

# 뇌-기계 인터페이스를 위한 모델 기반 디코더 및 딥러닝 디코더 간의 트레이드 오프 탐색

## Investigating the Trade-off Between Model-based and Deep Learning Decoders for Brain-machine Interfaces

이 승 한<sup>1</sup>, 김 준 식<sup>1</sup>, 정 천 기<sup>1</sup>, 김 성 필<sup>1,\*</sup>

(Seunghan Lee<sup>1</sup>, June Sic Kim<sup>2</sup>, Chun Kee Chung<sup>3</sup>, and Sung-Phil Kim<sup>1,\*</sup>)

<sup>1</sup>Department of Biomedical Engineering, Ulsan National Institute of Science and Technology

<sup>2</sup>Clinical Research Institute, Konkuk University Medical Center, Konkuk University Hospital

<sup>3</sup>Neuroscience Research Institute, Seoul National University Medical Research Center

**Abstract:** Severely paralyzed patients encounter major difficulties with daily tasks, restricting their independence and quality of life. Over the last few decades, brain-machine interfaces (BMIs) have emerged as game-changing paradigms, enabling patients to voluntarily control external devices (e.g., robotic arms) through neural signals. Among the key components of BMIs, the decoder, which interprets user intentions from neural activity, has significantly improved with deep learning. These deep-learning-based decoders have demonstrated state-of-the-art performance in BMI control. However, due to their complex model architecture, they typically require greater computational resources for training. This can pose a significant challenge for practical deployment, particularly in real-world BMI applications where computational constraints and environmental variability may differ from controlled laboratory settings. Models such as the Kalman filter (KF) are still popular in clinical and assistive applications due to their comparable performance to deep learning methods while requiring much fewer computational resources. In this study, we compared three decoding approaches using electrocorticography (ECoG) data from patients: the multiple linear regression model; the KF, which incorporates temporal dynamics; and a long short-term memory (LSTM) based recurrent deep-learning model. This comparison highlights the trade-off between computational cost and performance in real-world ECoG BMI applications.

**Keywords:** brain-machine interface, electrocorticography, neuronal decoder, machine learning, deep learning

### I. 서론

중증의 마비 환자는 일상적인 활동 수행에 어려움을 겪으며, 이는 삶의 질 저하로 이어진다. 특히 사지 마비 환자들은 물리적인 자율성이 제한되어 간단한 움직임조차 타인의 도움이 필요하다[1]. 이러한 환자들의 삶의 질을 향상시키기 위해 다양한 재활 장치와 보조 기술이 개발되어 왔으며, 그 중 뇌-기계 인터페이스(BMI)는 뇌 신호만을 통해 외부 장치를 제어할 수 있는 획기적인 기술로 부상하고 있다.

BMI는 뇌에서 발생하는 전기적 활동을 기록하고, 이를 디코딩 알고리즘을 통해 해석한 뒤, 해당 출력을 외부 장치와의 상호작용에 사용하는 방식으로 작동한다. 인공지능 알고리즘이 자율 시스템, 동역학 연구와 같이 다양한 연구분야에서 활용되는 가운데[2-3], 최근 BMI 분야에서도 딥러닝 기반 디코더가 최우선 선택지로 자리잡고 있다. 특히, 움직일 수 없는 사람이 상상하는 손끝끝을 인식하거나[4], 말할 수 없는 사람의 상상 음성 발화를 실시간 음성으로 생성하는[5] 것과 같은 새로운 응용 사례들이 딥러닝 알고리즘을 통해 가능해

지고 있다. 또한, 손가락 움직임의 실시간 예측[6], 커서 제어 [7] 등 기존에는 선형 디코더만 사용되던 영역에서도 딥러닝 모델이 높은 성능을 보여주고 있다.

