

AN ECOSYSTEM INSPIRATION FOR THE DEVELOPMENT OF A CO-EVOLUTIONARY POPULATION-BASED VARIABLE NEIGHBORHOOD SEARCH ALGORITHM

Gabriel Dominico, Wesklei Migliorini, Rafael Stubs Parpinelli

Universidade do Estado de Santa Catarina - UDESC

Departamento de Ciência da Computação, Campus Universitário – Joinville – SC
gabrieldominico@gmail.com, wesklei.m@gmail.com, rafael.parpinelli@udesc.br

Abstract. *This work approaches the Variable Neighborhood Search Algorithm (PRVNS) as part of an optimization ecological framework, called EPRVNS. The PRVNS algorithm allows to evolve a population of individuals (i.e., candidate solutions) in such a way that each individual has the ability to autonomously adapt its neighborhood search amplitude. Together with the ecological inspiration, the proposed approach achieves co-evolution through information exchange among different populations. This work focuses on unconstrained continuous optimization problems. Hence, some benchmark functions were applied with a high number of dimensions ($D=250$) in order to evaluate the proposed approach. Results were obtained and compared with its respective non-population approach suggesting that the proposed algorithm is a competitive alternative to unconstrained continuous optimization.*

Palavras-chave: VNS, ecossistema computacional, otimização contínua, repositório de benchmark

1. INTRODUÇÃO

Segundo Nenad *et al.* [2], o algoritmo de Busca em Vizinhança Variável (*Variable Neighbourhood Search - VNS*) é uma meta-heurística de melhoras iterativas onde sua principal característica é modificar iterativamente uma única solução corrente,

utilizando variações de vizinhança no decorrer da busca.

Existem algumas variações do VNS mas sua versão mais canônica é o VNS Reduzido (RVNS). Essencialmente, o algoritmo VNS não utiliza uma abordagem populacional. Um algoritmo populacional possui várias soluções candidatas (indivíduos). Cada indivíduo é iniciado de modo aleatório em diferentes regiões do espaço de busca, permitindo explorar diferentes regiões, aumentando a diversidade da busca.

Grande parte dos algoritmos populacionais fazem parte da Computação Natural, área da Ciência da Computação que utiliza a natureza como fonte de inspiração. Segundo Jonas *et al.* [1], tais algoritmos vem sendo usados para resolver problemas complexos na área de otimização. Outra abordagem bio-inspirada é o Ecossistema de Otimização proposto por Rafael *et al.* [4]. Durante a otimização, esta estratégia tira proveito das relações de um ecossistema, realizando a troca de informação entre as populações tentando melhorar a solução final.

Este artigo aplica uma versão populacional (PRVNS), do algoritmo RVNS, Wesklei *et al.* [5], dentro do Ecossistema de Otimização[4] para problemas de otimização contínua. No algoritmo PRVNS cada indivíduo define as variações de vizinhança de forma independente. O controle de amplitude autônomo para cada indivíduo permite intensificar ou diversificar a busca por regiões promissoras no espaço de soluções de maneira heterogênea.

A estrutura deste trabalho segue na Seção 2 com uma revisão bibliográfica sobre

os conceitos que envolvem o algoritmo *VNS* juntamente com o algoritmo *RVNS* e a versão populacional com o algoritmo *PRVNS*; a Seção 3 discute as relações ecológicas e o comportamento no ecossistema utilizado neste trabalho; a Seção 4 discute os experimentos realizados; a análise dos resultados é feita na Seção 5; por fim as conclusões do trabalho são apresentadas na Seção 6, juntamente com os trabalhos futuros.

2. BUSCA EM VIZINHANÇA VARIÁVEL E O ALGORITMO PRVNS

O algoritmo de Busca em Vizinhança Variável é um algoritmo meta-heurístico e modifica uma solução corrente explorando vizinhos na tentativa de encontrar melhores soluções. No *VNS*, a amplitude da busca varia dinamicamente de acordo com a dificuldade de melhora da solução corrente, Nenad *et al.* [2].

Uma estrutura de vizinhança é denotada por $N_k(\vec{x})$, sendo \vec{x} a solução corrente e k o índice da estrutura de vizinhança sendo explorada (k varia entre k_1 e k_{max}). O vetor \vec{x} é um vetor solução d -dimensional ($\vec{x} = [x_1, x_2, \dots, x_d]$) e entende-se por vizinhos de \vec{x} os vetores próximos a ele obedecendo à estrutura e amplitude de vizinhança utilizada. Para delimitar os vizinhos em uma região pode-se usar uma amplitude ou raio definido por $r_k(k_1, k_2, \dots, k_{max})$ em que, ao longo do processo de busca, este pode variar, ampliando ou contraindo a amplitude de vizinhos de \vec{x} [2].

