 속도 중 적어도 어느 하나를 제어하기 위한 프로그램 명령을 수행하는 프로세서를 포함한다. 상기 프로세서는, 상기 프로그램 명령에 의해, 소둔로에 대해 미리 스케줄되어 있고 현재 시점에 기저장되어 있거나 획득가능한 조업 데이터에 대한 입력값과 상기 소둔로의 내부 분위기 온도 제어 목표치와 철강 이동 속도에 대한 출력 목표값을 포함하는 시계열 입력 데이터를 받는 단계; 상기 시계열 입력 데이터에 기초하여 체인 구조의 인공지능망의 인공지능망 셀들을 통해 미래 출력값을 생성하는 단계; 및 상기 미래 출력값에 기초하여 현재 시점부터 미래제어출력수의 미래 시점까지의 상기 출력 목표값과 출력 오차를 최소화하도록 결정되는 제어 입력을 계산하는 단계를 수행하도록 구성될 수 있다.
- [0026] 상기 프로세서는, 상기 소둔로의 내부의 분위기 온도에 대한 온도 제어 목표치 및 상기 소둔로에 투입되는 철강의 이동 속도에 대한 제어 목표치 중 적어도 하나를 포함하는 제어 입력을 상기 소둔로로 전달하는 단계를 더 수행할 수 있다.
- [0027] 상기 소둔로 예측 제어 장치는, 상기 인공지능망에 연결되는 피드백 제어기를 더 포함할 수 있다. 상기 프로세서는, 상기 제어 입력에 대한 플랜트 반응 응답과 상기 출력 목표값에 기초하여 상기 피드백 제어기로 상기 소둔로의 정상 상태 오차가 최소화되도록 상기 소둔로로 전달되는 상기 제어 입력을 보정하는 단계를 더 수행할 수 있다.
- [0028] 상기 소둔로 예측 제어 장치는, 상기 인공지능망으로 구성되는 예측 제어 장치에 연결되어 상기 인공지능망을 학습시키는데 사용되는 예측 모델을 더 포함할 수 있다. 상기 예측 모델은 상기 소둔로 예측 제어 장치의 상기 인공지능망과 동일한 구조의 인공지능망을 가지고 상기 소둔로의 위치에서 상기 소둔로 예측 제어 장치에 연결될 수 있다.
- [0029] 상기 프로세서는, 상기 학습시키는 단계에서, 상기 시계열 입력 데이터를 상기 예측 모델의 입력으로 전달하는 단계; 상기 소둔로 예측 제어 장치의 현재의 제1 제어 입력을 상기 예측 모델의 다른 입력으로 전달하는 단계; 및 상기 예측 모델로부터 상기 시계열 입력 데이터 및 상기 제1 제어 입력에 따른 출력 예측값을 받는 단계를 더 수행할 수 있다.
- [0030] 상기 소둔로 예측 제어 장치는, 상기 예측 모델에 연결되는 비용함수 계산 모듈을 더 포함할 수 있다. 상기 프로세서는, 상기 학습시키는 단계에서, 상기 비용함수 계산 모듈을 통해 상기 출력 예측값과 상기 출력 목표값으로부터 비용함수를 계산하는 단계, 및 상기 비용함수가 최소화되도록 상기 소둔로 예측 제어 장치를 학습시키는

단계를 더 수행하도록 구성될 수 있다.

발명의 효과

- [0031] 본 개시에 의하면, 기존의 소둔로 등의 플랜트에 적용되는 온도 제어 방법에 인공지능 기술을 결합하여 더 높은 성능을 가지면서 서로 다른 규모의 소둔로들이나 서로 다른 종류의 소둔로들에 범용적으로 쉽게 적용할 수 있는 인공지능망 기반 소둔로 예측 제어 방법 및 장치를 제공할 수 있다.
- [0032] 또한, 본 개시에 의하면, 예측 모델을 기반으로 훈련된 인공지능망 기반 예측 제어 장치를 효과적으로 구축할 수 있다. 즉, 소둔 공정 등에 대한 조업 데이터를 기반으로 인공지능 기반 예측 모델을 구축하고, 인공지능 기반 예측 모델의 예측값을 이용하여 제어 오차를 최소화하는 방식으로 예측 제어 장치를 학습시킬 수 있다. 이러한 인공지능망 기반 예측 제어 장치는 비례, 적분 및 미분(Proportional, Integral, Differential, PID) 제어를 이용하는 단순 제어 방법이나 조업자의 재량에 따라 제어 입력 적용 시점을 변경하는 기존 방식에 비해 제어 성능에 대한 높은 신뢰성을 가지는 장점이 있다.
- [0033] 또한, 본 개시에 의하면, 소둔로 등의 플랜트의 공정 구간 별로 온도 제어 목표치를 예측하여 일정 시간 전에 온도를 제어하기 시작해야 하는, 즉 응답 시간이 긴 공정에 대해 효과적으로 적용할 수 있는 인공지능망 기반 예측 제어 장치를 제공할 수 있다. 이러한 예측 제어 장치에 의하면, 소둔로, 석유화학공장 등의 플랜트에서 처리되는 제품의 소재나 원료에 관계없이 공정별 혹은 플랜트 구간별 온도 제어에 대한 신뢰성과 안정성을 향상시킬 수 있다. 특히, 플랜트를 제어하는 제어 시스템의 응답 시간이 상대적으로 긴, 철강 계열의 공정뿐만 아니라 석유화학 계열의 공정 등에서도, 플랜트의 구간별 온도를 예측하여 플랜트에서 처리하는 제품 혹은 원료의 종류나 성분에 따라 플랜트의 구간별 분위기 온도나 제품 혹은 원료의 이동 속도를 효과적으로 예측 제어하여 고품질의 제품을 생산하는데 기여할 수 있다.
- [0034] 게다가, 본 개시에 의하면, 입력-출력 데이터를 충분히 확보할 수 있는 경우에 관련 플랜트들이나 공정들에 범용적으로 사용가능한 새로운 구조의 인공지능망 기반 혹은 학습 기반의 예측 제어 기술을 제공할 수 있다.

도면의 간단한 설명

- [0035] 도 1은 본 개시의 실시예에 따른 인공지능망 기반 소둔로 예측 제어 장치를 설명하기 위한 개략도이다.
- 도 2는 도 1의 소둔로 예측 제어 장치로 예측 제어할 수 있는 소둔로에 대한 개략적인 블록도이다.
- 도 3은 도 1의 소둔로 예측 제어 장치에 채용할 수 있는 인공지능망 기반 예측 모델에 대한 모식도이다.
- 도 4는 도 1의 소둔로 예측 제어 장치에 채용할 수 있는 또 다른 인공지능망 기반 예측 모델에 대한 모식도이다.
- 도 5는 도 1의 인공지능망 기반 소둔로 예측 제어 장치의 학습 구조에 대한 예시도이다.
- 도 6은 본 개시의 다른 실시예에 따른 인공지능망 기반 소둔로 예측 제어 장치의 제어 과정을 설명하기 위한 모식도이다.
- 도 7은 본 개시의 또 다른 실시예에 따른 인공지능망 기반 소둔로 예측 제어 방법에 대한 흐름도이다.
- 도 8은 도 6의 인공지능망 기반 소둔로 예측 장치의 성능 검증 결과를 설명하기 위한 그래프이다.
- 도 9는 도 6의 인공지능망 기반 소둔로 예측 장치와 비교예들의 성능 검증 결과들을 나타낸 그래프이다.
- 도 10은 본 개시의 또 다른 실시예에 따른 인공지능망 기반 소둔로 예측 제어 장치에 채용할 수 있는 장치 구조에 대한 개략적으로 블록도이다.

