



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

선박 및 해양플랫폼 에너지 시스템의  
이상 탐지 모델 성능 향상을 위한  
다변량 시계열 데이터 합성 및 검증

Multivariate Time Series Augmentation for  
Improving the Performance of Anomaly  
Detection in Energy System of Ships and  
Offshore Platforms

2023년 2월

서울대학교 대학원

조선해양공학과

장진관

선박 및 해양플랫폼 에너지 시스템의  
이상 탐지 모델 성능 향상을 위한  
다변량 시계열 데이터 합성 및 검증

지도교수 서 유 택

이 논문을 공학석사 학위논문으로 제출함  
2022년 12월

서울대학교 대학원  
조선해양공학과  
장 진 관

장진관의 공학석사 학위논문을 인준함  
2022년 12월

위 원 장 \_\_\_\_\_ 임 영 섭 (인)

부위원장 \_\_\_\_\_ 서 유 택 (인)

위 원 \_\_\_\_\_ 강 상 규 (인)

# 초 록

최근 국제 해운 분야의 환경 규제와 Digital Twin 기술의 발전으로 선박 및 해양플랫폼의 실시간 모니터링이 점차 확산되고 있다. 그리고 이상 상태가 누적되어 사고가 났을 때 막대한 피해가 발생할 수 있는 선박이나 해양플랫폼에서는 실시간 모니터링 중 특히 센서 데이터를 기반으로 하는 시계열 이상 탐지가 매우 중요한 기술이다. 하지만 고차원이면서 시간 종속성이 있는 다변량 시계열 데이터의 특성상 예측 및 이상 탐지가 쉽지 않기 때문에 딥러닝 기술을 활용해야 한다. 딥러닝 연구가 활발히 진행되면서 다변량 시계열 이상 탐지의 정확성이 크게 향상되었지만 딥러닝 모델의 구조가 더욱 복잡해지면서 모델의 capacity가 증가해 학습 데이터가 충분해야만 안정적으로 최고의 성능을 보인다는 문제점이 있다.

학습 목적의 실제 데이터를 더 취득할 수 없는 상황에서 그 대안으로 데이터 합성 및 증강 기법을 활용할 수 있다. 다만 다변량 시계열인 학습 데이터를 충분히 확보하기 위해 전통적인 시계열 데이터 합성 방법론인 random transformation이나 pattern mixing을 활용한다면 시간 종속성이 제대로 반영되지 않고 실제 데이터의 분포와 확연히 다른 데이터가 합성되어 증강된 학습 데이터의 품질이 떨어지게 된다. 결과적으로 오히려 딥러닝 모델의 성능을 악화시킬 수 있다. 따라서 실제 시계열의 분포와 매우 유사하고 시간 종속성과 변수 간의 관계도 모두 반영된 좋은 품질의 합성 시계열 센서 데이터를 생성할 수

있는 방법론을 활용해 접근해야 한다.

본 연구에서는 선박 및 해양플랫폼의 대표적인 에너지 시스템 중 하나인 open loop 유형의 SOx scrubber가 탑재되어 있는 디젤 엔진 선박의 에너지 시스템을 대상으로 이상 탐지를 수행한다. 선정된 에너지 시스템은 직관적이고 사후 분석이 용이하다는 장점이 있다. 보안 등의 이유로 접근 가능한 학습 데이터가 부족하거나 새로 건조되어 다양한 상황에 대한 학습 데이터 자체가 부족하다는 점을 고려해 학습 데이터를 합성 및 증강해야 할 것이다.

우선 본 연구에서 활용하려고 하는 GAN 기반 generative model인 TimeGAN이 다변량 시계열 합성에 있어 가장 적절한 모델인지 확인한다. 차원 축소를 활용한 데이터 분포 시각화와 두 가지 정량적 지표를 통해 전통적인 시계열 합성 방법론들과 비교하여 TimeGAN이 다변량 시계열 이상 탐지를 위해 실제와 매우 유사한 데이터를 합성할 수 있는 적절한 모델임을 확인하고 좋은 품질의 다변량 시계열 데이터를 합성해 학습 데이터를 증강한다.

이후 충분히 증강된 학습 데이터를 바탕으로 현재 이상 탐지 성능이 가장 좋은 Transformer 기반 다변량 시계열 이상 탐지 모델인 TranAD에 적용하여 기존의 데이터만 활용해 학습했을 때보다 안정적인 예측과 더 정확한 이상 탐지 성능을 보여주는지 검증한다.

**주요어** : 선박 및 해양플랫폼, 에너지 시스템, 실시간 모니터링, 다변량 시계열 합성 및 증강, 다변량 시계열 이상 탐지, 성능 향상  
**학 번** : 2021-25813

# 목 차

제 1 장 서론 .....	1
제 1 절 연구 배경 .....	1
제 2 절 기존 연구 .....	5
제 3 절 연구 목적 .....	11
제 2 장 배경 이론 및 연구 프레임워크 .....	13
제 1 절 다변량 시계열 데이터 합성 모델 - TimeGAN .....	13
제 2 절 다변량 시계열 이상 탐지 모델 - TranAD .....	17
제 3 절 연구 프레임워크 .....	20
제 3 장 Dataset .....	21
제 1 절 SOx Scrubber가 설치된 벌크선 운항 데이터셋 .....	21
제 1 항 Main Engine (M/E)의 Load .....	23
제 2 항 M/E Cylinder의 배출 가스 온도 .....	23
제 3 항 M/E Cylinder 전체의 평균 지시 압력 .....	24
제 4 항 Auxiliary Boiler의 Steam 압력 .....	25
제 5 항 SOx Scrubber의 SO <sub>2</sub> / CO <sub>2</sub> 비율 .....	26
제 4 장 결과 및 분석 .....	27
제 1 절 TimeGAN을 활용한 센서 데이터 합성 결과 .....	27
제 1 항 데이터 시각화 .....	28
제 2 항 합성 데이터 품질에 대한 정량적 지표 비교 .....	30
제 2 절 학습 데이터 증강 유무에 따른 이상 탐지 결과 .....	32
제 1 항 M/E의 Load 이상 탐지 결과 .....	33
제 2 항 M/E Cylinder의 배출 가스 온도 이상 탐지 결과 .....	35
제 3 항 M/E Cylinder 전체의 평균 지시 압력 이상 탐지 결과 .....	37
제 4 항 Auxiliary Boiler의 Steam 압력 이상 탐지 결과 .....	39
제 5 항 SOx Scrubber의 SO <sub>2</sub> / CO <sub>2</sub> 비율 이상 탐지 결과 .....	41
제 5 장 요약 및 결론 .....	44
제 1 절 TimeGAN을 활용한 좋은 품질의 다변량 시계열 합성 .....	44
제 2 절 선박 시스템 이상 탐지에서 학습 데이터 증강 효과 검증 .....	44
제 3 절 결론 .....	45
제 4 절 추후 연구 .....	46
참고문헌 .....	47
Abstract .....	49

## 표 목차

[표 1] 다변량 시계열 합성 기법을 응용한 선행 연구 목록 ....	10
[표 2] 선박 내 에너지 시스템의 주요 변수 목록 .....	22
[표 3] TimeGAN의 hyperparameter와 training settings ....	27
[표 4] TranAD의 hyperparameter와 training settings .....	32
[표 5] 이상 탐지 결과 (M/E Load) .....	34
[표 6] 이상 탐지 결과 (CYL EXH GAS Temp.) .....	36
[표 7] 이상 탐지 결과 (CYL AVG IND Press.) .....	38
[표 8] 이상 탐지 결과 (BLR Steam Press.) .....	40
[표 9] 이상 탐지 결과 (SO <sub>2</sub> /CO <sub>2</sub> Ratio) .....	43
[표 10] 데이터 증강 유무에 따른 이상 탐지 종합 결과 .....	45

## 그림 목차

[그림 1] 선박 센서 데이터 기반 모니터링 예시 .....	2
[그림 2] 선박 Main Engine, Generator의 연료 공급 시스템... 3	3
[그림 3] 선박 센서 데이터 기반 연료 공급 시스템 모사 모델. 3	3
[그림 4] 컴퓨터 비전 분야의 대표적인 데이터 증강 기법들 ....	5
[그림 5] 자연어 처리 분야의 Masked Language Modeling ....	5
[그림 6] 시계열 데이터 합성 및 증강 기법의 분류 .....	7
[그림 7] Random transformation 기반 시계열 변형 예시 .....	8
[그림 8] TimeGAN의 구조와 주요 구성 요소 .....	14
[그림 9] TranAD 모델의 구조 .....	17
[그림 10] SWaT에 대한 시계열 이상 탐지 모델 성능 비교... 18	18
[그림 11] TranAD를 활용한 시계열 이상 탐지 결과 예시 ....	19
[그림 12] 합성 및 증강을 활용한 에너지 시스템 이상 탐지.. 20	20
[그림 13] 정속 운항 중 일정하게 유지되는 M/E의 Load.....	23
[그림 14] 적당한 온도가 유지되는 M/E Cylinder 배출 가스. 24	24
[그림 15] 일정 범위 내 M/E Cylinder 전체 평균 지시 압력. 25	25
[그림 16] 보일러 가동 없이 유지되고 있는 steam 압력 .....	25
[그림 17] 자체 제어로 유지되는 Scrubber SO <sub>2</sub> /CO <sub>2</sub> 비율... 26	26
[그림 18] 실제 센서 데이터와 합성 데이터(TimeGAN) .....	28

[그림 19]	합성 데이터(TimeGAN)의 PCA, t-SNE 결과	..... 29
[그림 20]	합성 데이터(Time Warping)의 PCA, t-SNE 결과	29
[그림 21]	합성 데이터의 Discriminative Score 비교	..... 30
[그림 22]	합성 데이터의 Predictive Score 비교	..... 31
[그림 23]	TranAD base case(M/E Load)	..... 33
[그림 24]	학습 데이터 증강 결과(M/E Load)	..... 34
[그림 25]	TranAD base case(CYL EXH GAS Temp.)	..... 35
[그림 26]	학습 데이터 증강 결과(CYL EXH GAS Temp.)	... 36
[그림 27]	TranAD base case(CYL AVG IND Press.)	..... 37
[그림 28]	학습 데이터 증강 결과(CYL AVG IND Press.)	.... 38
[그림 29]	TranAD base case(BLR Steam Press.)	..... 39
[그림 30]	학습 데이터 증강 결과(BLR Steam Press.)	..... 40
[그림 31]	TranAD base case(SO <sub>2</sub> /CO <sub>2</sub> Ratio)	..... 42
[그림 32]	학습 데이터 증강 결과(SO <sub>2</sub> /CO <sub>2</sub> Ratio)	..... 43



# 제 1 장 서론

## 제 1 절 연구 배경

기후 변화 대응을 위해 온실가스 감축이 필요하다는 공감대를 기반으로 2015년에 파리기후협약이 채택되었다. 이후 160여개 참가국들은 본격적으로 자체적인 온실가스 감축 목표와 구체적인 실행 계획을 발표하였다. 글로벌 탄소 배출량의 3% 정도를 차지하고 있는 해운 분야에서도 탈탄소화 움직임이 나타나고 있다. 우선 선박의 온실가스 배출에 대한 모니터링을 위해 유럽연합(EU)의 Measurement, Reporting and Verification(MRV)과 국제해사기구(IMO)의 Data Collection System(DCS) 규정이 각각 2019년, 2020년에 시행되었다. 또한 온실가스 배출량 측정뿐만 아니라 Digital Twin의 주요 목적인 에너지 시스템의 효율 향상 및 이상 상황 발생 시 빠른 제어와 유지보수를 위해서도 실시간 센서 데이터 기반 모니터링은 필요하다. 위성통신, edge device 등을 활용하는 디지털화를 통해 선박 내 에너지 시스템의 센서 데이터를 기반으로 하는 실시간 모니터링이 점차 확산될 것이다. 해양플랫폼을 활용하는 석유 및 천연가스 개발 분야의 경우, 해운 분야보다 앞서 자동화 및 효율화 그리고 탈탄소화를 위해 센서 데이터 기반 실시간 모니터링 시스템을 적극적으로 구축하고 있으며 공정 관련 이상 탐지 및 예지 보전 연구도 수행하고 있다.

