

Bahia2D 2010: Team Description Paper

Bruno Silva, Marco Simões, Diego Frias e Josemar Souza

Núcleo de Arquitetura de Computadores e Sistemas Operacionais

Universidade do Estado da Bahia (UNEB), Salvador, Bahia, Brasil

Emails: patucaog@gmail.com, msimoes@uneb.br, diegofriass@gmail.com, josemar@uneb.br

Resumo—O Bahia2D é um time brasileiro iniciado em 2006 e que participou três vezes da Robocup Mundial. Este artigo descreve os desenvolvimentos recentes da equipe: um modelo para predição da chance de sucesso de passes e a criação da infraestrutura necessária para realizar experimentos. Descrevemos também os primeiros resultados obtidos e as direções futuras.

I. INTRODUÇÃO

O time do Bahia2D é desenvolvido pelo Núcleo de Arquitetura de Computadores e Sistemas Operacionais (ACSO), dentro da linha de pesquisa em Robótica Inteligente, cujos objetivos são pesquisar, analisar e desenvolver soluções de robótica inteligente utilizando sistemas multiagentes autônomos e técnicas de inteligência artificial. Mais especificamente, ele é um dos três times que compõe o projeto Bahia Robotics Team (BRT), que busca alcançar os objetivos delineados acima, através da pesquisa com futebol de robôs, alinhando-se de modo cooperativo com a RoboCup International Research Initiative. Atualmente, o grupo também desenvolve equipes para a liga simulada 3D e para a Mixed Reality. O Bahia2D, primeiro dos três a ser desenvolvido, foi iniciado no segundo semestre de 2006, tendo participado da Robocup mundial de 2007 em Atlanta, de 2009 em Graz e de 2010 em Cingapura.

Desde o início do projeto, nosso time utiliza o conhecimento [1] e o código base providos pelo UvA Trilearn¹. Nosso esforço inicial foi desenvolver a camada de habilidades do agente base através de redes neurais, e principalmente, lógica fuzzy[2]. Para detalhes sobre os desenvolvimentos desta fase inicial, o leitor deve referir-se a [3], [4] e [5]. Em 2009, o grupo focou-se na tentativa de desenvolver um framework genérico para agentes jogadores de futebol, que atendessem as três categorias que participamos, porém, identificou-se a necessidade, após 4 meses de projeto, de um maior amadurecimento nos 3 ambientes devido a complexidade envolvida na criação de um framework. Este evento inicia a fase atual do time, focado na busca do entendimento e análise do ambiente, e no desenvolvimento de modelos que descrevam o comportamento do mundo e que possam ser utilizados pelos agentes no processo de tomada de decisão, assim como a infraestrutura necessária para realizar experimentos rigorosos sobre o ambiente. A partir desses estudos, pretendemos desenvolver uma nova arquitetura para nosso agente, que substitua a já envelhecida estrutura atual. As próximas sessões, irão detalhar

¹Copyright (c) 2000-2003, Jelle Kok, University of Amsterdam. All rights reserved.

a primeira etapa deste processo: desde a criação da infraestrutura para realizar experimentos, até os primeiros estudos sobre um modelo para o passe, além dos resultados da utilização desse modelo no apoio a tomada de decisão de nosso agente.

II. ANÁLISE DO PASSE

O domínio da habilidade de passar a bola é fundamental para o bom desempenho de um time de futebol, sendo esta habilidade, juntamente com o posicionamento, a base para execução de jogadas ofensivas e manutenção da posse de bola. Insatisfeitos com a qualidade atual do passe em nosso agente, escolhemos essa habilidade para ser o foco do nosso estudo.

Essencialmente, um passe é a passagem da bola em posse do agente A, para um ponto no campo em que um companheiro B possa recapturá-la em melhores condições para alcançar as metas atuais do time. Obviamente, é essencial evitar que um adversário capture a bola durante esse deslocamento. Resolvemos então criar um modelo que previsse a chance de captura da bola por um jogador, dada uma trajetória de A para B que a bola precisa cumprir, nos permitindo avaliar os riscos envolvidos num passe. A identificação de elementos modulares de baixa granularidade como este, traz a vantagem de permitir a reutilização de análise, projeto, código e experimentações. Este modelo pode ser reutilizado por exemplo, para avaliar a possibilidade de fazer um gol e para estabelecer estratégias de marcação.

