



디지털을 넘어, 현실을 움직이는

Physical AI의 시대

Physical AI가 기업의 업무와 밸류체인을 어떻게 새롭게 정의하는지,
도입 시 고려해야 할 PoC, 구축방안 등에 대한 시사점을 제시합니다.

Issue Brief

August 2026



Table of contents

들어가며	02
현실세계와 융합하는 AI의 미래	03
Physical AI 시대의 Being AI	13
데모·실험을 넘어 확장 가능한 현장 검증 체계	22
제조 현장의 Physical AI 도입 전략	26
Physical AI Ready Data	31
PwC Physical AI & Robotics Center 소개	38



들어가며

최근 산업계 전반에서 가장 뜨거운 논의 중의 하나는 Physical AI일 것입니다. 생성형 AI가 텍스트와 이미지를 만들어내며 가능성을 보여주었다면, 에이전틱 AI는 업무의 흐름을 이해하고 여러 작업을 연결하는 방식으로 기업 운영의 변화를 예고했습니다. 이제 AI는 화면 안에 머무르지 않고, 로봇과 설비, 센서, 자율 시스템과 결합해 현실 세계를 인지하고 판단하며 직접 행동하기 시작했습니다.


Physical AI가 주목받는 이유도 여기에 있습니다. 이는 더 정교한 로봇을 도입하거나 특정 공정을 자동화하는 수준의 변화가 아닙니다. 생산라인, 물류창고, 건설현장과 같은 실제 산업 현장에서 AI가 사람과 협업하고, 물리적 환경에 대응하며, 기업의 운영 방식과 가치 창출 방식을 바꾸는 변화입니다.

그러나 Physical AI의 확산은 기술의 가능성만으로 결정되지 않습니다. 확산 시점에 대한 관심이 커질수록, 기업이 마주해야 할 더 중요한 질문은 이를 실제 운영 성과로 연결하기 위해 무엇을 준비해야 하는가에 있습니다. 로봇의 성능뿐 아니라 센서와 액추에이터, AI 모델과 디지털 트윈, 데이터와 운영 시스템이 하나의 구조로 연결되어야 하며, 현장에서 반복적으로 작동할 수 있는 검증 체계와 확장 가능한 운영 기반이 필요합니다.

Physical AI는 아직 초기 단계에 있지만, 그 영향은 기술 트렌드를 넘어 산업 현장의 작동 방식 자체를 바꿀 수 있습니다. 앞으로의 격차는 어떤 기술을 보유했는가보다, 이를 얼마나 빠르게 현장에 적용하고 실제 비즈니스 가치로 전환할 수 있는가에서 만들어질 것입니다.

본 보고서는 먼저 Physical AI 생태계 내 주요 플레이어들을 살펴보고, 요구되는 운영 모델과 도입 프레임워크를 제시합니다. 또한 데모와 실험을 넘어 실제 현장에서 검증하고 확산하기 위한 방법론과 제조 현장 적용 전략을 살펴본 후, 기업이 지금부터 준비해야 할 Ready Data에 대해 논의합니다. 본 보고서가 귀사의 Physical AI 전략 수립과 투자 우선순위 설정, 새로운 비즈니스 기회 발굴에 유용한 인사이트를 제공함으로써 미래 경쟁력 확보를 위한 의사결정에 실질적인 도움이 되기를 기대합니다.

현실 세계와 융합하는 AI의 미래



Physical AI의 도래

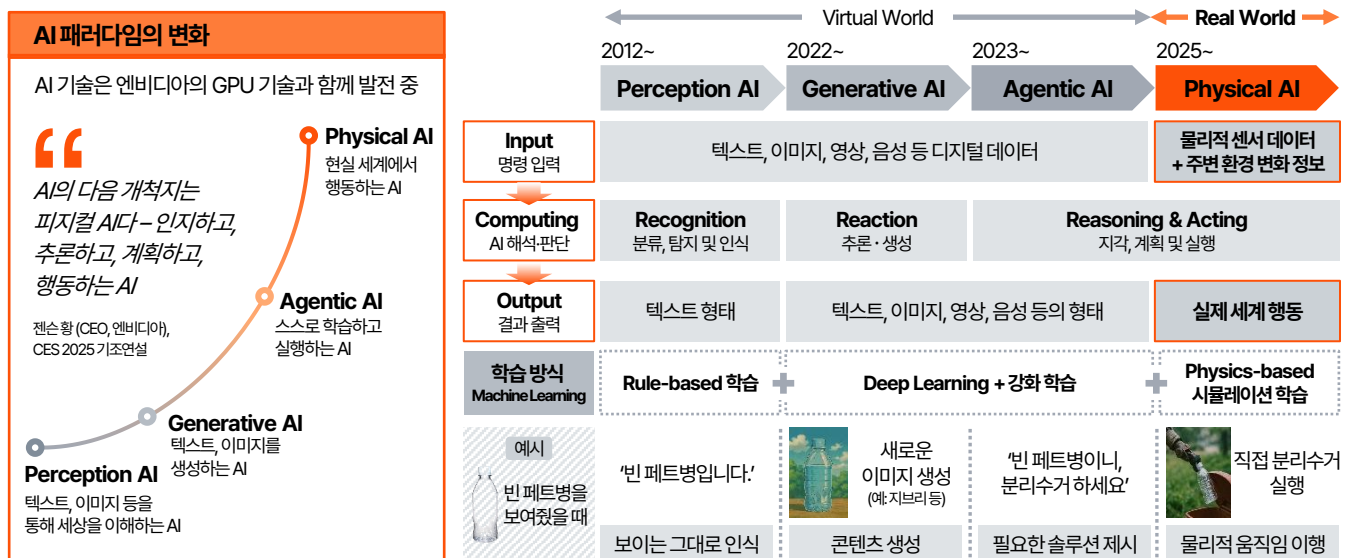
AI 패러다임의 변화

AI는 지금까지 총 네 번의 패러다임 전환을 거쳐 발전해왔습니다. 첫 번째는 인지형(Perception) AI로서 텍스트, 음성, 이미지 데이터 등을 통해 세상을 인식하는 단계입니다. 두 번째는 생성형 AI입니다. 텍스트와 이미지 등을 생성하면서 인간의 창의 영역까지 확장되었습니다. 세 번째는 에이전틱 AI입니다. 스스로 목표를 설정하고 판단하며 실행까지 이어지는 단계입니다.

그리고 지금 우리가 마주하고 있는 네 번째 전환이 Physical AI입니다. 지금까지의 AI는 디지털 공간 안에서만 머물렀습니다. 하지만 이제 AI는 현실 세계로 나와서 직접 행동하기 시작합니다.

이 차이를 아주 단순하게 보면 이해가 쉽습니다. 빈 페트병을 하나 보여줬다고 가정해보겠습니다. 인지형 AI는 그것을 인식하여 '빈 페트병입니다'라는 결과를 냅니다. 생성형 AI는 거기서 한 단계 더 나아가 새로운 이미지나 설명을 만들어냅니다. 에이전틱 AI는 '빈 페트병이니 분리수거를 하세요.'와 같은 판단을 내립니다. Physical AI는 여기서 끝나지 않습니다. 직접 로봇이 그 페트병을 집어서 분리수거를 수행합니다. 결과를 말하는 것이 아니라, 현실에서 행동하는 것입니다.

오늘날의 Physical AI



출처: PwC

Physical AI 적용 분야

Physical AI는 특정 기술 하나를 의미하지 않습니다. 실제 산업에서 작동하는 세 가지 핵심 도메인으로 나뉩니다. 바로 자율주행, 로봇틱스, 그리고 스마트 스페이스입니다.

먼저 자율주행입니다. 사람이나 원격 개입 없이 스스로 이동하고 운송을 수행하는 AI 기반 모빌리티입니다. 자동차를 넘어서 항공 영역까지 확장되고 있습니다. UAM 같은 사례가 대표적입니다. 이 영역의 핵심은 상황 인식과 의사결정입니다. 카메라와 레이더 같은 센서를 통해 주변 환경을 인식하고, AI가 경로를 계획하고 위험을 회피합니다.

두 번째는 로봇틱스입니다. 제조, 서비스, 가정까지 다양한 환경에서 실제 작업을 수행하는 물리적 에이전트입니다. 여기에는 로봇팔, 협동로봇 같은 비인간형 로봇과 휴머노이드가 포함됩니다. 핵심은 작업 이해와 정밀 제어입니다. 로봇은 단순 반복이 아니라 작업 환경을 인식하고 작업 지시를 해석하며 움직입니다.

세 번째는 스마트 스페이스입니다. 이건 개별 로봇이 아니라 공간 전체를 지능화하는 개념입니다. 공장, 도시, 공항 같은 환경에서 다수의 센서와 시스템을 연결해 전체 운영을 최적화합니다. 공장에서는 생산 최적화와 예지보전, 도시에서는 교통과 에너지 관리, 공항에서는 흐름 제어가 대표적인 사례입니다.

Physical AI 핵심 도메인

Physical AI 적용 분야			센서·시스템	AI 모델·칩	액추에이터
	정의	유형	Input 명령 입력	Computing AI 해석·판단	Output 결과 출력
 자율주행 (Vehicle, Air)	사람 또는 원격의 개입 없이 이동·운송을 수행하는 AI 기반 모빌리티	자율주행차	카메라, 레이더 등 센서 기반 주행 상황 파악	AI 기반 경로 계획 및 위험 회피를 판단	주행 자동 제어
		UAM	항법 센서, GPS, 기상 및 공역 데이터 인식	비행 경로 최적화 및 충돌 회피 진단	추진 및 비행 안정제어
 AI 로봇틱스	제조·서비스·가정 등에서 필요한 작업을 수행하는 AI 기반 물리적 에이전트	비인간형 로봇 (로봇팔, 협동로봇 등)	멀티 모달 센서 기반 작업 환경 정밀 인식	작업 지시 해석 및 궤적·동작 경로 계산	정밀 동작 제어
		휴머노이드	멀티 모달 센서 기반 사람 및 주변 환경 인식	자연어 이해 및 전신 움직임 계획	인간의 움직임 구현
 스마트 스페이스	다수의 로봇, 센서 등이 작동하는 공간 전체를 최적화·제어하는 AI 시스템	스마트 팩토리	라인·공정 내 센서 및 설비 가동 데이터 수집	생산 최적화 및 예지보전 연산	전체 공장의 자동화
		스마트 인프라 (도시, 공항 등)	CCTV, IoT 기반 군중·환경 데이터 수집	운영 상황 분석 및 최적 효율화 계산	전체 공간의 자유헌제어관리

출처: Press Release, PwC Analysis

Physical AI의 5가지 레이어

Physical AI는 단일 기술이 아니라 5개의 레이어 스택으로 구성된 산업입니다.

가장 아래에는 컴퓨트와 칩이 있습니다. 학습용 GPU와 시뮬레이션 서버가 핵심입니다. 하지만 이 영역은 현재 대부분 해외 의존도가 높은 상황입니다. 반면 온디바이스 추론 칩, 즉 로봇에 들어가는 저전력 NPU는 상대적으로 한국이 강점을 가질 수 있는 영역입니다. 앞으로 중요한 전략 포인트입니다.

그 다음은 데이터와 시뮬레이션입니다. 여기서 병목이 발생합니다. 실제 물리 세계 데이터를 수집하는 것이 어렵고 비용이 큼니다. 그래서 디지털 트윈과 합성 데이터를 활용한 시뮬레이션이 중요해집니다. 즉 가상에서 학습한 것을 현실로 전이(Sim-to-real)하는 기술이 핵심입니다.

그 위에는 브레인이 있습니다. 여기서 두 개의 구조가 나뉩니다. 하나는 월드 모델, 즉 고차 추론을 담당하는 영역입니다. 다른 하나는 VLA 기반 실행 모델입니다. Vision, Language, Action을 통합해서 실제 행동까지 이어지는 구조입니다.

그 다음은 하드웨어입니다. 여기에는 센서, 액추에이터, 전력 시스템이 포함됩니다. 특히 액추에이터와 구동계는 부품 원가의 40-60%를 차지합니다. 즉, 하드웨어 경쟁력이 매우 중요한 시장입니다.

마지막은 배치입니다. 실제 현장에 적용하고 운영하는 단계입니다. 로봇을 하나 설치하는 것이 아니라, 다수의 로봇을 통합해서 운영하는 플릿 관리와 RaaS 모델이 등장합니다.

Physical AI 5대 레이어 스택

컴퓨트 & 칩	데이터 & 시뮬레이션	브레인	하드웨어	배치
학습용 컴퓨트 학습용 GPU, 시뮬레이션 서버 (대부분 해외 의존)	Real-world Data 텔레오퍼레이션-웨어러블- 모션캡처 수집 (데이터 병목 영역)	월드 모델 (계획·추론) 고차 추론 대뇌, System 2	액추에이터·구동계 모터, 감속기, 관절	오케스트레이션·플릿· RaaS 다중 로봇 통합 관제, 구독형 (RaaS) 운영, 로봇전환(RX) 플랫폼
온디바이스 추론 칩 로봇 탑재용 저전력 NPU·SoC : 엣지 추론 담당 (한국 강점 영역)	Simulation-Synthetic 디지털 트윈 + 합성데이터 생성으로 Sim-to-real 학습 비용 절감	VLA-Foundation (실행) Vision-Language-Action, System 1	센서·인지 카메라, LiDAR, 촉각	버티컬 솔루션 & SI 도메인별 현장 적용·통합: 이종산업 융합이 실제 일어나는 지점
		Robot OS-MLOps ROS2·미들웨어 + 학습/평가 운영	전력·에너지 배터리, 전력관리	
			로봇 바다·차량 휴머노이드, AMR, AV 통합	
Cross-cutting Foundation		연결성 Private 5G·엣지 네트워크	관리체계·안전성 EU AI Act 대응 안전인증	데이터 프라이빗 운영 데이터 → 재학습 환류

출처: 업계 리포트·기업 공개자료(2025~2026), PwC Analysis

CES 2025 이후 2년

제품이 아니라 '노동'을 대체하는 Physical AI


Physical AI 시장은 기존 IT 시장과 완전히 다릅니다. 제품 시장이 아니라 노동 시장을 대체하는 구조입니다. 지금까지 기술 시장 규모는 판매되는 제품 기준이었습니다. 스마트폰 몇 대, 서버 몇 대 이런 식입니다. 그런데 Physical AI는 다릅니다. 노동력을 기준으로 시장이 정의되기 때문에 시장의 상한 자체가 다릅니다. 전 세계 노동 시장은 약 60조 달러 규모입니다. 이 중 일부만 대체해도 시장은 폭발적으로 커집니다.

