(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0045296
(43) 공개일자 2023년04월04일

(51) 국제특허분류(Int. Cl.)
G16H 20/70 (2018.01) *A61B 5/16* (2006.01)
A61B 5/28 (2021.01) *G06N 3/04* (2023.01)
G16H 30/40 (2018.01) *G16H 50/20* (2018.01)
G16H 50/50 (2018.01) *G16H 50/70* (2018.01)
(52) CPC특허분류
G16H 20/70 (2021.08)
A61B 5/165 (2013.01)
(21) 출원번호 10-2021-0127984
(22) 출원일자 2021년09월28일
심사청구일자 2021년09월28일

(71) 출원인
조선대학교산학협력단
광주광역시 동구 필문대로 309 (서석동)
(72) 발명자
김윤태
대전광역시 유성구 신성남로 91-12
정재효
광주광역시 북구 문산로 108동 906호
(뒷면에 계속)
(74) 대리인
특허법인씨엔에스

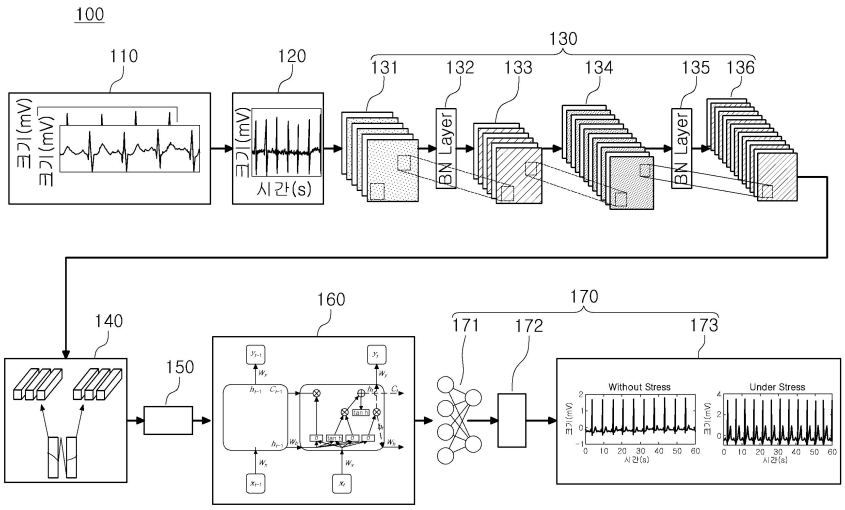
전체 청구항 수 : 총 8 항

(54) 발명의 명칭 **컨볼루션 신경망 및 장단기 메모리 네트워크 레이어를 이용한 정신적 스트레스 분류 장치, 방법 및 컴퓨터로 독출 가능한 기록매체**

(57) 요 약

본 발명의 일 실시 형태에 따른 컨볼루션 신경망 및 장단기 메모리 네트워크 레이어를 이용한 정신적 스트레스 분류 장치는, 심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환하는 시퀀스 폴딩 레이어와, 배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵을 생성하는 CNN 레이어와, 생성된 특징맵을 시퀀스 이미지로 변환하는 시퀀스 언폴딩 레이어와, 변환된 시퀀스 이미지를 1차원 데이터로 변환하는 플래튼 레이어와, 변환된 1차원 데이터에 가중치를 이용하여 특징값을 추출하는 장단기 메모리 네트워크 레이어와, 추출된 특징값에 따라 스트레스를 분류하는 분류 모듈을 포함할 수 있다.

대 표 도



(52) CPC특허분류
A61B 5/28 (2022.01)
G06N 3/042 (2023.01)
G06N 3/045 (2023.01)
G16H 30/40 (2018.01)
G16H 50/20 (2018.01)
G16H 50/50 (2018.01)
G16H 50/70 (2018.01)

(72) 발명자
강민구
광주광역시 동구 필문대로253번길 10-3 조대 명품 타운 102동 204호

신시호
광주광역시 북구 양일로 55, 103동 1202호

이 발명을 지원한 국가연구개발사업

과제고유번호	1711138632
과제번호	S1601201041
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신산업진흥원
연구사업명	인공지능중심산업융합집적단지조성(R&D)(1313921301332100214040 1)
연구과제명	AI 기반 다중센싱을 이용한 Brain-Body 인터페이스 기술 개발
기 여 율	1/2
과제수행기관명	조선대학교 산학협력단
연구기간	2021.01.01 ~ 2021.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1345264582
과제번호	2018R1A6A1A03015496
부처명	교육부(P13)
과제관리(전문)기관명	한국연구재단(ABX3869)
연구사업명	이공학학술연구기반구축(12111005005224002446300)
연구과제명	웨어러블 디바이스 기반 다중생체 신호를 이용한 사용자 인증 기술
기 여 율	1/2
과제수행기관명	조선대학교 산학협력단
연구기간	2021.03.01 ~ 2022.02.28

명 세 서

청구범위

청구항 1

심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환하는 시퀀스 폴딩 레이어;

배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵을 생성하는 CNN 레이어;

생성된 상기 특징맵을 시퀀스 이미지로 변환하는 시퀀스 언폴딩 레이어;

변환된 상기 시퀀스 이미지를 1차원 데이터로 변환하는 플래튼 레이어; 및

변환된 상기 1차원 데이터에 가중치를 이용하여 특징값을 추출하는 장단기 메모리 네트워크 레이어;

추출된 상기 특징값에 따라 스트레스를 분류하는 분류 모듈;

을 포함하는, 정신적 스트레스 분류 장치.

청구항 2

제1항에 있어서,

상기 심전도 신호는,

시간 영역의 심전도 신호와 상기 시간 영역의 심전도 신호에 대한 주파수 영역의 심전도 신호를 포함하는, 정신적 스트레스 분류 장치.

청구항 3

제2항에 있어서,

상기 주파수 영역의 심전도 신호는,

스펙트로그램을 이용하여 상기 시간 영역의 심전도 신호로부터 변환된 신호인, 정신적 스트레스 분류 장치.

청구항 4

제1항에 있어서,

상기 CNN 레이어는,

상기 배열 형태의 이미지에 합성곱 연산을 수행하여 제1 특징맵을 생성하는 제1 콘볼루션 레이어;

생성된 상기 제1 특징맵의 최대값을 추출함으로써 제1 특징맵의 차원을 축소시키는 제1 맥스 풀링 레이어;

차원이 축소된 제1 특징맵에 합성곱 연산을 수행하여 제2 특징맵을 생성하는 제2 콘볼루션 레이어; 및

생성된 상기 제2 특징맵의 최대값을 추출함으로써 제2 특징맵의 차원을 축소시키는 제2 맥스 풀링 레이어;

를 포함하는, 정신적 스트레스 분류 장치.

청구항 5

제4항에 있어서,

상기 정신적 스트레스 분류 장치는,

제1 콘볼루션 레이어와 상기 제1 맥스 풀링 레이어 사이에는 상기 제1 특징맵을 정규화는 제1 정규화 레이어; 및

제2 콘볼루션 레이어와 상기 제2 맥스 풀링 레이어 사이에는 상기 제2 특징맵을 정규화하는 제2 정규화 레이어;

를 더 포함하는, 정신적 스트레스 분류 장치.

청구항 6

제1항에 있어서,

상기 분류 모듈은,

추출된 상기 특징값에 따라 스트레스 상태와 스트레스가 아닌 상태를 출력하는 풀 커넥티드 레이어;

출력된 스트레스 상태와 스트레스가 아닌 상태 각각의 확률을 구하는 소프트맥스 레이어; 및

구한 상기 확률에 기초하여 상기 심전도 신호를 스트레스 상태 또는 스트레스가 아닌 상태로 분류하는 분류부;

를 포함하는, 정신적 스트레스 분류 장치.

