



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0056154
(43) 공개일자 2024년04월30일

(51) 국제특허분류(Int. Cl.)

A61B 5/00 (2021.01) G06N 3/08 (2023.01)
G16H 30/40 (2018.01) G16H 50/20 (2018.01)

(52) CPC특허분류

A61B 5/0075 (2013.01)
A61B 5/0042 (2013.01)

(21) 출원번호 10-2022-0136404

(22) 출원일자 2022년10월21일

심사청구일자 2022년10월21일

(71) 출원인

고려대학교 산학협력단

서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)

(72) 발명자

최은정

서울특별시 노원구 동일로 1000 810호

이승현

서울특별시 강남구 선릉로108길 39-2, 101호

(뒷면에 계속)

(74) 대리인

특허법인에스알비


전체 청구항 수 : 총 14 항

(54) 발명의 명칭 기능적 근적외선 분광신호의 동잡음 검출 및 제거 방법

(57) 요약

본 발명은 기능적 근적외선 분광신호의 동잡음 검출 및 제거 방법에 관한 것으로, 본 발명에 따른 방법은 다양한 환경에서 대상의 상태 정보를 충실히 반영하는 근적외선 분광신호를 획득할 수 있어, 의료영상기기의 소프트웨어 및 하드웨어로 이용될 수 있으며, 또한, 뇌-컴퓨터 인터페이스 분야에서 활용될 수 있다.

대표도 - 도3



(52) CPC특허분류

A61B 5/4064 (2021.01)
A61B 5/7207 (2013.01)
A61B 5/7225 (2021.01)
A61B 5/7253 (2013.01)
A61B 5/7264 (2023.08)
G06N 3/08 (2023.01)
G16H 30/40 (2018.01)
G16H 50/20 (2018.01)

필립스 제파니아

서울특별시 성북구 안암로 75 511호

(72) 발명자

백승호

서울특별시 강북구 솔샘로 159 114동 2204호

김법민

서울특별시 은평구 불광로2길 41 북한산래미안아파트 105동 1005호

이 발명을 지원한 국가연구개발사업

과제고유번호	1711174377
과제번호	KMDF-RS-2022-00140478
부처명	과학기술정보통신부
과제관리(전문)기관명	범부처전주기료기기연구개발사업단
연구사업명	의료공공복지 구현 및 사회문제 해결(2022년)
연구과제명	인공지능 기반 개인맞춤 최적재활 멀티모달 뇌신경자극 치료기기 개발
기 여 율	1/2
과제수행기관명	고려대학교
연구기간	2022.04.01 ~ 2025.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1465036228
과제번호	HI14C3477
부처명	보건복지부
과제관리(전문)기관명	한국보건산업진흥원
연구사업명	보건의료기술개발사업
연구과제명	광학기술기반 뇌 혈류 산소포화도 측정 연구 및 뇌기능 진단장비 개발
기 여 율	1/2
과제수행기관명	고려대학교 안암병원
연구기간	2014.12.01 ~ 2023.01.10

명세서

청구범위

청구항 1

컴퓨팅 장치에 의해 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을 제거하는 방법에 있어서,

대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하는 변환 단계;

미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하는 검출 단계; 및

미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 제거 단계;

를 포함하는, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 2

제1항에 있어서, 상기 변환 단계는,

시계열 데이터를 하기 수학적 식 1에 따라 극좌표로 변환하는 좌표 변환 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

[수학적 식 1]

$$\begin{aligned}\phi_i &= \arccos(x_i) \\ r_i &= \frac{i}{N}\end{aligned}$$

[여기서, N은 시계열 데이터의 타임스탬프 (timestamp)의 수, x_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값을 의미함]

청구항 3

제1항에 있어서, 상기 변환 단계는,

시계열 데이터를 하기 수학적 식 2에 따라 GASF (gramian angular summation field)로 변환하여 시계열 데이터를 이미지 데이터로 변환하는 GASF 이미지 생성 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

[수학적 식 2]

$$G = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \dots & \cos(\phi_n + \phi_n) \end{pmatrix}$$

[여기서, ϕ_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값의 아크코사인 (arccosine) 값임]

청구항 4

제1항에 있어서, 상기 검출 단계는,

변환된 이미지 데이터로부터 노이즈의 타입을 분류하는 분류 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 5

제1항에 있어서, 상기 방법은,

기능적 근적외선 분광 신호의 시계열 데이터를 표준화하는 표준화 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 6

제1항에 있어서, 상기 제거 단계는,

노이즈가 제거된 이미지 데이터를 시계열 데이터로 복원하는 복원 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 7

제1항에 있어서, 상기 검출 모델은,

하나 이상의 학습영상 및 상기 학습영상에 대응되며 노이즈 판단 결과를 포함하는 가이드 라벨에 기초하여 지도 학습되며,

상기 지도학습은 검출 모델을 이용하여 학습영상에 대해 생성한 학습 정보와 가이드 라벨의 비교 결과에 기초하여 수행되는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 8

제7항에 있어서, 상기 지도학습은,

상기 학습 정보와 상기 가이드 라벨을 이진 크로스 엔트로피 (Binary Cross-Entropy) 손실함수에 대입하여 계산한 결과값에 기초하여 수행되는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 9

제1항에 있어서, 상기 제거 단계는,

미리 학습된 노이즈 제거 모델을 통해 노이즈가 검출된 이미지 데이터로부터 노이즈 타입에 따라 제거 필터를 선택하는 선택 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 10

제1항에 있어서, 상기 검출 모델 및 상기 노이즈 제거 모델은 딥 뉴럴 네트워크 (Deep Neural Network; DNN) 모델인 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 11

제10항에 있어서, 상기 딥 뉴럴 네트워크 모델은 컨볼루션 뉴럴 네트워크 (convolutional neural network; CNN) 모델인 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 12

제1항에 있어서, 상기 검출 단계는,

인접한 채널로부터 측정된 시계열 데이터로부터 변환된 각각의 이미지 데이터를 비교함에 따라 노이즈를 검출하는 비교 단계를 포함하는 것인, 기능적 근적외선 분광 신호의 동잡음 제거 방법.

청구항 13

저장 매체에 저장된 컴퓨터 프로그램으로서, 컴퓨터 프로그램은 하나 이상의 프로세서에서 실행되는 경우, 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을 제거하기 위한 이하의 동

작들을 수행하도록 하며, 동작들은:

측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하는 변환 동작;

미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하는 검출 동작; 및

미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 제거 동작;

를 포함하는 것인, 저장 매체에 저장된 컴퓨터 프로그램.

청구항 14

기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을 제거하기 위한 컴퓨팅 장치로서, 하나 이상의 코어를 포함하는 프로세서; 및 메모리;를 포함하고,

프로세서는,

측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하고,

미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하고,

미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는, 컴퓨팅 장치.