A. Modelo de interceptação da bola

Para o modelo ser compreendido, cabe ressaltar algumas características relevantes do ambiente. Primeiro, o passo de tempo do ambiente é discreto. Isso nos leva a uma situação onde a bola não precisa passar por todos os pontos da trajetória para chegar ao destino, podendo até mesmo saltar um jogador, tornando impossível a este capturar a bola ainda que esteja posicionado sobre sua trajetória. Segundo, é preciso identificar os jogadores que potencialmente podem capturar a bola, dada sua velocidade inicial, antes desta alcançar seu destino. Esta limitação é dada pela posição, orientação e velocidade inicial do interceptador, e de seus limites físicos, como sua velocidade máxima real alcançada, capacidade de girar o corpo, aceleração e área chutável. Por simplificação, nosso modelo atual considera que o interceptador parte de uma posição onde está parado e pode se mover a sua velocidade máxima para qualquer direção, numa distribuição probabilística uniforme,

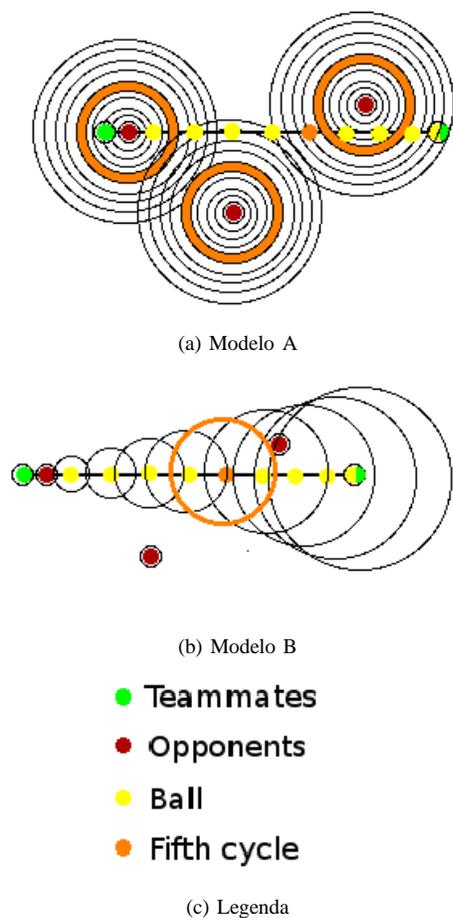


Figura 1: Os dois modelos representando a mesma situação

gerando uma região circular onde possui chances de capturar a bola.

Estas características nos fez primeiramente desenvolver um modelo que acompanha a cada ciclo as possibilidades de deslocamento da bola, e as possibilidades de movimento dos interceptadores (com as simplificações citadas acima), identificando que existe alguma chance de captura da bola quando o círculo que informa onde o jogador pode estar no ciclo t , sobrepõe o ponto onde a bola se encontra no mesmo ciclo. A situação pode ser visualizada na figura 1a.

Como atualmente nós não possuímos informações sobre os heterogêneos dos adversários, utilizamos os piores casos para o cálculo da previsão. Isso faz com que todos sejam considerados tendo a mesma velocidade e área chutável, e conseqüentemente todos os círculos de movimento de interceptadores comecem com o mesmo tamanho e cresçam na mesma velocidade. Essa simplificação nos permite abstrair o modelo acima, para outro onde utilizamos apenas um círculo centralizado na bola, ao invés de um círculo para cada interceptador. Neste caso, a chance de captura existe quando o círculo em volta da bola num ciclo t , sobrepõe o ponto onde o adversário se encontrava no ciclo inicial. Esta abordagem permite identificar a área onde os adversários

devem estar no momento inicial do passe para que haja chance de interceptação, além de centralizar o controle. Esta nova situação pode ser visualizada na figura 1b.