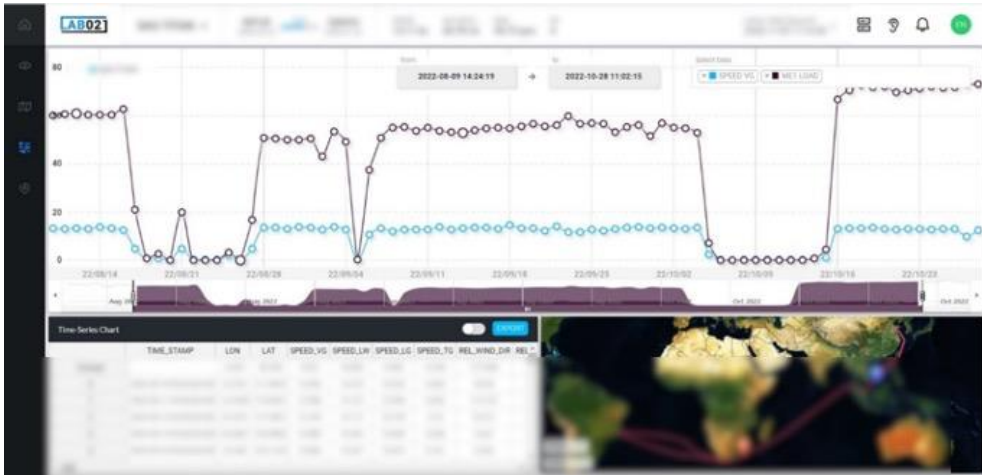


그림 1 선박 센서 데이터 기반 실시간 모니터링 예시[1]

실시간 센서 데이터 기반 모니터링에서 에너지 시스템의 이상 탐지는 에너지 시스템에서 비롯된 어느 시점의 시계열 센서 데이터가 국부적으로 또는 긴 주기 관점에서 봤을 때 기존의 제어 상황을 벗어나 정상적인 패턴을 보이지 않는 경우 이를 이상 상태로 판단하는 것이다. 엔진의 연료 과다 분사, 공급 연료의 밀도 변화 등으로 인해 에너지 시스템 내부에 미약한 이상 상황이 발생하더라도 제대로 파악하지 못해 누적된다면 메인 엔진의 폭발 등 큰 사고로 이어질 수 있다. 선박 및 해양플랫폼에서 예상하지 못한 사고가 한 번이라도 발생하면 인적 및 물적 피해가 매우 크기 때문에 실시간으로 수집되는 센서 데이터를 바탕으로 엔지니어가 직접적으로 확인하지 못하는 부분까지 이상 탐지를 정확히 해내는 것이 필요하다. 정확한 이상 탐지는 에너지 시스템이 완전한 통제를 벗어나지 않도록 최대한 빠르게 조치를 취할 수 있게 해 큰 사고가 발생하기 전에 유지 보수를 가능하게 한다.

현재는 Aspen HYSYS와 같은 열역학 시뮬레이션 프로그램을 통해 선박에서 수집된 에너지 시스템의 센서 데이터와 P&ID 그리고 각 장비의 specification을 바탕으로 간단한 모사 모델을 개발할 수 있다. Aspen HYSYS 기반 모사 모델을 통해 현재 시점의 pump work, heat exchanger의 열량, 전체 시스템의 에너지 효율 등은 계산할 수 있으나, 미래에 각 장비가 어떻게 작동할지에 대한 예측 및 이상 탐지는 불가능하다는 한계점이 있다.




그림 2 선박 Main Engine, Generator의 연료 공급 시스템

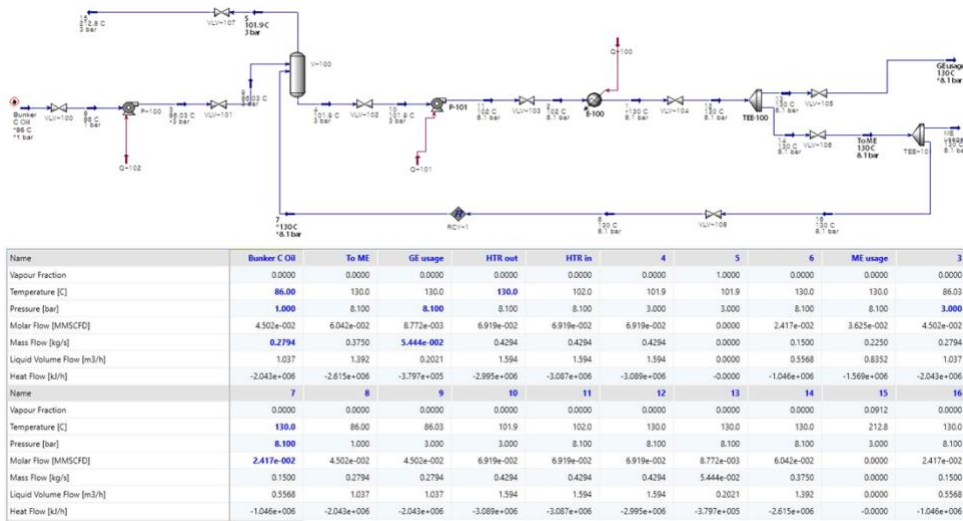


그림 3 선박 센서 데이터 기반 연료 공급 시스템 모사 모델 (Aspen HYSYS)

또한 에너지 시스템의 센서로부터 얻을 수 있는 다변량 시계열 데이터는 이미지와 같이 ‘고차원’ 이면서 추가적으로 ‘시간 종속성’도 함께 가지고 있어 데이터 특성상 분류, 예측 또는 이상 탐지가 쉽지 않다. 따라서 기존 열역학 시뮬레이션 프로그램과 독립적으로 딥러닝 기반 기술을 활용해야 한다.

최근에 개발된 Transformer 기반 시계열 예측 및 이상 탐지 모델은 기존의 순환 신경망(RNN) 기반 모델들의 단점을 극복하여 성능이 매우 뛰어나다. 하지만 모델이 복잡해진 만큼 capacity가 크게 증가하면서 이전보다 훨씬 더 많은 양의 학습 데이터가 전제된다. 하지만 국제 해운 및 해양 개발 분야의 경우, 보안 등의 여러 이유로 딥러닝 모델을 학습하기 위한 데이터의 접근이 어려워 다양한 상황과 조건에 대한 시계열 센서 데이터의 확보 자체가 어려울 수 있다. 또한 새로 건조된 선박은 운영 초기에 수집된 센서 데이터가 부족할 수 밖에 없기 때문에 학습에 사용되는 시계열 센서 데이터의 양이 적고 불균형이라면 시계열 분류, 예측 또는 이상 탐지 목적의 모델이 과적합(overfitting)될 수 있다. 따라서 시계열 데이터의 내재적 특성을 반영하는 데이터 합성 기법을 통해 실제와 매우 유사한 데이터를 많이 생성하여 복잡한 딥러닝 모델을 학습하기 위한 양질의 학습 데이터를 충분히 증강할 필요가 있다.

## 제 2 절 기존 연구

딥러닝 기술은 지금까지 컴퓨터 비전, 자연어 처리 분야에서 많은 연구와 성과가 있었다. 모델 구조가 혁신적으로 개선된 것뿐만 아니라 충분히 많은 데이터와 창의적인 데이터 합성 및 증강 기법의 발달로 인해 모델이 과적합(overfitting)되는 것을 방지하며 다양한 조건 또는 상황에서도 일관성 있게 성능을 발휘하는 강건함(robustness)을 얻을 수 있었다. 컴퓨터 비전과 자연어 처리 분야의 대표적인 데이터 증강 기법들은 아래의 그림 4, 그림 5를 통해 살펴볼 수 있다.

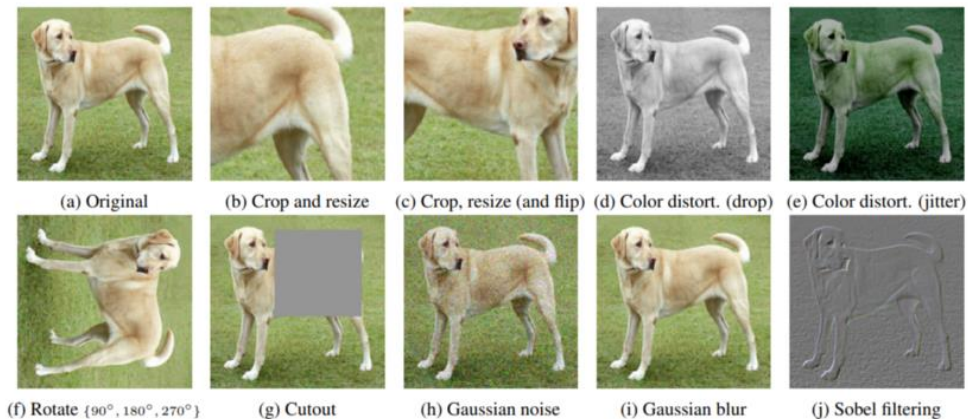


그림 4 컴퓨터 비전 분야의 대표적인 데이터 증강 기법들[2]




그림 5 자연어 처리 분야의 Masked Language Modeling[3]

이 외에도 컴퓨터 비전 분야의 경우 화풍을 바꿔주는 style transfer 기법[4], 데이터 증강 최적화를 위한 meta-learning 방법론[5] 등 다양한 데이터 증강 기법들이 계속 발전하면서 딥러닝 모델의 일반화(generalization)가 이루어지고 있다.

하지만 시계열 분야의 데이터 합성 및 증강 기법의 경우, 타 분야의 데이터 합성 및 증강 기법에 비해 연구가 상대적으로 더디게 진행되었다. 시계열 데이터는 시간에 대해 종속적인 특성을 가지고 있어 시계열의 내재적 특성을 반영하지 못하는 컴퓨터 비전과 자연어 처리 분야의 데이터 증강 기법들을 그대로 활용하기 어렵다. 또한 이미지나 언어 데이터와 달리 시계열 데이터는 시간 영역(time domain)과 주파수 영역(frequency domain)을 모두 살펴보면서 적절한 데이터 합성 및 증강 과정을 수행해야 하기 때문에 상대적으로 더 어려움이 있다[6].

