

Self-Attention 기반 Transformer 모델을 활용한 반도체 제조 장비 고장 예측 연구

안근진¹, 박승범², 배병성³, 김영진⁴

¹충남지역지능화센터 연구교수

²호서대학교 기술경영전문대학원 교수

³호서대학교 반도체공학과 교수

⁴호서대학교 반도체공학과 학부생

akj2995@daum.net, parksb@hoseo.edu, bsb3@hoseo.edu, kevin8445@naver.com

Failure Prediction of Semiconductor Manufacturing Equipment Using a Self-Attention-Based Transformer Model

Guen Jin Ahn¹, Sungbum Park², Byung Seong Bae³, Young Jin Kim⁴

¹Chungnam Intelligence Innoovation Center Research Professor.

²Graduate School of Management of Technology, Hoseo University

³Dept. of Semiconductor Engineering, Hoseo University

⁴Dept. of Semiconductor Engineering, Hoseo University

요 약

반도체 제조 장비는 화재, 부품 결함, 노후화 등의 다양한 요인으로 인해 예상치 못하게 가동이 중단되거나 정상적인 운용이 어려운 상황이 자주 발생한다. 이러한 장비의 고장은 반도체 생산 공정 전체를 중단시키며, 이에 따라 기업의 생산 효율 저하 및 원가 상승을 초래한다. 본 연구에서는 장비에 부착된 온도, 진동, 전력 센서로부터 수집된 시계열 데이터를 활용하여, Self-Attention 기반 Transformer 모델을 통해 반도체 제조 장비의 고장을 사전에 예측하고자 하였다. 제안하는 모델은 시계열 내 장기 의존성(Long-Term Dependency)을 효과적으로 학습함으로써, 기존 Auto-Encoder 기반 예측 모델 대비 정확도 향상을 목표로 한다.

1. 서론

반도체 제조 장비는 웨이퍼 가공, 패키징, 테스트 등 반도체 생산 공정 전반에서 필수적인 역할을 수행하는 핵심 설비이다. 이러한 장비가 예기치 않게 가동을 중단하게 되면 생산 차질 및 초과 비용이 발생하며, 이는 기업의 수익성과 생산 효율성에 큰 영향을 미친다. 따라서 반도체 장비의 고장을 사전에 예측하고, 잠재적 고장 원인을 조기에 식별하여 설비의 가용성을 극대화하는 것이 매우 중요하다.

장비 고장은 온도 상승, 화재, 전력 이상 등 외부 환경적 요인뿐만 아니라, 부품의 마모나 결함과 같은 내부 구조적 문제에서도 기인할 수 있다. 더불어 이 두 가지 원인이 복합적으로 작용하는 경우도 많아, 고장 원인의 다변성과 상호작용성을 함께 고려한 분석이 요구된다.

본 연구에서는 반도체 장비에 부착된 다중 센서(온도, 진동, 전력 등)에서 실시간으로 수집되는 시계열 데이터를 활용하여, Self-Attention 기반 Transformer 모델을 통해 고장을 사전에 예측하고자 한다. Transformer 모델은 시계열 내의 장기적인 의존성과 센서 간 상호 연관성을 효과적으로 학습할 수 있는 구조를 가지며, 특히 Self-Attention 메커니즘은 특정 시점의 입력 데이터 간 관계를 정밀하게 반영하는 데 강점을 가진다.

고장 예측 정확도를 높이기 위해 본 연구는 다음과 같은 과정을 통해 모델을 구성한다: (1) 센서 데이터 수집, (2) 시간 동기화 및 표준화 전처리, (3) 시간 도메인 및 주파수 도메인(Fast Fourier Transform 기반)으로의 데이터 변환, (4) Transformer 기반 딥러닝 모델 학습, (5) 예측 정확도 평가 및 기존 Auto-Encoder, LSTM 등의 모델과의 비교 분석.

본 논문은 Self-Attention 기반 시계열 분석을 반도체 장비 고장 예측에 적용함으로써, 기존 기법 대비 장비 고장의 사전 탐지 성능을 향상시키고, 설비 운영의 안정성과 효율성을 높이기 위한 새로운 접근을 제시한다.

2. 연구내용

그림 1과 같이 펌프 장비에 진동 센서를 부착하고, 이를 통해 발생하는 신호를 수집하여 저장한 후 분석에 활용하였다. 본 연구에서는 주요 센서로 진동 센서 외에도 전류 센서와 온도 센서를 함께 사용하였으며, 이들은 장비 운전 중 발생하는 물리적 이상 신호를 감지하는 데 효과적으로 작용한다. 이와 같은 센서 데이터를 기반으로 장비의 고장을 사전에 식별할 수 있는 가능성을 검토하였다.



