DMQA Open Seminar

Dynamic Threshold in Time Series Anomaly Detection

2023.09.22

Data Mining & Quality Analytics Lab.

이정민









✤ 이정민(JungMin Lee)

- 고려대학교 산업경영공학과 대학원 재학
- Data Mining & Quality Analytics Lab.(김성범 교수님)
- 석박 통합 과정(2022.03~Present)

✤ Research Interest

- Time series Anomaly Detection
- Uncertainty Quantification

✤ Contact

• jungmin9195@korea.ac.kr





Contents

Introduction

- Time Series Data
- Time Series Anomaly Detection

Dynamic Threshold

- Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding(2018, KDD)
- Adaptive Threshold for Outlier Detection on Data Streams(2018, IEEE)
- Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method
 with Dynamic Thresholding(2022, arXiv)

Conclusion





Related Seminar

✤ 시계열 이상치 탐지에 대한 설명과 관련 방법론들을 소개한 세미나





Time Series Data

- ✤ 시계열 데이터
 - 시간 순으로 이루어진 데이터로 다양한 현업에서 지속적으로 생산됨

시간	변수1
1	0.53
2	1.12
3	1.56
T-2	0.88
T-1	0.79
Т	0.86

시간	변수1	변수2		변수m
1	0.53	2.39	•••	0.19
2	1.12	1.54	•••	0.53
3	1.56	2.01	•••	0.33
:		:	•••	:
T-2	0.88	1.98	•••	0.34
T-1	0.79	2.34	•••	0.47
Т	0.86	2.56	•••	0.98

[단변량]

[다변량]

Time Series Data

✤ 시계열 데이터의 이상치

• 시계열 데이터의 이상치를 새롭게 정의

Revisiting Time Series Outlier Detection: Definitions and Benchmarks

Kwei-Herng Lai Rice University khlai@rice.edu

Daochen Zha Rice University daochen.zha@rice.edu Junjie Xu Penn State University jmx5097@psu.edu

Yue Zhao Carnegie Mellon University zhaoy@cmu.edu Guanchu Wang Rice University hegsns@rice.edu Xia Hu

Rice University xiahu@rice.edu

Lai, K. H., Zha, D., Xu, J., Zhao, Y., Wang, G., & Hu, X. (2021, June). Revisiting time series outlier detection: Definitions and benchmarks. In *Thirty-fifth conference on neural information processing systems datasets and benchmarks track (round 1).*



Time Series Data

- ✤ 시계열 데이터의 이상치
 - 기존: Point / Contextual / Collective



Lai, K. H., Zha, D., Xu, J., Zhao, Y., Wang, G., & Hu, X. (2021, June). Revisiting time series outlier detection: Definitions and benchmarks. In *Thirty-fifth conference on neural information processing systems datasets and benchmarks track (round 1).*



- ✤ 시계열 데이터의 이상치
 - 기존 이상치 기준을 보다 세분화하여 정의





- ✤ 시계열 데이터의 이상치
 - Point Global Anomaly





https://github.com/datamllab/tods/tree/benchmark

- ✤ 시계열 데이터의 이상치
 - Point Contextual Anomaly





https://github.com/datamllab/tods/tree/benchmark

- ✤ 시계열 데이터의 이상치
 - Pattern Shapelet Anomaly





https://github.com/datamllab/tods/tree/benchmark



- ✤ 시계열 데이터의 이상치
 - Pattern Seasonal Anomaly





https://github.com/datamllab/tods/tree/benchmark

- ✤ 시계열 데이터의 이상치
 - Pattern Trend Anomaly







Time Series Anomaly Detection

✤ 시계열 이상치 탐지



Choi, K., Yi, J., Park, C., & Yoon, S. (2021). Deep learning for anomaly detection in time-series data: review, analysis, and guidelines. IEEE Access, 9, 120043-120065.