Iwana 등[7]은 그림 6과 같이 시계열 데이터 합성 및 증강 기법을 크게 random transformation, pattern mixing, generative model, decomposition 총 4가지 범주로 분류하였다. 각 범주에서는 합성 또는 변형 대상 영역인 magnitude, time, frequency에 따라 더 세부적으로 분류하였다. 그리고 다양한 데이터셋에 대해 전통적인 시계열 합성 및 증강 기법인 random transformation, pattern mixing을 활용해 각종 딥러닝 기반 시계열 분류 모델의 정확도에 미치는 영향을 정량적으로 분석하였다. 그러나 VGG 모델을 제외하고 모델들의 유의미한 정확도 향상이 나타나지 않았고 오히려 떨어지는 경우가 많았다. 따라서 시계열 합성 및 증강 기법에 대한 신중한 선택이 필요하다.

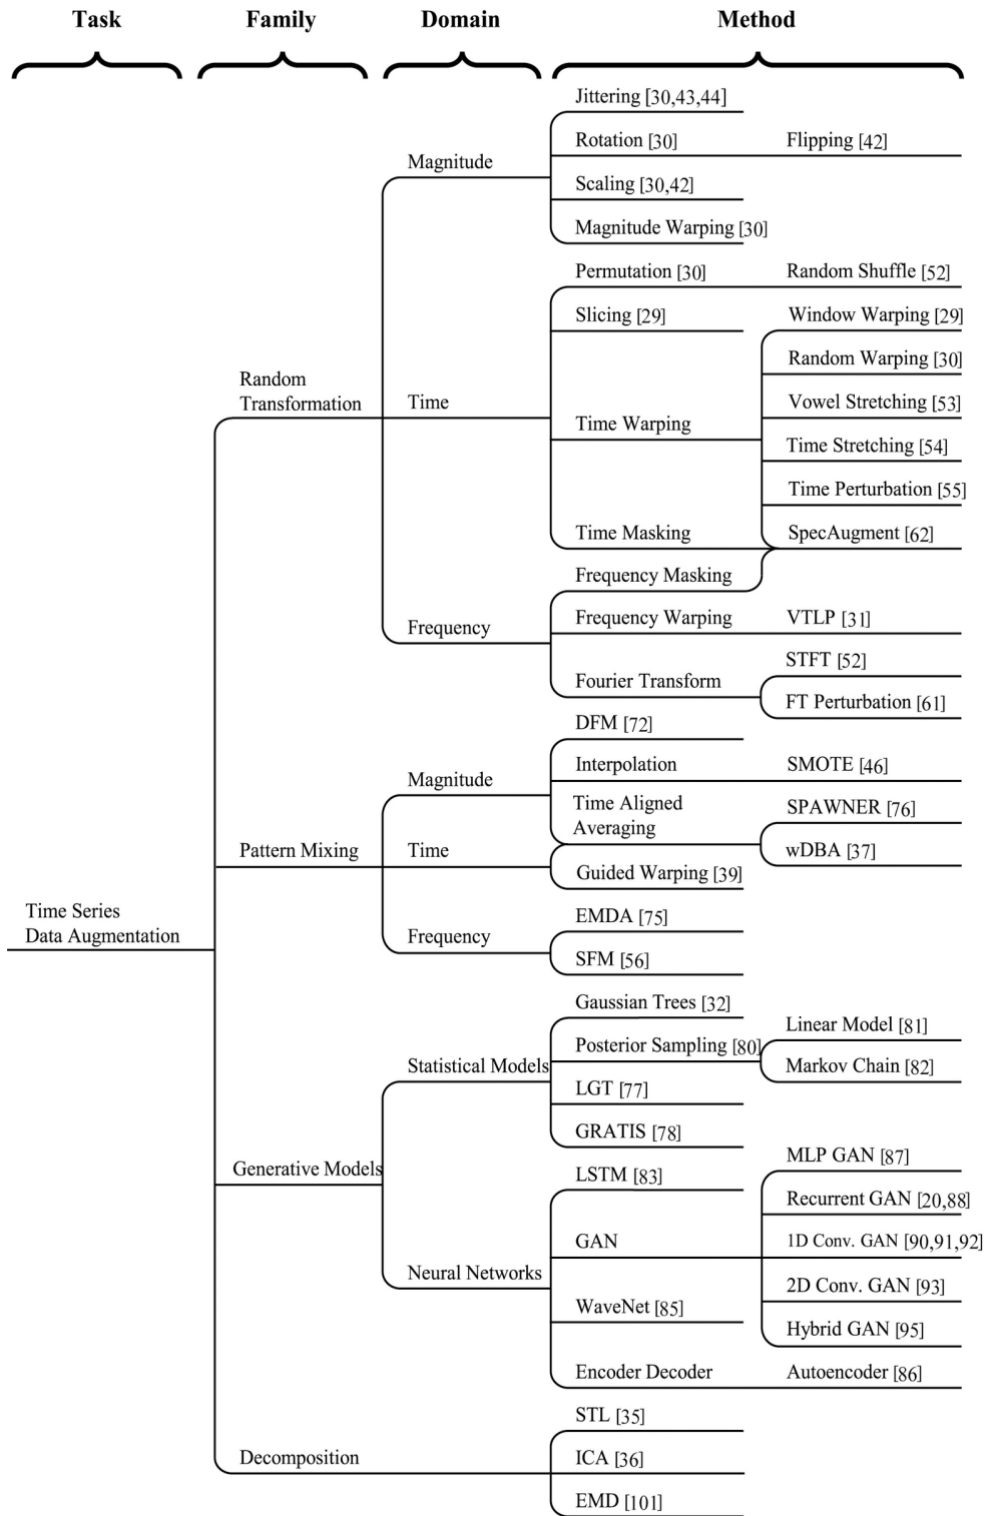





그림 6 시계열 데이터 합성 및 증강 기법의 분류[7]




(a) Original




(b) Jittering




(c) Flipping




(d) Scaling




(e) Magnitude Warping [30]




(f) Permutation



(g) Window Slicing [29]



(h) Time Warping [30]



(i) Window Warping [29]

그림 7 Random transformation 기반 시계열 변형 예시[7]



또한 Wen 등[6]은 대표적인 random transformation 기법인 window slicing, warping, flipping을 활용해 각종 시계열 데이터를 합성 및 증강시키고 이를 시계열 분류, 예측 그리고 이상 탐지 목적의 모델에 각각 학습시켜 데이터 증강을 하지 않은 기존 데이터로만 학습한 모델과 성능을 비교하였다. Transformer 기반 시계열 예측 모델의 경우, 일부 데이터셋에 대해 시계열 데이터 합성 및 증강이 모델의 성능에 오히려 부정적인 효과를 보이는 것으로 나타났다.

위의 연구 결과들을 종합해보면 random transformation과 pattern mixing 기반의 전통적인 접근법은 데이터셋의 유형과 변형 정도에 따라 시계열의 내재적 특징을 제대로 반영하지 못할 가능성이 크다. 특히 시계열 이상 탐지 모델에 시계열 데이터 합성 및 증강 기법을 적용하기 위해서는 합성된 데이터가 실제 데이터와 유사하며 정상 상태 범주 내에 있도록 하는 방법만 반드시 사용해야 할 것이다.

최근 다양한 분야에서 VAE<sup>①</sup>, GAN<sup>②</sup> 기반의 generative model을 활용해 실제와 유사한 다변량 시계열 데이터를 합성 및 증강하여 활용하는 연구가 활발히 진행되고 있다. RCGAN을 활용한 의료 데이터 합성 연구[8], WGAN-GP 또는 InfoVAE를 활용한 화학 공정의 이상 탐지 모델의 성능 향상 연구[9,10], TimeGAN을 활용한 난방 부하 예측 성능 향상 연구 또는 회전 기계의 이상 탐지 성능 향상 연구[11,12] 등이 있다.

---

① Variational Autoencoder

② Generative Adversarial Network

Reference	Dataset	Purpose	Model	Data Augmentation Method
Gao et al. (2020)	Tennessee Eastman Process	Anomaly Detection	Gradient Boosting Classifier	Generative Model(WGAN-GP)
Wen et al. (2020)	Yahoo! dataset / UCI repository	Anomaly Detection / Prediction	U-Net / Deep-AR, Transformer	Random Transformation
Iwana et al. (2021)	UCR archive	Classification	MLP, VGG, ResNet, LSTM, ...	Random Transformation, Pattern Mixing
Lee et al. (2021)	Tennessee Eastman Process	Anomaly Detection	Autoencoder	Generative Model(InfoVAE)
Zhang et al. (2022)	Heating substation dataset	Prediction	XGBoost	Generative Model(TimeGAN)
Li et al. (2022)	Rotating machinery dataset	Anomaly Detection	Efficient-Net	Generative Model(TimeGAN)

표 1 다변량 시계열 합성 기법을 응용한 선행 연구 목록

### 제 3 절 연구 목적

다양한 상황과 조건에서 보다 정확한 이상 탐지를 위해 딥러닝 모델에 포함된 개념 및 구조가 더욱 복잡해지고 커진 만큼 다량의 학습 데이터가 전제된다. 컴퓨터 비전 분야에서는 이미 capacity가 큰 딥러닝 기반 분류 모델의 과적합을 방지하고 강건한 분류 및 이상 탐지 성능 확보를 위해 다양한 데이터 합성 및 증강 기술을 필수적으로 활용하고 있다. 시계열 분야에서도 특히 시계열 이상 탐지에 적합한 적대적 생성 신경망(GAN) 기반 데이터 합성 기법을 활용해 데이터에 대한 접근이 제한적이거나 학습 데이터 자체가 적은 선박 및 해양플랫폼 에너지 시스템의 다변량 시계열 데이터를 증강시켜 활용할 수 있을 것이다. 이때, VAE 대신 GAN 기반 다변량 시계열 데이터 합성 기법을 활용하는 이유는 사전 분포 등의 어떠한 가정도 없이 실제 데이터의 분포와 가장 유사하게 데이터를 합성할 수 있기 때문이다.

본 연구에서는 다양한 선박 및 해양플랫폼 에너지 시스템 중 가장 대표적인 중유(Heavy Fuel Oil, HFO) 및 Marine Gas Oil(MGO)을 사용하는 기존 디젤 엔진 선박의 에너지 시스템 데이터셋을 활용한다. SOx scrubber가 설치되어 있는 새로 건조된 벌크선의 실제 운항 데이터 일부이며, 상대적으로 단순하며 직관적인 에너지 시스템에서 추출되어 사후 분석이 용이하다. 특정 운항에 대한 메인 엔진, 보일러, scrubber와 관련된 온도, 압력, 농도 등 5개 변수의 센서 데이터가 있다.

