



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공 학 박 사 학 위 논 문

뇌파 기반 스트레스 상태 분류 및
응용에 관한 연구

Research on EEG-based Stress State Classification
and Application

울 산 대 학 교 대 학 원

전기전자 · 컴퓨터공학과

손 동 구

뇌파 기반 스트레스 상태 분류 및
응용에 관한 연구

Research on EEG-based Stress State Classification and
Application

지도교수 김종면

이 논문을 공학박사학위 논문으로 제출함

2022년 2월

울산대학교 대학원

전기전자·컴퓨터공학과

손 동 구

손 동 구의 공학박사 학위논문을 인준함

심사위원 권 영 근 (인)

심사위원 김 종 면 (인)

심사위원 조 동 식 (인)

심사위원 정 진 호 (인)

심사위원 김 철 흥 (인)

울산대학교 대학원

2022년 2월

감사의 글

박사과정 동안 많은 분들의 도움이 있어 지금 순간까지 도착했다고 생각합니다. 감사의 글을 통해 감사하다는 말씀을 드리고 싶습니다. 저를 위해 자신의 시간을 할애하여 도움을 주신 분이 많이 있으며, 그 도움을 통해 논문을 마무리 할 수 있었습니다. 박사과정 기간 동안 함께했던 많은 분들께 감사드립니다.

저의 연구에 방향을 제시해 주시고, 마지막까지 응원해주시고, 지도해주신 김종면 교수님 감사합니다. 논문의 심사를 맡아주신 심사위원 분들께도 감사의 말씀 드리고 싶습니다. 박사과정 기간 내내 많은 조언을 주셨던 임기창 교수님께도 감사드립니다. 늘 자기 자리에서 노력하고 있는 김재영 박사는 지금 이 글을 쓰고 있는 순간에도 같은 공간에 있는데 심적으로 많은 무언의 격려를 받았다고 생각합니다.

박사학위 논문을 마무리하면서 논문 진행에만 진행할 수 없어 마무리를 잘 할 수 있을까 라는 걱정이 되었습니다. 그러나 이런 순간을 맞이할 수 있게 된 것은 연구실과 ICT융합안전연구센터 등 함께 했던 선배, 후배, 동료들의 도움이 매우 컸습니다. 그리고 저를 믿고 끝까지 응원해준 부모님과 동생에게도 감사하고 사랑합니다. 박사학위의 취득은 혼자 힘으로 가능했던 것이 아니기 때문에 이 영광을 돌리고 싶습니다.

졸업 이후에는 어떤 삶이 시작될지는 아직 잘 모르겠습니다. 다만 많은 분들이 도움을 주셨고, 그 도움에 감사하는 마음으로 세상에 이로움을 나누는 사람이 되도록 노력하겠습니다.

2021년 12월 5일

손동구

[국문 요약]

뇌파 기반 스트레스 상태 분류 및 응용에 관한 연구

과학기술의 발달로 인해 시설은 많은 부분이 자동화되었고, 이로 인해 수작업으로 이루어지던 많은 작업을 대신하여 감시 및 제어와 같은 일들을 소수의 인원이 처리하게 됨에 따라, 한 사람의 작업자로 인한 실수나 오작동으로 발생한 사고가 막대한 물질, 인적 손실을 초래할 수 있다. 산업재해의 대다수는 작업자의 불안전 행동에서 발생한다고 알려져 있으며, Mcsween에 따르면 10년간 듀폰사에서 발생한 부상의 76%가 불안전 행동에 의해 발생하였다. 불안전 행동을 일으키는 요소에는 피로, 수면부족, 스트레스, 육체적 결함 등이 있으며, 작업자의 부적절한 신체적·정신적 상태는 작업자의 스트레스가 발생의 원인이 된다.

뇌파는 뇌의 활동을 간접적으로 알 수 있는 전기적 신호이다. 뇌파는 EEG(Electroencephalographic)와 ECoG(electrocorticographic) 등의 방법으로 얻을 수 있다. ECoG는 뇌의 대뇌 피질에 직접 전극을 붙여 뇌파를 측정하는 방법으로, 가장 깨끗한 뇌파신호를 얻을 수 있는 방법이나, 전극을 이식함에 있어 수술적 방법이 필요하다는 단점이 있다. EEG는 머리의 두개골 밖의 두피에 전극을 붙여 뇌파를 측정하는 방법으로, 뇌파 신호의 정확도는 비교적 떨어지지만, 수술적 방법이 필요 없기 때문에 비교적 인체에 적용하는데 부담이 적다. 뇌파기반의 작업자 모니터링에는 비교적 적용에 부담이 적은 EEG를 이용하여 뇌파를 얻는 것이 적합하다.

본 논문에서는 뇌파 기반 작업자 안전 기술을 제안한다. 인공지능 기반 뇌파신호 활용 작업자의 안전관리 연구에서 사용하는 실험데이터는 감정 상태 분류를 위한 공개 뇌파 데이터셋인 DEAP(Database for Emotion Analysis using Physiological Signals)를 사용하며, 작업자 상태의 스트레스 상태와 정상 상태를 라벨링하기 위해서는 Bastos-Filho 외 4명이 사용한 분류기준을 사용한다. 상태 분류를 위한 특징으로는 통계적 특징, PSD(Power Spectrum, Density), HOC(Higher-Order Crossing)특징을 사용한다. 특징 선택 알고리즘으로는 PCA(Principle Component Analysis) 및 유전알고리즘을 사용하고, 최종적으로 인공지능 알고리즘을 이용해서

분류를 수행한다. 본 논문에서는 제안의 효용성을 확인하기 위해 PCA를 이용한 특징 선택 방법과 유전알고리즘을 이용한 방법을 비교한다. 실험 결과, 유전알고리즘 기반 방법은 PCA의 65.3%에 비해 분류 정확도가 71.76%로 6.46%더 높은 성능을 보였다. 또한 개별 학습 SVM을 이용한 분류 알고리즘과 유전알고리즘을 이용한 방법 사이에서 분류 정확도를 비교한 결과 각각 77.51%와 71.76%로, 개별학습 SVM을 사용하였을 때 분류 성능이 더 높았다.

마지막으로 인적오류 사고예방을 위해 작업자에 적용할 수 있는 뇌파측정기를 제안하였으며, 인공지능 알고리즘을 통해 분류된 스트레스 여부 결과를 통해 작업자의 위험도를 계산해내는 작업자 상태 지표를 제안하였다.

주제어 : 뇌파, 작업자 상태 분류, 특징선택, 유전 알고리즘, 기계 학습

목 차

제 1 장 서론	1
1.1. 연구배경	1
1.2. 논문의 구성	3
제 2 장 배경	4
2.1. 인적오류로 인한 사고통계	4
2.2. 뇌파	4
2.3. 특징선택 알고리즘	6
2.4. 분류 알고리즘	8
2.5. 관련 연구	9
제 3 장 EEG신호를 이용한 인공지능 기반의 스트레스 상태 분류	11
3.1. 소개	11
3.2. 실험방법 및 데이터셋	11
3.3. 실험결과	19
3.4. 결론	21
제 4 장 특징선택 기법을 사용한 인공지능 기반의 스트레스 상태 분류	22
4.1. 소개	22
4.2. 특징선택 알고리즘	22
4.3. 실험결과 및 성능비교	23
4.4. 결론	28

제 5 장 개별 학습 SVM을 사용한 인공지능 기반의 스트레스 상태 분류	30
5.1. 소개	30
5.2. 개별 학습 SVM	30
5.3. 실험결과 및 성능비교	30
5.4. 결론	34
제 6 장 인적오류 사고예방을 위한 뇌파 기반 기술의 응용	35
6.1. 소개	35
6.2. 산업 현장용 웨어러블 뇌파측정기	36
6.3. 스트레스 기반 작업자 상태 지표	46
6.4. 결론	48
제 7 장 결론	49
부록1. 인적오류로 인한 사고 통계	51
부록2. 인적오류 사고예방 소프트웨어	54

표 목 차

표 2.1. 뇌파 잡파의 원인	5
표 2.2. EEG신호의 주파수 밴드 범위	5
표 3.1. 시험에 사용한 EEG신호의 주파수 밴드 범위	16
표 3.2. 특징 분류 별 특징 개수	19
표 3.3. k-NN 알고리즘을 사용한 스트레스 분류 성능	20
표 4.1. 3가지 특징 선택 방법에 따른 피실험자 별 분류 정확도	25
표 4.2. 사용 특징 별 스트레스 분류 평균 정확도 비교	28
표 5.1. GA기반 특징선택 방법과 개별 학습 SVM 분류 성능 비교	32
표 5.2. 개별 학습 SVM 평균 분류 성능 비교	33
표 6.1. 기존 상용 제품 사양 조사	36
표 6.2. 장치 고유 ID 요청 패킷	38
표 6.3. 장치 고유 ID 응답 패킷	38
표 6.4. 뇌파 데이터 패킷	39
표 6.5. 뇌파 시뮬레이터 사양	42
표 6.6 비교 대상 뇌파측정기 사양	43
표 A1.1. 인적오류에 의한 국내 열차사고 발생현황	51
표 A1.2. 불안정한 행동의 사고 사망자 재해 분석	52
표 A1.3. 조선업 중대재해 인적오류 연도별 사고 횟수	52

그림 목 차

그림 2.1. 10-20 전극 배치법	6
그림 2.2. 유전알고리즘을 이용한 특징선택 절차	7
그림 2.3. k-NN 알고리즘의 예	8
그림 3.1. 스트레스 분류를 위한 전체 프로세스	12
그림 3.2. Valence-Arousal 평면	13
그림 3.3. 스트레스 및 평온한 상태 분류 기준	13
그림 3.4. 데이터 라벨링 결과	14
그림 3.5. k-NN 알고리즘을 사용한 스트레스 분류 성능	21
그림 4.1. 특징선택 기법을 사용한 스트레스 상태 분류의 전체 프로세스	24
그림 4.2. 3가지 특징 선택 방법에 따른 피실험자별 분류 정확도	26
그림 4.3. PCA를 사용한 특징공간 축소 결과(15번 피실험자)	26
그림 4.4. GA를 이용한 특징 선택 결과(15번 피실험자)	27
그림 4.5. 사용 특징 별 스트레스 분류 정확도 비교	28
그림 5.1. 개별 학습 SVM 개념도	30
그림 5.2. 개별 학습 SVM을 사용한 스트레스 상태 분류의 전체 프로세스	31
그림 5.3. GA기반 특징선택 방법과 개별 학습 SVM 분류 성능 비교 그래프	33
그림 5.4. 개별 학습 SVM 평균 분류 성능 비교 그래프	33
그림 6.1. 고용노동부 산업재해 현황	35
그림 6.2. 산업 현장용 웨어러블 뇌파측정기 개념도	37
그림 6.3. 산업 현장용 웨어러블 뇌파측정기	37
그림 6.4. 산업 현장용 웨어러블 뇌파측정기	38
그림 6.5. 뇌파측정기 설정 변경 버튼	39
그림 6.6. 뇌파측정기 설정 변경 어플리케이션	40
그림 6.7. 뇌파측정기를 통해 수집된 원본신호	41
그림 6.8. 대역통과 필터 및 노치필터를 적용한 뇌파 신호	41
그림 6.9. NETECH EEG 시뮬레이터	42
그림 6.10. 산업 현장용 웨어러블 뇌파측정기의 하드웨어 비교 절차도	43

그림 6.11. 사인파 입력 상태에서의 장비별 시간 도메인 비교	44
그림 6.12. 사인파 입력 상태에서의 장비별 주파수 도메인 비교	44
그림 6.13. 구형파 입력 상태에서의 장비별 시간 도메인 비교	45
그림 6.14. 구형파 입력 상태에서의 장비별 주파수 도메인 비교	45
그림 6.15. 뇌파측정기 제작품과 전문 뇌파 측정기의 비교 절차	46
그림 6.16. 뇌파측정기 제작품과 전문 뇌파 측정기의 신호 비교 결과	46
그림 6.17. 시간에 따른 의 변화	47
그림 A1.1. 연도별 원인에 따른 분류체계 통계	53
그림 A2.1. 인적오류 사고예방 소프트웨어 구성	54
그림 A2.2. 작업자 상태정보 통합 관리 데이터베이스 테이블 관계도	55
그림 A2.3. 작업자 모니터링 소프트웨어의 메인화면	55
그림 A2.4. 과거 작업자 스트레스 이력 조회 창	56
그림 A2.5. 주파수 도메인 분석 창	56

제 1 장 서론

1.1. 연구배경

안전보건공단[1]에 따르면 인적오류(Human error)는 인간이 수행하는 일련의 행동이나 행동군 중 에서 수용 한계를 벗어난 행동, 즉 시스템의 정상적 기능을 위하여 정의된 인간의 행동 한계를 넘은, 감내할 수 없는 행동으로 정의한다. 인적오류를 발생하는 요인으로는 높은 작업 부담, 불확실한 지시나 지침, 안전장치와 방어벽 결여, 작업자의 부적절한 신체적·정신적 상태, 소란하고 불쾌한 환경 등이 있다. 이와 같이 일반적으로 산업재해의 다수가 근로자의 불안정행동에 기인해 발생하므로, 인적오류에 의해 발생하는 원인을 심층 분석하여 적절한 방지조치가 필요하다. 불안전 행동을 유발하는 요인으로는 피로, 수면부족, 스트레스, 육체적 고통 등이 있다. 이 중 스트레스는 정신적, 정서적 또는 육체적 고통에 대한 신체의 반응이다. 이러한 스트레스 상태는 불안정행동을 유발할 뿐만 아니라 스트레스가 지속적일 경우에는 고혈압이나 관상 동맥 질환 등을 악화[2]시킬 수 있으며, [3]에 따르면 과민성 장 증후군, 우울증 같은 질병과도 관계가 있다.

스트레스는 신체의 호흡, 맥박 등 에도 영향을 미친다. 스트레스 상태는 호흡을 빠르게 변화시키며 맥박을 증가시킨다. 이러한 감정의 변화는 뇌의 활동에도 변화를 일으키고, 이러한 변화는 기능적 자기 공명 영상(fMRI; Functional magnetic resonance imaging), 근적외선 분광법(NIRS; Near-Infrared Spectroscopy), ECoG(electrocorticographic) 및 EEG(electro-encephalographic)를 통해 얻는 뇌파 등을 사용하여 얻을 수 있다.

[4]는 뇌의 신호를 얻는 여러가지 방법을 다루고 있다. 뇌의 혈액을 이용해서 뇌의 활성화를 얻는 방법으로는 자기장을 사용하는 fMRI나 근적외선을 이용하는 NIRS이 있다. fMRI는 뇌의 안쪽 까지 신호를 얻을 수 있으며, 공간해상도가 뛰어나다는 장점이 있으나, 뇌의 상태의 변화가 보이기 까지 지연시간이 있으며, 상대적으로 큰 장비가 필요한 단점이 있다. NIRS는 fMRI에 비해 저렴한 가격으로 뇌의 활동을 측정할 수 있으나, 비교적 뇌 표면의 상태만 알 수 있으며, 혈류량을 통해 간접적으로 얻는 신호라는 단점이 있다. 뇌파를 얻는다는 ECoG 및 EEG를 사용한다. ECoG는 뇌 표면에 직접 전극 패드를 부착하는 수술을 통해 뇌파를 얻는 방법으로, 높은 해상도와 넓은 대역폭을 얻을 수 있는 장점이 있으나 수술적인 방법이 필요하다는 단점이 있다. 반면에 EEG는 비록 뇌의 피질에 대한 활동만 관찰가능하며, 노이즈에

취약한 단점이 있으나, 두피에 전극을 배치하여 뇌파를 얻는 방법이다. [5]에 따르면 EEG는 비침습적이고, 비교적 신호취득이 쉬우면서도 시간 해상도가 높다는 장점을 가지고 있다.

EEG는 두피에서 신호를 얻기 때문에 헬멧과의 결합을 통해 웨어러블 기술과의 융합도 쉬워서 산업재해의 예방에 사용되는 것이 가능하며, [6]에서는 헬멧에서 생체 신호 및 EEG를 취득하는 방안을 제안했다.

따라서 본 논문에서는 작업자 안전에 영향을 미치는 인적오류를 줄이기 위한 방안으로 작업자의 불안전 행동을 유발할 수 있는 스트레스를 뇌파 기반으로 분류하는 알고리즘을 제안하며, 더 나아가 산업현장용 웨어러블 뇌파 측정기를 통해 작업자 상태 지표를 계산하여 모니터링 하는 응용 방법을 제안한다.