O comportamento de variação da vizinhança é ilustrado na Fig. 1. No passo (a), k inicia em 1 e $N_k(\vec{x})$ pode ser visto pelo círculo em negrito. Quando o *VNS* encontra uma solução melhor ele a assume como solução corrente e atribui o valor de $k=1$ como visto no passo (b). Em (c), k é ampliado até chegar em k_{max} que neste caso é 3 pois não encontrou melhor solução com valores menores de k . Este processo é

repetido até encontrar a solução ótima ou a condição de parada ocorrer.




Figura 1. Comportamento do VNS. Adaptado de [2].

O Algoritmo de Busca em Vizinhança Variável Reduzido baseado em População [5] faz uso não somente de uma única solução candidata para vasculhar o espaço de soluções, mas sim de um conjunto de possíveis soluções, chamado de população. O algoritmo se baseia no comportamento do *VNS* canônico (*RVNS*) e por isso é denotado *PRVNS*. No *RVNS* tem-se a estrutura denotada por $N_k(\vec{x})$ sendo que \vec{x} é um indivíduo e k sempre referencia este mesmo indivíduo. Já na versão populacional tem-se um valor de k associado a cada indivíduo, podendo assim assumir valores distintos, o que pode ser interessante para a diversificação da população. Desta maneira, pode-se definir a estrutura de vizinhança populacional por $N_{k_i}(\vec{x}_i)$ em que k_i é o índice da estrutura de vizinhança atual para o indivíduo \vec{x}_i da população. Este índice varia entre k_{i_1} e $k_{i_{max}}$. Modificando o respectivo k_i de um indivíduo é possível expandir ou contrair a amplitude de vizinhança.

3. FRAMEWORK ECOLÓGICO PARA OTIMIZAÇÃO

O sistema computacional de otimização ecologicamente inspirado é composto por populações de indivíduos que são candidatos a solução de um problema. Cada população faz uso de uma estratégia de busca que irá influenciar no seu comportamento evolutivo. Desta forma, o ecossistema pode se comportar de forma heterogênea ou homogênea. Se todas as populações do

ambiente utilizarem a mesma estratégia de busca, será um ecossistema homogêneo. Porém, se ao menos uma população usar uma estratégia diferente então o sistema será heterogêneo [3].

As populações que se encontram na mesma região do espaço de solução compõem um habitat. Estes habitats podem se relacionar internamente (intra-habitat), em que cada população do habitat trocará informações com uma ou mais populações do mesmo habitat, ou inter-habitat realizando troca de informações entre as populações de diferentes habitats.

O relacionamento intra-habitat das populações é feito por um vínculo reprodutivo entre os indivíduos, misturando as populações e colaborando para a evolução cooperativa. No caso do relacionamento inter-habitat, esta reprodução não existe e a comunicação entre os habitats é feita através da migração de indivíduos de uma população de um habitat para outro. A comunicação intra-habitat colabora para a intensificação da busca no mesmo espaço de solução. Já a inter-habitat colabora para a diversificação da busca através do processo de migração [4].

O algoritmo *PRVNS* dentro do Ecossistema é denotado por *EPRVNS*. A troca de informação entre os habitats segue a regra inter e intra habitat, fazendo vínculo reprodutivo e migração de indivíduos respectivamente. A comunicação entre os indivíduos colabora para a evolução colaborativa da população.

4. EXPERIMENTOS

Neste trabalho o algoritmo proposto *EPRVNS* é comparado com o algoritmo canônico *RVNS* e a versão populacional *PRVNS*. Os algoritmos foram aplicados a um conjunto de 4 funções *benchmark* para otimização contínua, descritas na Tabela 1. A tabela mostra a sigla de cada função usada no trabalho, bem como o nome, o domínio e o ótimo global para minimização da função. Todos os experimentos foram executados utilizando computadores *AMD Phenom II X4 B93* com *4GB* de memória e ambiente *Linux 64 bits*. Para todos os algoritmos foram utilizadas *500.000* avaliações da

função objetivo em cada execução. Os algoritmos *PRVNS* e *EPRVNS* utilizaram uma população de 50 indivíduos cada um.

