(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0010194
(43) 공개일자 2021년01월27일

(51) 국제특허분류(Int. Cl.)
G01M 3/02 (2006.01) *F22B 37/42* (2006.01)
G06N 3/08 (2006.01) *G06Q 50/06* (2012.01)
G06Q 50/10 (2012.01)
(52) CPC특허분류
G01M 3/02 (2013.01)
F22B 37/421 (2013.01)
(21) 출원번호 10-2019-0087792
(22) 출원일자 2019년07월19일
심사청구일자 2019년07월19일

(71) 출원인
울산과학기술원
울산광역시 울주군 언양읍 유니스트길 50
한국동서발전(주)
울산광역시 중구 종가로 395(북정동)
(72) 발명자
최재식
울산광역시 울주군 언양읍 유니스트길 50
유보선
울산광역시 울주군 언양읍 유니스트길 50
(뒷면에 계속)
(74) 대리인
특허법인 무한

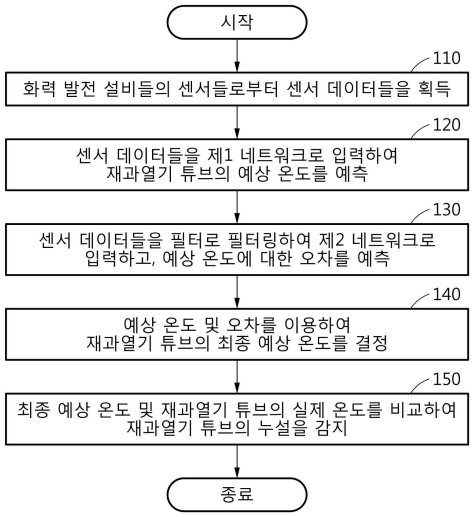
전체 청구항 수 : 총 15 항

(54) 발명의 명칭 **딥러닝 기반의 화력 발전소 재과열기 튜브의 누설 감지 방법 및 이를 수행하는 장치**

(57) 요 약

일 실시예에 따른 딥러닝 기반 재과열기 튜브의 누설 감지 방법은 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계; 센서 데이터들을 제1 네트워크로 입력하여 재과열기 튜브의 예상 온도를 예측하는 단계; 센서 데이터들을 제2 네트워크로 입력하고, 예상 온도에 대한 오차를 예측하는 단계; 예상 온도 및 오차를 이용하여 재과열기 튜브의 최종 예상 온도를 결정하는 단계; 및 최종 예상 온도 및 재과열기 튜브의 실제 온도를 비교하여 재과열기 튜브의 누설을 감지하는 단계를 포함한다.

대 표 도 - 도1



(52) CPC특허분류
G06N 3/08 (2013.01)
G06Q 50/06 (2013.01)
G06Q 50/10 (2013.01)
(72) 발명자
정해동
울산광역시 울주군 언양읍 유니스트길 50
김신
울산광역시 남구 돋질로261번길 32, 105동 306호(삼산동, 우성아파트)
유동근
충청남도 당진시 원당로 51-10, 108동 502호(원당동, 한라비발디아파트)
조정민
충청남도 당진시 석문면 해명3로 45-25, 114동 301호(파인빌)

명 세 서

청구범위

청구항 1

화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계;

상기 센서 데이터들을 제1 네트워크로 입력하여 재과열기 튜브의 예상 온도를 예측하는 단계;

상기 센서 데이터들을 제2 네트워크로 입력하고, 상기 예상 온도에 대한 오차를 예측하는 단계;

상기 예상 온도 및 상기 오차를 이용하여 상기 재과열기 튜브의 최종 예상 온도를 결정하는 단계; 및

상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계

를 포함하는,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 2

제1항에 있어서,

상기 제1 네트워크는,

완전 접속망(Fully connected network, FCN)이고,

상기 화력 발전 설비들의 센서 데이터들을 입력으로 상기 재과열기 튜브의 온도를 출력으로 학습되어 상기 화력 발전 설비들의 센서 데이터들 중 상기 재과열기 튜브의 온도에 영향을 미치는 데이터와의 관계를 모델링한 딥러닝 모델인,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 3

제1항에 있어서,

상기 제2 네트워크는,

컨볼루셔널 뉴럴 네트워크(Convolutional Neural Network, CNN)이고,

상기 제1 네트워크의 학습 과정에서 발생하는 상기 재과열기 튜브의 예상 온도의 오차를 학습한 모델인,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 4

제1항에 있어서,

상기 제2 네트워크의 컨볼루션 동작을 위한 필터의 제1 축은 시간이고,

상기 필터의 제2 축은 상기 센서 데이터들의 센싱 값이고,

상기 필터의 제3 축은 상기 센서 데이터들의 종류인,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 5

제1항에 있어서,

상기 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계는,

상기 화력 발전 설비들 각각에 대해서 특정 시간 구간에서 측정되는 시계열적인 상기 센서 데이터들로부터 특징을 추출하는 단계

를 포함하는,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 6

제1항에 있어서,

상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계는,

상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도가 미리 정해진 오차범위를 초과하는 경우, 상기 재과열기 튜브의 누설이 발생한 것으로 판단하는 단계

를 포함하는,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 7

제1항에 있어서,

상기 재과열기 튜브의 누설이 발생한 것으로 판단된 경우,

상기 화력 발전 설비들의 센서 데이터들, 상기 센서 데이터들 및 상기 실제 온도를 상기 제1 네트워크 또는 상기 제2 네트워크의 입력 및 출력으로 학습하는 단계

를 더 포함하는,

딥러닝 기반 재과열기 튜브의 누설 감지 방법.

청구항 8

하드웨어와 결합되어 제1항 내지 제7항 중 어느 하나의 항의 방법을 실행시키기 위하여 매체에 저장된 컴퓨터 프로그램.

청구항 9

딥러닝 기반 재과열기 튜브의 누설 감지 방법을 수행하기 위한 장치에 있어서,

하나 이상의 프로세서;

메모리; 및

상기 메모리에 저장되어 있으며 상기 하나 이상의 프로세서에 의하여 실행되도록 구성되는 하나 이상의 프로그

램을 포함하고,

상기 프로그램은,

화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계;

상기 센서 데이터들을 제1 네트워크로 입력하여 상기 재과열기 튜브의 예상 온도를 예측하는 단계;

상기 센서 데이터들을 제2 네트워크로 입력하고 상기 예상 온도에 대한 오차를 예측하는 단계;

상기 예상 온도 및 상기 오차를 이용하여 상기 재과열기 튜브의 최종 예상 온도를 결정하는 단계; 및

상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계

를 수행하는,

장치.

청구항 10

제9항에 있어서,

상기 제1 네트워크는,

완전 접속망(Fully connected network, FCN)이고,

상기 화력 발전 설비들의 센서 데이터들을 입력으로 상기 재과열기 튜브의 온도를 출력으로 학습되어 상기 화력 발전 설비들의 센서 데이터들 중 상기 재과열기 튜브의 온도에 영향을 미치는 데이터와의 관계를 모델링한 딥러닝 모델인,

장치.

청구항 11

제9항에 있어서,

상기 제2 네트워크는,

컨볼루션 뉴럴 네트워크(Convolution Neural Network, CNN)이고,

상기 제1 네트워크의 학습 과정에서 발생하는 상기 재과열기 튜브의 예상 온도의 오차를 학습한 모델인,

장치.

청구항 12

제9항에 있어서,

상기 제2 네트워크의 컨볼루션 동작을 위한 필터의 제1 축은 시간이고,

상기 필터의 제2 축은 상기 센서 데이터들의 센싱 값이고,

상기 필터의 제3 축은 상기 센서 데이터들의 종류인,

장치.

청구항 13

제9항에 있어서,

상기 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계에서,

상기 화력 발전 설비들 각각에 대해서 특정 시간 구간에서 측정되는 시계열적인 상기 센서 데이터들로부터 특징을 추출하는 단계

를 수행하는,

장치.

청구항 14

제9항에 있어서,

상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계에서,

상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도가 미리 정해진 오차범위를 초과하는 경우, 상기 재과열기 튜브의 누설이 발생한 것으로 판단하는 단계

를 수행하는,

장치.

청구항 15

제9항에 있어서,

상기 재과열기 튜브의 누설이 발생한 것으로 판단된 경우,

상기 화력 발전 설비들의 센서 데이터들, 상기 센서 데이터들 및 상기 실제 온도를 상기 제1 네트워크 또는 상기 제2 네트워크의 입력 및 출력으로 학습하는 단계

를 더 수행하는,

장치.

발명의 설명

기 술 분 야

[0001] 이하의 실시예는 딥러닝 기반의 화력 발전소 재과열기 튜브의 누설 감지 방법 및 이를 수행하는 장치에 관한 것이다.

배 경 기 술

[0003] 화력 발전 시스템에서 튜브 누설은 가장 빈번하게 발생하는 사고 사례 중 하나이며, 2차 피해를 유발하여 발전 설비에 대한 심각한 위협이 될 수 있다.

[0004] 또한, 튜브 누설에 의한 기동정지는 매우 큰 기회비용이 발생하기 때문에 보다 정확하고, 빠른 튜브 누설 검출 기술의 개발은 지속적으로 요구되고 있다.

[0005] 과거 화력 발전소의 고장 사례를 살펴보면, 2001~2017년, 당진 화력발전 1~9호기에 대한 고장 사례 총 110여 건 중, 튜브 누설 사례는 총 20여 건으로 전체 고장 사례에 약 20%가 재과열기 튜브와 관련이 있다.

[0006] 재과열기 튜브의 파열은 음향센서 기반의 BTLD 시스템(Boiler Tube Leak Detection System)이 유일한 검출 수단이나, 타 발전 설비 운영으로 인한 소음 등에 의해서 오작동이 빈번히 발생하여 제매장치 등 보일러 관련 기타 설비 운영 여건에 따라 매우 부정확한 검출 결과를 보이며, 작은 규모의 누설에 대한 정확한 검출을 기대하기 어렵다.

[0007] 더불어, 재과열기 튜브 파열로 인한 증기 및 튜브 표면의 비정상적 온도 및 압력 등에 대한 검출은 튜브 누설 진단에 필수적이다.

발명의 내용

해결하려는 과제

[0009] 실시예에 따른 발명은, 화력 발전소의 고장 시 재과열기 누설로 인한 고장을 미리 감지 하기 위해, 데이터베이스 체계를 구축하여 해당 데이터를 이용한 딥러닝 기반의 학습을 통해 미세한 균열에 대해서도 보다 정확한 고장을 감지하기 위한 것이다. 이를 통하여, 실시예들은 고장 원인을 조기 진단하고 차기 정비 시기를 예측하기 위한 방법을 제공할 수 있다.

과제의 해결 수단

[0011] 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계; 상기 센서 데이터들을 제1 네트워크로 입력하여 재과열기 튜브의 예상 온도를 예측하는 단계; 상기 센서 데이터들을 제2 네트워크로 입력하고, 상기 예상 온도에 대한 오차를 예측하는 단계; 상기 예상 온도 및 상기 오차를 이용하여 상기 재과열기 튜브의 최종 예상 온도를 결정하는 단계; 및 상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계를 포함하는, 딥러닝 기반 재과열기 튜브의 누설 감지 방법이 제공될 수 있다.

