

온사이트 지진조기경보를 위한 딥러닝 기반 실시간 오탐지 제거

Deep Learning-Based, Real-Time, False-Pick Filter for an Onsite Earthquake Early Warning (EEW) System

서정범^{1)*} · 이진구²⁾ · 이우동³⁾ · 이석태²⁾ · 이호준⁴⁾ · 전인찬⁵⁾ · 박남률²⁾

Seo, JeongBeom^{1)*} · Lee, JinKoo²⁾ · Lee, Woodong³⁾ · Lee, SeokTae²⁾ · Lee, HoJun⁴⁾ · Jeon, Inchan⁵⁾ · Park, NamRyoul²⁾

¹⁾케이아이티밸리 AiLab 연구소장, ²⁾케이아이티밸리 AiLab 수석연구원, ³⁾전북대학교 지구환경과학과 강의교수, ⁴⁾케이아이티밸리 연구기획본부 전문위원, ⁵⁾케이아이티밸리 AiLab 책임연구원

¹⁾Director, AiLab, KITValley Co., Ltd., ²⁾Principal Researcher, AiLab, KITValley Co., Ltd., ³⁾Professor of Lecture, Department of Earth and Environmental Sciences, Jeonbuk National University, ⁴⁾Lead Professional, R&P H.Q, KITValley Co., Ltd., ⁵⁾Senior Researcher, AiLab, KITValley Co., Ltd.

/ A B S T R A C T /

This paper presents a real-time, false-pick filter based on deep learning to reduce false alarms of an onsite Earthquake Early Warning (EEW) system. Most onsite EEW systems use P-wave to predict S-wave. Therefore, it is essential to properly distinguish P-waves from noises or other seismic phases to avoid false alarms. To reduce false-picks causing false alarms, this study made the EEWNet Part 1 'False-Pick Filter' model based on Convolutional Neural Network (CNN). Specifically, it modified the Pick_FP (Lomax et al.) to generate input data such as the amplitude, velocity, and displacement of three components from 2 seconds ahead and 2 seconds after the P-wave arrival following one-second time steps. This model extracts log-mel power spectrum features from this input data, then classifies P-waves and others using these features. The dataset consisted of 3,189,583 samples: 81,394 samples from event data (727 events in the Korean Peninsula, 103 teleseismic events, and 1,734 events in Taiwan) and 3,108,189 samples from continuous data (recorded by seismic stations in South Korea for 27 months from 2018 to 2020). This model was trained with 1,826,357 samples through balancing, then tested on continuous data samples of the year 2019, filtering more than 99% of strong false-picks that could trigger false alarms. This model was developed as a module for USGS Earthworm and is written in C language to operate with minimal computing resources.

Key words: Earthquake early warning, Onsite warning, False-pick, False alarm, Deep learning, Convolutional neural network

1. 서론

1.1 지진조기경보의 속도와 정확도

역사지진 연구를 통해 우리나라에서도 규모6.0의 지진 발생 가능성이 제기되었으며[1], 국가 발전에 따른 대도시의 확장, 고도화된 산업과 교통 인프라 등 지진에 취약한 요소가 증가되는 상황에서 2016년 경주 9.12지진, 2017년 포항지진 이후 지진위험에 대한 우려가 더욱 높아지고 있다.

지진에 대응하기 위한 방향은 지진의 발생을 예측하는 것과 지진 발생 후 빠르게 대응하는 것으로 구분할 수 있다.

지진 예측은 장기와 단기로 나눌 수 있으며, 장기 예측은 수십 년 이상의 예측으로 지진 발생 주기성을 기초로 과거 지진 발생 데이터와 관련된 지구 물리학적 데이터를 기반으로 확률을 예측하여[2], 건물의 내진설계기준과 지진재해대책 수립에 활용된다. 단기 예측은 수주에서 수년 이내의 예측으로 다양한 지진 전조현상에 대한 연구가 진행 중이지만, 충분한 인과관계 입증 부족 등으로 현재로서는 실용화에 어려움이 있다[3].

지진의 단기 예측이 어려움에 따라 여러 국가에서 사용되는 방법이 지진 발생 후 빠른 대응과 대피를 통해 인명과 재산의 손실을 최소화하는 지진조기경보이다[4]. 지진조기경보는 실제 피해를 유발하는 S파가 도달하기 전에 상대적으로 빠른 전파속도의 P파를 탐지하여 지진의 발생을 경보하는

*Corresponding author: Seo, JeongBeom

E-mail: jbseason@gmail.com

(Received December 31, 2020; Revised February 9, 2021; Accepted February 14, 2021)

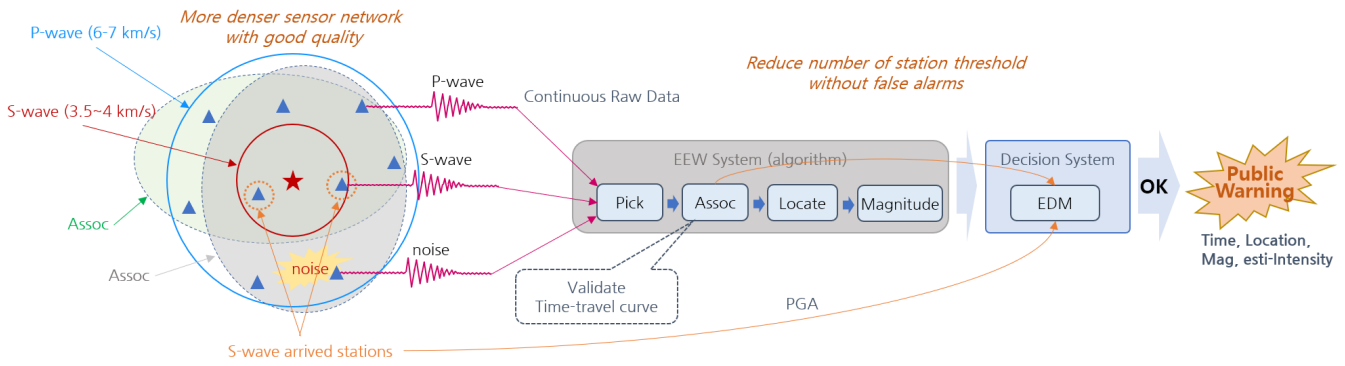


Fig. 1. Concept of Network Based Earthquake Early Warning System of KMA

것이다.

성공적인 지진조기경보(Earthquake Early Warning, EEW)를 위해서는 경보의 속도와 정확도가 핵심이다[5]. 경보의 속도가 빨라지면 진앙에 더 가까운 곳에서 피해를 유발하는 진동의 도달 전에 경보를 받을 수 있게 되고, 대응을 위한 시간적 여유도 증가한다. 경보의 정확도가 높은 경우에는 적절한 대응에 유리하고, 오경보 위험의 감소에 따른 자동화된 대응체계 구축이 가능해진다. 반면 정확도가 충분하지 않은 경우에는 미경보가 발생하거나, 오경보로 인해 사회적 혼란과 손실이 발생하고, 반복될 경우 점차 국민들로부터 경보에 대한 신뢰를 잃을 수 있다.

경보의 속도는 관측, 수집, 분석, 전파, 대응의 각 단계마다 지연요소가 존재한다. 관측 단계에서는 지진 발생 후 P파가 분석을 위해 필요한 수의 관측소에 모두 도달하기 위한 시간이 필요하고, 이는 발생 위치 및 관측망의 밀도 등과 관련 있다. 수집 단계에서는 기록계에서 수집서버로의 관측 자료 패킷 전송주기 및 네트워크 전송속도 등에 관련한 전송지연이 존재한다. 분석 단계에서는 수집된 관측자료에서 P파를 탐지하고, 지진의 발생 위치, 시각, 규모, 예상진도 등의 추정, 경보 결정을 위한 알고리즘 연산시간이 소요된다. 또한, 특정 관측소의 배정잡음의 수준이 높은 경우에는 탐지(picking) 알고리즘이 상대적으로 더 큰 에너지가 도달한 시점에 P파를 결정할 수 있으므로, 이에 따른 지연이 존재할 수 있다[6]. 전파 단계에서는 경보 메시지의 구성과 전송, 각 매체별 특성 및 경로에 따른 경보 전파 소요 시간이 존재한다. 최종적으로 대응 단계의 속도는 홍보/교육/훈련을 통한 인원의 지진대응요령 숙달과 자동화된 대응의 적용 여부에 연관된다.

