



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2019-0141326
(43) 공개일자 2019년12월24일

(51) 국제특허분류(Int. Cl.)
A61B 5/0464 (2006.01) A61B 5/00 (2006.01)
A61B 5/04 (2006.01)
(52) CPC특허분류
A61B 5/0464 (2019.05)
A61B 5/04012 (2013.01)
(21) 출원번호 10-2018-0067933
(22) 출원일자 2018년06월14일
심사청구일자 2018년06월14일

(71) 출원인
한국과학기술원
대전광역시 유성구 대학로 291(구성동)
(72) 발명자
김대영
대전광역시 유성구 대학로 291 (구성동, 한국과학기술원)
전태준
대전광역시 유성구 대학로 291 (구성동, 한국과학기술원)
(뒷면에 계속)
(74) 대리인
양성보

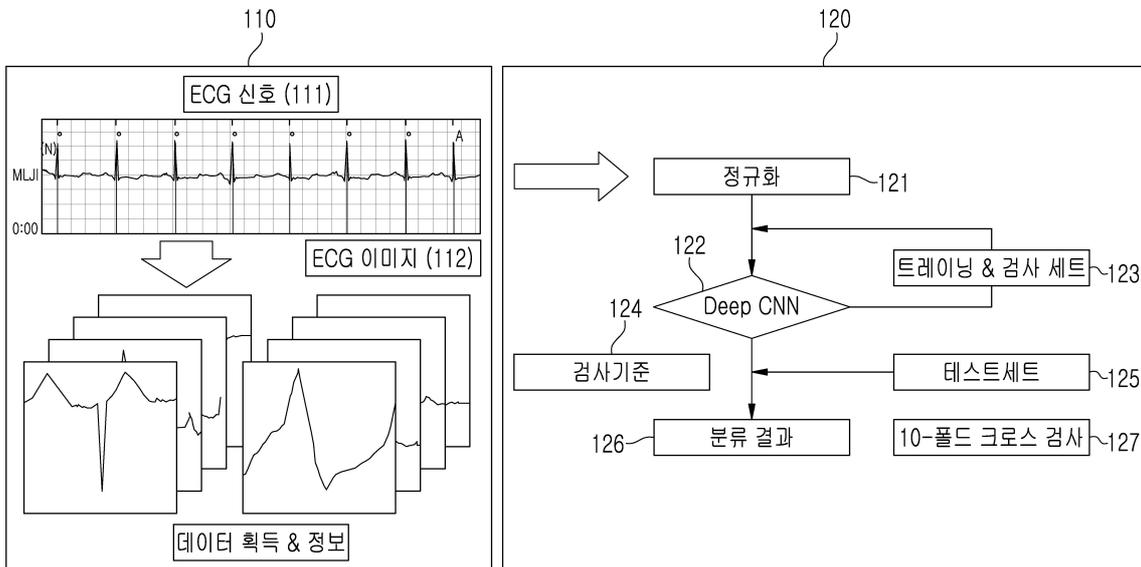
전체 청구항 수 : 총 14 항

(54) 발명의 명칭 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법 및 장치

(57) 요약

심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법 및 장치가 제시된다. 본 발명에서 제안하는 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법은 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계 및 학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계를 포함한다.

대표도



(52) CPC특허분류
A61B 5/7267 (2013.01)

(72) 발명자
응우웬, 민 호앙

대전광역시 유성구 대학로 291 (구성동, 한국과학
기술원)

강대연

대전광역시 유성구 대학로 291 (구성동, 한국과학
기술원)

김도현

대전광역시 유성구 대학로 291 (구성동, 한국과학
기술원)

명세서

청구범위

청구항 1

1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계; 및

학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계

를 포함하는 심전도 부정맥 분류 방법.

청구항 2

제1항에 있어서,

상기 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계는,

부정맥 유형은 각 ECG 신호의 R-웨이브 피크 타임에서 라벨링되고, 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 미리 정해진 복수 개의 마지막 ECG 신호를 제외하고 W-웨이브 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의하는

심전도 부정맥 분류 방법.

청구항 3

제1항에 있어서,

상기 CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계는,

학습 기법 중 그래디언트 디센트 기반 학습을 이용하고, 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키는 단계;

그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하는 단계;

그래디언트 디센트 기반 학습의 모델 내 커널 가중치의 출력 값을 정의 하는 단계;

그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하는 단계;

목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타내는 단계; 및

검사 세트를 이용하여 그래디언트 디센트 기반 학습의 모델이 트레이닝 세트에서 미리 정해진 정확도에 도달하는 지를 판단하는 단계

를 포함하는 심전도 부정맥 분류 방법.

청구항 4

제3항에 있어서,

상기 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키는 단계는,

2차원 ECG 이미지를 입력 데이터로 정의하여 자르기 및 리사이징을 통해 이미지를 수정하여 트레이닝 세트를 확장시키고, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지하는

심전도 부정맥 분류 방법.

청구항 5

제4항에 있어서,

상기 2차원 ECG 이미지를 보강하는 방식은 왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래의 서로 다른 자르기 방법을 이용하여 PVC, PAB, RBB, LBB, APC, VFW, VEB를 포함하는 보강 방식을 이용하여 복수의 ECG 부정맥 박동을 보강하는

심전도 부정맥 분류 방법.

청구항 6

제3항에 있어서,

상기 그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하는 단계는,

모든 커널에서 그래디언트의 비율을 대략 동일하게 유지하는 Xavier 초기화를 이용하고, 미리 정해진 범위에서 랜덤하게 초기화되는

심전도 부정맥 분류 방법.

청구항 7

제3항에 있어서,

상기 그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하는 단계는,

입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동되며, 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용되고, 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성 함수 직후에 배치 정규화 레이어를 적용하는

심전도 부정맥 분류 방법.

청구항 8

1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 전처리부; 및

학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 ECG 부정맥 분류부

를 포함하는 심전도 부정맥 분류 장치.

청구항 9

제8항에 있어서,

상기 전처리부는,

부정맥 유형은 각 ECG 신호의 R-웨이브 피크 타임에서 라벨링되고, 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 미리 정해진 복수 개의 마지막 ECG 신호를 제외하고 W-웨이브 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의하는

심전도 부정맥 분류 장치.

청구항 10

제8항에 있어서,

상기 ECG 부정맥 분류부는,

학습 기법 중 그래디언트 디센트 기반 학습을 이용하고, 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키고;

그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하고;

그래디언트 디센트 기반 학습의 모델 내 커널 가중치의 출력 값을 정의 하고;

그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하고;

목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타내고; 및

검사 세트를 이용하여 그래디언트 디센트 기반 학습의 모델이 트레이닝 세트에서 미리 정해진 정확도에 도달하는지를 판단하는

심전도 부정맥 분류 장치.

청구항 11

제10항에 있어서,

상기 ECG 부정맥 분류부는,

2차원 ECG 이미지를 입력 데이터로 정의하여 자르기 및 리사이징을 통해 이미지를 수정하여 트레이닝 세트를 확장시키고, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지하는

심전도 부정맥 분류 장치.

청구항 12

제11항에 있어서,

상기 2차원 ECG 이미지를 보강하는 방식은 왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래의 서로 다른 자르기 방법을 이용하여 PVC, PAB, RBB, LBB, APC, VFW, VEB를 포함하는 보강 방식을 이용하여 복수의 ECG 부정맥 박동을 보강하는

심전도 부정맥 분류 장치.

청구항 13

제10항에 있어서,

상기 ECG 부정맥 분류부는,

모든 커널에서 그래디언트의 비율을 대략 동일하게 유지하는 Xavier 초기화를 이용하고, 미리 정해진 범위에서 랜덤하게 초기화되는

심전도 부정맥 분류 장치.

청구항 14

제10항에 있어서,

상기 ECG 부정맥 분류부는,

입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동되며, 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용되고, 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성화 함수 직후에 배치 정규화 레이어를 적용하는

심전도 부정맥 분류 장치.

발명의 설명

기술 분야

본 발명은 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법 및 장치에 관한 것이다.

