JKSCI

한국컴퓨터정보학회논문지
Journal of The Korea Society of Computer and Information
Vol. 31 No. 11, pp. 417-425, November 2026
https://doi.org/10.9708/jksci.2026.31.11.417

Domain-Aware Predictive Maintenance for Smart-Farm Facilities An Edge-Cloud LSTM Framework with AR-Assisted Maintenance Decision Support

Bok-Eun Lee*

*Master's Course, Dept. of Smart Convergence (Major in Smart Agriculture), Sunchon National University, Jeonnam-Gwangju Special Metropolitan City, Korea

[Abstract]

Smart-farm production depends on tightly coupled pumps, ventilation fans, climate-control units, valves, and sensor networks; therefore, an isolated equipment failure can propagate rapidly into environmental instability and crop loss. This study develops a domain-aware predictive-maintenance architecture that integrates multivariate remaining-useful-life (RUL) estimation, edge-cloud model operations, and augmented-reality (AR) maintenance support. The predictive module uses a stacked long short-term memory network with piecewise-linear RUL labeling and leakage-controlled scaling. The action module converts RUL estimates into risk states and presents asset identity, degradation trends, uncertainty, and task instructions through an AR interface. The original manuscript reports an RMSE of 12.85 and a PHM asymmetric score of 289.41 on NASA C-MAPSS FD001. Rather than treating this benchmark as direct proof of smart-farm field effectiveness, the revised study interprets it as source-domain evidence for temporal prognostics and explicitly separates algorithmic validity from agricultural-domain validity. A staged validation protocol is proposed, comprising benchmark replication, cross-condition robustness testing, transfer learning with smart-farm sensor data, and prospective field evaluation of maintenance outcomes. The contribution is thus a technically reproducible and epistemically bounded framework that connects prediction, visualization, and intervention while making its domain-transfer assumptions testable.

▸ **Key words**: predictive maintenance, remaining useful life, smart farm, LSTM, augmented reality, edge-cloud computing, domain adaptation

• First Author: Bok-Eun Lee, Corresponding Author: Bok-Eun Lee
*Bok-Eun Lee (tommy@sccreative.kr), Dept. of Smart Convergence (Major in Smart Agriculture), Sunchon National University
• Received: 2026. 09. 22, Revised: 2026. 10. 06, Accepted: 2026. 10. 20.

Copyright © 2026 The Korea Society of Computer and Information
http://www.ksci.re.kr pISSN:1598-849X | eISSN:2383-9945
www.kci.go.kr

[요 약]

스마트팜 생산시스템은 양액 공급 펌프, 환기팬, 냉·난방기, 전자밸브 및 센서 네트워크가 상호 의존적으로 작동하므로 단일 설비의 고장이 환경 제어 실패와 작물 손실로 확산될 수 있다. 본 연구는 다변량 시계열 기반 잔존수명(RUL) 예측, 엣지–클라우드 모델 운영, 증강현실(AR) 유지보수 지원을 결합한 도메인 인지형 예지보전 프레임워크를 제안한다. 예측 모듈은 구간 선형 RUL 레이블과 데이터 누설을 통제한 정규화를 적용한 적층 LSTM으로 구성하고, 조치 모듈은 RUL 추정치를 위험상태로 변환하여 설비 식별정보, 열화 추세, 불확실성 및 작업 절차를 AR 인터페이스에 제공한다. 원문은 NASA C-MAPSS FD001에서 RMSE 12.85와 PHM 비대칭 점수 289.41을 보고한다. 그러나 본 개정 연구는 해당 결과를 스마트팜 현장 성능의 직접 증거로 과잉 해석하지 않고, 시계열 예후 예측에 관한 원천 도메인 근거로 한정한다. 또한 벤치마크 재현, 운용조건 강건성, 스마트팜 센서데이터를 활용한 전이학습, 실제 유지보수 성과에 대한 전향적 검증으로 이어지는 단계형 실증 프로토콜을 제시한다. 이를 통해 예측–시각화–조치의 폐루프를 구축하는 동시에 도메인 전이 가정을 검증 가능한 연구가설로 전환하였다.

▸ **주제어**: 스마트팜, 예지보전, 잔존수명, LSTM, 증강현실, 엣지-클라우드, 도메인 적응

I. Introduction

1. Research Background and Problem Definition

스마트농업은 센싱, 연결, 분석 및 자동제어를 결합하여 제한된 자원으로 생산성과 품질을 높이는 사이버-물리 생산체계이다. 그러나 생육환경의 정밀 제어가 고도화될수록 물리설비의 가용성에 대한 의존도도 함께 증가한다. 특히 양액 공급 펌프, 공조기, 환기팬 및 전자밸브는 수분, 염류, 분진, 반복 기동 및 전원 변동에 노출되며, 열화가 임계점을 넘으면 온도·습도·EC·pH·유량의 제어오차가 연쇄적으로 확대될 수 있다 [1], [2]. 따라서 스마트팜의 설비관리 문제는 단순한 장비 보전이 아니라 작물 생육 안정성과 경영위험을 동시에 다루는 운영 의사결정 문제로 정의되어야 한다.

