

CENTRO UNIVERSITÁRIO FEI  
MARCOS AURELIO PCHEK LAUREANO

**SISTEMA DE POSICIONAMENTO DE ROBÔS EM PARTIDAS DE FUTEBOL  
BASEADO EM INTELIGÊNCIA COLETIVA DE ENXAMES**

São Bernardo do Campo

2020



MARCOS AURELIO PCHEK LAUREANO

**SISTEMA DE POSICIONAMENTO DE ROBÔS EM PARTIDAS DE FUTEBOL  
BASEADO EM INTELIGÊNCIA COLETIVA DE ENXAMES**

Tese de Doutorado, apresentada ao Centro  
Universitário da FEI para obtenção do título  
de Doutor em Engenharia Elétrica. Orientado  
pelo Prof. Dr. Flavio Tonidandel.

São Bernardo do Campo

2020

Laureano, Marcos Aurelio Pchel.

Sistema de posicionamento de robôs em partidas de futebol baseado em inteligência coletiva de enxames / Marcos Aurelio Pchel Laureano. São Bernardo do Campo, 2020.

228 p. : il.

Tese - Centro Universitário FEI.

Orientador: Prof. Dr. Flavio Tonidandel.

1. Algoritmos de enxame. 2. Futebol de robôs. 3. Posicionamento por Otimização de enxame de partículas. I. Tonidandel, Flavio , orient. II. Título.

**Aluno:** Marcos Aurélio Pcheck Laureano

**Matrícula:** 515304-4

**Título do Trabalho:** Sistema de posicionamento de robôs em partidas de futebol baseado em inteligência coletiva por enxame.

**Área de Concentração:** Inteligência Artificial Aplicada à Automação e Robótica

**Orientador:** Prof. Dr. Flavio Tonidandel

**Data da realização da defesa:** 27/08/2020

**ORIGINAL ASSINADA**

Avaliação da Banca Examinadora

São Bernardo do Campo, / / .

**MEMBROS DA BANCA EXAMINADORA**

Prof. Dr. Flavio Tonidandel

Ass.: \_\_\_\_\_

Prof. Dr. Carlos Eduardo Thomaz

Ass.: \_\_\_\_\_

Prof. Dr. Reinaldo Augusto da Costa Bianchi

Ass.: \_\_\_\_\_

Prof. Dr. Eduardo Bento Pereira

Ass.: \_\_\_\_\_

Prof. Dr. João Alberto Fabro

Ass.: \_\_\_\_\_

A Banca Examinadora acima-assinada atribuiu ao aluno o seguinte:

APROVADO

REPROVADO

**VERSÃO FINAL DA TESE**

**ENDOSSO DO ORIENTADOR APÓS A INCLUSÃO DAS  
RECOMENDAÇÕES DA BANCA EXAMINADORA**

Aprovação do Coordenador do Programa de Pós-graduação

Prof. Dr. Carlos Eduardo Thomaz



## **AGRADECIMENTOS**

Cursar e finalizar um doutorado não é uma tarefa trivial. Requer dedicação e tempo. Eu realmente não conseguiria terminar este trabalho se não fosse o apoio da minha amada esposa! Uma Rosa que surgiu na minha vida.

Meus filhos também, deram o apoio, foram compreensivos, choravam ao telefone de saudades quando eu estava longe de casa. Foram a força motriz e o incentivo para não desistir.

As vocês, meu muito obrigado!! Amo demais essa família!!!

Muito desse trabalho também não poderia ter sido realizado sem o apoio da família RoboFEI. Agradeço ao Flavio pela orientação e ao Bianchi pela várias dicas ao longo da pesquisa.

Não posso esquecer meus colegas da SSL, especialmente aos que me acompanharam nessa jornada final e ajudaram bastante: Leonardo, Wesley e Pauli.

Finalmente, agradeço ao Instituto Federal do Paraná – IFPR pela liberação durante o período de doutoramento e ao CAPES pela bolsa de estudos.



## RESUMO

A equipe *Small Size League* (SSL) da RoboFEI existe desde 2008. Uma das motivações para a existência do projeto é aplicação dos conhecimentos em eletrônica, mecânica e programação no uso e desenvolvimento de algoritmos voltados para a Inteligência Artificial (IA). A IA abrange várias técnicas, como aprendizado, otimização e algoritmos bioinspirados. Algoritmos bioinspirados são utilizados para os mais diversos propósitos, inclusive para que robôs possam trabalhar de forma colaborativa. A liga SSL evoluiu com o passar dos anos e algumas mudanças já foram realizadas como o aumento das dimensões do campo e quantidade de robôs. Essa evolução também traz maiores possibilidades de jogadas e aumento da complexidade de uma partida. O posicionamento dos robôs em campo torna-se importante como mecanismo de defesa e ataque. Neste cenário, no trabalho aqui relatado é proposto a utilização do algoritmo *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO) como uma opção de inteligência coletiva aplicada para determinar o posicionamento dos robôs em partidas de futebol. São propostas novas funções de aptidão para defesa do gol e bloqueio de passes na liga SSL. Para o desenvolvimento dessas funções, princípios táticos de jogos do futebol moderno foram verificados. Para avaliar a efetividade das funções de otimização, são propostas novas métricas para mensurar o Índice de Performance do Posicionamento (IPOS) dos posicionamentos originais e otimizados. Essas métricas estão baseadas no Sistema de Avaliação Tática no Futebol (FUT-SAT) que define o Índice de Performance Tática (IPT) de uma equipe baseado em determinados critérios e posicionamentos em campo. Para avaliação da efetividade das funções de aptidão, foram selecionadas jogadas com gols efetivos da RoboCup 2019 – Liga A. Essas jogadas foram separadas do início do toque da bola até a finalização em gol em intervalos de 200 milissegundos e nomeadas de instantes. Para cada instante o posicionamento da defesa é otimizado. Ao final são aplicadas as métricas de avaliação do novo posicionamento e comparadas com as originais. A aplicação das métricas de avaliação e inspeção visual demonstram que os posicionamentos sugeridos poderiam ter impedido a continuidade da jogada em vários momentos antes da finalização ao gol. Os experimentos demonstraram a efetividade da otimização e das métricas. Finalmente, as funções de aptidão e métricas podem ser aplicadas em outras categorias de futebol de robôs.

Palavras-chave: Algoritmos de enxame. Futebol de robôs. Posicionamento por Otimização de enxame de partículas.

## ABSTRACT

The RoboFEI *Small Size League* (SSL) team was created in 2008. One of the motivations for the project is the application of knowledge in electronics, mechanics, and programming in the development of algorithms focused on Artificial Intelligence (AI). AI covers several techniques, such as learning, optimization, and bioinspired algorithms. Bioinspired algorithms are used for the most diverse purposes, including so that robots can work collaboratively. The SSL has evolved over the years. Some changes have already been made, such as increasing the size of the field and the number of robots. This evolution also brings greater possibilities for moves and increased complexity of a match. The positioning of robots in the field becomes essential as a defense and attack mechanism. In this scenario, this work proposes the use of the Particle Swarm Optimization (PSO) algorithm as a collective intelligence option applied to determine the positioning of robots in soccer matches. Fitness functions were proposed for defending the goal and blocking passes in the SSL. In order to develop these functions, tactical principles of modern soccer games were verified. To assess the effectiveness of the optimization, functions metrics proposed to measure the Positioning Performance Index (PPI) of the original and optimized positions.

These metrics based on the System of Tactical Assessment in Soccer (FUT-SAT) that defines the Tactical Performance Index (TPI) of a team based on specific criteria and positions in the field. To assess the effectiveness of the fitness functions, plays with effective goals from RoboCup 2019 – A league were selected. These plays were separated the match, from the beginning of the touch of the ball until the goal finish, at intervals of 200 milliseconds and called as “instants”. For each instant, the positioning of the defense is optimized. In the end, the evaluation metrics of the new positioning are applied and compared with the original. The evaluation and visual inspection metrics show that the suggested positions could have prevented the play’s continuation at several moments before the goal of the adversary team. The experiments demonstrated the effectiveness of optimization and metrics. Finally, we can apply fitness and metrics functions in other categories of soccer robots.

Keywords: Swarm algorithms. Robots soccer. Particle swarm optimization positioning.



## LISTA DE ILUSTRAÇÕES

Figura 1	– Componentes do futebol. . . . .	45
Figura 2	– Princípios Táticos Fundamentais do jogo de Futebol em função das fases. . . . .	47
Figura 3	– Formação 4–4–3 do futebol. . . . .	55
Figura 4	– Exemplo de formação 2–2–3 para robôs SSL. . . . .	56
Figura 5	– Dimensões do campo até 2017 (em mm). . . . .	56
Figura 6	– Dimensões dos campos (em mm). . . . .	57
Figura 7	– Dimensões do gol para 2018 (em mm). . . . .	57
Figura 8	– Dimensões de um robô SSL (em mm). . . . .	58
Figura 9	– Captura e propagação das localizações da bola e robôs em campo. . . . .	58
Figura 10	– Fluxograma do PSO. . . . .	66
Figura 11	– Mudança de posição de uma partícula no PSO. . . . .	68
Figura 12	– Exemplificação das mudanças ao longo das iterações. . . . .	69
Figura 13	– Pseudocódigo do PSO padrão. . . . .	70
Figura 14	– Diferentes topologias – Cada partícula é representada por um círculo. . . . .	74
Figura 15	– Ilustração do cálculo da linha de visão. . . . .	84
Figura 16	– Ilustração do cálculo área de atuação e área de perigo. . . . .	86
Figura 17	– Ilustração dos procedimentos para cálculo do RA e LA. . . . .	90
Figura 18	– Exemplo de jogada: chute a gol ou passe? . . . . .	95
Figura 19	– Ilustração das dimensões. . . . .	100
Figura 20	– Representação de uma população com 6 partículas. . . . .	101
Figura 21	– Transição defesa. . . . .	102
Figura 22	– Procedimento de otimização defensivo. . . . .	104
Figura 23	– Transição passe. . . . .	108
Figura 24	– Procedimento de otimização para bloqueio de passes . . . . .	111
Figura 25	– Formação 2–2–3 no futebol 8x8. . . . .	116
Figura 26	– Configurações do cenário: a) $c_1 = 1$ e $c_2 = 2$ ; b) $c_1 = 2$ e $c_2 = 1$ ; c) $c_1 = c_2 = 1$ ; d) $c_1 = c_2 = 2$ ; e) $c_1 = c_2 = 1.496$ . . . . .	118
Figura 27	– Exemplos de posicionamentos obtidos com os fatores de inércia propostos . . . . .	119
Figura 28	– Exemplos de posicionamentos ruins encontrados . . . . .	120
Figura 29	– % de interceptação em jogos da RoboCup . . . . .	121

Figura 30 – Exemplo de posicionamento . . . . .	122
Figura 31 – Possível posicionamento com valor mínimo. . . . .	123
Figura 32 – Resultado geral da RoboCup 2019 . . . . .	129
Figura 33 – Fluxograma do SSL–Referee para envio dos comandos. . . . .	130
Figura 34 – Fluxograma da sequência de experimentos. . . . .	133
Figura 35 – Análise da defesa – todas as dimensões. . . . .	134
Figura 36 – Defesa gol – Comparação entre os gols analisados. . . . .	135
Figura 37 – Análise da defesa – todas as dimensões. . . . .	136
Figura 38 – Bloqueio de passe – Comparação entre os gols analisados . . . . .	137
Figura 39 – Jogo 01 – Comparação jogo original com otimização – PSO em modo defesa. . . . .	139
Figura 40 – Jogo 01 – Jogada de gol – PSO em modo defesa . . . . .	140
Figura 41 – Jogo 01 – Jogada de gol (continuação) – PSO em modo defesa . . . . .	141
Figura 42 – Jogo 01 – Comparação da otimização original com a modificada – PSO em modo defesa. . . . .	141
Figura 43 – Jogo 01 – Comparação jogo original com otimização – PSO em modo passe. . . . .	142
Figura 44 – Jogo 01 – Comparação da otimização original com a modificada – PSO em modo passe. . . . .	143
Figura 45 – Jogo 01 – Jogada de gol – PSO em modo passe. . . . .	144
Figura 46 – Jogo 01 – Jogada de gol (continuação) – PSO em modo passe. . . . .	145
Figura 47 – Jogo 01 – Análise da qualidade do posicionamento (QR)– PSO em modo passe. . . . .	145
Figura 48 – Jogo 01 – Análise da localização em campo (LA) – PSO em modo passe.146	
Figura 49 – Jogo 01 – Análise do resultado da ação (RA) – PSO em modo passe. . .	146
Figura 50 – Jogo 01 – Posicionamento de defesa avaliada com métrica do passe – PSO em modo defesa. . . . .	146
Figura 51 – Jogo 01 – Posicionamento de passe avaliada com métrica da defesa – PSO em modo passe. . . . .	147
Figura 52 – Jogo 01 – Métrica de defesa e passe aplicada em conjunto – PSO em modo defesa. . . . .	147
Figura 53 – Jogo 01 – Métrica de defesa e passe aplicada em conjunto – PSO em modo passe. . . . .	148

Figura 54 – Jogo 01 – Sequência mostrando mudança de comportamento da equipe	148
Figura 55 – Jogo 02 – PSO em modo defesa.	150
Figura 56 – Jogo 02 – Jogada de gol – PSO em modo defesa	151
Figura 57 – Jogo 02 – PSO em modo passe.	151
Figura 58 – Jogo 02 – Jogada de gol – PSO em modo passe	152
Figura 59 – Jogo 02 – Função Defesa x Métrica Passe e Função Passe x Métrica Defesa.	153
Figura 60 – Jogo 02 – Avaliação das métricas em conjunto.	154
Figura 61 – Jogo 03 – Perda da bola e 1ºchute a gol	155
Figura 62 – Jogo 03 – Defesa 1ºchute a gol	156
Figura 63 – Jogo 03 – Defesa Perde o controle da bola.	157
Figura 64 – Jogo 03 – Passe e marcação do gol.	158
Figura 65 – Jogo 03 – Primeiro passe – PSO em modo defesa	159
Figura 66 – Jogo 03 – Comparação jogo original com otimização – PSO em modo defesa.	160
Figura 67 – Jogo 03 – Comparação da otimização original com otimização modificada – PSO em modo defesa.	160
Figura 68 – Jogo 03 – Segundo passe – PSO em modo defesa.	161
Figura 69 – Jogo 03 – Análise da qualidade do posicionamento (QR) – PSO em modo defesa.	162
Figura 70 – Jogo 03 – Primeiro passe – PSO em modo passe.	163
Figura 71 – Jogo 03 – Segundo passe – PSO em modo passe.	164
Figura 72 – Jogo 03 – Comparação jogo original com otimização – PSO em modo passe.	165
Figura 73 – Jogo 03 – Análise da qualidade do posicionamento (QR) – PSO em modo passe.	165
Figura 74 – Jogo 03 – Análise do resultado da ação (RA) – PSO em modo passe.	166
Figura 75 – Jogo 03 – Posicionamento de defesa avaliada com métrica do passe – PSO em modo defesa.	166
Figura 76 – Jogo 03 – Posicionamento de passe avaliada com métrica da defesa – PSO em modo passe.	167
Figura 77 – Jogo 03 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de defesa.	167

Figura 78 – Jogo 03 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de passe. . . . .	167
Figura 79 – Jogo 04 – Gol por cobrança de tiro direto. . . . .	169
Figura 80 – Jogo 04 – PSO em modo defesa . . . . .	170
Figura 81 – Jogo 04 – Comparação jogo original com otimização – PSO em modo defesa. . . . .	171
Figura 82 – Jogo 04 – Comparação da otimização original com otimização modificada – PSO em modo defesa. . . . .	171
Figura 83 – Jogo 04 – Análise da localização em campo (LA) – PSO em modo defesa.	171
Figura 84 – Jogo 04 – Análise da qualidade do posicionamento (QR) – PSO em modo defesa. . . . .	172
Figura 85 – Jogo 04 – PSO em modo defesa . . . . .	173
Figura 86 – Jogo 04 – Comparação jogo original com otimização – PSO em modo passe. . . . .	174
Figura 87 – Jogo 04 – Análise da qualidade do posicionamento (QR) – PSO em modo passe. . . . .	174
Figura 88 – Jogo 04 – Posicionamento de defesa avaliada com métrica do passe – PSO em modo defesa. . . . .	174
Figura 89 – Jogo 04 – Posicionamento de passe avaliada com métrica da defesa – PSO em modo passe. . . . .	175
Figura 90 – Jogo 04 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de defesa. . . . .	175
Figura 91 – Jogo 04 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de passe. . . . .	175
Figura 92 – Jogo 04 – Segundo gol – Comparação jogo original com otimização – PSO em modo defesa. . . . .	177
Figura 93 – Jogo 04 – Segundo gol – PSO em modo defesa . . . . .	178
Figura 94 – Jogo 04 – Segundo gol – Comparação jogo original com otimização – PSO em modo defesa avaliado com métrica de passe. . . . .	179
Figura 95 – Jogo 04 – Segundo gol – Comparação jogo original com otimização – PSO em modo passe. . . . .	179
Figura 96 – Jogo 04 – Segundo gol – PSO em modo passe . . . . .	180
Figura 97 – Jogo 04 – Segundo gol – PSO em modo passe . . . . .	181

Figura 98 – Jogo 05 – Primeiro gol – Comparação jogo original com otimização – PSO em modo defesa. . . . .	181
Figura 99 – Jogo 05 – Primeiro gol – PSO em modo defesa. . . . .	182
Figura 100 – Jogo 05 – Primeiro gol – Análise da qualidade do posicionamento (QR) – PSO em modo defesa. . . . .	182
Figura 101 – Jogo 05 – Primeiro gol – Análise da localização em campo (LA) – PSO em modo defesa. . . . .	183
Figura 102 – Jogo 05 – Primeiro gol – Comparação jogo original com otimização – PSO em modo passe. . . . .	183
Figura 103 – Jogo 05 – Primeiro gol – Adversários com visão bloqueada para passe – PSO em modo passe. . . . .	184
Figura 104 – Jogo 05 – Primeiro gol – Análise da qualidade do posicionamento (QR)– PSO em modo passe. . . . .	184
Figura 105 – Jogo 05 – Primeiro gol – Análise do resultado da ação (RA)– PSO em modo passe. . . . .	185
Figura 106 – Jogo 05 – Primeiro gol – Posicionamento defesa analisado com métrica do passe – PSO em modo defesa. . . . .	185
Figura 107 – Jogo 05 – Primeiro gol – Posicionamento passe analisado com métrica da defesa – PSO em modo passe. . . . .	185
Figura 108 – Jogo 05 – Segundo – Comparação jogo original com otimização – PSO em modo defesa. . . . .	186
Figura 109 – Jogo 05 – Segundo gol – PSO em modo defesa. . . . .	187
Figura 110 – Jogo 05 – Segundo gol – PSO em modo defesa. . . . .	187
Figura 111 – Jogo 05 – Segundo gol – Comparação jogo original com otimização – PSO em modo passe. . . . .	188
Figura 112 – Jogo 05 – Segundo gol – PSO em modo passe. . . . .	189
Figura 113 – Jogo 05 – Segundo gol – PSO em modo passe. . . . .	189
Figura 114 – Jogo 05 – Segundo gol – Análise da qualidade do posicionamento (QR) – PSO em modo passe. . . . .	190
Figura 115 – Jogo 05 – Segundo gol – Posicionamento defesa analisado com métrica do passe – PSO em modo defesa. . . . .	190
Figura 116 – Jogo 05 – Segundo gol – Posicionamento passe analisado com métrica da defesa – PSO em modo passe. . . . .	191

Figura 117 – Jogo 06 – Início do jogo. . . . .	191
Figura 118 – Jogo 06 – Gráficos de análise. . . . .	192
Figura 119 – Jogo 06 – Gráficos de análise. . . . .	192
Figura 120 – Jogo 07 – Início do jogo – Primeiro gol. . . . .	193
Figura 121 – Jogo 07 – Início do jogo – Segundo gol – robôs amarelos não se moveram.193	
Figura 122 – Divisão do campo em áreas. . . . .	195
Figura 123 – População original. . . . .	197
Figura 124 – População corrigida. . . . .	198
Figura 125 – Janelas em campo. . . . .	199
Figura 126 – Bloqueio de Passe. . . . .	200
Figura 127 – Defesa de gol. . . . .	200

## LISTA DE TABELAS

Tabela 1 – Sites com conteúdo sobre o PSO. . . . .	35
Tabela 2 – Princípios Táticos do Jogo de Futebol. . . . .	46
Tabela 3 – Categorias, sub-categorias, variáveis latentes e definições utilizadas para a avaliação do comportamento tático de jogadores de Futebol . . .	80
Tabela 4 – Categorias, sub-categorias, variáveis latentes e variáveis observadas relacionados à Localização e ao Resultado da ação tática . . . . .	81
Tabela 5 – Componentes e valores considerados para o cálculo do IPT no FUT–SAT	82
Tabela 6 – Tabela de penalizações. . . . .	99
Tabela 7 – Tabela de definições. . . . .	99
Tabela 8 – Partidas analisadas da RoboCup 2019 – Austrália . . . . .	126
Tabela 9 – Galeria da Fama da SSL. . . . .	127
Tabela 10 – Galeria da Fama da SSL considerando as edições 2015–2019. . . . .	128



## LISTA DE ABREVIATURAS

AE	Algoritmos Evolutivos
CBR	<i>Case-Based Reasoning</i> (Raciocínio baseado em casos)
DRL	<i>Deep Reinforcement Learning</i>
FEI	Centro Universitário da FEI
FUT–SAT	Sistema de Avaliação Tática no Futebol
grSim	<i>Robocup Small Size Robot Soccer</i>
IA	Inteligência Artificial
IEEE	<i>Institute of Electrical and Electronics Engineers</i> (Instituto de Engenheiros Eletricistas e Eletrônicos)
IPOS	Índice de Performance do Posicionamento
IPT	Índice de Performance Tática
LA	Localização da Realização da Ação Tática no Campo de Jogo
LARC	<i>Latin American Robotics Competition</i>
LFO	<i>Learning from Observation</i>
MSL	<i>Middle Size League</i>
PSO	<i>Particle Swarm Optimization</i> (Otimização de Enxame de Partículas)
QR	Qualidade de Realização da Ação Tática
RA	Resultado da Ação Tática
RL	<i>Reinforcement Learning</i>
RNAS	Redes neurais artificiais
RoboCup	<i>Robot Soccer World Cup</i>
RP	Realização do Princípio Tático
RRT	<i>Rapidly-exploring random tree</i>
SBSP	<i>Situation-Based Strategic Positioning</i> (Posicionamento Estratégico Baseado em Situação)
SI	<i>Swarm Intelligence</i> (Inteligência de Exame)
SLPSO	<i>Self-adaptive learning based particle swarm optimization</i>
SPAR	<i>Strategic Positioning by Attraction and Repulsion</i> (Posicionamento Estratégico por Atração e Repulsão)
SRC	<i>Selectively Re-active Coordination</i> (Coordenação Seletiva Reativa)
SSL	<i>Small Size League</i>

SSL-Referee *Referee for the RoboCup Small Size League*

SSL-Vision *Shared Vision System for the RoboCup Small Size League*

SVR *Support Vector Regression*

## LISTA DE SÍMBOLOS

$\wedge$	E lógico
$\sphericalangle$	Visão angular
$A$	Conjunto de adversários
$a$	Adversário do conjunto A
$D$	Conjunto de defensores
$d$	Defensor do conjunto D
$bola$	Representa a posição da bola em campo
$gol$	Representa o gol ou outra posição em campo
$side$	Representa o lado da defesa
$P$	Partícula que representa o conjunto de defensores na otimização
$p$	Defensor otimizado que compõem a partícula $P$
$IPOS_d$	Índice de Performance do Posicionamento para defesa
$IPOS_p$	Índice de Performance do Posicionamento para passe
$LA_d$	Localização da Realização da Ação Tática no Campo de Jogo para a defesa
$LA_p$	Localização da Realização da Ação Tática no Campo de Jogo para o passe
$\vee$	OU lógico
$\downarrow_1^9$	Ordenação do maior para o menor
$QR_d$	Qualidade de Realização da Ação Tática para a defesa
$QR_p$	Qualidade de Realização da Ação Tática para o passe
$RA_d$	Resultado da Ação Tática para a defesa



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	29
1.1	MOTIVAÇÕES E JUSTIFICATIVAS	31
1.2	DELIMITAÇÃO DO PROBLEMA	32
1.3	OBJETIVOS	33
1.4	CONTRIBUIÇÕES	33
1.5	ESCOLHA DO ALGORITMO DE OTIMIZAÇÃO	34
1.6	PESQUISAS NA ÁREA	36
1.7	CONSIDERAÇÕES DO CAPÍTULO	41
<b>2</b>	<b>CONCEITOS SOBRE FUTEBOL DE ROBÔS E HUMANO</b>	43
2.1	MOTIVAÇÃO	43
<b>2.1.1</b>	<b>Características do futebol humano</b>	44
2.2	CONSTRUÇÃO DE TIMES DE ROBÔS	47
<b>2.2.1</b>	<b>Características e requisitos</b>	48
<b>2.2.2</b>	<b>Habilidades necessárias para um robô jogar futebol</b>	50
<b>2.2.2.1</b>	<b><i>Movimentação</i></b>	50
<b>2.2.2.2</b>	<b><i>Chutar uma bola parada</i></b>	51
<b>2.2.2.3</b>	<b><i>Passar a bola para colega de equipe</i></b>	51
<b>2.2.2.4</b>	<b><i>Chutar uma bola em movimento</i></b>	51
<b>2.2.2.5</b>	<b><i>Passar a bola em movimento para um robô em movimento</i></b>	52
<b>2.2.2.6</b>	<b><i>Desviar de obstáculos</i></b>	52
<b>2.2.3</b>	<b>Posicionamento em campo</b>	52
2.3	SMALL SIZE LEAGUE – SSL	55
<b>2.3.1</b>	<b>Regras da SSL</b>	59
2.4	FUTURO DA SSL	60
2.5	CONSIDERAÇÕES DO CAPÍTULO	61
<b>3</b>	<b>INTELIGÊNCIA DE ENXAME</b>	63
3.1	INTRODUÇÃO AO SI	63
3.2	<i>Particle Swarm Optimization</i> (Otimização de Enxame de Partículas) (PSO)	65
<b>3.2.1</b>	<b>Definições do PSO</b>	65
<b>3.2.2</b>	<b>O algoritmo</b>	66
<b>3.2.3</b>	<b>Considerações sobre alguns parâmetros do algoritmo</b>	69

3.2.4	<b>Topologias</b>	73
3.2.5	<b>Variantes do PSO</b>	75
3.3	CONSIDERAÇÕES DO CAPÍTULO	76
4	<b>NOVA MÉTRICA PARA AVALIAÇÃO DOS POSICIONAMENTOS</b>	77
4.1	IMPORTÂNCIA DOS PRINCÍPIOS TÁTICOS	77
4.2	SISTEMA DE AVALIAÇÃO TÁTICA NO FUTEBOL – FUT–SAT	78
4.3	TRABALHOS RELACIONADOS	81
4.4	NOVA MÉTRICA	82
4.4.1	<b>Equações auxiliares</b>	83
4.4.2	<b>Avaliação de proteção da baliza</b>	87
4.4.3	<b>Avaliação de bloqueio de passes</b>	90
4.5	CONSIDERAÇÕES DO CAPÍTULO	94
5	<b>NOVAS FUNÇÕES DE APTIDÃO PARA APLICAÇÃO EM POSICIONAMENTOS DEFENSIVOS</b>	97
5.1	IMPORTÂNCIA E ESCOPO	97
5.2	DEFINIÇÕES E PUNIÇÕES	98
5.3	REPRESENTAÇÃO DE UMA SOLUÇÃO	99
5.4	OTIMIZAÇÃO DE DEFESA	100
5.4.1	<b>Diminuir o espaço do adversário</b>	103
5.4.2	<b>Bloqueio da visão de pontos de interesse</b>	105
5.4.3	<b>Bloqueio do portador da bola</b>	106
5.4.4	<b>Respeito as regras da SSL</b>	107
5.5	OTIMIZAÇÃO DO PASSE	108
5.5.1	<b>Raio de ação do portador da bola</b>	110
5.5.2	<b>Raio de atuação dos adversários</b>	112
5.5.3	<b>Visão dos companheiros de equipe pelo portador da bola</b>	112
5.5.4	<b>Visão dos companheiros de equipe entre si</b>	113
5.5.5	<b>Verificar se os robôs estão no raio de ação dos demais robôs da equipe</b>	113
5.6	CONSIDERAÇÕES DO CAPÍTULO	114
6	<b>SELEÇÃO DOS PARÂMETROS DO ALGORITMO PSO</b>	115
6.1	MOVIMENTAÇÃO DAS PARTÍCULAS	115
6.2	PARÂMETROS DO ALGORITMO	116
6.3	VERIFICAÇÃO VISUAL	119

6.4	VALIDAÇÃO INICIAL . . . . .	120
6.5	CONSIDERAÇÕES DO CAPÍTULO . . . . .	122
<b>7</b>	<b>ANÁLISE DAS APLICAÇÕES DAS FUNÇÕES DE APTIDÃO E MÉTRICAS</b>	<b>125</b>
7.1	JOGOS ESCOLHIDOS PARA ANÁLISE . . . . .	125
7.2	ANÁLISE DOS REGISTROS HISTÓRICOS . . . . .	125
7.3	INFORMAÇÕES SOBRE A CONFIGURAÇÃO DOS EXPERIMENTOS . . . . .	129
7.4	RESULTADOS CONSOLIDADOS . . . . .	132
7.5	JOGO 01 – UPPER FINAL . . . . .	138
<b>7.5.1</b>	<b>Análise da defesa . . . . .</b>	<b>138</b>
<b>7.5.2</b>	<b>Análise do passe . . . . .</b>	<b>142</b>
<b>7.5.3</b>	<b>Análise defesa – métrica do passe . . . . .</b>	<b>143</b>
<b>7.5.4</b>	<b>Análise passe – métrica da defesa . . . . .</b>	<b>145</b>
<b>7.5.5</b>	<b>Análise conjunta das métricas – passe e defesa . . . . .</b>	<b>146</b>
<b>7.5.6</b>	<b>Discussão e análises . . . . .</b>	<b>147</b>
7.6	JOGO 02 – LOWER 3 . . . . .	149
<b>7.6.1</b>	<b>Análise da defesa . . . . .</b>	<b>149</b>
<b>7.6.2</b>	<b>Análise do passe . . . . .</b>	<b>151</b>
<b>7.6.3</b>	<b>Análise defesa – métrica do passe . . . . .</b>	<b>152</b>
<b>7.6.4</b>	<b>Análise passe – métrica da defesa . . . . .</b>	<b>153</b>
<b>7.6.5</b>	<b>Análise conjunta das métricas – passe e defesa . . . . .</b>	<b>153</b>
<b>7.6.6</b>	<b>Discussão e análises . . . . .</b>	<b>154</b>
7.7	JOGO 03 – UPPER 2–2 . . . . .	154
<b>7.7.1</b>	<b>Análise da defesa . . . . .</b>	<b>156</b>
<b>7.7.2</b>	<b>Análise do passe . . . . .</b>	<b>159</b>
<b>7.7.3</b>	<b>Análise da defesa – métrica do passe . . . . .</b>	<b>162</b>
<b>7.7.4</b>	<b>Análise do passe – métrica da defesa . . . . .</b>	<b>162</b>
<b>7.7.5</b>	<b>Análise conjunta das métricas – passe e defesa . . . . .</b>	<b>163</b>
<b>7.7.6</b>	<b>Discussão e análises . . . . .</b>	<b>164</b>
7.8	JOGO 04 – LOWER 2–1 - Primeiro gol . . . . .	168
<b>7.8.1</b>	<b>Análise da defesa . . . . .</b>	<b>168</b>
<b>7.8.2</b>	<b>Análise do passe . . . . .</b>	<b>171</b>
<b>7.8.3</b>	<b>Análise defesa – métrica do passe . . . . .</b>	<b>172</b>
<b>7.8.4</b>	<b>Análise passe – métrica da defesa . . . . .</b>	<b>173</b>

7.8.5	<b>Análise conjunta das métricas – passe e defesa</b>	174
7.8.6	<b>Discussão e análises</b>	176
7.9	JOGO 04 – LOWER 2–1 – Segundo gol	176
7.9.1	<b>Análise defesa</b>	176
7.9.2	<b>Análise do passe</b>	177
7.9.3	<b>Discussão e análises</b>	178
7.10	JOGO 05 – A1–A2 – Primeiro gol	180
7.10.1	<b>Análise defesa</b>	181
7.10.2	<b>Análise do passe</b>	182
7.10.3	<b>Discussão e análises</b>	184
7.11	JOGO 05 – A1–A2 – Segundo gol	186
7.11.1	<b>Análise defesa</b>	186
7.11.2	<b>Análise do passe</b>	187
7.11.3	<b>Discussão e análises</b>	188
7.12	JOGO 06 – LOWER 3	190
7.13	JOGO 07 – B3–B4	192
7.14	ANÁLISES GERAIS E POSSÍVEIS APRIMORAMENTOS	194
7.15	CONSIDERAÇÕES FINAIS DO CAPÍTULO	197
<b>8</b>	<b>CONCLUSÃO</b>	<b>203</b>
8.1	TRABALHOS FUTUROS	203
8.1.1	<b>Novas métricas e funções de aptidão</b>	<b>204</b>
8.1.2	<b>Estratégia para defesa ou ataque</b>	<b>204</b>
8.1.3	<b>Aplicação de outros algoritmos</b>	<b>205</b>
	<b>REFERÊNCIAS</b>	<b>206</b>
	<b>APÊNDICE A – FUNÇÕES MATEMÁTICAS AUXILIARES</b>	<b>223</b>
A.1	VERIFICAÇÃO DE EXISTÊNCIA DE RETA	224
A.2	VERIFICAR SE UM PONTO ESTÁ ESQUERDA OU DIREITA	224
A.3	DISTÂNCIA EUCLIDIANA	224
A.4	CÁLCULO DE PONTO MÉDIO	224
A.5	DISTÂNCIA DE UM PONTO A RETA	225
A.6	ÁREA DE UM CÍRCULO	225
A.7	ÁREA DE INTERSEÇÃO DE DOIS CÍRCULOS	225
A.8	VERIFICAÇÃO DE RAIOS	226





## 1 INTRODUÇÃO

Na teoria dos jogos, um conjunto completo de opções que está disponível para jogadores em qualquer situação para atingir o objetivo é considerado uma estratégia (OSBORNE, 2003). O resultado dessa estratégia depende não apenas das ações de um jogador individual, mas também das ações dos demais jogadores ou elementos do jogo.

A estratégia pode ser considerada qualquer mapeamento ou descrição do espaço conhecido ou posições geográficas de objetos localizados nele. Um conjunto finito de regras dizem como esses objetos podem se comportar em determinadas situações. Esse princípio pode ser aplicado a várias áreas do mundo real e é geralmente chamado de planejamento estratégico.

O futebol de robôs contém vários desafios nas áreas de controle de robôs, análise de imagens e planejamento estratégico. A estratégia é fundamentalmente conectada com jogos de futebol de robôs. A ideia básica de futebol de robôs é o mesmo que no futebol real, ou seja, vencer o oponente pelo número de gols marcados. Como no futebol humano, o time que geralmente vence é o equipe com a melhor estratégia.

Com objetivos acadêmicos e científicos, a ideia de utilizar robôs para realizar partidas de futebol incentivam a realização de pesquisas na área de robótica autônoma multiagente e permite a implantação de sistemas experimentais de baixo custo no ambiente universitário. A construção de um time de futebol de robôs envolve a integração de diversas tecnologias e áreas de conhecimento, como projeto de agentes autônomos, cooperação em sistemas multiagentes, estratégias de aquisição de conhecimento, sistemas de tempo real, sistemas distribuídos, reconhecimento de padrões, integração de sensores, aprendizado, robótica móvel, entre outras. A *Robot Soccer World Cup* (RoboCup) é uma competição de robótica projetada para incentivar a pesquisa de técnicas de Inteligência Artificial (IA) por meio de jogos amigáveis (ROBOCUP, 2015).

No futebol de robôs, os robôs são autônomos ou seja, jogam de acordo com suas estratégias previamente programadas. Os jogos de futebol de robôs podem ser divididos em dois tipos principais: jogos com controle individual e jogos com controle centralizado. Nos jogos com controle individual, os jogadores são considerados agentes independentes. Cada jogador só tem informações sobre seus arredores, que na maioria dos casos contém informações simuladas da visão do jogador. Cada jogador também tem sua própria estratégia ou um conjunto de regras que define como deve se comportar na atual situação.

Uma situação significa informações sobre os objetos que estão atualmente no campo de visão do jogador.

O segundo tipo de jogo envolve jogos com controle centralizada, onde há um elemento central que tem informações sobre todos os objetos localizados no campo em cada etapa do jogo. O comportamento dos robôs, em determinadas situações, são controlados por um sistema de estratégia que comanda todos os robôs da equipe utilizando informações disponíveis, globalmente, como coordenadas da bola ou as coordenadas e rotações dos robôs que descrevem a situação atual do campo de jogo.

Na competição de futebol *Small Size League* (SSL), que é uma das diversas competições dentro da RoboCup, o controle dos robôs é centralizado. A SSL tem como foco principal o problema da cooperação e controle multiagente inteligente em um ambiente dinâmico. Um jogo de futebol de robôs na SSL consiste em uma arena, um servidor que captura as informações em campo e envia aos computadores das equipes, duas equipes, e um operador humano que atua como técnico, junto ao computador responsável por receber as informações do servidor e executar a estratégia de jogo previamente programada (ROBOCUP, 2015). Atualmente, a SSL está passando por várias modificações nas suas regras, que aumentam a dinâmica e a complexidade de uma partida de futebol. O aumento nas dimensões do campo e quantidade de robôs permitirá novas estratégias de jogo, e o posicionamento em campo também se torna mais complexo. Um correto posicionamento em campo é relevante para o sucesso estratégico de uma equipe de futebol (COSTA et al., 2009).

O projeto RoboFEI existe desde 2003, quando começou a projetar, desenvolver e aprimorar projetos de robótica para competir nas categorias de futebol de robôs da *Institute of Electrical and Electronics Engineers* (Instituto de Engenheiros Eletricistas e Eletrônicos) (IEEE) e RoboCup. A equipe SSL, criada em 2008, sagrou-se campeã brasileira pela primeira vez em 2010 e atualmente é heptacampeã (2010–2015, 2019). Participa do mundial desde 2009 e a melhor colocação (oitava) foi obtida em 2012.

Em termos práticos, as estratégias são aplicadas utilizando vários métodos (HUANG; YANG; CHEN, 2002; RIEDMILLER et al., 2001; KLEINER; DIETL; NEBEL, 2003; MIENE; VISSER; HERZOG, 2004; WU; LEE, 2004; KONUR et al., 2004; LEE et al., 2005; LATTNER et al., 2006; NAKASHIMA et al., 2006; LAM; ESFANDIARI; TUDINO, 2006; JOLLY et al., 2007; PARK et al., 2007; ROS et al., 2009). Por exemplo, estratégias baseadas em árvores de decisão onde as ações são selecionadas com base na posição dos

robôs em relação à bola, portador da bola, a distância para a área do gol, entre outras. Outro método frequentemente usado é uma estratégia baseada na lógica *fuzzy*, onde as situações de jogo são divididas em vários níveis e diferentes tipos de comportamentos correspondentes são atribuídos aos robôs. Outras estratégias utilizam métodos estratégicos de controle de robôs baseados em *Case-Based Reasoning* (Raciocínio baseado em casos) (CBR), que é uma técnica da Inteligência Artificial (IA) que cataloga a experiência em casos e combina o problema atual com a experiência prévia.

Pode-se encontrar combinações das abordagens mencionadas anteriormente ou mesmo outras abordagens diferentes. Mas a ideia principal continua a mesma: criar um sistema que responda o mais rapidamente possível a mudanças de situações durante uma partida de futebol pela melhor realocação e controle dos robôs em campo. Nesse contexto, é necessário usar técnicas que resolvam problemas com custo computacional eficiente. Algoritmos de otimização baseados em enxame permitem essa abordagem (BINITHA; SATHYA et al., 2012; DARWISH, 2018).

Na literatura podem ser encontrados muitos trabalhos envolvendo algoritmos de enxame e robótica. A *Swarm Intelligence* (Inteligência de Exame) (SI) originou-se do estudo de colônias, ou enxames de organismos sociais. Estudos sobre o comportamento social dos organismos (indivíduos) em enxames inspirou o desenvolvimento de algoritmos de otimização eficientes (BINITHA; SATHYA et al., 2012; DARWISH, 2018). Por exemplo, estudos de simulações da graciosa, mas imprevisível, coreografia de bandos de pássaros motivaram o desenvolvimento do algoritmo de otimização de enxame por partículas. O *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO) proposto por J. Kennedy e R. Eberhart (1995) é um algoritmo de otimização baseado em população de partículas que tem obtido reconhecimento na solução de diversos problemas, com simplicidade e utilizando poucos recursos computacionais.

## 1.1 MOTIVAÇÕES E JUSTIFICATIVAS

Conforme exposto em Weitzenfeld et al. (2015), a SSL passará por várias mudanças, destacando-se o aumento da quantidade de robôs em campo ( $11 \times 11$ ) prevista para ocorrer até 2021. Logo, as equipes deverão revisar suas estratégias de jogo e, com aumento da complexidade de jogo, é factível afirmar que equipes com estratégias basea-

das apenas em jogadas previamente programadas estarão em desvantagem em relação a equipes que utilizarem estratégias adaptativas durante uma partida.

As pesquisas na área da SSL concentram-se basicamente na análise dos registros históricos das partidas em conjunto com algoritmos de aprendizado, para identificar e classificar os conjuntos de jogadas dos adversários. Alguns exemplos podem ser encontrados em (VISSER; WELAND, 2002; BOWLING; BROWNING; VELOSO, 2004; TREVIZAN; VELOSO, 2010; YASUI et al., 2014; WEITZENFELD et al., 2015; QUINTERO et al., 2015; MENDOZA et al., 2016; MENDOZA; SIMMONS; VELOSO, 2016; ADACHI; ITO; NARUSE, 2017).

No futebol moderno, jogadas de bola parada (escanteios, faltas ou lançamentos) aumentam as chances ofensivas das equipes. Representam  $\approx 40\%$  dos gols durante um jogo. Nesse momento os jogadores conhecem o posicionamento da sua equipe e do adversário. A equipe com jogada a seu favor tenta desorganizar o adversário para obter o êxito enquanto a equipe adversária exerce uma ação contrária.

Para Costa et al. (2009), uma equipe de futebol deve-se adaptar a dinâmica do jogo tentando encontrar situações mais favoráveis para a equipe, e o correto posicionamento faz parte da estratégia de adaptação perante equipes mais ofensivas. O aprendizado prévio de jogadas de equipes adversárias têm-se mostrado efetivos (QUINTERO et al., 2015; YOON; BEKKER; KROON, 2016; OLLINO; SOLIS; ALLENDE, 2018; LARIK; HAIDER, 2018), mas a complexidade de uma partida de futebol indica a necessidade de soluções que possam se adaptar a estratégia da equipe adversária durante a realização do jogo. Nesse contexto, é necessário o uso de técnicas que resolvam problemas com tempo de processamento e custo computacional eficientes. Algoritmos de otimização de enxame permitem essa abordagem. Trabalhos envolvendo inteligência de enxame e algoritmos robóticos podem ser encontrados na literatura (WANG et al., 2006; SASKA et al., 2006; OKADA; WADA; YAMASHITA, 2011; LARIK; HAIDER, 2018).

## 1.2 DELIMITAÇÃO DO PROBLEMA

Nesse trabalho, foi considerado o ambiente do SSL para aplicação da pesquisa ou seja, em um ambiente de controle centralizado onde é possível conhecer todas as variáveis do jogo de futebol.

O conceito de camada superior e inferior é utilizado. A camada superior é responsável por decisões estratégicas tais como decidir qual robô irá atacar a bola ou qual irá receber ou cobrar um passe. A camada inferior é responsável pela operacionalização da estratégia, como planejamento das rotas ou o posicionamento em campo.

### 1.3 OBJETIVOS

O objetivo geral deste trabalho é o estudo de algoritmo baseado em inteligência coletiva e proposição de regras para a otimização de posições defensivas dos jogadores no futebol de robôs. Essas posições defensivas deverão respeitar os critérios do futebol moderno. Para alcançar o objetivo geral, tem-se os seguintes objetivos específicos:

- a) Estudo do algoritmo de otimização *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO);
- b) Proposição de funções de aptidão para defesa do gol e bloqueio de passes;
- c) Avaliação dos parâmetros de configuração do algoritmo PSO;
- d) Estudo dos critérios estratégicos aplicados no futebol humano atual;
- e) Avaliação e proposição de métricas para análise de posicionamentos baseadas em critérios aplicados no futebol humano;
- f) Aplicação das funções na categoria SSL.

### 1.4 CONTRIBUIÇÕES

A contribuição principal deste trabalho é a proposição de funções de aptidão ou avaliação para encontrar posições defensivas para defesa do gol e bloqueio de passes. Essas funções podem ser aplicadas em várias categorias do futebol de robôs. Vários grupos de pesquisa estudam técnicas de aprendizado para encontrar posicionamentos de robôs em campos de futebol. Essa contribuição vai na contra mão de outras pesquisas na área focadas principalmente em algoritmos de aprendizado, onde é necessário o conhecimento prévio das equipes adversárias.

A otimização permite encontrar boas posições defensivas em campo sem esse conhecimento prévio. Para isto, basta conhecer apenas as posições atuais ou futuras dos jogadores em campo.

Outra contribuição foi a definição dos parâmetros ideais para a execução do algoritmo de otimização. Embora existam parâmetros considerados canônicos, cada problema tem suas características e espaço de busca distintos que são influenciados pela configuração do algoritmo.

Finalmente, a terceira contribuição foi a proposição de métricas para avaliar posicionamentos em campo e suas expectativas de sucesso. Esses critérios foram baseados em métricas aplicadas no futebol humano e avaliam várias características defensivas do futebol moderno.

## 1.5 ESCOLHA DO ALGORITMO DE OTIMIZAÇÃO

O *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO) está entre os algoritmos de otimização heurística universalmente mais aplicados. Tem sido utilizado com sucesso em vários campos científicos, desde humanidades, engenharias, química, medicina até física avançada. Desde sua introdução em 1995, o método tem sido amplamente investigado, o que levou ao desenvolvimento de centenas de versões e a numerosas descobertas teóricas e empíricas sobre sua convergência e parametrização (PIOTROWSKI; NAPIORKOWSKI; PIOTROWSKA, 2020).

Nessa tese, o algoritmo PSO foi escolhido, após análise comparativa com outros algoritmos bioinspirados, como algoritmo base devido a uma série de características: é um algoritmo versátil, aplicado em várias áreas do conhecimento; converge rapidamente para um conjunto de respostas satisfatórias; em comparação com outros algoritmos de otimização, como os evolutivos, o PSO possui baixo custo computacional, é menos complexo e requer um pequeno número de parâmetros para ser otimizado; em comparação com outros algoritmos heurísticos, o PSO permite uma maior flexibilização entre a exploração local e a global no espaço de busca desejado.

Pesquisas em sites especializados com o termo *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO) obtém mais de 50.000 resultados considerando apenas o período 2015–2019. Estão disponíveis vários sites públicos relacionados ao PSO dedicados a compartilhar códigos, ideias e os últimos avanços do PSO (tabela 1). Nesses sites, e diversos outros, estão disponíveis vários tipos de códigos-fonte, escritas em diferentes linguagens de programação e muitas publicações sobre PSO e suas aplicações.

Tabela 1 – Sites com conteúdo sobre o PSO.

Site	URL
Particle swarm optimization	<a href="http://www.swarmintelligence.org/">http://www.swarmintelligence.org/</a>
Particle swarm optimization	<a href="http://www.scholarpedia.org/article/Particle_swarm_optimization">http://www.scholarpedia.org/article/Particle_swarm_optimization</a>
Particle swarm central	<a href="http://www.particleswarm.info/">http://www.particleswarm.info/</a>
PSO toolbox	<a href="http://psotoolbox.sourceforge.net/">http://psotoolbox.sourceforge.net/</a>
Particle swarm optimization	<a href="https://en.wikipedia.org/wiki/Particle_swarm_optimization">https://en.wikipedia.org/wiki/Particle_swarm_optimization</a>
ATOMS : Particle Swarm Optimization Toolbox	<a href="http://atoms.scilab.org/toolboxes/PSO">http://atoms.scilab.org/toolboxes/PSO</a>

Fonte: Autor

Embora seja um dos primeiros algoritmos de otimização criados, o PSO ainda é considerado um dos melhores algoritmos na área (LINDFIELD; PENNY, 2017). Vários pesquisadores conduzem pesquisas nas mais diversas áreas utilizando o PSO ou alguma de suas diversas variações (ZHANG; WANG; JI, 2015; PIOTROWSKI; NAPIORKOWSKI; PIOTROWSKA, 2020). Wahab, Nefti-Meziani e Atyabi (2015) afirmam, após a comparação de vários algoritmos, que o PSO está entre os melhores algoritmos de otimização.

Por exemplo, Almeida e Leite (2019) analisam o PSO como uma ótima solução para resolução de problemas de engenharia. Já Quan et al. (2015) e Shaari, Tekbiyik-Ersoy e Dagbasi (2019) afirmam que o PSO é robusto para soluções não diferenciáveis, problemas não-lineares, de alta dimensão através de simples procedimentos com alta velocidade de convergência.

Outras pesquisas compararam o PSO com outras técnicas para resolução de problemas específicos em diversas áreas e concluíram que o PSO era boa escolha ou obtinham resultados equivalentes (LEE; KIM, 2015; JIA; LICHTI, 2017; BARMPALEXIS et al., 2018).

Finalmente, Ma et al. (2015) compararam vários algoritmos em diversas situações, incluindo o PSO, e chegaram na conclusão que os resultados das simulações demonstraram que seus níveis de desempenho são bastante diferentes nas condições avaliadas, pois cada algoritmo mantém suas próprias distinções quando implementados em sua forma padrão e concluem que resultados divergentes simplesmente confirmam que o desempenho depende fortemente de variações algorítmicas e a seleção de problemas.

## 1.6 PESQUISAS NA ÁREA

O primeiro estudo abrangente do problema de posicionamento em futebol de robôs foi realizado por Stone, Veloso e Riley (1999) e aplicado na liga de simulação da RoboCup. Nesse método, chamado de *Strategic Positioning by Attraction and Repulsion* (Posicionamento Estratégico por Atração e Repulsão) (SPAR), a posição de referência de nível superior pode ser considerada como um ponto fixo no campo atribuído a cada jogador em relação ao seu papel no posicionamento da equipe. O nível superior era responsável por decisões de drible, passe ou chute. Para cada jogador, o controle inferior lida com a posição objetivo, que é o ponto no campo em que os fatores de atração e repulsão atingem algum equilíbrio. Isso permite que o jogador saia de sua posição original para a objetivo calculada com relação à situação atual. Esse método provou ser um bom começo, pois permitiu a equipe CMUnited sagrar-se campeã na liga simulada em 1998. Porém, mais tarde o modelo foi abandonado pela pouca flexibilidade no nível superior de controle.

Um método mais sofisticado, chamado *Situation-Based Strategic Positioning* (Posicionamento Estratégico Baseado em Situação) (SBSP), foi proposto por Reis, Lau e Oliveira (2001) e abordou essas deficiências de alto nível. Nesse trabalho, o sistema define posições de alvo específicas para robôs que não possuem a bola; essas posições-alvo são calculadas com relação à formação atual da equipe e aos papéis dos robôs. Para situações ativas, a posição do robô no campo é calculada verificando se a equipe está com a posse de bola, se é necessário a recuperação da bola ou se o jogo está parado. Para calcular a nova posição, é analisada a situação do jogo, tática e formação, posicionamento atual e o papel do jogador correspondente. Esta posição é então ajustada de acordo com a posição da bola e velocidade, situação (ataque, defesa, oportunidade de pontuação) e papel do jogador. O sistema então emite um comando que move os robôs para esse novo posicionamento. Esse comportamento permite que a equipe se mova de maneira semelhante a um time de futebol real, mantendo a bola bem coberta enquanto a equipe permanece distribuída ao longo do campo. Porém, o desenvolvimento que se seguiu não demonstrou melhoria no nível de controle inferior.

A equipe UvA Trilearn (BOER; KOK, 2002), implementou um método de posicionamento para jogadores um pouco mais simples. Esse método está localizado na camada de controle superior. A qualquer momento, a posição de referência é determinada como uma soma ponderada da posição inicial do jogador na formação e localização atual da

bola. Portanto, essa posição está mudando ao longo do tempo e mantém a localização relativa dos jogadores na formação, implementando a estratégia da equipe. Porém, esse método não leva em consideração detalhes, como a oportunidade de receber um passe. Com isso, o método foi aprimorado usando os chamados gráficos de coordenação (KOK; SPAAN; VLASSIS, 2003). Esse modelo de nível inferior combina a tomada de decisões sobre passar bola e receber passes e permitiu que a equipe fosse campeã na liga de simulação em 2003.

Outras técnicas foram aplicadas na tomada de decisão de jogos de futebol de robôs, incluindo Raciocínio Baseado em Casos, Aprendizado com Observação, Aprendizado por Reforço, Reconhecimento de Padrões, Teoria *Fuzzy*, Rede Neural, Algoritmos Evolucionários, Árvores de Decisão, entre outras aplicadas em pesquisas de futebol de robôs.

O *Case-Based Reasoning* (Raciocínio baseado em casos) (CBR), uma das técnicas de IA baseadas na solução de problemas humanos, na qual novos problemas são resolvidos através da recuperação e adaptação de soluções de problemas anteriores semelhantes (RUSSELL; NORVIG, 2010). Dada uma nova situação, o caso anterior mais semelhante é recuperado e sua solução é reutilizada após algum processo de adaptação para corresponder à situação atual. Ros et al. (2009) aplicaram CBR para modelar a seleção de ações de uma equipe no domínio do futebol de robôs. Os casos modelam o estado do domínio em um determinado momento e prescrevem uma ação de sucesso. Um caso pode ser tratado como uma receita que descreve o estado da descrição do problema e as ações a serem executadas nessa descrição da solução. De fato, a CBR por ser um sistema baseado na experiência, depende de quão boa é o conhecimento prévio; no entanto, a CBR não pode avaliar o quão bem-sucedida é a experiência. Se a solução de um problema passado semelhante não for boa o suficiente, o resultado não será satisfatório.

O *Learning from Observation* (LFO) visa modelar agentes que aprendem observando outros agentes e imitando seu comportamento (RUSSELL; NORVIG, 2010). Como no CBR, o agente de aprendizado seleciona a situação observada no passado mais semelhante em relação ao problema atual e, em seguida, reproduz a solução executada naquele momento. Lam, Esfandiari e Tudino (2006) desenvolveram um modelo de comportamento de agentes baseado no reconhecimento de cenas na liga simulada. A principal diferença entre CBR e LFO é que o agente de aprendizagem não é capaz de melhorar o agente observado pois não há feedback no modelo. Semelhante à CBR, o LFO não pode avaliar a qualidade do comportamento.

O *Reinforcement Learning* (RL) é uma área de aprendizado de máquina que se preocupa com a maneira como um agente deve executar ações em um ambiente, a fim de maximizar alguma noção de recompensa cumulativa (RUSSELL; NORVIG, 2010). Riedmiller et al. (2001) propuseram uma abordagem que aplica RL ao futebol de robôs em nível tático, como os movimentos para interceptação da bola, aguardar na posição, passar a bola para o companheiro de equipe, chutar para o gol, entre outras. Kleiner, Dietl e Nebel (2003) aplicaram RL na *Middle Size League* (MSL) em níveis de habilidade, como procurar a bola em campo, aproximar-se da bola, chutar, passar e assim por diante. Todos esses trabalhos estão focados na colaboração no nível de seleção de habilidades e ações.

Reconhecimento de padrões é uma área da ciência cujo objetivo é a classificação de objetos dentro de um número de categorias ou classes (RUSSELL; NORVIG, 2010). O reconhecimento de padrões foi usado para resolver o problema de modelagem de oponentes na liga simulada. Huang, Yang e Chen (2002) apresentaram uma abordagem que, combinando representação e reconhecimento de planos e técnicas de recuperação, traduz o fluxo de informações obtidos a partir da observação do adversário em fluxos de comportamentos de agentes usando técnicas de previsão. Conseqüentemente, sequências ou padrões de comportamento frequentes podem ser encontrados pela análise estatística, e os planos relevantes podem ser extraídos. Lattner et al. (2006) e Miene, Visser e Herzog (2004) propuseram uma abordagem que aplica aprendizado *off-line* simbólico não supervisionado a uma abstração qualitativa, a fim de criar padrões frequentes em cenas dinâmicas.

Teoria *fuzzy* é outra abordagem já adotada no jogo de futebol de robôs. Na lógica *fuzzy* os valores de verdade das variáveis podem ser qualquer número real entre 0 (correspondente ao valor falso) e 1 (correspondente ao valor verdadeiro). Foi estendida para lidar com o conceito de verdade parcial, em que o valor verdade se situa entre o completamente verdadeiro e o falso (RUSSELL; NORVIG, 2010). Lee et al. (2005) apresentaram uma estratégia usando o mediador lógico *fuzzy* que seleciona a ação apropriada do robô, dependendo das posições e papéis dos dois robôs adjacentes. Seu trabalho é implementado e testado no SimuroSot. Wu e Lee (2004) concentraram suas pesquisas na seleção de cinco categorias de ação na SSL. Dado um conjunto de variáveis de entrada, a saída das regras difusas indica a ação a ser executada pelo robô. A abordagem considera apenas um jogador e, portanto, nenhuma cooperação pode ser considerada.

As Redes neurais artificiais (RNAs) são modelos computacionais inspirados pelo sistema nervoso central de um animal (em particular o cérebro) que são capazes de realizar o aprendizado de máquina bem como o reconhecimento de padrões (RUSSELL; NORVIG, 2010). As RNAs são amplamente utilizadas no campo de sistemas inteligentes de múltiplos agentes. Jolly et al. (2007) apresentaram uma abordagem em duas etapas usando RNAs para seleção de ações na liga MiroSot. Mais precisamente, o trabalho deles é focado em decidir qual dos dois robôs próximos à bola deve persegui-la enquanto o outro permanece como suporte.

Os Algoritmos Evolutivos (AE) buscam tratar estruturas de objetos abstratos de uma população, como, por exemplo, variáveis de um problema de otimização, dos quais são manipulados por operadores inspirados na evolução biológica, que objetivam a busca para a solução de um problema, estes operadores são comumente chamados de operadores genéticos (RUSSELL; NORVIG, 2010). AE foram propostos em várias ocasiões na RoboCup. Nakashima et al. (2006) propuseram um método para a aquisição de estratégias de equipe na liga simulada. Eles empregaram um esquema de atualização de geração para produzir novas sequências inteiras usando mutação. Os autores utilizaram as pontuações dos jogos de futebol como medida de desempenho em seu método evolutivo. Park et al. (2007) utilizaram AE para determinar as regras de controle difuso apropriadas para o problema de planejamento de caminhos no futebol de robôs.

Já Konur et al. (2004) escolheram a técnica de aprendizado em árvore de decisão para decidir a próxima ação no jogo de futebol robô na liga simulada. Entretanto, durante a coleta dos dados de treinamento, o supervisor deve ter uma boa ideia de como o futebol é jogado, a fim de dar conselhos ao agente. O aprendizado da árvore de decisão não conseguiu resolver esse problema.

Okada, Wada e Yamashita (2011) utilizaram o PSO para encontrar posicionamentos da equipe de futebol em campo na modalidade *simulação* da liga da RoboCup. Nas simulações realizadas foi fixada a bola em 15 posições fixas do campo e o PSO utilizado para encontrar possíveis configurações das posições dos jogadores em campo. Segundo os próprios autores, as formações encontradas não demonstraram tendências para posições ofensivas ou defensivas, mantendo-se próximos ao meio do campo.

O uso do algoritmo PSO tem sido explorado na literatura para planejamento de rotas em várias situações, como jogos de estratégia (SINGH; DEEP, 2015), robôs reais

(NASROLLAHY; JAVADI, 2009) ou partidas de futebol (WANG et al., 2006; SASKA et al., 2006).

Wang et al. (2006) apresentaram uma proposta de utilização do PSO para cálculo de planejamento de rotas (*path-planning*) e desvios de obstáculos. A proposta foi aplicada e simulada em uma partida de futebol de robôs com cinco integrantes de cada lado. Conforme os autores, o uso do PSO para planejamento de rotas demonstrou-se possível, simples e fácil implementação. Porém várias variáveis, como a velocidade da bola e dos robôs, foram consideradas constantes o que dista de uma situação real de jogo. Novas pesquisas para introduzir parâmetros variáveis nas equações deverão ser realizadas a fim de aproximar o resultado ao mundo real.

Já Saska et al. (2006) aplicaram o algoritmo PSO em conjunto com *splines* de Ferguson para o cálculo de trajetórias do robôs em um campo de futebol. Conforme exposto pelo os autores a utilização de *splines*, que é uma curva definida matematicamente por dois ou mais pontos de controle onde os pontos de controle que ficam na curva são chamados de nós, é uma implementação de movimentação natural para robôs. Para os autores, esse cálculo de trajetórias reduz o custo computacional de processamento, pois não é necessário ocorrer a exploração de todos os possíveis caminhos como nos algoritmos tradicionais de *path-planning*.

Estimar o tempo para captura da bola e a decisão de qual robô consegue realizar essa interceptação é um problema em partidas de futebol. Deng et al. (2014) propuseram o uso do *Support Vector Regression* (SVR) para solução desse problema. Porém o PSO é utilizado para a otimização dos parâmetros do SVR. Os autores compararam o resultado do SVR com os parâmetros padrões e com os parâmetros otimizados. Na análise a execução com os parâmetros otimizados obteve melhores resultados.

Existem outros estudos relacionados a SSL. Mendoza et al. (2016) sugeriu o algoritmo *Selectively Re-active Coordination* (Coordenação Seletiva Reativa) (SRC), que contém duas camadas: uma camada agnóstica coordenada ao oponente permite que a equipe crie seus planos, criando espaço para um jogo ofensivo e uma reação individual ao oponente. A camada de seleção de ações permite que os robôs mantenham a atividade para diferentes oponentes. Essa abordagem permite uma troca entre a capacidade da equipe de criar planos independentemente dos oponentes e sua capacidade de reagir adequadamente a diferentes comportamentos do oponente.

Quintero et al. (2015) aplicaram técnicas de aprendizado de máquina ao problema de prever jogadas de futebol. Os autores demonstraram experimentalmente que é possível prever a jogada que determinada equipe executará em um jogo SSL. Schwab, Zhu e Veloso (2018) aplicaram *Deep Reinforcement Learning* (DRL) para treinar habilidades. Os autores demonstraram o aprendizado de duas habilidades diferentes: navegar para uma bola, mirar e arremessar. Embora não sejam perfeitas, essas habilidades aprendidas permitem um desempenho próximo ao das habilidades codificadas manualmente, mas não com a mesma precisão.

Albab, Wibowo e Basuki (2017) aplicaram algoritmos genéticos na SSL para tentar resolver problemas de planejamento de rotas e localização durante o deslocamento entre a posição atual e a posição final.

Larik e Haider (2018) apresentaram um estudo sobre várias aplicações de algoritmos de otimização inspirados na natureza na elaboração de estratégias cooperativas. Foram discutidas três categorias de algoritmos de otimização: algoritmos inspirados no processo de evolução, algoritmos inspirados em enxame ou processos biológicos e algoritmos inspirados na evolução cultural. A pesquisa categoriza ainda a aplicação em ambientes centralizados e descentralizados. A conclusão a que os autores chegaram é de que, para a comunidade RoboCup, soluções sobre estratégia, aprendizado ou posicionamento aplicadas no futebol de robôs são problemas em aberto, mesmo que existam pesquisas sobre o assunto.

Por fim Guarnizo e Mellado (2016) propõem uma arquitetura para equipes de futebol de robôs com tomada de decisão centralizada e percepção global. A arquitetura é baseada numa máquina de estados hierárquica e algumas regras são propostas para seleção dos comportamentos. Os autores defendem que a arquitetura, embora com regras finitas, é escalável e adaptável para aplicações semelhantes, porém concluem que para aumentar a efetividade da proposta é necessário a aplicação de técnicas de aprendizado para definição das regras.

## 1.7 CONSIDERAÇÕES DO CAPÍTULO

Embora existam vários trabalhos envolvendo robôs e o algoritmo PSO, inclusive em futebol de robôs, não foram encontradas pesquisas que utilizem o algoritmo PSO aplicados especificamente em posicionamento de robôs em ambientes dinâmicos.

Estudos sobre formações táticas e posicionamentos em campo vem sendo conduzido por pesquisadores e profissionais ligados ao futebol humano. De forma análoga, este é um problema ainda objeto de estudo no futebol de robôs nas mais diversas ligas.

Muitas pesquisas e estratégias das equipes estão centradas no robô adversário com a posse de bola. Este trabalho, difere dos demais ao propor regras de posicionamento em campo baseado nos critérios defensivos do futebol moderno. Um dos objetivos é encontrar em tempo e processamento eficientes soluções baseadas no posicionamento da equipe adversária. Embora o robô portador da bola mereça um acompanhamento especial para criar situações de retomada da bola, os demais adversários também tem importância relevante na estratégia da equipe.

Este trabalho está organizado para explicar os conceitos sobre futebol, a liga da SSL e requisitos táticos para equipes de futebol (capítulo 2). O capítulo 3 explora algumas técnicas de *Swarm Intelligence* (Inteligência de Exame) (SI), possíveis aplicações e detalha o algoritmo *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO), seu funcionamento e características principais. No capítulo 4 é apresentada uma métrica de avaliação para futebol humanos e novas métricas para avaliar os posicionamentos defensivos de futebol de robôs. O capítulo 5 apresenta as equações para otimização de posicionamentos defensivos, detalhando os critérios escolhidos e respeitando as regras da liga SSL. A escolha dos parâmetros do algoritmo PSO e primeiras validações das funções são apresentadas no capítulo 6. O capítulo 7 analisa a aplicação das métricas em conjunto com as equações de otimização em jogos realizados entre as principais equipes da SSL atualmente. Finalmente o capítulo 8 detalha as conclusões obtidas do trabalho e propõem possíveis direcionamentos para continuidade da pesquisa.

## 2 CONCEITOS SOBRE FUTEBOL DE ROBÔS E HUMANO

A robótica é uma divisão da área do conhecimento que lida com a modelagem, construção, operação, fabricação e aplicação de robôs. Como forma de desenvolvimento da área foram criadas diversas competições ao redor do mundo, que contam com a participação de estudantes, professores e pesquisadores, com o intuito de tanto demonstrar seus avanços na área de robótica, como compartilhar suas descobertas e verificar o trabalho de seus colegas.

A *Robot Soccer World Cup* (RoboCup), realizada anualmente, é uma competição de robótica projetada para incentivar a pesquisa no campo das engenharias e de técnicas de inteligência artificial por meio de jogos amigáveis (ROBOCUP, 2015). A competição de futebol *Small Size League* (SSL) é uma das diversas competições dentro da RoboCup.

### 2.1 MOTIVAÇÃO

Os seres humanos jogam diferentes jogos como futebol, vôlei ou basquete. Todos esses jogos têm seu próprio prazer e, mais importante, a razão pela qual as pessoas os jogam. Similarmente, a versão robotizada do futebol tem seus objetivos específicos.

O futebol de robôs tornou-se uma importante área de pesquisa que integra técnicas de mecatrônica, engenharias, ciência da computação e inteligência artificial para criar sistemas autônomos e construir robôs móveis. Basicamente, são realizados estudos de como robôs podem ser construídos e programados para jogar futebol. De fato, o futebol de robôs, uma versão robotizada do futebol humano, ganhou aceitação mundial como um domínio interessante e desafiador para estudar e investigar um amplo espectro de questões relevantes para o desenvolvimento de robôs autônomos e sistemas multi robôs.

O futebol de robôs não apenas fornece um campo de testes e experimentos para a pesquisa de sistemas robóticos multiagentes, mas também uma ferramenta educacional útil para cursos práticos nesta área. É útil para a integração de conhecimento, trabalho em equipe, questões do mundo real, pensamento crítico e criatividade. Particularmente, no futebol de robôs a colaboração é desejada para que o grupo de robôs trabalhe em conjunto para alcançar um objetivo comum. No futebol de robôs, a situação do jogo em campo é definida com base nas posturas dos robôs e na posição da bola. Naturalmente,

são necessárias boas estratégias para decidir as posições dos robôs da equipe durante o jogo.

Como o jogo de futebol humano, existem regras envolvidas neste jogo. No entanto, existe coisas básicas que não são exatamente como o futebol humano. A razão para isto é que os propósitos para os dois tipos de futebol são diferentes. Uma é para estudos e pesquisas, enquanto a outra é uma forma de lazer.

No futebol humano, o árbitro tem o poder de controlar as atividades no campo. Estes incluem suspensão de jogadores, tomar decisões relativas a um movimento errado entre outras situações. No entanto, em algumas ligas da RoboCup, especialmente aquelas que incluem vários robôs, podem haver vários árbitros ou um sistema automático que toma as decisões, como o *Auto-referees*, da SSL (MAGEL, 2016; SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2016).

Equipes de futebol humano são compostas basicamente de onze jogadores que jogam em conjunto, a menos que um jogador seja eliminado por violação das regras do futebol. Por outro lado, na RoboCup, o número de robôs que jogam em uma partida é diferente para cada liga que está em andamento. Por exemplo, a liga SSL é composta de oito robôs (liga A) ou seis robôs (liga B) em campo.

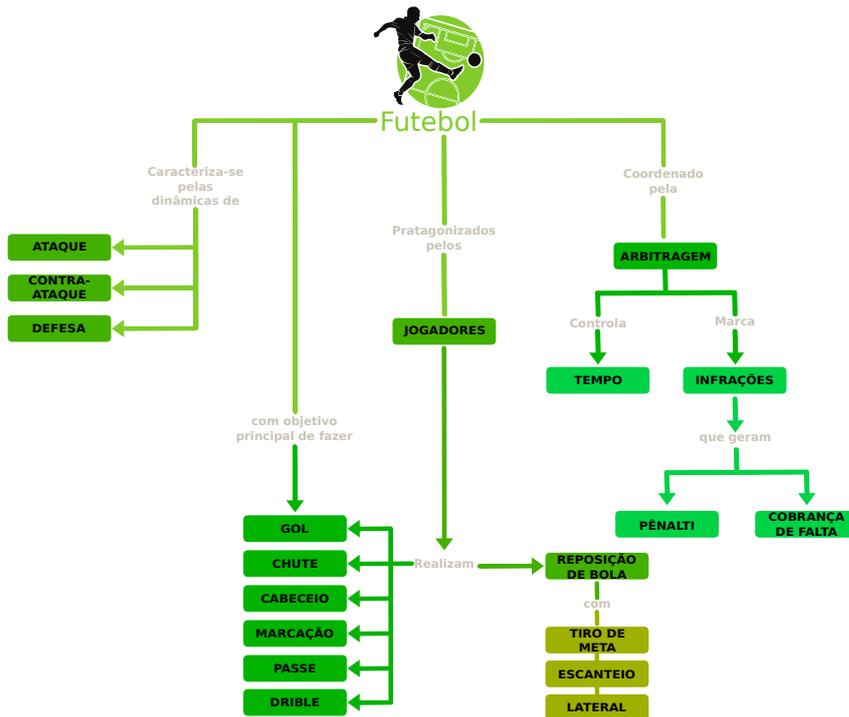
Outros aspectos do futebol permanecem constantes, assim como a terminologia utilizada tais como: pênalti, drible, escanteio, entre outros.