예를 들어 전 세계 가구의 10%가 지능형 로봇을 보유하게 되면, 2050년 시장 규모는 약 5조 달러 수준까지 확대됩니다. 초기에는 제조와 물류 중심으로 시작하지만, 시간이 지나면 돌봄, 가사까지 확장됩니다.

이 흐름은 구조적인 이유가 있습니다. 고령화입니다. 2050년에는 60세 이상 인구가 약 21억 명에 달할 것으로 예상됩니다. 노동력 부족은 문제를 피할 수 없는 현실이며 Physical AI는 이러한 상황에서 무한한 적용 가능성을 가지고 있습니다. Physical AI는 인간 환경에 그대로 들어갈 수 있기에 완전히 새로운 환경이 필요하지 않습니다. 공장, 물류센터, 가정, 병원 어디든 적용 가능합니다.

그래서 이 시장은 IT 산업이 아니라 산업 전체를 다시 정의하는 시장입니다. AI가 기존 산업을 지원하는 것이 아니라, 노동 자체를 대체하면서 산업 구조를 바꾸는 단계로 들어가고 있습니다.

Physical AI 시장 전망



1. 지능형 로봇 기준 시장 추정 (하드웨어 \$ 4.7 tril., 서비스/데이터/유지보수 \$ 0.3 tril. (2050년 연매출 기준))
출처: Morgan Stanley, Press Search, PwC Analysis

Physical AI 시장 성장 가속화

Physical AI 시장은 지금 예상보다 훨씬 빠르게 커지고 있습니다. 과거 전망치와 최근 전망치를 비교해보면, 시장이 단순히 성장하는 수준이 아니라 성장 속도 자체가 재평가되고 있습니다. 골드만삭스는 2035년 시장 규모에 대해 2022년에 한 전망 대비 2024년에 한 전망이 크게 상향 조정하였습니다. 그 결과 2025년 15억 달러, 2030년 100억 달러, 2035년 380억 달러, 2040년 600억 달러로 이어지는 성장 곡선을 제시하였습니다.


이 상향 조정의 배경은 네 가지입니다. 첫째, 제조원가가 빠르게 하락하고 있습니다. 특히 중국 업체들의 생산 확대와 양산 체계 구축으로 제조원가가 연간 약 40% 하락하고 있습니다. 이 변화는 소비자 경제성 확보 시점을 2~4년 당기는 효과를 만듭니다. 즉, '언젠가는 가능하다'가 아니라 '생각보다 빨리 가능하다'로 바뀌고 있습니다.

둘째, 로봇 지능이 빠르게 진화하고 있습니다. AI의 발달로 과거처럼 엔지니어가 일일이 코딩해서 동작을 정의하던 방식에서, 로봇이 스스로 학습하는 방식으로 넘어가고 있습니다. 이 변화는 개발 속도와 현장 적응 속도를 동시에 높입니다. 로봇을 하나 만들 때 필요한 엔지니어링 부담이 줄어들고, 새로운 작업을 익히는 시간도 단축됩니다.

셋째, 하드웨어 부품의 성숙화입니다. 액추에이터, 감속기 같은 핵심 부품이 EV 산업과 부품 생태계를 공유하면서 비용과 성능이 동시에 개선되고 있습니다. 특히 중국은 일부 핵심 부품의 국산화율을 90%를 달성한 것으로 제시됩니다. 이 말은 조립을 넘어 공급망 경쟁력까지 이미 확보하고 있다는 의미입니다.

넷째, 자본 유입이 확대되고 있습니다. 정부, 대기업, VC가 모두 지능형 로봇에 전방위적으로 투자하고 있고, 이 자본이 사업 규모 확대와 양산 체계 구축을 가속하고 있습니다. 결국 시장 전망 상향은 기대감 때문이 아니라, 비용 혁신, 기술 혁신, 공급망 성숙, 자본 유입이 동시에 발생했기 때문입니다. 이 조합은 시장 형성기의 가장 강력한 신호입니다.

Physical AI 시장 전망치 상향



1. 리뷰서: 플래네터리 롤러 스크류 등
출처: Goldman Sachs, Press Search, PwC Analysis

새로운 게임의 룰: 학습에서 추론으로

학습에서 추론으로 무게 중심이 이동하면서 경쟁 지형 또한 재편되고 있습니다. 학습은 한 번 필요하지만, 추론은 매 순간 필요합니다. 시장에서 추론의 비중이 빠르게 증가하고 있고, AI 컴퓨트의 대부분이 추론으로 이동하고 있습니다. 로봇과 에이전트가 늘어날수록 이 흐름은 더 가속화될 것입니다.

여전히 학습 시장은 엔비디아가 CUDA라는 해자로 지키고 있지만, 추론 시장은 분화하고 있습니다. 저마진 대량 추론 영역에서는 ASIC과 TPU가, 고난도 에이전트형 AI 영역에서는 GPU가 각각 주도적인 역할을 담당하는 구조로 재편되는 추세입니다.

이러한 흐름 속에서도 엔비디아는 GPU 시장 점유율 약 75%를 유지하며 여전히 압도적인 지위를 점하고 있습니다. 그러나 두 가지 방향에서 균열의 조짐이 나타나고 있습니다. 공급 측면에서는 구글과 브로드컴이 커스텀 실리콘 시장에 본격 합류하며 대안 생태계를 형성하고 있고, 수요 측면에서는 메타와 오픈AI 등 주요 고객사들이 자체 칩 개발에 나서며 엔비디아의 고객이 경쟁자로 전환되는 양상을 보이고 있습니다.

따라서 시장은 더 이상 특정 기업이 독점하는 승자독식 구조가 아니라, 용도별로 분화된 칩 생태계 안에서 수익이 분산되는 구도로 전환되고 있습니다. 이 분할의 틈 속에서 HBM 공급을 담당하는 삼성전자와 SK하이닉스, 그리고 커스텀 ASIC 설계사들에게 새로운 수요와 기회가 열리고 있습니다.

로봇 산업의 관점에서도 이 흐름은 직결됩니다. 추론 칩의 가격이 낮아질수록 로봇의 TCO가 하락하는 구조이기 때문에, 현재의 칩 경쟁은 반도체 시장의 재편을 넘어 로봇 보급 속도 자체를 좌우하는 핵심 변수로 작용하고 있습니다.

추론 시장의 분화

시장 돈이 추론으로 몰림 - 추론 비중 1/3(2023) → 2/3(2026) - 추론 칩 시장 \$16 bil → 2034년 \$86 bil - 에이전트·로봇이 추론 수요 폭증	기술 전용·저전력·엣지 - 범용 GPU → ASIC 전용 칩 - 엔비디아 루빈: 추론 성능 5배 - 온디바이스(엣지) 추론 부상	경쟁 지형 독점 → 다자 경쟁 - 추론 점유 엔비디아 ~75%, 균열 시작 - 구글 TPU, 브로드컴 ASIC 합류 - 고객(메타, 오픈AI)이 자체 칩 개발
전망	승자 독식이 아닌 분할 - 학습은 엔비디아(CUDA 해자) 유지 - 추론은 분화: 저마진·대량은 ASIC·TPU, 고난도·에이전트형은 GPU, 메모리·파운드리·ASIC 설계로 수익 분산(삼성전자, SK하이닉스 기회)	Physical AI에의 영향 - 로봇의 현장 판단은 실시간 추론 기반이므로 추론 칩이 싸질수록 로봇 TCO 하락 - 엣지 추론(테슬라 AI5, 구글 8)이 지연·전력을 좌우 → 칩 전쟁이 보급 속도 좌우

출처: PwC

패권 플레이어의 전략

피지컬 AI 시장의 패권 플레이어들인 엔비디아, 구글, 테슬라는 각각의 전략으로 경쟁하고 있습니다.

엔비디아는 수평 플랫폼 전략을 취하고 있습니다. 압도적인 GPU 시장 점유율을 바탕으로, Cosmos(합성데이터, 시뮬레이션), GR00T N2(로봇 파운데이션 모델)를 함께 제공하며 자율주행·로봇 디바이스 제조사들과 광범위한 동맹을 구축하고 있습니다. 생태계를 빠르게 확장할 수 있다는 것이 핵심 강점입니다. 다만 추론 시장이 TPU, ASIC으로 잠식되면서 Q4 기준 GPU 점유율이 35%까지 하락할 수 있다는 점은 구조적 약점으로 지목됩니다.

구글은 브레인-데이터 거인형 풀스택 전략으로 맞서고 있습니다. 학습용 TPU 8t와 추론용 TPU 8i를 분리 운영하며 외부 판매를 확대하는 한편, 안드로이드와 유튜브의 방대한 사용자 데이터와 지니 월드 모델을 결합해 시뮬레이션 역량을 고도화하고 있습니다. 추론 모델로는 제미니AI로보틱스(Gemini Robotics 1.5)를 내세우며 칩-데이터-모델-플랫폼을 하나로 통합하는 풀스택 구조를 완성해 가고 있습니다.

테슬라는 수직통합 제조사 전략을 고수합니다. AI5 엣지 추론 칩과 도조(Dojo) 학습 칩을 자체 설계하고, FSD 실세계 주행 데이터와 그록(Grok)을 결합해 옵티머스에 FSD 기술을 이식하는 순환 구조를 구축하고 있습니다. 옵티머스 V3는 2026년 하반기 양산을 목표로 제조 중이며, 테슬라 자사공장과 메르세데스 AV로 배치를 확대할 계획입니다. 2027년 본격 상용화가 예정되어 있으나, 폐쇄 생태계 특성상 자사 현장 외 외부 확장에는 한계가 있습니다.

여기서 중요한 질문은 '누가 이길 것인가'가 아닙니다. 엔비디아의 수평 플랫폼, 구글의 풀스택, 테슬라의 수직통합 중 누가 승자인지는 아직 정해지지 않았습니다. 한국 기업에게 주어진 질문은 '어느 전략에 합류할 것인가', 즉 특정 생태계에 종속될 것인지 아니면 자력으로 독자 포지션을 확보할 것인지입니다. 그 선택에 따라 전략의 방향이 근본적으로 달라집니다.

Physical AI 패권 플레이어

R&D 수준 개발 참여 X 상용화

	컴퓨터 & 칩	데이터&시뮬레이션	브레인	하드웨어	배치	전략방향성
엔비디아	압도적 GPU 시장 M/S (블랙웰-루빈) + Groq 우회 인수	코스모스 합성데이터-옵티머스	GR00T N2 (프리뷰, 연말 출시·벤치 1위)	AI 디바이스 (자율주행차·로봇 등) 업체와 동맹		무기상·수평 플랫폼 추론 시장이 TPU·ASIC에 잠식 가능성 존재
구글	TPU 8t(학습)·8i(추론) 분리: 외부 판매 확대	안드로이드·유튜브 + 지니 월드 모델	제미니AI로보틱스 1.5 (추론형 VLA)	AI 디바이스 (자율주행차·로봇 등) 업체와 동맹		브레인-데이터 거인형 풀스택 AI의 가치가 학습에서 추론으로 이동하며 TPU, 데이터 기반 무장
테슬라	AI5 엣지 추론 + Dojo 학습(자체 설계) 2027년 본격 상용화 및 양산 예정	FSD 실세계 데이터 플라이휠 + Grok	옵티머스 FSD 이식 (비전 기반)	옵티머스 V3 직접 제조 (26 2H 양산)	테슬라 자사공장 메르세데스 AV	수직통합 제조사 폐쇄 생태계로서 자사 현장에 한정

출처: PwC

이머징 플레이어 및 중국 진영의 전략

패권 플레이어 아래에는 두 그룹의 도전자들이 빠르게 부상하고 있으며, 한국 기업에게 기회와 위협이 동시에 존재합니다.

첫 번째 그룹은 SW 우선, HW 독립형 플레이어입니다. 이들은 특정 하드웨어에 종속되지 않는 로봇 비종속 통합 파운데이션 모델을 개발하며, 벤더 마진을 직접 압축하는 방식으로 기존 하드웨어 업체를 압박합니다. 브레인이 하드웨어로부터 분리되면, 하드웨어는 범용화되고 가격 경쟁으로 이어지는 구조입니다. 스킨드 AI의 밸류에이션은 이미 140억 달러를 기록했으며 엔비디아, 삼성, LG의 투자를 유치했습니다. 한국 기업 입장에서는 이들과의 협업 기회를 적극적으로 모색할 필요가 있습니다.

두 번째 그룹은 수직형 풀스택 스타트업입니다. 엔비디아의 GPU와 시뮬레이션 플랫폼을 활용하되, HW, SW, 데이터 전 계층에서 매출을 창출하는 구조를 지향합니다. 자본 부담이 크다는 단점이 있으나, 피규어(Figure)는 390억 달러 밸류에이션을 달성했으며 헬릭스 VLA와 피규어 02를 결합해 BMW 공장에서 3만 대 차량 생산에 직접 참여하고 있습니다. 데모가 아닌 실제 현장에서 검증된 '일하는 로봇'을 만들어내고 있다는 점에서 차별화됩니다.

세 번째는 중국 진영입니다. 유니트리(Unitree), 아지봇(AgiBot), 유비테크(UBTech)로 대표되는 이 그룹의 전략은 명확합니다. 부품 국산화율 90%, 제조원가 연 40% 하락을 주도하며 저가 양산 체계를 빠르게 완성하고 있습니다. 유비테크는 이미 산업용 양산에 돌입한 상태입니다. 이는 단순한 가격 경쟁이 아니라 공급망 전체를 장악하는 구조적 위협입니다.

결국 한국 기업은 두 가지 신호를 동시에 읽어야 합니다. SW 우선 플레이어와의 협업을 통해 새로운 생태계에 진입할 기회, 그리고 중국의 빠른 양산 속도와 원가 경쟁력이 가져오는 제조 기반 잠식의 위협입니다.