사후보전은 고장 발생 이후에 개입하므로 생육환경 이탈로 이미 발생한 손실을 회복하기 어렵고, 주기기반 예방보전은 실제 건강상태와 무관한 조기교체를 유발할 수 있다. 예지보전은 상태감시 데이터에서 열화징후를 추출하고 잔존수명을 추정하여 고장위험과 정비비용 사이의 의사결정을 지원한다 [3], [4]. 다만 높은 예측 정확도만으로 현장 효과가 자동 보장되지는 않는다. 모델이 제시한 수치가 어느 설비의 어떤 고장모드를 의미하는지, 불확실성이 어느 정도인지, 작업자가 언제 어떤 조치를 수행해야 하는지가 연결되어야 한다.

원문은 LSTM 기반 RUL 추정과 AR 유지보수 인터페이스를 결합했다는 점에서 중요한 통합 관점을 제시했으나, 세 가지 학술적 공백이 남아 있었다. 첫째, 항공기 터보팬 데이터에서 얻은 성능을 스마트팜 펌프와 팬에 일반화하는 도메인 전이 가정이 충분히 검토되지 않았다. 둘째, 데이터 분할·정규화·하이퍼파라미터·난수시드 등 재현성 정보가 미흡하여 보고된 수치를 독립적으로 검증하기 어려웠다. 셋째, AR 화면이 예측값을 어떻게 위험등급과 정비행동으로 변환하는지에 관한 의사결정 규칙 및 사용자 검증 설계가 부재하였다. 본 개정 연구는 이 세 공백을 연구문제와 단계형 검증체계로 전환한다.

2. Research Objectives, Research Questions, and Contributions

본 연구의 목적은 시계열 예후모델의 성능, 스마트팜 도메인으로의 전이가능성, 현장 작업자의 조치가능성을 하나의 검증 가능한 구조로 통합하는 데 있다. 이를 위해 다음 연구질문을 설정한다.

RQ1. 구간 선형 RUL 레이블과 적층 LSTM은 FD001 단일 운용조건에서 경쟁력 있는 예후 정확도를 제공하는가?

RQ2. 터보팬 데이터에서 학습된 시간적 표현 중 어떤 요소가 스마트팜 회전설비의 열화진단에 전이될 수 있으며, 어떤 요소는 현장데이터로 재학습되어야 하는가?

RQ3. RUL, 예측오차 및 데이터 품질정보를 결합한 위

www.kci.go.kr

험정책이 AR 인터페이스에서 작업자의 판단과 정비행동으로 변환될 수 있는가?

RQ4. 예측 오차 및 데이터 품질 정보를 결합하여 현장 작업자의 유지보수 판단을 돕는 의사결정 프레임워크의 개념적 구조는 어떠해야 하는가?

학술적 기여는 다음과 같다. 첫째, 스마트팜 환경을 위한 엣지-클라우드 기반 예지보전 시스템의 개념적 아키텍처를 제안하였다. 둘째, C-MAPSS 데이터의 특성을 고려하여 모델의 불확실성을 AR 작업지시로 전환하는 위험기반 의사결정 계층을 설계하였다. 셋째, 향후 물리적 전이 검증을 위한 기반으로서 스마트팜 설비별 센서-고장모드-조치의 개념적 대응관계를 도출하였다.

II. Theoretical Background and Related Work

1. Degradation and Condition Monitoring of Smart Farm Facilities

스마트팜 설비의 고장은 기계적, 전기적, 유체역학적, 화학적 원인이 중첩되는 다중모드 현상이다. 펌프에서는 베어링 마모, 캐비테이션, 임펠러 부식, 씰 열화 및 관로 막힘이 전류 · 진동 · 압력 · 유량에 서로 다른 패턴을 남긴다. 환기팬에서는 불평형과 축정렬 불량이 회전속도 변동 및 진동 고조파로 나타나며, EC/pH 센서에서는 오염과 전 극열화가 드리프트와 응답지연으로 관측된다. 따라서 단 일 임계값 경보보다 다변량 시계열의 공동변화를 분석하 는 접근이 적합하다. 다만 동일한 관측패턴이 복수 고장 원에서 발생할 수 있으므로 RUL 예측과 고장유형 진단 을 구분하고, 향후 다중과업학습으로 결합할 필요가 있다. 기존 스마트팜 및 농기계 예지보전 문헌[17]-[19]은 개별 설비의 알고리즘에 집중한 반면, 본 프레임워크는 원천 도메인과 목표 도메인(스마트팜) 간의 센서 구성 및 고장 정의의 차이를 극복하기 위한 엣지-클라우드 연계 구조를 제안한다는 점에서 차별성을 갖는다.

