



SIACO **Algoritmo de Colônia de Formigas com Interação Social**

Fábio dos Santos Ferreira

Grupo de Estudos Temáticos em Computação
Centro Universitário do Estado do Pará - CESUPA
Belém-PA, Brasil
ferreira06@gmail.com

Glauber Duarte Monteiro

Centro Universitário do Estado do Pará - CESUPA
Belém-PA, Brasil
glauberbcc@gmail.com

Otávio Noura Teixeira

Faculdade de Engenharia de Computação
Universidade Federal do Pará - UFPA
Tucuruí-PA, Brasil
onoura@gmail.com

RESUMO

Este trabalho foi desenvolvido para demonstrar as possibilidades de inserir Interação Social no Algoritmo de Colônia de Formigas. Os procedimentos adotados foram realizados no algoritmo Ant System desenvolvido por Marco Dorigo e a Interação Social criada por Otávio Teixeira no Algoritmo Genético. Uma nova fase de Interação Social foi inserida no Ant System, e o conflito é realizada com duas formigas da colônia. Os testes iniciais foram realizados sobre o problema do caixeiro viajante.

PALAVRAS CHAVE. Otimização, Colônia, Formigas, Interação, Social.

Tópicos: Ant System, Interação Social, Otimização Baseado em Colônia de Formigas com Interação Social (siaco)

ABSTRACT

This paper was developed to demonstrate the possibilities of input Social Interaction in the Ant Colony Algorithm. The adopted procedures were based on the Ant System algorithm developed by Marco Dorigo and the Social Interaction created by Otávio Teixeira in Genetic Algorithm. A new phase was inserted in the Ant System, and the conflict is performed with two ants from the colony. The initial tests were made with the traveling salesman problem.

KEYWORDS. Optimization, Colony, Ants, Iteraction, Social.

Paper topics: Ant System, Social Interation, Social Interaction in Ant Colony Optmization (siaco)



1. Introdução

Diversas classes de aplicação exigem poder computacional, tornando uma demanda constante à necessidade de redução do tempo de processamento. Buscar soluções para proporcionar maior desempenho e ampliar o conjunto de aplicações que podem ser resolvidos de maneira eficiente, está entre as atividades dos projetistas de soluções de otimização [Silva et al. 2005].

Minimizar custos e/ou maximizar benefícios é um tipo de problema comum às áreas de Engenharia, Economia, Administração, Computação, entre outras. Neste sentido, o campo de otimização tem um papel fundamental, pois mantém um elenco de classes de problemas, associadas a uma série de métodos de otimização capazes de resolvê-las.

A computação de alto desempenho é utilizada na programação de aplicações científicas, de multimídia, de gerenciamento de grandes volumes de dados entre outras [Silva et al. 2005]

O objetivo deste trabalho é apresentar um novo algoritmo de otimização baseado no Algoritmo de Otimização por Colônia de Formigas (ACO – *Ant Colony Optimization*) [Dirigo 1992] com a inserção de Interação Social, apresentado em [Teixeira 2005].

Os tópicos seguintes irão apresentar o referencial teórico utilizado no desenvolvimento deste trabalho, no tópico 2 será apresentado o algoritmo *Ant System*, desenvolvido por Marco Dorigo em [Dorigo 1992].

O tópico 3 irá apresentar a Interação Social, desenvolvida por [Teixeira 2005], que foi utilizado sobre o Algoritmo Genético (AG).

A Interação Social utilizada neste trabalho é realizada através da competição entre as formigas, para que esta se torne, de certa forma, mais influente do que as demais, e assim possa depositar mais feromônio em sua rota. Como poderá ser visto no tópico 4.

Por fim, serão apresentados os resultados de testes e experimentos realizados sobre o Problema do Caixeiro Viajante (TSP – *Traveling Salesman Problem*), utilizando a instancia brazil58, com 58 cidades do Brasil.

2. Ant System

As formigas são insetos sociais possuidores de um complexo sistema de organização e divisão de tarefas, tendo como função principal a garantia da sobrevivência do formigueiro.

A meta-heurística de Otimização por Colônia de Formigas (*ACO – Ant Colony Optimization*) foi inspirada na observação das colônias de formigas reais, particularmente no modo como elas encontram o menor caminho entre a fonte de alimentos e o formigueiro [Silva 2002].

A colônia de formigas, para obter alimentos, resolve um problema de otimização em sua forma mais básica, ela tenta encontrar a menor rota para chegar em sua fonte de alimento, partindo de seu formigueiro [Silva 2003]. Inicialmente as formigas percorrem, de forma aleatória as proximidades do formigueiro. Caso alguma delas encontre alimento nas proximidades, esta então retorna a sua origem, o formigueiro, excretando a substância crucial para a comunicação entre elas, o feromônio.

