

탄성사 크릴 장력제어 시스템의 저속 구름 베어링 고장진단을 위한 LSTM·MCNN 앙상블 모델

이대희*, 이은하**

LSTM - MCNN Ensemble for Low-Speed Rolling Bearing Fault Diagnosis in Elastic Yarn Creel Tension Control Systems

Dae-hee Lee*, Eun-ha Lee**

이 연구는 한국산업기술기획평가원 기계장비산업기술개발 사업 [과제명 : 산업용 섬유 2,000가닥 이상 다이렉트 제직을 위한 스마트 크릴 시스템 실증] (과제번호: RS-2025-16212968) 지원으로 수행되었습니다

요 약

탄성사 크릴 장력제어 시스템은 수십~수백 RPM의 저속으로 동작하여 베어링 결함주파수(BPFO, BPFI, BSF)가 저주파 대역에 형성되며, 기존 임계값 기반 방법으로는 고장 감지가 어렵다. 본 연구는 물리 기반 합성 데이터를 이용한 모델 학습·검증과 실제 크릴 장치 실측 스펙트럼 분석의 2단계 검증 체계를 적용하였다. 합성 데이터 기반 5-Fold 교차검증에서 제안하는 LSTM·MCNN 앙상블 모델은 100 RPM에서 79.2%, 1,797 RPM에서 99.2%의 정확도를 달성하여 기존 7개 비교 모델 대비 저속 구간 우수한 성능을 기록하였다. 실측 스펙트럼 분석에서 제안 알고리즘의 이상 지표가 합성 데이터 기반 결함 패턴과 일치하는 이상 징후를 감지함으로써 실제 크릴 환경에서의 적용 가능성을 확인하였다.

Abstract

Elastic yarn creel tension control systems operate at low speeds of tens to hundreds of RPM, so the bearing fault frequencies (BPFO, BPFI, BSF) form in the low-frequency band, making fault detection difficult with conventional threshold-based methods. This study applies a two-stage validation framework consisting of model training and validation using physics-based synthetic data, followed by spectrum analysis of measurements from an actual creel device. In 5-fold cross-validation on the synthetic data, the proposed LSTM·MCNN ensemble model achieved an accuracy of 79.2% at 100 RPM and 99.2% at 1,797 RPM, demonstrating superior performance in the low-speed range compared with seven existing benchmark models. In the field spectrum analysis, the anomaly indicators of the proposed algorithm detected anomalous signatures consistent with the fault patterns derived from the synthetic data, thereby confirming its applicability in a real creel environment.

Keywords

creel tension control system, low-speed rolling bearing, fault diagnosis, LSTM·MCNN ensemble, R^2 optimization

* 한국섬유기계융합연구원 하이테크 롤 첨단화 지원센터 책임연구원(교신저자)

- ORCID: <https://orcid.org/0009-0000-7658-9219>

** 한국섬유기계융합연구원 책임연구원

- ORCID: <https://orcid.org/0009-0001-9921-3174>

· Received: May 06, 2026, Revised: Jun. 12, 2026, Accepted: Jun. 15, 2026

· Corresponding Author: Dae-hee Lee

Dept. of Korea Textile Machinery Convergence Research Institute

Tel.: +82-54-474-3145, Email: dhlee@kotmi.re.kr

1. 서 론

섬유 제조 공정에서 크릴(Creel) 시스템은 수백~2,000가닥 이상의 원사 보빈을 거치하고 장력제어 롤을 통해 일정한 장력으로 원사를 공급하는 핵심 설비이다. 탄성사 공정에서 장력 균일성은 원단 품질에 직결되므로, 장력제어 시스템의 베어링 상태를 실시간으로 감시하는 예지정비(PHM, Prognostics and Health Management) 시스템이 요구된다.

크릴 장력제어 시스템은 수십~수백 RPM의 저속으로 작동하는 구조적 특성을 가진다. 본 연구의 대상 설비인 탄성사 크릴 장치의 서보모터는 운전 범위가 30~200 RPM으로, 이 경우 베어링 결함으로 발생하는 특성주파수 BPFO(Ball Pass Frequency Outer Race), BPFI(Ball Pass Frequency Inner Race), BSF(Ball Spin Frequency)가 수 Hz~수십 Hz의 저주파 대역에 형성된다. 예를 들어 100 RPM에서 외륜 결함주파수(BPFO)는 5.97 Hz, 내륜결함주파수(BPFI)는 9.04 Hz에 불과하여, 기존 임계값(Rule-based) 방법이나 Z-score 기반의 통계적 방법으로는 정상 신호와의 구분이 어렵다는 근본적 한계가 있다[1]. 그림 1에 크릴 장력제어 시스템의 구성과 진동센서 배치를 나타내었다.

그림 2는 본 연구의 대상 설비인 실제 탄성사 크릴 장력제어 시스템의 현장 사진이다. 그림 2(a)는 수백 가닥의 탄성사가 장력제어 롤을 통해 공급되는 전체 구성을, 그림 2(b)는 롤을 구동하는 서보모터와 하우징에 부착된 3축 가속도 센서 위치를 나타낸다. 서보모터는 저속(수십~수백 RPM) 조건에서 동작하며, 이에 따라 베어링 결함 주파수가 저주파 대역에 형성되는 고장진단의 어려움이 발생한다.

저속 베어링 고장진단 관련 기존 연구들은 주로

1,000 RPM 이상의 고속 조건을 대상으로 딥러닝 모델의 성능을 검증했으나[2][3], 저속 조건에서의 체계적인 다중 모델 비교 연구는 아직 미흡한 실정이다. 특히 STFT(Short-Time Fourier Transform) 파라미터 최적화가 RPM 조건에 따라 어떻게 달라져야 하는지, 그리고 어떤 모델이 저속 조건에서 더 강한 성능을 보이는지에 대한 정량적 분석이 요구된다.



그림 2. 탄성사 크릴 장력제어 시스템 실제 사진 (a) 전체 구성 및 원사 배열, (b) 서보모터(베어링) 및 진동센서 부착 위치

Fig. 2. Actual photos of elastic yarn creel tension control system (a) Overall composition and yarn arrangement, (b) servo motor and vibration sensor installation

본 연구에서는 SKF 6205-2RS 베어링의 물리적 파라미터를 기반으로 100~1,797 RPM의 4개 속도 조건에서 합성 진동 신호를 생성하고, R^2 기반 STFT 윈도우 최적화를 통해 각 RPM에 적합한 특징을 추출하며, 8개 고장진단 모델을 5-Fold 교차검증을 체계적으로 비교하여 저속 크릴 환경에 적합한 딥러닝 양상블 모델을 도출한다.