Table 1. Smart-farm assets, degradation modes, prognostic indicators, and actions

Asset	Key Sensors	Major Degradation Modes	Prognostic Indicators	Recommended Actions
Nutrient Solution Pump	Current, Vibration, Pressure, Flow rate	Bearing/Seal wear, Cavitation, Impeller corrosion	RUL, Vibration RMS, Pressure-flow efficiency	Inspection →Lubrication/Seal replacement→Pump replacement
Ventilation Fan	Current, RPM, Vibration, Temperature	Imbalance, Misalignment, Motor winding degradation	Speed fluctuation, Harmonics, Temperature rise rate	Cleaning/ Alignment → Bearing/ Motor maintenance
HVAC System	Power, Intake/Exhaust temp., Operating hours	Refrigerant leak, Compressor degradation, Frequent starts	COP proxy indicator, Starting frequency	Leak inspection → Compressor/Controller inspection
Solenoid Valve	Actuation current, Opening/ Closing time, Pressure	Solenoid degradation, Sticking, Leakage	Response delay, Pressure reduction after closing	Cleaning → Seal/Solenoid replacement
EC/pH Sensor	EC, pH, Temperature, Response time	Electrode contamination, Calibration drift, Aging	Drift, Response time constant	Cleaning/ Calibration →Electrode replacement

2. RUL Prediction and LSTM

RUL은 현재 시점에서 기능상실 기준에 도달할 때까지 남은 운용시간 또는 사이클 수로 정의된다. 전통적 통계모형은 해석가능성이 높지만 복잡한 비선형 열화와 장기 의존성을 표현하는 데 제약이 있고, 트리 기반 모델은 특징공학을 통해 강건한 기준선을 제공하지만 원시 시계열의 순서정보를 직접 모델링하지 않는다. LSTM은 입력게이트, 망각게이트 및 출력게이트를 통해 장기 의존성을 학습할 수 있어 다변량 설비데이터의 대표적 예후모델로 활용되어 왔다 [8], [9]. 그러나 최신 연구는 특정 아키텍처 자체보다 데이터 분할, 레이블 정의, 운용조건 변화, 불확실성 및 도메인 이동이 성능에 더 큰 영향을 줄 수 있음을 강조한다 [4], [5].

$$f_t = \mathrm{sigma}(W_f\,[h_{(t-1)}, x_t] + b_f) \quad (1)$$

$$i_t = \mathrm{sigma}(W_i\,[h_{(t-1)}, x_t] + b_i), \quad c_t = f_t * c_{(t-1)} + i_t * \tanh(W_c\,[h_{(t-1)}, x_t] + b_c) \quad (2)$$

$$o_t = \mathrm{sigma}(W_o\,[h_{(t-1)}, x_t] + b_o), \quad h_t = o_t * \tanh(c_t) \quad (3)$$

www.kci.go.kr

여기서 x_t는 t 시점의 센서벡터, h_t와 c_t는 은닉상태와 셀상태이다. 본 연구에서 LSTM을 선택한 이유는 '가장 우수한 모델'이라는 선험적 단정이 아니라, 원문 결과와의 연속성, 엣지 추론 가능성, 장기 의존성 모델링 및 비교 가능한 선행연구의 축적 때문이다. 후속 연구에서는 TCN, Transformer 및 확률적 생존모형을 동일 분할에서 비교해야 한다.

3. AR-Based Maintenance and Human-AI Collaboration

AR 유지보수는 설비 위에 부품 식별, 경고, 절차 및 원격지원 정보를 중첩하여 탐색시간과 작업오류를 줄이는 기술이다. 산업 유지보수 연구는 AR의 잠재적 이점을 보고했지만, 등록오차, 화면과부하, 장비 착용성, 콘텐츠 갱신비용 및 사용자 신뢰가 성과를 좌우한다 [13]-[16]. 따라서 AR은 단순한 시각화 장치가 아니라 예측정보를 작업 가능한 형태로 변환하는 의사결정 인터페이스로 설계되어야 한다. 특히 단일 RUL 값만 제시하면 과잉신뢰가 발생할 수 있으므로 예측구간, 데이터 신뢰도, 근거 센서, 권장 조치 및 승인주체를 함께 표시해야 한다.

4. Theoretical Issues in Domain Transfer

C-MAPSS FD001은 단일 운용조건과 단일 고장모드에서 100개 학습 엔진과 100개 시험 엔진의 run-to-failure 시계열을 제공한다 [6], [7]. 이 데이터는 다변량 열화 궤적과 RUL 평가를 위한 표준 벤치마크라는 장점이 있으나, 터보팬 압축기와 스마트팜 펌프·팬 사이에는 센서 의미, 부하범위, 샘플링 주기, 고장기준 및 환경잡음의 차이가 존재한다. 그러므로 FD001 성능은 '시간적 열화표현을 학습할 수 있음'을 지지할 뿐, '스마트팜에서 같은 정확도를 보장함'을 의미하지 않는다. 본 연구는 이를 구성개념 타당도와 외적 타당도의 문제로 분리하고, 원천모델의 일부 표현만을 전이한 뒤 현장 레이블로 재보정하는 전략을 채택한다.