이러한 딥러닝 모델은 복잡한 구조와 비선형 구조의 도입을 통해 높은 예측 정확도를 보이지만, 연산량이 많고 학습에 많은 시간이 소요되며, 실시간성이 중요한 응용 분야에서는 한계가 존재한다. 반면, 칼만 필터(Kalman filter)는 비교적 단순한 수학 모델을 기반으로 하여, 낮은 계산 비용과 실시간 처리의 장점을 갖는다[8-9]. BMI와 같은 실시간 제어 시스템에서는 정확도뿐만 아니라, 자원 효율성, 구현의 용이성 등이 중요한 요소로 작용한다.

본 연구에서는 대표적인 디코딩 방식인 다중선형회귀모델, 속도 칼만 필터, 칼만 필터, LSTM을 오프라인 디코딩 분석을 통해 디코딩 모델 간의 트레이드오프를 실험적으로 규명했다. 속도 칼만 필터가 가장 높은 궤적 제어 성능을 보여준 반면 노이즈 강건성 측면에서는 낮은 성능을 보였다. LSTM은 노이즈 강건성 측면에서 매우 높은 성능을 보였지만, 궤

\* Corresponding Author

Manuscript received April 18, 2025; revised June 15, 2025; accepted June 15, 2025

이승한: 울산과학기술원 바이오메디컬공학과 대학원생(seunghan95@unist.ac.kr, ORCID<sup>®</sup> 0009-0005-9148-3347)

김준식: 건국대학교병원 임상의학연구소 연구교수(junesic.kim@gmail.com, ORCID<sup>®</sup> 0000-0002-9659-4944)

정천기: 서울대학교의학연구원 신경과학연구소 책임연구원(chungc@snu.ac.kr, ORCID<sup>®</sup> 0000-0003-3485-2327)

김성필: 울산과학기술원 바이오메디컬공학과 교수(spkim@unist.ac.kr, ORCID<sup>®</sup> 0000-0001-6665-3475)

\* 본 연구는 2025년 정부(방위사업청)의 재원으로 국방과학연구소의 지원을 받아 수행된 미래도전국방기술 연구개발사업(No.915027201).

적 제어 성능이 좋지 못했을 뿐만 아니라 다른 모델 대비 매우 긴 학습시간이 소요됨을 확인할 수 있었다.

## II. 본론

### 1. 뇌피질전위 데이터

#### 1.1 피험자정보

본 연구에서는 국내 병원에서 뇌전증 진단을 받은 14명(남성 8명, 여성 6명, 나이범위: 18-58세, 평균나이: 30.79±12.55세)의 피험자로부터 수집된 피질전위(ECoG) 데이터를 사용하였다. ECoG 신호는 각 환자의 뇌전증 병변 위치에 따라 삽입된 피질 표면 전극을 통해 수집되었으며, 채널의 수(20-96개)와 위치는 환자마다 상이했다. 실험 중에 측정된 모든 ECoG 신호는 2 kHz로 샘플링되었다.

#### 1.2 중심-방향 운동 과제 실험 패러다임

참가자들은 오른손을 이용하여 목표까지 팔을 뻗는 중심-방향 운동 과제(center-out task)를 수행하였다. 과제가 시작되면 참가자는 먼저 손을 중심위치에 위치시킨 후, 무작위로 제시되는 4개의 목표 방향 중 하나로 손을 이동시켰다. 참가자별 시행 횟수는 약 40-250회(중앙값: 80회)였고, 특정 방향에 대한 편향이 생기지 않도록 각 피험자는 네 방향에 대해 동일한 횟수의 시행을 반복했다. 목표 지점까지의 평균 이동 시간은 1.38±0.26초였고, 전세 실험을 완료하는데 걸린 시간은 피험자당 평균 43±20분이었다.

#### 1.3 데이터 전처리

과제 수행 중에 측정된 ECoG 신호는 60 Hz notch filtering, bandpass filtering, CAR (Common Average Referencing)의 전처리 과정을 거쳤다. 특히 ECoG 특성벡터를 추출하기 위해서 0.2~8 Hz 대역 신호를 bandpass filtering 하였고, 필터링된 저주파의 대역신호 자체를 특성벡터로 간주하여 추가적인 특성추출 작업은 수행하지 않았다.

