

# Análise das Influências do Sistema Perceptual sobre a Evolução de Agentes Jogadores de Futebol de Robôs

Luiz Carlos Maia Jr.<sup>1</sup>, Reinaldo A. C. Bianchi

Faculdade de Engenharia Industrial – FEI – Departamento de Engenharia Elétrica  
Av. Humberto de A. C. Branco, 3972 09850-901  
São Bernardo do Campo – SP - Brasil

rbianchi@cci.fei.br

**Abstract.** *This article studies the influence of the two types of visual system allowed in the RoboCup F180 league in the evolution of robotic soccer players. The two perception approaches allowed in this category are: a global vision system, where the agent to have a complete perception of its environment; and the local vision, resulting in a partial perception. To do so, this work describes the agents that are capable of following a ball, which were implemented in a simulate system: agents with global vision and agents with local vision system. Based on the results it was possible to conclude that the complexity of agents with local vision were greatly increased in relation to global vision ones, but both agents achieved satisfactory performance.*

**Resumo.** *Este artigo analisa as influências dos dois tipos de sistema de visão computacional permitidos na liga F180 (pequenos robôs) da RoboCup na evolução de agentes jogadores de futebol robótico. Os dois modos possíveis de percepção nesta categoria são: a visão global, onde uma câmera é colocada sobre o campo de jogo; e a visão local, onde cada robô possui uma câmera embarcada. Para tanto, são descritos os agentes capazes de seguir uma bola que foram implementados em um ambiente simulado: agentes com visão global e agentes com visão local. Finalmente, são apresentados resultados que permitem concluir que a complexidade dos agentes com visão local sofreu aumento em relação a visão global, porém manteve a performance.*

## 1. Introdução

Partidas de futebol entre robôs, além de serem extremamente motivantes para possibilitar o surgimento de um espírito de ciência e tecnologia nas jovens gerações, constituem uma atividade que possibilita a realização de experimentos reais para o desenvolvimento e testes de robôs que apresentam comportamento inteligente e que cooperam entre si para a execução de uma tarefa, formando um time (Shen, 1998; Veloso et al., 1998).

Diversos pesquisadores têm estudado a utilização da Programação Genética para o desenvolvimento de agentes robóticos (Luke, 1998; Luke et al., 1998). A maioria destes


---

<sup>1</sup> Bolsista Fundação de Ciências Aplicadas – FCA/FEI

estudos envolve a evolução da coordenação entre os agentes, de novos comportamentos individuais, da maneira de gerar novos agentes, etc.

Baseado nestes trabalhos e objetivando a evolução de uma família de agentes robóticos que seja capaz de seguir uma bola em um campo simulado e que possa, futuramente, ser utilizada na construção de time de jogadores de futebol de robôs, este artigo estuda as influências dos dois tipos de sistema de visão computacional permitidos na liga F180 (pequenos robôs) da RoboCup na evolução de agentes jogadores de futebol robótico.

Os dois modos possíveis de percepção nesta categoria são a visão global, onde uma câmera é colocada sobre o campo de jogo permitindo ao agente ter uma visão completa do seu ambiente e a visão local, onde cada robô possui uma câmera embarcada resultando em uma visão parcial da área de jogo. A figura 1 mostra imagens adquiridas destas duas maneiras.



**Figura 1. Imagens de sistemas de visão Global x Local.**

O funcionamento de um time que utiliza visão global segue uma fórmula básica: realiza a aquisição da imagem por meio de uma única câmera localizada sobre o campo; processa a imagem usando técnicas de Visão Computacional para descobrir a posição de todos os robôs e da bola. Com esta imagem, um sistema de decisão define a melhor tática a ser aplicada e os movimentos instantâneos de cada robô. Já um time que utiliza visão local deve extrair dados da imagem localmente, para depois definir a tática de cada jogador.