III. Proposed Framework

1. Overall Architecture

제안 프레임워크는 데이터 수집, 엣지 품질관리·추론, 클라우드 학습·거버넌스, AR 의사결정·조치의 네 계층으로 구성된다. 핵심 설계원칙은 (a) 통신장애 시에도 현장 경보가 지속될 것, (b) 학습과 추론의 데이터 변환이 동일할 것, (c) 모델 버전과 정비이력이 추적될 것, (d) 자동 권고와 인간 승인경계를 명확히 할 것, (e) 현장 피드백이 다음 학습주기에 반영될 것이다.

Table 2. Four-layer edge-cloud-AR architecture

Layer	Core Function	Input	Output / Control
L1. Physical Collection	Sensor synchronization, Asset identification, Unit standardization	Current, Vibration, Pressure, Flow rate, Temperature	Time-aligned stream, Quality flags
L2. Edge Inference	Missing/Outlier handling, Normalization, RUL inference	Recent time-series window	RUL, Prediction interval, Latency
L3. Cloud MLOps	Training/Validation, Drift monitoring, Version approval	Long-term history, Maintenance labels	Approved model, Model card, Rollback point
L4. AR Action	Risk level, Root-cause rationale	RUL, Quality, Asset BOM	Inspection/Maintenance order, Work procedure, Feedback

2. Data Preprocessing and Data Leakage Prevention

FD001의 unit number는 집단 식별자, time cycles는 시간축, 세 개 setting 변수는 운용조건, s_1-s_21은 센서 채널이다. 원문은 변화량이 거의 없는 s_1, s_5, s_6, s_10, s_16, s_18, s_19를 제외하고 14개 센서를 사용하였다. 이 선택은 학습 데이터에서만 수행되어야 하며 시험 데이터의 분산이나 목표값을 참고하면 특징선택 누설이 발생한다. 정규화 파라미터도 학습집단에서 적합한 뒤 검증·시험집단에 고정 적용해야 한다. 설비 단위 분할을 사용하여 동일 엔진의 서로 다른 시점이 학습과 검증에 동시에 포함되는 것을 방지한다.

$$x'_j = (x_j - \min_train(x_j)) / (\max_train(x_j) - \min_train(x_j)) \quad (4)$$

구간 선형 레이블은 초기 건전구간에서 RUL을 상한 R_max로 제한하고 열화가 진행된 뒤 선형 감소하도록 정의한다. 원문의 R_max는 125 cycles이다. 이 값은 고정된 진리라기보다 FD001에서 널리 사용되는 설계 선택이므로, 100·125·130의 민감도 분석과 검증집합 기반 선택을 권장한다.

$$RUL_t = \min(R_max, T_fail - t), \quad R_max = 125 \quad (5)$$

www.kci.go.kr

3. Prediction Model and Training Objectives

입력은 길이 w의 14차원 센서 윈도 X_t ∈ R^(w×14), 출력은 시점 t의 RUL 추정값이다. 적층 LSTM의 마지막 은닉표현을 완전연결 회귀층에 전달하고, 학습손실은 평균제곱오차를 사용한다. 다만 늦은 경보의 비용이 조기경보보다 클 수 있으므로 배포단계에서는 비대칭 PHM 점수와 위험가중 손실을 함께 관찰한다. 과적합 방지를 위해 dropout, 조기종료, 학습률 감쇠 및 설비 단위 검증분할을 사용해야 하며, 모든 설정은 논문·코드·모델카드에 동일하게 기록되어야 한다.

L_MSE(theta) = (1/N) * sum_i (y_i - f_theta(X_i))^2 (6)

4. Risk Levels and AR Decision-Making Policies

현장 의사결정은 RUL 하나가 아니라 예측구간, 데이터 품질 및 정비 리드타임을 결합한다. 자산 a의 정비 준비시간을 L_a, 안전여유를 M_a라 할 때, RUL의 하한이 L_a+M_a보다 작으면 위험상태로 전환한다. 센서 결측률, 동기화 오류 또는 분포이동이 기준을 초과하면 모델 권고를 자동 정비명령으로 승격하지 않고 '데이터 점검' 상태로 분기한다.

Risk_a = P(RUL_a <= L_a + M_a | X_a), Action if Risk_a >= tau_a (7)

Table 3. Risk-to-action policy for the AR interface

Status	Decision Criteria	AR Display	Authorization / Action
Normal	RUL lower bound > Lead time + Margin	Green, Trend, Next inspection date	Automated recording
Caution	Risk probability increase or rapid trend change	Yellow, Root-cause sensor, Inspection items	Operator confirmation
Warning	RUL lower bound ≤ Lead time + Margin	Red, Parts, Procedure, LOTO guidance	Maintenance supervisor approval
Data Untrusted	Missing / Drift / Synchronization error	Gray, Sensor inspection prioritized	Defer model recommendation

IV. Experimental Design

1. Dataset and Evaluation Scope

원천 검증은 NASA C-MAPSS FD001을 사용한다. FD001은 단일 운용조건과 단일 고장모드로 생성되어 모델 비교가 용이하지만 실제 스마트팜 환경의 부하변동과 복합고장을 포함하지 않는다. 따라서 실험범위는 1단계 원천 알고리즘 검증으로 한정한다. 2단계에서는 FD002-FD004 또는 N-CMAPSS를 활용해 운용조건 변화에 대한 강건성을 검증하고, 3단계에서는 스마트팜 펌프·팬의 상태감시 데이터를 이용한 전이학습, 4단계에서는 실제 정비의 사결정 성과를 검증한다.