Time Series Anomaly Detection

✤ 시계열 이상치 탐지

- 평가 데이터의 이상치 스코어가 특정 threshold보다 크면 이상, 작으면 정상으로 판단
- Threshold를 수동으로 설정할 경우, 전문가의 도메인 지식 필요
- Fixed threshold의 경우 데이터의 특성을 반영하기 어려움





Time Series Anomaly Detection

✤ 시계열 이상치 탐지

• 데이터의 특성을 반영하여 threshold를 시간에 따라 **dynamic**하게 적용한다면, 보다 향상된 이상치 탐지가 가능할 것



ΔMQΛ





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

- Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding (2018, KDD)
 - Spacecraft에 적합한 모델링 방식과 통계적 기법을 활용한 nonparametric dynamic threshold 기법 제안

Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Kyle Hundman NASA Jet Propulsion Laboratory California Institute of Technology kyle.a.hundman@jpl.nasa.gov Valentino Constantinou NASA Jet Propulsion Laboratory California Institute of Technology vconstan@jpl.nasa.gov Christopher Laporte NASA Jet Propulsion Laboratory California Institute of Technology christopher.d.laporte@jpl.nasa.gov

Ian Colwell NASA Jet Propulsion Laboratory California Institute of Technology ian.colwell@jpl.nasa.gov Tom Soderstrom NASA Jet Propulsion Laboratory California Institute of Technology tom.soderstrom@jpl.nasa.gov

Hundman, K., Constantinou, V., Laporte, C., Colwell, I., & Soderstrom, T. (2018, July). Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining* (pp. 387-395).



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

- ✤ 연구 배경
 - Spacecraft는 수천개의 시계열 채널을 가지고 있는 매우 복잡하고 비싼 장비임
 - 잠재적인 위험을 감지하지 못하면 큰 손실을 야기할 수 있음
 - 채널 별 LSTM 모델링 & nonparametric dynamic threshold 기법을 활용하여 효율적인 이상치 탐지를 수행 하고자 함



Sensor 1 Sensor 2 Label Time Sensor d ... 정상 1.93 0.58 1.99 Time 1 ... 정상 Time 2 1.47 0.44 2.01 ÷ ÷ : : ÷ ... 이상 Time n 1.55 0.02 1.36 ...

Model 1

Detect





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

- ✤ 연구 배경
 - Spacecraft는 수천개의 시계열 채널을 가지고 있는 매우 복잡하고 비싼 장비임
 - 잠재적인 위험을 감지하지 못하면 큰 손실을 야기할 수 있음
 - 채널 별 LSTM 모델링 & nonparametric dynamic threshold 기법을 활용하여 효율적인 이상치 탐지를 수행 하고자 함



Time	Sensor 1	Sensor 2	 Sensor d	Label
Time 1	1.93	0.58	 1.99	정상
Time 2	1.47	0.44	 2.01	정상
:	:	:	 :	:
Time n	1.55	0.02	 1.36	이상

Model 2

Detect





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

- ✤ 연구 배경
 - Spacecraft는 수천개의 시계열 채널을 가지고 있는 매우 복잡하고 비싼 장비임
 - 잠재적인 위험을 감지하지 못하면 큰 손실을 야기할 수 있음
 - 채널 별 LSTM 모델링 & nonparametric dynamic threshold 기법을 활용하여 효율적인 이상치 탐지를 수행 하고자 함



Time	Sensor 1	Sensor 2	 Sensor d	Label
Time 1	1.93	0.58	 1.99	정상
Time 2	1.47	0.44	 2.01	정상
:	:	:	 :	:
Time n	1.55	0.02	 1.36	이상

Model d

Detect





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

✤ 모델링

- 각 채널 별로 LSTM 모델을 구축
 - > 고차원의 시계열 데이터에서 하나 혹은 적은 수의 모델을 사용하는 것은 성능 저하를 야기할 수 있음
 - ▶ 채널 레벨에서의 이상 패턴을 확인할 수 있음
- Command 정보가 각 스텝마다 one-hot encoding 되어 시계열 정보와 같이 입력 값으로 구성 됨





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

✤ 모델링

- 각 채널 별로 LSTM 모델을 구축
 - > 고차원의 시계열 데이터에서 하나 혹은 적은 수의 모델을 사용하는 것은 성능 저하를 야기할 수 있음
 - ▶ 채널 레벨에서의 이상 패턴을 확인할 수 있음
- Command 정보가 각 스텝마다 one-hot encoding 되어 시계열 정보와 같이 입력 값으로 구성 됨





