

Detects abnormal behavior using motor power consumption

KiHwan Kim*, Su-Mi Ryu*, Min-Kyu Kim*, Young-Jin Kang**, HyunHo Kim**, HoonJae Lee***, Jin-Heung Lee****

Abstract

In this paper, we used LSTM as a method to detect abnormal behavior of motors. We fixed the high layout size to 1 and changed the range of the input values and the neural network structure to see what change in power consumption prediction. Now, as the fourth industrial revolution era, smart factories are attracting attention. All the physical actions of smart factories are done using motors. Continuous monitoring of motor malfunctions helps to detect malfunctions and efficient operation. However, it is difficult to acquire the power consumption constantly due to the influence of the noise. We have experimented with a simple experimental environment, a method of predicting similarity to input data by adjusting the range of the input data or by changing the neural network structure.

▶ Keyword: Motor, AI, Prediction, Intrusion Detection, Smart Factory

1. Introduction

정보화 사회에서는 누구든지 정보를 생산하고 불특정 다수의 사람들이 소비하는 과정이 끊임없이 반복된다. 4차 산업 혁명의 주요 키워드로 꼽히는 인공지능(Artificial Intelligent)은 소프트웨어의 기술을 활용하여 인간의 뇌를 모방하는 기술로 상황 파악 및 판단하는 기술이다[1, 2]. 현재 인공지능은 사람이 사물을 인식하고 판단하는 수준과 비교할 수 없을 정도로 놀라운 발전 하고 있다[3]. 이와 같은 인공지능의 발전 속도는 방대한 양의 데이터를 학습 정보를 활용하여 인공신경망(Artificial Neural Network) 기술의 많은 연구와 성과가 있었기에 가능했다[4]. 인공신경망의 특징은 학습 데이터 유형과 예측 결과를 종합적으로 판단하여 적합한 인공신경망을 구성과 수많은 학습 과정을 거쳐서 임의의 데이터에 따른 예측 및 이상행위 탐지가 가능하다는 것이다[5]. 이와 같은 예측 기술을

스마트팩토리(Smart factory)에 활용할 수 있다면 적은 비용으로 관리 및 생산이 가능하게 될 것이다. 그러나 이상적인 스마트팩토리 운영은 사람이 관여하지 않고 올바른 결과물을 얻는 것이다. 따라서 스마트팩토리 스스로 상태점검을 할 수 있어야 하며, 이상행위를 감지한 경우 즉각적인 알람이 이루어져야 한다. 이에 스마트팩토리에서 유일하게 전기 에너지를 물리적인 동작으로 변동시킬 수 있는 모터를 대상으로 소비전력 예측을 통해 생산과정중 이상행위 탐지를 시도해볼 수 있다.

본 논문에서는 스마트팩토리의 동작행위를 모방할 시스템을 아두이노로 구성하고 모터의 소비전력을 측정하여 인공신경망에 예측 정확도를 실험한다. 2장은 인공신경망 유형을 살펴본다. 3장에서 실험에 사용될 데이터를 수집하는 방법을 소개하고 모터의 실시간 전력에 관한 데이터를 학습하여 도출된 실험

• First Author: KiHwan Kim, Corresponding Author: HoonJae Lee

*Ki-Hwan Kim (ghksdl90@naver.com), Dept. of Computer Science, Dongseo University

*Su-Mi Ryu (kshong@korea.ac.kr), Dept. of Computer Science, Dongseo University

*Min-Kyu Kim (alsrb1030@naver.com), Dept. of Computer Science, Dongseo University

**Young-Jin Kang (youngsil.lee0113@gmail.com), Dept. of Ubiquitous IT, Dongseo University

**HyunHo Kim (feei_@naver.com), Dept. of Ubiquitous IT, Dongseo University

***HoonJae Lee (hjlee@dongseo.ac.kr), Dept. of Information and Communication Engineering, Dongseo University

****Jin-Heung Lee (jhlee@daun.co.kr), Daun Information & Communication Co

• Received: 2018. 10. 01, Revised: 2018. 10. 22, Accepted: 2018. 10. 22.

