

SOM 기반 BCI 사용자 상태 분류를 활용한 맞춤형 학습 추천 기법

김귀정*

백석대학교 컴퓨터공학부 교수

A Personalized Learning Recommendation Method Using SOM-Based BCI User State Classification

Gui Jung Kim*

Professor, Division of Computer Engineering, Baekseok University

요약 본 연구는 학습자의 생리적·인지적 변화를 반영하는 적응형 학습 환경을 구현함으로써 개인화 학습의 효율성을 향상시킬 수 있음을 보여준다. 비지도 학습 기반의 Self-Organizing Map(SOM)을 활용하여 BCI(Brain-Computer Interface) 사용자 상태를 자동 분류하고, 이를 맞춤형 학습 추천 시스템에 적용한 것이다. EEG(뇌파) 신호의 주요 주파수 대역(알파, 베타, 세타)을 분석하여 학습자의 집중·보통·피로 상태를 구분하고, 각 상태에 적합한 학습 콘텐츠를 제시하였다. SOM을 통해 라벨링 없이도 내재된 EEG 패턴을 군집화하였으며, 온톨로지 기반 추천 알고리즘과 결합하여 인지 상태에 따라 학습 자료를 실시간으로 조정하였다. 향후에는 실제 EEG 실험과 다중 생체신호 통합을 통해 보다 정밀한 실시간 학습 추천 모델로 확장될 수 있을 것이다.

주제어 : 뇌-컴퓨터 인터페이스, 뇌파, 자기조직화지도, 학습 추천 시스템, 비지도 학습

Abstract The proposed system demonstrates the feasibility of adaptive learning environments that respond to learners' cognitive and physiological changes in real time. This study proposes an unsupervised learning approach using the Self-Organizing Map (SOM) to classify user states in Brain-Computer Interface (BCI) systems and apply them to a personalized learning recommendation model. EEG signals from alpha, beta, and theta frequency bands were analyzed to cluster user cognitive states into high focus, moderate focus, and low focus levels. The SOM model enabled clustering without labeled data, and the ontology-based recommendation algorithm dynamically adjusted learning content according to user states. Future work will focus on real EEG experiments and the integration of multimodal biosignals to enhance precision and expand the practical application of real-time personalized learning systems.

Key Words : BCI, EEG, SOM, Learning Recommendation System, Unsupervised Learning

1. 서론

최근 인공지능과 뇌공학 기술의 융합으로 학습자의 생체신호를 활용한 인지 상태 분석이 활발히 이루어지고 있다[1,2]. 특히 BCI(Brain-Computer Interface)는 EEG(뇌파) 신호를 통해 학습자의 집중도, 피로도, 흥미도 등 다양한 인지 상태를 실시간으로 파악할 수 있어 개인 맞춤형 학습 환경 구축에 효과적인 기술로 주목받고 있다[3,4]. 그러나 기존 EEG 기반 학습자 상태 분류 연구는 대부분 지도학습(Supervised Learning)에 기반하기 때문에 충분한 라벨링 데이터 확보가 필요하다[5]. 실제 학습 환경에서는 학습자의 인지 상태가 시간에 따라 변화하고 개인차가 커, 지도학습 기반 상태 분류 방식의 실환경 적용에는 한계가 존재한다[6].

이에 본 연구는 비지도 학습(unsupervised learning) 기반의 SOM(Self-Organizing Map) 알고리즘을 활용하여 학습자의 EEG 데이터를 자동으로 군집화하고, 이를 통해 인지 상태를 분류하는 방법을 제안한다[7,8]. SOM은 고차원 EEG 특징 벡터를 저차원 공간으로 사상하여 데이터 간 유사도를 기반으로 패턴을 시각화하고 군집화할 수 있어, 라벨 없이도 내재된 상태를 탐색할 수 있다[9]. 본 접근은 데이터 라벨링의 어려움이 존재하는 실제 학습 상황에서도 효율적으로 적용 가능하며, 개인별 EEG 패턴 차이를 자동으로 반영할 수 있다는 장점이 있다[10].

