

합성곱 신경망을 이용한 지진자료 품질관리

이서안 · 신동훈[‡]

전남대학교 지질환경과학과

요 약

지진 관측소의 증가는 지진 감지 능력을 향상시켜 실시간 지진 통보 및 지진조기경보 시간을 단축하는 데 효과적이다. 하지만 관측소의 증가는 지진자료 품질관리의 어려움 또한 증가시킨다. 그러므로 본 연구에서는 1시간 길이의 시간 영역 자료를 주파수 영역으로 변환한 파워스펙트럼밀도를 품질관리를 위한 입력자료로 사용하여, 지진자료의 품질을 자동으로 평가하는 기술을 개발하고자 한다. 이를 위해 광대역 속도계 10,309개의 파워스펙트럼밀도를, 가속도계 4,452개의 파워스펙트럼밀도를 수집하여 심층학습의 일종인 합성곱 신경망의 입력자료로 사용하였다. 광대역 속도계와 가속도계를 구분하여 두 개의 합성곱 신경망 모델을 학습시켜, 자동으로 자료의 품질을 정상상태와 이상상태로 평가할 수 있는 기술을 개발하였다. 본 연구를 통해 얻은 품질평가 모델의 정확도가 99.9% 이상으로 측정되었으며, 15분 길이의 자료를 이용한 파워스펙트럼밀도로도 지진자료의 품질을 효과적으로 평가할 수 있음을 확인하였다. 이를 통해 본 연구의 품질평가 모델을 이용하면 지진자료의 품질관리를 보다 효율적으로 수행할 수 있을 것으로 기대한다.

주요어: 파워스펙트럼밀도, 품질관리, 심층학습, 합성곱 신경망

Seoahn Lee and Dong-Hoon Sheen, 2021, Quality control of seismic data based on convolutional neural network. Journal of the Geological Society of Korea. v. 57, no. 3, p. 329-338

ABSTRACT: Installing more seismic stations may result in improving the capability of earthquake monitoring and shortening the time to report the occurrence of earthquakes or deliver public earthquake warnings. However, accordingly, it becomes difficult to assess the condition of seismic instrument. The goal of this study is to develop an automated method for assessing the quality of seismic data, which is based on power spectral densities (PSD) of one-hour waveform data. We collected 10,309 PSDs of broadband seismometers and 4,452 PSDs of accelerometers recorded from 2016, 2017 and 2019, and used them as the input of the convolutional neural network (CNN), a class of deep learning. Two deep CNNs for broadband seismometer and accelerometer were trained to automatically determine the condition of seismic data: normal and abnormal conditions. We find that the condition of seismic data determined by the CNNs have an accuracy of 99.9% and they can successfully determine the condition from PSDs of 15-minute waveforms. The outstanding performance of the trained models indicates that this can be a very effective tool for assessing the condition of seismic instrument.

Key words: power spectral density, quality control, deep learning, convolutional neural network

(Seoahn Lee and Dong-Hoon Sheen, Department of Geology and Environmental Sciences, Chonnam National University, Gwangju 61186, Republic of Korea)

1. 서 론

2020년 12월 기준으로 기상청은 총 265소의 지진 관측소를 운영하고 있다. 이러한 다수의 지진관측소에서 생산하는 지진자료에는 지진계의 이상, 일시적인 오작동, 전송 불량 등 다양한 원인으로 인한 지진

계의 이상상태를 기록한 자료들도 포함될 수 있다. 대부분의 경우 이상상태가 시작한 뒤 이른 시일 내에 정상상태로 복구되지만, 오랫동안 이상상태가 지속되어 지진 신호를 구분하기 어려운 자료들도 간혹 포함되어 있다. 만약 관측 자료의 이상으로 인해 지진파를 감지하지 못하거나 잘못된 신호를 감지하면

[‡] Corresponding author: +82-62-530-3454, E-mail: dhsheen@jnu.ac.kr

지진조기경보의 경보가 지체되거나 오경보를 야기할 수 있으므로 지진 관측소에서 전송되는 자료들의 품질관리가 중요하다. 현재 국내의 주요 지진관측기관에서는 지진자료의 품질관리를 위해 관측소별 배경잡음 분석을 수행하고 있지만 이를 품질관리에 충분히 활용하고 있지 못하다. 다수의 지진 관측소에서 전송된 많은 양의 지진자료를 하나하나 육안으로 검토하는 방식의 품질관리는 한계를 가질 수밖에 없다.

배경잡음은 다양한 원인에 의해 지진계에 기록되는 잡음을 통틀어 이르는 말로, 약 0.001 ~ 약 100 Hz의 넓은 범위에 걸쳐서 발생 원인에 따라 서로 다른 주파수 대역에서 특징적인 분포를 가진다. 일반적으로 1 ~ 10 Hz의 고주파 영역에서는 교통수단이나 공장 등 인간활동이 주된 원인으로 알려져 있으며(Kanai and Tanaka, 1961; Kim *et al.*, 2004; Sheen and Shin, 2010), 약 0.1 Hz 이하의 저주파 배경잡음은 해양에서 파도 활동이 있을 때 두드러지게 배경잡음 변화가 나타나며 이를 맥동(microseism)으로 부른다(Hasselmann, 1963; Cherry, 1974; Peterson, 1993; Sheen *et al.*, 2009). 이보다 훨씬 저주파 영역에서는 지표의 계절적인 온도 변화나 바람에 의한 미세한 기압변화가 원인으로 배경잡음이 발생한다(McNamara and Buland, 2004).

