

결함 데이터가 필요치 않는 비지도 학습 기반 차량 센서 고장 진단 알고리즘 개발

조경호¹⁾ · 유승한²⁾ · 안창선^{*1)}

부산대학교 기계공학부¹⁾ · 한국기술교육대학교 기계공학부²⁾

Fault Diagnosis Algorithm for Vehicle Sensors Based on Unsupervised Learning without Requiring Fault Data Collection

Gyeongho Cho¹⁾ · Seung-Han You²⁾ · Changsun Ahn^{*1)}

¹⁾School of Mechanical Engineering, Pusan National University, Busan 46241, Korea

²⁾School of Mechanical Engineering, Korea University of Technology and Education, Chungnam 31253, Korea

(Received 16 October 2023 / Revised 20 November 2023 / Accepted 21 November 2023)

Abstract : This paper presents a new approach to fault detection in vehicle sensors that is not dependent on specific vehicle dynamics models. The proposed technique utilizes easily accessible normal signal data, thus eliminating the need for expensive fault data collection methods. It focuses on a discriminator, which is developed by using Generative Adversarial Networks(GANs), that differentiates between genuine sensor signals and synthetic signals generated by a signal generator. This discriminator acts as a fault detection mechanism that helps identify faulty sensors. This study presents the GAN-based development process, neural network structures, data collection methods, and validation procedures on fault detection. Validation through simulation with CarSim demonstrates the feasibility of designing fault detection algorithms without having to collect fault data.

Key words : Fault detection(결함탐지), GAN(적대적생성모델), Anomaly detection(이상치 탐지), Vehicle sensors(센서), Autonomous driving(자율주행), ADAS(운전자 보조 시스템)

1. 서론

수십년간 차량에 안전을 위해 다양한 Advanced Driver Assistance System(ADAS) 기술이 개발되어 왔다. 우리나라의 경우 Anti-Lock Breaking System(ABS) 및 Electronic Stability Control(ESC) 탑재를 법적으로 강제하고 있으며,¹⁾ Lane Keep Asistant System(LKAS)와 Adaptive Cruise Control(ACC)등의 ADAS 장착률이 올라가고 있다.²⁾ 또한 최근 자율주행에 많은 투자가 이루어지고 기술 개발이 진행되고 있다. 대표적으로 테슬라는 오토파일럿이라는 이름으로 자율주행 기능을 상용화하여 판매하고 있고, 다른 자동차 회사들도 자율주행 기능이 포함된 자동차를 판매하고 있다.³⁾

ADAS와 자율주행 기술은 많은 센서와 액추에이터가 필요하다. Inertial Measurement Unit(IMU), Global Positioning

System(GPS) 등 차량의 운동상태와 거동을 측정하기 위한 센서, 카메라, 레이더 등과 같이 주변 환경을 측정하기 위한 센서, 가감속 및 조향을 제어하기 위한 액추에이터 등이 탑재 되어있다. 따라서 센서와 액추에이터의 결함은 운전자의 안전에 치명적인 영향을 미칠 수 있으며, 어떤 센서가 결함이 있는지 여부를 아는 것, 즉 결함 검출 기술은 안전한 자율주행차 설계에 매우 중요하다. 결함 검출 연구는 모델 기반 검출 방식^{4,9)}과 신호 기반 검출 방식^{10,11)} 크게 두가지로 나뉜다. 모델 기반 검출 방식은 동적 모델을 이용하여 센서 값을 추정하고 이를 측정값과 비교하여 결함여부를 판단하는 방식이다. 이러한 모델기반 검출 방식은 해당 센서 신호에 대한 동적 모델이 필요하기 때문에 다수의 센서 신호에 대한 결함 검출보다 개별 센서 신호별로 결함을 검출할 때 주로 사용된

*Corresponding author, E-mail: sunahn@pusan.ac.kr

[†]This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

다. 예를 들면 요각속도 센서,^{4,7)} 차량 속도 센서,^{12,13)} 조향각 센서, 가속도 센서,^{7,13-16)} 휠 속도 센서,^{5,13)} GPS^{13,15)} 의 결합 검출에 모델 기반 방식을 활용한 많은 연구들이 있다. 또한, 결합 여부를 검출하는 것뿐 아니라 결합이 있는 센서가 측정해야 할 정상적인 값을 대신 추정해주는 방법에 대한 연구들도¹⁵⁻¹⁷⁾ 존재한다.

