

인공신경망을 이용한 수전설비 고장 예측 방법

기태석, 이상호*
 충북대학교 소프트웨어학과

A Prediction Scheme for Power Apparatus using Artificial Neural Networks

Tae-Seok Ki, Sang-Ho Lee*
 Department of Software Engineering, Chungbuk University

요약 수전설비의 고장은 산업과 가정 등 전력을 사용하는 모든 곳에 정전사고를 발생시켜 많은 불편과 문제의 원인이 되고 있다. 수전설비 고장의 주요 원인으로는 노후화를 비롯하여 태풍, 지진을 비롯한 자연재해와 동물 등으로 파악되고 있다. 현재는 수전설비의 온도가 높아지면 고장이 발생한다는 추측만으로 온도의 고온이 지속되는 것을 모니터링한다. 따라서 적기에 수전설비의 고장에 대응하기 어려운 측면이 존재하는 것이 사실이다. 이 논문에서 제안하는 수전설비 모니터링 시스템은 갑작스런 자연재해 등으로 인한 고장을 제외한 일반적인 고장에 대해 효율적으로 대응하는 방안으로 제안한다. 수전설비 모니터링 시스템은 열 감지 센서를 부착하여 수전설비를 실시간으로 감시하고, 감시한 데이터를 수집하여 인공신경망을 이용한 학습을 통해 축적된 정보를 이용하여 고장을 예측한다. 인공신경망의 학습과 실험을 통하여 제안 방식이 효율적임을 보였다.

키워드 : 수전설비, 고장 예측, 인공신경망, 실시간 모니터링, 온도 센서

Abstract Failure of the power apparatus causes many inconveniences and problems due to power outage in all places using power such as industry and home. The main causes of faults in the Power Apparatus are aging, natural disasters such as typhoons and earthquakes, and animals. At present, the long high temperature status is monitored only by the assumption that a fault occurs when the temperature of the power apparatus becomes higher. Therefore, it is difficult to cope with the failure of the power apparatus at the right time. In this paper, we propose a power apparatus monitoring system as an efficient countermeasure against general faults except for faults caused by sudden natural disasters. The proposed monitoring system monitors the power apparatus in real time by attaching a thermal sensor, collects the monitored data, and predicts the failure using the accumulated information through learning using the artificial neural network. Through the learning and experimentation of artificial neural network, it is shown that the proposed method is efficient.

Key Words : Power apparatus, Failure prediction, Artificial neural network, Realtime monitoring, Thermal sensor

1. 서론

1.1 서론

한국아파트신문 2017년 11월 1일자 기사에 의하면 아파트 변전실 등 한전에서 고압전기를 받아들이는 수전설

비의 고장이나 침수로 일어나는 정전사고가 매년 100건에 달한다고 한다. 이러한 상황과 관련하여 한 국회의원이 2017년 한국전력 국정감사에서 아파트 수전설비 문제로 발생하는 대규모 정전사고의 문제점을 지적하며, 법적 제도적 대책 마련이 필요하다고 밝힌바 있다.

산업계 수전설비의 고장의 피해는 더욱 막대하다. 2008년 5월 여수산업단지에서 발생하였던 노후화된 피뢰기 사고가 해당 업체는 물론 산업단지 전체에 엄청난 경제적 손실을 갖고 온 사례에서 알 수 있는 것처럼 산업용 전력설비의 신뢰성이 크게 요구되고 있는 실정이나, 현실은 그러하지 못하다[1].

수전설비 고장사고는 실태조사 대상의 38.3%가 경험했던 것으로 나타났으며, 변압기 및 차단기에서 60%를 점유하였고 고장사고로 인한 평균 공장 중지시간은 15.8 시간이었으며, 이로 인한 손실액은 최소 3천3백만원에서 최대 45억(평균 약 7억)으로 조사되었다. 한편, 고장사고 예방을 위한 정밀점검은 3년 주기가 31.9%로 가장 높았으며, 수전설비 부품교체는 “점검 또는 진단에 의해서”가 83.0%로 조사되었다. 대규모 산업현장을 비롯한 사회 전반에 걸쳐 안정적인 전력의 공급은 필수 요소이다.