• This work was supported by the Technological Innovation R&D Program (Assignment number : S2457495) funded by the Small and Medium Business Administration(SMBA, Korea) and also supported by Institute for Information & communications Technology Promotion(IITP) grant funded by the Korea government(MSIP) (No.2018-0-00245, Development of prevention technology against AI dysfunction induced by deception attack).

결과를 분석하여 이상행위 탐지 및 학습모델의 기준점으로 활용가치 여부를 확인한다. 4장에서 결론 및 추후 연구 진행방향에 대하여 제시한다.

II. Related Research

1. Smart factory

스마트팩토리란 사람이 일일이 제품을 조립하고 포장하고 기계를 점검할 필요 없이 모든 과정이 자동으로 이뤄지는 공장을 말한다. 스마트팩토리는 사물인터넷 센서와 카메라를 활용하여 공정과정의 불순물 유입을 경고 및 제거하거나 출하 데이터를 기반으로 설비 이상 징후를 파악하여 효율적인 운영을 돕는다. 지금까지의 공장 운영방식은 각각의 공정별로 자동화가 이뤄지는 탓에 인접한 공정과정에서 문제가 발생하더라도 사람이 판단하고 조작해야 했다. 하지만 미래 지향적인 스마트팩토리는 모든 설비나 장치가 무선통신으로 연결돼 정보를 주고받고, 모든 공정을 실시간으로 관찰하여 AI를 활용한 분석·판단으로 최적의 생산 환경을 스스로 보정할 수 있는 기능을 희망하고 있다. 본 논문에서는 물리적인 움직임을 담당하는 모터의 전류를 활용하여 이상행위 탐지에 활용이 가능한 여부를 모의실험을 통해 알아보았다.

2. Types and Characteristics of AI

2.1 RNN(Recurrent Neural Network)

RNN은 각각의 입력을 하나의 요소로 규정하여 숨겨진 메모리를 활용하여 모든 과거의 결과를 암시적으로 포함하는 상태를 유지한다[6]. [Fig. 1]의 왼쪽은 RNN의 간단한 구조를 나타내며, 입력(x), 내부 상태(s), 출력(o)과 동일한 가중치 (U, W, V)로 볼 수 있다. 하나의 입력과 출력을 가지는 구조를 노드라고 하며, 이를 시간별로 나눈다면 [Fig. 1]의 오른쪽과 같이 무수히 많은 노드가 연결되면서 복잡한 연산 구조를 가지게 된다.




Fig. 1. RNN structure and operation method[7]

RNN은 일반적인 가중치를 조정하기 위하여 인공신경망과 비슷하게 가중치를 보정하기 위하여 경사 하강법(Gradient Descent)과 역전파(Backpropagation)를 활용하며, 다음과 같은 특징을 가지게 된다[9, 10].

- 입력과 출력의 길이가 동적이다.

- 내부 상태의 가중치가 각각의 시간에 따라 공유된다.
- 전체 노드의 손실은 각각의 시간에 따른 전체 손실의 합계이다.

따라서 RNN은 간단한 구조로 다양한 입력에 대응하여 지금까지 학습된 결과와 유사한 결과를 예측할 수 있다. RNN을 주로 활용하는 분야는 텍스트의 다음 문자를 예측하는 언어 번역 작업에서 주로 사용되고 있다.

