

딥러닝 기반 광섬유 분포 음향·진동 계측기술을 활용한 장거리 외곽 침입감지 시스템 개발

김희운¹ · 이주영¹ · 정효영¹ · 김영호¹ · 권준혁² · 기승도² · 김명진^{1,+}

Development of Long-perimeter Intrusion Detection System Aided by deep Learning-based Distributed Fiber-optic Acoustic·vibration Sensing Technology

Huioon Kim¹, Joo-young Lee¹, Hyoyoung Jung¹, Young Ho Kim¹,
Jun Hyuk Kwon², Song Do Ki², and Myoung Jin Kim^{1,+}

Abstract

Distributed fiber-optic acoustic·vibration sensing technology is becoming increasingly popular in many industrial and academic areas such as in securing large edifices, exploring underground seismic activity, monitoring oil well/reservoir, etc. Long-range perimeter intrusion detection exemplifies an application that not only detects intrusion, but also pinpoints where it happens and recognizes kinds of threats made along the perimeter where a single fiber cable was installed. In this study, we developed a distributed fiber-optic sensing device that measures a distributed acoustic·vibration signature (pattern) for intrusion detection. In addition, we demonstrate the proposed deep learning algorithm and how it classifies various intrusion events. We evaluated the sensing device and deep learning algorithm in a practical testbed setup. The evaluation results confirm that the developed system is a promising intrusion detection system for long-distance and seamless recognition requirements.

Keywords: Intrusion detection, Distributed sensing, Fiber-optic sensors, DAS, DVS, Acoustic, Vibration

1. 서 론

광섬유 분포 계측 기술은 광섬유에 펄스 형태의 레이저 입사 시 발생하는 역산란광의 변화를 측정함으로써 광섬유에 입력된 여러 가지 외란이나 물리량 변화를 계측하는 기술로, 일반적인 통신용 광섬유 케이블을 센서부로 이용한다는 점과 길이 방향으로 모든 구간에 대한 동시측정이 가능하다는 점에서 최근 SHM (structural health monitoring) 기반 도심 인프라 안전진단 분야의 핵심기술로 각광받고 있다[1]. 이 기술을 이용하면 온도,

변형(변위), 진동, 음향 등 광섬유에 인가된 외란의 크기 정보뿐만 아니라 발생의 위치 정보를 동시에 취득하는데, 조건에 따라 수·수십 km 이상의 거리에 대해 최소 1,000개에서 100,000개 이상의 지점에 대해 실시간 동시측정이 가능하다. 종래의 단일 지점 측정 센서로 이와 같은 시스템을 구축하려면 측정 지점의 수에 따라 네트워크의 복잡도 및 비용이 기하급수적으로 증가하지만 광섬유 분포 계측 기술은 최대 측정범위 내 일정한 비용과 복잡도를 보장한다는 특징이 있다. 주요 SHM 기반 응용 분야로는 교량, 건물, 도로 안전성 모니터링에서부터 지반 구조 분석 및 지진파 감지, 지하공동구 안전진단, 송유관 보안, 산사태 감시 등 매우 다양하다[1].

특히, 이러한 광섬유 기반 분포 계측 기술 중 음향·진동의 변화를 측정하는 광섬유 분포 음향·진동 계측(distributed acoustic·vibration sensing, DAS/DVS) 기술은 광섬유가 포설된 전구간의 음향·진동 시그니처(패턴)의 검출이 가능해 석유·가스 등의 지하 수송관의 안전성 모니터링[2,3], 도심 통신망 건전성 모니터링[4], 장거리 지진파 정보 획득[5,6], 철도차량 추적·철로 이상감지[7-9] 등 다양한 응용분야에서 활용되어 왔다.

장거리 외곽 침입감지 시스템(perimeter intrusion detection system, PIDS) 또한 DAS/DVS(이하 DAS)의 주요 응용 중 하

¹ 한국광기술원 광정밀계측연구센터(Optical Precision Measurement Research Center, Korea Photonics Technology Institute)

KOPTI, 9, Cheomdanventure-ro 108beon-gil, Buk-gu, Gwangju 61007, Korea

² ㈜에니트 (ENITT Co., Ltd.)

#303-304, Siheomsaengsan-dong, 333, Cheomdangwagi-ro, Buk-gu, Gwangju 61008, Korea

⁺ Corresponding author: mjinkim@kopti.re.kr

(Received : Oct. 26, 2021, Revised : Nov. 26, 2021)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<https://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.

