



**UNIVERSIDADE FEDERAL DO PARÁ**  
**INSTITUTO DE CIÊNCIAS EXATAS E NATURAIS**  
**FACULDADE DE COMPUTAÇÃO**

**LANA PRISCILA DA SILVA FERREIRA**

**Políticas de Migração Assíncronas em Algoritmos Genéticos  
Paralelos Aplicado a Otimização Multimodal**

Belém - PA

2017

Lana Priscila da Silva Ferreira

**Políticas de Migração Assíncronas em Algoritmos Genéticos  
Paralelos Aplicado a Otimização Multimodal**

Trabalho de Conclusão de Curso apresentado à faculdade de computação como requisito parcial para obtenção do grau de Bacharel em Ciência da Computação. Instituto de Ciências Exatas e Naturais. Universidade Federal do Pará.

Orientador Prof. Dr. Claudomiro de Souza de Sales Junior

Coorientador Ms. Reginaldo Cordeiro dos Santos Filho

Belém - PA

2017

Lana Priscila da Silva Ferreira

**Políticas de Migração Assíncronas em Algoritmos Genéticos  
Paralelos Aplicado a Otimização Multimodal**

Trabalho de Conclusão de Curso  
apresentado à faculdade de computação  
como requisito parcial para obtenção do  
grau de Bacharel em Ciência da  
Computação. Instituto de Ciências  
Exatas e Naturais. Universidade Federal  
do Pará.

Data da defesa: Belém-PA, 20 de abril de 2017

Conceito: \_\_\_\_\_

---

**Prof. Dr. Claudomiro de Souza de Sales Junior** – Orientador  
Faculdade de Computação – ICEN/UFPA

---

**Msc. Reginaldo Cordeiro dos Santos Filho** – Coorientador  
Faculdade de Computação – ICEN/UFPA

---

**Prof. Dr. Josivaldo de Souza Araujo** – Membro  
Faculdade de Computação – ICEN/UFPA

---

**Prof. Msc. Mauro Rodrigo Larrat Frota e Silva** – Membro  
Faculdade de Computação – ICEN/UFPA

*Dedico este trabalho aos meu pais, Wellington Jorge de Miranda  
Ferreira e Edinete Conceição Nogueira da Silva, por me apoiarem acima  
de tudo.*

## **AGRADECIMENTOS**

Agradeço primeiramente aos meus pais, Wellington e Edinete, pela educação a qual recebi, fruto dos esforços e sacrifícios de ambos, e que estiveram comigo a cada passo dessa trajetória contínua e árdua. E ao meu irmão Leonardo Ferreira, que se mostrou um desafio constante na minha vida e também o seu ponto de humor, com você jamais estarei só.

A minha grande amiga de infância Joyce Bastos, que escreveu parte de sua história comigo e mesmo longe continua a torcer por mim.

Agradeço ao meu orientador, Claudomiro de Souza de Sales Junior, por todos os seus ensinamentos ao longo, não somente da produção deste trabalho, mas da graduação como um todo, tendo sido um dos professores mais entusiasmados que conheci até hoje.

Agradeço ao meu Coorientador, Reginaldo por sempre me trazer novas ideias e perspectivas, sugerir alternativas, incentivar minhas buscas e me aconselhar muito diligentemente, seja por meio de meus intermináveis e-mails super explicativos (sim, eu sei que faço isso) ou as mensagens nos aplicativos de conversa deixadas na hora em que eu tinha uma ideia ou dúvida. Independente da hora.

Agradeço ao professor, Dionne Cavalcante Monteiro, por me guiar nos primeiros anos da graduação atuando não somente como meu orientador de Iniciação Científica, mas também como um amigo que aponta os primeiros caminhos dentro da graduação.

Ao meu amigo Leomario Machado, cujo entusiasmo constante para tudo que me parecia confuso, difícil ou complicado em minha visão de caloura, me inspirava a almejar mais.

Agradeço as minhas avós, que já não se encontram entre nós, mas que me forneceram um porto seguro a cada fim de semana, feriado, férias e datas comemorativas durante a minha vida.

Vocês eram extremamente diferentes e graças a isso eu pude ver o mundo de maneira mais ampla.

Agradeço à todas as pessoas que conheci nesses anos de graduação, tanto os amigos como o Alcyr, o Moisés, o Wallisson e a Alessandra com quem convivi e conversei mais em minha turma, quanto aqueles que conheci mais adiante, como o Anderson, a Nicoli, Alessandra Alves e João Courisi que se tornaram pessoas queridas um pouco depois, mas também a quem não tive tempo ou oportunidade de me afeiçoar, pois eles estiveram ali, no mesmo caminho, dividindo o mesmo dia a dia e passando provavelmente dificuldades similares. Àqueles que me estenderam as mãos, muito obrigada.

Agradeço a minha grande amiga Janynne Palheta, que foi sem dúvida a pessoa mais preciosa que tive a honra de conhecer durante esses anos, a pessoa que esteve ali me dando bronca a cada grito de desânimo que eu me permiti soltar e do meu lado a cada riso de felicidade. Ao meu amigo Tiago Araújo que atuou como um irmão e um encorajador, sobretudo nos anos finais da graduação, me mostrando que com muito esforço se vai longe. Ao Brunelli Miranda, um dos amigos mais compreensivos e enigmáticos que já tive, mas que ao se aproximar demonstrava conhecimento, amplidão de interesses e ... um nome que o Word sempre se esforça para corrigir.

Agradeço a todos os professores que tive, não somente na graduação, mas durante a minha vida. Eu não cito seus nomes, mas vocês são parte de tudo que conquistei.

Agradeço a todos os escritores e leitores, anônimos ou não, que me incentivaram no mundo da escrita, sendo um dos meus hobbies favoritos e uma atividade de prazer que sempre deu contrabalanço a vida tumultuada. Ao EXO que se tornou meu grupo asiático favorito, embalando com seus sons muitas de minhas noites insones, fases difíceis e dias alegres.

Por último, mas não menos importante, agradeço a todos que contribuíram direta ou indiretamente na realização deste trabalho e de todas as outras atividades desenvolvidas no decorrer da graduação.

*“Não são nossas habilidades que mostram quem realmente somos, são nossas escolhas” (Alvo Dumbledore – Da Obra de J.K Rolling)*

## RESUMO

Os algoritmos genéticos, são metaheurísticas bioinspiradas no campo da genética utilizadas para resolver problemas onde normalmente não se conhece um algoritmo eficiente; é muito aplicado em problemas de otimização, onde uma solução sub-ótima para o problema precisa ser encontrada. Há muitas formas de utilizar os conceitos de algoritmos genéticos na resolução de problemas, como os NP-Difíceis; devido a seus muitos parâmetros passíveis de personalização, sendo possível configurá-los de acordo com o problema em questão. Os algoritmos genéticos paralelos são comumente utilizados para resolução de problemas de forma mais próxima à analogia de evolução das espécies, visto que várias populações, por vezes isoladas se desenvolvem independentemente, podendo por tanto explorar um espaço de busca maior do que os AG seriais; podendo também interagir. Um desses mecanismos de interação é conhecido como técnicas ou políticas de migração. Neste trabalho serão apresentadas políticas de migração presentes na literatura, uma política proposta e mais algumas políticas decorrentes da variação destas, o objetivo é comparar os desempenhos das políticas de migração aqui apresentadas, na otimização de quatro funções multimodais a fim de determinar as mais eficientes e sugerir melhorias futuras para elas.

**Palavras-chave:** Algoritmo genéticos, Paralelismo, Políticas de Migração, Otimização Multimodal.

## **ABSTRACT**

Genetics algorithms are bionspired metaheuristics in the field of genetics used to solve problems where an efficient algorithm is usually not known; is very applied in optimization problems, where sub-optimal solution to the problem needs to be found. There are many ways to use the concepts of genetic algorithms in solving problems, such as NP-Difficult; due to is many customizable parameters, being possible to configure them according to the problem in question. Parallel genetic algorithms are commonly used to solve problems in a way that is closer to the evolutionary analogy of species, since several populations, sometimes isolated, develop independently and can therefore exploit a larger search space than the serial genetic algorithms; and can also Interact. One such interaction mechanism is known as migrations techniques or policies. In this work, migrations policies will be presented in the literature, a proposed policy and some other policies resulting from the variation of these, the objective is to compare the performance of the migrations policies presented here, in the optimization of four multimodal function in order to determine the most eficiente and suggest future improvements for them.

**Keywords :** Genetic Algorithms, Parallelism, Migration Policy, Multimodal Optimization.

## LISTA DE ILUSTRAÇÕES

Figura 1. Diagrama atividade Algoritmo genético.....	27
Figura 2 Cruzamento Uniforme .....	30
Figura 3 Cruzamento ponto a ponto.....	30
Figura 4 Cruzamento multiponto .....	31
Figura 5 Exemplo de Mutação Simples .....	31
Figura 6 Grafo totalmente conectado .....	34
Figura 7 Exemplo de Migração.....	35
Figura 8 Função Ackley .....	37
Figura 9 Função Rosenbrock.....	38
Figura 10 Função Griewank .....	39
Figura 11 Função Rastrigin .....	40
Figura 12 Algoritmo multipopulacional – Multithreading.....	41
Figura 13 Fluxograma da metaheurística genérica paralela assíncrona.....	43
Figura 14 Diagrama de classes.....	44
Figura 15 Política de Migração do Melhor .....	46
Figura 16 Política de migração dupla randômica.....	46
Figura 17 Política de migração simples de substituição aleatória pelo melhor .....	47
Figura 18 Política de migração dupla de substituição dos piores pelos melhores .....	48
Figura 19 Política de migração dupla substituição aleatória dos melhores.....	48
Figura 20 Gráfico de média de convergência aos Ótimos Globais .....	50
Figura 21 Média de ocorrência de migrações .....	51
Figura 22 Média do Fitness para PMM.....	55
Figura 23 Média do Fitness para PMDR.....	57
Figura 24 Média do Fitness para PMSAM.....	59

Figura 25 Média do fitness para PMDPM .....	61
Figura 26 Média de fitness para PMDSAM.....	63

## LISTA DE SIGLAS

AG	Algoritmo Genético
AC	Algoritmos Culturais
AGP	Algoritmo Genético Paralelo
AGPM	Algoritmo Genético Paralelo Multi-populacional
PMM	Política de Migração do Melhor
PMDR	Política de Migração Dupla Randômica
PMSAM	Política de Migração de Substituição Aleatória pelo Melhor
PMDPM	Política de Migração Dupla de Substituição dos Piores pelos Melhores
PMDSAM	Política de Migração Dupla de Substituição Aleatória dos Melhores

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>15</b>
<b>1.1</b>	<b>Motivação .....</b>	<b>17</b>
<b>1.2</b>	<b>Trabalhos Correlatos .....</b>	<b>17</b>
<b>1.3</b>	<b>Justificativa .....</b>	<b>19</b>
<b>1.4</b>	<b>Objetivos.....</b>	<b>20</b>
1.4.1	Objetivos Gerais .....	20
1.4.2	Objetivos Específicos .....	20
<b>1.5</b>	<b>Metodologia do Trabalho.....</b>	<b>21</b>
<b>1.6</b>	<b>Estrutura do Trabalho.....</b>	<b>22</b>
<b>2</b>	<b>ALGORITMOS EVOLUCIONÁRIOS .....</b>	<b>24</b>
<b>2.1</b>	<b>Algoritmos Genéticos .....</b>	<b>25</b>
2.1.1	Esquema de um Algoritmo Genético (AG) .....	26
2.1.2	Fitness .....	28
<b>2.2</b>	<b>Operadores Genéticos .....</b>	<b>28</b>
2.2.1	Seleção .....	28
2.2.2	Cruzamento.....	29
2.2.3	Mutação .....	31
<b>2.3</b>	<b>Algoritmos Genéticos Paralelos.....</b>	<b>32</b>

2.3.1	Tipos de Algoritmos Genéticos Paralelos.....	33
2.3.2	Topologia de Algoritmos Genéticos Paralelos .....	33
2.3.3	Migração .....	34
<b>2.4</b>	<b>Otimização Multimodal .....</b>	<b>36</b>
2.4.1	Ackley.....	36
2.4.2	Rosenbrock .....	37
2.4.3	Griewank.....	38
2.4.4	Rastrigin.....	39
<b>3</b>	<b>ALGORITMO GENÉTICO PARALELO APLICADO A OTIMIZAÇÃO MULTIMODAL ....</b>	<b>41</b>
<b>3.1</b>	<b>Fluxograma da metaheurística genética paralela assíncrona .....</b>	<b>42</b>
<b>3.2</b>	<b>Diagrama de Classe .....</b>	<b>44</b>
<b>3.3</b>	<b>Políticas de Migração .....</b>	<b>45</b>
3.3.1	Política de migração do melhor (PMM) .....	45
3.3.2	Política de migração dupla randômica (PMDR).....	46
3.3.3	Política de migração simples de substituição aleatória pelo melhor (PMSAM) .....	47
3.3.4	Política de migração dupla de substituição dos piores pelos melhores (PMDPM) .....	47
3.3.5	Política de migração dupla substituição aleatória dos melhores (PMDSAM) .....	48
<b>4</b>	<b>RESULTADOS .....</b>	<b>49</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>66</b>
<b>6</b>	<b>TRABALHOS FUTUROS .....</b>	<b>67</b>
	<b>REFERÊNCIAS .....</b>	<b>68</b>

# 1 INTRODUÇÃO

Com o avanço da computação ao longo das décadas e o desenvolvimento de novos algoritmos para resolução de problemas de maneira específica, ocorreu um impulso no sentido de alcançar novas formas de resolver problemas ainda não solucionados por conta de sua alta complexidade, tais problemas são conhecidos como NP-Difíceis, e possuem extremo interesse prático, cuja resolução, se dava por meio da força bruta, que é um método dispendioso que envolve basicamente caminhar por todas as combinações possíveis de soluções até obter uma resposta; métodos probabilísticos ou mesmo outras heurísticas; e estes embora obtivessem resultados, nem sempre eram satisfatórios. Nesse contexto, optou-se por buscar novas formas de inspirar-se, o que gerou diversas novas heurísticas, baseadas principalmente em outras áreas do conhecimento como, tal como, a biologia.