[0001]

배경 기술

- [0002] WHO에 따르면, 심혈관 질환(CVDs)은 오늘날 사망 원인 중 가장 큰 원인이다. 1770만 명이 넘는 사람들이 CVD로 인하여 사망했으며, 이는 전체 사망자의 약 31%에 달하고, 75% 이상이 저소득 및 중간 소득 국가에서 발생한다. 부정맥은 정상적인 심장 리듬에서 불규칙적인 변화를 나타내는 CVD의 대표적인 유형이다. 부정맥에는 심장 세동 (atrial fibrillation), 조기 수축(premature contraction), 심실 세동(ventricular fibrillation) 및 빈맥 (tachycardia) 등이 포함된다. 비록 단일 부정맥 심장 박동이 생명에 심각한 영향을 미치지 않을 수도 있지만, 지속적인 부정맥 박동은 치명적인 상황을 초래할 수 있다. 예를 들어, 연장된 조기 심실 수축(PVCs) 박동은 때 때로 심실 빈맥(VT) 또는 심실 결막(VF) 박동으로 전환되어 즉시 심장 마비로 이어질 수 있다. 따라서 CVDs를 관리하고 예방하기 위하여 심장 박동을 지속적으로 모니터링 하는 것은 중요하다. ECG는 심장 리듬 및 상태를 디스플레이하는 비-침습적 의료 도구이다. 따라서 ECG 신호에서 불규칙한 심장 리듬을 자동적으로 검출하는 것은 심장학(cardiology) 분야에서 매우 중요한 일이다.
- [0003] ECG 부정맥 분류에 대한 종래기술에서 다양한 방법들이 제안되었다. 먼저, FFNN(feed-forward neural networks)을 분류기로 사용한 종래기술을 요약하였다. Linh 등은 특징 추출을 위한 Hermite 함수가 적용된 퍼지 신경망 모델을 제안하였다. Güler 등은 FFNNdmf 분류기로 제안하고, 트레이닝에 Lavenberg-Marquard 알고리즘을 사용하여 특징을 추출하는 WT를 제안하였다. Ceylan 등은 FFNN을 분류기로 제안하였으며, 특징 추출을 위해 주 성분 분석(PCA) 및 웨이블릿 변환(WT)를 제안하였고, 특징 감소를 위해 퍼지 c-평균 클러스터링(FCM) 방법을 제안하였다. 결과적으로, PCA, FCM 및 FFNN의 조합을 포함하는 전술된 방법들은 10가지 서로 다른 부정맥을 이용하여 최상의 결과를 달성하였다. 96.95%의 정확을 가지는 4가지 서로 다른 부정맥이 검출되었다. Hassena 등은 FCM 기반 확률 신경망(PCC)을 소개하였으며, 8가지의 서로 다른 유형의 부정맥을 이용하여 거의 99%의 정확도를 달성하였다. 또 다른 종래기술들 또한, 서로 다른 FFNN을 다양한 특징 추출 및 특징 제거 방법을 가지는 분류기로 적용하였다.
- [0004] 서포트 벡터 머신(Support Vector Machine, SVM) 또한, ECG 부정맥 검출의 분류 방법으로 광범위하게 적용되었다. Osowski 등은 교차 통계(HOS)와 Hermite 함수를 특징 추출 방법으로 사용한 SVM을 분류기로 도입하였다. Song 등은 부정맥의 6가지 유형에 대하여 선형 판별 분석(LDA)과 SVM의 조합을 제안하였다. Polat 및 Güler은 279개의 특징을 5개로 감소시키는 PCA를 이용한 최소 자승 SVM(LS-SVM)을 제안하였다. Melgani 및 Bazi는 분류기에 대한 입자 군집 최적화(particle swarm optimization, PSO)와 함께 SVM을 제안하였으며, 그 결과를 K-nearest neighbor(K-NN) 및 radial basis function(RBF) 신경망 분류기와 비교하였다. 그 결과, 6가지 서로 다른 부정맥을 이용하여 89.72%의 전체적인 정확도를 달성하였다. Dutta 등은 LS-SVM 분류기를 이용한 교차-상관 관계 기반 특징 추출 방법을 제안하였다. Deasi 등은 특징 추출을 위한 이산 웨이블릿 변환(DWT) 및 특징 감소 방법인 독립 성분 분석(ICA)을 이용하여 SVM 분류기로 5가지 서로 다른 부정맥을 검출하는 방법을 제안하였다. 위 종래기술들 이외에, 또 다른 종래기술 또한, SVM 분류기를 ECG 부정맥 검출에 적용하였다.
- [0005] FFNN 및 SVM 이외에 다양한 기계 학습 기술이 분류기로 사용되었다. 종래기술 Übeyli는 고유 벡터 기반 특징 추출 방법을 가지는 재귀 신경망(RNN) 분류기를 제안하였다. 그 결과, 이 모델은 4가지 서로 다른 부정맥을 사용하여 98.06%의 평균 정확도를 달성하였다. Kumar 및 Kumaraswany 는 RR 간격만을 분류 특징으로 사용하는 랜덤 포레스트 트리(RFT)를 분류기로 제안하였다. K-nearest neighbor(K-NN) 또한, 부정맥 분류에 대한 유명한 분류기이다. Park 등은 17가지 유형의 ECG 박동 검출을 위해 K-NN 분류기를 제안하였으며, 이 방법은 97.1%의 민감도 및 98.9%의 정확도를 달성하였다. Jun 등은 고속 부정맥 검출을 위해 제안된 병렬 K-NN 분류기를 제안하였다. 본 논문과 관련하여, Kiranyaz 등은 ECG 부정맥 분류를 위한 1차원 컨볼루션 신경망(CNN)을 소개하였다. CNN 분류기를 사용하는 점에서 유사한 측면이 있으나, 우리의 방법은 CNN을 2차원 ECG 이미지에 적용하는 반면, Kiranyaz의 방법은 CNN을 1차원 ECG에 적용하는 차이가 존재하며, 이러한 차이로 인하여 우리 방법이 성능 측면에서 더 우수하다.
- [0006] 전술된 바와 같이 ECG 부정맥 분류에 대한 많은 수의 종래기술들이 제안되었으나, 이 종래기술들은 아래와 같은 제한들을 하나 이상 가지고 있다: 1) 교차-유효성 검사 없이 신중하게 선택된 ECG 기록의 우수한 성능, 2) 노이즈 필터링 및 특징 추출 방식에서의 ECG 박동 손실, 3) 분류를 위한 ECG 부정맥 유형의 제한된 수, 4) 실제 환경에 적용하기에 상대적으로 낮은 분류 성능.

발명의 내용

해결하려는 과제

[0007] 본 발명이 이루고자 하는 기술적 과제는 최근 패턴 인식 분야에서 뛰어난 성능을 보여주는 심층 2차원 컨볼루션 신경망(CNN)을 이용하여 ECG 부정맥을 효율적으로 분류하는 방법 및 장치를 제공하는데 있다. 모든 ECG 박동(beat)은 CNN 분류기의 입력으로서 2차원 그레이 스케일 이미지로 변환된다. 제안된 CNN 분류기의 최적화는 일괄 정규화(batch normalization), 데이터 증대(data augmentation), Xavier 초기화 및 드롭 아웃 등과 같은 다양한 심층 학습 기법을 포함한다. 또한, 제안된 분류기를 잘 알려진 두 개의 분류기(AlexNet 및 VGGNet)와 비교한다. MIT-BIH 부정맥 데이터베이스의 심전도 기록을 제안된 분류기 평가에 이용하였다.

과제의 해결 수단

[0008] 일 측면에 있어서, 본 발명에서 제안하는 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법은 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계 및 학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계를 포함한다.

[0009] 상기 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계는 부정맥 유형은 각 ECG 신호의 R-웨이브 피크 타임에서 라벨링되고, 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 미리 정해진 복수 개의 마지막 ECG 신호를 제외하고 W-웨이브 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의한다.

[0010] 상기 CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계는 학습 기법 중 그래디언트 디센트 기반 학습을 이용하고, 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키는 단계, 그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하는 단계, 그래디언트 디센트 기반 학습의 모델 내 커널 가중치의 출력 값을 정의 하는 단계, 그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하는 단계, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타내는 단계 및 검사 세트를 이용하여 그래디언트 디센트 기반 학습의 모델이 트레이닝 세트에서 미리 정해진 정확도에 도달하는 지를 판단하는 단계를 포함한다.

[0011] 상기 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키는 단계는 2차원 ECG 이미지를 입력 데이터로 정의하여 자르기 및 리사이징을 통해 이미지를 수정하여 트레이닝 세트를 확장시키고, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지한다.

[0012] 상기 2차원 ECG 이미지를 보강하는 방식은 왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래의 서로 다른 자르기 방법을 이용하여 PVC, PAB, RBB, LBB, APC, VFW, VEB를 포함하는 보강 방식을 이용하여 복수의 ECG 부정맥 박동을 보강한다.