[0012] 상기 제1 네트워크는, 완전 접속망(Fully connected network, FCN)이고, 상기 화력 발전 설비들의 센서 데이터들을 입력으로 상기 재과열기 튜브의 온도를 출력으로 학습되어 상기 화력 발전 설비들의 센서 데이터들 중 상기 재과열기 튜브의 온도에 영향을 미치는 데이터와의 관계를 모델링한 딥러닝 모델일 수 있다.

[0013] 상기 제2 네트워크는, 컨볼루션 뉴럴 네트워크(Convolution Neural Network, CNN)이고, 상기 제1 네트워크의 학습 과정에서 발생하는 상기 재과열기 튜브의 예상 온도의 오차를 학습한 모델일 수 있다.

[0014] 상기 제2 네트워크의 컨볼루션 동작을 위한 필터의 제1 축은 시간이고, 상기 필터의 제2 축은 상기 센서 데이터들의 센싱 값이고, 상기 필터의 제3 축은 상기 센서 데이터들의 종류일 수 있다.

[0015] 상기 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계는, 상기 화력 발전 설비들 각각에 대해서 특정 시간 구간에서 측정되는 시계열적인 상기 센서 데이터들로부터 특징을 추출하는 단계를 포함할 수 있다.

[0016] 상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계는, 상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도가 미리 정해진 오차범위를 초과하는 경우, 상기 재과열기 튜브의 누설이 발생한 것으로 판단하는 단계를 포함할 수 있다.

[0017] 상기 재과열기 튜브의 누설이 발생한 것으로 판단된 경우, 상기 화력 발전 설비들의 센서 데이터들, 상기 센서 데이터들 및 상기 실제 온도를 상기 제1 네트워크 또는 상기 제2 네트워크의 입력 및 출력으로 학습하는 단계를 더 포함할 수 있다.

[0018] 딥러닝 기반 재과열기 튜브의 누설 감지 방법을 수행하기 위한 장치에 있어서, 하나 이상의 프로세서; 메모리; 및 상기 메모리에 저장되어 있으며 상기 하나 이상의 프로세서에 의하여 실행되도록 구성되는 하나 이상의 프로그램을 포함하고, 상기 프로그램은, 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득하는 단계; 상기 센서 데이터들을 제1 네트워크로 입력하여 상기 재과열기 튜브의 예상 온도를 예측하는 단계; 상기 센서 데이터들을 제2 네트워크로 입력하고 상기 예상 온도에 대한 오차를 예측하는 단계; 상기 예상 온도 및 상기 오차를 이용하여 상기 재과열기 튜브의 최종 예상 온도를 결정하는 단계; 및 상기 최종 예상 온도 및 상기 재과열기 튜브의 실제 온도를 비교하여 상기 재과열기 튜브의 누설을 감지하는 단계를 수행하는, 장치가 제공될 수 있다.

발명의 효과

[0020] 실시예에 따른 발명을 통해 화력 발전소의 고장 시 재과열기 누설로 인한 고장을 미리 감지 하기 위해, 데이터

베이스 체계를 구축하여 해당 데이터를 이용한 딥러닝 기반의 학습을 통해 고장 원인을 조기 진단하고 차기 정비 시기를 예측하기 위한 방법을 제공할 수 있다.

[0021] 더불어, 차기 정비 시기를 예측하여 고장을 사전에 예방하고, 고장 발 생시, 고장 원인을 자동적으로 분석하여, 고장으로 인한 인적, 물적 손실을 최소화하며, 발전설비 관리를 보다 효율적으로 수행할 수 있다.

도면의 간단한 설명

[0023] 도 1은 실시예에서, 딥러닝 기반 재과열기 튜브의 누설 감지 방법의 흐름도이다.

도 2는 실시예에서, 재과열기 튜브 온도 예측을 위해 딥러닝된 모델이다.

도 3은 실시예에서, 실제 수집되는 센서 데이터들을 도시한 그래프이다.

도 4는 실시예에서, 센서 데이터들을 정제한 형태를 도시한 그래프이다.

도 5는 실시예에서, 이코노마이저(Economizer)의 출력 및 예상 온도의 그래프 및 누적 오차 그래프이다.

도 6은 실시예에서, Division S/H의 입력 및 예상 온도의 그래프 및 누적 오차 그래프이다.

도 7은 실시예에서, Division S/H의 출력 및 예상 온도의 그래프 및 누적 오차 그래프이다.

도 8은 실시예에서, Final S/H의 출력 및 예상 온도의 그래프 및 누적 오차 그래프이다.

도 9는 실시예에서, Finish S/H의 메탈 온도 및 예상 온도의 그래프 및 누적 오차 그래프이다.

도 10은 실시예에서, CNN을 이용한 예상 온도의 그래프 및 누적 오차 그래프이다.

도 11은 실제 데이터 중 학습 데이터를 위한 데이터의 분류를 설명하기 위한 그래프이다.

도 12는 실시예에서, 재과열기 튜브의 누설로 인한 비정상적 온도를 검출하는 실시예를 설명하기 위한 그래프이다.

도 13은 실시예에서, 딥러닝 기반 재과열기 튜브의 누설 감지 방법을 수행하는 장치의 블록도이다.

발명을 실시하기 위한 구체적인 내용

[0024] 본 명세서에서 개시되어 있는 특정한 구조적 또는 기능적 설명들은 단지 기술적 개념에 따른 실시예들을 설명하기 위한 목적으로 예시된 것으로서, 실시예들은 다양한 다른 형태로 실시될 수 있으며 본 명세서에 설명된 실시예들에 한정되지 않는다.

[0025] 제1 또는 제2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 이런 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 이해되어야 한다. 예를 들어 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소는 제1 구성요소로도 명명될 수 있다.

[0026] 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. 구성요소들 간의 관계를 설명하는 표현들, 예를 들어 "~간의에"와 "바로~간의에" 또는 "~에 이웃하는"과 "~에 직접 이웃하는" 등도 마찬가지로 해석되어야 한다.

[0027] 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "포함하다" 또는 "가지다" 등의 용어는 설시된 특징, 숫자, 단계, 동작, 구성요소, 부분품 또는 이들을 조합한 것이 존재함으로 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.

[0028] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 해당 기술분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가진다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 갖는 것으로 해석되어야 하며, 본 명세서에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지

않는다.

[0029] 이하, 실시예들을 첨부된 도면을 참조하여 상세하게 설명한다. 각 도면에 제시된 동일한 참조 부호는 동일한 부재를 나타낸다.

[0030] 본 발명의 바람직한 실시예를 첨부된 도면을 참조하여 상세히 설명한다. 본 발명을 설명함에 있어, 관련된 공지 구성 또는 기능에 대한 구체적인 설명이 본 발명의 요지를 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명은 생략한다.

[0031] 그러나, 본 발명이 실시예에 의해 제한되거나 한정되는 것은 아니며, 각 도면에 제시된 동일한 참조 부호는 동일한 부재를 나타낸다.

[0033] 재과열기 튜브(보일러 튜브)를 통과하는 수증기는 튜브로부터 열을 흡수하여 냉각시키는 역할을 수행한다. 이러한 재과열기 튜브에서 누설이 발생하여 냉각이 제대로 수행되지 않는다면, 재과열기 튜브의 온도는 비정상적으로 상승할 수 있다. 이러한 튜브의 비정상적 온도 증가를 검출하여 보다 정확하고 빠른 튜브 누설을 검출하기 위한 방법을 제안한다.

[0035] 도 1은 실시예에서, 딥러닝 기반 재과열기 튜브의 누설 감지 방법의 흐름도이다.

[0036] 실시예에 따른 방법은 입력 변수와 관련하여 발전 설비 관련 주요 센서 태그들을 설정하고, 재과열기 튜브의 센서 태그와의 관계를 학습한 딥러닝 모델을 이용하여 재과열기 튜브의 누설을 감지할 수 있다.

[0037] 실시예에 따른 방법은 딥러닝 기반 재과열기 튜브의 누설 감지 방법을 수행하기 위한 장치를 통해 수행될 수 있다.

[0038] 단계(110)에서 장치는 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득한다.

[0039] 실시예에서, 화력 발전 설비들 예를 들어, 이코노마이저(Economizer), 디비전(Division) S/H의 입출력 증기, 파이널(Final) S/H의 출력 증기 등 재과열기 튜브 온도 예측에 영향을 미칠 수 있는 센서 태그에 대한 센서 데이터들을 획득할 수 있다. 일 실시예에 따르면, 재과열기 튜브의 누설 등으로 인하여 재과열기 튜브 온도 예측이 부정확해 질 수 있다.

[0040] 실시예에 따른 화력 발전 설비의 감시를 위한 다양한 센서 데이터들 중 재과열기 튜브 누설의 온도 변화에 영향을 미치는 데이터를 선별하기 위해 화력 발전 운영 로직 분석, 그랜저 인과관계 검사(Granger causality test), 상관관계 분석 및 선형 회귀 기술(Lasso Regression, 라쏘 회귀) 등을 이용할 수 있고, 선별된 데이터들과 재과열기 튜브의 온도 사이의 관계를 모델링한 학습 모델을 이용할 수 있다.

[0041] 장치는 해당 모델을 포함하여 재과열기 튜브의 누설을 감지할 수 있으며, 이후 단계는 도 2에 도시된 모델을 참조하여 자세히 설명하도록 한다.

[0042] 도 2는 실시예에서, 재과열기 튜브 온도 예측을 위해 딥러닝된 모델이다.

[0043] 제1 네트워크(Regression-based skeleton prediction)는 FCN(Fully connected network)로, 화력 발전 설비 내 다양한 센서들의 센서 데이터를 입력 받아 재과열기 튜브의 온도를 출력할 수 있다.

[0044] 실시예에서, 제1 네트워크는 고장의 원인이 되는 설비와 고장 진단 대상인 재과열기 튜브를 함께 학습하여, 고장 징후가 발견되는 경우, 고장 원인이 발생한 설비에 대해 학습할 수 있다.

[0045] 단계(120)에서 장치는, 센서 데이터들을 제1 네트워크로 입력하여 재과열기 튜브의 예상 온도를 예측할 수 있다.

[0046] 실시예에서, 특정 시간구간 동안 측정되는 시계열적인 센서 데이터들이 제1 네트워크로 입력될 수 있는데, 제1 네트워크를 통해 센서 데이터들로부터 추출되는 특징에 대응하는 예상 온도를 도출할 수 있다.

[0047] 실시예에서, 수집된 센서 데이터들은 제1 네트워크로 입력하기 위해 정제 과정을 거칠 수 있다.

[0048] 도 3은 실시예에서, 실제 수집되는 센서 데이터들을 도시한 그래프이다.

[0049] 도 4는 실시예에서, 센서 데이터들을 정제한 형태를 도시한 그래프이다.

[0050] 실시예에서, 수집된 센서 데이터들은 도 3과 같이 측정값이 존재하지 않거나(누락 값, Missing Value), 계획 정비 등으로 인하여 발생하는 비정상 데이터를 포함할 수 있고, 태그 별 센서 데이터의 측정 간격이 서로 일정하지 않다.

[0051] 이에, 활용할 수 없는 데이터를 필터링하고 누락 값을 추정하고 수집된 센서데이터에 대해서 동기화 및 균일화를 위한 정제 단계를 수행할 수 있다. 실시예에 따른 정제 단계를 거친 센서 데이터는 도 4와 같이 나타날 수 있다.