Tabela 1. Funções utilizadas nos experimentos

	Função	Domínio	Min.
F1	Rosenbrock	$[-30,30]^d$	0
F2	Schaffer F6	$[-100,100]^d$	0
F3	Griewank	$[-600,600]^d$	0
F4	Ackley	$[-32,32]^d$	0

Foram realizadas 30 execuções de cada função com dimensão $d = 250$ para cada abordagem. Optou-se por uma alta dimensionalidade nas funções para poder avaliar o desempenho dos algoritmos em problemas com alto nível de complexidade. O *RVNS* usa $k_{max}=5$ com valores: 0,1 ; 0,28 ; 0,78 ; 2,19 e 6,14 obtidos de uma progressão geométrica de razão 2,8 definida de forma empírica. O *PRVNS* utiliza valores distribuídos uniformemente entre 0 e 1: 0,1 ; 0,3 ; 0,5 ; 0,7 e 0,9 também com $k_{max}=5$ de forma empírica. Os demais parâmetros do *EPRVNS* são o número de interações entre os habitats e as avaliações entre cada iteração. Foi definida 500 iterações dos habitats com 200 avaliações para cada iteração e o número de populações que constitui o sistema foi definido como 200.

5. RESULTADOS E ANÁLISE

Os resultados dos experimentos para as quatro funções *benchmark* são mostrados na Tabela 2 com o número de cada função e a média com desvio padrão para os algoritmos *RVNS*, *PRVNS* e *EPRVNS*, respectivamente. Em negrito esta ressaltado o algoritmo que obteve o melhor resultado para determinada função levando em consideração a sobreposição ou não do desvio padrão. Na parte inferior da tabela, a quantidade de melhores soluções encontradas foram sumarizadas para cada algoritmo.

Tabela 2. Resultados obtidos para os experimentos com as funções ($d=250$)

Número		RVNS	PRVNS	EPRVNS
F1	Média	3,81e+9	1444,04	245,24
	Desv. P.	2,79e+8	1638,60	0,17
F2	Média	123,00	113,87	104,23
	Desv. P.	0,91	1,84	0,71
F3	Média	7225,45	1,00	2,18e-16
	Desv. P.	403,71	0	0
F4	Média	21,12	3,13e-10	9,53e-11
	Desv. P.	0,07	0	0
Melhores soluções		0	0	4

Comparando o *PRVNS* com o *RVNS*, a influência populacional do *PRVNS* gerou uma melhora bastante significativa no valor da solução e na convergência do algoritmo como visto em todos os casos da Tabela 2. A melhora na solução ocorre pela troca de informação da população no processo de perturbação, o que aumenta a diversidade da busca. O controle de amplitude separada para cada indivíduo permite intensificar ou diversificar de forma independente diferentes regiões do espaço de busca.

Os resultados do *EPRVNS* na Tabela 2 foram melhores que os resultados do *RVNS* e *PRVNS* em todas as funções. A influência do Ecosistema no *EPRVNS* leva a melhores resultados devido a troca de informação e coevolução, o que permite maior equilíbrio na diversificação e intensificação do processo de busca.

6. CONCLUSÃO

O presente trabalho aplica uma versão populacional (*PRVNS*) do algoritmo *RVNS* dentro de um *framework* com inspiração ecológica [4] para problemas de otimização contínua. O algoritmo populacional *PRVNS*, permite usar várias soluções candidatas para explorar o espaço de soluções, em que cada indivíduo pode definir as variações de vizinhança de forma independente através da amplitude. Aliada a estratégia populacional, a inspiração no Ecosistema pelo *EPRVNS* permite tirar proveito da população de soluções candidatas co-evoluindo em um

contexto ecossistêmico. Esta abordagem permite maior equilíbrio na diversificação e intensificação do processo de busca devido a troca de informação e coevolução gerada pela inspiração no Ecosistema. Comparando o *RVNS* e *PRVNS* com o *EPRVNS*, os resultados se mostram melhores com a abordagem inspirada no Ecosistema. Estes resultados mostram que a comunicação entre os indivíduos colabora para a evolução colaborativa das populações.

Como trabalhos futuros, pretende-se utilizar um conjunto maior de funções e realizar testes estatísticos nos resultados. Objetiva-se também aplicar este algoritmo em problemas do mundo real.

REFERÊNCIAS

- [1] J. Krause, J. Cordeiro, R.S Parpinelli and H.S Lopes. A Survey of Swarm Algorithms Applied to Discrete Optimization Problems, 2013.
- [2] N. Mladenovic and J. Potvin. Handbook of Metaheuristics, Springer, 2010 p.61-86.
- [3] R.S. Parpinelli and H. S. Lopes. A computational ecosystem for optimization: review and perspectives for future research. Memetic Computing 7(1): 29-41 (2015)
- [4] R.S. Parpinelli and H.S. Lopes. Biological plausibility in optimisation: an ecosystemic view. In: Int. J. Bio-Inspired Computation, Vol. 4, No. 6, 2012.
- [5] W. Migliorini and R.S. Parpinelli. Uma Abordagem Populacional para o Algoritmo de Busca em Vizinhança Variável Aplicado em Otimização Contínua. In: Computer on The Beach, 2015, Florianópolis. Computer on The Beach, 2015. v. 1. p. 11-20.