



(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0145184  
(43) 공개일자 2024년10월07일

- (51) 국제특허분류(Int. Cl.)  
A61B 5/16 (2006.01) A61B 5/00 (2021.01)  
A61B 5/372 (2021.01) G16H 20/70 (2018.01)  
G16H 50/20 (2018.01)
- (52) CPC특허분류  
A61B 5/165 (2013.01)  
A61B 5/372 (2022.01)
- (21) 출원번호 10-2023-0039690  
(22) 출원일자 2023년03월27일  
심사청구일자 2023년03월27일
- (71) 출원인  
인천대학교 산학협력단  
인천광역시 연수구 갯벌로 27, 인천대학교 이노베이션센터(송도동)
- (72) 발명자  
전광길  
인천광역시 연수구 해송로 70, 209동 805호(송도동, 송도웹카운티2단지)
- (74) 대리인  
특허법인충정


전체 청구항 수 : 총 9 항

(54) 발명의 명칭 인공지능을 활용한 감정 예측 방법 및 장치

(57) 요약

본 발명은 인공지능을 이용한 감정 예측 방법에 관한 것으로, 사람의 뇌파(Electro Encephalo Graphy, EEG) 신호로부터 학습데이터를 수집하는 단계; 상기 수집된 학습데이터를 기반으로 감정 예측 모델을 생성하는 단계; 및 상기 생성된 감정 예측 모델을 이용하여 특정 사용자의 명상 전후의 EEG 신호를 기반으로 해당 사용자의 감정을 적어도 하나 이상의 감정으로 분류하고, 스트레스 정도를 예측하는 단계를 포함한다.

대표도 - 도12



(52) CPC특허분류

*A61B 5/7264* (2023.08)

*G16H 20/70* (2021.08)

*G16H 50/20* (2018.01)

---

## 명세서

### 청구범위

#### 청구항 1

컴퓨팅 장치에 의해 수행되는 감정 예측 방법에 있어서,  
 사람의 뇌파(Electro Encephalo Graphy, EEG) 신호로부터 학습데이터를 수집하는 단계;  
 상기 수집된 학습데이터를 기반으로 감정 예측 모델을 생성하는 단계; 및  
 상기 감정 예측 모델을 이용하여 특정 사용자의 명상 전후 EEG 신호를 기반으로 해당 사용자의 감정을 적어도 하나 이상의 감정으로 분류하고, 스트레스 정도를 예측하는 단계를 포함하는 인공지능을 활용한 감정 예측 방법.

#### 청구항 2

제1항에 있어서,  
 상기 특정 사용자의 명상 전후의 EEG 신호는, 명상을 수행하기 직전의 제1 EEG 신호와 명상을 수행한 직후의 제2 EEG 신호를 포함하고,  
 상기 제1 EEG 신호로부터 예측된 제1 스트레스 정도와 상기 제2 EEG 신호로부터 예측된 제2 스트레스 정도를 비교하는 단계를 더 포함하는 것을 특징으로 하는 인공지능을 활용한 감정 예측 방법.

#### 청구항 3

제2항에 있어서,  
 상기 스트레스 정도를 비교하는 단계는, 상기 제1 스트레스 정도와 상기 제2 스트레스 정도를 비교하여 얻은 개선도를 통해 상기 특정 사용자를 위한 최적의 명상 요법을 찾는 단계를 포함하는 인공지능을 활용한 감정 예측 방법.

#### 청구항 4

제1항에 있어서,  
 상기 명상은 영기 명상(Reiki)을 포함하는 것을 특징으로 하는 인공지능을 활용한 감정 예측 방법.

#### 청구항 5

제1항에 있어서,  
 상기 감정 예측 모델을 생성하는 단계는, 수정된 퓨전 퍼지 추론 시스템을 사용하여 감정 예측 모델을 생성하는 것을 특징으로 하는 인공지능을 이용한 감정을 분류하는 방법 및 장치.

#### 청구항 6

청구항 제1항 내지 제5항 중 어느 하나의 항에 따른 방법이 컴퓨터 상에서 수행될 수 있도록 컴퓨터 판독 가능한 기록매체에 저장된 컴퓨터 프로그램.

#### 청구항 7

사람의 뇌파(Electro Encephalo Graphy, EEG) 신호로부터 학습 데이터를 수집하는 데이터 수집부;  
 상기 학습 데이터를 저장하는 데이터베이스;  
 상기 데이터베이스에 저장된 학습 데이터를 기반으로 감정 예측 모델을 생성하는 학습모델 생성부; 및  
 상기 감정 예측 모델을 이용하여 특정 사용자의 명상 전후의 EEG 신호를 기반으로 해당 사용자의 감정을 적어도 하나 이상의 감정으로 분류하고, 스트레스 정도를 예측하는 감정 예측부를 포함하는 인공지능을 활용한 감정 예

측 장치.

## 청구항 8

제7항에 있어서,

상기 특정 사용자의 명상 전후의 EEG 신호는, 명상을 수행하기 직전의 제1 EEG 신호와 명상을 수행한 직후의 제2 EEG 신호를 포함하고,

상기 제1 EEG 신호로부터 예측된 제1 스트레스 정도와 상기 제2 EEG 신호로부터 예측된 제2 스트레스 정도를 비교하는 스트레스 비교부를 더 포함하는 것을 특징으로 하는 인공지능을 활용한 감정 예측 장치.

## 청구항 9

제8항에 있어서,

상기 스트레스 비교부는 상기 제1 스트레스 정도와 상기 제2 스트레스 정도를 비교하여 얻은 개선도를 통해 상기 특정 사용자를 위한 최적의 명상 요법을 찾는 동작을 수행하는 인공지능을 활용한 감정 예측 장치.

## 발명의 설명

### 기술 분야

[0001] 본 발명은 의료사물인터넷(IoMT)을 기반으로 인공지능을 활용한 감정 예측 방법 및 장치에 관한 것이다.

### 배경 기술

[0002] 오늘날 현대인들의 생활 방식은 지속되는 긴장감과 스트레스를 유발하여 정신적 불안을 초래한다. 감각 기능 장애, 우울증, 파괴적 행동, 정서적 비대칭, 불안 등의 다양한 정신장애는 스트레스와 밀접한 관련이 있다.

[0003] 명상은 정신 장애, 스트레스 및 감정 조절을 개선하는 자기 조절 연습으로 일상생활에서 긴장과 불안을 줄이는 효과적인 방법이 될 수 있다.

[0004] 영기 명상(Reiki)은 사람들의 부정적인 감정과 스트레스를 줄이는 데 사용되는 독특한 명상 기법 중 하나로, 신체 또는 정신 건강을 개선하기 위해 시술자의 손바닥을 통해 환자에게 에너지를 전달하는 일본의 에너지 요법 운동이다. 일부 연구에서 영기 명상은 정신 건강 문제와 부정적인 감정을 줄일 수 있는 자연 치유 방법인 것으로 나타났다. 영기 요법과 마사지를 결합하면 주로 정서적 및 신체적 증상 측면에서 불안과 스트레스 감소가 크게 개선될 수 있고, 완화 치료를 받는 환자의 호흡률 감소, 심장 기능 및 통증 완화와 같은 부정적인 감정을 줄이는 생리적 효과가 있다.