발명을 실시하기 위한 구체적인 내용

- [0036] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다. 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.
- [0037] 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, 유

사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다. 및/또는 이라는 용어는 복수의 관련된 기재된 항목들의 조합 또는 복수의 관련된 기재된 항목들 중의 어느 항목을 포함한다.

- [0038] 본 출원의 실시예들에서, 'A 및 B 중에서 적어도 하나'는 'A 또는 B 중에서 적어도 하나' 또는 'A 및 B 중 하나 이상의 조합들 중에서 적어도 하나'를 의미할 수 있다. 또한, 본 출원의 실시예들에서, 'A 및 B 중에서 하나 이상'은 'A 또는 B 중에서 하나 이상' 또는 'A 및 B 중 하나 이상의 조합들 중에서 하나 이상'을 의미할 수 있다.
- [0039] 어떤 구성요소가 다른 구성요소에 '연결되어' 있다거나 '접속되어' 있다고 언급된 때에는, 그 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성요소가 다른 구성요소에 '직접 연결되어' 있다거나 '직접 접속되어' 있다고 언급된 때에는, 중간에 다른 구성요소가 존재하지 않는 것으로 이해되어야 할 것이다.
- [0040] 본 출원에서 사용한 용어는 단지 특정한 실시예를 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, '포함한다' 또는 '가진다' 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.
- [0041] 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 가진 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.
- [0042] 이하, 첨부한 도면들을 참조하여, 본 발명의 바람직한 실시예를 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.
- [0043] 도 1은 본 개시의 일실시예에 따른 인공신경망 기반 소둔로 예측 제어 장치를 설명하기 위한 개략도이다.
- [0044] 도 1을 참조하면, 인공신경망 기반 소둔로 예측 제어 장치는 소둔로(Annealing Furnace, 200) 등의 플랜트의 동작을 제어하기 위한 신경망 모델 예측 컨트롤러(Neural Network Model Predictive Controller, 100)를 포함한다.
- [0045] 소둔로(200)는 조업 목표 온도에 도달하기 위해 응답 시간 전에 미리 적절한 제어 입력을 결정해야 하는 제어 시스템에 의해 그 동작이 제어되는 플랜트의 일종일 수 있다. 즉, 소둔 공정은 철강을 목표 온도까지 가열한 후 목표 온도를 정확하게 일정 시간동안 유지하는 공정이다. 이러한 열처리 공정은 제어 입력을 변화시켰을 때 목표의 온도가 변하기까지 상대적으로 시간이 오래 걸리기 때문에 단순 피드백 제어로는 온도 유지 성능이 떨어진 다. 따라서 소둔로(200) 등의 플랜트에서 보다 정확한 온도 제어를 위해 제어 입력의 변화에 대해 출력이 어떻게 변할지 미리 예측하는 것이 필요하다.
- [0046] 신경망 MPC(100)는 학습 데이터 및/또는 예측 모델을 기반으로 입력에 대한 출력 변화를 예측하는 모델 예측 제어(Model Predictive Control)를 수행하는 장치이다. 신경망 MPC(100)는 협의의 측면에서 인공신경망 기반 소둔로 예측 제어 장치로서 간략히 '소둔로 예측 제어 장치'나 '예측 제어 장치'(100)로 지칭될 수 있다.
- [0047] 예측 제어 장치(100)는 출력 목표값(r)과 미리 스케줄되어 있거나 현재 시점에서 기저장되어 있거나 획득가능한 입력값들 $[U_s(k)]$ 을 포함하는 입력 시퀀스(input sequence)를 입력으로 받고 입력 시퀀스를 사전 학습된 인공신경망을 통해 처리하고, 처리 결과로서 제어 입력 $[U_c(k)]$ 을 출력할 수 있다. 출력되는 제어 입력 $[U_c(k)]$ 은 소둔기(200)의 입력으로 사용되거나, 또는 소둔기(200)에 구비되어 소둔기(200)의 전자적인 신호의 입출력을 담당하는 동작 제어 모듈의 입력으로 사용될 수 있다.
- [0048] 도 2는 도 1의 소둔로 예측 제어 장치로 예측 제어할 수 있는 소둔로에 대한 개략적인 블록도이다.
- [0049] 도 2를 참조하면, 소둔로(200)는 연속적으로 용접된 긴 철판(Strip, 270)을 목표 온도까지 가열하는 플랜트이다. 철판(270)은 소둔로 내부를 위아래로 진행하면서 방사열관(Radiant tube, 250)에 의해 목표 온도까지 가열된다. 방사열관(250)으로 공급되는 연료량을 제어하여 소둔로 내부의 분위기 온도를 소정 구간들(Zone 1, Zone 2, ..., Zone 7, Zone 8)에서 각각 독립적으로 제어할 수 있으며 이러한 소둔로(200) 내부의 분위기 온

도에 의해 철판(270)이 가열된다.

