

군집 로봇 편대 제어를 위한 협력 입자 군집 최적화 알고리즘 기반 모델 예측 제어 기법

Cooperative Particle Swarm Optimization-based Model Predictive Control for Multi-Robot Formation

이 승 목, 김 한 근, 명 현*
(Seung-Mok Lee^{1,2}, Hanguen Kim¹, and Hyun Myung^{1,2})

¹Dept. of Civil and Environmental Engineering, KAIST

²Robotics Program, KAIST

Abstract: This paper proposes a CPSO (Cooperative Particle Swarm Optimization)-based MPC (Model Predictive Control) scheme to deal with formation control problem of multiple nonholonomic mobile robots. In a distributed MPC framework, each robot needs to optimize control input sequence over a finite prediction horizon considering control inputs of the other robots where their cost functions are coupled by the state variables of the neighboring robots. In order to optimize the control input sequence, a CPSO algorithm is adopted and modified to fit into the formation control problem. Experiments are performed on a group of nonholonomic mobile robots to demonstrate the effectiveness of the proposed CPSO-based MPC for multi-robot formation.

Keywords: formation control, multi-robot system, MPC (Model Predictive Control), CPSO (Cooperative Particle Swarm Optimization)

I. 서론

군집 로봇 시스템은 탐색, 구조 등과 같은 임무에 있어서 단일 로봇에 비해 많은 장점을 가지고 있기 때문에 지난 십 수 년간 많은 연구가 이루어져 왔다[1,2,4-8]. 군집 로봇 시스템이 탐색, 구조와 같은 임무를 수행하기 위해서는 그룹 내 로봇들이 상대적인 위치를 유지하면서 주어진 경로를 추종하는 편대 제어 기술이 필수적으로 요구된다.

최근에는 최적 제어 기법 중 하나인 모델 예측 제어(MPC: Model Predictive Control) 기법을 이용한 군집 로봇 제어 방식에 대하여 많은 연구가 이루어지고 있다. 모델 예측 제어 기법은 실제 산업 현장에서 성공적으로 적용되고 있는 최적 제어 기법 중의 하나로, 정확하게 모델링된 시스템을 바탕으로 미래 구간 동안의 출력을 예측하여 최적화 과정을 통해 시스템의 최적 제어 입력을 계산하는 방법이다[3]. 참고문헌 [4]은 모델예측제어 방법을 이용한 편대 제어의 근간이 되는 논문으로 분산화된 모델 예측 제어 기법을 제시하였다. 또한 참고문헌 [5]에서는 미분 게임 이론을 적용하여 로봇의 편대

제어를 위해 이동 구간 내쉬 제어(receding horizon Nash control) 알고리즘을 제시하였다. 하지만 위 연구는 로봇을 2차 시스템의 파티클로 모델링 하였으며 제안된 알고리즘의 목적은 편대를 안정화 시키는데 한정되었다. 참고문헌 [6,7]는 비홀로노믹(nonholonomic) 이동 로봇의 편대 제어를 위해 모델 예측 제어 기법을 기반으로 선도-추종(leader-follower) 방식의 비선형 제어를 설계하였다. 이와 비슷하게 [8]에서는 쿼드로터(quadrotor)의 편대 비행을 위해 선도-추종 방식이 사용되었다.

모델 예측 제어 기법 내의 최적화 과정을 위해 기존에는 경사도 탐색(gradient search) [9,10], 이차 계획법(quadratic programming) [11], 혼합정수 선형 계획법(mixed-integer linear programming) [12] 등이 사용되어 왔으며, 최근에는 진화 연산(evolutionary computation) 알고리즘들을 적용하는 다양한 시도가 이루어지고 있다. Onnen 등 [13]은 유전자 알고리즘(genetic algorithm)을 모델 예측 제어 기법에 적용하였으며, 분기 한정법(branch-and-bound method) 과 비교하여 유전자 알고리즘이 효과적으로 적용될 수 있음을 보였다. 그 밖에 위와 비슷한 접근 방법으로 유전자 알고리즘을 예측 제어 기법에 적용한 예를 참고문헌 [14-16]에서 볼 수 있다. 또한 입자 군집 최적화(PSO: Particle Swarm Optimization) 알고리즘이 다수의 구속 조건과 목적 함수가 주어졌을 때에도 빠른 수렴 특성을 보이 기 때문에 입자 군집 최적화 알고리즘을 이용하여 예측 제어 기법의 최적화 문제를 풀려는 시도가 이루어져 왔다[17-20]. 특히 참고문헌 [19]에서 개발된 입자 군집 최적화 기반 모델 예측 제어 방법은 이차 계획법을 이용한 모델 예측 제어 방법과 비교하여 좀더 우수한 성능을 보이는 것을 확인하였다.