신호 기반 결합 검출 방법은 모델 없이 신호처리 기법만을 이용하여 결합을 검출하는 방식이다. 이 방식은 모델이 필요하지 않다는 장점이 있지만, 결합 판단 기준 및 지표 설정 과정 중에 설계자가 개입되어야 하므로 검출 성능 및 강건성 등이 설계자의 역량에 많이 영향을 받는다.

최근 들어 인공지능 기법이 발달하면서, 딥러닝을 이용하여 결합을 검출하는 연구가 많아지고 있다. 딥러닝을 기반 결합 검출 기법은 신호 기반 결합 검출 방식으로 일종으로 분류될 수 있지만, 기존의 방식과는 달리 설계자의 지표 설정이나 검출 기준이 필요치 않고 딥러닝 기법에 의하여 내부적으로 자동 설정된다는 장점이 있다. 딥러닝을 활용한 결합 검출은 지도학습 기반 방식^{18,19)}과 비지도 학습 기반 방식^{20,21)} 크게 두가지로 나뉜다. 지도 학습 기반으로 결합 검출 알고리즘을 개발하기 위해서는 정상데이터와 결합데이터가 모두 있어야 하며 충분한 양의 결합데이터가 필요하다는 어려움이 있다. 또한 충분한 데이터가 확보되더라도 학습에 이용된 데이터 이외의 상황에 대하여서는 검출 성능을 보장하지 못한다는 단점이 있다.

이런 단점을 보완하기 위해 학습에 사용된 데이터 이외의 경우에도 성능이 어느정도 보장될 수 있도록 비지도 학습 기법을 결합 검출에 활용하는 연구가 늘고 있다. Generative Adversarial Networks(GAN)²²⁾ 기법은 유사 데이터를 생성하여 학습에 이용하여 검출 및 판단에 강건성을 높일 수 있는 방식이다. 대표적으로 Anomaly Detection을 수행하는 AnoGAN²³⁾이 있다. 이 방식은 비교적 확보하기 어려운 결합데이터를 사용하지 않고, 정상데이터만으로 학습이 가능하다는 장점이 있다. 하지만 AnoGAN은 결합여부만 알려주는 알고리즘으로 어떤 신호가 잘못된 신호인지 알려주지는 못한다.

본 연구는 모델이 필요치 않으면서도, 많은 결합신호를 필요치 않은 차량용 센서의 결합 검출을 위한 검출 기법에 대한 것이다. 비교적 확보하기 쉬운 정상 신호만을 활용하여 비정상 신호를 검출하는 기법을 제안한다. 제안하는 연구에서는 정상적인 차량센서에서 측정되는 정상신호와 신호생성기(Generator)로 생성한 합성신호를 구별하는 판별기(Discriminator)를 개발하고, 개발된 판별기를 결합 검출기로 사용하려 한다. 제안하는 방법은 학습 시 결합 데이터 없이 정상 데이터만을 이용하여 학

습이 가능하므로 데이터를 수집하는 비용이 적게 들고, 결합이 발생한 센서가 무엇인지 알 수 있다는 장점이 있다.

이후 내용은 생성기와 판별기를 GAN 기법을 활용하여 개발하는 과정과, 신호 생성기와 판별기의 인공지능망 구조, 학습 데이터 수집, 검증 순으로 이루어져 있다.

2. 고장진단 알고리즘 설계

결합이 발생한 센서가 무엇인지 확인할 수 있도록 네트워크를 설계하고, 제안한 구조의 분류기를 학습하기 위해 GAN 기반의 새로운 학습방법을 설명한다.

2.1 네트워크 구조

제안하는 방법은 딥러닝 네트워크를 이용하여 센서 결합을 예측하는 구조를 제안한다. GAN 기반으로 학습을 하기 때문에 생성기와 판별기 총 두 개의 딥러닝 네트워크를 필요로 하고, 이 때 판별기가 최종적으로 결합을 예측하는 검출기로 사용된다. Fig. 1은 생성기와 판별기

Table 1 Network parameters

Layer	Parameter	
Discriminator	CNN Layer1	kernel size: 9, out_channel: 128, padding: 4, stride: 4, activation: relu
	CNN Layer2	kernel size: 7, out_channel: 64, padding: 3, stride: 3, activation: relu
	CNN Layer3	kernel size: 5, out_channel: 32, padding: 0, stride: 2, activation: relu
	CNN Layer4	kernel size: 3, out_channel: num_sensors, padding: 0, stride: 1, activation: linear
Generator	LSTM Layer	input size: num_sensors, hidden size=128, num_layer:2, activation: relu
	Linear Layer	Output features: 13, activation: linear