A Computação Evolucionária é uma área de pesquisa dentro da ciência da computação, e como o nome sugere tem um sabor especial da computação, que se inspira no processo da evolução natural. (Eiben e Smith, 2015). Em Linden *et al* (2008) diz-se que os algoritmos evolucionários utilizam de modelos computacionais de processos naturais da evolução como um meio para resolver problemas.

Dentre os diversos modelos que compõe os Algoritmos Evolucionários, existem os Algoritmos Genéticos, os AGs são técnicas heurísticas que simulam os passos do processo de evolução biológica a fim de encontrar não apenas um resultado, mas um conjunto de resultados ótimos, podendo mesmo chegar ao melhor possível.

Os AGs são utilizados para realizar otimização e resolver problemas que normalmente necessitam de muitos recursos computacionais ou são muito complexos. Linden *et al* (2008) conceitua-os como políticas de busca extremamente eficientes que devem percorrer todo espaço de soluções buscando aquelas que são mais próximas de uma solução ótima. Sendo não

recomendados, portanto, para utilização, em problemas que possuam algoritmos específicos para este fim, pois em comparação a um algoritmo específico para a resolução de um problema os AGs não possuem um bom tempo de processamento.

Segundo Alba *et al* (1999) caso se imite a evolução natural, não se atuaria sobre uma única população cuja possibilidade de acasalamento se daria somente entre eles, ou seja, parceiros da mesma população, na realidade as espécies tendem a se reproduzir em subgrupos localizados. Uma grande população distribuída em subgrupos semi-isolados são chamadas de *polytypics*. Dentro desse contexto o Algoritmo Genético Paralelo (AGP) introduz o conceito de processos interconectados, ou seja, a comunicação entre processos semi-isoladas ou isoladas. As regras de seleção e reprodução permitiriam a evolução local da espécie, enquanto que através da migração a variabilidade seria alcançada. A migração por sua vez permitiria a comunicação entre essas populações, promovendo troca de informações entre elas e constituindo-se primariamente de enviar um indivíduo de uma população para a outra.

Existem duas alternativas para selecionar os indivíduos que emigram de um deme também chamada de ilha. Eles podem ser escolhidos aleatoriamente ou selecionando os melhores indivíduos em um deme. Da mesma forma, existem duas opções para substituir os indivíduos existentes no deme recebido com os migrantes que chegam: escolha aleatoriamente ou substitua do pior. (Cantú-Paz, 2001)

A migração é utilizada como um mecanismo para melhorar o desempenho do Algoritmos Genéticos Paralelos, ampliando a possibilidade de bons indivíduos serem repassados a outras populações e, portanto, melhores soluções candidatas podem surgir nas próximas gerações, resolvendo assim problemas de grande complexidade por meio desses conjuntos de soluções. Aprimorar essas políticas de migração pode auxiliar na diminuição do custo computacional, auxiliar na obtenção de resultados melhores e conseqüentemente na resolução de problemas.

## 1.1 Motivação

Durantes os estudos realizados acerca dos Algoritmos Genéticos Paralelos em conjunto com as políticas de migração existentes, notou-se um grande uso de políticas já estabelecidas na literatura há um bom tempo, modificando, entretanto, o esquema da migração como alteração de taxas ou adaptação de frequência de migrações, além de algumas comparações acerca dos tipos de migração sendo esta substituição pelo melhor indivíduo, substituir aleatoriamente um indivíduo. (CANTÚ-PAZ,2001). Todavia, não se observou nenhuma política abordando migração dupla, onde duas populações trocariam indivíduos ao mesmo tempo e o que uma política desta natureza poderia melhorar partindo das existentes. Bem como não se observou dentre os trabalhos atuais, a aplicabilidade dentro de um algoritmo assíncrono. Isso criou uma motivação em torno de verificar como políticas diferentes de migração atuariam em um mesmo projeto, na resolução de um mesmo problema em comparação a uma política de migração dupla proposta e suas variações, a fim de determinar se as migrações duplas podem se desempenhar tão bem quanto as existentes.

## 1.2 Trabalhos Correlatos

As políticas de migração são comumente aplicadas em trabalhos acerca de paralelismo a fim de comunicar populações, podem ser utilizadas de muitas maneiras, seja em algoritmos monobjetivos ou multiobjectivos, de forma síncrona ou assíncrona. Um dos primeiros que utilizou-se de políticas de migração foi Grosso *et al* (1985), onde foram implementadas cinco populações e cada qual trocava indivíduos com uma taxa de migração fixa. Foi também um dos primeiros a detectar a importância da taxa de migração e perceber que se esta fosse muito baixa as populações se comportariam quase como se estivessem isoladas.

A política de Pettey *et al* (1987) funciona da seguinte maneira, o melhor indivíduo encontrado em uma população é enviado aos seus vizinhos após cada geração, esta é uma política de migração da literatura cujo objetivo é a comunicação constante de forma a assegurar uma boa mistura dentre os indivíduos propiciando diversidade. Outra política bastante conhecida e utilizada é a desenvolvida por Tanese *et al* (1987) onde os migrantes são selecionados probabilisticamente dos melhores indivíduos de uma população e enviados para substituir os piores indivíduos do destino. Cohoon *et al* (1987) percebeu por suas experiências com

algoritmos genéticos paralelos que novas soluções foram encontradas após a ocorrência de migração, embora isso não afetasse significativamente a qualidade das soluções entre essas migrações. Observou também que até então as migrações ocorriam de maneira síncrona, em intervalos constantes e predeterminados.

Em Lin *et al* (2012) há uma análise de esquemas adaptativos de migração, no trabalho comparou-se esquemas de migração baseadas em aptidão (divididos em aptidão baseada em taxa de migração e intervalo de migração) e aptidão baseada em diversidade. A abordagem adaptativa propunha que a taxa de migração fosse ajustada de acordo com uma equação proposta que utilizava melhor aptidão, aptidão média e valores mínimos de aptidão de subpopulações como variáveis. A migração deveria ocorrer somente quando uma população estivesse próxima a convergência. Já os esquemas baseados em intervalo e taxa adaptavam seus valores para mais ou para menos ao longo das gerações de acordo com o comportamento da população, ou seja, se a qualidade de solução de uma subpopulação aumentava, essa taxa ou intervalo se ajustava. As políticas foram aplicadas ao problema da mochila booleana e contrário ao esperado a abordagem preliminar baseada em aptidão superou aquela baseada em diversidade. Esse fenômeno foi explicado posteriormente, afirmando que a equação aplicada a migração baseada em diversidade não era suficientemente boa para medir a convergência da população. Assim novos esquemas foram propostos; a política de migração utilizada dentro do esquema foi a de selecionar melhores indivíduos para substituir os piores da população vizinha.

No trabalho de Upadhyayula *et al* (2015) uma estratégia de dominância é utilizada para gerir as migrações, todavia não aplicada a Algoritmo Genético convencional ou Algoritmo Genético Paralelo Multi-populacional e sim a Algoritmos Culturais (AC), que são uma extensão de algoritmos genéticos. Um AC consiste em dois componentes, espaço de população e espaço de crenças, onde as informações são compartilhadas. A migração utilizada foi a de envio do pior indivíduo de uma população para outra, ou seja, aquele com o pior fitness foi enviado a população destino, sob o argumento de que o pior de uma população, poderia ser o melhor de uma outra.

Em Morady (2016) um algoritmo genético paralelo multi-populacional é utilizado para otimizar a programação de tarefas de um multiprocessador na presença de custos de comunicação. Segundo o autor, o uso de AGPM não só diminui o tempo de execução como

também aumenta a qualidade das soluções de agendamento; também afirma que o uso de tamanhos de populações menores e troca de informações através de migração conduzem a primeira e a última melhoria respectivamente.

Segundo Cantú-Paz (2001) a escolha dos migrantes, embora por vezes não seja considerado importante nos trabalhos de Algoritmos Genéticos Paralelos, podem influenciar fortemente a seleção fazendo com que o algoritmo venha a convergir mais rapidamente e atesta que a escolher tanto o migrante quanto o substituto por sua condição é a maneira mais eficiente e também a mais comum, dentre os Algoritmos Genéticos Paralelos que utilizam migração. A convergência mais rápida pode resultar em uma redução do trabalho computacional total [...]

### **1.3 Justificativa**

Os trabalhos correlatos atestam a importância das políticas de migração para obtenção de bons resultados e redução do tempo computacional. Ao longo do tempo as políticas de migração vêm sendo utilizadas sem grandes modificações, geralmente a partir de políticas clássicas da literatura adotando diferentes estratégias de aplicação, como a adaptativa, que manipula as taxas de migração de acordo com a necessidade do algoritmo, ou a manutenção da frequência fixa por exemplo, todavia percebeu-se poucos trabalhos que comparavam efetivamente a eficácia dessas políticas, também não se detectou a utilização de migrações duplas, como as propostas por este trabalho.

A justificativa se dá em observar o comportamento de algumas políticas tradicionais, atuando de maneira assíncrona, propondo outras a partir dessas políticas que possam atuar em um Algoritmo Genético Paralelo Multi-populacional de maneira assíncrona, realizar migrações simultâneas entre duas demes ou ilhas, para assim verificar quais poderiam ser melhores para resolver conjuntos de problemas futuros. Qual a aplicabilidade quanto a migração assíncrona de mais de um indivíduo, de que modo essa migração afeta a convergência, qual a chance de obter ótimos globais e sua eficácia em casos práticos.

## 1.4 Objetivos

### 1.4.1 Objetivos Gerais

O objetivo geral deste trabalho é aplicar políticas de migração inspiradas na literatura e adaptadas para trabalhar de modo assíncrono, em conjunto com políticas propostas para o trabalho, em um Algoritmo Genético Paralelo Multi-populacional (AGPM), para a resolução de quatro funções multimodais simples e analisar o desempenho dessas políticas.

Duas dessas políticas de migração assíncronas funcionam de modo a enviar seu melhor indivíduo, seja para todas as populações ou para um indivíduo aleatoriamente, uma política troca dois indivíduos aleatoriamente entre duas populações, uma das políticas envia o melhor indivíduo de uma população em substituição do pior, outra realiza uma migração dupla entre dois indivíduos, enviando seus melhores em substituição aos piores da população destino e por fim uma política de migração dupla, que envia seus melhores para substituir um indivíduo aleatório da população destino.

### 1.4.2 Objetivos Específicos

Os objetivos específicos deste trabalho compreendem a realização de estudos acerca dos Algoritmos Genéticos (AG), dos Algoritmos Genéticos Paralelos Multipopulacionais (AGPM), as políticas de migração da literatura, e as funções multimodais sobre as quais o algoritmo atuará para otimização. A sugestão de novas políticas de migração a partir do pesquisado na literatura com ênfase em migrações assíncronas que possuam as restrições necessárias, ou possam ser adaptadas para ser aplicados em Algoritmos Genéticos Paralelos (AGP). Também há o compromisso em criar uma técnica de migração que ainda não tenha sido abordada na literatura, a criação de técnicas inspiradas nas da literatura e na nova, comparando-as enfim com as do estado da arte.

- Realizar um estudo sobre os Algoritmos Genéticos, sua estrutura básica e seus operadores genéticos tradicionais tais como seleção, cruzamento e mutação.
- Realizar um estudo sobre os Algoritmos Genéticos Paralelos, sua estrutura e a atuação das políticas de migração sobre ele.
- Realizar uma pesquisa bibliográfica acerca das políticas de migração existentes e seu desempenho na comunicação de populações em diversas aplicações, tanto no sentido

de utilizar a mais pertinente para o algoritmo desenvolvido quanto como fonte de inspiração para a criação de novas políticas.

- Realizar um estudo acerca das funções multimodais a serem otimizadas.
- Implementar um algoritmo paralelo utilizando *multithreading*, para resolução de funções multimodais.
- Implementar uma ou mais políticas de migrações assíncronas da literatura.
- Implementar uma política de migração, diferente das abordagens anteriores.
- Realizar uma análise do desempenho das políticas de migração em relação ao mesmo problema, verificando quais são mais eficientes em termo de obtenção de ótimos globais e fitness.
- Apresentar o resultado das comparações realizadas e as conclusões acerca das políticas.

## 1.5 Metodologia do Trabalho

Em relação a metodologia deste trabalho, ela pode ser considerada exploratória e comparativa. Primeiramente foi realizado um estudo acerca dos Algoritmos Genéticos (AG), dos Algoritmos Genéticos Paralelos Multipopulacionais (AGPM) e o conceito de migração. Seguiu-se de um estudo das funções multimodais, problema passível de ser resolvido por AG como objeto para os testes. A seguir, uma pesquisa bibliográfica acerca das políticas de migração assíncronas e aos algoritmos genéticos foi realizada, enfatizando a resolução de problemas simples; Política da literatura então foram selecionadas, para serem utilizadas, outras foram propostas após o estudo para que se efetuasse a comparação.

O algoritmo paralelo foi então desenvolvido em linguagem JAVA, fazendo a utilização de *Multithreading* para a paralelização, as funções multimodais minimizantes foram configuradas para otimização por meio desse algoritmo e as políticas de migração foram por fim implementadas. Por conseguinte, realizou-se os testes e a análise de resultados das políticas

atuando sobre o mesmo conjunto de funções. Após isso os dados foram analisados e dispostos em gráficos para visualização dos resultados, explicações e conclusões.

## 1.6 Estrutura do Trabalho

Este trabalho está dividido em mais seis capítulos que fornecem o embasamento teórico utilizado em seu desenvolvimento, os detalhes, fluxogramas, diagramas e considerações acerca das comparações efetuadas, a política de migração sugerida, possíveis melhorias e trabalhos futuros

- **Capítulo 2 — Algoritmos Evolucionários**

Este capítulo conceitua os algoritmos genéticos fornecendo informações acerca de sua inspiração e objetivos, introduz mais diretamente aos Algoritmos Genéticos, modelo escolhido para o desenvolvimento do trabalho, tratando do conjunto de passos de um AG e seus respectivos operadores genéticos. Também introduz os conceitos e detalhes acerca dos Algoritmos Genéticos paralelos, seus tipos e suas topologias mais utilizadas, além de conceituar migração.