최근에는 군집 로봇의 편대 제어 문제를 다루기 위해 협력 입자 군집 최적화(CPSO: Cooperative Particle Swarm Optimization) 기반의 분산화된 모델 예측 제어 기법이 제안되었다[21,22].

* 책임저자(Corresponding Author)

Manuscript received February 20, 2013 / revised March 10, 2013 / accepted March 15, 2013

이승목, 명현: KAIST Urban Robotics Lab. 건설 및 환경공학과, 로봇공학학제전공(seungmok@kaist.ac.kr/hmyung@kaist.ac.kr)

김한근: KAIST Urban Robotics Lab. 건설 및 환경공학과 (sskhk05@kaist.ac.kr)

※ 본 연구는 지식경제부 융복합형 로봇 인력양성 “로봇 지능기술연구센터” 지원사업(NIPA-2012-H1502-12-1002) 및 교육과학기술부 일반연구자지원사업(2012-000-3897)의 지원으로 수행되었음.

※ 국토해양부의 U-City 석·박사과정 지원사업에서 장학금의 지원을 받았음.

※ 본 연구의 실험을 위해 KARPE (KAIST Arena with Real-time Positioning Environment) 시설을 이용할 수 있도록 도움을 주신 KAIST 한재홍 교수님께 감사드립니다.

협력 입자 군집 최적화 기반의 모델 예측 제어 기법은 주변의 이웃하는 로봇들의 미래 예측 구간 동안의 상태 변수에 대한 정보를 주고 받는다. 이때, 협력 입자 군집 최적화 알고리즘은 각 로봇이 주변 이웃하는 로봇들의 정보를 이용해 자신의 제어 입력을 최적화시키기 위해 내쉬 평형점 전략(Nash equilibrium strategy)을 이용한다. 즉, 각 로봇은 입자 군집 (particle swarm) 을 이용해 최적화하면서 매 세대마다 이웃하는 로봇들로부터 미래 구간 동안의 상태 변수 예측 정보를 서로 교환하여 내쉬 평형점에 도달하도록 한다. 협력 입자 군집 최적화 기반의 모델 예측 제어 기법의 성능은 참고문헌 [21,22]을 통해 모의 실험 결과가 제시되었다.

본 논문에서는 군집 로봇 편대 제어를 위한 협력 입자 군집 최적화 기반 모델 예측 제어 기법에 대하여 소개하고 실제 구현에 대하여 다룬다. 기존 연구 [21,22]에서는 실시간 제어를 고려하지 않은 모의 실험 결과만 보여주었으나, 본 논문에서는 군집 로봇의 실시간 제어를 고려하여 알고리즘을 구현하고 실제 군집 시스템에 적용하여 편대 제어 실험에 대한 결과를 제시한다. 또한 기존의 일반적인 입자 군집 최적화 기반 모델 예측 제어 기법 [17-19]을 로봇 편대 제어에 적용해 실험하고 두 방법의 성능을 비교하였다.

본 논문은 다음과 같이 구성되어 있다. II 장에서는 모델 예측 제어 기법 기반의 군집 로봇 시스템의 편대 제어 문제를 소개한 후, 편대 제어 문제를 다루기 위해 도입된 협력 입자 군집 최적화 알고리즘에 대하여 소개한다. III 장에서는 본 논문에서 제안한 협력 입자 군집 최적화 기반의 모델 예측 제어 기법을 제시하고, 이를 실제 실험을 통해 IV 장에서 검증한다. 마지막으로 V 장에서 본 논문을 마무리 한다.

II. 문제 정의

1. 모델 예측 제어 기반의 편대 제어

본 논문에서는 M 개의 이동 로봇으로 구성된 로봇 그룹이 지정된 편대를 이루어 주어진 경로를 추종하는 문제를 다룬다. 그룹에 속해 있는 각각의 이동 로봇 j 의 상태 변수 $X_j = [x_j, y_j, \theta_j]^T$ 의 운동 방정식은 다음과 같이 표현할 수 있다.

$$\dot{x}_j = v_j \cos \theta_j, \quad \dot{y}_j = v_j \sin \theta_j, \quad \dot{\theta}_j = \omega_j \quad (1)$$

x_j, y_j, θ_j 는 절대 좌표계에서의 이동 로봇 j 의 위치와 방향각을 의미하며, v_j 와 ω_j 는 각각 로봇의 선속도와 각속도 제어 입력을 의미한다.

편대 명령은 각 로봇에 대한 상대 위치를 로봇 편대 중심에서 정의된 좌표계에서 $F = \{[f_{1x}, f_{1y}], \dots, [f_{Mx}, f_{My}]\}$ 으로 표현할 수 있으며, $\sum_{i=1}^M f_{ix} = 0, \sum_{i=1}^M f_{iy} = 0$ 의 관계가 만족하도록 주어진다. 기준 경로는 $X_r = [x_r, y_r, \theta_r]^T$ 로 표기하며, 그룹 내 일부 로봇들만이 알고 있다고 가정하였다.

