



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](#)

교육학석사학위논문

# 휴대용 EEG 장비를 이용한 학습자의 뇌파 분석

- 학습 양식 및 Raven 데이터를 중심으로

2018년 2월

서울대학교 대학원

수학교육과

송 찬 황

# 휴대용 EEG 장비를 이용한 학습자의 뇌파 분석

- 학습 양식 및 Raven 데이터를 중심으로

지도교수 조 한 혁

이 논문을 교육학석사학위논문으로 제출함

2017년 12월

서울대학교 대학원

수학교육과

송 찬 황

송찬황의 석사학위논문을 인준함

2018년 1월

위 원 장 \_\_\_\_\_ 김 서 령 (인)

부 위 원 장 \_\_\_\_\_ 유 연 주 (인)

위 원 \_\_\_\_\_ 조 한 혁 (인)

## 국문초록

최근 증거 기반 교수(evidence based instruction), 데이터 기반 교수(data based instruction)에 대한 관심이 증가하고 있다. 데이터 기반 수학 교육을 위해서는 교수 학습 과정에서 학습자의 상태를 정확하게 진단하고 이에 맞추어 적절한 교수를 처방하는 것이 필요하다. 이를 위한 많은 교육 연구가 진행되고 있는 가운데 신경과학은 여기에 새로운 가능성을 열어줄 수 있을 것으로 기대된다. 교육 연구에서 신경 과학과의 협력 연구는 하나의 흐름이 되어가고 있음에도 불구하고 아직 수학 교육 연구에서 뇌파 연구는 많지 않은 것이 현실이다.

이에 본 연구는 뇌파 연구의 기초 연구로서 휴대용 뇌파 장비와 파이썬을 이용하여 뇌파 측정 및 분석 시스템을 구축하고 이를 이용한 뇌파 분석이 가능한 지 탐구하였다. 나아가 휴대용 뇌파 장비로 측정된 데이터를 활용한 머신 러닝 적용 사례를 개발함으로써 이러한 뇌파 분석 활동이 교수 학습 과정에서 학습 내용으로 활용될 수 있는 가능성 또한 모색하였다. 본 연구는 ‘수학교육 신경과학’의 기초 연구로서 증거 기반적인 견해를 제공하며 수학교수와 학습에 대한 보다 깊고 폭넓은 이해가 가능하도록 한다. 특히 휴대용 EEG 장비를 활용함으로써 EEG 연구가 교육 연구와 학교 현장에 확산될 수 있도록 하는데 기여한다는 측면에서 의의가 있다.

**주요어** : 수학교육 신경과학, 뇌파(EEG), 학습양식, APM, 머신러닝

**학 번** : 2016-21565

# 목 차

국문 초록 .....	i
목차 .....	ii
표 목차 .....	v
그림 목차 .....	vi

## I. 서론 .....1

1. 연구의 필요성 및 목적 .....	1
2. 연구 문제 .....	8
3. 용어의 정의 .....	9

## II. 이론적 배경 .....11

1. 수학교육 신경과학 .....	11
2. 뇌파 .....	16
2.1. 대뇌의 구조 .....	16
2.2. 뇌파와 EEG .....	17
2.3. 국제 표준 10-20 시스템 .....	18
2.4. 수학교육 EEG 선행연구 .....	19
3. 휴대용(Portable) EEG 시스템 .....	22
4. 유동지능과 패턴 추론 : Raven의 누진행렬검사 .....	24
5. 학습 양식 : Kolb의 LSI .....	27
5.1. KLSI 3.1 .....	27
6. 머신 러닝(machine learning, 기계학습) .....	30
6.1. K-means 클러스터링 .....	32
6.2. 신경망(Neural Network) .....	33

<b>III. 뇌파 측정 및 분석 환경 설계</b>	<b>38</b>
1. 뇌파 측정 도구의 선정	38
2. 뇌파의 측정	41
3. 뇌파의 분석	43
4. 뇌파 측정 및 분석 시스템 구성	46
<b>IV. 뇌파 측정 및 분석 사례</b>	<b>51</b>
1. 연구 설계 및 방법	51
1.1. 연구 참여자	51
1.2. 연구 절차	52
1.3. 검사 도구	54
2. 뇌파와 APM 분석 결과	59
2.1. 뇌파와 APM 사이의 Spearman의 상관 분석	59
2.2. 뇌파와 APM 사이의 대응 표본 T검정	67
2.3. 뇌파와 Raven 총점 사이의 다중 회귀 분석	68
2.4. 뇌파와 난도 사이의 반복측정 분산분석	71
3. 뇌파와 KLSI 분석 결과	74
3.1. EO 상태 뇌파 분석	75
3.2. EC 상태 뇌파 분석	78
<b>V. 머신러닝에의 응용</b>	<b>79</b>
1. K-means clustering	79
2. 신경망	82
2.1. EO, EC 상태 신경망	82
2.2. 난도와 신경망	83
2.3. 정오답과 신경망	84

3. 논의 .....	85
<b>VI. 결론 및 제언 .....</b>	<b>86</b>
1. 결론 .....	86
2. 제언 .....	88
<b>참고문헌 .....</b>	<b>90</b>
<b>부록 .....</b>	<b>98</b>

## 〈표 목 차〉

〈표 II-1〉 국내 수학교육 뇌파 연구에 사용된 뇌파 장비와 프로그램 ..	21
〈표 II-2〉 시판중인 휴대용 EEG 시스템 .....	22
〈표 II-3〉 시중에 공개된 EEG 분석 프로그램 .....	23
〈표 II-4〉 머신 러닝과 데이터 마이닝 비교 .....	30
〈표 III-1〉 뇌파 분류와 해당 주파수 대역 .....	44
〈표 III-2〉 Window size에 따른 뮤즈 변수 .....	45
〈표 IV-1〉 축소 버전에 사용된 APM 문항 번호 .....	58
〈표 IV-2〉 문항 번호별 오답률 .....	60
〈표 IV-3〉 분석에 사용된 뇌파 대역 .....	62
〈표 IV-4〉 Spearman의 상관 분석 결과 .....	66
〈표 IV-5〉 Wilcoxon 부호 순위 검정 결과 .....	67
〈표 IV-6〉 다중회귀분석 모형 선택 결과 .....	68
〈표 IV-7〉 다중회귀분석 ANOVA 결과 .....	69
〈표 IV-8〉 다중회귀분석 계수 .....	69
〈표 IV-9〉 반복측정 분산분석 효과 검정 .....	71
〈표 IV-10〉 반복측정 분산분석 대응별 비교 .....	72
〈표 IV-11〉 학생 KLSI 채점 결과 .....	74
〈표 IV-12〉 일원 배치 분산 분석 기술 통계량 .....	76
〈표 IV-13〉 일원 배치 분산 분석 결과 .....	77
〈표 IV-14〉 Mann-Whitney 테스트 결과 .....	78
〈표 V-1〉 k에 따른 클러스터링 정확도 .....	81



## [그림 목 차]

[그림 II-1] 대뇌 피질의 구조 .....	16
[그림 II-2] 뇌파의 종류 .....	17
[그림 II-3] 10-20 시스템 .....	18
[그림 II-4] Kolb의 4가지 기본적인 학습유형 .....	29
[그림 II-5] 신경망의 형태 .....	36
[그림 III-1] 뮤즈 본체와 전극 위치 및 규격 .....	40
[그림 III-2] 뮤즈의 전극 위치 .....	41
[그림 III-3] 뮤즈 착용 장면 .....	42
[그림 III-4] 윈도우 길이와 오버랩 .....	46
[그림 III-5] 뮤즈를 이용하여 전송된 데이터를 실시간 파이썬으로 나타낸 장면 ..	46
[그림 III-6] Muse-Bluetooth 4.0-Musemonitor-OSC protocol-python ..	47
[그림 III-7] 파이썬 뇌파 데이터 분석 코드 .....	48
[그림 III-8] 파이썬 K-means clustering 코드 .....	49
[그림 III-9] 파이썬 신경망 코드 .....	50
[그림 IV-1] 실험 장면 .....	53
[그림 IV-2] KLSI 구글 설문지 .....	55
[그림 IV-3] APM 문항 예시 .....	56
[그림 IV-4] 문항번호에 따른 학생 반응시간 평균 .....	59
[그림 IV-5] 문항 번호별 오답률 .....	60
[그림 IV-6] 학생별 APM 총점과 히스토그램 .....	61
[그림 IV-7] FFT 윈도우 크기에 따른 상관도의 차이 .....	63
[그림 IV-8] 오버랩 크기에 따른 상관도의 차이 .....	64
[그림 IV-9] 총점의 회귀 표준화 잔차 .....	70
[그림 IV-10] 성취 그룹별 TP9 감마의 반복측정 분산 분석 그래프 ..	73
[그림 IV-11] KSLI 분류 결과 .....	75

[그림 V-1] EC, EC 상태 뇌파의 2차원 그래프 .....	79
[그림 V-2] k=2인 경우 K-means clustering 분류 결과 .....	79
[그림 V-3] k=3인 경우 K-means clustering 분류 결과 .....	80
[그림 V-4] 학습률과 학습 횟수에 따른 신경망 성능 .....	82
[그림 V-5] 학습률과 학습 횟수에 따른 신경망 성능 .....	83
[그림 V-6] 학습률과 학습 횟수에 따른 신경망 성능 .....	84

# I. 서론

## 1. 연구의 필요성 및 목적

최근 증거 기반 교수(evidence based instruction), 데이터 기반 교수(data based instruction)에 대한 관심이 증가하고 있다. 원래 증거 기반이라는 표현은 의학계에서 등장한 용어이다. 1972년에 Archie Cochrane이 증거 기반 의료(evidence based medicine)의 개념을 설명하면서 알려지기 시작하여 80년대 후반부터 90년대 초반에 “증거 기반 의료”라는 명칭이 의학 분야의 실제적인 방법론으로 자리 잡게 되었다. 이후 증거 기반이라는 용어는 심리학, 경제학을 포함한 사회과학 전반에 영향을 미치게 되었다.

그런데 Pfeffer & Sutton(2006)에 따르면 실제로 의학에서 증거 기반적 접근을 통해서 의사결정이 이루어지는 사례는 15%에 미치지 못한다고 한다. 의사들은 자신이 예전에 학교에서 배운 처방, 오래되었지만 증명되지 않은 전통 요법, 자신의 경험에서 얻은 나름의 방식, 자신의 개인적 믿음에 따른 처방에 더 의존하고 있다. 의사들이 “현존하는 최선의 증거”를 활용하지 않는 것은 그들의 게으름, 태만과 같은 부정적인 이유 때문이 아니라 그들이 학문적 연구 결과보다 자신 고유의 경험을 더 믿고 있다는 이유에서 비롯되는 경우가 훨씬 많다는 것이다.

수학 교육에서도 이는 비슷한 상황이다. 교사들 중에서도 자신이 학교에서 배운 교수 방법과 지식, 자신의 교수 경험에서 얻은 나름의 방식, 오래되었지만 증명되지 않은 전통 교수 방법, 자신의 개인적 믿음에 따른 지도법에 의존하는 사람들이 존재한다. 수학교육 연구에서 드러난 학문적 연구 결과보다 자신 고유의 교수적 판단과 경험을 토대로 교수 실행을 구성하는 교사들이 많다. 교사들은 자신의 지식뿐만 아니라 학문적 연구 결과를 함께 고려하여 증거 기반으로 학생의 성과를 이끌어 낼 수 있는 교수적 실재를 추구할 수 있어야 한다. 하지만 많은 교사들은 학생

의 성과에 거의 영향을 미치지 못하는 교수적 실행을 활용하면서 증거 기반 혹은 연구 기반 실행을 외면하고 있다(Cook & Schirmer, 2003).

데이터 기반 교수는 증거기반 교수에 더해 D. Fuchs이 사용한 용어로 하나의 특정한 교수법이라기보다는 지속적이고 역동적인 ‘과정’으로 정의된다. 교사들이 연구 기반 교수를 적용하면서 학습 진전을 지속적으로 측정하고, 그 결과를 바탕으로 현재 교수의 효과성을 평가하며 교사의 교수적 의사결정을 돕는 과정이다(Stecker, Fuchs & Fuchs, 2005). 기존의 연구 기반 교수를 실시했을 때 대부분의 학생들은 교수에 충분한 반응을 보이지만, 5% 이내의 학습 장애 학생들은 충분한 반응을 보이지 않았다. 즉, 연구 기반 교수 자체만으로는 집중적인 개별화 교육이 필요한 학습 장애 학생들을 돕기 어렵기 때문에 연구 기반 교수에 효과적인 개별화 교육 장치를 포함한 데이터 기반 교수를 제안하였다(Fuchs et al. 2014). 이러한 데이터 기반 교수는 특히 특수 교육 분야에서 중재반응 모델(Response to Intervention, RTI)로서 활발하게 연구되고 있다.

데이터 기반 수학 교육을 위해서는 학생들의 수학 학습 상태를 정확하게 진단하고 이에 맞추어 적절한 교수를 처방하는 것이 요구된다. 다양한 심리측정법이나 검사지가 존재하지만 일관된 측정 도구의 부재 및 서로 다른 방법의 적용이 각기 다른 아동을 판별하기에 적합하지 않다는 점은 데이터 기반 교수의 한계점이다. 데이터 기반 교수가 보여주는 가능성에도 불구하고 과학적 연구 기반을 갖춘 이른바 데이터 기반 교수에 관한 합의된 기준점은 여전히 미완성이다. Swanson(2008)은 표준화된 적용이 없다는 점, 교사 효과가 항상 통제될 수 없다는 점, 그리고 최적의 교수 환경에서도 성과의 개인적 차이가 증가할 수 있다는 점 등을 지적하였다. 이러한 데이터 기반 교수에 대한 지적은 보다 과학적이고 객관적인 증거를 추가로 제시해야할 필요성에 대한 요구로 볼 수 있다.

이러한 측면에서 신경 과학은 데이터 기반 교수에 새로운 가능성을 열어줄 수 있을 것으로 주목받는 분야이다. 김동일 외(2011)에 따르면 교육 연구에서 신경과학과의 협력 연구는 하나의 흐름이 되어가고 있다. 신경과학과 교육의 협력에 대한 많은 논쟁이 진행 중에 있지만, 이미 연구자

들은 학문 간의 협력 작업을 시작했다는 것이다. 그동안에는 뇌에 대한 연구가 교육적으로 실용적이지 못한 지식이라고 판단되었기에 교육자들의 관심을 끌지 못했지만 점차 학습 과정과 관련된 특정 뇌의 영역을 찾아내고, 정보를 제공하는 신경학적 평가를 지지하는 신경심리학적 연구의 양이 증가함에 따라 교육자들의 인식에 많은 변화가 일어났다. 기술의 정교함이 발전함에 따라 교육에 대한 뇌 과학적 연구들의 수행은 교육 분야에 주목할 만 한 발전을 가져올 것을 예고하였다.

김두정(2010)이 주장한 바와 같이 뇌 과학을 포함한 신경과학과 교육은 상호 교류를 통해 신경 과학이 교육에 유의미한 기여를 할 수 있도록 해야 한다. 교육 실천가들은 인지신경과학의 개념과 방법을 익힘으로써 신경과학 분야의 연구 결과물들을 이해하고 비판적으로 수용하여 적용할 수 있다(Ansari, Coch, 2006). 뿐만 아니라, 신경과학을 교육에 적용하기 위한 중요한 연구 문제를 제기할 수 있고, 이를 해결할 수 있는 방안을 생각할 수 있도록 할 수 있다는 것이다(Eisenhart & DeHaan, 2005; Stanovich & Stanovich, 2003).

이러한 측면에서 협력 연구의 필요성이 제기되고 있지만 신경과학과 교육 사이의 협력 관계를 만드는 데 대한 어려움이 있다. 이에 대해 Ansari, Coch(2006)는 공통적인 언어와 배경의 결핍, 만날 기회와 간학문적 연구를 위한 장의 부족, 변화에 대한 기피, 그리고 연구 자금 문제 등을 꼽았다. 그럼에도 불구하고 학습과 교육의 과학을 위한 미래의 기대되는 결과가 너무 중요하기 때문에 협력 관계 형성을 더 이상 늦출 수 없으며, 신경과학과 교육 두 영역의 협력은 뇌 기반 교육 및 학습의 과학을 만들며, 이는 학교 현장 그리고 교육 연구자들에게 많은 이익을 가져다 줄 수 있다고 하였다(김동일 외, 2011).

외국 수학 교육계에서도 신경과학에 대한 관심이 생겨나고 있다. 인지신경과학과 정신생리학의 발전에 힘입어 Campbell(2006)은 “수학교육 신경과학”이라는 용어를 소개한 바 있다. 수학교육 신경과학에서는 관찰, 면담, 설문지, 실험, 사전사후 검사 등 기존에 연구에서 주로 사용하는 데이터에서 더 나아가 피부 반응, 시선, 동공 반응, 심전도, 뇌파, 호

흡 등과 같은 생리학적인 데이터를 수학 교육 연구에 이용하여 인간의 주관적인 기억, 감각, 사고 등을 관찰가능하며, 객관적이고, 구현된 행동 양식으로 드러내고자 한다. 이렇게 생리학적 데이터를 이용하는 것은 기존의 연구로는 접근할 수 없었던 측정과 분석을 가능하게 함으로써 수학 교수와 학습에 있어 보다 더 깊고 나은 이해를 제공할 수 있는 가능성을 가지고 있다는 것이다.

신경 과학의 연구 방법 중에서도 학습자의 시선을 추적하는 아이트래커(eye-tracker)는 중학생의 읽기 양상(최숙기, 2016)이나 독해력에 따른 문제 해결 상황에서의 독자의 눈동자 움직임(서혁 외, 2016) 등 주로 텍스트를 읽는 독자의 시선을 추적하는 방식으로 활용되고 있다. 수학 교과에서는 3D 입체 변별 과제(이지윤, 2015), 전개도 접기 과제(이은지, 2017)이나 공간 과제(이승주, 2017)등에서 시각적 자극을 처리 하는 과정에서 학습자의 사고방식을 유추하는 증거로서 아이트래커가 활용되었다. 최인용, 조한혁(2016)은 순열, 조합 문장제 문제를 해결하는 과정에서 수학적 인지를 추론하는 데 아이트래커를 이용하였다. 이 연구들에서 학습자의 시선은 문제 해결 과정에서 연구 참여자들의 주관적인 인지 과정을 관찰 가능한 증거를 통해 객관적으로 드러내는 것으로서 교수와 학습에 대해 보다 더 깊고 나은 이해를 제공하였다.

한편, 교육 분야에서 EEG 연구는 음악, 체육, 과학 등의 교과에서 활발하게 진행되고 있다. 하지만 신경 과학의 연구에서 인지 과제로 수학적 과제들이 많이 활용되고 있음에도 불구하고 정작 수학 교육에서 EEG 연구는 많지 않다. 현재까지 진행된 국내 수학 교육의 EEG 연구는 수학 영재(김남희, 2013), 수학 불안(윤은정, 2014; 석영민, 2015; 한세호, 고상숙, 2016; 고상숙, 이창연, 2016), 심적 회전(mental rotation)(김종진, 2016), 수학 교구의 두뇌 활성화(김형원, 2017)등에 관한 연구 등이 있다. 뇌파에 관련된 수학 교육 연구가 많지 않은 것은 장비를 갖추는 데에 비용이 많이 들고 신경 과학의 이론과 그 분석법의 내용이 어려워 초기 진입 장벽이 높아 연구의 접근성이 떨어지기 때문으로 생각된다.

이에 본 연구에서는 연구와 학교 현장에서 연구나 학습 목적으로 EEG

를 확산 시킬 수 있는 방안을 모색하는 것을 목표로 하였다. 기존의 교육 연구에서 사용된 EEG는 신경과학의 연구를 재현하여 사용한 것이 대부분이다. 교사나 교육 연구자들이 현장에서 뇌파를 더욱 이용할 수 있게 하려면 신경 과학의 EEG 연구를 교수학적으로 변환할 필요가 있다. 기술의 발전으로 학교에서도 사용할 수 있는 수준의 저비용, 휴대용 뇌파 장비들이 꾸준히 출시되고 있다. 하지만 휴대용 뇌파 장비들이 뇌파를 제대로 측정하는 것인지, 획득된 뇌파 데이터는 신뢰할 수 있는지에 대한 의문 또한 제기 되고 있어 이에 대해 연구를 통한 검증이 필요하다.

따라서 본 연구에서는 휴대용 뇌파장비를 이용하면서 시중의 유료 소프트웨어를 사용하지 않고 파이썬을 이용하여 뇌파 측정과 실시간 분석이 가능하도록 코딩을 통해 시스템을 구축하고 이러한 시스템을 통해 유의미한 뇌파의 변화를 확인할 수 있는지 탐구하고자 한다. 이러한 휴대용 뇌파 장비들로 신경 과학의 연구 결과들을 부분적으로 재현할 수 있다는 것이 확인되면 교육 현장에서 뇌파 연구가 더욱 활발해질 수 있을 것이다. 구축한 시스템을 이용하여 선행 연구를 바탕으로 인지적 능력으로서 유동 지능과 정의적 특성으로서 학습 양식이라는 대표적인 두 가지 특성과 관련하여 학습자의 뇌파 분석을 시도하였다. 유동 지능에 대한 신경과학적 접근은 전통적 연구로는 확인할 수 없었던 객관적 데이터에 대한 측정과 분석을 가능하게 함으로써 교육 연구자들로 하여금 학습자의 주관적인 사고 과정에 대해 새로운 통찰을 제공할 수 있을 것이다. 물론 현재까지 인지 과정에 대한 신경과학적 연구 결과들이 교수 학습 환경에 직접적으로 적용되기는 아직 어렵다. 하지만 이러한 연구 결과가 축적되어 인지 과정에 대한 이해가 높아지면 교육 분야에 공헌을 할 수 있을 것을 기대할 수 있다. ‘수학교육 신경과학’ 이 미래의 새로운 교육 연구 분야로 자리 잡는 데 기여한다는 측면에서 본 연구의 의의가 있다.

뇌파 측정 및 분석을 위해 S대학교 과학영재교육원 소속 중학생 31명에 대하여 유동지능검사로서 APM과 학습양식검사로서 KLSI를 실시한다.

그리고 동시에 참가자의 EEG를 기록하여 학습자의 학습 양식, 패턴 추론 과정, EEG 사이의 상관관계를 양적으로 분석한다. 특히 휴대용 EEG 장비와 무료 소프트웨어를 사용하여 학습자의 생리적 데이터를 측정하고 기록하여 상관관계를 분석하는 것이 가능한 지 밝힘으로써 교육 현장에서의 신경과학적 방법론의 활용 가능성을 높이고자 한다.

그리고 나아가 뇌파 데이터를 활용한 머신 러닝 적용 사례를 개발함으로써 이러한 뇌파 분석 활동이 하나의 교수 학습 과정에서 학습 내용으로서 활용될 수 있는 가능성을 모색한다. 평균과 행렬, 미분 등의 수학적 개념을 활용한 K-means clustering과 신경망 알고리즘을 이용하여 뇌파 데이터를 분석한다. 수학을 학습하는 학생들이 수학의 실용성에 의문을 품는 경우가 많은데 학생들의 연관성이 높은 생체 데이터를 활용한 머신 러닝 사례를 학생 탐구 과제로 개발함으로써 학생들에게 수학의 실용성을 느끼게 하고 정의적 태도 또한 함양시킬 수 있을 것으로 기대한다.

교육 연구와 다양한 신경과학의 발전을 통합하려는 본 연구와 같은 시도는 교육 연구를 변화시키고 새로운 관점에서 바라볼 수 있도록 하는 역할을 할 수 있을 것으로 기대된다. 본 연구는 EEG 장비를 이용한 연구로서 기존의 전통적인 연구 방법들에 비해 학습자에 대하여 증거 기반적이며 데이터 기반의 객관적 견해를 제공함으로써 수학 교수와 학습에 대한 보다 깊고 폭넓은 이해가 가능하도록 한다는 데 의의가 있다.



## 2. 연구 문제

2.1. 휴대용 EEG 장비를 이용하여 뇌파를 측정하고 분석할 수 있는 시스템은 어떻게 구성하는가?

2.2. 학습 양식과 APM에 따라 학습자의 뇌파 활성은 어떠한가?

2.3. 휴대용 EEG 장비로 측정된 학습자의 뇌파 데이터는 머신 러닝에 적용하기에 적합한가?

### 3. 용어의 정의

#### 3.1. 뇌파

뇌파는 EEG(Electroencephalograph)를 가리키는 용어로 사용한다. 두피 전극에서 측정된 전위차를 이용하여 두피에서의 전위를 측정하는 EEG를 본 연구에서는 뇌파로 정의한다.

#### 3.2. 뮤즈(Muse Headband)

휴대용 EEG 장비로서 뮤즈는 Interaxon社에서 개발한 Muse Headband 2016 버전(RRID : SCR\_014418)을 지칭한다.

#### 3.3. EO 상태

뇌파 측정 중 Eyes open 안정 상태. 의자에 앉아서 눈을 뜨고 안정을 취하고 있는 상태를 말한다. 여기서 안정 상태라고 하면 편안한 마음으로 어떠한 인지적 과제도 수행하고 있지 않은 상태로 전방의 십자(Fixation Cross)만을 응시하고 있는 상태이다.

#### 3.4. EC 상태

뇌파 측정 중 Eyes closed 안정 상태. 의자에 앉아서 눈을 감고 안정을 취하고 있는 상태를 말한다. 여기서 안정 상태라고 하면 편안한 마음으로 어떠한 인지적 과제도 수행하고 있지 않은 상태이다.

### 3.5. APM

Raven의 누진행렬검사(Raven's progressive matrices)는 SPM, CPM, APM의 3가지 종류가 있는데 별다른 언급이 없는 경우 통틀어 RPM이라고 부른다. 이 중에서 APM은 Raven의 고급 누진행렬검사(Advanced progressive matrices)를 가리킨다.

### 3.6. KLSI

Kolb의 학습양식 검사(Learning Style Inventory)를 KLSI 라고 한다. KLSI는 여러 버전이 있는데 그 중에서도 본 연구에서 KLSI, 학습 양식은 KLSI 3.1 버전을 의미한다.

### 3.7. K-means 클러스터링(K-means clustering)

데이터 마이닝이나 머신 러닝에서 사용되는 비지도 학습의 알고리즘이다.

### 3.8. 신경망(Neural Network)

신경망의 용어는 인체나 생물의 신경망을 가리키는 것이 아닌 데이터 마이닝이나 머신 러닝에서 사용되는 지도 학습의 인공 신경망 알고리즘으로 사용한다.

