한국정밀공학회지 제 43 권 제 11 호 pp. 1203-1211
J. Korean Soc. Precis. Eng., Vol. 43, No. 11, pp. 1203-1211
November 2026 / 1203
http://doi.org/10.7736/JKSPE.026.00068
ISSN 1225-9071 (Print) / 2287-8769 (Online)

• 특집 • AI 융합 제조로봇 조작 및 자동화 기술(AI-enabled Robotic Manipulation and Automation for Manufacturing)

적응 섭동 성형 기반 모델 예측 경로 적분 제어를 이용한 로봇 매니퓰레이터 자세 제어

Adaptive Perturbation-shaping Model Predictive Path Integral for Robotic Manipulator Pose Control

이문행[1], 김성재[2], 서진호[3,#]
Mun Haeng Lee[1], Sung Jae Kim[2], and Jin-Ho Suh[3,#]

1 국립부경대학교 지능로봇공학과 (Department of Intelligent Robot Engineering, Pukyong National University)
2 한국로봇융합연구원 (Korea Institute of Robotics & Technology Convergence)
3 국립부경대학교 기계시스템공학전공 (Major of Mechanical System Engineering, Pukyong National University)
Corresponding Author / E-mail: suhgang@pknu.ac.kr, TEL: +82-51-629-6189
ORCID: 0000-0002-8673-4528

KEYWORDS: Optimal control (최적 제어), Model predictive path integral control (모델 예측 경로 적분 제어), Low-pass filter (저역통과 필터), Adaptive covariance (적응 공분산), Robotic manipulator (로봇 매니퓰레이터), Pose control (자세 제어)

This study proposes a model predictive path integral (MPPI) control method that combines adaptive covariance adjustment with low-pass perturbation filtering for the pose control of a robotic manipulator. The proposed method updates the sampling covariance according to the position and orientation errors of the tool center point, which allows a large sampling range during the approach phase and reduces the perturbation magnitude near the target pose. The sampled perturbation sequences are then passed through a low-pass filter before rollout evaluation, and the nominal control sequence is updated using the weighted sum of the filtered perturbations. This structure adaptively regulates the sampling range while reducing abrupt temporal variations in the sampled perturbation sequences. Numerical simulations were conducted on a 6-DoF robotic manipulator under a sequential target-pose scenario with five random seeds. The proposed MPPI method reached the final target-hold condition at 4.10 ± 0.08 s and maintained root-mean-square (RMS) position and orientation errors of 0.47 ± 0.12 mm and 0.05 ± 0.01°, respectively, with an RMS input variation of 0.02 ± 0.001 rad/s. These results indicate that the proposed method can maintain fast target-approach performance while improving near-goal stability and input smoothness in robotic manipulator pose control.

Manuscript received: July 8, 2026 / Revised: August 30, 2026 / Accepted: October 5, 2026

1. 서론

산업 분야에서는 위험한 작업을 사람 대신 수행하기 위한 로봇 플랫폼 도입이 점차 증가하고 있다. 특히, 자동화 및 유지보수 작업에서 로봇 매니퓰레이터는 반복적인 위치 이동, 자세 정렬, 부품 조작 등 다양한 작업을 수행하기 위해 널리 활용되고 있다[1,2]. 그러나 로봇 매니퓰레이터는 관절 간 결합성, 비선형 운동학, 목표 자세로의 수렴 등을 동시에 고려해야 하므로 정밀한 제어에 어려움이 따른다. 이러한 문제를 해결하기 위해 로봇 매니퓰레이터 제어 분야에서는 PID, 슬라이딩 모드 제어, 모델 예측 제어 등 다양한 제어 기법이 연구되어 왔다[3-6].

이 중 모델 예측 제어(Model Predictive Control, MPC)는 입력

Copyright © The Korean Society for Precision Engineering
This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (http://creativecommons.org/licenses/by-nc/3.0) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

제한, 상태 제약 조건, 제어 성능을 하나의 최적화 문제 안에서 함께 고려할 수 있기 때문에 로봇 매니퓰레이터 제어에 활용되어 왔다. 기존 연구에서는 로봇 매니퓰레이터의 비선형 동역학, 조인트 공간 및 작업 공간 제어, 안전한 궤적 추종 등을 고려한 다양한 MPC 기반 제어 기법이 제안되었다[6-9]. 하지만 고자유도 로봇 매니퓰레이터에 MPC를 적용하기 위해서는 시스템 모델, 입력 제한, 상태 제약 조건 등을 포함한 최적화 문제를 반복적으로 구성하고 해결해야 한다. 특히 비선형 동역학 모델이나 복잡한 비용 함수가 포함될 경우 최적화 문제의 차원이 증가하고 비볼록성이 나타날 수 있으며, 이에 따라 제어 성능과 계산 부담이 문제 구성 및 해법 선택에 크게 의존할 수 있다[10,11].

이러한 문제를 다루기 위한 대안적 접근으로, 샘플링 기반 모델 예측 제어 기법의 하나인 모델 예측 경로 적분 제어(Model Predictive Path Integral Control, MPPI)가 로봇 매니퓰레이터 제어 문제에 적용되고 있다[12]. MPPI는 경로 적분 제어 이론을 Receding-horizon 구조에 적용한 제어 기법으로, 다수의 제어 입력 후보를 샘플링하고 각 롤아웃의 누적 비용을 평가한 뒤, 비용 기반 중요도 가중치를 이용하여 제어 입력 시퀀스를 갱신한다. 이러한 구조로 인해 MPPI는 그래디언트 기반 최적화에 직접 의존하지 않으며, 비볼록 또는 비평활 비용 함수를 비교적 유연하게 포함할 수 있다[13,14]. 또한 다수의 롤아웃 계산을 병렬적으로 수행할 수 있어, 샘플링 기반 제어 구조를 로봇 제어 문제에 적용하는 데 유리하다[14].

하지만 MPPI를 로봇 매니퓰레이터 제어에 적용할 경우, 확률적 섭동 샘플링에 기반한 제어 입력 탐색 과정에서 몇 가지 문제가 발생할 수 있다. 일반적인 MPPI에서는 고정된 공분산을 갖는 가우시안 섭동을 사용하여 제어 입력 후보를 생성한다. 이때 공분산이 크게 설정되면 넓은 입력 공간을 탐색하는 데 유리하지만, 목표 자세 근방에서는 불필요한 입력 변동이 증가하여 수렴 과정에서 진동이 발생할 수 있다. 반대로 공분산이 작게 설정되면 목표 근방에서 안정적인 수렴에는 유리하지만, 목표 자세까지 도달하는 과정에서 충분한 탐색성이 확보되지 않아 수렴 속도와 도달 성능이 저하될 수 있다. 이를 완화하기 위해 선행 연구에서는 작업 진행도와 장애물 근접성을 고려하여 샘플링 공분산을 조절하는 적응 공분산 기반 MPPI를 제안하였다[15]. 해당 방법은 작업 진행 상태에 따라 섭동의 크기를 조절함으로써 목표 자세로의 수렴성을 개선하였다. 그러나 공분산 조절은 샘플링 섭동의 크기 조절에 초점을 두기 때문에, 예측 구간 내 각 시점에서 생성되는 섭동의 시간적 상관성이나 주파수 특성을 직접적으로 조절하지는 않는다. 따라서 공분산이 적응적으로 조절되더라도 입력 후보에 고주파 성분이 포함될 수 있으며, 이는 유한한 샘플 기반 갱신 과정에서 진동 또는 급격한 입력 변화로 나타날 수 있다.