[0013] 상기 그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하는 단계는 모든 커널에서 그래디언트의 비율을 대략 동일하게 유지하는 Xavier 초기화를 이용하고, 미리 정해진 범위에서 랜덤하게 초기화된다.

[0014] 상기 그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하는 단계는 입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동되며, 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용되고, 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성화 함수 직후에 배치 정규화 레이어를 적용한다.

[0015] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 장치는 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 전처리부 및 학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 ECG 부정맥 분류부를 포함한다.

[0016] 상기 전처리부는 부정맥 유형은 각 ECG 신호의 R-웨이브 피크 타임에서 라벨링되고, 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 미리 정해진 복수 개의 마지막 ECG 신호를 제외하고 W-웨이브 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의한다.

- [0017] 상기 ECG 부정맥 분류부는 학습 기법 중 그레디언트 디센트 기반 학습을 이용하고, 그레디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키고; 그레디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하고; 그레디언트 디센트 기반 학습의 모델 내 커널 가중치의 출력 값을 정의 하고; 그레디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하고; 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타내고; 및 검사 세트를 이용하여 그레디언트 디센트 기반 학습의 모델이 트레이닝 세트에서 미리 정해진 정확도에 도달하는 지를 판단한다.
- [0018] 상기 ECG 부정맥 분류부는 2차원 ECG 이미지를 입력 데이터로 정의하여 자르기 및 리사이징을 통해 이미지를 수정하여 트레이닝 세트를 확장시키고, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지한다.
- [0019] 상기 2차원 ECG 이미지를 보강하는 방식은 왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래의 서로 다른 자르기 방법을 이용하여 PVC, PAB, RBB, LBB, APC, VFW, VEB를 포함하는 보강 방식을 이용하여 복수의 ECG 부정맥 박동을 보강한다.
- [0020] 상기 ECG 부정맥 분류부는 모든 커널에서 그레디언트의 비율을 대략 동일하게 유지하는 Xavier 초기화를 이용하고, 미리 정해진 범위에서 랜덤하게 초기화된다.
- [0021] 상기 ECG 부정맥 분류부는 입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동되며, 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용되고, 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성화 함수 직후에 배치 정규화 레이어를 적용한다.

발명의 효과

- [0022] 본 발명의 실시예들에 따르면 최근 패턴 인식 분야에서 뛰어난 성능을 보여주는 심층 2차원 컨볼루션 신경망(CNN)을 이용하여 ECG 부정맥을 효율적으로 분류하는 방법을 제안한다. 모든 ECG 박동(beat)은 CNN 분류기의 입력으로서 2차원 그레이 스케일 이미지로 변환한다. 제안된 CNN 분류기의 최적화는 일괄 정규화(batch normalization), 데이터 증대(data augmentation), Xavier 초기화 및 드롭 아웃 등과 같은 다양한 심층 학습 기법을 포함한다. 또한, 제안된 분류기를 잘 알려진 두 개의 분류기(AlexNet 및 VGGNet)와 비교하고, MIT-BIH 부정맥 데이터베이스의 심전도 기록을 제안된 분류기 평가에 이용한다. 결과적으로, 제안된 분류기는 99.05%의 평균 정확도와 97.85%의 평균 민감도를 달성하였다. 제안된 CNN 분류기를 정확하게 평가하기 위해, 모든 ECG 기록을 테스트 데이터로 포함하여 교차 평가를 10회 진행하였다. 변환된 ECG 이미지를 가지는 제안된 CNN 분류기는 노이즈 필터링, 특징 추출 및 특징 감소 등과 같은 수동적인 사전 프로세싱 없이도 매우 정확한 분류 성능을 제공할 수 있음이 실험 결과로 나타났다.

도면의 간단한 설명

- [0023] 도 1은 본 발명의 일 실시예에 따른 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 장치를 설명하기 위한 도면이다.
- 도 2는 본 발명의 일 실시예에 따른 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법을 설명하기 위한 흐름도이다.
- 도 3은 본 발명의 일 실시예에 따른 ECG 데이터 전처리 방식에서 얻어진 ECG 박동의 8가지 유형을 나타내는 도면이다.
- 도 4는 본 발명의 일 실시예에 따른 CNN 모델의 전체 구조를 나타내는 도면이다.
- 도 5는 본 발명의 일 실시예에 따른 PVC를 가지는 오리지널 이미지의 잘린 이미지에 대한 9가지 예시를 나타내는 도면이다.
- 도 6은 본 발명의 일 실시예에 따른 CNN 모델 구조를 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

- [0024] 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

- [0026] 도 1은 본 발명의 일 실시예에 따른 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 장치를 설명하기 위한 도면이다.
- [0027] 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 장치는 전처리부(110) 및 ECG 부정맥 분류부(120)를 포함한다. 부정맥 유형은 각 ECG 신호의 R-웨이브 피크 타임에서 라벨링되고, 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 미리 정해진 복수 개의 마지막 ECG 신호, 예를 들어 마지막 20개의 ECG 신호를 제외하고 W-웨이브 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의한다.
- [0028] 전처리부(110)는 1차원 ECG 신호를 2차원 ECG 이미지로 변환하고, ECG 부정맥 분류부(120)는 학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행한다.
- [0029] 본 발명의 실시예에 따르면, 그레이 스케일 ECG 이미지를 가지는 심층 2차원 CNN을 사용하여 ECG 부정맥을 분류하는 방법을 제안한다. 전처리부(110)를 통해 1차원 ECG 신호(111)를 2차원 ECG 이미지(112)로 변환함으로써, 노이즈 필터링 및 특징 추출이 필요하지 않게 되고, 데이터 및 정보를 획득할 수 있다. 노이즈 필터링 및 특징 추출 과정에서 ECG 박동이 무시될 수 있으므로, 이러한 특징은 매우 중요하다.
- [0030] ECG 부정맥 분류부(120)는 학습 기법 중 그래디언트 디센트 기반 학습을 이용하고, 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시킨다. 2차원 ECG 이미지를 입력 데이터로 정의하여 자르기 및 리사이징을 통해 이미지를 수정하여 트레이닝 세트를 확장시키고, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지한다. 2차원 ECG 이미지를 보강하는 방식은 왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래의 서로 다른 자르기 방법을 이용하여 PVC, PAB, RBB, LBB, APC, VFW, VEB를 포함하는 보강 방식을 이용하여 복수의 ECG 부정맥 박동을 보강한다.
- [0031] 그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하고, 모든 커널에서 그래디언트의 비율을 대략 동일하게 유지하는 Xavier 초기화를 이용하고, 미리 정해진 범위에서 랜덤하게 초기화한다.
- [0032] 그래디언트 디센트 기반 학습의 모델 내 커널 가중치의 출력 값을 정의한다.
- [0033] 그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화(121)를 수행한다. 입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동되며, 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용되고, 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성화 함수 직후에 배치 정규화 레이어를 적용한다.
- [0034] 표준화라고도 불리는 정규화는 트레이닝 단계에서의 오버피팅을 감소시키는 방법이다. 전형적인 정규화 방법은 L1 및 L2 정규화이지만, 최근 CNN 모델(122)에서는 드롭 아웃 및 배치(batch) 정규화를 적용하는 것이 일반적이다.
- [0035] 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타낸다. 그리고, 검사기준(124)에 따른 트레이닝 & 검사세트(123)를 이용하여 그래디언트 디센트 기반 학습의 모델이 트레이닝 세트에서 미리 정해진 정확도에 도달하는 지를 판단한다.
- [0036] 이후, 테스트세트(125)에 따른 분류 결과(126)를 나타내고, 이때 10-폴드 크로스 검사(127)를 이용한다.
- [0037] 다시 말해, ECG 부정맥 분류부(120)를 통해 ECG 이미지를 보강하여 트레이닝 데이터를 확장함으로써 더욱 높은 분류 정확성을 달성할 수 있다. 1차원 ECG 신호의 왜곡은 분류기의 성능을 저하시킬 수 있으므로, 종래기술에 따른 방법들에서는 데이터를 확장하기 어려웠다. 그러나 다른 자르기(cropping) 방법을 이용하여 2차원 ECG 이미지를 보강하면, CNN 모델을 단일 ECG 이미지의 서로 다른 시점으로 트레이닝시키는 데 도움이 된다. ECG 이미지를 ECG 부정맥 분류부(120)의 입력 데이터로 이용하면, 강건함 측면에서 도움이 된다. 모든 ECG 1차원 신호 값들이 분류의 동등한 정도를 가지기 때문에, 현재의 ECG 부정맥 검출 방법들은 노이즈 신호에 민감하다. 그러나 ECG 신호가 2차원 이미지로 변환될 때, 제안된 CNN 모델은 컨볼루션 및 풀링 레이어 전체에서 관련 특징 맵을 추출하는 동안 노이즈 데이터를 자동적으로 무시할 수 있다. 따라서 문헌들에서 제안된 이전 방법들이 서로 다른 장치에서 서로 다른 모델링을 필요로 하는 반면, 제안된 CNN 모델은 서로 다른 샘플링 속도 및 크기를 가지는 다양한 ECG 장치의 ECG 신호에 적용될 수 있다. 나아가, 의학 전문가들은 연속되는 ECG 이미지를 보여주는 모니터를 통하여 환자의 ECG 그래프를 관찰하므로, ECG 이미지를 이용하여 ECG 부정맥을 검출하는 것은 의학 진

문가들이 이용하는 방법과 유사하다. 달리 말하면, 제안된 방법은 ECG 신호를 모니터링하는 의학 로봇에 적용될 수 있으며, 의학 전문가들이 ECG 부정맥을 보다 정확하게 확인하는 데 도움을 줄 수 있다.