- [0050] 또한, 소둔로(200)의 하우징(200h) 내 디플렉션 롤(Deflection roll, 240)의 회전에 의해 철판(270)이 이동하기 때문에 디플렉션 롤(240)의 회전 속도를 제어하여 철판(270)의 이동 속도를 제어할 수 있다. 소둔로 내부의 분위기 온도는 각 구간(Zone) 별로 설치된 온도 센서들(210, 220, 230) 예컨대, 파이로미터들(Pyrometers)을 통해 측정될 수 있다.
- [0051] 전술한 소둔로(200)의 고전적인 제어 방법 중 하나인 PID(Proportional-Integral-Differential) 제어는 소둔로의 물리 모델에 대한 자세한 정보 없이도 제어 기법을 적용할 수 있다. PID 제어의 기본은 출력값과 목표값의 오차의 미분, 적분, 비례값을 피드백해서 입력값으로 사용하는 것이다. 이러한 PID 제어는 단순히 목표 온도를 초과하면 연료량을 줄이고 목표 온도보다 낮으면 연료량을 키우는 제어 방식으로 동작하므로, 복잡한 모델 정보를 모르더라도 간단하게 적용할 수 있다.
- [0052] 물리 모델은 목표로 하는 모델을 상태방정식을 통해 수식으로 나타낸 것을 말한다. 상태방정식을 구축하기 위해서는 대상 플랜트의 모든 정보가 필요하다. 이러한 정보는 구조와 재료뿐만 아니라 온도와 같은 상태 정보도 포함한다. 물리 모델을 구축하는 경우, 입력값의 변화에 따라 플랜트에서의 출력의 변화를 과거부터 미래까지 확인할 수 있다. 따라서 정확한 물리 모델을 구축할 수 있다면 단순 PID 제어가 아닌 미래 예측을 통해 플랜트를 미리 제어하는 제어 기법을 적용할 수 있다.
- [0053] 한편, 최근 철강 분야에서는 철강 종류의 다변화로 인해 서로 다른 종류의 철강들을 붙여 연속 조업하는 경우가 많아졌다. 그런데, 서로 다른 종류의 철강들을 용접하여 연속 조업하는 경우, 연속하여 배치된 철강들의 목표 온도가 서로 다를 수 있다. 이 경우, 소둔 공정 중의 철강에서 이종 철강들의 용접점이나 접합 부위, 용접 부위 또는 연결 부위에서 목표 온도를 정확하면서 신속하게 변경할 필요가 있다. 하지만, 소둔로의 특성상 소둔로 내부의 여러 구간들 중 특정 구간에서 온도를 즉각적으로 바꿀 수 없다. 따라서, 철강을 목표 온도까지 가열하는데 걸리는 시간을 조업자가 미리 예측하여 용접 부위에서 철강의 종류가 변경되기 전에 용접 부위가 위치한 소둔로 내부 구간(zone)의 분위기 온도를 미리 적절하게 변경해야 할 필요가 있다. 그런데, 종래 기술에서는 온도 예측 과정을 조업자의 경험에 의존하고 있기 때문에 상대적으로 정확하지 않고, 정확하지 않은 제어는 결국 철강의 품질을 하락시키는 원인이 되기 때문에, 소둔로 내부의 구간별 분위기 온도에 대한 더욱 정확한 제어를 위해 새로운 예측 제어 방안이 필요하다.
- [0054] 이에 본 실시예에서는 예측 제어 장치(100)가 예측 모델과 조업 데이터를 사용하여 사전에 학습되도록 구성으로써, 미래출력제어수 후의 소둔로로의 제어 입력에 대한 계산을 효과적으로 수행하여 소둔로에 대한 보다 정확한 온도 제어를 수행할 수 있다.
- [0055] 한편, 예측 제어를 위한 예측 모델을 구축하기 위해서는 제어 대상 시스템, 소둔로 또는 플랜트에 대한 조업 데이터 등의 많은 정보가 필요하기 때문에 상대적으로 더 크고 복잡한 제어 대상일수록 예측 모델을 구축하기가 어렵다.
- [0056] 소둔로의 경우, 플랜트의 크기가 클 뿐만 아니라 다양한 부품으로 구성되어 있다. 또한 물리 모델의 정확도를 높이기 위해서는 소둔로 내부의 온도와 같은 변수를 실시간으로 측정할 필요가 있다. 하지만 고온의 소둔로 내부 환경과 크기를 고려할 때 충분한 수의 센서를 설치하는 것은 어렵다. 게다가 복잡한 물리 모델을 구축하더라도 충분한 정확도를 확보하지 못할 수 있다. 아울러, 정확하지 못한 예측 모델을 기반으로 예측 제어를 수행하면 제어의 정확도 또한 하락하게 된다. 따라서 소둔로 분야에서 물리 모델을 사용한 예측 제어를 적용하는 것은 쉽지 않다.
- [0057] 이에 본 실시예에서는 소둔로 제어 정확도를 높이기 위해 인공지능망을 활용한 소둔로 예측 제어 알고리즘을 제공한다. 즉, 소둔로 예측 제어 알고리즘은 인공지능망 기반 예측 모델로 예측 제어 장치를 학습시켜 예측 성능을 높이고 이를 통해 소둔 공정 자동화에 기여할 수 있다.
- [0058] 다시 말해서, 기존의 소둔로 제어 시스템 대부분은 소둔로의 온도 제어를 위하여 조업자의 판단에 의해 제어 입력을 결정하는 방식으로서 정밀한 계산을 바탕으로 동작하는 것이 아니기 때문에 상대적으로 온도 제어에 있어 부정확한 성능을 나타내지만, 본 실시예에서는 예측 모델을 통해 얻어지는 제어 입력 즉, 목표 온도를 사용하여 소둔로의 각 구간에서 철강이 보다 정확한 온도에서 가열되도록 소둔로 내부 분위기 온도를 효과적으로 예측 제어할 수 있다.
- [0059] 도 3은 도 1의 소둔로 예측 제어 장치에 채용할 수 있는 인공지능망 기반 예측 모델에 대한 모식도이다.

- [0060] 도 3을 참조하면, 예측 모델(300m)은 체인 구조로 배치되는 복수의 모듈들(310)을 구비한다. 각 모듈(310)은 인공신경망 셀, 신경망 유닛 등으로 지칭될 수 있다. 예측 모델(300m)은 단방향 또는 양방향 인공신경망 구조를 구비할 수 있다.
- [0061] 또한, 예측 모델(300m)은 시계열 입력 데이터 기반으로 시계열 예측 결과를 출력하는 구조를 가지는, 인공신경망 기반의 LSTM(Long Short-term Memory), 어텐션(Attention) 구비 순환신경망(Recurrent Neural Network, RNN), 그리드(Grid) LSTM, 게이트 순환 유닛(Gated Recurrent Unit, GRU), 깊이 게이트 LSTM(Depth-Gated LSTM) 등으로 구현될 수 있다.
- [0062] LSTM은 시계열 데이터를 주로 처리하는 인공신경망의 일종이다. 또한, LSTM은 장기 기억(Long-term Memory)와 단기 기억(Short-term Memory)으로 구성된다. LSTM은 오래된 입력에 대해 중요도를 판단하여 기억할지 혹은 잊을지를 선택하여 장기 기억으로 출력할 것인지 단기 기억으로 출력할 것인지 정할 수 있다. 따라서 LSTM에서 불필요한 입력은 출력에 영향을 미치지 못하도록 빠르게 제거되고, 필요한 입력은 출력에 영향을 미치도록 기억된다. 이러한 구조로 인해 LSTM은 긴 길이의 시계열 입력을 학습하는데 특화된 인공신경망 구조이다. 소둔로의 경우, 시스템 응답 시간이 매우 긴 열역학적 시스템이기 때문에 현재 상태를 알기 위해서는 긴 길이의 과거 시계열 데이터가 필요하다. 따라서 긴 시계열 데이터의 특성을 학습하는 데 특화된 LSTM 구조나 이와 유사한 구조의 인공신경망을 사용하여 예측 모델을 구성할 수 있다.
- [0063] 예측 모델(100m)이 LSTM으로 형성되는 경우, 인공신경망 기반 예측 모델(300m)의 구조는 도 3에 나타난 바와 같다. 예측 모델(300m)의 각 모듈(310)은 LSTM 셀로 지칭될 수 있다. 예측 모델(300m)의 LSTM 셀들은 각 시점의 정보를 저장하고 출력할 수 있다. 특정 LSTM 셀에서 구해진 상태값은 체인 구조의 바로 다음에 위치하는 다음 LSTM 셀로 전달된다.
- [0064] 예측 모델(300m)에서 현재 시점을 k 라고 할 때, u 는 입력값을 의미하고 y 는 출력값을 의미한다. 즉, 예측 모델(300m)의 입력은 미리 정해진 관측 시간(Observation time) 동안의 수십 개 내지 수백 개 이상의 입력값들로 이루어진 제1 시계열 입력 데이터일 수 있다. 또한, 예측 모델(300m)의 입력은 예측 시간(Prediction time) 동안의 제1 시계열 입력 데이터와 관련되도록 체인 구조의 인공신경망 셀들의 후단에 위치하는 일부 인공신경망 셀들로 을 통해 계산되거나 처리되도록 입력되는 제2 시계열 입력 데이터를 포함할 수 있다. 그리고, 예측 모델(300m)의 출력은 미리 정해진 예측 시간(Prediction time) 동안 하나의 출력값이나 수백 개 이상의 출력값들을 포함할 수 있다.
- [0065] 본 실시예에서 입력값(u)은 $k-1$ 번째에서 $k-1$ 번째까지의 L 개의 제1 입력값들[$u(k-1)$ 내지 $u(k-1)$]과 k 번째에서 $k+h-1$ 번째까지의 H 개의 제2 입력값들[$u(k)$ 내지 $u(k+h-1)$]을 포함하고, 출력값(y)은 $k+1$ 번째에서 $k+h$ 번째까지의 H 개의 출력값들[$y(k+1)$ 내지 $y(k+h)$]을 가질 수 있다. L 과 H 는 2 이상의 임의의 자연수로서 동일하거나 서로 다른 값일 수 있다.
- [0066] 즉, 입력값(u)은 과거 입력에 대응하는 제1 입력값들과 예측 시간 동안 시간의 흐름에 따라 현재 시점의 입력들로부터 생성되는 제2 입력값들을 포함할 수 있다.
- [0067] 예측 모델(300m)의 LSTM 셀들(310) 중 앞단의 L 개의 제1 LSTM 셀들(f_1 내지 f_{L-1})은 관측 시간 동안 $k-1$ 번째 시점에서 $k-1$ 번째 시점까지의 L 개의 시점의 입력값들[$u(k-1)$ 내지 $u(k-1)$]을 각각 받을 수 있다. 그리고, LSTM 셀들(310) 중 뒷단의 H 개의 제2 LSTM 셀들(f_1 내지 f_{L+H-1})은 예측 시간(Prediction time) 동안 k 번째 시점(또는 현재 시점)에서 $k+h-1$ 번째 시점까지의 H 개의 출력값들[$y(k+1)$ 내지 $y(k+h)$]을 각각 출력할 수 있다.
- [0068] 또한, 예측 모델(100m)의 일부 복수의 LSTM 셀들(f_1, \dots, f_{L-1})은 과거 입력[$u(k-1)$ 내지 $u(k-1)$](‘과거 입력값’이라고도 한다)을 받아 과거 상태(h, c)에 대한 값(‘과거 상태값’이라고도 한다)을 계산할 수 있다. 또한, 예측 모델(300m)의 나머지 일부의 복수의 LSTM 셀들(f_1, \dots, f_{L+H-1})은 과거 입력값과 관련되는 현재 입력값[$u(k)$]과, 과거 입력값과 현재 입력값과 관련되는 미래 입력값들[$u(k)$ 내지 $u(k+h-1)$]을 입력으로 받고 예측 시간 동안의 과거 입력값과 현재 입력값과 미래 입력값들에 기초한 상태 값(‘미래 상태값’이라고도 한다)을 계산할 수 있다.
- [0069] 이러한 계산/저장 및 전달 과정을 순차적으로 반복하면, 예측 모델(300m)의 나머지 일부의 복수의 LSTM 셀들(f_1, \dots, f_{L+H-1})은 적어도 하나의 미래 출력값(y)을 예측하여 출력할 수 있다.
- [0070] 미래 출력값(y)은 예측 모델(300m)의 뒷단의 LSTM 셀들(f_1, \dots, f_{L+H-1}) 각각으로부터 출력되는 미래 출력값들[$y(k+1), \dots, y(k+h)$]을 포함할 수 있다. 또한, 미래 출력값(y)은 예측 모델(300m)의 뒷단의 LSTM 셀들($f_1, \dots,$