이때, RNN의 동작방식을 세부적으로 구분하자면 시간의 흐름에 따른 작업이기 때문에 역전파를 확장하고 이를 BPTT(Back Propagation Through Time)라고 한다[11]. BPTT는 반복적인 신경망 학습을 수행할 경우 다른 신경망 보다 월등히 빠른 성능을 보인다. 하지만 역전파 과정에서 기울기를 구하는 계산이 모두 곱셈으로 이루어져 있기 때문에 역전파 계산과정에서 기울기 수치가 0으로 수렴하면서 경사도가 사라지는 문제(Vanishing Gradients Problem)가 발생한다[12]. 이러한 문제를 해결하기 위해 입력, 과거 그리고 출력에 별도의 가중치를 기록하여 학습하는 방법을 연구하여 LSTM (Long Short-Term Memory models)이 제안되었다[13].

2.2 LSTM(Long Short-Term Memory models)

RNN은 BPTT로 인해 다른 신경망에 비하여 빠른 학습속도라는 장점보다 경사도가 사라지는 문제를 가지고 있었다. 경사도가 사라지는 문제는 반복 학습을 끊임없이 할 경우 학습 행위를 무의미하게 만드는 치명적인 문제로 유발될 수 있기 때문이다. 위와 같은 문제를 보완하기 위하여 제안된 신경 회로가 LSTM이다. LSTM은 장기 의존성 가중치를 잃지 않도록 가중치를 연산하는 방법을 곱셈이 아닌 덧셈으로 변경하여 경사도가 사라지는 문제를 피할 수 있게 하였다[14]. 또한 RNN과 마찬가지로 시계열적 특성을 가진 데이터의 패턴을 효과적으로 학습하는 것이 가능하다.

LSTM은 다양한 가중치를 가지도록 구성하여 시간과 입력수치에 따라 저장정보를 얼마나 가질지는 망각 게이트(forgot gate)에 의해 결정된다.




Fig. 2. LSTM structure and operation method[14]

3. Abnormal behavior detection method

3.1 Short-term electricity demand forecast

국내 전력 발전시설은 올바른 수요 예측을 수행하지 못하면 국가적으로 큰 문제로 이어지게 된다. 전력수요 예측을 위하여

기본적으로 전력 수요 패턴 분석을 수행하고 추가적으로 온도, 날씨, 공휴일 등의 외부 조건을 반영하여 정확도를 높이는 방법을 사용하고 있다. 단기간에 전력수요를 예측하는 방법으로 지수평활화 기법, 중회귀분석법, 신경회로망 기법, 퍼지 전문가 시스템 기법 등이 존재한다[6].

3.2 Strange behavior detection

실시간 전력수요를 외부의 잡음으로부터 보호받을 수 있는 환경에서 측정할 경우 측정 높은 데이터의 신뢰도를 기반으로 별다른 전처리과정 없이 사용이 가능하다. 하지만 개방된 환경에서 사용할 경우 측정된 데이터의 신뢰도를 항상 의심할 필요가 있으며, 딥러닝 학습 데이터로 사용하기에 부적합할 수 있다.

III. Experiments

스마트팩토리는 각종 모터(스텝모터, DC 모터)를 사용하는 기계를 동작시킬 경우 각종 노이즈를 제외하면 정상적인 운영에서는 주기별로 특유의 전력소모 패턴을 예측할 수 있다면 이상행위 탐지에 큰 도움이 될 수 있다. 그러나 공장 규모의 다양하고 방대한 데이터를 얻는 것에 제한이 있었다.

본 논문에서는 간단한 실험환경을 [Table 1]같은 환경을 구성하고 모터의 규칙적인 동작에 임의의 부하를 걸어 소비전력을 측정하고 AI를 통해 학습시킨 결과를 통해 예측과 실제 데이터간의 차이가 얼마만큼 발생하는지 확인하였다. AI 학습 환경은 Anaconda3를 기반으로 Tensorflow와 Keras를 사용하였으며, 각 학습에서 원본 데이터의 스케일 조정, 샘플수, 부분적 가중치 학습(Dropout) 등을 서로 다르게 설정하고 제한된 정보를 통해 미래 예측 모델로 활용하기 위하여 밀도 층(Dense Layer)은 1 그리고 배치 크기(batch_size)를 1로 고정하여 학습하였다.

