전자통신동향분석, 41권 6호 2026, 29-40

하나의 자아, 다양한 신체: Embodied Agent 지능 이식 동향

One Self, Many Bodies: Trends in Intelligence Transfer Across Embodied Agents

김용현 (Y.H. Kim, yhkeen@etri.re.kr) AI로봇UX연구실 책임연구원
장은혜 (E.H. Jang, cleta4u@etri.re.kr) AI로봇UX연구실 책임연구원
한지우 (J.W. Han, chau@etri.re.kr) AI로봇UX연구실 선임연구원
김우진 (W.J. Kim, wjinkim@etri.re.kr) AI로봇UX연구실 책임연구원/실장
윤대섭 (D.S. Yoon, eyetracker@etri.re.kr) AI로봇·모빌리티연구본부 책임연구원/본부장

ABSTRACT

As service robots, wearable robots, and autonomous vehicles enter everyday environments, maintaining user-specific intelligence across device and service boundaries has become increasingly important. Existing personalization methods use profiles, behavioral histories, personas, and long-term memory but remain tied to a specific service or device. Meanwhile, cross-body robot learning supports task transfer through multiplatform datasets and shared policies; however, preservation of individual behavior and preferences remains underexplored. This paper presents a review of approaches for abstracting personal, cognitive, affective, and behavioral characteristics into a body-invariant representation and decoding it for a target machine. These components are referred to as self kernel and re-embodiment. Relevant work spans personalization, cross-embodiment learning, motion retargeting, affordance-conditioned control, safety monitoring, and identity governance. While current generalist policies provide a foundation for cross-body skill transfer, integrated frameworks for personal representation, body-specific decoding, and preservation metrics remain limited. Therefore, future research should jointly examine target variables, constrained decoders, simulation-based evaluation, runtime safety, authorization, privacy, and governance.

KEYWORDS Ambient AI, Body-invariant representation, Cross-embodiment learning, Personal intelligence transfer, Re-embodiment

* DOI: https://doi.org/10.22648/ETRI.2026.J.410603
* This work is supported by Korea Evaluation Institute of Industrial Technology (KEIT) grant funded by the Ministry of Trade, Industry and Energy (MOTIE, Korea) (RS-2024-00403108).

본 저작물은 공공누리 제4유형
출처표시+상업적이용금지+변경금지 조건에 따라 이용할 수 있습니다.
©2026 한국전자통신연구원

I. 서론

1. 지능 파편화의 한계

물리적 행동을 수반하는 이기종 지능형 기기가 일상 환경에 도입되면서, 사용자의 개인화 정보를 기기와 서비스의 경계를 넘어 유지하는 문제가 핵심 과제로 부상하고 있다. 개별 기기는 독립적인 제어 및 학습 알고리즘에 기반하여 동작하므로, 기기와 상호작용 규칙이 다양해질수록 시스템이 관리해야 할 사용자 맥락의 복잡성도 증가한다. 다중 기기 환경의 상호작용 설계에 관한 HCI 분야의 대규모 문헌 분석에서도, 기기 간 상호작용의 연속성과 일관성 확보가 여전히 주요 연구 과제로 제시되고 있다[1]. 기존 개인화 기술은 이러한 문제를 해결하기 위해 지속적으로 발전해 왔으나, 개인화 정보의 활용 범위가 개별 기기 또는 특정 서비스 도메인에 제한된다는 구조적 한계를 지닌다. 사용자 모델링(User Modeling) 분야에서는 사용자 선호도와 상호작용 이력이 특정 서비스의 데이터 스키마에 종속되는 문제를 제기하였고[2], 온톨로지 기반 접근을 통해 이기종 시스템 간 상호운용성을 확보하고자 하였다[3]. 최근 대규모 언어모델(LLM) 기반 개인화 연구는 프롬프트 기반 맥락 구성, 어댑터 기반 미세조정, 개인 선호 정렬의 세 가지 접근으로 체계화되고 있으나[4], 개인화 정보의 활용이 주로 대화형 상호작용과 제한적인 도구 호출에 집중되어 있어 이기종 물리 시스템으로의 확장에는 여전히 한계가 존재한다.

서비스 로봇, 웨어러블 로봇, 자율주행차 등 물리적 행동을 수반하는 시스템에서도 개인화 기술에 관한 연구가 지속적으로 이루어져 왔다. 웨어러블 로봇 분야에서는 인간 참여형 최적화(Human-in-the-Loop Optimization)를 통해 개인별 보조 파라미터를 최적화하는 방법론이 제시되었으며[5], 자율주행 분야에서는 운전 스타일 인식과 이를 반영한 개인화 제어 기법이 연구되어 왔다[6]. 그러나 이러한 접근은 개별 응용 도메인의 특성과 요구사항에 기반하여 설계되어, 서로 다른 도메인 간 개인화 정보의 공유와 재사용을 충분히 다루지 못한다. 이는 기존 연구가 개인의 특성을 물리적 제어에 반영할 수 있음을 보여주는 반면, 이기종 기기 환경에서 해당 특성의 연속성을 확보하는 문제는 여전히 추가적인 연구가 필요함을 시사한다. 한편, 로봇 학습 분야에서는 이종 신체 사이의 정책 전이(Cross-Embodiment Policy Transfer)에 관한 연구가 발전하면서, 다양한 신체 구조에서 수집된 데이터를 통합적으로 학습하여 일반화 성능을 향상시키는 접근이 제안되고 있다[7,8]. 그러나 이러한 연구는 주로 과제(Task) 수행 능력의 전이에 초점을 맞추고 있으며, 기기와 독립적으로 개인의 인지 · 정서 · 행동 특성을 표현하고 유지하는 문제는 상대적으로 제한적으로 다루어져 왔다. 특히 기기마다 물리적 제약과 행동 공간(Action Space)이 상이하므로, 특정 기기에서 학습된 개인화 모델을 다른 기기에 직접 적용하는 것만으로는 개인의 행동 특성이 일관되게 유지된다고 보장하기 어렵다. 따라서 이기종 물리 시스템 간 개인화의 연속성을 확보하기 위해 기기 독립적인 개인 특성의 표현(Representation)을 다양한 기기의 행동 공간으로 사상(Mapping)하는 과정을 구분하여 접근할 필요가 있다.

