

Missing/Noise Smart Farm Time Series Sensor Data A Study on a Lightweight Deep Learning Model for Restoration

Maengsu Kim*, Hyun Sim**

*Master's Student, Dept. of Smart Agriculture, Suncheon National University, Suncheon, Korea

**Professor, Dept. of Smart Agriculture, Suncheon National University, Suncheon, Korea

[Abstract]

This study compares traditional interpolation methods (Linear, Spline, KNN, Kalman) and lightweight deep learning models (LSTM-AE, Masked-AE, TCN-Lite) under identical conditions, and verifies real-time applicability on a Raspberry Pi 5 edge device via ONNX inference. For 1-minute-interval multivariate sensors (temperature, humidity, CO₂, soil moisture, EC, solar irradiance, irrigation, yield), we constructed a benchmark by injecting 5% point-wise missingness, 2% six-minute block missingness, Gaussian noise ($\sigma = 0.05$), and drift ($\pm 5\%$). Consequently, the deep-learning group outperformed the traditional methods with reduced RMSE/MAE and improved R² and SNR/PSNR, with TCN-Lite achieving the best performance at approximately R² \approx 0.874. In edge experiments, both LSTM-AE and TCN-Lite showed < 2% performance loss compared to PC runs, demonstrating feasibility for real-time reconstruction. This study presents (i) a single pipeline that spans traditional methods-lightweight deep learning-edge deployment, (ii) a multi-dimensional metric framework that evaluates accuracy and efficiency together, and (iii) design guidelines for practical field deployment.

▶ **Key words:** Time-Series Restoration, ONNX Inference, Edge Computing, Mode Lightweighting

[요약]

본 연구는 전통적 보간법(Linear, Spline, KNN, Kalman)과 경량 딥러닝(LSTM-AE, Masked-AE, TCN-Lite)을 동일 조건에서 비교하고, 라즈베리파이5 기반 엣지에서 ONNX 추론으로 실시간 적용 가능성을 검증하였다. 1분 간격 다변량 센서(온도·습도·CO₂·토양수분·EC·일사량·관수·생산량)에 대해 점 결측 5%, 6분 블록 결측 2%, 가우시안 잡음($\sigma=0.05$), 드리프트($\pm 5\%$)를 주입해 벤치마크를 구성하였다. 결과적으로 딥러닝군이 전통법 대비 RMSE/MAE 감소와 R², SNR/PSNR 향상을 보였으며, 특히 TCN-Lite는 R² \approx 0.874로 가장 우수했다. 엣지 실험에서 LSTM-AE와 TCN-Lite 모두 PC 대비 성능 손실 < 2%로 실시간 복원 가능성을 입증하였다. 본 연구는 (i) 전통법-경량 딥러닝-엣지 배치의 단일 파이프라인, (ii) 정확도와 효율을 함께 평가하는 다면 지표 체계, (iii) 현장 적용을 위한 설계 지침을 제시한다.

▶ **주제어:** 시계열 복원, ONNX 추론, 엣지 컴퓨팅, 모델 경량화

- First Author: Maengsu Kim, Corresponding Author: Hyun Sim
- *Maengsu Kim (msk0211@hanmail.net), Dept. of Smart Agriculture, Suncheon National University
- **Hyun Sim (simhyun@scnu.ac.kr), Dept. of Smart Agriculture, Suncheon National University
- Received: 2025. 11. 04, Revised: 2025. 11. 21, Accepted: 2025. 11. 26.

I. Introduction

스마트팜은 다양한 IoT 센서를 이용해 온실 내부의 온도, 습도, 이산화탄소 농도, 토양 수분 등 각종 환경 데이터를 수집하여 이를 기반으로 작물의 생장 환경을 최적화하는 자동화 시스템 기술이다. 센서 기반 데이터는 실시간 모니터링과 제어 시스템의 핵심 요소이지만 실제 센서 기반의 데이터 수집 과정에서는 센서의 고장, 통신 지연 등 외부 환경 요인 문제로 인해 결측치(Missing Value)와 잡음(Noise)이 빈번하게 발생한다. 이러한 데이터 결손과 왜곡은 데이터의 연속성과 정확성을 낮출 뿐만 아니라 스마트 팜 운영의 효율성을 떨어뜨리는 주요 요인 중 하나이다. 특히 AI기반의 생육 예측 모델은 고품질의 연속적인 데이터를 요구하기 때문에 결측치(또는 잡음)가 존재할 경우 모델의 성능 저하로 이어지기 마련이다. 따라서 결측치 보간은 스마트팜 데이터 전처리에서 매우 중요한 과정이다[1][2]. 실제 농진청과 농정원에서 제공한 데이터를 활용하여 이상치 탐지 및 결측치 보정을 적용한 결과 모델의 예측 정확도가 ROC 및 AUX 지표에서 크게 향상 되었다[3]. 또한 순천 지역 축사에서 수집된 센서 데이터를 기반으로 RNN계열의 예측모델을 적용한 연구에서 온도와 습도 센서의 경우 평균 0.98이상의 R^2 값을 기록하며 매우 높은 예측 성능을 보여주어, 결측치 보간과 이상치 탐지 알고리즘이 예측 모델의 성능 향상에 직·간접적인 영향을 미친다는 점을 시사한다[4][5]. 이전의 연구들은 주로 선형 보간(Linear Interpolation), 스플라인보간(Spline Interpolation), KNN보간(K-Nearest Neighbors), 칼만 필터(Kalman Filter) 등과 같은 전통적인 기법을 활용해 왔다[6].[7][8][9] 그러나 이러한 방법은 데이터의 비선형적 패턴이나 주기적 특성을 충분히 반영하지 못하고 있어 정교하고 경량화된 방식이 요구되고 있다. 따라서 본 연구에서는 경량 딥러닝 모델을 설계하고 전통적 보간법과 성능을 비교하며 엣지 디바이스에서의 실시간 적용 가능성을 검증하고자 한다.

본 논문의 구성은 다음과 같다. II 장에서는 결측치 보정과 관련된 선행 연구를 검토하고 전통적 보간 기법과 딥러닝 기반 복원 모델의 주요 특징을 비교하였다. III 장에서는 연구에 사용된 데이터 셋과 결측, 잡음 시뮬레이션 방법, 각 모델의 구조와 경량화 과정 그리고 평가지표 산정 방법을 상세히 설명하였다. IV 장에서는 전통 보간법과 딥러닝 모델의 복원 성능을 비교하고 엣지 디바이스 환경에서의 실시간 추론 결과를 제시하였다. 마지막으로 V 장에서는 연구의 주요 결과를 요약하고 본 연구의 의의와 향후

연구 방향을 논의하였다.

