



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0005413
(43) 공개일자 2022년01월13일

(51) 국제특허분류(Int. Cl.)
G01V 1/28 (2006.01) G01V 1/22 (2006.01)
G06N 3/08 (2006.01)
(52) CPC특허분류
G01V 1/28 (2013.01)
G01V 1/22 (2021.01)
(21) 출원번호 10-2021-0088686
(22) 출원일자 2021년07월06일
심사청구일자 2021년07월06일
(30) 우선권주장
1020200082512 2020년07월06일 대한민국(KR)

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
고한석
서울특별시 용산구 이촌로88길 30, 101동 1402호 (이촌동, 삼성리버스위트아파트)
구본화
서울특별시 성북구 북악산로 831, 201동 706호(정릉동, 정릉 힐스테이트1차)
(74) 대리인
송인호, 윤형근, 최관락


전체 청구항 수 : 총 7 항

(54) 발명의 명칭 멀티태스크 딥러닝을 이용한 지진 이벤트 분류 방법 및 장치

(57) 요약

본 발명은 멀티태스크 딥러닝을 이용한 지진 이벤트 분류 방법 및 장치를 개시한다. 본 발명에 따르면, 지진 데이터를 중심화 전처리하는 전처리부; 상기 전처리된 지진 데이터를 입력 받고, 복수의 컨볼루션 레이어에서의 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑을 통해 복수의 채널을 갖는 특징맵을 추출하는 특징 추출부; 상기 추출된 특징맵을 통해 지진 여부를 분류하는 2 클래스 분류기; 및 상기 추출된 특징맵을 통해 지진의 종류를 분류하는 3 클래스 분류기를 포함하되, 상기 복수의 컨볼루션 레이어 각각은 상기 비선형 매핑을 통해 추출된 특징맵의 각 채널에 대한 중요도를 측정하는 주의 모듈(attention module)을 포함하고, 상기 측정된 중요도와 상기 추출된 특징맵을 요소별 곱하여 개선된 특징맵을 추출하는 지진 이벤트 분류 장치가 제공된다.

대표도 - 도1



(52) CPC특허분류

G01V 1/282 (2013.01)

G01V 1/284 (2013.01)

G06N 3/08 (2013.01)

G01V 2210/30 (2013.01)

G01V 2210/63 (2013.01)

G01V 2210/67 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1365003139
과제번호	KMI2018-09610
부처명	기상청
과제관리(전문)기관명	한국기상산업기술원
연구사업명	기상 · 지진See-At 기술개발연구(R&D)
연구과제명	인공지능 기술 활용 지진감지업무 적용 기술 연구
기 여 율	1/1
과제수행기관명	고려대학교 산학협력단
연구기간	2020.01.01 ~ 2020.12.31

명세서

청구범위

청구항 1

지진 이벤트 분류 장치로서,

지진 데이터를 중심화 전처리하는 전처리부;

상기 전처리된 지진 데이터를 입력 받고, 복수의 컨볼루션 레이어에서의 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑을 통해 복수의 채널을 갖는 특징맵을 추출하는 특징 추출부;

상기 추출된 특징맵을 통해 지진 여부를 분류하는 2 클래스 분류기; 및

상기 추출된 특징맵을 통해 지진의 종류를 분류하는 3 클래스 분류기를 포함하되,

상기 복수의 컨볼루션 레이어 각각은 상기 비선형 매핑을 통해 추출된 특징맵의 각 채널에 대한 중요도를 측정하는 주의 모듈(attention module)을 포함하고, 상기 측정된 중요도와 상기 추출된 특징맵을 요소별 곱하여 개선된 특징맵을 추출하는 지진 이벤트 분류 장치.

청구항 2

제1항에 있어서,

상기 복수의 컨볼루션 레이어 중 상기 전처리된 지진 데이터가 입력되는 제1 컨볼루션 레이어는 상기 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑 사이에 배치 정규화를 수행하는 지진 이벤트 분류 장치.