나로, 기존의 전통적인 침입감지 시스템에 비해 낮은 오탐율과 패턴 분석을 통한 신호원의 분류가 가능하다는 장점으로 인해 해외를 중심으로 여러 연구가 진행되어 왔다[10-12]. 기존 외부 침입 감지시스템은 마이크로웨이브, 진동·음파 센서, 적외선 센서 등이 주로 사용되고 있으나, 높은 오경보율로 인해 주로 국소 영역으로만 적용하거나 수백 m 이하 단거리에만 적용하는 등 한계점을 가지고 있다. 복수의 센싱 기술을 복합적으로 적용하여 가격대비 우수한 성능을 지니도록 하는 경우도 있으나, 이 경우 역시 최대 수백 m 정도까지만 감지 가능하며 그 이상의 장거리의 경우 시스템을 추가로 설치·운용하여야 하므로 전체 시스템의 복잡도와 비용이 그 규모에 비례하여 증가한다는 단점이 있다.

광섬유 기반의 분포형 진동센서의 경우 최대 50 km 이상의 장거리 침입감지를 단일 시스템으로 구현 가능하다. 또한 보통 수 m에서 십여 m 내외로 이벤트의 발생 위치를 특정할 수 있으며, 광섬유 케이블 상의 모든 지점에 대해 동시측정이 가능하다. 광 케이블이 센서와 신호선의 역할을 겸하기 때문에 별도의 연결선을 부설할 필요가 없으며, 따라서 설치 및 유지보수도 용이하다. 이와 더불어, 최근 인공지능 기술이 발달하면서 이벤트에 대한 상세 분류와 상황판단이 가능해지게 되었다. 이에 따라 보다 정밀한 이벤트 탐지를 통해 오경보를 효과적으로 억제하고 감지의 정확도와 신뢰도를 제고할 수 있게 되었다[13-17].

이러한 인공지능 기술 및 광섬유 분포 음향·진동 계측기술 기반 장거리 외곽 침입감지 시스템의 연구개발은 주로 해외를 중심으로 진행되어 왔으며, 국내에서는 핵심기술인 DAS장치 조차 개발 초기 단계에 머물러 있다. 따라서 본 연구에서는 침입여부 감지 및 이벤트 분류가 가능한 국산 PIDS의 개념증명을 위해 DAS 장치를 자체기술로 직접 개발하고, 이로부터 획득되는 신호 데이터를 분석하기 위한 딥러닝 알고리즘을 개발하였다. 특히 분포 음향·진동 신호를 획득하는 DAS 장치는 실험실 수준이 아니라 제품화 수준으로 개발을 완료하였고, 획득한 신호는 특정 시간 단위(타임프레임)로 처리하여 이를 CNN (convolutional neural network) 기반 딥러닝 분석 후 그 결과를 웹 인터페이스의 형태로 제공하는 애플리케이션을 제작하였다. 또한 광섬유를 펜스에 부착하거나 땅에 매립하여 실험환경을 구축하고 여러 가지 이벤트를 발생시켜 데이터를 수집한 후, 이를 이용하여 학습 및 추론을 수행하여 시스템의 유효성을 검증하였다.

2. 연구 방법

2.1 DAS 장치 개발

DAS 장치는 크게 광 신호를 생성하여 출력하는 광원 모듈과

광회로를 구성하는 광학계 모듈, 측정 광섬유에서부터 되돌아온 광 신호를 수신하는 광검출 모듈, 그리고 전체적인 제어기능을 수행하는 제어 모듈로 구성된다. 각 모듈의 핵심소자들을 선정하고 이를 구동하기 위한 회로를 설계한 후 PCB (printed circuit board)로 제작하였으며, 최종사양에 적합한지 모듈별로 검증을 수행하였다.

2.1.1 광원 모듈 설계 및 제작

광원 모듈은 광섬유에 입사할 광 펄스 신호 및 이의 증폭을 위한 보조 신호를 생성하는 역할을 한다. Fig. 1은 이러한 광원 모듈의 구성도를 보여준다. 광 펄스 신호는 Seed LD (laser diode)와 Optical Switch, 증폭 보조 신호는 Pump LD를 통해 생성된다. 이때 각 LD 및 Optical Switch를 제어하기 위한 온도 및 전류값은 제어 모듈의 DAC (digital to analog converter)에 의해 주어지며, 이 값들을 모니터링하기 위해 구동 회로로부터 전기 신호를 받아 ADC (analog to digital converter)에 의해 다시 제어 모듈로 전달된다.