그림 1. 진동 센서 및 온도센서의 부착

데이터는 실시간으로 게이트웨이 장치를 통해 수집되었으며, 시간 단위로 정렬 및 표준화 과정을 거쳐 학습이 가능한 형태로 변환되었다. 또한, 데이터의

Feature name	Function symbol	Feature name	Function symbol
Mean	$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$	Skewness	$\frac{N}{(N-1)(N-2)^2} \sum_{i=1}^N (x_i - \bar{x})^3$
Max	$\max(x_i)$	Standard Deviation	$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N-1}}$
Peak	$P_m = \max(x_i)$	Power	$\sum_{i=1}^N x_i^2$
Peak to Peak	$P_t = \max(x_i) - \min(x_i)$	Mean of band Power Spectrum	$S_\mu = \frac{1}{n} \sum_{i=1}^n S(f)_i$
RMS	$\sqrt{\frac{\sum_{i=1}^N x_i^2}{N}}$	Max of band power spectrum	$S_{MAX} = \max(S(f)_i)$
Variance	$\sum_{i=1}^N (x_i - \bar{x})^2$	Sum of total band Power	$S_{SBP} = \sum_{i=1}^n S(f)_i$
Crest Factor	$\frac{P_m}{RMS}$	Variance of band power	$S_V = \frac{\sum_{i=1}^n (S(f)_i - S_\mu)^2}{n-1}$
Pulse Indicator	$\frac{P_m}{\bar{x}}$	Skewness of band power	$S_K = \frac{1}{n} \sum_{i=1}^n \frac{(S(f)_i - S_\mu)^3}{S_V^{3/2}}$
Margin	$ \frac{\sum_{i=1}^N x_i}{N} $	Kurtosis of band power	$S_K = \frac{1}{n} \sum_{i=1}^n \frac{(S(f)_i - S_\mu)^4}{S_V^2}$
Kurtosis	$\frac{1}{N} \sum_{i=1}^N (x_i^4)$		

표 1. 19개 Feature Function.

양을 줄이고 특징 추출을 용이하게 하기 위해 13개의 시간 영역 통계 함수(Feature Function)를 정의

하였으며, 이에 대한 항목은 표 1과 같다. 각 항목은 평균, 표준편차, 최대값, RMS 등 대표적인 통계적 지표로 구성되어 있으며, 센서 데이터의 전반적인 특성을 반영할 수 있도록 구성되었다. 뿐만 아니라, 시간 영역에서 얻은 통계 지표 외에도 주파수 영역 특성을 파악하기 위해 FFT(Fast Fourier Transform)를 적용하였으며, 이를 통해 장비 상태 변화를 더욱 정밀하게 분석할 수 있도록 하였다. 그림 2는 추출된 19개 Feature 간의 상관관계를 히트맵으로 시각화한 결과이며, 각 변수 간 연관성이 높은 부분에 대한 해석이 가능하다.

고장 예측 정확도를 높이기 위해 데이터셋은 고장 발생 시간 전 구간을 기준으로 1시간 전, 2시간 전, 3시간 전 등 여러 구간으로 나누어 구성하였다. 각

