

ISSN. 2465-8456



11

2021 November | Vol. 7

융합연구리뷰

Convergence Research Review

과학을 위한 AI? AI를 위한 신경과학!

방석영(한국과학기술연구원 뇌과학연구소 Post-Doc)

건축물 화재 시 본능적 행동 반응에 기초한 피난경로 선택 특성 연구

- 가상현실(Virtual Reality) 실험을 기반으로 -

한기성(고려대학교 도시재생협동과정 박사과정생)

CONTENTS

- 01 편집자 주
- 03 과학을 위한 AI? AI를 위한 신경과학!
- 47 건축물 화재 시 본능적 행동 반응에 기초한
피난경로 선택 특성 연구
- 가상현실(Virtual Reality) 실험을 기반으로 -



융합연구정책센터
Convergence Research Policy Center

융합연구리뷰 | Convergence Research Review
2021 November vol.7 no.11

발행일 2021년 11월 8일

발행인 김현우

발행처 한국과학기술연구원 융합연구정책센터

02792 서울특별시 성북구 화랑로 14길 5

Tel. 02-958-4977 | <http://crpc.kist.re.kr>

펴낸곳 디사플래닝 Tel. 02-6315-4600



한국과학기술연구원 융합연구정책센터에서는 매해 과학기술정보통신부와 미래융합협의회 공동으로 '융합연구 정책 Fellowship'을 개최한다. 본 공모전은 신진연구자 및 박사과정에 있는 학생들이 대상이며, 연구자들의 융합연구 역량증진과 정책연구 아이디어를 제시할 수 있는 기회 제공을 목적으로 한다.

본 11월호에서는 '2021년 융합연구정책 Fellowship'에서 선정된 최우수 및 우수작을 소개하며, 신진연구자 및 박사과정생이 4개월 동안 수행한 융합연구 내용을 살펴본다.

과학을 위한 AI? AI를 위한 신경과학!

인공지능은 4차 산업혁명 시대의 핵심 기술로 산업 전반 및 다양한 연구에 영향을 미치고 있다. 뇌 관련 연구에도 인공지능이 활용되고 있으나 적용 범위에 한계가 존재한다. 신경과학은 두뇌에 있는 신경세포 간의 다양한 구조들을 밝히고 인공지능 알고리즘의 타당성을 검증하는 데에도 활용할 수 있다. 그러나 신경과학과 인공지능은 각각 생물학, 수학이라는 개별 언어 사용으로 상호 간에 간극을 좁힐 수 있는 방법이 필요한 실정이다.

본호 1부에서는 신경과학과 인공지능 간의 거리를 좁힐 수 있는 수단으로 개발한 'AI 네트워크-온-어-칩(AI Network-on-a-Chip)'을 소개한다. 'AI 네트워크-온-어-칩'은 미세공학과 세포생물학이 융합된 '브레인-온-어-칩' 기술을 기반으로 인공신경망이라는 인공물을 모사하여 개발한 플랫폼이다. 이를 통해 인공지능 측면에서는 인공지능의 작동 기전을 생물학적으로 설명할 수 있고, 신경과학의 발전 측면에서는 인지 기전의 이해, 신경 질환 기전의 이해가 가능할 것으로 전망된다.

본 연구를 통해 개발된 'AI 네트워크-온-어-칩'이 향후 인공지능 학습을 위한 효율적인 에너지 소비 감축과 신약 개발 등에 유용하게 활용될 수 있기를 기대해 본다.

건축물 화재 시 본능적 행동 반응에 기초한 피난경로 선택 특성 연구

2021년 11월 26일자 매일안전신문에 따르면, 소방청 화재사고 통계조사 결과, 2021년 '건축 구조물'에 의한 화재사고는 12,324건으로 작년(12,582건) 대비 2.09% 감소했으나 사고로 인한 부상자 수는 901명으로 작년에 비해 172명 증가했다. 건물에서의 화재사고로 인한 인명피해를 최소화하기 위해서는 화재가 발생했을 경우에 사람들의 피난 행동, 반응을 이해하고 예측하는 것이 중요하다. 그러나 화재의 상황은 매우 다양하고 현실적으로 실제와 같은 화재 상황을 구현하여 실증하는 데에는 한계가 있기 때문에 화재 시의 행동에 대한 연구는 화재사고 현장 조사 결과와 피해자 진술 등에만 의존하고 있는 실정이다.

본호 2부에서는 캐나다 및 국내의 실험 참가자를 대상으로 가상현실(Virtual Reality) 기술을 활용하여 실시한 화재 발생 상황에서의 사용자 행동 및 반응 실험을 통해 개발한 피난 경로예측 모델을 소개한다. 본 모델 개발을 위해 본능적 피난행동 및 영향 요소를 분석함으로써 화재 발생 시 피난 경로선택 및 행동을 예측할 수 있도록 하였다.

본 연구에서 개발된 피난 경로예측 모델의 활용으로 화재 시 효율적인 도피를 유도함으로써 화재사고로 발생하는 인명피해를 최소화할 수 있기를 기대해 본다.

융합연구리뷰

Convergence Research Review 2021 November vol.7 no.11



01

과학을 위한 AI? AI를 위한 신경과학!

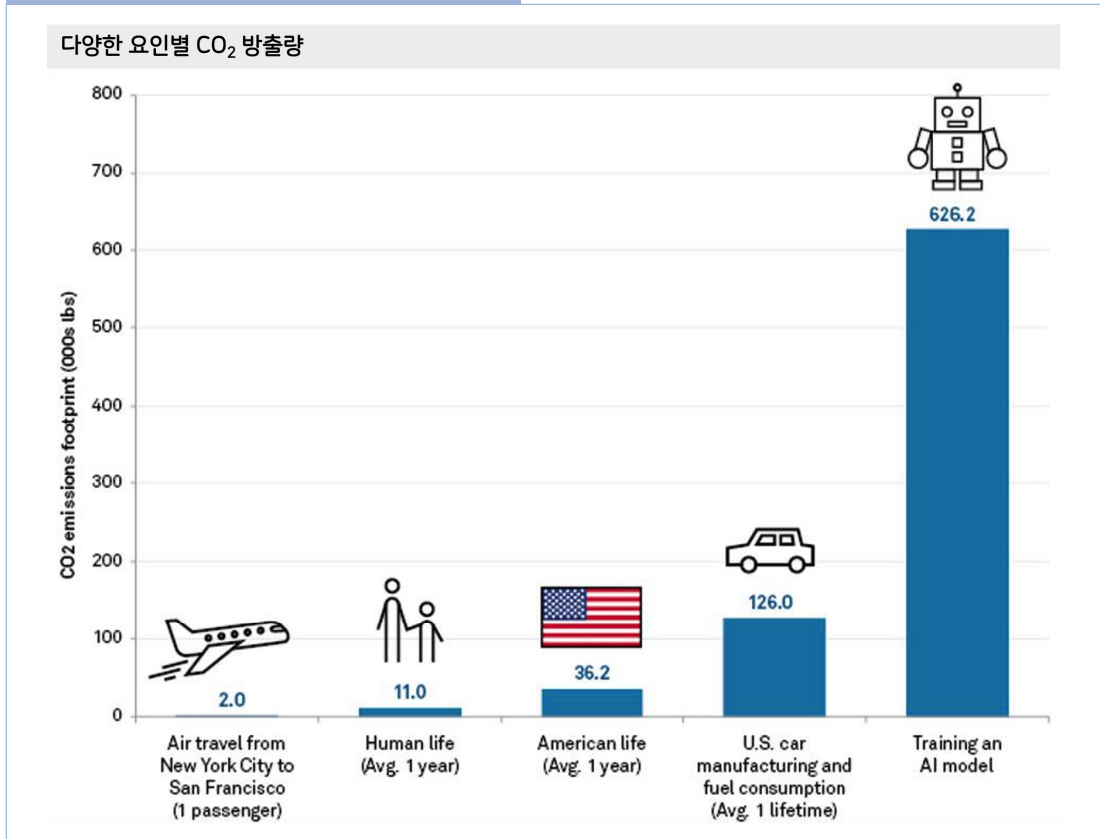
방석영(한국과학기술연구원 뇌과학창의연구단 Post-Doc)

I 서론

2021년 8월, UN의 ‘기후변화에 관한 정부 간 협의체(IPCC, Intergovernmental Panel on Climate Change)’는 인간이 대기, 해양, 육지의 온난화 현상에 영향을 미친 것은 명백하다라는 평가 보고서를 채택하였다. 이 보고서가 공개되자 안토니우 구테흐스(António Manuel de Oliveira Guterres) 유엔 사무총장은 “인류에 대한 ‘코드 레드’ 즉, 심각한 위기에 대한 경고”라고 평가했다.

지구를 따뜻하게 하는 인간의 영향들은 다양한 요인들의 융합적 결과이나, 그중 최근 급증하고 있는 요인이 바로 인공지능(AI, Artificial Intelligence)이다. 지난 2016년, 딥마인드 챌린지 매치(Google Deepmind Challenge match)에서 알파고 대 이세돌의 바둑 대국은 전 국민이 AI에 관심을 가지도록 한 이벤트였다. 당시 바둑 대국을 위한 알파고 작동에 시간당 약 56 kW의 전력을 소비하였다. 이에 더하여 알파고 연산을 위한 클라우드 컴퓨팅 인프라까지 고려한다면 그 이상의 전력이 사용되었을 것으로 추측된다. 많은 전력의 사용은 곧 탄소발자국의 증가를 의미한다. 최근 개발되는 AI의 훈련으로부터 나오는 이산화탄소 발생량은 자동차 한대의 생산 및 주행에서 발생하는 이산화탄소 발생량보다 무려 5배가량 많다(Strubell et al., 2019).〈그림 1〉


그림 1. 다양한 요인별 CO₂ 방출 정도



* 출처 : Strubell et al. (2019)

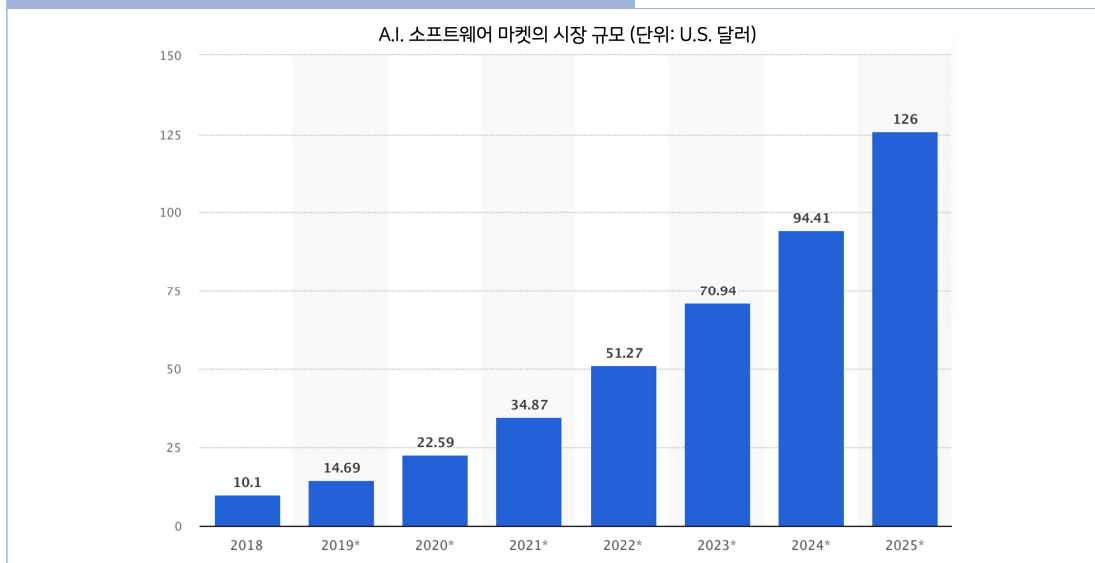
문제는 AI에 의한 탄소발자국은 기하급수적으로 증가하고 있다는 점이다. AI의 훈련에 필요한 연산량이 지수함수적으로 증가(Schwartz et al., 2020)하고 있으며(그림2), AI의 수요 역시 지수함수적으로 늘어나고 있다.(그림 3) 이러한 현 상황의 AI를 레드 AI(Red AI)라 한다.

그림 2. 딥러닝 훈련에 필요한 연산량의 지수함수적 증가



* 출처 : Roy Schwartz et al. (2020)

그림 3. 전세계 AI 소프트웨어 시장의 증가 현황



* 출처 : statista.com

레드 AI의 개념과 대척점에 있는 개념이 바로 그린 AI(Green AI)이다. 그린 AI를 실현시킬 방안은 총 5개의 지향점으로 재현성 강조, 하드웨어 성능 강화, 딥러닝에 대한 이해 증진, 딥러닝(Deep Learning) 기술 확산, 파트너 확대 등이라 할 수 있다(Talwalkar, 2020).〈표1〉

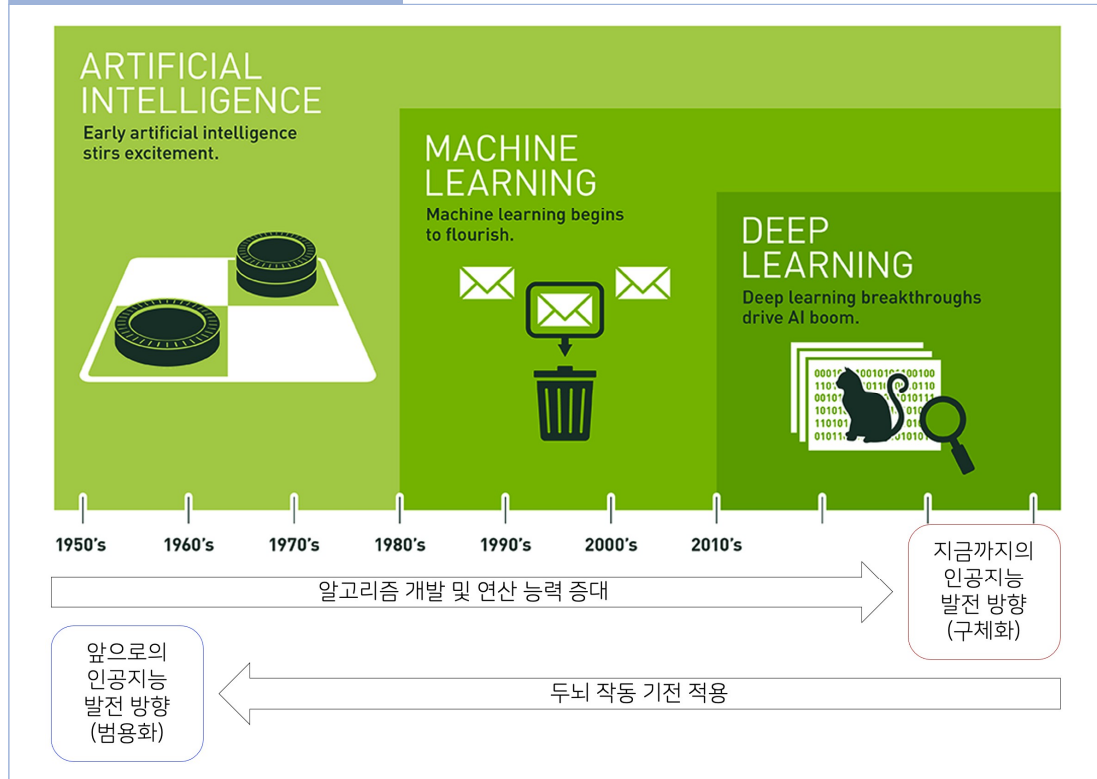
표 1. 그린 AI에 대한 전략

항목	내용
1. 재현성 강조 (Emphasize reproducibility)	이미 만들어진 AI 모델을 서로 공유
2. 하드웨어 성능 강화 (Increase hardware performance)	그래픽카드(GPU)의 발전으로 딥러닝을 위한 성능 향상뿐만 아니라 효율성 또한 증진 가능
3. 딥러닝에 대한 이해 증진 (Understand deep learning)	딥러닝의 작동 원리에 대한 근본적 이해를 통하여 딥러닝의 강점, 한계점을 파악. 나아가 더 정확하고 효율적인 AI 모델 제작 가능
4. 딥러닝 기술 확산 (Democratize deep learning)	정확도를 100%로 도달하려는 노력 대신, 현존하는 충분한 정도의 정확도 AI 모델을 업계에 확산
5. 파트너 확대 (Partner more)	세계적 IT 기업 단독으로 AI 효율 증진을 꾀하기보다는 대학 연구진 및 스타트업과 손을 잡고 AI의 발전을 도모

* 출처 : Talwalkar(2020), 저자 일부 수정

5개의 지향점 중 ‘딥러닝에 대한 이해 증진’에서 언급된 딥러닝은 AI의 하위 분야로써, 여러 레이어로 구성된 알고리즘으로 컴퓨터의 연산 능력 증대에 따라 최근의 AI의 발전 방향을 이끄는 모델이다.〈그림 4〉

그림 4. AI와 딥러닝 이해도



* 출처 : nvidia.com, 저자 일부 수정

하지만 딥러닝의 작동 기전에 대한 이해의 부족으로 인하여, 학습 과정의 에너지 효율성이 낮아 이로 인하여 AI의 학습은 많은 전력의 사용을 요구한다. 따라서 매우 효율적인 에너지 소비로 학습을 할 수 있는 모델을 분석한다면 이를 딥러닝에 적용하여 에너지 효율성을 높일 수 있을 것이다. 이를 위한 학습모델이 바로 두뇌이다. 사람 두뇌의 경우 시간당 20W의 에너지만을 소모한다. 이는 에너지 효율성에 있어서 AI보다 훨씬 우수한 수치이다. 나아가 단순히 정해진 문제 해결 능력뿐만이 아닌 다양한 문제를 수행할 수 있는 범용적인 지능을 지닌다. 하지만 딥러닝에 대한 이해가 부족한 것과 같이, 두뇌에 대한 이해 역시 여전히 부족한 수준이다. 이는 지능과 관련된 기관인 두뇌가 매우 복잡한 구조의 신경망으로 구성되어 있다는 점에 기인한다.

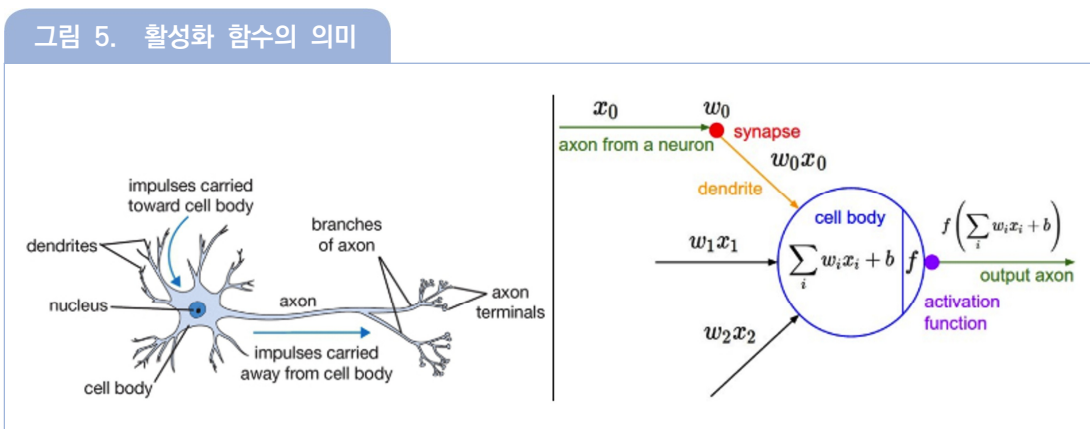
본 연구에서는 우선 인공지능의 큰 축을 담당하는 인공신경망에 대하여, 그리고 지능의 근원인 두뇌와 두뇌 신경망에 대하여 설명한다. 또한 인공신경망과 두뇌 신경망의 간극 및 이 간극을 극복하려는 전 세계에서 수행 중인 융합 시도들을 설명한다.

1. 인공신경망(Artificial Neural Network)

인공신경망은 인간의 신경망 구조를 추상화하여 만든 기계학습 모델이다. 기본 형태는 여러 레이어로 구성되는 다층구조인데, 각 레이어에 여러 개의 뉴런 노드(Node)를 배치하여 이들을 연결한 형태를 띤다. 각 개별 노드를 뉴런으로 간주한다. 이전 레이어에서의 여러 뉴런 노드들로부터 입력된 신호는, 그 뉴런 노드에서 활성화 함수를 거쳐 다음 레이어의 뉴런 노드들로 출력 신호를 전달한다. 이 때 사용되는 활성화 함수들은 비선형 함수가 주로 사용되며, 이는 실제 두뇌의 뉴런 활동을 모사하는 것이다. 다만, 이러한 활성화 함수들은 실제 두뇌 내의 뉴런의 활동과 일치하지는 않는다. 특히, 학습 과정에서 중요한 뉴런 노드 연결 간의 가중치 업데이트의 경우, 실제 두뇌 내 뉴런에서의 가중치 업데이트는 헤비안 이론이라는 방법이 알려져 있으나 매우 추상적일 뿐 생물학적으로 구체적으로 확립되지 않은 상태임을 고려할 필요가 있다.

1.1. 수학적 모델링


인공신경망의 수학적 모델링은 크게 두 가지로 나누어 생각해볼 수 있다. 첫 번째는 단일 뉴런 노드가 “현 상황”에서는 어떻게 출력값을 나타내는지”이며 이는 활성화 함수와 관련된다.<그림 5>



* 출처 : medium.com

현재 ‘sigmoid, tanh, ReLU, leaky ReLU’ 등의 다양한 비선형 함수들이 활성화 함수로써 개발되어 사용 중에 있다.<그림 6>


그림 6. 활성화 함수의 종류



* 출처 : towardsdatascience.com

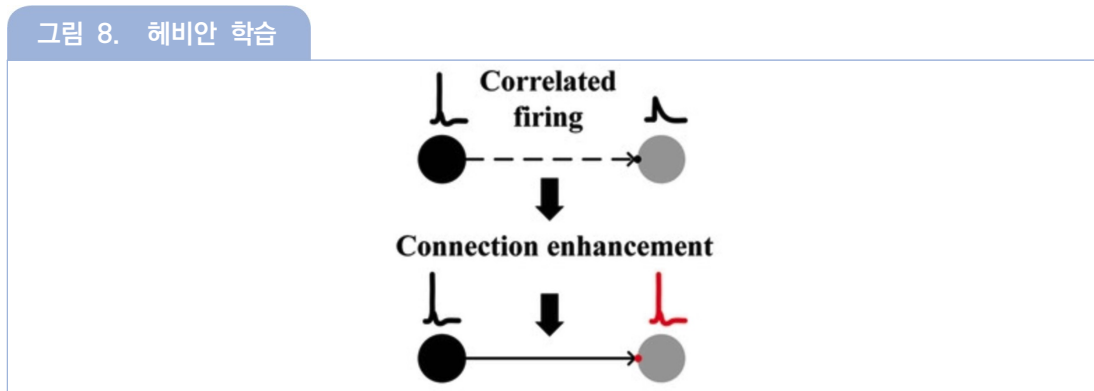
다른 하나는 학습 과정에서 뉴런 노드 간의 연결 가중치의 변형이다. 인공신경망에서의 학습 과정 중 가중치의 변형은 지도 학습, 비지도 학습, 강화 학습 등으로 분류되며 왔으나, 최근 다양한 융합적 시도들이 이루어지고 있다. 다양한 학습 방법 중 인공신경망의 시작부터 함께 존재하였으며 최근 그 성능이 재조명되고 있는 방법이 헤비안 학습(Hebbian Learning)이다(Lim, 2021). 헤비안 학습이란 시냅스 가소성에 기초하는데, 시냅스는 뉴런 간의 신호를 전달하는 구조체를 뜻하고 시냅스 가소성이란 특정 뉴런 간에 전달되는 반복적이고 지속적인 신호가 더 많은 경우 이 시냅스 연결이 강화되는 것을 의미하며, 이러한 현상을 장기 강화(LTP, Long-Term Potentiation)라 한다.<그림 7>

그림 7. 시냅스 가소성에 의한 장기 강화



* 출처 : Bear et al. (2020)

장기 강화는 실제 두뇌에서의 기억의 기저 현상으로 간주된다(Bear et al., 2020; Lynch, 2004). 헤비안 학습은 '함께 발화하는 뉴런은 서로 연결된다(Fire together, wire together)'로 요약되며, 이는 시냅스 가소성과 관련 있는 이론이다(Cooper, 2005; Tang et al., 2019).〈그림 8〉



* 출처 : Tang et al. (2019)

이를 통해, 신경과학을 통한 두뇌 및 뉴런의 작동 기전의 이해 증진이 궁극적으로 인공지능망의 효율적 수학적 모델링에 도움이 될 것이라는 것을 유추할 수 있다.

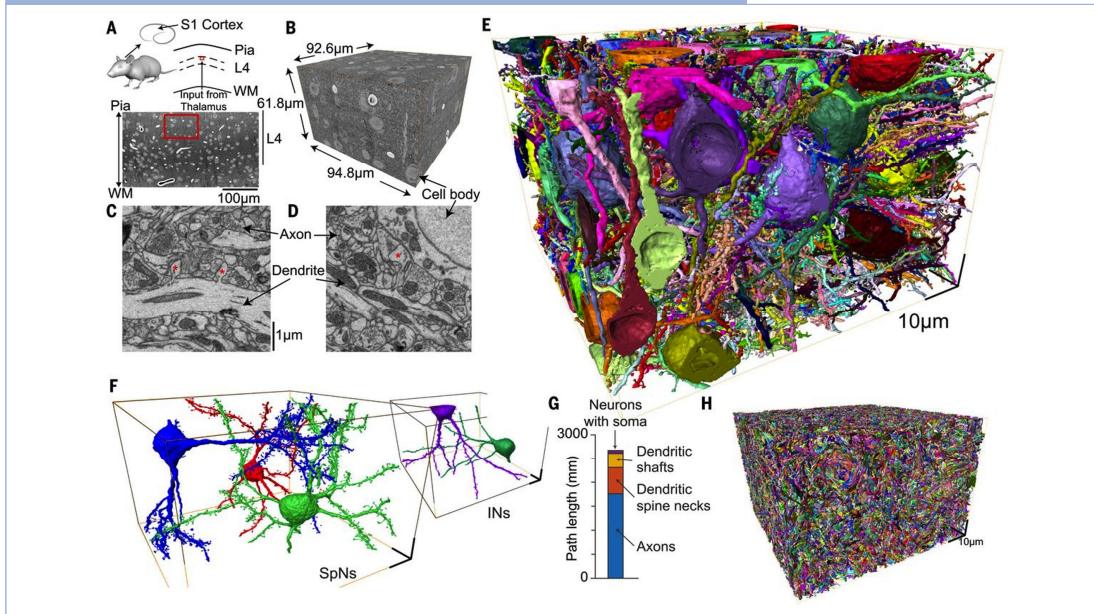
2. 두뇌 신경망

지능은 두뇌의 신경망을 통하여 구축된다. 현 인공지능망의 능력은 주어진 문제 해결을 얼마나 정확하게 효율적으로 하는지 평가되지만, 지능에 대해서는 통일된 정의가 존재하지 않을 정도로 복잡한 개념이다. 이러한 복잡한 개념의 지능을 구축하는 두뇌 내의 신경망 역시 매우 복잡하다. 복잡한 두뇌의 신경망을 연구하기 위한 신경과학 역시 발전하고 있으나, 여전히 연구되어야 할 영역이 넓다.