## II. 이론적 배경

### 1. 수학교육 신경과학

Campbell(2006)에 따르면 교육 신경과학은 전통적인 형태의 교육 연구에 대해 연구의 새로운 차원을 추가하고 통합하는 것을 도울 수 있는 과학적 근거와 증거 기반의 새로운 연구 분야이다. 특히, 교육 신경 과학은 발달 심리 및 인지 심리학과 같은 교육 연구의 이론과 인지 신경과학과 정신 생리학의 방법론을 결합하고자 한다. 인지 심리학 및 인지 신경 과학에 관한 연구를 통해 알려진 교육 연구 방법론을 사용하여 수학교육 신경과학은 수학적으로 사고하는 것에 대한 생물학적 능력과 문화적 능력에 대해 알려진 것을 통합하고 확장하는 것을 목표로 한다.

수학 교육에서 다양한 정서적, 인지적, 사회적 주제들(Grouws, 1992)에 대한 많은 연구가 있어 왔으며, 다양한 현상학적, 행동적, 인지적, 사회적 상호 작용 주의적 접근들이 이러한 주제들을 이해하기 위한 방법으로 사용되었다(Sierpinska & Kilpatrick, 1998). 그러나 현재까지 수학교육 분야의 연구자와 전문가들은 대체로 인지 심리학(Campbell, 2004)과 인지 신경과학(Dehaene, 1997), 그리고 빠르게 성장하는 신경 유전학(Gordon & Hen, 2004)과 같이 생물학적 기반으로 수학적 인지와 학습의 본성과 절차를 탐구하는 다른 연구 분야들의 성장을 알지 못하거나 의식하지 못한 채로 남아 있다. 기본적으로, 수학 교육과 관련된 현상들은 인본주의적, 사회적 및 과학적 관점에서 다양하게 연구되고 있다. 이 이질적인 분야들은 수학 교육의 현재 연구와 실행을 더욱 효과적으로 알리고 설명할 수 있도록 집중되고 통합되고, 확장되어야 한다.

교육 신경 과학은 최근에 만들어진 잠재적인 기초 교육 연구 영역이다. 두 가지 기본 사항에 대한 일반적인 합의가 있다. 첫째, 교육 신경 과학은 신경 과학이 교육 실행을 설명하는데 있어 합리적으로 설명되는 증거 기반 연구라는 점이 특징이다. 역도 마찬가지이다. 둘째, 인지 신경

과학을 설명하는 인지심리학과 인지심리학을 설명하는 인지 신경과학에 대한 교육 연구가 교육 신경 과학의 핵심이다(Bruer, 1997).

교육 신경 과학은 학습자를 우선시한다. 학습자의 인지적 행동의 이면에 놓여 있거나 혹은 그 것을 설명하는 신경 구조를 통해 정보를 얻으려고 하는 것이지 그러한 신경 구조를 확인하려고 하는 것이 아니다. 그것은 인지 신경과학의 과제이지 교육 신경 과학의 과제는 아니다. 따라서 교육 신경 과학과 인지 신경 과학의 차이점은 의식의 기능과 그것이 어디로부터 오는지, 그리고 어떻게 신경 체제의 활동으로부터 발생하는 것이 가능한지에 관련된 후자가 겪는 진퇴양난에서 확인될 수 있다. 교육 신경과학은 현실과 의식의 활용성을 주어진 것으로 보며, 작업의 대상으로 보지 설명해야 할 것으로 보지 않는다.

아마 인지 신경 과학과 교육 신경 과학 사이의 잠재적 교집합과 공통 관심 영역의 대부분은 각각 인지, 교육 심리학일 것이다. 둘 다 다양한 철학적 관점에서 인지 및 학습 모델들의 개발에 연관되어 왔다. 둘 다 이러한 모델과 뇌 행동 사이의 신뢰할 수 있는 상관관계를 확인하고 확립하는 데 관심이 있다.

인지 신경 과학은 인지 기능과 뇌 및 뇌 행동을 연관시키는 데 대단한 진보를 이루고 있다. 수학 교육은 이러한 발전으로부터 큰 혜택을 얻을 수 있다. 인지 신경과학의 방법론, 이론, 결과들로 설명되는 새로운 진실한 교육 연구 분야로서 이는 진정한 교육 신경 과학의 가능성을 제시한다.

인지 과학 및 인지적 테크놀로지들을 수학 교육 연구에 통합하려는 계획과 노력이 있었다(Davis, 1984; Schoenfeld, 1987; Pea, 1987). 그러나 최근까지 수학 교육 연구에서 신경 과학 또는 인지 신경 과학의 함의의 가능성을 연구하거나 밝혀내는 문헌들은 거의 없었다.

전통적으로 주관적인 인간의 경험과 객관적으로 관찰 가능한 행동에 대한 통합적 연구를 약화시키는 기초적 이원론을 배제하고 교육 신경과학은 다음의 관점을 택한다(Campbell & Dawson, 1995).

- (1) 마음은 몸(뇌에 대한 특별한 강조)에 있다.
- (2) 인간 문화 속에 체화된 마음을 위치시킨다.
- (3) 인간성의 자연 세계로부터 생물학적 발생과 자연에 대한 우리의 의존성을 인식한다.

만약 마음이 근본적으로(즉, 존재론적으로) 물질세계와 구별된다면, 왜 수학이 물질세계에 그렇게 효과적으로 적용될 수 있는지에 대한 것이 수수께끼로 남는다. 체화의 관점이 제안하는 것처럼 마음이 물질세계 안에 들어 있다고 한다면, 수수께끼는 예상으로 바뀌게 된다(Campbell, 2001). 더욱이 체화된 마음을 존재론적으로 원초적인 것으로 생각하면, 의식을 설명할 수 없고 명백히 쓸모없는 지금까지의 기계적인 신경 절차들의 부수적인 현상으로 간주 할 필요가 없다(Jackendoff, 1987). 그러면 우리는 자연 세계에서 명백하며, 객관적으로 관찰 가능한 구조와 절차들을 이용하여 주관적인 마음의 경험을 공유하고 참여하는 것을 기대할 수 있다(Campbell, 2001).

이 자연주의적인 체화된, 상황적, 창발적 관점에 따르면, 의미가 구성될 때, 마음에서 변환이 일어나고 이는 몸으로 표현된다(구체적으로 뇌 행동의 변화를 통해서). 물론 그러한 체화된, 즉 객관적으로 관찰 가능하고 측정 가능한, 마음의 표현은 주관성의 그림자 속에 남아있을 수 있다. 이는 신장성이 있는 물체의 표면을 물체 내부의 외부로의 표현으로 비유할 수 있다. 신장성이 있는 물체의 표면을 가능한 한 최대한 벗겨내도, 내부의 일부 영역은 여전히 드러나지 않을 것이다. 결론적으로 뇌와 뇌의 행동은 면밀한 관찰과 의료, 교실, 생태학적 맥락들에서 체화된 행동과 사회적 사회 작용에 대한 연구들을 통한 탐구로 설명될 것이다. 뇌 영상 기술의 진보에 따라 마음의 그림자는 더욱 날카로워질 것이다.

체화된 인지는 수학 교육 신경과학에 객관적으로 관찰 가능한 체화된 동작과 행동의 측면들로 표현되는 것으로 가정된 마음의 주관적 경험에 대한 일반적 관점을 제공한다. 이러한 프레임워크는 교육 신경과학이 진정한 초학문적 탐구가 될 수 있도록 한다. 마음에 대한 것(현상학), 뇌(신경과학), 기능(기능주의), 행동(행동주의)의 결합된 전통적 존재론적 프레

임 워크들을 넘어서 확장되고 통합될 수 있다. 게다가 마음을 뇌에 한정 짓거나(물리주의), 뇌를 마음에 한정 지으려는 시도(이상주의)가 필요 없다.

Campbell(2006)은 수학교육자 및 수학교육연구자로서 인지신경과학과 정신생리학의 발전을 수학교육과 관련시켜야 한다고 주장하였다. 그는 수학교육 신경과학의 근본적인 가정으로서 인간인지를 체화된 인지 로 보았는데, 즉 인간이 경험할 수 있는 모든 주관적인 기억, 감각, 사고 등은 근본적으로 관찰가능하며, 객관적이고, 구현된 행동양식으로 드러난다고 보았다. 또한 Campbell은 신경촬영법이 기존의 행동적 연구로는 접근할 수 없었던 측정과 분석을 가능하게 함으로써 교육학 연구자들에게 교수학습과 관련된 의문점을 탐색하는데 도움을 주며, 질적으로 기술된 체화의 반응을 양적으로 나타냄으로써 주관적인 경험에 대한 중요한 통찰을 제공한다고 보았다. 즉, Campbell은 수학교육 연구에 있어서 수학교육 신경과학의 주요한 역할이란 좀 더 증거 기반 적이고 객관적인 견해를 제공해 주는 것이라고 생각하였다. 예를 들어 피부반응, 아이 트래킹, 동공 반응, 심전도, EEG, 호흡 등과 같은 생리학적인 데이터를 활용한 수학교육 연구는 수학 교수와 학습에 있어 보다 더 깊고 나은 이해를 제공하게 된다.

이와 같은 관점에서 수학교육연구 방법으로서 사용될 수 있는 인지신경기법으로 신경생리학적 방법이 있는데, 이는 뇌파나 근전도 측정법을 아울러 말한다. 1794년에 Galvani는 개구리의 신경·근육 표본에서 신경의 자극이 근육수축을 일으킨다는 것을 관찰하였고, 이로써 신경생리학 역사가 시작되었다(진복희, 박선영, 2005). 이후 1929년에 Hans Berger는 사람의 두피 위에서 뇌의 활동에 관련한 전기현상을 기록하게 되었는데, 이것이 뇌파의 시작이다(진복희, 2011). 뇌파를 포함한 신경과학이 최근에 급속히 성장하게 된 원동력에는 분자 수준에서 연구가 가능하게 된 현대생물학의 발전과 살아있는 뇌의 인지기능을 연구할 수 있는 기능핵자기공명영상과 같은 뇌기능영상기술의 발달에 있다.

그 중에서도 EEG(electroencephalograph)은 가장 역사가 오랜 기법으로

서 뇌에서 자발적으로 일어나는 뇌전위의 변화를 측정하는 방법이다. 또한 EEG는 비 침습적이며, 경비가 비교적 저렴하고, 두뇌의 역동성에 대한 정보를 초당 만 비트 이상으로 쉽게 수집할 수 있다는 장점을 갖고 있다. 두피에서의 전위를 측정하는 EEG와 두뇌 내부에서의 전류 주변에 발생하는 자장을 측정하는 MEG는 다른 방법들에 비해서 시간적인 해상도가 매우 우수하다(권석원, 2009). 뿐만 아니라 fMRI나 MEG와 달리 개방된 공간에서 측정이 이루어지므로 실험환경이 연구대상자에게 주는 제약점을 최대한 차단할 수 있다는 장점이 있다. 특히 휴대용 EEG 장비들은 학교 현장에서도 사용할 수 있어 EEG의 활용 가능성을 높여줄 수 있을 것으로 기대 된다. 그러나 모든 인지 신경기법마다 고유의 장·단점이 있으므로 무엇보다도 연구목적 및 대상에 맞는 연구방법을 선정할 수 있는 연구자의 안목이 필요하다.

수학과 관련된 선행 연구에서, 뇌 영상은 수학 문제의 답을 계산하는 것이 단어 연상과 언어 과제에 관련된 뇌 영역들에서 활성이 증가함을 정확하게 보여주었다. 그 영역은 좌측 전두엽과 각이랑(angular gyrus)이었다(Dehaene et al., 1999). 이것은 정규 수학의 습득은 우리들이 규칙과 과정을 배우는 능력에 달려 있다는 것을 의미한다.

그리고 계산 장애(dyscalculia)는 우리들의 ‘전수학적’ 추정능력(pre mathematical)의 결손으로부터 발생한다. 수리적 장애를 갖고 있는 저체중으로 태어난 청소년에 관한 한 연구는 이런 장애와 연관된 지역인 두정 내 고랑에 회백질이 적다는 것을 보여주었다. 이와 같은 뇌 영상 연구로부터 얻는 통찰력은 교육적 중재를 개발하는 데 유용한 수학적 발달 모형에 기여하였다. 교사들이 수학 교육의 초기 단계에 기본적인 수리적 그리고 개념적 지식에 초점을 맞춘 경우에는 계산 장애를 갖고 있는 아이들의 광범위한 계산 능력이 상당히 향상됨을 보여주었다(Kaufmann et al., 2003).

그리고 Dehaene의 신경 과학 연구는 수학적 능력을 획득하는 데 우리들의 동물적 숫자 감각의 중요성을 강조해 왔다. 그는 이런 연구를 바탕으로 계산 장애 치료를 목표로 하는 교육 소프트웨어를 개발하고 평가하




는 데에 참여해 왔다. 이러한 소프트웨어는 계산 장애는 숫자 감각의 핵심이 결여되어 발생한다는 가설에 근거한다(Wilson et al., 2006).

## 2. 뇌파

뇌파를 측정하고 분석하기 위해서는 뇌의 구조와 뇌파의 측정 및 분석 방법에 대한 이해가 요구된다. 정신활동을 담당하고 있으며 뇌파 신호가 발생하는 두피와 직접적인 관련이 있는 대뇌의 구조를 먼저 살펴본다.

### 2.1. 대뇌의 구조



[그림 II-1] 대뇌 피질의 구조


인간의 뇌는 크게 대뇌와 소뇌, 그리고 뇌간으로 나뉜다. 이중 대뇌는 기억이나 판단 등 정신활동의 중추이다. 대뇌 피질은 크게 전두엽, 두정엽, 측두엽, 후두엽의 4개의 엽으로 구성되어 있다.

전두엽(Frontal Lobe)은 전두엽은 측열구 위쪽, 중심열구 앞쪽에 위치하며 여기에는 일차운동영역, 전운동영역, 전두안구운동영역, 운동언어영역, 전두연합영역 등이 속한다. 두정엽(Parietal Lobe)은 체감각, 시각, 청

각을 통해 입수된 정보를 통합하여 공간적 소재나 신체부위의 위치 등을 인식하고 운동을 기획하는 통합중추이다. 측두엽(Temporal Lobe)은 머리의 양 측면에 있는 부분으로 청각수용영역(auditory receptive area), 시각로를 이루는 부분, 일부 변연계와 관계 있는 부분, 그리고 우성 측두엽의 감각성 언어중추(receptive speech area) 등이 있다.

청각연합영역과 청각피질이 있어 주로 청각정보의 처리를 담당하는 중추 역할을 하며, 언어의 처리와 크게 관련되어 있다. 후두엽(Occipital Lobe)은 머리 뒷부분에 위치하며 후두엽의 모든 기능은 시각과 직·간접으로 관련되어 있다(김재용, 2005).

## 2.2. 뇌파와 EEG




[그림 II-2] 뇌파의 종류

EEG(Electroencephalography, 뇌전도)는 뇌의 전기적 활동을 기록하는 전기 생리학적 모니터링 방법이다. 보통 비침습적이며 전극은 두피를 따라 배치되지만 침습성 전극도 종종 사용되기도 한다. EEG는 뇌의 뉴런에서 이온 전류로 인한 전압 변동을 측정한다. 임상 맥락에서 뇌파는 두피에 놓인 여러 개의 전극에서 기록된 것과 같이 뇌의 자발적인 전기적 활동을 일정 시간 동안 기록한 것을 의미한다. 진단 응용 프로그램은 일반적으로 ERP 또는 EEG의 스펙트럼 내용에 초점을 둔다. 전자는 자극

또는 단추 누르기와 같은 이벤트에 따른 뇌파 반응을 조사하고 후자는 주파수 영역의 뇌파 신호에서 관찰 할 수 있는 신경 진동의 유형(일반적으로 “뇌파“라고 함)을 분석한다.

### 2.3. 국제 표준 10-20 시스템



[그림 II-3] 10-20 시스템

10-20 시스템 또는 국제 10-20 시스템은 EEG 실험에서 두피 전극의 위치를 기술하고 적용하는 국제적으로 인정된 방법이다. 이 방법은 표준 재현성을 보장하기 위해 개발되었다. 이 시스템은 전극의 위치와 대뇌 피질의 기본 영역 사이의 관계를 기반으로 한다. “10” 과 “20” 이란 인접한 전극 사이의 실제 거리가 두개골의 전체 앞뒤 또는 좌우 거리의 10% 또는 20%라는 사실을 나타낸다.

각 위치에는 엽을 식별 할 수있는 문자와 반구 위치를 식별하는 숫자가 있다. F, T, C, P 및 O는 각각 전두엽, 측두엽, 중심부, 두정엽 및 후두엽을 나타낸다. 짝수 우반구의 전극 위치를 홀수는 좌반구의 전극 위치를 의미하며 중앙으로부터 거리에 따라 오름차순으로 수를 배정한다. z는 중심선에 놓인 전극을 의미한다.

## 2.4. 수학교육 EEG 선행연구

현재까지 진행된 국내 수학 교육의 EEG 연구는 수학 영재(김남희, 2013), 수학 불안(윤은정, 2014; 석영민, 2015; 한세호, 고상숙, 2016; 고상숙, 이창연, 2016), 측정 환경 설계(김종진, 2016), 수학 교구의 두뇌 활성화(김형원, 2017) 등에 관한 연구들이 있다.

석영민(2015)은 대학교 학생 40명을 대상으로 수학불안 검사지를 실시하여 참여자를 HMA(고불안), LMA(저불안) 그룹으로 분류하였다. 그리고 함수 과제 수행 중 나타나는 뇌파를 측정하였다. 그리고 측정된 뇌파와 수학 불안 간의 상관관계를 분석하였다. 이 때 수학 불안이 큰 집단(HMA)의 뇌파 진폭이 더 크게 나타났는데 불안이 큰 집단이 불안이 더 적은 집단(LMA)보다 과제 수행 중에 더 많은 작업 기억을 필요로 하는 것과 관련되어 있는 것으로 보았다.

고상숙, 이창연(2016)은 마찬가지로 고등학교 학생 41명에 대하여 수학 불안 검사지를 실시하고 참가자를 HMA, LMA 그룹으로 분류하였다. 그리고 함수 영역에 대한 처치 프로그램을 적용한 후 뇌파를 측정하여 이들을 비교하고자 하였다. 산술과제 20문항, 그래프-함수식 과제 20문항, 함수식-그래프 과제 20문항의 뇌파 분석을 통해 HMA집단이 G과제에서 Fp1의 양극전위가 더 컸음을 밝힘으로써 서술 표상인 식에서 묘사표상인 그래프로 전환하는 것이 수학 불안에 의한 영향이 크다는 것을 밝혔다. 즉, 이미지나 아이콘 등의 하위 수준에서 기호화, 추상화 등의 상위 수준으로의 전환이 더 복잡한 작업 기억을 요구한다는 것이다.

한세호, 고상숙(2016)은 고등학교 여학생 11명을 대상으로 10차시의 수학불안 감소 프로그램을 개발하여 실시하고 사전, 사후 수학 불안 검사지와 뇌파 검사를 실시하여 수학 불안이 감소하였음을 보여주었다.

김남희(2013)는 눈 감고 안정, 눈 뜨고 안정, 과제 수행 시 각각 20초에 해당하는 뇌파를 측정하고 Field Trip에서 제공하는 Infomax 알고리즘을 적용한 독립 성분 분석(ICA)을 통해 근전도 혼입과 눈 깜박임 노이즈

를 제거하였다. 그리고 상대 파워 분석을 통해 14세의 수학 영재아(과학고 영재교육원 소속 학생) 8명과 일반아 8명의 뇌파 활성 차이를 확인하였다. 눈감고 안정 상태에서는 세타, 알파파 눈 뜨고 안정 상태에서는 세타, 알파, 감마파가 유의미한 차이가 있었다. 문제 해결 과정에서는 세타, 알파, 베타, 감마파 모두에서 차이를 확인하였다.

윤은정(2014)은 한국표준과학연구원의 자기 차폐실에서 뇌파 측정 실험을 수행하였다. 초등학교 6학년 학생 93명을 대상으로 수학불안 검사를 실시하고 HMA 11명, LMA 11명에 대하여 눈감고 안정 상태의 3초, 자연수, 분수, 소수의 연산과 같은 산술과제 20문항에 대해 문항 제시 직후 1초의 뇌파를 수집하였다. 그 결과 수학 불안이 높은 집단이 수학 불안이 낮은 집단보다 델타파가 많이 발생함을 확인하였다. sLORETA 프로그램으로 분석하여 우측 전두엽, 브로드만 영역 10, 11에서 델타파 신호원의 위치를 확인하였다. 또한 수학불안이 높은 학생들은 두뇌 각 영역들 간의 연결성이 떨어짐으로 인해 학업 성취가 떨어짐을 확인하였다.

김형원(2017)은 대학생 24명을 대상으로 교구를 활용한 경우와 교구를 활용하지 않은 경우에 나타나는 두뇌 활성 패턴을 연구하였다. 델타파는 제외하고 ICA 처리와 sLORETA 처리를 통해 뇌파를 분석한 결과 이상 연산 문제 해결 시 교구를 사용하는 것이 적절한 수준의 인지 부하를 발생시켰으며 이 때 학습자의 불안이 낮아졌음을 확인하였다.

김종진(2016)은 학습자의 인지 전략의 차이를 뇌파 특성으로 확인하기 위한 EEG 실험 환경을 설계하였다. 행동 검사 시스템과 과제 수행시의 EEG를 수집하는 뇌파 측정 시스템을 통합한 데이터 수집 환경과 이를 파이썬으로 분석하는 데이터 분석 환경을 설계하였다.




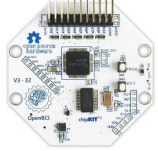
<표 II-1> 국내 수학교육 뇌파 연구에 사용된 뇌파 장비와 프로그램

논문	뇌파 장비	프로그램	채널	기관명
석영민(2015)	Brain Vision standard V-AMP	Professional Recorder, Analyzer	16	단국대
고상숙, 이창연(2016)	Brain Vision Standard V-AMP	Professional Recorder, Analyzer	16	
한세호, 고상숙(2016)	Brain Vision Standard V-AMP	Professional Recorder, Analyzer	16	
김남희(2013)	E-series EEG system	E-series 3.4 Release Version	19	교원대
윤은정(2014)	BioSEMI	KRISSMEG AG152V2K, BrainMap-3D	19	
김형원(2017)	E-series EEG system	E-series 3.4 Release Version	19	
김종진(2016)	Discovery 24e	python	19	서울대

국내 수학교육에서 뇌파 연구에 사용된 뇌파 장비와 프로그램을 위와 같이 정리하여 보면 그 특징이 드러난다. 윤은정(2014)이 한국과학표준원에서 연구를 수행한 경우를 제외하면 수학 교육에서는 뇌파 장비를 보유한 연구 기관인 단국대, 교원대, 서울대를 중심으로 뇌파 연구가 수행되고 있음을 알 수 있다. 이는 뇌파 연구의 장비 및 프로그램 의존성을 보여주는 것으로서 장비와 프로그램이 없는 곳에서 새롭게 뇌파 연구를 시작하기 어렵다는 것으로 해석할 수 있다. 그리고 표에 나타난 선행 연구들은 16~19채널의 뇌파 장비를 이용하여 신경 과학의 방법론을 그대로 재현하는 데 중점을 두었다. 이로 인해 이러한 연구 결과들이 현장의 교사나 교육 연구자들이 적용하는 데에는 한계가 있다. 이러한 맥락에서 EEG를 교수학적으로 변환하여 사용할 필요성이 생겨난다. 엄밀한 연구 환경에서 사용하는 EEG 시스템에 더해 교육 현장에서 사용할 수 있는 형태의 EEG 시스템의 가능성을 탐색하는 것은 EEG의 활용가능성을 높이는 측면에서 의미가 있다.

### 3. 휴대용(Portable) EEG 시스템

<표 II-2> 시판중인 휴대용 EEG 시스템

	Neurosky Mindwave	Interaxon Muse 2016	Emotiv EPOC	OpenBCI Biosensing Boards
				
가격	\$100	\$250	\$800	\$500-900
채널수	1	4-5	14	8-16
샘플링 레이트	512Hz	256Hz	256Hz	16khz
해상도	12 bits	12 bits	16 bits	24 bits
밴드 폭	3-100Hz	2-50Hz	0.2-43Hz	0.01-70Hz
배터리 타입	AAA 전지	리튬이온	리튬이온	AA 전지
블루투스	지원	지원	지원	지원
ERP 가능	X	O	O	O

연구 수준의 장비보다 저렴한 소비자 수준(Consumer grade) EEG 장비들이 꾸준히 출시되고 있으며 이에 맞추어 해외에서는 이러한 저비용, 휴대용(portable, low-cost) EEG 장비들의 효과성과 활용성에 관련된 연구들이 진행되고 있다. 그 중에서 Mindwave는 가장 저렴하지만 채널수가 1개 밖에 되지 않는다. EPOC는 합리적인 선택이 될 수 있는 스펙을 갖추고 있으나 raw data를 얻으려면 SDK access를 포함한 Emotiv PRO의 비용(월 \$99)을 지불해야 하는 단점이 있다. OpenBCI는 직접 전극을 원하는 위치에 부착할 수 있다는 장점이 있으나 그만큼 착용의 편리성이 떨어지고 사용법을 익히는데 시간이 소요된다. 뮤즈는 OpenBCI에 비해 상대적으로 사용 편의성이 우수하며 Mindwave에 비해 4채널을 확보하고

있어 활용성이 높다. 그리고 EPOC와 달리 별도의 추가 비용 없이 raw data를 확보할 수 있어 뇌파 데이터를 자유롭게 분석하고 연구할 수 있다. 뮤즈는 학교 현장에서 사용할 수 있을 정도의 비용으로 4채널 뇌파 데이터를 제공하므로 뇌파 연구를 시작하는 연구자나 학교에서 학습 용도로 사용하기 적절하다고 생각된다.

<표 II-3> 시중에 공개된 EEG 분석 프로그램

사용 언어	EEG 툴박스/프로그램
MATLAB	EEGLAB, BCILAB, ERPLAB, FieldTrip
python	PyEEG, MNE-python
C/C++	OpenViBE, BioSig, BrainBay

그리고 여러 EEG 신호 처리 및 분석을 할 수 있는 무료 툴박스나 프로그램들이 제공되고 있다. 그러나 이러한 프로그램을 손쉽게 사용하려면 요구하는 지원하는 파일 형식을 제공하는 뇌파 장비를 사용하여야 한다. 뮤즈의 경우에는 정식으로 지원하는 툴박스가 없어서 파이썬 모듈들을 활용하여 코드를 작성하여 신호 처리와 분석을 하기로 하였다.