청구항 7

시퀀스 폴딩 레이어에서, 심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환하는 제1 단계;

CNN 레이어에서, 배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵을 생성하는 제2 단계;

시퀀스 언폴딩 레이어에서, 생성된 상기 특징맵을 시퀀스 이미지로 변환하는 제3 단계;

플래튼 레이어에서, 변환된 상기 시퀀스 이미지를 1차원 데이터로 변환하는 제4 단계; 및

장단기 메모리 네트워크 레이어에서, 변환된 상기 1차원 데이터에 가중치를 이용하여 특징값을 추출하는 제5 단계;

추출된 상기 특징값에 따라 스트레스를 분류하는 제6 단계;

를 포함하는, 정신적 스트레스 분류 방법.

청구항 8

제7항에 기재된 방법을 컴퓨터상에서 실행하기 위한 프로그램을 기록한, 컴퓨터로 독출 가능한 기록 매체.

발명의 설명

기 술 분 야

[0001] 본 출원은, 컨볼루션 신경망 및 장단기 메모리 네트워크를 이용한 정신적 스트레스 분류 장치, 방법 및 컴퓨터로 독출 가능한 기록매체에 관한 것이다.

배 경 기 술

[0003] 현대인들이 겪고 있는 정신적 스트레스는 우울증, 암, 심혈관 질병 등 여러 질병을 유발하는 요인으로 이를 주기적으로 모니터링하고 관리하는 것이 중요하다. 스트레스는 적응하기 어려운 환경에 처할 때 사람이 느끼는 정신적, 육체적 반응으로, 과도한 영향을 받는 경우 악순환을 끼쳐 고혈압, 심장병, 암과 같은 만성질환의 원인이 되기도 하며, 심각할 경우 죽음에 이를 수 있다. 이러한 이유로 인하여 스트레스 관찰은 현대 사회에서 점점 더

중요해지고 있다.

[0005] 뇌전도(Electroencephalography), 근전도(Electromyography), 혈중 산소포화도(SpO2), 맥파(Photoplethysmography) 등의 생체신호를 이용한 스트레스 측정방법들이 제시되고 있다. 그러나 이러한 측정 방법들은 신호의 잡음과 채널수가 많아 스트레스 신호를 측정하는데 복잡하며, 잘못된 피크값을 검출할 수 있는 문제점이 있다.

[0007] 뇌전도 신호를 SVM(Support Vector Machine), MLP(Multi-Layer Perceptron), NB(Naive Bayes)으로 분석하여 75%, 85.20% 정확도를 얻었다. 그러나 이 연구들은 Training 데이터 개수가 15개로 부족하여 Overfitting이 발생할 수 있고 채널수가 7개로 스트레스 신호를 측정하는데 복잡하며 시간이 소요된다. 근전도 신호를 SVM으로 분석하여 85%의 정확도를 얻은 연구의 경우 근육의 미세한 움직임으로 인해 같은 동작에 대한 진폭의 크기가 다르며 신호의 잡음이 많아 정확한 특징점을 추출하는데 어려움이 있다.

[0009] 최근에는 심전도(Electrocardiography)를 이용한 스트레스를 분류하는 연구가 스트레스 신호의 측정 방법이 간편함으로 인해 많이 진행되고 있다. SVM(Support Vector Machine)의 알고리즘을 이용하여 89.21%, 84.4% 정확도를 얻은 연구 결과가 있으나, 심전도 신호를 측정하는데 시간이 요구되고 잡음이 많아 특징점을 추출하기 어려움이 있었다. HRV(Heart Rate Variability) Signal의 R-R Interval에 대한 표준 편차를 추출하여 75%~89%까지의 정확도를 얻은 연구 결과가 있으나, 이러한 연구들은 HRV Signal의 R-R Interval에 대한 표준 편차 계산이 5분 소요되고 매개변수 값의 차이가 작기 때문에 스트레스 상태를 판단하기 어렵다. 또한 주파수 영역에 대한 심전도 파형이 정확하지 않아 특징점을 추출하기 어렵고 소음이 인체의 미치는 영향을 직접적으로 확인하기 어려움이 있다.

[0011] 컨벌루션 신경망(Convolutional Neural Networks), CRNNs(Convolutional Recurrent Neural Networks)을 이용하여 87.39%, 90.19%의 정확도를 얻은 연구 결과가 있으나, 이러한 연구들은 스트레스 계층구조가 복잡하며, 잡음이 많아 잘못된 Rpeak 값을 검출하여 스트레스 분류 정확도를 높이는데 어려움이 있다. 장단기 메모리 네트워크(Long Short Term Memory network)을 이용하여 Epoch 20일 때 88.13% 정확도를 얻은 연구 결과가 있으나, 심전도 신호의 잡음이 많아 R-R Interval의 평균 제곱근을 계산하는데 어려움이 있다.

[0013] 또한, 호흡 신호와 심전도 신호를 측정하여 정신적 스트레스를 검출하는 연구가 있으나 호흡 신호와 심전도 신호를 분리하여 측정해야 하기 때문에 측정 시간이 오래 걸리며 심장 질환 및 스트레스와 같은 생리학적 신호를 객관적으로 정확히 판단할 수 없다. 기초적인 방법은 심전도 신호와 호흡 신호를 동시에 측정하여 판단하는 것이다.

[0015] 현재 호흡 및 심전도를 측정하는 장치가 많이 개발되어 있지만 대부분이 임상용이며 사용이 복잡하고 고가의 장비를 이용하여야 하는 문제점을 지니고 있다.

[0017] 심박변이도의 파라미터를 이용하여 스트레스 상태를 진단하는 연구가 있으나 사람에 따라 심박변이도가 다르고 잡음이 생길 수 있어 정확한 HRV signal의 R-R Interval을 이용한 파라미터를 산출하는데 어려움이 있으며 심박변이도의 파라미터의 가중치 값을 여러 번 산출해야 하는 복잡함이 있다.

선행기술문헌

특허문헌

[0019] (특허문헌 0001) 한국공개특허 제2008-0038512호(“심전도를 이용한 운전자 스트레스 지수 제공 시스템 및 방법”, 공개일: 2008년05월07일)

발명의 내용

해결하려는 과제

[0020] 본 발명의 일 실시 형태에 의하면, 기존의 CNN이나 장단기 메모리 네트워크를 단독으로 사용하여 분류하는 경우에 비해 스트레스의 분류 시간 및 분류 성능을 향상시킬 수 있고, 오버 피팅을 방지할 수 있는 컨볼루션 신경망 및 장단기 메모리 네트워크를 이용한 정신적 스트레스 분류 장치, 방법 및 컴퓨터로 독출 가능한 기록매체를 제공한다.

과제의 해결 수단

[0022] 본 발명의 일 실시 형태에 의하면, 심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환하는 시퀀스 폴딩 레이어; 배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵을 생성하는 CNN 레이어; 생성된 상기 특징맵을 시퀀스 이미지로 변환하는 시퀀스 언폴딩 레이어; 변환된 상기 시퀀스 이미지를 1차원 데이터로 변환하는 플래튼 레이어; 및 변환된 상기 1차원 데이터에 가중치를 이용하여 특징값을 추출하는 장단기 메모리 네트워크 레이어; 추출된 상기 특징값에 따라 스트레스를 분류하는 분류 모듈;을 포함하는, 정신적 스트레스 분류 장치를 제공한다.

[0024] 본 발명의 일 실시 형태에 의하면, 상기 심전도 신호는, 시간 영역의 심전도 신호와 상기 시간 영역의 심전도 신호에 대한 주파수 영역의 심전도 신호를 포함할 수 있다.

[0026] 본 발명의 일 실시 형태에 의하면, 상기 주파수 영역의 심전도 신호는, 스펙트로그램을 이용하여 상기 시간 영역의 심전도 신호로부터 변환된 신호일 수 있다.