1.2. 논문의 구성

제 2 장에서는 불안전행동 사례조사, 뇌파, 특징선택 알고리즘 및 학습 알고리즘 등 관련 기술들을 소개한다. 제 3장에서는 EEG신호를 이용한 인공지능 기반의 스트레스 상태 분류를 제안한다. 제 4장에서는 분류에 도움이 상대적으로 기여를 많이 하는 특징을 선택하는 알고리즘을 사용하여 EEG 기반으로 스트레스를 분류하였으며 성능 비교를 통해 특징선택 알고리즘의 효용성을 검증하였다. 제 5장에서는 4장에서 제안한 알고리즘을 활용하여 인적오류 사고예방을 위한 뇌파 기반 기술들을 산업현장에서 사용할 수 있도록 하는 응용 기술을 제안했다. 제 6장에서는 본 논문에서 언급했던 알고리즘 및 기술 응용을 다시 한 번 논의하며 본 논문을 마무리한다.

제 2 장 배경

2.1. 인적오류로 인한 사고통계

안전보건공단[1]에 따르면 인적오류(Human error)는 인간이 수행하는 일련의 행동이나 행동군 중 에서 수용 한계를 벗어난 행동, 즉 시스템의 정상적 기능을 위하여 정의된 인간의 행동 한계를 넘은, 감내할 수 없는 행동으로 정의한다. 인적오류를 발생하는 요인으로는 높은 작업 부담, 불확실한 지시나 지침, 안전장치와 방어벽 결여, 작업자의 부적절한 신체적·정신적 상태, 소란하고 불쾌한 환경 등이 있다.

인적오류로 인한 사고가 높은 빈도로 발생되지 않거나, 발생하더라도 위험도가 높지 않는다면 사고를 줄이기 위해 인적오류를 예방하는 기술을 개발하는 것이 의미 없을 수 있다. 따라서 인적오류로 인한 사고가 지속적으로 일어나는지와, 발생한 사고가 위험도가 높은지를 확인하기 위해 철도 분야 및 조선 분야 등 산업현장에서 발생한 사고통계를 조사하였다. 조사결과는 부록1에서 확인할 수 있다.

조사결과 인적오류로 인한 산업군과 무관하게 매년 지속적으로 발생하였기 때문에 본 논문의 작업자 스트레스 상태 분류는 중요하다 볼 수 있다.

2.2. 뇌파

뇌파는 뇌 신경세포 사이의 전기 흐름에 따라 측정되는 전위변화이다. 뇌파를 측정하는 전극의 위치에 따라 EEG(Electro-encephalogram) 및 ECoG(Electro-corticogram) 등의 방법이 있다. EEG는 두피에서 측정하는 방법이며, ECoG는 대뇌 피질에 전극을 설치하여 뇌파를 측정하는 방법이다. ECoG는 침습적인 수술을 통해 전극을 설치하기 때문에 작업자에 적용하는 것이 어렵다. 웨어러블 기기를 사용하여 뇌파 측정을 위해서는 두피의 전극을 통하여 비침습적인 측정방법을 이용하기 때문에 EEG가 유용하다.

EEG는 비전도체인 두개골을 통과하기 때문에 전극을 통해 측정되는 신호는 매우 미약하다. 그에 따라 뇌파는 외부의 환경적인 요인에 따라 artifact가 혼입된다. 표 2.1은 주위 환경, 신체의 움직임, 땀 등에 의해서 생기는 artifact의 원인을 보여주며, 이러한 artifact가 과다하게 들어오면 데이터 분석이 어려울 수 있다.

표 2.1. 뇌파 잡파의 원인

생리적 잡파		비생리적	
두피	땀 맥박 근육	도구	60 Hz 교류 정전기
눈	안검떨림 외안근 안구운동	전극	전극뒤틀 전선
입	혀 저작근 삼킴	환경	정맥주사 응고기
심장	심전도	디지털	위신호현상
사지	진전 움직임		

뇌파를 분석할 때 일반적으로 사용하는 주파수 범위는 0.5~40Hz 이다. 뇌파를 몇 개의 주파수 대역으로 나누는데, 주파수 대역에 따라 낮은 주파수에서 부터 델타파, 세타파, 알파파, 베타파, 감마파로 구분된다. 표 2.2는 주파수 대역 별 뇌파 분류를 보여준다.

표 2.2. EEG신호의 주파수 밴드 범위

뇌파 분류	주파수 범위 (Hz)
delta	0.5 ~ 3 Hz
theta	4 ~ 7 Hz
alpha	8 ~ 13 Hz
beta	14 ~ 30 Hz
gamma	30 Hz 이상

EEG 측정을 위한 전극을 부착할 때, 실험자 마다 다른 위치를 사용한다면, 개별 연구 사이의 비교에서 모호함이 발생한다. 그에 따라 뇌파 측정 센서를 부착하는 위치를 정해놓았는데, 가장 널리 사용하는 방법으로 10-20 전극 배치법(10-20 system)이 사용[기]된다. 전극 위치는 알파벳과 숫자를 사용하여 표현된다. 숫자 부분에서 짝수는 우측 뇌, 홀수는 좌측 뇌를 의미한다. 알파벳은 F(Frontal Lobe), P(Parietal Lobe), C(Central Lobe), T(Temporal Lobe), O(Occipital Lobe) 등이 있다. 그림 2.1은 10-20 전극 배치법을 보여준다.




그림 2.1. 10-20 전극 배치법

2.3. 특징선택 알고리즘

기계학습 알고리즘에 훈련을 할 때 훈련 데이터의 특징이 많은 경우, 모든 특징이 분류 결과에 주요한 영향을 끼치는 것은 아니므로, 학습에 도움이 되는 특징만을 선택하는 것은 분류에 도움이 된다. 또한 너무 고차원의 특징은 “차원의 저주”라 불리는 분류 알고리즘 성능의 저하로 이어질 수 있다. 이는 특징 차원이 많아질수록 특징 공간이 지수적으로 늘어나기 때문에 데이터의 밀도가 낮아지기 때문이다. 차원 축소 및 특징선택 알고리즘을 통해 쓸모없는 특징을 제거함으로써 노이즈 제거, 메모리 절약, 분류 성능 향상 등을 기대할 수 있으며, 3차원 이하의 특징 벡터의 경우 시각화를 통해 데이터를 쉽게 인지할 수 있다.

2.3.1. PCA

PCA(Principal Component Analysis: 주성분분석)[8]은 정보의 손실을 줄이면서 데이터의 차원을 축소하는 방법이다. 데이터의 주성분을 통계적 방법을 통해 구하고, 데이터를 사영하는 방법으로 차원을 축소한다.

2.3.2. 유전알고리즘을 이용한 특징선택

유전알고리즘(Genetic Algorithm: GA)는 다윈의 자연 선택(natural selection)에서 영감을 받았다. 유전알고리즘은 모집단에서 가장 적합한 해의 후보를 선택하는 것으로

시작한다. 후보들은 부모의 특성을 물려받아 다음 세대에 물려줄 새로운 유전자를 구성한다. 목적함수의 결과가 높으면 후보군의 생존확률이 높아진다. 이러한 과정을 반복함으로써 가장 좋은 해를 찾을 수 있다. 유전 알고리즘을 이용한 특징선택은 목적함수로서 클래스간 분리도가 높고, 클래스 내부 밀집도가 높은 특징 들을 선택함으로써 목적을 이룰 수 있다. 유전알고리즘을 이용한 특징선택 절차는 그림 2.2에서 보여준다.

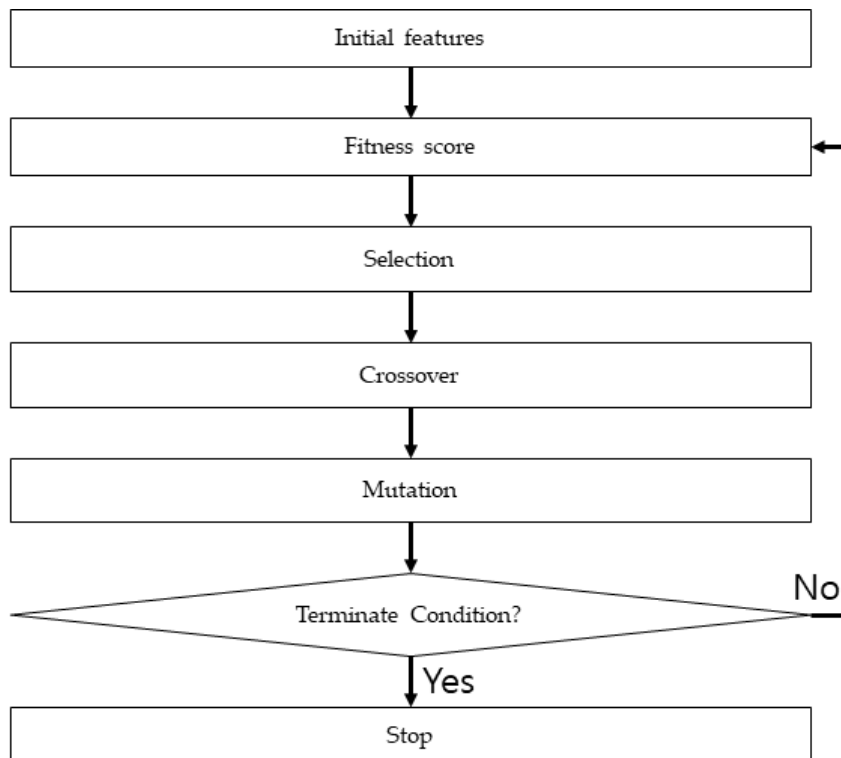


그림 2.2. 유전알고리즘을 이용한 특징선택 절차

(1) Initial features

모집단을 만드는 단계로, 각각의 특징이 유전자로 된 후보군을 생성한다. 이 단계에서는 유전자를 랜덤하게 생성하여 초기 특징 조합을 구성한다.

(2) Fitness Score

목적함수를 사용하여 각 후보군의 점수를 결정한다. 목적함수는 클래스간 분리도가 높고, 클래스 내부 밀집도가 높을 때 생존에 유리하도록 고려해야 한다.

(3) Selection

이 단계에서는 가장 적합한 후보를 선택하여 다음 세대에 유전자를 전달하도록 한다. 목적함수에서 높은 점수를 받은 후보가 선택될 기회가 더 많다.

(4) Crossover

선택된 후보 사이에서 교배 연산을 수행하여 새로운 유전자를 구성하게 된다. 새로운 세대의 후보들은 부모의 유전자를 서로 교환하여 생성된다.

(5) Mutation

새로운 세대의 후보 중 일부는 낮은 확률로 돌연변이를 일으킬 수 있다. 이는 일부 후보의 특징 조합이 무작위로 변경될 수 있음을 의미한다. 이 단계를 통해 유전자의 다양성을 확보하며, 조기수렴을 방지할 수 있다.

2.4. 분류 알고리즘

본 논문에서는 분류 알고리즘으로 k-NN(k-nearest neighbor)을 사용하였다. k-NN은 가장 기본적이고 간단한 분류 방법 중 하나이다. 분류되지 않은 특징조합을 분류하기 위해서는 k 개의 가장 가까운 훈련 데이터가 있음을 만족하면 된다. 이러한 과정에서 특징조합 간의 거리를 구하기 위해 일반적으로 유클리드 거리를 사용한다.

k-NN에서 k 값을 선택하는 분류 결과에 큰 영향을 미친다. 일반적으로 k값이 커질수록 전체 노이즈가 줄어들지만 세밀하게 분류하지 못한다는 단점이 있다.

그림 2.3의 예시에서 k값을 3으로 선택했다면 초록색 데이터의 분류결과는 삼각형이 되겠지만, k를 5으로 선택했다면 분류결과는 사각형이 된다.




그림 2.3. k-NN 알고리즘의 예

k-NN 분류기를 사용하여 작업자의 스트레스 여부를 분류했을 때의 장점으로서는 다른 분류기에 비해 단순하여 처리 속도가 짧게 걸리기 때문에, 인적오류 사고예방을 위한 뇌파 기반 기술을 시스템으로 구성하면, 많은 수의 작업자를 모니터링 할 수 있다.

본 논문에서 사용한 또 다른 분류 알고리즘으로 SVM(Support Vector Machine)을 사용하였다. SVM은 클래스간 분리를 최대화하기 위한 최대 마진을 가지는 분리 경계면을 계산한다. SVM에서는 최대 마진을 가지는 초평면을 얻어낼 때 필요한 서포트 벡터를 사용한다. 그러나 모든 경우에 선형으로 클래스를 구별할 수 있는 것은 아니다. 이러한 경우에 저차원 공간을 고차원 공간으로 매핑해 주면 평면을 사용하여 분류가 가능하게 되는데 이를 커널 트릭(Kernel Trick)이라고 한다. 커널 트릭에 사용되는 함수에는 Sigmoid, RBF(Radial Basis Function) 등이 있으며, 본 논문에서는 RBF커널을 사용했다. RBF커널은 카우시안 커널이라고도 하며, 수식은 아래와 같다.

$$K_{RBF}(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right) \quad (2.1)$$

2.5. 관련 연구

2.5.1. 뇌파 기반의 항공 교통 관제 시스템 인적요인 평가

뇌파 기반으로 인적 오류를 줄이는 노력으로 2017년 In Advances in Human Aspects of Transportation에 게재된 연구[9]가 있다. ATC(Air Traffic Control; 항공 교통 관제)에서의 관제가 작업부하, 스트레스 등의 정보를 얻어 인적요인을 평가하는 목적[13]이다. 관제사는 동시에 많은 양의 정보를 처리해야 하고, 앞으로 항공교통은 증가할 것으로 보이므로 관제사의 항공기 인식능력이 중요할 것으로 사료되지만 항공교통이 증가할수록 인식능력은 저하되었으며, 작업부하가 과중할 경우에는 조작의 실수가 발생한다는 것을 연구하였다. 정신적 작업부하는 뇌 활동, 심장 활동, 호흡 활동 등 인체 생리 신호에 영향을 주며, 특히 뇌파가 정신적 작업부하 모니터링에 적합한 것을 설명하였으며, 연구결과는 정신적 작업부하와 뇌파신호 간에 상관관계가 있음을 실험적으로 입증하여 보여주었다.

2.5.2. 감정 상태 인식을 위한 특징 추출 기법 연구

뇌파 신호는 사람의 내면의 감정 상태를 반영하고 시간 분해능에서 정신적 스트레스를 측정할 수 있는 선형연구[10]가 있다. [10]에서는 감정 상태 인식에 대한 연구에 광범위하게 사용되어온 3개의 뇌파 신호 추출 기법을 사용하였다. DEAP 데이터베이스의 EEG 신호를 사용하여 K-NN 분류기를 사용하여 스트레스의 감정

상태 분류를 통해 수행되었다. 연구결과는 PSD 특징을 사용하여 70.1%, HOC 기반 기술을 사용하여 69.59%의 분류 정확도를 보였다.

2.5.3. 인적오류 유발 상황에서 뇌파 상대파워 특성의 변화

뇌파의 밴드 파워로부터 인간과오의 특이성을 찾고, 반응에 따른 변화에 대한 선행연구[11]가 있다. 여러 가지 과업을 피실험자가 수행했을 때의 전체 파워에 대한 알파파와 베타파의 비율(밴드 파워비)을 이용하여 관계를 분석하고, 밴드 파워비의 영향이 일정하지는 않으나 과업에 따라서 다른 패턴을 보임을 확인하고자 수행된 연구이다. 연구결과에서 과업에 따른 파워비를 통계적으로 분석하였으며, 난이도에 따른 뇌파 파워비가 일부 달라짐을 확인하였다.

제 3 장 EEG신호를 이용한 인공지능 기반의 스트레스 상태 분류

3.1. 소개

급속한 산업의 발달로 인하여 시설이 대형화되고 복잡하게 되었으나 기술의 발달로 인해 소수의 인원으로 대형화된 시설물의 운영이 가능하게 되어 한 사람의 인적 오류가 막대한 물적, 인적 손실을 초래할 수 있다. 일반적으로 다수의 산업재해가 근로자의 불안전 행동에 기인해 발생한다고 알려져 있으며, 이를 줄이는 것이 중요하다.

한편 급한 성격, 욕구불만, 좌절, 과로, 스트레스 등의 부정적인 정신적 상태는 작업에 집중하지 못하게 하며 불안전 행동을 유발하고, 이러한 상태는 인적오류로 이어질 가능성을 높인다. 따라서 작업자의 이러한 부정적인 정신적 상태를 감지할 수 있는 방법이 필요하다. 스트레스는 이러한 부정적인 정신적 상태 중 하나이며, 스트레스 상태가 지속되면 호흡을 빠르게 변화시키고, 맥박을 증가시킨다. 감정의 변화는 뇌의 활동에도 변화를 일으키므로, 뇌파를 통해 스트레스 상태를 분류할 수 있다. EEG 신호를 취득하는 것은 뇌파를 두피에서 비침습적으로 얻을 수 있는 방법이므로 작업자의 상태를 얻어내는데 적절한 방법이다.

