

외부 Vive Tracker 기반 TPU 유연 링크 매니플레이터의 안정화 위치 예측 성능 및 관절공간 적용 범위 진단

Settled-Position Prediction and Joint-Space Applicability Diagnosis of a TPU Flexible-Link Manipulator Using an External Vive Tracker

김기현, 구미선, 최현규, 황수민

김광기

(Kihyun Kim, Miseon Ku, Hyunkyu Choi, Sumin Hwang and
Kwangki Kim)

Abstract: This article presents a tracker-referenced settled-position prediction pipeline for an SO-101-based manipulator with a single TPU 95A flexible link. The hardware evaluation is limited to a single-flexible-link configuration in which the shoulder-to-elbow link is replaced by a 300 mm TPU 95A link, and the settled end-effector position is measured using an external Vive Tracker. The learning problem is formulated as supervised prediction from commanded joint states, measured joint states, and target-position features to the tracker-measured settled reference position. Using 584 valid hardware samples and 50 repeated random-split evaluations, the density-aware local kernel ridge regression model achieved a mean 3D prediction error of 2.0135 mm, a median error of 1.5656 mm, a p95 error of 5.0003 mm, pass@2mm of 62.68%, and pass@2.5mm of 73.80%. These results show low-millimeter mean prediction accuracy within the collected single-link data distribution, while also indicating that sub-2-mm accuracy is not guaranteed for all samples. In addition, joint-space block holdout tests showed increased errors in unseen joint-space regions, suggesting that random-split interpolation performance should not be interpreted as unrestricted joint-space generalization. A dual-flexible-link configuration with $L_1 = 300$ mm and $L_2 = 180$ mm was further examined only as a synthetic-data-based extension for checking preprocessing, coordinate alignment, feature construction, and model-selection procedures. In this synthetic extension, the same pipeline achieved a mean 3D prediction error of 0.7101 mm and pass@2mm of 96.00%; however, these values should not be interpreted as hardware-validated dual-link performance. The contribution of this work is a measurement-based single-link dataset, a tracker-referenced settled-position prediction procedure, and an explicit distinction between random-split interpolation performance, joint-space applicability limits, and synthetic extension analysis.

Keywords: Flexible-link manipulator, SO-101, Tracker-referenced position prediction, Kernel ridge regression, Position residual, Out-of-distribution diagnosis

1. 서론

로봇 매니플레이터의 엔드이펙터 위치 계산과 명령 생성 문제에서는 일반적으로 강체 링크 기반 순기구학(forward kinematics, FK)과 역기구학(inverse kinematics, IK)을 사용한다. 강체 기구학 모델은 링크 길이, 관절축, 기준 좌표계 사이의 변환이 운동 중 일정하다고 가정하며, 이러한 가정 아래에서 관절각과 엔드이펙터 위치 사이의 관계를 계산한다. 이 접근은 금속 또는 고강성 링크를 사용하는 매니플레이터에서는 효과적이지만, 링크가 유연 소재로 제작되면 강체 링크 가정만으로는 외부 기준 측정 위치와의 차이를 충분히 설명하기 어렵다.

유연 링크는 위치 정확도 측면에서는 불리한 요소로 작용할 수 있지만, 경량화, 충격 완화, 구조적 안전성 측면에서는 장점을 가진다. 특히 망치질, 부품 탈거, 표면 타격 검사와 같이 짧은 시간 동안 큰

동적 상호작용이 발생하는 산업 현장 작업으로 확장하려면, 타격 성능을 논의하기에 앞서 타격 직전 또는 정착 상태에서의 말단 위치를 예측하고 적용 가능한 관절공간 범위를 진단하는 절차가 선행되어야 한다. 본 연구는 이러한 동적 작업 자체를 검증하는 것이 아니라, 그 선행 단계로서 SO-101 기반 TPU 유연 링크 매니플레이터의 외부 기준 위치 측정 데이터셋과 위치 예측 평가 절차를 제시한다.

유연 소재 링크를 포함한 시스템에서는 중력 방향 처짐, 비선형 탄성 변형, 관절 유격, 구동 오차, 장착 오프셋, 좌표계 정합 오차가 복합적으로 나타난다. 본 연구에서 정의하는 위치 잔차는 TPU 유연 링크의 비선형 탄성 변형을 비롯하여 관절 유격, 구동 오차, 장착 오프셋, 외부 측정 좌표계 정합 오차가 복합적으로 누적된 결과로 해석한다. 따라서 본 논문에서는 이를 단일 물리 원인에 대응하는 순

수 처짐량으로 단정하지 않고, 강체 FK 대비 tracker-referenced position residual로 정의한다. 또한 현재 데이터셋은 동적 타격 데이터가 아니라, 목표점 이동 후 정착 시간이 확보된 상태에서 측정된 Vive Tracker 기준 외부 위치 데이터이다.