DAS 장치의 Seed 광 신호 생성 시 매우 좁은 선폭의 1550 nm 파장대 고출력 LD 소자가 필요하며, 이를 정밀하게 제어하기 위한 전류 및 온도 제어 회로를 설계/제작하였다. LD 바이어스 전류는 최대 160 mA 공급이 가능하며, 전류 공급 확인을 위한 모니터링 회로가 부가되었다. 온도 제어는 ±1.5A TEC (thermoelectric cooling) 소자 회로를 통해 이루어지며, 제어 정밀도는 0.001°C 수준으로 구현하였다. 선정된 소자들과 제작된 구동 회로들의 성능 평가를 수행하여 Seed LD 광 출력력 파워 약 17.86 mW, 출력 파장 1548.2 nm, 선폭 13 kHz의 사양을 확인하였다.

Seed LD에서 생성된 광 신호를 변조하여 광 펄스 신호를 생성하기 위해서 고속의 광 펄스 신호 생성이 가능한 SOA (semiconductor optical amplifier) 소자를 Optical Switch로 활용하였으며, 1550 nm인 Seed LD 광 신호의 펄스 변조를 위한 광 파장 특성과 고품질 펄스 생성을 위한 60 dB 소광비 및 1 ns 스위칭 속도를 가지는 소자를 선정 및 적용하였다. Optical Switch 소자의 구동을 위해 최대 700 mA 바이어스 전류 공급이 가능

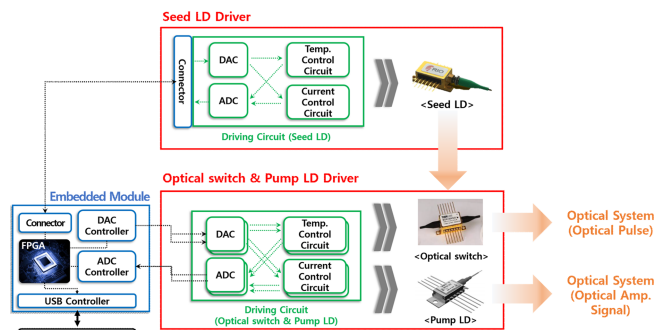


Fig. 1. Block diagram of optical source module.

한 회로 및 모니터링 회로, 10~100 ns 광 펄스 생성이 가능한 전기 펄스 생성 회로를 설계/제작하였다. 제어모듈의 FPGA (field programmable gate array)를 통해 변조 펄스폭을 조정하여 검증한 결과 제어값에 부합하는 광 펄스폭 신호 생성을 확인하였으며, 같은 방법으로 펄스 반복률을 검증한 결과 최대 10 kHz 펄스 반복률이 가능함을 확인하였다.

광학계 광 신호 증폭단에 980 nm 대역 고출력 광 신호를 전송하기 위한 Pump LD 소자는 EDF (erbium-doped fiber) 여기 (excitation)를 위한 100 mW 이상의 고출력 LD를 적용하였으며, 최대 1000 mA 전류 공급이 가능한 회로 및 고정밀 온도 제어 회로를 설계/제작하고 검증을 수행한 결과 210 mA 바이어스 전류 조건에서 103.4 mW의 충분한 출력을 확보하였다.

2.1.2 광학계 모듈 설계 및 제작

광학계 모듈은 광 신호 진행 경로를 제어하는 광 신호 순환부와 광원 신호 및 센싱 신호를 증폭하는 EDF 기반 광 신호 증폭부로 구성된다. 광 순환부는 Optical Circulator를 사용하여 광원 신호는 센싱 광섬유로, 센싱 광섬유로부터 되돌아온 측정 신호는 광 수신부로 전달하며, 이때 광손실은 최소화하는 것이 중요하다. 광신호 증폭부의 경우 광원 송신단의 2단계, 센싱 신호 수신단의 2단계, 총 4단계 광 신호 증폭이 가능하도록 설계/제작하였다. 증폭부 후단에는 ASE (amplified spontaneous emission) 노이즈를 제거하기 위해 Seen LD의 파장 영역만 통과시키는 대역통과필터를 부가하였다. Fig. 2는 이러한 광학계 모듈의 구성도를 보여준다.