수전설비의 노후화 등으로 인한 고장사고 시 발생하는 경제적 피해와 불편 등이 상당히 큰 것이 현실이므로, 수전설비에 대한 정부 차원의 권장교체 주기 제시 등 제도적 대책 마련과 함께 보다 정교한 고장 예측 시스템을 개발하여 사전에 고장을 최소화하는 노력이 요구된다.

2. 관련연구

2.1 현 수전설비 모니터링 시스템 개요

Fig. 1은 현재 전력회사에서 사용하고 있는 수전설비 모니터링 시스템의 센서를 중심으로 한 구조이다. 여기서 수전설비란 전선주에 부착되어있는 장비이고 Fig. 1의 박스 안에 장비들이 에 해당된다. 예를 들면 전선주 한 곳에 여러 개의 모니터링의 대상이 되는 기기들 (HEAD, TR, MOF, ASS)이 있고 각 기기들은 BODY, R,




Fig. 1. Sensor monitoring

S, T 로 구성되어 있다. 즉, 수전설비 모니터링이란 설비에 부착되어 있는 각 기기들을 온도 센서 카메라로 실시간 모니터링 하는 기능을 수행한다.

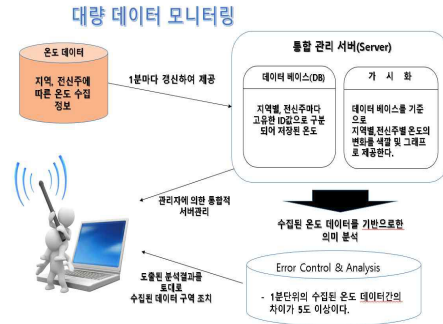


Fig. 2. System structure

Fig. 2는 수전설비의 열 감지 센서로부터 온도 데이터를 수집하여 서버로 전송하는 시스템의 전체적인 흐름도이다.

열 감지 카메라는 Fig. 1과 같이 수전설비의 각 구성요소에 대한 데이터를 수집하여 전송하게 된다. 수집된 데이터는 수전설비의 구성요소, 수집된 시간, 수전설비가 설치된 장소를 기준으로 각기 정렬된다. 정렬된 데이터들은 각각 웹페이지를 통해 그래프 형태로 수전설비 관리자에게 제공되어, 수전설비가 설치된 위치, 수전설비의 부위, 온도 데이터가 수집된 시간별로 그래프 형태를 나타내어 관리자가 실시간으로 모니터링 할 수 있도록 한다. 전국에 설치된 각 지역의 수전설비에서 측정된 온도 데이터들이 실시간으로 수집되면 매우 많은 양의 데이터가 된다.

2.3 기존 예측 방법들의 고찰

수전설비의 고장 탐지와 예측을 위한 방법으로 여러 가지 방법들이 연구되어 왔다. 김선구 등은 산업용 수전설비(66KV 이상)를 대상으로 노후 고장 예방을 위한 제도 및 관리체계를 개선하기 위하여 실태조사 분석을 수행하였다[1]. 분석 대상이 총 54곳이라는 제한이 있으나, 제도적, 관리적 측면에서 노후 설비의 권장 교체 주기, 정기검사 실시 및 전력계통 사고에 대한 데이터베이스화 등과 같은 다양한 시사점을 도출한데 의의가 있다.

이수복 등의 연구에서는 고객설비를 중심으로 고장 발생현황을 통계적 관점에서 분석하여 전력회사 관점에

서 고장을 줄일 수 있는 방향을 찾는 연구 수행을 통하여 고객 수전설비 관리 시스템이 필요하다고 하였다[2].

기존의 배전분야 고장 원인 분석 방법으로 사용되어 온 일원 또는 이원 분석 방법으로는 특별고압 파급고장을 감소시키는데 한계가 있다고 보고 데이터 마이닝 기법 기반의 다변량 분석 방법을 제안하였다[3]. 그 결과 고장발생 가능고객 예측 모델과 신뢰도 향상 대책을 제시하였다. 의사결정나무, 회귀분석, 인공신경망 등을 이용한 이 연구는 배전분야의 특별 고압 설비를 대상으로 진행하여 수전설비에 적용하기 어렵다.