Nguyen(2019)와 Gadringer(2020)는 기존 로봇 캘리브레이션 및 오차 보정 연구에서 기구학 모델과 데이터 기반 보정 모델을 결합해 위치 오차를 줄이는 접근을 제안했다[1,2]. 또한 Subedi(2020)는 유연 링크 매니플레이터의 모델링 및 제어에서 해석적 유연체 모델과 다양한 model-based, model-free 제어 접근을 정리했다[3]. 본 연구는 이러한 선행연구를 대체하거나 일반 이론을 새로 제안하기보다, SO-101 연구용 로봇, TPU 95A 유연 링크, Vive Tracker 기반 외부 기준 측정, 머신러닝 기반 위치 예측이라는 구체적인 실험 조건에서 안정화 위치 예측과 적용 범위 진단 절차를 정리한다.

본 논문의 실험은 $L=300\text{mm}$ 단일 유연 링크 조건에 한정한다. $L_1=300\text{mm}$, $L_2=180\text{mm}$ 이중 유연 링크 조건은 다유연 링크 구조로의 확장 가능성을 검토하기 위한 분석 대상으로 정의하며, 본문 및 부록의 합성 데이터 기반 분석은 좌표계 정합, 입력 특징 구성, 모델 적용 절차를 사전에 점검하기 위한 보조 분석으로 제한한다. 따라서 본 연구의 주요 결과는 단일 유연 링크 하드웨어 측정 데이터셋에서의 tracker-referenced 위치 예측 성능과 q-space holdout 기반 적용 범위 진단 결과로 해석한다.

II. 관련 연구

유연 링크 매니플레이터는 낮은 관성, 경량화, 안전성 등의 장점으로 다양한 로봇 시스템에서 연구되어 왔다. 그러나 링크 유연성은 정적 처짐과 동적 진동을 유발하며, 이는 엔드이펙터 위치 정확도와 궤적 추종 성능을 저하시킨다. Subedi(2020)는 유연 링크 매니플레이터 모델링에 assumed mode method, finite element method, lumped-parameter model 등이 활용되어 왔으며, 제어 기법은 model-based control과 model-free control로 구분될 수 있음을 정리했다[3]. 본 연구는 해석적 유연체 모델을 직접 구성하기보다, 강체 FK 기준 모델과 Vive Tracker 기준 측정 위치 사이의 잔차를 데이터 기반으로 보정하는 구조를 정의한다.

로봇 위치 오차는 링크 길이, 관절축 정렬, 기준 좌표계와 같은 기하학적 파라미터 오차뿐 아니라 link compliance, gear backlash, joint deflection과 같은 비기하학적 요인에 의해서도 발생한다. Nguyen(2019)은 로봇 모델 기반 식별과 ANN 기반 오차 보정을 결합함으로써 위치 정확도가 향상될 수 있음을 보였다[1]. Gadringer(2020)는 기구학 모델과 신경망을 결합한 보정 접근을 통해 로봇의 위치 및 자세 정확도를 개선할 수 있음을 보였다[2]. 본 연구는 이러한 보정 접근을 TPU 유연 링크 매니플레이터에 적용하기 위한 실험 단계, 데이터셋 구조, 평가 지표를 정리한다.

외부 광학 추적 장치는 로봇 내부 센서와 독립적으로 엔드이펙터 위치를 측정할 수 있으므로, 로

봇 캘리브레이션과 위치 정확도 평가에 활용된다. Kuhlmann de Canaviri(2023)는 다중 베이스 스테이션 구성에서 SteamVR Tracking 2.0의 정적·동적 정확도와 occlusion robustness를 평가했다[4]. Merker(2023)는 HTC Vive Tracker 3.0의 위치 측정 정확도를 Vicon 시스템과 비교하여 평가했다[5]. 본 연구에서는 HTC Vive Tracker 3.0을 Vive Tracker 기준 측정 위치를 얻기 위한 장치로 사용하며, 그 사용 범위는 학습 라벨 생성과 평가용 외부 기준 위치 측정으로 제한한다.

로봇 위치 오차 예측 문제에서는 입력 특징과 Vive Tracker 기준 측정 위치 사이의 비선형 관계를 근사하기 위해 ensemble 기반 회귀 모델 또는 확률적 비모수 회귀 모델을 사용할 수 있다. Breiman(2001)은 다수의 decision tree를 결합하는 Random Forest 방법을 제안했다[6]. Rasmussen과 Williams(2006)는 Gaussian Process 기반 비모수 확률 회귀의 이론과 적용 방법을 체계화했다[7]. Relano(2023)는 소프트 로봇의 forward/inverse kinematics 예측에서 GPR 기반 접근이 활용될 수 있음을 보였다[8]. Saunders(1998)는 커널 함수를 이용해 비선형 입력-출력 관계를 표현하고, ridge 정규화를 통해 회귀 계수를 추정하는 Kernel Ridge Regression 방법을 제안했다[9].

Hendrycks(2017)는 out-of-distribution(OOD) 입력 판정을 모델 적용 범위를 제한하기 위한 일반적 절차로 제안했다[10]. Jiang(2018)은 classifier의 예측 신뢰도 평가를 위해 nearest-neighbor 관계를 활용한 trust score를 제안했다[11]. 이에 따라 본 논문에서는 trust score 자체를 직접 구현하지 않고, nearest-neighbor distance와 local density를 모델 적용 범위 진단 지표로 사용한다.

