

순환신경망을 이용한 전력시스템의 다중-스텝 상태 예측

최형태*, 김정훈*
포항공과대학교*

Multi-Step State Forecasting in Power System via Recurrent Neural Network

Hyung Tae Choi*, Jung Hoon Kim*
Pohang University of Science and Technology (POSTECH)*

Abstract - 본 논문에서는 순환신경망 구조를 활용한 전력시스템의 다중 스텝 상태 예측 알고리즘을 제안한다. 우선, 다수의 분기점을 갖는 전력시스템을 모델링하고, 이를 위한 다중 스텝 상태 예측 문제를 수학적으로 정의한다. 해당 문제의 해결을 위해 다수의 층을 갖는 순환신경망 모델을 소개하고, 다수의 스텝 후의 상태를 예측할 수 있는 신경망 학습 알고리즘을 제안한다. 제안한 방법론의 검증은 위해, 예측 스텝의 수와 신경망 구조에 따른 예측 성능을 비교하고 분석한다.

1. 서론

전력시스템의 상태 추정(state estimation) 문제는 시스템 보호 및 에너지효율 관리 등의 목적으로 오랜 기간 다루어지고 있는 중요한 문제이다[1]. 보다 정확히 말하면, 위 문제는 전력 흐름(power flow) 등 관측 가능한 시스템의 정보로부터 시스템을 구성하는 상태에 해당하는 각 분기점의 전압값을 추정해 내는 문제를 말한다. 해당 문제의 해결을 위한 논의가 지속되는 이유는, 현재 전력시스템은 대규모(large-scale) 네트워크로 구성되어 있을 뿐만 아니라 관측 가능한 데이터들은 본질적으로 시스템 상태와 복잡한 비선형적(nonlinear) 관계를 가지고 있기 때문이다. 최근 인공지능(AI) 알고리즘을 적용한 방법론[2]들이 개발되어 위 문제를 해결하고 있지만, 이러한 해결책들은 급격한 전압 변동(fluctuation)과 같은 계통 고장을 사전에 예측한 후 방지하는 것에는 용이하지 않다.

상기의 어려움을 극복하기 위해, 전력시스템 상태 예측(state forecasting) 문제가 주목을 받고 있다[3]. 해당 문제는, 주어진 과거의 상태 정보들로부터 미래의 상태를 알아내는 것을 목적으로 한다. 이의 해결책으로, 칼만 필터(Kalman filter)를 사용한 방법론[4]과 벡터 자동-회귀(vector auto-regression)를 적용한 방법론[5] 등이 개발되었지만, 이들은 공통적으로 예측 값이 과거 정보들에 선형적(linearly)으로 의존하기 때문에 주로 비선형적 관계를 가지는 장시간(long-time) 예측을 수행하기에는 부적합하다. 따라서, 최근에는 위와 같은 비선형적인 입출력 관계를 표현하기 위해 인공신경망을 사용한 방법론[6,7]이 주목을 받고 있다. 그 중에서도, 순환신경망(RNN) 방법론[7]은 피드포워드 신경망(FNN) 방법론[6]에 비해 계산 부담을 절감하여 적은 학습 시간에도 더 좋은 예측 성능을 가진다는 것이 확인되었다. 하지만, [7]의 결과는 주어진 과거의 정보들로부터 단 한 스텝의 미래만 예측하는 '단일 스텝 예측'에 해당하기 때문에 이를 현실적으로 활용하기에는 어려움이 있다.

따라서 본 논문에서는, [7]에서 제안된 RNN 기반 상태 예측 알고리즘을 일반화하여 다중 스텝 상태 예측 알고리즘을 제안하고, 그 성능을 수치적으로 평가하려고 한다. 우선, 다수의 분기점을 가지는 전력시스템을 모델링하고, 해당 시스템에 대해 k -스텝($k > 1$) 상태 예측 문제를 소개한다. 문제의 해결을 위해, 숨은 상태(hidden state)들을 쌓아 만들어지는 RNN 모델을 소개하고, RNN의 출력이 상태 예측 값이 되도록 모델 계수들을 학습하는 알고리즘을 소개한다. 수치적 검증으로, 다수의 분기점을 가지는 실제 전력시스템 모델을 고려하며, RNN 구조와 예측 스텝 수(k)에 따른 예측 성능을 비교 및 분석한다.