As próximas formigas então, irão perceber a quantidade de feromônio presente no ambiente e irão escolher se seguem por esta rota ou tentam procurar por outra, seguido uma regra de decisão probabilística. Quanto maior a quantidade de feromônio em uma rota, maior a probabilidade de uma formiga seguir por este caminho.

Isto ocorre devido a quantidade de feromônio depositada pelas formigas, que aumenta cada vez que uma nova formiga escolhe aquele caminho. Com isso a probabilidade de selecionar o caminho de menor distância aumenta, à medida que a diferença de tamanho entre os caminhos torna-se maior. Sendo, inicialmente, a probabilidade de escolha a mesma para ambos, pois não existe feromônio no caminho.



Caminhos menores demandarão menos tempo para depositar feromônio, com isso terão mais feromônio do que os demais. A próxima formiga que tentar encontrar a fonte de alimentação irá perceber o feromônio no ambiente e fará a sua escolha.

2.1. Algoritmo Ant System

O algoritmo *Ant System* desenvolvida por [Dorigo 1992], foi proposta como uma abordagem multi-agente para problemas de otimização combinatoriais difíceis, como o Problema do Caixeiro Viajante (TSP – *Traveling Salesman Problem*).

A meta-heurística foi aplicada pela primeira vez sobre o problema TSP, por isto este algoritmo está intimamente ligado ao problema de encontrar o menor caminho entre um conjunto de cidades. Mas este mesmo algoritmo pode ser aplicado a uma série de problemas de otimização, desde que estes possam ser formulados como um problema de encontrar um ciclo hamiltoniano.

O algoritmo *Ant System*, baseado em [Dorigo 1992] é apresentado a seguir:

Tabela 1. Algoritmo *Ant System*, desenvolvido por [Dorigo 1992]

Algoritmo <i>Ant System</i>	
1	para t indo de 1 até um número máximo de iterações faça
2	para k indo de 1 até m faça
3	repita até a formiga k encontrar um caminho completo
4	selecione a próxima cidade a ser visitada segundo a regra de decisão probabilística $p_{ij}^k(t)$;
5	fim-do-repita
6	calcule a distância $L_k(t)$ do caminho descoberto pela formiga k ;
7	se $L_k(t) < L^*$ então $S^* \leftarrow S_k(t)$
8	fim-do-para
9	atualize $\tau_{ij}(t+1)$, $\forall (i, j) \in E$, segundo processo de depósito e evaporação de feromônio específico;
10	fim-do-para
11	retornar S^* ;

Fonte [Dorigo 1992]

Logo ao iniciar a execução do algoritmo, as m formigas da população inicial são distribuídas pelas cidades, segundo algum critério, e todos os caminhos $(i, j) \in E$ são inicializados com a mesma quantidade de feromônio, $\tau_{ij}(t) > 0$.

Em seguida, cada formiga deve selecionar as próximas cidades a serem visitadas, através da regra de decisão probabilística a seguir:

$$p_{ij}^k(t) = \left\{ \frac{[\tau_{ij}]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_{l \in N_i^k} l [\tau_{ij}]^\alpha \cdot [\eta_{ij}]^\beta} \right\} \quad (1)$$

Onde:

- $p_{ij}^k(t)$: probabilidade de a cidade j ser escolhida pela formiga k , na iteração atual t ;
- $\tau_{ij}(t)$: intensidade de feromônio presente no caminho $(i, j) \in E$, na iteração atual;
- α : parâmetro que regula a influência de $\tau_{ij}(t)$ na escolha da cidade j ;
- $\eta_{ij} = 1/d_{ij}$: visibilidade da cidade j , estando na cidade i ;
- d_{ij} : distância entre a cidade i e j ;
- β : parâmetro que regula a influência de η_{ij} ;
- $N_i^k(t)$: vizinhança da cidade i ainda não visitadas pela formiga k , na iteração atual;



Esta equação é utilizada no processo de seleção das cidades que serão visitadas. Juntamente com a equação de probabilidade, deve ser utilizado algum processo de seleção, que, favoreça as cidades com maior probabilidade de serem escolhidos, mas que não exclua as cidades com probabilidade menor.

Neste trabalho foi utilizado o método de seleção probabilístico Roleta, onde, as cidades a candidatas possuirão uma fatia desta, mas o tamanho desta fatia se dá de acordo com a probabilidade de escolher a cidade. Ou seja, quanto maior a probabilidade de escolha de uma cidade, maior a fatia desta, e maior a probabilidade desta ser selecionada e visitada.

Este processo de seleção é repetido até que a formiga complete um caminho interligando todas as cidades, sem repetições. E até que todas as formigas tenham completado o seu caminho.