### **2.1.1 Características do futebol humano**

O futebol apresenta-se como sequências de situações problema que geram fluxos de comportamentos com contornos variáveis, organizados em torno de lógicas particulares, em função de regras e princípios. Os princípios de jogo auxiliam a ação dos jogadores e são uma exigência natural do jogo (GARGANTA, 2008). A figura 1 ilustra os atores, ações e situações de um jogo de futebol.

Na literatura especializada em futebol tem-se utilizado diferentes denominações para mencionar e caracterizar os princípios táticos. As táticas compreendem tanto aspectos ligados à formação e à marcação das equipes, quanto estratégias usadas para provocar e atrapalhar o adversário. Entre a variedade de conceitos apresentada percebe-se certa concordância das ideias em volta de três definições teóricas que relacionam a organização

Figura 1 – Componentes do futebol.



Fonte: Autor "adaptado de" Unisinos, 2016

tática dos jogadores no campo de jogo, e que são identificados como (COSTA et al., 2009; CASARIN et al., 2011):

- a) Princípios gerais ou globais: são comuns as diferentes fases do jogo e aos demais princípios. Refere-se ao comportamento da equipe em relação aos adversários, nas zonas de disputa de bola;
- b) Princípios operacionais: são as operações necessárias para tratar uma ou várias categorias de situações. Refere-se aos conceitos atitudinais em campo: defesa e ataque;
- c) Princípios fundamentais: representam um conjunto de regras que orientam as ações dos jogadores nas fases do jogo (defesa ou ataque). O objetivo é desequilibrar a organização do adversário e estabilizar a própria organização em campo.

Esses princípios constituem referências funcionais comuns à todos os jogos coletivos para orientar a equipe ao cumprimento da lógica do jogo, e aos princípios específicos e seus conteúdos referentes aos diferentes e interconectados momentos do jogo (tabela 2).

Tabela 2 – Princípios Táticos do Jogo de Futebol.

Princípios Gerais	Tentar Criar superioridade numérica	Evitar a igualdade numérica	Não permitir a inferioridade numérica
Fases	<b>Ataque (com posse de bola)</b>		<b>Defesa (sem posse de bola)</b>
Princípios Operacionais	<p>Conservar a bola;            Construir ações ofensivas;            Progredir pelo campo do jogo adversário;            Criar situações de finalização;            Finalizar a baliza adversária.</p> <hr/> <p><b>Penetração</b></p> <ul style="list-style-type: none"> <li>– Desestabilizar a organização adversária;</li> <li>– Atacar diretamente o adversário ou baliza;</li> <li>– Criar situações vantajosas para o ataque em termos numéricos e espaciais.</li> </ul> <hr/> <p><b>Cobertura Ofensiva</b></p> <ul style="list-style-type: none"> <li>– Dar apoio ao portador da bola oferecendo-lhe opções para a sequência do jogo;</li> <li>– Diminuir a pressão adversária sobre o portador da bola;</li> <li>– Criar superioridade numérica;</li> <li>– Criar desequilíbrio na organização defensiva adversária;</li> <li>– Garantir a manutenção da posse de bola.</li> </ul> <hr/> <p><b>Mobilidade</b></p> <ul style="list-style-type: none"> <li>– Criar ações de ruptura da organização defensiva adversária;</li> <li>– Apresentar-se em um espaço muito propício para a consecução do gol;</li> <li>– Criar linhas de passe em profundidade;</li> <li>– Conseguir o domínio da bola para dar sequência a ação ofensiva (passe ou finalização).</li> </ul> <hr/> <p><b>Espaço</b></p> <ul style="list-style-type: none"> <li>– Utilizar e ampliar o espaço de jogo efetivo da equipe;</li> <li>– Expandir as distâncias/posicionamentos entre os jogadores adversários;</li> <li>– Dificultar as ações de marcação da equipe adversária;</li> <li>– Facilitar as ações ofensivas da equipe;</li> <li>– Movimentar para um espaço de menor pressão;</li> <li>– Ganhar "tempo" para tomar a decisão correta para dar sequência no jogo;</li> <li>– Procurar opções mais seguras, através dos jogadores posicionados mais defensivamente, para dar sequência ao jogo.</li> </ul> <hr/> <p><b>Unidade Ofensiva</b></p> <ul style="list-style-type: none"> <li>– Facilitar o deslocamento da equipe para o campo de jogo adversário;</li> <li>– Permitir a equipe atacar em unidade ou em bloco;</li> <li>– Oferecer mais segurança as ações ofensivas realizadas no centro do jogo;</li> <li>– Propiciar que mais jogadores se posicionem no centro do jogo;</li> <li>– Diminuir o espaço de jogo no campo defensivo.</li> </ul>		<p>Impedir a progressão do adversário;            Reduzir o espaço de jogo adversário;            Proteger a baliza;            Anular as situações de finalização;            Recuperar a bola.</p> <hr/> <p><b>Contenção</b></p> <ul style="list-style-type: none"> <li>– Diminuir espaço de ação ofensiva do portador da bola;</li> <li>– Orientar a progressão do portador da bola;</li> <li>– Parar ou atrasar o ataque ou contra-ataque adversário;</li> <li>– Propiciar maior tempo para organização defensiva;</li> <li>– Restringir as possibilidades de passe a outro jogador adversário;</li> <li>– Evitar o drible que favoreça progressão pelo campo de jogo em direção ao gol;</li> <li>– Impedir a finalização à baliza.</li> </ul> <hr/> <p><b>Cobertura defensiva</b></p> <ul style="list-style-type: none"> <li>– Servir de novo obstáculo ao portador da bola, caso esse passe pelo jogador de contenção;</li> <li>– Transmitir segurança e confiança ao jogador de contenção para que ele tenha iniciativa de combate às ações ofensivas do portador da bola;</li> </ul> <hr/> <p><b>Equilíbrio</b></p> <ul style="list-style-type: none"> <li>– Assegurar a estabilidade defensiva da região de disputa da bola;</li> <li>– Apoiar os companheiros que executam as ações de contenção e cobertura defensiva;</li> <li>– Cobrir eventuais linhas de passe;</li> <li>– Marcar potenciais jogadores que podem receber a bola;</li> <li>– Fazer recuperação defensiva sobre o portador da bola;</li> <li>– Recuperar ou afastar a bola da zona onde ela se encontra.</li> </ul> <hr/> <p><b>Concentração</b></p> <ul style="list-style-type: none"> <li>– Aumentar a proteção ao gol;</li> <li>– Condicionar o jogo ofensivo adversário para zonas de menor risco do campo de jogo;</li> <li>– Propiciar aumento de pressão no centro do jogo.</li> </ul> <hr/> <p><b>Unidade defensiva</b></p> <ul style="list-style-type: none"> <li>– Permitir a equipe defender em unidade ou em bloco;</li> <li>– Garantir estabilidade espacial e sincronia dinâmica entre as linhas longitudinais e transversais da equipe em ações ofensivas;</li> <li>– Diminuir a amplitude ofensiva da equipe adversária na sua largura e profundidade;</li> <li>– Assegurar linhas orientadoras básicas que influenciam as atitudes e os comportamentos tático-técnicos dos jogadores que se posicionam fora do centro de jogo;</li> <li>– Equilibrar ou reequilibrar constantemente a repartição de forças da organização defensiva consoante às situações momentâneas de jogo;</li> <li>– Reduzir o espaço de jogo utilizando a regra do impedimento;</li> <li>– Obstruir possíveis linhas de passe para jogadores que se encontram fora do centro de jogo;</li> <li>– Possibilitar a participação em uma ação defensiva subsequente;</li> <li>– Propiciar que mais jogadores se posicionem no centro de jogo.</li> </ul>

## Princípios Fundamentais

## Transição Defesa-ataque e/ou Ataque-defesa

Fonte: Costa et al., 2009

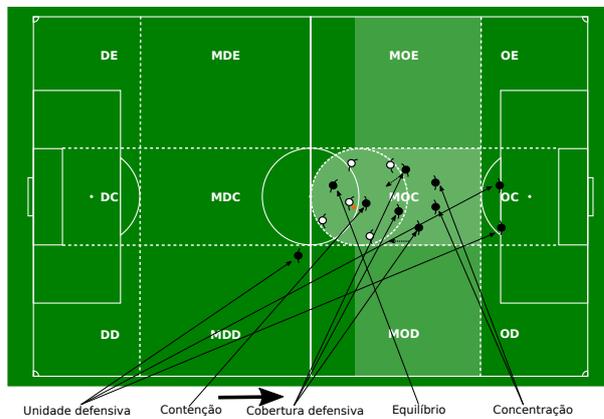
Ainda, uma partida de futebol divide-se em dois conceitos atitudinais: defesa e ataque. Sendo que defesa de uma equipe deve a) anular as situações de finalização; b) recuperar a bola; c) impedir a progressão do adversário; d) proteger o gol e e) reduzir o espaço de jogo adversário. No ataque: a) conservar a bola; b) construir ações ofensivas; c) progredir pelo campo de jogo adversário; d) criar situações de finalização; e e) finalizar

no gol adversária. Esses conceitos atitudinais e outros princípios táticos, relacionados ao posicionamento, serão priorizados no desenvolvimento das funções de aptidão de passe e defesa (capítulo 5).

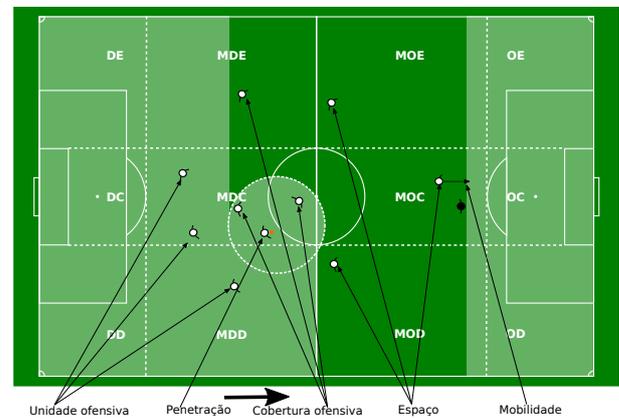
Como observado na figura 2, o campo é dividido em 12 áreas e categorizado: como lados e meio de campo Defensivo e Ofensivo; Lado Esquerdo, direito ou área central. Assim, MDC significaria “Meio de campo defensivo na área central” e OE apenas como “Área ofensiva esquerda”. Na figura, os critérios apresentados na tabela 2 estão relacionados com situações e posições em campo.

Figura 2 – Princípios Táticos Fundamentais do jogo de Futebol em função das fases.

(a) A – Defensivo



(b) B – Ofensivo



Fonte: Autor "adaptado de" Costa et al., 2011

## 2.2 CONSTRUÇÃO DE TIMES DE ROBÔS

O futebol é um esporte de equipe em que as atuações de todos os membros são importantes para o resultado de uma partida. Mas robôs não são bons jogadores de futebol. Eles não podem correr como um ser humano, não podem pular, às vezes saem do campo, colidem entre si, algumas modalidades necessitam de um sistema externo de visão para simular os olhos humanos ou um computador central que faz o papel de cérebro humano e técnico simultaneamente como na SSL, e depois de chutar a bola eles geralmente caem como crianças como no futebol humanoide.

Nas competições e simpósios de robótica, como a *Latin American Robotics Competition* (LARC) e RoboCup, vários experimentos são realizados e pesquisas apresentadas, nas áreas de mecânica, inteligência artificial, eletrônica, visão computacional, entre outras

(GURZONI et al., 2011; PERICO et al., 2014; SILVA et al., 2015; LAUREANO; TONIDANDEL, 2019a,b; DA SILVA COSTA; TONIDANDEL, 2019; PAULI; TONIDANDEL, 2019).

### 2.2.1 Características e requisitos

Um agente robótico inteligente é um robô físico autônomo situado em um ambiente real, e é reativo, proativo e comunicativo (KIM et al., 2004). Para ser considerado autônomo o robô deve atuar com intervenção humana mínima ou nenhuma. Para respeitar os objetivos, o robô deve ser:

- a) Reativo na medida em que pode perceber seu ambiente e responder de forma oportuna às mudanças que ocorrem;
- b) Pró-ativo na medida em que é capaz de tomar sua própria iniciativa;
- c) Comunicativo, pois é capaz de interagir com outros agentes, possivelmente incluindo seres humanos.

Reação, pró-atividade e comunicação são os meios pelos quais um robô interage com o seu ambiente. A inteligência de um robô é definida de acordo com suas interações. Em geral, portanto, a inteligência não é uma propriedade do robô isoladamente, mas é um resultado da interação com seu ambiente.

Idealmente, uma equipe de robôs deve ser projetada para satisfazer os requisitos de robustez e tolerância a falhas, confiabilidade, flexibilidade ou adaptabilidade, coerência e escalabilidade (SAMMUT, 2010):

- a) Robustez e tolerância a falhas: robustez refere-se à capacidade de um sistema para degradar-se graciosamente ante a presença de falha parcial do sistema. A noção relacionada sobre tolerância a falhas refere-se à capacidade de um sistema para detectar e compensar falhas parciais. Para conseguir robustez e tolerância a falhas as equipes precisam minimizar sua vulnerabilidade a interrupções do robô.
- b) Confiabilidade: refere-se ao nível de confiança do sistema, ou seja, se funciona corretamente cada vez que é utilizado.
- c) Flexibilidade ou Adaptabilidade: refere-se a capacidade dos membros da equipe de modificar suas ações à medida que o ambiente ou a equipe do robô muda. Idealmente, uma equipe cooperativa deve responder às mudanças baseada nas habilidades e desempenhos dos robôs individuais, bem como no am-

biente dinâmico. Além disso, a equipe não deve confiar em uma composição pré-especificada para atingir seu objetivo. As capacidades dos robôs da equipe podem mudar com o tempo devido ao aprendizado que deve melhorar o desempenho ou a causas mecânicas ou ambientais que podem reduzir ou aumentar o sucesso de um robô em determinadas tarefas. Os robôs da equipe devem responder a essas mudanças nos níveis de desempenho assumindo tarefas que não estão mais sendo adequadamente executadas ou abrindo mão das tarefas realizadas por outros robôs.

- d) **Coerência:** refere-se quão bem a equipe atua como um todo, ou seja, como os robôs executam ações individuais propositadamente combinadas para chegar no único objetivo. Normalmente, a coerência é medida por critérios como a eficiência do cálculo e qualidade da solução. Considerações de eficiência são particularmente importantes em equipes de robôs heterogêneos cujas capacidades se sobrepõem, em que diferentes robôs são capazes de realizar a mesma tarefa, mas com características de desempenho bastante diferentes. Em uma equipe altamente eficiente, os robôs selecionam tarefas para que o desempenho geral seja o mais próximo possível do ideal. Uma equipe na qual robôs realizam ações conflitantes ou duplicam as ações uns dos outros não pode ser considerada uma equipe altamente coerente. Uma equipe coerente, no entanto, não precisa estar totalmente livre de todos os possíveis conflitos. Em vez disso, os robôs da equipe devem ser capazes de resolver conflitos à medida que surgem.
- e) **Escalabilidade:** refere-se à facilidade com que uma equipe pode admitir mais membros para melhorar o desempenho geral ao trabalhar em suas tarefas problemáticas.

Através do jogo de futebol de robôs, os pesquisadores estudam como vários robôs de cada equipe poderiam ser construídos para cooperar em um ambiente adversário para alcançar objetivos específicos. O ambiente de futebol tem as seguintes características (KIM et al., 2004; SAMMUT, 2010):

- a) Agentes independentes com o mesmo objetivo de alto nível bem definido de marcar gols para vencer a partida: companheiros de equipe;
- b) Agentes com objetivos de alto nível conflitantes e bem definidos de contrapontuar gols para vencer a partida: adversários;

- c) Necessidade da tomada de decisão no menor tempo possível.

Para cooperar bem em tal ambiente, os robôs devem realizar reconhecimento visual em tempo real e rastreamento de objetos em movimento, colaborar com colegas de equipe para decidir seus papéis de ataque ou defesa em uma situação dinâmica de jogo, navegar em coordenação com companheiros de equipe e em contra-ação contra adversários, e acertar a bola na direção da baliza. Esses robôs devem ser (KIM et al., 2004; SAMMUT, 2010):

- a) Eficientes e funcionarem sob limitações de tempo e recursos;
- b) Reativos e proativos decidindo quais ações tomar com base no raciocínio estratégico da situação do jogo, e talvez aprendendo se adaptando com base na experiência;
- c) Comunicativos como parte de colaborar e coordenar uns com os outros ao decidir quais ações realizarão;
- d) Autônomos, como em casos de sensoriamento, decidindo e agindo como um sistema independente.

O ponto a enfatizar é que todas essas capacidades devem ser bem integradas em um único e completo sistema de futebol.

## **2.2.2 Habilidades necessárias para um robô jogar futebol**

Para que se tenha um bom desempenho no futebol é necessário o domínio de algumas técnicas específicas como movimentar-se, passar a bola, chutar a gol, interceptar penalidades entre outras (GROEN; SPAAN; VLASSIS, 2002; KIM et al., 2004; SAMMUT, 2010):

### **2.2.2.1 Movimentação**

O movimento fundamental de um robô  $r$  é definido como a possibilidade dele partir de uma posição arbitrária  $r_t \leftarrow (x_t, y_t, \Theta_t)$  no instante  $t$  e passar para outra posição  $r_{t+1} \leftarrow (x_{t+1}, y_{t+1}, \Theta_{t+1})$  no menor período de tempo possível, onde  $(x, y)$  são as coordenadas da posição do centro do robô em um plano cartesiano, e  $\Theta$  é o ângulo da direção do robô.

### 2.2.2.2 Chutar uma bola parada

Essa habilidade requer que um robô  $r$  deve mover-se de uma posição  $r_t \leftarrow (x_t, y_t, \Theta_t)$  para golpear uma bola estacionária  $b$  em  $b_t \leftarrow (x_t, y_t, \Theta_t)$  para passar por um ponto desejado  $pd$  em  $pd_t \leftarrow (x_t, y_t, \Theta_t)$ .

Em outras palavras, o robô deve ser capaz de começar em qualquer posição  $r_t$  para atingir uma bola colocada em qualquer posição  $b_t$  e fazê-la seguir na direção especificada  $pd_t$ .

### 2.2.2.3 Passar a bola para colega de equipe

O controle de passe não é uma atividade trivial. No entanto, a habilidade de passar a bola é um requisito mínimo para os robôs serem capazes de coordenar-se como companheiros de equipe para mover a bola de um robô para outro. Sem essa habilidade, nenhuma estratégia de jogo além chutar e correr pode ser efetivamente executada.

Para ocorrer o passe é necessário que um robô  $r_1$  em  $r_{1t} \leftarrow (x_t, y_t, \Theta_t)$  golpee uma bola estacionária  $b$  em  $b_t \leftarrow (x_t, y_t, \Theta_t)$  de forma que outro robô  $r_2$  a partir de  $r_{2t} \leftarrow (x_t, y_t, \Theta_t)$  possa bater na bola em movimento  $bm$  em  $b_m \leftarrow (x_t, y_t, \Theta_t)$  para direcionar a um ponto desejado  $pd$  em  $pd_t \leftarrow (x_t, y_t, \Theta_t)$ .

### 2.2.2.4 Chutar uma bola em movimento

Esse movimento reflete uma situação real do jogo, na qual a bola está se movendo a maior parte do tempo, e às vezes está se movendo rápido, excedendo  $1m/s$ . Para acertar uma bola em movimento, o sistema de visão deve estar funcionando na mais alta taxa de amostragem possível, já que o módulo de tomada de decisões precisa saber a velocidade da bola para prever onde ela estará quando o robô a atingir.

Chutar bola em movimento requer que um robô  $r_1$  se mova de  $r_{1t} \leftarrow (x_t, y_t, \Theta_t)$  para golpear a bola em movimento  $bm$  em  $b_m \leftarrow (x_t, y_t, \Theta_t)$  para que a bola passe um ponto desejado  $pd$  em  $pd_t \leftarrow (x_t, y_t, \Theta_t)$ ;

### 2.2.2.5 *Passar a bola em movimento para um robô em movimento*

Para essa habilidade, além do sistema estar funcionando com a taxa de amostragem mais alta possível, é necessário que o módulo de tomada de decisões verifique a velocidade da bola para definir o ponto de interceptação da bola  $b_i$  em  $b_{it} \leftarrow (x_t, y_t)$  e calcular a velocidade necessária para que outro robô se locomova em tempo suficiente para receber a bola.

O passe requer um robô  $r_1$  em  $r_{1t} \leftarrow (x_t, y_t, \Theta_t)$  para atingir uma bola em movimento  $bm$  em  $b_m \leftarrow (x_t, y_t, \Theta_t)$  para ser interceptada em  $b_{it} \leftarrow (x_t, y_t)$  por outro robô  $r_2$  a partir de  $r_{2t} \leftarrow (x_t, y_t, \Theta_t)$  para que a bola passe um ponto desejado  $pd$  em  $pd_t \leftarrow (x_t, y_t, \Theta_t)$ ;

### 2.2.2.6 *Desviar de obstáculos*

Para um robô navegar e realizar seus passes e chutes, é necessário que um robô desvie robôs adversários, da própria equipe elementos em campo, sem colidir com qualquer um deles. Muitas abordagens foram introduzidas para implementar o planejamento de caminhos no futebol de robôs. A abordagem é adaptada ao ambiente e nelas variáveis como tempo de processamento, efetividade e complexidade são consideradas (ALBAB; WIBOWO; BASUKI, 2017).

Na SSL, por exemplo, os algoritmos mais utilizados são variantes do  $A^*$  (proposto inicialmente por Hart, Nilsson e Raphael (1968)) ou o *Rapidly-exploring random tree* (RRT) (proposto por LaValle e James J. Kuffner (2001)).

Embora esses algoritmos funcionem de forma satisfatória, várias pesquisas para planejamento de caminho em futebol de robôs foram desenvolvidas ao longo dos anos, tais como os propostos por Saska et al. (2006), Wang et al. (2006), Pratomo et al. (2010), Shakiba, Najafipour e Salehi (2013), Sameshima et al. (2014), Rodríguez et al. (2015) e da Silva Costa e Tonidandel (2019) entre outros.

## 2.2.3 *Posicionamento em campo*

As táticas compreendem tanto aspectos ligados à formação e à marcação das equipes, quanto estratégias usadas para provocar e atrapalhar o adversário (UNISINOS, 2016).

As táticas consistem nas ações desempenhadas pelos jogadores dos times durante a defesa e o ataque, de modo a desarmar o adversário. Essas ações são previamente esquematizadas pelo técnico e estabelecem objetivos específicos para cada jogador (UNISINOS, 2014).

No futebol, são utilizados três termos para definir a tática de uma equipe, função, posição e posicionamento (UNISINOS, 2016):

- a) Função: refere-se ao papel do jogador na equipe, como atacante, goleiro, entre outros. Não impede que um atacante atue como defensor dado sua posição em momentos do jogo;
- b) Posição: localização do jogador em campo, que está relacionada com a função que o jogador desenvolve na estratégia da equipe. Diferentes posições podem apresentar diversas possibilidades de funções para um mesmo jogador;
- c) Posicionamento: esse termo se refere aonde o jogador se posiciona em relação ao esquema tático da equipe. O posicionamento envolve tomar a melhor decisão para os jogadores que não possuem a bola serem distribuídos estrategicamente em campo.

No futebol de robôs, tarefas separadas precisam ser definidas para os robôs. Como um robô para atuar como goleiro e um para atuar ativamente na recuperação da bola, sendo o robô ativo na jogada. Os robôs podem trocar de funções durante uma partida e mais de um robô pode atuar ativamente, contudo o habitual é considerar como robô ativo o portador da bola. Os demais robôs são jogadores estratégicos que precisam estar posicionados corretamente, ou seja, serem distribuídos. As posições desses jogadores influenciam no processo de decisão dos companheiros de equipe e dos oponentes.

A colaboração entre goleiro e defensores é de crucial importância para salvaguardar o gol. Um tipo simples dessa colaboração ocorre quando as posições dos defensores cobrem algumas partes da área defensiva. Isso permite que o goleiro cuide de uma pequena parte da área do gol, e não de toda a área.

A importância da colaboração entre o(s) robô(s) ativo(s) e os demais é importante. O robô portador da bola pode chutar a bola por diferentes velocidades e ângulos de chute. Por exemplo, um chute com velocidade pequena é uma ação de drible e um chute de velocidade mais alta pode ser uma ação de passe ou chute a gol. Suponha que esse robô

queira passar a bola para um companheiro de equipe. O robô que recebe o passe deve estar perto o suficiente do robô com a posse de bola e longe dos robôs oponentes para reduzir a probabilidade de perder a bola. Considerando apenas esses fatores, o processo de posicionamento pode ser definido como a distribuição dos companheiros para aumentar o número de robôs habilitados a receber um passe, portanto, o robô portador da bola terá mais opções e poderá executar o passe com maior precisão.

Para observar o efeito de um bom posicionamento no processo de tomada de decisão dos oponentes, assumamos que o robô adversário portador da bola quer selecionar um de seus companheiros para passar a bola. Se os demais robôs adversários estiverem com linha de passe bloqueados ou com pouca área de movimentação, o robô adversário portador da bola terá dificuldades para encontrar um companheiro de equipe livre e seu processo de decisão seria interrompido. A probabilidade de interceptar a bola aumentaria e os ataques dos oponentes seriam neutralizados.

Durante a competição, no que diz respeito à posição da bola, os robôs estratégicos têm que percorrer longos caminhos para alcançar a posição adequada e dirigir-se até o destino, necessitando energia. Os robôs, porém, têm energia restrita, logo essa preservação é vital e desenvolver métodos de posicionamento nos quais os agentes gastam um mínimo de energia é outro desafio no processo. Outro aspecto para o desenvolvimento de métodos de posicionamento é determinar parâmetros efetivos. Alguns podem ser os vetores de atração para a bola, capacidades dos companheiros de time, habilidades dos oponentes e seus níveis de agressividade para alcançarem o objetivo.

No futebol humano, os esquemas táticos ou formações são as formas de um treinador posicionar sua equipe dentro de campo, como no exemplo de formação 4-4-3 que pode ser observado na figura 3. Cada jogador tem uma função pré-determinada (goleiro, meio de campo, atacante e outras denominações) e uma área de atuação no campo. Porém a dimensão da tática no futebol não se restringe ao posicionamento dos jogadores no campo de jogo, mas de seus movimentos e decisões (PRAÇA et al., 2016).

No futebol de robôs, o método de posicionamento estratégico trata dos problemas de escolha da posição e o modo de dirigir-se até lá. Há sempre um jogador que está associado à bola e obedece a um método de decisão diferente baseado na estratégia; outros robôs devem mover-se em direção a sua melhor posição no campo. Portanto, o posicionamento deve ser implementado com cuidado na estratégia da equipe (DASHTI; KAMALI; AGHAEIPOUR, 2007).

Figura 3 – Formação 4–4–3 do futebol.



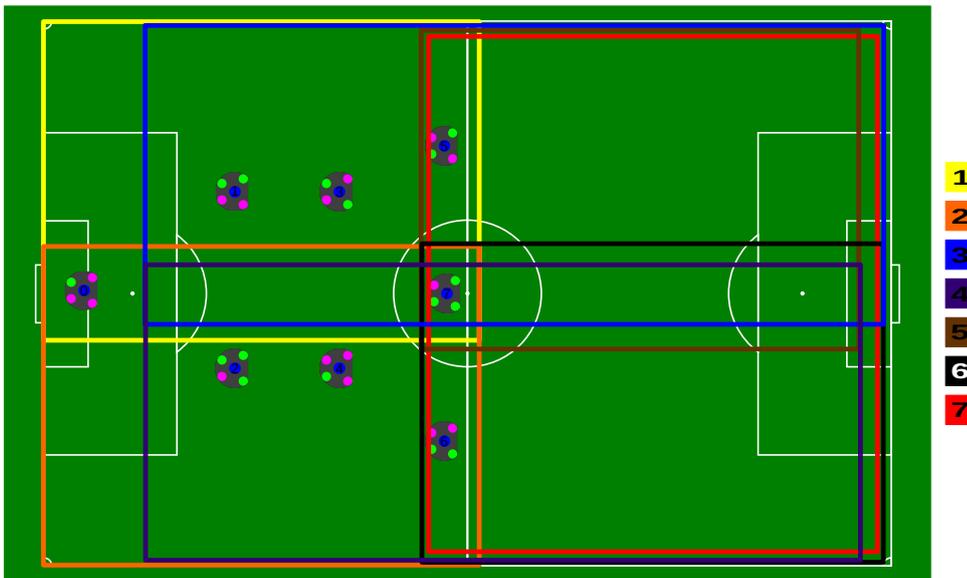
Fonte: Autor "adaptado de" Carling, Williams e Reilly, 2006

Na figura 4 as cores determinam a área de atuação de oponente. Na imagem, o robô sete atua em todo o campo de ataque. O cinco no campo de ataque superior e o seis no ataque inferior. Semelhantes aos posicionamentos encontrados no futebol humano com designações de lateral direito ou esquerdo. Essa área de atuação não impede que os robôs se movam pelas demais áreas do campo.

### 2.3 SMALL SIZE LEAGUE – SSL

O SSL tem como foco principal o problema da cooperação e controle multiagente inteligente em um ambiente dinâmico, com um sistema centralizado (ROBOCUP, 2015). O objetivo, além de fazer o gol, é combinar técnicas de construção de robôs (mecânica e eletrônica) e inteligência artificial para coordenar o jogo da equipe. A construção de uma equipe bem-sucedida requer planejamento, implementação e integração de muitos

Figura 4 – Exemplo de formação 2–2–3 para robôs SSL.

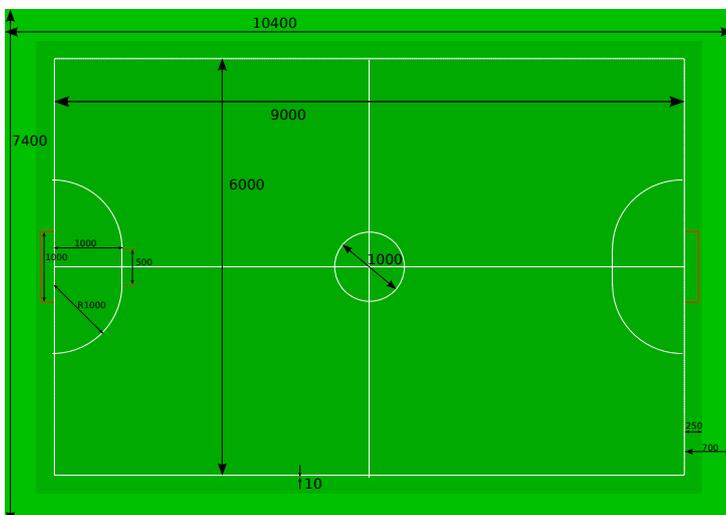


Fonte: Autor

subcomponentes de hardware e software de forma robusta, tornando um robô do SSL interessante e desafiador para pesquisa e educação.

Atualmente a SSL consiste de dois times ( $8 \times 8$  na liga A e  $6 \times 6$  na liga B) se enfrentando em um campo de futebol, carpetado utilizando uma bola laranja. Até 2017 não existia o conceito de ligas na SSL, as dimensões do campo e quantidade de robôs em campo eram menores. A área de gol era formada por uma semicirculo, conforme pode ser observado na figura 5. Todas as medidas são apresentadas em milímetros.

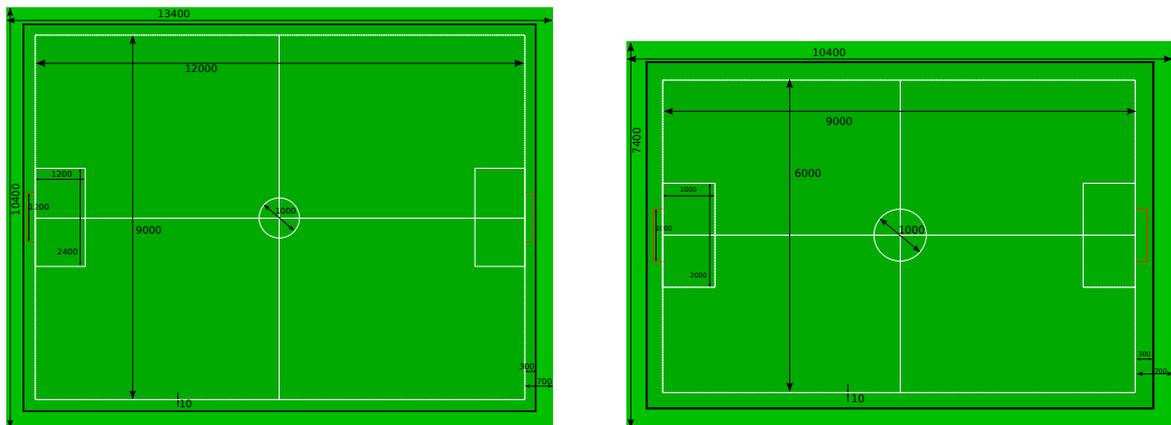
Figura 5 – Dimensões do campo até 2017 (em mm).



Fonte: Small Size League Technical Committee, 2017

Em 2018 foram criadas duas ligas (A e B) na SSL. A liga A é indicada para os times mais competitivos enquanto que a liga B é direcionada para equipes novas ou em amadurecimento. A criação dessas ligas acarretou em modificações nas dimensões dos campos de competição, quantidade de robôs, velocidade da bola, formato e dimensões do área do gol (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2018). As dimensões do campo podem variar de acordo com a liga da competição (figura 6).

Figura 6 – Dimensões dos campos (em mm).



(a) Liga A

(b) Liga B

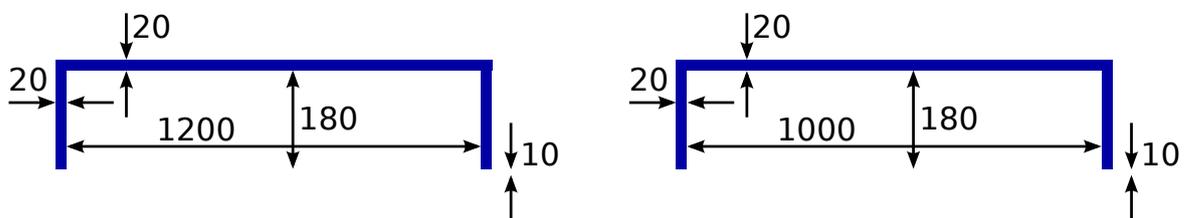
Fonte: Small Size League Technical Committee, 2018

Com o aumento do campo na liga A, a velocidade máxima da bola passou de  $8m/s$  para  $6,5m/s$ . As dimensões e formato da área do gol também foram modificados em 2018 (figura 7) (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2018).

Figura 7 – Dimensões do gol para 2018 (em mm).

(a) Liga A.

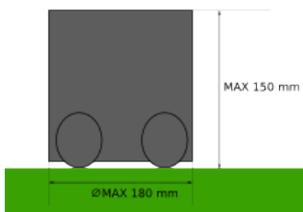
(b) Liga B.



Fonte: Small Size League Technical Committee, 2018

Cada time é, atualmente, composto por oito (liga A) ou seis (liga B) robôs e deve seguir as especificações indicadas para o ano da competição, sendo que a última atualização indica que cada robô tem 180 mm de diâmetro e não pode ter altura superior a 150 mm (figura 8) (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2018).

Figura 8 – Dimensões de um robô SSL (em mm).

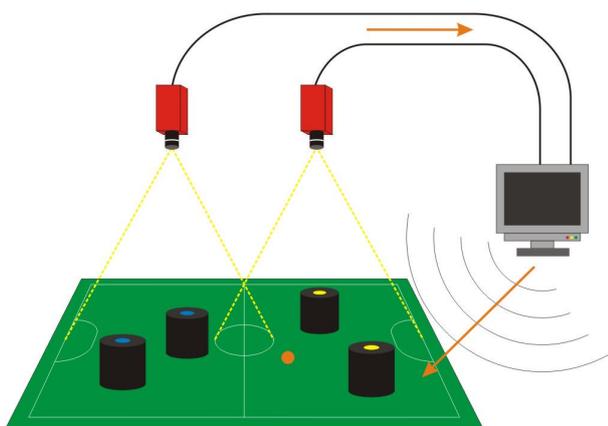


Fonte: Small Size League Technical Committee, 2018

Todos os objetos em campo (bola e robôs) são rastreados e padronizados por um sistema composto por até oito câmeras que são posicionadas em barras de quatro metros acima do campo. O sistema de visão, conhecido como *Shared Vision System for the RoboCup Small Size League (SSL-Vision)*, é um projeto livre e mantido por membros da RoboCup.

Computadores fora do campo recebem as informações indicando as posições dos robôs e da bola. Normalmente, estes computadores podem executar a maior parte, se não a totalidade, do processamento necessário para a coordenação da equipe de robôs. Em outras palavras, cabe a este computador fornecer as posições e estipular as estratégias de jogo. A comunicação é realizada por redes sem fio (exemplo de implementação na figura 9).

Figura 9 – Captura e propagação das localizações da bola e robôs em campo.



Fonte: Robotics Erlangen, 2017

Nos últimos anos, cada time teve a tendência de definir sua estratégia baseado nas posições e velocidades dos companheiros de equipe, oponentes e bola. Sendo que um dos grandes desafios da robótica, principalmente no futebol de robôs, é como prover que

os robôs tomarão decisões sem interferência humana. Na SSL, a velocidade do jogo tem crescido a cada ano e, conseqüentemente, prever o comportamento do adversário é importante. A adaptação em tempo de execução exige performance otimizada, principalmente contra times desconhecidos. Entretanto, as variáveis são vastas e existe pouco tempo para esta adaptação, já que uma partida do SSL tem 20 minutos (10 minutos para cada lado) de duração, com 5 minutos de intervalo (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2017).

### 2.3.1 Regras da SSL

Assim como no futebol humano, a SSL também possui regras. Muitas regras são baseadas no futebol humano, porém existe algumas regras específicas da categoria (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2019b):

- a) Os robôs devem ser totalmente autônomos. Operadores humanos não têm permissão para inserir qualquer informação no sistema durante uma partida, exceto em intervalos ou pedidos de tempo (*timeout*). Os pedidos de tempo são tratados como intervalos, o que significa que ambas as equipes têm permissão para fazer modificações em seus softwares e hardwares;
- b) Atacante na área do gol defensor – um robô não pode tocar na bola quando está parcialmente ou totalmente na área defensiva do oponente;
- c) Falta de progresso – ocorre quando uma equipe está autorizada a manipular a bola e não toca na bola no tempo definido de 5 segundos para chutes diretos ou indiretos e 10 segundos para outros casos;
- d) A bola é considerada em jogo quando movida por mais de 5cm;
- e) Um robô não deve conduzir a bola além de 1 metro, medido linearmente a partir do local da bola onde a condução começou. Um robô começa a conduzir a bola quando faz contato ela e para de conduzir quando há uma separação observável entre a bola e o robô. Os robôs podem ser utilizados para condução da bola por distâncias maiores, desde que o robô perca a posse periodicamente, como chutar a bola à sua frente, como costumam fazer os jogadores de futebol humanos;
- f) A velocidade máxima do robô é 6,5 m/s;

- g) Nos momentos de jogadas paradas, todos os robôs devem se manter a 20 cm de distância da área defensiva;
- h) Não pode ocorrer gols por cobertura.

Uma partida na SSL também é composta por vários comandos (*Referee Commands*) que indicam vários estados do jogo:

- a) STOP – Todos os robôs devem reduzir a velocidade para menos de 1,5 m / s. Além disso, todos os robôs devem manter pelo menos 0,5 metros de distância da bola e não podem toca-la.
- b) HALT – Nenhum robô pode mover-se ou tocar a bola;
- c) NORMAL\_START – Utilizado pelo árbitro em dois estágios. Quando o início normal é enviado, um atacante pode manipular a bola. Uma partida não pode ser retomada diretamente através do comando. É utilizado em conjunto com outros comandos, como cobrança de penalidades máxima;
- d) DIRECT\_FREE\_KICK – Habilita um robô atacante a chutar diretamente em direção ao gol. Os robôs da equipe defensora deverão posicionar-se a 0,5 metros de distância da bola;
- e) INDIRECT\_FREE\_KICK – Um robô pode passar a bola. Em caso de chute direto ao gol, o gol somente será válido se um outro robô tocou na bola após ela ter entrado em jogo.

Esses comandos ou regras foram considerados na definição das diversas equações das métricas (capítulo 4) ou otimização dos posicionamentos (capítulo 5).

## 2.4 FUTURO DA SSL

Weitzenfeld et al. (2015) discutiram sobre a evolução do SSL até o momento e propuseram mudanças para o SSL:

- a) 2015: jogo em um campo maior (ocorreu em 2018);
- b) 2016: introdução da comunicação de rádio padronizada;
- c) 2017 (ocorreu em 2016): introdução do *referee* automático e aumentar a quantidade do número de robôs (times mistos);
- d) 2018 (não ocorreu): introdução do controle a partir do próprio robô (eliminar o controle por um computador);

- e) 2019 (ocorreu em 2018 com divisão em duas ligas): aumentar o tamanho do campo para possibilitar 11 x 11 robôs; melhorar o sistema de visão compartilhada (em estudo para trocar o sistema de cores por algo semelhante ao QRCode a partir de 2022+);
- f) 2020 (ainda em discussão): introdução de treinamento automatizado durante o jogo.
- g) 2020+? (ocorreu a partir de 2016): inclusão de desafios técnicos (compulsórios e obrigatórios para se avançar na liga);
- h) 2020+?: mudança de regras para balancear o jogo ofensivo e defensivo;

Embora não deva haver mudanças físicas nas dimensões do robôs, o item que mais chama atenção é a possibilidade de eliminar o controle por um computador executando o sistema de estratégia e a inclusão do controle no próprio robô. Ainda não está claro se os robôs poderão interagir entre si ou se cada robô deverá executar o próprio sistema de estratégia e se trabalharão de forma colaborativa.

Outra sugestão que chama a atenção é a possibilidade de interação dos humanos com os robôs de forma similar a um jogo real, onde o técnico interage para seus jogadores, de forma que os times possam modificar suas estratégias por comandos de voz ou escritos.

Se qualquer uma das sugestões for aplicada nas próximas competições, é seguro dizer que todas as equipes competidoras terão que fazer alterações significativas nos seus sistemas de estratégia e nos projetos mecânicos e eletrônicos dos robôs

## 2.5 CONSIDERAÇÕES DO CAPÍTULO

A SSL tem evoluído com o passar do tempo com a introdução de novas regras, possíveis mudanças na arquitetura dos robôs e desafios técnicos para as equipes. E essas mudanças na liga abrem novas oportunidades de pesquisas.

As modificações na liga, principalmente implementadas em 2018, aumentam a complexidade de uma partida de futebol de robôs nesta categoria. O posicionamento dos robôs em campo também se torna mais complexo e um correto posicionamento é cada vez mais relevante para o sucesso da equipe.



### 3 INTELIGÊNCIA DE ENXAME

A *Swarm Intelligence* (Inteligência de Exame) (SI) estuda o comportamento coletivo dos sistemas descentralizados e auto-organizados, naturais ou artificiais. O termo foi utilizado pela primeira vez em Beni e Wang (1989).

Os sistemas SI consistem tipicamente em uma população de agentes que interagem localmente um com o outro e com seu ambiente. A inspiração geralmente vem da natureza, especialmente dos sistemas biológicos. Os agentes seguem regras simples e, embora não exista uma estrutura de controle centralizada que dite como os agentes individuais devem comportar-se as interações entre esses agentes levam ao surgimento de um comportamento global *inteligente*. Exemplos em sistemas naturais de SI incluem colônias de formigas, agrupamento de aves, criação de animais, crescimento bacteriano ou cardumes de peixes (REYNOLDS, 1987; EBERHART; SHI; KENNEDY, 2001; SPECTOR et al., 2003; DORIGO; STÜTZLE, 2004).

Grupos de animais ou insetos, que vivem socialmente em conjuntos, fornecem exemplos de fenômenos coletivos em que repetidas interações entre indivíduos produzem padrões dinâmicos e respostas em uma escala maior que os próprios indivíduos. De fato, algoritmos bioinspirados são amplamente estudados e aplicados em várias situações tais como: distribuição de energia, resolução de problemas do tipo caixeiro-viajante, descoberta de caminhos entre tantos outros propósitos.

Este capítulo apresenta algumas características, propriedades, conceitos e algoritmos de SI.

#### 3.1 INTRODUÇÃO AO SI

Os sistemas de enxame são uma rica fonte de novos métodos computacionais que visam resolver problemas difíceis de forma eficiente e confiável.

Quando enxames resolvem problemas na natureza, suas habilidades geralmente são atribuídas à inteligência do enxame. Talvez o exemplo mais conhecido sejam as colônias de insetos sociais, como cupins, abelhas e formigas (EBERHART; SHI; KENNEDY, 2001).

Várias pesquisas de sistemas em que os fenômenos coletivos ocorrem prepararam o terreno para o desenvolvimento da Inteligência de enxames. Não obstante suas caracte-

rísticas físicas ou diferenças estruturais, tais sistemas compartilham propriedades comuns, reconhecidas como os cinco princípios básicos da inteligência dos enxames (MILLONAS, 1994):

- a) Proximidade: capacidade de realizar cálculos de espaço e tempo.
- b) Qualidade: capacidade de responder a fatores de qualidade ambiental.
- c) Respostas diversas: capacidade de produzir uma pluralidade de respostas diferentes.
- d) Estabilidade: capacidade de manter comportamentos robustos sob mudanças ambientais suaves.
- e) Adaptabilidade: capacidade de mudar o comportamento quando é ditado por fatores externos.

O termo *Swarm Robotics* (robótica de enxame) é uma abordagem para a coordenação de sistemas de múltiplos robôs, que consiste da utilização de uma quantidade significativa de robôs para resolução de um problema (BRAMBILLA et al., 2013). Supõe-se que um comportamento coletivo desejado possam emergir das interações entre robôs e interações de robôs com o meio ambiente, sendo, portanto, uma abordagem coletiva que se inspira nos comportamentos auto-organizados sociais dos animais (BRAMBILLA et al., 2013).

Normalmente, a robótica de enxame envolve a construção de robôs mais simples, mas que trabalhando em conjunto permitem a resolução de problemas complexos. A simplicidade de um robô permite manter o custo individual mais baixo e assim, ganhar escalabilidade tornando cada membro do enxame menos exigente de recursos.

Nesse contexto, o ambiente da SSL é propício para a aplicação de algoritmos de enxame, pois possuem vários aspectos em comum: comportamento coletivo, devem interagir entre si e com o ambiente, permitem o controle descentralizado e múltiplos agentes.

Nos últimos anos, surgiram várias propostas e variações de algoritmos baseados no comportamento coletivo de enxames, como partículas autopropulsionadas (VICSEK et al., 1995), comportamento altruísta (WAIBEL; FLOREANO; KELLER, 2011), otimização por colônia de formigas (DORIGO; STÜTZLE, 2004), vagalume (YANG, 2009), entre outros. Cada algoritmo visando resolver um tipo específico de problema, como coordenação, movimentação ou busca de caminhos. Uma das melhores técnicas desenvolvidas deste tipo foi o *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO) (EBERHART; SHI; KENNEDY, 2001).

As próximas seções detalham as características do algoritmo PSO utilizado nesse trabalho.

### 3.2 *Particle Swarm Optimization* (Otimização de Enxame de Partículas) (PSO)

O PSO é um método computacional que otimiza um problema tentando iterativamente melhorar uma solução candidata em relação a uma determinada medida de qualidade. É um algoritmo heurístico baseado no comportamento social de pássaros. Proposto por J. Kennedy e R. Eberhart (1995), o algoritmo tem como objetivo buscar uma solução ótima, em um espaço de busca, através da troca de informações entre indivíduos de uma população determinando qual trajetória cada um deles deverá tomar no espaço de busca.

#### 3.2.1 Definições do PSO

A fim de determinar uma terminologia padrão, alguns termos devem ser formalmente definidos (ENGELBRECHT, 2001; REYES-SIERRA; COELLO, 2006; POLI; KENNEDY; BLACKWELL, 2007):

- a) Enxame (*swarm*) – população do algoritmo;
- b) partícula (*particle*) – membro (individual) do enxame. Cada partícula representa uma solução potencial do problema a ser resolvido;
- c) partícula *pbest* (oriundo de *personal best*) – melhor posição de uma partícula até o momento. Ou seja, a posição da partícula que proporcionou o maior sucesso (medido em termos escalares);
- d) partícula *lbest* (oriundo de *local best*) – posição da melhor partícula em relação a sua vizinhança;
- e) partícula *gbest* (oriundo de *global best*) – posição da melhor partícula do enxame;
- f) partícula líder – partícula que é usada como referência para guiar outras partículas no espaço de busca;
- g) velocidade – determina a direção que a partícula precisa se mover para melhorar sua posição;
- h) inércia – O fator de inércia é usado para controlar a exploração e exploração no espaço de busca. Um alto valor faz com que a partícula siga um compor-

tamento mais global, enquanto um valor mais baixo faz com a que partícula tenha um comportamento mais local;

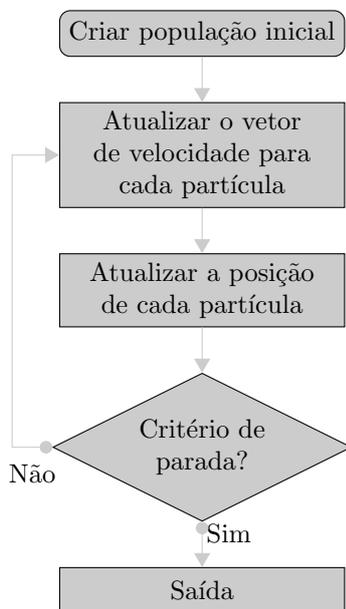
- i) variável Cognitiva ( $c_1$ ) – representa o quanto as partículas tendem a seguir seu próprio comportamento passado em caso de sucesso;
- j) variável social ( $c_2$ ) – representa a tendência de seguir o sucesso de outros indivíduos;
- k) topologia da vizinhança – determina o conjunto de partículas que contribuem para o cálculo do *lbest* de uma determinada partícula.

As influências que valores dos parâmetros e topologias exercem sobre o funcionamento do algoritmo PSO são detalhadas nas seções 3.2.3 e 3.2.4.

### 3.2.2 O algoritmo

Os procedimentos do algoritmo básico PSO é dividido em algumas etapas (figura 10).

Figura 10 – Fluxograma do PSO.



Fonte: Autor

- a) 1ºPasso – Iniciar uma população de partículas com posições e velocidades geradas aleatoriamente no espaço dimensional  $n$ ;

- b) 2ºPasso – Avaliar a função de aptidão;
- c) 3ºPasso – Atualizar a velocidade de cada partícula de acordo com a Equação (1);
- d) 4ºPasso – Atualizar a posição de cada partícula, de acordo com a Equação (2);
- e) 5ºPasso – Mapear a posição de cada partícula dentro do espaço de solução e avaliar o valor da função de aptidão. E ao mesmo tempo, atualizar o *pbest* e *gbest* caso necessário;
- f) 6ºPasso – Voltar à Etapa 2 até que o critério de parada seja atingido. Geralmente esse critério é um valor de aptidão suficientemente bom ou atingiu-se um número máximo de iterações.

O algoritmo PSO realiza pesquisas através de um enxame de partículas que se atualiza a cada iteração. Para buscar a solução ideal, cada partícula se move na direção da sua melhor posição (*pbest*) anterior e a melhor posição global (*gbest*) no enxame como pode ser observado nas equações de (1) e (2) (ZHANG; WANG; JI, 2015). Para funções de minimização busca-se o menor valor (*argmin*), para maximização o maior valor (*argmax*).

$$\begin{aligned}
 pbest(i,t) = \underset{i \in 1,2,\dots,N_p}{\operatorname{argmin}}[f(P_i(k))], & \quad pbest(i,t) = \underset{i \in 1,2,\dots,N_p}{\operatorname{argmax}}[f(P_i(k))], \\
 k = 1,\dots,t & \quad \text{ou} & \quad k = 1,\dots,t
 \end{aligned} \tag{1}$$

$$\begin{aligned}
 gbest(t) = \underset{i \in 1,\dots,N_p}{\operatorname{argmin}}[f(P_i(k))], & \quad gbest(t) = \underset{i \in 1,\dots,N_p}{\operatorname{argmax}}[f(P_i(k))], \\
 k = 1,\dots,t & \quad \text{ou} & \quad k = 1,\dots,t
 \end{aligned} \tag{2}$$

Sendo que  $i$  é o índice da partícula;  $N_p$  indica número total de partículas;  $t$  informa a iteração corrente;  $f$  é a função de aptidão; e,  $P$  indica a posição da partícula  $i$ .

No algoritmo PSO cada partícula tem uma velocidade associada aleatoriamente, permitindo assim que as soluções potenciais se movimentem pelo espaço de busca do problema a ser otimizado. Entretanto, cada partícula mensura a sua orientação mediante a avaliação da função objetivo e conserva seu conhecimento do melhor valor de orientação (*pbest*), por meio de uma memória individual e uma memória coletiva. A memória individual permite que a partícula lembre a posição (no espaço de busca) em que encontrou o seu

$pbest$ , e a memória coletiva permite que as partículas lembrem a posição em que o enxame encontrou o melhor valor global ( $gbest$ ).

A velocidade  $V$  e a posição  $P$  das partículas é atualizada a partir das equações (3) e (4) respectivamente:

$$V_i(t+1) = \underbrace{\omega V_i(t)}_{\substack{\text{inércia} \\ \text{diversificação}}} + \underbrace{c_1 r_1 (pbest(i,t) - P_i(t))}_{\text{cognitiva}} + \underbrace{c_2 r_2 (gbest(t) - P_i(t))}_{\text{social}} \quad (3)$$

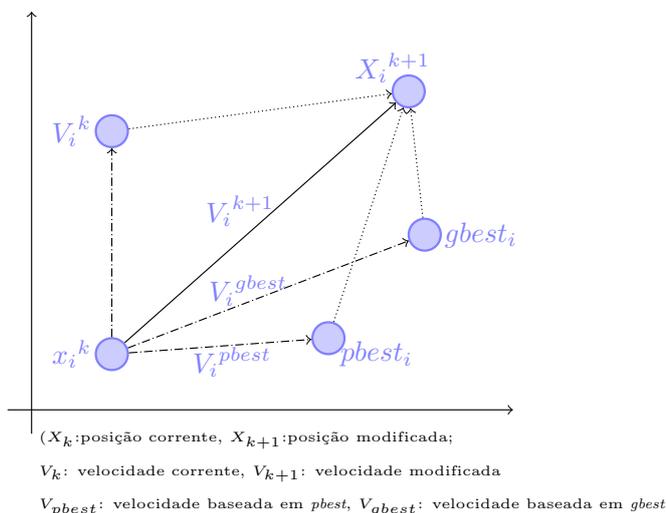
intensificação

$$P_i(t+1) = P_i(t) + V_i(t+1) \quad (4)$$

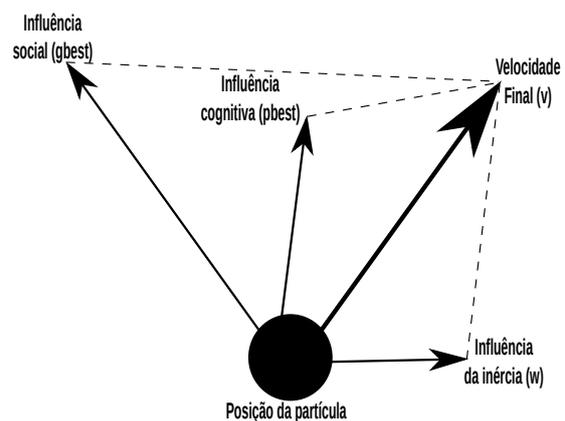
Onde  $V$  denota a velocidade,  $\omega$  é o fator de inércia utilizado para equilibrar a exploração global e a exploração local,  $r_1$  (parte cognitiva)  $r_2$  (parte social) são variáveis randômicas uniformemente distribuídas no intervalo  $[0,1]$ , e  $c_1$  (parâmetro de confiança para a parte cognitiva) e  $c_2$  (parâmetro de confiança para a parte social) são parâmetros constantes positivos chamados de *coeficientes de aceleração*.

Figura 11 – Mudança de posição de uma partícula no PSO.

(a) Representação da equação de velocidade.



(b) Influências na equação de velocidade.

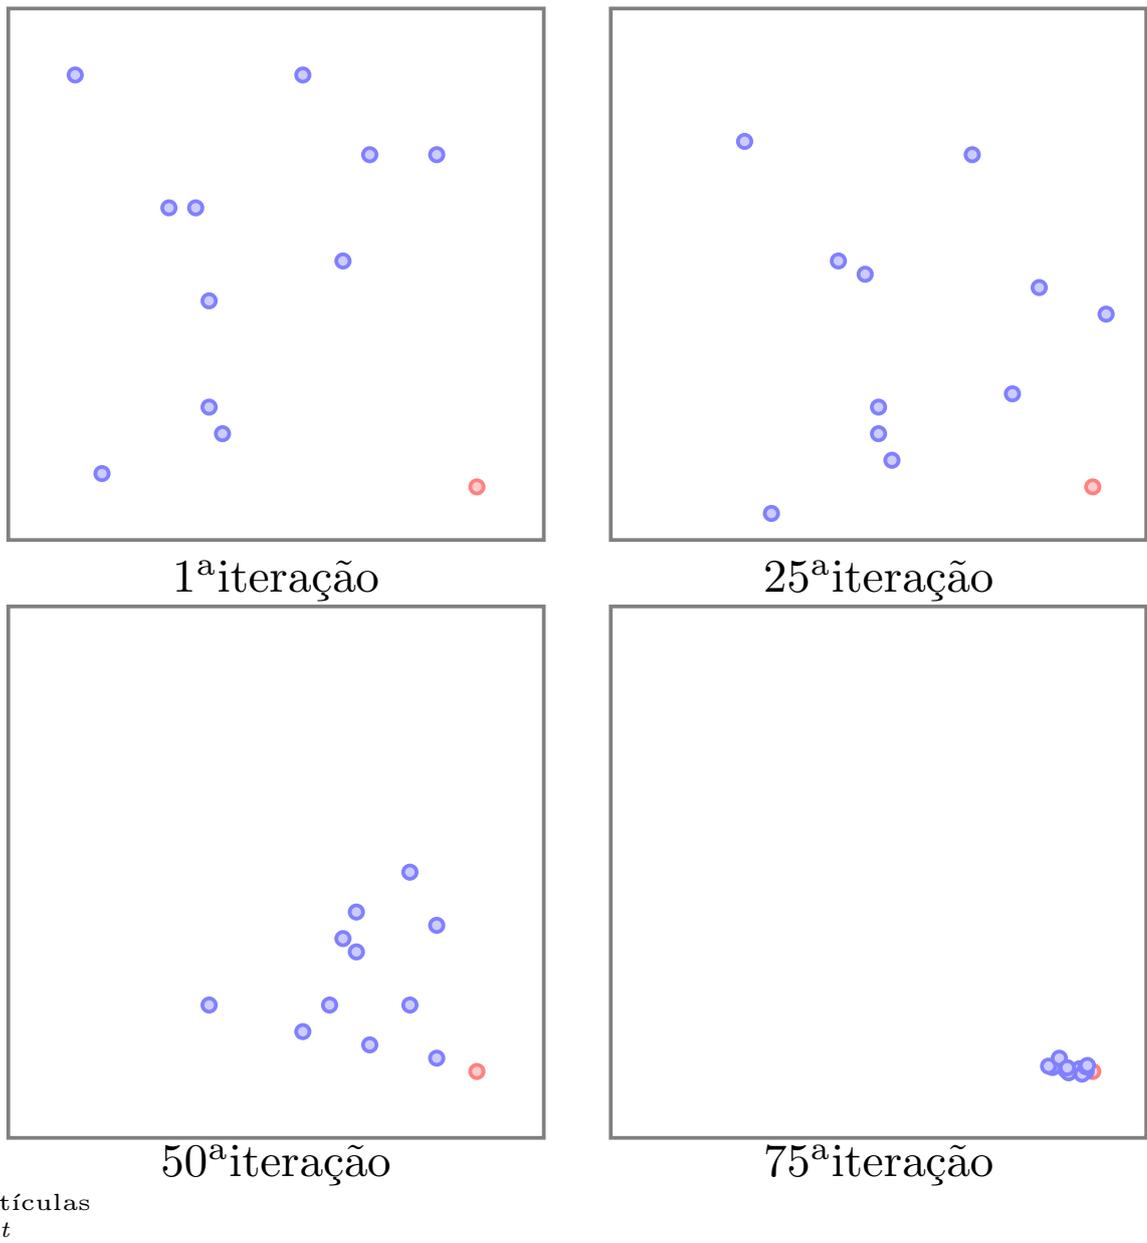


Fonte: Autor "adaptado de" Clerc (2006) e Konstantinos Parsopoulos e Michael Vrahatis (2010)

A figura 11 ilustra o conceito de mudança de posição de uma partícula no PSO, onde a nova posição  $X_i^{k+1}$  é calculado a partir da velocidade  $V_i^{k+1}$ . Finalmente a figura 12 apresenta um possível comportamento das partículas a medida que as iterações ocorrem.

O algoritmo na figura 13 apresenta o algoritmo padrão do PSO:

Figura 12 – Exemplificação das mudanças ao longo das iterações.



Fonte: Autor

### 3.2.3 Considerações sobre alguns parâmetros do algoritmo

O espaço de busca pode ser definido na forma  $[X_{min}, X_{max}]^D$  ( $X_{min}$  indica valor mínimo,  $X_{max}$  valor máximo e  $D$  o número de dimensões). A distribuição das partículas devem ocorrer de forma uniformemente distribuída no espaço de busca, porém as partículas possuem uma velocidade que é atualizada a cada iteração podendo ocasionar que as partículas saiam do espaço de busca prematuramente. Assim, Clerc (2006) sugere que as partículas sejam distribuídas uniformemente no espaço  $[\frac{X_{min}-X_{max}}{2}, \frac{X_{max}-X_{min}}{2}]$ .

Figura 13 – Pseudocódigo do PSO padrão.

```

1 Passo 1. Inicialização
2 início
3   para cada partícula  $i \in 1, \dots, N_p$  faça
4     Inicializa posição da partícula distribuído de forma uniforme sendo
        $P_i(0) \sim U(LB, UB)$ , onde LB e UB representa os limites da parte baixa
       e alta do espaço de busca
5     Inicializa pbest para a posição inicial:  $pbest(i,0) = P_i(0)$ 
6     Inicializa gbest para o menor valor do enxame:
        $gbest(0) = argmin_f[P_i(0)]$ 
7     Inicializa a velocidade:  $V_i \sim U(-|UB - LB|, |UB - LB|)$ 
8   fim
9 fim

10 Passo 2. Repete até o critério ser alcançado
11 início
12   para cada partícula  $i \in 1, \dots, N_p$  faça
13     Escolha aleatoriamente:  $r_1, r_2 \sim U(0,1)$ 
14     Atualiza a velocidade da partícula:
        $V_i(t+1) = \omega V_i(t) + c_1 r_1 (pbest(i,t) - P_i(t)) + c_2 r_2 (gbest(t) - P_i(t))$ 
15     Atualiza a posição da partícula:  $P_i(t+1) = P_i(t) + V_i(t+1)$ 
16     se  $f[P_i(t)] < f[pbest(i,t)]$  então
17       Atualiza a melhor posição conhecida da partícula i:  $pbest(i,t) = P_i(t)$ 
18       se  $f[P_i(t)] < f[gbest(t)]$  então
19         Atualiza a melhor posição do enxame:  $gbest(t) = P_i(t)$ 
20       fim
21        $t \leftarrow (t + i)$ 
22     fim
23   fim
24 fim

25 Passo 3. retorna ( $gbest(t)$ ) como a melhor solução
Fonte: Autor "adaptado de" Zhang, Wang e Ji, 2015

```

O uso de um parâmetro  $v_{max}$  como mecanismo de controle de velocidade tornou-se crucial. Altos valores de velocidade poderiam resultar em partículas saindo da área de busca das boas soluções enquanto baixos valores poderiam resultar em uma exploração insuficiente do espaço de busca. Angeline (1998) comprovou que a ausência de um mecanismo de controle da velocidade permitia uma baixa eficiência do algoritmo PSO em comparação a outras técnicas evolucionárias.

Shi e Eberhart (1998) introduziram o conceito de inércia para controlar a exploração (*exploration*) e exploração (*exploitation*) do espaço de busca. O fator de inércia controla a

capacidade de exploração das partículas. Valores grandes de  $\omega$  resultam em uma busca global enquanto valores pequenos de  $\omega$  permitem às partículas explorar localmente a vizinhança de uma possível solução.

O valor de inércia é o principal fator desempenho para a convergência do PSO, sendo amplamente pesquisado na literatura (EBERHART; SHI, 2001; CLERC; KENNEDY, 2002; CHATTERJEE; SIARRY, 2006; CHEN et al., 2006; ARUMUGAM; RAO, 2006; MALIK; RAHMAN; SITI ZAITON MOHD. HASHIM, 2007; FENG et al., 2007; GAO; AN; LIU, 2008; NICKABADI; EBADZADEH, 2008; KENTZOGLANAKIS; POOLE, 2009; LI; GAO, 2009; XIN; CHEN; HAI, 2009; NICKABADI; EBADZADEH; SAFABAKHSH, 2011; BANSAL et al., 2011; JORDEHI; JASNI, 2013; ZHANG; WANG; JI, 2015).

Entre as principais contribuições, pode-se destacar a variação linear da inércia proposta por Eberhart e Shi (2001) e não linear proposta por Chatterjee e Siarry (2006).

Eberhart e Shi (2001) propuseram que o valor da inércia deve estar no intervalo  $0,4 \leq \omega \leq 0,9$  a partir da equação (5).

$$\omega_i = (\omega_{inicial} - \omega_{final}) \times \frac{N - i}{N} + \omega_{final} \quad (5)$$

Onde  $\omega_{inicial}$  e  $\omega_{final}$  são os valores iniciais e finais da inércia,  $i$  a iteração atual  $\omega_i$  o valor da inércia para a iteração  $i$  e  $N$  o total de iterações.

Outros autores sugerem que peso da inércia inicial em torno de 1,2 e decaindo ao longo das iterações até o valor zero pode ser considerado uma boa escolha para  $\omega$  (PARSOPOULOS, K. E.; VRAHATIS, M. N., 2002; PARSOPOULOS, K.; VRAHATIS, M., 2010).

Chatterjee e Siarry (2006) propuseram que  $\omega_{inicial}$  e  $\omega_{final}$  permaneçam inalterados, porém, no decorrer das iterações o valor de inércia é controlado por um expoente de não linearidade (equação (6)).

$$\omega_i = \frac{N - i^n}{N^n} \times (\omega_{inicial} - \omega_{final}) + \omega_{final} \quad (6)$$

Onde  $\omega_{inicial}$  e  $\omega_{final}$  são os valores iniciais e finais da inércia,  $i$  a iteração atual,  $\omega_i$  o valor da inércia para a iteração  $i$ ,  $N$  o total de iterações e  $n$  um expoente de não linearidade.

Os coeficientes de aceleração representam a ponderação dos termos de aceleração estocásticos que influenciam as partículas para aproximar-se de  $pbest$  e  $gbest$ . Se o valor

dessas constantes for muito alto, as partículas se movem abruptamente e o risco de ficar preso em falsos ótimos aumenta. Por outro lado, se o seu valor também é baixo, as partículas se movem muito devagar, o esforço computacional aumenta significativamente e é provável que o algoritmo não consiga convergir para uma solução ideal.

A escolha dos coeficientes de aceleração afetam o comportamento do algoritmo. Escrevendo  $c_1r_1$  e  $c_2r_2$  (equação (3)) como  $\varphi_1$  e  $\varphi_2$ , respectivamente, observa-se que: se  $\varphi_1 > 0$  e  $\varphi_2 = 0$ , apenas a confiança individual da partícula influencia a atualização da velocidade; se  $\varphi_1 = 0$  e  $\varphi_2 > 0$ , apenas a confiança da partícula do enxame influencia na atualização da velocidade; se o coeficiente de aceleração  $\varphi_1 > \varphi_2$ , a atração para a partícula  $pbest$  é incrementada e para  $gbest$  diminui. O inverso ocorre se  $\varphi_1 < \varphi_2$ . Na literatura, os valores  $c_1 = c_2 = 2$  são bem aceitos para a maioria das implementações do PSO (POLI; KENNEDY; BLACKWELL, 2007; JORDEHI; JASNI, 2013; ZHANG; WANG; JI, 2015).

James Kennedy (1998) ponderam que os valores ideais estejam no intervalo  $0 \leq \varphi_1 + \varphi_2 \leq 4$ . Clerc e Kennedy (2002) consideram ideal  $\varphi = \varphi_1 + \varphi_2 > 4$  e quando  $\varphi = 4,1$ , considerando  $\varphi_1 = \varphi_2$ , o valor de multiplicação  $\chi \approx 0,7298$ , obtido na equação (7), é  $\chi \times 2,05 \approx 1,49618$ .

Em várias implementação do PSO, as variáveis inércia e coeficientes são ajustados como  $\omega = 0,7298$  e  $c_1 = c_2 = 1,49618$  sendo esses os valores mais encontrados na literatura, pois resulta no decrescimento gradual da amplitude da trajetória das partículas, assegurando assim a convergência do algoritmo (CLERC; KENNEDY, 2002).

$$\chi = \frac{2}{\varphi - 2 + \sqrt{\varphi^2 - 4\varphi}} \quad (7)$$

A própria velocidade da partícula tende a fazê-la deixar o espaço de busca. Clerc (2006) propõe um intervalo de confinamento para manter a partícula no espaço de busca. O mecanismo consiste em limitar o espaço de busca, fazendo com que a partícula fique presa ao limiar da região delimitada, se uma nova coordenada calculada de acordo com a equação (4) resultar em  $X_{n,d} \notin [X_{min}, X_{max}]$ , um valor limítrofe será atribuído a  $X_{n,d}$  por meio da equação (8).

$$X_{n,d} = \min(\max(X_{n,d} + v_{nd}, X_{min}), X_{max}). \quad (8)$$

A equação não altera a velocidade da partícula, que será calculada novamente e provavelmente permaneça orientada na mesma direção, assim a partícula tenderá a cruzar o espaço definido sendo confinada novamente sucessivamente. Nesse caso pode-se anular ( $v_i = 0$ ) ou inverter ( $v_i = v_i \times -1$ ) a velocidade da partícula.