이에 본 연구는 EEG 기반 BCI 신호로부터 학습자의 인지 상태를 SOM 기반 비지도 학습으로 분류하고, 분류 결과를 학습 추천 로직에 연계하여 상태 변화에 따라 학습 콘텐츠를 조정하는 맞춤형 학습 추천 기법을 제안한다[11]. 또한 분류된 상태에 따라 적합한 학습 콘텐츠를 추천하는 규칙 기반 추천 모형을 설계하여 학습자의 몰입도와 효율을 향상시키는 맞춤형 학습 지원 시스템을 구현하였다.

본 시스템은 실시간 EEG 데이터의 흐름을 반영하도록 설계되어, 학습자의 상태 변화에 따라 즉각적으로 학습 콘텐츠를 조정할 수 있는 점에서 실용적 의미가 크다[14]. 본 연구는 설계 및 시뮬레이션 기반 연구로서, 상용 BCI 장치의 일반적 사양을 기준으로 EEG 처리 절차를 구성하고, 공개 EEG 데이터셋을 활용해 제안 시스템의 타당성을 검증하였다[15]. 이를 통해 비지도 학습 기반 EEG 분석의 실용성과 학습 추천 시스템의 확장 가능성을 확인하고자 한다.

기존 맞춤형 학습 추천 연구가 학습 이력과 성취도 중

심의 정적 정보에 기반하였다면, 본 연구는 EEG 기반 인지 상태를 실시간 입력 변수로 반영하여 추천을 동적으로 조정한다는 점에서 차별성을 갖는다. 또한 라벨링이 어려운 EEG 환경을 고려하여 SOM 기반 비지도 학습을 적용하고, 온톨로지 기반 매핑을 통해 상태-콘텐츠 연계를 구조적으로 제시한다.

2. 선행 연구

BCI(Brain-Computer Interface)는 뇌파 신호를 분석하여 사용자의 인지 상태나 집중도를 파악하는 기술로, 의료·재활 분야뿐 아니라 학습 환경에서도 활용 가능성이 확대되고 있다[1,3]. 특히 학습자의 주의 집중, 인지 부하, 피로도를 실시간으로 분석하여 학습 환경을 개선하려는 연구가 활발히 이루어지고 있다[4,5]. EEG 신호는 비침습적이며 시간적 해상도가 높아 학습 상황의 인지 변화를 민감하게 반영할 수 있는 장점이 있다[6,7].

기존 EEG 기반 인지 상태 분석 연구에서는 SVM, KNN, CNN 등 지도학습 기법이 주로 활용되었으나, 대량의 라벨링 데이터가 필요하고 사용자 간 EEG 편차로 인해 일반화에 한계가 있다[8,9]. 최근에는 딥러닝 기반 CNN이나 RNN을 활용한 연구도 시도되고 있으나, 학습 데이터 불균형과 라벨 품질 문제로 인해 실환경 적용에는 제약이 따른다[10,11].

이에 비해 SOM(Self-Organizing Map)은 비지도 학습 기반으로 데이터의 잠재 구조를 시각화하고 EEG 패턴을 군집화하는 데 효과적인 방법으로 평가된다[12,13,14]. SOM은 입력 데이터 간 유사도를 유지하면서 저차원 공간으로 사상함으로써 복잡한 EEG 패턴의 해석과 상태 구분을 가능하게 한다[15]. 최근에는 SOM을 활용하여 학습자의 집중도나 피로 상태를 분류하고, 학습 지원에 적용하려는 연구가 보고되고 있다[9,13]. 그러나 이러한 접근은 학습자의 인지 상태를 추천 과정에 구조적으로 통합하는 데에는 한계가 있다[10].

한편 학습 추천 시스템은 학습자의 이력, 성취도, 선호도 등을 기반으로 콘텐츠를 제안하는 기술로 발전해 왔으며, 최근에는 BCI 기반 인지 상태 분석과의 결합이 시도되고 있다[11,15]. 본 연구는 이러한 연구 흐름을 바탕으로 SOM 기반 비지도 학습을 통해 학습자의 인지 상태를 분류하고, 이를 학습 추천 시스템과 연계하는 새로운 접근을 제안한다.