이러한 배경잡음의 특성이나 변화 등의 연구에 시간 영역의 지진자료를 주파수 영역에서 진폭스펙트럼 값으로 표현한 파워스펙트럼밀도(power spectral density)가 널리 사용되어 왔다(Aster *et al.*, 2008; McNamara *et al.*, 2009; Koper and Burlacu, 2015; Poli *et al.*, 2020; Guenaga *et al.*, 2021). 국내에서도 이러한 파워스펙트럼밀도를 이용한 연구들이 많이 이루어졌는데, Cho *et al.* (2009)는 기상청에서 운영하는 관측소의 배경잡음을 분석하여 광대역 관측소의 표준배경잡음 모델을 개발하였고, Sheen *et al.* (2009)는 국내 관측소의 파워스펙트럼밀도로부터 주파수별, 계절별 배경잡음 변화를 살펴보았으며, Sheen and Shin (2010)은 주·야간 배경잡음 수준 차이를 고려하여 국내 광대역 관측소의 지진 관측 능력을 분석한 바가 있다.

Seo (2019)는 지진자료의 품질관리를 하고자 2016년에서 2017년까지의 광대역 속도계의 파워스펙트럼밀도를 정상, 이상, 지진 신호로 분류하고 합성곱

신경망(convolutional neural network)을 이용한 자동 평가 기술을 개발한 바가 있다. 그런데 지진 신호는 일시적으로 기록되는 신호이므로 지진자료 품질의 관점에서는 정상상태로 볼 수 있다. 따라서 본 연구에서는 지진자료의 품질을 정상상태와 이상상태의 두 범주로 구분할 수 있는 합성곱 신경망 모델을 학습시켰다. 또한, 지진조기경보에서 활용되는 가속도계 자료도 수집하여 품질평가 모델을 학습시켜 자동으로 지진자료의 품질을 평가할 수 있는 기술을 개발하였다.

2. 지진자료 품질관리 기술

2.1 파워스펙트럼밀도

본 연구에서는 1시간 길이의 시계열 자료를 서로 중첩된 13개의 단위(segment)로 나누어, 각각의 단위별로 파워스펙트럼밀도를 계산해 이를 평균하는 McNamara and Buland (2004)의 방법으로 파워스펙트럼밀도를 계산하였다. 그림 1은 다양한 특성을 가지는 시계열 자료와 이를 각각 파워스펙트럼밀도로 변환한 자료를 도시한 것이다. 정상상태의 시계열 자료(그림 1a)의 파워스펙트럼밀도는 그림 1f에서 확인할 수 있는 것처럼 모든 주파수 대역에서 검은색 실선으로 표현한 Peterson (1993)의 고 잡음모델(High Noise Model; HNM)과 저 잡음모델(Low Noise Model; LNM)인 표준잡음모델 사이에 안정적으로 분포한다. 반면 이상상태(그림 1b~c)나 지진 신호(그림 1d~e)의 파워스펙트럼밀도는 표준잡음모델에 벗어나 분포하는 것을 확인할 수 있다(그림 1f).

이상상태는 원인에 따라 파워스펙트럼밀도의 양상이 다양하게 나타난다. 지진계 센서의 연결 없이 기록계만 작동되는 상태에서 전기적 잡음만 기록된 자료를 시간 영역에서 도시한 경우(그림 1b)에는 정상상태의 잡음과 차이를 구분하기 어려운데, 파워스펙트럼밀도에서는 고주파 영역에서 맥동보다 약간 높게, 저주파 영역은 그보다 약간 낮게 나타나는 사선의 형태를 보여 표준잡음모델과 수월하게 구분할 수 있다. 광대역 지진계 센서 내의 추가 고정되어 있어 지반의 움직임 측정할 수 없는 상태(그림 1c)는 전기적 잡음만 기록되므로 파워스펙트럼밀도가 모든 주파수 대역에서 대체로 낮은 값을 보인다.

지진 신호의 경우 실체파는 고주파수 대역에서

우세하게 나타나고, 표면파는 0.1 Hz 이하의 저주파수 대역에서 우세한 특징을 가진다. 그림 1d는 2017년 11월 15일 규모 5.4 포항 지진을 무등산(KWJ2) 관측소에서 기록한 것으로 고주파수 대역에서 신호의 진폭이 크게 나타난 것을 볼 수 있다. 그림 1e는 2016년 11월 13일 뉴질랜드에서 발생한 규모 7.4 원거리 지진을 옥천(OKCB) 관측소에서 기록한 자료로 0.1 Hz 이하의 주파수 대역에서 우세한 특징을 보이는 것을 확인할 수 있다.

2.2 자료 수집

Seo (2019)는 2016년에서 2017년까지 광대역 속도계에 기록된 자료 중에서 1시간 길이의 지진파형을 파워스펙트럼밀도로 변환하여 3,000개의 이상 신호, 2,922개의 정상 신호, 2,376개의 지진 신호를 수집하였다.

본 연구에서는 지진자료의 품질을 정상상태와 이상상태의 두 가지 범주로 구분하므로, Seo (2019)에서 지진 신호로 수집된 자료를 정상상태의 범주에 포함시켰다. 합성곱 신경망 모델의 학습 과정에서 발생할 수 있는 과적합을 방지하기 위해 학습에 사용할 정상상태와 이상상태 자료의 수를 비슷하게 사용할 필요가 있다(Ross *et al.*, 2018). 따라서 2019년에 관측된 광대역 속도계 자료 중 이상상태 1,939개, 정상상태 72개의 자료를 추가하여 총 70개소의 정상상태 5,370개, 이상상태 4,939개를 학습에 사용하였다. 가속도계도 총 26개소로부터 정상상태 2,097개, 이상상태 2,355개의 자료를 수집하여 서로 비슷한 개수의 자료를 학습에 활용하였다.

지진계 종류와 상태별로 수집된 자료를 확률 밀도 함수로 표현하여 그림 2에 도시하였다. 광대역 속도계의 정상상태는 모든 주파수 대역에서 Peterson




Fig. 1. Waveforms and corresponding power spectral densities. Waveforms of (a) normal condition, (b) abnormal condition (no signal), (c) abnormal condition (locked), (d) local earthquake, and (e) teleseism. Power spectral densities (f) with colors corresponding to conditions of waveforms. Black lines in power spectral densities represent high and low noise models of Peterson (1993).