편대 제어를 위한 로봇 j 에 대한 에러는 다음과 같이 정의한다.

$$e_j = \begin{bmatrix} e_{jx} \\ e_{jy} \\ e_{j\theta} \end{bmatrix} = \begin{bmatrix} \cos \theta_j & \sin \theta_j & 0 \\ -\sin \theta_j & \cos \theta_j & 0 \\ 0 & 0 & 1 \end{bmatrix} z_{je} \quad (2)$$

이때, $\tilde{X}_j = X_r + P_j - X_j$ 으로 표현되며, $z_{je} = \sum_{i \in \Omega_j} (\tilde{X}_j - \tilde{X}_i) + \tilde{X}_j$ 는 절대 좌표계에서 표현된 에러 값, e_j 는 로봇 고정 좌표계에서 표현된 에러 값이다. Ω_j 는 로봇 j 와 이웃하는 로봇들의 색인 집합을 의미한다. e_j 의 미분을 통해 다음과 같이 에러 상태 방정식을 구할 수 있다.

$$\begin{aligned} \dot{e}_{jx} &= \omega_j e_{jy} + \sum_{i \in \Omega_j} (v_i \cos \theta_{ij} - v_j) + \mu_j (v_r \cos \tilde{\theta}_j - v_j), \\ \dot{e}_{jy} &= -\omega_j e_{jx} + \mu_j v_r \sin \tilde{\theta}_j + \sum_{i \in \Omega_j} v_i \sin \theta_{ij}, \\ \dot{e}_{j\theta} &= \sum_{i \in \Omega_j} (\omega_i + \omega_j) + \mu_j (\omega_r + \omega_j), \end{aligned} \quad (3)$$

θ_{ij} 는 $\theta_i - \theta_j$ 를 나타내며, v_r 과 ω_r 은 각각 기준 경로에 의해 구해지는 선속도 값과 각속도 값을 나타낸다. 로봇이 기준 경로를 알고 있는 경우 $\mu=1$, 그렇지 않은 경우 $\mu=0$ 으로 주어진다. 식 (3)는 일반적인 형태로 다음과 같이 나타낸다.

$$\dot{e}_j(t) = f(e_j(t), u_j(t)) \quad (4)$$

$u_j = [v_j, \omega_j]^T$ 는 로봇의 선속도와 각속도에 대한 제어 입력을 나타낸다.

분산화된 모델 예측 제어 기법 구조 내에서 각 로봇이 최적화 시켜야 할 비용 함수는 다음과 같이 정의되었다.

$$J_j(t, e_j(t)) = \int_t^{t+T} e_j^T(\tau) Q e_j(\tau) d\tau \quad (5)$$

Q 는 양정치(positive definite) 가중 행렬을 나타내며, T 는 예측 구간을 나타낸다.

시간 t 에서의 분산화된 모델 예측 제어 기법 구조 내에서 최적화 시켜야 할 문제는 다음과 같이 공식화 할 수 있다.

$$\min_{u_j} J(t, e_j(t)) \quad (6)$$

제한 조건:

$$\begin{aligned} \dot{e}_j(\tau) &= f(e_j(\tau), u_j), \\ 0 \leq v_j(\tau) &\leq V_{\max}, \\ |\omega_j(\tau)| &\leq \Omega_{\max}. \end{aligned}$$

이때, ($\tau \in [t, t+T]$) 이며, V_{\max}, Ω_{\max} 는 각각 로봇의 최대 선속도와 각속도를 나타낸다.

2. 협력 입자 군집 최적화 알고리즘

입자 군집 최적화 알고리즘은 Kennedy와 Eberhart [23]에 의해 개발된 진화 연산 기법 중의 하나이다. 각 입자들은 후보 해로 간주되며, 서로 위치와 움직임의 갱신을 반복적으로 수행하여 최적 해를 찾는다. 이때, 각각의 입자들은 두 개의 최적 값에 의하여 갱신되는데, 입자 자신의 가장 좋은 값을 갖는 개별 최적해(personal best)와 모든 입자들 중에서 가장 좋았던 값을 갖는 전역 최적해(global best)에 의하여 각 입자들의 위치와 속도를 갱신한다. \mathbf{x}_i^t 는 i 번째 입자의 위치, \mathbf{v}_i^t 는 i 번째 입자의 속도, \mathbf{p}_i^t 는 i 번째 입자의 개별 최적해, \mathbf{p}_g^t 는

전역 최적해 라고 정의 하자. 그리고 아래첨자 l 은 현재 세대까지의 진화 횟수를 나타내는 색인이라고 할 때, \mathbf{x}_l^i 입자의 위치와 속도는 다음 식에 의하여 갱신된다.