기존에 사용하는 과전류 계전 기법을 이용한 철도 고압배전선로의 고장검출 기법의 문제점을 지적하고, 이를 개선하기 위하여 웨이브렛 변환을 이용하여 다양한 형태의 고조파가 함유된 과도신호로부터 고장을 검출하는 기법을 제시하였다[4].

대표적인 전력기기인 GIS(Gas Insulated Switchgear)는 설계 및 운전 중에 결함이 존재할 경우 운전시간이 경과함에 따라 이 결함에 의해 절연열화가 진전되는 것이 일반적인 현상이라고 가정하여, GIS의 사고가 전체 시스템의 정전을 초래할 수 있어 그에 대한 예방보전을 위한 고장 조기 감지 시스템을 패턴 인식 기법을 기반으로 한 신경망 모델을 이용한 연구도 수행되었다[5]. 이 연구는 신경망 모델을 이용하므로 데이터에 주어지지 않은 결함이 발생했을 때에도, 발생할 수 있는 방전전하량을 추론할 수 있는 장점이 있어 고장 진단에 유용하게 활용될 수 있다.

이 논문에서 수행하고자 하는 내용과 가장 유사한 것으로 수배전반 시스템을 대상으로 오류 예측에 대한 연구를 들 수 있다[6]. 이 연구에서는 고장의 발생을 예측하고 예방하는 방법이 존재하지 않는다고 주장하며, 배전반 내의 전류, 전압, 온도의 센서 데이터 분석을 통해 수배전반 시스템의 고장을 예측하는 시스템인 EPS(Error Prediction System)을 설계하고 구현하였다. EPS는 고장 가능성을 판별하기 위하여 설비의 동작 상태 정보를 획득하고 분석하며, 동작 상태 정보로는 기본적인 전류, 전압, 온도 등과 부가적으로 문의 개폐 등을 사용하였으며, 센서에서 측정된 수배전반 시스템의 내부 설비의 전류, 전압, 온도 데이터를 토대로 정상범위를 넘는 이상 신호와 이러한 이상 신호가 자주 발생하는 빈도를 이용하여 이상사건을 분류하고 또한 이상사건의 빈도를 이용하여 경고로 분류하는 방식을 제안하였다.

따라서 수전설비의 고장에 능동적으로 대응하여 산업계는 물론 일반 가정에서도 보다 안심하고 전력을 사용할 수 있도록 하기 위해서 RNN(Recurrent Neural Network) 등과 같은 인공신경망을 이용하여 학습 기반의 고장을 예방하는 방법이 필요하다.

3. 제안 방법

3.1 개요

수전설비의 고장을 예방 또는 예측하기 위해서는 현재 수전설비의 상태를 파악하는 방법이 필요하다. Fig. 3은 특정 수전설비에서 고장이 발생할 때의 온도 데이터의 이력을 나타낸다. 이 그림에서 x가 고장이 발생한 시점이다.

Fig. 3에서 경고1, 경고2, 고장은 각각 수전설비의 고장이 발생한 시점으로부터 얼마나 떨어져 있는지 식별하기 위해 이 연구에서 부여하는 레이블이다. 경고1은 고장으로부터 6일만큼 떨어져 있기 때문에 경고1 단계이고, 경고2 단계는 고장 발생 3일전, 마지막 단계는 고장이 발생하기 직전 상태이다.



Fig. 3. Temperature data of failure state

시스템은 각 상태에 해당하는 온도데이터들을 입력받아 해당하는 단계(경고1, 경고2 혹은 고장)를 출력하도록 인공신경망을 학습시킨다.




Fig. 4. Relationship on input and output

학습이 완료된 시스템은 Fig. 4와 같이 현재 측정된 온도 데이터들을 입력받아 해당 온도 데이터에 맞는 단계를 출력하게 된다.

