

---

# Inteligência de Enxames

---

André Ricardo Gonçalves

`andreric [at] dca.fee.unicamp.br`

`www.dca.fee.unicamp.br/~andreric`

# Sumário

<b>1</b>	<b>Inteligência de Enxames</b>	p. 3
1.1	Ant Colony Optimization . . . . .	p. 3
1.1.1	Ant System . . . . .	p. 5
1.1.2	Outros algoritmos ACO . . . . .	p. 7
1.1.2.1	<i>MAX-MIN</i> Ant System . . . . .	p. 7
1.1.2.2	Ant Colony System . . . . .	p. 8
1.2	Particle Swarm Optimization . . . . .	p. 8
1.2.1	Simulando o Comportamento Social . . . . .	p. 9
1.2.2	Modelo Matemático do Comportamento Social . . . . .	p. 9
1.2.3	Variações do Algoritmo PSO . . . . .	p. 11
1.2.3.1	Modelo Somente Cognitivo . . . . .	p. 12
1.2.3.2	Modelo Somente Social . . . . .	p. 12
1.2.3.3	Modelo “Selfless” . . . . .	p. 12
1.3	Aplicações . . . . .	p. 13
1.4	Conclusão . . . . .	p. 13
	<b>Referências</b>	p. 14

# 1 Inteligência de Enxames

Com a busca incessante por modelos inteligentes inspirados em processos do mundo real, foi observado que agentes simples os quais sozinhos são incapazes de realizar tarefas simples, quando se interagem emergem um sistema auto-organizado capaz de desenvolver tarefas de grande complexidade (LOPES, 2006), como as abelhas na construção e estruturação de uma colméia, os cupins que constroem complexos sistemas de túneis, as formigas que podem encontrar caminhos diretos quando buscam por alimentos.

Inspirados nestes processos naturais foram desenvolvidos modelos computacionais interessantes, baseados no conceito de inteligência coletiva. Estudos que levaram a criação de uma nova área na inteligência computacional, a inteligência de enxames (*swarm intelligence*).

Dentro do contexto da inteligência de enxames, uma técnica que vêm sendo aplicada com bastante sucesso em problemas de otimização, é a chamada Otimização por Colônias de Formigas, do inglês **ACO!** (**ACO!**) criada por Colorni, Dorigo e Maniezzo (1992), que simula o comportamento de uma colônia de formigas em relação a certos problemas por ela encontrado, como encontrar o menor caminho entre o formigueiro e o local onde se encontra o alimento. Outra técnica bastante difundida é a Otimização por Enxame de Partículas, do inglês **PSO!** (**PSO!**), que utiliza do comportamento social de algumas espécies para resolução de problemas complexos. Ambas técnicas são abordadas neste trabalho.

## 1.1 Ant Colony Optimization

Em meados dos anos quarenta o entomologista francês Pierre-Paul Grassé, descreveu como “estímulo significante” a reação de algumas espécies de térmitas (inseto da família do cupim). Esta reação podia agir como um novo estímulo significante para outros insetos da colônia. Grassé foi o primeiro a utilizar o termo *estigmergia* para identificar o particular tipo de comunicação entre os agentes (térmitas)(DORIGO; BIRATTARI; STUTZLE, 2006).

Dorigo, Birattari e Stutzle (2006) observa duas principais características que diferenciam a *estigmergia* de outros tipos de comunicação:

- Estigmergia é uma forma de comunicação indireta e não-simbólica, intermediada pelo ambiente: insetos trocam informações modificando seus ambientes;
- A informação estigmérgica é local, podendo ser acessada somente pelo inseto que visitar o local (ou imediatamente sua vizinhança).

Algumas espécies de formigas utilizam desta forma de comunicação, sendo feita por meio de depósito de substância no local utilizado pela formiga, substância denominada de *ferormônio*. Ao passar por uma trilha, uma formiga deposita certa quantidade de ferormônio, posteriormente outras formigas que passem pelo mesmo local, serão estimuladas a seguirem as trilhas com a maior quantidade de ferormônio.