2.1.3 광검출 모듈 설계 및 제작

광검출 모듈은 측정된 광 신호를 전기 신호로 변환하는 광검출 소자 회로 및 전기 신호를 증폭하는 증폭 회로로 구성되며, 1550 nm 대역 광 신호의 광전 변환이 가능한 InGaAs Pin Photodiode소자가 사용된다. 광검출 소자의 동작을 위해 ±5 V의 전압을 안정적으로 공급할 수 있는 회로와, 광검출 모듈로부터 출력되는 전류를 전압으로 변환하고 증폭 시켜주는 TIA (transimpedance amplifier) 회로를 설계, 제작하였으며, 회로 전

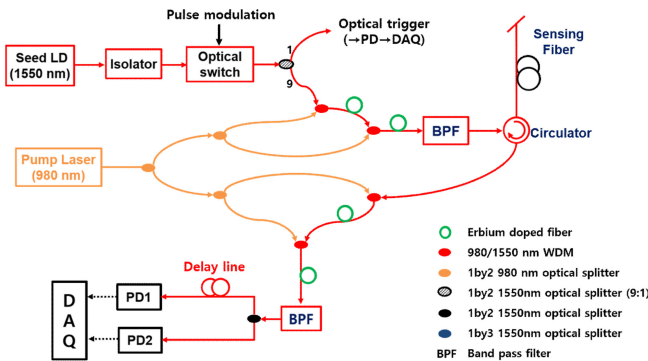


Fig. 2. Schematic of optical system.

체의 증폭률 계산 결과 49.96 dB로 충분한 증폭률을 보이는 것으로 확인하였다.

2.1.4 제어 모듈 및 UI S/W 설계 및 제작

하드웨어의 전체적인 제어 기능을 수행하는 FPGA 기반 제어 모듈과, 이와 연계되는 제어 소프트웨어를 설계하고 제작하였다. 제어 모듈은 각 하드웨어 모듈을 제어하기 위한 핵심로직이 구동되는 FPGA 칩과 그 주변 회로, 제어 소프트웨어와 연동을 위한 USB 인터페이스 칩 및 구동 회로로 구성되며, FPGA 및 USB 컨트롤러에 탑재되는 펌웨어도 자체 구현하였다.

FPGA의 로직 블록은 크게 광원 제어, 광검출 제어, ADC 제어, USB 인터페이스 제어, 메인 블록의 다섯 가지로 구성되어 있으며, 각 블록 별로 세부적인 제어를 담당한다. USB 컨트롤러는 제어 소프트웨어가 구동되는 외부 PC와 제어 모듈의 중간에 위치하여 제어 소프트웨어로부터 전송되는 명령 코드를 FPGA에 전달하는 역할을 하며, ADC모니터링 값들을 제어 소프트웨어로 전달하는 역할도 한다.

제어 소프트웨어는 내장 PC에 위치하며 사용자에게 GUI를 제공하여 임의의 제어 값을 설정하거나, 수집한 데이터를 가시화하여 보여주는 역할을 한다. 이때 제어 명령 및 데이터 송수신은 유저레벨 USB 드라이버를 통해 이루어지며, USB 통신 패키지 구조 설계 및 USB 인터페이스 함수 기반 고수준 명령 함수를 설계하고 구현하였다. 통신 패키트는 타겟 모듈을 지정하는 모듈 주소 부분과 각 기능별 고유의 명령코드 및 전달 인자로 구성된다.

2.1.5 모듈 통합 및 장치 제작

제작된 각 모듈 및 부속품들을 수용할 수 있는 19인치 랙 거치형 케이스 및 모듈 배치를 위한 내부 기구물들을 설계, 제작하였다. 케이스 내부에 각 모듈과 장치내장용 산업용 PC를 적절히 배치하고 연결하여 통합 시제품의 형태로 제작하였으며, 최종적으로 완성된 장치의 모습은 Fig. 3과 같다.

2.2 딥러닝 알고리즘 개발 및 시각화 시스템 제작

DAS 장치의 광 분포 신호 원천 데이터는 전처리 알고리즘




Fig. 3. DAS prototype system; (a) Appearance, (b) Innards.

을 통해 음향·진동 신호 특성을 극대화한다. 전처리된 데이터에 기반하여 학습 및 추론을 하기 위한 딥러닝 알고리즘을 개발하였다. 또한 실시간 딥러닝 추론을 통한 이벤트 분류 결과는 제작한 웹 기반 시각화 시스템을 통해 사용자에게 표시된다.