III. 실험 구성 및 조건

1. SO-101 기반 유연 링크 매니플레이터

단일 유연 링크 조건에서는 어깨축-팔꿈치축 사이의 링크를 TPU 95A 유연 링크로 교체한다. 유연 링크 길이는 $L=300\text{mm}$ 이다. 본 논문의 실제 하드웨어 정량 평가는 이 조건에서 수집한 단일 유연 링크 하드웨어 측정 데이터셋에 한정한다. 목표점 이동 후 정착 시간을 확보하고, 정착 상태값과 트레이커 유효성 지표를 기준으로 유효 표본을 선별하였다. 최종 라벨은 정착 후 Vive Tracker 기준 측정 위치이다.

그림 1은 SO-101 기반 유연 링크 매니플레이터의 CAD 도면과 주요 치수를 나타낸다. 본 연구에서는 이 도면의 링크 구조를 기반으로 단일 유연 링크 조건과 이중 유연 링크 확장 조건을 정의한다.




그림 1. 실험 장비의 CAD 도면 및 주요 치수

단일 유연 링크 조건에서는 어깨축-팔꿈치축 사이의 링크를 TPU 95A 유연 링크로 교체한다. 유연 링크 길이는 300mm이다. 본 논문의 실제 하드웨어 정량 평가는 이 조건에서 수집한 단일 유연 링크 하드웨어 측정 데이터셋에 한정한다. 목표점 이동 후 정착 시간을 확보하고, 정착 상태값과 트래커 유효성 지표를 기준으로 유효 표본을 선별하였다. 최종 라벨은 정착 후 Vive Tracker 기준 측정 위치이다.

이중 유연 링크는 어깨-팔꿈치 연결 링크와 팔꿈치-손목 연결 링크를 모두 3D프린팅 TPU 95A 유연 링크로 교체하는 구조로 정의한다. 첫 번째 링크와 두 번째 링크의 길이는 각각 $L_1=300\text{mm}$, $L_2=180\text{mm}$ 이다. 이 조건은 두 유연 링크의 복합적인 위치 잔차와 관절 자세에 따른 오차 누적을 향후 다유연 링크 구조에서 분석하기 위한 확장 조건이다. 실험에서는 해당 조건의 합성 데이터 기반 분석을 좌표계 정합, 입력 특징 구성, 모델 적용 절차를 사전에 점검하는 보조 분석으로 다룬다.

2. 실험 설계

단일 유연 링크와 이중 유연 링크 조건은 구동축 수가 아니라 TPU 유연 링크가 적용된 링크의 개수를 기준으로 구분한다. 구동 자유도는 1축 구동 실험, 2축 구동 실험 조건으로 구분한다. 이중 유연 링크 실험에 앞서, 단일링크와 이중 링크 조합의 2링크 강체 FK/IK 모델을 실험 장비 구동 전 도달 가능 작업공간과 기하학적 기구학 해의 유효성을 사전 확인하였다.

IV. 연구 및 실험 방법

본 절에서는 Vive Tracker 기준 측정 위치를 예측하기 위한 데이터 표현, 강체 FK 대비 위치 잔차의 정의, 직접 위치 예측 문제의 정식화, density-aware local KRR 모델, 적용 범위 진단 절차를 정리한다. 강체 FK 대비 잔차 표현은 본 연구에서 다루는 위치 차이의 성격을 설명하고 향후 보정 명령 생성 문제로 확장하기 위한 보조적 식 표현이며, 본 논문의 정량 결과는 직접 위치 예측 모델의 평가에 해당한다.

1. 외부 기준 측정 위치와 좌표 정의

각 실험 조건에서는 초기 자세의 Vive Tracker 측정 위치를 기준 원점으로 사용한다. k 번째 표본의 Vive Tracker 기준 외부 측정 위치는 식(1)과 같이 초기 자세 기준 좌표로 변환한다.

$$P_{ref,k} = P_{vive,k} - P_{vive,0} \quad (1)$$

여기서 $P_{vive,k}$ 는 Vive Tracker가 측정한 원시 위치이고, $P_{vive,0}$ 는 실험자가 지정한 원점 위치의 측정값이다. $P_{ref,k}$ 는 학습 라벨 평가 기준으로 사용하는 외부 기준 측정 위치이다. $P_{ref,k}$ 는 절대적인 외부 참값을 의미하지 않으며, 본 연구의 실험 구성에서 정의한 tracker-measured reference position을 의미한다.