해외에서도 휴대용 EEG 장비들의 효과성 검증이 최근 몇 년간 꾸준히 이루어지고 있다. Karydis et al.(2015)에서는 웨어러블 EEG 장치를 이용하여 5개의 표준 머신 러닝 알고리즘들을 결합하여 두뇌 상태를 정확하게 분류 할 수 있는 새로운 자기 교정 프로토콜(Self-Calibrating Protocol, SCP)을 제안하였다. 그들은 시판 중인 웨어러블 EEG 센서가 임의의 사용자 상태를 실시간으로 차별화 할 수 있을 만큼 빠른 속도로 충분한 데이터 충실도를 제공한다는 것을 확인하였으며 SCP를 이용하여 개별화된 치료 및 맞춤형 프로그램을 개발할 수 있을 것이라고 결론지었다.

Bashivan, Rish, Heisig(2016)은 교수적(논리적), 오락(감정적) 비디오를 감상하는 동안의 뇌파를 Consumer grade EEG를 이용하여 측정하였다.



머신러닝의 SVM 기법을 이용하여 두 가지 심적 상태(mental state)를 휴대용 뇌파 장비를 이용하여 구분하는 것이 가능함을 입증하였다.

Armanfard et al.(2016)은 뮤즈를 이용하여 5명의 참가자가 PVT를 실행하는 동안 5분의 뇌파를 녹화하였다. 이를 이용하여 자극에 대한 반응 속도로서 조심성(vigilance)을 측정하였다. 이때 SVM을 이용하여 뇌파로 사용자의 주의 상태를 95%의 정확도로 판별해냈다.

Krigolson et al.(2017)은 뮤즈를 이용하여 신경과학의 ERP 연구가 가능한지 탐구하였다. Odd ball task와 Reward learning task 과제 수행 시에 두 가지 장비 actiChamp(\$77,100)과 뮤즈(\$249)를 이용하여 뇌파를 측정하였다. 그 결과 뮤즈를 이용하여 10분 이내의 짧은 시간에 actiChamp와 유사하게 N200, P300를 관측할 수 있음을 보여주었다.

그리고 Li et al.(2015)은 뮤즈를 이용하여 집중과 안정 상태를 구분할 수 있는지 연구하였다. 연구 결과 F7, F8의 감마파를 이용하여 두 가지 상태가 구분되는 것으로 나타났다. 이를 이용하여 분석적 위계 모델(Analytic hierarchy Model)을 바탕으로 뇌파 SVM 모델을 구축하였다. 이를 이용하여 사용자의 집중과 안정 상태를 93%의 정확도로 구별해냈다. 그리고 파이썬을 이용하여 뇌파로 비행기를 조종할 수 있는 프로그램을 코딩하였다.

#### 4. 유동지능과 패턴 추론 : Raven의 누진행렬검사

미국심리학회의 일반지능(general intelligence)의 정의에 따르면 “개인들은 복잡한 아이디어를 이해하는 능력과 환경에 효과적으로 적응하는 것에서 차이를 보이며 경험으로부터 배우는 것과 다양한 형태의 추론 과정과 사고를 통해 어려운 문제를 해결하는 능력들이 서로 다르다. 이 능력의 근간을 이루는 것을 지능이라고 부른다.” 이렇게 정의된 지능은 측정 가능하며, 지능 점수는 학업 성취에서 개인 간 차이와 성인이 되었을 때 직업에서의 성공도 예측할 수 있다(Tariq et al., 2012). 지능과 학업성취간의 관계를 이해하기 위해서 지능을 유동지능과 결정지능으로 구

분하는 것은 중요하다(Moutafi, Furnham & Paltiel, 2004). 이러한 구분을 처음으로 제안한 사람은 Raymond Cattell인데, 그의 제안 이래로 gf-gc 이론은 지능의 심리측정학 패러다임에서 가장 널리 수용되고 있다(Carroll, 1993). 유동지능은 기본적으로 경험에 의존하지 않는 기술로 즉석에서 행해지는 추리력으로 정의되어 왔다(Belsky, 1990). 유동 지능은 신속한 사고, 추리, 개념간의 관계 유추, 새로운 문제를 시도하는 능력과 관련된 것으로 생물학적인 기반을 지닌 것으로 간주된다(Brody, 1992).

유동 지능은 복잡한 관계를 이해하며, 새로운 문제를 해결할 수 있는 능력이라고 정의된다(Martinez-Pons, 1999). 유동 지능은 때로는 ‘비언어적 지능’, ‘추론 능력’으로 불리기도 하는데 학습이나 문화의 영향에 크게 의존하지 않는다는 특징이 있다. 유동 지능은 추상적인 정보나 규칙, 논리적 관계 등을 다루는 능력이기 때문에 수학적 능력과 깊은 관계를 가질 수밖에 없으며 여러 요인들 중에서 학업 성취도에 대해 가장 높은 예측 도를 보인다(Spinath, Fruedenthaler, & Neubauer, 2010).

유동 지능은 일반적으로 레이븐의 누진 행렬 검사(Raven's Progressive Matrices, RPM)를 이용하여 측정한다. 유동 지능과 수학 성취도와의 관계는 여러 연구자들에 의해서 알려졌다(Holyoak & Morrison, 2005; Preusse et al., 2011; Spinath, Freudenthaler & Neubauer, 2010). 오스트리아의 연구팀이 8학년 학생 1300 명의 언어와 수, 공간적 능력과 유동성 지능뿐 아니라 정서적 요인들(자아감이나 동기 등)을 모두 고려했을 때도 지능은 모든 영역의 학업 성취(수학, 영어, 독일어)에서 가장 높은 예측력을 보였다(Spinath, Freudenthaler & Neubauer, 2010).

RPM 검사는 추론 능력을 측정하기 위해 개발된 비언어성 검사로서 60년 이상의 역사를 가지고 있다. 국제적으로 표준화된 지능검사로 인정받고 있으며 다양한 선별 도구 중에서 능력 검사의 타당도가 가장 높은 편이다(Schmidt & Hunter, 1998). 이 행렬 검사는 총 3가지의 버전이 있다. 가장 먼저 SPM(Standard Progressive Matrices)이 1938년에 출시되었다. 그리고 1947년에 CPM(Coloured Progressive Matrices)가 출시되었는데 이 검사는 어린 아동, 노인, 지적장애가 있는 사람을 대상으로 사용할 수

있다. 그리고 고급 수준의 APM(Advanced Progressive Matrices)가 1941년 출시되었다. 우리는 따로 구분할 필요가 없을 때에는 이를 통틀어 RPM(Raven's Progressive Matrices)라고 부른다. RPM 검사는 기업체의 선발도구로서 사용되며 학교, 병원 등 여러 장면에서 사용하고 있지만 문항의 난이도와 변별력에 관해서는 많은 비판이 존재하기도 한다. 예를 들어 문항 난이도와 관련하여 SPM의 경우 검사 문항이 쉽거나 중간 수준에 해당하는 문항들이 너무 많이 포함되어 있다는 비판을 받고 있다(전덕임, 1995).

RPM 검사는 원래 시간제한이 없는 검사로서 점점 어려워지는 순서로 문항을 배열하여 어느 수준의 문제까지 푸느냐에 의해 지적 능력을 측정한다. 그런데 난이도가 높은 문항을 보유하고 있지 못하면 검사의 변별력이 전반적으로 떨어질 수 있다는 것이다(윤희현, 이종구, 2008).

이에 본 연구에서는 RPM 중에서도 APM 검사를 사용하기로 결정하였다. 난이도가 높은 문항도 보유한 검사지를 활용함으로써 쉬운 문제와 어려운 문제를 풀 때 학습자의 뇌파를 관찰하는 것이 더욱 용이하도록 한 것이다. APM은 1941년 48개의 문항으로 처음으로 개발되었고 1962년에 36개의 문항으로 줄이고 문항을 재배열하는 큰 개정이 이루어졌다.

APM은 심리측정학 및 인지심리분야에서 엄격히 연구된 몇 안 되는 검사도구 가운데 하나로서 시간과 비용 측면에서 교육적 활용도가 높다. 김혜진, 설현수(2008)에 따르면 APM은 일반지능검사를 대체하여 간편하게 사용할 수 있는 사회경제적인 영향이 최소화된 지능검사임을 경험적으로 확인하였다. APM의 도형추론지능은 K-WISC-III로 측정된 일반지능과 유의미한 상관관계가 있었으며 성별과 사회경제적 지위에 따라 차이가 없는 것으로 확인되었다. 또한 APM 점수는 학업성취도와 유의미한 상관관계가 있는 것으로 나타났다.

학교 현장에서 뇌파 연구를 도입하기 위해 본 연구에서는 학생들이 해결해야 할 인지 과제의 선정이 매우 중요한 문제이다. 수학 교수와 학습의 실행 장면에서 나타나는 실제 수학 문제를 해결하는 도중에 뇌파를 측정하여 학생들에게 피드백을 제공하는 것은 수학 교육신경과학의 최종

목표이기는 하나 본 연구에서 뇌파 분석 용도의 인지과제로 사용하는 것은 아직 이르다고 판단하였다. 신경 과학의 영역에서 APM과 뇌파의 관계는 선행 연구들이 존재하고, APM 자체도 오랜 시간 동안 엄격히 연구되어 그 타당성을 인정받고 있는바 뮤즈를 이용하여 APM을 해결하는 학습자의 뇌파를 측정하여 분석하는 것은 신뢰성을 확보할 수 있을 것으로 기대한다.

## 5. 학습 양식 : Kolb의 LSI

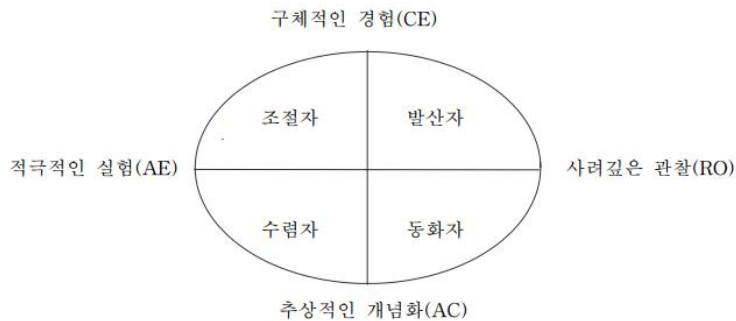
학습유형(learning style)이란 일련의 학습 습관이며, 학습 방법들의 집합체이다(전명남, 2004). 학습유형이란 학습자가 오랜 시간을 두고 형성해 온 자신이 선호하는 학습의 양식이라고도 할 수 있다. 학습유형은 개인이 정보를 수집하고 처리하는데 나타나는 지속적인 선호방법이나 양식으로 알려져 왔다. Kolb(1976)는 학습이 경험의 변형(transformation)을 통한 창조과정이라는 경험학습이론(Experiential Learning Theory: ELT)을 주장하면서 이 이론에 바탕을 둔 학습유형 모형을 제시하였다.

### 5.1. KLSI 3.1

Kolb와 Kolb(2005)는 경험학습이론을 기반으로 하는 학습유형검사를 다음과 같이 두 가지 목적을 성취하기 위해 개발하였다. 첫째, 이 검사는 학습자가 경험으로부터 배우는 학습과정과 자신의 학습행동 특성에 대한 이해를 증진시키는 교육적 도구로서 개발되었다. 자신이 어떻게 배우는지에 대한 이해를 증진함으로써 학습자의 학습과정에 대한 초인지적 통제능력을 강화하고 다양한 학습상황에서 자기에게 가장 적합한 학습방식을 선택할 수 있게 해 준다는 것이다. Kolb와 Kolb(2005)는 이 검사를 시험으로서가 아니라 자신의 학습을 이해하기 위한 도구로서 활용할 것을 권고하고 있다. 둘째, 이 검사는 경험학습이론에 대한 연구의 도구로 활

용하기 위해 개발되었다. 이들은 경험 학습의 폭넓은 활용과 발전을 위해, 학습유형별 점수의 타당도를 높이기 위해 이 검사가 활용되기를 기대하였다. 또한 학습유형검사는 준거기준검사가 아니며 개인행동의 예측을 위해 개발된 도구가 아니기 때문에 선발, 배치, 진로지도 혹은 선택적 처치를 위해 활용해서는 안 된다고도 하였다. Kolb 학습유형검사는 1971년 버전 1이 개발된 이래 4차례의 수정을 거쳐 2005년 출판된 버전 3.1에 이르렀다. 최초의 Kolb 학습유형검사는 1969년 MIT에서 경영학 교과서(Kolb, Rubin & McIntyre, 1971) 개발 과정에서 제작되었다. 이 검사는 학습자들이 경험학습의 개념과 경험을 통해 배우는 개인의 학습행동 특성을 이해하는데 도움을 줄 수 있는 경험학습의 도구로서 개발되었던 것이다. 문항은 경험학습에 대한 전문적인 이해를 가지고 있는 학자 4명으로 구성된 패널을 통해 초안을 개발한 다음 20명의 대학원 학생들의 문항별 사회적 적합성 평정을 통해 정리되었다. 최종적으로 남은 12개의 문항으로 사전검사가 실시되었으며 그 결과를 반영하여 9개로 조정되었다. 버전 1은 1985년 버전 2가 나오기 전까지 발표된 350여 편의 연구를 통해 검증되었다. 버전 2는 버전 1에서 지적된 신뢰도 문제를 개선하기 위해 3개를 삭제하고 6개 문항을 새로 추가하였으며 문장을 더욱 단순화하였다. 1993년에 출간된 버전 2a는 버전 2의 문항을 더욱 불규칙적으로 배열한 것으로서 내적 타당도는 약간 감소했으나 재검사 신뢰도가 매우 증가하는 효과가 있었다. 1999년에 개정 출판된 버전 3은 자기 진단이 가능하도록 편집하여 해설과 함께 소책자로 만들어진 것이다. 2005년의 버전 3.1에는 6,977명의 학습유형검사 사용자의 검사결과 자료를 준거로 판단 기준을 첨부하였다. 전체 12개의 문항으로 구성된 학습유형검사는 각 문항마다 응답자에게 4개의 학습유형을 대표하는 진술에 대하여 자신의 학습행동과 가장 가까운 것부터 먼 것 순서로 점수(1점부터 4점까지)를 기입하게 하고 그 점수들을 각 유형별로 합산하여 각 유형별 특성을 나타내는 점수를 얻는 것이다. 학습 상황을 제시하고 모든 유형에 대하여 선호 정도를 강제로 표기하게 한 것이 특징이다. Kolb와 Kolb(2005)는 이러한 응답방식은 경험학습의 통전적, 역동적, 변증법적 특성을 반영하

기 위한 것이라고 하였다. 학습 상황에 따라 학습유형 중 우선순위를 결정하게 한 것은 학습유형간의 상호 연관성을 반영하기 위해서라고 하였다. 또한 경험학습이론은 학습 유형은 어떤 고정된 특성이 아니라 개인이 환경과의 상호작용 과정에서 경험을 파지, 변형하는 과업의 수행 상황에 따라 역동적으로 선택될 수 있는 것이라고 하였다.



[그림 II-4] Kolb의 4가지 기본적인 학습유형

Kolb(1976)는 개인의 학습 유형을 발산자, 조절자, 수렴자, 동화자의 네 가지 유형으로 분류시켰다. 네 가지 학습 유형은 그림 II-4와 같다. 사분면 중 1사분면에 위치한 발산자는 경험을 구체적으로 인식하고 이를 사려 깊게 처리하기를 좋아한다. 이 유형에 속하는 사람들의 가장 큰 강점은 상상력을 발휘하고 다양한 관점으로부터 구체적인 상황을 바라보는 능력이 탁월한 사람들이다. 사분면 중 2사분면에 위치한 조절자는 정보를 구체적으로 인식하고 이를 적극적으로 처리하기를 좋아한다. 이 유형에 속하는 사람들의 가장 큰 강점은 무언가를 행하는 데에서 발휘될 수 있다. 이들은 새로운 경험 속에 자신을 관여시키고 위험을 무릅쓰고 무언가를 하는 경향이 있으며 시행착오의 방식으로 문제를 해결하는 것을 좋아한다. 사분면 중 3사분면에 위치한 수렴자는 정보를 추상적으로 인식하고, 이를 적극적으로 처리하기를 좋아한다. 이 유형에 속하는 사람들의 가장 큰 강점은 생각을 실제로 응용하는데 탁월하다는 점이다. 이들은 또한 개별적인 관찰들을 통합시키는 데에도 뛰어나다. 마지막으로

사분면의 4사분면에 위치한 동화자는 정보를 추상적으로 인식하고, 이를 사려 깊게 처리하기를 좋아한다. 이 유형에 속하는 사람들의 강점은 이론적인 모형을 창조하는 능력이 있다는 것이다.

Rashid(2011)는 학습자의 학습 양식을 KLSI를 통해 4가지로 구분하고 EO, EC 상태에서 뇌파를 기록하였다. 4개의 학습 양식을 multiple fixed-factor variable로 Alpha ESD 값을 multiple dependent variables로 SPSS를 이용하여 분석하였다. MANOVA로 어떤 변수가 가장 학습자의 학습 양식을 잘 예측하는지 분석한 결과 알파파가 학습 양식을 가장 잘 예측하였다. 이를 이용하여 Two step cluster analysis를 이용하여 참가자의 EEG 데이터를 학습 양식과 100% 일치하게 분류해 낼 수 있었다. 그리고  $ARR = (PL - PR) / (PL + PR)$  지표를 활용한 알파파 분석 결과 학습 양식 가운데 발산자(Diverger)가 가장 높은 IQ를 나타냈으며 수렴자(Converger), 발산자(Diverger)가 스트레스에 가장 취약한 것으로 나타났다.

## 6. 머신 러닝(machine learning, 기계학습)

<표 II-4> 머신 러닝과 데이터 마이닝 비교

머신 러닝	데이터 마이닝
훈련 데이터를 통해 학습된 알려진 속성을 기반으로 예측에 초점을 두고 있음.	데이터의 미처 몰랐던 속성을 발견하는 것에 집중함. 데이터베이스의 지식 발견 부분의 분석절차에 해당함.

머신 러닝은 인공지능의 한 분야로 컴퓨터가 학습할 수 있도록 하는 알고리즘과 기술을 개발하는 분야를 말한다. 머신 러닝은 빅데이터에 대한 활용을 가능하게 한다. 머신 러닝의 개념은 이미 1959년에 등장하였으며 아서 사무엘은 머신 러닝을 “기계가 일일이 코드로 명시하지 않은

동작을 데이터로부터 학습하여 실행할 수 있도록 하는 알고리즘을 개발하는 연구 분야”라고 정의하였다. 머신 러닝과 데이터 마이닝은 종종 같은 방법을 사용하며 상당히 중첩되는 부분이 많지만 표 II-4과 같은 특성이 있다.

현대는 데이터가 자산인 시대로서 저장 장치와 통신 장비, 측정 기술의 발달로 다양한 형태의 데이터들이 폭발적으로 매순간 생성되고 전송되어 저장된다. 데이터의 폭발적 증가는 데이터를 처리하고 저장하고 분석할 수 있는 기술이 뒷받침되고 있기 때문이다. 데이터 분석을 위한 빅데이터나 머신 러닝, 딥 러닝과 같은 용어들이 최근 대두되고 있지만 사실 이러한 개념들은 이미 수십 년 전에 태동한 분야이다. 수십 년 동안의 잠복기 끝에 이러한 개념들이 다시 대두되는 이유는 기술이 이론을 구현할 만큼 발전했기 때문이다. 그리고 머신 러닝이 복잡해 보이지만 그 핵심에는 수학이 있다. 머신 러닝의 다양한 알고리즘 중에는 평균, 편차, 행렬, 함수 등 중·고등학교의 학교 수학의 수학적 개념과 간단한 프로그램 사용법만 익히면 사용할 수 있는 것들이 있다. 그럼에도 불구하고 수학교육에서 머신 러닝은 어려운 것으로 받아들이기 쉽다. 그리고 머신 러닝에는 데이터가 중요하다. 그런데 머신 러닝의 학습에 있어 그동안 성별, 나이별 키와 몸무게나 와인의 종류와 같은 데이터를 활용해 왔다. 뇌파 데이터는 그 방대한 데이터 양으로 인해 자연스럽게 데이터 분석의 필요성을 느끼게 한다. 따라서 학생 자신의 뇌파 데이터를 사용하여 머신러닝을 체험해볼 수 있도록 하면 학생 자신과 연관성(relevance)이 확보된 상태에서 자연스럽게 데이터 분석에 몰입할 수 있도록 할 수 있다. 또한 그 분석 과정이 다소 어려울 수 있지만 외부 모듈의 도움을 받으면서 체험해볼 수 있는 상대적으로 쉬운 머신러닝의 알고리즘을 이용하면 된다. 이를 통해 학생들은 수학의 유용성을 체험하고 수학에 대한 정의적 태도를 키울 수 있으며 4차 산업 혁명 시대에 어울리는 수학과 데이터 코딩의 융합의 관점에서 종합적인 학습 경험을 가질 수 있을 것으로 기대한다. 여러 머신 러닝 기법들이 존재하지만 그 중에 비지도 학습으로 K-means 클러스터링과 지도학습으로 신경망 알고리즘



을 뮤즈를 이용하여 획득한 뇌파 데이터를 이용하여 적용하고자 한다.

## 6.1. K-means 클러스터링

클러스터링(Clustering)이란 데이터를 1. 높은 클러스터 내(intra-cluster) 유사성(similarity), 2. 낮은 클러스터 간(inter-cluster) 유사성과 같은 조건을 갖는 클러스터로 조직하는 것이다. 쉽게 말하면 데이터들에 대한 자연스러운 그룹화를 찾는 것이다. 유사성은 어떻게 측정할까? 오브젝트 사이의 유사성을 측정하기 위해서 두 대상 사이의 거리(distance)를 측정해야 한다. 먼저 오브젝트를 거리를 잴 수 있는 공간의 데이터들로 대응시켜야 한다. 즉, 데이터를 특성 벡터로, 유클리드 공간의 점으로 변환하는 것이다. 데이터를 클러스터로 조직하면 데이터의 내부 구조에 대한 정보를 얻을 수 있다. 이미지 분할과 같이 데이터를 분할하는 것 자체가 목적이 될 수도 있다. 데이터에서 지식을 발견하는 것이 목적이 될 수 있다.

그 중에서 K-means clustering이란 같은 클러스터에 속하는 데이터들의 클러스터 내 유사성을 증가시키는 방향으로 클러스터를 형성한다. 이때 가정은 데이터가 유클리드 공간 위에 있어야 한다는 것이다. 즉, 평균을 구할 수 있도록 실수의 좌표를 가져야 한다.

1. K의 값을 결정한다. K는 클러스터의 개수이다.
2. K 클러스터의 초기 중심점  $C = \{C_1, C_2, \dots, C_K\}$  을 랜덤하게 설정한다.
3. 각각의 오브젝트를 그 오브젝트와 가장 가까운 중심점으로 할당한다. 이것을 통해 전체 오브젝트의 클래스 멤버십을 결정한다.
4. 같은 중심점에 할당된 오브젝트들의 평균값  $\mu = \{m^{(1)}, m^{(2)}, \dots, m^{(K)}\}$  을 구한다.
5. 구한 평균값을 새로운 중심점으로 설정  $C = \{C_1, C_2, \dots, C_K\}$   
 $\leftarrow \mu = \{m^{(1)}, m^{(2)}, \dots, m^{(K)}\}$  로 바꾼다.
6. 3~5의 단계를 더 이상 어떤 오브젝트도 자신이 속한 클러스터가 바뀌지 않을

때까지, 즉 클러스터의 멤버십이 바뀌지 않을 때까지 반복한다.

## 6.2. 신경망(Neural Network)

인간의 중추 신경계에 대한 연구는 신경망 개념에 영감을 주었다. 생물학적 신경망을 흉내 내는 네트워크를 형상화하기 위해 신경망에서 인공 뉴런들은 서로 연결되어 있다. 통계학적 모델들이 다음과 같은 특징들을 가지고 있을 때 해당 집합을 우리는 신경이라고 부른다.

1. 조정이 가능한 가중치들의 집합 즉, 학습 알고리즘에 의해 조정이 가능한 숫자로 표현된 매개변수로 구성되어있다.
2. 입력의 비선형 함수를 유추할 수 있다.

조정 가능한 가중치들은 뉴런 사이의 연결 강도를 의미하고 이들은 훈련 또는 예측하는 동안에 작동한다. 다양한 유닛들이 할당된 하위 작업보다 유닛들에 의한 병렬 혹은 집합적으로 함수들을 수행한다는 점에서 신경망은 생물학적 신경망과 닮았다. '신경망'이라는 단어는 보통 통계학, 인지 심리학 그리고 인공지능에서 사용되는 모델들을 가리킨다. 중추 신경을 모방하는 신경망 모델들은 이론 신경과학과 계산 신경과학의 한 부분이다.

인공신경망을 구현한 현대의 소프트웨어에서는 생물학적 접근법은 신호처리와 통계학에 근거한 좀 더 현실적인 접근법들로 인해 주로 사용되지 않는다. 이러한 시스템들 중 몇몇에서는 신경망 또는 신경망의 부분들(인공 신경들)은 큰 시스템을 형성하며 이러한 시스템은 조정이 가능하거나 기능하지 않은 구성 요소들로 결합되어 있다. 이러한 시스템의 일반적인 접근법은 많은 현실 문제 해결에 적합한 반면에 전통적인 인공지능 연결 모델에서는 그렇지 않다. 그러나 이들에게도 공통점이 있는데 그것은 비선형의 원리 분산, 병렬과 지역 처리 그리고 적응이다. 역사적으로 신경 모델들의 이용은 18세기 후반 if-then 규칙으로 표현된 지능

을 가진 전문가 시스템을 특징으로 하는 고차원(symbolic) 인공지능에서부터 동적 시스템의 매개변수들을 가진 지능을 특징으로 하는 저차원(sub-symbolic) 기계학습으로 가는 패러다임의 변환이다.

Warren McCulloch와 Walter Pitts는 1943년 수학과 임계 논리(threshold logic)라 불리는 알고리즘을 바탕으로 신경망을 위한 계산학 모델을 만들었다. 이 모델은 신경망 연구의 두 가지 다른 접근법에 대한 초석을 닦았다. 하나의 접근법은 뇌의 신경학적 처리에 집중하는 것이고 다른 하나는 인공 신경망의 활용에 집중하는 것이다.