No contexto da tese, conforme detalhados no capítulo 6, os resultados obtidos pelo algoritmo PSO dependem de uma correta parametrização relacionada com o problema a ser otimizado, nesse caso, o posicionamento de robôs em campo.

### 3.2.4 Topologias

Na implementação do algoritmo PSO, a velocidade da partícula é atualizada com base na inércia, cognição e componentes sociais. A forma como as partículas podem ser conectadas umas as outras influencia o resultado geral, sendo importante considerar a sociometria do enxame, diferenciando a forma como a informação deve ser compartilhada entre as partículas, no intuito de melhorar o desempenho do algoritmo (KENNEDY, J., 1999). Essas conexões entre partículas vizinhas são representados por um grafo (ENGELBRECHT, 2001; REYES-SIERRA; COELLO, 2006; POLI; KENNEDY; BLACKWELL, 2007; DORIGO; OCA; ENGELBRECHT, 2008; PARSOPOULOS, K.; VRAHATIS, M., 2010).

A figura 14 exemplifica essas topologias descritas em seguida:

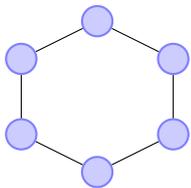
- a) Grafo vazio: nessa topologia as partículas são isoladas. Cada partícula é conectada somente consigo mesmo e a comparação da posição corrente somente ocorre a sua melhor posição encontrada (*pbest*). Nesse caso, a variável  $c_2 = 0$  na equação (3).
- b) Local best: nessa topologia, cada partícula é ligada a  $k$  partícula. Cada partícula é influenciada por sua melhor *pbest* posição e pela melhor posição da vizinhança (*lbest*). Quando  $k = 2$ , têm-se uma topologia conhecida como anel onde cada partícula é afetada apenas por seus dois vizinhos adjacentes.
- c) Global Best: ao contrário do grafo vazio, essa topologia é representado por um grafo totalmente conectado. Todas as partículas são conectadas umas as outras. Cada partícula é influenciada pela sua melhor posição (*pbest*) e também pela melhor posição de uma partícula do enxame (*gbest*).
- d) Estrela: A partícula focal está conectada às demais partículas e essas conectados somente a partícula focal (figura 14). A partícula focal compara o

desempenho das demais partículas e com base nisso faz seu movimento. As outras partículas seguem o movimento da partícula focal.

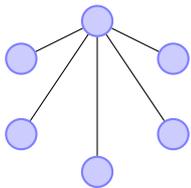
- e) **Árvore:** nessa topologia, todas as partículas são dispostos em uma árvore e cada nó da árvore contém exatamente uma partícula. Uma partícula é influenciado pela sua melhor posição até o momento (*pbest*) e pela melhor posição da partícula que está diretamente acima na árvore (pai). Se uma partícula em um nó filho encontrou uma solução melhor do que a melhor partícula do nó pai, ocorre uma troca de posições na árvore. Assim, essa topologia oferece vizinhança dinâmica.
- f) **Von Neumann:** as partículas estão conectadas na forma de uma grade, ou seja, diretamente ligados a outras quatro partículas na vizinhança.

Figura 14 – Diferentes topologias – Cada partícula é representada por um círculo.

(a) LBest – Anel.

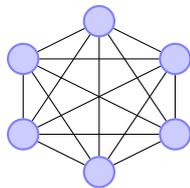


(c) Estrela.

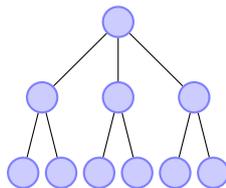


Fonte: Autor

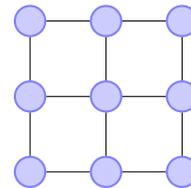
(b) GBest – grafo totalmente conectado.



(d) Árvore.



(e) Von Neumann.



Na literatura, as topologias mais utilizadas tem sido a *gbest* (melhor global) e *lbest* (melhor local). Um algoritmo PSO com topologia *gbest* converge rapidamente devido a que todas as partículas são fortemente atraídas pela melhor partícula no enxame, produzindo assim resultados sub-ótimos quando a melhor partícula encontra-se presa num mínimo local. Por outro lado, um algoritmo PSO com topologia *lbest* converge lentamente, porém com maiores chances de encontrar o ótimo global, pois cada partícula é influenciada apenas pelos vizinhos adjacentes e, portanto, grupos de vizinhos podem explorar distintas regiões ou ótimos locais no espaço de busca (KENNEDY; MENDES, 2002).

Nesta tese, conforme explicado no capítulo 6, topologias *gbest* e *lbest* serão avaliadas a fim de determinar qual topologia permite que o algoritmo PSO obtenha um melhor desempenho global para o encontrar o posicionamento de robôs em campo.

### 3.2.5 Variantes do PSO

O algoritmo PSO sofreu várias modificações desde sua proposição. Algumas mudanças afetam a forma como a velocidade da partícula é atualizada, alguns têm resultado em desempenho geral melhorado enquanto outros têm melhor desempenho em relação a determinados tipos de problemas (POLI; KENNEDY; BLACKWELL, 2007; DORIGO; OCA; ENGELBRECHT, 2008; ZHANG; WANG; JI, 2015; PIOTROWSKI; NAPIORKOWSKI; PIOTROWSKA, 2020).

No PSO binário, cada indivíduo da população só tem conhecimento da decisão binária que deve tomar: sim/não ou verdadeiro/falso. Em James Kennedy e Russell C. Eberhart (1997) é descrita uma reformulação do algoritmo PSO para operar com variáveis binárias. Na versão binária as partículas não são encaradas como possíveis soluções, mas sim probabilidades e as trajetórias são modificadas conforme a probabilidade de que uma coordenada de uma partícula assumirá o valor zero ou um.

Alguns pesquisadores observaram uma tendência para levar o enxame a convergir prematuramente em sub-ótimos locais (POLI; KENNEDY; BLACKWELL, 2007). Assim, surgiram os algoritmos PSO com controle de diversidade, onde várias abordagens foram implementadas para corrigir o declínio de diversidade à medida que o enxame se concentra em um simples ótimo.

Vários investigadores tem tentado adaptar parâmetros do algoritmo PSO, em resposta a informações a partir do ambiente (POLI; KENNEDY; BLACKWELL, 2007). Técnicas da computação evolucionária e outros métodos, como algoritmos genéticos foram adaptados pelos pesquisadores do PSO. Um dos modelos híbridos e adaptativos consiste na seleção de partículas. Partículas *boas* eram reproduzidas e as partículas *ruins* são descartadas (ANGELINE, 1998).

Várias outras modificações foram propostas por pesquisadores ao longo dos anos, maiores detalhes dessas variações podem ser obtidas em (EBERHART; SHI; KENNEDY, 2001; EBERHART; SHI, 2001; POLI; KENNEDY; BLACKWELL, 2007; DORIGO; OCA;

ENGELBRECHT, 2008; PARSOPOULOS, K.; VRAHATIS, M., 2010; KENNEDY, James, 2010; ZHANG; WANG; JI, 2015).

O algoritmo PSO com as inclusões do fator de inércia e coeficientes cognitivo e social são os mais encontrados na literatura, sendo conhecidos academicamente como algoritmo PSO canônico. Este trabalho utilizará essa versão do algoritmo PSO como base.

### 3.3 CONSIDERAÇÕES DO CAPÍTULO

A primeira aplicação prática do PSO foi para o treinamento de uma rede neural e foi relatada juntamente com o próprio algoritmo. Muitas áreas de aplicação foram exploradas desde então, incluindo telecomunicações, controle, mineração de dados, design, otimização combinatória, sistemas de energia, processamento de sinal e muitos outros. Até o momento, existem centenas de publicações que relatam aplicações de algoritmos de otimização de enxames de partículas.

Embora o PSO tenha sido utilizado principalmente para resolver problemas de otimização sem restrições e de objetivo único, o algoritmo PSO sofreu modificações para resolver problemas restritos, problemas de otimização multiobjetivos, problemas com paisagens dinâmicas e encontrar soluções múltiplas.

É importante evidenciar que o ambiente do SSL é conveniente para a aplicação de algoritmos bioinspirados. É composto de vários robôs que devem trabalhar de forma colaborativa para chegar a um resultado desejado. Contudo, exige aplicações de software que acompanhem a dinâmica e características das partidas de futebol.

Nesse trabalho, o algoritmo PSO foi escolhido devido a uma série de características: é um algoritmo versátil, aplicado em várias áreas do conhecimento; converge rapidamente para um conjunto de respostas satisfatórios; possui baixo custo computacional ao ser comparado com o aprendizado; é menos complexo e requer um pequeno número de parâmetros para ser otimizado; permite flexibilização entre a exploração local e a global no espaço de busca.

## 4 NOVA MÉTRICA PARA AVALIAÇÃO DOS POSICIONAMENTOS

No futebol os resultados costumam ser o melhor indicador do desempenho de uma equipe em uma determinada competição, mas insuficientes para um treinador avaliar o desempenho geral de sua equipe. Como consequência, as ferramentas de medição táticas desempenham um papel importante nessa área específica.

Podemos dizer que a tática é a aplicação da estratégia traçada pelo treinador e que também está diretamente relacionada a forma de distribuição dos jogadores em campo, tanto no momento inicial do jogo, quanto em suas variações nos momentos ofensivos e defensivos.

### 4.1 IMPORTÂNCIA DOS PRINCÍPIOS TÁTICOS

Neste trabalho, os princípios táticos foram os norteadores do desenvolvimento das equações de otimização defensiva (capítulo 5). Particularmente, os princípios fundamentais defensivos foram os direcionadores. Os princípios observados foram (GARGANTA, 2008; COSTA et al., 2009; TEOLDO DA COSTA et al., 2010; COSTA et al., 2011):

- a) **Contenção:** caracteriza-se pela rápida realização de oposição ao portador da bola. Um defensor (jogador de contenção) deve se aproximar o mais rápido possível do portador da bola na tentativa de induzir o adversário ao erro e, por consequência, sua equipe recuperar a posse de bola. Em termos operacionais, a contenção tem como objetivo: impedir o chute a gol; impedir a progressão; retardar ação do oponente; direcionar o jogo para as zonas com menor risco;
- b) **Cobertura defensiva:** o objetivo é os demais defensores oferecerem apoio defensivo ao jogador de contenção. A cobertura defensiva visa servir de novo obstáculo ao portador da bola atuando como segunda contenção ou obstruindo possíveis linhas de passe caso o adversário passe pelo jogador de contenção. O objetivo é transmitir segurança e confiança ao jogador de contenção para que ele tenha iniciativa de combate às ações ofensivas do portador da bola. Operacionalmente, o jogador que faz cobertura defensiva deve procurar se posicionar, preferencialmente, entre o jogador de contenção e a baliza;

- c) Equilíbrio: pauta-se na premissa de possuir superioridade, ou no mínimo garantir igualdade, numérica setorial de jogadores nas relações de oposição no Centro de Jogo, espaço de jogo entre a bola e a própria baliza. O equilíbrio setorial é necessário para não deixar jogador(es) adversário(s) sem marcação, para isso pode-se dividir o campo em setores imaginários (com quantidade e tamanho variados). Em linhas gerais, visa assegurar a estabilidade defensiva na região de disputa da bola;
- d) Concentração: objetiva aumentar a proteção defensiva na zona de maior risco à baliza. Visa diminuir a penetração adversária, direcionar a bola para zonas de menor risco, marcar adversários que buscam aumentar o espaço de jogo ofensivo e o número de jogadores entre a bola e o gol;
- e) Unidade defensiva: tem como objetivo a redução do espaço de jogo efetivo da equipe adversária. A unidade defensiva permite defesa em unidade ou bloco, reduzindo o espaço de jogo, com diminuição da amplitude defensiva da equipe na sua largura e profundidade. A defesa em bloco reduz os espaços livres que o time adversário poderia utilizar para dar continuidade às suas ações ofensivas.

Ainda, existem vários tipos de marcação no futebol, uma delas é o *pressionamento por área* que é uma forma de marcação por zona baseada na recuperação ativa da bola (HUGHES, 1998). É uma ação tática defensiva e coletiva com a finalidade de não deixar liberdade alguma de ação ao adversário e, por tanto, trata de romper sua zona de interesse do jogo ofensivo.

A pressão por área tem origem no futebol do carrossel holandês da década de 70. A estratégia consiste em adiantar o posicionamento inicial de todos os jogadores, sufocando o adversário, ocupando espaços e diminuindo o tempo necessário para o time rival pensar o jogo. Essa estratégia vem sendo aperfeiçoada ao longo dos anos por técnicos de futebol.

#### 4.2 SISTEMA DE AVALIAÇÃO TÁTICA NO FUTEBOL – FUT–SAT

Independente das técnicas estratégicas utilizadas, não existe uma métrica ideal para analisar a efetividade da aplicação das diversas técnicas computacionais. Em sua grande maioria, para justificar a eficiência de uma técnica de estratégia, os pesquisadores

comparam resultados de partidas de futebol antes e depois, normalmente contabilizando o resultado da partida em números de gols (pró ou contra) como índice de sucesso (ABREU et al., 2011; NAKASHIMA et al., 2015).

Abreu et al. (2011) apresentaram uma heurística, baseada em coordenadas cartesianas, para determinar o desempenho geral de uma equipe em futebol real. A validação dos experimentos foi realizada com partidas da RoboCup 2D e permitiu identificar várias situações em uma partida de futebol, tais como: número de passes certos, tempo de posse da bola, chutes a gol, laterais e outras situações em campo.

Embora não seja possível conhecer exatamente uma estratégia que uma equipe está adotando, essa estratégia está bem representada pela forma como os jogadores da equipe chutam durante os jogos. Partindo dessa premissa Nakashima et al. (2015) propuseram que chutes extraídos, como passes e dribles, formam uma distribuição de chutes, o que pode representar a estratégia da equipe. Para mostrar a utilidade da distribuição de chutes, técnicas de cluster são utilizadas para agrupar essa distribuição e reduzir a incerteza na previsão dos resultados do jogo.

Para Abreu et al. (2011), o ideal é observar determinados comportamentos em campo para analisar o desempenho geral da equipe, tais como:

- a) Jogador – localização (coordenadas cartesianas dentro do campo), orientação (orientação do corpo e da cabeça), parâmetros de energia (resistência, esforço, recuperação) e recursos de visualização (largura e qualidade), entre outros, de todos os jogadores;
- b) Bola – localização (coordenadas cartesianas);
- c) Jogo – ciclo de simulação atual, estado do jogo (reposição, impedimento, canto, chute a gol e outros), nomes de equipes e pontuação atual.

Existem outras iniciativas de pesquisa, com diferentes abordagens, que visam extrair estatísticas de equipes a partir dos registros históricos (análise de vídeos de jogo, por exemplo). Embora sirvam como indicadores de eficiência de uma equipe, essas estatísticas apresentam o panorama global do jogo e ainda persistem dificuldades de determinar a real eficiência em situações específicas de jogo.

Com base na dificuldade de avaliar taticamente equipes de futebol, Costa et al. (2011) propuseram uma metodologia de teste chamada de Sistema de Avaliação Tática no Futebol (FUT-SAT). Essa metodologia é amplamente validada na área de educação física

e esportes. A adaptação dessa métrica é proposta neste trabalho para analisar as técnicas computacionais aplicadas no futebol de robôs.

A avaliação tática é baseada em variáveis latentes nos dez princípios táticos fundamentais da fase ofensiva e defensiva, conforme apresentado na tabela 3.

Tabela 3 – Categorias, sub-categorias, variáveis latentes e definições utilizadas para a avaliação do comportamento tático de jogadores de Futebol

<b>Categoria</b>	<b>Sub-categorias</b>	<b>Variáveis Latentes</b>	<b>Definições</b>
Princípios Táticos Fundamentais do Jogo de Futebol	Ofensivo	Penetração	Redução da distância entre o portador da bola e a baliza ou a linha de fundo adversária.
		Cobertura Ofensiva	Oferecimento de apoios ofensivos ao portador da bola.
		Mobilidade	Criação de instabilidade na organização defensiva adversária.
		Espaço	Utilização e ampliação do espaço de jogo efetivo em largura e profundidade.
	Defensivo	Unidade Ofensiva	Movimentação de avanço ou apoio ofensivo do(s) jogador(es) que compõe(m) a(s) última(s) linha (s) transversais da equipe.
		Contenção	Realização de oposição ao portador da bola.
		Cobertura Defensiva	Oferecimento de apoios defensivos ao jogador de contenção.
		Equilíbrio	Estabilidade ou superioridade numérica nas relações de oposição.
		Concentração	Aumento de proteção defensiva na zona de maior risco à baliza.
		Unidade Defensiva	Redução do espaço de jogo efetivo da equipe adversária.

Fonte: Costa et al., 2011

A avaliação dos jogadores, com o FUT-SAT, é feita por meio da observação de quatro fatores: Realização do Princípio Tático (RP), Qualidade de Realização da Ação Tática (QR), Localização da Realização da Ação Tática no Campo de Jogo (LA) e Resultado da Ação Tática (RA). Com esse instrumento é possível gerar um Índice de Performance Tática (IPT), que leva em consideração os fatores acima citados. A equação (9) é usada para obtenção do IPT para a defesa.

$$IPT = \frac{\sum \text{ações táticas}(RP \times QR \times LA \times RA)}{\text{número de ações táticas}} \quad (9)$$

Os valores para essas variáveis são distribuídas atribuindo-se notas positivas ou negativas conforme apresentado na tabela 4. Gonçalves, Rezende e Teoldo (2017) propuseram valores para essas variáveis conforme observado na tabela 5.

Existem três fases principais para um jogo: atacar para criar chances de gols; jogo defensivo para evitar chances de gols do adversário; e o jogo do meio-campo, que envolve reorganização ao criar jogos ofensivos ou defender-se contra a formação do adversário.

Tabela 4 – Categorias, sub-categorias, variáveis latentes e variáveis observadas relacionados à Localização e ao Resultado da ação tática

<b>Categorias</b>	<b>Sub-categorias</b>	<b>Variáveis Latentes</b>	<b>Variáveis Observadas</b>
Localização da ação no Campo de Jogo	Ofensivo	Meio Campo Ofensivo	Ações Táticas Ofensiva Ações Táticas Defensivas
	Defensivo	Meio Campo Defensivo	Ações Táticas Ofensivas Ações Táticas Defensivas
Resultado da Ação	Ofensiva	Eficácia Ofensiva	Realizar finalização ao gol Continuar com a posse de bola Sofrer falta, ganhar lateral ou escanteio Cometer falta, ceder lateral ou escanteio Perder a posse de bola
	Defensiva	Eficácia Defensiva	Recuperar a posse de bola Sofrer falta, ganhar lateral ou escanteio Cometer falta, ceder lateral ou escanteio Continuar sem a posse de bola Sofrer finalização ao gol

Fonte: Costa et al., 2011

Em outras palavras, a posse de bola é determinante no futebol (CARLING; WILLIAMS; REILLY, 2006).

#### 4.3 TRABALHOS RELACIONADOS

Abreu et al. (2011) apresentam uma heurística, baseada em coordenadas cartesianas, para determinar o desempenho geral de uma equipe em futebol real. A validação dos experimentos foi realizado com partidas da RoboCup 2D e permitiu identificar várias situações em uma partida de futebol, tais como: número de passes certos, tempo de posse da bola, chutes a gol, laterais e outras situações em campo.

Embora não seja possível conhecer exatamente uma estratégia que uma equipe está adotando, essa estratégia está bem representada pela forma como os jogadores da equipe chutam durante os jogos. Partindo dessa premissa Nakashima et al. (2015) propõe que chutes extraídos, como passes e dribles, formam uma distribuição de chutes, o que pode representar a estratégia da equipe. Para mostrar a utilidade da distribuição de chutes, técnicas de cluster são utilizadas para agrupar essa distribuição e reduzir a incerteza na previsão dos resultados do jogo.

Existem outras iniciativas de pesquisa, com diferentes abordagens, que visam extrair estatísticas de equipes a partir dos registros históricos (análise de vídeos de jogo, por exemplo). Embora sirvam como indicadores de eficiência de uma equipe, essas estatísti-

Tabela 5 – Componentes e valores considerados para o cálculo do IPT no FUT–SAT

<b>Componentes</b>	<b>Ação</b>	<b>Valores</b>
Realização do Princípio (RP)	Fez	1
	Não fez	0
Qualidade da realização do princípio (QR)	Bem-sucedido	10
	Mal-sucedido	5
Ação no campo ofensivo de jogo (LA)	Ações táticas ofensivas	2
	Ações táticas defensivas	2
Ação no campo defensivo de jogo (LA)	Ações táticas defensivas	1
	Ações táticas ofensivas	1
Resultado da ação (RA) ofensiva	Realizar finalização à baliza	5
	Continuar com a posse de bola	4
	Sofrer falta, ganhar lateral ou escanteio	3
	Cometer falta, ganhar lateral ou escanteio	2
	Perder posse de bola	1
Resultado da ação (RA) defensiva	Recuperar a posse de bola	5
	Sofrer falta, ganhar lateral ou escanteio	4
	Cometer falta, ganhar lateral ou escanteio	3
	Continuar sem posse de bola	2
	Sofrer finalização à baliza	1

Fonte: Gonçalves, Rezende e Teoldo, 2017

cas apresentam o panorama global do jogo e ainda persistem dificuldades de determinar a real eficiência em situações específicas de jogo. A abordagem proposta por Costa et al. (2011) permite analisar essas situações específicas.

#### 4.4 NOVA MÉTRICA

Podem ocorrer diversas situações distintas em partidas de futebol, seja de robôs ou humana. Jogadas de bola parada são uma dessas situações, onde pode ocorrer o passe para um colega da equipe ou um chute direto a baliza adversária. Nesse trabalho são desenvolvidas equações matemáticas para avaliar o posicionamento defensivo em jogadas de bola parada na SSL. Procurou-se analisar os princípios de contenção, cobertura defensiva, equilíbrio e concentração.

Com base na equação (9) que calcula o IPT de uma equipe de futebol, os posicionamentos encontrados serão avaliados individualmente de acordo com as fórmula descritas

em (10) (defesa) e (11) (passe) que estamos chamando de Índice de Performance do Posicionamento (IPOS).

$$IPOS_d = (QR_d \times LA_d \times RA_d) \quad (10)$$

$$IPOS_p = (QR_p \times LA_p \times RA_p) \quad (11)$$

Nas equações (10) e (11), utiliza-se as mesmas variáveis aplicadas na fórmula original do FUT–SAT: Realização do Princípio Tático (RP), Qualidade de Realização da Ação Tática (QR), Localização da Realização da Ação Tática no Campo de Jogo (LA) e Resultado da Ação Tática (RA). A única diferenciação das equações é a identificação para equação da defesa ou passe.

Embora prevista na fórmula original do FUT–SAT, a RP não será considerada nas métricas, pois cada jogada de gol será avaliada individualmente. As análises das partidas originais sempre resultariam no valor zero, pois houve gol e logo a realização do princípio não ocorreu. Os próprios autores defendem que a métrica proposta pode ser flexibilizada no uso das variáveis que compõem a avaliação.

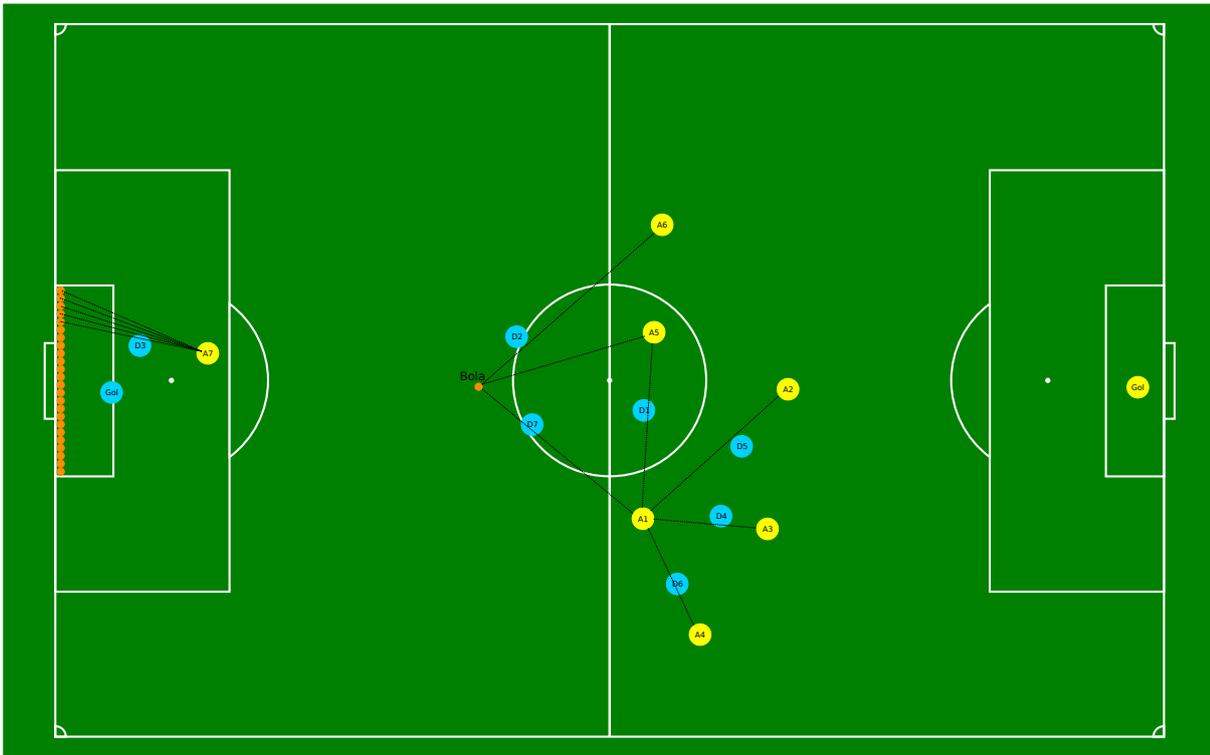
Cabe ressaltar que o IPT visa estabelecer uma nota final para a equipe e o IPOS tem como objetivo calcular um índice para momentos específicos dos jogos que serão analisados no capítulo 7, portanto a variável RP foi descartada no desenvolvimento das métricas.

#### 4.4.1 Equações auxiliares

A figura 15 ilustra os três conceitos de bloqueio utilizados nas equações das métricas e equações para defesa e passe: bloqueio de visão do gol, visão dos adversários e visão da bola.

Para o cálculo da visão do gol, a abertura do gol é dividida em 24 segmentos de tamanho equivalente ao diâmetro da bola ( $\approx 5 \text{ cm}$ ) utilizada na SSL. São traçados segmentos de retas entre o robô atacante (representado por A7) e cada segmento dentro do gol. A verificação do bloqueio da visão consiste em saber se existe um robô defensor (representado por D3) no mesmo segmento.

Figura 15 – Ilustração do cálculo da linha de visão.



Fonte: Autor

Um segmento de reta é considerado bloqueado se distância entre ele e o robô defensor for inferior a  $\approx 5 \text{ cm}$  e a distância entre robô defensor e o gol for menor que a distância entre o robô atacante e o gol (essa propriedade é válida para ambos os lados).

Para o cálculo de visão dos adversários, são traçados segmentos de reta entre todos os robôs adversários. Se existir um robô defensor onde a distância do segmento de reta seja inferior a 10 cm (representando a metade do tamanho de um robô na liga SSL) e se a distância do robô atacante com o robô defensor for menor que a distância entre os robôs atacantes, a visão é considerada bloqueada. Na figura 15, o robô A1 tem visão livre apenas do robô A2.

Finalmente o bloqueio da visão da bola pelos adversários é calculada de forma semelhante ao cálculo de visão dos adversários.

A equação (12) verifica se na reta formada por um robô atacante  $a$  em relação ao gol  $gol$  existe um robô  $d$  e se o robô  $d$  está entre o gol (orientação é dada por  $side$ ) e robô  $a$ . A verificação é realizada da posição inicial do gol (eixo  $y$ ) até a posição final a cada 5cm ( $\approx$  o tamanho da bola utilizada na liga). Os operadores  $f_{estaNaReta}$  e  $f_{DireitaEsquerda}$  estão definidos nas equações (51) e (52) no apêndice A.

$$f_{\text{VisaoGol}}(a,d,gol,side) = \frac{blocks}{linesGol}$$

**onde:**

$$sizegol \leftarrow gol_{final} - gol_{start};$$

$$sizesegment \leftarrow 5; \quad (12)$$

$$linesGol \leftarrow \frac{sizegol}{sizesegment};$$

$$blocks \leftarrow \sum 1 \forall f_{estaNaReta}(a,d,gol) = 0 \wedge$$

$$f_{DireitaEsquerda}(a,d,gol) = side.$$

A equação (13) verifica se existe um defensor  $d$  bloqueando a visão do adversário  $a$  de um objetivo  $alvo$ . O objetivo  $alvo$  pode ser a posição da bola ou a posição de outro robô. Os operadores  $f_{\text{DistEuclidiana}}$ ,  $f_{\text{pontoMedio}}$  e  $f_{\text{DistanciaReta}}$  estão definidos nas equações (53), (54) e (55) no apêndice A.

$$f_{\text{VisaoAlvo}}(a,alvo,d) = \{ distancia_{reta} \leq 10 \wedge \\ ( distancia_{Dmedio} \leq distancia_{alvoMedio} \vee \\ distancia_{Dmedio} \leq distancia_{AMedio} ) \};$$

**onde:**

$$distancia_{reta} \leftarrow f_{\text{DistanciaReta}}(a,alvo,d); \quad (13)$$

$$pontoM \leftarrow f_{\text{pontoMedio}}(a,alvo);$$

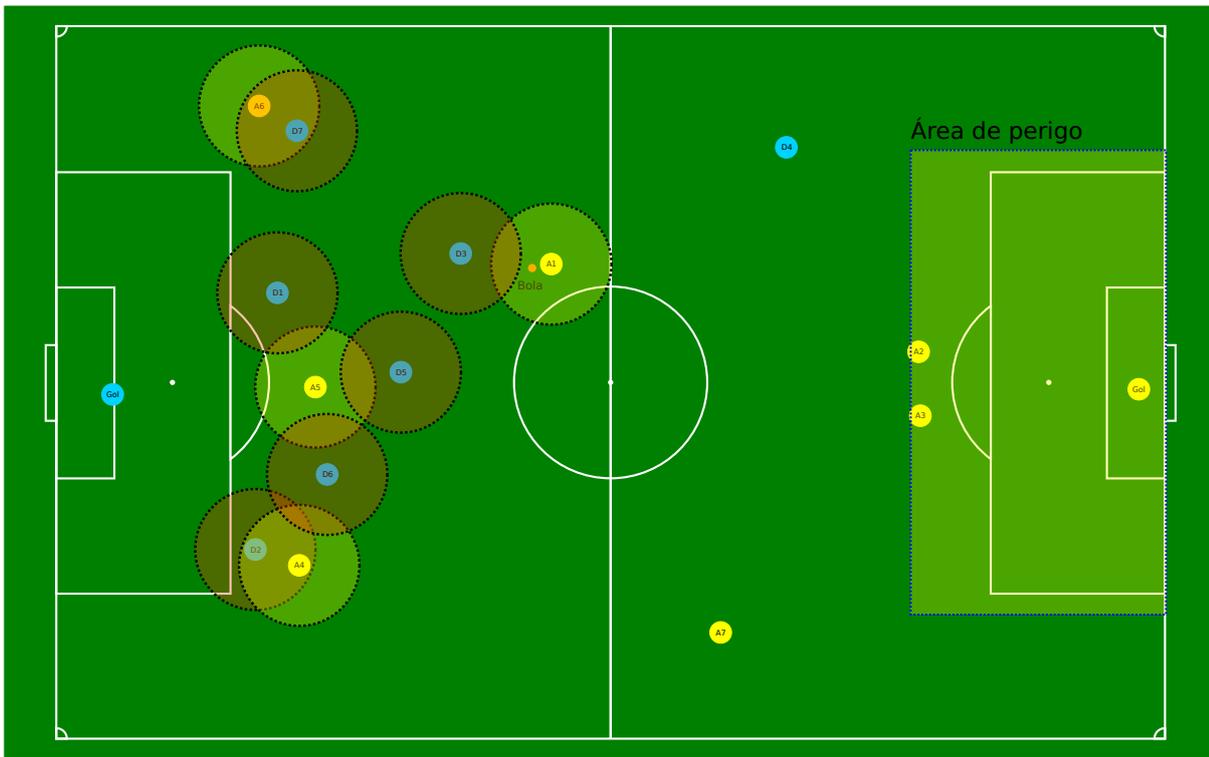
$$distancia_{DMedio} \leftarrow f_{\text{DistEuclidiana}}(d,pontoM);$$

$$distancia_{alvoMedio} \leftarrow f_{\text{DistEuclidiana}}(alvo,pontoM);$$

$$distancia_{AMedio} \leftarrow f_{\text{DistEuclidiana}}(a,pontoM).$$

A figura 16 ilustra o conceito de área de atuação dos robôs e área de perigo do gol. A área de atuação de um robô é calculada considerando um raio  $raio$  para traçar um círculo imaginário a partir do centro. O espaço disponível para um robô se locomover sem invadir a área de outro robô é considerado como área livre de atuação. Considerando o robô A5, sua área livre de atuação é calculada por  $f_{\text{areaCirculo}}(A5,raio) - (f_{\text{areaInterCirculo}}(A5,D1) + f_{\text{areaInterCirculo}}(A5,D5) + f_{\text{areaInterCirculo}}(A5,D6))$ . A equação (14) calcula área de atuação de um robô atacante  $a$  com raio de ataque  $r_{ataque}$  a partir da somatória de robôs defensores  $D$  com raio de defesa  $r_{defesa}$ . Um valor negativo indica que o robô não tem área de atuação livre. Os operadores  $f_{\text{areaCirculo}}$  e  $f_{\text{areaInterCirculo}}$  estão definidos nas equações (56) e (57) no apêndice A.

Figura 16 – Ilustração do cálculo área de atuação e área de perigo.



Fonte: Autor

$$f_{\text{areaLivre}}(a, r_{\text{ataque}}, D, r_{\text{defesa}}) = \left( \sum_{d \in D} f_{\text{areaInterCirculo}(p_a, p_d)} \right) - f_{\text{areaCirculo}}(r_{\text{ataque}});$$

onde: (14)

$$p_a(x, y, \text{raio}) \leftarrow (a_x, a_y, r_{\text{ataque}});$$

$$p_d(x, y, \text{raio}) \leftarrow (d_x, d_y, r_{\text{defesa}}).$$

A área de perigo abrange área do campo defensivo como um metro de distância da área do goleiro ( $1,2m \times 2,4m$  na liga A da SSL), ou seja, o retângulo formado pela medidas  $2,2m \times 3,4m$  (semelhante a grande área do futebol humano). A equação (15) verifica se

um robô  $r$  está na área de perigo da defesa (identificado por  $side$ ).

$$f_{\text{areaPerigo}}(r, side) = \begin{cases} r_x < x_{\text{perigo}} \wedge y_{ok}, & \text{if } side = \text{ESQUERDA} \\ r_x > (1200 - x_{\text{perigo}}) \wedge y_{ok}, & \text{if } side = \text{DIREITA} \end{cases}$$

onde:

$$x_{\text{perigo}} \leftarrow 220; \quad (15)$$

$$y_{\text{perigo}} \leftarrow 340;$$

$$y_{\text{meioGol}} \leftarrow 450;$$

$$y_{ok} \leftarrow r_y < \left(y_{\text{meioGol}} + \frac{y_{\text{perigo}}}{2}\right) \wedge r_y > \left(y_{\text{meioGol}} - \frac{y_{\text{perigo}}}{2}\right).$$

#### 4.4.2 Avaliação de proteção da baliza

Considera-se o jogador atacante com a posse de bola, utilizado nas jogadas de DIRECT\_KICK ou INDIRECT\_KICK (cobranças que podem resultar em passe ou chute para o gol).

A Qualidade de Realização da Ação Tática (QR) é calculada pela equação (16):

$$QR_d = \frac{QR_{d1} + QR_{d2} + QR_{d3} + QR_{d4}}{4} \quad (16)$$

$QR_{d1}$ ,  $QR_{d2}$ ,  $QR_{d3}$  e  $QR_{d4}$  são, por sua vez, definidos nas equações (17), (18), (19) e (20).

Nas equações (17) e (18) o gol foi dividido em espaços correspondentes a dimensão da bola para determinar as linhas de visão ( $\approx 5cm$  o tamanho da bola utilizada na SSL) e o goleiro da equipe não é considerado no bloqueio do gol. Na equação (17) o robô adversário com posse de bola é desconsiderado. A equação (18) verifica a visão do jogador adversário com a posse de bola, e o desejável é que essa visão seja a menor possível para evitar chutes diretos ao gol.

$$QR_{d1}(A,D,gol,side) = \begin{cases} 10 & \text{if } VGol \leq 20\% \\ 5 & \text{if } VGol \leq 40\% \\ 2 & \text{if } VGol > 40\% \end{cases} \quad \text{onde:} \quad (17)$$

$$VTotal \leftarrow \sum_{a \in A} f_{VisaoGol}(a,d,gol,side) \quad \forall (d \in D);$$

$$VGol \leftarrow \frac{VTotal}{size(A) - 1}.$$

Na equação (17),  $A$  representa o conjunto de robôs adversários e  $a$  um robô do conjunto  $A$ ;  $D$  o conjunto de defensores e  $d$  um robô do conjunto  $D$ ;  $gol$  a posição a ser defendida e  $side$  o lado da defesa.

$$QR_{d2}(a,D,gol,side) = \begin{cases} 10 & \text{if } VBola \leq 25\% \\ 5 & \text{if } VBola \leq 25\% \end{cases} \quad \text{onde:} \quad (18)$$

$$VBola \leftarrow \sum_{d \in D} f_{VisaoGol}(a,d,gol,side).$$

Na equação (18),  $a$  representa o robô adversário portador da bola,  $D$  o conjunto de defensores,  $gol$  a posição a ser defendida e  $side$  o lado da defesa.

A equação (19) verifica qual a possibilidade da bola chegar ao gol, caso fosse chutado em linha reta da sua posição atual em direção ao gol. Na equação,  $bola$  representa a coordenada em campo,  $D$  o conjunto de defensores,  $gol$  o objetivo e  $side$  o lado.

$$QR_{d3}(bola,D,gol,side) = \begin{cases} 10 & \text{if } VBola \leq 25\% \\ 5 & \text{if } VBola \leq 50\% \\ 2 & \text{if } VBola > 50\% \end{cases} \quad \text{onde:} \quad (19)$$

$$VBola \leftarrow \sum_{d \in D} f_{VisaoGol}(bola,d,gol,side).$$

A equação (20) verifica a superioridade numérica da defesa em campo. A variável  $TotalPosicionados$  representa a quantidade de robôs necessários atuando no campo de defesa. Várias equipes mantém dois ou três robôs fixos atuando como barreira de defesa em frente ao gol, em uma formação conhecida como *delta defensivo*. O valor 13 é escolhido para resultar no valor 10 (melhor resultado). Na equação, a variável  $A$  representa o

conjunto de robôs adversários,  $D$  o conjunto de defensores e  $side$  o lado da defesa. O valor 600 indica a metade do campo.

$$QR_{dA}(A,D,side) = \begin{cases} \min(13 - TotalDefesa, 10) & \text{if } TotalAdv < TotalDefesa \\ 5 & \text{if } TotalAdv = TotalDefesa \\ 2 & \text{if } TotalAdv > TotalDefesa \end{cases}$$

onde:

$$TotalAdv \leftarrow \begin{cases} \sum_{a \in A} 1 \forall a_x \leq 600 & \text{if } side = ESQUERDA \\ \sum_{a \in A} 1 \forall a_x \geq 600 & \text{if } side = DIREITA \end{cases} \quad (20)$$

$$TotalDefesa \leftarrow \begin{cases} \sum_{d \in D} 1 \forall d_x \leq 600 & \text{if } side = ESQUERDA \\ \sum_{d \in D} 1 \forall d_x \geq 600 & \text{if } side = DIREITA \end{cases}$$

A respeito da equação (20), embora considere a superioridade numérica como vantagem defensiva, equipes com estratégias totalmente defensivas ou que mantêm muitos robôs fixos em frente ao gol possuem menos alternativas para realização de estratégias ofensivas.

A equação (21) é responsável pelo cálculo da Localização da Realização da Ação Tática no Campo de Jogo (LA):

$$LA_d = \begin{cases} 10 & \text{if Posicionamento atuou no campo ofensivo} \\ 8 & \text{if Posicionamento atuou no campo defensivo} \\ 5 & \text{if Posicionamento atuou na área de perigo} \\ 1 & \text{if Posicionamento não atuou} \end{cases} \quad (21)$$

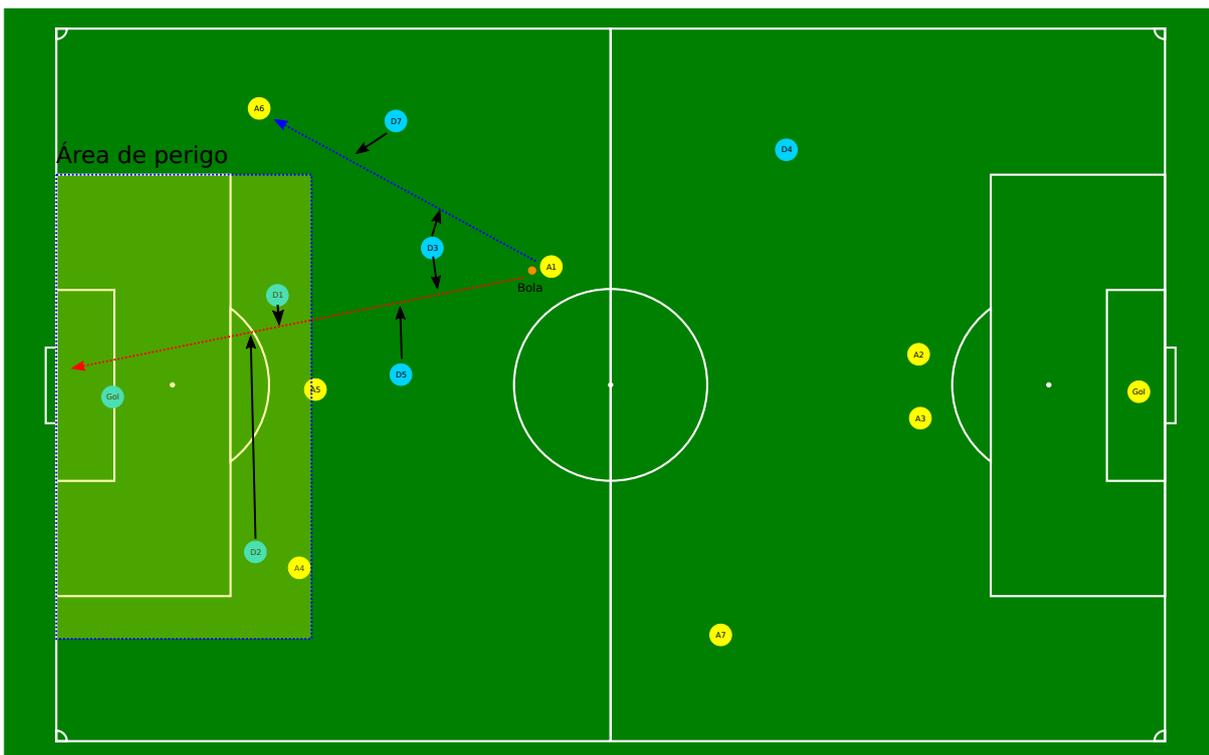
Na equação (21), *área de perigo* abrange área do campo defensivo como um metro de distância da área do goleiro ( $1,2m \times 2,4m$  na liga A da SSL), ou seja, o retângulo formado pela medidas  $2,2m \times 3,4m$  (semelhante a grande área do futebol humano).

O Resultado da Ação Tática (RA) é calculado de acordo com a equação (22). Essa equação prevê *Recuperação da bola*, mas essa avaliação não é possível de realizar nos posicionamentos otimizados.

$$RA_d = \begin{cases} 10 & \text{if Bloqueou chute direto a gol e permitiu recuperação da bola} \\ 5 & \text{if Bloqueou chute direto a gol mas não permitiu recuperação da bola} \\ 10 & \text{if Bloqueou passe e permitiu recuperação da bola} \\ 5 & \text{if Bloqueou passe mas não permitiu recuperação da bola} \\ 1 & \text{if Não bloqueou chute a gol ou passe} \end{cases} \quad (22)$$

Na figura 17 são ilustradas duas situações: chute a gol e passe. Para o cálculo do RA, é verificado se algum robô defensor interceptou a bola durante o seu percurso ao objetivo. A posição em campo determina o valor para a variável LA.

Figura 17 – Ilustração dos procedimentos para cálculo do RA e LA.



Fonte: Autor

#### 4.4.3 Avaliação de bloqueio de passes

A Qualidade de Realização da Ação Tática (QR) é calculada pela equação (23), que é a soma do resultados das equações (24), (25), (26), (27), (28) e (29):

$$QR_p = \frac{QR_{p1} + QR_{p2} + QR_{p3} + QR_{p4} + QR_{p5} + QR_{p6}}{6} \quad (23)$$

A equação (24) verifica a possibilidade de interceptação da bola e (25) a possibilidade de bloquear o avanço de um jogador.

$$QR_{p1}(r, bola) = \frac{\max(distância - f_{DistEuclidiana}(r, bola), 0)}{10} \quad (24)$$

A variável *distância*, na equação (24) indica a quantidade de centímetros necessários para que um robô *r* consiga interceptar a bola *bola* no instante da verificação da jogada. Quanto maior a distância necessária para interceptação menor seria a chance do bloqueio na sequência da jogada e portanto o valor da variável  $QR_{p1}$ . O valor máximo da *distância* considerado nessa equação será um metro (100 cm). Esse valor foi escolhido devido a velocidade média do robô na SSL ser de  $\approx 2 m/s$  e considerando o movimento da bola em  $4 m/s$  e possibilidade de interseção do robô com a bola em um ângulo de  $90^\circ$ . O operador  $f_{DistEuclidiana}$  está definida na equação (53) no apêndice A.

$$QR_{p2}(d, a) = \frac{\max(distância - f_{DistEuclidiana}(d, r), 0)}{10} \quad (25)$$

Será considerado bloqueio de avanço, quando o posicionamento encontrado não permitir que o robô adversário (*a*) consiga conduzir a bola por mais de 50cm sem colisão com robô da equipe (*d*), na SSL o robô pode conduzir a bola por no máximo 1 metro, devido a regra que limita a distância de condução da bola. Foi considerado o valor de 50cm para *distância*, velocidade do robô defensor com  $1m/s$  e robô atacante com  $2m/s$  e possibilidade de interseção do robô defensor com o robô atacante em um ângulo de  $90^\circ$ . Se não existir robô atacante com posse de bola, considera-se o valor zero para a equação. O valor de  $1m/s$  para o robô defensor considera o tempo de processamento e resposta dos comandos pelo robô.

A equação (26) verifica a visão do gol pelo adversário e (27) o total de visão dos companheiros da equipe.

$$QR_{p3}(a, D, gol, side) = \begin{cases} 10 & \text{if } VBola \leq 25\% \\ 5 & \text{if } VBola > 25\% \end{cases} \quad (26)$$

onde:

$$VBola \leftarrow \sum_{d \in D} f_{VisaoGol}(a, d, gol, side).$$

Na equação (26),  $a$  representa um robô adversário,  $D$  o conjunto de robôs defensores,  $gol$  posição a ser defendida e  $side$  o lado da defesa.

$$QR_{p4}(A,D,a_{bola}) = \begin{cases} 10 & \text{if } VAdv \leq 20\% \\ 5 & \text{if } VAdv \leq 40\% \\ 2 & \text{if } VAdv > 40\% \end{cases} \quad \text{onde:} \quad (27)$$

$$VTotal \leftarrow \sum_{a \in A} f_{VisaoAlvo}(a_{bola}, a, d) \quad \forall (d \in D);$$

$$VAdv \leftarrow \frac{VTotal}{size(A) - 1}.$$

Na equação (27),  $A$  representa o conjunto de robôs adversários,  $D$  o conjunto de robôs defensores,  $a_{bola}$  o robô adversário com a posse de bola.

As equações (28) e (29), embora idênticas, são aplicadas conforme posicionamento do jogador com posse de bola em campo. No futebol humano, o ideal é haver um equilíbrio entre a disposição dos jogadores para recepção do passe. Caso o passe ocorra no campo de defesa, o ideal é existir opção de passe em ambos os lados do campo (defesa e ataque). Assim, a equação (28) é aplicada para os jogadores no campo de defesa e a equação (29) para os jogadores no campo de ataque.

$$QR_{p5}(A,D,side) = \begin{cases} \min(13 - TotalPosicionados, 10) & \text{if } TotalAdv < TotalPosicionados \\ 5 & \text{if } TotalAdv = TotalPosicionados \\ 2 & \text{if } TotalAdv > TotalPosicionados \end{cases}$$

onde:

$$TotalAdv \leftarrow \begin{cases} \sum_{a \in A} 1 \quad \forall a_x \leq 600 & \text{if } side = ESQUERDA \\ \sum_{a \in A} 1 \quad \forall a_x \geq 600 & \text{if } side = DIREITA \end{cases};$$

$$TotalPosicionados \leftarrow \begin{cases} \sum_{d \in D} 1 \quad \forall d_x \leq 600 & \text{if } side = ESQUERDA \\ \sum_{d \in D} 1 \quad \forall d_x \geq 600 & \text{if } side = DIREITA \end{cases} \quad (28)$$

$$QR_{p6}(A,D,side) = \begin{cases} \min(13 - TotalPosicionados, 10) & \text{if } TotalAdv < TotalPosicionados \\ 5 & \text{if } TotalAdv = TotalPosicionados \\ 2 & \text{if } TotalAdv > TotalPosicionados \end{cases}$$

onde:

$$TotalAdv \leftarrow \begin{cases} \sum_{a \in A} 1 \forall a_x \leq 600 & \text{if } side = ESQUERDA \\ \sum_{a \in A} 1 \forall a_x \geq 600 & \text{if } side = DIREITA \end{cases};$$

$$TotalPosicionados \leftarrow \begin{cases} \sum_{d \in D} 1 \forall d_x \leq 600 & \text{if } side = ESQUERDA \\ \sum_{d \in D} 1 \forall d_x \geq 600 & \text{if } side = DIREITA \end{cases} \quad (29)$$

Nas equações (28) e (29) a variável *TotalPosicionados* refere-se a quantidade de jogadores que estão posicionados ofensivamente (em caso de ataque) ou defensivamente (em caso de defesa), *side* indica o lado da defesa, *A* o conjunto de robôs adversários e *D* o conjunto de robôs defensores. Desconsidera-se o robô com posse de bola que irá realizar o passe.

A equação (30) é responsável pelo cálculo da Localização da Realização da Ação Tática no Campo de Jogo (LA):

$$LA_p = \begin{cases} 10 & \text{if Posicionamento atuou no campo ofensivo} \\ 8 & \text{if Posicionamento atuou no campo defensivo} \\ 5 & \text{if Posicionamento atuou na área de perigo} \\ 1 & \text{if Posicionamento não atuou} \end{cases} \quad (30)$$

Na equação (30) *área de perigo* abrange área do campo defensivo como um metro de distância da área do goleiro ( $1.2m \times 2.4m$  na liga A da SSL), ou seja, o retângulo formado pela medidas  $2.2m \times 3.4m$  (semelhante a grande área do futebol humano).

O Resultado da Ação Tática (RA) é dada pela equação (31), composta pelas equações (32) e (33).

$$RA_p = \frac{RA_{p1} + RA_{p2}}{2} \quad (31)$$

A equação (32) desconsidera o robô portador da bola. O termo Bloqueou está relacionado com a questão de se o posicionamento em campo teria interceptado a bola,

ou seja, durante a trajetória da bola a cada momento é verificado se algum robô a tocara impedindo a continuidade da jogada.

$$RA_{p1} = \begin{cases} 10 & \text{if Bloqueou chute direto a gol e permitiu recuperação da bola} \\ 5 & \text{if Bloqueou chute direto a gol mas não permitiu recuperação da bola} \\ 10 & \text{if Bloqueou passe e permitiu recuperação da bola} \\ 5 & \text{if Bloqueou passe mas não permitiu recuperação da bola} \\ 1 & \text{if Não bloqueou chute a gol ou passe} \end{cases} \quad (32)$$

$$RA_{p2}(A,D) = \frac{100 - \left( \frac{AreaLivre}{size(A)} \right)}{10}; \quad \text{onde:} \quad (33)$$

$$AreaLivre \leftarrow \sum_{a \in A} f_{areaLivre}(a, 300, D, 100).$$

Na equação (33) *AreaLivre* é a quantidade de espaço que os robôs adversários poderiam se mover sem colidir com outros robôs da equipe. Com menos espaço para movimentação os adversários terão dificuldades para avançarem em direção ao gol.

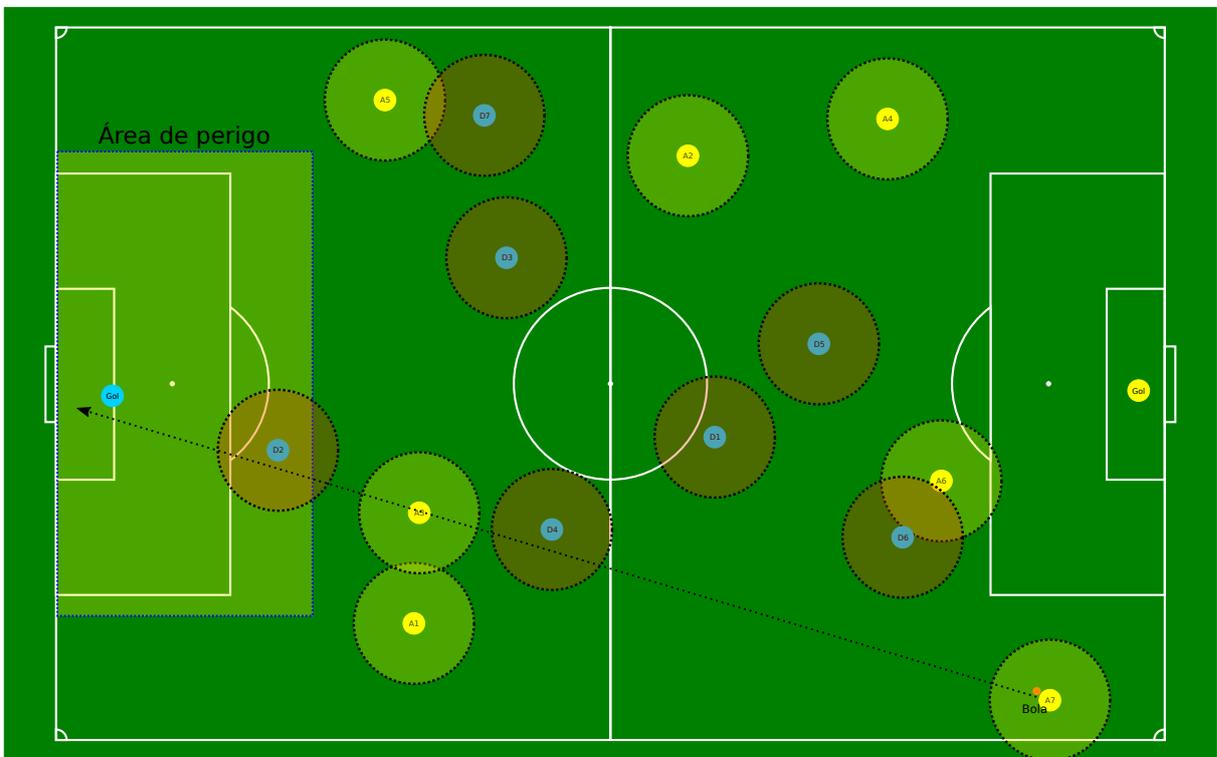
#### 4.5 CONSIDERAÇÕES DO CAPÍTULO

Utilizando o sistema de avaliação do FUT-SAT foram desenvolvidas duas métricas para avaliação. Porém, determinadas condições não são triviais para verificação, como as que ocorrem para as dimensões LA e RA.

A figura 18 ilustra um exemplo de jogada. O robô A7 chutou a bola a gol ou tentou realizar um passe para o robô A3 que está posicionado na mesma linha. Os robôs D4 e D2 poderiam interceptar a bola durante a sua trajetória. Porém, qual posição em campo deve ser usada para considerar no cálculo da dimensão LA? Na situação de chute ou passe não existe distinção na equação de cálculo do RA. Para a LA adotou-se a média das possíveis situações. No caso, para D4 o valor de LA seria 8, pois atuaria no campo defensivo. Para o robô D2 o valor de LA seria 5, pois atuaria na área de perigo. Nessa situação, o valor de LA da jogada considerado é 6,5 ( $\frac{8+5}{2}$ ).

A aplicação das métricas e avaliações em diversas situações de jogo serão apresentadas no capítulo 7.

Figura 18 – Exemplo de jogada: chute a gol ou passe?



Fonte: Autor



## 5 NOVAS FUNÇÕES DE APTIDÃO PARA APLICAÇÃO EM POSICIONAMENTOS DEFENSIVOS

A habilidade de uma equipe futebol de tomar decisões sobre onde se mover no campo sem a bola é fator crítico de sucesso, seja no futebol humano ou de robôs. Normalmente apenas um jogador de cada lado está controlando a bola ou tentando obter a posse da bola. O restante está realizando outras atividades; de fato, cada um deve se mover deliberadamente para algum lugar no campo. Para um jogador comum, isso acontece mais de 90% do tempo (HUGHES, 1998). Assim, ao contrário de outros comportamentos que lidam com eventos como passar a bola, deve-se esperar um impacto de melhoria na estratégia da equipe com base nos posicionamentos dos jogadores.

No posicionamento defensivo, a equipe precisa movimentar-se e procurar o melhor espaço em campo. A movimentação deve permitir o recuo defensivo impedindo o progresso do adversário. Cada posição tem suas características, como marcar os adversários ou antecipar-se para interceptação da bola.

As equações que descrevem como é realizado o cálculo da visão do gol, cálculo de distância, verificação de condição de formação de retas, verificação de raio de ação, cálculo de áreas e outras operações matemáticas necessárias para verificação de condições de existência de retas, interseção de objetos ou cruzamento de pontos no plano dado por  $X, Y$  referente ao posicionamento em campo estão descritas no apêndice A.

Nas equações para bloqueio de passe e defesa, o tamanho do campo é considerado em centímetros e o centro da bola e dos robôs (coordenadas  $X, Y$ ) são utilizados nas equações. As equações consideram os tamanhos dos objetos e nas suas definições estão indicados quando ocorrem. O objetivo pode ser qualquer ponto de interesse no espaço de pesquisa. Por exemplo: o canto esquerdo ou direito do goleiro ou um conjunto de pontos do ataque de campo do oponente.

O goleiro não é considerado nas equações, visto que tem regras, atuação e posicionamento próprio, recebendo tratamento específico pelo sistema de estratégia.

### 5.1 IMPORTÂNCIA E ESCOPO

O jogo de futebol pode ser entendido a partir de quatro momentos: ofensivo, defensivo, de transição ofensiva e de transição defensiva, os quais se relacionam entre si de

forma complexa (COSTA et al., 2011). Em decorrência da observação do comportamento distinto das equipes nas jogadas originárias de bolas paradas surgiram várias discussões sobre a necessidade de se adicionar um novo momento para o entendimento do jogo de futebol surgindo assim o quinto momento do jogo. No futebol moderno, jogadas de bola parada aumentam as chances ofensivas das equipes (HUGHES, 1998; BONFANTI, 2002; CASTELO, 2009).

Nesse momento os jogadores conhecem o posicionamento da sua equipe e do adversário. A equipe com jogada a seu favor tenta desorganizar o adversário para obter o êxito na jogada enquanto a adversária exerce uma ação contrária.

Castelo (2009) e Cecconi (2015) em seus estudos estimam que entre 25% e 50% das situações de finalização ou criação tem origem em jogadas de bola parada. Bonfanti (2002) estima em 50% o número de gols marcados no futebol moderno em jogadas de bola parada. Hughes (1998) aponta cinco vantagens das jogadas de bola parada:

- a) A bola parada elimina a necessidade de controle da bola;
- b) O treinamento desses lances cria sincronia nos movimentos da equipe;
- c) Adversários precisam estar a uma distância mínima, diminuindo a pressão sobre a bola;
- d) Jogadores com potencial para jogo aéreo deslocam-se para áreas ofensivas de perigo;
- e) Os atacantes posicionam-se em zonas pré-planejadas, em alguns casos baseado no estudo das deficiências dos adversários.

Os momentos a) e b) permitem a equipe adversária encontrar as melhores posições em campo para aplicar sua estratégia.

Baseado nessas informações, as equações foram desenvolvidas com foco em situações de jogadas de bola parada na SSL. Embora sua efetividade seja maior no início de uma jogada de bola parada, as equações podem também ser utilizadas em outros momentos.

## 5.2 DEFINIÇÕES E PUNIÇÕES

A tabela 6 apresenta as punições utilizadas nas equações. Estes valores representam centímetros e são utilizados para diferenciar situações que podem ocorrer um jogo.

Por exemplo, infrações que podem resultar em interferências nas regras da SSL foram definidas como PHIGH (penalização alta).

Tabela 6 – Tabela de penalizações.

Tipo de Penalização	Valor	Significado
PLOW	100	Baixa penalização
PMID_LOW	500	Penalização média de baixo impacto
PMID	1000	Penalização média
PMID_HIGH	2000	Penalização média com alto impacto
PHIGH	5000	Penalização alta, interfere nas regras da SSL

Fonte: Autor

Na tabela 7 são definidas algumas constantes que são utilizadas na equações de otimização.

Tabela 7 – Tabela de definições.

Variável	Valor	Significado
<i>DBALL</i>	5 cm	Diâmetro da bola
<i>DROBOT</i>	20 cm	Diâmetro do robô

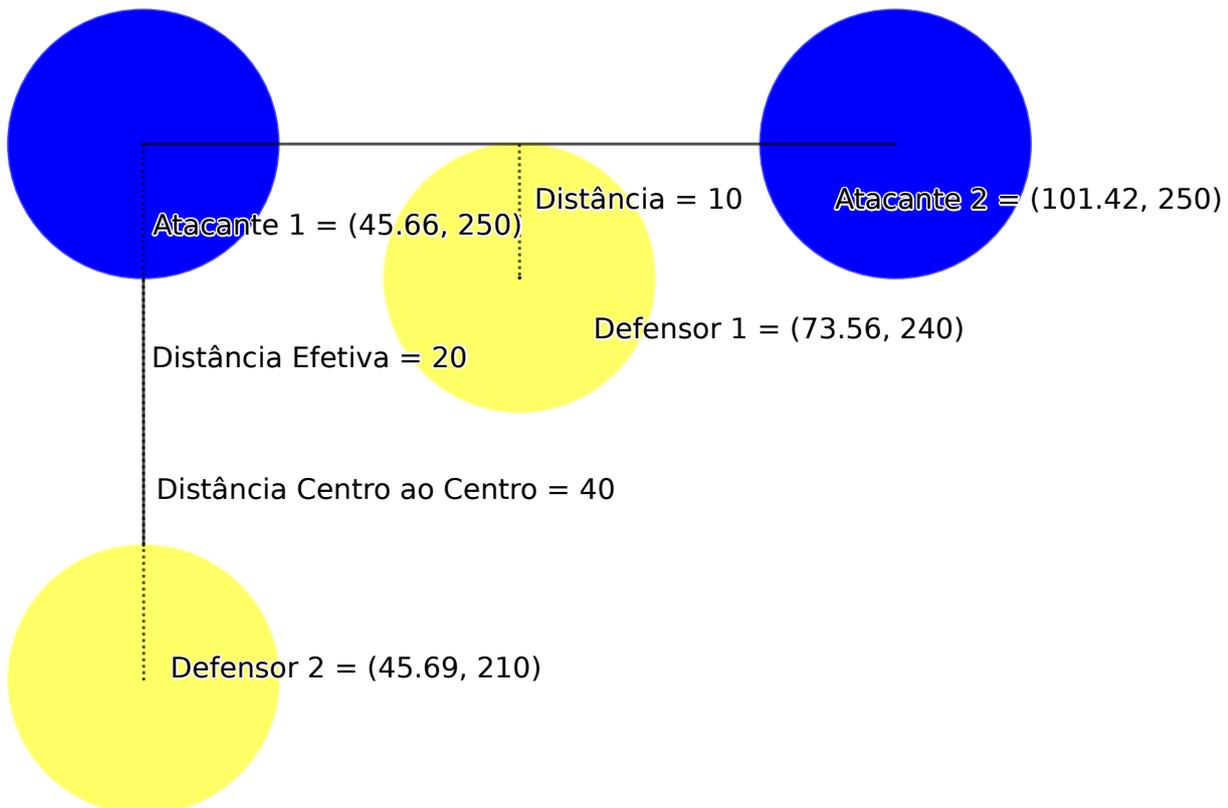
Fonte: Autor

A figura 19 ilustra algumas dimensões que são utilizadas nas equações. Os cálculos são realizados considerando os pontos  $(X,Y)$  dos objetos em campo. Foi definido como distância mínima entre os robôs o tamanho de  $40cm$  ( $\approx$  dois robôs da SSL), porém com espaço efetivo de  $20cm$ . Nas linhas de visão, foi considerando duas vezes o tamanho da bola, aproximadamente metade das dimensões de um robô SSL. Com essa distância equivalente a  $10cm$  ( $DBALL \times 2$ ), as visões entre os adversários já estariam parcialmente bloqueadas.

### 5.3 REPRESENTAÇÃO DE UMA SOLUÇÃO

A figura 20 apresenta um exemplo de população. Cada campo de futebol com os robôs posicionados é uma partícula da população. Cada partícula representa uma solução candidata para a otimização e é composta por 7 robôs (representados em vermelho). O goleiro da equipe não é considerado e em todas as possíveis soluções sua posição é fixa (representado em amarelo). O time adversário está representado em azul

Figura 19 – Ilustração das dimensões.



Fonte: Autor

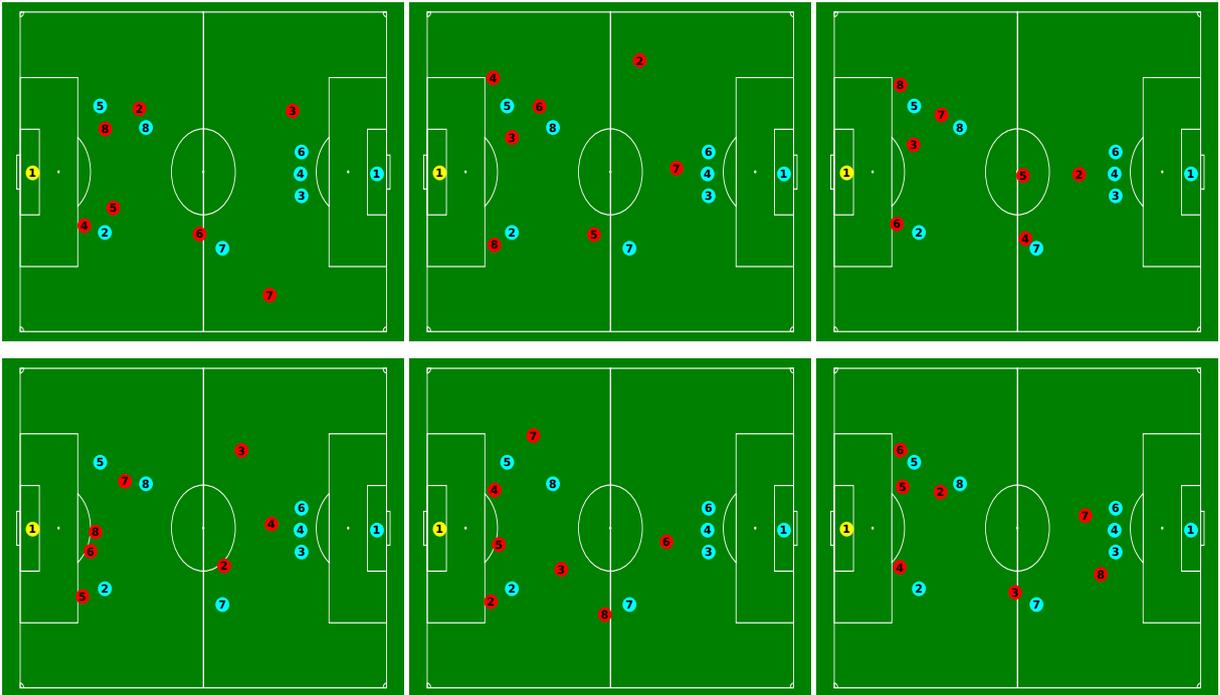
#### 5.4 OTIMIZAÇÃO DE DEFESA

A defesa é o momento no qual uma equipe busca tomar a posse de bola da equipe adversária, utilizando-se de um conjunto de ações de marcação e desarme para evitar sofrer gols. As ações defensivas bem-sucedidas podem desencadear contra-ataques (UNISINOS, 2016).

Nesta tese, a otimização de defesa visa impedir o acesso ao gol. Para atender aos requisitos de defesa semelhantes aos do futebol humano, uma função de avaliação de aptidão é proposta. A otimização considera quatro situações desejáveis para uma formação de defesa:

- Uma distância mínima entre os robôs para que o oponente realize movimentos mais difíceis e diminuam as chances do adversário receber a bola, fazer passes ou chutar para o gol;
- A visão dos robôs do oponente em relação a um certo ponto de interesse é bloqueada;

Figura 20 – Representação de uma população com 6 partículas.



Fonte: Autor

- c) A visão do objetivo de todos os robôs adversários é bloqueada por pelo menos um robô da equipe, especialmente o robô adversário com posse de bola;
- d) Respeito pelas regras SSL em colisões entre robôs e invasão da área de gol.

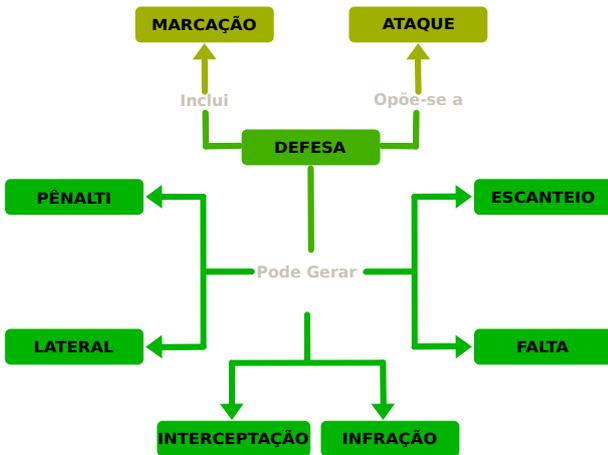
A visão de um robô significa um campo livre de obstáculos entre o robô e um certo ponto de interesse.

Essas quatro situações implementam os princípios fundamentais defensivos:

- a) Contenção: pois ao menos um robô estará próximo suficiente para oferecer combate ao portador da bola;
- b) Cobertura defensiva: os demais robôs são posicionados para impedir/bloquear o acesso dos robôs adversários;
- c) Equilíbrio: pautando-se na premissa de superioridade numérica;
- d) Concentração: na proteção do objetivo a fim de impedir a conclusão da jogada contra a baliza;
- e) Unidade defensiva: na redução do espaço de jogo efetivo da equipe adversária.

