



Received: 2026/08/11
Revised: 2026/08/22
Accepted: 2026/09/17
Published: 2026/09/30

***Corresponding Author:**

Sun-Ju Won

20, Daewangpangyo-ro 851beon-gil, Sujeong-gu,
Seongnam-si, Gyeonggi-do, Republic of Korea

Tel: +82-31-8038-0439

E-mail: sunju.won@ligdna.com

Redfish API와 BIT 정보 융합 기반 서버류 장비 CBM+ 적용 방안 연구

Study on CBM+ Application for Server-Class Equipment Based on Redfish API and BIT Data Fusion

원선주^{1*}, 박병호¹, 박경덕², 조일훈², 김영선³, 김민³

¹LIG 디펜스앤에어로스페이스 미래전장IPS연구소 선임연구원

²LIG 디펜스앤에어로스페이스 미래전장IPS연구소 수석연구원

³네모시스(주) 신뢰성 연구팀 책임

Sun-Ju Won^{1*}, Byeongho Bak¹, Kyoung-Deok Park², Il-Hoon Cho²,
Young-Seon Kim³, Min Kim³

¹Research engineer, Future Warfare Integrated Product Support R&D, LIG
Defense&Aerospace

²Chief research engineer, Future Warfare Integrated Product Support R&D, LIG
Defense&Aerospace

³Principal researcher, Reliability Research Group, Nemosys Co., Ltd.

Abstract

본 연구는 해군 무기체계에 적용되는 COTS 기반
랙마운트형 서버류 장비의 CBM+ 적용 방안을
제안한다. 고성능 서버는 평시 낮은 자원 사용률과 오버
프로비저닝 특성으로 인해 고장 데이터가 부족하고,
고장 직전까지 상태지표가 정상 범위에 머무를 수 있다.
이에 Redfish API 기반 하드웨어 상태정보와 체계 고유
BIT 정보를 융합하고, LSTM-autoencoder 기반
이상감지, Bayesian LSTM 기반 RUL 산출, 운전자
피드백 기반 모델 보정 절차를 제시하였다.

This study proposes a CBM+ application framework for
COTS-based rack-mounted server-class equipment in
naval weapon systems. The proposed framework
integrates Redfish-based hardware telemetry and
system-specific BIT data and employs LSTM-AE-based
anomaly detection, Bayesian LSTM-based RUL
estimation, and operator-feedback-based model
calibration.

Keywords

상태기반정비 플러스(CBM+),
레드피시 API(Redfish API), 자체고장진단(BIT),
장단기 메모리 오토인코더(LSTM-AE), 잔여수명(RUL),
운전자 참여형(Human-in-the-Loop)

1. 서론

1.1 연구의 배경 및 필요성

최근 국방 무기체계는 개방형 시스템 아키텍처(MOSA, modular open systems approach)를 기반으로 상용기술과 COTS(commercial off-the-shelf) 품목을 적극 활용하여 개발기간과 획득비용을 절감하고, 최신 정보기술을 신속하게 반영하는 방향으로 발전하고 있다. 이러한 추세와 함께 AI 기반 다종 데이터 융합 및 대량 데이터 처리를 위한 고성능 연산 요구가 증가하면서, 19인치 표준랙에 장착되는 서버급(server-class) 컴퓨팅 플랫폼을 핵심 연산장치로 적용하는 사례가 확대되고 있다[1,2]. 해군 무기체계의 서버류 장비는 대용량 음향·해양 정보 처리, 데이터 입출력 및 연산 처리를 담당하므로 고장 발생 시 전체 체계의 임무 수행에 직접적인 영향을 줄 수 있다[7].