발명의 설명

기술 분야

[0001] 본 발명은 기능적 근적외선 분광신호의 동잡음 검출 및 제거 방법에 관한 것으로, 더욱 상세하게는, 시계열 데이터로 표현된 기능적 근적외선 분광신호 (functional Near-Infrared Spectroscopy; fNIRS)를 이미지로 변환하고, 인공 신경망 모델을 이용하여 변환된 이미지로부터 기능적 근적외선 분광신호의 동잡음 (motion artifact)을 검출하는 방법에 관한 것이다.

배경 기술

[0002] 전자 기술의 발달에 따라 다양한 전자 기술이 응용된 의료 기구들에 대한 연구 및 개발이 이루어지고 있다. 피검체인 인체의 내부, 특히 뇌의 생체 정보를 비침습적 방법으로 취득하기 위하여 EEG (electroencephalogram, 뇌전도), CT (computed tomography, 컴퓨터 단층 촬영), MRI (magnetic resonance imaging, 자기공명장치) 등의 장비들이 활용된다.

[0003] 최근에는, 뇌 생체 정보 취득을 위한 다양한 장치와 더불어 기능적 근적외선 분광법 (functional near-infrared spectroscopy; fNIRS)에 대한 연구가 활발히 진행되고 있다. 기능적 근적외선 분광법은 인체에 무해한 빛을 이용하여 인체 조직을 영상화할 수 있는 방법으로, 여타 방식과는 달리 비용 부담을 최소화시킬 수 있다는 장점이 있다. 기능적 근적외선 분광법은 인체조직에 존재하는 산화 헤모글로빈, 환원 헤모글로빈, 미오글로빈 등과 같은 흡수물질의 농도변화 및 광학계수를 비침습적으로 측정할 수 있는 방법으로, 700~2800 nm, 특히 700~900 nm 대역의 근적외선은 인체조직 내에서 산란 및 흡수가 다른 대역에 비해 상대적으로 작게 일어나기 때문에 빛이 깊이 도달할 수 있으며, 이를 이용하여 인체 내 수 cm 깊이까지 정보를 얻어낼 수 있다는 점에서 특징을 갖는다. 인체 내 존재하는 흡수물질은 크게 산소에 의존적인 물질과 비 의존적인 물질로 나눌 수 있다. 특히 산소에 의존적인 물질의 농도변화는 인체 내 대사활동과 밀접하게 연관되어 있어 이를 정량, 정성적으로 분석하는 것이 매우 중요하다.

[0004] 기능적 근적외선 분광법을 이용하는 경우, 인지, 운동 등 다양한 활동 중에 실시간으로 상태 측정이 가능하나, 머리, 체간 등의 움직임에 인한 광극 (optode)의 수평/수직 이동으로 인하여 신호가 비정상적으로 튀는 현상인 동잡음 (motion artifact)이 발생할 수 있다. 동잡음이 발생하는 경우 기능적 근적외선 분광법을 이용하여 신경생리학적 정보가 포함된 충실한 뇌혈류역학 신호 획득이 곤란한 문제점이 존재한다.

[0005] 이에, 충실한 충실한 뇌활성도 신호 획득을 위한 효과적인 동잡음 제거방법이 필요한 실정이다.

발명의 내용

해결하려는 과제

- [0006] 이에 본 발명자들은 인공 신경망 모델을 기반으로 하는 기능적 근적외선 분광신호 (functional Near-Infrared Spectroscopy; fNIRS)의 동잡음 (motion artifact)의 검출 및 제거 방법을 구축하였으며, 이의 동잡음 검출 및 제거 성능이 월등히 우수한 것을 확인하였다.
- [0007] 이에, 본 발명의 목적은 기능적 근적외선 분광 신호의 동잡음을 제거하는 방법을 제공하는 것이다.
- [0008] 본 발명의 다른 목적은 기능적 근적외선 분광 신호의 동잡음을 제거하는 컴퓨터 프로그램을 제공하는 것이다.
- [0009] 본 발명의 또 다른 목적은 기능적 근적외선 분광 신호의 동잡음을 제거하기 위한 컴퓨팅 장치에 관한 것이다.

과제의 해결 수단

- [0010] 본 발명은 기능적 근적외선 분광신호의 동잡음 검출 및 제거 방법에 관한 것으로, 본 발명에 따른 방법은 인공 신경망 모델을 기반으로 실시간으로 근적외선 분광신호의 동잡음을 검출 및 제거할 수 있다.
- [0011] 이하 본 발명을 더욱 자세히 설명하고자 한다.
- [0013] 본 발명의 일 양태는, 컴퓨팅 장치에 의해 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을 제거하는 방법에 있어서, 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하는 변환 단계; 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하는 검출 단계; 및 미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 제거 단계;를 포함하는, 기능적 근적외선 분광 신호의 동잡음 제거 방법이다.
- [0014] 본 명세서 상의 용어 "동잡음"이란, 기능적 근적외선 분광기의 광극(fNIRS-optode)의 수평/수직 이동으로 인해 발생하는 잡음으로 비정상적으로 튀는 현상을 의미한다. 동잡음은 신경혈관 결합으로 인해 예상되는 뇌혈류역학 변화를 해석하는 데에 어려움을 일으킨다. 이를 해결하기 위해 spline interpolation, PCA, Wavelet 필터와 같은 기법이 사용되어 왔으나, 필터별로 제거되지 않는 동잡음이 있으며, 필터를 조합하여 사용할 경우 제거되는 주파수 대역으로 인해 유의미한 신호가 불필요하게 필터링되는 문제점이 존재하였다.
- [0015] 본 명세서 상의 용어 "대상"은 기능적 근적외선 분광신호의 측정 대상이 되는 객체 (또는 피검체)일 수 있다. 본 발명의 일 구현예에서, 대상은 포유류 일 수 있고, 예를 들어, 대상은 인간, 원숭이, 개, 고양이, 마우스, 래트, 소, 말, 돼지, 염소 및 양으로 이루어지는 그룹에서 선택되는 하나 이상일 수 있다.
- [0016] 본 발명의 일 구현예에서, 검출 모델 및/또는 노이즈 제거 모델은 딥 뉴럴 네트워크 (Deep Neural Network; DNN) 모델인 것일 수 있다.
- [0017] 본 명세서 상의 용어 "딥 뉴럴 네트워크"는 입력 레이어와 출력 레이어 외에 복수의 히든 레이어를 포함하는 신경망을 의미할 수 있다. 용어 "딥 뉴럴 네트워크"는 본 명세서에 걸쳐 용어 "신경망", "네트워크 함수", "뉴럴 네트워크 (neural network)"와 상호교차되어 사용될 수 있다. 딥 뉴럴 네트워크를 이용하면 데이터의 잠재적인 구조 (latent structures)를 파악하는 것이 가능하다. 즉, 사진, 글, 비디오, 음성, 음악의 잠재적인 구조 (예를 들어, 어떤 물체가 사진에 있는지, 글의 내용과 감정이 무엇인지, 음성의 내용과 감정이 무엇인지 등)를 파악할 수 있다. 본 발명에 있어서, 딥 뉴럴 네트워크는 컨볼루션 뉴럴 네트워크 (convolutional neural network; CNN), 리커런트 뉴럴 네트워크 (recurrent neural network; RNN), 제한 볼츠만 머신 (restricted boltzmann machine; RBM), 심층 신뢰 네트워크 (deep belief network; DBN), Q 네트워크, U 네트워크, 삼 네트워크 등을 포함할 수 있으나, 이에 제한되는 것은 아니다.
- [0018] 본 발명의 일 구현예에서, 변환 단계는, 시계열 데이터를 하기 수학식 1에 따라 극좌표로 변환하는 좌표 변환 단계를 포함하는 것일 수 있다.