Frank Rosenblatt는 1958년 퍼셉트론 즉, 간단한 덧셈과 뺄셈을 하는 이층구조의 학습 컴퓨터 망에 근거한 패턴 인식을 위한 알고리즘을 만들었다. 계산학 표기법과 함께 Rosenblatt는 또한 기본적인 퍼셉트론에 대한 회로가 아닌 예를 들면 배타적 논리합 회로(exclusive-or circuit)와 같은 회로를 표기하였다. 해당 회로의 수학 계산은 Paul Werbos에 의해 오차역전파법이 만들어진 후에 1975년에 가능하였다.

Marvin Minsky와 Seymour Papert에 의해 기계학습 논문이 1969년 발표된 후에 신경망 연구는 침체되었다. 그들은 인공신경망에서 두 가지 문제점을 찾아내었다. 첫 번째로는 단층 신경망은 배타적 논리합(XOR) 회로를 처리하지 못한다는 것이다. 두 번째 중요한 문제는 거대한 신경망에 의해 처리되는 긴 시간을 컴퓨터가 충분히 효과적으로 처리할 만큼 정교하지 않다는 것이다. 신경망 연구는 컴퓨터가 충분히 빨라지고, 배타적 논리합 문제를 효율적으로 처리하는 오차 역전파법이 만들어지기까지 더디게 진행되었다.

인공신경망은 SVM과 같은 다른 기계학습 방법들의 인기를 점차적으로 추월하고 있다. 2000년대 이후 딥 러닝의 출현이후 신경 집합의 새로운 관심은 다시 조명 받고 있다. 단어 ‘인공신경망’에서 망은 각 시스템에 있는 여러 층의 뉴런 간의 연결을 의미한다. 예를 들어 세 층이 있는 시스템이 있다면, 첫 번째 층은 시냅스를 통해 두 번째 층의 뉴런들로 데이터를 보내는 입력 뉴런들이 있고, 더 많은 시냅스를 통해 세 번째 층의 출력 뉴런으로 신호를 보내는 식이다. 시스템이 더 복잡해질수록

뉴런 층의 수도 더 많아지고, 그 층 안에 있는 입력 뉴런과 출력 뉴런들의 수도 많아질 것이다. 이 시냅스들은 계산 과정에서 데이터 값을 조절하는 가중치 값을 저장한다. 학습 패러다임에는 크게 지도 학습, 자율 학습, 준 지도 학습이 있으며, 각각 특정한 추상적인 학습 과제에 대응된다.


뉴런은 입력을 받았을 때 즉시 반응하지는 않는다. 대신에 입력이 누적되어 어떤 수준으로 커진 경우에만 출력을 하게 된다. 즉 입력 값이 어떤 분계 점에 도달해야 출력이 발생하는 것이다. 이처럼 입력 신호를 받아 특정 분계 점을 넘어서는 경우에 출력 신호를 생성해주는 함수를 활성화 함수(activation function)이라고 한다. 계단 함수나 시그모이드 함수(sigmoid function)와 그 변형 함수들이 사용된다.

$$\text{시그모이드 함수} : y = \frac{1}{1 + e^{-x}}$$

뉴런은 여러 입력 값을 더해 시그모이드 함수의 입력 값으로 전달한다. 그리고 시그모이드 함수는 이 입력 값을 이용해 출력을 생성한다. 뉴런을 여러 계층(layer)에 위치시키고 각각의 뉴런은 직전 계층과 직후 계층에 있는 모든 뉴런들과 상호 연결되어 있도록 표현하면 된다. 노드 간 연결의 강도를 조정해 나감으로써 신경망이 구축된다. 이 때 각각의 연결에 가중치(weight)를 적용한다. 낮은 가중치는 신호를 약화하며 높은 가중치는 신호를 강화한다.

신경망에서 학습이란 연결 노드의 가중치를 업데이트하는 과정을 의미한다. 가중치의 업데이트는 오차에 의해 주도되는데, 오차는 학습 데이터로부터 주어진 정답과 출력값 간의 차이를 의미한다.

중간 계층에 존재하는 노드들의 오차는 명백하지 않다. 출력 계층의 노드들의 오차를 이와 연결된 가중치의 크기에 비례해 나누어 역전파하고 이를 재조합하는 것이 하나의 방법이다.



[그림 II-5] 신경망의 형태

오차의 역 전파에 대한 가중치는 경사 하강법(gradient descent)을 이용하여 구할 수 있다.

은닉 계층과 출력 계층 사이에 있는 가중치를 업데이트하기 위해서 다음의 오차 기울기를 구한다.

오차를  $E = \sum_n (t_n - o_n)^2$  이라 두고

양변을  $w_{jk}$ 에 대해 편미분하면  $\frac{\partial E}{\partial w_{jk}} = \frac{\partial}{\partial w_{jk}} (t_k - o_k)^2$  이다.

연쇄법칙에 의해  $\frac{\partial E}{\partial w_{jk}} = -2(t_k - o_k) \cdot \frac{\partial}{\partial w_{jk}} \text{sigmoid}(\sum_j w_{jk} \cdot o_j)$

$\Leftrightarrow \frac{\partial E}{\partial w_{jk}} = -(t_k - o_k) \cdot \text{sigmoid}(\sum_j w_{jk} \cdot o_j) (1 - \text{sigmoid}(\sum_j w_{jk} \cdot o_j)) \cdot o_j$ 가 된다.

그리고 은닉 계층과 입력 계층 사이에 있는 가중치들에 대해서도 유사하게 오차 기울기를 찾을 수 있다. 첫 오차인  $e_j = (\text{목표값} - \text{실제값})$ 은 은닉 계층에서 재조합된 역전파 오류가 되고 두 번째 시그모이드 부분은 동일하지만 합 부분이 은닉 계층의 노드 j로 들어오는 입력 값에 가중치를 적용한 결과가 된다. 이 입력 값을  $i_j$ 라 하고 마지막 부분은 첫 번째 계층의 노드  $o_i$ 의 결과 값이 되므로 다음을 얻을 수 있다.

$$\frac{\partial E}{\partial w_{ij}} = -(e_j) \cdot \text{sigmoid}(\sum_i w_{ij} \cdot o_i) (1 - \text{sigmoid}(\sum_i w_{ij} \cdot o_i)) \cdot o_i$$

학습률이란 오버슈팅을 방지하기 위해 변화의 강도를 조정하는 역할을 하는 상수  $\alpha$ 이다. 학습률을 이용하여  $(w_{jk})' = w_{jk} - \alpha \cdot \frac{\partial E}{\partial w_{jk}}$ 와 같이 역전파 가중치를 조절하는데 사용한다. 이는 적합하지 않은 데이터에서 받는 나쁜 영향을 줄이고 가중치가 최저점 근처에서 오버슈팅 되는 것을 방지할 수 있다.

본 연구에서는 파이썬을 이용하여 신경망 클래스 코드를 작성하고 본 연구에서 확인한 뇌파 특성 벡터를 학습시켜 임의의 질의에 대해 신경망을 이용하여 출력값을 결정할 수 있도록 한다.

### Ⅲ. 뇌파 측정 및 분석 환경 설계

#### 1. 뇌파 측정 도구의 선정

최근 기술의 발전으로 인해 휴대할 수 있는 저비용 EEG 시스템들이 출시되고 있다. 이러한 EEG 시스템들은 개발자 도구 소프트웨어를 제공하여 연구자들로 하여금 원본 데이터를 다룰 수 있도록 하고 있다. 그러나 시스템의 개발과 별개로 이러한 시스템들을 이용한 EEG 연구의 효과성을 입증하기 위한 연구들은 아직까지 많지 않으며 이 연구들은 주로 표준 뇌파 장비들의 연구를 모방하며 이를 그대로 재현하는데 초점을 맞추어 왔다(Duvinage et al., 2013; Gramann et al., 2014; Wascher et al., 2014; Maskeliunas et al., 2016; Kuziek et al., 2017). 대부분의 저비용 EEG 연구가 전자 캡을 이용하거나 모든 표준 전극을 이용하고 있는데 이는 저비용 EEG 시스템이 가진 휴대성과 손 쉬운 사용이라는 장점을 희생하는 것이다.

기술적 관점에서 연구용 뇌파 장비가 아닌 저비용, 비표준 장비를 이용하여 뇌파 연구를 시행하기 어려운 이유가 몇 가지 있는데 첫째는 데이터의 질 문제이다. 뇌파 분석에서 요구되는 250Hz 이상의 샘플링 레이트와 노이즈와 아티팩트면에서 질 좋은 데이터를 얻을 수 있느냐 하는 문제이다. 뇌파 측정에서 데이터 수집의 품질을 확보하는 것은 중요한 문제로서 Picton et al.(2000)은 Pinton Paper에서 전극의 타입, 전극의 종류, 의미 있는 해석을 위한 전극의 수, 증폭기의 능력 등을 논하였다. 예를 들어 컨버터의 비트수(최소 8비트)와 같은 증폭기 성질 EEG 연구를 위해 필요한 최소값들이다. 따라서 저비용 EEG 시스템의 사용에 있어서 실제 하드웨어가 요구되는 데이터의 수준을 만족하는지 살펴보는 것이 중요한 관심사가 된다. 만약 Picton paper에 나타난 최소 표준을 저비용 EEG 시스템이 충족시키지 못한다면 해당 시스템은 의미 있는 해석을 위해 필요한 수준의 EEG data를 얻을 수 없다는 것이다. portable, low


cost EEG systems for ERP research에 관련된 선행 연구(Debener et al., 2012; Vos et al., 2014)에 따르면 휴대용 EEG 장비를 이용하여 뇌파 분석에 필요한 데이터의 질을 확보하는 것이 가능하다고 나타난다.

또 다른 저비용 EEG 시스템에 관련된 문제는 시간의 문제이다. 보통 뇌파 연구에서는 자극을 제시하는 컴퓨터에서 녹화하는 컴퓨터로 이벤트 마커(event marker)를 보내는데 이때 parallel 또는 TTL cable을 이용하여 데이터에 마킹을 남기게 된다. 마킹된 데이터를 이용하여 연구에 필요한 각 epoch를 정확히 추출할 수 있다. 그리고 블루투스 프로토콜을 이용하기 때문에 데이터에 시간 축에서 잡음(jitter)이 발생하게 된다. 그러나 이러한 블루투스 딜레이( $\pm 20\text{ms}$ )에서 오는 편차는 자연적인 것으로 정규적(Gaussian)으로 가정할 수 있으므로 데이터 분석에서 평균을 내는 방식으로 이러한 오차를 처리할 수 있다.

그리고 저비용 EEG 시스템의 마지막 문제는 전극의 위치 문제이다. 보통 연구자들은 이미 선행 연구에서 밝혀진 특정 요소에 대해 그 특징이 가장 잘 나타나는 특정 전극의 데이터를 찾아 분석하는 것이 일반적이다(Rugg and Coles, 1995; Luck, 2014). 그러나 저비용 EEG 시스템을 사용하게 되면 특정 전극을 사용할 수 없게 된다. 전극 위치를 마음대로 정할 수 없다는 단점을 사용이 간편하다는 장점과 교환하기로 결정할 수 있다. 이러한 방법이 이상적이지는 않지만 본 연구의 목적 하에서는 주어진 장비의 전극을 이용할 수밖에 없다.

여러 뇌파 장비들 가운데에서도 연구 수준으로 사용할 수 있는 가능성이 있으면서 사용이 간편한 뮤즈(Interaxon Muse)를 본 연구에서 사용한다. 비록 전극 위치를 마음대로 정할 수 없다는 단점이 있지만 사용이 간편하다는 점과 학생들이 착용할 때 거부감이 적은 점, 측정하는 데 시간이 적게 든다는 점 등에서 교육 현장에서 활용 가능성을 높여주기 때문이다. 뮤즈를 사용하는 것이 뇌파를 탐구하기 위한 순수 연구 목적 하에서는 이상적이지 않을 수 있지만 뇌파를 교육 현장으로 확산시키고자 하는 본 연구의 목적 하에서는 적절할 수 있다고 판단하였다.



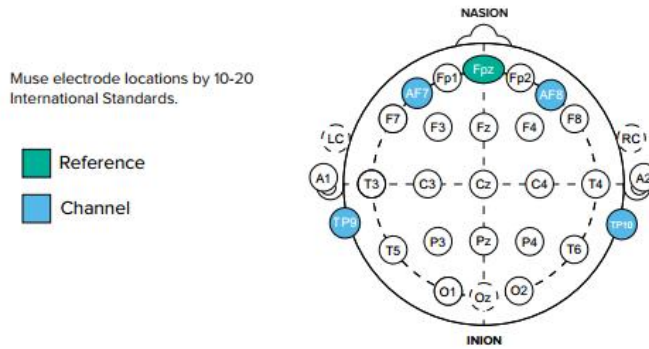


[그림 III-1] 뮤즈 본체와 전극 위치 및 규격

뮤즈는 2014, 2016 두 가지 버전이 있는데 본 연구에서는 2016 버전을 사용하였다. 뮤즈는 헤드밴드 형태로 이마와 양쪽 귀에 걸쳐서 착용한다. 이마 쪽에 5개, 양쪽의 고무 밴드에 2개의 전극이 탑재되어 있다. 이때 이마 쪽 전극의 가운데 3개는 Fpz로 레퍼런스로 사용된다. 그리고 양측 2개의 전극은 왼쪽이 AF7, 오른쪽이 AF8에 해당된다. 그러나 이러한 전극 위치는 개인의 머리 둘레에 따라 달라질 수 있다. 머리의 크기가 작을수록 AF7은 F7에 AF8은 F8에 가까워진다. 그리고 양쪽의 귀 부분에 TP9, TP10의 전극을 이용하고 있다.

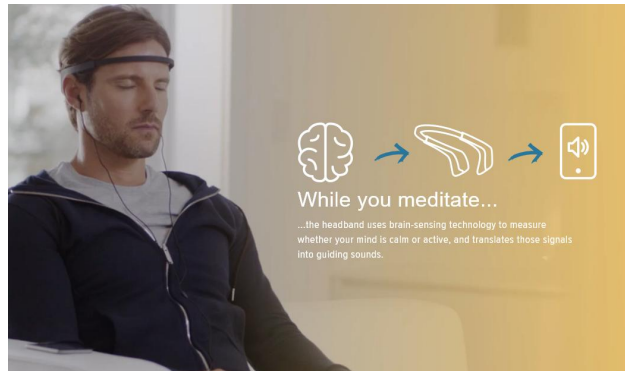
따라서 레퍼런스를 제외하면 머리의 좌측으로부터 총 4개 TP9, AF7, AF8, TP10의 4개의 전극에서 뇌파를 측정한다고 할 수 있다. 그리고 후면의 microUSB 포트를 이용하면 여분의 전극 1개를 추가로 이용할 수 있다. 이를 이용하면 EMG, ECG, 특정 전극의 EEG를 기록할 수 있게 된다.

측정된 데이터는 기본적으로 Bluetooth 4.0 LE를 이용하여 전송된다. 12bits 크기의 데이터가 초당 256개의 속도로 기록된다. 이마 쪽 전극의 소재는 은으로 되어 있으며 귀 쪽 전극의 소재는 전도성 실리콘-고무이다. 노이즈  $2\mu V$ (RMS) 이상의 DRL-REF의 차를 기록하며 Notch Filter는 기본적으로 제공되지 않는다. 블루투스를 이용하여 컴퓨터나 휴대폰 앱으로 데이터를 전송하는데 이때 블루투스 딜레이가 평균적으로 20ms 정도 발생하는 것으로 알려져 있다. 선행 연구와 마찬가지로 블루투스 딜레이( $\pm 20ms$ )에서 오는 편차는 자연적인 것으로 정규적(Gaussian)으로 가정할 수 있으므로 데이터 분석에서 평균을 내는 방식으로 이러한 오차를 처리할 수 있다.



[그림 III-2] 뮤즈의 전극 위치

## 2. 뇌파의 측정



[그림 III-3] 뮤즈 착용 장면

그림과 같이 착용된 뮤즈는 그 데이터를 Open Sound Control(OSC)라는 프로토콜을 이용하여 /muse/eeg라는 OSC path로 전송한다. 이 때 이 데이터의 단위는  $\mu V$  이고 데이터 형태는 floats이다. 12비트의 해상도로 각 전극별로  $0.0-1682.815\mu V$  범위의 값을 [TP9, AF7, AF8, TP10, 추가전극]의 순서쌍으로 전송한다. 3차원 가속계, 중력 감지기 값과 내장 프로세서에서 계산된 밴드 파워 값들도 함께 전송되지만 본 연구에서 사용하지 않는다.

본 연구에서는 뮤즈에서 획득한 뇌파의 raw data 자체만을 이용하여 뇌파의 측정과 분석을 진행한다. 굳이 뮤즈에서 제공하는 밴드 파워를 사용하지 않고 raw data를 직접 가공하여 사용하는 이유 2가지가 있다.

첫째, 다른 장비로 뇌파 장비를 교체하거나 업그레이드 하였을 때 동일한 절차의 측정과 분석 방법을 그대로 이용할 수 있도록 하기 위함이다.

둘째는 뇌파 대역이나 연구 대상을 추후 연구자가 직접 수정할 수 있도록 하기 위해서이다. 제조사가 제공하는 대역의 뇌파 데이터만을 사용하면 연구자가 수동적이 될 수밖에 없다. 선행 연구들을 살펴보면 때에 따라서는 베타파를 13-30Hz로 살펴볼 수도 있고 하이베타, 로우베타 13-20, 20-30Hz 로 그 대역을 세분하여 살펴볼 수도 있다. 따라서 이러한 자유도를 갖기 위해서 밴드 파워는 raw data를 이용하여 직접 FFT 처리하여 사용하기로 하였다.

이렇게 측정된 뇌파 데이터를 컴퓨터로 전송하여 기록하는 것은 어떻게 할 수 있을까? 2가지 방법이 있다.

첫째, 블루투스로 뮤즈와 Muse-IO를 연결하고 Muse-IO에서 OSC 스트리밍을 하도록 하는 것이다. 이것은 뮤즈 홈페이지에서 기본적으로 제공하고 있는 방법으로서 무료이다. 하지만 Muse-IO가 Muse 2014 버전만을 지원하므로 Muse 2016을 사용하는 이용자는 이용할 수 없는 방법이다.

둘째, MuseMonitor라는 휴대폰 애플리케이션을 이용하는 것이다. 이 앱은 안드로이드 플레이스토어나 애플의 앱스토어에서 다운로드 하여 사용할 수 있다. 이 앱은 Muse-IO의 대체제로서 작용하며 뮤즈로부터 데이터를 받아 지정된 IP, PORT로 OSC 스트리밍을 해주는 역할을 한다.

2017년 하반기에 MuseDirect가 출시되었다. 이는 2014, 2016버전 모두 Muse-IO를 이용하도록 할 수 있는 프로그램의 베타 버전으로서 아직은 완벽하지 않지만 앞으로 뮤즈 2016에서 Muse-IO를 이용할 수 없었던 문제점을 해소할 수 있게 되었다.

### 3. 뇌파의 분석

획득된 뇌파의 분석에 사용되는 여러 프로그램들이 존재한다. 그러나 교육 현장에서는 고비용의 뇌파 분석 프로그램을 구매하여 이용하기 어렵다. 무료 프로그램들 중에서는 MATLAB의 EEGLAB 모듈이 무료이면서 그 활용성을 인정받고 있으나 MATLAB 프로그램 자체가 유료 라이선스로 구입해야 하기 때문에 교육 현장에서 이용하기 어렵다.

따라서 본 연구의 목적에 맞게 교육 현장에 뇌파 연구를 확산시키기 위해 무료로 사용할 수 있는 프로그램으로서 상대적으로 사용이 쉬운 언어인 파이썬을 이용하여 뇌파를 분석할 수 있는 프로그램을 개발하여 사용하기로 하였다. 파이썬을 이용하면 기록된 뇌파의 데이터를 이용하여 실시간 분석과 사후 분석이 모두 가능하다.

실시간으로 뮤즈와 연동하기 위해서는 pythonOSC라는 모듈을 이용하여 Muse-IO나 MuseMonitor의 OSC 스트리밍 데이터를 실시간으로 가져

와야 한다. 파이썬에는 2버전과 3버전의 두 가지 버전이 존재한다. 2버전의 모듈들이 3버전으로 옮겨지는 상황이라는 하지만 모든 모듈들이 상호 호환 되는 것은 아니다. 그런데 pythonOSC는 python 3버전만 지원하기 때문에 실시간 뮤즈 연동을 감안하고 파이썬을 설치하는 경우에는 3버전을 설치해서 사용한다. 만약 실시간으로 뮤즈와 연동이 필요 없는 경우에는 파이썬 2버전을 사용해도 무방하다.

파이썬을 이용하여 Raw 데이터에 몇 가지 단계에 걸쳐 신호 처리를 수행한다. 첫 번째로 노치 필터(Notch Filter)를 적용한다. 노치 필터란 밴드 패스 필터와는 반대 특성을 나타내는 필터로서 송신기에서 발사되는 간섭파나 고조파와 같은 원하지 않는 신호를 없애는데 사용한다. 뇌파에서는 보통 측정과 기록에 모두 전기가 들어가는 전자 장비를 이용하는데 이때 전선 내의 교류 진동수에 대한 잡음이 발생한다. 따라서 이를 제거하는 것이 노치 필터이다. 한국, 미국에서는 60Hz를 사용하고 유럽 등지에서 50Hz를 사용한다.

둘째로 밴드 패스 필터를 적용한다. raw data에서 0hz offset을 제거하여 주어야 하고 고주파와 저주파에서 잡음이 포함되어 있는 경우가 많으므로 0.5-50Hz 정도로 특정 주파수의 신호만 남기고 나머지를 삭제하는 밴드패스 필터를 적용한다.

<표 III-1> 뇌파 분류와 해당 주파수 대역

이름	주파수 대역
델타파( $\delta$ , delta absolute)	1-4 Hz
세타파( $\theta$ , theta absolute)	4-8 Hz
알파파( $\alpha$ , alpha absolute)	8-12 Hz
베타파( $\beta$ , beta absolute)	12-30 Hz
감마파( $\gamma$ , gamma absolute)	30-50 Hz

그리고 Hamming Window를 이용하여 Raw 데이터에 주파수 축으로 FFT 분석을 진행한다. FFT 함수가 파이썬 numpy 모듈에 내장되어 있으므로 이를 쉽게 사용할 수 있다.

그런데 이때 결정해야 할 것 것은 FFT window의 크기와 window overlap의 정도이다. 이를 결정하기 위해 신호 처리의 개념이 필요하다. SR(Sampling Rate), FR(Frequency Resolution), TR(Time Resolution),  $F_{max}$  (maximum Frequency),  $F_0$ (minimum Frequency), T(period), window size (한 번의 FFT 계산에 사용되는 데이터의 개수)라고 하자.

그러면 Nyquist-shannon theorem에 의해  $SR \geq \text{highest frequency}$ 여야 하고  $F_{max} = \frac{SR}{2}$  이다. 그리고  $T = \frac{1}{F}$ 일 때  $T_{window} = 5 * T_{signal}$ 을 만족해야 한다. 즉, window의 길이는 반드시 신호 주기의 5배 이상이어야 한다.

$$T = \frac{(\text{window size})}{(SR)}, \quad F_0 = \frac{5(SR)}{(\text{window size})}, \quad (\text{window size}) = \frac{5(SR)}{F},$$

$$TR = \frac{(\text{window size})}{(SR)}, \quad N(\text{bins}) = \frac{(\text{window size})}{2}$$


<표 III-2> Window size에 따른 뮤즈 변수

Window size(Hz)	Window size(s)	$F_0$	FR (주파수 해상도)	TR (시간 해상도)
256	1	5	1	1
512	2	2.5	0.5	2
768	3	1.67	0.33	3
1024	4	1.25	0.25	4
1280	5	1	0.2	5
1536	6	0.83	0.17	6
1792	7	0.71	0.14	7

뮤즈의 경우를 <표III-2>에 정리하였다.

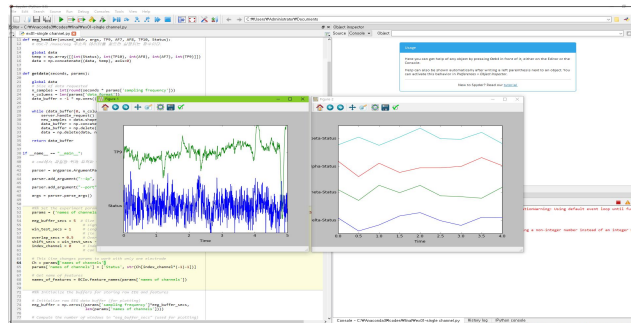
뮤즈의  $SR = 256$ 으로  $F_{max} = 128$  이 되어 감마파 대역을 측정할 수 있다. 그리고 window size에 따라  $F_0$ 가 변하는데 1Hz 이상을 감지하려면 5초가 적절하다. 만약 델타파에 큰 관심이 없다면 window size를 줄이면

서 시간 해상도를 늘릴 수 있다. 다만 window size가 1초 이하로 내려가게 되면 주파수 해상도가 1 이상이 되어 적절하지 않다. 예를 들어 window size를 5초, 1280개를 한다면 측정 가능한 최소 주파수는 1 Hz이고 주파수 해상도는 0.2 Hz, 시간 해상도는 5초이다. 이 때 시간 해상도가 너무 낮아서 시간이 길게 되면 짧은 순간의 뇌파 변화를 감지하기 어렵다는 문제가 있다.



[그림 III-4] 윈도우 길이와 오버랩

하지만 window를 겹치는 방법으로 시간 해상도가 떨어지는 문제점을 보완할 수 있다. 예를 들어 오버랩을 90%, 4.5초로 하면 FFT 계산 주기가 0.5초가 된다.



[그림 III-5] 뮤즈를 이용하여 전송된 데이터를 실시간 파이썬으로 나타낸 장면

#### 4. 뇌파 측정 및 분석 시스템 구성



[그림 III-6]

Muse - Bluetooth 4.0 - Musemonitor - OSC protocol - python

최종적으로 그림 IV-4의 형태로 시스템을 구성하였다. 뮤즈(2016 버전)에서 측정된 뇌파는 블루투스를 이용하여 휴대폰으로 전송된다. 휴대폰에서는 직접 뇌파 데이터를 파일로 저장하거나 OSC protocol을 통해 지정한 IP, port(예: 127.0.0.1:5000)로 전송된 데이터를 streaming할 수 있다. streaming된 데이터는 파이썬의 pythonOSC 모듈을 이용하여 수신하고 데이터 분석을 실시간으로 수행하거나 파일로 저장하여 수행할 수 있다.

연구 과정에서는 실시간이 아니라 파일로 저장된 뇌파 데이터를 파이썬3를 이용하여 신호 처리 및 뇌파 분석을 진행하였다. 뮤즈의 SR은 256Hz이며 노치 필터 60Hz, 밴드패스 필터 0.5-50Hz를 적용한다. Hamming window를 사용하였으며 윈도우 크기와 오버랩은 분석자가 원하는 수치를 입력하여 사용할 수 있도록 하였다.