그러나 서버류 장비는 기계장비와 달리 진동, 윤활, 마모와 같은 물리적 열화 정보보다 CPU, 메모리, 네트워크, 저장장치, 팬, 전원 공급장치 상태와 같은 전자장비 내부 상태정보가 CBM+ 기반 상

태평가 및 이상감지를 위한 핵심 지표가 된다. 따라서 기존 기계장비 중심의 상태기반정비 플러스(CBM+, condition based maintenance plus) 방법론을 그대로 적용하기에는 한계가 있으며, 상용 서버가 제공하는 표준 상태정보와 체계개발 과정에서 정의되는 자체고장진단(BIT, built-in test) 정보를 함께 활용하는 상태평가 구조가 필요하다[6,8,9].

1.2 연구 목적 및 차별성

본 연구는 Redfish API 기반 하드웨어 상태정보와 체계 고유 BIT 정보를 시계열적으로 동기화하는 이종 상태정보 데이터 융합(heterogeneous telemetry fusion) 아키텍처를 제안한다. 또한 개발 단계의 고장 데이터 희소성을 고려하여 모의 데이터 기반 초기 모델을 구성하고, 전력화 이후 실제 정비 이력(ground truth)과 운용자 피드백을 활용하여 모델 파라미터와 임계치를 점진적으로 보정하는 운용자 참여형 능동학습(human-in-the-loop active learning) 운용 프레임워크를 제시한다.

이러한 접근은 진동, 윤활, 마모 등 물리적 열화정보를 중심으로 상태를 진단하는 기존 기계장비 기반 CBM+ 연구와 달리, 서버류 장비에서 표준화된 Redfish 상태정보와 체계 고유의 BIT 정보를 통합하여 상태평가 지표를 구성하고, 이를 이상감지 및 고장 예측에 활용한다는 점에서 차별성이 있다.

2. 서버류 장비 CBM+ 적용 특성

대상 장비는 COTS 기반 랙마운트형 워크스테이션 또는 서버로 가정하였다. 체계 특성상 음향·해양 정보와 같이 데이터 용량이 큰 정보를 처리하므로 네트워크 및 디스크 입출력, CPU 및 RAM 연산 처리 상태가 핵심 감시 대상이다. 고성능 서버는 미션 크리티컬 장비로 운용되기 때문에 평시에는 자원 여유율을 크게 확보하는 오버 프로비저닝(over-provisioning) 형태로 설계될 가능성이 높다. 이 경우 정상 운용 중 CPU 사용률은 낮게 유지되고, 고장 직전까지 지표 변화가 작게 나타날 수 있다[17,18].

특히 정상 데이터는 지속적으로 축적되는 반면 실제 고장 데이터는 체계개발 단계에서 확보하기 어렵다. 예를 들어 정상 상태에서는 CPU 사용률이 15% 내

Table 1. Characteristics and CBM+ issues of server-class equipment

Item	Server Traits	CBM+ Issue	Action
High Perf. / Low Load	Large CPU / RAM margin; Low load	Weak signs before failure	Use avg. / Delta / Trend features
Fault Data Gap	Mostly normal data	Hard supervised learning	Use unsupervised + Simulated faults
Electronic Equipment	Status / logs > Physical wear	Mechanical CBM+ limits	Fuse Redfish + BIT
Mission Critical	24/7 ops; Mission SW linked	False/Missed alarms burden ops	Post-process + Feedback tuning

외에 머무를 수 있으며, 사용률 50% 이상의 고부하 데이터는 시험환경에서 의도적으로 생성하지 않는 이상 확보가 제한될 수 있다. 따라서 개발 단계 모델은 실제 고장 데이터를 전제로 하기보다 정상 데이터 기반 이상감지와 모의 고장 시나리오 검증을 결합하는 방식으로 구축하는 것이 현실적이다[19,20].

3. Redfish API와 BIT 정보 융합 구조

Redfish API는 서버 플랫폼 관리 정보를 RESTful 인터페이스로 제공하는 DMTF 표준으로, CPU, 메모리, 저장장치, 전원공급장치, 냉각팬 등 하드웨어 상태정보를 표준화된 형태로 제공할 수 있다. 그러나 Redfish 정보는 주로 상용 서버 하드웨어의 상태를 대상으로 하며, 무기체계 고유의 임무 소프트웨어, 통신모듈, 암호모듈, 자체 BIT 결과 등 체계 특화 상태정보를 모두 포함하지는 않는다[3-5].