[0028] 본 발명의 일 실시 형태에 의하면, 상기 CNN 레이어는, 상기 배열 형태의 이미지에 합성곱 연산을 수행하여 제1 특징맵을 생성하는 제1 콘볼루션 레이어; 생성된 상기 제1 특징맵의 최대값을 추출함으로써 제1 특징맵의 차원을 축소시키는 제1 맥스 풀링 레이어; 차원이 축소된 제1 특징맵에 합성곱 연산을 수행하여 제2 특징맵을 생성하는 제2 콘볼루션 레이어; 및 생성된 상기 제2 특징맵의 최대값을 추출함으로써 제2 특징맵의 차원을 축소시키는 제2 맥스 풀링 레이어;를 포함할 수 있다.

[0030] 본 발명의 일 실시 형태에 의하면, 상기 정신적 스트레스 분류 장치는, 제1 콘볼루션 레이어와 상기 제1 맥스 풀링 레이어 사이에는 상기 제1 특징맵을 정규화는 제1 정규화 레이어; 및 제2 콘볼루션 레이어와 상기 제2 맥스 풀링 레이어 사이에는 상기 제2 특징맵을 정규화하는 제2 정규화 레이어;를 더 포함할 수 있다.

[0032] 본 발명의 일 실시 형태에 의하면, 상기 분류 모듈은, 추출된 상기 특징값에 따라 스트레스 상태와 스트레스가 아닌 상태를 출력하는 풀 커넥티드 레이어; 출력된 스트레스 상태와 스트레스가 아닌 상태 각각의 확률을 구하는 소프트맥스 레이어; 및 구한 상기 확률에 기초하여 상기 심전도 신호를 스트레스 상태 또는 스트레스가 아닌 상태로 분류하는 분류부;를 포함할 수 있다.

[0034] 본 발명의 다른 실시 형태에 의하면, 시퀀스 폴딩 레이어에서, 심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환하는 제1 단계; CNN 레이어에서, 배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵을 생성하는 제2 단계; 시퀀스 언폴딩 레이어에서, 생성된 상기 특징맵을 시퀀스 이미지로 변환하는 제3 단계; 플래튼 레이

어에서, 변환된 상기 시퀀스 이미지를 1차원 데이터로 변환하는 제4 단계; 및 장단기 메모리 네트워크 레이어에서, 변환된 상기 1차원 데이터에 가중치를 이용하여 특징값을 추출하는 제5 단계;추출된 상기 특징값에 따라 스트레스를 분류하는 제6 단계;를 포함하는, 정신적 스트레스 분류 방법을 제공한다.

[0036] 본 발명의 다른 실시 형태에 의하면, 상기 방법을 컴퓨터상에서 실행하기 위한 프로그램을 기록한, 컴퓨터로 독출 가능한 기록 매체를 제공한다.

발명의 효과

[0038] 본 발명의 일 실시 형태에 의하면, 특징맵을 생성하는 CNN 레이어의 출력을 장단기 메모리 네트워크 레이어의 입력으로 하되, 시퀀스 폴딩 레이어, 시퀀스 언폴딩 레이어, 플래튼 레이어를 추가함으로써, 기존의 CNN이나 장단기 메모리 네트워크를 단독으로 사용하여 분류하는 경우에 비해 스트레스의 분류 시간 및 분류 성능을 향상시킬 수 있다.

[0040] 또한, 본 발명의 일 실시 형태에 의하면, 학습시 시간 영역의 심전도 신호와 함께 스펙트로그램을 이용하여 변환한 주파수 영역의 심전도 신호를 사용함으로써, 트레이닝 데이터 셋을 증가시켜 오버 피팅을 방지할 수 있다.

[0042] 또한, 상술한 정신적 스트레스 분류 장치는 홈 트레이닝, 수면 상태 분석, 심혈관계 모니터링 등 다양한 의료시스템 개발에 활용 가능하며, 주기적인 스트레스 관리를 통해 우울증, 고혈압, 당뇨병과 같은 각종 질병을 예방하는데 기여할 수 있다.

도면의 간단한 설명

[0043] 도 1은 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 블록도이다.

도 2는 본 발명의 일 실시 형태에 따른 시간 영역의 스트레스 상태와 스트레스가 아닌 상태와 스펙트로그램을 이용하여 변환한 주파수 영역의 스트레스 상태와 스트레스가 아닌 상태를 도시한 도면이다.

도 3은 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 컨퓨젼 매트릭스를 도시한 도면이다.

도 4는 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 ROC 곡선을 도시한 도면이다.

도 5는 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 PR 곡선을 도시한 도면이다.

도 6은 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 방법을 설명하는 흐름도이다.

발명을 실시하기 위한 구체적인 내용

[0044] 이하, 첨부된 도면을 참조하여 본 발명의 실시형태를 설명한다. 그러나 본 발명의 실시형태는 여러 가지의 다른 형태로 변형될 수 있으며, 본 발명의 범위가 이하 설명하는 실시형태로만 한정되는 것은 아니다. 도면에서의 요소들의 형상 및 크기 등은 더욱 명확한 설명을 위해 과장될 수 있으며, 도면상의 동일한 부호로 표시되는 요소는 동일한 요소이다.

[0045] 도 1은 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치(100)의 블록도이다.

[0046] 도 1에 도시된 바와 같이, 본 발명의 일 실시 형태에 따른 스트레스 분류 장치(100)는 시퀀스 입력 레이어(110), 시퀀스 폴딩 레이어(120), CNN 레이어(130), 시퀀스 언폴딩 레이어(140), 플래튼 레이어(150), 장단기 메모리 네트워크 레이어(160) 및 분류 모듈(170)을 포함하여 구성될 수 있다.

[0047] 구체적으로, 시퀀스 입력 레이어(Sequence input layer, 110)는 시간 영역과 주파수 영역의 심전도 신호가 입력되면 이를 시퀀스 이미지로 변환하여 시퀀스 폴딩 레이어(120)로 전달할 수 있다.

[0048] 본 발명에서는 심전도 신호는 시간 영역의 심전도 신호와 시간 영역의 심전도 신호에 대한 주파수 영역의 심전도 신호를 포함하며, 주파수 영역의 심전도 신호는, 스펙트로그램을 이용하여 시간 영역의 심전도 신호로부터

변환된 신호일 수 있다.

[0050] 한편, 도 2는 본 발명의 일 실시 형태에 따른 시간 영역에서의 스트레스 상태 및 스트레스가 아닌 상태와 각각에 대하여 스펙트로그램을 이용하여 변환한 주파수 영역에서의 스트레스 상태와 스트레스가 아닌 상태를 도시한 도면이다.

[0051] 도 2의 (a)는 스트레스가 아닌 상태의 시간 영역의 심전도 신호를, (c)는 스트레스가 아닌 상태의 시간 영역의 심전도 신호를 스펙트로그램을 이용하여 주파수 영역의 심전도 신호로 변환한 것이며, 도 2의 (b)는 스트레스 상태의 시간 영역의 심전도 신호를, (d)는 스트레스 상태의 시간 영역의 심전도 신호를 스펙트로그램을 이용하여 주파수 영역의 심전도 신호로 변환한 것이다.

[0053] 도 2에 도시된 바와 같이, 일반적으로 잡음에 노출된 심전도 신호 상태일 때 심장이 불규칙적으로 빨리 뛰게 되며 심전도 신호의 R-R Interval이 좁아지게 되고 $^{R-S_{peak}}$가 작아진다. 휴식 상태의 심전도 신호의 평균 $^{R-S_{peak}}$는 1.47mv이고 잡음에 노출된 심전도 신호의 평균 $^{R-S_{peak}}$는 4.25mV를 나타냈다.

[0055] 본 발명의 정신적 스트레스 분류 장치는, 도 2에 도시된 바와 같이, 시간 영역의 심전도 신호와 함께 스펙트로그램을 이용하여 변환한 주파수 영역의 심전도 신호를 학습에 사용함으로써, 트레이닝 데이터 셋을 증가시켜 오버 피팅을 방지할 수 있다.