[0019] [수학식 1]

$$\phi_i = \arccos(x_i)$$

$$r_i = \frac{i}{N}$$

[0020]

[0021] [여기서, N은 시계열 데이터의 타임스탬프 (timestamp)의 수, x_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값을 의미함]

[0022] 본 발명의 일 구현예에서, 변환 단계는, 시계열 데이터를 하기 수학식 2에 따라 GASF (gramian angular summation field)로 변환하여 시계열 데이터를 이미지 데이터로 변환하는 GASF 이미지 생성 단계를 포함하는 것일 수 있다.

[0023] [수학식 2]

$$G = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \dots & \cos(\phi_n + \phi_n) \end{pmatrix}$$

[0024]

[0025] [여기서, ϕ_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값의 아크코사인 (arccosine) 값임]

[0026] 본 발명의 일 구현예에서, 검출 단계는, 변환된 이미지 데이터로부터 노이즈의 타입을 분류하는 분류 단계를 포함하는 것일 수 있다.

[0027] 본 발명의 일 구현예에서, 분류 단계는 변환된 이미지 데이터로부터 노이즈의 타입을 스파이크 (spike) 및 기준선 이동 (baseline shift)로 분류하는 것일 수 있다.

[0028] 본 발명의 일 구현예에서, 방법은, 기능적 근적외선 분광신호의 시계열 데이터를 표준화하는 표준화 단계를 포함하는 것일 수 있다.

[0029] 본 발명의 일 구현예에서, 표준화 단계는, 시계열 데이터의 신호를 -1 내지 1 사이로 표준화하는 것일 수 있다.

[0030] 본 발명의 일 구현예에서, 제거 단계는, 노이즈가 제거된 이미지 데이터를 시계열 데이터로 복원하는 복원 단계를 포함하는 것일 수 있다.

[0031] 본 발명의 일 구현예에서, 제거 단계는, 미리 학습된 노이즈 제거 모델을 통해 노이즈가 검출된 이미지 데이터로부터 노이즈 타입에 따라 제거 필터를 선택하는 선택 단계를 포함하는 것일 수 있다.

[0032] 본 발명의 일 구현예에서, 검출 모델 및/또는 노이즈 제거 모델은, 하나 이상의 학습영상 및 상기 학습영상에 대응되며 노이즈 판단 결과를 포함하는 가이드 라벨에 기초하여 지도학습되는 것일 수 있다.

[0033] 본 발명의 일 구현예에서, 지도학습은 검출 모델 및/또는 노이즈 제거 모델을 이용하여 학습영상에 대해 생성한 학습 정보와 가이드 라벨의 비교 결과에 기초하여 수행되는 것일 수 있다.

[0034] 본 발명의 일 구현예에서, 검출 모델 및/또는 노이즈 제거 모델은, 하나 이상의 학습영상 및 학습영상에 대응되며 노이즈 판단 결과를 포함하는 가이드 라벨에 기초하여 지도학습되며, 지도학습은 검출 모델 및/또는 노이즈 제거 모델을 이용하여 학습영상에 대해 생성한 학습 정보와 가이드 라벨의 비교 결과에 기초하여 수행되는 것일 수 있다.

[0035] 본 발명의 일 구현예에서, 지도학습은, 학습 정보와 가이드 라벨을 이진 크로스 엔트로피 (Binary Cross-Entropy) 손실함수에 대입하여 계산한 결과값에 기초하여 수행되는 것일 수 있다.

[0036] 본 발명의 일 구현예에서, 검출 단계는, 인접한 채널로부터 측정된 시계열 데이터로부터 변환된 각각의 이미지 데이터를 비교함에 따라 노이즈를 검출하는 비교 단계를 포함하는 것일 수 있다.

[0037] 본 발명의 다른 양태는, 저장 매체에 저장된 컴퓨터 프로그램으로서, 컴퓨터 프로그램은 하나 이상의 프로세서에서 실행되는 경우, 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을

제거하기 위한 이하의 동작들을 수행하도록 하며, 동작들은: 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하는 변환 동작; 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하는 검출 동작; 및 미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 제거 동작; 를 포함하는 것인, 저장 매체에 저장된 컴퓨터 프로그램이다.

[0038] 본 발명의 또 다른 양태는, 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동 잡음을 제거하기 위한 컴퓨팅 장치로서, 하나 이상의 코어를 포함하는 프로세서; 및 메모리;를 포함하고, 프로세서는, 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하고, 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하고, 미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는, 컴퓨팅 장치이다.

발명의 효과

[0039] 본 발명은 기능적 근적외선 분광신호의 동잡음 검출 및 제거 방법에 관한 것으로, 본 발명에 따른 방법은 다양한 환경에서 대상의 상태 정보를 충실히 반영하는 근적외선 분광신호를 획득할 수 있어, 의료영상기기의 소프트웨어 및 하드웨어로 이용될 수 있으며, 또한, 뇌-컴퓨터 인터페이스 분야에서 활용될 수 있다.

도면의 간단한 설명

[0040] 도 1은 본 발명의 일 실시예에 따른 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을 제거하기 위한 동작을 수행하는 컴퓨팅 장치의 블록구성도를 도시한 도면이다.

도 2는 본 발명의 일 실시예에 따른 딥 뉴럴 네트워크를 나타낸 개략도이다.

도 3은 본 발명의 일 실시예에 따른 기능적 근적외선 분광 신호의 동잡음을 제거하는 과정을 설명하기 위한 블록구성도를 도시한 도면이다.

도 4는 본 발명의 일 실시예에 따라 측정된 근적외선 분광신호로, 스파이크 (spike) 및 기준선 변화 (baseline shift) 노이즈가 포함된 시계열 데이터를 나타낸 그래프이다.

도 5는 본 발명의 일 실시예에 따라 스파이크 (spike) 및 기준선 변화 (baseline shift) 노이즈가 포함된 시계열 데이터를 극좌표로 변환한 결과를 나타낸 도면이다.

도 6은 본 발명의 일 실시예에 따라 스파이크 (spike) 및 기준선 변화 (baseline shift) 노이즈가 포함된 시계열 데이터를 GASF (gramian angular summation field) 이미지로 변환한 결과를 나타낸 도면이다.