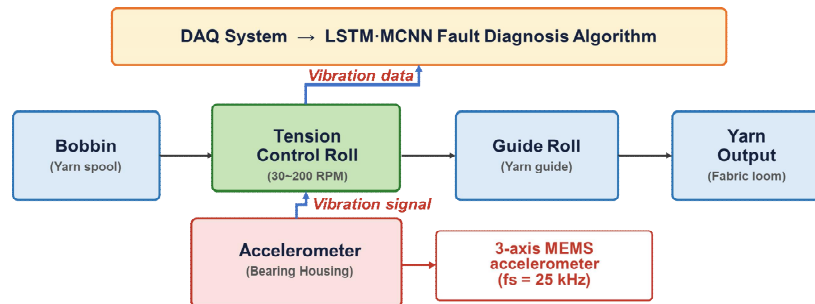


그림 1. 크릴 장력제어 시스템 구성 및 진동센서 배치도

Fig. 1. Creel tension control system configuration and vibration sensor placement

본 논문의 기여점은 다음과 같다. 첫째, 저속 베어링 진단의 어려움을 4개 RPM 조건의 8개 모델 비교 실험으로 정량화하여, 딥러닝 앙상블 접근법의 필요성을 입증하였다. 둘째, R^2 기반 STFT 윈도우 최적화로 각 RPM 조건에서 MPF(Mean Peak Frequency) 특징 품질을 개선하였다. 셋째, 합성 데이터 기반 모델 개발과 실제 크릴 장치 실측 스펙트럼 분석의 2단계 검증 체계를 통해, 제안 알고리즘의 실제 환경 적용 가능성을 확인하였다.

II. 관련 연구

2.1 PHM 고장진단 연구 동향

최근 PHM(Prognostics and Health Management) 분야에서는 Transformer 기반 자기주의(Self-attention) 메커니즘을 활용한 시계열 이상 감지, 그래프 신경망(GNN, Graph Neural Network) 기반 다중 센서 신호 이상 감지, 대조 학습(Contrastive learning) 기반 소수 레이블 환경에서의 고장 분류 등 다양한 딥러닝 접근이 제안되고 있다[9]-[11]. 그러나 이러한 방법들은 공통적으로 충분한 레이블 학습 데이터와 상대적으로 높은 SNR(Signal-to-Noise Ratio) 환경을 전제로 설계되어 있어, 극저속(100 RPM 이하), 낮은 SNR(5dB), 실측 레이블 데이터 부재라는 삼중 제약 조건이 동시에 존재하는 산업 현장 적용에는 한계가 있다. 본 연구는 물리 기반 합성 데이터 생성과 앙상블 분산 감소 전략을 결합함으로써, 데이터 취득이 제한된 저속 크릴 환경에서의 베어링 진단 가능성을 검증한다는 점에서 위의 연구들과 차별성을 갖는다. 또한 비교 대상으로 선정된 모델인 SVM(Support Vector Machine), Random Forest, 1D-CNN (Convolutional Neural Network), LSTM(Long Short-Term Memory), MCNN(Multi-scale Convolutional Neural Network)은 저속 PHM 관련 문헌에서 실질적으로 활용되는 대표적 기준(Baseline) 모델로[3][8], 제안 앙상블 방법의 상대적 우위를 정량적으로 확인하기에 적합하다.

2.2 저속 베어링 진동의 특성과 진단 어려움

베어링 회전속도가 낮아지면 결합 충격 간격(=1/BPFO)이 길어져 단위 시간 내 신호 에너지가 감소하고 신호 대 잡음비(SNR)가 현저히 저하된다. 1,797 RPM에서 외륜 결합 주파수는 BPFO=107.4 Hz(충격 간격 9.3 ms)이지만, 100 RPM에서는 BPFO=5.97Hz(충격 간격 167ms)로 동일한 관찰 시간 내에 발생하는 충격 횟수가 약 18배로 감소한다. 이러한 특성으로 인해 기존 RMS(Root Mean Square) 임계값, Z-score, 포락선 분석 등의 방법이 저속 조건에서 성능 저하를 겪는다[1].

STFT 기반 MPF(Mean Peak Frequency) 분석은 시간-주파수 에너지 분포를 분석하여 결합 주파수 대역의 에너지 변화를 추적할 수 있으나, 저속 조건에서는 최적 STFT 윈도우 크기가 고속과 달리 충분히 커야 한다는 제약이 있다[2]. 이를 해결하기 위한 객관적 파라미터 선택 기준이 요구된다[6].

2.3 딥러닝 기반 고장진단 모델

LSTM은 삭제, 입력, 출력 게이트 구조를 통해 시계열의 장기 의존성을 학습하며, 저속 조건에서 긴 충격 간격(100 RPM에서 BPFO 주기 \approx 167ms)을 포착하는 데 유리하다[3]. MCNN(Multi-scale CNN)은 커널 크기 {3, 5, 7}의 병렬 합성곱을 통해 다양한 시간 스케일의 패턴을 동시에 추출하며, 저속의 완만한 에너지 변화와 산발적 충격을 함께 학습할 수 있다. 두 모델의 소프트 투표 앙상블은 LSTM이 놓치는 순간적 특징을 MCNN이 보완하고, MCNN이 오분류하는 장기 패턴을 LSTM이 교정하는 상호 보완 효과를 발휘한다[4]. 특히 저속에서 SNR이 낮아 단일 모델의 예측 분산이 커질 때, 앙상블이 분산을 평균화하여 안정적인 성능을 유지하는 것이 핵심 장점이다.

EBM-LSTM 하이브리드 모델[5]은 설명 가능한 AI 모델인 EBM(Explainable Boosting Machine)으로 핵심 변수를 선별한 후 LSTM으로 잔여 수명을 예측하여 항공기 터빈 엔진에서 RMSE(Root Mean Square Error)=15.33, $R^2=0.862$ 를 달성하였다. 이는 특징 선택과 딥러닝 앙상블의 결합이 PHM 분야에서 높은 유효성을 가짐을 보여준다. 이는 특징 선택과 딥러닝 앙상블의 결합이 PHM 분야에서 높은 유효성을

가짐을 보여준다. 한편, 딥 합성곱 신경망(Deep CNN)을 활용한 잔여 수명(RUL) 예측 연구[7]에서도 시계열 특징 학습을 통한 고장진단 성능 향상이 보고된 바 있다.

2.4 R² 기반 STFT 파라미터 최적화

선행 연구[2]에서는 고압 분산기 MPF 시계열의 LSTM/MCNN 예측 정확도를 R²로 평가하고, window, hop, NFFT(Number of FFT Points)의 그리드 탐색으로 R²를 최대화하는 조합을 자동 선택하는 방법을 제안하였다. MPF는 시간에 따라 연속적으로 변화하는 시계열 형태를 보이므로 1-스텝 예측 가능성이 높을수록 결함 주파수 대역의 에너지 집중도가 명확함을 의미한다. 따라서 R²는 단순한 회귀 지표를 넘어 특징 품질(Feature quality)의 대리 지표(Surrogate indicator)로 기능한다. 저속 조건에서 결함 에너지가 낮고 충격 간격이 길어질수록 최적 윈도우가 커져야 하는 물리적 타당성이 R² 최대화 방향과 일치한다[1].

