

학습에 의한 진화전략의 수렴성에 관한 연구

A Study on the Convergence of the Evolution Strategies based on Learning

전효병 · 심귀보

Hyo-Byung Jun and Kwee-Bo Sim

중앙대학교 전자전기공학부

요 약

본 논문에서는 라마르크 진화와 볼드윈 효과를 진화전략에 적용하여 진화전략의 수렴성에 대해서 고찰한다. 또한 진화전략의 탐색법으로 랜덤 지역탐색법과 강화 지역 탐색법을 제안한다. 랜덤 지역 탐색은 미리 정한 일정한 회수의 지역탐색을 랜덤하게 수행하는 것이고, 강화 지역탐색은 이전의 지역탐색의 경험을 다음 수행에 반영하는 것이다. 일반적으로 가장 이상적인 지역탐색은 주어진 범위 내에 존재하는 모든 개체의 적합도를 평가하여 가장 적합도가 높은 개체 주변을 탐색하는 것이다. 이러한 관점에서 라마르크 진화와 볼드윈 효과를 기본으로 하는 강화 지역탐색은 단순히 랜덤하게 주변 개체의 적합도를 탐색하는 것이 아니라 해 공간상에서 적합도가 높아지는 방향으로 지역탐색을 행함으로써 랜덤 지역탐색에 비해 보다 효과적으로 주변 개체를 탐색할 수 있어 전역적 탐색능력의 향상은 물론 수렴속도의 향상은 가져 올 수 있었다. 결과적으로 진화과정에 학습을 도입함으로써 진화만으로 최적해를 탐색할 때보다 그 성능이 향상됨을 볼 수 있다. 제안한 방법은 다양한 함수최적화 문제에 적용하여 그 시뮬레이션을 통해 학습이 진화에 미치는 영향에 대해서 고찰한다.

ABSTRACT

In this paper, we study on the convergence of the evolution strategies by introducing the Lamarckian evolution and the Baldwin effect, and propose a random local searching and a reinforcement local searching methods. In the random local searching method some neighbors generated randomly from each individual are tried without any other information, but in the reinforcement local searching method the previous results of the local search are reflected on the current local search. From the viewpoint of the purpose of the local search it is suitable that we try all the neighbors of the best individual and then search the neighbors of the best one of them repeatedly. Since the reinforcement local searching method based on the Lamarckian evolution and Baldwin effect does not search neighbors randomly, but searches the neighbors in the direction of the better fitness, it has advantages of fast convergence and an improvement on the global searching capability. In other words the performance of the evolution strategies is improved by introducing the learning, reinforcement local search, into the evolution. We study on the learning effect on evolution strategies by applying the proposed method to various function optimization problems.

1. 서 론

진화 알고리즘(evolutionary algorithms ; EAs)은 생물의 진화과정을 모뎀링하여 복잡한 문제를 해결하고자 하는 계산모델이다. 이는 개체군 내에서의 집단적 탐색과정에 기초하며, 각 개체는 탐색공간에서 하나의 탐색점에 대응된다. 임의로 형성된 초기 개체군은 세대가 지날수록 연산과정과 선택과정을 통해 탐색공간 내에서 적합도가 좋아지는 방향으로 진화해 나간다. 이러한 진화 알고리즘의 네 가지 주요 분야로는 유전자 알고리즘(GAs)[1,2], 진화전략(ESs)[3,4], 진화 프로그래밍(EP)[5], 유전자 프로그래밍(GP)[6] 등이 있

다. 이중 유전자 알고리즘은 가장 널리 알려져 있고 그 연구 또한 활발하다. 이러한 유전자 알고리즘의 연구 분야 중의 하나로서 학습과 진화에 대한 연구인 라마르크 진화(Lamarckian evolution)와 볼드윈 효과(Baldwin effect)가 존재한다[7-10]. 이는 기존의 유전자 알고리즘에 학습과정을 도입함으로써 보다 유용한 효과를 얻고자하는 연구이다. 라마르크 진화와 볼드윈 효과에서는, 유전자 알고리즘의 선택과정 이전에 현재 개체로부터 해밍 거리가 가까운 주변 개체들의 적합도를 탐색한다. 이를 지역탐색(local search)이라 하며, 개체의 생존 기간(life time)동안 발생하는 학습으로 볼 수 있다. 이때 라마르크 진화는 지역탐색 후