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

✤ 모델링

- 각 채널 별로 LSTM 모델을 구축
 - > 고차원의 시계열 데이터에서 하나 혹은 적은 수의 모델을 사용하는 것은 성능 저하를 야기할 수 있음
 - ▶ 채널 레벨에서의 이상 패턴을 확인할 수 있음
- Command 정보가 각 스텝마다 one-hot encoding 되어 시계열 정보와 같이 입력 값으로 구성 됨

Time	Sensor 1	Sensor 2	 Sensor d	Label
Time 1	1.93	0.58	 1.99	정상
Time 2	1.47	0.44	 2.01	정상
:	:	:	 :	:
Time n	1.55	0.02	 1.36	이상

hidden vector



Time	CI 1	CI 2	 CI k
Time 1	0	0	 1
Time 2	0	0	 1
:	:	:	 :
Time n	0	1	 0

[Input Sequence Length: 3 / Prediction Length: 1]



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

- 여러 환경적 요인들로 인해 급속하게 입력 값들이 변하기 때문에, 이에 적합한 dynamic threshold 기법 제안
- 연산량이 크지 않고 에러 분포의 가정이 필요 없는 nonparametric dynamic threshold 기법 제안



[정규 분포]



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

- 각 채널 별 이상 sequence가 하나 이상 포함된 5일 단위 timeframe 형성
- Timeframe 단위로 학습 및 평가



[Test Time Frame]



Copyright © 2023, All rights reserved.



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

- 값이 급속하게 변하는 경우 LSTM 예측 성능이 저하될 수 있음
 - ▶ Exponential –Weighted Moving Average(EWMA)를 통해 prediction error를 smoothing 시킴(e_s)
- 현실에서는 충분한 양의 label을 확보하기 어려움
 - ➢ Unsupervised 방식으로 threshold 설정

Error history:
$$\boldsymbol{e}_{s} = [e_{s}^{t-h}, ..., e_{s}^{t-3}, e_{s}^{t-2}, e_{s}^{t-1}, e_{s}^{t}]$$

$$\Delta \mu(e_s) = \mu(e_s) - \mu(\{e_s \in e_s | e_s < \epsilon\})$$
$$\Delta \sigma(e_s) = \sigma(e_s) - \sigma(\{e_s \in e_s | e_s < \epsilon\})$$
$$e_a = (\{e_s \in e_s | e_s > \epsilon\})$$

 $E_{seq} = continuous \ sequences \ of \ e_a \in e_a$

$$\epsilon = \operatorname{argmax}(\epsilon) = \frac{\Delta \mu(e_s) / \mu(e_s) + \Delta \sigma(e_s) / \sigma(e_s)}{|e_a| + |E_{seq}|^2}$$

$$\epsilon = \mu(e_s) + z\sigma(e_s)$$
$$(\epsilon = [\epsilon_2, \epsilon_{2.5}, \dots, \epsilon_{10}])$$



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

• 목적식을 최대화하는 threshold 탐색

Error history: $e_s = [e_s^{t-h}, ..., e_s^{t-3}, e_s^{t-2}, e_s^{t-1}, e_s^t]$

$$\Delta \mu(e_s) = \mu(e_s) - \mu(\{e_s \in e_s | e_s < \epsilon\})$$

$$\Delta \sigma(e_s) = \sigma(e_s) - \sigma(\{e_s \in e_s | e_s < \epsilon\})$$

$$e_a = (\{e_s \in e_s | e_s > \epsilon\})$$

older 판단된 경우
$$E_{seq} = continuous \ sequences \ of \ e_a \in e_a$$

연속된 이상 sequence

$$\epsilon = argmax(\epsilon) = \frac{\Delta \mu(e_s) / \mu(e_s) + \Delta \sigma(e_s) / \sigma(e_s)}{|e_a| + |E_{seq}|^2}$$

$$\boldsymbol{\epsilon} = \boldsymbol{\mu}(\boldsymbol{e}_s) + \boldsymbol{z}\boldsymbol{\sigma}(\boldsymbol{e}_s)$$
$$(\boldsymbol{\epsilon} = [\boldsymbol{\epsilon}_2, \boldsymbol{\epsilon}_{2.5}, \dots, \boldsymbol{\epsilon}_{10}])$$

