

심우주 궤적 최적화를 위한 ISHACDE-ADCP: 차원별 적응 Cauchy 섭동을 결합한 차분 진화 알고리즘 (ISHACDE-ADCP: Adaptive Dimension-wise Cauchy Perturbation for Deep-Space Trajectory Optimization)

최태종*

(Tae Jong Choi)

요약

심우주 탐사 임무에서 우주선 궤적 최적화는 강한 비선형성과 중첩된 다중 퍼널 탐색 구조로 인해 전역 최적해 탐색이 어렵다. 특히 다중 중력보조가 포함된 문제는 해공간의 민감도가 높아, 차분 진화 기반 기법에서도 조기수렴 및 정체가 빈번히 발생한다. 본 연구는 이러한 한계를 완화하기 위해 Independent Success History Adaptation Competitive Differential Evolution에 Adaptive Dimension-wise Cauchy Perturbation을 결합한 ISHACDE-ADCP를 제안한다. 제안 알고리즘은 차원별 수렴 수준을 추정하고 점프 확률을 조절하여 Cauchy 섭동을 적용한다. 이를 통해 다양성이 빠르게 소실된 차원에는 강한 재탐색을 부여하고, 다양성이 유지되는 차원에는 교란을 억제하여 탐색-수렴 균형을 개선한다. 성능 검증은 GTOPIX를 대상으로 수행되며, ISHACDE와의 비교를 통해 해 품질과 수렴 안정성을 분석했다.

■ 중심어 : 심우주 궤적 최적화 ; 다중 중력보조 ; 차분 진화 ; 차원별 적응 Cauchy 섭동

Abstract

Space mission trajectory optimization in the preliminary design of deep-space missions is challenging due to strong nonlinearity and nested multi-funnel landscapes, especially for multiple-gravity-assist (MGA) problems where differential evolution (DE) often stagnates and prematurely converges. We propose ISHACDE-ADCP, which augments Independent Success History Adaptation Competitive Differential Evolution (ISHACDE) with Adaptive Dimension-wise Cauchy Perturbation (ADCP). ISHACDE-ADCP retains ISHACDE's competitive exploration-exploitation switching and independent success-history parameter adaptation, while injecting targeted diversity during crossover. At each generation, the algorithm estimates a convergence level for every decision variable from the reduction of population dispersion and maps it to a dimension-specific jumping rate. When a dimension becomes over-converged, a Cauchy perturbation is applied with higher probability, encouraging re-exploration; otherwise the operator is suppressed to avoid unnecessary disruption. We evaluate the proposed method on the GTOPIX benchmark suite and compare it with ISHACDE in terms of solution quality and robustness across repeated runs. Additional analyses of convergence curves and dimension-wise jumping-rate dynamics illustrate how ADCP mitigates stagnation without sacrificing late-stage refinement.

■ keywords : Space mission trajectory optimization ; Multiple-gravity-assist ; Differential evolution ; Adaptive dimension-wise Cauchy perturbation

1. 서론

심우주 탐사 임무의 설계 단계에서 핵심적인 과제는, 발사 기회, 총 비행시간, 추진제 소모 등 주어진

* 정회원, 전남대학교

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00242528).

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00214326).

이 논문은 전남대학교 학술연구비(과제번호: 2024-0389) 지원에 의하여 연구되었음

접수일자 : 2026년 01월 14일

게재확정일 : 2026년 02월 27일

수정일자 : 2026년 01월 25일

교신저자 : 최태종 e-mail : ctj17@jnu.ac.kr

임무 요구조건을 만족하는 후보 궤적을 탐색하고 그중 최적 궤적을 결정하는 일이다[11, 5]. 이 문제는 일반적으로 연료 최소화와 임무 제약조건을 동시에 만족해야 하는 전역 최적화 문제로 정식화되며, 비선형·블랙박스·고차원 특성 때문에 제한된 계산 하에서 안정적으로 우수 해를 확보하는 것이 어렵다고 보고되어 왔다[6]. 특히 다중 중력 보조 (Multiple Gravity Assist, MGA) 기반 임무는 행성 스윙바이, 공전역학 및 제약조건이 결합되면서 탐색 공간이 민감하고 강한 비선형성을 가지며, 다수의 국소 최적해가 공존하는 복잡한 구조를 형성한다[4, 7, 9].

진화연산 기반 기법 중 차분 진화(Differential Evolution, DE)는 단순한 구조와 구현 용이성에도 불구하고 연속 최적화에서 경쟁력 있는 성능을 보여 심우주 궤적 최적화에도 널리 적용되어 왔다[1, 6]. 그러나 DE 계열 알고리즘은 변이 전략 및 제어 매개변수 설정이 성능에 큰 영향을 미치며, 탐색이 진행되면서 개체군 다양성이 감소할 경우 조기수렴 (premature convergence) 또는 정체(stagnation)가 발생하여 전역 탐색 능력이 저하될 수 있다[8, 13]. 이에 따라 최근 연구들은 지식/학습 기반 적응 (CLDE)[5], 유도 이동(guided movement) 기반 (G-DE)[4], 자기학습(self-learning) 기반 DE[11], 하이브리드 LSHADE 계열[9], 강화학습 결합 (RL-HDE)[7], 다중 연산자·이주 전략 (IMODE TMS)[1] 등 다양한 고도화 기법을 제안하며 성능 개선을 시도하고 있다.