[0052] 도 3 및 도 4를 비교하면, 도 4는 수집된 센서 데이터에서 누락 값을 복구하고, 비정상 상태의 데이터를 제거한 형태를 가진다.

[0053] 실시예에서, 해당 센서 데이터를 수집하는 시간을 동일한 시간 간격으로 분할하고, 각 시간 간격에 대한 대표값, 예를 들어 평균 값을 생성하여, 해당 값을 이용하여 누락 값을 추정할 수 있다. 더불어, 화력 발전 설비 내 유사한 부분을 감시 중인 다른 센서 데이터를 이용하여 누락 값을 추정할 수도 있다.

[0054] 단계(130)에서 장치는, 센서 데이터들을 제2 네트워크로 입력하고, 예상 온도에 대한 오차를 예측한다.

[0055] 도 2를 참조하면, 제2 네트워크(Convolutional NN-based Residual fitting)의 컨볼루션 동작을 위한 필터는 3차원 필터로, 필터의 너비는 시간 축이고, 필터의 높이는 센서 데이터의 값이며, 필터의 차원은 센서들 각각을 나타낼 수 있다.

[0056] 실시예에 따른 제2 네트워크는 센서 데이터에 대해서 제1 네트워크의 출력인 재과열기 튜브의 온도에 대해 오차 값을 예측할 수 있다. 예를 들어, 오차 확률 몇 %의 범위 내에 몇 도의 오차가 발생 가능함에 대해서 예측할 수 있다.

[0057] 실시예를 위해서 제2 네트워크는 CNN 모델로 학습될 수 있다.

[0058] 단계(140)에서 장치는, 예상 온도 및 오차를 이용하여 재과열기 튜브의 최종 예상 온도를 결정한다.

[0059] 실시예에서, 제1 네트워크에서 출력된 예상 온도와 제2 네트워크에서 출력된 오차를 합산하여 재과열기 튜브의 온도에 대한 최종 예측 온도를 결정할 수 있다. 예를 들어, 예상 온도와 오차의 합산으로 최종 예상 온도의 범위가 결정되거나, 최종 예측 온도에 대한 확률을 결정할 수 있다.

[0060] 단계(150)에서 장치는, 최종 예상 온도 및 재과열기 튜브의 실제 온도를 비교하여 재과열기 튜브의 누설을 감지한다.

[0061] 실시예에서, 최종 예상 온도와 실제 측정 값이 상이하면, 재과열기 튜브에 누설이 발생한 것으로 판단할 수 있다. 예를 들어, 실측값이 예측값보다 높고, 그 오차의 정도가 점점 증가하는 패턴의 상이함이 지속적으로 보이는 경우, 재과열기 튜브에 누설이 발생한 것으로 판단할 수 있다. 재과열기 튜브에 대한 실제 온도는 재과열기 튜브에 설치된 센서 태그로부터 획득할 수 있다.

[0063] 이하에서는 도 1 내지 도 2를 통해 설명한 재과열기 튜브의 누설 감지 방법 및 이를 감지하기 위한 학습 모델을 이용하여 재과열기 튜브의 누설을 감지하는 예시에 대해서 설명하도록 한다.

[0064] 앞서 설명한 바와 같이, 화력 발전 설비의 센서 데이터를 분석하여 센서 태그 간의 상호 관계를 파악하고 재과열기 튜브에 대한 목적 데이터의 예측을 위해 우선적 입력 요인을 결정할 수 있다. 이를 위해 그랜저 인과관계 검사 및/또는 라쏘 회귀 방법 등을 이용할 수 있다. 그랜저 인과관계 검사는 센서 간 인과관계를 파악하기 위해 목적 데이터에 영향을 미치나 직관적으로 파악하기 어려운 입력 요인을 찾기 위한 검사 방법이다. 라쏘 회귀는 데이터 선형 모델에 미치는 영향이 적은 특징들을 필터링하여 특징 선택을 하는 데에 유용한 방법으로, 목적 데이터를 예측하는데 요구되는 입력 데이터에 관해 특정하기 위한 내용이다.

[0065] 도 5 내지 도 10은 인공지능 기반의 주요 튜브 증기 온도를 예측한 그래프이다.

[0066] 도 5(a)는 실시예에서, 이코노마이저(Economizer)의 출력 및 예상 온도의 그래프이고, 도 5(b)는 누적 오차 그래프이다.

[0067] 실시예에서, 센서 태그 35BW TT01C에 의해서 모니터링될 수 있다. CNN은 시간적, 공간적으로 인접한 데이터들을 예측하기 위해 동시에 고려할 수 있는 기술적 특성으로 딥러닝 분야에서 광범위하게 사용된다. CNN을 이용

한 예측은 평균 오차 1.513℃, 전체 검증 데이터에서 98%의 센서 데이터를 예측 오차 4℃이내로 예측할 수 있다.

[0068] 도 6(a)는 실시예에서, Division S/H의 입력 및 예상 온도의 그래프이고, 도 6(b)는 누적 오차 그래프이다.

[0069] 실시예에서, SH TT04C에 의해 모니터링되고, 평균 오차가 0.596℃이며, 전체 검증데이터에서 98%의 데이터를 예측 오차 2℃ 이내로 예측할 수 있다.

[0070] 도 7(a)는 실시예에서, Division S/H의 출력 및 예상 온도의 그래프이고, 도 7(b)는 누적 오차 그래프이다.

[0071] 실시예에서, SH TT02E에 의해 모니터링되고, 평균 오차 1.945℃, 전체 검증데이터에서 98%의 데이터를 예측 오차 5℃ 이내로 예측할 수 있다.

[0072] 도 8(a)는 실시예에서, Final S/H의 출력 및 예상 온도의 그래프이고, 도 8(b)는 누적 오차 그래프이다.

[0073] 실시예에서, MS TT01A에 의해 모니터링되고, CNN을 이용하여 예측된 평균 오차는 0.840℃이며, 전체 오차의 98%가 2.545℃ 이하로 나타날 수 있다.

[0074] 도 9(a)는 실시예에서, Finish S/H의 메탈 온도 및 예상 온도의 그래프이고, 도 9(b)는 누적 오차 그래프이다.

[0075] 실시예에서, 주요 튜브에 대한 증기 온도 예측 결과는 비교적 높은 정확성을 보여주나, 예측 결과가 상대적으로 부정확한 목적 데이터도 존재할 수 있다. SH TT01H는 Finish S/H 내에 위치하며, 튜브의 메탈 온도를 모니터링 할 수 있다.

[0076] 실시예에서, 딥러닝 기반의 예측은 평균 오차 2.466℃, 오차의 98%가 8℃ 내에 있으며, 최대 오차가 약 12.682℃로, 앞서 측정된 예상 온도에 대비하여 상대적으로 큰 오차가 발생한다.

[0077] 도 10(a)는 실시예에서, CNN을 이용한 예상 온도의 그래프이고 도 10(b)는 누적 오차 그래프이다.

[0078] 실시예에서, 도 9와 동일한 센서 태그에 대해서 CNN을 이용하여 센서 데이터를 예측한 결과, 평균 오차는 2.624℃이며, 오차의 98%가 7.157℃ 이내에 존재하고, 최대 오차는 11.383℃로 나타나는 것을 볼 수 있다. 해당 결과는 회귀(regression) 기반 모델에 대비하여 조금 개선된 정확도를 보인다.

[0080] 실시예에서, 딥러닝을 기반으로 재과열기 튜브의 센서 데이터를 예측하기 위한 모델을 학습하는 방법에 대해서 설명하도록 한다.

[0081] 실시예에서, 분석 대상이 되는 재과열기 튜브에 영향을 미치는 센서들을 선정할 수 있다. 이를 위해 화력 발전 설비 및 화력 발전 설비의 센서 시스템을 분석하여 센서들 간의 인과관계를 확인할 수 있다. 또는 보일러 설계 도면을 바탕으로 수증기의 경로 및 경로에 위치한 센서 시스템을 확인할 수 있다. 또는 서로 다른 센서간 양의 상관관계(Correlation) 및 음의 상관관계 확인하거나, 라쏘 필터링(Lasso filtering)을 통해 특징 선택(feature selection)에 활용하는 기법으로 대상 센서에 영향을 미치는 센서 선택 및 영향을 미치는 정도를 확인할 수 있다.

[0082] 센서 데이터의 분석을 위한 학습 데이터는 실제 측정된 데이터가 사용될 수 있다. 실시예에서는 도 3 내지 도 4를 통해 설명한 정제된 센서 데이터가 사용될 수 있다.

[0083] 도 11은 실시예에서, 실제 데이터 중 학습 데이터를 위한 데이터의 분류를 설명하기 위한 그래프이다.

[0084] 도 11(a)는 2017년 1년 기간 동안 측정된 센서 데이터들에 해당하고, 해당 센서 데이터들 중 안정된 센서 데이터가 나타나는 기간에 대해서 도 11(b)와 같은 센서 데이터가 학습 데이터로 이용될 수 있다. 센서 데이터가 측정되지 않는 기간은 계획 정비 기간, 발전량 감소 기간 등의 이유로 센서 데이터가 측정되지 않을 수 있다.

[0085] 도 11(b)를 참조하면, 학습에 이용되는 센서 데이터는 일정 비율로 나뉘어 훈련 데이터, 검증 데이터 및 시험 데이터로 각각 사용될 수 있다. 실시예에 따른 비율은 8:1:1이다. 도 11의 센서 데이터는 다양한 단위를 가진 데이터가 혼재되어 있으므로, 표준화한 값을 이용할 필요가 있다. 이때 센서 데이터의 복원을 위해 표준화 시 사용한 평균값 및 표준편차에 대한 정보를 별도로 저장할 수 있다.

[0086] 실시예에서, 센서 데이터에 대한 학습 데이터가 준비되면, 진단 대상이 되는 센서 태그를 선정할 수 있다. 예를 들어, 실제 고장 사례를 참조하면 2017년 1월 12일 7호기에서 발생한 CID Fan #A L.O Tank Level Low-Low로 Runback 고장 사례의 경우 CID Fan #A의 유압실린더 작동용 고압호스 접속부 누설로 인해 발생한 사례이며, 이

와 관련하여 5FG XAPT51 XQ01(CIDF A HYD OIL PRESS), 35FG XAPT61 XQ01(CIDF A LO PRESS), 35FG XATT64 XQ01(CIDF A HYD LINE OIL TEMP), 35FG XATT65 XQ01(CIDF A LO TK TEMP) 이렇게 4개의 센서가 원인 태그가 될 수 있는 것으로 판단하였다.

[0087] 실시예에서, 선정된 진단 대상 센서를 예측하기 위한 입력 센서를 선정할 수 있다. 예를 들어, CID Fan #A 내 온도, 압력, 진동, 유량 등 센서 시스템을 대상으로 설비를 분석하여 입력 센서와 대상 센서 간 상관관계 및 센서들 간 상관 관계를 알아낼 수 있다. 여기서, 라쏘 회귀 분석을 사용하여 일정 수의 입력 센서를 선정할 수 있다.

