

# 매장 에너지 절감을 위한 LSTM 기반의 전력부하 예측 시스템 설계

최종석\*, 신용태\*\*

## LSTM-based Power Load Prediction System Design for Store Energy Saving

Jongseok Choi\*, Yongtae Shin\*\*

**요약** 소상공인 업체들의 매장은 다수의 전기기기를 사용하는 매장이 대부분이며 특히 냉장 시스템을 이용한 매장이 많아 여름, 겨울의 계절 변화에 따라 전력의 수요가 변화하고 온도의 급변에 냉장 시스템을 적용시키지 못할 시에 많은 전력부하가 발생되어 심할 경우 전력공급의 차단이 발생됨에 따라 매장 내 자산에 손실을 미칠 수 있다. 이에 따라 본 논문에서는 매장의 에너지 수요율을 측정하고 에너지를 절감하기 위하여 LSTM 기반의 전력 부하 예측 시스템을 설계하였다. 이는 데이터 기반의 중소 매장용 전력절감 시스템으로 사용될 수 있어 향후 소상공인 데이터 기반의 전력 수요 예측 시스템으로 사용되고, 전력 부하로 인한 피해 방지 분야에서 사용될 것으로 예상된다.

**Abstract** Most of the stores of small business owners are those that use a large number of electrical devices, and in particular, there are many stores that use a cold storage system. In severe cases, there is a lot of power load on the store, which can cause a loss to the assets in the store as the power supply is cut off. Accordingly, in this paper, an LSTM-based power load prediction system was designed to measure the energy demand rate of stores and to save energy. Since it can be used as a data-based power saving system for small and medium-sized stores, it is expected to be used as a data-based power demand prediction system for small businesses in the future, and to be used in the field of preventing damage due to power load.

**Key Words** : Data Mining, Data Analytics, Smart-Grid, Power Reduction, Store Data

### 1. 서론

소상공업체는 다수의 전기기기를 사용하는 매장으로, 전기료 절약을 위한 전력 절감 서비스가 필요하다. 특히, 전력량이 소상공업체의 매장에서 하절기와 동절기에 냉장 시스템에서 최대수요로 발생하고 있는 점을 고려하여 수요반응서비스를 통한 냉장시스템의 과전력 제어가 가능한 전력절감 시스템을 구축시 매장 내의 소비 전력을 절감할 수 있다.

이러한 소비 전력의 절감을 진행하기 위하여 현재의 매장들은 많은 IoT시스템을 통해 전력 데이터를 실시간으로 확인할 수 있는 기능이 갖추어져 있어 인력을

통해 과전력 과온도에 도달 시 조절하는 체계가 마련되어 있다. 다만 이는 인력을 사용하여야 한다는 점에서 지속적이고 체계적인 전력 제어가 어려운 실정이다.[1] 본 연구는 IoT 및 스마트그리드를 기반으로 전력의 사용량을 확인할 수 있는 시스템에서 LSTM(Long Short-Term Memory)기반의 데이터 분석으로 수요관리 최적화 제어를 통하여 매장 에너지 관리를 진행하고자 한다. 특히 전력 사용이 가장 많은 압축기를 사용하는 냉장 시스템에 중점을 두어 제어하고자 한다.

\*Spartan Software Education Institute, Soongsil University (jschoi@ssu.ac.kr)

\*\*Corresponding Author : School of Computing, Soongsil University (shin@ssu.ac.kr)

Received August 13, 2021

Revised August 16, 2021

Accepted August 21, 2021

## 2. 관련연구

### 2.1 시계열 데이터 예측 알고리즘

#### 2.1.1 순환신경망 알고리즘

순환신경망 알고리즘(RNN, Recurrent Neural Network) 히든 노드가 방향을 가진 엣지로 연결되어, 각 노드가 순환 구조를 이루는 인공신경망으로 음성, 문자, 시계열 등 순차적으로 구성된 데이터 처리에 적합하다. <그림 2>와 같이 입력( $x$ )를 받아 출력( $h$ )를 만들고, 출력을 다시 입력으로 전환하는 순환 구조를 이루며 각 타임 스텝( $t$ )마다 순환 뉴런을 구성하여 타임 스텝별 입력( $x_t$ )와 출력( $h_t$ )를 나타낸다.[2]




그림 1. RNN의 순환 뉴런  
Fig. 1. Circulatory neurons in RNN

각 순환 뉴런은 가중치  $w_x$ 와  $w_y$ 를 가지는데,  $w_x$ 는  $x_y$ 를 위한 것이고  $h_x$ 는 타임 스텝의 출력  $h_{t-1}$ 을 위한 것으로 순환 층 전체와 함께 가중치 벡터  $w_x$ 와  $w_y$ 를 행렬  $W_x$ 와  $W_y$ 로 나타낼 수 있다. 타임 스텝  $t$ 에서의 미니배치의 입력을 행렬  $X_t$ 로 나타내어 아래 식과 같이 순환 층의 출력을 계산할 수 있다.

