

LSTM 순환신경망을 이용한 비선형 시변 전력데이터 예측 및 분석기술에 관한 연구

최 성 수, 이 효 동
한국전기연구원

sschoi@keri.re.kr

A Study on the Prediction and Analysis of Nonlinear Time varying Power Data Using A LSTM Recurrent Neural Network

Sungsoo Choi, Hyo-Dong Lee
Korea Electrotechnology Research Institute (KERI)

요 약

본 논문은 인공지능(AI) 알고리즘의 딥러닝 방법중 하나인 순환신경망(RNN)기법을 사용하여 전력시스템의 응답지연시간보상이 가능한 실시간 비선형 시변 전력데이터 예측과 분석에 관한 연구방향을 제시한다. 본 연구에서는 3개의 TSC와 2개의 TCR의 싸이리스터 스위칭 기능을 갖는 300MVar SVC (Static Var Compensator)가 설치된 6,000MVA 735kV 임의 계통을 대상으로 하고 있으며, 계통모선의 PCC(Point of Common Coupling)로 부터 전력데이터를 계속하여 딥러닝 학습, 예측과 분석이 가능하도록 하였다. 모의 계통에서 생성된 계속 전력데이터로 부터 장단기기억 (LSTM) 셀로 구성된 RNN딥러닝 구조를 설계하고 학습 데이터 전처리와 딥러닝 모델 도출을 위해 전력데이터의 최적 측정구간과 예측샘플 간격을 포함한 딥러닝 하이퍼 파라미터 최적화를 수행하였다. 또한 계속된 전력데이터와 예측데이터에 대한 이상진단을 돕기위해 IEEE519-2014 표준을 따르는 종합 고조파 왜형률(THD) 분석기능을 함께 구현하였다. 개발된 딥러닝 모델로 실험한 결과, 비선형 시변 전력데이터 예측성능은 약 96.45%로 매우 높은 정확성을 보여주었다.

I. 서 론


최근 대규모 재생에너지 단지와 산업플랜트 확대에 따라 수변부하, 전력변환기기, 인버터 등 비선형 부하가 늘어나고 있는 추세이다. 비선형 부하에 전력을 공급하면, 부하에 흐르는 전류의 파형이 왜곡되고, 이에 의한 전압의 파형왜곡을 발생시키며 계통에 유입되는 고조파전류로 인한 전력계통에 연결된 콘덴서등에 과전류에 의한 과열로 전력설비관리와 어려움과 오동작을 일으키게 되는 원인이 되고 있다[1]. 동시에 교류계통은 송, 수신 양단의 전압 상차각에 따라서 전력을 수송하고 있지만 송전선이 장거리화하면 위상각이 증대하여 탈조, 난조에 이르게 되는데 중간점의 전압을 SVC에 의하여 유지하면 과도안정도가 대폭 향상된다. 대체로 공급변전소의 계통모선을 PCC 지점으로 하며 송전계통의 설비고장 등 계통무효전력 수급 불균형에 대비하고, 정상운전 및 상정고장시 안정도 향상을 목적으로 운영한다[2]. 그러나 기존 SVC PI 제어기는 전압안정화를 위한 처리지연으로 전력데이터가 계속되는 시점의 크기와 위상값이 현 제어시점과 틀어질 수 있는 문제를 가지고 있다. 제어하는 시점이 약간만 틀어져도 이에 따라 오히려 변형된 위상투입으로 인한 공칭값의 수습여백 큰 과전류가 발생할 수 있다. 이러한 문제점을 해결하기 위해 본 연구에서는 인공지능(AI) 알고리즘의 딥러닝 방법중 하나인 순환신경망(RNN)기법을 사용하여 비선형 시변 전력데이터값을 미리 예측을 하여, 전력시스템 SVC 제어부의 응답지연시간을 획기적으로 줄이고자 한다. 또한 계속 및 예측된 전력데이터가 IEEE 519표준에서 정하는 고조파 전압 및 전류제한에 따르고 있는지 비교 분석해 보고자 한다.