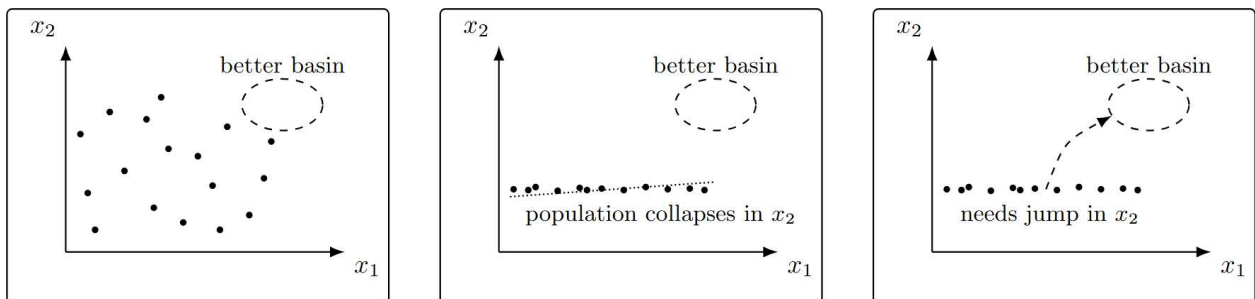


그림 1. MGA 궤적의 기하학적 구조

이러한 연구 흐름 속에서 Zhong 등은 Independent Success History Adaptation Competitive Differential Evolution (ISHACDE)을 제안하여, space mission trajectory optimization (SMTO) 문제에서 안정적인 성능 향상을 도모하였다[6]. 그럼에도 심우주 궤적 최적화에서는 변수별로 수렴·정체 양상이 이질적으로 발생할 수 있으며, 단일한 다양성 주입 메커니즘만으로는 특정 차원에서의 다양성 붕괴가 전체 해 품질을 제한하는 병목으로 작용할 가능성이 있다(그림 2)[13]. 이를 보완하기 위해 본 연구는 ISHACDE의 적응 메커니즘을 유지하면서, Cauchy 섭동의 heavy-tail 특성을 이용하여 이를 차원별로 적응화하는 Adaptive Dimension-wise Cauchy Perturbation (ADCP) 개념을 결합한 ISHACDE-ADCP를 제안한다. 제안 기법은 GTOPIX 기반 SMTO 벤치마크[12]에서 성능을 평가하여, 전역 수렴성·탐색 신뢰성 및 다양한 임무 문제에 대한 적용 가능성을 검증하는 것을 목



(a) Initial: sufficient diversity (b) Mid: diversity collapse (c) Consequence: bottleneck blocks improvement

그림 2. 차원별 다양성 붕괴의 개념도. 일부 차원에서는 개체군 다양성이 유지되더라도, 특정 차원에서 다양성이 붕괴하면 더 우수한 해(궤적) 영역(better basin)으로의 진입이 제한되어 성능 향상이 정체될 수 있음을 나타낸다.

표로 한다[6].

논문의 구성은 다음과 같다. 2장에서는 관련 연구를 소개한다. 3장에서는 ISHACDE-ADCP의 구성 요소와 차원별 Cauchy 섭동 결합 방식을 기술한다. 4장에서는 실험 결과 및 통계적 비교를 제시한다. 5장에서는 결론 및 향후 연구 방향을 논의한다.

II. 관련 연구

1. 심우주 궤적 최적화와 진화연산의 개괄

우주선 궤적 최적화 분야에서는 동역학 모델, 목적함수, 제약조건 및 수치적 접근이 다양한 형태로 발전해 왔으며, 전역 탐색 기법들이 폭넓게 검토되어 왔다. Shirazi 등은 궤적 최적화의 모델·목적·해법을 폭넓게 정리하며, 문제 특성에 따라 단일 알고리즘보다 하이브리드/적응형 접근이 활용되는 경향을 보여준다[3].

2. DE 기반 SMTO 고도화 연구

- **Restart/다양성 기반 개선:** Vasile 등은 inflationary differential evolution(IDEA)을 제시하며, guided restart를 통해 기만적 지역최소에 의한 정체 가능성을 낮추는 방향을 제안하였다[8].
- **지식 학습 기반:** Zuo 등은 case learning-based differential evolution(CLDE)을 제안하고, 사례 기반 학습을 통해 세대별로 동적 지식 전달과 매개변수 자기적응을 수행하여 GTOX 문제들에서 경쟁력 있는 성능 및 일부 새로운 최적해를 보고하였다[5].
- **유도 이동 기반:** Zuo 등은 guided movement를 도입한 G-DE를 제안하여, 개체군을 그룹화하고 두 단계 진화 과정(전역 구조 학습 후 guided 이동)을 통해 탐색 안정성과 다양성을 강화하는 접근을 제시하였다[4].
- **자기학습(Self-learning) 기반:** Choi 등은

self-learning 기반 DE를 제안하고, 변이 전략 풀을 구축·선택·업데이트하는 메커니즘과 조기 수렴 대응을 위한 reinitialization을 포함한 구조를 제시하였다[11].

- **하이브리드 LSHADE 계열:** Tang 등은 하이브리드 LSHADE를 제안하고, 문제 특화 초기화 및 국소 탐색 전략을 결합해 탐색 능력을 강화하는 방향을 제시하였다[9].
- **강화학습 결합:** Peng 등은 Q-learning을 이용해 다중 변이 전략을 선택하는 reinforcement learning-based hybrid DE(RL-HDE)를 제안하여, 탐색-수렴 균형을 적응적으로 조절하는 접근을 제시하였다[7].
- **다중 연산자 + 이중 전략:** Yuan 등은 improved multi-operator DE(IMODE TMS)를 제안하고, two-phase migration 전략을 통해 수치 최적화 및 우주 궤적 최적화 문제에서 성능 개선을 목표로 했다[1].
- **ISHACDE:** Zhong 등은 ISHACDE를 제안하고, scaling factor의 독립 적응(차분 벡터별 상이한 F)을 핵심 아이디어로 GTOX 기반 벤치마크에서 경쟁력을 검증하였다[6].

3. 탐색공간 축소/전처리 기반 연구

Song 등은 solar system boundary exploration 임무의 중력보조 설계에서 encounter sequence 후보를 pruning하여 탐색공간을 줄이고, GTOX의 MGA 문제들로 검증하는 프레임워크를 제시하였다[10]. 이는 “알고리즘 자체 고도화”뿐 아니라 “문제 구조를 이용한 후보 축소”가 성능과 계산 효율성에 크게 기여할 수 있음을 시사한다[10].