Table 4. Staged validation strategy

Stage	Objective	Data	Key Metrics	Evidence Level
1. Benchmark	Time-series RUL learning feasibility	C-MAPSS FD001	RMSE, PHM Score	Source Domain
2. Robustness	Condition and failure mode changes	FD002-FD004 /N-CMAPSS	Condition-specific error, Calibration	Extended Source Domain
3. Transfer	Adaptation to smart farm assets	Pump/Fan run-to-failure / Maintenance log	Pre/Post-transfer error, Early warning lead time	Target Domain Exploratory Validation
4. Field	Operational performance and user effects	Prospective pilot / Control group	MTTR, False alarm rate, Downtime, Operator errors	Field Causal Evidence

2. Evaluation Metrics and Statistical Analysis

예지보전에서는 전체 평균 오차보다 늦은 예측(Late Prediction)의 꼬리 위험이 치명적이므로, RMSE 단일 지표의 맹점을 보완하기 위해 비대칭 손실(Asymmetric loss) 함수 또는 PHM Score와 같은 위험 가중 지표의 활용이 필수적이다. 향후 스마트팜 실증 시에는 이러한 비대칭 지표를 도입하여 현장 운영의 신뢰성을 확보해야 한다.

RMSE = sqrt((1/N) * sum_i (y_i - yhat_i)^2) (8)

Score = sum_i [exp(-d_i/13)-1 if d_i<0; exp(d_i/10)-1 if d_i>=0], d_i=yhat_i-y_i (9)

3. Reproducibility Protocol

원문에는 윈도 길이, LSTM 은닉유닛, 층수, dropout, batch size, optimizer, 학습률, epoch, 조기종료 조건, 검증분할, 난수시드 및 실행환경이 충분히 기록되어 있지 않다. 본 개정본은 이를 임의로 생성해 기존 실험설정으로 가장하지 않는다. 대신 아래 항목을 최종 제출 전 실험로그와 코드에서 확정하도록 명시한다. 이 구분은 보고값의 진실성을 보존하면서 재현 가능한 후속 검증으로 연결하

www.kci.go.kr

기 위한 것이다.

Table 5. Reproducibility information required before submission

Item	Required Reporting Content	Current Status
Splitting	Engine IDs and generation rules for train/validation/test	Needs revision
Preprocessing	Excluded sensors, scaler fit range, missing/outlier rules	Partially reported
Sequence	Window length, stride, padding, target time step	Needs revision
Model	Number of layers, hidden units, dropout, number of parameters	Needs revision
Training	Optimizer, learning rate, batch size, epoch, early stopping	Needs revision
Repetition	10 or more random seeds, mean ± standard deviation, confidence interval	Needs revision
Artifacts	Code commit, environment lockfile, model weights, predicted values	Needs revision

V. Results

1. Benchmark Prognostic Performance

원문은 FD001 시험집합에서 RMSE 12.85와 PHM Score 289.41을 보고하였다. 이 값은 LSTM과 구간 선형 레이블 조합이 표준 벤치마크에서 경쟁력 있는 수준임을 시사한다. 그러나 독립 실행로그, 반복시드 및 시험유닛별 예측값이 제공되지 않아 본 편집 과정에서 통계적 재현 여부를 확인할 수 없었다. 따라서 아래 표는 독립 재현 결과가 아니라 알고리즘의 기준 성능(Baseline)을 설명하기 위한 원문 보고값으로 한정하며, 서로 다른 전처리 및 분할 프로토콜로 인해 표에 제시된 타 모델과의 직접적인 우열 비교는 불가함을 밝힌다.

Table 6. Reported performance and comparability constraints

Model	RMSE	PHM Score	Interpretation Caveat
Proposed stacked LSTM	12.85	289.41	Originally reported value; repeated experiments and confidence interval not provided
Asif et al. (2022)	~12 level	Varies by paper setting	Identical preprocessing and splitting need to be verified
Deep CNN families	Varies by literature	Varies by literature	Direct superiority judgment prohibited prior to identical protocol re-execution

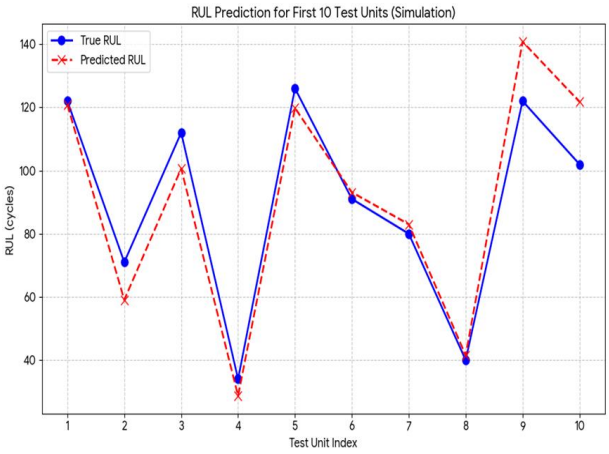


Fig. 1. Illustrative comparison of true and predicted RUL for ten test units (figure retained from the source manuscript; not a substitute for full test-set statistics)

