

불확실한 환경에서 최적화 : MAP-Elites 알고리즘을 중심으로

박다희, 최태중*

전남대학교

dahee@jnu.ac.kr, *ctj17@jnu.ac.kr

Advances in Multi-Dimensional Archive of Phenotypic Elites for Uncertain Domains: A Trend Analysis

Da Hee Park and Tae Jong Choi*

Chonnam National Univ.

요 약

이 논문은 불확실성을 고려한 최적화에서 MAP-Elites 알고리즘의 한계와 이를 개선하기 위한 다양한 접근법을 소개한다. MAP-Elites 알고리즘은 다양한 최적해를 동시에 탐색하고, 다차원의 특징 공간에서 우수한 최적해들을 아카이빙한다. 그러나 MAP-Elites 알고리즘은 불확실성에 민감하고 탐색 효율성이 저하되는 한계가 있다. 본 논문에서는 불확실성을 고려한 최적화에서 MAP-Elites 알고리즘의 성능을 개선하기 위해 제안된 최신 접근법들을 공유하고 그 응용 사례를 살펴본다. 이를 통해 불확실성을 고려한 최적화에서 MAP-Elites 알고리즘을 중심으로 한 최적화에 대한 이해를 높이고자 한다.

I. 서 론

MAP-Elites(Multi-Dimensional Archive of Phenotypic Elites) 알고리즘[1]은 기존의 진화 알고리즘과 달리 단일 최적해를 찾는 것이 아니라, 특징 공간에서 다양한 최적해를 탐색한다. 이러한 방식은 복잡한 환경에서 적응적 행동을 탐색하고 유지하는 데 매우 유리하다. 또한, 품질 다양성(Quality-Diversity, QD) 알고리즘[2]의 일환으로서 다양성과 품질을 동시에 고려하여 다양한 상황에 적용할 수 있는 해를 탐색한다는 점에서 진화 알고리즘 분야에서 주목받고 있다. 그러나 MAP-Elites 알고리즘은 불확실성을 고려한 최적화에서는 한계가 있다[2]. 불확실성은 여러 원인을 통해 발생할 수 있는데, 예를 들면 모델의 파라미터가 정확하지 않거나 미래의 조건이나 사건들이 불확실하기 때문일 수 있다. 불확실성을 고려한 최적화는 특히 현실 세계의 문제를 다룰 때 중요한데, 현실 세계의 많은 최적화 문제는 환경, 입력 데이터, 시스템 동작 등에 내재된 불확실성으로 인해 단순히 확정적인 데이터에 기반한 최적화를 수행하기 어렵기 때문이다. 이러한 MAP-Elites 알고리즘의 한계를 극복하기 위해 다양한 개선된 알고리즘들이 제안되고 있다. 본 논문에서는 MAP-Elites 알고리즘의 한계와 문제점을 분석하고, 이것을 해결하기 위한 개선된 알고리즘들을 소개한다.

II. MAP-Elites 알고리즘의 동작 과정

MAP-Elites 알고리즘[1]은 탐색 공간에서 다양한 후보 해를 생성하고, 이를 특징 공간으로 매핑(mapping)하여 다양한 솔루션을 탐색하는 진화 알고리즘이다. 탐색 공간은 문제의 모든 가능한 해를 포함하는 반면, 특징 공간은 이러한 해들이 가진 특정 속성을 기준으로 구분된다.

MAP-Elites 알고리즘은 특징 공간을 설정하고, 이 공간을 일정한 구간으로 나눈다. 초기화 단계에서 무작위로 생성된 후보 해들은 각 셀에 배치되고, 해당 셀에 저장된다. 이후 진화 단계에서는 기존의 우수한 해를 기반으로 교차와 변이 연산을 통해 새로운 자손을 생성한다. 이 자손들은 평가를 거쳐 기존의 해보다 성능이 우수한 경우 해당 셀에 업데이트된다.




그림1 : MAP-Elites 알고리즘에서 탐색 공간(Search space)의 후보해는 특징 공간(Feature space)으로 매핑됨.