2. 강체 FK 기준 모델과 위치 잔차

실험 장비의 링크 길이, 관절축, 기준 좌표계 변환을 포함하는 강체 기구학 변수를 θ_{rigid} 라 한다. 엔코더 관절각 벡터 $\vec{q}_k$ 에 대한 강체 FK 예측 위치는 식(2)와 같이 정의한다.

$$P_{rigid,k} = FK_{rigid}(\vec{q}_k, \theta_{rigid}) \quad (2)$$

강체 FK 대비 위치 잔차는 식(3)과 같이 정의한다.

$$r_k = P_{ref,k} - P_{rigid,k} \quad (3)$$

본 연구에서 정의하는 위치 잔차는 TPU 유연 링크의 비선형 탄성 변형 뿐만 아니라 관절 유격, 구동 오차, 장착 오프셋, 좌표계 정합 오차, 외부 측정 노이즈가 함께 포함된 복합적인 위치 차이이다. 따라서 본 논문에서는 이를 단일 물리 원인에 대응하는 순수 처짐량으로 해석하지 않으며, 강체 FK 대비 외부 기준 측정 위치 잔차로 정의하며 위치 예측 오차 크기는 식(4)와 같이 계산한다.

$$e_k = \| P_{ref,k} - \widehat{P}_{ref,k} \|_2 \quad (4)$$

허용 오차 임계값 τ 에 대한 pass rate는 식(5)와 같이 정의한다.

$$pass@{\tau} = \frac{1}{N} \sum_{k=1}^N \mathbf{1}(e_k \leq \tau) \times 100 \quad (5)$$

본 연구에서는 pass@2mm와 pass@2.5mm 조건에서 실험 평가 및 해석을 진행하였다.

유연 링크 변형과 장착 오차 등은 강체 FK 출력과 외부 기준 측정 위치 사이의 잔차로 반영되며, 특히 이중 유연 링크 synthetic 분석에서 사용한 Kabsch(1976)의 방식[14]은 서로 다른 좌표계의 비교 가능성을 확보하기 위한 전처리 단계에서 사용한다.

3. 데이터셋 가공 및 특징 설계

단일 유연 링크에 대한 정량 평가를 위해 입력 특징 X_k 는 명령 관절각, 엔코더 측정 관절각, 목표 위치를 기본 특징으로 정의한다.

본 연구에서 사용하는 데이터는 단일 유연링크 실험 데이터셋, 확장 특징 집합, 이중 유연링크 합성 데이터셋, 선택적 보조 변수로 구분된다. 단일 유연링크 실험 데이터셋은 명령 관절각, 엔코더 기준 관절각, 목표 위치를 주요 입력 변수로 포함하며, Vive Tracker로 측정한 엔드이펙터 위치를 기준 위치로 사용한다. 이를 통해 강제 FK 모델로 계산한 위치와 실제 측정 위치 사이의 오차를 산출하고, 데이터 기반 위치 보정 모델의 학습 라벨을 구성한다.

확장 특징 집합은 강제 FK 기반 예측 위치, 이동 방향, 모터 상태 등을 포함한다. 이러한 특징은 단순한 관절각 입력만으로 설명하기 어려운 위치 잔차를 모델링하고, 향후 보정 명령을 생성하기 위한 입력으로 사용된다. 또한 특징별 기여도를 분석함으로써 유연 링크 매니플레이터의 위치 오차에 영향을 미치는 주요 요인을 진단할 수 있다.

이중 유연링크 구조에 대해서는 관절각, 목표 위치, 강제 FK 위치, 이동 방향을 포함하는 합성 데이터셋을 구성한다. 이 데이터셋은 Kabsch 정합을 통해 합성 기준 위치를 생성하고, 단일 링크 조건에서 확장된 잔차 특성을 진단하기 위해 사용된다. 추가로 전류, 부하, 온도, Tracker 유효성 지표와 같은 보조 변수는 데이터 품질 선별, 이상치 제거, 추가 성능 분석에 활용한다.

4. 위치 예측 문제와 잔차 표현 정의

본 연구의 정량 평가는 입력 특징 X_k 로부터 Vive Tracker 기준 측정 위치 $P_{ref,k}$ 를 직접 예측하는 문제로 정의하며, 식(6)과 같이 표현된다.

$$\widehat{P_{ref,k}} = g_\phi(X_k) \quad (6)$$

강제 FK 대비 위치 잔차 r_k 는 본 연구에서 다루는 위치 차이의 물리적 성격을 설명하고, 향후 보정 명령 생성 문제로 확장하기 위한 보조 지표이다. 잔차 표현을 사용할 경우 예측 위치는 식(7)과 같이 표현된다.

$$\widehat{r_k} = h_\phi(X_k), \quad \widehat{P_{ref,k}} = P_{rigid,k} + \widehat{r_k} \quad (7)$$

잔차 기반 표현은 기구학 모델과 데이터 기반 오차 모델을 결합하는 Nguyen(2019)와 Gadringer(2020)의 방법을 이용한다[1,2]. 다만 본 연구의 실험 결과 및 분석은 식(6)의 직접 위치 예측 모델에 대한 결과이며, 식(7)을 이용한 보정 명령의 생성이나 오차 감소율 평가는 후속 연구로 남긴다.