2.1. 두뇌의 복잡성

사람 두뇌에는 약 860억 개의 뉴런이 존재하며 이들이 두뇌 신경망을 구축한다(Azevedo et al., 2009). 개별 뉴런은 매우 많은 수의 신경돌기를 보유하며, 신경돌기를 통해 다른 뉴런과 연결된다. 이러한 뉴런 간의 신호를 전달하는 연결점을 시냅스라 하며, 개별 뉴런당 약 1,000개의 시냅스를 형성하는 것으로 알려져 있다. 두뇌 속에는 수많은 뉴런들 및 신경돌기들이 3차원 구조로 얽혀있어, 신경망의 구조를 파악하는 것이 매우 어렵다(Motta et al., 2019).〈그림 9〉


그림 9. 두뇌의 복잡성 1: 매우 복잡하게 얽혀있는 신경회로



* 출처 : Motta et al. (2019)

나아가 두뇌에는 뉴런 이외에 다양한 세포들이 뉴런들과 뒤섞여 존재한다. 두뇌를 구성하는 다양한 세포들 역시 뉴런과 다양한 영향을 주고받는 역할을 수행한다.<그림 10>

그림 10. 두뇌의 복잡성 2: 두뇌를 구성하는 다양한 종류의 세포



* 출처 : Seo et al. (2021), 저자 일부 수정


이러한 두뇌의 복잡성 때문에, 두뇌 내에서의 신경망이 어떻게 작동하는지, 그보다도 더 간단한 헤비안 학습이 구체적으로 어떻게 이루어지는지조차 검증하기가 매우 어려운 것이 현실이다. 따라서 두뇌의 신경망과 인공신경망의 구조적, 기능적 유사성을 파악하는 것이 매우 어렵다. 이러한 복잡성을 극복하고 두뇌의 신경망의 구조 및 기능을 파악하기 위한 다양한 신경과학적 도구들이 개발되고 있다.

2.2. 두뇌 신경망의 구조, 기능을 파악하기 위한 새로운 신경과학적 도구

두뇌가 매우 많은 수의 뉴런으로 구성되어 있지만, 뉴런들이 무작위로 배열되어 있는 것은 아니다. 두뇌의 신경망은 각기 다른 구조 및 기능을 담당하는 여러 영역들로 구분된다. 이러한 영역 간의 연결을 구조적, 기능적으로 파악하기 위하여 다양한 신경과학적 도구들이 개발되고 있다. 그 중 대표적인 두 가지 도구를 설명한다.

첫 번째는 두뇌의 두 영역 간 연결의 구조적 특성(시냅스 분포 정도)을 확인하기 위한 도구이다. 일반적으로 두뇌 신경망에서의 시냅스 분포를 확인하고자 할 때에는, 두뇌를 적출한 후 매우 얇은 슬라이스로 만들어 이를 형광 마커를 이용한 분석을 실시한다. 하지만 이런 방법은 다음과 같은 단점을 가진다. 두뇌 신경망의 특정 두 영역 간의 연결을 이루는 시냅스는 다음과 같이 '영역1 내의 뉴런 간의 시냅스, 영역2 내의 뉴런 간의 시냅스, 영역1과 영역2 뉴런 간의 시냅스'로 분류할 수 있다. 하지만 단순 형광 마커는 모든 시냅스를 확인할 수 있을 뿐, 각 타입의 시냅스를 선택적으로 확인할 수 없다. 서로 다른 영역 간의 시냅스만을 선택적으로 분석하기 위하여 mGRASP(mammalianGFP Reconstitution Across Synaptic Partners)라는 도구가 개발되었다. 이 도구를 사용하면 서로 다른 영역의 뉴런 간에 형성된 시냅스만을 선택적으로 관찰할 수 있다. 두뇌의 한 구역에는 pre-mGRASP를 발현시키고 다른 구역에는 post-mGRASP를 발현시킨다면, 두 구역 간에 시냅스가 형성된 곳에 녹색형광단백질(GFP, Green Fluorescent Protein) 형광 신호가 나타나게 된다. 기존 두뇌 내 시냅스를 확인하기 위해서는 노동 및 시간이 많이 요구되는 전자현미경 기법이 필요했으나, mGRASP를 이용하면 광학을 이용하여 두뇌 신경망의 구조를 파악하기 수월해진다(Kim et al., 2012; Takahashi et al., 2020).〈그림 11〉

그림 11. 시냅스 검출 방법



* 출처 : Takahashi et al. (2020), Kim et al. (2012)

두 번째는 두뇌의 영역 간 연결의 기능적 특성을 확인하기 위한 도구이다. 두뇌의 특정 영역을 자극하였을 때, 두뇌의 어떠한 다른 영역이 활성화되는지 혹은 나아가 개체가 어떠한 행동을 보이는지 파악함으로써 두뇌 신경망의 기능적 특성을 확인할 수 있다. 이 때 필요한 것이 두뇌 신경망의 특정 영역만을 선택적으로 자극하는 기술이다. 이를 위하여 광유전학(Optogenetics)이 뉴런에 도입되었다. 광유전학이란 일부 미생물의 세포막에 광 자극에 반응하는 이온 게이트 단백질이 발현되는 특성을 뉴런에 도입한 기술이다. 광 자극에 반응하는 이온 게이트 단백질이 발현된 뉴런에 광 자극을 주면 해당 뉴런의 발화를 유도하거나 억제할 수 있다(Boyden et al., 2005). <그림 12>

그림 12. 빛을 이용한 뉴런 제어

뉴런을 빛으로 자극할 수 있는 '**광유전학 (optogenetics)**'

- 빛에 민감한 유전자를 신경세포에 삽입하여 빛의 파장에 따라 신경세포의 활성을 조절하는 기술
- 기존 신경 자극기술과는 달리 매우 국소적인 부위의 신경 세포를 자극 가능
- 광유전학에는 다양한 단백질이 다양한 역할로써 작동 가능
 - 채널로돕신 (channelrhodopsin) - 활동전위 발생
 - 할로로돕신 (halorhodopsin) - 활동전위 억제
 - 아키로돕신 (archaerhodopsin) - 활동전위 억제


* 출처 : addgene.com

이처럼 다양한 신경과학적 도구들이 개발되고 있지만, 두뇌 신경망의 복잡성으로 인하여 여전히 두뇌 신경망의 많은 특성들은 미지로 남아있다. 두뇌 신경망의 복잡성을 피하기 위한 방법으로, 두뇌를 직접 연구하는 방법이 아니라 뉴런을 체외에서 따로 배양하여 그 특성을 분석하는 방법도 이루어지고 있다.

2.2.1 체외 신경세포 배양

두뇌 신경망의 실시간 관찰 및 분석은 매우 제한적일 수 밖에 없는데, 이는 두뇌 신경망이 복잡하고, 두뇌는 단단한 두개골로 보호되어 있으며 두뇌 조직은 매우 연한 기계적 물성치를 갖고 있기 때문이다. 따라서 접근이 쉬운 방법으로 뉴런을 체외에서 배양하는 연구도 많이 진행되고 있다. 체외 뉴런 배양의 경우 대부분 유리 혹은 플라스틱의 표면에 뉴런을 부착시켜 성장시킨다.<그림 13>

그림 13. 2차원 환경에서 배양된 뉴런의 모습



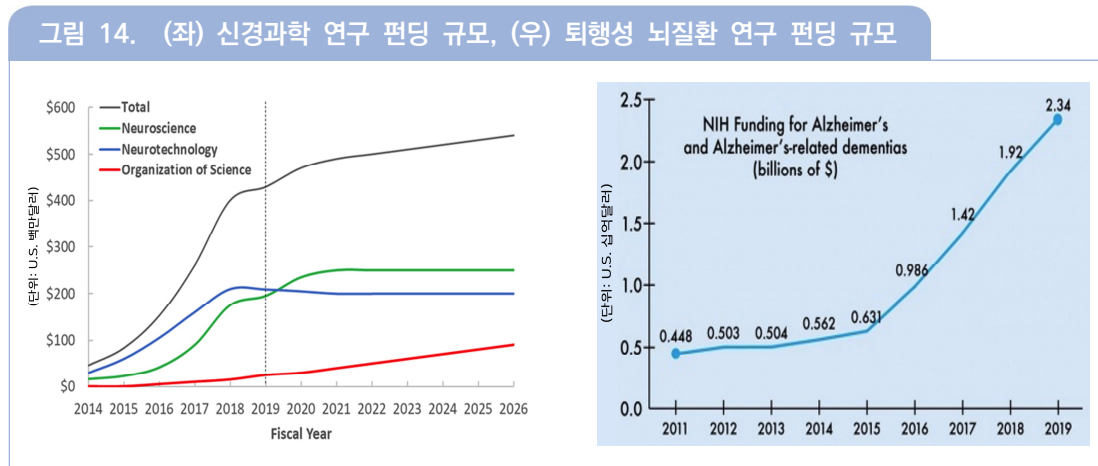
* 출처 : 저자 연구 결과물

하지만 이러한 방법은 여러 단점들을 지닌다. 하나는 유리 혹은 플라스틱의 기계적 물성치가 매우 연한 조직인 두뇌의 기계적 물성치와 큰 차이를 보인다는 것이다. 이러한 특성은 유리 및 플라스틱 위에서 배양된 뉴런이 형태, 기능에서 두뇌 신경망 내의 뉴런과 차이를 나타내도록 한다. 또 다른 단점은 뉴런들이 마구잡이로 배열되어 있을 뿐만 아니라 신경돌기가 불규칙하게 성장하고 시냅스 또한 마구잡이로 분포한다는 것이다. 이는 두뇌 신경망이 다양한 영역으로 구분되며 매우 정교한 연결되어 있는 것과 상반된다. 따라서 이러한 단점들을 극복할 새로운 체외 뉴런 배양 플랫폼이 필요하다.

3. 인공신경망과 두뇌 신경망의 간극

최근 인공신경망과 관련하여 다양한 활성화 함수 및 학습 모델들이 개발되면서 성능이 많이 향상되고 있다. 하지만 앞서 설명한 바와 같이, 인공신경망의 성능뿐만 아니라 효율까지 향상되기 위해서는 두뇌 신경망에 대한 이해 역시 필요하다. 두뇌 신경망의 구조가 인공신경망의 알고리즘 및 노드-레이어 사이의 연결 구조 등에 영감을 줄 뿐만 아니라 인공신경망 알고리즘의 타당성을 검증하는 데에도 사용될 수 있기 때문이다(Brooks et al., 2012).

신경과학 역시 최근 급속도로 증가하는 신경과학 연구 펀딩 및 퇴행성 뇌질환 연구 펀딩에 힘입어 많은 발전을 이루고 있다. <그림 14>



* 출처 : (좌) nih.gov, (우) duke.edu

광학, 전자 현미경, 다양한 마커 개발 등 두뇌 신경망을 밝히고자 하는 다양한 도구들의 발명 및 발전 덕분에, 두뇌 신경망의 다양한 구조들을 밝혀내고 있으나, 매우 복잡한 연결들을 확인하는데 그리고 자극에 의한 구조 가소성을 실시간으로 확인하는데 있어 아직은 한계가 있다.

따라서 여전히 인공신경망과 두뇌 신경망은 상호 간에 거리감이 존재하며 이를 좁히는 것에 어려움을 겪고 있다. 그러나 최근 이러한 인공신경망과 두뇌 신경망의 간극을 극복하고자 하는 여러 융합적 시도들이 있으며, 이러한 최근 연구 동향을 설명한다.

II 인공지능망과 두뇌 신경망의 간극 극복 연구 동향

인공지능망과 두뇌 신경망의 간극을 극복하려는 최근의 전 세계 연구 동향을 살펴봄으로써 현재의 기술 수준을 파악할 수 있을 것이다.<표 2>

표 2. 인공지능망-두뇌 신경망 융합 관련 연구 동향

국가	조직	관련 연구 내용
미국	IARPA (Intelligence Advanced Research Projects Activity, 정보고등연구기획국)	<ul style="list-style-type: none"> • "Machine Intelligence from Cortical Network(대뇌피질 네트워크로부터의 기계지능)" 프로젝트 수행 • 두뇌를 리버스 엔지니어링 하는 1억 달러 규모의 프로젝트 • 쥐의 뇌 1mm³의 커넥톰 분석이 목표
	Yale University (예일대학교)	<ul style="list-style-type: none"> • fMRI(functional Magnetic Resonance Imaging)을 이용하여 두뇌의 실시간 활동 패턴을 분석 • 피실험자에게 이미지를 제시한 후, 두뇌 활동 패턴을 분석하여 이미지를 재구성하는 연구
영국	Deep Mind (딥마인드, 알파고 개발 기업)	<ul style="list-style-type: none"> • 신경 회로, 호르몬 등 두뇌의 기능을 연구하며, 이를 기존 AI 모델과의 유효성 검증 및 발전시키는 연구 진행(예: 분포강화학습 등)
호주	Cortical Labs (호주 스타트업)	<ul style="list-style-type: none"> • 전국 그리드 칩 위에 쥐의 뉴런을 배양하여, 뉴런의 신호를 컴퓨터와 실시간 소통 가능하도록 하는 기술 이용 • 생물학적 뉴런 시스템이 간단한 게임을 진행하는 것이 목표

* 출처 : 저자 작성

미국의 정보고등연구기획국(IARPA)은 '대뇌피질 네트워크로부터의 기계지능(Machine Learning from Cortical Network)'라는 이름의 1억 달러 규모의 프로젝트를 진행하고 있다. 이 프로젝트의 목표는 쥐의 두뇌 피질 중 1mm³에 해당하는 영역의 뉴런 연결을 분석하는 것이다. 두뇌 신경망의 구조를 리버스 엔지니어링(RE, Reverse Engineering, 구조 분석을 통해 기능을 추론하는 것)하여 인공지능망에 대입하고자 하는 내용인데, 사람도 아닌 쥐의 두뇌를 전 영역이 아닌 가로(1mm)x세로(1mm)x높이(1mm)만을 분석하는 것이 목표라고

하니 이를 통해 역으로 두뇌 신경망의 복잡성을 다시금 생각하게 된다. 이 프로젝트가 성공하더라도 중요한 단점이 있는데, 그것은 두뇌 신경망 분석에 죽어서 고정된 상태의 두뇌를 이용하는 것이기 때문에 해당 상태의 시냅스 분포를 파악할 수는 있어도 살아있는 두뇌 신경망의 시냅스 가소성을 파악할 수는 없다는 점이다(Abbott, 2015).

미국의 예일대학교에서는 기능적 자기공명영상(fMRI, functional Magnetic Resonance Imaging)을 이용하여 두뇌 신경망의 실시간 활동 패턴을 분석하는 프로젝트를 수행 중이다. 피실험자에게 이미지를 제시한 후, fMRI를 이용한 실시간 두뇌 활동 패턴을 분석하여 이미지를 재구성하는 것이 목표이다. 하지만 fMRI의 해상도가 세포 수준에 못 미치기 때문에 두뇌 신경망의 구체적인 구조 및 기능을 파악하는 데에는 한계가 있다(O'Connell & Chun, 2018).

영국 기업 딥마인드(Deep Mind) 역시 신경과학을 이용하여 두뇌 신경망 및 두뇌 내 호르몬 등의 연구를 꾸준히 수행 중이다. 하지만 두뇌를 이용한 연구를 진행하기 때문에 앞서 설명한 두뇌 연구의 다양한 어려움이 등장한다(Dabney et al., 2020).

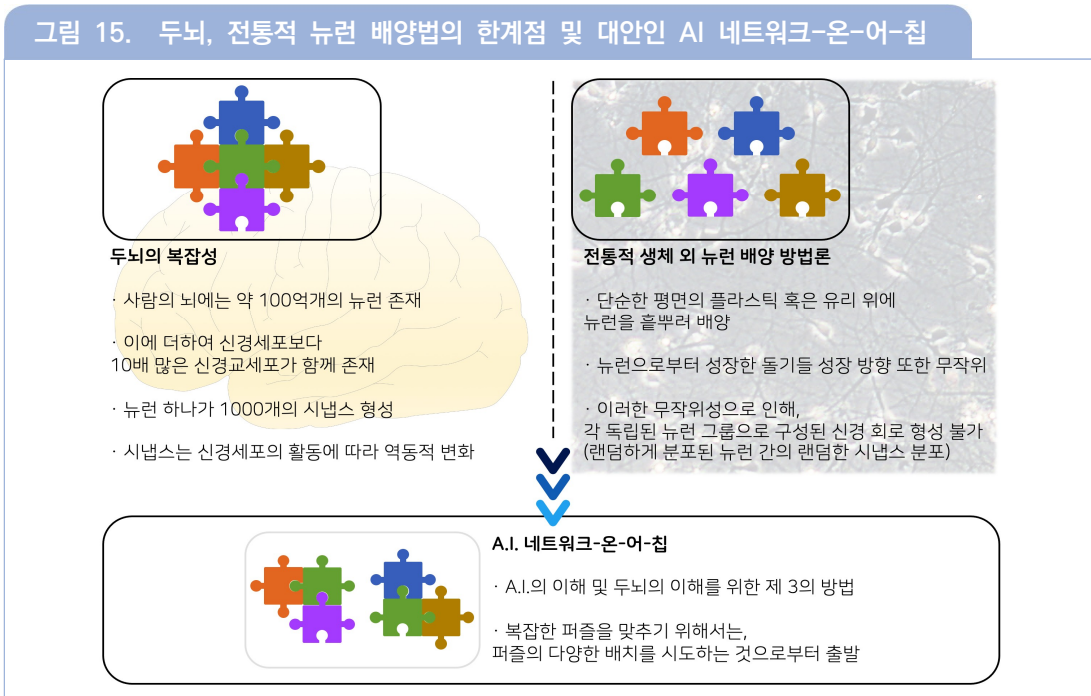
마지막으로 호주의 스타트업인 Cortical Labs는 체외뉴런 배양 기술을 이용한다. 전극 그리드 칩 위에 뉴런을 배양하여, 뉴런의 신호를 컴퓨터와 실시간 소통 가능하도록 하는 기술을 이용한다. 하지만 체외 뉴런 배양 기술의 단점 중 하나인 무작위로 배열된 뉴런 간의 연결은 해당 업체의 플랫폼에서도 발생한다. 따라서 두뇌 신경망의 정교한 연결이 이루어지지 못하고 체외 배양된 뉴런의 무작위한 연결로 대체되는 단점이 있다.

현재의 전 세계적 선도 기술들 역시 두뇌 신경망의 실시간 구조적, 기능적 분석 혹은 재현에 한계점을 가지고 있다. 즉, 시냅스 가소성을 갖는 살아있는 뉴런을 이용하여 인공신경망의 학습 모델이 되는 헤비안 학습을 검증 및 재현할 수 있는 플랫폼이 아직 존재하지 않는 것이다. 본 연구는 체외에서 살아있는 뉴런을 배양하는 기법을 이용한 헤비안 학습 검증 및 재현이 가능한 융합연구 플랫폼을 제안한다. 이는 현재의 큰 화두들인 인공지능과 신경과학이 융합의 개념 및 방법론의 명확화에 기여하도록 하며, 관련 융합연구를 촉진하도록 할 것이다.

III 미세공학과 생물학의 융합을 통한 새로운 해결책 제시

1. AI 네트워크-온-어-칩 연구의 기술적 배경

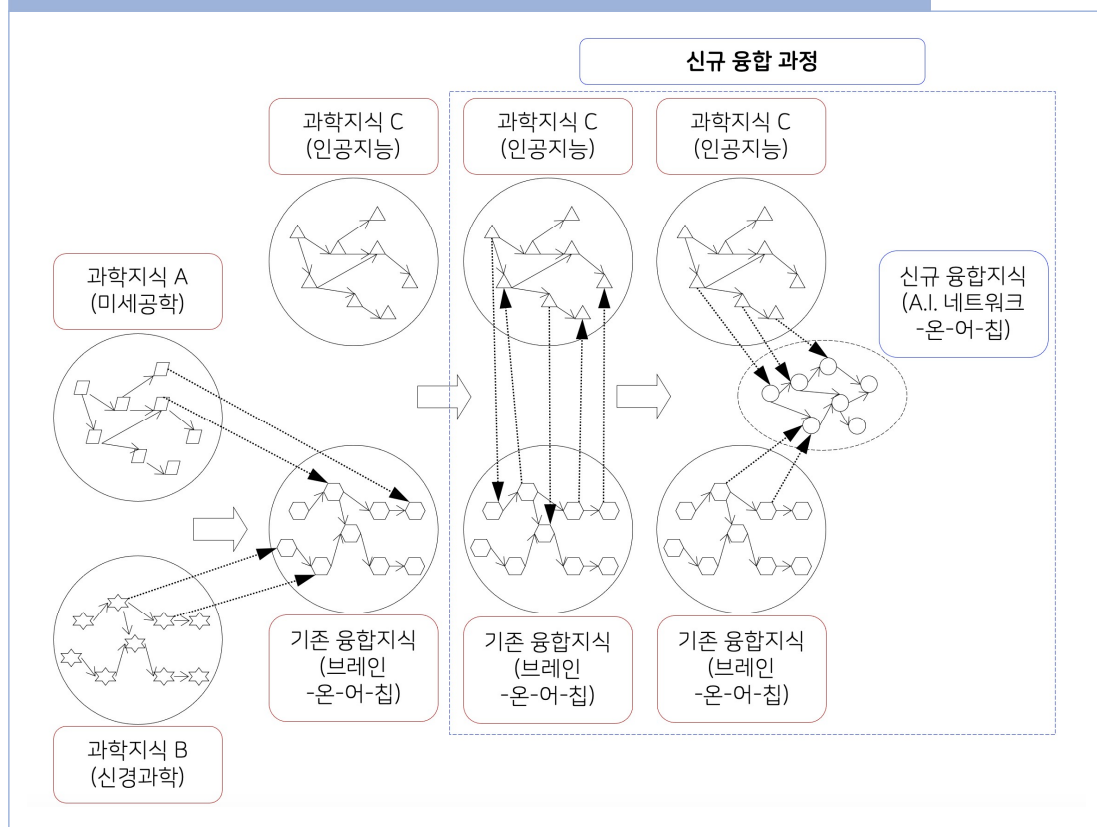
본 연구에서는 인공지능과 신경과학의 융합연구 주제로써 살아있는 뉴런을 이용한 헤비안 학습 검증 및 재현이 가능한 융합연구 플랫폼을 제안하고 이 플랫폼을 ‘AI 네트워크-온-어-칩(AI Network-on-a-Chip)’으로 명명한다. 기존의 두뇌 신경망의 작동 원리를 파악하고자 했던 연구들의 접근 방법들의 한계점으로부터 ‘AI 네트워크-온-어-칩’의 필요성을 찾아볼 수 있다.<그림 15>



* 출처 : 저자 작성


인공신경망의 효율적인 학습 모델을 제시할 가능성이 높은 두뇌 신경망 분석을 새롭게 진행하기 위해서는 창의적인 문제 해결 방안이 필요하다. 기존의 두뇌 신경망 분석에는 한계점들이 존재하기 때문이다. 창의적인 문제 해결은 지식들의 참신한 결합으로부터 시작한다(Herstatt & Kalogerakis, 2005). 즉, 창의적인 해답을 도출하기 위해서는 이전에 함께 결합되지 않았던 지식 조각들을 서로 연결하여 융합할 때에 그 가능성이 보이는 것이다(김선중, 2017). 이러한 융합 관점에서 ‘AI 네트워크-온-어-칩’은 두 단계의 융합 과정을 거쳐 나온 플랫폼으로 볼 수 있다(김한성, 2019; Zhou et al., 2019). <그림 16>

그림 16. 과학지식 융합과정으로 본 AI 네트워크-온-어-칩의 융합 도식화



* 출처 : Zhou et al. (2019), 김한성 (2019), 저자 재구성

‘AI 네트워크-온-어-칩’은 ‘인공지능’과 ‘브레인-온-어-칩(Brain-on-a-Chip)’의 융합 과정의 결과이다. ‘AI 네트워크-온-어-칩’을 이루는 두 지식 조각 중 하나의 지식 조각을 이루는 ‘브레인-온-어-칩’ 역시 최근에 융합된 연구 분야이다. ‘브레인-온-어-칩’은 장기칩(Organ-on-a-Chip)의 한 종류로, 미세공학(Micro-Engineering)과 세포생물학의 융합 과정의 결과물으로써, 2005년 첫 발표된 이래 이를 이용한 최신 연구들이 많이 발표되고 있다(Bang et al., 2021a; Taylor et al., 2005). ‘AI 네트워크-온-어-칩’ 역시 미세공학과 세포생물학을 기저 기술로 사용하게 된다. 다만 ‘브레인-온-어-칩’은 체외 뉴런 배양 기술과 미세공학을 융합하여 두뇌 신경망 구조를 모사하고자 하는 자연모사 설계(Biomimetics)에 초점을 맞춘, 제한적 범위의 기술이었다. 자연모사 설계란 인체 장기와 같은 자연물의 구조 및 기능을 모사하여 응용기술을 연구하는 것이다. 반면 ‘AI 네트워크-온-어-칩’은 이 두 기저 기술을 이용하여 인공신경망이라는 인공물을 모사하는 인공물모사 설계로 확장되었다는 것이 큰 차이이다. 앞서 살펴본 인공신경망과 두뇌 신경망의 간극을 극복하려는 최근의 전 세계적 연구 동향에서도 살아있는 세포를 이용한 인공물모사 설계는 없던 시도이다. 따라서 이러한 ‘AI 네트워크-온-어-칩’의 융합 과정은 인공신경망과 두뇌 신경망의 간극 해결이라는 난제에 Grand Challenge한 융합연구라 볼 수 있다.(그림 17)



* 출처 : 저자 작성


2. AI 네트워크-온-어-칩 연구의 기반 기술들

앞서 설명하였듯이 융합 연구인 ‘AI 네트워크-온-어-칩’을 실제화 할 방법으로써의 기저 기술은 ‘디자인 및 공정을 위한 미세공학’과 ‘칩 위에서 배양될 뉴런을 다루고 제어할 세포생물학’이다. 이 두 기저 기술에 대하여 설명한다.

2.1. 기반 기술 1: 디자인 및 공정을 위한 미세공학

기존의 체외 뉴런 배양에서 사용하던 유리 및 플라스틱 표면과 같은 실험 도구들은 마이크로미터 수준의 제어를 할 수 없었다. 따라서 뉴런 패터닝(뉴런을 마이크로미터 수준으로 정밀하게 원하는 곳에 위치시키는 기술), 기계적 물성 제어, 농도 구배 제어 등에 어려움이 있었다. 이러한 어려움은 두뇌 신경망 특성 모사에 한계를 가져왔다. 그러나 미세공학의 도입은 체외 뉴런 배양에 세밀한 제어를 가능하게 하는 ‘브레인-온-어-칩’의 등장을 가능하게 하여 두뇌 신경망 모사에 발전을 가져다 주었다(방석영 & 김홍남, 2020; Bang et al., 2021a).

‘브레인-온-어-칩’은 다양한 공정을 통하여 다양한 디자인으로 제작될 수 있다. ‘브레인-온-어-칩’ 제작에 사용되는 공정은 소프트 리소그래피(Soft Lithography), 포토리소그래피(Photolithography), 플라스틱 사출 공정, 3D 프린팅, 이광자 리소그래피(Two-Photon lithography) 등 다양하지만, 그중 대표적으로 사용되는 소프트 리소그래피와 포토리소그래피에 의한 공정을 설명한다(Park et al., 2006). <그림 18>



* 출처 : Park et al. (2006)

‘브레인-온-어-칩’은 뉴런 및 신경돌기를 패터닝(Patterning)할 수 있는 구조물을 포함한다. 이러한 구조물의 규모는 수 마이크로미터 수준으로써 단일 세포보다도 작은 크기이다. 이러한 작은 크기의 구조물을 제작하기 위하여, 반도체 제작 공정에 주로 사용되는 기술을 사용하는데 이 기술이 포토리소그래피이다. 포토리소그래피는 빛을 이용하여 실리콘 웨이퍼 위에 형상을 만드는 작업으로써, 기계적 공정이 할 수 없는 미세한 공정을 가능하게 하는 초미세 공정이다. 실리콘 웨이퍼 위에 감광액을 원하는 두께로 도포한 후 마스크를 올려놓고 자외선을 노광시키면 마스크의 형태가 실리콘 웨이퍼 위에 새겨진다. 포토리소그래피 된 실리콘 웨이퍼가 ‘브레인-온-어-칩’의 몰드로써 사용된다. ‘브레인-온-어-칩’의 디자인 변경은 노광용 마스크의 디자인을 변경한 후 재가공하는 방식으로 이루어진다.