4. 본 연구의 차별성

기존 DE 기반 SMTO 고도화 연구들은 (i) restart/재초기화로 정체를 완화하거나, (ii) 학습·강화학습을 통해 변이 전략/매개변수를 선택하거나,

(iii) 하이브리드 국소탐색으로 수렴을 보완하는 방향이 주를 이룬다. 그러나 심우주 궤적 최적화에서는 변수별로 수렴 속도와 정체 양상이 이질적으로 발생할 수 있어, 개체군 전체에 동일한 방식으로 다양성을 주입하면 일부 차원에서는 과도한 교란이, 다른 차원에서는 다양성 붕괴가 동시에 발생할 수 있다. 본 연구의 ISHACDE-ADCP는 이러한 병목을 겨냥하여, 교차 단계에서 차원별 수렴 정도를 추정하고 필요한 차원에만 heavy-tail 섭동을 선택적으로 주입함으로써 정체 완화와 후반 정밀수렴 간 균형을 개선한다.

III. 제안하는 알고리즘

이 절에서는 제안하는 ISHACDE-ADCP를 기술한다. ISHACDE[6]은 경쟁 메커니즘의 구조를 기반으로 하며, 성공 이력에 기반한 제어 매개변수 적응을 확장하여 변이 연산 내 4개의 스케일링 계수 ($F_1 \sim F_4$) 및 2개의 교차율 (Cr_1, Cr_2) 이 서로 독립적으로 진화하도록 설계된 자기적응형 DE 변종이다. 핵심 아이디어는, DE/winner-to-best/1 변이 연산에서 사용되는 각 스케일링 계수가 서로 다른 차분 벡터를 증폭하므로, 성공 이력을 분리하여 독립적으로 적응시키는 것이 유리할 수 있다는 점에 기반한다.

1. 연속 최적화 문제 및 초기화

이 논문에서는 연속 최적화 문제

$$\begin{aligned} \min_{x \in \Omega} f(x), \\ \Omega = \{x | lb_j \leq x_j \leq ub_j, j = 1, \dots, D\} \end{aligned} \quad (1)$$

를 고려한다. 세대 t 에서 개체군은 $\{X_i^t\}_{i=1}^N$ 로 표기하며, X_{best}^t 는 현재 개체군 최소해이다. 초기 개체군은 각 차원 j 에 대해 균등분포 난수 $r \sim U(0,1)$ 를 사용하여

$$x_{ij}^0 = r(ub_j - lb_j) + lb_j \quad (2)$$

와 같이 생성한다. 한편 ADCP[13] 결합을 위해 초기 개체군의 “차원별 분포 통계량”과 점프 확률을

함께 초기화한다. 먼저, 초기 세대 $t=0$ 의 개체군에 대해 각 차원의 초기 평균(mean_init) 및 초기 표준편차(stddev_init)를 계산하여 저장한다.

$$\begin{aligned} mean_j^0 &= \frac{1}{NP} \sum_{i=1}^{NP} x_{i,j}^0, \\ stddev_j^0 &= \sqrt{\frac{1}{NP} \sum_{i=1}^{NP} (x_{i,j}^0 - mean_j^0)^2} \end{aligned} \quad (3)$$

또한 각 차원에 대한 점프 확률 JR_j^0 은 최소값(0.1)으로 초기화하여, 탐색 초반에 과도한 섭동이 발생하지 않도록 한다.

2. 경쟁 기반 변이: DE/winner-to-best/1

ISHACDE-ADCP는 각 타깃 벡터 X_i^t 에 대해 동일 개체군에서 무작위 경쟁자 $X_{r_1}^t$ 를 선정하고, 두 해의 목적함수 값을 비교하여 두 가지 변이 전략 중 하나를 선택한다. 구체적으로, 경쟁자가 더 우수하면 DE/rand-to-best/1 형태를, 그렇지 않으면 DE/current-to-best/1 형태를 사용하며, 이를 하나의 DE/winner-to-best/1 연산으로 정리하면 다음과 같다.

$$V_i^t = \begin{cases} X_{r_1}^t + F_1(X_{best}^t - X_{r_1}^t) \\ \quad + F_2(X_{r_2}^t - X_{r_3}^t) & \text{if } f(X_{r_1}^t) < f(X_i^t) \\ X_i^t + F_3(X_{best}^t - X_i^t) \\ \quad + F_4(X_{r_2}^t - X_{r_3}^t) & \text{otherwise} \end{cases} \quad (4)$$

여기서 r_1, r_2, r_3 는 i 와 서로 다른 인덱스로 무작위 선택된다. 첫 번째 분기는 ‘더 좋은 기반점’에서 출발해 전역 최선 방향과 차분 벡터를 결합함으로써 상대적으로 큰 탐색 폭을 확보하고, 두 번째 분기는 현재 해 주변에서 최선 방향으로 수렴을 유도하는 형태로 지역 탐색을 강화한다.

3. ADCP 기반 이항 교차

ISHACDE-ADCP는 변이 벡터 v_i^t 와 현재 개체 x_i^t 를 결합하여 trial 벡터 u_i^t 를 생성한다.