5. 최종 위치 예측 모델 및 OOD 진단과 적용

최종 위치 예측 모델은 표준화된 feature space에

서 query point 주변의 kNN local subset을 선택하고 해당 subset에 대해 Kernel Ridge Regression을 적용하는 local KRR 구조이다. 이하에서는 기존 결과 표기와 연속성을 위해 density-aware local KRR로 표기하되, 이 용어는 density-weighted loss optimization을 의미하지 않는다. KRR은 커널 함수를 이용해 비선형 입력-출력 관계를 표현하고 ridge 정규화를 통해 회귀 계수를 추정하는 방법이다[9]. 본 연구에서 "density-aware"라는 표현은 표준화된 feature space에서 query point 주변의 국소 이웃을 선택하고, nearest-neighbor distance와 local density를 산출하여 경험적 적용 가능 범위를 진단하는 절차를 의미한다.

입력 특징은 train split의 평균과 표준편차를 이용해 식(8)과 같이 표준화한다.

$$\tilde{x} = \frac{x - \mu_{train}}{\sigma_{train}} \quad (8)$$

예측 대상 query x^* 에 대해, 표준화된 feature space에서 가장 가까운 k 개의 학습 표본으로 local subset $N_k(x^*)$ 를 식(9)와 같이 구성한다.

$$N_k(x^*) = \text{kNN}_k(\tilde{x}; \{\tilde{x}_i: x_i \in D_{train}\}) \quad (9)$$

해당 query 주변의 local density 진단값은 평균 이웃 거리에 기반해 식(10)과 같이 정의한다.

$$\rho(x^*) = \left(\frac{1}{k} \sum_{x_i \in N_k(x^*)} \|\tilde{x}_i - \tilde{x}^*\|_2 + \epsilon \right)^{-1} \quad (10)$$

여기서 $\epsilon > 0$ 은 query point와 학습 표본이 같거나 평균 이웃 거리가 0에 가까워질 때 분모가 0이 되는 것을 방지하기 위한 미소 상수이다. $\rho(x^*)$ 가 클수록 query 주변 학습 표본이 조밀하며, $\rho(x^*)$ 가 작은 경우 그 반대로 해석한다.

Local subset에 대해 RBF kernel을 식(11)과 같이 정의한다.

$$K_{ij} = \exp(-\gamma \|\tilde{x}_i - \tilde{x}_j\|_2^2), x_i, x_j \in N_k(x^*) \quad (11)$$

최종 예측은 local subset에 대해 계산한 KRR 예측, 즉 식(12)로 얻는다.

$$\hat{y}(x^*) = k_*^\top (K_N + \lambda I)^{-1} Y_N \quad (12)$$

여기서 K_N 은 local subset $N_k(x^*)$ 에 대해서 계산한 RBF kernel matrix, k_* 는 query point와 local subset 사이의 kernel vector, Y_N 은 local subset에 대응하는 출력 라벨이다. λ 는 ridge 정규화 계수이고, γ 는 RBF kernel width를 결정하는 계수이다. 하이퍼파라미터 k, λ, γ 는 validation split의 mean 3D prediction error를 기준으로 선택한다.

학습 분포 밖의 query를 진단하기 위해, 표준화된 feature space에서 nearest-neighbor distance와 local density를 사용한다. Nearest-neighbor distance는 식

(13)과 같이 정의한다.

$$d_{NN}(x^*) = \min_{x_i \in D_{train}} \|\tilde{x}_i - \tilde{x}^*\|_2 \quad (13)$$

$d_{NN}(x^*)$ 가 크거나 $\rho(x^*)$ 가 작은 query는 학습 데이터가 희소한 영역에 위치한 입력으로 해석한다. 본 논문에서 이 값들은 모델 적용 가능 범위를 경험적으로 판단하기 위한 진단 지표이며, 실제 safety filter나 closed-loop stability guarantee를 제공하는 것은 아니다. CBF 기반 safety filter, 보정량 제한, physics-informed ML은 향후 command-level compensation으로 확장할 때 검토할 장기 확장 방향으로 둔다.

V. 실험 결과

1. 단일 유연 링크 데이터셋 및 모델 결과

단일 유연 링크의 원본 지도학습 표본은 600개이며, 결측, 트래커 유효성 지표 저하, 정착 상태값 미달 등 데이터 품질 기준 미달에 해당하는 16개의 표본을 제외한 584개 표본을 최종 분석에 사용하였다. 입력 특징은 각 관절의 명령 관절각 q_{cmd} , 인코더 측정 관절각 q_{enc} , 3차원 목표 공간 위치 P_{target} 으로 구성되었으며, 세션 간 자세 정합을 적용하지 않고 Vive Tracker를 장착한 매니플레이터의 수직 자세 기준 상대좌표를 정렬하기 위한 변환 행렬 연산만을 수행했다. 상대좌표 $\tilde{p}_{trk} = [\tilde{x}_{trk}, \tilde{y}_{trk}, \tilde{z}_{trk}]^T$ 에서 최종 라벨 좌표 p_{vive} 로의 고정 직교 축 정렬 변환은 식(14)와 같이 수행되었다.

$$p_{vive} = R_{align} \tilde{p}_{trk}, \quad R_{align} = \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (14)$$

여기서 $R_{align} \in SO(3)$ 는 Vive Tracker 상대좌표계를 목표 위치 및 강체 FK 좌표계와 비교 가능한 축 방향으로 정렬하기 위한 고정 회전행렬이다. 이 변환은 세션별 최적 정합이나 학습 기반 보정이 아니라, 모든 단일 유연링크 표본에 동일하게 적용한 고정 좌표계 변환이다.