[0005] 효과적인 명상 기반 건강 관리 방법을 개발하기 위해 감정의 정확한 식별과 감각 상태의 추정이 필요하지만, 생리학적 신호에는 이해할 수 없는 데이터가 포함되어 있어 스트레스와 관련된 신호만을 구별해내는 것은 어렵다. 또한 특정 명상 루틴을 설계하고 생리적 신호를 분석하기 위한 방법도 제한적이다.

[0006] 스마트 환경 기반의 패턴 인식 및 신호 처리 프레임워크를 사용하여 명상이 감정과 스트레스에 미치는 영향을 조사하는 새로운 방법을 제안할 수 있으나, 스트레스와 불안 자극에 대한 통제된 환경을 구축하고 유지하는 것은 시간과 비용이 많이 들 수 있다. 특히 IoMT의 광범위한 사용에는 상당한 양의 환자에 민감한 데이터가 포함되므로 개인 정보를 유지하고 IoMT의 의료 응용 프로그램에 대한 데이터 보안을 보장하는 것의 필요성은 더욱 중요하다. 그러나 현재 IoMT 시스템의 대다수는 데이터 처리 및 분석을 위해 원격 클라우드 서버에 전적으로 의존하여 클라우드에 데이터를 저장할 뿐이다.

[0007] 데이터 보안 및 개인 정보 보호의 문제를 해소하고 많은 양의 데이터를 처리하기 위해 신뢰도가 높고 실시간으로 처리할 수 있는 시스템을 개발해야 한다.

## 선행기술문헌

### 특허문헌

[0008] (특허문헌 0001) KR 10-2017-0016900 A

## 발명의 내용

### 해결하려는 과제

- [0009] 이와 같은 문제점을 해결하기 위하여, 본 발명은 인공지능을 이용하여 감정을 예측하고 분석하는 방법 및 장치에 관한 것으로, 메타휴리스틱 퍼지 추론 시스템 기반 학습(fMFIS-L)을 통해 생체신호 데이터 중 하나인 EEG 신호로부터 감정을 분류하고, 실시간으로 사용자의 스트레스 지수를 확인할 수 있다.
- [0010] 명상 전후의 EEG 신호로부터 분류된 감정을 비교 및 분석하여 특정 사용자에게 최적화된 명상 요법을 찾을 수 있고, 해당 사용자에게 맞춤형 정보를 실시간으로 제공하여 스트레스 완화에 도움을 줄 수 있다.

### 과제의 해결 수단

- [0011] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 방법은, 사람의 뇌파(Electro Encephalo Graphy, EEG) 신호로부터 학습데이터를 수집하는 단계; 상기 수집된 학습데이터를 기반으로 감정 예측 모델을 생성하는 단계; 및 상기 감정 예측 모델을 이용하여 특정 사용자의 명상 전후 EEG 신호를 기반으로 해당 사용자의 감정을 적어도 하나 이상의 감정으로 분류하고, 스트레스 정도를 예측하는 단계를 포함할 수 있다.
- [0012] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 방법 중 상기 특정 사용자의 명상 전후의 EEG 신호는, 명상을 수행하기 직전의 제1 EEG 신호와 명상을 수행한 직후의 제2 EEG 신호를 포함할 수 있다.
- [0013] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 방법 중 상기 스트레스 정도를 예측하는 단계는, 상기 제1 EEG 신호로부터 예측된 제1 스트레스 정도와 상기 제2 EEG 신호로부터 예측된 제2 스트레스 정도를 비교하는 단계를 더 포함할 수 있다.
- [0014] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 방법에서, 상기 명상은 영기 명상(Reiki)을 포함할 수 있다.
- [0015] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 방법은, 상기 감정 예측 모델을 생성하는 단계에서 수정된 퍼지 퍼지 추론 시스템을 사용한 내용을 더 포함할 수 있다.
- [0016] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 방법은, 컴퓨터 상에서 수행될 수 있도록 컴퓨터 판독 가능한 기록매체에 저장된 컴퓨터 프로그램이 제공될 수 있다.
- [0017] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 장치는, 사람의 뇌파(Electro Encephalo Graphy, EEG) 신호로부터 학습 데이터를 수집하는 동작을 수행하는 데이터 수집부; 상기 학습 데이터를 저장하는 데이터 베이스; 상기 데이터베이스에 저장된 학습 데이터를 기반으로 감정 예측 모델을 생성하는 동작으로 수행하는 학습모델 생성부; 및 상기 감정 예측 모델을 이용하여 특정 사용자의 명상 전후 EEG 신호를 기반으로 해당 사용자의 감정을 적어도 하나 이상의 감정으로 분류하고, 스트레스 정도를 예측하는 동작을 수행하는 감정 예측부를 포함할 수 있다.
- [0018] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 장치는, 상기 특정 사용자의 명상 전후의 EEG 신호는, 명상을 수행하기 직전의 제1 EEG 신호와 명상을 수행한 직후의 제2 EEG 신호를 포함할 수 있다.
- [0019] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 장치는, 상기 제1 EEG 신호로부터 예측된 제1 스트레스 정도와 상기 제2 EEG 신호로부터 예측된 제2 스트레스 정도를 비교하는 동작을 수행하는 스트레스 비교부를 더 포함할 수 있다.
- [0020] 본 발명의 일 실시예에 의한 인공지능을 이용한 감정 예측 장치는, 상기 제1 스트레스 정도와 상기 제2 스트레스 정도를 비교하여 얻은 개선도를 통해 상기 특정 사용자를 위한 최적의 명상 요법을 찾는 동작을 수행할 수 있다.

### 발명의 효과

- [0021] 여러 IoT 기반 의료 감지 기술은 IoMT 기반 의료 애플리케이션에서 많은 양의 데이터를 생성하고 저장하기 때문

에 데이터 보안 및 개인 정보 보호가 문제되고 있다. 본 발명에서는 메타휴리스틱 퍼지 추론 시스템 기반 학습(fMFIS-L)으로 EEG 신호에서 감정을 분류하여 스마트 홈의 의료 응용 프로그램의 요구 사항에 따라 의사 결정을 빠르게 수행하고 실시간 처리 서비스를 제공함으로써 위 문제점을 해결할 수 있다.

[0022] 본 발명에서는 현대 사회에서 불안을 효과적으로 감소시킬 수 있는 명상 기법과 그것이 건강관리에 미치는 영향을 분석하여, 사용자에게 최적의 긴장 완화 요법을 제시할 수 있다. 특히, 명상을 전후로 사용자의 EEG 신호를 수신하고 감정을 분류하여 스트레스가 완화된 정도를 수치로 비교할 수 있다.