- **Capítulo 3 — Otimização Multimodal**

Este capítulo faz uma breve conceituação de otimização e introduz as funções multimodais sobre as quais o AG atuou, demonstrando como essas funções se comportam e por meio da expressão matemática em si, qual o resultado esperado de cada execução do algoritmo.

- **Capítulo 4 — Algoritmo paralelo Aplicado a Otimização Multimodal**

Este capítulo explica como funciona o algoritmo deste trabalho, mostra o pseudocódigo que o representa, seu fluxograma, o diagrama de classes do AGPM aplicado ao problema da otimização multimodal, bem como as políticas de migração selecionadas com seus respectivos detalhes e diagramas de sequência.

- **Capítulo 5 — Resultados**

Este capítulo mostra os resultados das políticas atuando sobre o problema, as conclusões tiradas a partir dos dados, figuras e gráficos com média de ótimos globais, média de fitness e análise dos dados obtidos todos os pormenores pertinentes a avaliação do desempenho das políticas.

- **Capítulo 6 — Considerações finais**

No último capítulo são apresentadas as considerações finais sobre o trabalho bem como sugestões para trabalhos futuros.

## 2 ALGORITMOS EVOLUCIONÁRIOS

Em seu livro “Introdução a Computação Evolucionária”, Eiben e Smith *et al* (2015, tradução própria) dizem o seguinte:

“ Não é surpreendente que alguns cientistas da computação escolheram a evolução natural como fonte de inspiração: O poder de evolução da natureza é evidente em diversas espécies que compõe o nosso mundo, cada um adaptado para viver em seu próprio nicho. A metáfora fundamental da computação evolutiva relaciona essa poderosa evolução natural com um estilo particular de resolução de problemas. ”

De acordo com Tomassini *et al* (1999) os algoritmos genéticos podem ser considerados como uma ampla classe de técnicas de otimização estocástica. Sendo considerados bastante adequados para problemas difíceis onde pouco se sabe sobre o espaço de pesquisa adjacente. Um algoritmo evolucionário mantém uma população de soluções candidatas para o problema a ser resolvido e faz essa população evoluir iterativamente aplicando um conjunto de operadores estocásticos [...]

Pode-se perceber que o intuito em utilizar essa metáfora evolutiva era a busca por simular computacionalmente as condições adequadas para a resolução de problemas, sobretudo aqueles mais difíceis, abstraindo o conceito de evolução como uma forma de delinear um campo de busca mais específico a um problema, evitando o andamento desgovernado (*Randon Walking*), fornecendo assim um conjunto de soluções candidatas de um problema que atravessaram gerações, aperfeiçoando-se e aproximando-se de soluções ótimas ou mesmo ideais. Um desses modelos evolucionários é nomeado de Algoritmo Genético e dele trataremos a seguir.

## 2.1 Algoritmos Genéticos

Os algoritmos genéticos (AG) são um ramo dos Algoritmos Evolucionários, sendo assim definidos como uma busca baseada na metáfora de processos biológicos; são técnicas heurísticas de otimização global (Linden, 2008).

Acerca desta metáfora (Eiben, 2015) diz o seguinte:

[...] é uma classe de algoritmos que são amplamente baseados nos processos Darwinianos e inspirados na genética molecular. Ao longo da história muitas espécies surgiram e evoluíram para atender a diferentes ambientes, todos usando o mesmo mecanismo biológico. Da mesma forma se nós fornecermos um algoritmo com um processo evolutivo e um novo ambiente, esperamos ver a adaptação inicial da população de forma que melhor se adeque ao ambiente.

Em termos práticos o ambiente pode ser interpretado com o problema a ser resolvido e o fitness obtido a cada geração, o meio pelo qual o algoritmo avalia o quão apto os indivíduos estão, ou seja, o quão próximo estão, de um conjunto de soluções para esse problema. Por se tratar de um método heurístico, os AG não buscam uma solução única e sim apontam para um conjunto de soluções e dessa maneira é mais recomendado que se utilize em problemas de difícil solução, que não possuam um algoritmo próprio para sua resolução, já que estes provavelmente obteriam um desempenho melhor em relação ao problema, afora o fato de que por tratar-se de uma heurística os resultados mudam a cada execução, não sendo possível obtê-los da mesma maneira que anteriormente.

Segundo Kalyanmoy *et al* (1999) a primeira vez que o conceito acerca dos algoritmos genéticos foi introduzido foi na Universidade de Michigan, Ann Harbor. Por um cientista chamado John Holland, tendo junto com seus alunos dado continuidade aos estudos acerca desta heurística; mais tarde utilizada para resolver diversos problemas do espaço dos NP-Difíceis.

### 2.1.1 Esquema de um Algoritmo Genético (AG)

Acerca do esquema básico de um AG, alguns conceitos são pertinentes para o entendimento e construção dos mesmos. Todos os termos são análogos aos da biologia.

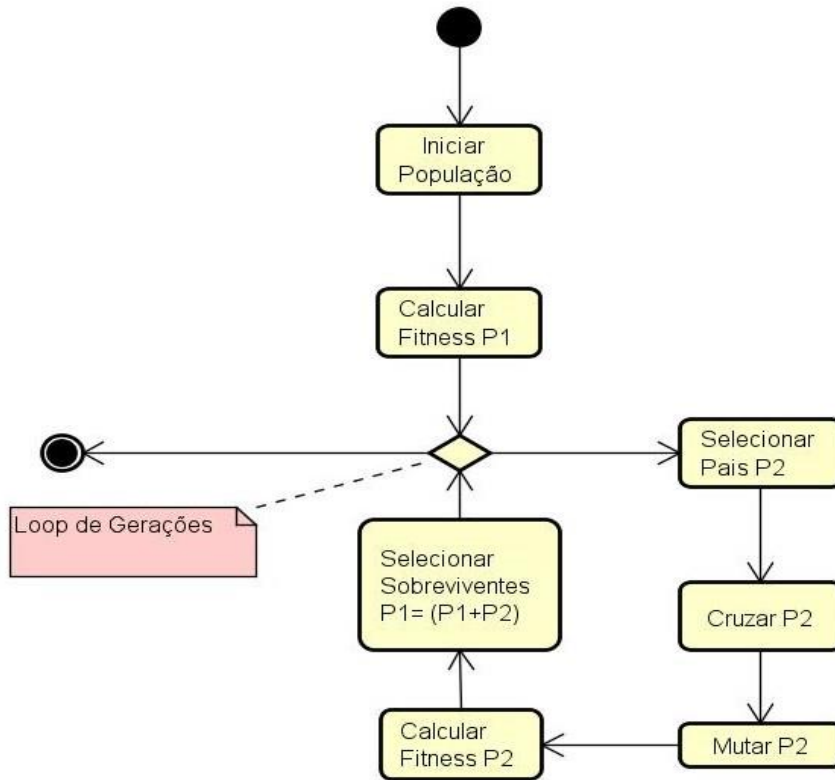
- **Genes:** As características de um indivíduo.
- **Cromossomos:** Formado por genes que são a unidade estrutural genética que compõe um indivíduo. Em algoritmos genéticos é tipicamente representado de duas maneiras, dependendo do problema em questão. Binária e Real.
- **Pais:** Dois indivíduos que interagem trocando informações genéticas para a geração de um terceiro que possua características de ambos.
- **Filhos:** Conjunto de indivíduos gerados a partir da interação dos pais.
- **População:** Conjunto de indivíduos que pode ou não ser geograficamente isolado.
- **Geração:** Um ciclo completo evolutivo, onde houve seleção de pais, cruzamento, avaliação de fitness e ocasionalmente mutação.

Para que um algoritmo genético possa ser utilizado na resolução de problemas, existem passos do algoritmo em si que serão repetidos até que uma determinada condição o pare, ou seja por convergência para o conjunto solução ou alguma outra condição estabelecida pelo desenvolvedor.

Usualmente uma população é iniciada de forma aleatória, a informação quanto ao problema a ser solucionado que guia a geração dos indivíduos dessa população encontra-se no cromossomo, formado por genes que possuem as características que esses indivíduos necessitam para fornecer um conjunto solução. Ao longo das gerações, essa população sofrerá a influência de operadores, estes fazem parte da metáfora evolucionária e representam o que se daria na natureza acerca do desenvolvimento de uma espécie, o fitness verificara a qualidade desses candidatos simulando por sua vez o processo de sobrevivência dos mais aptos.

Os operadores tradicionais são: seleção, cruzamento e mutação. É possível que ocorram outros de acordo com os critérios do desenvolvedor.

O comportamento geral dos algoritmos genéticos ocorre de acordo com o diagrama de atividades da figura 1. Alguns conceitos serão introduzidos posteriormente para melhor entendimento.



**Figura 1. Diagrama atividade Algoritmo genético.**

**Fonte: Produzido pela autora**

No diagrama de atividade da figura 1, percebe-se a iniciação da população onde os primeiros indivíduos serão configurados. Após o cálculo do fitness determinando a qualidade de cada um, dois deles são selecionados para ser os pais, esses indivíduos serão cruzados gerando um conjunto de novos indivíduos, ocorre então a mutação que modifica alguma informação genética, ocorre assim uma avaliação e os sobreviventes são eleitos para prosseguir nas próximas gerações. O algoritmo para quando a população converge, chegando a solução mais próxima do ideal, até lá o loop de gerações continuará atuando.

### **2.1.2 Fitness**

O fitness é uma função que relaciona a população ao escopo do problema e si, ela tem por objetivo dentro de um AG de avaliar a qualidade dos indivíduos em relação a solução do problema e suas chances de sobrevivência, efetuando o que na natureza seriam os fatores genéticos, ambientais e outros que influenciariam a sobrevivência de uma espécie. Essa função é utilizada a cada geração para avaliar novos indivíduos bem como manter os de gerações anteriores dentro do espaço de soluções.

## **2.2 Operadores Genéticos**

Os operadores genéticos são muito importantes para um AG pois eles têm a função de promover modificações nos genes dos indivíduos a cada geração, esse processo provoca a evolução das populações conforme as gerações passam e também mantem a variabilidade das soluções candidatas. Assim sendo, eles são responsáveis pela exploração do espaço de busca, orientando e ordenando a procura por soluções.

### **2.2.1 Seleção**

Dois indivíduos da população são escolhidos para que realizem o cruzamento, para essa seleção normalmente se utiliza aqueles indivíduos que possuem alta avaliação quanto ao fitness, todavia, considerando também alguns indivíduos menos aptos para que não haja perda de variabilidade genética e outras características favoráveis aos filhos. Essa seleção de pais ocorre de acordo com a política implementada, usualmente as mais utilizadas são roleta e torneiro, contudo há outras.

#### *2.2.1.1 Roleta*

Na seleção dos pais baseados no método da roleta, cada indivíduo recebe uma probabilidade de ser selecionado, ao acaso, de acordo com seu fitness. Um número aleatório gerado por uma distribuição uniforme  $[0,1]$  é calculado. O indivíduo que corresponder a esse número aleatório é selecionado para a população de pais, caso contrário, o gene é mantido. Este processo se repete até que todos os indivíduos sejam selecionados.

### 2.2.1.2 Torneio

Na seleção de pais baseados no método de torneio, um conjunto de cromossomos é selecionado por meio de uma distribuição uniforme, estes cromossomos são comparados em termos de fitness e os cromossomos mais adaptados para o problema são selecionados para compor os pais. Esse mecanismo é repetido até que todos os  $n$  cromossomos sejam selecionados.

### 2.2.1.3 Ranking

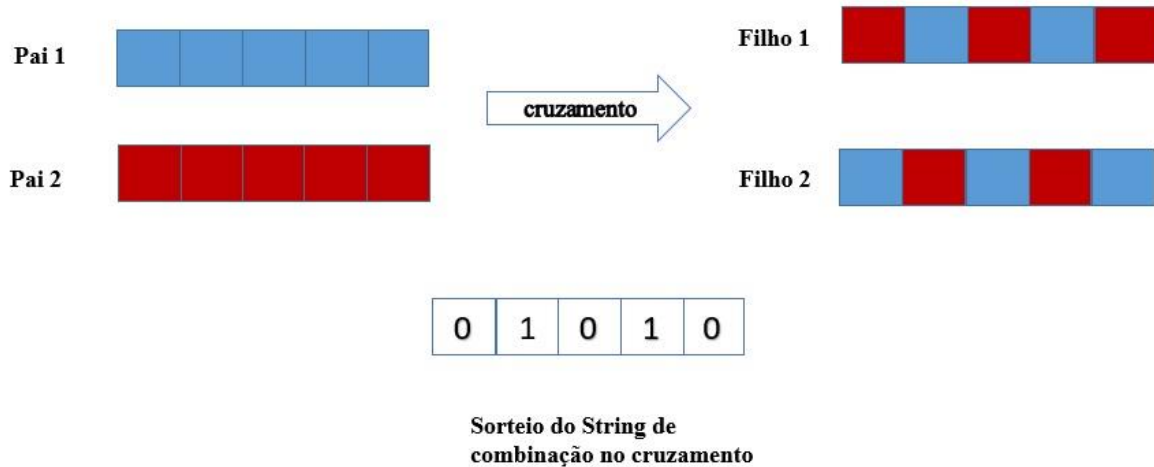
Na seleção de pais baseados no método de ranking, a população é ordenada de acordo com seu *fitness* em ordem crescente de aptidões, um número aleatório associado a posição ocupada por esses indivíduos é gerado aleatoriamente e o indivíduo que estiver na posição sorteada é utilizado para integrar a população. Esse procedimento se repete até que toda essa população seja preenchida. Percebe-se que a função fitness só é utilizada para ordenar os candidatos, não sendo diretamente ligada a escolha dos indivíduos, assim não necessariamente serão selecionados os mais aptos para a população dentre os possíveis candidatos.

## 2.2.2 Cruzamento

O cruzamento, também chamado de crossover é um dos operadores mais importantes, pois ele tem a função de gerar novos indivíduos que serão chamados de “filhos” a partir de dois indivíduos que são chamados de “pais”. Cada par de cromossomos selecionado é associado a uma avaliação que dita sua possibilidade de ocorrência de um cruzamento, e assim um número aleatório é gerado e comparado a essa avaliação, caso esse valor atribuído ao par seja menor do que o número aleatório gerado o cruzamento não ocorrer os filhos serão iguais aos pais. Há três tipos de cruzamento: uniforme, ponto a ponto e multiponto.