Physical AI의 도전자 지형

R&D 수준 개발 참여 X 상용화

	컴퓨터 & 칩	데이터&시뮬레이션	브레인	하드웨어	배치	전략방향성
스킨드 AI			로봇 비종속 통합 FM: 벤더 마진 압축형 스킨드 브레인 \$14 bil 엔비디아-삼성-LG 투자		-	SW 우선· HW 독립형
π(파이)						
리얼월드						
투머로 로보틱스						
피규어	엔비디아 GPU 활용	엔비디아 시뮬레이션 플랫폼 활용 (모방학습 및 강화학습)	전 스택(HW, SW, 데이터) 통합 모델로 대규모 자본 투입 필요 헬릭스 VLA와 피규어 02의 조합으로 BMW 공장 차량 생산 참여		피규어 x BMW	수직형 풀스택
뉴빌리티						
뉴로메카						
홀리데이 로보틱스						
유니트리				저가 휴머노이드 양산 선도: 부품 국산화율 90%, 제조원가 연 40% 하락 주도	유비테크 양산 돌입	Capacity-first 중심의 원가 우위
아지봇						
유비테크						

출처: PwC

넘어야 할 장벽과 제언

냉정한 현실, 무엇이 가로 막고 있는가

Physical AI가 왜 아직까지 전면 확산되지 않았는지를 이해하려면, 데모와 실제 배치 사이의 간극을 초래하는 4가지 허들을 봐야 합니다.

첫째, 낮은 가동 신뢰성입니다. 현재 구동계는 유리턱·매스 페널티 문제와 토크 밀도·충격 흡수 난제를 완전히 해결하지 못한 상태입니다. 배터리 역시 현재 가동 시간으로는 산업 현장이 요구하는 8~20시간 연속 가동을 감당하지 못합니다.


둘째, 손의 정밀 조작 능력이 미흡합니다. 물체를 잡고, 접는 등의 행위는 인간에게는 자연스러운 동작이지만, 로봇에게는 매우 정밀한 제어가 필요합니다.

셋째, 시뮬레이션과 현실 간의 격차입니다. 가상 환경에서 잘 작동하는 알고리즘도 바닥 마찰, 조명 변화 같은 현실의 미세한 변수 앞에서 성능이 저하됩니다.

넷째, 학습 데이터 부족입니다. 로봇이 물리 환경에서 학습하려면 영상 데이터를 넘어 물리 프로세스 데이터, 접촉 정보 등 복합적인 데이터가 필요합니다. 이러한 데이터는 수집 비용이 높고 속도도 느린 것이 현실입니다.

이처럼 현실의 벽은 여전히 높습니다. 다만, 피규어 AI의 장시간 가동 실증 노력, ABB와 엔비디아의 정교한 시뮬레이션 데이터 주입 환경 구축 등 기술 돌파 사례가 등장하여 Physical AI의 전면 확산을 가로막던 장벽은 점차 낮아질 것으로 기대합니다.

Physical AI 발전의 주요 허들



1) 미국 최대 벤처캐피탈 중 하나로, 피규어 AI, 스킨드 AI 등 휴머노이드 주요 기업에 투자, 2) 액추에이터, 감속기
출처: Goldman Sachs, Press Search, PwC Analysis

제언: 공급 기업

첫째, 공급 기업은 운영 부담을 완화할 수 있어야 합니다. 공급 기업은 로봇을 만들어 판매하는 방식만으로는 더 이상 경쟁력이 유지되지 않습니다. Physical AI의 가치는 실제 현장에서 얼마나 운영 부담을 줄여주느냐로 평가됩니다. 따라서 공급 기업은 제품 공급자가 아니라, 운영 문제를 해결하는 파트너 역할을 해야 합니다.

둘째, 폐루프(Closed Loop)를 완성해야 합니다. 현재 기술 수준에서 핵심 경쟁력은 폐루프 완성도입니다. 지각, 인식, 판단, 실행이 현장 조건에서도 끊임 없이 반복적으로 작동하고 이 반복성이 유지되어야 합니다. 즉, 한 번 잘 되는 것이 아니라 지속적으로 동일한 결과를 만들어낼 수 있는가가 중요합니다. 따라서 공급 기업은 기술 과시적 자율성 경쟁 보다 환경 변화, 예외 상황에서도 반복 실행될 수 있는 시스템 완성도를 높여야 합니다.

셋째, 작업과 환경에 특화된 패키지를 설계해야 합니다. 같은 로봇이라도 어떤 환경과 작업에 투입되는지에 따라 성과가 크게 달라집니다. 따라서 범용 로봇 하나를 제공하는 접근보다는, 특정 작업과 특정 환경에서의 하드웨어, 소프트웨어, 운영 시나리오를 묶어 '작업 단위 패키지' 설계로 도입 장벽을 낮추는 전략이 필요합니다.

넷째, RaaS 사업 모델을 검토해야 합니다. 많은 기업들이 PoC 이후 실제 도입 단계에서 멈춥니다. 초기 투자 비용과 운영 부담이 크기 때문입니다. 이 문제를 해결하기 위한 방식이 RaaS입니다. 로봇을 구매하는 것이 아니라, 대여 모델로 초기 진입 장벽을 낮추고, 고객이 실제 운영 경험을 쌓을 수 있도록 만드는 방식입니다.

제언: 수요 기업

수요 기업 입장에서는 더 중요한 질문이 있습니다. 지금 무엇부터 해야 하는가입니다. Physical AI 도입은 기술 도입 프로젝트가 아니라 운영 혁신 프로젝트이기 때문입니다.

첫째, 현재 기술 수준에서 수행 가능한 업무를 정의해야 합니다. 모든 것을 자동화하려고 하면 실패합니다. 로봇이 들어왔을 때 작업자의 부담이 어떻게 변화하는지를 구체적으로 측정하고, 검증된 영역을 중심으로 적용 범위를 점진적으로 넓혀가야 합니다.

둘째, 작업·환경 적합성 기준으로 도입 효과를 평가해야 합니다. 현장에서는 동일한 로봇이라도 어떤 작업, 어떤 환경에 투입되는지에 따라 성과 차이가 큼니다. 따라서 로봇의 범용성보다 자사의 환경에서 반복 적용이 가능한지 여부를 기준으로 효과를 평가해야 합니다.

셋째, 운영 경험을 축적할 수 있는 도입 방식을 고려해야 합니다. RaaS 같은 운영 기반 모델을 활용하면 부담을 낮추면서 경험을 축적할 수 있습니다. 이 경험이 쌓이는 것이 더 중요합니다.

넷째, Physical AI 운영 성과를 사업 모델로 전환할 수도 있습니다. 운영 경험은 경쟁력입니다. 로봇을 어디에, 어떻게, 어떤 방식으로 투입했는지에 대한 데이터와 노하우가 자산으로 축적됩니다. 이를 활용하여 서비스형 사업 모델을 구축할 수도 있습니다.

Physical AI 시대의 Being AI




Physical AI 도입 방향 및 프레임워크

Physical AI, Being AI로의 전환

우리가 Physical AI를 이야기할 때 가장 먼저 바뀌어야 하는 것은 기술이 아니라 관점입니다. 많은 기업들이 여전히 AI를 어떤 설비에 붙일 것인가, 어떤 공정을 자동화할 것인가, 어떤 로봇을 한 대 더 넣을 것인가라는 관점으로 보고 있습니다. 이 접근은 익숙하고 실행하기도 쉽습니다. 특정 라인에 로봇을 도입하고, 특정 작업에 비전 시스템을 붙이고, 일부 공정에 최적화 알고리즘을 올리면 가시적인 결과가 바로 보이기 때문입니다. 하지만 이런 방식은 대부분 개별 포인트 솔루션에 머물게 됩니다. 공정 하나는 좋아질 수 있어도 운영 전체가 바뀌지는 않습니다. 이게 바로 Doing AI의 한계입니다.

이제는 Being AI로 넘어가야 합니다. Being AI는 AI를 도입하는 것이 아니라, 운영 자체를 AI 중심으로 다시 설계하는 접근입니다. 개별 설비나 특정 공정을 바꾸는 수준이 아니라, 물리 세계의 운영 전체를 다시 정의하는 것입니다. 생산, 설비, 품질, 물류, 안전, 자산 관리가 따로 움직이는 것이 아니라, 센서와 로봇, 설비와 데이터가 하나의 흐름 안에서 연결되고, 그 위에서 AI가 지속적으로 인지하고 판단하고 실행하는 구조를 만드는 것입니다. 즉, 사람이 시스템을 운영하는 구조에서, 시스템이 스스로 운영되도록 설계하는 방향으로 넘어가는 것입니다.

Doing AI vs Being AI



출처: PwC

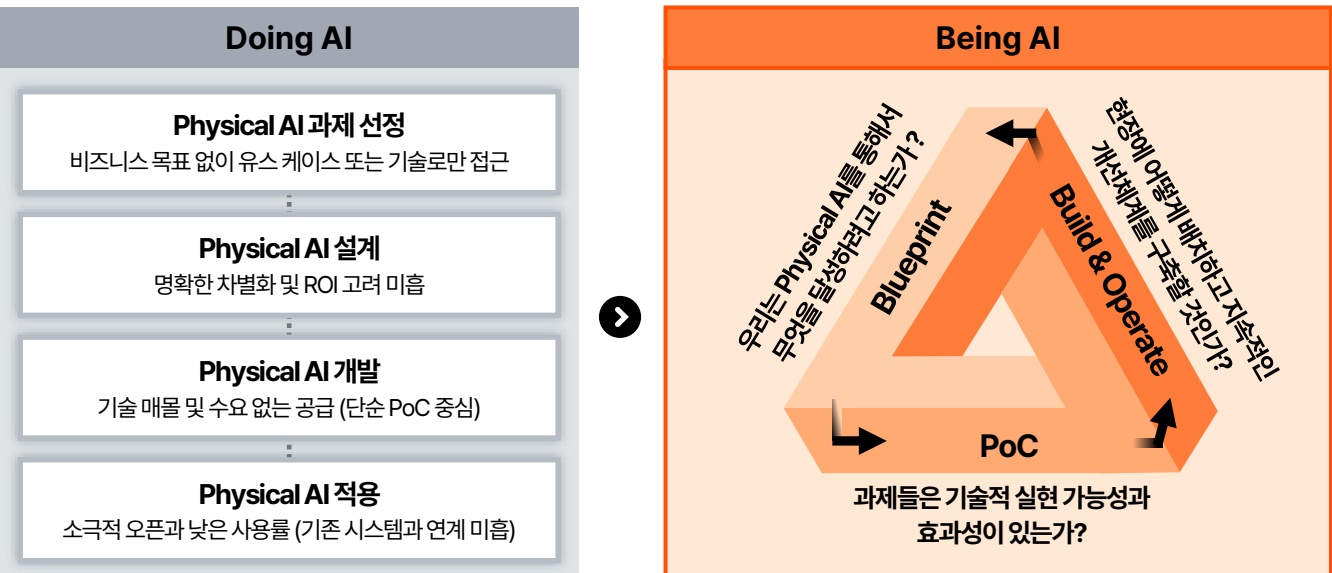
Physical AI 도입 방향

Physical AI를 실제 성과로 연결시키려면 접근 방식부터 바뀌어야 합니다. 많은 기업들이 기술 자체나 개별 유스 케이스에서 시작합니다. 새로운 로봇이 나왔으니까 적용해보자, AI 비전이 좋아졌으니 검사 공정에 붙여보자 등과 같은 식입니다. 그런데 이런 접근은 거의 대부분 동일한 패턴으로 실패합니다. 과제 선정 단계에서는 비즈니스 목표 없이 기술 중심으로 시작하고, 설계 단계에서는 ROI나 경쟁 우위를 고려하지 못합니다. 개발 단계에서는 기술적으로 가능한 것을 만드는 데 집중하다 보니 현장의 수요와 괴리가 생깁니다. 그리고 적용 단계에서는 기존 시스템과 연결되지 않아서 사용률이 떨어지고 결국 방치됩니다.

이 패턴이 반복되는 이유는 전체 흐름이 끊겨 있기 때문입니다. 과제 선정, 설계, 개발, 운영이 하나의 스토리로 연결되지 않습니다. 각각 따로 움직이다 보니, 결과는 나오더라도 운영에 자리잡지 못합니다. Physical AI에서 중요한 것은 '만드는 것'이 아니라 '계속 쓰이는 것'입니다. 이 차이를 만들기 위해서는 반드시 단계적 접근이 필요합니다.

첫 번째 단계는 블루프린트입니다. 여기서 해야 할 일은 명확한 방향 설정입니다. 어떤 문제를 해결할 것인지, 어떤 영역에서 시작할 것인지, 무엇이 비즈니스 임팩트가 있는지 정의해야 합니다. 이 단계 없이 시작하면 나중에 방향이 계속 흔들립니다. 두 번째는 PoC입니다. 여기서는 기술이 아니라 '현장에서 실제로 작동하고 효과가 있는지'를 검증합니다. 단순 테스트가 아니라, 실제 환경에서 적용했을 때의 효과를 확인해야 합니다. 세 번째는 구축 및 운영(Build & Operate)입니다. 검증된 것을 실제 운영에 붙이고, 지속적으로 확산시키는 단계입니다.

Being AI 기반의 프레임워크



출처: PwC

PwC Physical AI 블루프린트 프레임워크

Physical AI를 추진할 때는 여섯 개의 핵심 축을 동시에 봐야 합니다. 이 중 하나라도 빠지면 전체 프로젝트가 제대로 작동하지 않습니다.

첫째, 비즈니스 의사결정입니다. 가장 먼저 해야 할 질문은 '왜 하는가'입니다. Physical AI를 통해 어떤 문제를 해결할 것인지, 어떤 성과를 만들 것인지가 명확해야 합니다. 과제를 식별하고, 우선순위를 정하고, ROI를 정의하는 과정이 여기에서 이뤄집니다.

둘째, 데이터입니다. Physical AI Ready Data를 정의하고 있는지, 어떤 방법으로 해당 데이터를 수집하고 있는지를 점검해야 합니다.

셋째, 기술과 인프라입니다. 데이터를 처리하고, 모델을 운영하고, 시스템을 연결하는 인프라가 필요합니다. 특히 Physical AI는 비정형 데이터 처리, 엣지 환경까지 고려해야 합니다.