3장에서는 작업자의 부정적인 정신적 상태 중 하나인 스트레스를 감지하기 위해 EEG (Electro-encephalography)신호에서 Statistical Feature, Frequency Domain Feature, High-order crossings, Hjorth Parameter 및 Frontal Asymmetry Alpha 등의 특징을 추출하였으며, k-NN(k-nearest neighbor) 알고리즘 기반으로 스트레스와 정상 상태를 분류하였다.

3.2. 실험방법 및 데이터셋

3.2.1. 실험방법론

스트레스 분류를 위한 전체 프로세스는 그림 3.1에서 보여준다. 본 논문에서는 데이터셋에서 스트레스(stress) 상태와 정상(calm) 상태를 라벨링 하는 data annotation, 분류알고리즘에서 상태를 잘 분류할 수 있는 특징을 계산하는 feature extraction, 스트레스 상태와 고요 상태를 분류해 내는 classification의 과정으로 실험을 진행했다.

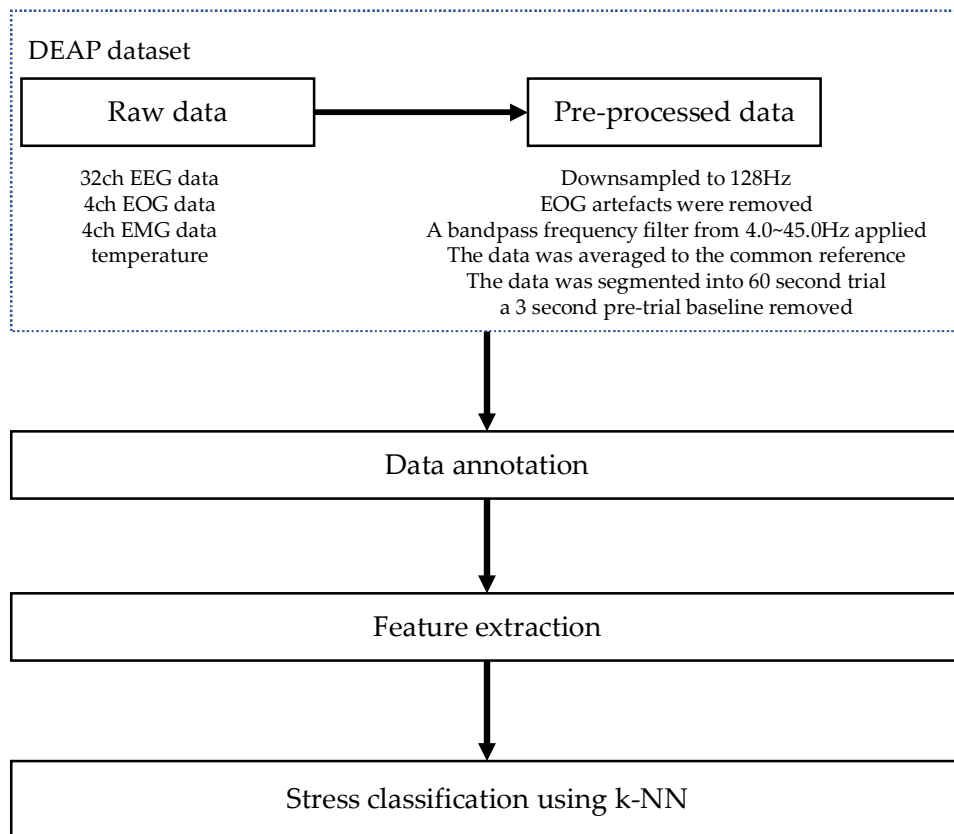


그림 3.1. 스트레스 분류를 위한 전체 프로세스

3.2.2. 데이터셋

본 논문에서는 감정 분류를 위한 실험을 위해 공개된 뇌파 데이터셋인 Database for Emotion Analysis using Physiological Signals (DEAP)[12]를 사용했다. 건강한 피실험자 32명을 대상으로 감정 유발을 위한 40개의 1분 길이 뮤직비디오를 보여 주고, 뮤직비디오를 시청 할 때의 뇌파를 취득하였다. 감정인식을 위해 32개의 EEG 신호 뿐만 아니라, EOG(Electro-oculography; 안전도), EMG(Electro-myography; 근전도), 체온 등의 인체의 생리적 정보를 포함한 데이터 셋이다. DEAP은 감정상태를 Arousal(각성)상태와 Valence(즐거움) 감정을 9단계의 사람그림으로 나타내는 SAM(self-assessment manikins)[13]을 통해 피실험자로부터 얻은 정보와, 전문가의 의견을 종합하여 Arousal, Valence 등 정보가 제공하며, 본 데이터셋에서의 감정은 그림 3.2와 같이 Valence-Arousal 평면을 통해 표현된다. 한편 DEAP 데이터셋에서는 원본 데이터를 128Hz로 다운샘플링, 4Hz에서 45Hz 대역 필터 적용 및 뇌파의 artifact를 제거한 pre-processed데이터를 제공한다. 본 논문에서는 스트레스 상태 분류를 위한 알고리즘 실험을 위해 DEAP에서 제공하는 pre-processed데이터를 사용하였다.




그림 3.2. Valence-Arousal 평면

3.2.3. 데이터 라벨링

실험을 위해 스트레스 상태와 평온 상태를 [14]에서 사용한 방법으로 정의했다.

$$(arousal < 4) \cap (4 < valence < 6) \quad (3.1)$$

식 3.1과 같이 Arousal이 4 미만이고 Valence가 4와 6사이이면 평온한 상태로 데이터를 라벨링 하였다.

$$(arousal > 5) \cap (valence < 3) \quad (3.2)$$

식 3.2와 같이 arousal 이 5를 초과하고 valence가 3미만이면 스트레스 상태로 평가하여 데이터에 표시했다. 그림 3.3은 스트레스 및 평온한 상태 분류 기준을 보여준다.




그림 3.3. 스트레스 및 평온한 상태 분류 기준

개별 피실험자에 대해 각각 스트레스 상태와 평온 상태를 분리한 결과 총 32명의 피실험자 중에서 7명은 스트레스 상태와 평온 상태 중 한가지로만 분리되어 분류를 위한 학습데이터로 사용할 수 없기 때문에, 나머지 25명에 대해 실험을 진행하였다. 그림 3.4는 데이터 라벨링의 결과를 보여준다. 빨간색 점(다이아몬드)은 보통 상태에 해당되는 데이터를, 파란색 점(원)은 스트레스 상태에 해당되는 데이터를 의미한다.




그림 3.4. 데이터 라벨링 결과

3.2.4. 특징 추출

DEAP 데이터셋의 뇌파신호는 실험회차에 따라 분리되어 있으며, 각 실험회차의 뇌파신호 길이는 약 60초(8064 samples)이다. 개별 실험자의 실험회차는 40회에 불과하기 때문에 기계학습 알고리즘을 위한 학습데이터로 충분하지 않다. 충분한 학습 데이터를 확보하지 않으면 과적합 문제가 발생할 수 있으며, 이는 기계학습 알고리즘이 데이터 분류에서 테스트 데이터나 실제 데이터에서 성능이 떨어지는 결과를 가져올 수 있다. 따라서 좋은 데이터를 다량으로 확보하는 것이 중요한데, 제한된 DEAP데이터셋에서 데이터셋 양을 늘리기 위해 8064샘플의 데이터를 32등분 했다. 따라서 알고리즘 학습 및 분류에 사용하는 입력 데이터는 약 2초길이 (252 samples)를 사용했다. 이를 통해 원래 1개 데이터셋이었던 뇌파 신호를 증

강하여 32개 데이터셋으로 만들어 기계학습 알고리즘의 학습이 원활하게 이루어지도록 했다.

추출한 특징들은 과거 연구[10,15-21]에서 뇌파 감정 분석에 일반적으로 사용하는 특징 5가지인 statistical features, frequency domain features, higher-order crossings, Hjorth parameter, frontal asymmetry alpha를 본 논문에서도 사용했다.

(1) Statistical Feature

본 논문에서는 [14,21] 에서 통계 특징으로 사용된 아래의 6개의 특징을 사용했다. 첫 번째 특징인 Mean은 아래의 수식을 사용하여 계산했다.

$$\mu_x = \frac{1}{N} \sum_{n=1}^N X(n) \quad (3.3)$$

두 번째 특징인 Standard deviation은 아래의 수식을 사용하여 계산했다.

$$\sigma_x = \sqrt{\frac{1}{N} \sum_{n=1}^N (X(n) - \mu_x)^2} \quad (3.4)$$

세 번째 특징인 First difference는 아래의 수식을 사용하여 계산했다.

$$\delta_x = \frac{1}{N-1} \sum_{n=1}^{n-1} |X(n+1) - X(n)| \quad (3.5)$$

네 번째 특징인 Normalized first difference는 아래의 수식을 사용하여 계산했다.

$$\tilde{\delta}_x = \frac{\delta_x}{\sigma_x} \quad (3.6)$$

다섯 번째 특징인 Second difference는 아래의 수식을 사용하여 계산했다.

$$\gamma_x = \frac{1}{N-2} \sum_{n=1}^{n-2} |X(n+2) - X(n)| \quad (3.7)$$

네 번째 특징인 Normalized second difference는 아래의 수식을 사용하여 계산했다.

$$\tilde{\gamma}_x = \frac{\gamma_x}{\sigma_x} \quad (3.8)$$

수식 3.3부터 3.8에서의 $X(n)$ 은 DEAP 데이터셋의 전처리된 뇌파신호를 32등분 한 데이터이며, 따라서 $N=252$ 이다. 또한 각 피실험자마다 부착한 뇌파 전극의 채널 개수는 32개 채널이며, 각 채널의 뇌파신호에 대해 각각 6개의 특징을 추출하였기 때문에 1개 데이터에서 추출한 Statistical Feature의 수는 총 192개 이다.

(2) Frequency Domain Feature

EEG를 이용한 감정 인식 연구에서 가장 많이 사용하는 특징은 각 주파수밴드 별 파워이다. 일반적으로 뇌파는 주파수 영역에 따라 delta, theta, alpha, beta, gamma 등 5개 밴드로 구분한다[15-17]. 뇌파 밴드 별 주파수 영역의 범위는 연구자의 정의에 따라 조금씩 조정될 수 있다. S.Sanei외 1명[22]에 따르면 델타파는 깊은 잠에 연관되어 있으며, 세타파는 졸린 상태에서 주로 생성된다. 알파파는 편안히 깨어 있는 상태를 반영하며, 베타파는 집중상태에서 주로 연관 되어있다. 감마파는 고도의 정신기능 수행시에 나타난다. 본 논문에서는 [14]를 참고하여 5개의 대역을 더 작게 나누어 7개의 대역을 사용했다. 표 3.1은 사용한 7개의 대역을 보여준다. Frequency Domain Feature는 이들 7개 대역에 대한 밴드파워를 계산한 것이다. 밴드파워는 Welch's method[23]로부터 power spectrum density(PSD)를 구한 다음 주파수밴드 범위를 합산하여 구한다. Welch's method는 시간 도메인 데이터를 Overlab된 구간으로 나눈 뒤 각각의 구간에 대한 스펙트럼을 구하고 평균을 내는 것이며, 이를 통해 일시적으로 불안정한 신호나 잡음에 대한 영향을 줄일 수 있다. PSD특징은 [14,16]에서 사용되었다.

표 3.1. 실험에 사용한 EEG신호의 주파수 밴드 범위

주파수 밴드 번호	주파수 범위 (Hz)
1	4 ~ 7.2 Hz
2	7.2 ~ 10.4 Hz
3	10.4 ~ 13.8 Hz
4	13.8 ~ 17 Hz
5	17 ~ 20 Hz
6	20 ~ 23 Hz
7	23 ~ 60 Hz

32개 채널의 뇌파에 대해 각각 6개의 특징을 추출하였기 때문에 1개 데이터에서 추출된 Frequency Domain Feature의 수는 192개 이다.

(3) High-order crossings(HOC)

[24]에서 감정상태와 관련이 있다고 한 HOC(Higher-order crossing)를 특징으로 사용했다. HOC은 뇌파신호의 주기적 변화 패턴을 나타내는데 유용하다.

Zero-crossing은 신호가 0값을 통과한 것을 카운트 한 것이며 difference operator를 사용해 다양한 high-pass 필터된 시계열을 zero-crossing count 한 것이 HOC이다. 연산이 간단하기 때문에 효율적으로 스펙트럼 분석을 할 수 있는 방법이다.

HOC특징은 아래 식과 같이 D의 시퀀스로 정의한다.

$$HOC = [D_1, D_2, \dots, D_M] \quad (3.9)$$

여기서, M은 HOC 특징 벡터의 차수를 의미하며, 본 논문에서는 5를 사용하였다.

32개 채널의 뇌파에 대해 각각 5개의 특징을 추출하였기 때문에 1개 데이터에서 추출된 HOC 특징의 수는 160개 이다.

(4) Hjorth Parameter

요르트 파라미터[25]는 시간 도메인에서 구할 수 있는 Activity, Mobility, 그리고 Complexity로 이루어진 특징이다. Activity는 신호 amplitude의 분산이며, 평균 파워를 나타낸다. Mobility는 신호 기울기의 분산에서 신호크기의 분산을 나눈 것을 제곱근한 것이며, 평균주파수를 나타낸다. Complexity는 신호의 모양이 순수 sine 파와 얼마나 비슷한지를 나타낸다.

이 파라미터는 시간 도메인 상에서 계산하지만, 신호의 주파수 스펙트럼에 대한 정보를 담고 있다. 그렇기 때문에 주파수 스펙트럼에 대한 정보를 얻는 다른 방법에 비해 더 낮은 계산 시간을 가진다.

이산신호에서 각각의 요르트 파라미터를 구하는 식은 아래와 같다.

$$\sigma_1 = \frac{1}{n} \sum_{i=1}^n x_i^2 \quad (3.10)$$

여기서, x는 신호를, σ_1 은 분산을 의미한다.

$$\sigma_2 = \frac{1}{n-1} \sum_{i=1}^{n-1} (x_{i+1} - x_i)^2 \quad (3.11)$$

여기서, σ_2 은 분산의 미분을 의미한다.

$$\sigma_3 = \frac{1}{n-2} \sum_{i=1}^{n-2} \{(x_{i+2} - x_{i+1}) - (x_{i+1} - x_i)\}^2 \quad (3.12)$$

여기서, σ_3 은 분산의 2차 미분을 의미한다.

$$activity(f(i)) = variance(f(i)) = \sigma_1 \quad (3.13)$$

여기서, *activity*는 신호의 분산을 의미한다.

$$mobility(f(i)) = \sqrt{\frac{activity\left(\frac{df}{di}\right)}{activity(f(i))}} = \sqrt{\frac{\sigma_2}{\sigma_1}} \quad (3.14)$$

여기서, *mobility*는 신호의 평균 주파수를 의미한다.

$$complexity(f(i)) = \frac{mobility\left(\frac{df}{di}\right)}{mobility(f(i))} = \sqrt{\frac{\sigma_3/\sigma_2}{\sigma_2/\sigma_1}} \quad (3.15)$$

여기서, *complexity*는 사인파의 모양으로부터의 신호 분산을 의미한다.

32개 채널의 뇌파에 대해 각각 *activity*, *mobility*, *complexity* 등 3개의 특징을 추출하였기 때문에 1개 데이터에서 추출된 Horth parameter 특징의 수는 96개 이다.

(5) Frontal Asymmetry Alpha

우울증 환자들에게서 비정상적인 뇌파가 나오는 것은 여러 연구의 결과[10, 20, 26-29]를 통해 알 수 있으며, 특히 대뇌 반구에서 우반구와 좌반구 각각 측정되는 전두엽의 알파파가 비대칭적으로 나온다.

뇌파에서 나타나는 전두엽의 좌우 차이를 보기 위해서 뇌파 전극에서 Fp1과 Fp2를 사용한다. Fp는 뇌에서 Pre-frontal 영역을 의미한다. 각각의 전극에서 알파파 대역의 파워를 구하고 로그를 취한 다음 서로 뺄셈을 했다. Frontal Asymmetry Alpha를 구하는 식은 아래와 같다.

$$Frontal\ Asymmetry\ Alpha = |\ln R| - |\ln L| \quad (3.16)$$

32개 채널 중 Frontal Asymmetry Alpha 특징과 관련된 채널은 Fp1 및 Fp2이고, 두 신호의 절대값의 차를 계산하므로 1개 데이터에서 추출되는 Frontal Asymmetry Alpha 특징은 1개 이다.

(6) 분류 알고리즘의 입력으로 사용되는 특징 셋

DEAP 데이터셋에서 제공하는 뇌파신호는 32채널이며, 채널별로 각각 특징을 추출하였다. 채널별로 특징값이 나오지 않는 Frontal Asymmetry Alpha 특징의 경우에는 Fp1과 Fp2 채널만을 사용하여 계산되는 값이므로 1개의 특징을 추출했다. 표 3.2는 특징 분류별로 추출되는 특징의 개수를 보여준다.