A figura 21 ilustra a importância da defesa e suas possíveis consequências.

Figura 21 – Transição defesa.



Fonte: Autor "adaptado de" Unisinos, 2016

A equação (34) implementa as situações desejáveis para a formação defensiva. A equação é composta por outras cinco equações detalhadas nas próximas seções.

$$\text{Defesa}(A, p(i,t), gol, bola) = \{$$

$$f_{\text{MinDist}}(RA, p(i,t)) + f_{\text{LinhasDeVisão}}(RA, p(i,t), gol, a_{bola}) +$$

$$f_{\text{ProtGol}}(a_{bola}, p(i,t), gol) + f_{\text{Colisão}}(RA, p(i,t)) +$$

$$f_{\text{Invasão}}(p(i,t))$$

$$\}$$

onde:

$$a_{bola} \leftarrow \text{pos}(bola) = \text{pos}(a)$$

$$RA \leftarrow f_{\text{OrganizaOponentes}}(A, gol, \text{size}(p(i,t), a_{bola}))$$

(34)

Onde  $A$  representa o conjunto de robôs adversários,  $p(i,t)$  é uma partícula da população, que representa o conjunto de robôs para formação da defesa (solução candidata).  $i$  e  $t$  representam o número da partícula e iteração. A variável  $gol$  representa o ponto de interesse que deve ser defendido e  $bola$  a posição da bola em campo. O conjunto  $A$ , utilizado em todas as equações, é organizado de acordo com a regra descrita na equação (35) que retorna o conjunto de adversários considerados para a otimização.

O operador  $\text{pos}$  é utilizado para verificar a aproximação. No caso  $\text{pos}(bola) = \text{pos}(a)$  visa identificar qual robô está próximo suficiente para ser considerado com posse da bola para definição da variável  $a_{bola}$ .

$$f_{OrganizaOponentes}(A, gol, k, a_{bola}) = \begin{cases} RA_{1\dots l} \in RA, & \text{if } l = k \\ a_{bola} + RA_{1\dots(l-k+1)} \subset RA, & \text{if } l > k \\ RA_{1\dots l} \in RA, & \text{if } l < k \end{cases}; \quad (35)$$

onde:

$$l \leftarrow size(A);$$

$$RA \leftarrow \downarrow_1^g(\triangle gol)A.$$

Na equação (35)  $RA$  é o conjunto de oponentes  $A$  ordenados do maior para o menor de acordo com a visão angular do objetivo definido por  $gol$ .  $a_{bola}$  representa o robô adversário com a posse de bola;  $l$  é a quantidade de robôs adversários e  $k$  a quantidade de robôs defensores. Robôs com baixos ângulos de visão do objetivo possuem maiores dificuldades para chutar a bola em sua direção. Essa ordenação é realizada para priorizar a defesa dos robôs com maior ângulo de visão ou posse bola, o ideal para a composição da defesa é que seja buscada sempre a situação onde  $l < k$  para garantir a superioridade numérica.

A figura 22 ilustra o processo de otimização defensivo, destacando os parâmetros utilizados e a sequência de execução das equações e procedimentos. A escolha dos parâmetros utilizados no algoritmo estão detalhados no capítulo 6.

#### 5.4.1 Diminuir o espaço do adversário

A equação (36) verifica a distância entre os robôs que compõem a defesa e os adversários, retornando a somatória das distâncias entre os robôs adversários e defensores. Uma distância mínima é desejada para dificultar passes ou chutes. O posicionamento próximo ao adversário também dificulta o seu avanço em direção ao gol.

Figura 22 – Procedimento de otimização defensivo.

```

1 Função PSO // Algoritmo PSO para otimização da defesa
2 Entrada: Robôs atacantes A, Posicionamento Atual PA, Ponto a ser
   defendido gol, posição da bola em campo bola
3 Saída: Posicionamento otimizado representado por (gbest(t))
4 Passo 1. Inicialização
5 início
6   Inicializa total de indivíduos do exame:  $total \leftarrow 100$ 
7   Organiza atacantes  $A \leftarrow f_{OrganizaOponentes}(A, gol, total)$ 
8   para cada partícula  $i \in 1, \dots, total-1$  faça
9     Inicializa posição da partícula distribuído de forma uniforme sendo
        $p_i \sim U((1, D_{maxX}), 1, D_{maxY})$ , onde  $D_{maxX} = 1200$  e  $D_{maxY} = 900$ 
       representam as dimensões do campo
10    Inicializa pbest para a posição inicial:
        $pbest(i) \leftarrow Defesa(A, p_i, gol, bola)$ 
11    Inicializa a velocidade:  $V_i \leftarrow (v_x = 1, v_y = 1)$ 
12  fim
13  Insere PA em partícula
14  Inicializa pbest da última partícula:
        $pbest(total) \leftarrow Defesa(A, p_{total}, gol, bola)$ 
15  Inicializa a velocidade:  $V_{total} \leftarrow (v_x = 1, v_y = 1)$ 
16  Inicializa gbest para o menor valor pbest do enxame:
        $gbest(0) \leftarrow \min(partícula)$ 
17 fim
18 Passo 2. Repete até o critério ser alcançado – 300 iterações
19 início
20   Inicializa parâmetros do algoritmo:  $c_1 \leftarrow c_2 \leftarrow 2$  e  $\omega \leftarrow 0.7298$ 
21   para cada Iteração  $t \in 1, \dots, 300$  faça
22     para cada partícula  $i \in 1, \dots, total$  faça
23       Escolha aleatoriamente:  $r_1, r_2 \sim U(0, 1)$ 
24       Atualiza a velocidade da partícula:
          $V_i(t+1) \leftarrow \omega V_i(t) + c_1 r_1 (pbest(i, t) - P_i(t)) + c_2 r_2 (gbest(t) - P_i(t))$ 
25       Atualiza a posição da partícula:  $P_i(t+1) \leftarrow P_i(t) + V_i(t+1)$ 
26       se  $Defesa(A, P_i(t), gol, bola) < pbest(i, t)$  então
27         Atualiza a melhor posição conhecida da partícula i:
            $pbest(i, t) \leftarrow Defesa(A, P_i(t), gol, bola)$ 
28         se  $Defesa(A, P_i(t), gol, bola) < gbest(t)$  então
29           Atualiza a melhor posição do enxame:  $gbest(t) \leftarrow P_i(t)$ 
30         fim
31       fim
32     fim
33   fim
34 fim
35 Passo 3. retorna (gbest(t)) como a melhor solução

```

Fonte: Autor

$$f_{\text{MinDist}}(A, P) = \sum_{a \in A} \sum_{p \in P} \text{proximidade}(p, a);$$

onde:

$$\text{proximidade}(p, a) \leftarrow \begin{cases} \text{desejado}, & \text{if } \text{desejado} > 0 \\ \text{PMID}, & \text{else} \end{cases}; \quad (36)$$

$$\text{desejado} \leftarrow \left(1 - \frac{DROBOT \times 2}{\text{distância}}\right);$$

$$\text{distância} \leftarrow f_{\text{DistEuclidiana}}(p, a).$$

Na equação (36),  $P$  representa o conjunto de robôs da defesa,  $A$  os oponentes,  $a$  é um robô do conjunto  $A$ , e  $p$  é um robô do conjunto  $P$ . O operador  $\text{proximidade}(p, a)$  é usado para verificar a distância mínima entre um robô  $p$  da equipe e um robô  $a$  oponente. O valor  $DROBOT \times 2$  indica uma dimensão de dois robôs na SSL ( $\approx 40cm$ ). Um valor  $> 0$  indica que o robô está entre o oponente e o objetivo. A distância de dois robôs foi escolhida para o defensor ficar suficientemente próximo do atacante mas diminuindo a possibilidade de colisão.

O operador  $f_{\text{DistEuclidiana}}$  verifica a distância Euclidiana e está definido em (53) no apêndice A.

#### 5.4.2 Bloqueio da visão de pontos de interesse

A equação (37) verifica se a visão do objetivo pelos oponentes está bloqueada. Normalmente as equipes da SSL tem dificuldades para a realização e recepção de passes por cobertura então o bloqueio é desejável para dificultar passes ou chutes diretos. No caso, uma soma muita alta indica que vários oponentes estão com visão direta do objetivo.

$$f_{\text{LinhasDeVisao}}(A, P, gol, a_{bola}) = \sum_{a \in A} \sum_{p \in P} \text{distânciaReta} + a_{semBola} + a_{comBola};$$

onde:

$$a_{semBola} \leftarrow \begin{cases} 0 & \text{if } a = a_{bola} \\ \text{PLOW} & \text{otherwise} \end{cases};$$

$$a_{comBola} \leftarrow \begin{cases} \text{PHIGH} & \text{if } d > \text{DBALL} \times 2 \wedge a = a_{bola} \\ \text{PLOW} & \text{if } \text{distânciaReta} > \text{DBALL} \times 2 \wedge a \neq a_{bola} \\ 0 & \text{if } \text{distânciaReta} \leq \text{DBALL} \times 2 \end{cases};$$

$$\text{distânciaReta} \leftarrow f_{\text{DistanciaReta}}(a, p, gol).$$

(37)

O operador  $f_{\text{LinhasDeVisao}}$  retorna os somatórios das distâncias  $\text{distânciaReta}$  entre cada robô  $a$  da linha formada entre cada robô  $p$  e  $gol$ . Se  $a \neq a_{bola}$  (não possui a bola, dado por  $a_{semBola}$ ), uma punição é aplicada. Assim, o bloqueio das linhas de visão do robô com a bola é privilegiada.  $a_{comBola}$  verifica se a distância da reta é inferior a duas vezes diâmetro da bola, definido por  $\text{DBALL}$ . O valor  $\text{DBALL} \times 2$  representa  $\approx$  metade de um robô da SSL ( $\approx 10\text{cm}$ ). Caso o portador da bola esteja com visão desbloqueada é aplicada a penalização máxima (PHIGH). O valor PLOW como penalização tem dois objetivos: priorizar o bloqueio do robô portador da bola; e indicar que mesmo a visão desbloqueada de um robô sem bola deve ser considerada nas otimizações. Um robô com linha de visão livre poderia receber um passe e realizar um chute a gol.

Como os cálculos utilizam o centro do robô como referência, as dimensões devem ser consideradas na condição de bloqueio de visão. O operador  $f_{\text{DistanciaReta}}$  está definido na equação (55) no apêndice A.

### 5.4.3 Bloqueio do portador da bola

A equação (38) verifica se existe ao menos um robô  $p$  do conjunto de defensores  $P$  obstruindo a visão do robô portador da bola  $a_{bola}$  do objetivo dado por  $gol$ . Esse bloqueio impede um chute direto ao gol. Chutes pelo alto não são evitados, porém as regras da SSL impede a realização de gols por cobertura.

$$f_{\text{ProtGol}}(a_{\text{bola}}, P, \text{gol}) = \begin{cases} 0 & \text{if } \textit{desejado} > 0 \\ \text{PHIGH} & \text{if } \textit{desejado} = 0 \end{cases}$$

**onde:** (38)

$$s \leftarrow \left( \sum_{p \in P} 1 \vee f_{\text{DistanciaReta}}(a_{\text{bola}}, p, \text{gol}) > \text{DBALL} \times 2 \right);$$

$$\textit{desejado} \leftarrow \text{size}(P) - s.$$

Na equação (38), o valor  $\text{DBALL} \times 2$  representa metade de um robô da SSL ( $\approx 10\text{cm}$ ). A variável  $s$  é a soma de robôs em  $P$  que estão bloqueando a visão do portador da bola. É preciso que ao menos um robô defensor esteja bloqueando a visão adversária, dado pela variável  $\textit{desejado}$ . Caso a visão do portador da bola esteja desbloqueada é aplicada uma alta penalização pois ele poderia chutar diretamente a gol.

#### 5.4.4 Respeito as regras da SSL

A equação (39) verifica se existe a possibilidade de colisão entre robôs da equipe com os robôs adversários.

$$f_{\text{Colisão}}(A, P) = \text{PHIGH} \times \left( \left( \sum_{a \in A} \sum_{p \in P} (\text{pos}(a) = \text{pos}(p)) \right) + \left( \sum_{p \in P} \sum_{q \in P} (\text{pos}(p) = \text{pos}(q)) \wedge p_{id} \neq q_{id} \right) \right) \quad (39)$$

Na equação (39) a verificação da colisão utiliza as coordenadas em campo. No caso  $\text{pos}(a) = \text{pos}(p)$  indica que  $a_x = p_x$  e  $a_y = p_y$ ;  $E p_{id} \neq q_{id}$  compara os identificadores dos robôs defensores.

Por fim, a equação (40) verifica se área do gol está sendo invadida. Cabe ressaltar que o sistema de estratégia possui verificação caso receba coordenadas que indicam a invasão do gol. O mesmo ocorre na prevenção para a colisão entre os robôs. Nessas situações, o sistema posiciona os robôs próximos as coordenadas informadas.

$$f_{\text{Invasão}}(P) = \text{PHIGH} \times \left( \sum_{p \in P} 1 \vee \text{areaGol}(p) = \textit{verdadeiro} \right);$$

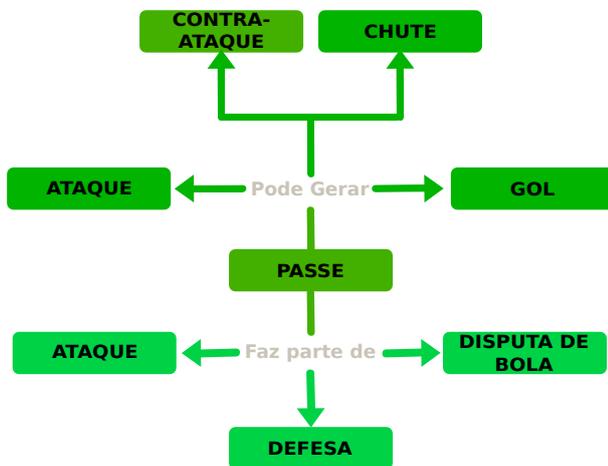
**onde:** (40)

$$\text{areaGol}(p) \leftarrow (p_x < 120 \vee p_x > 1100) \wedge (p_y > 320 \wedge p_y < 620).$$

## 5.5 OTIMIZAÇÃO DO PASSE

No futebol, os passes compreendem todas as formas de transferência da bola para um colega de equipe dentro do campo, seja com os pés ou com a cabeça. Em situações de ataque, passes que resultem em finalizações ao gol são chamados de assistências. Também possibilitam a inversão de jogadas de um lado para outro do campo, bem como as tabelas – que são trocas rápidas de passes entre dois jogadores (UNISINOS, 2014, 2016). A figura 23 ilustra as ações relacionadas ao passe.

Figura 23 – Transição passe.



Fonte: Autor "adaptado de" Unisinos, 2016

Para que uma equipe realize ataques com sucesso todos os jogadores devem manter a formação, implementando a estratégia da equipe. Os atacantes devem estar aptos para recepção de um passe direto. Os jogadores devem manter o espaço aberto. Isso significa que a distância do ponto avaliado ao oponente mais próximo deve ser maximizada.

Os atacantes devem manter um caminho aberto para o gol do oponente para criar oportunidades de pontuação. Portanto, a distância da linha que liga o ponto avaliado e o centro do gol ao oponente mais próximo (exceto o goleiro) deve ser maximizada.

Assim, o principal responsável por um passe é o jogador que recebe a bola e não o que executa o passe. Cabe a quem recebe o passe sempre procurar a melhor posição em campo.

Sendo essas as condições para uma equipe que está atacando consiga realizar passes com sucesso, a otimização de bloqueio considera cinco situações desejáveis para uma formação de bloqueio de passes:

- a) Manter uma distância mínima entre os robôs para que o oponente realize movimentos mais difíceis e diminuam as chances do adversário receber a bola, fazer passes ou chutar para o gol;
- b) O espaço para execução do passe deve ser o menor possível, a fim de dificultar a execução;
- c) Os robôs defensores devem estar distribuídos para limitar a visão dos adversários pelo portador da bola, ser numericamente superior ou equivalente e estarem próximos entre si para oportunizar suporte na recuperação de bola;
- d) Aumentar o espaço de jogo da própria equipe e diminuir o espaço do adversário;
- e) Respeito pelas regras SSL em colisões entre robôs e invasão da área de gol.

A equação (41) implementa as situações desejáveis para a formação defensiva para bloqueio de passes. A equação é composta por oito equações detalhadas nas próximas seções.

$$\begin{aligned}
 \text{BloqueioPasse}(A, p(i, t), \text{gol}, \text{bola}) = \{ & \\
 & f_{\text{MinDist}}(RA, p(i, t)) + \\
 & f_{\text{RaioAção}}(p(i, t), a_{\text{bola}}) + \\
 & f_{\text{LinhasDeVisãoBola}}(RA, p(i, t), a_{\text{bola}}) + \\
 & f_{\text{LinhasDeVisãoEquipe}}(RA, p(i, t)) + \\
 & f_{\text{RaioEquipe}}(p(i, t), a_{\text{bola}}, \text{gol}) + \\
 & f_{\text{ProtGol}}(a_{\text{bola}}, p(i, t), \text{gol}) + & (41) \\
 & f_{\text{Colisão}}(RA, p(i, t)) + \\
 & f_{\text{Invasão}}(p(i, t)) \\
 & \}
 \end{aligned}$$

**onde:**

$$a_{\text{bola}} \leftarrow \text{pos}(\text{bola}) = \text{pos}(a) \forall a \in A$$

$$RA \leftarrow f_{\text{OrganizaOponentes}}(A, \text{gol}, \text{size}(p(i, t)))$$

Onde  $A$  representa o conjunto de robôs adversários,  $p(i, t)$  é uma partícula da população e representa o conjunto de robôs para formação do bloqueio de passes (solução candidata).  $i$  e  $t$  representam o número da partícula e iteração. A variável  $\text{gol}$  representa a

baliza da equipe e  $bola$  a posição da bola em campo, dada por suas coordenadas  $(x,y)$ . O conjunto  $A$ , utilizado em todas as equações, é organizado de acordo com a regra descrita na equação (35).

O operador  $pos$  é utilizado para verificar a aproximação. No caso  $pos(bola) = pos(a)$  visa identificar qual robô está próximo suficiente para ser considerado com posse da bola ( $a_{bola}$ ). As funções para verificação de distância mínima, proteção do gol, colisão e invasão foram definidas anteriormente nas equações (36), (38), (39) e (40).

A figura 24 ilustra o processo de otimização defensivo, destacando os parâmetros utilizados e a sequência de execução das equações e procedimentos. A escolha dos parâmetros utilizados no algoritmo está detalhada no capítulo 6.

### 5.5.1 Raio de ação do portador da bola

No futebol real o conceito de pressionamento do portador da bola é aplicado para reduzir seu espaço para manobras e induzi-lo ao erro. Esse conceito foi desenvolvido na equação (42).

A equação (42) verifica se um determinado robô  $p$  (do conjunto  $P$ ) está no raio  $raio$  de ação do robô portador da bola  $a_{bola}$ . O valor para o raio de ação  $raio$  indica a distância segura para a realização de um passe. Esse valor é influenciado pela arquitetura física do robô e sua capacidade de controle. Nas simulações em campo, o valor médio de dois metros foi encontrado como um parâmetro aceitável e portanto adotado como distância mínima. Essa distância é calculada de acordo com a distância do robô portador da bola  $a_{bola}$  para o objetivo  $gol$ .

$$f_{\text{RaioAção}}(p(i,t), a_{bola}, gol) = \left\{ \begin{array}{ll} \text{PHIGH} \times \frac{\text{size}(P)}{3} & \text{if } \text{robosFora} > \frac{\text{size}(P)}{3} \wedge \text{side}(a_{bola}) = \text{side}(gol) \\ \text{PMID\_HIGH} & \text{if } \text{robosFora} > \frac{\text{size}(P)}{3} \wedge \text{side}(a_{bola}) \neq \text{side}(gol) \end{array} \right\}$$

onde:

$$\text{robosFora} \leftarrow \sum_{p \in P} 1 \vee f_{\text{EstaNoRaio}}(\text{raio}, p, a_{bola}) = \text{FORA};$$

$$\text{raio} \leftarrow \min(200, f_{\text{DistEuclidiana}}(a_{bola}, gol) - 100).$$

(42)

O operador  $side$  é utilizado para verificar se a jogada está ocorrendo no campo de ataque ou defesa. Para o bloqueio adotou-se como critério  $\frac{1}{3}$  da equipe obrigatoriamente

Figura 24 – Procedimento de otimização para bloqueio de passes

```

1 Função PSO // Algoritmo PSO para otimização de bloqueio de passe
2   Entrada: Robôs atacantes A, Posicionamento Atual PA, Ponto a ser
      defendido gol, posição da bola em campo bola
3   Saída: Posicionamento otimizado representado por (gbest(t))
4   Passo 1. Inicialização
5   início
6     Inicializa total de indivíduos do exame:  $total \leftarrow 100$ 
7     Organiza atacantes  $A \leftarrow f_{OrganizaOponentes}(A, gol, total)$ 
8     para cada partícula  $i \in 1, \dots, total-1$  faça
9       Inicializa posição da partícula distribuído de forma uniforme sendo
           $p_i \sim U((1, D_{maxX}), 1, D_{maxY})$ , onde  $D_{maxX} = 1200$  e  $D_{maxY} = 900$ 
          representam as dimensões do campo
10      Inicializa pbest para a posição inicial:
           $pbest(i) \leftarrow BloqueioPasse(A, p_i, gol, bola)$ 
11      Inicializa a velocidade:  $V_i \leftarrow (v_x = 1, v_y = 1)$ 
12    fim
13    Insere PA em partícula
14    Inicializa pbest da última partícula:
           $pbest(total) \leftarrow BloqueioPasse(A, p_{total}, gol, bola)$ 
15    Inicializa a velocidade:  $V_{total} \leftarrow (v_x = 1, v_y = 1)$ 
16    Inicializa gbest para o menor valor pbest do enxame:
           $gbest(0) \leftarrow \min(partícula)$ 
17  fim
18  Passo 2. Repete até o critério ser alcançado – 300 iterações
19  início
20    Inicializa parâmetros do algoritmo:  $c_1 \leftarrow c_2 \leftarrow 2$  e  $\omega \leftarrow 0.7298$ 
21    para cada Iteração  $t \in 1, \dots, 300$  faça
22      para cada partícula  $i \in 1, \dots, total$  faça
23        Escolha aleatoriamente:  $r_1, r_2 \sim U(0, 1)$ 
24        Atualiza a velocidade da partícula:
           $V_i(t+1) \leftarrow \omega V_i(t) + c_1 r_1 (pbest(i, t) - P_i(t)) + c_2 r_2 (gbest(t) - P_i(t))$ 
25        Atualiza a posição da partícula:  $P_i(t+1) \leftarrow P_i(t) + V_i(t+1)$ 
26        se  $BloqueioPasse(A, P_i(t), gol, bola) < pbest(i, t)$  então
27          Atualiza a melhor posição conhecida da partícula i:
             $pbest(i, t) \leftarrow BloqueioPasse(A, P_i(t), gol, bola)$ 
28          se  $BloqueioPasse(A, P_i(t), gol, bola) < gbest(t)$  então
29            Atualiza a melhor posição do enxame:  $gbest(t) \leftarrow P_i(t)$ 
30          fim
31        fim
32      fim
33    fim
34  fim
35  Passo 3. retorna (gbest(t)) como a melhor solução

```

Fonte: Autor.

atuando junto ao robô adversário com a posse de bola. Caso a equipe esteja completa em campo com 7 jogadores haveria ao menos 2 realizando essa função. Se o adversário estiver no campo de defesa e a regra não é cumprida atribui-se uma penalização alta ( $\text{PHIGH} \times \frac{\text{size}(P)}{3}$ ). O operador  $\text{size}(P)$  retorna a quantidade de robôs participando da otimização. O operador  $f_{\text{EstaNoRaio}}$  está definido na equação (58) no apêndice A.

### 5.5.2 Raio de atuação dos adversários

Semelhante ao futebol humano, os adversários que são marcados por proximidade tem maiores dificuldades para movimentação em campo e recepção de passes. A equação (43) é responsável por diminuir o espaço de movimentação.

A equação (43) verifica se no posicionamento dos adversários  $a$  em  $A$  se ao menos um dos robôs defensores  $p$  em  $P$  está no raio de ação. A penalidade para cada robô fora da área de ação do oponente é mediana, pois ao mesmo tempo é desejável que o novo posicionamento cubra a maior área possível. O raio de ação mínimo foi definido como dois metros, equivalente a  $200\text{cm}$ .

$$f_{\text{RaioAdversarios}}(A, P, a_{\text{bola}}, \text{gol}) = \text{PMID} \times \text{robosFora}$$

onde:

$$\begin{aligned} \text{robosFora} &\leftarrow \sum_{p \in P} \sum_{a \in A} 1 \vee f_{\text{EstaNoRaio}}(\text{raio}, p, a) \neq \text{FORA}; \\ \text{raio} &\leftarrow \frac{\min(200, f_{\text{DistEuclidiana}}(a_{\text{bola}}, \text{gol}) - 100)}{2}; \end{aligned} \tag{43}$$

### 5.5.3 Visão dos companheiros de equipe pelo portador da bola

Como exposto anteriormente, adversários bem posicionados sem marcação são os responsáveis por passes bem sucedidos. As equipes da SSL tem dificuldades para recepção de passes por cobertura. Evitar que os adversários possam receber passes diretos é responsabilidade da equação (44).

A equação (44) verifica se a visão dos companheiros de equipe  $A$  pelo robô portador da bola  $a_{\text{bola}}$  estão bloqueadas pelos robôs em  $P$ . A penalização é proporcional a quantidade de adversários com linha de passe aberta, calculada na variável *bloqueio*.

$$f_{\text{LinhasDeVisãoBola}}(A, P, a_{\text{bola}}) = \text{PHIGH} \times (1 - \min(1, \frac{\text{bloqueio}}{\text{size}(A)}))$$

onde:

$$\text{bloqueio} \leftarrow \sum_{a \in A} \sum_{p \in P} 1 \forall f_{\text{DistanciaReta}}(a, p, a_{\text{bola}}) > \text{DBALL} \times 2 \quad (44)$$

#### 5.5.4 Visão dos companheiros de equipe entre si

Bloquear a visão dos companheiros entre si é uma estratégia para impedir que possa ocorrer a tabela entre dois adversários.

A equação (45) verifica se a visão dos adversários entre si estão bloqueadas pelos robôs em  $P$ . A penalização é proporcional a quantidade robôs adversários com visão desbloqueada entre si.

$$f_{\text{LinhasDeVisãoEquipe}}(A, P) = \text{PHIGH} \times (1 - \min(1, \frac{\text{bloqueio}}{\text{size}(A) - 1}));$$

onde:

$$\text{bloqueio} \leftarrow 0; \quad (45)$$

$$\forall a_1 \in A: \text{bloqueio} \leftarrow \text{bloqueio} + \sum_{a_2 \in A} \sum_{p \in P} 1 \forall$$

$$f_{\text{DistanciaReta}}(a_2, p, a_1) > \text{DBALL} \times 2 \wedge a_1 \neq a_2.$$

Para robô adversário  $a$  em  $A$ , exceto o robô portador da bola, a equação verifica se existe um robô  $p$  em  $P$  com distância  $\text{DBALL} \times 2$  do segmento de reta entre  $a$  e  $a_{\text{bola}}$ . Foi considerando o espaço de  $10\text{cm}$  ou  $\text{DBALL} \times 2$  para considerar que a visão do portador da bola  $a_{\text{bola}}$  para  $a$  seja parcialmente bloqueada.

#### 5.5.5 Verificar se os robôs estão no raio de ação dos demais robôs da equipe

Evitar que os colegas de equipe estejam próximos é desejável para a cobertura defensiva seja mais efetiva ao impedir que vários robôs atuem na mesma área de cobertura de outros da equipe.

A equação (46) verifica se um robô da equipe está dentro da área de ação de outro robô da equipe. O raio de ação entre os defensores foi definido para ser a metade

do raio de ação dos atacantes (mínimo de um metro). A penalização para cada robô é média, pois é desejado que os robôs estejam distribuídos em campo, possibilitando maiores oportunidades de cobertura defensiva. A variável  $robosFora$  indica a quantidade de robôs  $p_2$  em  $P$  que estão atuando no raio defensivo de  $p_1$ .

$$f_{\text{RaioEquipe}}(P, a_{bola}, gol) = \text{PMID} \times robosFora$$

onde:

$$robosFora \leftarrow \sum_{p_1 \in P} \sum_{p_2 \in P} 1 \vee f_{\text{EstaNoRaio}}(raio, p_1, p_2) \neq FORA \wedge p_1 \neq p_2;$$

$$raio \leftarrow \frac{\min(200, f_{\text{DistEuclidiana}}(a_{bola}, gol) - 100)}{2}.$$
(46)

## 5.6 CONSIDERAÇÕES DO CAPÍTULO

A SSL teve modificações já implementadas e outras possíveis mudanças em discussão para um futuro próximo. As principais modificações na categoria SSL, foram a divisão em duas ligas (A e B), mudanças na área do goleiro e o aumento da quantidade de robôs em campo ( $8 \times 8$  na liga A e futuramente  $11 \times 11$ ) (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2018).

Essas mudanças possibilitarão diversas combinações de jogadas para defesa e ataque, logo, um sistema de otimização para posicionamento respeitando os diversos critérios defensivos do futebol moderno é uma solução para responder as diversas situações em jogo.

Neste capítulo foi proposto um conjunto de equações para atuar como funções de aptidão na otimização do PSO. O foco das equações é encontrar posicionamentos em jogadas de bola parada visando diminuir a vantagem do adversário.

A equação para posicionamento defensivo foi utilizado nos experimentos para definir os parâmetros de configuração do PSO (detalhados no capítulo 6). No capítulo 7 as equações são aplicadas e analisadas em diversas situações de gol ocorridos na RoboCup 2019 em Sidney.

## 6 SELEÇÃO DOS PARÂMETROS DO ALGORITMO PSO

Como apresentado no capítulo 3, os parâmetros do algoritmo PSO influenciam no resultado da otimização. Na seção 3.2.3 foi verificado que várias discussões sobre a influência dos parâmetros do PSO como a inércia ( $\omega$ ) e coeficientes de aceleração ( $c_1$  e  $c_2$ ) influenciam a exploração do espaço de busca.

Este capítulo explica os critérios para escolha dos diversos parâmetros do algoritmo, inicialização e movimentação da população de partículas e limitações do espaço de busca.

A equação para defesa do gol foi utilizada para definir os parâmetros ideais do PSO. Os valores encontrados nos experimentos foram aplicados também nas otimizações posteriores para bloquear passes.

### 6.1 MOVIMENTAÇÃO DAS PARTÍCULAS

Cada partícula é composta de sete robôs. Cada robô representa uma coordenada  $(x,y)$  em campo com velocidade  $vx,vy$ .

Para que as partículas se movessem no espaço de busca, os próprios robôs deveriam movimentar-se em campo. Assim, a equação de velocidade e posição do PSO (detalhadas na seção 3.2.2) foram utilizadas para definir as equações(47) e (48).

$$V_{i_r}(t+1) = \omega V_{i_r}(t) + c_1 r_1 (pbest(i_r,t) - P_{i_r}(t)) + c_2 r_2 (gbest(t) - P_{i_r}(t)) \quad (47)$$

$$P_{i_r}(t+1) = P_{i_r}(t) + V_{i_r}(t+1) \quad (48)$$

A equação (47) é utilizada para calcular a velocidade individual dos robôs. A equação (48) para atualizar a posição individual. Nas equações, a variável  $i_r$  é a identificação do robô ( $r$ ) na partícula  $i$ .

O espaço de busca foi definido como  $900 (D_{maxY}) \times 1200 (D_{maxX})$  para representar proporcionalmente o tamanho do campo da SSL na liga A. Para compor a partícula, cada robô é definido com posição dado por  $x = rand(0,D_{maxX})$  e  $y = rand(0,D_{maxY})$  e velocidade  $vx = 1,vy = 1$ .

## 6.2 PARÂMETROS DO ALGORITMO

O peso da inércia ( $\omega$ ) e coeficientes de aceleração ( $c_1$  e  $c_2$ ) influenciam a exploração do espaço de busca. Várias são as propostas para definição desses componentes do PSO e um dos objetivos dessa tese é determinar os parâmetros ideais do PSO para uso na otimização.

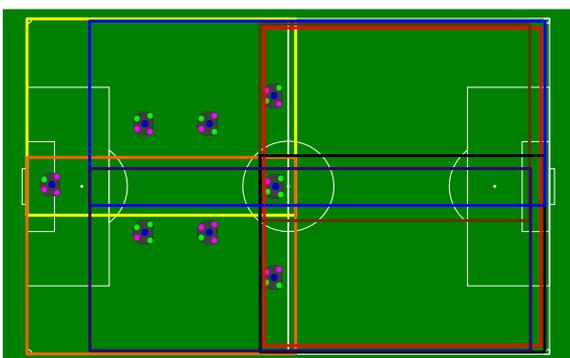
Para determinar os parâmetros ideais, os robôs oponentes foram posicionados na clássica formação 2–2–3 utilizada em jogos  $8 \times 8$  para definição dos cenários. Nesta formação, os jogadores têm um campo bem definido de atuação para ataque e defesa (figura 25a).

Na figura 25a as cores determinam a área de atuação individual para cada adversário. Na imagem, o robô identificado pelo número sete atua em todo o campo de ataque. O robô cinco no campo de ataque superior e o seis no ataque inferior. Semelhantes aos posicionamentos encontrados no futebol humano com designações de lateral direito ou esquerdo. Essa área de atuação não impede que os robôs se movam pelas demais áreas do campo.

Cada cenário foi composto por cinco robôs adversários distribuídos aleatoriamente em campo conforme sua área de atuação apresentada na figura 25a. A figura 25b apresenta um exemplo da posição dos oponentes usados nas simulações. Um robô adversário foi escolhido aleatoriamente para possuir a bola.

Figura 25 – Formação 2–2–3 no futebol  $8 \times 8$ .

(a) Formação 2–2–3



(b) Exemplo de distribuição nas simulações.



Fonte: Autor

O peso de inércia desempenha um papel fundamental no processo de fornecer equilíbrio entre a intensificação e diversificação no espaço de busca. O peso da inércia determina a taxa de contribuição no cálculo da velocidade da partícula.

O artigo (BANSAL et al., 2011) comparou várias propostas de pesos de inércia e concluiu que o valor constante 0.7298 (proposto por (CLERC; KENNEDY, 2002)), o randômico  $0.5 + \frac{rand(0,1)}{2}$  (proposto por (EBERHART; SHI, 2001)) e o linear  $(\omega_{start} - \omega_{end}) \times \frac{itMax-it}{itMax} + \omega_{end}$ , onde  $\omega_{start} = 0.9$  e  $\omega_{end} = 0.4$ ,  $itMax$  é o máximo de iterações e  $it$  a iteração corrente (proposto por (XIN; CHEN; HAI, 2009)) são os mais indicados para chegar em solução com uma quantidade menor de iterações ou menor erro.

Foram realizadas 10 mil simulações para cada cenário utilizando a equação para bloqueio de defesa (equação (34)), definida no capítulo anterior.

Cada cenário foi composto de cinco instantes, simulando a movimentação do adversário e os novos posicionamentos da defesa. A cada instante os robôs adversários eram movidos aleatoriamente 50cm em direção ao gol. Essa movimentação poderia ser para esquerda ou direita.

Os coeficientes de aceleração ( $c_1$  e  $c_2$ ) foram escolhidos com base literatura na especializada. Os valores mais utilizados na literatura são:  $c_1 = c_2 = 2$  e  $c_1 = c_2 = 1.496$ , nas simulações foram acrescentados os valores  $c_1 = c_2 = 1$ ,  $c_1 = 2, c_2 = 1$  e  $c_1 = 1, c_2 = 2$ . O coeficiente  $c_1$  controla a diversidade individual de cada partícula e o  $c_2$  a diversidade global. Quando  $c_1 > c_2$  a partícula tende-se a mover para sua melhor posição individual (pbest) e quando  $c_1 < c_2$  a partícula tende-se a mover para a melhor posição global do enxame.

O tamanho da população em cada conjunto de simulações variou de 50 a 200 participantes e o número de iterações de 50 até 500. Essas variações visam determinar se o tamanho da população e a quantidade de iterações influenciaria no resultado final do algoritmo. Determinar o tamanho da população e quantidade de interações é importante, pois impacta diretamente no tempo final da execução do algoritmo.

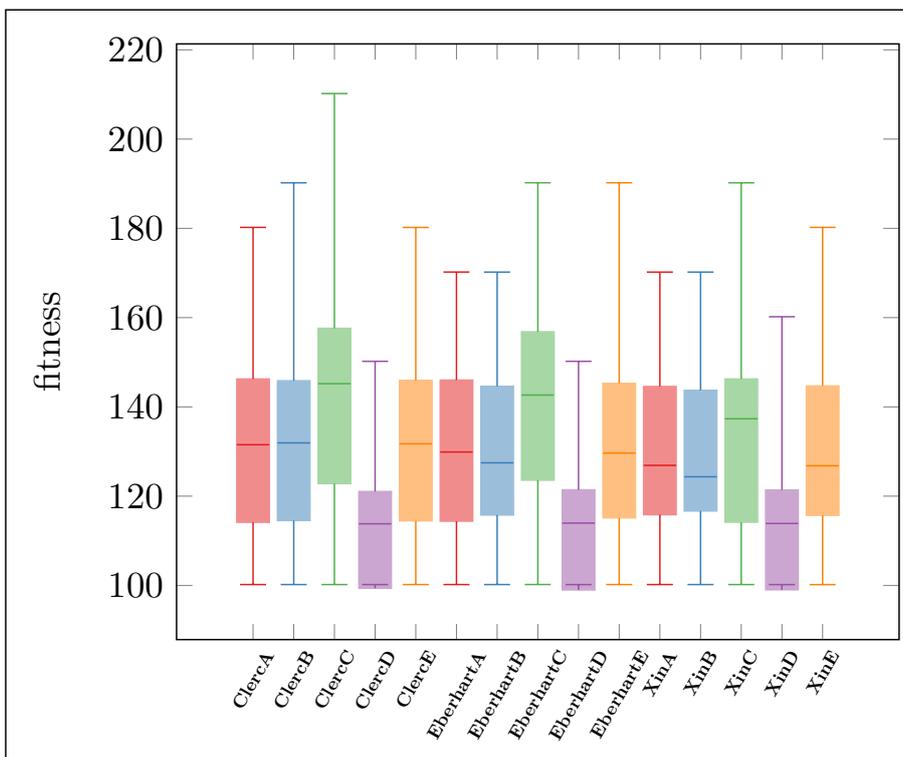
A posição atual da equipe faz parte da população, assim é a única partícula não criada conforme as regras expostas anteriormente. A movimentação adversária pode ter sido mínima e o posicionamento atual pode continuar sendo a melhor escolha.

As topologias de vizinhança global e local foram consideradas nos experimentos. Na topologia global, todas as partículas estão interligadas, na local é determinado o tamanho da vizinhança. Nos experimentos a vizinhança local foi configurada para dez partículas.

As configurações que forneceram melhores resultados foram com 100 partículas na população de enxames e 300 iterações; acima disso, não houve melhora nos resultados. Cada partícula consistiu em cinco robôs posicionados em defesa (com as coordenadas  $x,y$  e velocidades  $vx,vy$ ), o goleiro não foi considerado. A topologia *lbest* com os mesmos parâmetros obteve resultados semelhantes aos da topologia *gbest*, mas com um tempo médio de execução 30 % maior.

A figura 26 apresenta os resultados de cenários de simulação com 300 iterações, população de 100 partículas e topologia *gbest* após 10 mil simulações. Como mostra a figura 26, o valor mínimo (o valor desejado, pois é uma função de minimização) é o mesmo em todas as simulações (variação  $\approx 0.1$ ). Outras posições de campo obtêm valores semelhantes. Na figura 26 as legendas ClercA, EberhartA e XinA significam o fator de inércia proposto por cada autor aplicado com os coeficientes  $c_1 = 1$  e  $c_2 = 2$ ; ClercB, EberhartB e XinB com os coeficientes  $c_1 = 2$  e  $c_2 = 1$ ; ClercC, EberhartC e XinC com os coeficientes  $c_1 = c_2 = 1$ ; ClercD, EberhartD e XinD com os coeficientes  $c_1 = c_2 = 2$ ; ClercE, EberhartE e XinE com os coeficientes e  $c_1 = c_2 = 1.496$ .

Figura 26 – Configurações do cenário: a)  $c_1 = 1$  e  $c_2 = 2$ ; b)  $c_1 = 2$  e  $c_2 = 1$ ; c)  $c_1 = c_2 = 1$ ; d)  $c_1 = c_2 = 2$ ; e)  $c_1 = c_2 = 1.496$ .



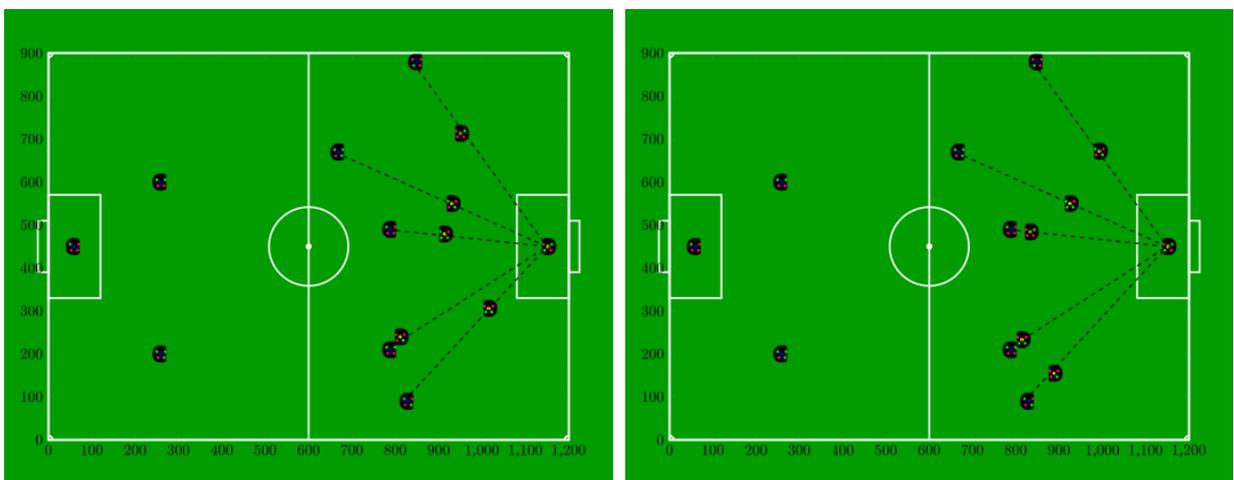
Fonte: Autor

As figuras 27a, 27b e 27c mostram alguns exemplos das posições obtidas para cada fator de inércia. A figura 28b mostra a pior situação de posicionamento ( $c_1 = c_2 = 1$ ). Nesse caso, a solução encontrada está muito abaixo do ideal para um sistema de posicionamento de defesa. Para este cenário e espaço de pesquisa, valores mais altos para  $c_1$  e  $c_2$  são mais eficazes pois resultam na diminuição gradual da amplitude da trajetória das partículas, garantindo assim a convergência do algoritmo (ZHANG; WANG; JI, 2015).

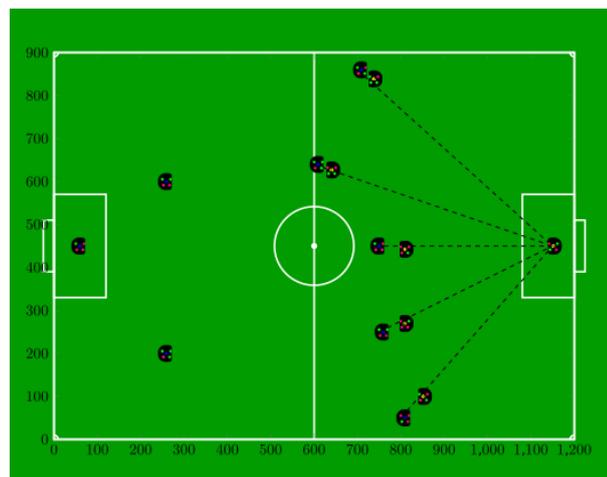
Figura 27 – Exemplos de posicionamentos obtidos com os fatores de inércia propostos

(a) (CLERC; KENNEDY, 2002)

(b) (EBERHART; SHI, 2001)



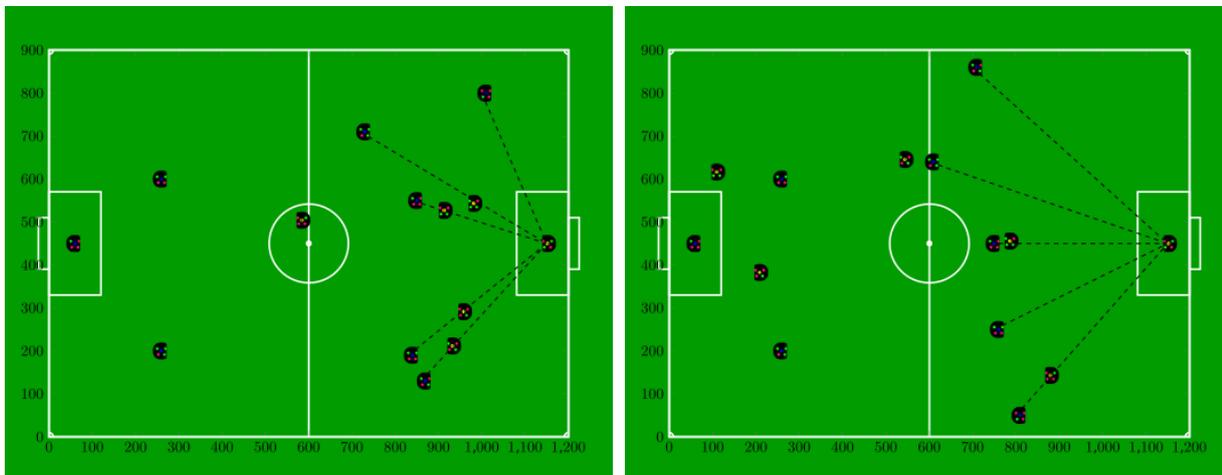
(c) (XIN; CHEN; HAI, 2009)



### 6.3 VERIFICAÇÃO VISUAL

No simulador grSim (MONAJJEMI; KOOCHAKZADEH; GHIDARY, 2012), a bola e os robôs do adversário foram posicionados em diferentes localizações no campo para

Figura 28 – Exemplos de posicionamentos ruins encontrados

(a) Coeficientes  $c_1 = c_2 = 2$ .(b) Coeficientes  $c_1 = c_2 = 1$ .

Fonte: Autor

verificação visual do comportamento dos robôs da equipe. Essas validações permitiram identificar e ajustar alguns parâmetros das funções de aptidão.

Em situações de bola parada, é normal que os jogadores se movimentem pelo campo procurando a melhor posição para receber ou bloquear passes. Esse comportamento foi observado no simulador.

Durante a *Latin American Robotics Competition (LARC) 2018* foram realizados alguns experimentos em campo para observar o comportamento dos robôs da equipe RoboFei. Nesses experimentos foi utilizada a função de aptidão para defesa do gol. Em situações de bola parada os robôs se posicionaram conforme o esperado. Porém no decorrer do jogo percebeu-se que era necessário que a otimização recebesse as posições futuras dos robôs adversários. O tempo de resposta entre a captura das informações pelo sistema de visão, processamento pelo sistema de estratégia, otimização, cálculo das rotas de movimentação e envio dos novos posicionamentos chegavam tardiamente para os robôs, ocasionando atrasos  $\approx 3s$ .

#### 6.4 VALIDAÇÃO INICIAL

Para validar a proposta inicial deste trabalho, foram selecionadas situações de passe e chutes a gol. Da RoboCup 2018 foram analisados cinco partidas com função

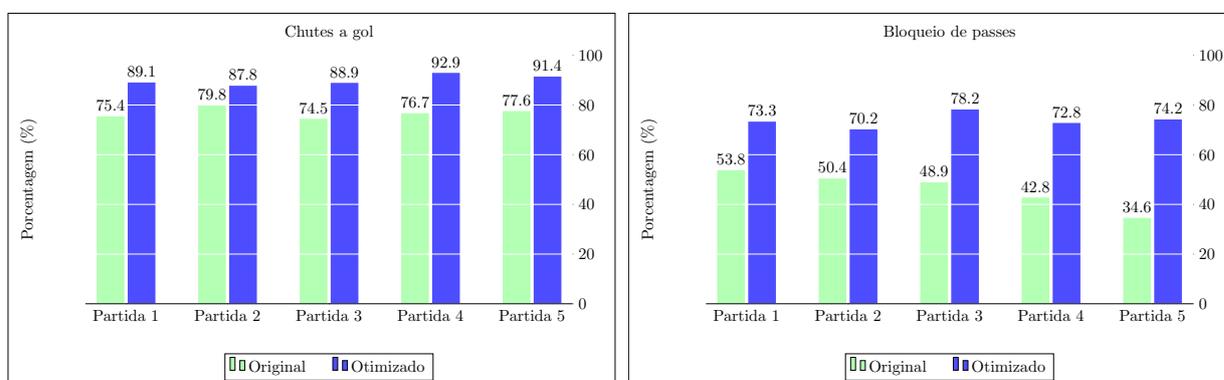
de aptidão de defesa (equação (34)) e da RoboCup 2019 cinco partidas com a função de aptidão para bloqueio de passes (equação (41)).

Desses jogos, foram analisadas todas as jogadas de INDIRECT\_KICK. Cada jogada foi analisada individualmente com 10 mil simulações com os parâmetros do algoritmo definidos anteriormente. As figuras 29a e 29b mostram a taxa de aumento para bloqueio de chutes ou interceptação de passes.

Figura 29 – % de interceptação em jogos da RoboCup

(a) 2018

(b) 2019



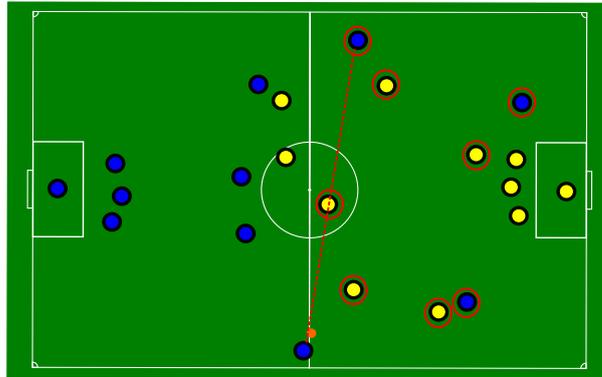
Fonte: Autor

Nas simulações, as novas posições aumentaram a probabilidade de sucesso em bloquear os passes ou chutes a gol. Porém só foi verificado o início da jogada e se existia ao menos um robô bloqueando a linha de passe ou chute.

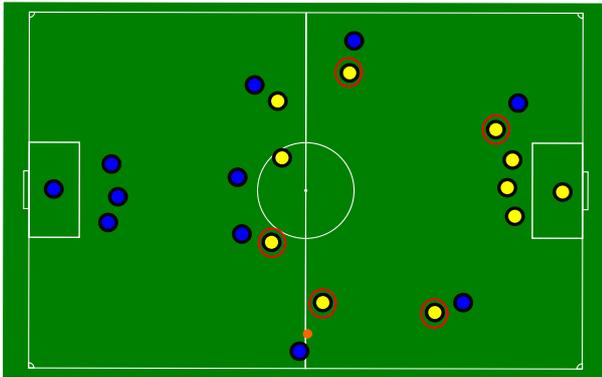
Na figura 30 pode ser observado as posições originais dos robôs que participaram do chute indireto como defesa (equipe amarela) ou ataque (equipe azul). A linha pontilhada vermelha indica o passe feito originalmente pela equipe azul. Pode-se observar que ambas as equipes usam delta defensivo (usar 3 robôs para formar uma linha de defesa na frente do gol). Na figura 30b pode ser observado o efeito da pressão da equipe amarela sob o adversário. Como o chute indireto não permite que a equipe marque um gol sem que a bola seja passada para outro robô, os robôs que compõem a defesa delta podem ser usados para pressionar, como na figura 30c.

Figura 30 – Exemplo de posicionamento

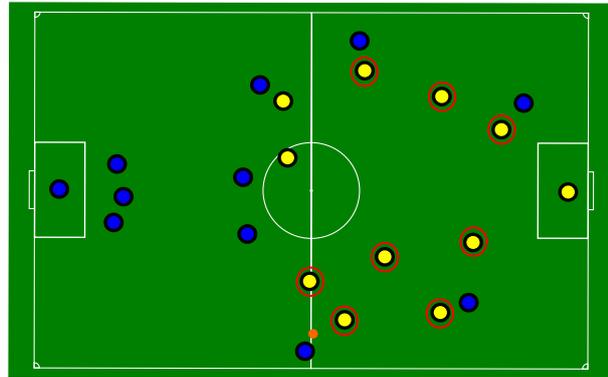
(a) Posição original



(b) Posição otimizada para bloqueio de passe com delta defensivo



(c) Posição otimizada para bloqueio de passe sem delta defensivo



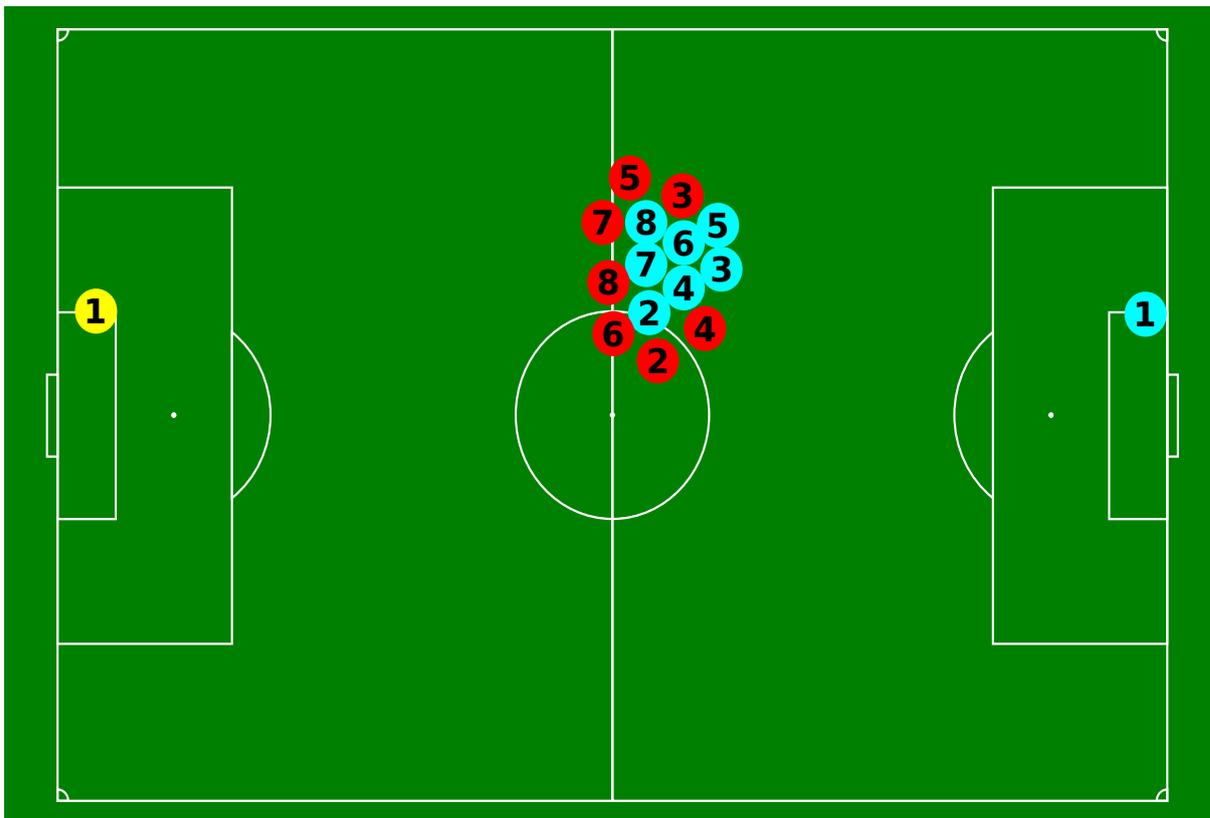
Fonte: Autor

## 6.5 CONSIDERAÇÕES DO CAPÍTULO

A contribuição original deste capítulo foi definir os parâmetros ideais para configuração do algoritmo PSO para problemas de otimização em situações com espaço de busca semelhantes. Diversas aplicações adotam os parâmetros  $\omega = 0.7298$  e  $c_1 = c_2 = 1.496$  por padrão. Porém, os cenários com  $c_1 = c_2 = 2$  apresentaram os melhores resultados, seguidos pelos cenários com  $c_1 = c_2 = 1.496$ . Nos testes realizados, a inércia adotada mostrou pouca influência no resultado final do algoritmo. Foi escolhida uma inércia fixa ( $\omega = 0.7298$ ) por exigir menos processamento.

Não é possível determinar o valor mínimo ideal para cada função. Esses valores são obtidos utilizando somatórios de distâncias ou ângulos de visão bloqueados ou não. Logo, esse valor difere para cada posicionamento adversário. Para obter um valor mínimo

Figura 31 – Possível posicionamento com valor mínimo.



Fonte: Autor

próximo de zero, as equipes teriam que estar posicionadas conforme a figura 31 (adversários representados em azul e defensores em vermelho). Porém, esse posicionamento não ocorreria em uma partida real de futebol.

Experimentos realizados em campo durante a LARC 2018 mostraram que é necessário antecipar a posição do robô adversário e da bola. O tempo entre o processamento das novas posições, envio e execução pelos robôs não foi ideal. Cerca de 3 segundos para o cálculo do posicionamento, o sistema enviar os comandos aos robôs e esses executarem a ação. Porém, em jogos com bola parada, o posicionamento encontrado sempre dificultava passes ou chutes para o gol.

As validações iniciais demonstraram a possibilidade de aumento de sucesso no bloqueio de passes ou chutes a gol. Porém, nesses experimentos foram considerados apenas a posição inicial da bola e verificado se em algum momento o passe ou chute foi bloqueado. Também não foi possível determinar pela análise dos registros históricos se o passe foi realizado com bola alta ou não. Resultados parciais foram publicados em (LAUREANO; TONIDANDEL, 2019a,b)

No próximo capítulo serão analisadas individualmente várias jogadas de gol que ocorreram na RoboCup 2019 realizados em Sidney. Todos os experimentos foram realizados com a configuração conforme detalhada anteriormente. Para fator de inércia adotou-se  $\omega = 0.7298$ , coeficientes de aceleração  $c_1 = c_2 = 2$ , topologia de vizinha global, 100 partículas e 300 iterações. A composição da partícula mudou de acordo com o jogo realizado em função da quantidade de robôs em campo. Para definir a quantidade de robôs que fariam parte da partícula adotou-se a quantidade de defensores em campo no momento da jogada. Eventualmente algum robô poderia estar suspenso por penalidade ou estava fora de campo por falhas mecânicas ou eletrônicas.

## 7 ANÁLISE DAS APLICAÇÕES DAS FUNÇÕES DE APTIDÃO E MÉTRICAS

Após validação dos parâmetros e análise inicial em situações de jogo, explicada no capítulo 6, este capítulo apresenta as análises individuais de jogadas com conclusão a gol em jogos da RoboCup 2019. São apresentadas as partidas/gols selecionados, os critérios para a escolha das equipes e a avaliação individual de cada gol baseado nas novas métricas apresentadas no capítulo 4.

Inicialmente é apresentado o resultado consolidado dos jogos analisados. Com as médias individuais das variáveis analisadas e comparação final do resultado geral. Na sequência, os jogos são analisados individualmente. Nas primeiras quatro análises optou-se por detalhar todos os testes e gráficos criados durante a fase de validação. Nas demais, optou-se por evidenciar os resultados.

### 7.1 JOGOS ESCOLHIDOS PARA ANÁLISE

As jogadas selecionadas para análise foram da liga A da edição da RoboCup de 2019 realizado em Sidney (Austrália). Foram selecionadas jogadas de finalização em gol, conforme tabela 8.

Os gols com origem na jogada NORMAL\_START foram marcados com cobranças de penâltis, logo, essas jogadas foram desconsideradas nas análises. Na partida Upper 2-1, o registro histórico aponta com gol da equipe amarela (ER-Force) a partir de uma jogada indicada como DIRECT\_FREE\_BLUE mas esse gol na realidade foi marcado como penâlti (aparentemente houve erro do árbitro da partida na sequência de comandos enviados).

Atualmente, as equipes selecionadas para análise, estão entre as melhores colocadas nas últimas edições, como pode ser observado nas tabelas 9 e 10.

A figura 32 apresenta a classificação final da edição 2019 da RoboCup.

### 7.2 ANÁLISE DOS REGISTROS HISTÓRICOS

Na SSL os objetos em campo são rastreados pelo sistema de visão da liga, o SSL-Vision transforma imagens de todas as câmeras em coordenadas transmitidas para as equipes (SMALL SIZE LEAGUE TECHNICAL COMMITTEE, 2009). Esse sistema de vi-

Tabela 8 – Partidas analisadas da RoboCup 2019 – Austrália

Jogo	Equipes	Cor	Resultado	Histórico	Jogada que originou gol	Horário
Grande Final 07/07/2019	ER-Force ZJUNlict	Yellow Blue	0 1		Arquivo de registro histórico incompleto.	
Upper Final 07/07/2019 08:40:03.759	ER-Force ZJUNlict	Yellow Blue	0 2	– Gol Blue(15)–1463 Gol Blue(15)–1524	INDIRECT_FREE_YELLOW(10)–1461 DIRECT_FREE_BLUE(9)–1522	– 08:59:01 09:16:53
Upper 2–1 06/07/2019 01:50:04.924	ER-Force TIGERS Mannheim	Yellow Blue	2 0	Gol Yellow(14)–243 <sup>1</sup> Gol Yellow(14)–274 –	DIRECT_FREE_BLUE(9)–241 DIRECT_FREE_YELLOW(8)–272 –	02:42:45 02:50:21 –
Upper 2–2 06/07/2019 03:21:44.824	MRL ZJUNlict	Yellow Blue	0 2	– Gol Blue(15)–367 Gol Blue(15)–422	INDIRECT_FREE_YELLOW(10)–363 NORMAL_START(2)–420	– 03:40:54 03:58:07
Upper Round 1–3 05/07/2019 09:57:03.857	MRL RoboDragons	Yellow Blue	1 0	Gol Yellow(14)–760 –	NORMAL_START(2)–758 –	11:06:04 –
Lower Final 07/07/2019 02:26:28.147	ER-Force MRL	Yellow Blue	1 0	Gol Yellow(14)–2680 –	NORMAL_START(2)–2678 –	03:06:52 –
Lower Round 1–1 06/07/2019 04:47:41.779	KIKS RoboDragons RoboDragons KIKS	Yellow Blue Yellow Blue	1 1 2 0	Gol Yellow(14)–598 Gol Blue(15)–615 Gol Yellow(14)–820 <sup>1</sup> Gol Yellow(14)–884 –	NORMAL_START(2)–595 NORMAL_START(2)–614 DIRECT_FREE_YELLOW(8)–819 NORMAL_START(2)–882 –	05:00:32 05:05:21 05:49:57 05:59:07 –
Lower Round 2–1 06/07/2019 09:57:03.857	RoboDragons TIGERS Mannheim	Yellow Blue	0 4	– Gol Blue(15)–1632 Gol Blue(15)–1655 <sup>2</sup> Gol Blue(15)–1661 <sup>2</sup> Gol Blue(15)–1735	– DIRECT_FREE_BLUE(9)–1630 NORMAL_START(2)–1653 NORMAL_START(2)–1659 INDIRECT_FREE_BLUE(11)–1733	– 10:05:06 10:13:32 10:14:22 10:24:58
Lower Round 3 07/07/2019 00:30:19.607	TIGERS Mannheim MRL	Yellow Blue	0 2	– Gol Blue(15)–2479 Gol Blue(15)–2489	– DIRECT_FREE_YELLOW(8)–2476 INDIRECT_FREE_BLUE(11)–2487	– 01:09:51 01:12:15
Group A1–A2 05/07/2019 04:29:33.688	TIGERS Mannheim MRL	Yellow Blue	3 1	Gol Yellow(14)–45 Gol Yellow(14)–78 Gol Yellow(14)–127 Gol Blue(15)–280	DIRECT_FREE_YELLOW(8) – 43 INDIRECT_FREE_YELLOW(10) – 76 NORMAL_START(2)–125 NORMAL_START(2)–276	04:45:59 04:52:14 05:05:57 05:57:04
Group B3–B4 05/07/2019 12:36:46.032	RoboTeam Twente RoboDragons	Yellow Blue	0 3	– Gol Blue(15)–1490 Gol Blue(15)–1511 Gol Blue(15)–1591	– NORMAL_START(2)–1488 INDIRECT_FREE_BLUE(11)–1506 INDIRECT_FREE_YELLOW(10)–1589	– 12:32:16 13:38:56 14:04:04
Group B1–B3 04/07/2019 23:04:02.090	ER-Force RoboDragons	Yellow Blue	1 0	Gol Yellow(14)–842 –	NORMAL_START(2)–838 –	23:20:00 –

<sup>1</sup> vídeo aponta gol de penalti. <sup>2</sup> vídeo indica gol com origem em saída de meio de campo (KICK\_OFF).

Fonte: Autor

são utiliza uma tecnologia de segmentação de cores conhecida como CMVision (BRUCE; BALCH; VELOSO, 2000).

O SSL-Vision coleta as informações de cada câmera, atualmente com suporte até oito câmeras, e as envia diretamente para cada equipe. As informações utilizam um protocolo próprio e não recebem nenhum tipo de tratamento pelo sistema de captura, cabe a cada equipe desenvolver seus algoritmos para tratamento, intercalação das câmeras e reconhecimento dos dados coletados. Por exemplo, o SSL-Vision pode enviar duas posições diferentes da bola em campo, de acordo com a leitura de cada câmera. As equipes interpretam esses dados conforme seus próprios critérios e a posição resultante da bola em campo pode ser calculada por métodos diferentes. Porém, esse envio sem tratamento em alguns casos pode ocasionar em erros de interpretação dos dados. Durante a reali-

Tabela 9 – Galeria da Fama da SSL.

Ranque	Time	País	1°	2°	3°	4°
1	<b>CMDragons CMUnited CM<math>\mu</math>s</b>	USA	5 (97,98,06,07,15)	6 (08,10,13,14,16,18)	–	–
2	<b>ZJUNlict</b>	China	4 (13,14,18,19)	1 (12)	3 (15,16,17)	2 (07,08)
3	Cornell Big Red*	USA	4 (99,00,02,03)	1 (05)	–	–
4	Skuba*	Tailândia	4 (09,10,11,12)	–	1 (08)	–
5	FU-Fighters*	Alemanha	2 (04,05)	3 (99,00,02)	1 (03)	1 (01)
6	<b>MRL</b>	Irã	1 (16)	1 (15)	4 (10,11,13,19)	–
7	Plasma-Z*	Tailândia	1 (08)	1 (07)	2 (06,09)	–
8	LuckyStar*	Singapura	1 (01)	–	4 (99,00,02,04)	–
9	SRC*	China	1 (17)	–	–	–
10	RoboRoos*	Austrália	–	3 (98,03,04)	–	–
11	<b>ER-Force</b>	Alemanha	–	2 (17,19)	–	2 (14,18)
12	RoboDragons	Japão	–	1 (09)	2 (07,14)	2 (13,16)
13	Field Rangers*	Singapura	–	1 (01)	1 (05)	1 (06)
14	5dpo*	Portugal	–	1 (06)	1 (98)	–
15	Naist*	Japão	–	1 (97)	–	–
16	Immortals	Irã	–	1 (11)	–	–
17	KIKS	Japão	–	–	1 (12)	2 (10,11)
18	<b>Tigers Mannheim</b>	Alemanha	–	–	1 (18)	1 (19)
19	CMRoboDragons*	Japão	–	–	–	2 (04,05)
19	Parsian	Irã	–	–	–	2 (12,17)
20	Cambridge*	USA	–	–	–	1 (98)
21	ODENS*	Japão	–	–	–	1 (09)
21	STOX's*	Colômbia	–	–	–	1 (15)

Fonte: Small Size League Technical Committee, 2019a – \* não participou da RoboCup em 2019.

zação de uma partida, esse tipo de erro pode passar despercebido pelas equipes devido a velocidade de transmissão com 60 frames por segundo, porém em registros históricos essa informação permanece e pode ocasionar em erros na análise dos dados.

Uma característica do SSL-Vision é envio contínuo das informações em conjunto com sistema SSL-Referee (BROWNING, 2010). É o SSL-Referee que envia os comandos com as ações para as equipes interpretarem.

Por exemplo o comando INDIRECT\_FREE\_YELLOW indica que a equipe amarela pode realizar uma cobrança indireta, ocasionado por alguma infração pela equipe azul. Uma cobrança indireta significa que a bola não pode ser chutada diretamente a gol. O comando DIRECT\_FREE\_BLUE indica que o time azul pode realizar uma cobrança com tentativa de chute direto a gol ou passe para outro robô da equipe. Como no futebol humano, existem comandos para várias situações. Por exemplo, para início de jogo ou au-

Tabela 10 – Galeria da Fama da SSL considerando as edições 2015–2019.

Ranque	Time	País	1	2	3	4
1	<b>ZJUNlict</b>	China	2 (18,19)	–	3 (15,16,17)	–
2	CMDragons* CMUnited Cm $\mu$ s	USA	1 (15)	2 (16,18)	–	–
3	<b>MRL</b>	Irã	1 (16)	1 (15)	1 (19)	–
4	<b>ER-Force</b>	Alemanha	–	2 (17,19)	–	1 (18)
5	SRC*	China	1 (17)	–	–	–
6	<b>Tigers Mannheim</b>	Alemanha	–	–	1 (18)	1 (19)
7	<b>RoboDragons</b>	Japão	–	–	–	1 (16)
8	Parsian	Irã	–	–	–	1 (17)
9	STOX's*	Colômbia	–	–	–	1 (15)

Fonte:Autor – \* não participaram da RoboCup em 2019

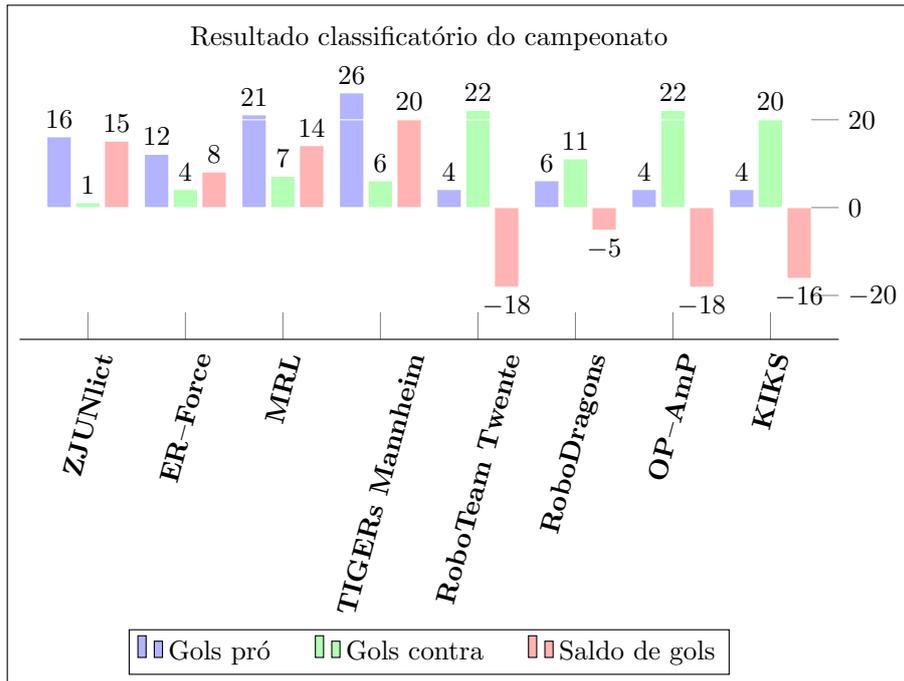
torização para cobrança de penalidade máxima é utilizado o comando `NORMAL_START`. Em caso de penalidade máxima o comando `NORMAL_START` é precedido do comando `PREPARE_PENALTY_YELLOW` ou `PREPARE_PENALTY_BLUE`.

