

스마트 양식 시스템 모니터링을 위한 딥러닝 기반 수온 예측 모델의 시퀀스 길이에 따른 성능 분석

박태현, 신학중, 조성균, 정재영*

*한국전자통신연구원

toddpk@etri.re.kr, hakjong@etri.re.kr, skjo@etri.re.kr, *jyy72@etri.re.kr

Performance Analysis of a Deep Learning-Based Water Temperature Prediction Models According to Sequence Length for Smart Aquaculture

Park Tae Hyun, Shin Hak Jong, Jo Seng Kyoung, Jung Jae Young*

*Electronics and Telecommunications Research Institute

요약

국내 넙치 양식장 내 수온 환경은 먹이 섭취율과 사료 효율성에 직결되지만, 대부분이 단순 실시간 모니터링과 사후 분석에 의존해 신속히 대응하지 못함으로써 최적의 사육 환경을 이끌어내지 못하고 있다. 본 연구에서는 이러한 문제를 해결하기 위해, 국내 넙치 양식장에서 수집된 수온 데이터를 활용하여 딥러닝 알고리즘 기반의 수온 예측 시계열 모델을 개발하였다. 이를 위해, RNN, LSTM, Transformer 학습 알고리즘 및 입력 시퀀스 길이에 따른 예측 성능 거동을 분석하였다. 그 결과, 입력 시퀀스 길이가 길어짐에 따라 전체적인 시계열 예측 모델들의 성능이 저하하는 것으로 나타났으며, Transformer 기반 모델이 가장 안정적인 성능을 보이는 것으로 나타났다.

I. 서론

국내 어류 양식업은 2024년 총 81,911톤의 생산량을 기록하며 전년 대비 2.4% 성장세를 보였다[1]. 이 중 넙치(Paralichthys olivaceus)는 약 40,000톤(전체 생산량의 49%)·6,800억원(전체 생산금액의 56%)을 차지하며 양식업의 주력 품목으로 자리잡고 있다. 넙치는 체중과 사육 수온 변화에 따라 먹이 섭취율(feed intake rate)이 유의미하게 달라지고, 이로 인한 사료 효율(feed conversion ratio)의 변동은 결국 성장 속도 및 경제적 수익성에 직접적인 영향을 미친다[2]. 그러나 대부분의 양식장에서는 여전히 실시간 센서 모니터링과 사후 통계 분석에만 의존하고 있어, 수온 변화에 따른 적절한 사전 조치가 불가능하다. 그 결과 적정 수온에 따른 최적 효율의 사료 투입이 어려워 비용 손실 및 생산성 저하를 초래한다. 본 연구에서는 이러한 한계를 극복하고 사육 환경의 예측 기반 의사결정을 지원하기 위해, 국내 넙치 양식장에서 실측된 수온 데이터를 활용하여 딥러닝 기반 수온 예측 모델을 설계하고, 다양한 시계열 알고리즘 및 입력·출력 시퀀스 조건에 따른 성능을 체계적으로 분석하였다.

II. 본론

본 연구에서는 그림 1과 같이 2023년 7월 16일부터 2024년 10월 5일까지 전남 완도군 넙치 양식장 테스트베드에서 1분 간격으로 수집한 연속 수온 시계열 데이터를 활용한다. 1 시간 내 수온 변화는 평균값을 중심으로 약 $\pm 0.2^{\circ}\text{C}$ 범위로 작은 범위에서 변화가 있기에 한 시간 단위로 샘플링을 진행하였다.




그림 1. 넙치 양식장 테스트베드 내 수조 수온 거동

본 연구에서는 입력과 출력의 길이가 동일한 시계열 예측 모델을 설계하였다. 길이 L 의 입력 시퀀스를 $L/2$ 만큼 중첩되는 슬라이딩 윈도우로 분할해 학습 데이터를 생성하고, 추론 시에는 입력 시퀀스의 마지막 $L/2$ 구간을 참조구간으로 디코더에 입력한 뒤, 길이 L 의 출력 값을 순차적으로 예측하도록 하였다. L 은 1, 2, 4, 6, 12, 24, 36, 48, 96으로 설정하여 시퀀스 길이에 따라 모델을 비교하였다.

비교 대상 모델로는 딥러닝 기반의 RNN[3], LSTM[4], Transformer[5] 알고리즘을 사용하였다. RNN은 순환 신경망의 기본 구조로 학습 성능의 하한을 제시하고, LSTM은 기울기 소실 문제를 해소하여 장·단기 의존성을 효과적으로 학습할 수 있는지 검증하기 위해 도입하였다. Transformer는 자기-어텐션(self-attention) 메커니즘을 통해 비선형·비주기적 패턴을 병렬로 학습할 수 있는 구조로, 순환 모델 대비 학습 효율과 예측 정확도를 비교하기 위해 포함하였다.

모든 딥러닝 모델의 학습률, 은닉 차원 등 주요 하이퍼파라미터는 검증 세트를 기반으로 베이지안 옵티마이저를 통해 탐색하였으며, 학습에는 Adam 옵티마이저와 MSE 손실 함수를 사용한다. 모델 성능 평가는 MAE(Mean Absolute Error), MSE(Mean Squared Error) 두 가지 지표를 통해 테스트 세트 결과를 정량 비교·분석하였다.