표 3.2. 특징 분류 별 특징 개수

특징 분류	특징 개수
Statistical features	192
Frequency domain	192
HOC	160
Hjorth Parameter	96
Frontal Asymmetry Alpha	1
합계	641

3.3. 실험결과

본 논문에서는 분류를 위해 k-nearest neighbors(k-NN) [17]을 사용했다. k-NN 분류기는 간단함과 계산효율로 인해 가장 많이 사용되는 분류 기법 중 하나로, 특징 추출 과정을 통해 나온 특징들과 가장 가까운 k개의 학습 데이터를 비교하여 해당하는 클래스를 분류한다.

특정 학습 데이터에 특화된 결과가 나올 가능성을 줄이기 위해, 학습 데이터와 테스트 데이터의 분리는 k-fold validation을 사용했으며, 본 논문에서는 k값으로 3을 사용했다. 표 3.3과 그림 3.5는 k-NN 알고리즘을 사용한 스트레스 상태 분류 실험의 결과를 보여준다. 앞서 설명한 것과 같이 3, 6, 7, 9, 17, 13, 30번 피실험자는 스트레스 상태와 평온 상태 중 한가지로만 분리되어 분류를 위한 학습데이터로 사용할 수 없기 때문에, 나머지 25명에 대해 스트레스 분류 알고리즘 실험을 수행하였다.

표 3.3. k-NN 알고리즘을 사용한 스트레스 분류 성능

피실험자 번호	분류 정확도
1	87.91%
2	63.91%
4	54.69%
5	61.24%
8	72.54%
10	60.05%
11	68.03%
12	73.58%
13	71.63%
14	82.21%
15	79.31%
16	62.24%
18	73.48%
19	51.84%
20	58.98%
21	66.78%
22	63.97%
24	73.26%
25	60.94%
26	54.69%
27	88.89%
28	63.54%
29	67.19%
31	54.69%
32	61.35%




그림 3.5. k-NN 알고리즘을 사용한 스트레스 분류 성능

실험결과 피실험자별로 최소 51.84%, 최대 88.89%의 분류 정확도를 보였으며, 평균 67.08%의 정확도로 분류가 되었다.

3.4. 결론

3장에서는 작업자의 스트레스를 뇌파 기반으로 분류하는 알고리즘을 제안하였다. 실험은 데이터 라벨링, 특징 추출, 분류 등 3단계로 수행되었다. 실험에 사용한 데이터는 감정 분류를 위한 실험을 위해 공개된 뇌파 데이터셋인 DEAP를 사용하였고, 해당 데이터셋에서 제공되는 Valence-Arousal 평면에서 [14]이 사용한 방법으로 스트레스 상태와 정상 상태를 라벨링하였다. DEAP에서 제공하는 데이터셋은 기계학습 알고리즘으로 학습하기에 그 양이 충분하지 않아 2분 길이의 데이터를 32등분 하여, 2초 뇌파 길이 단위로 특징을 추출했다. 추출한 특징의 종류로는 Statistical Feature, Frequency Domain Feature, High-order crossings, Hjorth Parameter 및 Frontal Asymmetry Alpha 등이 있으며, 데이터 별 총 641개 특징을 추출하여 분류알고리즘을 학습하고 검증하는데 사용했다. 분류를 위해 사용한 알고리즘은 k-NN을 사용했으며, 피실험자별로 다소 차이가 있었으며, 평균 67.08%의 정확도로 스트레스와 정상 상태를 분류하였다.

제 4 장 특징선택 기법을 사용한 인공지능 기반의 스트레스 상태 분류

4.1. 소개

3장에서는 데이터별로 641개라는 많은 양의 특징을 사용하여 분류하였다. 또한 [14]과 [30]에서도 많은 양의 특징을 사용하여 분류를 하였는데, 이런 경우에는 일반적으로 차원의 저주라 불리는 문제가 야기된다. 특징이 많으면 모델링에 필요한 학습 집합의 크기가 커야 하며, 분류할 때의 시간이 많이 걸리게 된다. 그에 따라 [31]는 principal components analysis(PCA), maximum relevance minimum redundancy(mRMR)을 사용하였고, [15]은 F-score를 이용하여 특징을 선택하는 등 다양한 특징 공간의 축소 기법을 사용하였다. 따라서 4장에서는 GA기반의 특징선택을 사용하여 특징 공간을 축소하였으며, 성능 비교를 위해 PCA를 사용한 차원 축소와 성능을 비교한다.

본 논문에서는 k-NN(k-Nearest Neighbor)을 이용해 스트레스와 스트레스가 아닌 상태를 분류하였다. EEG 신호 특징은 3장에서 사용한 특징을 동일하게 사용하였으며, 모든 특징을 이용한 분류 정확도와, PCA를 사용한 분류정확도, GA기반의 특징선택을 사용한 분류정확도를 비교하였다.

4.2. 특징선택 알고리즘

특징선택은 고차원 특징공간을 줄이는 방법이다. 특징선택을 통해 분류 알고리즘을 수행하는데 걸리는 계산시간을 줄일 수 있다. 본 4장에서는 특징차원축소에서 일반적으로 많이 사용되는 PCA와 GA기반의 특징선택을 각각 적용하여 비교했다.

Principal component analysis(PCA)는 특징들의 분산이 최대가 되게 하는 Principal Component(PC)를 찾는 기법[8]으로 서로 연관성 있는 고차원 특징 공간을 축소하여 시각화 하는데 유용하다.

Genetic algorithm(GA)는 진화이론에 기반한 강인하고 효율적인 최적화기법이다. GA는 selection, crossover, mutation, replacement 등의 주요 연산으로 구성된다. GA기반의 특징선택[32]은 추출한 여러 특징조합을 염색체로 만들어, 가장 클래스간 구별이 잘 되는 특징조합을 좋은 염색체로 선택되도록 한다.

클래스간 구별이 잘 되는 특징조합을 찾기 위해서 두 클래스 사이의 분리정도의 계산이 필요하다. 클래스 사이의 분리정도를 계산하는 식은 식 4.1에서 보여준다.

$$\text{class separability rating} = \frac{\text{inter classes separability}}{\text{intra class closeness}} \quad (4.1)$$

여기서, inter classes separability는 서로 다른 클래스 사이가 얼마나 떨어져 있는지에 대한 척도다. intra class closeness는 동일 클래스 내부의 특징들이 얼마나 모여 있는지에 대한 척도이다. 결국 클래스 사이의 분리정도는 동일 클래스는 모여 있을수록, 서로 다른 클래스 사이는 멀수록 높아지게 된다.

본 연구에서는 2개 특징벡터 간 거리를 구하는데 Euclidean distance를 사용했다. 식 4.2는 Euclidean distance 계산식을 보여준다.

$$d(x,y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.2)$$

여기서, x와 y는 두 개의 다른 특징 벡터이며, n은 특징의 개수이다.

inter classes separability는 서로 다른 클래스의 각 특징벡터의 거리 평균을 구하고, 먼저 서로 다른 두 클래스의 특징벡터 사이의 모든 거리를 계산한 다음 평균을 낸다. 계산식은 아래 식 4.3과 같다.

$$\text{inter classes separability} = \frac{1}{{}_n C_2 \cdot M \cdot M} \sum_{i=1}^N \sum_{j=i+1}^N \sum_{k=1}^M \sum_{l=1}^M d(i_k, j_l) \quad (4.3)$$

intra class closeness는 동일 클래스 내부의 특징에서 특징벡터끼리의 모든 거리를 계산한 다음 평균을 낸 값이다. 계산식은 아래 식 4.4와 같다.

$$\text{intra classes separability} = \frac{1}{N \cdot M \cdot M} \sum_{i=1}^N \sum_{j=1}^M \sum_{k=1}^M d(i_j, j_k) \quad (4.4)$$

수식 4.3 및 수식 4.4에서, N은 클래스의 개수를 의미한다. 본 논문에서는 스트레스와 정상 상태 등 2개의 클래스를 사용하였으며, 따라서 N=2이다. 각 클래스의 특징 개수는 M이다. i_j 는 I클래스에서의 j번째 특징 벡터를 의미한다.

4.3. 실험결과 및 성능비교

4장에서는 3장에서의 스트레스 분류를 위한 프로세스에 feature selection을 추가하였다. 제안하는 GA기반 특징 선택 알고리즘의 성능을 검증하기 위한 비교군으로 PCA를 이용한 특징 차원 축소 기법을 사용한다. 그림 4.1은 특징선택 기법을 사용한 EEG신호를 이용한 인공지능 기반의 스트레스 상태 분류의 전체 프로세스를 보여준다.

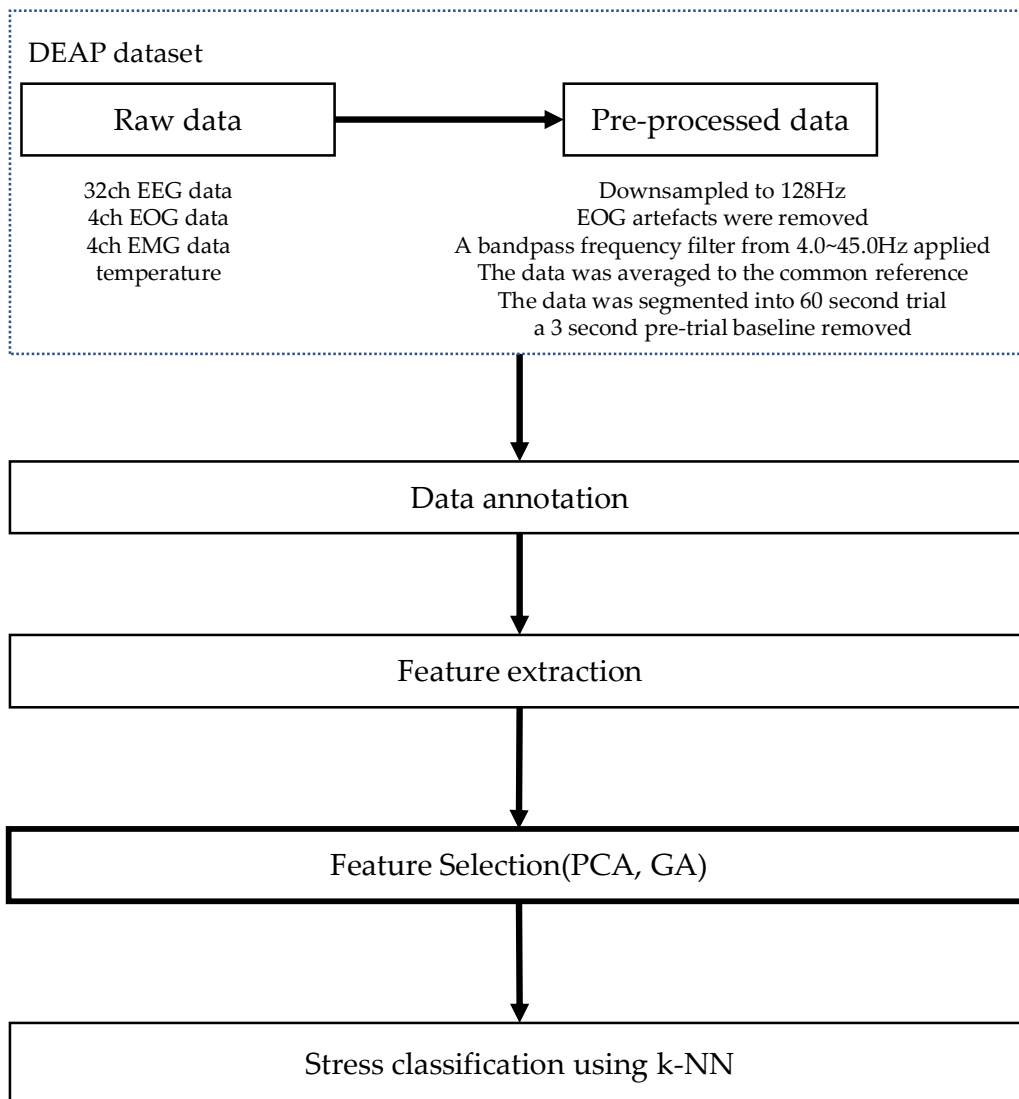


그림 4.1. 특징선택 기법을 사용한 스트레스 상태 분류의 전체 프로세스

4장에서도 3장에서와 같이 분류를 위해 k-nearest neighbors(k-NN) [17]을 사용했다. k-NN을 사용한 이유는 알고리즘이 동작하는 특성으로 인해 특징 선택 알고리즘의 성능이 가장 잘 반영되기 때문이다. k-NN을 사용하여 특징 추출 및 특징 선택 과정에서 나온 특징들과 가장 가까운 k개의 학습 데이터를 비교하여 해당하는 클래스를 분류하였다.

표 4.1과 그림 4.2에서 3가지 특징 선택 방법에 따른 분류정확도를 비교하였다. 특징 선택 없이 모든 특징을 사용한 방법, PCA를 사용한 특징 차원 축소, GA를 통한 특징 선택의 분류 정확도를 피실험자별로 비교하였다. 각각의 실험은 여러번 반복하여 수행하였으며, 각 실험의 최상의 결과를 비교표에 반영하였다. GA 기반 특징 선택 알고리즘을 사용한 경우에는 17명의 피실험자(전체 25명 중 68%)에서 가장 높은 성능을 보였다. 반면에 모든 특징을 사용하여 분류하였을 때는 7명의 피실험자에서 분

류 정확도가 더 높았다. PCA를 사용한 차원축소를 적용한 결과에서는 단 한 피실험자의 분류 정확도가 가장 높았다. GA 기반의 특징선택을 하였을 경우에는 비교적 나쁜 성능을 보인 피실험자에서도 정확도 차이가 평균 1.18%로 성능차이만을 보였다. 이러한 결과는 GA 기반 특징선택의 성능이 유용하다는 것을 의미한다. 이러한 실험 결과가 나온 이유는 GA알고리즘이 분류를 하는데 적합한 특징 조합을 선택했기 때문이다.

표 4.1. 3가지 특징 선택 방법에 따른 피실험자 별 분류 정확도

피실험자 번호	모든 특징 + KNN 분류 정확도(%)	PCA + KNN 분류 정확도(%)	GA based + KNN 분류 정확도(%)
1	87.91%	80.10%	87.13%
2	63.91%	60.22%	61.64%
4	54.69%	51.04%	52.60%
5	61.24%	59.36%	68.15%
8	72.54%	66.93%	72.51%
10	60.05%	55.14%	61.83%
11	68.03%	66.59%	75.72%
12	73.58%	73.29%	72.45%
13	71.63%	72.83%	78.84%
14	82.21%	80.29%	83.65%
15	79.31%	75.80%	91.42%
16	62.24%	60.16%	64.84%
18	73.48%	73.44%	79.68%
19	51.84%	49.98%	61.22%
20	58.98%	54.28%	62.49%
21	66.78%	64.45%	72.64%
22	63.97%	62.14%	62.14%
24	73.26%	75.00%	77.08%
25	60.94%	61.14%	60.56%
26	54.69%	54.62%	89.11%
27	88.89%	88.54%	88.19%
28	63.54%	65.63%	68.23%
29	67.19%	64.06%	68.23%
31	54.69%	51.82%	57.81%
32	61.35%	58.99%	75.78%

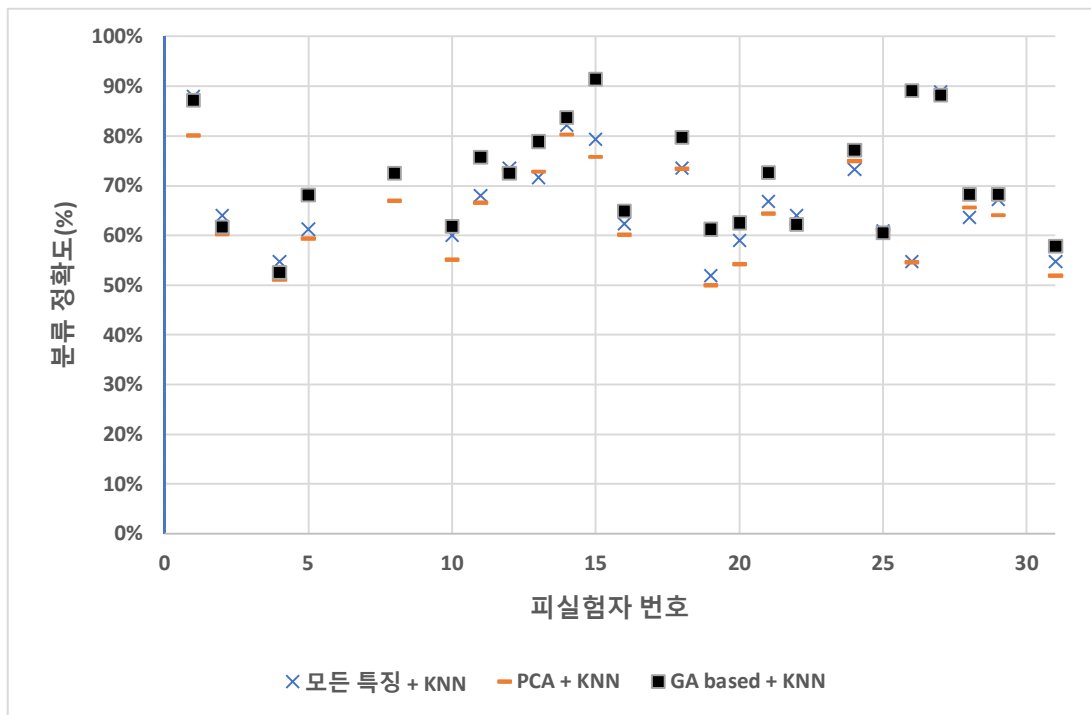


그림 4.2. 3가지 특징 선택 방법에 따른 피실험자별 분류 정확도




그림 4.3. PCA를 사용한 특징공간 축소 결과(15번 피실험자)




그림 4.4. GA를 이용한 특징 선택 결과(15번 피실험자)

그림 4.3과 그림 4.4는 분류 정확도에서 큰 차이를 보인 15번 피실험자에서 각각 PCA와 GA를 사용한 결과를 산점도 차트를 이용해 나타내었다. PCA를 사용한 방법에서는 두 클래스간 분리가 잘 되어있지 않으며, 클러스터의 형성이 좋지 않은 것이 확인된다. 한편 GA를 이용한 특징 선택에서는 클래스간의 분리가 비교적 높음을 시각적으로 확인할 수 있다.