### 2.2.2.1 Cruzamento Uniforme

O cruzamento uniforme funciona da seguinte maneira, cada gene dos filhos recebe um número aleatoriamente gerado entre zero e um. Se ocorrer de ser sorteado o número um, o primeiro filho receberá os genes do primeiro pai e o segundo filho receberá os genes do segundo pai, se o número sorteado for zero, ocorrerá o inverso, conforme a figura 2.

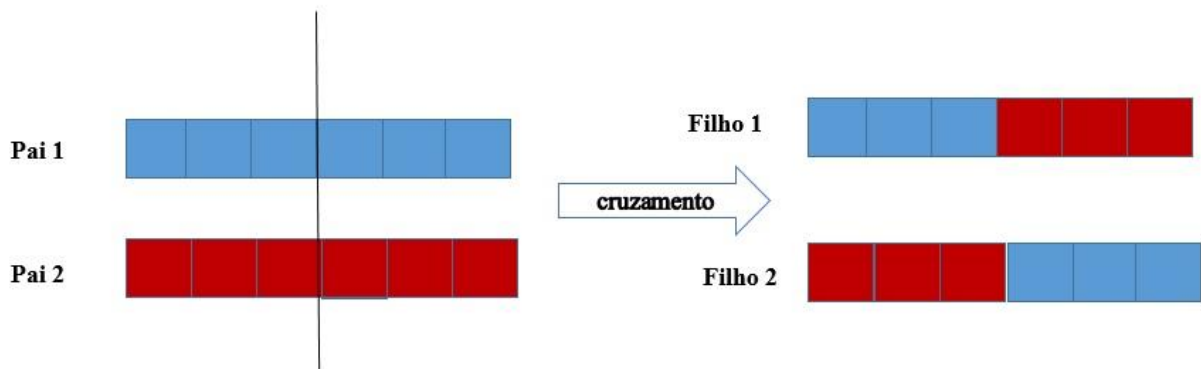


**Figura 2 Cruzamento Uniforme**

**Fonte: Produzido pela autora**

### 2.2.2.2 Cruzamento Ponto a Ponto

No cruzamento ponto a ponto é selecionado um “corte” em um único ponto dos pais dividindo-os em duas partes. Assim sendo o filho irá receber a primeira parte de um dos pais e a segunda parte do outro, formando assim um novo indivíduo, conforme a figura 3.




**Figura 3 Cruzamento ponto a ponto**

**Fonte: Produzido pela autora**

### 2.2.2.3 Cruzamento Multiponto

O cruzamento multiponto é bastante similar ao cruzamento ponto a ponto, todavia são selecionados dois cortes nos pais de forma que até o primeiro ponto de corte a informação genética pertença a um pai 1, a informação delimitada pelos dois pontos de corte pertença ao pai 2

e por fim a informação genética a partir do segundo ponto de corte até o fim torne a pertencer ao pai 1, conforme a figura 4.



**Figura 4 Cruzamento multiponto**

**Fonte: Produzido pela autora**

### 2.2.3 Mutação

Possui a função de promover a variabilidade genética entre as populações. Nesse operador ocorre a alteração de alguns genes do indivíduo, algumas vezes inclusive ocorrendo acréscimos de novas características a população original, o que é benéfico a criação de novos indivíduos. Contudo esta ocorre em taxas baixas de modo que não atinja muitos indivíduos e nem comprometa a evolução de gerações anteriores. A taxa de mutação muito alta poderia acarretar em perda de informações dos cromossomos. O tipo de mutação utilizado neste trabalho é chamado de mutação Gaussiana e ela consiste em alterar o valor do gene de um cromossomo por meio de uma distribuição Gaussiana, assim sendo o valor novo do gene é relativamente próximo ao anterior. Uma mutação simples, pode ser representada pela figura 5.



**Figura 5 Exemplo de Mutação Simples**

**Fonte: Produzido pela autora**

## 2.3 Algoritmos Genéticos Paralelos

Segundo Tomassini (1999) os algoritmos genéticos quando aplicados a problemas muito grandes ou difíceis tendem a tornar-se lentos, assim uma das maneiras de superar a restrição de tamanho e tempo é paralelizar. Sobre esse aspecto pode-se observar também que de acordo com Cormen *et al* (2001) a programação paralela permite que vários cálculos sejam computados ao mesmo tempo. Diversos problemas podem ser resolvidos seguindo o paradigma de divisão e conquista se conceitua como dividir um problema maior em problemas menores (subproblemas) de maneira que sejam resolvidos ao mesmo tempo de forma que se possa obter a resposta final a partir da união das soluções individuais obtidas.

Assim sendo o paralelismo em AG é utilizado para que as multipopulações sejam criadas segundo sua lógica e dentro de cada subpopulação o processamento ocorre de maneira individual, todavia, no caso dos AG os subproblemas permanecem como um conjunto de soluções candidatas.

Em Lin *et al* (2012) conceitua-se que algoritmos genéticos paralelos multipopulacionais são uma extensão dos algoritmos genéticos tradicionais de uma única população onde dividem a população em subpopulações isoladas onde a evolução prossegue e os indivíduos são autorizados a migrar de uma subpopulação para a outra. Essa não é uma estratégia incomum, na realidade é a essência da programação paralela contextualizada, no entanto, para o objetivo dos AG.

Os algoritmos genéticos que trabalham com múltiplas populações são difíceis de configurar pois requerem a atribuição de muitos parâmetros que afetam a eficiência e a acurácia do algoritmo (Cantú-Paz, 1999). Por conta disso, utilizar o paralelismo evolutivo requer especial atenção a esses parâmetros. Em Eiben e Smith *et al* (2011) cita-se que uma das formas de resolver esse problema seria a sintonia de parâmetros que pode ser normalmente utilizada em abordagens *multithreading*, abordagem esta utilizada no trabalho.

### 2.3.1 Tipos de Algoritmos Genéticos Paralelos

Algoritmos genéticos paralelos possuem tipos ou modelos que costumam ser aplicados em sua implementação, Morady *et al* (2016) explica que existem dois modelos mais implementados em algoritmos genéticos, o mestre e escravo e o modelo de ilha.

- Mestre- escravo: Possui um único AG (população) mantido pelo mestre e os escravos trabalham em paralelos as partes mais demoradas do algoritmo como avaliação de aptidão. É um modelo utilizado principalmente em arquiteturas de memória compartilhada e só melhora o tempo de execução total, não contribuindo diretamente para a qualidade das soluções.
- Ilhas ou Demes: O modelo de ilhas, conhecido também como modelo de migração ou modelo de múltiplas populações, consiste em vários AG independentes ocorrendo em paralelo. O modelo de ilhas não só diminui o tempo de execução como também aumenta a qualidade das soluções. O uso de tamanhos populacionais menores e intercâmbio de informações (migração), segundo o autor causa as melhorias no tempo e nas soluções.


### 2.3.2 Topologia de Algoritmos Genéticos Paralelos

A topologia é responsável pela conexão entre as subpopulações, essa organização é um dos parâmetros relevantes para a realização da migração de indivíduos, de forma que estes possam trocar informações. Neste aspecto Cantú-Paz (1999) realizou alguns estudos acerca dos AGPM, verificando o comportamento tanto de populações isoladas com baixa taxa de migração que foi denominado de limite inferior, nesta experiência as ilhas (demes) executaram até que os indivíduos se tornassem idênticos, algo possível por conta da falta de mutação; a conclusão foi que a velocidade neste caso era muito baixa e deveria ser evitada na prática; em seguida populações foram fortemente conectadas ou seja todos comunicavam-se com todos e as taxas de migração foram configuradas para seu máximo sendo denominado de limite superior, neste caso a intercomunicação resultou em melhorias significativas na qualidade das soluções, traduzido em redução do tamanho das demes e do esforço computacional.

Ainda em Cantú-Paz (1999) citava-se um trabalho anterior, que estudava o uso de mais processadores e os problemas acarretados com o aumento de custo de comunicação e diminuição de cálculos, foi demonstrado como utilizar esse trade-off a fim de reduzir o tempo computacional

e neste estudo foram considerados que a comunicação entre populações após convergência, implica em um limite inferior na frequência das migrações, tendo como limite superior então, o caso em que as populações se comunicam a cada geração. A topologia das comunicações é então um grafo totalmente conectado dividido a população entre partes iguais. Esses fatores demonstram a influência da topologia de conexão entre subpopulações na quantidade de migrações e, por conseguinte no possível desempenho do algoritmo.

A figura 6 ilustra o tipo de conexão utilizada nos estudos de Cantú-Paz e neste trabalho para comunicação entre as subpopulações no AGPM. Há outras formas de comunicação podem ser utilizadas para estabelecer comunicação em um Algoritmo paralelo, algumas delas são citadas por Nowostawski (1999) onde é afirmado que as topologias comumente utilizadas para a conexão em algoritmos genéticos paralelos são: Hipercubo, duas dimensões mesh, três dimensões mesh e Torus.



**Figura 6 Grafo totalmente conectado**

**Fonte: Produzido pela autora**

### **2.3.3 Migração**

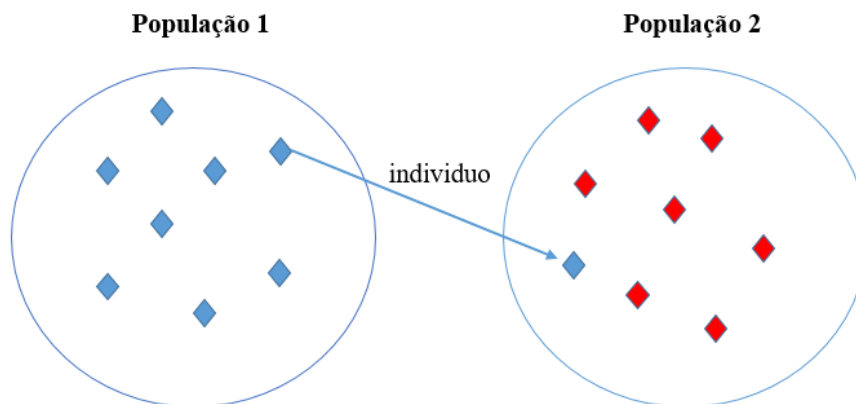
A migração é um mecanismo pelo qual populações de indivíduos trocam informações, de maneira geral é similar ao sentido que existe na biologia, onde há trânsito de indivíduos entre populações, trocando informações entre si, de fato “[...] o esquema de migração é o principal mecanismo para aumentar a diversidade de cada subpopulação” (Lin, 2012). Isso é reforçado em Morady *et al* (2016) onde cita-se que uma migração proporciona diversidade genética e ajuda a evitar a convergência prematura. Assim as políticas de migração desenvolvidas em AG buscam de modo geral manter uma variabilidade entre os indivíduos evitando uma convergência

prematura no algoritmo, isso quer dizer que possibilita uma pesquisa mais ampla no espaço de busca ao invés de interromper bruscamente a pesquisa limitando a apenas alguns ótimos locais.

As políticas de migração são dirigidas principalmente por alguns aspectos, sua taxa de migração, sua frequência também chamado de intervalo são bastante importantes. Morady *et al* (2016) diz que a taxa de migração é definida como a quantidade de informação (cromossomos) são trocadas entre a população. Por sua vez a frequência de migração corresponde ao intervalo em que a migração ocorre, ou seja, frequência em que há troca de informações entre as subpopulações. Usualmente ao aplicar uma política de migração a taxa e o intervalo devem ser decididos em conjunto e isso determinará o comportamento do algoritmo e como este irá convergir, se mais rapidamente e eficientemente ou não.

Segundo Lin *et al* (2012) trabalhos anteriores acerca destes parâmetros produziram uma diretriz geral, onde se estabeleceu que a taxa de migração afeta a diversidade, assim quanto maior a taxa de migração, menor a diversidade global. O intervalo de migração, entretanto desempenha um papel inverso, quanto maior um intervalo de migração, maior é a diversidade global.

Uma forma simples de representar um processo migratório pode ser visualizada na figura 7, nela observa-se um indivíduo sendo enviado de uma população 1 em direção a uma população dois.



**Figura 7 Exemplo de Migração**

**Fonte: Produzido pela autora**

Políticas de migrações podem ser divididas em 4 tipos segundo (Cantú-Paz,1999).

- Melhores migrantes substituem pior indivíduo: onde é selecionado um pior indivíduo de uma deme e este é substituído pelo melhor migrante de outra.
- Melhores migrantes substituem um indivíduo aleatório: onde é selecionado um indivíduo aleatório de uma deme e este e substituído pelo melhor migrante de outra.
- Migrante aleatório substitui o pior indivíduo: Onde um migrante aleatório é selecionado e enviado para substituir o pior de outra deme.

## 2.4 Otimização Multimodal

Em Dieterich e Hartker *et al* (2012) considera-se que “qualquer abordagem para a otimização global deve ser validada em um conjunto de funções referências e/ou problemas. Na área de funções referências existe uma gama de funções publicadas projetadas para estressar partes diferentes de um algoritmo de otimização global. ” Também é enfatizado que existem funções populares dentro deste contexto e dentre estas foram escolhidas *Ackley* e *Rastrigin* que de acordo com os autores “[...] possuem força de expressão analítica com um mínimo conhecido [...] e são extensíveis a dimensionalidade arbitrária permitindo investigação de escala. ” Funções com essa característica são chamadas de funções multimodais, uma função multimodal é aquela que possui vários ótimos locais que podem ser máximos ou mínimos de uma função em que não haja pontos adjacentes melhores que ele. Neste trabalho as funções utilizadas foram de minimização.

Além de *Ackley* e *Rastrigin* selecionou-se também as funções *Rosenbrock et al* (1960) e *Griewank* apresentadas em *Griewank et al* (1981). As quatro funções citadas foram selecionadas para testar a otimização multimodal propiciada pelo algoritmo apresentado neste trabalho, sobretudo quanto a sua capacidade de encontrar seus ótimos globais, influenciados por diversas políticas de migração implementadas que serão testadas individualmente e comparadas a partir de seu desempenho.

### 2.4.1 Ackley


A função Ackley é considerada uma função trivial devido a sua constituição em um único funil, porém de importância para aplicações do mundo real, possui um mínimo global = 0.0.