2.2.1 전처리 알고리즘 개발

DAS 신호의 전처리는 이상치(outlier) 제거와 측정 광섬유 내 광 신호 감쇠를 보정하기 위한 감쇠보정의 두 가지로 나누어진다. 이상치는 연속적인 위치에서 주변의 음향·진동 신호와 시간적/공간적 연관성을 보이지 않는 신호다. 통계적 관측치에서 벗어나는 패턴을 야기하기 때문에 딥러닝 모델에 입력되면 결과를 왜곡시키는 요인이 된다. 이를 효율적으로 제거하기 위해 여러 가지 필터링 기법들 - Input, Diffusion (gaussian, anisotropic), Median Filter, Bilateral Filter - 을 DAS 신호에 적용하여 비교 분석한 결과, Median Filter를 통해 원본 신호의 크기를 왜곡하지 않고 이상치만 효과적으로 제거할 수 있었다. 또한 일반적으로 광 신호는 광섬유를 도파 하면서 그 세기가 일정 비율로 감쇠하는 특징이 있는데, 이에 따라 수집된 신호 데이터의 크기도 감쇠한다. 이러한 신호 감쇠는 거리별 지수형태의 특성을 가지며, 시작 및 중단 지점의 평균 파워를 계산하여 감쇠 계수를 도출하고 감쇠곡선 이론으로 보정곡선을 추정하여 감쇠를 보정한다.

2.2.2 딥러닝 알고리즘 개발

딥러닝 기반 분류 알고리즘을 개발하여 DAS 장치로부터 수집되는 음향 및 진동신호 패턴을 분석하여 침입 이벤트의 종류를 판단한다. 수집된 시간과 거리 값을 기준으로 데이터 세트를 생성하고 특정 시간 단위(타임 프레임)로 처리된 데이터

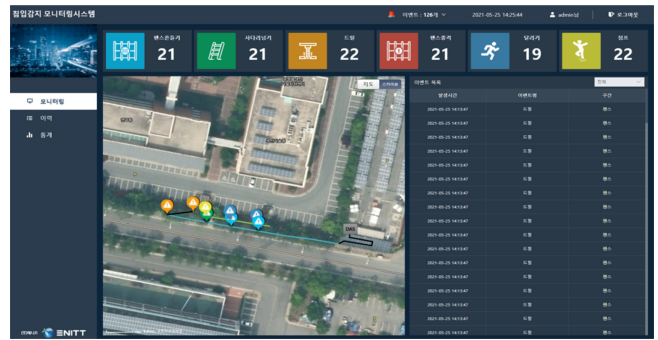


Fig. 5. Visualization system screenshot.

를 쌓아 거리와 시간에 대한 2차원 컬러맵 데이터로 변환한 후 이에 대한 CNN 기반 학습 모델을 개발/적용하였다. 딥러닝 모델은 Convolution 레이어 3개, Maxpooling 레이어 3개, Flatten 레이어 1개, Dense 레이어 1개, Dropout 레이어 1개를 이용하여 구성되었으며, 다중 분류 문제를 풀기 위한 활성화 함수로 softmax 값을 마지막 레이어에 설정하였다. 손실 함수는 categorical_crossentropy, 최적화 함수는 adam을 사용하였다. Fig. 4는 Python으로 작성된 모델 구현 및 그 결과를 보여준다.

2.2.3 시각화 시스템 제작

딥러닝 추론을 통해 침입감지 이벤트 분류 결과를 시각화하여 사용자에게 제공하기 위한 웹 기반 시각화 시스템을 제작하였다. 시각화 시스템의 개발 및 구동 환경은 우분투 GNU/Linux, MySQL, Spring 프레임워크이며, DB에 저장된 침입 이벤트 분류 결과를 시각화하여 표시한다. 총 6가지 침입 이벤트를 분류

```

model = Sequential()
model.add(Convolution2D(16, (3, 3), padding='same', activation='relu', input_shape=X_train.shape[1]))
model.add(MaxPooling2D(pool_size=(2, 2)))
#model.add(Dropout(0.25))

model.add(Convolution2D(64, 3, 3, activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
#model.add(Dropout(0.25))

model.add(Convolution2D(64, 3, 3))
model.add(MaxPooling2D(pool_size=(2, 2)))
#model.add(Dropout(0.25))

model.add(Flatten())
model.add(Dense(256, activation = 'relu'))
model.add(Dropout(0.5))
model.add(Dense(num_classes, activation = 'softmax'))

model.compile(loss='categorical_crossentropy', optimizer='Adam', metrics=['accuracy'])
#model.fit(X_train, Y_train, batch_size=32, nb_epoch=10)
history = model.fit(X_train, Y_train, batch_size=20, epochs=10)

model.save('image_6_classification_model.h5')
model.summary()
    
```