3. 시스템 설계 및 구현

본 시스템은 학습자의 EEG 신호로부터 인지 상태를 추정하고, 이를 학습 추천 알고리즘과 연계하여 실시간 맞춤형 학습 환경을 제공하는 것을 목표로 한다. 시스템은 (1) EEG 데이터 전처리, (2) SOM 기반 상태 분류, (3) 온톨로지 기반 추천 알고리즘의 세 단계로 구성된다. 전체 구조는 모듈 간 실시간 데이터 흐름을 중심으로 설계되어, 향후 실제 학습 플랫폼과의 연동이 가능하도록 확장성을 확보하였다.

3.1 EEG 데이터 수집 및 전처리

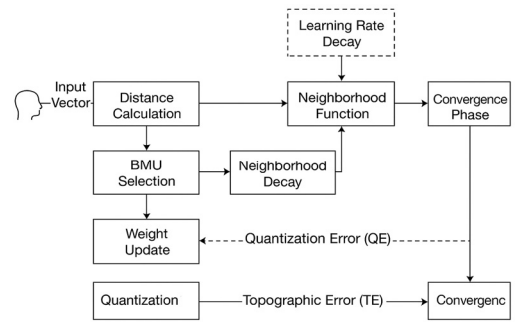
본 연구는 상용 BCI 장치(예: Emotiv, Muse, OpenBCI)의 일반적 사양을 기준으로 설계된 EEG 데이터 처리 절차를 기반으로 시스템을 구성하였다. 실제 적용 시를 가정하여 전두엽 및 두정엽 채널에서 수집된 EEG 신호를 0.5~50 Hz 대역통과 필터로 노이즈를 제거하고, 독립성 분분석(ICA)을 이용하여 근전도 및 안구 신호를 분리 제거하였다. 이후 채널별 정규화를 수행하여 개인 간 편차를 최소화하였다.

EEG의 시간적 변동성을 반영하기 위해 2초 단위의 슬라이딩 윈도우를 적용하였으며, 각 구간에서 파워 스펙트럼 밀도(PSD), 대역 비율(β/α , θ/β), 피크 주파수 등의 특징을 추출하였다. 이러한 전처리 및 특징 추출 절차는 4장에서 활용되는 공개 EEG 데이터셋에도 동일하게 적용되어, SOM 학습의 입력 벡터로 사용된다. 이 단계는 실시간 적용 가능성을 고려하여 처리 복잡도를 최소화하고, 연산 효율성을 유지하도록 설계되었다.

3.2 SOM 기반 사용자 상태 분류


전처리된 EEG 특징 벡터(공개 데이터셋 및 시뮬레이션 기반)는 SOM(Self-Organizing Map) 모델에 입력되어 사용자 상태를 비지도 학습 방식으로 군집화하였다. SOM은 고차원 EEG 특징 벡터를 저차원(2D 격자) 공간으로 사상하면서 데이터 간 유사도를 보존하는 신경망 모델로, 복잡한 EEG 패턴의 구조를 시각적으로 표현할 수 있다. SOM의 학습 과정은 [Fig.1]에 나타내었다.

[Fig.1]은 SOM의 학습 절차를 단계별로 도식화한 것으로, Ordering Phase에서는 높은 학습률과 넓은 이웃 반경을 적용하여 데이터의 전반적 분포를 정렬하고, 이후 거리 계산, BMU 선택, 가중치 갱신 과정을 반복하며 학습률과 이웃 반경을 점진적으로 감소시킨다. Convergence Phase에서는 군집 구조가 안정화되며, Quantization



[Fig. 1] SOM Training Process

Error(QE)와 Topographic Error(TE)의 감소를 통해 SOM의 수렴 특성을 확인할 수 있다.



[Fig. 2] SOM-based EEG User State Classification Process

[Fig.2]는 SOM 기반 EEG 사용자 상태 분류 과정을 나타낸다. 본 연구에서는 SOM의 크기를 10×10 노드, 학습 반복 횟수를 1000회로 설정하였으며, 이는 군집 안정성과 맵 해상도의 균형을 고려해 사전 실험적으로 결정하였다. 학습 결과, EEG 특징 패턴은 집중(High Focus), 보통(Moderate Focus), 피로(Low Focus)의 세 가지 군집으로 구분되었으며, U-Matrix와 Component Plane을 통해 군집 경계와 주요 특징 분포를 해석하였다.

