

## A Framework for Learning and Reuse of Motor Patterns Emerged from Embodied Chaotic Search

Yoonsik Shim\*

\*Professor, Dept. of Software Engineering, Pai Chai University, Daejeon, Korea

### [Abstract]

We present an improved framework for stabilizing and reusing self-organized motor patterns discovered through chaotic search in embodied neuromechanical systems. Based on the Embodied Chaotic Search (ECS) paradigm—which enables the emergent generation of periodic motor patterns via neuro-body-environment interactions without episode-based machine learning—our approach addresses the inherent limitation of pattern instability. The proposed method introduces a two-stage process that decouples search and learning. Upon detecting a promising motor pattern, external sensory feedback is suppressed to freeze the system's dynamics, enabling stable learning of inter-CPG coupling weights through adaptive synchronization. The learned weights are stored and can be reloaded to reliably reproduce the pattern. Phase space deformation before and after learning is visualized, demonstrating the convergence of multiple transient attractors into a single stable one. To reduce complexity, we replace the rotation-center correction of prior adaptive synchronization algorithms with a bias-based learning mechanism compatible with standard neural models. This framework improves the acquisition and memory stability of the ECS system and highlights the potential of leveraging these patterns as initial policies for conventional machine learning, as well as foundational motor primitives for high-level behavioral synthesis in robotic systems.

▶ **Key words:** Embodied AI, Self organization, Chaotic exploration, Central pattern generator, Adaptive synchronization, Motor primitive, Neuromechanical system

### [요 약]

본 연구는 체화된 신경-기계 시스템에서 카오스 기반 탐색을 통해 자가조직적으로 생성된 운동 패턴을 안정화 및 재사용을 위한 향상된 프레임워크를 제안한다. 제시된 방법은 신경-신체-환경 간 상호작용을 통해 에피소드 기반 기계학습 없이 주기적 운동패턴이 자발적으로 생성되는 Embodied Chaotic Search(ECS) 패러다임에 기반하며, 기존 방식의 주요 한계였던 패턴의 불안정한 유지 문제를 개선하고자 한다. 이를 위해 패턴 탐색과 적응적 동기화 학습을 명시적으로 분리한 2단계 접근법을 도입함으로써, 유용한 후보 패턴이 탐지되면 외부 감각 입력을 차단하여 시스템의 동역학을 고정시키고, 적응적 동기화를 통해 CPG 간 결합 가중치를 안정적으로 학습할 수 있도록 한다. 학습된 가중치는 저장되어 로드 시 동일한 패턴을 안정적으로 재현 가능하며, 학습 전후 위상공간의 변화를 시각화함으로써 다수의 전이성 끌개들이 유일한 안정된 끌개로 수렴함을 확인하였다. 또한 기존 동기화 알고리즘의 회전중심 보정 과정을 대체하여, 표준 신경망 모델과 호환되는 바이어스 기반 학습 메커니즘도 제시하였다. 본 방법은 ECS 기반 시스템의 패턴 습득 및 기억 안정성을 향상시키고, 학습된 패턴을 강화학습의 초기 정책이나 고차원 로봇 행동 합성을 위한 운동원형으로 활용할 수 있는 가능성을 제시한다.

▶ **주제어:** 체화지능, 자가조직화, 카오스 탐색, 중추패턴발생기, 적응적 동기화, 운동원형, 신경-기계 시스템

- 
- First Author: Yoonsik Shim, Corresponding Author: Yoonsik Shim
  - Yoonsik Shim (ysshim@pcu.ac.kr), Dept. of Software Engineering, Pai Chai University
  - Received: 2025. 09. 01, Revised: 2025. 09. 24, Accepted: 2025. 09. 26.

## I. Introduction

자연계 동물들이 보이는 높은 적응성과 민첩성을 지닌 운동 제어는 단순히 뇌에서 근육으로 전달되는 일방적 명령으로만 이루어지지 않으며, 신경계와 신체, 그리고 이를 둘러싼 물리적 환경 간의 복잡한 상호작용을 통해 창발적으로 나타난다. 이러한 현상은 기존 신경망 모델이 수행하는 기계적이고 정적인 연산만으로는 설명하기 어려운 고차원적이고 비선형적인 동역학적 과정을 내포하고 있으며, 지능은 단순히 뇌의 정보처리에 국한되지 않고 신체 구조와 물리적 환경 간의 상호작용으로부터 출현한다는 사실을 시사한다[1][2].

이러한 관점은 현재 인공지능의 한계를 극복하기 위한 새로운 패러다임으로 주목받고 있는 체화지능(Embodied Intelligence)의 핵심 철학으로, 지능을 단지 뇌내에서만 이루어지는 정보처리로 국한하지 않으며 신체와 환경의 상호작용을 통해 출현하는 총체적 현상으로 이해한다 [2][3]. 이를 바탕으로, 로봇 지능 분야에서는 체화된 인공지능(Embodied AI)의 실현을 위해 비선형 동역학 시스템(Nonlinear dynamical system) 접근법이 주로 활용되고 있으며, 이를 통해 주기적 운동 패턴의 생성, 적응적 모델 개발, 그리고 생물학적 메커니즘의 모사 등이 활발히 연구되고 있다[4][5].

동역학적 체화지능 접근법은 기존 기계학습 기반 로봇 제어가 직면한 높은 계산 복잡도, 대규모 반복 시뮬레이션 비용, 현실 이식성(reality gap) 등의 문제를 극복하기 위한 대안으로 주목받고 있다. 이러한 시도 중 하나로 제안된 체화된 혼돈 탐색(Embodied Chaotic Search, ECS) 시스템[6][7][8]은 동물의 운동 발달 모델의 선구적 연구인 '체화를 통한 행동 창발(Behavior Emergence through Embodiment)' 모델[9][10]을 기반으로, 생물학적 운동지능에서 중요한 역할을 담당하는 자가조직화(self-organization), 카오스(chaos) 동역학, 그리고 형태학적 계산(morphological computation) 등의 개념들을 로봇 제어에 적용하여, 비 기계학습적인 창발적인 운동원형(motor primitive) 생성 가능성을 제시하였다.