도 7은 본 발명의 일 실시예에 따라 이미지 데이터로부터 노이즈를 제거 과정을 설명하기 위한 도면이다.

도 8은 본 발명의 일 실시예에 따라 노이즈가 제거된 GASF 이미지를 나타낸 도면이다.

도 9는 노이즈가 포함된 근적외선 분광신호의 시계열 데이터를 나타낸 그래프이다.

도 10은 도 9의 시계열 데이터를 기존의 방법을 이용하여 시계열 데이터로부터 노이즈를 제거한 결과를 나타낸 그래프이다.

도 11은 도 9의 시계열 데이터를 본 발명의 일 실시예에 따른 방법을 통해 노이즈를 제거한 결과를 나타낸 그래프이다.

발명을 실시하기 위한 구체적인 내용

[0041] 아래에서는 첨부한 도면을 참고로 하여 본 발명의 실시예에 대하여 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다. 그러나 본 발명은 여러가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시예에 한정되지 않는다. 그리고 도면에서 본 발명을 명확하게 설명하기 위해서 설명과 관계없는 부분은 생략하였으며, 명세서 전체를 통하여 유사한 부분에 대해서는 유사한 도면 부호를 붙였다.

[0042] 명세서 전체에서, 어떤 부분이 어떤 구성 요소를 "포함" 한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성 요소를 제외하는 것이 아니라 다른 구성 요소를 더 포함할 수 있는 것을 의미한다. 용어 "및/또는," "그리고/또는"은 그 관련되어 나열되는 항목들의 모든 조합들 및 어느 하나를 포함한다.

[0043] 또한, 명세서에 기재된 "... 부", "... 모듈"의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를

의미하며, 이는 하드웨어나 소프트웨어 또는 하드웨어 및 소프트웨어의 결합으로 구현될 수 있다.

[0044] 본 명세서 상에서 실시예들과 관련되어 설명된 다양한 예시적 논리적 블록들, 구성들, 모듈들, 회로들, 수단들, 로직들, 및 알고리즘 단계들이 전자 하드웨어, 컴퓨터 소프트웨어, 또는 양쪽 모두의 조합들로 구현될 수 있음을 인식해야 한다. 하드웨어 및 소프트웨어의 상호교환성을 명백하게 예시하기 위해, 다양한 예시적 컴포넌트들, 블록들, 구성들, 수단들, 로직들, 모듈들, 회로들, 및 단계들은 그들의 기능성 측면에서 일반적으로 위에서 설명되었다. 그러한 기능성이 하드웨어로 또는 소프트웨어로서 구현되는지 여부는 전반적인 시스템에 부과된 특정 어플리케이션(application) 및 설계 제한들에 달려 있다. 숙련된 기술자들은 각각의 특정 어플리케이션들을 위해 다양한 방법들로 설명된 기능성을 구현할 수 있다. 다만, 그러한 구현의 결정들이 본 개시내용의 영역을 벗어나게 하는 것으로 해석되어서는안된다.

[0046] 도 1은 본 발명의 일 실시예에 따른 기능적 근적외선 분광 (functional Near-Infrared Spectroscopy; fNIRS) 신호의 동잡음을 제거하기위한 동작을 수행하는 컴퓨팅 장치의 블록구성도를 도시한 도면이다.

[0047] 도 1을 참조하면, 일 실시예에 따른 기능적 근적외선 분광 신호의 동잡음을 제거하기위한 동작을 수행하는 컴퓨팅 장치 (1000)는 프로세서 (100) 및 메모리 (200)를 포함할 수 있다.

[0048] 프로세서 (100)는, 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환하고, 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단하고, 미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 동작을 수행할 수 있다.

[0049] 프로세서 (100)는, 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환할 때, 시계열 데이터를 극좌표로 변환하는 동작을 수행할 수 있고, 예를 들어, 프로세서는 시계열 데이터를 하기 수학적 식 1에 따라 극좌표로 변환하는 동작을 수행할 수 있다.

[0050] [수학적 식 1]

$$\begin{aligned}\phi_i &= \arccos(x_i) \\ r_i &= \frac{i}{N}\end{aligned}$$

[0051]

[0052] [여기서, N은 시계열 데이터의 타임스탬프 (timestamp)의 수, x_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값을 의미함]

[0053] 프로세서 (100)가 기능적 근적외선 분광신호의 시계열 데이터를 극좌표로 변환하는 경우, 시계열 데이터 상에 측정된 근적외선 분광신호는 극좌표계 상에서 반경 (r) 및 각도로 표현될 수 있고, 이를 기반으로 극좌표 형태로 표현된 근적외선 분광신호 값은 후술할 GASF (gramian angular summation field)로 변환될 수 있다. 이때, 극좌표에서 반경은 시계열 데이터의 타임스탬프를 기반으로 산출되기 때문에 극좌표계에는 시계열 데이터와 마찬가지로 시간 정보 및 근적외선 분광 신호 값 정보가 동시에 포함될 수 있다.

[0054] 프로세서 (100)는, 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환할 때, 시계열 데이터를 하기 수학적 식 2에 따라 GASF (gramian angular summation field)로 변환하여 시계열 데이터를 이미지 데이터로 변환하는 동작을 수행할 수 있다.

[0055] [수학적 식 2]

$$G = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \dots & \cos(\phi_n + \phi_n) \end{pmatrix}$$

[0056]

[0057] [여기서, ϕ_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값의 아크코사인 (arccosine) 값임]