넷째, 프로세스입니다. AI를 적용한 프로세스가 어떻게 변화하는지, 사람과 로봇의 업무가 어떻게 구별되고, 연계되는지 고려해야 합니다.

다섯째, 조직과 거버넌스입니다. 조직 구조와 책임 체계가 함께 바뀌어야 합니다. 특히 AI가 개입하는 순간 책임 구조가 달라지기 때문에 관리 체계가 매우 중요해집니다.

여섯째, 조직문화와 인력입니다. 결국 사람이 바뀌지 않으면 아무것도 바뀌지 않습니다. 데이터 기반 의사결정, AI 활용, 협업 방식까지 모든 것이 바뀌어야 합니다.

PwC Physical AI 블루프린트 프레임워크

1	2	3	4	5	6
비즈니스 의사결정	데이터	기술 및 인프라	프로세스	조직 및 거버넌스	조직문화 및 인력
Physical AI를 무엇에 활용할 것인가?	적절한 데이터를 보유하고 있는가?	적절한 시스템과 툴을 갖추고 있는가?	비즈니스 프로세스는 최적화되어 있는가?	적절한 조직 구조와 거버넌스를 갖추고 있는가?	데이터 기반 문화를 어떻게 구축하고 장려할 수 있는가?
- Physical AI를 어떤 목적으로 사용하려 하는가? - 실제 적용할 과제가 식별되고, 우선 순위가 설정되고, ROI가 측정 되었는가?	- Physical AI Ready Data를 정의하고 있는가? - 어떤 방법으로 Physical AI 데이터를 수집, 생성하고 있는가?	- Physical AI를 적용 운용할 기술 구조는 정의되어 있는가? - 데이터 통합, 저장, 탐색, 전처리를 위한 기술은 무엇인가? - 비정형 데이터를 활용하기 위한 인프라는 존재 하는가?	- Physical AI가 적용되면 업무 프로세스는 어떻게 변화되는가? - 사람이 하는 업무와 로봇 (설비)이 하는 업무는 어떻게 구분되며 어떻게 연계되는가?	- Physical AI 도입 시 조직은 어떻게 구성되어야 하는가? - 규제 준수를 위한 거버넌스 구조는 존재 하는가?	- 우리 조직은 스스로 지식 기업, AI 기업으로 인식하고 있는가? - 리더십은 데이터 기반 의사결정을 하는가? - 현장직원이 인사이트 기반 Physical AI를 실행할 수 있는 권한을 부여 받았는가?

출처: PwC

① 비즈니스 의사결정

기업이 Physical AI를 도입하는 목적은 단순한 자동화가 아닙니다. 운영 모델을 바꾸고, 궁극적으로는 비즈니스 모델을 확장하기 위한 것입니다. 실제로 많은 기업들이 가까운 미래에 운영 방식이 완전히 달라질 것이라고 보고 있습니다. 이 변화의 핵심 구조는 인지, 판단, 행동입니다. 먼저 데이터를 통해 상태를 인지합니다. 센서, 카메라, GPS, 시스템 데이터가 모두 여기 들어갑니다. 그 다음 AI가 이 데이터를 기반으로 상황을 해석하고 판단을 내립니다. 마지막으로 그 판단이 행동으로 이어집니다. 이 세 단계가 끊기지 않고 연결될 때, 운영이 자동화됩니다.

제조 현장을 보면 이 흐름이 명확하게 드러납니다. 생산 데이터, 모션 데이터, 자재 데이터가 수집됩니다. 이를 기반으로 어떤 작업을 해야 하는지 판단합니다. 그리고 로봇이 실제로 자재를 이동시키고 공정을 수행합니다. 즉, 사람이 개입하지 않아도 흐름이 이어집니다. 농업에서도 동일합니다. 농기계, 센서, 기상 데이터로 농장의 상태를 파악합니다. 그 다음 구역별로 어떤 작업을 해야 하는지 AI가 판단합니다. 그리고 농기계가 자동으로 움직입니다. 이 전체가 하나의 시스템으로 돌아갑니다.

중요한 변화는 여기서 끝나지 않습니다. 이런 구조가 만들어지면 비즈니스 모델이 바뀝니다. 제품을 파는 것이 아니라, 운영 성과를 제공하는 서비스로 확장할 수 있습니다. 예를 들어, 존 디어(John Deere)는 자율 작업이 가능한 농기계를 제조할 뿐만 아니라 농업 솔루션으로 서비스화하여 구독 형식의 사업 모델을 만들어 전체 매출의 10%를 목표로 하고 있습니다. 즉, Physical AI는 생산성 개선이 아니라 가치 창출 방식 자체를 바꾸는 도구입니다.

② 데이터

Physical AI 도입 시 기업들이 가장 어려워하는 부분은 데이터입니다. 많은 기업들이 실제 적용 단계에서 데이터 관리와 확보에 어려움을 겪습니다.

중요한 것은 데이터의 양보다 신뢰성입니다. 데이터가 많아도 품질이 낮으면 아무런 의미가 없습니다. 따라서 신뢰 확보를 위한 일관된 데이터 관리체계(거버넌스)가 필수입니다. 첫째, 데이터를 어떻게 생성, 수집, 활용, 폐기할 것인지 전체 라이프사이클을 관리해야 합니다. 둘째, 데이터 오너십이 명확해야 합니다. 누가 데이터를 관리하고, 사용할 수 있는지 정의해야 합니다. 셋째, 데이터 품질도 관리하여 정확성, 완전성, 최신성을 유지해야 하고, 이를 검증하고 개선하는 프로세스가 존재해야 합니다. 넷째, 보안과 규제 대응을 강화하여 접근 권한, 암호화, 규제 준수 체계가 함께 설계되어야 합니다.

더불어, Physical AI에서는 데이터 확보가 중요합니다. 작업 동작을 세분화한 모션 토큰 디셔너리, 작업 환경을 옮겨 놓은 디지털 트윈 데이터가 있어야 하며 나아가 이러한 데이터를 지속적으로 관리할 수 있는 데이터 팩토리가 필요합니다.

③ 기술 및 인프라

Physical AI에서 많은 기업들이 기대만큼 성과를 내지 못하는 이유는 기술이 부족해서가 아니라, 복잡성이 제대로 관리되지 않기 때문입니다. Physical AI는 단일 솔루션이 아니라 수많은 레이어와 구성 요소가 결합된 시스템입니다. 이 구조를 이해하지 못하면 개별 기술은 있어도 전체는 작동하지 않습니다.

전체 아키텍처를 보면 여러 층이 동시에 돌아갑니다. 가장 위에는 사용자와 상호작용하는 경험 레이어가 있고, 그 아래에는 다중 로봇을 통합 관리하는 오케스트레이션이 있습니다. 그 다음에는 실제 물리적 실행을 담당하는 바디, 즉 액추에이터, 센서, 전력 시스템이 위치합니다. 동시에 판단을 수행하는 브레인, 즉 AI 모델과 에이전트가 작동합니다. 그리고 이 모든 것은 데이터 흐름을 통해 연결되고, 학습과 추론이 이루어지는 인프라 위에서 돌아갑니다.

여기서 중요한 것은 각 요소가 잘 동작하는가가 아닙니다. 이 요소들이 연결되어 하나의 흐름으로 작동하는가입니다. 예를 들어, 로봇 성능이 아무리 좋아도 데이터가 늦게 들어오면 판단이 늦어집니다. 데이터가 좋아도 시스템 간 연결이 안 되면 실행으로 이어지지 않습니다. 병목은 항상 '경계'에서 발생합니다. 시스템과 시스템 사이, 데이터와 실행 사이, 판단과 행동 사이에서 문제가 생깁니다.

결론적으로 Physical AI의 경쟁력은 개별 기술이 아니라 통합 설계 능력입니다. 다양한 시스템을 하나의 흐름으로 연결하고, 이 흐름을 안정적으로 운영할 수 있는 구조를 만드는 것이 핵심입니다.

적절한 시스템과 틀을 갖추고 있는가?

2nd

기술 투자가 기대한 성과를
완전히 달성하지 못한
두 번째 이유로 임원의
47%가 **통합 복잡성**을
원인으로 지목



Physical AI 아키텍처의 10대 핵심 레이어

■ 핵심 요소

경험 레이어	UI/UX	프롬프트 템플릿	대화형 에이전트	
시스템 및 커넥터	제조실행시스템	물류실행시스템	유틸리티실행시스템	
오케스트레이터	플릿 관리	이기종 로봇 통합 관제	오케스트레이션 에이전트	
바디 (물리적 구현체)	구성 부품 (액추에이터/모터)	센서-인식	전력-에너지	바디
브레인 (AI 인텔리전스)	RFM	ROS	합성 데이터	Sim-to-real
운영 데이터 흐름	데이터 수집	데이터베이스 파이프라인	데이터 스토리지	OPC UA
학습 데이터 수집	원격 조작	모션 캡처	데이터 팩토리	영상 전환
AI 인프라	온디바이스 컴퓨팅	클라우드 호스팅	클라우드 컴퓨트	모니터링·알림
보안 및 접근 제어	인증	권한 부여	디렉토리 서비스	키 관리
AI 거버넌스 (신뢰 계층)	편향 검토	코드 품질 점검	모델 모니터링	휴먼 피드백 루프

출처: PwC

④ 프로세스

Physical AI가 가장 먼저 바꾸는 것은 개별 기술이나 설비가 아니라 업무 프로세스입니다. 많은 글로벌 기업들이 향후 몇 년 내에 가장 큰 변화가 발생할 영역으로 워크플로우를 지목하고 있습니다. 이 얘기는 업무 방식 자체를 재설계 해야 한다는 의미입니다. R&D, 생산, 물류로 이어지는 밸류체인에 따라 인지, 판단, 행동이 적용됩니다.

첫째, 데이터를 통해 현장을 인지합니다. 설비 센서, 계측 장비, 물류 데이터, 생산 진행 상황, 실험 결과, 자재 위치 등 다양한 데이터가 통합됩니다. 이 단계에서는 현재 상태를 정확히 이해하는 것이 핵심입니다.

둘째, 판단입니다. 수집된 데이터를 기반으로 AI가 불량 원인을 분석하고, 공정 조건을 최적화하고, 자재 흐름을 조정합니다. 기존에는 엔지니어가 경험과 규칙을 기반으로 하던 판단이 AI로 이동합니다. 특히 복잡한 조건에서의 최적 의사결정 영역에서 AI의 역할이 커집니다.

마지막 단계는 실행입니다. 판단 결과가 실제 행동으로 이어집니다. 설비 운전 조건을 변경하고, 자재 이동을 자동으로 수행하고, 공정 라우팅을 조정합니다. 인간이 중간에서 지시하지 않아도 시스템이 스스로 실행합니다.

⑤ 조직 및 거버넌스

Physical AI가 확산되면 조직의 구조 자체가 바뀝니다. 지금까지 조직은 사람 중심으로 설계되어 있었습니다. 시스템은 도구였고, 의사결정과 실행은 사람이 담당했습니다. 하지만 이제 AI는 도구가 아니라 조직의 구성원처럼 작동하기 시작합니다.

현재 대부분의 기업은 AI 활용(AI Enabled) 단계에 있습니다. 기존 조직에 AI를 추가해서 업무를 보조하는 방식입니다. 예를 들어 특정 부서에 AI 에이전트를 붙여서 분석이나 보고서를 자동화하고, 일부 작업을 로봇으로 대체하는 수준입니다. 이 단계에서는 조직 구조 자체는 크게 변하지 않습니다.

하지만 앞으로는 AI 네이티브 조직으로 이동합니다. AI 에이전트와 Physical AI가 조직의 역할 안으로 들어옵니다. 즉, 단순 지원 역할이 아니라 하나의 '역할을 가진 구성원'으로 정의됩니다. 생산 부서에는 설비와 로봇이 실제 작업을 수행하고, AI 에이전트는 데이터 분석과 판단을 수행합니다. 사람은 이 위에서 전략과 의사결정을 담당합니다.

이때 중요한 것은 협업 구조입니다. 사람과 AI가 따로 일하는 것이 아니라 하나의 팀처럼 연동되어야 합니다. 이 변화가 의미하는 것은 명확합니다. 앞으로 조직 경쟁력은 사람 숫자가 아니라 '사람 + AI 조합'의 효율성에서 결정됩니다. AI를 잘 쓰는 기업이 아니라, AI와 함께 일하는 조직 구조를 가진 기업이 경쟁력을 갖게 됩니다.

⑥ 조직 문화 및 인력

기술이 아무리 발전해도, 최종 책임과 의사결정은 여전히 사람에게 있습니다. AI 에이전트가 일을 제안하고, 사람이 결정하고 책임을 지고, Physical AI가 실행하는 방식을 '휴먼 인 더 루프(Human in the Loop)'라고 합니다.

이 구조를 제대로 운영하기 위해서는 새로운 역량이 필요합니다. 바로 AI 리터러시입니다. 단순히 AI를 사용할 줄 아는 것이 아니라, AI의 판단을 이해하고 평가할 수 있는 능력입니다. AI가 왜 이런 결론을 냈는지, 어떤 데이터에 기반했는지, 어디까지 신뢰할 수 있는지를 판단해야 합니다.


또한 AI의 한계와 리스크도 이해해야 합니다. 확증편향, 오류 가능성, 데이터 품질 문제 같은 요소를 인지하지 못하면, 잘못된 판단을 그대로 받아들이게 됩니다. 특히 Physical AI는 실제 행동으로 이어지기 때문에 리스크 관리가 더 중요합니다.

이와 함께 중요한 것은 역할 재정의입니다. 어떤 업무는 AI에게 맡기고, 어떤 업무는 사람이 수행할 것인지 명확하게 구분해야 합니다. 이를 위해서는 업무를 구조적으로 분해하고, 각각의 역할을 재배치하는 과정이 필요합니다.

규제와 책임 구조도 함께 고려해야 합니다. 산업별로 AI 활용에 대한 규제가 다르고, 책임 주체도 명확해야 합니다. AI가 실행한 결과에 대한 책임을 누가 질 것인지 정의되어야 합니다.