[0056] 한편, 학습을 위해 ST Change Database, WESAD Database를 사용하였으며, 상술한 ST Change Database는 육체적 스트레스를 기록한 심전도 데이터로써 15명의 피험자로부터 28개의 심전도 신호를 취득한 데이터이다. WESAD Database는 피험자 15명으로부터 손목 및 가슴에서 측정한 30개의 심전도 신호를 포함하고 있다.

[0058] 한편, 시퀀스 폴딩 레이어(Sequence Folding Layer, 120)는 심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환할 수 있다. 변환된 배열 형태의 이미지는 CNN 레이어(130)로 전달될 수 있다.

[0060] CNN(Convolution Neural Network) 레이어(130)는 배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵(feature map)을 생성할 수 있다.

[0061] 구체적으로, CNN 레이어(130)는 배열 형태의 이미지에 합성곱 연산을 수행하여 제1 특징맵을 생성하는 제1 콘볼루션 레이어(131)와, 생성된 제1 특징맵의 최대값을 추출함으로써 제1 특징맵의 차원을 축소시키는 제1 맥스 풀링 레이어(133)와, 차원이 축소된 제1 특징맵에 합성곱 연산을 수행하여 제2 특징맵을 생성하는 제2 콘볼루션 레이어(134)와, 생성된 제2 특징맵의 최대값을 추출함으로써 제2 특징맵의 차원을 축소시키는 제2 맥스 풀링 레이어(136)를 포함할 수 있다.

[0062] 또한, 본 발명의 일 실시 형태에 의하면, 제1 콘볼루션 레이어(131)와 제1 맥스 풀링 레이어(133) 사이에는 제1 특징맵을 정규화하는 제1 정규화 레이어(132)를 더 포함할 수 있으며, 제2 콘볼루션 레이어(134)와 제2 맥스 풀링 레이어(136) 사이에는 제2 특징맵을 정규화하는 제2 정규화 레이어(135)를 더 포함할 수 있다.

[0064] 시퀀스 언폴딩 레이어(Sequence Unfolding Layer, 140)는 생성된 특징맵을 시퀀스 이미지로 변환할 수 있다. 변환된 시퀀스 이미지는 플래튼 레이어(150)로 전달될 수 있다.

[0066] 그리고, 플래튼 레이어(Flatten Layer, 150)는 변환된 시퀀스 이미지를 1차원 데이터로 변환할 수 있다. 변환된 1차원 데이터는 장단기 메모리 네트워크 레이어(160)로 전달될 수 있다.

[0067] 본 발명의 일 실시 형태에 의하면, 플래튼 레이어에서 출력된 1차원 데이터를 장단기 메모리 네트워크 레이어(160)의 입력값으로 함으로써, 장단기 메모리 네트워크 레이어의 매개변수를 변환할 필요가 없는 장점이 있다.

[0069] 장단기 메모리 네트워크 레이어(Long-Short Term Memory network, 160)는 변환된 1차원 데이터에 가중치를 이용하여 특징값을 추출할 수 있다. 추출된 특징값은 분류 모듈(170)로 전달될 수 있다.

[0070] 입력층에 가중치값 Wx=800×11532, Wh=800×200을 적용하여 하기 수학식 1에 따라 특징값을 추출할 수 있다.

수학식 1

[0071] [수학식 3]

$$i_t = \sigma(w_x x_t + w_h h_{t-1} + b_i)$$
$$g_t = \tanh(w_{xg} x_t + w_{hg} h_{t-1} + b_g)$$
$$f_t = \sigma(w_{xf} x_t + w_{hf} h_{t-1} + b_f)$$
$$o_t = \sigma(w_{xo} x_t + w_{ho} h_{t-1} + b_o)$$
$$c_t = f_t \circ c_{t-1} + i_t \circ g_t$$

[0072] 수학식 1은 장단기 메모리 네트워크 레이어(160)의 연산 과정을 나타낸다. 장단기 메모리 네트워크 레이어(160)는 입력 게이트(i_t, g_t), 망각 게이트(f_t), 출력 게이트(O_t)로 구성된다. 입력 게이트(i_t, g_t)는 새로운 정보를 결정하는 게이트이며, 망각 게이트(f_t)는 이전 정보를 결정하는 게이트이며, 출력 게이트(O_t)는 갱신된 셀(Cell)의 출력값을 제어하는 게이트를 의미한다. 이때 각 게이트에서는 시그모이드(sigmoid) 함수, 하이퍼볼릭 탄젠트(tanh) 함수를 이용하여 입력 벡터(x_t), 은닉 상태(h_{t-1}), 셀 상태(C_t)에 따라 가중치값을 곱한 후 특징값을 추출할 수 있다.

[0074] 이후 하기 수학식 2를 적용하여 출력 게이트에서 연산된 특징값을 출력층으로 전달한다. 수학식 4는 출력 게이트에서 계산된 여러 개의 특징값 중 불 필요한 값을 버리고 필요한 특징값을 추출하는 과정을 나타낸다. Tanh 함수를 이용하여 -1에서 1까지의 특징값을 추출한 후 출력 게이트에 계산된 해당 범위의 특징값을 출력층으로 전달한다.

수학식 2

[0075] $$h_t = o_t \circ \tanh(c_t)$$

[0077] 상술한 장단기 메모리 네트워크 레이어(160)는 RNN(Recurrent Neural Networks) 한 종류로써 글, 유전자 신호 분석 등 배열의 형태를 갖는 데이터에서 패턴을 인식하는 인공 신경망이다. 일반적인 인공 신경망은 데이터를 입력하면 연산이 입력 층(Input layer)에서 은닉 층(Hidden layer)를 거쳐 출력까지 순차적으로 진행한다. 이 과정에서 입력 데이터는 모든 노드를 딱 한 번씩만 지나가게 된다. 이전의 데이터는 잘 기억하지 못하는 단점이 있다.

[0078] 하지만 RNN은 일반적인 인공 신경망과 달리 은닉 층의 결과가 다시 같은 은닉 층의 입력으로 들어가도록 연결되어 있다. 따라서, 은닉 층의 출력이 다시 같은 은닉 층으로 반복해서 입력되는 것을 의미한다. 하지만 크기가 큰 데이터들은 잘 처리하지 못하므로 연산 속도가 매우 느려진다. 이를 해결하기 위해 장단기 메모리 네트워크(LSTM)를 사용한다. 장단기 메모리 네트워크는 RNN의 특별한 종류로 순차적인 입력 데이터간의 거리가 멀어도 잘 기억하고 학습할 수 있도록 설계된 신경망이다.

[0080] 마지막으로, 분류 모듈(170)은 추출된 특징값에 따라 스트레스를 분류할 수 있다.

[0081] 구체적으로, 분류 모듈(170)은 추출된 특징값에 따라 스트레스 상태와 스트레스가 아닌 상태를 출력하는 풀 커

넥티드 레이어(Fully Connected Layer, 171)과, 출력된 스트레스 상태와 스트레스가 아닌 상태 각각의 확률을 구하는 소프트맥스 레이어(Softmax Layer, 172)와, 구한 확률에 기초하여 심전도 신호를 스트레스 상태 또는 스트레스가 아닌 상태로 분류하는 분류부(173)를 포함할 수 있다.

[0082] 하기 표 1에 상술한 각 레이어의 구조를 정리하여 도시하였다.