- [0058] 이때, 이미지 데이터에서의 각각의 픽셀 (pixel) 값은 수학적 2의 그라미안 행렬 (gramian matrix)의 각각의 성분과 대응되는 것일 수 있다. 그리고, 정해진 기준에 따라서, 그라미안 행렬의 각각의 성분 값 수치는 대응되는 색상으로 이미지 데이터로 표현될 수 있다. 상기 수학적 2에 도시된 그라미안 행렬에 나타난 바와 같이, GASF로 변환된 행렬의 성분들은 시간의 쌍으로 이루어진 극좌표계로 표현된 시계열 데이터의 각도에 함으로 표현되기 때문에, 시간적 상관관계가 행렬상에서 표현될 수 있고, 이에 따라 변환된 이미지 데이터 상에서도 시간적 상관관계가 표현될 수 있다. 즉, 이미지 데이터의 좌측 상단으로부터 우측 상단까지 이어지는 대각선 상의 픽셀은 본래의 시계열 데이터의 값을 표현하게 되며, 대각선을 제외한 부분은 둘 이상의 다른 시점에서 측정된 신호 값 정보를 포함하게 되는 것으로 서로 다른 시간에서의 상관관계가 나타날 수 있다.
- [0059] 프로세서 (100)는, 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단할 때, 변환된 이미지 데이터로부터 노이즈의 타입을 분류하는 동작을 수행할 수 있다. 이때, 프로세서 (100)는 변환된 이미지 데이터로부터 노이즈의 타입을 스파이크 (spike) 또는 기준선 변화 (baseline shift)로 분류하는 동작을 수행할 수 있다.
- [0060] 프로세서 (100)는, 기능적 근적외선 분광 신호의 시계열 데이터를 표준화하는 동작을 수행할 수 있다. 프로세서 (100)는, 예를 들어, 시계열 데이터의 신호값을 -1 내지 1 사이의 값으로 표준화하는 동작을 수행할 수 있다.
- [0061] 프로세서 (100)는, 미리 학습된 노이즈 제거 모델을 이용하여 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거할 때, 이미지 데이터로부터 노이즈가 제거된 이미지 데이터를 생성하는 동작을 수행할 수 있다.
- [0062] 프로세서 (100)는, 미리 학습된 노이즈 제거 모델을 이용하여 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거할 때, 노이즈가 제거된 이미지 데이터를 시계열 데이터로 복원하는 동작을 수행할 수 있다. 구체적으로, 프로세서 (100)는 노이즈 제거 모델을 통해 시계열 데이터로부터 변환된 이미지 데이터에서 노이즈가 제거된 이미지 데이터를 생성할 수 있고, 노이즈가 제거된 이미지 데이터를 기반으로 시계열 데이터로 복원할 수 있다. 전술한 바와 같이 일 실시예에 따른 이미지 데이터는 수학적 2와 같은 그라미안 행렬을 기초로 생성되는 것으로, 이미지 데이터의 주 대각선 방향은 시계열 데이터와 마찬가지로 특정 시간에서의 신호값을 나타내므로, 프로세서 (100)는 이를 기반으로 이미지 데이터를 다시 시계열 데이터로 복원할 수 있다.
- [0063] 프로세서 (100)는, 미리 학습된 노이즈 제거 모델을 이용하여 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거할 때, 미리 학습된 노이즈 제거 모델을 통해 노이즈가 검출된 이미지 데이터로부터 노이즈 타입에 따라 제거 필터를 선택하는 동작을 수행할 수 있다. 예를 들어, 프로세서 (100)는 노이즈가 검출된 이미지 데이터로부터 노이즈 타입에 따라, 노이즈 제거 모델을 통해 가우시안 필터, 칼만 필터, 적응형 잡음 제거 필터 등의 필터를 선택하고, 필터를 이용해 이미지 데이터로부터 노이즈가 제거된 이미지 데이터를 생성할 수 있다.
- [0064] 프로세서 (100)는, 기능적 근적외선 분광 신호의 동잡음을 제거하기 위한 동작을 수행할 때, 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이용할 수 있다. 즉, 측정된 근적외선 분광신호의 시계열 데이터는 서로 다른 채널을 통해 측정된 데이터를 포함하는 것일 수 있다.
- [0065] 그리고, 프로세서 (100) 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 동작을 수행할 때, 인접한 채널로부터 측정된 시계열 데이터로부터 변환된 각각의 이미지 데이터를 비교함에 따라 노이즈를 검출하는 동작을 수행할 수 있다. 전술한 바와 같이 시계열 데이터가 변환된 이미지 데이터 상에는 시간적 상관관계가 표현되어 있으며, 각각의 채널에서 얻어진 시계열 데이터가 변환된 각 이미지 데이터의 픽셀 값이 서로 비교됨에 따라 동잡음의 유무가 판단될 수 있다. 예를 들어, 3개의 인접한 채널을 통해 기능적 근적외선 분광 신호가 측정되어 3개의 시계열 데이터가 형성된 경우, 3개의 시계열 데이터는 전술한 과정을 거쳐 각각의 이미지 데이터로 변환되어 3개의 이미지 데이터가 형성될 수 있다. 이때, 하나의 채널에서 측정되어 변환된 이미지 데이터의 특정 픽셀 값이 나머지 두개의 인접한 채널에서 측정되어 변환된 이미지 데이터의 대응되는 픽셀 값과 차이가 큰 경우, 학습된 검출 모델은 이를 동잡음 발생으로 판단할 수 있다.
- [0066] 따라서, 일 실시예에 따른 기능적 근적외선 분광 신호의 동잡음을 제거하기 위한 동작을 수행하는 컴퓨팅 장치는 이미지 데이터로 변환된 복수의 채널에서 측정된 데이터를 기반으로 동잡음을 검출 및 제거할 수 있기 때문에 보다 정확하게 동잡음 유무를 판단하고 제거하는 것이 가능하다. 구체적으로, 하기 실시예 1 내지 2에 나타난 것과 같이 일 실시예에 따른 기능적 근적외선 분광 신호의 동잡음을 제거하기 위한 동작을 수행하는 컴퓨팅 장치는, 컷오프 방법을 통해 동잡음을 제거하는 기존의 방법에서 동잡음이 판단되지 않은 부분에서도 명확하게 동잡음을 잡아내어 제거하는 것이 가능하다.
- [0067] 미리 학습된 검출 모델 및/또는 노이즈 제거 모델은 딥 뉴럴 네트워크 (deep neural network; DNN)일 수 있다.

딥 뉴럴 네트워크는 입력 레이어, 출력 레이어를 포함할 수 있고, 또는 입력 레이어 및 출력 레이어 외의 별개의 복수의 히든 레이어를 포함하는 것일 수 있다. 딥 뉴럴 네트워크는 컨볼루셔널 뉴럴 네트워크(convolutional neural network; CNN), 리커런트 뉴럴 네트워크(recurrent neural network; RNN), 제한 볼츠만 머신(restricted boltzmann machine; RBM), 심층 신뢰 네트워크(deep belief network; DBN), Q 네트워크, U 네트워크, 삼 네트워크 등을 포함할 수 있고, 예를 들어, 딥 뉴럴 네트워크는 컨볼루셔널 뉴럴 네트워크일 수 있다.

[0068] 컨볼루셔널 뉴럴 네트워크는 다계층 퍼셉트론의 한 종류로 컨볼루셔널 레이어를 포함하는 신경망을 포함할 수 있다. 컨볼루셔널 뉴럴 네트워크는 신경망을 통한 연산과정에서 가중치를 이용할 수 있다. 컨볼루셔널 뉴럴 네트워크는 하나 이상의 컨볼루셔널 레이어 및 이와 결합된 신경망 레이어로 구성될 수 있다. 컨볼루셔널 레이어는 필터를 사용하여 입력된 데이터로부터 특징(feature)를 추출할 수 있다. 이때, 컨볼루셔널 레이어는 필터와 필터를 비선형 값으로 바꾸는 액티베이션 함수를 포함할 수 있다. 컨볼루셔널 뉴럴 네트워크는 이미지 데이터를 차원을 가진 행렬로 나타내어 처리할 수 있으며, 이를 통해 컨볼루셔널 뉴럴 네트워크는 이미지에서 오브젝트를 인식하기 위해 이용될 수 있다. 예를 들어, 레드, 그린 및 블루로 인코딩 된 이미지 데이터는 R, G, B 색상별로 2차원 행렬로 나타내 질 수 있고, 즉, 각 픽셀의 색상 값이 행렬의 성분이 될 수 있으며, 이때, 행렬의 크기는 이미지의 크기와 동일할 수 있다. 컨볼루셔널 뉴럴 네트워크는 풀링 레이어(Pooling layer)를 포함할 수 있고, 그리고, 이를 통해 2차원 구조의 입력 데이터를 활용하는 것이 가능하다.