이를 완화하기 위해 제어 입력을 변화율 입력으로 재정의하고, 그에 대한 비용항을 추가하는 연구가 제안되었다[16]. 또한 Colored Noise를 이용하여 시간적으로 상관된 섭동을 생성하는 방법[17], 샘플링된 섭동에 저역통과 필터를 적용하여 고주파 성분을 필터링함으로써 입력 변화를 완화하는 방법[18]이 제안되었다. 이러한 평활화 기반 접근은 고주파 성분을 줄이고 입력 변동을 완화하는 데 효과적일 수 있으나, 목표 자세로 접근하는 과정에서 요구되는 탐색 범위와 목표 근방에서 요구되는 수렴 안정성을 함께 조절하기에는 한계가 있다. 따라서 로봇 매니퓰레이터의 목표 자세 제어에서는 샘플링 섭동의 시간적 평활성뿐만 아니라 작업 진행 상태에 따른 크기 조절도 함께 고려할 필요가 있다.

이에 본 논문에서는 로봇 매니퓰레이터의 목표 자세 제어를 위해 적응 공분산과 저역통과 필터 기반 섭동 샘플링을 결합한 MPPI 제어 방법을 제안한다. 제안하는 방법은 목표 자세로의 접근 정도에 따라 샘플링 섭동의 크기를 조절하여 탐색성과 수렴 안정성 사이의 상충 관계를 완화한다. 또한, 샘플링된 섭동에 저역통과 필터를 적용하여 제어 입력 후보의 고주파 성분을 줄이고, 시간적으로 보다 평활한 입력 후보가 롤아웃에 적용되도록 한다. 이를 통해 목표 자세로의 접근 단계에서는 충분한 샘플링 범위를 확보하여 빠른 목표 접근 성능을 유지하고, 목표 근방에서는 섭동 크기를 감소시켜 안정적인 자세 수렴을 유도한다. 또한, 저역통과 필터를 통해 전체 제어 과정에서 제어 입력 후보의 시간적 변동을 완화하는 것을 목표로 한다.

본 논문의 주요 기여는 다음과 같다.

1) 로봇 매니퓰레이터의 자세 제어 문제에서 MPPI 샘플링 섭동을 크기 특성과 시간적 특성으로 구분하여 다루는 제어 구조를 제안한다. 이를 통해 목표 접근 과정에서 요구되는 탐색성과 목표 근방에서 요구되는 수렴 특성, 그리고 제어 입력 후보의 시간적 평활성을 함께 고려한다.
2) 적응 공분산 조절과 저역통과 필터 기반 섭동 샘플링을 MPPI의 샘플링 과정에 통합한다. 제안 구조에서는 제어 명령을 사후적으로 필터링하는 것이 아니라 롤아웃 평가에 사용되는 섭동 자체의 크기와 주파수 특성을 조절한다.
3) 6자유도 로봇 매니퓰레이터 수치 시뮬레이션을 통해, 섭동 크기 조절과 저역통과 필터 기반 평활화의 결합 효과를 검토한다.

본 논문의 구성은 다음과 같다. 2장에서는 로봇 매니퓰레이터의 자세 제어 문제와 기본 MPPI 구조를 정식화하고, 3장에서는 적응 공분산과 저역통과 필터 기반 섭동 평활화를 결합한 제안 방법을 설명한다. 4장에서는 6자유도 로봇 매니퓰레이터 수치 시뮬레이션을 통해 제안 방법의 성능을 검증하고, 5장에서 결론을 제시한다.

2. 로봇 매니퓰레이터 자세 제어 문제 정식화

본 장에서는 로봇 매니퓰레이터에 대한 운동학 모델을 표현하고, 목표 자세 제어를 위한 최적 제어 문제를 정식화한다. 이후 본 연구에서 사용하는 MPPI 제어 구조를 간략히 정리한다.

2.1 운동학 기반 자세 제어 문제

본 논문에서는 6자유도 로봇 매니퓰레이터에 대한 자세 제어 문제를 다룬다. 본 연구는 관절 속도 명령을 이용한 기구학

기반 자세 제어 문제를 대상으로 하며, 하위 관절 제어기는 주어진 속도 명령을 충분히 추종한다고 가정한다.

시간 t에서의 관절각을 $\boldsymbol{q}_t \in \mathbb{R}^6$, 명목 제어 입력을 $\boldsymbol{u}_t \in \mathbb{R}^6$ 로 정의한다. MPPI에서는 입력 공간 탐색을 위해 명목 제어 입력에 가우시안 섭동 $\delta \boldsymbol{u}_t$ 을 부가하며, 이를 통해 롤아웃 평가에 사용되는 입력 후보는 식(1)과 같이 표현된다.

$$\boldsymbol{v}_t = \boldsymbol{u}_t + \delta \boldsymbol{u}_t \tag{1}$$

여기서 $\delta \boldsymbol{u}_t$ 는 평균이 0이고 공분산이 Σ 인 가우시안 섭동을 나타낸다. 따라서 관절 상태는 다음의 이산 운동학 모델로 갱신된다.

$$\boldsymbol{q}_{t+1} = \boldsymbol{q}_t + g(\boldsymbol{v}_t)\Delta t \tag{2}$$

Δt 는 이산 시간 간격을 의미하며, $g(\cdot)$는 입력을 허용 가능한 범위 내로 제한하는 클램핑 함수이다. 이를 통해 관절 속도 제한은 별도의 제약 조건이 아니라 상태 전이 모델의 일부로 반영된다[13].

MPPI에서는 각 입력 후보 시퀀스로부터 생성된 예측 궤적을 평가하고, 그 결과를 바탕으로 명목 제어 입력 시퀀스를 갱신한다. 예측 구간 H에서 입력 후보 시퀀스를 $\boldsymbol{V} = [\boldsymbol{v}_0,\ \boldsymbol{v}_1,\ \cdots,\ \boldsymbol{v}_{H-1}]$, 관절각 시퀀스를 $Q = [\boldsymbol{q}_0,\ \boldsymbol{q}_1,\ \cdots,\ \boldsymbol{q}_H]$ 로 정의한다. 본 연구의 목표는 TCP가 목표 위치와 목표 자세에 수렴하도록 하는 명목 제어 입력 시퀀스를 계산하는 것이며, 이를 위한 최적 제어 문제는 식(3)과 같이 표현된다.

$$\begin{aligned} &\min_U \mathrm{J} = \mathbb{E}\left[\phi(\boldsymbol{q}_H) + \sum_{h=0}^{H-1} \left(\ell(\boldsymbol{q}_h) + \boldsymbol{v}_h^{\top} \mathbf{W}_{\mathbf{u}} \boldsymbol{v}_h \right) \right], \\ &s.t.\ \boldsymbol{q}_{h+1} = \boldsymbol{q}_h + g(\mathbf{v}_h)\Delta t, \\ &\boldsymbol{v}_h = \boldsymbol{u}_h + \delta \boldsymbol{u}_h \end{aligned} \tag{3}$$

J는 예측 궤적 비용의 기댓값을 의미한다. $\ell(\cdot)$ 은 예측 시점에서의 단계 비용이며, $\phi(\cdot)$은 예측 구간의 마지막 상태에서 평가되는 말단 비용을 나타낸다. 또한, $\mathrm{W_u}$은 제어 입력 비용에 대한 양의 정부호 행렬이다.