Identificada a chance de interceptação, é necessário identificar quanto a probabilidade de sucesso de um passe é afetada por essa possibilidade pontual. Por último, devemos considerar as incertezas existentes no ambiente para que o modelo esteja completo, como imprecisão do movimento da bola, da direção do chute, das informações recebidas, além do uso de informações desatualizadas para tomada de decisão.

Utilizamos, porém, para avaliação do modelo, o técnico offline, que devido ao seu modelo de mundo mais preciso nos permite eliminar praticamente todos os fatores de incerteza existentes. Apenas a imprecisão do movimento da bola não pôde ser descartada. Como ela ainda não é levada em conta no modelo descrito acima, existe um pouco de ruído nos resultados. Apesar da avaliação dispensar as incertezas, o uso do modelo durante os jogos pelo time irá precisar de tratamento específico para incertezas, o que está em desenvolvimento.

III. PLANEJANDO OS EXPERIMENTOS

A. Infraestrutura do técnico offline

Para avaliar corretamente o modelo probabilístico um método de experimentação automático e tão reutilizável quanto possível é desejável. Como criar uma estrutura reutilizável é um desafio de engenharia de software, adotamos um modelo de desenvolvimento incremental, focando neste momento, apenas no requisito dos experimentos de passe. Isto permitiu uma implementação inicial mais rápida e um melhor entendimento dos requisitos, que irão ajudar futuramente a criar uma solução mais geral.

Nesta implementação, o experimento representa uma dada situação num jogo, por exemplo, um escanteio com três companheiros na área do oponente. Cada experimento tem um tipo e uma quantidade de amostras, cada amostra é formada por dados a respeito dos objetos envolvidos, suas posições e formação inicial, além de métodos de análise e geração de resultados (saída). O experimento em si, depois de feitas todas as amostras, calcula as estatísticas obtidas a partir de sua execução.

Os experimentos são gerenciados pelo componente LabManager, que controla todas os experimentos pendentes e garante que se ele for interrompido pelo fim de uma partida ou condições adversas os experimentos pendentes serão reiniciados na próxima execução.

B. Experimentos realizados

Para avaliação do modelo fizemos dois tipos de experimentos. O primeiro, um experimento controlado, consistiu em recriar, utilizando a infra-estrutura descrita na seção III-A, situações de passe que fossem representativas do conjunto de possíveis passes em uma partida, executá-las de modo controlado e repetí-las exaustivamente de modo a obter um resultado estatisticamente válido.

O objetivo desse experimento foi coletar dados que permitissem avaliar e refinar o poder de previsão do modelo, através

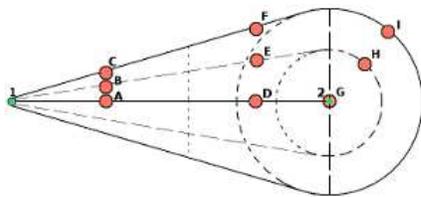


Figura 2: Posições possíveis dos oponentes nos experimentos, dado um passe do ponto 1 para o ponto 2

da comparação entre a previsão de sucesso de passe que ele calcula e os resultados obtidos na simulação para um mesmo caso de teste. A variável dependente desse experimento é o percentual de sucesso do passe obtido em uma dada situação simulada. As variáveis independentes são as posições dos oponentes e a qualidade do time adversário. Foram controladas a quantidade de oponentes com chance de interceptação(1), a distância (18 metros), a velocidade inicial (2.5 ms/ciclo) e a direção do passe(máximo de 3 graus de erro).

As posições dos agentes em um experimento são determinados por um envelope que recobre os círculos gerados a partir da posição da bola a cada ciclo (círculos em preto que aparecem na figura 1b). Dentro do envelope, foram definidas as posições perto, médio e longe, tanto para o eixo horizontal quanto vertical. As nove posições vistas na figura 2, nomeadas de A a I foram geradas a partir destas definições.