저사이는 파다되 겨이



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

• 목적식을 최대화하는 threshold 탐색



$$\epsilon = \operatorname{argmax}(\epsilon) = \frac{\Delta \mu(e_s) / \mu(e_s) + \Delta \sigma(e_s) / \sigma(e_s)}{|e_a| + |E_{seq}|^2}$$

정상으로 판단된 경우 $\Delta \mu(e_s) = \mu(e_s) - \mu(\{e_s \in e_s | e_s < \epsilon\})$ $\Delta \sigma(e_s) = \sigma(e_s) - \sigma(\{e_s \in e_s | e_s < \epsilon\})$ $e_a = (\{e_s \in e_s | e_s > \epsilon\})$ older Point Point



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

• 목적식을 최대화하는 threshold 탐색



$$\epsilon = \operatorname{argmax}(\epsilon) = \frac{\Delta \mu(e_s) / \mu(e_s) + \Delta \sigma(e_s) / \sigma(e_s)}{|e_a| + |E_{seq}|^2} \uparrow$$

정상으로 판단된 경우 $\Delta \mu(e_s) = \mu(e_s) - \mu(\{e_s \in e_s | e_s < \epsilon\})$ $\Delta \sigma(e_s) = \sigma(e_s) - \sigma(\{e_s \in e_s | e_s < \epsilon\})$ $e_a = (\{e_s \in e_s | e_s > \epsilon\})$ 이상으로 판단된 경우 $E_{seq} = continuous sequences of <math>e_a \in e_a$ 연속된 이상 sequence





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

• 목적식을 최대화하는 threshold 탐색



$$\epsilon = \operatorname{argmax}(\epsilon) = \frac{\Delta \mu(e_s) / \mu(e_s) + \Delta \sigma(e_s) / \sigma(e_s)}{|e_a| + |E_{seq}|^2} \quad \uparrow$$

정상으로 판단된 경우 $\Delta \mu(e_s) = \mu(e_s) - \mu(\{e_s \in e_s | e_s < \epsilon\})$ $\Delta \sigma(e_s) = \sigma(e_s) - \sigma(\{e_s \in e_s | e_s < \epsilon\})$ $e_a = (\{e_s \in e_s | e_s > \epsilon\})$ 이상으로 판단된 경우 $E_{seq} = continuous sequences of <math>e_a \in e_a$ 연속된 이상 sequence



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

• 목적식을 최대화하는 threshold 탐색





Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Dynamic Error Thresholds

• 각 이상 sequence에서 이상의 severity 도출



[Severity]

$$s^{i} = \frac{max(e^{i}_{seq}) - argmax(\epsilon)}{\mu(e_{s}) + \sigma(e_{s})}$$



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

- Mitigating False Positives Learning from History
 - 실시간 연산이 가능하면서 false positive를 줄이기 위한 기법 제안
 - 같은 채널에서 비슷한 severity를 가진 이상은 자주 발생하지 않음
 - 각 채널별로 *sⁱ* < *s_{min}*인 경우, **정상으로 재분류**



$$\epsilon = \operatorname{argmax}(\epsilon) = \frac{\Delta \mu(e_s) / \mu(e_s) + \Delta \sigma(e_s) / \sigma(e_s)}{|e_a| + |E_{seq}|^2}$$



$$s^{i} = \frac{max(e^{i}_{seq}) - argmax(\epsilon)}{\mu(e_{s}) + \sigma(e_{s})}$$



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Mitigating False Positives – Pruning Anomalies

- 실시간 연산이 가능하면서 false positive를 줄이기 위한 기법 제안
- 이상 sequence step 사이의 error 감소율이 특정 값 p 보다 작으면 정상으로 재분류



Hundman, K., Constantinou, V., Laporte, C., Colwell, I., & Soderstrom, T. (2018, July). Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining (pp. 387-395).



Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding

Experiments

- LSTM 모델을 고정으로 사용
- Spacecraft 도메인에서는 False alarm rate을 중요하게 여김 \rightarrow $F_{0.5}$ score 사용

Thresholding Approach	Precision	Recall	$F_{0.5}$ score
Non-Parametric w/ Pru	uning $(p = 0)$).13)	
MSL	92.6%	69.4%	0.69
SMAP	85.5%	85.5%	0.71
Total	87.5%	80.0%	0.71
Non-Parametric w/out	Pruning (p	= 0)	
MSL	75.8%	69.4%	0.61
SMAP	43.0%	92.8%	0.44
Total	48.9%	84.8%	0.47
Gaussian Tail ($\epsilon_{norm} =$	0.0001)		
MSL	84.2%	44.4%	0.54
SMAP	88.5%	78.3%	0.71
Total	87.5%	66.7%	0.66
Gaussian Tail ($\epsilon_{norm} =$	0.01)		
MSL	61.3%	52.8%	0.48
SMAP	82.4%	81.2%	0.68
Total	75.8%	71.4%	0.62
Gaussian Tail w/ Pruni	ng (enorm =	= 0.01, p	= 0.13)
MSL	88.2%	41.7%	0.54
SMAP	92.7%	73.9%	0.71
Total	91.7%	62.9%	0.66

Table 2: Results for each spacecraft using LSTM predictions and various ap-



Figure 4: Plot showing comparison of overall precision and recall results for parametric approach and approach presented in this paper (labeled 'Nonparametric') with various parameter settings.

Hundman, K., Constantinou, V., Laporte, C., Colwell, I., & Soderstrom, T. (2018, July). Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining* (pp. 387-395).



Adaptive Threshold for Outlier Detection on Data Streams

- Anomaly Threshold for Outlier Detection on Data Streams(2018, IEEE)
 - Concept drift가 발생할 때, 슬라이딩 윈도우 기법과 가설 검정을 활용한 adaptive threshold 기법 제안
 - **VATU**(Variable window size Adaptive Threshold Updating)

Adaptive Threshold for Outlier Detection on Data Streams

James P. Clark Centralized Super Computing Facility Lockheed Martin Herndon, V.A., USA james.p.clark@lmco.com Zhen Liu School of Medical Inofrmation Engineering Guangdon Pharmaceutical University Guangzhou, China liu.zhen@gdpu.edu.cn Nathalie Japkowicz Computer Science Department American University Washington D.C., USA japkowic@american.edu

Clark, J., Liu, Z., & Japkowicz, N. (2018, October). Adaptive threshold for outlier detection on data streams. In 2018 IEEE 5th International Conference on Data Science and Advanced Analytics (DSAA) (pp. 41-49). IEEE.





Adaptive Threshold for Outlier Detection on Data Streams

- Concept drift
 - 데이터의 분포 자체가 변하는 경우



Copyright © 2023, All rights reserved.



- Concept drift
 - 데이터의 분포 자체가 변하는 경우
 - 이 때 고정 threshold를 사용하면, 분포의 변화를 반영할 수 없음





- ✤ VATU Training
 - 정상 데이터를 잘 복원하도록 모델 학습





- VATU Threshold update
 - 검증 데이터의 이상치 스코어를 사용하여 초기 threshold 설정($\mu(z_{w1}) + 2\sigma(z_{w1})$)





- VATU Threshold update
 - Window size T를 채울 때까지, 평가 데이터(*x*_t)의 이상치 스코어를 *z*_{w1}, *z*_{w2}, *t*_w에 저장
 - x_t의 이상치 스코어가 초기 threshold보다 크면 이상, 그렇지 않으면 정상으로 판단





- VATU Threshold update
 - Window size T를 채울 때까지, 평가 데이터(*xt*)의 이상치 스코어를 *zw*1, *zw*2, *tw*에 저장
 - x_t의 이상치 스코어가 초기 threshold보다 크면 이상, 그렇지 않으면 정상으로 판단