2. 무자각 상호작용의 층위

앰비언트 인텔리전스(Ambient Intelligence) 분야에서는 사용자의 명시적인 인지적 개입을 최소화하고, 환경과의 무자각적이고 연속적인 상호작용(Unaware & Seamless Interaction)을 실현하는 것을 주요 연구 목표로 삼아 왔다. 이러한 비전은 기술이 일

상 환경의 배경으로 자연스럽게 통합되어야 한다는 유비쿼터스 컴퓨팅의 기본 철학[9]과 지능형 인터페이스가 환경에 내재하여 사용자의 존재와 상황을 비가시적으로 인식하고 대응해야 한다는 초기 구상[10]에 기반하며, 이후 센서 네트워크, 퍼베이시브 컴퓨팅 및 인공지능 기술과의 융합을 통해 구체화되어 왔다[11]. 최근의 종합적 문헌 검토에서도 비가시적 사용자 인터페이스 기반의 보조적 · 예측적 지원이 앰비언트 인텔리전스의 주요 특성으로 제시되고 있다[11]. 기존 다중 기기 상호작용 연구에서 연속성은 주로 기기 전환 과정에서 작업 맥락과 서비스 상태를 유지하는 세션 연속성(Session Continuity)의 관점에서 논의되어 왔다[1]. 그러나 서비스 로봇, 웨어러블 로봇, 자율주행차 등 이기종 지능형 기기를 연속적으로 이용하는 환경에서는 작업이나 서비스의 연속성을 넘어, 기기 간 사용자에 대한 이해와 개인화된 대응의 일관성을 유지하는 문제로 논의가 확장될 필요가 있다. 이에 본고에서는 작업 및 서비스 상태의 유지를 '세션 연속성'으로, 기기 전환에도 불구하고 개인의 특성과 이에 기반한 상호작용의 일관성이 유지되는 것을 '자아 연속성(Self Continuity)'으로 구분한다.

본고는 이러한 자아 연속성의 구현을 위한 기술적 접근과 주요 연구 과제를 분석하기 위해, 개인의 인지 · 정서 · 행동 특성을 특정 하드웨어에 종속되지 않는 표현으로 구성하고 이를 이기종 기기의 행동 공간으로 사상하는 기술을 주요 분석 대상으로 설정한다. 이때 기기 독립적으로 유지되는 개인 특성의 표현을 '자아 커널(Self Kernel)'로 명명하며, 해당 표현을 개별 기기의 신체 구조와 물리적 제약에 부합하는 행동으로 변환하는 과정을 '재체화(Re-Embodiment)'로 정의한다. 기존 문헌 분석 연구는 LLM 기반 개인화[4], 이종 신체 로봇 학습[7,8], 원격조작 및 모션 리타게팅[12], 앰비언트 인텔리전스[11] 등 개별 기술 영역을 중심으로 발전해 왔다. 이에 반해 본고는 이들 연구를 '개인 표현의 신체 간 이식'이라는 공통된 분석 관점에서 통합적으로 검토함으로써, 기술 간 연계성과 상호 보완 가능성을 분석하고 기존 연구에서 상대적으로 충분히 다루어지지 않은 과제를 도출한다. 본고의 구성은 다음과 같다. Ⅱ장에서는 개인화 기술의 발전 과정을 고찰하고, 자아 커널의 주요 요건과 인접 개념 간 관계를 검토한다. Ⅲ장과 Ⅳ장에서는 각각 기기 독립적 개인 표현의 학습 기술과 이종 신체의 행동 공간으로 변환하는 디코딩(Decoding) 알고리즘을 분석한다. Ⅴ장에서는 개인화 특성의 이식 결과에 대한 정합성 검증, 안전성 평가 방법론 및 관련 거버넌스 논의를 다룬다. Ⅵ장에서는 이러한 기술이 앰비언트 AI 환경으로 확장되는 과정에서 해결해야 할 개방형 연구 과제(Open Challenges)를 도출하며, 마지막으로 Ⅶ장에서 결론을 제시한다.

Ⅱ. 개인화에서 자아 이식으로

1. 개인화 표현의 발전

개인화 기술은 지난 30여 년간 사용자 표현(User Representation)의 구성 방식과 활용 범위를 중심으로 발전해 왔다. 본고에서는 이러한 발전 과정을 표현의 생성 방식과 기기 간 이동 가능성을 기준으로 네 가지 단계로 구분한다.

첫 번째 단계인 '설정 기반 개인화'는 사용자가 명시적으로 입력한 선호도와 설정값을 저장하고 재사용하는 초기 개인화 방식을 의미한다. 이 단계에서 사용자 표현은 사람이 해석할 수 있는 속성값의 집합으로 구성되며, 개인화 정보의 생성과 갱신은 주로 사용자의 직접적인 입력에 의존한다.

두 번째 단계인 '이력 기반 학습 개인화'에서는 추천 시스템과 적응형 인터페이스의 발전에 따라

사용자 행동 이력으로부터 선호도를 추정하는 접근이 확산되었다. 사용자 표현은 잠재 요인 벡터(Latent Factor Vector)와 같은 통계적 모델로 확장되면서 개인화 성능이 향상되었으나, 특정 서비스의 데이터 구조와 학습 환경에 종속되는 표현의 고립 문제가 발생하였다. 유비쿼터스 사용자 모델링 연구에서는 이러한 한계를 극복하기 위해 다중 애플리케이션 사이의 사용자 모델의 의미론적 상호운용성을 확보하는 방안이 제안되었다[2]. 대표적으로 GUMO(General User Model Ontology)는 OWL(Web Ontology Language) 기반 온톨로지를 활용하여 사용자의 생리적 · 심리적 차원을 정의하고, 이기종 시스템 간 사용자 정보의 교환을 지원하고자 하였다[3]. 다만 명시적인 기호 체계의 정의와 유지에 따른 부담 및 확장성 제약으로 인해 광범위한 적용에는 한계가 있었다. 그럼에도 특정 서비스나 기기에 종속되지 않는 사용자 표현의 필요성이 제기되었다는 점에서 중요한 기술적 기반을 제공하였다고 할 수 있다.