얻어진 최대 적합도를 갖는 개체를 기존 개체와 대체한다. 반면 볼드윈 효과는 기존 개체의 개체값은 그대로 둔 채, 지역탐색에 의해 얻어진 최대 적합도를 해당 개체의 적합도로 정의한다. 이와 같이 라마르크 진화는 지역탐색의 결과를 진화과정중의 개체값에 반영함으로써 유전자 알고리즘의 수렴속도를 향상시키고, 볼드윈 효과는 지역탐색의 결과를 개체의 적합도에 반영함으로써 국소해가 많은 해공간 상에서도 전역해를 찾을 수 있는 효과를 갖는다. 그러나 현재까지 라마르크 진화와 볼드윈 효과는 여러 가지 진화 알고리즘 중에서 유전자 알고리즘의 경우에만 적용되어졌고, 지역탐색 방법도 랜덤 지역탐색에만 의존하고 있다.

본 논문에서는 라마르크 진화와 볼드윈 효과를 진화전략에 적용하여 진화전략의 수렴성에 대해서 고찰한다. 또한 진화전략의 탐색법으로 랜덤 지역탐색법과 강화 지역 탐색법을 제안한다. 랜덤 지역탐색은 미리 정한 일정한 회수의 지역탐색을 랜덤하게 수행하는 것이고, 강화 지역탐색은 이전의 지역탐색의 경험을 다음 수행에 반영하는 것이다. 일반적으로 가장 이상적인 지역탐색은 주어진 범위 내에 존재하는 모든 개체의 적합도를 평가하여 가장 적합도가 높은 개체 주변을 탐색하는 것이다. 이러한 관점에서 라마르크 진화와 볼드윈 효과를 기본으로 하는 강화 지역탐색은 단순히 랜덤하게 주변 개체의 적합도를 탐색하는 것이 아니라 해 공간상에서 적합도가 높아지는 방향으로 지역탐색을 행함으로써 랜덤 지역탐색에 비해 보다 효과적으로 주변 개체를 탐색할 수 있어 전역적 탐색능력의 향상은 물론 수렴속도의 향상은 가져 올 수 있었다. 결과적으로 진화과정에 학습을 도입함으로써 진화만으로 최적해를 탐색할 때보다 그 성능이 향상됨을 볼 수 있다. 제안한 방법은 다양한 함수최적화 문제에 적용하여 그 시뮬레이션을 통해 학습이 진화에 미치는 영향에 대해서 고찰한다.

본 논문의 구성은 다음과 같다. 2장에서는 진화전략에 대해서 간략히 살펴보고, 3장에서는 본 논문에서 제안하는 랜덤 지역탐색과 강화 지역탐색을 중심으로 진화전략에 라마르크 진화와 볼드윈 효과를 적용하는 방법에 대해서 논한다. 4장에서는 몇 가지 함수 최적화 문제에 대한 시뮬레이션 결과를 통해 학습이 진화전략에 미치는 영향을 검토하고, 마지막으로 5장에서는 결론을 맺는다.

2. 진화전략

진화전략은 1964년 독일에서 처음으로 발생하여 유체역학 문제에 적용된 후 Rechenberg[3]와 Schwefel

[4]의 연구를 통해 더욱더 발전을 거듭하였다. 일반적으로 진화전략에서 세대의 갱신은 다음과 같다. 우선 부모 개체군 $P(k)$ 가 주어지고 이것에 대해서 재조합(recombination), 돌연변이(mutation), 선택(selection)을 적용한다. 이를 알고리즘으로 나타내면 다음과 같다[11].

Algorithm :

$k = 0;$

initialize $P(0) = \{a_1(0), \dots, a_\mu(0)\}$

where $a_i(0) = (x_i(0), \sigma_i(0), \alpha_i(0)),$

$x_i(0) \in R^n, \sigma_i(0) \in R^m,$

$\alpha_i(0) \in [0, 2\pi]^{m(n-1)^2}, \forall i \in \{1, \dots, \lambda\};$

evaluate $P(0);$

while termination criterion not fulfilled **do**

recombine $a_i'(k) = r(P(k)) \forall i \in \{1, \dots, \lambda\};$

mutate $a_i''(k) = m(a_i'(k));$

evaluate $P(k) = \{a_1''(k), \dots, a_\lambda''(k)\};$

select $P(k+1) = s(P(k))$ if $(\mu, \lambda) - ES;$

$P(k+1) = s(P(k) \cup P(k))$ if $(\mu + \lambda) - ES;$

$k = k+1;$

od

한편 진화전략의 각 개체(individual) \vec{a} 는 다음과 같은 세 가지 벡터로 구성된다.