O fluxograma das ações do SSL–Referee pode ser observada na figura 33. Para jogadas de bola parada, como `INDIRECT_KICK` ou `DIRECT_KICK` os comandos são precedidos do comando `STOP`. A partir do momento que o SSL–Referee envia o comando `INDIRECT_KICK_YELLOW`, por exemplo, a equipe amarela está autorizada a realizar a cobrança. Esse sistema é operado por um juiz humano e portanto com possíveis falhas de marcação, como os encontrados no jogo RoboDragons com ZJUNlict pela fase de grupos.

Porém não existe mudança de status dessa informação quando a equipe realiza um passe ou chute. O sistema entra no modo *running* e até que um novo comando seja enviado o sistema envia continuamente o último. Cabe a estratégia de cada equipe detectar quando o robô tocou na bola e a mesma deslocou-se por um determinado espaço para determinar o início do jogo. No sistema da RoboFEI é considerado bola em jogo, ou seja, a equipe adversária tocou na bola, quando a mesma se movimenta mais que um diâmetro de robô ( $\approx 18cm$ ), sendo adotada essa métrica nos experimentos.

Os arquivos dos registros históricos foram processados e separados a partir do início das jogadas que originaram gol. Cada arquivo foi processado a cada  $\approx 200$  milissegundos. O valor de 200 milissegundos foi escolhido para representar o jogo real, ou seja,

Figura 32 – Resultado geral da RoboCup 2019



Fonte: Autor

o tempo de processamento necessário para receber as informações das câmeras e aplicar a estratégia da equipe. As posições dos robôs e da bola em campo foram calculados pela média aritmética do processamento nesse intervalo de tempo e verificado a mediana para detectar discrepâncias nos registros. Esse intervalo de tempo foi agrupado e chamado de *instante* nos posicionamentos gerados.

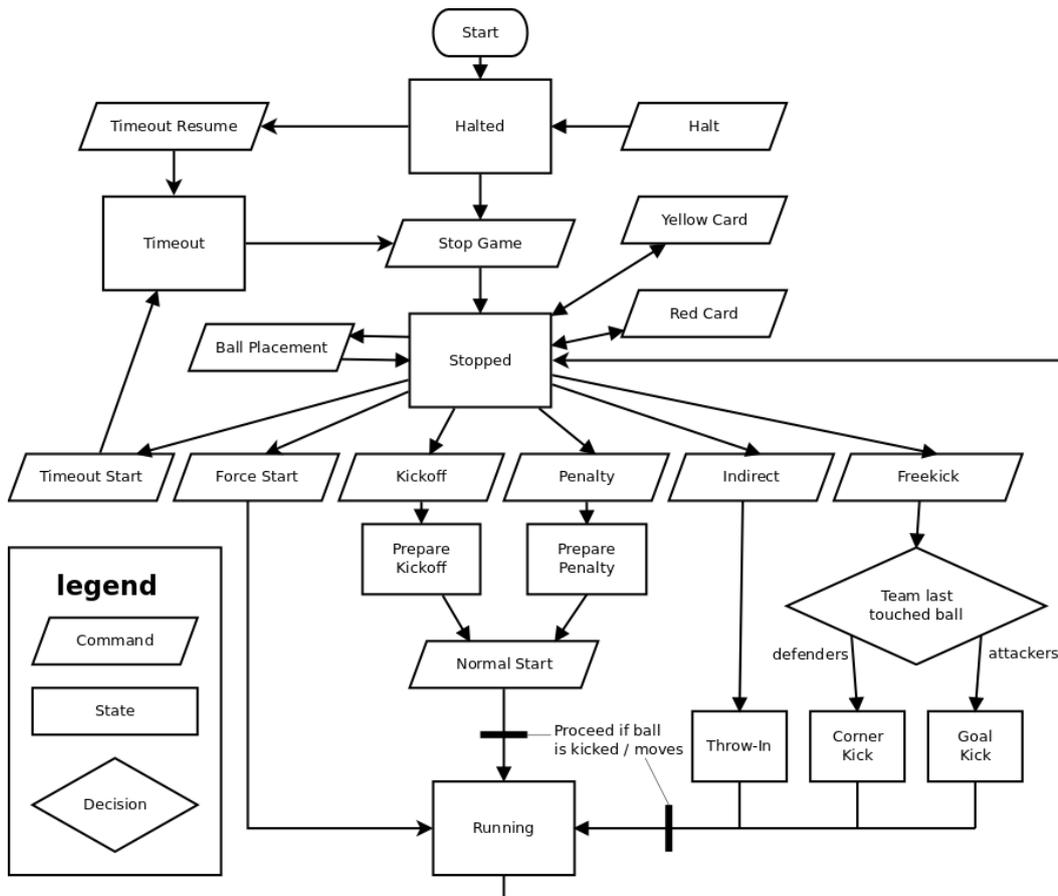
Esses instantes foram verificados para detectar o momento da movimentação da bola como forma de identificar o início da jogada realizada. Posteriormente, até o final da jogada (mudança de status do jogo), todos os posicionamentos foram calculados para verificar a situação atual (real em campo) e a situação otimizada.

Quando a bola encontra-se fora de campo, o programa para de executar os testes. Eventualmente, robôs que se encontravam fora de campo eram desconsiderados no processamento, ou seja não participam da jogada.

### 7.3 INFORMAÇÕES SOBRE A CONFIGURAÇÃO DOS EXPERIMENTOS

Para cada jogada foram gerados posicionamentos utilizando as funções de aptidão para formação de defesa e bloqueio de passe. Cada jogada foi otimizada em sua totalidade

Figura 33 – Fluxograma do SSL-Referee para envio dos comandos.



Fonte: Browning, 2010

100 vezes e uma foi escolhida aleatoriamente pela simulação para aplicação das métricas, as demais foram descartadas. Adotou-se essa escolha aleatória para não haver influência no resultado geral do trabalho após a aplicação das métricas. Na prática, a escolha do melhor ou pior cenário exigiria a aplicação das métricas em todos os cenários otimizados.

Cada jogada foi analisada em sua totalidade não havendo escolha de cenários. Para cada instante foi aplicado o posicionamento retornado pelo algoritmo. Em determinados instantes da mesma jogada o posicionamento pode ser o melhor caso possível em todas as demais simulações para mesmo instante, em outros o pior. Por exemplo, uma jogada composta de 100 instantes poderia no 1 instante ter um posicionamento ruim como resultado da otimização e no próximo ter um otimizado ótimo.

Nos posicionamentos otimizados, não são identificadas as posições individuais dos robôs. Cabe ao sistema de estratégia decidir qual robô deverá ir para cada posição otimizada e qual(is) robô(s) deveriam sair do posicionamento otimizado para atacar a bola. O conceito de atacar bola, utilizado neste trabalho, refere-se na escolha de um robô para

tentar a recuperação. Para simular o sistema de estratégia, foi realizado uma modificação no posicionamento retornado pelo PSO, que está sendo chamado de PSO modificado.

O PSO modificado consiste em alterar o posicionamento de um robô após a otimização. Essa modificação ocorre apenas para aplicação das métricas. Esse robô é escolhido para sair da posição otimizada e simular o ataque a bola. No bloqueio de gol, optou-se por escolher o robô mais próximo e no bloqueio de passes o robô mais distante da bola. O ataque a bola consiste na aproximação do robô a uma distância de  $20\text{cm}$ . Optou-se apenas pela aproximação para indicar nas métricas que existe a probabilidade de combate ao robô portador da bola. Nas imagens que mostram os posicionamentos otimizados esse ataque a bola não é apresentado.

Para otimizar os posicionamentos, a população é gerada aleatoriamente e acrescida do posicionamento da defesa original em campo e o último otimizado pelo PSO. Cada partícula da população representa uma solução de posicionamento. Para definir a quantidade de robôs que fazem parte da partícula adotou-se o mesmo número de defensores em campo no momento da jogada. Eventualmente algum robô poderia estar suspenso por penalidade ou estava fora de campo.

O goleiro da equipe não é considerado como membro da partícula para otimização do posicionamento, visto que o goleiro tem suas ações de posicionamento e regras no jogo a parte. Nas otimizações e análises, foi considerado a posição original do goleiro.

Cabe ao sistema de estratégia a escolha dos adversários como parâmetro de entrada para as funções de aptidão. Nas otimizações foram considerados todos os adversários em campo, incluindo os que não participavam ativamente da jogada. O goleiro adversário é desconsiderado.

As otimizações de defesa de gol e bloqueio de passe foram realizadas separadamente. Não houve troca das funções de aptidão durante o decorrer da jogada. Os parâmetros de configuração do algoritmo foram os apresentados no capítulo 6:  $\omega = 0.7298$ ,  $c_1 = c_2 = 2$ , 100 indivíduos na população do enxame (98 distribuídos aleatoriamente, o último posicionamento otimizado pelo algoritmo e, finalmente, a última partícula é composta do posicionamento original em campo), 300 iterações e topologia de vizinhança global. O espaço de busca foi definido como  $1200 (D_{maxX}) \times 900 (D_{maxY})$ . Para compor a partícula, cada robô é definido com posição dado por  $x = rand(0, D_{maxX})$  e  $y = rand(0, D_{maxY})$  e velocidade  $vx = 1, vy = 1$ .

Para validar os posicionamentos, foram realizados vários testes com as métricas apresentadas no capítulo 4:

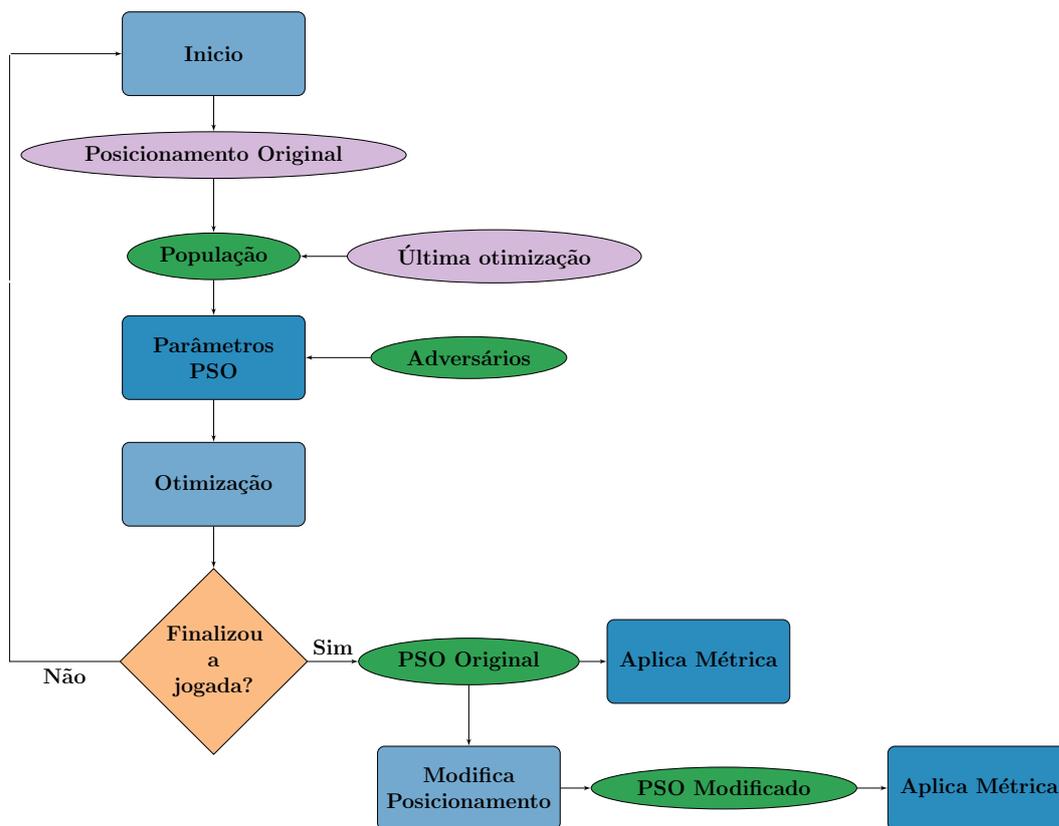
- a) Para cada jogo original foram criados arquivos de métricas para analisar defesa, passe e o conjunto das duas situações simultâneas;
- b) Para o posicionamento de defesa encontrado pelo PSO, foram feitas as seguintes avaliações com métricas:
  - Posicionamento Defesa – analisado com métrica de defesa e confrontado com o original;
  - Posicionamento Defesa – analisado com métrica de passe e comparado com a original - teste realizado para verificar a possibilidade da defesa atuar como bloqueio de passe;
  - Posicionamento Defesa – analisado com métricas de defesa e passe em conjunto e comparado com a métrica do conjunto original;
- c) Para o posicionamento de bloqueio de passe encontrado pelo PSO, foram feitas as seguintes avaliações com métricas:
  - Posicionamento Passe - analisado com métrica de passe e confrontado com a métrica original;
  - Posicionamento Passe – analisado com métrica de defesa e comparado com a defesa original – experimento realizado para verificar se o posicionamento de bloqueio de passe atuaria como defesa;
  - Posicionamento Passe – analisado com métricas de defesa e passe em conjunto e comparado com a métrica do conjunto original;

A figura 34 ilustra a sequência de passos para realização dos experimentos e análises com as métricas.

#### 7.4 RESULTADOS CONSOLIDADOS

Para as otimizações foram aplicadas as equações de bloqueio de gol e bloqueio de passes. Os resultados finais para análise do bloqueio de gol estão nas figuras 35 e 36. A figura 35 apresenta as médias para cada variável avaliada, ao menos em uma das variáveis houve melhora com o posicionamento otimizado. A figura 36 demonstra que o posicionamento otimizado sempre foi superior em algum momento.

Figura 34 – Fluxograma da sequência de experimentos.



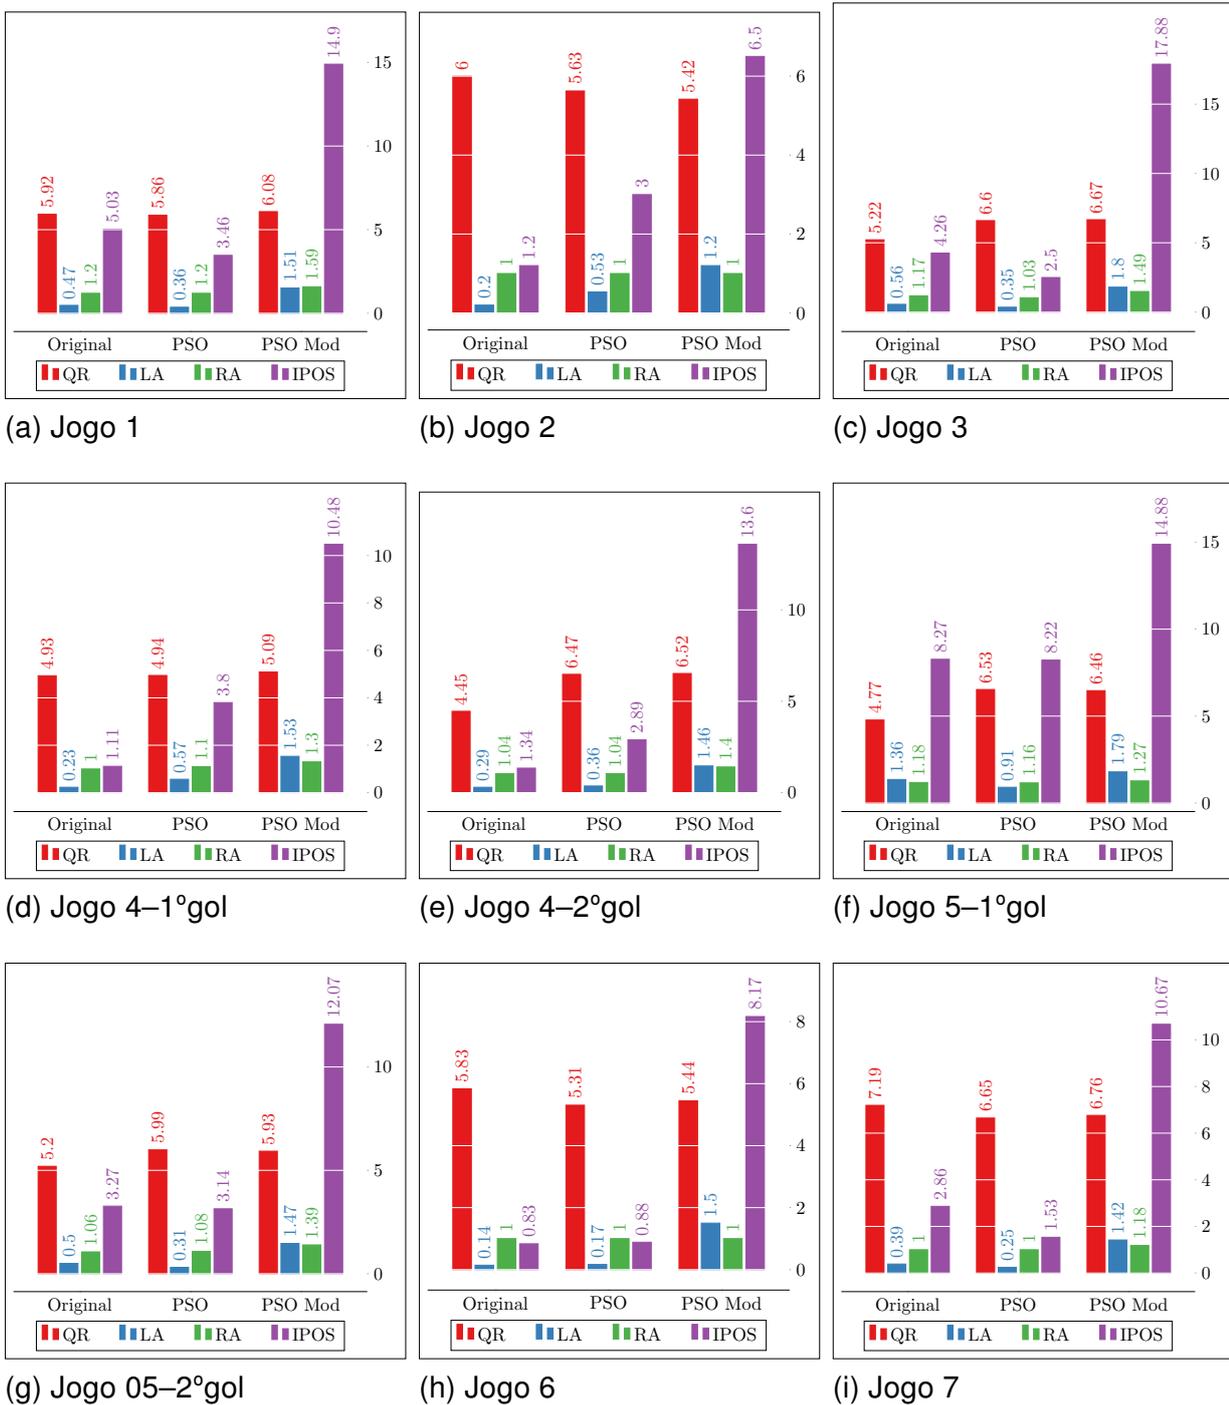
Fonte: Autor

Na figura 35, a variável QR analisa possíveis situações em campo, como possível bloqueio de avanço, interceptação de bola, área de atuação e superioridade numérica; a variável LA analisa se a equipe tinha a possibilidade de tocar a bola; A variável RA analisa duas possibilidades do jogo: se na mudança de direção da bola, haveria algum robô para interceptar a mesma e se os adversários tem espaço para atuação; a variável IPOS é a avaliação final da jogada

A figura 36 aponta que os posicionamentos otimizados foram superiores aos originais na sua totalidade. Em alguns momentos o posicionamento otimizado foi inferior ao original (como na figura 35a) mas o sistema de estratégia fez a escolha adequada do robô para combater o adversário portador da bola e o posicionamento foi mais efetivo. Em outros jogos (figuras 35f e 35g) a escolha do robô para combater o adversário portador da bola diminui a efetividade do posicionamento otimizado.

Os resultados finais para análise do bloqueio de passes estão nas figuras 37 e 38. A figura 37 apresenta as médias para cada variável avaliada, ao menos em uma das variáveis houve melhora com o posicionamento otimizado. A figura 38 demonstra

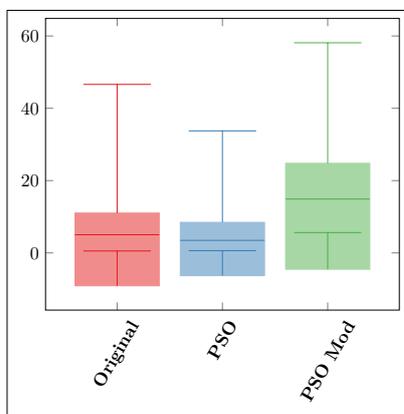
Figura 35 – Análise da defesa – todas as dimensões.



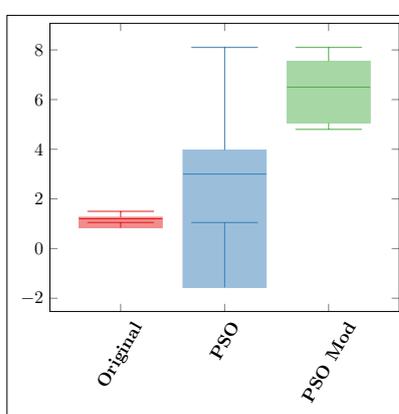
Fonte: Autor

que o posicionamento otimizado sempre foi superior em algum momento. A figura 38 demonstra que os posicionamentos otimizados foram superiores aos originais no bloqueio de passes. Em algumas situações o posicionamento original foi superior ao otimizado pelo PSO, porém o sistema de estratégia ao escolher robô defensor para combater o adversário corrigiu o posicionamento.

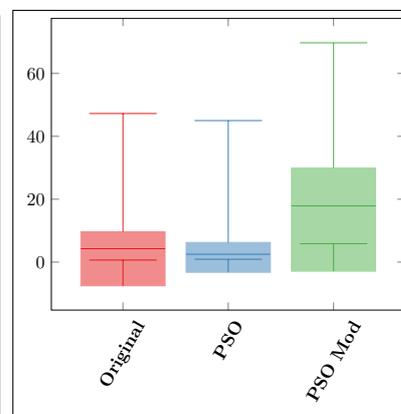
Figura 36 – Defesa gol – Comparação entre os gols analisados.



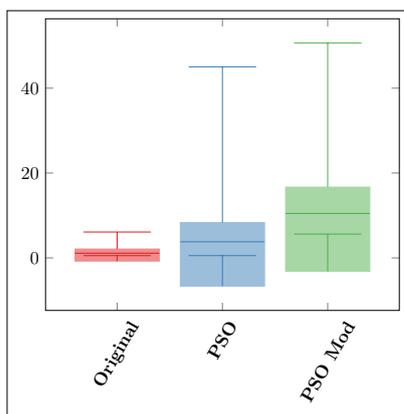
(a) Jogo 1



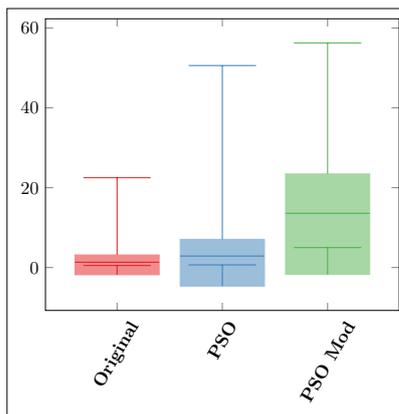
(b) Jogo 2



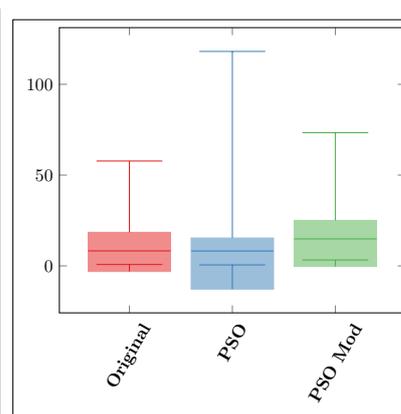
(c) Jogo 3



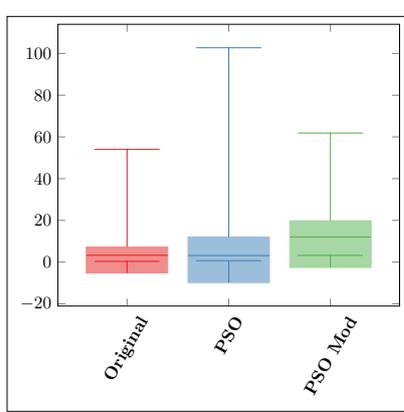
(d) Jogo 4–1ºgol



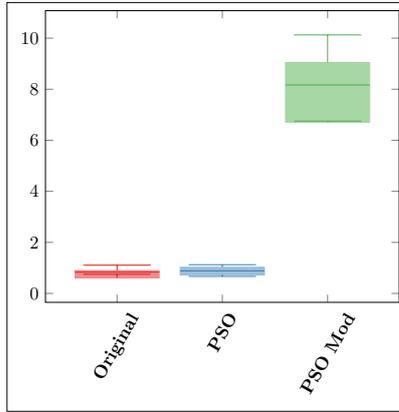
(e) Jogo 4–2ºgol



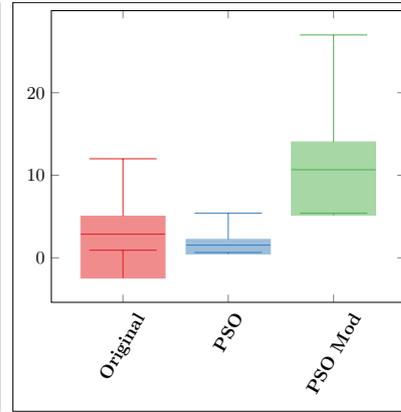
(f) Jogo 5–1ºgol



(g) Jogo 5–2ºgol



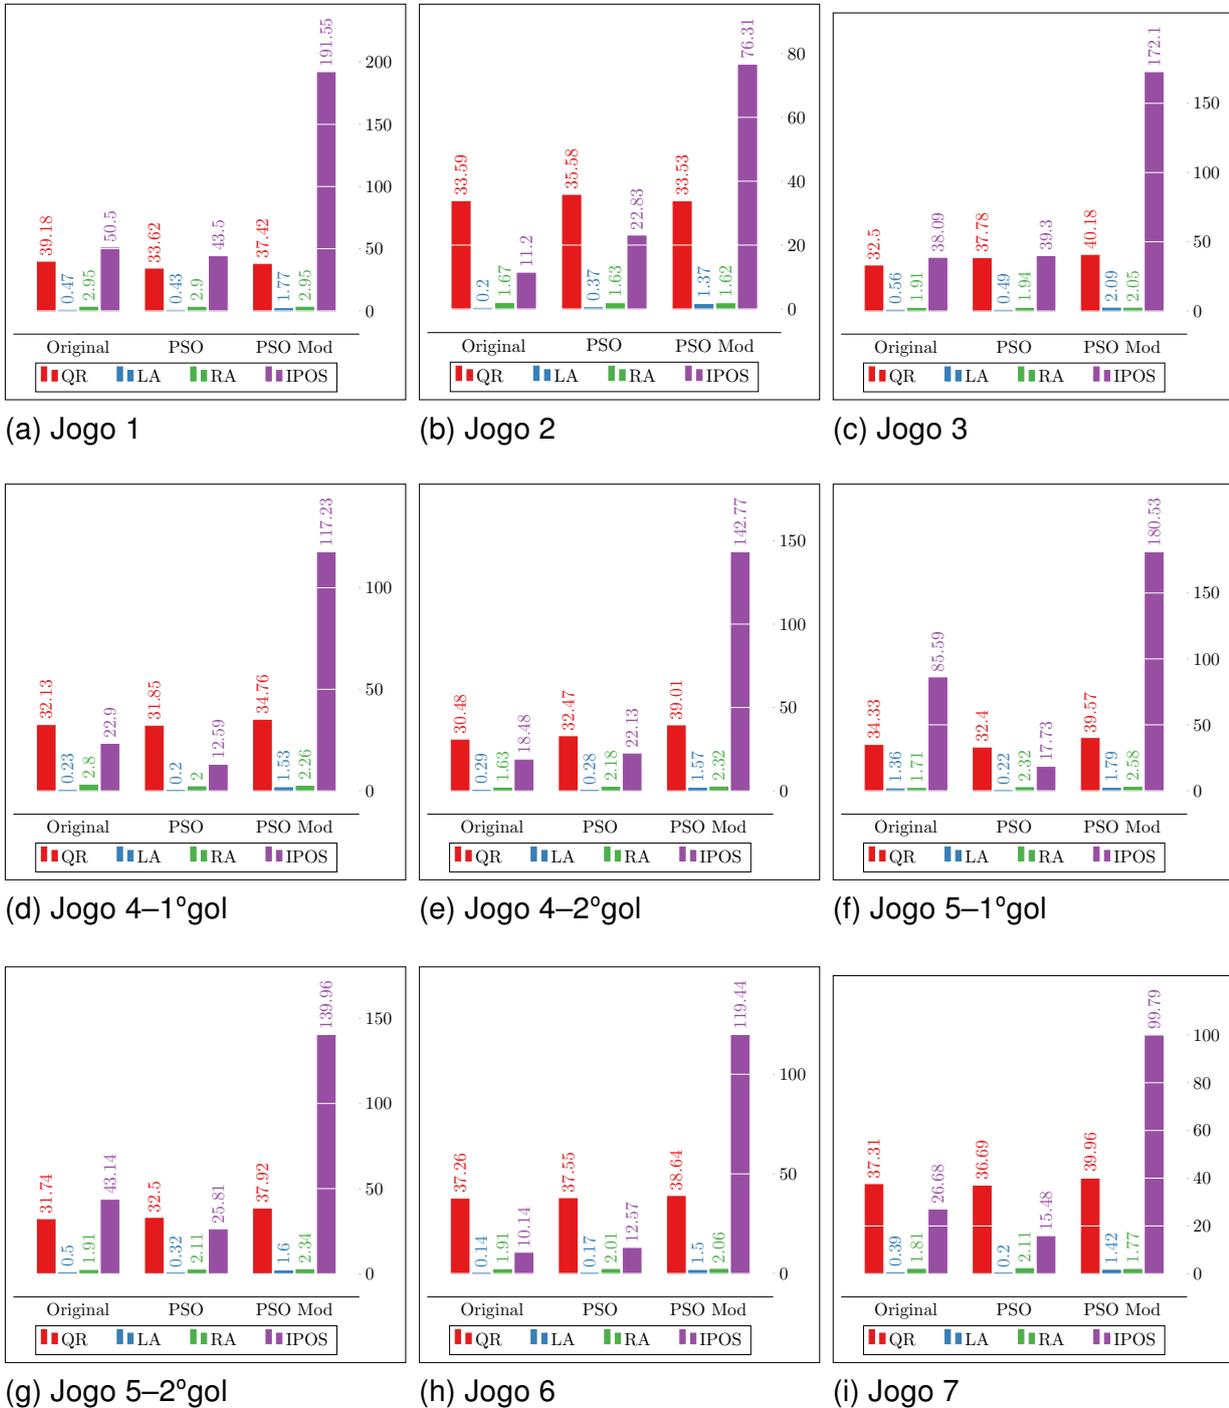
(h) Jogo 6



(i) Jogo 7

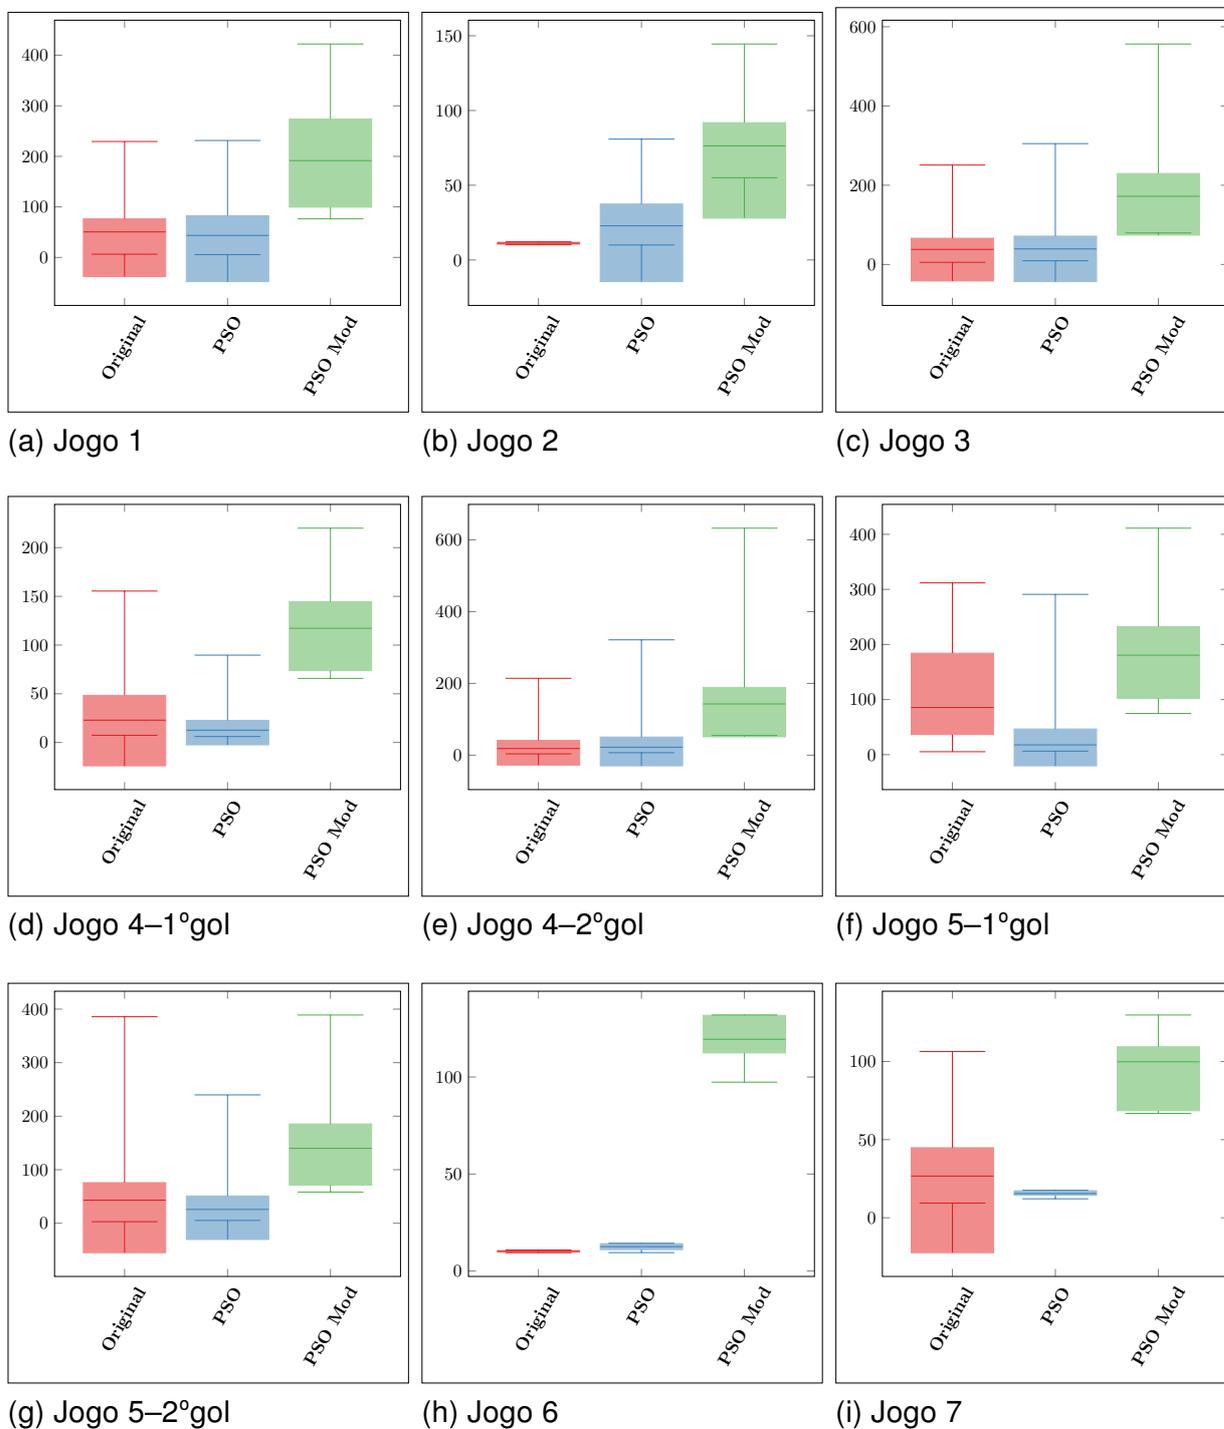
Fonte: Autor

Figura 37 – Análise da defesa – todas as dimensões.



Fonte: Autor

Figura 38 – Bloqueio de passe – Comparação entre os gols analisados



Fonte: Autor

## 7.5 JOGO 01 – UPPER FINAL

Jogo realizado na fase semifinal entre as equipes ER-Force (equipe amarela) e ZJUNlict (equipe azul). A jogada total, após tratamento do registro histórico, é composta de 41 instantes. O placar do jogo foi  $2x0$  para o time azul considerado atacante nesta partida. O gol analisado teve como origem uma jogada de bola parada (DIRECT\_FREE\_BLUE).

A análise dos jogos dessas equipes evidenciam suas características. Atualmente consideradas as melhores da liga A da SSL. A grande final foi realizada entre essas equipes, porém a jogada que originou o gol da final não estava disponível no registro histórico e não pôde ser analisada.

A equipe ER-Force tem como característica um forte posicionamento defensivo. A equipe sofreu apenas 4 gols durante todo o campeonato com a ZJUNlict marcando 3 gols em 3 jogos realizados.

Um diferencial significativo da ZJUNlict é o controle de bola devido ao desempenho mecânico do seu *roller* que permite rotacionar o robô sobre seu próprio eixo em alta velocidade sem perder a posse da bola. Esse controle permite que a equipe ZJUNlict consiga criar várias possibilidades de jogadas aproveitando-se de uma característica comum das demais equipes: considerar a posição da bola em suas estratégias como fator de decisão para o posicionamento dos robôs em campo.

### 7.5.1 Análise da defesa

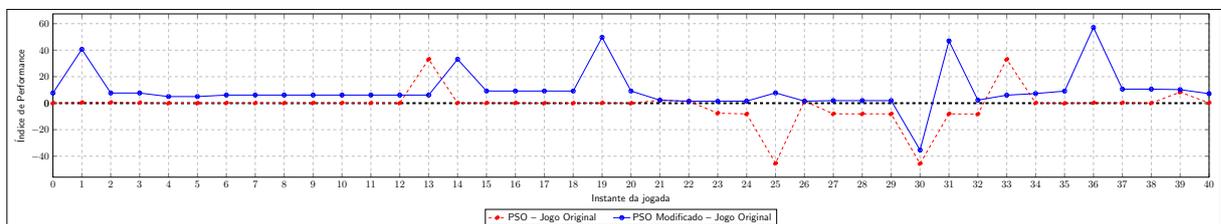
Para esse experimento, o posicionamento adversário a cada instante foi informado ao algoritmo PSO. O PSO otimizou o posicionamento defensivo utilizando a função de aptidão da defesa. Posteriormente, o posicionamento foi modificado para um robô simular o ataque a bola. Finalmente, todos os posicionamentos (defesa original, otimizado pelo PSO e otimizado com a modificação para atacar a bola) foram analisados com a métrica de defesa proposta no capítulo 4. O goleiro será considerado o da jogada original e não é alterado ou afetado pelo sistema de posicionamento, visto que o goleiro tem suas ações de posicionamento e regras no jogo distintos dos demais.

A figura 39 apresenta a comparação da aplicação da métrica de defesa entre o posicionamento original e o posicionamento otimizado. A linha em vermelho na figura 39 indica o Índice de Performance do Posicionamento (IPOS) do posicionamento otimizado

pelo PSO a cada instante da jogada e comparada com o IPOS da equipe analisada. A linha em azul indica o IPOS do posicionamento otimizado após a modificação para simular o ataque a bola e posteriormente é comparado com o IPOS da equipe analisada.

Pontos positivos ao longo do gráfico indicam que o posicionamento otimizado ou modificado foram superiores ao posicionamento original da equipe analisada. Pontos negativos indicam que o posicionamento retornado pelo PSO foi inferior aos da equipe analisada. Esses pontos são calculados a partir da aplicação das métricas de avaliação adaptadas do FUT-SAT (capítulo 4).

Figura 39 – Jogo 01 – Comparação jogo original com otimização – PSO em modo defesa.



Fonte: Autor

As figuras 40 e 41 apresentam vários momentos da jogada. Nessa figura, está sendo apresentando apenas o posicionamento otimizado sem a modificação de ataque a bola. Os times azul e amarelo estão representados em suas posições originais. O jogadores em vermelho são os posicionamentos encontrados pelo PSO para cada momento do jogo. As linhas tracejadas indicam a direção do movimento de jogadores que participam ativamente da jogada e da bola.

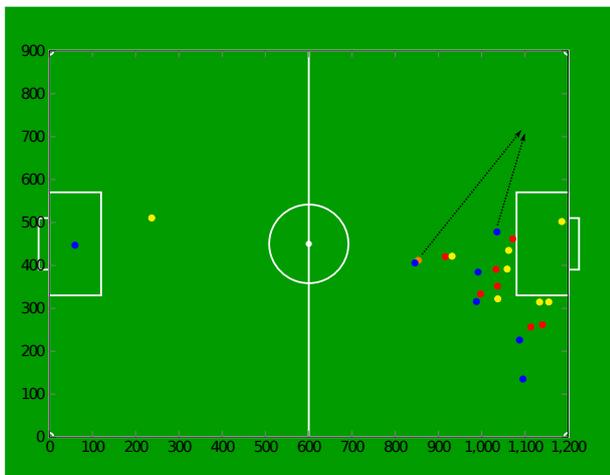
Na figura 39 em dois momentos (instante 25 e 30) ocorre uma piora do resultado da avaliação da métrica de defesa. Essa piora está representada nas figuras 40c, 40d e 41a.

Na figura 40c a defesa original consegue obter a posse de bola momentaneamente, o que na métrica de defesa tem um alto valor pelo fato do robô estar em contato com a bola, o mesmo não ocorre com os posicionamentos retornados pelo PSO, pois o mesmo só prevê a aproximação da bola cabendo ao sistema de estratégia decidir como realizar o ataque a bola.

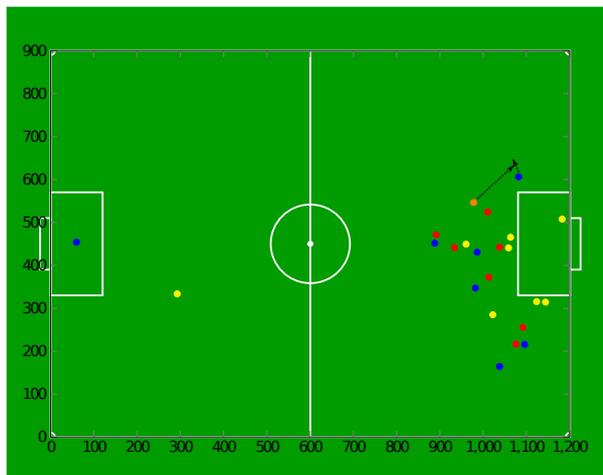
Nas figuras 40d e 41a o time azul recua seu jogadores. Esse recuo pode estar relacionado a 2 motivos: no momento que o time amarelo toca a bola e equipe adversária volta para marcar o único atacante próximo a área de gol da equipe azul ou pelo fato do sistema de visão ter informado que a bola estava no meio do campo. Como consequência,

Figura 40 – Jogo 01 – Jogada de gol – PSO em modo defesa

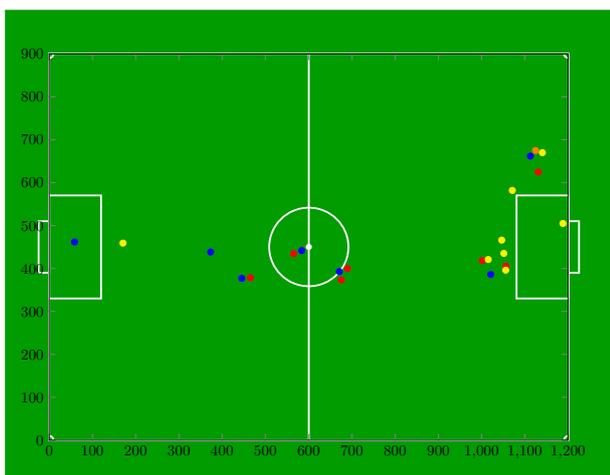
(a) Momento do início da jogada



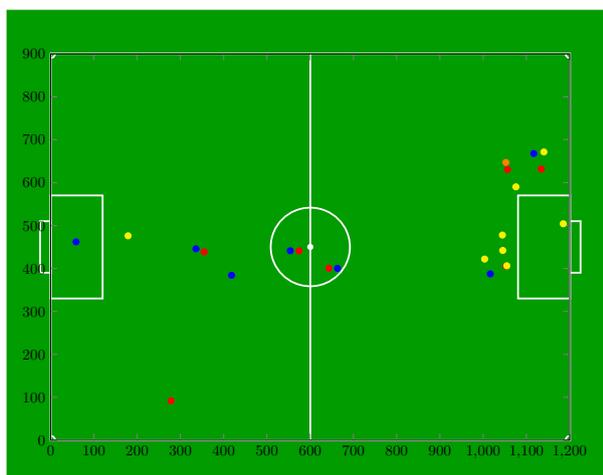
(b) Sequência da jogada



(c) Defesa perde o controle da bola



(d) Time azul recua para campo de defesa



Fonte: Autor

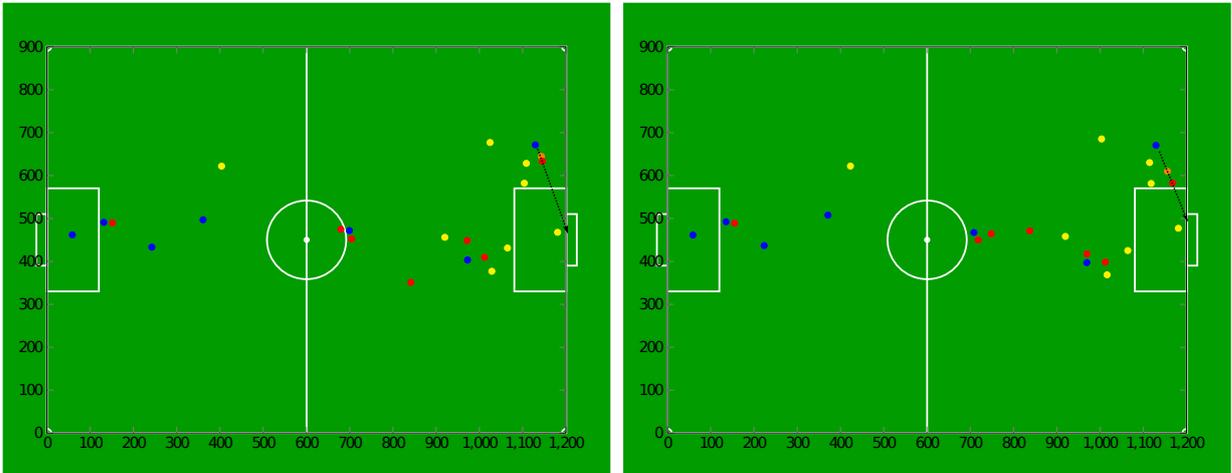
a função de aptidão da defesa, avançou os jogadores para acompanhar a equipe azul. Esse posicionamento visa diminuir o espaço dos jogadores adversários. Originalmente o time amarelo concentrou-se em formar uma linha de defesa a frente do gol, diminuindo o espaço de visão do gol pelos adversários. Esse bloqueio de visão, em teoria, deveria impedir a realização de gols a distância e portanto na métrica de defesa a posição original tem alto peso.

Contudo, nas figuras 41a e 41b fica claro que o posicionamento teria impedido a realização do gol. Como pode ser observado na figura 39, antes da finalização da jogada, os posicionamentos encontrados pelo PSO já poderiam ter impedido a continuação da mesma visto que o posicionamento encontrado é superior ao original.

Figura 41 – Jogo 01 – Jogada de gol (continuação) – PSO em modo defesa

(a) Time azul chuta a gol

(b) Bola indo em direção ao gol

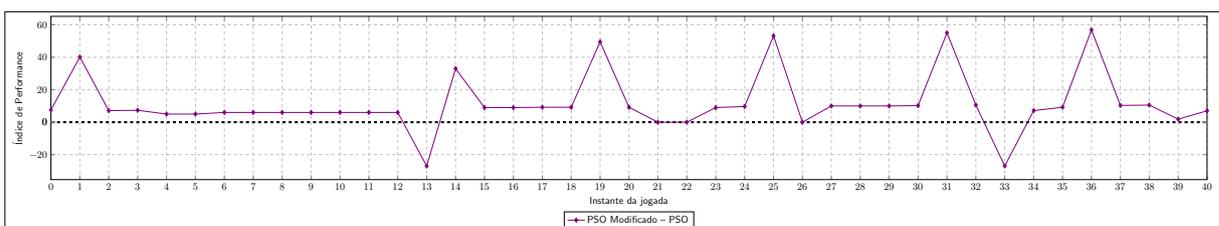


Fonte: Autor

A figura 42 apresenta diferença entre o posicionamento otimizado original e o posicionamento modificado. O posicionamento modificado simula o ataque a bola. A figura ressalta a importância do sistema de estratégia decidir como o posicionamento será adotado em campo, principalmente na questão de decidir qual robô atacará a bola. Essa melhora pode ser observada pela linha azul superior a linha vermelha (figura 39 ).

O instante 13 na figura 42 evidencia que a escolha da robô para realizar o ataque a bola foi inadequada. Porém cabe ao sistema de estratégia decidir qual robô deveria sair do posicionamento retornado pelo PSO para atacar a bola. Nesse caso, foi escolhido o robô mais próximo da bola o que ocasionou uma piora na avaliação das métrica por ocasionar brechas na defesa que são avaliadas negativamente pela métrica.

Figura 42 – Jogo 01 – Comparação da otimização original com a modificada – PSO em modo defesa.

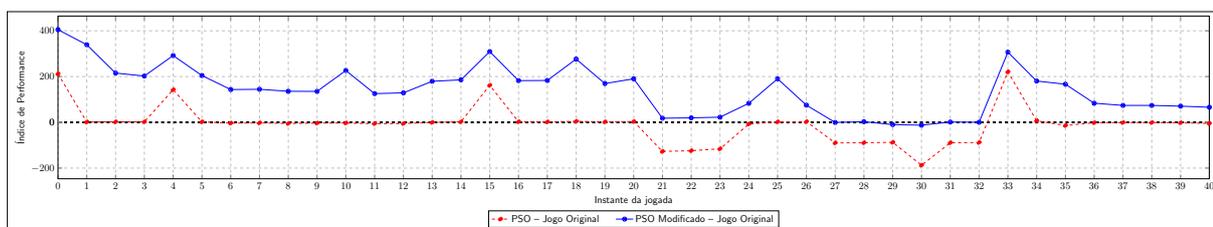


Fonte: Autor

## 7.5.2 Análise do passe

Para esse experimento, o posicionamento adversário a cada instante foi informado ao algoritmo PSO. O PSO otimizou o posicionamento defensivo utilizando a função de aptidão de bloqueio de passe. Posteriormente, o posicionamento foi modificado para um robô simular o ataque a bola. Finalmente, todos os posicionamentos (original, otimizado pelo PSO e otimizado com a modificação para atacar a bola) foram analisados com a métrica de bloqueio de passe proposta no capítulo 4. O goleiro será considerado o da jogada original e não é alterado ou afetado pelo sistema de posicionamento, visto que o goleiro tem suas ações de posicionamento e regras no jogo distintos dos demais.

Figura 43 – Jogo 01 – Comparação jogo original com otimização – PSO em modo passe.



Fonte: Autor

A figura 43 apresenta a comparação da aplicação da métrica de passe entre o posicionamento original e o posicionamento otimizado. A linha em vermelho na figura 43 indica o IPOS do posicionamento otimizado pelo PSO a cada instante da jogada. A linha em azul indica o IPOS após o posicionamento otimizado ser modificado para simular o ataque a bola.

As figuras 45 e 46 apresentam vários momentos da jogada. Os times azul e amarelo estão representados em suas posições originais. O jogadores em vermelho são os posicionamentos encontrados pelo PSO para cada momento jogo. Inicialmente, as figuras 45a e 45b apresentam um posicionamento otimizado mais próximo da bola, a fim de dificultar o domínio e controle pela equipe adversária. As linhas tracejadas indicam a direção do movimento de jogadores que participam ativamente da jogada e da bola.

A figura 43 demonstra que o posicionamento encontrado pelo PSO desde o início impossibilitaria a continuidade da jogada pela equipe adversária. Os pontos negativos no gráfico compreendidos entre os instantes 27 até 32 ocorreram, principalmente, por uma falha da posição da bola no arquivo do registro histórico (evidenciado na figura 45d). O

gráfico da figura 44 apresenta diferença entre o posicionamento otimizado original e o posicionamento modificado. O posicionamento modificado simula o ataque a bola. A figura ressalta a importância do sistema de estratégia decidir como o posicionamento será adotado em campo, principalmente na questão de decidir qual robô atacará a bola. Nas figuras 46a e 46b pode ser observado o posicionamento otimizado do bloqueio de passe atuado defensivamente.

Figura 44 – Jogo 01 – Comparação da otimização original com a modificada – PSO em modo passe.



Fonte: Autor

A figura 47 que analisa a Qualidade de Realização da Ação Tática (QR), mostra que o posicionamento otimizado, no início da jogada, é superior ao modificado. A piora no posicionamento modificado ocorre pela escolha do robô que foi utilizado para atacar a bola, nesse caso o robô escolhido deixou de atuar adequadamente. O desempenho inferior nessa métrica, em relação ao posicionamento original está relacionado com linha defensiva utilizada pela equipe amarela, que bloqueia a visão do gol. Os posicionamentos otimizados estavam atuando no bloqueio dos jogadores adversários para dificultar o passe.

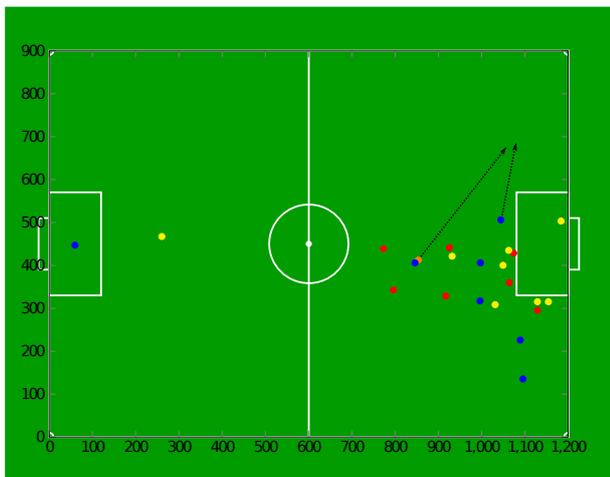
Tanto que ao analisar a Localização da Realização da Ação Tática no Campo de Jogo (LA) (figura 48), e a Resultado da Ação Tática (RA) (figura 49) observa-se que o desempenho do posicionamento otimizado foi superior ao original. Essa melhora reflete a possibilidade do posicionamento atuar para o bloqueio do passe.

### 7.5.3 Análise defesa – métrica do passe

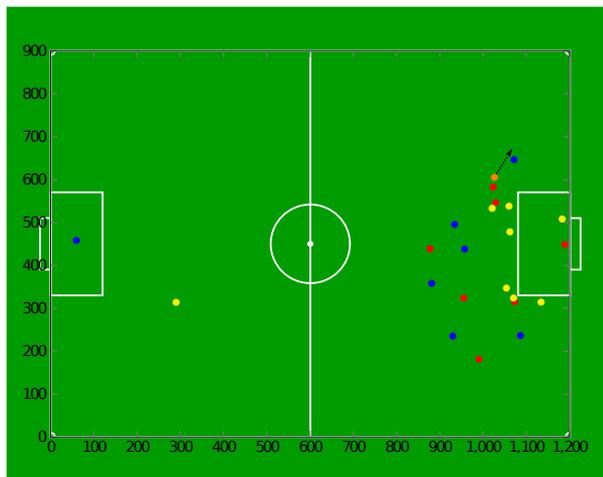
A análise do posicionamento defensivo com a métrica de avaliação de bloqueio de passe visa determinar se os posicionamentos encontrados poderiam ser aplicados como estratégia de bloqueio de passes. O PSO otimizou os posicionamentos com a função de aptidão de defesa. Finalmente, todos os posicionamentos foram analisados com a métrica de bloqueio de passes proposta no capítulo 4.

Figura 45 – Jogo 01 – Jogada de gol – PSO em modo passe.

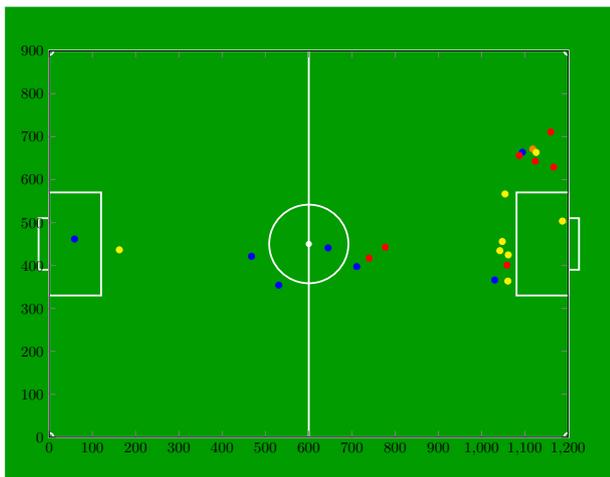
(a) Momento do início da jogada



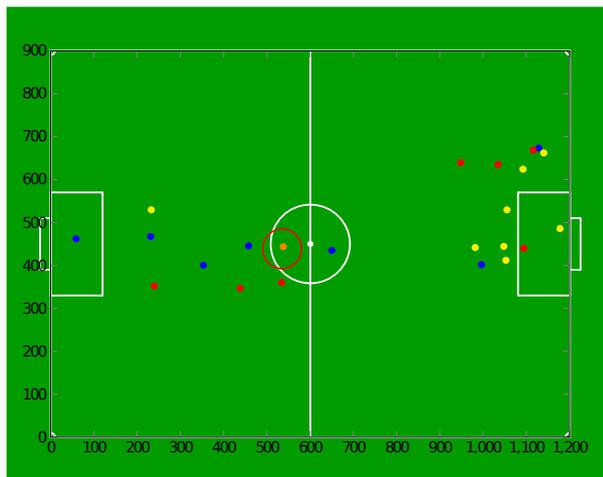
(b) Sequência da jogada



(c) Defesa perde o controle da bola



(d) Posição da bola errada no arquivo.



Fonte: Autor

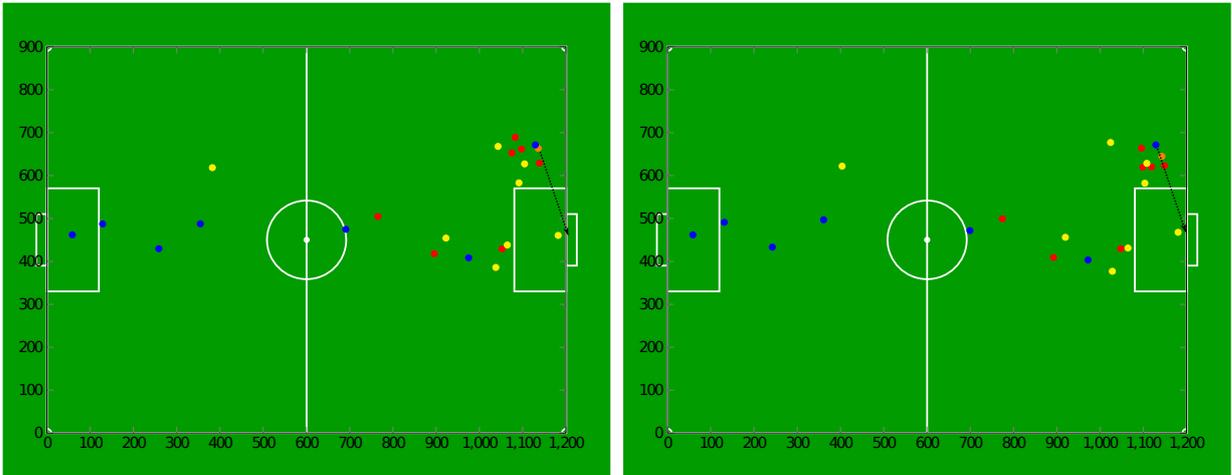
Na figura 50 pode ser observado que o posicionamento defensivo teria forte atuação como alternativa para bloqueio de passe. Porém o principal diferencial entre o resultado está relacionado com o baixo desempenho, representado pela linha vermelha, da otimização original retornada pelo PSO. Após a modificação do posicionamento para simular o ataque a bola, representando pela linha azul, o posicionamento defensivo tornou-se eficiente. Essa diferença pode ser observada na figura 44 que apresenta o resultado da avaliação da função de aptidão do passe pela métrica do passe.

Um dos critérios da métrica que avalia o passe é verificar o espaço deixado para a equipe adversária locomover-se em campo, atrelado aos princípios táticos defensivos (capítulo 2) como contenção, equilíbrio em campo e concentração. Na função de aptidão

Figura 46 – Jogo 01 – Jogada de gol (continuação) – PSO em modo passe.

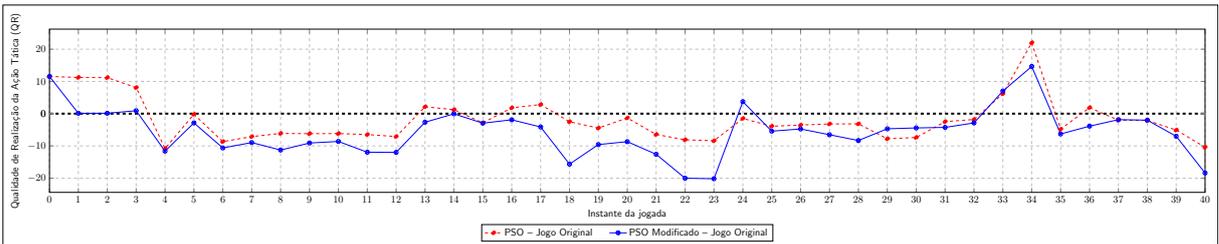
(a) Time azul chuta a gol

(b) Bola indo em direção ao gol



Fonte: Autor

Figura 47 – Jogo 01 – Análise da qualidade do posicionamento (QR)– PSO em modo passe.



Fonte: Autor

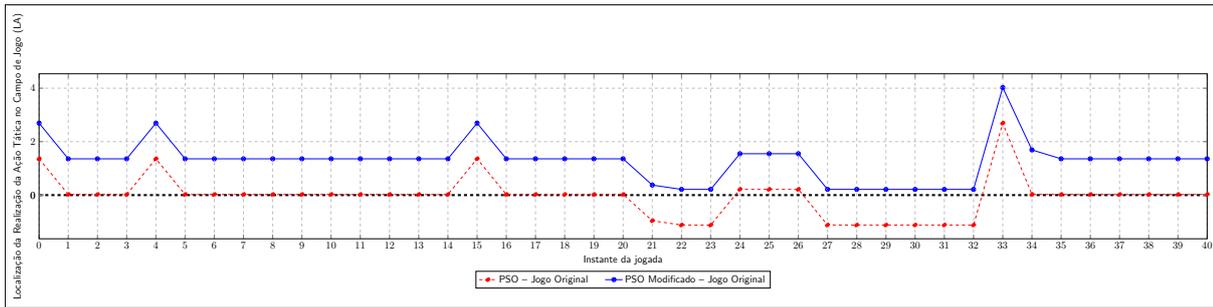
da defesa não estão previstas essas regras, portanto o posicionamento encontrado não atende a todos os critérios impostos pelas métricas de avaliação do passe.

### 7.5.4 Análise passe – métrica da defesa

A análise do posicionamento de bloqueio de passes com a métrica de avaliação de defesa visa determinar se os posicionamentos encontrados poderiam ser aplicados como estratégia de defesa. O PSO otimizou os posicionamentos com a função de aptidão de bloqueio de passes. Finalmente, todos os posicionamento foram analisados com a métrica de defesa.

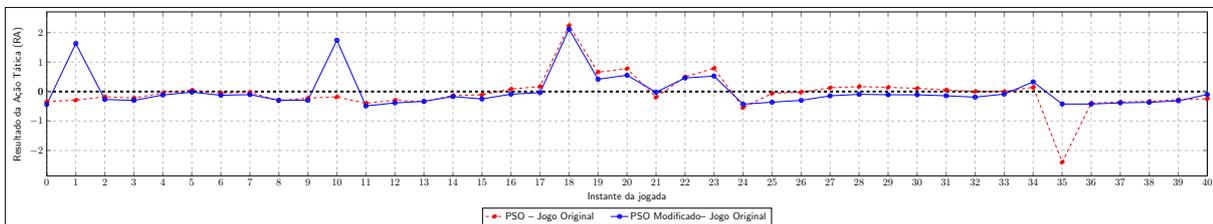
Na figura 51 pode ser observado que o posicionamento de bloqueio de passe, para essa jogada, não teria atuado adequadamente como estratégia de defesa.

Figura 48 – Jogo 01 – Análise da localização em campo (LA) – PSO em modo passe.



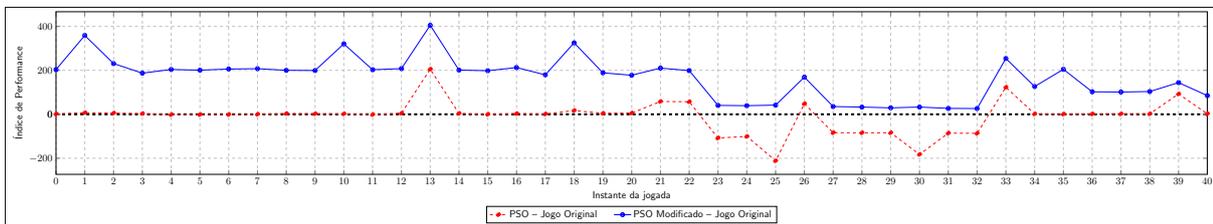
Fonte: Autor

Figura 49 – Jogo 01 – Análise do resultado da ação (RA) – PSO em modo passe.



Fonte: Autor

Figura 50 – Jogo 01 – Posicionamento de defesa avaliada com métrica do passe – PSO em modo defesa.



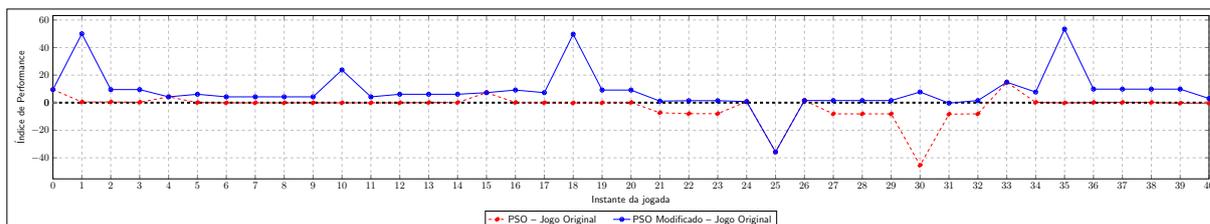
Fonte: Autor

Esse resultado está relacionado com os objetivos conflitantes entre as funções de defesa e passe. Enquanto o passe visa diminuir espaço de jogo, atendendo também alguns critérios defensivos a defesa visa bloquear o acesso total ao gol. Nessa comparação, o posicionamento defensivo da equipe ER-Force foi mais eficiente de acordo as métricas defensivas.

### 7.5.5 Análise conjunta das métricas – passe e defesa

Para esse experimento, o posicionamento adversário a cada instante foi informado ao algoritmo PSO. O PSO otimizou o posicionamento defensivo utilizando as funções de

Figura 51 – Jogo 01 – Posicionamento de passe avaliada com métrica da defesa – PSO em modo passe.



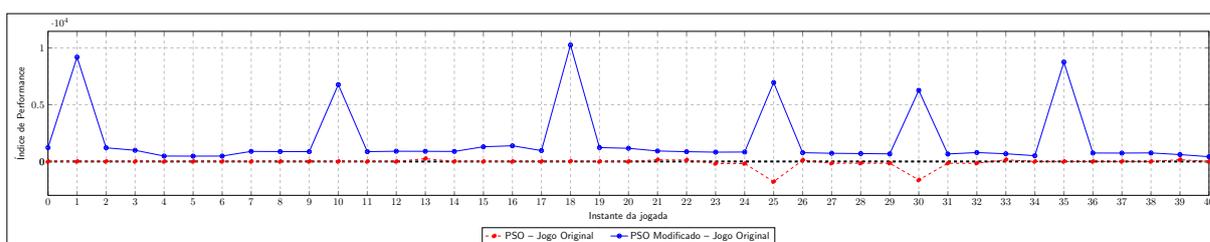
Fonte: Autor

aptidão para defesa e bloqueio de passes. Posteriormente, o posicionamento foi modificado para um robô simular ataque a bola. Finalmente, todos os posicionamentos foram analisados com a métrica de defesa em conjunto com a métrica de passe.

Para esses experimentos, os posicionamentos da defesa e passe foram comparados em conjunto com as métricas de defesa e passe para cálculo do IPOS geral de cada instante. O resultado inferior dessa análise, embora ainda positivo ao ser analisado a linha azul do gráfico, foi ocasionado pelo forte posicionamento defensivo da equipe ER–Force, que nas análises anteriores já obteve melhores índices da avaliação nesse quesito.