즉, 제안 시스템은 수전설비의 최근 온도 데이터(최근 3일의 데이터)를 학습이 완료된 인공 신경망에 입력받아 입력 온도에 해당하는 상태, 즉 경고1, 경고2, 고장 상태를 출력한다. 학습 과정은 4장 실험에서 기술한다. 수전설비 관리자는 시스템의 출력 값이 경고1이면 고장으로부터 6일전 이라는 뜻으로 상태를 해석할 수 있어 이에 적절한 대응을 할 수 있게 된다. 만약 출력 값이 고장이면 고장 직전상태라는 뜻으로 즉시 해당 수전설비의 상태를 정밀 조사하여야 한다고 판단할 수 있다. Fig. 4에서는 편의 상 3일 간격으로 온도 데이터들을 표현하였지만 다양한 일 간격을 적용할 수 있다.

3.2 인공신경망 설계

수전설비의 고장을 예측하는 방법으로 인공신경망 기반의 방법을 제안한다. 인공신경망 중에서 RNN의 한 종류인 LSTM(Long Short-Term Memory)을 사용하고자 한다. RNN을 사용하는 이유는 입력 시 출력해야하는 값이 정해져 있는 지도학습이고, 인공신경망 중에서 온도 데이터 같은 시계열 데이터에 적절하기 때문이다. RNN은 Fig. 5에서 보는 바와 같이 하나의 네트워크가 여러개 복사된 형태를 가지고 있으며, 각각의 네트워크는 다음 단계로 정보를 넘겨준다.




Fig. 5. Structure of RNN

Fig. 5에서 x_t 는 입력 값으로, 예를 들어 최근 3일 치의 온도 데이터에 대응한다.

LSTM은 오차의 경사가 시간을 거슬러서 잘 흘러갈 수 있도록 도와주는 특징을 갖는 RNN으로, Backprop하는 과정에서 오차의 값이 더 잘 유지된다[7]. Fig. 6은 LSTM 작동을 보여준다. LSTM 네트워크 하나는 여러 개의 게이트(Gate)가 존재하는 셀(Cell)로 이루어져있으며 이 셀의 정보를 저장, 불러오기, 유지하는 기능이 있

다. 셀은 연결된 게이트의 값을 보고 무엇을 저장할지, 언제 정보를 내보낼지, 언제 쓰고 언제 지울지를 결정한다. 각 게이트는 0에서 1사이의 값을 가진다.




Fig. 6 LSTM

각 게이트가 갖는 값, 즉 게이트의 가중치(Weight)는 은닉층(신경망의 중간층)의 값과 같은 원리로 학습된다. 즉 게이트는 언제 신호를 저장/불러오기/유지할지를 학습하며 이 학습과정은 출력의 오차를 이용한 경사 하강법을 사용한다.

LSTM에 입력되는 값은 현재 입력 값과 인접 셀에서 온 피드백 값을 합친 것으로, 바로 입력되는 것이 아니라 3개의 게이트로 들어가고 각 게이트에서는 입력 값을 어떻게 다룰 것인지를 정한다. 게이트는 입력 값을 얼마나 반영할지, 현재 값 중 얼마를 지울지, 그리고 얼마나 출력할지를 결정한다.

Fig. 6에서 보는 바와 같이 LSTM에는 더하기 기능이 있다. 일반적인 RNN은 곱하기로 동작하지만, LSTM은 피드백을 더한다. 따라서 Sigmoid를 곱하면서 발생하는 오차 수정이 안 되는 문제가 없다는 특징을 갖는다.

Oftmax 함수의 동작 과정은 Fig.7과 같다. LSTM의 출력 값을 Softmax 함수에 입력으로 사용한다. Softmax 함수를 거치면 Softmax의 출력은 전체의 합이 1인 확률 값들로 구성된다. 학습을 진행하는 과정에서 LSTM의 신경망 Weight들은 Softmax의 레이블의 확률을 높이는 작업을 진행한다. 예를 들면 현재 레이블이 경고 1인 온도 데이터가 입력으로 들어오고 Softmax 출력이 Fig. 7과 같은 결과를 보이면 시스템은 경고 1의 확률이 0.7에서 1을 향하고 경고 2와 고장 확률은 더 줄어들도록 LSTM weight들을 조금씩 조절한다. 많은 온도 데이터

들을 입력하여 시스템이 올바른 레이블(경고1, 경고2, 고장)을 출력시키도록 학습이 완료되면 실제 상황에서 데이터를 입력하면 관리자는 출력된 레이블을 보고 수전설비의 고장 상태를 확률적으로 판단할 수 있게 된다.