결국 Physical AI 시대의 경쟁력은 기술이 아니라 사람입니다. AI를 이해하고, 활용하고, 통제할 수 있는 조직만이 이 변화를 성과로 연결할 수 있습니다.

Human in the Loop와 AI 리터러시



출처: PwC

PwC의 차별점

이러한 여섯 가지 핵심 영역에 대해 PwC는 차별화 서비스를 제공하는 조직과 경험을 보유하고 있습니다.

먼저, Physical AI의 도입 목적과 방향성을 수립하는데 있어서 PwC는 전략 전문 조직을 통해 도입의 전략적 근거와 우선순위를 명확히 할 수 있습니다. 데이터 영역에서는 AI를 위한 데이터 관리 체계를 정의하기 위해 AI 및 데이터 전문 조직과 PwC 데이터 거버넌스 프레임워크를 활용합니다. 기술 및 인프라 영역에서는 확장 가능한 아키텍처, 최적화된 모델, 인프라 확보 방안을 구체화하기 위한 파트너십 생태계를 보유하고 있습니다.

더불어, 프로세스 영역에서는 핵심 역량 확보가 가능한 영역을 정의하고 과제를 발굴합니다. 산업과 밸류체인 전문성은 현장 적용 가능한 실행 과제를 도출합니다. 이어서 조직 영역에서는 AI 가치 확산을 위한 조직 운영 방향성을 확립하는 것이 중요한데 HR 전문 조직이 이를 담당합니다. 마지막으로, 조직문화 및 인력 영역에서는 AI와 함께 일하는 문화와 가치 확산 방안을 구체화합니다.

PwC Physical AI 블루프린트 프레임워크 영역별 차별화 역량

	추진 목적	PwC Differentiator			
비즈니스 의사결정	Physical AI 도입을 통해 달성하고자 하는 목적 및 방향성 수립	PwC BMR 프레임워크 (Business Model Reinvention)	+	전략 전문 조직	+
데이터	비즈니스와 상호 작용하는 AI를 위한 데이터 관리 체계 정의	AI 및 데이터 전문 조직	+	PwC 데이터 거버넌스 프레임워크	+
기술 및 인프라	확장 가능한 Physical AI 설계 구조, 최적화된 모델 및 인프라 확보 방안 구체화	PwC 로보틱스 랩	+	Physical AI 파트너십 생태계	+
프로세스	핵심 역량 확보가 가능한 영역 정의 및 과제 발굴	산업 및 밸류체인 전문성	+	PwC 블루프린트 AI + MVP 선정	+
조직 및 거버넌스	AI 가치 확산을 위한 조직 운영 방향성 (조직구성, R&R, 성과관리) 확립	HR 전문 조직	+	AI 퍼포먼스 모니터링 툴	+
조직문화 및 인력	AI와 함께 일하는 문화 및 가치 확산 방안 구체화	AX 워크샵	+	PwC AI 리터러시 이터닝 플랫폼	+
					E2E 프로젝트 경험

출처: PwC

블루프린트 수행 사례

국내 전통 제조업 A사


A사는 인력 의존도가 높고 지방 사업장의 인력 확보가 어려워지면서 생산 방식의 지속가능성과 경쟁력 확보에 어려움을 겪고 있었습니다. PwC는 5개 사업장, 2,500여 개 액티비티를 분석해 핵심 병목과 자동화 우선순위를 도출했습니다.

분석 결과 상위 80% FTE가 집중된 액티비티에 개선 기회가 집중되어 있었으며, 수작업 의존, 부서 간 단절, 데이터 활용 부족이 주요 문제로 확인되었습니다. 이를 통해 어떤 기술을 적용할지가 아니라 어떤 업무를 어떻게 바꿀 것인지를 먼저 정의하는 것이 중요하다는 점을 확인했습니다.

이후 Physical AI 기반의 실행 방향을 설계했습니다. 공장 내 이동, 창고 이송, 자재 공급 등 물류 영역은 무인 이동과 로봇 자동화를 통해 운영 안정성과 효율성을 높이고, 포장·팔레타이징·상차 작업은 로봇 적용과 함께 실시간 품질 모니터링 체계를 구축해 사전 대응이 가능하도록 설계했습니다. 또한 물리적 자동화뿐 아니라 제어 자동화(Control Automation), AI 기반 의사결정(AI-Enabled Intelligence), 데이터 통합을 함께 추진해 운영 체계 전반의 혁신 방향을 수립했습니다.

마지막으로 과제별 비즈니스 가치를 기준으로 우선순위(Must-do, Quick-win, Strategic-build)를 구분했습니다. 예를 들어 파라미터 설정 자동화는 작업자의 수작업을 줄이고 불량 비용을 감소시켜 의미 있는 개선 효과를 창출할 수 있는 영역(Quick-win)으로 평가되었습니다. 이처럼 과제 선정은 기술 가능성보다 FTE 절감, 품질 향상, 리스크 감소 등 명확한 비즈니스 가치를 기준으로 이루어졌습니다.

A사의 과제정의 및 우선순위화 사례



출처: PwC

데모·실험을 넘어 확장 가능한 현장 검증 체계



Physical AI PoC 개념과 PwC 6단계 방법론

데모는 가능성을, PoC는 현실을 검증한다

데모는 어떤 기술이 된다는 가능성을 보여주는 것입니다. 통제된 환경에서, 가장 잘되는 조건을 맞춰 놓고, 성공하는 시나리오만 보여줍니다. 하지만 PoC는 '이게 우리 현장에서 실제로 작동하는가'를 묻습니다. 조명, 먼지, 진동, 온도, 작업자 행동, 설비 상태 같은 변수들이 존재하는 환경에서 반복적으로 동일한 성과를 낼 수 있는지를 검증하는 단계입니다.

Physical AI는 디지털 환경에서 성능을 검증하는 기존 AI와 달리 실제 설비와 운영 환경에서 안전성과 신뢰성을 동시에 입증해야 합니다. PwC는 이를 위해 대상 작업 선정부터 KPI 정의, 데이터·시뮬레이션 준비, 모델과 제어 시스템 통합, 현장 검증, 확산 가능성 평가까지 단계적으로 검증하는 PoC 프레임워크를 제안합니다. 특히 중요한 것은 각 단계별 성공 기준을 명확히 설정하고, 최종적으로 다른 공정과 사업장으로 확대 적용할 수 있는지 판단하는 것입니다.

PwC Physical AI PoC Framework

단계별 소요 기간은 산업, 작업, 노이즈에 따라 변동



출처: PwC

Step 1&2: 대상 작업 선정, PoC 합의 및 KPI 정의

PoC의 시작점은 생각보다 훨씬 중요합니다. 특히 대상 작업을 어떻게 선정하고 KPI를 어떻게 정의하느냐에 따라 PoC의 성패가 결정됩니다. 대상 작업 선정에서 업계가 공통적으로 보는 기준은 반복성, 위험도, 영상화 가능성, 데이터 가용성, 경제성입니다.

반복성이 낮으면 자동화 효과가 거의 없습니다. 데이터가 없으면 학습이 불가능합니다. 위험도가 너무 높으면 초기 적용이 어렵습니다. 영상으로 추적이 안 되면 AI 모델 자체가 작동하기 어렵습니다. 그리고 경제성이 없으면 아무리 기술이 좋아도 의미가 없습니다.

다음은 KPI 정의입니다. 여기서 가장 중요한 것은 경영진, 현장, 기술 전문가가 모두 관여해야 한다는 것입니다. 왜냐하면 PoC 결과를 실제 투자 의사결정으로 연결하려면 이 세 주체가 모두 동의해야 하기 때문입니다.

KPI도 두 가지로 나뉩니다. 결과 지표와 과정 지표입니다. 결과 지표는 장기적인 성과입니다. 예를 들어 작업 시간 15% 감소, 불량률 20% 감소, 가동률 90% 달성 같은 것들입니다. 하지만 PoC 단계에서는 데이터 수집 완료율, 예외 케이스 확보 수, 작업자 참여 수준 같은 과정 지표를 중심으로 KPI를 설정하는 것이 좋습니다.

Step 3&4: 데이터 및 시뮬레이션 준비, 모델+제어 결합

PoC에서 가장 많은 시간이 소요되는 구간이 바로 데이터와 모델, 그리고 실제 실행 시스템을 연결하는 단계입니다.

먼저 현실 데이터의 한계를 이해해야 합니다. 충돌 직전 상황, 이상 동작 같은 극단적 케이스는 현장에서 직접 확보하기 어렵습니다. 그래서 나온 것이 데이터 팩토리와 합성 데이터입니다. 시뮬레이션 70%, 실측 30%의 구조로 데이터를 구성하는 것이 현실적인 기준입니다. 디지털 트윈 기반으로 조명, 장애물 같은 환경 변수를 추가해 데이터 다양성을 확보합니다.

모델과 제어 결합 단계에서는 기존 VLA를 그대로 쓰는 것이 아니라 산업 환경에 맞는 sVLA로 재설계해야 합니다. 단순 영상 입력이 아니라 PLC·센서·작업 지시까지 통합하고, 행동 공간도 설비 제어 명령과 파라미터 기반으로 제한된 구조로 설계해야 합니다.

Step 5&6: 현장 검증, 확장 가능성 평가

이제 실제 현장 검증 단계입니다. 검증은 관찰 단계(Shadow Mode), 보조 단계(Assisted Mode), 자율 단계(Autonomous Mode)로 나뉩니다.

관찰 단계에서 로봇은 실제 작업에 개입하지 않고 작업자의 움직임, 설비 신호, 환경 데이터를 수집합니다. 보조 단계에서 로봇은 사람과 함께 작업합니다. 이 때 오류가 발생하면 즉시 사람이 개입합니다. 미끄러짐, 충돌 근접 같은 예외 케이스를 최대한 많이 확보해야 합니다. 자율 단계에서는 최소 개입 상태에서 자율 운영을 합니다. 하지만 여전히 모니터링과 기록을 지속하면서 KPI를 측정합니다. 이후는 의사결정으로서 확장, 조건부 확장, 방향 전환, 중단 등의 결정을 내립니다.

Step 5&6

5 현장 검증			6 확장 가능성 평가		
Shadow Mode Assisted Mode Autonomous Mode			[4가지 의사결정 기준 예시]		
관찰 단계 - 로봇 작동하되 실제 작업 미수행 - 작업자 동선, 설비 신호 패턴 학습 - 현장 변수 로그: 조명, 위치, 소음, 진동 - 초기 모델 추가 학습	보조 단계 - 작업자 옆 병행 작업 오류 시 즉시 개입 - 예외 케이스 수집: 이물질, 충돌 근접 - KPI 1차 측정: 작업 시간, 불량률 - 품질 점수 기반 전문가 검수	자율 단계 - 작업자 개입 최소화 자율 작동 - 감시 카메라 상시 모니터링 - 최종 KPI 측정+진행 또는 중단 데이터 - 근거 기록 완성	Go	KPI 100% 달성 5대 인프라 요건 충족	3개 추가 라인 확산
목표 KPI 현장 변수 수집률 ≥ 95%	목표 KPI 재현율 ≥ 95% 오탐 < 3%	목표 KPI 재현율 ≥ 98% 오탐 < 1% 가동률 ≥ 90% 안전 0건	Scale	KPI 80% 이상 달성, 일부 개선 확인	조건부 확산 및 보완
			Pivot	대상 작업 변경 필요, 기술은 적합하나 대상 부적합	대상 변경 후 재시도
			Kill	KPI 미달, 개선 불가, 안전 이슈 발생	프로젝트 종료

출처: PwC

Lessons Learned 및 스케일 확장

현장 사례에서 얻은 5가지 교훈

Physical AI PoC 실패의 대부분은 기술 문제가 아닙니다. 준비, 협업, 문서화의 문제입니다.

첫 번째 교훈은 KPI 없는 PoC는 반드시 데모로 끝난다는 것입니다. KPI는 나중에 추가하는 것이 아니라 시작 전에 정의해야 하며, 경영진, 현장, 기술 조직이 함께 합의해야 합니다.

두 번째는 작업자 저항입니다. 이것은 기술로 해결할 수 없습니다. 오히려 기술이 좋아질수록 반발이 커질 수 있습니다. 그래서 처음부터 작업자를 사용자가 아니라 파트너로 참여시켜야 합니다.

세 번째는 데이터 문제입니다. 완벽한 데이터를 기다리다 보면 아무것도 시작할 수 없습니다. 최소 데이터 기준을 정의하고 시작한 뒤, 운영하면서 데이터를 축적하는 방식으로 가야 합니다.

네 번째는 현장 변수입니다. 실제로 시뮬레이션과 현실의 차이는 평균적으로 30% 이상 발생합니다. 그래서 초기 단계에서 충분한 버퍼와 테스트 기간이 필요합니다.

다섯 번째는 문서화입니다. PoC가 성공해도 재현할 방법이 없으면 확장이 불가능합니다. 운영 매뉴얼, 데이터 구조, 예외 대응 방식까지 문서화해야 합니다.

결론적으로 PoC는 기술 검증이 아니라 '학습 시스템'으로 설계되어야 합니다.

PoC에서 풀 스케일로의 확장

PoC 이후 확장 단계에서 중요한 것은 게이트 구조입니다. PoC에서 바로 풀 스케일로 가지 않습니다. 반드시 단계적으로 확장해야 합니다.

PoC 단계에서 한 개 라인에 대해 제한된 범위에서 검증하여 확장 가능성을 확인하면 다음 단계는 파일럿 스케일(Pilot Scale)입니다. 2~3개 라인에서 동시에 운영하며 같은 방식으로 같은 결과가 나오는지 확인해야 합니다. 이어서 풀 스케일 단계에서는 전체 공장에 적용합니다.

확장 판단 기준은 세 가지입니다. 비용 예측성, 운영 자립도, 재현 가능성입니다. 즉, 라인당 추가 투입 비용이 추정 가능한지, 내부 팀 단독 운영이 가능한 비중은 어느 정도인지, 동일한 방법론으로 타 라인에서 재현이 가능한지를 타진해야 합니다.

제조 현장의 Physical AI 도입 전략



현장 특화 RFM 학습 방안

Physical AI의 제조현장 도입 Journey 개요

Physical AI를 제조 현장에 도입하려면 명확한 Journey를 따라가야 합니다. 이는 6단계로 구성됩니다.