	MIN	MAX	MEAN	RMS	VAR	STD	POWER	PEAK	P2P	CREST FACTOR	SKW	KURTOSIS	MAX_F	SUM_F	MEAN_F	VAR_F	PEAK_F	SKW_F	KURTOSIS_F	Index
MIN	1.00	-0.22	0.29	0.19	0.45	-0.52	0.17	-0.22	-0.53	-0.51	-0.04	0.13	-0.15	0.17	0.24	-0.28	-0.15	0.04	0.13	-0.28
MAX	-0.22	1.00	0.60	0.77	0.82	0.81	0.77	1.00	0.94	0.79	0.25	0.16	0.82	0.78	0.57	0.74	0.82	0.25	0.16	0.81
MEAN	0.29	0.60	1.00	0.99	0.47	0.41	0.96	0.69	0.59	0.13	-0.22	0.25	0.72	0.68	0.88	0.58	0.72	-0.22	0.25	0.27
RMS	0.19	0.77	0.99	1.00	0.60	0.55	1.00	0.77	0.81	0.23	-0.17	0.21	0.81	1.00	0.87	0.87	0.78	-0.17	0.21	0.34
VAR	0.45	0.82	0.47	0.60	1.00	0.88	0.61	0.82	0.88	0.85	0.15	-0.17	0.72	0.61	0.41	0.82	0.72	0.15	-0.17	0.50
STD	-0.52	0.81	0.44	0.56	0.98	1.00	0.55	0.81	0.88	0.71	-0.20	0.20	0.71	0.58	0.37	0.80	0.71	0.17	-0.20	0.49
POWER	0.17	0.77	0.96	1.00	0.61	0.53	1.00	0.77	0.81	0.24	-0.17	0.20	0.79	1.00	0.88	0.69	0.79	-0.17	0.20	0.35
PEAK	-0.22	1.00	0.69	0.77	0.82	0.81	0.77	1.00	0.94	0.79	0.25	0.16	0.82	0.78	0.57	0.74	0.82	0.25	0.16	0.81
P2P	-0.53	0.94	0.59	0.61	0.88	0.88	0.61	0.94	1.00	0.89	0.23	0.09	0.85	0.61	0.42	0.73	0.85	0.23	0.09	0.83
CREST FACTOR	-0.51	0.79	0.13	0.23	0.68	0.71	0.24	0.79	0.86	1.00	0.55	0.05	0.65	0.24	0.19	0.48	0.55	0.56	0.06	0.82
SKW	-0.04	0.25	-0.22	-0.17	0.15	0.17	-0.17	0.25	0.23	0.55	1.00	-0.27	0.18	-0.17	-0.22	0.07	0.18	1.00	-0.27	0.29
KURTOSIS	0.13	0.16	0.25	0.21	0.17	-0.28	0.20	0.16	0.09	-0.05	-0.27	1.00	0.22	0.20	0.27	-0.85	0.22	-0.27	1.00	0.16
MAX_F	-0.15	0.82	0.72	0.78	0.72	0.71	0.75	0.82	0.85	0.85	0.18	0.22	1.00	0.78	0.78	0.85	1.00	0.18	0.22	0.60
SUM_F	0.17	0.77	0.98	1.00	0.61	0.55	1.00	0.77	0.81	0.24	-0.17	0.20	0.79	1.00	0.88	0.69	0.79	-0.17	0.20	0.35
MEAN_F	0.24	0.57	0.88	0.87	0.41	0.37	0.88	0.57	0.42	0.06	-0.22	0.27	0.76	0.88	1.00	0.69	0.76	-0.22	0.27	0.29
VAR_F	-0.28	0.74	0.58	0.67	0.82	0.80	0.69	0.74	0.73	0.48	0.07	-0.05	0.85	0.69	0.89	1.00	0.85	0.07	-0.05	0.50
PEAK_F	-0.15	0.82	0.72	0.78	0.72	0.71	0.75	0.82	0.85	0.85	0.18	0.22	1.00	0.78	0.78	0.85	1.00	0.18	0.22	0.60
SKW_F	0.04	0.25	-0.22	-0.17	0.15	0.17	-0.17	0.25	0.23	0.55	1.00	-0.27	0.18	-0.17	-0.22	0.07	0.18	1.00	-0.27	0.29
KURTOSIS_F	0.13	0.16	0.25	0.21	0.17	-0.28	0.20	0.16	0.09	-0.05	-0.27	1.00	0.22	0.20	0.27	-0.85	0.22	-0.27	1.00	0.16
Index	0.78	0.81	0.27	0.34	0.50	0.49	0.35	0.81	0.53	0.82	0.29	0.18	0.60	0.35	0.29	0.50	0.80	0.29	0.18	0.10

그림 2. 19개 항목간 상관관계 구간은 고장이 발생하기 이전의 데이터를 기반으로 학습되었으며, 학습된 모델은 실시간 데이터를 입력 받아 사전 이상 징후를 탐지하는 방식으로 설계되었다. 또한, 수집된 데이터를 실시간으로 확인하고 분석할 수 있도록 그림 3과 같은 웹 기반 모니터링 시스템을 구축하였다.

학습에는 XGBoost, Random Forest, DNN, RNN AutoEncoder, Transformer 기반 모델 등을 사용하

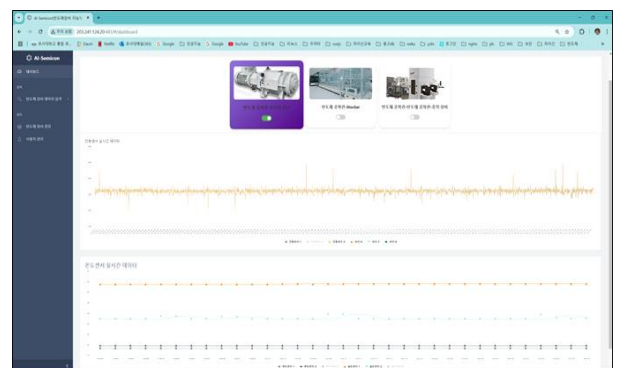


그림 3.반도체 장비 센서 데이터 모니터링 시스템

였으며, 이들 모델 간의 예측 정확도를 비교 분석하였다. 모델 학습에는 시간 및 주파수 도메인으로 변환된 데이터를 활용하였으며, 모델별 정확도 비교 결과는 그림 4 와 같다