(a)

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 100, 100, 16)	448
max_pooling2d (MaxPooling2D)	(None, 50, 50, 16)	0
conv2d_1 (Conv2D)	(None, 16, 16, 64)	9280
max_pooling2d_1 (MaxPooling2)	(None, 8, 8, 64)	0
conv2d_2 (Conv2D)	(None, 2, 2, 64)	36928
max_pooling2d_2 (MaxPooling2)	(None, 1, 1, 64)	0
flatten (Flatten)	(None, 64)	0
dense (Dense)	(None, 256)	16640
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 6)	1542
Total params: 64,838		
Trainable params: 64,838		
Non-trainable params: 0		

(b)

Fig. 4. Deep learning model written in Python; (a) Model implementation codes, (b) Model summary output.

하여 발생 위치를 GIS (Geographic Information System) 기반해 표시한다. 또한 이벤트 이력 및 통계 관리 기능도 제공한다. Fig. 5는 제작된 시각화 시스템의 UI 화면이다.

2.3 실험환경 구축 및 데이터 수집/학습

데이터 수집, 학습 및 평가를 위해 광케이블 펜스 부착 및 노면 매립 테스트베드를 구축하고 개발된 DAS 장치와 딥러닝 알고리즘, 가시화 시스템을 이용하여 유효성 검증을 수행하였다. Fig. 6은 구축된 테스트베드 현장을 보여준다. 펜스 부착의 경우 약 120 cm 높이 펜스 상단에 케이블 타이를 이용하여 1 m 간격으로 광섬유를 고정하여 포설하였고, 매립의 경우 노면에서 약 15 cm 아래에 광섬유를 직접 매설하였다.

침입상황은 펜스 관련 이벤트 3종과 매립 관련 이벤트 3종, 총 6종으로 구성한다. 펜스 관련 이벤트는 펜스 충격, 펜스 흔들기, 사다리 넘기이다. 매립관련 이벤트는 드릴, 달리기, 점프이다. 외부 침입 이벤트 데이터를 수집, 분석하여 학습용 데이터를 선정하고 레이블링 작업 후 학습용 세트와 검증용 세트를 생성하였다. Fig. 7은 침입 이벤트에 의해 나타나는 2D 컬러맵상의 패턴들을 보여준다. 각 이벤트에 의한 신호는 서로 상이한 2D 패턴을 보여주며, CNN 기반 학습기법을 통해 이러한 패턴




Fig. 6. Experiment environment (testbed) where a fiber cable attached to fence and buried underground

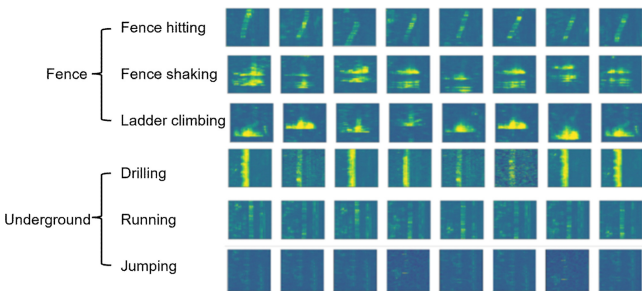


Fig. 7. Intrusion event categories and 2D patterns

이미지 분류를 수행하게 된다.