2. 전력시스템 상태 예측 문제를 위한 RNN 모델

본 장에서는 전력시스템 상태 예측 문제를 소개하고, 이를 해결하기 위한 RNN 모델을 소개하는 것을 목표로 한다. 우선, 첫 번째 절에서는 n -bus 전력시스템을 소개하고 이를 기반으로 상태 예측 문제를 수학적으로 정의한다.

2.1 n -bus 전력시스템 소개 및 문제 설정

n -bus 전력시스템은 수학적으로 n 개의 노드를 갖는 그래프 $G=(N,L)$ 로 정의된다. 여기서, $N:=\{1,2,\dots,n\}$ 은 전력시스템을 구성하는 bus들의 집합이고, $L:=\{(i,j)|i,j\in N\}$ 은 bus와 bus를 잇는 line들의 집합이다.

전력시스템 G 의 상태(state)는 k 번째 bus ($k\in N$)와 시간 t 에서의 복소전압값 $V_{k,t}=v_{k,t}^r+jv_{k,t}^i$ 으로 정의된다. 여기서, $v_{k,t}^r, v_{k,t}^i\in R$ 는 각각 전압 $V_{k,t}$ 의 실수 값과 허수 값을 의미한다. 복소전압값 $V_{k,t}$ 을 전력시스템의 상태로 정의하는 이유는, 각 bus에서의 복소전압값 $V_{k,t}$ 으로부터 각 line (i,j)를 따라 흐르는 전류 및 전력의 흐름 등을 모두 계산해 낼 수 있는 핵심적인 정보이기 때문이다.

각 bus에서의 상태 $V_{k,t}$ 의 성분들을 쌓은 상태벡터 v_t 를 다음과 같이 정의해보자.

$$v_t = [v_{1,t}^r, v_{1,t}^i, v_{2,t}^r, v_{2,t}^i, \dots, v_{n,t}^r, v_{n,t}^i]^T \quad \dots (1)$$

이를 기반으로, n -bus 전력시스템 G 의 k -스텝 상태 예측 문제는 다음과 같이 정의된다.

[k -스텝 상태 예측 문제]

주어진 과거 상태정보 $\{v_t|0\leq t\leq T\}$ 들로부터, 관계식 $v_{t+k}=\phi(v_t, v_{t-1}, \dots, v_{t-r+1})$ 을 가장 잘 만족하는 함수 ϕ 를 찾아라. 보다 정확하게 말하면, 예측 오차값 $\|v_{t+k}-\phi(v_t, v_{t-1}, \dots, v_{t-r+1})\|$ 을 최소화하는 함수 ϕ 를 찾는 문제이다.

단, $r, k(\geq 1)$ 는 각각 예측을 위해 필요한 과거 상태의 개수, 예측하고자 하는 스텝의 수를 의미한다. 또한, $k=1$ 인 경우 기존에 다루어진 단일 스텝 예측 문제[7]에 해당하며, 본 논문에서는 이를 다중 스텝 $k > 1$ 인 예측 문제로 확장하고자 한다.

2.2 n -bus 전력시스템의 상태 예측을 위한 RNN 모델

본 절에서는 k -스텝 상태 예측 문제의 해결을 위한 RNN 모델을 소개하고, 그 구체적인 해결 방법에 대해 다루고자 한다. 즉, 위의 예측 함수 ϕ 를 RNN 모델로 대체하는 방법을 소개한다.