세 번째 단계인 '파운데이션 모델 기반 개인화'에서는 LLM의 발전과 함께 페르소나, 장기 기억, 검색 증강 생성(RAG: Retrieval Augmented Generation) 등 언어 기반 사용자 표현의 활용이 확대되었다[4]. 최근의 개인화 프레임워크는 에피소드 기억과 의미 기억을 구분하여 관리하고, 이를 도구 활용 및 행동 실행 모듈과 결합하는 구조로 발전하고 있다[13]. 자연어와 범용 임베딩을 활용함으로써 다양한 응용 환경에서 개인화 맥락을 재구성할 수 있는 가능성이 확대되었으나, 개인화된 상호작용은 여전히 대화, 정보 검색 및 도구 호출을 중심으로 이루어지고 있어 물리적 행동 공간으로의 확장에는 추가적인 기술적 과제가 남아 있다.

네 번째 단계인 '행동 공간 사상 기반 개인화'는 사용자 표현을 이기종 물리 시스템의 행동 공간으로 확장하기 위해 본고에서 제시하는 기술적 발전 방향이다. 서비스 로봇, 웨어러블 로봇, 자율주행차 등 다양한 지능형 기기가 일상 환경에 도입됨에 따라, 개인화 정보를 언어 중심의 디지털 상호작용을 넘어 물리적 행동과 제어에 반영하는 기술의 중요성이 증가하고 있다. 이 단계에서는 개인의 특성을 특정 하드웨어에 종속되지 않는 형태로 표현하는 동시에, 서로 다른 신체 구조와 물리적 제약을 가진 기기에서도 해당 특성에 기반한 행동의 일관성을 확보하는 것이 핵심 과제로 제시된다. 본고에서는 이러한 기기 독립적 개인 표현을 앞서 정의한 '자아 커널'의 개념으로 설명한다.

이상의 발전 과정은 사용자 표현의 활용 범위가 개별 기기의 설정값에서 특정 서비스의 학습 모델로, 나아가 디지털 서비스 간 개인화 맥락과 이기종 물리 시스템으로 확장되는 흐름으로 해석할 수 있다. 특히 네 번째 단계에서는 개인화 정보의 단순한 전달이나 재사용을 넘어, 기기 독립적 표현을 각 신

표 1 개인 표현 관련 개념의 비교

개념	주요 목적	표현 형식	적용 범위
사용자 모델과 프로파일	선호 기술과 서비스 적응	속성값· 잠재 벡터	인터페이스· 콘텐츠
인간 및 인지 디지털 트윈	개인 상태와 반응의 시뮬레이션	다중 데이터 기반 복제 모델	예측과 재현
아바타와 디지털 휴먼	외형과 표현 특성의 사상	3D 형상· 표정·동작	시각적 표현
에이전트 메모리와 페르소나	상호작용 이력 기반 개인화	텍스트· 기억·도구 이력	디지털 행동
행동 기반 식별	개인 간 구별	행동 특징 벡터	인증과 분류
자아 커널	개인 특성의 이종 신체 간 재사용	신체 비종속 최소 충분 표현	물리적 행동 생성

체의 행동 공간으로 변환하는 디코딩 과정이 요구된다. 따라서 표 1에 기술하였듯이 이기종 기기 간 자아 연속성의 확보는 사용자 표현의 이동 가능성뿐만 아니라, 물리적 제약이 상이한 환경에서도 개인화된 행동의 의미적 일관성을 유지할 수 있는가의 문제로 확장된다고 볼 수 있다.

2. 자아 커널의 요구사항

신체 독립적 개인 표현인 '자아 커널'의 기술적 요구사항은 표현 학습, 사용자 모델링 및 인지과학 분야의 관련 논의를 바탕으로 세 가지 핵심 특성으로 구분할 수 있다.

첫째, '신체 불변성(Morphology Invariance)'은 개인 표현이 특정 기기의 자유도, 제어 주기 및 센서 구성과 같은 신체적 · 기술적 특성에 종속되지 않아야 함을 의미한다. 이는 서로 다른 신체 구조를 공유 잠재 공간(Shared Latent Space)으로 사상하려는 이종 신체 로봇 학습 연구[14,15]와 정보이론적 관점에서 과제와 무관한 요인(Task-Irrelevant Factors)의 영향을 최소화하려는 표현 학습 연구[16]와 개념적 연관성을 갖는다. 본고에서는 이러한 불변성의 대상을 환경적 변동 요인뿐만 아니라 기기의 신체 구조와 제어 특성으로 확장하여, 기기 전환에도 개인의 핵심 특성이 일관되게 유지될 수 있는 표현을 요구한다.

둘째, '최소 충분성(Minimal Sufficiency)'은 개인의 행동 특성을 재현하는 데 필요한 정보를 보존하면서, 목적과 무관한 정보의 포함을 최소화하는 성질을 의미한다. 정보 병목(Information Bottleneck) 이론에서 충분성은 목표 변수에 관한 정보를 손실 없이 보존하는 것을, 최소성은 이러한 조건을 충족하면서 입력 정보와 표현 사이의 정보 의존성을 최소화하는 것을 의미한다[17]. 이러한 접근은 표현의 효율성을 높이는 동시에, 개인화에 불필요한 민감정보의 포함을 줄이기 위한 이론적 기반을 제공할 수 있다. 다만 개인의 인지 · 정서 · 행동 특성을 포괄하는 목표 변수를 어떻게 정의하고 관측 가능한 형태로 구성할 것인지는 추가적인 검토가 필요한 과제로 남아 있다.