그림 2에서 옅은 회색 점은 계획 목표 위치를, 진한 회색 점은 고정 직교 축 정렬 변환 후 Vive Tracker 기준 측정 라벨을 나타낸다. 두 점군 간의 차이는 학습 모델의 시험 예측 오차가 아니라, 목표 위치와 정착 후 외부 기준 측정 위치 사이에 존재하는 시스템적 위치 차이를 시각화한 전처리 진단 결과이다.




그림 2. 목표 위치와 측정 라벨의 점군 비교

모델이 학습한 관절공간 범위를 확인하기 위해 q1/q2 command angle 분포를 확인하였다. 그림 3은 단일 유연링크 데이터셋이 포함하는 관절 명령각 범위를 나타낸다.




그림 3. 단일 유연링크 데이터셋의 명령각 분포

그림 4와 같이 단일 유연링크 데이터셋에서 GPR baseline, RBF-KRR, density-aware local KRR을 비교한 결과, 평균 3D 예측 오차는 각각 5.97mm, 2.14mm, 2.0135mm로 감소하였다. GPR baseline 대비 density-aware local KRR의 평균 3D 예측 오차는 약 66.3% 감소하였다. 이 비교는 동일 데이터셋 내 모델 선택을 위한 예측 성능 비교 결과이다.

50회 반복 random-split 평가에서 density-aware local KRR은 평균 3D 예측 오차 2.0135mm, 중앙값 1.5656mm, p90 3.9056mm, p95 5.0003mm, pass@2mm 62.68%, pass@2.5mm 73.80%를 보였다. 이는 동일 수집 프로토콜과 동일 데이터 분포 내부의 random-split 보간 조건에서 평균 예측 오차가 2mm 수준으로 낮아졌음을 의미한다. p95와 pass rate가 80% 이하인 점을 함께 고려하면, 본 모델이 모든 표본에서 2mm 이하의 위치 예측 오차를 보장한다고 해석할 수는 없으나, density-aware local KRR이 GPR baseline보다 낮은 오차를 내는 경향성이 있다고 볼 수 있다.




그림 4. 단일링크 모델 간 평균 3D 예측 오차 변화

2. 이중 유연 링크 데이터셋 및 모델 결과

이중 유연 링크의 원본 지도학습 표본은 5,000개이며, 결측, 트래커 유효성 지표 저하, 정착 상태 값 미달 등 데이터 품질 기준 미달에 해당하는 188개의 표본을 제외한 4,812개 표본을 최종 분석에 사용하였다. 입력 특징은 각 관절의 명령 관절각 q_{cmd} , 엔코더 측정 관절각 q_{enc} , 3차원 목표 공간 위치 P_{target} 으로 구성되었으며, 출력 라벨은 Vive Tracker 기반 측정 위치를 P_{target} 좌표계와 비교할 수 있도록 p_{vive} 로 정의하였다.

원본 지도학습 표본은 label window 안에서 계산된 Vive Tracker 상대좌표 평균값으로부터 얻어졌으며, 전체 데이터셋에 대하여 하나의 전역 강체 정합을 적용하였다. 원본 지도학습 표본 점군 $\tilde{p}_{trk}$ 를 기반으로 하여 목표 위치 점군 P_{target} 을 기준 점군으로 두고 Kabsch 정합을 수행하여 하나의 회전행렬과 이동 벡터를 식(15)와 같이 계산하였다. 이후 모든 표본에 대하여 동일한 작업을 수행하여 p_{vive} 를 생성하였다.

$$p_{vive} = R_{Kabsch} \tilde{p}_{trk} + t_{Kabsch} \quad (15)$$

여기서 R_{Kabsch} 와 t_{Kabsch} 는 원본 지도학습 표본의 점군을 FK 좌표계와 비교 가능한 수준으로 정렬하기 위해 계산된 전역 회전행렬과 이동 벡터이다. 이 변환은 최종 학습과 분석에 사용된 공통 고정 좌표계 정합이다.

그림 5, 6, 7, 8은 Kabsch 정합을 통해 정렬된 원본 지도학습 표본 점군과 정렬된 점군의 RMSE 비교이다. 정합 전에는 target 좌표와 raw label 좌표 간 상관이 낮고 RMSE가 크게 나타났으며, 이는 원본 지도학습 표본 점군이 FK 좌표계와 원점 및 축 방향에서 일치하지 않음을 의미한다. 반면 Kabsch 정합 후에는 x, y, z축 모두에서 target 좌표와 aligned label 좌표 간 상관이 증가하고 RMSE가 감소하였다. 상세 수치로 보았을 때, x축은 $corr=-0.073$, $RMSE=581.8mm$ 에서 $corr=0.940$, $RMSE=21.8mm$ 로, y축은 $corr=0.020$, $RMSE=292.6mm$ 에서 $corr=0.968$, $RMSE=27.7mm$ 로, z축은 $corr=0.289$, $RMSE=101.3mm$ 에서 $corr=0.924$, $RMSE=37.5mm$ 로 개선되었다. 이를 통해 전처리 보정 과정에서 정렬 품질을 개선하였다.