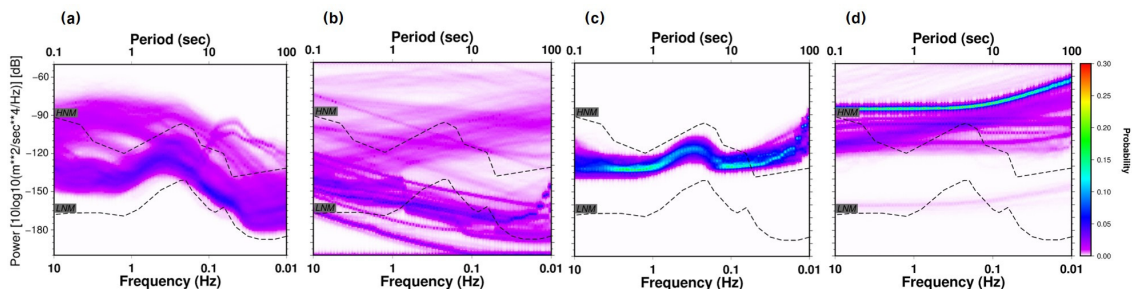


Fig. 2. Probability density function plot of power spectral densities. (a) normal condition of broadband seismometer, (b) abnormal condition of broadband seismometer, (c) normal condition of accelerometer, (d) abnormal condition of accelerometer.

(1993)의 표준잡음모델 사이에 분포하고, 1 Hz 부근과 0.1 Hz 이하에서 일부 자료들은 표준잡음모델 보다 높은 값을 보이는데 이는 각각 Seo (2019)에서 지진 신호로 분류한 국지 지진과 원거리 지진 신호이다(그림 2a). 이상상태는 표준잡음모델과 무관한 불규칙한 양상으로 정상상태와 뚜렷하게 구분할 수 있다(그림 2b). 가속도계를 살펴보면, 정상상태는 0.1 Hz 이상의 주파수 대역에서는 광대역 속도계의 정상상태와 같이 표준잡음모델 사이에 파워스펙트럼 밀도가 분포하나 0.1 Hz 이하의 대역에서 이보다 약간 높은 값이 나타나는데, 이는 가속도 센서의 특성상 0.1 Hz 이하의 저주파수 신호를 기록하기 어려워서 나타나는 현상이다(그림 2c). 가속도계의 이상상태도 광대역 속도계의 이상상태와 마찬가지로 대체

로 표준잡음모델의 형태와 무관하게 높은 값을 보여 정상상태와 다른 양상을 보이는 것을 확인할 수 있다(그림 2d).

2.3 합성곱 신경망 기반 품질평가 모델과 학습

지진자료의 파워스펙트럼밀도를 기반으로 자료의 품질을 평가하기 위해 그림 3과 같이 합성곱 신경망 모델을 구성하였다. 선별한 파워스펙트럼밀도를 1차원의 입력자료로 사용하였다. 입력층 이후 합성곱 층과 풀링 층에서 자료의 특징을 추출하는데, 합성곱 필터가 순회하며 합성곱 연산을 하여 파워스펙트럼밀도의 특징을 찾으려 하였다. 1차원의 합성곱 신경망 층을 두 번 중첩한 층을 4층으로 모델을 구성하였고, 모든 층에 배치 정규화(batch normalization)

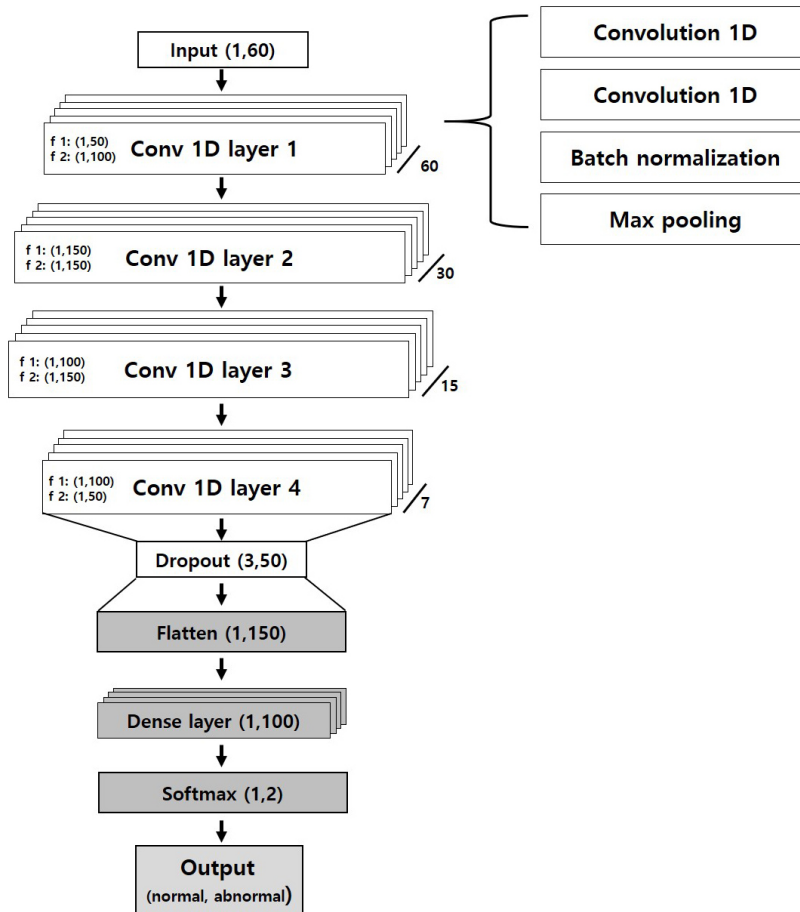


Fig. 3. Schematic diagram of the convolutional neural network model. The input shapes of the first and second layers are given as f1 and f2, respectively. The numbers at the bottom right of each layer indicate the numbers of filters in that layer.