포토리소그래피를 이용하여 ‘브레인-온-어-칩’ 몰드가 가공되었으면, 이후 소프트 리소그래피를 이용하여 ‘브레인-온-어-칩’을 제작하게 된다. ‘브레인-온-어-칩’ 제작에 주로 사용되는 재료는 폴리디메틸실록산(PDMS, Polydimethylsiloxane)이다. PDMS는 액체 베이스(Base)와 액체 경화제(Curing Agent)로 구성되어 있으며, 이 둘을 섞으면 수 시간 이내에 탄성 있는 고체가 된다. PDMS는 저렴한 가격, 높은 투명도 및 기체 투과성을 가진다. 특히 액체 형태로 몰드에 부어진 후 경화되면, 몰드의 구조 형태를 나노미터 수준까지 재현하여 역전사할 수 있다는 장점이 있다. 액체 형태의 PDMS를 ‘브레인-온-어-칩’의 몰드에 부은 후, 이를 경화시키고 떼어 내면 ‘브레인-온-어-칩’이 완성되며, 이 때 사용된 몰드는 무제한 재사용이 가능하다. 이러한 가공 방법론을 이용하여 인공신경망의 형태를 가진 구조물을 제작하는 것도 가능하며, 이는 ‘AI 네트워크-온-어-칩’에 사용될 수 있다.

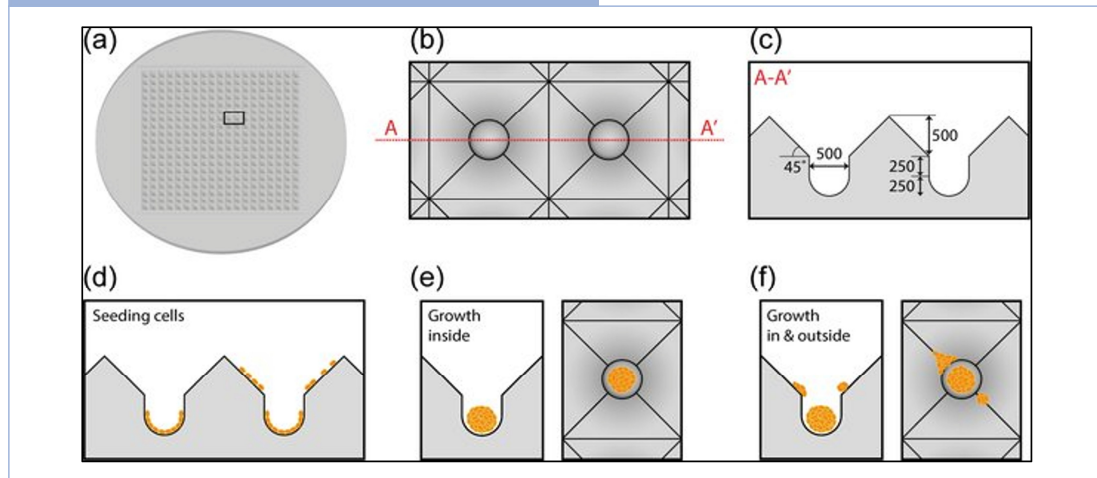
2.2. 기반 기술 2: 칩 위에서 배양될 뉴런을 다루고 제어할 세포생물학

세포생물학은 그 범위가 매우 넓어서, 여기에서는 본 연구에서 직접적으로 사용될 두 가지 주제만을 설명한다. 하나는 3차원 뉴로스페로이드(Neurospheroid)의 균일한 대량 생산 기술이고 다른 하나는 바이러스를 이용하여 세포에 원하는 단백질을 발현하는 기술이다.

뉴로스페로이드란 체외에서 뉴런들을 3차원 구 형태로 뭉친 구조체를 의미한다. 뉴로스페로이드가 형성되는 과정에서 이를 구성하는 뉴런들이 만들어내는 세포외기질(Extracellular Matrix) 때문에 뉴런끼리 서로 흩어지지 않고 뭉쳐진 형태가 유지된다. 2차원 배양 형태에서는 뉴런 간의 상호작용을 위한 분자가 세포 배양액으로 흩어지기 때문에 상호작용이 강하지 않다. 반면 뉴로스페로이드에서는 뉴런 간의 거리가 매우 가깝기 때문에 뉴런 간의 상호작용이 매우 강하다. 이는 뉴로스페로이드의 뉴런 기능이 2차원 배양된 뉴런의 기능보다 두 배

내 뉴런의 기능과 유사함을 의미한다. 이러한 뉴로스페로이드를 균일한 크기로 대량 생산할 수 있는 기술이 최근 개발되었다. 세포가 달라붙지 않도록 표면 처리 된 마이크로웰 어레이(Microwell Array) 위에 뉴런현탁액을 뿌리면 각 마이크로웰에서 뉴로스페로이드가 형성된다(Rosellini et al., 2019). <그림 19>

그림 19. 균질 뉴로스페로이드 대량 생산 기술

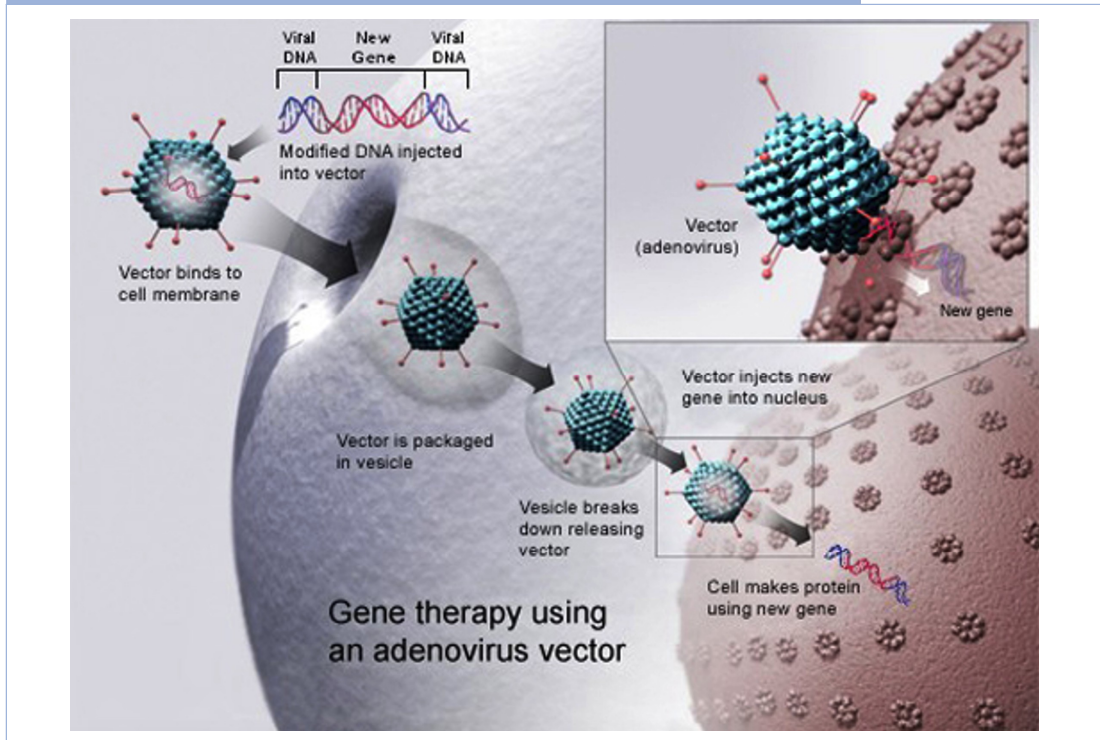


* 출처 : Rosellini et al. (2019)

이러한 방식을 이용하여 마이크로웰 어레이에 대량으로 생산된 균일한 뉴로스페로이드는 개별적으로 다른 곳으로 이송되어 배양될 수 있다. 즉, 뉴로스페로이드를 ‘AI 네트워크-온-어-칩’ 플랫폼으로 이송하여 인공신경망 형태로 배양할 수 있음을 의미한다.

앞서 서론에서 소개하였던 mGRASP 혹은 광유전학 단백질과 같이 새롭게 엔지니어링 된 단백질을 뉴런에서 발현시키기 위해서는 해당 단백질을 제작하는 정보를 가진 DNA를 뉴런의 핵 내로 운반하는 기술이 필요하다. 세포 생물학의 발전에 힘입어 외부 DNA를 세포핵 내로 운반하는 여러 기술들이 개발되었다. 여기에서는 그중 바이러스를 개량하여 DNA 전달체로 사용하는 기술을 간략히 설명한다. 바이러스성 전달체는 세포에 감염을 일으키는 바이러스 고유의 세포 내 침투 기전을 이용한다. 또한, 세포 내로 들어간 다음에도 비 바이러스성 DNA 전달의 경우에는 세포 내 수송경로인 엔도솜(Endosome)이 가수분해효소를 가져 효소 작용을 하는 리소솜(Lysosome)과 융합된 다음 엔도리소솜(Endolysosome)에서 유전자들이 분해되는 문제점이 있으나, 바이러스성 전달체는 리소솜을 통과하지 않고 핵내로 유전자를 전달하는 기전에 의하여 유전자의 손실이 작아서 유전자 전달 효율이 높다(오유경, 2010). <그림 20>

그림 20. 바이러스 유전자 전달체를 이용한 뉴런 내 단백질 발현 기술



* 출처 : nih.gov

핵심은 뉴런에도 이러한 바이러스 DNA 전달 기술을 응용할 수 있다는 것이다. 특히 앞서 설명한 뉴로스페로이드를 제작할 수 있는 마이크로웰 어레이에 바이러스성 전달체를 주입하면 여러 개의 뉴로스페로이드에 동시에 DNA를 전달할 수 있다. 즉, 마이크로웰 어레이 기술과 바이러스성 전달체 기술의 융합을 통해 mGRASP 혹은 광유전학 단백질을 보유한 뉴로스페로이드를 대량 생산할 수 있다.

3. AI 네트워크-온-어-칩 연구 모형

3.1. 'AI 네트워크-온-어-칩' 구성을 위한 다양한 신경세포 배양 기법 비교

'AI 네트워크-온-어-칩'을 이루는 요소는 살아있는 체외 배양된 뉴런이며, 이는 미세공학에 의해 제어될 수 있다. 다만, 신규 융합 결과물이 될 'AI 네트워크-온-어-칩'이 기 융합 결과물인 '브레인-온-어-칩'과의

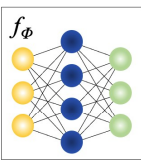

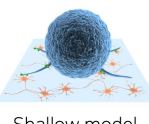

가장 큰 차이점은 구조적 지향점이 자연물인 두뇌가 아닌 인공구조물인 인공신경망이라는 점이다. 그러기에 다양한 신경세포 배양 기법들이 각각 인공신경망을 어느 정도로 모사가 가능할 지 살펴볼 필요가 있다. 이를 위하여 전통적 체외 2D뉴런 배양 기법 모델, 뉴로스페로이드-2D 뉴런의 하이브리드 모델(Shallow Model), 뉴로스페로이드들로만 구성된 모델(Deep Model)을 인공신경망과 비교하고자 한다.

우선 인공신경망의 모델링에 필요한 요소들은 다음과 같다: 역전파(Backpropagation), 순환 뉴런 노드(Recurrent Neuron Node), 여러 개의 레이어. 역전파는 인공신경망의 정교한 학습에 필요한 기법인데, 이를 위해서는 한 레이어에서 양 쪽의 레이어로 정보를 전달할 수 있어야 한다. 순환뉴런 노드는 인공신경망의 강화된 학습에 필요한 기법으로 이를 위해서는 한 뉴런에서 나온 신호가 다시 자기 자신에게 올 수 있어야 한다. 마지막으로 여러 개의 레이어는 인공신경망의 학습의 정확성을 증진시킨다고 알려져 있다. 이와 더불어 한 가지 추가로 고려할 요소는 체외 뉴런 배양 플랫폼의 배양 및 관찰의 난이도이다. 'AI 네트워크-온-어-칩'은 궁극적으로 뉴런으로 구성되기 때문이다.

전통적 체외 2D뉴런 배양 기법 모델의 경우, 개별 뉴런은 하나의 축삭신경돌기(신경돌기 중 신호를 다른 뉴런으로 전달하는 역할의 돌기)만을 가진다. 그렇기 때문에 양 방향의 레이어로 신호를 전달할 수 없기 때문에 역전파는 불가능하다. 유사한 이유로 자신의 축삭신경돌기가 자신의 수상신경돌기(신경돌기 중 신호를 다른 뉴런으로부터 받아들이는 역할의 돌기)와 만나기 어렵기 때문에 순환 뉴런 노드 또한 불가능하다. 많은 수의 뉴런이 흩뿌려져 있기 때문에, 이를 매우 많은 수의 레이어라고 간주할 수 있기는 하지만 각 샘플의 균일성을 보장할 수 없다. 이러한 이유들로 인하여 전통적 체외 2D 뉴런 배양 기법 모델은 'AI 네트워크-온-어-칩' 플랫폼으로 적절하지 않다.

이러한 인공신경망 모델링에서의 전통적 체외 2D 뉴런배양 기법 모델의 한계점들은 뉴로스페로이드의 도입으로 해결책을 모색해 볼 수 있다. 다음에서 뉴로스페로이드가 도입된 배양 기법 모델이 인공신경망 모델링이 가능한 이유를 설명한다.(그림 21)

그림 21. 인공지능망과 다양한 뉴런 배양 기법 비교

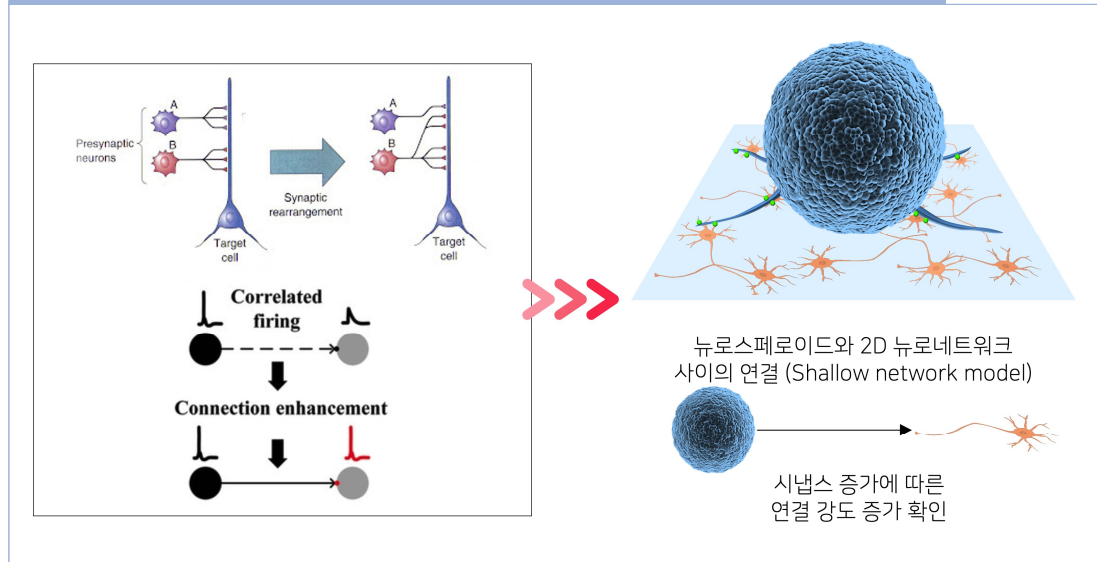
		수학적 모델링	전통적 생체 외 뉴런 배양	A.I. 네트워크-온-어-칩	
					
			개별 신경세포 배양	Shallow model (본 연구)	Deep model (후속 발전)
내 원 간 연 계 망	역전파 (Recapitulation of backpropagation)	필요 정교한 학습	불가능 단일 신경세포의 축삭돌기는 1개. 양 방향의 레이어로 동시에 축삭돌기를 뻗을 수 없음.	가능 스페로이드와 2D 뉴로네트워크 사이의 연결 가능.	가능 한 스페로이드로부터 성장한 축삭돌기는 매우 많음. 양 방향의 레이어로 많은 축삭돌기를 뻗을 수 있음.
	순환 뉴런 노드 (Recapitulation of recurrent neuron node (RNN))	필요 강화된 학습	불가능 한 신경세포로부터 나온 축삭돌기가 자신의 수상돌기와 만나기 어려움.	가능 스페로이드 내부에도 많은 수의 축삭돌기가 존재. 스페로이드를 이루는 신경세포 간의 시냅스 다수 존재.	가능 스페로이드 내부에도 많은 수의 축삭돌기가 존재. 스페로이드를 이루는 신경세포 간의 시냅스 다수 존재.
	레이어 개수	무제한	무제한	2개	무제한
비용	배양 및 관찰 난이도	해당 없음	쉬움	보통	어려움

* 출처 : 저자 작성

3.2. 두 레이어로 구성된 하이브리드 형태의 Shallow Model

최근의 인공지능망은 여러 레이어를 가진 형태로 구성된다. 이를 Deep Model이라 한다. 하지만 인공지능망의 전부를 모사하기에 앞서, 인공지능망의 최소 단위의 모사부터 시작할 필요가 있다. 서로 연결된 두 노드만으로 이루어진 얇은 형태(Shallow Model)를 구축한다면, 이를 이용하여 헤비안 학습을 검증하기에 적합하다. 이를 위하여 뉴로스페로이드의 장점과 2D 뉴런 배양 기법의 장점을 합친 하이브리드 형태의 모델을 구축할 수 있다.(그림 22)

그림 22. 뉴로스페로이드-2D 뉴로네트워크 연결로만 구성된 Shallow Model



* 출처 : (좌) Bear et al. (2020) , Tang et al. (2019), (우) 저자 작성

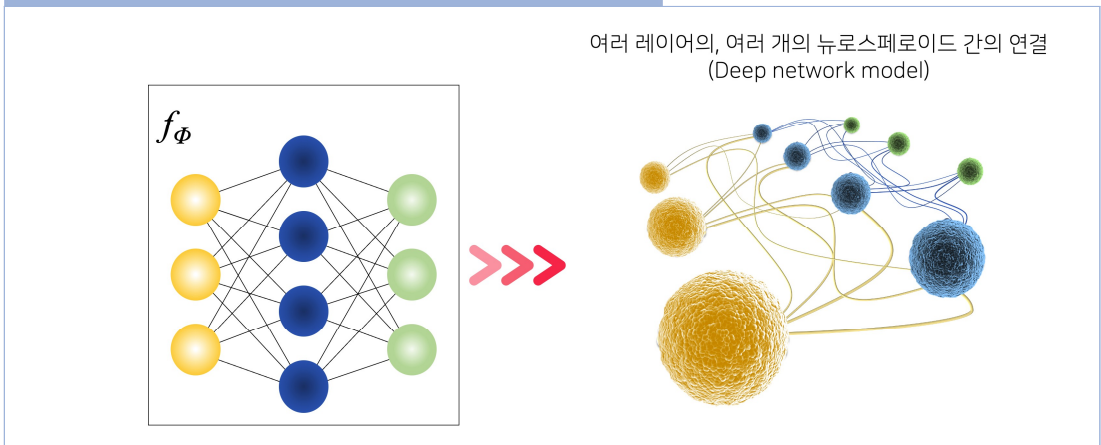
뉴로스페로이드는 많은 수의 뉴런이 뭉친 형태이기 때문에, 개별 뉴런과는 달리 하나의 뉴로스페로이드에서 많은 수의 축삭신경돌기가 뻗어 나온다. Shallow Model에서는 신호를 전달할 대상이 한 곳 밖에 없지만, Deep Model의 경우 전후 레이어의 여러 노드로 축삭신경돌기를 보낼 수 있다. 이것이 단일 뉴런과 차별되는 뉴로스페로이드만의 장점이다. 또한 뉴로스페로이드 내부에도 여러 축삭신경돌기가 존재한다. 따라서 뉴로스페로이드를 구성하는 뉴런 간에 서로 신호를 전달할 수 있는데, 이는 뉴로스페로이드를 하나의 노드로 간주할 시에 순환 뉴런 노드를 모사한 것이 된다. 즉, 뉴로스페로이드는 이를 구성하는 개별 뉴런들의 기능을 증진시킬 뿐만 아니라, 그 자체로도 인공신경망의 노드 역할을 충분히 수행할 수 있는 능력을 지닌다. 다만 뉴로스페로이드의 단점은 배양 및 관찰이 전통적 2D 뉴런 배양 기법에 비하여 복잡하다는 것이다. 따라서 Shallow Model에서는 뉴로스페로이드와 전통적 2D 뉴런 배양 기법을 각각의 노드로 존재하며, 이는 관찰이 용이한 헤비안 학습 분석 플랫폼으로 적합하다.

3.2.1. 헤비안 학습 검증 이후 Deep Model로의 확장 가능성

앞서 설명한 바와 같이 인공신경망의 노드로써 뉴로스페로이드는 역전파, 순환 뉴런 노드의 역할을 수행할 수 있다. 또한 미세공학을 이용하여 인공신경망의 구조와 같이 뉴로스페로이드를 원하는 위치에 위치시킬

수 있다(Kato-Negishi et al., 2010). 앞서 Shallow Model이 살아있는 뉴런을 이용한 헤비안 학습을 검증하는 역할을 수행한다면, 인공신경망의 모든 노드를 뉴로스페로이드로 치환한 Deep Model은 살아있는 뉴런으로 구성된 신경망이 학습하는 과정 전반을 모사하는 플랫폼으로 기능할 수 있을 것<그림23>이고, 이로부터 얻은 정보가 인공 신경망의 학습 모델에도 역으로 적용될 수 있을 것이다.

그림 23. 뉴로스페로이드로만 구성된 Deep Model



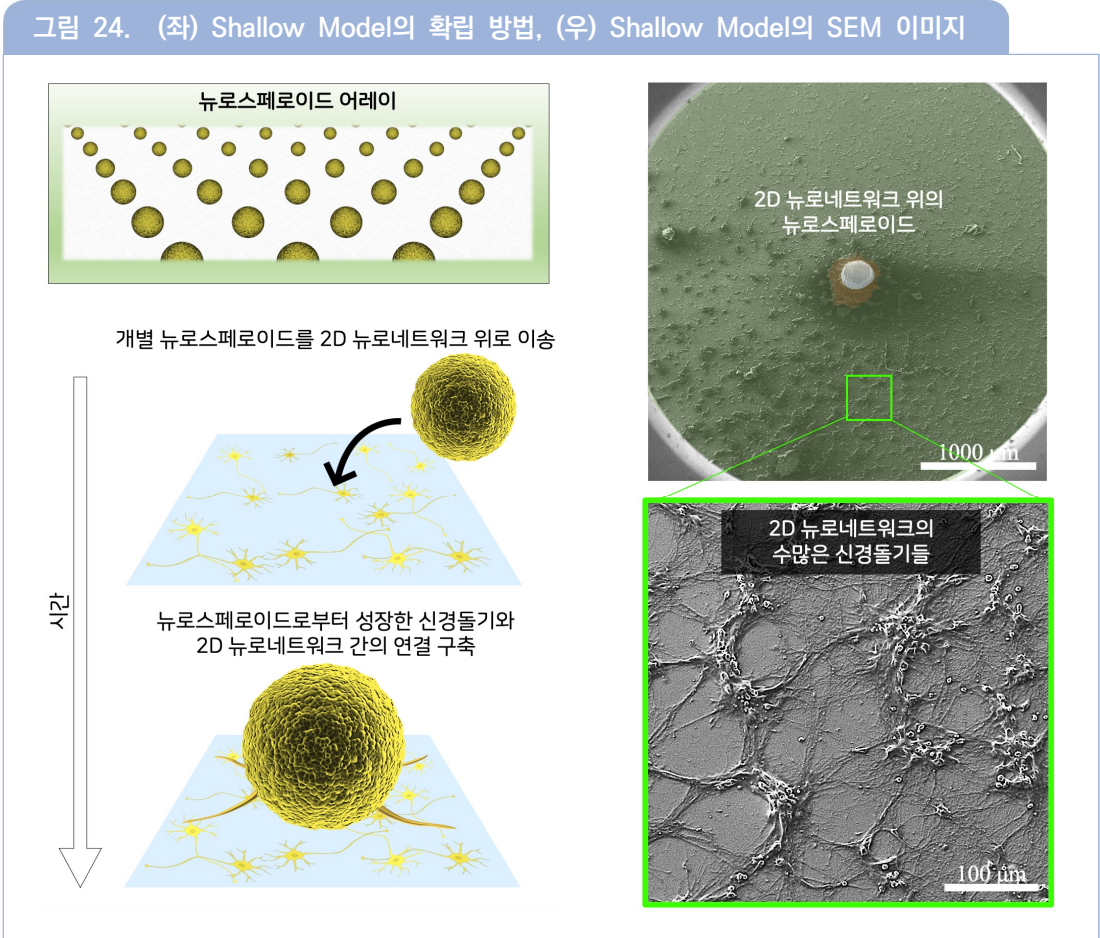
* 출처 : 저자 작성

IV 연구 결과

1. 두 레이어로 구성된 하이브리드 형태의 Shallow Model 확립

본 연구에서 사용된 뉴런은 쥐 초기 배아의 대뇌피질 뉴런(Rat Primary Embryo Cortical Neuron)을 이용하였다. 사람의 체세포를 인위적으로 자극하여 모든 종류의 세포로 분화가능하도록 변화된 역분화줄기세포를 이용한 뉴런을 활용할 수 있는 기술이 최근 개발되었으나, 배양 비용이 매우 비싸며 및 배양 기간 또한 매우 길기 때문에 본 연구에서 이는 배제하였다. 반면 설치류 동물 뉴런의 경우 비용이 저렴하며 체외 배양 시 뉴런이 성숙되어 시냅스를 형성하는데 2주만 소요되어 배양 소요 기간도 짧다. 이러한 이유 때문에 신경망의 초기 모델링에는 설치류 동물 뉴런이 많이 사용되며, 본 연구에서도 이와 같은 이유로 설치류 동물 뉴런이 사용되었다.


먼저 뉴런은 두 종류의 플랫폼에 독립적으로 배양되었다. 하나는 유리 표면이고 다른 하나는 앞서 설명한 균질 뉴로스페로이드를 대량 생산할 수 있는 마이크로웰 어레이이다. 다른 하나는 마이크로웰 어레이이다. 마이크로웰 어레이에서 뉴로스페로이드가 형성되어 안정적인 구조를 갖게 되면, 그 중에 하나를 유리 위에서 성장 중인 2D 뉴로네트워크로 이송하여 모은다(Assembly). 이후 배양을 지속하면 뉴로스페로이드로부터 많은 수의 축삭신경돌기가 2D 뉴로네트워크로 뻗어나간다.(그림 24) 이처럼 어셈블리 된 Shallow Model을 2D 뉴로네트워크 영역을 전자현미경(SEM, Scanning Electron Microscope)으로 관찰하면 수많은 신경돌기들이 유리 표면을 덮고 있음을 확인할 수 있다.



