

믹서 기반 신경망을 이용한 이진 수열 생성

윤보라, 김정현, 최효정*, 송홍엽*

세종대학교, 연세대학교*

22012142@sju.ac.kr, j.kim@sejong.ac.kr, {hjchoi3022, hysong}@yonsei.ac.kr*

Binary Sequence Generation via Mixer-based Neural Networks

Bora Yoon, Junghyun Kim, Hyojeong Choi*, Hong-Yeop Song*

Sejong Univ., Yonsei Univ.*

요약

본 논문은 MLP-Mixer 기반 구조를 활용하여 수열 내 및 수열 간 관계를 효과적으로 학습하는 수열 생성 모델을 제안한다. 제안 모델은 자기상관 및 상호상관 지표를 포함한 수열 설계에 특화하여 새롭게 정의된 순실 함수를 통해 상관특성과 균형특성을 동시에 만족하는 수열을 생성한다. 실험을 통해 제안된 모델이 기존 세 가지 Chaotic map 기반 수열 생성 방식에 비하여 가장 좋은 자기상관 및 상호상관 값을 나타내며 균형성 측면에서도 가장 우수한 성능을 보임을 확인하였다.

I. 서론

신경망은 학습을 통해 일정한 규칙이나 패턴을 내재화하고 이를 바탕으로 새로운 데이터를 생성하거나 예측할 수 있는 모델이다[1]. 학습 과정에서 얻은 특성과 구조적 관계를 활용하여 초기 조건이나 입력에 따라 다양한 데이터를 유연하게 생성하거나 추론할 수 있다. 이러한 특성을 바탕으로 신경망은 통신 시스템을 포함한 다양한 응용 분야에 적용되고 있으며, 관련 연구도 활발히 진행되고 있다[2-4]. 최근에는 순실 함수와 평가지표를 사용자의 목적으로 맞게 정의하고 최적화할 수 있도록 지원하는 딥러닝 프레임워크가 등장하면서, 목표 기반의 모델 설계와 성능 향상에 기여하고 있다[5].

한편 Chaotic map 기반 수열 생성 기법은 초기값에 대한 민감도를 활용하여 서로 다른 무한한 수열을 생성할 수 있다는 점에서 주목받았다. 이러한 특성은 좋은 상관특성과 균형특성을 갖는 수열 생성을 가능하게 하여 기존 연구에서 Logistic map, Tent map, Chebyshev map 등을 바탕으로 이진 수열을 생성하고 그 특성을 분석했다[6].

본 논문에서는 이러한 Chaotic map 기반 수열 생성의 장점을 유지하면서 신경망을 기반으로 더욱 정밀한 수열을 생성할 수 있는 모델을 제안한다. 제안 모델은 학습을 통해 상관특성 및 균형특성을 동시에 만족하는 수열을 생성할 수 있도록 설계되었으며 이를 위해 이진 수열의 통계적 특성을 정량화한 맞춤형 순실 함수를 정의하여 학습 과정에 직접 반영하였다. 또한, 생성된 수열을 기존 Chaotic map으로 생성된 수열과 비교하여 생성된 수열들의 상관특성 및 균형특성을 분석한다. 실험 결과, 신경망 기반 생성 모델에 의해 생성된 수열 모두 우수한 상관특성과 균형특성을 동시에 만족함을 확인하였다.

II. 본론

본 논문에서는 MLP-Mixer 기반의 생성 모델을 통해 이진 수열을 생성하는 과정을 제안한다. MLP-Mixer 기반 생성 모델의 구조는 그림 1과 같으며 수열 내 관계 및 수열 간 관계를 효과적으로 학습할 수 있는 mixer 구조를 도입하여 자기상관 및 상호상관 특성을 고려한다. 먼저 initial

sequence 레이어는 외부 입력없이 각 수열에 대해 선형적으로 증가하는 초기값을 직접 생성한다. 생성된 각 초기값은 수열의 길이만큼 반복되어 벡터 형태로 확장되며 여기에 작은 노이즈를 더하여 학습 가능한 초기 수열을 생성한다. 따라서 수열의 길이와 수열의 개수를 자유롭게 설정할 수 있다. Initial sequence 레이어의 구조는 그림 2에 상세히 나타나있다. 이후, Intra-sequence mixing block을 통해 위치 방향을 기준으로 MLP 연산을 수행해 수열 내 위치 간 관계를 학습한다. 또한, 수열 간의 관계를 학습하기 위해 수열을 전치한 후 Inter-sequence mixing block을 적용하며 이는 다양한 수열 간의 관계를 학습하는 역할을 한다. 이때 MLP 연산은 Layer Normalization, Linear, GELU, Linear 레이어로 구성된다. 마지막으로 Sigmoid 함수를 통해 수열을 생성해 출력한다.