층과 맥스 풀링(max pooling) 층을 추가해주었다. 배치 정규화는 입력 자료의 분포를 균일하게 하여 더 안정적으로 학습을 수행하고자 적용하였다(Ioffe and Szegedy, 2015). 자료의 특징을 추출하는 층들을 거친 뒤, 마지막으로 플래튼(flatten) 층과 완전 연결(dense) 층을 지나 출력층의 활성화 함수인 소프트맥스(softmax) 층에서 입력자료를 각각 이상상태와 정상상태일 확률을 계산해 평가를 수행하였다. 이때 새로운 자료에 대해 평가가 어려워지는 과적합에 빠질 가능성이 있어 출력층과 가까운 4층에 드롭아웃(dropout) 층을 추가해 주었다(Srivastava *et al.*, 2014).

수집 자료 중 70%는 합성곱 신경망 모델의 학습에 사용하였고, 나머지 30%는 모델의 성능을 객관적으로 평가하기 위한 검증 자료로 이용하였다. 같은 입력자료와 모델 구성이라도 무작위로 자료를 추출하여 모델을 학습시키기 때문에, 매 학습 도출된 모델의 성능에 차이가 있을 수 있다. 이에 따라 총 100번의 학습을 수행하였으며, 각 학습의 시행횟수(epoch)는 100회로 설정하여 모델이 최적에 수렴하도록 하였다. 이와 같은 과정을 거쳐 얻어진 100개의 학습모델 중에서 모델이 예측한 자료의 품질 상태와 실제 자료의 품질 상태와의 불일치를 나타내는 손실이 작은 가장 최적의 모델을 최종 모델로 선정하였다.

선정된 품질평가 모델의 정확도는 모델이 전체 자료 중에서 예측을 올바르게 한 비율을 나타내는 것으로 광대역 속도계의 경우 정확도 99.91% 정도의 높은 값을 보였고, 가속도계는 100%로 오분류 없

이 잘 평가한 것을 확인할 수 있었다. 가속도계의 품질평가에서 오류가 없었던 것은 광대역 속도계보다 학습에 사용된 자료의 수도 적고 특징도 단순해 나타나는 현상으로 생각된다. 향후 실시간 활용을 위해서는 보다 다양한 형태의 광대역 속도계와 가속도계 파워스펙트럼밀도의 추가 학습이 필요할 수도 있다. 하지만 본 연구 결과로부터 판단해 볼 때, 매우 높은 수준의 정확도를 가지는 품질평가 모델의 활용을 기대한다.

3. 토 의

본 연구에서 제시한 품질평가 모델이 실시간 또는 준실시간으로 관측자료의 품질을 평가할 수 있는지 검토하였다. 이를 위해 관측소의 이상상태를 인지하고 정상상태로 복구한 시간과 복구 방법 등이 기록되어 있는 기상청의 관측소 점검목록을 참고하였다. 관측소 이상상태 전·후와 정상상태 복구 전·후에 기록된 지진자료를 파워스펙트럼밀도로 변환하여 품질평가 모델을 사용해 관측 자료의 상태를 평가하였다(그림 4~7). 이 자료들은 학습에 사용되지 않은 자료로 본 연구에서 개발된 기술의 적용 가능성을 보여줄 수 있다고 판단된다.

그림 4는 1시간 길이의 화천(HWCB) 관측소 광대역 속도계 동서(E-W) 성분의 시계열 자료와 파워스펙트럼밀도를 도시한 것이다. 기상청의 관측소 점검목록에 의하면 2019년 1월 2일 2시 45분(이하 UTC 기준)에 이 지진계의 장애 복구가 요청되었다. 그림

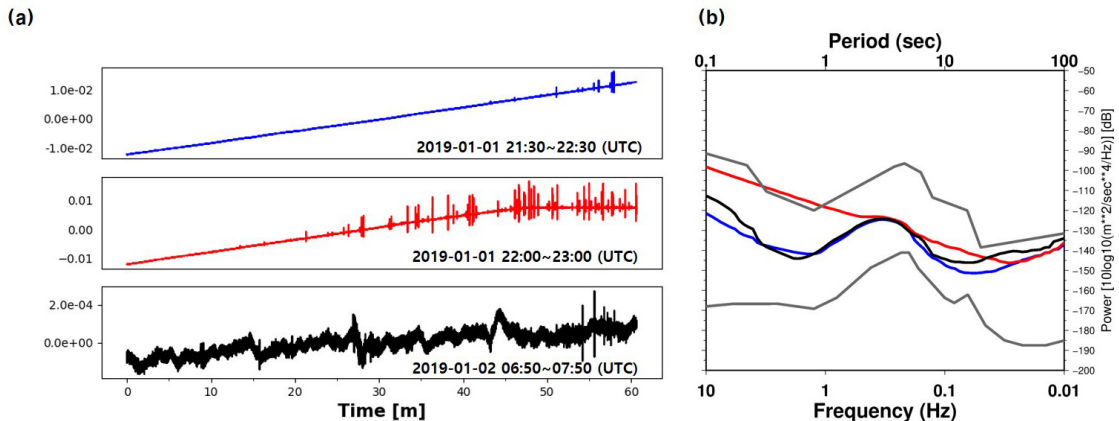


Fig. 4. (a) One-hour waveforms and (b) corresponding power spectral densities of broadband seismometer of station HWCB. Colors in power spectral densities are corresponding to waveforms.

4a의 시계열 자료에서는 1월 1일 21시 30분부터 1시간 길이의 자료와 22시부터의 자료에서 차이를 구분하기 어렵지만 그림 4b의 파워스펙트럼밀도에서 두 자료의 품질 상태가 구분되는 것을 볼 수 있다. 따라서 지진자료를 검토했을 때, 기상청에서 장애 복구를 요청한 시간보다 약 4시간 전인 2019년 1월 1일 22~23시경부터 자료에 문제가 발생했던 것으로 보인다. 이 지진계는 속도계 센서 내부에 있는 추의 위치 조정(mass centering)으로 장애가 복구되었으며, 1월 2일 6시 50분경부터 기록된 자료의 파워스펙트럼밀도를 통해 장애가 복구된 것을 쉽게 확인할 수 있다. 이처럼 장애 발생 전과 장애 복구 후에는 파워스펙트럼밀도가 Peterson (1993)의 고 잡음모델과 저 잡음모델 사이에 정상적으로 분포하지만, 장애가 발생했을 때는 정상상태와 쉽게 구분할 수 있는 것을 알 수 있다. 본 연구에서 개발한 품질평가 모델이 이와 같은 파워스펙트럼밀도를 평가했을 때에도 22시부터의 자료를 이상상태로 잘 구분하였다.