f_{1+h-1}) 중 적어도 하나로부터 출력되는 적어도 하나의 미래 출력값을 포함하도록 설정될 수 있다. 이와 같이, 미래 출력값은 예측 시간 동안 예측 모델(300m)의 뒷단에 위치하는 LSTM 셀들의 개수와 동일하거나 그보다 작은 개수만큼 생성될 수 있다.

- [0071] 또한, 예측 시간은 소문로 또는 소문로의 동작을 직접 제어하기 위한 동작 제어 모듈의 응답 시간을 고려하여 정해질 수 있다. 예측 모델(300m)에서는 현재의 제어 입력의 변화가 출력값에 영향을 미치는 것을 분석하기 위해 플랜트제어 시스템의 응답 시간을 고려하여 상대적으로 충분한 길이의 예측 시간을 설정할 수 있다.
- [0072] 예를 들어, 관측 시간이 2000초이고, 예측 시간이 2000초이며, LSTM 셀들 간의 처리 시간 간격이 5초라고 하면, 예측 모델(100m)은 800개의 LSTM 셀들로 이루어지는 체인 구조를 가질 수 있다. 이 경우, 예측 시간은 약 34분이 될 수 있다. 이와 같이, 예측 시간은 수 분 내지 수십 분에서 선택되는 어느 특정 시간을 포함할 수 있다.
- [0073] 전술한 예측 모델(300m)에 의하면, 관측 시간만큼의 과거 입력 정보 즉, 과거 입력값들에 의해 소문로의 현재 상태 및 미래 상태를 결정할 수 있고, 이에 의해 현재시점부터 수분 내지 수십분 후의 미래시점까지의 제어 입력을 결정할 수 있다.
- [0074] 한편, 본 실시예에서 예측 모델(300m)을 통해 미리 설정된 관측 시간 동안의 복수의 과거 입력값들로부터 그 개수에 대응하는 미래 출력값들을 얻는 것으로 한정되지 않고, 복수의 과거 입력값들보다 작은 개수의 미래 출력값들을 얻도록 구성될 수 있다. 물론, 본 실시예에서 예측 모델(300m)은 복수의 과거 입력값들로부터 특정 시점에 대해 예측된 하나의 미래 출력값을 얻도록 구성될 수 있다.
- [0075] 참고로, LSTM 셀은, 이미 잘 알려지 바와 같이, 반복 모듈로 지칭될 수 있고, 4개의 레이어들을 구비하고, 4개의 레이어들이 서로 정보를 주고받는 구조로 구성될 수 있다. LSTM 셀의 상태(state)는, 입력 또는 출력 측에서 볼 때, 크게 2개의 벡터들 즉, 단기 상태를 나타내는 제1 벡터(h_t)와 장기 상태를 나타내는 제2 벡터(c_t)로 나누어질 수 있다. 즉, 도 3을 참조하면, 제1 벡터는 각 LSTM 셀에서 나오는 특정 벡터들(h_1, h_{1-1}, h_1 참조)에 대응되고, 제2 벡터는 각 LSTM 셀에서 나오는 다른 특정 벡터들(c_1, c_{1-1}, c_1 참조)에 대응될 수 있다.
- [0076] 또한, LSTM 셀은, 그 내부의 작동 상태 측면에서, 셀 스테이트(Cell state), 망각 게이트(Forget gate), 입력 게이트(Input gate), 셀 스테이트 업데이트(Cell state update), 및 출력 게이트(Output gate) 중 어느 하나의 상태로 구분될 수 있다.
- [0077] 여기서, 각 상태를 좀더 구체적으로 설명하면, 셀 스테이트(Cell state)는 각 LSTM 셀에서 덧셈 연산을 통해 LSTM 셀의 정보가 바뀌지 않고 그대로 흐르도록 기능할 수 있다. 망각 게이트(Forget gate)는 셀 스테이트에서 시그모이드 레이어(sigmoid layer)를 통해 어떤 정보를 버릴 것인지 정하도록 기능할 수 있다. 버릴 것으로 정해진 정보는 곱셈 연산을 통해 셀 스테이트에 전달될 수 있다.
- [0078] 입력 게이트(Input gate)는 앞으로 들어오는 새로운 정보 중 어떤 것을 셀 스테이트에 저장할 것인지를 정하도록 기능할 수 있다. 입력 게이트(Input gate)는 먼저 시그모이드 레이어를 거쳐 어떤 값을 업데이트할 것인지를 정한 후 하이퍼볼릭 탄젠트(Hyperbolic Tangent, tanh) 레이어에서 새로운 후보 벡터를 생성하도록 기능할 수 있다.
- [0079] 셀 스테이트 업데이트(Cell state update)는, 이전 입력 게이트에서 정해진 버릴 정보들과 업데이트할 정보에 따라 셀 스테이트에 더해질 업데이트를 처리하도록 기능할 수 있다. 그리고, 출력 게이트(Output gate)는 어떤 정보를 출력으로 내보낼지를 정하도록 기능할 수 있다. 출력 게이트는 먼저 시그모이드 레이어에 입력 데이터를 넣어 출력 정보를 정한 후 셀 스테이트를 하이퍼볼릭 탄젠트 레이어에 넣어 시그모이드 레이어의 출력과 곱하여 출력으로 내보내도록 동작할 수 있다.
- [0080] 도 4는 도 1의 소문로 예측 제어 장치에 채용할 수 있는 또 다른 인공지능망 기반 예측 모델에 대한 모식도이다.
- [0081] 도 4를 참조하면, 예측 모델(300m)은 제1 인공지능망 층과 제1 인공지능망 층에 중첩되는 제2 인공지능망 층을 가진 2층 구조를 구비할 수 있다.
- [0082] 제1 인공지능망 층에 구비되는 L개와 H개를 더한 개수의 제1 인공지능망 셀들($f_1, \dots, f_1, \dots, f_{1+h-1}$) 각각은 LSTM 셀일 수 있으나, 이에 한정되지는 않는다. 이와 유사하게, 제2 인공지능망 층에 구비되는 H개의 제2 인공지능망 셀들(g_1, \dots, g_h) 각각은 LSTM 셀일 수 있으나, 이에 한정되지는 않는다. 제1 인공지능망 층의 제1 인공지능망 셀

