

A Realidade das Abordagens Adaptadas em Problemas de Otimização Contínua

Raphael Bezerra Xavier, André L. P. Guedes

Universidade Federal do Paraná (UFPR)

E-mails: rbxavier@inf.ufpr.br, andre@inf.ufpr.br



Resumo

A necessidade no contexto da computação distribuída para resolver problemas de otimização de alto grau de complexidade, requer algoritmos que produzam soluções com qualidade e com baixo custo computacional. A importância de métodos e técnicas de otimização, mais especificamente as ferramentas baseadas em inteligência computacional denominadas meta-heurísticas, faz com que estas técnicas ganhem adaptações para tratar problemas de forma mais rápida. Algumas meta-heurísticas se destacam na resolução de problemas de natureza contínua, tais como: *Simulated Annealing*(SA), *Ant Colony*, *Greedy Randomized Adaptive Search Procedure*(GRASP), o *Variable Neighborhood Search*(VNS), as quais não utilizam cálculo de gradiente, mesmo possuindo uma convergência lenta quando comparadas a métodos clássicos não lineares, são eficientes por terem a capacidade de ir além da otimalidade local, não ficando presas em ótimos locais aparentemente satisfatórios.

Introdução

Comumente pesquisadores têm a necessidade de resolver problemas de otimização de alto grau de complexidade, como o de escalonamento de tarefas, alocação de pessoas e transporte. A solução destes problemas requer o desenvolvimento de algoritmos que produzam soluções com qualidade e que sejam obtidas com custo computacional reduzido.

O estudo de métodos híbridos tem se fortificado no intuito de minimizar o esforço computacional, porém existe uma tendência muito grande de autores continuarem crescendo o número de novas implementações destes métodos híbridos. Os algoritmos bio-inspirados estão na lista dos que mais sofrem adaptações, por exemplo. Com isto sustenta-se a ideia do estudo analítico para desmistificar e explicar o motivo de uma alta quantidade de adaptações e hibridizações em algoritmos de otimização.

O avanço deste estudo pode trazer razões e novas tendências para se analisar as melhores formas de como utilizar os algoritmos ou técnicas de otimização. Será realizado um levantamento bibliográfico com trabalhos da literatura, onde os problemas em que estes algoritmos são utilizados serão vistos de uma forma em que técnicas mais fundamentais podem tratá-los de forma mais simples.

Casos Estudados

Apresentamos três algoritmos híbridos da literatura que servem de exemplo para as abordagens de resolução de problemas de otimização.

A self-adaptive virus optimization algorithm for continuous optimization problems [Liang and Juarez, 2020]

É proposto um algoritmo híbrido com um mecanismo autoadaptativo para diminuir o número de parâmetros controláveis, na aplicação em um problema de otimização de natureza contínua. Veja na Figura 1 o fluxo do algoritmo adaptado, detalhando todos os passos do seu funcionamento.

Accelerating continuous GRASP with a GPU [Nogueira et al., 2019]

É proposto um algoritmo híbrido que usa uma versão do GRASP contínuo(C-GRASP) com uma paralelização utilizando *Graphics Processing Unit*(GPU) em suas duas fases, a fim de conseguir a redução do número de avaliações na execução do algoritmo. Veja na Figura 2 o pseudocódigo do C-GRASP com as duas fases paralelizadas.

An adaptive large neighborhood search metaheuristic for the vehicle routing problem with drones [Sacramento et al., 2019]

É proposto uma abordagem híbrida, *Adaptive Large Neighborhood Search* que usa uma extensão da Busca em vizinhança de grande porte (*Large Neighborhood Search* - LNS). O mecanismo de busca das duas heurísticas iniciam a partir de uma solução inicial viável e operam com diferentes métodos que destroem e reparam a solução corrente. Na busca LNS um par dessas heurísticas de remoção e inserção é adotada durante toda a busca, já na ALNS várias heurísticas de remoção e inserção são utilizadas durante uma mesma busca.

Um peso é usado inicialmente para cada heurística com intuito de encontrar o par de heurísticas mais eficiente para o problema. Todos os pesos são ajustados dinamicamente, baseados na eficiência de cada método ao longo da busca. Veja na Figura 3 o pseudocódigo do ALNS.