* 출처 : (좌) 저자 작성, (우) 저자 연구 결과물

구체적으로 Shallow Model이 신경망으로 성숙할 정도로 배양됨을 면역염색법을 통하여 확인하였고, <그림 25a>에서 뉴로스페로이드로부터 2D 뉴로네트워크를 향하여 많은 수의 신경돌기가 방사형으로 뻗어나감을 확인하였다. 또한 <그림 25b>에서 축삭신경돌기의 경우 Shallow Model 영역 전반에 뻣뻣하게 성장하였음을 확인할 수 있다. 특히 특정 단백질의 세포 내 분포를 관찰할 수 있는 면역염색법으로 시냅스를 관찰한 결과, 평균 직경 $1\mu\text{m}$ 의 시냅스들이 Shallow Model 전 영역에 생성되었음을 확인하였다.<그림 25c> 이 결과들을 통하여 뉴로스페로이드와 2D 네트워크간의 어셈블리는 Shallow Model을 충족한다는 것이 명확해졌다.

그림 25. Shallow Model의 온전한 형성을 확인하기 위한 면역염색을 이용한 형광 이미지

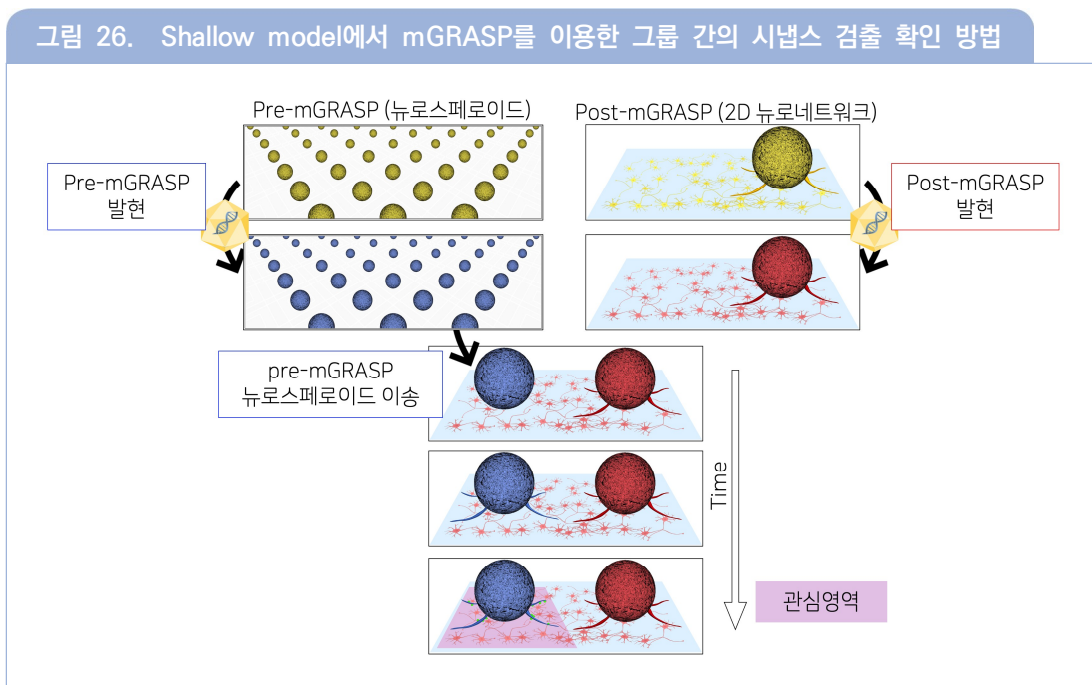


* 출처 : 저자 연구 결과물

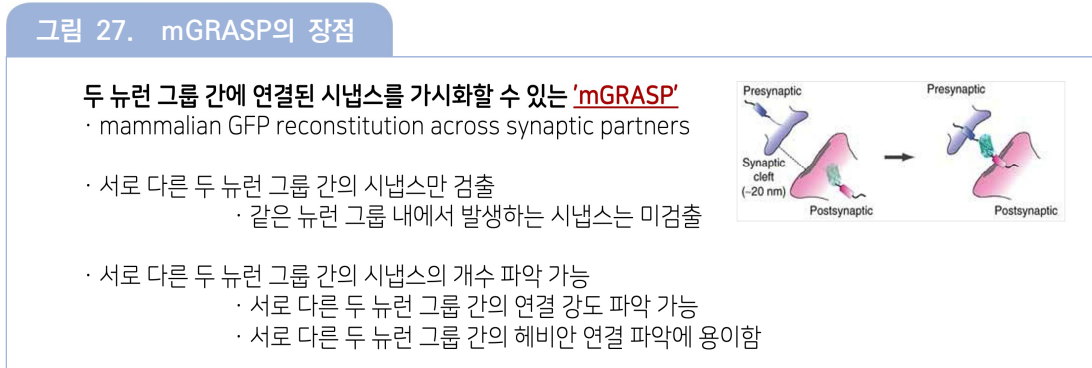
2. mGRASP의 도입

어셈블리 전 단계에서 뉴로스페로이드와 2D 뉴로네트워크는 독립적으로 존재한다. 따라서 이 시기에는 뉴로스페로이드와 2D 뉴로네트워크에 서로 섞이지 않고 독립적인 물질 처리가 가능하다. 이를 응용하여 뉴로스페로이드에는 pre-mGRASP를 발현하는 유전자를 전달하는 바이러스(Virus)를 처리하고, 2D 뉴로네트워크에는 post-mGRASP를 발현하는 유전자를 전달하는 Virus를 처리한다. 이후 뉴로스페로이드와 2D 뉴로네트워크를

어셈블리하여 두 그룹 간의 시냅스만을 확인할 수 있게 된다. 뉴로스페로이드 뉴런끼리의 시냅스, 2D 뉴로네트워크 뉴런끼리의 시냅스는 mGRASP 신호에 나타나지 않는 장점이 있다. <그림 26, 27> 본 연구 기간에서는 어셈블리 이전에 필요한 독립적인 Virus 처리의 최적화를 진행하였다.



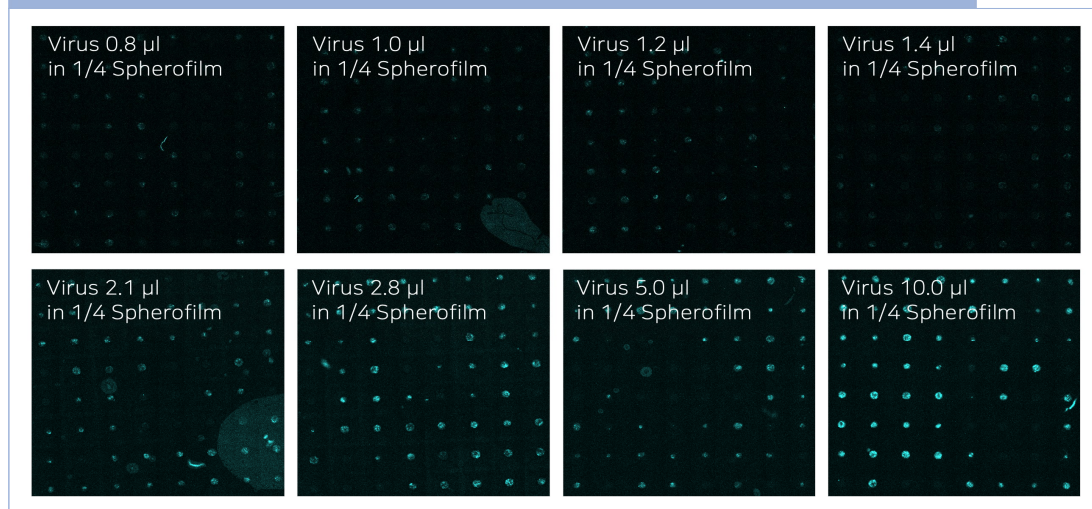
* 출처 : 저자 작성



* 출처 : (그림) Kim et al. (2012), (글) 저자 작성

Pre-mGRASP 유전자 전달 Virus는 마이크로웰 어레이(Spherofilm)에 투여하여 각 뉴로스페로이드에서 발현된다. 마이크로 웰 어레이에 뉴런을 담고 일주일 이 지나면 뉴로스페로이드가 형성된다. 이 때 Virus를 처리하였으며, 추가 1주일 배양 후 일부 뉴로스페로이드를 유리 표면 위로 이송하였다. 마이크로웰 어레이의 뉴로스페로이드들 중 이송되지 않은 뉴로스페로이드들은 최적화 비교를 위하여 마이크로 웰 어레이에서 계속 배양되었다. <그림 28>은 pre-mGRASP 유전자 전달 Virus 처리 3주 후에 같은 조건에서 형광 이미징한 결과를 나타낸다. Virus액 10 μ l를 마이크로웰 어레이에 처리한 조건에서 pre-mGRASP가 가장 발현이 잘 되었다는 것을 확인하였다.


그림 28. 마이크로웰 어레이에서의 pre-mGRASP 바이러스 전달체 최적화 결과



* 출처 : 저자 연구 결과물

<그림 29>는 virus액 10 μ l 조건의 뉴로스페로이드를 2D 유리 위로 이송한 후 배양한 결과를 나타낸다. 많은 수의 pre-mGRASP 단백질을 발현하는 축삭돌기신경들이 뉴로스페로이드로부터 뿔어 나온 것을 확인할 수 있다.(하얀 화살표)


그림 29. Pre-mGRASP 뉴로스페로이드로부터 뻗어나온 축삭신경돌기들(화살표)



* 출처 : 저자 연구 결과물

Post-mGRASP 유전자 전달 Virus는 유리 표면 위의 2D 뉴로네트워크에 처리하였다. 유리 표면 위에 뉴런을 부착하고 일주일 이 지나면 시냅스가 아직 존재하지 않는 미성숙한 2D 뉴로네트워크가 형성된다. 이 때 Virus를 처리 하였으며, 추가 2주 배양 후 형광 이미징으로 최적화 비교를 진행하였다. 그 결과, Virus액 5 μ l를 1ml의 배양액에 섞어서 처리한 조건에서 post-mGRASP가 가장 발현이 잘 되었다는 것을 확인하였다. Virus가 너무 적으면 발현 정도가 낮고, Virus가 너무 많으면 뉴런의 생존 능력이 떨어지는 현상이 나타난다.(그림 30)


그림 30. 2D 뉴로네트워크에서의 post-mGRASP 바이러스 전달체 최적화 결과



출처 : 저자 연구 결과물

Virus액 5 μ l를 1ml의 배양액에 섞어서 처리한 조건에서, post-mGRASP 발현하는 세포들이 뉴런이 맞는지 추가 검증을 진행한 결과, post-mGRASP를 발현하는 세포 대부분이 뉴런이 맞는 것으로 확인되었다 (하얀 화살표, 뉴런만을 염색하는 NeuO 마커와 post-mGRASP와의 일치 확인).〈그림 31〉

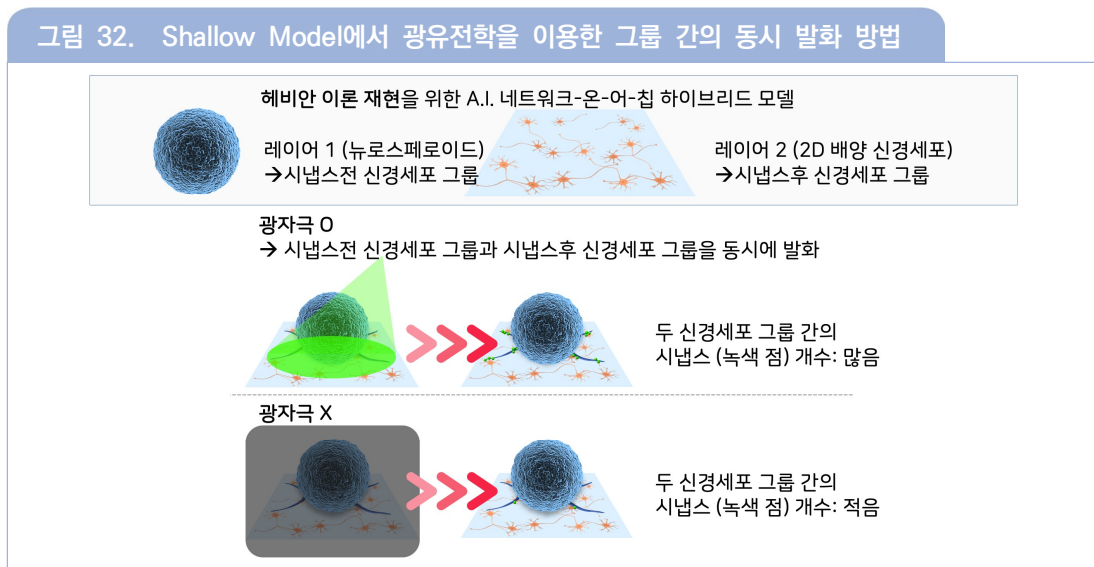
그림 31. 2D 뉴로네트워크 상의 post-mGRASP 발현 세포가 뉴런이 맞음을 확인한 결과(화살표 참고)



출처 : 저자 연구 결과물


3. 광유전학 단백질의 도입

‘함께 발화하는 뉴런은 서로 연결된다(Fire together, wire together)’로 요약되는 헤비안 학습을 Shallow Model에서 검증할 수 있도록 하기 위해서는 뉴로스페로이드와 2D 뉴로네트워크가 동시에 발화하도록 해야 한다. 이를 위하여 뉴로스페로이드와 2D 뉴로네트워크의 어셈블리 이후에 광유전학 단백질 유전자 전달 Virus를 처리한다. 이후 광유전학 단백질이 Shallow Model의 전 뉴런에 발현될 때까지 배양하면, 광 자극에 의하여 뉴로스페로이드와 2D 뉴로네트워크가 동시에 발화할 수 있게 된다.<그림 32>



본 연구 기간에서는 mGRASP없는 Shallow Model 어셈블리에 광유전학 단백질 유전자 전달 Virus를 처리한 후 광 자극에 따른 반응 분석을 실시하였다. 이 때 사용된 광유전학 단백질은 채널로돕신(Channelrhodopsin)에 형광단백질이 달려있는 것을 사용하였다. 채널로돕신 단백질은 푸른 빛에 의해서 개폐되는 이온 채널이다. 형광단백질은 뉴런 내에 광유전학 단백질이 발현되었는지 여부를 알려준다. 배양 결과, Shallow Model 전 뉴런에 녹색 형광이 발현하였으며, 이는 Shallow Model 전 뉴런에 광유전학 단백질이 발현하였음을 의미한다. <그림 33a> 이러한 광수용체 단백질이 발현된 Shallow Model을 이용하여 광 반응 현상을 실시간 세포 내 칼슘 이온 농도 어세이(Real-time Intracellular Calcium Ion Concentration Assay)를 이용하여 분석하였다.<그림 33b> 그 결과, 빛 자극이 없을 때에 비하여 빛 자극이 있을 때 Shallow Model 전 영역에서 동기화된 반응이 활발해짐을 확인하였다.<그림 33c>

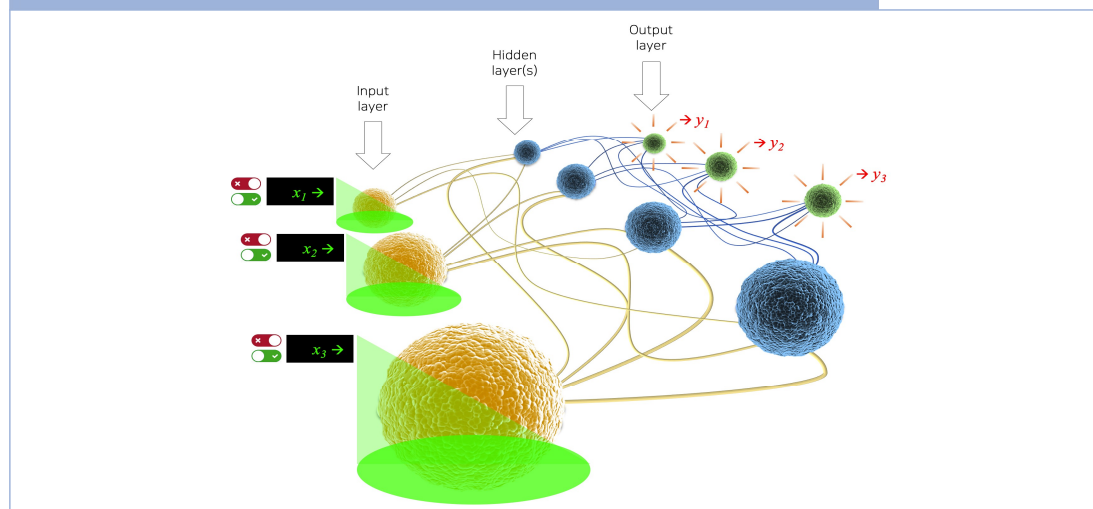
그림 33. 채널로돕신을 Shallow Model에 발현 후 광 자극에 반응함을 확인한 결과



4. AI 네트워크-온-어-칩 개발을 위한 후속 연구 방안

Shallow Model에서의 살아있는 뉴런을 이용한 헤비안 이론의 이해를 증진하기 위해 수행한 본 연구의 후속 연구로써 ‘뉴로스페로이드, 미세공학 플랫폼 그리고 광유전학’의 융합으로 Deep 인공지능망을 모사하는 주제를 상정할 수 있다. 여기에는 ‘AI 네트워크-온-어-칩’의 입력 및 출력의 최적화 연구가 수반된다. 나아가 간단한 구조로 작동된다고 알려진 인공지능망 구조 및 입출력을 ‘AI 네트워크-온-어-칩’에서 재현함으로써 본격적인 인공지능-신경과학의 융합연구가 출범할 것이다.<그림 34>

그림 34. 후속 연구계획으로써 Deep Model을 이용한 인공지능망 모사



* 출처 : 저자 작성

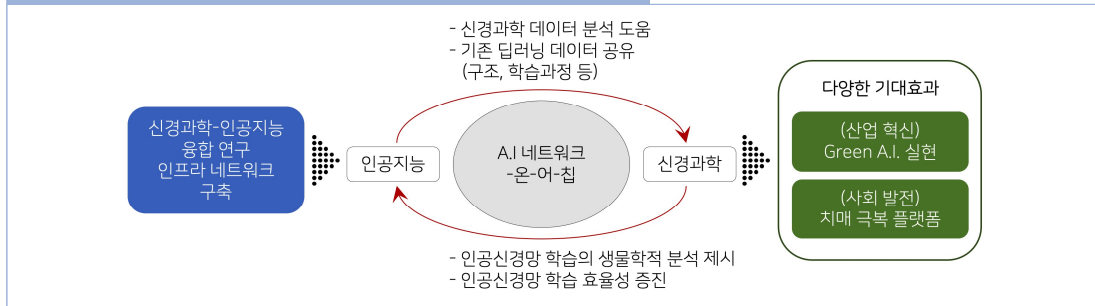
V 향후 인공지능망과 두뇌 신경망의 융합연구 활성화 과제 및 전망

1. 융합연구 활성화 과제

인공지능의 발달에 따른 탄소발자국의 급격한 증가와 같은 산업적, 사회적 문제에 대응하기 위하여 새로운 융합연구의 활성화가 그 방안이 될 수 있다. 본 연구는 '현재의 큰 화두들인 인공지능과 신경과학을 융합할 수 있는 새로운 개념 및 방법론은 무엇인가?'라는 연구문제와 함께 그 대안으로 가능한 'AI 네트워크-온-어-칩'에 관하여 논의하였다. 이와 함께 'AI 네트워크-온-어-칩'의 초기 단계의 가능성을 실증하였다. 즉, 본 연구는 인공지능과 신경과학의 융합연구 활성화의 필요성에 대한 중요도를 상기하고 그 방안을 마련하였다는 데에 의미가 있다.

나아가 이 새로운 융합연구 분야는 더욱 발전될 여지가 있으며, 이를 위해서는 '인공지능-신경과학 연구자들의 융합연구를 촉진할 수 있는 인프라 네트워크 구축'으로부터 시작될 수 있다. 이후 'AI 네트워크-온-어-칩'을 포함한 다양한 형태의 인공지능-신경과학 융합 플랫폼을 통하여, 그동안 분리되었던 인공지능 연구자와 신경과학 연구자 간의 언어가 통합될 수 있다. 이는 두 분야의 연구자들 서로에게 긍정적인 영향을 줄 것이다 (Helmstaedter, 2015). 예를 들어 인공지능 분야는 신경과학 분야로 복잡한 데이터 분석에 도움을 줄 수 있으며, 기존의 성공적인 결과를 낸 인공지능망의 구조 및 학습과정을 신경과학 분야에 공유하여 두뇌 신경망의 구조 및 학습과정을 유추하는데 도움을 줄 수 있을 것이다. 신경과학 분야는 인공지능 분야로 인공지능망 학습과정의 생물학적 분석을 제시하여 학습 효율성을 증진시키는데 도움을 줄 수 있을 것이다. 이러한 두 분야의 융합연구는 서로 선순환을 유도하여 산업적, 사회적, 학문적으로 다양한 기대효과를 유도할 수 있다. <그림 35>

그림 35. 인공지능-신경과학 융합연구 활성화 방안



* 출처 : 저자 작성

2. 융합연구 활성화 전망

‘AI 네트워크-온-어-칩’과 같은 인공지능-신경과학 융합연구는 산업적, 사회적, 학문적으로 다양한 분야에서의 발전을 유도할 수 있다. 이 기대효과를 인공지능 측면, 신경과학 측면으로 나누어 설명한다.(그림 36)

그림 36. 인공지능-신경과학 융합연구의 기대효과



출처 : 저자 작성

2.1. 인공지능으로의 적용 전망

헤비안 학습과 같은 학습 기전을 실제 뉴런을 이용하여 증명함으로써, 인공신경망의 작동 기전을 생물학적으로 설명할 수 있게 된다. 이는 그 동안 미지의 영역이었던 인공신경망 학습 모델의 원리를 설명할 수 있을 것이다. 나아가 더욱 정교하고 효율적인 학습 모델을 제시할 수 있을 것으로 기대한다. 이는 궁극적으로 현 학습 과정의 수많은 연산 과정으로 인하여 많은 양의 탄소발자국을 남기고 있는 Red AI를 Green AI로 전환하는데 기여하여, 정부의 2050 탄소중립 정책에 도움을 줄 것이다.

2.2. 신경과학으로의 적용 전망

그 동안 신경과학의 많은 발전이 있었으나, 두뇌 신경망의 복잡성으로 인하여 학습 및 기억 기전에 있어 세포 수준의 기전은 밝히지 못하고 있다. 하지만 'AI 네트워크-온-어-칩'이 개발되어 살아있는 뉴런을 이용한 학습이 가능한 뉴런 신경망 모델을 제시한다면, 세포 수준에서의 학습 및 기억 기전을 이해하는 데 큰 역할을 할 것이다.

또한 'AI 네트워크-온-어-칩'이 학습 및 기억이 가능하다면, 이와 관련된 질병을 생각해 볼 수 있다. 앞서 설명한 사람의 줄기세포를 이용한 뉴런을 획득하는 방법과 관련하여, 알츠하이머병 환자의 줄기세포를 이용하면 알츠하이머병을 가진 사람 뉴런을 얻을 수 있다(방석영 & 김홍남, 2020; Bang et al., 2021b). 이런 치매 질병 뉴런을 이용하여 'AI 네트워크-온-어-칩'을 제작한다면, 일반 뉴런에 비하여 학습 및 기억 능력이 떨어지는 뉴런 신경망이 될 것으로 기대된다. 이러한 새로운 치매 신경망 플랫폼은 치매 관련 신약 테스트 베드로써 사용이 가능할 것이며, 이는 정부의 치매국가책임제 중 치매 연구개발(R&D) 정책에 도움을 줄 것이다.

VI 결론

최근 인공지능의 학습 효율성 증진의 필요성이 대두되고 있으며, 그에 따라 인공지능의 작동 원리에 대한 근본적 이해 증진 연구에 대한 관심이 높아지고 있다. 따라서 고효율 학습 모델인 두뇌 신경망에 대한 관심이 함께 높아지고 있다. 하지만 아직 인공지능을 설명하는 언어와 두뇌 신경망을 설명하는 언어 간에는 큰 차이가 존재하며 여전히 그 간극이 좁혀지지 못하고 있다. 따라서 인공지능과 두뇌 신경망을 융합할 수 있는, '두뇌를 모사하고자 하는 인공지능'이라는 난제에 Grand Challenge할 수 있는 새로운 연구 방법을 필요로 한다.

이에, 미세공학, 뉴로스페로이드, 유전자 전달체 바이러스, mGRASP, 광유전학 단백질 등 개별적으로도 연구 가치가 뛰어난 다양한 최선의 과학적 기술들을 융합하여, 인공지능-신경과학 융합 플랫폼인 'AI 네트워크-온-어-칩'을 제안하였다. 인공지능의 노드를 3차원 뉴런 집합체인 뉴로스페로이드로 치환 시에 발생하는 다양한 인공지능 모사에 관한 장점들을 논의하였다. 특히, 인공지능의 이론적 토대가 되는 헤비안 학습이론을 뉴로스페로이드를 포함한 체외 뉴런 신경망으로 검증할 수 있음을 논의하였으며, 이 때 필요한 mGRASP, 광유전학 등의 다양한 최신 기술들을 본 플랫폼에서 실증해보았다.

나아가 'AI 네트워크-온-어-칩'을 포함한 인공지능-두뇌 신경망 융합연구를 활성화하기 위한 과제와 인공지능-두뇌 신경망 융합연구를 통해서 얻을 수 있는 다양한 산업적, 사회적, 학문적 기대효과들을 고찰하였다.

저자_ **방석영**(Seokyoung Bang)

• 학력

서울대학교 기계항공공학 박사
서울대학교 기계항공공학 학사

• 경력

現) 한국과학기술연구원 뇌과학연구소 Post-Doc

참고문헌

〈국내문헌 : 가나다순〉

- 1) 김선중 (2017). 자연모사를 이용한 4차 산업혁명 창의적 문제 해결 방법론. 융합연구리뷰 (KIST 융합연구정책센터), pp. 4-43.
- 2) 김한성 (2019). PEST-SWOT-AHP 방법론을 활용한 융합연구 활성화 방안에 관한 연구 - ICT 융합연구를 중심으로 - 융합연구리뷰 (KIST 융합연구정책센터), pp. 4-43.
- 3) 방석영 & 김홍남(2020). 퇴행성 뇌질환 모델링을 위한 두뇌모사칩. 기계저널 (대한기계학회), pp. 39-43.
- 4) 오유경 (2010). 유전자 전달 기술. News & Information for Chemical Engineers (화학공학소재연구정보센터), pp. 189-192.

〈국외문헌 : 알파벳순〉

- 5) Abbott, A. (2015). Crumb of mouse brain reconstructed in full detail. Nature News, 524, 17.
- 6) Azevedo, F. A., Carvalho, L. R., Grinberg, L. T., Farfel, J. M., Ferretti, R. E., Leite, R. E., Filho, W. J., Lent, R., and Herculano-Houzel, S.(2009). Equal numbers of neuronal and nonneuronal cells make the human brain anisometrically scaled-up primate brain. Journal of Comparative Neurology 513, 532-541.
- 7) Bang, S., Hwang, K. S., Jeong, S., Cho, I. J., Choi, N., Kim, J., and Kim, H. N. (2021a). Engineered Neural Circuits for Modeling Brain Physiology and Neuropathology. Acta Biomater, 132, 379-400.
- 8) Bang, S., Lee, S., Choi, N., and Kim, H. N. (2021b). Emerging Brain-Pathophysiology-Mimetic Platforms for Studying Neurodegenerative Diseases: Brain Organoids and Brains-on-a-Chip. Advanced Healthcare Materials, 2002119.
- 9) Bear, M., Connors, B., and Paradiso, M.A. (2020). Neuroscience: Exploring the Brain, Enhanced Edition: Exploring the Brain (Jones & Bartlett Learning).
- 10) Boyden, E. S., Zhang, F., Bamberg, E., Nagel, G., and Deisseroth, K. (2005). Millisecond-timescale, genetically targeted optical control of neural activity. Nature Neuroscience, 8, 1263-1268.
- 11) Brooks, R., Hassabis, D., Bray, D., and Shashua, A. (2012). Is the brain a good model for machine intelligence? Nature, 482, 462-463.