[0023] 한편, EEG 신호에서 감정을 분류하는 과정과 관련하여, 여러 ANFIS 학습자의 적절한 융합 모델과 혁신적인 AIG(gunner algorithm)를 사용하여 EEG 분석을 위한 효과적인 예측 체계가 개발되어왔다. AIG 알고리즘은 군집 절차의 솔루션 벡터 특성의 결과로 검색 공간에서 의미 있는 탐색을 할 수 있다. 다양한 솔루션으로 로컬 옵티마를 피할 수 있다는 특징을 갖고 있고, 다양한 모양에 대한 최적의 경로 및 다차원의 기능을 제공한다. 가정에서 개인의 스트레스 수준을 분류하는 데 사용할 수 있는 메타휴리스틱 퍼지 추론 시스템 기반 학습(fMFIS-L) 모델은 더 나은 의사 결정을 위해 상기 AIG 알고리즘을 이용한 접근 방식을 통합한다. 자동화되고 매우 효율적인 형태의 스트레스 평가 방식을 사용하기 때문에 스트레스를 보다 효과적으로 식별하고 관리할 수 있다. EEG 신호, fMFIS-L 기반 분류 및 IoMT 플랫폼을 활용하면 스트레스 진단 및 분류의 정확도를 크게 향상시킬 수 있다.

### 도면의 간단한 설명

[0024] 도 1은 본 발명의 일 실시 예에 따른 감정 예측 장치의 구성을 나타내는 도면이다.

도 2는 본 발명의 일 실시 예에 따라 특정 사용자의 감정을 예측하고 명상 전후의 개선도를 평가하여, 해당 사용자에게 최적의 명상 요법을 제공하기 위한 일반적인 절차를 나타낸 도면이다.

도 3은 인공지능을 이용하여 사람의 감정을 식별하기 위하여, IoMT 환경에서 EEG 신호를 받아 감정과 스트레스를 감지하는 상황을 나타낸 도면이다.

도 4는 본 발명의 일 실시 예에 따라 감정 예측 모델을 생성하는 방법을 설명하는 순서도이다.

도 5는 인공지능을 이용하여 사람의 감정을 식별하기 위하여, EEG 신호를 세가지로 분류한 것으로, 긍정적, 중립적, 부정적 감정의 신호를 나타내는 도면이다.

도 6은 인공지능을 이용하여 사람의 감정을 식별하기 위하여, 퍼지 추론 시스템을 기반으로 한 학습 분류기의 전반적인 구조를 나타낸 도면이다.

도 7은 인공지능을 이용하여 사람의 감정을 식별하기 위하여, 퓨전 러닝(fusion learning)의 확장된 구조를 나타낸 도면이다.

도 8은 인공지능을 이용하여 사람의 감정을 식별하기 위하여, 리젝션(Rejection)영역과 표준화된 감정 통계량의 분포도를 나타낸 도면이다.

도 9는 인공지능을 이용하여 사람의 감정을 식별하기 위하여, 임의의 EEG 신호를 토대로한 컨버전스의 과정에서 최적의 손실을 위해 적절한 결과 매개변수(p, q 및 r)를 얻는데 있어서 AIG, 수정된 AIG 및 fast AIG 알고리즘을 비교한 것을 나타낸 도면이다.

도 10은 인공지능을 이용하여 사람의 감정을 식별하기 위하여, 스트레스를 완화하기 위한 일련의 절차를 위해 감정을 평가한 것으로, (a)는 리커드 척도(Likert scale)를 통한 평가, (b)는 최적화된 ANFIS 퓨전 러닝 구조를 기반으로 비교한 것을 나타낸 도면이다.

도 11은 인공지능을 이용하여 사람의 감정을 식별하기 위하여, 보이지 않는 EEG 신호를 토대로 감정을 분류한 것의 손실을 계산한 것으로, (A) 부정적 감정 (B) 긍정적 감정 (C) 중립적 감정을 나타낸 도면이다.

### 발명을 실시하기 위한 구체적인 내용

[0025] 본 발명의 목적, 특정한 장점들 및 신규한 특징들은 첨부된 도면들과 연관되어지는 이하의 상세한 설명과 바람직한 실시예들로부터 더욱 명백해질 것이다. 이때, 각각의 도면에서 동일한 구성요소는 가능한 동일한 부호로 나타낸다. 또한, 이미 공지된 기능 및/또는 구성에 대한 상세한 설명은 생략한다.

[0026] 이하에 개시된 내용은, 다양한 실시 예에 따른 동작을 이해하는데 필요한 부분을 중점적으로 설명하며, 그 설명

의 요지를 흐릴 수 있는 요소들에 대한 설명은 생략한다. 또한 도면의 일부 구성요소는 과장되거나 생략되거나 또는 개략적으로 도시될 수 있다. 각 구성요소의 크기는 실제 크기를 전적으로 반영하는 것이 아니며, 따라서 각각의 도면에 그려진 구성요소들의 상대적인 크기나 간격에 의해 여기에 기재되는 내용들이 제한되는 것은 아니다.