[0069] 컨볼루셔널 뉴럴 네트워크는 하나 이상의 컨볼루셔널 레이어 및 서브 샘플링 레이어를 포함할 수 있다. 컨볼루셔널 레이어의 출력에는 서브샘플링 레이어가 연결되어 컨볼루셔널 레이어의 출력을 단순화할 수 있다. 예를 들어, 2*2 에버리지 풀링 필터를 가지는 풀링 레이어에 컨볼루셔널 레이어의 출력을 입력시키는 경우, 이미지의 각 픽셀에서 2*2 패치마다 각 패치에 포함되는 평균값을 출력하여 이미지를 압축할 수 있다. 전술한 풀링은 패치에서 최소값을 출력하거나, 패치의 최대값을 출력하는 방식일 수도 있으며 임의의 풀링 방식이 이용될 수 있다. 컨볼루셔널 뉴럴 네트워크는 컨볼루셔널 과정과 풀링 등의 서브 샘플링 과정을 반복적으로 수행하여 주어진 이미지에서 특징(feature)를 추출할 수 있다. 이때, 컨볼루셔널 레이어 및/또는 서브샘플링 레이어에서 출력은 풀리 커넥티드 레이어(fully connected layer)에 입력될 수 있다. 풀리 커넥티드 레이어는 하나의 레이어에 있는 모든 뉴런과 이웃한 레이어에 있는 모든 뉴런이 연결되는 레이어이다.

[0070] 프로세서(100)는, 하나 이상의 코어로 구성될 수 있으며, 컴퓨팅 장치의 중앙 처리 장치(central processing unit; CPU), 그래픽 처리 장치(graphics processing unit; GPU), 텐서 처리 장치(tensor processing unit; TPU) 등의 데이터 분석, 딥러닝을 위한 프로세서를 포함할 수 있다. 프로세서는, 메모리에 저장된 컴퓨터 프로그램을 판독하여 일 실시예에 따른 기계 학습을 위한 데이터 처리를 수행할 수 있다. 일 실시예에 따라 프로세서는, 신경망의 학습을 위한 연산을 수행할 수 있다. 프로세서는, 딥러닝(deep learning; DL)에서 학습을 위한 입력 데이터의 처리, 입력 데이터에서의 피쳐 추출, 오차 계산, 역전파(backpropagation)를 이용한 신경망의 가중치 업데이트 등의 신경망의 학습을 위한 계산을 수행할 수 있다. 프로세서(110)의 CPU, GPU, 및 TPU 중 적어도 하나가 네트워크 함수의 학습을 처리할 수 있다.

[0071] 메모리(200)는, 플래시 메모리 타입(flash memory type), 하드디스크 타입(hard disk type), 멀티미디어 카드 마이크로 타입(multimedia card micro type), 카드 타입의 메모리(예를 들어 SD 또는 XD 메모리 등), 램(Random Access Memory; RAM), SRAM(Static Random Access Memory), 롬(Read-Only Memory; ROM), EEPROM(Electrically Erasable Programmable Read-Only Memory), PROM(Programmable Read-Only Memory), 자기 메모리, 자기 디스크, 광디스크 중 적어도 하나의 타입의 저장매체를 포함할 수 있다.

[0073] 도 2는 본 발명의 일 실시예에 따른 딥 뉴럴 네트워크를 나타낸 개략도이다.

[0074] 뉴럴 네트워크는 입력 데이터로부터 특징 데이터를 추출하고 특징 데이터를 이용한 추론(inference) 연산을 제공하도록 설계된 기계 학습 구조의 모델을 나타낼 수 있다. 이때, 특징 데이터는 입력 데이터가 추상화된 특징에 관한 데이터를 나타낼 수 있다. 도 2는 설명의 편의를 위해 히든 레이어가 3개의 레이어를 포함하는 것으로 도시되었으나, 히든 레이어에는 다양한 수의 레이어들을 포함할 수 있다. 신경망은 하나 이상의 레이어를 포함할 수 있으며, 각각의 레이어는 하나 이상의 노드를 포함할 수 있다.

[0075] 노드(또는 유닛)은 각 레이어를 구성하는 요소로, 각각의 레이어는 노드 또는 노드들의 집합으로 구성될 수 있다. 뉴럴 네트워크내에서 출력 레이어를 제외한 레이어들의 노드들은 출력 신호를 전송하기 위한 링크들을 통해

다음 레이어의 노드들과 연결될 수 있다. 이때, 각각의 레이어들의 노드들은 링크를 통해 서로 연결될 수 있으며, 연결된 레이어의 노드들은 신호의 송 수신 여부에 따라 입력 노드 및 출력 노드의 관계에 있을 수 있다. 링크를 통해 연결된 노드 중, 출력 노드의 데이터는 입력 노드에 입력된 데이터에 따라 값이 결정될 수 있다. 히든 레이어에 포함된 각각의 노드에는 이전 레이어에 포함된 노드들의 가중된 입력들 (weighted inputs)에 관한 활성화 함수 (activation function)의 출력이 입력될 수 있다. 가중된 입력은 이전 레이어에 포함된 노드들의 입력에 가중치(weight)가 반영된 것이다. 이때, 가중치는 가변적일 수 있으며, 신경망의 기능 및 알고리즘에 따라 서로 가변될 수 있다. 가중치는 뉴럴 네트워크의 파라미터로 지칭될 수 있으며, 활성화 함수는 시그모이드 (sigmoid), 하이퍼볼릭 탄젠트 (hyperbolic tangent; tanh) 및 렐루 (rectified linear unit; ReLU)를 포함할 수 있다.

[0076] 최초 입력 노드는 신경망 내의 노드들 중 다른 노드들과의 관계에서 링크를 거치지 않고 데이터가 직접 입력되는 하나 이상의 노드들을 의미할 수 있다. 또는, 신경망 네트워크 내에서, 링크를 기준으로 한 노드 간의 관계에 있어서, 링크로 연결된 다른 입력 노드들을 가지지 않는 노드들을 의미할 수 있다. 이와 유사하게, 최종 출력 노드는 신경망 내의 노드들 중 다른 노드들과의 관계에서, 출력 노드를 가지지 않는 하나 이상의 노드들을 의미할 수 있다. 또한, 히든 노드는 최초 입력 노드 및 최종 출력 노드가 아닌 신경망을 구성하는 노드들을 의미할 수 있다.