표 1

[0083]

Number	Layer	Activations	Weights	Bias
1	Sequence Input Layer	124*124*3	-	-
2	Sequence Folding Layer	124*124*1	-	-
3	Convolution 2D Layer	124*124*6	5*5*3*6	1*1*6
4	Batch Normalization Layer	124*124*6	-	-
5	Max Pooling Layer	62*62*6	-	-
6	Convolution 2D Layer	62*62*12	3*3*6*12	1*1*12
7	Batch Normalization Layer	62*62*12	-	-
8	Max Pooling Layer	31*31*12	-	-
9	Sequence Unfolding Layer	31*31*12	-	-
10	Flatten Layer	11532	-	-
11	LSTM Layer	200	Input: 800*11532 Recurrent: 800*200	800*1
12	Fully Connected Layer	2	2*200	2*1
13	Softmax Layer	2	-	-
14	Classification	-	-	-

[0085] 한편, 도 3은 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 컨퓨젼 매트릭스를 도시한 도면이며, 도 4는 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 ROC 곡선을 도시한 도면이며, 도 5는 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 장치의 PR 곡선을 도시한 도면이다.

[0086] 즉, 본 발명에서는 스트레스 신호의 분류 성능을 평가하기 위해 컨퓨젼 매트릭스(도 3 참조), ROC 곡선(도 4 참조), PR 곡선(도 5 참조)을 사용하였다.

[0087] 컨퓨젼 매트릭스(Confusion Matrix)는 모델의 성능을 평가할 때 사용되는 지표로써, 예측값이 실제 관측값을 얼마나 정확히 예측했는지 보여주는 행렬이다.

표 2

[0088]

Time + Frequency Domain					
Stress	Precision	Sensitivity	Specificity	Negative Predictive Value	Accuracy
Performance (%)	100%	98.3%	100%	98.3%	99.1%
Error (%)	0.0%	1.7%	0.0%	1.7%	0.9%

[0089] 표 2에는 컨퓨젼 매트릭스(Confusion Matrix)를 사용하여 스트레스 신호의 분류모델의 성능에 대한 정확도(Accuracy), 민감도(Sensitivity), 특이도(Specificity), 정밀도(Precision), 음성 예측도(Negative Predictive Value)의 값을 나타낸다. 그리고, 아래의 수학식 5는 정확도, 민감도, 특이도, 정밀도, 음성 예측도를 계산하는 과정을 나타낸다.

수학식 3

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$
$$Sensitivity = \frac{TP}{FN + TP}$$
$$Specificity = \frac{TN}{TN + FP}$$
$$Precision = \frac{TP}{TP + FP}$$
$$Native Predictive\ Value = \frac{TN}{TN + FN}$$

[0090]

[0091] 정확도(Accuracy)는 모든 잡음에 노출된 심전도 신호와 휴식 상태의 심전도 신호를 정확하게 분류한 확률을 나타낸다. 시간 영역 및 주파수 영역에 대한 정확도는 99.1%를 나타냈다. 민감도(Sensitivity)는 잡음에 노출된 심전도 데이터 중 알고리즘이 잡음에 노출된 심전도 신호로 정확하게 분류한 확률이다. 시간 영역 및 주파수 영역에서의 민감도는 98.3%를 나타냈다. 특이도(Specificity)는 휴식 상태의 심전도 데이터 중 알고리즘이 휴식 상태의 심전도 데이터로 정확하게 분류된 확률이다. 시간 영역 및 주파수 영역에서의 특이도는 100%를 나타냈다. 정밀도(Precision)는 잡음에 노출된 심전도 데이터 중 알고리즘의 잡음에 노출된 심전도 데이터로 정확하게 분류한 확률이다. 시간 영역 및 주파수 영역에서 정밀도는 100%를 나타냈다. 음성 예측도(Negative Predictive Value)는 결과가 잡음에 노출된 심전도 데이터로 나온 경우 알고리즘이 잡음에 노출된 심전도 데이터로 정확하게 분류된 확률이다. 시간 영역 및 주파수 영역에서의 음성 예측도는 98.3%를 나타냈다.

[0093] 도 5에 도시된 바와 같이, 본 발명의 일 실시 형태에 따른 컨벌루션 신경망과 장단기 메모리 네트워크를 결합한 알고리즘의 스트레스 신호 분류 정확도는 99.1%를 나타내었으며, 이러한 결과는 기존 CNN 단독 또는 장단기 메모리 네트워크 단독의 경우보다 스트레스 신호의 분류 알고리즘에 비해 정확도가 15.5% 향상되었다.

[0095] 한편, 하기 표 3은 심전도 신호의 분류 성능을 평가하기 위해 시간 영역 및 주파수 영역의 에폭(epoch) 수에 따른 평균 제곱 오류율(Mean Squared Error)을 도시하고 있다.

표 3

[0096]

Time + Frequency Domain	
Epoch	MAE
50	0.34
100	0.33
150	0.31
200	0.29
223	0.27

[0097] 훈련, 검증 및 테스트 성능과 관련하여 컨벌루션 신경망과 장단기 메모리 네트워크를 결합한 알고리즘의 스트레스 분류 성능을 평가한다. 훈련 데이터는 스트레스 신호의 분류 알고리즘을 학습하는데 사용되며, 검증 데이터는 훈련 데이터의 성능을 기반으로 데이터 값을 결정하는데 사용되며, 테스트 데이터는 전체 스트레스 신호의 분류 성능을 평가하기 위해 사용된다. 시간 영역 및 주파수 영역에서는 Epoch 223에서 스트레스 신호의 분류 오차율이 가장 작으며 스트레스 신호의 분류 성능이 뛰어났다.

[0099] 한편, 도 4에 도시된 ROC 곡선(Receiver Operating Characteristic Curve)은 이진 분류 시스템의 성능 평가 기법으로 스트레스와 같은 질병의 유무를 판단하는 분석 방법이다. ROC Curve의 아래 면적인 AUC(Area Under The Curve)는 스트레스 신호의 분류 성능을 평가하는 지표이다. AUC 범위가 0.9 이상 1.0 미만이면 스트레스 신호의 분류 성능이 우수하며, 0.8 이상 0.9 미만이면 스트레스 신호의 분류 성능이 낮음을 나타낸다.

[0101] 도 6의 시간 영역 및 주파수 영역에서 ROC Curve의 AUC는 98.3%를 나타냈다. 반면, CNN 단독 또는 장단기 메모리 네트워크 단독의 경우 ROC Curve를 이용한 스트레스 신호의 AUC는 85.7%를 나타냈다. 따라서 기존 스트레스 신호의 분류 알고리즘에 비해 ROC Curve의 AUC는 12.6% 향상되어 스트레스 신호의 분류 성능이 더 좋다는 것을 알 수 있다.

[0103] 그리고, 도 5는 심전도 신호를 이용한 시간 영역과 주파수 영역의 에폭(epoch) 값에 따르 PR 곡선(Precesion Recall curve)을 도시하고 있다.

[0104] ROC 곡선은 데이터 셋이 매우 불안정할 경우 곡선의 모양이 한쪽으로 치우쳐 스트레스 신호의 분류 성능을 평가하는데 많은 어려움이 있다. PR Curve는 ROC Curve의 단점을 극복하기 위해 사용하고 정밀도와 재현율 사이의 연관성을 나타낸다. PR Curve의 AP(Average Precision)는 스트레스 신호의 분류 성능을 평가하는 지표이다. X 축은 Recall(Sensitivity), Y 축은 Precision를 나타낸다. PRCurve에서 AP가 클수록 스트레스 신호의 분류 성능이 뛰어남을 나타낸다.

[0105] 도 5의 시간 영역 및 주파수 영역에서 PR Curve의 AUC는 97.6%를 나타내고 있으며 기존 스트레스 신호의 분류 알고리즘의 AP는 84.2%를 나타낸다. 따라서 기존 스트레스 신호의 분류알고리즘에 비해 PR Curve의 AP는 13.4% 향상되어 스트레스 분류 성능이 더 좋다는 것을 알 수 있다.

[0106] 한편, 하기 표 4는 컨벌루션 신경망과 장단기 메모리 네트워크를 결합한 알고리즘을 이용하여 스트레스 신호의 분류 정확도를 나타낸다.