Na próxima seção é apresentada de forma sucinta características básicas da Programação Genética. A seção 3 descreve o agente seguidor de bola com visão global e a seção 4 o agente com visão local. Os resultados são apresentados na seção 5 e a última seção apresenta as conclusões deste trabalho.

## **2. Programação Genética**

De acordo com a Teoria da Evolução de Darwin, os organismos mais adaptados ao mundo em que vivem são os que terão maiores chances de sobrevivência. Os organismos que existem hoje são consequência da evolução de outros organismos inferiores que se extinguiram e que sem eles, provavelmente, não existiriam. Cada criatura nessa cadeia é o produto de uma série de “acidentes” que têm acontecido continuamente sobre a pressão seletiva do ambiente.

Programação Genética (Koza, 1992) é uma forma de computação baseada em simulação de evolução de indivíduos. Nela é aproveitado o fato de que a evolução na natureza é

criativa, pois produz muitas vezes resultados inesperados, impensáveis e não-lineares, diferente do modo de programação usual. Algumas características importantes da Programação Genética são descritas a seguir.

Em PG o indivíduo que deve ser evoluído é um programa de computador definido como uma árvore de funções e terminais, que constituem suas características e define o comportamento no ambiente para o qual foi desenvolvido. Cada função é um ramo da árvore e cada terminal uma folha do indivíduo. Funções podem ser condições, sensores, operações aritméticas ou lógicas etc. e são usadas para captar informações sobre o ambiente e, convenientemente, para melhorar o desempenho de cada indivíduo. Já os terminais geralmente representam as ações que os robôs podem executar, como andar para frente, virar etc. Uma população contém um determinado número de indivíduos que é renovada a cada iteração, criando uma nova geração.

*Fitness* é um parâmetro que mede o “encaixe” da espécie em seu ambiente, sendo usado para descartar, a cada iteração, os piores indivíduos. Existem várias definições para *fitness*, sendo aqui utilizada a seguinte: “Quanto maior o *fitness* do indivíduo maior sua probabilidade de sobrevivência e adaptação ao ambiente”. Com este dado calculado, os indivíduos podem ser organizados de forma descendente, sendo então eliminados os piores e mantidos os melhores para serem reproduzidos ou cruzados.

A criação de uma nova geração pode ser feita de três maneiras distintas: a Reprodução, onde os melhores indivíduos da geração atual são simplesmente copiados para a nova geração, com o objetivo de não se descartar os melhores indivíduos; o Cruzamento, onde são escolhidos dois indivíduos (pais) bem adaptados, dos quais são criados dois descendentes que vão estar na próxima geração – o objetivo é um novo indivíduo seja criado usando o que há de melhor de uma geração, com alguma variação; finalmente, na Mutação um indivíduo é selecionado, depois um ponto de mutação, e a partir dele é criado um novo ramo – o objetivo é melhorar um indivíduo, mas com isso ele pode perder desempenho e ser eliminado.

### **3. Agente Seguidor de Bola com visão global**

O agente Seguidor de Bola foi escolhido para ser o primeiro passo da evolução dos agentes jogadores de futebol, pois é similar ao clássico “Seguidor de Paredes” (Koza, 1992), adicionando elementos simples como a bola e obstáculos. Por possuir visão global, qualquer indivíduo desta família sabe a cada momento onde se encontra a bola e ele próprio.

O objetivo dos indivíduos na simulação é alcançar a bola e tocá-la o maior número de vezes em um número determinado de passos. É considerado um passo cada vez que o robô executar um terminal (agir) e o indivíduo deve percorrer a sala buscando pela bola em no máximo 2000 passos. Esse número de passos foi definido para tornar a representação final mais clara, pois o excesso de caminhos em uma figura poderia torná-la ilegível. A cada simulação a posição da bola e a posição e orientação do agente são iniciadas aleatoriamente.