청구항 3

제1항에 있어서,

상기 2 클래스 분류기 및 3 클래스 분류기는 두 개의 풀리 커넥티드(Fully Connected) 레이어 및 소프트맥스 함수로 구성되는 지진 이벤트 분류 장치.

청구항 4

제3항에 있어서,

상기 3 클래스 분류기는 상기 복수의 컨볼루션 레이어의 적어도 일부가 출력하는 특징맵의 벡터화를 통해 특징 벡터로 변환하고, 상기 변환된 특징 벡터를 상기 두 개의 풀리 커넥티드 레이어의 입력으로 주입하여 지진의 종류를 분류하는 지진 이벤트 분류 장치.

청구항 5

제1항에 있어서,

상기 주의 모듈은 SENET(Squeeze and Excitation Network)에 기반으로 상기 중요도를 측정하는 지진 이벤트 분류 장치.

청구항 6

제5항에 있어서,

상기 주의 모듈은 명암대비 스트레칭(contrast stretching) 방법을 이용한 글로벌 가중 평균 풀링(Global Weight Average Pooling) 방법을 통해 글로벌 정보를 유지하면서 상기 특징맵을 압축하는 지진 이벤트 분류 장치.

청구항 7

프로세서 및 메모리를 포함하는 장치에서 지진 이벤트를 분류하는 방법으로서,

지진 데이터를 중심화 전처리하는 단계;

상기 전처리된 지진 데이터를 입력 받고, 복수의 컨볼루션 레이어에서의 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑을 통해 복수의 채널을 갖는 특징맵을 추출하는 단계;

2 클래스 분류기를 통해 상기 추출된 특징맵을 통해 지진 여부를 분류하는 단계; 및

3 클래스 분류기를 통해 상기 추출된 특징맵을 통해 지진의 종류를 분류하는 단계를 포함하되,

상기 복수의 컨볼루션 레이어 각각은 상기 비선형 매핑을 통해 추출된 특징맵의 각 채널에 대한 중요도를 측정하는 주의 모듈(attention module)을 포함하고, 상기 측정된 중요도와 상기 추출된 특징맵을 요소별 곱하여 개선된 특징맵을 추출하는 지진 이벤트 분류 방법.

발명의 설명

기술 분야

[0001] 본 발명은 멀티태스크 딥러닝을 이용한 지진 이벤트 분류 방법 및 장치에 관한 것이다.

배경 기술

[0002] Convolutional Neural Network(CNN)은 신경망의 일종으로 컨볼루션(convolution) 연산을 통한 선형 조합과 비선형 변환의 연쇄적인 구조를 가지고 있다.

[0003] Multi-layer perceptron(MLP)의 경우 학습 데이터의 차원이(예, 영상 입력) 증가하게 되는 경우 학습해야 될 파라미터의 양은 기하급수적으로 증가하게 되며 파라미터들을 학습하기 위해서는 대용량의 데이터가 요구된다.

[0004] 이에 반해 CNN은 local connection과 weight sharing의 특성을 갖는 컨볼루션 연산을 통해 학습해야 할 파라미터의 개수를 상당히 줄일 수 있으며 목적에 부합되는 컨볼루션 필터를 학습을 통해 자동으로 생성할 수 있다.

[0005] 일반적으로 CNN은 컨볼루션 레이어, 풀링(Pooling) 레이어, 풀리 커넥티드(Fully-connected, FC) 레이어의 3단계로 구성된다.

[0006] 여기서, 컨볼루션 레이어는 컨볼루션 연산과 비선형 변환을 통해 의미있는 특징(특징맵)들을 추출하고, 풀링 레이어는 생성된 특징을 줄이기 위해 서브샘플링(subsampling) 과정을 수행하고, FC 레이어는 특징 셋을 1차원 데이터로 변환한 이후, 출력 레이어와 완전히 연결된 neural network를 이용하여 분류를 수행한다.