As figuras 52 e 53 evidenciam o resultado dos posicionamentos otimizados.

Figura 52 – Jogo 01 – Métrica de defesa e passe aplicada em conjunto – PSO em modo defesa.

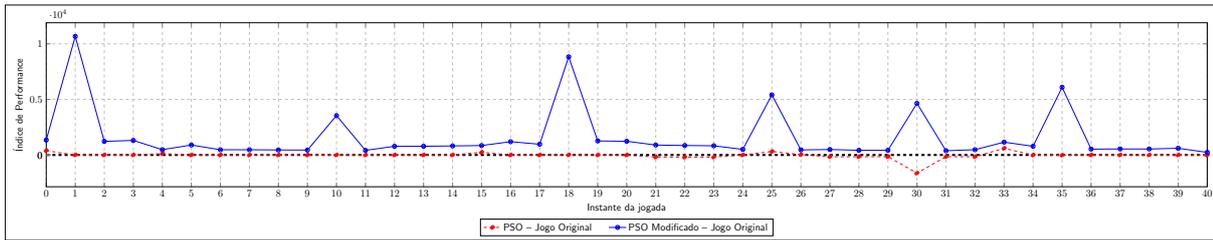


Fonte: Autor

## 7.5.6 Discussão e análises

A análise dessa jogada em particular evidenciou o forte esquema tático adotado pela equipe ER–Force. Nesse jogo, a equipe perdeu por 2x0. A jogada analisada foi o primeiro gol marcado. Na verificação do segundo gol, e demais situações de jogo após o primeiro gol, ficou evidente que a equipe ER–Force modificou sua estratégia para posicionar-se frontalmente a equipe ZJUNlict na tentativa de diminuir a vantagem competitiva do *roller*

Figura 53 – Jogo 01 – Métrica de defesa e passe aplicada em conjunto – PSO em modo passe.

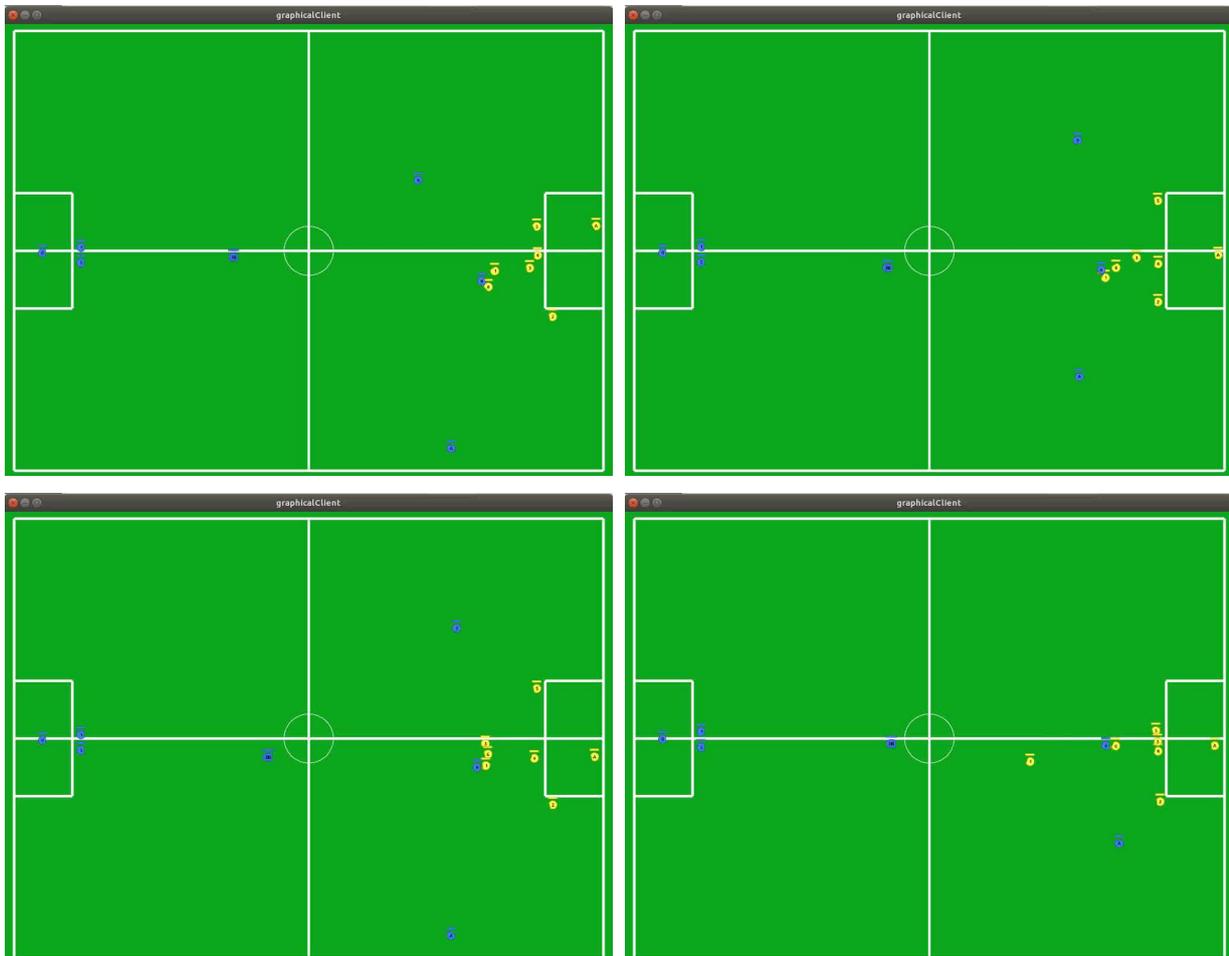


Fonte: Autor

adversário que permitia realizar movimentos rápidos para deslocar os robôs defensores de suas posições e assim chutar a gol.

Esse comportamento da equipe pode ser observado na sequência de imagens da figura 54 onde o robô atacante (azul) está com a posse de bola em frente ao gol adversário e a equipe amarela concentra-se totalmente a frente do gol.

Figura 54 – Jogo 01 – Sequência mostrando mudança de comportamento da equipe



Fonte: Autor

Esse comportamento defensivo da equipe ER–Force garantiu bons índices na avaliação defensiva. Nesse caso o IPOS do posicionamento retornado pelo PSO, mesmo que superior, foi próximo ao IPOS calculado para a defesa.

Porém, a equipe atuando como ataque não obteve bons resultados e marcou poucos gols contra equipes expressivas da liga A, excetuando uma goleada de  $8x0$  sobre a equipe OP–AmP.

A ausência de gols contra equipes mais expressivas explica-se justamente pelo esquema defensivo da equipe que diminui as possibilidades de ataques. A análise do posicionamento pela métrica de passe comprovou essa característica da equipe.

## 7.6 JOGO 02 – LOWER 3

Jogo realizado na oitavas de finais entre as equipes TIGERs Mannheim (equipe azul) e ER–force (equipe amarela). A jogada total, após tratamento do registro histórico, é composta de 6 instantes. O placar do jogo foi  $2x0$  para o time amarelo considerado atacante nesta partida. O gol analisado teve como origem uma jogada de bola parada (DIRECT\_FREE\_YELLOW).

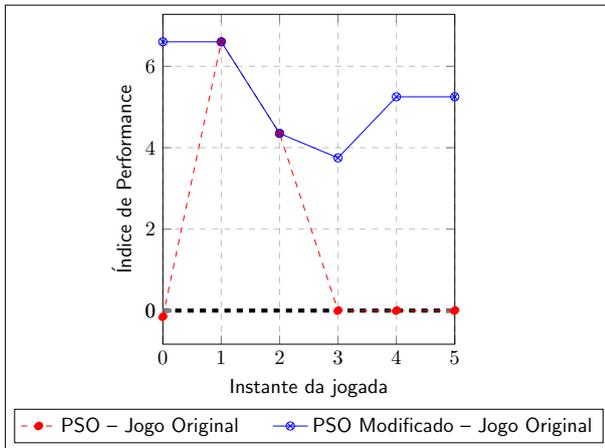
A equipe TIGERs Mannheim tem como característica um posicionamento agressivo. A equipe marcou 26 gols durante todo o campeonato tendo tomado apenas 6 gols. A TIGERs Mannheim é uma equipe que tem evoluído constantemente na liga A, tendo obtido a quarta colocação em 2019 e a terceira em 2018. A equipe tem como característica a realização de passes longos e devido a isso em várias situações perde o controle da bola para o adversário e acaba sofrendo gol. O outro gol sofrido pela equipe nessa partida foi realizada com cobrança de penalidade máxima e portando descartado para análise.

### 7.6.1 Análise da defesa

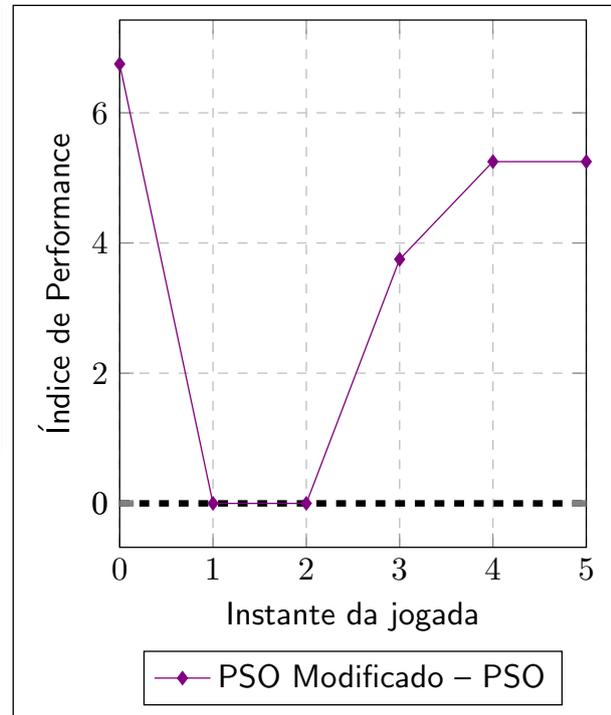
A figura 55a apresenta a comparação da aplicação da métrica de defesa entre o posicionamento original e o posicionamento otimizado. A linha em vermelho na figura 55a indica o Índice de Performance do Posicionamento (IPOS) do posicionamento otimizado pelo PSO a cada instante da jogada e comparada com o IPOS da equipe analisada. A linha em azul indica o IPOS do posicionamento otimizado após a modificação para simular o ataque a bola e posteriormente é comparado com o IPOS da equipe analisada.

Figura 55 – Jogo 02 – PSO em modo defesa.

(a) Jogo original x otimização



(b) Otimização original x modificada



Fonte: Autor

Na figura 55a pode ser observado que desde o início o posicionamento otimizado traria melhor resultado que o original. Essa constatação é observada na figura 56. Normalmente as equipes em situações de DIRECT\_FREE, que possibilita chutar a bola diretamente ao gol, tem o hábito de realizar passes. Nesse caso a equipe TIGERS falhou no posicionamento para proteção do gol.

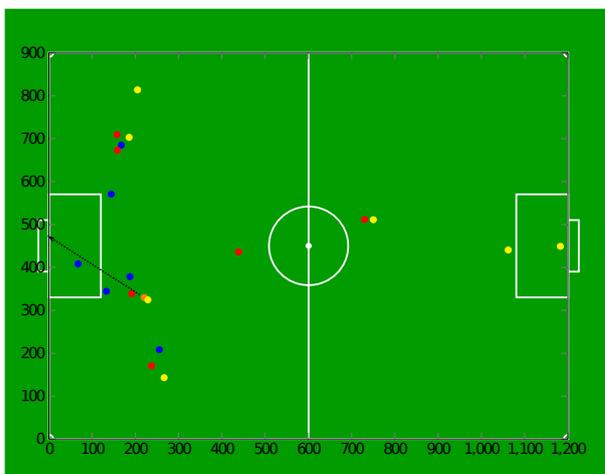
A figura 55b ressalta que nessa jogada o posicionamento otimizado (representado pela linha vermelha nos instantes 2 e 3 na figura 55a) estavam corretamente posicionados para o combate ao adversário.

A partir do instante 4, embora o gráfico de desempenho demonstra piora no posicionamento otimizado e melhora com o modificado, pode ser desconsiderado. A equipe já sofreu o gol e a métrica continuou avaliando os demais critérios. Esse fato corrobora que em jogadas de bola parada o posicionamento otimizado impediria a sequência da jogada.

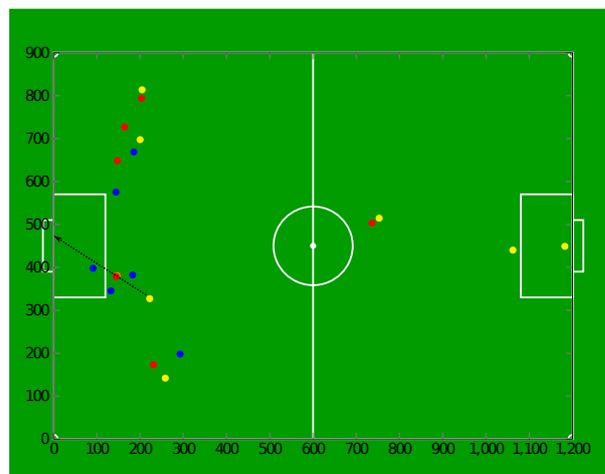
A figura 56 apresenta vários momentos da jogada. Os times azul e amarelo estão representados em suas posições originais. O jogadores em vermelho são os posicionamentos encontrados pelo PSO para cada momento jogo.

Figura 56 – Jogo 02 – Jogada de gol – PSO em modo defesa

(a) Momento do início da jogada



(b) Sequência da jogada



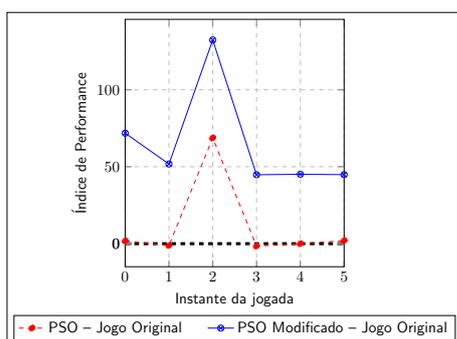
Fonte: Autor

### 7.6.2 Análise do passe

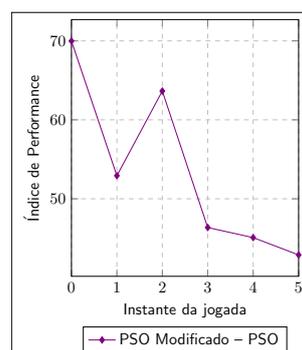
A figura 57a apresenta a comparação da aplicação da métrica de passe entre o posicionamento original e o otimizado. A linha em vermelho na figura 57a indica o posicionamento otimizado e a linha em azul após a modificação do posicionamento otimizado.

Figura 57 – Jogo 02 – PSO em modo passe.

(a) Jogo original x otimização



(b) Otimização original x modificada



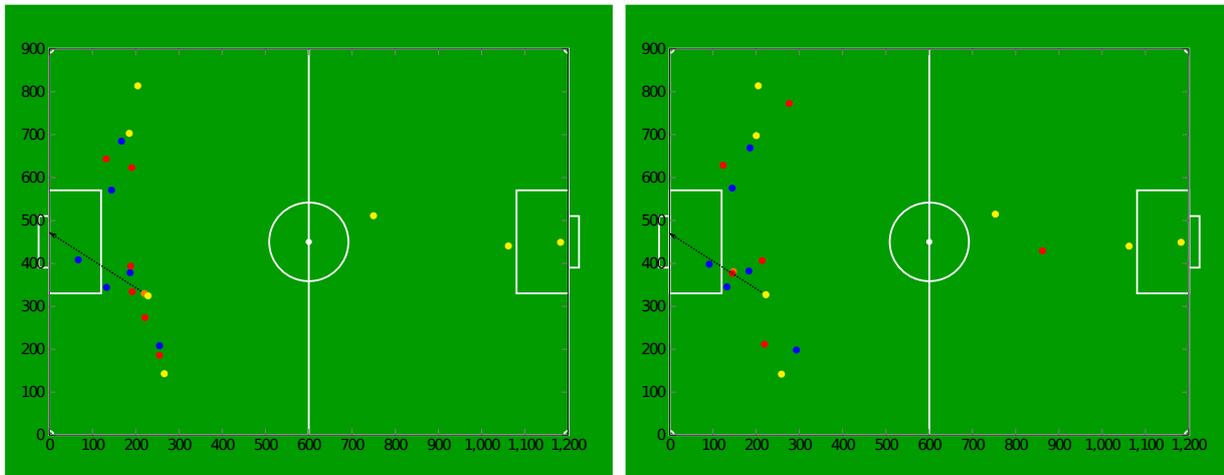
Fonte: Autor

A figura 57a demonstra que o posicionamento encontrado pelo PSO desde o início impossibilitaria a continuidade da jogada pela equipe adversária. A partir do instante 4, embora o gráfico de desempenho mostra que o posicionamento otimizado desde o início era melhor que original.

Figura 58 – Jogo 02 – Jogada de gol – PSO em modo passe

(a) Momento do início da jogada

(b) Sequência da jogada



Fonte: Autor

A figura 58 apresenta vários momentos da jogada. Os times azul e amarelo estão representados em suas posições originais. O jogadores em vermelho são os posicionamentos encontrados pelo PSO para cada momento jogo. As figuras 58a e 58b apresentam um posicionamento mais próximo da bola, a fim de dificultar o domínio e controle pela equipe adversária. Nesse caso, a métrica para impedir a realização de passes atuou como linha de defesa.

### 7.6.3 Análise defesa – métrica do passe

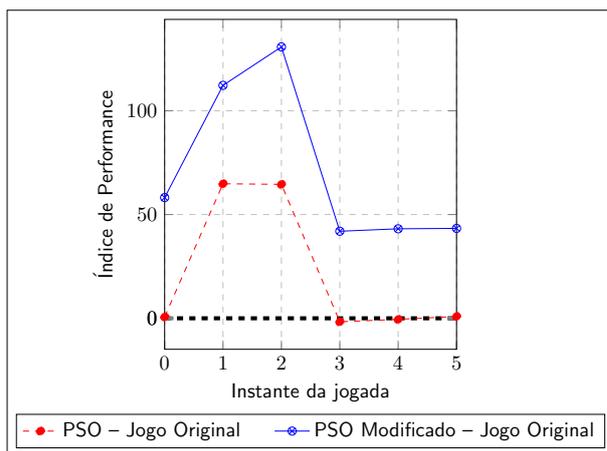
A análise do posicionamento defensivo com a métrica de avaliação de bloqueio de passe visa determinar se o posicionamento encontrado poderia ser aplicado como estratégia de bloqueio de passes. O algoritmo otimizou o posicionamento defensivo utilizando a função de aptidão de defesa. Na figura 59a pode ser observado que o posicionamento defensivo atuaria como alternativa para bloqueio de passe. Após a modificação do posicionamento para simular o ataque a bola, representando pela linha azul, o posicionamento defensivo tornou-se mais eficiente. Essa diferença pode ser observada na figura 57b que apresenta o resultado da avaliação da função de aptidão do passe pela métrica do passe.

Um dos critérios da métrica que avalia o passe é verificar o espaço deixado para a equipe adversária locomover-se em campo, atrelado aos princípios táticos defensivos (capítulo 2) como contenção, equilíbrio em campo e concentração. Na função de aptidão

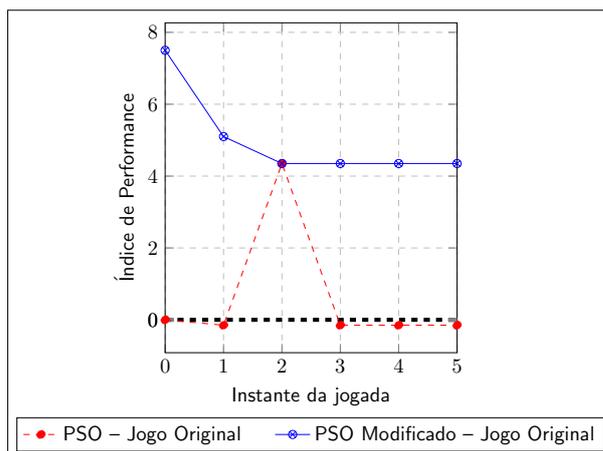
da defesa não estão previstas essas regras, porém por ser uma jogada próxima a área do gol, o posicionamento defensivo dificultaria a realização de um possível passe.

Figura 59 – Jogo 02 – Função Defesa x Métrica Passe e Função Passe x Métrica Defesa.

(a) Defesa x Métrica Passe



(b) Passe x Métrica Defesa



Fonte: Autor

#### 7.6.4 Análise passe – métrica da defesa

Para esse experimento, PSO otimizou o posicionamento utilizando a função de aptidão de bloqueio de passes. Posteriormente, os posicionamentos foram analisados com a métrica de defesa para determinar se o posicionamento encontrado atuaria na defesa do gol. No gráfico da figura 59b essa possibilidade foi verificada. Essa constatação é observada na figura 58 que apresenta o posicionamento do passe.

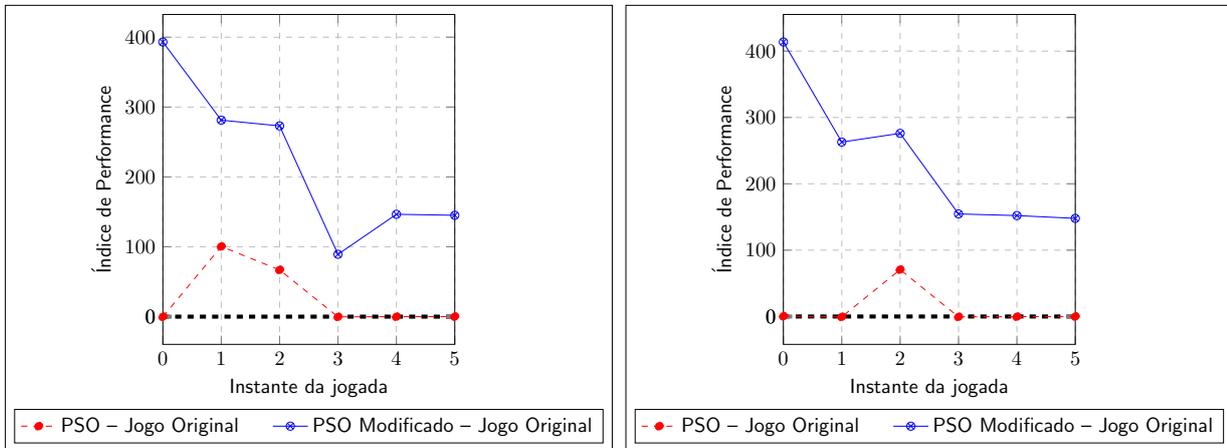
#### 7.6.5 Análise conjunta das métricas – passe e defesa

Para esses experimentos, os posicionamentos da defesa e passe foram comparados simultaneamente com as métricas de defesa e passe. As figuras 60a e 60b evidenciam o resultado dos posicionamentos otimizados ao demonstrarem que desde o início da jogada haveria a possibilidade de impedir a sua continuidade.

Figura 60 – Jogo 02 – Avaliação das métricas em conjunto.

(a) Métrica de defesa e passe aplicada em conjunto na função de aptidão de defesa.

(b) Métrica de defesa e passe aplicada em conjunto na função de aptidão de passe.



Fonte: Autor

### 7.6.6 Discussão e análises

A análise dessa jogada, por ser próxima a área de gol e com possibilidade de chute direto a gol, evidenciam que o posicionamento defensivo é importante.

A função de aptidão para a defesa visa bloquear a linha de visão e diminuir o espaço de todos os jogadores, para essa situação de cobrança de DIRECT\_KICK próxima a área demonstrou-se sua eficiência.

Porém, o posicionamento do passe que visa diminuir a área de atuação do portador da bola e dos possíveis candidatos a receberem passe, demonstrou-se taticamente mais eficiente atuando como defesa. Nesse cenário, isso só foi possível devido ao time adversário estar disperso em campo permitindo que a métrica de passe atuasse adequadamente próximo a área do gol.

## 7.7 JOGO 03 – UPPER 2–2

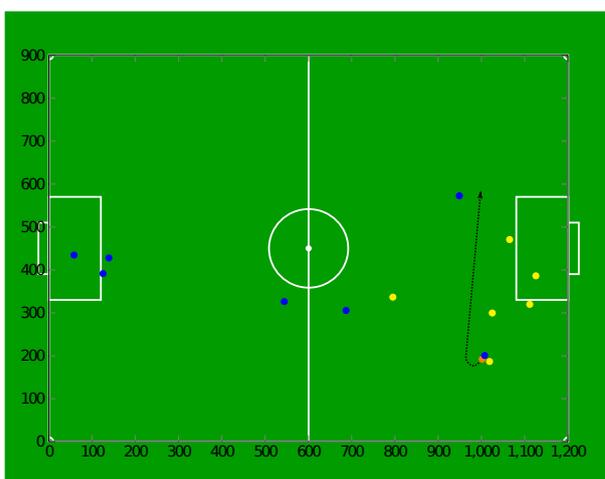
Jogo realizado na fase semifinal entre as equipes MRL (equipe amarela) e ZJUNlict (equipe azul). A jogada total, após tratamento do registro histórico, é composta de 115 instantes. O placar do jogo foi 2x0 para o time azul considerado atacante nesta partida. O gol analisado teve como origem uma jogada de bola parada (INDIRECT\_FREE\_YELLOW).

A equipe MRL, campeã da SSL em 2016 na Alemanha e quarta colocação em 2019, teve o início da jogada. A equipe demonstra bom posicionamento em campo porém não tem o mesmo controle de bola como a ZJUNlict (sua adversária).

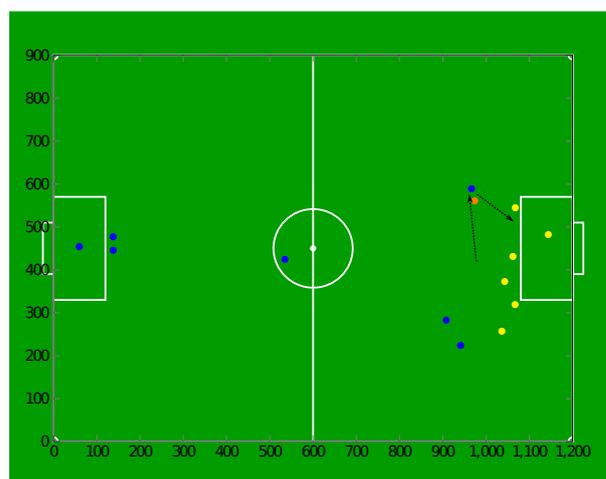
No início da jogada a equipe MRL toca na bola e perde o controle da mesma. A ZJUNlict, com a vantagem competitiva do seu *roller* obtém a posse de bola (figura 61a) e já realiza um passe (figura 61b). Instantaneamente a equipe azul chuta a gol (figuras 61c e 61d), porém a equipe amarela estava bem posicionada e consegue defender o primeiro chute (figuras 62a e 62b).

Figura 61 – Jogo 03 – Perda da bola e 1º chute a gol

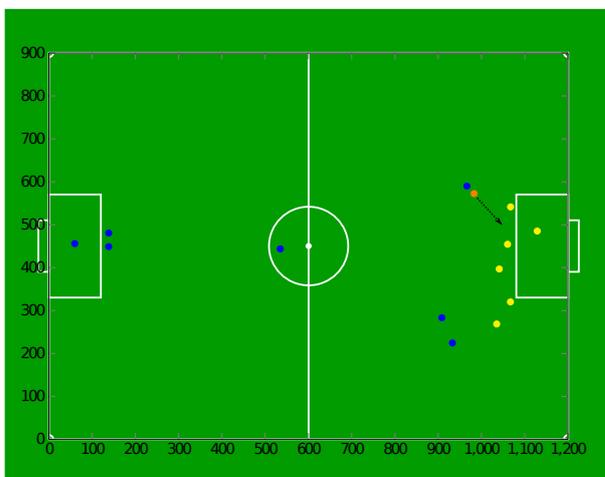
(a) Momento do início da jogada.



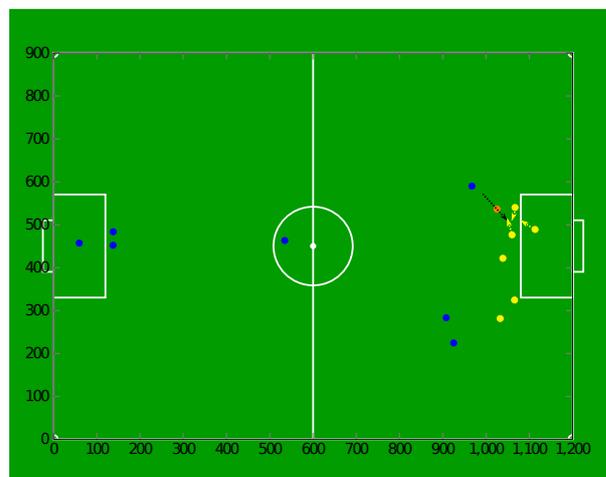
(b) Robô adversário recebendo a bola.



(c) Chute a gol.



(d) Chute a gol.

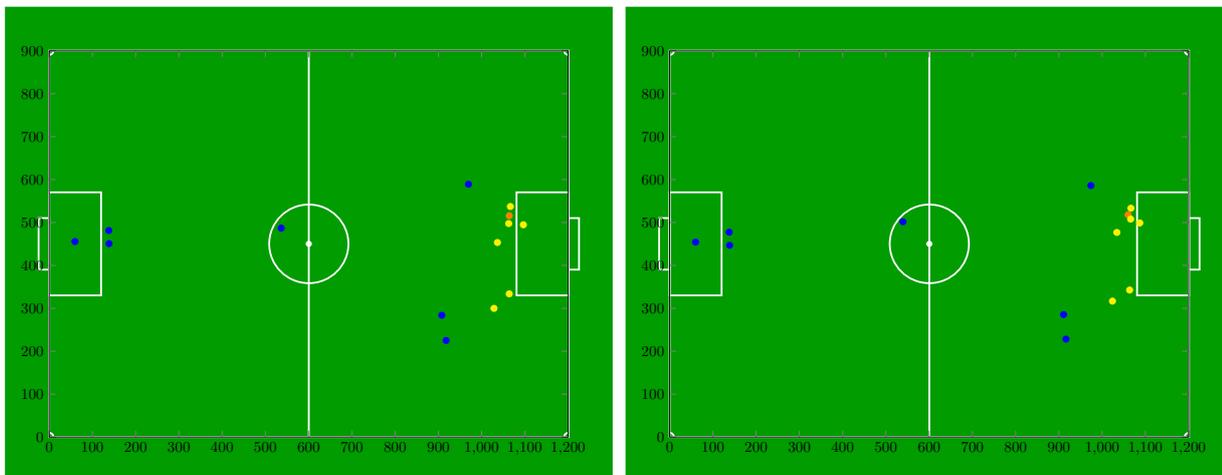


Fonte: Autor

Figura 62 – Jogo 03 – Defesa 1º chute a gol

(a) Equipe amarela defendendo chute.

(b) Equipe amarela defendendo chute.



Fonte: Autor

Na sequência a equipe novamente não consegue manter a posse de bola (figuras 63a e 63b) e a equipe azul retoma a bola (figuras 63c e 63d).

Com a retomada do controle da bola, ocorre o passe (figuras 64a e 64b). Após recepção do passe a equipe ZJUNlict com sua vantagem mecânica, gira sobre o próprio eixo e marca o gol (figuras 64b e 64c).

A exemplo de outras equipes, a estratégia da equipe MRL (amarela) é considerar a bola como pivô central da sua estratégia de defesa e não marcando os demais robôs da equipe adversária. Essa abordagem permitiu que ocorressem as 2 situações de passe com sucesso pela outra equipe.

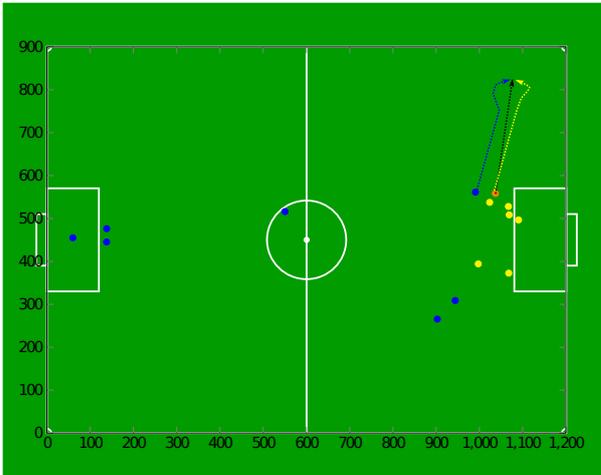
### 7.7.1 Análise da defesa

A figura 65 apresenta vários momentos do primeiro passe na jogada. Os times azul e amarelo estão representados em suas posições originais. O jogadores em vermelho são os posicionamentos encontrados pelo PSO para cada momento jogo dos jogadores amarelos. O goleiro defensor será considerado o da jogada original.

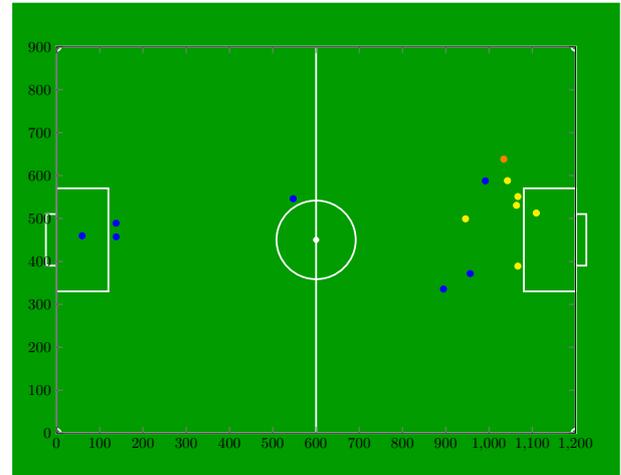
Na figura 65a o posicionamento otimizado já impediria a sequência da jogada, pois o robô que receberia o passe está com sua visão bloqueada. Na figura 65b já haveria um

Figura 63 – Jogo 03 – Defesa Perde o controle da bola.

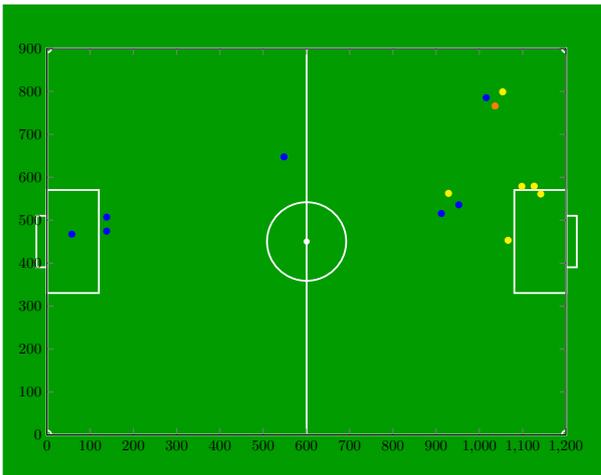
(a) Equipe perde controle da bola.



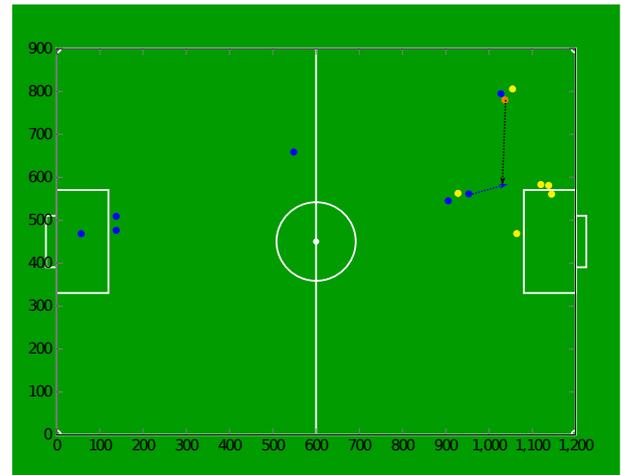
(b) Sequência da jogada.



(c) Equipe perde controle da bola.



(d) Equipe azul retoma controle da bola.



Fonte: Autor

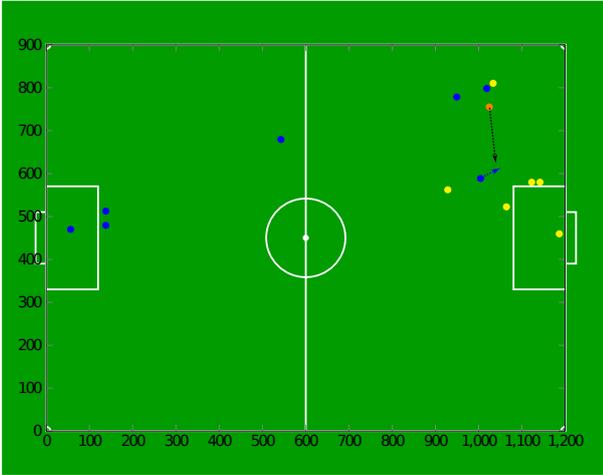
robô atacando a bola para impedir a continuidade da jogada e na figura 65c haveria um robô para bloqueio do chute.

A figura 66 apresenta a comparação da aplicação da métrica de defesa entre o posicionamento original e o posicionamento otimizado. A figura mostra que no instante 45 houve um baixo desempenho do posicionamento modificado, nesse caso a modificação no resultado do PSO para simular o ataque a bola implicou na invasão da área de gol, considerado uma infração na SSL.

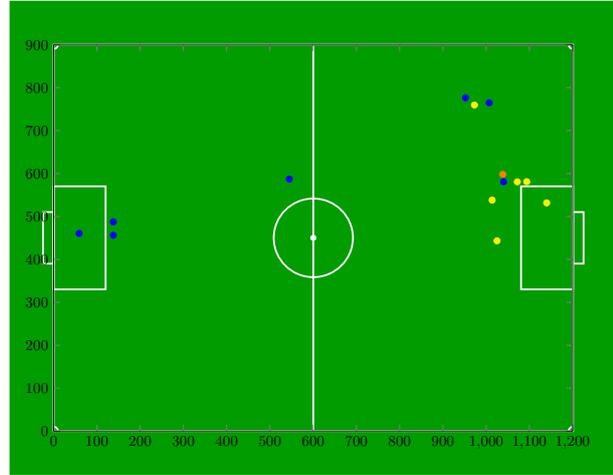
O instante 83 da figura 66 foi inferior ao posicionamento original pois a equipe amarela estava tocando a bola e a estratégia utilizada na posicionamento modificado consiste

Figura 64 – Jogo 03 – Passe e marcação do gol.

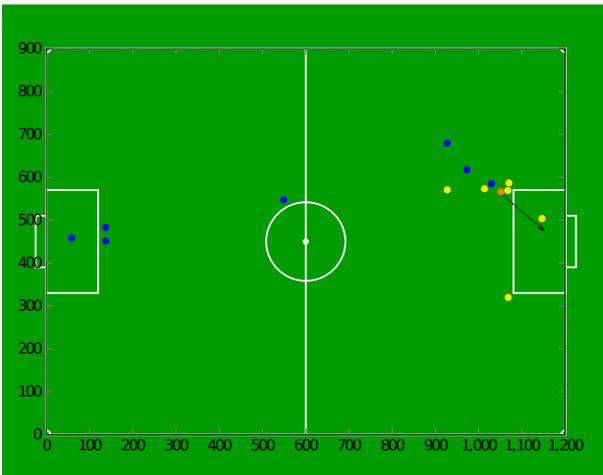
(a) Passe da bola.



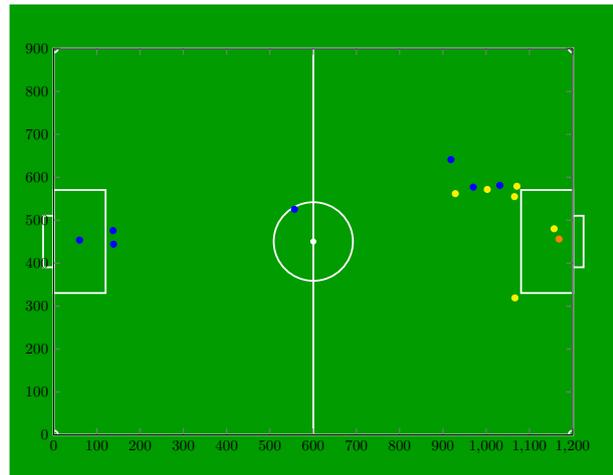
(b) Recepção do passe.



(c) Chute a gol.



(d) Marcação do gol.



Fonte: Autor

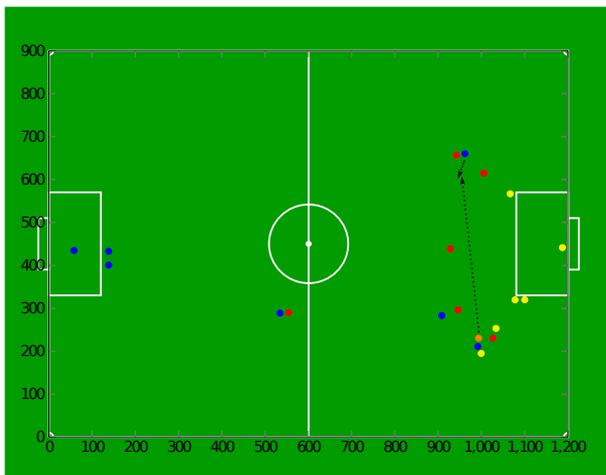
em aproximar-se da bola para simular o ataque. Nas métricas, estar tocando a bola tem um peso maior. Os instantes negativos na figura 67 evidenciam que a escolha da robô para realizar o ataque a bola foi inadequada.

Novamente o segundo passe seria interceptado pois o posicionamento da defesa impediria a recepção da bola (figura 68a). Na figura 68b ocorre a recepção do passe e as posições dos robôs próximos ao goleiro impedem a visão do robô adversário. Nesse caso, o posicionamento otimizado e original estavam cumprindo suas funções.

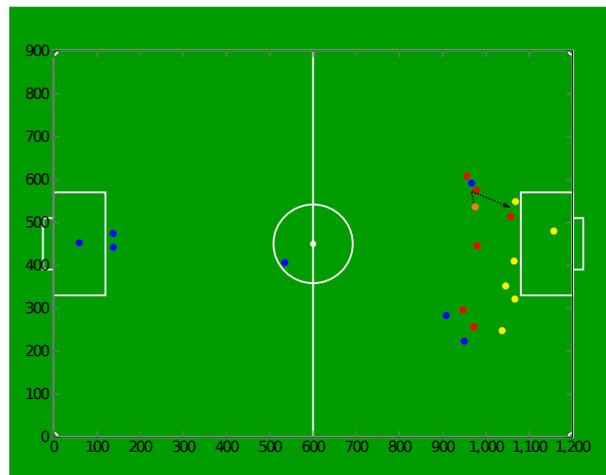
Por fim, a figura 69 que analisa a Qualidade de Realização da Ação Tática (QR), mostra que o posicionamento otimizado é idêntico ao posicionamento modificado, sendo

Figura 65 – Jogo 03 – Primeiro passe – PSO em modo defesa

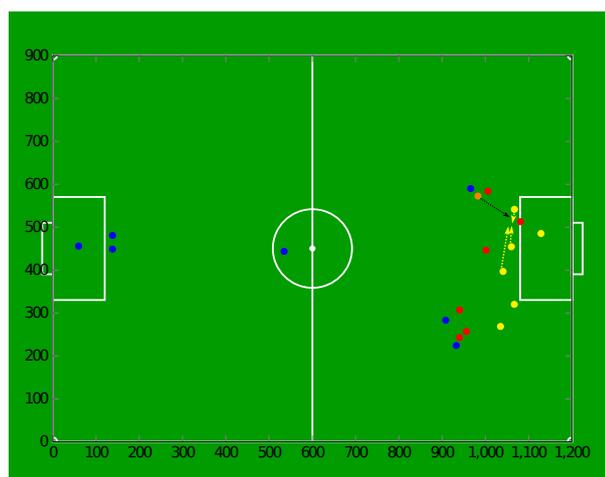
(a) Momento do passe



(b) Recepção do passe.



(c) 1º chute a gol.



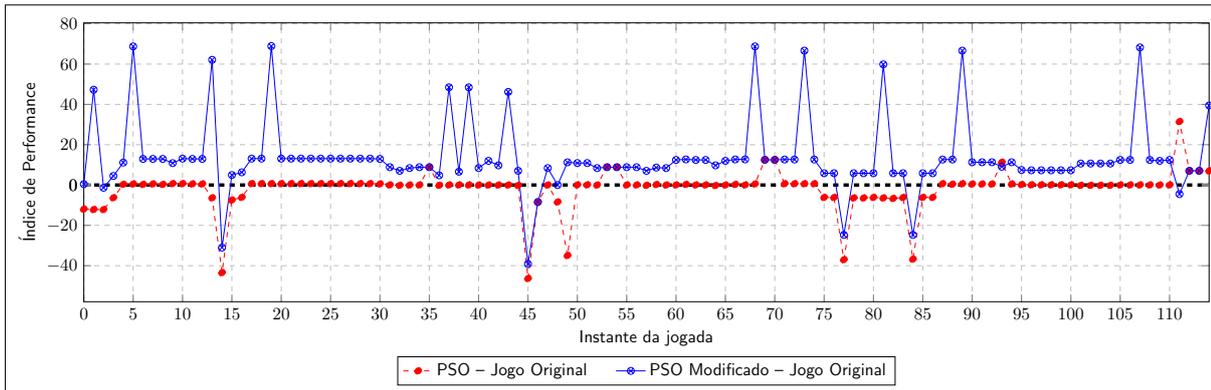
Fonte: Autor

superior em alguns casos. A piora no posicionamento modificado ocorre pela escolha do robô que foi utilizado para atacar a bola.

### 7.7.2 Análise do passe

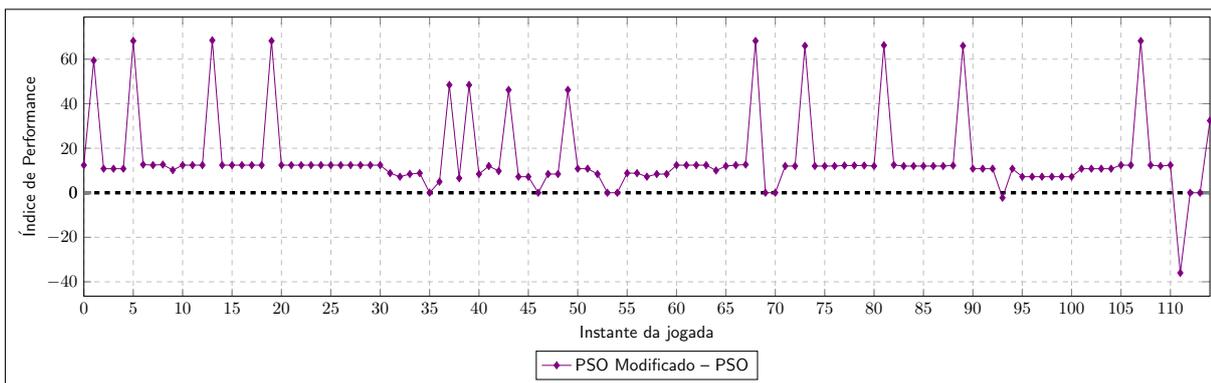
A figura 70 apresenta vários momentos da jogada. Os times azul e amarelo estão representados em suas posições originais. O jogadores em vermelho são os posicionamentos encontrados pelo PSO para cada momento jogo, o goleiro não é considerado na

Figura 66 – Jogo 03 – Comparação jogo original com otimização – PSO em modo defesa.



Fonte: Autor

Figura 67 – Jogo 03 – Comparação da otimização original com otimização modificada – PSO em modo defesa.



Fonte: Autor

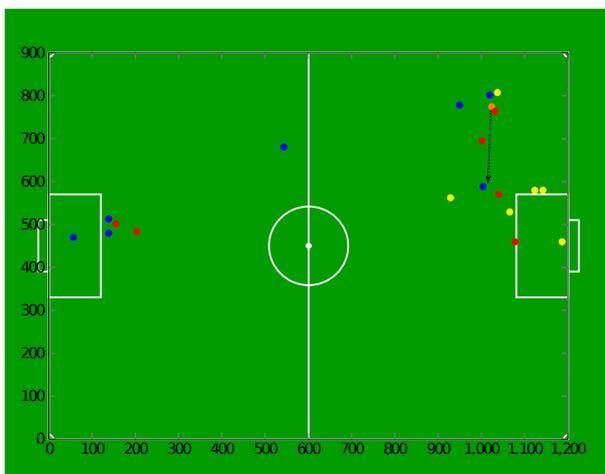
otimização e não está destacado na figura. As linhas tracejadas indicam a trajetória da bola ou dos robôs que estão participando ativamente da jogada.

A figura 71 apresenta momentos antes do gol. Na figura 71a o robô que realiza o passe está cercado por pelos robôs otimizados, o que dificultaria a realização do passe. As figuras 71b e 71c ilustram a recepção do passe e chute a gol. Embora tenha três robôs otimizados marcando outros robôs no campo de ataque, os robôs restantes estão bloqueando o acesso ao gol.

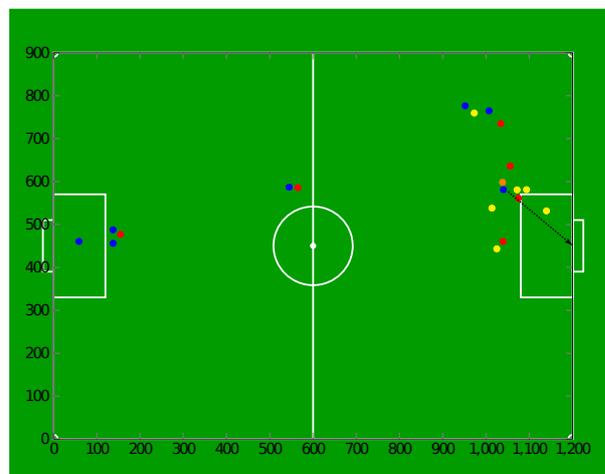
A figura 72 apresenta a comparação da aplicação da métrica de passe entre o posicionamento original e o posicionamento otimizado. O ponto negativo no instante 45 é relativo ao primeiro chute a gol, nesse caso o posicionamento do passe não atuou adequadamente como defesa, pois enquanto no posicionamento original haviam 3 robôs formando

Figura 68 – Jogo 03 – Segundo passe – PSO em modo defesa.

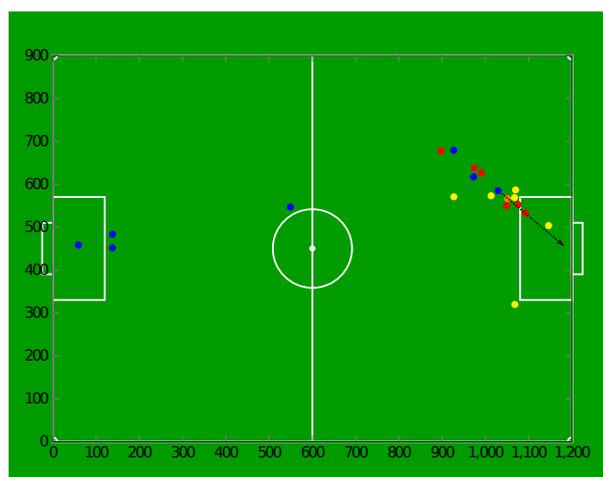
(a) Momento do passe



(b) Recepção do passe.



(c) 2º chute a gol.

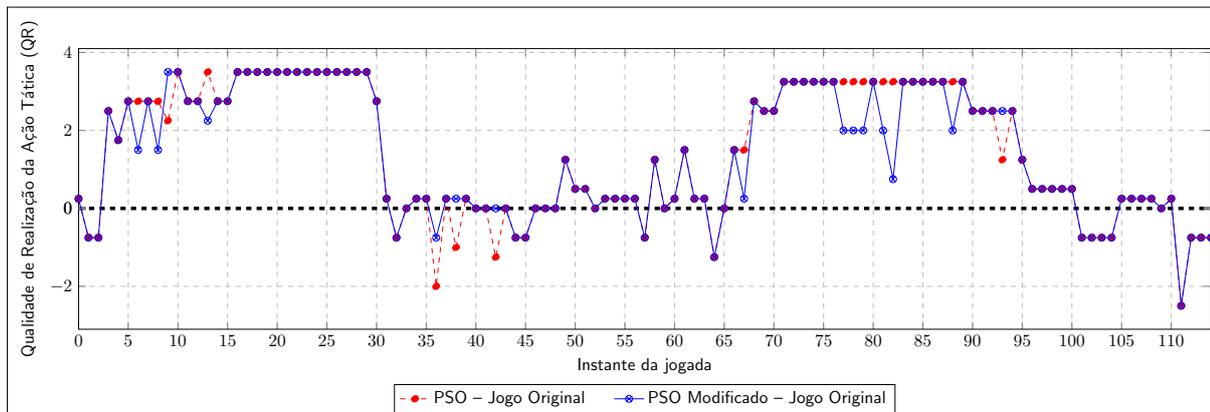


Fonte: Autor

a linha defesa, a otimização do passe posicionou apenas 1 robô. Entre os instantes 75 e 85, que estão negativos (linha vermelha), compreende a tentativa da recuperação de bola pela equipe amarela em seu posicionamento original.

A figura 73 que analisa a Qualidade de Realização da Ação Tática (QR), mostra que o posicionamento otimizado é superior ao posicionamento modificado. O posicionamento modificado melhora a avaliação nas demais variáveis da avaliação das métricas, porém, nesse caso o posicionamento otimizado desde o início da jogada tem uma avaliação melhor, inclusive que o posicionamento original. A piora no posicionamento modificado ocorre pela escolha do robô que foi utilizado para atacar a bola.

Figura 69 – Jogo 03 – Análise da qualidade do posicionamento (QR) – PSO em modo defesa.



Fonte: Autor

Por fim, a Resultado da Ação Tática (RA) analisa duas possibilidades do jogo: se na mudança de direção da bola, haveria algum robô para interceptar a mesma e se os adversários tem espaço para atuação. A figura 74, demonstra que em vários momentos os posicionamentos otimizados teriam maiores chances de recuperação de bola.

### 7.7.3 Análise da defesa – métrica do passe

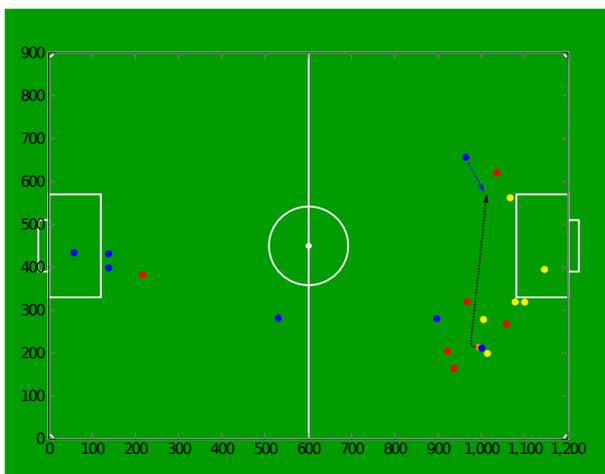
A análise do posicionamento defensivo com a métrica de avaliação de bloqueio de passe visa determinar se o posicionamento encontrado poderia ser aplicado como estratégia de bloqueio de passes. Na figura 75 pode ser observado que o posicionamento defensivo atuaria como alternativa para bloqueio de passe. Os pontos negativos que ocorrem nessa avaliação estão relacionadas com as considerações anteriores a respeito da defesa e passe.

### 7.7.4 Análise do passe – métrica da defesa

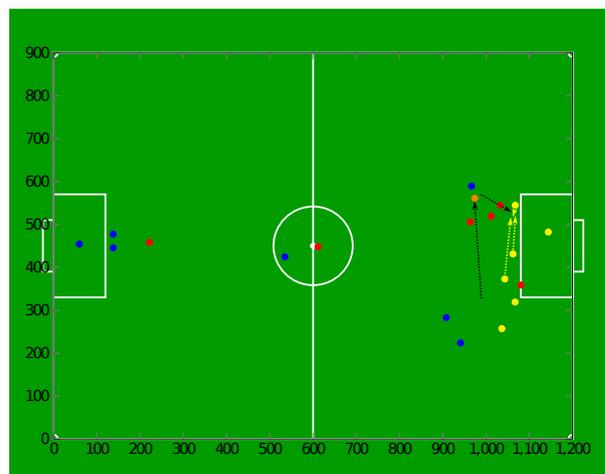
Na figura 76 pode ser observado que o posicionamento de bloqueio de passe, para essa jogada, não teria atuado adequadamente como estratégia de defesa. Esse resultado está relacionado com os objetivos conflitantes entre as funções de defesa e passe. Enquanto o passe visa diminuir espaço de jogo, atendendo também alguns critérios de-

Figura 70 – Jogo 03 – Primeiro passe – PSO em modo passe.

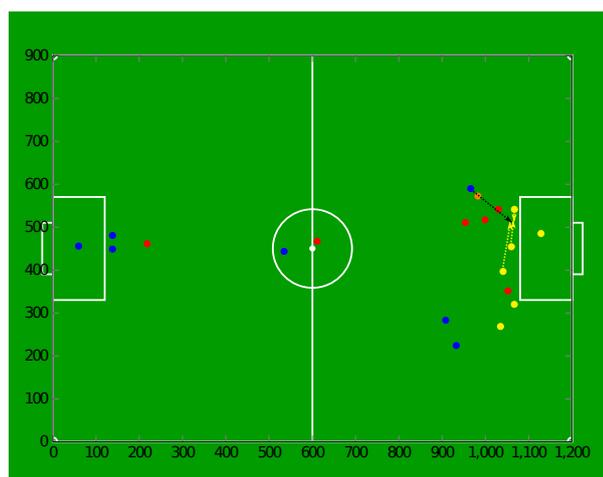
(a) Momento do início da jogada.



(b) Recepção do passe.



(c) 1º chute a gol.



Fonte: Autor

fensivos a defesa visa bloquear o acesso total ao gol. Nessa análise, o posicionamento defensivo da equipe MRL foi mais eficiente de acordo as métricas de análise de defesa.

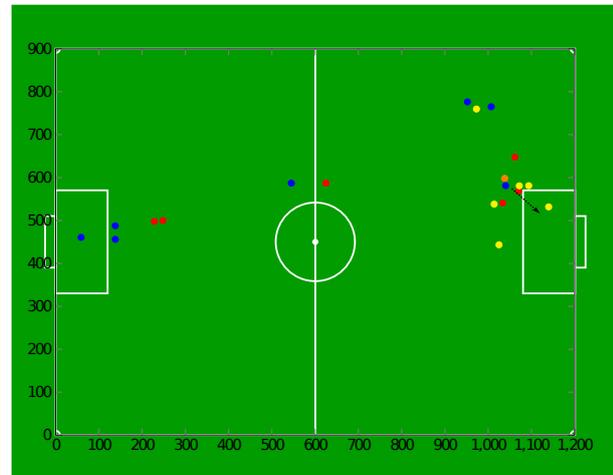
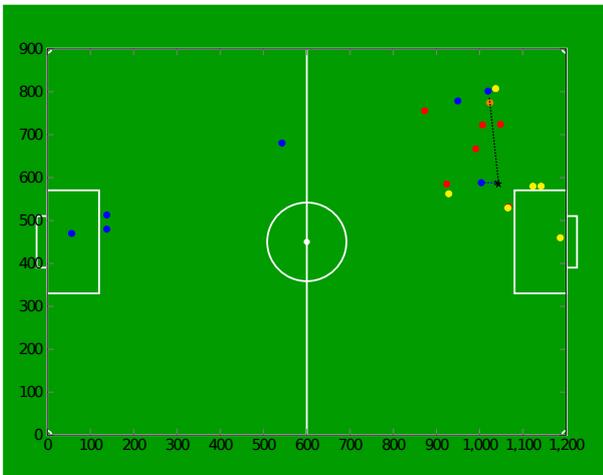
### 7.7.5 Análise conjunta das métricas – passe e defesa

Para esses experimentos, os posicionamentos da defesa e passe foram comparados em conjunto com as métricas de defesa e passe para cálculo do IPOS geral. As figuras 77 e 78 evidenciam o resultado dos posicionamentos otimizados simulando o ataque a bola. Considerando apenas as linhas vermelhas das figuras, o resultado da aplicação

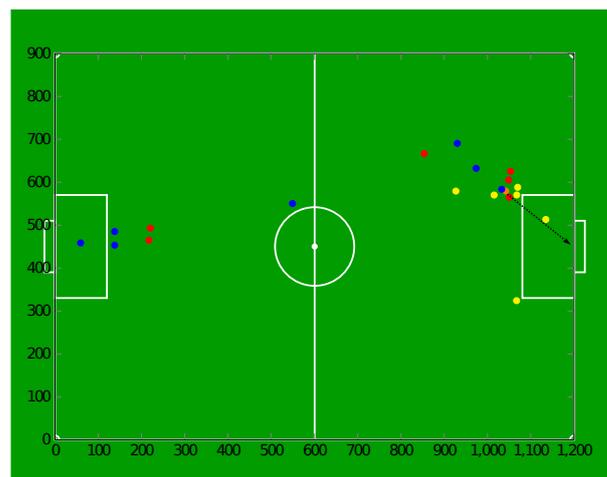
Figura 71 – Jogo 03 – Segundo passe – PSO em modo passe.

(a) Momento do início da jogada.

(b) Recepção do passe.



(c) 2º chute a gol.



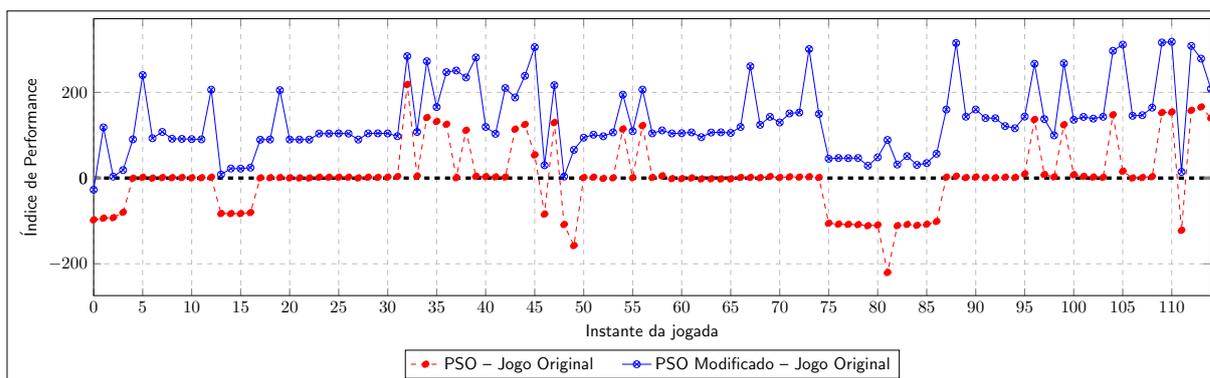
Fonte: Autor

conjunta das métricas para a jogada se anularam. O posicionamento defensivo teve um bom resultado na métrica de passe e o inverso não ocorreu.

### 7.7.6 Discussão e análises

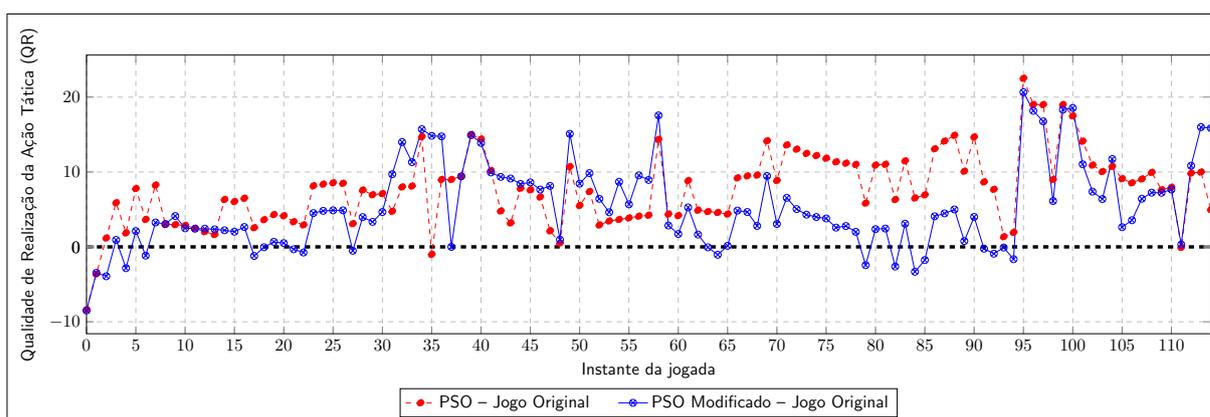
A análise dessa jogada em particular evidenciou que o controle mecânico da bola pela ZJUNlict atua drasticamente a seu favor. A equipe MRL, nessa ocasião, estava com um posicionamento adequado. Porém, sua estratégia de centralizar a atenção na bola e

Figura 72 – Jogo 03 – Comparação jogo original com otimização – PSO em modo passe.



Fonte: Autor

Figura 73 – Jogo 03 – Análise da qualidade do posicionamento (QR) – PSO em modo passe.



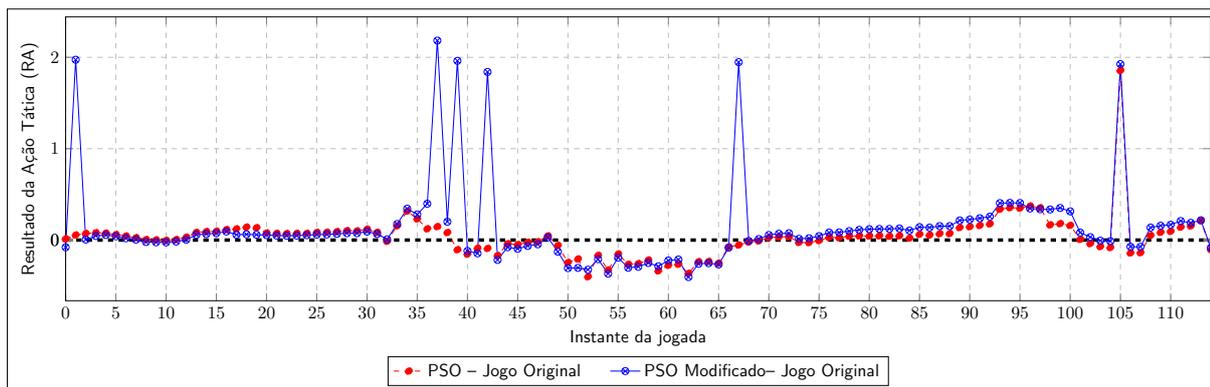
Fonte: Autor

não ter a mesma capacidade de controle para manter a posse de bola resultou na tomada do gol.

Os resultados negativos para o posicionamento modificado indicam que a escolha do robô para realizar o ataque a bola foi inadequado. Ao retirar o robô do posicionamento para realizar esse ataque, o posicionamento perdeu sua eficiência por não ter outro robô cumprindo as mesmas funções que o robô selecionado.

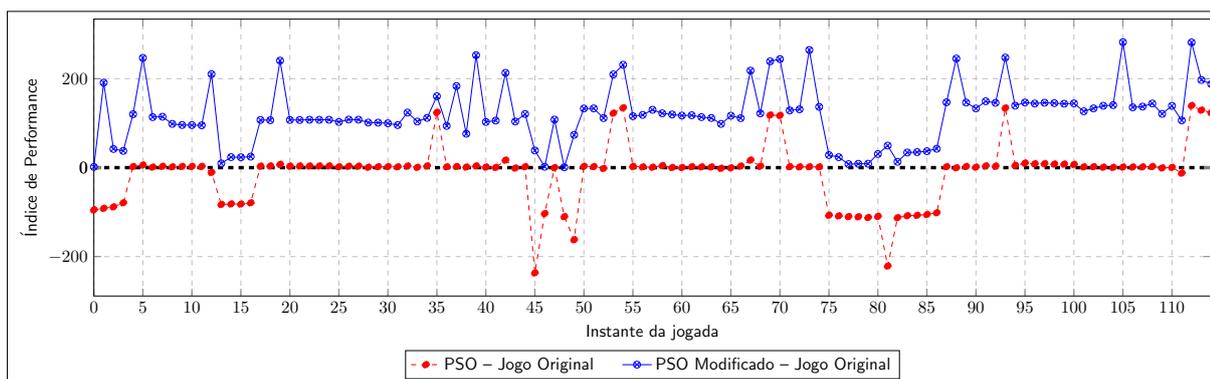
Resultados otimizados, como ilustrados nas figuras 71b e 71c, estão respeitando as regras da função de aptidão de bloqueio de passes. Porém indicam que a otimização deve ocorrer apenas para marcar robôs adversários que estejam participando ativamente da jogada.

Figura 74 – Jogo 03 – Análise do resultado da ação (RA) – PSO em modo passe.



Fonte: Autor

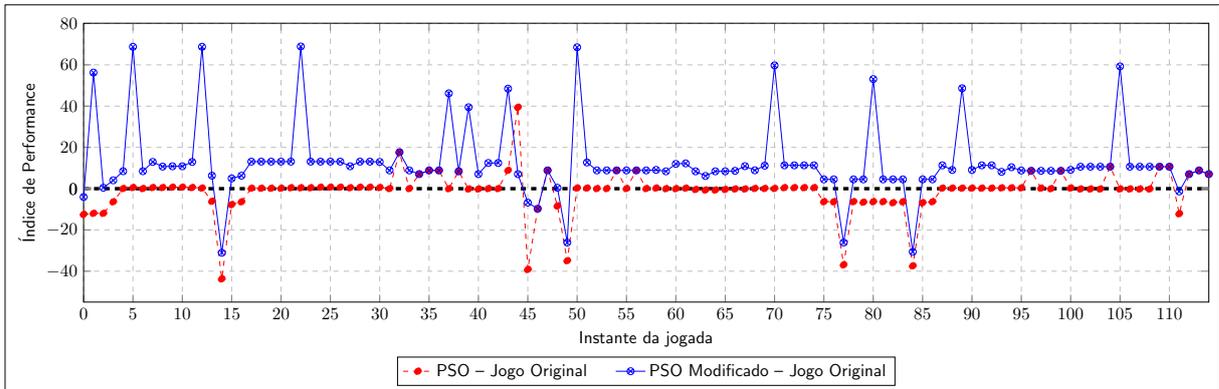
Figura 75 – Jogo 03 – Posicionamento de defesa avaliada com métrica do passe – PSO em modo defesa.