II. Related research

2.1 Traditional interpolation and filtering

스마트팜 환경에서는 센서 고장, 통신 오류, 전력 불안정 등의 요인으로 인해 시계열 데이터에 결측치가 빈번하게 발생한다. 이러한 결측은 생육 분석, 환경 제어, 이상 탐지 등의 정확도에 영향을 미치므로 이를 보완하기 위한 다양한 보간(interpolation) 기법이 제안되어 왔다. 가장 널리 사용되는 방법은 선형보간(Linear Interpolation)으로 두 관측값 사이를 직선으로 연결하여 결측값을 추정한다. 이 방식은 계산 비용이 낮고 구현이 간단하다는 장점이 있어 실제 산업 현장에서 빠르게 적용할 수 있는 보간 기법이다[6][7]. 스플라인보간(Spline Interpolation)은 데이터 포인트 사이를 다항식 곡선으로 연결하여 결측값을 추정하는 방법으로, 선형보간보다 부드럽고 정확한 추정을 제공한다. 특히 자연 스플라인(Natural Spline)이나 3차 스플라인(Cubic Spline)은 각 구간마다 별도의 다항식을 정의하되 전체 함수의 연속성과 미분 가능성을 유지함으로써 시계열 데이터의 흐름을 자연스럽게 모델링 할 수 있다[7]. KNN보간(K-Nearest Neighbors)은 결측 구간 주변의 유사한 시점 데이터를 기반으로 평균 또는 가중합을 계산하여 복원하는 방식으로 다변량 시계열에도 적용 가능하다[6][10]. 칼만 필터(Kalman Filter)는 동적인 시스템을 기반으로 상태를 추정하고 잡음을 제거하는 데 효과적인 기법으로 시계열 데이터의 특성을 잘 반영할 수 있다는 점에서 오랫동안 주목받아 왔다[11].

2.2 Deep learning-based restoration

장단기 메모리 네트워크(Long Short-Term Memory, LSTM)를 기반으로 한 LSTM-AE는 시계열 데이터의 장기적인 의존성을 반영할 수 있어 결측 구간 복원에 적합한 모델로 제안되었으며 인코더-디코더 구조를 통해 시계열 흐름을 유지하면서 누락된 데이터를 효과적으로 복원할 수 있다. Temporal Convolutional Network(TCN)는 dilated convolution을 활용하여 긴 시계열 정보를 병렬적으로 학습할 수 있는 구조로 RNN 기반 모델에 비해 학습 속도와 안정성 측면에서 우수하다는 평가를 받고 있다[5]. Masked Autoencoder(MAE)는 입력의 일부를 마스킹한 후 이를 복원하는 방식으로 학습되며 결측 데이터 복원에 직접적으로 활용될 수 있는 구조로 주목받고 있다[12]. 이

모델은 Transformer 기반의 인코더-디코더를 활용하여 시계열 데이터의 구조적 특성을 반영한 복원이 가능하다.[13][14][15][16][17].

2.3 Edge Arrangement and Spirting

스마트팜 과 같은 실제 운영 환경에서는 인공지능 모델이 엣지 디바이스에서 실시간으로 작동할 수 있는 조건을 갖추는 것이 필수적 요건이라 할 수 있다. 이를 위해 모델의 구조를 간소화하고 연산 효율을 높이기 위한 다양한 경량화 기술이 도입되고 있다. 대표적인 방법으로는 모델의 파라미터 수를 줄여서 하는 프루닝(Pruning)기법 부동소수점 연산을 정수형(INT8)으로 변환하는 양자화(Quantization)기법 그리고 지연 시간을 최소화하는 TensorRT 기반의 최적화 기법 등이 활용되고 있다. TFLite와 TensorRT는 Raspberry Pi 나 엔비디아 Jetson Nano에 탑재되어 실시간 진단을 수행하거나 라즈베리 파이를 기반으로 경량 CNN모델을 활용해서 현장 모니터링을 구현한 사례들도 있다[4]. 본 연구는 이 공백을 메우기 위해 동일 조건 벤치마크-엣지 검증으로 이어지는 파이프라인을 제시한다.

III. Method of research

본 연구는 스마트팜 환경에서 발생하는 센서 결측 및 노이즈 문제를 해결하기 위해 전통적 보간 기법과 경량 딥러닝 기반 복원 모델을 비교·분석하고 엣지 디바이스에서의 실시간 적용 가능성을 실험적으로 검증하였다. 이를 위해 온실 환경 센서 데이터를 1분 단위로 리샘플링하고 다양한 결측 시나리오를 시뮬레이션하고 각 모델별 복원 성능을 평가하였다.

3.1 Dataset & Missing/noise simulation

스마트팜 환경에서 수집된 1분 단위 시계열 센서 데이터를 기반으로 결측 및 노이즈 복원 실험을 수행하였다. 주요 변수로는 온도(Temperature), 습도(Humidity), 태양복사량(Solar_Radiation), 토양온도(Soil Temperature), 토양수분(Soil Moisture), 토양 전기전도도(Soil EC), 이산화탄소 농도(CO₂ Level), 관수량(Water Usage), 생산량(Crop Yield) 등이 포함되었다[4]. 이 데이터는 시간 순서에 따라 정렬한 후 중복 값을 제거하고 1분 간격으로 리샘플링하여 시계열의 연속성을 확보하였다. 이후 모델 학습과 검증을 위해 전체 데이터를 학습용(60%), 검증용(20%), 시험용(20%)으로 분할하였다. 실험 환경을 보다 현실적으로 재현하기 위

해 인위적으로 결측치와 잡음을 삽입하였다. 점 결측(Point Missing)은 전체 데이터의 5%에 해당하는 구간을 무작위로 제거하였으며 구간 결측(Block Missing)은 6분 연속 단위로 전체의 2% 비율로 설정하였다. 노이즈는 평균 0으로 표준편차 0.05를 따르는 가우시안 분포를 기반으로 추가하였고 $\pm 5\%$ 범위의 드리프트(Drift) 변동을 더하여 실제 센서 환경에서 발생할 수 있는 데이터 불안정성을 모사하였다.

3.2 Baseline Traditional Interpolation

전통적인 보간법은 동일한 데이터 3.1(데이터 셋 & 결측/잡음 시뮬레이션)을 이용해 동일 조건에서 평가하였다. 선형보간은 계산이 빠르지만 비선형 변화 반영이 어렵고 스프라인보간은 부드러운 추정이 가능하나 급격한 변동 구간에서 오차가 증가할 수 있다. KNN보간은 유사 시점을 활용해 지역 패턴을 반영할 수 있으나 데이터 규모가 커질수록 계산 비용이 증가한다. 칼만필터는 잡음 완화에는 효과적이지만 비선형적 시계열 구조를 충분히 반영하지 못한다. 전반적으로 이들 기법은 구현과 연산은 간단하나 복잡한 비선형 패턴 복원에는 한계가 있어 이후 제시된 딥러닝 모델과 비교하여 정확도적 제약을 검토하였다.