이러한 ECS 시스템은 기계학습과 같은 방대한 파라미터 학습이나 최적화 과정 없이, 이미 주어진 신경-신체-환경 간의 고유한 상호작용(neuro-body-environment interaction)으로부터 형성되는 동역학적 위상공간에서 주기적 운동 패턴들이 끌개(attractor)의 형태로 자발적으로 발현될 수 있도록, 생물학적으로 타당한 중추패턴발생기(Central Pattern Generator, CPG) 기반의 체화 신경-기

계 모델(Embodied Neuromechanical Model)을 구축하고, 그로 인해 자가조직화된 운동 패턴들 사이를 탐색하기 위해 전역 제어 파라미터를 통하여 전체 시스템이 기존의 안정적 상태부터 준주기 및 카오스 상태로 전이하도록 하여 이러한 패턴 끌개들 사이를 빠르게 넘나들 수 있음을 보였다. 이를 바탕으로 실시간으로 추적된 각 패턴들의 성능에 따라 제어 파라미터를 다시 안정화함으로써, 보다 높은 성능을 지향하는 방향으로 전체 동역학 시스템 궤도의 움직임을 시행착오(trial-and-error) 방식으로 탐색하는 프레임워크를 제안하고, 이를 간단한 바이오메카니컬 모델 및 관절형 사지로봇과 소프트바디 로봇 등에 적용하여 그 가능성과 범용성을 보여주었다.

그러나 대부분의 유용한 패턴들은 완벽히 안정적인 끌개보다는 특정 manifold를 따라 궁극적으로 다른 패턴으로 전이되는 전이성 패턴들이 대부분이며, 순수한 카오스 탐색 방법에서는 특정 패턴의 주변에 동역학적 궤도가 도달 후 시스템을 안정화시킨 후에도 해당 패턴에 계속 머물지 않고 다른 곳으로 전이하는 경우가 빈번하여 원하는 운동 패턴을 완벽히 고정 또는 기억시키기 힘들다는 한계가 존재한다. 이를 개선하기 위해 [6]에서는 [11]에서 제안된 neuro-physical adaptive synchronization 기법을 도입하여 각 CPG간의 연결 가중치를 실시간으로 빠르게 학습시킴으로써 원하는 전이성 패턴을 최대한 유지시키는 방식을 사용하였다. 하지만 이 방식은 가중치 학습을 제어 파라미터 변화에 따른 연속적인 변수의 형태로 통합시켜 단지 패턴 안정성 강화를 위한 보조수단으로만 쓰였으며, 학습 도중에도 전이성 패턴의 흩어짐으로 인해 시스템이 다시 카오스 상태로 되돌아가 결과적으로 학습된 가중치가 리셋되는 경우가 잦았다. 또한 [11]에 기반한 학습 알고리즘 역시 원점에서 벗어난 주기신호들의 회전중심을 보상하기 위해 모든 CPG 변수들과 외부신호들에 대한 회전 중심들을 구해야 하는 계산복잡성이 있다.

이에 실제 적용을 위한 공학적 관점에서 본 연구는 첫째로, 패턴탐색과 가중치학습 단계를 명시적으로 분리하여, 유용한 운동패턴이 발견되었을 때 외부 센서 신호를 차단하는 방법으로 위상공간상에서 안정적인 패턴은 물론 전이성 패턴들까지도 명시적으로 고정시키고, 이들 패턴들에 대해 가중치 학습을 적용하여 충분히 수렴시킨 후 학습된 가중치들을 메모리에 저장하여 추후에 재적용 시 해당 운동패턴이 다시 복원될 수 있도록 하였다(Fig 1).




Fig. 1. An overview of chaotic pattern search and acquisition for embodied neuromechanical system.

둘째로, 학습 전과 후의 동역학 공간 상의 패턴분포의 차이를 보이기 위해 각 CPG 간의 위상차 맵 및 flow field로 가시화하여, 가중치 학습 전에 공존하던 여러개의 전이성 패턴들이 적용 후 전체공간에서 유일하게 안정적인 끌개로 변화됨을 보였다. 셋째로, 기존의 가중치 학습 방법을 더욱 효율적으로 개선하기 위해, 기존의 모든 주기신호를 위한 미분방정식 기반 회전중심 계산을 없애고, 각 CPG neuron들에만 추가적인 bias term들을 도입하여 가중치 행렬에 통합시킴으로써, 원점을 벗어난 회전의 보상을 위한 불필요한 계산 대신에 오늘날의 행렬기반 신경망 학습과 호환되는 개선된 알고리즘을 제시하였다.

나아가 이렇게 학습되어 저장된 가중치들은 추후 더욱 세밀한 움직임 생성을 위해 CPG기반 강화학습 등 일반적인 기계학습을 위한 초기 데이터로 사용되거나 고차원적 로봇행동 합성을 위한 운동원형(motor primitive)으로 활용될 수 있는 기반을 제공할 수 있다.

논문의 전체 구성은 2장 배경이론, 3장 제안내용 및 결과분석, 그리고 4장 결론으로 구성되어 있다.