Em seguida há o processo de depósito e evaporação de feromônio, este ocorre da seguinte maneira:

$$\tau_{ij}(t+1) = (1-\rho) \times \tau_{ij}(t) + \Delta \tau_{ij}(t) \quad (2)$$

Sendo:

$$\Delta \tau_{ij}(t) = \sum_{k=1}^m \Delta \tau_{ij}^k(t) \quad (3)$$

Com:

$$\Delta \tau_{ij}^k(t) = \frac{Q^k(t)}{L_k(t)} \quad (4)$$

e a formiga k percorreu o caminho $(i, j) \in E$; caso contrário:

$$\Delta \tau_{ij}^k(t) = 0 \quad (5)$$

Onde:

- $\rho \in [1,0]$: parâmetro que regula a redução de $\tau_{ij}(t) \in E$;
- m : número de formigas;
- $\Delta \tau_{ij}^k(t)$: ganho de feromônio no caminho $(i, j) \in E$, causado pela formiga k ;
- $Q^k(t)$: quantidade de feromônio excretado por uma formiga na iteração atual;
- $S_k(t)$: caminho completo que interliga todas as cidades uma única vez, descoberto pela formiga k ;
- $L_k(t)$: distância associada ao caminho completo $S_k(t)$ descoberto pela formiga k ;

A cada iteração da heurística, o procedimento depósito e evaporação é realizado. E ao final, quando o critério de parada for atingido, no caso o número máximo de iterações é alcançado, a heurística retorna a melhor solução encontrada. Segundo [Dorigo et al. 1999] “... o feromônio acrescentado pelas formigas é uma memória compartilhada de longo período que influencia a decisão das formigas...”.

No tópico a seguir é apresentado o método de Interação Social, apresentado por [Teixeira 2005].

3. Interação Social

Interação Social foi pela primeira vez desenvolvido por [Teixeira 2005], onde neste trabalho aplicou os seus fundamentos no Algoritmo Genético, com o intuito de simular a luta pela sobrevivência que ocorre na natureza [Darwin 1859].

Antes de analisarmos a Interação Social, propriamente dita, devemos considerar uma introdução sobre a Teoria dos Jogos.



3.1. Fundamentos da Teoria dos Jogos

Em seu trabalho, Teixeira utilizou a Teoria dos Jogos [Teixeira 2005], desenvolvida por Jon Von Neumann [von Neumann e Morgenstrern 1944], para simular a situação de disputa entre os indivíduos, onde segundo o mesmo, a Teoria dos Jogos:

“... lida com situações de conflitos de interesse, onde dois ou mais agentes racionais disputam entre si algum recurso limitado ou escasso presente no ambiente” [Rapoport 1999].

Neste momento um indivíduo, normalmente se defronta com uma situação que possui cursos alternativos de ação. E, segundo [Teixeira et al. 2011], cada um dos cursos leva a uma consequência ou a uma entre as diversas possíveis.

Os agentes racionais, segundo [von Neumann e Morgenstrern 1944], são agentes que consideram as consequências de seus atos, e estabelecem uma preferência, baseado nestes e nos seus resultados anteriores, maximizando seus ganhos. E em alguns casos este resultado pode depender de ações de outros indivíduos racionais, sobre os quais o primeiro não tem qualquer controle.

Este resultado é uma consequência dos atos dos indivíduos, somados ao “estado do mundo”. As decisões a serem tomadas por cada um podem ser classificadas, de acordo com as suas preferências, em ordem crescente da melhor para a pior, por exemplo [von Neumann e Morgenstrern 1944].

Somando-se ponderadamente todos os ganhos possíveis correspondentes a uma decisão em particular, onde os pesos são as probabilidades de cada uma das ocorrências, tem-se o “ganho esperado” ou “expectativa de ganho” [von Neumann e Morgenstrern 1944].

No tópico a seguir é apresentado o Dilema do Prisioneiro, considerado o mais famoso e conhecido jogo de duas pessoas da Teoria dos Jogos.

3.2. O paradigma do dilema do Prisioneiro

O dilema do Prisioneiro define uma situação de conflito de interesses, onde dois indivíduos são presos e colocados em celas diferentes e sem comunicação entre eles [Poundstone 1993].

Foi proposto a cada preso pela polícia o seguinte:

- Se um deles confessasse o crime e o outro não, então, este ficaria preso por três meses, pela sua cooperação e o outro por dois anos;
- Se ambos confessassem o crime, então ambos ficam presos por um ano;
- Se não, caso não confessem o crime, eles serão presos por seis meses.

A tabela a seguir mostra o pagamento do Dilema do Prisioneiro, combinando todos os pares de estratégias, e seus respectivos pagamentos para cada indivíduo.