[0077] 딥 뉴럴 네트워크 (deep neural network; DNN)는 입력 레이어와 출력 레이어 외에 복수의 히든 레이어를 포함하는 신경망을 의미할 수 있다. 딥 뉴럴 네트워크를 이용하면 데이터의 잠재적인 구조 (latent structures)를 파악할 수 있다. 즉, 사진, 글, 비디오, 음성, 음악의 잠재적인 구조 (예를 들어, 어떤 물체가 사진에 있는지, 글의 내용과 감정이 무엇인지, 음성의 내용과 감정이 무엇인지 등)를 파악할 수 있다. 딥 뉴럴 네트워크는 컨볼루션 뉴럴 네트워크 (convolutional neural network; CNN), 리커런트 뉴럴 네트워크 (recurrent neural network; RNN), 오토 인코더 (auto encoder), GAN (Generative Adversarial Networks), 제한 볼츠만 머신 (restricted boltzmann machine; RBM), 심층 신뢰 네트워크 (deep belief network; DBN), Q 네트워크, U 네트워크, 삼 네트워크, 적대적 생성 네트워크(GAN: Generative Adversarial Network) 등을 포함할 수 있다.

[0078] 컨볼루션 뉴럴 네트워크 (convolutional neural network; CNN)는 동물의 시각 피질의 구성에서 영감을 받아, 이미지와 같은 격자 패턴을 갖는 데이터를 처리하기 위한 딥 러닝 모델의 일종이다. 컨볼루션 뉴럴 네트워크는 일반적으로 컨볼루션 레이어, 풀링 레이어 및 풀리 커넥티드 레이어 (fully connected layer)를 포함할 수 있다. 컨볼루션 레이어 및 풀링 레이어는 신경망 내에 반복적으로 존재할 수 있으며, 입력 데이터는 이러한 레이어 계층을 통해 출력으로 변환될 수 있다. 컨볼루션은 레이어는 특징 추출을 위해서 커널 (또는 마스크)를 이용하여, 커널의 각 요소와 입력 값 간의 요소별 곱은 각각의 위치에서 계산되고 합산되어 출력 값을 얻게되며, 이를 특징 맵 (feature map)이라 지칭한다. 이러한 절차는 임의의 수의 특징 맵을 형성하기 위해 여러 커널을 적용하며 반복될 수 있다. 컨볼루션 뉴럴 네트워크에서 컨볼루션 및 풀링 레이어는 특징 추출을 수행하는 반면, 풀리 커넥티드 레이어는 추출된 특징을 분류하는 동작 등의 최종 출력에 매핑한다.

[0079] 컨볼루션 뉴럴 네트워크는 등의 뉴럴 네트워크는 출력 오류를 최소화하는 방향으로 학습될 수 있다. 입력 레이어에서 출력 레이어로부터 값을 추출하는 순전파과정과 별개로, 뉴럴 네트워크 내에서는 입력된 학습데이터 및 이에 대한 뉴럴 네트워크의 출력값 사이의 오류를 계산하고 이러한 오류를 줄이기 위해 각각의 레이어의 노드들에 대한 가중치를 업데이트 하는 역전파 (backpropagation)가 일어나게 된다. 컨볼루션 뉴럴 네트워크에서 학습시키는 과정은 주어진 학습데이터를 기반으로, 가장 오류가 적은 출력값을 추출하는 커널을 찾는 과정으로 요약될 수 있다. 커널은 컨볼루션 레이어의 훈련과정에서 자동으로 학습되는 유일한 매개변수이다. 반면, 컨볼루션 뉴럴 네트워크에서 커널의 크기, 커널의 수, 패딩 등은 훈련 과정을 시작하기 전에 설정해야하는 하이퍼 파라미터이며, 따라서, 커널의 크기, 커널의 수, 컨볼루션 레이어 및 풀링 레이어의 숫자에 따라서 각기 다른 컨볼루션 뉴럴 네트워크 모델로 구분될 수 있다.

[0080] 뉴럴 네트워크는 각각의 학습 데이터에 정답이 라벨링 된 학습데이터를 이용하는 교사 학습 (supervised learning), 학습 데이터에 정답이 라벨링 되지 않은 비교사 학습 (unsupervised learning), 반교사학습 (semi supervised learning), 또는 강화학습 (reinforcement learning) 중 적어도 하나의 방식으로 학습될 수 있다. 이때, 뉴럴 네트워크를 통한 출력과 라벨 또는 학습 데이터가 비교되면서 오류가 계산될 수 있고, 계산된 오류는 뉴럴 네트워크에서 역방향(즉, 출력 레이어에서 입력 레이어 방향)으로 역전파 되며, 역전파에 따라 뉴럴 네트워크의 각 레이어의 각 노드들의 연결 가중치가 업데이트 될 수 있다. 업데이트 되는 각 노드의 연결 가중치는 학습률(learning rate)에 따라 변화량이 결정될 수 있다.

[0081] 과적합 (overfitting)은 뉴럴 네트워크에서 학습 데이터에 대한 학습이 과하게 일어나게 됨에 따라 학습 수가 증가함에도 오히려 오류가 증가하는 현상이다. 과적합은 머신러닝 알고리즘의 오류를 증가시키는 원인으로 작용할 수 있으며, 이러한 과적합을 막기 위하여 다양한 최적화 방법이 사용될 수 있다. 과적합을 막기 위해서는 학습 데이터를 증가시키거나, 레귤라이제이션 (regularization), 학습의 과정에서 네트워크의 노드 일부를 비활성화하는 드롭아웃 (dropout), 배치 정규화 레이어 (batch normalization layer)의 활용 등의 방법이 적용될 수 있다.

[0083] 도 3은 본 발명의 일 실시예에 따른 기능적 근적외선 분광 신호의 동잡음을 제거하는 과정을 설명하기 위한 블록구성도를 도시한 도면이다.

[0084] 도 3을 참조하면, 일 실시예에 따른 기능적 근적외선 분광 신호의 동잡음을 제거하는 컴퓨팅 장치는 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환 (S101)하고, 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단 (S102)하고, 미리 학습된 노이즈 제거 모델을 이용하여, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거 (S103)할 수 있다.

[0085] 컴퓨팅 장치는, 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환할 때, 시계열 데이터를 극좌표로 변환하는 동작을 수행할 수 있고, 예를 들어, 프로세서는 시계열 데이터를 하기 수학식 1에 따라 극좌표로 변환할 수 있다.

[0086] [수학식 1]

$$\begin{aligned}\phi_i &= \arccos(x_i) \\ r_i &= \frac{i}{N}\end{aligned}$$

[0087]

[0088] [여기서, N은 시계열 데이터의 타임스탬프 (timestamp)의 수, x_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값을 의미함]

[0089] 컴퓨팅 장치는, 대상으로부터 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이미지 데이터로 변환할 때, 시계열 데이터를 하기 수학식 2에 따라 GASF (gramian angular summation field)로 변환하여 시계열 데이터를 이미지 데이터로 변환할 수 있다.