$$(\mathbf{x}(k), \boldsymbol{\sigma}(k), \boldsymbol{\alpha}(k)) \in P(k) \quad (1)$$

여기서 k 는 세대, $P(k)$ 는 개체군, $\mathbf{x}(k) \in R^n$ 는 개체값 벡터, $\boldsymbol{\sigma}(k) \in R^{m\sigma}$ 와 $\boldsymbol{\alpha}(k) \in [-\pi, \pi]^{m\alpha}$ 는 표준편차 및 회전각 벡터로 $\mathbf{x}(k)$ 의 돌연변이를 제어하기 위한 공분산 행렬의 대각요소와 비대각요소를 각각 나타낸다. 상기의 벡터에서 표준편차 벡터의 크기는 $1 \leq n_\sigma \leq n$ 의 범위를 갖고 있으며, 회전각 벡터의 크기는 $n_\alpha = (n - n_\sigma/2) \cdot (n_\sigma - 1)$ 의 값을 갖는다. 개체값 벡터 $\mathbf{x}(k)$ 는 해공간상의 하나의 해 후보를 나타내며, 돌연변이시의 탐색 폭을 결정하는 전략 파라미터인 $\boldsymbol{\sigma}(k)$ 와 $\boldsymbol{\alpha}(k)$ 는 각각 n 차 정규분포의 표준편차와 분산에 해당한다. 문제에 따라서 회전각 벡터를 생략하고 표준편차 벡터만을 전략 파라미터로 사용할 수 있다.

2.1 재조합(Recombination)

먼저 μ 개의 개체로 구성된 부모 개체군 $P(k)$ 은 재조합 연산

$$r(P(k)) = a' = (\mathbf{x}', \boldsymbol{\sigma}', \boldsymbol{\alpha}') \quad (2)$$

을 통해서 새로운 λ 개의 개체를 생성한다. 재조합은

두 개의 부모벡터 $a = (x_a, \sigma_a, \alpha_a)$ 와 $b = (x_b, \sigma_b, \alpha_b)$ 를 선택하여 이들에 대해서 (3)식과 같이 각 벡터마다 서로 다른 재조합 방법을 사용할 수 있다. 이들을 합쳐서 하나의 벡터 v 로 나타내면 각 요소마다 다음과 같은 연산을 행한다.

$$v_i = \begin{cases} v_{a,i} & \text{:without recomb.} \\ v_{a,i} \text{ or } x_{b,i} & \text{:discrete recomb.} \\ v_{a,i} + u_i \cdot (x_{b,i} - v_{a,i}) & \text{:intermediate recomb.} \\ v_{a,i} \text{ or } x_{b,i} & \text{:global disc.recomb.} \\ v_{a,i} + u_i \cdot (x_{b,i} - a_{a,i}) & \text{:global inter.recomb.} \end{cases} \quad (3)$$

여기서 a 와 b 는 부모 개체군 $P(k)$ 로부터 랜덤하게 선택한 두 부모개체이며, u_i 는 $[0, 1]$ 의 범위를 갖는 균일한(uniform) 랜덤 변수이다. 이 식에서 discrete recombination(이산 재조합)은 미리 선택된 두 부모개체 중 랜덤하게 하나의 개체값을 골라서 새로운 개체의 값으로 결정하는 방법이고, intermediate recombination(중간 재조합)은 두 부모 개체값들의 중간값을 취하는 방법이며, global recombination(전역 재조합)은 i 번째 개체값을 재조합할 때마다 새로운 두 부모개체를 선택하는 방법이다. 진화전략의 재조합은 개체값의 변화량이 일반적으로 돌연변이보다 커지기 때문에 전역적 탐색능력을 향상시키는 효과를 갖는다.