3. 결과 및 고찰

3.1 PIDS용 DAS 장치 성능검증

PIDS용 침입 이벤트 신호 데이터 수집 장치로서 DAS 계측기의 시제품을 완성하고 그 성능을 Table 1의 성능지표에 의거하여 평가하였다. 측정빈도 10 kHz, 측정진동수 5 kHz, 측정거리 20 km, 위치분해능 5 m로, 총 20 km 이내의 거리에서 매 5 m 구간의 진동 신호를 식별할 수 있으며, 5 kHz 이하의 진동 주파수를 가지는 진동 신호를 검출할 수 있기 때문에, 일반적인 상황에서 외곽 침입감지 시스템의 신호 수집장치로서 충분히 기능할 수 있음을 확인하였다. 특히, 정밀한 위치 특정과 국소 지점에서 침입 이벤트간 상호 구별 가능한 패턴을 얻기 위해서는 위치분해능 성능이 중요하며, 개발된 DAS 장치의 위치별 측정데이터가 상정한 6가지의 이벤트에 대해서 고유한 신호 이미지 패턴을 생성함을 확인할 수 있었다. 측정빈도와 측정거리, 그리고 위치분해능은 상보적 관계에 있기 때문에, 상황과 요구조건에 따라 좀 더 중점적인 요소에 초점을 맞춰 조정하는 것이 필요하다. 예를 들어, 좀 더 정밀한 데이터 획득 및 분석을 위해 높은 측정빈도와 위치분해능이 필요할 경우 측정거리를 짧게 하면 물리적인 한계 내에서 목표치 달성이 가능하다.

3.2 침입 이벤트 분류 성능검증

DAS 장치로부터 생성된 데이터의 전처리 과정을 거친 후 2D 이미지로 변환해서 학습용 세트와 검증용 세트를 생성하였다. 이렇게 생성된 데이터 세트를 사용하여 딥러닝 알고리즘 모델 튜닝 및 최적화 진행 후 학습용 데이터 세트를 사용하여 지도 학습을 수행하였다. Fig. 8은 전처리된 DAS 데이터를 2D 이미지로 변환 후 학습을 수행하는 과정을 보여준다. 학습 수행 후 검증용 데이터 세트를 사용하여 평가를 수행하였으며, 6종류의 이벤트에 대해 약 90% 이상의 정확도를 가짐을 확인하였다. Fig. 9는 다중분류 혼동행렬(confusion matrix)과 모델 예측 정확도 그래프를 보여준다.

Table 1. DAS unit performance metrics

Metrics	Unit	Target Value
Meas. Rate	kHz	10
Target Frequency	kHz	5
Distance	km	20
Spatial Resolution	m	5




Fig. 8. Image data training and tuning by events.




Fig. 9. Confusion matrix and accuracy graph

감사의 글

본 연구는 행정안전부와 한국산업기술평가관리원의 사회 복합재난 대응기술 개발사업(No. 20015728) 및 중소벤처 기업부와 한국산업기술진흥원의 지역특화 산업육성+(R&D) 사업(No. S2910209)의 지원을 받아 수행된 연구임.

4. 결 론

본 연구에서는 장거리 외곽 침입감지 시스템으로 사용할 수 있는 광섬유 기반 분포 음향·진동 계측기를 개발하고, 이를 제어, 운영하기 위한 펌웨어 및 제어 프로그램을 구현하였다. 또한 측정 데이터로부터 침입 이벤트 분류가 가능한 딥러닝 알고리즘을 개발하고 그 결과를 표출할 수 있는 가시화 시스템을 제작하였으며, 침입감지 모사환경을 구축하고 6가지 종류의 침입 이벤트 데이터를 수집하여 딥러닝 알고리즘 최적화 및 분류 성능 검증을 수행하였다. 이를 통해 기존 기술을 대체하여 침입감지 뿐만 아니라 위치 특정 및 침입 이벤트의 종류도 판단할 수 있음을 확인하였다.

향후 오경보율을 효과적으로 억제하고 환경 노이즈 등 침입 신호가 아닌 이벤트에 대한 분류도 할 수 있도록 시스템을 고도화하는 연구가 필요하다. 이를 위해서는 현실적인 이벤트를 다수 식별하고 이벤트별 신뢰성 있는 데이터 수집/분석이 요구된다. 또한 딥러닝 모델도 특정 타임프레임 이미지에 대한 CNN 분석 모델에서, 실시간 분석이 가능한 시공간적(spatiotemporal) 복합 분석 모델이 적용된다면 분류의 실시간성과 성능이 더욱 향상될 것으로 기대된다.