따라서 본 연구에서는 Redfish 기반 out-of-band 하드웨어 상태정보와 체계 BIT 정보를 별도 수집한 뒤, 시간 기준으로 정렬하여 통합 건전성 지표(health indicator)를 구성하는 방안을 제안한다.




Fig. 1. Proposed CBM+ architecture based on Redfish and BIT data fusion

Table 2. Data items for heterogeneous telemetry fusion

Data	Items	Use
Redfish	CPU temp./util., Memory, Fan, PSU, Drive, Network	HW health; Anomaly detection
BIT	Mission SW, Comm, Crypto, BIT, Interface	Fault judgment; Maintenance link
Features	Net util., Mem delta, CPU avg, MSE slope	Trend / Degradation detection

Redfish 정보는 범용 하드웨어의 조기 이상 징후 탐지에 유리하고, BIT 정보는 체계 기능 수준의 고장 정의와 판단기준을 반영할 수 있다. 두 정보의 융합은 단일 정보만을 사용하는 방식보다 고장 원인 식별성과 정비 의사결정 신뢰성을 높일 수 있다.

4. 이상감지 및 고장예측 알고리즘

이상감지의 목적은 현재 상태가 정상인지 또는 비정상 징후를 보이는지를 판정하는 것이다. 서버류 장비에서는 순간적인 CPU 사용률 급등, 네트워크 송수신량 급감, 디스크 입출력 폭주와 같은 스파이크형 이상과, 메모리 누수 또는 냉각 성능 저하에 따른 CPU 온도 상승처럼 장시간에 걸쳐 점진적으로 진행되는 트렌드형 이상이 모두 발생할 수 있다. 이에 본 연구에서는 LSTM-autoencoder(LSTM-AE)를 기본 이상감지 모델로 적용하고, isolation forest를 경량 보조 모델로 검토하였다[10,11,13].

LSTM-AE는 정상 시계열 패턴을 학습한 뒤 입력 시계열을 복원하며, 복원오차가 증가하는 경우 정상 패턴에서 벗어난 것으로 판단한다. 슬라이딩 윈도우 방식으로 10초 단위 데이터 60개를 하나의 입력 시퀀스로 구성하면 약 10분간의 변화 추세를 반영할 수 있

Table 3. Roles of anomaly detection and prognostics algorithms

Algorithm	Role	Strength	Limit
LSTM-AE	MSE-based anomaly detection	Trend and pattern detection	Data / Parameter sensitive
Isolation Forest	Outlier detection	Lightweight; Fast	Weak temporal modeling
Bayesian LSTM	Trend RUL estimation	Uncertainty-aware RUL	Not for spike faults


다[12]. Isolation forest는 데이터를 반복적으로 분할하여 정상 데이터 분포에서 벗어난 값을 빠르게 고립시키는 방식으로, 실시간성 및 설명력이 필요한 경우 보조적으로 활용할 수 있다. Bayesian LSTM은 트렌드형 이상에 대한 잔여수명(RUL, remaining useful life) 예측에 활용된다[14-16]. 예측 시 dropout을 반복 적용하여 다수의 예측 결과를 생성하고, 이를 기반으로 평균 RUL과 95% 신뢰구간을 산출한다. 본 연구에서는 LSTM-AE의 복원오차 변화율을 입력 특성으로 사용하여 고장 임계치 도달 시점을 예측한다.

5. 모의 데이터 기반 초기 검증

본 연구에서는 서버류 장비의 이상감지 기준을 부품별 고장모드와 상태지표의 관계를 기반으로 설정하였다. CPU는 연산 부하 증가에 따른 사용률 급등을 주요 이상 징후로 정의하고, 메모리는 사용률의 절대값보다 시간에 따른 점진적 증가율을 메모리 누수 판단 기준으로 활용하였다. 네트워크는 송수신량의 급증 또는 급감을 데이터 입출력 이상 징후로 정의하였다.

