

수전설비 고장 예측 방법에 대한 연구

기태석, 방진영, 이상호*
충북대학교 소프트웨어학과

Study about predict Live Power-Equipment

Tae-Seok Kee, Jin-Yuong Bang, Sang-Ho Lee*
Department of Software Engineering, Chungbuk University

요 약

수전 설비는 지금까지 태풍, 지진을 비롯한 자연재해와 동물에 의해 고장을 일으켜왔다. 수전설비의 상태를 점검하는 것은 지금까지 일정 주기로 직접 점검해야만 했다. 수전 설비 모니터링 시스템은 이를 해결하기 위해서 열 감지 센서를 부착하여 수전설비를 실시간으로 감시하고, 감시한 데이터를 수집한다. 이 논문에서는 실시간으로 수집되는 온도데이터를 인공신경망 RNN을 통해 학습을 하여 고장을 예측하는 방법에 대해 기술한다.

1. 서론

수전 설비란 전력회사에서 3상의 전원으로 전기를 공급 받는 설비다. 수전 설비 모니터링 시스템[2]이란 수전 설비의 주요 고장 징후를 신속하게 파악, 실시간으로 모니터링 해주는 시스템으로 수전 설비의 온도 상승(열화), 침수, 침입탐지, 소리 등의 이상 징후를 사전에 파악하여 대응 할 수 있도록 도와주는 IoT 기술이다.

침수 감지는 침수로 인한 설비의 오작동과 고장을 예방한다. 소음 감지는 설비의 상태 유추와 외부 요인 분석이 목적이다. 동작 감지는 쥐, 뱀, 조류 등의 외부침입을 감지하여 신속하게 대처가 목적이다. 중계기 감지는 중계기 작동상태를 감지하여 정전 및 중계기 고장으로 인한 문제점을 사전에 파악하여 대처 하는 목적이다. 고온 감지는 설비 주요 부위에 비 접촉 온도센서를 이용하여 장비의 이상을 실시간으로 모니터링 한다.

이 논문은 온도 데이터만을 이용하여 설비의 고장을 예방하는 방법으로써 고온으로 인한 고장 예측 방법에 대해서만 소개한다.

2. 관련 연구

수전설비의 고장 탐지를 위한 방법으로 여러 가지 방법들이 연구되고 있다. 그 중 빅 데이터 분석 방법으로 군집 분석이 있다. 온도 센서로부터 가져온 방대한 양의 온도 데이터에 대한 변화 수준과 시간을 바탕으로 군집 분석을 수행하여 유사 군집의 특성을 파악하는 방법이다. 이 방법을 사용하여 고장의 특성과 정상의 특성으로 군집을 생성해 예측한다.

이 논문에서는 기존 방법이 아닌 인공신경망의 RNN 알고리즘을 이용해 수전설비의 고장을 예측하려고 한다[1]. 기존의 군집 분석은 센서의 이상온도를 감지하는 것에 그치므로 대량의 데이터를 이용한 패턴을 분석하는 인공 신경망을 이용해 보다 더 정확한 예측을 하려고 한다. 인공신경망을 이용한 예측은 고장에 대한 데이터가 많이 있어야 가능하다. 고장에 대한 데이터가 있다는 가정 하에 가상 데이터로 고장 시에 나타나는 온도 데이터를 RNN에 적용시켜 고장을 예측하려고 한다.

3. 제안 시스템 설계

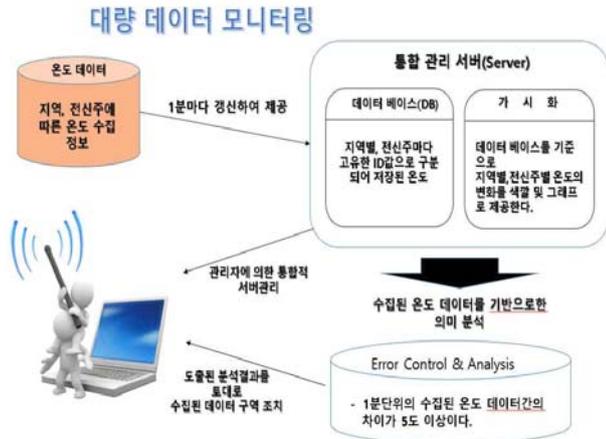
3.1. 데이터 수집

아래 그림 [시스템 구조도]는 수전설비의 열 감지 센서로부터 온도데이터를 수집하여 서버로 전송하는 시스템의 전체적인 흐름도이다.