Fig. 7. Structure of softmax

이 연구에서 제안하는 시스템은 LSTM의 출력 결과를 Softmax가 입력받아 온도에 적합한 상태를 알려주는 기능을 갖는다. Fig. 8은 LSTM과 Softmax를 결합한 제안 시스템의 개요이다.




Fig. 8 predict system learning model

4. 실험

4.1 실험 설계

인공신경망을 이용하여 현재 수전설비의 위험 상태를 알아내는 방법을 학습시키기 위해서는 실제 수전설비 고장 발생 시의 최근 온도 데이터가 필수적으로 필요하다. 하지만 실제 수전설비 고장 시 온도 데이터 확보가 불가능하여 부득이 이 연구에서는 모의 데이터를 만들어서 실험하기로 한다.

실험 사용 도구로는 구글의 Tensorflow와 Anaconda를 사용하며, 학습에 사용되는 인공신경망은 LSTM이며 신경망과 LSTM, 오차를 줄이는 학습은 모두 Tensorflow가 추상적으로 제공하는 함수를 이용하기로 한다.

모의 데이터의 구성은 다음과 같다. 온도가 50~60일 때의 상태는 경고1이고 레이블은 0이다. 온도가 60~70일 때의 상태는 경고1이고 레이블은 0이다. 온도가 70~80일 때의 상태는 경고1이고 레이블은 0이다. 여기서 레이블은 상태를 식별하는 값으로 LSTM의 예측값이 맞춰야 하는 실제 정답 값이다. Fig. 9에서 보는 바와 같이, 학습 초기에 온도를 50~60 입력을 주었는데 예측 값이 2가 나왔다고 가정하면, LSTM은 예측 값과 입력된 실제 정답 라벨인 0이 되도록 오차를 줄여나간다.

실제 데이터를 입력할 때의 학습 방법은 다음과 같다. 고장이 발생 했을 때의 온도 데이터가 8000세트를 사용하며, 각 세트마다 최근 21일치 온도 데이터를 가지고 있는 것으로 가정한다. 그리고 21일을 7일 단위로 나눠서 고장이 발생하기 전 21일~14일은 경고1 상태, 14일~7일은 경고2 상태, 7일~0일은 고장 직전 상태라고 정한다. 이러한 각각의 7일 단위의 데이터는 한번 학습 시 입력되는 데이터이다. 데이터 세트 하나를 7일 단위로 설계 하였으므로 학습 횟수는 3*8000 즉 24000번 하게 된다. 학습할 때의 레이블은 입력되는 실제 정답 값으로 Fig. 8에서 경고1은 0, 경고2는 1, 고장은 2가 레이블이다. 학습을 하게 되면 모델은 예측 값이 실제 레이블과 같아지도록 오차를 줄여나간다.




Fig. 9. Full process

4.2 실험 및 결과

Fig. 10은 실험 결과를 보여준다. 최근 7일의 온도로 수전설비의 위험 상태를 예측하도록 실험을 설계하였으므로 수전설비의 최근 7일치의 온도인 입력 값 7개, 그 상태를 나타내는 출력 값 1개인 학습 모델이다. 즉 고장이 발생 했을 때의 온도 데이터들을 RNN에 입력시켜 학습하면 RNN 모델은 고장이 발생하기 전의 데이터들의 공통적인 특징을 학습하게 되고 학습된 특징과 입력한 최근 7일치의 온도를 비교할 수 있게 된다. 비교한 결과가 경고1, 경고2 고장 상태 중 어느 상태(경고1은 고장 발생 3주일 전, 경고 2는 고장발생 2주일 전, 고장은 고장

발생 1주일 전)일 확률이 가장 큰지 알려는 것이 이 모델의 설계 목적이다. 실험에 사용된 데이터는 보통 수전설비의 고장이 발생하는 시나리오가 온도가 점점 상승할 때이기 때문에 7일의 온도가 50~60일 때는 경고 1 상태, 60~70일 때는 경고2, 70~80일 때는 고장 직전인 고장 상태로 정의하였다.