$$\begin{aligned} \mathbf{x}_{l+1}^i &= \mathbf{x}_l^i + \mathbf{v}_{l+1}^i, \\ \mathbf{v}_{l+1}^i &= \varphi_l \mathbf{v}_l^i + c_1 r_1 (\mathbf{p}_l^i - \mathbf{x}_l^i) + c_2 r_2 (\mathbf{p}_l^g - \mathbf{x}_l^i). \end{aligned} \quad (7)$$

이때, φ_l 은 관성 계수로 연산이 반복될 때마다 선형적으로 감소되며, c_1 과 c_2 는 가속도 계수, r_1 과 r_2 는 $[0, 1]$ 의 범위에서 균등하게 발생하는 랜덤 변수이다.

협력 입자 군집 최적화 알고리즘은 입자 군집 최적화 알고리즘의 변형으로 다중 입자 군집을 이용하여 각 군집들이 문제의 서로 다른 변수들을 맡아 최적화시켜 다중 군집을 동시에 진화시키는 공진화 기법의 일종이다. 이러한 시도는 Bergh와 Engelbrecht [24]에 의해 이루어졌으며, 최근에는 Li와 Yao [25,26]에 의하여 그 성능이 입증되었다.

사실 협력 입자 군집 최적화 알고리즘은 높은 차원의 최적화 문제를 다루기 위해 개발되었으나, 본 논문에서는 분산화된 모델 예측 제어 기법에 의해 운영되는 군집 로봇 시스템의 내쉬 평형점을 찾기 위해 사용되었다.

III. 협력 입자 군집 최적화 기반의 모델 예측 제어 기법

각 로봇이 최적화 시켜야 할 비용 함수는 이웃하는 로봇들의 상태 변수 및 제어 입력 값과 결합된 형태로 정의되어 있다. 또한 각 로봇은 하나의 입자 군집을 갖고 있으며 그것을 이용해 주어진 비용 함수를 최적화 시킨다. 군집 로봇 간 내쉬 평형점에 도달하기 위하여 각 로봇은 입자 군집 최적화 알고리즘의 매 세대마다 발생하는 전역 최적 입자를 이웃하는 로봇들의 전역 최적 입자들과 서로 교환한다.

제안된 협력 입자 군집 최적화 알고리즘에서 사용되는 입자의 표현형은 다음과 같다. $P_j \cdot \mathbf{x}_l^i$ 는 l 세대에서의 j 번째 입자 군집 i 번째 입자의 위치를 표현한다. $P_j \cdot \mathbf{y}_l^i$ 는 j 번째 입자 군집 i 번째 입자의 개별 최적 입자를 나타낸다. $P_j \cdot \hat{\mathbf{y}}_l^i$ 는 j 번째 입자 군집의 전역 최적 입자를 나타낸다. 각 입자 $P_j \cdot \mathbf{x}_l^i$ 는 업데이트 시간 t_k 에서 계산된 예측 구간 T 동안의 제어 입력 $u_j(t) = [v_j(t), \omega_j(t)]^T$ 의 시계열을 나타내며 다음과 같이 표현된다.

$$P_j \cdot \mathbf{x}_l^i = [v_j(t_{k+1}; t_k), v_j(t_{k+2}; t_k), \dots, v_j(t_{k+N-1}; t_k), \omega_j(t_{k+1}; t_k), \omega_j(t_{k+2}; t_k), \dots, \omega_j(t_{k+N-1}; t_k)] \quad (8)$$

이때, $0 \leq v_j(t_{k+m}; t_k) \leq V_{\max}$, $|\omega_j(t_{k+m}; t_k)| \leq \Omega_{\max}$, $m = 0, 1, 2, \dots, N-1$ 의 조건을 만족하며, $N = T/\delta t$ 은 예측 구간의 스텝 수를 나타낸다. 최적화 과정이 수행되는 업데이트 시간은 $t_k = t_0 + \delta t \cdot k, (k = 0, 1, 2, \dots)$ 으로 표현할 수 있다.

제안된 협력 입자 군집 최적화 기반 모델 예측 제어 기법 알고리즘의 흐름도는 그림 1과 같다. 알고리즘의 전체적인 구조는 로봇의 현재 위치 측정, 협력 입자 군집 최적화를 통한 예측 구간 동안의 최적 제어 입력 계산, 계산된 제어 입력의 적용의 단계로 구성되어 있다. 먼저 로봇의 현재 위치