표 4.2와 그림 4.5는 특징선택 알고리즘의 성능의 비교를 보여준다. 모든 특징을 사용한 경우에는 평균 67.08%의 정확도가, PCA를 이용해 특징선택을 한 경우에는 평균 65.03%의 정확도를 보였으며, GA기반의 특징선택을 사용한 경우에는 평균 71.76%의 정확도로 나타났다. 실험결과에서 GA기반의 특징선택을 사용했을 때 가장 좋은 분류성능을 보였다. 이와 같이 모든 특징을 사용했을 때 보다 GA기반의 특징선택을 사용했을 때 클래스간 분리가 가장 잘 되는 것을 알 수 있다.

표 4.2. 사용 특징 별 스트레스 분류 평균 정확도 비교

Features	Classifier	Precision
모든 특징 사용	k-NN	67.08%
PCA[31] 이용 차원 축소		65.03%
GA 알고리즘 기반 특징 선택		71.76%




그림 4.5. 사용 특징 별 스트레스 분류 정확도 비교

4.4. 결론

4장에서는 뇌파 특징을 선택하는 기법을 제안하였다. 실험은 데이터 라벨링, 특징 추출, 특징 선택, 분류 등 4단계로 수행되었다. 실험에 사용한 데이터는 3장에서와 같이 감정 분류를 위한 실험을 위해 공개된 뇌파 데이터셋인 DEAP를 사용하였고, 스트레스 상태와 정상 상태를 라벨링 방법도 같은 방법을 사용하였다.

PCA 및 GA기반의 특징선택 기법을 사용하여 k-NN알고리즘을 통해 분류하여 각 특징차원 축소기법을 적용한 이후의 분류 정확도를 비교하였다. 4장에서의 결과는 GA기반의 특징선택을 했을 때 분류성능이 가장 좋음을 보였다.

모든 특징을 모두 사용하여 테스트 데이터셋을 k-NN분류기를 사용한 결과 정확도가 67.08%가 나왔으며, PCA를 사용하여 특징공간 차원축소를 하였을 때는

65.03%의 정확도를 보였다. GA기반의 특징선택을 수행한 후 k-NN 분류기를 사용한 결과 71.76%의 정확도를 보였다. 이를 통해 GA 기반의 특징선택이 클래스간 분리가 잘 된 특징을 잘 선택했음을 알 수 있다. 비교를 위해 k-NN을 사용한 실험과의 비교에서도 특징선택을 하지 않았을 경우에는 그 결과가 크게 차이가 없었으나, GA기반의 특징선택을 사용했을 때는 다소 정확도가 향상되는 결과를 보였다.

제 5 장 개별 학습 SVM을 사용한 인공지능 기반의 스트레스 상태 분류

5.1. 소개

특징선택을 통해 특징조합을 찾아서 분류 알고리즘에 공통적으로 적용할 경우 최적의 분류 성능이 나오지 않을 수 있다. 특징 유형별로 각각 SVM 분류 모델을 생성하면 특징 유형별로 좋은 분류성능을 보이는 SVM 분류 모델이 생성되며, 이를 통해 전체적인 분류성능의 향상을 기대할 수 있다.

머신러닝을 다루는 분야에서 개별 학습 SVM과 같은 앙상블 기법을 사용한 다양한 연구[33-34]가 진행되고 있다. 본 논문에서는 개별 학습 SVM을 이용하여 스트레스와 스트레스가 아닌 상태를 분류하여 분류 정확도를 도출하고, 성능 검증을 위해 GA기반의 특징선택을 사용한 분류 정확도와 비교하였다.

5.2. 개별 학습 SVM

분류성능의 향상을 위해 각각의 SVM에 적합한 특징을 개별적으로 학습하였다. 분류알고리즘의 성능을 높이기 위해 서로 다른 특징을 가지고 학습된 SVM에서 나온 분류결과를 결정함수에 입력하여 최종 분류결과를 도출하게 된다. 그림 5.1은 개별 학습 SVM의 개념도를 보여준다.




그림 5.1. 개별 학습 SVM 개념도

5.3. 실험결과 및 성능비교

5장에서는 3장에서 4장까지 사용했던 특징들 중 Statistical Feature, Frequency Domain Feature, High-order crossings을 사용하였다. 각각의 특징 유형은 개별적인 SVM알고리즘으로 학습하여 각각의 학습모델을 만들었다. 그림 5.2는 특징선택 기법을 사용한 EEG신호를 이용한 인공지능 기반의 스트레스 상태 분류의 전체 프로세스를 보여준다.

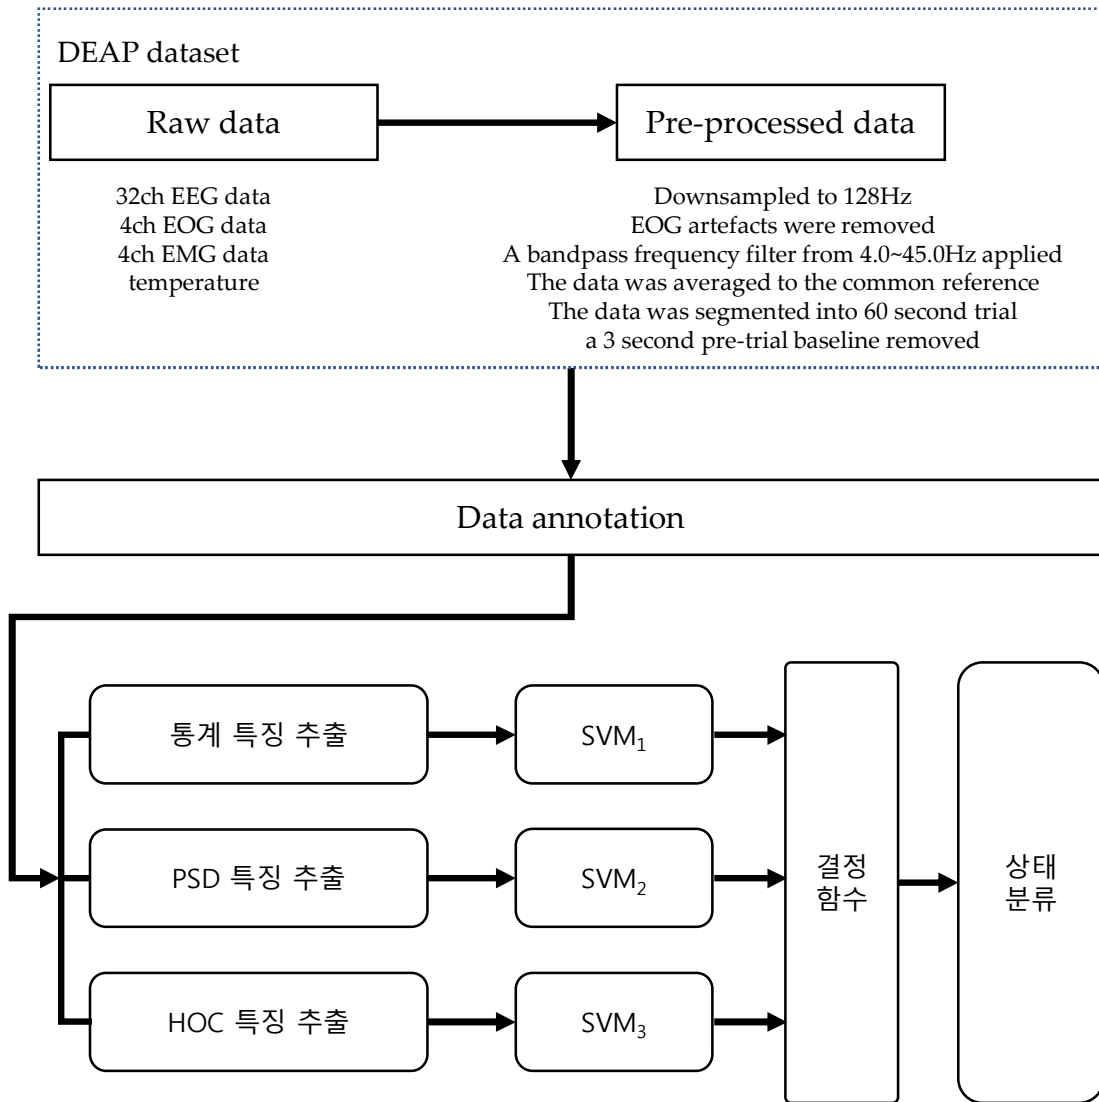


그림 5.2. 개별 학습 SVM을 사용한 스트레스 상태 분류의 전체 프로세스

결정함수 단계에서는 각 SVM에서 나온 결과를 취합하게 되는데, 상태분류를 위해 아래의 식을 사용하였다.

$$Decision = \sum_{n=1}^3 SVM_n \quad (5.1)$$

$$Status = \begin{cases} normal, & \text{if } Decision \geq 2 \\ stress, & \text{Otherwise} \end{cases}$$

개별 학습 SVM의 분류 성능을 검증하기 위해, 4장에서의 GA기반 특징선택 알고리즘을 적용한 분류 결과와 비교하였다. 표 5.1과 그림 5.3은 개별 학습 SVM을 사용한 분류 결과와 GA기반 특징선택을 사용한 결과를 피실험자 별로 비교한 결과를 보여준다. 개별 학습 SVM은 피실험자에 따라 최소 63.91%, 최대 91.25%의 분류

정확도를 보였다. 반면 GA기반 특징선택의 경우 최소 52.60%, 최대 91.42%의 분류정확도를 보였다. 개별학습 SVM을 사용한 경우 19명의 피실험자에서 가장 높은 성능을 보였고, GA기반 특징선택을 사용한 경우는 6명의 피실험자에서만 분류 정확도가 더 높았다. 이 결과를 통해 개별학습 SVM이 스트레스 분류에 전반적으로 더 우수한 성능을 가졌음을 알 수 있다.

표 5.1. GA기반 특징선택 방법과 개별 학습 SVM 분류 성능 비교

피실험자 번호	GA based + KNN 분류 정확도(%)	개별학습 SVM 분류 정확도(%)
1	87.13%	85.00%
2	61.64%	82.50%
4	52.60%	75.21%
5	68.15%	69.75%
8	72.51%	76.75%
10	61.83%	80.18%
11	75.72%	79.52%
12	72.45%	73.41%
13	78.84%	77.21%
14	83.65%	84.71%
15	91.42%	91.25%
16	64.84%	74.90%
18	79.68%	78.75%
19	61.22%	75.00%
20	62.49%	63.91%
21	72.64%	67.34%
22	62.14%	69.56%
24	77.08%	77.78%
25	60.56%	65.31%
26	89.11%	89.38%
27	88.19%	88.89%
28	68.23%	69.17%
29	68.23%	83.54%
31	57.81%	76.98%

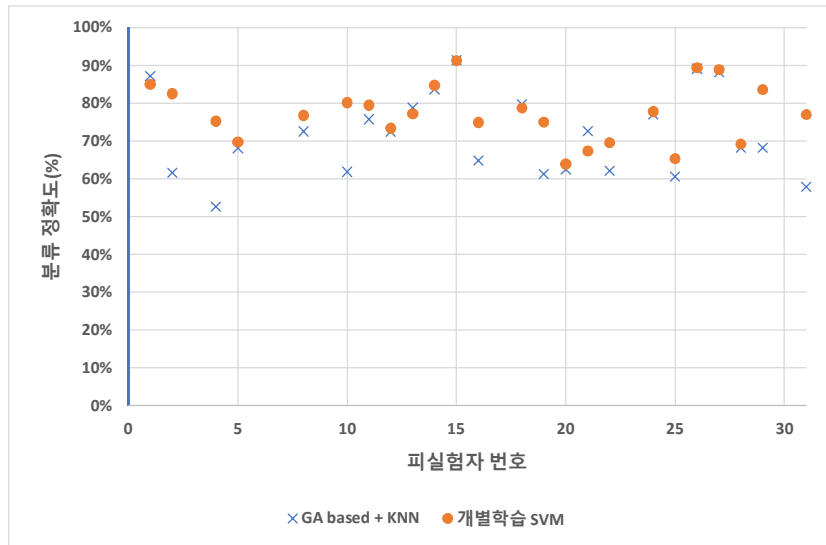


그림 5.3. GA기반 특징선택 방법과 개별 학습 SVM 분류 성능 비교 그래프

실험결과 개별학습 SVM이 GA기반 특징선택 알고리즘을 적용한 결과보다 평균 5.75% 분류 성능이 높게 나왔다. 표 5.2와 그림 5.4는 개별 학습 SVM과 GA기반 특징선택 방법을 적용한 분류 성능의 평균을 보여준다.

표 5.2. 개별 학습 SVM 평균 분류 성능 비교

종류	분류 성능 평균
GA기반 특징선택	71.76%
개별학습 SVM	77.51%

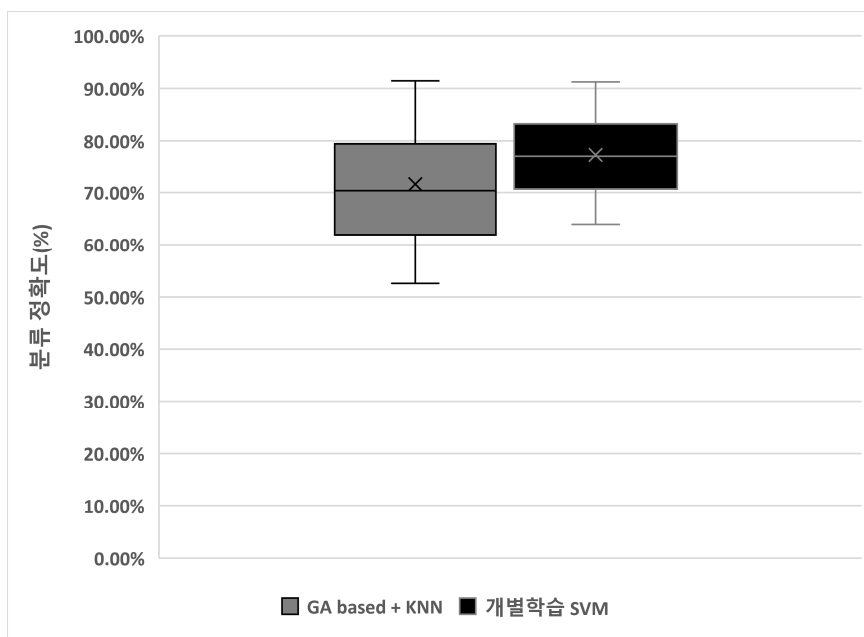


그림 5.4. 개별 학습 SVM 평균 분류 성능 비교 그래프

5.4. 결론

5장에서는 뇌파를 통해 스트레스를 분류하는 알고리즘으로 개별학습 SVM을 제안하였다. 실험에 사용한 데이터는 4장에서와 같이 감정 분류를 위한 실험을 위해 공개된 뇌파 데이터셋인 DEAP를 사용하였고, 3개 SVM에 각각 Statistical Feature, Frequency Domain Feature, High-order crossings을 특징 유형별로 학습시켰다. 3개의 SVM서 나온 분류결과를 취합하는 방법은 다수결을 사용했다. 개별학습 SVM을 사용한 스트레스 분류 실험에서 평균 분류 성공률은 77.51%로 나타났으며, 이는 GA알고리즘 기반의 특징선택을 사용한 결과인 71.76% 대비 5.75% 높은 성능이 나타남을 보였다.