우선 GAN 기반 다변량 시계열 합성 모델인 TimeGAN[13]을 활용해 선박 에너지 시스템의 실제 센서 데이터와 매우 유사한 합성 데이터를 생성하여 부족한 학습 데이터를 증강한다. 이후 많은 학습 데이터가 전제되지만 현재 가장 성능이 뛰어난 Transformer 기반 다변량 시계열 이상 탐지 모델인 TranAD[14]에 적용하여 이상 탐지 성능 향상을 검증한다.

추가적인 실제 센서 데이터 수집 없이도 실제 센서 데이터의 분포 및 시간적 특성을 잘 파악하여 좋은 품질의 학습 데이터를 충분히 제공함으로써 선박 내 에너지 시스템의 이상 상황에 대해 모델의 성능을 최대한 끌어올려 일반화할 수 있는지 확인하는 것이 이번 연구의 목적이다.

## 제 2 장 배경 이론 및 연구 프레임워크

### 제 1 절 다변량 시계열 데이터 합성 모델 - TimeGAN

시계열 데이터 합성에서는 시계열 데이터의 시간적 종속성을 잘 보존할 필요가 있다. 다변량 시계열인 경우는 시간에 따른 변수들 간의 관계도 잘 보존되어야 한다. 하지만 일반적인 GAN 기반 모델은 시계열 데이터만의 시간적인 관계를 적절히 반영하지 못한다는 문제가 있었다. 따라서 시계열 데이터의 시간적 종속성을 잘 보존하고 다변량인 경우 시간에 따른 변수 간 관계까지 포함할 수 있도록 실제 시계열 데이터를 기반으로 지도 학습이 추가적으로 필요하다.

Yoon 등[13]은 실제 다변량 시계열 데이터의 시간적 역학을 잘 보존하는 데이터 합성을 목적으로 일종의 hybrid GAN 모델인 TimeGAN을 설계했다. 아래의 그림 8과 같이 Autoencoder Network와 GAN 그리고 Supervisor가 결합된 구조를 가지고 있다.

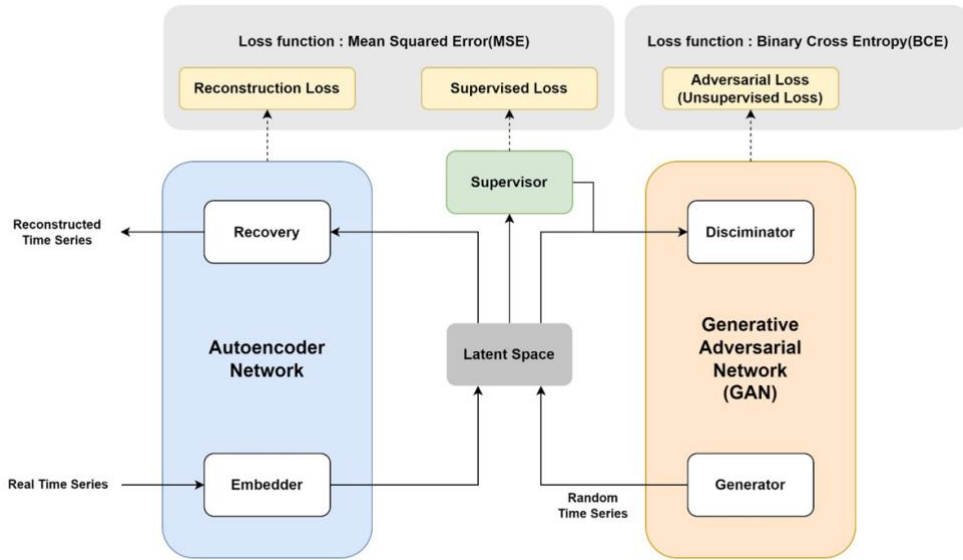


그림 8 TimeGAN의 구조와 주요 구성 요소

우선 다변량 시계열 데이터가 고차원이기 때문에 연산의 효율성을 위해 데이터의 특징들만 잘 살려낸 저차원의 잠재 공간(latent space)에서 다변량 시계열 데이터를 다룰 수 있도록 Autoencoder Network를 활용하고 있다. Autoencoder Network는 세부적으로 차원을 축소시키는 Embedder와 다시 복원하는 Recovery로 구성된다. 차원 축소 이후 다시 복원했을 때 원본 시계열 데이터와 거의 동일하도록 학습한다. 한편, GAN은 합성 시계열을 생성하는 Generator와 대상 시계열이 실제 시계열 또는 합성 시계열인지 판별하는 Discriminator로 구성되며, 각 구성 요소가 동시에 학습되고 발전하는데 최종적으로 Generator가 생성하는 합성 시계열이 Discriminator가 실제 시계열과 구분하기 힘들 정도로 유사한 수준이 될 때까지 학습을 진행한다. 이 때 실제 시계열을 통해 시간 종속성을

학습하는 Supervisor가 특별히 잠재 공간에 존재하는데 합성 데이터에 시간 종속성을 부여해주어 실제 시계열과 유사한 합성 시계열을 만들 수 있도록 도움을 준다. 그리고 TimeGAN의 각 구성 요소들을 학습하기 위한 loss function은 세 가지로 구분할 수 있으며, reconstruction loss, supervised loss, 그리고 adversarial loss(unsupervised loss)가 있다.

TimeGAN의 학습 과정은 세 단계로 구분된다. 우선 Autoencoder Network를 실제 시계열로 학습하여 reconstruction loss를 최소화한다. 다음으로 실제 시계열의 시간적인 특징을 포착하기 위해 supervised loss를 최소화한다. 이후 Generator와 Discriminator의 통합적인 학습을 통해 모든 loss function을 동시에 최소화한다. Adam optimizer를 활용해 reconstruction loss와 Generator, Discriminator의 관점에서 supervised loss와 adversarial loss(unsupervised loss)가 결합된 discriminator loss, generator loss로 새롭게 정의하여 각각 최소화하며 각 loss function들은 다음과 같이 간략히 표현된다.

$$E_{Loss}(reconstruction\ loss) = 10 * \sqrt{MSE(X, \tilde{X})}$$

$$D_{Loss}(discriminator\ loss) = D_{Loss(Real)} + D_{Loss(Fake)} + \gamma * D_{Loss(Fake(e))}$$

$$G_{Loss}(generator\ loss) = G_{Loss(U)} + \gamma * G_{Loss(U(e))} + 100 * G_{Loss(V)} + 100 * \sqrt{G_{Loss(S)}}$$

TimeGAN은 확률 분포 기반의 유연성 있는 GAN과 시계열 특징에 대한 가이드라인 역할을 해주는 Supervisor가 결합되어 실제와 매우 유사한 합성 시계열 데이터셋을 잘 생성하지만, 각 구성 요소가 동시에 학습되고 발전하는 GAN 특성상 전통적인 통계 기법에 기반한 VAE 기반 generative model보다 일정 수준 이상 수렴되는데 시간이 다소 소요된다는 단점은 있다. 하지만 특정 분포를 사전 분포로 가정하는 VAE 기반 generative model과 달리 아주 유연한 딥러닝 모델로서 실제 시계열이 매우 복잡한 분포를 가지는 경우도 아주 유사한 분포로 합성 시계열을 생성한다. 지도 학습을 통한 실제 시계열의 시간 종속성까지 반영되어 학습 이후 좋은 품질의 합성 시계열을 빠르게 무한정 생성한다는 큰 장점을 가지고 있다.



## 제 2 절 다변량 시계열 이상 탐지 모델 - TranAD

먼저 시계열 이상 탐지(Time Series Anomaly Detection)의 정의는 어느 시점의 시계열이 국부적으로 또는 긴 주기 관점에서 봤을 때 정상적인 패턴을 보이지 않는 경우 이상 상태(Anomaly)로 판단하는 것이다. 특히 화학 공정이나 에너지 시스템에서 비롯된 다변량 센서 시계열 데이터에 대해 이상 탐지를 수행하여 엔지니어가 직접적으로 확인할 수 없는 이상을 쉽게 파악할 수 있다면 큰 사고를 예방할 수 있을 것이므로 선박 및 해양플랫폼에서 유용한 기술이다.

기존의 Encoder-Decoder 기반 이상 탐지 모델은 긴 주기의 trend만 학습하고 국부적인 특징을 포착하지 못해 종종 약간의 noise도 이상 상태로 판단해버리는 문제점이 있었다. 하지만 Tuli 등[14]은 Transformer 기반인 TranAD를 개발하였다. TranAD는 긴 주기의 trend뿐만 아니라 시계열의 국부적인 특징도 다시 한 번 잘 파악해 기존 다변량 시계열 이상 탐지 모델들보다 정확성을 높였다.




그림 9 TranAD 모델의 구조[14]

TranAD는 Input Reconstruction, Focused Input Reconstruction 두 단계로 학습이 진행되며, 최종적인 loss function는 아래 수식과 같다.

$$L_1 = \epsilon^{-n} \|O_1 - W\|_2 + (1 + \epsilon^{-n}) \|\hat{O}_2 - W\|_2 \quad L_2 = \epsilon^{-n} \|O_2 - W\|_2 - (1 - \epsilon^{-n}) \|\hat{O}_2 - W\|_2$$

학습 데이터가 충분한 총 9가지 데이터셋에 대해 시계열 이상 탐지 모델들의 성능을 F1 Score<sup>③</sup>, AUC<sup>④</sup>로 비교했을 때 TranAD가 대부분의 경우 가장 좋았다. 특히 이번 연구에서 활용하는 에너지 시스템 관련 데이터셋과 유사한 수처리 플랜트의 센서 데이터셋인 SWaT(Secure Water Treatment)에 대해서 그림 10와 같이 F1 Score, AUC 기준으로 TranAD가 가장 좋은 성능을 보여주었다. 이 때 SWaT의 학습 데이터는 51개의 변수에 대해 총 496,800개인 다변량 시계열이다.




그림 10 SWaT에 대한 시계열 이상 탐지 모델 성능 비교

③ Precision과 Recall의 조화평균으로 데이터 label이 불균형(정상 상태에 비해 이상 상태의 비율이 매우 낮은 경우)일 때 모델의 성능을 정확하게 평가할 수 있음

④ ROC curve의 아래 면적을 뜻하며 이진 분류기의 성능을 표현하는 값

이번 연구에서 활용하려고 하는 TranAD 모델의 이상 탐지 과정은 다음과 같다. 우선 정상적인 패턴을 가지는 학습 데이터로 TranAD를 학습하고, 이후 이상 상태가 포함된 시험 데이터에 대해 정상적인 상태만을 가정했을 때 예측되는 시계열로 재구성(reconstruction)한다. 이상 상태에 대한 정량적인 판단을 위해서 이상 상태와 관련된 점수와 기준도 필요할 것이다. 이상 상태가 포함된 기존 시험 데이터와 이를 정상 상태로 재구성하여 예측한 시계열 데이터의 차이인 잔차(residual)를 제공하여 각 시점에 대한 Anomaly Score를 계산한다. 그리고 Generalized Pareto Distribution 가정이 포함된 Peak-Over-Threshold(POT) 방법을 활용해 이상 상태 기준인 threshold를 각 변수에 대해서 자동적으로 설정해주어 이상 상태를 최종적으로 판별한다. 아래의 그림 11에서 TranAD를 활용한 시계열 이상 탐지 예시를 확인할 수 있다.