## II. Preliminaries

### 1. ECS Framework

#### 1.1 CPG Model and Chaoticity Control

본 연구의 ECS 프레임워크는 로봇 액추에이터의 제어를 위해 FitzHugh-Nagumo(FHN) 모델을 기반으로 구현된 중추 패턴 발생기(CPG)를 사용하며, 주어진 진동수 하에서 자가조직적으로 각 구동부의 위상차 구조를 형성하는 데

초점을 둔다. CPG 기반 사지기동 로봇에서의 다양한 보행 패턴과 협응 구조는 주로 사지 간 위상차 조절을 통해 결정되며[4][12], 이는 적은 수의 제어 변수로도 높은 다양성과 안정성을 유도할 수 있는 강력한 제어 방식으로 간주된다. 개별 FHN 기반 CPG- $i$ 의 동역학은 식 (1)과 같다.

$$\begin{aligned} \frac{du_i}{dt} &= c(u_i - \frac{u_i^3}{3} - v_i + z) + \delta(s_i - u_i) + \lambda C_i(u) \\ \frac{dv_i}{dt} &= (u_i - bv_i + a)/c + \gamma s_i + \lambda C_i(v) \end{aligned} \quad (1)$$

여기서  $u_i$ 는 해당 CPG의 출력,  $v_i$ 는 복원 변수이며,  $p$ 는 주기적(periodic) 패턴의 stable 상태부터 chaos 상태까지 시스템 동작을 변화시키기 위한 전역 분기 파라미터(global bifurcation parameter)이다. 입력  $s_i$ 는 신체 감각(proprioception) 입력 신호로, 이 신호는 체화 시스템의 형태 변화나 물리적 환경 변화로 인한 센서값의 변화에도 견고성을 유지하도록 항상성 기반 감각 적응 메커니즘(Homeostatic Sensor Adaptation Mechanism, HSAM)을 통해 조절된 후 CPG로 입력된다. coupling 함수  $C_i(x)(x \in \{u, v\})$ 는 외부 CPG들의 출력들로부터 CPG- $i$ 의 각 뉴런  $u, v$ 에 가해지는 입력이다.

동역학적 궤도의 탐색을 가능하게 하는 본 시스템의 특징은 파라미터 값을 동적으로 조정하여 카오스의 정도를 제어할 수 있다는 점이다. 전역 분기 파라미터  $z$ 는 혼돈계수  $\mu$ 를 통해 다음과 같이 실시간으로 결정된다.

$$z = z_s(1 - h) - z_c h, \quad h = \mu H(\mu - \epsilon) \quad (2)$$

$$\tau_\mu \frac{d\mu}{dt} = -\mu + G(E, E_H, E_L)$$

$$\tau_{H,L} \frac{dE_{H,L}}{dt} = -E_{H,L} + E$$

여기서  $z_s, z_c$ 는 시스템을 stable 및 chaos 상태로 보내기 위한 경계값이며, 적용되는 물리시스템에 따라 다르게 설정된다.  $H(x)$ 는 heaviside 함수이며, chaoticity  $\mu$ 가 임계값( $\epsilon$ ) 이하일 때 시스템을 안정화 상태로 고정시킴으로써 작은 성능 측정값의 떨림에 상관없이 패턴의 안정화를 도모한다. 혼돈계수  $\mu \in [0, 1]$ 는 상한( $E_H$ )과 하한( $E_L$ ) 기대치 범위 내 성능비율  $G(E, E_H, E_L)$ 에 따라 안정적(0)에서 카오스(1)까지 시스템 동역학을 변화시킨다.

$$G(E, E_H, E_L) = \sigma\left(\frac{16}{E_H - E_L} \left(E - \frac{E_H + E_L}{2}\right)\right) \quad (3)$$

$$\tau_H(E) = \tau_d(10 - 9H(E - E_H))$$

$$\tau_L(E) = \tau_d(1 + 9H(E - E_L))$$

$\sigma(x)$ 는 sigmoid함수이며  $E_H$ 와  $E_L$ 는 모두  $E$ 에 대한 filtered mean( $\tau_{H,L}(dE_{H,L}/dt) = E - E_{H,L}$ )이다. 시간

상수  $\tau_H, \tau_L$ 들은 각 상황에 따라 다른 값을 사용하여 변화 속도가 조절되는데, 상한치 증가와 하한치 감소는 각 반대 경우보다 10배 빠르게 변화하도록 하여  $E$ 가 두 기대값 사이를 움직이면서도 이전보다 높은 기대 성능을 향한 탐색 압력을 주는 동시에 발견된 패턴에서 벗어났을 때는 더 빠르게 혼돈상태로 전환되도록 유도하였다[7][8].

### 1.2 Homeostatic Sensor Adaptation Mechanism

체화 기반 카오스 탐색의 확장성과 보편성을 뒷받침하는 중요한 요소는 항상성 감각 적응 메커니즘(HSAM)이다. ECE 프레임워크에서의 각 CPG는 자신을 제외한 나머지 신체를 마치 또 다른 CPG로 간주하며, 이 과정에서 신체 신호를 일관되게 처리할 수 있도록 센서 입력을 동적으로 조절한다[8]. 이를 통해 시스템은 형태적 차이나 환경 변화에도 불구하고 동일한 scale-invariant 탐색이 가능하다. HSAM의 동작은 식 (4)와 같다.

$$\begin{aligned} h_i &= (r_i - \tilde{r}_i) \ln(1 + e^{\alpha_i}) + (\tilde{r}_i + \beta_i), \quad s_i = gh_i \\ \tau_h \frac{d\alpha_i}{dt} &= q_r - q_v, \quad \tau_h \frac{d\beta_i}{dt} = -\tilde{h}_i \\ \tau_h \frac{dq_i}{dt} &= -q_i + \ln[1 + (h_i - \tilde{h}_i)^2] \end{aligned} \quad (4)$$

여기서  $r_i$ 는 처리전 센서 원신호(raw sensory signal)이고,  $h_i$ 는 HSAM 변환 후 신호이다.  $\tilde{x}$ 는 해당 변수의 filtered mean(by  $\tau_h$ )이며  $\alpha_i$ 와  $\beta_i$ 는 진폭 스케일과 편향을 조절하는 적응 변수이다. 진폭 스케일은 원신호의 신호 세기  $q_i$ 가 CPG세기( $q_r$ )에 근접하도록 조정된다. 이러한 항상성 메커니즘은 감각 입력의 크기를 최적 범위 내로 유지함으로써 입력 신호가 과도하게 포화되거나 소멸하는 현상을 방지하여 카오스 탐색의 일관성을 유지한다. 본 논문에서의 학습 전 패턴 고정을 위해 식 (1)에서의 CPG 입력은 gating 변수( $g$ )를 통해 제어된다.