셋째, '이식 가능성(Transferability)'은 기기 독립적 개인 표현을 서로 다른 신체 구조와 행동 공간을 가진 시스템에 적용할 수 있는 성질을 의미한다. 이는 기존 사용자 모델링 분야에서 논의된 의미론적 상호운용성[2]을 물리적 행동의 영역으로 확장하는 것으로, 사용자 정보의 표현 및 해석에 관한 정합성뿐만 아니라 기기별 행동 가능 범위(Affordance)와 물리적 제약의 차이를 함께 고려해야 한다. 이식 결과의 평가에는 인지과학의 '최소 자아(Minimal Self)' 개념에서 논의되는 행위 주체감(Sense of Agency)과 신체 소유감(Sense of Ownership)[18]을 참고하여, 기기의 행동이 자신의 특성을 반영한다고 인식하는 정도를 사용자 귀속 판단(Attribution Judgment)을 통해 검토하는 접근을 고려할 수 있다. 관련하여 최소 자아 개념을 로봇의 감각운동 표현 학습과 연결하려는 연구도 보고된 바 있다[19]. 따라서 이식 품질의 평가는 표현의 정보 보존과 행동 정합성에 관한 정량적 분석뿐만 아니라, 개인화된 행동에 대한 사용자의 주관적 인식을 함께 고려하는 방향으로 확장될 필요가 있다.

III. 신체 독립적 표현 학습 기술

1. 이종 신체 간 정책 학습

로봇 학습 분야에서 신체 독립적 표현에 관한 연구는 개별 플랫폼에서 수집할 수 있는 학습 데이터의 제한을 극복하고, 서로 다른 신체 구조로의 정책 일반화를 확보하는 과정에서 발전해 왔다. 이를 위해 다중 로봇 플랫폼에서 수집된 데이터를 통합하

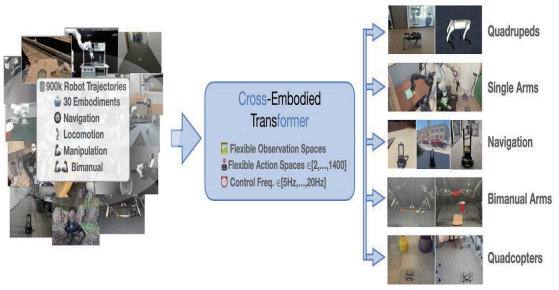

출처 Reprinted from R. Doshi et al., "Scaling Cross-Embodied Learning: One Policy for Manipulation, Navigation, Locomotion and Aviation," in Proc. 8th Conf. Robot Learn., (Munich, Germany), 2024, pp. 496-512.

그림 1 CrossFormer의 다종 로봇 통합 학습

여 사전학습(Pre-Training)에 활용하는 접근이 제안되었다[7]. 대규모 실로봇 데이터셋을 활용한 연구는 단일 로봇 및 특정 과제에 종속된 학습 데이터의 범위를 확장하고, 학습되지 않은 과제와 이종 로봇으로의 일반화 가능성을 제시하였다[7]. 최근에는 그림 1과 같이 단일 트랜스포머 아키텍처를 통해 20종의 로봇 데이터를 통합 학습하는 CrossFormer가 제안되었으며[8], 범용 로봇 제어를 위한 $\pi 0$[20]와 휴머노이드 파운데이션 모델 GR00T N1[21] 등 다양한 신체 구조와 과제에 대응하기 위한 모델도 등장하였다. 또한 오프라인 강화학습의 정책을 전이하는 접근[22]과 신체 형태의 다양성을 증강하는 방법[23]을 통해 데이터 활용 효율성과 미학습 신체에 대한 일반화 성능을 향상시키려는 연구가 이루어지고 있다. 그러나 이러한 접근은 주로 과제 수행 능력과 제어 정책의 일반화에 초점을 맞추고 있으며, 특정 개인의 행동 특성과 선호도를 기기 독립적인 표현으로 학습하고 유지하는 문제는 상대적으로 제한적으로 다루어져 왔다.

2. 이종 신체 간 표현 학습 접근

이종 신체 간 구조적 차이를 고려한 표현 학습 및 정책 일반화 접근은 신체 정보를 활용하는 방식에 따라 명시적 조건화(Explicit Conditioning)와 잠재 정렬(Latent Alignment)의 두 가지 관점에서 구분할 수 있다.

첫째, '명시적 조건화'는 로봇의 물리적 구조와 운동학적 특성을 기술하는 URDF 등의 명세 정보 또는 신체 형태 임베딩(Morphology Embedding)을 정책 신경망의 조건 입력으로 활용하는 접근이다[24]. 대표적으로 전문가 정책 증류(Expert Policy Distillation)를 통해 다양한 신체 구조에서 일반화 가능한 정책을 학습하는 연구[24]와 다리형 로봇 제어를 시퀀스 모델링 문제로 구성하여 신체 간 정책 일반화를 추구하는 연구[25]가 관련 접근으로 논의될 수 있다. 이러한 방식은 신체 구조의 차이를 정책 학습 과정에 반영함으로써, 서로 다른 로봇의 물리적 특성에 대응할 수 있는 제어 정책을 구성하는 데 초점을 맞춘다.

둘째, '잠재 정렬'은 서로 다른 신체 구조에서 관측되는 상태, 행동 또는 과제 관련 정보를 공통된 잠재 표현 공간에서 정렬하여 정책이나 기술의 전이를 지원하는 접근이다. 대표적으로 그림 2의 XSkill은 시간적으로 정렬되지 않은 인간과 로봇의 영상

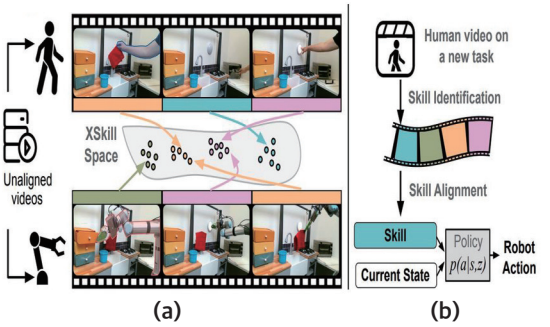

출처 Reprinted from M. Xu et al., "XSkill: Cross Embodiment Skill Discovery," in Proc. 7th Conf. Robot Learn., (Atlanta, GA, USA), 2023, pp. 3536-3555.