O *fitness* foi calculado através da seguinte fórmula:

$$\text{fitness} = \text{hits} * k - \sum(n / Dini)$$

Onde *hits* é o número de vezes que o agente atingiu a bola; *n* é o número de passos do agente e *Dini* é a distância inicial medida antes do agente se movimentar. O valor  $n/Dini$  (chamado de penalização) é recalculado a cada vez que o robô atinge a bola, por isso é usada a somatória desses valores no *fitness*; 'k' é uma constante a ser definida em cada caso e cuja variação é analisada nos resultados. O número de *hits* máximo é estimado em 15 com base na área de movimentação, no número de execuções e na distância máxima que a bola pode estar do robô.

Além das funções de desvio de paredes e das ações de movimentação (andar para frente, virar), que são similares a do agente seguidor de paredes, adicionou-se apenas uma ação que relaciona a movimentação do robô com a movimentação da bola. As funções definidas são:

- PROGN3(3): executa três ramos em seqüência;
- PROGN2 (2): executa dois ramos em seqüência;
- IFWALL (I): executa seu ramo esquerdo se não for detectada parede pelo robô (a no máximo 1 passo de distância) e caso contrário executa seu ramo direito.

Os terminais (ações) definidos são:

- WALKFRONT (F): faz robô dar um passo à frente;
- WALKBACK (B): faz robô dar um passo para trás;
- RIGHT (R): faz robô virar à direita;
- LEFT (L): faz robô virar à esquerda;
- ALIGN (A): direciona o robô para a bola.

Outros parâmetros usados na simulação incluem: População (M) = 500; Probabilidade de Cruzamento = 70%; Probabilidade de Reprodução = 30%; Matriz de simulação = 200 x 200, com o posicionamento do robô em números reais; Limite de complexidade (no sorteio) = 1000; Ângulo de virada = 5° (permite bastante precisão na movimentação buscando a bola); Número de execuções por indivíduo = 1.

#### **4. Agente seguidor de bola com visão local**

Esta segunda família de agentes tem por objetivo, como no caso anterior, alcançar a bola e tocá-la o maior número de vezes possíveis dentro de seu tempo de execução. Os indivíduos criados nesta família são mais complexos, pois além dos obstáculos e da bola, o agente possui uma visão limitada e não sabe as condições de todo o ambiente (como acontecia na visão global). Sendo assim, deve estar preparado para uma situação na qual não vai enxergar a bola e terá que encontrá-la antes de poder tocá-la. O agente precisa buscar a bola da maneira mais rápida e desviando dos obstáculos que atrapalham sua visão.

Para simular a visão local de uma câmera sobre um robô móvel, foi adicionada ao sistema uma função que fornece ao agente a informação sobre a visibilidade da bola. Essa função retorna verdadeira se a bola estiver em frente ao agente (com um ângulo de visão de 30° para cada lado) e falsa caso contrário. A figura 2 mostra o campo visual de um agente com visão local.

O *fitness* nesta simulação foi calculado da mesma forma que na simulação anterior, visto que o objetivo da evolução é o mesmo (tocar a bola), apenas adicionando dificuldade na

localização da bola. As funções e ações definidas para esta simulação também são iguais as do agente com visão global, apenas com a adição da função IFBALL:

- IFBALL (C): executa o ramo esquerdo se enxergar bola e caso contrário executa o ramo direito.

Os terminais definidos são os mesmos do agente com visão global, apenas com uma diferença na função ALIGN, que só direciona o robô para a bola se ela estiver dentro do campo de visão do agente.




Figura 2. Campo visual de um agente com visão local.

Os outros parâmetros da simulação (população, probabilidades, etc.) são exatamente iguais ao da visão global. Os agentes também são iniciados em posições aleatórias e o ambiente de simulação (paredes e obstáculos) continua igual.