과제 수행 중에 이동하는 손의 궤적을 3차원 움직임 감지 센서를 이용해서 손의 위치와 속도 데이터를 측정했다. 본




그림 1. 중심-방향 운동 과제(center-out task) 실험 패러다임.  
Fig. 1. Center-out task experiment paradigm.

연구에서는 3차원 데이터 중 모델에 따라서  $x$ 축과  $y$ 축의 2차원 속도벡터 혹은 위치와 속도벡터를 병합한 벡터를 디코딩 모델 적합을 위해 사용했다.

### 2. 디코딩 모델구조

#### 2.1 선형회귀모델

선형 회귀는 독립 변수  $x$ 와 종속 변수  $y$ 간의 선형 관계를 모델링하는 대표적인 지도학습 기법으로 본 연구에서는 속도 정보를 디코딩하기 위해 다음과 같은 구조로 정의했다.

$$\hat{y}_t = Wx_t + b$$

$$\mathcal{L} = \frac{1}{T} \sum_{t=1}^T \|y_t - \hat{y}_t\|^2 \quad (1)$$

여기서  $\hat{y}_t$ 는 시점  $t$ 에서의 속도 예측 값,  $x_t$ 는 ECoG 특성벡터,  $W$ 는 회귀 가중치 행렬,  $b$ 는 편향(bias) 항이다. 학습은 실제 속도 값  $y_t$ 과 예측 값  $\hat{y}_t$ 사이의 오차를 최소화하는 최소제곱법(least square method)를 사용했다.

#### 2.2 칼만 필터

##### 2.2.1 칼만필터의 구조

칼만 필터는 선형 상태공간 모델 기반의 시계열 추론 방식으로, 시스템의 상태와 관측 값 사이의 관계를 다음과 같은 수식으로 표현한다.

$$x_t = Ax_{t-1} + w_t$$

$$z_t = Hx_t + v_t \quad (2)$$

여기서  $x_t$ 는 시스템의 상태벡터,  $z_t$ 는 ECoG 특성벡터,  $A$ 는 상태 전이 행렬,  $H$ 는 관측 행렬,  $w_t \sim \mathcal{N}(0, W)$ 와  $v_t \sim \mathcal{N}(0, Q)$ 는 각각 상태 및 관측 잡음이다. 칼만 필터는 다음의 예측 및 업데이트 단계로 구성된다:

$$\text{예측 단계: } \hat{x}_{t|t-1} = A\hat{x}_{t-1|t-1}$$

$$\text{갱신 단계: } \hat{x}_{t|t} = \hat{x}_{t|t-1} + K_t(z_t - H\hat{x}_{t|t-1}) \quad (3)$$

여기서  $K_t$ 는 칼만 이득(Kalman gain)으로, 오차 공분산을 기반으로 계산된다. 동시에 칼만필터는 해당 상태 예측 값의 불확실성(공분산)도 계산한다:

$$\Sigma_{t|t-1} = A\Sigma_{t-1}A^T + W \quad (4)$$

여기서  $W$ 는 선형 상태공간 모델로 추가되는 불확실성이다.

##### 2.2.2 칼만필터의 종류

본 연구에서는 상태벡터의 구조에 따른 칼만필터 모델 간의 트레이드오프를 비교했다. 예를 들어,  $p_x, p_y$ 를 현재 위치,  $v_x, v_y$ 를 현재 속도로 정의하자. 첫 번째 모델에서는 상태벡터를 다음과 같이 구성하고  $A$ 와  $W$ 를 아래 식 (5)의 제약조건으로 정의했다.