2.2 기본 모델 예측 경로 적분 제어

MPPI에서는 현재 명목 제어 입력 시퀀스를 기준으로 다수의 입력 후보 시퀀스를 생성하고, 각 후보에 대한 롤아웃 비용을 평가한다. 샘플의 수를 K라고 할 때, k번째 롤아웃의 누적 비용을 S_k 로 정의한다. 이 경우, 각 롤아웃에 대한 중요도 가중치는 식(4)로 계산된다.

$$\omega_k = \frac{1}{\eta} \exp\left(-\frac{1}{\lambda}(S_k - \rho) \right) \tag{4}$$

식(4)의 $\rho = \min_k S_k$ 는 수치적 안정성을 위해 각 롤아웃 비용에서 차감되는 최소 비용이다[12]. $\lambda > 0$는 비용에 따른 분포의 선택성을 조절하는 Inverse Temperature 파라미터이며, η는 정규화 상수이다.

계산된 중요도 가중치를 이용하여 명목 제어 입력 시퀀스는 샘플링 섭동의 가중합으로 갱신된다.

$$\boldsymbol{u}_h \leftarrow \boldsymbol{u}_h + \sum_{k=1}^{K} \omega_k \delta \boldsymbol{u}_{k,h}, \quad h = 0,1,\ldots,H-1 \tag{5}$$

매 제어 주기에서는 갱신된 입력 시퀀스의 첫 번째 입력만 시스템에 적용하며, 나머지 입력 시퀀스는 다음 제어 주기의 초기 입력 시퀀스로 사용한다.

3. 샘플링 섭동 조절 메커니즘

3.1 작업 진행도 기반 적응 공분산 메커니즘

기본 MPPI에서는 고정된 공분산을 갖는 가우시안 섭동을 이용하여 입력 후보 시퀀스를 생성한다. 이때 섭동의 크기는 입력 공간에서의 탐색 범위를 결정하는 주요 요소로 작용한다. 큰 섭동은 목표로 접근하는 과정에서 다양한 입력 후보를 탐색하는 데 유리하지만, 목표 근방에서는 불필요한 입력 변동을 유발하여 수렴 안정성을 저하시킬 수 있다. 반대로 작은 섭동은 목표 근방에서 세밀한 수렴에는 유리하지만, 초기 접근 과정에서 충분한 탐색성을 확보하기 어렵다.

본 연구에서는 이러한 Trade-off를 완화하기 위해, 앞서 정의한 샘플링 공분산을 고정된 값으로 사용하지 않고 작업 진행 상태에 따라 조절한다. 구체적으로, 공분산 행렬을 표준편차 벡터의 제곱을 대각 성분으로 갖는 대각 행렬로 구성하고, 위치 및 방향 오차에 따라 표준편차 벡터를 갱신함으로써 샘플링 섭동의 크기를 변화시킨다.

로봇 매니퓰레이터의 위치 및 방향 제어에서는 TCP의 위치와 방향을 동시에 고려해야 한다. 그러나 위치와 방향은 서로 다른 기하학적 특성을 가지므로, 단일 진행도 변수만으로 표준편차를 조절할 경우 위치 수렴과 방향 수렴 상태를 충분히 구분하기 어렵다. 이에 본 연구에서는 위치 오차와 방향 오차에 대한 진행도 변수를 각각 정의하고, 이를 이용하여 샘플링 섭동의 크기를 조절한다.

매 제어 주기에서 현재 TCP 위치 $\boldsymbol{p} \in \mathbb{R}^3$와 목표 위치 $p_g \in \mathbb{R}^3$ 사이의 오차를 식(6)과 같이 정의한다.

$$e_{pos} = \left\| \boldsymbol{p} - \boldsymbol{p}_g \right\| \tag{6}$$

위치 오차를 사용하여 위치와 관련된 진행도 변수 ζ_{pos} 을 식(7)과 같이 정의한다.

$$\zeta_{pos} = \begin{cases} 1, & \text{if } e_{pos} \geq d_{far} \\ \dfrac{e_{pos} - d_{near}}{d_{far} - d_{near}}, & \text{if } d_{near} < e_{pos} < d_{far} \\ 0, & \text{if } e_{pos} \leq d_{near} \end{cases} \tag{7}$$

여기서 d_{far}과 d_{near}은 각각 위치 오차가 큰 영역과 목표 근방 영역을 구분하기 위한 경계값이며, $d_{far} > d_{near} > 0$을 만족한다. ζ_{pos}는 목표에서 멀리 떨어져 있을수록 큰 값을 가지며, 목표에 접근할수록 작은 값을 가진다. 전이 구간에서 표준편차 변화율을 완화하기 위해 Smoothstep 함수를 적용하고, 이를 통해 섭동 크기 조절 계수를 식(8)과 같이 계산한다.

$$s_{pos} = (3\zeta_{pos}^2 - 2\zeta_{pos}^3) \in [0,1] \tag{8}$$

방향에 대해서도 동일한 방식으로 목표 방향과 TCP 방향 사이의 회전 오차를 이용하여 섭동 크기를 조절한다. 현재 TCP 방향을 $R \in SO(3)$, 목표 방향을 $R_g \in SO(3)$로 두면, 방향 오차는 식(9)와 같은 최소 회전각으로 정의된다.

$$e_{ori} = \cos^{-1}\left(\frac{\mathrm{tr}(R_g^\top R) - 1}{2}\right) \tag{9}$$

여기서 tr(·)은 행렬의 대각합 연산자를 의미한다. 방향 오차 e_{ori}에 대한 진행도 변수는 식(10)으로 정의된다.

$$\zeta_{ori} = \begin{cases} 1, & \text{if } e_{ori} \geq \theta_{far} \\ \dfrac{e_{ori} - \theta_{near}}{\theta_{far} - \theta_{near}}, & \text{if } \theta_{near} < e_{ori} < \theta_{far} \\ 0, & \text{if } e_{ori} \leq \theta_{near} \end{cases} \tag{10}$$

여기서 θ_{far}과 θ_{near}은 각각 방향 오차가 큰 영역과 목표 근방 영역을 구분하기 위한 경계값이며, $\theta_{far} > \theta_{near} > 0$을 만족한다.

이에 따라 방향에 대한 섭동 크기 조절 계수는 식(11)과 같이 계산된다.

$$s_{ori} = (3\zeta_{ori}^2 - 2\zeta_{ori}^3) \in [0,1] \tag{11}$$

식(8)과 식(11)을 통해 계산된 조절 계수는 가우시안 섭동의 공분산 행렬을 구성하는 표준편차 크기를 조절한다.

$$\boldsymbol{\sigma}_{pos} = \boldsymbol{\sigma}_{pos,min} + (\boldsymbol{\sigma}_{pos,max} - \boldsymbol{\sigma}_{pos,min}) s_{pos} \tag{12}$$

$$\boldsymbol{\sigma}_{ori} = \boldsymbol{\sigma}_{ori,min} + (\boldsymbol{\sigma}_{ori,max} - \boldsymbol{\sigma}_{ori,min}) s_{ori} \tag{13}$$

$\boldsymbol{\sigma}_{(\cdot),max}$와 $\boldsymbol{\sigma}_{(\cdot),min}$는 위치와 방향에 대한 표준편차의 상한과 하한을 의미하며, $\boldsymbol{\sigma}_{pos}$와 $\boldsymbol{\sigma}_{ori}$는 각각 위치와 방향 오차에 대응하여 갱신되는 표준편차 벡터를 나타낸다.