2.2 돌연변이(Mutation)

재조합을 통해서 생성된 λ 개의 개체들은 각 개체가 다시 다음과 같은 돌연변이 연산을 거쳐 새로운 λ 개의 개체들을 생성한다.

$$\begin{aligned} \sigma_i''(k) &= \sigma_i'(k) \exp(\tau' N(0, 1) + \tau N_i(0, 1)) \\ \alpha_{ij}''(k) &= \alpha_{ij}'(k) + \beta N_{ij}(0, 1) \\ \mathbf{x}''(k) &= \mathbf{x}'(k) + \mathbf{z}(0, M^{-1}) \end{aligned} \quad (4)$$

여기서 $M^{-1} = (c_{ij})$, $c_{ii} = (\sigma_i')^2$, $c_{ij} = (1/2)((\sigma_i')^2 - (\sigma_j')^2) \tan 2\alpha_{ij}'$ 이고, $N(0, 1)$ 는 모든 요소 $i \in \{1, \dots, n\}$ 에 대하여 동일한 값을 갖는 평균 0, 분산 1인 정규난수이며, $N_i(0, 1)$ 는 매 i 번째 요소마다 새롭게 발생되어 적용되는 정규난수를 나타낸다. 또한 $\mathbf{z}(0, M^{-1})$ 은 (5)식과 같은 확률밀도 함수를 갖는 일반화된 n 차의 정규분포에 따라 발생하는 랜덤 벡터이다.

$$p(\mathbf{z}) = (2\pi)^{-n/2} \det(M)^{1/2} \exp\left(-\frac{1}{2} \mathbf{z}^T M \mathbf{z}\right) \quad (5)$$

(4)와 (5)식의 M^{-1} 은 $M^{-1} = (c_{ij})$, $c_{ii} = (\sigma_i')^2$, $c_{ij} = (1/2)$

$((\sigma_i')^2 - (\sigma_j')^2) \tan 2\alpha_{ij}'$ 인 공분산 행렬(covariance matrix)로, 표준편차 벡터 (σ_i') 는 c_{ii} 로, 회전각 벡터 $\alpha_i (0 \leq \alpha_i \leq 2\pi)$ 는 $c_{ij} = c_{ji} (i \neq j)$ 로 각각 사용된다. 따라서 표준편차 벡터와 회전각 벡터는 개체값 벡터의 돌연변이 범위에 영향을 주는 탐색 폭으로서 동작한다. 그리고 식 (4)의 각 파라미터(τ, τ', β)는 일반적으로 Schwefel [4]에 의해서 제안된 $\tau \propto (\sqrt{2\sqrt{n}})^{-1}$, $\tau' \propto (\sqrt{2n})^{-1}$, $\beta = 0.0873(5^\circ)$ 의 값을 사용한다.

Schwefel은 이와 같이 진화전략의 벡터들이 위상적인 조건에 맞추어 진화하고 적응하는 것을 자기 적응(self-adaptation)이라 명하였다. 특히, 식 (4)와 같이 회전각 벡터가 도입된 돌연변이를 상호관련 돌연변이(correlated mutation)라고 한다.

2.3 선택(Selection)

일반적으로 진화전략은 선택방법에 따라 $(\mu + \lambda)$ -ES와 (μ, λ) -ES로 구분된다. $(\mu + \lambda)$ -ES는 μ 개의 부모개체가 재 조합과 돌연변이를 통해 $\lambda (> 1)$ 개의 자손개체를 생성한다. 이 μ 개의 부모개체와 λ 개의 자손개체 중에서 적합도 순서대로 μ 개의 개체를 선택하여 다음 세대의 개체군을 형성한다. 반면 (μ, λ) -ES는 $\lambda (> \mu)$ 개의 자손개체 중에서만 μ 개의 개체를 선택하여 다음 세대의 개체군을 형성한다. $(\mu + \lambda)$ -ES는 (μ, λ) -ES에 비하여 엘리트 선택방법을 취하기 때문에 적합도가 단조적으로 증가되는 효과를 가질 수 있으나, 자기 적응능력이 떨어지기 때문에 최근에는 (μ, λ) -ES를 보다 많이 사용하고 있는 추세이다.

3. 진화전략에 대한 학습의 적용

자연계에서 개체의 특성이 변할 수 있는 방법으로는 학습(learning)과 진화(evolution)가 있다. 학습은 각 개체가 생존 기간동안 특정한 환경과의 상호작용을 통해서 일어나는 반면에, 진화는 개체군 단위로 선택, 교차, 돌연변이 등을 통해 세대간에 변화가 일어난다. 따라서 학습에 의한 변화는 개별적으로 축적되며, 진화에 의한 변화는 긴 세대동안 유전적으로 축적된다. 이러한 학습과 진화는 서로 융합이 가능하며, 이중 학습이 진화에 직접적으로 영향을 준다고 하는 것이 라마르크 진화이며, 간접적으로 영향을 준다는 이론이 볼드윈 효과이다.