Dieterich e Hartker *et al* (2012) citam o exemplo a hipersuperfície de energia livre das proteínas que pode ser considerada como tendo forma semelhante, porém menos simétrica.

A função é a seguinte:

$$F(x) = -20 \exp\left(-0.2\sqrt{0.5(x_1^2 + x_2^2)}\right) - \exp(0.5(\cos(2\pi x_1) + \cos(2\pi x_2))) + e + 20$$

E pode ser representado pela figura 8.



**Figura 8 Função Ackley**

**Fonte: Produzido pela autora**


## 2.4.2 Rosenbrock

A função de Rosenbrock (1960) foi proposta como uma forma de projetar processos químicos de forma a obter resultados mais econômicos, ou seja, produtos com um custo final mais barato. Para tal a forma escolhida foi variar os parâmetros disponíveis para que o custo fosse mínimo. Limitando as possíveis soluções para uma região, chamada de “ espaço de parâmetro” e a melhor solução quase sempre se encontra nessa região.

Uma das formas da função é dada pela equação:

$$f(x) = \sum_{i=1}^{m-1} (100(x_i + 1 - x^2)^2 + (1 - x_i)^2)$$

E pode ser representada pelo gráfico da figura 9:



**Figura 9 Função Rosenbrock**

**Fonte: Produzido pela autora**

A solução ótima para uma função Rosenbrock é  $f(1,1) = 0$

### 2.4.3 Griewank

A função de Griewank (1981) foi proposta para introduzir um método de minimização global não restringida de uma função objetivo diferenciável. Considera-se este um problema de minimização local, onde há vários mínimos de a partir de um ponto inicial e a função busca o mínimo possível, desprezando os mínimos maiores. A solução ótima para uma função Griewank é  $f(0) = 0$ .


A função visa localizar mínimos comparativamente baixos de um objeto função  $f$  com uma multiplicidade de mínimos locais considerando a busca de trajetórias definidas por uma equação [...]. Esse objetivo pode ser obtido se a sensibilidade é aproximadamente recíproca a média da ordem de crescimento (nos vizinhos de seus mínimos locais.). Verificou-se que as trajetórias

podem ignorar mínimos aceitáveis se for muito pequeno ou muito grande respectivamente [...]. (Griewank,1981)

A função pode ser representada pela equação:

$$f(x) = 1 + \frac{1}{4000} \sum_{i=1}^m x_i^2 - \prod_{i=1}^m \cos\left(\frac{x_i}{\sqrt{i}}\right)$$

E pode ser representada pela figura 10:



**Figura 10 Função Griewank**

Fonte: <https://www.sfu.ca/~ssurjano/griewank.png>

#### 2.4.4 Rastringin

De acordo com Dieterich e Hartker *et al* (2012) a função Rastringin possui menos mínimos dentro de um espaço de pesquisa e são definidos no seguinte intervalo:

$$-5.12 \leq x_i \leq 5.12$$


Em seu trabalho, a função em questão foi definida pelo que nomearam de potencial harmônico adicional fora do espaço de busca que forçariam a solução a permanecer dentro desse limite acima ao usar etapas de otimização irrestrita. Após análise os autores concluíram que a escala não se desvia muito entre diferentes algoritmos, sugerem que a não intrusão de mecanismos de mutação é o melhor pois fornece uma melhor exploração a curto alcance do que

qualquer outro algoritmo. De maneira geral concluem que da mesma forma que o Ackley essa função pode ser resolvida com escala quase linear fazendo uso de algoritmos atuais.

A função pode ser representada pela seguinte equação:

$$f(x_0 \dots x_n) = 10 \cdot n + \sum_{i=0}^n \begin{cases} x_i > 5.12 \vee x_i < -5.12: & 10 \cdot x_i^2 \\ -5.12 \leq x_i \leq 5.12: & x_i^2 - 10 \cdot \cos(2\pi x_i) \end{cases}$$

E pode ser representada pela figura 12:



**Figura 11 Função Rastrigin**

**Fonte: Produzido pela autor**

A solução ótima para uma função Rastrigin é  $f(0) = 0$

### 3 ALGORITMO GENÉTICO PARALELO APLICADO A OTIMIZAÇÃO MULTIMODAL

O algoritmo paralelo neste trabalho, faz uso de *multithreading* para estabelecer esse paralelismo . As funções configuradas para serem resolvidas por esse algoritmo são todas de minimização, assim sendo há um valor estabelecido que pode ser comparado com os resultados da execução do algoritmo. As políticas de migração implementadas são representadas genericamente pelo termo operadores de migração que representa todo o conjunto de políticas existentes que são, todavia, executadas individualmente.

---

```
Algoritmo multipopulacional - Multithreading
```

---

```
1  Entrada: func, sp, cruz, mut, ss
2
3  Início
4  // inicializa cada população
5  // executa o algoritmo com os parâmetros de entrada
6      para cada  $p \in P$  faça
7          inicialize ( $p_i$ );
8           $t[i] := \text{Thread}(p_i, func, sp, cruz, mut, ss).start()$ ;
9      fim
10 // inicializa operador de migração
11  $\text{Thread}(mig).start()$ ;
12 // Aguarda todas as populações convergirem
13 para cada  $i \in |P|$  faça
14      $t[i].Join()$ ;
15 fim
16 // calcula métricas estatísticas
17 ...
18 fim
```

---

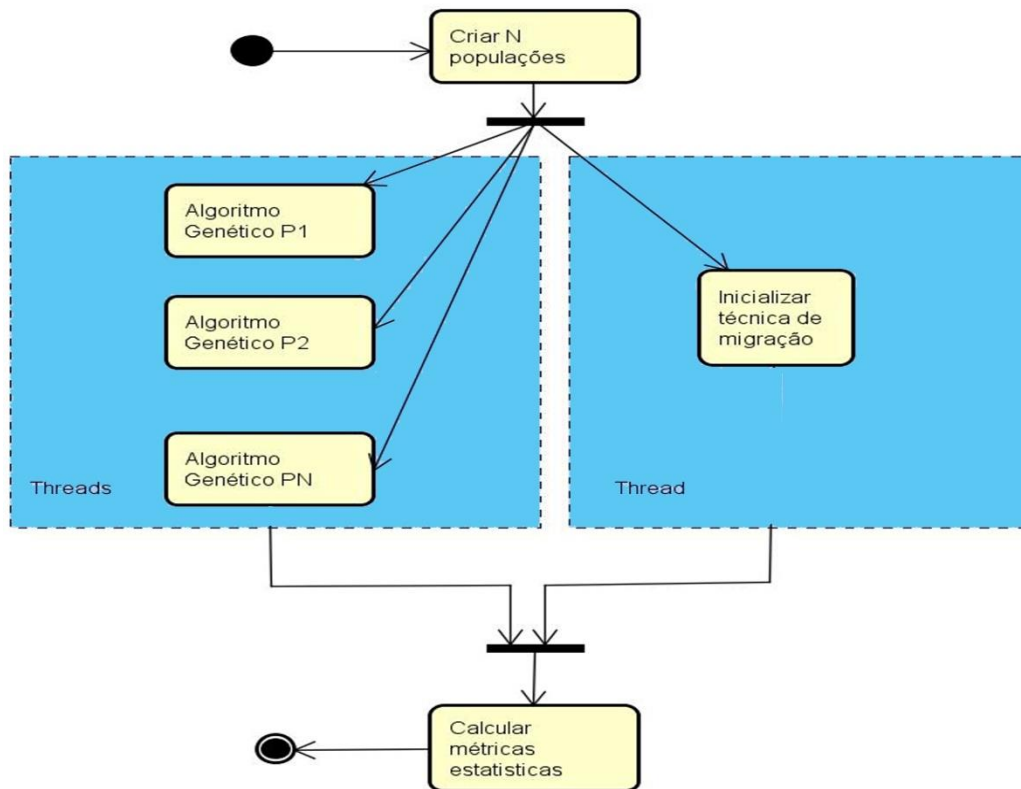
Figura 12 Algoritmo multipopulacional – Multithreading

Fonte: Produzido pela autora

O pseudocódigo na figura 13, ilustra a ordem em que os threads são inicializados. Após a população ser inicializada (linha 7) essa população é passada como argumento para o AG, juntamente com as interfaces *func* - corresponde a função a ser otimizada, *sp* - corresponde a seleção de pais, *cruz* - corresponde ao operador de cruzamento, *mut* - corresponde ao operador de mutação e *ss* - correspondendo a seleção de sobreviventes; cada instância do algoritmo é encapsulada com thread (linha 8) e armazenada em um vetor de threads chamado de *t*. Em seguida o operador de migração selecionado para a execução é iniciado também com uma thread (linha 11). A estrutura do *para* (linhas 13-15) é utilizada para verificar a thread principal da aplicação, sobretudo por que as populações convergem de forma assíncrona, sendo necessário assim que a thread principal saiba o momento em que os cálculos estatísticos possam ser realizados, assim sendo a thread principal precisa sincronizar sua execução com a das demais threads. A partir de então (linha 17) os cálculos pertinentes as métricas estatísticas podem ser realizados e avaliados tais como média das soluções, desvio, quais políticas de migração obtiveram melhores soluções e sobre quais funções e assim por diante.

### **3.1 Fluxograma da metaheurística genética paralela assíncrona**

O fluxograma da figura 14 demonstra o funcionamento do AGPM, nesse algoritmo N populações são criadas paralelamente de forma assíncrona e funcionam por meio de conjuntos de AGs independentes, representados por P1, P2... Pn, onde cada uma destas *threads* passa pelos processos evolutivos independentemente, as técnicas de migração são iniciadas em outra *thread* paralelamente a essas populações e podem interferir nas populações P a fim de realizar a migração de indivíduos dentre elas. Como cada AG atua independente do outro, desenvolvendo-se assincronamente, e as *thread* que atua na realização da migração, através da satisfação de uma distribuição uniforme pode ou não intervir nesses AGs, uma variável de controle booleano foi estabelecida para lidar com o assincronismo.



**Figura 13 Fluxograma da metaheurística genérica paralela assíncrona**

**Fonte: Produzido pela autora**

Esses critérios de controle foram definidos a fim de impedir que populações que já convergiram sejam modificadas, uma vez que essa convergência ocorre de forma assíncrona em relação as outras populações e operadores, bem como as políticas de migração. Há também uma variável de controle que atua em cada cromossomo de cada população, impedindo que um indivíduo que já convergiu possa ser modificado. Para exemplificar, se um cromossomo estiver em processo de seleção de sobreviventes e for assinalado que o mesmo deve sobreviver, o controle não pode permitir nenhuma interação naquele cromossomo neste dado instante para não comprometer a evolução natural. De modo geral, essas variáveis de controle são configuradas para “1”, enquanto estiver disponível a realização de operações, quando uma operação estiver ocorrendo é configurada para “0”, tornando a ser “1” ao fim de todas as operações pertinentes. Após todas as gerações estabelecidas ocorrerem, o algoritmo se encerra e pode-se avaliar os resultados das populações e assim extrair dados estatísticos que ilustrem o funcionamento do experimento.

### 3.2 Diagrama de Classe

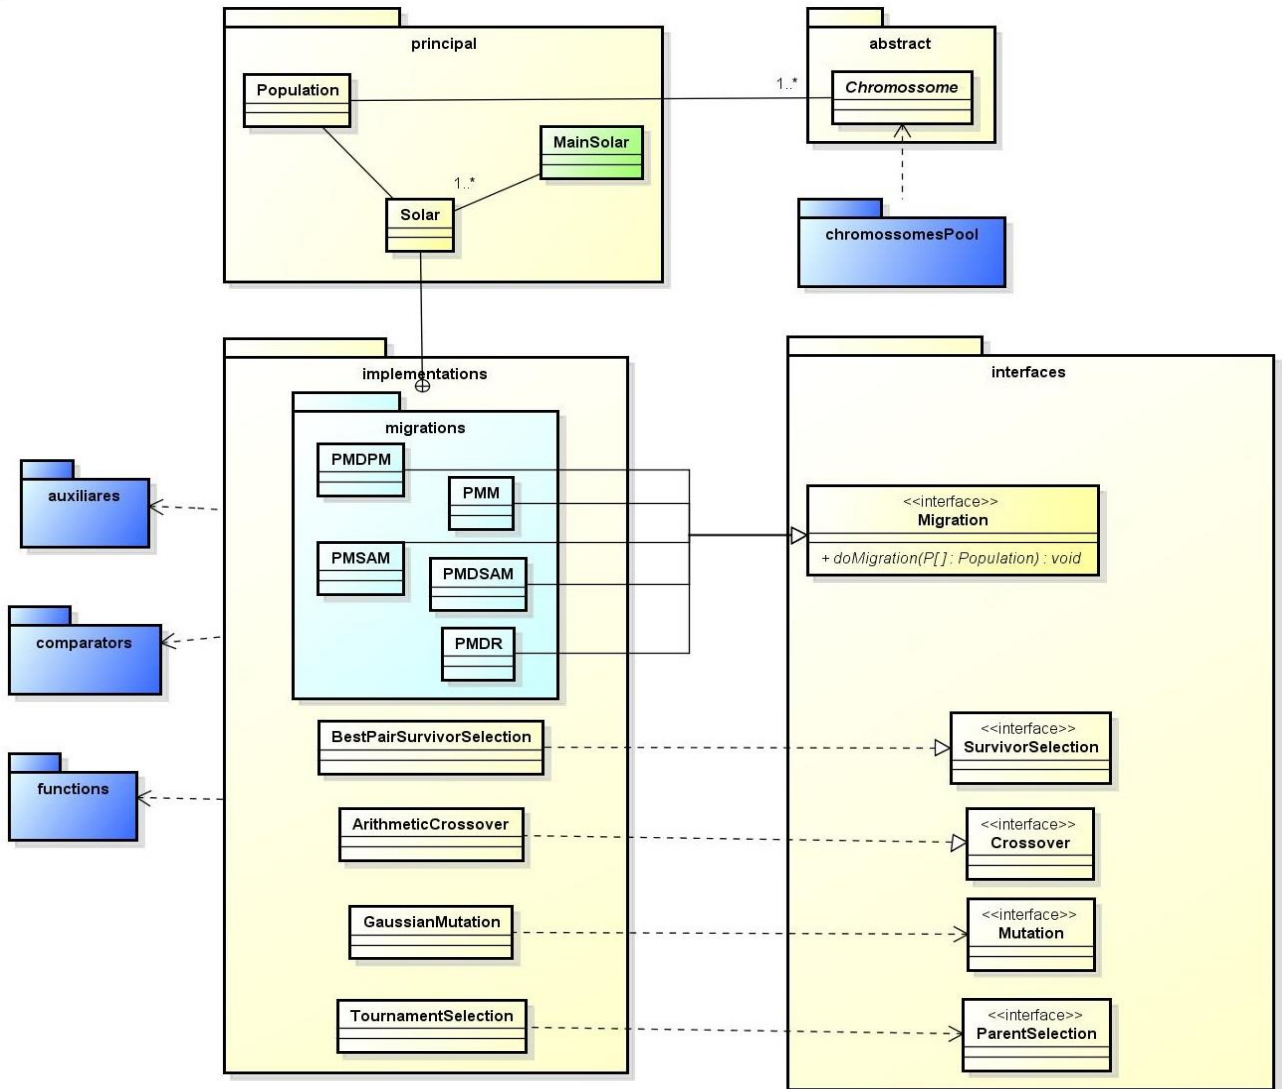


Figura 14 Diagrama de classes

Fonte: Produzido pela autora

A figura 14 representa o diagrama de classes que ilustra a organização do AGPM implementado, o pacote *migrations* contido no pacote *implementations* ilustra as políticas de

migração desenvolvidas para este trabalho e sua relação com a interface e com o pacote principal. Nota-se também os pacotes de seleção de pais, o tipo de cruzamento escolhido, a mutação e a seleção por meio de torneio.

