

Uma Revisão sobre Tecnologias Aplicadas ao Futebol de Robôs

Walber C. de Jesus* Ejziel S. Santos*
 Glendon S. dos Santos* Lucas L. R. da Silva*
 Fabrício V. de Jesus* Matheus N. Tavares*
 Kevin L. dos Santos* Higor S. de Jesus* Paulo F. F. Rocha*
 João C. N. Bittencourt* André L. C. Ottoni*

* *Centro de Ciências Exatas e Tecnológicas (CETEC),
 Universidade Federal do Recôncavo da Bahia (UFRB), BA, Brasil
 (e-mails: pfabio.rocha@ufrb.edu.br, joaacarlos@ufrb.edu.br,
 andre.ottoni@ufrb.edu.br).*

Abstract: Robot soccer has become an important test-bench in the areas of artificial intelligence, computer vision, and control, thus being a widely studied. Such a scenario is an extremely enriching domain for the development of abilities in real, dynamic, and uncertain environments, where teams need to perform cooperatively to face their opponents. Building a team capable of competing in world championships involves multidisciplinary research in areas such as machine learning, multi-robot systems, computer vision, control theory, robotics hardware development, among others. This paper presents an overview of the aspects involved in the development of a robot soccer team. Among other contributions, there is a review of the main technologies and methods recently used. Such a review can thus be used as reference and guidance material for novel teams in preparation to start research in this area.

Resumo: O futebol de robôs se apresenta hoje como um importante ambiente de teste nas áreas de inteligência artificial, visão computacional e controle, sendo assim uma linha de pesquisa largamente estudada. Nesse aspecto, o futebol de robôs é um domínio extremamente enriquecedor para e o desenvolvimento de habilidades frente a ambientes reais, dinâmicos e incertos, onde os times de robôs operam de forma cooperativa para enfrentar seus adversários. A construção de um time capaz de competir em campeonatos mundiais envolve pesquisa multidisciplinar em áreas como *machine learning*, sistemas multi-robôs, visão computacional, teoria de controle, desenvolvimento de hardware para robótica, dentre outros. Este artigo apresenta uma visão geral dos principais aspectos envolvidos no desenvolvimento de um time de futebol de robôs. Dentre as principais contribuições, apresenta-se uma revisão sobre as tecnologias mais utilizadas no futebol de robôs nos últimos anos. Espera-se que o conteúdo apresentando aqui seja utilizado como material de consulta e direcionamento para equipes de estudantes em fase de preparação para iniciar as pesquisas nessa área.

Keywords: Robot-soccer; Artificial intelligence; Computer vision; Control; Mechanical systems.

Palavras-chaves: Futebol de robôs; Inteligência artificial; Visão computacional; Controle; Sistemas mecânicos.

1. INTRODUÇÃO

A Robótica é uma área multidisciplinar da Engenharia (Craig, 2009; Romero et al., 2014; dos Santos, 2017; Fernandes et al., 2019). De fato, a robótica surpreende pela abrangência de locais no qual pode ser empregada, desde ambientes domésticos até indústrias (Romero et al., 2014; Fernandes et al., 2019). Além disso, a robótica envolve tarefas complexas, tais como a navegação em ambientes dinâmicos, onde existe a necessidade de deslocamento de robôs para realização de tarefas (Costa, 2018). Nesse aspecto, um importante campo de estudo refere-se aos robôs móveis (Romero et al., 2014). Na robótica móvel, para que uma dada operação seja viável, o robô deve adquirir conhecimento sobre o ambiente, tomar decisões,

localizar-se e se deslocar em meio a um conjunto de trajetórias (Heinen, 2002).

O futebol de robôs é um desafio da robótica móvel reconhecido mundialmente e amplamente discutido nos fóruns científicos (Tadokoro et al., 2000; Akin et al., 2013). A primeira iniciativa no sentido do futebol de robôs foi proposta na década de 1990 como forma de incentivar pesquisas e experimentos no ambiente acadêmico na temática de robótica autônoma multiagente (Hoopes et al., 2003). Para impulsionar essa meta, pesquisadores propuseram, como objetivo principal do futebol de robôs, o desenvolvimento de um time de robôs humanoides autônomos capaz de vencer a seleção campeã da FIFA, até meados do século XXI (Kitano et al., 1997; Kitano et al., 1998; Akin et al., 2013; Holz et al., 2019).

Para regulamentar os campeonatos de futebol de robôs existem atualmente diversas entidades, com destaque para duas federações: *RoboCup Federation* (Kitano et al., 1997) e *FIRA - Federation of International Robot-soccer Association* (Kim et al., 1998). Ambas fomentam as pesquisas em robótica promovendo o aumento do número de pesquisadores na área e as inovações tecnológicas empregadas nos times que participam dos campeonatos. Nos torneios da RoboCup e da FIRA, além dos jogos, as equipes apresentam trabalhos onde descrevem suas experiências, possibilitando assim o desenvolvimento tecnológico e o intercâmbio de ideias.

Durante o processo de construção de um time de futebol de robôs ocorre a integração de diversas tecnologias necessárias para desenvolver os agentes autônomos e também para atender as regras das federações. Nesse aspecto, o futebol de robôs apresenta-se como um domínio extremamente enriquecedor para estudantes desenvolverem habilidades em várias frentes de estudo (Romero et al., 2014). As linhas de pesquisa necessárias para projetos com futebol de robôs que tem merecido maior destaque nas últimas décadas são: Inteligência Artificial (Riedmiller et al., 2009; Li and Chen, 2015), Aprendizado de Máquina (Stone et al., 2005; Abreu et al., 2019), Visão Computacional (Luo et al., 2017; Barry et al., 2019), Teoria de Controle (Andreotti et al., 2016; Gomes et al., 2017) e Mecânica de Robôs (Lugli et al., 2019; Mirahy et al., 2019).

Baseando-se na relevância dos estudos associados à robótica móvel, este trabalho tem como principal objetivo apresentar uma revisão sobre as principais tecnologias utilizadas no futebol de robôs nos últimos anos. Espera-se que, com isso, o conteúdo apresentando seja utilizado como material de consulta e direcionamento novas para equipes de estudantes em fase de preparação para iniciar as pesquisas nessa área.