기상청의 관측소 점검목록을 기반으로 지진자료를 검토했을 때, 많은 경우에 장애 인지와 복구가 적절히 수행된 것을 확인할 수 있었다. 하지만 일부의 경우에는 장애 인지에 많은 시간이 소요되기도 하였다(그림 5~7). 그림 5는 이러한 사례의 예시로, (a)와 (b)는 홍도(HGDB) 관측소 광대역 속도계 자료 수직(U-D) 성분, (c)와 (d)는 비금도(BGDB) 관측소 가속

도계 자료 동서(E-W) 성분의 1시간 길이의 시계열 자료이다. 이 그림에서 (a)와 (c)는 장애가 발생하는 과정을, (b)와 (d)는 장애 복구 전·후를 기록한 자료이다.

그림 6a, 6b는 홍도 관측소의 장애 발생 전·후, 그림 6c, 6d는 장애 복구 전·후의 시계열 자료와 파워스펙트럼밀도이다. 각각 그림 5a, 5b에 제시된 1시간 길이 시계열 자료를 McNamara and Buland (2004)의 자료처리 방법에 따라 15분 길이의 13개의 단위로 세분화하여 도시하였고, 1시간 길이의 시계열 자료와 세분화된 시계열 자료의 파워스펙트럼밀도를 함께 도시하였다. 이 그림에서 검은색 점선으로 표현된 것이 1시간 길이 자료의 파워스펙트럼밀도이며, 품질평가 모델이 정상상태로 평가한 자료들은 파란색 실선으로, 이상상태로 평가한 자료들은 빨간색 실선으로 표현하였다. 품질평가에는 Intel Xeon CPU E5-2640을 가진 컴퓨터를 사용하였으며, 하나의 자료를 평가하는데 약 0.6초가 소요되었다.

이 관측소의 장애 복구 요청은 2019년 8월 14일 12시 50분에 있었지만, 그림 6a에서 확인할 수 있는 것처럼 이보다 약 20일 전인 2019년 7월 27일 4시 45분경부터 장애가 발생했던 것으로 보인다. 이 자료의 파워스펙트럼밀도(그림 6b)를 살펴보면 그림 1c와 같은 형태로 이상상태임을 쉽게 확인할 수 있다. 이때 품질평가 모델은 4시 45분 이후 15분 시계열 자료의 파워스펙트럼밀도 자료들을 이상상태로 평

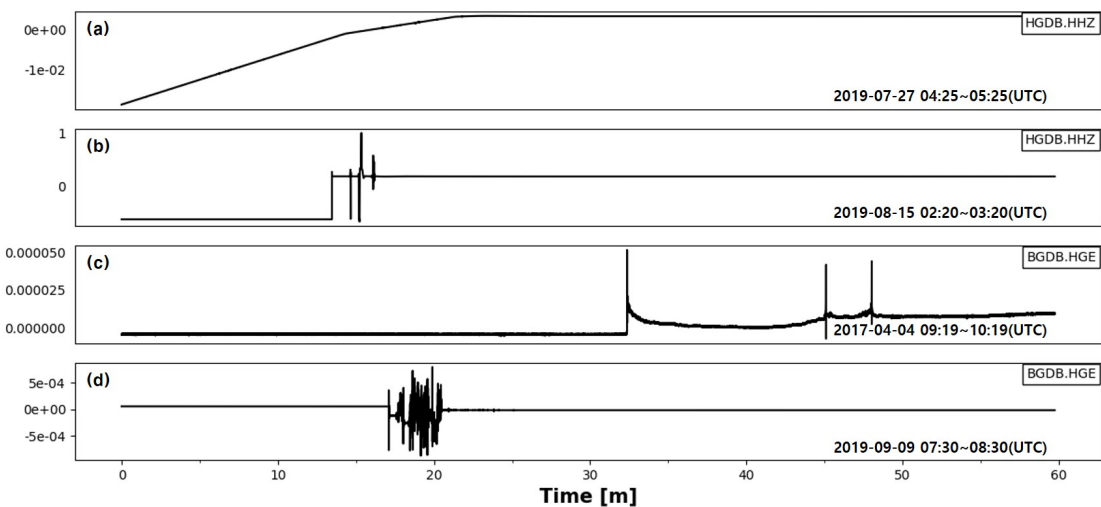


Fig. 5. One-hour waveforms of broadband seismometer of station HGDB and accelerometer of station BGDB. (a) and (c) show the change of the condition from normal to abnormal at stations HGDB and BGDB, respectively. (b) and (d) show the recovery of stations HGDB and BGDB, respectively.

가하였다. 관측소 점검목록에 의하면 2019년 8월 15일 추를 위치 조정하여 장애 복구를 완료하였다. 8월 15일 2시 40분경부터 정상적으로 작동하게 된 것을 확인할 수 있고(그림 6c), 2시 40분 이후 15분 자료의 파워스펙트럼밀도들도 표준잡음모델 사이에 정상적으로 분포하는 것을 확인할 수 있다(그림 6d). 품질평가 모델은 2시 40분 이후 파워스펙트럼밀도들에 대해 정상상태인 것으로 평가하였다.