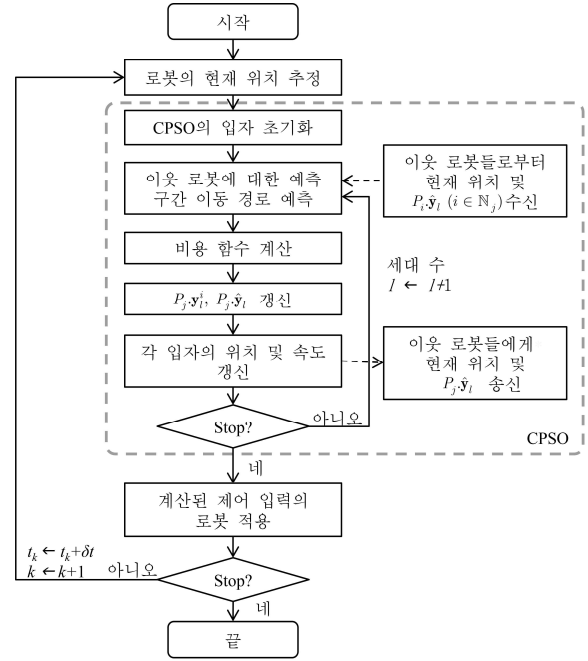


그림 1. 협력 입자 군집 최적화 기반 모델 예측 제어 기법 흐름도.

Fig. 1. Flowchart of CPSO-based MPC.

를 추정 후, 협력 입자 최적화 알고리즘을 통해 각 로봇의 최적 제어 입력을 계산한다. 협력 입자 최적화 알고리즘의 입자 초기화는 $0 \leq v_j \leq V_{\max}$ 과 $|\omega_j| \leq \Omega_{\max}$ 을 만족하도록 균일하게 무작위로 분포시킨다. 각 로봇 j 는 주변 이웃하는 로봇들과 각 로봇들에 의해 찾아진 전역 최적해 입자를 서로 주고 받고, 그 정보를 이용하여 예측 구간 동안의 주변 로봇들의 이동 경로를 예측한다. 예측된 주변 로봇들의 이동 경로를 바탕으로 협력 입자 군집 최적화 알고리즘을 통해 식 (6)에서 정의된 비용함수를 최소화 시키는 제어 입력 시계열을 계산한다.

M 대의 로봇이 존재하는 군집 로봇 시스템을 가정할 경우, 로봇 j 는 그들의 비용 함수 J_j 를 최적화 시켜야 하며 이때, 각 $P_j \cdot \mathbf{x}_l^i$ 의 비용함수 J_j 를 계산하기 위하여 이웃 로봇들로부터 전역 최적해 입자들을 받아 온다. 이를 통해 계산된 비용 함수를 바탕으로 업데이트 법칙에 의해 각 입자들을 업데이트 시킨 후 자신의 전역 최적해 입자를 이웃하는 로봇들에게 전파한다.

각 입자의 위치와 속도의 업데이트 법칙은 식 (7)의 기존의 입자 군집 최적화 알고리즘의 업데이트 법칙을 기반으로 다음과 같이 표현할 수 있다.

$$\begin{aligned} P_j \cdot \mathbf{x}_{l+1}^i &= P_j \cdot \mathbf{x}_l^i + P_j \cdot \mathbf{v}_{l+1}^i, \\ P_j \cdot \mathbf{v}_{l+1}^i &= \varphi_l P_j \cdot \mathbf{v}_l^i + c_1 r_1 (P_j \cdot \mathbf{y}_l^i - P_j \cdot \mathbf{x}_l^i) + c_2 r_2 (P_j \cdot \hat{\mathbf{y}}_l^i - P_j \cdot \mathbf{x}_l^i) \end{aligned} \quad (9)$$

협력 입자 군집 최적화 의 세대를 반복하더라도 비용 함수가 더 이상 줄어들지 않을 때는 각 로봇들이 내쉬 평형점에 도달했다고 가정하고, 계산된 최적 제어 입력 시계열 즉, $P_j \cdot \hat{\mathbf{y}}_l^i$ 중에서 첫 번째 구간에 해당하는 제어 입력 $[v_j(t_k; t_k),$

$\omega_j(t_k; t_k)^T$ 을 $[t_k, t_k + \delta t)$ 구간 동안 로봇 j 에게 적용한다. 그리고 계산된 전역 최적해 입자 P_j, \hat{y}_j 는 로봇 j 와 이웃하는 주변 로봇들에게 전파한다. 단, 각 로봇들이 최적화 과정을 수행할 때 서로 동기화 되어 동시에 최적화 과정을 수행해야 한다. 또한 각 협력 입자 군집 최적화 과정에서의 진화 세대 수는 최대 진화 세대 수를 넘길 경우에는 준 최적해로 가정하고 계산된 최적 제어 입력을 위와 같은 방법으로 로봇에 적용한다.