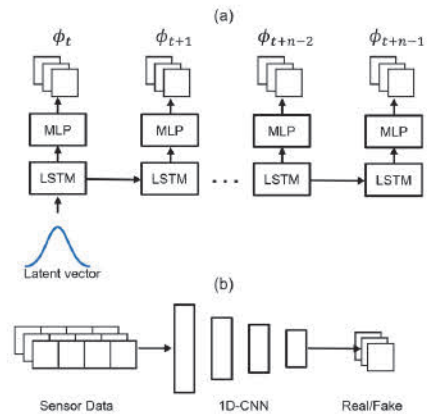


Fig. 1 Network (a) Generator network (b) Discriminator network

의 네트워크 구조를 도식화한 것이다. 생성기는 Latent vector를 입력으로 하고 가짜 센서데이터를 생성하는 역할을 한다. 생성기의 모델은 시계열 데이터를 생성하기에 적합한 LSTM을 이용했고 출력단에 Multi-Layer Perceptron(MLP)를 추가했다. 판별기는 시계열 데이터 분류에 적합한 1D-CNN을 4개 쌓은 구조로 설계했다. 모든 심층 레이어의 활성화 함수는 ReLU를 사용했다. Table 1은 각 네트워크 설계에 사용된 파라미터이다. 생성기는 생성하는 시퀀스 길이와 특성을 고려하도록 파라미터를 설정했고, 판별기는 Receptive field를 고려하고 충분한 Feature를 추출할 수 있도록 파라미터를 설정했다.

2.2 학습 데이터

제안한 방법을 학습하기 위해서는 차량의 센서 데이터가 필요하다. 다양한 상황에 대한 데이터를 얻기 위해 차량 시뮬레이션 프로그램인 CarSim을 통해 데이터를 수집했다.

Table 2는 데이터를 수집에 사용된 시나리오와 수집한 데이터 양을 나타낸 표이다. 차량의 동역학적 특성을 잘 나타내는 직진, 오실레이션, 단일 차선 변경, 이중 차선 변경, 급한 이중차선 변경 총 다섯 가지 경로를 선정하여 시나리오를 구성하였다. 다양한 속도 조건의 데이터를 얻기 위해 도심주행을 가정하여 각 시나리오마다 속도를 40, 50, 60 kph로 변경하며 데이터를 수집하였다. 운전자 모델은 CarSim에 있는 운전자 모델을 이용했다.

수집한 센서값은 Table 3과 같이 실제 차량에 주로 탑재되는 센서인 IMU, GPS, 휠 엔코더와 스티어링 각도 센서부터 측정되는 물리량에 대해서 실험을 진행했다. 센서 측정 주기는 0.01초로 설정하고 데이터를 수집하였다.

검증을 위해 3가지 결함 상황을 가정하였다. 첫번째로 상수 결함은 센서가 단선, 합선 등의 이유로 특정 값을 갖는 상수 시그널이 측정되는 경우이다. 두번째로 노이즈 결함은 신호에 노이즈가 심하게 포함되는 경우이다. 마지막으로 역상 결함은 특정 센서 측정값의 부호가 반대로 나타나는 경우이다. 이는 상수, 노이즈 결함과 달리 신호에 대한 결함이 아닌 동역학적 특성을 통해 결함을 검출할 수 있다.

각 결함에 대한 데이터는 정상데이터의 특정 센서 값을 식 (1)과 같이 변형하여 생성했다.

$$\begin{aligned} \tilde{\phi}_{t:t+n}^i &= \alpha \\ \tilde{\phi}_{t:t+n}^i &= \phi_{t:t+n}^i + R_{N-(\mu, \sigma)} \\ \tilde{\phi}_{t:t+n}^i &= -\phi_{t:t+n}^i \end{aligned} \quad (1)$$

Table 2 Data acquisition scenario and data size

Scenario/Speed	Data size	Sampling rate
Straight (40 kph, 50 kph, 60 kph)	601	100 samples/s
Slalom (40 kph, 50 kph, 60 kph)	3,602	100 samples/s
Single Lane Change (40 kph, 50 kph, 60 kph)	601	100 samples/s
Double Lane Change (40 kph, 50 kph, 60 kph)	1501	100 samples/s
Tight Double Lane Change (40 kph, 50 kph, 60 kph)	601	100 samples/s

Table 3 Data information

Sensor	Measurements	Unit
IMU	a_x	m/s ²
	a_y	
	a_z	
	Pitch rate ($\dot{\theta}$)	deg/s
Roll rate ($\dot{\phi}$)		
	Yaw rate ($\dot{\psi}$)	
GPS	Velocity	m/s
Wheel speed	Speed of wheels	km/hours
Throttle	Throttle	-
Steering angle	Steering wheel angle	deg



Fig. 2 Data collection method

위 식에서 $\phi_{t:t+n}^i$ 은 i 번째 센서의 $t \sim t+n$ 시간 스텝 센서 데이터이다. $\tilde{\phi}_{t:t+n}^i$ 는 결함이 발생한 센서 데이터를 나타낸다. α 는 임의의 상수이고, $R_{N-(\mu, \sigma)}$ 는 평균이 μ 이고 표준편차가 σ 인 정규분포를 따르는 랜덤 노이즈다.