본 논문에서는 진화전략에 라마르크 진화와 볼드윈 효과를 적용한다. 개체의 생존 기간은 선택과정 이전과 이후의 사이로 정의되며 이 기간동안 지역탐색을 수행한다. 지역탐색이란 선택 과정 이전에 λ 개의 자손 개체들이 각각 주변 개체들 중 최대 적합도를 갖

는 개체를 탐색하는 과정을 말한다. 이후 라마르크 진화는 원래의 개체들 대신에 탐색되어진 최대 적합도를 갖는 새로운 개체의 자손 개체들을 선택 과정에 반영한다(그림 1). 반면, 볼드윈 효과는 원래의 개체를 그대로 선택 과정에 적용하지만 그 적합도 값은 지역 탐색을 통해 얻어진 최대 적합도로 대체한다(그림 2).

본 논문에서 제안하는 진화전략에서의 지역탐색은 각 개체가 갖고 있는 표준편차를 이용하며, 랜덤 지역 탐색(random local search)과 강화 지역탐색(reinforcement local search)으로 구분된다. 진화전략에서의 랜덤 지역탐색은 기존의 유전자 알고리즘에서의 방법으로는 그 적용이 불가능하다. 이는 진화전략의 개체가 일반적인 유전자 알고리즘과는 달리 실수치 벡터로 구성되어 있기 때문이다. 이러한 제약은 지역탐색 시에 각 개체가 갖고 있는 표준편차 벡터를 이용함으로써 극복할 수 있다. 강화 지역탐색은 기존의 랜덤한 방법과는 달리 강화학습을 이용한 새로운 지역탐색 방

법이다.

강화학습(reinforcement learning)[12-14]은 동물의 학습수단에 근거하며 그 개념은 다음과 같이 요약된다. 즉, 어떠한 에이전트의 행동이 만족할만한 혹은 향상된 상태로 옮겨졌을 때 그러한 행동을 행하고자 하는 경향은 더욱 강화되며, 반대의 경우엔 더욱 약화된다. 결국, 에이전트의 행동은 시행착오를 통해 얻는 환경으로부터의 보상을 최대화하는 행동전략을 학습한다. 이러한 강화학습에는 여러 가지 방법이 존재하지만 진화전략에 직접적으로 적용하기에는 많은 제약이 따른다. 따라서 본 논문에서는 강화학습의 기본 개념만을 살린 가장 간단한 강화학습을 지역탐색 방법으로 사용한다.

다음의 3.1절에서는 랜덤 지역탐색에 대해서, 3.2절에서는 강화 지역탐색에 대해서 각각 나타낸다.

3.1 랜덤지역 탐색

랜덤 지역탐색은 n 차의 개체값 벡터에 대하여 이 중 랜덤하게 L 개의 자리를 선택한 후 이 값에 정규분포에 따라 발생한 랜덤 변수를 더하여 새로운 n 차의 개체 값 벡터를 생성한다. 이때의 표준편차는 해당 개체가 갖고 있는 표준편차 벡터에 따른다. 이는 가장 단순한 진화전략의 돌연변이와 유사하다. 한 개체에 대하여 이와 같은 랜덤 지역탐색을 N 번 수행한 후 이 중 가장 적합도가 높은 개체를 찾는다. 라마르크 진화는 탐색된 최대 적합도를 갖는 개체의 개체값 벡터를 다음의 선택과정에 반영하며, 볼드윈 효과는 탐색된 최대 적합도 값을 원래의 개체의 적합도 값으로 대체한 후 선택과정에 반영한다. 한번 수행에 대한 랜덤 지역탐색의 수식은 다음과 같다.

$$x_i^{(t)} = x_i^{(0)} + N(0, \sigma_i^{(0)}), t = \{1, \dots, N\} \quad (6)$$

여기서, $x_i^{(0)}$ 는 지역탐색 이전의 원래의 개체값 벡터의 i 번째 원소를 말하며, $x_i^{(t)}$ 는 t 번째 수행에 대한 주변 개체의 개체값 벡터의 i 번째 원소를 말한다. 또한 $N(0, \sigma_i^{(0)})$ 는 평균이 0이고 표준편차가 $\sigma_i^{(0)}$ 인 정규분포에 따라 발생한 랜덤 변수이다. i 는 랜덤하게 선택된 L 개의 자리에 대한 인덱스에 해당하며, L 값의 범위는 $1 \leq L \leq n$ 이다.

3.2 강화지역 탐색

강화 지역탐색은 N 번의 지역탐색을 수행함에 있어서 이전의 지역탐색의 경험을 다음 지역탐색에 반영하는 방법이다. 한번의 강화 지역탐색에 대한 수식은 다음과 같다.