III. 알고리즘 설계

3.1 전체 시스템 구조

그림 3과 같이 본 시스템은 (1) 저속 베어링 진동 신호 취득, (2) R² 기반 최적 STFT 윈도우 선택, (3) 17개 특징 추출, (4) 8개 모델 병렬 평가, (5) 고장 클래스 분류 및 RPM별 성능 비교의 5단계로 구성된다.

3.2 R² 기반 STFT 윈도우 최적화

각 RPM 조건에서 MPF 시계열 $x = \{m_1, m_2, \dots, m_n\}$ 을 추출하고, 길이 L의 과거 시퀀스로 다음 값을 예측하는 1-스텝 회귀 모델의 결정계수 R²를 식 (1)로 정의한다.

$$R^2 = 1 - SS_{res} / SS_{tot}, SS_{res} = \sum (m_i - \hat{m}_i)^2 \quad (1)$$

여기서 $SS_{res} = \sum (m_i - \hat{m}_i)^2$ 는 잔차 제곱합(residual sum of squares), $SS_{tot} = \sum (m_i - \bar{m})^2$ 는 전체 제곱합(total sum of squares)이며, m_i 는 i번째 실제 MPF 값, \hat{m}_i 는 1-스텝 예측 MPF 값, \bar{m} 는 MPF 시계열의 평균값이다.

표 1에서 300 RPM의 R²(0.891)이 가장 높는데, 이는 window=512(42.7 ms)가 해당 속도의 BPFO 주기(T=55.8 ms)와 가장 잘 대응하여 MPF 특징의 시간적 규칙성이 잘 포착되기 때문이다. 반면 100 RPM에서 R²(0.697)이 상대적으로 낮은 것은 낮은 SNR과 극히 긴 충격 간격으로 인한 MPF 불규칙성을 반영한다. 그림 4는 RPM별 R² 최적화 결과를 시각화한 것이다.

표 1. R² 기반 RPM별 최적 STFT 파라미터

Table 1. Optimal STFT parameters by RPM based on R²

RPM	window	NFFT	hop	R ² (LSTM)	R ² (MCNN)
100	1,024	2,048	0.50	0.697	0.676
300	512	1,024	0.50	0.891	0.864
600	256	512	0.50	0.819	0.794
1,797	128	256	0.50	0.708	0.687

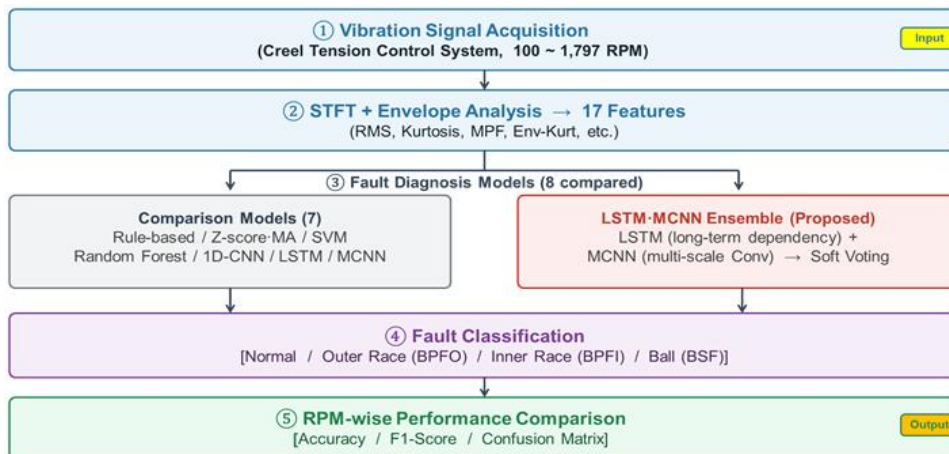


그림 3. 저속 베어링 고장진단 시스템 구조 및 다중 모델 비교 프레임워크

Fig. 3. System architecture and multi-model comparison framework for low-speed bearing fault diagnosis

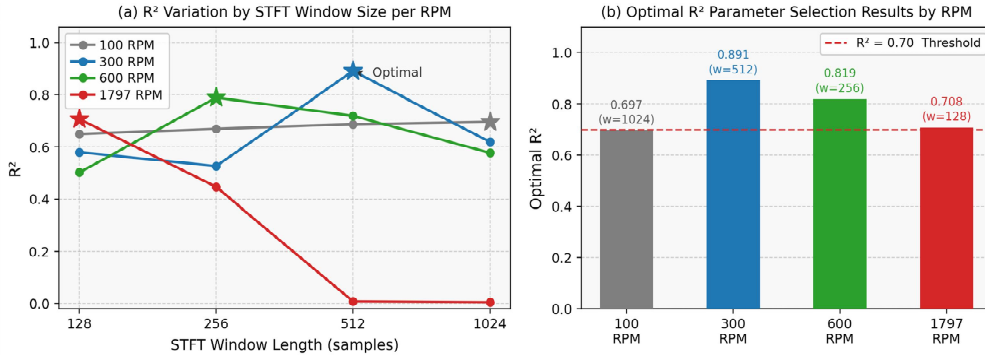


그림 4. R² 기반 RPM별 최적 STFT 파라미터 선택 결과
 Fig. 4. Optimal STFT parameter selection results based on R² by RPM

3.3 특징 추출 (17개)

최적 STFT 파라미터를 적용하여 표 2의 17개 특징을 추출한다. 이들 특징은 시간, 주파수, 포락선 영역의 다양한 신호 특성을 반영하여 저속 조건에서 결합 구분력을 향상하기 위해 선정되었다. 시간 영역 8개 RMS, Peak, Kurtosis, Crest Factor, Skewness, P2P(Peak-to-Peak), Variance, Shape Factor, 주파수 영역 5개 MPF, BW(Bandwidth), HF ratio(High-Frequency ratio), LF ratio(Low-Frequency ratio), Spectral Entropy, 포락선 영역 4개(Env-RMS, Env-Kurtosis, Env-Std, RMS×Kurtosis)를 사용하며, 모든 특징은 z-정규화 후 모델에 입력된다.

표 2. 특징 추출 구성 (17개)
 Table 2. Feature extraction configuration (17 features)

Domain	Feature list	Count
Time domain	RMS, Peak, Kurtosis, Crest, Skewness, P2P, Variance, Shape	8
Freq. domain	MPF, BW, HF ratio, LF ratio, Spectral Entropy	5
Envelope	Env-RMS, Env-Kurtosis, Env-Std, RMS×Kurtosis	4

3.4 LSTM·MCNN 앙상블 모델 (제안)

LSTM 모델은 은닉층 크기 {128, 64, 32}의 3층 구조로 구성되며, 시계열 데이터의 장기 의존성을 학습하기 위해 게이트 기반 메모리 구조를 활용한다. MCNN 모델은 커널 크기 {3, 5, 7}의 병렬 합성곱 구조와 은닉층 크기 {256, 128, 64}, tanh 활성화

함수를 사용하여 다양한 시간 스케일의 특징을 동시에 추출한다. 각 병렬 합성곱 경로의 출력은 채널 방향으로 결합(concatenation)되어 다중 스케일 특징 표현을 형성한다.