2.3 네트워크 학습 방법

센서별 결함 여부를 검출하는 검출기를 학습하기 위해 GAN기반의 학습 방법을 제안한다. 판별자의 출력값이 하나인 기존의 GAN과는 달리 제안하는 검출기의 출력 값은 센서 측정값의 수만큼 존재하기 때문에 새로운 학습 방법이 필요하다.

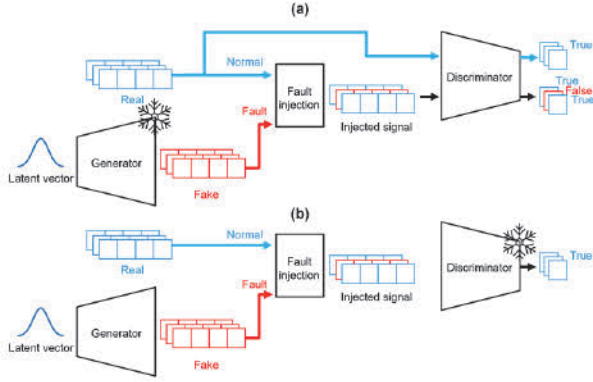


Fig. 3 Training architecture (a) Training discriminator
(b) Training generator

Fig. 3의 (a)는 판별기의 학습구조를 도식화한 것이다. 먼저 생성기는 Latent vector를 입력 받아 모든 센서에 대한 합성 신호를 생성한다. 실제 데이터의 특정 센서를 무작위로 선정하여 센서 값을 생성기가 생성한 합성 데이터로 바꾼다. 판별기는 실제와 합성 데이터가 섞인 데이터를 입력으로 받아 실제 센서 값에 대해서는 참으로 구분하고, 합성 데이터로 바뀐 센서에 대해서는 거짓이 되도록 학습한다. 또한 실제 신호만을 입력 받아 모든 센서에 대해 참이 되도록 학습한다.

Fig. 3의 (b)는 생성기의 학습구조를 도식화한 것이다. 판별자 학습과 마찬가지로 실제 데이터의 무작위로 선정한 특정 센서 값을 생성기가 생성한 합성 데이터로 바꾼다. 생성기는 판별기가 모든 센서 값에 대해 참으로 구분하도록 학습한다.

본 논문에서 제안하는 학습방법의 목적함수는 식 2와 같이 나타낼 수 있다.

$$\max_G \min_D E_{x,z \sim X, Z} [BCE_{Loss}\{D(F(x, G(z))), F(1, 0)\} + BCE_{Loss}\{D(x, 1)\}] \quad (2)$$

위 식에서 G 는 생성기이고, D 는 판별기이다. X 는 실제 센서 데이터이고, Z 는 Latent space이다. F 는 특정 센서 데이터를 Fake data로 대체하는 Fault Injection함수이다. Algorithm 1은 학습과정을 Pseudo Code로 나타낸 것이다. 판별기는 목적함수가 감소하도록 학습하여 생성기가 생성한 센서 데이터에 대해서는 해당 채널 출력이 0이 되도록, 실제 데이터에 대해서는 해당 채널 출력이 1이 되도록 학습한다. 이를 통해 판별기는 실제 데이터의 분포에 대해 1을 출력하게 된다. 생성기는 목적함수가 증가하도록 학습하여 생성한 데이터를 판별기가 1로 판

Algorithm 1: Adversarial training of fault detection network	
Input:	normal sensors dataset X ; generator G ; discriminator D ;
1:	Initialize G, D with random weights
2:	for epoch do
3:	Generate latent vector z
4:	Generate fake sensor data y from G with z
5:	Inject one sensor channel data of y into $x \sim X$
6:	Training discriminator D
7:	Training Generator G
8:	end for




Fig. 4 ROC curve




Fig. 5 Normal signal

단하도록 학습한다. 이를 통해 생성기는 실제와 유사한 분포의 데이터를 생성할 수 있게 된다.