#### 2.1.2 장단기메모리 알고리즘

인공지능 알고리즘의 종류중 하나인 LSTM은 순환 신경망구조로 RNN의 문제점인 데이터의 장기 의존성의 한계를 해결하여 시계열 데이터 학습 및 예측에 높은 성능을 나타내는 알고리즘이다.[3]




그림 2. LSTM의 구조  
Fig. 2. Structure of LSTM

LSTM은 RNN처럼 활성화 함수 tanh를 무조건 연산하지 않고 gate를 통해 연산 제어를 한다. <그림 2>와 같이 LSTM은 우선적으로 Cell State에서 어떤 정보를 망각 게이트에서 버릴지 결정한다. 이때, 입력 게이트의 Sigmoid layer에서 이를 결정하고, 이후 Cell Stage에서 어떤 새로운 정보를 저장할지 결정한다. 이후 Cell State를 tanh layer를 통해 계산된 Sigmoid layer의 출력게이트와 곱하여 결과를 생성한다. 이러한 단계에서 사용된 LSTM 입력 게이트, 망각 게이트, 출력 게이트의 상세 내용은 아래 <표 1>과 같다.[4]

표 1. 게이트 설명  
Table 1. Gate Description

Gate	Description
Forget Gate	Activation function Sigmoid is used to determine which information to forget from the input and output of the previous cell.
Input Gate	Decide which of the input( $x_t$ ) information and the cell output( $h_{t-1}$ ) information at time to be memorized as the cell state
Output Gate	It decides which part of input or memory to output as output, and uses Back Propagation Through Time (BPTT) like RNN as a way to reduce errors

### 2.2 전력 제어 장치의 구조

전력 관리의 대상 중 핵심 부분인 냉각장치는, 동작 전원이 공급되는 전원부와, 전원부로부터 입력되는 전원을 직류전원으로 변환하는 컨버터부와, 컨버터부의 출력을 모터 구동을 위한 교류로 변환하는 인버터부와, 인버터부로부터 동작전원을 입력받아 동작되는 압축기를 포함하여 구성된다.[5]

또한, 냉각장치는 외부와 데이터를 송수신하는 통신부와, 냉각장치 내부에 설치되어 온도를 측정하는 온도 센서와, 컨버터부 및 인버터부의 구동을 제어하고, 온도 센서로 부터 감지되어 입력된 온도 값에 따라 압축기 모터의 구동을 제어하는 제어부를 포함한다.

온도센서는 냉각장치의 냉각실 내부에 설치될 수 있으며, 공기조화기의 경우는 실외기 또는 실내기 양쪽에 모두 설치될 수 있다. 온도센서가 측정한 온도 데이터는 제어부로 전송된다.

제어부는 컨버터부 또는 인버터부로 스위칭 신호를 인가하여 컨버터부가 전원부로부터 입력되는 전원을 직류의 전원을 출력하도록 하며, 인버터부로부터 압축기를 위한 전원이 공급 되도록 한다. 이러한 구동의 제어는 아래와 같은 운전을 기본으로 하여 각 운전모드에 따라 저온대기 및 고온대기를 진행한다. 이러한 사항을 기반으로 냉각장치의 내부 기반이 구성되며, 냉각 장치의 운전모드가 동작한다.




그림 3. 냉각장치의 운전모드 구성  
Fig. 3. Configuration diagram of operation mode of cooling system

냉각 장치의 운전모드는 <그림 3>과 같이 온도에 따라 동작한다. 제어부는 실내 또는 냉각실의 온도가 고온허용온도에 도달하면 온도를 저온전환 모드로 변경한다. 이후 정해진 저온전환시간 동안 저온허용온도에 도달하도록 압축기를 제어하며, 저온 전환모드 및 저온 전환단계 진입시점에 계산된 압축기의 용량 또는 압축기 인가 전류량에 따라 온도변화와 다르게 온도가 급격히 감소한다면 제어부는 저온대기 제어를 수행한다. 이때, 만약 사용자가 저온으로 설정한 온도에 도달한 상태에서 냉동실의 문을 여는 행동이나, 기타 온도 상승 요인발생으로 정해진 저온허용온도에 도달하기 어렵다고 판단되면 제어부는 압축기의 전류량을 증가시킬 수 있다. 또한, 고온대기모드 및 고온전환단계는 진입시점에 계산된 압축기의 용량 또는 압축기 인가 전류량에 따른 온도 변화와 다르게 온도가 변화하지 않는다면 수행된다.[6]