경보의 정확도는 오경보(false alarm) 발생과 예측값의 정확도가 중요한 요소이다. 오경보는 낙뢰, 발파 등 주변 잡음, 전기 잡음 등에서 발생하는 오탐지 및 원거리 지진, 이벤트 스플릿(split), 여진(aftershock) 등으로 정확한 위상의 결정이 어려워짐에 따라 발생된다[7-9]. 예측값의 정확도는 위치, 규모, 진도 등 알고리즘 추정 결과의 정확도이며, 이에 관련하여 과잉경보 또는 미경보가 발생할 수 있다.

경보의 속도와 정확도는 트레이드 오프(trade-off) 관계로서 일반적으로 속도를 높이기 위해 경보 시점을 앞당기면 정확도가 낮아지며, 오경보 발생이 증가하게 된다[5, 10]. 오경보 위험은 분석결과에서 경보를 결정하는 기준 설정에 중요한 고려사항이며, 만약 새로운 방법으로 오경보를 발생시키는 오탐지를 식별하고 차단할 수 있다면 경보 시점을 앞당길 수 있다.

Fig. 1과 같이 현재 국내에 지진조기경보를 제공하는 네트워크 기반의 지진조기경보 시스템(Network Based Earthquake Early Warning System)

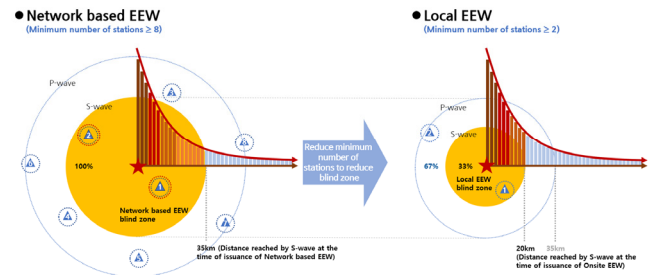


Fig. 2. Comparison of blind zone between Network-Based EEW and Local EEW using Onsite method

은 전국에 분포한 지진관측망을 기반으로 지진이 발생한 뒤 가장 가까운 3~4개의 관측소에 P파가 도달하게 되면, 이를 탐지(picking)하고, 연관(association) 알고리즘을 통해 동일한 지진의 것을 식별하고, 위치추정(location) 알고리즘으로 위치를 추정한 뒤, 규모(magnitude)를 추정한다[11]. 하지만, 이러한 분석의 초기버전은 오경보의 불확실성이 높기 때문에 정확도를 높이기 위해 새로운 탐지가 추가될 때마다 분석을 반복하여, 8개의 관측소에 P파가 도달한 시점에 결정 단계(Early Decision Module, EDM)에서 위치, 규모, 발생시간 등의 분석 결과의 경보 기준 충족과 함께 오경보를 피하기 위해 진앙 근접 관측소의 가속도 관측값 크기 등의 추가 조건을 충족할 경우 전 국민을 대상으로 경보하게 된다[12].

네트워크 기반의 지진조기경보의 속도를 높이기 위해서는 관측망의 밀도를 높이거나 오경보를 제거할 수 있는 새로운 방법을 개발하여, 보다 적은 수의 P파탐지를 이용한 분석 결과에 대해 오경보 위험을 충분히 줄일 수 있어야 한다.

지진조기경보가 발령되는 시점에 이미 S파가 도달하여 사전에 경보할 수 없는 진앙에 가까운 영역을 경보공백역(blind zone)이라고 하는데, Fig. 2와 같이 진앙에서 가까울수록 더 큰 에너지가 도달하고, 그에 따라 피해가 증가하기 때문에 보다 신속한 조기경보를 통해 경보공백역을 줄이게 되면 더 큰 피해의 감소를 기대할 수 있다[13].

네트워크 기반의 지진조기경보에서 내륙지진의 경우 8개의 관측소에 P파가 도달하여 경보가 발령되는 시점은 대략 최초 관측 후 7초 내외이며, 이는 지진 발생 기준 10초 내외가 된다. 그 시점에 S파는 진앙으로부터 대략 35 km까지 도달하게 되어, 반경 35 km가 경보공백역이 된다.

Fig. 3과 같이 온사이트 지진조기경보(Onsite Earthquake Early Warning System)는 경보 수요자의 위치에 설치된 1~2개의 지진계에서 측정된 지진

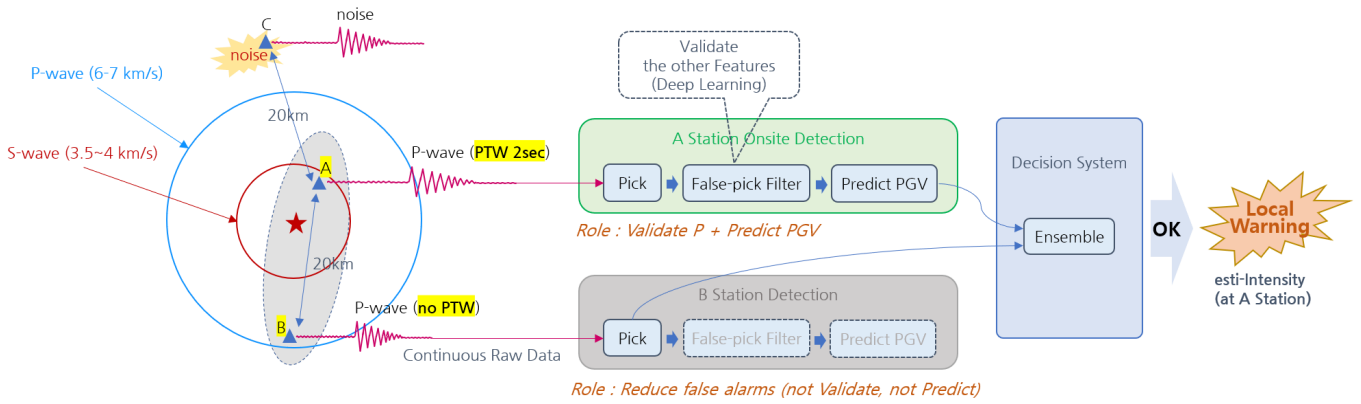


Fig. 3. Concept of Local Earthquake Early Warning System using Onsite method

Table 1. False-Picks from the continuous data in 2019 of Korean EEW seismic network

		Number of false-picks	Sub total	Number of occurrences per time			
				Month	Day	Hour	
False-Picks of 2019 Korean Continuous Data	Small false-pick detections that do not trigger false alarms	Level I	1,296,313	1,327,803	110,650.3	3,637.8	151.6
		Level II	21,540				
		Level III	7,093				
		Level IX	2,857				
	Large false-pick detections that can cause false alarms	Level V	1,922	9,675	806.3	26.5	1.1
		Level VI	1,869				
		Level VII	4,632				
		Level VIII	955				
		Level IX	297				
Total		1,337,478	1,337,478				

※ Level is from onsite empirical estimation and defined the corresponding Intensity

관측자료에서 P파를 탐지하고, 탐지된 P파의 진폭 정보로부터 P파보다 느린 속도로 도달하여 피해를 발생시키는 S파의 최대 진동 크기에 대한 예측 값을 산출하여 S파가 도달하기 전에 현장(관측 지점)을 대상으로 신속하게 정보한다[14]. 이는 필요한 관측의 수를 진앙에 가까운 1~2개로 감소하고 지진 기록계와 경보장치를 통합하는 등 수집 단계의 전송지연을 최소화하고, 현장에 대한 직접 연계 및 경보 전파로 경보의 속도를 높임으로써 경보 공백역을 20 km 이하로 축소할 수 있다.

하지만, 앞서 언급된 경보의 속도와 정확도의 트레이드 오프(Trade-off) 관계와 같이 온사이트 지진조기경보의 크게 향상된 경보 속도는 곧 정확도의 문제를 발생시키게 된다. 단지 1~2개의 관측만으로 경보를 결정하면 경보 기준을 넘는 크기의 오탐지가 발생할 경우 이는 그대로 오경보로 이어질 수 있다.

1.2 지진조기경보의 오탐지 발생

지진조기경보의 전통적인 탐지 방법에서 오경보를 유발할 수 있는 오탐지의 발생량을 파악하기 위해 기상청 지진조기경보 2단계 서비스 기반 구축에서 테스트한 결과 여러 위상탐지(picker) 모듈 가운데 가장 뛰어난 성능을 보여주었던 Pick_FP[15, 16]를 개선하고, 한반도 지진조기분석용으로 최적화한 pick_ffp를 이용하여 지진조기분석 관측망의 2019년 연간 관측자료에 대해 P파를 탐지한 뒤, 이 가운데 기상청 국내지진 카탈로그와 연

관되지 않는 오탐지를 분석하였다.