그림 11 TranAD를 활용한 시계열 이상 탐지 결과 예시[14]

### 제 3 절 연구 프레임워크

이번 연구에서 활용한 다변량 시계열 이상 탐지 모델인 TranAD는 Transformer 구조로 이루어져 기존의 RNN 기반 Encoder-Decoder 이상 탐지 모델들보다 더욱 복잡해지고 성능이 좋아진 만큼 많은 양의 학습 데이터가 전제된다. 이를 감안하여 적은 양의 학습 데이터셋에 대해서도 성능을 보완하기 위해 learning rate를 유연하게 조절하는 등 meta-learning 기법을 추가적으로 활용하고 있다. 하지만 학습 데이터의 부족으로 나타나는 문제를 근본적으로 해결하지 못해 모델의 강건함과 충분한 성능을 보장하지 못한다. 대신 학습 데이터에 대한 좋은 품질의 합성 및 증강으로 충분한 학습 데이터를 확보하여 이를 해결할 수 있을 것이다. 특히 보안 등의 이유로 접근 가능한 학습 데이터가 부족하거나 새롭게 건조되어 학습 데이터 자체가 부족한 선박 및 해양플랫폼의 에너지 시스템에 대해서 실제 데이터와 매우 유사한 학습 데이터 합성 및 증강이 효과적일 것이다.

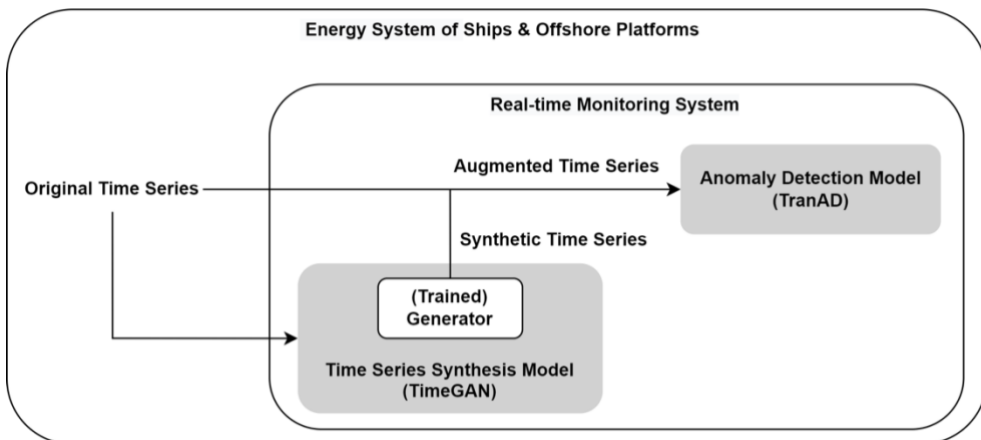


그림 12 합성 및 증강을 활용한 에너지 시스템 이상 탐지

## 제 3 장 Dataset

### 제 1 절 SOx Scrubber가 설치된 벌크선 운항 데이터셋

다양한 선박 및 해양플랫폼 에너지 시스템 중 가장 대표적인 HFO 또는 MGO를 사용하는 기존 디젤 엔진 선박의 에너지 시스템은 상대적으로 단순하며 직관적인 에너지 시스템을 갖추고 있어 사후 분석이 용이하다는 장점이 있다. 본 연구에서 활용한 데이터셋은 해수를 분사하는 open loop 유형의 SOx scrubber가 설치된 신조선인 케이프사이즈 벌크선의 에너지 시스템에서 각종 센서를 통해 10초 간격으로 수집되었다. 약 7일 간의 운항 기간 동안 수집된 데이터로 이 기간 동안 실제 Main Engine의 running hour는 약 48시간으로 나타났다.

선박 내 에너지 시스템의 Main Engine, Auxiliary Boiler, Scrubber와 관련된 주요 변수들이 이상 탐지 분석 대상이다. 정상 상태가 안정적으로 유지되어 이상 탐지 모델의 학습에 활용할 수 있는 데이터는 표 2의 5개 변수에 대해 7,200개로 실제 운항 중 72,000초에 대한 다변량 센서 시계열 데이터다.

다만 앞서 살펴본 수처리 플랜트 SWaT 데이터셋의 학습 데이터 개수와 비교해보면 496,800개에 비해 7,200개는 현저히 부족한 것을 확인할 수 있다. 결국 효율적 학습을 위해 TranAD에 포함된 meta-

learning 기법을 고려하더라도 이미 검증된 다양한 시계열 벤치마크 데이터셋의 학습 데이터 개수를 종합적으로 생각해보면 이번 연구에서 활용한 데이터셋의 학습 데이터를 최소 두 배 이상 확보해야 TranAD의 이상 탐지 성능이 최대화되며 안정적인 것이다. 본 연구에서 활용한 선박 및 해양플랫폼 에너지 시스템의 이상 탐지 성능 향상을 위해서는 좋은 품질의 학습 데이터 합성 및 증강이 필요할 것이다.

Machinery	Variable
Main Engine	Main Engine Load (%)
	Main Engine Cylinder Exhaust Gas Outlet Temperature (°C)
	Main Engine All Cylinder Average Indicated Pressure (kgf/cm <sup>2</sup> )
Auxiliary Boiler	Auxiliary Boiler Steam Pressure (kgf/cm <sup>2</sup> )
Scrubber	Scrubber SO <sub>2</sub> / CO <sub>2</sub> Ratio (ppm/%(v/v))

표 2 선박 내 에너지 시스템의 주요 변수 목록

## 제 1 항 Main Engine(M/E)의 Load

선박이 정속으로 정상적인 운항 중일 때는 Main Engine의 Load가 60~68(%) 정도로 일정하게 유지되어야 한다. 그림 13은 학습 데이터의 일부로 Main Engine의 Load가 특정 범위 내에서 잘 유지되고 있는 것을 보여준다.




그림 13 정속 운항 중 일정하게 유지되는 M/E의 Load

## 제 2 항 M/E Cylinder의 배출 가스 온도

Main Engine에 총 7개의 Cylinder가 있으며, 엔진을 가동할 때 각 Cylinder에서 배출되는 가스는 서로 다른 온도 범위를 가지지만 시간에 따른 변화는 거의 동일하다. 그리고 제1항에서 살펴본 Main Engine의 Load 변화가 Cylinder의 배출 가스 온도 변화의 주요한 원인이 된다. 그림 13, 그림 14를 통해 Main Engine의 Load가 일정하게 유지되고 있는 상황에서는 특정 Cylinder의 배출 가스 온도도 급격한 변화없이 적당한 범위 내에서 유지된다는 것을 확인할 수 있다.




그림 14 적당한 온도가 유지되는 M/E Cylinder 배출 가스

### 제 3 항 M/E Cylinder 전체의 평균 지시 압력

Main Engine Cylinder 전체의 평균 지시 압력은 매 시간 단위마다 각 Cylinder의 폭발 압력의 평균을 의미한다. Cylinder의 배출 가스 온도와 마찬가지로 Main Engine의 Load 변화가 Cylinder 전체의 평균 지시 압력 변화의 주요한 원인이 된다. 그림 13, 그림 15를 통해 Main Engine의 Load가 일정하게 유지되고 있는 상황에서는 Cylinder 전체의 평균 지시 압력도 급격한 변화없이 적당한 범위 내에서 유지된다는 것을 확인할 수 있다.






그림 15 일정 범위 내 M/E Cylinder 전체 평균 지시 압력

#### 제 4 항 Auxiliary Boiler의 steam 압력

Steam의 압력은 사실 대부분의 시간 동안 Auxiliary Boiler의 가동 없이 Economizer를 통해 그림 16처럼 6.4~6.6(kgf/cm<sup>2</sup>) 정도로 유지되고 있다. 다만 연료의 heating 목적으로 steam과 관련된 밸브를 정기적으로 열어 steam을 많이 사용하게 되면 일정 수준 이하로 압력이 떨어지는데 이는 known anomaly로 이상 상태에서 제외한다. 그리고 steam의 압력을 회복하기 위해 Auxiliary Boiler가 가동된다.




그림 16 보일러 가동 없이 유지되고 있는 steam 압력

## 제 5 항 SOx Scrubber의 SO2 / CO2 비율

SOx scrubber는 Main Engine의 Load에 관계없이 자체적인 해수 분사 제어를 통해 1.5~3.0 정도의 SO2 / CO2 비율을 안정적으로 유지한다. 아래 그림 17의 학습 데이터 일부를 통해 안정적으로 유지되고 있는 SOx scrubber의 SO2 / CO2 비율을 확인할 수 있다.




그림 17 자체 제어로 유지되는 Scrubber SO2/CO2 비율

## 제 4 장 결과 및 분석

### 제 1 절 TimeGAN을 활용한 센서 데이터 합성 결과

우선 SOx Scrubber가 설치되어 있는 새로 건조된 벌크선 운항 데이터셋의 학습 데이터에 대해 TimeGAN 모델이 다른 시계열 합성 방법론들에 비해 실제와 아주 유사한 좋은 품질의 다변량 시계열 데이터를 생성한다는 것을 시각화와 정량적 지표를 통해 확인할 수 있다. 이 때 TimeGAN 모델에 적용한 hyperparameter와 training settings은 아래의 표 3과 같다.

Hyperparameter		Training Settings	
Module	GRU <sup>⑤</sup>	Optimizer	Adam
Hidden dimension	25	Learning rate	0.0005
Number of layers	3 (Supervisor : 2)	Iterations	10000
Sequence length(Window size)	12 (120 seconds)	Batch size	128

표 3 TimeGAN의 hyperparameter와 training settings

<sup>⑤</sup> Gated Recurrent Unit

## 제 1 항 데이터 시각화

먼저 선박 에너지 시스템의 Main Engine, Auxiliary Boiler, Scrubber와 관련된 주요 변수들에 대해 실제 데이터(Original)를 TimeGAN 모델로 합성한 데이터(Synthetic)와 함께 시간에 대한 그래프로 나타냈다. 그림 18을 통해 모든 변수에 대해서 실제와 매우 유사하게 합성 데이터가 생성되는 것을 쉽게 확인할 수 있다.




그림 18 실제 센서 데이터와 합성 데이터(TimeGAN)

그리고 대표적인 차원 축소 방법인 PCA<sup>⑥</sup>와 t-SNE<sup>⑦</sup>를 통해서도 실제 데이터와 합성 데이터의 분포가 얼마나 유사한지 확인할 수 있다. 2차원으로 시각화한 결과 그림 19처럼 TimeGAN 모델로 합성한 데이터(Synthetic)는 실제 데이터(Original)와 구분이 매우 어렵다.