이에 따라, 사용자가 설정한 온도에 도달한 시점에서 변화된 온도가 낮다면 전력제어장치를 통해 압축기, 공조기에 사용되는 전류량을 낮출 수 있다. 반대로 사용자가 설정한 온도보다 높게 도달되면, 전류량을 증가시

킨다. 다만 전류량이 급격히 높아지거나, 급격히 낮아지는 경우 과전력이 발생하여 부하 및 전력낭비가 발생될 수 있고 매장 내 자산과 시스템에 경제적 문제를 발생시킬 수 있다. 이에 따라 매장 내에서 사용되는 냉방 장치의 운전 상태와 압축기들에 대한 과전력 데이터, 일반 전력 데이터들을 분류 수집하여 판단한 후 실시간으로 분석하여 과전력·저전력으로 발생할 수 있는 전력부하 등의 문제점을 선제적으로 파악하여 관리할 필요성이 있다.

### 3. 제안하는 시스템 설계 방안

제안하는 전력부하 예측 시스템은 3가지의 단계로 이루어진다. 첫 번째 단계로는 데이터의 수집 단계에서 나타날 수 있는 결측치를 제거하여 예측의 정확도를 높인다. 두 번째는 얻어진 데이터에 대해 클러스터화하여 전력사용 시스템인 공조기, 압축기, 냉난방기 별 과전력 데이터부분과 일반적 전력의 데이터를 분류하여야 한다. 세 번째로 클러스터링된 데이터를 학습하여 전력 절감 서비스를 위한 예측 데이터를 생성한다.

#### 3.1 결측 데이터의 처리

전력 데이터 특성상 센서에서 수집되는 데이터이기 때문에 누락되는 데이터가 종종 발생하여 결측데이터를 처리해야 학습의 정확도를 향상시킬 수 있다.

무선환경 및 데이터의 통합 중 나타날 수 있는 가장 많은 빈도의 결측은 무작위적 결측치로 발생기제를 구분할 수 있음에 따라 보완할 수 있는 결측으로 판단되며, 분석에 필요한 표본의 수에 따라 통계적 검정이 가능한 정도로 판단된다.




그림 4. MICE 처리 흐름도  
Fig. 4. MICE processing flow chart

<그림 4>와 같이 형태에서 MICE를 통해 전력제어의 데이터를 imputation화 하고 m개의 완성된 데이터 셋

으로 분석을 진행한다. 이에 따라 불확실성이 고려된 전력제어 데이터 확인할 수 있게 되고 이 데이터에 대하여 평균, 분산, 신뢰구간을 계산한 결과를 합쳐 결측을 해결한다.

### 3.2 패턴화를 위한 데이터 클러스터링

매장 전력의 운용은 공조기, 압축기, 냉난방기 별 과 전력 데이터부분을 나눌수 있는 데이터와 일반적 전력의 데이터를 분류할 수 있고, 이러한 데이터를 기반으로 저온전환모드와 일반모드, 고온전환모드, 절전모드의 변화에 따라 전력제어의 변환이 이루어지고 있다. 이는 한 점포의 상태를 말하며, 여러 점포 시스템의 일괄 통제 및 패턴분석을 위해서는 해당 시스템의 데이터화가 필요하다. 또한 패턴화는 인공지능을 이용한 예측 시스템 개발 시 반드시 필요한 요소 중의 하나로 이미 전력의 에너지 삭감을 이루고 있는 점포의 상태를 클러스터링을 통한 패턴화하로 저장하는 중요하며 이를 위한 단계는 아래 <그림 5>와 같다. 패턴화는 에너지 사용량을 과전력 데이터부분과 일반적 전력의 데이터로, 사용된 전력 모드, 압축기, 공조기로 분류하여 나누고 시간 단위를 기반으로 K-means 클러스터링을 통해 패턴화 한다. 이를 클러스터간의 거리로 나누어 압축기, 공조기별 및 전력 모드별 클러스터로 그룹 분류를 실시하여 그룹화를 진행한다.