분석 결과 Table 1과 같이 연간 130만건 이상의 오탐지가 발생하였고, 이 오탐지에서 산출된 Pa, Pv, Pd 값을 Onsite 예측식[17]을 통해 추정된 최대지반속도(PGV) 값을 기상청 진도서비스의 지진동-진도변환식(GMICE)[18]을 이용하여 진도로 환산한 결과, 진도V 이상(MMI ≥ 4.5)인 경우도 연간 9,600여건을 넘었다.

만약 오탐지 제거를 위한 별도의 방법이 없이, 각 기상청 관측소에 독립적으로 온사이트 지진조기경보를 적용할 경우, 전국적으로 매 시간당 1회의 오경보가 발생할 수 있으며, 특히 이 가운데 절반 이상은 예측값이 진도 VII 이상으로 경주 9.12지진 본진이나 포항지진 본진 규모의 지진이 유발하는 진도에 해당하므로, 사용이 불가능하게 된다.

이처럼 오탐지를 제거하는 것은 온사이트 지진조기경보 기술의 실용화에 가장 중요한 장벽이며, 기존의 전통적인 P파 탐지 방법만으로는 해결하지 못한다. 하지만, 최근 빠르게 발전하고 있는 딥러닝 기술은 이러한 문제에 적합한 해결 방법을 제공할 수 있다.

1.3 딥러닝을 이용한 지진분석

인공지능은 기계가 주변 환경과 상황에 따라 적절히 기능하도록 하는 기술을 포괄적으로 지칭하는 용어이다. 인공지능 내에 명시적으로 프로그래

밍하지 않아도 기계가 스스로 배울 수 있는 방법을 연구하는 분야가 기계학습이고[19], 이 가운데 인공지능경망이 포함된다. 본 연구에서 사용한 딥러닝 기술은 대규모 인공지능경망을 활용한 기계학습 기술이다.

지진분야에 딥러닝 적용을 위한 노력은 최근 수년간 전세계적으로 활발히 이루어지고 있다. 지진 신호 탐지 및 분류[20], 지진 데이터 보간[21], 지진 파라미터 예측[22], 지진 잡음 분석 및 저감[23], 지하구조 이미지[24], 복합신호/모델 시각화 등이 최근 시도되는 분야이다. 대규모 데이터를 기반으로 학습된 딥러닝과 같은 최첨단 기술은 뛰어난 결과를 제공할 잠재력을 지니고 있다[25].

대만 국립 응용 연구소(National Applied Research Laboratories, NARLabs) 지진 공학 연구센터는 2017년 12월 대만에서 열린 ‘Future Tech 2017’ 전시회에서 인공지능 기반 지진조기경보 시스템을 선보였으며, 이 시스템은 딥러닝 기술을 사용하여, 축적된 지진 데이터를 바탕으로 지진 예측의 정확성을 높였다[26, 27].

Zachary E. Ross는 2018년에 합성곱신경망(Convolutional Neural Network, CNN)을 기반으로 총 1,742,763개의 파라미터를 포함한 GPD (Generalized Phase Detection)을 이용해 P파와 S파를 구분하였다. 수작업으로 분류한 4백만 건의 Southern California Seismic Network의 4초 구간의 3축 파형 데이터를 이용하여 훈련 및 테스트를 진행하였고, 검증세트에 대한 P파 및 S파의 식별 능력은 99% 이상이였다[28].

2019년에 Weiqiang Zhu는 합성곱신경망의 일종인 변형된 U-net[29]을 기반으로 한 모델을 이용하여 P파와 S파의 도달시점과 종류를 식별하였다. 이 연구는 Northern California Earthquake Data Center의 30년 동안의 지진 기록에서 전문가에 의해 분류된 7백만 건의 3축 파형 데이터를 전처리 및 정규화를 거쳐 사용하였으며, 전통적인 STA/LTA 방식의 AR picker와 비교할 때 모든 면에서 좋은 성능을 거두었다[30].

또한, 국내에서는 기상청 지진/지진 See-At 기술개발연구 사업의 일환으로 김승일 등이 지진 신호에서 추출한 멜 스펙트럼에 대해서 각각 필터를 적용하여 서로 다른 주파수 대역(저/중/고 주파수)의 신호를 추출하고 이를 각각 합성곱신경망 기반 분류를 수행하고 그 결과를 융합하여 지진 이벤트를 식별하는 연구를 진행하였다[31].

기존의 지진조기분석 기술은 전문가들이 연구한 규칙을 전통적 프로그래밍을 통해 위상탐지(picker), 연관(association), 위치추정(location), 규모산출, 결정(decision) 등의 모듈로 구현하고, 실시간 데이터를 이 모듈에 입력하여 그 출력 결과에 따라 경보하는 구조를 가진다. 이와 달리 기계학습 방법은 정답이 포함된 과거 데이터를 이용하여 기계학습 모델을 훈련시키고, 이렇게 학습된 모델에 실시간 데이터를 입력하여 산출된 예측 결과를 경보에 활용하는 구조를 가지고 있다. 기계학습 방법은 전통적 방식으로는 너무 많은 수동 조정과 규칙이 필요한 문제나 전혀 해결 방법이 없는 복잡한 문제에 적합하며[32], 탐지된 P파 가운데 오탐지를 분류하는 문제가 어려운 경우에 해당된다.

앞에서 살펴본 바와 같이 지진조기경보는 실용적인 지진예보 기술이 등장하기 전까지 지진 피해를 경감시키기 위한 현실적인 대안이다. 또한, 전통적인 지진조기경보 기술의 경우 P파에 대한 오탐지가 많기 때문에 효율성이 떨어지는 측면이 있었다. 본 논문은 지진조기경보를 최적화하기 위해 전통적 방법과 딥러닝 방법을 결합한 기술을 이용하여 지진의 P파에 대한 오탐지가 제거 가능함을 보이기 위한 타당성 실험(feasibility test)의 결과

를 설명한다. 이를 이용해 궁극적으로 온사이트 지진조기경보 기술을 활용한 지역대상 지진조기경보 방법을 제시할 수 있을 것으로 기대한다.

2장에서는 딥러닝 학습을 위한 데이터를 확보하고 가공한 방법과 결과에 대해 설명하고, 3장에서는 딥러닝을 활용하여 오탐지를 제거하기 위한 방법과 모델의 구조에 대해 설명한다. 4장에서는 이러한 딥러닝 모델을 이용한 오탐지 분류 성능을 확인하고, 연구 결과물의 실제 활용에 대한 이해를 돕기 위해 부가적으로 본 연구에서 개발된 오탐지 제거 기술이 지진조기경보 전체 틀 내에서 어떻게 적용되는지 간단하게 설명한다. 마지막으로 5장에서는 결론과 연구의 한계 및 후속 연구의 필요성을 제시한다.

2. 데이터

기계학습 알고리즘이 잘 작동하려면 충분한 양의 데이터가 필요하고, 많은 경우 알고리즘 자체보다 데이터가 모델의 성능에 더 중요한 영향을 준다[32]. 본 연구는 실시간 지진조기경보 시스템을 구성하기 위한 실용적인 목적을 위해 진행되었으며, 이에 따라 데이터는 실제 사용될 모듈과의 조합된 성능을 최적화할 수 있도록 구성하였다.

이 연구를 위해 2015년에서 2020년 3월까지 발생한 규모 2.0 이상의 국내 이벤트 727개, 국내관측 국외 이벤트 103개, 대만기상청(CWB)에서 제공받은 화렌지진이 발생했던 2018년 2월 미소지진 포함 대만 이벤트 1,734개의 이벤트 구간 관측자료에서 81,394 샘플의 학습데이터와 2018년에서 2020년 3월까지 27개월의 국내 연속자료에서 3,108,189 샘플의 학습데이터를 만들었으며, 이를 Table 2와 같이 훈련세트와 테스트세트로 분할하였다. Fig. 4는 이벤트 데이터의 이벤트 분포를 보여준다.

각 샘플들은 과거 관측자료에 대한 시뮬레이션을 통해 본 연구에서 개선한 pick_ffp 모듈로 Filter Picker[15, 16]를 이용하여 P파를 탐지하고, 탐지시점을 중심으로 4초 구간의 파형신호에서 가속도, 속도, 변위 등의 특성 값들을 추출하였으며, 이후 이벤트 카탈로그와의 비교를 통해 레이블(label)을 부여하여 작성하였다. 이때, 관측자료의 샘플률 주파수는 100 Hz, 탐지 및 특징 추출에서 0.3 Hz의 하이패스 필터(high-pass filter)를 적용하였다. pick_ffp에서 탐지한 P파에는 실제 P파와 오탐지가 섞여 있으며, 각 샘플은 기상청 지진 이벤트 카탈로그와 IASP91[34] 전지구 속도모델을 이용하여 예상 도달시간과의 오차를 기준으로 P파, S파, 노이즈로 레이블을 부여하였다.