첫째, 현장의 물리 대상 및 작업의 분석입니다. 공장의 구조, 설비 배치, 작업 대상, 작업자의 동선을 분석해야 합니다. 둘째, 물리 대상 및 동작 데이터 구조화로서 세부 동작 단위로 토큰화합니다. 즉, 작업이 아니라 동작 단위로 쪼개는 것입니다. 이 과정에서 어떤 동작이 기존 모델로 가능하고, 어떤 동작이 새롭게 학습되어야 하는지를 구분합니다. 세 번째는 RFM 학습과 튜닝입니다. 사전 학습된 모델을 그대로 쓰는 것이 아니라, 해당 공장의 물리 환경과 작업 동작에 맞게 파인 튜닝합니다. 네 번째는 동작 검증 및 배치입니다. 투입 전에 가상 환경에서 충돌, 간섭, 수행 가능성을 검증합니다. 다섯 번째는 통합 관제 시스템 구축입니다. 휴머노이드-휴머노이드, 혹은 휴머노이드-AMR 등 이기종 로봇들 간 협업을 위한 통합 제어 체계를 만듭니다. 마지막은 시스템 연결입니다. MES, WMS 같은 기존 생산 시스템과 로봇 시스템을 연결해서 실제 생산 흐름 안에 편입시킵니다.

Physical AI의 제조현장 도입 Journey



출처: PwC

Physical AI 4단계 레이어 모델

Physical AI를 제대로 이해하려면 먼저 이 기술이 어떤 구조 위에서 작동하는지를 봐야 합니다. 많은 경우 단일 AI 모델이나 로봇 성능만을 중심으로 이해하려고 하지만, 실제로는 Physical AI는 명확한 계층 구조 위에서 동작합니다. 이 구조를 이해하지 못하면 이후 학습 전략이나 시스템 설계가 전부 틀어지게 됩니다.

전체를 보면 Physical AI는 크게 네 개의 레이어로 나뉩니다. 가장 아래에는 월드 파운데이션 모델(World Foundation Model)이 있습니다. 이는 물리 세계에 대한 기본적인 이해를 담당합니다. 물체는 어떻게 움직이는지, 힘이 가해지면 어떤 반응이 나타나는지, 공간에서의 관계나 인과가 어떻게 작동하는지 같은 물리적 상식이 여기 들어갑니다. 이 모델이 없으면 로봇은 세상을 해석할 수 없습니다. 로봇이 행동을 하면 어떤 결과가 나올 것인지, 로봇이 물리적 힘을 가한 대상은 어떻게 바뀔 것인지를 예측할 수 있어야 하기 때문입니다.

다음은 범용 로봇 파운데이션 모델입니다. 이 레이어는 인간의 일반적인 행동 패턴을 기반으로 학습된 모델입니다. VLA 구조를 통해 주어진 상황을 이해하고, 어떤 행동을 해야 하는지를 결정합니다. 이 단계까지는 아직 산업 특화가 아니라, 인간의 다양한 일반 행동을 따라할 수 있는 기본적인 능력을 가진 상태입니다. 현재 상용화된 RFM 모델들의 수준에 해당합니다.

세 번째는 산업용 로봇 파운데이션 모델입니다. 여기서부터 실제 제조 현장과 연결되기 시작합니다. 공장 환경, 장비 조작 방법, 산업 안전 규정, 작업 순서 같은 도메인 지식이 포함됩니다. 즉, 로봇이 공장에서 일할 수 있는 수준으로 올라오는 단계입니다. 다양한 산업에서 Physical AI와 로봇이 도입되고, 해당 로봇의 작업 과정에서 추가 획득한 행동 데이터들이 축적·피드백 되면, 산업 별 모델들의 상용화 시점도 곧 올 것입니다.

마지막 최상위 레이어는 현장 물리·작업 특화 미세 조정(Fine-tuned) 모델입니다. 동일한 산업이라도 공장마다 설비, 작업 방식, 제품 특성이 다릅니다. 이 레이어에서는 특정 공장의 환경, 제품 특성 등에 맞게 모델이 다시 학습됩니다. 아무리 산업 별 모델이 상용화되고, 정교화된다고 하더라도, 이 레이어의 모델 학습 과정이 없다면, Physical AI 적용은 불가능합니다. 실제 경쟁력은 이 레이어에서 결정됩니다. 같은 로봇을 써도 공장마다 성과가 다른 이유가 바로 여기에 있습니다.

여기서 많은 기업들이 놓치는 중요한 점이 있습니다. 실제로 상당수 기업은 위에서 두 번째 레이어까지만 보고 시작합니다. 그래서 모델은 좋은데 실제 현장에서는 안 된다는 문제가 발생합니다. Physical AI의 본질은 범용성이 아니라 현장 적합성입니다. 따라서 반드시 최상위 레이어까지 설계해야 합니다.

현장·작업 특화 RFM 구성 절차

RFM을 현장에 맞게 구축하는 출발점은 사전 학습된 모델의 확보입니다. 월드 파운데이션 모델, 범용 RFM, 혹은 산업용 RFM(존재하는 경우)을 확보합니다. 그리고 해야 할 것은 현장 물리 정보 분석입니다. 공장 내 구조물, 설비 배치, 작업 대상 물체의 특성을 분석해야 합니다. 위치 정보만이 아니라, 물체의 무게 중심, 마찰 계수, 강도, 변형 특성까지 포함됩니다. 이 정보가 없으면 로봇은 동일한 작업이라도 매번 다른 결과를 낼 수 있습니다.

그 다음은 작업자 동작 분석입니다. 사람의 동작을 작업으로 보는 것이 아니라, 행동 단위로 쪼개야 합니다. 팔의 움직임, 손의 회전, 힘의 적용까지 세부적으로 분해하고 이를 토큰 단위로 정의합니다. 이게 바로 모션 토큰화(Motion Tokenization)입니다. 이렇게 정의된 동작은 모션 딕셔너리(Motion Dictionary) 상의 기존 동작들과 매칭하여 기 학습된 동작인지, 신규 학습이 필요한 동작인지 구분해야 합니다. 작업을 동작 단위로 토큰화하지 않고, 작업 단위로 모든 동작을 새로 학습하면 시간이 너무 오래 걸립니다. 재사용 가능한 동작은 최대한 활용해야 합니다.

그 다음 단계는 실제 신규 동작을 학습하는 파인 튜닝 단계로 모방학습, 강화학습 등이 사용됩니다. 특히 디지털 트윈 기반 시뮬레이션을 통한 학습 시 다양한 변수를 미리 반영하여 학습할 수 있습니다. 마지막은 검증입니다. 가상 환경에서 먼저 검증하고, 실제 현장에서 다시 검증합니다.

새로운 동작의 학습 방법

앞서 언급한 바와 같이 현장에서 새로운 동작이 필요할 때는 추가 학습이 필요하며, 이때 사용할 수 있는 학습방법으로 대표적인 세 가지가 있습니다.

첫째, 인간 동작 모방학습입니다. 사람이 직접 작업을 수행하고 그 동작을 그대로 로봇이 학습하는 방식입니다. 텔레오퍼레이션이나 모션 캡처를 활용합니다. 이 방식의 가장 큰 장점은 정확도입니다. 사람이 수행하는 작업을 그대로 학습하기 때문에 가장 현실적인 결과를 얻을 수 있습니다. 하지만 인건비와 시간이 많이 든다는 단점도 있습니다.

둘째, 영상 기반 모방학습입니다. AI가 영상을 보고 사람의 행동을 이해하고 이를 학습하는 방식입니다. 여기서는 2D 영상을 3D로 변환하는 기술이 중요합니다. 장점은 데이터 확보가 용이하면서도 학습비용이 매우 저렴하고, 단점은 정확도가 상대적으로 떨어질 수 있다는 점입니다.

셋째, 디지털 트윈 기반 합성 데이터 강화 학습입니다. 가상 환경에서 수많은 시뮬레이션을 반복하면서 최적 행동을 찾는 방식입니다. 이 방법은 대규모 데이터 생성이 가능하고, 다양한 변수를 반영할 수 있다는 장점이 있습니다. 특히 희소 시나리오나 위험 상황도 안전하게 학습할 수 있습니다.

통합 관제 시스템 구축 방안


Digital Manufacturing Simulation 기반 통합 관제 체계

기존 제조 공장은 MES, WMS, SCADA, PLC를 중심으로 설비를 제어하는 구조였습니다. 하지만 Physical AI가 현장에 투입되려면 새로운 관리 체계가 필요합니다. 기본적으로 Physical AI 환경에서는 휴머노이드와 이동형 로봇에 탑재된 RFM이 두뇌 역할을 합니다. ROS(Robot Operating System)는 이러한 RFM의 판단 결과를 토대로 실제 로봇이 구동할 수 있도록, 소프트웨어와 하드웨어를 연결하는 역할을 담당합니다.

실제 제조 현장은 다수의 이기종 로봇들이 포함될 수 있고, 서로 다른 역할을 하면서도 유기적으로 협업할 수 있도록 시뮬레이션을 통한 충돌, 병목, 간섭 위험을 사전에 검증해야 합니다. 이 역할을 수행하는 계층이 POA(Physical AI Orchestration Agent)입니다. POA는 MES의 작업 지시를 디지털 명령으로 변환하고, 여러 로봇이 수행할 협업 시나리오를 생성하며, 이를 바탕으로 개별 로봇들이 수행할 작업과 동작을 결정한 후, 최종 실행 명령을 생성합니다.

제조 현장은 제품 사양이 변경되고 작업 방식이 바뀌며 예외 상황이 발생합니다. Physical AI는 학습된 환경을 벗어나면 상당 수준의 추가 학습이 필요합니다. 결국 제조 공정 전체를 디지털 환경에서 먼저 계획·검증하는 디지털 제조 시뮬레이션(Digital Manufacturing Simulation)이 중요합니다. 작업이 MES로 전달되기 전에 공정 흐름, 설비 운용, 로봇 협업 방식, 작업 순서 등을 가상 환경에서 먼저 검증하고 최적화함으로써 실제 생산 과정의 시행착오를 최소화할 수 있습니다.

제조 현장 IT·OT 아키텍처



출처: PwC

제언

우리는 무엇을 준비해야 하는가?

향후 2~3년 내 휴머노이드가 기술적으로 완성되는 시점이면, Physical AI 시대가 본격적으로 도래할 것입니다. 이러한 가능성을 전제로 제조 공장을 휴머노이드와 로봇이 함께 일하는 공간으로 빠르게 전환하기 위해서는 지금부터 두 가지를 준비해야 합니다.

첫째, Physical AI Ready 데이터를 확보하는 것입니다. 현장의 작업들을 모션 단위로 구성한 토큰 디렉터리와, 현장의 물리 정보가 이에 해당합니다. 향후 로봇으로 대체할 작업에 대해 SOP를 정비하고, 이를 동작 단위로 더 세분화해야 합니다. 예를 들어 '고정 볼트 제거'라는 작업 하나도 드라이버를 잡는 동작, 위치를 맞추는 동작, 손목을 회전하는 동작, 볼트를 뽑아내는 동작 등으로 쪼갤 수 있어야 합니다.

여기에 물리 정보도 결합해야 합니다. 부품별로 필요한 토크, 악력, 저항, 변형 가능성 같은 물리 파라미터가 함께 DB화 되어야 합니다. 그래야 로봇이 어떻게 움직여야 하는지뿐 아니라 얼마나 힘을 줘야 하는지까지 판단할 수 있습니다. 결국 모션 토큰 디렉터리가 동작의 언어라면, 물리정보 DB는 그 언어를 현실에서 실행 가능한 수준으로 만드는 감각 데이터라고 볼 수 있습니다.

둘째, 디지털 트윈 체계 구축입니다. 신규 학습이 필요할 때는 Sim-to-real 기반 강화학습을 통해 가상환경에서 빠르게 적응합니다. 이후 실제 현장에서 수집된 작업 데이터와 물리 정보를 디지털 트윈에 지속적으로 반영(Real-to-sim)함으로써 가상환경을 현실과 동기화해야 합니다. 이를 통해 학습된 RFM의 동작을 반복적으로 검증하고 고도화할 수 있습니다. 다시 말해, 현실이 학습과 개선의 출발점이 되고, 가상이 실험과 검증, 확장의 기반이 되는 구조입니다. 이러한 이중 루프가 구축되어야 제품 변경, 작업 변경, 예외 상황에도 빠르게 대응할 수 있습니다.

Physical AI는 준비과정 없이 바로 도입할 수는 없습니다. 현장의 데이터를 구조화하고, 디지털 트윈 기반 검증 체계를 만들어가야 하는 여정을 지금부터 시작해야 합니다. 이를 먼저 해 놓은 기업일수록, 향후 Physical AI 도입이 본격화되는 시점이 오면, 도입 속도와 이에 따른 생산성 측면에서 커다란 격차를 만들어 낼 것입니다.

Physical AI Ready Data



기업이 준비해야 할 데이터

AI Ready Data 요구사항 변화

AI가 발전할수록 데이터에 요구되는 조건도 달라져 왔습니다. 전통적인 머신러닝과 딥러닝에서는 정형화된 표와 수치 데이터가 중심이었으며, 통계적 정확성과 스키마 관리가 데이터 품질의 핵심이었습니다. 생성형 AI 시대에는 문서, 이미지, 음성 등 비정형 데이터가 중요해지면서 의미 정확성, 최신성, 개인정보 보호와 환각 방지가 중요했습니다. 에이전틱 AI는 더 나아가 업무 맥락과 지식, 도구 접근 권한, 실시간 상태 정보까지 요구하고 있습니다.

Physical AI 데이터는 이보다 복잡합니다. 로봇은 답변을 생성하는 데 그치지 않고 물리세계에서 직접 움직이기 때문입니다. 따라서 3차원 공간정보, 시간에 따라 변하는 센서값, 관절 상태, 물체와 로봇의 좌표, 힘과 토크 등이 포함되어야 합니다. 데이터 품질도 정확성을 넘어 실제 환경에서 행동으로 실현할 수 있는 물리적 정확성과 재현성으로 평가되어야 합니다.