입력 데이터는 17개 특징으로 구성된 시계열 데이터로 정의되며, 길이 L의 슬라이딩 윈도우를 적용하여 입력 시퀀스를 구성한다. 여기서 L은 입력 시퀀스 길이를 의미한다. 이에 따라 입력 텐서는 (batch_size×L×17) 형태로 모델에 입력된다. 출력은 정상, 외륜결함(BPFO), 내륜결함(BPFI), 볼결함(BSF)의 4개 클래스에 대한 확률 분포로 나타내며, 가장 높은 확률을 갖는 클래스를 최종 고장 상태로 판정한다.

모든 모델은 동일한 조건에서 비교를 위해 Adam 옵티마이저를 사용하였으며, 학습률은 0.001, 배치 크기는 32로 설정하였다. 손실 함수는 다중 클래스 분류를 위해 categorical cross-entropy를 사용하였다.

최종 분류 확률 P_{ens} 는 식 (2)의 소프트 투표 방식으로 산출된다.

$$P_{ens} = \alpha \cdot P_{LSTM} + (1 - \alpha) \cdot P_{MCNN} \quad (2)$$

여기서 P_{LSTM} 과 P_{MCNN} 은 각각 LSTM 및 MCNN 모델이 출력하는 4개 고장 클래스(정상/BPFO/BPFI/BSF)에 대한 소프트맥스 확률 벡터이며, α 는 두 모델의 앙상블 가중치이다. 본 연구에서는 두 모델을 동등하게 결합하기 위해 $\alpha=0.5$ (동일 가중치)로 설정하였다.

제안하는 앙상블 모델은 단순한 평균 정확도 향상보다는 저속 및 낮은 신호대잡음비 환경에서 개

별 모델의 예측 분산 감소를 주요 목적으로 하면서도, 결과적으로 정확도 향상 효과도 함께 나타난다. 특히 저속 조건에서는 충격 간격 증가와 신호 에너지 감소로 인해 단일 모델의 예측 변동성이 커질 수 있으므로, 앙상블을 통한 분산 감소 효과가 중요한 성능 향상 요인으로 작용한다.

IV. 실험 및 결과

4.1 2단계 검증 체계

본 연구는 그림 5의 실측 실험 환경을 바탕으로 2단계 검증 체계를 적용한다. 1단계(합성 데이터 기반 모델 학습·검증)에서는 실제 크릴 설비와 동일한 베어링 파라미터로 생성된 물리 기반 합성 신호로 8개 모델을 학습하고 5-Fold 교차검증으로 성능을 비교한다. 2단계(실측 스펙트럼 기반 이상 감지 확인)에서는 실제 크릴 장치에서 취득한 진동 스펙트럼 데이터에서 제안 알고리즘의 이상 지표를 추출하고, 합성 데이터 기반 결합 패턴과의 일치 여부를 분석하여 실제 환경 적용 가능성을 검증한다.




그림 5. 실측 진동 데이터 취득 실험 환경

(a) NI DAQ 계측 시스템 전경, (b) 탄성사 장력제어 롤 운전 상태, (c) 서보모터 하우징 3축 가속도 센서 부착

Fig. 5. Real vibration data acquisition setup

(a) NI DAQ system, (b) elastic yarn tension control roll, (c) 3-axis accelerometer on servo motor housing

4.2 1단계: 합성 데이터 기반 모델 학습·검증

SKF 6205-2RS 베어링(볼 수 $N=9$, 볼 직경 $d=7.938$ mm, 피치직경 $D=38.5$ mm)의 물리적 파라미터를 이용하여 100~1,797 RPM의 4개 속도 조건에서 정상(Normal), 외륜결함(Outer Race, OR), 내륜결함(Inner Race, IR), 불결함(Ball)의 4클래스 합성 진동 신호를 생성하였다. 결합 충격 신호는 공진주파수($f_c=3,500$ Hz, 감쇠비 $\zeta=0.05$)의 링다운 응답으로 모델링하고, RPM별 SNR은 저속의 낮은 신호 품질을 반영하여 표 3과 같이 설정하였다[1]. 표 3의 SNR 설정은 저속일수록 신호 품질이 저하되는 실제 크릴 환경을 반영하여 단계적으로 증가하도록 구성하였다.

표 3. 합성 데이터 구성

Table 3. Synthetic dataset composition

RPM	SNR (dB)	Samples /class	Window length	BPFO (Hz)	Classes
100	5±1	100	2,048	5.97	Normal/OR/IR/Ball
300	7±1	100	2,048	17.9	Normal/OR/IR/Ball
600	9±1	100	2,048	35.8	Normal/OR/IR/Ball
1,797	12±1	100	2,048	107.4	Normal/OR/IR/Ball

이때 결합 충격의 주기성은 베어링 결합 특성 주파수를 기준으로 정의하였다. 외륜결함, 내륜결함 및 불결함의 충격 주기 T_d 는 식 (3)과 같이 각각 BPFO, BPFI, BSF의 역수로 설정하였다.

$$T_d = \frac{1}{f_{defect}} \quad (3)$$

여기서 f_{defect} 는 결합 특성 주파수이며, 외륜결함은 BPFO, 내륜결함은 BPFI, 불결함은 BSF를 의미한다. 결합 충격 신호는 각 충격 발생 시점에서 링다운 응답이 반복적으로 발생하는 형태로 식 (4)와 같이 모델링하였다.

$$x_d(t) = \sum_{n=0}^N A e^{-2\pi\zeta f_c(t-t_n)} \cos(2\pi f_c(t-t_n)) u(t-t_n) \quad (4)$$

여기서 A 는 충격 진폭, ζ 는 감쇠비, f_c 는 공진주

파수, $u(\cdot)$ 는 단위 계단 함수, t_n 은 n 번째 충격 발생 시점이다. 실제 설비의 회전 변동을 반영하기 위해 각 충격 주기에 $\pm 2\%$ 의 가우시안 speed jitter를 식 (5)와 같이 적용하였다.

$$t_n = t_{n-1} + T_d(1 + \epsilon_n), \epsilon_n \sim \mathcal{N}(0, \sigma_j^2) \quad (5)$$

최종 합성 신호는 식 (6)과 같이 정상 배경 진동 성분, 결합 충격 성분 및 잡음 성분의 합으로 구성하였다.

$$x(t) = x_b(t) + x_d(t) + w(t) \quad (6)$$

여기서 $x_b(t)$ 는 정상 배경 진동 성분, $x_d(t)$ 는 결합 충격 성분, $w(t)$ 는 AWGN을 의미한다. AWGN은 표 3의 RPM별 목표 SNR을 만족하도록 부가하였으며, 정상 클래스는 $x_d(t)$ 를 제외하고 생성하였다. 각 RPM 조건에서는 클래스당 100개 샘플을 생성하여 Stratified 5-Fold 교차검증에 사용하였다.

