

장단기 기억 신경망의 상태 추정에 관한 연구

진용식

한국전자통신연구원

yongsik@etri.re.kr

A study on state estimation of long short-term memory neural networks

Jin Yongsik

Electronics and Telecommunications Research Institute.

요약

본 논문은 장단기 기억 신경망의 상태 추정에 대한 연구 결과를 제시한다. 제안된 방법에서는 상태 추정기 설계를 위하여 리아프노프 안정성 해석 방법을 적용하였다. 상태 추정기 설계 조건을 선형 행렬 부등식으로 도출하기 위하여 게이트 유닛과 활성화 함수의 비선형 성질이 이용되며 제시된 설계 조건을 볼록 최적화 문제로 최적화하여 상태 추정기의 이득 값을 계산한다. 제시된 연구의 주요 기여점은 기존의 간단한 순환 신경망들을 다루었던 상태 추정 연구들을 더 복잡한 구조를 가지는 장단기 기억 신경망으로 확장한 것이다. 따라서 많은 논문들에서 다루었던 상태 추정 및 안정성 분석 연구 결과들을 더 복잡한 순환 신경망에 적용할 수 있게 한다. 제시된 방법은 장단기 기억 신경망의 상태 추정 시뮬레이션을 통해 검증된다.

I. 서론

인공 신경망은 사람이나 동물 뉴런의 메커니즘을 모방하여 정보를 처리하는 기술로 다양한 분야에서 뛰어난 성과를 보여주고 있다. 특히 영상 인식/검출, 자연어처리, 음성 신호처리 등 복잡한 신호를 처리하는 문제에서 우수한 성능을 보여준다 [1-3]. 인공 신경망의 활용이 많아짐에 따라 신경망의 안정성 및 동적 특성을 분석하는 연구가 많이 이루어지고 있다 [4]. 특히 실제 뉴런의 상태를 추정하는 문제와 신경망의 카오스 성질을 이용한 보안 통신 문제에 활용하기 위하여 동적 신경망의 상태를 동기화하는 연구가 심도있게 진행되어 왔다 [5, 6].

기존의 연구들은 주로 간단한 순환 신경망 모델에 대한 안정성 분석 및 상태 추정 문제를 다루었다 [7]. 하나의 활성화함수를 가지는 단일 순환 신경망 모델에 대하여 외란, 상태 및 입력의 시간 지연 등의 문제를 해결하였고 다양한 성능 개선 방법들이 제시되었다 [8]. 그러나 장단기 기억 신경망과 같이 게이트 유닛들을 가지는 순환 신경망에 대해 안정성 분석이나 상태 추정 방법은 아직 개발되지 않았다. 이는 본 연구의 주요 기여점으로 제안된 방법에서는 입력, 출력, 망각 게이트를 가지는 신경망의 상태 추정기 설계 방법을 제안한다.

장단기 기억 신경망은 기존의 단순한 구조의 순환 신경망들이 가졌던 장기 기억에서의 문제점을 해결하고자 게이트 유닛들과 셀 상태를 도입하였다 [9]. [9]에서 제안된 방법은 기존 순환 신경망들의 성능들을 많이 개선하였고 최근의 시계열 데이터 처리에서는 대부분 장단기 기억 신경망이 적용된다 [10]. 그러나 게이트 유닛들은 순환 신경망의 동작 메커니즘을 더 복잡하게 만들고 기존의 안정성 분석 및 상태 추정 방법을 적용할 수 없게 만들었다. 따라서 장단기 기억 신경망의 안정성 분석 및 상태 추정 방법을 제공하는 것은 중요한 문제로 남아 있다.

II. 본론

본론에서는 장단기 기억 신경망의 상태 추정기 설계 방법이 제시된다.

장단기 신경망 모델은 다음과 같이 주어진다.

$$\begin{aligned}c(t+1) &= f(t)c(t) + i(t)g(t), \\g(t) &= \tanh(W_x x(t) + W_h h(t) + b), \\h(t) &= o(t)\tanh(c(t)), \\y &= Dc(t).\end{aligned}\tag{1}$$

(1)에서 $c(t)$ 와 $h(t)$ 는 장단기 신경망의 셀 상태와 은닉 상태를 나타내는 벡터이며 $f(t)$, $i(t)$, $o(t)$ 는 각각 망각, 입력, 출력 게이트를 의미한다. $x(t)$ 신경망의 입력을 나타내고 $y(t)$ 는 외부에서 접근 가능한 장단기 신경망의 출력이다. W_x , W_h , b 는 신경망의 가중치 행렬과 바이어스 벡터를 나타낸다 [9].