이와 같은 구성으로 위치는 완벽하게 속도에 의해서 예측이 되도록 모델을 구축했다. 모델 적합을 시키면 일반적으로  $a_{v_y, v_x}$ 와  $a_{v_x, v_y}$ 는 0에 가까운 값을 가지고 대각요소인  $a_{v_x, v_x}$

와  $a_{v^y, v^y}$ 는 1보다 작은 값을 가지게 되어 감쇠 속도 다이나믹(damped velocity dynamics)을 보이게 된다.

$$x_t = [p_x, p_y, v_x, v_y]^T$$

$$A = \begin{bmatrix} 1 & 0 & dt & 0 \\ 0 & 1 & 0 & dt \\ 0 & 0 & a_{v^x, v^x} & a_{v^x, v^y} \\ 0 & 0 & a_{v^y, v^x} & a_{v^y, v^y} \end{bmatrix}$$

$$W = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & w_{v^x, v^x} & w_{v^x, v^y} \\ 0 & 0 & w_{v^y, v^x} & w_{v^y, v^y} \end{bmatrix} \quad (5)$$

두 번째 모델에서는 상태벡터를 다음과 같이 구성했다.

$$x_t = [v_x, v_y]^T \quad (6)$$

이와 같은 구성은 첫 번째 모델의 식 (5)에서  $A$ 와  $W$ 의 위치 관련 요소를 모두 0으로 만들고 우측 하위 블록만을 남긴 구조와 같다.

### 2.3 장단기 기억 네트워크(LSTM)

본 연구에서는 가장 일반적인 구조의 LSTM을 사용했다. LSTM은 입력 시퀀스의 장기 의존성을 학습할 수 있는 순환 신경망 구조이다. 각 시점  $t$ 에서의 계산은 다음과 같은 게이트 기반 수식으로 정의된다:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t$$

$$h_t = o_t \odot \tanh(c_t) \quad (7)$$

여기서,  $x_t$ 는 ECoG 특성벡터,  $h_t$ 는 은닉 상태,  $c_t$ 는 셀 상태,  $\sigma$ 는 sigmoid 함수,  $\odot$ 는 요소별 곱(element-wise multiplication)을 의미한다. LSTM에서 출력 값은 은닉 상태  $h_t$ 이며, 이는 후속 회귀 레이어(regression layer)의 입력으로 전달된다. 회귀 레이어의 출력 값이 시점  $t$ 의 속도 값이 된다.

LSTM 레이어는 단일 레이어로 구성했고, 300개의 LSTM 유닛을 사용했다.

### 3. 디코더 예측 성능 비교

그림 2는 실제 손 궤적과 다양한 디코딩 모델을 통해 예측된 손 궤적 예시를 나타낸다. 실제 손 궤적은 네 개의 방향으로 분리된 중심-방향(center-out) 형태를 나타내며, 모든 디코딩 모델의 예측 결과에서 네 방향으로 분리되는 양상을 확인할 수 있었다(그림 2 우측).

모델 간의 제어 성능을 정량적으로 비교하기 위해, 사용자 인터페이스 분야(human-computer interaction, HCI)에서 포인팅 장치(예: 마우스)의 성능 평가에 사용되는 지표를 적용하였다




그림 2. 디코딩 모델로 예측된 손 궤적 예시.  
Fig. 2. Example of hand trajectories decoded by each model.

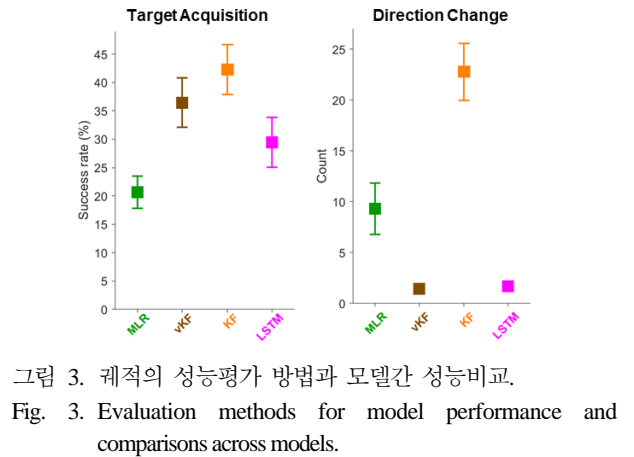



그림 3. 궤적의 성능평가 방법과 모델간 성능비교.  
Fig. 3. Evaluation methods for model performance and comparisons across models.

[10]. 구체적으로, 예측된 궤적이 목표 지점에 도달했는지 여부를 통해 목표 도달 성공률을 측정하였으며, 궤적의 방향 전환 횟수를 기준으로 직진성(straightness)을 평가하였다(그림 3 상단 참조).