## III. The Proposed Scheme

### 1. Adaptive Synchronization

본 절에서는 다수의 신경 발진기 간 상호작용을 실시간으로 동기화하기 위한 적응적 동기화 알고리즘을 설명한다. 제안된 방법은 탐색 중 발견된 전이성 패턴을 안정적 끝개로 기억하도록 하며, 기존의 CPG-물리시스템 동기화 기법[11]을 다수의 CPG 간 동기화로 확장한 것이다[6]. 특히 각 뉴런의 bias 항을 명시적으로 학습하는 편향 보상을 도입하여 covariance learning 방식의 복잡성을 줄이고,

신경망 계산 구조에 적합하게 개선하였다. 또한 단방향 연결에 국한되었던 기존 방식과 달리, 본 연구에서는 다수의 CPG들이 상호 연결된 양방향 네트워크를 구성하고 연결 가중치와 바이어스(bias)를 통합적으로 학습함으로써 네트워크 전체의 동기화를 가능하게 하였다.

### 1.1 Phase-Locking based Learning

Adaptive synchronization은 CPG 뉴런들과 그로 들어오는 외부 입력 신호들이 특정 위상관계를 형성하고 있을 때, 이 관계를 유지하기 위한 연결가중치를 학습하는 메커니즘이다. 이를 위해 동일 주파수 정현파 형태로 가정된 외부 입력  $\mathbf{y}(t) \in \mathbb{R}^S$ 와 뉴런 상태  $\mathbf{x}(t) \in \mathbb{R}^C$  벡터 간의 관계를 phase-lock 행렬  $\mathbf{P} \in \mathbb{R}^{C \times S}$ 를 통해  $\hat{\mathbf{x}}(t) = \mathbf{P} \cdot \mathbf{y}(t)$ 와 같이 선형관계로 근사한다. 실제 출력  $\mathbf{x}(t)$ 와 예측값  $\hat{\mathbf{x}}(t)$  간의 차이를 최소화하는 제곱 오차 기반 목적함수는 식 (5)와 같다(시간표기 ( $t$ ) 생략).

$$E = \frac{1}{2} \|\mathbf{x} - \mathbf{P} \cdot \mathbf{y}\|^2 = \frac{1}{2} \sum_i \left( x_i - \sum_k p_{ik} y_k \right)^2 \quad (5)$$

기존 Doya의 연구[11]에서는 목적함수 최소화 시 원점 회전이 아닌 경우의 편향 효과의 상쇄를 위해 각 행렬요소  $p_{ik}$ 에 대해 다음과 같은 학습 규칙을 사용하였다.

$$\frac{dp_{ik}}{dt} = \eta \left( (x_i - \tilde{x}_i) - \sum_j p_{ij} (y_j - \tilde{y}_j) \right) (y_k - \tilde{y}_k) \quad (6)$$

$\tilde{x}, \tilde{y}$ 는 filtered mean이며  $\eta$ 는 학습률이다. 이는 실제 값과 평균의 차이들로 이루어진 예측오차와 외부입력에 대한 covariance-like learning으로 볼 수 있다. 뉴런  $x_i$ 의 동작이  $dx_i/dt = f_i(\mathbf{x})$ 로 표현되는 동역학 시스템이라고 할 때,  $x_i$ 와 전체 입력  $\sum p_{ik} y_k$ 과의 차이를 최소화하도록 하기 위한 feedback term은 식 (7)과 같다.

$$\frac{dx_i}{dt} = f_i(\mathbf{x}) + \lambda \cdot \left( \sum_k p_{ik} y_k - x_i \right) \quad (7)$$

여기서  $\lambda$ 는 feedback gain으로서 본래의 뉴런 상태가 지나치게 왜곡되지 않도록 작은 값을 가진다. 수식에서 볼 수 있듯이, 결과적으로 phase-lock term인  $p_{ik}$ 가 그대로 다시 외부입력에 대한 가중치로서 작동하며 학습으로 업데이트된다는 것을 알 수 있다.

### 1.2 Learning with Bias for Coupling $C_i(x)$

본 연구에서는 이러한 Doya의 방법을 응용하여 센서 입력 신호  $y_k$ 를 다른 CPG들의 출력  $u_j$ 로 대체하고, 회전 중심에 대한 compensation을 위해 CPG 및 모든 센서들의 평균값을 구하는 대신, 가중치와 동일하게 학습되는

bias term( $b_i$ )을 각 CPG 뉴런들에만 적용한다. 식 (1)에서의 coupling feedback term  $C_i(x)(x \in \{u, v\})$ 는 다음과 같이 실제 뉴런 상태( $x_i$ )와 외부에서 받는 입력들의 가중합으로 계산된 예측값( $\hat{x}_i$ )과의 차이( $e_i^x = x_i - \hat{x}_i$ )에 대한 음의 피드백으로 주어진다.

$$C_i(x) = -e_i^x = (\hat{x}_i - x_i), \quad \hat{x}_i = \sum_{j \neq i} w_{ij}^x u_j + b_i^x \quad (8)$$

CPG- $i$ 의 두 뉴런  $u_i$ 와  $v_i$  모두 외부 CPG의 출력 뉴런  $u_j$ 들의 합산입력을 받으며, 각 입력 가중치  $w_{ij}^x$ 는 CPG- $j$ 의 출력이 CPG- $i$ 의 뉴런  $x_i$ 로 들어올 때의 연결,  $b_i^x$ 는 뉴런  $x_i$ 의 bias이다. 마찬가지로 예측오차  $e_i^x$ 를 통한 각 가중치와 bias 학습은 식 (9)와 같이 업데이트 된다.