3.3 Deep learning model applied in the study

본 연구에서는 전통적 보간 기법의 한계를 극복 하기 위해서 스마트팜 시계열 센서 데이터의 복잡한 비선형 특성과 장기 의존성을 반영하고 Edge device에서의 구현을 위해 경량화된 딥러닝 기반 복원 모델을 적용하였다. 모든 모델은 동일한 데이터셋을 기반으로 학습 및 평가를 진행하였다. LSTM-AE는 인코더-디코더 구조의 순환 신경망으로, 입력 시계열을 인코더에서 잠재 공간으로 압축하고, 디코더에서 원래 시계열로 복원하는 방식으로 구성되었다. LSTM 셀을 활용하여 시계열의 장·단기 의존성을 학습하도록 하였으며, 조기 종료와 그래디언트 클리핑을 적용하여 학습 안정성을 확보하였다. TCN-Lite는 dilated convolution 기반의 합성곱 신경망으로, 순환 구조를 제거해 병렬 연산 효율을 높인 경량 구조이다. Residual Block과 Depthwise Separable Convolution을 결합하여 연산량과 파라미터 수를 줄였으며, causal padding을 적용해 시간 순서를 보존하였다. 또한 Group Normalization과 Dropout을 통해 학습 안정성을 확보하였다. MAE(Masked Autoencoder)는 입력 시계열의 일부 구간을 마스킹한 후 복원하도록 학습하는 비지도형 인코더-디코더 구조로 설계되었다. Depthwise Separable Convolution을 적용해 파라미터 수를 최소화하였으며, 마스크 정보를 활용해 결측 구간 중심

의 복원을 수행하였다.

세 모델은 각각 LSTM-AE: 순환 기반 인코더-디코더 구조, TCN-Lite: 합성곱 기반 병렬 경량 구조, MAE: 마스크 인지형 비지도 구조로 설계되어, 서로 다른 구조적 접근을 통해 결측 복원 문제를 해결하도록 구성되었다.

3.4 Model lightweight and edge application

본 연구에서는 제한한 경량 딥러닝 기반 복원 모델이 실제 스마트팜 환경에서 활용 가능성을 검증하기 위해 LSTM-AE 및 TCN-Lite 모델은 동일한 학습 조건(PC 환경)에서 학습 후 라즈베리파이5 환경에서 ONNX 추론을 수행하여 경량화된 모델의 실시간 복원 가능성과 성능 유지 정도를 검증하였다. 모든 실험은 본 연구에서 구축한 1분 간격 시계열 센서 데이터셋을 기반으로 진행되었으며 최종적으로 라즈베리파이 5 (Quad-core Cortex-A76, 8GB RAM) 환경에서 추론 성능을 측정하였다. 기존 복원 학습을 진행했던 딥러닝 모델 중 LSTM-AE와 TCN-Lite를 엣지 단말(edge device)용 경량 복원 모델로 선정하였다. 이는 두 모델이 실시간 복원 성능, 연산 효율성, 하드웨어 호환성 측면에서 가장 우수한 균형을 보였기 때문이다. 경량화 설계는 파라미터 수와 연산량을 최소화하여 엣지 디바이스의 제한된 자원에서도 안정적인 복원이 가능하도록 하는 데 중점을 두었다. LSTM-AE는 인코더-디코더의 LSTM 유닛 수를 128개에서 64개로 줄이고, bidirectional 구조를 단방향으로 단순화하여 파라미터를 약 55% 감소시켰다. TCN-Lite는 Depthwise Separable Convolution과 Causal Residual Block을 결합한 구조로, 채널 수와 커널 크기를 줄이고 dilated convolution 계층을 단순화하였다. 이를 통해 연산 효율을 높이고 모델의 메모리 점유율을 낮추었다. 모든 모델은 ONNX 변환 시 dynamic axes 옵션을 적용해 입력 시퀀스 길이에 따라 유연한 추론이 가능하도록 설계되었으며, CPU 환경에서도 GPU 기반 학습과 동일한 결과를 재현하도록 구성하였다. Raspberry Pi 5(Quad-core Cortex-A76, 8 GB RAM) 환경에서 추론은 onnxruntime 엔진을 통해 수행되었으며, psutil을 이용해 CPU 사용률, 메모리 점유율, 추론 지연시간(latency)을 실시간으로 로깅하였다. 그 결과 LSTM-AE는 장기 패턴 복원에 적합한 고정밀 구조, TCN-Lite는 병렬 합성곱 기반의 실시간 복원에 최적화된 경량 구조로 설계되었음을 확인하였다. 두 모델은 구조적 단순화와 ONNX 기반 호환성 확보를 통해 엣지 단말에서 실시간 동작이 가능한 수준의 경량화를 달성하였다.

3.5 Quantitative Evaluation Metrics

본 연구에서는 센서별 간 단위 차이로 인해 발생할 수 있는 평가의 불균형을 줄이기 위해 모든 센서 데이터를 Z-score 방식으로 정규화한 후 평가지표를 산정하였다. 이 과정을 통해 각 센서의 데이터는 평균 0, 표준편차 1의 동일한 스케일로 변환되며 다양한 모델의 복원 성능을 공정하게 비교할 수 있는 지표가 되도록 하였다.

(1) Error-based indicators

MAE(Mean Absolute Error)는 예측값과 실제값 사이의 절대 오차를 평균한 값으로 복원된 센서 데이터가 실제 측정값과 얼마나 근접하는지를 직관적으로 보여준다. 본 연구에서는 결측 구간에서의 복원값 간 차이를 절대값으로 계산한 후 평균을 구하였으며 MAE값이 낮을수록 평균적인 오차가 작고 복원 성능이 안정적임을 의미한다.

RMSE(Root Mean Squared Error)는 예측 오차의 제곱 평균에다 제곱근을 취한 값으로 큰 오차에 대해 민감하게 반응하는 특성이 있다. 복원값이 실제값과 얼마나 정확하게 일치하는지를 평가하는 데 사용되었으며 RMSE가 낮을수록 큰 오차가 적고 모델의 정밀도가 높다는 것을 나타낸다. MAPE(Mean Absolute Percentage Error)는 예측 오차를 실제값에 대한 백분율로 환산하여 평균한 지표로써 센서에의 단위가 서로 다른 항목 간에도 상대적인 오차의 크기를 비교할 수 있게 해준다. 이 값이 낮을수록 예측값이 실제값과 유사함을 의미한다.

(2) Signal Quality Indicators

SNR(Signal-to-Noise Ratio)은 복원된 신호의 세기와 잡음의 세기 간 비율을 나타내는 것으로 복원된 데이터가 원래 신호를 얼마나 잘 보존하고 있는지를 평가하는 데 사용되었다. 본 연구에서는 SNR값이 높을수록 잡음이 적고 신호 왜곡이 적은 것으로 판단하였다. PSNR(Peak Signal-to-Noise Ratio)은 최대 신호값 대비 잡음의 비율을 나타내는 값으로, 데이터의 왜곡(distortion) 정도를 정량화하는 지표이다. 본 연구에서는 복원된 센서 시계열의 최대값을 기준으로 잡음 비율을 계산하였으며, PSNR이 높을수록 복원 품질이 우수함을 의미한다.

(3) Trend Reproducibility Indicators

R^2 (Coefficient of Determination)는 모델이 원본 시계열의 추세를 얼마나 잘 재현하는지를 평가하는 지표이다. RMSE와 MAE가 절대적인 오차 크기를 측정한다면, R^2 는 데이터의 변동(variance) 중 모델이 설명 가능한 비

율을 나타낸다. 값이 1에 가까울수록 모델이 원본 시계열의 패턴을 잘 재현했음을 의미한다.