RNN은 입력과 출력 사이의 상관관계를 학습하기 위해, 숨은 상태(hidden state)라는 대상을 사용한다. 숨은 상태 s_τ ($t-r+1\leq\tau\leq t$)란, 다음의 관계식을 만족하는 상태이다.

$$s_t = f(R^0 v_t + R^{ss} s_{t-1} + r^0) \quad \dots (2)$$

여기서, R^0, R^{ss} 는 각각 입력과 이전 시간의 숨은 상태를 위한 가중 행렬 (weighted matrix)이며, r^0 는 편향 (bias) 항을 의미한다. 또한, $f(\cdot)$ 는 활성화 함수(activation function)라고 부르는 함수로 일반적으로 비선형성을 지닌다. 이러한 개념을 반복 적용하면, RNN의 각 층(layer)을 위한 숨은 상태 s_t^l 를 다음과 같이 정의할 수 있다.

$$s_t^l = f(R^{l-1} s_{t-1}^{l-1} + R^{ss,l} s_{t-1}^l + r^{l-1}) \quad \dots (3)$$

여기서, l 은 RNN을 구성하는 층의 번호를 의미하며, $R^{l-1}, R^{ss,l}, r^{l-1}, f(\cdot)$ 는 위와 같이 정의된 가중 행렬과 편향 항 및 활성화 함수에 해당한다. 여기서, $l \geq 3$ 인 경우의 RNN 구조를 Deep RNN 이라고 부른다.

수식 (3)과 같은 RNN의 숨은 상태들을 사용해, 최종적으로는 다음과 같은 모양의 RNN의 출력 y 를 정의할 수 있다.

$$y = R^{out} s_t^l + r^{out} \quad \dots (4)$$

여기서, 출력 y 는 최종 층의 숨은 상태에 선형인 관계를 갖고 있음을 주목하자.

이러한 RNN 모델을 활용하여, 우리는 앞서 언급한 k -스텝 상태 예측 문제를 해결하고자 한다. 즉, $y = v_{t+k}$ ($k > 1$) 를 만족하는 RNN 구조를 찾고자 하며, 이는 주어진 활성화 함수에 대해 가중 행렬들과 편향 항 ($R^{l-1}, R^{ss,l}, r^{l-1}$)을 잘 결정하도록 하는 문제로 귀결된다. 가중 행렬과 편향 항의 결정을 위해서는, 기존에 알려진 역전파기법(back-propagation method)를 사용하여 예측 오차값이 작아지도록 하는 방향으로 위 행렬과 항들을 변형하도록 한다.

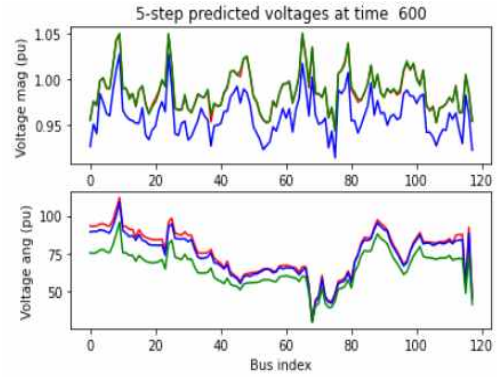
3. 수치적 검증

본 장에서는 이전 장에서 소개한 RNN 기반 상태 예측 알고리즘의 성능을 평가하기 위해, 수치적 예제를 소개하는 것을 목표로 한다. 보다 구체적으로, IEEE 118-bus 시스템 ($n = 118$)을 예제로 들어 위 알고리즘을 수치적으로 평가해 본다.

우선, 주어진 과거의 상태는 총 $T = 18528$ 시간 만큼 알려져 있고 (즉, 주어진 정보는 $\{v_t | 0 \leq t \leq 18528\}$), 이 중 80%에 해당하는 상태 정보는 RNN을 학습하는 것에 사용하며, 나머지 20%는 학습된 RNN의 예측 성능을 평가하는 것에 사용한다. RNN의 활성화 함수는 잘 알려진 'Relu' 또는 'Tanh'를 사용하였고, 이의 학습을 위해 Epoch는 10, Batch size는 32로 설정한 'Adam' optimizer를 사용하였다. 또한, 상태 예측에 필요한 과거 상태의 개수 r 은 20으로 설정하였다.