(1) 차원별 통계량 갱신 및 점프 확률 업데이트

Algorithm 1 ISHACDE-ADCP

Require: Objective function $f(\mathbf{x})$, bounds \mathbf{lb}, \mathbf{ub} , population size NP , dimension D , max generations T , learning rate c , fixed std σ_F, σ_{Cr} , JR_{\min}, JR_{\max}, k

Ensure: Best solution \mathbf{x}_{best}

Initialization:
 Generate initial population $\{\mathbf{x}_i^0\}_{i=1}^{NP}$ uniformly in $[\mathbf{lb}, \mathbf{ub}]$
 Evaluate $f(\mathbf{x}_i^0)$ for all i ; set $\mathbf{x}_{best}^0 = \arg \min_i f(\mathbf{x}_i^0)$
 Set $(\mu_{F1}, \mu_{F2}, \mu_{F3}, \mu_{F4}) \leftarrow 0.5, (\mu_{Cr1}, \mu_{Cr2}) \leftarrow 0.5$
 Set $\sigma_F \leftarrow 0.1, \sigma_{Cr} \leftarrow 0.1$

(ADCP) Initialize per-dimension statistics:
for $j = 1$ to D **do**
 $\bar{x}_j^0 \leftarrow \frac{1}{NP} \sum_{i=1}^{NP} x_{i,j}^0$
 $\sigma_j^0 \leftarrow \sqrt{\frac{1}{NP} \sum_{i=1}^{NP} (x_{i,j}^0 - \bar{x}_j^0)^2}$
 $JR_j^0 \leftarrow JR_{\min}$
end for

for $t = 0$ to $T - 1$ **do**
(ADCP) Update per-dimension jumping rates (once per generation):
for $j = 1$ to D **do**
 $\bar{x}_j^t \leftarrow \frac{1}{NP} \sum_{i=1}^{NP} x_{i,j}^t$
 $\sigma_j^t \leftarrow \sqrt{\frac{1}{NP} \sum_{i=1}^{NP} (x_{i,j}^t - \bar{x}_j^t)^2}$
 $CL_j^t \leftarrow \text{clip}_{[0,1]} \left(1 - \frac{\sigma_j^t}{\sigma_j^0} \right)$
 $JR_j^t \leftarrow JR_{\min} + (JR_{\max} - JR_{\min}) \cdot \frac{e^{k \cdot CL_j^t} - 1}{e^k - 1}$
end for
 Initialize success sets $SF_1, SF_2, SF_3, SF_4 \leftarrow \emptyset; SCR_1, SCR_2 \leftarrow \emptyset$
for $i = 1$ to NP **do**
 Randomly select mutually distinct indices $r_1, r_2, r_3 \in \{1, \dots, NP\} \setminus \{i\}$
if $f(\mathbf{x}_{r_1}^t) < f(\mathbf{x}_i^t)$ **then**
 Conduct DE/rand-to-best/1 phase (Algorithm 2).
else
 Conduct DE/current-to-best/1 phase (Algorithm 3).
end if
end for
 Update best: $\mathbf{x}_{best}^{t+1} \leftarrow \arg \min_i f(\mathbf{x}_i^{t+1})$
for $kidx = 1$ to 4 **do**
if $SF_{kidx} \neq \emptyset$ **then**
 $\mu_{F_{kidx}} \leftarrow (1 - c)\mu_{F_{kidx}} + c \cdot \text{LEHMERMEAN}(SF_{kidx})$
end if
end for
for $jidx = 1$ to 2 **do**
if $SCR_{jidx} \neq \emptyset$ **then**
 $\mu_{Cr_{jidx}} \leftarrow (1 - c)\mu_{Cr_{jidx}} + c \cdot \text{MEAN}(SCR_{jidx})$
end if
end for
end for
return \mathbf{x}_{best}^T

Algorithm 1. 제안하는 알고리즘의 의사코드

세대 t 에서 교차를 수행하기 전에, 각 차원 j 의 현재 분포 통계량을 계산한다. 즉,

$$mean_j^t = \frac{1}{NP} \sum_{i=1}^{NP} x_{i,j}^t, \quad (5)$$

$$stddev_j^t = \sqrt{\frac{1}{NP} \sum_{i=1}^{NP} (x_{i,j}^t - mean_j^t)^2}$$

이때 ADCP는 초기 표준편차 $stddev_j^0$ 와 현재 표준편차 $stddev_j^t$ 의 비율을 이용하여 차원별 수렴 수준을 다음과 같이 정의한다.

$$CL_j^t = 1 - \frac{stddev_j^t}{stddev_j^0} \quad (6)$$

즉, $\frac{stddev_j^t}{stddev_j^0}$ 가 작아질수록 CL_j^t 가 증가하며, 이는 해당 차원이 더 강하게 수렴되었음을 의미한다. 이후 차원별 점프 확률은 CL_j^t 를 입력으로 하는 지수 스케일링 함수를 통해 업데이트한다.

Algorithm 2 DE/rand-to-best/1 Phase (with ADCP crossover)

$F_1 \leftarrow \text{SAMPLEF}(\mu_{F1}, \sigma_F); F_2 \leftarrow \text{SAMPLEF}(\mu_{F2}, \sigma_F)$
 $Cr \leftarrow \text{SAMPLECR}(\mu_{Cr1}, \sigma_{Cr})$
 $\mathbf{v}_i^t \leftarrow \mathbf{x}_{r_1}^t + F_1(\mathbf{x}_{best}^t - \mathbf{x}_{r_1}^t) + F_2(\mathbf{x}_{r_2}^t - \mathbf{x}_{r_3}^t)$
 $\mathbf{u}_i^t \leftarrow \text{ADCPBINOMIALCROSSOVER}(\mathbf{x}_i^t, \mathbf{v}_i^t, Cr, \mathbf{JR}^t, \gamma)$
 $\mathbf{u}_i^t \leftarrow \text{BOUNDREPAIR}(\mathbf{u}_i^t, \mathbf{lb}, \mathbf{ub})$
if $f(\mathbf{u}_i^t) \leq f(\mathbf{x}_i^t)$ **then**
 $\mathbf{x}_i^{t+1} \leftarrow \mathbf{u}_i^t$
 $SF_1 \leftarrow SF_1 \cup \{F_1\}; SF_2 \leftarrow SF_2 \cup \{F_2\}$
 $SCR_1 \leftarrow SCR_1 \cup \{Cr\}$
else
 $\mathbf{x}_i^{t+1} \leftarrow \mathbf{x}_i^t$
end if

Algorithm 2. 제안하는 알고리즘의 DE/rand-to-best/1 단계

Algorithm 3 DE/current-to-best/1 Phase (with ADCP crossover)