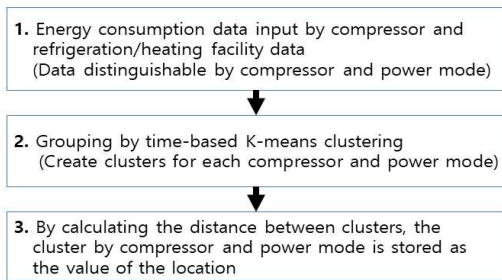


그림 5. 패턴화 및 그룹화 흐름도  
Fig. 5. Patterning and Clustering Flowchart

### 3.3 LSTM을 통한 예측 시스템 설계

3.2에서 생성된 그룹 데이터를 기반으로 전력 사용에 대한 시간대별 사용량을 예측하기 위해서는 머신러

닝을 통한 학습을 진행하여야 한다. 클러스터링을 통해 생성된 데이터는 기본적으로 전력 데이터임에 따라 시계열 데이터의 구조를 가짐에 따라 LSTM의 학습이 적절한 모델이다. 이러한 전력기반의 클러스터링 데이터를 학습하기 위한 LSTM은 Tensorflow와 Keras, Python 3.x 기반으로 아래와 같이 설계하였다.

- 1) 전력 데이터의 x축은 시간이 되어야 함에 따라 데이터가 기록된 시간 컬럼을 인덱스로 설정
- 2) 인덱스는 시계열 데이터 인덱스로 설정하기 위해 pandas의 datetime함수와 DatetimeIndex 함수를 사용하여 시계열 인덱스로 설정
- 3) numpy의 MinMaxScaler와 pandas의 DataFrame 통해 학습데이터와 테스트 데이터의 데이터 정제를 진행
- 4) 학습 타겟이 되는 전력 데이터 컬럼을 data로 지정하고, 미리 지정해 놓은 시계열 인덱스로 설정
- 5) 학습 타겟이 되는 전력 컬럼을 data로 지정하고, 미리 지정해 놓은 시계열 인덱스로 설정
- 6) 학습 데이터와 예측 테스트 데이터의 X축과 Y축을 구분하여 변수에 저장하고, 각각 데이터의 null 값을 제외하는 dropna 함수를 사용하여 클러스터링 단계에서 발생되었을 수 있는 결측치를 제거함
- 7) 시계열 학습을 위한 LSTM 모델을 생성하고, LSTM의 셀 개수를 100개, 인풋 웨이프를 12개로 설정
- 8) 학습 모델은 평균제곱오차를 사용하고, 옵티마이저는 adam을 사용
- 9) 모델의 fit 함수를 통해 학습데이터의 x축과 y축의 데이터를 지정하고, 5회 반복 학습으로 설정한 후 save\_weights 함수를 사용하여 학습 모델을 저장함
- 10) 모델의 predict 함수를 사용하여 예측 테스트 데이터의 x축인 시계열 데이터로 y축의 전력 데이터를 예측 함

## 4. 성능평가

매장 내에서 사용되는 냉방 장치의 운전 상태와 압축

기들에 대한 전력 데이터들을 수집하고 분류하여 학습한 결과를 알고리즘의 정확도 형태로 판단하여 실제 소상공인 매장에서 사용되었을 때, 전력관리가 충분히 가능한지를 판단하기 위하여 수집 시 발생할 수 있는 결측 데이터의 처리가 가능한지 여부를 살펴보고 각 데이터가 그룹화 패턴화되는 데에 문제가 없는지 확인하였다. 또한, 전력예측에 대하여 제시한 알고리즘이 알고리즘의 정확도 측면에서 문제가 없는지 판단하였다. 이를 위한 데이터로는 실제 소상공 매장 중 베이커리에서 사용되는 전력 데이터를 1개월 동안 수집하여 활용하였다.

### 4.1 결측 데이터의 처리 결과

확인된 결측 데이터의 빈도와 결측 데이터의 패턴을 분석하여 누락된 값을 찾아내고 이는 dataframe에 있는 값을 이용해 예측하여 채워 넣었다. 누락된 자료가 채워진 완성된 데이터 세트를 여러 개 만들어 내고 각각의 세트에 with함수를 사용하여 통계 모형을 순서대로 적용하였다.




그림 6. MICE를 통한 데이터 대체 전(위) 후(아래)  
Fig. 6. Before (up) and after (down) data replacement through MICE

이 후 pool 함수를 사용하여 분석 결과를 통하여 결측 데이터를 보완하였다. 이 결과 <그림 6>과 같이 MICE 알고리즘 실행 후 결측 데이터의 빈도와 패턴을 분석하면, 결측 데이터가 다중 대체된 것을 확인할 수 있다.