[0088] 실시예에서, 고장 진단을 위한 예측 모델로 비선형 분석을 위한 CNN 모델을 사용할 수 있다. CNN 모델은 도 2의 제2 네트워크를 참조할 수 있다. 다수의 입력 센서 데이터를 하나의 이미지와 같이 사용하고, 입력 센서 데이터를 일정 단위로 재조합하여 결과를 예측할 수 있다.

[0089] 실시예에서, 도 11(b)의 기간의 센서 데이터에 대해서 학습할 수 있다. 예를 들어, 상기의 예시에 의하면 5FG XAPT51 XQ01(CIDF A HYD OIL PRESS), 35FG XAPT61 XQ01(CIDF A LO PRESS), 35FG XATT64 XQ01(CIDF A HYD LINE OIL TEMP), 35FG XATT65 XQ01(CIDF A LO TK TEMP) 각각의 센서에 대해서 학습을 수행할 수 있다.

[0090] 실시예에서, 고장 사례를 적용하여 센서 데이터가 고장 이전 발생하는 이상 징후를 분석할 수 있고, 딥러닝 학습에 사용된 센서와 동일한 입력 센서를 이용하여 해당 고장 사례에 대해 고장 진단을 적용할 수 있다. 딥러닝 모델을 이용한 고장 진단 결과, 동일한 설비의 데이터가 아니더라도 선형 모델의 예측 결과보다 좋은 성능을 보임을 알 수 있다. 이에, 실제 온도와 예상 온도 사이의 오차의 임계치를 설정하고, 재과열기 튜브의 누설이 발생하기 일정 시간 이전에 고장의 예시를 할 수 있도록 한다.

[0091] 도 12는 실시예에서, 재과열기 튜브의 누설로 인한 비정상적 온도를 검출하는 실시예를 설명하기 위한 그래프이다.

[0092] 도 12(a)는 딥러닝 기반의 학습 모델을 이용한 재과열기 튜브의 누설 검출하는 실시예이고, 도 12(b)는 BTLD 기반의 재과열기 튜브의 누설을 검출하는 실시예에 관한 것이다. 실시예에서, 딥러닝 모델을 당진화력발전소 5호기의 2017년 정상 데이터에 대하여 학습하고, 실제 재과열기 튜브 누설이 발생한 2015년 1월 사례에 적용한 결과이다.

[0093] 도 12와 같이 실제 누설이 발생한 경우, 실제 튜브의 온도(파란색)가 예측 온도(주황색)보다 점차 증가하는데, 딥러닝 기반의 학습 모델을 이용하는 방법이 기존의 소리 신호를 이용한 BTLD 검출 방법보다 빠르게 감지가 가능한 것을 확인할 수 있다.

[0095] 도 13은 실시예에서, 딥러닝 기반 재과열기 튜브의 누설 감지 방법을 수행하는 장치의 블록도이다.

[0096] 실시예에 따른 장치(1300)는 메모리(1310) 및 프로세서(1320)를 포함하여 구성될 수 있으며, 딥러닝 기반 재과열기 튜브의 누설 감지 방법을 수행하기 위한 프로그램을 수행할 수 있다.

[0097] 실시예에서 장치(1300)는 화력 발전 설비들의 센서들로부터 센서 데이터들을 획득한다.

[0098] 실시예에서, 화력 발전 설비들 예를 들어, 이코노마이저(Economizer), 디비전(Division) S/H의 입출력 증기, 파이널(Final) S/H의 출력 증기 등 재과열기 튜브의 누설의 원인이 될 수 있는 센서 태그에 대한 센서 데이터들을 획득할 수 있다.

[0099] 실시예에 따른 화력 발전 설비의 감시를 위한 다양한 센서 데이터들 중 재과열기 튜브 누설의 온도 변화에 영향을 미치는 데이터를 선별하기 위해 화력 발전 운영 로직 분석, 그랜저 인과관계 검사(Granger causality test), 상관관계 분석 및 선형 회귀 기술(Lasso Regression, 라쏘 회귀) 등을 이용할 수 있고, 선별된 데이터들과 재과열기 튜브의 온도 사이의 관계를 모델링한 학습 모델을 이용할 수 있다.

[0100] 앞서 설명한 바와 같이 도 2를 참조하면, 제1 네트워크(Regression-based skeleton prediction)는 FCN(Fully connected network)로, 화력 발전 설비 내 다양한 센서들의 센서 데이터를 입력 받아 재과열기 튜브의 온도를 출력할 수 있다.

[0101] 실시예에서, 제1 네트워크는 고장의 원인이 되는 설비와 고장 진단 대상인 재과열기 튜브를 함께 학습하여, 고장 징후가 발견되는 경우, 고장 원인이 발생한 설비에 대해 학습할 수 있다.

[0102] 장치(1300)는, 센서 데이터들을 제1 네트워크로 입력하여 재과열기 튜브의 예상 온도를 예측할 수 있다.

[0103] 실시예에서, 특정 시간구간 동안 측정되는 시계열적인 센서 데이터들이 제1 네트워크로 입력될 수 있는데, 제1 네트워크를 통해 센서 데이터들로부터 추출되는 특징에 대응하는 예상 온도를 도출할 수 있다.

[0104] 실시예에서, 수집된 센서 데이터들은 제1 네트워크로 입력하기 위해 정제 과정을 거칠 수 있다.

[0105] 실시예에서, 수집된 센서 데이터들은 측정값이 존재하지 않거나(누락 값, Missing Value), 계획 정비 등으로 인하여 발생하는 비정상 데이터를 포함할 수 있고, 태그 별 센서 데이터의 측정 간격이 서로 일정하지 않다.

[0106] 이에, 활용할 수 없는 데이터를 필터링하고 누락 값을 추정하고 수집된 센서데이터에 대해서 동기화 및 균일화를 위한 정제 단계를 수행할 수 있다. 실시예에서, 해당 센서 데이터를 수집하는 시간을 동일한 시간 간격으로 분할하고, 각 시간 간격에 대한 대표 값, 예를 들어 평균 값을 생성하여, 해당 값을 이용하여 누락 값을 추정할 수 있다. 더불어, 화력 발전 설비 내 유사한 부분을 감시 중인 다른 센서 데이터를 이용하여 누락 값을 추정할 수도 있다.

[0107] 장치(1300)는, 센서 데이터들을 제2 네트워크로 입력하고, 예상 온도에 대한 오차를 예측한다.

[0108] 도 2를 참조하면, 제2 네트워크(Convolutional NN-based Residual fitting)는 센서 데이터에 대해서 제1 네트워크의 출력인 재과열기 튜브의 온도에 대해 오차값을 예측할 수 있다. 예를 들어, 오차 확률 몇 %의 범위 내에 몇 도의 오차가 발생 가능함에 대해서 예측할 수 있다. 실시예를 위해서 제2 네트워크는 CNN 모델로 학습될 수 있다.

[0109] 장치(1300)는, 예상 온도 및 오차를 이용하여 재과열기 튜브의 최종 예상 온도를 결정한다.

[0110] 실시예에서, 제1 네트워크에서 출력된 예상 온도와 제2 네트워크에서 출력된 오차를 합산하여 재과열기 튜브의 온도에 대한 최종 예측 온도를 결정할 수 있다. 예를 들어, 예상 온도와 오차의 합산으로 최종 예상 온도의 범위가 결정되거나, 최종 예측 온도에 대한 확률을 결정할 수 있다.

[0111] 장치(1300)는, 최종 예상 온도 및 재과열기 튜브의 실제 온도를 비교하여 재과열기 튜브의 누설을 감지한다.

[0112] 실시예에서, 최종 예상 온도와 실제 측정 값을 비교함으로써, 재과열기 튜브에 누설이 발생한 것으로 판단할 수 있다. 재과열기 튜브에 대한 실제 온도는 재과열기 튜브에 설치된 센서 태그로부터 획득할 수 있다.

[0114] 이상에서 설명된 실시예들은 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치, 방법 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0115] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치, 또는 전송되는 신호 파(signal wave)에 영구적으로, 또는 일시적으로 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

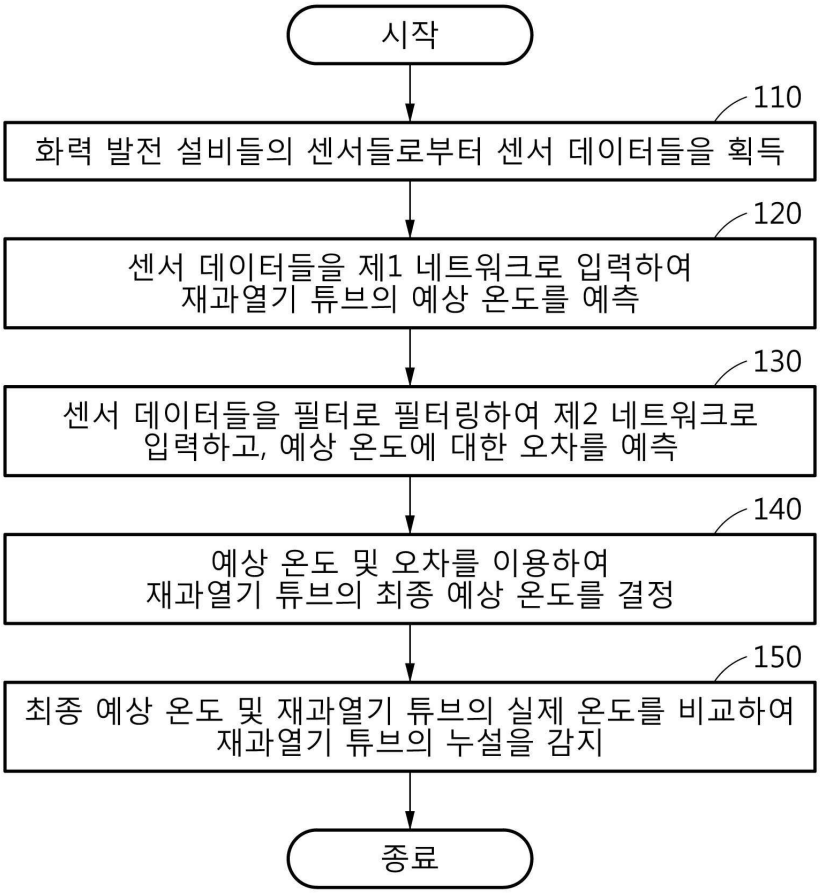
[0116] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판

독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다. 상기된 하드웨어 장치는 실시예의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.