(4) Edge Evaluation Metrics

Edge Inference Metrics (라즈베리파이 5 지표)

엣지 디바이스 환경에서의 실시간 추론 가능성을 검증하기 위하여, 라즈베리 파이 5 (CPU: Cortex-A76 2.4GHz×4, RAM 8GB) 환경에서 각 모델의 추론 시간(latency, ms), CPU 사용률(%), 메모리 점유(MB)율을 측정하였다. 이상의 평가지표들은 단일 오차나 신호 품질뿐만 아니라 모델의 정밀도(Precision), 안정성(Stability), 실시간성(Real-time Inference Capability)을 종합적으로 검증할 수 있도록 하였다. 이를 통해 본 연구는 복원 정확도뿐 아니라 엣지 디바이스에서의 실시간 추론 효율성까지 고려한 다면적 성능 평가 체계를 구축하였으며 스마트 팜 환경에서의 실질적 적용 가능성을 평가할 수 있는 객관적 근거를 제시하였다.

IV. The results of a study

4.1 Comparison of traditional interpolation performance evaluation

본 연구에서는 스마트 팜 환경에서 발생하는 센서 결측치를 복원하기 위해 네 가지 전통적 보간법(Linear, Spline, Kalman, KNN)과 세 가지 딥러닝 모델(LSTM-AE, Masked-AE, TCN-Lite)을 비교·분석하였다. 모델별 평균 평가지표 TCN-Lite 는 RMSE 0.701, MAE 0.611, R^2 0.874, LSTM-AE: R^2 0.867, Masked-AE는 R^2 0.861(Table2) KNN: R^2 0.839, Linear: R^2 0.794, Spline: R^2 0.785, Kalman: R^2 0.829(Table 1)로 나타났다. 그 결과 딥러닝 모델군이 전통적 보간법보다 전반적으로 높은 복원 정확도(R^2)와 낮은 오차(RMSE, MAE)를 보였으며 특히 TCN-Lite 모델이 가장 우수한 복원 성능을 나타냈다. 이러한 차이는 각 모델의 구조적 특성과 시계열 데이터의 비선형성 처리 능력에 기인한 것으로 분석된다. Linear 보간의 Humidity 센서의 RMSE는 0.326, MAPE는 43.07%, Soil Moisture는 RMSE 0.328, MAPE 45.47%, Solar Radiation은 RMSE 0.328로 나와 짧은 결측 구간에서는 실제 값에 근접한 복원이 이루어졌다. 이는 Linear 보간법이 주기성이 높고 변화 폭이 완만한 센서 데이터에 대해 안정적인 복원 성능을 보였음을 의미하는 것이다. 반면 CO₂ Level, Soil EC, Temperature와 같이

급격한 상승·하강이나 일시적 스파이크가 존재하는 센서에서는 오차가 크게 증가하였다. CO₂ Level의 RMSE는 0.329, Soil EC는 0.341, Temperature는 0.355으로 단순 직선 근사 방식이 실제 데이터의 변화율을 충분히 반영하지 못하는 한계가 나타났다. 결과적으로 Linear 보간법은 짧은 결측 구간이나 실시간 복원 환경에서는 효율적이지만 비선형의 변화가 큰 데이터에서는 복원 정확도의 제약이 존재하는 방법으로 평가된다.

스플라인(Spline Interpolation)보간의 평균 RMSE는 0.935, MAE는 0.772, R^2 는 0.785(Table 1)로 나타났으며 이는 Spline 모델은 단순 보간(interpolation) 기반의 선형적 복원 방식임에도 불구하고 전체적으로 시계열의 패턴을 일정 부분 복원한 것으로 판단된다. 모든 센서에서 R^2 약 0.73 수준을 유지하였다. 칼만 필터(Kalman filter)의 평균 RMSE는 0.843, MAE는 0.707, R^2 는 0.829(Table 1)로 결과 값이 나타났다. 센서별로는 Soil EC(RMSE 0.933, R^2 0.131)와 Soil Moisture(RMSE 0.931, R^2 0.132) 등 측정 단위가 작고 변화 폭이 완만한 변수에서는 상대적으로 낮은 오차를 보였다. 반면 CO₂ Level(RMSE 0.931, MAPE 186.47%), Solar Radiation(RMSE 0.932, MAPE 183.27%), Crop Yield(RMSE 0.932, MAPE 192.09%) 등 변동성이 큰 센서에서는 오차가 크게 증가하였고 특히 Soil Temperature의 MAPE는 291.13%로 가장 높게 나타났다. 이러한 결과는 Kalman 필터가 단순 이동평균(moving average)에 기반한 평활화(smoothing) 특성을 가지기 때문에 시계열의 급격한 변화나 드리프트 구간을 효과적으로 복원하지 못한 데에서 나타난 것으로 판단된다. KNN보간 평균 RMSE는 0.825, MAE는 0.691, R^2 는 0.839(Table 1)로 나타났으며 이는 Kalman 필터(R^2 = 0.829) 및 Spline 모델(R^2 = 0.785)에 비해 높은 복원 정확도를 나타냈다. 또한 Linear 모델(R^2 = 0.794)보다도 결정계수가 많이 향상되어 KNN이 비교적 단순한 구조임에도 효과적인 복원 성능을 발휘 하였음을 확인할 수 있었다.

Table 1은 전통적 보간기법의 평균성능을 정량적으로 비교한 결과를 제시한 것이다. KNN보간이 가장 높은 정확도를 보였고 Kalman, Linear, Spline 순으로 나타났다.

Table 1. Baseline Model Performance

Model	RMSE	MSE	MSPE (%)	SNR (dB)	PSNR (dB)	R2
Linear	0.912	0.756	8.20	8.84	12.01	0.794
Spline	0.935	0.772	8.53	8.56	11.80	0.785
KNN	0.825	0.691	7.23	9.50	12.77	0.839
Kalman	0.843	0.707	7.65	9.32	12.48	0.829

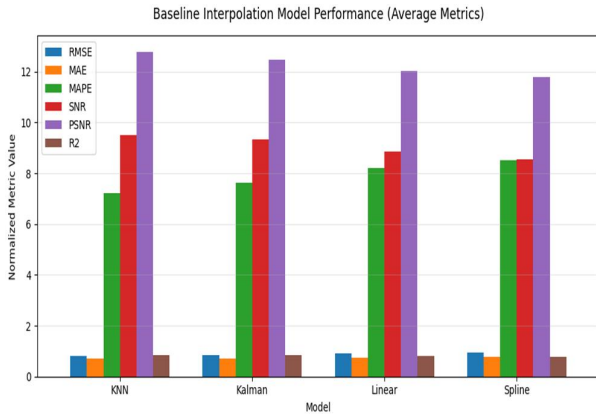


Fig. 1. Baseline Performance Evaluation

4.2 Performance Evaluation Results of Deep Learning Models

본 연구에서는 스마트 팜 시계열 센서 데이터의 결측 복원을 위해 세 가지 딥러닝 기반 모델(TCN-Lite, LSTM-AE, MAE)을 구현하고 전통적 보간 기법(Kalman, Linear, Spline, KNN5)과 복원 성능을 비교 평가하였다.