III. 성능평가

그림 2는 입력 및 출력 시퀀스 길이에 따른 시계열 예측 모델들의 MAE(Mean Absolute Error) 변화를 나타내고 있다. 그림 2에 나타난 바와 같이, 세 모델 모두 시퀀스 길이가 증가할수록 MAE가 전반적으로 상승하는 경향을 보였으며, 특히 RNN 모델은 시퀀스 길이가 96에 도달할 때 급격한 예측 성능 저하를 나타냈다. 반면 LSTM과 Transformer 모델은 전 구간에 걸쳐 비교적 안정적인 예측 성능을 유지하였으며, 시퀀스 길이가 증가함에 따라 서서히 오차가 커지는 유사한 성능 변화를 보였다. 두 모델 모두 긴 시퀀스에 대한 학습과 예측이 가능한 구조적 특성을 지니고 있으나, 전반적으로 Transformer 기반 모델이 LSTM 대비 더 낮은 MAE를 기록하였으며 예측 정확도 측면에서 우수한 성능을 보였다.




그림 2. 시퀀스 길이 및 알고리즘별 시계열 예측 모델의 MAE 거동

그림 3은 시퀀스 길이 72에서의 수온 예측을 비교한 결과를 나타낸다. 예측 구간에서 RNN과 LSTM 모델은 변동성을 제대로 포착하지 못해 중앙값 부근의 거의 직선 형태로 수렴한 반면, Transformer 모델은 입력 데이터의 변동성을 일정 부분 재현해 실제 추세와 유사한 패턴을 유지했다. 표 1은 딥러닝 알고리즘별 시계열 모델의 성능지표를 나타낸 것으로 실험 결과 수치상 큰 차이는 보이지 않았다. RNN과 LSTM 모델은 시퀀스 길이가 길어질수록 평균 회귀적 예측 경향이 강화되어 오차가 감소한 반면 Transformer 모델은 시퀀스 길이가 길어 질수록 시계열 데이터 패턴을 보다 정교하게 재현함을 확인하였다. 이를 통해 해당 모델은 변동성이 큰 양식장 환경에 보다 적합한 모델임을 시사한다.




그림 3. 딥러닝 알고리즘별 시계열 예측 모델 비교(시퀀스 길이: 72)

표 1. 딥러닝 알고리즘별 시계열 모델의 성능지표(시퀀스 길이: 72)

Model	MAE	MSE
RNN	0.4718	0.4324
LSTM	0.4516	0.4154
Transformer	0.4203	0.4020

IV. 결론

본 연구는 실시간 모니터링과 사후 분석에 의존해 온 기존 양식장 관리 방식의 한계를 극복하기 위해, 전남 완도군 넓치 양식장 테스트베드에서 수집된 수온 데이터를 활용하여 시계열 예측 모델의 성능을 비교·분석하였다. 실험에는 RNN, LSTM, Transformer 알고리즘을 적용하였으며, 입력 시퀀스 길이와 예측 구간 조건을 달리하여 모델별 예측 성능을 평가하였다. 그 결과, Transformer 모델이 모든 조건에서 일관되게 가장 낮은 예측 오류를 기록하며 우수한 성능을 보였다. 이는 양식장 운영자가 수온 변화를 사전에 인지하고, 이에 따라 적절한 사료 투입 시점과 투입량을 조절함으로써 불필요한 비용 손실과 성장 저하를 효과적으로 방지할 수 있음을 시사한다.

향후 연구에서는 용존산소, pH, 염도 등 다변량 환경 요인을 통합하여 예측 정확도를 더욱 향상시키고, Informer, Pathformer, DUET 등 Transformer 기반 최신 시계열 예측 아키텍처를 도입함으로써 보다 정교하고 실시간 대응이 가능한 스마트 사육 환경 관리 시스템으로의 발전이 기대된다.

ACKNOWLEDGMENT

본 연구는 2022년도 해양수산부 재원으로 해양수산 과학기술진흥원의 지원(RS-2022-KS221676, 유수식 스마트 양식 시스템 개발)을 받아 수행된 연구임.

참 고 문 헌

- [1] Statistics Korea, "Preliminary Results of the Survey on the Status of Fish Culture in 2024," 2024. [Online]. Available: <https://www.kostat.go.kr/>. [Accessed: Mar. 21, 2025].
- [2] J. Seo and J. Park, "Development of a TGC-based growth model for the olive flounder, *Paralichthys olivaceus*, and its application in developing a fish growth simulator architecture," *Aquaculture*, vol. 594, p. 741383, 2025.
- [3] I. Amalou, N. Mouhni, and A. Abdali, "Multivariate time series prediction by RNN architectures for energy consumption forecasting," *Energy Reports*, vol. 8, pp. 1084-1091, 2022.
- [4] M. Waqas and U. W. Humphries, "A critical review of RNN and LSTM variants in hydrological time series predictions," *MethodsX*, p. 102946, 2024.
- [5] A. Zeng, M. Chen, L. Zhang, and Q. Xu, "Are transformers effective for time series forecasting?," in *Proc. AAAI Conf. Artif. Intell.*, vol. 37, no. 9, pp. 11121-11128, Jun. 2023.