- [0039] 도 2는 본 발명의 일 실시예에 따른 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법을 설명하기 위한 흐름도이다.
- [0040] 제안하는 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법은 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계(210) 및 학습 기법을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 오버피팅을 감소시키기 위한 정규화를 수행하여 트레이닝 데이터를 확장하며, 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계(220, 썩, 270)를 포함한다.
- [0041] 상기 1차원 ECG 신호를 2차원 ECG 이미지로 변환하는 단계(210)는 부정맥 유형은 각 ECG 신호의 R-웨이브 피크 타임에서 라벨링되고, 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 미리 정해진 복수 개의 마지막 ECG 신호, 예를 들어 마지막 20개의 ECG 신호를 제외하고 W-웨이브 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의한다.
- [0042] 상기 CNN분류기를 통해 복수의 ECG 유형에 대한 분류를 수행하는 단계(220, 썩, 270)는 학습 기법 중 그래디언트 디센트 기반 학습을 이용하고, 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키는 단계(220), 그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하는 단계(230), 그래디언트 디센트 기반 학습의 모델 내 커널 가중치의 출력 값을 정의 하는 단계(240), 그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하는 단계(250), 목적함수를 이용하여 신경망이 트레이닝된 정도를 측정하고, 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타내는 단계(260) 및 검사 세트를 이용하여 그래디언트 디센트 기반 학습의 모델이 트레이닝 세트에서 미리 정해진 정확도에 도달하는 지를 판단하는 단계(270)를 포함한다.
- [0043] 상기 그래디언트 디센트 기반 학습을 이용하여 변환된 2차원 ECG 이미지를 보강하고, 트레이닝 세트를 확장시키는 단계(220)는 2차원 ECG 이미지를 입력 데이터로 정의하여 자르기 및 리사이징을 통해 이미지를 수정하여 트레이닝 세트를 확장시키고, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지한다.
- [0044] 상기 2차원 ECG 이미지를 보강하는 방식은 왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래의 서로 다른 자르기 방법을 이용하여 PVC, PAB, RBB, LBB, APC, VFW, VEB를 포함하는 보강 방식을 이용하여 복수의 ECG 부정맥 박동을 보강한다.
- [0045] 상기 그래디언트 디센트 기반 학습의 모델이 수렴하도록 하기 위해 커널 가중치를 초기화하는 단계(230)는 모든 커널에서 그래디언트의 비율을 대략 동일하게 유지하는 Xavier 초기화를 이용하고, 미리 정해진 범위에서 랜덤하게 초기화된다.
- [0046] 상기 그래디언트 디센트 기반 학습에 따른 내부 공변량을 감소시키고, 트레이닝 단계에서의 오버피팅을 감소시키기 위한 정규화를 수행하는 단계(250)는 입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동되며, 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용되고, 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성화 함수 직후에 배치 정규화 레이어를 적용한다.
- [0047] 다시 말해, 제안하는 분류 방법은 아래와 같은 단계들을 포함한다: 데이터 획득, ECG 데이터 전처리 및 CNN 분류기. 본 발명에서 다루지는 ECG 신호 데이터는 ECG 부정맥 분류 연구에서 일반적으로 사용되는 부정맥 데이터 베이스인 MIT-BIH 데이터 베이스에서 얻어진다. 제안하는 CNN 모델은 2차원 이미지를 입력으로 필요로 하므로, 이 ECG 기록을 사용하여 모든 단일의 ECG 박동을 128x128 그레이 스케일 이미지로 변환한다. 이전 ECG 부정맥 분류와 달리, 제안하는 방법에서 입력 데이터는 정확한 단일 박동으로 분류될 필요가 없다. 달리 말하면, 비록 이전 및 이후 박동의 추가 신호가 이미지에 존재하더라도, 제안하는 CNN 모델은 이 모델을 학습할 때 노이즈 데이터를 자동적으로 무시할 수 있다. 마지막으로, CNN 분류기는 아래와 같은 ECG 박동의 8가지 서로 다른 유형을 분류하기 위해 최적화된다: 정상 박동(NOR), 조기 심실 수축 박동(PVC), paced 박동(PAB), right bundle branch block beat (RBB), left bundle branch, block beat (LBB), atrial premature contraction beat(APC), ventricular flutter wave beat (VFW), 및 ventricular escape beat (VEB). MIT-BIH 데이터 베이스 내 ECG 신호 대부분이 정상 박동이기 때문에, 트레이닝 단계에서 9가지 서로 다른 방법으로 이미지를 잘라 7개의 다른 부정맥 박동을 보강하였다. 제안된 보강 방법을 이용함으로써 CNN 모델에 대한 추가적인 수정 없이 조기수축박동

(premature contraction beat), 심실조동파형(ventricular flutter wave), 및 심실보충수축(ventricular escape beat) 등의 세 가지 부정맥 유형에서 5% 이상의 가중 평균 민감도를 달성하였다. 데이터 보강에 추가하여, 일괄 정규화(batch normalization), 데이터 증대(data augmentation), Xavier 초기화 및 드롭 아웃 등과 같은 최신의 심층 학습 기법을 이용하여 CNN 모델을 최적화하였다. 제안된 분류기의 성능은 하이-엔드 NVIDIA GPU를 지원하는 TensorFlow를 사용하여 평가되었다. 테스트 데이터로서 모든 ECG 기록을 포함하는 제안된 분류기를 더욱 정확하게 검사하기 위해 10회 교차 검사 방법이 적용되었으며, 그 결과, CNN 분류기는 99.05%의 평균 정확도, 99.57%의 특정성(specificity), 97.85%의 평균 민감도 및 98.55%의 평균 양성 예측치를 달성하였다. 도 3 내지 도 6을 참조하여, 심층 컨볼루션 신경망을 이용한 심전도 부정맥 분류 방법 및 장치에 대하여 더욱 상세히 설명한다.

[0048] 제안하는 CNN 기반 ECG 부정맥 분류는 아래와 같은 단계들을 포함한다: ECG 데이터 전처리 및 ECG 부정맥 분류. 본 발명에서는 CNN 모델의 트레이닝과 테스트를 위해 MIN-BIH 부정맥 데이터 베이스를 이용하였다. CNN 모델은 2차원 이미지를 입력 데이터로 하므로, ECG 데이터 전처리 단계에서 ECG 신호가 ECG 이미지로 변환된다. 이러한 과정을 거쳐 ECG 이미지가 얻어지면, CNN 분류기 단계에서 8가지의 ECG 유형에 대한 분류가 수행된다. 전체적인 과정은 도 1에 도시되어 있다.

[0050] 먼저, ECG 데이터 전처리 과정에 대하여 설명한다.