결국 Physical AI의 Ready Data는 로봇이 어떤 환경에서 어떤 행동을 할 수 있는지, 어디까지가 안전한 범위인지, 예외 상황에서는 어떻게 중단 또는 복구해야 하는지까지 설명할 수 있어야 합니다. AI Ready Data가 '모델 활용 가능한 단순 정보'에서 '안전한 물리 실행 가능한 행동 데이터'로 확장되고 있는 것입니다.

AI 유형별 Data Readiness 요구사항

AI 패러다임의 진화		ML-DL Structured Data	Gen AI-LLM Unstructured Data	Agentic AI Knowledge Data	Physical AI Physical Data
Physical AI 물리 행동 실행 에이전틱 AI 업무 실행 생성형 AI 콘텐츠 생성 머신러닝, 딥러닝 AI 분류, 예측, 판단 데이터 형식, 저장, 품질, 거버넌스가 물리 세계 기준으로 재정의	데이터 형태	• 정형, 표형 중심	• 비정형, 텍스트, 문서	• 멀티 모달, 업무 맥락	• 3D/시계열, 센서, 좌표
	핵심 인프라	• 특징 저장소 (Feature Store)	• 벡터 DB, RAG 파이프라인	• 지식 그래프, 도구 API	• 시뮬레이션, 디지털 트윈
	품질 기준	• 통계적 정확성	• 의미 정확성, 최신성	• 실시간 일관성, 신뢰성	• 물리 정확성, 재현성
	거버넌스	• 데이터 스키마, 데이터 계보	• PII 필터, 환각 방지	• 권한 기반 톨 접근	• 안전성, ODD, Sim-to-real • 안전 필수 인증-규제 준수
저장-운영		• 레이크하우스, 특징 저장소	• 객체 저장소, 벡터 DB	• KG DB, Tool 등록소, 메모리 저장소	• 시계열 데이터 • 로봇틱스 플랫폼

출처: PwC

에이전틱 AI 대비 Physical AI 특징과 정의

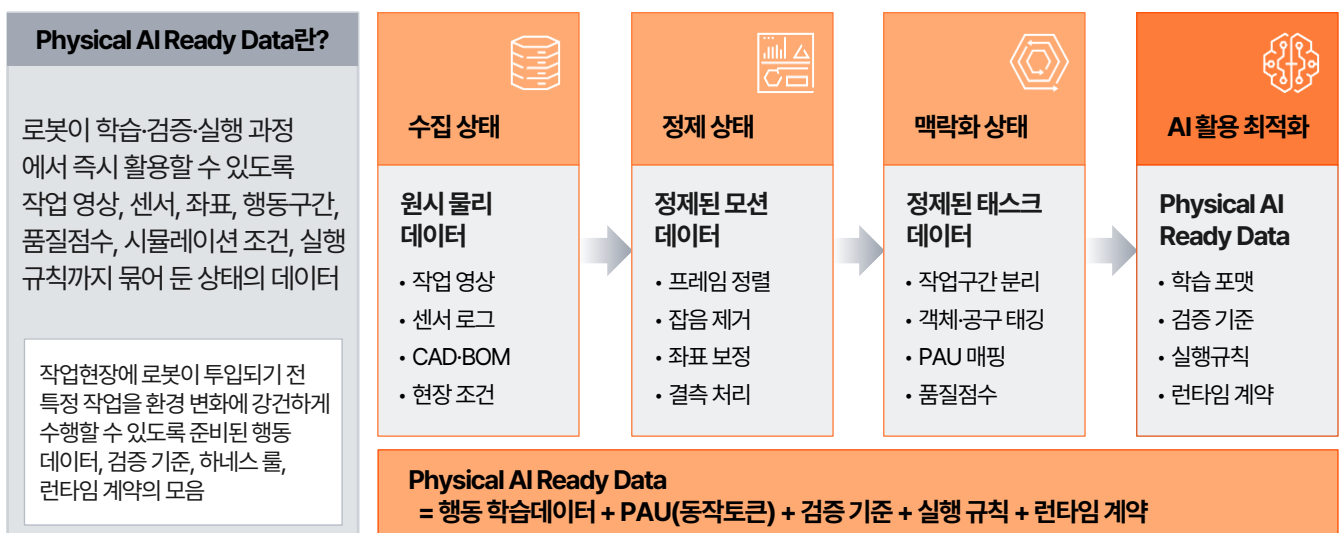
Physical AI의 구조는 에이전틱 AI와 비교하면 쉽게 이해할 수 있습니다. 에이전틱 AI는 업무 데이터와 도구 사용 데이터를 기반으로 GPT 같은 언어모델을 학습하거나 보완합니다. 이후 LangChain이나 LangGraph 같은 오케스트레이션 계층을 통해 API, 데이터베이스, 브라우저 등의 디지털 도구를 사용하며, 실행 결과는 LangSmith나 Langfuse와 같은 운영도구에서 추적·평가됩니다.

Physical AI도 기본 구조는 유사합니다. 업무 데이터 대신 작업 영상과 센서 데이터가 사용되고, 이를 LeRobot과 같은 표준 데이터셋으로 변환해 RFM 또는 VLA 모델을 학습합니다. 학습된 모델의 출력은 ROS 2, MoveIt, Nav2 등의 실행계층으로 전달되고, 로봇팔, 그리퍼, 카메라, PLC와 같은 물리적 장치를 움직이게 합니다. 운영 과정에서는 RMS와 TrustOps가 실행상태, 장애, 안전 이벤트와 재학습 후보를 관리합니다.

차이는 실행 대상에 있습니다. 에이전틱 AI는 API 호출에 실패하면 오류 메시지를 남기고 다시 시도할 수 있지만, Physical 에이전트의 오류는 충돌, 제품 손상, 생산 중단 또는 작업자 안전사고로 이어질 수 있습니다. 따라서 Physical AI에서는 모델 성능뿐 아니라 실행 전 검증, 안전 한계값, 승인과 중단 조건, 운영 로그가 하나의 체계로 연결되어야 합니다. 업무 데이터로 GPT를 길들여 디지털 도구를 사용하게 하는 것이 에이전틱 AI라면, 작업 데이터로 RFM을 길들여 물리적 장치를 안전하게 사용하게 하는 것이 Physical AI입니다.

Physical AI Ready Data는 로봇의 학습, 시뮬레이션, 검증, 의미, 맥락, 품질, 신뢰성과 물리적 제약이 보장된 데이터 패키지입니다. 그저 작업 영상을 많이 저장하거나 센서 로그를 축적한 상태만으로는 Ready Data라고 할 수 없습니다. 영상과 센서 정보가 로봇이 이해하고 학습할 수 있는 좌표, 행동, 상태의 구조로 변환되어야 합니다.

Physical AI Ready Data 정의



출처: PwC


Ready Data 체계 구축 방법

Physical AI 도입은 로봇 구매나 모델 선정에서 시작해서는 안 됩니다. 우선 기업이 보유한 작업 가운데 어떤 작업을 데이터로 전환할 수 있고 반복적으로 확장할 수 있는지를 판단해야 합니다. 사람의 손동작, 사용하는 공구, 대상 부품과 지그, 작업환경을 분석하여 촬영, 좌표화, 센서화가 가능한 작업을 식별하는 것이 첫 단계입니다. 동시에 작업의 복잡도와 위험도, 성공과 실패의 판단 기준도 정의해야 합니다.

다음으로 Ready Data 전략과 데이터 아키텍처를 설계합니다. 작업 영상, 센서, 3차원 좌표정보를 어떤 방식으로 수집하고 저장할지, LeRobot 데이터셋과 모델 학습환경을 어떻게 연결할지, PAU와 품질점수를 어떤 기준으로 관리할지를 결정해야 합니다. 이후 제품이나 공구가 변경되었을 때 디지털 트윈과 규칙 엔진을 통해 필요한 부분만 재검증하고 재학습할 수 있도록 확장 구조를 마련해야 합니다.

마지막 단계는 실제 유스 케이스를 활용한 파일럿입니다. 1차 Ready Data를 생성하고 품질을 검토한 뒤, PAU 라이브러리와 시나리오 라이브러리를 구성합니다. 디지털 트윈에서 실패조건과 한계값을 시험하고, 그 결과를 하네스 룰과 런타임 계약으로 전환해 실제 실행 가능성을 검증해야 합니다. 중요한 것은 데이터를 먼저 수집한 후 정비하는 방식이 아니라, AI 학습과 로봇 실행을 전제로 처음부터 데이터 구조를 설계하는 것입니다. 질문의 출발점도 '어떤 로봇을 살 것인가'가 아니라 '어떤 작업을 데이터화해 반복적으로 확장할 것인가'가 되어야 합니다.

Physical AI Ready Data Design



출처: PwC

기본 및 확장 Ready Data 수집

기본 Ready Data 수집

기본 Ready Data의 목적은 사람의 작업을 단순히 기록하는 것이 아니라 로봇이 동일한 행동을 학습하고 재현할 수 있는 기준 행동 데이터를 만드는 데 있습니다. 최초 작업을 위한 기본 Ready Data는 실제 작업 영상과 센서 데이터를 기준으로 생성합니다. 먼저 정면과 측면, 손목 카메라 등 여러 시점에서 작업을 촬영하고, 필요한 경우 RGB-D 영상과 힘, 토크, 설비 센서 로그도 시간축에 맞춰 동기화해야 합니다. 단일 시점의 영상만으로는 물체의 깊이와 가림, 손과 공구의 정확한 위치를 판단하기 어렵기 때문에 작업 특성에 따라 적절한 촬영 구조를 설계해야 합니다. 그리고 이 비디오 기반 모방학습 이외에도 다양한 행동 데이터 수집 방법이 있기 때문에 작업 환경, 조건, 유형에 따라 결정하면 됩니다.

다음으로 사람의 손과 팔 관절, 대상 물체, 공구와 지그의 위치를 추출하고 행동 이동 좌표를 추출합니다. 연속된 작업은 접근, 집기, 이동, 정렬, 삽입, 체결, 검사와 같은 행동구간으로 분리됩니다. 이 행동구간은 이후 PAU 후보가 되며, 다른 제품이나 작업에 재사용할 수 있는 기본 단위를 형성합니다. 각 데이터에는 가림, 영상 흔들림, 좌표 안정성, 성공·실패 여부, 반복성과 라벨 신뢰도를 반영한 품질점수를 부여합니다. 품질이 기준에 미달하는 데이터는 보정하거나 재촬영해야 합니다. 최종적으로 영상, 프레임, 관절정보, 행동구간, 품질점수와 메타데이터를 LeRobot 호환 포맷으로 패키징합니다.

기본 Ready Data 생성 흐름



출처: PwC

확장 Ready Data가 필요한 이유

제조 현장에서는 신제품이나 파생모델이 출시되어도 공정의 큰 흐름은 유지되는 경우가 많습니다. 그러나 로봇에게는 대상 부품의 형상, 홀의 위치, 무게, 재질, 표면 반사, 공차와 체결 토크가 달라져도 이전과 같은 작업으로 인식되지 않습니다. 변경된 조건을 반영해 행동을 다시 검증하고 필요한 부분을 재학습해야 합니다.

문제는 신제품이 실제로 생산되기 전에는 충분한 작업 영상이나 실패 로그를 확보할 수 없다는 점입니다. 생산이 시작된 후 실제 라인에서 시행착오를 반복하는 것도 어렵습니다. 로봇의 오류는 제품 손상과 설비 정지, 품질문제와 안전사고로 이어질 수 있기 때문입니다. 기본 Ready Data 만으로는 아직 존재하지 않는 제품, 다양한 옵션과 예외상황에 대응하기 어렵습니다. 그리고 유사 제품군을 생산할 때도 동일 공정내 부품의 변화가 있습니다. 이밖에 조명, 속도 등 환경의 변화도 무시할 수 없습니다. 이러한 변화 속에서도 작업을 문제없이 수행하기 위해 반드시 학습이 필요합니다. 실제 작업을 촬영한 것으로 학습한다면 시간과 비용 등이 막대하게 소요될 수 있습니다.

그래서 이 데이터 공백을 해결하기 위해 환경변화, CAD, BOM 공차와 소재 정보를 디지털 트윈에 반영하여 가상환경에서 부품 위치와 재질, 조명, 센서, 힘과 토크 조건을 변화시키며 실패 상황을 생성하고, 추가 학습데이터와 실행 한계값을 도출합니다. 여기에서 변경 학습데이터, 하네스 룰, 런타임 계약으로 구성된 확장 Ready Data가 만들어집니다.

PAU, 재사용 가능한 로봇 행동의 최소 단위

PAU(Physical Action Unit)는 로봇이 수행할 수 있는 최소 물리 행동 단위를 의미합니다. 행동토큰, 행동구간으로도 표현될 수 있습니다. 전체 작업을 하나의 긴 동작으로 관리하면 제품이나 공구가 조금만 변경되어도 전체 데이터를 다시 수집하고 학습해야 합니다. 반면 작업을 접근, 집기, 이동, 정렬, 삽입, 체결, 검사, 회피와 같은 최소 행동 단위로 나누면 변경된 부분만 선택적으로 보정하거나 재학습할 수 있습니다.

PAU 안에는 관절과 좌표, 궤적, 센서정보와 같은 행동 데이터가 포함되고, 속도, 힘, 토크, 공차 등의 파라미터가 함께 관리됩니다. 어떤 물체와 환경에서 행동이 가능한지, 어떤 조건에서는 실행을 금지해야 하는지에 대한 정책과 제약도 포함됩니다. 성공과 실패를 구분하는 검증 기준, 중지, 재정렬, 승인과 같은 실행규칙, 로그와 감사-재현 정보까지 포함될 수 있습니다.

이처럼 PAU를 데이터와 정책, 검증, 실행을 결합한 행동 자산으로 관리하면 최초로 수집한 작업 데이터가 일회성 학습자료에 머물지 않습니다. 제품이 변경되어도 동일한 접근이나 공구 집기 PAU를 재사용하고, 변경된 정렬이나 체결 PAU만 추가 검증하면 됩니다. PAU 라이브러리는 Physical AI의 행동을 축적하고 조합하는 기업의 핵심 지식자산이며, 확장 Ready Data를 구현하기 위한 기본 단위라 할 수 있습니다.