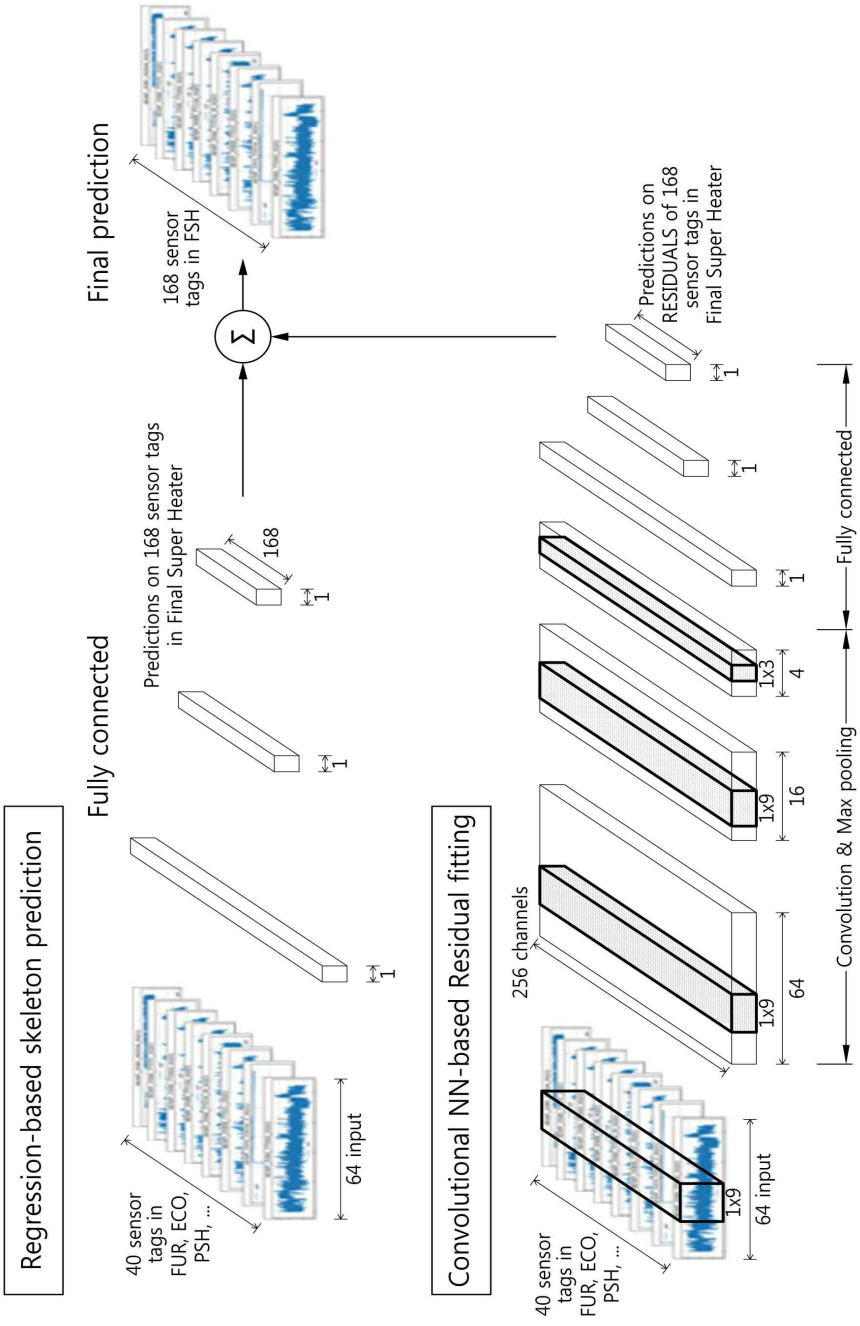
[0117] 이상과 같이 실시예들이 비록 한정된 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기를 기초로 다양한 기술적 수정 및 변형을 적용할 수 있다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

도면

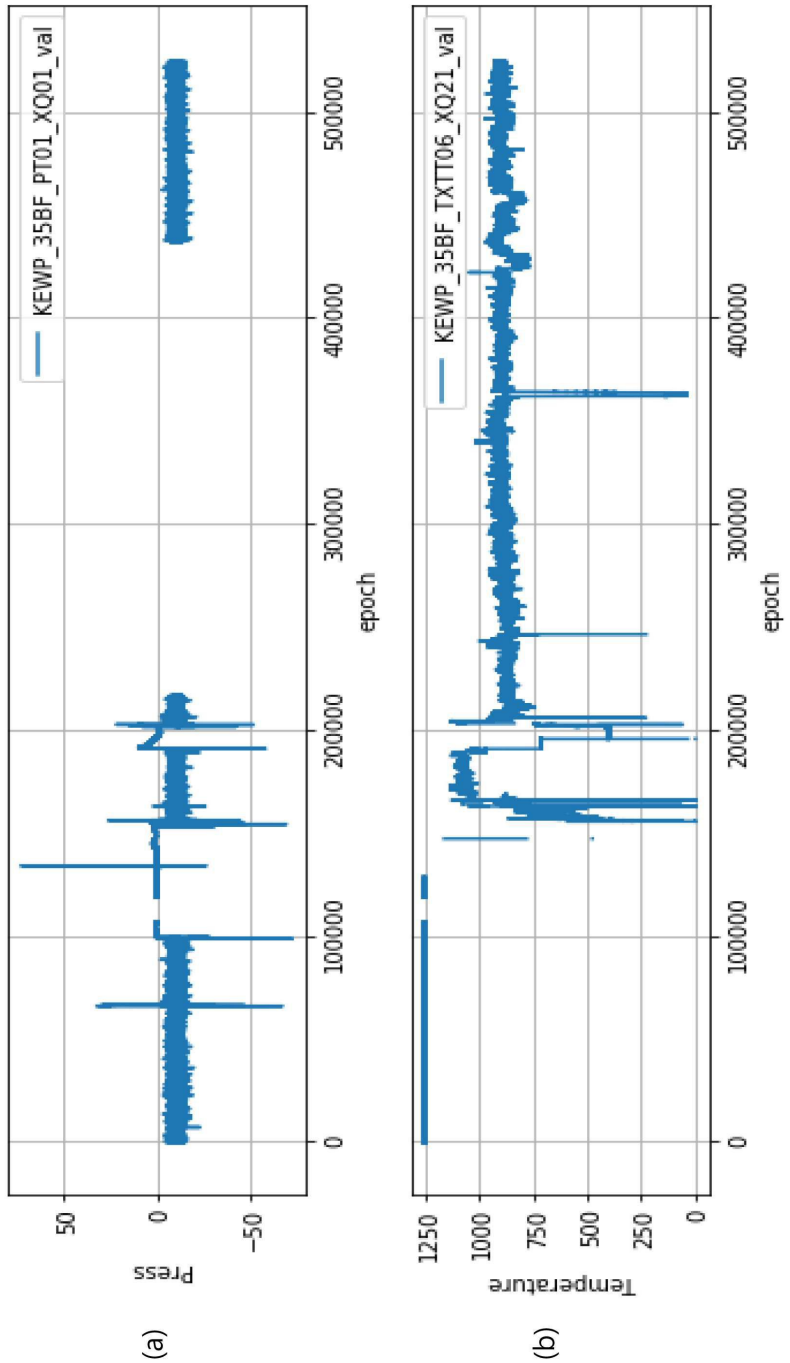
도면1



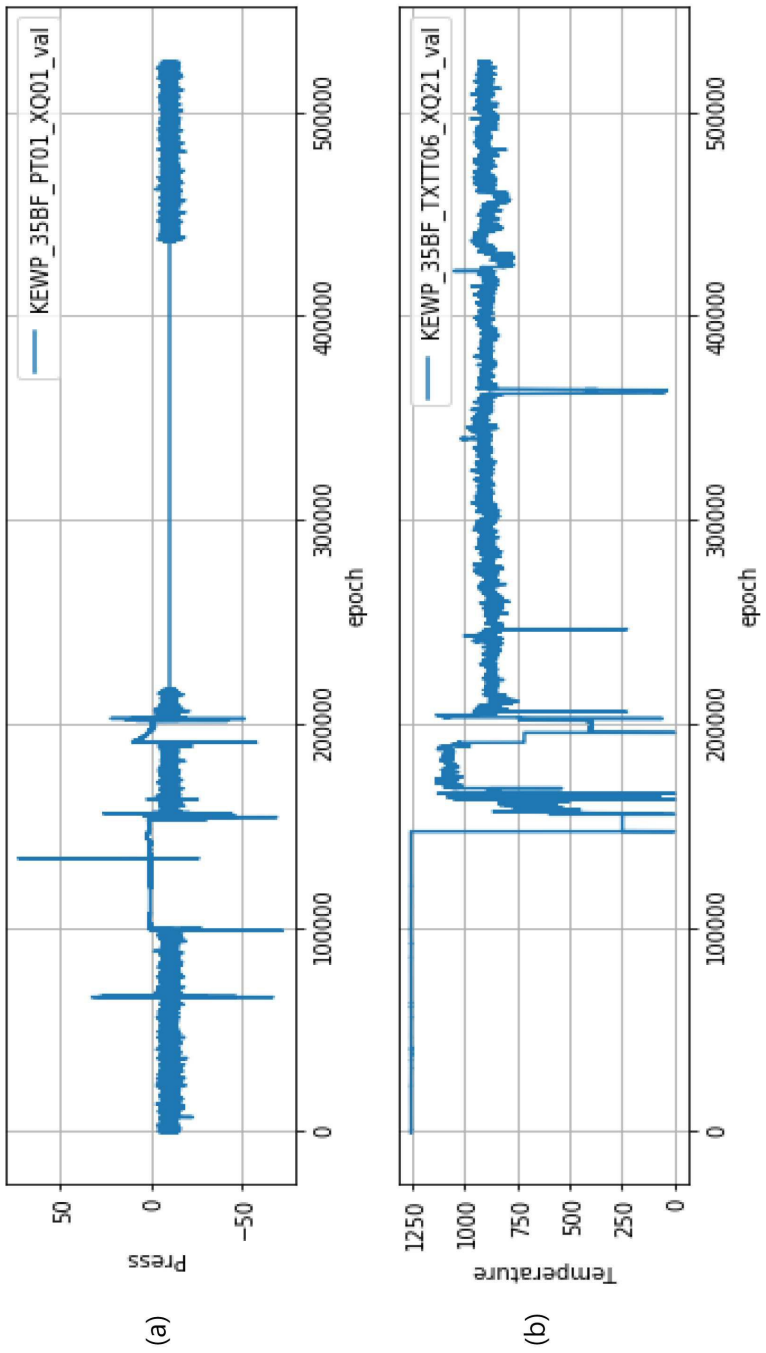
도면2


Regression-based skeleton prediction
Fully connected
Final prediction
40 sensor tags in FUR, ECO, PSH, ...
64 input
1
Predictions on 168 sensor tags in Final Super Heater
168
1
168 sensor tags in FSH
Σ
Convolutional NN-based Residual fitting
40 sensor tags in FUR, ECO, PSH, ...
64 input
1x9
256 channels
64
1x9
16
1x3
4
1
1
Predictions on RESIDUALS of 168 sensor tags in Final Super Heater
1
Convolution & Max pooling
Fully connected