그림 1. 라마르크 진화의 모식도
Fig. 1. Framework of Lamarckian Evolution

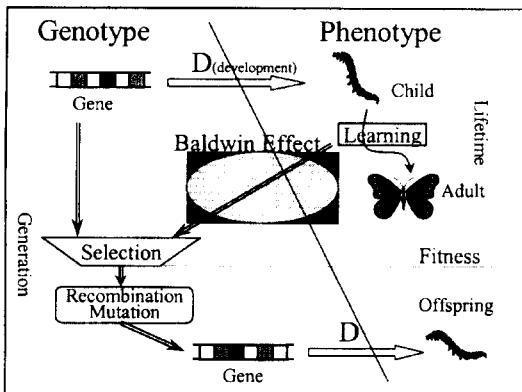


그림 2. 볼드윈 효과의 모식도
Fig. 2. Framework of Baldwin Effect

$$x_i^{(t)} = x_i^{(0)} + N(m_i^{(t)}, \sigma_i^{(0)}), \forall i = \{1, \dots, n\} \quad (7)$$

여기서, $m_i^{(t)}$ 는 t번째 지역탐색에 대한 정규분포의 평균에 해당하며, 한번의 지역탐색 이후에 매번 다음과 같이 증감된다.

$$m_i^{(t+1)} = \begin{cases} m_i^{(t)} + (x_i^{(t)} \cdot x_i^{best}) \cdot |N(0, 1)| & \text{if } f(\vec{x}^{(t)}) > f(\vec{x}^{best}), \\ m_i^{(t)} & \text{otherwise} \end{cases} \quad (8)$$

여기서, $f(\vec{x}^{(t)})$ 는 t번째 지역탐색에 의한 개체값 벡터의 적합도를 말하며, $m_i^{(0)}$ 는 모든 계 대하여 0으로 정의한다. 또한, \vec{x}^{best} 는 t번째 지역탐색을 수행하기 이전까지 탐색되어진 개체들 중에서 최대 적합도를 갖는 개체를 말한다.

식 (8)의 의미는 다음과 같다. 만일 t번째 지역탐색에 의해서 t-1번째까지 탐색되어진 최대 적합도보다 높은 적합도를 갖는 개체가 탐색되면, 개체값 벡터의 차이만큼 정규분포의 평균을 옮긴다. 그렇지 않으면 이전의 평균값을 그대로 유지한다. 이는 다음 지역탐색의 수행시에 해 공간상에서 적합도가 높아지는 방향으로 탐색을 유도하며 랜덤 지역탐색과는 달리 N번의 지역탐색 과정 중에서 다수의 과정이 그 결과에 반영된다.

일반적인 유전자 알고리즘의 개체는 이진 코드로 구성된다. 따라서 해 공간상에서 이산적으로 개체가 분포하며 주변 개체에 대한 범위도 명확해진다. 반면 진화전략은 실수치 벡터를 사용함으로써 해 공간상에서 연속적인 분포를 갖게 되어, 주변 개체에 대한 범위가 불분명할 뿐만 아니라 주변 개체 모두의 적합도를 탐색하는 것도 불가능하다. 결국 지역탐색은 그 한계가 존재한다. 이때, 강화학습의 개념을 이용해 적합도가 높아지는 한 방향으로의 탐색을 수행함으로써 랜덤 탐색법보다는 유용하게 주변 개체 중 최대 적합도를 갖는 개체를 탐색할 수 있다.

4. 학습이 진화에 미치는 영향


3장에서는 라마르크 진화와 볼드윈 효과를 진화전략에 적용하는 방법을 소개하였다. 4장에서는 이러한 학습이 적용된 진화전략과 일반적인 진화전략을 몇 가지 함수 최적화 문제에 적용하고 그 결과를 통해 학습이 진화전략에 미치는 영향에 대해서 고찰한다. 먼저 첫 번째 수치 예로써 수식 (9)과 같은 문제에 일반적인 진화전략(CES)과 라마르크 진화를 이용한 진

화전략, 그리고 볼드윈 효과를 이용한 진화전략을 각각 적용하였다.

$$f_1(x)_{|i=1,30} = \sum_{i=1}^{30} x_i^2 \quad x_i \in [-100, 100], f_{min} = 0 \quad (9)$$


그림 3은 각 진화전략에 대한 적합도의 변화 그림으로서, 10번 수행후의 평균 결과이다. 부모 개체수는 30개, 자손 개체수는 200개, 표준편차의 초기값은 3.0으로 균일하게 적용하였다. 개체값 벡터 \vec{x} 는 이산 재조합을, 전략 파라미터인 σ 와 $\vec{\alpha}$ 는 전역 중간 재조합을 적용하였으며, 개체값 벡터와 표준편차의 차수는 공히 30으로 두었다. 지역탐색시의 수행 회수 $N = 10$, 랜덤 지역탐색시의 자리수 $L = 10$ 로 설정하였다.