Um experimento realizado por Deneubourg et al. (1990), visava demonstrar o processo de comunicação entre as formigas via depósito de ferormônio. Na fase inicial colocaram-se duas trilhas de tamanhos iguais entre o ninho e a fonte de alimento, como mostra a figura 1. No começo as formigas escolhiam trilhas randomicamente, algum tempo depois todas as formigas seguiam sempre a mesma trilha, devido a uma das trilhas conter uma maior quantidade de ferormônio. Deneubourg e colaboradores repetiram o experimento várias vezes e identificaram que cada trilha era escolhida em 50% dos casos.




Figura 1: Experimento 1: trilhas com mesmo tamanho

Na fase final do experimento Deneubourg e colaboradores, modificaram o tamanho de uma das trilhas, fazendo-a significativamente mais longa, como mostra a figura 2.




Figura 2: Experimento 2: trilhas com tamanhos diferentes

Inicialmente as formigas seguiam trilhas aleatoriamente, mas com o passar do tempo, as formigas tendiam a trilhas mais curtas. Com isso os autores identificaram uma importante regra: “as formigas escolhem por acaso a trilha que primeiro alcança a fonte de alimento”, devido ao fato da trilha mais curta receber mais rapidamente o ferormônio do que trilha maior, fazendo com que as formigas que fazem o caminho de volta utilizem a trilha mais curta, essas por sua vez depositam ferormônio, aumentando a quantidade presente na trilha menor, convergindo para a situação onde todas as formigas utilizem o caminho mais curto.

Baseado nesta característica, Colorni, Dorigo e Maniezzo (1992) propuseram uma técnica denominada *Ant System*, que utiliza todos estes conceitos, para solução de problemas de otimização de rotas, abrindo caminho para um grande número de outras pesquisas nesta área, sendo este campo denominado de Otimização por Colônia de Formigas.

### 1.1.1 Ant System

O **AS!** (**AS!**) foi o primeiro algoritmo **ACO!** proposto na literatura (COLORNI; DORIGO; MANIEZZO, 1992). É um modelo inspirado no comportamento de algumas espécies de formigas durante o processo de busca por alimento, no qual as formigas ao passar por trilhas vão deixando certa quantidade de ferormônio pelo caminho, assim as formigas que venham posteriormente, são atraídas por esta substância tendo alta probabilidade de seguir este mesmo caminho (DORIGO; BIRATTARI; STUTZLE, 2006).

É um modelo baseado em população, cada indivíduo é a representação de uma possível solução do sistema, isso permite trabalhar com diversas soluções ao mesmo tempo. Inicialmente as formigas estão em seu ninho e com o passar do tempo elas vão percorrendo as trilhas e depositando seu ferormônio até que cheguem ao seu destino (fonte de alimento). A representação do sistema é feita utilizando um grafo direcionado, como mostra a figura 3.




Figura 3: Representação do ambiente

Segundo (DORIGO; BIRATTARI; STUTZLE, 2006) a quantidade de ferormônio em cada trilha é atualizada em relação ao número  $m$  de formigas que utilizaram esta trilha, a fórmula de atualização da quantidade de ferormônio de uma trilha entre os pontos  $i$  e  $j$  é dada pela Eq. (1.1).

$$\tau_{ij} = (1 - \rho) \cdot \tau_{ij} + \sum_{k=1}^m \Delta\tau_{ij}^k \quad (1.1)$$

onde  $\rho$  é a taxa de evaporação,  $m$  o número de formigas que utilizaram esta trilha e  $\Delta\tau_{ij}^k$  é a quantidade de ferormônio deixado pela formiga  $k$  na trilha entre os pontos  $i$  e  $j$ , o qual é calculado conforme a Eq. (1.2).

$$\Delta_{ij}^k = \begin{cases} Q/L_k & , \text{ se a formiga } k \text{ utilizou esta trilha} \\ 0 & , \text{ caso contrário} \end{cases} \quad (1.2)$$

caso a formiga  $k$  tenha utilizado esta trilha e  $\Delta_{ij}^k = 0$  caso contrário, onde  $Q$  é uma constante e  $L_k$  é o comprimento da rota utilizado pela formiga  $k$  (DORIGO; BIRATTARI; STUTZLE, 2006).

Segundo (DORIGO; MANIEZZO; COLORNI, 1996), em uma visão mais prática, a taxa de evaporação é utilizada para evitar que o sistema tenha uma convergência rápida para uma solução sub-ótima. A quantidade inicial de ferormônio em cada trilha ( $\tau_{ij}(0)$ ) é obtida arbitrariamente, comumente utilizam-se valores pequenos (COLORNI; DORIGO; MANIEZZO, 1992).