분석 결과, 속도 칼만 필터(vKF)와 칼만 필터(KF)는 다른 모델 두 모델에 비해 더 높은 목표 도달 성공률을 나타냈다(그림 3 하단 왼쪽). 흥미롭게도, LSTM 모델은 예측과는 달리 낮은 성공률을 보였다. 이는 충분한 최적화가 이루어지지 않은 결과로 예상된다.

반면, 직진성 지표에서는 vKF와 LSTM 모델이 가장 우수한 성능을 보였으며, KF는 가장 낮은 직진성을 기록하였다(그림 3 하단 오른쪽). 이는 KF 구조 내에서 위치 정보에 대해 항상 일정 수준의 사전 불확실성이 존재한다는 점과 관련이 있을 수 있다. 특히 식 (5)의  $A$ 에서 보듯이, 속도의 불확실성이 위치로 전파되어 궤적에 노이즈 같은 진동(jitter)을 유발할 수 있으며, 이러한 특성이 직진성 저하로 이어졌을 가능성이 있다[9].

### 4. 모델 훈련시간 비교

그림 4는 각 모델의 적합을 위해서 소요된 시간을 비교한

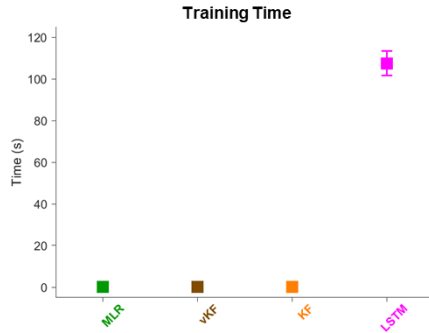


그림 4. 모델 적합 소요시간.  
Fig. 4. Computational time for model fitting.

결과를 보여준다. 다중선형회귀(MLR), vKF, KF는 모두 비교적 짧은 시간 내에 적합이 완료되었다. 반면, LSTM 모델은 다른 모델들과 비교하여 현저히 긴 적합 시간을 보였다. 이는 LSTM이 갖는 복잡한 네트워크 구조와 그에 수반되는 상대적으로 많은 수의 학습 파라미터에 기인한 것으로 해석된다.

5. 모델의 노이즈 저항성 비교

노이즈에 대한 강건성은 실제 BMI 조작 환경에서 안정성과 직결되는 중요한 성능 척도 중 하나이다. 실제 데이터의 표준편차의 배수로 노이즈를 추가하여 각 디코딩 모델의 예측 성능을 비교했다.

그림 5는 각 모델의 노이즈에 대한 민감도 및 강건성을 평가한 결과를 보여준다. 상단 그래프는 데이터 표준편차의 0.1 배의 노이즈(Magnitude), 지속 시간 50 ms (Duration) 조건 하에서 실제 속도(검정 실선)와 각 모델의 추정된 속도를 비교한 것이다. vKF와 LSTM은 일정 수준의 추세를 유지했으나, MLR은 노이즈에 민감하게 반응하여 큰 스파이크(spike)를 보인 이후 기존 속도 추세를 유지했다. KF는 노이즈의 영향을 비교적 오래 유지하는 양상이 관찰되었다.

그림 5의 하단 두 그래프는 노이즈 지속 시간과 노이즈 크기에 따른 RMSE 변화를 보여준다. LSTM을 제외한 모델이 노이즈 크기나 지속시간의 증가에 따라 RMSE가 증가하는

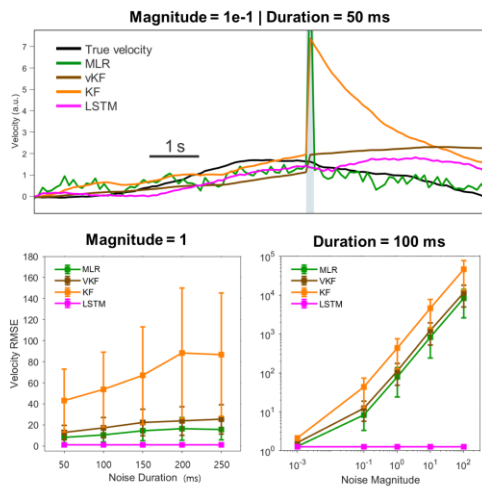


그림 5. ECoG 데이터에 노이즈 추가에 따른 모델 강건성 평가.  
Fig. 5. Model robustness evaluation under noise injection in ECoG data.