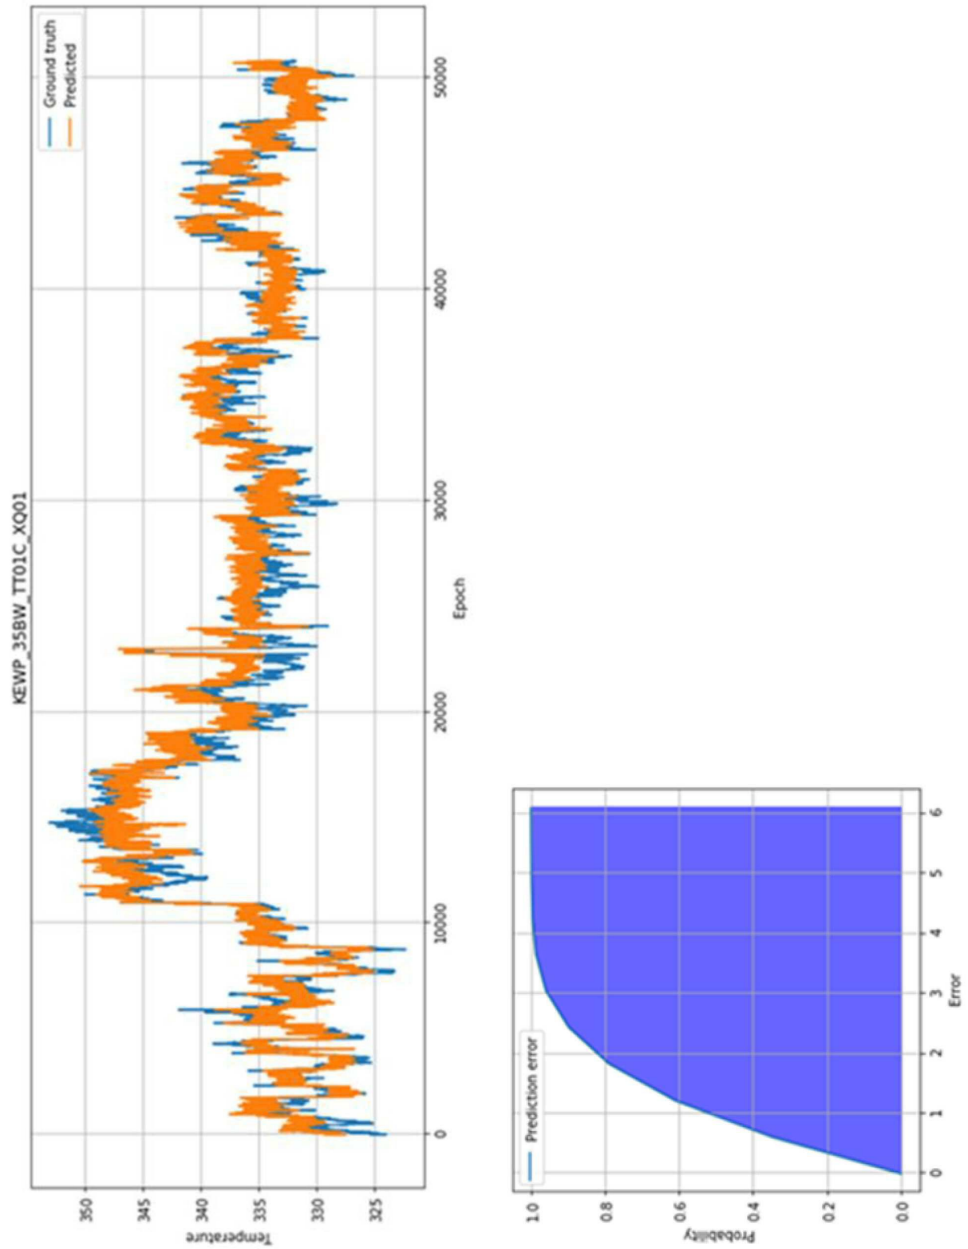
도면3


KEWP_35BF_PT01_XQ01_val
Press
50
0
−50
0
100000
200000
300000
400000
500000
epoch
(a)
KEWP_35BF_TXTT06_XQ21_val
Temperature
1250
1000
750
500
250
0
0
100000
200000
300000
400000
500000
epoch
(b)

도면4

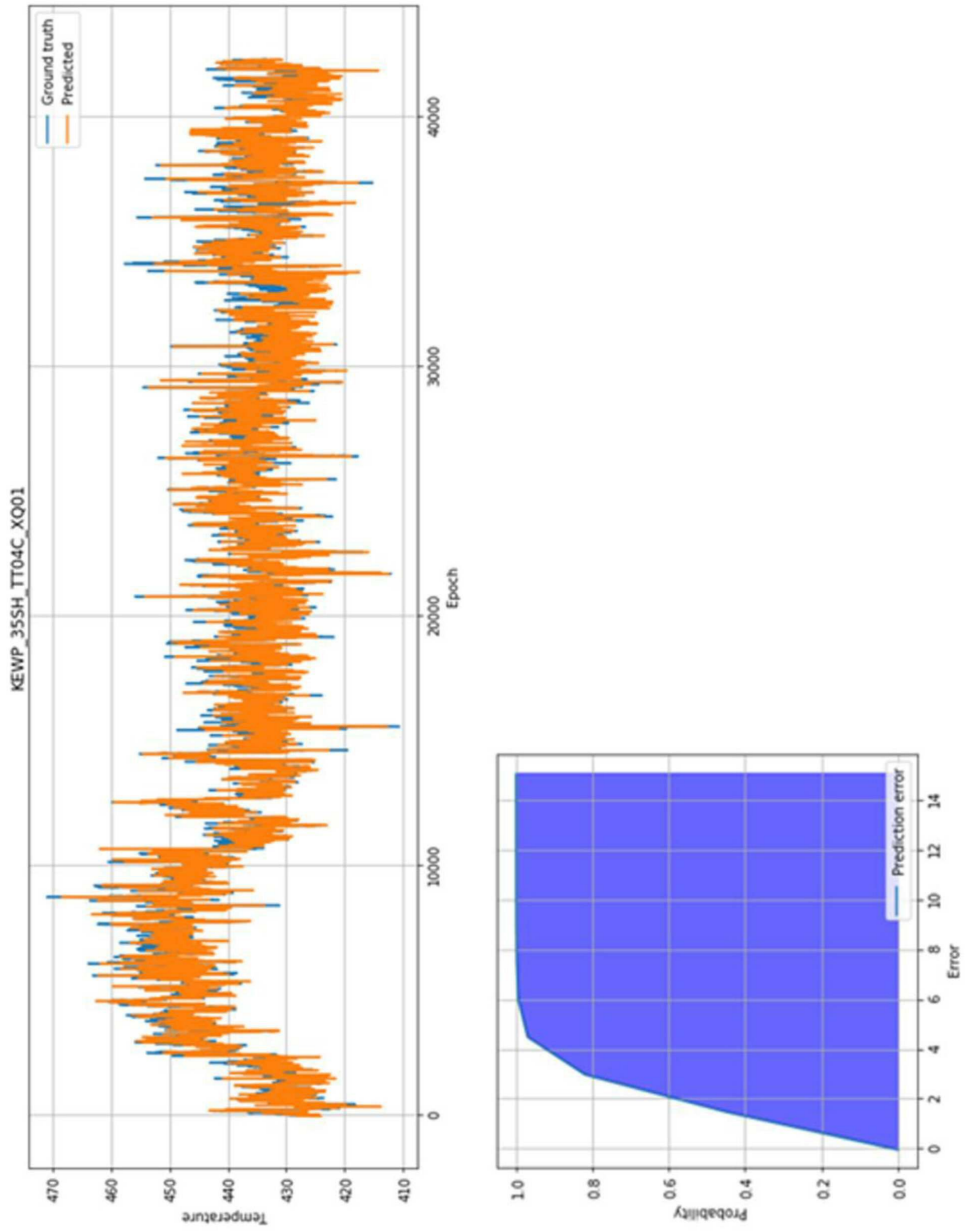

KEWP_35BF_PT01_XQ01_val
Press
50
0
−50
0
100000
200000
300000
400000
500000
epoch
(a)
KEWP_35BF_TXTT06_XQ21_val
Temperature
1250
1000
750
500
250
0
0
100000
200000
300000
400000
500000
epoch
(b)

도면5

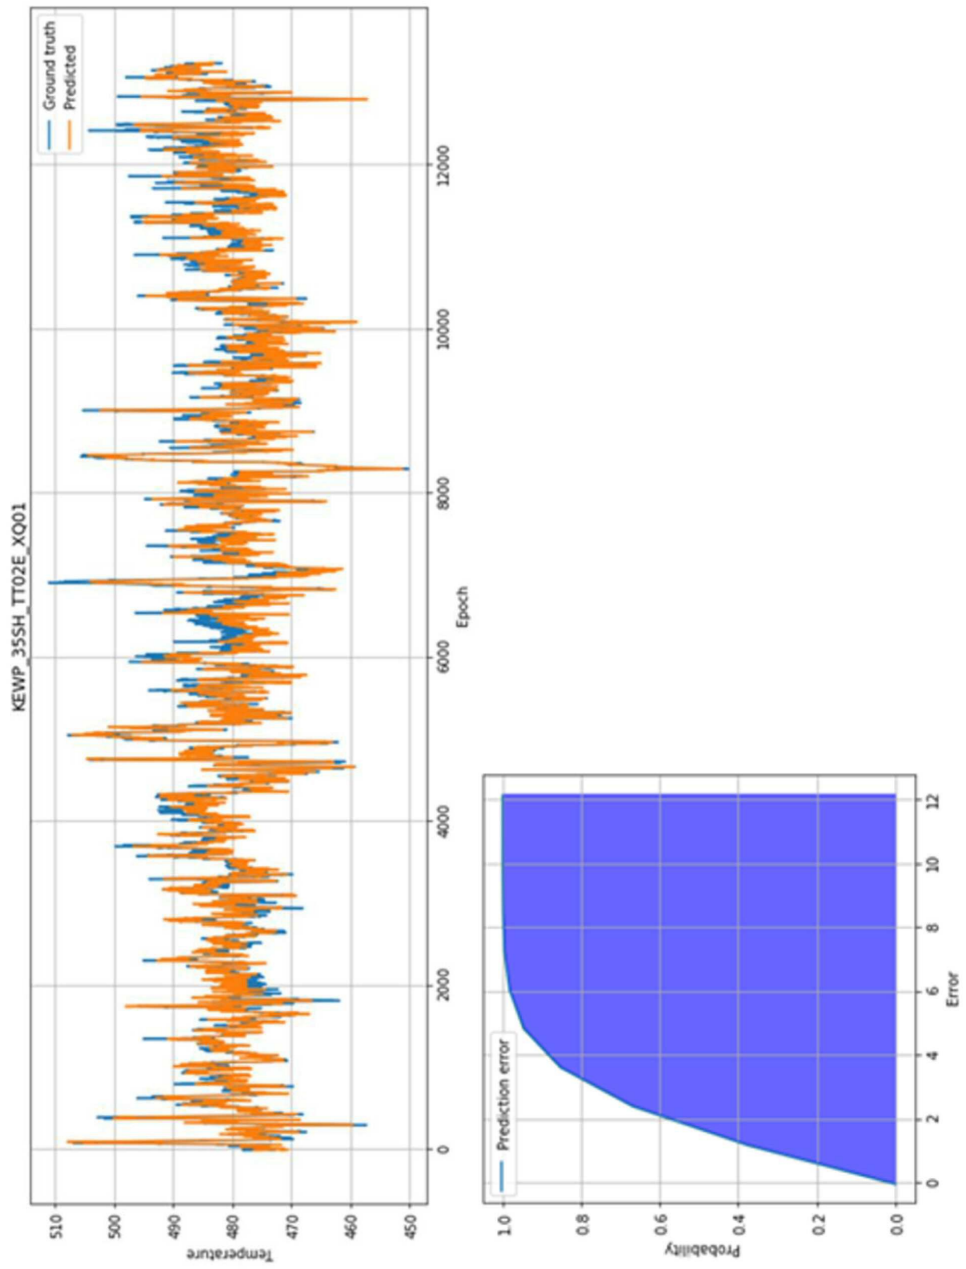

KEWP_35BW_TT01C_XQ01
Ground truth
Predicted
Temperature
Epoch
Prediction error
Probability
Error