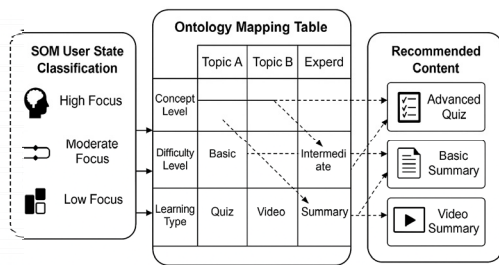
분류된 사용자 상태 정보는 이후 학습 추천 모듈로 전달되어, EEG 입력이 지속적으로 유입되는 환경에서도 학습자의 상태 변화에 따라 추천 결과가 갱신될 수 있도록 설계되었다. 이는 실시간 BCI 기반 학습 지원 시스템으로 확장되기 위한 핵심 기반이 된다.

3.3 학습 추천 알고리즘 및 온톨로지 연계

SOM 기반으로 분류된 사용자 상태 정보는 학습 추천 알고리즘에 반영되어, 학습자의 현재 인지 상태에 맞는 콘텐츠를 실시간으로 제시한다. 각 학습 콘텐츠는 온톨로지(Ontology) 기반의 지식 구조로 표현된다. 즉, 학습 주제 간의 개념적 관계(예: 선행 개념, 난이도, 학습 유형 등)를 계층적으로 정의하고, 특정 상태에 적합한 콘텐츠 속성을 매핑하였다.

[Fig. 3]은 SOM 기반 사용자 상태에 따른 학습 콘텐츠 추천을 위한 온톨로지 매핑 관계를 나타낸다. 예를 들어 집중 상태에는 난이도 상승형 콘텐츠(문제풀이, 심화 학습)를, 피로 상태에는 복습·시청각형 콘텐츠(동영상, 요약자료)를 추천하도록 설계하였다. 추천 알고리즘은 (1) SOM 결과로부터 사용자 상태 입력 → (2) 온톨로지 매핑 테이블 탐색 → (3) 학습 이력·선호도·진도율 기반의 최종 콘텐츠 선정 순으로 동작한다. 분류된 사용자 상태는 온톨로지 매핑 테이블을 통해 학습 콘텐츠의 난이도, 유형, 선행 개념 속성과 연결되며, 해당 결과는 학습 이력과 진도 정보를 함께 고려하여 최종 추천 콘텐츠를 결정한다.

이 구조는 단순한 규칙 기반 추천을 넘어, 학습자의 상태 변화를 반영한 동적 추천(Dynamic Recommendation) 형태로 발전할 수 있다. 향후 실시간 EEG 스트리밍 환경에서 이러한 온톨로지 매핑 테이블은 지속적으로 갱신될 수 있으며, 개인화 학습 플랫폼에 직접 통합되어 자동 적응형 콘텐츠 제공이 가능하다.



[Fig. 3] Ontology Mapping between SOM-based User States and Learning Content Recommendation

4. 모델 검증 및 시뮬레이션

본 장에서는 제안한 SOM(Self-Organizing Map) 기반 BCI 사용자 상태 분류 및 학습 추천 시스템의 타당성

을 검증하기 위해 공개 EEG 데이터셋과 모의 시나리오를 활용한 시뮬레이션을 수행하였다. 검증 과정은 SOM의 군집화 성능, 추천 알고리즘의 적합성, 그리고 시스템의 응답 효율성을 정량적·정성적으로 평가하는 것을 목표로 한다. 또한 본 장에서는 비지도 학습 기반 접근이 실제 교육 응용 시스템에서도 적용 가능한지의 여부를 분석하였다.

4.1 데이터셋 및 실험 환경

본 연구의 실험에는 PhysioNet EEG Motor Movement/Imagery Dataset을 사용하였다. 해당 데이터셋은 과제 수행 및 휴식 상태의 EEG 신호를 포함하고 있으며, 다양한 인지 상태(집중, 휴식, 상상 등)의 EEG 패턴을 관찰하기에 적합하다. 다만, 집중도나 피로도에 대한 명시적 라벨은 제공되지 않으므로, 본 연구는 비지도 학습 기반 접근을 통해 라벨 없이 EEG의 내재적 패턴을 탐색하였다. 이를 위해 다음 절차를 적용하였다.