Stratified 5-Fold 교차검증(학습 80%, 검증 20%)으로 8개 모델을 비교하였다. 비교 대상 모델은 회전 기계 고장진단 오픈소스 벤치마크 연구[8]에서 제시된 대표적 기준(baseline) 모델을 포함하여 선정하였다. 그림 6은 4개 RPM 조건에서의 정확도 변화를 나타낸다. Rule-based와 Z-score/MA(Moving Average)는 전 RPM에서 22~38%로 저속 환경 적용이 사실상 불가능하며, SVM은 1,797 RPM에서 99.4%로 우

수하나 100 RPM에서 74.4%로 저하된다. 제안하는 LSTM-MCNN 앙상블 모델은 전반적으로 우수한 성능을 보이며, 특히 저속(100 RPM) 조건에서 단일 모델 대비 가장 효과적인 성능을 나타낸다.

표 4는 8개 모델의 RPM별 고장진단 정확도(평균 \pm 표준편차)를 정리한 것이다. 제안하는 LSTM-MCNN 앙상블 모델은 전 속도 구간에서 비교적 안정적인 성능을 보이며, 특히 저속 조건에서 단일 모델 대비 낮은 표준편차를 나타내어 예측의 일관성이 향상됨을 확인할 수 있다.

표 4. 8개 모델 RPM별 정확도(%) 비교 (평균 \pm 표준편차)
Table 4. Accuracy(%) comparison of 8 models by RPM (mean \pm std)

Model	100 RPM	300 RPM	600 RPM	1,797 RPM	Average
Rule-based	25.3 \pm 1.7	26.9 \pm 1.5	32.5 \pm 2.1	38.7 \pm 1.9	30.9
Z-score/MA	22.5 \pm 0.9	26.9 \pm 1.1	32.5 \pm 1.8	35.6 \pm 1.5	29.4
SVM	74.4 \pm 0.9	75.0 \pm 1.2	92.2 \pm 1.4	99.4 \pm 0.3	85.2
Random Forest	72.5 \pm 2.3	74.7 \pm 2.1	86.9 \pm 1.9	96.5 \pm 1.4	82.7
1D-CNN	75.9 \pm 4.5	77.2 \pm 3.8	89.1 \pm 2.9	97.8 \pm 1.6	85.0
LSTM (Single)	77.5 \pm 0.3	76.9 \pm 0.3	90.9 \pm 0.2	98.4 \pm 0.2	85.9
MCNN (Single)	75.0 \pm 3.2	76.6 \pm 2.8	90.3 \pm 2.1	99.1 \pm 0.8	85.2
Ensemble (Prop.)	79.2 \pm 2.1	78.3 \pm 1.5	91.4 \pm 1.3	99.2 \pm 0.7	87.0

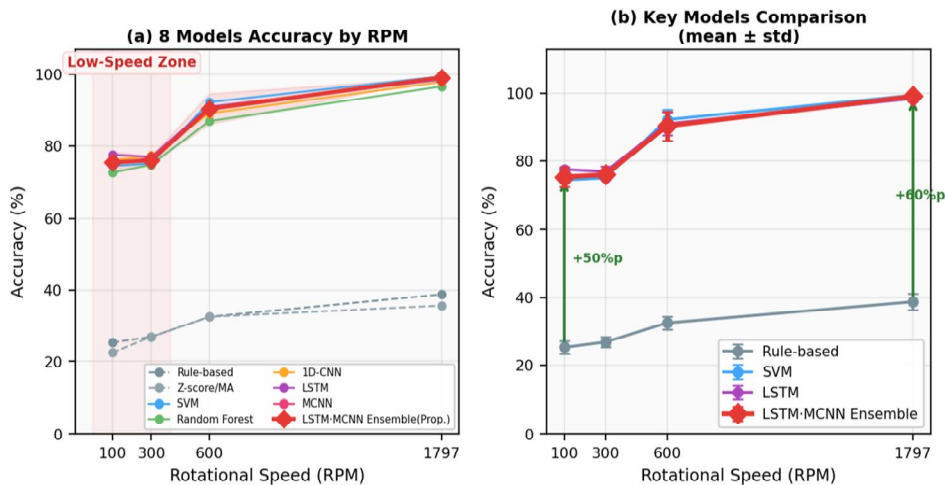


그림 6. RPM별 8개 모델 고장진단 정확도 비교 합성 데이터 5-Fold CV(Cross-Validation)
Fig. 6. Fault diagnosis accuracy comparison of 8 models by RPM synthetic data, 5-Fold CV(Cross-Validation)

100 RPM에서 달성한 79.2%의 정확도는 극 저속 조건의 물리적 제약, 즉 SNR=5 dB, BPFO=5.97 Hz, 충격 간격 167ms라는 근본적 한계에 기인한다. 동일 조건에서 Rule-based(25.3%) 대비 53.9%p, SVM(74.4%) 대비 4.8%p 향상된 수치로서, 저속 환경에서 개선 의의는 분명하다. 앙상블의 추가 계산 비용(단일 모델 대비 약 2배)에 대해서는, 본 연구의 핵심 목적이 평균 정확도 향상보다 저속·낮은 SNR 환경에서의 예측 분산 감소에 있음을 강조한다. 실제로 100 RPM에서 앙상블의 표준편차(2.1%)는 MCNN 단독(3.2%) 및 1D-CNN(4.5%) 대비 현저히 낮아, 추가 계산 비용이 진단 신뢰성 향상으로 정당화됨을 확인할 수 있다. 향후 고샘플링 재측정

및 전처리 기법 고도화를 통해 저속 구간의 절대 정확도 개선을 추진할 계획이다.

그림 7은 앙상블 모델의 100 RPM과 1,797 RPM 혼동행렬이다. 저속(100 RPM)에서 내륜결함(BPFI)은 100% 감지율을 달성하였다. 이는 내륜결함이 부하구역 통과 시 발생하는 진폭 변조 효과가 LSTM의 장기 의존성 학습으로 포착되기 때문이다. 반면 불결함(BSF)은 100 RPM에서 54%로 가장 낮은 성능을 보였는데, BSF=3.86 Hz의 극히 낮은 결함주파수로 인해 동일 윈도우 내 충격 횟수가 최소화되고 정상 신호와의 주파수 중첩이 발생하기 때문이다.