경향을 보였고, 특히 다른 모델 대비 KF의 큰 성능 변화를 관찰할 수 있었다. 반면, LSTM은 전체 노이즈 범위에서 일관된 성능을 유지하였다.

KF의 경우 물리 기반의 상태공간 모델을 활용하기 때문에 이론적으로 잡음이 섞인 데이터에서 보다 정확한 운동 정보를 추정할 수 있도록 설계 되어있다. 하지만 본 실험의 결과는 ECoG 데이터에는 비선형 딥러닝 기반 모델인 LSTM이 노이즈에 대해 더 높은 강건성을 가짐을 시사한다.

III. 결론

본 연구에서는 동일한 피질전위 기반 BMI 환경에서 대표적인 디코딩 알고리즘인 다중선형회귀(mLR), 속도 칼만 필터(VKF), 칼만 필터(KF), 그리고 LSTM을 비교 분석하여, 각 모델의 구조적 특성과 실제 응용에서의 장단점을 실험적으로 규명하였다.

속도 칼만 필터는 가장 높은 궤적 제어 성능을 보여주며 실시간 제어에 적합한 디코더로서의 가능성을 보였으나, 노이즈 주입 조건에서는 상대적으로 낮은 강건성을 보였다. 반면, LSTM은 노이즈 강건성 측면에서 가장 우수한 성능을 보였지만, 궤적 제어 정확도는 칼만 필터에 비해 낮았고, 훈련 시간이 길고 계산 자원 소모가 크다는 한계가 존재하였다. 칼만 필터는 낮은 연산량에도 불구하고 비교적 안정적인 성능을 유지하였으며, 과적합 위험이나 추론 지연 없이 동작 가능한 실시간 응용 환경에서의 장점을 확인할 수 있었다. 다중선형회귀는 구조가 단순하고 빠르지만, 복잡한 운동 패턴을 정밀하게 추적하는 데에는 성능의 한계가 있었다.

또한, 본 연구에서는 모델 최적화 과정을 수행하지 않았음에도 불구하고 LSTM은 상당한 계산 비용을 요구하였으며, 최적화를 포함할 경우 그 자원 소모는 더욱 클 것으로 예상된다. 이는 실시간 BMI 시스템이나 계산 자원이 제한된 환경에서는 선형 기반 모델의 실용성이 더 클 수 있음을 시사한다.

결론적으로, BMI 디코더의 선택은 단순히 정확도만이 아니라, 실시간성, 연산 효율성, 노이즈 강건성, 그리고 사용자 및 하드웨어 제약에 대한 적합성 등 다양한 요소를 종합적으로 고려하여 결정되어야 함을 본 연구에서 실험적으로 보여주었다. 향후 연구에서는 칼만 필터의 예측 정확도를 향상시키거나, LSTM을 경량화하여 실시간 시스템에 적용할 수 있는 방안을 모색하고, 두 접근법의 장점을 결합한 하이브리드 디코더 개발 또한 유망한 방향이 될 수 있다. 아울러, 신호 특성 및 사용자 특성에 따라 디코더 성능이 달라질 수 있는 만큼, 사용자 맞춤형 튜닝, 온라인 적응형 학습, 다양한 환경에 대응 가능한 범용 디코딩 구조에 대한 연구도 필요하다.

REFERENCES

[1] B. S. Armour, E. A. Courtney-Long, M. H. Fox, H. Fredine, and A. Cahill, "Prevalence and causes of paralysis—united states, 2013," *American Journal of Public Health*, vol. 106, no. 10, pp. 1855-1857, Oct. 2016.