로봇의 최적 제어 입력 값이 계산되어 업데이트 될 때마다 새롭게 이동한 위치에서의 최적 제어 입력 값을 다시 계산하기 위하여 각 로봇이 갖고 있는 입자 군집들은 초기화 되어야 한다. 이때, 각 입자 군집들의 전역 최적해는 그대로 유지시켜 이전 업데이트 시간에서의 전역 최적해 값을 바탕으로 최적화를 시킨다. 이를 통해 좀더 빠른 수렴 속도를 빠르게 할 수 있다.

IV. 실험 결과

본 장에서는 제안된 알고리즘의 성능을 검증하기 위해 3대의 이동 로봇에 적용하고 그 실험 결과를 제시한다. 실험에 사용된 로봇은 CNRobot 사 [27]에서 제작한 CRX10 (그림 2)으로 차동 구동 이동 로봇이 사용되었다. 로봇들의 위치 인식을 위해 Motion Analysis 사의 Eagle Digital Realtime System (<1mm 정확도)이 구축되어 있는 환경 [28]에서 실험을 수행하였다. 로봇들과 Eagle Digital Realtime System과의 통신, 로봇간 정보를 주고 받기 위한 통신은 TCP/IP 프로토콜을 통해 구현하였다. 각 로봇에 대한 제어 입력은 랩탑 컴퓨터를 통해 5Hz 의 속도로 계산한다. 예측 구간 T 가 길어지면 계산 시간이 증가하기 때문에 실시간 로봇 편대 제어에 적용이 어렵다. 따라서 계산 속도를 고려하여 예측 구간 T 와 예측 간격 δt 를 각각 $T = 2s$, $\delta t = 0.2s$ 으로 설정하였다. 가중치 행렬은 $Q = \text{diag}[0.1, 0.1, 0.001]$ 으로 설정하였다.

각 입자 군집의 개체 수는 100이며, 각 입자 군집당 최대 진화 세대 수는 100으로 제한하였다. 참고문헌 [23]의 제안에 따라 관성 가중치 ϕ_i 은 입자들이 세대수가 증가함에 따라 0.9에서 0.4까지 선형적으로 감소하도록 설정하였으며, 가속도 계수는 $c_1 = 2.0$, $c_2 = 2.0$ 으로 설정하였다. 로봇의 최대 선속도 및 각속도를 고려하여 $V_{\max} = 0.5 \text{ m/s}$, $\Omega_{\max} = \pi/2 \text{ rad/s}$ 으로 설정하였으며, 각 입자 군집들의 검색 영역 (search space) 을 $[0, V_{\max}]$ 과 $[-\Omega_{\max}, \Omega_{\max}]$ 으로 제한하였다.

로봇 편대가 추종해야 할 기준 경로는

$$\begin{aligned} x_r(t) &= 3 \cos(\omega t), \\ y_r(t) &= 3 \sin(\omega t), \end{aligned} \quad (10)$$

으로 주어졌으며, $\omega = 0.1 \text{ rad/s}$ 이며, 기준 경로는 로봇 1 만이 알고 있다고 가정하였다. 편대 명령은 삼각 편대로 다음과 같이 주어졌다.

$$F = \{[0, 0.5], [0.25\sqrt{3}, -0.25], [-0.25\sqrt{3}, -0.25]\}$$

알고리즘의 성능을 측정하기 위해 다음과 같이 성능 지표를 정의하였다.




그림 2. 실험에 사용된 3대의 차동 구동 이동 로봇 (CRX 10).
Fig. 2. The three differential wheeled mobile robots used in the experiments (CRX 10).

$$E(t) = \sqrt{\frac{1}{M} \sum_{j=1}^M e_j^r(t) Q e_j(t)}. \quad (11)$$

협력 입자 군집 최적화 기반 모델 예측 제어 기법과 기존 일반적인 입자 군집 최적화 기반 모델 예측 제어 기법 [17-19]을 군집 로봇 편대 제어에 적용하여 실험 결과를 통해 성능을 비교하였다. 그림 3은 기존의 일반적인 입자 군집 최적화 기반 모델 예측 제어 기법에 의한 실험 결과를 보여준다. 그림에서 삼각형은 12초 마다 샘플 된 로봇들의 위치를 나타내며 원은 편대 중심의 위치를 나타낸다. 실선은 로봇 편대가 추종해야 할 기준 경로를 나타낸다. 결과를 보면, 3대의 로봇이 삼각 편대를 유지하면서 주어진 경로를 추종하는 로봇 궤적이 기준 경로를 정확히 따라가지 못하고 불안정한 것을 확인할 수 있다. 반면 그림 4의 협력 입자 군집 최적화 기반 모델 예측 제어 기법은 편대를 유지하면서 주어진 경로를 안정적으로 추종하는 것을 확인할 수 있다. 그림 5는 식 (11)에 의해 계산된 성능 지표를 보여준다. 두 방법의 성능 지표 비교를 통해 협력 입자 군집 최적화 기반 모델 예측 제어 기법과 비교하여 효과적임을 확인할 수 있다.