[0007] 한편, 기존의 지진 분류 알고리즘은 STA(Short Time Average)와 LTA(Long Time Average) 방식을 사용하였는데, 이는 비율 문턱치를 통해 지진을 탐지하는 대표적인 방식이나, 낮은 SNR 환경에서는 부적합하다.

[0008] 또한, Autocorrelation 기반 방식은 단일 지역에서 반복되는 지진 파형(waveform)들간의 correlation을 기반으로 지진을 탐지하는 방식으로 성능은 우수하지만 연산량 과부하 및 긴 시간의 신호에는 활용성에 한계를 갖고 있다.

[0009] 템플릿 매칭(Template matching) 방식은 autocorrelation 방법의 연산량 과부하 문제를 개선하기 위해 제안된 기법으로 지진 템플릿을 설정 후 템플릿과 입력 지진 파형과의 correlation을 통해 지진을 탐지하게 된다. 템플릿의 숫자는 성능에 주요한 영향을 미치며 PCA(Principle Component Analysis) 혹은 subspace learning을 통해 템플릿의 숫자를 줄이는 접근 방식들이 제안되고 있다.

[0010] 최근에는 템플릿 매칭의 연산량을 개선하기 위한 FAST(Fingerprint And Similarity Thresholding) 방법이 제안되었다. 이 방식은 비지도(unsupervised) 지진 탐지 방식으로 spectral image와 haar wavelet 변환을 통해 지문과 유사한 지진 특징을 추출하며 local sensitive hashing을 통해 유사도 측정 연산량을 감소시킨다.

[0011] 최근 딥러닝을 적용한 지진 탐지 기법이 다양하게 보고되고 있다.

[0012] 지진 이벤트 분류 문제는 지진 여부를 분류하는 것뿐만 아니라 지진의 종류를 분류하는 문제가 발생하게 된다. 일반적으로 규모가 큰 지진에 비해 작은 규모의 미소 지진 감지는 낮은 SNR 환경으로 인해 잡음과의 분류 성능이 만족스럽지 못하며 인공 발파 및 핵실험 등의 인공 지진은 자연 미소 지진과의 분류 성능이 저하될 수 있다.

선행기술문헌

특허문헌

[0013] (특허문헌 0001) 대한민국공개특허공보 10-2020-0061307

발명의 내용

해결하려는 과제

[0014] 상기한 종래기술의 문제점을 해결하기 위해, 본 발명은 지진 데이터와 잡음의 분류 및 지진의 종류를 효과적으로 분류할 수 있는 멀티태스크 딥러닝을 이용한 지진 이벤트 분류 방법 및 장치를 제안하고자 한다.

과제의 해결 수단

[0015] 상기한 바와 같은 목적을 달성하기 위하여, 본 발명의 일 실시예에 따르면, 지진 이벤트 분류 장치로서, 지진 데이터를 중심화 전처리하는 전처리부; 상기 전처리된 지진 데이터를 입력 받고, 복수의 컨볼루션 레이어에서의 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑을 통해 복수의 채널을 갖는 특징맵을 추출하는 특징 추출부; 상기 추출된 특징맵을 통해 지진 여부를 분류하는 2 클래스 분류기; 및 상기 추출된 특징맵을 통해 지진의 종류를 분류하는 3 클래스 분류기를 포함하되, 상기 복수의 컨볼루션 레이어 각각은 상기 비선형 매핑을 통해 추출된 특징맵의 각 채널에 대한 중요도를 측정하는 주의 모듈(attention module)을 포함하고, 상기 측정된 중요도와 상기 추출된 특징맵을 요소별 곱하여 개선된 특징맵을 추출하는 지진 이벤트 분류 장치가 제공된다.