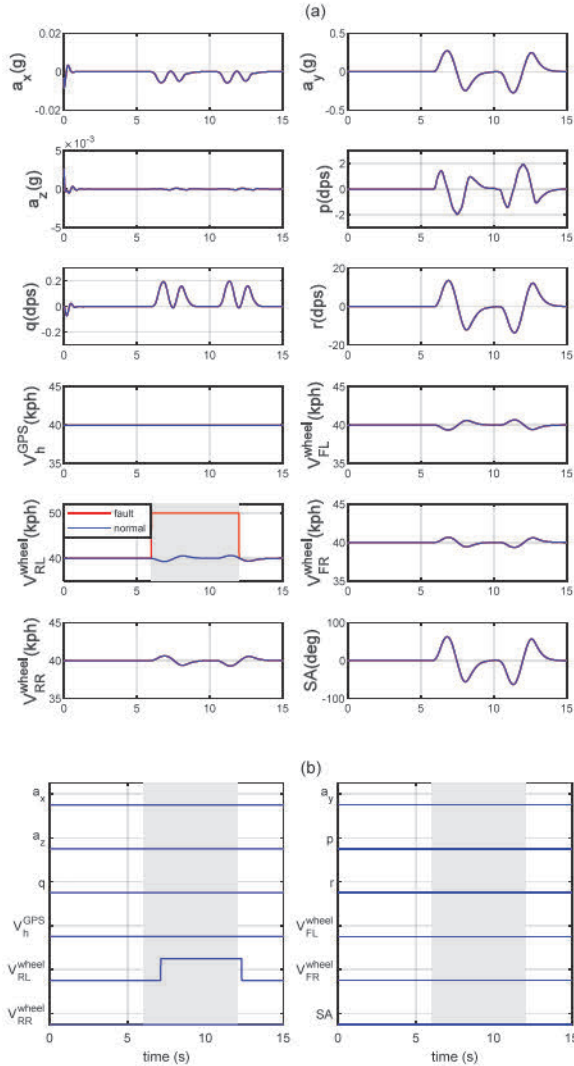


Fig. 6 Evaluation result about constant fault (a) signals
(b) fault prediction flag

2.4 학습 결과

학습을 위해 사용된 하이퍼 파라미터는 다음과 같다. Latent vector는 크기가 32인 랜덤 벡터이고 $N \sim (0,1)$ 의 정규 분포를 따른다. 에폭은 445, 생성기 학습률은 0.001, 판별기 학습률은 0.01로 하였고 배치사이즈는 32로 했다. 학습은 Python 3.10와 Pytorch 1.13.1을 사용하여 제안한 알고리즘을 구현했다.

판별기가 올바르게 학습이 되었는지 확인하기 위해 이진 분류에서 주로 사용되는 평가지표인 민감도(Sensitivity)와 특이도(Specificity)를 이용하여 판별기의 결함 검출 성능을 평가했다. 민감도와 특이도를 계산하는 공식은 식 (3) 이다.