Após as formigas terem passado por uma trilha, elas necessitam escolher uma nova trilha a ser seguida, a fim de atingir o objetivo final, chegar à fonte de alimento. A quantidade de ferormônio acumulado em cada trilha será decisiva para sua escolha, quanto mais ferormônio a trilha contiver maior será a probabilidade de esta trilha ser seguida, a probabilidade de uma formiga  $k$ , escolher uma trilha partindo de  $i$  para o ponto  $j$ , é dada pela Eq. (1.3)

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{\sum_{c_{il} \in N(s^p)} \tau_{ij}^\alpha \cdot \eta_{ij}^\beta} & , \text{ se } c_{il} \in N(s^p) \\ 0 & , \text{ caso contrário} \end{cases} \quad (1.3)$$

onde  $N(s^p)$  é o conjunto de trilhas ainda não utilizadas pela formiga. Segundo (DORIGO; BIRATTARI; STUTZLE, 2006), os parâmetros  $\alpha$  e  $\beta$ , controlam a relativa importância do ferormônio em relação à informação heurística,  $\eta_{ij}^\beta$ , a qual de acordo com (COLORNI; DORIGO; MANIEZZO, 1992) é chamado de *visibilidade*, que diz que pontos mais próximos devem ter uma maior probabilidade de serem escolhidos, a mesma é definida conforme a fórmula 1.4

$$\eta_{ij}^\beta = \frac{1}{d_{ij}} \quad (1.4)$$

onde  $d_{ij}$  é a distância entre os pontos  $i$  e  $j$ .

Este processo continua até que todas as formigas cheguem ao destino. Com o passar do tempo, as formigas tenderão a seguir caminhos mais curtos, devido a um maior

trânsito de formigas, e conseqüentemente um maior despejo de ferormônio, por unidade de tempo. Isso causa uma maior concentração de ferormônios em caminhos mais curtos, até que todas as formigas utilizem um único caminho, o mais curto (o sistema convirja para solução ótima, ou próxima dela).

## 1.1.2 Outros algoritmos ACO

Diversos outros algoritmos baseados no Ant System foram propostos na literatura. Estes métodos são melhorias e extensões do *Ant System* original.

Dorigo, Birattari e Stutzle (2006) apresentam os principais algoritmos ACO propostos, destacando-se duas das variantes mais bem sucedidas do *Ant System*, o *MAX-MIN Ant System* e o *Ant Colony System*.

### 1.1.2.1 MAX-MIN Ant System

Proposto por (UTZLE; HOOS, 1997) este algoritmo é um melhoramento sobre AS original, no qual o processo de atualização da quantidade de ferormônio presente na trilha, é realizado pela melhor formiga, não dentre todas como o AS original. Além disso, foi imposto um limite, inferior e superior, na quantidade de ferormônio em cada trilha.

Com isso a atualização do ferormônio da trilha  $i$  para  $j$ , é dado pela Eq. (1.5)

$$\tau_{ij} = [(1 - \rho) \cdot \tau_{ij} + \Delta\tau_{ij}^{melhor}]_{\tau_{min}}^{\tau_{max}} \quad (1.5)$$

onde  $\tau_{min}$  e  $\tau_{max}$  representam o limite inferior e superior imposto para o ferormônio. O operador  $[x]_b^a$  é definido pela Eq. (1.6).

$$[x]_b^a = \begin{cases} a & , \text{ se } x > a, \\ b & , \text{ se } x < b, \\ x & , \text{ caso contrário} \end{cases} \quad (1.6)$$

A quantidade de ferormônio deixada pela formiga que utilizou o percurso com menor custo (melhor formiga), é calculado segundo a Eq. (1.7), onde  $L_{melhor}$  é o custo do percurso realizado pela melhor formiga.

$$\Delta\tau_{ij}^{melhor} = \begin{cases} \frac{1}{L_{melhor}} & , \text{ se } (i,j) \text{ pertence ao melhor percurso} \\ 0 & , \text{ caso contrário} \end{cases} \quad (1.7)$$

De acordo com (DORIGO; BIRATTARI; STUTZLE, 2006), o valor de  $L_{melhor}$  pode ser o melhor percurso da iteração corrente ( $L_{mi}$ ), o melhor percurso desde o início do algoritmo ( $L_{mt}$ ) ou ainda uma combinação dos dois.