O restante deste artigo está dividido da seguinte forma: a Seção 2 apresenta uma síntese acerca das competições atuais de futebol de robôs; a Seção 3 aborda técnicas de inteligência artificial aplicadas ao aprendizado da tomada de decisão e multiagente; a Seção 4 discorre sobre técnicas aplicadas na Visão Computacional; a Seção 5 discute sobre as técnicas de controle aplicadas nas categorias de robôs físicos; a Seção 6 aborda conceitos associados à mecânica dos robôs; por fim a Seção 7 apresenta as considerações finais e direcionamentos para equipes em fase de formação.

2. FUTEBOL DE ROBÔS

A *RoboCup Federation* é uma organização que promove o futebol de robôs no mundo inteiro (Kitano et al., 1997; Kitano et al., 1998). Uma das atividades da entidade consiste em organizar a Copa do Mundo de Robôs (*Robot World Cup - RoboCup*), evento de mesmo nome da federação. A competição da *RoboCup* é realizada desde 1997 e já passou por vários países: Japão (1997, 2002, 2005 e 2017), França (1998), Suécia (1999), Austrália (2000 e 2019), EUA (2001 e 2007), Itália (2003), Portugal (2004), Alemanha (2006 e 2016), China (2008 e 2015), Áustria (2009), Singapura (2010), Turquia (2011), México (2012), Holanda (2013) e Canadá (2018). Em 2014, o mundial da *RoboCup* foi sediado pela primeira vez no Brasil, na cidade

de João Pessoa (PB)¹. A Figura 1 mostra pesquisadores realizando ajustes em um campo de futebol de robôs da *RoboCup* 2014.



Figura 1. Pesquisadores trabalhando na *RoboCup* 2014. Fonte: Arquivo dos autores.

No Brasil, a *RoboCup* também realiza todos os anos a Competição Brasileira de Robótica (CBR)². A CBR é organizada em parceria com sociedades científicas, como SBC (Sociedade Brasileira de Computação), SBA (Sociedade Brasileira de Automática) e IEEE (Instituto de Engenheiros Eletricistas e Eletrônicos). Além disso, a CBR é sediada em conjunto com outros importantes eventos na área, como por exemplo a Mostra Nacional de Robótica (MNR), Olimpíada Brasileira de Robótica (OBR), Simpósio Brasileiro de Robótica (SBR) e Workshop de Robótica Educacional (WRE)³. A Competição Brasileira de Robótica congrega as categorias da *RoboCup* e também outras ligas de robótica organizadas em conjunto com o IEEE: *Humanoid Robot Racing*, *Open*, *Standard Educacional Kit* e *Very Small Size Soccer*.

Os campeonatos de futebol de robôs são divididos em categorias, de acordo com a estrutura e tamanho do robô, tipo de locomoção (rodas ou *humanoid*) e ambiente (real ou simulado). Atualmente, a *RoboCup* conta com diversas categorias de competições de robótica, que abrangem várias frentes de pesquisa no futebol de robôs (*RoboCup Soccer*). As principais ligas da *RoboCup Soccer* são: *Humanoid*, *Standard Platform*, *Middle Size*, *Small Size*, *Simulation 3D* e *Simulation 2D*. A Figura 2 mostra um time de robôs humanoides da categoria *Standard Platform*. Apesar de estarem um papel significativo para o futebol de robôs, os conceitos e técnicas empregados nas categorias humanoides não são alvo da pesquisa apresentada neste trabalho.

3. INTELIGÊNCIA ARTIFICIAL

A adoção de técnicas de Inteligência Artificial (IA) no contexto do futebol de robôs, é de extrema importância para implementar o comportamento estratégico e tático do time. Os agentes (jogadores) são inseridos em um ambiente de tomada de decisão e colaboração multiagente com diversas situações possíveis de jogo. Para tratar esse desafio, várias técnicas já foram utilizadas no futebol de

¹ <http://www.robocup2014.org>

² <http://www.cbrobotica.org>

³ <http://www.robotica.org.br/>



Figura 2. Time de robôs humanoides da categoria *Standard Platform*. Fonte: Arquivo dos autores.

robôs, tais como: Redes Neurais (Riedmiller et al., 2009), Lógica Fuzzy (Li and Chen, 2015) e Aprendizado por Reforço (AR) (Abreu et al., 2019).

Nesta seção, são abordados aspectos da adoção do AR para o aprendizado de políticas de tomada de decisão no futebol de robôs. Além disso, são apresentados estudos sobre o aprendizado multiagente de robôs para o ambiente de futebol.

3.1 Aprendizado na Tomada de Decisão

O Aprendizado por Reforço (AR), em inglês, *Reinforcement Learning*, é uma técnica com diversas aplicações no futebol de robôs (Stone et al., 2005; Riedmiller et al., 2009; Fabro et al., 2015; Bai et al., 2018; Abreu et al., 2019). Um importante aspecto da adoção do AR é o de aprendizado das ações que devem ser executadas nas distintas situações de um jogo. Nesse aspecto, para implementar uma estratégia de AR no futebol de robôs, devem ser considerados os fundamentos básicos da teoria dos Processos de Decisão de Markov (Sutton and Barto, 2018). Dessa forma, para o aprendizado de políticas de tomada de decisão devem ser definidos um conjunto de estados, ações e recompensas que representem os aspectos de um jogo de futebol.

A definição das ações de um agente de futebol de robôs, pode envolver desde a seleção de comportamentos básicos até mais complexos (Stone et al., 2005; Bai et al., 2018). Alguns exemplos de ações básicas são: chute (*kick*), giro (*turn*) e aceleração (*dash*). Outras ações podem englobar habilidades um pouco mais trabalhadas como: carregar a bola, segurar a bola, mover-se até a bola ou em direção a um ponto do campo. Existem também as macro-ações (ou jogadas), que agregam aspectos coordenados de mais de uma ação primitiva. Por exemplo, para um determinado agente marcar um gol, o jogador deverá girar o corpo, carregar a bola e chutar em direção ao gol.

Por outro lado, os estados do ambiente devem representar as diversas condições possíveis do jogo de futebol de robôs (Stone et al., 2005; Ottoni et al., 2015; Hausknecht and Stone, 2016). Nesse sentido, são variáveis interessantes os ângulos e distâncias dos vários objetos de importância no campo, como bola, gol, outros jogadores e marcas no campo (ex.: escanteio, linhas centrais e laterais) (Hausknecht and Stone, 2016). Outra possibilidade é a utilização da posição dos jogadores no campo (coordenadas x e y) para

mapear os estados (Ottoni et al., 2015). Para exemplificar, a Figura 3 apresenta o campo de futebol da categoria de Simulação 2D da *RoboCup*, com uma divisão de 32 estados, agrupados em 8 seções que variam da letra A à H.