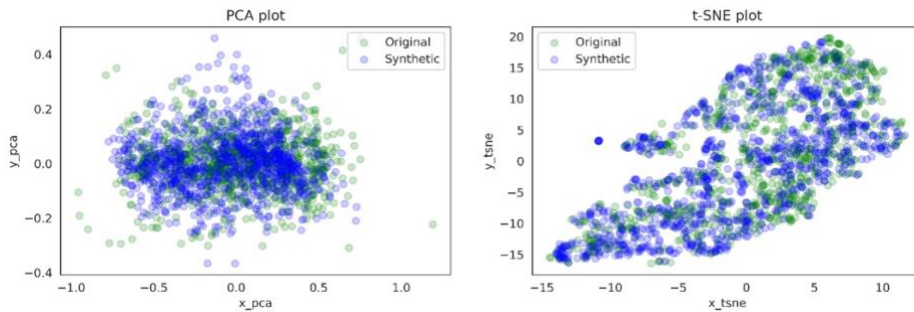


그림 19 합성 데이터(TimeGAN)의 PCA, t-SNE 결과

반면, 다른 전통적인 합성 방법론(e.g. Time Warping)의 경우, 실제 데이터와 확연히 구별되는 합성 데이터를 생성하는 것을 그림 20을 통해 확인할 수 있다. 실제 데이터와 구분이 된다는 것은 서로 다른 분포를 가진다는 의미로 학습 데이터의 증강 효과가 나타나지 않을 수 있으며 오히려 성능을 감소시킬 가능성도 있다.

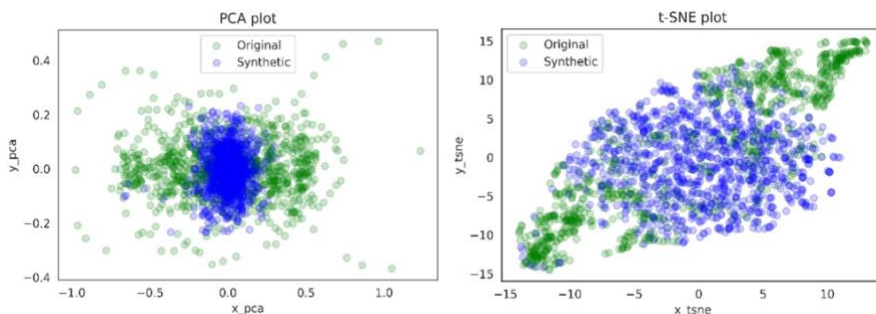


그림 20 합성 데이터(Time Warping)의 PCA, t-SNE 결과

⑥ 원본 데이터를 선형적으로 mapping하는 차원 축소 및 시각화 방법

⑦ 비선형적 차원 축소 및 시각화 방법으로 특히 고차원의 데이터에 대해 성능이 좋음

## 제 2 항 합성 데이터 품질에 대한 정량적 지표 비교

합성 데이터 품질에 대한 정량적 지표로 Discriminative Score와 Predictive Score가 있다.

우선 실제 데이터와 구분할 수 있는 정도를 정량적으로 나타내는 지표인 Discriminative Score는 2-layer LSTM으로 구성된 post-hoc 시계열 분류 모델을 통해 classification error를 측정하여 구한다. 이 때 시계열 분류 모델이 실제 시계열과 합성 시계열을 제대로 구분하지 못한다는 의미인 0.5(50%)를 기준으로 재설정하여, 값이 0에 가까울수록 합성 데이터는 실제 데이터와 구분이 어렵고 0.5에 가까울수록 구분이 쉽다는 것을 의미하도록 했다. 아래의 그림 21을 통해 TimeGAN 모델로 합성한 데이터는 다른 전통적인 방법론들과 달리 0에 가까운 값을 가지며 실제 데이터와 구분이 매우 어렵다는 것을 정량적으로 확인할 수 있다.

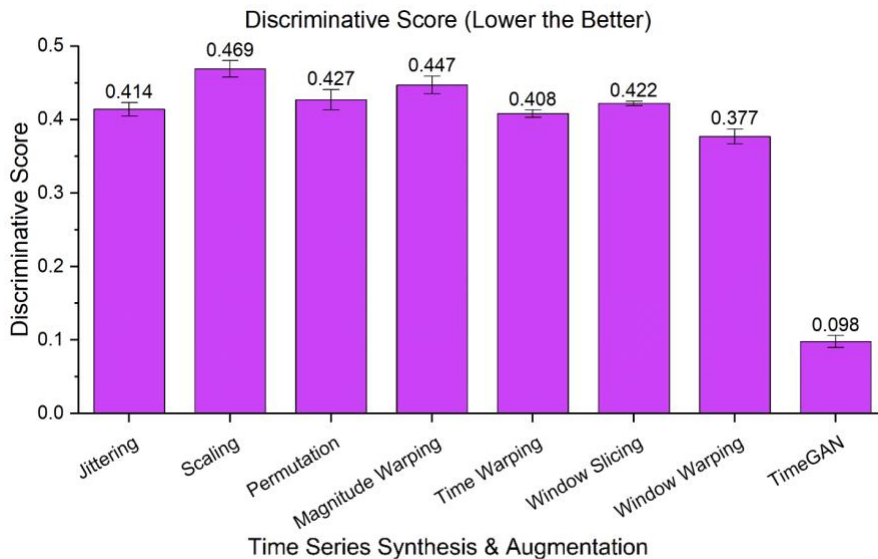


그림 21 합성 데이터의 Discriminative Score 비교

한편, Predictive Score는 시계열 예측 모델을 실제 데이터로 학습한 경우와 동일한 크기의 합성 데이터로 학습한 경우에 대해 각각 예측 성능을 표현한 지표다. 1에서 예측 확률을 뺀셈하여 0에 가까울수록 예측 정확도가 높다는 것을 의미하도록 재설정했다. 아래의 그림 22를 통해 전통적인 방법론의 합성 데이터만으로 시계열 예측 모델을 학습한 경우, 실제 데이터로 학습한 경우보다 오히려 예측 정확도가 감소한다는 것을 확인할 수 있다. 반면, TimeGAN의 합성 데이터만으로 학습한 경우는 실제 데이터로 학습한 경우와 예측 정확도가 거의 동일하다는 것을 확인할 수 있다.

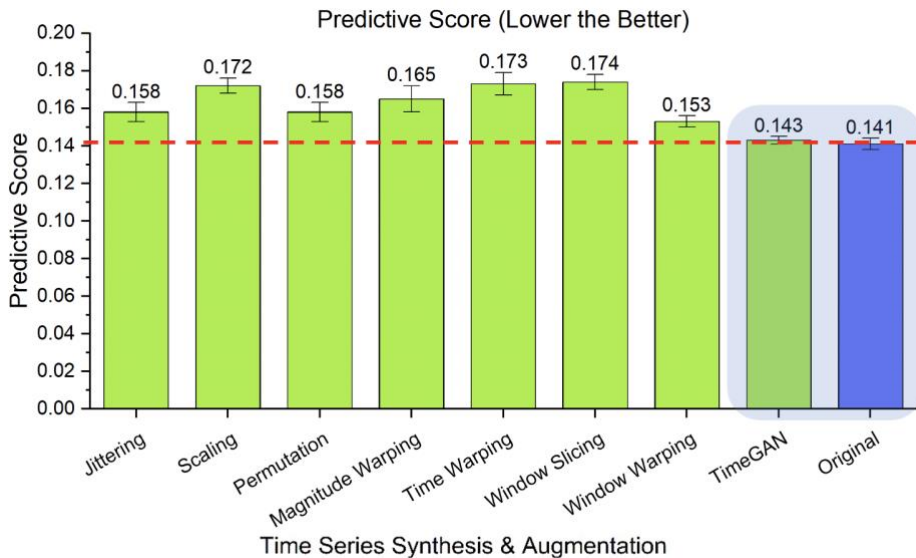


그림 22 합성 데이터의 Predictive Score 비교

이 때 합성 데이터의 품질을 정확히 비교하기 위해 모두 동일한 크기의 데이터로만 학습해 비교했다는 것을 유의해야 한다. 실제와 매우 유사한 좋은 품질의 합성 데이터를 충분히 생성하여 학습한다면 제한된 크기의 실제 데이터로만 학습하는 경우보다 성능이 더 좋아질 것이다.

## 제 2 절 학습 데이터 증강 유무에 따른 이상 탐지 결과

SOx Scrubber가 설치되어 있는 새로 건조된 벌크선 운항 데이터셋의 부족한 학습 데이터를 TimeGAN의 합성 데이터로 증강한 후 다변량 시계열 이상 탐지 모델인 TranAD을 활용해 변수별로 이상 탐지를 수행했다. 좋은 품질의 합성 데이터를 활용하여 학습 데이터를 증강시켰을 때 이상 탐지 성능 향상이 나타나는지 정량적으로 검증하기 위해 기존의 meta-learning 기법만 활용하고 부족한 실제 데이터로만 학습한 경우를 base case로 두고 비교했다. 이 때 TranAD 모델에 적용한 hyperparameter와 training settings은 아래의 표 4와 같다.

Hyperparameter		Training Settings	
Window size	12	Optimizer	AdamW
Number of layers	1 (in Transformer encoders)	Learning rate	0.01
	2 (in feed-forward unit of encoders)		
Hidden units in encoder layers	64	Meta-learning rate	0.02
Dropout in encoders	0.1		

표 4 TranAD의 hyperparameter와 training settings



## 제 1 항 M/E의 Load 이상 탐지 결과

교통 혼잡 상황으로 인한 인위적인 변속 또는 악천후 항해 중 프로펠러의 일부가 수면 위로 드러나면서 발생하는 부하 불균형 등 여러 원인으로 인해 Main Engine의 Load가 요동치는 이상 상태(Anomaly)가 나타날 수 있다. 시험 데이터 일부를 나타낸 그림 23, 그림 24를 살펴보면 Main Engine의 Load가 60~65(%)로 일정하게 유지되어야 하는 구간이지만 17,000초 부근부터 이상 상태가 나타나고 있다.

그림 23은 부족한 실제 데이터만 활용해 학습한 base case로 일부 구간에 대한 trend 예측이 다소 빗나가면서 17,000초 이전의 정상 상태인 일부 구간을 이상 상태로 잘 못 판별하는 문제점이 있었다.