- 12] Cooper, S. J. (2005). Donald O. Hebb's synapse and learning rule: a history and commentary. *Neuroscience & Biobehavioral Reviews*, 28, 851–874.
- 13] Dabney, W., Kurth–Nelson, Z., Uchida, N., Starkweather, C.K., Hassabis, D., Munos, R., and Botvinick, M. (2020). A distributional code for value in dopamine–based reinforcement learning. *Nature*, 577, 671–675.
- 10] Helmstaedter, M. (2015). The mutual inspirations of machine learning and neuroscience. *Neuron*, 86, 25–28.
- 11] Herstatt, C., and Kalogerakis, K. (2005). How to use analogies for breakthrough innovations. *International Journal of Innovation and Technology Management*, 2, 331–347.
- 12] Kato–Negishi, M., Tsuda, Y., Onoe, H., and Takeuchi, S. (2010). A neurospheroid network–stamping method for neural transplantation to the brain. *Biomaterials*, 31, 8939–8945.
- 13] Kim, J., Zhao, T., Petralia, R. S., Yu, Y., Peng, H., Myers, E., and Magee, J. C. (2012). mGRASP enables mapping mammalian synaptic connectivity with light microscopy. *Nature methods*, 9, 96–102.
- 14] Lim, S. (2021). Hebbian learning revisited and its inference underlying cognitive function. *Current Opinion in Behavioral Sciences* 38, 96–102.
- 15] Lynch, M. A. (2004). Long–term potentiation and memory. *Physiological reviews* 84, 87–136.
- 16] Motta, A., Berning, M., Boergens, K. M., Staffler, B., Beining, M., Loomba, S., Hennig, P., Wissler, H., and Helmstaedter, M. (2019). Dense connectomic reconstruction in layer 4 of the somatosensory cortex. *Science*, 366.
- 17] O'Connell, T. P., and Chun, M.M. (2018). Predicting eye movement patterns from fMRI responses to natural scenes. *Nature Communications*, 9, 1–15.
- 18] Park, J. W., Vahidi, B., Taylor, A.M., Rhee, S. W., and Jeon, N.L. (2006). Microfluidic culture platform for neuroscience research. *Nature Protocols*, 1, 2128–2136.
- 19] Rosellini, A., Freer, G., Quaranta, P., Dovere, V., Menichini, M., Maggi, F., Mazzetti, P., and Pistello, M. (2019). Enhanced in vitro virus expression using 3–dimensional cell culture spheroids for infection. *Journal of Virological Methods*, 265, 99–104.
- 20] Schwartz, R., Dodge, J., Smith, N. A., and Etzioni, O. (2020). Green ai. *Communications of the ACM*, 63, 54–63.

- 211** Seo, Y., Bang, S., Son, J., Kim, D., Jeong, Y., Kim, P., Yang, J., Eom, J. H., Choi, N., Kim, H. N. (2021). Brain physiome: A concept bridging in vitro 3D brain models and in silico models for predicting drug toxicity in the brain. *Bioactive Materials*.
- 221** Strubell, E., Ganesh, A., and McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *arXiv preprint*.
- 231** Takahashi, M., Sugiyama, A., Wei, R., Kobayashi, S., Fukuda, K., Nishino, H., Takahashi, R., Tsutsumi, K., Kita, I., and Ando, K. (2020). Hyperactive and impulsive behaviors of LMTK1 knockout mice. *Scientific Reports*, 10, 1–13.
- 241** Talwalkar, A. (2020). AI in the 2020s Must Get Greener – and Here’s How The push for energy efficient “Green AI” requires new strategies. In *IEEE Spectrum*.
- 251** Tang, J., Yuan, F., Shen, X., Wang, Z., Rao, M., He, Y., Sun, Y., Li, X., Zhang, W., and Li, Y. (2019). Bridging biological and artificial neural networks with emerging neuromorphic devices: fundamentals, progress, and challenges. *Advanced Materials*, 31, 1902761.
- 261** Taylor, A. M., Blurton-Jones, M., Rhee, S. W., Cribbs, D. H., Cotman, C. W., and Jeon, N.L. (2005). A microfluidic culture platform for CNS axonal injury, regeneration and transport. *Nature Methods*, 2, 599–605.
- 271** Zhou, Y., Dong, F., Kong, D., and Liu, Y. (2019). Unfolding the convergence process of scientific knowledge for the early identification of emerging technologies. *Technological Forecasting and Social Change*, 144, 205–220.

〈기타문헌〉

- 281** <https://www.statista.com/statistics/607716/worldwide-artificial-intelligence-market-revenues/>
- 291** <https://developer.nvidia.com/deep-learning/>
- 301** <https://medium.com/mlait/getting-started-with-neural-networks-ff506e445f45>
- 311** <https://towardsdatascience.com/everything-you-need-to-know-about-activation-functions-in-deep-learning-models-84ba9f82c253/>
- 321** <https://braininitiative.nih.gov/strategic-planning/acd-working-groups/brain-initiative%C2%AE-20-cells-circuits-toward-cures/>

- 33) <https://neurology.duke.edu/about/news/how-does-nihs-alzheimers-boost-research-funding-impact-search-cure/>
- 34) <https://www.nhlbi.nih.gov/news/2018/coming-age-gene-therapy-review-past-and-path-forward>



02

건축물 화재 시 본능적 행동 반응에 기초한 피난경로 선택 특성 연구 - 가상현실(Virtual Reality) 실험을 기반으로 -

한기성(고려대학교 도시재생협동과정 박사과정생)

I 서론

1. 연구의 배경

1.1. 연구의 필요성

재난사고는 사회 전 분야의 엄청난 발전에도 불구하고 최근에도 우리 주변에서 끊임없이 발생하고 있다. 특히, 화재 사고는 다양한 기술 도입과 여러 제도적인 노력에도 다양한 시설에서 발생하고 있다. 화재통계에 따르면 건축, 구조물화재의 발생 건수가 2019년 한해 26,025건으로 전체 화재의 64.9%의 비중을 차지하고 있으며, 그에 따른 피해는 사망자 216명(75.8%), 부상자 1,777명(79.7%), 재산피해액 5,528억 원(64.3%)으로 화재 유형 중 매년 가장 큰 규모로 발생하고 있다. 산업사회의 지속적인 발전과 고도화를 고려하면 사회적, 경제적 피해는 계속해서 증가할 것으로 예측된다(소방청, 2019).

이에 대해, 건축물 계획·설계 시 재난사고를 대비한 인명 안전의 확보를 주안점으로 두고, 성능 위주 설계(PBD, Performance Based Design)를 의무적으로 시행하고 있다. 인명 피해와 연관되는 피난 안전성¹⁾에 대해서는 건축물 계획단계에서 화재 및 피난 시뮬레이션을 활용해 피난소요시간(RSET, Required Safe Egress Time), 피난가능시간(ASET, Available Safe Egress Time) 등으로 평가하고 있다. 평가는 특정 화재 상황에 대한 시나리오 설정, 에이전트(Agent, 행위자)의 속성값을 입력하고 시뮬레이션을 수행하여 평가 기준이 되는 데이터를 얻을 수 있으며, 이를 기반으로 건축물의 공간구조에 대한 안전성을 검토하고 조정하는 등의 수정 및 보완사항을 제시하는 근거로 활용된다.

건축 계획과정에서 계획안에 대한 여러 가지 평가와 결정을 위한 기준이 되는 중요한 요소 중 하나가 인간의 행동이다. 즉, 건물을 이용하는 사람에게 부적합한 부분이 있는지 사전에 검토해 봄으로써 인간행동이라는

1) 피난 안전성 평가는 피난소요시간(RSET, Required Safe Egress Time)이 피난가능시간(ASET, Available Safe Egress Time) 이하가 되는지 평가하는 과정으로 RSET은 재실자의 성별, 연령 구성 등의 특성과, 보행속도, 피난경로의 효율성, 안전구획까지의 거리와 같은 인자들에 의하여 계산되며, ASET은 피난에 영향을 미치는 조건으로 화재시나리오에 의해 산출된 플래시오버 시간, 특정 높이까지의 연기 층 하강시간 등을 의미한다.

관점에서 평가하게 된다(이강훈, 1997). 이를 바탕으로 피난 안전성을 평가하는 수단으로 활용되는 시뮬레이션은 신체규격, 속도 등 일부 인간 속성이 반영된 에이전트의 피난 행동을 평가하고 있으나, 현재 상용화된 피난 시뮬레이션들 가운데 대표적인 것으로 알려진 Simulex나 Building Exodus 등도 정적인 기술적인 환경에서의 피난 행동을 주로 다루고 있으며, 동적인 환경요소에 대한 인간의 인지기반 행동 예측 모델은 고려되지 않고 있다(ER Galea, 2006).

다시 말해, 이는 실제 화재 시 대피자가 어떻게 화재를 인식하고 정보를 수집하여 피난을 개시하고, 어떠한 행동으로 어느 경로를 선택하여 이동하는지 등의 인간행동 및 환경 반응에 대한 메커니즘이 반영되어 있지 않아, 이는 생사와 직접 관련이 있는 피난을 평가하는 부분에 있어서 데이터의 신뢰성 오류를 지닌 것으로 볼 수 있다. 또한, 아직까지 이러한 시뮬레이션의 단점을 보완하기 위하여 이를 뒷받침할 수 있는 검증된 피난 행동 및 예측 모델 등 또한 미흡한 실정이다(박재성, 2004).

화재와 같은 비상상황에서 인간행동을 예측하는 것은 건축물 방재 공학에서 매우 어려우면서도 가장 중요한 분야 중 하나이며, 인간행동에 관한 정보는 화재가 자주 발생하지 않고, 발생 환경이 매우 다양하기 때문에 이를 일반화하는 것은 더욱 어렵다(박재성 윤명오, 2004). 또한 윤리적·현실적 문제로 실제와 같은 화재 상황을 구현하여 실증하는 것은 쉬운 일이 아니며, 기존 피난 행동의 이론적 배경이 되는 관련 연구에서도 화재 사고 조사, 피해자 진술 등만을 기초로 이루어져 화재·피난 분야의 발전에 여러 한계가 존재하며, 외국자료를 모사하는 수준에 머무르고 있다. 특히, 화재 시 행동에 관한 국내 연구는 일부 연구자에 국한되어 이루어지고 있다.

보다 안전한 건축물 내 피난 환경을 구축하고 그에 대한 안전성을 평가하는데 있어 신뢰도를 더욱 높이기 위해서는 화재 상황에 대한 피난 행동, 반응을 이해하고 예측하는 것이 필수적이다. 어떠한 경우에 어떤 행동이 나타나고 어떠한 요소가 얼마나 영향을 미치는지 등의 피난 행동에 대한 실증적 근거를 마련하고, 피난 행동 및 경로선택에 대해 예측할 수 있는 체계화된 이론 모델을 개발하기 위해 새로운 연구 방법이 요구된다. 특히, 지하공간이나, 다중이용시설 같은 익숙하지 않은 환경에서 사람들의 행동과 반응에 초점을 맞춘 더 많은 연구가 수행되어야 한다(Cosma, 2014).

최근 이러한 연구 방법적 한계를 극복하기 위한 시도로 도입·적용하고 있는 기술이 가상현실(VR, Virtual Reality)이다. 이 기술은 실재감, 몰입감을 제공할 수 있어 의료, 건설, 교육 등 다양한 분야에 활용되고 있으며, 그에 대한 활용 및 효과에 대한 실증을 통해 범위를 점차 확장해 가고 있다(Zhu et al., 2020; Liu et al., 2020). 특히, 현실과 유사한 환경조건과 상황을 가상공간에서 구현하고 다양한 요소를 통제할 수 있는 특징과

HMD(Head Mounted Display, 머리 탑재형 디스플레이) 장비를 통해 가상환경에서 실제와 같이 반응하고 행동하는 인간의 특징은 인간공학적 연구에서 보다 심도 있는 연구를 수행할 수 있어 기대를 불러오고 있다. 이를 활용하여 본 연구에서 살펴보고자 하는 실제상황과 같은 화재 발생 환경에서 인간의 본능적이고 직관적으로 빠른 상황판단과 인지 반응에 대한 실증 실험을 통하여 기존 이론 모델을 재검토 및 재규명하여 건축물 화재 상황에서 인간의 행동 특성을 더욱 구체적이고 논리적으로 파악할 수 있을 것이다.

1.2. 연구의 목적

본 연구에서는 화재 시 인간 행동 특성에 대한 검증을 위해 기존 연구의 한계를 보완하고, 결과의 신뢰도를 높이고자 이론상의 본능적 경로선택 행동에 기초하여 실제와 유사한 가상의 공간을 구현하고 가상현실 장비를 활용하여 피험자를 대상으로 실증 실험을 수행하였다. 이러한 실험을 통해 공간 및 시각적 조건에 따른 경로선택 특성 등을 파악하고 이론적 경로선택 모델을 재규명함으로써 재실자의 피난행동을 예측할 수 있는 논리적 근거를 마련하는데 본 연구의 목적이 있다. 이러한 기초 하에 향후 가상현실 기술을 활용하여 피난 과정에서 나타나는 의사결정 프로세스와 경로선택에 영향을 미치는 환경적 요인들을 도출하고 상황에 따라 나타나는 피난 경로선택 행동 모델을 개발하기 위한 기초를 마련하는 것을 궁극적인 목표로 한다.

II 연구방법 및 연구모형

1. 연구방법 및 연구모형

1.1 연구의 방법 및 범위

건축물에서 화재가 발생할 경우 재실자가 어떤 행동과 반응을 보이는지 파악하기 위한 가장 일반적인 방법으로는 실제 화재 사고를 조사한 보고서 등을 통한 피난 행동을 분석하는 방법과 일정 조건의 상황 및 일부 공간 환경을 구현하여 피험자를 대상으로 실험을 수행하는 방법이 있다. 또한, 특정 시설에서 이동하는 사람들의 흐름 및 행동 등을 관찰하고 측정하여 군집 행동을 분석하는 방법 등이 있다. 피난 행동을 일으키는 요소 중 피난 경로를 선택하는 특성을 해석하기 위한 방법으로는 과거 발생한 화재 사고 후 조사된 자료나 일정 조건에서의 실험을 통한 방법이 가장 많이 이용되고 있다.

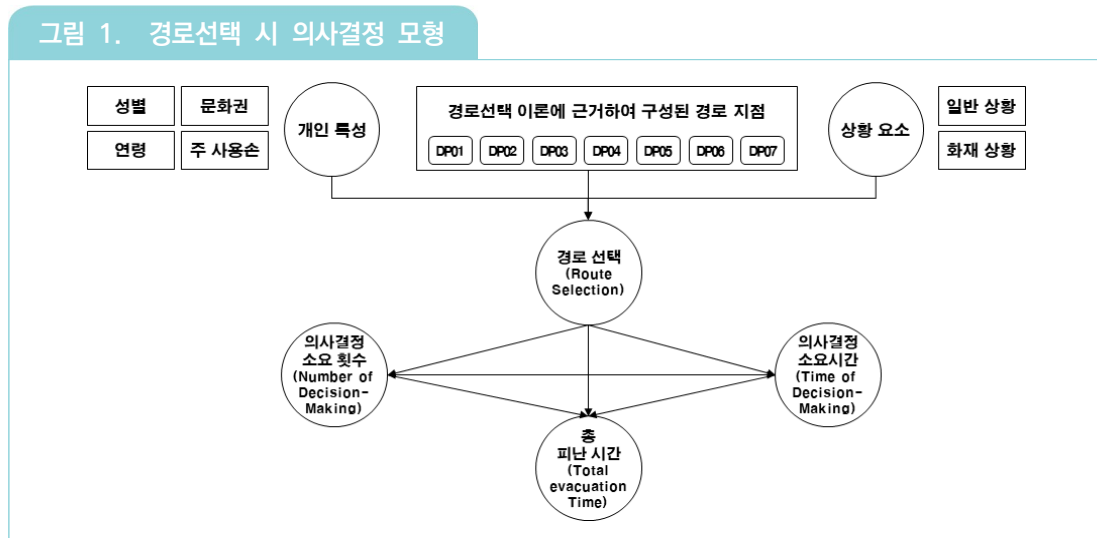
피난 경로를 선택할 때는 본능적인 행동 반응에 의해서, 또는 합리적인 의사결정을 바탕으로 선택이 이루어진다. 본 연구에서는 이론상으로 밝혀져 있는 본능적 피난 경로선택 행동에 기초하여 구성된 경로를 가상의 건축물로 구현하여 피험자 1명이 대피하는 상황을 연출하였으며, 그에 대한 행동 및 반응을 측정하는 실험을 실시하였다. 비상상황에서 환경요소의 자극에 대한 개별적인 반응들이 어떻게 발전되는지 면밀히 살펴볼 필요가 있다 (Canter, 1984).

본 연구에서는 가상의 단독 피난행동 실험을 통해서 피난개시 이후 출구를 찾아 이동하는 과정에서 나타나는 피험자의 경로선택 행동의 특성, 공간적 상황에 따른 경로선택의 특성, 피난 성능을 평가하는 지표인 피난 시간 등을 중심으로 조사하여 분석하고자 한다. 또한, 본 연구에서는 귀소본능과 추종본능이 발현되지 않는 상태에서의 피난 경로선택 특성을 파악하고자 한다.

1.2. 연구모형

인지심리학적 관점에서 인간 개인의 행동은 의사결정 과정의 결과로 볼 수 있다. 개인의 의사결정 과정이 본능, 경험, 그리고 한정적 합리성의 세 가지 기본 관습을 따른다고 추측한다. 개인은 각자가 직면하는 특정 상황에 따라서 이러한 기본 규칙을 하나 또는 조합하여 선택할 수 있다(Pan et al., 2007). Elisangela, et al.(2014)는 복도 너비, 밝기, 피난유도 형태, 그리고 상황(Everyday vs Emergency)에 따라 경로선택의 차이가 있다고 하였다. 또한, Almeida, et al.(2017)은 위험요소(화재, 연기), 피난유도등 설치, 개인특성(성별, 연령) 등에 따라 경로선택의 차이가 있음을 밝혔다. 또한, Zhu et al. (2020)은 중국, 미국, 영국에서의 문화적 차이에 따른 비상상황에서의 경로선택, 피난시간 등의 차이를 살펴보고, Vasudevan & Son(2011)은 피난 시간, 이동거리, 의사결정 횟수, 의사결정 시간, 본능적 결정 횟수 등의 변수에 대해 인간(Human)과 행위자(Agent)의 비교 연구를 수행하였다.

위의 연구들을 통해서 상황적 요소와 개인 특성에 따라 환경에 대한 인지 경로선택이 다르고 그것이 본능적 경로선택 행동에 기초하여 구성된 공간에서 각 경로선택 지점에서 의사결정 시 소요되는 두리번거림 횟수, 그리고 의사결정 소요시간은 정적인 관계가 있을 것으로 추측된다. 또한, 경로를 선택하는 상황에서 이루어지는 의사결정 과정(행동-반응), 즉 의사결정 시 소요되는 두리번거림의 횟수와 시간이 길어질수록 총 피난 시간은 증가한다는 것을 유추할 수 있어, 아래 <그림 1>과 같은 모형을 설정할 수 있다.



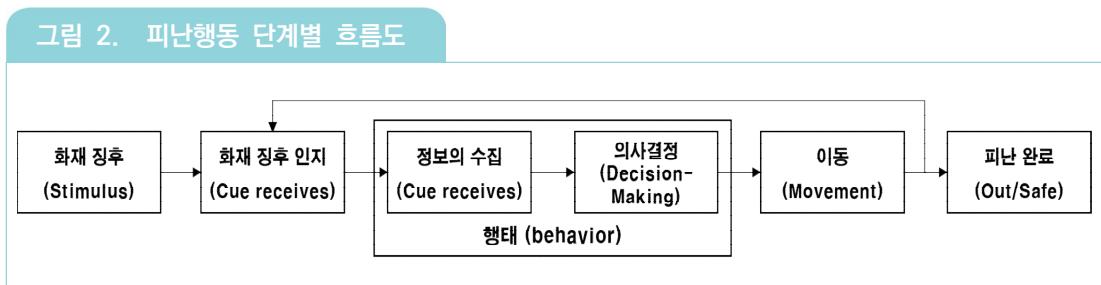
* 출처 : 저자 작성

III 피난 행동에 관한 이론적 고찰

1. 피난 행동에 관한 이론적 고찰

1.1 피난 행동의 정의 및 개념

피난은 화재와 같은 비상상황 시 건물 외부 등 보다 안전한 장소로 이동하는 행위를 의미하며, 피난 행동은 건축물 또는 구조물에 대한 공간적 조건, 화재의 확산과 시간의 흐름이라는 상황적 조건 속에서 그에 대응하며 안전한 장소로 이동하는 피난의 주체인 인간의 행동이다. 이는 시간의 흐름과 함께 화재, 인간, 공간 등 관련 요소의 상호작용에 의해 정상적/비정상적, 효율적/비효율적인 특성에 따라 다양하게 진행된다. 또한, 화재로부터의 새로운 징후 및 정보에 따라 행동 단계를 새롭게 결정해야 하는 지속적인 과정이다. <그림 2>는 화재가 발생하고 이를 인지하여 피난을 완료하기까지의 피난행동단계를 단순 개념화하여 구성한 것이다(건축방재론, 2017).



* 출처 : 건축방재론(2017), 저자 재구성

피난행동에 대한 개념화된 과정을 보면, 피난은 화재가 발생하고 난 후, 피난을 수행하는 주체인 재실자는 발생한 화재에 대한 징후를 인지하고 그에 대한 정보를 수집, 해석하는 단계를 거쳐 화재 발생에 대한 정보를 전달, 소방서에 통보, 화재를 소화 또는 피난 개시, 인지한 징후를 무시하는 등의 다양한 형태의 의사결정을

하게 된다. 피난에 대한 직접적인 행동 단계인 이동이 이루어지는 경우, 자신이 이동하려고 생각했던 피난 경로가 연기에 의하여 사용할 수 없게 되는 등 새로운 상황이 발생하게 되면 이동 단계의 전 단계, 또는 전전 단계로 되돌아가는 단계적 피난 행동이 이루어졌다(박재성, 2004).

1.2. 화재 시 피난 행동에 관한 이론적 고찰

1.2.1. 피난 행동 이론

피난 행동에 대한 이론들은 앞서 언급한 단계적 피난 행동에 따라 구분되어 다루어졌다. 특히, 피난개시 전 행동 시간(Pre-movement Time)에 대해서 몇몇 연구에서는 피난의 지체를 발생시키지만, 이동하는데 필요한 시간보다 더 중요한 요소라고 밝혔다(Sime, 1994; Proulx, 1994; Fahy, 1994). 특히, Bryan(1999)은 건물 내 재실자가 알람이나 경보 신호를 감지하고 그것을 인지하고 해석하여 경보나 화재 신호가 자신에게 실제 위협이 되는지 여부를 판단하는 과정에서 무엇을 할 것인지를 결정하기 위해 사용하는 과정은 6가지 기본 구성 요소(Recognition, Validation, Definition, Evaluation, Commitment, Reassessment)로 이루어져 있다고 주장한다. Canter(1984)는 사람들이 새로운 상황에 노출될 때 특히, 위협이나 화재와 같은 비상 시에 지속적인 의사결정을 하고 이를 이해하는 것이 중요하다고 언급하고 있다. 피난을 개시하기 전까지 사람들은 그 순간에 자신이 이용할 수 있는 정보를 평가하고, 그런 다음 더 많은 정보를 수집하거나 대피하거나 소화하는 행동을 한다. 그리고 상황에 대한 이해는 끊임없이 발전한다. 화재 또는 다른 상황에 대한 새로운 정보를 얻을 때마다 새롭게 얻게 된 정보로 의사결정 과정을 진행한다. 이렇듯, Canter(1984)는 처음 취한 결정이 이동 과정에서 계속해서 변경된다는 것에 대해 언급하고 있다.

이와 같은 맥락에서, 최원영, 이경희(1988)는 인간이 주변 환경과의 상호작용에서 끊임없이 자극을 받고 그에 대해 반응하며 행동하는 환경지각-인지-반응과정에 대한 이론을 근거로, 피난행태 예측을 위한 이론적 모델을 제시하였다. 시간을 변수로 다양하게 진행되는 피난행태를 동적으로 해석하였으며, 재실자의 피난행태는 매시간 주변의 사회적, 물리적 환경의 지각 - 정보해석 및 의사결정 - 행동의 연속적인 과정을 통해 진행되고 특히, 공간이동에 대한 의사결정은 주변 환경에 대한 정보 및 안전대피에 대한 내적 욕구를 바탕으로 한 인지적 가치치에 의해 진행되는 확률적 추정방법으로 예측될 수 있다고 하였다.

박재성(2004)은 화재 시 재실자의 피난행동에 관해 선행연구, 화재사례, 피난 행동 실험 등의 분석을 통하여 국내 다중이용 건축물의 피난환경에 적합한 피난예측모델을 예측 가능한 결정적 요인을 중심으로 해석하였으며, 건축물 용도별 피난대상 인원의 산정 및 화재 발생에서 피난개시까지 경과된 시간, 재실자 유형 및 공간적

조건에 따른 피난경로 및 출구의 선택, 군집보행에 따른 피난 경로별 보행속도 등으로 피난예측모델의 범위를 제한하였다.

1.2.2. 환경 인지 이론

피난 행동은 일반상황에서와 달리 화재와 같은 비상상황이 발생하면 사람들은 타인과의 일반적인 행동 및 상호 교류가 되지 않을 수 있는, 처음 접하거나 예측할 수 없는 상황을 접하게 되며, 특히 익숙하지 않은 환경에서 일상적인 판단의 행동이 어렵다(Kuligowski, 2011). 일반상황과 다른 행태를 보이는 화재 상황에서의 행동들은 사례가 많지 않을 뿐 아니라 실증연구로도 분석하기 어렵고 복잡하다. 이러한 인간의 행동을 연구하기 위해 유용한 이론들이 이전부터 개발되어 왔으며, 그중 하나가 어포던스 이론(Theory of Affordances)이다. 어포던스 이론은 사람들이 어떻게 사물을 인지하고 어떻게 특정한 장치의 기능을 해석하는지에 대한 설명을 제공하기 위해, 1977년 깁슨(Gibson)에 의해 처음 소개된 이론이다.

이 이론은 몇 년 후 깁슨(Gibson, 1979년)에 의해 수정되었는데, 그는 사물이 사람들에게 무엇을 제공하거나 제공할 수 있는지에 대한 개념을 도입하고 확장했다. Hartson(2003)은 물체가 사용자에게 제공할 수 있는 다른 어포던스의 4가지 분류를 도입함으로써 깁슨(Gibson)에 의해 제안된 원래 이론을 수정했다. 이러한 분류는 다음과 같이 요약할 수 있다.