REFERENCES

- [1] M. F. Bado and J. R. Casas, "A Review of Recent Distributed Optical Fiber Sensors Applications for Civil Engineering Structural Health Monitoring", *Sens.*, Vol. 21, No. 5, pp. 1818(1)- 1818(83), 2021.
- [2] H. Wu, Y. Qian, W. Zhang, and C. Tang, "Feature extraction and identification in distributed optical-fiber vibration sensing system for oil pipeline safety monitoring", *Photonic Sens.*, Vol. 7, No. 4, pp. 305-310, 2017.
- [3] D. Tan, X. Tian, W. Sun, Y. Zhou, L. Liu, Y. Ma, J. Meng, and H. Zhang, "An oil and gas pipeline pre-warning system based on Φ -OTDR", *Proc. Int. Conf. Opt. Fibre Sensors*, pp. 91578W(1)- 91578W(4), Santander, Spain, 2014.
- [4] A. Lv and J. Li, "On-line monitoring system of 35 kV 3-core submarine power cable based on Φ -OTDR", *Sens. Actuators A, Phys.*, Vol. 273, pp. 134-139, 2018.
- [5] T. Parker, S. V. Shatalin, M. Farhadiroushan, Y. I. Kamil, A. Gillies, D. Finfer and G. Estathopoulos, "Distributed Acoustic Sensing - A New Tool for Seismic Applications", *Proc. of 74th EAGE Conference and Exhibition*, pp. cp-293-00801(1)- cp-293-00801(9), Copenhagen, Denmark, 2012.
- [6] L. Shiloh, A. Lellouch, R. Giryes, and A. Eyal, "Fiber-optic distributed seismic sensing data generator and its application for training classification nets", *Opt. Lett.*, Vol. 45, No. 7, pp. 1834-1837, 2020.
- [7] Z Wang, B Lu, H Zheng, Q Ye, Z Pan, H Cai, R Qu, Z Fang,

- and H Zhao, "Novel railway-subgrade vibration monitoring technology using phase-sensitive OTDR", *25th Optical Fiber Sensors Conference (OFS)*, pp. 1-4, Jeju, Korea, 2017.
- [8] C. Du, S. Dutta, P. Kurup, T. Yu, and X. Wang, "A review of railway infrastructure monitoring using fiber optic sensors", *Sensors and Actuators A-physical*, Vol. 303, pp. 111728(1)-111728(36), 2020.
- [9] Z. Li, J. Zhang, M. Wang, Y. Zhong, and F. Peng, "Fiber distributed acoustic sensing using convolutional long short-term memory network: a field test on high-speed railway intrusion detection", *Opt. Express*, Vol. 28, No. 3, pp. 2925-2938, 2020.
- [10] J. C. Juarez and H. F. Taylor, "Field test of a distributed fiber-optic intrusion sensor system for long perimeters", *Appl. Opt.*, Vol. 46, No. 11, pp. 1968-1971, 2007.
- [11] F. Tanimola and D. Hill, "Distributed fibre optic sensors for pipeline protection", *J. Nat. Gas. Sci. Eng.*, Vol. 1, No. 4-5, pp. 134-143, 2009.
- [12] A. Owen, G. Duckworth and J. Worsley, "OptaSense: Fibre Optic Distributed Acoustic Sensing for Border Monitoring", *2012 Eur. Intell. Secur. Inform. Conf.*, pp. 362-364, Odense, Denmark, 2012.
- [13] A. V. Makarenko, "Deep learning algorithms for signal recognition in long perimeter monitoring distributed fiber optic sensors", *2016 IEEE 26th Int. Workshop on Mach. Learn. Signal Process. (MLSP)*, pp. 1-6, Vietri sul Mare, Italy, 2016.
- [14] M. Aktas, T. Akgun, M. U. Demircin, and D. Buyukaydin "Deep learning based multi-threat classification for phase-OTDR fiber optic distributed acoustic sensing applications", *Proc. SPIE 10208, Fiber Optic Sens. Appl. XIV*, Vol. 10208, California, United States, 2017
- [15] C. Xu, J. Guan, M. Bao, J. Lu, and Wei Ye, "Pattern recognition based on time-frequency analysis and convolutional neural networks for vibrational events in ϕ -OTDR", *Opt. Eng.*, Vol. 57, No. 1, pp. 016103(1)- 016103(7), 2018.
- [16] Y. Shi, Y. Wang, L. Zhao, and Z. Fan, "An Event Recognition Method for Φ -OTDR Sensing System Based on Deep Learning", *Sens.*, Vol. 19, No. 15, pp. 3421(1)-3421(9), 2019.
- [17] L. Shiloh, A. Eyal and R. Giryes, "Efficient Processing of Distributed Acoustic Sensing Data Using a Deep Learning Approach", *J. Lightwave Technol.*, Vol. 37, No. 18, pp. 4755-4762, 2019.