[0090] [수학식 2]

$$G = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \dots & \cos(\phi_n + \phi_n) \end{pmatrix}$$

[0091]

[0092] [여기서, ϕ_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값의 아크코사인 (arccosine) 값임]

[0093] 컴퓨팅 장치는, 미리 학습된 검출 모델을 이용하여, 변환된 이미지 데이터로부터 노이즈 유무를 판단할 때, 변환된 이미지 데이터로부터 노이즈의 타입을 분류할 수 있다. 이때, 프로세서 (100)는 변환된 이미지 데이터로부터 노이즈의 타입을 스파이크 (spike) 또는 기준선 변화 (baseline shift)로 분류할 수 있다.

[0094] 컴퓨팅 장치는, 기능적 근적외선 분광 신호의 시계열 데이터를 표준화할 수 있다.

[0095] 컴퓨팅 장치는, 미리 학습된 노이즈 제거 모델을 이용하여 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거할 때, 이미지 데이터로부터 노이즈가 제거된 이미지 데이터를 생성할 수 있다.

[0096] 컴퓨팅 장치는, 미리 학습된 노이즈 제거 모델을 이용하여 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거할 때, 미리 학습된 노이즈 제거 모델을 통해 노이즈가 검출된 이미지 데이터로부터 노이즈 타입에 따라 제거 필터를 선택할 수 있다.

[0097] 컴퓨팅 장치는, 미리 학습된 노이즈 제거 모델을 이용하여 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거할 때, 노이즈가 제거된 이미지 데이터를 시계열 데이터로 복원할 수 있다.

[0098] 컴퓨팅 장치는, 기능적 근적외선 분광 신호의 동잡음을 제거할 때, 복수의 채널을 통해 측정된 기능적 근적외선 분광신호의 시계열 데이터를 이용할 수 있다. 그리고, 컴퓨팅 장치는, 노이즈가 검출된 이미지 데이터로부터 노이즈를 제거하는 동작을 수행할 때, 인접한 채널로부터 측정된 시계열 데이터로부터 변환된 각각의 이미지 데이터를 비교함에 따라 노이즈를 검출할 수 있다.

[0100] 이하, 본 발명을 하기의 실시예에 의하여 더욱 상세히 설명한다. 그러나 이들 실시예는 본 발명을 예시하기 위한 것일 뿐이며, 본 발명의 범위가 이들 실시예에 의하여 한정되는 것은 아니다.

[0102] 실시예 1: 합성곱신경망을 이용한 기능성 근적외선 분광신호의 동잡음 검출

[0103] fNIRS 기기로부터 동잡음을 유도하였다. 구체적으로, 동잡음을 만들기 위해 피험자에게 눈썹 들어올리기, 고개 좌우로 흔들기, 고개 좌우로 기울이기, 상체 좌우로 움직이기, 빠르게 머리 좌우로 흔들기 작업을 요청하였으며, 도 4와 같이 동잡음이 포함된 신호 데이터를 획득하였다.

[0104] 이후, 획득한 시계열 데이터를 최소-최대 정규화 (Min-Max normalization)으로 데이터 값 범위를 [-1, 1]로 조정된 뒤, 각 타임포인트의 근적외선 분광신호 값을 하기 수학식 1에 따라 도 5와 같이 arccos 값으로 계산하였다.

[0105] [수학식 1]

$$\begin{aligned}\phi_i &= \arccos(x_i) \\ r_i &= \frac{i}{N}\end{aligned}$$

[0107] [여기서, N은 시계열 데이터의 타임스탬프 (timestamp)의 수, x_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값을 의미함]

[0108] 이어서, 획득한 극좌표 값을 수학식 2에 따른 gram matrix에 대입하여 연산한 뒤 colorbar = 'jet' 타입을 기준으로 연산한 GASF 배열 데이터를 도 6 내지 7과 같이 이미지로 변환하였다.

[0109] [수학식 2]

$$G = \begin{pmatrix} \cos(\phi_1 + \phi_1) & \cos(\phi_1 + \phi_2) & \dots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cos(\phi_2 + \phi_2) & \dots & \cos(\phi_2 + \phi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cos(\phi_n + \phi_2) & \dots & \cos(\phi_n + \phi_n) \end{pmatrix}$$

[0111] [여기서, ϕ_i 는 특정 타임 스탬프 i에서의 기능적 근적외선 분광 신호 값의 아크코사인 (arccosine) 값임]

[0112] 이후, 도 8에서 확인할 수 있듯이, 노이즈 검출의 경우 동잡음 검출 딥러닝 모델을 통해 검출하였으며, 해당 모델은 동잡음이 없는 데이터, 동잡음이 있는 데이터 (비정상적으로 튀는 현상 및 기준선 이동)를 라벨링 (Labeling) 한 뒤 학습된 것을 이용하였다. 상기 딥러닝 모델을 이용해 검출되는 노이즈가 없는 데이터, 비정상적으로 튀는 현상이 있는 동잡음, 기준선이 이동하는 경향이 있는 동잡음의 3가지의 데이터를 분류하였다.

[0113] 동잡음 검출 딥러닝 모델을 통해 검출한 이미지는 동잡음 제거 딥러닝 모델에 적용되어 동잡음이 제거되었으며, 동잡음 제거 딥러닝 모델 훈련의 경우 2차원 노이즈 제거 필터 종류와 노이즈가 있는 데이터로 학습된 것으로, 노이즈 타입에 따라 제거 필터가 다르게 적용하여 노이즈를 제거하였다.


[0115] 실시예 2: 기존 동잡음 검출 방법과의 비교

[0116] 기존의 동잡음 검출은 이전에 획득했던 동잡음이 있는 fNIRS 데이터로 진행했다. 도 9에 따라 획득된 신호 데이터를, 기존 동잡음 검출의 경우 일정 값을 기준으로 벗어날 경우 동잡음이 있다고 판단하였으며, 데이터를 최소-최대 정규화 (Min-Max normalization) 작업을 거쳐 0~1 범위 값으로 조정하여 0.5'를 기준으로 '0.5'보다 값이 클 경우 도 10과 같이 동잡음으로 검출 및 제거하는 방식으로 진행하였다.


[0117] 이후, 기존 동잡음 검출 및 제거 방법과 실시예 1에 따른 동잡음 제거 방법을 통해 획득된 도 11의 나온 1차원 시계열 데이터를 신호 대 잡음비 (SNR : signal to noise ratio)로 비교하였으며, 실험 결과, 두 방법을 비교했을 때 제안하는 방법에서의 SNR가 기존 동잡음 검출 및 제거 방법의 SNR보다 값이 크게 나왔음을 확인되었다.

도면


도면1




도면2




도면3




도면4




도면5




도면6




도면7




도면8



도면9



도면10



도면11