[0016] 상기 복수의 컨볼루션 레이어 중 상기 전처리된 지진 데이터가 입력되는 제1 컨볼루션 레이어는 상기 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑 사이에 배치 정규화를 수행할 수 있다.

[0017] 상기 2 클래스 분류기 및 3 클래스 분류기는 두 개의 풀리 커넥티드(Fully Connected) 레이어 및 소프트맥스 함수로 구성될 수 있다.

[0018] 상기 3 클래스 분류기는 상기 복수의 컨볼루션 레이어의 적어도 일부가 출력하는 특징맵의 벡터화를 통해 특징 벡터로 변환하고, 상기 변환된 특징 벡터를 상기 두 개의 풀리 커넥티드 레이어의 입력으로 주입하여 지진의 종류를 분류할 수 있다.

[0019] 상기 주의 모듈은 SENET(Squeeze and Excitation Network)에 기반으로 상기 중요도를 측정할 수 있다.

[0020] 상기 주의 모듈은 명암대비 스트레칭(contrast stretching) 방법을 이용한 글로벌 가중 평균 풀링(Global Weight Average Pooling) 방법을 통해 글로벌 정보를 유지하면서 상기 특징맵을 압축할 수 있다.

[0021] 본 발명의 다른 측면에 따르면, 프로세서 및 메모리를 포함하는 장치에서 지진 이벤트를 분류하는 방법으로서,

[0022] 지진 데이터를 중심화 전처리하는 단계; 상기 전처리된 지진 데이터를 입력 받고, 복수의 컨볼루션 레이어에서의 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑을 통해 복수의 채널을 갖는 특징맵을 추출하는 단계; 2 클래스 분류기를 통해 상기 추출된 특징맵을 통해 지진 여부를 분류하는 단계; 및 3 클래스 분류기를 통해 상기 추출된 특징맵을 통해 지진의 종류를 분류하는 단계를 포함하되, 상기 복수의 컨볼루션 레이어 각각은 상기 비선형 매핑을 통해 추출된 특징맵의 각 채널에 대한 중요도를 측정하는 주의 모듈(attention module)을 포함하고, 상기 측정된 중요도와 상기 추출된 특징맵을 요소별 곱하여 개선된 특징맵을 추출하는 지진 이벤트 분류 방법이 제공된다.

발명의 효과

[0023] 본 발명에 따르면, 멀티태스크 학습을 통해 지진 여부 및 지진의 종류에 적합한 주요한 핵심 특징을 추출할 수 있고, 주의 기반 특징 추출을 통해 각 클래스별 구별성이 향상된 특징 추출을 통해 낮은 SNR 환경에서도 지진 감지 성능을 향상시킬 수 있는 장점이 있다.

[0024] 또한, 본 발명에 따르면, 정확하고 신속한 지진 정보를 제공함으로써 평상시 지진에 대한 불안감을 줄이고 경보의 신뢰 향상을 기대할 수 있고, 지진 탐지 분석 정보를 바탕으로 주요 산업시설의 건설 계획 시 안전한 곳에 건설하도록 유도하거나 내진 설계 등의 대비를 통해 대규모 재난의 가능성을 낮출 수 있다.

[0025] 나아가, 누적된 미소 지진 탐지 정보를 분석하여 요주의 지역을 도출할 수 있으며, 인근 지역을 집중적으로 감시하여 지진피해에 대한 빠른 경보 및 대응이 가능하다.

도면의 간단한 설명

[0026] 도 1은 본 발명의 일 실시예에 따른 멀티태스크 기반 지진 이벤트 분류 네트워크 구조를 도시한 도면이다.

도 2는 본 실시예에 따른 주의 모듈이 적용된 컨볼루션 레이어를 도시한 도면이다.

도 3은 SENET 기반 주의 모듈의 구성을 도시한 도면이다.

도 4는 본 실시예에 따른 주의 모듈 기반 특징 병합 구조를 도시한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0027] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다.