그림 7은 비금도 가속도계의 장애처리 사례를 도시한 것이다. 장애 복구 요청은 2019년 9월 7일 1시 43분에 있었지만, 연속파형 자료를 검토했을 때 이보다 약 2년 5개월 전인 2017년 4월 4일 9시 50분경부터 자료에 문제가 있었음을 확인할 수 있었다(그림 5c). 9시 50분 이전까지의 정상상태 신호들이 갑작스러운 진폭 변화 이후 약 2년 5개월간 이상상태

를 유지하였다. 이와 같은 지진자료의 변화는 파워스펙트럼밀도에서도 잘 관찰할 수 있다(그림 7b). 9시 50분 이후의 자료를 40% 이상 포함한 9시 43분 이후 파워스펙트럼밀도들을 살펴보면 표준잡음모델과 무관한 대각선의 양상을 보여 이상상태임을 확인할 수 있었다. 품질평가 모델도 9시 43분 이후 파워스펙트럼밀도들을 이상상태로 평가하였다. 관측소 점검목록에 따르면 이 지진계는 2019년 9월 9일 가속도 센서를 교체해 장애 복구를 완료하였다. 9월 9일 8시 2분경부터 정상적으로 복구된 것을 확인할 수 있고(그림 7c), 장애 복구 후의 파워스펙트럼밀도들이 표준잡음모델 사이에 분포하는 것을 확인할 수 있다(그림 7d). 품질평가 모델도 8시 2분 이후 파워스펙트럼밀도들을 정상상태로 잘 평가하였다.

그림 8은 품질평가 모델이 잘못 예측한 사례를 나

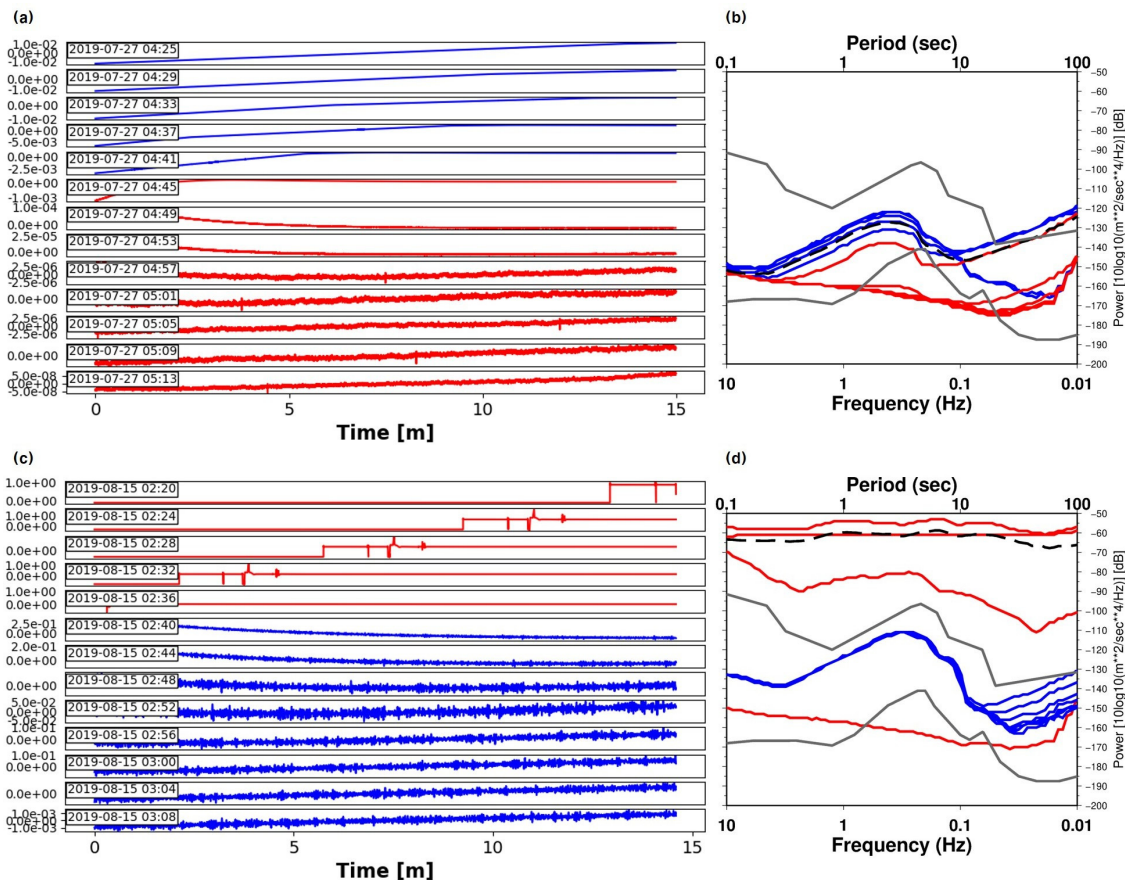


Fig. 6. 15-minute waveforms and corresponding power spectral densities of broadband seismometer of station HGDB. Waveforms of (a) and (c) are 13 segments of one-hour waveforms of Fig. 5a and 5b, respectively. Colors in power spectral densities are corresponding to waveforms.