Table 1. Experimental environment information.

	performance
CPU	i7-8700K
RAM	16GB
GPU	GTX 1070
AI	Tensorflow 1.8, Keras 2.1.6

1. Experimental environment and data generation process

실험환경은 [Fig. 3]과 같이 스텝모터와 전력측정센서를 아두이노에 연결하여 2가지 유형의 데이터를 생성하였으며, 각각의 스텝모터를 단방향으로 1~180도를 1초에 1도씩 회전시키고 무작위로 임의의 부하를 가하여 소비 전력을 측정하였다.

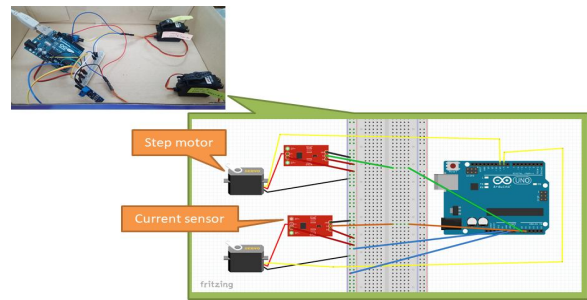


Fig. 3. Experimental environment using Arduino sensor

측정결과 [Fig. 4]처럼 각 라운드별 180개의 샘플 데이터를 23회 측정하여 총 4,163개 샘플을 획득하였다. 본 논문에서는 앞에서부터 순서대로 80:10:10의 비율로 나누어 각각 학습용 데이터, 학습 검증용, 학습용 및 학습 검증용으로 사용하지 않은 무작위 검증용 데이터로 사용하였다.




Fig. 4. Power consumption data according to motor operation

2. Learning method

2.1 LSTM memory = 32

AI 구조는 [Table 2]처럼 각각 3개의 LSTM에 32개의 메모리를 연결하고 부분적 가중치 학습을 0.2로 설정하여 마지막 구간에 밀도 층 함수를 통해 1개의 출력을 가지도록 설정해 보았다. 학습 데이터로 데이터 그룹을 20개씩 배치 크기를 1로 구성하여 총 100번의 학습을 수행하였다.

Table 2. AI learning data structure and parameters for experiment 1

Layer	Output Shape	Parameters
LSTM_1	(1, 20, 32)	4352
Dropout_1 (0.2)	(1, 20, 32)	0
LSTM_2	(1, 20, 32)	8320
Dropout_2 (0.2)	(1, 20, 32)	0
LSTM_3	(1, 32)	8320
Dropout_3 (0.2)	(1, 32)	0
Dense_1	(1, 1)	33
Total parameters : 21,025		
Trainable parameters : 21,025		
Inputs : (1, 20, 1)		
Outputs : (1, 1)		
Actual Input : (5760, 2)		
Actual Output : (4011, 1)		

첫 번째 스텝모터의 데이터를 활용하여 [Fig. 5]와 같이 임의의 데이터를 추출하여 예측시켰다. 학습결과 50번째 학습 구간을 벗어날수록 학습 데이터의 영향을 많이 받는 것을 볼 수 있었다. 모델은 200회의 학습 이후 예측 검증을 진행하였다.

학습된 AI에 임의의 데이터를 입력하여 [Fig. 6]과 같은 결과를 확인하였다. [Fig. 6]에서 실제 데이터는 파란색 실선으로 예측 데이터는 빨간색 실선으로 그려져 있다. 일부 실제 데이터가 예측과 겹쳐 보이지만 전체적으로 예측이 실패하였고 특히 0.2 이상으로 예측되는 구간이 전혀 없는 점과 임의의 데이터의 양상과 다른 흐름을 보이는 점은 이상행위 탐지의 지표로 활용하기에 적합하지 못한 것을 알 수 있었다. 해당 인공지능경망에는 오류값을 배제하기 위하여 부분적 가중치 학습을 적용하였으나 이것만으로는 오류 배제가 어려운 것으로 보인다. 이에 따른 문제로 원본 데이터 주기성 무시와 과도한 학습 또는 학습 데이터의 부족으로 나누어 보았다. 이때 학습 데이터 부족 문제는 본 논문에서 제외하고 주기성 보장에 초점을 맞추어 보았다.