제 6 장 인적오류 사고예방을 위한 뇌파 기반 기술의 응용

6.1. 소개

고용노동부 통계에 따르면 산업재해율[35]은 그림 6.1의 그래프와 같이 2012 0.59%에서 2020년 0.57%로 해다마 산업 재해가 이어지고 있다. 이 수치는 선진국에 비해 2배 이상 높은 실정이며, 근로자 십만명당 치명적 산업재해 수가 2019년 기준으로 4.6명을 기록하는 등 무시할 수 없는 수준으로 산업재해가 발생하고 있다.




그림 6.1. 고용노동부 산업재해 현황

산업이 급속히 발달함에 따라 시설은 대형화가 되고 복잡해졌으며 소수인원으로 대형설비 운전이 가능하므로, 인적오류가 발생했을 경우에는 막대한 물적, 인적 손실을 초래할 수 있으며, 국내의 대표적인 사례로는 92년 해양도시가스 폭발사고, 94년 아현동 도시가스 폭발사고, 95년 대구 지하철 폭발사고 등이 있었다. 따라서 산업재해를 줄이는 것이 중요하다.

뇌파는 뇌 신경세포 사이의 전기 흐름으로 심신상태에 따라 다르게 나타나며, 뇌 상태를 간접적으로 측정하는 가장 중요한 지표중 하나이다. 작업자의 안전과 건강에 가해지는 위험으로부터 근로자를 보호하는 장비를 개인보호구라고 하며, 산업현장에서는 작업장 특성에 따라 다양한 개인보호구를 착용하고 있다. 작업자는 다양한 개인보호구를 이미 착용하고 있는 상태이므로 뇌파측정기를 추가적으로 휴대하는 것에 대한 거부감 발생할 수 있다. 따라서, 뇌파측정기를 산업현장에 적용하는 데는 웨어러블 형태로 제작하여 개인보호구와 결합된 형태로 제작하여 작업자가 자연스럽게 사용가능한 형태가 되어야 한다.

6장에서는 안전모에 결합된 뇌파 측정 장치를 통해 작업자의 불안전행동을 유발하는 스트레스를 감지하여 산업재해를 줄이는데 도움이 되고, 인적오류로 인한

대규모 사고방지를 위한 기술의 응용에 대해 설명한다. 먼저 기존 뇌파 상용 제품을 분석하고, 산업 현장용 웨어러블 뇌파측정기를 제안한다. 또한 스트레스 기반 작업자 상태 지표를 개발하여 작업자의 상태를 숫자로 표현하였다. 마지막으로 인적오류 사고예방 소프트웨어를 통해 작업자 상태 기술 응용의 예를 제시하였다.

6.2. 산업 현장용 웨어러블 뇌파측정기

6.2.1. 기존 뇌파 상용 제품 조사

산업 현장용 웨어러블 뇌파측정기의 사양 및 형태를 정의하기 위해 기존 뇌파 상용 제품을 조사하였다. 뇌파를 수집하는 전극의 사양, 뇌파를 수집할 때의 샘플링 주파수, 통신 방법, 무게 등을 조사하였다. 표 6.1은 기존 상용 제품의 사양을 정리한 것이다.

표 6.1. 기존 상용 제품 사양 조사

회사/제품명	전극 사양	샘플링 주파수	통신 사양	무게(본체)
Emotiv/INSIGHT	뇌파전극 5, 기준전극 2	128Hz	BLE	-
SmartCap/LifeBand	뇌파전극 5	-	BT, BLE	55g
NeuroSky/MindWave	뇌파전극 1, 기준전극 1	100Hz	BT, BLE	90g
MyndPlay/MindBand	뇌파전극 1, 기준전극 2	512Hz	BT, BLE	-
Macrotellect/Brainlink	뇌파전극 2, 기준전극 2	512Hz	BT	39g

대부분 장비는 웨어러블 장비로서 가벼운 무게로 제작되었으며, 뇌파 데이터를 전송하는 방법은 블루투스 무선통신을 이용하여 전송하였다. 샘플링 주파수는 최소 100Hz에서 최대 512Hz로 뇌파를 수집하는데 충분한 샘플링 주파수를 만족하였다.

6.2.2. 산업 현장용 웨어러블 뇌파측정기 하드웨어

뇌파 측정기 하드웨어는 (주)커넥스의 뇌파측정기 개발품을 사용하였으며, 주요 개발과정에서 형태, 전극, 사양 등을 함께 논의하였다. 그림 6.2는 산업 현장용 웨어러블 뇌파측정기의 형태를 보여준다.




그림 6.2. 산업 현장용 웨어러블 뇌파측정기 개념도

측정된 뇌파 신호를 최대한 아날로그 신호의 변형없이 뇌파 모니터링 서버로 전송하기 위해 고성능 생체신호용 AD컨버터를 적용하였다. 또한 통신 방법으로 WiFi를 적용하여 작업자의 편의성을 고려하면서도 고해상도 뇌파데이터를 실시간으로 전송가능하도록 설계하였다. 뇌파를 측정하기 위한 전극은 기록전극 4개와 기준전극 1개를 설치하였으며, 샘플링 주파수는 500Hz, 해상도는 24bit로 수집하도록 하였다.

제작한 하드웨어의 최종 형태는 안전모, 전극머리띠, 뇌파수집 및 무선전송 모듈 등 3가지로 구성된다. 그림 6.3은 산업 현장용 웨어러블 뇌파측정기를 보여주며, 그림 6.4는 각각의 구성을 보여준다.



그림 6.3. 산업 현장용 웨어러블 뇌파측정기




그림 6.4. 산업 현장용 웨어러블 뇌파측정기

((a): 안전모, (b): 전극머리띠, (c): 뇌파수집 및 무선전송 모듈)

제작한 산업 현장용 웨어러블 뇌파측정기는 WiFi를 통해 TCP/IP 통신을 통하여 뇌파신호를 송신하도록 설계하였으며, 뇌파 수집 서버 한 대에 여러 장치가 접속되어 뇌파를 수집할 수 있도록 장치 고유 번호를 접속 초기에 요청하도록 프로토콜을 설계하였다. 장치 고유 ID 전달을 포함한 뇌파 신호 전송 프로토콜의 절차는 다음과 같다.

- Step1 : 클라이언트가 서버에 접속을 요청
- Step2 : 서버에서 클라이언트 접속 수락
- Step3 : 서버에서 클라이언트에게 ID 요청
- Step4 : 클라이언트에서 서버로 ID 전송
- Step5 : 클라이언트에서 서버로 뇌파 데이터 스트림 전송

서버와의 접속이 성공하면 장치 고유 ID 요청 패킷을 보내며, 패킷의 형태는 표 6.2와 같다.

표 6.2. 장치 고유 ID 요청 패킷

Number	Field ID	Field Name	Type	Size(byte)	Example
1	Request	Request String	Str.	7	“REQUEST”

장치 고유 ID 요청에 대한 응답은 표 6.3과 같다.

표 6.3. 장치 고유 ID 응답 패킷

Number	Field ID	Field Name	Type	Size(byte)	Example
1	Response	Response String	Str.	18	“REQUEST000000001”

뇌파 데이터 전송은 최대 8채널 뇌파데이터를 받을 수 있게 설계하였으며, 연속해서 보내는 경우를 고려하여 starting point를 인식할 수 있는 4바이트 필드를

정의하였다. 표 6.4는 뇌파 데이터를 전송하는 패킷을 보여준다.

표 6.4. 뇌파 데이터 패킷

Number	Field ID	Field Name	Type	Size(byte)	Example
1	Check Byte	Check packet starting point	INT	4	“REQUEST000000001”
2	CH1	Channel 1	INT	4	
3	CH2	Channel 2	INT	4	
4	CH3	Channel 3	INT	4	
5	CH4	Channel 4	INT	4	
6	CH5	Channel 5	INT	4	
7	CH6	Channel 6	INT	4	
8	CH7	Channel 7	INT	4	
9	CH8	Channel 8	INT	4	

개별 뇌파측정기는 장치 고유 ID를 저장하고 있으며, 통신할 때 장치 고유 ID를 서버에 전송한다. 서버에서는 장치 고유 ID를 기준으로 작업자를 구별하기 때문에, 뇌파측정기를 사용하는 작업자가 변경될 경우 뇌파측정기가 저장한 장치 고유 ID를 변경해야 한다. 이러한 상황에 유연하게 대처하기 위해 뇌파측정기는 외부 무선 접속을 통한 설정변경이 가능하도록 제작되었다. 뇌파 측정기 외부의 버튼을 누른 상태로 전원을 켜면 설정 변경 모드로 진입하게 된다. 그림 6.5에서 설정 변경 버튼의 위치를 표시하였다.



그림 6.5. 뇌파측정기 설정 변경 버튼

설정변경모드로 전원이 켜진 뇌파측정기는 WiFi를 통해 접속이 가능하다. 설정을 편리하게 변경할 수 있도록, 그림 6.6에서의 안드로이드 어플리케이션을 개발하였다.

설정할 수 있는 항목은 장치 고유 ID 뿐만 아니라, 접속 대상 AP의 SSID 및 보안키, 모니터링 시스템의 아이피와 포트번호 등이 있다.

2:15 90%

접속하기 접속끊기 접속상태 : 접속안됨

SSID : eegtest

SSID 비밀번호 : eegtest1234

모니터링 시스템 IP : 192.168.1.5

모니터링 시스템 PORT : 12345

확인

사용방법

1. 부팅모드 스위치가 눌린 상태에서 수집장치 전원을 켭니다.
2. CNSBRAIN 와이파이기에 연결합니다.
(비밀번호:cnspassword12345)
3. 접속버튼을 누릅니다.
(접속이 안된다면 수집장치의 전원을 내렸다 올립니다)
4. 새로운 정보를 입력합니다.
5. 저장버튼을 누릅니다.

그림 6.6. 뇌파측정기 설정 변경 어플리케이션

제작한 뇌파측정기를 통해 수집된 데이터의 원본신호를 보면 노이즈가 상당히 포함되어 있어 뇌파신호가 거의 보이지 않는다. 이는 미약한 신호인 뇌파신호를 받아들이기 위해 전극에서 수집된 신호를 큰 이득으로 증폭하는 과정에서, 주변의 전원으로 공급되는 전기의 주파수인 60Hz 신호가 다량으로 유입되기 때문이다. 그림 6.7는 뇌파측정기를 통해 수집된 원본 데이터를 보여준다.




그림 6.7. 뇌파측정기를 통해 수집된 원본신호

따라서 60Hz 노치 필터의 적용이 필요하며, 뇌파연구에서 주로 사용되는 주파수 대역(delta, theta, alaph, beta, gamma)만을 남기는 대역통과필터를 적용하여 뇌파를 제외한 신호의 영향을 줄이는 것이 필요하다. 뇌파측정기에 신호를 수집하는데 적용한 대역통과필터는 0.5Hz ~ 128Hz를 사용하였다. 그림 6.8은 대역통과필터 및 60Hz 노치필터를 적용한 뒤의 뇌파신호를 보여준다.




그림 6.8. 대역통과 필터 및 노치필터를 적용한 뇌파 신호

제작한 산업 현장용 웨어러블 뇌파측정기가 취득한 데이터가 잘 들어오는지 확인하기 위하여 NETECH사의 EEG 시뮬레이터를 사용하였다. 표 6.5는 뇌파 시뮬레이터의 사양을 보여주며, 그림 6.9는 NETECH사의 뇌파 시뮬레이터의 사진이다.

표 6.5. 뇌파 시뮬레이터 사양

항목	사양
품명	Minisim EEG Simulator
신호 종류	Alpha, Beta, Sine, Square, Triangle
주파수	0.1, 0.5, 2, 50, 60 Hz
진폭	10, 30, 50, 100, 500 μ V, 1, 2, 2.5 mV



그림 6.9. NETECH EEG 시뮬레이터

산업 현장용 웨어러블 뇌파측정기에서 수집되는 뇌파신호가 잘 들어오는지 여부를 확인하기 위한 비교군으로는 전문 뇌파 측정기인 Latha사의 QEEG-32FX 및 시중에 나와 있는 무선 뇌파 장비(NeuroSky Mindwave, 메딕션 Mave)를 사용했다. 비교 대상 뇌파측정기의 사양은 표 6.6과 같다.

표 6.6 비교 대상 뇌파측정기 사양

회사/제품명	전극 사양	샘플링 주파수	통신 사양
메딕션/Mave	뇌파전극 2, 기준전극 1	250Hz	BT, BLE
NeuroSky/MindWave	뇌파전극 1, 기준전극 1	512Hz	BT, BLE
Laxtha/QEEG-32FX	뇌파전극 32, 기준전극 2	1024Hz	USB

하드웨어 성능 비교를 위해서 뇌파 시뮬레이터에서 각각 사인파 및 구형파를 발생시켜보고, 전극을 통해 제작한 웨어러블 뇌파측정기 및 비교 대상 뇌파측정기에 신호를 입력시킨다. 이후 파형 비교를 통해 뇌파신호가 잘 들어오는지 확인한다. 그림 6.10은 산업 현장용 웨어러블 뇌파측정기의 하드웨어 비교 절차 과정을 나타내었다.




그림 6.10. 산업 현장용 웨어러블 뇌파측정기의 하드웨어 비교 절차도

먼저 사인파 입력에서의 각 장비 신호 측정 결과를 비교하였다. 뇌파 시뮬레이터에 Waveform Type는 Sine, Frequency는 5Hz, Amplitudes는 30uV으로 설정하였으며, 사인파 입력에서의 기기 간 편차는 거의 없는 것으로 나타났다. 그림 6.11은 사인파 입력 상태에서의 장비별 시간 도메인 비교를, 그림 6.12은 주파수 도메인에서의 비교한 파형을 보여준다.




그림 6.11. 사인파 입력 상태에서의 장비별 시간 도메인 비교




그림 6.12. 사인파 입력 상태에서의 장비별 주파수 도메인 비교

다음으로는 구형파 입력에서의 각 장비 신호 측정 결과를 비교하였다. 뇌파 시뮬레이터에 - Waveform Type는 Square, Frequency는 5Hz, Amplitudes는 30uV으로 설정하였다. 구형파에서의 비교 실험에서는 Mindwave를 제외하고 비슷한 결과를 보였다. 그림 6.13은 구형파 입력 상태에서의 장비별 시간 도메인 비교를, 그림 6.14는 주파수 도메인에서의 비교한 파형을 보여준다.




그림 6.13. 구형파 입력 상태에서의 장비별 시간 도메인 비교




그림 6.14. 구형파 입력 상태에서의 장비별 주파수 도메인 비교

뇌파 시뮬레이터를 사용한 성능 비교 실험 이후 추가적으로, 실제 두피에 전극을 붙여 데이터를 취득하여 신호의 형태를 비교하였다. 그림 6.15은 뇌파측정기 제품과 전문 뇌파 측정기의 비교 절차를 보여준다.



그림 6.15. 뇌파측정기 제작품과 전문 뇌파 측정기의 비교 절차

그림 6.16은 뇌파측정기 제작품과 전문 뇌파 측정기의 신호 비교한 결과를 보여준다. 전문 뇌파 측정 장비는 전체 32채널 중 Fp1, Fp2 등 2개 채널을 사용하여 측정하였으며, 그래프를 통해 비교했을 때, 유사한 파형이 나타나는 것을 확인할 수 있었다.




그림 6.16. 뇌파측정기 제작품과 전문 뇌파 측정기의 신호 비교 결과

6.3. 스트레스 기반 작업자 상태 지표

3장과 4장에서의 스트레스 상태 분류 알고리즘을 통해 나온 결과는 이진 분류 결과로서 참 또는 거짓으로 출력된다. 뇌파를 통해 스트레스 상태로 분류되는 빈도가 높다면 작업자의 상태가 불안정한 것으로 볼 수 있다. 따라서 단위시간 당 작업자가 스

트레스인 상태로 분류된 횡수를 이용하며, 수식 6.1을 사용하여 계산하며, 안전한 상태부터 위험한 상태까지 0부터 10까지의 숫자로 표현된다.

$$f(t) = \begin{cases} 5 + \frac{1}{90} \sum_{m=0}^t [cf(m) - 1] & \text{at } 0 \leq t \leq 900 \\ 5 + \frac{1}{90} \left\{ \sum_{m=0}^{900} [cf(m) - 1] + \sum_{m=901}^t cf(m) \right\} & \text{at } 900 < t < 1800, \\ \frac{1}{180} \left\{ \sum_{m=t-1800}^t cf(m) \right\} & \text{at } t \geq 1800 \end{cases} \quad (6.1)$$

여기서, $cf(m)$ 는 인공지능 알고리즘으로 도출된 스트레스 분류 결과(0 또는 1)를, $f(t)$ 는 현재 시간 t 에서의 스트레스 상태에 대한 지표를 의미한다.