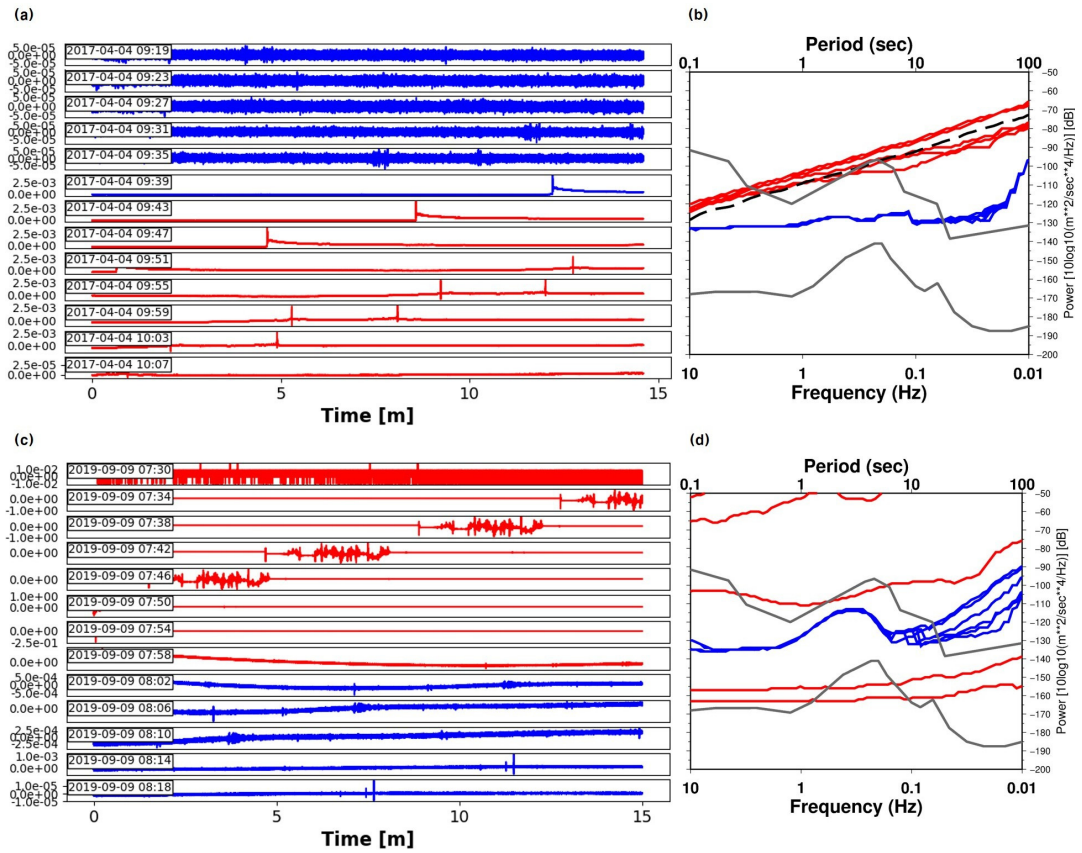


Fig. 7. 15-minute waveforms and corresponding power spectral densities of accelerometer of station BGDB. Waveforms of (a) and (c) are 13 segments of one-hour waveforms of Fig. 5c and 5d, respectively. Colors in power spectral densities are corresponding to waveforms.

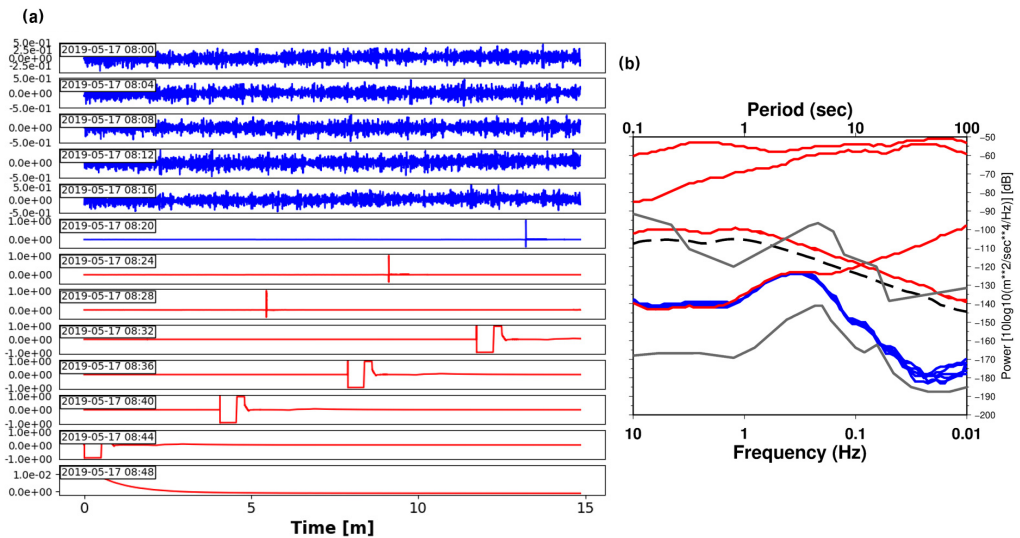


Fig. 8. (a) 15-minute waveforms and (b) corresponding power spectral densities of broadband seismometer of station BOSB. Colors in power spectral densities are corresponding to waveforms.

타낸 것으로, 보성(BOSB) 관측소 광대역 속도계의 남북(N-S) 성분 자료이다. 점선으로 표현한 1시간 길이의 파워스펙트럼밀도를 품질평가 모델은 정상상태로 잘못 평가하였다. 그런데 15분 길이의 자료를 이용한 파워스펙트럼밀도와 품질평가는 이 지진계가 정상상태에서 이상상태로 변했음을 보여준다. 일시적인 큰 진폭의 이상 신호 발생 이후의 자료가 약 45% 이상 포함된 시점보다 앞선, 초반부 자료들은 파워스펙트럼밀도가 표준잡음모델 사이에 분포하고 있으며 정상상태로 평가되었다. 반면에, 이상 신호가 45% 이상 포함된 시점부터의 후반부 자료들은 파워스펙트럼밀도가 표준잡음모델과 무관한 형태로 나타나며, 이상상태로 평가되었다. 이처럼 1시간 길이 자료의 일부 구간에 포함된 부분적인 특징으로 인해 적절한 품질 평가가 어려울 수도 있지만, 만약 시간 창의 길이를 줄여 자료의 품질을 평가한다면 보다 좋은 결과를 얻을 수 있음을 알 수 있다.

본 연구에서는 McNamara and Buland (2004)의 방법에 따른 1시간 길이의 파워스펙트럼밀도로 품질평가 모델을 학습시켰지만, 1시간 길이를 세분화한 15분 길이의 자료를 이용한 파워스펙트럼밀도에도 잘 적용할 수 있음을 확인할 수 있었다. 후속 연구를 통해 보다 짧은 자료의 품질평가 가능성을 시험하여 실시간 적용 시험을 진행해볼 예정이며, 이를 통해 광대역 속도계와 가속도계의 실시간 또는 준실시간 지진자료 품질평가에도 활용할 수 있을 것으로 예상된다.