Fig. 5. Loss change according to learning in experiment 1




Fig. 6. Power estimation result of experiment 1

2.2 LSTM memory : 18

앞서 주기 정보를 일정 부분 보완하기 위하여 동일한 데이터로 [Table 3]과 같이 메모리 공간을 18개로 데이터 변화에 따른 상호관계성을 낮추기 위해 부분적 가중치 학습을 0.1, 밀도층을 통해 1개의 결과를 가지도록 설정하였다. 학습 데이터로 데이터 그룹은 180개씩 배치 크기를 1로 구성하여 100번의 학습을 수행하였다.

이번 학습 구조는 많은 메모리를 활용하여 다양한 패턴을 기억하고 참조할 수 있는 것에 초점을 맞추었다. 그 결과 [Table 2]와 같이 층 파라미터수가 이전 실험에 비하여 약 7배 이상 증가한 것을 볼 수 있다.

Table 3. AI learning data structure and parameters for experiment 2

Layer	Output Shape	Parameters
LSTM_1	(1, 180, 18)	1440
Dropout_1 (0.1)	(1, 180, 18)	0
LSTM_2	(1, 180, 18)	2664
Dropout_2 (0.1)	(1, 180, 18)	0
LSTM_3	(1, 180)	143280
Dropout_3 (0.1)	(1, 180)	0
Dense_1	(1, 1)	181
Total parameters : 147,565		
Trainable parameters : 147,565		
Inputs : (1, 180, 1)		
Outputs : (1, 1)		
Actual Input : (4320, 2)		
Actual Output : (3276, 1)		

학습결과 손실률은 [Fig. 7]처럼 나타났으며, 학습수치와 검증수치가 거의 같은 변화를 보이고 있다. 수치의 변화가 거의 없는 것으로 보아 앞서 실험한 검증 데이터에서 문제점으로 지적된 과도한 학습 부분은 해결된 결과이다. 동일한 정보를 토대로 예측한 결과 [Fig. 8]과 같았다. 학습 결과 [Fig. 6]처럼 기준점을 벗어난 예측은 이루어지지 않으며, 예측이 원본 데이터와 많은 차이를 보였다. 또한 일부 데이터는 원본 데이터와 상호 대조되는 결과를 나타냈다.




Fig. 7. Loss change according to learning in experiment 2




Fig. 8. Power estimation result of experiment 2

두 가지 실험에서 예측이 원본 데이터와 비교하여 큰 오차를 보였다. 두 가지 실험을 통해 수정되어야 할 사항으로 원본 데이터 주기성을 고려하는 인공지능경망 구조와 과도한 학습을 경계해야 함을 확인하였다. 또 다른 부분으로 두 가지 실험의 임의의 데이터에 따른 손실 수치를 살펴보았다. 먼저 손실 함수는 평균 제곱 오차(mean_squared_error)로 설정하였다. [Fig. 6]은 손실 수치

가 0.03895902로 측정되었으며, [Fig. 8]은 0.00559098을 나타내었다. 손실 수치는 모델 예측과 실제 값과 발생한 차이를 의미하므로 수치적인 면에서 후자의 실험이 정확도가 높은 것으로 평가되고 있다. 하지만 정확도가 80%를 넘지 못하기 때문에 이를 개선하기 위하여 다른 방법을 시도해 보았다.