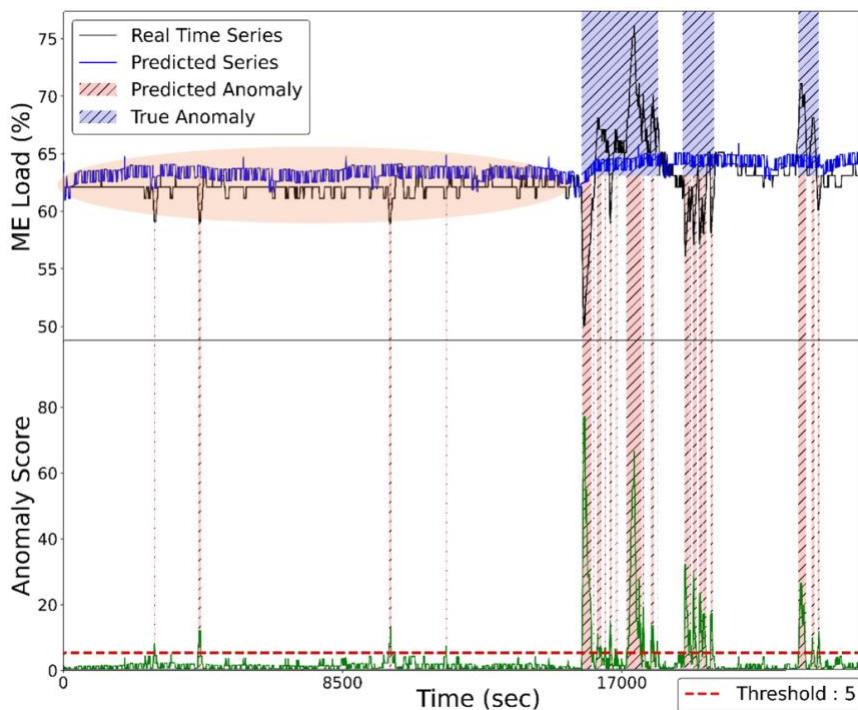


그림 23 TranAD base case(M/E Load)

그림 24는 TimeGAN의 합성 데이터로 증강하여 충분히 학습한 결과로 trend 예측이 더 정확해지면서 실제로 이상 상태인 구간에 대해서만 정확히 이상 상태로 판별했다. 결과적으로 Main Engine의 Load에 대한 이상 탐지 모델의 정확도가 향상되는 것을 확인할 수 있다.




그림 24 학습 데이터 증강 결과(M/E Load)

정량적으로는 Recall이 향상되어 F1 Score, AUC 기준으로 각각 1.04(%), 1.15(%) 정도 성능이 향상되었다.

Model	Precision	Recall	F1 Score	AUC
Base Case	0.8404	0.9712	0.9011	0.9760
TranAD with data augmentation(TimeGAN)	0.8356	1.0000	<b>0.9104</b>	<b>0.9872</b>

표 5 이상 탐지 결과 (M/E Load)

## 제 2 항 M/E Cylinder의 배출 가스 온도 이상 탐지 결과

Main Engine의 Load 변화가 Cylinder의 배출 가스 온도 변화의 주요한 원인으로 작용하게 되므로, 여러 이유 때문에 Main Engine의 Load가 요동칠 때 Cylinder의 배출 가스 온도도 함께 이상 상태가 나타난다. 시험 데이터 일부를 나타낸 그림 25, 그림 26을 살펴보면 Main Engine의 Load의 영향을 받아 17,000초 부근부터 이상 상태가 함께 나타나고 있다.

그림 25은 부족한 실제 데이터만 활용해 학습한 base case로 일부 구간에 대한 trend 예측이 조금 빗나가면서 17,000초 이전의 정상 상태인 일부 구간을 이상 상태로 잘 못 판별하는 문제점이 있었다.




그림 25 TranAD base case(CYL EXH GAS Temp.)

그림 26은 TimeGAN의 합성 데이터로 증강하여 충분히 학습한 결과로 trend 예측이 더 정확해지고 분산도 감소하면서 안정적인 예측 성능을 보여주었다. 결과적으로 Main Engine Cylinder의 배출 가스 온도에 대한 이상 탐지 모델의 정확도가 향상되는 것을 확인할 수 있다.




그림 26 학습 데이터 증강 결과(CYL EXH GAS Temp.)

정량적으로는 Recall이 향상되어 F1 Score, AUC 기준으로 각각 1.38(%), 0.80(%) 정도 성능이 향상되었다.

Model	Precision	Recall	F1 Score	AUC
Base Case	0.9202	0.9691	0.9440	0.9832
TranAD with data augmentation(TimeGAN)	0.9186	0.9988	<b>0.9570</b>	<b>0.9911</b>

표 6 이상 탐지 결과 (CYL EXH GAS Temp.)

### 제 3 항 M/E Cylinder 전체의 평균 지시 압력 이상 탐지 결과

Main Engine의 Load 변화가 Cylinder의 배출 가스 온도와 마찬가지로 Cylinder 전체의 평균 지시 압력 변화의 주요한 원인으로 작용하게 되므로, 여러 이유로 인해 Main Engine의 Load가 요동칠 때 Cylinder 전체의 평균 지시 압력도 함께 이상 상태가 나타날 것이다. 시험 데이터 일부를 나타낸 그림 27, 그림 28을 살펴보면 Main Engine의 Load의 영향을 받아 17,000초 부근부터 이상 상태가 함께 나타나고 있다.

그림 27은 부족한 실제 데이터만 활용해 학습한 base case로 일부 구간에 대한 trend 예측이 다소 빗나가면서 17,000초 이전의 정상 상태인 일부 구간을 이상 상태로 잘 못 판별하는 문제점이 있었다.




그림 27 TranAD base case(CYL AVG IND Press.)

그림 28은 TimeGAN의 합성 데이터로 증강하여 충분히 학습한 결과로 trend 예측이 더 정확해지고 분산도 감소하면서 안정적인 예측 성능을 보여주었다. 결과적으로 Main Engine Cylinder 전체의 평균 지시 압력에 대한 이상 탐지 모델의 정확도가 향상되었다.




그림 28 학습 데이터 증강 결과(CYL AVG IND Press.)

정량적으로는 Recall이 향상되어 F1 Score, AUC 기준으로 각각 1.98(%), 0.68(%) 정도 성능이 향상되었다.

Model	Precision	Recall	F1 Score	AUC
Base Case	0.9489	0.9687	0.9587	0.9853
TranAD with data augmentation(TimeGAN)	0.9563	1.0000	<b>0.9777</b>	<b>0.9920</b>

표 7 이상 탐지 결과 (CYL AVG IND Press.)



#### 제 4 항 Auxiliary Boiler의 Steam 압력 이상 탐지 결과

Steam의 압력은 대부분의 시간 동안 Auxiliary Boiler의 가동 없이 Economizer를 통해 6.4~6.6(kgf/cm<sup>2</sup>) 정도로 유지되고 있다. 하지만 연료의 heating 등의 정기적인 목적이 아닌 알 수 없는 원인으로 밸브의 opening 오류가 발생해 그림 29, 그림 30과 같이 steam의 압력이 일정 수준 이하로 급격히 떨어지게 되었다. 이 때, 다행히 steam이 통과하는 배관의 파손되는 등의 심각한 이상 상황은 아니기 때문에 Auxiliary Boiler의 가동만으로 steam의 압력을 빠르게 회복하였다.

데이터의 분포가 비교적 단순하고 trend가 매우 일정한 경우라서 부족한 실제 데이터만 활용해 학습했을 때 그림 29와 같이 실제로 이상 상태인 구간에 대해서 이상 상태로 잘 판별하고 있다. 다만 부족한 학습 데이터로 인해 예측 시계열이 실제보다 분산이 커서 다소 불안정하다.




그림 29 TranAD base case(BLR Steam Press.)

그림 30과 같이 TimeGAN의 합성 데이터로 증강하여 학습한 경우는 그림 30과 같이 예측한 시계열의 분산이 실제와 유사하게 감소하면서 더욱 안정된 예측 성능을 보이며 Anomaly Score의 비교를 통해 간접적으로 확인할 수 있다. 즉, 이상 탐지 모델이 더욱 강건해짐을 알 수 있다.




그림 30 학습 데이터 증강 결과(BLR Steam Press.)

정량적으로도 Recall이 약간 향상되어 F1 Score, AUC 기준으로 각각 0.02(%), 0.27(%) 정도 성능이 향상되었다.

Model	Precision	Recall	F1 Score	AUC
Base Case	1.0000	0.9996	0.9998	0.9962
TranAD with data augmentation(TimeGAN)	1.0000	1.0000	1.0000	0.9989

표 8 이상 탐지 결과 (BLR Steam Press.)



## 제 5 항 SOx Scrubber의 SO2 / CO2 비율 이상 탐지 결과

SOx scrubber는 Main Engine의 Load에 관계없이 자체적인 해수 분사 제어를 통해 1.5~3.0 정도의 SO2 / CO2 비율을 안정적으로 유지한다. 하지만 Main Engine의 Load 변화에 따른 과량의 SOx 성분 유입과 파도에 의한 선박의 운동으로 일시적으로 해수 분사가 효과적으로 작용하지 못하는 등 여러 원인으로 CO2 농도(%v/v) 변화에 비해 SO2의 농도(ppm)가 급격히 증가할 수 있다. 시험 데이터의 일부인 그림 31, 그림 32를 살펴보면 17,000초 부근에서 SO2 / CO2 비율이 급격히 증가하여 일시적으로 ECA 기준 제한선까지 상승하는 이상 상태가 나타난다.

Steam의 압력과 마찬가지로 데이터의 분포가 비교적 단순하고 trend가 매우 일정한 경우라서 그림 31과 같이 부족한 실제 데이터만 활용해 학습하더라도 극히 일부 구간을 제외하고는 실제 이상 상태인 구간에 대해서 이상 상태로 잘 판별하고 있다. 다만 부족한 학습 데이터로 인해 예측 시계열이 실제 데이터의 국부적인 특징(local context)을 제대로 포착하지 못하여 다소 불안정한 이상 탐지를 보여주고 있다.

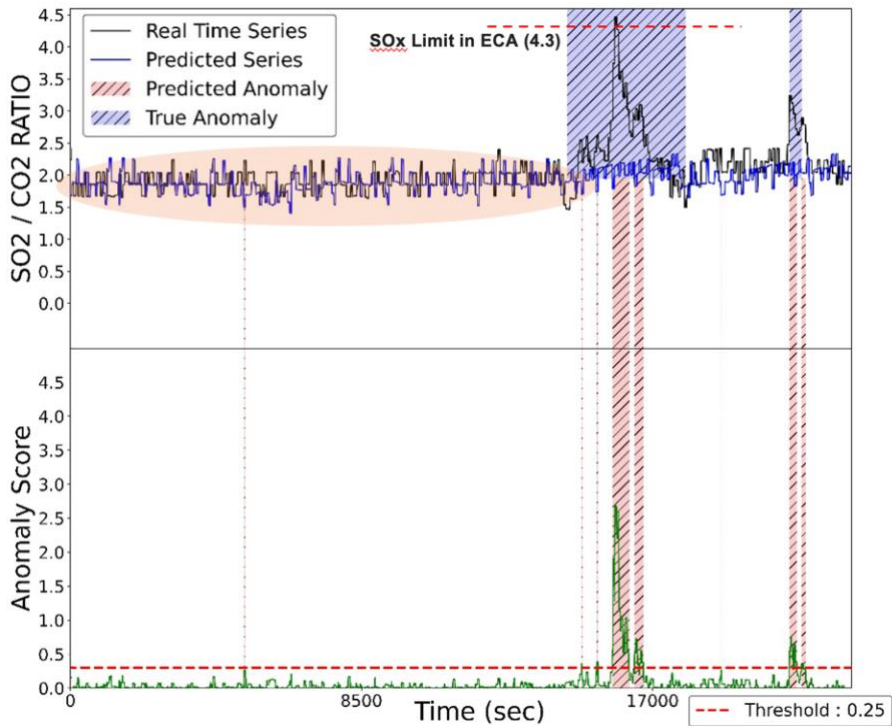


그림 31 TranAD base case(SO2/CO2 Ratio)

하지만 TimeGAN의 합성 데이터로 증강하여 학습한 경우 그림 32와 같이 실제 데이터의 극부적인 특징을 좀 더 정확히 파악해 안정적인 예측 성능을 바탕으로 더욱 안정적으로 실제 이상 상태인 구간에 대해서 이상 상태로 판별한다. 따라서 SO<sub>2</sub>/CO<sub>2</sub> 비율에 대한 이상 탐지 모델의 정확도가 향상됨을 확인할 수 있다.