따라서 가우시안 섭동을 생성하기 위한 공분산은 다음으로 갱신된다.

$$\Sigma_{AC} = \mathrm{diag}(\underbrace{\boldsymbol{\sigma}_{pos}^2}_{\mathcal{J}_b}, \underbrace{\boldsymbol{\sigma}_{ori}^2}_{\mathcal{J}_w}) \tag{14}$$

여기서 $\mathcal{J}_b$와 $\mathcal{J}_w$는 관절 그룹을 의미한다. 6자유도 매니퓰레이터를 고려했을 때, $\mathcal{J}_b$은 관절 1-3, $\mathcal{J}_w$는 관절 4-6을 포함한다. 이러한 관절 그룹 구분은 일반적인 6자유도 직렬 매니퓰레이터의 팔-손목 구조에서 착안하였다[19]. 이는 TCP의 위치와 방향 운동이 기구학적으로 분리되는 것을 의미하진 않으며, 매니퓰레이터의 기구학적 결합은 롤아웃 과정에서의 순기구학 계산과 비용 평가에 그대로 반영된다. 이러한 구조를 통해 위치와 방향 중 하나의 오차가 먼저 감소하더라도, 남아 있는 오차에 대응하는 관절 그룹의 샘플링 탐색 여지를 유지할 수 있다.

3.2 저역통과 필터 기반 섭동 평활화

적응 공분산은 작업 진행 상태에 따라 샘플링 섭동의 크기를 조절하지만 각 시점에서 생성되는 섭동의 분산을 변화시키는 방법으로 예측 구간 내 섭동 시퀀스의 시간적 상관성이나 주파수 특성을 직접적으로 보장하지 않는다. 이에 본 절에서는 기존 LP-MPPI [18]의 저역통과 필터 기반 샘플링 절차를 적응 공분산 구조와 결합하여, 작업 진행도 기반 공분산으로부터 생성된 섭동 시퀀스를 롤아웃 전에 필터링한다.

k번째 롤아웃에 대해 작업 진행도 기반 공분산으로부터 생성된 섭동 시퀀스를 식(15)와 같이 정의한다.

$$\delta U_k = [\delta u_{k,0}, \delta u_{k,1}, ..., \delta u_{k,H-1}] \tag{15}$$

각 예측 시점의 섭동은 식(14)의 적응 공분산을 이용하여 식(16)과 같이 샘플링된다.

$$\delta \boldsymbol{u}_{k,h} \sim \mathcal{N}(0, \Sigma_{AC}), \quad h = 0,1,\ldots,H-1 \tag{16}$$

이후 생성된 섭동 시퀀스에 저역통과 필터를 적용하여 필터링된 섭동 시퀀스를 얻는다.

$$\delta \tilde{U}_k = \mathcal{F}_{LPF}(\delta U_k, f_c, o_{LPF}) \tag{17}$$

여기서 $\mathcal{F}_{LPF}(\cdot)$은 Butterworth 저역통과 필터로 구성되며, f_c와 o_{LPF}는 각각 차단 주파수와 필터 차수를 나타낸다[20]. 본 연구에서는 Zero-phase Filtering을 적용하지 않고 각 관절 및 롤아웃의 섭동 시퀀스에 대해 예측 구간 방향으로 Forward IIR Filtering을 수행하였다. 필터 시작부에는 첫 번째 섭동값을 이전 입력 및 출력 이력으로 설정하여 초기 과도응답을 완화하였다.

필터링된 섭동을 이용하여 k번째 롤아웃에서 h번째 예측 시점의 입력 후보는 식(18)과 같이 표현된다.

$$\boldsymbol{v}_{k,h} = \boldsymbol{u}_h + \delta \tilde{\boldsymbol{u}}_{k,h} \tag{18}$$

따라서 각 롤아웃의 누적 비용은 식(18)의 입력 후보로부터 생성된 예측 궤적을 이용하여 평가된다. 또한, 명목 제어 입력 시퀀스의 갱신에는 기존의 독립 샘플링 섭동 대신 필터링된 섭동을 사용한다.

$$\boldsymbol{u}_h \leftarrow \boldsymbol{u}_h + \sum_{k=1}^{K} \omega_k \delta \tilde{\boldsymbol{u}}_{k,h}, \quad h = 0,1,\ldots,H-1 \tag{19}$$

3.3 제안 MPPI 알고리즘

앞 절에서 정의한 적응 공분산 메커니즘과 저역통과 필터 기반 섭동 평활화를 통합한 MPPI 절차를 Algorithm 1에 정리하였다. 제안하는 방법은 매 제어 주기마다 현재 관절 상태로부터

Algorithm 1 Proposed MPPI Algorithm

Given: g: input clipping function;
K, H: Number of samples and prediction horizon;
$U = (\boldsymbol{u}_0, \boldsymbol{u}_1, \ldots, \boldsymbol{u}_{H-1})$: Initial nominal control sequence;
λ: Inverse temperature parameter;
f_c, o_{LPF}: low-pass filter cutoff frequency and order;
Δt : sampling time;

Output: Control input $\boldsymbol{u}_0$ at each control step

while task not completed **do**
  Get current state estimate $\boldsymbol{q} \leftarrow \boldsymbol{q}_0$;
  Compute current TCP pose $(\boldsymbol{p}, R) \leftarrow \mathrm{FK}(\boldsymbol{q})$;
  Update covariance:
    $\Sigma_{AC} \leftarrow ComputeAC(\boldsymbol{p}, R, \boldsymbol{p}_g, R_g)$; ▷ Section 3.1

  Noise sequence $\delta \boldsymbol{U} = \{\delta \boldsymbol{u}_{k,h}\}$, $\delta \boldsymbol{u}_{k,h} \sim \mathcal{N}(0, \Sigma_{AC})$;
  Filtered noise sequence $\delta \tilde{\boldsymbol{U}} = \mathcal{F}_{LPF}(\delta \boldsymbol{U}, f_c, o_{LPF})$ ▷ Section 3.2

  for $k \leftarrow 1$ to K **do**
    $\boldsymbol{q}_{k,0} \leftarrow \boldsymbol{q}$;
    $\boldsymbol{S}_k \leftarrow 0$;
    for $h \leftarrow 0$ to $H-1$ **do**
      $\boldsymbol{\nu}_{k,h} \leftarrow \boldsymbol{u}_h + \delta \tilde{\boldsymbol{u}}_{k,h}$
      $\boldsymbol{q}_{k,h+1} \leftarrow \boldsymbol{q}_{k,h} + g(\boldsymbol{\nu}_{k,h})\Delta t$
      $S_k \leftarrow S_k + \ell(\boldsymbol{q}_{k,h+1}) + \boldsymbol{\nu}_{k,h}^{\top} W_u \boldsymbol{\nu}_{k,h}$
    end for
    $S_k \leftarrow S_k + \phi(\boldsymbol{q}_{k,H})$
  end for

  Compute normalized weights ω_k
  for $h \leftarrow 0$ to $H-1$ **do**
    $\boldsymbol{u}_h \leftarrow \boldsymbol{u}_h + \sum_{k=1}^{K} \omega_k \, \delta \tilde{\boldsymbol{u}}_{k,h}$
  end for

  Apply $\boldsymbol{u}_0$ and shift horizon: $U \leftarrow (\boldsymbol{u}_1, \ldots, \boldsymbol{u}_{H-1}, \boldsymbol{u}_{\mathrm{init}})$
  Update the current state estimate $\boldsymbol{q}_0$
end while

Fig. 1 Proposed MPPI algorithm with adaptive covariance and low-pass perturbation filtering

TCP의 위치와 방향을 계산하고, 목표 자세와의 오차를 이용하여 적응 공분산 Σ_{AC}을 갱신한다. 이후 갱신된 공분산을 이용하여 전체 롤아웃에 대한 섭동 집합을 샘플링하고, 이에 대해 저역통과 필터를 적용한다.