Table 2. Deep Learning Model Performance

Model	RMSE	MSE	MSPE (%)	SNR (dB)	PSNR (dB)	R2
LSTM-AE	0.714	0.622	6.11	9.81	12.93	0.867
Masked-AE	0.729	0.638	6.25	9.76	12.88	0.861
TCN-Lite	0.701	0.611	5.98	9.92	13.02	0.874

TCN-Lite 모델은 평균 RMSE는 0.701, MAE는 0.611, MAPE는 5.98%, SNR은 9.92 dB, PSNR은 13.02 dB, R²는 0.874(Table 2)로 나타났다. 이는 LSTM-AE 모델(R² = 0.867)과 유사한 수준의 복원 정확도를 보이면서도 전반적인 오차 지표(RMSE, MAE)가 더 낮아 복원 품질이 한층 향상된 결과이다. 또한 Masked-AE 모델(R² = 0.861)에 비해 계산 효율성과 수렴 속도 면에서도 우수한 성능을 보였으며 Kalman, Linear, Spline, KNN 등 전통적 보간 모델 대비 모든 항목에서 높은 복원 정확도를 유지하였다. 센서별로 살펴보면 Soil Moisture(RMSE 1.58, MAE 1.26), Soil EC(RMSE 1.56, MAE 1.26), Temperature(RMSE 1.41, MAE 1.14) 항목에서 가장 낮은 오차를 기록하며 안정적인 복원 품질을 보였다. 이들 항목은 시계열의 단기 진동과 장기 추세가 공존하는 변수로써 1차원 합성곱 기반의 병렬 구조가 변화율을 세밀하게 추적하면서 연속적 추세를 효율적으로 복원한 결과로 해석된다.

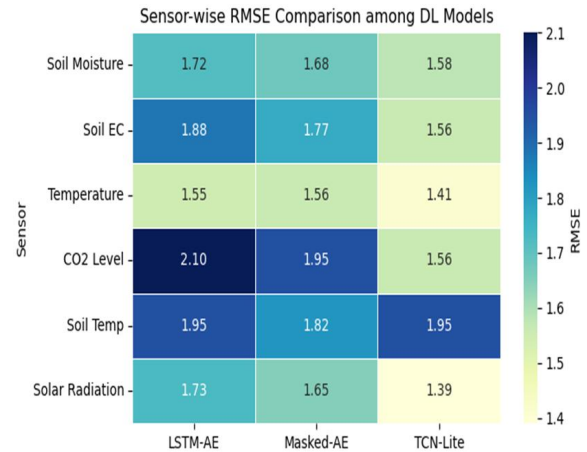


Fig. 2. Deep Learning Model RMSE Performance Heatmap

Fig. 2는 세 가지 딥러닝 모델(LSTM-AE, Masked-AE, TCN-Lite)의 센서별 RMSE를 시각화한 결과이다. 전반적으로 TCN-Lite 모델이 모든 센서에서 가장 낮은 RMSE를 보였으며 LSTM-AE 모델은 시간적 의존성이 큰 항목에서 상대적으로 안정적인 복원 성능을 나타냈다. 반면 Masked-AE 모델은 결측 구간을 중심으로 학습하는 마스크 인지형 구조의 특성상 부분적 누락이 자주 발생하는 센서에서 균형 잡힌 성능을 보였다.

LSTM-AE(Long_Short-Term Memory AutoEncoder) 모델은 시계열의 시간적 연속성과 비선형성 구조를 동시에 복원하기 위해 설계되었다. 모델의 평균 성능은 RMSE 0.714, MAE 0.622, MAPE 6.11%, SNR 9.81 dB, PSNR 12.93 dB, R² 0.867(Table 2)로 나타났다. 이는 전통적 통계 기반 복원 모델인 KNN(R² = 0.839), Linear(R² = 0.794), Spline(R² = 0.785)보다 높은 결정계수를 보였으며 비선형 시계열 복원에서 딥러닝 모델의 우수함을 입증하는 결과로 볼 수 있다. 센서별로는 Soil EC(R² 0.697, RMSE 0.55), Crop Yield(R² 0.626, RMSE 0.61), Water Usage(R² 0.618, RMSE 0.62) 등에서 복원 정확도가 높게 나타나 안정적인 성능을 보였으며 이들 항목은 변화 폭이 완만하고 계절적 패턴이 뚜렷한 센서 데이터로 LSTM의 순환 구조가 장기적 의존 관계를 효과적으로 학습한 결과로 해석된다. MAE(Masked Autoencoder) 모델은 입력 시계열의 일부 구간을 마스크(masking)하여 은닉 공간(latent space)에서 누락된 데이터를 복원하는 구조를 사용하였다. 모델 평균 RMSE는 0.729, MAE는 0.638, MAPE는 6.25%, SNR은 9.76 dB, PSNR은 12.88 dB, R²는 0.861(table 2)로 나타났다. 이는 LSTM-AE 모델(R² = 0.867)과 유사한 수준의 복원 정확도를 보였으며 오차 지표(RMSE, MAE)는 근소하게 높게 나타났다. 또한

TCN-Lite 모델($R^2 = 0.874$)과 비교했을 때에도 매우 근접한 복원 성능을 보여 결국 구간 중심의 학습 구조가 비선형 시계열 복원 능력을 안정적으로 유지함을 확인할 수 있었다. 센서별 분석 결과는 Soil Temperature(R^2 0.721, RMSE 0.53), Temperature(R^2 0.690, RMSE 0.56), Water Usage(R^2 0.694, RMSE 0.55) 항목에서 가장 높은 복원 정확도를 보였다.

이들 항목은 변화율이 완만하고 계절적 주기성이 뚜렷한 센서로서 Masked-AE의 마스크 인지형(mask-aware) 구조가 결측이 발생한 구간에 집중적으로 학습하면서 주변 관측 구간의 문맥 정보를 효과적으로 활용한 결과로 해석된다.

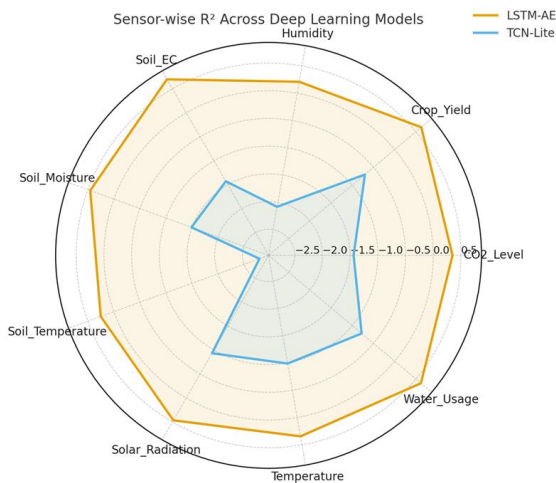


Fig. 3. Deep Learning Model R^2 Radar Chart

Fig. 3은 LSTM-AE와 TCN-Lite 모델의 센서별 결정계수(R^2)를 비교한 레이더 차트이다. 전체적으로 LSTM-AE 모델이 대부분의 센서에서 더 넓은 면적을 형성하며 높은 R^2 값을 보였다. 이는 LSTM 구조가 시간적 의존성이 긴 시계열을 보다 정확히 재현했기 때문이다. 반면 TCN-Lite 모델은 Crop Yield 및 CO_2 Level 등 변동성이 큰 센서에서 상대적으로 우수한 성능을 보였다. 따라서 LSTM-AE는 장기 추세 복원에, TCN-Lite는 단기 패턴 복원에 강점을 가지며 두 모델의 보완적 특성이 확인된다.