1	5	9	13	17	21	25	29
2	6	10	14	18	22	26	30
3	7	11	15	19	23	27	31
4	8	12	16	20	24	28	32
A	B	C	D	E	F	G	H

Figura 3. Campo da categoria Simulação 2D, com divisão de 32 estados. Baseado em (Ottoni et al., 2015).

Quanto a definição das recompensas, existem alguns métodos adotados na literatura (Berton and Bianchi, 2015; Ottoni et al., 2015; Hausknecht and Stone, 2016). Uma forma é aplicar reforços para o aprendizado de ações específicas. Por exemplo, Hausknecht and Stone (2016) adotam um reforço proporcional à distância do agente em relação a bola na tarefa de interceptação do objeto. Já Berton and Bianchi (2015), abordam valores de reforços distintos de acordo com a função do jogador na partida: goleiro, defensor e atacante. Em outra vertente, Ottoni et al. (2015) propõem recompensas que valorizam os progressos feitos pelo time em direção ao gol. Nesse aspecto, quanto mais próximo de efetuar o chute ao gol (ex.: estados 31 e 32 da Figura 3), maior é a recompensa recebida no aprendizado (Ottoni et al., 2015).

Nesse sentido, a modelagem do aprendizado é determinada de acordo com a definição do estados e a escolha das ações que os agentes podem executar, tais como: drible, chute ao gol, lançamento de bola e passe. Sendo assim, a partir da interação dos robôs no jogo, o sistema aprende uma política de decisão, onde ao se executar uma ação dentro de um estado é retornada uma recompensa. Dessa maneira, o objetivo é aprender a selecionar as ações que maximizam os reforços nos estados do jogo (Sutton and Barto, 2018; Riedmiller et al., 2009; Ottoni et al., 2015).

Um dos métodos mais adotados para realizar o aprendizado no futebol de robôs é o algoritmo *Q-learning* (Watkins and Dayan, 1992; Neri et al., 2012; Fabro et al., 2015; Ottoni et al., 2015). O Algoritmo 1, apresenta uma abstração do funcionamento do *Q-learning*. A cada evento dentro de uma partida do futebol de robôs, é observado o estado atual e assim será selecionada uma ação, de acordo com a política ϵ -greedy. Esse parâmetro de aleatoriedade possui um valor entre 0 (0%) e 1 (100%), do qual define a porcentagem das ações que serão escolhidas aleatoriamente ou mais bem estimadas de acordo com os valores da tabela de aprendizado Q. Após ser definida, essa ação é executada e então uma recompensa imediata e atualizada a tabela Q, de acordo com a Equação 1 (Watkins and Dayan, 1992). O estado é atualizado e o ciclo se repete até o fim da partida.

$$Q_{t+1} = Q_t(s, a) + \alpha[r + \gamma \max_{a'} Q(s_{t+1}, a') - Q_t(s, a)], \quad (1)$$

em que, Q_{t+1} é novo valor a ser atribuído na tabela para um determinado par de estado e ação; $Q_t(s, a)$ é o valor atual da tabela para um determinado par de estado e ação; α é a taxa de aprendizado; r é valor da recompensa imediata recebida com a execução da ação; γ é o fator de desconto; $\max_a Q(s_{t+1}, a)$ é o maior valor existente entre as ações do estado futuro.

Algoritmo 1 *Q-learning* (Watkins and Dayan, 1992).

```

Inicialize  $Q(s_t, a_t) = 0$  para todos os pares  $(s_t, a_t)$ 
while o critério de parada não é satisfeito do
  Observe o estado  $s_t$ 
  Selecione  $a_t$  de acordo com a política  $\epsilon$ -greedy
  Execute a ação  $a_t$ 
  Receba a recompensa  $r(s_t, a_t)$ 
  Observe o estado  $s_{t+1}$ 
  Atualize  $Q(s_t, a_t)$  de acordo com a Equação (1)
   $s_t \leftarrow s_{t+1}$ 
end

```

3.2 Aprendizado Multiagente

O desenvolvimento de técnicas e *frameworks* para o aprendizado multiagente também é uma importante vertente de pesquisas com o futebol de robôs (Stone et al., 2005; Taylor et al., 2007; Fabro et al., 2015; Hausknecht and Stone, 2016). Nessa linha, destaca-se o ambiente do *RoboCup Soccer Keepaway* (Stone et al., 2005; Taylor et al., 2007).

O *Keepaway* é um sub-domínio da categoria de Simulação 2D, destinado a realização de testes de técnicas de IA. Nesse ambiente, um dos objetivos é desenvolver métodos de AR que possibilitem que jogadores atacantes (*keepers*) aprendam a manter a posse de bola contra jogadores adversários (*takers*) (Stone et al., 2005; Bai et al., 2018). O trabalho de Stone et al. (2005), por exemplo, aplica o algoritmo SARSA com função de aproximação *tile coding* no ambiente de *Keepaway*. Os autores testam a influência no aprendizado multiagente de diferentes variações de cenários, como tamanho do campo e número de jogadores (Stone et al., 2005). Nessa mesma linha, Bai et al. (2018) adotam o método de *Concurrent Hierarchical Reinforcement Learning* para o *Keepaway*. Os resultados dos experimentos confirmaram que o método proposto foi significativo no desempenho aprendido dos agentes de futebol de robôs (Bai et al., 2018).

O trabalho de Fabro et al. (2015), por sua vez, apresenta uma estratégia de AR para o *Setplay framework*, denominado FCP-RL-Setplays. O *Setplay* reúne um conjunto de ações colaborativas e coordenadas e compõe a biblioteca da equipe fcportugal (Fabro et al., 2015). Os experimentos demonstraram que o FCP-RL-Setplays chegou a alcançar 93% de vitórias contra outras equipes de futebol de robôs simulado (Fabro et al., 2015).

As pesquisas no campo de transferência de aprendizado (*transfer learning*) também são frequentemente investigadas no futebol de robôs (Taylor et al., 2007; Bianchi et al., 2015, 2018). Os algoritmos de transferência de aprendizado são caracterizados por três pontos de grande relevância (Bianchi et al., 2015): qual informação será transferida; como tal informação será transferida; e quando será transferida. No âmbito de futebol de robôs, a trans-

ferência de aprendizado pode ser importante no repasse de informações de jogo, como a disposição dos jogadores para estratégias de defesa e/ou ataque, individual ou geral, melhorando assim o desempenho geral do time (Taylor et al., 2007).