$$\frac{dw_{ij}^x}{dt} = \eta \cdot e_i^x \cdot u_j, \quad \frac{db_i^x}{dt} = \eta \cdot e_i^x \quad (9)$$

$\eta$ 는 learning rate이다. 이렇게 bias를 도입한 알고리즘은 기존 방식과 동일한 역할을 하면서도 그 형태는 보편적인 오류 역전파 기반 신경망 학습과 유사함을 알 수 있다. 식 (1)과 (4)에서의 피드백 계수  $\lambda$ 와 센서 gating 변수  $g$ 는 혼돈계수  $\mu$ 에 따라 식 (10)과 같이 제어된다.

$$\tau_s \frac{dg}{dt} = H(\mu - \epsilon) - g, \quad \lambda = 0.018(1 - g) \quad (10)$$

이를 통해 패턴이 발견되어 시스템이 안정화될 때 센서 입력은 부드럽게 소거되는 동시에 CPG 연결이 활성화된다.

## 2. Mechanical System

본 연구에서의 물리적 시스템은 이전 연구들과 마찬가지로 질점들이 무질량 스프링-댐퍼로 연결된 구조로 모델링 되었다. 스프링 상수를 매우 높게( $k=1000\text{N/m}$ ) 고정된 연결은 구조를 유지하기 위한 뼈대(strut)로 설정되고, 신체 구동을 위한 ‘근육’으로 지정된 연결은 Hill-type 근육의 단순화된 모델로서[13] 스프링 강성이 CPG 출력에 따라 제어되도록 설계되었다( $k = 1 + \tanh(u)$ ). 식 (4)에서의 raw sensor값  $r$ 은 단순화된 근육 수용기(muscle proprioceptor)의 운동감각 정보(group Ia, Ib, II afferents:  $V_{Ia}, F_{Ib}, L_{II}$ )의 선형결합으로 정의된다[15].

$$r = 0.5 V_{Ia} - F_{Ib} + L_{II} \quad (11)$$

각 감각정보는 근육의 수축(이완)속도, 장력, 길이를 고유길이(Fig. 2의 각 근육 길이의 1/2)로 정규화한 값이다 [7][8]. 이러한 모델을 바탕으로, Fig. 2에서와 같이 단순 선형 구조(Linear MSD) 및 2차원 수중 swimmer와 3차원 tensegrity-style walker의 세 가지 서로 다른 환경에서의 물리 시스템에 대한 시뮬레이션이 진행되었다.




Fig. 2. Mechanical models for different embodiment. The swimmer is actuated by three pairs of antagonistic muscles, each pair driven by control signals of opposite polarity. The strut is depicted as a thick gray line.

Table 1. System Environment

Item	Value
CPG	$a = 0.7, b = 0.675, c = 1.75,$ $\delta = 0.013, \gamma = 0.022$
Search	$\epsilon = 10^{-4}, \tau_\mu = 1.6, \tau_d = 8, z_s = 0.73$ $z_c = 0.37(\text{swimmer}), 0.39(\text{walker})$
HSAM	$\tau_h = 8, q_r = 0.78$
Learning	$\eta = 0.125, \tau_s = 1.6$

모든 시스템은 지나친 복잡성을 지양하고 명료한 위상차 가시화를 위해 3개의 actuation 근육을 통해 구동되도록 하였으며, 따라서 동일한 3-자유도의 ECS 프레임워크를 통해 탐색-정착-학습의 과정을 거친다. 실험에 사용된 주요 고정 매개변수들은 Table 1과 같으며, 수중저항력 및 지면마찰 모델을 포함한 기타 세부 사항은 이전 연구 [7][8][14]들과 동일하게 구성되었다.

## 3. Experimental Results and Analysis

이와 같이 구성된 ECS 신경-기계 시스템에서 생성되는 서로 다른 운동패턴 및 전이 과정은 각 근육의 주기 운동간 위상차 관계를 통해 특정되고 추적될 수 있다. 이를 위해 CPG 1과 2, 그리고 1과 3 사이의 위상차들을 2차원 공간상의 위상관계 벡터(pDiff 1-2 및 1-3)로 정의하여 이를 기반으로 위상차 공간(패턴공간) 내 패턴들의 동역학적 변화와 안정성 등을 분석 및 가시화하였다.

Fig. 3-5는 제시된 3가지 응용 시스템에 대한 시뮬레이션 결과를 나타낸다. 각 Figure의 상단 두 이미지는 학습 전후의 위상차 공간 안정성 지형(stability landscape)으