2. Limited Interpretation of Results

RMSE 12.85는 평균적으로 약 13 cycles 규모의 오차가 존재함을 의미하지만, 설비별 오차분포와 고장 직전 구간의 편향을 알지 못하면 운영의미를 판단하기 어렵다. 예지보전에서는 전체 평균보다 늦은 예측의 꼬리위험이 중요하므로 PHM Score, 10·20·30 cycles 이내 정확도, 위험구간별 MAE, calibration curve 및 조기경보시간을 함께 제시해야 한다. 또한 제시된 10개 유닛 그림은 설명용 표본이므로 전체 100개 시험유닛의 산점도, 잔차분포 및 Bland-Altman형 분석으로 보완되어야 한다.

문헌 수치를 직접 배열하는 것만으로 모델의 우수성을 입증할 수는 없다. 센서선택, 윈도 길이, RUL 상한, 검증분할, 학습 반복 및 점수 구현이 다르면 수치의 비교가능성이 훼손된다. 본 연구는 프레임워크의 개념 설계에 집중하였으므로 모델 간 어블레이션 실험은 현재 수행되지 않았다. 따라서 Table 7의 항목들은 향후 제안 프레임워크의 유효성을 입증하기 위해 반드시 수행되어야 할 필수 실험 프로토콜(가이드라인)로써 역할을 한다.

www.kci.go.kr

3. Essential Ablation and Robustness Analysis

Table 7. Required ablation and robustness experiments

Experiment	Comparison	Validation Hypothesis	Recommended Reporting
Label	Linear vs. piecewise linear RUL	Reduction in bias during early healthy operating period	Mean ± SD, unit-level paired CI
Feature	21 sensors vs. selected 14 sensors	Effect of removing constant/invariant sensors	RMSE, inference latency, parameter count
Model	RF / TCN / LSTM / Transformer	Relative advantage of long-term dependency modeling	Identical split, identical computational budget
Window	w = 20 / 30 / 50 / 70	Sensitivity to temporal context length	Performance-latency Pareto front
Uncertainty	Point vs. ensemble / MC dropout	Calibration quality of risk policies	NLL, coverage, ECE
Domain	Source-only vs. fine-tuning	Contribution to target field domain transfer	Target domain few-shot learning curve

VI. Discussion

1. Theoretical Implications

본 연구의 핵심 함의는 예지보전을 단일 회귀문제가 아니라 증거수준이 다른 세 문제의 결합으로 재정의한 데 있다. 첫째는 시계열에서 열화표현을 학습하는 예측문제, 둘째는 원천 도메인의 표현을 목표설비에 이전하는 전이문제, 셋째는 불확실한 예측을 안전한 정비행동으로 변환하는 의사결정문제이다. 이 구분은 벤치마크 정확도가 높더라도 현장효과가 낮을 수 있는 이유를 설명하며, 반대로 예측오차가 다소 크더라도 충분한 리드타임과 적절한 위험정책을 통해 운영가치를 만들 수 있음을 보여준다.

LSTM은 입력센서의 시간적 상관을 압축하는 표현학습기로 기능하지만, 그 표현이 물리적으로 어떤 열화원인을 의미하는지는 자동으로 보장되지 않는다. 따라서 센서 중요도, counterfactual perturbation, attention/gradient attribution 및 고장모드 레이블을 통해 설명을 검증해야 한다. AR 화면에는 설명가능성 결과를 단순 순위가 아니라 '어떤 센서가 기준에서 얼마나 벗어났고 어떤 정비항목과 연결되는지'의 형태로 제공하는 것이 바람직하다.

2. Practical Implications and Human Oversight

현장 적용에서 가장 중요한 통제는 자동화 수준의 경계이다. 정상상태 기록과 점검일 추천은 자동화할 수 있으나, 생산중단·부품교체·안전잠금과 같은 고위험 조치는 책임자의 승인을 요구해야 한다. 모델 드리프트, 센서고장 및 통신장애가 감지되면 시스템은 강한 확신을 가장하지 않고 데이터 불신 상태로 전환해야 한다. 작업자는 AR 인터페이스에서 권고수용·거부·수정의 이유를 기록하고, 이 피드백은 오류분석과 모델 개선에 사용된다.

성과평가는 모델지표와 운영지표를 분리해 설계해야 한다. 모델지표에는 RMSE, PHM Score, calibration 및 지연시간이 포함되고, 운영지표에는 오경보당 비용, 경보 후 실제 결함발견률, 평균수리시간(MTTR), 평균고장간격(MTBF), 계획정비 비중, 다운타임 및 작물환경 이탈시간이 포함된다. AR의 효과는 동일 작업을 종이매뉴얼·태블릿·AR로 수행하는 무작위 또는 교차설계로 비교하고, 작업시간·오류·인지부하·신뢰를 함께 측정해야 한다.