O autor supracitado ainda observa que os valores de  $\tau_{min}$  e  $\tau_{max}$  são obtidos

de maneira empírica, e até o momento não há direção de como obter esses valores.

### 1.1.2.2 Ant Colony System

O algoritmo **ACS!** (**ACS!**) utiliza-se do conceito de atualização local do ferormônio (*local pheromone update*), em adição a atualização do ferormônio no final de percurso.

A atualização local do ferormônio é realizada por todas as formigas em cada passo da construção, cada formiga aplica esta atualização somente na última trilha percorrida (DORIGO; BIRATTARI; STUTZLE, 2006). A atualização local é realizada de acordo com a Eq. (1.8), onde  $\varphi \in (0,1]$  é o coeficiente de depósito de ferormônio e  $\tau_0$  é a quantidade inicial de ferormônio.

$$\tau_{ij} = (1 - \varphi) \cdot \tau_{ij} + \varphi \cdot \tau_0 \quad (1.8)$$

O objetivo principal da atualização local é a produção de diferentes soluções, dada o aumento das alterações na quantidade de ferormônio nas trilhas, criando uma maior diversidade de trilhas, encorajando novas formigas a escolherem outras soluções (DORIGO; BIRATTARI; STUTZLE, 2006).

Assim como no *MAX-MIN Ant System*, a atualização no final de cada percurso é realizada considerando apenas a formiga que obteve o percurso de menor custo, assim a fórmula de atualização é dada pela Eq. (1.9)

$$\tau_{ij} = \begin{cases} (1 - \rho) \cdot \tau_{ij} + \rho \cdot \Delta\tau_{ij} & , \text{ se } (i,j) \text{ pertence ao melhor percurso} \\ \tau_{ij} & , \text{ caso contrário} \end{cases} \quad (1.9)$$

O valor de  $\Delta\tau_{ij}$  é calculado da mesma forma do *MAX-MIN Ant System*, conforme a Eq. (1.7), com  $L_{melhor}$  podendo ser melhor da iteração ( $L_{mi}$ ) ou melhor dentre todos ( $L_{mt}$ ).

Como observa (DORIGO; BIRATTARI; STUTZLE, 2006) outra importante diferença entre ACS e AS é o modo como é feito o cálculo da probabilidade de escolha dentre as trilhas possíveis de uma formiga. No ACS é utilizada uma regra denominada de *regra pseudo-aleatória proporcional*, na qual a probabilidade de escolha de uma trilha entre  $i$  e  $j$  depende de uma variável aleatória  $q \in [0,1]$  uniformemente distribuída e ainda um outro parâmetro  $q_0$ . Assim uma trilha  $t$  é escolhida segundo a Eq. (1.10).

$$t = \begin{cases} \arg \max_{c_{il} \in N(s^p)} \left\{ \tau_{il} \eta_{il}^\beta \right\} & , \text{ se } q \leq q_0 \\ \text{Equação 1.3} & , \text{ caso contrário} \end{cases} \quad (1.10)$$



## 1.2 Particle Swarm Optimization

A técnica denominada Otimização por Enxames de Partículas, do inglês *Particle Swarm Optimization (PSO)*, é uma abordagem estocástica, baseada em população que simula o processo comportamental de interação entre os indivíduos de um grupo (MEDEIROS, 2005).

Sua teoria é fundamentada pela observação do comportamento de grupos de animais como pássaros, peixes, entre outros, que realizam interessantes tarefas de otimização na execução de atividades simples, como a busca por alimentos (KENNEDY; EBERHART, 1995). Com isso o PSO busca a simulação destas atividades naturalmente simples, porém matematicamente complexas.

Com base nas observações comportamentais dos grupos, pode-se concluir que o comportamento do mesmo é influenciado pelos resultados de experiências obtidos por cada indivíduo e também com a experiência obtida pelo grupo (KENNEDY; EBERHART, 1995).

Nesta abordagem cada indivíduo é dito ser uma possível solução para o problema investigado, sendo atribuído a cada indivíduo um valor que está relacionado a adequação da partícula com a solução do problema, denominada de *fitness*, e também uma variável velocidade que representa a direção do movimento do indivíduo (partícula). Com o passar do tempo os indivíduos vão ajustando suas velocidades em relação a melhor solução (melhor *fitness*) encontrada por ele próprio e também pela melhor solução do grupo, realizando este processo até que os indivíduos (partículas) encontrem o alimento (melhor solução global ou próxima dela).