- VATU Threshold update
 - Window size T를 채울 때까지, 평가 데이터(*x*_t)의 이상치 스코어를 *z*_{w1}, *z*_{w2}, *t*_w에 저장
 - x_t의 이상치 스코어가 초기 threshold보다 크면 이상, 그렇지 않으면 정상으로 판단





- VATU Threshold update
 - Window size T를 채울 때까지, 평가 데이터(*x*_t)의 이상치 스코어를 *z*_{w2}, *t*_w에 저장
 - x_t의 이상치 스코어가 초기 threshold보다 크면 이상, 그렇지 않으면 정상으로 판단





Adaptive Threshold for Outlier Detection on Data Streams

VATU – Threshold update

- *z*_{w2}의 길이가 T이상이 되면, *z*_{w1}와 *z*_{w2}의 평균에 대한 가설 검정(z-test) 수행
 - ▶ 귀무가설: *z*_{w1}와 *z*_{w2}의 평균이 같을 것이다
 - ▶ p-value < 유의 수준: 귀무가설 기각 / p-value > 유의 수준: 귀무가설 채택

 Z_{w2}

0.412

0.278

0.279

0.318

0.352

[p-value < 유의 수준]

1. z_{w1} 에 z_{w2} 대입 후 z_{w2} 초기화



_	_	_		
	_	_		
		_		





Adaptive Threshold for Outlier Detection on Data Streams

VATU – Threshold update

- *z*_{w2}의 길이가 T이상이 되면, *z*_{w1}와 *z*_{w2}의 평균에 대한 가설 검정(z-test) 수행
 - ▶ 귀무가설: *z*_{w1}와 *z*_{w2}의 평균이 같을 것이다
 - ▶ p-value < 유의 수준: 귀무가설 기각 / p-value > 유의 수준: 귀무가설 채택

[p-value < 유의 수준]

1. z_{w1} 에 z_{w2} 대입 후 z_{w2} 초기화







Adaptive Threshold for Outlier Detection on Data Streams

- VATU Threshold update
 - *z*_{w2}의 길이가 T이상이 되면, *z*_{w1}와 *z*_{w2}의 평균에 대한 가설 검정(z-test) 수행
 - ▶ 귀무가설: *z*_{w1}와 *z*_{w2}의 평균이 같을 것이다
 - ▶ p-value < 유의 수준: 귀무가설 기각 / p-value > 유의 수준: 귀무가설 채택





- *1.* z_{w1} 에 z_{w2} 대입 후 z_{w2} 초기화
- *2.* t_w **Ξ** Threshold update(μ + 2 σ)
- *3.* t_w길이 T 만큼의 앞 부분 삭제

۰T



- VATU Threshold update
 - *z*_{w2}의 길이가 T이상이 되면, *z*_{w1}와 *z*_{w2}의 평균에 대한 가설 검정(z-test) 수행
 - ▶ 귀무가설: *z*_{w1}와 *z*_{w2}의 평균이 같을 것이다
 - ▶ p-value < 유의 수준: 귀무가설 기각 / p-value > 유의 수준: 귀무가설 채택

[p-value < 유의 수준]







- *1.* z_{w1} 에 z_{w2} 대입 후 z_{w2} 초기화
- *2.* t_w **Ξ** Threshold update(μ + 2 σ)
- 3. t_w길이 T 만큼의 앞 부분 삭제
- 4. z_{w2} 에 다시 T 만큼 score 저장



Adaptive Threshold for Outlier Detection on Data Streams

VATU – Threshold update

- *z*_{w2}의 길이가 T이상이 되면, *z*_{w1}와 *z*_{w2}의 평균에 대한 가설 검정(z-test) 수행
 - ▶ 귀무가설: *z*_{w1}와 *z*_{w2}의 평균이 같을 것이다
 - ▶ p-value < 유의 수준: 귀무가설 기각 / p-value > 유의 수준: 귀무가설 채택

[p-value > 유의 수준]