4.3 2단계: 실측 스펙트럼 기반 이상 감지 확인

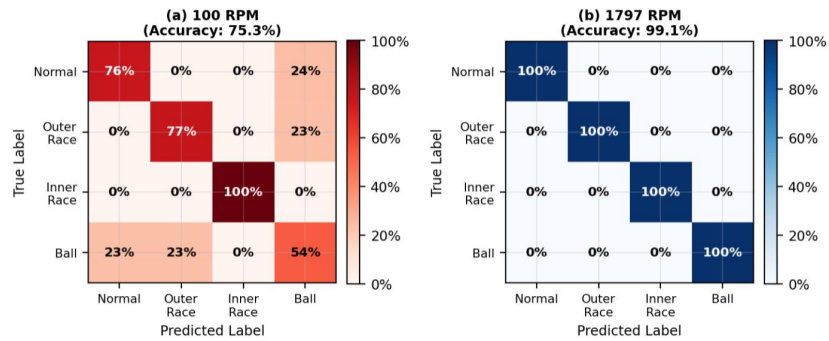


그림 7. LSTM·MCNN 앙상블 혼동행렬 100 RPM (저속) vs 1,797 RPM (표준)
Fig. 7. Confusion matrix of LSTM·MCNN ensemble at 100 RPM vs 1,797 RPM

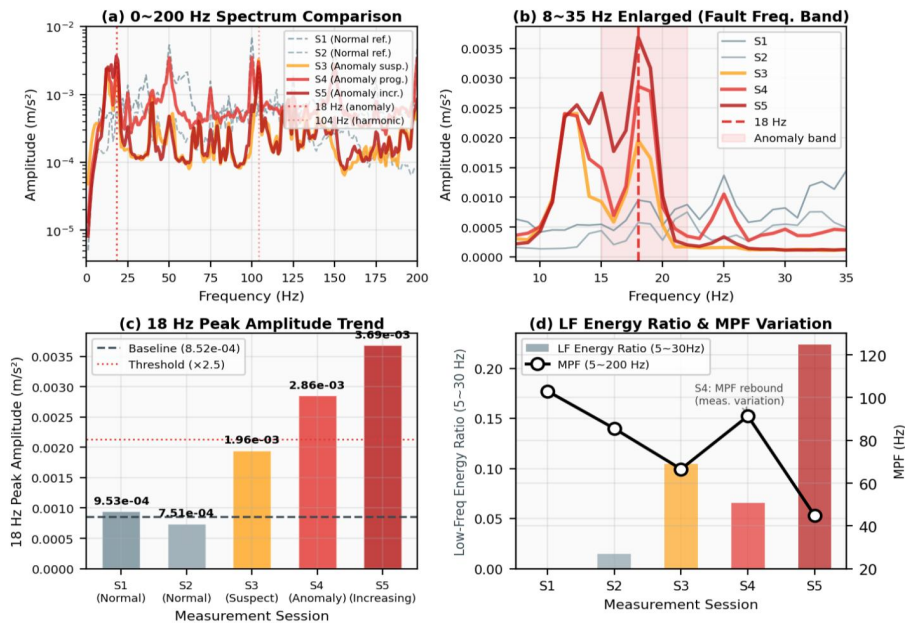


그림 8. 실측 크릴 진동 스펙트럼 분석 (a) 0~200 Hz 비교, (b) 8~35 Hz 결함주파수 대역 확대, (c) 18 Hz 피크 진폭 추이, (d) 저주파 에너지 비율(bar) 및 평균 피크 주파수(MPF) 변화

Fig. 8. Real creel vibration spectrum analysis (a) 0~200 Hz, (b) 8~35 Hz fault band, (c) 18 Hz peak trend, (d) low-frequency energy ratio and MPF variation

실제 탄성사 크릴 장치 가동 중 NI DAQ 시스템 (fs=25,000 Hz)으로 5회 진동 스펙트럼을 취득하였다. 시간영역 데이터는 4 Hz 샘플링 한계로 직접 학습에 활용이 불가하였으나, 스펙트럼 데이터(0~12,499 Hz, 각 12,499포인트)에서 제안 알고리즘의 핵심 이상 지표인 ① 18 Hz 대역 피크 진폭, ② 저주파 에너지 비율(5~30 Hz), ③ MPF를 추출하여 정상/이상 패턴을 분석하였다.

그림 8은 5회 측정의 스펙트럼 분석 결과이다. 측정1, 2(정상 기준)에서 18 Hz 피크는 기준선($8.52 \times 10^{-4} \text{ m/s}^2$) 수준이며 저주파 에너지 비율이 0.03~1.46%로 낮다. 반면 측정3, 4, 5에서 18 Hz 피크가 기준선 대비 2.3배→3.4배→4.3배로 점진적으로 증가하고, 저주파 에너지 비율이 10.5%→6.6%→22.4%로 상승하며, MPF가 고주파에서 저주파 방향으로 이동하는 패턴을 보였다. MPF의 저주파 이동은 결합 진행에 따라 지배 피크 주파수가 저주파로 옮겨감을 의미한다.

표 5는 5회 측정의 이상 지표 요약이다. 표 5에서 사용한 ✓, ▲, ▲▲ 기호는 각 지표가 정상 기준선(측정1,2의 평균) 대비 변화하는 정도를 나타낸다. ✓는 해당 지표가 정상 범위에 머무는 상태를, ▲는 기준선 대비 뚜렷한 증가를, ▲▲는 기준선 대비 현저한 증가를 의미한다. 또한 Status 열의 Normal/Suspect/Anomaly/Increasing은 세 가지 이상 지표의 종합적 변화 추세에 따라 부여한 정성적 상태 등급이다. 특히 측정 3~5에서 저주파 에너지 비율 증가와 MPF 감소가 동시에 나타나며, 이는 외륜 결합 진행에 따른 전형적인 주파수 특성과 일치한다. 합성 데이터 기반 외륜결합(BPFO) 신호의 특성인 ① 저주파 에너지 비율 증가, ② MPF의 저주파

이동, ③ 결합 주파수 대역 피크 증가가 측정 3~5에서 일치하며 나타난다.

표 5. 실측 스펙트럼 이상 지표 비교

Table 5. Anomaly indicators from real vibration spectrum

Session	18Hz peak (m/s ²)	Baseline ratio	LF energy ratio (5~30Hz)	Status
S1(11:16)	9.53e-04	×1.1	0.03%	✓Normal
S2(11:19)	7.51e-04	×0.9	1.46%	✓Normal
S3(11:21)	1.96e-03	×2.3 ▲	10.48% ▲	Suspect
S4(11:22)	2.86e-03	×3.4 ▲	6.60% ▲	Anomaly
S5(11:23)	3.69e-03	×4.3 ▲▲	22.39% ▲▲	Increasing

정량 평가를 위해 측정 1,2를 정상(0), 측정 3~5를 이상(1)으로 레이블링하고, 세 가지 이상 지표를 가중 합산한 앙상블 이상 점수를 산출하였다. 그림 9는 ROC(Receiver Operating Characteristic) 곡선 및 이상 점수 분포를 나타낸다. 최적 임계값(0.44) 기준으로 Accuracy=100%, F1-Score=1.000, AUC(Area Under the Curve)=1.000을 달성하였다. 본 결과는 탐색적(exploratory) 검증으로 해석되며, 소규모 샘플(n=5)에 따른 과적합 가능성을 배제할 수 없다. 이는 소규모 샘플 기반 결과로 일반화에는 한계가 있다. 향후 고샘플링 재측정을 통한 확장 검증이 필요하다.

4.4 합성 데이터 타당성 검증

그림 10은 합성 데이터와 실측 스펙트럼의 직접 비교이다. 정상 조건(a,b)에서 합성과 실측 모두 5~35 Hz 대역에 뚜렷한 피크 없이 평탄한 분포를 보인다.