O valor de *fitness* é calculado com base na função objetivo que se deseja maximizar (minimizar). Segundo (LOPES, 2006) o valor de *fitness* é definido pela natureza do problema de otimização e é computada por uma função objetivo que avalia um vetor solução.

### 1.2.1 Simulando o Comportamento Social

Objetivando a simulação dos movimentos dos bandos de pássaros, diversos pesquisadores buscam entender como eles se mantêm aninhados e alteram suas direções repentinamente, dispersando, e novamente reagrupando sem haver nenhum tipo de colisão.

A partir destas pesquisas, alguns modelos de simulação foram surgindo, estes modelos são fundamentados na distância individual entre as aves, e que a sincronia no comportamento do bando está no esforço dos pássaros em manter uma distância ótima entre eles e seus vizinhos (KENNEDY; EBERHART, 1995).

Kennedy e Eberhart (1995) afirmam que a hipótese fundamental para o desenvolvimento do PSO, surgiu a partir de um relato do sociobiologista Edward O. Wilson, que descrevia sobre a busca por comida de um cardume de peixes. Wilson afirmava que em teoria os membros individuais do cardume poderiam obter vantagem nas descobertas e pela experiência prévia de todos os outros membros do cardume durante o processo de busca por alimento, sendo que esta vantagem poderia ser decisiva, mesmo com a desvantagem da competição pelos itens de alimento, não importando o quão imprevisível estão distribuídos no ambiente (WILSON, 1975 apud KENNEDY; EBERHART, 1995). Este relato sugere que o compartilhamento social da informação entre os indivíduos oferece uma vantagem evolucionária.

## 1.2.2 Modelo Matemático do Comportamento Social

Com base nas teorias sociobiológicas, Kennedy e Eberhart (1995) apresentaram um modelo matemático básico do comportamento social de indivíduos em grupo. Neste modelo os indivíduos guardam consigo informações para orientá-los durante o processo de busca, os quais são elas: a posição do indivíduo no ambiente ( $X_{id}^t$ ), a qual é um vetor  $n$ -dimensional, dependendo da dimensão dos dados do problema; a velocidade ( $V_{id}^t$ ) e a melhor posição encontrada por ele até o momento ( $P_{id}$ ). Para (LOPES, 2006) o termo velocidade não tem a dimensão de espaço/tempo, mas sim a variação da posição do indivíduo no espaço de busca ( $\Delta X_{id}^t$ ), que por motivo de simplificação os autores definiram como *velocidade*. Além disso, guarda a melhor solução global que é definida por  $P_{gd}$ , que é utilizada no processo de atualização das velocidades dos indivíduos.

Inicialmente o vetor posição e a velocidade de cada indivíduo são iniciados de maneira randômica. Para o vetor posição os valores estão no intervalo no qual se deseja obter o valor máximo (mínimo) da função objetivo, para uma boa dispersão dos indivíduos no espaço de busca, um bom gerador de números randômicos é necessário.

Segundo (KENNEDY, 1997) para que o sistema não exploda e implemente realisticamente a simulação das alterações incrementais na aprendizagem humana, um valor  $V_{max}$  é utilizado como um limite de velocidade, tanto para a geração inicial das velocidades de cada indivíduo, quanto no processo de atualização das mesmas, com isso os valores iniciais das velocidades estão no intervalo  $[-V_{max}, V_{max}]$ .

De posse destes valores iniciais, o processo de avaliação e atualização das posições dos indivíduos é iniciada. Este processo é realizado de forma iterativa, até que uma condição de parada seja satisfeita. Alguns dos critérios de parada mais utilizados é a definição de um número máximo de iterações, ou quando os indivíduos não mais alterarem suas posições (LOPES, 2006).