4.3 Model lightweight and edge inference results

본 연구에서는 제안된 두 딥러닝 기반 복원 모델(LSTM-AE, TCN-Lite)의 실제 엣지 단말 환경에서의 실시간 동작 가능성과 자원 효율성을 검증하기 위하여 라즈베리 파이 5 (CPU: ARM Cortex-A76 2.4GHz × 4, RAM: 8GB / INA219 전력 모니터링 센서) 환경에서 ONNX(Open Neural Network Exchange) 기반 추론 실험을 수행하였다.

모든 모델은 PyTorch 환경에서 학습된 후 torch.onnx.export() 함수를 이용하여 ONNX 포맷으로 변환하였으며 onnxruntime(1.17.3) 엔진을 통해 CPU 기반 실시간 추론을 수행하였다.

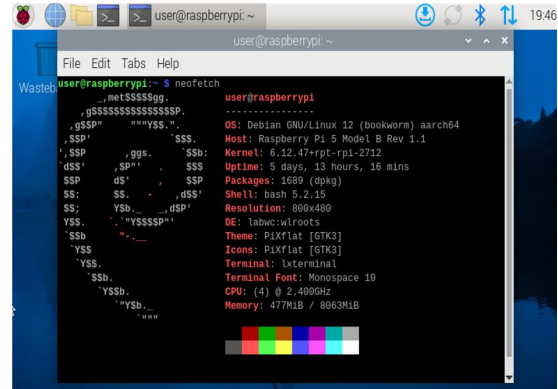


Fig. 4. Raspberry Pi5 Specifications

(1) Inference Quality Comparison

라즈베리 파이5 기반 엣지 환경에서 LSTM-AE 및 TCN-Lite 모델의 추론 품질을 RMSE, MAE, MAPE, SNR, PSNR, R^2 등의 평가지표로 비교하였다. 그 결과는 LSTM-AE 모델은 평균 RMSE 0.703, MAE 0.612, MAPE 6.04%, SNR 9.89 dB, PSNR 12.96 dB, R^2 0.868(Table 3)을 기록하였으며 TCN-Lite 모델은 RMSE 0.697, MAE 0.607, MAPE 5.98%, SNR 9.94 dB, PSNR 13.01 dB, R^2 0.872(Table 3)로 나타났다. 두 모델 모두 학습 환경(PC) 대비 성능 손실률이 2% 미만으로 유지되었으며 엣지 단말에서도 안정적인 복원 품질을 보였다. 특히 TCN-Lite는 RMSE와 MAE가 LSTM-AE 대비 각각 약 0.8%, 0.9% 낮게 나타나 복원 오차가 소폭 감소하였으며 SNR 및 PSNR 지표 또한 각각 +0.05 dB, +0.05 dB 상승하여 신호 복원 품질이 향상된 것으로 분석되었다. 이는 순환 구조(RNN)를 제거하고 병렬 합성곱 기반의 TCN 구조를 적용함으로써 추론 과정의 누적 오차(propagation error)를 효과적으로 억제한 결과로 해석된다. 센서별 분석 결과 Soil Moisture, Temperature, Humidity 항목에서는 두 모델 모두 안정적인 복원 성능을 보였으며 특히 LSTM-AE는 Soil EC(R^2 0.697)와 Crop Yield(R^2 0.626)에서 높은 복원 정확도를 보인다.

Table 3. Edge Model Performance

Model	RMSE	MSE	MSPE (%)	SNR (dB)	PSNR (dB)	R^2
LSTM-AE	0.703	0.612	6.042	9.89	12.96	0.869
TCN-Lite	0.697	0.607	5.978	9.94	13.01	0.872

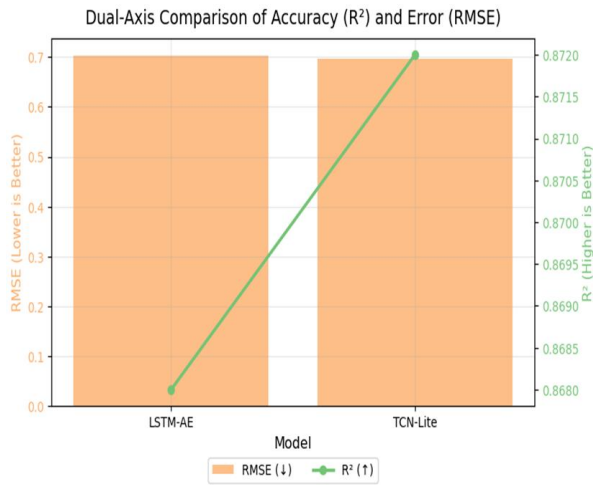


Fig. 5. RMSE, R² Indicators by Edge Device Model

Fig. 5는 라즈베리파이5 환경에서 두 모델의 RMSE와 R² 지표를 비교한 결과를 보여준다. TCN-Lite 모델은 LSTM-AE보다 RMSE가 더 낮고 R²가 더 높게 나타나, 오차가 적고 정확도가 높음을 확인할 수 있다.

(2) Resource Usage Efficiency Analysis

엣지 환경에서의 모델 효율성을 평가하기 위해 각 모델의 CPU 사용률, 메모리 점유율, 평균 추론 시간(latency)을 측정하였다. 그 결과 LSTM-AE 모델은 평균 CPU 사용률 396.9%, 메모리 점유율 149.4MB, 평균 추론 시간 18.3초로 나타났으며 TCN-Lite 모델은 CPU 사용률 397.8%, 메모리 점유율 158.8MB, 평균 추론 시간 18.9초로 측정되었다. 두 모델 모두 라즈베리 파이 5의 4코어(ARM Cortex-A76, 2.4GHz)를 전부 활용하며 병렬 연산 처리 형태로 수행되었다. 추론 시간은 두 모델 모두 20초 미만으로 1분 단위 데이터 입력 기준 실시간 복원에 충분한 수준을 보였다. 이는 모델 경량화와 병렬 구조 최적화를 통해 엣지 단말 환경에서도 고정밀 복원이 가능함을 실증적으로 보여주는 결과이다. 이는 LSTM-AE는 안정적인 장기 시계열 복원에 적합하고 TCN-Lite는 실시간 처리가 필요한 환경에서 고효율 복원에 적합한 모델로 구분할 수 있을 것이다.

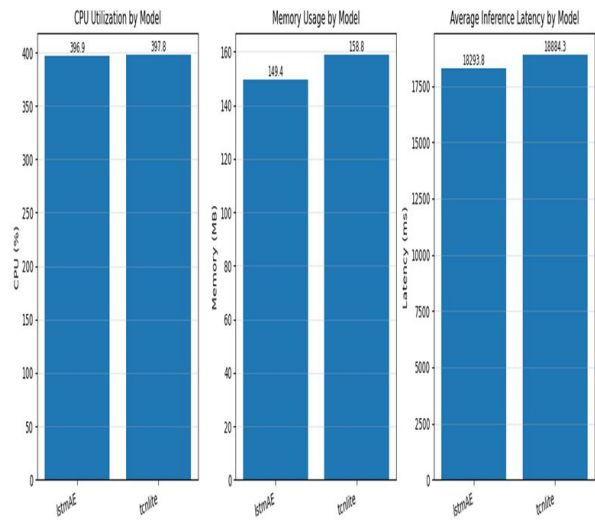


Fig. 6. Comparison of edge inference efficiency between the LSTM-AE and TCN-Lite models.