들($f_1, \dots, f_1, \dots, f_{1+h-1}$)과 제2 인공신경망 셀들(g_1, \dots, g_h) 각각은 각 시점의 정보를 저장하고 출력할 수 있다.

- [0083] 소둔로의 현재 상태는 과거 입력값에 의해 결정된다. 따라서 예측 시간(Observation time) 만큼의 과거 입력 정보를 필요로 한다. 제1 인공신경망 셀들($f_1, \dots, f_1, \dots, f_{1+h-1}$) 중 앞단의 제1 인공신경망 셀들(f_1, \dots, f_{1-1})은 과거 입력값을 입력으로 사용하여 과거 상태(h_1 내지 h_{1-1} , c_1 내지 c_{1-1}) 값들을 구해 다음 셀로 전달할 수 있다.
- [0084] 또한, 제1 인공신경망 셀들($f_1, \dots, f_1, \dots, f_{1+h-1}$) 중 뒷단의 제1 인공신경망 셀들(f_1, \dots, f_{1+h-1})은 현재 및 미래 입력값을 입력으로 사용하여 미래 상태(h_1 내지 h_{1+h-1} , c_1 내지 c_{1+h-1}) 값들을 구해 다음 셀로 전달할 수 있다. 그리고, 제1 인공신경망 셀들(f_1, \dots, f_{1+h-1})의 미래 상태(h_1 내지 h_{1+h-1} , c_1 내지 c_{1+h-1}) 값들은 제2 인공신경망 셀들(g_1, \dots, g_{1+h})의 입력으로 사용되고, 이에 의해 제2 인공신경망 셀들(g_1, \dots, g_h)은 예측 시간동안 도 3의 예측 모델(300m)보다 1층 더 깊게 예측된 미래 출력값들 [$y(k+1), \dots, y(k+h)$]을 출력할 수 있다.
- [0085] 미래 출력값들은 예측 시간만큼 예측되며, 이러한 예측 시간은 시스템의 응답 시간을 고려하여 정해질 수 있다. 그것은 현재의 제어 입력의 변화가 출력값에 영향을 미치는 것을 분석하기 위해 충분한 길이의 예측 시간이 필요하기 때문이다. 이와 같이, 예측 모델(300n)에 의하면, 과거 입력값들을 입력으로 사용하여 적어도 하나의 미래 출력값을 예측할 수 있는 예측 모델을 제공할 수 있다. 특히 예측 모델은 소둔로 등의 예측 제어 대상인 플랜트의 종류, 크기 등에 따라 최적화된 인공신경망의 깊이를 결정하도록 구성될 수 있다.
- [0086] 소둔로의 경우, 인공신경망 기반 예측 모델(300n)의 구조적 깊이는 2층인 것이 바람직하나, 이에 한정되지 않고, 소둔로의 크기가 소정의 크기보다 더 커지는 경우, 2층 이상의 다층 구조의 인공신경망들의 미래 출력값들에 있어서 최적의 예측 신뢰도를 가진 구조를 선택하도록 구성될 수 있다. 즉, 다층 구조의 예측 모델(300n)의 층 수는, 제어 대상 플랜트의 크기나 이에 대응하는 예측 시간의 길이나 시스템의 응답 속도에 따라 선택될 수 있다.
- [0087] 진술한 바와 같이, 예측 제어 장치를 설계하기 위해서는 온도 제어 타겟인 소둔로 등의 플랜트에 대한 예측 모델이 필요하다. 예컨대 종래 기술에서는 복잡한 소둔로의 모델을 정확하게 구축하는 물리 모델을 이용하므로 그 구현이 어렵거나 범용성이 크게 제한되는 한계가 있었다. 한편, 본 실시예에서는 데이터 기반 예측 모델을 이용하므로, 소둔로의 구조와 재질을 고려하지 않는 인공신경망 모델을 구축할 수 있다. 즉, 입력과 출력 데이터에 소둔로의 구조와 재질 등의 데이터가 내재되어 있기 때문에 입력과 출력 데이터를 학습하는 것을 통해, 소둔로 내부 구조를 모르더라도 입력에 대해 출력을 제공하는 인공신경망 모델을 효과적으로 구축할 수 있다. 또한 종래의 물리 모델을 이용하는 경우에는, 다른 소둔로에 적용하기 위해서 새롭게 모델을 다시 설계해야 하는 문제가 있지만, 본 실시예의 인공신경망 기반 예측 모델은 충분한 입력-출력 데이터만 확보된다면 모델 구조 변경 없이 다양한 소둔로에 쉽게 적용할 수 있는 장점이 있다.
- [0088] 도 5는 도 1의 인공신경망 기반 소둔로 예측 제어 장치의 학습 구조에 대한 예시도이다.
- [0089] 도 5를 참조하면, 본 실시예에 따른 인공신경망 기반 소둔로 예측 제어 장치(이하 간략히 '예측 제어 장치')(100)는 예측 모델(300)을 활용한 계산에 입각하여 출력 오차를 최소화하는 제어를 수행하도록 학습될 수 있다.
- [0090] 예측 모델(300)은 도 3 또는 도 4를 참조하여 앞서 설명한 예측모델들(300m, 300n) 중 어느 하나를 선택하여 사용할 수 있다. 그리고, 예측 제어 장치(100)의 학습에 이용할 수 있는 예측 모델(300)은 예측 제어 장치(100)와 실질적으로 동일한 인공신경망 구조를 포함하도록 구성될 수 있다. 다시 말해서, 예측 제어 장치(100)의 인공신경망 구조는 예측 모델(300)의 인공신경망 구조와 동일할 수 있다.
- [0091] 예측 모델(300)은 미리 학습된(Pre-trained) 상태로 고정하여 사용될 수 있다. 예측 제어 장치(100) 및 예측 모델(300)의 입력 데이터는 그 세부 항목으로서 소둔로 내부의 분위기 온도, 철강 종류, 철강 두께, 철강 너비, 철강 이동 속도를 포함할 수 있다.
- [0092] 예측 제어 장치(100)의 출력값으로는 소둔로 내부의 분위기 온도 제어 목표치(간략히 '온도 제어 목표치')와 철강 이동 속도가 설정될 수 있다. 학습 과정에서, 예측 모델(300)의 입력값은 크게 두 가지 종류로 구분될 수 있으며, 그 첫번째 입력값은 미리 스케줄되어 있거나 현 시점에 알고 있는 입력값들($u_{si,1}, u_{ci,1}, u_{si,h}$)이고, 그 두번째 입력값은 예측 제어 장치(100)가 결정한 현재부터 미래까지의 제어 입력($u_{ci,h}$)이다. 두번째 입력값은 비용 함수 계산 모듈(500)에 제공될 수 있다.