Tabela 2. Tabela de pagamento do Dilema do Prisioneiro

		Jogador 2	
		Cooperar (C)	Trair(D)
Jogador 1	Cooperar (C)	(R, R)	(S, T)
	Trair (D)	(T, S)	(P, P)

Fonte: [Borges 1996].

Na Tabela I, podemos ver que cada um dos jogadores tem dois tipos de comportamento: Cooperar (*Cooperate*) e Trair (*Defeated*). Por trás disso, tem-se quatro variáveis que significam: (1) R é a recompensa (*Reward*) para cada jogador caso ambos venham a cooperar; (2) P é a punição (*Punishment*) para cada jogador caso ambos venham a trair; (3) T é a tentação (*Temptation*) de cada um dos jogadores, caso traiam sozinhos; (4) S é o “pagamento do otário” (*Sucker*) que coopera sozinho.



As variáveis, devem seguir a relação:

- $T > R > P > S$
- $R > (T + S)/2$
- $(T + S)/2 > P$

Neste ambiente os indivíduos irão interagir, buscando maximizar os seus ganhos. Na Interação Social, apresentada por Teixeira o Dilema do Prisioneiro é utilizado como ambiente de disputa.

As estratégias de comportamentos e a tabela de pagamento utilizados neste trabalho seguem, também, o proposto no Dilema do Prisioneiro.

Segundo [von Neumann e Morgenstern 1944], as estratégias de comportamento podem ser puras ou mistas. As estratégias podem ser escolhidas entre duas possibilidades, a de sempre cooperar (ALL-C) ou a de sempre trair (ALL-D).

As estratégias mistas trazem a possibilidade de o jogador mudar o seu comportamento no decorrer do jogo. Assim como em [von Neumann e Morgenstern 1944], foram escolhidas duas estratégias mistas, são elas a estratégia Aleatória, onde o jogador coopera ou trai, sem um padrão estabelecido; e a estratégia *Tit-For-Tat* (TFT), nesta estratégia o jogador primeiramente coopera, e a partir da segunda rodada passa a copiar a estratégia do seu adversário.

3.3. Método de Interação Social

No contexto do trabalho de [Teixeira et al. 2011] a Interação Social (SI – *Social Iteration*) foi inserida como mais uma etapa no Algoritmo Genético, com o intuito de alterar o valor de fitness, no processo evolutivo, no decorrer da execução do Algoritmo Genético.

Com esta modificação é esperado que o indivíduo melhore as suas chances de gerar descendentes, através da disputa entre dois ou mais indivíduos.

Nesta nova etapa a população é exposta a um novo ambiente, que representa um jogo estratégico, onde os indivíduos possuem a chance de brigar uns com os outros pela sua existência durante uma iteração do algoritmo [Teixeira 2005].

A fase de Interação Social consiste, basicamente de três etapas:

- Seleção dos indivíduos, pode ser aleatória.
- Obter o comportamento de cada um dos indivíduos, a partir de sua estratégia de comportamento.
- Alterar o seu valor de *fitness* com base na tabela de pagamento do jogo.

Para que os indivíduos tenham a capacidade de se comportar estrategicamente é inserido um novo cromossomo, responsável pelo código genético da sua estratégia. Este é transmitido para seus descendentes, através do cruzamento, e também sofre a mutação em um de seus genes [Teixeira et al. 2011].

A codificação do cromossomo é feita como um vetor de duas posições, e um alfabeto com três símbolos somente, 0, 1 e 2. Que codificam as quatro estratégias mencionadas.

A tabela a seguir apresenta a codificação do sistema binário adotado, e a notação genética. Esta última é representada pela letra C ou c e possui uma relação de dominância entre os alelos $C^h = C^d > c$.

Tabela 3. Codificação genética das estratégias de comportamento

Genótipo	Cromossomo	Fenótipo	Observação
$C^h C^h$	00	ALL-D	Conhece apenas comportamento trair.
$C^h C^d$	01	TFT	Conhece os dois comportamentos e os aplica de acordo com a ultima jogada do adversário, mas prioriza a cooperação.
$C^h c$	02	ALL-D	Conhece apenas comportamento trair.
$C^d C^h$	10	TFT	Conhece os dois comportamentos e os aplica de acordo com a ultima jogada do adversário, mas prioriza a cooperação.



C^dC^d	11	ALL-C	Conhece apenas o comportamento cooperar.
$C^d c$	12	ALL-C	Conhece apenas o comportamento cooperar.
$C^h c$	20	ALL-D	Conhece apenas comportamento trair.
$C^d c$	21	ALL-C	Conhece apenas o comportamento cooperar.
cc	22	Aleatório	

Fonte: [Brito 2005].