열감지 카메라는 아래 그림 [수전설비 온도 측정부분]와 같이 수전설비의 각 부분에 대한 데이터를 수집하여 각각 다른 헤더를 포함한 데이터로 전송하게 된다. 수집된 데이터는 작성된 정렬 알고리즘으로 수전설비의 부분, 수집된 시간, 수전설비가 설치된 장소를 기준으로 각기 정렬된다. 정렬된 데이터들은 각각 Html로 구성된 웹페이지에서 그래프 형태로 띄워주게 되고, 수전설비가 설치된 위치, 수전설비의 부위, 온도 데이터가 수집된 시간별로 그래프 형태를 나타내어 관리자가 실시간으로 모니터링 할 수 있도록 한다. 시간당 전국에 설치된 각지의 수전설비 온도 데이터들은 매우 많은 양의 데이터가 수집된다. 이렇게 수집

*Corresponding author : Sang-Ho Lee (shlee@chungbuk.ac.kr)

된 data는 차후 RNN을 이용한 수전설비의 고장 예측에 사용된다.



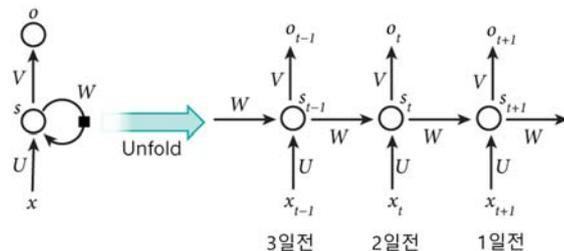
[그림 1] 시스템 구조도

3.2. 데이터 분석

이 논문에서는 설비 고장 시 나타나는 데이터를 이용해 인공 신경망 모델에 학습 시켜 수전설비의 고장을 예측하는 방법을 제안한다. 인공 신경망 모델의 학습이란 고장 시에 나타나는 대량의 데이터들을 신경망 모델에 입력시켜 Gradient Descent를 이용해 오차를 조절하고 Softmax 함수를 이용해 고장이나 위험상황에 대한 확률을 알아낸다. 출력된 값 중 가장 큰 확률에 해당하는 라벨(고장, 경고 1, 경고 2)을 알려주어서 상태를 예측하는 방법이다.

RNN은 Recurrent Neural Network로 하나의 네트워크가 여러 개 복사된 형태를 띠고 있다. 그림 2와 같이 각각의 네트워크는 다음 단계로 정보를 넘겨준다. 이러한 속성 때문에 시계열 데이터, 자연어와 같은 분야에 많이 쓰이고 있다. 음성인식, 번역 등 여러 분야에서 성공적으로 적용된 사례가 있다. 이 논문은 시간에 따라 변하는 온도데이터를 그림 7과 같이 하나의 RNN이 아닌 multi RNN을 적용시켜 학습을 진행하는 실험을 한다.

RNN 입출력은 many to one 방식으로 이 논문에서는 3개의 온도 값을 입력하고 하나의 결과를 출력하는 방식이다.



[그림 2] RNN

Softmax는 데이터를 2개 이상의 그룹으로 나누기 위해 binary Classification을 확장한 모델이다. 이 함수는 가장 큰 값을 찾는 개념을 말한다. 그림 3과 같이 일반적으로 숫자를 거꾸로 뒤집었을 경우에 대해 가장 큰 숫자를 찾

는다. Softmax 함수는 0이 아닌 자연수 N개의 값이 존재할 때, 각각의 값의 편차를 확대시켜 큰 값은 상대적으로 더 크게, 작은 값은 상대적으로 더 작게 만든 다음 Normalization 시키는 함수이다. 이 방법은 RNN으로 학습된 출력된 값 중 가장 큰 확률에 해당하는 라벨(고장, 경고 1, 경고 2)을 찾을 때 사용된다.

$$softmax_n(x) = \frac{e^{x_n}}{\sum_{k=1}^N e^{x_k}}, n \in \{1, 2, 3, \dots, N\}$$

[그림 3] softmax 함수

4. 구현 및 실험

수전설비 모니터링 시스템은 고장을 미리 예측하는 것이 목표다. 따라서 학습 데이터는 고장이나 경고를 주는 시점 이전 수일동안의 온도 값이다.

그림 4는 수전설비의 고장이 발생했을 때의 온도 데이터 사례이다. 이 데이터를 가지고 신경망의 학습을 진행한다. 장치의 온도가 점점 상승하고 상승이 유지되면서 기기의 과부하로 인해 고장이 나는 특정한 상황을 나타낸 데이터 이다.



[그림 4] 고장 시 데이터

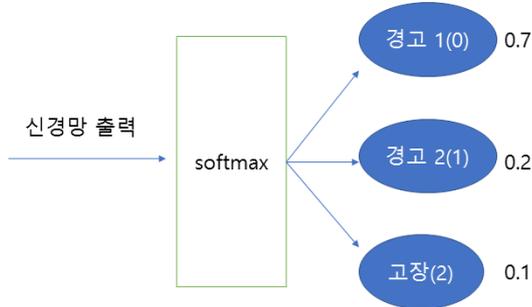
그림 4에서 경고 1, 경고 2는 고장이 나기 전에 관리자에게 경고를 주는 시점이다. 그림에 각 숫자는 온도 값이다. 고장이 나기 수일 전까지의 온도데이터를 학습하여 장치의 고장이나 경고 상태에 대한 확률을 예측하여 관리자에게 알려준다. 이 논문에서는 그림 4와 같이 경고 시점 전 3일 동안의 데이터만 학습한다.