실데이터 확보 전 단계에서는 서버류 장비의 운용 특성을 반영한 모의 데이터를 생성하여 알고리즘의 기본 동작을 검증하였다. 샘플링 주기는 10초로 설정하고, 총 3,000건의 데이터를 구성하였다. 정상 상태는 고사양 서버의 저부하 특성을 반영하여 CPU 사용률 평균 7%, 메모리 사용률 평균 15%, 네트워크 트래픽은 1 Gbps 대역폭 기준 5~6 MB/s 수준으로 설정하였다.

비정상 시나리오는 돌발 이상과 추세 이상으로 구분하였다. 돌발 이상은 특정 구간에서 CPU 사용률이 60% 수준으로 급등하는 스파이크 형태로 구성하였고, 추세 이상은 메모리 누수에 의해 일정 시점 이후

**Fig. 2.** Anomaly classification and maintenance decision flow




Fig. 3. Simulated CPU, memory, and network telemetry data

메모리 사용률이 점진적으로 증가하는 형태로 구성하였다. 파생 변수로는 네트워크 사용률, 메모리 변화량, CPU 10분 이동평균을 생성하였다.

검증 결과, isolation forest는 CPU 스파이크 발생 시 정상 데이터 분포에서 벗어난 지점을 즉각적으로 이상으로 판정하였다. 다만 단발성 노이즈를 모두 알람으로 표시할 경우 알람 피로도가 증가할 수 있으므로, 이상 판정이 6회 연속 발생하는 경우 경고 알람을 발생시키는 후처리 로직을 적용하였다. 이 과정에서 단발성 오탐은 감소하였으나, 탐지 지연이 발생할 수 있음을 확인하였다.

LSTM-AE는 CPU 스파이크와 메모리 누수형 추세 이상을 모두 복원오차 증가로 감지하였다. 특히 메모리 사용률 자체가 즉시 임계치에 도달하지 않더라도 복원오차의 기울기가 증가하는 경우 트렌드형 이상으로 분류할 수 있었다. 트렌드형 이상에 대해서는 이상감지 시점 이후 복원오차가 고장 기준에 도달하는 시점을 Bayesian LSTM으로 예측하고, 예측 불확실성을 표현하기 위해 일반적인 통계적 신뢰수준인 95% 신뢰구간 형태의 RUL을 제시하였다.




Fig. 4. Anomaly detection and RUL estimation results

6. 운용자 피드백 기반 모델 보정

국방 무기체계에서는 모델이 자동으로 임계치와 파라미터를 변경하는 방식보다, 시스템이 조정 필요 항목과 예상 효과를 제안하고 운용기관이 검토 및 확정하는 구조가 신뢰성과 추적성 측면에서 적합하다. 따라서 본 연구에서는 이상감지 결과를 운용자가 확인하여 실고장, 오경보, 정상 부하 변동, 검토 필요로 라벨링하고, 이를 피드백 DB에 축적하는 human-in-the-loop 보정 절차를 제안한다.

운용자 피드백은 즉시 모델을 변경하는 데 사용하지 않고, 검증용 라벨 데이터로 저장한다. 이후 일정 주기마다 정비 이력, 운용 로그, 알람 이력, 피드백 라벨을 대조하여 오경보(false alarm)와 미경보 사례를 식별하고, 오프라인 환경에서 임계치, 윈도우 길이, 복원오차 기준, isolation forest contamination, Bayesian LSTM dropout 비율 등을 조정한다. 조정된 모델은 재현 가능한 시험 절차와 성능평가 결과를 거친 뒤 승인된 모델 버전으로 배포한다.