Z_{W2}
0.412
0.278
0.279
0.318
0.352



1. Zw2 첫 번째 스코어 제거



Adaptive Threshold for Outlier Detection on Data Streams

- VATU Threshold update
 - *z*_{w2}의 길이가 T이상이 되면, *z*_{w1}와 *z*_{w2}의 평균에 대한 가설 검정(z-test) 수행
 - ▶ 귀무가설: *z*_{w1}와 *z*_{w2}의 평균이 같을 것이다
 - ▶ p-value < 유의 수준: 귀무가설 기각 / p-value > 유의 수준: 귀무가설 채택

[p-value > 유의 수준]

Z
0.412
0.278
0.279
0.318

1. z_{w2} 첫 번째 스코어 제거

2. 순차적으로 가설 검정 진행





- VATU Threshold update
 - t_w의 길이가 threshold window size(M)으로 나눠 떨어지면 threshold update
 - t_w 의 길이가 upper bound 보다 크면 t_w 첫 번째 스코어 제거



Adaptive Threshold for Outlier Detection on Data Streams

✤ Experiments

- 두개의 artificial dataset 사용
- 사용 모델: Autoencoder, LOF

Algorithm	FMeasure	False Alarm
VATU(AE)	.935	.0026
FATU (500, AE)	.843	.005
FATU (100, AE)	.934	.0006
Baseline (AE)	.275	.585
VATU (LOF)	.887	.0064
FAIU (500, LOF)	.911	.0034
FATU (100, LOF)	.881	.0062
Baseline (LOF)	.396	.339

TABLE	I: Artificial	Data Set	1
-------	---------------	----------	---

Algorithm	FMeasure	False Alarm
VATU (AE)	.887	.0064
FATU (500, AE)	.911	.0034
FATU (100, AE)	.881	.0062
Baseline(AE)	.396	.339
VATU (LOF)	.922	.005
FATU (500, LOF)	.923	.006
FATU (100, LOF)	.908	.0062
Baseline(LOF)	.303	.511

TABLE II: Artificial Data Set 2

Clark, J., Liu, Z., & Japkowicz, N. (2018, October). Adaptive threshold for outlier detection on data streams. In 2018 IEEE 5th International Conference on Data Science and Advanced Analytics (DSAA) (pp. 41-49). IEEE.



Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

- Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding(2022, arXiv)
 - 무인항공기 데이터에서의 이상치 탐지 자동화를 위한 dynamic threshold 기법 제안

Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

Victoria Bell¹, Divish Rengasamy², Benjamin Rothwell^{2,*} and Grazziela P Figueredo³

- ¹ School of Computer Science, The University of Nottingham, Nottingham, NG8 1BB, UK; Victoria.Bell2@nottingham.ac.uk
- ² Gas Turbine and Transmissions Research Centre, The University of Nottingham, NG7 2RD, UK; divish.rengasamy@nottingham.ac.uk
- ³ The Advanced Data Analysis Centre, The University of Nottingham, Nottingham NG8 1BB, UK; grazziela.figueredo@nottingham.ac.uk
- * Correspondence: benjamin.rothwell@nottingham.ac.uk



Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

✤ 연구 배경

- 항공 기술이 발달됨에 따라, 무인 항공기가 상업 및 군용에서 국제적으로 통합되고 있음
- 안전성 향상, 운영 비용 절감을 위해 무인 항공기에서의 이상 탐지는 점점 중요해짐
- 이에 적합한 dynamic threshold 기법을 제안



Time	Sensor 1	Sensor 2	•••	Sensor d	Label
Time 1	1.93	0.58		1.99	정상
Time 2	1.47	0.44		2.01	정상
Time n	1.55	0.02		1.36	이상





Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

✤ 모델링

- Single Autoencoder는 큰 재구축 오차를 야기할 수 있기 때문에 LSTM Stacked Autoencoder 사용
- 입력 sequence의 역순으로 복원



[Single LSTM Autoencoder]



Encoder LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM \rightarrow LSTM

Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

- ✤ 모델링
 - Single Autoencoder는 큰 재구축 오차를 야기할 수 있기 때문에 LSTM Stacked Autoencoder 사용







Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

- ✤ 모델링
 - 기존 연구들은 손실 함수로 MSE loss(재구축 오차) 사용



A DMQA

Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

- ✤ 모델링
 - 기존 연구들은 손실 함수로 MSE loss(재구축 오차) 사용
 - Dynamic Weighted Loss Function: 더 큰 loss를 도출하는 샘플에 더 큰 가중치를 적용



$$L(x_i, x_i^i) = D(x_i, x_i') * MSE(x_i, x_i')$$
$$D(x_i, x_r) = \begin{cases} \frac{|x_i - x_i'|}{2} & \text{if } |x_i - x_i'| < C\\ |x_i - x_i'| & \text{otherwise} \end{cases}$$

Rengasamy, D., Jafari, M., Rothwell, B., Chen, X., & Figueredo, G. P. (2020). Deep learning with dynamically weighted loss function for sensor-based prognostics and health management. Sensors, 20(3), 723.



Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

Dynamic Threshold

- 이상치 스코어(재구축 오차)의 연속적인 정보를 반영할 수 있는 dynamic threshold 기법 제안
- 이전 시점 이상치 스코어들의 기초 통계량을 활용한 dynamic threshold 기법
- T_n : Dynamic Threshold, x_n : Reconstruction loss





Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding

✤ Experiments

- UAV 도메인에 해당하는 데이터셋 한 가지 사용
- Dynamic Threshold(DT), Dynamic Weighted loss function(DW)의 유무에 따른 실험

	Precision	Recall	Accuracy	Detection Delay (seconds)
LSTM-AE + ST	0.736	0.721	0.752	2.426
	±0.09	±0.17	±0.11	±1.83
LSTM-AE + DT	0.770	0.747	0.809	0.504
	± 0.08	±0.12	±0.10	± 0.55
LSTM-AE + DT + DW	0.793	0.735	0.821	0.522
	± 0.08	±0.13	± 0.11)	±0.56

Bell, V., Rengasamy, D., Rothwell, B., & Figueredo, G. P. (2022). Anomaly detection for unmanned aerial vehicle sensor data using a stacked recurrent autoencoder method with dynamic thresholding. arXiv preprint arXiv:2203.04734.



Conclusion







Conclusion

Conclusion

- Detecting Spacecraft Anomalies Using LSTMs and Nonparametric Dynamic Thresholding
 - Spacecraft 분야에 적합한 모델링 방식과 dynamic threshold 및 false positive를 줄이는 기법 제안
- Anomaly Threshold for Outlier Detection on Data Streams
 - Concept drift가 발생할 때, 슬라이딩 윈도우 기법과 가설 검정을 활용한 adaptive threshold 기법 제안
- Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding
 - 무인항공기 데이터에서의 이전 시점 이상치 스코어의 기초 통계량을 활용한 dynamic threshold 기법 제안



References







References

- Lai, K. H., Zha, D., Xu, J., Zhao, Y., Wang, G., & Hu, X. (2021, June). Revisiting time series outlier detection: Definitions and benchmarks. In *Thirty-fifth conference on neural information processing systems datasets and benchmarks track (round 1).*
- Choi, K., Yi, J., Park, C., & Yoon, S. (2021). Deep learning for anomaly detection in time-series data: review, analysis, and guidelines. IEEE Access, 9, 120043-120065.
- Hundman, K., Constantinou, V., Laporte, C., Colwell, I., & Soderstrom, T. (2018, July). Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining (pp. 387-395).
- Clark, J., Liu, Z., & Japkowicz, N. (2018, October). Adaptive threshold for outlier detection on data streams. In 2018 IEEE
 5th International Conference on Data Science and Advanced Analytics (DSAA) (pp. 41-49). IEEE.
- Bell, V., Rengasamy, D., Rothwell, B., & Figueredo, G. P. (2022). Anomaly detection for unmanned aerial vehicle sensor data using a stacked recurrent autoencoder method with dynamic thresholding. *arXiv preprint arXiv:2203.04734*.
- Rengasamy, D., Jafari, M., Rothwell, B., Chen, X., & Figueredo, G. P. (2020). Deep learning with dynamically weighted loss function for sensor-based prognostics and health management. *Sensors*, *20*(3), 723.



고맙습니다