수식 6.1에서는 작업자의 초기 상태 지표를 5로 두고, 정상상태가 계속 유지되면 정상상태를 지표값에 빠르게 반영하여 위험도를 낮게 평가하고, 스트레스 상태가 계속 유지되는 상태에서는 15분 동안에는 초기 상태인 5를 유지하다가, 15분이 지난 시점부터 위험도를 올리도록 하는 만들어진 수식이다. 그림 6.17의 그래프는 작업자의 스트레스 상태가 계속해서 1이거나 0일 때 $f(t)$ 의 변화를 보여준다.




그림 6.17. 시간에 따른 $f(t)$ 의 변화

6.4. 결론

6장에서는 인적오류 사고예방을 위한 뇌파 기반 기술을 산업현장에 활용하는 응용방법을 제안하였다. 산업현장에서 작업자의 상태를 잘 반영하는 뇌파를 얻는 데 웨어러블 형태의 개인보호구를 사용하면 작업자의 추가적인 불편함 없이 산업현장에 적용이 가능하기 때문에 안전모와 뇌파측정기의 결합된 형태를 제시하였다.

뇌파 측정기의 제작에 앞서 기존 뇌파 상용 제품의 전극 사양, 샘플링 주파수, 통신 방법, 무게 등을 조사한 결과를 바탕으로 하드웨어의 사양을 결정하였다. 최종적으로 안전모, 전극머리띠, 뇌파수집 및 무선전송 모듈로 구성된 산업 현장용 웨어러블 뇌파측정기 하드웨어를 제작하였다. 제작한 뇌파측정기를 통해 뇌파가 잘 수집되는지의 확인을 위해 뇌파 시뮬레이터에서 출력되는 신호를 상용제품 2종, 전문 뇌파 측정기 및 제작한 뇌파측정기에 각각 입력하여 수집된 신호를 비교하였다. 비교한 결과는 상용제품 뿐만 아니라 전문 뇌파 측정기와도 비슷한 신호가 수집됨을 확인했다.

마지막으로 3장에서 5장에 걸쳐 제안한 알고리즘의 결과인 스트레스 분류 결과들의 30분간의 결과를 사용하여 작업자의 상태를 0부터 10까지 표현하기 위해 스트레스 기반 작업자 상태 지표를 제안하였다.

제 7 장 결론

작업자의 안전 향상을 위해 본 논문에서는 뇌파 분석 기술을 적용한 작업자 상태 모니터링 기술을 제안했다. 제안하는 기술은 EEG신호를 이용한 인공지능 기반의 스트레스 상태 분류 알고리즘과 인적오류 사고예방을 위한 뇌파 기반 기술의 응용이다. 인공지능 기반의 스트레스 상태 분류 알고리즘은 뇌파 측정, 특징 추출, 특징 선택, 인공지능 알고리즘 학습 및 분류 등 4단계로 구성된다. 인적오류 사고예방을 위한 뇌파 기반 기술의 응용에서는 산업 현장용 웨어러블 뇌파측정기 및 스트레스 기반 작업자 상태 지표를 제안하였으며, 이를 종합한 응용 방안으로 인적오류 사고예방 소프트웨어를 제시했다.

첫 번째로 인공지능 기반의 스트레스 상태 분류 알고리즘을 제안하였으며, 뇌파를 통해 작업자의 스트레스 상태와 정상 상태를 분류하기 위해 고안하였다. 실험을 위해 감정 분류를 위한 실험을 위해 공개된 뇌파 데이터셋인 Database for Emotion Analysis using Physiological Signals(DEAP)를 사용하였으며, DEAP 데이터셋에서 제공하는 Valence-Arousal 평면으로부터 스트레스 상태와 정상 상태를 라벨링 하여 실험에 사용했다. 사용한 특징들은 과거 연구에서 많이 사용되었던 특징인 statistical features, frequency domain features, higher-order crossings, Hjorth parameter, frontal asymmetry alpha를 사용하였다. 추출한 특징들을 이용하여 k-NN 분류기를 통해 분류한 결과 평균 67.08%의 정확도를 보였다.

두 번째로는 특징선택 기법을 적용하여 스트레스 상태 분류하는 방법을 제안하였다. 많은 양의 특징을 사용하는 경우 인공지능 알고리즘 학습에 필요한 데이터양이 기하급수적으로 늘어나고, 분류에 필요한 자원이 많이 필요하다. 따라서 클래스의 구분을 잘 할 수 있도록 특징 공간을 축소하는 방법을 적용하여야 한다. 본 논문에서는 GA기반의 특징선택을 뇌파신호에 활용하는 방법을 제안하였으며, 특징선택 알고리즘의 성능 비교를 위해 PCA를 사용한 결과와 비교하였다. 실험결과 모든 특징을 사용한 경우 분류 정확도는 67.08%, PCA를 사용한 경우에는 65.03%의 분류성능을 보였다. 본 논문에서 제안한 GA기반의 특징선택을 사용한 경우에는 71.76%의 분류성능을 보여, GA기반의 특징선택이 뇌파 특징조합에서 클래스간 분리가 잘 된 특징을 선택할 수 있음을 확인했다.

세 번째로는 분류알고리즘의 성능을 높이기 위해 특징들의 유형별로 개별 학습하여 분류하는 방법을 제안하였다. 개별학습 SVM에는 각각 statistical features, frequency domain features, higher-order crossings 등 3가지 특징 유형별로 개별적인 SVM

알고리즘에 학습하였으며, 다수결의 원리에 따라 스트레스 상태와 정상 상태를 분류하였다. GA기반 특징선택과의 분류성능 비교 실험 결과 GA기반 특징선택의 분류성능인 71.76% 대비 5.75%포인트 더 높은 77.51%의 분류 정확도를 보였고, 스트레스 상태 분류에서 개별학습 SVM이 유용함을 확인했다.

마지막으로 6장에서는 제안한 알고리즘을 활용하기 위한 응용 방안을 제시하였다. 산업현장의 작업자가 불편함 없이 받아들일 수 있게 안전모에 웨어러블 기술을 접목한 형태의 뇌파측정기를 제시하고, 기존 제품 분석을 통해 사양을 선정하여 제작하였다. 뇌파 시뮬레이터를 이용한 전문 뇌파 측정기 및 상용제품과의 성능 비교 실험에서 수집된 신호가 거의 동일함을 확인하여 제작한 산업 현장용 웨어러블 뇌파측정기가 잘 제작되었음을 확인했다.

향후 연구에서는 본 논문에서의 제안한 알고리즘 및 시스템은 작업자의 뇌파로부터 분류한 스트레스 상태를 이용하여 상태지표를 나타내는 방법을 발전시켜, 작업자의 불안정한 상태를 발생시킬 수 있는 다양한 감정 상태를 검출하는 알고리즘과 다양한 감정 상태를 통해 위험도 지표를 계산할 수 있는 계산식으로 발전시킨다면 더 세밀하게 작업자 위험 상태를 모니터링 할 수 있을 것으로 기대된다.

부록1. 인적오류로 인한 사고통계

부록1.1. 국내 열차 사고 사례

김성곤 외 1명[36]은 2004년부터 10년 동안의 인적오류로 인한 국내 열차 사고 사례를 연구하였으며, 인적오류로 인한 국내 열차사고 발생현황을 정리하였다. 인적오류로 인한 국내 열차 사고는 2004년부터 10년 동안 23건이 발생하였으며, 신호 확인 소홀과 유지 보수 소홀로 인해 발생한 사고가 9건과 7건으로 많이 부분을 차지하였다. 이와 같이 철도 분야에서는 인적오류로 인한 사고가 매년 지속적으로 발생하였다. 표 A1.1은 국내 열차사고 발생이 매년 꾸준히 발생하고 있음을 보여준다.

표 A1.1. 인적오류에 의한 국내 열차사고 발생현황 (국토교통부 항공·철도사고 조사위원회)

종별	연도										
	'04	'05	'06	'07	'08	'09	'10	'11	'12	'13	'14
기기취급 소홀			1						1		2
선로전환기 취급불량			1								1
신호 확인 소홀			1	3	2				1	2	9
운전방법 불량				1							1
운전협의 소홀			1		1						2
유지보수 소홀	1	1	1		1	1	1	1			7
작업방법 불량								1			1
합계	1	1	5	4	4	1	1	2	2	2	23

부록1.2. 크레인 사망재해 원인 분석

신윤철[37]은 이동식 크레인 사망재해 원인분석 연구에서 불안정한 행동에 의한 사망자 재해분석을 연구하였으며, 불안정한 행동으로 인한 사고로 총 1154명의 사망자가 발생했다고 연구에서 밝혔다. 세부적으로 작업 수행 소홀 및 절차 미준수(25.7%) 및 작업 수행 중 과실(19.2%)를 통해 약 45%의 사망자가 발생하였으며, 이러한 불안전행동에 의한 사망자는 제조업 및 건설업에서 빈번하게 발생했다. 표 A1.2는 불안정한 행동이 사망으로 충분히 이어질 수 있음을 보여준다.

표 A1.2. 불안전한 행동의 사고 사망자 재해 분석

구분	사망자(명)	발생비율(%)
계	1154	100
설비·기계 및 물질의 부적절한 사용·관리	175	15.1
구조물 등 그 밖의 위험방치 및 미확인	214	18.5
작업수행소홀 및 절차 미준수	297	25.7
불안전한 작업자세	0	0
작업수행 중 과실	222	19.2
무모한 또는 불필요한 행위 및 동작	42	3.6
복장, 보호구의 부적절한 사용	167	14.4
기타(분류불능 포함)	37	3.2

부록1.3. 조선업 관련 중대재해속보를 이용한 사고 통계 조사

본 논문에서는 안전보건공단에 공개된 조선업 관련 중대재해속보[38]를 이용하여 2013년부터 2018년 4월까지 약 5년 간 발생한 중대재해에 대하여 인적오류 분류 체계[39]에 따라 원인적 분류로 분석하였다.

중대재해는 산업재해 중 사망 등 재해 정도가 심한 것으로서 사망자가 1명 이상 발생한 재해, 3개월 이상의 요양이 필요한 부상자가 동시에 2명 이상 발생한 재해, 부상자 또는 직업성질병자가 동시에 10명 이상 발생한 재해를 말한다. 사고 횟수를 연도별로 집계한 결과는 표 A1.3에서 보여준다.

표 A1.3. 조선업 중대재해 인적오류 연도별 사고 횟수

연도	사고 발생 횟수
2013	17
2014	23
2015	15
2016	23
2017	11

인적오류 분류 체계에 따른 분류결과 실수로 인한 인적오류 비율은 24.2%, 착오로 인해 발생한 인적오류 비율은 36.3%로 나타났다. 그림 A1.1은 조선업 중대재해 인적오류를 원인에 따른 분류체계를 사용하여 분류하여 연도별로 집계한 것을 보여준다.




그림 A1.1. 연도별 원인에 따른 분류체계 통계

원인에 따른 분류체계로 분류한 결과 실수 및 착오로 인한 사고가 5년간 60.5%로 많은 부분을 차지했다. 피로 및 스트레스로 인해 야기되는 실수 및 착오를 줄이기 위한 방안이 필요하다. 피로 및 스트레스는 신체의 변화를 가져오며, 뇌파에도 영향을 미치기 때문에 뇌파기반의 작업자 모니터링을 하였을 때 작업자의 상태를 신속하게 알 수 있으며, 산업현장의 전반적인 안전 향상이 기대된다.

부록2. 인적오류 사고예방 소프트웨어

부록2.1. 인적오류 사고예방 소프트웨어 구성

인적오류 사고예방 소프트웨어는 크게 관리 데이터베이스, 작업자 상태 인지 모듈, 작업자 모니터링 소프트웨어로 구성된다. 관리 데이터베이스는 작업자별 뇌파 정보와 작업자 상태인지 결과를 저장한다. 작업자 상태 인지 모듈은 작업자의 스트레스 상태를 분류하고, 이를 지표 계산식에 의해 작업자의 상태를 숫자로 나타낸다. 마지막으로 작업자 모니터링 소프트웨어는 작업자의 실시간 뇌파신호 데이터에 대한 모니터링 기능을 제공한다. 그림 A2.1은 인적오류 사고예방 소프트웨어의 구성을 보여준다.

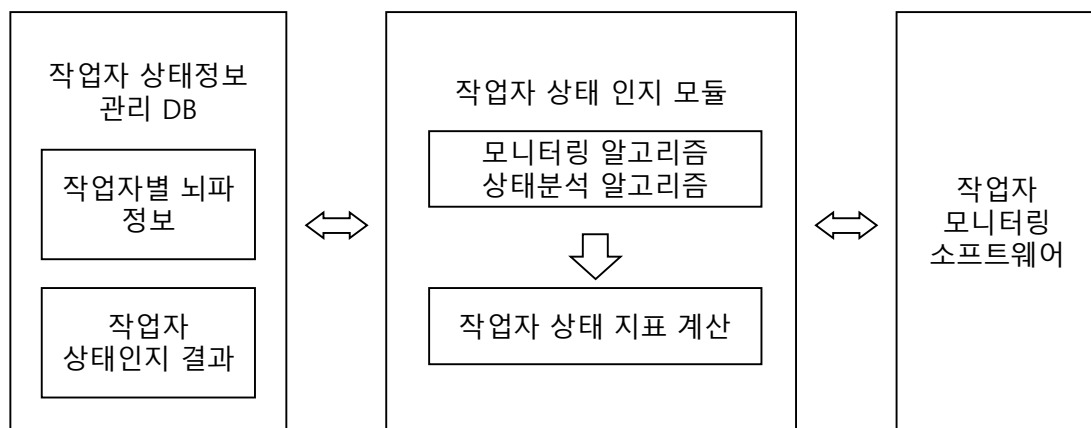


그림 A2.1. 인적오류 사고예방 소프트웨어 구성

부록2.2. 작업자 상태정보 관리 데이터베이스

작업자 상태정보 관리 데이터베이스의 목적은 다수의 작업자로부터 수집된 다채널 뇌파 정보를 저장하고, 작업자의 상태인지 결과를 통합적으로 저장하는 것이다. 데이터베이스 테이블에는 작업자 정보, 장치 정보, EEG 원본 신호 정보, EEG 결과 정보 등이 있다. 또한 모니터링 소프트웨어에서 실시간으로 수집되는 뇌파데이터를 보여주기 위한 실시간 데이터 테이블을 별도로 두었으며, 자정이 지난 이후에 기록되는 작업자별 일일 상태 지표 평균을 저장하는 테이블을 생성하였다.

작업자 상태정보 관리 데이터베이스는 MariaDB를 사용하여 구축하였으며, 그림 A2.2는 작업자 상태정보 관리 데이터베이스의 테이블 관계도를 보여준다.

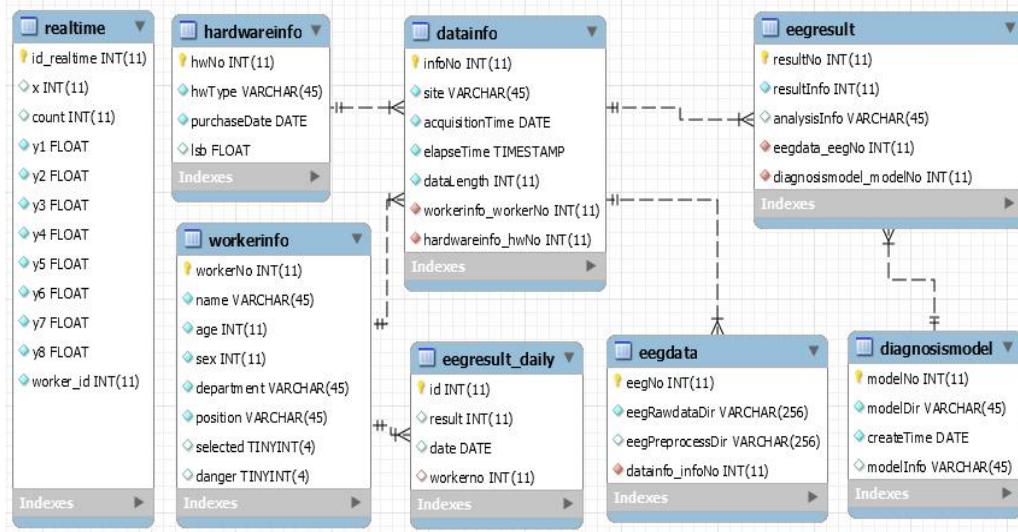


그림 A2.2. 작업자 상태정보 통합 관리 데이터베이스 테이블 관계도

부록2.3. 작업자 모니터링 소프트웨어

작업자 모니터링 소프트웨어는 데이터베이스에 저장된 작업자의 뇌파 데이터 및 상태 지표를 쉽게 모니터링 할 수 있도록 개발하였다. 주요 기능으로 작업자의 실시간 뇌파신호 데이터에 대한 모니터링이 가능하며, 작업자 상태 지표 결과를 볼 수 있는 게이지 차트가 있다. 마지막으로 작업자의 과거 상태 이력을 열람 가능하도록 만들었다. 그림 A2.3은 작업자 모니터링 소프트웨어의 메인화면을 보여준다.