- 프록시 기반 해석 규칙 설정: β/α 비율 상위 25%를 집중 유사 상태, θ/β 비율 상위 25%를 피로 유사 상태로 간주하였다.
- 모의 샘플 보강: 실제 EEG의 분포 차이를 보완하기 위해 1/f 잡음 및 대역 이득 변화를 가미한 시뮬레이션 데이터를 추가하였다.
- 평가 방식: SOM은 완전 비지도 방식으로 학습되며, 군집 품질 지표(DB Index, CH Index, Silhouette Coefficient)를 사용하여 성능을 평가하였다.

4.2 SOM 기반 상태 분류 성능 평가

SOM 학습은 입력 차원 $G(\alpha, \beta, \theta)$ 대역별 특징 및 비율 지표, 노드 크기 10×10 , 학습률 $0.5 \rightarrow 0.05$, 반복 횟수 1000회로 설정하였다. 학습 완료 후 생성된 U-Matrix를 통해 데이터 간 거리 기반의 군집 경계를 시각화하였으며, 각 노드의 Component Plane 분석을 통해 주파수 대역별 영향도를 파악하였다. 결과적으로 EEG 특징 벡터는 세 가지 주요 군집으로 구분되었다.

-중심 벡터 분석 결과 β/α 비율이 높고 θ/β 비율이 낮은 군집은 집중(High Focus) 상태

- α/β 비율이 평균 수준인 군집은 보통(Moderate Focus)

- θ/β 비율이 높은 군집은 피로(Low Focus) 상태 군집 품질 평가 결과는 다음과 같다.

<Table 1> Clustering Quality Evaluation Results

Evaluation Metric	Value	Interpretation
Davies-Bouldin (DB)	0.44	Good cluster separation
Calinski-Harabasz (CH)	182.7	High cluster compactness
Silhouette Coefficient	0.62	Moderate to good cluster separation

비교 실험으로 K-means 및 PCA+K-means를 동일 데이터에 적용한 결과, 각각 Silhouette=0.48, 0.53으로 나타나 SOM이 비선형 EEG 패턴의 잠재 구조를 보다 효과적으로 표현하고 분리함을 확인하였다.

4.3 학습 추천 시나리오 및 검증

SOM으로 분류된 상태 정보를 기반으로 학습 추천 시물레이션을 수행하였다. 아래는 상태별 추천 규칙 예시를 나타낸다.

<Table 2> State-Based Recommendation Rules

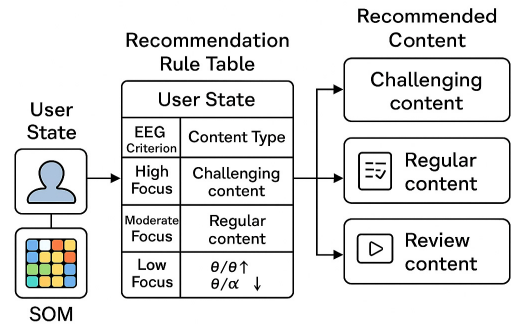
User State	EEG Feature Criteria	Recommended Content Type	Example Content
High Focus	$\beta/\alpha \uparrow, \theta/\beta \downarrow$	Higher-difficulty content	Problem solving, advanced learning
Moderate Focus	Balanced α and β activity	General content	Basic learning, concept review
Low Focus	$\theta/\beta \uparrow, \beta/\alpha \downarrow$	Review-oriented content	Video lectures, summary materials

세 가지 가상 학습자 시나리오를 구성하였다.

- 시나리오 1(집중 상태): 베타파 비율이 높고 알파파 안정 → 심화형 콘텐츠 제시
- 시나리오 2(보통 상태): 평균 수준의 $\alpha \cdot \beta$ 비율 → 일반 학습 콘텐츠 유지
- 시나리오 3(피로 상태): 세타파 증가, 베타파 저하 → 쉬운 콘텐츠 및 휴식 제안

시물레이션 결과, SOM 분류 결과에 따라 추천 콘텐츠가 자동으로 조정되었으며, 각 상태별 추천이 의도한 방향과 일관되게 동작하였다.