3. Threats to Validity

Table 8. Threats to validity and mitigation

Validity Dimension	Primary Threat	Impact	Mitigation Strategy
Internal Validity	Temporal leakage, feature selection on test set	Overestimated performance	Unit-level split, train-only fitting
Construct Validity	Turbofan RUL vs. smart-farm pump RUL definition mismatch	Distorted measurement construct	Redefine failure threshold, unit, and lead time
External Validity	Single operating condition and single failure mode	Limited generalizability to real field conditions	Multi-condition datasets and prospective field validation
Statistical Conclusion	Single random seed, incomplete baseline comparisons	Spurious variance and comparative bias	Repeated runs, confidence intervals, paired hypothesis testing
Human Factors	Cognitive overload, over-trust, AR registration errors	Potential operational mistakes	Usability testing, authorization boundaries, fail-safe mechanisms

4. Limitations and Boundaries

첫째, 5장에 제시된 성능 수치는 본 연구의 독립적 재현결과가 아닌, 알고리즘의 기준 성능(Baseline)을 설명하기 위한 원문 보고값이다. 특히 R_max=125 설정은 C-MAPSS 데이터의 관행이며, 단위와 구성 개념이 다른 스마트팜 도메인으로의 직결적 전이에는 명확한 한계가

www.kci.go.kr

존재한다. 둘째, 실제 스마트팜 run-to-failure 데이터와 정비 레이블이 포함되지 않아 목표도메인의 정량 성능을 아직 주장할 수 없다. 셋째, 단일 RMSE 평가의 맹점을 보완하기 위해 늦은 예측에 대한 비대칭 손실(Asymmetric loss) 등을 추가로 고려해야 하며, AR 인터페이스 역시 사용자 실증 평가가 완료되지 않은 개념 설계 단계이다. 넷째, LSTM 과 소수 문헌모델의 비교만으로 최신 시계열모델 전체에 대한 우위를 주장할 수 없다. 이러한 한계점들은 본 연구가 제안하는 프레임워크의 물리적 실증을 위해 향후 반드시 수행되어야 할 과제이다.

VII. Conclusions

본 연구는 스마트팜 설비의 예지보전을 위한 엣지-클라우드 모델 운영 및 AR 유지보수 지원의 통합 아키텍처(개념적 프레임워크)를 제안하였다. 기존 문헌이 보고한 성능을 보존하되, 이를 스마트팜 현장효과의 직접증거로 확대해석하지 않고 원천 도메인 알고리즘 근거로 재해석하였다.

후속 연구는 세 방향으로 진행되어야 한다. 첫째, 코드·분할·하이퍼파라미터와 시험유닛별 예측값을 공개하여 FD001 결과를 재현한다. 둘째, 스마트팜 펌프와 팬에서 장기 상태감시·정비이력을 수집하고, 원천모델과 전이학습 모델을 비교하여 도메인 이동의 크기를 정량화한다. 셋째, AR 인터페이스의 정비시간, 오류, 신뢰 및 인지부하를 대조실험으로 평가한다. 이 절차가 완료될 때 제안 프레임워크는 '가능성 있는 통합구조'에서 '현장근거를 갖춘 예지보전 시스템'으로 전환될 수 있다.

Data, Code, and Reproducibility Statement

C-MAPSS 데이터는 NASA Prognostics Center of Excellence Repository에서 제공된다 [7]. 본 개정본 작성 시 원문 HWP에 포함된 보고값과 그림을 보존하였으나, 원 실험 코드·모델가중치·분할목록·예측 원시값은 제공되지 않았다. 따라서 성능 수치는 independent replication이 아니라 source-reported results로 표기하였다. 최종 투고 전 Appendix A의 항목을 충족하고, 코드 저장소의 고정 버전과 실행 환경을 명시해야 한다.

ACKNOWLEDGEMENT

This work was supported by Innovative Human Resource Development for Local Intellectualization program through the Institute of Information & Communications Technology Planning & Evaluation(IITP) grant funded by the Korea government(MSIT)(IITP-2026-2020-0-01489).

REFERENCES

[1] S. Wolfert, L. Ge, C. Verdouw, and M.-J. Bogaardt, "Big Data in Smart Farming - A review," Agricultural Systems, Vol. 153, pp. 69-80, 2017. DOI: 10.1016/j.agsy.2017.01.023.

[2] M. Ayaz, M. Ammad-Uddin, Z. Sharif, A. Mansour, and E.-H. M. Aggoune, "Internet-of-Things (IoT)-Based Smart Agriculture: Toward Making the Fields Talk," IEEE Access, Vol. 7, pp. 129551-129583, 2019. DOI: 10.1109/ACCESS.2019.2932609.

[3] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. P. Francisco, J. P. Basto, and S. G. S. Alcalá, "A systematic literature review of machine learning methods applied to predictive maintenance," Computers & Industrial Engineering, Vol. 137, Art. 106024, 2019. DOI: 10.1016/j.cie.2019.106024.