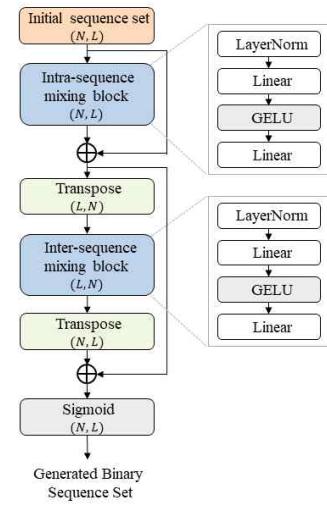


그림 1. 제안하는 신경망 기반 이진 수열 생성 모델

이렇게 생성된 수열은 Binarize-Straight-Through Estimator(STE)를 적용하여 미분이 불가능한 이진화 연산을 연속적으로 근사화함으로써 학습이 가능하도록 처리된다. 학습 중에는 이 근사값을 통해 역전파가 가능하고 최종 출력은 0과 1로 이루어진 수열이다. 이후 상관특성 계산을 위

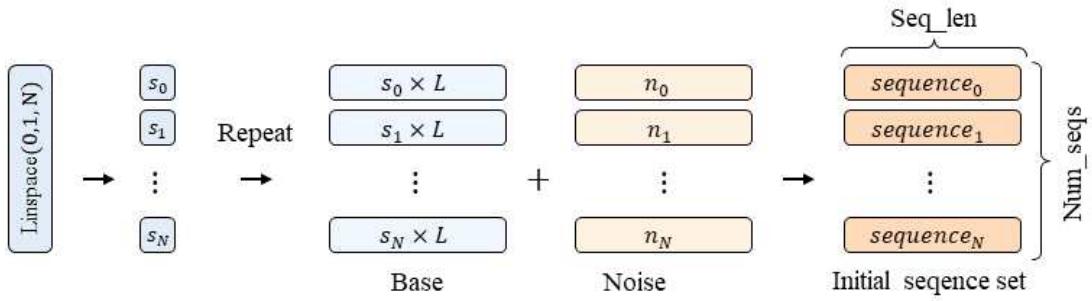


그림 2. 초기 수열 집합 생성

해 -1과 1로 이루어진 수열로 변환한다. 변환된 수열에 대해 자기상관 및 상호상관 값을 구한다. 이때 자기상관 및 상호상관 연산은 시간 영역에서의 직접 연산하는 대신 convolution theorem[6]를 기반으로 fast fourier transform(FFT)와 inverse fast fourier transform(IFFT) 연산을 활용하여 주파수 영역에서 계산되었으며 이는 계산 효율을 크게 향상시켰다.

좋은 상관특성과 균형특성을 갖는 수열 생성을 위해서는 효과적인 생성 모델 설계뿐만 아니라 학습 과정에서 이러한 특성들을 유도할 수 있는 손실 함수의 정의가 필수적이다. 본 논문에서는 수열의 자기상관 및 상호상관 값을 이용해 수열 설계에 특화된 새로운 손실 함수를 정의하였다. 해당 손실 함수는 7개의 항목으로 구성되며 각각 자기상관 평균, 자기상관 최대값, 상호상관 평균, 상호상관 최대값, 균형성, 유일성, 파라미터에 대한 정규화 항을 포함한다. 각 항목은 가중치를 적용해 결합되며 본 논문에서는 균형성과 유일성에 가장 큰 가중치를 부여하였다. 특히, 유일성 여부를 상호상관을 통해 반영하려 하였으나 학습 중 특정 수열 간 상호상관 값을 비정상적으로 증가하는 현상이 발생하여 유일성 항목을 분리하여 별도로 추가하였다. 이렇게 구성된 손실 함수를 기반으로 모델을 최적화하여 학습을 진행했다.