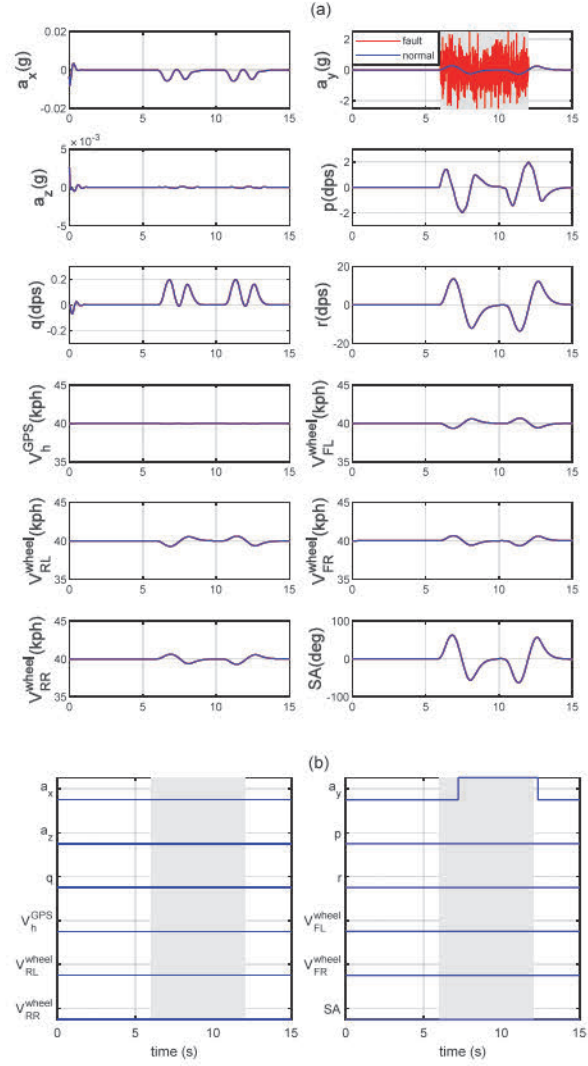


Fig. 7 Evaluation result about noise fault (a) signals
(b) fault prediction flag

$$Sensitivity = \frac{TP}{TP + FN} \tag{3}$$

$$Specificity = \frac{TP}{TP + FP}$$

위 식에서 TP는 True Positive, FN은 False Negative, FP는 False Positive이다.

1- 특이도를 가로축으로 하고 민감도를 세로축으로 하여 Threshold에 대한 그래프를 그리면 Receiver Operating Characteristic(ROC) 곡선을 그릴 수 있다. ROC 곡선은 (0,0), (1,1)을 반드시 지나는 특징이 있고, 곡선이 좌상단에 가까울수록 좋은 성능의 이진 분류기임을 나타낸다.

Fig. 4는 2.2절에서 언급한 3가지 결함에 대한 ROC 곡선이다. ROC 곡선을 확인해보면 3가지 경우 모두 (0,0)

과 (1,1)을 있는 직선을 기준으로 좌상단에 가까우므로 정상적으로 이진분류기의 역할을 수행하고 있다고 판단 된다.

3. 알고리즘 검증

3.1 검증 시나리오

40 kph로 이중 차선 변경을 하는 상황의 데이터로 결함 검출 성능을 검증하고자 한다. Fig. 5는 해당 시나리오의 각 센서 별 정상 신호이다. 이후 검증은 정상 신호에 특정 구간에 결함을 생성하여 결함이 검출이 되는지 여부를 판단한다. 검증 시 모델 출력에 로우 패스 필터를 적용하여 검출 노이즈를 제거한 결과를 표시했다. 로우 패스 필터는 윈도우 내의 모델 예측 값을 평균 값이 기준

이상일 경우 결함이라고 검출한다.

3.2 검증 결과

Fig. 6은 6 ~ 12초 구간에 좌측 후륜의 바퀴 속도 센서에 상수 결함이 발생한 경우의 결과이다. (a)는 결함이 발생한 상황의 센서 신호이고, 좌측 후륜 바퀴 속도 센서의 측정값이 50 kph로 고정되어 나오는 것을 확인할 수 있다. (b)는 각 센서에 대한 결함 검출 결과이다. 좌측 후륜 바퀴 속도 센서에 대해 결함이라고 올바르게 예측하고 있고, 다른 센서는 정상 신호임을 표시하고 있다. 그러나 결함이 발생한 시점과 약간의 시간 지연이 있는 것을 확인할 수 있다. 이는 결함 검출기에 신호를 적층하여 입력할 때 발생하는 지연과 로우 패스 필터로 인한 지연으로 발생하는 값이다.

Fig. 7은 6 ~ 12초 구간에 횡방향 가속도에 노이즈가 발생한 경우의 결과이다. (a)는 결함이 발생한 경우의 센서 신호이고, 횡방향 가속도에 평균은 0이고, 표준편차가 1인 정규분포의 노이즈가 추가되어 측정되고 있다. (b)는 각 센서에 대한 결함 예측 결과이다. 횡방향 가속도 신호에 결함이 있음을 올바르게 예측하고 있다.

Fig. 8은 6 ~ 12초 구간에 횡방향 가속도가 역상이 된 결과이다. (a)는 결함이 발생한 경우의 센서 신호이고, 횡방향 가속도 값의 부호가 반대로 나타나는 것을 확인할 수 있다. (b)는 각 센서에 대한 결함을 예측한 결과이다. 9 ~ 11초 사이 구간은 횡방향 가속도의 결함을 예측하지 못한다. 이는 측정값이 0에 가까우므로 정상 측정 신호와 결함신호의 차이가 작아 정상신호로 분류하는 것으로 판단되고, 측정 값이 적당히 큰 구간에서는 결함을 올바르게 검출하고 있는 것을 확인할 수 있다.