[0028] 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0030] 본 실시예는 멀티태스크 딥러닝 기반으로 지진 여부 및 지진 종류를 분류하는 방법을 제시한다.

[0031] 도 1은 본 발명의 일 실시예에 따른 멀티태스크 기반 지진 이벤트 분류 네트워크 구조를 도시한 도면이다.

[0032] 도 1에 도시된 바와 같이, 본 실시예에 따른 장치는 전처리부(100), 특징 추출부(102), 2 클래스 분류기(104) 및 3 클래스 분류기(106)를 포함할 수 있다.

[0033] 본 실시예에 따른 장치는 프로세서 및 메모리를 포함하는 장치일 수 있다.

[0034] 여기서, 프로세서는 컴퓨터 프로그램을 실행할 수 있는 CPU(central processing unit)나 그밖에 가상 머신 등을 포함할 수 있다.

[0035] 메모리는 고정식 하드 드라이브나 착탈식 저장 장치와 같은 휘발성 저장 장치를 포함할 수 있다. 착탈식 저장 장치는 콤팩트 플래시 유닛, USB 메모리 스틱 등을 포함할 수 있다. 메모리는 각종 랜덤 액세스 메모리와 같은 휘발성 메모리도 포함할 수 있다.

[0036] 이와 같은 메모리에는 프로세서(100)에 의해 실행 가능한 프로그램 명령어들이 저장된다.

[0037] 지진 데이터의 경우 관측소별 특성으로 인해 지진 데이터의 범위가 서로 다를 수 있다.

[0038] 이러한 점을 고려하여 전처리부(100)는 다음의 수학식 1과 중심화(centering) 과정의 지진 데이터 전처리를 수행한다.

[0039] 센터링 과정을 통해 기하학적으로 데이터의 군집을 모든 차원에 대해서 원점으로 이동시키는 효과를 얻을 수 있다.

수학식 1

$$y_m = x_m - \frac{1}{M} \sum_{i=1}^M x_i, \quad m=1, \dots, M$$

[0041] 여기서 M은 하나의 데이터에서 취득하는 총 샘플수이다.

[0042] 본 실시예에 따른 입력은 3채널 지진 데이터를 이용하며 채널당 1000 샘플의 입력 데이터를 사용한다. 1000 샘플 입력 데이터는 100Hz 샘플링 10초 구간의 데이터를 나타낸다.

[0043] 특징 추출부(102)는 전처리된 지진 데이터를 입력 받고, 1D 컨볼루션 연산 및 ReLU 함수를 통한 비선형 매핑을 통해 필터별로 복수의 채널을 갖는 특징맵을 추출하는 복수의 컨볼루션 레이어(Conv1 내지 Conv8)를 포함한다.

- [0044] 도 1은 특징 추출부(102)가 8개의 컨볼루션(convolution) 레이어를 포함하는 것을 예시적으로 도시한다.
- [0045] 또한, 본 실시예에 따른 네트워크는 추출된 특징맵을 통해 지진 여부를 분류하는 2 클래스 분류기(104) 및 추출된 특징맵을 통해 지진 여부를 분류하는 3 클래스 분류기(106)를 포함할 수 있다.
- [0046] 도 1에 도시된 바와 같이, 각 분류기(104,106)는 2개의 풀리 커넥티드(Fully-Connected, FC) 레이어와 소프트맥스(softmax) 함수로 구성된다.
- [0047] 8개의 컨볼루션 레이어(Conv1 내지 Conv8)에서는 아래의 수학적 식 2와 같이 1D 컨볼루션 연산을 수행하며 컨볼루션 연산 결과는 수학적 식 3과 같은 ReLU(Rectified Linear Unit) 함수를 통해 비선형 매핑을 거친다.
- [0048] 제1 컨볼루션 레이어(Conv 1)에서는 도 2와 같이 컨볼루션 연산과 ReLU 사이에 배치 정규화(Batch normalization) 과정을 거친다. 1D 컨볼루션 연산의 필터 크기는 3x1 형태를 사용하며 채널 크기는 각 레이어마다 32개를 적용할 수 있다.