필터링된 섭동을 이용하여 각 롤아웃의 입력 후보와 예측 궤적을 생성하고, 누적 비용 S_k를 계산한다. 이후 중요도 가중치 ω_k에 따른 필터링 섭동의 가중합으로 명목 제어 입력 시퀀스를 갱신하며, 갱신된 첫 번째 입력을 제어 입력으로 사용한다.

4. 수치 시뮬레이션 및 결과

4.1 시뮬레이션 설정 및 비용 구성

제안된 MPPI 프레임워크의 성능을 검증하기 위해 6자유도 로봇 매니퓰레이터에 대한 수치 시뮬레이션을 수행한다. 시뮬레이션은 NVIDIA GeForce RTX 4070 Ti를 사용하는 MATLAB에서 진행되며, Indy7_v2 모델을 사용한다. MPPI의 다수 롤아웃에 대한 계산은 GPU 기반 병렬 연산으로 수행하였다.

시뮬레이션 작업은 다중 목표 자세 제어 문제로 구성된다. 시뮬레이션 시간 간격, 예측 구간, 샘플 수는 각각 0.01초, 25스텝, 300개로 설정하였으며, 5개의 시드에 대해 수행한다. TCP는 작업 공간 내 배치된 네 개의 목표 자세를 순차적으로 추종해야 하며, 위치 오차와 방향 오차가 각각 0.005 m 및 1° 이하인 상태를 0.5초 유지한 뒤 다음 목표점으로 전환한다.

시뮬레이션에서 사용되는 단계 비용은 위치 오차, 방향 오차, 관절 제한 비용이 포함되며 식(20)과 같이 구성된다.

$$\ell = \omega_{pos} \| \boldsymbol{p}_h - \boldsymbol{p}_g \|^2 + \omega_{ori} \left(\cos^{-1} \left(\frac{\mathrm{tr}(R_g^{\top} R_h) - 1}{2} \right) \right)^2 + \omega_q \ell_q \quad (20)$$

여기서 $\omega_{(\cdot)}$는 각 항목에 대한 가중치를 의미하며, 관절 제한 비용인 ℓ_q는 식(21) 및 식(22)와 같다.

$$\ell_q = \sum_{n_q=1}^{N_q} \alpha_{n_q} \quad (21)$$

$$\alpha_{n_q} = \begin{cases} 0, & \text{if } q_{n_q,h} \in [q_{min}, q_{max}] \\ 1, & \text{if otherwise} \end{cases} \quad (22)$$

N_q는 전체 관절 수를 의미하며, $q_{n_q,h}$는 예측 시점 h에서의 n_q번째 관절각을 나타낸다. q_{min}과 q_{max}는 각각 관절의 하한과 상한을 의미한다.

말단 비용에는 식(20)의 위치 오차와 방향 오차에 대한 비용이 포함되며, 마지막 비용에 조금 더 가중치를 부여하기 위해 각 오차에 대해 $\omega_{pos,H}$와 $\omega_{ori,H}$의 가중치를 적용하며 식(23)과 같다.

$$\phi = \omega_{pos,H} \| \boldsymbol{p}_H - \boldsymbol{p}_g \|^2 + \omega_{ori,H} \left(\cos^{-1} \left(\frac{\mathrm{tr}(R_g^{\top} R_H) - 1}{2} \right) \right)^2 \quad (23)$$

시뮬레이션에서는 제안 방법의 구성 요소별 효과를 비교하기 위해 네 가지 MPPI 기반 제어기를 사용하였다. 비교 제어기는 기본 MPPI인 Base-MPPI, 저역통과 필터만 적용한 LP-MPPI, 적응 공분산만 적용한 AC-MPPI, 그리고 적응 공분산과 저역통과 필터를 모두 적용한 Proposed MPPI로 구성하였다. 모든 제어기는 동일한 비용 함수, 가중치 등의 파라미터를 적용하였으며, 시뮬레이션에서 사용된 주요 파라미터는 Table 1에 정리되어 있다.

여기서 $\boldsymbol{\sigma}_{max}$, $\boldsymbol{\sigma}_{mid}$, $\boldsymbol{\sigma}_{min}$는 샘플링 섭동의 표준편차 벡터를 의미하며, 각 공분산 행렬은 $\Sigma = \mathrm{diag}(\boldsymbol{\sigma}^2)$로 구성된다. 따라서 논문에서는 각 표준편차 벡터에 대응하는 공분산 행렬을 각각 Σ_{max}, Σ_{mid}, Σ_{min}로 표기한다. 또한, 모든 관절은 동일한 각도 제한을 가진다.

4.2 시뮬레이션 결과

Fig. 2는 네 개의 목표 자세를 순차적으로 수행하는 다중 목표 작업에서 비교 제어기별 TCP 궤적을 나타내며, Table 2는 5개의 서로 다른 시드에 대해 각 목표 자세의 유지 조건을 만족한 완료 시간을 평균과 표준편차로 정리한 결과이다. Fig. 2의 점선은 목표점 전환 순서를 나타내며, 사전에 주어진 추종 경로를 의미하지 않는다. 모든 비교 제어기는 5회의 반복 실험에서 네 개의 목표에 대해 조건을 만족하였으나, 제어기별 궤적 형상과 목표 완료 시간에 차이가 나타났다.

Base-MPPI는 네 번째 목표 자세의 평균 유지 완료 시간이

Table 1 Control parameters

Parameter	Value
H, K	25, 300
$\boldsymbol{\sigma}_{max}$	$[0.25, 0.25, 0.3, 0.3, 0.25, 0.25]^\top$
$\boldsymbol{\sigma}_{mid}$	$[0.1625, 0.1625, 0.195, 0.195, 0.1625, 0.1625]^\top$
$\boldsymbol{\sigma}_{min}$	$[0.075, 0.075, 0.09, 0.09, 0.075, 0.075]^\top$
λ	1
q_{min}, q_{max}	-2π, 2π
f_c, o_{LPF}	1 Hz, 1
ω_{pos}, ω_{ori}	1000, 200
ω_q	10^6
$\omega_{pos,H}$	5000
$\omega_{ori,H}$	400
d_{far}, d_{near}	0.01 m, 0.002 m
θ_{far}, θ_{near}	5°, 0.5°