- [0093] 예측 모델(300)은 예측 제어 장치(100)가 생성한 입력값을 이용하여 출력 예측값(Y)을 예측할 수 있다.
- [0094] 학습 과정에서 예측 모델(300)이 단층 구조(도 3 참조)인 경우, 출력 예측값(Y)은 예측 모델(300)의 후단의 인공신경망 셀들로부터 출력되고 단기 상태 또는 히든 스테이트(Hidden state)를 나타내는 제1 벡터들(예를 들어, h_1 내지 h_{1+h-1} 로 표현할 수 있음)에 대응되는 미래 출력값들 [$y(k+1)$ 내지 $y(k+h)$]을 예측하기 위한 것일 수 있다.
- [0095] 학습 과정에서 예측 모델(300)이 다층 구조(도 4 참조)인 경우, 출력 예측값(Y)은 예측 모델(300)의 제2 인공신경망 셀들로부터 출력되고 단기 상태 또는 히든 스테이트(Hidden state)를 나타내는 벡터들이나 미래 출력값들 [$y(k+1)$ 내지 $y(k+h)$]을 예측하기 위한 것일 수 있다.
- [0096] 더욱이, 학습 과정에서, 비용함수 계산 모듈(500)에 의해, 예측 제어 장치(100)의 각 시점이나 각 제어 위치에서의 출력 목표값 [$r(k+1)$ 내지 $r(k+h)$]과 출력 예측값(Y)의 차이를 이용하여 비용함수를 계산한 후, 계산된 비용함수를 최소화하는 방향으로 인공신경망 기반 예측 제어 장치(100)를 학습할 수 있다.
- [0097] 학습 과정에서 예측 제어 장치(100), 예측 모델(300) 및 비용함수 계산 모듈(500)의 동작을 제어하기 위한 별도의 프로세서나 컨트롤러가 예측 제어 장치(100), 예측 모델(300) 및 비용함수 계산 모듈(500)에 연결될 수 있다. 이러한 별도의 프로세서나 컨트롤러 또는 이를 포함하는 장치는 예측 제어기 학습 장치로 지칭될 수 있고, 후술하는 장치(도 10의 1000 참조)의 구성을 구비할 수 있다.
- [0098] 학습이 완료된 예측 제어 장치(100)는 현재부터 미래제어출력수(Prediction horizon) 이내의 미래까지의 출력 오차를 최소화하는 제어 입력을 계산할 수 있다.
- [0099] 전술한 실시예에서 설명한 바와 같이, 종래 기술에서는 조업자의 감각에 의존하여 소둔로의 온도를 제어하기 때문에 최적화된 예측 제어를 수행하지 못할 뿐만 아니라 섬세한 예측 제어를 수행할 수 없는 한계가 있다. 또한 종래 기술에서는 조업자의 숙련도에 따라 생산되는 철강의 품질이 좌우되는 문제가 있다. 하지만, 본 실시예에 의하면, 인공신경망 기반 예측 제어 장치를 사용하여 과거 입력값들로부터 미래제어출력수 후의 제어를 위한 미래 출력값을 계산하고 이를 바탕으로 연속 조업에서도 일정한 품질의 철강을 생산할 수 있다.
- [0100] 도 6은 본 개시의 다른 실시예에 따른 인공신경망 기반 소둔로 예측 제어 장치의 제어 과정을 설명하기 위한 모식도이다.
- [0101] 도 6을 참조하면, 예측 제어 장치(100)는 적분 제어기(Integral controller, 600)와 결합될 수 있다. 이 경우, 예측 제어 장치(100)와 적분 제어기(600)는 광의의 측면에서 또 다른 예측 제어 장치(700)로 지칭될 수 있다. 여기서, 예측 제어 장치(100)는 다시 신경망 MPC(Neural network model predictive controller)로 지칭될 수 있고, 적분 제어기(600)는 피드백 제어기 또는 피드백 적분 제어기로 지칭될 수 있다.
- [0102] 예측 제어 장치(700)는, 소둔로(Annealing Furnace, 200)의 내부 분위기 온도를 제어하고 철강 이동 속도를 제어하기 위하여, 신경망 MPC(100)와 소둔로(200)에 미리 스케줄되어 있고 현재 시점에서 알고 있는 입력값 [$u_{si}(k)$]이 입력될 때 그리고 신경망 MPC(100)에 목표 제어치(r)가 입력될 때, 현재 결정된 제어 입력 [$u_{ci}(k)$]을 사용하여 소둔로(200)를 내부 분위기 온도와 철강 이동 속도를 제어할 수 있다.
- [0103] 상기의 입력값 [$u_{si}(k)$]과 제어 입력 [$u_{ci}(k)$]에 대한 소둔로(200)의 반응 결과(y_r)는 목표 제어치(r)에 뺄셈 연산될 수 있다. 소둔로(200)의 반응 결과(y_r)가 반영된 목표 제어치가 피드백 적분 제어기(600)로 입력되면, 이러한 입력에 기초하여, 피드백 적분 제어기(600)는 신경망 MPC(100)에서 소둔로(200)로 전달되는 제어 입력 [$u_{ci}(k)$]을 보정할 수 있다.
- [0104] 도 7은 본 개시의 또 다른 실시예에 따른 인공신경망 기반 소둔로 예측 제어 방법에 대한 흐름도이다.
- [0105] 도 7을 참조하면, 인공신경망 기반 소둔로 예측 제어 방법(이하 간략히 '예측 제어 방법')은 예측 제어 장치(도 6의 700 참조)에 의해 다음의 단계들을 수행하도록 구성될 수 있다.
- [0106] 먼저, 협의의 측면의 예측 제어 장치에 대응하는 신경망 MPC(도 6의 100 참조)는 소둔로의 현재 상태와 관련된 시계열 입력 데이터와 출력 목표값을 입력으로 받을 수 있다(S71).
- [0107] 다음, 신경망 MPC는 제어 대상인 소둔로에 최적화된 제어 입력을 계산할 수 있다(S73).
- [0108] 다음, 제어 입력과 시계열 입력 데이터를 소둔로에 입력하여 소둔로 출력 온도를 계산할 수 있다(S75). 본 과정

은, 실제 현장에 적용한 과정에 대응되고, 소둔로의 자리에 플랜트 시뮬레이터(Plant simulator)를 사용하면, 시뮬레이션 과정으로 사용할 수 있다. 시뮬레이션 과정에서는 소둔로 출력 온도를 계산하는 것 대신에 소둔로 시뮬레이터의 출력 예측값을 획득하도록 설정될 수 있다.