A Interação Social realiza disputas entre os agentes (indivíduos) de uma população. O comportamento de cada um é codificado segundo a Tabela 3 e a disputa é realizada com uma quantidade n de agentes de acordo com a tabela de pagamento do jogo Dilema do Prisioneiro.

Diferentemente do apresentado no trabalho de [Teixeira et al. 2011], o aplicado neste trabalho, com Otimização por Colônia de Formigas, as formigas não disputarão para passar seu cromossomo adiante em uma população que realiza evolução genética, mas sim disputarão para escolher a que poderá ter o melhor caminho dentre as que disputaram.

A formiga poderá tornar seu caminho mais atrativo, pois ganhou na disputa com outras formigas com comportamentos diferentes.

A seguir é apresentado o algoritmo de colônia de formigas com Interação Social.

4. Otimização baseado em Colônia de Formigas com Interação Social (SIACO)

No Algoritmo de Otimização por Colônia de Formigas, um indivíduo (formiga), ao encontrar um alimento, marca a rota que tomou com o seu feromônio. Com isso ela tenta influenciar as demais, para que estas escolham a mesma rota que ela tomou.

Uma formiga realiza uma influência sobre as demais formigas através deste depósito de feromônio.

A ideia central neste novo algoritmo é, ao invés das formigas realizarem a mesma influência sobre o ambiente, ou seja, depositarem a mesma quantidade de feromônio, elas tenham a possibilidade de competir entre si e com isso, a formiga consiga, pelo jogo, um ganho em sua quantidade de feromônio depositado.

Com essa competição, uma formiga ganhadora irá depositar mais feromônio no ambiente do que a formiga perdedora. Em se tratando de influência, a formiga ganhadora irá realizar mais influência sobre o ambiente do que a perdedora. E assim também a sua influência sobre as outras formigas, em suas decisões, será maior do que a perdedora.

A competição se dará devido a necessidade de uma formiga passar as informações de sua rota adiante, e considerar que a sua rota pode ser a melhor.

O seu comportamento também será passado adiante, e isso é realizado inserindo um Ambiente Social (SE - *Social Environment*) que será compartilhado por todas as formigas. Uma formiga também realizará a sua influência neste ambiente e as demais formigas poderão escolher o seu comportamento baseado em uma seleção probabilística semelhante a seleção de sua rota. A influência de uma formiga sobre o Ambiente Social também irá evaporar no decorrer das iterações, como acontece com a quantidade de feromônio no Ambiente do Problema.

Tabela 4. Algoritmo SIACO

Algoritmo SIACO	
1	para t indo de 1 até um número máximo de iterações faça
2	para k indo de 1 até m faça
3	selecione o comportamento da formiga segundo a regra de decisão probabilística $p_c^k(t)$;
4	repita até a formiga k encontrar um caminho completo
5	selecione a próxima cidade a ser visitada segundo a regra de decisão probabilística $p_{ij}^k(t)$;
6	fim-do-repita
7	calcule a distância $L_k(t)$ do caminho descoberto pela formiga k ;
8	se $L_k(t) < L^*$ então $S^* \leftarrow S_k(t)$
9	fim-do-para
10	repita até um número máximo de disputas



11	selecionar aleatoriamente dois indivíduos;
12	repita até um número máximo de rodadas
13	Calcule o percentual de ganho de feromônio da formiga k , pela tabela de pagamento do dilema do prisioneiro.
14	fim-do-repita
15	fim-do-repita
16	atualize $\tau_{ij}(t+1)$, $\forall(i, j) \in E$, segundo processo de depósito e evaporação de feromônio específico;
17	atualize $\tau_c(t+1)$, $\forall(c) \in SE$, segundo processo de depósito e evaporação de feromônio específico;
18	fim-do-para
19	retornar S^* ;

Neste novo algoritmo, as formigas irão, primeiramente, selecionar um comportamento que deverão tomar durante toda a iteração.

O meio que a formiga possui para influenciar as outras é o feromônio, por isso, no Ambiente Social, também deverá ser depositado feromônio, de acordo com o processo de depósito e evaporação de feromônio que será apresentado mais adiante.

Mas, ao iniciar o algoritmo, o ambiente social possui a mesma quantidade de feromônio, $\tau_c(t) > 0$. Desta forma, as primeiras escolhas de comportamento são completamente aleatórias.