3. Learning by modifying the data scale

이전 학습 결과에서 기준점 이상의 예측이 거의 이루어지지 않을 것을 보완하고자 학습 데이터를 [Fig. 4]에서 2.5를 기준으로 아래의 수치를 위로 반전시켜 [Fig. 9]처럼 0.0에서 1.0까지 작은 범위로 압축시켰다. 전력 수요는 얼핏 규칙성을 보이는 데이터로 보이지만 각도 데이터에 비하여 불규칙적인 양상을 보였다. 이외에 [Fig. 10]의 추가로 각도 정보를 학습에 사용하였다.




Fig. 9. Absolute value conversion according to average measurement amount of power consumption data according to motor operation




Fig. 10. Angle data according to motor operation

3.1 Use angle data

학습데이터가 이전 방식과 달리 0.0~1.0 사이의 정해진 구간에서 학습하여 기율기의 손실을 효과적으로 얻도록 구성해보았다. AI 학습 구조는 [Table 4]처럼 2개의 LSTM을 부분적 가중치 학습과 혼합하여 구성하였다. 이때, 총 파라미터 수는 첫 번째 실험보다 적은 12,866개로 설정하였다. 이를 통해 LSTM과 부분적 가중치 학습의 누적 계층이 이전 학습 모델에 비하여 적으며, 앞서 실험한 계층보다 적을 경우 어떤 변화를 보일지 실험해보았다. 학습 데이터로 데이터 그룹을 17개씩 배치 크기를 1로 구성하여 100번의 학습을 수행하였다.

Table 4. AI learning data structure and parameters for experiment 3

Layer	Output Shape	Parameters
LSTM_1	(1, 17, 32)	4480
Dropout_1 (0.05)	(1, 17, 32)	0
LSTM_2	(1, 32)	8320
Dropout_2 (0.05)	(1, 32)	0
Dense_1	(1, 1)	66
Total parameters : 12,866		
Trainable parameters : 12,866		
Inputs : (1, 17, 2)		
Outputs : (1, 2)		
Actual Input : (1495, 17, 2)		
Actual Output : (1495, 2)		

학습결과 [Fig. 11]처럼 학습이 거듭되면서 학습수치와 검증수치가 급격하게 떨어지면서 20번째 학습 이후부터 큰 변화가 없는 것으로 나타난다.




Fig. 11. Loss change according to learning in experiment 3

검증결과 [Fig. 12]처럼 초반에는 비교적 예측과 원본 데이터가 일치했지만 [Fig. 13]의 각도 예측이 어긋나기 시작하면서 예측 결과의 정확도가 크게 낮아지는 모습을 보였다. 인상적인 부분은 각도 예측이 일치하는 부분은 전체적으로 전력 예측도 거의 일치하는 모습을 보였다.




Fig. 12. Power estimation result of experiment 3



Fig. 13. Angle estimation result of experiment 1

3.2 Exclude dropout function from learning

마지막으로 이전 학습에서 2.5mA 이상의 예측이 비교적 적은 것을 보완하기 위하여 [Fig. 9] 학습 데이터를 음수로 반전하고 부분적 가치치 학습을 모두 제거해보았다. 비록 오차가 심하더라도 학습에 활용하기로 하여 LSTM 메모리를 179개로 [Table 5]와 같은 구조로 학습을 진행하였다. 그 결과 총 파라미터 수가 21,025개로 지금까지 수행한 모든 모델보다 상태를 저장할 수 있게 되었다. 학습 데이터로 데이터 그룹을 179개씩 배치 크기를 1로 구성하여 50번의 학습을 수행하였다.

Table 5. AI learning data structure and parameters for experiment 4

Layer	Output Shape	Parameters
LSTM_1	(1, 179, 32)	4352
LSTM_2	(1, 179, 32)	8320
LSTM_3	(1, 32)	8320
Dense_1	(1, 1)	33
Total parameters : 21,025		
Trainable parameters : 21,025		
Inputs : (1, 179, 1)		
Outputs : (1, 1)		
Actual Input : (3277, 179, 1)		
Actual Output : (3277, 1)		

학습 결과 [Fig. 14]처럼 손실 감소는 모두 비슷하게 수렴하여 낮아졌다. 또한 30번의 학습 이후부터는 손실이 거의 발생하지 않는 것으로 나타났다. 실험결과 [Fig. 15]처럼 시간이 경과할수록 예측이 크게 어긋나는 모습을 보였다.