- 감각적 어포던스(Sensory Affordance): 물체의 디자인은 사람이 물체를 인지하는 것을 도와야 한다. 즉, 물체를 쉽게 보거나 듣거나 느낄 수 있어야 한다.
- 인지적 어포던스(Cognitive Affordance): 물체의 설계는 사용자가 기기의 기능성과 사용 목적을 이해하는 데 도움이 되어야 한다.
- 물리적 어포던스(Physical Affordance): 물체는 사용자가 어떤 일을 하는 데 도움을 주도록 설계되고, 최종 목표를 달성하기 위해서 사용자의 큰 노력을 요구하지 않아야 한다.
- 기능적 어포던스(Functional Affordance): 목표는 사용자의 최종 목표를 달성해야 한다.

화재 및 피난 안전 공학에서 어포던스 이론은 특히 인간행동 분야에서 사용되어 왔다(Nilsson, 2009; Nilsson, 2014). 이 이론은 특정 환경요소의 설계의 긍정적 영향 여부 또는 환경요소의 적절성 여부를 설명하기 위해 사용된다. 어포던스 이론이 요소의 설계와 병행하여 단계별로 진행되기 때문에 해당 요소의 최상의 성능을 달성하기 위해 이 이론의 기본원리를 이해하는 것은 중요하다고 할 수 있다(Cosma, 2014).

이렇듯 비상상황에서 사람들이 피난행동에 대한 의사결정을 어떻게 내리는가 하는 문제는 환경지각/인지 심리학 측면에서의 인간의 정보지각 및 해석과정으로 설명될 수 있다(최원영, 1988). 환경인지를 통한 정보의 해석과정에서는 각 개인의 주관적인 판단이 매우 중요하게 작용한다. 즉, 인간은 모든 환경자극을 완전하고 정확하게 지각, 경험할 수 없기 때문에, 그에 관한 판단은 확률적 추정을 통한 최선의 선택(Best Bet)만이 가능하다는 것이다(Brunswick, 1967, 최원영, 1988, 재인용). 그렇기 때문에, 피난 상황에서 환경요소의 자극에 대한 개별적인 반응들이 어떻게 발전되는지 면밀히 살펴볼 필요가 있다(Canter, 1984). 오랜 시간 지체된 후 소방구조가 이루어지는 지하공간이나, 다중이용시설과 같은 익숙하지 않은 환경에서 환경요소에 대한 사람들의 행동과 반응에 초점을 맞춘 연구가 더 많이 수행되어야 한다(Cosma, 2014).

1.3. 기존 연구의 고찰

경로선택 행동에 관한 연구는 과거부터 문헌 고찰, 화재 대피훈련, 예고하지 않은 소방 훈련, 실제 시설 실험 등 꾸준히 수행되어 왔으나, 그 수에 있어서 미흡한 실정이었다. 하지만 2000년대 들어오면서 가상의 컴퓨터 시뮬레이션이 가능해짐에 따라 다양한 측면에서 점차 늘어나는 추세이다.

1.3.1. 본능적 경로선택 행동에 관한 연구

Bryan(1995)은 일련의 연구를 수행했는데, 피실험자의 약 1/3에게서 나타나는 길 찾기 도움 없이 연기가 가득한 환경으로 계속 나아가는 대신 되돌아가는 위험회피성과 길찾기 도움을 통한 계속적으로 전방으로 나아가려는 직진성에 대해 관찰하였다.

이강훈(1997)은 평상시의 인간행동 습성과 건물 화재사례에서 나타난 인간의 피난행동 패턴에 대해서 문헌을 통해 고찰하고, 피난로 설계 시 적용 가능한 구체적인 설계방법을 제시하였다. 특히, 본능적 피난 행동에 근거한 경로선택에 대해서 왔던 길을 되돌아가려는 귀소성, 일상적으로 사용하는 익숙한 경로를 찾으려는 일상동선 지향성, 밝고 넓은 곳으로 향하는 향광성 및 향개방성, 처음 눈에 들어온 곳을 향하는 일시경로 선택성, 가장 가까운 거리를 선택하려는 지근거리 선택성, 정면 통로를 선택하거나 막다른 곳이 나올 때까지 직진하려는 직진성, 약간의 연기만 있어도 그곳을 피하려는 본능적 위험회피성, 다수의 사람들이 피난하는 곳으로 쫓아가려는 부화뇌동성(군집추종성) 등으로 설명하였다. 또한, 일반적으로 인간은 오른손잡이가 많고, 왼쪽보다 오른손과 오른발이 발달했기 때문에 좌회본능이 나타난다고 말하고 있다. 그의 다른 연구에서는 고층 건축물에서 피난 실험을 통해 오른손잡이의 경우 좌회전 계단을 사용할 때 편리함을 느끼고 대피하는 속도가 빠르며, 왼손잡이는 우회전 계단을 사용할 때 편리함을 느끼고 빠르다는 것을 밝혔다(이강훈, 1998).

Shields & Boyce(2000)는 매장 4곳의 예고 없이 급작스러운 화재 대피 상황을 통해 피실험자에게 친숙도 및 짧은 경로선택이 중요한 요소임을 주장하며 이에 대해 피난 모형에 필히 넣어야 함을 주장하였다.

박재성(2004)은 대규모 판매시설에서 피험자를 대상으로 한 피난행동 실험을 통해, 출발지점에서 피난행동을 개시한 후 최초로 경로선택을 하는 대표적인 행동패턴은 피험자가 서있는 자세에서 시각적 범위 내에 인지되는 경로 중 하나를 본능적 직감에 의해서 선택하여 피난 출구를 찾아 이동하는 것으로 설명하였다. 또한, 특징인은 근거리 및 일상 동선에 위치한 경로를 선택하게 되며, 불특정인의 경우 추종성과 귀소성에 의해서 경로를 선택하는 경향이 강하게 나타나지만, 공간 규모가 크고, 교차점이 많을수록 경로 인지능력이 저하되어 귀소성이 약해진다고 하였다.

Kobes et al.(2010)은 실제 호텔에서 밤에 화재 경보를 울림으로써 소방훈련을 실시하였고, 연기 유무, 피난유도등 설치 위치, 유도등 밝기 등에 따른 경로선택의 차이를 비교하였다. 그 결과, 연기가 감지되지 않을 때 피난 경로에 대한 사전 조사는 출구 선택과 강한 상관관계가 있으나, 연기가 감지될 때는 사전 검사는 출구 선택에 영향을 미치는 것처럼 보이지만, 상관관계는 연기가 감지되지 않을 때 만큼 강하지 않다고 하였다.

1.3.2. 가상현실을 활용한 경로선택에 관한 연구

최근 들어 가상현실 기술의 진보와 더불어 피난행동 연구에서도 점차 이를 활용한 화재 상황에 대한 연구가 진행되고 있다. Chiewchengchol et al. (2011)은 피난 시뮬레이터를 개발하여 귀소 본능에 초점을 맞춰 실험을 진행하였다. 구조물에 익숙하지 않은 피험자 50%는 귀소성을 나타냈으나, 나머지 50%는 새로운 피난 경로를 찾았다. 귀소성을 나타낸 실험자 46.6%는 피난표지나 다른 대피자를 보아도 귀소성을 나타낸 반면, 나머지 53.5%는 표지 또는 다른 대피자를 따라 새로운 경로로 피난하였다.

Vasudevan & Son(2011)은 피난 안전과 생산성을 동시에 고려하는 제조 시설에 대하여 이론 모델과 행위자(Agent)와의 시뮬레이션과 가상현실 실험을 진행하였다. 그 결과, 출구 구성, 화재 강도, 그리고 피난 개시 위치가 피험자의 반응에 주요 영향을 미치고 혼잡(Congestion)은 피난 시간과 비선형(Non-linear) 영향 관계가 있음을 언급하였다.

Vilar et al.(2013)은 비상상황 시 경로선택에 대한 환경적 특징들의 영향에 관한 연구에서 복도 교차로의 형태 속성, 즉 너비, 밝기에 대한 영향력에 대한 가상현실 실험을 수행하였다. 총 57가지의 다른 복도 구성에 대해서 사람들은 F, T 형태 경로에서 모두 밝은 경로를 따라가는 것을 선호하였으며, T 형태 경로에서는 넓은 경로를 따르는 것으로 나타났다. 또한, 그의 다른 연구에서는 일반상황과 비상상황을 비교하여 일반

상황에서 피난표지가 없는 경우 피험자들은 주로 넓고 밝은 복도를 선택하였으나, 이와 대조적으로 피난표지가 있을 경우에는 표지에 크게 의존하는 반면 비상상황 시 표지가 없을 때는 교차로 형태 경로에 의한 영향이 큰 것으로 나타났다.

Almeida et al.(2017)는 가상현실에서의 비상 시 피난 시나리오에 따른 인간 행동에 대한 실험을 진행하였으며, 방에서 문을 통해 나오기 전에 피난 표지판, 복도의 연기, 화재, 가상현실 사람들의 피난 방향 등의 시나리오를 설정하였다. 그 결과, 설문 시와 실제 실험 간 차이, 남성과 여성 간의 경로선택 차이가 있는 것으로 나타났다.

Zhu et al.(2020)의 연구에서는 건축적 시각적 접근성에 따른 비상 시 길 찾기에 대하여 가상현실 실험을 수행하였다. 또한, 중국, 영국, 미국 간 문화적 차이에 대해서 비교 분석하였다. 그 결과, 건물의 공간적 특성과 디자인 전략은 피험자들은 방향적 선택에 영향을 주었다. 미국, 영국 참가자들은 균중을 피해 대피하는 경향을 보인 반면, 중국 피험자들은 균중을 따라가는 경향이 큰 것으로 나타났다.

IV 가상현실 피난 경로선택 실험 및 결과

1. 가상현실 피난 경로선택 실험

본 연구에서 수행한 피난 경로선택 실험은 1명의 피험자가 가상의 복잡한 공간구조에서 단독으로 사전에 설정된 방의 출발지점에서 피난 행동을 개시한 후 피난 출구를 찾아 이동하는 과정을 관찰·측정하는 실험이다. 또한, 참가자 대상 사전 사후 설문 조사를 통해 개인특성 및 경로선택 과정에서의 행동 결정 요인에 대해서 파악하였다.

1.1. 실험환경 제작 및 참가자 구성

1.1.1. 실험환경 제작

실험에 사용된 가상 건축물의 공간 구조는 앞에서 소개한 이론에서 밝혀진 화재 시 재실자의 피난 경로선택 행동을 기초로 하여 공간을 구성하였다. 경로 형태는 다른 본능적 경로선택 행동이 발현되지 않도록 구성하였다(예, T 형태 좌회성이 있을 수 있다는 전제하에 향광성의 창문은 우측 복도에 설치하였다). 선행연구 및 건축물 설치규정 내 계획 기준을 기반으로 기본적인 경로 너비(1.2m), 길이(10m), 높이(2.4m)로 설정하고, +, T, F 형태의 경로를 조합하여 경로를 구성하였다.


모든 경로선택 지점을 포함하여 경로를 구성함에 있어서 다음과 같은 기본적인 두 가지 원칙이 있다. 1) 모든 경로는 선택지점에서 나누어진 이후 다시 만나지 않도록 구성한다. 경로가 다시 만나게 되면 이동한 경로로 다시 돌아오거나 통제를 잃어버릴 수 있다. 2) 경로선택 이후 경험하게 되는 환경(경로구성)은 동일한 구성을 경험할 수 있도록 설계한다.

실험환경 제작을 위해 Autodesk사의 2018 AutoCad를 사용하여 공간을 설계하였고, 3D Modeling 소프트웨어인 Blender를 통하여 3D 모델을 제작하였다. 제작된 3D 모델을 Unity3D로 가져와(Import) 가상의 환경을 구현하였다. 비상상황과 일반상황으로 구분하여 제작이 되었으며, 비상상황은 실재감을 위하여 실험시작과

함께 폭발음이 커지도록 설정하였으며, 이후 비상 알람벨이 울리도록 설정하였다. 또한, 점멸등(Flickering light)을 통하여 비상등이 깜빡이는 효과를 통하여 실재감을 높였다.

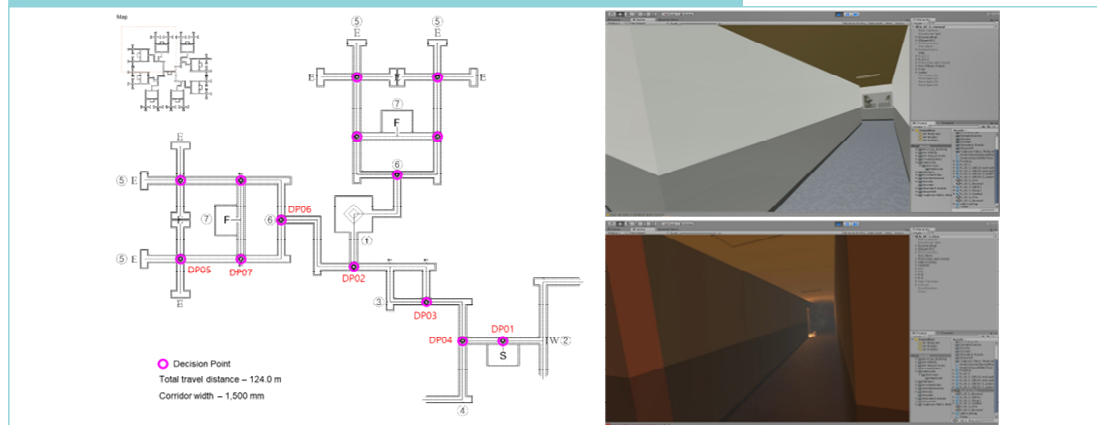
가상현실 실험에 사용된 장비는 가상환경 제작 및 구동을 위한 VR Ready PC와 HMD 장비인 HTC VIVE이다. HMD는 가상 내 공간을 현실에서와 같이 시선과 머리 움직임을 통해 자유롭게 볼 수 있는 특징이 있다. 또한, 공간의 제약으로 인해 실제 구성된 실험환경에서 이동할 수 없는 점을 고려하여 HTC VIVE Controller 사용하여 이동을 구현하였다.

그림 3. 본능적 경로선택에 기초한 경로 구성



* 출처 : 저자 작성

그림 4. 각 경로선택 지점을 조합한 경로 구성 및 실험환경



* 출처 : 저자 작성

1.1.2. 참가자 구성

본 실험에서는 문화권의 차이에 따라 피난 시의 행동 차이를 살펴보기 위해 국가 간 실험으로 진행되었고 참가자는 캐나다 British Columbia주의 Kamloops 지역에 거주하는 43명과 한국 수도권에 거주하는 44명으로 총 87명이 실험에 참여하였다. 실험은 캐나다에서 2019년 9월에, 한국에서 2020년 2~4월에 진행되었다. 실험 참가자의 인구 사회학적 특성은 <표 1>과 같다.

표 1. 참가자 인구통계학적 요인

Variable(변수)		N	%
Exp_nation(국적) (n=87)	South Korea(한국)	44	50.6
	Canada(캐나다)	43	49.4
Gender(성별) (n=87)	Male(남)	57	65.5
	Female(여)	30	34.5
Age_grp(연령) (n=87)	20s(20대)	70	80.5
	30s(30대)	13	14.9
	40s(40대)	4	4.6
Main hand(주 사용손) (n=87)	Right(오른손)	72	82.8
	Left(왼손)	10	11.5
	Ambidextrous(양손)	5	5.7



* 출처 : 저자 작성

한국의 실험참가자 수는 44명(50.6%), 캐나다의 실험참가자 수는 43명(49.4%)으로 차이가 거의 없고, 성별의 경우 남자는 57명(65.5%), 여자는 30명(34.5%)으로 남자 참가자가 여자 참가자보다 비율이 더 높았다. 또한, 실험참가자의 연령대는 20대 70명(80.5%), 30대 13명(14.9%), 40대 4명(4.6%) 순이었다. 주 사용 손의 경우 오른손 72명(82.8%), 왼손 10명(11.5%), 양손 5명(5.7%)이었다. 실제 왼손잡이는 전 세계 인구의 약 10% 정도이며, 양쪽 손 모두 자유로이 사용하는 사람인 양손잡이는 약 0.1%를 차지한다. 본 실험의 참가자도 낮은 비율을 나타내고 있다(Wikipedia).

1.2. 피난 경로선택 실험절차

1.2.1. 실험절차

실험은 크게 실험 참가동의서 작성, 참가자의 인구 사회학적 특성에 대한 사전 설문, 가상공간 내 이동 조각을 익히기 위한 연습, 본 실험, 가상현실 및 경로선택 행동 반응에 관한 사후 설문 총 5단계로 나눌 수 있다.

1.3. 본능적 경로선택 행동 및 반응에 관한 결과

본 연구는 SPSS 25 버전 통계 프로그램을 이용하여 분석하였다. 대상자의 인구통계학적 특성 등을 분석하기 위해 빈도분석(Frequency Analysis) 및 기술 분석(Descriptive Analysis)을 실시하였고, 주요 변수 간 상관관계를 살펴보기 위해 상관관계분석(Correlation Analysis)을 실시하였다. 각 모델에 대한 설명력과 매개효과를 검증하기 위해 다중회귀분석(Multiple Regression Analysis)을 실시하였다.

1.3.1. 상황(화재-일반)에 따른 경로선택 및 행동 반응 분석

1) 상황에 따른 경로선택 차이

전체 참가자의 본능적 경로선택 행동을 기반으로 하여 구성된 경로에서 화재 또는 일반상황에 따른 경로선택의 차이를 살펴보기 위하여 교차표를 산출하였다.〈표2〉

표 2. 상황(화재-일반)에 따른 경로선택 차이

Unit: Count (%)

Variable(변수)	Situation(상황)		Total(합계)	χ^2	p	
	Fire(화재)	Normal(일반)				
향광성 (DP01)	0: No window(창문 없음)	13 (14.9)	10 (11.5)	23 (13.2)	0.421	.502
	1: Window(창문 있음)	74 (85.1)	77 (88.5)	151 (86.8)		
향개방성 (DP02)	0: Same width corridor (기존과 동일 너비의 복도)	45 (51.7)	51 (58.6)	96 (55.2)	0.837	.360
	1: Wider corridor or large room (기존보다 넓은 복도 또는 공간)	42 (48.3)	36 (41.4)	78 (44.8)		
초기인지 경로 선택성 (DP03)	0: Subsequent seen route (화재 이후 인지 경로)	16 (18.4)	26 (29.9)	42 (24.1)	3.139	.076
	1: First seen route(화재 초기 인지 경로)	71 (81.6)	61 (70.1)	132 (75.9)		
지근거리 선택성 (DP04)	0: Long(긴 거리)	24 (27.6)	31 (35.6)	55 (31.6)	1.303	.254
	1: Short(짧은 거리)	63 (72.4)	56 (64.4)	119 (68.4)		
직진성 (DP05)	0: Left or Right(왼쪽 또는 오른쪽)	15 (17.2)	22 (25.3)	37 (21.3)	1.682	.195
	1: Straight(직진)	72 (82.8)	65 (74.7)	137 (78.7)		
좌회성 (DP06)	0: Right(오른쪽)	49 (56.3)	47 (54.0)	96 (55.2)	0.093	.760
	1: Left(왼쪽)	38 (43.7)	40 (46.0)	78 (44.8)		
위험회피성 (DP07)	0: Dangerous-fire, smoke (위험요소 유(有)-화재, 연기)	9 (10.3)	28 (32.2)	37 (21.3)	12.392***	.000
	1: No Dangerous(위험요소 무(無))	78 (89.7)	59 (67.8)	137 (78.7)		
Total(합계)		87 (100.0)	87 (100.0)	174 (100.0)		

* $p < .05$, ** $p < .01$, *** $p < .001$

* 출처 : 저자 작성

그 결과, 향광성(DP01)에 대해 살펴본 결과, 화재 상황에서 창문이 없는 경로를 선택한 참가자가 13명(14.9%), 창문이 있는 경로를 선택한 참가자가 74명(85.1%)으로 나타났고, 일반상황에서는 창문이 없는 경로를 선택한 참가자가 10명(11.5%), 창문이 있는 경로를 선택한 참가자가 77명(88.5%)으로 나타났다. 두 상황 모두에서 창문이 설치된 경로를 선택한 비율이 높게 나타났으며(F: 85.1%, N: 88.5%), 이는 화재 상황에서만 나타나는 것이 아닌 일반상황에서도 향광성의 경향을 보였다.

넓은 복도 또는 넓은 공간을 선택하는 향개방성(DP02)과 관련하여 화재 상황 시 기존에 이동하던 복도와 동일한 너비의 복도를 선택한 참가자는 45명(51.7%), 넓은 복도 또는 넓은 공간을 선택한 참가자가 42명(48.3%)으로 나타났고, 일반상황에서는 동일 너비의 복도를 선택한 참가자가 51명(58.6%), 넓은 복도 또는 공간을 선택한 참가자는 36명(41.4%)으로 나타나, 상황에 따라 넓은 복도나 개방적인 공간으로 향하는 경향이 뚜렷하게 나타나지 않았다.

처음 인지한 경로를 선택하는 행동을 살펴보는 초기인지 경로 선택성(DP03)에 대해서 살펴본 결과, 화재 상황 시 초기에 인지한 경로를 선택한 참가자가 71명(81.6%), 이후 인지한 우회 경로를 선택하는 참가자는 16명(18.4%)으로 나타났으며, 일반상황에서는 초기 인지한 경로를 선택한 참가자가 61명(70.1%), 이후 인지한 경로를 선택한 참가자는 26명(29.9%)으로 나타났다. 두 상황에서 모두 처음에 본 경로를 선택한 비율이 상대적으로 높게 나타났다.

가까운 거리를 선택하는 지근거리 선택성(DP04)에 대해서는 화재 상황에서 긴 거리의 경로를 선택한 참가자가 24명(27.6%), 짧은 거리의 경로를 선택한 참가자가 63명(72.4%)으로 나타났고, 일반 상황에서는 긴 거리의 경로를 선택한 참가자가 31명(35.6%), 짧은 거리의 경로를 선택한 참가자가 56명(64.4%)으로 나타났다. 이는 각 상황에서 모두 짧은 경로를 선택한 비율이 비교적 높게 나타났다.

十 형태의 교차로에서 직진성(DP05)에 대해 살펴본 결과, 화재 상황 시 좌, 우측 경로를 선택한 참가자가 15명(17.2%), 직진 경로를 선택한 참가자가 72명(82.8%)으로 나타났고, 일반상황에서는 좌, 우측 경로를 선택한 참가자는 22명(25.3%), 직진 경로를 선택한 참가자가 65명(74.7%)으로 나타났다. 두 상황에서 모두 직진 경로를 선택한 비율이 높게 나타나, 본능적 행동이 나타나는 것을 알 수 있었다.

화재-일반 상황에 따른 좌회성(DP06)에 대해 알아본 결과, 화재 상황에서 우측 경로를 선택한 수가 49명(56.3%), 좌측 경로를 선택한 수는 38명(43.7%)으로 나타났고, 일반상황에서 우측 경로를 선택한 참가자가 47명(54.0%), 좌측을 선택한 참가자가 40명(46.0%)으로 나타났다. 두 상황 모두 좌측 경로와 우측 경로를 선택한 비율의 차이가 크게 없었으며, 화재 상황에서 좌측 경로를 우선 선택하는 좌회성이 결과에서 나타나지는 않았다.

화재, 연기와 같은 위험요소 유무의 경로에 대한 선택 행동인 위험회피성(DP07)에 대해 알아본 결과, 화재 상황에서 화재, 연기와 같은 위험요소가 있는 경로를 선택한 참가자가 9명(10.3%), 위험요소가 없는 경로를 선택한 참가자가 78명(89.7%)으로 나타났고, 일반상황에서 연기가 있는 경로를 선택한 참가자가 28명(32.2%), 연기가 없는 경로를 선택한 참가자가 59명(67.8%)으로 나타났다. 두 상황에서 모두 위험요소가 없는 경로를 선택한 비율이 높게 나타나, 안전한 경로를 선택하는 것으로 확인되었다.

2) 상황에 따른 경로선택 시 의사결정 소요횟수, 소요시간 차이

화재상황과 일반상황에서 대피자의 경로선택 시 반응요소인 의사결정 소요횟수 즉, 각 경로를 살펴보는 두리번거림의 횟수, 의사결정 소요시간에서의 차이를 비교하기 위해 통계적 검증법인 독립표본 t-검정을 실시하였다. 먼저, 경로선택 시 상황에 따른 의사결정 소요횟수는 초기인지 경로 선택성(DP03)에서 유의한 차이를

보였는데($t=-2.353, p<.05$), 화재 상황($M=2.39$)에서 일반 상황($M=2.77$)보다 더 적게 나타났다. 좌회성(DP06)에서도 유의한 차이가 나타났는데($t=-3.809, p<.001$), 화재 상황($M=2.59$)에서 일반 상황($M=3.01$)보다 더 적게 나타났다. 또한, 의사결정 소요횟수의 합에서도 화재상황과 일반상황 사이에 유의한 차이가 있는 것으로 나타났는데($t=-4.061, p<.001$), 화재 상황($M=18.82$)에서 일반 상황($M=20.10$)보다 더 적게 두리번거림 것으로 나타났다. 반면에 향광성(DP01), 향개방성(DP02), 지근거리 선택성(DP04), 직진성(DP05), 위험회피성(DP06)에서는 각 상황에 따른 의사결정 소요횟수에 차이가 없는 것으로 드러났다.

그리고 각 본능적 경로선택 특성에서 평균 의사결정 소요횟수가 높게 나타난 경로선택 지점은 직진성(DP05)으로 화재상황($M=3.63$), 일반상황($M=3.70$)으로 나타났다. 이는 경로형태가 T자형 구조로 되어있어 두리번거림 횟수가 상대적으로 많은 것으로 판단된다.

표 3. 상황(화재-일반)에 따른 의사결정 소요횟수 차이

Variable		N	M	S.D.	t	p
향광성 (DP01)	Decision Number_01 (Fire)	87	2.91	0.757	-0.904	0.369
	Decision Number_01 (Normal)	87	3.01	0.946		
향개방성 (DP02)	Decision Number_02 (Fire)	87	2.39	0.783	0.495	0.622
	Decision Number_02 (Normal)	87	2.33	0.831		
초기인지 경로 선택성(DP03)	Decision Number_03 (Fire)	87	2.39	1.004	-2.353*	0.021
	Decision Number_03 (Normal)	87	2.77	1.128		
지근거리 선택성 (DP04)	Decision Number_04 (Fire)	87	2.45	0.774	-1.789	0.077
	Decision Number_04 (Normal)	87	2.63	0.809		
직진성 (DP05)	Decision Number_05 (Fire)	87	3.63	0.717	-0.485	0.629
	Decision Number_05 (Normal)	87	3.70	1.058		
좌회성 (DP06)	Decision Number_06 (Fire)	87	2.59	0.786	-3.809***	0.000
	Decision Number_06 (Normal)	87	3.01	1.126		
위험회피성 (DP07)	Decision Number_07 (Fire)	87	2.46	0.804	-1.615	0.110
	Decision Number_07 (Normal)	87	2.64	0.876		
Decision Number_Sum	Decision Number_Sum(Fire)	87	18.82	2.879	-4.061***	0.000
	Decision Number_Sum(Normal)	87	20.10	3.296		

* $p<.05$, ** $p<.01$, *** $p<.001$

* 출처 : 저자 작성

다음으로 경로선택 반응요소인 의사결정 소요시간에 있어서 7개의 경로선택 지점 모두에서 화재, 일반 상황에 따라 유의한 차이를 보이지 않았다. 다만, 각 지점에서 소요된 의사결정 시간의 합에서는 유의한 차이가 나타났고($t=-2.587, p<.05$), 화재 상황($M=15.02$)에서 일반 상황($M=16.10$)보다 더 적게 나타났다. 또한, 전체 피난시간에서도 의사결정 소요시간은 유의한 차이가 있었으며($t=-2.024, p<.05$), 화재상황($M=84.57$)에서 일반상황($M=88.59$)보다 더 적게 나타났다.