### 4.2 패턴화를 위한 클러스터링의 기능 구현

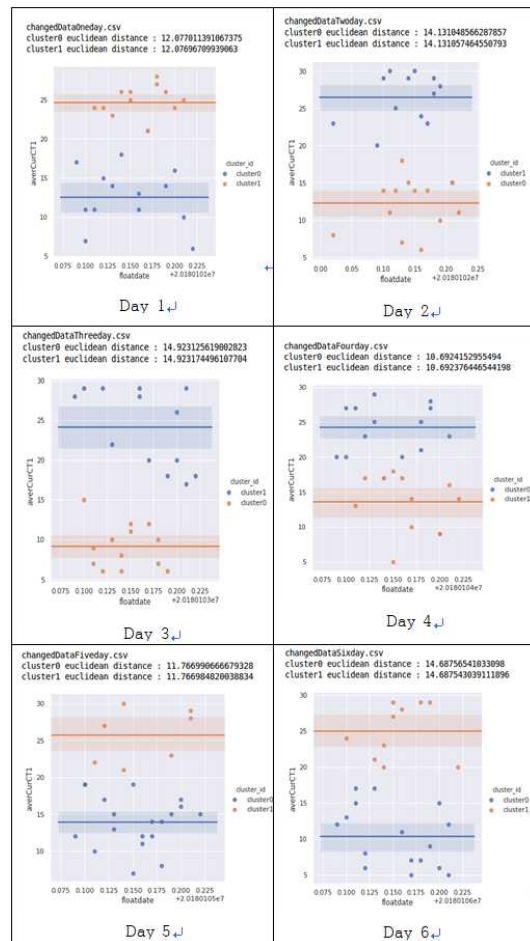


그림 7. 클러스터 데이터 생성 결과  
Fig. 7. Cluster data creation result

압축기의 개수, 평균 전류, 평균 전압 등의 데이터를 일별로 구분하고 클러스터링을 수행하여 2개의 클러스터를 생성하였다. 1개의 클러스터는 stable한 데이터를 의미하고, 다른 한 개의 클러스터는 전류 또는 전압의

전력부하시에 특정된 데이터를 의미한다. 이를 기존에 정의된 10,000건을 일별로 구분하여 6일치로 실시하였으며, 명확한 클러스터가 생성됨을 확인하였다.

### 4.3 LSTM 알고리즘을 통한 처리 정확도

클러스터 데이터로부터 도출된 전력 데이터 결과를 제안된 알고리즘의 형태로 학습하였을 때, 예측한 예측 데이터와 실제 측정 데이터인 테스트 데이터를 비교 하였다.

```
Epoch 1/5
16019/16019 [=====]
Epoch 2/5
16019/16019 [=====]
Epoch 3/5
16019/16019 [=====]
Epoch 4/5
16019/16019 [=====]
Epoch 5/5
16019/16019 [=====]
- 36s 2ms/step - loss: 0.0088 - mae: 0.0616
- 25s 2ms/step - loss: 5.4684e-04 - mae: 0.0161
- 27s 2ms/step - loss: 2.0748e-04 - mae: 0.0087
- 27s 2ms/step - loss: 1.0603e-04 - mae: 0.0064
- 29s 2ms/step - loss: 6.4110e-05 - mae: 0.0050
mean loss 0.258514
```




그림 8. LSTM 알고리즘의 결과  
Fig. 8. Results of LSTM Algorithm

학습은 클러스터 데이터의 70% (11,214)이며, 테스트 데이터는 전력 데이터의 30%(4,805)로 진행하였으며 5회의 반복시험을 실행하였다. 7:3의 비율로 데이터 셋의 비율을 나눈 것은 학습데이터를 8이상으로 설정 시 과도하게 높은 형태의 정확도가 나타나게 되어 모델

학습의 결과를 명확히 할 수 없기에 7:3을 기준으로 무작위 분할하여 데이터 셋을 생성하였다.[7]

학습의 결과로 <그림 8>과 같이 시험 결과 평균 오차 범위 값이 0.258514와 실제 학습 데이터와 예측 데이터의 차이를 확인할 수 있다. 그래프와 정확도상의 결과로 실제 데이터와 예측 데이터의 차이가 거의 없어 전력사용 기반 LSTM 알고리즘의 예측 정확도가 높음을 확인할 수 있다. 또한 <표 2>와 같이 정확도를 30회에 걸쳐 RNN알고리즘과 비교 측정하여 본 결과 30회의 오차 평균치가 LSTM의 경우 0.292614로 낮게 측정되었고 RNN은 0.4867로 비교적 높게 측정되어 클러스터화된 전력 데이터의 학습 및 예측에 전력데이터를 기반으로한 LSTM의 알고리즘 사용이 매우 적합함을 확인할 수 있었다.