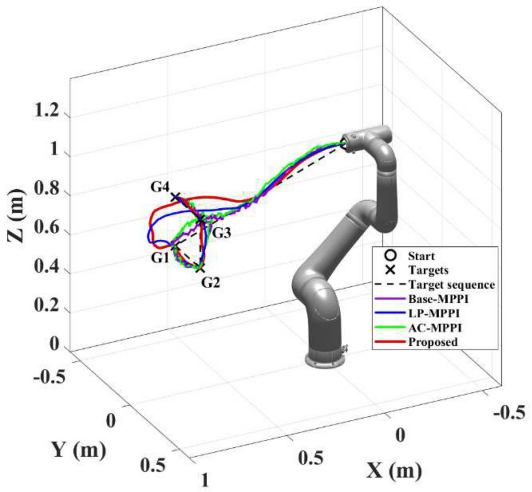


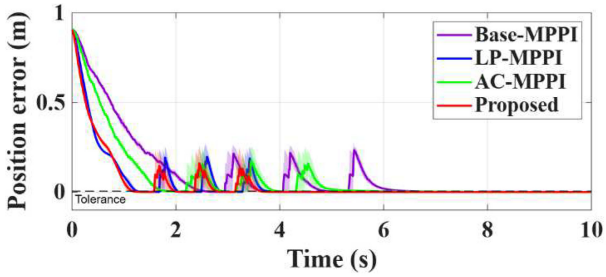
Fig. 2 TCP trajectories of the compared controllers for a representative trial (seed 1)

7.00 ± 0.04초로 가장 느린 결과를 보였으며, AC-MPPI는 6.26 ± 0.10초로 Base-MPPI 보다 단축되었지만, LP-MPPI 및 Proposed MPPI 대비 느린 결과를 보였다. LP-MPPI와 Proposed MPPI는 각각 4.24 ± 0.08과 4.10 ± 0.08초로 상대적으로 빠른 완료 시간을 나타내었다. 또한 Fig. 2의 대표 궤적에서 LP-MPPI와 Proposed MPPI는 목표점 전환 구간에서 상대적으로 완만한 곡선형 TCP 궤적을 보였으며, 이는 저역통과 필터가 적용된 제어 입력 후보의 특성이 궤적 형상에 반영된 결과로 볼 수 있다.

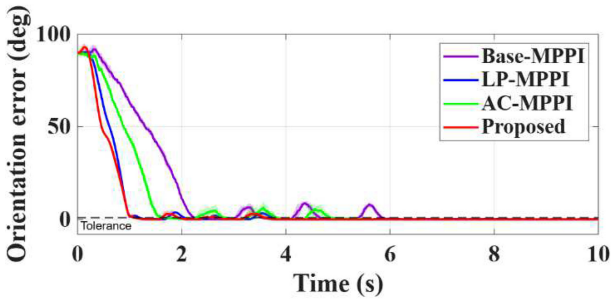
Fig. 3은 5개의 시드에 대해 계산한 비교 제어기별 위치 오차와 방향 오차 변화를 나타내며, 음영 영역은 표준편차를 나타낸다. Fig. 3에서 목표 자세가 순차적으로 전환됨에 따라 위치와 방향 오차가 일시적으로 증가한 뒤 다시 감소하는 경향을 보인다. 이는 각 목표 자세에 도달한 이후 다음 목표 자세로 전환되면서 새로운 목표에 대한 오차가 다시 계산되기 때문이다.

Table 2 Goal-wise target-hold completion time

Method	Goal [s]			
	G1	G2	G3	G4
Base-MPPI	3.04±0.07	4.14±0.06	5.38±0.04	7.00±0.04
LP-MPPI	1.73±0.05	2.54±0.04	3.36±0.05	4.24±0.08
AC-MPPI	2.37±0.12	3.34±0.12	4.42±0.09	6.26±0.10
Proposed	1.65±0.07	2.43±0.07	3.24±0.09	4.10±0.08



(a) Position error



(b) Orientation error

Fig. 3 Mean position and orientation errors of the compared controllers over five random seeds

Base-MPPI와 AC-MPPI는 오차가 감소하는 과정에서 상대적으로 큰 국부적 변동을 보였다. 이는 예측 구간의 각 시점에서 생성된 섭동이 별도의 주파수 성형 없이 사용되므로, 인접 시점 간 급격한 변화가 입력 후보에 직접 반영되기 때문이다. 한편 AC-MPPI는 Base-MPPI보다 전반적으로 빠른 목표 접근 성능을 나타냈으며, Table 2에서 네 번째 목표 자세의 유지 완료 시간이 7.00 ± 0.04에서 6.26 ± 0.10초로 단축된 것을 확인할 수 있다. 이는 적응 공분산이 목표 접근 단계에서는 충분히 큰 섭동 크기를 유지하고, 목표 근방에서는 섭동 크기를 감소시켜 이동과 수렴 간 Trade-off를 조절하기 때문으로 해석된다.

LP-MPPI와 Proposed MPPI는 앞의 두 비교 제어기에 비해 위치 및 방향 오차가 보다 평탄하게 감소하는 경향을 보였다. 이는 저역통과 필터가 샘플링 섭동 시퀀스의 고주파 성분을 억제하고 인접 예측 시점 간 섭동의 급격한 변화를 완화함으로써 보다 평활한 입력 후보가 생성되기 때문으로 해석할 수 있다. Table 2에서 Proposed MPPI는 모든 목표 자세에 대해 LP-MPPI보다 일관되게 짧은 평균 유지 완료 시간을 보였으며, 최종 목표에서는 4.10 ± 0.08초로 LP-MPPI의 4.24 ± 0.08초보다 빠르게

Table 3 Ablation comparison of adaptive covariance and low-pass filtering

AC	LPF OFF	LPF ON
OFF	Base-MPPI 7.00±0.04 s	LP-MPPI 4.24±0.08 s
ON	AC-MPPI 6.26±0.10 s	Proposed 4.10±0.08 s

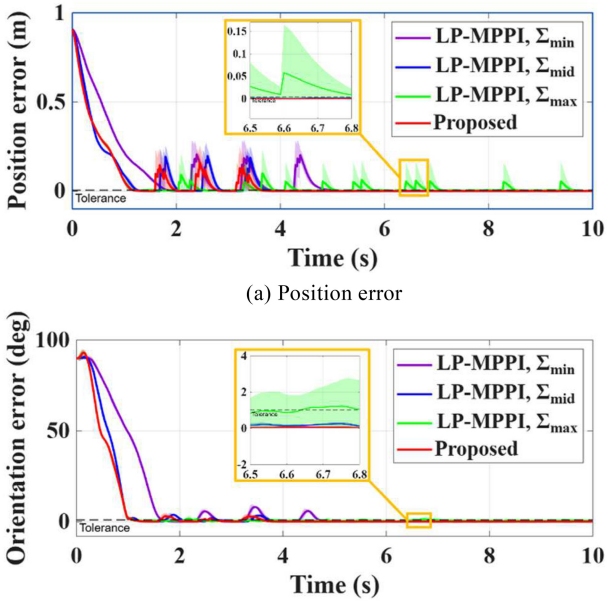
유지 조건을 만족하였다. 이러한 결과는 저역통과 필터를 통한 섭동의 시간적 평활화를 유지하면서 적응 공분산을 함께 적용할 경우, 목표 접근 과정에서 필요한 샘플링 범위를 확보하여 수렴 성능을 추가로 개선할 수 있음을 보여준다.

이상의 결과를 바탕으로 적응 공분산과 저역통과 필터 간의 효과를 비교하기 위해 두 구성요소의 적용 여부와 최종 목표자세의 평균 유지 완료 시간을 Table 3에 정리하였다.