## 5. Resultados

Esta seção apresenta e compara três tipos de resultados para os dois agentes: os gráficos evolutivos, exemplos de caminhos percorridos e os melhores indivíduos gerados. Para a obtenção destes resultados foi criado um ambiente de simulação para o ambiente Linux onde os robôs se movimentam livremente, respeitando apenas os limites das paredes e de obstáculos. Também foi criada uma família de robôs que, inicialmente, teve o objetivo de seguir paredes – um problema tradicional da área de Programação Genética – e que foi aperfeiçoada para seguir uma bola (Maia & Bianchi, 2000).

Neste ambiente, o simulador atualiza a posição do robô e da bola a cada iteração. A cada vez que o robô toca a bola, ela é “chutada” para a direção na qual o robô se deslocava, com uma velocidade aleatória maior que a do robô. Este laço é repetido para cada indivíduo de uma geração até que um número máximo de iterações seja atingido. Ao final da execução de todos os indivíduos, é feita a avaliação de todos e a criação da nova geração, com base nos dados já descritos.

### 5.1. Gráficos Evolutivos

O primeiro gráfico (figura 3) apresenta a evolução dos agentes com visão global, por meio de quatro seqüências. As duas mais altas mostram o resultado do *fitness* do melhor agente de cada geração, com a evolução usando  $k = 1500$  (a mais alta) e  $k = 1000$  (a

segunda mais alta). As duas seqüências mais baixas apresentam o *fitness* médio para cada geração, com  $k = 1500$  (a terceira) e  $k = 1000$  (a mais baixa).

A primeira observação que se pode fazer é que ocorre uma grande variação do *fitness* do melhor indivíduo (que não acontece em casos simples como o seguidor de paredes). Isso se deve ao fato do agente interagir com outro objeto que também se movimenta, que é mais rápido do que ele e que reflete em outros objetos.

Podemos comparar também os resultados com  $k = 1500$  e  $k = 1000$ . O valor  $k = 1000$  fez com que a somatória das penalizações dos indivíduos tivesse maior significância no *fitness* e com isso selecionou melhor aqueles que deveriam continuar, ocasionando uma variação menor nos melhores indivíduos. Já a utilização de  $k = 1500$  aumentou a velocidade da evolução dos agentes (tanto os melhores quanto a média).




Figura 3. Gráfico evolutivo para agentes com visão global (50 gerações).

O segundo gráfico (figura 4) apresenta a evolução dos agentes com visão local, por meio de duas seqüências. A mais alta mostra o resultado do *fitness* do melhor agente de cada geração, com a evolução usando  $k = 1500$ . A mais baixa apresenta o *fitness* médio para cada geração também com  $k = 1500$ . Neste gráfico, como já havia sido notado na simulação anterior, também existe uma grande variação no desempenho do melhor agente. Mais uma vez isso se deve à grande gama de possibilidades em que o ambiente pode se apresentar para o agente, antes que ele comece a buscar pela bola.