Fig. 14. Loss change according to learning in experiment 4




Fig. 15. Power estimation result of experiment 4

4. Experimental Results

본 논문의 실험들은 서로 다른 기준치를 가진 데이터, 메모리, 인공 신경망 그리고 학습 횟수를 가지고 있고 배치 크기가 1인 공통점이 존재한다. 학습 결과를 평균 제곱 오차로 각 실험별 손실을 수치로 나타낸 결과 [Table 6]처럼 손실 수치를 기준으로 실험 2와 실험 4가 적절한 학습이 진행된 것, 실험 1은 과도한 학습이 진행된 것, 실험 3은 추가적인 학습이 필요한 것으로 보인다.

실험 결과 AI 단독으로 이상행위를 탐지하는 것이 불가능했다. 따라서 AI를 통해 예측되는 최소, 최대 구간과 임의의 오차 허용 범위를 지정하여 사용하는 것이 합당할 것으로 보인다.

Table 6. Loss score for each experiment (Rounded to 9 decimal places)

	Train Score	Validation Score	Test Score
Experiment 1	0.00580724	0.03618324	0.03895902
Experiment 2	0.00536132	0.00580908	0.00559098
Experiment 3	0.00548329	0.01197435	0.01280079
Experiment 4	0.01622732	0.01732073	0.01663422

IV. Conclusions

본 논문은 AI 단독으로 모터의 소비전력을 얼마나 정확하게 예측할 수 있는가에서 시작되었다. 반복적인 행위는 규칙성이 존재하고 시계열과 같은 반복적인 특성을 가진다. 하지만 모터의 경우 노이즈가 불규칙하고 외부 환경(온도, 습도, 공급 전력의 불규칙성 등)에 많은 영향을 받으며, 초기에 수집된 데이터에도 잡음이 추가된 데이터 집합이다. 따라서 AI가 얼마만큼 잡음을 배제하고 학습할 수 있는 점이 주요 핵심이었다.

실험 결과 예측은 실패했다. 동일한 데이터를 다양한 방법으로 가공하여 학습시켜도 소비전력의 변화만으로 예측이 불가능한 것을 확인하였다. 다만 [Fig. 7]과 [Fig. 9]를 통해 대략적인 예측은 가능함을 보였다. 추후 대략적인 예측결과를 활용하여 구간별 최소, 최대 수치의 범위와 다양한 특징을 학습시키는 것이 가능하다면, 스마트 공장의 이상행위 탐지의 척도로 활용이 가능할 것으로 기대한다.