그림 3의 (a)는 지역탐색 방법 중에 랜덤 지역탐색을 적용한 결과이다. 일반적인 진화전략보다는 라마르크 진화를 사용한 진화전략이 보다 빠른 수렴속도를 보이고 있다. 반면 볼드윈 효과를 사용한 경우에는 수렴속도가 보다 늦어짐을 알 수 있다. (b)는 강화 지역탐색을 적용한 결과이다. 강화 지역탐색을 이용한 라



(a) 랜덤 지역탐색을 이용한 라마르크 진화와 볼드윈 효과

(a) Lamarckian evolution and the Baldwin effect with random local search method.



(b) 강화 지역탐색을 이용한 라마르크 진화와 볼드윈 효과

(b) Lamarckian evolution and the Baldwin effect with reinforce local search method.


그림 3. $f_1(x)$ 에 대한 적합도 추이
Fig. 3. Fitness change in $f_1(x)$

마크 진화의 경우는 랜덤 지역탐색을 이용한 경우와 큰 차이를 보이지 않는다. 하지만 볼드윈 효과의 경우는 강화 지역탐색을 수행할 때가 랜덤 지역탐색을 수행할 때보다 빠른 수렴속도를 가질 수 있었다. 수식 (9)의 문제는 국소해가 없는 단봉성(unimodal) 문제에 해당한다. 결국 이러한 문제에 대해선 라마르크 진화를 사용함으로써 일반적인 진화전략보다 빠른 수렴속도를 얻을 수 있으며, 볼드윈 효과는 랜덤 지역탐색이 아닌 강화 지역탐색을 사용함으로써 그 성능이 향상 될 수 있다. 라마르크 진화는 일반적인 진화전략에 비해 한세대 동안 보다 높은 적합도를 탐색할 수 있기 때문에 그 수렴속도는 향상된다.

두 번째 수치 예로써 수식 (10)과 같은 문제에 일반적인 진화전략(CES)과 라마르크 진화를 이용한 진화전략, 그리고 볼드윈 효과를 이용한 진화전략을 각각 적용하였다.


$$f_2(x_{i=1,2}) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$$

$$x_i \in [-5, 5], f_{\min} = -1.0316285 \quad (10)$$



(a) 랜덤 지역탐색을 이용한 라마르크 진화와 볼드윈 효과

(a) Lamarckian evolution and the Baldwin effect with random local search method



(b) 강화 지역탐색을 이용한 라마르크 진화와 볼드윈 효과

(b) Lamarckian evolution and the Baldwin effect with reinforce local search method

그림 4. $f_2(x)$ 에 대한 적합도 추이

Fig. 4. Fitness change in $f_2(x)$

수식 (10)은 비교적 다수의 국소해를 갖는 다봉성(multimodal) 문제에 해당한다. 그림 4는 세 가지 진화전략에 이 문제를 적용한 결과로서 30번 수행 후의 평균 결과이다. 이때 부모 개체수는 3개, 자손 개체수는 20개, 표준편차의 초기값은 0.3으로 균일하게 적용하였다. 재조합은 이전 문제와 동일하게 적용하였으며 개체값 벡터와 표준편차의 차수는 공히 2로 두었다. 지역탐색시의 수행 회수 $N=3$, 랜덤 지역탐색시의 자리수 $L=2$ 로 설정하였다. 그림 4에서 볼 수 있듯이 일반적으로 국소해가 다수 존재하는 문제에 있어서는 볼드윈 효과가 라마르크 진화보다 그 성능이 우월하다. 또한 랜덤 지역탐색보다는 강화 지역탐색을 사용함으로써 두 경우 모두 그 성능을 보다 향상시킬 수 있다. 볼드윈 효과는 지역 최소값 부근의 적합도 분포를 평탄화하는 효과를 갖으며, 결국 지역 최소값에 빠지는 위험이 줄어들고 전역해로의 수렴성을 높일 수 있다. 또한 강화 지역탐색은 랜덤 지역탐색보다는 효율적으로 주변 개체를 탐색하기 때문에 성능이 보다 향상된다.