4. VISÃO COMPUTACIONAL

A visão computacional está entre as áreas de percepção mais eficientes, fornecendo aos robôs a capacidade de realizar suas atividades no decorrer da partida. Dentro do ponto de vista do futebol de robôs, a visão computacional vem sendo estudada para aplicações desde os primeiros anos das competições da *RoboCup* (Jamzad et al., 2001; Zickler et al., 2009). Um sistema de visão computacional deve capturar a pose dos objetos reconhecidos na cena de maneira precisa, em tempo real, ser sensível a variações de luminosidade, oclusão, distorções na lente e ruídos. Além disso, em certas categorias, o sistema de visão deve reconhecer diferentes cores e formatos para fornecer a informação correta sobre a cena, apresentando um bom desempenho na realização dessas tarefas.

4.1 Detecção e classificação de características do campo

O primeiro desafio apresentado a um sistema de visão corresponde à detecção e classificação de características do campo. Tal análise parte do princípio da detecção dos elementos que compõem a partida. Dentre os objetos associados ao sistema de visão, destaca-se a detecção e classificação dos jogadores, da bola, e das linhas do campo, como ilustrado no exemplo apresentado na Figura 4.

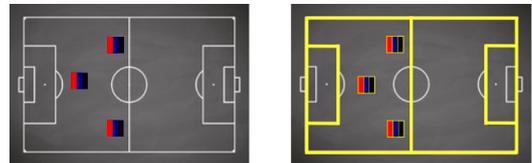


Figura 4. Exemplo de detecção do campo e jogadores.

Sistemas de detecção utilizam uma adaptação dos mecanismos de classificação. Para detectar um objeto, tais sistemas utilizam um classificador para um dado objeto e avalia sua presença em uma imagem. Abordagens recentes, utilizam Redes Neurais Convolucionais Recorrentes (R-CNN) para determinar uma região potencial, delimitando assim as regiões de análise (Girshick et al., 2013).

O trabalho apresentado por Luo et al. (2017) demonstra a utilização do método *You Only Look Once* (YOLO) (Redmon et al., 2016), ferramenta de visão computacional para detecção e classificação de objetos em tempo real, com dados provenientes de uma Rede Neural Convolutional. Nos experimentos realizados os autores atestam que o sistema necessita de cerca de 60 ms para realizar o processo de previsão. Além dos resultados apresentados, o trabalho disponibiliza a base de dados construída para as respectivas etapas de treinamento e testes.

O futebol de robôs exige que sejam tomadas decisões rápidas durante a partida, por exemplo, detectar a bola e demais jogadores em campo. No trabalho desenvolvido por Barry et al. (2019) foi proposta uma rede neural

convolucional que utiliza uma versão adaptada do detector de objetos YOLO, denominada xYOLO. Nos experimentos utilizando a plataforma Raspberry Pi 3 Modelo B, os autores apontam para uma taxa média de desempenho equivalente a 10 quadros por segundo, com cerca de 70 % de acurácia. Levando em conta tais aspectos, embora ofereça taxas de acurácia menores quando comparado ao original Redmon et al. (2016), o modelo apresentado oferece um desempenho melhor quando comparado ao YOLO. Além do desempenho na etapa de reconhecimento de objetos, o modelo também apresenta tempo de treinamento reduzido em cerca de 78 %, o que facilita os testes e implementação de mudanças na rede neural.

Os trabalhos apresentados por Cruz et al. (2017) e Schneckburger et al. (2017), são bons exemplos recentes com enfoque na detecção de características gerais no futebol de robôs. Os autores destacam a eficácia do uso de redes neurais convolucionais para detectar os elementos do campo de jogo.

4.2 Detecção da bola

Em uma partida de futebol, a bola se move constantemente em diferentes velocidades ao longo do campo. Deste modo, é fundamental que o sistema de visão computacional associado à sua detecção seja tolerante a tais variações. Além disso, visando proporcionais maior dinâmica às estratégias de um time de futebol de robôs, é fundamental estimar, de forma eficaz, a distância entre os robôs e a bola. A Figura 5 apresenta dois exemplos de variações possíveis na detecção da bola, quando parada e em movimento.

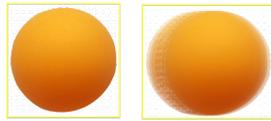


Figura 5. Demonstração de detecção da bola parada e em movimento.

O trabalho apresentado por Wibowo et al. (2019) propõe um sistema para detecção da bola no futebol de robôs, tolerante a diferentes níveis de luminosidade. Para tanto, o método utiliza um sistema de detecção que emprega a técnica *Local Binary Pattern* (LBP) (Pietikäinen et al., 2011). A justificativa dos autores para o uso da LBP é pautada no fato de os sistemas de detecção que utilizam da limiarização, apresentarem taxas de acurácia reduzidas, quando submetidas à mudanças nas condições de luminosidade. Nos experimentos realizados por Wibowo et al. (2019), as taxas de sucesso alcançaram um valor máximo de 98,74% e mínimo de 80,69%, considerando a bola se movendo lentamente, em diferentes condições de luminosidades. Por outro lado, os experimentos realizados destacam uma taxa entre 60,42% e 83,79% quando a bola se move rapidamente. Além da detecção da bola, o sistema proposto por Wibowo et al. (2019) apresenta 92,4% de acurácia na estimativa de distância entre a bola e o robô.

Abreu and Bianchi (2019) propõem um conjunto de soluções voltadas para detecção da bola em tempo real, fundamentadas no uso de redes neurais convolucionais. Para tanto, utiliza-se de dois modelos de redes neurais: a Faster R-CNN e a Mobilenet, em conjunto com as técnicas

de transferência de aprendizado (Tan et al., 2018) e *data augmentation* (Shorten and Khoshgoftaar, 2019). Os objetivos da aplicação de tais técnicas fundamenta-se na aceleração do treinamento das redes neurais, proporcionada pela aplicação da técnica de transferência de aprendizado, bem como, o ajuste correto do conjunto de treinamento, resultado da aplicação da *data augmentation*.