표 4. 상황(화재-일반)에 따른 의사결정 소요시간 차이

Variable		N	M	S.D.	t	p
항광성 (DP01)	Decision Time_01 (Fire)	87	2.20	1.08	0.881	0.381
	Decision Time_01 (Normal)	87	2.07	1.17		
항개방성 (DP02)	Decision Time_02 (Fire)	87	1.55	0.94	-1.851	0.068
	Decision Time_02 (Normal)	87	1.80	1.21		
초기인지 경로 선택성 (DP03)	Decision Time_03 (Fire)	87	1.53	1.06	-1.507	0.136
	Decision Time_03 (Normal)	87	1.75	1.46		
지근거리 선택성 (DP04)	Decision Time_04 (Fire)	87	2.51	1.40	-1.030	0.306
	Decision Time_04 (Normal)	87	2.72	1.56		
직진성 (DP05)	Decision Time_05 (Fire)	87	2.53	1.04	-0.169	0.866
	Decision Time_05 (Normal)	87	2.56	1.11		
좌회성 (DP06)	Decision Time_06 (Fire)	87	3.21	1.67	-1.524	0.131
	Decision Time_06 (Normal)	87	3.54	1.95		
위험회피성 (DP07)	Decision Time_07 (Fire)	87	1.49	1.04	-1.283	0.203
	Decision Time_07 (Normal)	87	1.66	1.16		
Decision Time_Sum	Decision Time_01 (Fire)	87	15.02	4.89	-2.587*	0.011
	Decision Time_01 (Normal)	87	16.10	5.96		
Total Evacuation Time	Decision Time_07 (Fire)	87	84.57	16.77	-2.024*	0.046
	Decision Time_07 (Normal)	87	88.59	18.09		

* $p<.05$, ** $p<.01$, *** $p<.001$

* 출처 : 저자 작성

1.3.2. 경로선택 시 의사결정 주요 변수 간 상관분석

본 연구의 주요 변수인 각 경로선택 지점에서의 의사결정 소요 횟수, 의사결정 소요 시간, 소요 횟수의 합, 소요 시간의 합, 총 피난시간 간의 상대적 영향력을 확인하기 위해 피어슨의 상관관계 분석(Pearson's Correlation Analysis)을 상황에 따라 구분하여 실시하였다.

1) 화재 상황에서 경로선택 시 의사결정 주요 변수 간 상관분석

화재 상황에서 상관분석 결과, 화재 상황에서 향광성 여부의 경로선택 지점에서 소요횟수(DNum_01)는 해당 지점의 소요시간(DTime_01)과 직접적 영향 관계는 없는 것으로 나타났으나, 소요횟수의 합(DNum_Sum)과 상관관계 중 $r=0.590$, $p<.001$ 으로 가장 높은 양(+)적 상관관계를 나타냈다. 그리고 소요시간의 합(DTime_Sum)과도 각 경로선택 지점에서의 소요횟수 중 상대적으로 가장 높은 양(+)적 상관관계를 나타냈다. 또한, 총 피난시간(Total ET)과는 낮은 양(+)적 상관관계를 보였다.

향개방성 여부의 경로선택 지점에서 소요횟수(DNum_02)는 소요횟수의 합(DNum_Sum)과의 상관관계 $r=0.471$, $p<.001$ 으로 높은 양(+)적 상관관계를 나타냈으며, 해당 지점의 소요시간(DTime_02), 소요시간의 합(DTime_Sum), 총 피난시간(Total ET)과는 관계가 없는 것으로 나타났다.

초기인지 경로선택 지점에서의 소요횟수(DNum_03)는 해당 지점 소요시간(DTime_03)과 $r=0.647$, $p<.001$ 으로 높은 양(+)적 상관관계를 보였으며 소요횟수의 합(DNum_Sum)과도 양(+)적 상관관계를 나타냈다. 반면, 소요시간의 합(DTime_Sum)과는 약한 양(+)의 상관관계를 나타냈다.

지근거리 선택성의 경로선택 지점에서 소요횟수(DNum_04)와 해당 지점 소요시간(DTime_04) 간 상관관계는 $r=0.596$, $p<.001$ 으로 가장 높은 양(+)적 관계를 나타냈으며, 소요횟수의 합(DNum_Sum), 소요시간의 합(DTime_Sum) 간에도 양(+)적 상관관계를 나타냈다. 총 피난 시간(Total ET)과는 $r=0.272$ 로 낮은 양(+)적 상관관계를 가진 것으로 나타났다.

직진성 경로선택 지점에서의 소요횟수(DNum_05)와 소요시간(DTime_05) 간의 상관관계는 $r=0.508$, $p<.001$ 으로 높은 상관관계를 나타냈고 소요횟수 합(DNum_Sum)과도 $r=0.569$, $p<.001$ 으로 높은 양(+)의 상관관계를 나타냈다. 반면, 소요시간 합(DTime_Sum)과는 $r=0.266$ 으로 약한 양(+)의 상관관계를 가졌다.

좌회성 여부의 경로선택 지점에서도 소요횟수(DNum_06)와 소요시간(DTime_06) 간의 상관관계는 $r=0.567$, $p<.001$ 으로 양(+)의 상관관계를 나타냈고, 소요횟수 합(DNum_Sum)과도 $r=0.454$, $p<.001$ 으로 높은 양(+)의 상관관계를 나타냈다. 반면, 소요시간 합(DTime_Sum)과는 $r=0.239$ 으로 약한 양(+)의 상관관계를 가졌다.

위험회피성에 대한 경로선택 지점의 소요횟수(DNum_07)와 소요시간(DTime_07) 간의 상관관계는 $r=0.554$, $p<.001$ 으로 양(+)적 상관관계를 나타냈다. 또한, 소요시간 합(DTime_Sum)과도 $r=0.380$ 으로 양(+)의 상관관계를 가졌다.

각 경로선택 지점에서 소요시간 사이의 영향 관계를 알아본 결과, 향광성 여부의 경로선택 지점에서의 소요시간(DTime_01)과 모든 경로선택 지점에서의 소요시간의 합(DTime_Sum) 간의 상관관계는 $r=0.425$,

$p < .001$ 으로 양(+)의 상관관계를 보였으며, 총 피난 시간(Total ET)과는 $r = 0.224$ 으로 약한 양(+)의 상관관계를 나타냈다.

향개방성의 소요시간(DTime_02)과 향광성의 소요시간(DTime_01)을 제외한 모든 시간요소 간에는 상관관계를 보였으며, 소요횟수의 합(DNum_Sum)과도 $r = 0.381$ 으로 양(+)의 관계를 나타냈다. 특히, 소요시간의 합(DTime_Sum)과는 상관관계 $r = 0.597$, $p < .001$ 으로 상대적으로 높은 양(+)의 상관관계를 보였으며, 총 피난 시간(Total ET)과도 $r = 0.407$ 로 양(+)의 상관관계를 나타냈다.

먼저 인지된 경로와 나중 인지된 경로에 대한 초기인지 경로선택성의 지점에서 소요된 시간인 DTime_03은 소요시간 합(DTime_Sum)과 상관관계 $r = 0.661$, $p < .001$ 로, 시간요소 간 상관관계 중 가장 높은 양(+)의 상관관계를 보였으며, 총 피난시간(Total ET)과도 $r = 0.436$ 으로 양(+)의 상관관계가 나타났다. 또한, 소요횟수의 합(DNum_Sum)과도 $r = 0.439$ 로 양(+)의 상관관계를 나타냈다.

지근거리 선택성의 소요시간(DTime_04)은 소요횟수 합(DNum_Sum, $r = 0.292$), 총 피난시간(Total ET, $r = 0.298$)과 낮은 양(+)의 상관관계를 보였으며, 소요시간 합(DTime_Sum)과의 상관관계는 $r = 0.565$, $p < .001$ 으로 상대적으로 높은 양(+)의 상관성이 나타났다.

직진성에 대한 경로선택 지점의 소요시간(DTime_05)은 소요시간 합(DTime_Sum) 간의 상관관계는 $r = 0.596$, $p < .001$ 으로 높은 양(+)의 상관관계를 보였고, 총 피난시간(Total ET)과 $r = 0.439$ 로 양(+)의 상관관계를 나타냈다. 또한, 소요횟수 합(DNum_Sum)과도 상관관계 $r = 0.420$, $p < .001$ 으로 양(+)의 상관관계를 보였다.

좌회성 선택 지점에서 소요시간(DTime_06)은 소요횟수의 합(DNum_Sum, $r = 0.342$, $p < .001$), 소요시간 합(DTime_Sum, $r = 0.644$, $p < .001$), 총 피난시간(Total ET, $r = 0.381$, $p < .001$)과 모두 양(+)의 상관관계를 나타냈다. 화재, 연기가 발생한 경로와 위험요소가 없는 경로에 대한 위험경로회피성 지점의 상관성 결과, 소요시간 합(DTime_Sum)과의 상관관계 $r = 0.660$, $p < .001$ 으로 상관관계 중 높은 양(+)의 상관관계를 보였으며, 소요횟수의 합(DNum_Sum, $r = 0.345$, $p < .001$), 총 피난시간(Total ET, $r = 0.517$, $p < .001$)과 관계에서도 양(+)의 상관성을 나타냈다.

각 경로선택 지점의 모든 의사결정 소요횟수의 합(DNum_Sum)과 소요시간의 합(DTime_Sum) 간 상관관계는 $r = 0.573$, $p < .001$ 으로 양(+)의 상관관계를 나타냈고, 총 피난 시간(Total ET)과의 사이에는 $r = 0.275$, $p < .001$ 으로 낮은 양(+)의 상관관계를 가졌다. 또한, 소요시간의 합(DTime_Sum)과 총 피난 시간(Total ET) 간에는 상관관계 $r = 0.640$, $p < .001$ 으로 상관관계 중 높은 양(+)의 상관성을 보였다.

표 5. 경로선택 시 주요 변수 간 상관관계 분석(화재 상황)

Pearson Correlation

Variables	DNum_01 (Fire)	DNum_02 (Fire)	DNum_03 (Fire)	DNum_04 (Fire)	DNum_05 (Fire)	DNum_06 (Fire)	DNum_07 (Fire)	DTime_01 (Fire)	DTime_02 (Fire)	DTime_03 (Fire)	DTime_04 (Fire)	DTime_05 (Fire)	DTime_06 (Fire)	DTime_07 (Fire)	DNum_Sum (Fire)	DTime_Sum (Fire)	Total Evacuation Time (Fire)
DNum_01 (Fire)	1																
DNum_02 (Fire)	0.140	1															
DNum_03 (Fire)	0.109	0.011	1														
DNum_04 (Fire)	0.131	0.015	0.161	1													
DNum_05 (Fire)	.387***	.342***	0.024	0.133	1												
DNum_06 (Fire)	0.072	0.190	0.104	0.060	0.119	1											
DNum_07 (Fire)	.357***	0.062	0.121	0.188	0.176	0.102	1										
DTime_01 (Fire)	0.096	.505***	-0.152	0.133	0.170	-0.017	0.019	1									
DTime_02 (Fire)	.540***	0.129	0.148	0.165	0.168	0.085	0.154	0.063	1								
DTime_03 (Fire)	.294***	-0.028	.647***	.224*	0.018	0.059	.224*	0.177	.300**	1							
DTime_04 (Fire)	0.194	0.013	-0.089	.596***	0.145	0.038	.221*	.307**	.249*	0.204	1						
DTime_05 (Fire)	.357***	0.024	.257*	0.160	.508***	0.053	0.166	0.076	.453***	.395***	0.189	1					
DTime_06 (Fire)	0.105	0.037	0.096	0.094	0.064	.567***	.270*	0.120	.266*	.290**	0.110	0.202	1				
DTime_07 (Fire)	.308**	-0.079	.214*	0.180	0.098	-0.013	.505***	0.046	.320**	.499***	0.198	.334**	.412***	1			
DNum_Sum (Fire)	.590***	.471***	.492***	.465***	.569***	.454***	.554***	0.188	.381***	.439***	.292**	.420***	.342***	.345***	1		
DTime_Sum (Fire)	.421***	0.135	.243*	.384***	.266*	.239*	.380***	.425***	.597***	.661***	.565***	.596***	.644***	.660***	.573***	1	
Total ET (Fire)	.232*	-0.086	0.183	.272*	0.193	0.034	0.156	.224*	.407***	.436***	.298**	.439***	.381***	.517***	.275**	.640***	1

DNum: Decision number, Dtime: Decision time, Total ET: Total evacuation time
 * P<.05, ** P<.01, *** P<.001

출처 : 저자 작성

2) 일반 상황에서 경로선택 시 의사결정 주요 변수 간 상관분석

일반 상황에서의 상관분석을 실시한 결과, 향광성에 대한 경로선택 지점에서 나타난 의사결정 소요횟수(DNum_01)와 소요시간(DTime_01) 간의 상관관계는 $r=0.354$, $p<.001$ 으로 양(+)의 상관관계를 보였고, 소요횟수와 소요횟수의 합(DNum_Sum) 간에는 $r=0.496$, $p<.001$, 소요시간의 합(DTime_Sum) 간에는 $r=0.376$, $p<.001$ 으로 양(+)의 상관관계를 가졌다.

향개방성의 경우, 의사결정 소요횟수(DNum_02)는 소요시간(DTime_02)과 유의한 상관관계를 보이지 않았으나, 소요횟수 합(DNum_Sum)과는 $r=0.497$, $p<.001$ 으로 양(+)의 상관관계를 나타냈고, 소요횟수와 소요시간의 합(DTime_Sum)은 $r=0.291$ 로 낮은 양(+)의 상관관계를 가졌다.

초기인지 경로선택성 지점에서의 소요횟수(DNum_03)와 소요시간(DTime_03) 간의 상관관계는 $r=0.594$, $p<.001$ 으로 양(+)의 상관관계를 나타냈으며, 소요횟수 합(DNum_Sum)과 $r=0.513$, $p<.001$, 소요시간 합(DTime_03)과는 $r=0.403$, $p<.001$ 으로 양(+)의 상관관계가 나타났다.

지근거리 선택성에 대한 경로선택 지점에서의 의사결정 소요횟수인 DNum_04와 소요 시간인 DTime_04 간의 상관관계는 $r=0.692$, $p<.001$ 으로 상관관계 중 높은 양(+)의 상관관계를 나타냈으며, 소요횟수의 합(DNum_Sum)과는 $r=0.372$, $p<.001$ 으로 양(+)의 상관관계가 나타났고, 소요시간의 합(DTime_Sum)과는 $r=0.309$, $p<.001$ 으로 상대적으로 낮은 양(+)의 상관관계를 가졌다.

직진성 여부에 대한 경로선택 지점에서의 의사결정 소요횟수(DNum_05)와 소요시간(DTime_05) 간의 상관관계는 $r=0.720$, $p<.001$ 으로 상관관계 중 높은 양(+)의 상관관계를 나타냈다. 그리고 소요횟수의 합(DNum_Sum)과는 $r=0.473$ 으로 양(+)의 상관관계가 나타난 반면, 소요시간의 합(DTime_Sum), 총 피난시간(Total ET)과는 유의한 상관관계를 보이지 않았다.

좌회성 여부에 대한 경로선택 시 의사결정 소요횟수(DNum_06)와 해당 소요시간(DTime_06) 간 상관관계는 $r=0.813$, $p<.001$ 으로 상관관계 중 가장 높은 양(+)의 상관관계가 나타났다. 소요횟수 합(DNum_Sum)과는 $r=0.583$ 으로 양(+)의 상관관계를 보였고, 소요시간 합(DTime_Sum)도 상관관계 $r=0.583$ 으로 양(+)의 상관관계가 나타났다.

위험경로 선택성 지점에서의 의사결정 소요횟수(DNum_07)와 소요시간(DTime_07) 간 상관관계는 $r=0.494$, $p<.001$ 으로 양(+)의 상관관계를 보였으며, 소요횟수 합(DNum_Sum)과는 $r=0.432$, $p<.001$ 으로 양(+)의 상관관계를 보였고, 소요시간 합(DTime_Sum)과는 $r=0.246$ 으로 낮은 양(+)의 상관관계를 가졌다.

다음으로 각 경로선택 지점에서 소요시간 사이의 영향 관계를 분석한 결과, 항광성 여부 선택 지점에서 소요시간(DTime_01)과 소요횟수 합(DNum_Sum) 간의 상관관계는 $r=0.434$, $p<.001$ 으로 양(+)의 상관성이 나타났으며, 소요시간 합(DTime_Sum)과는 $r=0.633$, $p<.001$ 으로 상대적으로 높은 양(+)의 상관성을 보였다. 반면에 총 피난 시간(Total ET)과는 유의한 관계를 보이지 않았다.

항개방성 지점에서의 소요시간(DTime_02)은 모든 시간 요소 간에 유의한 양(+)의 상관관계를 보였다. 특히, 소요시간 합(DTime_Sum)과는 상관계수 $r=0.763$, $p<.001$ 으로 높은 양(+)의 상관성이 나타났고, 총 피난 시간(Total ET)과도 $r=0.363$ 으로 양(+)의 상관관계를 나타냈다. 또한, 소요횟수의 합(DNum_Sum)과도 $r=0.381$ 로 양(+)의 상관관계를 보였다.

초기인지 경로선택성에 대한 경로선택 지점의 소요시간(DTime_03)도 항개방성과 마찬가지로 모든 시간 요소 사이에 유의한 양(+)의 상관관계를 보였다. 소요시간 합(DTime_Sum)과 상관계수는 $r=0.736$, $p<.001$ 으로 높은 양(+)의 상관관계를 보였고, 총 피난 시간(Total ET)과는 $r=0.245$ 으로 낮은 양(+)의 상관관계를 나타냈다.

지근거리 선택성 특성에 대한 경로선택 지점의 소요시간(DTime_04)과 소요횟수 합(DNum_Sum) 간의 상관계수는 $r=0.420$ 으로 양(+)의 상관성을 보였고, 소요시간 합(DTime_Sum)과 상관관계 $r=0.617$, $p<.001$ 으로 상대적으로 높은 양(+)의 상관관계가 나타났다. 반면에 총 피난 시간(Total ET)과의 상관분석에서 유의한 상관관계를 보이지 않았다.

직진성 경로선택 지점에서의 소요시간(DTime_05)과 소요횟수 합(DNum_Sum) 간의 상관계수는 $r=0.450$ 으로 양(+)의 상관관계를 보였고, 소요시간 합(DTime_Sum)과 상관관계는 $r=0.455$, $p<.001$ 으로 양(+)의 상관관계가 나타났다. 또한, 총 피난 시간(Total ET)과 $r=0.296$ 으로 낮은 양(+)의 관계를 나타냈다.

좌회성에 대한 소요시간(DTime_06)과 소요횟수 합(DNum_Sum) 간 상관관계는 $r=0.431$ 으로 양(+)의 상관 관계를 보였고, 소요시간 합(DTime_Sum)과도 $r=0.573$, $p<.001$ 으로 양(+)의 상관 관계가 나타났다. 반면에 총 피난 시간 Total ET와의 상관분석에서 유의한 관계를 보이지 않았다.

위험경로 회피성에서 소요시간(DTime_07)은 소요횟수의 합(DNum_Sum)과는 $r=0.319$, $p<.001$ 으로 양(+)의 상관성을 보였고, 소요시간 합(DTime_Sum)과는 상관관계 $r=0.540$, $p<.001$ 으로 양(+)의 상관성이 나타났다. 총 피난시간(Total ET)과는 $r=0.462$, $p<.001$ 으로 양(+)의 상관관계를 보였다.

모든 경로선택 지점의 소요횟수 합과 소요시간 합 간의 상관관계는 $r=0.690$, $p<.001$ 으로 상관관계 중 상대적으로 높은 양(+)의 상관관계를 보였으며, 반면에 총 피난 시간과의 상관관계에서는 유의한 관계를 보이지 않았다. 그리고 각 경로선택 시 이루어진 의사결정 소요시간의 합과 총 피난 시간 간의 상관관계는 $r=0.391$, $p<.001$ 으로 양(+)의 상관관계가 나타났다.

표 6. 경로선택 시 주요 변수 간 상관관계 분석(일반 상황)

Pearson Correlation																	
Variables	DNum_01 (Normal)	DNum_02 (Normal)	DNum_03 (Normal)	DNum_04 (Normal)	DNum_05 (Normal)	DNum_06 (Normal)	DNum_07 (Normal)	DTime_01 (Normal)	DTime_02 (Normal)	DTime_03 (Normal)	DTime_04 (Normal)	DTime_05 (Normal)	DTime_06 (Normal)	DTime_07 (Normal)	DNum _Sum (Normal)	DTime _Sum (Normal)	Total Evacuation Time (Normal)
DNum_01 (Normal)	1																
DNum_02 (Normal)	0.187	1															
DNum_03 (Normal)	0.057	0.095	1														
DNum_04 (Normal)	0.036	0.133	0.136	1													
DNum_05 (Normal)	0.050	0.154	0.088	-0.021	1												
DNum_06 (Normal)	.295**	0.195	0.194	0.094	-0.017	1											
DNum_07 (Normal)	0.061	0.037	0.010	0.043	.298**	0.087	1										
DTime_01 (Normal)	.354***	.553***	0.114	.266*	0.015	0.203	0.055	1									
DTime_02 (Normal)	.592***	0.211	.241*	0.194	0.109	.236*	0.077	.480***	1								
DTime_03 (Normal)	0.209	.229*	.594***	0.107	-0.006	.241*	-0.030	.503***	.524**	1							
DTime_04 (Normal)	0.157	0.125	.239*	.692***	-0.057	0.130	0.165	.533***	.403***	.360**	1						
DTime_05 (Normal)	0.048	0.072	.257*	0.094	.720***	0.018	.262*	-0.008	.329**	.238*	0.066	1					
DTime_06 (Normal)	0.178	0.099	0.185	-0.063	-0.007	.813***	0.117	0.166	.291**	.304**	0.066	0.160	1				
DTime_07 (Normal)	0.136	0.022	0.075	0.062	.294**	0.023	.494***	0.118	.378***	.239*	.235*	.381**	0.162	1			
DNum_Sum (Normal)	.496***	.497***	.513***	.372***	.473***	.583***	.432***	.434***	.489***	.420**	.398**	.450**	.431**	.319**	1		
DTime_Sum (Normal)	.376***	.291**	.403***	.309**	0.198	.455***	.246*	.633***	.763***	.736**	.617**	.455**	.573**	.540**	.680**	1	
Total ET (Normal)	0.162	-0.033	0.079	0.005	0.191	-0.018	0.150	0.134	.363***	.245*	0.190	.296**	0.109	.462**	0.161	.391**	1

DNum: Decision number, Dtime: Decision time, Total ET: Total evacuation time
 * P<.05, ** P<.01, *** P<.001

출처 : 저자 작성

1.3.3. 경로선택 시 행동 반응 요인이 시간에 미치는 영향

1) 본능적 경로선택, 의사결정 소요횟수가 의사결정 소요시간에 미치는 영향

각 본능적 피난 행동에 대한 경로선택 지점에서의 경로선택, 의사결정 소요횟수가 의사결정 소요시간에 미치는 영향을 검증하기 위해, 다중회귀분석(Multiple Linear Regression Analysis)을 실시하였다. 모든 회귀모형에서 Durbin-Watson(D-W)²⁾의 2에 근사한 값을 보여 잔차의 독립성 가정에 문제는 없는 것으로 평가되었고, 분산팽창지수(VIF)³⁾도 모두 10 미만으로 작게 나타나 다중공선성 문제는 없는 것으로 판단되었다.

표 7. 본능적 경로선택, 의사결정 소요횟수가 의사결정 소요시간에 미치는 영향

D.V.	I.V.	B	S.E.	β	t	p	VIF
DTime_01 (Fire)	(Constant)	1.534	0.505	.	3.040**	.003	
	Decision Point_01 (Fire)	0.424	0.328	.141	1.291	.200	1.027
	DNum_01 (Fire)	0.105	0.156	.073	0.674	.502	1.027
$F=1.235(p<.296)$, $R^2=.029$, $adjR^2=.005$, D-W=1.798							
DTime_02 (Fire)	(Constant)	0.700	0.313	.	2.237*	.028	
	Decision Point_02 (Fire)	0.809	0.183	.433	4.430***	<.001	1.005
	DNum_02 (Fire)	0.191	0.117	.160	1.634	.106	1.005
$F=10.687(p<.001)$, $R^2=.203$, $adjR^2=.184$, D-W=1.760							
DTime_03 (Fire)	(Constant)	0.720	0.267	.	2.698**	.008	
	Decision Point_03 (Fire)	-0.950	0.202	-.349	-4.712***	<.001	1.003
	DNum_03 (Fire)	0.663	0.078	.628	8.478***	<.001	1.003
$F=49.252(p<.001)$, $R^2=.540$, $adjR^2=.529$, D-W=1.839							
DTime_04 (Fire)	(Constant)	0.001	0.451	.	0.002	.999	
	Decision Point_04 (Fire)	-0.178	0.271	-.057	-0.654	.515	1.000
	DNum_04 (Fire)	1.075	0.158	.596	6.821***	<.001	1.000
$F=23.511(p<.001)$, $R^2=.359$, $adjR^2=.344$, D-W=2.165							
DTime_05 (Fire)	(Constant)	0.053	0.511	.	0.103	.918	
	Decision Point_05 (Fire)	-0.448	0.258	-.163	-1.735	.086	1.038
	DNum_05 (Fire)	0.785	0.137	.540	5.736***	<.001	1.038
$F=16.661(p<.001)$, $R^2=.284$, $adjR^2=.267$, D-W=1.627							

2) Durbin-Watson(D-W) 검정법은 회귀모형 추정후 잔차들을 이용하여 오차들 사이의 자기 상관계에 대한 존재 여부를 검정하는 방법중 가장 많이 사용되는 방법으로 D-W값이 2에 가까우면 자기 상관계에 문제가 없는 것으로 판단한다. 값이 0에 가까우면 정(Positive)의 자기 상관계 있고, 4에 가까우면 부(Negative)의 자기 상관계 있는 것으로 판단한다. 즉, 0이나 4에 가까우면 회귀모형이 부적합한 것으로 평가한다.

3) 분산팽창요인(VIF, Variance Inflation Factors)은 독립 변수간 상관관계에 대한 다중공선성(Multicollinearity)을 판단하는 척도이며, 일반적으로 VIF가 10이 넘으면 다중공선성 있다고 판단하며 5가 넘으면 주의할 필요가 있는 것으로 평가한다.

D.V.	I.V.	B	S.E.	β	t	p	VIF
DTime_06 (Fire)	(Constant)	0.065	0.514	.	0.127	.899	
	Decision Point_06 (Fire)	0.303	0.308	.090	0.986	.327	1.055
	DNum_06 (Fire)	1.164	0.195	.547	5.958***	<.001	1.055
$F=20.668(p<.001)$, $R^2=.330$, $adjR^2=.314$, D-W=1.940							
DTime_07 (Fire)	(Constant)	0.453	0.447	.	1.012	.315	
	Decision Point_07 (Fire)	-0.553	0.316	-.163	-1.748	.084	1.019
	DNum_07 (Fire)	0.624	0.120	.483	5.178***	<.001	1.019
$F=16.458(p<.001)$, $R^2=.282$, $adjR^2=.264$, D-W=2.058							

D.V.: Dependent Variable, I.V.: Independent Variable, S.E.: Standard Error, VIF: Variance Inflation Factor

* $p<.05$, ** $p<.01$, *** $p<.001$

출처 : 저자 작성

각 회귀모형의 결과를 살펴보면, 향광성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하지 않게 나타났으며($F=1.235$, $p=.296$), 회귀모형의 설명력은 약 2.9%(수정된 R제곱은 0.5%)로 나타났다($R^2=.029$, $adjR^2=.005$). 회귀계수의 유의성 검증결과, 본능적 경로선택($\beta=.141$, $p=.200$), 의사결정 소요횟수($\beta=.073$, $p=.502$)는 모두 의사결정 소요시간에 유의한 영향이 없는 것으로 나타났다.