$F_3 \leftarrow \text{SAMPLEF}(\mu_{F3}, \sigma_F); F_4 \leftarrow \text{SAMPLEF}(\mu_{F4}, \sigma_F)$
 $Cr \leftarrow \text{SAMPLECR}(\mu_{Cr2}, \sigma_{Cr})$
 $\mathbf{v}_i^t \leftarrow \mathbf{x}_i^t + F_3(\mathbf{x}_{best}^t - \mathbf{x}_i^t) + F_4(\mathbf{x}_{r_2}^t - \mathbf{x}_{r_3}^t)$
 $\mathbf{u}_i^t \leftarrow \text{ADCPBINOMIALCROSSOVER}(\mathbf{x}_i^t, \mathbf{v}_i^t, Cr, \mathbf{JR}^t, \gamma)$
 $\mathbf{u}_i^t \leftarrow \text{BOUNDREPAIR}(\mathbf{u}_i^t, \mathbf{lb}, \mathbf{ub})$
if $f(\mathbf{u}_i^t) \leq f(\mathbf{x}_i^t)$ **then**
 $\mathbf{x}_i^{t+1} \leftarrow \mathbf{u}_i^t$
 $SF_3 \leftarrow SF_3 \cup \{F_3\}; SF_4 \leftarrow SF_4 \cup \{F_4\}$
 $SCR_2 \leftarrow SCR_2 \cup \{Cr\}$
else
 $\mathbf{x}_i^{t+1} \leftarrow \mathbf{x}_i^t$
end if

Algorithm 3. 제안하는 알고리즘의 DE/current-to-best/1 단계

Algorithm 4 ADCP-based Binomial Crossover

Require: target vector \mathbf{x}_i^t , mutant vector \mathbf{v}_i^t , crossover rate Cr , per-dimension jumping rates $\mathbf{JR}^t = (JR_1^t, \dots, JR_D^t)$, Cauchy scale γ (default 0.1)

Ensure: trial vector \mathbf{u}_i^t

Choose $j_{rand} \sim \mathcal{U}\{1, \dots, D\}$
for $j = 1$ to D **do**
 $r_1 \sim \mathcal{U}(0, 1)$
if $r_1 \leq Cr$ or $j = j_{rand}$ **then**
 $\mathbf{u}_{i,j}^t \leftarrow \mathbf{v}_{i,j}^t$
else
 $r_2 \sim \mathcal{U}(0, 1)$
if $r_2 \leq JR_j^t$ **then**
 $\mathbf{u}_{i,j}^t \leftarrow \text{CAUCHYRAND}(x_{i,j}^t, \gamma)$
else
 $\mathbf{u}_{i,j}^t \leftarrow x_{i,j}^t$
end if
end if
end for
return \mathbf{u}_i^t

Algorithm 4. 제안하는 알고리즘의 이항 교차 연산자

$$JR_j^t = JR_{\min} + (JR_{\max} - JR_{\min}) \cdot \frac{e^{k \cdot CL_j^t} - 1}{e^k - 1} \quad (7)$$

여기서 JR_{\min}, JR_{\max} 는 점프 확률의 최소/최대값이며, k 는 증가 곡선의 기울기를 조절하는 하이퍼파라미터이다. 이 업데이트는 세대당 1회 수행된다.

(2) ADCP 기반 이항 교차 연산자

개체 i 에 대해, ISHACDE의 분기 구조에 따라 교차율 Cr_i 는 Cr_1 또는 Cr_2 에서 샘플링되어 사용된다. 그런 다음 $j_{rand} \in \{1, \dots, D\}$ 를 임의로 선택하고, 각 차원 j 에 대해 다음 규칙으로 trial 벡터를 구성한다.

$$u_{i,j}^t = \begin{cases} v_{i,j}^t & \text{if } r_1 \leq Cr_i \text{ or } j = j_{rand} \\ randc(x_{i,j}^t, 0.1) & \text{if } r_1 > Cr_i \text{ and } r_2 \leq JR_j^t \\ x_{i,j}^t & \text{otherwise} \end{cases} \quad (8)$$

여기서 $randc(m, s)$ 는 location m , scale s 를 갖는 Cauchy 분포에서 난수를 샘플링하는 연산을 의미한다. 결과적으로, (i) 변이 벡터에서 상속되지 않는 차원에 대해서도 (ii) 그 차원이 과도하게 수렴한 경우에는 Cauchy 섭동이 선택적으로 활성화되어, 차원별로 “필요한 곳에만” 강한 점프가 주입된다.

4. 선택 및 독립 성공이력 적응

선택은 1:1 탐욕 선택을 사용한다. 즉,

$$X_i^{t+1} = \begin{cases} U_i^t & \text{if } f(U_i^t) < f(X_i^t) \\ X_i^t & \text{otherwise} \end{cases} \quad (9)$$

로 다음 세대를 구성한다. trial이 채택되는 경우, 해당 trial 생성에 사용된 제어 매개변수들이 “성공 이력”으로 기록되어 다음 세대의 매개변수 적응에 활용된다.

ISHACDE-ADCP는 DE/winner-to-best/1 내부의 4개 스케일링 계수와 2개 교차율을 각각 독립적인 성공 이력 집합으로 관리한다. 즉, 분기별로 성공 시 다음의 집합에 값을 저장한다:

- 경쟁자 우수 분기 성공 시: $(S_{F_1}, S_{F_2}, S_{Cr_1})$
- 그 외 분기 성공 시: $(S_{F_3}, S_{F_4}, S_{Cr_2})$

알고리즘은 초기 기대값을 $\mu_{F_1} = \mu_{F_2} = \mu_{F_3} = \mu_{F_4} = 0.5$, $\mu_{Cr_1} = \mu_{Cr_2} = 0.5$ 로 설정하고, 각 세대에서 아래 분포로부터 매개변수를 샘플링한다.

$$\begin{aligned} F &\leftarrow randn(\mu_F, \sigma_F^2), \\ Cr &\leftarrow randc(\mu_{Cr}, \sigma_{Cr}^2) \end{aligned} \quad (10)$$

여기서 μ_F , μ_{Cr} 는 해당 매개변수의 현재 기대값이며, σ_F^2 , σ_{Cr}^2 는 고정 분산(0.1)이다. 샘플링된 값은 DE 관례에 따라 $F \in (0, 1]$, $Cr \in [0, 1]$ 로 제한한다.