표 4

[0107]

	Time+ Frequency Domain
Epoch	20
Batch Size	64
Elapsed Time	7min 26sec
Accuracy	99.1%

[0108] 심전도 데이터의 시간 영역과 주파수 영역을 이용한 기존 스트레스 신호의 분류 알고리즘은 Epoch=10, Batch Size=64로 설정했다. 그 결과 기존 스트레스 신호의 분류 알고리즘에 대한 시간 영역과 주파수 영역의 정확도는 83.6%, 74.5%를 나타냈다. 하지만 이 구조는 스트레스 신호를 분류하는 과정에서 Overfitting이 일어날 수 있다.

[0109] 따라서 본 발명에서는 Epoch=20, Batch Size=64로 설정한 후 컨벌루션 신경망과 장단기 메모리 네트워크를 결합한 알고리즘을 이용하여 심전도 데이터의 시간 영역 및 주파수 영역에 대한 스트레스 신호의 분류 정확도를 측정했다. 분류 결과 시간 영역 및 주파수 영역의 분류 시간은 7분 28초이며 검증 정확도는 99.1%를 나타냈다. 따라서 기존 스트레스 신호의 분류 알고리즘보다 15.5%, 24.6% 높은 정확도를 나타냄을 알 수 있다.

[0111] 마지막으로, 도 6은 본 발명의 일 실시 형태에 따른 컨볼루션 신경망 및 장단기 메모리 네트워크를 이용한 정신적 스트레스 분류 방법을 설명하는 흐름도이다.

[0112] 이하 도 1 내지 도 6을 참조하여 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 방법을 상세하게 설명한다. 다만, 발명의 간명화를 위해 도 1 내지 도 5에서 설명된 사항과 중복된 부분에 대한 설명은 생략한다.

[0113] 본 발명의 일 실시 형태에 따른 정신적 스트레스 분류 방법은, 다음, 시퀀스 폴딩 레이어(Sequence Folding Layer, 120)는 심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환할 수 있다(S601). 변환된 배열 형태의 이미지는 CNN 레이어(130)로 전달될 수 있다.

[0115] CNN(Convolution Neural Network) 레이어(130)는 배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵(feature map)을 생성할 수 있다(S602).

[0116] 구체적으로, CNN 레이어(130)는 배열 형태의 이미지에 합성곱 연산을 수행하여 제1 특징맵을 생성하는 제1 콘볼루션 레이어(131)와, 생성된 제1 특징맵의 최대값을 추출함으로써 제1 특징맵의 차원을 축소시키는 제1 맥스 풀링 레이어(133)와, 차원이 축소된 제1 특징맵에 합성곱 연산을 수행하여 제2 특징맵을 생성하는 제2 콘볼루션 레이어(134)와, 생성된 제2 특징맵의 최대값을 추출함으로써 제2 특징맵의 차원을 축소시키는 제2 맥스 풀링 레이어(136)를 포함할 수 있다.

[0117] 또한, 본 발명의 일 실시 형태에 의하면, 제1 콘볼루션 레이어(131)와 제1 맥스 풀링 레이어(133) 사이에는 제1 특징맵을 정규화하는 제1 정규화 레이어(132)와, 제2 콘볼루션 레이어(134)와 제2 맥스 풀링 레이어(136) 사이에는 제2 특징맵을 정규화하는 제2 정규화 레이어(135)를 더 포함할 수 있다.

[0119] 시퀀스 언폴딩 레이어(Sequence Unfolding Layer, 140)는 생성된 특징맵을 시퀀스 이미지로 변환할 수 있다(S603). 변환된 시퀀스 이미지는 플래튼 레이어(150)로 전달될 수 있다.

[0121] 그리고, 플래튼 레이어(Flatten Layer, 150)는 변환된 시퀀스 이미지를 1차원 데이터로 변환할 수 있다(S604). 변환된 1차원 데이터는 장단기 메모리 네트워크 레이어(160)로 전달될 수 있다.

[0123] 장단기 메모리 네트워크 레이어(Long-Short Term Memory network layer, 160)는 변환된 1차원 데이터에 가중치를 이용하여 특징값을 추출할 수 있다(S605). 추출된 특징값은 분류 모듈(170)로 전달될 수 있다.

[0125] 마지막으로, 분류 모듈(170)은 추출된 특징값에 따라 스트레스를 분류할 수 있다(S606).

[0126] 구체적으로, 분류 모듈(170)은 추출된 특징값에 따라 스트레스 상태와 스트레스가 아닌 상태를 출력하는 풀 커넥티드 레이어(Fully Connected Layer, 171)과, 출력된 스트레스 상태와 스트레스가 아닌 상태 각각의 확률을 구하는 소프트맥스 레이어(Softmax Layer, 172)와, 구한 확률에 기초하여 심전도 신호를 스트레스 상태 또는 스트레스가 아닌 상태로 분류하는 분류부(173)를 포함할 수 있음은 상술한 바와 같다.

[0128] 상술한 바와 같이, 본 발명의 일 실시 형태에 의하면, 특징맵을 생성하는 CNN 레이어의 출력을 장단기 메모리 네트워크 레이어의 입력으로 하되, 시퀀스 폴딩 레이어, 시퀀스 언폴딩 레이어, 플래튼 레이어를 추가함으로써, 기존의 CNN이나 장단기 메모리 네트워크를 단독으로 사용하여 분류하는 경우에 비해 스트레스의 분류 시간 및 분류 성능을 향상시킬 수 있다.

[0130] 또한, 본 발명의 일 실시 형태에 의하면, 학습시 시간 영역의 심전도 신호와 함께 스펙트로그램을 이용하여 변환한 주파수 영역의 심전도 신호를 사용함으로써, 트레이닝 데이터 셋을 증가시켜 오버 피팅을 방지할 수 있다.

[0132] 또한, 상술한 정신적 스트레스 분류 장치는 홈 트레이닝, 수면 상태 분석, 심혈관계 모니터링 등 다양한 의료시스템 개발에 활용 가능하며, 주기적인 스트레스 관리를 통해 우울증, 고혈압, 당뇨병과 같은 각종 질병을 예방하는데 기여할 수 있다.

[0134] 상술한 본 발명의 일 실시 형태에 따른 컨볼루션 신경망 및 장단기 메모리 네트워크를 이용한 정신적 스트레스 분류 장치, 방법은 컴퓨터에서 실행되기 위한 프로그램으로 제작되어 컴퓨터가 읽을 수 있는 기록 매체에 저장될 수 있다. 컴퓨터가 읽을 수 있는 기록 매체의 예로는 ROM, RAM, CD-ROM, 자기 테이프, 플로피디스크, 광 데이터 저장장치 등을 포함한다. 또한, 컴퓨터가 읽을 수 있는 기록 매체는 네트워크로 연결된 컴퓨터 시스템에 분산되어, 분산방식으로 컴퓨터가 읽을 수 있는 코드가 저장되고 실행될 수 있다. 그리고 상기 방법을 구현하기

위한 기능적인(function) 프로그램, 코드 및 코드 세그먼트들은 본 발명이 속하는 기술분야의 프로그래머들에 의해 용이하게 추론될 수 있다.

[0136] 또한, 본 발명을 설명함에 있어, '~ 모듈', '~ 부'는 다양한 방식, 예를 들면 프로세서, 프로세서에 의해 수행되는 프로그램 명령들, 소프트웨어 모듈, 마이크로 코드, 컴퓨터 프로그램 생성물, 로직 회로, 애플리케이션 전용 집적 회로, 펌웨어 등에 의해 구현될 수 있다.

[0138] 본 발명은 상술한 실시형태 및 첨부된 도면에 의해 한정되지 아니한다. 첨부된 청구범위에 의해 권리범위를 한정하고자 하며, 청구범위에 기재된 본 발명의 기술적 사상을 벗어나지 않는 범위 내에서 다양한 형태의 치환, 변형 및 변경할 수 있다는 것은 당 기술분야의 통상의 지식을 가진 자에게 자명할 것이다.