[4] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, and J. Lin, "Machinery health prognostics: A systematic review from data acquisition to RUL prediction," Mechanical Systems and Signal Processing, Vol. 104, pp. 799-834, 2018. DOI: 10.1016/j.ymssp.2017.11.016.

[5] O. Fink, Q. Wang, M. Svensén, P. Dersin, W.-J. Lee, and M. Ducoffe, "Potential, challenges and future directions for deep learning in prognostics and health management applications," Engineering Applications of Artificial Intelligence, Vol. 92, Art. 103678, 2020. DOI: 10.1016/j.engappai.2020.103678.

[6] A. Saxena, K. Goebel, D. Simon, and N. Eklund, "Damage propagation modeling for aircraft engine run-to-failure simulation," Proceedings of the 2008 International Conference on Prognostics and Health Management, Denver, USA, pp. 1-9, 2008. DOI: 10.1109/PHM.2008.4711414.

[7] A. Saxena and K. Goebel, "Turbofan Engine Degradation Simulation Data Set," NASA Prognostics Data Repository, NASA Ames Research Center, 2008. https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/.

[8] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Computation, Vol. 9, No. 8, pp. 1735-1780, 1997. DOI: 10.1162/neco.1997.9.8.1735.

[9] S. Zheng, K. Ristovski, A. Farahat, and C. Gupta, "Long Short-Term Memory Network for Remaining Useful Life

www.kci.go.kr

Estimation," Proceedings of the 2017 IEEE International Conference on Prognostics and Health Management, Dallas, USA, pp. 88-95, 2017. DOI: 10.1109/ICPHM.2017.7998311.

[10] X. Li, Q. Ding, and J.-Q. Sun, "Remaining useful life estimation in prognostics using deep convolution neural networks," Reliability Engineering & System Safety, Vol. 172, pp. 1-11, 2018. DOI: 10.1016/j.ress.2017.11.021.

[11] O. Asif, S. A. Haider, S. R. Naqvi, J. F. W. Zaki, K.-S. Kwak, and S. M. R. Islam, "A Deep Learning Model for Remaining Useful Life Prediction of Aircraft Turbofan Engine on C-MAPSS Dataset," IEEE Access, Vol. 10, pp. 95425-95440, 2022. DOI: 10.1109/ACCESS.2022.3203406.

[12] Y. Alomari, M. Andó, and M. L. Baptista, "Advancing aircraft engine RUL predictions: an interpretable integrated approach of feature engineering and aggregated feature importance," Scientific Reports, Vol. 13, Art. 13466, 2023. DOI: 10.1038/s41598-023-40315-1.

[13] R. Palmarini, J. A. Erkoyuncu, R. Roy, and H. Torabmostaedi, "A systematic review of augmented reality applications in maintenance," Robotics and Computer-Integrated Manufacturing, Vol. 49, pp. 215-228, 2018. DOI: 10.1016/j.rcim.2017.06.002.

[14] I. Fernández del Amo, J. A. Erkoyuncu, R. Roy, R. Palmarini, and D. Onoufriou, "A systematic review of augmented reality content-related techniques for knowledge transfer in maintenance applications," Computers in Industry, Vol. 103, pp. 47-71, 2018. DOI: 10.1016/j.compind.2018.08.007.

[15] T. Masood and J. Egger, "Augmented reality in support of Industry 4.0 - Implementation challenges and success factors," Robotics and Computer-Integrated Manufacturing, Vol. 58, pp. 181-195, 2019. DOI: 10.1016/j.rcim.2019.02.003.

[16] J. Egger and T. Masood, "Augmented reality in support of intelligent manufacturing - A systematic literature review," Computers & Industrial Engineering, Vol. 140, Art. 106195, 2020. DOI: 10.1016/j.cie.2019.106195.

[17] A. Iosif, E. Maican, S. S. Biriș, and N.-V. Vlăduț, "Application of Machine Learning Models for Predictive Maintenance of Biotechnical Systems," INMATEH - Agricultural Engineering, Vol. 75, No. 1, 2025. DOI: 10.35633/inmateh-75-79.

[18] M. Adkisson, J. C. Kimmel, M. Gupta, and M. Abdelsalam, "Autoencoder-based Anomaly Detection in Smart Farming Ecosystem," arXiv:2111.00099, 2021. DOI: 10.48550/arXiv.2111.00099.

[19] C. Zhang et al., "Digital twin-based approaches for agricultural machinery damage prediction and maintenance," Journal of Computational Design and Engineering, Vol. 12, No. 10, pp. 87-119, 2025.

[20] G. Morales Méndez, "Augmented Reality in Industry 4.0 Assistance and Training Applications," Electronics, Vol. 13, No. 6, Art. 1147, 2024. DOI: 10.3390/electronics13061147.

Authors



Bok-Eun Lee has been serving as the CEO of SC Creative Co., Ltd. since March 2020. Since March 2025, he has been pursuing the M.S. degree in the Department of Smart Convergence (Major in Smart Agriculture) at Sunchon National University, Korea. His current research interests include smart farm equipment condition monitoring, sensor data analytics, artificial intelligence (AI), and extended reality (XR).

www.kci.go.kr