실험에서 LSTM의 신경망 깊이는 3층, 학습 비율(Learning_rate)은 0.1로 설정하였다. 모의 데이터를 이용하여 먼저 학습을 하고 테스트를 진행하였다. Fig. 9는 모의 데이터 8000개로 학습을 하고 2000번의 테스트를 수행한 결과이다.

```

step: 7996 input: [[57, 55, 56, 53, 51, 55, 52]]
step: 7997 input: [[60, 67, 69, 65, 69, 62, 62]]
step: 7998 input: [[78, 74, 72, 77, 70, 70, 78]]
step: 7999 input: [[53, 57, 58, 57, 58, 56, 58]]
step: 8000 input: [[60, 67, 64, 67, 69, 69, 64]]

output: [[0]] hypo: 0.49 0.0 0.5 loss: 0.705468
output: [[1]] hypo: 0.0 1.0 0.0 loss: 0.0
output: [[2]] hypo: 0.0 0.0 1.0 loss: 3.6835e-05
output: [[0]] hypo: 1.0 0.0 0.0 loss: 0.00019322
output: [[1]] hypo: 0.0 1.0 0.0 loss: 0.0

step: 1998 input: [[55, 58, 56, 59, 56, 53, 54]] output: [[0]]
step: 1999 input: [[69, 65, 61, 67, 67, 67, 62]] output: [[1]]
step: 2000 input: [[71, 75, 79, 79, 79, 76, 77]] output: [[2]]
step: 2001 input: [[56, 52, 58, 50, 50, 56, 57]] output: [[0]]
success: 1954 fail: 46 accuracy: 0.977
    
```

Fig. 10. Learning result

Fig. 10의 첫 번째와 두 번째 박스는 학습 할 때의 입력과 출력에 대한 내용이다. 여기서 input은 7일분의 온도 값이고 output은 해당 온도의 상태를 나타내는 값이다. 상태는 고장 발생 시간으로부터 가장 먼 경고1, 경고2 순으로 고장까지의 3종류가 있다. Fig. 9처럼 경고1은 0, 경고2는 1, 고장은 2가 실제 목표로 하는 레이블 즉 정답인 값이다. Fig. 10의 Hypo는 Hypothesis로 학습하는 모델이 예측한 값의 확률로 경고1, 경고2, 고장에 대한 각각의 확률 값이다. Loss는 모델이 예측한 값(가장 큰 확률로써 선택된 값)과 실제 정답(레이블) 즉 Output과의 오차이다. 두 번째 박스의 Output이 실제 정답 값이고 예측 값은 Hypo중 가장 큰 값이다.

입력에 해당하는 첫 번째 박스의 첫 행의 의미는 다음과 같다. 학습 단계는 7996번째이고 이어서 7일치 온도가 입력된다. 입력된 온도를 학습 모델이 판단하여 결과로써 각 레이블(경고1, 경고2, 고장)에 대한 확률(Hypo)을 출력한다.

Fig. 10의 두 번째 박스의 의미는 다음과 같다. 경고1일 확률이 0.49, 경고2일 확률이 0.0, 고장일 확률이 0.5이다. 경고1이 실제 답인데 학습 모델은 고장이라고 판단한 것을 나타낸다. 오차인 loss도 큰 값으로 계산되었다. 이것은 첫 행은 잘못된 답을 추측한 결과라는 의미이다. 오답이 발생하면 학습 모델은 스스로 오차를 줄여나가면서 학습을 진행하게 된다.

세 번째 박스는 실험 결과로 LSTM을 이용하여 수행한 고장에 대한 진단이 97.7% 성공률을 보이고 있다.