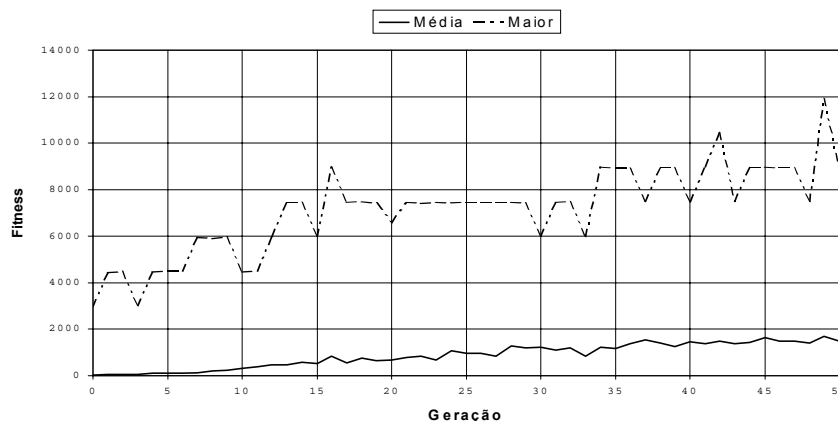
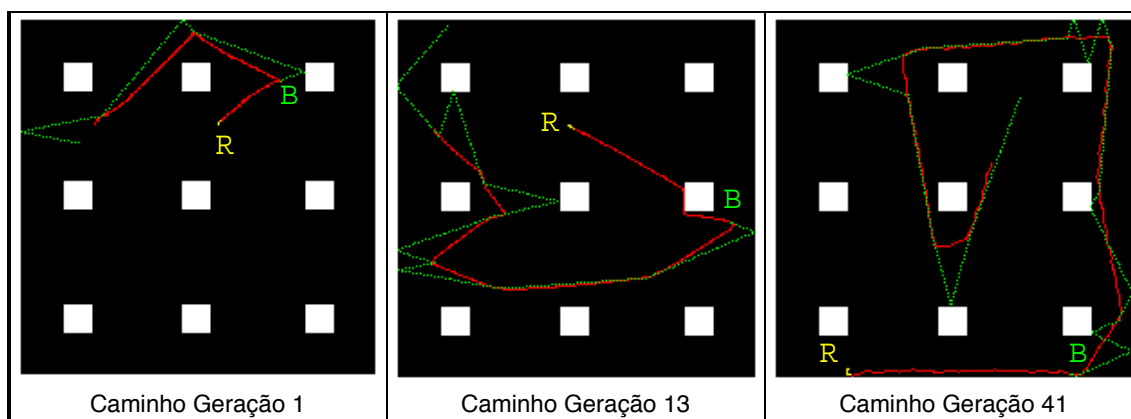


Figura 4. Gráfico evolutivo para agentes com visão local (50 gerações).

Um ponto marcante que pode ser percebido nessas simulações e que as diferenciam de outros sistemas usados geralmente em sistemas de PG é o baixo valor da média dos indivíduos, que nem chega a alcançar o desempenho do melhor indivíduo da primeira geração. Isso se deve principalmente ao alto grau de dificuldade dessa simulação. Mas como se trata de uma evolução espelhada na natureza, o que se espera é que se esses mesmos agentes fossem deixados evoluindo durante mais tempo, os melhores deveriam estabilizar-se em um valor próximo ao ótimo e a média não deveria ficar muito longe disso.

## 5.2. Exemplos de Caminhos

A figura 5 apresenta caminhos extraídos da simulação de agentes com visão global, com  $k$  valendo 1500. Os quadrados brancos são obstáculos para o indivíduo e para a bola. O caminho feito pelo agente é representado pela cor vermelha (com o R amarelo marcando o início do caminho) e a cor verde mostra o caminho da bola (B no início). Vale ressaltar que a escolha dos exemplos de caminhos apresentados priorizou aqueles que exemplifiquem o desenvolvimento e sejam de fácil entendimento.



**Figura 5. Caminhos para agentes com visão global.**

Esses caminhos mostram o funcionamento dos melhores agentes de cada geração, destacando aspectos da evolução. Pode-se notar que o indivíduo da primeira geração toca poucas vezes na bola, mas já a persegue, além de não ter problemas com os obstáculos, pois ele é uma evolução de um agente que sabe seguir e desviar de paredes. Na décima terceira geração, o indivíduo já persegue bem a bola. Ele inicia a busca pela bola com um obstáculo entre sua posição e seu destino e utiliza suas funções e treinamento para desviar-se. Neste caso é importante ressaltar que a visão global favoreceu a resolução. Finalmente, na geração número 41, o indivíduo consegue por várias vezes atingir a bola, já que o *fitness* o estimula a fazer isso. Nota-se também que este indivíduo não perde tempo ao seguir a bola e sempre tenta a melhor trajetória.

A figura 6 apresenta caminhos extraídos da simulação de agentes com visão local, com  $k$  valendo 1500. Novamente, os quadrados brancos são obstáculos para o indivíduo e para a bola, o caminho feito pelo agente é representado pela cor vermelha (com o R amarelo marcando o início do caminho) e a cor verde mostra o caminho da bola (B no início).