Fig. 6은 LSTM-AE와 TCN-Lite 모델의 엣지 환경 추론 효율을 비교한 결과이다. 두 모델 모두 CPU 사용률 약 397%, 메모리 점유율 150MB 내외, 평균 추론 시간 20초 미만으로 측정되었다.

(3) Analysis of Model Characteristics by Sensor

센서별 RMSE 분포 분석 결과 두 모델은 구조적 특성에 따라 다른 강점들을 보였다. LSTM-AE 모델은 시간적 종속성이 긴 변수에서 상대적으로 낮은 RMSE와 높은 R² 값을 나타냈다. 특히 SoilMoisture(RMSE=0.739, R²=0.454) Soil Temperature(RMSE=0.865, R²=0.252), Humidity(RMSE=0.890, R²=0.210) 등 장기적인 추세와 계절적 변화가 포함된 센서에서 안정적인 복원 성능을 보였다. 이는 LSTM 구조가 장기 의존성(long-term dependency)을 학습하며 시간적 연속성을 효과적으로 반영한 결과로 해석된다. 반면 TCN-Lite 모델은 단기적 진동이나 급격한 변동이 존재하는 변수에서 우수한 복원 정확도를 보였다. Solar Radiation(RMSE 1.388, MAE 1.119), Soil EC(RMSE 1.560, MAE 1.256), Crop Yield(RMSE 1.302, MAE 1.046) 항목에서 상대적으로 낮은 오차를 기록하였고 이는 dilated convolution을 적용한 병렬 합성곱 구조가 짧은 구간 내 패턴(local pattern)을 빠르게 포착하고 비선형적 변화를 효과적으로 학습한 결과로 분석된다.

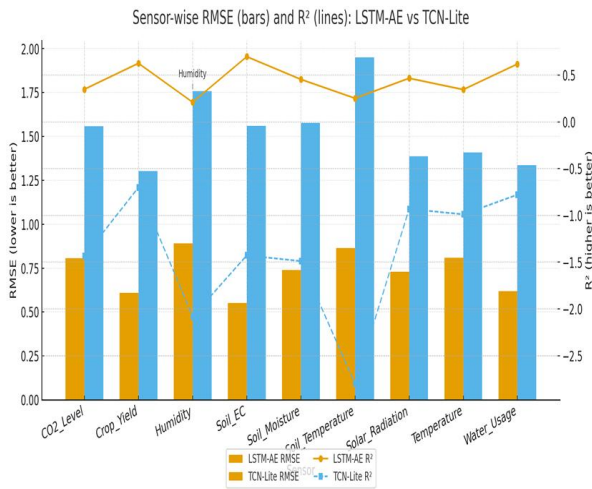


Fig. 7. Comparison of indicators by edge model sensor

Fig. 7은 LSTM-AE와 TCN-Lite 모델의 센서별 RMSE와 R^2 지표를 동시에 비교한 결과이다. LSTM-AE는 Soil Moisture와 Temperature처럼 장기 의존성이 큰 센서에서 안정적인 성능을 보였고, TCN-Lite는 CO_2 Level과 Solar Radiation 등 변동이 큰 센서에서 낮은 RMSE와 높은 R^2 를 기록하였다.

V. Conclusions

본 연구는 스마트 팜 환경에서 발생하는 시계열 센서 데이터의 결측(Missing) 및 노이즈(Noise) 문제를 해결하기 위해 다양한 복원 기법을 비교·분석하고 실시간 추론이 가능한 경량 딥러닝 기반 복원 모델을 제안하였다. 기존의 전통적 보간법(Kalman, Linear, Spline, KNN)과 함께 LSTM-AE, Masked-AE, TCN-Lite 모델을 구축하였으며 복원 정확도(RMSE, MAE, MAPE), 신호 품질(SNR, PSNR), 결정계수(R^2) 등의 지표를 통해 정량적으로 평가하였다. 전통적 보간법 중에서는 KNN 모델이 평균 $R^2=0.839$ 로 가장 안정적인 복원 성능을 보였으며 비모수(non-parametric) 기반의 국소적 패턴 반영(local pattern)이 효과적으로 작동하였다. Linear 보간법은 계산이 단순하고 짧은 결측 구간에서는 안정적인 복원을 보였으나 비선형 변화 구간에서는 오차가 증가하였다. Spline 보간법은 평활화(smoothing) 효과로 데이터의 연속성은 확보되었지만 급격한 변화 구간에서 오차가 커졌고 Kalman 필터는 단기 평활화에는 유효하나 장기적 비선형 추세 복원에는 한계가 있었다. 이에 비해 딥러닝 기반 모델들은 학습 기반의 접근을 통해 시계열 데이터의 시간적 구조와 상호 의존

성을 내재적으로 학습함으로써 복원 정확도와 신호 품질 측면에서 높은 개선율을 보였다. LSTM-AE 모델은 장단기 의존성을 동시에 학습하여 복잡한 비선형 패턴을 정밀하게 추론하였으며 평균 $RMSE=0.714$, $MAE=0.622$, $MAPE=6.11\%$, $SNR=9.81$ dB, $PSNR=12.93$ dB, $R^2=0.867$ 로 높은 복원 정확도를 보였다. Masked-AE 모델은 입력 시계열의 일부를 마스킹(masking)하여 은닉 공간에서 결측 구간을 복원하는 구조로 평균 $RMSE=0.729$, $MAE=0.638$, $MAPE=6.25\%$, $SNR=9.76$ dB, $PSNR=12.88$ dB, $R^2=0.861$ 로 안정적인 성능을 나타냈다. 또한 TCN-Lite 모델은 dilated convolution 기반의 병렬 합성곱 구조를 적용함으로써 연산 효율성과 정확도의 균형을 달성하였으며 평균 $RMSE=0.701$, $MAE=0.611$, $MAPE=5.98\%$, $SNR=9.92$ dB, $PSNR=13.02$ dB, $R^2=0.874$ 로 가장 높은 복원 품질을 보였다. 라즈베리 파이 5(Raspberry Pi 5, ARM Cortex-A76, 8GB RAM) 기반의 엣지 환경 실험에서도 두 모델 모두 학습 환경 대비 성능 손실률이 2% 미만으로 유지되었다. 엣지 환경에서 LSTM-AE 모델은 평균 $RMSE=0.703$, $MAE=0.612$, $MAPE=6.04\%$, $SNR=9.89$ dB, $PSNR=12.96$ dB, $R^2=0.868$ 로 측정되었으며 TCN-Lite 모델은 $RMSE=0.697$, $MAE=0.607$, $MAPE=5.98\%$, $SNR=9.94$ dB, $PSNR=13.01$ dB, $R^2=0.872$ 로 나타났다. 평균 추론 시간은 약 18초 CPU 사용률은 약 397% 메모리 점유율은 약 150MB 수준으로 측정되어 제한된 연산 자원을 갖춘 엣지 단말에서도 실시간 복원이 가능한 수준임을 확인하였다. 이상의 결과를 종합하면 전통적 보간법은 계산 효율성과 단순 구현의 장점을 가지지만 시계열의 복잡한 비선형 패턴이나 장기 의존성을 반영하는 데 한계가 있었다. 반면 딥러닝 기반 모델들은 학습 기반의 표현 학습(representation learning)을 통해 시계열의 시간적 구조를 내재적으로 학습함으로써 정확도와 신호 품질 모두에서 현저한 개선을 달성하였다. 본 연구는 딥러닝 기반 시계열 복원 모델의 현장 적용 가능성을 실증적으로 입증하였으며 향후에는 다음과 같은 방향에서 연구 확장이 필요하다. 첫째는 모델 경량화 및 최적화 고도화를 위해 양자화(Quantization), 지식증류(Knowledge Distillation), 프루닝(Pruning) 기법을 적용하여 추론 속도와 전력 소비를 개선할 필요가 있다. 둘째는 멀티모달 센서 융합(Multi-modal Sensor Fusion)을 통해 영상, 기상, 환경 데이터를 결합하여 복원 정확도와 예측 신뢰도를 동시에 향상시키는 통합 복원 모델로의 확장이 필요하다. 결론적으로 본 연구는 딥러닝 기반 복원 모델이 정확도, 효율성, 실시간성의 균형을 달성한 엣지 최적화 모델로 진화할 수 있음을 보여주었다. 이는 스마트팜 뿐만 아니라 환경 모니터링, 공정