세대 t 에서 기록된 성공 집합을 이용해 다음 세대의 기대값을 갱신하며, 스케일링 계수의 경우 Lehmer 평균, 교차율은 산술평균을 사용한 지수평활 형태로 업데이트한다.

$$\begin{aligned} \mu_F &\leftarrow (1-c)\mu_F + c \cdot mean_L(S_F) \\ \mu_{Cr} &\leftarrow (1-c)\mu_{Cr} + c \cdot mean_A(S_{Cr}) \end{aligned} \quad (11)$$

여기서 c 는 학습률이다. ISHACDE-ADCP에서는 위 갱신을 $(F_1, F_2, F_3, F_4, Cr_1, Cr_2)$ 각각에 대해 서로 다른 성공 집합을 사용하여 독립적으로 수행하며, 전체 절차는 Algorithms 1-4 형태로 요약된다. Algorithm 1은 세대별 반복 구조를 보이며, 각 세대에서 (i) 차원별 분산 감소로 수렴수준을 계산하고 점프확률 JR_j^t 를 갱신한 뒤, (ii) 경쟁 기반 winner-to-best 변이(Algorithms 2-3)로 변이 벡터를 생성한다. 이후 (iii) 이항 교차 과정에서 변이 벡터가 상속되지 않는 차원에 대해 JR_j^t 에 따라 Cauchy 섭동을 선택적으로 주입(Algorithm 4)하여 과수렴 차원의 재탐색을 유도하고, 마지막으로 (iv) 탐욕 선택 및 성공이력 기반 매개변수 적응을 수행한다.

IV. 실험 설정 및 결과

1. 실험 설정

본 연구에서는 심우주 궤적 최적화 문제의 전역 탐색 성능을 검증하기 위해 GTOPTX 벤치마크[12]의 단일 목적(space mission trajectory optimization, SMT0) 문제 7개를 사용하였다. GTOPTX는 실제 임무를 기반으로 한 블랙박스 궤적 설계 문제들로 구성되며, 각 문제의 설계변수 차원 (D)과 제약 조건 수(m)는 다음과 같다.

- Cassini1 ($D=6$, $m=4$)
- Cassini2 ($D=22$, $m=0$)
- Messenger(reduced) ($D=18$, $m=0$)
- Messenger(full) ($D=26$, $m=0$)
- GTOC1 ($D=8$, $m=6$)
- Rosetta ($D=22$, $m=0$)
- Sagas ($D=12$, $m=2$)

제안 기법인 ISHACDE-ADCP의 효과를 명확히 분석하기 위해, 비교 기준 알고리즘으로 ADCP가 결합되지 않은 원본 ISHACDE를 사용하였다. 두

표 1. 제안하는 알고리즘과 비교 알고리즘의 성능 평가 결과.

F	D	m	ISHACDE-ADCP	ISHACDE
			Mean FEV (Std. Dev.)	Mean FEV (Std. Dev.)
Cassini1	6	4	1.323e+01 (3.975e+00)	1.325e+01 (4.078e+00)
Cassini2	22	0	2.017e+01 (3.500e+00)	2.075e+01 (2.600e+00)
Messenger (reduced)	18	0	-6.411e+05 (1.497e+05)	-6.287e+05 (1.236e+05)
Messenger (full)	26	0	1.549e+01 (1.531e+00)	1.478e+01 (1.430e+00)
GTOC1	8	6	1.760e+01 (2.854e+00)	1.641e+01 (2.601e+00)
Rosetta	22	0	4.206e+00 (1.771e+00)	5.835e+00 (2.205e+00)
Sagas	12	2	5.458e+07 (3.088e+07)	6.487e+07 (2.600e+07)