- [0109] 특히, 본 실시예에서는, 예를 들어 2층 구조의 소둔로 예측 제어 모델에서 최종 층(즉 제2층)의 인공신경망의 출력 개수는 입력 층(즉, 제1층)의 인공신경망의 입력 개수의 절반으로 정해져 한정되는 것이 아니라, 예측하고 싶은 길이 만큼으로 임의로 정해질 수 있다. 다시 말해서, 입력 층의 인공신경망의 입력 개수가 예측에 필요한 과거 데이터의 길이(관측 시간에 대응함)와 예측하고 싶은 길이(예측 시간에 대응함)로 정해질 때, 예측 시간이 관측 시간과 같은 것으로 한정되지 않고, 예측 시간에 대응하는 출력 개수가 제어 목적에 따라서 입력 개수의 절반보다 적거나 절반보다 많도록 유동적으로 변경될 수 있다.
- [0110] 다음, 소둔로 출력 온도에서 발생한 정상 상태 오차를 최소화하도록 피드백 적분 제어를 이용하여 제어 입력을 보정할 수 있다(S77). 즉, 적분 제어를 사용하여, 소둔로 출력 온도값과 목표 온도값 사이의 차이를 최소화하는 방향으로 제어 입력을 보정할 수 있다. 이러한 제어 과정을 통해 추가적으로 제어 오차를 줄일 수 있다.
- [0111] 도 8은 도 6의 인공신경망 기반 소둔로 예측 제어 장치의 성능 검증 결과를 설명하기 위한 그래프이다.
- [0112] 신경신경망 기반 소둔로 예측 제어 장치는 신경망 예측 모델과 실질적으로 동일한 인공신경망 구조와 예측 성능을 가질 수 있다.
- [0113] 도 8을 참조하면, 인공신경망 기반 예측 모델의 성능 검증 결과로서, 공정 데이터(Operational data)에 대한 신경망 예측 모델(Neural network predictive model)(본 실시예)의 검증 결과의 그래프가 실제 공정 데이터의 그래프와 매우 유사한 것을 알 수 있다. 즉, 성능 검증 결과에 대한 그래프들을 통해 실제 소둔로 조업 데이터와 비교하여 예측 모델의 성능이 떨어지지 않는 것을 확인할 수 있다.
- [0114] 신경망 시뮬레이터(Neural network simulator)로는 본 실시예의 예측 제어 장치의 시뮬레이션에 사용하는 소둔로 플랜트 모델이 사용되었다.
- [0115] 전체 검증 구간에 대한 MSE(mean squared error)를 통해 수치적으로 성능을 확인할 수 있다. 이는 수치가 작을수록 정확하다는 것을 보여주는 지표로, 신경망 기반 예측 모델은 6.35, 신경망 기반 시뮬레이터는 8.20의 MSE를 나타내었다.
- [0116] 실제 소둔로 조업에서 오차를 ± 10 °C 이내로 제어하는 것을 목표로 하는 점을 고려할 때, 본 실시예의 예측 모델이나 이러한 예측 모델로 사전 훈련되고 실질적으로 동일한 인공신경망 구조를 구비하는 예측 제어 장치는 충분한 예측 성능을 갖고 있다는 것을 확인할 수 있다.
- [0117] 도 9는 도 6의 인공신경망 기반 소둔로 예측 제어 장치와 비교예들의 성능 검증 결과들을 나타낸 그래프이다.
- [0118] 도 9를 참조하면, 점선으로 표시된 온도 제어 목표치를 기준으로 3가지 종류의 제어기의 제어 성능을 비교 검증한 결과를 확인할 수 있다.
- [0119] 파란 선으로 표시된 것은 본 실시예의 예측 제어 장치인 인공신경망 기반 예측 제어기(Neural network MPC)에 대한 제어 성능 검증 결과이다. 빨간 선으로 표시된 것은 제1 비교예의 선형 저차원 모델 예측 제어기(linear low-order MPC)에 대한 제어 성능 검증 결과이다. 제1 비교예는 비-인공신경망 기반의 예측 제어기의 일종에 해당한다. 그리고, 초록 선으로 표시된 것은 제2 비교예의 비례-적분(PI) 제어기에 대한 제어 성능 검증 결과이다. 제2 비교예는 예측 제어를 수행하지 않는 제어기에 해당한다.
- [0120] 이러한 세 가지의 제어기들의 제어 성능을 비교한 결과, 본 실시예의 예측 제어기가 상대적으로 우수한 성능을 나타내는 것을 확인할 수 있다.
- [0121] 예측 제어를 수행하지 않는 PI 제어기의 경우, 목표 변경 시점에 미리 대응하지 못하기 때문에 각 시점에서 온도 제어 목표치와 차이 및/또는 지연이 생기는 것을 확인할 수 있다.
- [0122] 한편, 예측 제어를 수행하는 본 실시예와 제1 비교예의 두 제어기들의 경우, 목표 변경 시점 이전에 미리 대응하여 오차를 줄이는 모습을 확인할 수 있다. 다만, 본 실시예의 인공신경망 기반 예측 제어기가 제1 비교예의 비-인공신경망 기반 예측 제어기에 비해 더 적은 오차로 안정적으로 제어 대상 시스템을 제어하는 것을 확인할 수 있다.
- [0123] 표 1은 전술한 세 가지 제어기들의 제어 성능을 수치적으로 나타낸 것이다.

표 1

	인공신경망 기반 예측 제어기	비-인공신경망 기반 예측 제어기	PI 제어기
MSE	3.10	3.54	8.68
±10℃이내 정확도 [%]	99.0	96.2	77.1

[0124]

[0125]

[0126]

[0127]

[0128]

[0129]

[0130]

[0131]

[0132]

[0133]

[0134]

[0135]

[0136]

표 1을 참조하면, 본 실시예의 인공신경망 기반 예측 제어기가 비교예들보다 더 낮은 오차를 갖고 더 높은 정확도를 보이는 것을 알 수 있다.

도 10은 본 개시의 또 다른 실시예에 따른 인공신경망 기반 소둔로 예측 제어 장치에 채용할 수 있는 구조에 대한 개략적으로 블록도이다.

본 실시예에서 예시하는 장치 구조는 예측 제어 장치 외에 예측 제어 장치를 학습시키는 예측 제어기 학습 장치에 대하여도 적용될 수 있다.

도 10을 참조하면, 예측 제어 장치(1000)는 적어도 하나의 프로세서(1100), 메모리(1200) 및 네트워크와 연결되어 통신을 수행하는 송수신 장치(1300)를 구비할 수 있다. 또한, 예측 제어 장치(1000)는 입력 인터페이스 장치(1400), 출력 인터페이스 장치(1500), 저장 장치(1600) 등을 더 구비할 수 있다. 예측 제어 장치(1000)에 구비되는 각각의 구성 요소들은 버스(bus, 1700)에 의해 연결되어 서로 통신을 수행할 수 있다.

다만, 예측 제어 장치(1000)에 포함된 각각의 구성요소들은 공통 버스(1700)가 아니라, 프로세서(1100)를 중심으로 개별 인터페이스 또는 개별 버스를 통하여 연결될 수 있다. 예를 들어, 프로세서(1100)는 메모리(1200), 송수신 장치(1300), 입력 인터페이스 장치(1400), 출력 인터페이스 장치(1500) 및 저장 장치(1600) 중에서 적어도 하나와 전용 인터페이스를 통하여 연결될 수 있다.

프로세서(1100)는 메모리(1200) 및 저장 장치(1600) 중에서 적어도 하나에 저장된 프로그램 명령(program command)을 실행할 수 있다. 프로세서(1100)는 중앙 처리 장치(central processing unit, CPU), 그래픽 처리 장치(graphics processing unit, GPU), 또는 본 발명의 실시예들에 따른 방법들이 수행되는 전용의 프로세서를 의미할 수 있다.

메모리(1200) 및 저장 장치(1600) 각각은 휘발성 저장 매체 및 비휘발성 저장 매체 중에서 적어도 하나로 구성될 수 있다. 예를 들어, 메모리(1200)는 읽기 전용 메모리(read only memory, ROM) 및 랜덤 액세스 메모리(random access memory, RAM) 중에서 적어도 하나로 구성될 수 있다.

송수신 장치(1300)는 근거리 무선 네트워크나 케이블 연결, 위성과의 통신, 이동통신 기지국과의 통신 등을 위한 통신인터페이스 또는 서버통신시스템을 포함할 수 있다.

입력 인터페이스 장치(1400)는 키보드, 마이크, 터치패드, 터치스크린 등의 입력 수단들에서 선택되는 적어도 하나와 적어도 하나의 입력 수단을 통해 입력되는 신호를 기저장된 명령과 매핑하거나 처리하는 입력 신호 처리부를 포함할 수 있다.