수학적 식 2

[0049]
$$F_{c,t}^l = R \left(\sum_{c'}^C \sum_{t'}^3 F_{c',t'+1}^{l-1} \cdot W_{c,c'}^l \right) \text{ for } l=1, \dots, 8$$

- [0050] 여기서, F^l 은 컨볼루션 레이어 l 의 특징맵을 나타내고, F^0 은 입력 파형을 나타내고, F^l 은 차원 $C_l \times C_{l-1} \times 3$ 을 갖는 레이어 l 의 필터 가중치를 나타내고, C_l 은 레이어 l 의 채널 수이다.

수학적 식 3

[0051]
$$R(z) = \max(0, z)$$

- [0052] 비선형 매핑된 특징맵의 각 채널에 대해 도 3과 같은 주의 모듈(Attention module)을 기반으로 중요도가 측정된다.
- [0053] 도 3에 도시된 바와 같이, 각 채널별 중요도는 특징맵과의 요소별 곱(Element-wise multiply)을 통해 개선된 특징맵을 산출하게 되며 맥스 풀링(max-pooling)을 통해 다운샘플링(down-sampling) 과정을 거치게 된다. 맥스 풀링의 간격은 2로 설정하여 이 과정을 거칠 때 마다 특징 정보는 1/2배로 축소된다. 본 실시예에서는 overfitting을 방지하기 위해 첫 번째 제1 풀리 커넥티드 레이어(FC 1)에 드롭아웃 정규화(drop-out regularization)를 적용한다.
- [0054] 특징 추출부(102)는 히든 레이어로서 공유 특징을 추출하고, 2 클래스 분류기(104)는 공유 특징을 통해 지진과 잠음을 분류하고, 3 클래스 분류기(106)는 미소, 강진 및 잠음을 분류한다.
- [0055] 본 실시예에 따른 2 클래스 분류 과정에서는 마지막 컨볼루션 레이어의 특징 정보만을 이용하여 분류 작업을 수행한다.
- [0056] 보다 상세하게, 2 클래스 분류기(104)는 마지막 컨볼루션 레이어(Conv 8)의 특징맵을 벡터화 과정을 통해 특징 벡터로 변환하고, 변환된 특징 벡터를 2개의 풀리 커넥티드 레이어의 입력으로 주입한 다음 소프트맥스 함수를 사용하여 2 클래스 분류를 수행한다.
- [0057] 3 클래스 분류기(106)는 초기 컨볼루션 레이어에서 고주파 성분의 특징이 주로 추출되고, 레이어가 깊어질수록 저주파 특징이 주로 추출되는 점을 이용하여 제6 내지 제8 컨볼루션 레이어(Conv 6 내지 Conv 8)과 같은 후단 컨볼루션 레이어들의 특징맵들을 병합하여 특징 벡터를 구성한다.
- [0058] 즉, 도 4에 도시된 바와 같이, 각 레이어의 특징맵을 단순히 연결하는 대신 주의 모듈을 사용하여 복수의 컨볼루션 레이어의 특징맵을 병합하는 방식을 이용한다.
- [0059] 본 실시예에 따른 주의 기반 특징 병합 방식은 작업의 중요한 부분에 더 중점을 둔 특징 벡터를 구성한다.

[0060] 본 실시예에 따른 멀티태스크 학습 구조의 손실 함수는 아래의 수학적 식 4와 같이 2 클래스 분류기(104)의 손실 L^2 와 3 클래스 분류기(106)의 손실 L^3 의 합으로 구성되며, 네트워크 가중치 W 의 L2 norm을 통한 정규화를 적용한다.