Os valores de *fitness* são calculados para cada indivíduo, e a posição do indivíduo com melhor *fitness* é atribuída a uma variável  $P_{gb}$ , que guarda a posição da melhor solução obtida por todos os indivíduos até o momento. Com isso todos os outros indivíduos atualizam suas velocidades pela equação definida por (KENNEDY; EBERHART, 1995):

$$V_{id}^{t+1} = V_{id}^t + \varphi_{id}(P_{id} - X_{id}) + \varphi_{id}(P_{gd} - X_{id}) \quad (1.11)$$

O segundo termo do lado direito da equação, é descrito por (KENNEDY; EBERHART, 1995), como sendo o fator cognitivo do indivíduo e o terceiro termo o fator social. Na visão matemática o segundo termo define a distância entre a posição atual do indivíduo e a melhor posição que ele obteve até o momento, e o terceiro termo a distância entre a sua posição atual e a posição do indivíduo que obteve a melhor solução global (melhor valor de *fitness*).

Os valores de  $\varphi_{id}$  estão dentro do intervalo no qual se busca a solução ótima, e segundo (KENNEDY, 1997) pode ser um valor randômico, dentro do intervalo de busca.

De acordo com (LOPES, 2006) para que se possa cobrir satisfatoriamente o espaço de busca, um número de indivíduos entre 20 e 50 é suficiente.

Com as velocidades atualizadas, agora pode ser realizado o processo de atu-

alização da posição de todos os indivíduos, conforme a Eq. (1.12) descrita por (KENNEDY; EBERHART, 1995).

$$X_{id}^{t+1} = X_{id}^t + V_{id}^{t+1} \quad (1.12)$$

Este processo é realizado até que algum critério de parada pré-definido seja satisfeito. O algoritmo 1 apresenta o pseudo-código do algoritmo PSO.

---

**Algoritmo 1:** Particle Swarm Optimization

---

```

1 begin
2   for todos os indivíduos do
3     Inicialize a posição e velocidade randomicamente (dentro do espaço de busca);
4   end
5   while não condição de parada do
6     Calcule o valor de fitness para todos os indivíduos;
7     Obtenha a posição do indivíduo com melhor solução global;
8     Atualize a velocidade de cada indivíduo;
9     Atualize a posição de cada indivíduo;
10  end
11  Melhor solução da última iteração;
12 end

```

---

### 1.2.3 Variações do Algoritmo PSO

Existem algumas variações do algoritmo PSO canônico. Um modelo interessante utiliza o conceito de que um indivíduo inicialmente tende a imitar os indivíduos que estão mais próximos a ele. Com isso surgiu o termo “melhor vizinho”, que consiste em utilizar a posição do melhor vizinho, ao invés de utilizar a melhor posição global obtida até o momento.

Este modelo foi inicialmente proposto por (KENNEDY, 1997), o qual apresentava que a vizinhança é descrita pelo equivalente à um ciclo de comunicação, ou seja, para cada indivíduo  $i$ , a vizinhança era composta pelos indivíduos,  $i - 1$ ,  $i$  e  $i + 1$ . A figura 4 ilustra o conceito de ciclo de comunicação.

Utilizando este conceito de melhor vizinho, chamamos de  $P_{vd}$  a posição do melhor vizinho, a Eq. (1.13) apresenta como são atualizadas as velocidades dos indivíduos.

$$V_{id}^{t+1} = V_{id}^t + \varphi_{id}(P_{id} - X_{id}) + \varphi_{id}(P_{vd} - X_{id}) \quad (1.13)$$

O processo de atualização das posições é a mesmo apresentado pela Eq. (1.12).

Outros modelos foram apresentados por Kennedy (1997), os quais são denominados Modelo somente Cognitivo (“*Cognition-only Model*”), Modelo somente Social (“*Social-only Model*”) e o Modelo “*Selfless*” (“*Selfless Model*”).




Figura 4: Ciclo de comunicação entre os indivíduos

### 1.2.3.1 Modelo Somente Cognitivo

A ciência cognitiva vem tentando tratar indivíduos como se estivessem isolados, como se a cognição ocorresse dentro da cabeça do indivíduo. Face a isto, Kennedy (1997) apresentou um modelo no qual se baseia apenas no fator cognitivo, com isso a fórmula da atualização da velocidade é descrita por:

$$V_{id}^{t+1} = V_{id}^t + \varphi_{id}(P_{id} - X_{id}) \quad (1.14)$$

A equação que define a atualização da posição dos indivíduos é a mesma apresentada pela Eq. (1.12). Em teste comparativo com o modelo PSO canônico, aplicando ambos os modelos na otimização dos pesos de uma rede neural, Kennedy (1997) mostra que o modelo somente cognitivo obteve um desempenho proporcionalmente satisfatório, mas é suscetível a falhas dependendo dos parâmetros utilizados em  $V_{max}$  e  $\varphi$ .