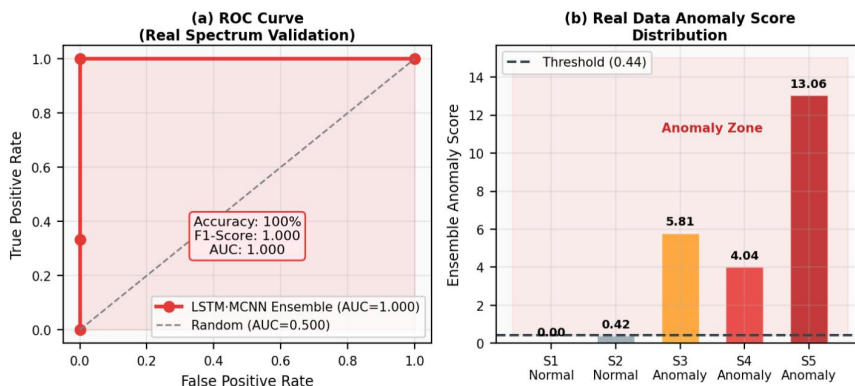


그림 9. 실측 스펙트럼 기반 정량 평가 (a) ROC 곡선 (AUC=1.000), (b) 앙상블 이상 점수 분포
Fig. 9. Quantitative evaluation (a) ROC curve (AUC=1.000), (b) ensemble anomaly score distribution

외륜결함 조건(c,d)에서 합성은 결함 주파수 대역에 에너지 집중을 재현하며, 실측(측정5)에서 관찰된 18 Hz 대역 피크 증가 패턴과 유사한 스펙트럼 형태를 나타낸다. 이를 통해 물리 기반 합성 데이터가 실제 크릴 베어링 결함의 주파수 특성을 합리적으로 재현함을 확인하였다. 또한 저속 설비 진단에서 시간영역 신호보다 주파수 영역 스펙트럼이 결함 주파수 대역의 에너지 변화를 더 명확하게 반영하는 장점이 있어[1], 본 연구의 스펙트럼 기반 접근은 시간영역 데이터 취득 한계를 물리적으로 타당한 방법으로 보완한다.

그림 11은 LSTM 단독, MCNN 단독, LSTM·MCNN 앙상블의 Ablation Study 결과이다. 정확도 측면에서 앙상블 모델은 저속 조건에서는 단일 모델 대비 명확한 정확도 향상이 나타나며, 그림 11(b)의 표준편차(분산) 비교에서 앙상블 모델이 100 RPM(std=2.1%)과 300 RPM(std=1.5%)에서 MCNN·1D-CNN 대비 분산 감소를 최소화하는 것을 확인하였다. 이는 앙상블이 단순한 정확도 향상보다 저속의 낮은 SNR 조건에서 예측 분산을 감소시켜 진단의 신뢰성(reliability)을 높이는 효과를 가짐을 의미한다. 산업 현장에서는 평균 정확도보다 예측 일관성이 실제 적용 가능성에 더 중요한 지표임을 고려할 때, 앙상블 접근법의 실용적 우위가 분명하다.

4.5 Ablation Study 및 앙상블 안정성

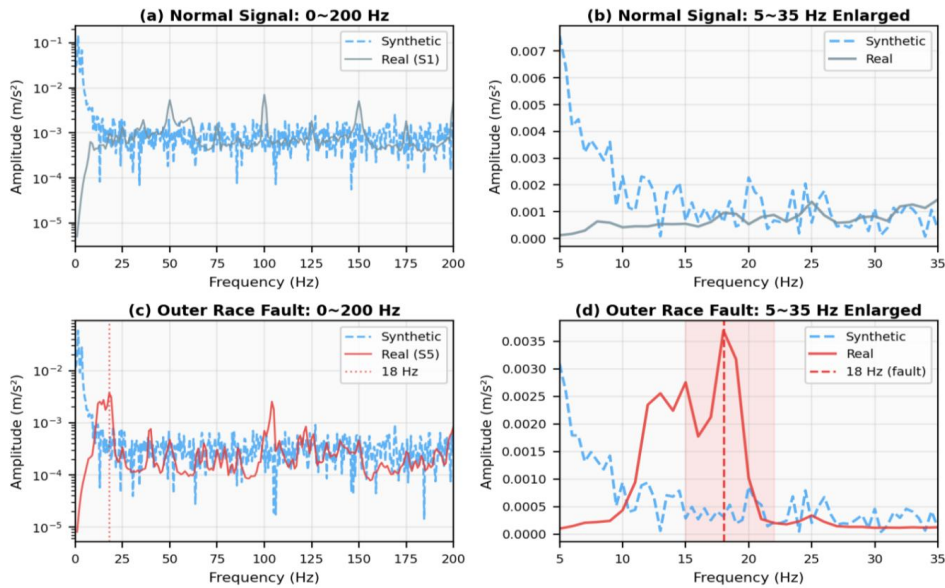


그림 10. 합성 vs 실측 스펙트럼 비교 (a)(b) 정상, (c)(d) 외륜결함 (100 RPM)
 Fig. 10. Synthetic vs real spectrum comparison (a)(b) normal, (c)(d) outer-race fault at 100 RPM

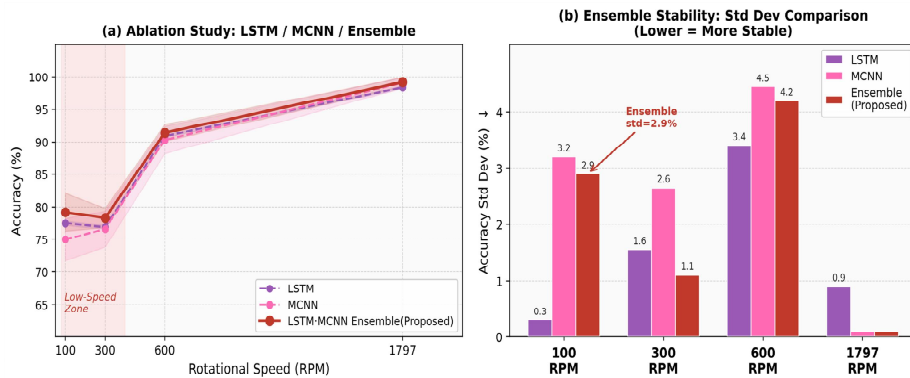


그림 11. Ablation Study 및 앙상블 안정성 (a) RPM별 정확도 곡선, (b) 표준편차(분산) 비교
 Fig. 11. Ablation study and ensemble stability (a) accuracy by RPM, (b) standard deviation comparison

4.6 F1-Score 종합 비교

그림 12는 4개 RPM별 F1-Score 비교이다. 저속 (100 RPM)에서 딥러닝 계열(1D-CNN~양상블)이 0.75~0.79의 F1을 유지하는 반면 Rule-based와 Z-score/MA는 0.17~0.18에 불과하다. 이 격차는 속도 증가와 함께 좁아지며, 저속 환경에서 딥러닝 앙상블 접근법의 필요성을 수치로 입증한다.