그리고 뇌파 분석 데이터를 K-means clustering과 Neural Network에 적용하였다. 이를 통해 뮤즈로 측정된 뇌파 데이터가 머신러닝에 적합한지 확인할 수 있다.



```

92 f = open(path+'analysis.csv', 'w')
93
94 win_test_secs = input("Length of the window computing the features? (in seconds) : ")
95 overlap_secs = input("Overlap between two consecutive windows? (in seconds) : ")
96
97 source = 'muse'
98 session_title = "Muse EEG Test Data"
99
100
101
102 for filename in files:
103
104     EEG = EEGrunt.EEGrunt(path, filename, source, session_title)
105     muse_eeg = np.genfromtxt(path+"s"+filename+"raw.csv", delimiter=",")
106
107     EEG.raw_data = muse_eeg[:, :4]
108     EEG.t_sec = np.arange(len(EEG.raw_data[:, 0])) / EEG.fs_Hz
109
110     print ("\nLoading EEG data file : "+path+"s"+filename+"raw.csv")
111     print ("This Session is "+str(len(EEG.t_sec)/EEG.fs_Hz)+ " (seconds) long.")
112
113
114     a, b = EEG.raw_data.shape
115     step = EEG.fs_Hz * overlap_secs
116     FFT_window = int(win_test_secs*EEG.fs_Hz)
117     n=0;temp = []; sum = np.zeros(20)
118
119     for i in np.arange(0, a - FFT_window, step):
120         n+=1
121         y = EEG.raw_data[int(i):int(i) + FFT_window, :]
122         temp = compute_feature_vector(y, EEG.fs_Hz)
123         sum += temp
124
125     sum /= n
126     for item in sum:
127         f.write("%s," %item)
128
129     f.write("%s" % "s"+filename)
130     f.write("\n")
131     print (path+"s"+filename+"raw.csv has been analyzed.")
132
133
134
135 f.close()

```

[그림 III-7] 파이썬 뇌파 데이터 분석 코드

데이터의 기록과 분석의 모든 과정은 파이썬 코드를 이용하여 수행하였다. 이 때 윈도우 크기와 오버랩을 분석자가 원하는 수치를 입력하여 사용할 수 있도록 하였다. 그러나 SSP나 ICA, Maxwell filter등을 이용한 아티팩트 보정은 시행되지 않았으므로 ERP 등의 연구에는 이를 유의하여야 한다.

```

35 ## Assignment Stage
36
37 def assignment(df, centroids):
38     for i in centroids.keys():
39         # sqrt((x1 - x2)^2 - (y1 - y2)^2)
40         df['distance_from_{}'.format(i)] = (
41             np.sqrt(
42                 (df['x'] - centroids[i][0]) ** 2
43                 + (df['y'] - centroids[i][1]) ** 2
44             )
45         )
46     centroid_distance_cols = ['distance_from_{}'.format(i) for i in centroids.keys()]
47     df['closest'] = df.loc[:, centroid_distance_cols].idxmin(axis=1)
48     df['closest'] = df['closest'].map(lambda x: int(x.lstrip('distance_from_')))
49     df['color'] = df['closest'].map(lambda x: colormap[x])
50     return df
51
52 df = assignment(df, centroids)
53 print(df.head())
54
55 fig = plt.figure(figsize=(5, 5))
56 plt.scatter(df['x'], df['y'], color=df['color'], alpha=0.5, edgecolor='k')
57 for i in centroids.keys():
58     plt.scatter(*centroids[i], color=colormap[i])
59 plt.xlim(-1, 0)
60 plt.ylim(-1, 0)
61 plt.show()
62
63 ## Update Stage
64
65 import copy
66
67 old_centroids = copy.deepcopy(centroids)
68
69 def update(k):
70     for i in centroids.keys():
71         centroids[i][0] = np.mean(df[df['closest'] == i]['x'])
72         centroids[i][1] = np.mean(df[df['closest'] == i]['y'])
73     return k
74
75 centroids = update(centroids)
76
77 fig = plt.figure(figsize=(5, 5))
78 ax = plt.axes()
79 plt.scatter(df['x'], df['y'], color=df['color'], alpha=0.5, edgecolor='k')
80 for i in centroids.keys():
81     plt.scatter(*centroids[i], color=colormap[i])
82 plt.xlim(-1, 0)
83 plt.ylim(-1, 0)
84 for i in old_centroids.keys():
85     old_x = old_centroids[i][0]
86     old_y = old_centroids[i][1]
87     dx = (centroids[i][0] - old_centroids[i][0]) * 0.75
88     dy = (centroids[i][1] - old_centroids[i][1]) * 0.75
89
90 plt.show()

```

[그림 III-8] 파이썬 K-means clustering 코드

K-mean clustering의 코드 또한 파이썬으로 작성하였다. 뇌파 데이터를 입력받아 그 분류 결과를 그래프로 나타낼 수 있도록 하였다. 머신 러닝 모듈을 사용하여 결과만 바로 도출하는 대신 centroids를 새롭게 구해가는 클러스터링 과정을 드러낼 수 있도록 코드를 작성하였다.

```

1 import numpy as np
2 import scipy.special
3 import matplotlib.pyplot
4
5 class NeuralNetwork:
6     def __init__(self, inputnodes, hiddennodes, outputnodes, learningrate):
7         self.inodes = inputnodes
8         self.hnodes = hiddennodes
9         self.onodes = outputnodes
10        self.wih = np.random.normal(0.0, pow(self.hnodes, -0.5), (self.hnodes, self.inodes))
11        self.who = np.random.normal(0.0, pow(self.onodes, -0.5), (self.onodes, self.hnodes))
12        self.lr = learningrate
13        self.sigmoid = lambda x: scipy.special.expit(x)
14
15    def query(self, input_list):
16        inputs = np.array(input_list, ndmin=2).T
17        hidden_inputs = np.dot(self.wih, inputs)
18        hidden_outputs = self.sigmoid(hidden_inputs)
19        final_inputs = np.dot(self.who, hidden_outputs)
20        final_outputs = self.sigmoid(final_inputs)
21        return final_outputs
22
23    def train(self, inputs_list, targets_list):
24        inputs = np.array(inputs_list, ndmin=2).T
25        targets1 = np.array(targets_list, ndmin=2).T
26        hidden_inputs = np.dot(self.wih, inputs)
27        hidden_outputs = self.sigmoid(hidden_inputs)
28        final_inputs = np.dot(self.who, hidden_outputs)
29        final_outputs = self.sigmoid(final_inputs)
30        output_errors = targets1 - final_outputs
31        hidden_errors = np.dot(self.who.T, output_errors)
32
33        self.who += self.lr * np.dot((output_errors * final_outputs * (1.0-final_outputs)), np.transpose(hidden_outputs))
34        self.wih += self.lr * np.dot((hidden_errors * hidden_outputs * (1.0-hidden_outputs)), np.transpose(inputs))
35
36
37
38 input_nodes = 20      # 입력 노드수
39 hidden_nodes = 14    # hidden 노드수
40 output_nodes = 2     # 출력 노드 수
41 learning_rate = 0.3  # 학습률
42 epochs = 1000       # 학습 반복 횟수
43
44 NN = NeuralNetwork(input_nodes,hidden_nodes,output_nodes,learning_rate)
45
46 training_data_file = open("NN_dataset/NN_trainingdata0X.csv", 'r')
47 training_data_list = training_data_file.readlines()
48 training_data_file.close()
49
50 for e in range(epochs):
51     for record in training_data_list:
52         all_values = record.split(',')
53         inputs = (np.asarray(all_values[1:])+1.5)/3.3*0.99+0.01
54         targets = np.zeros(output_nodes)+0.01
55         if int(all_values[0]) == -1:
56             targets[0] = 0.99
57         elif int(all_values[0]) == 1:
58             targets[1] = 0.99
59         NN.train(inputs, targets)

```

[그림 III-9] 파이썬 신경망 코드

신경망의 코드도 파이썬으로 작성하였다. 트레이닝 데이터와 테스트 데이터를 .csv로 각각 입력받아 분류 결과와 정답률을 화면에 출력하도록 하였다. 마찬가지로 머신 러닝 모듈을 사용하는 대신 NeuralNetwork class를 코드 안에서 만들어서 사용함으로써 신경망의 훈련 과정을 드러낼 수 있도록 코드를 작성하였다. K-mean clustering과 신경망의 알고리즘을 살펴볼 수 있도록 코드를 작성한 것은 이 코드들이 차후에 학생들의 학습 용도로 사용될 것을 염두에 둔 것이다.

## IV. 뇌파 측정 및 분석 사례

본 연구에서는 뇌파를 측정하여 기록하고 분석할 수 있는 파이썬 환경을 설계하였다. 이에 따라 portable EEG 시스템이 실제로 유효한지를 확인하기 위하여 선행 연구를 바탕으로 2가지 과제를 선정하였다. 학습자 개인의 인지적 능력과 정의적 특성에 대해 각각 한 가지씩 선정하여 이를 뇌파 데이터와 비교하여 본다.

개인의 인지적 능력으로서 유동 지능과 정의적 특성으로서 학습 양식에 대하여 뇌파를 분석해보았다. 유동 지능은 특히 생물학적인 기반을 가졌다는 점과 지능을 뇌파를 이용하여 변별할 수 있다는 선행 연구(Thatcher et al., 2016)를 바탕으로 선정하였다.

그리고 학습 양식 또한 눈감고 휴식 상태의 알파파를 이용하여 변별할 수 있다는 선행 연구(Rashid, 2011)를 바탕으로 선정하였다.

유동 지능과 학습 양식에 대한 신경과학적 접근은 전통적 연구로는 확인할 수 없었던 객관적 데이터에 대한 측정과 분석을 가능하게 함으로써 교육 연구자들로 하여금 학습자의 주관적인 사고 과정에 대해 새로운 통찰을 제공할 수 있을 것이다.

### 1. 연구 설계 및 방법

#### 1.1. 연구 참여자

본 연구의 대상은 S대학교 과학영재교육원 정보 분과 중학교 2학년 학생 20명과 중학교 3학년 학생 13명으로 총 33명(남자 27명, 여자 6명)이다. 연구에 참가하는 학생들은 학생, 학부모 동의서를 서면으로 제출하였으며 모든 연구 과정은 서울대학교 생명윤리위원회(IRB)의 심의(승인번호 No. 1704/003-014)하에 진행되었다. 연구 참여자들에게 연구에 관하여

충분히 설명하였으며 자발적 참여를 바탕으로 원하지 않는 학생은 연구에 참여하지 않도록 하였다.

이 학생들은 그 동안의 영재원 프로그램에 성실히 임한 학생들로서 정보 분과의 교육과정에는 프로그래밍 활동의 일환으로 뇌파에 대한 이론과 함께 자신의 뇌파를 직접 측정하고 여기서 얻어진 데이터를 가공하여 로봇을 움직이는 내용 등이 포함되어 있었기 때문에 본 연구의 의도와 계획을 잘 이해하고 뇌파의 측정 과정에 성실히 참여할 것으로 기대되어 연구의 참여자로 선정하였다. 뇌파는 측정 도중 신체의 움직임에 민감하므로 연구의 참여자는 이러한 사실에 대해 인지하고 협조할 수 있어야 한다.

또한 인지 과제로 제시되는 Raven의 누진 행렬 검사는 평균 이상의 지능을 가진 사람을 변별하는데 효과적인 도구로 알려져 있다. 따라서 일정 수준 이상의 지능을 가진 참여자들을 대상으로 하는 것이 바람직한데 이러한 점에서도 영재원 학생들이 연구 참여자로서 적합하다고 할 수 있다.


## 1.2. 연구 절차

연구의 시작에 앞서 학생들 전체를 대상으로 연구의 의도 및 목적에 대하여 충분히 설명하였으며 연구 절차에 대한 안내를 제공하였다. 공통적으로 제시된 검사 도구에 대한 예시 문항 외에 학생들은 검사 문항에 대한 별도의 사전 학습이 전혀 없는 상태로 연구가 진행되었다.

본 연구는 Kolb의 학습 양식과 Raven 누진 행렬 검사의 결과를 뇌파 분석 결과와 비교하여 분석하는 것이다. Kolb의 학습 양식은 설문지로 APM은 컴퓨터 검사로 진행된다.


연구 참가자들에 대해 먼저 학습 양식 설문을 진행하였다. 학습 양식 설문지(Kolb LSI 3.1, 총 12문항, 5분 이내)를 Google 설문지로 시행하였다. 설문지 작성 과정에서 연구자가 옆에서 입장하여 학습 양식 설문에 대한 질문을 받았으나 설문 문항에 대해 질문한 학생은 따로 없었다.

그리고 컴퓨터를 이용하여 Raven 누진 행렬 검사(APM: Raven's Advanced Progressive Matrices)를 연습문항 3문항, 본 문항 12문항으로 실시하였다. 각 문항의 시작에 앞서 3초간 응시 십자(+)가 제시되었으며 각 문항에 대해 키보드 숫자패드 1-8을 이용하여 응답하도록 하였다. 충분한 시간을 가지고 고민할 수 있도록 각 문항에 대한 제한 시간은 따로 두지 않았으며, 여유 있게 과제를 수행할 수 있도록 안내하였다. 참여자의 과제별 정답 여부와 반응 시간 등의 문항 반응 데이터가 컴퓨터로 기록되며 동시에 뮤즈를 이용하여 EEG를 기록하였다.



×12 문항 반복

그리고 눈 감고 안정 상태(EC 상태)에 대하여 90초, 눈 뜨고 안정 상태(EO 상태)에 대하여 모니터 중앙의 Fixation cross를 응시하는 90초에 대한 뇌파 또한 기록하였다.



[그림 IV-1] 실험 장면

### 1.3. 검사 도구

#### 1.3.1. 학습 양식 설문지(Learning Style Inventory)

De Bello(1990)은 학습 양식을 파악하기 위해 지금까지 공개된 여러 학습 양식 설문지(LSI)가 있지만 타당성(validity)의 관점에서 논쟁이 있다고 하면서 적절한 LSI를 논하기 위해 다음과 같은 3가지 질문을 제기하였다. (1) 안정적이며 타당성이 있는 도구인가? (2) 현장에 널리 사용되는 도구인가? (3) 이 도구에 대한 광범위한 연구가 있는가?

Kolb(2005)의 학습 양식 검사지는 이러한 조건을 충족시킨다. Kolb는 1969년에 Kolb LSI-version 1을 처음으로 만든 뒤에 1985, 1993, 1999, 2005년 Kolb LSI-version 3.1까지 계속 개정해 왔다. 3.1 버전의 매뉴얼에는 6977명의 데이터를 바탕으로 한 기준(norms)을 제공하고 있으며 내적 일관성 신뢰도, 검사-재검사 신뢰도 등의 정량적 데이터도 함께 제시하고 있다. 오랜 기간 사용되어 왔으며 꾸준한 개정으로 KLSI는 안정성과 타당성을 확보했다고 볼 수 있다.

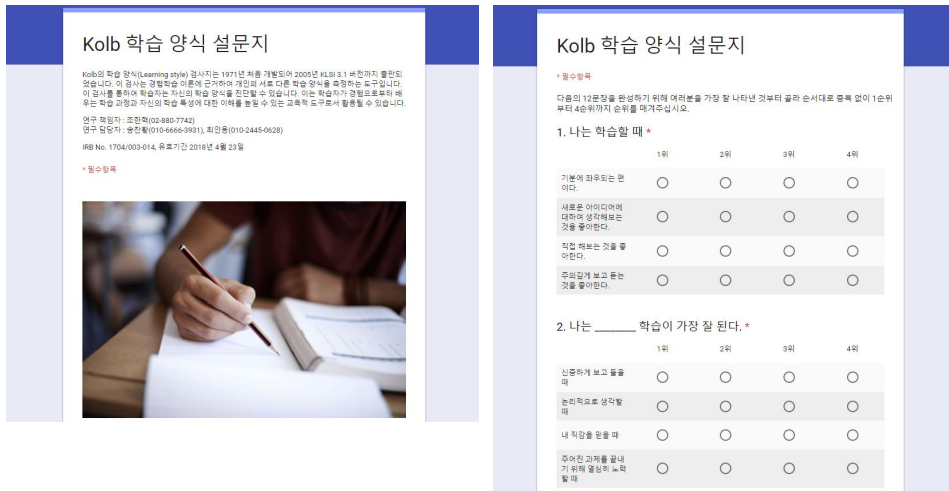
그리고 현재 Haygroup에서 판매 중인 검사지로서 현장에서 사용되고 있다. 온라인 검사지는 Version 4까지 출시되었다.

그리고 KLSI에 대한 연구들이 다양하게 존재한다. 1971-1999년에 걸쳐 ELT/LSI간 일치도를 통해서 KLSI의 유효성(validity)을 확인했으며 내적 타당도 근거와 외적 타당도 근거 또한 연구들에서 나타난다. 이와 같은 3가지 측면들을 종합적으로 검토할 때 KLSI는 본 연구에서 학습 양식을 검사하기에 적절한 도구라고 판단하였다.

그러나 한국에서 KLSI를 실시하는 것에 어려운 점은 원문이 영어로 되어 있다는 점이다. 검사지를 자체적 번역하여 시행하는 과정에서 검증된 검사 도구의 특성들이 의도치 않게 변하게 될 가능성이 있다.

이에 임세영 외(2012)는 Kolb 학습유형검사를 번역하여 한국어 버전 검사를 개발하였다. 영어의 한글번역 작업과 번역된 검사도구의 적합성을 검증하였는데 1차로 영어→한국어 번역을 하고 다시 한국어→영어로 번



역을 하여 원저자인 Kolb에게 송부하였다. 원저자가 동의할 때까지 이를 반복하고 Spertbert 외(1994)의 7점 척도 평가 결과가 4.0 이하인 문항은 제거한 뒤 다시 처음부터 번역, 재번역 작업을 반복하여 Kolb LSI의 한글 버전을 개발하였다. 그리고 K 대학교 596명을 대상으로 KLSI의 한글 버전을 실시한 결과 그 신뢰도와 타당도에 무리가 없음이 나타났다. 이에 본 연구에서는 임세영 외(2012)에서 개발한 KLSI 한국어 버전 설문지의 문장을 Google 설문지로 옮겨 작성하였다. 다만 학생들이 배점을 헛갈리지 않도록 한국어 버전과 다르게 응답 방식을 Kolb의 원본과 마찬가지로 가장 선호하는 것을 1위로 하고 가장 선호되지 않는 것을 4위로 응답하게 하였다. 학생들의 응답 결과는 제출 시 온라인 서버에 저장되고 사후에 이를 Excel 파일로 저장하여 분석하였다.



[그림 IV-2] KLSI 구글 설문지



### 1.3.2. Raven의 누진행렬검사(Raven's Advanced Progressive Matrices)



[그림 IV-3] APM 문항 예시

APM은 기본적으로 상단에 3x3 크기의 과제가 제시되고 우측 하단의 빈칸에 알맞은 도형을 8개 중 고르는 선다형 패턴 추론 문제이다. 특히 상위능력 집단을 변별해주는 비언어성 지능검사로써 기하학적인 도형 과제를 통해 추상적 관계추론 능력 즉, 복잡한 상황을 이해하는 능력, 주어진 사태의 의미를 도출하는 능력, 분명하게 지각하고 사고하는 능력을 측정한다(Abedel-Khalek & Raven, 2006).

APM은 심리측정학 및 인지심리분야에서 엄격히 연구된 몇 안 되는 검사도구 가운데 하나로서 시간과 비용 측면에서 교육적 활용도가 높다. 김혜진 외(2008)에 따르면 APM은 일반지능검사를 대체하여 간편하게 사용할 수 있는 사회경제적인 영향이 최소화된 지능검사임을 경험적으로 확인하였다. APM의 도형추론지능은 K-WISC-III로 측정된 일반지능과 유의미한 상관관계가 있었으며 성별과 사회경제적 지위에 따라 차이가 없는 것으로 확인되었다. 또한 APM 점수는 학업성취도와 유의미한 상관관계가 있는 것으로 나타났다.

학교 현장에서 뇌파 연구를 도입하기 위해 본 연구에서는 학생들이 해결해야 할 인지 과제의 선정이 매우 중요한 문제이다. 수학 교수와 학습의 실행 장면에서 나타나는 실제 수학 문제(예. 교과서 예제)를 해결하는 도중에 뇌파를 측정하여 학생들에게 피드백을 제공하는 것은 수학 교육 신경과학의 최종 목표이기는 하나 본 연구에서 뇌파 분석의 인지과제로 사용하는 것은 아직 이르다고 판단하였다. 신경 과학의 영역에서 APM과 뇌파의 관계는 선행 연구들이 존재하고, APM 자체도 오랜 시간 동안 엄격히 연구되어 그 타당성을 인정받고 있는바 뮤즈를 이용하여 APM을 해결하는 학습자의 뇌파를 측정하여 분석하는 것은 신뢰성을 확보할 수 있을 것으로 기대한다.

본 연구에서 사용된 APM 검사지는 1998년에 표준화된 것이다. APM은 총 Set I 12문항과 Set II 36문항으로 구성되어 있다. Set I은 5분으로서 사전에 공개해서 사용해도 좋은 연습 문제이다. APM Set II의 맞은 문제수에 따라 0~36점의 점수를 얻을 수 있고 이 점수를 이용하여 규준과 비교하여 지능을 판단한다. 검사의 실시는 시간제한 없이 실시하는 최대능력검사와 40분의 시간제한이 있는 속도검사 2가지 형태가 있다. 영재들을 판별하기 위해서는 시간제한 없이 해결할 수 있는 가장 어려운 문항의 수준이 어느 정도 인지 확인하는 최대능력 검사가 주로 실시된다. 문항을 해결하는 과정에서 학생들이 겪는 어려움의 수준을 뇌파로 확인하는 것이 본 연구의 목적이므로 시간제한 없이 검사를 실시하기로 결정하였다.

APM의 대중성과 그동안 드러난 강점들에도 불구하고 APM 실시에 있어서 큰 제약점은 시간의 문제이다. 특정 실험 설계에서 이러한 40분 이상의 검사 시간은 큰 부담으로 작용하는데 이는 뇌파에서도 마찬가지이다. APM의 36문항을 모두에 대해 뇌파 측정을 실시하는 실험 설계는 부담이 크다. 뇌파 장비를 착용한 채로 40분 이상, 시간제한 없이 검사를 실시하는 과정에서 학생들의 피로, 과제로부터 이탈(disengagement), 의욕 상실, 몸 상태의 변화에 따른 뇌파의 변화 등이 연구 결과를 오염시킬 수 있기 때문이다.

이러한 시간 제약의 단점을 극복하기 위해 APM의 short version을 개발하기 위한 체계적 연구들이 수행되었다. Arthur, Day(1994)는 36문항을 3문항씩 12섹션으로 등분할하고 각 섹션에서 문항과 전체 검사 간 상관도가 가장 높은 문항을 1개씩 골라내어 12문항을 추려내었다. 이렇게 만들어진 축소 버전의 내적 합치도(alpha=.65)는 원본(alpha=.86)보다 약간 낮았으며 둘 사이의 상관계수는 .66으로 나타났다. Arthur, Tubre, Paul, Sanchez-Ku(1999)는 Arthur, Day에 의해 제안된 12문항에 대하여 1506명의 대학생을 대상으로 표준 데이터를 제공한다.

Bors and Stokes(1998)는 문항-전체 검사 간 상관 분석을 통해 모든 문항을 순서대로 정렬하고 각 항목의 문항 간 상관관계를 기준으로 24개 항목을 제거하여 12개 문항을 선별하고 506명의 학생에 대해 실시하여 Vicker's et al.(1972)의 IT task와 APM 원본 간의 상관 계수 -.48, IT task와 축소 버전 간의 상관 계수 -.42임을 밝힘으로서 축소 버전의 신뢰성과 타당성을 검증하였다.

<표 IV-1> 축소 버전에 사용된 APM 문항 번호

선행 연구	문항 번호
Arthur and Day(1994)	1, 4, 8, 11, 15, 18, 21, 23, 25, 30, 31, 35
Bors and Stokes(1998)	3, 10, 12, 15, 16, 18, 21, 22, 28, 30, 31, 34


이에 본 연구에서는 두 버전을 비교, 검토한 뒤 Bors and Stokes(1998)의 12문항을 사용하기로 하였다.

## 2. 뇌파와 APM 분석 결과

학생코드 s1~s33의 총 33명의 대상 학생 가운데 s13은 KLSI만 참여하고 뇌파 녹화 세션에는 동의하지 않아 참여하지 않았으며, s27은 동의는 했으나 개인 사정으로 모든 실험에 참여하지 않았다. 따라서 s13, s27 2명은 뇌파 데이터가 없는 관계로 모든 뇌파 분석에서 제외한다. 결과적으로 데이터의 수집은 총 31명을 대상으로 이루어졌다. EO, EC 상태 뇌파 데이터는 31명 모두 정상적으로 수집되었으며 APM 과제 수행 뇌파는 4명 s4, s5, s7, s11의 데이터가 수집 과정에서 손상되었다. 손상된 4명의 APM 뇌파 데이터를 재수집하는 것은 학습 효과로 인해 데이터 분석 결과를 왜곡할 수 있다고 판단되어 다시 시행하지 않았다. KLSI의 설문은 대상 학생 31명의 데이터가 모두 정상적으로 기록되었다.

따라서 뇌파 데이터와 APM 과제 사이의 데이터 분석에는 27명의 데이터가 이용되며 EO, EC 상태의 뇌파와 KLSI 간의 데이터 분석에는 31명의 데이터가 이용되었다.

### 2.1. 뇌파와 APM 사이의 Spearman의 상관 분석




[그림 IV-4] 문항번호에 따른 학생 반응시간 평균

APM 검사는 총 12문항으로 시간제한이 없는 형태로 실시되었다. 공인 난이도의 경우 문항 번호가 증가할수록 어려운 것으로 알려져 있는데 학생들의 반응 시간(response time)을 살펴보면 뒷 번호로 갈수록 소요 시간이 길어지는 경향이 있는 것을 그래프로 확인할 수 있다. 학생들이 Raven 검사 12문항을 해결하는데 평균적으로 349.38초가 소요되었다.