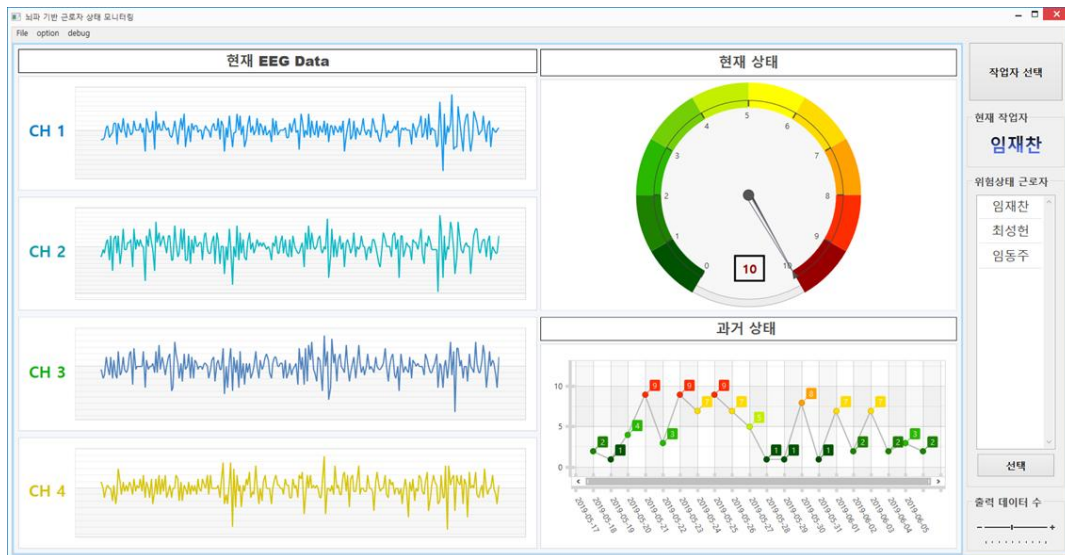


그림 A2.3. 작업자 모니터링 소프트웨어의 메인화면

오른쪽 하단 과거 상태를 보여주는 그래프의 숫자를 클릭하면 그림 A2.4와 같이 과거 상태 이력 조회 창이 출력된다. 과거 상태 이력 조회 창에서는 시간, 분, 초를 선택하여 선택버튼을 누르면, 수집되었던 원본 뇌파를 읽어서 화면 우측의 그래프로 표현하며, 선택한 시점의 작업자 상태 지표를 표시한다.



그림 A2.4. 과거 작업자 스트레스 이력 조회 창

한편 메인화면에서 현재 EEG Data화면의 채널 번호를 클릭하면 주파수 도메인 분석창이 열린다. 주파수 도메인 분석창에서는 실시간 뇌파 데이터 파워 스펙트럼 및 실시간 뇌파 주파수 밴드별 출력을 지원하여 뇌파를 분석할 수 있도록 화면을 구성하였다. 그림 A2.5는 개발한 주파수 도메인 분석 창을 보여준다.

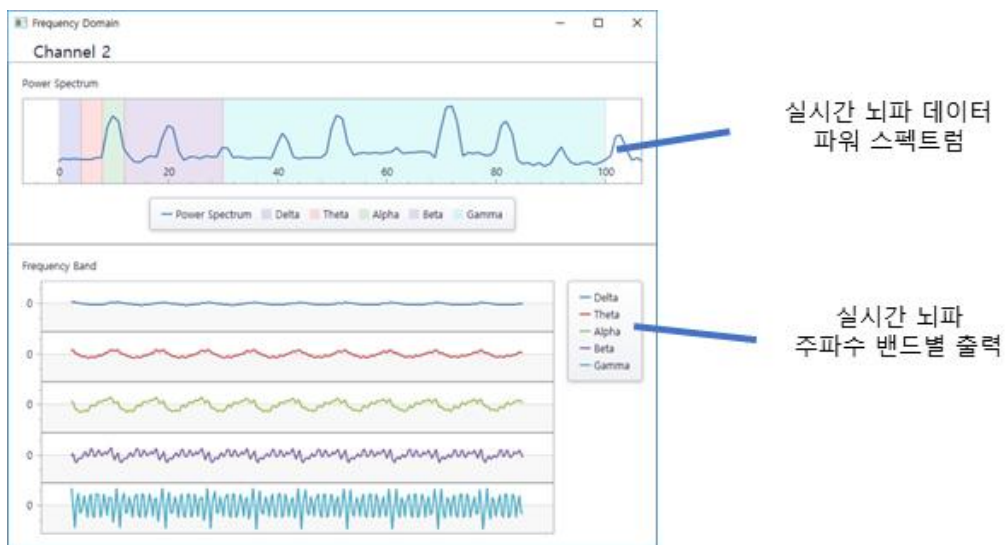


그림 A2.5. 주파수 도메인 분석 창

참고문헌

- [1] 안전보건공단. 인지신뢰도 및 휴먼에러분석기법(CREAM)에 관한 기술지침. (2016).
- [2] Pickering, T.G. Mental stress as a causal factor in the development of hypertension and cardiovascular disease. *Current hypertension reports* 2001, 3, 249-254.
- [3] Bender, R. E.; Alloy, L. B. Life stress and kindling in bipolar disorder: Review of the evidence and integration with emerging biopsychosocial theories. *Clinical psychology review*. 2011, 31, 383-398.
- [4] Major, T. C.; Conrad, J. M. A survey of brain computer interfaces and their applications. *IEEE SOUTHEASTCON*, Lexington, KY, USA, 13-16 Mar. 2014, IEEE: pp 1-8.
- [5] Elsayed, N.; Zaghoul, Z. S.; Bayoumi, M. Brain computer interface: EEG signal preprocessing issues and solutions. *Brain* 2017, 169, 12-16.
- [6] Von Rosenberg, W.; Chanwimalueang, T.; Goverdovsky, V.; Looney, D.; Sharp, D.; Mandic, D. P. Smart helmet: Wearable multichannel ECG and EEG. *IEEE journal of translational engineering in health and medicine* 2016, 4.
- [7] 박주현, 뇌와 IT의 융합. *전자공학회지*, 37(5), 2010, 523-530.
- [8] Jolliffe, I. T. Graphical Representation of Data Using Principal Components. In *Principal Component Analysis*, 2nd ed.; Springer, 2002, pp. 78-110, 978-0-387-22440-4.
- [9] Hou, X., Trapsilawati, F., Liu, Y., Sourina, O., Chen, C. H., Mueller-Wittig, W., & Ang, W. T. EEG-based human factors evaluation of conflict resolution aid and tactile user interface in future Air Traffic Control systems. In *Advances in Human Aspects of Transportation* (pp. 885-897). Springer, Cham. (2017).
- [10] Gotlib I. H. Frontal EEG Alpha Asymmetry, Depression, and Cognitive Functioning. *Cognition and Emotion* 1998, 12, 449-478.
- [11] 임현교. 인간과오 유발상황에서 뇌파 상대파워 특성의 변화. *한국안전학회지*, 23(3), 65-70. (2008).
- [12] Koelstra, S.; Muhl, C.; Soleymani, M.; Lee, J.; Yazdani, A.; Ebrahimi, T.; Pun, T.; Nijholt, A.; Patras, I. DEAP: A Database for Emotion Analysis using Physiological Signals. *IEEE Transactions on Affective Computing* 2012, 3, 18-31.

- [13] Morris, J. D. Observations: SAM: the Self-Assessment Manikin; an efficient cross-cultural measurement of emotional response. *Journal of advertising research* 1995, 35(6), 63-68.
- [14] Bastos-Filho, T. F.; Ferreira, A.; Atencio, A. C.; Arjunan, S.; Kumar, D. Evaluation of feature extraction techniques in emotional state recognition. In *Intelligent human computer interaction (IHCI), 4th international conference on. IEEE*, 27-29 Dec. 2012, IEEE: pp 1-6
- [15] Lin, Y. P.; Wang, C. H.; Jung, T. P.; Wu, T. L.; Jeng, S. K.; Duann, J. R.; Chen, J. H. EEG-based emotion recognition in music listening. *IEEE Transactions on Biomedical Engineering* 2010, 57, 1798-1806.
- [16] Rozgi?, V.; Vitaladevuni, S. N.; Prasad, R. Robust EEG emotion classification using segment level decision fusion. In *Acoustics, Speech and Signal Processing (ICASSP), Vancouver, BC, Canada, 26-31 May 2013, IEEE*: pp 1286-1290.
- [17] Ackermann, P.; Kohlschein, C.; Bitsch, J. A.; Wehrle, K.; Jeschke, S. EEG-based automatic emotion recognition: Feature extraction, selection and classification methods. In *e-Health Networking, Applications and Services (Healthcom), Munich, Germany, 14-16 Sept. 2016, IEEE*: pp 1-6.
- [18] Petrantonakis, P. C.; Hadjileontiadis, L. J. Emotion recognition from EEG using higher order crossings. *IEEE Transactions on Information Technology in Biomedicine* 2010, 14, 186?197.
- [19] Oh, S. H.; Lee, Y. R.; Kim, H. N. A novel EEG feature extraction method using Hjorth parameter. *International Journal of Electronics and Electrical Engineering* 2014, 2, 106-110.
- [20] Pizzagalli, D. A.; Sherwood, R. J.; Henriques, J. B.; Davidson, R. J. Frontal Brain Asymmetry and Reward Responsiveness: A Source-localization Study. *Psychological Science* 2005, 16, 805-813.
- [21] Jenke, R.; Peer, A.; Buss, M. Feature extraction and selection for emotion recognition from EEG. *IEEE Transactions on Affective Computing* 2014, 5(3), 327-339.
- [22] Sanei, S.; Chambers, J. A. Brain Rhythms. In *EEG signal processing*, 1st ed.; John Wiley & Sons. 2007, pp. 10-13, 978-0470025819
- [23] Welch, P. The use of fast Fourier transform for the estimation of power spectra: a

- method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics* 1967, 15, 70-73
- [24] Petrantonakis, P. C.; Hadjileontiadis, L. J. Emotion recognition from EEG using higher order crossings. *IEEE Transactions on Information Technology in Biomedicine* 2010, 14, 186-197.
- [25] Thibodeau, R.; Jorgensen, R. S.; Kim, S. Depression, anxiety, and resting frontal EEG asymmetry: a meta-analytic review. *Journal of abnormal psychology* 2006, 115, 715-729.
- [26] Baehr, E.; Rosenfeld, J. P.; Baehr, R.; Earnest, C. Comparison of two EEG asymmetry indices in depressed patients vs. normal controls. *International Journal of Psychophysiology* 1998, 31, 89-92.
- [27] Tops, M.; Wijers, A. A.; van Staveren, A. S.; Bruin, K. J.; Den Boer, J. A.; Meijman, T. F.; Korf, J. Acute cortisol administration modulates EEG alpha asymmetry in volunteers: relevance to depression. *Biological Psychology* 2005, 69, 181-193.
- [28] Mathersul, D.; Williams, L. M.; Hopkinson, P. J.; Kemp, A. H. Investigating models of affect: Relationships among EEG alpha asymmetry, depression, and anxiety. *Emotion* 2008, 8, 560-572.
- [29] Thibodeau, R.; Jorgensen, R. S.; Kim, S. Depression, anxiety, and resting frontal EEG asymmetry: a meta-analytic review. *Journal of abnormal psychology* 2006, 115, 715-729.
- [30] Atencio, A. C.; Garcia, J. C.; Benevides, A. B.; Longo, B. B.; Ferreira, A.; Porner-Escher, A.; Souza, M. D. P.; Bastos, T. Computing stress-related emotional state via frontal cortex asymmetry to be applied in passive-ssBCI. 5th ISSNIP-IEEE, Salvador, Brazil, 26-28 May 2014, IEEE.
- [31] Liu, J.; Meng, H.; Li, M.; Zhang, F.; Qin, R.; Nandi, A. K. Emotion detection from EEG recordings based on supervised and unsupervised dimension reduction. *Concurrency and Computation: Practice and Experience* 2018.
- [32] Islam, R.; Khan, S. A.; Kim, J. M. Discriminant Feature Distribution Analysis-Based Hybrid Feature Selection for Online Bearing Fault Diagnosis in Induction Motors. *Journal of Sensors* 2016, 2016.
- [33] 김태준, 김태준, 장하영, 박정완, 황성택, 장병탁, 온라인 필기인식을 위한

증가하는 데이터를 이용한 앙상블 기법, 정보과학회논문지: 소프트웨어 및 응용
41.2 (2014): 164-170.

- [34] 서민지, 김명호 "음성의 감정 인식을 위한 감정 분류기 앙상블 기법"
한국IT정책경영학회 논문지 11.2 pp.1187-1193 (2019) : 1187.
- [35] 고용노동부, 산업재해 현황분석, 2020.
- [36] 김성곤, 류수영, 철도안전관리 향상에 관한 사례연구. Korea Business Review,
21(1), 117-138. (2017).
- [37] 신운철, 이동식 크레인 사망재해 원인분석 연구, 안전보건공단. (2014).
- [38] 안전보건공단, 정보마당-조선업중대재해속보, last modified Jul. 26, 2018, accessed
Aug. 03, 2018, <https://www.kosha.or.kr/www/cmsTiles.do?url=/cms/board/board/Board.jsp?communityKey=B0027&menuId=158>
- [39] 박정철, 화학설비의 휴먼 에러 사고방지를 위한 작업자 신뢰성 평가기법,
KNUT(한국교통대학교), July. 2, 2012.

[Abstract]

Research on EEG-based Stress State Classification and Application

Due to the development of science and technology, many parts of the facility have been automated, and as a result, a small number of people are handling tasks such as monitoring and control. Accidents caused by this can lead to huge material and human losses. It is known that the majority of occupational accidents are caused by unsafe behaviors of workers, and according to Mcsween, 76% of injuries at DuPont in 10 years were caused by unsafe behavior. Factors that cause unsafe behavior include fatigue, lack of sleep, stress, and physical defects. The inappropriate physical and mental state of workers causes stress.

A brain wave is an electrical signal that can indirectly know the activity of the brain. The brain wave can be obtained by methods such as electro-encephalographic (EEG) and electro-corticographic (ECoG). ECoG is a method to measure brain waves by attaching electrodes directly to the cerebral cortex of the brain. It is a method that can obtain the cleanest EEG signal, but has a disadvantage that a surgical method is required for electrode implantation. EEG is a method of measuring EEG by attaching electrodes to the scalp outside the skull of the head, and although the accuracy of EEG signals is relatively low, it is relatively less burdensome to apply to the human body because it does not require a surgical method. For EEG-based worker monitoring, it is suitable to obtain EEG using EEG, which is relatively light in a application.

In this paper, It is proposed an EEG-based worker safety technology. The experimental data used in the study on safety management of workers

utilizing AI-based EEG signals use DEAP (Database for Emotion Analysis using Physiological Signals), an open EEG dataset for emotional state classification, and examines the stress state and normal state of the worker state. For labeling, we use the classification criteria used by Bastos-Filho et al. Statistical features, PSD (Power Spectrum, Density), and HOC (Higher-Order Crossing) features are used as features for state classification. As a feature selection algorithm, PCA (Principal Component Analysis) and a genetic algorithm are used, and finally, classification is performed using an artificial intelligence algorithm. In this paper, to check the effectiveness of the proposal, we compare the feature selection method using PCA and the method using the genetic algorithm. As a result of the experiment, the genetic algorithm-based method showed a 6.46% higher performance with a classification accuracy of 71.76% compared to 65.3% of PCA. In addition, as a result of comparing the classification accuracy between the classification algorithm using the individual learning SVM and the method using the genetic algorithm, the classification performance was higher when using the individual learning SVM as 77.51% and 71.76%, respectively.

Finally, for the prevention of human error accidents, we proposed an EEG that can be applied to workers, and a worker condition index that calculates the risk of workers based on the results of stress classified through an artificial intelligence algorithm. By combining this, we developed human error accident prevention software that can monitor the condition of the worker, and suggested an application plan for the EEG-based worker monitoring technology.

Key words : EEG, worker state classification, feature selection, genetic algorithm, machine learning