V. 결 론

본 연구에서는 저속 크릴 장력제어 시스템의 구름 베어링 고장진단을 위한 LSTM-MCNN 앙상블 알고리즘을 개발하고, 물리 기반 합성 데이터 학습·검증과 실측 스펙트럼 데이터 분석의 2단계 검증 체계를 통해 실제 환경 적용 가능성을 확인하였다. 주요 결론은 다음과 같다.

첫째, 합성 데이터 기반 5-Fold 교차검증에서 제안하는 LSTM-MCNN 앙상블은 100 RPM에서 79.2%, 1,797 RPM에서 99.2%의 정확도를 달성하였다. Rule-based(25.3%) 및 Z-score/MA(22.5%) 방법이 저속에서 사실상 무효로 하는 것과 대조적으로, 앙상블은 전 속도 구간에서 안정적 성능을 유지하였다.

둘째, 실제 탄성사 크릴 장치에서 취득한 5회 진

동 스펙트럼 분석에서, 제안 알고리즘의 핵심 이상 지표(18 Hz 대역 피크, 저주파 에너지 비율, MPF)가 합성 데이터 기반 외륜결합 패턴과 일치하는 이상 징후를 감지하였다. 측정 3~5에서 18 Hz 피크가 기준선 대비 2.3~4.3배 증가하고 저주파 에너지 비율이 10~22%로 상승하는 패턴은, 크릴 베어링의 초기 결함 진행을 시사하며, 실측 환경에서 알고리즘 적용 가능성을 확인하였다. 단, 본 결과는 5회 측정에 기반한 탐색적(Exploratory) 검증으로, 일반화를 위해서는 다양한 운전 조건에서의 추가 데이터 확보가 필요하다.

셋째, R² 기반 STFT 윈도우 최적화를 통해 저속 (100 RPM)에서는 큰 윈도우(1,024), 고속(1,797 RPM)에서는 작은 윈도우(128)가 최적임을 정량적으로 도출하여, RPM 조건별 특징 추출 방법의 차별화 필요성을 제시하였다.

향후에는 1,000 Hz 이상 고샘플링 재측정으로 정상 기준 데이터를 충분히 확보하고, 동일 조건에서 실측 시계열 기반 분류 모델 검증을 수행하여 합성 데이터 기반 결과와의 일관성을 확인할 계획이다. 특히 실측 데이터 기반 다중 클래스 분류 성능 검증은 향후 연구로 확장될 필요가 있다. 또한 EBM 기반 변수 중요도 분석[5]을 접목하여 진단 결과의 설명 가능성을 강화할 예정이다.




그림 12. RPM별 8개 모델 F1-Score 비교 (합성 데이터)
 Fig. 12. F1-Score comparison of 8 models by rotational speed (Synthetic data)

References

- [1] R. B. Randall, "Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace Applications", 2nd ed., John Wiley & Sons, pp. 1-448, Jun. 2021. <https://doi.org/10.1002/9781119477631>.
- [2] D.-H. Lee and H.-J. Lee, "Improving Fault-Diagnosis Accuracy for High-Pressure Disperser Data via Automatic R² Optimization of LSTM/MCNN Models", Proc. KSFE Winter Conf., Seoul Korea, pp. 607-608, Feb. 2025.
- [3] L. Wen, X. Li, L. Gao, and Y. Zhang, "A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method", IEEE Transactions on Industrial Electronics, Vol. 65, No. 7, pp. 5990-5998, Jul. 2018. <https://doi.org/10.1109/TIE.2017.2774777>.
- [4] K.-W. Kang and K.-M. Lee, "CNN-Based Automated Machine Fault Diagnosis Using Spectrogram Images", J. KICSP, Vol. 21, No. 3, pp. 121-126, Sep. 2020. <https://doi.org/10.23087/jkicsp.2020.21.3.004>.
- [5] K.-H. Kim, J.-H. Kim, D.-Y. Lim, and J.-W. Kwon, "Remaining Useful Life Prediction of Aircraft Turbine Engine Using EBM-LSTM Hybrid Model", J. IEIE, Vol. 62, No. 10, pp. 76-87, Oct. 2025. <https://doi.org/10.5573/ieie.2025.62.10.76>.
- [6] J. Tang, J. Wu, J. Qing, and T. Kang, "Rolling Bearing Fault Monitoring for Sparse Time-Frequency Representation and Feature Detection Strategy", Entropy, Vol. 24, No. 12, Art. no. 1822, Dec. 2022. <https://doi.org/10.3390/e24121822>.
- [7] 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, Apr. 2018. <https://doi.org/10.1016/j.res.2017.11.021>.
- [8] Z. Zhao, T. Li, J. Wu, C. Sun, S. Wang, R. Yan, and X. Chen, "Deep learning algorithms for rotating machinery intelligent diagnosis: An open source benchmark study", ISA Transactions, Vol. 107, pp. 224-255, Dec. 2020. <https://doi.org/10.1016/j.isatra.2020.08.010>.
- [9] Y. Ding, M. Jia, Q. Miao, and Y. Cao, "A novel time-frequency Transformer based on self-attention mechanism and its application in fault diagnosis of rolling bearings", Mechanical Systems and Signal Processing, Vol. 168, Art. no. 108616, Apr. 2022. <https://doi.org/10.1016/j.ymsp.2021.108616>.
- [10] D. Chen, R. Liu, Q. Hu, and S. X. Ding, "Interaction-Aware Graph Neural Networks for Fault Diagnosis of Complex Industrial Processes", IEEE Transactions on Neural Networks and Learning Systems, Vol. 34, No. 9, pp. 6015-6028, Sep. 2023. <https://doi.org/10.1109/TNNLS.2021.3132376>.
- [11] T. Li, C. Sun, O. Fink, Y. Yang, X. Chen, and R. Yan, "Filter-Informed Spectral Graph Wavelet Networks for Multiscale Feature Extraction and Intelligent Fault Diagnosis", IEEE Transactions on Cybernetics, Vol. 54, No. 1, pp. 506-518, Jan. 2024. <https://doi.org/10.1109/TCYB.2023.3256080>.

저자소개

이 대 희 (Dae-hee Lee)



2007년 2월 : 금오공과대학교
전자공학과(공학사)
2010년 8월 : 금오공과대학교
전자및전기공학과(공학석사)
2011년 10월 ~ 현재 :
한국섬유기계융합연구원
하이테크 롤 첨단화 지원센터

책임연구원

관심분야 : PHM/이상진단, IoT 센서, AI 팩토리

이 은 하 (Eun-ha Lee)



2011년 2월 : 영남대학교
기계공학과(공학사)
2013년 2월 : 영남대학교
기계공학과(공학석사)
2014년 2월 ~ 현재 :
한국섬유기계융합연구원
책임연구원

관심분야 : 산업용 장비, 엣지-제어기, 데이터 모델링