O trabalho apresentado por Susanto et al. (2018) propõe uma solução para detecção da bola de cor predominante branca no futebol de robôs da categoria humanoide. O algoritmo proposto utiliza a combinação de dois métodos, CVblobs, o qual utiliza a cor para detectar o objeto, e *Hough Circle Method*, responsável por detectar objetos circulares em meio à imagens. O método proposto baseia-se no sistema de cores YUV, uma vez que utiliza diferentes canais para luz e cor. Nos experimentos realizados, os autores apontam para uma taxa média de processamento de 26 fps para cada movimento do robô, enquanto detectava a bola. O método proposto alcançou resultados de qualidade comparável à de métodos que utilizam de aprendizado de máquina ou *deep learning*, sem a utilização de uma GPU dedicada, mostrando-se eficaz para aplicação também no futebol de robôs.

Os trabalhos apresentados por Speck et al. (2017) e Militari and Colombini (2017), são outros exemplos recentes com enfoque na detecção da bola em tempo real no futebol de robôs. Ambas as pesquisas utilizam de otimizações baseadas em técnicas de redes neurais convolucionais para detecção da bola.

5. SISTEMAS DE CONTROLE

No âmbito do futebol de robôs, o sistema de controle é responsável por realizar o acionamento dos motores associados ao sistema locomoção para executar o deslocamento dos robôs conforme a estratégia e a tática planejadas pelo time. Embora as tomadas de decisão sejam definidas pela inteligência artificial, o sistema de controle que garante o seguimento da trajetória, visto que as técnicas controle utilizam as informações de posição e velocidade para corrigir o movimento do robô.

5.1 Modelagem matemática dos robôs

Independente da lei de controle adotada, o projeto do controlador passa pela modelagem matemática das variáveis controladas para que haja uma relação mais eficiente entre maior desempenho e menor complexidade (Romero et al., 2014). Os modelos matemáticos são divididos em:

Cinemático: descreve o movimento do robô ignorando a influência da massa sobre o mesmo, de modo que o robô é tratado como um ponto no espaço.

Dinâmico: estuda o movimento do robô, considerando grandezas como massa, momento de inércia e torque. Em projetos em que se requer altas velocidades ou transporte de cargas pesadas, o modelo dinâmico é o mais apropriado para ser aplicado.

A solução do problema de controle pode ser abordada considerando apenas o modelo cinemático, apenas o modelo dinâmico ou ambos os modelos, cinemático e dinâmico (Romero et al., 2014). Especificamente nas categorias de

futebol de robôs dotados de rodas, tais como a *Very Small Size*, a *Small Size* e a *Middle Size*, cujos movimentos são no plano bidimensional e os robôs são leves, é predominantemente adotado o modelo cinemático para o projeto de controladores (Andreoti et al., 2016; Gomes et al., 2017). Entretanto, existem trabalhos na literatura que adotam os modelos cinemático e dinâmico (Abiyev et al., 2017).

A representação no plano XY de um robô uni-ciclo, tipicamente usado na categoria VSS, é apresentada na Figura 6. Nessa situação, as velocidades linear (v) e angular (w) são controladas a partir das componentes de posição x e y e da orientação θ . O modelo cinemático é descrito pela Equação (2):

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \cos \theta & 0 \\ \sin \theta & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix}. \quad (2)$$

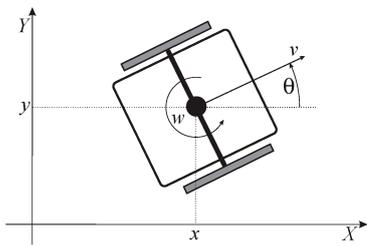


Figura 6. Robô uniciclo no plano bidimensional. Fonte: (Guechi et al., 2019).

5.2 Técnicas de controle

O controlador mais popular entre as equipes de futebol de robô é o do tipo PID (Dadalto et al., 2016; Lopes et al., 2018; Lugli et al., 2019), no qual o ajuste do erro (diferença entre estado desejado e estado atual da variável controlada) é feito de forma proporcional (P), integral (I) e/ou derivativa (D) (Ogata, 2011). O sinal de saída $u(t)$ do controlador PID é dado pela Equação (3)

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{d}{dt} e(t), \quad (3)$$

em que, K_p , K_i e K_d são as constantes dos ganhos proporcional, integrativo e derivativo, respectivamente, e $e(t)$ corresponde ao erro.

A estratégia de campos potenciais, na qual a velocidade aumenta ou diminui de acordo com a distância entre a localização atual do robô e a desejada, também é empregada (Gomes et al., 2017; Lopes et al., 2018).

Alternativas de controladores que vem sendo empregados no futebol de robôs atualmente, são baseados na lógica *fuzzy* (Andreoti et al., 2016; Abiyev et al., 2017). Essa técnica utiliza de linguagem natural para produzir as regras de controle (Lee, 1990).

6. MECÂNICA

O desafio da construção da estrutura mecânica de um robô jogador inicia-se pelas especificações de tamanho e de formato indicados pelas regras de cada categoria. São apresentadas a seguir algumas das especificações dos robôs que utilizam rodas como parte do sistema de locomoção:

Vary Small Size (VSS): formato cúbico com dimensões máximas de $7,5 \times 7,5 \times 7,5$ cm.

F180: formato cilíndrico com diâmetro menor que 18 cm e altura máxima de 15 cm.

Middle Size (MS): qualquer formato desde que a base tenha entre 30×30 cm e 52×52 cm e altura entre 40 cm e 80 cm.

Dentre os elementos da estrutura mecânica, as três categorias possuem em comum o chassi, carcaça e sistema de locomoção. Nas categorias F180 e MS, há, ainda, sistema de chute e de drible.

6.1 Chassi e carcaça

O chassi tem papel fundamental na construção de um robô com rodas, uma vez que proporciona sustentação a toda estrutura física, sendo também onde se acopla o sistema de tração do robô. Por outro lado, a carcaça protege os componentes internos e serve para a fixação dos elementos de identificação dos robôs. Desta forma, a estrutura mecânica do robô deve apresentar boa rigidez estrutural e garantir proteção aos componentes internos. Além disso, deve ser confeccionado a partir de um material leve e de fácil manufatura.

Na categoria VSS, é comum as equipes construïrem tanto o chassi quanto a carcaça com o mesmo material, como nos trabalhos que usaram na fabricação do conjunto os materiais: PETG-XT (Lugli et al., 2019), aço inoxidável (de Almeida et al., 2018), ABS (Santos et al., 2015; Gomes et al., 2017), dentre outros.

Em geral, as equipes da categoria F180 não apresentam em seus trabalhos o tipo material para a construção dos robôs. Entretanto, dentre aquelas que revelam, é preponderante a utilização de alumínio para a construção do chassi (Gaurav et al., 2019; Mirahy et al., 2019) ou mesmo de polímeros, tais como Polióxido de Metileno (Croll et al., 2017), que também é usado na carcaça. A Figura 7 apresenta os modelos de robôs das categorias VSS e F180.