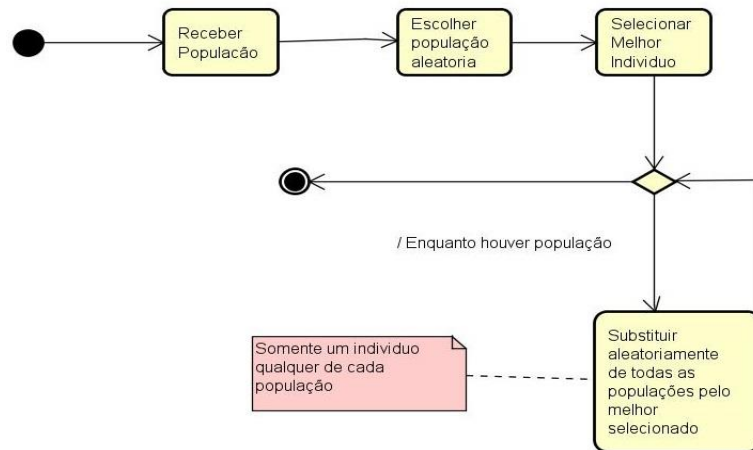
### **3.3 Políticas de Migração**

As políticas de migração podem ser entendidas como a forma que irá determinar como a migração deve ocorrer, de maneira geral podem existir diversas formas de realizar um processo migratório e este dependerá dos objetivos do trabalho em questão. Neste trabalho as políticas foram desenvolvidas de forma experimental a fim de averiguar quais poderiam ser mais eficazes na resolução do problema e construídas através de conceitos já existentes na literatura, além de respeitar aspectos como uma taxa baixa de migração, afim de não causar convergência prematura.

A migração no algoritmo apresentado possui uma probabilidade de ocorrência associada e executa somente se um número aleatório gerado por uma distribuição uniforme satisfaz a probabilidade de ocorrência, isto porque a migração é assíncrona e não ocorre de modo preestabelecido previamente, sendo necessária essa variável estatística para efetivamente executar a migração. Para que não ocorra perda de informações por conta de troca exagerada esse valor foi configurado respeitando a ordem de  $10^{-3}$ .

#### **3.3.1 Política de migração do melhor (PMM)**

Política adaptada daquela apresentada por Pettey (1987), onde uma população aleatória é selecionada e envia seu melhor indivíduo para todas as demais populações. Foi selecionada por ser uma política passível de manipulação em AG assíncronos e possuir parâmetros compatíveis com os apresentados no algoritmo do trabalho, conforme o mostrado na figura 15.




**Figura 15 Política de Migração do Melhor**

**Fonte: Produzido pela autora**

### 3.3.2 Política de migração dupla randômica (PMDR)

Política apresentada neste trabalho, onde dois indivíduos de populações diferentes aleatórias, selecionados também aleatoriamente trocam de lugar um com o outro, conforme o mostrado na Figura 16.



**Figura 16 Política de migração dupla randômica**

**Fonte: Produzido pela autora**

### 3.3.3 Política de migração simples de substituição aleatória pelo melhor (PMSAM)

Política derivada da primeira, apresentada por Pettey, neste caso é enviado o melhor indivíduo de uma população p1 para uma e apenas uma população aleatória, conforme o mostrado na Figura 17.

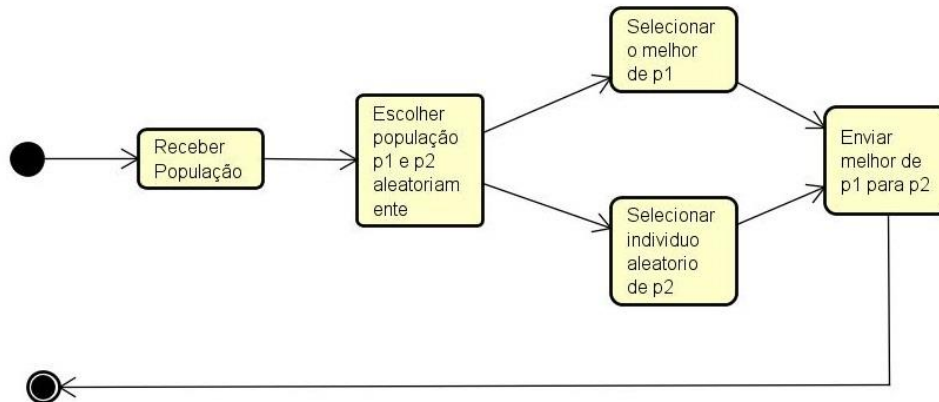
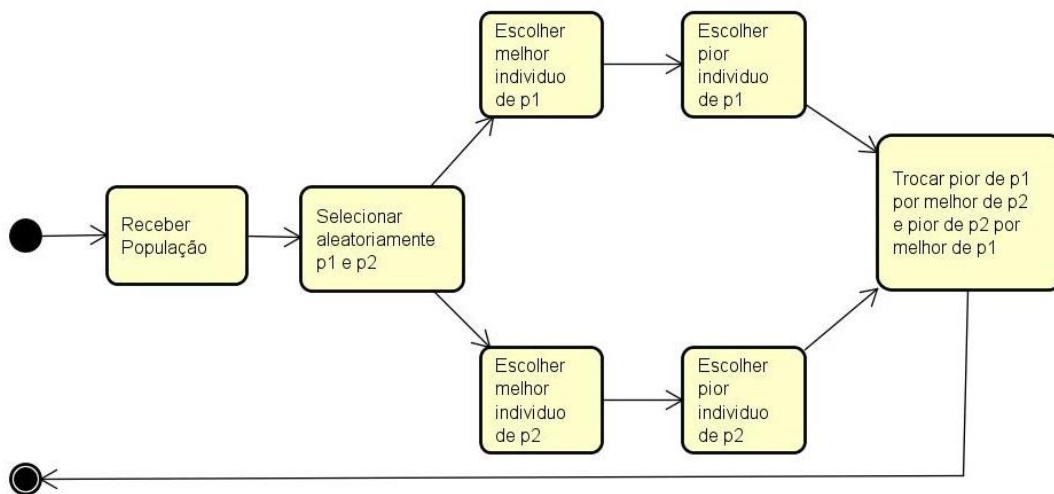


Figura 17 Política de migração simples de substituição aleatória pelo melhor

Fonte: Produzido pela autora

### 3.3.4 Política de migração dupla de substituição dos piores pelos melhores (PMDPM)

Política adaptada a partir da migração dupla e da apresentada por Tanese (1987), neste caso são selecionadas duas populações p1 e p2 de maneira aleatória e o melhor indivíduo da população p1 é enviado para ocupar o lugar do pior de p2, assim como o melhor da população p2 é enviado para ocupar o lugar do pior de p1, conforme o mostrado na Figura 18. Pode-se observar que esta tecnica possui mais uma operação, que seria selecionar o pior dos individuos, sendo necessário portanto, consultar o fitness de todos.

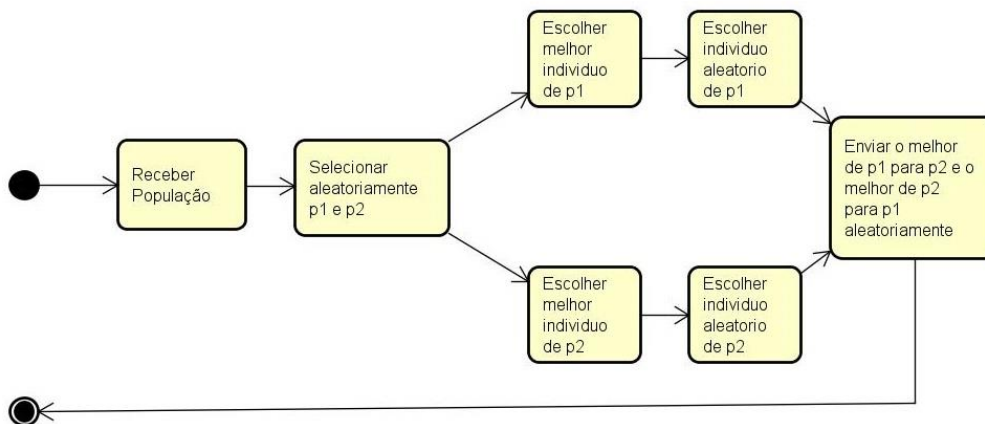


**Figura 18 Política de migração dupla de substituição dos piores pelos melhores**

Fonte: Produzido pela autora

### 3.3.5 Política de migração dupla substituição aleatória dos melhores (PMDSAM)

Neste caso são selecionadas duas populações  $p_1$  e  $p_2$  de maneira aleatória e o melhor indivíduo da  $p_1$  é enviado aleatoriamente para  $p_2$  assim como o melhor de  $p_2$  é enviado aleatoriamente para  $p_1$ , conforme o mostrado na Figura 19.



**Figura 19 Política de migração dupla substituição aleatória dos melhores**

Fonte: Produzido pela autora

## 4 RESULTADOS

O Algoritmo genético paralelo Multi-populacional (AGPM) foi escrito em JAVA, utilizando o Eclipse Neon 2. E os testes foram realizados em hardware cujas configurações seguem:

Especificações de Hardware:

- Sistema Operacional Windows 10
- Computador Intel I3- 5005U CPU @ 2.200GHz 64bits
- Memória RAM: 8,00 GB

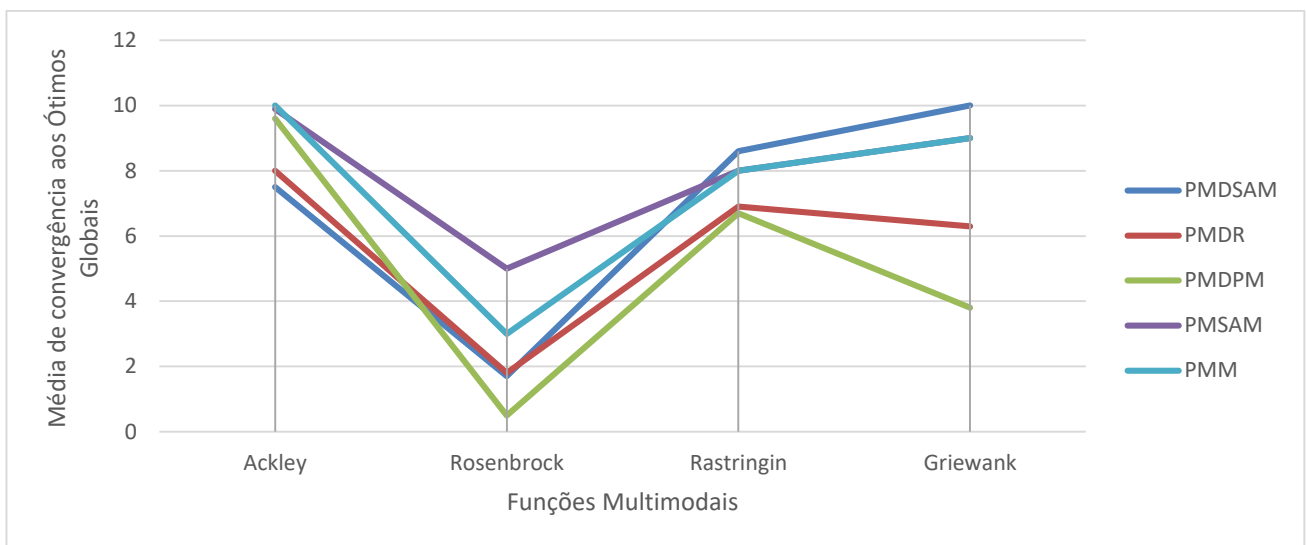
O paralelismo foi estabelecido por meio de threads assíncronas e o seu funcionamento foi configurado a partir do descrito abaixo:

- Gerações = 500;
- Populações = 10;
- Probabilidade de cruzamento = 0,8.
- Probabilidade de mutação = 0,01.
- Probabilidade de migração = 0,003.
- Seleção de pais e sobreviventes = Torneio.
- Tipo de Mutação: Gaussiana.
- Topologia = grafo fortemente conexo.

A geração foi definida em 500 de forma que se pudesse observar o comportamento das políticas de migração aplicadas ao AGPM em um número significativo de gerações que permitisse ilustrar o provável comportamento para gerações ainda maiores. A população foi definida para 10 de forma a seguir o expresso em Grosso (1985) onde o autor constata que AGPM converge mais rapidamente em *demes* ou ilhas, melhor do que em *panmictic*, assim

traços favoráveis se espalhariam mais rapidamente em ilhas menores do que nas que são maiores. A probabilidade de migração foi configurada para um número na ordem de  $10^{-3}$  de forma que não ocorra com muita frequência e nem deixe de ocorrer, conforme estabelecido na secção de políticas de migração, e estas só ocorrerão se um número aleatório originado de uma distribuição uniforme satisfizer a probabilidade de migração.