근거리 발생 지진의 P파를 탐지하여 경보하는 지진조기경보의 목적에 최적화되도록 P파로 레이블된 샘플은 진앙으로부터 200 km 이내만을 사용하였고, 그 이상의 먼 거리에서 탐지된 것은 폐기하였다. 노이즈로 레이블된 샘플의 경우 이벤트 발생 시점부터 120초 이내에 존재하는 샘플은 지진파가 혼입될 우려가 있으므로 폐기하였다. 기타, 매 초 단위로 분할하여 전달되는 패킷에 유실이 존재하는 등 기준에 맞지 않는 샘플들도 폐기하였다.

동일한 이벤트에서 발생하여 서로 다른 관측소에 도달하여 탐지된 샘플들은 단층 파열면에 대한 방향, 전파거리 및 전파경로의 매질에 따른 감쇠와 변형 등으로 서로 차이가 존재하지만, 동일한 발생 단계의 특징을 공유함으로써 다른 이벤트에 속한 샘플 간의 유사성과 비교할 때 패턴 유사성이 높을 가능성을 배제하기 어렵다. 이에 따라 국내에서 발생된 큰 규모의 이벤트 수가 많지 않은 상황에서 만약 동일한 이벤트에서 발생한 샘플들을 훈련 세트와 테

Table 2. Dataset composition for this study [33]

	Total	FirstP	N (S + Noise + Explosion + Spall)	Data
Train Set	1,826,357	70,138	1,756,219 (9,305 + 1,726,268 + 20,605 + 41)	Korean Events (2015~2018, 2020 - excluding the mainshock of Pohang earthquake) + Teleseismic Events + Taiwan Events + Korean Continuous Data (2018, 2020)
Test Set	1,363,226	23,309	1,339,917 (3,818 + 1,308,979 + 26,999 + 121)	Korean Events (2019, the mainshock of Pohang earthquake), Korean Continuous Data (2019)

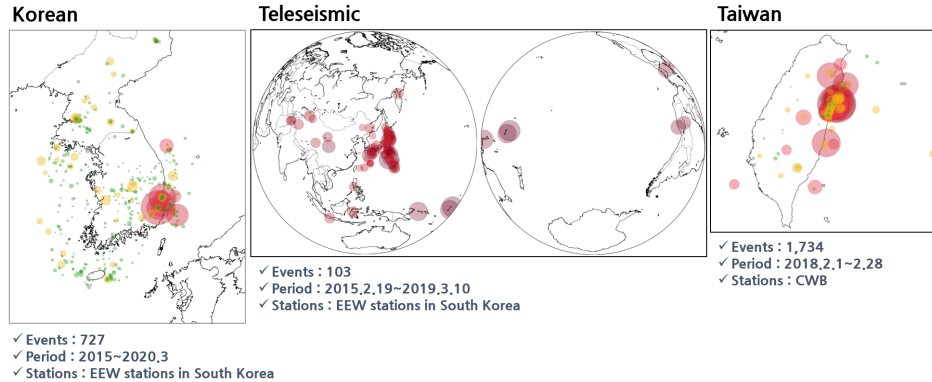


Fig. 4. Distribution of events of the event data

스트 세트에 무작위로 분배할 경우, 동일 이벤트 샘플 간에 존재하는 고유 특성에 대한 편향이 발생하여, 향후 실시간 운용시 새로운 이벤트에 대한 일반화 성능이 기대보다 저하될 우려가 있다. 이에 따라, 가끔씩 동일 이벤트의 샘플들이 훈련 세트와 테스트 세트에 분산되는 것을 최소화할 수 있도록 훈련 및 테스트 세트 분할 기준을 이벤트 발생 시기 및 지역으로 설정하였다. Table 2의 내용과 같이 훈련 세트는 2019년과 포항지진 본진을 제외한 국내 이벤트, 국내관측국의 이벤트, 대만 이벤트, 2018년과 2020년의 연속자료의 샘플로 구성했고, 테스트 세트는 2019년 발생 국내 이벤트와 포항지진 본진, 2019년 연속자료의 샘플로 구성했다. 이에 따라 훈련세트는 1,826,357개의 샘플, 테스트세트는 1,363,226개의 샘플을 포함하였다(Table 2).

또한, 학습 데이터에는 이벤트 발생 구간 관측자료에서 생성된 샘플 수(81,394)와 연속자료 샘플 수(3,108,189), 연속자료 내에서 Onsite 예측식 [17] 산출값이 오경보를 유발할 수 있는 큰(\geq MMI 4.5) 노이즈 샘플 수(24,348)와 작은($<$ MMI 4.5) 노이즈 샘플 수(3,044,708)에 있어 클래스 불균형(class imbalance) 문제가 존재한다. 이대로 모델을 학습하게 되면 다수를 차지하는 작은 노이즈 특성에 최적화되므로, P파, S파, 큰 노이즈 샘플에 대한 학습 비중을 강화할 필요가 있다. 이를 해결하기 위해 학습 데이터와 테스트 데이터에 각각 P파, S파, 큰 노이즈 샘플들을 반복하여 추가하는 균형 조정을 하였다. 이러한 균형 조정을 통해 최종적으로 모델의 훈련에 사용된 훈련세트는 4,063,907개 샘플, 테스트세트는 2,865,106개 샘플로 크기가 확대되었다.

1) 훈련 데이터 균형 조정

- 국내 이벤트(2015~2018, 2020, 포항 본진 제외) + 원거리 이벤트 + 대만 이벤트 + 국내 연속(2018, 2020)으로 기본 훈련 데이터셋 구성 → 이후 다음의 데이터를 반복 추가
- 2018, 2020 국내 이벤트, 대만 이벤트 데이터의 P와 S파 샘플: 30회

(총 31회: 기본 1 + 추가 30)

- 2018, 2020 연속자료 가운데 예측 MMI 3.5이상의 노이즈 샘플: 10회 (총 11회: 기본 1 + 추가 10)
- 2018, 2020 연속자료 가운데 예측 MMI 5.5이상의 노이즈 샘플: 30회 (총 41회: 기본 1 + 추가 10 + 추가 30)

2) 테스트 데이터 균형 조정

- 국내 이벤트(2019, 포항 본진) + 국내 연속(2019)로 기본 테스트 데이터셋 구성 → 이후 다음의 데이터를 반복 추가
- 국내 이벤트 데이터의 P와 S파 샘플: 200회 (총 201회: 기본 1 + 추가 200)
- 2019 연속자료 가운데 예측값 Level 4.5이상의 노이즈 샘플: 40회 (총 41회: 기본 1 + 추가 40)

3. 모델

본 논문에서 제시하는 새로운 실시간 오탐지 제거 방법은 전통적인 P파 탐지 방법과 딥러닝 분류 방법을 결합한 것이 특징이다. 딥러닝 분류 방법만으로도 오탐지를 최소화하며 P파를 탐지하는 것이 가능하지만, 관측자료의 모든 구간에 대해 특징 추출 및 딥러닝 연산을 하기 위해서는 계산 비용이 지나치게 증가될 수 있다. 전통적 기술에 의해 선택된 구간에 대해서만 딥러닝 기술을 적용함으로써 많은 연산이 필요한 특징 추출 방법 및 깊은 층의 신경망을 사용하더라도 시스템의 부담이 최소화되도록 하였다. 또한, 전통적인 방법의 탐지 성능과 새로운 방법의 분류 성능을 모두 적용함으로써 오탐지 제거 성능을 극대화할 수 있었다.

딥러닝 모델은 구글 Tensorflow[35]의 C API를 기반으로 구현하였고, 또한 특징 추출 및 딥러닝 분류를 포함한 모든 부분을 C언어를 사용한




Fig. 5. Onsite-EEW procedure with real-time false-pick filter based on deep learning

USGS Earthworm의 모듈로 개발하여, 수백 개의 기상청 지진조기경보 관측소를 대상으로 하는 실시간 운용 및 라즈베리파이(Raspberry Pi)와 같은 소형 장치에서 소규모 운용이 모두 가능하도록 하였다.