장단기 기억 신경망의 상태를 추정하기 위해 다음의 상태 추정기가 구성된다.

$$\begin{aligned}\hat{c}(t+1) &= \hat{f}(t)\hat{c}(t) + \hat{i}(t)\hat{g}(t) + K(y(t) - \hat{y}(t)), \\ \hat{g}(t) &= \tanh(W_x x(t) + W_h \hat{h}(t) + b), \\ \hat{h}(t) &= \hat{o}(t)\tanh(\hat{c}(t)), \\ \hat{y} &= D\hat{c}(t).\end{aligned}\tag{2}$$

$\hat{c}(t)$ 와 $\hat{h}(t)$ 는 상태 추정기의 셀 상태와 은닉 상태를 나타내는 벡터이며 $\hat{f}(t)$, $\hat{i}(t)$, $\hat{o}(t)$ 는 각각 상태 추정기의 망각, 입력, 출력 게이트를 의미한다. $\hat{y}(t)$ 는 상태 추정기의 출력을 나타낸다. K 는 상태 추정기의 제어 이득 값이며 설계되어야 하는 행렬이다.

상태 추정기 설계를 위해 상태 추정 오차를 $e(t) = c(t) - \hat{c}(t)$ 로 정의하면 다음과 같은 상태 추정 오차 모델이 주어진다.

$$\begin{aligned}e(t+1) &= f(t)e(t) + (f(t) - \hat{f}(t))\hat{c}(t) + i(t)\bar{g}(t) \\ &\quad + (i(t) - \hat{i}(t))\hat{g}(t) + KDe(t), \\ \bar{g}(t) &= g(t) - \hat{g}(t).\end{aligned}\tag{3}$$

제어기 K 의 설계를 위해 리아프노프 안정성 방법이 사용된다. 리아프노프 안정성 방법을 적용하기 위해 아래와 같은 리아프노프 함수가 정의된다.

$$V(t) = e(t)^T P e(t). \quad (4)$$

또한 상태 추정기 이득 행렬을 최적화 하기 위해 선형 행렬 부등식 형태로 안정 조건이 도출되며 이때 장단기 기억 신경망의 비선형성을 처리하기 위해 $\tanh(\bullet)$ 와 게이트 유닛들의 섹터 비선형 성질이 이용된다. 따라서 아래의 두 조건들을 만족시키는 충분조건을 선형 행렬 부등식 형태로 도출하면 상태 추정기의 이득 값을 최적화할 수 있고 장단기 기억 신경망의 상태 추정 오차를 0으로 수렴시키는 것을 보장할 수 있다.

$$\begin{aligned} V(t) &= e(t)^T P e(t) > 0, \\ \Delta V(t) &= e(t+1)^T P e(t+1) - e(t)^T P e(t) < 0. \end{aligned} \quad (5)$$

III. 시뮬레이션

상태 추정기 설계 방법을 검증하기 위해 장단기 기억 신경망의 상태 추정이 시뮬레이션된다. 3개의 뉴런을 가지는 장단기 기억 신경망이 주어지고 상태 추정기를 이용하여 신경망의 셀 상태를 추정한다. 상태 추정기는 하나의 뉴런의 상태 값을 이용하여 나머지 2개의 뉴런 상태 값을 추정한다. 그림 1은 장단기 기억 신경망과 상태 추정기의 상태 궤적을 보여주고 그림 2는 상태 추정 오차의 궤적을 보여준다. 상태 추정 오차가 0으로 수렴하는 것을 그림 2에서 확인할 수 있다.