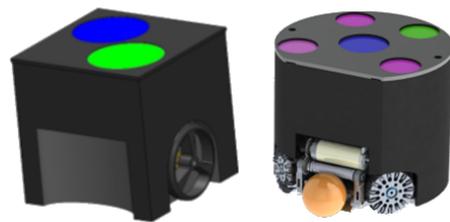


Figura 7. Modelo do robô VSS da equipe RobotBulls (esquerda) e do robô F180 da equipe ITAndroids (direita). Fontes: Lugli et al. (2019) e Mirahy et al. (2019).

6.2 Sistema de locomoção

O sistema de locomoção promove mobilidade aos robôs precisa ser projetado de modo que não haja um dimensionamento exagerado ou inferior ao necessário. Tal sistema é composto por um conjunto de rodas e motores elétricos de corrente contínua.

Nas categorias VSS, F180 e MS, cada roda é independente e ligada a um sistema de tração. As diferenças ficam por

conta do tipo e disposição das rodas. De maneira geral, na categoria VSS são utilizadas duas rodas fixas sobre um mesmo eixo e pode haver uma roda adicional, não tracionada, para dar equilíbrio. Na categoria F180, são utilizadas quatro rodas omnidirecionais. Por fim, na categoria MS, são três ou quatro rodas também omnidirecionais. Tal característica é devida aos anéis acoplados ao redor de toda a circunferência da roda.

A escolha do motor é determinada a partir da relação do torque e o peso do robô, caso o motor tenha boa rotação e torque insuficiente, o mesmo é acoplado a um sistema de engrenagem chamada de caixa de redução aumentando o torque (Gomes et al., 2017).

6.3 Sistema de chute e drible

O sistema de chute é responsável por disparar a bola que está em contato com o sistema de drible, o qual tem a função de pegá-la e controlá-la. Além disso, o sistema de chute é composto por um mecanismo de disparo, que pode ser de mola, pneumático ou com solenoide. Este último vem sendo o mais utilizado pelas equipes tradicionais no futebol de robôs (Croll et al., 2017; Mirahy et al., 2019; Gaurav et al., 2019).

O sistema de drible tem como componentes principais um motor, uma caixa de redução e uma barra cilíndrica. Na Figura 8 são apresentados os sistemas de chute e drible da equipe KgpKubs (Gaurav et al., 2019).



Figura 8. Sistema de chute (esquerda) e de drible (direita).
Fonte: Gaurav et al. (2019).

7. CONCLUSÃO

O objetivo deste trabalho foi apresentar uma revisão sobre tecnologias e métodos aplicados ao futebol de robôs. O futebol de robôs é um domínio extremamente desafiador, oferecendo ótimas oportunidades para pesquisadores, em diferentes níveis da graduação ou pós-graduação, realizarem estudos em diversas áreas das ciências exatas e tecnológicas. Nesse sentido, o futebol de robôs também apresenta-se como um grande aliado no ensino das Engenharias, ao unir conteúdos teóricos aos conceitos práticos de desenvolvimento de projetos e trabalho em equipe.

Na expectativa de direcionar novos pesquisadores desse domínio, neste trabalho foram apresentados estudos referentes a diferentes frentes do futebol de robôs. Os estudos relacionados à IA, destacam um potencial para o uso de técnicas de *machine learning* para aprendizado e desenvolvimento de políticas de tomadas de decisão. As pesquisas nessa área estabelecem uma tendência em que as novas tecnologias e sistemas sejam coordenadas pela IA. Neste contexto, também se integra a área da visão computacional, buscando proporcionar aos sistemas a capacidade de interagir com o ambiente no qual está inserido com

o intuito de promover eficiência nos processos. No âmbito da visão computacional, os estudos aqui descritos apontam para a necessidade do desenvolvimento de técnicas que proporcionem uma redução no tempo de resposta, conduzindo assim a sistemas mais eficientes.

Além disso, tendo em vista proporcionar melhorias na mobilidade dos robôs físicos, é necessário trazer novas propostas de modelos cada vez mais eficientes para o desenvolvimento dos sistemas de controle robóticos. O uso de técnicas de processamento leve precisam ser investigadas, tendo em vista produzir plataformas robustas cada vez mais robustas. Finalmente, o desenvolvimento de novos materiais e mecanismos que auxiliem na mobilidade dos robôs, na estrutura de chute e na liberdade do drible também são vertentes que devem continuar sendo investigadas no futuro.

AGRADECIMENTOS

Este trabalho foi desenvolvido dentro do contexto do projeto de pesquisa UFRBots: Equipe de Futebol de Robôs da UFRB, com apoio dessa instituição, código de projeto 2372, PPGCI/UFRB.

REFERÊNCIAS

- Abiyev, R.H., Günsel, I.S., Akkaya, N., Aytac, E., Çağman, A., and Abizada, S. (2017). Fuzzy control of omnidirectional robot. *Procedia Computer Science*, 120, 608 – 616. 9th International Conference on Theory and Application of Soft Computing, Computing with Words and Perception.
- Abreu, L.R.d. and Bianchi, R.A.d.C. (2019). Real-time Ball Detection for Robocup Soccer Using Convolutional Neural Networks. *Anais do XV Workshop de Visão Computacional (WVC) da SBC*, 103–108.
- Abreu, M., Reis, L.P., and Lau, N. (2019). Learning to run faster in a humanoid robot soccer environment through reinforcement learning. In S. Chalup, T. Niemueller, J. Suthakorn, and M.A. Williams (eds.), *RoboCup 2019: Robot World Cup XXIII*, 3–15.
- Akin, H.L., Ito, N., Jacoff, A., Kleiner, A., Pellenz, J., and Visser, A. (2013). Robocup rescue robot and simulation leagues. *AI magazine*, 34(1), 78–78.
- Andreotti, S.E., Menezes, T.A., and Bordon, M.E. (2016). Controle de trajetória de um robô móvel com tração diferencial usando lógica nebulosa. In *Mostra Nacional de Robótica (MNR)*.
- Bai, A., Russell, S., and Chen, X. (2018). Concurrent hierarchical reinforcement learning for robocup keepaway. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11175 LNAI, 190–203.
- Barry, D., Shah, M., Keijsers, M., Khan, H., and Hopman, B. (2019). xYOLO: A Model For Real-Time Object Detection In Humanoid Soccer On Low-End Hardware. In *2019 International Conference on Image and Vision Computing New Zealand (IVCNZ)*, 1–6.
- Berton, P.A. and Bianchi, A.C. (2015). Aprendizado por reforço aplicado ao desenvolvimento de agentes humanoides no domínio do futebol de robôs simulado. *XII Simpósio Brasileiro de Automação Inteligente*.
- Bianchi, R., Celiberto, L.A., J., Santos, P., Matsuura, J., and Lopez De Mantaras, R. (2015). Transferring knowledge as heuristics in reinforcement learning: A case-based approach. *Artificial Intelligence*, 226, 102–121.
- Bianchi, R., Santos, P., da Silva, I., Celiberto, L.A., J., and Lopez de Mantaras, R. (2018). Heuristically accelerated reinforcement learning by means of case-based reasoning and transfer learning. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 91(2), 301–312.
- Costa, T.M.S. (2018). Robôs móveis com visão omnidirecional. *FEUP/Universidade do Porto*.
- Craig, J.J. (2009). *Introduction to robotics: mechanics and control, 3/E*. Pearson Education India.
- Croll, E., Freije, R., de Haan, K., van der Heide, H., Hoekstra, J., Okken, B., Plompen, R., Rubbens, B., Timmer, R., Tolboom, S., de Weerdt, D., Weijers, I., and Westra, W. (2017). Robotteam twente 2017 team description paper. In *RoboCup 2017 Symposium*.