딥러닝 기반 실시간 오탐지 제거를 사용하기 위한 기본적인 온사이트 지진조기경보 분석 프로세스는 Fig. 5와 같다. 먼저 실시간 관측신호에서 전통적 방식으로 P파를 탐지하고, 탐지시점을 중심으로 일정 구간의 관측값에서 특징을 추출한 다음, 이를 합성곱신경망(Convolutional Neural Network, CNN)[36] 기반 모델을 통한 분류를 거쳐 오탐지를 제거한다. 이후 P파의 특성값에서 앞으로 도달할 S파의 크기를 추정하여 지진의 발생을 정보하는 흐름을 갖는다.

3.1 P파 탐지

전통적인 P파 탐지 기술은 긴 시간 구간의 신호 크기 평균(Long-Term Average, LTA)에서 짧은 시간 구간의 신호 크기 평균(Short-Term Average, STA)을 전체 또는 주파수별로 비교하여 일정한 기준을 초과할 경우에 P파의 탐지를 결정하는 방식을 응용한다[37]. 이러한 방법은 오랜 기간 활용을 통해 충분히 검증되었고, 연산의 처리속도가 빠르며, 검출시점에 대해 일관적이므로, 기계학습 입력용 특징을 추출하기 위한 일관된 시간구간을 결정하는데 유용하다[15, 16]. 하지만, 관측자료에는 다양한 원인과 형태의 임펄스 노이즈(impulse noise)가 포함되는데, 이들 역시 긴 시간 구간에 대해 짧은 시간 구간의 신호 크기가 증가하는 형태를 갖기 때문에 일부는 P파 탐지를 위한 기준을 충족하여 오탐지를 발생시키게 된다.

본 연구에서는 이러한 전통적 P파 탐지 방법인 FilterPicker[15, 16] 알고리즘을 사용하는 pick_ffp 모듈을 이용하여 P파를 최초 탐지하였다. pick_ffp는 기상청 지진조기경보 2단계 서비스 기반 구축에서 위상탐지(picking) 알고리즘 4종에 대한 테스트 결과 최종 선택된 pick_FP[15, 16] 모듈을 기반으로 과거 국내 이벤트 대상 매개변수 조합 테스트를 통해 한반도 지역에 최적화한 것이다. pick_ffp는 본 연구에서 각기 별도로 전송되는 3축 채널의 전송 패킷들을 실시간 결합하고, 3축 특성값(속도, 가속도, 변위 등)들을 산출하여, 오탐지 식별을 위한 딥러닝 추론(inference) 모듈 및 예상진도 추정에 대한 입력값으로 제공할 수 있도록 하였다.

3.2 오탐지 식별

본 연구에서는 신호의 수직 성분 크기 변화를 기준으로 하는 전통적인 방법에서 발생한 오탐지를 제거하기 위해, P파와 오탐지 간의 3축 성분 주파수 분포의 패턴이 가지는 차이를 딥러닝 모델에 학습시켜 분류하는 방법

을 사용하였다.

EEWNet Part 1 ‘False-Pick Filter’는 Fig. 6과 같이 pick_ffp에서 산출된 3축 성분의 특성값에서 P파 도달시점 기준 전후 각 2초씩, 총 4초의 관측 자료에 대한 1초 단위 로그-멜 파워 스펙트럼(Log-Mel Power Spectrum)의 특징을 추출하고, 이를 합성곱신경망을 통해 실제 P파 및 오탐지로 분류하는 모델이다.

합성곱신경망(Convolutional Neural Network, CNN)은 이미지 인식 분야에서 주로 사용되며, 기본적으로 합성곱층(convolutional layer)과 풀링층(pooling layer)을 이용하여 이미지를 단순한 특징에서 복잡한 특징으로 추상화하고, 마지막 완전연결층(fully connected layer)에서 분류를 수행하는 구조를 갖고 있다[36]. 본 모델은 3축 성분의 특징벡터에 대한 합성곱 연산을 수행할 수 있도록 구성되었다.

모델은 크게 특징추출(feature extraction)과 특징학습(feature learning), 분류(classification) 단계로 구성되어 있다.

특징추출 단계에서는 각 축별로 정규화된 4초 길이의 파형으로부터 1초 단위로 패딩(padding), 파워스펙트럼(power spectrum) 변환, 멜 필터뱅크(mel-filterbank) 적용, 로그스케일(log-scale) 변환을 거쳐 256 길이의 로그-멜 파워 스펙트럼 벡터를 생성한다. Fig. 7은 특징추출 단계에서 산출한 P파, 노이즈, S파의 특징벡터들을 시각화한 예시이다.

특징학습 단계에서는 3축의 로그-멜 파워 스펙트럼 벡터를 합친 3x256 크기의 입력벡터에 대해 5번의 합성곱(convolution)과 맥스풀링(max-pooling) 연산을 통해 핵심 특징들을 학습한다. 일반적으로 합성곱신경망은 단계별로 필터(filter)의 개수를 증가하지만, 본 모델은 첫 합성곱층부터 필터의 갯수를 26개로 구성하고 마지막 합성곱층까지 동일하게 유지함으로써 세밀한 특징의 정보가 최종 단계에 전달될 수 있도록 한 것이 특징이다. 각 합성곱층에는 3x3 크기의 2차원 필터를 사용하였고, 1x1의 스트라이드(strid)를 적용하였다. 풀링층은 최초 4번은 (1, 3), 마지막은 (3, 3) 크기의 맥스풀링을 적용하였다. 이때 활성화수는 ReLu(Rectified Linear Unit)를 사용하였다[38]. 또한, 과적합을 줄이기 위해 평탄화(flatten) 레이어와 완전연결층(fully connected layer) 사이에 확률 0.4의 드롭아웃(dropout) 레이어를 구성하였다[39, 40].

분류 단계에서는 완전연결층을 거쳐 최종적으로 P파와 P파가 아닌 것으로 이진분류(binary classification)를 수행한다. 마지막 층의 활성화수는 소프트맥스(softmax)를 사용하였다[40].

이 모델은 1,826,357개의 훈련 데이터의 양에 비해 충분히 작은 24,934개의 파라미터를 가지고 있어, 과적합을 최소화할 수 있도록 하였다.

지진조기경보에 적용하기 위한 모델의 개발에서 P파 도달시점을 기준으로 몇 초의 시간구간에 대한 특징을 사용할 것인지 결정하는 것은 중요한

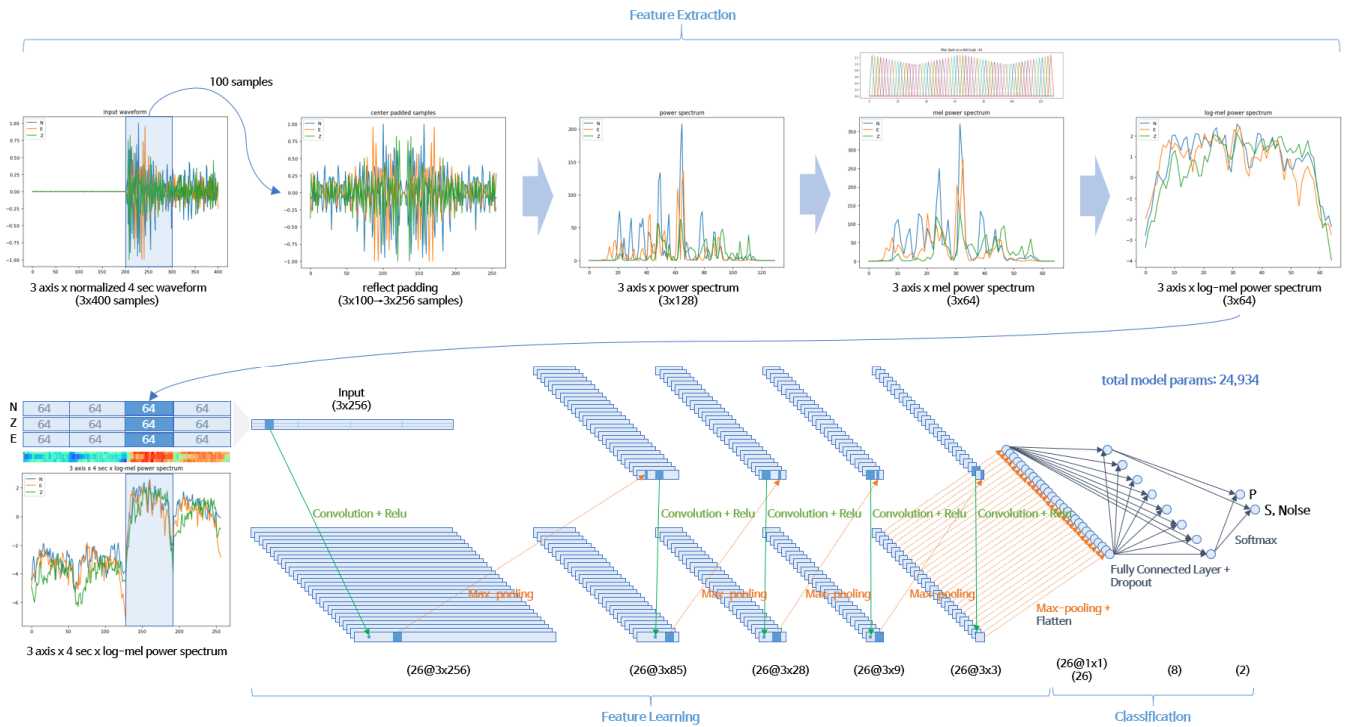


Fig. 6. Schematic diagram of the EEWNet Part 1 'False-Pick Filter' [33]