- [0027] 본 발명의 실시예들을 설명함에 있어서, 본 발명과 관련된 공지기술에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략하기로 한다. 그리고, 후술되는 용어들은 본 발명에서의 기능을 고려하여 정의된 용어들로서 이는 사용자, 운용자의 의도 또는 관례 등에 따라 달라질 수 있다. 그러므로 그 정의는 본 명세서 전반에 걸친 내용을 토대로 내려져야 할 것이다. 상세한 설명에서 사용되는 용어는 단지 본 발명의 실시 예들을 기술하기 위한 것이며, 결코 제한적이어서는 안 된다. 명확하게 달리 사용되지 않는 한, 단수 형태의 표현은 복수 형태의 의미를 포함한다. 본 설명에서, "포함" 또는 "구비"와 같은 표현은 어떤 특성들, 숫자들, 단계들, 동작들, 요소들, 이들의 일부 또는 조합을 가리키기 위한 것이며, 기술된 것 이외에 하나 또는 그 이상의 다른 특성, 숫자, 단계, 동작, 요소, 이들의 일부 또는 조합의 존재 또는 가능성을 배제하도록 해석되어서는 안 된다.
- [0028] 또한, 제1, 제2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되는 것은 아니며, 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다.
- [0029] 이하에서는, 첨부된 도면들을 참조하여 본 발명의 바람직한 실시형태를 상세히 설명하기로 한다.
- [0030] 도 1은 본 발명의 일 실시예에 따른 감정 예측 장치의 구성을 나타내는 도면이다.
- [0031] 도 1을 참조하면, 본 발명의 일 실시 예에 따른 감정 예측 장치(100)는 데이터 수집부(110), 데이터베이스(120), 학습모델 생성부(130), 감정 예측부(140) 및 스트레스 비교부(150)를 포함할 수 있다. 도 1에 도시된 구성요소들은 감정 예측 장치를 구현하는데 있어서 필수적인 것은 아니어서, 본 명세서 상에서 설명되는 감정 예측 장치는 위에서 열거된 구성요소들 보다 많거나 또는 적은 구성요소들을 가질 수 있다.
- [0032] 도 1 및 도 12를 참조하면, 학습 데이터 수집 단계(S1210)에서, 데이터 수집부(110)는 특정 사용자의 감정 상태를 예측하기 위한 머신러닝모델(machine learning model)을 생성하기 위하여 필요한 학습 데이터를 수집할 수 있다. 여기서, 학습 데이터는 뇌파(EEG) 신호를 포함할 수 있다.
- [0033] 도 3은 IoMT 환경에서 EEG 신호에 대한 정보를 수신하는 과정을 보여준다.
- [0034] 상기 학습 데이터는 다음과 같이 측정된 EEG 신호로부터 추출한 데이터를 포함할 수 있다. 평균 연령은 21.12세( $SD = 2.33$ ), 참가자의 50%는 남성으로 구성된 모집단 전체 30명을 대상으로 수집한 데이터로 지원자들을 위해 음악이 포함된 40개의 비디오를 보여줌으로써 분노, 불안, 우울 등의 감정 상태를 불러일으킨다. 각 비디오는 영화 및 일상 뉴스 이벤트에서 발췌한 30초이며, 두 명의 심리학자로부터 정서적 영향력을 확인한 영상이다. 상기 뇌파(EEG) 신호를 수신하기 위한 전극은 특수 젤을 사용하여 두피 표면에 배치하고, 국제 시스템에 따라 19개 채널을 두었다. 각 지원자의 EEG 신호는 약 60초 동안 기록되고, 잡음이 없는 저역 통과 필터를 사용하여 128Hz로 필터링한다.
- [0035] 도 5는 긍정적, 중립적 및 부정적 감정의 윈도우(windowed) EEG 신호의 샘플이다.
- [0036] 데이터 베이스(120)는 데이터 수집부(110)을 통해 수집된 EEG 신호 데이터를 저장할 수 있다. 데이터베이스(120)는 저장된 EEG 신호 데이터를 학습모델 생성부(130)로 제공할 수 있다.
- [0037] 도 1 및 도 12를 참조하면, 감정 예측 모델 생성 단계(S1220)에서, 학습모델 생성부(130)는 데이터베이스(120)로부터 획득한 데이터를 학습하여 EEG 신호 데이터를 기반으로 감정을 예측하기 위한 감정 예측 모델을 생성할 수 있다.
- [0038] 좀 더 구체적으로, 학습 모델 생성부(130)는 데이터베이스(120)로부터 획득한 학습 데이터를 기반으로 머신러닝 알고리즘의 변수를 설정할 수 있다. 여기서, 머신러닝 알고리즘의 변수는 입력 벡터에 해당하는 독립 변수와 출력 벡터에 해당하는 종속 변수를 포함할 수 있다.
- [0039] 학습모델 생성부(130)는 학습 데이터 중 EEG 신호 데이터를 머신러닝 알고리즘의 독립 변수로 설정할 수 있고, 감정 상태 데이터를 해당 알고리즘의 종속 변수로 설정할 수 있다.
- [0040] 학습모델 생성부(130)는 독립 변수 및 종속 변수로 설정된 학습 데이터를 기반으로 미리 결정된 머신러닝 알고

리즘을 수행하여 감정 상태 예측 모델을 생성할 수 있다. 이 경우, 상기 머신러닝 알고리즘으로는 메타휴리스틱 퍼지 추론 시스템 기반 학습(fMFIS-L) 모델이 사용될 수 있으며 반드시 이에 제한되지는 않는다.

- [0041] 학습모델 생성부(130)는 이러한 머신러닝 과정을 통해 생성된 감정 예측 모델을 데이터베이스(120)에 저장할 수 있다.
- [0042] 도 1 및 도 12를 참조하면, 스트레스 정도 예측 단계(S1230)에서, 감정 예측부(140)는 미리 학습된 감정 예측 모델을 이용하여 특정 사용자의 EEG 신호를 기반으로 해당 사용자의 감정 상태를 예측할 수 있다.
- [0043] 즉, 감정 예측부(140)는 특정 사용자의 EEG 신호를 수신하여 상기 EEG 신호로부터 추출한 데이터 획득하고, 이를 미리 학습된 감정 예측 모델에 입력하면 현재 해당 사용자의 감정상태가 출력되어 이를 예측할 수 있다.
- [0044] 도 2에 도시된 바와 같이, 스트레스 정도 비교 단계(S1240)에서, 스트레스 비교부(150)에서는 감정 예측부(140)에서 특정 사용자의 명상 전 제1 EEG 신호와 명상 후 제2 EEG 신호를 수신하여 예측한 제1 감정과 제2 감정 상태를 토대로, 명상 전 제1 스트레스 정도와 명상 후 제2 스트레스 정도를 예측하고 비교하여 개선도(improvement)를 수치화할 수 있다.
- [0045] 상기 스트레스 비교부(150)는 개선도 정보를 활용하여 해당 사용자를 위한 최적의 명상 요법을 제공할 수 있다.
- [0046] 좀 더 구체적으로, 상기 EEG 신호를 수신하는 과정에서 참가자들은 동시에 설문지에 대한 답변을 작성할 수 있다. 상기 설문지는 스트레스를 평가하는 두 가지 질문을 포함할 수 있다. "지금 필요한 일을 관리할 수 없다는 느낌이 드십니까?" 그리고 "지금 스트레스와 초조함을 느끼십니까?"로 각 항목은 0점("전혀 그렇지 않음")에서 6점("매우 그렇다")까지 리커트 척도로 평가한 것으로, 이 과정에서 스트레스 데이터를 수집할 수 있다. 상기 스트레스 데이터가 클수록 불안이나 스트레스 정도가 높은 것을 의미한다. 전문가 의견에 따르면 점수가 4보다 높으면 해당 감정에 명확한 레이블이 지정되지만, 2에서 4 사이이면 재평가를 위해 다시 더 많은 질문을 하고, 그렇지 않으면 다른 감정을 검사할 수 있다.
- [0047] 스트레스 비교부(150)에서는, 참가자들을 두 그룹으로 나누고, 두 번째 그룹만 레이키 명상을 2주 동안 수행하는 것을 포함할 수 있다. 감정 변화와 스트레스 수준에 미치는 영향을 구별하기 위해 발목과 발, 7개의 차크라를 포함한 9개의 주요 지점에서 14일 연속 하루 30분 동안 3개의 영기 명상을 수행할 수 있다. 각 비디오에는 세 가지의 뚜렷한 감정 상태가 포함될 수 있다. 명상 전후 뇌파 신호를 기록하고, 리커트 척도(Likert scale)로 스트레스 정도를 측정할 수 있고, 부정적인 감정 분류를 결정하기 위해 제안한 최적화된 퓨전 학습 방법을 적용할 수 있다.
- [0048] 도 4은 본 발명의 일 실시예에 따라 감정 예측 모델을 생성하는 단계(S1220)를 설명하는 순서도이다. 본 실시예에 따른 감정 예측 모델 생성 단계(S1220)는 감정 예측 장치(100)에 의해 수행될 수 있다. 도시된 순서도에서는 감정 예측 모델 생성 단계(S1220)를 복수 개의 단계로 나누어 기재하였으나, 적어도 일부의 단계들은 순서를 바꾸어 수행되거나, 다른 단계와 결합되어 함께 수행되거나, 생략되거나, 세부 단계들로 나뉘어 수행되거나, 또는 도시되지 않은 하나 이상의 단계가 부가되어 수행될 수 있다.
- [0049] 도 4를 참조하면, 본 발명의 일 실시예에 따른 감정 예측 장치(100)는 특정 사용자의 감정을 예측하기 위한 학습 데이터를 수집할 수 있다(S410). 여기서, 학습 데이터는 사람의 생체신호 중 EEG 신호로부터 추출한 데이터를 포함할 수 있다. 상기 학습 데이터는 특정인을 대상으로 일정 기간 동안 수집되거나 혹은 불특정 다수의 사람들을 대상으로 일정 기간 동안 수집될 수 있다.
- [0050] 감정 예측 장치(100)는 수집된 학습 데이터를 전처리하는 동작을 수행할 수 있다(S420). 일 예로, 감정 예측 장치(100)는 특징(features) 추출 프로세스 중 이상치(outlier)를 제거하기 위한 감지 기술을 활용할 수 있다. 또한, EEG 신호를 기록, 처리 및 해석하기 위하여 미리 정해진 프로토콜(무선 통신 기술)이 절차에 사용될 수 있고, DWT(Discrete Wavelet Transform) 방식으로 전처리한 하위 대역(sub-band data)들로 변환시킬 수 있다.
- [0051] 상기 데이터 전처리 단계(S420)에서는 2개의 필터와 2개의 샘플링 계수를 가진 다운 샘플러를 사용할 수 있다. 또한 적절한 분석을 얻기 위하여 생리학적인 신호를 윈도우잉(windowing)할 수 있다. 각 윈도우를 보존하기 위하여 그 다음 윈도우와 겹치고, 각 윈도우의 길이는 연속된 두 윈도우 사이의 중첩(20~50%)을 고려하여 설정된 시간을 토대로 적절한 특징들을 추출할 수 있는 방식으로 결정될 수 있다. 분리되지 않은 신호는 평가를 복잡하게 하므로, EEG 신호를 분할하고 윈도우 청크(windowed chunks)를 생성하는 것은 중요하다.
- [0052] 감정 예측 장치(100)는 EEG 신호 데이터에서 특징을 찾아내고 이를 토대로 상기 데이터를 벡터로 변환하는 작업인 특징(feature) 추출 동작을 수행할 수 있다(S430). 자기상관(auto-correlation) 시퀀스 FFT(Fast Fourier