만일 더 많은 학습 데이터로 학습하게 되면 정확도가 높게 나올 것이다.

5. 결론

현재는 수전설비의 온도가 높아지면 고장이 발생한다는 추측만으로 온도의 고온이 지속되는 것을 모니터링하는 방식으로 수전설비의 고장에 대응하고 있다. 따라서 적기에 수전설비의 고장에 대응하기 어려운 측면이 존재하는 것이 현실이다. 이 논문에서는 수전 설비 모니터링 시스템은 갑작스런 자연재해 등으로 인한 고장을 제외한 일반적인 고장을 예측하는 방안을 제안하였다.

수전설비의 고장을 예측하는 방법으로 앞으로는 축적된 고장 데이터를 사용하여 딥러닝을 적용한 예측 모델이 사용될 것으로 보인다. 이 논문에서는 딥러닝을 어떤 방법으로 고장 예측에 적용할 수 있는지에 대한 사례를 실험을 통해 소개하였다.

단, 실험 과정에서 신경망의 깊이를 3개로 할 때는 학습이 잘 되지만 깊이가 5개 이상일 때는 학습이 수렴하지 않는 결과가 나왔다. 이러한 한계는 LSTM에 대한 적용 연구가 더 필요한 부분이다.

ACKNOWLEDGMENTS

본 연구는 과학기술정보통신부 및 정보통신기술진흥센터(IITP)의 서울어코드활성화지원사업의 연구결과로 수행되었음.

이 논문은 2017년 추계학술대회 학부생 발표 논문 중 우수논문으로 선정되었습니다.

REFERENCES

- [1] S. G. Kim, J. W. Jung & J. S. Jung. (2010). A Study on Field Survey for Prevention of Aging Fault in Industrial Power Apparatus. *The Korean Institute of Electrical Engineers* (pp 2173-2174). Seoul : KIEE.
- [2] S. M. Yi & S. H. Cho. (2009). Analysis of the power failure in connection with the customer electric facility. *The Korean Institute of Electrical Engineers* (pp14-17). Seoul : KIEE.
- [3] S. H. Bae, J. H. Kim, J. S. Hong & H. S. Lim. (2009). A study on Reliability Enhancement Method and the Prediction Mode Construction of Medium-Voltage Customers Causing Distribution Line Fault Using Data Mining Techniques. *Transaction on The Korean Institute of Electrical Engineers*. 58(10), 1869-1880.
- [4] H. S. Jung, M. S. Han, C. M. Lee, J. Kim & H. M. Lee. (2004). *Fault Detection Technique in Railway High Voltage Distribution Lines using Wavelet Transform*. The Korean Society for Railway. <http://railway.or.kr>
- [5] J. K. Lee. (2011). A Study on the Fault Early Detection System for the Preventive Maintenance in Power Receiving and Substation. *Journal of The Korean Society of Industry Convergence* 14(3), 95-100.
- [6] S. Y. Cho. (2011). An Error Prediction System for Reliability Improvement of Power Distribution System. *Journal of Security Engineering*, 8(6), 705-713.
- [7] Github. (2015). *Understanding LSTM Networks*. Github. <http://colah.github.io/posts/2015-08-Understanding-LSTMs>

저 자 소 개

기 태 석(Tae-Seok Ki)

[학생회원]



- 2010년 2월 : 경북 고등학교 졸업
- 2014년 3월 ~ 현재 : 충북대학교 소프트웨어학과 재학 중

<관심분야> : 소프트웨어 설계, 딥러닝

이 상 호(Sang-Ho Lee)

[종신회원]



- 1972년 2월 : 숭실대학교 전자계산학과 학사
 - 1981년 2월 : 숭실대학교 대학원 전자계산학과 석사
 - 1989년 2월 : 숭실대학교 대학원 전자계산학과 박사
 - 1981년 3월 ~ 현재 : 충북대학교 소프트웨어학과 교수
- <관심분야> : 컴퓨터네트워크, 통신보안, 중소기업정보화, IT융합