그림 3. 기존 일반적인 입자 군집 최적화 기반 모델 예측 제어 기법에 의한 로봇 3대의 궤적 (삼각형), 로봇 편대 중심 (원), 기준 경로 (실선).

Fig. 3. Trajectories of the three robots by the conventional PSO-based MPC (triangle), formation center (circle), reference trajectory (solid line).




그림 4. 협력 입자 군집 최적화 기반 모델 예측 제어 기법에 의한 로봇 3대의 궤적 (삼각형), 로봇 편대 중심 (원), 기준 경로 (실선).

Fig. 4. Trajectories of the three robots by the CPSO-based MPC (triangle), formation center (circle), reference trajectory (solid line).

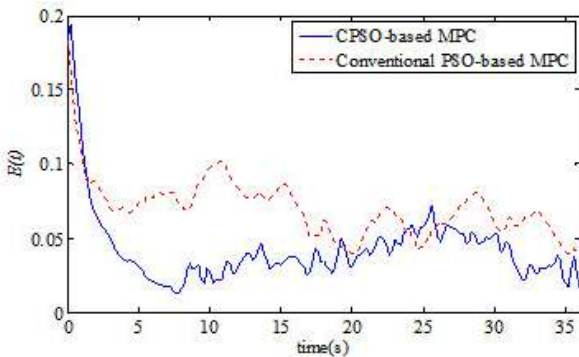


그림 5. 성능 지표 비교.

Fig. 5. Comparison of performance indices.

V. 결론

본 논문에서는 군집 로봇의 편대 제어를 위한 협력 입자 군집 최적화 기반 모델 예측 제어 기법을 제안하였다. 군집 로봇들은 주어진 경로에 대하여 편대를 유지하면서 효과적으로 경로 추종을 하기 위해 다른 로봇의 미래 구간 동안의 움직임을 전달 받아 최적의 제어 입력을 계산한다. 실험을 통해 기존의 일반적인 입자 군집 최적화 기반 모델 예측 제어 기법과 비교하여 제안된 알고리즘이 편대 제어 및 경로 추종에 있어 효과적임을 확인하였다. 향후에는 제안된 협력 입자 군집 최적화 기반 모델 예측 제어 기법의 안정성에 대하여 연구할 예정이다. 또한 제안된 알고리즘과 기존 해석해 기반 모델 예측 제어 기법의 계산 시간을 측정하여 실시간 적용 측면에서 성능 비교를 할 계획이다.

참고문헌

[1] S. Kim, S. Cho, S.-B. Cho, and C.-B. Park, "Development of operation network system and processor in the loop simulation for swarm flight of small UAVs," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 18, no. 5, pp. 433-438, 2012.

[2] H. Kim, H. Shim, and J. Back, "Formation control algorithm for coupled unicycle-type mobile robots through switching interconnection topology," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 18, no. 5, pp. 439-444, 2012.

[3] F. A. C. C. Fontes, "A general framework to design stabilizing nonlinear model predictive controllers," *Systems & Control Letters*, vol. 42, pp. 127-143, 2001.

[4] W. B. Dunbar and R. M. Murray, "Distributed receding horizon control for multi-vehicle formation stabilization," *Automatica*, vol. 42, no. 4, pp. 549-558, 2006.

[5] D. Gu, "A differential game approach to formation control," *IEEE Transactions on Control Systems Technology*, vol. 16, no. 1, pp. 85-93, Jan. 2008.

[6] J. Chen, D. Sun, J. Yang, and H. Chen, "Leader-follower formation control of multiple non-holonomic mobile robots incorporating a receding-horizon scheme," *International Journal of Robotics Research*, vol. 29, no. 6, pp. 727-747, May 2010.

[7] D. Gu and H. Hu, "A model predictive controller for robots to follow a virtual leader," *Robotica*, vol. 27, no. 6, pp. 905-913, Oct. 2009.

[8] M. Turpin, N. Michael, and V. Kumar, "Trajectory design and control for aggressive formation flight with quadrotors," *Autonomous Robots*, vol. 33, no. 1-2, pp. 143-156, Aug. 2012.

[9] G. J. Sutton and R. R. Bitmead, "Computational implementation of NMPC to nonlinear submarine," *Nonlinear Model Predictive Control*, vol. 26, pp. 461-471, 2000.

[10] Y. Yoon, J. Shin, H. J. Kim, Y. Park, and S. Sastry, "Model-predictive active steering and obstacle avoidance for autonomous vehicles," *Control Engineering Practice*, vol. 17, no. 7, pp. 741-750, Jul. 2009.

[11] J. Yan and R. R. Bitmead, "Incorporating state estimation into model predictive control and its application to network traffic control," *Automatica*, vol. 41, no. 4, pp. 595-604, Apr. 2005.