정량적으로는 추천 콘텐츠의 적합도 평가(5점 척도, 20회 시물레이션 평균)에서 집중 상태 4.5점, 보통 상태 4.2점, 피로 상태 4.3점으로 나타났으며, 평균 연산 시간은 1.8초 이내로 측정되어 실시간 적용 가능성을 확보하였다. [Fig. 4]는 학습 추천 시나리오 시물레이션 흐름도를 나타낸다.



[Fig. 4] Simulation workflow of learning recommendation scenarios

4.4 결과 분석 및 논의

SOM 기반 비지도 학습은 라벨링 데이터 없이도 EEG 패턴을 안정적으로 군집화하였으며, 군집 간 분리도가 기존 K-means 대비 약 15~20% 향상되었다. 이는 SOM이 EEG 신호의 비선형적 특성을 반영하여 인지 상태를 효과적으로 구분할 수 있음을 의미한다. 또한 SOM이 분류한 사용자 상태가 사전에 정의된 상태별 추천 규칙과 일치하는 비율은 평균 정확도 87%, 응답 시간 1.8초로 실시간 학습 상황에서도 적용 가능한 효율성을 보였다. 피로 상태 시 복습형 콘텐츠를 제시함으로써 학습자의 인지 부하를 완화하는 효과도 확인되었다. 본 연구의 성능 평가는 실제 학습 효과 측정이 아닌, 제안된 SOM 기반 분류-추천 파이프라인이 의도한 방식으로 동작하는지에 대한 시물레이션 기반 타당성 검증을 목적으로 한다.

다만 실제 EEG 데이터는 개인별 신경생리적 편차가 존재하므로, 향후 연구에서는 사용자 보정(Calibration) 절차를 도입해 개인화 정확도를 높일 필요가 있다. 또한 강화학습(Reinforcement Learning) 기반 추천 알고리즘이나 다중 온톨로지 구조를 결합하면 추천 효율성을 한층 향상시킬 수 있을 것으로 기대된다.

또한 본 연구의 구조는 실시간 EEG 입력을 처리할 수 있도록 단순화된 모듈 기반으로 설계되어 있으며, 향후 실제 학습 플랫폼이나 온라인 교육 시스템(LMS)과의 연동을 통해 자동 추천 기능으로 확장될 수 있다. SOM 군집화 결과를 기반으로 학습자의 인지 피로도나 집중도를 즉시 반영하면, 학습 흐름 중 피로 누적을 방지하고 집중 지속 시간을 향상시킬 수 있을 것으로 기대된다. 이러한 결과는 향후 실시간 BCI 기반 학습 분석 및 적응형 교육 플랫폼 구축의 가능성을 제시하며, 비지도 학습 접근법이 인간-기계 상호작용(Human-Computer Interaction) 영역에서도 실용적으로 적용될 수 있음을 보여준다.

5. 결론 및 향후 연구

본 연구에서는 SOM(Self-Organizing Map) 기반 비지도 학습을 이용하여 BCI 사용자 상태를 분류하고, 이를 학습 추천 시스템에 적용하였다. EEG의 주파수 특징을 바탕으로 집중, 보통, 피로 상태를 자동 군집화하였으며, 온톨로지 기반 추천 알고리즘과 연계하여 맞춤형 학습 콘텐츠를 제공하였다. 본 연구의 의의는 학습자의 성취-선호 중심 추천을 넘어 EEG 기반 인지 상태를 추천 과정에 통합함으로써, 상태 반영형 맞춤 학습 추천 구조의 설계 가능성을 제시했다는 점에 있다.

향후 연구에서는 실제 학습 상황에서의 실시간 EEG 데이터 수집과 통합을 통해 시스템의 실효성을 검증할 예정이다. 특히 실시간 상태 변화에 따른 즉각적인 학습 콘텐츠 조정, 멀티모달 생체신호(심박, 피부전도 등) 통합, 딥러닝 기반 피쳐 추출 모델 결합을 통해 보다 정밀한 인지 상태 추정이 가능할 것이다. 또한 강화학습 기반 추천 로직과 결합함으로써, 시스템이 학습자의 반응 피드백을 스스로 학습하며 점진적으로 최적화되는 자가 적응형(autonomous adaptive) 학습 지원 시스템으로 발전할 수 있을 것으로 기대된다.