Transform) 신호를 계산하여 Welch's 방법과 같은 비모수적 방법을 사용하여 추정될 수 있다. Welch's 파워 스펙트럼은 수정된 주기도 파워 스펙트럼 밀도 추정 값(Periodogram)에 L 세그먼테이션(segmentation)을 고려하여 계산될 수 있다.

### 수학식 1

$$P_{xx}^w = \frac{1}{L} \sum_{i=0}^{L-1} P_{xx}(f)^{(i)}$$

길이가 N인 신호에 대한 샘플 엔트로피는 [수학식2]로 주어진다.

### 수학식 2

$$SampEnt(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \frac{C^{m+1}(r)}{C^m(r)} \right\}$$

여기서  $C^m(r)$ 는 m포인트(거리에 기초한)의 두 시퀀스가 유사할 확률을 나타내며,  $C^{m+1}(r)$ 은 m+1 포인트들에서 두 시퀀스의 유사성 확률이다.

N이 유한한 값일 때 추정된 샘플 엔트로피는 [수학식 3]으로 표현될 수 있다.

### 수학식 3

$$SampEnt(m, r) = -\ln \frac{C^{m+1}(r)}{C^m(r)}$$

여기서 m은 학습된 시퀀스의 길이이다.

r은 시퀀스의 유사성이 허용되는 허용 오차이며 일반적으로 N 값의 20%로 선택된다.

매개변수 m 및 r은 2와 같고 입력 신호 표준편차 20% 라고 가정할 수 있다.

스펙트럼 엔트로피라는 또 다른 엔트로피가 정의되었으며, EEG 신호에 대한 상대적인 스펙트럼 파워를 포함하고 [수학식 4]에 따라 계산될 수 있다.

### 수학식 4

$$H(f) = \frac{-1}{\ln(N)} \sum_{i=1}^N p_i \ln(p_i)$$

여기서  $p_i$ 와 N은  $i_{th}$  주파수 스펙트럼 및 주파수의 총 개수이며, 모든  $p_i$ 의 합은 1이다.

반복되는 과정을 통해 프랙탈(Fractals)은 더 성장하는데, 이러한 변형은 주로 시작지점에서 구성되고 형성된다.

고정되지 않은 EEG 신호를 설명하기 위해 Katz 및 Higuchi 방법을 포함한 무작위 프랙탈 차원을 사용할 수 있다.

감정 예측 장치(100)는 훈련 데이터 셋(training data set)을 기반으로 미리 결정된 머신러닝 알고리즘을 수행하여 감정 예측 모델을 생성할 수 있다(S440). 이 때, 상기 머신러닝 알고리즘으로는 최소자승법(least square method)과 역전파(back propagation) 알고리즘을 통합한 퍼지 추론 시스템(fuzzy inference system)을 기반으

로한 구조를 학습할 수 있으며 반드시 이에 제한되지는 않는다.

[0068] 일 예로, 상기 퍼지 추론 시스템에는 입력  $x$  및  $y$ 와 출력  $f$ 가 있고, 다음과 같이 표현할 수 있는 일련의 규칙이 있다.

### 수학식 5

[0069] 
$$\begin{aligned} \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 &\rightarrow f_1 = P_1x + Q_1y \\ \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 &\rightarrow f_2 = P_2x + Q_2y \end{aligned}$$

[0070] 위 방정식에서,  $A_1$ ,  $A_2$  및  $B_1$ ,  $B_2$ 는 각각 입력값  $x$ ,  $y$ 의 멤버십 함수(membership functions)이며,  $P_1$ ,  $Q_1$  및  $P_2$ ,  $Q_2$ 는 Takagi-Sugeno 퍼지 추론 모델의 선형 매개변수이다.

[0071] 또한, 비퍼지화(defuzzification) 아웃라인의 평균 중심(mean center)은 비퍼지화(defuzzification)화에 의해 결정될 예정이므로 그 출력은 다음 [수학식 6]과 같이 결정된다

### 수학식 6

[0072] 
$$f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} = \overline{w_1}f_1 + \overline{w_2}f_2$$

### 수학식 7

[0073] 
$$\overline{w_1} = w_1 \times (w_1 + w_2)^{-1}, \quad \overline{w_2} = w_2 \times (w_1 + w_2)^{-1}$$

[0075] 도 6에 도시된 바와 같이, 퍼지 추론 시스템 기반 학습의 구조는 5개의 레이어를 포함할 수 있다.

[0076] 레이어 1 : 각  $i$ 노드는 다음과 같은 내부 함수를 갖는다.

### 수학식 8

[0077] 
$$\begin{aligned} O_{1,i} &= \mu A_i(x), \text{ for } i = 1, 2 \\ O_{1,i} &= \mu B_i(x), \text{ for } i = 3, 4 \end{aligned}$$

[0078] 각 노드의 매개 변수들은 그 노드의 퍼지 세트에서의 멤버십 함수의 모양을 결정한다. 벨 함수(bell function s)는 대개 [수학식 9]와 같은 형태의 퍼지 세트의 멤버십 함수로 표현된다.