그림 2 XSkill의 사람-로봇 간 기술 표현 학습: (a) Training Skill Discovery with Cross-Embodiment Videos, (b) Inference on Novel Tasks

으로부터 신체 간 공유 가능한 스킬 프로토타입을 학습하고, 이를 조건부 확산 정책과 결합하여 로봇 행동으로 전이하는 방법을 제안하였다[14]. 또한 XIRL은 서로 다른 신체의 시연 데이터로부터 공유 표현을 학습하고, 이를 보상 함수 구성에 활용함으로써 신체 간 기술 전이를 지원하였다[15]. 이러한 연구는 신체 구조와 관측 방식이 상이한 환경에서도 과제 수행에 필요한 공통 특성을 학습할 수 있음을 보여준다.

3. 개인 행동 스타일의 표현

개인의 행동 특성을 정량적으로 표현하고 물리적 제어에 반영하는 연구는 서비스 로봇과 원격조작, 웨어러블 로봇과 재활, 자율주행차 등 다양한 응용 분야에서 발전해 왔다. 자율주행 분야에서는 운전 스타일 인식과 개인화 제어를 결합하는 접근이 지속적으로 연구되어 왔으며[6], 역강화학습(IRL: Inverse Reinforcement Learning)을 통해 운전 궤적으로부터 개인의 주행 선호도를 추정하고 이를 적응형 제어에 활용하는 방법이 제안되었다[6]. 웨어러블 로봇 분야에서는 대사 에너지 소모와 같은 생체 반응을 최적화 목표로 활용하는 인간 참여형 최적화를 통해 개인별 보조 토크 패턴을 조정하는 방법론이 발전하였으며[5], 이는 개인의 신체적 특성과 요구사항을 물리적 제어 파라미터에 반영하는 대표적인 사례에 해당한다. 최근에는 최대 평균 불일치(MMD: Maximum Mean Discrepancy)와 KL 발산(Kullback–Leibler Divergence)을 활용하여 주행 스타일의 차이를 정량화하고, 기반 모델의 미세조정을 통해 개인화 성능을 개선하려는 접근도 보고되었다[26]. 이러한 연구는 개인의 행동 특성을 관측 가능한 지표로 표현하고 제어 정책에 반영할 수 있음을 보여준다. 그러나 가감속 패턴이나 보행 특성과 같은 지표는 개별 응용 도메인의 상태 및 행동 공간에 의존하므로, 이를 서로 다른 신체 구조를 가진 기기에서 공통으로 활용하기 위해서는 추가적인 표현 변환과 의미적 정렬이 요구된다.

기존 연구의 전이 방식은 정보의 출처와 대상, 그리고 전이되는 표현의 성격에 따라 세 가지 관점에서 구분할 수 있다. 첫째, '기기 간 운동 정책 전이'는 이종 로봇 데이터를 활용하여 서로 다른 신체 구조에서 과제 수행 능력과 제어 정책을 공유하는 접근으로, 주로 로봇 간 정책 일반화에 초점을 맞춘다[7,8]. 둘째, '인간의 개인화 정보 전이'는 개인화 LLM 에이전트를 통해 사용자의 선호도와 상호작용 이력을 모델의 언어적 맥락이나 기억 표현에 반영하는 접근으로, 물리적 신체의 행동 제약을 직접적으로 고려하는 데에는 한계가 있다[4,13]. 셋째, '인간 동작의 로봇 전이'는 원격조작과 모션 리타게팅을 통해 인간의 동작이나 시연 정보를 로봇의 행동 공간으로 변환하는 접근으로, 주로 동작 궤적과 과제 수행의 전이에 초점을 맞춘다[12,14].

이러한 접근은 각각 과제 수행 능력, 개인화 맥락 및 동작 정보의 전이를 지원하지만, 개인의 행동 특성을 기기 독립적인 표현으로 구성하고 이를 서로 다른 물리적 신체의 행동으로 일관되게 구현하는 문제를 통합적으로 다루지는 않는다. 따라서 이기종 기기 간 자아 연속성을 확보하기 위해서는 도메인별로 관측되는 행동 특성으로부터 개인의 공통된 특성을 추출하고, 이를 각 기기의 행동 가능 범위와 물리적 제약에 맞추어 변환할 수 있는 표현 학습 및 사상 방법론이 요구된다고 볼 수 있다.

IV. 재체화 디코딩 기술 동향

1. 물리 제약 기반 행동 사상

신체 독립적 개인 표현인 '자아 커널'을 실제 행

동으로 변환하기 위해서는 대상 기기의 행동 가능 범위와 물리적 제약을 함께 고려해야 한다. 특히 기기별 자유도, 구동 범위 및 작업 공간의 차이는 행동 사상 과정의 주요 제약 조건으로 작용한다. 행동 가능 범위 개념[27]은 로봇 조작 분야에서 환경 및 물체와의 상호작용 가능성을 표현하고, 이를 정책 학습에 반영하는 데 활용되어 왔다[28]. 본고에서 다루는 재체화는 이러한 논의를 기기의 형태학적 · 동역학적 제약으로 확장하여 행동 사상의 조건으로 고려한다. 관련 기술적 기반으로는 서로 다른 신체 구조 간 동작을 변환하는 모션 리타게팅(Motion Retargeting) 연구를 들 수 있다[29]. 해당 기술은 기구학적(Kinematic) 사상에서 동역학적 제약을 고려한 전신 제어로 발전해 왔으며[12], 최근에는 접촉 및 상호작용 특성의 보존[30]과 후속 제어 정책을 고려한 리타게팅 품질 평가[31]로 연구 범위가 확대되고 있다. 그러나 개인의 행동 특성은 동작 궤적이나 접촉 조건과 달리 명시적으로 정량화하기 어려우므로, 이를 행동 사상 과정에 반영하기 위한 별도의 표현 및 평가 기준이 요구된다.