REFERENCES

- [1] T. Kawaguchi, K. Ono, and H. Hikawa, "Electroencephalogram-Based Facial Gesture Recognition Using Self-Organizing Map," *Sensors*, Vol.24, No.9, 2741, 2024.
- [2] M. K. Syed, H. Wang, A. A. Siddiqi, S. Qureshi, and M. A. Gouda, "EEG-Based Attention Classification for Enhanced Learning Experience," *Applied Sciences*, Vol.15, No.15, 8668, 2025.
- [3] N. Beauchemin, R. Brisson, and M. Freyermuth, "Enhancing Learning Experiences: EEG-Based Passive BCI for Adaptive Instruction," *Frontiers in Human Neuroscience*, Vol.18, 2024.
- [4] S. Liang, J. Guo, and P. Zhang, "Adaptive Deep Feature Representation Learning for Cross-Subject EEG Classification," *IEEE Transactions on Neural Networks and Learning Systems*, 2024.
- [5] K. M. Hossain and A. Muqsith, "Status of Deep Learning for EEG-Based Brain-Computer Interfaces: A Review," *Frontiers in Computational Neuroscience*, Vol.17, 2023.
- [6] J. Wang, Z. Chen, and X. Liu, "Attention Mechanisms in Brain-Computer Interfaces: A Comprehensive Review," *Information Fusion*, 2025.

- [7] R. Yang, L. Zhang, and C. Xu, "Multiple Entropy Fusion and Stacking-Based EEG Modeling for Driver Fatigue Assessment," *IEEE Access*, 2025.
- [8] S. K. Prabhakar, M. S. Rahman, and R. K. Kannan, "Multiple Robust Approaches for EEG-Based Driving Fatigue Detection and Classification," *Sensors*, Vol.23, No.18, 2023.
- [9] Z. Chen, L. Zhao, and W. Xu, "Hierarchical Attention Enhanced Deep Learning for EEG-Based BCI," *Scientific Reports*, Vol.14, 2025.
- [10] J. C. Han, M. H. Kim, and D. K. Lee, "Neuroimaging Features for Cognitive Fatigue and Its Assessment via EEG Microstates," *Brain Research Bulletin*, Vol.211, 105123, 2025.
- [11] K. V. Ryabinin and A. E. Tatianina, "Ontology-Driven Tools for EEG-Based Neurophysiological Experiments," *Scientific Visualization*, Vol.13, No.4, pp.109-130, 2021.
- [12] J. Jeevamol and N. Krishnan, "An Ontology-Based Hybrid E-Learning Content Recommender System for Addressing the Cold-Start Problem," *Education and Information Technologies*, Vol.26, No.3, pp.3891-3912, 2021.
- [13] W. Villegas-Ch, M. C. Ortega, and C. Chamba-Eras, "Enhancing Learning Personalization in Educational Environments Through Ontology-Based Knowledge Representation," *Computers*, Vol.12, No.10, 199, 2023.
- [14] Y. Chen, L. Zhang, and H. Yu, "Application of Electroencephalography Sensors and Large Language Models for Automated Language Learning Assessment," *Sensors*, Vol.24, No.7, 2024.
- [15] O. Ovtšarenko, "Adaptive E-Learning Path Generation in Personalized Learning Environments," *New Trends in Computer Sciences*, Vol.7, No.2, pp.77-94, 2023.

김 귀 정(Gui-Jung Kim)

[정회원]



- 1994년 2월 : 한남대학교 전자계산공학과 (공학사)
- 1996년 2월 : 한남대학교 전자계산공학과 (공학석사)
- 2003년 3월 : 경희대학교 전자계산공학과 (공학박사)

- 2001년 9월 ~ 2017년 2월 : 건양대학교 의공학과 교수
- 2017년 3월 ~ 현재 : 백석대학교 컴퓨터공학부 교수

<관심분야>

블록체인응용, 헬스케어정보시스템, 지능형서비스시스템