출력 인터페이스 장치(1500)는 프로세서(1100)의 제어에 따라 출력되는 신호를 기저장된 신호 형태나 레벨로 매핑하거나 처리하는 출력 신호 처리부와, 출력 신호 처리부의 신호에 따라 진동, 빛 등의 형태로 신호나 정보를 출력하는 적어도 하나의 출력 수단을 포함할 수 있다. 적어도 하나의 출력 수단은 스피커, 디스플레이 장치, 프린터, 광 출력 장치, 진동 출력 장치 등의 출력 수단들에서 선택되는 적어도 하나를 포함할 수 있다.

전술한 본 실시예에 따른 방법들은 다양한 컴퓨터 수단을 통해 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 컴퓨터 판독 가능 매체에 기록되는 프로그램 명령은 본 발명을 위해 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다.


컴퓨터 판독 가능 매체의 예에는 롬(rom), 램(ram), 플래시 메모리(flash memory) 등과 같이 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러(compiler)에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터(interpreter) 등을 사용해서 컴퓨터에 의해 실행될 수 있는 고급 언어 코드를 포함한다. 상술한 하드웨어 장치는 본 발명의 동작을 수행하기 위해 적어도 하나의 소프트웨어 모듈로 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.

[0137]


이상 실시예를 참조하여 설명하였지만, 해당 기술 분야의 숙련된 당업자는 하기의 특허 청구의 범위에 기재된 본 발명의 사상 및 영역으로부터 벗어나지 않는 범위 내에서 본 발명을 다양하게 수정 및 변경시킬 수 있음을 이해할 수 있을 것이다.

도면

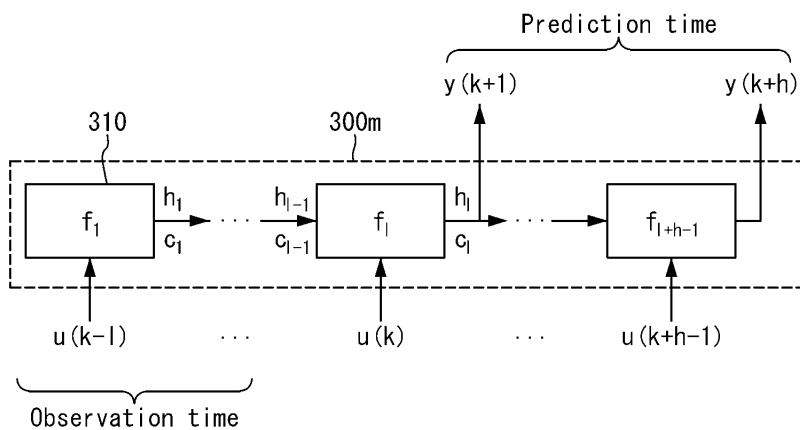
도면1



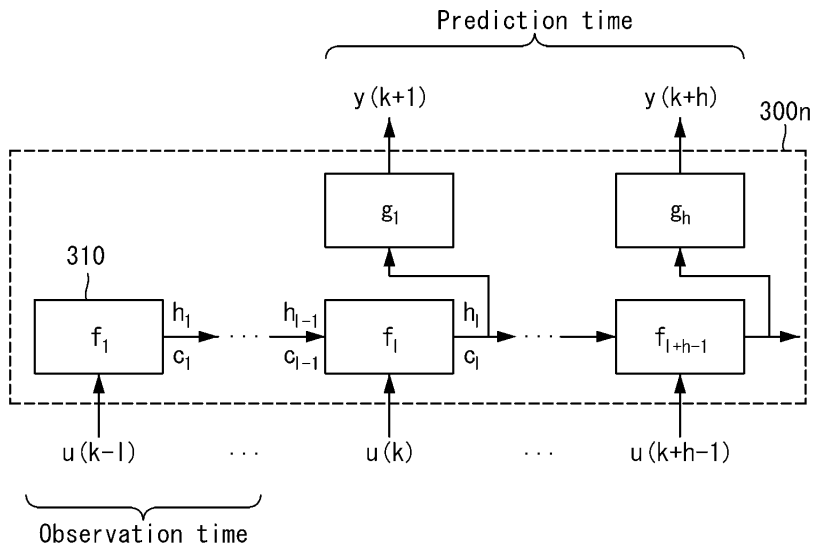
도면2



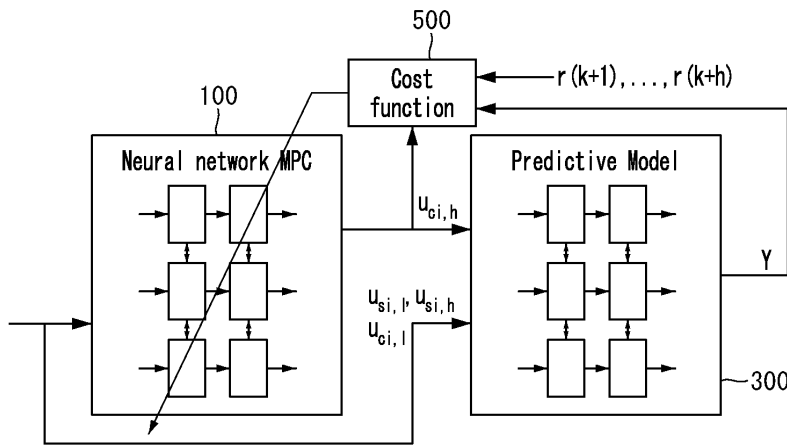
도면3



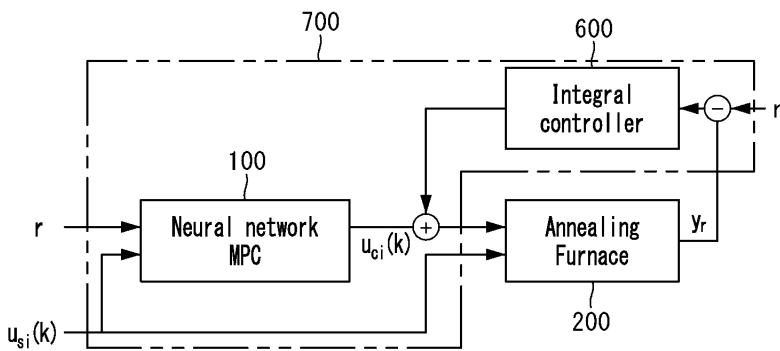
도면4



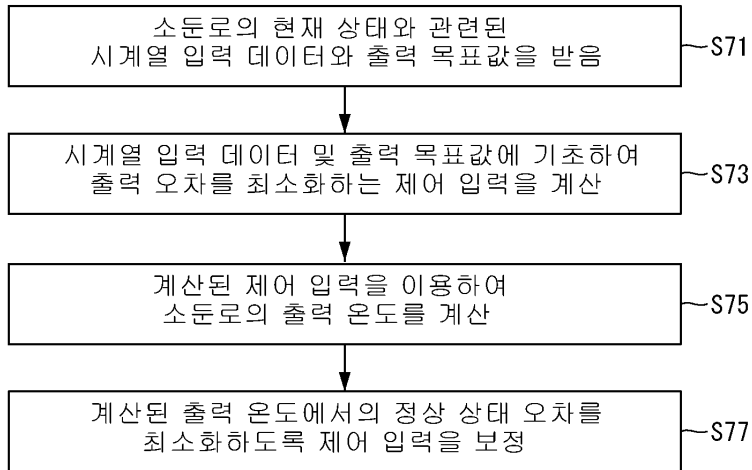
도면5




도면6




도면7



도면8



도면9



도면10