Fonte: Autor

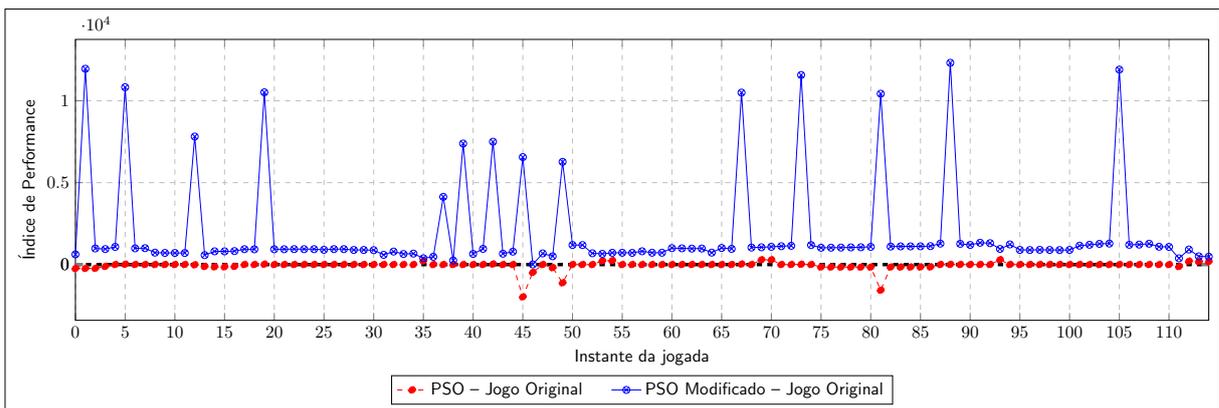
Finalmente, a análise individual das variáveis demonstraram que os posicionamentos otimizados foram bem avaliados na dimensão da qualidade (QR). Com isso, esses posicionamentos estavam atuando mais efetivamente para o bloqueio de passes e defesa do gol que o posicionamento original. Para o passe, a análise da Resultado da Ação Tática (RA) demonstrou que haveria a possibilidade de recuperação de bola em vários momentos ao longo da jogada.

Figura 76 – Jogo 03 – Posicionamento de passe avaliada com métrica da defesa – PSO em modo passe.



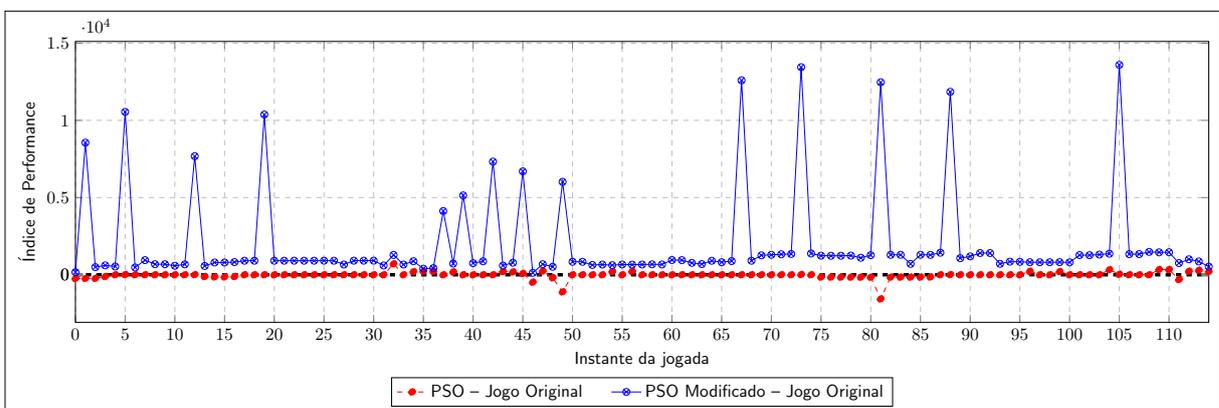
Fonte: Autor

Figura 77 – Jogo 03 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de defesa.



Fonte: Autor

Figura 78 – Jogo 03 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de passe.



Fonte: Autor

## 7.8 JOGO 04 – LOWER 2–1 - Primeiro gol

Jogo realizado na fase oitava de final entre as equipes RoboDragons (equipe amarela) e TIGERS Mannheim (equipe azul). A jogada total, após tratamento do registro histórico, é composta de 40 instantes. O placar do jogo foi  $4x0$  para o time azul considerado atacante nesta partida. O gol analisado teve como origem uma jogada de bola parada (DIRECT\_FREE\_BLUE).

A equipe TIGERS tem uma cobrança no canto inferior do campo (figura 79a). No início da jogada a equipe lança a bola na área da RoboDragons (figura 79b). A bola bate um robô amarelo (figura 79c) e volta para o mesmo robô que lançou a bola (figura 79d). A análise da sequência sugere que bola foi lançada para área pelo alto. Pela movimentação da equipe amarela, percebe-se que a estratégia da mesma é focar na bola pois o robô que realizou o passe ficou sem marcação, o que no rebote da bola possibilitou a conclusão no gol.

### 7.8.1 Análise da defesa

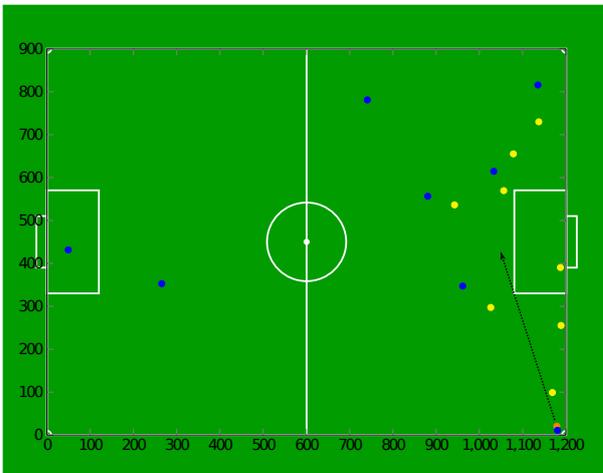
A figura 80 apresenta vários momentos do passe na jogada. A análise defensiva desta jogada demonstrará que equipe amarela centraliza sua estratégia em marcar a bola. Houve um passe com interceptação pelo defensor mas sem controle da bola, permitindo o retorno para robô adversário com finalização em gol, porém esse gol ocorreu devido a falha de marcação.

Na figura 80a o posicionamento otimizado já impediria a sequência da jogada, pois já haveria um robô impedindo o passe. Supondo que o passe foi realizado por bola alta, a proximidade dificultaria a realização da jogada por limitar o espaço necessário. A figura 80b mostra que o posicionamento otimizado também estaria recebendo a bola. A figura 80c demonstra que o robô que receberia a bola está sendo marcado ativamente no posicionamento otimizado e por fim teria bloqueado o chute a gol (figura 80d).

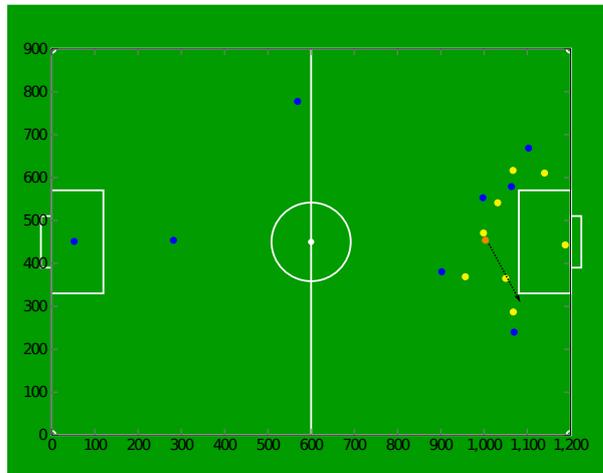
A figura 81 apresenta a comparação da aplicação da métrica de defesa entre o posicionamento original e o posicionamento otimizado. A linha em vermelho na figura 81 indica o Índice de Performance do Posicionamento (IPOS) do posicionamento otimizado pelo PSO a cada instante da jogada e comparada com o IPOS da equipe analisada. A

Figura 79 – Jogo 04 – Gol por cobrança de tiro direto.

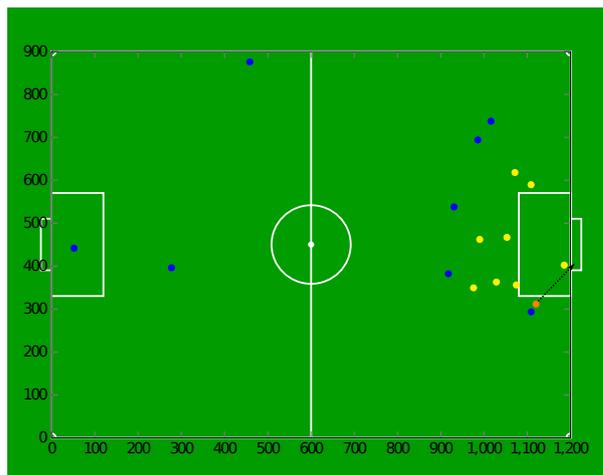
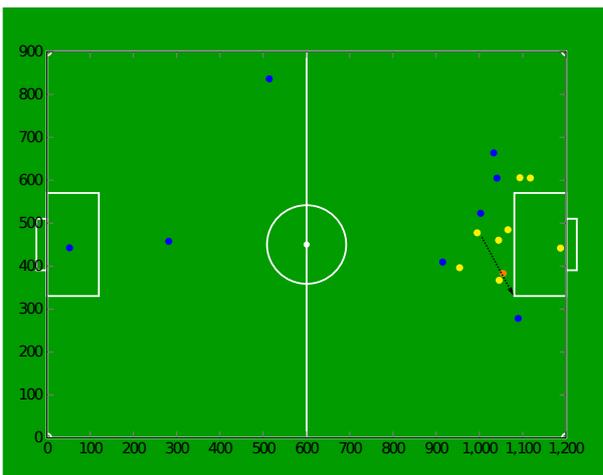
(a) Momento do início da jogada.



(b) Robô recebendo a bola.



(c) Bola indo em direção ao robô adversário. (d) Chute a gol.



Fonte: Autor

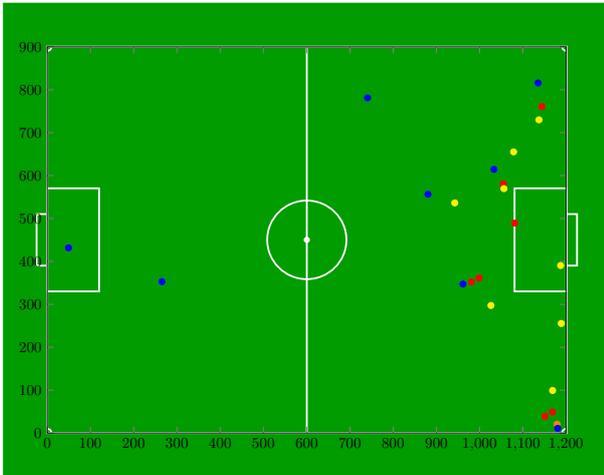
linha em azul indica o IPOS do posicionamento otimizado após a modificação para simular o ataque a bola e posteriormente é comparado com o IPOS da equipe analisada.

A figura 82 apresenta diferença entre o posicionamento otimizado original e o posicionamento modificado. O posicionamento modificado simula o ataque a bola. A figura ressalta a importância do sistema de estratégia decidir como o posicionamento será adotado em campo, principalmente na questão de decidir qual robô atacará a bola. Essa melhora pode ser observada pela linha azul superior a linha vermelha (figura 81 )

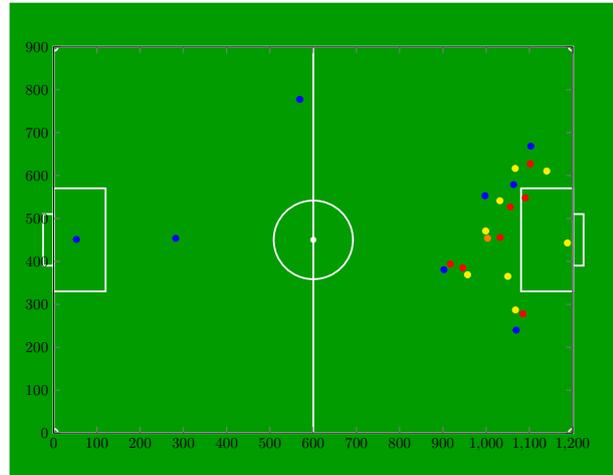
A equipe amarela manteve seus robôs posicionados junto a área do gol, devido a proximidade da jogada. Nesse caso, o principal destaque do posicionamento otimizado

Figura 80 – Jogo 04 – PSO em modo defesa

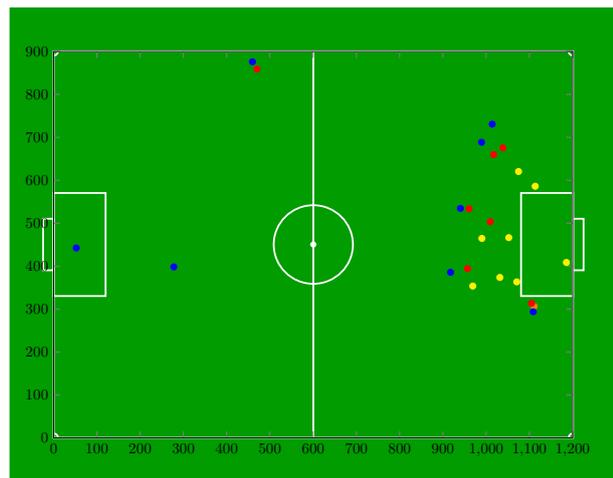
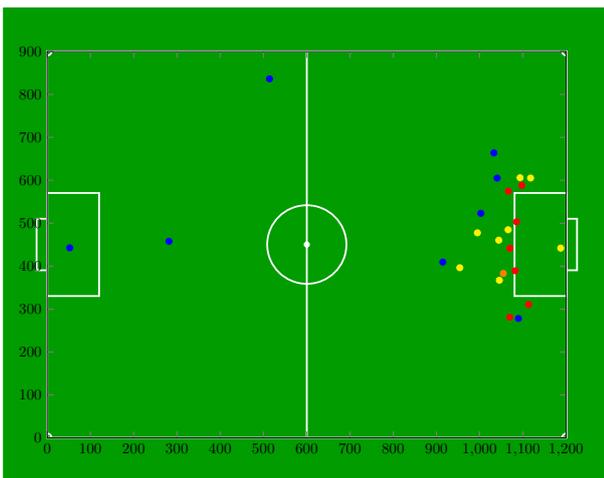
(a) Momento do início da jogada.



(b) Robô recebendo a bola.



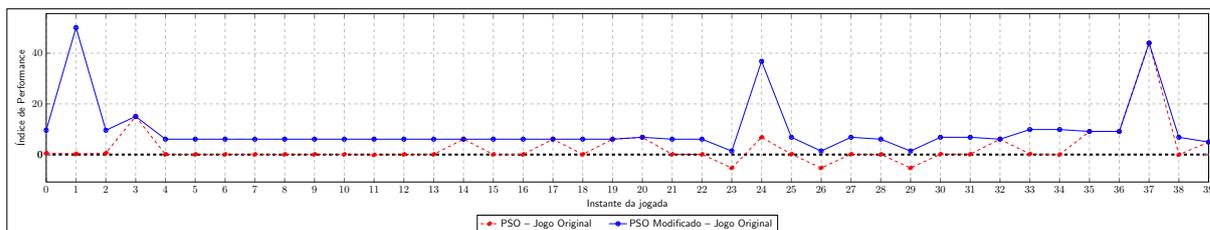
(c) Bola indo em direção ao robô adversário. (d) 1º chute a gol.



Fonte: Autor

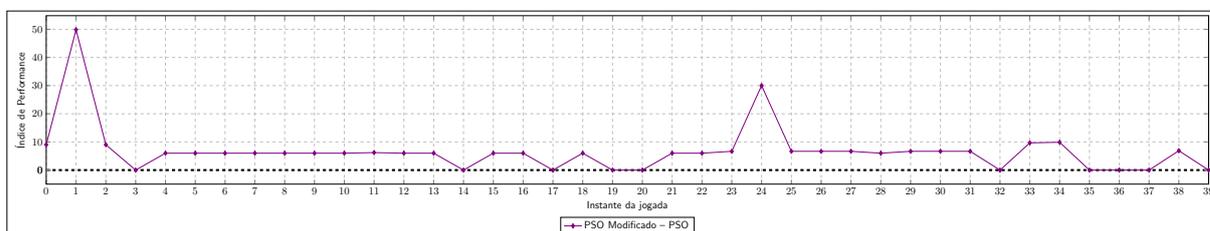
está relacionado com a análise dos posicionamentos em campos, medido pela Localização da Realização da Ação Tática no Campo de Jogo (LA) (figura 83) e pela análise da qualidade do posicionamento, medido pela Qualidade de Realização da Ação Tática (QR) (figura 84). As figuras demonstram que nos primeiros instantes a jogada provavelmente teria impedida sua continuidade.

Figura 81 – Jogo 04 – Comparação jogo original com otimização – PSO em modo defesa.



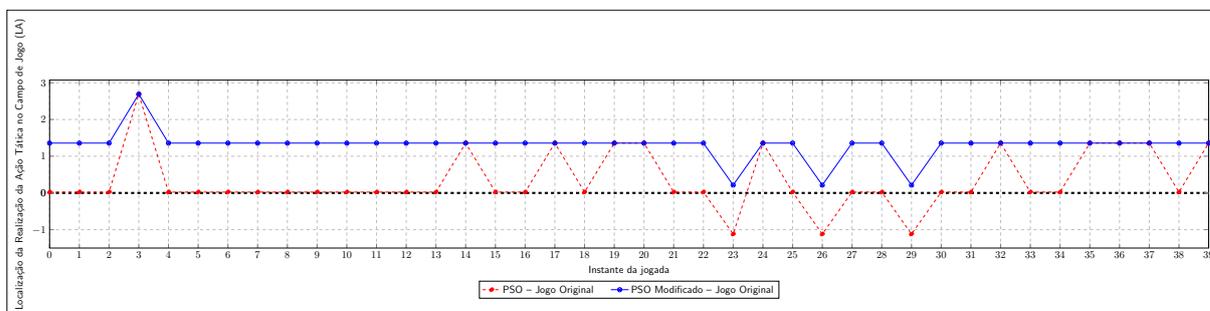
Fonte: Autor

Figura 82 – Jogo 04 – Comparação da otimização original com otimização modificada – PSO em modo defesa.



Fonte: Autor

Figura 83 – Jogo 04 – Análise da localização em campo (LA) – PSO em modo defesa.

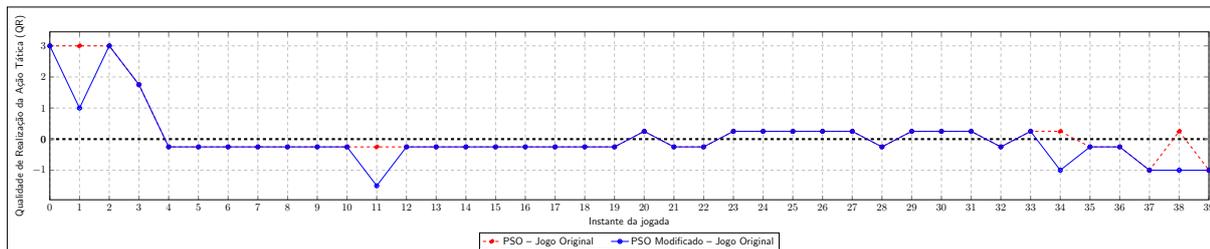


Fonte: Autor

## 7.8.2 Análise do passe

A figura 85 apresenta vários momentos da jogada. A figura 85a demonstra o início da jogada. No início da jogada o robô com bola está bem marcado e com poucas possibilidades de realizar um passe direto. Embora haja apenas 2 robôs em frente a área do gol, eles estavam bem posicionados para diminuir o espaço dos 3 robôs próximos. Contudo, na continuidade da jogada a função de aptidão de passe não teve um bom desempenho na

Figura 84 – Jogo 04 – Análise da qualidade do posicionamento (QR) – PSO em modo defesa.



Fonte: Autor

análise visual. Permitindo que o robô adversário receba a bola e conclua o chute a gol (figuras 85c e 85d).

A figura 86 apresenta a comparação da aplicação da métrica de passe entre o posicionamento original e o posicionamento otimizado. A melhora geral no posicionamento otimizado está diretamente relacionado com a diminuição do espaço de jogo dos robôs adversários.

A figura 87 que analisa a Qualidade de Realização da Ação Tática (QR), mostra que o posicionamento otimizado é superior ao modificado. O posicionamento modificado melhora a avaliação nas demais variáveis da avaliação das métricas, porém, nesse caso o otimizado desde o início da jogada teve uma avaliação superior ao posicionamento modificado e o original. A piora no posicionamento modificado ocorre pela escolha do robô que foi utilizado para atacar a bola.

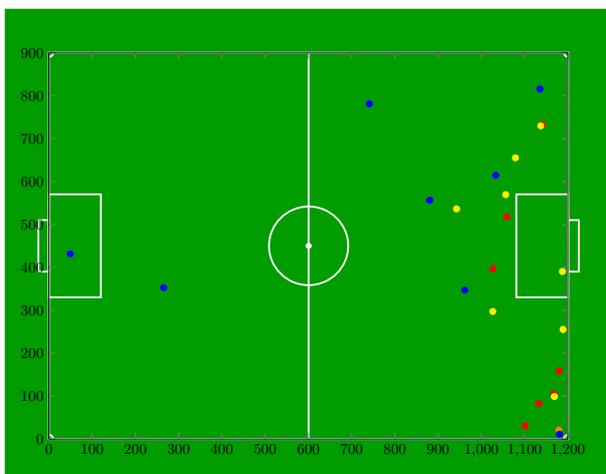
Por fim, a figura 87 ressalta 2 situações a respeito da função de aptidão para passe. Que no início da jogada os posicionamentos encontrados são os adequados para impedir a continuidade da jogada, porém no decorrer das avaliações os novos posicionamentos não mantiveram sua efetividade.

### 7.8.3 Análise defesa – métrica do passe

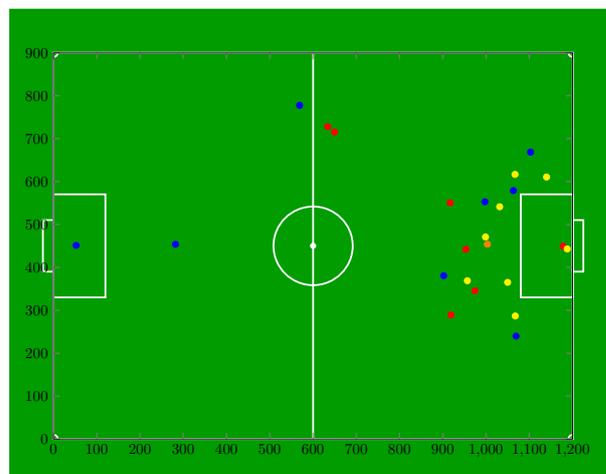
A análise do posicionamento defensivo com a métrica de avaliação de bloqueio de passe visa determinar se o posicionamento encontrado poderia ser aplicado como estratégia de bloqueio de passes.

Figura 85 – Jogo 04 – PSO em modo defesa

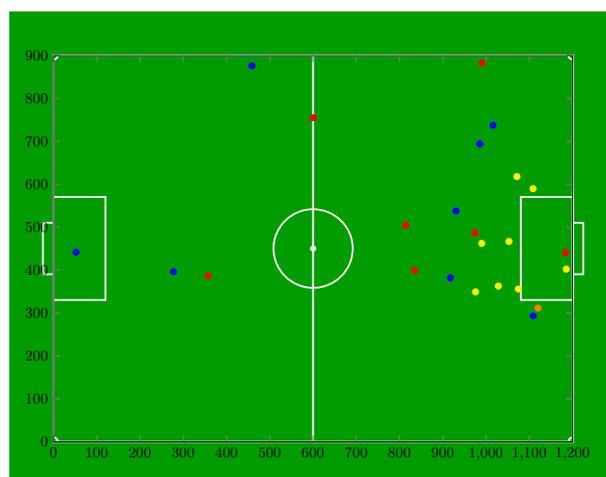
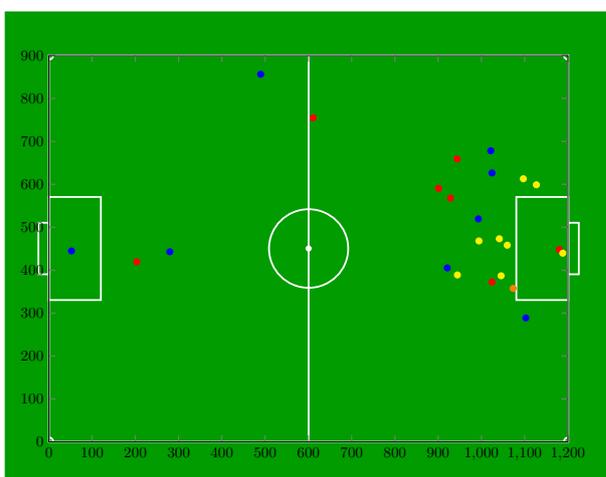
(a) Momento do início da jogada.



(b) Robô recebendo a bola.



(c) Bola indo em direção ao robô adversário. (d) 1º chute a gol.



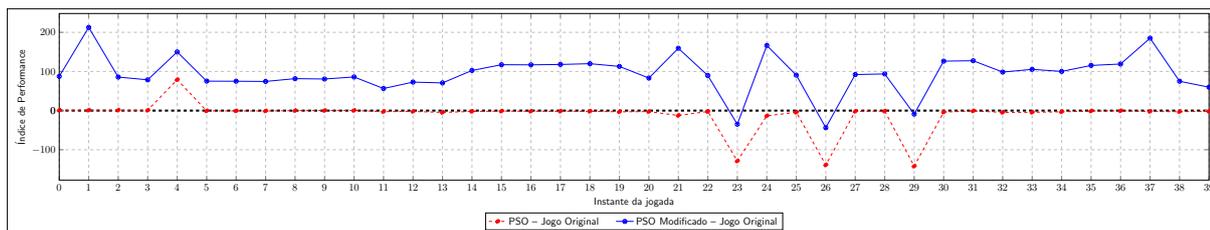
Fonte: Autor

O destaque do posicionamento defensivo para atuar como bloqueio de passes (figura 88) corrobora sua efetividade para bloqueio de passes em jogadas próximas a área frontal do gol.

#### 7.8.4 Análise passe – métrica da defesa

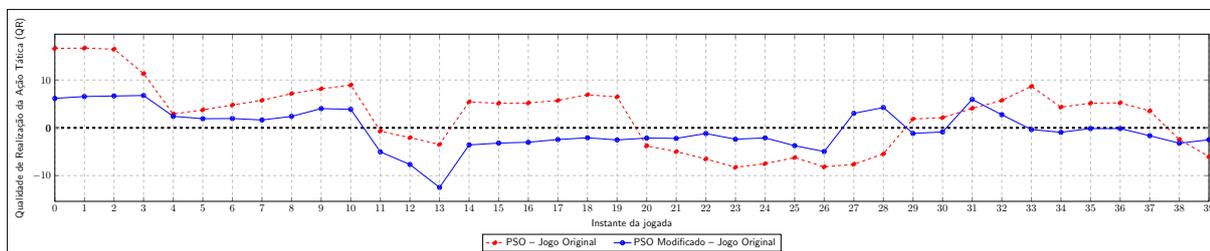
O gráfico na figura 89 aponta que no início da jogada o posicionamento de passe teria boa atuação como opção de defesa. A jogada inicia-se longe da área frontal do

Figura 86 – Jogo 04 – Comparação jogo original com otimização – PSO em modo passe.



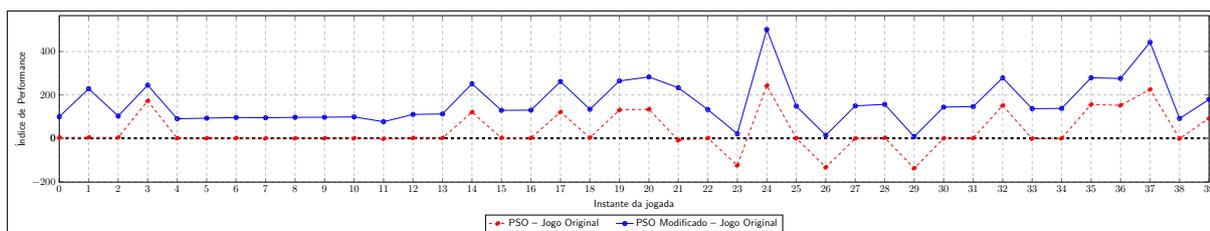
Fonte: Autor

Figura 87 – Jogo 04 – Análise da qualidade do posicionamento (QR) – PSO em modo passe.



Fonte: Autor

Figura 88 – Jogo 04 – Posicionamento de defesa avaliada com métrica do passe – PSO em modo defesa.



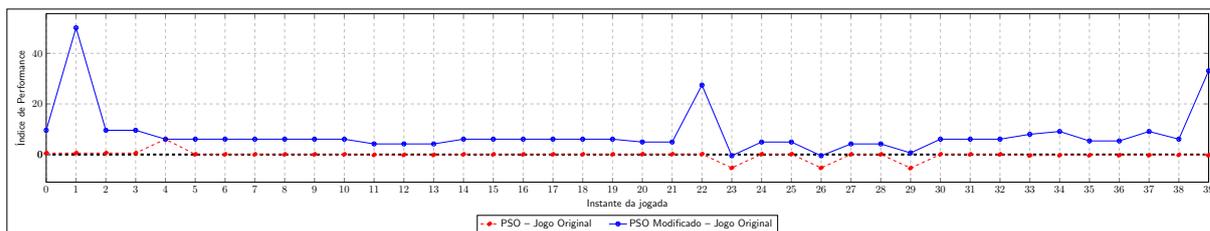
Fonte: Autor

gol. Contudo, na continuidade o novos posicionamentos não demonstraram a mesma efetividade defensiva.

### 7.8.5 Análise conjunta das métricas – passe e defesa

Para esses experimentos, os posicionamentos da defesa e passe foram comparados em conjunto com as métricas de defesa e passe para cálculo do IPOS geral.

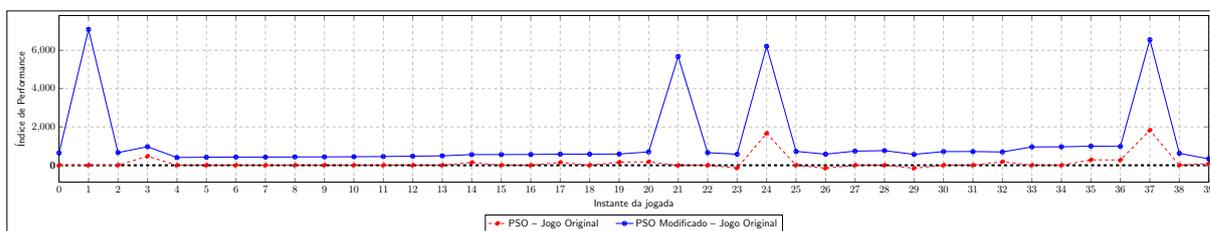
Figura 89 – Jogo 04 – Posicionamento de passe avaliada com métrica da defesa – PSO em modo passe.



Fonte: Autor

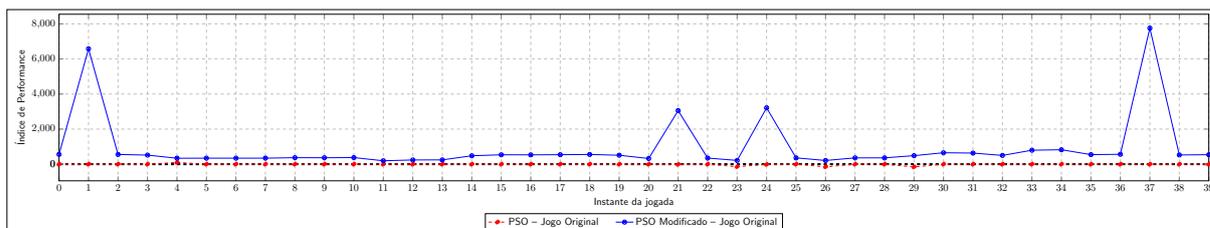
As figuras 90 e 91 evidenciam o resultado dos posicionamentos otimizados simulando o ataque a bola. Considerando apenas as linhas vermelhas das figuras, o resultado da aplicação conjunta das métricas para a jogada se anularam. O posicionamento defensivo teve um bom resultado na métrica de passe e o inverso não ocorreu.

Figura 90 – Jogo 04 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de defesa.



Fonte: Autor

Figura 91 – Jogo 04 – Métrica de defesa e passe aplicada em conjunto na função de aptidão de passe.



Fonte: Autor

### 7.8.6 Discussão e análises

A função de aptidão para bloqueio de passes tem dificuldades para encontrar bons posicionamentos em jogadas com bola em frente ao gol e com muitos robôs adversários próximos. A tentativa de diminuir o espaço de todos nessas situações não garante um bom resultado. Para esses casos a função de aptidão de defesa mostrou-se mais eficiente. Contudo, no início da jogada o posicionamento defensivo do passe mostrou-se eficiente para diminuir o espaço do portador da bola e dificultar o passe e também pela marcação junto aos demais adversários. Em todas as análises o posicionamento inicial de defesa e passe demonstraram que haveria possibilidades de bloqueio da jogada.

A função de aptidão de defesa mostrou-se mais efetiva para proteção do gol e para bloqueio de passes em jogadas com muitos robôs aglomerados na área frontal do gol. Inclusive, como pode ser observado na análise individual da defesa o robô adversário que realizou o passe e pegou o rebote da bola foi marcado durante toda a jogada. Esse comportamento de marcação, que é o desejado no futebol, impediria a realização do gol.

## 7.9 JOGO 04 – LOWER 2–1 – Segundo gol

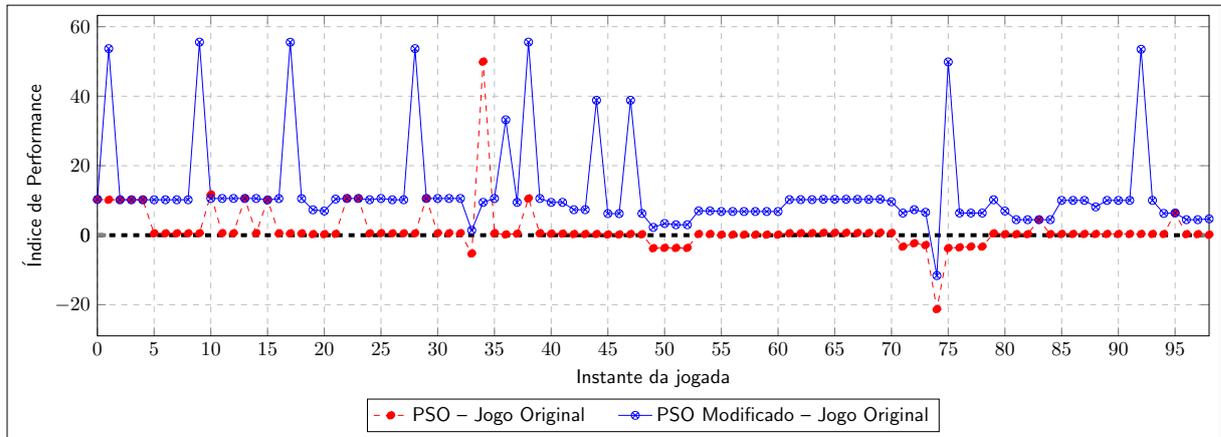
Jogo realizado na fase oitava de final entre as equipes RoboDragons (equipe amarela) e TIGERs Mannheim (equipe azul). A jogada total, após tratamento do registro histórico, é composta de 99 instantes. O placar do jogo foi 4x0 para o time azul considerado atacante nesta partida. O gol analisado teve como origem uma jogada de bola parada (INDIRECT\_FREE\_BLUE).

### 7.9.1 Análise defesa

Para a otimização de defesa, a figura 92 demonstra na comparação que no início da jogada, o posicionamento original (linha em vermelho) indica a interrupção da jogada. Porém, o destaque nessa figura é dado pelo ponto negativo no instante 74. Na figura 93 esse momento da jogada está representado.

Na figura 93 o robô amarelo está tocando a bola e o posicionamento otimizado está próximo. Nas métricas esse toque na bola indica possibilidade de recuperação, mas o passe de bola pela equipe azul ocorre logo na sequência com marcação do gol. Porém,

Figura 92 – Jogo 04 – Segundo gol – Comparação jogo original com otimização – PSO em modo defesa.



Fonte: Autor

o destaque nesse posicionamento se dá pela distribuição dos demais robôs otimizados. Inicialmente há um robô obstruindo a linha do robô com a bola e os demais marcando diretamente os robôs adversários. Esse posicionamento dificultaria conclusão do passe e o gol posteriormente.

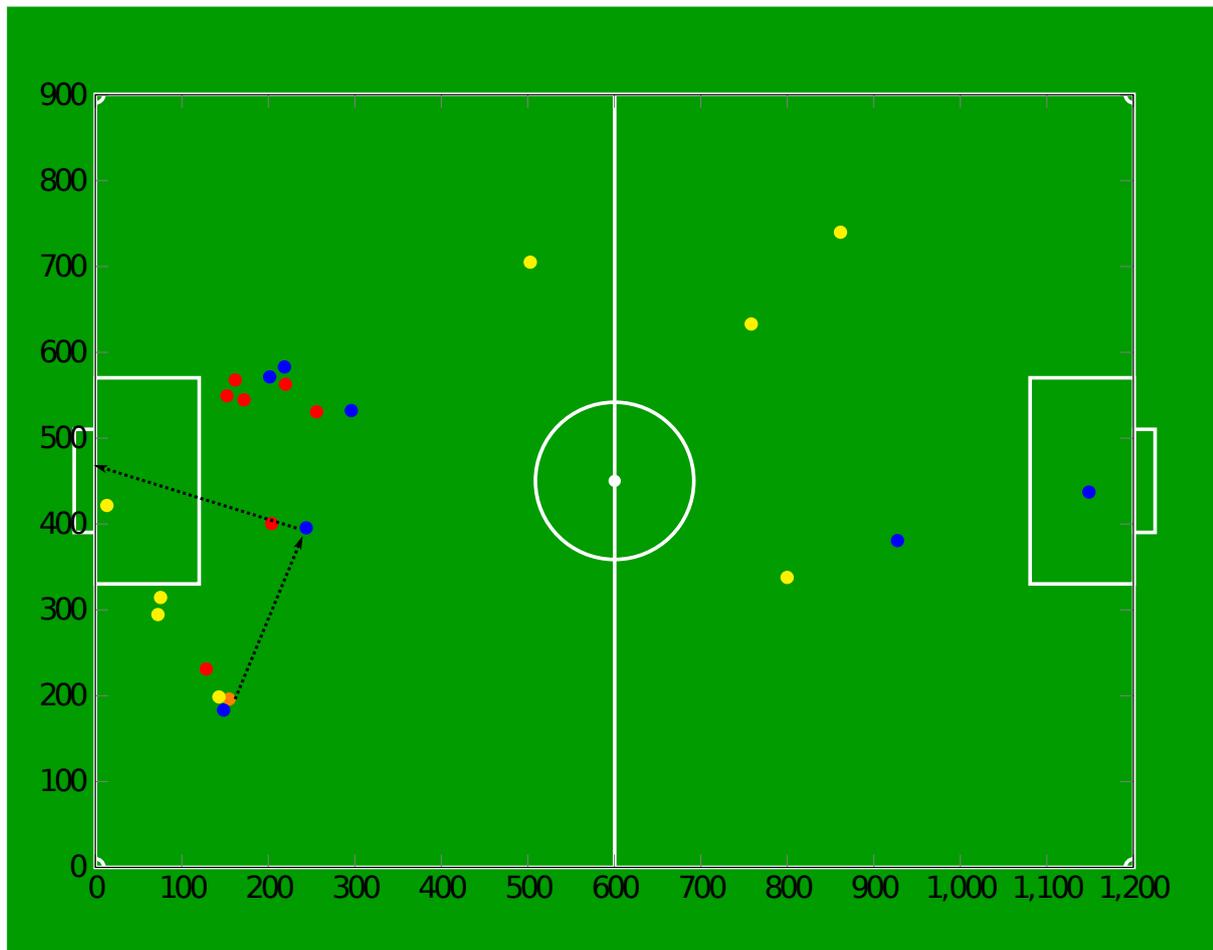
Por fim, a figura 94 apresenta o desempenho do posicionamento de defesa com a métrica que avalia o passe. O desempenho superior nessa avaliação demonstra que o posicionamento defensivo em jogadas realizadas próxima a área frontal do gol é extremamente efetivo. O destaque é o posicionamento modificado ser superior ao longo de toda a jogada. Nesse caso, a escolha do robô para combater a robô adversário com a bola demonstrou efetividade.

### 7.9.2 Análise do passe

A otimização do passe está representada na figura 95. A comparação no início da jogada demonstra que o posicionamento original (linha em vermelho) é inferior ao posicionamento modificado (linha em azul). Porém, o destaque é o ponto negativo no mesmo instante da defesa. Na figura 96 esse momento da jogada está representado.

Na figura 96 o robô amarelo está tocando a bola e o posicionamento otimizado está próximo. Nas métricas esse toque na bola indica possibilidade de recuperação, mas o passe de bola ocorre logo na sequência com marcação do gol. O destaque se dá pelo

Figura 93 – Jogo 04 – Segundo gol – PSO em modo defesa



Fonte: Autor

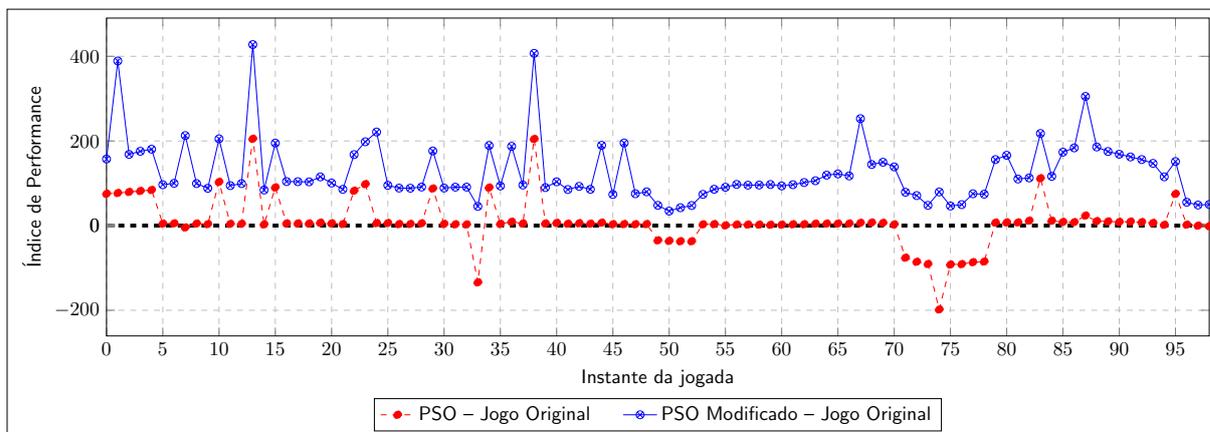
posicionamento otimizado dos robôs. O adversário está sob pressionamento por área, ou seja, com aumento de possibilidade de perder o domínio da bola por drible ou passe errado. Os quatro adversários próximos a área estão sendo ativamente marcados por três defensores.

As figuras 97a e 97b representam os instantes 80 e 87 da figura 95. As métricas de avaliação indicam aumento do IPOS relacionado com os posicionamentos em campo que estão dificultando a continuidade da jogada.

### 7.9.3 Discussão e análises

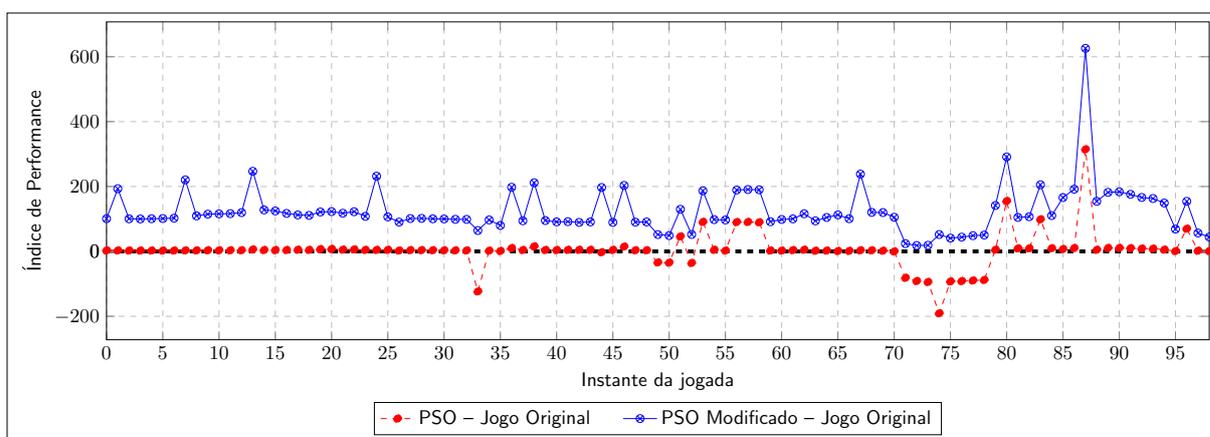
Essa jogada demonstrou que o uso adequado dos critérios defensivos utilizados no futebol moderno aplicados nos jogos de futebol de robôs aumentariam a eficiência defen-

Figura 94 – Jogo 04 – Segundo gol – Comparação jogo original com otimização – PSO em modo defesa avaliado com métrica de passe.



Fonte: Autor

Figura 95 – Jogo 04 – Segundo gol – Comparação jogo original com otimização – PSO em modo passe.

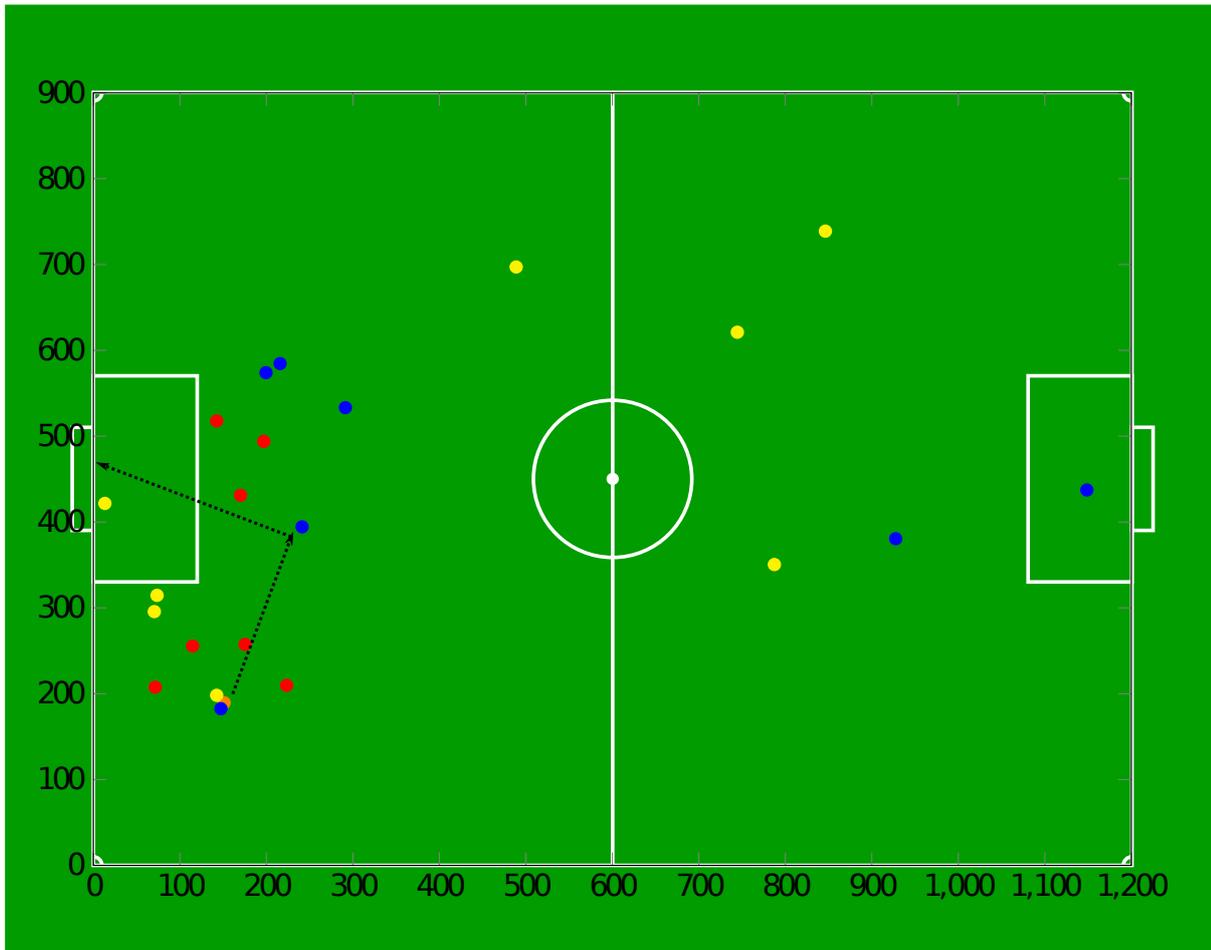


Fonte: Autor

siva das equipes. Nesse cenário o foco sai da marcação individual ao adversário com o posse da bola para a marcação coletiva.

Os posicionamentos para defesa atuariam adequadamente para bloqueio de passes em jogadas na área frontal do gol. E a inspeção visual dos posicionamentos encontrados nos pontos negativos dos gráficos de avaliação demonstram sua efetividade.

Figura 96 – Jogo 04 – Segundo gol – PSO em modo passe



Fonte: Autor

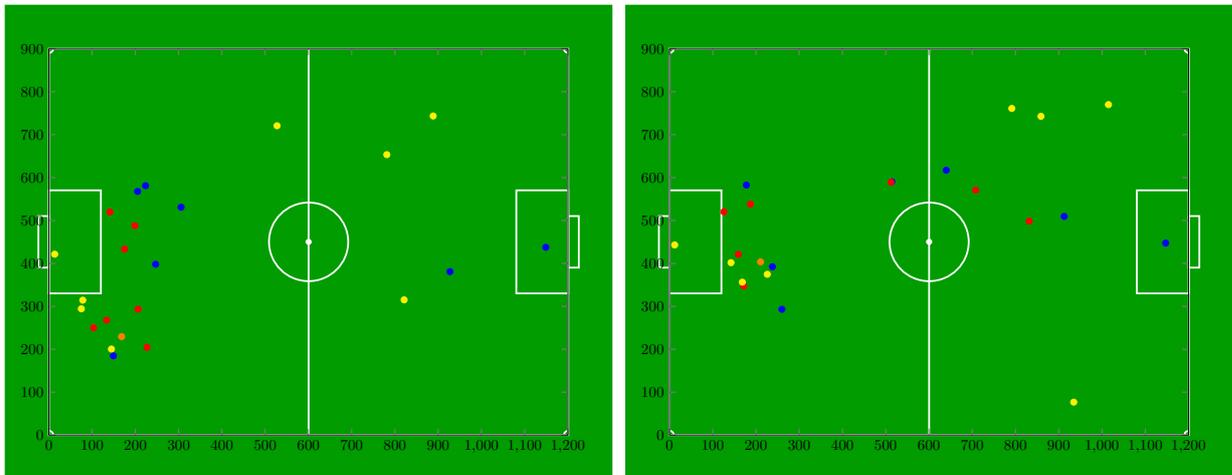
#### 7.10 JOGO 05 – A1–A2 – Primeiro gol

Jogo realizado na fase de grupos entre as equipes MRL (equipe azul) e TIGERs Mannheim (equipe amarelo). A jogada total, após tratamento do registro histórico, é composta de 175 instantes. O placar do jogo foi  $3 \times 1$  para o time amarelo considerado atacante nesta partida. O gol analisado teve como origem DIRECT\_FREE\_YELLOW. Essa jogada teve uma forte disputa de bola no meio do campo. Na análise das métricas, essa disputa pode ser observada nos pontos negativos dos gráficos já que a defesa estar tocando na bola tem peso maior.

Figura 97 – Jogo 04 – Segundo gol – PSO em modo passe

(a) Instante 80.

(b) Instante 87.

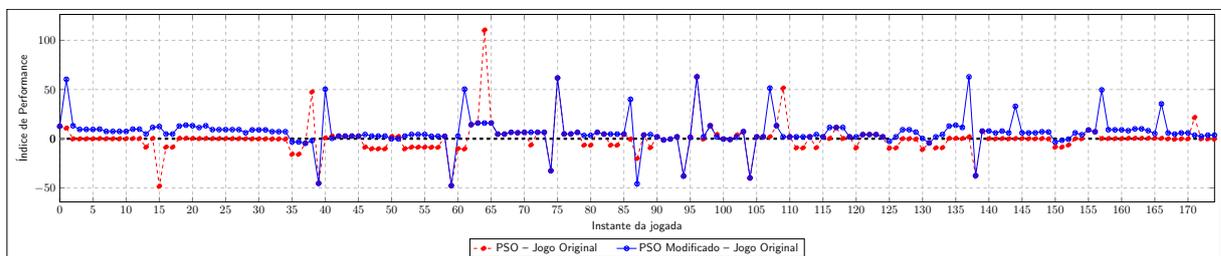


Fonte: Autor

### 7.10.1 Análise defesa

Para a otimização de defesa, a figura 98 demonstra na comparação que no início da jogada, o posicionamento original (linha em vermelho) indica a interrupção da jogada. O goleiro será considerado o da jogada original e não é alterado ou afetado pelo sistema de posicionamento. Porém, o destaque nessa figura é dado pelo instante inicial do jogo (figura 99a) e no final da jogada (figura 99b).

Figura 98 – Jogo 05 – Primeiro gol – Comparação jogo original com otimização – PSO em modo defesa.



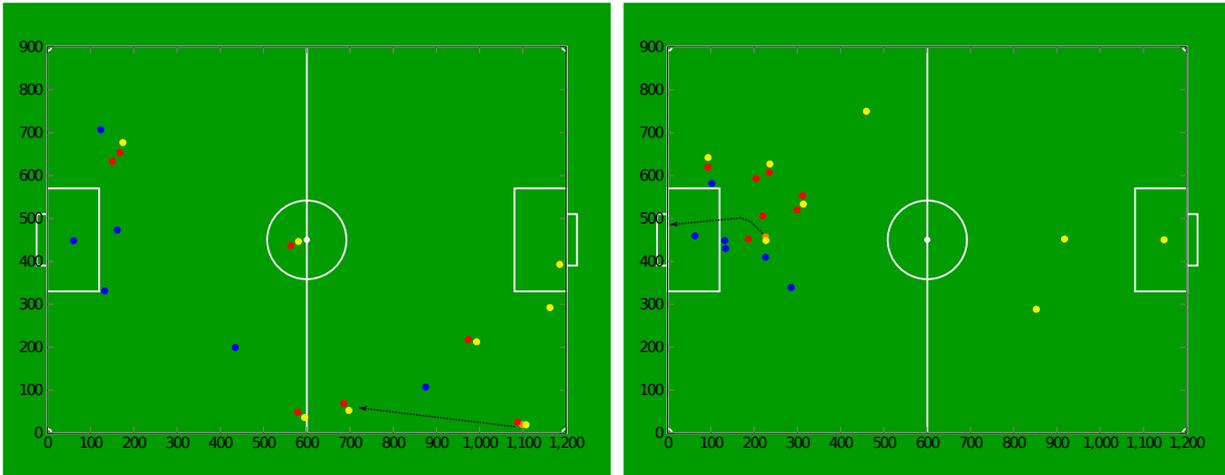
Fonte: Autor

Nas figuras 99a e 99b observa-se que os PSO posicionamentos otimizados estão possibilitando o ataque a bola e uma forte marcação nos robôs amarelos. Na jogada original, o passe da bola ocorreu na lateral do campo. Com o posicionamento otimizado provavel-

Figura 99 – Jogo 05 – Primeiro gol – PSO em modo defesa.

(a) Momento do início da jogada.

(b) Momentos antes do chute a gol.

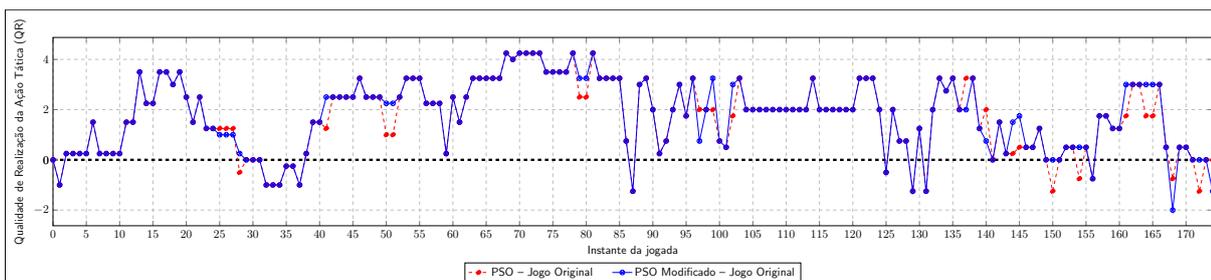


Fonte: Autor

mente esse passe não ocorreria. E o trajeto final realizado pelo adversário, evidenciado na figura 99b, estaria parcialmente bloqueados pelos robôs defensores otimizados.

A análise das variáveis isoladamente (figuras 100 e 101) demonstram que ao longo da jogada em vários momentos ocorreria a possibilidade de interrupção da jogada.

Figura 100 – Jogo 05 – Primeiro gol – Análise da qualidade do posicionamento (QR) – PSO em modo defesa.

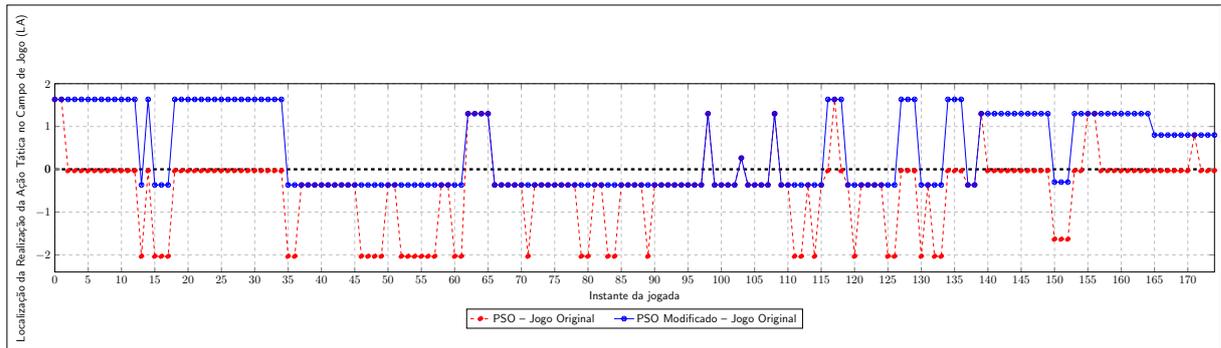


Fonte: Autor

### 7.10.2 Análise do passe

A otimização do passe está representada na figura 102. A comparação no início da jogada demonstra que o posicionamento original (linha em vermelho) é inferior ao posicionamento modificado (linha em azul). Porém, o destaque são os pontos negativos entre

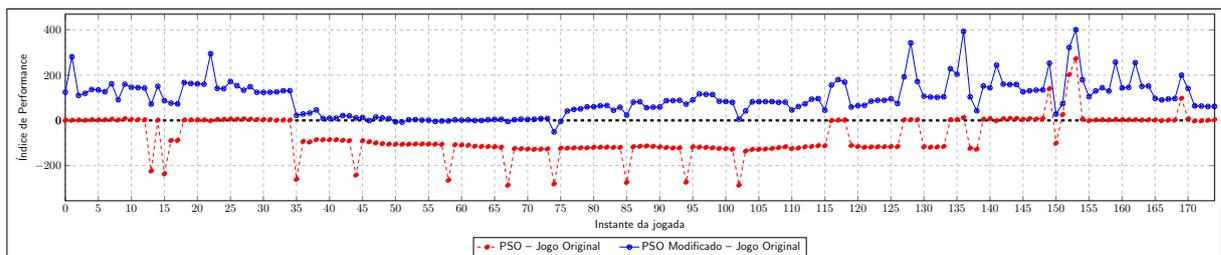
Figura 101 – Jogo 05 – Primeiro gol – Análise da localização em campo (LA) – PSO em modo defesa.



Fonte: Autor

o instante 35 e 115. Nesse intervalo, o posicionamento de bloqueio de passe otimizado visa obstruir a visão do jogador portador da bola. As figuras 103a e 103b ilustram dois momentos desse intervalo negativo. Os robôs adversários (equipe amarela) estão com visão obstruída e marcados por proximidade.

Figura 102 – Jogo 05 – Primeiro gol – Comparação jogo original com otimização – PSO em modo passe.

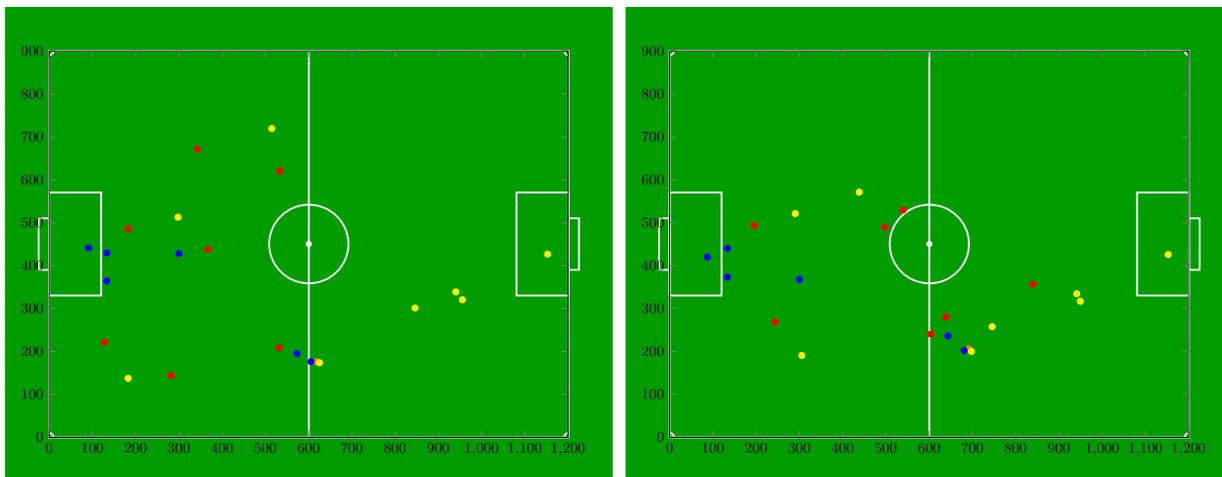


Fonte: Autor

A efetividade do posicionamento pode ser observado nas variáveis QR (figura 104) que avalia a qualidade do posicionamento e RA (figura 105) que avalia o resultado da ação. Nesse caso, o posicionamento otimizado foi ao longo de todo o intervalo mais efetivo. A escolha errada do robô para simular o ataque a bola diminuiu a efetividade do posicionamento (linha azul).

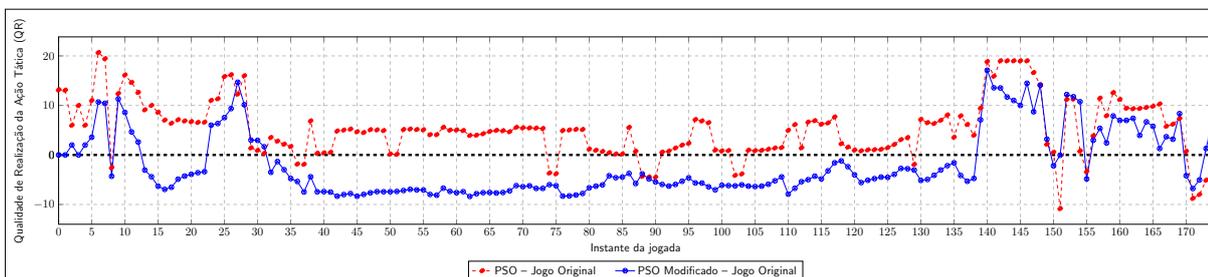
Figura 103 – Jogo 05 – Primeiro gol – Adversários com visão bloqueada para passe – PSO em modo passe.

(a) Amarelos bloqueados pelos vermelhos (b) Amarelos bloqueados pelos vermelhos



Fonte: Autor

Figura 104 – Jogo 05 – Primeiro gol – Análise da qualidade do posicionamento (QR)– PSO em modo passe.



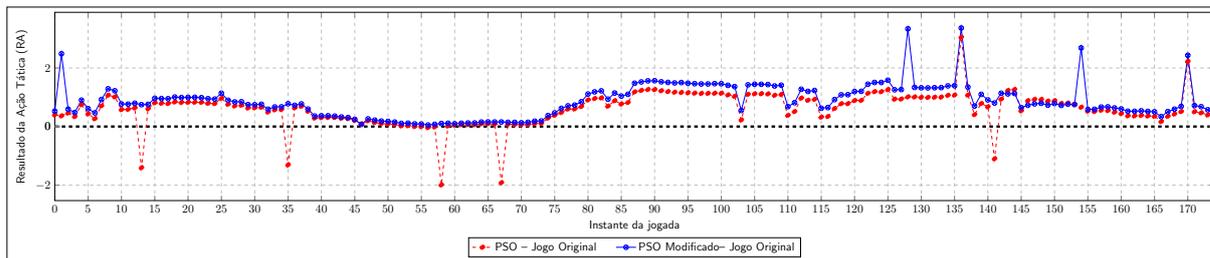
Fonte: Autor

### 7.10.3 Discussão e análises

As figuras 106 e 107 demonstram que os posicionamentos encontrados atuariam adequadamente em cenários diferentes. Ambos, após modificação, teriam boas chances de impedir a continuidade da jogada.

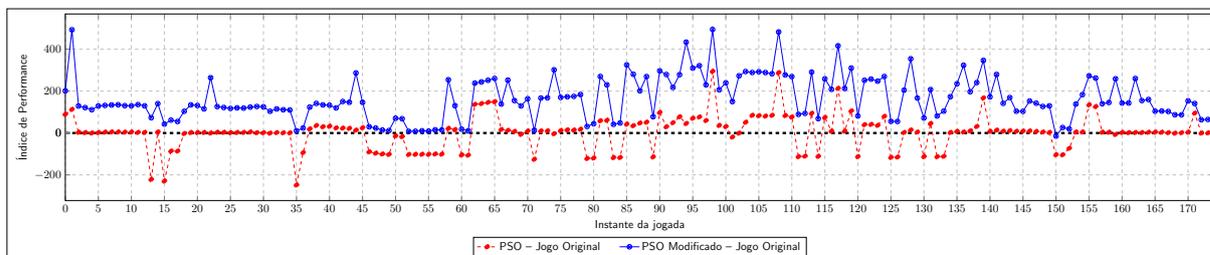
Embora as equações tenham sido desenvolvidas com foco em jogadas de bola parada, empiricamente acreditava-se que as equações obteriam bons resultados durante as análises com a bola em movimento. Por ser uma jogada longa, com disputa de bola e troca de passes em vários momentos, as características dessa jogada permitiram certificar esses resultados.

Figura 105 – Jogo 05 – Primeiro gol – Análise do resultado da ação (RA)– PSO em modo passe.



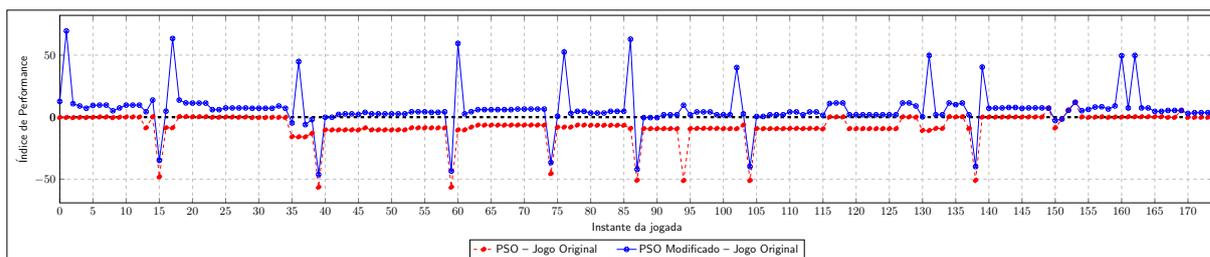
Fonte: Autor

Figura 106 – Jogo 05 – Primeiro gol – Posicionamento defesa analisado com métrica do passe – PSO em modo defesa.



Fonte: Autor

Figura 107 – Jogo 05 – Primeiro gol – Posicionamento passe analisado com métrica da defesa – PSO em modo passe.



Fonte: Autor

A equipe TIGERs Mannheim tem na ofensividade a sua principal característica, com bom controle de bola e trocas de passes com precisão. A equipe MRL, com a estratégia de marcar a bola, demonstrou em vários momentos fragilidades na marcação. Os robôs adversários sem posse bola trocavam de posição em campo em vários momentos, para facilitar a recepção de passes, e a equipe amarela continuava com os robôs defensores

no mesmo lugar. O posicionamento otimizado por sua vez, acompanhava e realizava a marcação junto a esses adversários sem no entanto desproteger a linha de visão do gol.

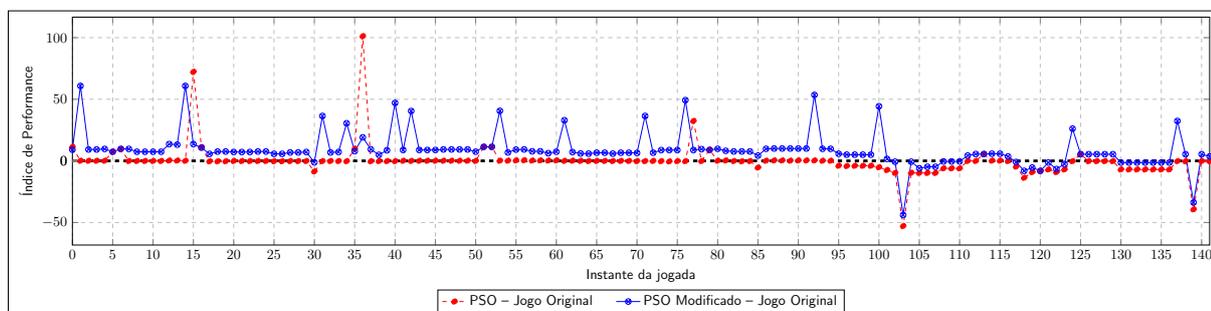
### 7.11 JOGO 05 – A1–A2 – Segundo gol

Jogo realizado na fase de grupos entre as equipes MRL (equipe azul) e TIGERs Mannheim (equipe amarelo). A jogada total, após tratamento do registro histórico, é composta de 142 instantes. O placar do jogo foi  $3x1$  para o time amarelo considerado atacante nesta partida. O gol analisado teve como origem INDIRECT\_FREE\_YELLOW. Essa jogada teve uma forte disputa de bola próxima a entrada da área do gol. Na análise das métricas, essa disputa pode ser observada nos pontos negativos dos gráficos já que estar tocando na bola tem peso maior.

#### 7.11.1 Análise defesa

Para a otimização de defesa, a figura 108 demonstra na comparação que no início da jogada, o posicionamento original (linha em vermelho) indica a interrupção da jogada. As figuras 109a, 109b, 110a e 110b ilustram vários momentos do jogo. Nessas figuras podem ser observados que os posicionamentos defensivos estavam oferecendo combate ao adversário. Inclusive com possibilidades de interceptar a bola em vários momentos do jogo antes dela chegar próximo ao gol.