3. 요약 및 향후 연구

본 연구에서 비교한 여섯 개의 예측 모델 중, Self-Attention 기반 Transformer 모델은 고장 발생 1시간 전의 데이터를 기준으로 학습한 결과, 테스트

Table 1. Average Accuracy of Anomaly Detection prediction Model (6 model)				
feature 19 dataset	반도체 제조장비 A			
	온도, 진동, 전력 ALL	온도, 진동 전력 (-1시간전)	온도, 진동 전력 (-2시간전)	온도, 진동 전력 (-3시간전)
RandomForest	0.8220	0.9140	0.9070	0.9040
xgboosting	0.8888	0.9214	0.9298	0.8888
DNN	0.8700	0.9167	0.9060	0.8900
RNN	0.8500	0.9367	0.9230	0.9000
Auto-Encoder	0.9200	0.9500	0.9300	0.9120
Transformer	0.9100	0.9600	0.9400	0.9430

그림 4. 6개 모델에 대한 정확도 평가표
데이터에서 가장 높은 고장 예측 정확도(Accuracy: 0.96)를 나타냈다. Transformer 모델은 시계열 데이터의 장기 의존성(Long-Term Dependency)을 효과적으로 학습할 수 있으며, Self-Attention 메커니즘을 통해 각 시점 간의 관계를 정밀하게 반영하는 데 강점을 가진다. 특히, 센서 간의 상호 연관성까지 동시에 고려할 수 있어, 시간 축에서의 정보뿐 아니라 다채널 센서 데이터의 복합 패턴 분석에도 적합하다.

일반적으로 Auto-Encoder와 같은 모델은 입력 데이터의 압축 및 재구성에 중점을 두고 있어, RNN이나 LSTM과 같은 순환 구조를 가지지 않는 이상 시계열상의 시간 종속성(Time Dependency)을 충분히 반영하지 못하는 단점이 존재한다. 이를 보완하기 위해 일부 실험에서는 LSTM-AutoEncoder 구조도 활용되었으나, 본 연구의 실험 결과는 Transformer 기반의 Self-Attention 구조가 이러한 시간 종속성과 다변량 센서 데이터의 복합성에 보다 효과적으로 대응할 수 있음을 입증하였다.

실험을 통해, 반도체 장비에 부착된 온도, 진동, 전력 센서로부터 수집된 데이터를 Transformer 모델에 입력하여 고장 발생 1시간 전에 이상 징후를 사전에 탐지할 수 있음을 확인하였다. 이러한 예측 시스템은 실제 반도체 제조 현장에서 운영 담당자에게 조기 경고 알람을 제공함으로써, 장비의 갑작스러운 정지를 방지하고 생산 손실을 최소화하는 데 크게 기여할 수 있다.

다만, 본 연구는 특정 모델 장비를 대상으로 실험

을 수행한 결과로, 모든 반도체 장비에 일반화하여 적용하기에는 제한점이 존재한다. 따라서 향후에는 다양한 종류의 반도체 장비와 센서 구성에 대한 고장 예측 성능을 비교 분석하여, 보다 범용적인 고장 예측 모델로 확장할 필요가 있다.

사 사

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-지역지능화혁신인재양성사업의 지원을 받아 수행된 연구임

(IITP-2025-RS-2024-00436765)

his 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-2024-00436765)

참고문헌

- [1] Lee, J., Qiu, H., Yu, G., Lin, J. (2007) Rexnord :Technical Services, ‘Bearing Data Set’, IMS, University of Cincinnati, NASA Ames Prognostics Data Repository.
- [2] Park, S., Kim, J.W., Lee, C., Lee, J., Gil, H.B. (2012) Local Fault Detection Technique for Steel Cable using Multi-Channel Magnetic Flux Leakage Sensor, J. Comput. Struct. Eng. Inst. Korea, 25(4), pp.287~292.
- [3] Yun, J., Yun, H. W., Kim, Y. J., Lee, J. H., Ahn, G. J., Park, S., & Bae, B. S. (2024). Research on Semiconductor Equipment Failure Prediction Based on Auto-Encoder Model. Annual Conference of KIPS, 435 - 437. <https://doi.org/10.3745/PKIPS.Y2024M10A.435>
- [4]Wang, R., Dong, E., Cheng, Z., Liu, Z. & Jia, X. (2024). Transformer-based intelligent fault diagnosis methods of mechanical equipment: A survey. Open Physics, 22(1), 20240015. <https://doi.org/10.1515/phys-2024-0015>