### 수학식 9

[0079] 
$$\mu_{A(x)} = \left( 1 + \left| \frac{x - c_i}{a_i} \right|^{2bi} \right)^{-1}$$

[0080]  $x$ 는 노드 $i$ 와 적응형 매개 변수로 불리는  $S1 = \{a_i, b_i, c_i\}$ 에서 입력 값을 나타낸다.

[0081] 레이어 2 : 계층의 각 노드는 룰(rule)의 활성화 정도를 계산한 값을 의미한다.

## 수학식 10

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2$$

$\mu_{A_i}(x)$  는  $A_i$ 의 세트에서 멤버십  $x$ 의 정도를 나타내고,  $\mu_{B_i}(y)$  는  $B_i$ 의 세트에서 멤버십  $y$ 의 정도를 나타낸다.

**레이어 3** : 이 계층에서  $i$ 번째 노드는 모든 룰(rules)의 액티비티 세트에 대비하여  $i$ 번째 룰(rule)의 액티비티의 비율을 정규화(normalize)한다.

## 수학식 11

$$O_{3,i} = \overline{w_i} = w_i \times (w_1 + w_2)^{-1}, \quad i = 1, 2$$

여기서  $w_i$ 는  $i$ 번째 룰의 정규화된 활동 정도를 나타낸다.

**레이어 4** : 이 계층에서 각 노드의 출력은 [수학식 12]를 기반으로 얻는다.

## 수학식 12

$$O_{4,i} = \overline{w_i} f_i = \overline{w_i} (p_i x + q_i y + r_i)$$

여기서  $S_2 = \{p_i, q_i, r_i\}$  세트는 결과 매개변수라고 한다.

**레이어 5** : 이 계층에서 각 노드는 다음과 같이 최종 출력 값을 계산한다(노드 수는 출력 수와 동일함).

## 수학식 13

$$O_{5,i} = \sum_i \overline{w_i} f_i = \sum_i w_i f_i \times (\sum_i w_i)^{-1}$$

수정된 AIG 알고리즘을 사용하여 ANFIS 학습을 개선할 수 있다.

알고리즘의 종료 조건은 분류 과정의 오류의 최소값을 계산하는 것을 기반으로 한다. 알고리즘이 반복되는 절차의 회수의 특정해서 실현되지는 않는다고 가정할 수 있다.

이 경우 최상의 분류 모델과 일치하는 매개 변수가 선택되는데, 해당 변수는 다른 ANFIS 구조보다 분류 학습에 더 큰 영향을 미친다.

도 7은 확장된 학습 구조를 일반 도식으로 나타낸 것이다.

첫 번째 단계는 학습 데이터를 활용하여 퍼지 추론 시스템 기반 학습 풀(learning pool)을 분류 퓨전 모델(classification fusion model)로 구현한다.

각 ANFIS 분류기는 결과 매개변수( $p$ ,  $q$  및  $r$ )를 초기화하고, 최초에는 무작위로 설정된다. 매개변수의 변화 폭은 0에서 1 사이이다.

학습 데이터를 이용하고, 평균 오차 값이 가장 낮은 구조를 결정한다. 해당하는 매개변수는 AIG 알고리즘에 입력되고, 이로써 이상적인 반응으로의 컨버전스는 가속화되고 조금 더 정확해진다.

풀 구조(pool structure)의 회귀 퓨전(regression fusion), 평균 정확도, 최상의 매개변수를 평가하기 위해 5번 반복할 수 있다. 정확도가 가장 높은 그리드(grid)가 가장 잘 맞는 매개변수이다. 결과 매개변수의 최상의

값을 찾는 것은 수정된 AIG 알고리즘을 넓은 범위의 최적 값을 쉽게 검색할 수 있게 한다.

[0102] 상기 감정 예측 모델을 생성하는 단계(S440)에서는, 특정 사용자의 EEG 신호로 부터 예측된 감정과 해당 사용자가 체크한 스트레스 수준 간의 상관관계를 평가하는 것을 포함할 수 있다.

[0103] 첫 번째 단계에서 ITSTT(independent two-sample t-test)를 사용한다. 평균이 다양한지 테스트하기 위한 t-통계량은 결과 값으로써 계산될 수 있다.

#### 수학식 14

$$t = (\overline{X_1} - \overline{X_2}) \times \left( S_p \sqrt{\frac{2}{n}} \right)^{-0.5}$$

#### 수학식 15

$$s_p = \sqrt{\frac{s_{X_1}^2 + s_{X_2}^2}{2}}$$

[0106]  $s_p$ 는  $n = n_1 = n_2$  및  $s_{X_1}^2$  및  $s_{X_2}^2$ 에 대한 풀링(pooling)된 표준 편차이며, 두 샘플 분산의 편향되지 않은 추정 값이다.

[0107] t의 분모는 두 평균 간 차이 값의 표준 오차를 의미한다.

[0109] 도 8을 참고하면, 테스트된 모든 샘플에 대해 신뢰 구간은 95%보다 크다.

[0110] 감정상태와 스트레스 수준의 상관관계에 대한 p-value를 계산한 후에 귀무가설( $H_0$ )은 기각되었다.

[0111] 분노(Ang), 우울(Dpr), 불안(Anx)의 세 가지 등급을 모두 고려하여 그 결과값을 표로 나타냈다. 또한 교차 검증(CV = 5) 전략을 사용하여 제안된 디자인의 성능을 평가할 수 있다.

[0112] 스트레스 레이블(labels)을 개인의 감정으로 분류하고 할당할 수 있다. 접근 방식의 성능을 평가하기 위하여는 정확도 평가 방법과 통계 분석이 활용된다. 다양한 수준의 스트레스는 먼저 혼동 행렬(Confusion Matrix)을 구성한 다음에 다중 클래스 절차(multi-class procedure)에서 OvO(One-vs-One)를 기반으로 정확도를 평가하여 정량화된다.

[0113] 표 1과 표 2는 상관성 1단계 결과를 나타낸다.

[0114] 표 1에서는 감정 상태와 스트레스 수준 간의 상관 관계 결과 값을 나타내고 있다.

**표 1**

[0115]

| Groups  | Emotions   | 1 <sup>st</sup> week |                 |         | 2 <sup>nd</sup> week |                 |         |
|---------|------------|----------------------|-----------------|---------|----------------------|-----------------|---------|
|         |            | Coefficient          | 95% CI          | p-Value | Coefficient          | 95% CI          | p-Value |
| Group 1 | Angry      | -5.94                | (-10.2 to 1.79) | 0.02    | -3.873               | (-8.81 to 0.21) | <0.01   |
|         | Anxiety    | -2.731               | (-7.36 to 2.19) | 0.28    | -1.389               | (-5.73 to 1.08) | 0.16    |
|         | Depression | 2.012                | (-1.04 to 5.21) | 0.19    | 1.732                | (-2.08 to 5.44) | 0.31    |
| Group 2 | Angry      | -6.853               | (-10.2 to 1.79) | <0.01   | -3.455               | (-9.84 to 2.13) | <0.01   |
|         | Anxiety    | -4.848               | (-8.49 to 0.61) | 0.08    | -3.299               | (-8.68 to 0.31) | 0.03    |
|         | Depression | 3.571                | (-0.04 to 8.53) | 0.05    | 3.873                | (-1.17 to 7.14) | 0.07    |

[0116] 표 1에 따르면, 동영상 자극으로 유발되는 감정을 측정한 결과, 분노와 불안 감정이 스트레스와 더 관련이 있음을 알 수 있다.