4. 결론

본 논문에서는 차량 센서의 결함을 탐지하기 위한 비지도학습 기반 딥러닝 네트워크 학습방법에 대해 논하였다. 제안하는 방법은 신호 기반 검출 방식으로 모델을 동적 설계할 필요가 없다는 장점이 있고, 하나의 판별기로 여러 개의 센서 신호에 대한 결함을 검출할 수 있다는 장점이 있다. 또한 정상 데이터만을 이용하여 학습하므로 학습데이터 수집이 용이하다.

검증을 위해 상수 결함, 노이즈, 역상으로 3가지 결함 상황을 가정하고, 결함 데이터를 생성하여 검증을 수행하였다. 검증 결과 검증한 모든 결함 상황에 대해 정상적으로 결함이 검출되는 것을 확인하였다.

본 논문에서 제안하는 방식이 모델 기반 방식이나 다른 신호 기반 방식보다 성능이 우수하다고 장담하지는

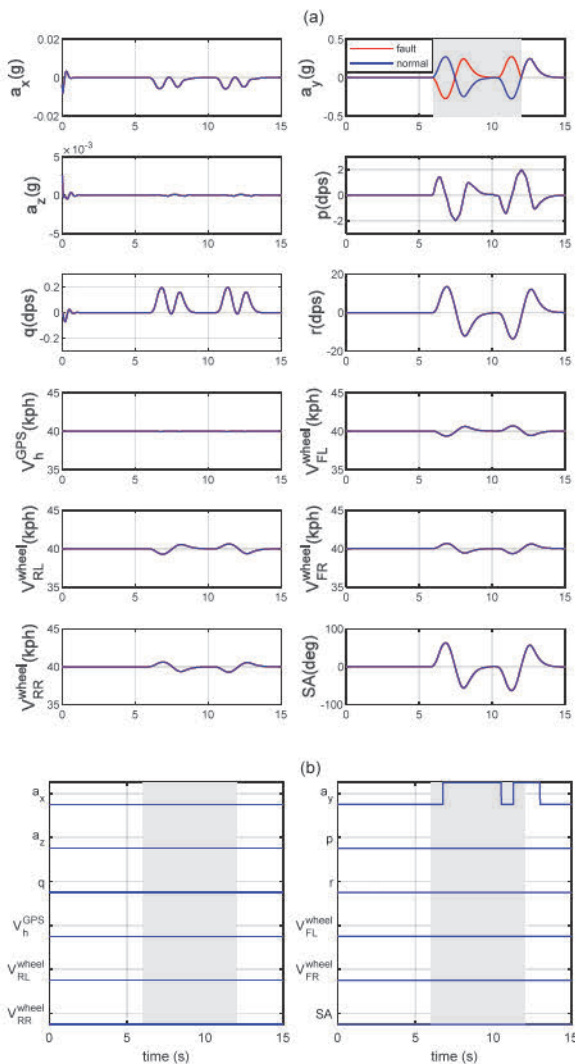


Fig. 8 Evaluation result about reverse fault (a) signals (b) fault prediction flag

못하지만, 비용적으로 시간적으로 구하기 어려운 결함 데이터 없이 학습기반 방식의 결함검출 방식을 구현할 수 있다는 방법론적인 이점이 있다는 것은 명확하다. 본 연구는 이런 접근법을 차량 센서 결함 검출에 활용할 수 있음을 보여주는 연구이다. 본 접근법은 대상 시스템에 대한 모델 또는 정보를 요구하지 않기 때문에, 차량 센서 결함뿐만 아니라, 선박, 항공기, 열차 등 다른 시스템 가능한 방식으로 확장 가능성이 있다.

후 기

이 연구는 2023년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임('20015831').