Fig. 3과 Table 3을 종합하면, 적응 공분산만 적용한 AC-MPPI는 Base-MPPI에 비해 최종 목표의 평균 유지 완료 시간이 단축되었으며, LPF만 적용한 LP-MPPI에서도 완료 시간의 감소와 함께 보다 평활한 오차 감소 특성이 나타났다. 두 구성요소를 함께 적용한 Proposed MPPI는 가장 짧은 평균 완료 시간을 보였다. 이는 적응 공분산에 의한 샘플링 범위 조절과 LPF에 의한 섭동 시퀀스의 고주파 성분 억제 및 시간적 평활화가 서로 다른 역할을 수행하며, 두 요소를 결합함으로써 목표 접근 성능과 입력 후보의 평활성을 함께 확보할 수 있음을 보여준다.

한편, 적응 공분산의 효과는 샘플링 공분산의 크기 변화에 기반하므로, 공분산 크기 자체가 수렴 및 목표 유지 성능에 미치는 영향을 추가적으로 확인하였다. 이를 위해 동일한 조건에서 공분산만 변경하여 추가 시뮬레이션을 수행하였다. 비교군은 LP-MPPI에 공분산 Σ_{min}, Σ_{mid}, Σ_{max}을 각각 고정한 세 조건과 적응 공분산을 적용한 Proposed MPPI로 구성하였다.

Fig. 4는 공분산 크기에 따른 위치 오차와 방향 오차의 변화를 시각화한 그래프이다. 각 실선은 5개의 시드에 대한 평균을 나타내며, 음영 영역은 표준편차를 나타낸다. Σ_{max} 조건에서는 일부 실험이 최종 조건을 만족하지 못하였으나, 실패한 시드의 결과를 포함하여 그래프에 표시하였다. Σ_{min}을 적용한 LP-MPPI는 안정적으로 오차가 감소하며, 최종 목표 도달 이후 안정적으로 허용치 아래에서 위치 및 방향을 유지하는 것을 알 수 있다. 하지만 작은 샘플링 범위로 인해 각 목표에 대한 접근이 보수적으로 나타났으며, 최종 목표 자세의 유지 완료 시간이 5.49 ± 0.05초로 나타났다. Σ_{mid}을 적용한 경우에서는 평균 유지 완료 시간이 4.24 ± 0.08초로 단축되어 Σ_{min} 보다 빠른 수렴을 보였다. 그러나 최종 목표 유지 구간에서 위치와 방향에 대한 평균 제곱근 편차(RMS, Root Mean Square)는 각각 1.52 ± 0.22 mm와 0.18 ± 0.02^{o}로 나타나 Σ_{min}보다 유지 성능은 저하되었다. Σ_{max}의 경우 목표 근방으로 빠르게 접근하였으나, 큰 샘플링 범위로 인해 허용 오차 내에서 0.5초 동안 자세를 유지하지 못하는 구간이 반복되었다. 그 결과 5회의 실험 중 2회만 최종 목표



(a) Position error

(b) Orientation error

Fig. 4 Position and orientation errors under different covariance settings with magnified views near the final target

Table 4 Quantitative comparison under different covariance settings

Method	Success	Position RMS [mm]	Orientation RMS [°]	$\|\Delta u\|$ RMS [rad/s]
LP-MPPI Σ_{min}	5/5	0.48±0.17	0.04±0.01	0.02±0.001
LP-MPPI Σ_{mid}	5/5	1.52±0.22	0.18±0.02	0.09±0.004
LP-MPPI Σ_{max}	2/5	16.46±27.98	0.63±0.20	0.26±0.05
Proposed	5/5	0.47±0.12	0.05±0.01	0.02±0.001

자세의 유지 조건을 만족하였으며, 성공한 실험의 평균 유지 완료 시간은 7.47 ± 1.79초로 나타났다. 또한, 위치 오차 RMS는 16.46 ± 27.98 mm로 크게 증가하였다. 반면, Proposed MPPI는 목표와의 오차를 빠르게 감소시키면서도, 목표 근방에서는 공분산의 크기를 Σ_{min} 수준으로 줄임으로써 위치 및 방향 오차를 안정적으로 유지하였다. 그 결과, 5회의 실험에서 모두 최종 목표의 유지 조건을 만족하였으며, 평균 완료 시간은 4.10 ± 0.08초로 나타났다. 위치 및 방향 오차 RMS 또한 0.47 ± 0.12 mm와 0.05 ± 0.01^{o}로 Σ_{min}과 유사한 수준을 보였다. 이러한 정량적 결과는 Table 4에 정리하였다. 표의 RMS는 성공 여부와 관계없이 모든 시드에 대해 시뮬레이션의 최종 1초 구간(9–10 초)에서 계산하였다.

다음으로, 공분산 설정에 따른 입력 변화 특성을 확인하기 위해 입력 변화량을 Fig. 5에 나타내었다. Σ_{min}을 적용한 LP-MPPI는 전 구간에서 입력 변화량이 낮은 수준으로 유지되었으며, 이는 Fig. 4에서 확인한 보수적인 목표 접근 특성과 대응된다.

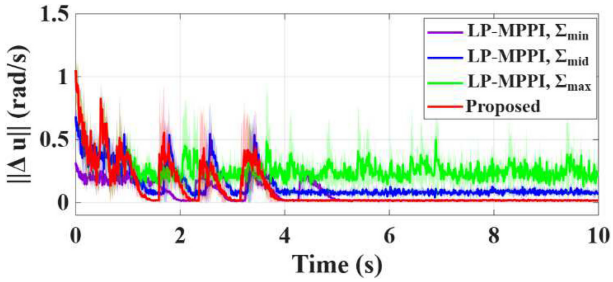


Fig. 5 Input variation norm of joint velocity commands under different covariance settings

반면, Σ_{mid}와 Σ_{max}를 적용한 경우에는 상대적으로 큰 변화량을 확인할 수 있다. 특히 Σ_{max}의 경우 큰 샘플링 범위의 영향으로 전 구간에서 큰 입력 변화량이 지속되었으며, 이는 목표 근방에서 위치 및 방향 오차를 안정적으로 유지하지 못하는 원인으로 해석할 수 있다. Proposed MPPI는 목표 전환 직후에는 샘플링 범위가 커지면서 입력 변화량이 일시적으로 증가하였으나, 목표 근방으로 접근한 이후에는 공분산이 감소함에 따라 입력 변화량 또한 낮은 수준으로 감소하였다. Table 4에서도 Proposed MPPI의 입력 변화량 RMS는 0.02 ± 0.001 rad/s로 Σ_{min}과 유사한 수준을 보이는 것을 알 수 있다. 이러한 결과는 제안 방법이 목표 접근 단계에서 충분한 샘플링 범위를 제공하여 빠른 접근 성능을 유지하고, 목표 근방에서는 섭동 크기를 줄여 위치 및 방향 오차와 입력 변화량을 함께 억제할 수 있음을 보여준다.

계산 성능과 관련하여, 현재 MATLAB 구현에서 Proposed MPPI의 업데이트당 평균 계산 시간은 약 0.12초로 측정되었다. 따라서 본 연구에서 사용한 0.01초는 이산 시간 간격이며, 100 Hz 실시간 적용을 위해서는 추가적인 구현 최적화가 필요하다.

5. 결론

본 논문에서는 로봇 매니퓰레이터의 자세 제어를 위해 적응 공분산과 저역통과 필터 기반 섭동 평활화를 결합한 MPPI 제어 방법을 제안하였다. 제안한 방법은 목표 자세와의 위치 및 방향 오차에 따라 샘플링 공분산을 조절하여 목표 접근 단계의 탐색 범위와 목표 근방의 섭동 크기를 적응적으로 변화시켰다. 또한 저역통과 필터를 통해 예측 구간 내 섭동 시퀀스에 시간적 평활성을 부여함으로써, 롤아웃 평가에 사용되는 입력 후보의 급격한 변화를 완화하였다. 이를 통해 MPPI의 샘플링 단계에서 탐색 범위 조절과 입력 후보 평활화를 함께 반영하였다.