### 1.2.3.2 Modelo Somente Social

Este modelo trabalha utilizando somente o fator social do algoritmo canônico, e também utilizando o conceito de melhor vizinho. Este modelo indica um processo socio-fisiológico sem a tendência de indivíduos voltarem a crer que o sucesso provém de experiências passadas (KENNEDY, 1997). A Eq. (1.15) identifica como são atualizadas as velocidades dos indivíduos.

$$V_{id}^{t+1} = V_{id}^t + \varphi_{id}(P_{vd} - X_{id}) \quad (1.15)$$

Em comparação com o modelo canônico e o modelo somente cognitivo, aplicados na otimização dos pesos de uma rede neural, o modelo somente social mostrou uma convergência mais rápida, até mesmo sobre o modelo canônico. Mas isto não pode ser afirmado, pois o mesmo pode não exibir um mesmo desempenho em outros tipos de problema.

### 1.2.3.3 Modelo “Selfless”

No modelo somente social, quando a posição do próprio indivíduo for a melhor em relação a vizinhança, pode ocorrer uma confusão do indivíduo em relação a auto-influência e a influência dos outros. Com o objetivo de tentar eliminar esta confusão, Kennedy (1997) apresentou o modelo “*Selfless*”, no qual o cálculo do melhor *fitness* na vizinhança exclui o próprio indivíduo do processo.

Este modelo apresentou uma convergência mais rápida, aplicados à otimização de pesos de uma rede neural, em relação ao modelo somente cognitivo, mas obteve um desempenho pior em relação aos modelos canônico e o modelo somente social.

A escolha do melhor modelo apresentado depende diretamente do problema no qual será aplicado, a dimensão dos dados de entrada, entre outras características.

## 1.3 Aplicações

Pesquisas na área de Inteligência de Enxames tiveram grande avanço nos últimos anos, fazendo com que as abordagens ACO e PSO fossem aplicadas em um grande número de problemas reais. Dorigo, Birattari e Stutzle (2006) destaca que ACO foi aplicado, na maioria, em problemas  $\mathcal{NP}$ -difícil. Problemas estes, onde os melhores algoritmos conhecidos garantem encontrar a solução ótima em tempo exponencial, sendo muitas vezes de impossível aplicação na prática.

Face a isto, algoritmos de inteligência de enxame surgem como uma alternativa promissora, podendo encontrar soluções de alta qualidade rapidamente.

Algoritmos ACO foram aplicados a problemas redes de telecomunicação, especificamente em roteamento (SIM; SUN, 2003); problemas de agendamento (SOCHA; SAMPELS; MANFRIN, 2003); bioinformática (SHMYGELSKA; HOOS, 2005); otimização de parâmetros de redes neurais (GONÇALVES; CAMARGO-BRUNETO, 2008b), entre outros.

O algoritmo PSO foi aplicado em diversos problemas complexos de várias áreas como problemas de engenharia nuclear (MEDEIROS, 2005); otimização de parâmetros de redes neurais (GONÇALVES; CAMARGO-BRUNETO, 2008a); otimização de funções (LIANG et al., 2006); mineração de dados (SOUSA; SILVA; NEVES, 2004).

Ambas abordagens podem ser combinadas entre si e/ou com outras técnicas formando sistemas híbridos eficientes.

## 1.4 Conclusão

Alguns sistemas encontrados na natureza impressionam pela capacidade de resolução de problemas complexos, mesmo tendo como atores agentes simples. Este comportamento, denominado de *inteligência coletiva*, é provido pelas interações sociais entre os próprios indivíduos e com o ambiente, e em conjunto formam um sistema auto-organizado complexo, apto a realizar tarefas complexas. O segredo destes sistemas está na capacidade de

comunicação e auto-organização que os permite saber quais são suas atividades por meio do conhecimento do que os outros estão fazendo.