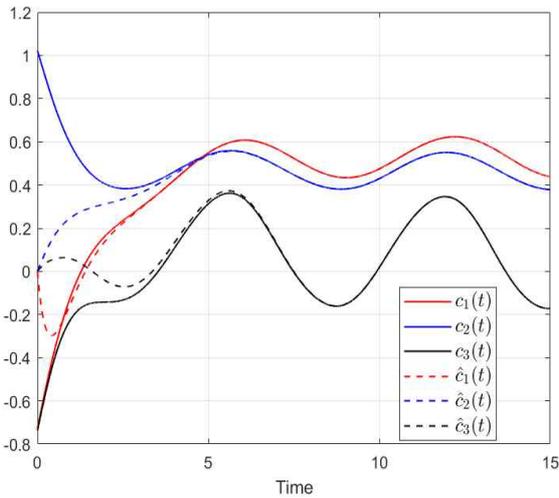


그림 1. 장단기 기억 신경망과 상태 추정기의 궤적

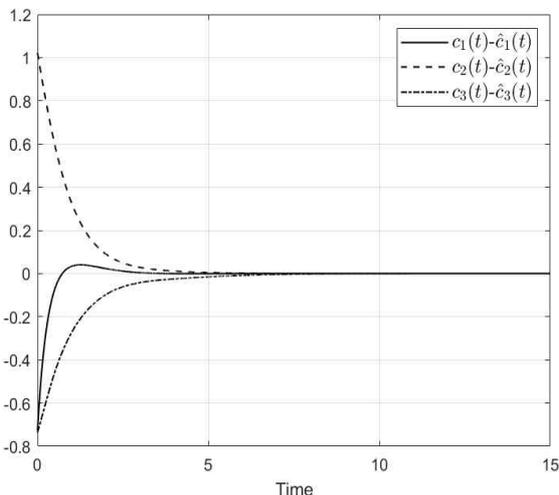


그림 2. 상태 추정 오차의 궤적

IV. 결론

본 논문은 장단기 기억 신경망의 상태 추정기 설계 방법을 다루었다. 상태 추정기를 설계하기 위해 리아프노프 안정성 해석 방법이 사용되었다. 또한 설계 조건을 선형 행렬 부등식으로 도출하여 블록 최적화하기 위해 게이트 유닛과 활성화 함수의 비선형 성질이 이용되었다.

ACKNOWLEDGMENT

This research was supported by "Electronics and Telecommunications Research Institute (ETRI) grant funded by the Korean government (22ZD1130), Development of ICT Convergence Technology for Daegu-Gyeongbuk Regional Industry".

참고 문헌

- [1] Khan, Faisal, Saqib Salahuddin, and Hossein Javidnia. "Deep learning-based monocular depth estimation methods—A state-of-the-art review." *Sensors* 20.8 (2020): 2272.
- [2] Agbo-Ajala, Olatunbosun, and Serestina Viriri. "Deep learning approach for facial age classification: a survey of the state-of-the-art." *Artificial Intelligence Review* 54.1 (2021): 179–213.
- [3] Chai, Junyi, and Anming Li. "Deep learning in natural language processing: A state-of-the-art survey." 2019 International Conference on Machine Learning and Cybernetics (ICMLC). IEEE, 2019.
- [4] Kaplan, Harris S., et al. "Nested neuronal dynamics orchestrate a behavioral hierarchy across timescales." *Neuron* 105.3 (2020): 562–576.
- [5] Roelfsema, Pieter R., et al. "Visuomotor integration is associated with zero time-lag synchronization among cortical areas." *Nature* 385.6612 (1997): 157–161.
- [6] Shanmugam, Lakshmanan, et al. "Adaptive synchronization of reaction-diffusion neural networks and its application to secure communication." *Ieee transactions on cybernetics* 50.3 (2018): 911–922.
- [7] Zhang, Xian-Ming, and Qing-Long Han. "State estimation for static neural networks with time-varying delays based on an improved reciprocally convex inequality." *Ieee transactions on neural networks and learning systems* 29.4 (2017): 1376–1381.
- [8] Jin, Yongsik, Wookyong Kwon, and Sangmoon Lee. "Parameterized Luenberger-Type H^∞ State Estimator for Delayed Static Neural Networks." *Ieee Transactions on Neural Networks and Learning Systems* (2021).
- [9] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." *Neural computation* 9.8 (1997): 1735–1780.
- [10] Sherstinsky, Alex. "Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network." *Physica D: Nonlinear Phenomena* 404 (2020): 132306.