2. 재체화 구조와 이식 손실

재체화 디코더는 구현 방식에 따라 신체 정보를 조건 입력으로 활용하는 조건부 정책[24], 공통 백본과 모듈식 어댑터를 결합하는 구조[26], 신체 명세에 기반한 하이퍼네트워크, 행동 궤적을 공통 토큰 표현으로 변환하는 구조[8]의 네 가지 접근으로 구분할 수 있다. 자아 커널의 재체화에는 신체 특성과 개인 특성을 함께 조건으로 활용하여 행동을 생성하는 구조가 고려될 수 있으나, 이종 신체 간 학습 안정성과 데이터 효율성 확보는 추가적인 연구 과제로 남아 있다. 본고에서는 재체화 과정에서 발생하는 개인 특성의 재현 오차를 '이식 손실(Transfer Loss)'로 정의하고, 이를 표현 학습 과정의 인코딩 손실, 행동 사상 과정의 디코딩 손실, 대상 기기의 물리적 제약에 따른 제약 손실로 구분한다. 특히 제약 손실은 대상 신체의 행동 가능 범위에 따라 불가피하게 발생할 수 있으므로, 기기 간 이식 품질을 비교할 때 별도로 고려할 필요가 있다. 또한 개인 특성의 보존과 과제 수행 성능 및 안전성 사이의 상충 가능성을 고려하여, 위험한 행동 특성의 재현을 제한하는 제약 기반 최적화(Constrained Optimization) 접근도 검토할 수 있다.

3. 신체군별 적용 특성

재체화의 기술적 요구사항은 대상 기기의 신체 구조와 사용자와의 상호작용 방식에 따라 달라진다. 대리 행위자로 기능하는 서비스 로봇과 로봇 팔은 높은 행동 자유도와 사용자 신체와의 구조적 차이로 인해 행동 사상의 불확실성이 증가할 수 있다. 반면 사용자와 직접 결합하는 웨어러블 로봇은 생체 반응을 통해 개인 특성을 관측하고 제어에 반영하기 용이하지만[5], 신체 접촉에 따른 엄격한 안전 제약을 고려해야 한다. 자율주행차는 주행 행동을 비교적 제한된 제어 변수로 표현할 수 있으며, 운전 스타일의 정량화와 개인화 제어에 관한 연구가 축적되어 왔다[6,26]. 그러나 이러한 기기별 특성과 물리적 제약의 차이로 인해, 이종 신체 전반에 적용 가능한 공통 재체화 구조의 설계는 여전히 중요한 연구 과제로 남아 있다.

V. 정합성 및 안전성 평가

1. 뉴로 심볼릭 기반 행동 검증

물리적 행동의 실행 안전성을 확보하기 위한 연구는 고신뢰 제어 아키텍처[32]와 강화학습 정책의

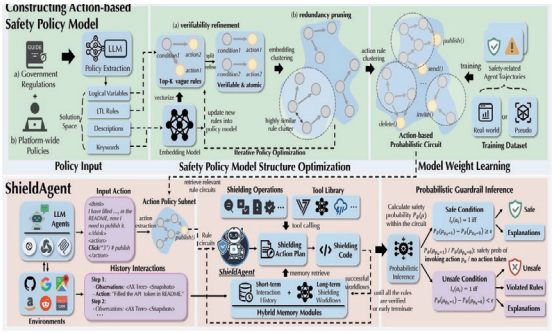

출처 Reprinted from Z. Chen et al., "ShieldAgent: Shielding Agents via Verifiable Safety Policy Reasoning," in Proc. 42nd Int. Conf. Mach. Learn., (Vancouver, Canada), 2025, pp. 8313-8344.

그림 3 ShieldAgent의 검증 가능 안전 정책 추론 사례

불안전한 행동을 제한하는 실드(Shield) 기법[33]을 중심으로 발전해 왔다. 최근에는 그림 3과 같이 정책 문서로부터 안전 규칙을 추출하고, 행동 궤적에 대한 규칙 준수 여부를 검증하는 접근도 제안되었다[34]. 자아 커널의 재체화 과정에서는 이러한 기호적 안전 규칙과 잠재 표현에 기반한 개인 행동 특성을 결합하여, 생성된 행동의 안전성과 개인화 정합성을 함께 검증하는 구조가 고려될 수 있다.

2. 개인 특성의 보존 평가

개인 특성의 이식 정합성은 통계적 거리 지표[26]와 행위주체감 및 신체 소유감에 기반한 인지적 귀속 평가[18]를 통해 검토할 수 있다. 다만 통계적 지표는 도메인별 행동 공간의 차이에 영향을 받으며, 주관적 평가는 신체 구조와 상호작용 방식에 따른 사용자 기대의 차이로 인해 직접적인 비교가 제한된다. 정보이론적 척도[16,17] 역시 보존 대상이 되는 개인 특성과 목표 변수의 명확한 정의를 요구한다. 실제 이종 기기에서의 데이터 수집과 평가에 제약이 있음을 고려하면, 시뮬레이션 기반 폐루프(Closed-Loop) 벤치마크가 이식 정합성과 행동 안전성을 검토하기 위한 평가 수단으로 활용될 수 있다[26,35].

3. 개인 표현의 보호

자아 커널에는 개인의 인지 · 정서 · 행동 특성이 포함될 수 있으므로, 해당 정보의 보호와 접근 권한 관리가 요구된다[36]. 기존 연구에서는 디지털 유사성(Digital Likeness) 보호를 위한 프레임워크[36]와 장기적 개인 모델링에 따른 윤리적 쟁점[37]이 논의되어 왔다. 그러나 자아 커널은 기기 간 이동과 재사용을 전제로 하므로, 개인정보 보호와 표현의 이동 가능성을 함께 고려해야 한다. 이를 위해 개인화에 필요한 정보만을 유지하는 최소 충분성 기반 표현 학습과 기기별 접근 권한을 관리하는 동적 권한 검증의 결합이 검토될 필요가 있다.

VI. Ambient AI로의 확장

1. 무자각 상호작용 연구

앰비언트 인텔리전스가 지향하는 무자각적이고 연속적인 상호작용은 센서 네트워크와 퍼베이시브 컴퓨팅을 기반으로 한 상황 인식 및 사용자 지원 기술을 중심으로 발전해 왔다[9-11]. 기존 다중 기기 상호작용 연구에서 연속성은 주로 기기 전환 과정에서 작업 맥락과 서비스 상태를 유지하는 세션 연속성(Session Continuity)의 관점에서 논의되어 왔다[1]. 그러나 분산된 이기종 기기 환경에서 동일 사용자에 대한 이해와 개인화된 대응의 일관성을 유지하는 자아 연속성은 상대적으로 제한적으로 다루어져 왔다[11].