A formiga escolhe o comportamento através da regra de decisão probabilística:

$$p_c^k(t) = \left\{ \frac{[\tau_c]^\alpha}{\sum_{l_c \in N_c^k} l[\tau_c]^\alpha} \right\} \quad (6)$$

Onde:

- $p_c^k(t)$: probabilidade de um comportamento c ser escolhida pela formiga k , na iteração atual t ;
- $\tau_c(t)$: intensidade de feromônio presente no comportamento $c \in SE$, na iteração atual;
- α : parâmetro que regula a influencia de $\tau_c(t)$ na escolha do comportamento;
- $N_c^k(t)$: vizinhança do comportamento c ainda não escolhido pela formiga k , na iteração atual;

Esta equação é utilizada na seleção do comportamento que será adotado pela formiga no processo de Interação Social (linhas 10 a 11). Para a seleção proporcional a probabilidade do comportamento, foi escolhido, novamente, o método da Roleta. Quanto maior a quantidade de feromônio em um Comportamento no Ambiente Social, maior é a probabilidade de escolher o mesmo. Neste trabalho o comportamento adotado será armazenado como um vetor de duas posições, com cada posição contendo um gene de comportamento, como o utilizado em [Teixeira et al. 2011].

Com o comportamento já escolhido pela formiga, ela segue para os próximos passos, que são a escolha das cidades que serão visitadas, processo este que continua idêntico ao processo do ACO original. Em seguida é realizado o processo de cálculo da distância percorrida pela formiga, na iteração atual.

O processo de seleção do caminho da formiga também continua o mesmo, com seleção probabilística, equação (1).

Após a seleção das cidades a serem visitadas, ocorrerá a etapa de interação social entre as formigas. Nesta etapa n formigas são escolhidas aleatoriamente, e estas irão competir durante r rodadas.

Cada formiga ganhará um valor respectivo ao seu comportamento, de acordo como a tabela de pagamento do jogo Dilema do Prisioneiro. Este valor será um percentual que deverá ser acrescido na quantidade de feromônio que a formiga pode depositar, seguindo a formula a seguir:



$$Q^k(t) = Q^k + \frac{(\text{pagamento} \times Q^k)}{100} \quad (7)$$

O ganho de feromônio ocorre somente na iteração atual e para a formiga atual. Esta nova quantidade de feromônio será utilizada para depósito no caminho encontrado e no comportamento por ela adotado. Após ser calculado a nova quantidade de feromônio, ocorrerá o processo de depósito/evaporação do mesmo.

O processo de depósito/evaporação de feromônio no ambiente ocorre da mesma maneira definida pela equação (2). O mesmo processo será realizado no Ambiente Social, com cada formiga, também, realizando o depósito de feromônio no comportamento escolhido. Ao final do processo, o comportamento que escolhido pela maioria terá a maior quantidade de feromônio, e irá atrair mais formigas para ele.

O processo de depósito/evaporação de feromônio, no Ambiente Social será realizado pela seguinte equação:

$$\tau_c(t+1) = (1-\rho) \times \tau_c(t) + \Delta \tau_c(t) \quad (8)$$

Sendo

$$\Delta \tau_c(t) = \sum_{k=1}^m \Delta \tau_c^k(t) \quad (9)$$

Com

$$\Delta \tau_c^k(t) = \frac{Q^k(t)}{L_k(t)} \quad (10)$$

E a formiga k escolheu o comportamento $c \in ES$; caso contrário:

$$\Delta \tau_c^k(t) = 0 \quad (11)$$

Onde:

- $\rho \in [1,0]$: parâmetro que regula a redução de $\tau_c(t) \in ES$;
- m : número de formigas;
- $\Delta \tau_c^k(t)$: ganho de feromônio no comportamento $c \in ES$, causado pela formiga k ;
- $Q^k(t)$: quantidade de feromônio excretado por uma formiga na iteração atual;
- $S_k(t)$: caminho completo que interliga todas as cidades uma única vez, descoberto pela formiga k ;
- $L_k(t)$: distância associada ao caminho completo $S_k(t)$ descoberto pela formiga k ;

Ao final da iteração a melhor solução é armazenada e comparada com a melhor solução encontrada até o momento. E ao final, quando o critério de parada for atingido, número máximo de iterações, a heurística retorna a melhor solução encontrada.

O tópico a seguir apresenta os resultados de testes realizados sobre o TSP, mais especificamente a instancia Brazil 58.

5. Testes e Resultados sobre o Brazil 58

O Problema do Caixeiro Viajante (TSP – *Traveling Salesman Problem*) é um problema de otimização combinatória, onde uma pessoa deseja viajar entre diversas cidades de uma região, com a condição de que este deve ser o melhor caminho entre todos os possíveis.

É um problema que se encaixa na classe de problemas NP-Completo, de tempo exponencial, para o tamanho da entrada. A instancia utilizada neste artigo é a brazil58, onde devem ser percorridas 58 cidades do Brasil e retornar ao local de partida.



Na execução do algoritmo foram definidas 200 formigas, cada uma iniciando em uma cidade específica e foram realizadas 2000 iterações, Nestas iterações são realizadas 2 rodadas como o experimento realizado em [Teixeira et al. 2011].