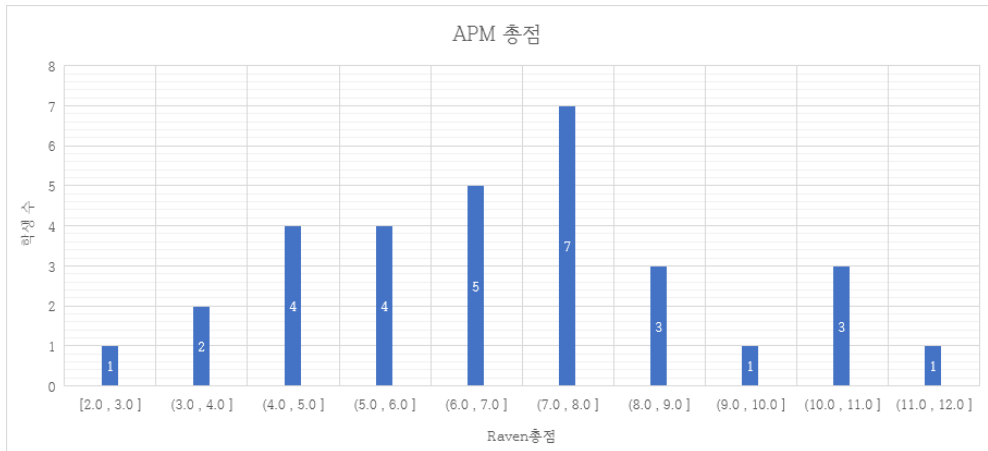
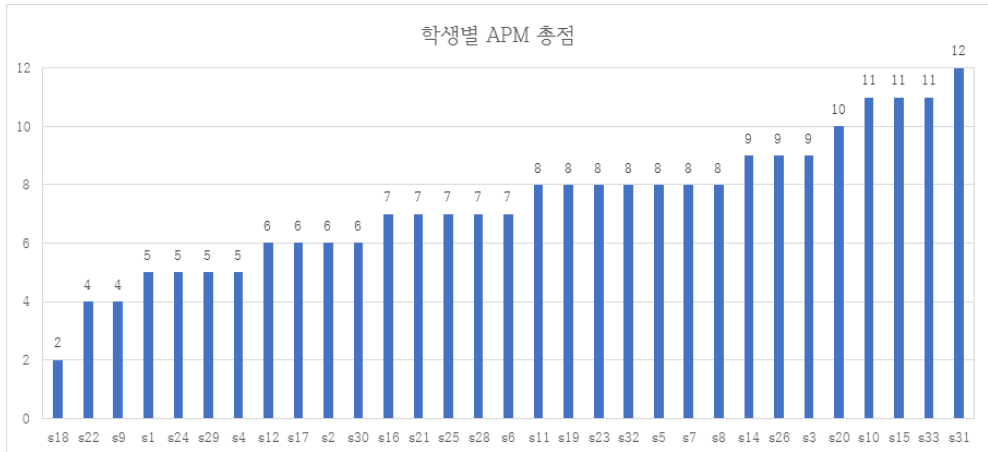
<표 IV-2> 문항 번호별 오답률

문항번호	1	2	3	4	5	6	7	8	9	10	11	12
학생 오답률	16%	32%	3%	39%	6%	26%	52%	19%	77%	61%	52%	84%
공인 오답률	12%	23%	14%	17%	24%	32%	42%	24%	37%	57%	62%	69%
난도	저 난도				중 난도				고 난도			



[그림 IV-5] 문항 번호별 오답률

27명 학생의 오답률을 문항별로 계산하여 보면 편차가 있으나 뒷번호로 갈수록 오답률이 증가하는 것을 확인할 수 있다. 이에 문항 난도의 분류는 공인 난이도를 기준으로 1~4번 문항을 저 난도, 5~8번 문항을 중 난도, 9~12번 문항을 고 난도 문항으로 분류하였다.



[그림 IV-6] 학생별 APM 총점과 히스토그램

학생별 APM 총점을 살펴보면 2~12점까지 분포한다. 이러한 분포를 바탕으로 학생 그룹은 3그룹으로서 총점을 기준으로 하여 저FI(2점~5점) 6명(s18, s22, s9, s1, s24, s29), 고FI(9점~12점) 5명(s20, s10, s15, s33, s31), 나머지 20명의 학생들 중FI(6점~8점)로 분류하였다.

뇌파 데이터는 각 학생들이 12문항의 문제를 해결하는 동안 TP9, AF7, AF8, TP10의 4개 전극에서 기록되었으며 각 문항에 대한 반응 시간, 정오답, 총점, 난도 등이 함께 기록되었다.

본 연구에서는 절대 뇌파를 이용하여 분석을 진행하였다. 절대 뇌파는 상대 뇌파와 대비되는 개념으로 Raw data에 FFT를 적용하여 각 채널별로 획득된 absolute 값을 가리킨다. 분석에 사용된 뇌파 대역의 구분은 다음과 같다.

<표 IV-3> 분석에 사용된 뇌파 대역

이름	주파수 대역
델타파( $\delta$ , delta absolute)	1-4 Hz
세타파( $\theta$ , theta absolute)	4-8 Hz
알파파( $\alpha$ , alpha absolute)	8-12 Hz
베타파( $\beta$ , beta absolute)	12-30 Hz
감마파( $\gamma$ , gamma absolute)	30-50 Hz

학생들이 각 문항을 해결하는 도중에 측정된 뇌파와 반응 시간, 정오답, 총점, 난도 사이의 상관 분석을 실시하고 상관관계가 확인된 뇌파에 대하여 분산 분석을 실시한다. 그리고 EO, EC 뇌파와 총점 사이에 상관 분석과 회귀 분석을 실시한다.

먼저 최적의 FFT 윈도우의 크기와 오버랩의 정도를 결정하기 위해 FFT 윈도우 크기를 변화시키면서 뇌파와 반응 시간, 정오답, 총점, 난도 사이의 상관 분석을 실시한다. 상관 분석은 나이와 혈압, 허리둘레와 체중과 같이 두 관측치들 사이의 관계, 특히 연속형 자료들 사이의 관계를 분석하는 것이다. Pearson의 상관 분석은 대표적인 상관분석법으로 두 연속형 자료중 적어도 한 개는 정규성을 갖는 다는 가정을 전제로 한다. 표본수가 30 이상이라면 정규성 검정 없이도 이 방법을 적용할 수 있지만 27명으로 표본수가 적고 정규 분포를 가정할 수 없으므로 이변량 상관계수 Spearman의 상관 분석을 양측 유의성 검정으로 시행한다.

결론적으로 FFT 윈도우의 크기와 오버랩에 따라서 상관관계가 나타나는지 여부와 그 크기가 다르게 나타났다. 정오답, 총점, RT, 난도를 모두 가장 잘 드러내는 유일한 FFT 윈도우와 오버랩의 크기는 찾을 수 없었다. 정오답, 총점, RT, 난도와 뇌파 사이의 상관 계수의 크기는 FFT 윈도우와 오버랩의 크기에 따라서 다르게 나타났다.


FFT 윈도우의 크기를 변화시키면서 FFT 주기는 0.5초로 일정하게 고정하였을 때를 살펴본다. 정오답-뇌파 사이의 상관 계수를 살펴보면 윈도우 크기가 커질수록 설명력이 증가한다. 그러나 총점의 경우에는 그 반대의 경향이 나타난다. RT의 경우에는 뇌파와 상관성이 윈도우 크기에 따라 선형적으로 나타나지 않고 3, 4초 일 때 상관계수의 크기가 크게 나타난다.



[그림 IV-7] FFT 윈도우 크기에 따른 상관도의 차이



난도에 따른 뇌파의 차이의 경우 AF7 세타파의 경우에는 윈도우 크기가 5초일 때 상관계수가 제일 크지만 TP9 베타, 감마파의 경우 오히려 5초일 때 상관 계수의 절댓값이 소폭 감소한다. 즉, 5종류의 윈도우 크기와 뇌파와의 상관표를 모두 조사하였을 때 모든 관측 변수에 통용되는 최적의 윈도우 크기는 존재하지 않는다는 것이 결론이다. 목적 변수에 따라서 최적의 윈도우 크기는 다르다.



[그림 IV-8] 오버랩 크기에 따른 상관도의 차이

이는 향후 뮤즈의 뇌파 데이터를 이용한 BCI, Neurofeedback과 같은 장면에서도 마찬가지로 생각된다. 이것은 BCI 게임에서 집중 시알파파와 베타파를 사용한다면 상황에 따라 집중을 가장 잘 드러내는 윈도우 길이를 직접 찾아서 적용해야 함을 의미한다. 윈도우 길이와 뇌파(4x16) 64가지의 모든 상관관계를 종합적으로 고려하였을 때 Raven 과제 수행과 뇌파와의 상관관계(정오답, 총점, RT, 난도와 뇌파와의 상관관계)를 종합적으로 가장 잘 나타내는 윈도우 크기는 3초로 판단하였다.

그리고 나서 FFT 윈도우 크기를 3초로 고정한 뒤에 오버랩을 변화시키면서 이변량 상관계수 Spearman의 상관 분석을 양측 유의성 검정으로 시행하였다. 오버랩을 0.5초~2.5초일 때 5가지 경우에 대하여 상관 분석을 실시한 결과 윈도우 크기와 마찬가지로 관측 변수와 뇌파에 따라서 유일한 오버랩을 찾을 수는 없다.

Raven 과제 수행과 뇌파와의 상관관계를 종합적으로 고려하여 오버랩 2초를 분석에 사용하기로 결정하였다. 결과적으로 윈도우 크기 3초, 오버랩을 2초로 FFT를 적용한다. 이는 FFT를 매 1초마다 계산하는 것과 같다. 그러면 이 경우에 총 768개의 데이터를 이용하여 FFT를 계산하며  $f_0$ 는 1.67Hz이 된다. 따라서 1~4 Hz에 해당하는 델타파의 일부가 소실되고 델타파는 잡음 등의 아티팩트가 흔하게 발생하는 e대역으로 알려져 있으므로 델타파는 이후 분석에서 사용하지 않는다. 이 때 주파수 해상도는 0.33Hz가 되어 뇌파 분석에 문제가 없는 수준이며 시간 해상도 또한 3이므로 Raven 인지 과제 수행 상의 뇌파를 분석하는 데 충분할 것으로 판단된다.

이와 같은 분석 결과에 따라 윈도우 크기 3초, 오버랩을 2초로 FFT를 적용하고 Spearman의 상관 분석을 양측 유의성 검정으로 시행하였다.

<표 IV-4> Spearman의 상관 분석 결과

정오답	세타	알파	베타	감마
TP9	-0.063	-0.041	0.021	0.011
AF7	-.151**	-.124*	-0.089	-0.071
AF8	-0.051	-0.034	-0.042	-0.038
TP10	-0.071	-0.055	-0.031	-0.021

RT	세타	알파	베타	감마
TP9	-.144**	-.114*	-.113*	-.124*
AF7	.113*	-0.057	-.146**	-.134*
AF8	-0.035	-.122*	-0.099	-.126*
TP10	-.160**	-.138*	-0.105	-0.101

난도	세타	알파	베타	감마
TP9	-0.017	-0.062	-.115*	-.131*
AF7	.138*	-0.033	-0.063	-0.068
AF8	0.027	-0.067	-0.063	-0.082
TP10	-0.029	-0.069	-0.103	-.116*

총점	세타	알파	베타	감마
TP9	-.317**	-.238**	-0.076	-0.098
AF7	-.249**	-.260**	-.238**	-.247**
AF8	-.177**	-.234**	-.196**	-.252**
TP10	-.331**	-.252**	-.141*	-.146**

\* p=.05, \*\* p=.01 양측

정오답 여부의 경우 문제를 맞춘 경우에 AF7 세타파와 알파파가 감소하였다. 그리고 반응 시간이 길어질수록 TP9 세타, 알파, 베타, 감마파가 감소하였다. AF7 세타파는 소폭 증가하였으며 베타파와 감마파는 감소하였다. AF8 알파파와 감마파는 감소하였으며 TP10의 세타, 알파파 또한 감소하였다. 문항 난도에 따라 TP9 베타파와 감마파는 감소하였다. AF7 세타파는 증가하였으며 TP10 감마파는 감소하였다.

뇌파와 가장 큰 상관관계를 보여주는 것은 총점이다. 총점은 APM 검사 중 맞은 문항의 개수로서 유동 지능과 관련된다. TP9 세타, 알파파가 감소했으며 AF7 세타, 알파, 베타, 감마파가 감소하였다. 그리고 AF8 세타, 알파, 베타, 감마파가 감소하였으며 TP10의 세타, 알파, 베타, 감마파가 감소하였다. 총점의 경우 모든 전극의 세타, 알파파가 유의하게 음의 상관관계를 보여주었다. 이것은 총점이 높은 학생일수록 뇌파의 절대 크기가 작은 것을 보여주는 것으로 신경 효율성(Neural efficacy) 이론의 결과와 부합하는 것으로 해석할 수 있다. 하지만 상관 계수의 크기가 전반적으로 크지 않아 큰 영향을 미친다고 말하기는 어렵다. 즉, 연관성은 분명히 나타나지만 연관성의 정도가 크지 않다고 할 수 있다.

## 2.2. 뇌파와 APM 사이의 대응 표본 T검정

정오답시 AF7 세타파에 대하여 대응표본 T검정을 실시한다. 이를 통해 정답, 오답 인 경우 뇌파가 유의하게 차이가 나타나는지 확인할 수 있다. 그러나 자료의 숫자가 적고 정오답 뇌파가 정규분포를 따른다고 볼 수 없으므로 비모수적인 방법으로 Wilcoxon signed rank test를 시행하였다.

<표 IV-5> Wilcoxon 부호 순위 검정 결과

Wilcoxon 부호 순위 검정				
순위				
		N	평균 순위	순위합
정답-오답	음의 순위	19	15.68	298.00
	양의 순위	8	10	80.00
	등순위	0		
	전체	27		
검정 통계량 <sup>a</sup>				
		정답-오답		
	Z	-2.619b		
	근사 유의확률(양측)	.009		
a. Wilcoxon 부호 순위 검정				
b. 양의 순위를 기준으로.				

AF7 알파과도 마찬가지로의 결과를 보여주었다. 따라서 문제를 맞추었을 경우 AF7 세타과와 알파과가 유의하게 감소하는 것으로 볼 수 있다.

### 2.3. 뇌파와 Raven 총점 사이의 다중 회귀 분석

뇌파의 16개의 독립변수를 이용하여 총점(Score)의 종속 변수를 예측할 수 있는지를 추정하기 위하여 다중회귀분석을 시행하였다. 이를 이용하여 각각의 개별 독립 변수들의 실질적인 영향의 정도를 분석할 수 있다. 종속변수에 영향을 미치는 독립 변수들이 결정되면 각각의 독립 변수가 종속 변수에 미치는 영향의 크기를 비교할 수 있다. 표준화 회귀 계수의 절댓값을 비교하여 여러 독립 변수들 가운데 가장 영향력이 큰 변수를 발견하고자 하였다. 16개의 뇌파 독립 변수로 시작하여 단계 선택법에 따라 독립 변수를 추가하거나 제거하면서 최종 모형을 결정하였다.

<표 IV-6> 다중회귀분석 모형 선택 결과

모형 요약 f					
모형	R	R 제곱	수정된 R제곱	추정값의 표준오차	Durbin-Watson n
1	.333a	.111	.108	2.3348112	
2	.430b	.185	.180	2.2392451	
3	.474c	.225	.218	2.1865375	
4	.503d	.253	.243	2.1504220	
5	.515e	.265	.254	2.1356542	.315
a. 예측자: (상수), AF7알파					
b. 예측자: (상수), AF7알파, TP10베타					
c. 예측자: (상수), AF7알파, TP10베타, AF7감마					
d. 예측자: (상수), AF7알파, TP10베타, AF7감마, TP10세타					
e. 예측자: (상수), AF7알파, TP10베타, AF7감마, TP10세타, AF8세타					
f. 종속변수: Raven 총점					

단계 선택법에 의해 회귀 모형은 모형5에서 결정되었다. 모형5의 설명력은 0.265로 총점은 모형5의 회귀식에 의해 26.5%만큼 설명될 수 있다.

<표 IV-7> 다중회귀분석 ANOVA 결과

ANOVAa						
모형		제곱합	자유도	평균제곱	F	유의확률
5	회귀	523.818	5	104.764	22.969	.000f
	잔차	1450.404	318	4.561		
	전체	1974.222	323			
a. 종속변수: Raven 총점						
f. 예측자: (상수), AF7알파, TP10베타, AF7감마, TP10세타, AF8세타						

최종 선택된 모형 5는 분산 분석에 의해 유의수준  $p < 0.000$ 로 유의하다. 포함된 변수들의 VIF가 10 이상인 변수가 없으므로 다중공선성은 없는 것으로 판단한다.

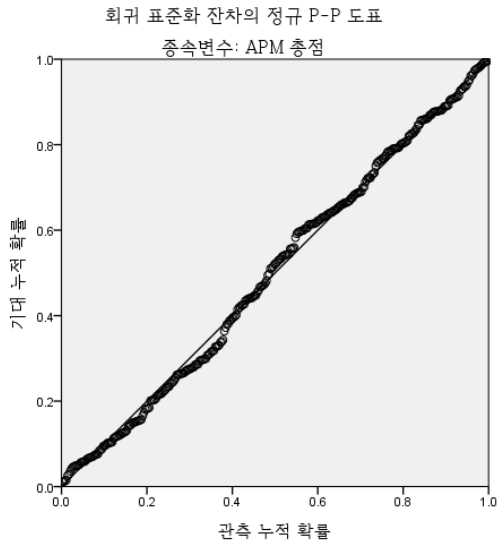
<표 IV-8> 다중회귀분석 계수

계수a								
모형		비표준화 계수		표준화 계수	t	유의확률	공선성 통계량	
		B	표준오차	베타			공차	VIF
5	(상수)	7.022	.797		8.807	.000		
	AF7알파	-6.854	1.951	-.301	-3.513	.001	.316	3.168
	TP10베타	9.939	1.315	.621	7.556	.000	.342	2.922
	AF7감마	-4.133	.820	-.475	-5.039	.000	.260	3.848
	TP10세타	-3.327	.816	-.268	-4.079	.000	.535	1.871
	AF8세타	2.861	1.228	.141	2.330	.020	.627	1.594
a. 종속변수: Raven 총점								

추정된 회귀식은 다음과 같다.

$$\text{Score} = 7.022 - 6.854 \times \text{AF7알파} + 9.939 \times \text{TP10베타} - 4.133 \times \text{AF7감마} - 3.327 \times \text{TP10세타} + 2.861 \times \text{AF8세타}$$

회귀 계수가 가장 큰 것은 TP10베타(9.939,  $p=.000$ )로 나타났다. AF7알파, AF7감마, TP10세타와의 크기가 작을수록 총점의 크기가 크게 나타났으며 TP10베타, AF8세타의 크기가 클수록 총점이 크게 나타났다.



[그림 IV-9] 총점의 회귀 표준화 잔차

총점의 잔차 또한 관측된 확률에 거의 근접하여 증가하고 있으므로 정규성을 보여주고 있다고 볼 수 있다.

## 2.4. 뇌파와 난도 사이의 반복측정 분산분석

저, 중, 고 3가지 난도에 따른 TP9 감마파의 변화에 대하여 반복측정 분산분석을 실시하였다. 총점에 따라 성취그룹을 저FI, 중FI, 고FI 3개로 나누고 그룹별로 변화의 차이가 있는지도 살펴본다.

개체 내 요인으로 난도를 입력하고 개체 내 변수로 3가지 난도를 개체 간 요인으로 성취 그룹을 주고 주효과 비교에 신뢰구간 조정 방법으로 Bonferroni를 선택하였다. Mauchly의 구형성 가정이 성립하지 않으므로 Greenhouse-Geisser, Huynh-Feldt 검정 통계량을 이용한다.

<표 IV-9> 반복측정 분산분석 효과 검정

개체-내 효과 검정						
측도 : TP9 감마						
소스		제 III 유형 제공합	자유도	평균제곱	F	유의확률
난도	구형성 가정	.516	2	.258	6.914	.002
	Greenhouse-Geisser	.516	1.368	.378	6.914	.007
	Huynh-Feldt	.516	1.543	.335	6.914	.005
	하한	.516	1.000	.516	6.914	.015
난도 * 성취그룹	구형성 가정	.082	4	.020	.548	.702
	Greenhouse-Geisser	.082	2.735	.030	.548	.637
	Huynh-Feldt	.082	3.086	.027	.548	.658
	하한	.082	2.000	.041	.548	.585
오차(난도)	구형성 가정	1.792	48	.037		
	Greenhouse-Geisser	1.792	32.824	.055		
	Huynh-Feldt	1.792	37.038	.048		
	하한	1.792	24.000	.075		




그 결과 난도의 효과 검정에서는 유의 확률이 .007, .005이므로 난도에 따른 뇌파의 변화가 있다고 할 수 있다. 그리고 난도\*성취그룹은 유의하지 않으므로 성취 그룹의 난도에 따른 뇌파 변화는 다르다고 볼 수 없다. 개체-내 대비 검정 결과 난도에 따른 뇌파 변화는 선형 모형(.008), 이차 모형(.609)이므로 선형 모형에 가깝다고 볼 수 있다.

<표 IV-10> 반복측정 분산분석 대응별 비교

대응별 비교						
측도 : TP9 감마						
(I) 난도	(J) 난도	평균차이(I-J)	표준오차	유의확률b	차이에 대한 95% 신뢰구간b	
					하한	상한
1	2	.094	.058	.353	-.055	.243
	3	.221*	.076	.023	.026	.416
2	1	-.094	.058	.353	-.243	.055
	3	.127*	.040	.011	.025	.229
3	1	-.221*	.076	.023	-.416	-.026
	2	-.127*	.040	.011	-.229	-.025
추정 주변 평균을 기준으로						
*. 평균차이는 .05 수준에서 유의합니다.						
b. 다중비교를 위한 수정: Bonferroni						

난도는 저 난도 : 1, 중 난도 : 2, 고 난도 : 3으로 코딩하였다. 난도에 따른 뇌파 차이는 저 난도와 중 난도의 차이는 통계적으로 확인되지 않았다. 그러나 고난도의 경우에는 저 난도, 중 난도와 TP9 감마파의 감소가 통계적으로 유의미하게 나타난다. 저 난도와 중 난도의 차이는 유의 확률 .353이나 고 난도는 .011, .023으로 저 난도, 중 난도에 비해 TP9 감마파가 감소한 것으로 볼 수 있다.

앞서 상관분석에서 살펴본 것과 같이 문항 난도가 증가함에 따라 TP9 베타파와 감마파, TP10 감마파는 감소하였다. AF7 세타파는 증가하였다.




[그림 IV-10] 성취 그룹별 TP9 감마의 반복측정 분산 분석 그래프

난도에 따른 뇌파의 변화는 성취 그룹별로 다르게 나타날지 살펴보았다. 저FI(Low), 중FI(Middle), 고FI(High) 집단별로 난도에 따른 뇌파의 변화를 살펴보면 그래프 상으로는 고FI 그룹에서 난도가 어려워짐에 따라 TP9 감마파가 더욱 감소한 것으로 보일 수 있다. 하지만 통계적으로 유의미한 수준으로 난도에 따른 뇌파의 차이는 집단별로 다르게 나타나지 않았다.

### 3. 뇌파와 KLSI 분석 결과

<표 IV-11> 학생 KLSI 채점 결과

학생코드	CE	AC	RO	AE	KLSI 분류
1	34	25	20	41	4
2	24	26	30	40	4
3	27	44	27	22	2
4	19	41	36	24	2
5	27	26	23	44	4
6	38	25	17	40	4
7	23	42	29	26	2
8	23	43	35	19	2
9	20	40	27	33	2
10	24	39	33	24	2
11	35	27	19	39	4
12	21	36	25	38	4
14	19	37	30	34	2
15	24	30	24	42	4
16	30	33	36	21	3
17	31	26	21	42	4
18	32	41	20	27	2
19	24	32	27	37	4
20	18	39	25	38	2
21	25	28	25	42	4
22	30	25	28	37	4
23	15	33	31	41	4
24	22	35	31	32	2
25	18	37	39	26	3
26	24	30	26	40	4
28	25	40	20	35	2
29	30	27	34	29	3
30	38	28	24	30	1
31	27	45	18	30	2
32	27	36	20	37	4
33	22	32	26	40	4



[그림 IV-11] KSLI 분류 결과

총 31명의 EO, EC 상태 뇌파 데이터와 KLSI 사이의 관계를 분석하였다. 구체적인 경험(concrete experience: CE), 사려 깊은 관찰(reflective observation: RO), 추상적인 개념화(abstract conceptualization: AC), 적극적인 실험(active experimentation: AE)를 각각 CE : 1그룹, AC : 2그룹, RO : 3그룹, AE : 4그룹으로 코딩하였다. KLSI 구글 설문지를 엑셀을 이용하여 채점하였다. 그 결과 1그룹 1명, 2그룹 12명, 3그룹 3명, 4그룹 15명으로 나타났다. 1, 3그룹에 해당하는 학생이 적고 대부분의 학생들이 2, 4그룹에 해당한다.

### 3.1. EO 상태 뇌파 분석

Rashid(2011)에 보면 EC, EO 상태의 뇌파 중 특히 알파파를 이용하여 Kolb의 학습 양식을 100% 정확도로 구별해냈다. 따라서 EC 뇌파와 EO 뇌파를 이용하여 상관 분석과 회귀 분석을 통해 학습 양식과 관련성이

나타나는지 확인하도록 한다.

총 31명의 데이터를 이용하여 분석하였으며 KLSI의 4개 분야 구체적 경험, 추상적 개념화, 반성적 성찰, 능동적 실험을 각각 CE : 1그룹, AC : 2그룹, RO : 3그룹, AE : 4그룹으로 코딩하였다.

독립된 세 군 이상의 뇌파의 크기를 비교하기 위하여 일원 배치 분산 분석을 시행한다. 그러나 1그룹은 단 1명임에 따라 통계 분석을 진행할 수 없었기 때문에 1그룹은 데이터에 분석에 사용하지 않기로 하였다. 그리고 나머지 3개의 그룹 2,3,4 에 대해서 일원 배치 분산 분석을 시행하였다.