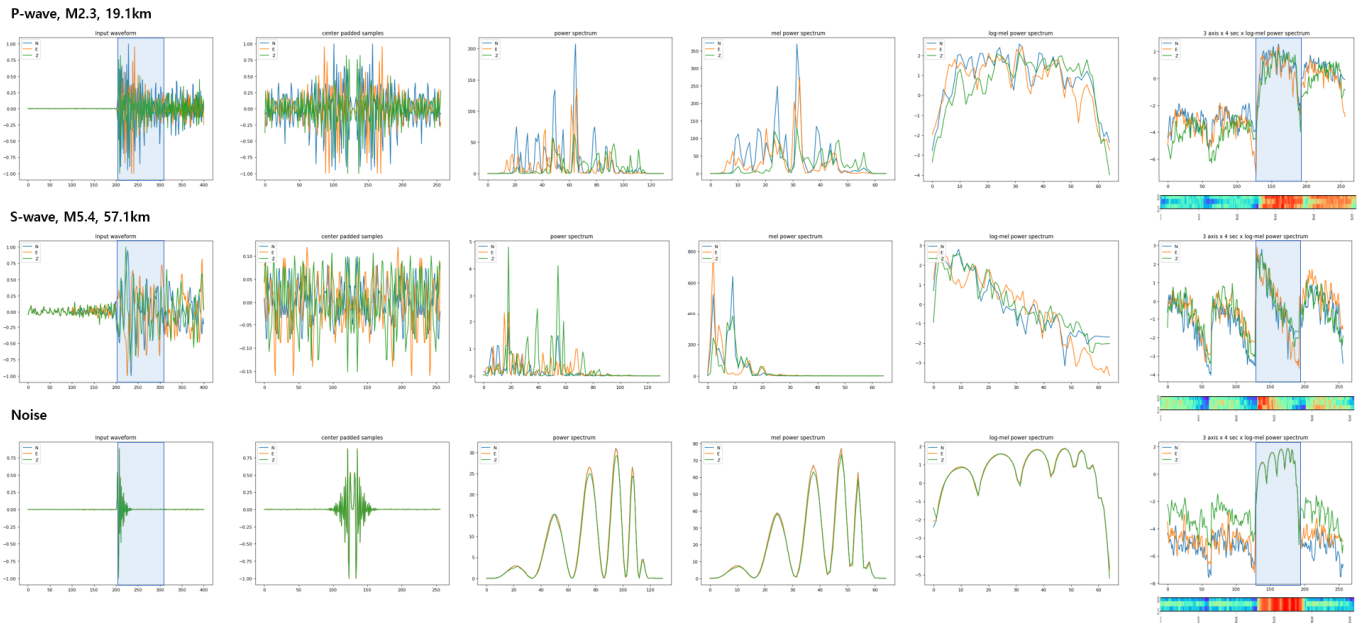


Fig. 7. Example of the visualized outputs from the feature-extraction steps of P-wave, S-wave, and noise

요소이며, 이는 지진조기경보의 속도와 정확도에 크게 영향을 미친다. 만약 이 시간구간을 1초로 줄일 경우에는 경보의 속도를 최대한 신속하게 할 수 있지만, 분류의 정확도가 상당히 낮아진다. 3초 이상으로 늘일 경우에는 전체적인 정확도는 약간 상승하지만 지진조기경보에 있어서 가장 중요한 진앙에 가까운 지점에서는 S파의 혼입이 발생하여 진앙 인근에서 오히려 성능이 떨어질 우려가 있으며, 경보의 속도가 지나치게 늦어진다. 이에 따라 본 모델은 시간구간을 P파 도달 이후 2초까지로 결정하였다.

3.3 훈련

모델은 균형 조정을 거친 훈련 세트를 이용하여 훈련하였다. 모델의 훈련 과정에는 가중치 초기화(weight initialization)에 무작위(random)값이 포함되므로 각 결과마다 성능의 차이가 존재하며[41], 여러 결과 가운데 균형 조정을 거친 테스트 세트에 대한 정확도(accuracy)와 2019년 국내 연속 자료에서 오경보를 발생시키는 오탐지에 대한 차단 성능을 종합적으로 관찰하여 최종적으로 결과를 선택하였다.

Table 3. Test Result of Balanced Test Set (Events and Continuous Data Samples)

Test Data	Definition		Filtering Result	
Test Set	Accuracy		97.58%	
	P-wave	Success (pass)	95.58%	1,007,139 / 1,053,709
		Failure (stop)	4.42%	46,570 / 1,053,709
	S-wave Noise	Success (stop)	98.74%	1,788,591 / 1,811,397
		Failure (pass)	1.26%	22,806 / 1,811,397

Table 4. Test Result of 2019 Korean Continuous Data

Test Data	Definition		Filtering Result	
2019 Korean Continuous Data	Accuracy		98.65%	
	P-wave	Success (pass)	77.09%	13,998 / 18,157
		Failure (stop)	22.91%	4,159 / 18,157
	S-wave Noise	Success (stop)	98.95%	1,323,376 / 1,337,478
		Failure (pass)	1.05%	14,102 / 1,337,478

Table 5. Model's test result for false-picks of 2019 Korean Continuous Data [33]

Test Data	False Alarm Risk	Noise Level	Number of samples	Filtering Result	
				Success (stop) Rate	Failure (pass) Rate
False-Picks of 2019 Korean Continuous Data	Small false-pick detections that do not trigger false alarms	Level I	1,296,313	98.93%	1.07%
		Level II	21,540	99.48%	0.52%
		Level III	7,093	99.38%	0.62%
		Level IV	2,857	99.54%	0.46%
	Large false-pick detections that can cause false alarms	Level V	1,922	99.84%	0.16%
		Level VI	1,869	100.00%	0.00%
		Level VII	4,632	100.00%	0.00%
		Level VIII	955	99.90%	0.10%
		Level IX	297	100.00%	0.00%
		Total		1,337,478	98.95%

4. 결과

모델의 성능 평가는 테스트 샘플의 특징벡터를 모델에 입력하여 예측된 레이블을 정답과 비교한 결과에 대한 정확도(accuracy)를 지표로 사용하였으며, 이는 P파를 P파로 예측한 샘플과 P파가 아닌 것을 P파가 아닌 것으로 예측한 샘플의 수를 전체 테스트 샘플의 수로 나눈 값이다. 이러한 성능 평가의 결과는 pick_ffp가 P파로 탐지한 샘플 내의 실제 P파와 오탐지를 대상으로 한 식별 성능이기 때문에 pick_ffp가 이미 대부분의 노이즈 및 S파를 차단한 것을 감안하여야 한다.

Table 3과 같이 균형 조정을 거친 테스트 세트에 대하여 테스트한 결과 정확도는 97.58%였다.

Table 4와 같이 2019년 국내 연속자료의 샘플을 대상으로 한 테스트 결과의 정확도는 98.95%였다. 이 결과는 균형 조정을 거치지 않은 연간 연속 자료를 대상으로 하였기 때문에 규모 2.0 이하의 미소지진의 샘플 비율이 높고, 균형 조정을 거친 테스트 세트에 대한 결과와 비교할 때 오인차단이 4.42%에서 22.91%로 증가하였다. 하지만, 미소지진은 지진조기경보의 관심대상이 아니다.

Table 5는 2019년 발생한 연간 오탐지에 대한 테스트 결과이다. 노이즈

레벨은 경험식 추정을 통해 상응하는 진도 기준값으로 정의하였으며, 예상 진도 추정은 pick_ffp에서 산출한 특성값(속도, 가속도, 변위 등)에서 P파 도달 후 2초 구간의 수직성분 Pa, Pv, Pd 값을 산출하여 ‘한국형 지진현장 경보를 위한 예측 경험식’[17]에 입력하여 산출된 결과를 사용하였다. 테스트 결과 1년간 발생된 오경보를 유발할 수 있는 크기의 오탐지 9,675개 가운데 99% 이상이 차단되었다. 차단에 실패한 극소수의 오경보를 유발할 수 있는 샘플들이 존재하였지만, 이들은 추가적으로 “기계학습을 이용한 지역 대상 지진조기경보를 위한 실시간 경보 결정 방법”[42]의 적용을 통해 최종적으로 모두 차단되었다.