Os parâmetros utilizados foram os definidos em [Gaertner e Clark 2005] como os ideais para o problema TSP. São eles: $\alpha = 1$ (no trabalho [Gaertner e Clark 2005] é definido que este parâmetro deve ser fixado, pois influencia pouco na busca realizado pelo ACO), $\beta = 6$, $\tau_{ij}(0) = 0,001$, $\rho = 0.2$ (no artigo [Gaertner e Clark 2005] é utilizado 0.6, mas, com esse valor, durante o processo de execução foi observado que o feromônio evapora com grande velocidade).

Também utilizamos os parâmetros testados por Dorigo em [Dorigo et al. 1999] e também dito como ideias para o problema TSP, mais especificamente para o problema Oliver30 um problema de 30 cidades descrito em [Whitley et al. 1989]. São eles: $\tau_{ij}(0) = 0,001$, $\alpha = 1$, $\beta = 5$, $\rho = 0.5$.

A tabela a seguir realiza uma comparação dos 10 melhores resultados encontrados em 30 execuções do algoritmo *Ant System* e o SIACO com as duas versões para seus parâmetros, além de uma média dos resultados encontrados.

Tabela 5. 10 melhores resultados para a execução do algoritmo *Ant System* e o algoritmo SIACO

	<i>Ant System</i>	<i>Ant System</i>	SIACO	SIACO	
	$\alpha=1,$ $\beta=5,$ $\rho=0.5$	$\alpha=1,$ $\beta=6,$ $\rho=0.2$	$\alpha=1,$ $\beta=5,$ $\rho=0.5$	$\alpha=1,$ $\beta=6,$ $\rho=0.2$	c_k
	25835	25870	25954	25809	22
	25957	25883	26006	25906	01
	26067	25925	26031	25934	01
	26082	25949	26061	25945	01
	26090	25955	26098	25955	02
	26093	25981	26125	25985	11
	26118	25981	26131	25999	11
	26123	25983	26148	26015	21
	26124	25988	26153	26017	20
	26132	26002	26180	26019	20
Media	26062,1	25951,7	26088,7	25958,4	

Como pode ser visto na Tabela 5 o algoritmo SIACO encontrou o melhor resultados de todas as execuções com 25809 e $c_k = 22$ (c_k é o comportamento escolhido por uma formiga). Na mesma tabela pode ser visto que no resultado do SIACO com os parâmetros definidos por Dorigo não há domínio de um comportamento, enquanto que no SIACO com os parâmetros definidos em 18, há o domínio do comportamento TFT nos cinco melhores resultados, com três destes.

O melhor resultado encontrado pelo SIACO, com os parâmetros definidos em [Dorigo et al. 1999], (linha 1), é 0,46% pior do que o melhor resultado encontrado pelo *Ant System* com os mesmos parâmetros e a media é 0,1% pior. Comparado com o *Ant System* com os parâmetros definidos em [Gaertner e Clark 2005] é 0,32% pior e a diferença da média entre estes é de 0,52%, também para pior.

O melhor resultado encontrado pelo SIACO, com os parâmetros definidos em [Gaertner e Clark 2005], (linha 1), é 0,1% melhor do que o melhor resultado encontrado pelo *Ant System* com os parâmetros encontrados em [Dorigo et al. 1999], e a diferença entre as suas médias é de 0,39% também para melhor. Comparado com o *Ant System* com os parâmetros definidos em [Gaertner e Clark 2005] é 0,23% melhor e a diferença da média entre estes é de 0,02%, mas agora para pior.


As imagens 4 a 7 demonstram os resultados encontrados na melhor execução das quatro versões apresentadas. Nas figuras 4 e 5 são demonstrados os resultados do algoritmo *Ant System* com os parâmetros definidos em [Dorigo et al. 1999] e [Gaertner e Clark 2005], respectivamente.




As figuras 6 e 7 apresentam os resultados encontrados com a execução do SIACO com os parâmetros definidos em [Dorigo et al. 1999] e [Gaertner e Clark 2005], respectivamente.

Mas os resultados acabaram por ser muito próximos, o que trás uma boa perspectiva sobre as possibilidades do novo algoritmo.


A figura 6 demonstra a execução do melhor resultado encontrado com o algoritmo SIACO utilizando os parâmetros indicados em [Dorigo et al. 1999]. Neste gráfico pode ser visto que o melhor resultado foi encontrado já na iteração 380. O que indica que, assim como o *Ant System*, o melhor resultado continua sendo encontrado de maneira muito rápida.




Ant System com os parâmetros definidos em [Dorigo et al. 1999]. O algoritmo encontra a melhor rota na iteração 391, como dito em [Dorigo et al. 1999], a solução é encontrada rapidamente.