[12] A. Richards and J. How, "Decentralized model predictive control of cooperating UAVs," *Proc. of the 43rd Conf. Decision and Control*, pp. 4286-4291, Dec. 2004.

[13] C. Onnen, R. Babuska, U. Kaymak, J. M. Sousa, H. B. Verbruggen, and R. Iserman, "Genetic algorithms for optimization in predictive control," *Control Engineering Practice*, vol. 5, no. 10, pp. 1363-1372, 1997.

[14] M. L. Fravolini, A. Ficola, and M. L. Cava, "Real-time evolutionary algorithms for constrained predictive control," *Frontiers in Evolutionary Robotics*, InTech, pp. 139-184, Apr. 2008.

[15] M. Martinez, J. S. Senent, and X. Blasco, "Generalized predictive control using genetic algorithms," *Engineering Applications of Artificial Intelligence*, vol. 11, no. 3, pp. 355-367, 1997.

[16] S. C. Shin and S. B. Park, "GA based predictive control for nonlinear processes," *Electronics Letters*, vol. 34, no. 20, pp. 1980-1981, 1998.

[17] A. J. Newman, S. R. Martin, J. T. DeSena, J. C. Clarke, J. W. McDerment, W. O. Preissler, and C. K. Peterson, "Receding horizon controller using particle swarm optimization for closed-loop ground target surveillance and tracking," *Proceedings of SPIE 2009*, vol. 7336, 2009.

- [18] M. S. Yousuf, *Nonlinear Predictive Control using Particle Swarm Optimization: Application to Power Systems*, VDM Verlag Dr. Muller, 2010.
- [19] J. Mercieca and S. G. Fabri, "Particle swarm optimization for nonlinear model predictive control," *Engineering Applications of Artificial Intelligence, Proceedings of the 5th Conference on Advanced Engineering Computing and Applications in Sciences*, pp. 88-93, 2011.
- [20] M. Sedraoui and S. Abdelmalek, "Multivariable generalized predictive control using an improved particle swarm optimization algorithm," *Informatica*, vol. 35, no. 3, pp. 363-374, 2011.
- [21] S.-M. Lee and H. Myung, "Particle swarm optimization-based distributed control scheme for flocking robots," *Proc. of the 1st International Conference on Robot Intelligence Technology and Applications 2012*, Gwangju, Korea, Dec. 2012.
- [22] S.-M. Lee and H. Myung, "Cooperative particle swarm optimization-based predictive controller for multi-robot formation," in *Proceedings of the 12th International Conference on Intelligent Autonomous Systems*, Jeju Island, Korea, Jun. 2012.
- [23] J. Kennedy and R. C. Eberhart, *Swarm Intelligence*, Morgan Kaufmann Publishers, 2001.
- [24] F. van den Bergh and A. Engelbrecht, "A cooperative approach to particle swarm optimization," *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 3, pp. 225-239, Jun. 2004.
- [25] X. Li and X. Yao, "Tackling high dimensional nonseparable optimization problems by cooperatively coevolving particle swarms," *Proceedings of IEEE Congress on Evolutionary Computation*, pp. 1546-1553, May 2009.
- [26] X. Li and X. Yao, "Cooperatively coevolving particle swarms for large scale optimization," *IEEE Transactions on Evolutionary Computation*, vol. 16, no. 2, pp. 210-224, Apr. 2012.
- [27] CNRobot Co., Ltd., <http://www.cnrobot.co.kr/en/>.
- [28] KAIST Arena with Real-time Positioning Environment (KARPE), <http://karpe.kaist.ac.kr/>.



이 승 목

2006년 중앙대학교 물리학과 졸업. 2008년 과학기술연합대학원대학교 위성시스템 및 활용공학 석사. 2009년~현재 KAIST 건설 및 환경공학과(로봇공학학제) 박사과정 재학중. 관심분야는 군집 로봇 제어, 로봇 네비게이션.



김 한 군

2009년 경희대학교 전자전파공학과 졸업. 2011년 동 대학원 전자 전파공학과 석사. 2011년~현재 KAIST 건설 및 환경공학과 박사과정 재학중. 관심분야는 이동 로봇 네비게이션, AI.



명 현

1992년 KAIST 전기 및 전자공학학부 졸업. 1994년 동 대학원 석사. 1998년 동 대학원 박사. 1998년~2002년 ETRI 선임 연구원. 2002년~2003년 (주)이머시스 CTO, 연구소장 겸임. 2003년~2008년 삼성종합기술원 전문연구원. 2008년~현재 KAIST 건설 및 환경공학과 교수, 로봇공학학제 전공 겸임. 관심분야는 로봇 네비게이션, 위치인식, 구조물 건전도 진단, 수상/수중 로봇, 군집 로봇.