(a) (b)

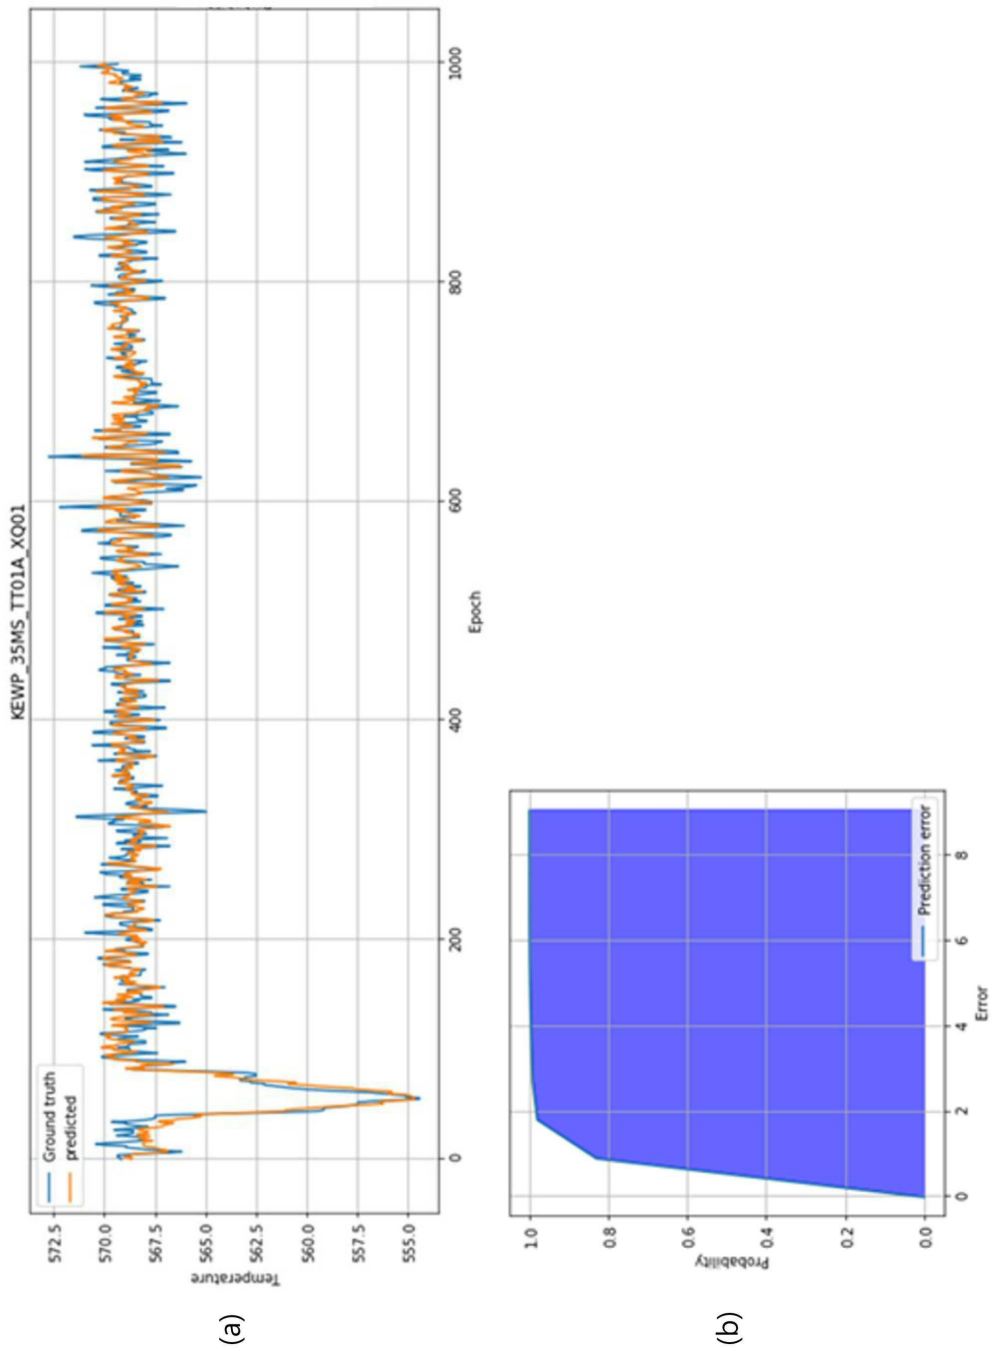
도면6


KEWP_35SH_TT04C_XQ01
Ground truth
Predicted
Temperature
Epoch
Probability
Error
Prediction error
(a)
(b)

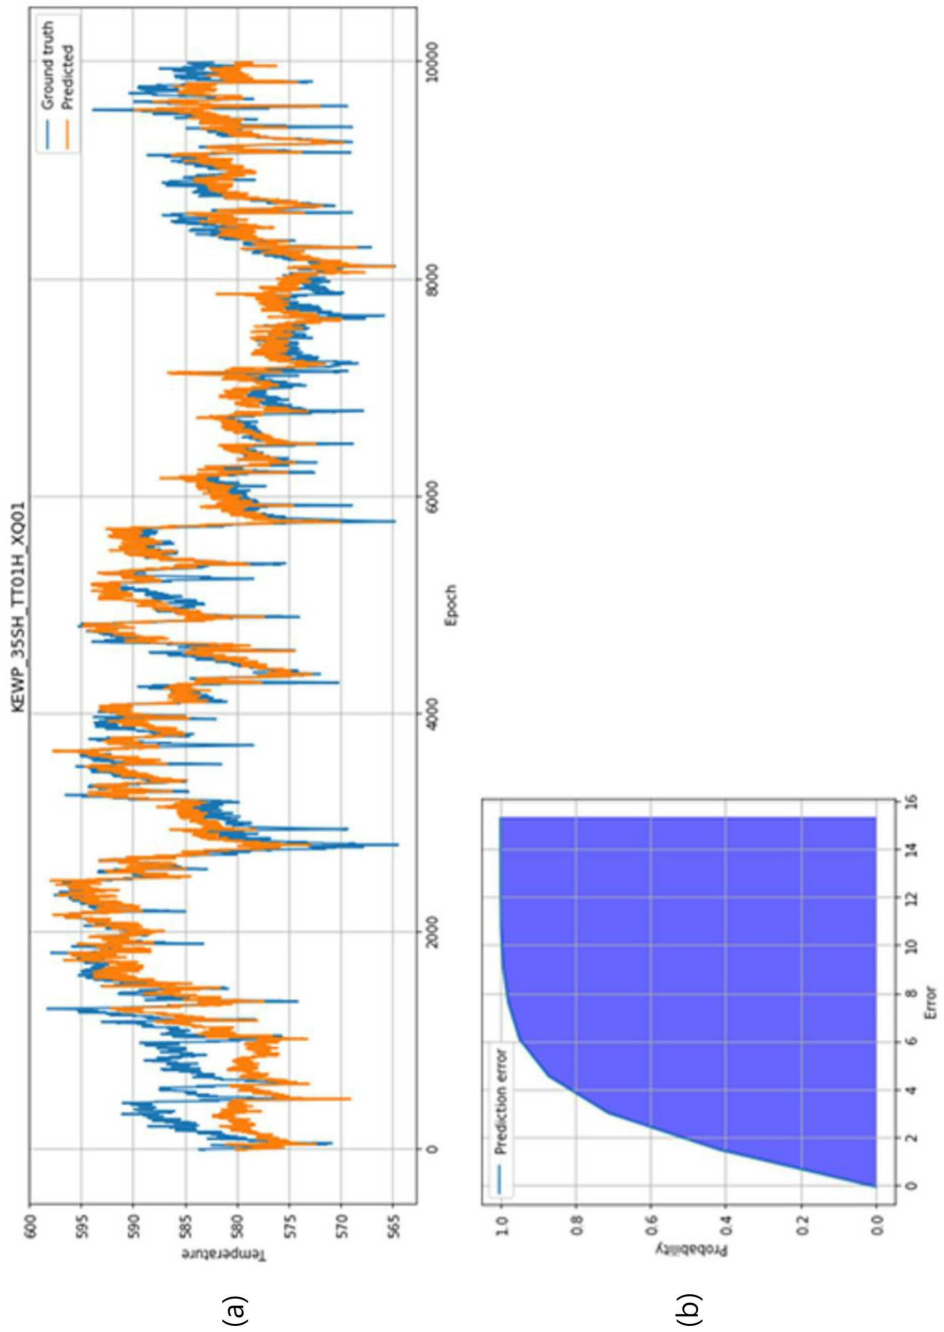
도면7


KEWP_35SH_TT02E_XQ01
Ground truth
Predicted
Temperature
Epoch
510
500
490
480
470
460
450
0
2000
4000
6000
8000
10000
12000
(a)
Prediction error
Probability
Error
1.0
0.8
0.6
0.4
0.2
0.0
0
2
4
6
8
10
12
(b)