표 1. Chaotic map과 제안 모델의 상관특성과 균형특성

Type	Auto correlation		Cross correlation		1의 비율
	평균	sidelobe max 평균	평균	max 평균	
Logistic map[6]	0.01761	0.0760	0.01763	0.0804	0.49912
Tent map[6]	0.01760	0.0757	0.01763	0.0803	0.50029
Chebyshev map[6]	0.01759	0.0759	0.01761	0.0784	0.50015
제안 모델	0.01700	0.0641	0.01749	0.0705	0.49999

표 1은 기존 Chaotic map 기반 수열 생성 방식(Logistic map, tent map, Chebyshev map)과 본 논문에서 제안한 신경망 기반 생성 모델이 생성한 수열의 상관특성을 비교한 결과를 나타낸다. 제안 모델은 기존 Chaotic map 기반 방식보다 자기상관(auto correlation) 및 상호상관(cross correlation) 관련 여러 지표에서 모두 낮은 값을 보여 상관특성에서 우수한 성능을 보인다. 또한, 각 수열의 1의 비율을 통한 균형특성을 비교한 결과에서도 제안 모델이 안정적인 분포를 형성하는 것을 확인할 수 있다. 이는 신경망 기반 생성 모델과 수열 설계에 특화되어 정의된 손실 함수가 좋은 상관특성과 균형특성을 동시에 만족하는 수열 생성을 가능하게 함을 보여준다.

III. 결론

본 논문에서는 MLP-Mixer 모델을 기반으로 수열 내 및 수열 간 관계를 효과적으로 학습하고 자기상관 및 상호상관 값을 이용한 수열 설계에 특화된 새로운 손실 함수를 정의하여 상관특성과 균형특성을 동시에 만족하는 수열 생성 모델을 제안하였다. 실험 결과, 제안한 신경망 기반 생성 모델은 기존 세 가지 Chaotic map 기반 수열에 비해 가장 낮은 자기상관 및 상호상관 값을 가지며, 1의 비율 분포를 통해 균형성 측면에서도 가장 안정적인 수열을 생성함을 확인하였다. 이러한 결과는 제안 모델이 Chaotic map의 장점을 유지하면서도 더 우수한 특성을 갖는 무한한 수의 이진 수열 집합을 생성할 수 있음을 나타낸다.

ACKNOWLEDGMENT

이 (성과)는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No.RS-2023-00209000).

참 고 문 헌

- [1] Goodfellow, I., Bengio, Y., and Courville, A., "Deep Learning," Cambridge, MA, USA: MIT Press, 2016.
- [2] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, T., and Polosukhin, I., "Attention is all you need," in Proc. Advanced in Neural Information Processing Systems (NeurIPS), pp. 5998–600, 2017.
- [3] Roberts, A., Engel, J., Raffel, C., Hawthorne, C., and Eck, D., "Music Transformer: Generating music with long-term structure," in Proc. International Conference on Learning Representations (ICLR), 2021.
- [4] Lee, H., Lee, B., Yang, H., Kim, J., Kim, S., Shin, W., Shim, B., and Poor, H. V., "Towards 6G Hyper-Connectivity: Vision, Challenges, and Key Enabling Technologies," Journal of Communications and Networks, vol. 25, no. 3, pp. 344–354, Jun. 2023.
- [5] Terven, J., Cordova-Esparza, D.M., Romero-González, J.A., Ramírez-Pedraza, A., and Chávez-Urbiola, E. A., "A comprehensive survey of loss functions and metrics in deep learning," Artificial Intelligence Review, vol. 58, no. 195, Apr. 11, 2025.
- [6] Choi, H., Noh, H., and Song, H.-Y., "Correlation property and balance property of binary sequence generated by chaotic map," Proceedings of Symposium of the Korean Institute of communications and Information Sciences, pp. 565–566, Nov. 2022.
- [7] Oppenheim, A. V., and Schafer, R. W. "Discrete-Time Signal Processing," Pearson Education India, 1999.