### 5.3. Exemplos dos melhores indivíduos

Na figura 7 é mostrado o melhor indivíduo com visão global enquanto a figura 8 apresenta um dos melhores indivíduos com visão local. Como o indivíduo é uma árvore, abaixo é apresentada uma travessia desta árvore que também é usada para guardar os agentes ao término da evolução. Cada letra representa uma função ou um terminal da árvore: PROG3 = 3; PROG2 = 2; IFWALL = I; WALKFRONT = F; WALKBACK = B; RIGHT = R; LEFT = L; ALIGN = A.

```
3IIR2FF323I2ILIB32R3FRRR22L3RAF2BRFR323I2ILIBILLIAAIR32F2IF3FFRFFF33RB2RRF33
FFRILI23I2IRIB32R3FR32AR32F2IIAL2FRFAF22IALF2BRR22L3RF2IBF323IFIRR33RBII3FBB
IRAFF33FF22F2IIAL3F3RRFRFIRAI232FRR2B2BR33FBIRF3L2RF3FFR2RBA2BIR32FRFBAI
RFII333F2LFFFRBAI2IBIIAL3FF3FFR3FFRAFL2BRFR323I2ILIB33BIAR22FF3A2IIAL3FFRLF
F2FRIAAIR32F2IF3FFRFFF33RF2RRF33FFRILR2BIR32FR3FFRBFLII3FLBIRAF33FFRL32FR
R2FIBFAIRF32RIIFRIFF33AIL3A2FFFLLFR2BIR32FR2FRBAIRFII3FBBIRFF33FFRL3AR2FIB
FAIRFII3L3FA3AILIFRFFFIRAFRLF
```

Figura 7. Exemplo de agente com visão global.

```
3F33FCA32LLACI23FRBFBIIFL3I232FIICAF22BIIRRLBR3CA23FLII2F2BLIBIL2IILR2BAF3I2
32FIBR3CA23FLIICA32LL2I3B2IBCARR2LFRBCAIIIFL3I232FIICAF22BIIR3RCA3R3ICARIR2
BIBCAIRFI23FCACA3FBBRRFALRLBR3CA23FLII2F2BLIBIL2IILR2BCARFIL22LBIL223CAI
FB3IRBFBLL3FB2I33LILRBFL2IIR2CA3R2FIICBB3LL2LBCAR32B2LLLFCAR3FRLLRF223L2
FRRCABLCAICAFFFBILCA2I3L3FFR3B33FLFBLBLBRLIRIL2IILR2BCARFIL22L222IFB23FC
ALB2LRR2F3RIF2RLI323BRRFL23CACACAF2BI3F2RBB3BRFLLI3LCA3FIR3233FFF3B2ILR
FBCA2B322LRLRLACAR3BBCA3R333ILRLFBBIIR3IILB23BFFBLLRIR23CAFBB3FB2IC
A2FFCALRF223L2FRRBLCAICAFFFBILCA2I3L3FFR3BRLLRFL22L3IB3CAFLBFLFBILC
A2I3L3FF2I32B3RCF3FB232I33CF2BR3B2RIBRRFIFBBLI3IB2LFILBFLB3RIR33RIBCA3CA
32FBR2LCALBR2I2BLILBCA3RBB3CA2I2LR3CARRLLRLRI23IR23LBCAI2L3LL2I22CAR3FI
3ICALII32B3R3CAF2BI2LCA3FRII3I2F3RLRICA2BCAIIICA2IRBCAF3B2CABB3RABLLFR
LRLBRRBFLBRFRFFBLBRFBRRBFCALBLLRFLBCAB
```

Figura 8. Exemplo de agente com visão local.