<표 IV-12> 일원 배치 분산 분석 기술 통계량

기술통계									
		N	평균	표준 편차	표준 오차	평균에 대한 95% 신뢰구간		최소 값	최대 값
						하한	상한		
AF8 베타	2.00	12	-.3253	.15216	.04393	-.4220	-.2287	-.57	-.12
	3.00	3	-.5710	.09118	.05264	-.7975	-.3445	-.63	-.47
	4.00	15	-.4129	.16007	.04133	-.5015	-.3243	-.66	-.15
	전체	30	-.3937	.16462	.03006	-.4552	-.3322	-.66	-.12
AF8 감마	2.00	12	-.3786	.18752	.05413	-.4978	-.2595	-.68	-.10
	3.00	3	-.6810	.13918	.08035	-1.0268	-.3353	-.76	-.52
	4.00	15	-.4910	.19591	.05058	-.5995	-.3825	-.86	-.19
	전체	30	-.4651	.20363	.03718	-.5411	-.3890	-.86	-.10
TP10 감마	2.00	12	-.3383	.17988	.05193	-.4526	-.2240	-.58	.11
	3.00	3	-.4624	.30026	.17335	-1.2082	.2835	-.71	-.13
	4.00	15	-.5195	.17129	.04423	-.6143	-.4246	-.85	-.19
	전체	30	-.4413	.20062	.03663	-.5162	-.3664	-.85	.11

<표 IV-13> 일원 배치 분산 분석 결과

다중비교								
종속변수			평균차 이(I-J)	표준오 차	유의확률	95% 신뢰구간		
						하한	상한	
AF8 베타	Tukey HSD	2.00	3.00	.24567*	.09860	.049	.0012	.4901
			4.00	.08756	.05916	.316	-.0591	.2342
		3.00	2.00	-.24567*	.09860	.049	-.4901	-.0012
			4.00	-.15811	.09661	.248	-.3976	.0814
		4.00	2.00	-.08756	.05916	.316	-.2342	.0591
			3.00	.15811	.09661	.248	-.0814	.3976
AF8 감마	Tukey HSD	2.00	3.00	.30238*	.12190	.050	.0001	.6046
			4.00	.11238	.07314	.290	-.0690	.2937
		3.00	2.00	-.30238*	.12190	.050	-.6046	-.0001
			4.00	-.19000	.11944	.267	-.4861	.1061
		4.00	2.00	-.11238	.07314	.290	-.2937	.0690
			3.00	.19000	.11944	.267	-.1061	.4861
TP10 감마	Tukey HSD	2.00	3.00	.12402	.12089	.567	-.1757	.4238
			4.00	.18113*	.07253	.048	.0013	.3610
		3.00	2.00	-.12402	.12089	.567	-.4238	.1757
			4.00	.05711	.11845	.880	-.2366	.3508
		4.00	2.00	-.18113*	.07253	.048	-.3610	-.0013
			3.00	-.05711	.11845	.880	-.3508	.2366

\*. 평균차이는 0.05 수준에서 유의합니다.

뇌파는 Levene의 등분산 가정을 모두 만족하므로 Tukey의 다중 비교법을 적용하였다. 이 때 AF8 베타파, AF8 감마파는 2, 3그룹 간에만 차이가 나타났으며 4그룹과는 유의미한 차이를 확인할 수 있는 그룹이 없었다. 3그룹의 학생수가 3명밖에 되지 않으므로 3그룹을 데이터에서 제거하고 2, 4 그룹에 대해서만 Mann-Whitney 테스트를 시행하였다. 검정 변수로 뇌파를, 집단 변수로 2, 4 그룹을 지정한 다음 순위합을 이용하여 독립 2-표본 비모수 검정을 시행하였다.

<표 IV-14> Mann-Whitney 테스트 결과

	TP10 감마
Mann-Whitney의 U	38.000
Wilcoxon의 W	158.000
Z	-2.537
근사 유의확률(양측)	.011
정확 유의확률[2*(단측 유의확률)]	.010

그 결과 TP10 감마파만 학습 양식 2, 4 그룹 간에 유의미한 뇌파 차이가 나타났다.

Pearson의 상관 분석은 대표적인 상관분석법으로 두 연속형 자료중 적어도 한 개는 정규성을 갖는다는 가정을 전제로 한다. 표본수가 31로 30 이상이므로 정규성 검정 없이 이 방법을 적용하였다. 그러나 총점과 학습양식과 EO 상태 뇌파사이의 Pearson 상관 분석 결과에서 어떠한 상관도 유의미하게 나타나지 않았다.

### 3.2. EC 상태 뇌파 분석


EO 상태 뇌파 분석과 마찬가지로 1그룹은 단 1명으로 통계 분석이 진행되지 않아 제외하고 2,3,4 그룹에 대해서 독립된 세 군 이상의 크기를 비교하는 방법인 일원 배치 분산 분석을 시행하였다. 그럼에도 불구하고 그룹 간에 통계적으로 유의미하게 차이가 나는 뇌파는 없었다.

그리고 총점과 학습양식과 EC 상태 뇌파사이의 Pearson 상관 분석 결과 어떠한 상관도 유의미하게 나타나지 않았다.


종합하면 뮤즈를 이용한 배경뇌파 상태의 뇌파는 유동 지능, KLSI와 상관관계가 거의 나타나지 않았으며 뇌파 분석에서 EO AF8베타, AF8감마, TP10감마의 일부 그룹 간 평균 차이가 나타났으나 1그룹 1명, 2그룹 12명, 3그룹 3명, 4그룹 15명으로서 일부 그룹의 학생 수가 매우 적고 그룹 간 학생 수의 차이가 커 결과 해석에 한계가 존재하였다.

## V. 머신러닝에의 응용

### 1. K-means clustering




[그림 V-1] EC, EC 상태 뇌파의 2차원 그래프



[그림 V-2] k=2인 경우 K-means clustering 분류 결과





[그림 V-3] k=3인 경우 K-means clustering 분류 결과

EO, EC 상태의 베타, 감마파가 K-means clustering 기법을 이용하여 우연 수준(chance level)인 33.3%, 50% 이상의 정확도로 분류할 수 있는 뇌파로 나타났다. 31명의 학생의 EO, EC 상태에 대해서 좌, 우뇌의 베타 파와 감마파를 2차원 좌표 상에 점으로 나타냈다.  $(x, y) = (\text{AF7 베타}, \text{AF8 베타})$ ,  $(x, y) = (\text{AF7 감마}, \text{AF8 감마})$ 와 같이 베타파와 감마파를 각각 총 62개(31명 \* 2)의 점으로 이루어진 이차원 분포로 나타낸 것이 [그림 V-1]이다. 그리고 k=2를 이용하여 K-means clustering 기법을 적용한 것이 [그림 V-2]이고 k=3일 때가 [그림 V-3]이다.

이러한 클러스터링 기법은 BCI(Brain computer interface)에 연결될 수 있다. 로봇을 예를 들면 뇌파를 머신러닝으로 자동적으로 분류된 클러스터에 따라 로봇의 특정 명령과 연동시킬 수 있는 것이다. 머신 러닝을 이용하여 EO 상태의 뇌파에 로봇이 왼쪽으로 가도록 하고 EC 상태의 뇌파에 로봇이 오른쪽으로 가도록 할 수 있다는 것이다.

<표 V-1> k에 따른 클러스터링 정확도

		베타과	감마과
k=2	반응률	100%	100%
	정확도	83.87%	82.25%
k=3	반응률	66.13%	88.71%
	정확도	91.96%	91.94%

k=2인 경우 한 번의 FFT로 계산된 뇌파는 EC, EO 상태로 클러스터링 된다. 그리고 분류에 따라 바로 로봇이 왼쪽으로 움직이거나 오른쪽으로 움직이도록 한다. 이 때 로봇의 반응률은 뇌파가 계산될 때마다 반응하므로 100%가 된다. 로봇의 반응 정확도는 EC, EO 실제 상태와 그 분류의 일치도이다. 눈을 감았는데 뜬 것으로 판별한다거나 눈을 뜨고 있는데 눈을 감은 것으로 판별하는 경우이다. 정확도는 베타파를 사용하였을 경우 83.87%, 감마파를 사용하였을 경우 82.25%이다.


k=3인 경우 중간 지대를 만들어서 뇌파가 중간 분류에 해당되는 경우에는 로봇이 움직이지 않도록 한다. 즉, 판단이 교차할 수 있는 우범 지대의 경우에 로봇 명령을 연동시키지 않는 것이다. 따라서 뇌파가 EC, EO의 중간 지대에 해당하는 경우에는 로봇이 반응하지 않도록 하기 때문에 로봇의 반응률은 베타파를 사용했을 때 66.13%, 감마파를 사용했을 때 88.71%로 k=2인 경우보다 떨어진다. 그러나 일부 경우에 반응하지 않는 대신 더욱 확실한 경우에만 로봇 명령이 작동하므로 로봇 반응 정확도는 k=2일 때보다 높아지게 된다. 이는 베타파를 사용한 경우 91.96%, 감마파를 사용한 경우 91.94%이다.

Rashid(2011)의 선행 연구에서는 뇌파를 이용하여 KLSI의 4가지 학습 양식을 100%로 분류할 수 있었지만 뮤즈를 이용하여 뇌파로 KSLI를 분류할 수 없었다. 4개의 학습 양식을 가진 학생 그룹 간에 뇌파 차이를 확인할 수 없었다.

## 2. 신경망

Feedforward 인공 신경망의 하나인 멀티레이어 퍼셉트론(Multilayer perceptron, MLP)를 이용하여 분석을 진행하였다. 신경망을 사용하는 경우에는 적절한 알고리즘의 선택과 함께 입력 노드수(input nodes), 계층 수(layers), 은닉 노드수(hidden\_nodes), 출력 노드수(output\_nodes), 학습률(learning rate), 학습 횟수(epochs) 변수를 결정해야 한다. 입력 노드수는 입력 벡터의 원소수로서 4개 전극에서 델타파를 제외하고 세타, 알파, 베타, 감마 4개 뇌파를 사용하므로  $4 \times 4 = 16$ 이 된다. 계층 수는 대다수의 데이터의 경우에 3 계층으로 충분함이 알려져 있으므로 3 계층을 사용한다. 출력 노드 수는 신경망이 결과로 내놓는 원소의 수이다. 정오답의 경우 2, EO vs EC의 경우 2, 난도의 경우 저, 중, 고 난도로 3이 된다. 은닉 노드의 수는 정답은 없지만 보통 입력 노드와 출력 노드의 사잇값이 적당하다. 대체적으로 입력 노드 수의  $2/3$ 에 출력 노드수를 더하여 사용하면 적당하다고 알려져 있으므로 12개의 은닉 노드를 사용하였다. 학습률과 학습 횟수는 데이터 분석 과정에서 직접 적절한 값을 찾아보았다.


### 2.1. EO, EC 상태 신경망



[그림 V-4] 학습률과 학습 횟수에 따른 신경망 성능

31명의 EO, EC 상태 뇌파의 평균값 62개\*12채널을 신경망에 학습시켜 테스트하였다. 학습률에 따른 신경망의 성능을 테스트한 결과 0.6~0.8의 학습률이 좋은 성능을 보여주었다. 이에 0.6의 학습률로 학습 횟수를 변화시키면서 성능을 관찰한 결과 3000회부터 신경망 성능은 100%에 이르렀다. 3계층 멀티레이어 퍼셉트론을 이용하여 EO, EC를 잘 구별할 수 있음을 알려준다. 출력 노드가 2개인 경우 0, 1로 코딩하는 것보다 -1, 1로 코딩하는 것이 좋다.

## 2.2. 난도와 신경망




[그림 V-5] 학습률과 학습 횟수에 따른 신경망 성능

31명의 12개 문항의 난도에 따른 뇌파의 평균값 372개\*12채널을 신경망에 학습시켜 테스트하였다. EPOCHS를 100, 500으로 두고 2가지 경우에 대해 학습률에 따른 신경망의 성능을 테스트한 결과 0.2의 학습률이 좋은 성능을 보여주었다. 이에 0.2의 학습률로 학습 횟수 1000~29000까지 변화시키면서 성능을 관찰한 결과 학습 횟수가 증가할수록 신경망의 성능 또한 향상되는 경향이 있었다. 31명의 모든 학생의 데이터를 이용한 신경망의 경우 학습 횟수 23000에서 최고 성능 71.91%를 보여주었으며 그 이상으로 학습 횟수를 더 늘려도 성능은 하락하였다.

이에 같은 조건에서 Raven 총점 기준 고FI 집단과 저FI 집단으로 나누어 집단별로 신경망을 학습시키고 성능을 테스트 하였다. 모든 변수가 동일할 때에는 고FI 집단에 대한 신경망 성능이 상대적으로 더 좋게 나타났다. 학습 횟수 23000~25000에서 최고 96.67%의 성능을 보여주었다. 저FI 집단의 경우에도 신경망은 학습 횟수 27000에서 최소 90.28%의 성능을 보여주었다.

### 2.3. 정오답과 신경망



[그림 V-6] 학습률과 학습 횟수에 따른 신경망 성능

31명의 12개 문항의 정오답 여부에 따른 뇌파의 평균값 372개\*12채널을 신경망에 학습시켜 테스트하였다. 학습 횟수를 1000으로 두고 학습률에 따른 신경망의 성능을 테스트한 결과 0.9의 학습률이 가장 좋은 성능을 보여주었다. 하지만 0.9는 과학습(오버 피팅)의 위험이 있어 0.2의 학습률로 학습 횟수 1000~29000까지 변화시키면서 성능을 관찰한 결과 마찬가지로 학습 횟수가 증가할수록 신경망의 성능 또한 향상되는 경향이 있었다. 31명의 모든 학생의 데이터를 이용한 신경망의 경우 학습 횟수 21000에서 최고 성능 82.41%를 보여주었다.

이에 같은 조건에서 Raven 총점 기준 고FI 집단과 저FI 집단으로 나누어 집단별로 신경망을 학습시키고 성능을 테스트 하였다. 모든 변수가 동일할 때에는 고FI 집단에 대한 신경망 성능이 상대적으로 더 좋게 나타났다. 학습 횟수 210000에서 최대 100%의 성능을 보여주었다. 저FI 집단의 경우에 신경망은 학습 횟수 27000에서 최대 91.67%의 성능을 보여주었다.

### 3. 논의

휴대용 EEG 장비로 기록된 뇌파를 이용하여 머신러닝에 적용하여도 유용한 수준의 성능이 나타남을 확인할 수 있었다. 하지만 동시에 머신러닝의 한계점도 분명히 존재하며 체계적인 확인 연구가 필요함을 인식하여야 한다. 기본적으로 머신 러닝은 매 실행마다 예외적인 상황이 발생할 수 있음을 이해해야 한다. 특히 K-means clustering의 경우 비지도 학습으로서 초깃값에 따라 클러스터링의 효과가 많이 달라질 수 있다. 예를 들어 k=3인 경우 초깃값 centroid 세 점이 모두 몰린 경우 모든 데이터가 단 하나의 클러스터로 분류될 수도 있다. 따라서 초기 centroid를 데이터의 분포에 따라 적절히 분배하여 선택할 수 있도록 알고리즘을 보완한다면 K-means clustering의 예외성을 줄일 수 있을 것이다.

신경망의 경우에는 지도 학습으로 그 정확성이 K-means clustering에 비해 더 높았다. 다만 매우 많은 연산으로 인해 컴퓨터의 성능에 따라 신경망 학습 시간이 많이 소요된다는 점은 단점이다. 따라서 실전에서 신경망을 사용할 경우 학습 시간까지 고려한 인풋노드 수, 학습 수를 결정하여 사용해야 할 필요성이 있다. 별도의 테스트 데이터를 마련하지 못하여 학습에 사용된 데이터를 이용하여 신경망 성능을 테스트 하여 성능의 과대 평가 가능성에 유의하여야 한다. 신경망의 신뢰할 수 있는 성능을 확인하기 위한 목적으로 학습 데이터와 테스트 데이터를 체계적으로 수집한 뒤 신경망 성능을 평가할 필요성이 있다.

## VI. 결론 및 제언

### 1. 결론

본 연구의 결과를 통해 다음과 같은 결과를 얻을 수 있다.

첫째, 휴대용 EEG 장비를 이용하여 실시간으로 뇌파를 측정하고 데이터를 전송하여 기록할 수 있었으며 파이썬을 이용하여 뇌파 데이터에 대한 신호처리를 진행하고 뇌파 분석을 시행할 수 있었다. 뇌파 분석 시 APM 과제에 대한 적절한 FFT 윈도우 크기, 오버랩은 관측 변수에 따라 모두 다르게 나타났다. 즉, 단 하나의 최적 FFT 윈도우 크기, 오버랩은 존재하지 않았지만 APM 과제에 대한 전반적으로 적절한 FFT 윈도우 크기는 3초, 오버랩은 2초로 나타났다.

둘째, APM 수행 중의 뇌파 분석 결과 APM 문항의 난도, 정오답, RT와 학생의 APM 총점에 따라 APM 수행 중의 뇌파에 유의미한 차이가 나타났다. 정오답 여부의 경우 문제를 맞힌 경우에 AF7 세타파와 알파파가 감소하였다. 그리고 반응 시간이 길어질수록 TP9 세타, 알파, 베타, 감마파가 감소하였다. AF7 세타파는 소폭 증가하였으며 베타파와 감마파는 감소하였다. AF8 알파파와 감마파는 감소하였으며 TP10의 세타, 알파파 또한 감소하였다. 문항 난도에 따라 TP9 베타파와 감마파는 감소하였다. AF7 세타파는 증가하였으며 TP10 감마파는 감소하였다.

뇌파와 가장 큰 상관관계를 보여주는 것은 총점이었다. 총점은 Raven 검사 중 맞은 문항의 개수로서 유동 지능과 관련된다. TP9 세타, 알파파가 감소했으며 AF7 세타, 알파, 베타, 감마파가 감소하였다. 그리고 AF8 세타, 알파, 베타, 감마파가 감소하였으며 TP10의 세타, 알파, 베타, 감마파가 감소하였다. 총점의 경우 모든 전극의 세타, 알파파가 유의하게 음의 상관관계를 보여주었다. 이것은 총점이 높은 학생일수록 뇌파의 절대

크기가 작은 것을 보여주는 것으로 신경 효율성(Neural efficiency) 이론(Thatcher, 2016)의 결과와 부합하는 것으로 해석할 수 있다.

상관관계를 바탕으로 추가적으로 비모수적인 방법으로 Wilcoxon signed rank test를 시행한 그 결과 오답일 때보다 해당 문제를 맞힌 경우에 AF7 세타파와 알파파가 유의하게 감소하는 것으로 나타났다.

그리고 총점에 대한 다중 회귀 분석을 실시한 결과 총점에 대해 회귀 계수가 가장 큰 것은 TP10 베타(9.939,  $p=0.000$ )로 나타났다. AF7 알파(-6.854), AF7 감마(-4.133), TP10 세타파(-3.327)의 크기가 작을수록 총점의 크기가 크게 나타났으며 TP10 베타(+9.939), AF8 세타(+2.861)의 크기가 클수록 총점이 크게 나타났다.

또한 뇌파와 난도 사이의 반복측정 분산분석 결과 난도에 따라 뇌파의 감소가 나타났다. 하지만 고난도의 경우에만 저, 중 난도와 다른 뇌파의 차이가 나타났으며 저, 중 난도 간에는 유의미한 뇌파 차이가 확인되지 않았다. 난도에 따른 뇌파의 변화는 성취 그룹 저FI(Low), 중FI(Middle), 고FI(High)에 따라 고FI 집단이 더 큰 변화를 보여주었으나 유의미한 수준으로 나타나지는 않았다.

하지만 뇌파와 KLSI는 연관성을 찾기 어려웠다. KLSI 그룹들에 대해서 일원 배치 분산 분석을 시행한 결과 EO상태의 뇌파에 대해 AF8 베타파, AF8 감마파는 2, 3그룹 간에만 차이가 나타났으며 4그룹과는 유의미한 차이를 확인할 수 있는 그룹이 없었다. 2, 4 그룹에 대해서 Mann-Whitney 테스트를 시행한 결과 하였다. 검정 변수로 뇌파를, 집단 변수로 2, 4 그룹을 지정한 다음 순위합을 이용하여 독립 2-표본 비모수 검정을 시행한 결과 TP10 감마파만 학습 양식 2, 4 그룹간에 유의미한 뇌파 차이가 나타났다. EC상태의 뇌파는 유의미한 차이가 나타나지 않았다. Pearson의 상관 분석에서도 EO, EC 상태 모두 뇌파와 KLSI 간에 유의미한 상관이 나타나지 않았다.

셋째, 휴대용 EEG 장비로 기록된 뇌파를 이용하여 머신러닝에 적용하여도 유용한 수준의 성능이 나타남을 확인할 수 있었다. 머신러닝을 이



용한 뮤즈 뇌파 분류 시스템은 효과적으로 작동하였다. K-means clustering은 EO, EC 상태를 비지도(unsupervised) 방법으로 k=2인 경우 최고 84%, k=3인 경우 최고 92%의 정확도로 판별해낼 수 있었다. 이러한 클러스터링 기법은 BCI(Brain computer interface)에 연결될 수 있다. 그리고 멀티레이어 퍼셉트론 신경망을 이용한 분류의 경우 뇌파를 학습하기 위해 적절한 학습률은 0.2 ~ 0.3으로 나타났다. 학습 횟수의 경우 더 많이 학습할수록 대체적으로 신경망의 성능이 향상되는 것으로 나타났다. 하지만 시간이 많이 소요된다는 단점과 오버 피팅의 위험이 따른다는 것을 유의해야 한다. 신경망을 이용한 EO, EC 상태의 분류는 가장 적은 데이터와 학습 횟수로도 100%의 성능을 보여주었다. 이는 EO, EC 상태가 뇌파로 명확히 구분할 수 있는 상태임을 의미한다. 신경망을 이용한 과제 난도 분류는 최고 72%의 성능을 보여주었다. 그리고 신경망을 이용한 정오답 분류는 최고 82%의 성능을 보여주었다. 즉, APM 과제 수행시의 뇌파를 이용한 신경망 분류는 우연 수준 이상의 성능을 보여줌으로써 효과적인 것으로 나타났다. 휴대용 뇌파 장비를 이용하여 측정된 뇌파로도 머신 러닝을 활용한 상태 변별의 가능성이 존재함을 확인한 것이다. 하지만 이를 실제로 응용하려면 추가적으로 체계적인 검증이 필요할 것으로 생각된다.

## 2. 제언

본 연구를 바탕으로 휴대용 EEG 장비에 관하여 다음과 같은 후속 연구가 필요하다.

첫째, 휴대용 EEG 장비와 전문 EEG 장비를 비교하는 연구가 필요하다. 휴대용 EEG 장비로 획득되는 뇌파들이 문항의 난도나 정오답 여부에 따라서 유의미하게 다르게 나타난 것으로 확인되기는 했지만 이와 같은 뇌파가 전문 EEG장비로 획득한 뇌파와 비교했을 때 그 신뢰성이 어느 정도인지 규명하는 후속 연구가 필요하다.

둘째, 휴대용 EEG를 이용한 뇌파의 유의미한 차이가 나타나는 경우

그 신호원이 무엇인지를 규명할 수 있는 후속 연구가 필요하다. 본 연구는 전극 센서 수준에서 데이터 분석을 시행하였으며 뇌파 차이의 원인을 밝히지 못했다. 신호원 수준의 뇌파 분석을 위해서는 많은 수의 전극을 요구되지만 sLORETA 등 신호원(source) 수준의 뇌파 분석을 시도해볼 필요가 있다.

셋째, STEAM의 관점에서 생체 신호를 학습 내용으로 도입하는 것에 대한 교육 연구가 요구된다. 교수학적 변환을 통해 뇌파 측정 - 분석 - 머신러닝 - BCI 일련의 과정을 종합 프로그램으로서 학생들이 체험하고 학습할 수 있는 적절한 수준으로 재개발하는 것이다. 수학, 과학, 프로그래밍 등이 종합적으로 요구되는 이러한 탐구 활동은 4차 산업 혁명 시대의 역량 있는 인재들을 키우는 데 적합한 활동이 될 수 있다.

넷째, 본 연구는 수학 교육 연구에서 뇌파를 활용한 연구 방법론의 문턱을 낮추고 뇌파의 활용가능성을 제시하였지만 체계적인 신호 처리 방법과 머신 러닝 적용 등에서 한계가 있었다. 이를 보완하기 위해서는 뇌파 측정 과정에서 신호 처리 이론을 바탕으로 근전도와 눈 깜박임 등의 제거를 사전에 충분히 고려하여야 한다. 그리고 머신 러닝에의 적용 또한 트레이닝, 테스트 데이터를 어떻게 수집하여 사용할 것인지 먼저 체계적으로 결정한 뒤에 데이터를 수집하여야 한다.

종합적으로 본 연구는 휴대용 EEG 장비를 활용함으로써 EEG 연구가 교육 연구와 학교 현장에 확산될 수 있는 가능성을 높일 수 있도록 기여한다는 측면에서 의의가 있다. 앞으로 뇌파를 활용한 연구가 수학 교육 연구의 다양한 영역으로 확산될 수 있기를 기대한다.