수학적 식 4

$$L = L^2 + L^3 + \lambda \sum W^2$$

[0062] 주의 모듈은 특징에서 주요한 구성요소를 추출하여 특징을 향상시키는 수단이다.

[0063] 본 실시예에서는, 도 4와 같이, SENET(Squeeze and Excitation Network)에 기반을 둔 개선된 주의 모듈을 적용한다.

[0064] SENET은 squeeze 연산과 excitation 연산으로 구성된다.

[0065] 일반적으로 Squeeze 연산은 각 채널에서 global average pooling(GAP)을 사용하여 전역(글로벌) 정보를 유지하면서 특징맵을 압축하게 된다. Excitation 연산은 두 개의 풀리 커넥티드 레이어와 시그모이드(sigmoid) 활성화 함수를 사용하여 각 채널의 중요도에 따라 적응적으로 주의 값을 재조정한다.

[0066] 제1 풀리 커넥티드 레이어(FC 1)는 감소율 r 을 갖는 차원 감소 레이어를 나타내며, 제2 풀리 커넥티드 레이어(FC 2)는 특징맵의 채널 차원으로 복원하는 차원 복원 레이어를 나타낸다.

[0067] 최종적인 주의 값은 시그모이드 활성화 함수를 통해 채널의 중요도(가중치)를 0 내지 1 사이의 값으로 조절한다.

[0068] 기존의 SENET에서는 GAP을 이용하여 squeeze 연산을 사용하는 반면, 본 실시예에서는 상기한 수학적 식 5와 같이 이미지 향상에 사용되는 명암대비 스트레칭(contrast stretching) 방법을 이용한 글로벌 가중 평균 풀링(Global Weight Average Pooling) 방법을 제안한다.

[0069] 명암대비 스트레칭은 낮은 대비 이미지 분포의 히스토그램을 확산시켜 넓은 범위의 대비 값을 달성함으로써 이미지의 가시성을 향상시키는 방법으로서, 이를 통해 뚜렷한 채널별 통계 정보를 포함하는 squeeze 연산을 수행할 수 있게 된다.

수학적 식 5

$$s_{GMAP}(c) = \frac{1}{L} \sum_{i=1}^L \beta_c(i) G_{\max_c}$$

[0071] 여기서, s 는 스퀴즈 연산 벡터, L 은 길이, $\beta_c(i) = \frac{F_c(i) - G_{\min_c}}{G_{\max_c} - G_{\min_c}}$, $G_{\max_c}$ 와 $G_{\min_c}$ 는 특징맵에서 채널 c 의 글로벌 최대값과 최소값이다.

[0073] 이하에서는 본 실시예의 성능 평가를 위한 실험 과정을 설명한다.

[0074] 실험을 위해 2016년 1월1일부터 2018년 7월 31일까지의 대한민국에서 발생하는 지진 데이터 정보들을 이용하여 지진 데이터 및 잡음 데이터를 수집하였다.

[0075] 기상청에서 제공되는 24시간 지진 관측 데이터 및 지진 이벤트 목록 파일을 토대로 지진 이벤트 및 잡음 데이터 베이스가 구축되었다.

[0076] 지진 데이터는 100샘플 데이터만을 이용하였으며 데이터베이스는 중간규모(규모 3.0 이상), 미소지진(규모 3.0

미만), 잡음으로 구분하였다. 그러나 국내 지진 데이터의 경우 중간규모 지진 데이터가 매우 작은 관계로 중간 규모의 지진 데이터는 IRIS에서 제공하는 2019년 3 ~ 2019년 9월 사이에 환태평양 지대에서 발생한 지진 데이터를 추가적으로 이용하였다.

[0077] 지진 이벤트의 추출은 각 관측소별 지진이 관측된 시점부터 10초 구간의 데이터를 추출하고 있다. 그러나 수집 데이터의 양을 늘리기 위해 본 실험에서는 지진 발생 시점 보다 3초 앞서서부터 총 13초 구간의 데이터를 수집하고 있으며 추출 window를 1초 간격으로 sliding 하는 방식을 적용하였다.