As funções multimodais Ackley, Rosenbrock, Rastrigin e Griewank foram então submetidas as cinco políticas de migração e seus resultados acerca da média de convergência aos ótimos globais pode ser observado na figura 20.



**Figura 20** Gráfico de média de convergência aos Ótimos Globais

**Fonte: Produzido pela autora**


A figura 20 representa a média de convergência aos ótimos globais obtidos na execução das cinco políticas de migração aplicada as quatro funções. Esta aponta para a quantidade de ótimos obtidos para as funções de acordo com as políticas de migrações expressas em cores.

Devido à natureza estocástica do AG, foram executados dez testes para cada política de migração, seguindo as configurações especificadas acima sobre gerações e frequências, e cada vez que uma população convergia para o ótimo global ou extremamente próximo ao ótimo global que foi estipulado para valores abaixo de 0.01 para resultados sub-ótimos, o valor de convergência era contado como “1”. Assim o quociente entre o número de vezes que uma população alcançou o ótimo global sobre todas as populações foi extraído e utilizado para

compor o gráfico, enfatizando dessa maneira, quais políticas tiveram uma média melhor de funcionamento e para quais funções. Segue a equação que representa a operação.

$$\text{Média de convergência dos ótimos globais} = \frac{\text{número de ótimos}}{\text{total da população}}$$

A análise das curvas intuitivamente aponta para uma convergência melhor sobretudo de Ackley, que foi consistente em todas as políticas alcançando o ótimo global entre 7 e 10 populações dentre as 10 populações configuradas para evoluir, o que significa que a cada teste rodado, de 7 a 10 populações convergiam para o ótimo global em média, alcançando assim uma média geral expressiva ao final de todas as execuções. O oposto pode-se dizer de Rosenbrock para a maioria das políticas, embora tenha se desempenhado razoável em conjunto com a política PMSAM, alcançando uma média próxima a 5 ótimos, demonstrou um desempenho ruim em relação a PMDM nos testes, revelando uma média de 1 ótimo após todas as execuções. Importante enfatizar que embora algumas políticas apresentem um desempenho inferior a outras, a média de convergência para ótimos demonstra que o algoritmo e as políticas funcionam, pois obtiveram resultados ótimos na realização dos testes pelo menos uma vez, satisfazendo assim a resolução do problema da melhor maneira possível.



**Figura 21 Média de ocorrência de migrações**

**Fonte: Produzido pela autora**

Conforme o explicitado anteriormente, a migração ocorre de acordo com um parâmetro estatístico e não fixo, diferente do que se pode observar em trabalhos anteriores da literatura,

como Grosso (1985), Pettey( 1987) e Tanese (1987), por exemplo; portanto tornou-se necessário averiguar a quantidade de migrações que ocorreram durante o processo de evolução das populações até sua completa convergência; dessa maneira, ao longo dos testes a quantidade de migração foi contabilizada e desta maneira, uma média foi extraída para cada uma das políticas conforme expresso na Figura 22. Observa-se uma quantidade significativa de migrações ao longo das 500 gerações. Nota-se também que o número de migrações tende a ser maior em relação a função Ackley para basicamente todas as políticas implementadas, embora no caso da PMM esta ser relativamente menor em relação as demais, todavia esse fato não parece ter afetado sua convergência para ótimos em relação a função Ackley, o mesmo não pode ser observado para Rosenbrock, função sobre a qual ocorreram menos migrações bem como uma menor média de convergência para ótimos globais.

Realizando uma comparação entre as Figura 20 e 21 pode-se intuir em uma análise preliminar indícios de uma relação entre a convergência e a migração, cujas curvas parecem estar associadas, ou seja, as funções em que ocorreram migrações frequentes tenderam a ter uma média global melhor, exceto para Griewank que apesar de ter sofrido uma média menor de migrações que variam entre um valor acima de 1000 para PMDPM até 2500 para PMDSAM, ainda obteve uma média de ótimos globais relativamente boa conforme figura 21, entre 4 e 10 ótimos.

Para efeitos de comparação pode se dividir as políticas de migração em dois grupos, políticas que foram implementadas para o trabalho, são elas:

- PMDSAM: representada pela linha azul escuro na Figura 21
- PMDR: representada pela linha vermelha na Figura 21
- PMSAM: representada pela linha amarela na Figura 21

Políticas que estão presentes na literatura e são utilizadas em diversos trabalhos, são elas:

- PMDPM: representada pela linha verde no gráfico na Figura 21
- PMM: representada pela linha azul claro no gráfico na Figura 21

Essa subdivisão permite realizar uma comparação objetiva dentre as técnicas desenvolvidas.

O PMDSAM obteve bons desempenhos, alcançando uma média boa de convergência para ótimos globais para a função Griewank, empatando em primeiro com PMM para a função Ackley; o PMDSAM obteve também o terceiro maior desempenho em obter uma média de

convergência para ótimos globais sobre a função Rastringin, sugerindo que realizar migrações por um indivíduo de uma população que não seja necessariamente o pior, não prejudica o desempenho da mesma e pode trazer boa variabilidade para as populações alteradas, embora uma substituição por um indivíduo aleatório sempre possa eliminar um indivíduo de bom fitness.



A política PMDR, embora realize uma migração dupla entre dois indivíduos aleatórios de duas populações, comportou-se relativamente bem, obtendo uma média de convergência para ótimos globais entre 2 e 8, enquanto PMSAM obteve resultados entre 1 e 10 em média, um intervalo relativamente grande. Pode-se observar, em relação as políticas com mecanismos aleatórios que seu desempenho foi bom, tendo PMDSAM nestes testes, inclusive equivalido a PMM na obtenção de ótimos globais para uma função, e esta é uma política utilizada a bastante tempo.

As políticas presentes na literatura que foram selecionadas para este trabalho, e adaptadas para eles foram nomeadas de PMDPM e PMM, sendo que a primeira obteve uma das piores médias de convergência de ótimo global para Rosenbrock, conforme a figura 21 e curiosamente foi a que menos sofreu migração conforme ilustra a Figura 21. Já PMM desempenhou-se bem para a maioria das funções, exceção a Rosenbrock, função que sofreu menos migrações conforme a figura 22 e obteve as menores médias de convergência global para todas as políticas. Importante enfatizar que, embora se tratem das mesmas políticas da literatura, seu comportamento varia neste trabalho, por conta da característica assíncrona; desta maneira Pettey (1987) por exemplo, cuja migração deveria ocorrer em toda geração, ocorrerá agora a partir da determinação estatística estipulada, assim como as demais, uniformizando dessa maneira o comportamento de todas as políticas para se adequar ao estudo.

De modo geral, pode-se observar que as políticas sugeridas no trabalho a partir das existentes, tais como PMDR, PMSAM e PMDSAM, se comportam de maneira satisfatória, obtendo bons resultados e inclusive superando as políticas tradicionais utilizadas em diversos trabalhos anteriores tais, como as de Pettey (1987), Tanese (1987), para algumas funções. Pode-se observar também que os mecanismos aleatórios das políticas PMDSAM, PMDR e PMSAM auxiliaram no desempenho das mesmas, ênfase para PMDSAM nos testes, bem como confirmaram o bom desempenho de PMM. Nota-se também que a PMSAM foi a política que


mais impactou sobre a função Rosenbrock, cujas médias foram em geral mais baixas para todas as demais políticas, sendo uma função bastante difícil de otimizar.

Uma pertinente análise acerca do comportamento dessas políticas pode ser realizada através do fitness obtido ao longo das 500 gerações de forma a averiguar se a qualidade dos indivíduos sofreu uma melhora significativa, impactando diretamente nos resultados finais. Para tanto foram extraídos gráficos traçando o comportamento das políticas conforme a figura 21, 23, 24, 25, 26 e 27 em relação as quatro funções multimodais.




(A)

(B)



(C)




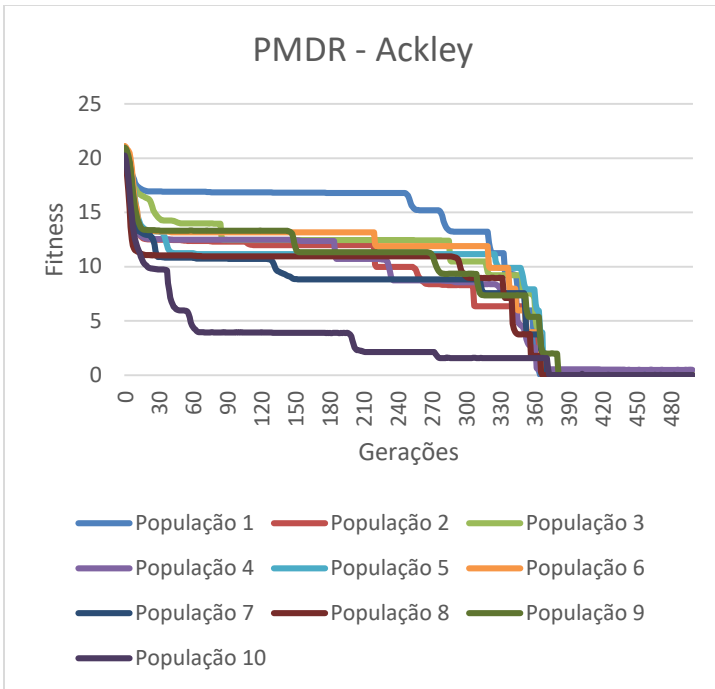
(D)

**Figura 22 Média do Fitness para PMM**

Fonte: Produzido pela autora



A Figura 22 ilustra a média dos fitness das populações submetidas a política de migração PMM ao longo de 500 gerações, nota-se para todas as funções uma melhora gradativa na média do fitness ao longo das gerações, percebe-se que em relação a função Rosenbrock, Figura 23(B), no entanto, a maioria das populações essa evolução foi um pouco lenta ao longo das gerações, o que pode indicar a necessidade de mais gerações para que ocorra uma convergência completa, já para as demais funções é possível verificar uma curva mais pronunciada, com ênfase para Ackley, figura que manteve uma contínua melhora até o fim das gerações estipuladas, sobretudo a partir da geração 360 geração e Rastrigin cuja curva foi pronunciada até a 390 geração, onde se estabilizou, com muitas das populações alcançando a estabilidade no fitness ótimo; Griewank cuja algumas populações dispararam a frente em termos de obter uma boa média de fitness, sendo que algumas desta, alcançam uma convergência próximo a metade das gerações, apresenta um comportamento mais lento que as demais em algumas gerações.

As funções Ackley e Rosenbrock em relação a política PMM, segundo a Figura 22 (A) e Figura 22(B) respectivamente, foram as que mais tiveram atuação das políticas e migração e pode-se perceber pela Figura 21 que o impacto dessa política de migração foi positivo em relação à média do fitness.



(A)

(B)




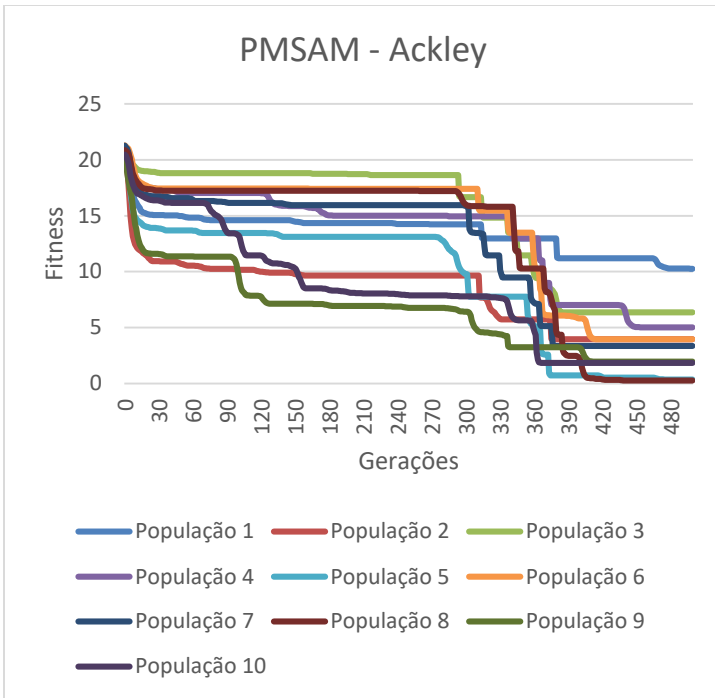
(C)

(D)

**Figura 23 Média do Fitness para PMDR**


Fonte: Produzido pela autora

A Figura 23 ilustra a média do fitness da política de migração PMDR ao longo das 500 gerações, nessa política as trocas entre indivíduos de duas populações aleatoriamente podem impactar de maneira um tanto imprevisível no fitness, todavia neste trabalho a média do fitness melhorou gradativamente para todas as funções, embora, boa parte da população em relação a Rosenbrock demonstrou uma melhora mais lento em relação às demais funções, sugerindo que possivelmente para esta função seja necessária uma maior quantidade de gerações para obter melhor convergência. Observando as curvas, nota-se que para as funções Ackley da Figura 23 (A) e Rastrigin na Figura 23(C) a média do fitness melhorou mais rapidamente e de maneira mais uniforme do que para as demais, ou seja, a maioria da população melhorou continuamente, o que parece corroborar com a Figura de 21 onde a média de migrações para esta política é maior para estas funções o que demonstra que a política PMDR melhorou o fitness; é possível observar também que para essas duas funções o PMDR obteve uma das melhores convergência para os ótimos globais conforme a figura 20.