III. MAP-Elites 알고리즘의 한계

MAP-Elites 알고리즘은 다양한 솔루션을 탐색하고 아카이빙하는 강력한 진화 알고리즘이지만, 노이즈가 포함된 도메인에서는 몇 가지 중요한 한계가 있다. 첫째, 알고리즘은 성능 평가나 행동 기술자에 포함된 노이즈에 매우 민감하여, 잘못된 엘리트가 선택되면 전체 아카이브의 품질이 저하될 수 있다[3]. 둘째, 노이즈가 있는 환경에서는 시간이 지남에 따라 불안정한 솔루션이 유지될 가능성이 높아져 최적화 성능이 저하될 수 있다[4]. 이로 인해 특정 엘리트가 잘못된 셀에 위치하거나, 시간이 지남에 따라 부적절한 엘리트가 아카이브에 남아 있을 수 있으며, 이는 전체 탐색의 효율성을 저하시킬 수 있다. 이러한 한계는 MAP-Elites 알고리즘이 노이즈 환경에서 성능이 저하될 가능성이 있음을 나타내며, 이를 해결하기 위해 다양한 개선된 접근법이 제안되고 있다[4].

IV. 노이즈 문제를 해결하기 위한 접근법

MAP-Elites 알고리즘의 중요한 한계 중 하나는 노이즈에 대한 민감성이다. 이를 해결하기 위해 다양한 방법이 제안되었으며, 그 중 몇 가지 접근법을 소개한다.

1. Deep Grid MAP-Elites

Deep Grid MAP-Elites[3]는 전통적인 MAP-Elites 알고리즘의 셀 구조를 확장하여 각 셀에 여러 개체를 저장함으로써 성능을 더 정확하게 추정하는 방법이다. 이 접근법은 노이즈로 인한 오류를 줄이고 아카이브의 안정성을 높일 수 있지만, 여러 개체를 관리하고 평가하는 과정에서 많은 계산 자원이 소모된다. 또한, 여러 개체의 성능을 종합적으로 평가하는 과정이 복잡해질 수 있으며, 과적합 문제가 발생할 가능성도 있다. 이러한 한계에도 불구하고, Deep Grid MAP-Elites는 노이즈 환경에서 최적화 성능을 향상시키는 데 중요한 기법으로 사용된다.

2. Multi-emitter MAP-Elites

Multi-emitter MAP-Elites[5]의 Adaptive Sampling과 Drifting Elites는 노이즈가 많은 환경에서 MAP-Elites 알고리즘의 성능을 향상시키기 위한 기법이다. Adaptive Sampling은 성능 추정이 불안정한 솔루션에 대해 샘플링 횟수를 동적으로 조절하여 평가의 정확도를 높인다. 이 방법은 더 많은 샘플을 수집해 불확실성을 줄이면서도, 안정적인 솔루션에는 적은 샘플을 사용해 계산 자원을 절약할 수 있다. 반면, Drifting Elites는 아카이브에 추가된 솔루션을 지속적으로 재평가하여, 시간이 지남에 따라 엘리트가 올바른 위치로 이동할 수 있도록 한다. 이 기법은 특히 노이즈가 많은 환경에서 아카이브의 품질을 유지하는 데 효과적이다. 그러나 두 기법 모두 계산 비용 증가와 탐색 공간의 불균형 문제 등의 한계가 있다.

3. Uncertain Quality-Diversity

Uncertain Quality-Diversity[6]의 Implicit Averaging과 Explicit Averaging[6]은 노이즈가 있는 환경에서 MAP-Elites 알고리즘의 성능을 개선하기 위한 기법이다. Implicit Averaging은 개체를 여러 번 평가하는 대신 인구 집단의 크기를 늘려 유사한 개체들이 자연스럽게 평균적인 성능을 나타내도록 한다. 이는 노이즈 환경에서 성능 추정을 안정화하지만, 인구 집단이 커질수록 계산 자원이 많이 소모될 수 있다. 반면, Explicit Averaging은 동일한 개체를 여러 번 평가해 평균 성능을 추정하는 방법으로, 단순하고 직관적이지만 평가 횟수가 많아질수록 계산 비용이 크게 증가할 수 있다. 두 기법 모두 노이즈 처리 능력을 강화하지만, Implicit Averaging은 자원이 중요한 상황에서, Explicit Averaging은 고비용 환경에서 각각 한계를 가진다.