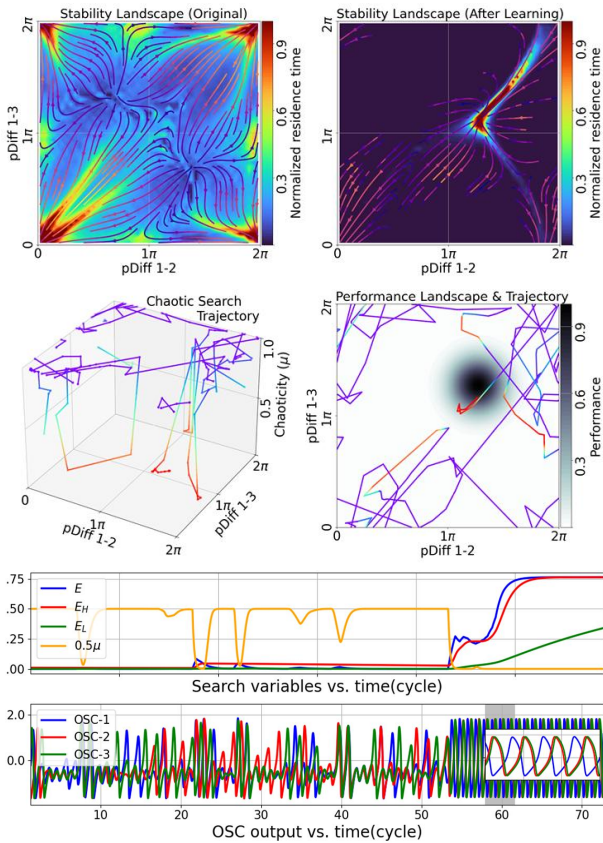


Fig. 3. Search-acquisition process of linear MSD system

로, 각 지점의 색과 흐름선은 50×50=2500회의 시뮬레이션 궤적으로부터 계산된 체류시간과 평균 전이속도를 나타낸다. 둘째 행 왼쪽은 위상차와 혼돈계수의 탐색 궤적 (search trajectory), 오른쪽은 이를 성능 지형 (performance landscape)과 함께 표시한 결과이다. 성능지형 역시 해당 지점의 위상차를 고정시켜 측정되었으며, 3개 물리시스템 중 선형 MSD 모델은 벽에 고정된 구조로서 시스템 고유의 기동능력이 정의되지 않는 관계로, 수동으로 부여한 gaussian 분포를 통해 안정성이 낮고 전이 흐름이 빠른 지점(4π, 4π) 주변을 단일 목표패턴으로 설정하였다. 마지막 두 개의 시계열 그래프들은 탐색 과정에서의 주요 변수들 및 CPG 출력 변화를 보여준다.

세 시스템 모두에서 카오스 탐색 궤적은 위상 공간의 여러 영역을 오가며 잠재적 후보 패턴들로 안정화와 전이를 반복하는 특징을 보였다. 이는 시행착오(trial-and-error) 방식의 전역 탐색 특성을 보여주며, 학습 전 안정성 지형에서는 각 시스템의 구조와 환경에 따라 다수의 안정구역이 공존함을 확인할 수 있다[7]. 또한 성능 지형 궤적에서는 상대적으로 성능이 높은 구역으로 접근하려는 경향이 뚜렷하게 나타났다.