[0051] 2차원 CNN은 입력 데이터로 이미지를 필요로 한다. 따라서 각 ECG 박동을 개별적인 128x128 그레이 스케일 이미지로 도시하여 ECG 신호를 ECG 이미지로 변환하였다. MIN-BIH 부정맥 데이터 베이스에서, 모든 ECG 박동은 R-웨이브 피크 타입에 기반하여 슬라이스된다(sliced). 보다 구체적으로, 부정맥 유형은 각 ECG 박동의 R-웨이브 피크 타입에서 라벨링된다. 따라서 이전 및 이후의 R-웨이브 피크 신호에서 첫 번째 및 마지막 20개의 ECG 신호를 제외하고 W-wave 피크 신호를 센터링함으로써 단일 ECG 이미지를 정의하였다. 시간 변환에 기반하여, 단일 ECG 박동 범위가 다음과 같이 정의될 수 있다:

[0052]
$$T(Qpeak(n - 1) + 20) \leq T(n) \leq T(Qpeak(n + 1) - 20) \quad (1)$$

[0054] 도 3은 본 발명의 일 실시예에 따른 ECG 데이터 전처리 방식에서 얻어진 ECG 박동의 8가지 유형을 나타내는 도면이다.

[0055] 위에서 설명한 바와 같이, ECG 데이터 전처리 과정을 통해 결과적으로 MIT-BIH 부정맥 데이터 베이스에서 100,000개의 이미지를 얻었으며, 각 이미지는 8가지 ECG 박동 유형 중 하나이다. 도 3은 128x128 그레이 스케일을 가지며 ECG 데이터 전처리 방식에서 얻어진 ECG 박동의 8가지 유형을 나타낸다.

[0057] 도 4는 본 발명의 일 실시예에 따른 CNN 모델의 전체 구조를 나타내는 도면이다.

[0058] 다음으로, ECG 부정맥 분류과정에 대하여 설명한다. 본 발명에서는 ECG 분류부를 통해 CNN을 적용하였다. CNN은 LeCun 등에 의해 1980년에 처음 소개되었으며, 손으로 쓰여진 zip) 코드를 인식하기 위한 프로젝트를 통해 발전하였다. 기존의 피드-포워드 신경망(feed-forward neural network)은 이미지의 토폴로지를 고려하지 않고 원시 이미지가 직접 처리되기 때문에 자유 파라미터의 수가 지수적으로 증가하므로 이미지 분류에 적합하지 않다. CNN 모델의 출현으로 인하여, 공간적으로 인접한 픽셀의 상관 관계가 비선형 필터의 적용 및 다중 필터의 적용을 통하여 추출됨으로써 이미지의 다양한 로컬 특징을 추출할 수 있다. 본 논문에서 ECG 신호를 ECG 이미지 형식으로 변환하여 2차원 CNN을 적용하는 이유는 2차원 컨볼루션 및 풀링 레이어가 ECG 이미지의 공간적 지역성을 필터링하는 데 좀 더 적합하기 때문이다. 결과적으로, 더 높은 ECG 부정맥 분류 정확성이 얻어질 수 있다. 또한, 의사는 눈을 통한 시각적인 진단을 통하여 환자의 ECG 신호 내 부정맥을 판단한다. 따라서 2차원 CNN 모델을 ECG 이미지에 적용하는 것은 의사의 부정맥 판단 방법과 거의 유사하다.

[0059] 주어진 이미지 세트에서 대상을 검출하고 분류하기 위한 성공적인 CNN 모델이 다수 존재한다. 2012년에 발표된 AlexNet은 ILSVRC에 CNN 모델과 GPU를 사용하는 첫 번째 모델로서 압도적인 성능으로 인하여 1위를 차지하였다. 2014년에, GoogLeNet 및 VGGNet은 ILSVRC에서 각각 1위와 2위를 차지하였다. 비록, VGGNet가 2위를 차지하였다고 하더라도, VGGNet는 구조가 훨씬 간단하고 성능이 GoogLeNet과 크게 다르지 않기 때문에 3x3 필터와 하위 샘플

플링이 반복하는 VGGNet 구조가 이미지 인식에 더 자주 사용된다. 최근에 나타난 ResNet 및 DenseNet은 CNN 모델의 심도가 더 깊어질수록 이미지의 초기 특징이 최종 출력에 미치는 영향이 작다는 문제를 해결하기 위하여 제안되었다. 본 발명에서는 ECG 부정맥 분류에 대한 최적의 성능을 달성하기 위해 VGGNet의 기본 구조를 따르며 CNN 모델을 최적화한다. 제안된 CNN 모델의 성능을 AlexNet 및 VGGNet와 비교하는 반면, GoogLeNet, ResNet 및 DenseNet와는 비교하지 않는다. 본 발명의 ECG 이미지는 128x128 그레이 스케일 이미지이므로 심층 심도 레이어를 가질 필요가 없고 오버피팅 및 성능 저하를 발생시키는 자유 파라미터의 증가가 존재하지 않기 때문이다. 도 4는 제안된 CNN 모델의 전체 구조를 보여준다.

[0061] 도 5는 본 발명의 일 실시예에 따른 PVC를 가지는 오리지널 이미지의 잘린 이미지에 대한 9가지 예시를 나타내는 도면이다.

[0062] 다음으로, 데이터 보강에 대하여 설명한다.

[0063] 데이터 보강은 이미지를 입력 데이터로 이용하는 중요한 이점 중 하나이다. 이전 ECG 부정맥 연구의 대부분은 단일 ECG 신호 값의 왜곡으로 인하여 테스트 세트의 성능이 저하될 수 있으므로 보강된 데이터를 트레이닝 세트에 수동으로 추가할 수 없었다. CNN과 달리, SVM, FFNN 및 트리-기반 알고리즘 등과 같은 다른 분류기들은 각 ECG 신호 값이 분류의 동등한 가치를 가진다고 가정하기 때문이다. 그러나 우리의 CNN 모델은 2차원 ECG 이미지를 입력 데이터로 정의하기 때문에 자르기 및 리사이징을 통해 이미지를 수정하는 것이 성능을 저하시키지 않음은 물론, 트레이닝 세트를 확장시킨다. CNN이 분류기로 사용되는 경우, 데이터 보강은 오버피팅을 효과적으로 감소시키며 클래스들 간에 균형 잡힌 분산을 유지시킨다. 의료 데이터의 대부분이 정상적이며 소수만이 비정상적이므로 이러한 이점은 의료 데이터 분석에 매우 중요하다. 이 경우, 그레디언트 디센트(gradient descent) 학습으로 인하여, batch 내 복수의 클래스에 대응하는 정상적인 손실이 우선적으로 감소하며, 본 논문의 부정맥인 작은 클래스는 상대적으로 무시된다. 결과적으로, 트레이닝 과정에서 특이성은 매우 높은 반면, 민감도는 낮아질 수 있다. 달리 말하면, 입력 데이터를 보강하고 밸런싱(balancing)함으로써 높은 특이성과 민감도를 달성할 수 있다. 본 연구에서는 9가지의 서로 다른 자르기 방법(왼쪽 위, 중앙 위, 오른쪽 위, 중앙 왼쪽, 중앙, 중앙 오른쪽, 왼쪽 아래, 중앙 아래 및 오른쪽 아래)을 이용하여 7가지의 ECG 부정맥 박동(PVC, PAB, RBB, LBB, APC, VFW, VEB)를 보강하였다. 각 자르기 방법은 ECG 이미지의 세 가지 사이즈 중 두 가지 즉, 96x96을 만든다. 그런 다음, 보강된 이미지는 128x128의 오리지널 크기로 리사이징된다. 도 5는 PVC를 가지는 오리지널 이미지의 잘린 이미지에 대한 9가지 예를 보여준다. 이미지들을 디스크에서 복사하면 메인 메모리와 GPU 메모리 사이의 메모리 복사에 소요되는 시간이 증가되어 학습 속도가 느리게 되므로, 보강된 이미지는 모델 내부에서 생성된다.

[0064] 다음으로, 커널 초기화에 대해 설명한다.

[0065] 그레디언트 디센트 기반 학습의 주요 함정은 모델이 발산하거나 로컬 최소 지점으로 떨어질 수 있다는 것이다. 따라서 수렴하도록 하기 위해 현명한 가중치 초기화가 요구된다. CNN에서, 가중치는 커널(또는 필터)로 제시되며, 커널 그룹은 단일의 컨볼루션 레이어를 구성한다. 제안된 CNN 모델은 Xavier 초기화를 이용한다. 이 초기화기는 모든 커널에서 그레디언트의 비율을 대략 동일하게 유지한다. 가중치는 아래와 같은 범위에서 랜덤하게 초기화된다:

[0066]
$$x = \frac{\sqrt{6}}{In + Out}; [-x, x] \quad (2)$$

[0067] 위 식에서, *In* 및 *Out* 은 각각 커널 가중치에서의 입력 및 출력 유닛 수이다.