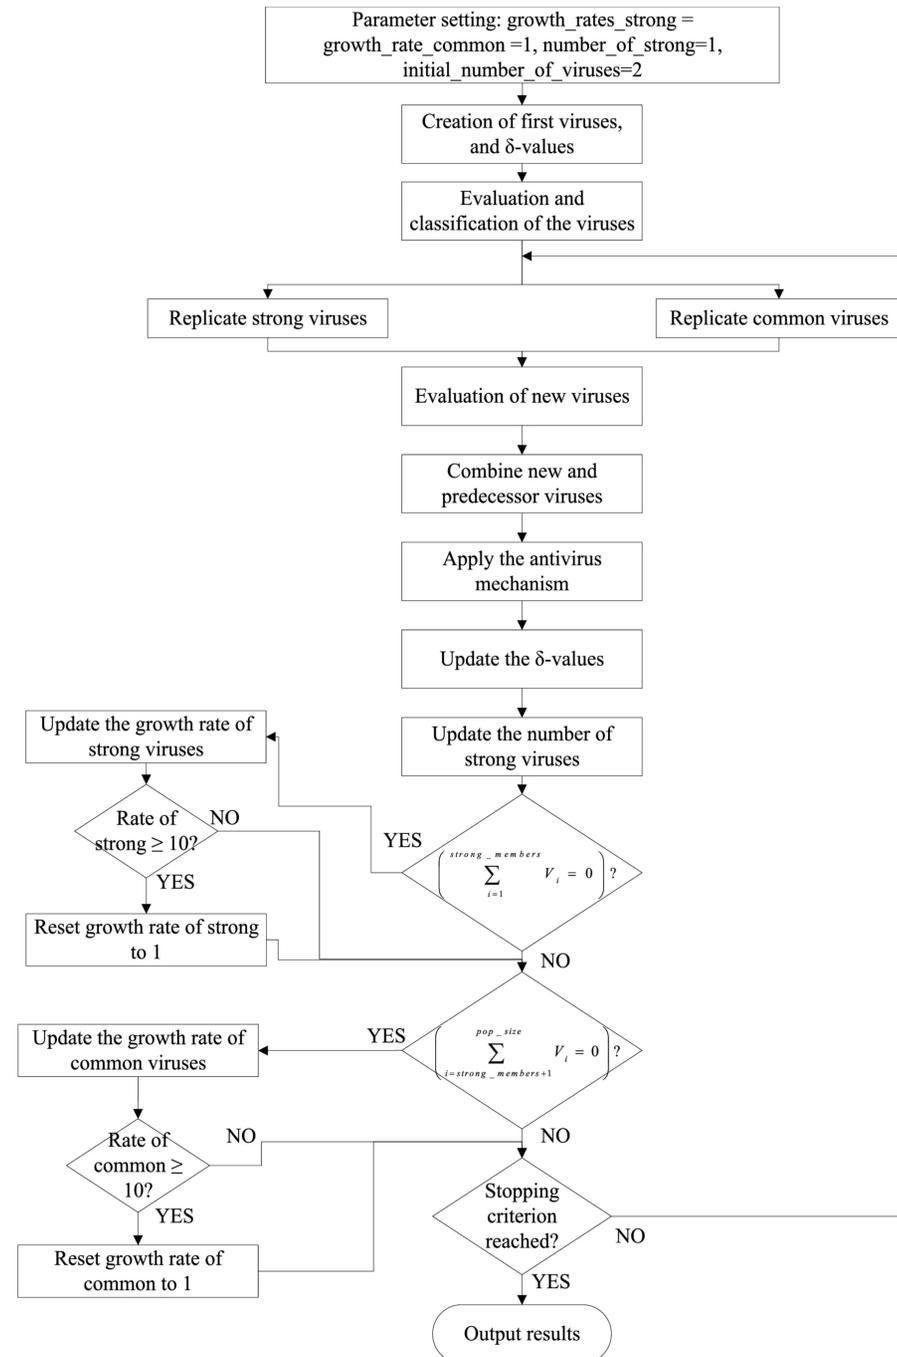


Figura 1: Procedure of the saVOA. Fonte:[Liang and Juarez, 2020]

```
1 GPU C-GRASP(n, l, u, f(·), h_s, h_e)
2 f* ← ∞
3 [d_x, d_l, d_u, d_z, d_g, d_Fixed] ← InitGPU(n, l, u)
4 while stop criteria not met do
5   x ← RandSolution(n, l, u)
6   h ← h_s
7   while h ≥ h_e do
8     [x, Impr_C] ← GPUConstructGreedyRandomized(x, d_x, n, d_l, d_u, f(·), h,
9       d_z, d_g, d_Fixed)
10    [x, Impr_L] ← GPULocalImprovement(x, d_x, n, d_l, d_u, f(·), h)
11    if f(x) < f* then
12      x* ← x
13      f* ← f(x)
14    if Impr_C = false and Impr_L = false then
15      h ← h/2
16 return x*
```

Figura 2: Pseudocode of GPU C-GRASP. Fonte:[Nogueira et al., 2019]

```
1 procedimento ALNS()
2 Gere uma solução inicial s;
3 s_melhor ← s;
4 enquanto algum critério de parada não seja satisfeito faça
5   Selecione um par de heurísticas de parada de remoção e de inserção
6   (h_r, h_i) baseadas em seus pesos adaptativos;
7   Aplique (h_r, h_i) em s, produzindo s';
8   se s' é melhor que s_melhor então
9     s_melhor ← s';
10    s ← s';
11   senão
12     se s' satisfaz o critério de aceitação então
13       s ← s';
14   Atualize as pontuações e os pesos das heurísticas;
15 retorna s_melhor;
```

Figura 3: Pseudocode of Adaptive Large Neighborhood Search. Fonte:[Sacramento et al., 2019]

Conclusões

Com isso conclui-se que é mais comum realizar uma nova adaptação para resolver um problema, do que tentar ver como o algoritmo em sua forma original pode se comportar e também resolver o mesmo problema. Será que este número alto de adaptações traz algum benefício computacional, ou os problemas simples são tratados de forma complexa para poder acelerar a convergência através destas adaptações?

Referências

- [Liang and Juarez, 2020] Liang, Y.-C. and Juarez, J. R. C. (2020). A self-adaptive virus optimization algorithm for continuous optimization problems. *Soft Computing*, 24(17):13147–13166.
- [Nogueira et al., 2019] Nogueira, B., Tavares, E., Araujo, J., and Callou, G. (2019). Accelerating continuous grasp with a gpu. *The Journal of Supercomputing*, 75(9):5741–5759.
- [Sacramento et al., 2019] Sacramento, D., Pisinger, D., and Ropke, S. (2019). An adaptive large neighborhood search metaheuristic for the vehicle routing problem with drones. *Transportation Research Part C: Emerging Technologies*, 102:289–315.