II. 본론


비선형 시변 전력데이터 예측 및 분석 대상

본 연구의 계통시험모델은 그림1에 보인 바와 같이 기본주파수 60Hz에서 200MW 인덕터 단락등가회로를 갖는 부하와 300MVar SVC (Static Var Compensator)가 설치된 6000MVA 735kV 계통을 대상으로 한다. SVC 설비는 109MVar TCR 한 개와 94MVar TSC 세 개로 구성된다. SVC 제어시스템은 계통모선 1차측으로 부터 전압값을 측정하여 싸이리스터 제어각 펄스들을 생성하

고 싸이리스터 스위치 On/Off 신호를 발생시킨다. SVC 제어시스템을 5×10^{-5} 샘플링시간으로 1.1초동안 연속적으로 운영하며 계통모선의 무효전력(Q)을 투입/방출시킴으로 계통전압을 안정화 시킨 결과의 그림2에 보였다.



[그림1] 비선형 시변전력데이터 예측 및 분석을 위한 SVC 실험모델




[그림2] 300MVar/100MVar SVC 계통모의 실험결과: 비선형 시변 전력데이터 I_{SVC} 샘플일부(좌), 전력데이터 V_{pri} , I_{svc} 계측값, 무효전력, 전압기준오차 및 TCR펄스, TSC 스위치 제어신호(우)

LSTM 순환신경망 딥러닝 알고리즘 모델 최적화 설계

RNN은 시계열 데이터를 처리하는데 적합한 딥러닝 알고리즘으로 잘 알려져 있다. 시간의 흐름에서 발생하는 데이터를 시계열 시퀀스 데이터라 한다. 이미지 추론으로 잘 알려진 CNN과 같은 신경망 구조에서는 모든 입력과 출력이 독립적으로 동작하기 때문에 시퀀스

데이터를 시간의 흐름에 반영 할 수 없다. 하지만 RNN의 출력 결과는 이전의 계산 결과에 영향을 받기 때문에 시퀀스의 모든 요소마다 적용이 가능하다는 장점이 있다. 그러나 RNN 딥러닝 알고리즘은 시퀀스 데이터 시간의 길이가 길어지고 층이 깊어질수록 학습능력이 크게 떨어지는 단점이 있다. 이를 해결하기 위해 나온 알고리즘이 LSTM셀을 적용한 RNN기법으로, 입력 시퀀스 데이터에 대해 cell state로부터 어떤 정보를 버릴 것인지 알 것인지 정한다. 즉 오래된 기억까지 잃어버리지 않고 전달하여 학습에 사용될 수 있도록 셀 내에 여러 게이트와 필터기능을 추가한 것으로 RNN의 장기기억 의존성문제 (Vanishing gradient problem)를 근본적으로 해결한다[3].



[그림3] 순환신경망을 구성하는 LSTM 셀 기본구조

본 논문에서는 순환신경망의 LSTM셀을 채택하여 변압기 1차측의 계통 모선 PCC에서 1.1초 동안의 i.i.d 통계분포를 갖는 Monte-Carlo 방법으로 비선형 시변 전력데이터를 생성한다. 추출된 전체 전력데이터들 중 80%는 학습데이터로 사용하고 이들 중 20%를 validation, 그리고 나머지 20%를 테스트데이터로 분할하여 딥러닝 엔진모델의 입력값으로 순차적으로 사용한다. 학습모델 구조와 최적의 파라미터 추출은 무효전력보상과 전압안정화를 위해 SVC제어 응답시간 내 처리와 전력데이터를 미리 확보할 수 있도록 설계하였다. LSTM을 이용하여 3개의 층으로 구조를 구성하고, 두 단의 FC 층을 두고 주어진 계층구간에서 부분학습을 진행하였으며 SVC 응답시간 내 처리가능한 시간마진에 해당하는 예측 샘플값을 갖도록 LSTM 모델의 구조는 many to one과 many to many 방식을 사용하였다. 하이퍼 파라미터 최적화를 위해서 Batch Size, Learning rate, 그리고 Optimizer 등의 파라미터 종류를 정한다. Batch Size는 40, 60, 128, 256, 512, 764, 1024로 가변 설정하고, Learning rate는 0.1, 0.01, 0.001, 0.0001, 0.00001로 변화를 줄 수 있도록 하였다. Optimizer 종류는 Adam, Adagrad, Adadelata, SGD, 그리고 RMSprop으로 가변하며 개별적으로 딥러닝 학습의 최적화를 수행한다. 반복되는 학습 결과, 최소의 Loss 값을 갖는 하이퍼 파라미터들을 최종 학습모델에 반영 하였다.