표 2. 30회의 정확도 측정 결과  
Table 2. 30 times accuracy measurement result

Number	Result(Average) - LSTM	Result(Average) - RNN
1 ~ 5	0.312576	0.481762
6 ~ 10	0.297187	0.570571
11 ~ 15	0.215679	0.387214
15 ~ 20	0.325785	0.587212
21 ~ 25	0.324727	0.438723
26 ~ 30	0.279732	0.454718

## 5. 결론

전력제어 장치를 분석하고 데이터에 사용될 예측 알고리즘 확인하여 매장 에너지의 절감을 위한 LSTM 기반의 전력 부하 예측 시스템을 설계하였다.

데이터의 결측 처리 및 클러스터링화 하여 데이터별 분류를 진행한 후 학습을 수행함으로써 에너지 절충 및 관리 체계를 마련하였다. 또한 제안된 결과를 실 데이터를 통하여 결측 처리 과정을 살펴보고, 패턴화 클러스터링 분류 및 학습에대한 정확도를 확인함으로써 제안된 내용에 관련된 신뢰성을 검증하였다.

데이터 기반의 중소매장용 전력절감 시스템으로써 위 기술은 실용화를 위한 단계를 거쳐 향후 이를 통해 소상공인 데이터 기반의 새로운 마케팅이 가능해질 것으로 판단되며, 사용되는 냉장 등의 장비의 과전류로 인한 피해 최소화가 가능해질 것으로 예상된다.

REFERENCES

[1] I. J. Yoo, I. S. Cha, Y. S. Kang, "Development of AI Algorithm for Power Load Prediction of Refrigeration Compressors for Fish Storage Warehouses", *Journal of the Korean Solar Energy Society*, Vol. 41 No. 3, pp. 167-182, Jun, 2021,

[2] S. U. Lim, J. H. Kim, "RNN model for Emotion Recognition in Dialogue by incorporating the Attention on the Other's State", *The Korean Institute of Information Scientists and Engineers*, Vol. 48, No. 7, pp. 802-808, Jul, 2021

[3] Y. S. Kim, H. J. Park, "Modeling and Predicting South Korea's Daily Electric Demand Using DNN and LSTM", *Journal of Climate Change Research*, Vol. 12, No. 3, pp. 241-253, June, 2021

[4] J. S. Kim, J. S. Hwang, J. W. Chung, "A New LSTM Method Using Data Decomposition of Time Series for Forecasting the Demand of Aircraft Spare Parts", *The Korean Operations Research and Management Science Society Korea Management Science Review*, Vol 37, No. 1, pp. 1-18, Jun, 2020

[5] H. J. Kim, H. J. Kim, D. Y. Kim, J. M. Kim, "DC Voltage Balancing Control of Half-Bridge PWM Inverter for Linear Compressor of Refrigerator", *The Transactions of Korean Institute of Power Electronics*, Vol. 22 No. 3, pp. 256-262, Jun, 2017

[6] I. H. Kim, J. H. Kim, "Multivariate time series clustering of electricity consumption data", *Journal of the Korean Data And Information Science Society*, Vol 32, No. 3, pp.569-584, May, 2021.

[7] N. Andrew, "Machine Learning Yearning", *DeepLearning.AI*, Jul. 2018

저자약력

최 종 석(Jongseok Choi)

[정회원]



- 2013.03 ~ 2015. 02  
승실대학교 박사수료
- 2019. 10 ~ 현재  
(주)공감하다 대표
- 2020. 09 ~ 현재  
승실대학교 스파르탄SW교육원  
교수

〈관심분야〉 빅데이터, IoT, 데이터분석, 스마트그리드

신 용 태(Yongtae Shin)

[비회원]



- 1994 Unviersity of Iowa  
Computer Science 공학박사
- 1995. 03 ~ 현재  
승실대학교 컴퓨터학부 교수
- 2018. 03 ~ 현재  
승실대학교 스파르탄SW교육원  
원장

〈관심분야〉 인공지능, 데이터분석, 무선통신, IoT