VI. 결론

MAP-Elites 알고리즘은 진화 알고리즘의 중요한 발전으로, 다양한 최적화 문제에서 유용한 솔루션을 제공할 잠재력을 가지고 있다. 그러나 이 알고리즘은 노이즈에 민감하며, 탐색 효율성 저하와 높은 계산 비용 등의 한계가 있다. 이를 극복하기 위해 최근 다양한 개선된 접근법이 제안되었다. 이러한 방법들은 노이즈 문제를 완화하고, 탐색 효율성을 높이며, 더욱 안정적이고 정확한 솔루션을 제공하는 데 기여한다. 이러한 개선된 알고리즘들은 실제 응용에서 실용적이고 효과적인 솔루션을 제공할 수 있으며, 향후 다양한 도메인에서 그 적용 가능성이 넓어질 것이다.

후속 연구에서는 이러한 알고리즘들의 성능을 더욱 향상시키고, 다양한 실제 문제에 대한 적용성을 검토하여 MAP-Elites 알고리즘의 범위를 확장하고, 더욱 복잡한 최적화 문제를 해결하고자 한다.

표 1. MAP-Elites의 노이즈 문제를 해결하기 위한 접근법 비교

구분	Deep Grid MAP-Elites [3]	Multi-emitter MAP-Elites [5]	Uncertain Quality-Diversity [6]
노이즈 제거 기법	● 딥 그리드 구조를 통해 각 셀에 여러 개체를 저장	● 적응적 샘플링과 드리프팅 엘리트 사용	● 암묵적 및 명시적 평균화를 사용해 개체 성능 여러 번 평가
특징	● 여러 개체를 저장 후 다양한 성능 추정치를 통합 ● 노이즈로 인한 오류 감소 및 아카이브의 장기적 안정성 보장	● 불안정한 솔루션에 대해 샘플링을 늘려 평가의 신뢰성을 높임 ● 드리프팅 엘리트로 아카이브의 품질 유지	● 노이즈가 큰 환경에서도 성능의 신뢰성을 확보하지만, 계산 자원이 많이 소모될 수 있음
응용 분야	● 로봇 제어 및 학습: 노이즈가 많은 환경에서 로봇의 다관절 로봇 팔 제어 및 Hexapod 로봇의 시뮬레이션에 사용	● 로봇 제어: 다양한 발신자(emitter)를 사용하여 로봇의 동작을 최적화 ● 자동 설계 최적화: 고비용 블랙박스 함수 최적화에 적용	● 재정적 의사결정 및 최적화 문제: 불확실성이 큰 환경에서 안정적인 성능을 유지하는 데 사용

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00214326 및 RS-2023-00242528).

참 고 문 헌

- [1] Mouret, Jean-Baptiste, and Jeff Clune. "Illuminating search spaces by mapping elites." arXiv preprint arXiv:1504.04909 (2015).
- [2] Pugh, Justin K., Lisa B. Soros, and Kenneth O. Stanley. "Quality diversity: A new frontier for evolutionary computation." Frontiers in Robotics and AI 3 (2016): 202845.
- [3] Flageat, Manon, and Antoine Cully. "Fast and stable MAP-Elites in noisy domains using deep grids." Artificial Life Conference Proceedings 32. One Rogers Street, Cambridge, MA 02142-1209, USA journals-info@ mit. edu: MIT Press, 2020.
- [4] Cully, Antoine. "Multi-emitter map-elites: improving quality, diversity and data efficiency with heterogeneous sets of emitters." Proceedings of the Genetic and Evolutionary Computation Conference. 2021.
- [5] Justesen, Niels, Sebastian Risi, and Jean-Baptiste Mouret. "Map-elites for noisy domains by adaptive sampling." Proceedings of the Genetic and Evolutionary Computation Conference Companion. 2019.
- [6] Flageat, Manon, and Antoine Cully. "Uncertain quality-diversity: evaluation methodology and new methods for quality-diversity in uncertain domains." IEEE Transactions on Evolutionary Computation (2023).