2. 멀티 디바이스 환경 적용

'자아 커널'을 Ambient AI 환경에 적용하기 위해

서는 다중 센서와 기기에서 관측된 사용자 정보를 공통 잠재 표현으로 통합하고, 각 기기가 물리적 제약에 부합하는 행동을 생성하며 정합성을 검증하는 분산 아키텍처를 고려할 수 있다. 이는 기존 기호 기반 유비쿼터스 사용자 모델링[2,3]을 물리적 행동 영역으로 확장하는 접근으로, 웨어러블 로봇을 비롯한 복합 보조 기기가 활용되는 재활 및 돌봄 환경[5]에서 기기 간 개인화 정보의 불일치를 완화하고 사용자 부담을 줄이는 데 기여할 가능성이 있다. 이러한 확장을 위해서는 다음과 같은 기술적 과제에 대한 검토가 요구된다.

- **이식 보존량의 평가 기준 및 데이터셋 구축:** 이종 신체 간 개인 행동 특성의 비교를 위한 범용 평가 지표 및 기준 모델(Baseline)의 제약[26,35]. 정보이론적 척도와 다종 기기 기반 개인 행동 특성 벤치마크 데이터셋 구축 필요
- **이동성과 보안 간 상충관계 해소:** 자아 커널의 기기 간 이동 · 재사용과 개인 표현 보호 및 무단 복제 방지 요구 간 상충관계[36]. 실행 시점 검증(Runtime Verification)[34]과 접근 권한 관리를 결합한 거버넌스 체계 마련 필요

향후 연구는 개인 특성의 불변 표현을 위한 목표 변수 정의, 이종 신체 및 모션 리타게팅 기술을 활용한 디코딩 알고리즘의 고도화, 시뮬레이션 기반 벤치마크를 통한 정합성 검증 체계 구축의 세 가지 방향으로 전개될 수 있다. 현재 관련 연구는 개별 기술 영역에서 발전하고 있으나, 기기 독립적 개인 특성의 정의와 평가 기준은 아직 충분히 정립되지 않았다. 따라서 후속 연구에서는 개인 표현의 학습 및 행동 사상 알고리즘 개발과 함께, 이식 결과의 정합성과 안전성을 검증할 수 있는 평가 프레임워크의 구축이 병행될 필요가 있다.

VII. 결론

본고는 기존 개인화 기술의 기기 및 서비스 종속적 한계를 고찰하고, 신체 독립적 개인 표현인 '자아 커널'의 학습과 이를 이종 신체의 행동 공간으로 변환하는 재체화 기술의 발전 동향을 분석하였다. 이는 유비쿼터스 사용자 모델링에서 제기된 상호운용성 문제를 표현 학습과 물리적 행동 제어의 관점으로 확장한 것으로, 개인 특성의 표현과 신체 간 이식을 중심으로 관련 기술과 연구 과제를 체계화하였다. 기존 이종 신체 학습과 모션 리타게팅 연구는 과제 수행 능력과 동작의 전이를 위한 기술적 기반을 제공하고 있으나, 개인의 인지 · 정서 · 행동 특성을 기기 독립적으로 보존하고 재현하는 문제는 상대적으로 제한적으로 다루어져 왔다. 특히 개인 특성을 공통 표현으로 학습하고 대상 신체의 물리적 제약에 맞게 디코딩하는 통합적 기술 체계는 아직 충분히 확립되지 않았으며, 보존 대상이 되는 목표 변수의 정의와 이식 정합성의 정량적 평가 기준이 주요 연구 과제로 남아 있다. 또한 기기 간 개인 표현의 이동과 재사용을 위해서는 실행 안전성 검증과 접근 권한 관리가 함께 고려되어야 한다. 향후 이러한 기술적 과제와 시뮬레이션 기반 이종 신체 평가 체계가 구체화된다면, Ambient AI 환경에서 기기 전환에도 개인화된 상호작용의 일관성을 유지하고 자아 연속성을 지원하는 기반 기술로 활용될 수 있을 것으로 기대된다.

참고문헌

[1] F. Brudy et al., “Cross-Device Taxonomy: Survey, Opportunities and Challenges of Interactions Spanning Across Multiple Devices,” in Proc. CHI Conf. Hum. Factors Comput. Syst., (Glasgow, UK), 2019, pp. 1-28, doi: 10.1145/3290605.3300792

[2] F. Carmagnola et al., “User model interoperability: a survey,” User Model. User-Adapt. Interact., vol. 21, no. 3, 2011, pp. 285-331, doi: 10.1007/s11257-011-9097-5

[3] D. Heckmann et al., “GUMO - The General User Model Ontology,” in Proc. Int. Conf. User Model., (Edinburgh, UK), 2005, pp. 428-432, doi: 10.1007/11527886_58

[4] J. Liu et al., “A Survey of Personalized Large Language Models: Progress and Future Directions,” arXiv preprint, 2025, doi: 10.48550/arXiv.2502.11528

[5] J. Zhang et al., “Human-in-the-loop optimization of exoskeleton assistance during walking,” Science, vol. 356, no. 6344, 2017, pp. 1280-1284, doi: 10.1126/science.aal5054

[6] C.M. Martinez et al., “Driving Style Recognition for Intelligent Vehicle Control and Advanced Driver Assistance: A Survey,” IEEE Trans. Intell. Transp. Syst., vol. 19, no. 3, 2018, pp. 666-676, doi: 10.1109/TITS.2017.2706978

[7] Open X-Embodiment Collaboration, “Open X-Embodiment: Robotic Learning Datasets and RT-X Models,” in Proc. IEEE Int. Conf. Robot. Autom., (Yokohama, Japan), 2024, pp. 6892-6903.

[8] R. Doshi et al., “Scaling Cross-Embodied Learning: One Policy for Manipulation, Navigation, Locomotion and Aviation,” in Proc. 8th Conf. Robot Learn., (Munich, Germany), 2024, pp. 496-512.

[9] M. Weiser, “The Computer for the 21st Century,” Sci. Am., vol. 265, no. 3, 1991, pp. 94-104.