[2] T. Park, H. Shin, and H. Oh, "Detection of fiducial marker with neural network compression," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 29, no. 8, pp. 628-635, Aug. 2023.

- [3] K. H. Kim, C. Jeong, J. Kim, S. Lee, and C. M. Kang, "Neural network modeling approach for vehicle lateral dynamics using real vehicle data," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 30, no. 7, pp. 696-702, Jul. 2024.
- [4] M. S. Willsey, S. R. Nason-Tomaszewski, S. R. Ensel, H. Temmar, M. J. Mender, J. T. Costello, P. G. Patil, and C. A. Chestek, "Real-time brain-machine interface in non-human primates achieves high-velocity prosthetic finger movements using a shallow feedforward neural network decoder," *Nature Communications*, vol. 12, no. 1, p. 6899, Nov. 2022.
- [5] D. A. Moses, S. L. Metzger, J. R. Liu, G. K. Anumanchipalli, J. G. Makin, P. F. Sun, J. Chartier, M. E. Dougherty, P. M. Liu, G. M. Abrams, et al., "Neuroprosthesis for decoding speech in a paralyzed person with anarthria," *New England Journal of Medicine*, vol. 385, no. 3, Jul. 2021.
- [6] S. R. Nason, M. J. Mender, A. K. Vaskov, M. S. Willsey, N. Ganesh Kumar, T. A. Kung, P. G. Patil, and C. A. Chestek, "Real-time linear prediction of simultaneous and independent movements of two finger groups using an intracortical brain-machine interface," *Neuron*, vol. 109, no. 19, Oct. 2021.
- [7] W. Wu, M. Black, Y. Gao, M. Serruya, A. Shaikhoui, J. Donoghue, and E. Bienenstock, "Neural decoding of cursor motion using a kalman filter," *Advances in neural information processing systems*, 2002.
- [8] S.-P. Kim, J. D. Simeral, L. R. Hochberg, J. P. Donoghue, and M. J. Black, "Neural control of computer cursor velocity by decoding motor cortical spiking activity in humans with tetraplegia," *Journal of Neural Engineering*, vol. 5, pp. 455-476, Dec. 2008.
- [9] V. Gilja, P. Nuyujukian, C. A. Chestek, J. P. Cunningham, B. M. Yu, and J. M. Fan, "A brain machine interface control algorithm designed from a feedback control perspective," *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1318-1322, 2012.
- [10] S. A. Douglas, A. E. Kirkpatrick and I. S. MacKenzie, "Testing pointing device performance and user assessment with the ISO 9241 Part 9 standard," *Proc. SIGCHI Conf. on Human Factors in Computing Systems (CHI'99)*, pp. 215-222, 1999.



### 이 승 한

2020년 충남대학교 생물과학과 졸업.  
2021년~현재 울산과학기술원 대학원 바이오메디컬공학과 석박통합과정 재학 중. 관심분야는 신경 디코딩, 뇌-기계 인터페이스, 신경 동역학 모델링.



### 김 준 식

2002년 한양대학교 바이오메디컬공학과 (공학박사). 2004년~2014년 서울대학교 병원 신경외과 조교수. 2014년~2023년 서울대학교 기초과학연구원 연구교수. 2023년~현재 건국대학교병원 임상의학 연구소 연구교수. 관심분야는 뇌-기계 인터페이스, 신경 이미징, 딥러닝.



### 정 천 기

1993년 서울대학교 의과대학원 신경외과(의학박사). 2006년~2023년 서울대학교 병원 신경외과 교수. 2013년~2023년 서울대학교 뇌인지과학과 교수. 2023년~현재 서울대학교 의학연구원 신경과학 연구소 책임연구원. 관심분야는 음성발화 뇌-기계 인터페이스.



### 김 성 필

2005년 University of Florida, Department of Electrical and Computer Engineering(공학박사). 2013년~2020년 울산과학기술원 인간공학과 교수, 2020년~현재 울산과학기술원 바이오메디컬공학과 교수. 관심분야는 신경 디코딩, 뇌-기계 인터페이스, 신경 동역학 모델링.