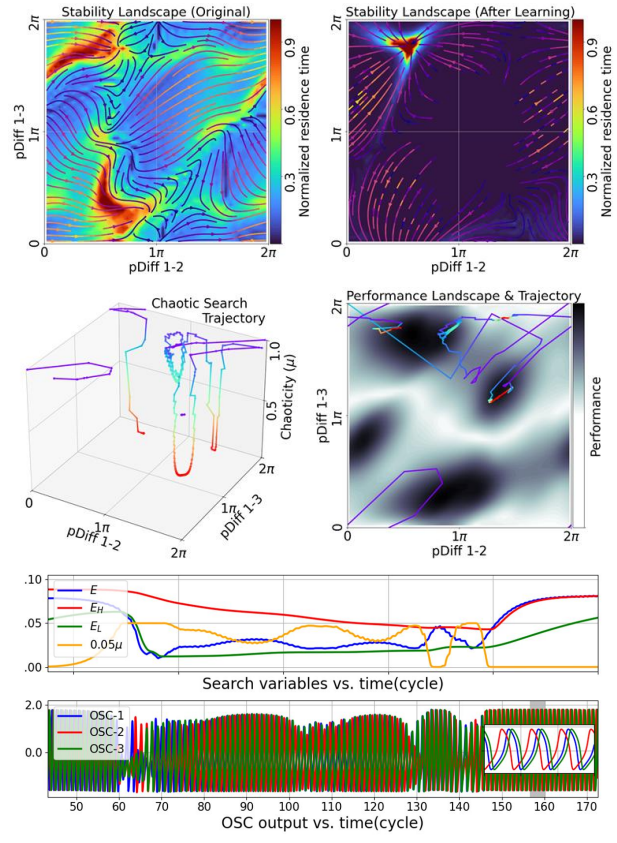


Fig. 4. Search-acquisition process of Swimmer-2D

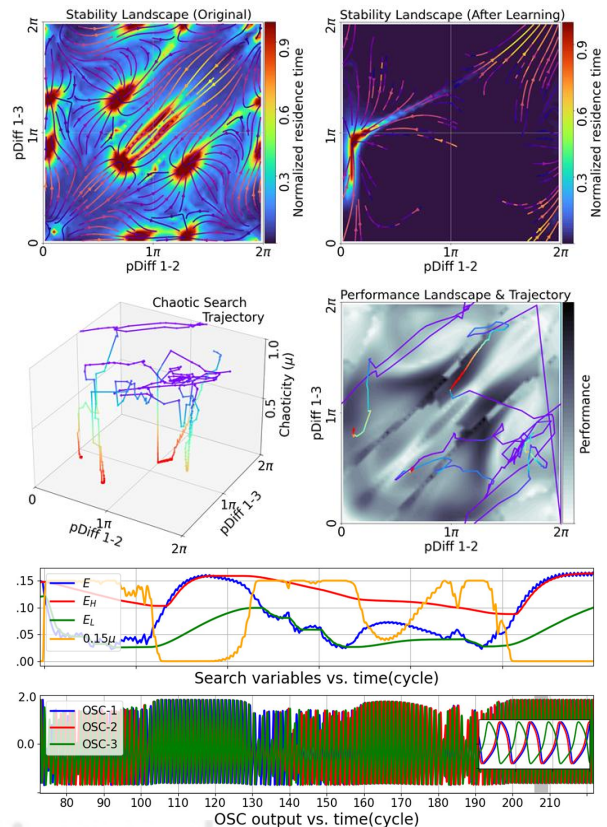


Fig. 5. Search-acquisition process of Walker-3D

탐색궤적은 처음 만난 패턴에 고정되지 않고 여러개를 거쳐가는 모습을 보이고 있는데, 이는 식 (10)의 센서 게이팅이 즉각적 차단이 아닌, 급작스러운 요동을 방지하기 위해 일정한 시간상수를 두고 약 4~5 진동 주기에 걸쳐 점진적으로 감소하는 방식이기 때문이다. 실시간 성능은 주기 운동에 따른 미세한 진동을 포함하기 때문에 느리게 갱신되는 기대 성능을 약간 상회하더라도 두 값의 크기가 순간적으로 역전되어 게이팅이 완전히 닫히기 전에 풀리는 현상이 보이게 된다. 그 결과, 탐색 과정에서 접근한 패턴이 충분한 안정성과 성능을 동시에 확보하지 못하면 고정이 풀리며 다른 후보 패턴으로 전이되는 현상이 발생한다. 반대로, 성능이 높은 동시에 안정적인 구역에 위치한 패턴의 경우에는 실시간 성능이 평균 기대치를 지속적으로 앞서게 되어 게이팅이 더 오래 차단되고, 최종적으로 해당 패턴이 안정적으로 학습되어 유지된다. 탐색된 패턴의 학습이 완료된 이후의 안정성 지형에서는, 초기에 다수의 끌개가 공존하던 구도가 사라지고 습득된 패턴만이 유일한 안정 구역으로 남는 것을 확인할 수 있으며, 이는 탐색-정착-기억의 일련의 과정이 성공적으로 수행되었음을 의미한다.

로봇 기동 모델들인 Swimmer-2D와 Walker-3D 시스템의 성능은 로봇 무게중심의 이동속도에 대한 누적값으로 측정되었다[6]. 두 경우에서 모두 안정 영역과 불안정 영역 모두에서 고성능 구역들이 존재하는 것을 볼 수 있으며, 성능지형의 대부분 구역이 낮고 평탄한 선형 MSD 모델의 경우와 달리, 상대적으로 짧은 혼돈상태 이후 바로 고성능 구역 중 하나로 접근하는 경향을 보였다. Swimmer-2D(Fig. 4)의 안정성 지형에서는 대칭적인 2개의 안정 구역이 가장 두드러졌으며 이는 3개의 분절이 장어와 유사한 순차적 위상차를 보이는 패턴들이다. 성능 역시 해당 구역 주변으로 높게 나타났으며 추가로 불안정 구역에도 버금가는 성능이 존재하였다. 전체적인 위상차 및 성능 분포는 부드러운 지형을 보이며 이는 연속적인 유체 저항 환경의 영향이라 볼 수 있다. 탐색궤적은 안정한 고성능 구역 주변에서 가장 오래 유지되었고, 이를 학습 후에는 해당 패턴이 유일한 끌개로 저장되었다.

Walker-3D 모델(Fig. 5)은 질점-지면 접촉에 따른 불연속 마찰력의 영향으로 가장 복잡한 안정·성능 지형을 보였다. 작은 위상차 변화에도 접촉 상태가 달라져 안정성과 성능이 크게 변동하며, 이로 인해 안정 구역은 파편화되고 성능 분포도 불연속적으로 나타났다. 3-strut tensegrity 유사 구조는 각 옆면에 대각방향으로 비대칭적 순환 연결을 가진 관계로, 한 보행주기 내 대부분은 하부 4개의 질점 중 3개만으로 지면을 딛는 움직임을 보였다. 이로부터

두 가지 주요 보행패턴이 관찰되었는데, 첫째는 하부 두 근육이 in-phase로 움직이며 앞쪽 두 질점과 뒤쪽 한 질점의 마찰력 차이로 추진하는 방식이고(성능지형의 중앙 영역), 둘째는 근육이 anti-phase로 움직이며 앞쪽 두 질점이 교대로 끌어주는 방식이다(축 경계 부근 구역). 두 패턴 중, 성능은 다소 낮지만 파편화가 적은 후자 anti-phase 패턴에서 탐색이 더 오래 유지되었다.

이와 같이 시스템의 복잡성 및 물리·환경적 차이에도 불구하고 모든 모델들은 공통적으로 동일한 메커니즘을 통하여 카오스 탐색 단계에서 위상 공간을 전역적으로 탐사하며 성능과 안정성이 타협된 패턴으로의 정착 및 고정 후, 적응적 동기화 학습을 통해 발견된 패턴을 안정적으로 기억할 수 있었다.

## IV. Conclusion

본 연구는 체화된 신경-기계 시스템에서 카오스 탐색을 통해 자가조직적으로 발현되는 운동 패턴을 안정적으로 학습·재현하기 위한 ECS-Adaptive Synchronization 프레임워크를 제안하였다. 제안된 방법은 탐색과 학습 단계를 분리하고 bias 기반 학습을 도입함으로써, 기존 방식의 패턴 습득 불안정성과 계산 복잡도를 개선하고 패턴을 안정적인 동역학적 끌개의 형태로 저장 및 재현이 가능함을 보였다. 각기 다른 형태 및 물리적 환경을 가진 세 가지 신경-기계 시스템 모두에서 탐색-정착-기억의 일관된 메커니즘이 공통적으로 작동됨이 확인되었고, 이는 제안된 접근법이 형태 구조와 환경 차이에 무관하게 적용 가능함을 보여준다. 학습 및 저장된 가중치를 재적용 후에는 해당 패턴만이 단일 안정 끌개로 존재하게 되어 CPG 기반 로봇제어의 장점인 주기적 운동 패턴의 전역적 안정성을 확보할 수 있다. 종합적으로 본 연구의 개선된 프레임워크는 잠재적으로 유용한 전이성 패턴의 불안정성을 극복하고, 습득된 패턴들을 CPG 기반 로봇 강화학습의 초기 정책이나 고차원 행동 합성을 위한 운동원형으로 활용할 수 있는 기반을 제공한다.