5. 결 론

본 논문에서는 라마르크 진화와 볼드윈 효과를 진화전략에 적용하여 진화전략의 수렴성에 대해서 고찰하였다. 또한 지역탐색 방법으로는 랜덤 지역탐색과 강화 지역탐색으로 구분하여 각각을 함수 최적화 문제에 적용하였다. 그 결과 기존의 유전자 알고리즘에 라마르크 진화와 볼드윈 효과를 적용한 경우와 마찬가지로 진화전략에서도 라마르크 진화는 수렴속도의 향상을, 볼드윈 효과는 전역적 탐색 능력의 향상을 가져왔다. 즉, 진화과정에 학습을 도입함으로써 진화만으로 최적해를 탐색할 때보다 그 성능이 향상된다. 이때의 학습은 선택과정 이전의 개체가 주변 개체들 중에서 적합도가 보다 높은 개체를 탐색하는 지역탐색으로서 정의되어 진다. 가장 이상적인 지역탐색은 주어진 범위 내에 존재하는 모든 개체의 적합도를 평가하여 가장 높은 적합도를 갖는 주변 개체를 탐색하는 것이라 할 수 있다. 이러한 관점에서 강화 지역탐색은 단순히 랜덤하게 주변 개체의 적합도를 탐색하는 것이 아니라 해공간 상에서 적합도가 높아지는 방향으로 지역탐색을 행함으로써 랜덤 지역탐색에 비해 보다 효과적으로 주변 개체를 탐색할 수 있었다.

참고문헌

[1] J. H. Holland, *Adaptation in Natural and Artificial*

- Systems*, Ann Arbor, University of Michigan Press, 1975.
- [2] M. Mitchell, *An Introduction to Genetic Algorithm*, A Bradford Book, The MIT Press, 1996.
 - [3] I. Rechenberg, *Cybernetic Solution Path of an Experimental Problem*. Ministry of Aviation, Royal Aircraft Establishment (U.K.), 1965.
 - [4] H. -P. Schwefel, *Evolution and Optimum Seeking*, A Wiley-Interscience Publication, John Wiley & Sons, Inc., 1995.
 - [5] L. J. Fogel, A. J. Owens, and M. J. Walsh., *Artificial Intelligence Through Simulated Evolution*, John Wiley, Chichester, UK, 1966.
 - [6] J. R. Koza, *Genetic Programming: On the Programming of Computers by Means of Natural Selection*, A Bradford Book, The MIT Press, 1993.
 - [7] D. H. Ackley and M. Littman, "Interactions between learning and evolution," *Proc. of the 2nd Conf. on Artificial Life*, C.G. Langton, ed., Addison-Wesley, pp. 487-509, 1991.
 - [8] J. M. Baldwin, "A new factor in evolution," *Amerian Naturalist* 30, pp. 441-451, 1896.
 - [9] G. E. Hinton and S. J. Nolan, "How learning can guide evolution," *Complex Systems* 1, pp. 495-502, 1987.
 - [10] D. H. Ackley, and M. L. Littman, "A Case for Lamarckian Evolution," *Artificial Life III*, C. G. Langton, ed., Addison-Wesley, pp. 3-10, 1994.
 - [11] T. B ck and H. -P. Schwefel, "An overview of evolutionary algorithms for parameter optimization," *Evolutionary Computation*, vol. 1, no. 1, pp. 1-23, 1993.
 - [12] R. S. Sutton, "Learning to Predict by the Methods of Temporal Differences," *Machine Learning*, vol. 8, pp. 9-44, 1992.
 - [13] C. J. C. H. Watkins and P. Dayan, "Technical Note: Q-Learning," *Machine Learning*, vol. 8, pp. 279-292, 1992.
 - [14] A. G. Barto, "Reinforcement Learning," *The handbook of Brain Theory and Neural Network*, The MIT Press, pp. 804-809, 1995.



전효병 (Hyo-Byung Jun) (준회원)

제 9권 제 1호 참조

현재 : 중앙대학교 대학원 제어계측학과
박사과정 (로보틱스 및 지능정보
시스템)



심귀보 (Kwee-Bo Sim) (종신회원)

제 9권 제 4호 참조

현재 : 중앙대학교 전자전기공학부 교수