부호의 설명

[0139] 100: 정신적 스트레스 분류 장치

110: 시퀀스 입력 레이어

120: 시퀀스 폴딩 레이어

130: CNN 레이어

131: 제1 콘볼루션 레이어

132: 제1 정규화 레이어

133: 제1 맥스 풀링 레이어

134: 제2 콘볼루션 레이어

135: 제2 정규화 레이어

136: 제2 맥스 풀링 레이어

140: 시퀀스 언폴딩 레이어

150: 플래튼 레이어

160: 장단기 메모리 네트워크 레이어

170: 분류 모듈

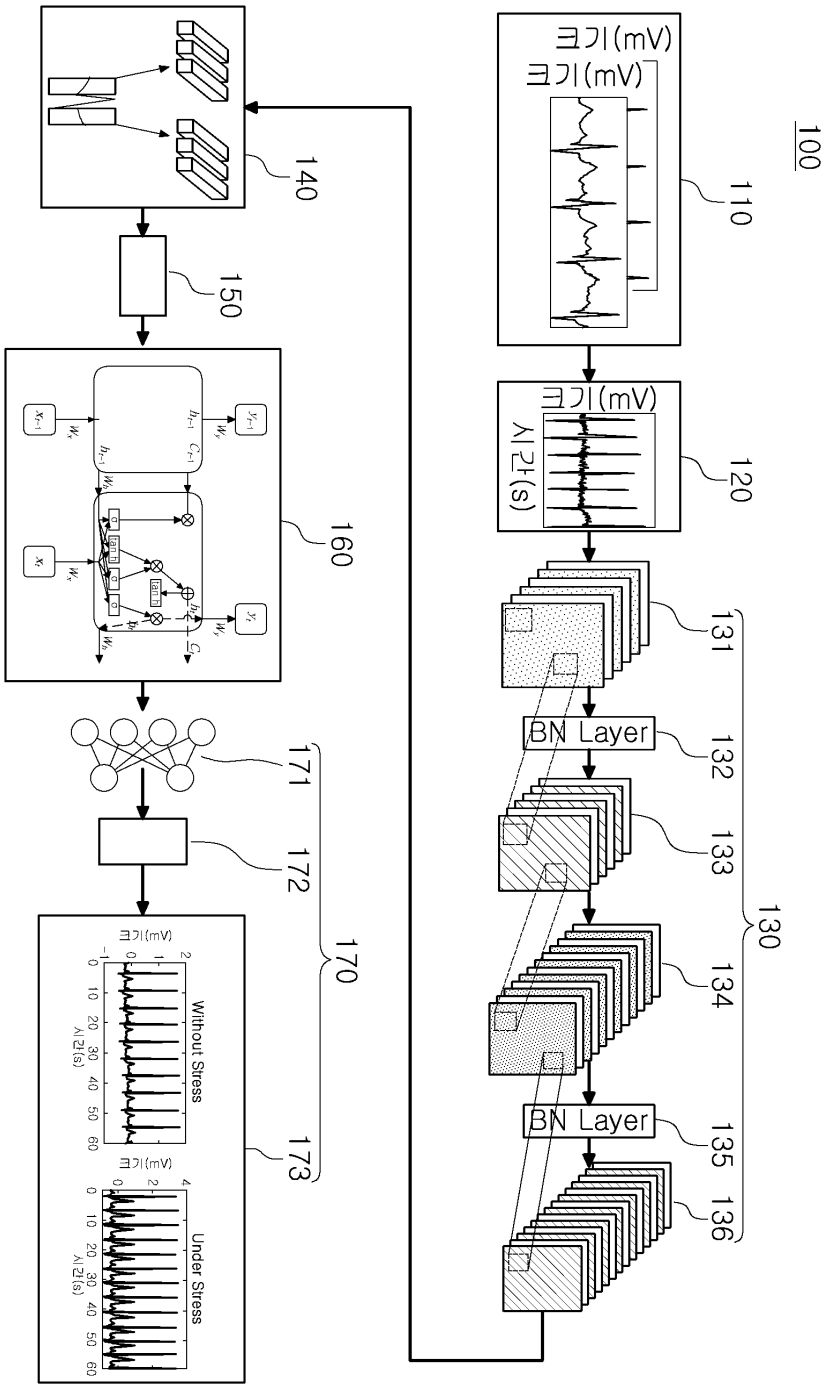
171: 풀 커넥티드 레이어

172: 소프트맥스 레이어

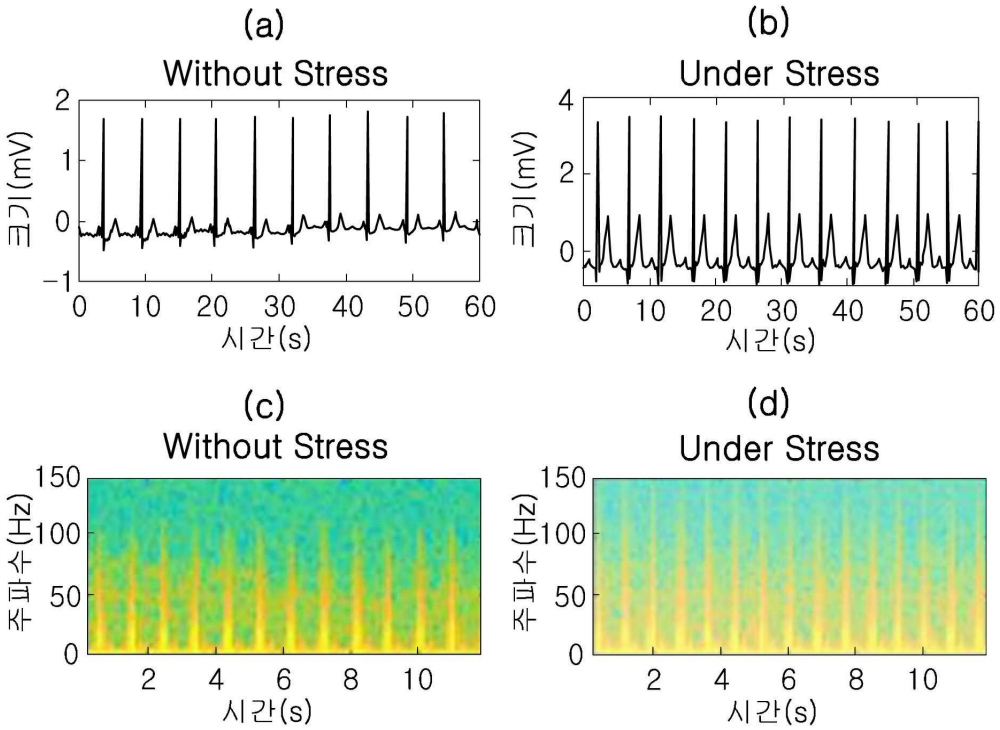
173: 분류부

도면

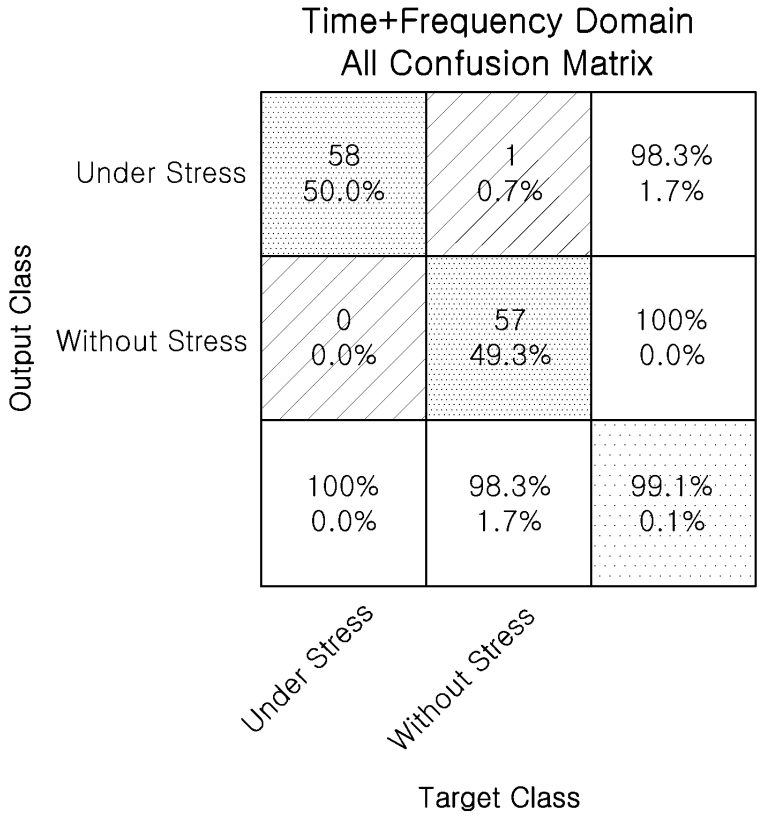
도면1


100
110
크기(mV)
크기(mV)
120
크기(mV)
시간(s)
130
131
BN Layer
132
133
134
BN Layer
135
136
140
150
160
170
171
172
173
Without Stress
Under Stress
크기(mV)
시간(s)

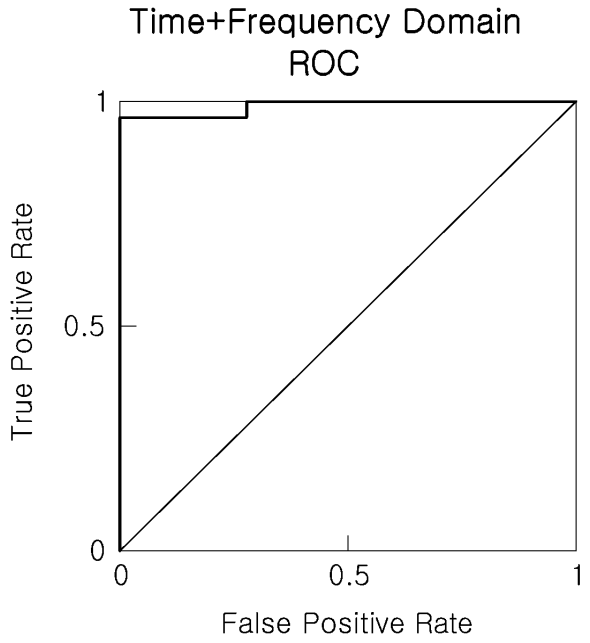
도면2


(a)
Without Stress
크기(mV)
시간(s)
(b)
Under Stress
크기(mV)
시간(s)
(c)
Without Stress
주파수(Hz)