향개방성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=10.687$, $p<.001$), 회귀모형의 설명력은 약 20.3%(수정된 R제곱은 18.4%)로 나타났다($R^2=.203$, $adjR^2=.184$). 회귀계수의 유의성 검증 결과, 본능적 경로선택($\beta=.433$, $p<.001$)은 의사결정 소요시간에 유의한 양(+)의 영향을 미치는 것으로 나타났으나, 의사결정 소요횟수($\beta=.160$, $p=.106$)는 유의한 영향을 미치지 않는 것으로 나타났다. 즉, 넓은 복도나 공간의 경로선택 지점에서 해당 선택이 나타날수록 의사결정 소요시간도 증가하는 것으로 평가되었다.

초기인지 경로선택성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=49.252$, $p<.001$), 회귀모형의 설명력은 약 54.0%(수정된 R제곱은 52.9%)로 나타났다($R^2=.540$, $adjR^2=.529$). 회귀계수의 유의성 검증 결과, 본능적 경로선택($\beta=-0.349$, $p<.001$)은 의사결정 소요시간에 유의한 음(-)의 영향을 미치고, 의사결정 소요횟수($\beta=.628$, $p<.001$)는 소요시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다. 다시 말해, 처음 인지된 경로에 대한 선택이 나타날수록 의사결정 시 소요되는 시간은 감소하고, 소요횟수가 증가할수록 소요시간도 증가하는 것으로 평가되었다.

지근거리 경로 선택성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=23.511$, $p<.001$), 회귀모형의 설명력은 약 35.9%(수정된 R제곱은 34.4%)로 나타났다($R^2=.359$,

$adjR^2=.344$). 회귀계수의 유의성 검증 결과, 본능적 경로선택은 의사결정 소요시간에 유의한 영향을 미치지 않는 것으로 나타났다. 반면에 의사결정 소요횟수($\beta=.596$, $p<.001$)는 소요시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다. 즉, 지근거리 지점에서는 의사결정 소요횟수가 증가할수록 소요시간은 증가하는 것으로 평가되었다.

직진 경로 선택성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=16.661$, $p<.001$), 회귀모형의 설명력은 약 28.4%(수정된 R제곱은 26.7%)로 나타났다($R^2=.284$, $adjR^2=.267$). 회귀계수의 유의성 검증 결과, 의사결정 소요횟수($\beta=.540$, $p<.001$)는 소요시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다. 즉, 지근거리 경로선택 지점에서는 의사결정 소요횟수가 증가할수록 소요시간은 증가하는 것으로 평가되었다. 반면에 본능적 경로선택은 의사결정 소요시간에 신뢰구간($p<.05$) 내에서는 유의한 영향을 미치지 않는 것으로 나타났으나, 신뢰구간 수준을 90%로 넓혀보게 되면 경로선택($\beta=-.163$, $p<.10$)에서 유의한 음(-)의 영향을 미치는 것으로 나타났다.

좌회 경로 선택성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=20.668$, $p<.001$), 회귀모형의 설명력은 약 33.0%(수정된 R제곱은 31.4%)로 나타났다($R^2=.330$, $adjR^2=.314$). 회귀계수의 유의성 검증 결과, 본능적 경로선택은 의사결정 소요시간에 유의한 영향을 미치지 않는 것으로 나타났다. 반면에 의사결정 소요횟수($\beta=.547$, $p<.001$)는 소요시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다. 즉, 좌, 우회 경로선택 지점에서는 의사결정 소요횟수가 증가할수록 소요시간은 증가하는 것으로 평가되었다.

위험경로 회피성에 대한 경로선택 지점에서 의사결정 소요시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=16.458$, $p<.001$), 회귀모형의 설명력은 약 28.2%(수정된 R제곱은 26.4%)로 나타났다($R^2=.282$, $adjR^2=.264$). 회귀계수의 유의성 검증 결과, 의사결정 소요횟수($\beta=.483$, $p<.001$)는 소요시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다. 즉, 지근거리 경로선택 지점에서는 의사결정 소요횟수가 증가할수록 소요시간은 증가하는 것으로 평가되었다. 반면에 본능적 경로선택은 의사결정 소요시간에 신뢰구간($p<.05$) 내에서는 유의한 영향을 미치지 않는 것으로 나타났으나, 신뢰구간 수준을 90%로 넓혀보게 되면 경로선택($\beta=-.163$, $p<.10$)에서 음(-)의 영향을 미치는 것으로 나타났다.

2) 본능적 경로선택, 의사결정 소요횟수 및 소요시간이 총 피난시간에 미치는 영향

본능적 경로선택 여부, 의사결정 소요횟수 및 의사결정 소요시간이 총 피난시간에 미치는 영향에 대해

살펴보기 위해 다중회귀분석(Multiple Linear Regression Analysis)을 실시하였다. 모든 모형에서 D-W 값은 2에 근사한 값을 보여 잔차 독립성 가정에 문제가 없으며, 분산팽창지수 값에서도 10 미만으로 다중공선성 문제도 없는 것으로 판단되었다.

표 8. 경로선택, 소요횟수, 소요시간이 총 피난시간에 미치는 영향

D.V.	I.V.	B	S.E.	β	t	p	VIF
Total Evacuation Time (Fire)	(Constant)	69.337	7.822	.	8.864	.000	
	Decision Point_01 (Fire)	-9.977	4.877	-.213	-2.046	.044	1.048
	DNum_01 (Fire)	5.417	2.294	.244	2.361	.021	1.033
	DTime_01 (Fire)	3.621	1.605	.233	2.256	.027	1.029
	$F=4.447(p<.01)$, $R^2=.138$, $adjR^2=.107$, D-W=1.319						
Total Evacuation Time (Fire)	(Constant)	81.131	5.819	.	13.942	.000	
	Decision Point_02 (Fire)	-3.566	3.660	-.107	-0.974	.333	1.240
	DNum_02 (Fire)	-3.303	2.149	-.154	-1.537	.128	1.037
	DTime_02 (Fire)	8.431	1.970	.472	4.279	.000	1.254
	$F=6.681(p<.001)$, $R^2=.195$, $adjR^2=.165$, D-W=1.389						
Total Evacuation Time (Fire)	(Constant)	81.199	5.796	.	14.010	.000	
	Decision Point_03 (Fire)	-3.625	4.719	-.084	-0.768	.445	1.268
	DNum_03 (Fire)	-2.383	2.219	-.143	-1.074	.286	1.861
	DTime_03 (Fire)	7.856	2.272	.496	3.458	.001	2.173
	$F=7.483(p<.001)$, $R^2=.213$, $adjR^2=.184$, D-W=1.291						
Total Evacuation Time (Fire)	(Constant)	72.372	6.432	.	11.252	.000	
	Decision Point_04 (Fire)	-2.581	3.879	-.069	-0.665	.508	1.005
	DNum_04 (Fire)	3.237	2.801	.149	1.155	.251	1.554
	DTime_04 (Fire)	2.451	1.555	.204	1.576	.119	1.560
	$F=3.319(p<.05)$, $R^2=.107$, $adjR^2=.075$, D-W=1.271						
Total Evacuation Time (Fire)	(Constant)	68.633	8.764	.	7.831	.000	
	Decision Point_05 (Fire)	1.488	4.507	.034	0.330	.742	1.075
	DNum_05 (Fire)	-1.184	2.768	-.051	-0.428	.670	1.445
	DTime_05 (Fire)	7.503	1.871	.467	4.011	.000	1.397
	$F=6.704(p<.001)$, $R^2=.195$, $adjR^2=.166$, D-W=1.341						
Total Evacuation Time (Fire)	(Constant)	82.364	5.673	.	14.520	.000	
	Decision Point_06 (Fire)	-2.206	3.415	-.066	-0.646	.520	1.068
	DNum_06 (Fire)	-5.507	2.571	-.258	-2.142	.035	1.501
	DTime_06 (Fire)	5.427	1.204	.541	4.508	.000	1.492
	$F=6.823(p<.001)$, $R^2=.198$, $adjR^2=.169$, D-W=1.279						

D.V.	I.V.	B	S.E.	β	t	p	VIF
Total Evacuation Time (Fire)	(Constant)	83.726	7.252	.	11.546	.000	
	Decision Point_07 (Fire)	-5.981	5.189	-.109	-1.153	.252	1.056
	DNum_07 (Fire)	-3.016	2.230	-.145	-1.353	.180	1.344
	DTime_07 (Fire)	9.135	1.758	.565	5.195	.000	1.392
	$F=11.509(p<.001)$, $R^2=.294$, $adjR^2=.268$, $D-W=1.335$						
Total Evacuation Time (Fire)	(Constant)	62.530	9.261	.	6.752	.000	
	DNum_Sum (Fire)	-0.794	0.589	-.136	-1.347	.182	1.489
	DTime_Sum (Fire)	2.462	0.347	.719	7.103	.000	1.489
	$F=30.744(p<.001)$, $R^2=.423$, $adjR^2=.409$, $D-W=1.386$						

D.V.: Dependent Variable, I.V.: Independent Variable, S.E.: Standard Error, VIF: Variance Inflation Factor

* $p<.05$, ** $p<.01$, *** $p<.001$

* 출처 : 저자 작성

각 모형의 영향에 대한 결과를 보면, 먼저 향광성에 대한 경로선택 지점에서 총 피난시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=4.447$, $p<.01$), 회귀모형의 설명력은 약 13.8%(수정된 R제곱은 10.7%)로 나타났다($R^2=.138$, $adjR^2=.107$). 한편 회귀계수 유의성 검증결과, 본능적 경로선택($\beta=-.213$, $p<.05$)은 총 피난 시간에 유의한 음(-)의 영향을 미치는 것으로 나타났다. 즉, 향광성에 대한 경로선택이 나타날 시 총 피난 시간이 줄어드는 것으로 평가되었다. 의사결정 소요횟수($\beta=.244$, $p<.05$)는 총 피난 시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다. 즉, 의사결정 소요횟수가 증가할수록 총 피난 시간도 증가하는 것으로 나타났다. 의사결정 소요시간($\beta=.233$, $p<.05$)의 경우 총 피난 시간에 유의한 양(+)의 영향을 미치는 것으로 나타났다.

향개방성에 대한 총 피난시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=6.681$, $p<.001$), 회귀모형의 설명력은 약 19.5%(수정된 R제곱은 16.5%)로 나타났다($R^2=.195$, $adjR^2=.165$). 회귀계수 유의성 검증결과, 본능적 경로선택과 의사결정 소요횟수는 총 피난 시간에 유의한 영향을 미치지 않는 것으로 나타났으나, 의사결정 소요시간($\beta=.472$, $p<.001$)은 총 피난시간에 유의한 양(+)의 영향을 미치는 것으로 나타나, 소요시간이 증가할수록 총 피난시간도 증가하는 것으로 나타났다.

초기인지 경로선택성에 대한 총 피난시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=7.483$, $p<.001$), 회귀모형의 설명력은 약 21.3%(수정된 R제곱은 18.4%)로 나타났다($R^2=.213$, $adjR^2=.184$). 회귀계수 유의성 검증결과, 경로선택과 의사결정 소요횟수는 총 피난시간에 유의한 영향이 없는 것으로 나타났다. 반면, 의사결정 소요시간($\beta=.496$, $p<.001$)은 총 피난시간에 유의한 양(+)의 영향을 미치는 것으로 평가되었으며, 다시 말해, 소요시간이 증가할수록 총 피난 시간도 증가하는 것으로 나타났다.

지근거리 선택성의 경우 총 피난 시간과의 회귀모형에서 통계적으로 유의한 것으로 나타났으며($F=3.319$, $p<.05$), 회귀모형의 설명력은 약 10.7%(수정된 R제곱은 7.5%)로 나타났다($R^2=.107$, $adjR^2=.075$). 회귀계수 유의성 검증결과, 경로선택과 의사결정 소요횟수, 소요시간 모두 유의한 영향을 미치지 않는 것으로 나타났다.

직진성에 대한 총 피난시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=6.704$, $p<.001$), 회귀모형의 설명력은 약 19.5%(수정된 R제곱은 16.6%)로 나타났다($R^2=.195$, $adjR^2=.166$). 회귀계수 유의성 검증결과, 본능적 경로선택과 의사결정 소요횟수에서 모두 총 피난시간에 유의한 영향을 미치지 않는 것으로 나타났다. 반면, 의사결정 소요시간($\beta=.467$, $p<.001$)은 총 피난 시간에 유의한 양(+)의 영향을 미치는 것으로 평가되었으며, 즉, 직진성 경로선택 지점에서의 소요시간이 증가할수록 총 피난 시간도 증가하는 것으로 나타났다.

좌회성에 대한 총 피난시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=6.823$, $p<.001$), 회귀모형의 설명력은 약 19.8%(수정된 R제곱은 16.9%)로 나타났다($R^2=.198$, $adjR^2=.169$). 회귀계수 유의성 검증결과, 경로선택은 총 피난시간에 유의한 영향이 없는 것으로 나타났으며, 의사결정 소요횟수, 의사결정 소요시간은 모두 유의한 영향을 주는 것으로 평가되었다. 의사결정 소요횟수($\beta=-.258$, $p<.05$)는 총 피난시간에 유의한 음(-)의 영향을 미치는 것으로 평가되었으며, 다시 말해, 좌회성 경로선택 지점에서의 의사결정 소요횟수가 증가할수록 총 피난시간은 감소하는 것으로 나타났다. 의사결정 소요시간($\beta=.541$, $p<.001$)은 총 피난시간에 유의한 양(+)의 영향을 미치는 것으로 평가되었고, 이는 소요시간이 증가할수록 총 피난시간도 증가하는 것을 나타낸다.

위험경로 회피성에 대한 총 피난시간의 회귀모형은 통계적으로 유의하게 나타났으며($F=11.509$, $p<.001$), 회귀모형의 설명력은 약 29.4%(수정된 R제곱은 26.8%)로 나타났다($R^2=.294$, $adjR^2=.268$). 회귀계수 유의성 검증결과, 본능적 경로선택과 의사결정 소요횟수에서 모두 총 피난시간에 유의한 영향을 미치지 않는 것으로 나타났다. 반면, 의사결정 소요시간($\beta=.565$, $p<.001$)에서는 총 피난시간에 유의한 양(+)의 영향을 미치는 것으로 나타나, 즉, 직진성 경로선택 지점에서의 소요시간이 증가할수록 총 피난시간도 증가하는 것으로 나타났다.

위의 결과처럼 의사결정 소요 횟수와 소요시간이 총 피난시간에 유의한 영향을 미치므로, 이에 소요횟수 합(DNum_Sum), 소요시간 합(DTime_Sum)이 총 피난시간에 유의한지 검증하였다. 그 결과, 총 피난 시간의 회귀모형은 유의하게 나타났으며($F=30.744$, $p<.001$), 모형 설명력은 약 42.3%(수정된 R제곱은 40.9%)로 나타났다($R^2=.423$, $adjR^2=.409$). 회귀계수 유의성 검증결과, 의사결정 소요횟수는 총 피난 시간에 유의한 영향을 미치지 않는 것으로 나타났고, 반면, 의사결정 소요시간($\beta=.719$, $p<.001$)의 경우 총 피난시간에 유의한 양(+)의 영향을 미치는 것으로 드러났다. 즉, 의사결정 소요시간이 증가할수록 총 피난시간도 증가하는 것으로 나타났다.

V 결론

1. 결론

본 연구는 화재 시 피난 경로선택 행동 특성에 대한 검증을 위해 기존의 연구 한계를 보완하고, 결과의 신뢰도를 높이고자 이론상의 본능적 경로선택 행동에 기초하여 실제와 유사한 가상 실험환경을 구현하고 가상현실 장비를 통해 실증 실험을 수행하였다.

피난 경로선택 실험을 통해 파악된 각 본능적 경로선택 공간 조건과 상황에 따른 피험자의 행동 및 반응에 관한 주요 결과는 다음과 같다.

첫째, 상황에 따른 본능적 경로선택의 차이에 있어서 전반적으로 유의한 차이가 나타나지는 않았다. 이는 본능적 경로선택이 화재 상황에서만 국한되어 나타나는 행동이 아닌, 보다 일반화하여 볼 수 있는 경로선택 특성으로 해석할 수 있을 것으로 판단된다. 다만, 위험경로 선택성의 경우, 유의미한 차이가 나타났는데, 이는 화재상황에서는 위험요소가 있는 경로를 선택한 비율이 낮았지만, 일반상황에서는 연기가 피어오르는 경로를 선택하여 확인하는 피험자가 일부 나타났는데, 이는 확인 단계의 피난 행동이 나타난 것으로 판단된다. 또한, 각 경로선택의 결과에 있어서 향광성(DP01), 초기인지 경로선택성(DP03), 지근거리 선택성(DP04), 직진성(DP05), 위험경로회피성(DP07)에서는 뚜렷한 경로선택 경향의 차이가 나타나는 지점이 있는 반면, 그렇지 않은 향개방성(DP02)이나 좌회성(DP06) 같이 경로선택의 비율이 비슷한 지점이 있는 것을 확인할 수 있었다. 특히, 주 사용 손 특성에 따른 차이를 살펴봤을 때도, 좌회성 지점에서 유의한 차이는 보이지 않았다.

경로선택행동 반응요소인 의사 결정시 소요되는 횟수, 시간을 상황에 따른 차이를 분석한 결과, 대부분 유의한 차이를 보이지 않았으나, 지점의 의사결정 소요횟수 합, 소요시간 합, 전체 피난 시간에서는 유의한 차이를 보였다. 이는 화재 시 나타나는 두리번거림, 시간의 의사결정 과정이 상대적으로 일반 상황보다 적고, 짧게 이루어진다는 것을 확인할 수 있다.

둘째, 각 본능적 경로선택 지점에서의 경로선택에 따른 의사결정 반응의 차이를 살펴보면, 의사결정 소요횟수의 경우, 화재상황에서는 좌회성, 일반상황에서는 지근거리 선택성과 위험회피성에서 유의한 차이가 나타났다. 반면, 소요시간에서는 화재상황에서 향개방성, 초기인지 경로선택성, 좌회성, 위험회피성에서 유의한 차이를 보였으며, 일반상황은 향광성, 향개방성, 초기인지 경로선택성, 지근거리 선택성에서 유의한 차이가 나타났다. 이는 소요시간은 두리번거림의 횟수의 영향을 받지 않는다는 것을 알 수 있다. 또한, 의사결정 소요횟수의 평균을 비교해보면 직진성에서 가장 높은 평균을 보이며, 이는 경로 형태가 소요횟수에 영향을 미칠 수 있음을 알 수 있다. 하지만 소요시간이 직진성에서는 상대적으로 높게 나타나지는 않은 것을 알 수 있다. 향후 경로 형태 및 구성에 있어서 보다 면밀히 살펴볼 필요가 있을 것으로 판단된다.

셋째, 상관분석에 있어서 각 경로선택 지점에서의 의사결정 소요횟수는 대부분 해당 소요시간과 유의한 양(+)의 상관관계를 보였다. 또한, 의사결정 소요시간에 있어서 상황에 따라 총 피난시간 사이의 영향관계가 다르게 나타났는데, 화재상황에서는 모두 양(+)의 상관관계에 있음을 나타냈으나, 일반상황에서는 유의한 향개방성 지점 외에 낮은 상관관계를 보이거나 유의한 영향관계가 없음을 나타냈다. 이는 화재가 발생했을 때 경로선택 시 소요되는 시간이 일반상황에 비하여 전체 피난시간에 미치는 영향이 많은 것으로 확인할 수 있다.

마지막으로, 경로선택과 의사결정 소요횟수가 각 소요시간에 미치는 영향 정도를 보았을 때, 향광성 지점에서의 소요횟수를 제외한 모든 지점에서의 소요횟수는 피난 시간에 영향을 미치며, 그 정도에 있어서는 유의한 양(+)의 관계를 보였다. 즉, 소요횟수가 증가할수록 해당 소요시간도 증가하는 것을 확인할 수 있었다. 반면, 경로선택에 있어서는 본능적 경로선택이 나타날 때, 향개방성, 초기인지 경로선택성에서 유의한 것으로 나타났으나, 향개방성의 경우 향개방성 경로를 선택할 경우 해당 소요시간이 증가하는 것으로 나타났다. 하지만, 초기인 지경로선택성의 경우 해당 경로를 선택할 때, 소요시간은 줄어드는 것으로 나타났다. 이는 향개방성의 경우 경로선택 상황에서 넓은 공간에 대해 불확실함으로 인한 주저함으로 소요시간이 증가하는 것으로 판단되며, 그와 반대로 초기인지 경로선택성에 있어서, 초기에 확인된 위험요소가 없는 경로를 선택 하는데 주저함은 상대적으로 낮은 인간 심리적 요인이 작용하여 위 결과가 나타났을 것으로 판단된다.

앞서 언급한 결론을 종합하여 보면, 이론상의 본능적 경로선택 행동은 선택지점의 환경이 의사결정 반응 시간에 영향을 미치는 것을 볼 수 있었으며, 공간의 구조적 특성을 고려하여 적절한 피난 경로를 설계하면 보다 신속하고 안전한 피난이 이루어질 수 있을 것으로 판단된다. 하지만, 본 연구는 가상현실 기술을 활용하여

여러 환경요소를 통제하고 실험한 결과로써, 추후 건축물 내 물리적 환경 요소에 대한 경로선택 실험과 더불어 실제 건물 모델에서의 실증 실험을 통하여 본 실험의 결과에 대한 검토 및 보완이 필요할 것이다. 향후 경로선택 모델을 개발하기 위한 기초 근거 제시에 본 연구의 의의가 있다.

저자_ 한기성(Gisung Han)

• 학력

고려대학교 도시재생협동과정
석박사통합과정 수료
가천대학교 건축학 학사

• 경력

現) 고려대학교 도시재생협동과정 석박사통합과정
재학 중

참고문헌

〈국내문헌 : 인용 순〉

- 1) 박재성. (2004). 건축물 화재시 피난행동을 고려한 피난예측모델에 관한 연구. 서울시립대학교 학위논문.
- 2) 박재성, & 윤명오. (2004). 대규모 미로형 다중이용공간에서의 피난경로선택 특성에 관한 연구. 대한건축학회 논문집-구조계, 20(9), 71-78.
- 3) 송창영. (2017). 건축방재론. 예문사, 312p, ISBN 9788927421177(8927421175)
- 4) 이강훈. (1997). 인간 행동패턴에 대한 고찰과 피난로 설계에의 적용방법에 관한 연구. 대한건축학회 논문집, 13(7), 83-92.
- 5) 이강훈. (1998). 인간행동습성과 피난계단의 설계에 관한 연구. 한국화재소방학회지, 12(4), 3-12.
- 6) 최원영, & 이경희. (1988). 건물화재시 재실자의 피난형태 예측 모델에 관한 연구. 대한건축학회 논문집, 4(4), 177-184.

〈국외문헌 : 인용 순〉

- 7) Almeida, J. E., Rossetti, R. J., Jacob, J. T. P. N., Faria, B. M., & Coelho, A. L. (2017). Serious games for the human behaviour analysis in emergency evacuation scenarios. Cluster Computing, 20(1), 707-720.
- 8) Bryan, J. L. (1999). Human behaviour in fire: the development and maturity of a scholarly study area. Fire and Materials, 23(6), 249-253.
- 9) Chiewchengchol, W., Koga, T., & Hirate, K. (2011). Development of an evacuation simulator using a walkthrough system and research on evacuation behavior in the case of fire. Journal of Asian Architecture and Building Engineering, 10(1), 101-108.
- 10) Cosma, G. (2014). Virtual Reality Experiments on the Impact of Way-finding Lighting Systems on Egress From Smoke-filled Railway Tunnel LUTVDG/TVBB.
- 11) Fahy, R. F. (1994). Exit 89-an evacuation model for high-rise buildings-model description and example applications. Fire Safety Science, 4, 657-668.
- 12) Galea, E. R. (2006). Proposed methodology for the use of computer simulation to enhance aircraft evacuation certification. Journal of Aircraft, 43(5), 1405-1413.
- 13) Gibson, J. J. (1977). The theory of affordances. Hilldale, USA, 1(2), 67-82.

- 14) Gibson, J. J. (1979). The theory of affordances. The ecological approach to visual perception.
- 15) Hartson, R. (2003). Cognitive, physical, sensory, and functional affordances in interaction design. *Behaviour & Information Technology*, 22(5), 315-338.
- 16) Kobes, M., Helsloot, I., De Vries, B., Post, J. G., Oberijé, N., & Groenewegen, K. (2010). Way finding during fire evacuation: an analysis of unannounced fire drills in a hotel at night. *Building and Environment*, 45(3), 537-548.
- 17) Kuligowski, E. D. (2011). Terror defeated: occupant sensemaking, decision-making and protective action in the 2001 World Trade Center disaster. University of Colorado at Boulder.
- 18) Liu, H., Chen, H., Hong, R., Liu, H., & You, W. (2020). Mapping knowledge structure and research trends of emergency evacuation studies. *Safety Science*, 121, 348-361.
- 19) Nilsson, D. (2009). Exit choice in fire emergencies-Influencing choice of exit with flashing lights. Lund University.
- 20) Pan, X., Han, C. S., Dauber, K., & Law, K. H. (2007). A multi-agent based framework for the simulation of human and social behaviors during emergency evacuations. *Ai & Society*, 22(2), 113-132.
- 21) Proulx, G. U. Y. L. E. N. E., & Hadjisophocleous, G. V. (1994). Occupant response model: a sub-model for the NRCC risk-cost assessment model. *Fire Safety Science*, 4, 841-852.
- 22) Shields, T. J., & Boyce, K. E. (2000). A study of evacuation from large retail stores. *Fire Safety Journal*, 35(1), 25-49.
- 23) Sime, J. (1994). Escape behaviour in fires and evacuations. *Design against Fire, an introduction to fire safety engineering design*. London: E & FN SPON, 56-87.
- 24) Tong, D., & Canter, D. (1985). The decision to evacuate: a study of the motivations which contribute to evacuation in the event of fire. *Fire Safety Journal*, 9(3), 257-265.
- 25) Vasudevan, K., & Son, Y. J. (2011). Concurrent consideration of evacuation safety and productivity in manufacturing facility planning using multi-paradigm simulations. *Computers & Industrial Engineering*, 61(4), 1135-1148.
- 26) Vilar, E., Rebelo, F., Noriega, P., Teles, J., & Mayhorn, C. (2013). The influence of environmental features on route selection in an emergency situation. *Applied Ergonomics*, 44(4), 618-627.

- 27) Vilar, E., Rebelo, F., Noriega, P., Duarte, E., & Mayhorn, C. B. (2014). Effects of competing environmental variables and signage on route-choices in simulated everyday and emergency wayfinding situations. *Ergonomics*, 57(4), 511-524.
- 28) Zhu, R., Lin, J., Becerik-Gerber, B., & Li, N. (2020). Influence of architectural visual access on emergency wayfinding: A cross-cultural study in China, United Kingdom and United States. *Fire Safety Journal*, 113, 102963.

〈기타문헌 : 홈페이지 등〉

- 29) 화재발생현황. e-나라지표.. 소방청「화재통계연보」, URL: www.index.go.kr

융합연구리뷰

Convergence Research Review 2021 November vol.7 no.11

이 보고서는 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 사업임

(No. NRF-2012M3C1A1050726)