4. 결 론

다양한 원인에 의해 기록되는 이상상태 자료들은 지진파를 감지 못해 지진조기경보를 지연시키거나 잘못된 정보를 제공해 오경보를 발생시킬 수 있으므로 지진 관측소에서 전송되는 자료들의 품질관리는 중요하다. 이를 위해 지진자료의 품질을 효과적으로 관리할 수 있도록 합성곱 신경망을 활용한 품질평가 모델을 개발하였다.

McNamara and Buland (2004)의 방법으로 1시간 시계열 자료를 파워스펙트럼밀도로 변환하여 총 70개소 광대역 속도계의 정상상태 5,370개, 이상상태 4,939개, 총 26개소 가속도계의 정상상태 2,097개, 이상상태 2,355개의 파워스펙트럼밀도를 수집하

였다. 광대역 속도계와 가속도계로 구분하여 각각 자료의 품질을 평가할 수 있는 합성곱 신경망 모델을 학습시켰다. 본 연구에서 개발된 모델의 정확도는 99.9% 이상으로 측정되어, 합성곱 신경망에 기반한 품질평가 모델이 광대역 속도계와 가속도계의 작동상태를 잘 판단할 수 있음을 알 수 있었다.

본 연구의 품질평가 모델이 실시간 또는 준실시간으로 관측자료의 품질을 파악할 수 있는지 검토하고자, 관측소 점검 목록을 참고하여 장애 발생 전·후와 장애 복구 전·후의 파워스펙트럼밀도 자료로 평가를 수행하였다. 품질평가 모델의 학습에는 1시간 길이의 파워스펙트럼밀도를 사용하였지만 15분 길이의 자료를 이용한 파워스펙트럼밀도라도 관측자료의 품질을 잘 평가함을 확인할 수 있었다. 따라서 향후 지진조기경보에서 실시간 또는 준실시간 지진자료 품질관리를 위한 모듈로 활용할 수 있을 것으로 기대한다. 하지만 지진관측소 주변의 다양한 배경잡음 영향을 고려할 때, 실시간 활용을 위해서는 보다 다양한 자료의 추가와 학습을 통해 품질평가 모델을 지속적으로 검증하고 개선할 필요가 있다.

감사의 글

이 연구는 기상지진 See-At 기술개발연구(KMIPA 2017-4030)의 지원으로 수행되었습니다. 관측소 점검 목록을 제공해 준 기상청과 파워스펙트럼밀도 자료를 제공해 자료 선별에 도움을 준 한국지질자원연구원에 감사드립니다. 또한 심사과정을 통해 좋은 의견을 주신 익명의 심사위원들과 편집위원께 감사드립니다.

REFERENCES

Aster, R.C., McNamara, D.E. and Bromirski, P.D., 2008, Multidecadal climate-induced variability in microseisms. *Seismological Research Letters*, 79, 194-202.

Cherry, S., 1974, Earthquake ground motions: Measurement and characteristics. In the *engineering seismology and earthquake engineering* edited by Soines, Noordhoffleiden, 315.

Cho, B.-J., Sheen, D.-H., Jo, B.-G., Park, S.-C. and Hwang, E.-H., 2009, Development of a standard background noise model for broadband seismic stations of KMA. *Journal of the Geological Society of Korea*, 45, 127-141

- (in Korean with English abstract).
- Guenaga, D.L., Marcillo, O.E., Velasco, A.A., Chai, C. and Maceira, M., 2021, The silencing of U.S. campuses following the COVID-19 response: evaluating root mean square seismic amplitudes using power spectral density data. *Seismological Research Letters*, 92, 941-950.
- Hasselmann, K., 1963, A statistical analysis of the generation of microseisms. *Reviews of Geophysics*, 1, 177-210.
- Ioffe, S. and Szegedy, C., 2015, Batch normalization: Accelerating deep network training by reducing internal covariate shift. *Proceedings of Machine Learning Research*, 37, 448-456.
- Kanai, K. and Tanaka, T., 1961, On microtremors VIII. *Bulletin of Earthquake Research Institute, University of Tokyo*, 39, 97-114.
- Kim, S.K., Nam, S.-T. and Ryoo, Y.G., 2004, Characteristics of the background noise of seismograph stations in Korea. *Journal of the Geological Society of Korea*, 40, 515-536 (in Korean with English abstract).
- Koper, K.D. and Burlacu, R., 2015, The fine structure of double-frequency microseisms recorded by seismometers in North America. *Journal of Geophysical Research: Solid Earth*, 120, 1677-1691.
- McNamara, D.E. and Buland, R.P., 2004, Ambient noise levels in the continental United States. *Bulletin of the Seismological Society of America*, 94, 1517-1527.
- McNamara, D.E., Hutt, C.R., Gee, L.S., Benz, H.M. and Buland, R.P., 2009, A method to establish seismic noise baselines for automated station assessment. *Seismological Research Letters*, 80, 628-637.
- Peterson, J., 1993, Observations and modeling of seismic background noise. *U.S. Geological Survey Open-File Report*, 93-322.
- Poli, P., Boaga, J., Molinari, I., Cascone, V. and Boschi, L., 2020, The 2020 coronavirus lockdown and seismic monitoring of anthropic activities in Northern Italy. *Scientific Reports*, 10, 9404-9411.
- Ross, Z.E., Meier, M.A. and Hauksson, E., 2018, *P* wave arrival picking and first-motion polarity determination with deep learning. *Journal of Geophysical Research: Solid Earth*, 123, 5120-5129.
- Seo, G.J., 2019, Study on automatic quality control scheme for realtime seismic monitoring. M.S. thesis, Chonnam National University, Gwangju, 71 p (in Korean with English abstract).
- Sheen, D.-H. and Shin, J.S., 2010, Earthquake detection thresholds of broadband seismic networks in South Korea considering background seismic noise levels. *Journal of the Geological Society of Korea*, 46, 31-38 (in Korean with English abstract).
- Sheen, D.-H., Shin, J.S. and Kang, T.-S., 2009, Seismic noise level variation in South Korea. *Geosciences Journal*, 13, 183-190.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., 2014, Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929-1958.

Received : April 1, 2021

Revised : April 26, 2021

Accepted : April 27, 2021