시간(s)
(d)
Under Stress
주파수(Hz)
시간(s)

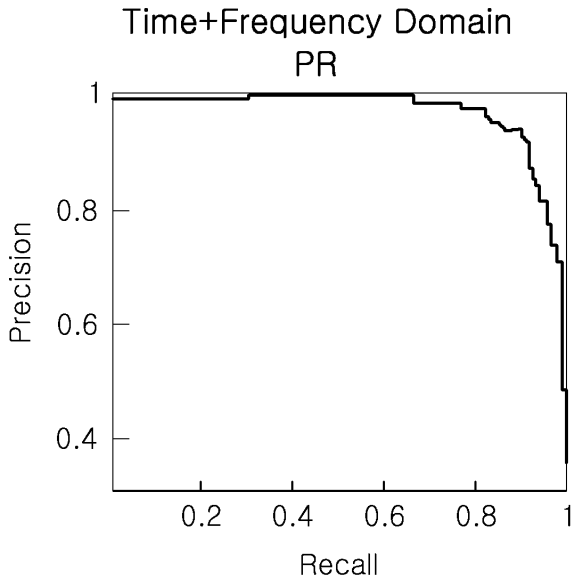
도면3


Time+Frequency Domain
All Confusion Matrix
Output Class
Under Stress
Without Stress
58
50.0%
1
0.7%
98.3%
1.7%
0
0.0%
57
49.3%
100%
0.0%
100%
0.0%
98.3%
1.7%
99.1%
0.1%
Under Stress
Without Stress
Target Class

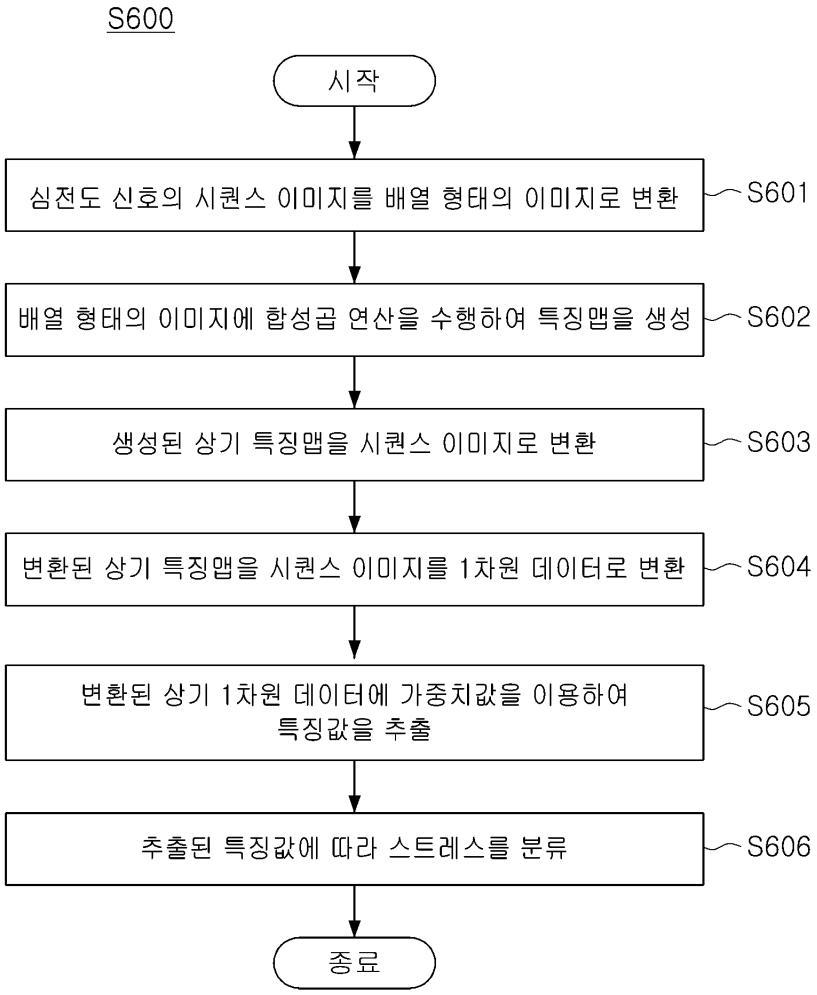
도면4


Time+Frequency Domain
ROC
True Positive Rate
False Positive Rate
0
0.5
1
0
0.5
1

도면5


Time+Frequency Domain
PR
Precision
Recall
1
0.8
0.6
0.4
0.2
0.4
0.6
0.8
1

도면6


S600
시작
심전도 신호의 시퀀스 이미지를 배열 형태의 이미지로 변환
S601
배열 형태의 이미지에 합성곱 연산을 수행하여 특징맵을 생성
S602
생성된 상기 특징맵을 시퀀스 이미지로 변환
S603
변환된 상기 특징맵을 시퀀스 이미지를 1차원 데이터로 변환
S604
변환된 상기 1차원 데이터에 가중치값을 이용하여 특징값을 추출
S605
추출된 특징값에 따라 스트레스를 분류
S606
종료