- [0117] 특정 사용자가 기록한 스트레스 평가 점수를 통해 유발된 감정을 추론할 수 있다. 결과 값의 평균에 따르면 분노, 불안 및 우울은 관계성을 보인다.
- [0118] [95% CI, ( 9.325 ~ 2.205), and p-Value =< 0.0147],
- [0119] [95% CI, ( 7.202 ~ 0.695), and p-Value =< 0.0987],
- [0120] [95% CI, ( 1.625 ~ 6.298), and p-Value =< 0.1934],
- [0121] 표 1에서는, 리커트 척도를 기준으로 측정된 스트레스와 부정적인 감정들의 관계성이 중요하다는 것을 추론했다.
- [0123] 표 2에서는, 스트레스 수준과 뇌파 신호로부터 감지된 감정 사이의 관계를 측정하는 것이 의미가 있음을 나타낸다. 유발된 감정을 추론하는 과정은 제안된 퍼지 퓨전 학습 방법을 사용하여 수행되었다.

표 2

| Groups  | Emotions   | 1 <sup>st</sup> week |                 |         | 2 <sup>nd</sup> week |                  |         |
|---------|------------|----------------------|-----------------|---------|----------------------|------------------|---------|
|         |            | Coefficient          | 95% CI          | p-Value | Coefficient          | 95% CI           | p-Value |
| Group 1 | Angry      | -4.834               | (8.69-0.41)     | 0.03    | -4.978               | (-9.83 to 1.94)  | 0.01    |
|         | Anxiety    | 6.128                | (-2.91 to 9.31) | 0.28    | 3.371                | (-1.18 to 6.14)  | 0.22    |
|         | Depression | -2.248               | (-4.52 to 1.47) | 0.35    | -4.034               | (-7.15 to 1.84)  | 0.24    |
| Group 2 | Angry      | -3.271               | (-9.73 to 3.08) | <0.01   | -6.873               | (-10.12 to 1.82) | <0.01   |
|         | Anxiety    | 4.972                | (-0.06 to 9.03) | 0.02    | 6.173                | (-0.18 to 10.15) | 0.09    |
|         | Depression | -5.413               | (-9.61 to 2.3)  | 0.13    | -2.07                | (-5.83 to 2.09)  | 0.10    |

- [0124]
- [0125] 평균 값 결과는 분노, 불안, 우울 감정과 스트레스 수준의 상대적인 관계가 다음과 같다는 것을 증명한다.
- [0126] [95% CI, (-9.974~1.253), and p-Value =< 0.0092]
- [0127] [95% CI, (- 0.684 ~ 8.131), and p- Value =< 0.1431]
- [0128] [95% CI, (- 6.493 ~ 1.951), and p- Value = < 0.1951].
- [0129] 리커트 척도를 기반으로 기록된 점수에서 유추한 결과와 제안된 fMFIS-L 방법 사이의 상관관계도 중요한데(p-Value =< 0.005), 제안된 최적화 ANFIS 학습 방법은 사람이 감정 분류에 효과적으로 활용될 수 있을 것으로 기대된다.
- [0131] 표 3에서는, EEG 신호로부터 감정을 인식하는 데 사용되는 유사 퍼지 퓨전 기반 학습 방법 중 분류 정확도를 기준으로 비교한 것이다.

표 3

| Data Dividing | Classifier                | Signals                                                    |                                                            |                                                            |
|---------------|---------------------------|------------------------------------------------------------|------------------------------------------------------------|------------------------------------------------------------|
|               |                           | Max ( $\pm$ STD)                                           | Average ( $\pm$ STD)                                       | Min ( $\pm$ STD)                                           |
| 5-fold (1)    | Fuzzy structure           | 0.92 $\pm$ (0.003)                                         | 0.91 $\pm$ (0.015)                                         | 0.90 $\pm$ (0.028)                                         |
|               | ANFIS structure           | 0.92 $\pm$ (0.004)                                         | 0.91 $\pm$ (0.019)                                         | 0.90 $\pm$ (0.027)                                         |
|               | Fusion learning           | 0.92 $\pm$ (0.011)                                         | 0.91 $\pm$ (0.019)                                         | 0.90 $\pm$ (0.028)                                         |
|               | Optimized Fusion learning | <b>0.92 <math>\pm</math> (0.003) <math>\uparrow</math></b> | <b>0.91 <math>\pm</math> (0.014) <math>\uparrow</math></b> | <b>0.90 <math>\pm</math> (0.023) <math>\uparrow</math></b> |
| 5-fold (2)    | Fuzzy structure           | 0.91 $\pm$ (0.008)                                         | 0.91 $\pm$ (0.021)                                         | 0.90 $\pm$ (0.032)                                         |
|               | ANFIS structure           | 0.91 $\pm$ (0.008)                                         | 0.91 $\pm$ (0.024)                                         | 0.90 $\pm$ (0.028)                                         |
|               | Fusion learning           | 0.92 $\pm$ (0.011)                                         | 0.91 $\pm$ (0.022)                                         | 0.90 $\pm$ (0.032)                                         |
|               | Optimized Fusion learning | <b>0.92 <math>\pm</math> (0.007) <math>\uparrow</math></b> | <b>0.91 <math>\pm</math> (0.018) <math>\uparrow</math></b> | <b>0.90 <math>\pm</math> (0.026) <math>\uparrow</math></b> |
| 5-fold (3)    | Fuzzy structure           | 0.91 $\pm$ (0.009)                                         | 0.91 $\pm$ (0.023)                                         | 0.90 $\pm$ (0.032)                                         |
|               | ANFIS structure           | 0.92 $\pm$ (0.009)                                         | 0.91 $\pm$ (0.026)                                         | 0.90 $\pm$ (0.031)                                         |
|               | Fusion learning           | 0.91 $\pm$ (0.008)                                         | 0.91 $\pm$ (0.018)                                         | 0.90 $\pm$ (0.028)                                         |
|               | Optimized Fusion learning | <b>0.92 <math>\pm</math> (0.007) <math>\uparrow</math></b> | <b>0.91 <math>\pm</math> (0.015) <math>\uparrow</math></b> | <b>0.90 <math>\pm</math> (0.025) <math>\uparrow</math></b> |
| 5-fold (4)    | Fuzzy structure           | 0.91 $\pm$ (0.008)                                         | 0.91 $\pm$ (0.028)                                         | <b>0.90 <math>\pm</math> (0.026)</b>                       |
|               | ANFIS structure           | 0.91 $\pm$ (0.012)                                         | <b>0.91 <math>\pm</math> (0.025)</b>                       | 0.89 $\pm$ (0.031)                                         |
|               | Fusion learning           | 0.91 $\pm$ (0.011)                                         | 0.91 $\pm$ (0.028)                                         | 0.90 $\pm$ (0.030)                                         |
|               | Optimized Fusion learning | <b>0.91 <math>\pm</math> (0.010) <math>\uparrow</math></b> | 0.91 $\pm$ (0.026) $\downarrow$                            | 0.90 $\pm$ (0.028) $\downarrow$                            |
| 5-fold (5)    | Fuzzy structure           | 0.92 $\pm$ (0.010)                                         | 0.91 $\pm$ (0.022)                                         | 0.90 $\pm$ (0.034)                                         |
|               | ANFIS structure           | 0.91 $\pm$ (0.011)                                         | 0.91 $\pm$ (0.019)                                         | 0.90 $\pm$ (0.033)                                         |
|               | Fusion learning           | 0.91 $\pm$ (0.012)                                         | 0.91 $\pm$ (0.019)                                         | 0.90 $\pm$ (0.028)                                         |
|               | Optimized Fusion learning | <b>0.92 <math>\pm</math> (0.009) <math>\uparrow</math></b> | <b>0.91 <math>\pm</math> (0.016) <math>\uparrow</math></b> | <b>0.90 <math>\pm</math> (0.026) <math>\uparrow</math></b> |