Ferramentas computacionais foram desenvolvidas inspirando-se na interação social entre indivíduos, considerando os princípios da inteligência coletiva, sendo eles: *proximidade entre indivíduos, capacidade de avaliar seu comportamento, reagir a situações inesperadas, nem todas as variações ambientais afetam o comportamento do agente e capacidade de adequar ao ambiente*. Ferramentas essas que se mostraram bastante atrativas, através de bem sucedidas aplicações em problemas reais, embora ainda seja necessário um aprofundamento no seu embasamento teórico (LOPES, 2006).

## Referências

- COLORNI, A.; DORIGO, M.; MANIEZZO, V. Distributed optimization by ant colonies. In: *Proceedings European Conference on Artificial Life*. Paris, França: Elsevier, Amsterdam, 1992. p. 134–142. Disponível em: <<http://iridia.ulb.ac.be/~mdorigo/ACO%20-%20publications.html>>.
- DENEUBOURG, J.-L. et al. The self-organizing exploratory pattern of the argentine ant. *Journal of Insect Behavior*, v. 76, p. 159, 1990.
- DORIGO, M.; BIRATTARI, M.; STUTZLE, T. Ant colony optimization: Artificial ants as a computational intelligence technique. *Computational Intelligence Magazine, IEEE*, v. 1, n. 4, p. 28–39, 2006. Disponível em: <[http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=4129846](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4129846)>.
- DORIGO, M.; MANIEZZO, V.; COLORNI, A. Ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics-Part B*, v. 26, n. 1, p. 29–41, 1996.
- GONÇALVES, A. R.; CAMARGO-BRUNETO, M. A. de O. Aplicação de modelos computacionais evolutivos na otimização de parâmetros de uma rede neural multilayer perceptron treinada via backpropagation. In: *Aceito para: XVII Encontro Anual de Iniciação Científica*. Foz do Iguaçu, Paraná: [s.n.], 2008.
- GONÇALVES, A. R.; CAMARGO-BRUNETO, M. A. de O. Um novo modelo híbrido baseado em otimização por colônia de formigas e redes neurais para identificação de indivíduos com dpoc. In: *Aceito para: XI Congresso Brasileiro de Informática Aplicada a Saúde*. Campos do Jordão, São Paulo: [s.n.], 2008.
- KENNEDY, J. The particle swarm: social adaptation of knowledge. In: *IEEE International Conference on Evolutionary Computation*. [S.l.: s.n.], 1997. p. 303–308.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: *Proceedings IEEE International Conference on Neural Networks*. [s.n.], 1995. v. 4, p. 1942–1948. Disponível em: <<http://dx.doi.org/10.1109/ICNN.1995.488968>>.
- LIANG, J. J. et al. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions. *Evolutionary Computation, IEEE Transactions on*, v. 10, n. 3, p. 281–295, 2006.
- LOPES, H. S. *Fundamentos da Computação Evolucionária e Aplicações*. Bandeirantes, Paraná, 2006. 52-106 p.
- MEDEIROS, J. A. C. C. *Enxame de Partículas como ferramenta de Otimização em Problemas Complexos da Engenharia Nuclear*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2005.

- SHMYGELSKA, A.; HOOS, H. An ant colony optimisation algorithm for the 2d and 3d hydrophobic polar protein folding problem. *BMC Bioinformatics*, v. 6, n. 1, 2005. Disponível em: <<http://dx.doi.org/10.1186/1471-2105-6-30>>.
- SIM, K. M.; SUN, W. H. Ant colony optimization for routing and load-balancing: survey and new directions. *Systems, Man and Cybernetics, Part A, IEEE Transactions on*, v. 33, n. 5, p. 560–572, 2003.
- SOCHA, K.; SAMPELS, M.; MANFRIN, M. Ant algorithms for the university course timetabling problem with regard to the state-of-the-art. In: *In Proc. Third European Workshop on Evolutionary Computation in Combinatorial Optimization (EvoCOP 2003)*. [S.l.]: Springer Verlag, 2003. p. 334–345.
- SOUSA, T.; SILVA, A.; NEVES, A. Particle swarm based data mining algorithms for classification tasks. *Parallel Computing*, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 30, n. 5-6, p. 767–783, 2004.
- UTZLE, S.; HOOS, T. *Improvements on the ant system: Introducing MAXMIN ant system*. 1997. Disponível em: <<http://citeseer.ist.psu.edu/278024.html>>.
- WILSON, E. O. *Sociobiology: The New Synthesis*. Cambridge, MA: Harvard University Press, 1975.