[10] K. Ducatel et al., “Scenarios for Ambient Intelligence in 2010,” ISTAG Final Report, European Commission, 2001. 2.

[11] R. Dunne et al., “A Survey of Ambient Intelligence,” ACM Comput. Surv., vol. 54, no. 4, 2021, pp. 1-27.

[12] K. Darvish et al., “Teleoperation of Humanoid Robots: A Survey,” IEEE Trans. Robot., vol. 39, no. 3, 2023, pp. 1706-1727, doi: 10.1109/TRO.2023.3236952

[13] W. Zhang et al., “PersonaAgent: Bridging Memory and Action for Personalized LLM Agents,” in Findings Assoc. Comput. Linguist.: ACL 2026, (San Diego, CA, USA), 2026, pp. 26421-26439.

[14] M. Xu et al., “XSkill: Cross Embodiment Skill Discovery,” in Proc. 7th Conf. Robot Learn., (Atlanta, GA, USA), 2023, pp. 3536-3555.

[15] K. Zakka et al., “XIRL: Cross-embodiment Inverse Reinforcement Learning,” in Proc. 5th Conf. Robot Learn., (London, UK), 2021, pp. 537-546.

[16] A. Achille and S. Soatto, “Emergence of Invariance and Disentanglement in Deep Representations,” J. Mach. Learn. Res., vol. 19, no. 50, 2018, pp. 1-34.

[17] N. Tishby et al., “The Information Bottleneck Method,” in Proc. 37th Annu. Allerton Conf. Commun., Control Comput., (Monticello, IL, USA), 1999, pp. 368-377.

[18] O. Blanke and T. Metzinger, “Full-body Illusions and Minimal Phenomenal Selfhood,” Trends Cogn. Sci., vol. 13, no. 1, 2009, pp. 7-13, doi: 10.1016/j.tics.2008.10.003

[19] P.D.H. Nguyen et al., “Sensorimotor Representation Learning for an ‘Active Self’ in Robots: A Model Survey,” K nstl. Intell., vol. 35, 2021, pp. 9-35, doi: 10.1007/s13218-021-00703-z

[20] K. Black et al., “π0 : A Vision-Language-Action Flow Model for General Robot Control,” in Proc. Robot.: Sci. Syst., (Los Angeles, CA, USA), 2025.

[21] J. Bjorck et al., “GR00T N1: An Open Foundation Model for Generalist Humanoid Robots,” arXiv preprint, 2025, doi: 10.48550/arXiv.2503.14734

[22] H. Niu et al., “A Comprehensive Survey of Cross-Domain Policy Transfer for Embodied Agents,” in Proc. 33rd Int. Joint Conf. Artif. Intell., (Jeju, Republic of Korea), 2024, pp. 8197-8206, doi: 10.24963/ijcai.2024/906

[23] G. Ji et al., “OXE-AugE: A Large-Scale Robot Augmentation of OXE for Scaling Cross-Embodiment Policy Learning,” in Proc. 43rd Int. Conf. Mach. Learn., (Seoul, Republic of Korea), 2026, pp. 51486-51513.

[24] T. Chen et al., “Hardware Conditioned Policies for Multi-Robot Transfer Learning,” in Adv. Neural Inf. Process. Syst., (Montr al, Canada), 2018, pp. 9355-9366.

[25] C. Yu et al., “Multi-embodiment Legged Robot Control as a Sequence Modeling Problem,” arXiv preprint, 2022, doi: 10.48550/arXiv.2212.09078

[26] X. Dong et al., “Driving with A Thousand Faces: A Benchmark for Closed-Loop Personalized End-to-End Autonomous Driving,” arXiv preprint, 2026, doi: 10.48550/arXiv.2602.18757

[27] J.J. Gibson, “The Ecological Approach to Visual Perception,” Houghton Mifflin, 1979.

[28] S. Nasiriany et al., “RT-Affordance: Affordances are Versatile Intermediate Representations for Robot Manipulation,” in Proc. IEEE Int. Conf. Robot. Autom., (Atlanta, GA, USA), 2025, pp. 8249-8257, doi: 10.1109/ICRA55743.2025.11127525

[29] K. Aberman et al., “Skeleton-Aware Networks for Deep Motion Retargeting,” ACM Trans. Graph., vol. 39, no. 4, 2020, pp. 1-14, doi: 10.1145/3386569.3392462

[30] L. Yang et al., “OmniRetarget: Interaction-Preserving Data Generation for Humanoid Whole-Body Loco-Manipulation and Scene Interaction,” arXiv preprint, 2025, doi: 10.48550/arXiv.2509.26633

[31] J.P. Araujo et al., “Retargeting Matters: General Motion Retargeting for Humanoid Motion Tracking,” in Proc. IEEE Int. Conf. Robot. Autom., (Vienna, Austria), 2026.

[32] L. Sha, “Using Simplicity to Control Complexity,” IEEE Softw., vol. 18, no. 4, 2001, pp. 20-28, doi: 10.1109/MS.2001.936213

[33] M. Alshiekh et al., “Safe Reinforcement Learning via Shielding,” in Proc. AAAI Conf. Artif. Intell., (New Orleans, LA, USA), vol. 32, no. 1, 2018, pp. 2669-2678, doi: 10.1609/aaai.v32i1.11797

[34] Z. Chen et al., “ShieldAgent: Shielding Agents via Verifiable Safety Policy Reasoning,” in Proc. 42nd Int. Conf. Mach. Learn., (Vancouver, Canada), 2025, pp. 8313-8344.

[35] M. Parakh et al., “AnyBody: A Benchmark Suite for Cross-Embodiment Manipulation,” arXiv preprint, 2025, doi: 10.48550/arXiv.2505.14986

[36] H. Atta et al., “DIRF: A Framework for Digital Identity Protection and Clone Governance in Agentic AI Systems,” arXiv preprint, 2025, doi: 10.48550/arXiv.2508.01997

[37] V.K. Bonagiri et al., “Cognitive Digital Twins: Ethical Risks and Governance for AI Systems That Model the Mind,” arXiv preprint, 2026, doi: 10.48550/arXiv.2606.23094