Fig. 5. Human-in-the-loop feedback and model tuning procedure

Table 4. Operator feedback labels and their use in model calibration

Label	Definition	Calibration Use
Confirmed Fault	Fault verified by logs / Maintenance	Keep rule or raise sensitivity
False Alarm	Alarm with no fault found	Raise threshold; Tighten logic
Normal Load Variation	Normal mission / Ops load	Add to normal patterns
Undetermined	Cause unclear	Exclude; Collect more logs

7. 파라미터 튜닝 및 성능개선 방법론

모델 파라미터 조정은 단순히 알람 수를 줄이는 방향으로 수행해서는 안 된다. 오경보를 줄이기 위해 임계치를 과도하게 높이면 미경보가 증가할 수 있고, 탐지 민감도를 높이면 알람 피로도가 증가할 수 있다. 따라서 본 연구에서는 오경보율, 미경보율, 탐지 지연, RUL 예측오차, 신뢰구간 폭을 함께 고려하는 다목적 성능평가 절차를 적용한다.

초기 단계에서는 무작위 탐색(random search)을 통해 넓은 파라미터 공간에서 후보 조합을 탐색하고, 실제 피드백 데이터가 축적된 이후에는 베이지안 최적화(Bayesian optimization)를 통해 성능이 우수한 영역을 집중 탐색한다. 각 후보 모델은 동일한 검증 데이터셋에서 비교하고, 기존 모델 대비 오경보율과 탐지 지연이 개선되더라도 미경보율이 악화되는 경우 배포 대상에서 제외한다. 또한 모델 버전, 학습 데이터 기간, 파라미터 값, 성능지표, 승인 이력을 관리하여 추적성을 확보한다.

Table 5. Parameters and performance metrics for model tuning

Model	Parameters	Metrics
LSTM-AE	Window, Hidden size, LR, MSE threshold	Detection, False alarm, Latency
Isolation Forest	Contamination, Trees, Sample size	Spike detection, Time, False alarm
Post-Processing	Consecutive count, Hold time, Re-alarm gap	Alarm fatigue, Latency
Bayesian LSTM	Dropout, Horizon, Training span	RUL error, CI coverage

8. 결론

본 연구는 해군 무기체계에 적용되는 서버류 장비를 대상으로 Redfish API와 체계 BIT 정보를 융합한 CBM+ 적용방안을 제안하였다. COTS 기반 고성능 서버는 평시 낮은 사용률, 오버 프로비저닝, 고장 데이터 부족, 전자장비 특성으로 인해 기존 기계장비 중심 CBM+ 방법론을 그대로 적용하기 어렵다. 이에 본 연구에서는 상태정보 데이터 융합, LSTM-AE 기반 이상감지, Bayesian LSTM 기반 RUL 산출, 운용자 피드백 기반 모델 보정 절차를 통합한 프레임워크를

제시하였다.

모의 데이터 검증을 통해 CPU 스파이크와 메모리 누수형 추세 이상에 대한 탐지 가능성을 확인하였으며, 스파이크형 이상은 즉시 점검 알람 대상으로, 트렌드형 이상은 RUL 기반 의사결정 대상으로 구분하는 절차를 제안하였다. 향후 연구에서는 실제 서버 운용 데이터의 샘플링 주기, 결측치, 단위 체계, 정상 운용 모드별 부하 패턴을 분석하고, 실제 정비 이력과 운용자 피드백을 반영하여 모델 파라미터와 고장 임계치를 지속적으로 보정할 필요가 있다.