(A)

(B)



(C)

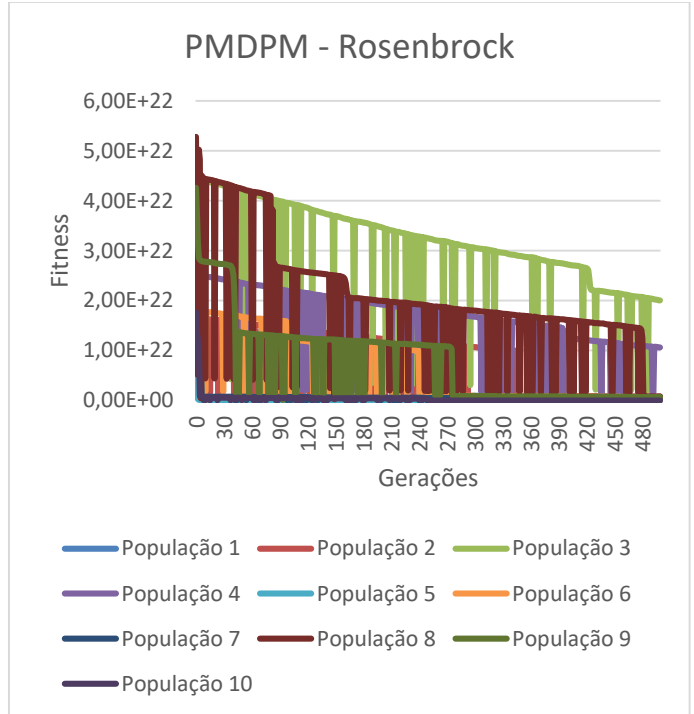



(D)

**Figura 24 Média do Fitness para PMSAM**



**Fonte: Produzido pela autora**

A Figura 24 ilustra a média do fitness da política de migração PMSAM ao longo das 500 gerações, nesta política um melhor indivíduo de uma população é enviado para outra população aleatória e neste caso a expectativa de melhora é um tanto indefinida, já que este pode tanto substituir um indivíduo com um fitness melhor que o enviado como pode acabar por substituí-lo por um indivíduo com fitness pior; no caso do PMSAM averiguado neste trabalho a média do fitness melhorou para todas as funções aplicadas. Rastrigin representada pela Figura 24(C) foi a função sobre a qual a política de migração se comportou melhor conforme mostra o gráfico, todas as populações obtiveram uma melhora expressiva no fitness; seguida pela função Ackley de Figura 24 (A) ; se comparadas a figura 21, percebe-se que são também as funções em que ocorreram a maior quantidade de migrações e segundo a figura 20 obtiveram uma boa média quanto a convergência aos ótimos globais. Para esta política, Rosenbrock, Figura 24(B) e Griewank, Figura 24(D) tiveram um desempenho um pouco inferior em relação a outras, ainda houve melhora, todavia esta foi dispare em relação as demais funções; no caso de Rosenbrock de Figura 24(B), o PMSAM foi a política que apresentou maior impacto tanto no fitness quanto na média de convergência para ótimos globais conforme pode-se observar na figura 20.



(A)

(B)





(C)

(D)

**Figura 25 Média do fitness para PMDPM**



Fonte: Produzido pela autora

A figura 26 ilustra a média do fitness da política de migração PMDPM ao longo de 500 gerações, pode-se observar que há uma melhora na média do fitness para todas as populações em todas as funções sobre a qual a política foi aplicada, nesta política os piores são substituídos pelos melhores entre duas populações selecionadas, as funções Ackley na Figura 25 (A) e Rastrigin na Figura 25 (C) demonstram uma melhora significativa em suas médias de fitness, destacando-se das outras, conforme pode-se verificar pelas curvas que representam os indivíduos, embora Griewank na Figura 25(D) tenha ficado pouco atrás neste quesito. Rosenbrock na Figura 25(C) em relação ao PMDPM comportou-se um tanto dispersamente em relação à média do fitness com algumas populações obtendo uma média inferior. Pode-se observar ao comparar com as figuras 20 e 21 que foi a política aplicada a Rosenbrock que obteve a menor média de convergência dos ótimos globais e a menor média de migrações, o que pode ter contribuído para esse comportamento. Também foi uma das políticas com os resultados menos expressivos para a maioria das funções.



(A)

(B)



(C)

(D)

**Figura 26 Média de fitness para PMDSAM**

**Fonte: Produzido pela autora**

A figura 27 ilustra a média de fitness da política de migração PMDSAM, ao longo de 500 gerações, pode-se observar que há uma melhora da média de fitness para todas as populações do fitness para todas as populações em todas as funções sobre a qual a política foi aplicada, nessa política, duas populações são selecionadas e enviam seus melhores uma para outra em substituição aleatória a outro indivíduo, tratando-se assim de uma migração dupla. A melhora em relação média de fitness é mais expressiva para a função Rastrigin na Figura 27(C), Ackley na Figura 27 (A) e Griewank na Figura 27 (D), seguida da função; para Rosenbrock de figura 27 (B) pode-se observar uma média mais dispersa, onde algumas populações ao longo das gerações crescem mais significativamente que outras, e a melhora, embora ocorra é menor. Foi a técnica que se comportou melhor na maioria das funções obtendo os melhores resultados em termos de convergência de ótimos globais.

O uso do paralelismo pode ser eficiente na redução do tempo de computação e desempenho de um algoritmo genético, possibilitando que múltiplas populações investiguem diferentes regiões do espaço de busca; quanto a migração atuando sobre esses AGPM, estas permitem que populações que por ventura viessem a convergir prematuramente troquem indivíduos e informações evitando assim essa convergência, além de inserir novos genes em uma determinada população, melhorando assim o fitness e possivelmente os resultados.

De modo geral pode-se observar que as diversas políticas de migração implementadas contribuíram para a melhora do fitness e para a quantidade de ótimos globais obtidos aplicadas as funções multimodais. Todas as políticas conseguiram encontrar em média o ótimo global, pelo menos uma vez, ao fim das execuções, assim como ocorreram vezes em que todas as populações convergiram para o ótimo global. Conforme observado na seção anterior, para efeitos de comparação as políticas haviam sido divididas em dois grupos, um que utilizava alguma forma de randomização diretamente ligada a migração e políticas que não utilizavam esse recurso, e conforme a figura 16 demonstra, duas delas PMSAM e PMDSAM obtiveram os maiores números de ótimos globais, sendo superiores inclusive ao PMDPM que substitui os melhores pelos piores, demonstrando que apesar de ocorrer seleções e substituições aleatórias ainda pode-se obter resultados positivos. A política PMDR cujos indivíduos são trocados aleatoriamente entre si, comportou-se de maneira um pouco inferior a essas políticas sem, todavia, ser a pior

dentre elas. Quanto a política PMM, adaptada da literatura, obteve ótimos resultados, reforçando-a como uma política passível de ser utilizada nos mais diversos algoritmos. Os resultados sugerem que políticas que misturem a substituição de melhores em conjunto com mecanismos aleatórios podem ter desempenho tão bom quanto as políticas predecessoras, que realizavam o envio de um melhor para substituir um pior, por exemplo.

O motivo que pode relacionar esse comportamento em relação a obtenção de ótimos e essas políticas, pode ser justamente o fator de preservação, que é maior em políticas que não retirem diretamente um “pior” indivíduo com muita frequência, pois este pode vir a ser útil em termos de variabilidade genética.

Estima-se que essas políticas possam ser utilizadas em diversos algoritmos genéticos paralelos, tais como as da literatura atualmente o são, contudo pode-se observar que seu desempenho para com as funções apresentadas não foi uniforme, tendo Rosenbrock a média do fitness e a média de convergência de ótimos globais menor que as demais, o que significa em efeitos práticos que o melhor poderia ser o teste das políticas com outras funções conhecidas de minimização que possam atestar a praticabilidade de aplicar as políticas apresentadas, bem como o aumento do número de gerações.

Dentre as funções multimodais selecionadas, a Rosenbrock demonstrou-se como a mais difícil de otimizar, tanto pelas políticas de migração da literatura quando as demais; criada originalmente para reduzir os custos de processos químicos tendo por objetivo, foi perceptível durante o teste a dificuldade em chegar ao espaço de parâmetro e por conseguinte ao seu ótimo global. As figuras 20,21,22, 23, 24, 25, 26 e 27 apresentadas durante o trabalho, sobretudo o de média do fitness que correspondem as figuras 23, 24, 25, 26 e 27 que demonstra sua melhora lenta, sugerem a necessidade de mais interações do algoritmo, o que pode significar aplicar as políticas com uma taxa maior do que a utilizada neste trabalho, ou outras modificações nos parâmetros estabelecidos.

## 5 CONSIDERAÇÕES FINAIS

Este trabalho abordou Algoritmos Genéticos Paralelos, sobretudo em relação as políticas de migração. Nota-se que dentre os Algoritmos Evolucionários, a heurística dos AGP constitui-se de uma abordagem de grande interesse prático na resolução de problemas que exigem grande custo computacional e para que ele tenha um desempenho eficaz e necessário especial atenção a sua configuração.

Enfatizou-se as políticas de migração, por tratar-se do principal mecanismo de comunicação entre as populações, trocando dados entre elas e possibilitando melhores soluções candidatas ao fim do processamento, além de manter a variabilidade genética, se configurados corretamente. Há várias políticas dentro da literatura que se provaram eficientes para a tarefa de comunicação, sem, entretanto, fechar caminho para que novas políticas possam ser desenvolvidas, aplicadas e comparadas com estas em trabalhos futuros. Ao longo do trabalho e da aplicação sobre as funções multimodais designadas para os testes das políticas, notou-se o bom desempenho tanto das políticas já existentes, como das sugeridas para a otimização das funções multimodais aplicadas. Pode-se notar que de modo geral as políticas melhoraram significativamente a média do fitness de todas as populações configuradas e obtiveram boas médias de convergência de ótimos globais para a maior parte das funções. O PMDSAM, política sugerida por esse trabalho foi uma das que se comportou de maneira mais favorável dentre as políticas apresentadas, mostrando que as migrações duplas podem alcançar bons resultados.

## 6 TRABALHOS FUTUROS

Como trabalhos futuros considera-se aplicar esse conjunto de políticas a outro conjunto de funções de modo a averiguar se o comportamento das mesmas se mantem, sobretudo as sugeridas no trabalho. A taxa de migração selecionada para o trabalho foi relativamente baixa a fim de condizer com a literatura e não provocar dessa maneira convergência prematura, todavia pode-se futuramente aumentar essa taxa gradativamente e analisar o comportamento do algoritmo. A frequência foi delimitada de maneira probabilística de modo que apenas o número aleatório originado da distribuição uniforme satisfizesse essa probabilidade pudesse influenciar na quantidade de vezes que a migração ocorre, todavia, futuramente pode-se fixar essa taxa ou mesmo torna-la adaptativa. Também é passível de um estudo, a variação na quantidade de *threads* que representam a população e o impacto no funcionamento do algoritmo, bem como estudo acerca do tempo de processamento total do AGPM. O algoritmo apresentado também possui como característica o assincronismo, assim sendo o controle é realizado por meio de condições que estabelecessem que as populações que já haviam convergido, esperem que as demais finalizassem para exibir o conjunto solução, pode-se futuramente torna-lo síncrono, de modo que se economize tempo e possibilite que outras manipulações quanto a frequência ou a taxa dessas migrações sejam mais flexíveis.

## REFERÊNCIAS

- PETTEY, C.B; LEUZE, M.R; GREFENSTETTE.: **A Parallel Genetic Algorithms** . Proc . 2nd International Conference on Genetic Algorithms, pp. 155-161, 1987.
- TANESE, R.: **Parallel Genetic Algorithm for a hypercube** . Proc. 2nd International Conference on Genetic Algorithms. Pp 434-439, 1987.
- GROSSO, P.B.: **Computer Simulation of Genetic adaptation: Parallel Subcomponent interaction in a multilocus model** . PhD Dissertation, the University of Michigan , 1985.
- COHOON, J.P; HEDGE, S.U; MARTIN. W.N; RICHARD D. S.: **Punctuated Equilibria : A parallel Genetic Algorithm**, Proc. 2 International Conference on Genetic Algorithms.pp 148-152. 1987.
- EIBEN, A. E., & SMITH, J. E. **Introduction to Evolutionary Computing - Second Edition**. 2015 Berlin: Springer.
- LINDEN, R. **Algoritmos Genéticos - Uma importante ferramenta da Inteligência Computacional 2º edição**. 2008 Rio de Janeiro: Brasport.
- LIN, Y. W ; TZUNG-PEI, H.: **Revisiting the Design of Adaptive Migration Schemes for Multipopulation Genetic Algorithms**. Conference on Technologies and Applications of Artificial Intelligence. 2012. Taiwan.
- CANTU-PAZ, E: **A Survey of Parallel Genetic Algorithms** : Calculateurs Paralleles. 1998.
- UPADHYAYULA, S; KOBTI, Z : **Population Migration Using Dominance in Multi-Population Cultural Algorithms**. 2015. IEEE 14th International Conference on Machine Learning and Applications.
- MORADY,R; DAL D.: **A Multi-Population Based Parallel Genetic Algorithm for Multiprocessor Task Sheduling with Communication Costs**. 2016. IEEE Symposium on Computers and Communication (ISCC).
- TOMASSINI , M. : **Parallel and Distributed Evolutionary Algorithms : A review**. 1999.

KALYANMOY, D.: **A Introduction to genetic Algorithms.** Sādhanã , Vol 24, Partes 4 & 5 , August & October 1999, p 293-315. India.

CORMEN, T. H; STEIN , C; RIVEST, R.L ; LEISERSON C, E.: **Introduction to Algorithms.** 2001. McGraw-Hill Higher Education , 2nd Edition

CANTU-PAZ, E; GOLDBERG , D.E.: **On the Scalability of Parallel Genetic Algorithms.** Evolutionary Computing Vol 7 , Number 4. Massachusetts, 1999.

NOWOSTAWSKI, M; POLI, R.: **Parallel Genetic Algorithm Taxonomy.** 1999. Third Internacional Conference on Knowledge - Based Intelligent Information Engineering Systems, 31st Aug- 1 st Sept 1999, Adelaide, Austrália.

DIETERICH, J.M ; HARTKE, B.: **Empirical Review of Standard Benchmark Functions Using Evolutionary Global Optimization.** 2001. CORR , abs/ 1207.4318.

ROSENBROCK, H.H .: **An automatic method for finding the greatest or least value of a function.** 1960 The Computer Jornal. 3(3) 175- 184.

GRIEWANK, A. : **Generalized descent for global optimization .** J.Otim. Theory Apply . 34: 11-39

CANTU-PAZ.: **Migration Policies, Selecion Pressure, and Parallel Evolucionary Algorithms.** Jornal of heuristic , 2001. v7 n4 p.311-334