그림 5. x축에 대한 Kabsch 정합 결과




그림 6. y축에 대한 Kabsch 정합 결과




그림 7. z축에 대한 Kabsch 정합 결과

모델이 학습한 관절공간 범위를 확인하기 위해 q1/q2/q3 command angle 분포를 확인하였다. 그림 8은 이중 유연 링크 데이터셋이 포함하는 관절 명령 각 범위를 나타낸다.




그림 8. 이중 유연링크 데이터셋의 명령각 분포

그림 9와 같이 이중 유연 링크 데이터셋에서 Rigid baseline, RBF-KRR, density-aware local KRR을 비교한 결과, 평균 3D 예측 오차는 각각 18.8246mm, 1.1149mm, 0.7101mm로 감소하였다. Ridge baseline 대비 density-aware local KRR의 평균 3D 예측 오차는 약 96.2% 감소하였고, RBF-KRR

baseline 대비로도 약 36.3% 감소하였다.




그림 9. 이중링크 모델 간 평균 3D 예측 오차 변화

50회 반복 random-split 평가에서 density-aware local KRR은 평균 3D 예측 오차 0.7101mm, 중앙값 0.5193mm, p95 1.8215mm, pass@2mm 96.00%를 보였다. 이는 동일 데이터 생성 조건과 동일 데이터 분포 내부의 random-split 보간 조건에서 평균 예측 오차가 1 mm 이하 수준으로 낮아졌음을 의미한다. 또한 그림 10의 seed별 평균 오차에서도 대부분의 seed에서 평균 3D 예측 오차가 약 0.66-0.76mm 범위에 분포하여, 반복 split 조건에서도 비교적 안정적인 예측 성능을 보였다. 다만 test error 분포에서 일부 tail sample은 2mm를 초과하므로, 본 모델이 모든 표본에서 2mm 이하의 위치 예측 오차를 보장한다고 해석할 수는 없다. 따라서 본 결과는 학습된 데이터의 random-split 기준 1mm 이하 평균 예측 성능으로 정리하는 것이 적절하며, 실제 제어 성능은 향후 optimizer 구현 및 실측 또는 시뮬레이션 검증을 통해 별도로 확인해야 한다.

그림에도, density-aware local KRR은 동일 조건에서 Ridge baseline 및 RBF-KRR baseline에 대비하여 낮은 평균 오차와 p95를 보이는 경향성이 있다고 볼 수 있다.




그림 10. Density-aware local KRR 모델의 50회 반복 random-split 평가 결과

VI. 결론

본 연구에서는 외부 Vive Tracker를 활용하여 TPU 95A 유연 링크를 장착한 SO-101 매니퓰레이터의 안정화 위치 예측 파이프라인을 구성하고, 관절

공간에서의 적용 가능 범위를 진단하였다. 비선형 탄성 변형, 관절 유격, 구동 오차, 조립 오차, 좌표계 정합 오차 등이 복합적으로 작용하는 시스템 특성을 고려하여, 강체 기구학 모델과 외부 기준 측정 위치 사이의 차이를 단일 물리 원인에 따른 순수 치짐량으로 규정하지 않고 **tracker-referenced position residual**로 정의하였다.

단일 유연 링크 하드웨어 실험에서는 데이터 품질 기준을 통과한 584개 유효 표본을 사용하였다. 50회 반복 **random-split** 평가 결과, **density-aware local KRR** 모델은 평균 3D 예측 오차 2.0135 mm, 중앙값 오차 1.5656 mm를 보였으며, **GPR baseline** 대비 평균 오차를 약 66.3% 감소시켰다. 이는 수집된 단일 유연 링크 데이터 분포 내부의 보간 조건에서 수 밀리미터 수준의 평균 위치 예측이 가능함을 보여준다.

그러나 **p95** 오차가 5.0003 mm이고 **pass@2mm**가 62.68%에 그친 점을 고려하면, 제안한 모델이 모든 표본에서 2 mm 이하의 예측 오차를 보장한다고 해석할 수는 없다. 또한 **q-space block holdout** 평가에서 관측되지 않은 관절공간 영역의 예측 오차가 증가하는 경향을 확인하였다. 따라서 **random-split** 조건에서 얻은 예측 성능을 전체 관절공간에 대한 전체 관절 공간에 대한 일반화 성능으로 해석하는 것은 적절하지 않으며, 학습 데이터 분포 밖 입력에 대해서는 별도의 적용 범위 진단이 필요하다.

이중 유연 링크 구조에 대해서는 **L1=300 mm**, **L2=180 mm** 조건의 합성 데이터 기반 분석을 통해 **Kabsch** 정합을 포함한 좌표계 정렬, 입력 특징 구성, 모델 선택 절차를 사전 점검하였다. 이 결과는 다유연 링크 구조로 확장하기 위한 분석 절차의 가능성을 보여주지만, 실제 이중 유연 링크 하드웨어에서의 위치 예측 성능을 검증한 결과로 해석해서는 안 된다.