A tabela 1 apresenta uma comparação entre o *fitness* e os pontos de complexidade dos melhores agentes de cada tipo. Pode-se perceber que a complexidade dos agentes com visão local sofreu um grande aumento, já que esta tarefa é mais complexa e exigiu uma maior elaboração dos indivíduos. Quanto ao *fitness*, por já saber onde se encontra a bola, o agente com visão global apresenta um melhor resultado.

	<i>Fitness médio</i> (Melhores agentes de cada simulação)	<i>Complexidade média</i> (melhores agentes)
<b>Visão global</b>	16433	535
<b>Visão local</b>	8447	1479

Tabela 1. Comparação entre *fitness* e complexidade dos agentes.

## 6. Conclusão

A partir dos resultados obtidos, conclui-se que, usando Programação Genética é possível criar indivíduos que apresentam os comportamentos básicos para atuar no domínio do Futebol de Robôs, como seguir paredes e bolas, tanto utilizando um sistema perceptual baseado em visão global quanto um baseado em visão local.

Verificou-se que a medida que a complexidade da tarefa exigida pelo ambiente se torna maior, aumenta também a média da complexidade dos indivíduos que são capazes de realizar as tarefas corretamente. Assim, a complexidade dos agentes com visão local é aproximadamente três vezes maior que a dos agentes com visão global – uma vez que a tarefa mais complexa exigiu uma maior elaboração dos indivíduos.

Uma tarefa mais complexa também aumenta o gasto computacional: por exemplo, para serem geradas 50 gerações de um agente que apenas siga uma parede, o tempo médio de execução do programa é de 30 minutos; já o agente seguidor de bola com visão global leva 50 minutos e o seguidor de bola com visão local 1:40 h (todos no mesmo computador, modelo Celeron com S.O. Linux).

Quanto ao *fitness*, os agentes com visão global apresentam um melhor resultado – fato esperado, já que não precisam procurar a bola. Entretanto, apesar do *fitness* dos agentes com sistema de visão local ser menor, a performance dos dois tipos de agentes foi satisfatória.

Entre os possíveis trabalhos futuros em estudo encontram-se a comparação do uso de visão local x global para outros comportamentos como: goleiro, defesa, ataque, etc.; verificar a relação entre a função de *fitness* utilizada e a evolução destes mesmos agentes; a inserção de comunicação entre os agentes para a formação de times; a implementação destes agentes no Simulador Oficial da RoboCup; e, finalmente, a utilização dos melhores agentes gerados como módulos de controle de robôs reais.

## Referências Bibliográficas

- KOZA, J. Genetic programming: on the programming of computers by means of natural selection. Cambridge, MA, MIT Press, 1992.
- LUKE, S. 1998. Evolving soccerbots: a retrospective. In Proceedings of 12th Annual Conference of the Japanese Society for Artificial Intelligence (**JSAI**).
- LUKE, S.; HOHN, C.; FARRIS, J.; JACKSON, G; HENDLER, J. 1998. Co-evolving Soccer Softbot Team Coordination with Genetic Programming. In **RoboCup-97: Robot Soccer World Cup I** (Lecture Notes in Artificial Intelligence No. 1395), H. Kitano, ed. Berlin: Springer-Verlag. 398-411.
- MAIA, L.; BIANCHI, R. A C. Evoluindo Agentes Jogadores de Futebol. In: **WORKCOMP'2000**, 3, São José dos Campos, 2000. *Proceedings*. CTA/ITA, pp. 113 - 119, 2000.
- SHEN, W. et al. Integrated Reactive Soccer Agents. In: **ROBOCUP WORKSHOP**, 2, Paris, 1998. *Proceedings*. FIRA, pp. 251-264, 1998.
- VELOSO, M.; STONE, P.; HAN, K. The CMUnited-97 Robotic Soccer Team: Perception and Multiagent Control. In: **INTERNATIONAL CONFERENCE ON AUTONOMOUS AGENTS**, 2, Minneapolis, 1998. *Proceedings*. AAAI, 1998.