- Cruz, N., Lobos-Tsunekawa, K., and Ruiz-del Solar, J. (2017). Using convolutional neural networks in robots with limited computational resources: detecting NAO robots while playing soccer. In *Robot World Cup*, 19–30. Springer.
- Dadalto, A.P., Tabchoury, G.A., and Henrique A. Amitay, G.A.F., Miyamoto, H.K., de Melo, L.A., Junior, M.M., de C. Coelho, M., Stringhini, P.H.F., Grego, P., Fernandes, U.P., and Ide, W.T.S.T. (2016). Um projeto de futebol de robôs autônomos baseado na categoria ieev very small size soccer da competição brasileira de robótica. In *CBR/LARC 2016*.
- de Almeida, A.H.S., de Oliveira, A.P., Boas, A.S.C.A.V., Rodrigues, B.H., Rodrigues, B.N., de Oliveira, C.J., Maurício, D.R., Boas, E.R.V., Costa, E.B., dos Santos, F.B., Barino, F.O., Barros, G.J.C., Oliveira, G.F.R., da Silva, G.A.F., Santos, G.N., Barbosa, I.H.S., Pimentel, J.P.P., da Costa, L.P.M., Kappel, L.B., de Almeida, L.G., Gonçalves, M.P.P.R.P., de Oliveira, T.V.B., and de Campos, V.Q. (2018). Rinobot team equipe de competição de robôs autônomos da universidade federal de juiz de fora. In *LARC/CBR/2018*.
- dos Santos, C.B. (2017). *Utilizando a Robótica Educacional para Aprimorar Conceitos Didático-Pedagógicos*. Ph.D. thesis, Instituto Federal de Educação.
- Fabro, J., Reis, L., and Lau, N. (2015). Using reinforcement learning techniques to select the best action in setplays with multiple possibilities in robocup soccer simulation teams. In *2nd SBR Brazilian Robotics Symposium*, 85–90.
- Fernandes, V.S., da Silva, J.R., Campos, A.L.A., Lopes, M.F.A., Vieira, F.M.S., D'Angelo, M.F.S.V., and Netto, J.C. (2019). A robótica na democratização do uso de tecnologias. *Anais do Simpósio Ibero-Americano de Tecnologias Educacionais*.
- Gaurav, A., Jatoria, T., Panda, S.K., Dalal, P., Mittal, H., Sinha, S., Agarwal, S., Kumar, R., Jenamani, R.K., Ramnani, P., Reddy, K.S., Bhat, M., Raj, V., Aggarwal, S., Kirtania, A., Chilukuri, G.R., Kartik, M., Agrawal, A., Roy, A., Praharaj, A., Jerry, J., Dewangan, P., Dwivedi, A., Surya, D.P., Mondal, R., Raj, D., Garg, C., Gupta, A., Sharma, S., Bhushan, M., Sharma, S., and Roy, A. (2019). Kgpkubs 2019 team description paper. In *RoboCup 2019 Symposium*.
- Girshick, R.B., Donahue, J., Darrell, T., and Malik, J. (2013). Rich feature hierarchies for accurate object detection and semantic segmentation. corr abs/1311.2524 (2013). *arXiv preprint arXiv:1311.2524*.
- Gomes, A.O., Paula, A.R., Martins, B.B.S., Oliveira, B.L.M., Silva, D.F., Quijano, E.H.D., Assis, L.S., Dias, N.J.B., Mortosa, O.S., Alves, P.S.R., Tomé, R.A.A., Rafael F. G. Jardim, T.M.P., Oliveira, T.H., Santos, V.A., and Aguas, W.G. (2017). Pequi mecânico ieev vss soccer team. In *LARC/CBR/2017*.
- Guechi, E.H., Belharet, K., and Blažič, S. (2019). Tracking control for wheeled mobile robot based on delayed sensor measurements. *Sensors*, 19(23), 5177.
- Hausknecht, M. and Stone, P. (2016). Deep reinforcement learning in parameterized action space. In *4th International Conference on Learning Representations*.
- Heinen, F.J. (2002). Sistema de controle híbrido para robôs móveis autônomos. *Universidade do Vale do Rio do Sinos*.
- Holz, D., Genter, K., Saad, M., and von Stryk, O. (2019). *RoboCup 2018: Robot World Cup XXII*, volume 11374. Springer.
- Hoopes, D., Davis, T., Norman, K., and Helps, R. (2003). An autonomous mobile robot development platform for teaching a graduate level mechatronics course. In *33rd Annual Frontiers in Education, 2003. FIE 2003.*, volume 2, F4E–17. IEEE.
- Jamzad, M., Sadjad, B., Mirrokni, V.S., Kazemi, M., Chitsaz, H., Heydarnoori, A., Hajiaghaj, M., and Chiniforooshan, E. (2001). A fast vision system for middle size robots in robocup. In *Robot Soccer World Cup*, 71–80. Springer.
- Kim, J.H., Vadakkepat, P., and Verner, I.M. (1998). Fira robot world cup initiative and research directions. *Int. J. of Robotics and Automation Systems*.
- Kitano, H., Asada, M., Kuniyoshi, Y., Noda, I., Osawa, E., and Matsubara, H. (1997). Robocup: A challenge problem for ai. *AI Magazine*, 18(1), 73–85.
- Kitano, H., Asada, M., Noda, I., and Matsubara, H. (1998). Robocup: robot world cup. *IEEE Robotics Automation Magazine*, 5(3), 30–36.
- Lee, C.C. (1990). Fuzzy logic in control systems: fuzzy logic controller. *IEEE Transactions on Systems, Man, and Cybernetics*, 20(2), 404–418.
- Li, X. and Chen, X. (2015). Fuzzy inference based forecasting in soccer simulation 2d, the robocup 2015 soccer simulation 2d league champion team. In *Robot Soccer World Cup*, 144–152. Springer.