도면8

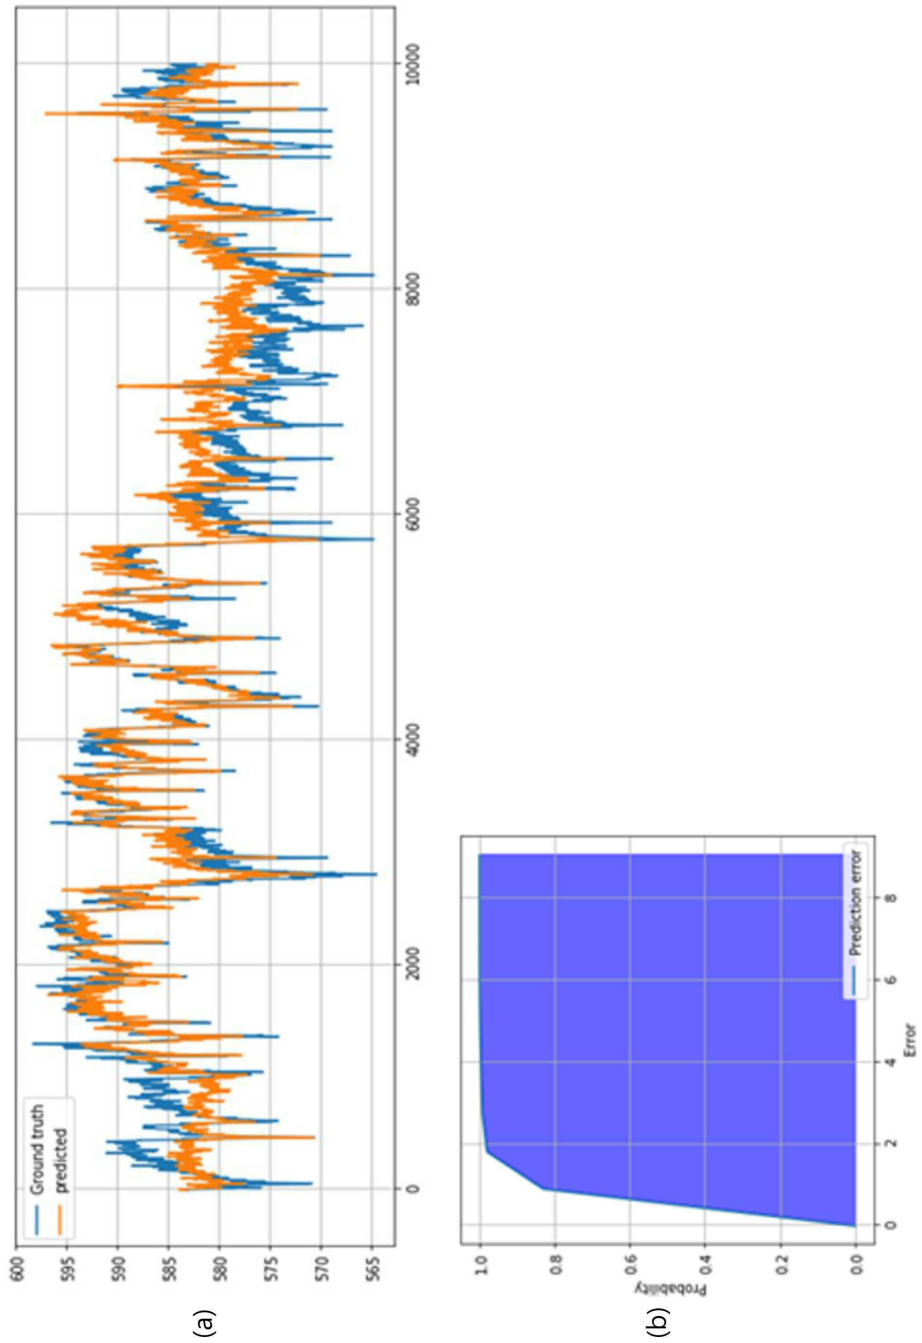

KEWP_35MS_TT01A_XQ01
Ground truth
predicted
Temperature
Epoch
572.5
570.0
567.5
565.0
562.5
560.0
557.5
555.0
0
200
400
600
800
1000
(a)
Prediction error
Probability
Error
1.0
0.8
0.6
0.4
0.2
0.0
0
2
4
6
8
(b)

도면9

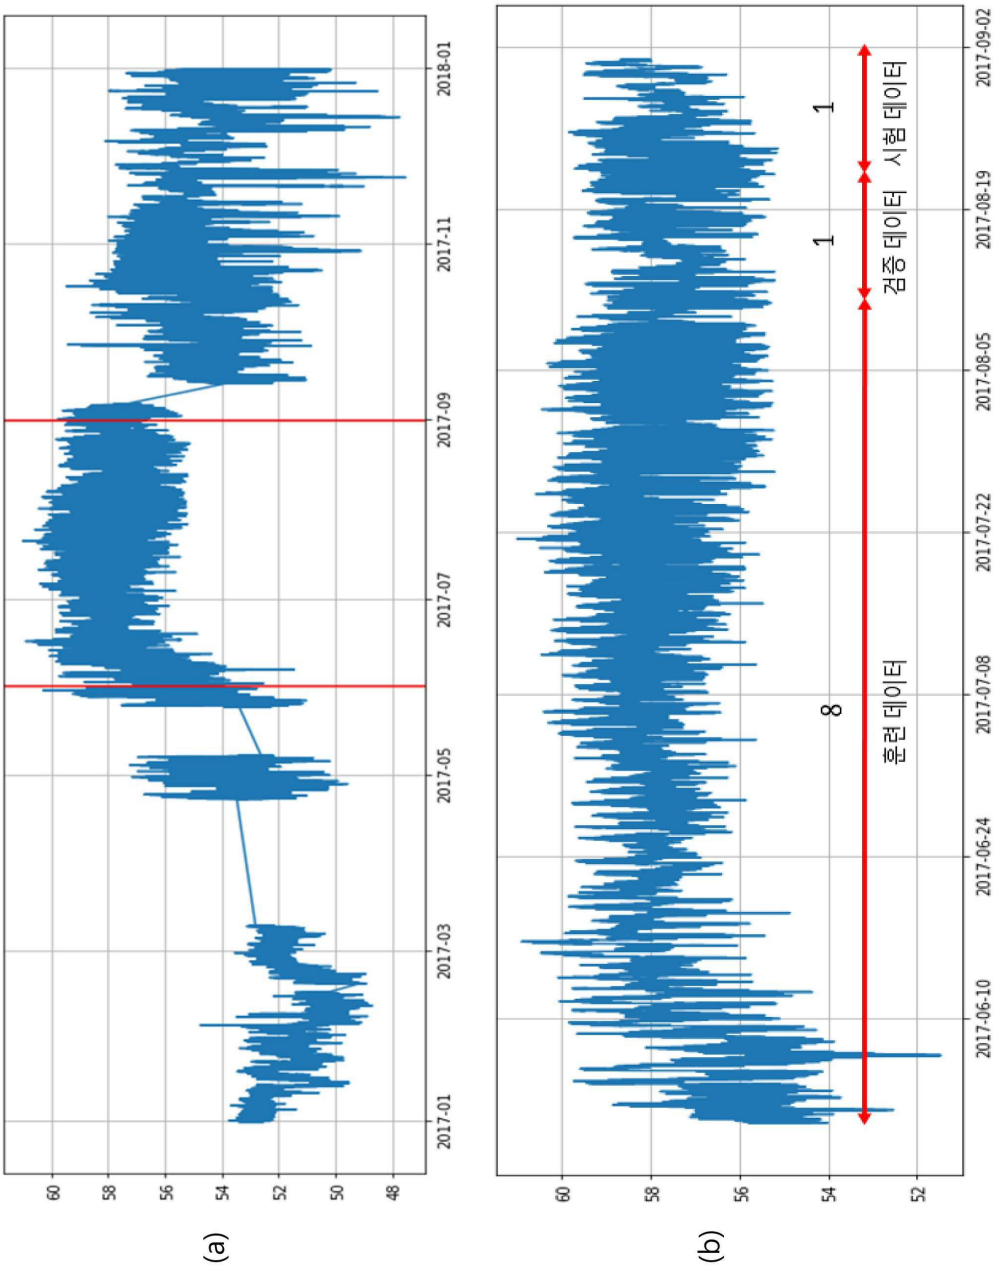

KEWP_35SH_TT01H_XQ01
Ground truth
Predicted
Temperature
Epoch
600
595
590
585
580
575
570
565
0
2000
4000
6000
8000
10000
Prediction error
Probability
Error
1.0
0.8
0.6
0.4
0.2
0.0
0
2
4
6
8
10
12
14
16

(a) (b)

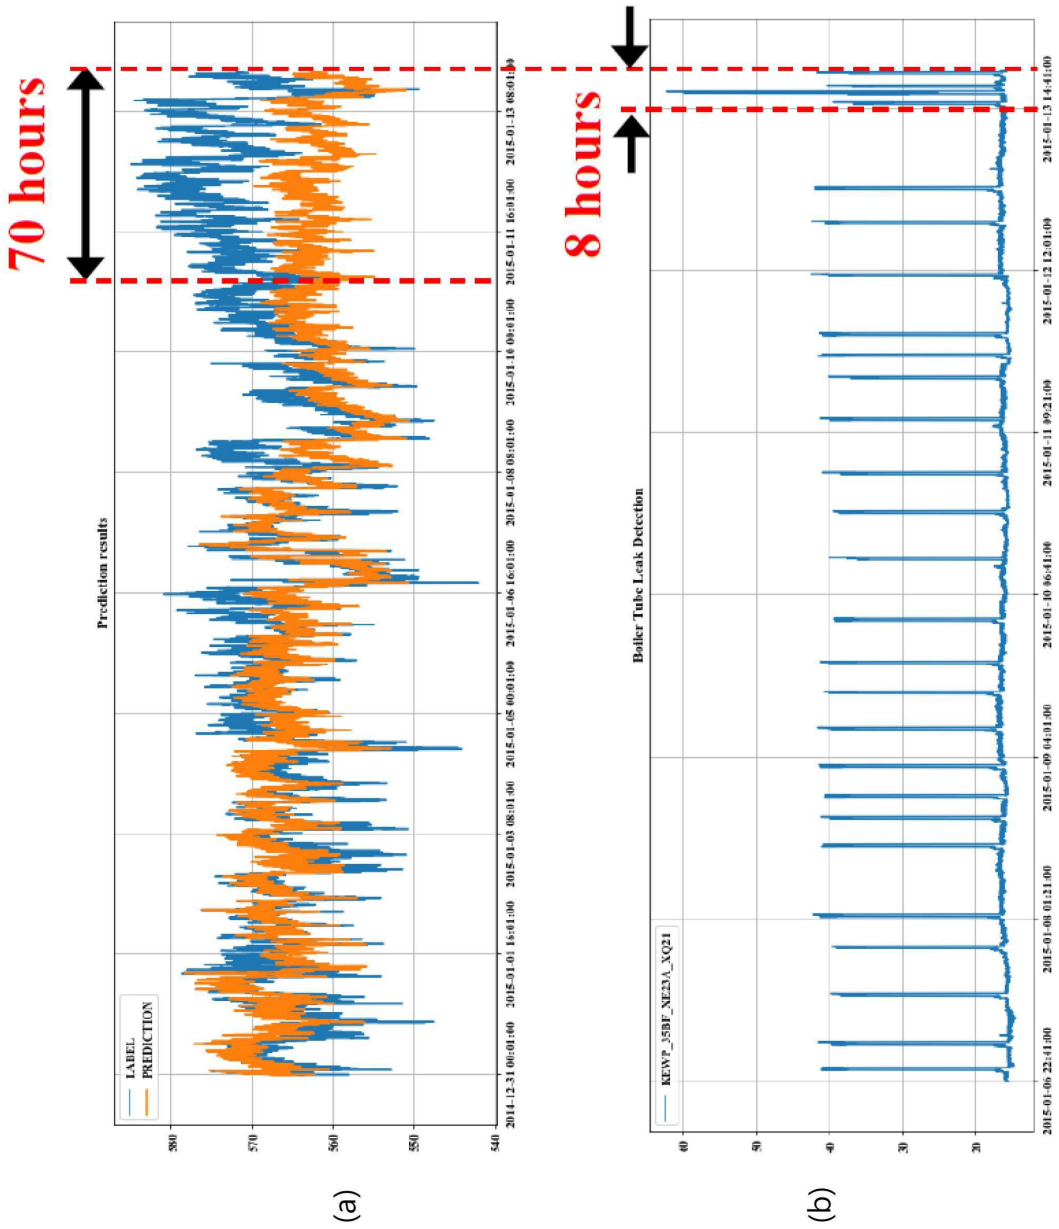
도면10


Ground truth
predicted
600
595
590
585
580
575
570
565
0
2000
4000
6000
8000
10000
(a)
Prediction error
Probability
Error
1.0
0.8
0.6
0.4
0.2
0.0
0
2
4
6
8
(b)

도면11


(a)
(b)
훈련 데이터
검증 데이터
시험 데이터
8
1
1
1
2017-01
2017-03
2017-05
2017-07
2017-09
2017-11
2018-01
2017-06-10
2017-06-24
2017-07-08
2017-07-22
2017-08-05
2017-08-19
2017-09-02

도면12


70 hours
8 hours
Prediction results
LABEL
PREDICTION
Boiler Tube Leak Detection
KEWP_35BF_NE23A_XQ21
(a)
(b)

도면13