[0078] 잡음 이벤트의 수집은 두 가지 방식으로 적용하였다. 지진 이벤트 목록에 기록된 날짜의 경우 발생한 시간의 앞 뒤 1시간을 제외한 부분에서 임의 샘플링 방식으로 10초의 잡음 데이터를 추출하였으며 지진 이벤트 목록에 기록되지 않은 날짜의 경우는 24시간 데이터 내에서 임의로 잡음 데이터를 추출하였다. 모의 실험에서 사용하는 이벤트 데이터셋 구성은 표 1과 같다.

표 1

이벤트별	[1]	[2]	[3]
지진[1] vs 잡음[2]	25432/4720	40000/20000	
미소[1] vs 중규모 [2] vs 잡음 [3]	19604/2740	5288/1980	40000/20000

[0080] 본 모의 실험은 NVIDIA Geforce GTX 1080Ti GPU와 Tensorflow 기반으로 수행하였으며 네트워크 훈련은 총 300 epoch 수행하였다. 모델 훈련시 최적화는 ADAM 방법을 이용하였으며 학습율은 10^{-3} , L2 regularization 파라미터 λ 는 10^{-5} 을 주었다.

[0081] 성능 분석을 위해 ConvNetQuake 기반의 single task 구조와 비교 분석을 수행하였으며 성능 측정은 수학적 6과 같이 accuracy, true positive rate, false positive rate 지수를 사용하였다.

수학적 6

$$Accuracy = \frac{TP + TN}{\text{테스트 개수}}, \quad TPR = \frac{TP}{TP + FN}, \quad FPR = \frac{FP}{TN + FP}$$

[0082]

[0083] 성능 비교 결과는 표 2와 같다.

표 2

이벤트 클래스	Single-tasking 구조			Multi-tasking 구조		
	Accuracy	TPR	FPR	Accuracy	TPR	FPR
지진 vs 잡음	98.6	96.1	0.9	99.1	96.7	0.4
미소 vs 중규모 vs 잡음	98.2	91.9/ 94.3/ 99.4	0.5/ 0.6/ 4.8	98.7	95.4/ 93.9/ 99.7	0.4/ 0.4/ 3.3

[0085] 베이스라인 구조는 기존의 ConvNetQuake를 기반으로 한 single task 구조와 비교 분석하였다. 표 2에서 본 실시예에 따른 방법은 모든 이벤트 분류에 대한 베이스라인 방법보다 우수한 성능을 보여 주었다. 제안된 방법은 기존 베이스라인보다 향상된 성능을 보여주었으며 특히 3 class 분류 결과에서 TPR 측면의 성능이 크게 향상되는 모습을 보여주었다.

[0086] 또한 표 3과 같이 제안된 주의 기반 특징 병합에 따른 멀티태스크 학습 구조는 단순 특징 병합 방법보다 우수한 성능을 보여주었다.


표 3

이벤트 클래스	단순 MAX 기반 FA			Attention 기반 FA		
	Accuracy	TPR	FPR	Accuracy	TPR	FPR
지진 vs 잡음	98.9	96.6	0.6	99.1	96.7	0.4
미소 vs 중규모 vs 잡음	98.5	94.6/ 93.0/ 99.5	0.5/ 0.6/ 3.9	98.7	95.4/ 93.9/ 99.7	0.4/ 0.4/ 3.3


상기한 본 발명의 실시예는 예시의 목적을 위해 개시된 것이고, 본 발명에 대한 통상의 지식을 가지는 당업자라면 본 발명의 사상과 범위 안에서 다양한 수정, 변경, 부가가 가능할 것이며, 이러한 수정, 변경 및 부가는 하기의 특허청구범위에 속하는 것으로 보아야 할 것이다.

도면


도면1



도면2



도면3



도면4