## 참고문헌

- 고상숙, 이창연(2016). 비심리적 처치프로그램에 의한 고등학생 수학불안집단 간의 뇌파 연구. *수학교육*, 55(3), 383-396.
- 권석원(2009). 생명현상 관찰에서 과학적 의문 생성의 신경 생리적 경로 모델 개발 : MEG연구. 한국교원대학교 대학원 박사학위 논문.
- 김남희(2013). 개방형 문제 해결 과정에서 수학 영재아와 일반아의 뇌파 활성 분석. 한국교원대학교 대학원 석사학위논문.
- 김두정(2010). 뇌 과학 : 학교 교육과 교육과정의 시사점. *교육과정연구*, 28(3), 127-145.
- 김재용(2005). *신경학*. 서울대학교출판문화원.
- 김종진(2016). 심적 회전 과제에서의 뇌파 측정 및 분석을 위한 EEG 실험 환경 설계. 서울대학교 대학원 석사학위논문.
- 김형원(2017). 연산문제 해결 시 수학 교구가 두뇌 활성화에 미치는 영향. 한국교원대학교 대학원 석사학위논문.
- 김혜진, 설현수(2008). Advanced Progressive Matrices의 도형추론지능과 일반지능간의 관계 및 배경 변인 분석. *교육평가연구*, 21(2), 141-164.
- 서혁, 김지희, 편지윤, 신윤하(2016). 문제 해결 상황에서 독자의 눈동자 움직임 및 뇌파 특성 분석: 독해력 수준에 따른 독자의 과제집착력. *독서연구*, 38, 225-254.
- 석영민(2015). 뇌 기반 측정을 통하여 나타난 수학불안증의 특징 : 함수적 과제를 중심으로. 단국대학교 대학원 석사학위논문.
- 윤은정(2014). 수학불안에 관한 국내외 연구의 동향 및 과제 -인지신경기법을 중심으로-. *학습자중심교과교육연구*, 14(1), 295-314.
- 윤희현, 이종구(2008). 규칙의 유형과 수에 따른 Raven 검사의 문항 난이도. 한국심리학회 학술대회 자료집. 2008(1), 292-293.
- 이승주(2017). 안구 운동을 통한 공간 과제 해결 과정 분석 - 실행식의 효과를 중심으로. 서울대학교 대학원 석사학위논문.
- 이은지(2017). 전개도 접기 과제의 해결전략 연구 : 안구 운동 분석을 활용하여. 서울대학교 대학원 석사학위논문.
- 이지운(2015). 3D 입체 변별 과제에서 공간 인지 전략의 유형과 역할 - 체화된 3D 거북 표현식과 전략을 중심으로. 서울대학교 대학원 박사학위논문.
- 임세영, 이병철, 최현숙, 안미선, 이웅일(2012). Kolb학습유형검사의 한글버전 개발,

- 한국실천공학교육학회논문지, 4, 30-44.
- 전덕임(1995). Raven progressive matrices검사의 한국판 개발을 위한 예비연구. 충북대학교 대학원 석사학위논문.
- 전명남(2004). kolb-McCarthy 학습유형에 따른 심층학습의 차이. 교육심리연구, 18(4), 279-292.
- 진복희(2011). 임상생리학 뇌파(Electroencephalogram). 서울: 고려의학.
- 진복희, 박선영(2005). 신경생리를 배우는 사람들을 위하여. 서울: 고려의학.
- 최속기(2016). 아이트래커를 활용한 중학생의 다문서 읽기 양상 분석. 독서연구, 39, 159-191.
- 최인용, 조한혁 (2016). 순열 조합 이해 과제에서의 안구 운동 추적 연구. 수학교육학연구, 26(4), 635-662.
- 한세호, 고상숙(2016). 심리적 처치프로그램에서 고등학교 학생들의 뇌파반응에 따른 수학불안의 변화. 수학교육학연구, 26(2), 205-224.
- Kolb, A. Y. & Kolb, D. A.(2005). "The Kolb Style Inventory-Version 3.1 2005 Technical Specifications," ed. Boston, USA: Hay Resources Direct.
- Ansari, D. & Coch, D. (2006). Bridges over troubled waters: education and cognitive neuroscience. Trends Cogn. Sci. 10, 146-151.
- Armanfard, N., Komeili, M., Reilly J. P. & Pino, L.(2016). Vigilance lapse identification using sparse EEG electrode arrays. Canadian Conference on Electrical and Computer Engineering(CCECE), Vancouver, BC, 1-4.
- Arthur, W. Jr., & Day, D. V. (1994). Development of a short form for the Raven Advanced Progressive Matrices Test. Educational and Psychological Measurement, 54, 394-403. Bilker, W. B., Brensinger, C., Kurtz, M. M., Kohler, C., Gur, R. C., Arthur, W. Jr., Tubre, T. C., Paul, D. S. & Sanchez-Ku, M. L. (1999). College-sample psychometric and normative data on a short form of the raven advanced progressive matrices test. Journal of Psychoeducational Assessment, 17, 354-361.
- Bashivan, P., Rish, I. & Heisig, S. (2016). Mental state recognition via wearable EEG. arXiv preprint arXiv:1602.00985.
- Belsky, J. (1990). The psychology of aging: Theory, research, and interventions. Pacific Grove, CA: Brooks/Cole Publishing Company.
- Bors, D. A., & Stokes, T. L. (1998). Raven's Advanced Progressive Matrices:

- Norms for first-year university students and the development of a short form. *Educational and Psychological Measurement*, 58, 382-398.
- Brody, N. (1992). *Intelligence* (2nd ed.). New York: Academic Press.
- Bruer, J. T. (1997). Education and the brain: A bridge too far. *Educational Researcher*, 26(8): 4-16.
- Campbell, J. I. D. (Ed.) (2004). *The handbook of mathematical cognition*. New York: Psychology Press.
- Campbell, S. R. & Dawson, A. J. (1995). Learning as embodied action, in R. Sutherland, & J. Mason (Eds.) *Exploiting mental imagery with computers in mathematics education* (pp. 233- 249). Berlin, Heidelberg: Springer-Verlag.
- Campbell, S. R. (2001). Enacting possible worlds: Making sense of (human) nature. In J. F. Matos, W. Blum, S. K. Houston, & S. P. Carreira, *Modelling and mathematics education* (pp. 1-14). Chichester, UK: Horwood Publishing.
- Campbell, S. R. (2006). Defining mathematics educational neuroscience. In S. Aatorre, J. L. Cortina, M. Saiz, & A. Mendez (Eds.), *PMENA*, 2, 442-449, Merida, Mexico: Universidad Pedagogica Nacional.
- Campbell, S. R. (2010). Embodied minds and dancing brains: New opportunities for research in mathematics education. In *Theories of mathematics education*, 309-331. Springer Berlin.
- Carroll, J. B. (1993). *Human Cognitive abilities. A survey of factor-analytic studies*. Cambridge: Cambridge University Press.
- Cook, B. G. & Schirmer, B. R. (2003). What is special about special education? *Overview and Analysis*, 37, 200-205.
- Davis, R. B. (1984). *Learning mathematics: The cognitive science approach to mathematics education*. Norwood, NJ: Ablex.
- de Vos, M., Gandras, K., & Debener, S. (2014). Towards a truly mobile brain computer interface: exploring the P300 to take away. *Int. J. Psychophysiol.* 91, 46-53.
- DeBello, T. C. (1990). Comparison of Eleven major Learning Styles Model : Variables, Appropriate populations, Validity of Instrumentation and the research behind them. *Journal of Reading, Writing, and Learning Disabilities*, 6, 203-222.
- Debener, S., Minow, F., Emkes, R., Gandras, K. & de Vos, M. (2012). How about

- taking a low-cost, small, and wireless EEG for a walk? *Psychophysiology* 49, 1617-1621.
- Dehaene, S. (1997). *The number sense: How the mind creates mathematics*. New York, NY: Oxford University Press.
- Dehaene, S., Spelke, E., Pine, P., Stanescu, R. & Tsivkin, S. (1999). Sources of mathematical thinking: Behavioral and brain-imaging evidence. *Science*, 284, 970-974.
- Duvinage, M., Castermans, T., Petieau, M., Hoellinger, T., Cheron, G. & Dutoit, T. (2013). Performance of the Emotiv Epoc headset for P300-based applications. *Biomed. Eng. Online* 12:56.
- Eisenhart, M. & Dehaan, R. L. (2005). Doctoral preparation of scientifically based education researchers. *Educational Researcher*, 34, 3-13.
- Fuchs, D., Fuchs, L. S. & Stecker, P. M. (2010). The “blurring” of special education in a new continuum of general education placements and services. *Exceptional Children*, 76(3), 301-323.
- Fuchs, D., Fuchs, L. S. & Vaughn, S. (2014). What is intensive instruction and why is it important?. *Teaching Exceptional Children*, 46(4), 13-18.
- Gordon, J. A. & Hen, R. (2004). Genetic approaches to the study of anxiety. *Annual Review of Neuroscience*, 27, 193-222.
- Gramann, K., Ferris, D. P., Gwin, J. & Makeig, S. (2014). Imaging natural cognition in action. *Int. J. Psychophysiol.* 91, 22-29.
- Grouws, D. A. (1992). *Handbook of research on mathematics teaching and learning: A project of the National Council of Teachers of Mathematics*. New York: Macmillian. Hopko,
- Holyoak, K. J. & Morrison, R. G.(2005). *The Cambridge Handbook of Thinking and Reasoning*. Cambridge University Press.
- Jackendoff, R. (1987). *Consciousness and the computational mind*. Cambridge, MA: MIT Press.
- Karydis, T., Aguiar, F., Foster, S. L. & A. Mershin(2015). Performance characterization of self-calibrating protocols for wearable EEG applications, *Proceedings of the 8th ACM International Conference on Pervasive Technologies Related to Assistive Environments*, July 01-03, Corfu, Greece.

- Kaufmann, L., Handl, P., & Thony, B. (2003). Evaluation of a numeracy intervention program focusing on basic numerical knowledge and conceptual knowledge: A pilot study. *Journal of Learning Disabilities*, 36, 564-573.
- Kolb, D. A. (1976). *Learning Style Inventory*. Boston, MA: Hay Group, Hay Resources Direct.
- Kolb, D. A., Rubin, I. M. & McIntyre, J. (1971). *Organizational psychology: An experiential approach*. Englewood Cliffs, NJ: Prentice Hall.
- Krigolson, O. E., Williams, C. C., Norton, A., Hassall, C. D. & Colino, F. L.(2017). Choosing MUSE: Validation of a Low-Cost, Portable EEG System for ERP Research. *Front. Neurosci.* 11-109.
- Kuziek, J. W., Shienh, A. & Mathewson, K. E. (2017). Transitioning EEG experiments away from the laboratory using a Raspberry Pi 2. *J. Neurosci. Methods* 277, 75-82.
- Li, Z., Xu, J., Zhu, T.(2015). Prediction of Brain States of Concentration and Relaxation in Real Time with Portable Electroencephalographs. *arXiv preprint arXiv:1509.07642*.
- Luck, S. J. (2014). *An Introduction to the Event-Related Potential Technique*, 2nd Edn. Cambridge, MA: MIT Press.
- Martinez-Pons, M. (1999). Emotional intelligence as a self-regulatory process: A social cognitive view. *Imagination, Cognition & Personality* 19(4): 331-350.
- Maskeliunas, R., Damasevicius, R., Martisius, I. & Vasiljevas, M. (2016). Consumer-grade EEG devices: are they usable for control tasks? *Peer J* 4:e1746.
- Moutafi, J., Furnham, A. & Crump, J. (2006). What facets of openness and conscientiousness predict fluid intelligence score?. *Learning and Individual Differences*, 16(1), 31-42.
- Pea, R. D. (1987). *Cognitive technologies for mathematics education*. Hillsdale, NJ: LEA.
- Pfeffer, J. & Sutton, R. I. 2006. Evidence-based management. *Harvard Business Review*, 84: 62-74.
- Picton, T. W., Bentin, S., Berg, P., Donchin, E., Hillyard, S. A. & Johnson, R.(2000). Guidelines for using human event-related potentials to study cognition: recording standards and publication criteria. *Psychophysiology* 37, 127-152.

- Preusse, F., Meer, E., Deshpande, G., Krueger, F. & Wartenbruger, I.(2011). Fluid intelligence allows flexible recruitment of the parieto-frontal network in analogical reasoning. *Front. Hum. Neurosci.* 5:22.
- Rashid, N. A., Taib, M. N., Lias, S., Sulaiman, N., Murat, Z. H., Shilawani S. R. & Kadir, A. (2011), Learners' Learning Style Classification related to IQ and Stress based on EEG, *Procedia - Social and Behavioral Sciences*, 29, 1061 - 1070.
- Raven, J., Raven, J. C., & Court, J. H. (1998). Raven manual section 4: Advanced progressive matrices. Oxford, England: Oxford Psychologists Press.
- Rugg, M. D. & Coles, M. G. (1995). *Electrophysiology of Mind: Event-Related Brain Potentials and Cognition*. Oxford, UK: Oxford University Press.
- Schmidt, F. L. & Hunter, J. E.(1998). The Validity and Utility of selection methods in Personnel psychology:practical and theoretical implications of 85 years of research findings. *Psychological Bulletin*, 124(2), 262-274.
- Schoenfeld, A. H. (1987). *Cognitive science and mathematics education*. Hillsdale, NJ: LEA.
- Sierpinska, A. & Kilpatrick, J. (Eds.) (1998). *Mathematics education as a research domain: A search for identity — An ICMI Study (2 vols.)*. Dordrecht: Kluwer Academic Publishers.
- Spinath, B., Fruedenthaler, H. H. & Neubauer, A. C.(2010). Domain-specific school achievement in boys and girls as predicted by intelligence, personality and motivation. *Personality and Individual Differences*, 48(4), 481-486.
- Stanovich, P. J. & Stanovich, K. E. (2003). *Using research and reason in education: How teachers can use scientifically based research to make curricular & instructional decisions*. Washington, DC: US Department of Education.
- Stecker, P. M., Fuchs, L. S. & Fuchs, D. (2005). Using curriculum-based measurement to improve student achievement: Review of research. *Psychology in the Schools*, 42(8), 795-819.
- Swanson, H. L. (2008). Neuroscience and RTI: A complimentary role. In E. Fletcher-Janzen & C. R. Reynolds (Eds.), *Neuropsychological perspectives on learning disabilities in the era of RTI: Recommendations for diagnosis and intervention* (pp. 28-53). Hoboken, NJ: John Wiley & Sons.



- Tariq, A., Abdelrahman, A., Mohammad, H., Zuhair, B. & Nisbet, A.(2012). Information Extraction from Wireless Sensor Networks: System and Approaches *Sensors & Transducers*, 14(2), 1-17.
- Thatcher, R. W., Palmero-Soler, E., North, D. M. & Biver, C. J. (2016). Intelligence and eeg measures of information flow: efficiency and homeostatic neuroplasticity. *Scientific Reports* 6, 38890.
- Wascher, E., Heppner, H. & Hoffmann, S. (2014). Towards the measurement of event-related EEG activity in real-life working environments. *Int. J. Psychophysiol.* 91, 3-9.
- Wilson, A. J., Dehaene, S., Pinel, P., Revkin, S. K., Cohen, L. & Cohen, D.(2006): Principles underlying the design of “The Number Race“, an adaptive computer game for remediation of dyscalculia. *Behavioral and Brain Functions*, 2: 19-10.

## 부 록

### 1. converter(Musemonitor).py : Musemonitor를 이용하여 녹화한 raw data에서 뇌파 데이터를 저장

```
import numpy as np
def convert_data(path, filename):
    print("Loading EEG data: "+path+filename+".csv")
    try:
        with open(path+filename+".csv") as file:
            pass
    except IOError:
        print ( "EEG data file not found." )
        exit()
    skiprows = 1
    cols = (21,22,23,24,25)
    raw_data = []
    raw_data = np.genfromtxt(path + filename+".csv", delimiter=";", usecols=cols,
skip_header=skiprows)
    dt = np.dtype('Float64')
    raw_data = np.array(raw_data, dtype=dt)
    temp = [0,0,0,0,0]
    index = []
    for (i,v) in enumerate(raw_data):
        if temp[1] == v[1]:
            index.append(i)
        if np.isnan(v[1]):
            index.append(i)
        temp = v
    raw_data = np.delete(raw_data, index, 0)
    np.savetxt(path + "converted/" + filename + "raw.csv", raw_data, delimiter =
";,")
```

## 2. converter(MuseLab).py : MuseLab을 이용하여 녹화한 녹화한 raw data에서 뇌파 데이터를 저장

```
import numpy as np
def convert_data(path, filename):
    print("Loading EEG data: "+ path + filename + ".csv")
    try:
        with open(path+filename+".csv") as file:
            pass
    except IOError:
        print'EEG data file not found.'
        exit()
    skiprows =0
    raw_data = []
    with open(path + filename+".csv", 'rb') as csvfile:
        for row in csvfile:
            cols = row.split(',')
            if(cols[1].strip() =="/muse/eeg"):
                raw_data.append(cols[2:7])
    dt = np.dtype('Float64')
    raw_data = np.array(raw_data, dtype=dt)
    np.savetxt(path + "converted/" + filename + "raw.csv", raw_data,
    delimiter=",")
    path = "data/"
    files = [ "#input file list" ]
    for filename in files:
        convert_data(path, filename)
```

### 3. 뇌파 분석 코드

```
import numpy as np
import EEGrunt
def nextpow2(i):
    n = 1
    while n < i:
        n *= 2
    return n
def compute_feature_vector(eegdata, Fs):
    # 1. Compute the PSD
    winSampleLength, nbCh = eegdata.shape
    # Apply Hamming window
    w = np.hamming(winSampleLength)
    dataWinCentered = eegdata - np.mean(eegdata, axis=0) # Remove offset
    dataWinCenteredHam = (dataWinCentered.T*w).T
    NFFT = nextpow2(winSampleLength)
    Y = np.fft.fft(dataWinCenteredHam, n=NFFT, axis=0)/winSampleLength
    PSD = 2*np.abs(Y[0:NFFT/2,:])
    f = Fs/2*np.linspace(0,1,NFFT/2)
    # SPECTRAL FEATURES
    ind_delta, = np.where(f<4)
    meanDelta = np.mean(PSD[ind_delta,:],axis=0)
    # Theta 4-8
    ind_theta, = np.where((f>=4) & (f<=8))
    meanTheta = np.mean(PSD[ind_theta,:],axis=0)
    # Alpha 8-12
    ind_alpha, = np.where((f>=8) & (f<=12))
    meanAlpha = np.mean(PSD[ind_alpha,:],axis=0)
    # Beta 12-30
    ind_beta, = np.where((f>=12) & (f<=30))
```

```

meanBeta = np.mean(PSD[ind_beta,:],axis=0)
# Gamma 12-30
ind_gamma, = np.where((f>=30) & (f<50))
meanGamma = np.mean(PSD[ind_gamma,:],axis=0)
feature_vector = np.concatenate((meanDelta, meanTheta, meanAlpha,
meanBeta, meanGamma), axis=0)
feature_vector = np.log10(feature_vector)
return feature_vector
def compute_bandpower():
result = []
for channel in EEG.channels:
    EEG.load_channel(channel)
    EEG.get_spectrum_data()
    start_Hz =1; stop_Hz =50
    EEG.data = EEG.bandpass(start_Hz,stop_Hz)

    delta = EEG.compute_band_power(0,3.5)
    theta = EEG.compute_band_power(4,8)
    alpha = EEG.compute_band_power(8,12)
    beta = EEG.compute_band_power(12,30)
    gamma = EEG.compute_band_power(30,50)
    result.append([delta, theta, alpha, beta, gamma])

result = np.array(result, dtype='Float64')
result = result.ravel()
return result
path = "EC(0)/"
files = [ "#input file list" ]
f =open(path+'analysis.csv', 'w')
win_test_secs = input("Length of the window computing the features? (in
seconds) : ")

```

```

overlap_secs = input("Overlap step between two consecutive windows?(in
seconds) : ")
source = 'muse'
session_title = "Muse EEG Test Data"
for filename in files:
    EEG = EEGrunt.EEGrunt(path, filename, source, session_title)
    muse_eeg = np.genfromtxt(path+"s"+filename+"raw.csv", delimiter=",")
    EEG.raw_data = muse_eeg[:, :4]
    EEG.t_sec = np.arange(len(EEG.raw_data[:, 0])) / EEG.fs_Hz
    print ("\nLoading EEG data file : "+path+"s"+filename+"raw.csv")
    print ("This Session is "+str(len(EEG.t_sec)/EEG.fs_Hz)+" (seconds) long.")
    a, b = EEG.raw_data.shape
    step = EEG.fs_Hz * overlap_secs
    FFT_window = int(win_test_secs*EEG.fs_Hz)
    n=0; temp = []; sum = np.zeros(20)
    for i in np.arange(0, a - FFT_window, step):
        n += 1
        y = EEG.raw_data[int(i):int(i) + FFT_window, :]
        temp = compute_feature_vector(y, EEG.fs_Hz)
        sum += temp
    sum /= n
    for item in sum:
        f.write("%s, " %item)
    f.write("%s" % "s"+filename)
    f.write("\n")
    print (path+"s"+filename+"raw.csv has been analyzed.")
f.close()

```

#### 4. K-means clustering 코드

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
df = pd.DataFrame({#2차원 뇌파 데이터})
np.random.seed(200)
k = 3
centroids = {
    i+1: [np.random.randint(-100, 100)/100, np.random.randint(-100, 100)/100]
    for i in range(k)}
fig = plt.figure(figsize = (5, 5))
plt.scatter(df['x'], df['y'], color='k')
colmap = {1: 'r', 2: 'g', 3: 'b'}
for i in centroids.keys():
    plt.scatter(*centroids[i], color=colmap[i])
plt.xlim(-2, 2)
plt.ylim(-2, 2)
plt.show()
## Assignment Stage
def assignment(df, centroids):
    for i in centroids.keys():
        df['distance_from_{}'.format(i)] = (np.sqrt((df['x'] - centroids[i][0]) **
2 + (df['y'] - centroids[i][1]) ** 2))
    centroid_distance_cols = ['distance_from_{}'.format(i) for i in
centroids.keys()]
    df['closest'] = df.loc[:, centroid_distance_cols].idxmin(axis=1)
    df['closest'] = df['closest'].map(lambda x: int(x.lstrip('distance_from_')))
    df['color'] = df['closest'].map(lambda x: colmap[x])
    return df
df = assignment(df, centroids)
```

```

fig = plt.figure(figsize=(5, 5))
plt.scatter(df['x'], df['y'], color=df['color'], alpha=0.5, edgecolor='k')
for i in centroids.keys():
    plt.scatter(*centroids[i], color=colmap[i])
plt.xlim(-2, 2)
plt.ylim(-2, 2)
plt.show()
## Update Stage
import copy
old_centroids = copy.deepcopy(centroids)
def update(k):
    for i in centroids.keys():
        centroids[i][0] = np.mean(df[df['closest'] == i]['x'])
        centroids[i][1] = np.mean(df[df['closest'] == i]['y'])
    return k
centroids = update(centroids)
fig = plt.figure(figsize=(5, 5))
ax = plt.axes()
plt.scatter(df['x'], df['y'], color=df['color'], alpha=0.5, edgecolor='k')
for i in centroids.keys():
    plt.scatter(*centroids[i], color=colmap[i])
plt.xlim(-2, 2)
plt.ylim(-2, 2)
for i in old_centroids.keys():
    old_x = old_centroids[i][0]
    old_y = old_centroids[i][1]
    dx = (centroids[i][0] - old_centroids[i][0]) *0.75
    dy = (centroids[i][1] - old_centroids[i][1]) *0.75
plt.show()
# Repeat Assigment Stage
df = assignment(df, centroids)

```



```

# Plot results
fig = plt.figure(figsize=(5, 5))
plt.scatter(df['x'], df['y'], color=df['color'], alpha=0.5, edgecolor='k')
for i in centroids.keys():
    plt.scatter(*centroids[i], color=colmap[i])
plt.xlim(-2, 2)
plt.ylim(-2, 2)
plt.show()

```

## 5. 신경망(Neural Network) 코드

```

import numpy as np
import scipy.special
import matplotlib.pyplot
%matplotlib inline #Jupyter notebook으로 실행시 필요
class NeuralNetwork:
    def __init__(self, inputnodes, hiddennodes, outputnodes, learningrate):
        self.inodes = inputnodes
        self.hnodes = hiddennodes
        self.onodes = outputnodes
        self.wih = np.random.normal(0.0, pow(self.hnodes, -0.5), (self.hnodes,
self.inodes))
        self.who = np.random.normal(0.0, pow(self.onodes, -0.5), (self.onodes,
self.hnodes))
        self.lr = learningrate
        self.sigmoid = lambda x: scipy.special.expit(x)
    def query(self, input_list):
        inputs = np.array(input_list, ndmin=2).T
        hidden_inputs = np.dot(self.wih, inputs)
        hidden_outputs = self.sigmoid(hidden_inputs)
        final_inputs = np.dot(self.who, hidden_outputs)

```

```

        final_outputs = self.sigmoid(final_inputs)
    return final_outputs
def train(self, inputs_list, targets_list):
    inputs = np.array(inputs_list, ndmin=2).T
    targets1 = np.array(targets_list, ndmin=2).T
    hidden_inputs = np.dot(self.wih, inputs)
    hidden_outputs = self.sigmoid(hidden_inputs)
    final_inputs = np.dot(self.who, hidden_outputs)
    final_outputs = self.sigmoid(final_inputs)
    output_errors = targets1 - final_outputs
    hidden_errors = np.dot(self.who.T, output_errors)
    self.who += self.lr * np.dot((output_errors * final_outputs *
(1.0-final_outputs)), np.transpose(hidden_outputs))
    self.wih += self.lr * np.dot((hidden_errors * hidden_outputs *
(1.0-hidden_outputs)), np.transpose(inputs))

input_nodes = 20      # 인풋 노드수
hidden_nodes = 14     # 히든 노드수
output_nodes = 2      # 결과 노드 수
learning_rate = 0.3   # 학습률
epochs = 10000        # 학습 반복 횟수

NN = NeuralNetwork(input_nodes,hidden_nodes,output_nodes,learning_rate)
training_data_file =open("#학습 데이터",'r')
training_data_list = training_data_file.readlines()
training_data_file.close()
for e in range(epochs):
    for record in training_data_list:
        all_values = record.split(',')
        inputs = (np.asarray(all_values[1:])+1.5)/3.3*0.99+0.01
        targets = np.zeros(output_nodes)+0.01

```

```

    if int(all_values[0]) == -1:
        targets[0] = 0.99
    elif int(all_values[0]) == 1:
        targets[1] = 0.99
    NN.train(inputs, targets)
test_data_file = open("#테스트 데이터", 'r')
test_data_list = test_data_file.readlines()
test_data_file.close()
score = []
for record in test_data_list:
    all_values = record.split(',')
    correct_label = int(all_values[0])
    inputs = (np.asarray(all_values[1:])+1.5)/3.3*0.99+0.01
    outputs = NN.query(inputs)
    label = np.argmax(outputs)
    if label == 0: label = -1
    print("Correct label : ", correct_label, "    Neural Network label : ",
label, outputs)
    if correct_label == label:
        score.append(1)
    else:
        score.append(0)
score_array = np.asarray(score)
print("Performance = ", float(score_array.sum())/score_array.size*100, " %")

```

## Abstract

# An analysis of the EEG of learners using portable, low-cost EEG device

- Focusing on the Learning style and APM

Song, Chan Hwang

Department of mathematics Education

The Graduate School

Seoul National University

Recently, interest in evidence based instruction and data based instruction has increased. For data-based mathematics education, it is necessary to accurately diagnose the learner's condition in the teaching and learning process and to prescribe appropriate teaching according to it. Many educational researches are being carried out, and neuroscience is expected to open new possibilities for this data-based mathematics education. Cooperative research with neuroscience in general education research is becoming one of the trends, but it is hard to find much research on EEG in mathematics education research.

The purpose of this study is to construct EEG measurement and analysis system using portable, low-cost EEG and Python as a basic study of EEG research and to investigate the possibility of EEG analysis using it. Furthermore, by developing a case study of machine learning using data measured by this EEG equipment, we sought the possibility that such EEG activity can be used as learning contents in teaching and learning process at school. This study provides a proof-based view as a basic study of ‘mathematics education neuroscience’ and enables a deeper and broader understanding of mathematics teaching and learning. Especially, by using portable EEG equipment, it is easier to conduct EEG research in educational research and school.

*Keywords* : Mathematics Educational Neuroscience, EEG, Learning Style, APM, Machine Learning

*Student Number* : 2016-21565