[0068] 다른 경우, CNN 모델은 일반적으로 작은 사이즈의 심도를 가지는 큰 사이즈의 커널에서 시작하여 큰 사이즈의 심도를 가지는 작은 사이즈의 커널에서 종료한다. 그러나 더 깊은 레이어를 가지는 작은 사이즈의 커널이 이전 방법보다 더 낫다는 점이 알려져 있다. 따라서 최신 CNN 분류기에 일반적으로 사용되는 3x3을 이용하여 커널 사이즈를 초기화하였다. 또한, 컨볼루션 레이어를 바이패스한 후 이미지의 원래 사이즈를 유지시키기 위하여 제로-패딩(zero-padding) 절차를 수행한다.

[0069] 다음으로, 활성화 함수에 대하여 설명한다.

[0070] 활성화 함수의 역할은 모델 내 커널 가중치의 출력 값을 정의하는 것이다. 최신의 CNN 모델에서는 ReLU(rectified linear units), LReLU(leakage rectified linear units) 및 ELU(exponential linear units) 등을 포함하는 비

선형 활성화가 널리 사용된다. 비록 ReLU가 CNN에서 널리 사용되는 활성화 함수라고 하더라도, ReLU는 전체 음의 값을 0으로 변환하여 노드가 학습에 참여하지 않게 되므로 LReLU 및 ELU는 작은 음의 값을 제공한다. 실험 후, ECG 부정맥 분류에 LReLU, ReLU, LReLU 및 ELU 보다 더 나은 성능을 보여주는 ECL를 사용하였으며, ELU는 아래와 같이 나타난다:

[0071]
$$ReLU(x) = \max(0, x) \quad (3)$$

[0072]
$$LReLU(x) = \max(0, x) + \alpha \min(0, x) \quad (4)$$

[0073]
$$ELU(x) = \begin{cases} x & \text{if } x \geq 0 \\ \gamma(\exp(x) - 1) & \text{if } x < 0 \end{cases} \quad (5)$$

[0074] 위 식에서, 누출 계수 (α) 는 0.3이며, 하이터-파라미터 (γ) 은 1.0이다.

[0075] 다음으로, 정규화에 대해 설명한다.

[0076] 표준화라고도 불리는 정규화는 트레이닝 단계에서의 오버피팅을 감소시키는 방법이다. 전형적인 정규화 방법은 L1 및 L2 정규화이지만, 최근 CNN 모델에서는 드롭 아웃 및 배치(batch) 정규화를 적용하는 것이 일반적이다. 심층 학습에서, 레이어가 더 깊어지면, 이전 레이어에서의 작은 파라미터 변화는 이후 레이어의 입력 왜곡에 큰 영향을 줄 수 있다. 이러한 현상은 내부 공변량(covariate) 변화라고 불린다. 배치 정규화는 이 내부 공변량 변화를 감소시키기 위해 제안되었으며, 입력 배치의 평균 및 분산이 정규화된 다음, 배율이 변경되고 이동된다. 배치 정규화의 위치는 일반적으로 활성화 함수 이전 및 컨볼루션 레이어 이후에 적용된다. 그러나 우리의 실험에서, 몇 가지 경우에, 배치 정규화 레이어를 활성화 함수 이후에 배치하는 것이 더 좋으며, ECG 부정맥 분류가 이 경우에 해당한다. 그러므로 우리는 컨볼루션 블록 및 완전 연결 블록을 포함하여 모델의 모든 활성화 함수 직후에 배치 정규화 레이어를 적용하였다.

[0077] 드롭아웃은 동일한 레이어의 노드에 확률적으로 참여하여 레이어들 간 종속성을 감소시킴으로써 오버피팅을 방지하는 방법이다. 트레이닝 단계에서, 드롭아웃은 학습에서 일부 네트워크를 의도적으로 제외하므로, 모델은 모델 조합에 의하여 voting 효과를 달성할 수 있다. 본 발명에서는 0.5의 확률로 드롭아웃을 적용하였으며, 이를 완전 연결 블록의 배치 정규화 레이어 이후에 위치시켰다. 컨볼루션 레이어는 많은 자유-파라미터를 가지지 않으며 노드들 사이의 상호 적응(co-adaptation)이 오버 피팅의 감소보다 중요하기 때문에, 일반적으로 드롭 아웃이 컨볼루션 블록에 적용되지 않는다.

[0078] 다음으로, 목적 함수 및 최적화 함수에 대하여 설명한다.

[0079] 목적 함수는 신경망이 트레이닝된 정도를 측정하며 주어진 트레이닝 샘플 및 예상되는 출력 사이의 차이를 나타낸다. 최적화 함수를 사용하여 목적 함수를 최소화하였다. 다양한 유형의 목적 함수가 존재하지만, 심층 학습은 전형적으로 크로스 엔트로피 함수를 사용한다.

[0080]
$$C = -\frac{1}{n} \sum [y \ln a + (1 - y) \ln(1 - a)] \quad (6)$$

[0081] 위 식에서, n 은 트레이닝 데이터(또는 배치 사이즈)의 수이고, y 는 예상 값이며, a 는 출력 레이어로부터의 실제 값이다.

[0082] 목적 함수를 최소화하기 위해, 학습 률을 가지는 그레디언트 디센트 기반 최적화 함수가 사용되었다. Adam, Adagrad 및 Adadelta 등과 같은 잘 알려진 최적화 함수가 존재한다. 전술된 함수들 사이의 최종 성능 차이는 크지 않지만, 우리의 실험에서는 Adam이 사용되었을 때 가장 최적의 지점에 도달하는 것으로 나타났다. 그 결과, 우리는 1,000 단계 당 0.001 과 0.95의 초기 학습 률로 Adam 최적화 함수를 사용하였다.

[0083] 본 발명의 실시예에 따른 CNN 모델에서는 0.95의 감쇠율로 1,000 감쇠 단계마다 기하급수적으로 학습률을 감소시켜 0.0001 시작 학습률을 가지는 Adam 최적화 함수를 적용하였다. 주어진 전체 단계에서의 학습률은 아래와 같이 계산될 수 있다:

[0085] $LearningRate = LearningRate_0 * 0.95^{\lceil (GlobalStep/1,000) \rceil}$ (7)

[0087] 검사 세트는 주어진 모델이 트레이닝 세트에서 충분한 정확도에 도달하는 지를 판단하기 위해 사용되었다. 검사 절차가 없는 경우, 모델은 오버피팅될 수 있다. 일반적으로, CNN에 대한 검사 기준으로 손실 값이다. 하지만, 본 발명의 실시예에 따른 관찰에 따르면, 손실 값에 기초하여 모델을 조기에 멈추게 하면 7가지 부정맥 분류에서 더 높은 민감도를 달성할 수 있다. 따라서 검사 세트의 평균 민감도를 상기 검사 기준으로 설정하였다. 지난 500개의 전체 단계에서 가장 평균 민감도가 증가하지 않는 경우, 학습 절차를 중단시키고 테스트 세트로 평가를 시작한다.

[0089] 도 6은 본 발명의 일 실시예에 따른 CNN 모델 구조를 나타내는 도면이다.

[0090] 도 6은 최적화된 CNN 분류기 구조이다. 전술된 절차를 고려하여, ECG 부정맥 분류에 대한 CNN 모델을 설계하였다. CNN 모델의 주요 구조는 오버피팅을 감소시키고 분류 정확도를 향상시키기 위해 다양한 함수를 최적화하는 VGGNet와 유사하다. 테이블 1 및 도 6은 제안된 CNN 모델 구조를 상세히 설명한다. 제안된 CNN 모델이 AlexNet 및 VGGNet과 비교되었기 때문에, 테이블 2 및 3은 ECG 부정맥 분류에 배포한 AlexNet 및 VGGNet의 구조를 나타낸다.