Neste tipo de experimento o reposicionamento instantâneo do jogador pelo técnico é intrusivo, no sentido que pode afetar as crenças do agente em seu modelo de mundo. Para reduzir o efeito deste distúrbio foram tomadas algumas precauções, como paralisar todos os agentes no local de destino por alguns ciclos, de modo que ele pudesse atualizar parcialmente seu modelo de mundo, tornando o experimento mais similar a uma situação de jogo.

O critério para definir a variável independente qualidade foi o desempenho geral dos times em Robocup anteriores. Nós selecionamos o WrightEagle e o KickOffTug, em suas versões utilizadas no China Exercise 2009 e o PET-Soccer, em sua versão utilizada no Brasil Open de 2008. A combinação das variáveis independentes geraram a soma de 27 casos, com cada caso sendo repetido 1000 vezes. Os resultados são discutidos na seção IV.

O segundo tipo de experimento é um experimento natural, que busca avaliar o impacto do uso do modelo em jogo sobre os resultados finais das partidas. Foi usado como grupo de controle nosso time atual sem o uso do modelo, e como grupo experimental o nosso time usando o modelo. Foram repetidas 50 partidas contra as mesmas versões do Wright Eagle e do PetSoccer usadas nos experimento controlados. Os resultados também estão resumidos na seção IV.

IV. RESULTADOS DOS EXPERIMENTOS DE PASSE

Baseados nos resultados obtidos nos experimentos controlados, apresentados na tabela I, nós podemos afirmar que o modelo criado foi em média, mais conservativo que a realidade capturada pelos experimentos, mas que por outro

Set ¹	Taxa de sucesso predita pelo modelo	Taxa de sucesso real contra oponentes selecionados		
		WrightEagle	PET-Soccer	KickOffTug
A	0.162	0.270	0.143	0.530
B	0.256	0.396	0.492	0.517
C	0.695	0.623	0.947	0.765
D	0.042	0.009	0.109	0.242
E	0.285	0.301	0.450	0.817
F	0.549	0.816	0.939	0.992
G	0.000	0.328	0.222	0.091
H	0.559	0.834	0.755	0.588
I	0.793	0.987	0.964	0.989

¹Set representa a posição do adversário, de acordo com a figura 2.

Tabela I: Média de passes com sucesso em experimentos controlados, baseada em 1000 repetições de cada Set

Adversário	PetSoccer		WrightEagle	
	Controle	Experimental	Controle	Experimental
Vitórias	9	7	0	0
Empates	1	3	0	0
Derrotas	40	40	50	50
Gols pró	52	61	2	0
Gols contra	124	155	836	871
Saldo de gols	-72	-94	-834	-871

Tabela II: Resultados da utilização do modelo em jogos normais, sem nenhuma interferência do técnico offline

lado, os resultados mostraram também uma relação de coerência entre os valores do modelo e dos casos experimentais. Destes resultados pudemos também entender a importância de adicionar adaptabilidade ao modelo a depender da qualidade da interceptação do adversário em questão, dada a grande variação da capacidade de interceptar a bola de oponentes diferentes em algumas situações.

Já a tabela II, resume os resultados obtidos no segundo tipo de experimento, as simulações de partidas completas e sem interferências do técnico offline. Apesar de sabermos que o modelo ainda precisava de ajustes, os resultados em questão nos surpreenderam negativamente dada a leve piora no desempenho global do time.

A. Avaliando o modelo probabilístico

Para cada caso experimental nós computamos a probabilidade de sucesso P_s usando o modelo e gravamos o resultado da amostra, como *TRUE* se a bola não fosse interceptada e *FALSE* quando contrário. Nós definimos duas classes P_s : classe Theoretical True, quando P_s excedia o valor $P_{min} = 0.65$ (sets C e I) e a classe Theoretical False quando P_s era menor que $P_{max} = 0.35$ (sets A, B, D, E e G), de modo que $P_{min} \geq P_{max}$ ². Nós definimos então um critério de qualidade Q dado pela razão entre boas previsões e previsões ruins, que é $Q = N_{good}/N_{wrong}$.