변경에 대응하는 확장 Ready Data 수집 방법

확장 Ready Data는 모든 제품 변경 때마다 전체 작업을 새로 촬영하는 방식으로 만들지 않습니다. 기본 Ready Data의 PAU로 분해하고, 제품, 부품, 지그, 공차, 센서, 조명 등의 변경조건을 입력한 뒤 PAU별 영향도를 판단합니다. 영향도에 따라 기존 PAU를 그대로 재사용하거나 파라미터를 보정하고, 필요한 구간만 추가 데이터를 생성하거나 재학습합니다.

작업 위치나 공차가 소폭 변경된 경우에는 기존 PAU가 대부분 유효합니다. 파지점과 목표 좌표, 힘과 속도 같은 파라미터만 조정하고 디지털 트윈에서 검증할 수 있습니다. 부품의 형상이나 재질, 반사특성이 달라진 경우에는 인식이나 집기 구간의 추가 데이터가 필요할 수 있습니다. 작업 순서나 공구가 변경되면 기존 PAU를 새롭게 조합하고 일부 정책을 재학습합니다. 작업 원리 자체가 바뀌는 경우에만 신규 Ready Data를 생성하면 됩니다.

예를 들어 알루미늄 모터 제어박스가 플라스틱 센서 제어박스로 변경되더라도 하우징 인식, 커버 집기, 정렬, 드라이버 집기, 체결, 검사라는 전체 흐름은 유사할 수 있습니다. 이때 변경된 형상과 재질, 홀 위치, 토크 기준에 영향을 받는 PAU만 선별합니다. 확장의 핵심은 모든 행동을 다시 수집하는 것이 아니라 무엇을 재사용하고 어느 부분만 다시 만들 것인지를 판단하는 데 있습니다.

확장 Ready Data 생성도구로서의 디지털 트윈

Physical AI 관점에서 디지털 트윈은 제품과 작업조건의 변화를 실제 로봇에 적용하기 전에 먼저 실패 시켜 보고, 실패의 경계와 실행 한계값을 찾는 Ready Data 생성도구입니다. 아이작 Sim, MuJoCo 등의 시뮬레이션 환경에서는 부품의 위치를 조금씩 이동시키거나 정렬오차와 마찰계수를 변경하고, 힘과 토크를 단계적으로 증가시키면서 성공과 실패의 경계를 탐색할 수 있습니다. 또한 사람이 작업공간에 접근하거나 센서의 인식 신뢰도가 낮아지는 상황도 반복적으로 시험할 수 있습니다.

이 과정에서 정렬 허용범위, 토크 한계, 사람과 로봇 사이의 안전거리와 같은 안전 경계가 도출될 수 있습니다. 발견된 조건은 감속, 정지, 재시도, 사람 이양 등의 하네스 룰로 전환되고, 실행 허용조건과 금지조건, 모니터링 방식을 포함한 런타임 계약으로 패키징됩니다. 디지털 트윈의 핵심 가치는 현실을 복제하는 데 있는 것이 아니라 새로운 작업의 실패조건을 선제적으로 발견하고 안전한 실행규칙을 생성하는 데 있습니다.

참고로 하네스 룰은 모델이 제안한 행동을 그대로 수행하지 않고, 안전, 품질, 권한 기준에 따라 실행을 제한하는 통제규칙입니다. 예를 들어 커버의 정렬오차를 1mm, 2mm, 3mm로 증가시키며 체결을 시험한 결과 2mm 이상에서 나사산 손상이 증가한다면, 1mm 초과 시 재정렬하고 2mm 이상에서는 체결을 금지하는 규칙을 만들 수 있습니다. 즉, 하네스 룰은 시뮬레이션에서 발견된 물리적 한계를 실제 현장의 실행 통제로 전환하는 연결고리라 할 수 있고, 이를 통해 제조현장에서 로봇이 실패 없이 작업이 가능하도록 관리할 수 있습니다.

제언


무엇을 준비해야 할 것인가?

Physical AI 경쟁력은 최신 휴머노이드나 고성능 로봇을 얼마나 많이 보유했는지로 결정되지 않습니다. 로봇이 수행해야 할 작업을 학습·검증·실행 가능한 Ready Data로 반복 전환할 수 있는 운영체계를 보유했는지가 더 중요합니다. 동일한 로봇과 모델을 사용하더라도 기업의 공정, 제품, 품질기준, 안전조건을 데이터와 규칙으로 축적한 기업이 더 빠르고 안정적으로 적용범위를 확대할 수 있습니다.

준비는 기본 Ready Data에서 시작합니다. 실제 작업을 기준 행동 데이터로 만들고, 이를 재사용 가능한 PAU 라이브러리로 자산화해야 합니다. 이후 제품과 작업환경의 변경조건을 디지털 트윈에서 선검증하여 필요한 추가 학습데이터를 생성하고, 발견된 실행 한계값을 하네스 룰로 전환합니다. 마지막으로 승인, 중단, 재시도, 모니터링과 복구조건을 런타임 계약에 담아 운영 통제체계를 완성합니다.

따라서 기업은 우선 Ready Data 구축 대상 작업을 선정하고 1차 데이터를 만들어야 합니다. 이후 PAU와 시나리오 라이브러리를 축적하면서 디지털 트윈 기반의 변경 대응체계를 확장하고, 최종적으로 런타임 거버넌스까지 연결해야 합니다. 로봇 도입의 핵심은 로봇을 구매하는 것이 아니라 로봇이 실패하지 않고 작업할 수 있도록 학습·검증·실행 데이터를 미리 준비하는 능력입니다. Physical AI 시대의 지속 가능한 경쟁우위는 Ready Data를 End-to-End로 생성하고 검증하며 운영할 수 있는 기업 역량이 핵심입니다.

기본 Ready Data와 확장 Ready Data의 결합



출처: PwC

PwC Physical AI & Robotics Center 소개

Physical AI 시대는 새로운 기술을 도입하는 문제를 넘어, 기업 운영 방식 자체를 근본적으로 재정의하는 단계로 진입하고 있습니다. 이러한 전환 환경에서 PwC는 전략 수립부터 실제 현장 적용, 그리고 운영 내재화까지 전 과정을 통합적으로 지원할 수 있는 역량을 갖춘 조직으로 Physical AI & Robotics Center를 운영하고 있습니다.

PwC의 강점은 기술 이해에 머물지 않는다는 점입니다. 스마트팩토리, 자동화 설비, 제조 운영, 제조 AI 등 다양한 분야의 전문가로 구성된 약 100명의 인력을 보유하고 있으며, 제조사의 디지털 전환과 공정 혁신 과정에서 AI와 로봇틱스를 적용하고 성과를 만들어낸 경험을 갖춘 실행 조직이라는 점에서 의미가 있습니다.

또한 PwC는 단독으로 기술을 개발하거나 적용하는 방식이 아니라, 글로벌 및 국내 유수의 RFM 개발사, 시스템 통합(SI) 기업들과의 파트너십을 기반으로 생태계를 구성하고 있습니다. 이러한 생태계 기반 접근은 Physical AI가 하드웨어, 소프트웨어, 모델, 데이터, 운영 시스템이 함께 결합되는 복합 영역이라는 점을 고려한 전략입니다.

PwC의 또 하나의 경쟁력은 서비스 모델의 완결성에 있습니다. Physical AI 도입은 전략 수립, 대상 작업 선정, RFM 설계 및 학습, PoC 검증, 실제 공정 적용, 운영 및 유지보수까지 이어지는 긴 여정을 필요로 합니다. PwC는 블루프린트 컨설팅 단계에서부터 시작하여, PoC를 통한 기술 및 비즈니스 검증, 구축 단계에서의 현장 적용 및 시스템 통합, 그리고 오퍼레이션 단계에서의 지속 운영 및 고도화까지 전 단계를 포괄하는 서비스를 제공합니다.



이러한 통합적 접근은 Physical AI를 기업 전환 프로젝트로 이해하고 있다는 점에 기인합니다. 결국 Physical AI는 실제 현장에서 반복 가능하게 적용하고 확산시킬 수 있는 기업만이 성과를 낼 수 있는 영역입니다. PwC는 전략, 기술, 데이터, 운영을 통합한 실행 체계를 확보하고 있으며, 이를 통해 고객사가 새로운 운영 모델과 경쟁력을 확보할 수 있도록 지원하고 있습니다. 이런 점에서 PwC는 Physical AI 시대에서 기업의 전환을 실질적으로 이끌 수 있는 준비된 파트너라고 할 수 있습니다.

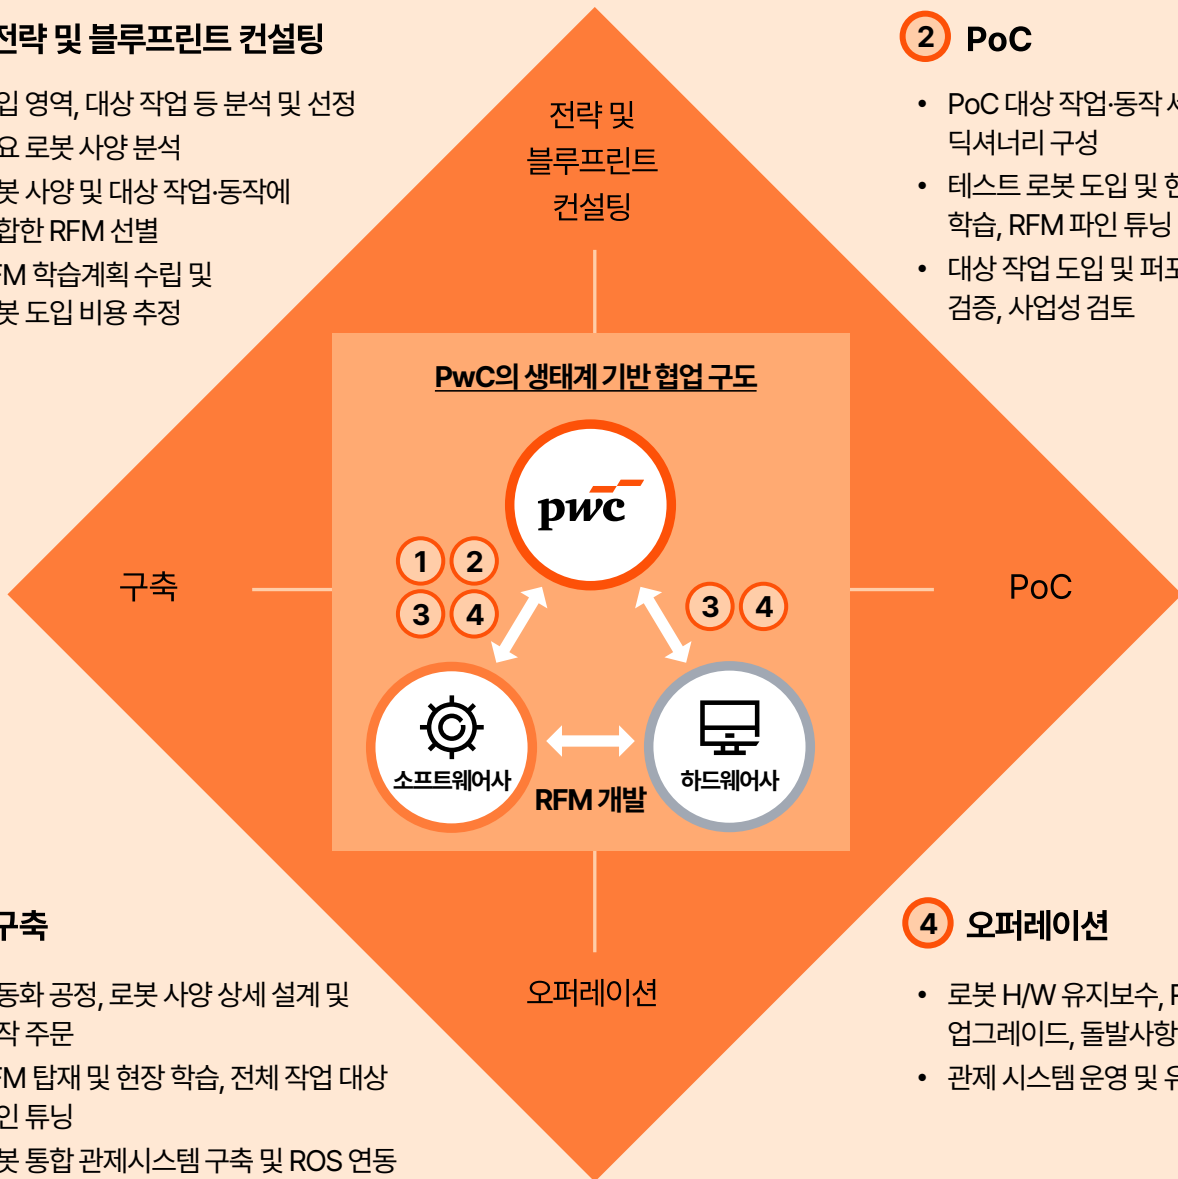
Physical AI & Physical AI & Robotics Center 서비스 모델

① 전략 및 블루프린트 컨설팅

- 도입 영역, 대상 작업 등 분석 및 선정
- 필요 로봇 사양 분석
- 로봇 사양 및 대상 작업·동작에 적합한 RFM 선별
- RFM 학습계획 수립 및 로봇 도입 비용 추정

② PoC

- PoC 대상 작업·동작 세부 디렉터리 구성
- 테스트 로봇 도입 및 현장 학습, RFM 파인 튜닝
- 대상 작업 도입 및 퍼포먼스 검증, 사업성 검토



출처: PwC

Contacts

문 홍 기 Partner

hong-ki.moon@pwc.com
02-709-0394

김 범 수 Partner

bumsu.b.kim@pwc.com
02-3440-2163

신 민 용 Partner

min-yong.shin@pwc.com
02-3781-9154

성 윤 호 Partner

yun-ho.sung@pwc.com
02-3781-9879

김 선 호 Partner

sunho1.kim@pwc.com
02-3781-9393

김 정 연 Partner

jungyoun.k.kim@pwc.com
02-709-2295



S/N: 2607C-RP-098

© 2026 PwC Consulting. All rights reserved. PwC refers to the PwC network and/or one or more of its member firms, each of which is a separate legal entity. Please see www.pwc.com/structure for further details.

Disclaimer: This content is for general purposes only, and should not be used as a substitute for consultation with professional advisors.