References

- 1) S. Lee, Y. Hwang and B. Kang, "Trend of Global NCAP Regarding ADAS," KSAE Fall Conference Proceedings, pp.849-854, 2019.
- 2) M. Imlay, ADAS Systems, Specialty Equipment Market Association-SEMA. SEMA News, Diamond Bar, 2018.
- 3) M. Dikmen and C. M. Burns, "Autonomous Driving in the Real World: Experiences with Tesla Autopilot and Summon," 8th International Conference on Automotive User Interfaces and Interactive Vehicular Applications, pp.225-228, 2016.
- 4) T. Hsiao and M. Tomizuka, "Sensor Fault Detection in Vehicle Lateral Control Systems Via Switching Kalman Filtering," Proceedings of the 2005 American Control Conference, pp.5009-5014, 2005.
- 5) M. L. Schwall and J. C. Gerdes, "A Probabilistic Approach to Residual Processing for Vehicle Fault Detection," Proceedings of the 2002 American Control Conference, Vol.3, pp.2552-2557, 2002.
- 6) J. Y. Su and W. H. Chen, "Fault Diagnosis for Vehicle Lateral Dynamics with Robust Threshold," Proceedings 2016 IEEE International Conference on Industrial Technology(ICIT), pp.1777-1782, 2016.
- 7) S. Varrier, D. Koenig and J. J. Martinez, "Robust Fault Detection for Vehicle Lateral Dynamics," IEEE 51st IEEE Conference on Decision and Control, pp.4366-4371, 2012.
- 8) W. Hwang, I. Yang and K. Huh, "Model-based Sensor Fault Detection Algorithm for EMB System," Transactions of KSAE, Vol.20, No.1, pp.1-7, 2012.
- 9) B. Moon and C. Park, "Robust Model based Fault Detection of EPB System for Varying Temperature," Transactions of KSAE, Vol.17, No.5, pp.26-30, 2009.
- 10) J. -S. Im, J. -H. Park, J. -Y. Kim, H. -S. Yun and Y. -B. Cho, "Development of Diagnosis System for Hub Bearing Fault in Driving Vehicle," Transactions of KSAE, Vol.19, No.2, pp.72-77, 2011.
- 11) Z. Gao, C. Cecati and S. X. Ding, "A Survey of Fault Diagnosis and Fault-Tolerant Techniques—Part I: Fault Diagnosis with Model-Based and Signal-Based Approaches," IEEE Transactions on Industrial Electronics, Vol.62, No.6, pp.3757-3767, 2015.
- 12) Q. Chen, W. F. Tian, W. W. Chen, Q. Ahmed and Y. M. Wu, "Model-Based Fault Diagnosis of an Anti-Lock Braking System via Structural Analysis," Sensors-Basel, Vol.18, No.12, Paper No.4468, 2018.
- 13) W. Huang and X. Su, "Design of a Fault Detection and Isolation System for Intelligent Vehicle Navigation System," International Journal of Navigation and Observation, Paper No.279086, 2015.
- 14) Z. Gao, S. X. Ding and Y. Ma, "Robust Fault Estimation Approach and Its Application in Vehicle Lateral Dynamic Systems," Optimal Control Applications and Methods, Vol.28, No.3, pp.143-156, 2007.
- 15) D. Mori, H. Sugiura and Y. Hattori, "Adaptive Sensor Fault Detection and Isolation Using Unscented Kalman Filter for Vehicle Positioning," IEEE Intelligent Transportation Systems Conference (ITSC), pp.1298-1304, 2019.
- 16) D. L. Ossig, K. Kurzenberger, S. A. Speidel, K. U. Henning and O. Sawodny, "Sensor Fault Detection Using an Extended Kalman Filter and Machine Learning for a Vehicle Dynamics Controller," 46th Annual Conference of the IEEE Industrial Electronics Society, pp.361-366, 2020.
- 17) K. Bouibed, A. Aitouche and M. Bayart, "Sensor Fault Detection by Sliding Mode Observer Applied to an Autonomous Vehicle," 2009 International Conference on Advances in Computational Tools for Engineering Applications, pp.622-626, 2009.
- 18) A. Nair, J. Weitzel, A. Hykkerud and H. Ratnaweera, "Supervised Machine Learning Based System for Automatic Fault-Detection in Water-Quality Sensors," 26th International Conference on System Theory, Control and Computing, pp.64-67, 2022.
- 19) M. Saied, H. Attieh, H. Mazeh, H. Shraim and C.

- Francis, "Supervised Learning Classification Applications in Fault Detection and Diagnosis: An Overview of Implementations in Unmanned Aerial Systems," SAE International Journal of Aerospace, Vol.16, No.1, pp.57-74, 2023.
- 20) Y. W. Liao, A. Yeaser, B. Yang, J. Tung and E. Hashemi, "Unsupervised Fault Detection and Recovery for Intelligent Robotic Rollators," Robotics and Autonomous Systems, Vol.146, Paper No.103876, 2021.
- 21) K. H. Park, E. Park and H. K. Kim, "Unsupervised Fault Detection on Unmanned Aerial Vehicles: Encoding and Thresholding Approach," Sensors-Basel, Vol.21, No.6, Paper No.2208, 2021.
- 22) I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville and Y. Bengio, "Generative Adversarial Networks," Communications of the ACM, Vol.63, No.11, pp.139-144, 2020.
- 23) T. Schlegl, P. Seebock, S. M. Waldstein, U. Schmidt-Erfurth and G. Langs, "Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery," International Conference on Information Processing in Medical Imaging(IPMI 2017), Vol.10265, pp.146-157, 2017.