²Note que os sets F e H não são usados para avaliar o modelo por se encontrarem em uma zona nebulosa

Neste caso, N_{good} contabiliza as amostras que têm resultado TRUE em um experimento Theoretical True somados as amostras que têm resultado FALSE em um experimento Theoretical False: $N_{good} = TheoreticalTrue(TRUE) + TheoreticalFalse(FALSE)$. Já N_{wrong} contabiliza as amostras que têm resultado aposto a classe Theoretical ao qual o experimento pertence: $N_{wrong} = TheoreticalTrue(FALSE) + TheoreticalFalse(TRUE)$. Na situação hipotética do modelo criado ser estocástico, o valor de Q será próximo de 1, porque o modelo não reflete a probabilidade de sucesso de modo algum. Quanto mais Q esteja acima de 1 maior a precisão do modelo, o que nos permite escolher parâmetros otimizados para ele, em particular o valor de s_* e v_a . De acordo com os resultados apresentados na tabela I e os critérios acima, calculamos o valor de Q para o modelo atual:

$$Q = N_{good}/N_{wrong}$$

logo, $Q = (5272 + 10083)/(4917 + 725) = 2.72$.

Nós consideramos estes resultados como bons para uma primeira abordagem, apesar da quantidade elevada de resultados TRUE para experimentos Theoretical False. Isto nos permite concluir que o valor de s_* atual gera um modelo conservativo, e precisa de ajustes finos.

V. TRABALHOS FUTUROS

Para o futuro, dados os resultados descritos neste artigo, planejamos trabalhar na criação de experimentos menos intrusivos no modelo de mundo dos jogadores de modo a obter um resultado mais confiável das experimentações controladas. Outro passo importante é realizar experimentos variando a distância do passe e o número de adversários envolvidos na jogada, de modo a obter informações sobre como a relação entre o modelo e a realidade se comporta nas mais variadas situações, otimizando o modelo atual e investigando se a substituição da implementação antiga pela nova, mesmo em situações onde a coerência entre modelo e realidade não foi comprovada (com mais de um adversário por exemplo), não afetou o resultado dos experimentos em partidas.

Outras melhorias importantes são incorporar ao modelo as questões relativas aos tipos heterogêneos e às incertezas inerentes ao ambiente. Melhorar a coleta de informações, tanto por meio de um melhor controle do pescoço quanto por meio da comunicação e fusão de sensores, é outra abordagem promissora dentro da qual já estamos dando os primeiros passos. Outro incremento que já está sendo desenvolvido, é o detalhamento das informações estatísticas coletadas pelo técnico, acrescentando por exemplo a coleta da quantidade de passes certos e errados, nos permitindo avaliar de modo mais preciso os efeitos práticos de uma mudança inserida no agente.

AGRADECIMENTOS

Este projeto é parcialmente financiado pela UNEB, IC/FAPESB, PICIN/UNEB e Fácil Computadores.

- [1] R. de Boer e J. R. Kok, "The incremental development of a synthetic multi-agent system: The uva trilearn 2001 robotic soccer simulation team," Master's thesis, University of Amsterdam, The Netherlands, Feb 2002.
- [2] N. K. Kasabov, *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering*. Massachusetts Institute of Technology, 1998.
- [3] M. A. C. Simões, H. G. Aragão, V. Souza, S. Viegas, H. da L. Silva, and J. Meyer, "Bahia2d team description," in *CD Robocup 2007*. Atlanta, EUA: Springer-Verlag, July 2007.
- [4] M. A. C. Simões, H. Silva, J. Meyer, J. Oliveira, D. Cruz, L. Pessoa, H. Aragão, and R. Lima, "Bahia 2d: Descrição do time," in *Anais do Simpósio Brasileiro de Automação Inteligente (SBAI)*. Florianópolis, SC: Sociedade Brasileira de Automática (SBA), 2007.
- [5] D. Oliveira and M. A. C. Simões, "Controladores nebulosos e rede neural para a marcação de um agente jogador de futebol do ambiente simulado 2d (in portuguese)," Undergraduation Conclusion Work, UNEB, 2007.