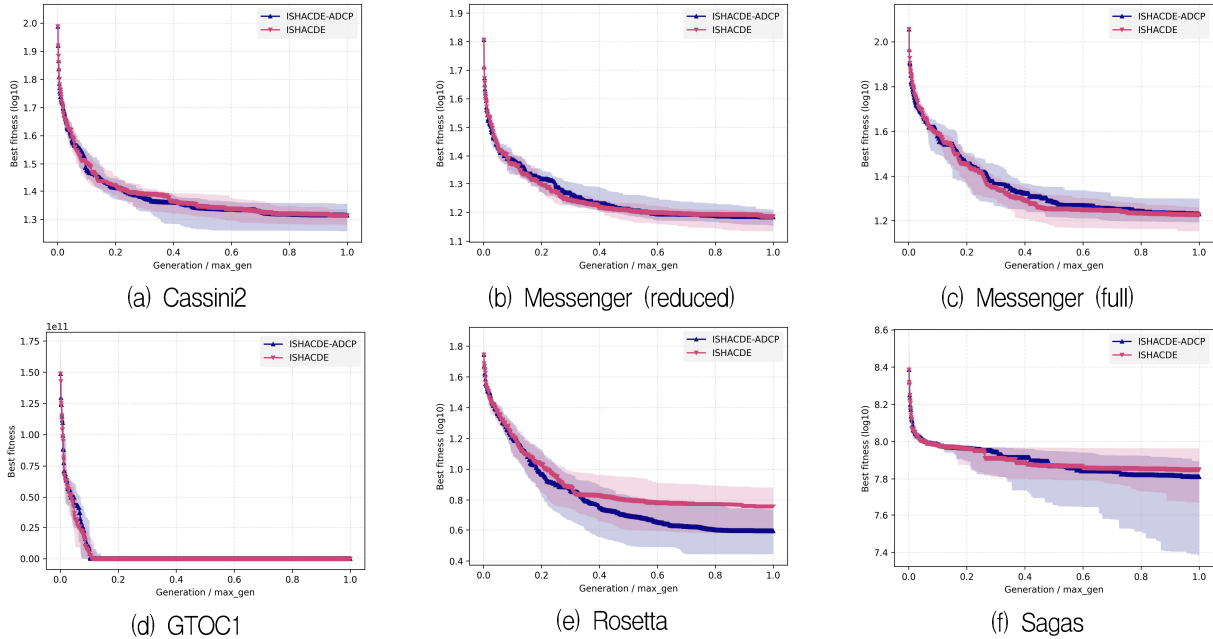


그림 3. GTOPX 문제들 중 수렴 양상 차이가 관찰된 6개 문제(Cassini2, Messenger(reduced), Messenger(full), GTOC1, Rosetta, Sagas)에 대한 수렴 곡선 비교. 각 곡선은 30회 독립 실행에서 best-so-far fitness의 중앙값을 나타내고, 음영은 사분위 범위를 나타낸다. 가로축은 정규화된 세대 비율(Generation/max_gen), 세로축은 best fitness(log10)이다.

알고리즘은 동일한 변이/선택 프레임워크와 성공 이력 기반 적응 구조를 공유하며, ISHACDE-ADCP는 교차 단계에서만 차원별 수렴 정도를 반영한 ADCP 섭동을 선택적으로 적용한다. 모든 실험은 최대 함수 평가 횟수를 $\text{MaxFE}=20,000$ 으로 설정하였고, 개체군 크기는 $\text{NP}=20$ 으로 고정하였다. 각 알고리즘은 확률적 변동성을 완화하기 위해 문제당 30회 독립 실행하였으며, 각 실행에서 얻은 최종 해의 목적함수 값을 수집하여 통계적으로 비교하였다.

ISHACDE 관련 하이퍼파라미터는 ISHACDE 원 논문 설정을 기본값으로 사용하여, μ_F 및 μ_{Cr} 를 0.5로 두고, $\sigma_F = \sigma_{Cr} = 0.1$ 로 설정하였다. 또한 학습

률은 $c = 0.1$ 로 설정하였다. ADCP 관련 하이퍼파라미터는 ADCP 원 논문 설정을 기본값으로 사용하여, $JR_{\min} = 0.1$, $JR_{\max} = 0.2$ 로 두었다.

제약 처리를 위해 모든 알고리즘에 정적 페널티 방식을 적용하였으며, 페널티가 포함된 평가지표 $F(x)$ 는 다음과 같이 정의하였다:

$$F(x) = f(x) + w \sum_{i=1}^m \max(0, -g_i(x)) \quad (12)$$

여기서 w 는 큰 상수로 설정하였다. 이를 통해 (i) feasible 해는 목적함수 값으로 비교되고, (ii) infeasible 해는 위반량에 비례하여 불리하게 평가되도록 하였다.

2. 실험 결과

표 1은 GTOPIX 단일목적 7개 문제에서 제안한 ISHACDE-ADCP와 ISHACDE의 성능을 비교한 결과를 제시한다. 각 값은 30회 독립 실행에서 얻은 최종 해의 성능지표(FEV; 페널티 포함 목적함수 값)의 평균과 표준편차이며, 값이 작을수록 우수하다. 표에서는 더 낮은 평균값을 굵게 표시하였다. ISHACDE-ADCP는 7개 중 4개 문제(Cassini2, Messenger(reduced), Rosetta, Sagas)에서 평균 성능이 개선되었고, Cassini1에서는 거의 동등한 결과를 보였다. 반면 Messenger(full)과 GTOC1에서는 ISHACDE가 더 낮은 평균값을 기록하여, 교차 단계에서의 ADCP 섭동이 일부 문제에서는 성능 저하로 이어질 수 있음을 확인하였다. 이는 제안 기법이 특정 문제군에서 정체 완화에 유리하나, 다양성 주입이 과도하면 정밀 수렴을 방해할 수 있음을 시사한다. 또한 표준편차 관점에서 Cassini2와 Sagas에서 변동성이 증가하는 경향이 관찰되었는데, 이는 heavy-tail 특성의 Cauchy 섭동이 탐색 다양성을 강화하는 대신 실행 간 산포를 확대할 수 있음을 의미한다.

그림 3은 6개 GTOPIX 문제에 대해 세대 진행에 따른 best-so-far 적합도의 수렴 곡선을 비교한다. 가로축은 정규화된 세대 비율이며, 세로축은 best fitness를 로그 스케일로 표시하였다(단, GTOC1은 초기 페널티 값이 매우 커 원 스케일로 제시). 각 곡선은 중앙값이며, 음영은 실행 간 변동(IQR)을 나타낸다. 전반적으로 두 알고리즘 모두 초기 구간에서 급격한 성능 향상을 보인 뒤 완만한 개선 또는 정체 구간에 진입한다. 이때 ISHACDE-ADCP는 일부 문제에서 중후반 정체를 완화하며 추가적인 하강을 유도하는 경향을 보인다. Cassini2는 초기 수렴 속도는 유사하나 중반 이후 ISHACDE가 정체 양상을 보이는 반면 ISHACDE-ADCP는 더 낮은 best fitness로 점진적 개선이 지속된다. Rosetta에서는 ISHACDE가 plateau에 가까운 완만한 감소를 보이는 동안 ISHACDE-ADCP가 후반까지 하강을 유지하여 최종 수렴 수준이 더 낮게 나타난다. Sagas에서도 후반 구간에서 ISHACDE-ADCP가 소폭 우세

하나, 음영 폭이 상대적으로 커 일부 실행에서 큰 개선을 얻는 대신 변동성이 커질 가능성을 시사한다. 요약하면, ISHACDE-ADCP는 정체 구간에서 추가 탐색을 유도해 후반 개선을 얻는 사례(Cassini2, Rosetta, Sagas)가 존재하는 반면, 문제 구조에 따라 과도한 교란이 불리하게 작용할 수 있으며(Messenger(full)), 최적의 섭동 강도 설정은 문제 특성에 의존할 수 있다.