- Lopes, A.G., Hasuda, D.G., Pinheiro, F.C.R., de Oliveira, G.S., Okuyama, I.F., ao Ribeiro, I.M., Arruda, T.P., ao, T.P.B., de Medeiros, T.F., Junior, J.R., and Máximo, M. (2018). Itandroids very small size soccer team description paper for larc 2018. In *LARC/CBR/2018*.
- Lugli, A.B., Oppenheimer, D.R., Neto, E.R., ao Victor de O. G. Ribeiro, J., Nogueira, L.E., Lima, M.E.C., de Oliveira, P.P.S., and Saldanha, W.E. (2019). Robotbolls very small size soccer (vsss) team. In *LARC/CBR/2019*.
- Luo, S., Lu, H., Xiao, J., Yu, Q., and Zheng, Z. (2017). Robot detection and localization based on deep learning. In *2017 Chinese Automation Congress (CAC)*, 7091–7095.
- Militao, G. and Colombini, E. (2017). Ball Depth Detection using CNN. *Universidade Estadual de Campinas*.
- Mirahy, B., Éric Machado, Moreira, E., Azevedo, F., da Silva, J., Luciano, J., Santos, M., Máximo, M., Lima, R., Linhares, R., Bittencourt, R., and Duarte, V. (2019). Itandroids small size soccer team description 2019. In *RoboCup 2019 Symposium*.
- Neri, J.R.F., Zатели, M.R., dos Santos, C.H.F., and Fabro, J.A. (2012). A proposal of qlearning to control the attack of a 2d robot soccer simulation team. In *2012 Brazilian Robotics Symposium and Latin American Robotics Symposium*, 174–178.
- Ogata, K. (2011). *Engenharia de controle moderno*. PRENTICE HALL BRASIL, 5 edition.
- Otoni, A.L.C., Oliveira, M., Nepomuceno, E.G., and Lamperti, R.D. (2015). Análise do aprendizado por reforço via modelos de regressão logística: Um estudo de caso no futebol de robôs. *Revista Junior de Iniciação Científica em Ciências Exatas e Engenharia*, 1(10), 44–49.
- Pietikäinen, M., Hadid, A., Zhao, G., and Ahonen, T. (2011). *Computer vision using local binary patterns*, volume 40. Springer Science & Business Media.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Riedmiller, M., Gabel, T., Hafner, R., and Lange, S. (2009). Reinforcement learning for robot soccer. *Autonomous Robots*, 27(1), 55–73.
- Romero, R.A., Prestes, E., Osório, F., and Wolf, D. (2014). Robótica móvel. *São Paulo: LTC*.
- Santos, G., Mercês, R., Pimentel, F., Sapucaia, F., Laranjeira, C., Souza, J., Simões, M., and Frias, D. (2015). Evoluindo o projeto de robôs para liga de futebol very small size soccer. In *LARC/CBR/2015*.
- Schnekenburger, F., Scharffenberg, M., Wulker, M., Hochberg, U., and Dorer, K. (2017). Detection and Localization of Features on a Soccer Field with Feedforward Fully Convolutional Neural Networks (FCNN) for the Adult-Size Humanoid Robot Sweaty. *Proceedings of the 12th Workshop on Humanoid Soccer Robots, 17th IEEE-RAS International Conference on Humanoid Robots*.
- Shorten, C. and Khoshgoftaar, T.M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.
- Speck, D., Barros, P., Weber, C., and Wermter, S. (2017). Ball Localization for Robocup Soccer Using Convolutional Neural Networks. In S. Behnke, R. Sheh, S. Sarel, and D.D. Lee (eds.), *RoboCup 2016: Robot World Cup XX*, Lecture Notes in Computer Science, 19–30.
- Stone, P., Sutton, R., and Kuhlmann, G. (2005). Reinforcement learning for robocup soccer keepaway. *Adaptive Behavior*, 13(3), 165–188.
- Susanto, Agung Dewasakti, G.B., and Analia, R. (2018). Introduction to Modest Object Detection Method of Bareleng-FC Soccer Robot. In *2018 International Conference on Applied Engineering (ICAE)*.
- Sutton, R.S. and Barto, A.G. (2018). *Reinforcement learning: An introduction*. MIT press, 2nd edition.
- Tadokoro, S., Kitano, H., Takahashi, T., Noda, I., Matsubara, H., Shinjoh, A., Koto, T., Takeuchi, I., Takahashi, H., Matsuno, F., et al. (2000). The robocup-rescue project: A robotic approach to the disaster mitigation problem. In *Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation.*, volume 4, 4089–4094. IEEE.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., and Liu, C. (2018). A survey on deep transfer learning. In *International conference on artificial neural networks*, 270–279. Springer.
- Taylor, M., Stone, P., and Liu, Y. (2007). Transfer learning via inter-task mappings for temporal difference learning. *Journal of Machine Learning Research*, 8, 2125–2167.
- Watkins, C.J. and Dayan, P. (1992). Q-learning. *Machine learning*, 8(3), 279–292.
- Wibowo, I.K., Haq, M.A., Bachtiar, M.M., Dewantara, B.S.B., and Ihsan, F.L.H. (2019). Ball Detection using Local Binary Pattern in Middle Size Robot Soccer (ERSOW). In *2019 2nd International Conference of Computer and Informatics Engineering (IC2IE)*, 29–32.
- Zickler, S., Laue, T., Birbach, O., Wongphati, M., and Veloso, M. (2009). Ssl-vision: The shared vision system for the robocup small size league. In *Robot Soccer World Cup*, 425–436. Springer.