본 연구는 다양한 체화 모델을 위한 범용성과 적응성을 확인하였으나, 탐색 과정에서 사용되는 고정 매개변수들의 최적 설정에 대한 추가적인 분석이 필요하다. 일례로, 다양한 시간상수( $\tau$ )로 정의되는 평가 및 목표설정, 감각 적응, 분기(bifurcation)등에 관련된 느린 동역학들의 시간 척도는 탐색 궤적의 안정성, 패턴의 기억과 망각의 균형, 그리고 수렴 특성에 영향을 미칠 수 있다. 다른 주요 매개변수로는 CPG의 최대 chaos 파라미터( $z_c$ )가 있으며, 이

는 항상 카오스적 동역학이 생성될 수 있도록 로봇의 구조와 물리적 환경에 따라 사전 실험을 통해 설정된다. 비록 선행 연구[8]에서 최대 Lyapunov 지수 및 bifurcation 분석을 통하여 혼돈생성의 메커니즘이 어느정도 분석되었으나, 본 프레임워크의 범용성을 위하여 해당 파라미터에 대한 자동화 연구가 필요하다.

향후 연구에서는 이러한 매개변수와 체화 특성에 따른 동역학적 민감도를 체계적으로 규명하여 보다 최적화된 탐색-학습 프레임워크를 정립할 필요가 있다. 또한 더욱 복잡한 로봇 플랫폼과 실제 환경에서도 동작할 수 있도록, 노이즈를 비롯한 다양한 불확실성을 고려한 시스템 개발을 통해 체화된 혼돈 탐색 기반 제어의 실효성과 범용성을 확장해 나갈 계획이다.

## ACKNOWLEDGEMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MEST) (No. RS-2020-NR053396).

## REFERENCES

- [1] R. D. Beer, "Dynamical approaches to cognitive science," *Trends in Cognitive Sciences*, Vol. 4, No. 3, pp. 91-99, 2000. DOI: 10.1016/s1364-6613(99)01440-0
- [2] R. Pfeifer and J. Bongard, *How the Body Shapes the Way We Think: A New View of Intelligence*, MIT Press, 2006. <https://doi.org/10.7551/mitpress/3585.001.0001>
- [3] M. Wilson, "Six views of embodied cognition," *Psychonomic Bulletin & Review*, Vol. 9, No. 4, pp. 625-636, 2002. DOI: 10.3758/bf03196322
- [4] A. J. Ijspeert, "Central pattern generators for locomotion control in animals and robots: A review," *Neural Networks*, Vol. 21, No. 4, pp. 642-653, 2008. <https://doi.org/10.1016/j.neunet.2008.03.014>
- [5] F. Iida and F. Giardina, "On the Timescales of Embodied Intelligence for Autonomous Adaptive Systems," *Annual Review of Control, Robotics, and Autonomous Systems*, Vol. 6, pp. 95-122, 2023. <https://doi.org/10.1146/annurev-control-063022-094301>
- [6] Y. S. Shim and P. Husbands, "Chaotic Exploration and Learning of Locomotion Behaviours," *Neural Computation*, Vol. 24, No. 8, pp. 2185-2222, 2012. DOI: 10.1162/NECO\_a\_00313
- [7] Y. Shim and P. Husbands, "Incremental Embodied Chaotic Exploration of Self-Organized Motor Behaviors with Proprioceptor Adaptation," *Frontiers in Robotics and AI*, Vol. 2, 2015. DOI: 10.3389/frobt.2015.00007
- [8] Y. Shim and P. Husbands, "Embodied neuromechanical chaos through homeostatic regulation," *Chaos: An Interdisciplinary Journal of Nonlinear Science*, Vol. 29, No. 3, p. 033123, 2019. <https://doi.org/10.1063/1.5078429>
- [9] Y. Kuniyoshi and S. Suzuki, "Dynamic emergence and adaptation of behavior through embodiment as coupled chaotic field," in *Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS)*, Vol. 2, pp. 2042-2049, 2004. DOI: 10.1109/IROS.2004.1389698
- [10] Y. Kuniyoshi and S. Sangawa, "Early motor development from partially ordered neural-body dynamics: experiments with a cortico-spinal-musculo-skeletal model," *Biological Cybernetics*, Vol. 95, No. 6, pp. 589-605, 2006. <https://doi.org/10.1007/s00422-006-0127-z>
- [11] K. Doya and S. Yoshizawa, "Adaptive Synchronization of Neural and Physical Oscillators," in *Advances in Neural Information Processing Systems*, Vol. 4, Morgan-Kaufmann, 1991. <https://dl.acm.org/doi/10.5555/2986916.2986930>
- [12] C. Pehlevan, F. Ali, and B. P. Ölveczky, "Flexibility in motor timing constrains the topology and dynamics of pattern generator circuits," *Nature Communications*, Vol. 9, p. 977, 2018. DOI:10.1038/s41467-018-03261-5.
- [13] Ö. Ekeberg, "A combined neuronal and mechanical model of fish swimming," *Biological Cybernetics*, Vol. 69, No. 5, pp. 363-374, 1993. <https://doi.org/10.1007/BF00199436>
- [14] M. Sfakiotakis and D. P. Tsakiris, "Simuun: A simulation Environment for Undulatory Locomotion," *International Journal of Modelling and Simulation*, Vol. 26, No. 4, pp. 350-358, 2006. DOI: 10.1080/02286203.2006.11442388
- [15] A. Prochazka, "Chapter 11 Quantifying Proprioception," in *Peripheral and Spinal Mechanisms in the Neural Control of Movement*, M. D. Binder, Ed., *Progress in Brain Research*, Vol. 123, pp. 133-142, Elsevier, 1999. doi:10.1016/S0079-6123(08)62850-2

## Authors



Yoonsik Shim received his B.S. degree in Mechanical Engineering and M.S. degree in Computer Science from Korea University, Seoul, Korea. He earned his Ph.D. degree in Informatics from the University of Sussex,

United Kingdom, in 2013. He is currently an Assistant Professor in the Department of Game Engineering at Pai Chai University, Daejeon, Korea. His research interests include bio-inspired adaptive robotics, computational neuroscience, chaotic neurodynamics, self-organization, and evolutionary robotics.