V. 결론

본 연구는 심우주 궤적 최적화 문제에서 차분 진화 기반 방법이 겪는 조기수렴과 정체를 완화하기 위해, ISHACDE-ADCP를 제안하였다. 제안 기법은 ISHACDE의 경쟁 기반 탐색 구조와 성공 이력 기반 적응 메커니즘을 유지하면서, 교차 단계에서 차원별 수렴 정도를 추정하고 차원별 점프 확률을 조절하여 Cauchy 섭동을 선택적으로 주입함으로써, 다양성이 과도하게 소실된 차원에 대해서만 재탐색을 강화하도록 설계되었다.

GTOPIX 단일목적 7개 문제에 대한 실험 결과, ISHACDE-ADCP는 Cassini2, Messenger(reduced), Rosetta, Sagas 등 일부 문제에서 평균 성능을 개선하였고, Cassini1에서는 유사한 성능을 보였다. 수렴 곡선 분석에서도 ISHACDE-ADCP가 특정 문제에서 중후반 정체 구간을 완화하며 추가적인 하강을 유도하는 경향이 관찰되어, 차원별로 선택적 다양성 주입이 정체 완화에 기여할 수 있음을 확인하였다. 반면 Messenger(full)과 GTOC1에서는 ISHACDE가 더 우수한 평균값을 기록하였으며, 이는 heavy-tail 섭동이 문제 구조에 따라 후반 정밀 수렴을 방해할 수 있음을 시사한다. 또한 일부 문제에서는 실행 간 산포가 증가하는 경향이 나타나, 다양성 강화와 수렴 안정성 간의 트레이드오프가 존재함을 확인하였다. 제안한 차원별 선택적 섭동 메커니즘은 심우주 임무의 초기 설계 단계에서 반복적으로 수행되는 블랙박스 궤적 탐색 과정에 쉽게 결합될 수 있어, 제한된 계산 예산 하에서도 보다 안정적인 전역 탐색 성능을 제공할 것으로 기


대된다.

향후 연구로는 (i) 문제 특성에 따라 ADCP의 섭동 강도를 자동으로 조절하는 자기적응 (self-adaptive) 메커니즘을 도입하고, (ii) ADCP로 인한 변동성을 완화하기 위해 세대 기반 스케줄링, Cauchy 샘플 크기 클리핑, 성공 이력 기반의 자기적응적 강도 조절을 적용하며, (iii) 추가 벤치마크 및 실제 임무 시나리오로 확장하여 일반화 성능을 검증할 예정이다.

REFERENCES

- [1] Z. Yuan et al., "An improved multi-operator differential evolution with two-phase migration strategy for numerical optimization," *Information Sciences*, vol. 669, Art. no. 120548, 2024.
- [2] M. Schlueter, "MIDACO software performance on interplanetary trajectory benchmarks," *Advances in Space Research*, vol. 54, no. 4, pp. 744-754, 2014.
- [3] A. Shirazi, J. Ceberio, and J. A. Lozano, "Spacecraft trajectory optimization: A review of models, objectives, approaches and solutions," *Progress in Aerospace Sciences*, vol. 102, pp. 76-98, 2018.
- [4] M. Zuo et al., "A differential evolution algorithm with the guided movement for population and its application to interplanetary transfer trajectory design," *Engineering Applications of Artificial Intelligence*, vol. 110, Art. no. 104727, 2022.
- [5] M. Zuo et al., "A case learning-based differential evolution algorithm for global optimization of interplanetary trajectory design," *Applied Soft Computing*, vol. 94, Art. no. 106451, 2020.
- [6] R. Zhong et al., "Space mission trajectory optimization via competitive differential evolution with independent success history adaptation," *Applied Soft Computing*, vol. 171, Art. no. 112777, 2025.
- [7] L. Peng et al., "Reinforcement learning-based hybrid differential evolution for global optimization of interplanetary trajectory design," *Swarm and Evolutionary Computation*, vol. 81, Art. no. 101351, 2023.
- [8] M. Vasile, E. Minisci, and M. Locatelli, "An inflationary differential evolution algorithm for space trajectory optimization," *IEEE Transactions on Evolutionary Computation*, vol. 15, no. 2, pp. 267-281, 2011.
- [9] Z. Tang et al., "Enhancing the search ability of a hybrid LSHADE for global optimization of interplanetary trajectory design," *Engineering Optimization*, vol. 55, no. 4, pp. 632-649, 2023.
- [10] Y. Song et al., "Gravity assist space pruning and global optimization of spacecraft trajectories for solar system boundary exploration," *Complex & Intelligent Systems*, vol. 10, no. 1, pp. 323-341, 2024.
- [11] J. H. Choi, J. Lee, and C. Park, "Deep-space trajectory optimizations using differential evolution with self-learning," *Acta Astronautica*, vol. 191, pp. 258-269, 2022.
- [12] M. Schlueter et al., "GTOPX space mission benchmarks," *SoftwareX*, vol. 14, Art. no. 100666, 2021.
- [13] T. J. Choi and Y. An, "Adaptive dimension-wise Cauchy perturbation for enhanced differential evolution optimization," *AIMS Mathematics*, vol. 11, no. 1, pp. 734-766, 2026.

저자 소개



최태종(정회원)

2017년 성균관대학교 전기전자컴퓨터 공학과 박사 졸업.
2020년~2022년 경일대학교 컴퓨터사이언스학부 조교수.
2022년~현재 전남대학교 데이터사이언스대학원 부교수.

<주관심분야 : 인공지능, 머신러닝, 딥러닝, 진화연산>