참고문헌

- [1] U.S. Department of Defense, DoD Instruction 5000.88: Engineering of Defense Systems, November 18, 2020.
- [2] Office of the Under Secretary of Defense for Research and Engineering, Implementing a Modular Open Systems Approach in Department of Defense Programs, 2025.
- [3] DMTF, Redfish Specification, DSP0266 Version 1.24.0, Distributed Management Task Force, 2026.
- [4] DMTF, Redfish Data Model Specification, DSP0268, Distributed Management Task Force, 2026.
- [5] DMTF, Redfish Resource and Schema Guide, DSP2046 Version 1, Distributed Management Task Force, 2026.
- [6] ISO, ISO 13374-3:2012, Condition Monitoring and Diagnostics of Machines – Data Processing, Communication and Presentation – Part 3: Communication, 2012.
- [7] Jin Eun Jeong & Gyunghyun Choi, 'On the Study of the Establishment of Condition Based Maintenance System for Weapon Systems,' Asia-Pacific Journal of Convergent Research Interchange, VOL. 10, NO. 6, 2024, pp. 65–83.
- [8] Andrew K. S. Jardine, Daming Lin, & Dragan Banjevic, 'A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance,' Mechanical Systems and Signal Processing, VOL. 20, NO. 7, 2006, pp. 1483–1510.
- [9] N. M. Vichare & M. G. Pecht, 'Prognostics and Health Management of Electronics,' IEEE Transactions on Components and Packaging Technologies, VOL. 29, NO. 1, 2006, pp. 222–229.
- [10] Fei Tony Liu, Kai Ming Ting, & Zhi-Hua Zhou, 'Isolation Forest,' Proceedings of the 8th IEEE International Conference on Data Mining, Pisa, Italy, December 2008, pp. 413–422.
- [11] Pankaj Malhotra, Anusha Ramakrishnan, Gaurangi Anand, Lovekesh Vig, Puneet Agarwal, & Gautam Shroff, 'LSTM-Based Encoder-Decoder for Multi-Sensor Anomaly Detection,' arXiv:1607.00148, 2016.
- [12] Pankaj Malhotra, Vishnu TV, Anusha Ramakrishnan, Gaurangi Anand, Lovekesh Vig, Puneet Agarwal, & Gautam

Shroff, 'Multi-Sensor Prognostics using an Unsupervised Health Index Based on LSTM Encoder-Decoder,' arXiv:1608.06154, 2016.

[13] Thamo Sutharssan, Stoyan Stoyanov, Chris Bailey, & Chunyan Yin, 'Prognostic and Health Management for Engineering Systems: A Review of the Data-Driven Approach and Algorithms,' *The Journal of Engineering*, VOL. 2015, NO. 7, 2015.

[14] Yarin Gal & Zoubin Ghahramani, 'Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning,' in *Proceedings of the 33rd International Conference on Machine Learning*, 2016, pp. 1050-1059.

[15] James Bergstra & Yoshua Bengio, 'Random Search for Hyper-Parameter Optimization,' *Journal of Machine Learning Research*, VOL. 13, 2012, pp. 281-305.

[16] Jasper Snoek, Hugo Larochelle, & Ryan P. Adams, 'Practical Bayesian Optimization of Machine Learning Algorithms,' *Advances in Neural Information Processing*

Systems 25, 2012.

[17] Office of the Secretary of Defense, *Condition Based Maintenance Plus DoD Guidebook*, U.S. Department of Defense, 2008.

[18] Yong Kim, Daewoong Kim, & Dohyeon Jeong, 'Feasibility and Foundational Elements of CBM+ Technology Application in Weapon Systems,' *Journal of Advances in Military Studies*, VOL. 7, NO. 2, 2024, pp. 29-54.

[19] Jong-Moon Rhee, Dong-Ju Jeon, Yonggeun Kim, & So-Jung Kim, 'The Operational Availability Improvement Based on PMS & CBM+ Strategy,' *Journal of the Korea Academia-Industrial Cooperation Society*, VOL. 25, NO. 6, 2024, pp. 246-252.

[20] Younho Lee, Seongmok Kim, Ji-Won Kim, Jae-Woo Jung, Jung-Won Park, & Yong Soo Kim, 'A Study on Method for Applying CBM+ in Missile for Effective Health Management,' *Journal of the KIMST*, VOL. 27, NO. 2, 2024, pp. 294-303.