6자유도 로봇 매니퓰레이터 시뮬레이션 결과, Proposed MPPI는 네 번째 목표 자세의 평균 유지 완료 시간이 4.10 ± 0.08초로 나타나 LP-MPPI의 4.24 ± 0.08초보다 짧은 완료 시간을 보였다. 또한, 첫 번째부터 세 번째 목표 자세의 유지 완료 시간은 각각 1.65 ± 0.07, 2.43 ± 0.07, 3.24 ± 0.09초로 LP-MPPI보다 단축되었다. 위치 및 방향 오차는 목표 전환 이후 빠르게 감소하였으며, 목표 근방에서는 허용 오차 내에서 안정적으로 유지되는 경향을 확인하였다.

공분산 크기 변화에 따른 추가 실험에서도 Proposed MPPI의 효과를 확인하였다. Proposed MPPI는 LP-MPPI (Σ_{mid})와 유사한 목표 완료 시간을 유지하면서도, 최종 목표 유지 구간에서 위치 오차 RMS 0.47 ± 0.12 mm, 방향 오차 RMS $0.05 \pm 0.01°$ 그리고 입력 변화량 RMS 0.02 ± 0.001 rad/s로 LP-MPPI(Σ_{min})와 유사한 수준을 유지하였다. 이러한 결과는 제안하는 방법이 목표 접근 단계의 샘플링 범위와 목표 근방의 섭동 크기를 적응적으로 조절하여 빠른 접근 성능과 안정적인 목표 유지 성능을 함께 확보할 수 있음을 보여준다.

향후 연구에서는 제안한 방법을 실제 로봇 시스템에 적용하고, 동역학 모델을 포함한 제어 구조와 계산 효율화를 함께 고려하여 실제 환경에서의 적용 가능성을 검증할 예정이다.

ACKNOWLEDGEMENT

본 연구는 산업통상자원부의 로봇산업기술(No. RS-2024-00507783, 제철 공정의 AI 자율 예지보존 및 고위험 작업을 위한 모바일 자율로봇 기술 개발)의 지원을 받았습니다.

REFERENCES

1. Arents, J., Greitans, M., (2022), Smart industrial robot control trends, challenges and opportunities within manufacturing, Applied Sciences, 12(2), 937.
2. Ghodsian, N., Benfriha, K., Olabi, A., Gopinath, V., Arnou, A., (2023), Mobile manipulators in industry 4.0: A review of developments for industrial applications, Sensors, 23(19), 8026.
3. Nohooji, H. R., (2020), Constrained neural adaptive PID control for robot manipulators, Journal of the Franklin Institute, 357(7), 3907-3923.
4. Zhai, J., Xu, G., (2021), A novel non-singular terminal sliding mode trajectory tracking control for robotic manipulators, IEEE Transactions on Circuits and Systems II: Express Briefs, 68(1), 391-395.
5. Wang, F., Ren, B., Liu, Y., Cui, B., (2022), Tracking moving target for 6 degree-of-freedom robot manipulator with adaptive visual servoing based on deep reinforcement learning PID controller, Review of Scientific Instruments, 93(4), 045108.
6. Chen, Y., Luo, X., Han, B., Luo, Q., Qiao, L., (2020), Model predictive control with integral compensation for motion control of robot manipulator in joint and task spaces, IEEE Access, 8, 107063-107075.

7. Elsisi, M., Mahmoud, K., Lehtonen, M., Darwish M. M. F., (2021), Effective nonlinear model predictive control scheme tuned by improved NN for robotic manipulators, IEEE Access, 9, 64278-64290.

8. Kleff, S., Meduri, A., Budhiraja, R., Mansard, N., Righetti, L., (2021), High-frequency nonlinear model predictive control of a manipulator, Proceedings of the IEEE International Conference on Robotics and Automation, 7330-7336.

9. Nubert, J., Köhler, J., Berenz, V., Allgöwer, F., Trimpe, S., (2020), Safe and fast tracking on a robot manipulator: Robust mpc and neural network control, IEEE Robotics and Automation Letters, 5(2), 3050-3057.

10. Yaren, T., Kizir, S., (2025), Real-time nonlinear model predictive control of a robotic arm using spatial operator algebra theory, Journal of Field Robotics, 42(5), 2337-2354.

11. Tinoco, V., Silva, M. F., Santos, F. N., Morais, R., Magalhães, S. A., Oliveira, P. M., (2025), A review of advanced controller methodologies for robotic manipulators, International Journal of Dynamics and Control, 13, 36.

12. Li, J., Wang, A., Lyu, Y., Ding, Z., (2024), Global path guided model predictive path integral control: Applications to GPU-parallelizable robot simulation systems, Computers and Electrical Engineering, 120(A), 109645.

13. Williams, G., Drews, P., Goldfain, B., Rehg, J. M., Theodorou, E. A., (2018), Information-theoretic model predictive control: theory and applications to autonomous driving, IEEE Transactions on Robotics, 34(6), 1603-1622.

14. Williams, G., Aldrich, A., Theodorou, E. A., (2017), Model predictive path integral control: from theory to parallel computation, Journal of Guidance, Control, and Dynamics, 40(2), 344-357.

15. Lee, M. H., Kim, D. J., Kim, S. J., Suh, J.-H., (2026), Adaptive covariance-based model predictive path integral for robotic manipulator pose control, Proceedings of the Spring Conference of the Korean Society of Precision Engineering, 273.

16. Kim, T., Park. G., Kwak, K., Bae, J., Lee, W., (2022), Smooth model predictive path integral control without smoothing, IEEE Robotics and Automation Letters, 7(4), 10406-10413.

17. Vlahov, B., Gibson, J., Fan, D. D., Spieler, P., Aghamohammadi, A. -a., Theodorou, E. A., (2024), Low frequency sampling in model predictive path integral control, IEEE Robotics and Automation Letters, 9(5), 4543-4550.

18. Kicki, P., (2026), LP-MPPI: Low-pass filtering for efficient model predictive path integral control, arXiv preprint arXiv:2503.11717.

19. Spong, M. W., Hutchinson, S., Vidyasagar, M., (2006), Robot Modeling and Control, John Wiley & Sons.

20. Butterworth, S., (1930), On the theory of filter amplifiers, Experimental Wireless & the Wireless Engineer, 7(85), 536-541.



Mun Haeng Lee
Ph.D. candidate in Intelligent Robot Engineering at Pukyong National University. His research interests include robotics, optimal control, manipulators, and motion planning.
E-mail: leemun417@gmail.com



Sung Jae Kim
Ph.D. in Intelligent Robot Engineering, Pukyong National University in 2024. Since 2026, Senior Researcher at the Korea Institute of Robotics & Technology Convergence. His research interests include control engineering, robust control of nonlinear plants, neuro control, optimal control, robot systems.
E-mail: ksj7020@kiro.re.kr



Jin-Ho Suh
Professor in the Major of Mechanical System Engineering, Division of Energy Transport Systems Engineering, College of Engineering, Pukyong National University. His research interests include disaster response robots, underwater robots, and system control & integration in field robotics.
E-mail: suhgang@pknu.ac.kr