[0092] [표 1]

| | Type | Kernel size | Stride | # Kernel | Input size |
|---------|--------|-------------|--------|----------|----------------|
| Layer1 | Conv2D | 3 x 3 | 1 | 64 | 128 x 128 x 1 |
| Layer2 | Conv2D | 3 x 3 | 1 | 64 | 128 x 128 x 64 |
| Layer3 | Pool | 2 x 2 | 2 | | 128 x 128 x 64 |
| Layer4 | Conv2D | 3 x 3 | 1 | 128 | 64 x 64 x 64 |
| Layer5 | Conv2D | 3 x 3 | 1 | 128 | 64 x 64 x 128 |
| Layer6 | Pool | 2 x 2 | 2 | | 64 x 64 x 128 |
| Layer7 | Conv2D | 3 x 3 | 1 | 256 | 32 x 32 x 128 |
| Layer8 | Conv2D | 3 x 3 | 1 | 256 | 32 x 32 x 256 |
| Layer9 | Pool | 2 x 2 | 2 | | 32 x 32 x 256 |
| Layer10 | Full | | | 2048 | 16 x 16 x 256 |
| Layer11 | Out | | | 8 | 2048 |

[0093]

[0095] [표 2]

| | Type | Kernel size | Stride | # Kernel | Input size |
|---------|--------|-------------|--------|----------|----------------|
| Layer1 | Conv2D | 11 x 11 | 1 | 3 | 128 x 128 x 1 |
| Layer2 | Conv2D | 5 x 5 | 1 | 48 | 128 x 128 x 3 |
| Layer3 | Pool | 3 x 3 | 2 | | 128 x 128 x 48 |
| Layer4 | Conv2D | 3 x 3 | 1 | 128 | 63 x 63 x 48 |
| Layer5 | Pool | 3 x 3 | 2 | | 31 x 31 x 128 |
| Layer6 | Conv2D | 3 x 3 | 1 | 192 | 31x 31 x 128 |
| Layer7 | Conv2D | 3 x 3 | 1 | 192 | 31 x 31 x 192 |
| Layer8 | Conv2D | 3 x 3 | 1 | 128 | 31 x 31 x 192 |
| Layer9 | Pool | 3 x 3 | 2 | | 31 x 31 x 128 |
| Layer10 | Full | | | 2048 | 15 x 15 x 128 |
| Layer10 | Full | | | 2048 | 2048 |
| Layer11 | Out | | | 8 | 2048 |

[0096]

[0098] [표 3]

| | Type | Kernel size | Stride | # Kernel | Input size |
|---------|--------|-------------|--------|----------|----------------|
| Layer1 | Conv2D | 3 x 3 | 1 | 64 | 128 x 128 x 1 |
| Layer2 | Conv2D | 3 x 3 | 1 | 64 | 128 x 128 x 64 |
| Layer3 | Pool | 2 x 2 | 2 | | 128 x 128 x 64 |
| Layer4 | Conv2D | 3 x 3 | 1 | 128 | 64 x 64 x 64 |
| Layer5 | Conv2D | 3 x 3 | 1 | 128 | 64 x 64 x 128 |
| Layer6 | Pool | 2 x 2 | 2 | | 64x64x128 |
| Layer7 | Conv2D | 3 x 3 | 1 | 256 | 32 x 32 x 128 |
| Layer8 | Conv2D | 3 x 3 | 1 | 256 | 32 x 32 x 256 |
| Layer9 | Conv2D | 3 x 3 | 1 | 256 | 32 x 32 x 256 |
| Layer10 | Pool | 2 x 2 | 2 | | 32 x 32 x 256 |
| Layer11 | Conv2D | 3 x 3 | 1 | 512 | 16 x 16 x 256 |
| Layer12 | Conv2D | 3 x 3 | 1 | 512 | 16 x 16 x 512 |
| Layer13 | Conv2D | 3 x 3 | 1 | 512 | 16 x 16 x 512 |
| Layer14 | Pool | 2 x 2 | 2 | | 8 x 8 x 512 |
| Layer15 | Full | | | 2048 | 8 x 8 x 512 |
| Layer16 | Full | | | 2048 | 2048 |
| Layer17 | Out | | | 8 | 2048 |

[0099]

[0101] 위에서 설명한 바와 같이, 본 발명의 실시예들에 따르면 최근 패턴 인식 분야에서 뛰어난 성능을 보여주는 심층 2차원 컨볼루션 신경망(CNN)을 이용하여 ECG 부정맥을 효율적으로 분류하는 방법을 제안한다. 모든 ECG 박동(beat)은 CNN 분류기의 입력으로서 2차원 그레이 스케일 이미지로 변환한다. 제안된 CNN 분류기의 최적화는 일괄 정규화(batch normalization), 데이터 증대(data augmentation), Xavier 초기화 및 드롭 아웃 등과 같은 다양한 심층 학습 기법을 포함한다. 또한, 제안된 분류기를 잘 알려진 두 개의 분류기(AlexNet 및 VGGNet)와 비교하고, MIT-BIH 부정맥 데이터베이스의 심전도 기록을 제안된 분류기 평가에 이용한다. 결과적으로, 제안된 분류기는 99.05%의 평균 정확도와 97.85%의 평균 민감도를 달성하였다. 제안된 CNN 분류기를 정확하게 평가하기 위

해, 모든 ECG 기록을 테스트 데이터로 포함하여 교차 평가를 10회 진행하였다. 변환된 ECG 이미지를 가지는 제안된 CNN 분류기는 노이즈 필터링, 특징 추출 및 특징 감소 등과 같은 수동적인 사전 프로세싱 없이도 매우 정확한 분류 성능을 제공할 수 있음이 실험 결과로 나타났다.

[0103] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPA(field programmable array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0104] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embodiment)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

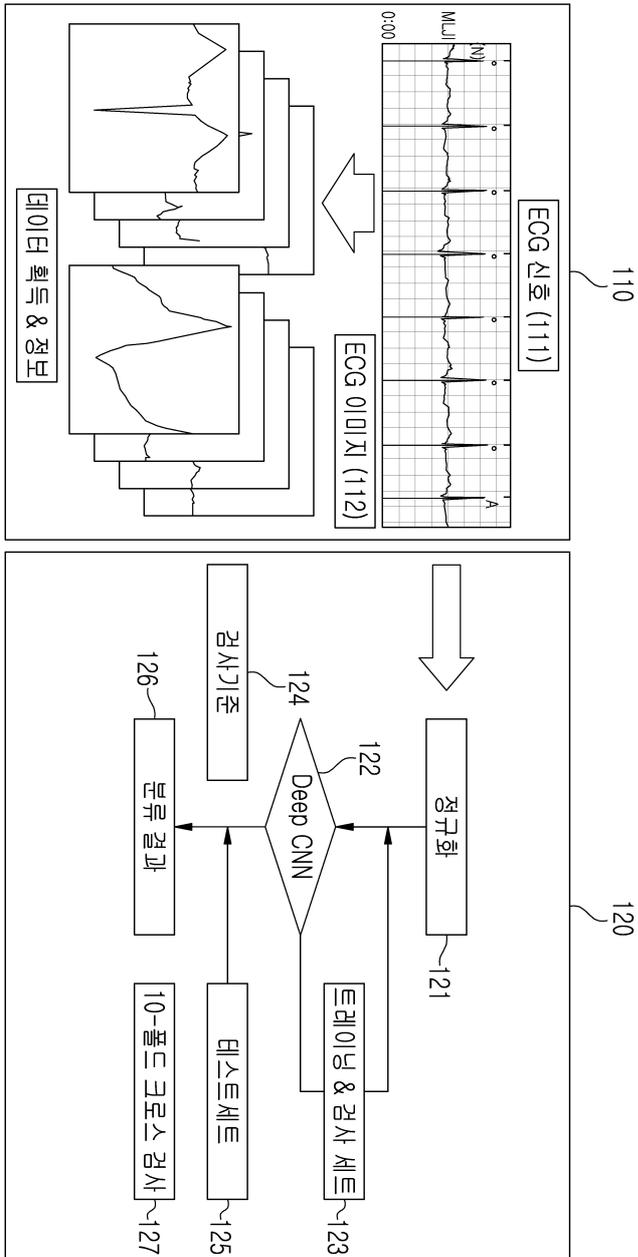
[0105] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0106] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