그림 32 학습 데이터 증강 결과(SO<sub>2</sub>/CO<sub>2</sub> Ratio)

정량적으로는 Recall이 향상되어 F1 Score, AUC 기준으로 각각 0.56(%), 0.53(%) 정도 성능이 향상되었다.

Model	Precision	Recall	F1 Score	AUC
Base Case	0.8118	0.9894	0.8918	0.9739
TranAD with data augmentation(TimeGAN)	0.8129	1.0000	<b>0.8968</b>	<b>0.9791</b>

표 9 이상 탐지 결과 (SO<sub>2</sub>/CO<sub>2</sub> Ratio)

## 제 5 장 요약 및 결론

### 제 1 절 TimeGAN을 활용한 좋은 품질의 다변량 시계열 합성

보안 등의 이유로 접근 가능한 학습 데이터가 부족하거나 새로 건조되어 학습 데이터 자체가 부족한 선박 및 해양플랫폼의 에너지 시스템은 더욱 복잡해져 많은 양의 학습 데이터가 전제되는 딥러닝 기반 다변량 시계열 이상 탐지 모델을 제대로 학습하기 어렵다. 그 대안으로 전통적인 시계열 합성 방법인 random transformation과 pattern mixing을 활용하는 경우 실제 시계열과 쉽게 구별되고 시계열의 내재적 특성을 포착하지 못해 양질의 학습 데이터를 얻지 못한다는 문제점이 있다. 하지만 GAN 기반 generative model의 일종인 TimeGAN을 활용한다면 선박 및 해양플랫폼 에너지 시스템의 실제 센서 데이터의 분포와 매우 유사하고 시간 종속성과 변수 간의 관계도 모두 반영된 좋은 품질의 합성 시계열 센서 데이터를 생성할 수 있으며 효과적으로 학습 데이터를 증강할 수 있다.

### 제 2 절 선박 시스템 이상 탐지에서 학습 데이터 증강 효과 검증

선박 및 해양플랫폼의 대표적인 에너지 시스템 중 하나인 SOx scrubber가 탑재되어 있는 새롭게 건조된 벌크선 에너지 시스템에 대해

센서 데이터가 부족한 상황에서도 이상 탐지 성능 향상을 위해 학습 데이터를 증강시키고 그 효과를 검증했다. TimeGAN으로 좋은 품질의 합성 데이터를 생성하고 학습 데이터를 증강시켜 충분한 학습 데이터를 확보한 뒤, Transformer 기반 다변량 시계열 이상 탐지 모델인 TranAD에 적용한 결과, 기존 데이터로만 학습했을 때보다 trend 예측이 더 정확해지고 분산이 작아지며 시계열의 국부적인 특징까지 더 정확히 파악해 정상 상태를 이상 상태로 판단하는 경우가 거의 없으며 안정적인 예측 및 이상 탐지 성능을 보여주었다. 정량적으로는 Recall이 향상되어 전체 변수에 대해 종합적인 이상 탐지 성능이 F1 Score, AUC 기준으로 각각 1.00(%), 0.70(%) 정도 향상되었다.

Model	Precision	Recall	F1 Score	AUC
Base Case	0.9043	0.9796	0.9404	0.9763
TranAD with data augmentation(TimeGAN)	0.9047	0.9998	<b>0.9498</b>	<b>0.9831</b>

표 10 데이터 증강 유무에 따른 이상 탐지 종합 결과

### 제 3 절 결론

선박 및 해양플랫폼 에너지 시스템의 센서 데이터 수집이 제한적이라도 TimeGAN을 활용해 생성한 좋은 품질의 합성 데이터를 바탕으로 충분한 학습 데이터를 확보하였고, 모델의 capacity가 커서 충분히 많은 학습 데이터가 전제되어야 성능이 좋은 다변량 시계열 이상 탐지 모델의 성능을 최대한 끌어올릴 수 있다는 것을 보여주었다.

## 제 4 절 추후 연구

각 변수에 대해 이상 상태를 정확하게 판단할 수 있다면 어떤 인과 관계에 의해 이상 상태가 어떻게 전파되는지 파악하는 것도 중요하다. 데이터를 기반으로 우선 directed acyclic graph 형태의 causal structure를 파악하고 인과 추론을 통해 어떤 변수가 다른 변수에 어느 정도 영향을 끼치는지 정량적으로 도출하기 위한 연구가 필요할 것이다.

또한 이상 탐지 및 인과 관계 파악 이후 에너지 시스템을 어떻게 제어할 수 있을지 연구하여 기존 제어 모델과 연계하는 것도 필요하다. 더 나아가 변수별로 본격적인 이상 상황이 발생하기 전에 이상 징후를 먼저 포착할 수 있는 연구를 통해 기존 제어 모델과 연계한다면 이상 상황이 애초에 발생하지 않지 않게 하거나 그 정도를 약화시킬 수 있을 것으로 기대된다.

마지막으로 이번 연구에서는 상대적으로 간단하고 직관적인 선박 에너지 시스템에 적용해보았지만 이후 LNG 또는 암모니아 추진 선박의 추진 시스템 또는 LNG와 액화 수소 운반선의 LNG 또는 수소 재액화 시스템, FLNG의 액화 공정과 같은 더욱 복잡한 시스템에 대해서도 이번 연구 프레임워크를 적용해볼 수 있을 것이다.

## 참고 문헌

- [1] Lab021, Monitoring Dashboard, <https://www.vessellink.com>
- [2] Chen, T., Kornblith, S., Norouzi, M., & Hinton, G. (2020, November). A simple framework for contrastive learning of visual representations. In International conference on machine learning (pp. 1597–1607). PMLR.
- [3] Amit Chaudhary, Masked Language Modeling for NLP, <https://amitnness.com/2020/05/data-augmentation-for-nlp/>
- [4] Jackson, P. T., Abarghouei, A. A., Bonner, S., Breckon, T. P., & Obara, B. (2019, June). Style augmentation: data augmentation via style randomization. In CVPR workshops (Vol. 6, pp. 10–11).
- [5] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1–48.
- [6] Wen, Q., Sun, L., Yang, F., Song, X., Gao, J., Wang, X., & Xu, H. (2020). Time series data augmentation for deep learning: A survey. *arXiv preprint arXiv:2002.12478*.
- [7] Iwana, B. K., & Uchida, S. (2021). An empirical survey of data augmentation for time series classification with neural networks. *Plos one*, 16(7), e0254841.
- [8] Esteban, C., Hyland, S. L., & Rätsch, G. (2017). Real-valued (medical) time series generation with recurrent conditional gans. *arXiv preprint arXiv:1706.02633*.
- [9] Gao, X., Deng, F., & Yue, X. (2020). Data augmentation in fault diagnosis based on the Wasserstein generative adversarial network with gradient penalty. *Neurocomputing*, 396, 487–494.

- [10] Lee, H., Kim, C., Jeong, D. H., & Lee, J. M. (2021). Data-driven fault detection for chemical processes using autoencoder with data augmentation. *Korean Journal of Chemical Engineering*, 38(12), 2406–2422.
- [11] Zhang, Y., Zhou, Z., Liu, J., & Yuan, J. (2022). Data augmentation for improving heating load prediction of heating substation based on TimeGAN. *Energy*, 124919.
- [12] Li, J., Liu, Y., & Li, Q. (2022). Generative adversarial network and transfer-learning-based fault detection for rotating machinery with imbalanced data condition. *Measurement Science and Technology*, 33(4), 045103.
- [13] Yoon, J., Jarrett, D., & Van der Schaar, M. (2019). Time-series generative adversarial networks. *Advances in neural information processing systems*, 32.
- [14] Tuli, S., Casale, G., & Jennings, N. R. (2022). TranAD: Deep transformer networks for anomaly detection in multivariate time series data. *arXiv preprint arXiv:2201.07284*.



# Abstract

Jang, Jinkwan

Naval Architecture and Ocean Engineering

The Graduate School

Seoul National University

Recently, with the development of environmental regulations in the international shipping industry and the emergence of Digital Twin technology, real-time monitoring of ships and offshore platforms is gradually spreading. In particular, multivariate time-series anomaly detection based on sensor dataset is a very important technology for real-time monitoring of ships and offshore platforms, where large damages may occur when abnormal states accumulate and lead to accidents. However, due to the characteristics of high-dimensional and time-dependent multivariate time-series data, it is difficult to predict and detect anomalies, and therefore it is necessary to use deep learning technology. As advanced deep learning architectures have invented every year, the accuracy of multivariate time-series anomaly detection has greatly improved, but as the structure of deep learning models becomes more complex, the model's capacity increases and it requires a huge amount of training data to show

stable, optimal performance.

In situations where it is not possible to obtain more real data for training purposes, data synthesis and augmentation techniques can be used as an alternative. However, if conventional time-series data synthesis methods such as random transformation or pattern mixing are used to gain sufficient multivariate time-series data for training, the time dependency may not be properly contained and also the distribution of generated data is significantly different from that of actual data, resulting in a poor quality of the augmented training data. As a result, it may actually degrade the performance of the deep learning model. Therefore, it is necessary to approach the problem by using novel method like deep generative models that can generate high-quality synthetic time-series sensor data that is very similar to the distribution of actual time-series data and contains both the time dependency and the relationship between variables.

This study is for reliable detection of anomalies with high accuracy on the energy system of a diesel engine bulk carrier with an open loop type SOx scrubber, which is one of the representative energy systems of ships and offshore platforms. The selected energy system has the advantage of being intuitive and easy to analyze. Considering the limited access to training data due to

security reasons or the lack of training data itself for various situations in new-build ships, it is necessary to synthesize and augment the training data sufficiently.

High-quality synthetic data generated by TimeGAN for training applied to the TranAD, a Transformer-based multivariate time-series anomaly detection model that currently has the best anomaly detection performance, and verify that it shows more stable prediction and better anomaly detection performance than when it was trained using only existing sensor dataset.

**Keywords : Ships & Offshore Platforms, Energy System, Real-time Monitoring, Multivariate Time Series Synthesis & Augmentation, Multivariate Time Series Anomaly Detection, Performance Improvement**

**Student Number : 2021-25813**