표 3에서는, 또 다른 실험으로써 교차 검증(CV = 5)을 고려하여 최적화된 ANFIS(퓨전 학습) 네트워크의 성능을 서로 비교했다. 최대, 평균, 최소값의 결과는 표준 편차(STD)로 계산된다.

도 9를 참조하면, 감정 예측 장치(100)는 감정 예측 모델을 검증하는 동작을 수행할 수 있다(S450).

도 9에서는, 최적의 결과 매개변수(p, q, r)를 얻기 위해 학습 접근법(수정 AIG, AIG 및 fast AIG)을 비교하였다. 각 접근법은 빠른 컨버전스를 달성하는 능력과 높은 정확성을 보증하는 정도에 따라 다른 평가를 받는다. 나머지 두 가지 방법과는 다르게 최적화된 퍼지 추론 시스템 기반 학습(퓨전 학습)이 더 빠르고 더 적절한 특징(features)을 생성한 것을 확인할 수 있다. 신호가 복잡하더라도 세 가지 테크닉에 대한 최적의 값을 달성하는 데는 제안된 구조의 신뢰성 및 강건함(robustness)이 중요하다고 볼 수 있다.

수정된 네트워크는 여러 다른 CV에서 성공적이었고, 유사한 구조에 비해 우울증, 불안 및 화난 상태를 포함한 감정을 식별하기 위한 만족스러운 예측을 제시했다.

참가자의 스트레스 수준과 직접적으로 관련된 세 가지 부정적인 감정과 관련하여, EEG 감정 신호 분류의 최종 정확도는 92% 이상이다.

도 10에서는, 스트레스를 완화(분노 및 불안 수준 감소)하는 일련의 과정에 도움이 되는 것으로 평가된 감정들과 관련한 값들을 영기명상 전후로 비교하여 나타낸다. 해당 그래프는 리커트 척도 평가 및 제안된 최적화 퍼지 추론 시스템을 기반으로 한 학습(퓨전 학습)을 토대로 한다.

[0141] 긍정적, 부정적, 중립적 감정 중 하나를 불러일으키는 영화(각 재생시간 약 4분)를 참여자(남성 3명, 여성 3명)에게 보여주고, 3주 동안 각 참가자에 대해 반복했다. 측정된 각 신호에는 세 가지 긍정적, 부정적, 중립적 감정이 표시된다.

[0142] 기본 ANFIS, 융합 학습, 메타 휴리스틱 최적화를 포함하여 수정된 퍼지 및 신경망 아키텍처 등이 제안된 방법에 활용되고, 테스트 데이터의 평균 정확도는 각 모델 별로 계산되었다.

[0144] 표 4에서는, 기본적인 퍼지, 신경망, ANFIS, 퓨전 ANFIS, 수정된 AIG 알고리즘을 기반으로 한 퓨전 ANFIS와 비교하여 제안된 수정된 모델의 평균 정확도를 나타낸다.

표 4

| Classifier learning                                | Positive | Negative | Natural |
|----------------------------------------------------|----------|----------|---------|
| Fuzzy                                              | 82.67    | 79.43    | 82.90   |
| Neural network                                     | 80.29    | 81.14    | 81.13   |
| ANFIS                                              | 84.71    | 84.38    | 82.90   |
| Fusion ANFIS                                       | 89.83    | 87.38    | 90.21   |
| Fusion ANFIS with modified AIG algorithm (fMFIS-L) | 92.36    | 90.18    | 93.54   |

[0145]

[0146] 표 4에서는, 위 평가의 결과를 요약한 것으로, 수정된 AIG 알고리즘에 의해 최적화된 퍼지-신경망 아키텍처 기반의 퓨전 학습으로 제안된 수정된 모델이 기본 퍼지 및 신경망보다 더 나은 성능을 갖고 있음을 보여준다.

[0148] 도 11에서는, 보이지 않는 EEG 신호를 기반으로 한 감정 분류의 손실을 계산한 것으로 (A)는 부정적인 감정, (B)는 긍정적인 감정, (C)는 자연스러운 감정을 나타낸다.

[0149] 도 11에서는, 감정 분류에서 보이지 않는 9개의 뇌파 신호에 대해 최소값에 도달하도록 설정된 알고리즘의 손실 함수 컨버전스 결과를 보여준다.

[0150] 리커트 척도 및 fMFIS-L 예측에 의해 결정되는 부정적인 감정 중 분노의 감정은 평가된 스트레스 수준 사이에서 상당한 관련성이 있다.

[0152] 학습 단계에서, 알고리즘이 최적의 값을 획득하려고 할 때, 변형된 AIG 알고리즘의 검색 변경 횟수를 늘리거나 퍼지 매개변수의 개수를 늘려 더 만족스러운 결과를 얻을 수 있다.

[0153] 제안하는 기법을 구현하기 위해 Windows 10용 MATLAB R2019b 프로그래밍 환경을 사용할 수 있다. SSD HARD에서 예약된 16GB RAM을 포함하여 8GB RAM이 있는 Intel® Core TM i5-8500 시스템(단일 CPU)을 사용하여 모델을 시뮬레이션할 수 있다. 모델은 0.002의 기본 학습률( $\mu$ )과 100~1000 사이의 에포크(epoch)로 구성될 수 있다.

### 부호의 설명


|        |               |               |
|--------|---------------|---------------|
| [0155] | 100: 감정 예측 장치 | 110: 데이터 수집부  |
|        | 120: 데이터 베이스  | 130: 학습모델 생성부 |
|        | 140: 감정 예측부   | 150: 스트레스 비교부 |




도면3




도면4




도면5




도면6




도면7




도면8




도면9



도면10



도면11



도면12