[그림 5] 온도에 따른 상태 예측 모델

우선 RNN에 데이터들을 입력해 학습을 시켜야 한다. 그림 5와 같이 입력에 따라 상태를 출력하도록 학습한다.

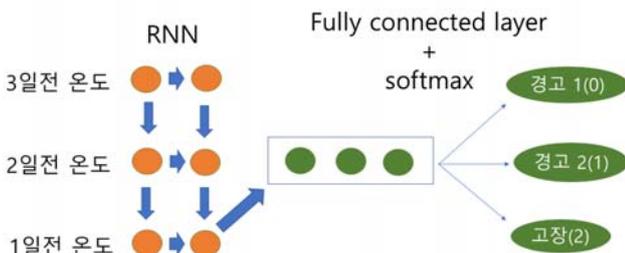
온도가 50~60 이면 경고1을 의미하는 0을 출력,
 온도가 60~70 이면 경고2을 의미하는 1을 출력,
 온도가 70~80 이면 고장 직전임을 의미하는 2을 출력한다.



[그림 6] softmax 학습 과정

Softmax 함수의 과정은 그림 6과 같다. RNN으로부터 받은 출력 값을 Softmax 함수에 적용한다. Softmax 함수를 거치면 전체의 합이 1인 라벨들로 구성 된다. 결국 이 값을 이용해 상태를 확률적으로 판단할 수 있게 된다. 가장 큰 값이 가장 큰 확률로 발생한다는 의미이기 때문에 이 그림에서는 현재 고장 1일 확률이 크다는 의미이므로 제대로 학습했다면 0을 출력해야 한다.

경고 1, 경고 2에 대한 학습 모델이 생성되면, 실제 온도 데이터를 각각의 학습 모델에 넣어 Softmax함수의 결과로 각각 라벨에 대한 확률을 알 수 있다. 그 중 가장 큰 확률을 수전설비의 경고 1, 경고 2, 고장 상태로 대응시켜 예측할 수 있다. 그림 7은 RNN의 전체 학습 과정이다.



[그림 7] multi RNN

실험 결과는 그림 8과 같다. 학습 횟수 초기에는 실제 값과 예측 값이 다르지만 10000번 트레이닝 후에는 거의 같게나와 오차가 매우 작다.

하지만 학습이 잘 된 상태에서 계속 학습을 진행하면 값이 수렴하지 않고 학습이 되지 않는 현상이 발생하였다.

이 실험에서는 학습이 어느 정도 잘 되면 그 상태의 모델을 사용해야하는 단점이 있다.

횟수	온도	실제값	예측값	오차
2	[[62, 65, 65]]	[[1]]	[[-0.15713182]]	1.33895
3	[[70, 72, 74]]	[[2]]	[[-0.03144427]]	4.12677
4	[[53, 59, 56]]	[[0]]	[[0.06883121]]	0.00473774
5	[[65, 64, 67]]	[[1]]	[[0.13076325]]	0.755573
6	[[74, 71, 71]]	[[2]]	[[0.20457572]]	3.22355
7	[[59, 56, 53]]	[[0]]	[[0.30542582]]	0.0932849
9995	[[64, 65, 60]]	[[1]]	[[1.00651836]]	4.24891e-05
9996	[[70, 71, 77]]	[[2]]	[[2.00837016]]	7.00596e-05
9997	[[52, 52, 58]]	[[0]]	[[-0.01149541]]	0.000132144
9998	[[61, 65, 61]]	[[1]]	[[0.99230868]]	5.91565e-05
9999	[[79, 72, 71]]	[[2]]	[[1.98777914]]	0.000149349
10000	[[56, 55, 58]]	[[0]]	[[0.0105114]]	0.000110489

[그림 8] 학습 결과

5. 결론

이 논문은 인공지능망 학습 데이터에 온도데이터만을 사용하였다. 온도 데이터만이 아닌 침수 감지나 동작 감지 등의 여러 종류의 센서 데이터를 이용해 기기 고장 발생을 예측하는 모델을 만들 수 있다. 현재는 고장과 관련된 데이터가 적어 실무에 적용해 원하는 결과를 만들기는 힘들다. 또한 이 논문은 쉬운 가상 데이터를 사용하였지만 실제 데이터로 실험을 하게 되면 다시 연구해야 할 부분이다. 실험 중 학습이 잘 된 상태에서 계속 학습을 진행하면 값이 수렴하지 않고 학습이 되지 않는 현상이 발생한 부분도 더 연구해 봐야한다.

ACKNOWLEDGMENTS

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

참고문헌

- [1] 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.
- [2] S. Y. Cho. (2011). An Error Prediction System for Reliability Improvement of Power Distribution System. *Journal of Security Engineering*, 8(6), 705-713