본 연구의 의의는 유연 매니퓰레이터의 위치 예측 성능을 단순히 평균 오차 관점에서 제시하는 데 그치지 않고, **random-split** 보간 성능과 관절공간 외삽 한계를 구분하여 평가했다는 점에 있다. 또한 **nearest-neighbor distance**와 **local density**를 활용하여 학습 데이터가 희소한 입력 영역을 경험적으로 진단하는 절차를 제시하였다. 향후 연구에서는 더 넓은 관절공간과 다양한 하중 조건에서 하드웨어 데이터를 추가 수집하고, 제어 장벽 함수 기반 **safety filter**, 보정량 제한, **physics-informed ML** 등을 활용하여 학습 분포 밖 입력에 대한 적용 안정성을 높이는 방향으로 확장할 필요가 있다. 나아가 본 위치 예측 모델을 **command-level** 보정 제어 알고리즘과 결합하여 실제 위치 보정 성능을 검증할 계획이다.

참고문헌

[1] H.-N. Nguyen, P.-N. Le, and H.-J. Kang, "A new calibration method for enhancing robot position accuracy by combining a robot model-based identification approach and an artificial neural network-based error compensation technique,"

Advances in Mechanical Engineering, vol. 11, no. 1, pp. 1–11, 2019.

[2] S. Gadringer, H. Gatringer, A. Mueller, and R. Naderer, "Robot calibration combining kinematic model and neural network for enhanced positioning and orientation accuracy," IFAC-PapersOnLine, vol. 53, no. 2, pp. 8432–8437, 2020.

[3] D. Subedi, I. Tyapin, and G. Hovland, "Review on modeling and control of flexible link manipulators," Modeling, Identification and Control, vol. 41, no. 3, pp. 141–163, 2020.

[4] L. Kuhlmann de Canaviri, K. Meiszl, V. Hussein, P. Abbassi, S. D. Mirraziroudsari, L. Hake, T. Potthast, F. Ratert, T. Schulten, M. Silberbach, Y. Warnecke, D. Wiswede, W. Schiprowski, D. Hess, R. Bruengel, and C. M. Friedrich, "Static and dynamic accuracy and occlusion robustness of SteamVR Tracking 2.0 in multi-base station setups," Sensors, vol. 23, no. 2, article 725, 2023.

[5] S. Merker, S. Pastel, D. Buerger, A. Schwadtke, and K. Witte, "Measurement accuracy of the HTC VIVE Tracker 3.0 compared to Vicon system for generating valid positional feedback in virtual reality," Sensors, vol. 23, no. 17, article 7371, 2023.

[6] L. Breiman, "Random forests," Machine Learning, vol. 45, pp. 5–32, 2001.

[7] C. E. Rasmussen and C. K. I. Williams, Gaussian Processes for Machine Learning. Cambridge, MA, USA: MIT Press, 2006.

[8] C. Relañó, J. Muñoz, and C. A. Monje, "Gaussian process regression for forward and inverse kinematics of a soft robotic arm," Engineering Applications of Artificial Intelligence, vol. 126, article 107174, 2023.

[9] C. Saunders, A. Gammerman, and V. Vovk, "Ridge regression learning algorithm in dual variables," in Proceedings of the Fifteenth International Conference on Machine Learning, pp. 515–521, 1998.

[10] D. Hendrycks and K. Gimpel, "A baseline for detecting misclassified and out-of-distribution examples in neural networks," in International Conference on Learning Representations, 2017.

[11] H. Jiang, B. Kim, M. Y. Guan, and M. Gupta, "To trust or not to trust a classifier," Advances in Neural Information Processing Systems, vol. 31, 2018.

[12] A. D. Ames, X. Xu, J. W. Grizzle, and P. Tabuada, "Control barrier function based quadratic programs for safety critical systems," IEEE Transactions on Automatic Control, vol. 62, no. 8, pp. 3861–3876, 2017.

[13] M. Raissi, P. Perdikaris, and G. E. Karniadakis,

“Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations,” *Journal of Computational Physics*, vol. 378, pp. 686–707, 2019.

- [14] W. Kabsch, “A solution for the best rotation to relate two sets of vectors,” *Acta Crystallographica Section A*, vol. 32, no. 5, pp. 922–923, 1976.



김 기 현

2021년~현재 인하대학교 전기전자공학부 재학 중. 관심분야는 로봇 학습, 학습 기반 제어




구 미 선

2023년~현재 인하대학교 전기전자공학부 재학중. 관심분야는 로봇 모션 제어 알고리즘 및 센서 기반 제어 시스템 설계.



최 현 규

2021년~현재 인하대학교 전기전자공학부 재학 중. 관심분야는 매니플레이터 제어, 기계학습 제어.



황 수 민

2023년~현재 인하대학교 전기전자공학부 재학 중. 관심분야는 기계학습 제어, 전력시스템.