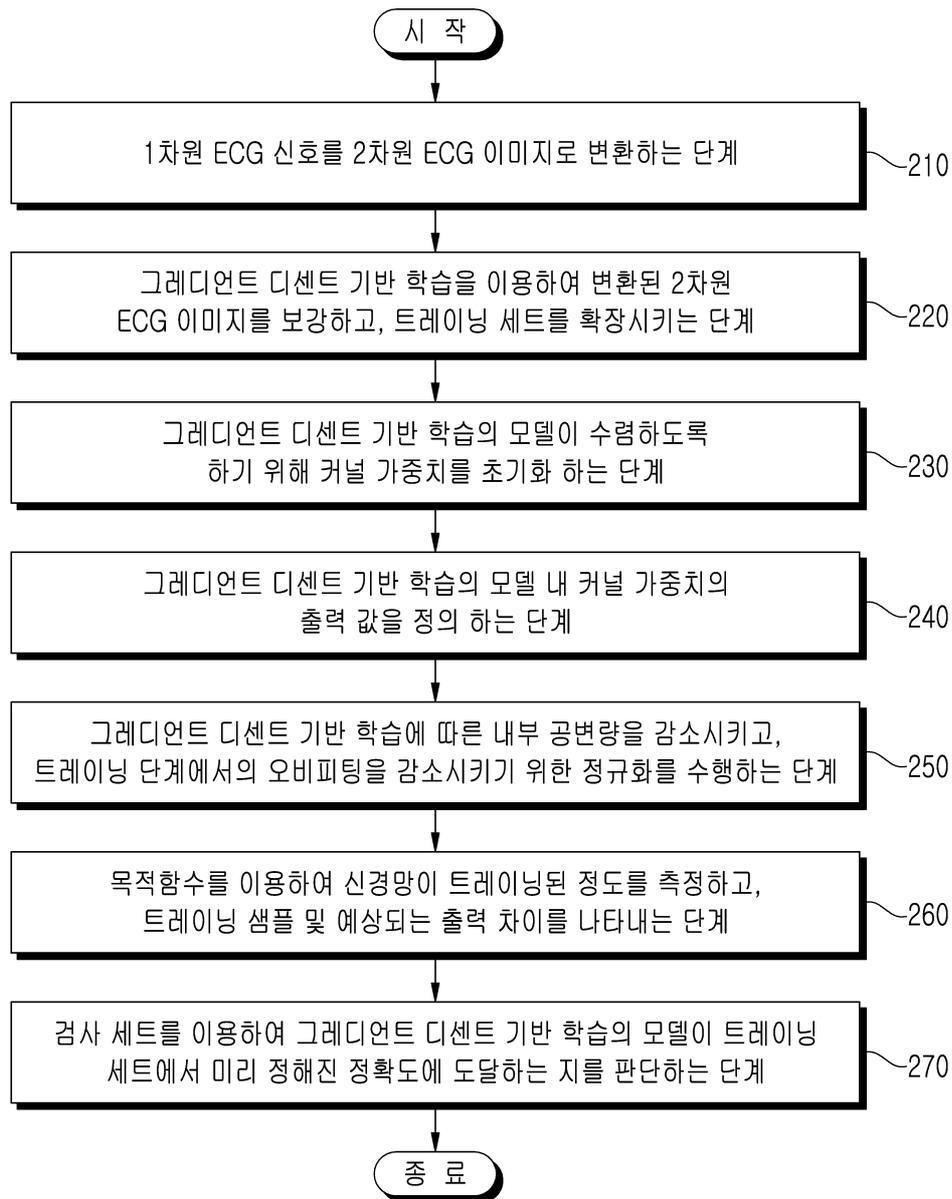
[0107] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

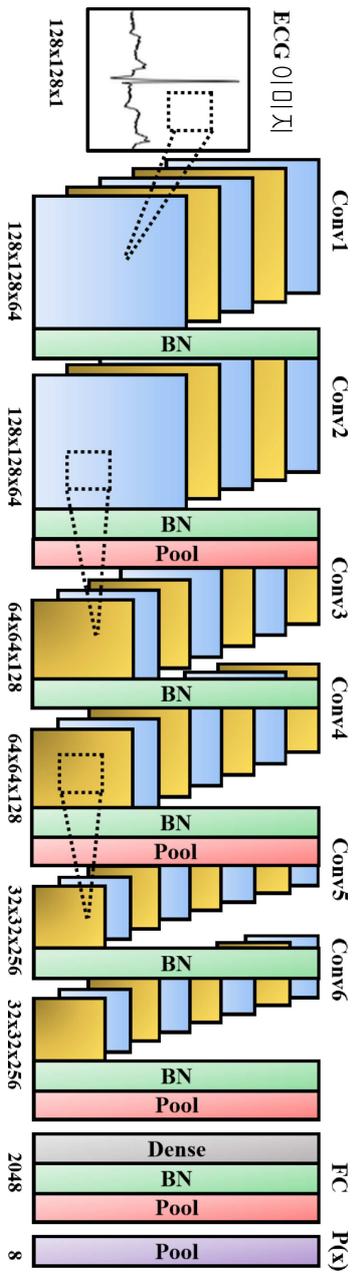
도면1



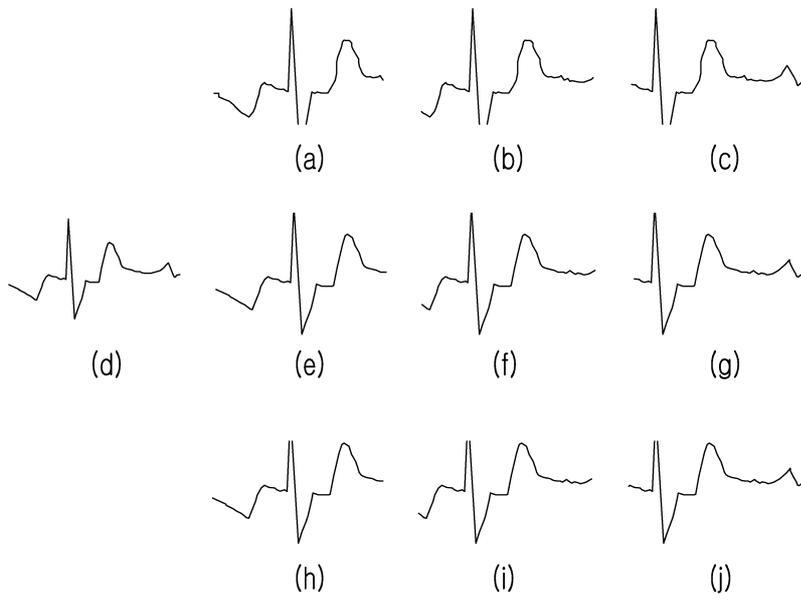
도면2



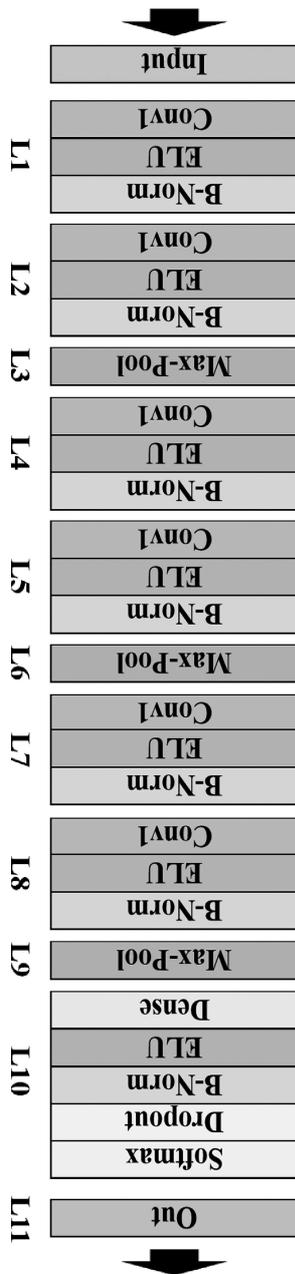
도면3



도면4



도면5



| | | | |
|----------------|---------------------------------------|---------|------------|
| 专利名称(译) | 深度卷积神经网络进行心电图心律失常分类的方法和设备 | | |
| 公开(公告)号 | KR1020190141326A | 公开(公告)日 | 2019-12-24 |
| 申请号 | KR1020180067933 | 申请日 | 2018-06-14 |
| [标]申请(专利权)人(译) | 韩国科学技术院 | | |
| 申请(专利权)人(译) | 科学与韩国高等科技研究院 | | |
| [标]发明人 | 김대영 전태준 강대연 김도현 | | |
| 发明人 | 김대영 전태준 응우웬, 민 호앙 강대연 김도현 | | |
| IPC分类号 | A61B5/0464 A61B5/00 A61B5/04 | | |
| CPC分类号 | A61B5/0464 A61B5/04012 A61B5/7267 | | |
| 代理人(译) | 培训. | | |
| 外部链接 | Espacenet | | |

摘要(译)

公开了一种使用深度卷积神经网络 (CNN) 的ECG心律不齐分类方法及其装置。使用深CNN的ECG心律失常分类方法包括以下步骤：将一维ECG信号转换为二维ECG图像；并增强通过学习方法转换的二维ECG图像，执行归一化以减少过度拟合以扩展训练数据，通过使用目标函数来测量神经网络的训练程度，并通过多种方法对多个ECG类型进行分类CNN分类器。