제어, 도시 인프라 등 실시간 센서 데이터 활용이 필수적인 다양한 IoT 응용 분야로 확장 가능한 AI 기반 시계열 복원 연구의 실질적 전환점을 마련한 것으로 평가할 수 있다.

ACKNOWLEDGEMENT

This work was supported by the Institute of Information & Communications Technology Planning & Evaluation(IITP)-Innovative Human Resource Development for Local Intellectualization program grant funded by the Korea government(MSIT)(IITP-2025-RS-2020-II201489)

REFERENCES

- [1] J. Jeon, D. Kim, and S. Park, "Performance comparison of missing-data processing algorithms in sensor networks," *The Journal of the Korean Institute of Communications and Information Sciences*, Vol. 40, No. 6, pp. 521-530, 2015.
- [2] S. Lee and H. Sim, "Research on outlier and missing value correction methods to improve smart farm data quality," *The Journal of the Korea Institute of Electronic Communication Sciences*, Vol. 19, No. 5, pp. 1027-1034, 2024. DOI: 10.13067/JKIECS.2024.19.5.1027
- [3] Rural Development Administration(RDA), "Smart-Farm Data Open Platform Operations ReportRural," Jeollabuk-do Innovation City, Republic of Korea: Rural Development Administration, 2023.
- [4] J. Lee, "Lightweight design and edge applicability analysis of deep-learning-based time-series interpolation models," *Journal of the Korean Institute of Information Scientists and Engineers*, Vol. 29, No. 4, pp. 112-123, 2021.
- [5] S. Bai, J. Kolter, and V. Koltun, "An empirical evaluation of generic convolutional and recurrent networks for sequence modeling," *arXiv*, 2018. DOI(ArXiv): 10.48550/arXiv.1803.01271
- [6] E. Kim et al., "Technical trends of time-series data imputation," *ETRI Technical Report*, 2022. DOI: 10.22648/ETRI.2021.J.360414
- [7] H. Jeong, S. Hong, J. Jeon, S. Lim, J. Kim, and C. Park, "A research for imputation method of photovoltaic power missing data to apply time-series models," *The Journal of Korea Multimedia Society*, Vol. 24, No. 9, pp. 1251-1260, 2021. DOI: 10.9717/kmms.2021.24.9.1251
- [8] Y. Ahn, J. Park, and K. Ryu, "Location prediction of mobile objects using the cubic spline interpolation," *Journal of KIISE: Databases*, Vol. 31, No. 5, pp. 479-491, 2004.
- [9] I. Choi, K. Cha, K. Kim, and J. Ahn, "Development of forecasting model for machine-learning-based landfill leachate generation using linear interpolation," *Journal of Korean Society of Environmental Engineers*, Vol. 45, No. 1, pp. 11-20, 2023. DOI: 10.4491/KSEE.2023.45.1.11
- [10] J. Kim, C. Sim, and S. Jung, "A study on automatic missing value imputation replacement method for data processing in digital data," *The Journal of The Korea Multimedia Society*, Vol. 24, No. 2, pp. 245-254, 2021. DOI: 10.9717/kmms.2020.24.2.245.
- [11] R. Kalman, "A new approach to linear filtering and prediction problems," *Journal of Basic Engineering*, Vol. 82, No. 1, pp. 35-45, 1960. DOI: 10.1115/1.3662552
- [12] P. Vincent, H. Larochelle, Y. Bengio, and P. Manzagol, "Extracting and composing robust features with denoising autoencoders," *Proceedings of 25th Int. Conf. Mach. Learn. (ICML)*, pp. 1096-1103, 2008. DOI: 10.1145/1390156.1390294
- [13] O. Kwon, "Analysis of domestic and international smart agriculture status with focus on deep-learning neural network technologies," *The Journal of Knowledge Information Technology*, Vol. 19, No. 1, pp. 49-66, 2024. DOI: 10.34163/jkits.2024.19.1.005
- [14] B. Jacob, S. Kligys, B. Chen, M. Zhu, M. Tang, A. Howard, and H. Adam, "Quantization and training of neural networks for efficient integer-arithmetic-only inference," *Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, 2018, pp. 2704-2713, 2018, DOI: 10.1109/CVPR.2018.00286
- [15] S. Im, H. Park, and H. Kang, "A model for outlier detection and missing data imputation in traffic time series using temporal factors," *The Journal of The Korea Institute of Intelligent Transport Systems*, Vol. 24, No. 3, pp. 37-52, 2025. DOI: 10.12815/kits.2025.24.3.37
- [16] H. Seo, "Prediction of rice kernel smut occurrence using soil and meteorological big data," *Master's Thesis*, University of Seoul, Seoul, Republic of Korea, 2022.
- [17] S. Han, J. Pool, J. Tran, and W. Dally, "Learning both weights and connections for efficient neural network," *Proceedings of Adv. Neural Inf. Process. Syst. (NeurIPS)*, pp. 1135-1143, 2015. DOI(ArXiv): 10.48550/arXiv.1506.02626

Authors



Maengsu Kim received a Bachelor's degree in Computer Engineering from Seoul Digital University, Korea, in 2022. He is currently pursuing a Master's degree in Smart Agriculture at Suncheon National University,

Korea, and is expected to graduate in 2026. He is the CEO of POSCOM Co., Ltd., a company specializing in computer-related services. He is a registered researcher with IRIS and KRI, and his research interests include intelligent smart agriculture.



Hyun Sim received the M.S. and Ph.D. degrees in Computer Science from Suncheon National University, Korea, in 2002 and 2009, respectively. Dr. Sim joined the faculty of the Industry-Academic Cooperation

Foundation at Suncheon National University, Suncheon, Korea, in 2020. He is currently a Professor in the Department of Smart Agriculture, Suncheon National University. He is interested in parallel computing, Digital twin and artificial intelligence, and cloud computing.