“기계학습을 이용한 지역대상 지진조기경보를 위한 실시간 경보 결정 방법”은 기계학습을 이용한 지역대상 지진조기경보 시스템의 실시간 지진조기경보 발령 결정 과정에 있어 경보 시점을 최대한 앞당기고, 오경보를 최소화하도록 결정하는 방법이다. Fig. 8과 같이 한 관측소에서 P파를 감지한 후 일정 시간의 추가 관측을 통해 오탐지 제거를 위한 분류와 경보를 위한 예측을 수행한 후, 기계학습을 이용한 분류 결과가 지진으로부터 발생한 P파이고, 예측되는 최대 지진동이 경보 기준 이상일 때, 기준 거리 범위 내의 다른 관측소에서 기준 시간 범위 내에 P파를 감지하였을 경우, 오경보의 확률을 최소화한 상태에서 지역대상 지진조기경보를 발령하는 방법이다[42].

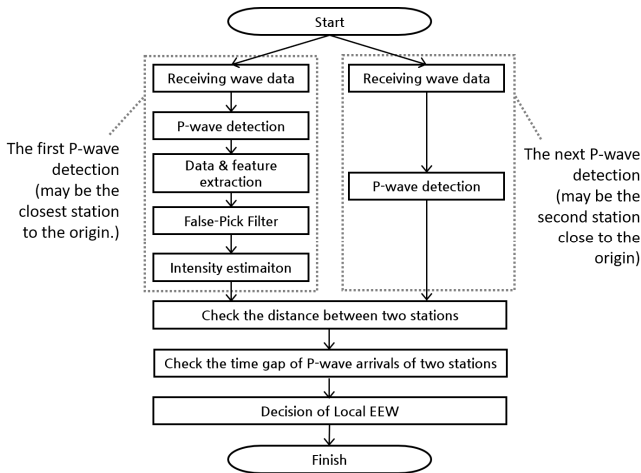


Fig. 8. Process of determining real-time alarm for local target EEW using mechanical learning [42]

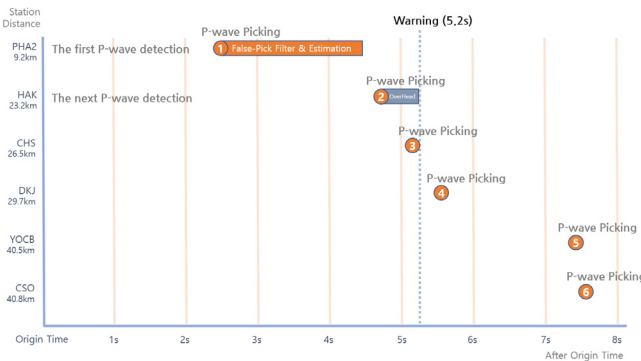


Fig. 9. Expected decision timing of the Pohgang Earthquake (M5.4) by combined algorithms of False-Pick Filter and local EEW illustrated in Fig. 8 [42]

본 연구의 결과를 기상청 지진조기분석 관측망에 “기계학습을 이용한 지역대상 지진조기경보를 위한 실시간 정보 결정 방법”과 함께 적용할 경우 현재 네트워크 기반 지진조기경보가 8개 관측소의 탐지를 기다린 후 경보하는 것에 비해 2개의 관측소 탐지 후 신속히 지역에 경보하는 것이 가능하다. Fig. 9는 포항지진 본진(M5.4)에서 진원 인근 관측소에 대한 IASP91[34] 전지구 속도모델에 의한 P파 도달시점과 이 방법을 통해 이론적으로 예상되는 경보시점을 보여준다. 그림에서 상단으로부터 진원에 가까운 순서로 관측소가 나열되었으며, 우측 방향으로 진원시 이후 시간의 경과를 보여준다. 먼저 진원에 가장 인접한 포항(PHA2) 관측소가 최초로 지진관측을 하고, 이후 2초 동안 딥러닝을 이용한 오탐지 차단 및 예측값 산출을 한다. 이후 학계리(HAK) 관측소가 두 번째 지진관측을 하고, 두 관측의 거리와 시간차를 확인한 다음, 전승 및 분석 등의 지연을 고려한 0.5초의 오버헤드를 추가하여, 대략 5~6초에 경보가 결정될 것으로 추정하였다. 위의 방법을 구현한 실시간 프로토타입 시스템을 이용하여 과거지진 시뮬레이션을 수행한 결과, 포항(PHA2) 관측소의 최초 지진관측 후 2.2초에 학계리(HAK) 관측소가 두 번째 지진관측을 하였고, 최초 관측 3초 내외에 지역대상 지진조기경보를 결정하였다. 과거 포항지진 본진(M5.4) 발생 시에 최초 지진관측은 발생 후 3초였으며, 지진조기경보는 최초 관측 후 19초에 발령되었다[43]. 그리고, 훈련세트에 포함된 이벤트로 지진 관측망 외곽에서 발

생된 포항지진과는 달리 관측망 내부에 위치한 경주 9.12지진의 전진(M5.1)과 본진(M5.8)에 대한 과거지진 시뮬레이션에서는 최초 관측 2초 내외에 경보가 결정되었다.

5. 결론

본 연구는 딥러닝 기술을 이용하여 오경보를 유발할 수 있는 지진에 대한 오탐지를 차단할 수 있음을 보여주고 이를 이용하여 지진조기경보의 속도와 정확성을 높이기 위하여 진행되었다. 이를 위해 P파 도달시점 기준 전후 각 2초씩, 총 4초의 관측자료에 대한 1초 단위 로그-멜 파워 스펙트럼의 특징을 추출하고, 이를 합성곱신경망을 통해 실제 P파 및 오탐지로 분류하는 EEWNet Part 1 ‘False-Pick Filter’ 모델을 제시하였다.

이를 훈련하고 테스트하기 위해 국내 발생 이벤트, 국내 관측국의 이벤트, 대만 이벤트의 관측자료 및 27개월간의 국내 연속자료를 처리하여 3,189,583 샘플의 데이터를 만들었다.

최종적으로 2019년 연속자료에 대한 테스트 결과 1년간 발생된 오경보를 유발할 수 있는 크기의 오탐지 9,675개 가운데 99% 이상을 차단하였다. 차단되지 못한 소수의 오탐지는 “기계학습을 이용한 지역대상 지진조기경보를 위한 실시간 정보 결정 방법”[42]의 적용을 통해 최종적으로 모두 차단되었다.

연구 결과를 지진조기경보 관측망에 적용하여 지역경보로 활용하면, 기존의 지진조기경보보다 빠른 경보가 가능하게 되며, 과거 포항지진 본진의 경우에는 경보시점을 진원시 기준 6초 내외로 단축할 수 있게 된다.

본 연구의 결과는 USGS Earthworm 기반의 모듈로 구현되었으며 일반화된 성능의 검증에 위해 실시간 프로토타입 시스템을 구축하여 2020년 10월부터 기상청에서 실시간 시험운용을 통해 성능과 안정성에 대한 검증을 진행 중이다.

본 연구의 한계로 진원에 매우 근접한 관측소에서 2초의 특징추출 구간 내에 P파와 S파가 혼입될 경우, 이로 인한 오인차단이 발생할 수 있다. 향후 이를 개선하고, 경보의 시점을 앞당기기 위하여, 오탐지 차단 성능을 유지하며 특징추출 구간을 P파 도달시점 이후 2초에서 1초의 단축할 필요가 있다. 하지만, 이를 위하여 전 과정에 대한 최적화와 보조 센서를 활용하는 방법 등의 다양한 후속 연구가 필요하다.

/ 감사의 글 /

본 연구를 위하여 관측자료를 제공해주신 한국 기상청과 대만 기상청에 감사드립니다.

또한, 세심하고 아낌없는 조언을 해주신 육군사관학교 이성태 교수, 서울디지털대학교 서동조 교수, 고려대학교 구분화 교수, 편집위원과 익명의 심사위원 들께 감사드립니다.

본 논문은 한국기상산업기술원 기상지진 See-At 기술개발사업의 연구비 지원(KMI2018-02210)에 의해 수행된 것으로 이에 감사드립니다.