SIACO com os parâmetros definidos em [Dorigo et al. 1999]. O algoritmo encontra a melhor rota na iteração 380.



Ant System com os parâmetros definidos em [Gaertner e Clark 2005]. O algoritmo encontra a melhor rota na iteração 806



SIACO com os parâmetros definidos em [Gaertner e Clark 2005]. O algoritmo encontra a melhor rota na iteração 59.

A figura 7 demonstra a execução do melhor resultado encontrado pelo SIACO utilizando os parâmetros indicados em [Gaertner e Clark 2005], apenas com modificações no parâmetro $\rho = 0,2$. Nele pode ser visto que, na melhor execução, o melhor resultado foi encontrado já na iteração 59. Indicando que o melhor resultado foi encontrado de maneira ainda mais rápida, mas isto também pode indicar que a quantidade de feromônio no caminho escolhido é muito grande.

6. Conclusão

Com o SIACO, é esperado que haja uma maior cobertura do espaço de busca, já que o algoritmo, ao invés de se direcionar a um ótimo local, com a evaporação de feromônio, trás condições de rotas não tão boas causarem maior influencia sobre a escolha das formigas. A disputa entre as formigas trás essa possibilidade, de que uma solução que não é tão boa possa ser utilizada como parte de uma solução que pode vir a ser a melhor.

Estudos futuros sobre os melhores parâmetros a serem utilizados em ambos os algoritmos, com execuções exaustivas, podem nos trazer resultados melhores e tornar mais claro a influência dos parâmetros sobre as escolhas das formigas.

Referências



Borges, P., (1996). “A Model of Strategy Games based on the Paradigm of the Iterated Prisoner's Dilemma Employing Fuzzy Sets”, Tese de Doutorado, Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, SC.

Brito, F., Teixeira, O. e Oliveira, R. (2005). “A introdução da interação social fenotípica em algoritmos genéticos através dos jogos evolucionários e da codificação e transmissão genética do comportamento”, In: Anais do VII Simpósio Brasileiro de Automação Inteligente.

Darwin, C. (1859). “On the Origin of Species by Means Natural Selection, or Preservation of Favored Races in the Struggle for Life”, London, UK: John Murray.

Dorigo, M. (1992). “Optimization, Learning and Natural Algorithms”, Ph.D. Thesis, Politecnico di Milano, Itália.

Dorigo, M., Di Caro, G. e Gambardella, L. (1999) “Ant Algorithms for Discrete Optimization”, To appear in Artificial Life, MIT Press.

Dorigo, M., Maniezzo, V. e Coloni, A. (1996) “The Ant System: Optimization by a colony of cooperating agents”, IEEE Transactions on Systems, Man, and Cybernetics–Part B, Vol.26, No.1, pp.1-13.

Gaertner, D. e Clark, K. (2005) “On Optimal Parameters for Ant Colony Optimization algorithm”, Proceedings of the International Conference on Artificial Intelligence, pp. 83-89, CSREA Press.

Poundstone, W. (1993). “Prisoner's Dilemma: John von Neumann, Game Theory, and the Puzzle of the Bomb”, Sydney, Australia: Anchor Books.

Rapoport, A. (1999) “Two-Person Game Theory”, Mineola, USA: Dover Publications.

Silva, E., Bahiense, C. e Castro, M. (2005). “Uma Abordagem Paralela Baseada em Colônia de Formigas para o Problema do Caixeiro Viajante”, Cadernos do IME: Série Informática: Vol. 18.

Silva, R. M. (2003) “Otimização Baseada em Colônia de Formigas Aplicada ao Problema de Cobertura de Conjuntos”. Capítulo 3 - Otimização Baseada em Colônia de Formigas, Tese de Doutorado em Ciência da Computação, Centro Federal de Informática, Universidade Federal de Pernambuco - UFPB, Recife, Brasil.

Teixeira, O., Lobato, W., Yanaguibachi, H., Cavalcante, R., Silva, D. e Oliveira, R. (2011) “Algoritmo Genético com Interação Social na Resolução de Problemas de Otimização”, Computação Evolucionária em Problemas de Engenharia, Lopes & Takahashi, Eds, pp. 197-224.

Teixeira, O. (2005). “Proposta de um Novo Algoritmo Genético baseado na Teoria dos Jogos”, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Pará, Belém, PA.

von Neumann, J. e Morgenstern, O. (1944) “Theory of Games and the Economic Behavior”, Princeton, USA: Princeton University Press.

Whitley, D., Starkweather, T. e Fuquay, D. (1989) “Scheduling Problems and Travelling Salesman: the Genetic Edge Recombination Operator”, Proceedings of the Third International Conference on Genetic Algorithms, Morgan Kaufmann.