REFERENCES

- [1] Jo Seongjun, Gang Seokho, "Industrial Applications of Machine Learning (Artificial Intelligence)," *Industrial Engineering Magazine*, Vol. 23, No. 2, pp. 34-38, June. 2016.
- [2] Gong Mansik, Chae Hongjun, Yu Bohyeon, "Trends and Prospects of Internet (IoT) Technology," *Journal of the KSME*, Vol. 56, No. 2, pp. 32-36, Feb. 2016.
- [3] Choe Yerim, Gim Gwanho, "Artificial intelligence overview and application examples," *Industrial Engineering Magazine*, Korean Institute of Electrical Engineers, Vol.23, No.2, pp. 23-29, May. 2016.
- [4] Da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B., & dos Reis Alves, S. F. "Artificial neural networks," Cham: Springer International Publishing, 2017.
- [5] Gu Hyeongil, "Artificial Intelligence and Deep Running Trends," *The Korean Institute of Electrical Engineers*, Vol.67, No.7, pp. 7-12, July. 2018.
- [6] Caterini, A. L., & Chang, D. E. "Deep Neural Networks in a Mathematical Framework," Springer International Publishing, 2018.
- [7] Recurrent Neural Networks Tutorial, Part 1 - Introduction to RNNs, <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>
- [8] Yann LeCun, Yoshua Bengio, Geoffrey Hinton, "Deep learning", *nature*, Vol. 521, pp. 436-444, 28, May. 2015.
- [9] Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. "Deep learning (Vol. 1)," Cambridge: MIT press, 2016.
- [10] Ian Goodfellow, Yoshua Bengio, Aaron Courville, "Deep Learning," MIT Press, pp. 196, 2016.
- [11] Talwar, C., & Ollivier, Y. "Unbiasing Truncated Backpropagation Through Time," *arXiv preprint arXiv:1705.08209*, 2017.
- [12] Pascanu, Razvan, Tomas Mikolov, and Yoshua Bengio. "On the difficulty of training recurrent neural networks," *International Conference on Machine Learning*, 2013.
- [13] Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. "LSTM: A search space odyssey," *IEEE transactions on neural networks and learning systems*, Vol. 28, No. 10, pp. 2222-2232, 2017.
- [14] Understanding LSTM Networks, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Authors



Ki Hwan Kim received the B.S., M.S. degree in Computer Networking from Dongseo University, Republic of Korea in 2015. He current research interests are in Cryptography, Information Security and Network Security. Mr. Kim is now a MS.

student in the ubiquitous IT department at Dongseo Graduate School in 2017. He research interests are cryptography, network security and Artificial Intelligent.



Su-Mi Ryu received the B.S. degree in Computer Networking from Dongseo University, Republic of Korea in 2015. He current research interests are in Cryptography, Information Security and Network Security. Ms. Ryu is now a M.Phil.

student in the ubiquitous IT department at Dongseo Graduate School in 2017. He research interests are cryptography, Information security and network security.




Min-Kyu Kim received the B.S. degree in Computer Networking from Dongseo University, Republic of Korea in 2017. He current research interests are in Cryptography, Information Security and Network Security. Mr. Kim is now a M.Phil.

student in the ubiquitous IT department at Dongseo Graduate School in 2017. He research interests are cryptography, Information security and network security.



Young-Jin Kang received the B.S., M.S. degree in Computer Networking from Dongseo University, Republic of Korea in 2015. He current research interests are in Wireless Sensor Networks, Cryptography and Network Security, Side Channel

Analysis. Mr. Kang is now a MS. student in the ubiquitous IT department at Dongseo Graduate School in 2015. He research interests are Network Security, Side Channel Analysis.



HyunHo Kim received the B.S., M.S. degree in Computer Networking from Dongseo University, Republic of Korea in 2013. He current research interests are in Digital Forensic, Information Security and Network Security. Mr. Kim is now a MS.

student in the ubiquitous IT department at Dongseo Graduate School in 2015. He research interests are Digital Forensic, Information security and network security.



Hoon-Jae Lee received the B.S., M.S. and Ph.D. degree in Electrical Engineering from Kyungpook national university in 1985, 1987 and 1998, respectively. Dr. Lee had been engaged in the research on cryptography and network security at

Agency for Defense Development from 1987 to 1998. Since 2002 he has been working for Department of Computer Engineering of Dongseo University as an associate professor, and now he is a full professor. His current research interests are in security communication system, side-channel attack, USN & RFID security. He is a member of the Korea institute of Information security and cryptology, IEEE Computer Society, IEEE Information Theory Society and etc



Jin-Heung Lee received the B.S. degree in Information and Communication Engineering from Dongseo University in 1998 and M.S. and Ph.D. degree in Information Security from Pukyong National University in 2000 and 2007

respectively. Dr. Lee is a research associate professor at Dongseo University from 2001 to 2015. Since 2015 he has been working for Daun Information & Communication Co. He is interested in network security, automatic control system security management, IoT platform, smart factory, and others.