/ REFERENCES /

1. Jeon YS, Park EH, Lee DK, 9.12 Earthquake Response Report, Korea Meteorological Administration, 2017, 28 p.
2. Bebbington M, Harte D, The linked stress release model for spatio-temporal seismicity: formulations, procedures and applications, *Geophysical Journal International*, 2003 Sep;154(3):925-946.
3. Pritchard ME, Allen RM, Becker TW, Behn MD, Brodsky EE, Bürgmann R, Ebinger C, Freymueller JT, Gerstenberger M, Haines B, Kaneko Y, Jacobsen SD, Lindsey N, McGuire JJ, Page M, Ruiz S, Tolstoy M, Wallace L, Walter WR, Wilcock W, Vincent H, New Opportunities to Study Earthquake Precursors, *Seismological Research Letters*, 2020 JUL;91(5):2444-2447.
4. Allen MR, Kanamori H, The Potential for Earthquake Early Warning in Southern California, *Science*, 2003 May;300(5620):768-789.
5. Allen RM, Melgar D, Earthquake Early Warning: Advances, Scientific Challenges, and Societal Needs, *Annual Review of Earth and Planetary Sciences*, 2019 May;47:361-388.
6. Allen RM, Probabilistic warning times for earthquake ground shaking in the San Francisco Bay Area, *Seismological Research Letters*, 2006;77(3):371-376.
7. Hoshiba M, Iwakiri K, Hayashimoto N, Shimoyama T, Hirano K, Yamada Y, et al, Outline of the 2011 off the Pacific coast of Tohoku Earthquake (Mw 9.0)—Earthquake Early Warning and observed seismic intensity, *Earth, Planets and Space*, 2011 May;63(7).
8. Cochran ES, Kohler MD, Given DD, Guiwits S, Andrews J, Meier MA, et al, Earthquake early warning ShakeAlert system: Testing and certification platform, *Seismological Research Letters*, 2018; 89(1):108-117.
9. Meier MA, Ross ZE, Ramachandran A, Balakrishna A, Nair S, Kundzicz P, et al, Reliable Real Time Seismic Signal/Noise Discrimination With Machine Learning, *Journal of Geophysical Research: Solid Earth*, 2019;124:788-800.
10. Meier MA, Kodera Y, Bese M, Chung A, Hoshiba M, Cochran E, et al, How often can Earthquake Early Warning systems alert sites with high intensity ground motion?, *Journal of Geophysical Research: Solid Earth*, c2020.
11. Chung A, Henson I, Allen RM, Optimizing Earthquake Early Warning Performance: Elarms3, *Seismological Research Letters*, 2019;90 (2A):727-743.
12. Seo JB, Lee JK, Jeon I, Cho KC, Park NR, Lee ST, Ko HW, Jeong H, Lee JH, Jang GR, Lee JK, Kang JW, Cho CK, Lee JW, Park DK, Lee SK, Kang HR, Lee HK, Kim MC, Kang CS, Choi YJ, A Development of Base for Earthquake Early Warning 2nd Step Service (III), Korea Meteorological Administration, c2018.
13. Caruso A, Colombelli S, Elia L, Picozzi M, Zollo A, An on-site alert level early warning system for Italy: An onsite early warning system for Italy, *Journal of Geophysical Research: Solid Earth*, c2017.
14. Wu YM, Kanamori H, Experiment on an Onsite Early Warning Method for the Taiwan Early Warning System, *Bulletin of the Seismological Society of America*, 2005;95(1):347-353.
15. Lomax A, Satriano C, Vassallo M, Automatic Picker Developments and Optimization: FilterPicker—a Robust, Broadband Picker for Real-Time Seismic Monitoring and Earthquake Early Warning, *Seismological Research Letters*, 2012;83:531-540.
16. Vassallo M, Satriano C, Lomax A, Automatic Picker Developments and Optimization: A Strategy for Improving the Performances of Automatic Phase Pickers, *Seismological Research Letters*, 2012; 83(3):541-554.
17. Lee HJ, Jeon I, Seo JB, Lee JK, Application of the onsite EEW technology using the P-wave of seismic records in Korea, *Journal of the Society of Disaster Information*, 2020;16(1):133-143.
18. Seo JB, Introduction to the production procedures and technologies of KMA intensity information, Korea Meteorological Administration, 2019 Apr:56-59.
19. Samuel AL, Some studies in machine learning using the game of checkers, *IBM Journal of Research and Development*, 1959;3(3):210-229.
20. Perol T, Gharbi M, Denolle M, Convolutional neural network for earthquake detection and location, *Science Advances*, 2018 Feb;4(2).
21. Wang B, Zhang N, Lu W, Wang J, Deep-learning-based seismic data interpolation: A preliminary result, *GEOPHYSICS*, 2019 Jan; 84(1):1JF-Z5.
22. Derakhshani A, Foruzan AH, Predicting the principal strong ground motion parameters: A deep learning approach, *Applied Soft Computing*, 2019 Jul;80:192-201.
23. Seydoux L, Balestrieri R, Poli P, Hoop M, Campillo M, Baraniuk R, Clustering earthquake signals and background noises in continuous seismic data with unsupervised deep learning, *Nat Commun*, 2020 Aug;11:3972.
24. Araya-Polo M, Jennings J, Adler A, Dahlke T, Deep-learning tomography, *The Leading Edge*, 2018 Jan;37(1):2-80.
25. Kong Q, Chai C, Li Z, Chen M, Wang R, 2018 Seismology of the Americas Meeting: Technical Sessions: Applications of Machine Learning and Data Science in Seismology, *Seismological Research Letters*, 2018 Mar-Apr;89(2B):728-729.
26. Hsu TY, Wang HH, Lin PY, Lin CM, Kuo CH, We KL, Performance of the NCREE's onsite warning system during the 5 February 2016 Mw 6.53 Meinong earthquake, *Geophysical Research Letters*, 2016 Aug;43(17).
27. Choi YS, Earthquake prediction and warning in 5 seconds by artificial intelligence... AI earthquake early warning system released in Taiwan, [Internet], IT Chosun, 2018 Jan, Available from: http://it.chosun.com/site/data/html_dir/2018/01/01/2018010185010.html.
28. Ross ZE, Meier MA, Hauksson E, Heaton TH, Generalized Seismic Phase Detection with Deep Learning, *Bulletin of the Seismological Society of America*, 2019 Jan;108(5A):2894-2901.
29. Ronneberger O, Fischer P, Brox T, U-Net: Convolutional Networks for Biomedical Image Segmentation, *Miccai*, 2015:234-241.

30. Zhu W, Beroza GC. PhaseNet: A Deep-Neural-Network-Based Seismic Arrival Time Picking Method. arXiv:1803.03211v1 [physics.geo-ph]. c2018.
31. Kim SI, Kim DH, Shin HH, Ku BH, Ko H. Earthquake detection based on convolutional neural network using multi-band frequency signals. 2019;38(1):23-29.
32. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 2nd Edition. O'Reilly Media, Inc.; c2019.
33. Seo JB, Lee JK, Jeon I, Lee HJ. Development of Onsite warning technology using Deep Learning. Proceedings of EESK Conference 2020. 2020 Sep;7-8.
34. Kennett BLN, Engdahl ER. Travel times for global earthquake location and phase association. Geophysical Journal International. 1991;105:429-465.
35. Abadi M, Agarwal A, Barham P, Brevdo E, Chen Z, Citro C, Corrado GS, Davis A, Dean J, Devin M, et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems. c2016.
36. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems 25 (NIPS 2012). 2012:1097-1105.
37. Allen RV. Automatic earthquake recognition and timing from single traces. Bulletin of the Seismological Society of America. 1978;68(5):1521-1532.
38. Nair V, Hinton GE. Rectified linear units improve restricted boltzmann machines. 27th International Conference on Machine Learning (ICML 2010). c2010.
39. Srivastava N. Improving neural networks with dropout. Ph.D. thesis, University of Toronto. 2013.
40. Goodfellow I, Bengio Y, Courville A. Deep Learning. MIT Press. c2016.
41. Fernández-Redondo M, Hernández-Espinosa C. Weight initialization methods for multilayer feedforward. ESANN. 2001 Apr:119-124.
42. Seo JB, Lee JK, Lee HJ, Jeon I, Lee J, Ahn JK, inventors; Method for determining real-time alarm for local target earthquake early warning using mechanical learning. Korean patent 10-2020-0147842.
43. Volcano, Earthquake, Tsunami, Korea Meteorological Administration, [Internet]. Available from: https://www.weather.go.kr/download_01/disaster_book.pdf: 14 p.