상기에 언급한 특성들을 고려하며 RNN을 학습한 결과로, $k = 2, 3, 5, 10$ 에 대한 k -스텝 상태 예측 결과를 얻을 수 있었고, 그 중 대표적으로 $k = 5$ 인 경우를 그림 1에 첨부하였다. 그림 1에 따르면, 적색으로 표기된 실제 상태 값 v_{true} 를 따라, 청색과 녹색으로 표기된 k -스텝의 상태 예측이 잘 이루어졌음을 확인할 수 있다. 단, 여기서 청색은 'relu' 활성화 함수를 사용한 예측 결과이고, 녹색은 'tanh' 활성화 함수를 사용한 예측 결과에 해당한다.

또한, 예측 알고리즘의 정량적 평가를 위해, 각각의 $k = 2, 3, 5, 10$ 에 대해 전력시스템의 예측된 상태 v_{pred} 와 실제 상태 값 v_{true} 의 차이에 대한 2-norm, 즉, $|v_{pred} - v_{true}|_2$ 를 고려하도록 한다. 표 1에 따르면, k 가 커짐에 따라 예측 오차값이 상대적으로 증가하긴 하지만 실제 값 v_{true} 에 비해서는 받아들일 만한 오차($\sim 1\%$)임을 확인할 수 있으며, 'relu' 활성화 함수가 'tanh' 활성화 함수에 비해 일반적으로는 더 좋은 예측 성능을 가짐을 확인할 수 있다.



<그림 1> t=600에서, 전압 크기와 위상의 5-스텝 예측 (적색: 실제 전압 값, 청색: 'relu' 를 사용한 예측 값, 녹색: 'tanh' 를 사용한 예측 값)

<표 1> k-스텝 상태 예측 알고리즘의 예측 오차 값(%)

	k=2	k=3	k=5	k=10
Relu activation	0.4818%	0.5663%	0.7464%	0.6713%
Tanh activation	1.1941%	1.1879%	1.2465%	1.2036%

4. 결론

본 논문에서는 RNN 모델을 사용하여 n-bus 전력시스템의 상태를 예측하였다. 보다 구체적으로는, 기존의 단일 스텝 예측 알고리즘을 일반화하여 다중 스텝 예측 알고리즘을 구성하였고, 제안한 알고리즘을 실제 전력시스템 모델을 사용하여 수치적 성능을 평가해 보았다. 후속 연구로, 기존의 RNN 모델을 발전시킨 LSTM, Attention 및 Transformer를 활용한 예측 알고리즘을 제안하고 기존과의 성능을 비교하는 연구가 가능할 것이다.

감사의 글

본 연구는 2022년도 산업통상자원부의 재원으로 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구과제입니다.(No. 2022A10100010)

[참고 문헌]

- [1] G. Wang, et. al., "Distribution network state estimation: An overview of recent developments," Front. Inf. Technol. Electron. Eng., vol. 20, no. 1, pp. 4-17, 2019.
- [2] L. Wang, et. al., "Physics-guided deep learning for power system state estimation," Jour. Moder. Pow. Syst. Clean Ener., vol. 8, no. 4, pp. 607-615, 2020.
- [3] L. Zhang, et. al., "Power system state forecasting via deep recurrent neural network," IEEE Conf. Acou. Sp. Sig., 2019, pp. 8092--8096.
- [4] A. S. Debs, et. al., "A dynamic estimator for tracking the state of a power system," IEEE Trans. Power App. Syst., vol. 89, no. 7, pp. 1670-1678, 1970.
- [5] M. Hassanzadeh, et. al., "A short-term nodal voltage phasor forecasting method using temporal and spatial correlation," IEEE Trans. Power Syst., vol. 31, no. 5, pp. 3881-3890, 2016.
- [6] M. B. Do Coutto Filho, et. al., "Forecasting-aided state estimation - Part I: Panorama," IEEE Trans. Power Syst., vol. 24, no. 4, pp. 1678-1685, 2009.
- [7] L. Zhang, et. al., "Real-time power system state estimation and forecasting via deep unrolled neural networks," IEEE Trans. Sig. Proc., vol. 67, no. 15, 2019.