[표1] 최적화된 딥러닝 학습 최종 하이퍼 파라미터 결과

measured_time	target_time	optimizer	learning_rate	batch_num	epoch_num
50	30	Adam	0.01	1024	20

비선형 시변 전력데이터 측정구간 및 예측 최적화


순환신경망 구조설계에 따른 비선형 시변 전력데이터 전처리와 측정구간 및 예측 최적화를 위한 파라미터 설정의 경우 측정구간 설정값을 10~60으로 하고, 예측 샘플간격을 10~60으로 번갈아 입력하며 최적화 실험을 수행하였고, 측정구간 50샘플과 예측 샘플간격 30의 최적 딥러닝 파라미터값을 최종적으로 추출하였으며, 이에 따른 예측 정확도성능은 약 96.45% 를 보였다.

전력데이터 분석을 위한 종합 고조파 왜형률 (THD) 측정

IEEE 519-2014 표준을 따르는 극단시간 고조파 측정을 통하여 THD를 분석한다. 전력데이터 분석을 위한 고조파 측정법으로는 극단시간고조파측정법(very short time harmonic measurements)과 단시간고조파측정법(Short time harmonic measurements)이 있다. 극단시간 고조파 측정법은 IEC 61000-4-30에서 제한한 3초 간격 기준 측정법이다. 60Hz 계통에서는 12cycle, 50Hz 계통에서는 10cycle이 되어야 한다. 극단시간 고조파 측정법은 아래 수식에 보인 바와 같이 측정시간이 24시간이며 12cycle 동안 측정된 값을 15회 연속하여 누적해 3초간의 값으로 고조파를 측정한다.

$$F_{n,vs} = \sqrt{\frac{1}{15} \sum_{i=1}^{15} F_{n,i}^2}$$

여기서 $F_{n,i}$ 는 전압(V) 또는 전류(I), n은 고조파 차수, i는 카운팅수, vs는 very short을 뜻한다. 고조파 측정으로 통계적 평가 방법이 사용된다. 통계적 평가 방법은 측정된 전압 및 전류 데이터를 통계적 누적분포 함수로 변환해 백분위 95% 또는 99%가 되는 값을 대표 THD로 사용한다. 대표 THD 값은 IEEE std 519-2014의 규제치 이내에 있어야 한다[4]. 이때 일간 측정 99% 백분위는 극단시간(3sec)값으로 IEEE std.519-2014 전압제한치의 1.5배보다 낮아야 한다. 그림4는 본 연구에서 개발된 비선형 시변 전력데이터 예측 최적화 파라미터 추출결과, 시뮬레이터 수행결과로 예측 전류파형 및 고조파 제한치에 따른 대표THD분석 비교결과를 보여준다.



[그림4] 비선형 시변 전력데이터 예측 및 분석 시뮬레이터 수행 결과 및 프로그램 GUI사진

III. 결론

본 논문에서는 SVC가 설치된 6000MVA 735kV계통모선 PCC에서 비선형 시변 전력데이터 기반 LSTM셀을 적용한 RNN 구조를 설계하였고, 50개의 계층 샘플 시퀀스데이터입력으로 30샘플 간격 만큼 앞서서 정확히 예측하는 최적의 파라미터를 추출하였다. 설계된 학습모델을 통한 실험결과, 예측 전력데이터에 대해 96.45% 예측정확도 성능을 가지며 전력시스템에서 약 1.5ms 시간 마진을 확보할 수 있었다. 이는 기존 SVC 제어기에서 처리지연으로 인한 전력데이터가 계속되는 시점의 크기와 위상값이 현 제어시점과 틀어질 수 있는 문제를 주어진 시간내 즉각적으로 해결할 수 있음을 의미한다. 향후, 본 연구를 바탕으로 비선형 시변 전력데이터를 대상으로 하는 딥러닝 알고리즘에 기반한 다양한 온-타임 제어기 설계에 대한 활발한 연구가 기대되어 진다.

ACKNOWLEDGMENT

이 연구는 2021년도 정부(과학기술정보통신부)의 재원으로 국가과학기술위원회 지원의 지원을 받아 수행된 한국전기연구원 기본사업임 (No. 21A01108)

참고 문헌

- [1] 한국전력공사 계통계획처, "송전계통 고조파 관리기준", June 2018.
- [2] 윤종수외, "SVC 설치 운전에 따른 계통의 영향성 평가", 전기학회논문지, 1187-1193, July 2010.
- [3] Hochreiter, S. and Schmidhuber, "Long short-term memory". Neural Computation, 9(8), 1725-1780, J., 1997.
- [4] IEEE Power and Energy Society, "IEEE Recommended Practice and Requirements for Harmonic Control in Electric Power Systems", IEEE std 519-2014.