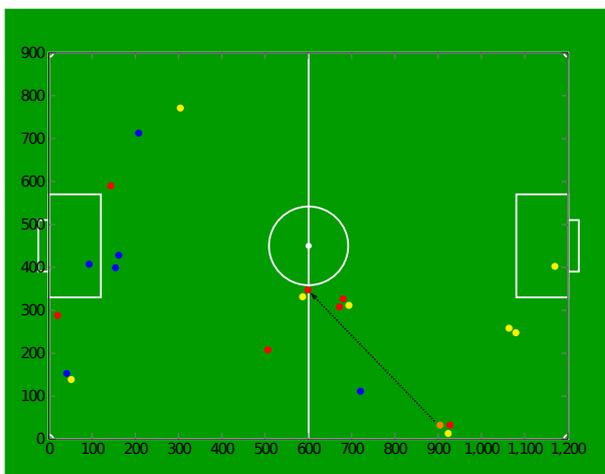
Figura 108 – Jogo 05 – Segundo – Comparação jogo original com otimização – PSO em modo defesa.



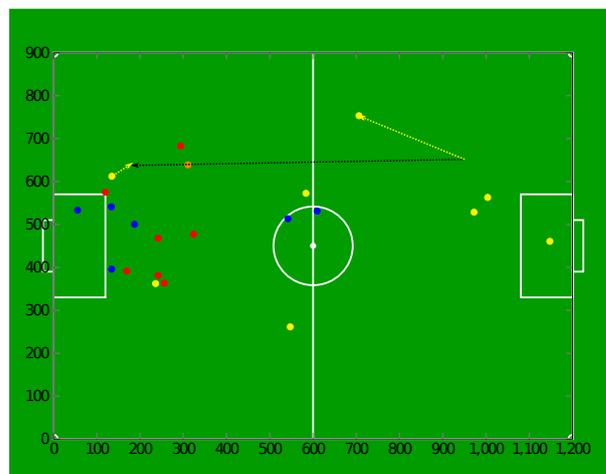
Fonte: Autor

Figura 109 – Jogo 05 – Segundo gol – PSO em modo defesa.

(a) Momento do início da jogada



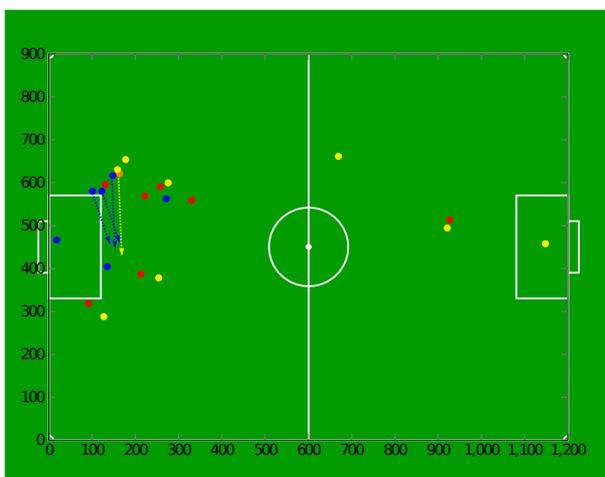
(b) Momentos antes recepção do passe



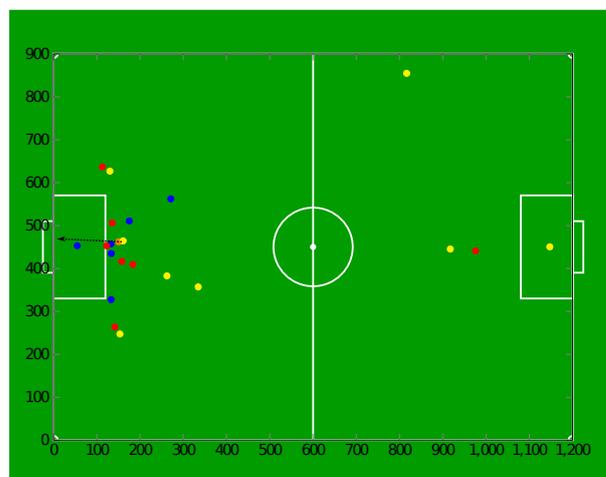
Fonte: Autor

Figura 110 – Jogo 05 – Segundo gol – PSO em modo defesa.

(a) Tentativa de chegar próximo ao gol.



(b) Equipe perde controle da bola e toma gol.



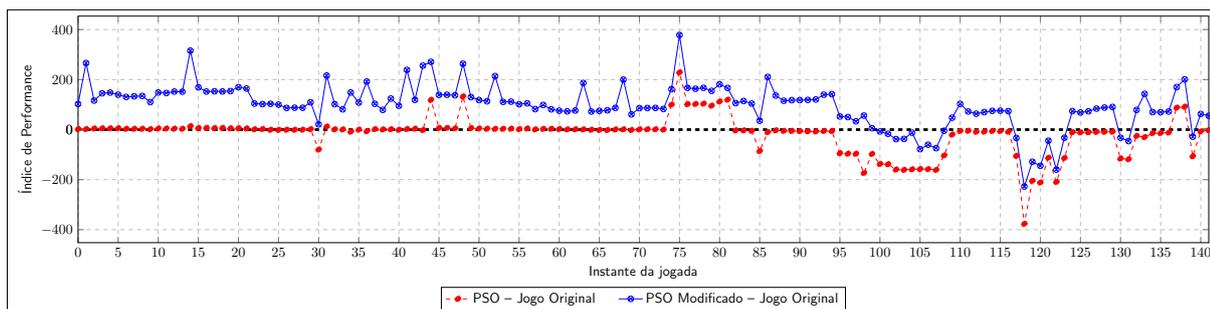
Fonte: Autor

### 7.11.2 Análise do passe

A otimização do passe está representada na figura 111. A comparação no início da jogada demonstra que o posicionamento original (linha em vermelho) é inferior ao posicionamento modificado (linha em azul). Porém, o destaque são os pontos negativos a partir do instante 95. A partir desse momento a jogada estava sendo realizada próxima à área frontal do gol e, como já constatado anteriormente, a função de aptidão de passe

tem dificuldades para otimizar posicionamentos para bloqueio de passe nessa região do campo. Nesse caso, o ideal seria a otimização do posicionamento com a função de aptidão da defesa. Essa dificuldade pode ser constatada pela análise da figura 114 que pontua a qualidade do posicionamento.

Figura 111 – Jogo 05 – Segundo gol – Comparação jogo original com otimização – PSO em modo passe.



Fonte: Autor

As figuras 112a, 112b e 113a ilustram vários momentos do jogo. Nessas figuras podem ser observado que os posicionamentos de bloqueio estavam oferecendo combate ao adversário. Inclusive com possibilidades de interceptar a bola em vários momentos do jogo antes dela chegar próximo ao gol. Contudo a figura 113b ilustra a dificuldade em encontrar um bom posicionamento em jogadas próximas a área frontal do gol. Embora todos os robôs adversários estivessem sendo corretamente marcados, o posicionamento não seria bom o suficiente para atuar defensivamente para proteção do gol.

### 7.11.3 Discussão e análises

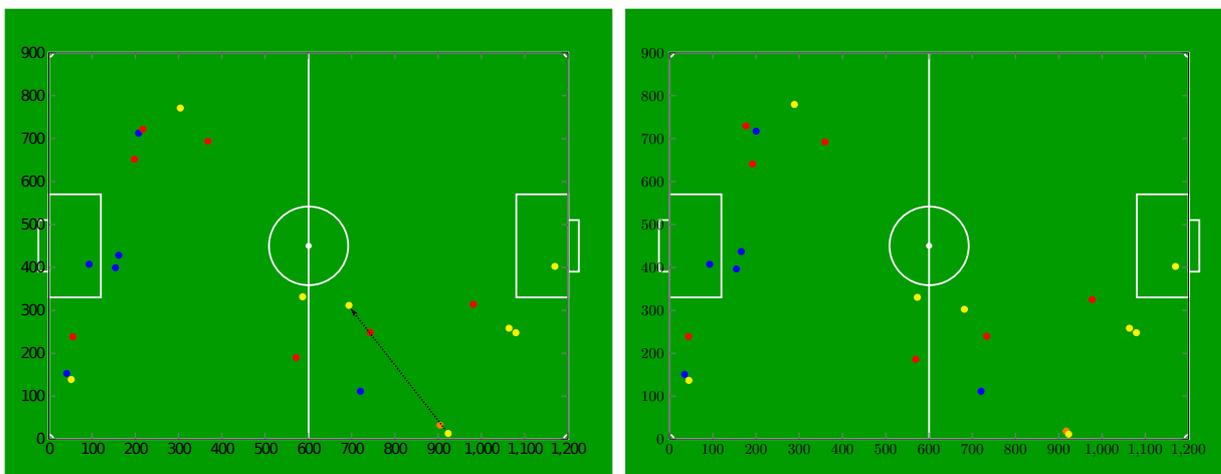
As figuras 115 e 116 demonstram que os posicionamentos encontrados atuariam adequadamente em cenários diferentes. Ambos, após modificação, teriam boas chances de impedir a continuidade da jogada.

Embora as equações tenham sido desenvolvidas com foco em jogadas de bola parada, empiricamente acreditava-se que as equações obteriam bons resultados durante as análises com a bola em movimento. Por ser uma jogada longa, com disputa de bola e troca de passes em vários momentos, as características dessa jogada permitiram certificar esses resultados.

Figura 112 – Jogo 05 – Segundo gol – PSO em modo passe.

(a) Momento do início da jogada.

(b) Momentos antes recepção do passe.

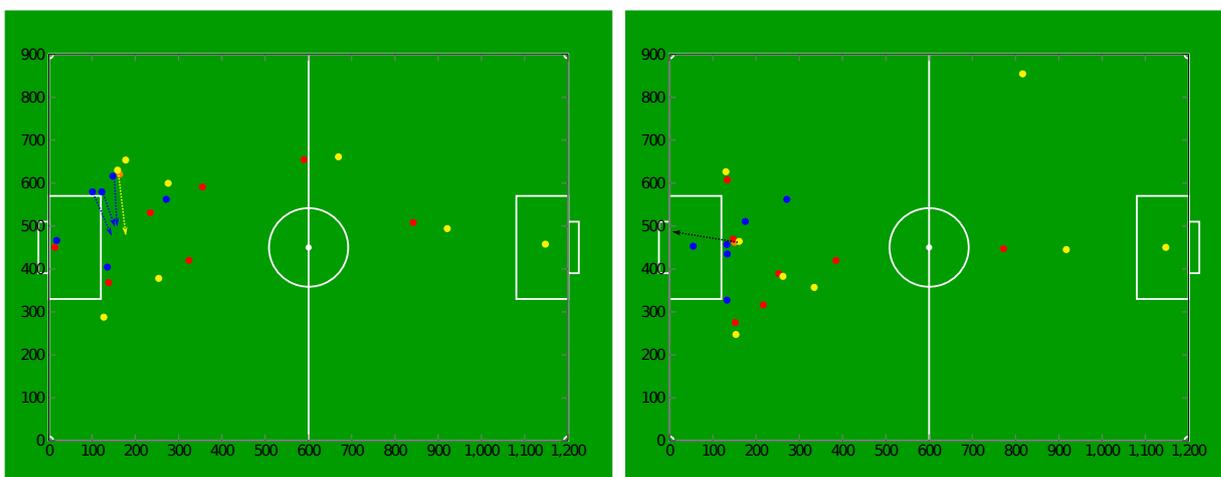


Fonte: Autor

Figura 113 – Jogo 05 – Segundo gol – PSO em modo passe.

(a) Tentativa de chegar próximo ao gol.

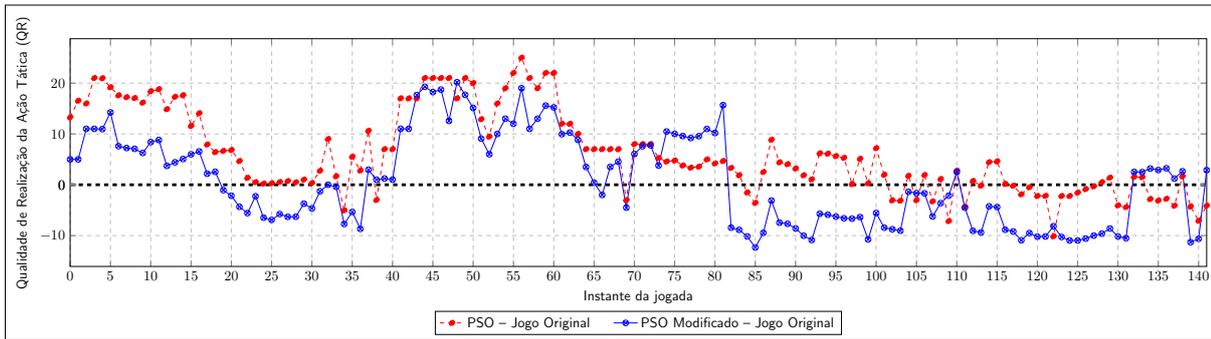
(b) Equipe perde controle da bola e toma gol.



Fonte: Autor

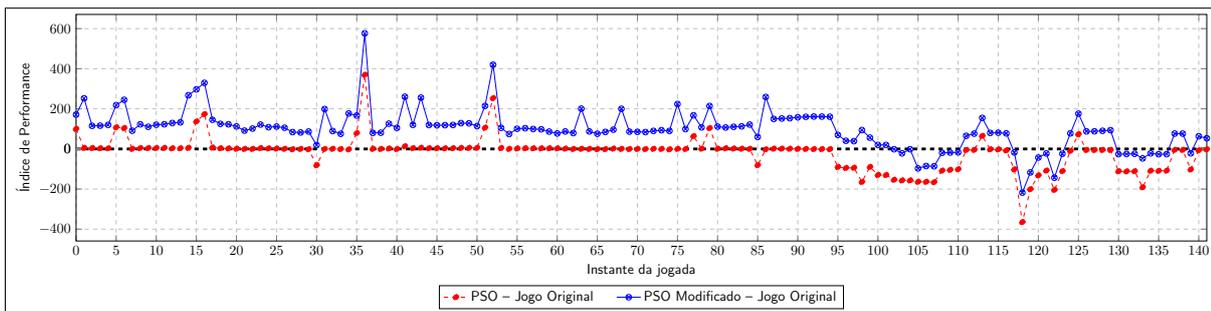
Como constatado em outras análises, a equação de aptidão para bloqueio de passes não consegue encontrar bons posicionamentos próximos a área frontal do gol quando existem vários robôs aglomerados.

Figura 114 – Jogo 05 – Segundo gol – Análise da qualidade do posicionamento (QR) – PSO em modo passe.



Fonte: Autor

Figura 115 – Jogo 05 – Segundo gol – Posicionamento defesa analisado com métrica do passe – PSO em modo defesa.



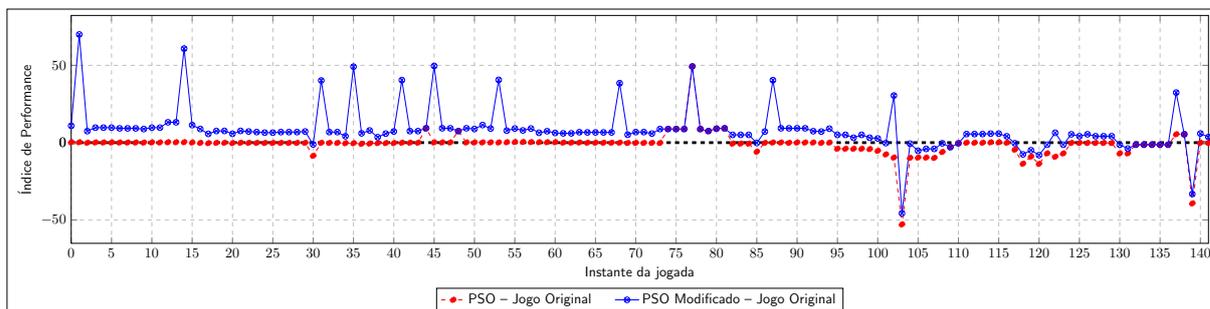
Fonte: Autor

## 7.12 JOGO 06 – LOWER 3

Jogo realizado na quartas de finais entre as equipes TIGERs Mannheim (equipe amarela) e MRL (equipe azul). A jogada total, após tratamento do registro histórico, é composta de 9 instantes. O placar do jogo foi  $2x0$  para o time azul considerado atacante nesta partida. O gol analisado teve como origem uma jogada de bola parada (INDIRECT\_FREE\_BLUE).

As figuras 117a e 117b mostram, respectivamente, posicionamento para a função de aptidão de defesa e passe. As figuras demonstram que no momento do chute a gol, o robô adversário seria marcado. Com destaque para o posicionamento de bloqueio de passe, que nessa situação atuou de forma semelhante as equipes que utilizam o delta defensivo.

Figura 116 – Jogo 05 – Segundo gol – Posicionamento passe analisado com métrica da defesa – PSO em modo passe.



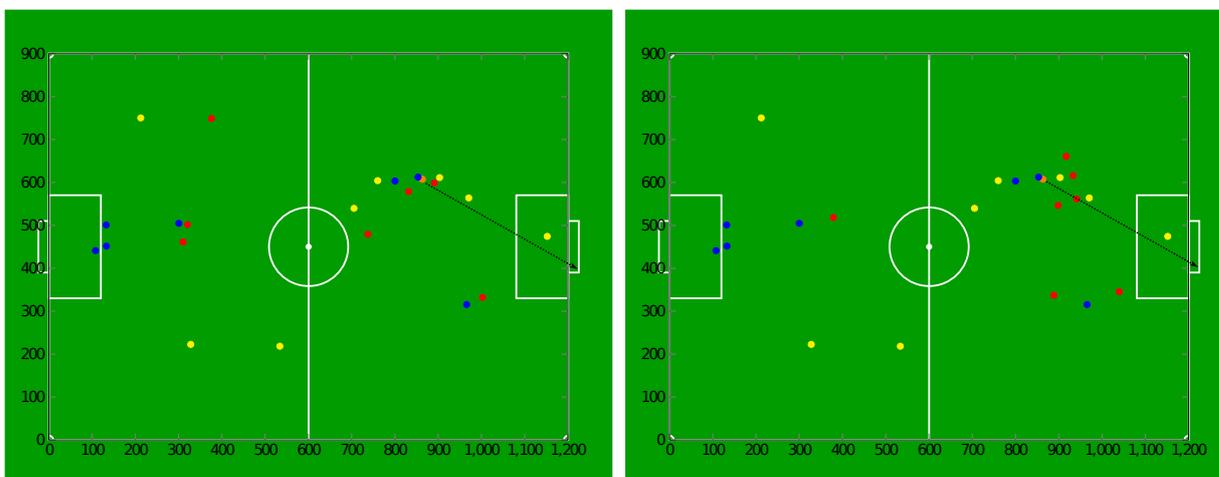
Fonte: Autor

A verificação do desempenho dos posicionamento podem ser observados nas figuras 118a, 118b, 119a e 119b.

Figura 117 – Jogo 06 – Início do jogo.

(a) PSO em modo defesa.

(b) PSO em modo passe.

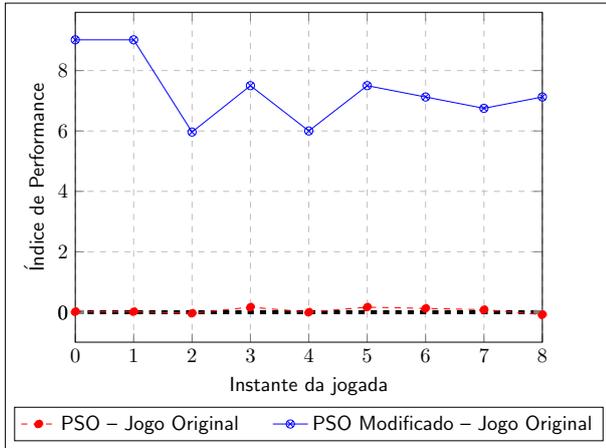


O destaque é dado pelas figuras 119a e 119b que avaliaram a defesa com a métrica do passe e o passe com a métrica da defesa. Nessa jogada, o passe teve forte atuação defensiva, o que pode ser observado na figura 117b.

Essa análise demonstra que a otimização do posicionamento para defesa deve ocorrer apenas com os robôs adversários ativos na jogada. Assim, mais robôs teriam atuado próximo a área nessa situação. Porém, cabe ao sistema de estratégia decidir quais os robôs adversários que devem ser marcados.

Figura 118 – Jogo 06 – Gráficos de análise.

(a) PSO em modo defesa.



(b) PSO em modo passe.

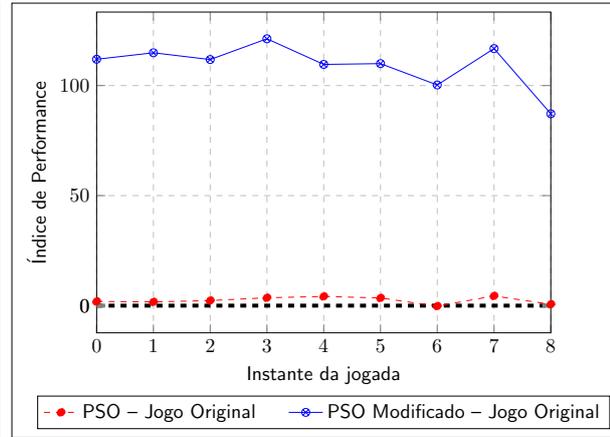
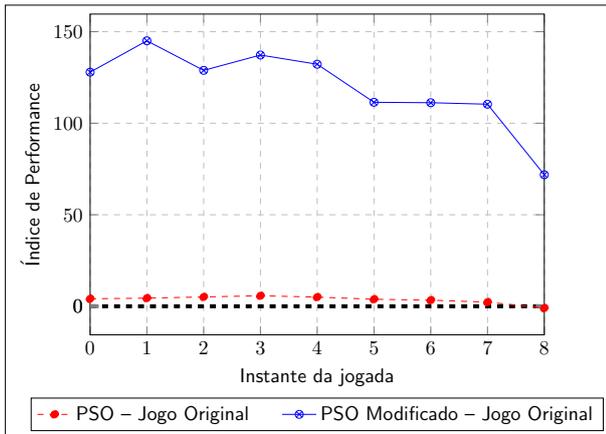
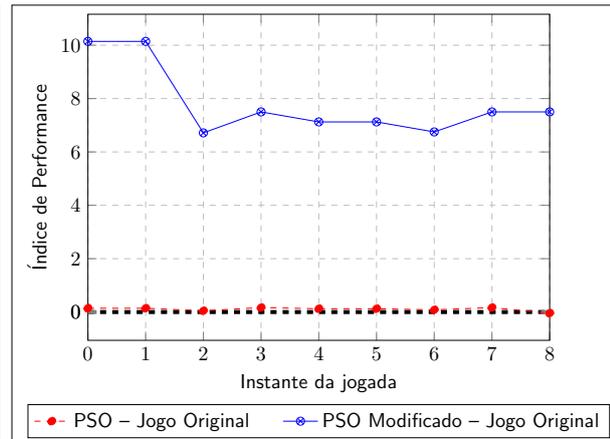


Figura 119 – Jogo 06 – Gráficos de análise.

(a) Defesa analisado como passe – PSO em modo defesa.



(b) Passe analisado como defesa – PSO em modo passe.



### 7.13 JOGO 07 – B3–B4

Jogo realizado na fase de grupos entre as equipes RoboTeam Twente (equipe amarela) e Robodragons (equipe azul). O placar do jogo foi 3x0 para o time azul considerado atacante nesta partida. Na análise do vídeo das jogadas, percebe-se que a RoboTeam Twente tem problemas com seus robôs. Os mesmos permanecem paralisados em suas posições originais.

As figuras 120a e 120b mostram, respectivamente, posicionamento para a função de aptidão de defesa e passe no primeiro gol. As figuras 121a e 121b mostram, respec-

tivamente, posicionamento para a função de aptidão de defesa e passe no segundo gol. As figuras demonstram em ambas as situações que no momento do chute a gol, o robô adversário seria marcado.

Figura 120 – Jogo 07 – Início do jogo – Primeiro gol.

(a) PSO em modo defesa.

(b) PSO em modo passe.

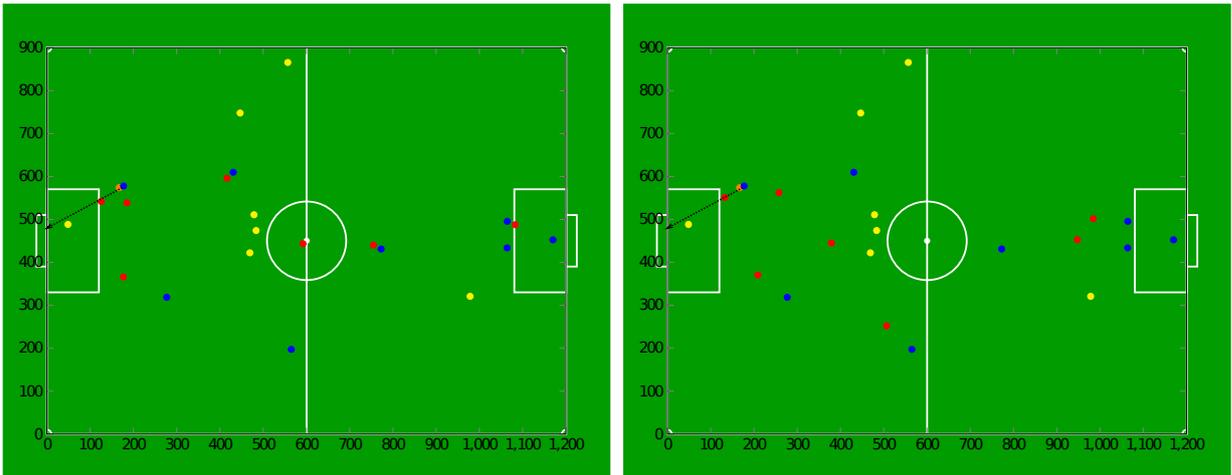
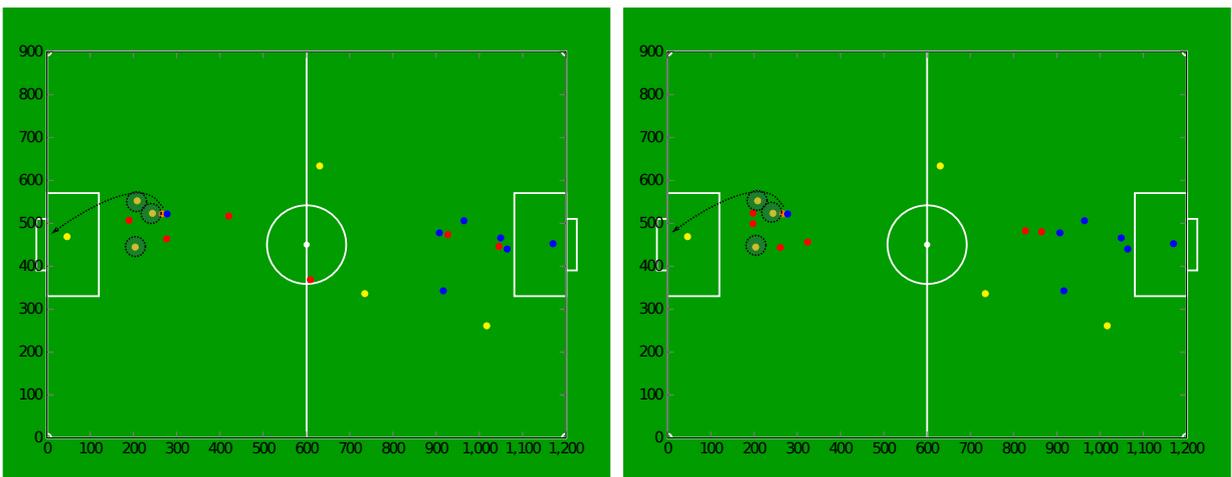


Figura 121 – Jogo 07 – Início do jogo – Segundo gol – robôs amarelos não se moveram.

(a) PSO em modo defesa.

(b) PSO em modo passe.



Porém, o destaque dessa análise é confirmação que a otimização do posicionamento para defesa deve ocorrer apenas com os robôs adversários ativos na jogada. Assim, mais robôs teriam atuado próximo a área nessa situação. Porém, cabe ao sistema de estratégia decidir quais os robôs adversários que devem ser marcados.

## 7.14 ANÁLISES GERAIS E POSSÍVEIS APRIMORAMENTOS

Nas análises, a função de aptidão para posicionamento de passe está bem posicionada com possibilidades de impedir a continuidade da jogada. Porém, no decorrer do evento em situações muito próximas a área frontal do gol e com muitos robôs adversários aglomerados a função não otimiza posicionamentos adequados. Essa situação está atrelada as regras para diminuir a área de atuação dos adversários e ao mesmo tempo que um robô defensor não fique na mesma área de atuação que um colega. Para essas situações a regra de área de atuação entre robôs da equipe deveria ser excluída. Para a área de cobertura e atuação em jogadas próximas a parte frontal da área de gol a área de cobertura deverá ser proporcional a essa proximidade e a quantidade de robôs adversários próximos ao gol para permitir que os posicionamentos encontrados sejam mais eficientes nessas situações.

A função de aptidão de defesa teve bom desempenho nessas situações, impedindo a continuidade das jogadas após o passe. Assim, uma possível modificação é iniciar o posicionamento defensivo com bloqueio de passes e em sequência alterar para a função de defesa.

Nos experimentos, o objetivo sempre foi a proteção do gol ou da bola. Porém a função de defesa poderia defender outras áreas do campo já que os pontos de interesse podem ser informados. Porém é necessário realizar alterações no sistema de estratégia para a escolha dos pontos de interesse que devem ser defendidos a cada momento.

Com relação as métricas, a métrica que avalia defesa está dando peso maior para equipes com linha de defesa fixa. Como visto nos capítulos 2 e 4, um dos critérios do futebol é o equilíbrio. Ele pauta-se na premissa de possuir superioridade, ou no mínimo garantir igualdade numérica setorial de jogadores no espaço de jogo entre a bola e a própria baliza. Esse critério foi respeitado nas funções de aptidão, porém a área de defesa foi considerada todo o campo defensivo. Nesse caso, o campo de defesa deverá ser dividido em áreas com pesos diferenciados, conforme exemplo da figura 122.

Como pode ser observado na figura 122, o campo é dividido em 12 áreas e categorizado: como lados e meio de campo Defensivo e Ofensivo; Lado Esquerdo, direito ou área central. Assim, MDC significaria “Meio de campo defensivo na área central” e OE apenas como “Área ofensiva esquerda”. Cada área deverá ter um peso específico e a equação que verifica a Localização da Realização da Ação Tática no Campo de Jogo (LA) deverá ser

Figura 122 – Divisão do campo em áreas.



Fonte: Autor

reescrita. Simultaneamente, as demais equações das métricas deverão ser proporcionais a essa regra.

A otimização não considerou o tempo de deslocamento dos robôs de sua posição original para a nova. Essa regra não foi implementada pois cabe ao sistema de estratégia decidir quais robôs irão para cada posição. Essa decisão segue regras próprias e considera outras condições como o planejamento das rotas. Porém, essa avaliação poderia ser feita pela média geral de deslocamento dos robôs (equação (49)) ou pela quantidade de robôs que não alcançariam a nova posição no tempo estabelecido (equação (50)).

$$f_{\text{deslocamento}}(P, O, V_{\text{média}}, t_{\text{seguro}}) = \begin{cases} 0, & \widetilde{\Delta t} \leq t_{\text{seguro}} \\ PHIGH, & \widetilde{\Delta t} > t_{\text{seguro}} \end{cases} \quad \text{onde:} \quad (49)$$

$$\widetilde{\Delta t} \leftarrow \frac{1}{\text{size}(P)} \times \sum_{p \in P, o \in O} \frac{p-o}{V_{\text{média}}}$$

$$f_{\text{deslocamento}}(P, O, V_{\text{média}}, t_{\text{seguro}}) = \text{PHIGH} \times \text{robos}_{\text{fora}} \quad \text{onde:} \quad (50)$$

$$\text{robos}_{\text{fora}} \leftarrow \sum_{p \in P, o \in O} \forall \frac{p-o}{V_{\text{média}}} > t_{\text{seguro}}$$

A variável  $V_{\text{média}}$  é a velocidade média do robô (medido em laboratório),  $t_{\text{seguro}}$  o tempo máximo aceitável que um robô percorreria a distância,  $P$  é o conjunto de robôs com posicionamento futuro e  $O$  o original.

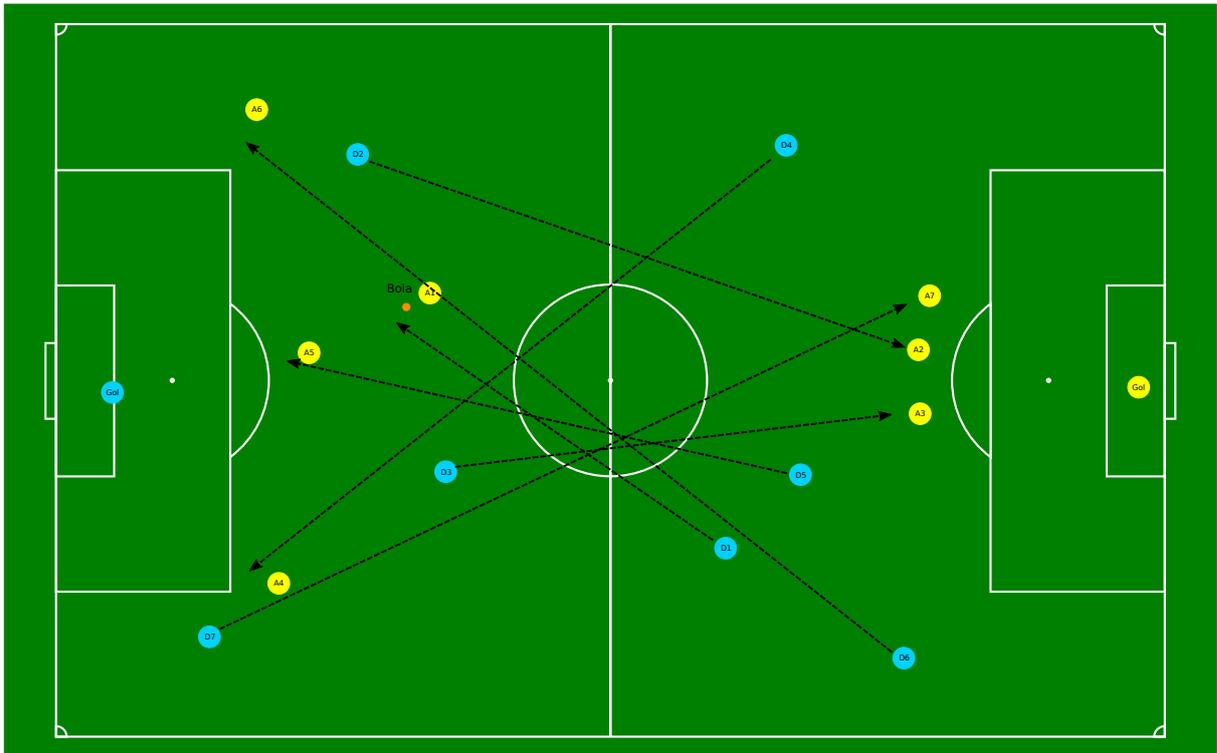
Alguns autores sugerem que modificações na população podem aumentar a eficiência do PSO (COELLO; LAMONT; VELDHUIZEN, 2007; COOREN; CLERC; SIARRY, 2009; GAO; DU; YAN, 2015; KHAJEH; GHASEMI; ARAB, 2019). Ajustar a ordem dos robôs após a criação da partícula poderia melhorar o desempenho da otimização. Para fins de ilustração, será considerado apenas a regra que posiciona um robô defensor a frente de um adversário com o menor espaço possível. Para a composição de cada partícula, as posições dos robôs são aleatoriamente distribuídas em campo. Na equações, as otimizações são realizadas pela ordem de criação e comparadas sequencialmente com a ordem de entrada dos adversários. A figura 123 ilustra essa ideia: os robôs defensores (azuis) estão distribuídos na criação da partícula com setas indicando a posição desejada após a otimização.

A cada iteração de atualização da velocidade e posição, usando as equações originais do algoritmo, os robôs deveriam aproximar-se de seus objetivos. Porém, com essa configuração existe a possibilidade que quantidade de iterações para obtenção dos resultados desejados sejam elevados ou insuficientes. Uma possível modificação seria organizar a população para que os robôs se movam para outros alvos, como os mais próximos sugerido na figura 124.

Assim, cabe realizar experimentos para avaliar se modificações na população poderiam contribuir para uma rápida convergência com menos iterações. Essa análise pode diminuir a quantidade de partículas da população e o número de iterações necessários. Essa diminuição contribuiria para melhoria do tempo de otimização.

Por fim, a análise do segundo gol da RoboDragons contra a equipe RoboTeam Twente demonstrou a possibilidade das otimizações considerarem apenas algumas áreas do campo conforme posicionamento do robô adversário mais avançando ou posição da bola em campo. A figura 125 ilustra essa possibilidade com duas possibilidades de janelas:

Figura 123 – População original.



Fonte: Autor

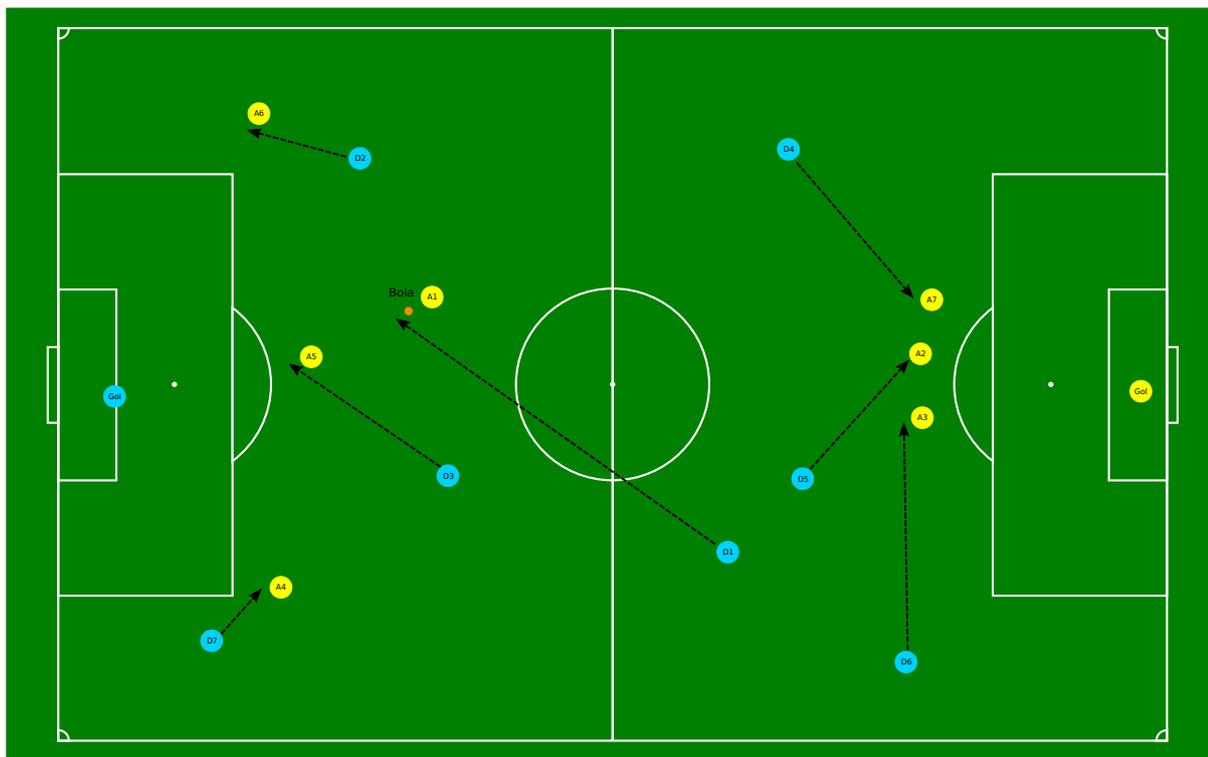
a) primeiro considerando a posição da bola, que está no campo de defesa e próxima a área de gol; b) a segunda considera o início da área do gol conforme posição dos robôs adversários mais avançados.

Esses ajustes possibilitam duas situações desejáveis: a) montar uma linha defensiva apenas contra robôs adversários que efetivamente estejam participando da jogada e/ou possam oferecer perigo; b) utilizar menos robôs na otimização de posicionamento liberando os demais para desempenhar outras funções definidas pelo sistema de estratégia. Contudo esse não é um problema a ser resolvido pelas equações de otimização. Cabe ao sistema de estratégia escolher os robôs adversários que precisam de marcação e quais robôs da equipe para compor a defesa.

## 7.15 CONSIDERAÇÕES FINAIS DO CAPÍTULO

As análises demonstraram que a equação para bloqueio de passes obteve os piores resultados nos momentos que a bola estava posicionada na parte frontal do gol. Nessas

Figura 124 – População corrigida.



Fonte: Autor

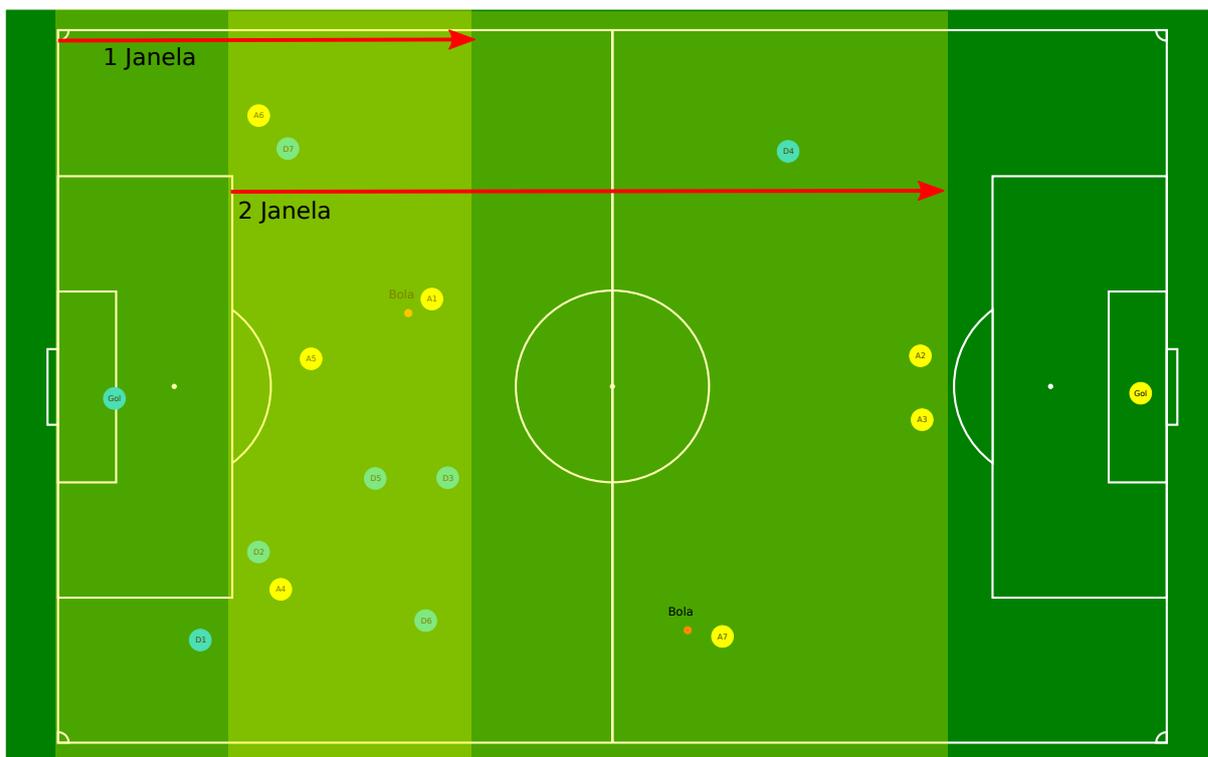
situações o correto é aplicar a equação de bloqueio de gol. Essa piora é decorrente da escolha dos critérios defensivos para cada situação. No bloqueio de passe tenta-se pressionar o portador da bola e diminuir o espaço de jogo dos demais adversários. Porém, em jogadas próximas a área frontal do gol é comum haver menos espaço para movimentação ocasionado pela concentração de robôs.

A aplicação das equações de otimização podem ocorrer a qualquer momento de um jogo de futebol de robôs na SSL. As análises das métricas e inspeção visuais demonstraram sua efetividade no início das jogadas de bola parada. Essa importância foi destacada anteriormente na proposição das equações.

Em registros históricos, as análises das jogadas selecionadas demonstraram a viabilidade da aplicação do PSO em conjunto com funções de aptidão para otimizar posicionamentos em campo. A otimização não necessita de conhecimento prévio sobre a equipe adversária, apenas as coordenadas em campo da bola e dos robôs adversários.

Foi verificado que em algumas situações a métrica da defesa pode atuar também como mecanismo para o bloqueio dos passes. Essa análise fica mais evidente para os

Figura 125 – Janelas em campo.



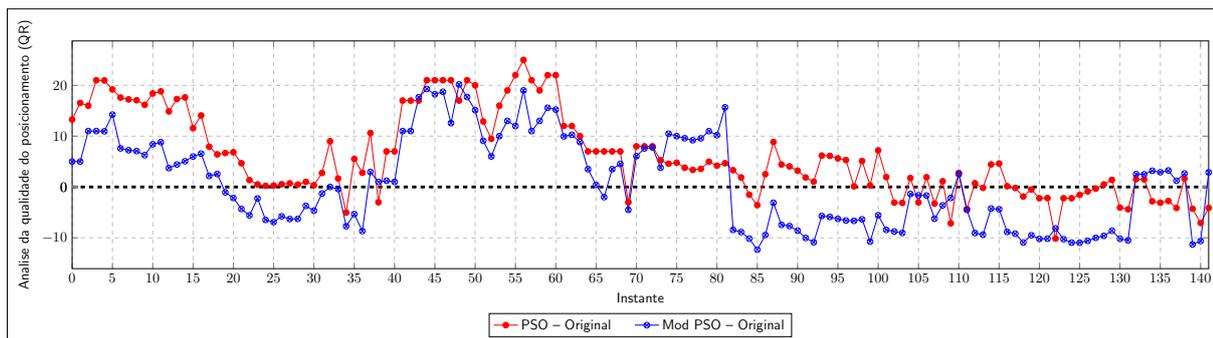
Fonte: Autor

momentos que a bola está mais próxima ao gol da equipe. De forma análoga, a função de aptidão para bloqueio dos passes demonstrou sua eficácia nos momentos que a bola estava mais afastada do gol adversário.

As figuras 126 e 127 também demonstraram que o uso da mesma equação para otimizar toda a jogada não é apropriada. A figura 126 ilustra uma situação de otimização de bloqueio de passes, porém a partir do instante 85 a jogada está ocorrendo próxima a área frontal do gol e deveria ser aplicada a equação para bloqueio do gol. O inverso ocorre na figura 127. A figura ilustra uma situação de otimização de bloqueio de gol. Nos instantes iniciais e finais do jogo a otimização de bloqueio atuou de forma adequada. Porém o restante da jogada é composta de trocas de passes e disputa de bola e nesse caso a equação de bloqueio de passes deveria ser aplicada.

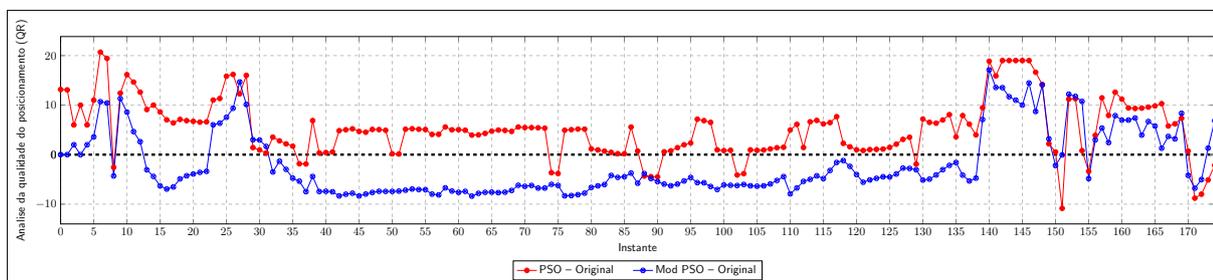
Nos experimentos, o objetivo sempre foi a proteção do gol ou da bola. Porém a função de defesa poderia defender outras áreas do campo já que os pontos de interesse podem ser informados. Porém é necessário realizar alterações no sistema de estratégia para a escolha dos pontos de interesse que devem ser defendidos a cada momento.

Figura 126 – Bloqueio de Passe.



Fonte: Autor

Figura 127 – Defesa de gol.



Fonte: Autor

A aplicação das métricas na análise dos jogos das equipes com ótimo posicionamento defensivo, como a ER-Force por exemplo, demonstraram sua eficiência como instrumento para avaliar posicionamentos defensivos para cobertura do gol e bloqueio de passes.

As avaliações demonstraram que apenas a otimização dos posicionamentos não seriam suficientes para o sucesso das equipes em campo. Cabe ao sistema de estratégia decidir como será realizado o combate ao robô portador da bola.

Nas simulações para a defesa optou-se por escolher o robô mais próximo da bola para dar o combate ao robô adversário e no passe o mais distante da bola. Essa abordagem, escolhida apenas para realizar os experimentos, não é ideal. Em alguns momentos o PSO retornou um posicionamento melhor e a abordagem retirou um robô que estava bem posicionado. Essa constatação pode ser observada nos gráficos onde a linha azul (posicionamento do PSO modificado) estava abaixo da vermelha (posicionamento retornado pelo PSO). Uma abordagem correta seria determinar uma regra para verificar qual robô pode ser retirado do posicionamento sem prejuízo para o esquema defensivo da equipe.

A aplicação das métricas, em algumas situações, não destacaram a efetividade dos posicionamentos otimizados. Porém, a inspeção visual e comparação entre posicionamento original e o otimizado constatou que ambos estavam bem posicionados. Normalmente as equipes tem como estratégia recuar a totalidade de robôs para o campo de defesa ou manter determinados robôs em frente a área de gol formando uma linha fixa de defesa. Essa estratégia não é considerada ruim, porém limita as possibilidades de jogadas em campo como realizar passes muito longos ou por cobertura para lançamentos, como ocorre no futebol humano. Essa característica também afeta o resultado das métricas, pois um dos critérios é manter a superioridade numérica em sua área de defesa ou ataque. Nos experimentos, a avaliação sempre foi do lado da defesa, portanto equipes com essas características obtiveram notas maiores na avaliação do seu IPOS em relação ao posicionamento otimizado.

Nas análises realizadas em registros históricos o posicionamento defensivo otimizado sempre foi superior ao original, porém não é possível prever a reação da equipe adversária. A aplicação dos princípios táticos do futebol, como contenção, unidade defensiva, entre outros já apresentados no capítulo 2, foram observados nos posicionamentos otimizados e, conclui-se, que a equipe adversária teria maiores dificuldades para conclusão de suas jogadas. Os testes indicaram que o posicionamento de defesa teve melhor desempenho em jogadas próximas a área de gol e posicionamento de bloqueio de passes na situação inversa.



## 8 CONCLUSÃO

A principal contribuição desta tese foi o desenvolvimento de funções de aptidão para otimizar posicionamentos defensivos e de bloqueios de passe respeitando critérios do futebol moderno. Foram realizados experimentos para determinar os parâmetros ideais para a configuração do algoritmo. A principal vantagem dessa abordagem é a possibilidade de otimizar, em tempo real e sem conhecimento prévio sobre a equipe adversária, combinações de posicionamento com baixo custo computacional, o que não é possível atualmente com outras técnicas como as de aprendizado.

A partir do estudo sobre o futebol moderno, foram propostas novas métricas para análise do posicionamento defensivo em situações de jogadas de bola parada para defesa da baliza e bloqueio de passes.

As avaliações demonstraram que as funções de aptidão obtiveram posicionamentos melhores que os originais em campo. Nas análises, observou-se que não haveria a continuidade das jogadas. A comparação do posicionamento original de várias equipes e os otimizados demonstraram que as métricas são uma ferramenta importante para avaliação do desempenho de equipes de futebol.

Nas análises dos diversos registros históricos foi possível identificar que muitas equipes focam sua estratégia em torno da posição da bola em campo e muitas vezes não realizam a marcação adequada dos demais robôs adversários. Nos posicionamentos otimizados essas marcações foram realizadas.

### 8.1 TRABALHOS FUTUROS

Além das melhorias já citada na seção 7.14, existem outras possibilidades de continuidade do trabalho. Inclusive a aplicação das métricas e funções de aptidão em outras categorias de futebol de robôs.

É seguro afirmar que as métricas podem ser aplicadas em qualquer categoria de futebol de robôs. Contudo, as funções de aptidão para otimização na forma atual são aplicáveis apenas as categorias com as mesmas características do SSL: um sistema de estratégia que controla toda a equipe. Para outras categorias, as funções precisam ser modificadas para representar os diversos tipos de controles estratégicos.

### **8.1.1 Novas métricas e funções de aptidão**

Um sistema de estratégia tático para o futebol necessita de mais verificações para a continuidade do jogo além do posicionamento estratégico em campo. Alguns direcionamentos para melhoria da pesquisa foram apresentados no capítulo 7. Nesse sentido, a fim de desenvolver um sistema estratégico mais eficiente sugerem-se alguns encaminhamentos.

Uma partida de futebol não se resume apenas a se defender. É necessário que equações para posicionamentos ofensivos e outras situações de jogo sejam propostas. Para isso é necessário aprofundamento dos estudos sobre análise de jogo e suas principais características. Esses ensinamentos são importantes para a compreensão dos processos da análise de partidas e a lógica do jogo coletivo.

É possível, utilizando o guia proposto por Costa et al. (2011), criar regras matemáticas para verificar as chances de sucesso do adversário ou da própria equipe. Essas regras, por sua vez, podem ser utilizadas em conjunto com outros algoritmos para determinar se um novo posicionamento aumenta ou diminui as chances de sucesso da equipe.

De forma análoga, funções de aptidão para encontrar posicionamentos ofensivos poderão ser criadas. Por exemplo, a função de bloqueio de passes poderia ser alterada para atuar inversamente e ser utilizada para encontrar posicionamentos que facilitem a recepção de um passe.

### **8.1.2 Estratégia para defesa ou ataque**

Nas análises, percebeu-se que em determinadas condições as otimizações tiverem índices finais díspares. Simultaneamente, uma equipe não pode atuar todo o tempo em sua totalidade como defesa. Assim, é importante definir regras para a escolha de quais robôs comporão a otimização e qual a função de aptidão será adotada.

Uma possível solução seria a criação de regras de aprendizado para determinar o momento ideal e a configuração dos parâmetros para execução PSO. Essas regras podem ser criadas utilizando a avaliação FUT-SAT e aplicada em sistemas de CBR.

A escolha do robô para simular o ataque a bola foi um dos problemas encontrados. Algumas verificações demonstram que o critério escolhido não foi adequado. A definição

desses critérios deverão considerar algumas questões, principalmente se a retirada do robô do posicionamento otimizado não irá acarretar em falhas defensivas.

Os experimentos utilizaram a totalidade de robôs disponíveis nas otimizações de defesa e bloqueios de passes. Porém, os robôs poderiam ser classificados com papéis diferenciados baseados em critérios específicos como posição da bola em campo, quantidade de robôs adversários em campo, robôs com melhor qualidade mecânica ou eletrônica, entre outros. Assim, é possível aplicar uma otimização de defesa para um grupo de robôs e passe para o outro simultaneamente.

### **8.1.3 Aplicação de outros algoritmos**

Um problema dos algoritmos de otimização são cair em ótimos locais, ou sub-ótimos. Na literatura outros algoritmos de otimização estão disponíveis inclusive variantes do próprio PSO que tentam minimizar essas situações. Assim, utilizando as equações de otimização sugere-se a comparação com esses algoritmos.

Acredita-se que uma extensão deste trabalho para raciocínio probabilístico possa obter resultados melhores.

Finalmente, o ideal seria o algoritmo PSO receber as prováveis posições futuras dos robôs adversários em campo. Desta forma é possível a execução das ações pelos robôs para se posicionarem conforme a otimização. Essas posições futuras podem ser obtidas com cálculos probalísticos, uso do filtro de Kalmann ou combinado com outras algoritmos de IA, como o próprio aprendizado.



## REFERÊNCIAS

ABREU, Pedro Henriques et al. Performance analysis in soccer: a Cartesian coordinates based approach using RoboCup data. **Soft Computing**, Springer Science e Business Media LLC, v. 16, n. 1, p. 47–61, mai. 2011. DOI: 10.1007/s00500-011-0733-0. Disponível em: <https://doi.org/10.1007/s00500-011-0733-0>.

ADACHI, Yusuke; ITO, Masahide; NARUSE, Tadashi. Classifying the Strategies of an Opponent Team Based on a Sequence of Actions in the RoboCup SSL. In: BEHNKE, Sven et al. (Ed.). **RoboCup 2016: Robot World Cup XX**. [S.l.]: Springer International Publishing, 2017. P. 109–120. ISBN 978-3-319-68792-6. DOI: 10.1007/978-3-319-68792-6\_9. Disponível em: [https://doi.org/10.1007/978-3-319-68792-6\\_9](https://doi.org/10.1007/978-3-319-68792-6_9).

ALBAB, Rizki Taufik Ulil; WIBOWO, Iwan Kurnianto; BASUKI, Dwi Kurnia. Path planning for mobile robot soccer using genetic algorithm. In: 2017 International Electronics Symposium on Engineering Technology and Applications (IES-ETA). [S.l.: s.n.], set. 2017. P. 276–280. DOI: 10.1109/ELECSYM.2017.8240416. Disponível em: <https://doi.org/10.1109/ELECSYM.2017.8240416>.

ALMEIDA, Bruno Seixas Gomes de; LEITE, Victor Coppo. Particle Swarm Optimization: A Powerful Technique for Solving Engineering Problems. In: **SWARM Intelligence - Recent Advances, New Perspectives and Applications**. [S.l.]: IntechOpen, dez. 2019. DOI: 10.5772/intechopen.89633. Disponível em: <https://doi.org/10.5772/intechopen.89633>.

ANGELINE, Peter J. Evolutionary optimization versus particle swarm optimization: Philosophy and performance differences. In: **Evolutionary Programming VII: 7th International Conference, EP98 San Diego, California, USA, March 25–27, 1998 Proceedings**. Edição: V. W. Porto. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998. P. 601–610. ISBN 978-3-540-68515-9. DOI: 10.1007/BFb0040811. Disponível em: <https://doi.org/10.1007/BFb0040811>.

ARUMUGAM, M. Senthil; RAO, M. V. C. On the performance of the particle swarm optimization algorithm with various inertia weight variants for computing optimal control of a class of hybrid systems. **Discrete Dynamics in Nature and Society**, Hindawi Limited, v. 2006, p. 1–17, 2006. DOI: 10.1155/ddns/2006/79295. Disponível em: <https://doi.org/10.1155/DDNS/2006/79295>.

BANSAL, J. C. et al. Inertia Weight strategies in Particle Swarm Optimization. In: 2011 Third World Congress on Nature and Biologically Inspired Computing. [S.l.: s.n.], out. 2011. P. 633–640. DOI: 10.1109/NaBIC.2011.6089659. Disponível em: <https://doi.org/10.1109/NaBIC.2011.6089659>.

BARMPALEXIS, Panagiotis et al. Comparison of multi-linear regression, particle swarm optimization artificial neural networks and genetic programming in the development of mini-tablets. **International Journal of Pharmaceutics**, Elsevier BV, v. 551, n. 1-2, p. 166–176, nov. 2018. DOI: 10.1016/j.ijpharm.2018.09.026. Disponível em: <https://doi.org/10.1016/j.ijpharm.2018.09.026>.

BENI, Gerardo; WANG, Jing. Swarm Intelligence in Cellular Robotic Systems. In: NATO Advanced Workshop on Robots and Biological Systems. [S.l.: s.n.], jun. 1989.

BINITHA, S; SATHYA, S Siva et al. A survey of bio inspired optimization algorithms. **International journal of soft computing and engineering**, Citeseer, v. 2, n. 2, p. 137–151, mai. 2012. ISSN 2231-2307.

BOER, Remco; KOK, Jelle. **The Incremental Development of a Synthetic Multi-Agent System: The UvA Trilearn 2001 Robotic Soccer Simulation Team**. Mai. 2002. Diss. (Mestrado) – Faculty of Science University of Amsterdam.

BONFANTI, Mario. **Fútbol a balón parado : saque inicial, de portería, de esquina, de falta, de banda, penalti**. Edição: PAIDOTRIBO. Barcelona: Paidotribo Editorial, 2002. ISBN 978-8480196307.

BOWLING, Michael; BROWNING, Brett; VELOSO, Manuela. Plays as Effective Multiagent Plans Enabling Opponent-Adaptive Play Selection. In: PROCEEDINGS of the Fourteenth International Conference on International Conference on Automated Planning and Scheduling. Whistler, British Columbia, Canada: AAAI Press, 2004. (ICAPS'04), p. 376–383. ISBN 1577352009. DOI: 10.5555/3037008.3037058. Disponível em: <https://dl.acm.org/doi/10.5555/3037008.3037058>.

BRAMBILLA, Manuele et al. Swarm robotics: a review from the swarm engineering perspective. **Swarm Intelligence**, v. 7, n. 1, p. 1–41, 2013. ISSN 1935-3820. DOI: 10.1007/s11721-012-0075-2. Disponível em: <http://dx.doi.org/10.1007/s11721-012-0075-2>.

BROWNING, Brett. **RoboCup Small Size League Referee Box**. [S.l.: s.n.], 2010. <https://robocup-ssl.github.io/ssl-refbox/>.

BRUCE, J.; BALCH, T.; VELOSO, M. Fast and inexpensive color image segmentation for interactive robots. In: PROCEEDINGS. 2000 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2000) (Cat. No.00CH37113). [S.l.: s.n.], 2000. v. 3, 2061–2066 vol.3. DOI: 10.1109/IROS.2000.895274. Disponível em: <https://doi.org/10.1109/IROS.2000.895274>.

CARLING, Christopher; WILLIAMS, Mark; REILLY, Tom. **Handbook of Soccer Match Analysis: A Systematic Approach to Improving Performance**. [S.l.]: Routledge, 2006. ISBN 0415339081. DOI: 10.4324/9780203448625. Disponível em: <https://doi.org/10.4324/9780203448625>.

CASARIN, Rodrigo Vicenzi et al. Modelo de jogo e processo de ensino no futebol: princípios globais e específicos. Português. **Movimento**, v. 17, p. 133–152, 2011. ISSN 0104-754X. Disponível em: <https://www.redalyc.org/articulo.oa?id=115321322008>.

CASTELO, Jorge. **Tratado general de fútbol : guía práctica de ejercicios de entrenamiento**. Edição: PAIDOTRIBO. Badalona: Paidotribo, 2009. ISBN 9788480196093.

CECCONI, Eduardo. **Bola Parada**. [S.l.: s.n.], dez. 2015. Análise Tática no Futebol. Acesso em 10/05/2019. Disponível em: <https://eduardocecconi.wordpress.com/2015/12/03/9-bola-parada/>.

CHATTERJEE, A.; SIARRY, P. Nonlinear inertia weight variation for dynamic adaptation in particle swarm optimization. **Computers & Operations Research**, v. 33, n. 3, p. 859–871, 2006. ISSN 0305-0548. DOI: 10.1016/j.cor.2004.08.012. Disponível em: <https://doi.org/10.1016/j.cor.2004.08.012>.

CHEN, Guimin et al. Natural Exponential Inertia Weight Strategy in Particle Swarm Optimization. In: 2006 6th World Congress on Intelligent Control and Automation. [S.l.: s.n.], 2006. v. 1, p. 3672–3675. DOI: 10.1109/WCICA.2006.1713055. Disponível em: <https://doi.org/10.1109/WCICA.2006.1713055>.

CLERC, M.; KENNEDY, J. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 1, p. 58–73, fev. 2002. ISSN 1089-778X. DOI: 10.1109/4235.985692. Disponível em: <https://doi.org/10.1109/4235.985692>.

CLERC, Maurice. **Particle Swarm Optimization**. 1. ed. [S.l.]: John Wiley & Sons, 7 fev. 2006. 244 p. ISBN 1905209045. Disponível em: [http://www.ebook.de/de/product/5311949/clerc%5C\\_particle%5C\\_swarm%5C\\_optimization.html](http://www.ebook.de/de/product/5311949/clerc%5C_particle%5C_swarm%5C_optimization.html).

COELLO, Carlos Coello; LAMONT, Gary B.; VELDHUIZEN, David A. van. **Evolutionary Algorithms for Solving Multi-Objective Problems**. [S.l.]: Springer US, 2007. (Genetic and Evolutionary Computation). ISBN 978-0-387-36797-2. DOI: 10.1007/978-0-387-36797-2. Disponível em: <https://www.springer.com/gp/book/9780387332543>.

COOREN, Yann; CLERC, Maurice; SIARRY, Patrick. Performance evaluation of TRIBES, an adaptive particle swarm optimization algorithm. **Swarm Intelligence**, v. 3, n. 2, p. 149–178, jun. 2009. ISSN 1935-3820. DOI: 10.1007/s11721-009-0026-8. Disponível em: <https://doi.org/10.1007/s11721-009-0026-8>.

COSTA, Israel Teoldo da et al. Princípios Táticos do Jogo de Futebol: conceitos e aplicação. **Motriz. Revista de Educação Física**, v. 15, n. 3, p. 657–668, jul. 2009. ISSN 1980-6574. DOI: 10.5016/2488.

COSTA, Israel Teoldo da et al. Proposta de avaliação do comportamento tático de jogadores de Futebol baseada em princípios fundamentais do jogo. pt. **Motriz: Revista de Educação Física**, scielo, v. 17, p. 511–524, set. 2011. ISSN 1980-6574. DOI: 10.1590/S1980-65742011000300014. Disponível em: <https://doi.org/10.1590/S1980-65742011000300014>.

DA SILVA COSTA, Leonardo; TONIDANDEL, Flavio. Comparison and Analysis of the DVG+A\* and Rapidly-Exploring Random Trees Path-Planners for the RoboCup-Small Size League. In: 2019 Latin American Robotics Symposium (LARS), 2019 Brazilian Symposium on Robotics (SBR) and 2019 Workshop on Robotics in Education (WRE). [S.l.]: IEEE

Computer Society, 2019. P. 1–6. DOI: 10.1109/LARS-SBR-WRE48964.2019.00009. Disponível em: <https://doi.org/10.1109/LARS-SBR-WRE48964.2019.00009>.

DARWISH, Ashraf. Bio-inspired computing: Algorithms review, deep analysis, and the scope of applications. **Future Computing and Informatics Journal**, v. 3, n. 2, p. 231–246, 2018. ISSN 2314-7288. DOI: <https://doi.org/10.1016/j.fcij.2018.06.001>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2314728818300631>.

DASHTI, Hesam T.; KAMALI, Shahin; AGHAEPOUR, Nima. Positioning in Robots Soccer. In: ROBOTIC Soccer. [S.l.]: I-Tech Education e Publishing, dez. 2007. DOI: 10.5772/5123. Disponível em: <https://doi.org/10.5772/5123>.

DENG, M. et al. Online estimation of arriving time for robot to soccer ball in RoboCup Soccer using PSO-SVR. In: PROCEEDINGS of the 2014 International Conference on Advanced Mechatronic Systems. [S.l.: s.n.], 2014. P. 543–546. DOI: 10.1109/ICAMechS.2014.6911605. Disponível em: <https://doi.org/10.1109/ICAMechS.2014.6911605>.

DORIGO, M.; OCA, M. A. Montes de; ENGELBRECHT, A. Particle swarm optimization. **Scholarpedia**, v. 3, n. 11, p. 1486, 2008. revision #91633. DOI: 10.4249/scholarpedia.1486. Disponível em: <http://dx.doi.org/10.4249/scholarpedia.1486>.

DORIGO, Marco; STÜTZLE, Thomas. **Ant Colony Optimization**. Scituate, MA, USA: Bradford Company, 2004. ISBN 0262042193.

EBERHART, R. C.; SHI, Yuhui. Tracking and optimizing dynamic systems with particle swarms. In: PROCEEDINGS of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546). [S.l.: s.n.], 2001. v. 1, 94–100 vol. 1. DOI: 10.1109/CEC.2001.934376. Disponível em: <https://doi.org/10.1109/CEC.2001.934376>.

EBERHART, Russell C.; SHI, Yuhui; KENNEDY, James. **Swarm Intelligence**. 1. ed. [S.l.]: Morgan Kaufmann, 11 abr. 2001. 512 p. ISBN 978-1558605954. Disponível em: [http://www.ebook.de/de/product/3247904/russell\\_c\\_eberhart\\_yuhui\\_shi\\_james\\_kennedy\\_swarm\\_intelligence.html](http://www.ebook.de/de/product/3247904/russell_c_eberhart_yuhui_shi_james_kennedy_swarm_intelligence.html).

ENGELBRECHT, Andries P. **Computational Intelligence**. 1. ed. [S.l.]: John Wiley e Sons Ltd, 2001. 628 p. ISBN 978-0-470-03561-0. Disponível em: [http://www.ebook.de/de/product/6597149/andries\\_p\\_engelbrecht\\_computational\\_intelligence.html](http://www.ebook.de/de/product/6597149/andries_p_engelbrecht_computational_intelligence.html).

FENG, Y. et al. Chaotic Inertia Weight in Particle Swarm Optimization. In: SECOND International Conference on Innovative Computing, Informatio and Control (ICICIC 2007). [S.l.: s.n.], set. 2007. P. 475–475. DOI: 10.1109/ICICIC.2007.209. Disponível em: <https://doi.org/10.1109/ICICIC.2007.209>.

GAO, Y. I.; AN, X. h.; LIU, J. m. A Particle Swarm Optimization Algorithm with Logarithm Decreasing Inertia Weight and Chaos Mutation. In: 2008 International Conference on Computational Intelligence and Security. [S.l.: s.n.], dez. 2008. v. 1, p. 61–65. DOI: 10.1109/CIS.2008.183. Disponível em: <https://doi.org/10.1109/CIS.2008.183>.

GAO, Yang; DU, Wenbo; YAN, Gang. Selectively-informed particle swarm optimization. **Scientific Reports**, Springer Science e Business Media LLC, v. 5, n. 1, mar. 2015. DOI: 10.1038/srep09295. Disponível em: <https://doi.org/10.1038/srep09295>.

GARGANTA, Júlio. Modelação táctica em jogos desportivos – A desejável cumplicidade entre pesquisa, treino e competição. In: F. TAVARES A. GRAÇA, J. Garganta & I. Mesquita (Ed.). **Olhares e Contextos da Performance nos jogos desportivos**. [S.l.]: Universidade do Porto: Faculdade de Desporto., 2008. P. 108–121.

GONÇALVES, Eder; REZENDE, Alexandre Luiz Gonçalves de; TEOLDO, Israel. Comparação entre a performance táctica defensiva e ofensiva de jogadores de futebol Sub-17 de diferentes posições. **Revista Brasileira de Ciências do Esporte**, v. 39, n. 2, p. 108–114, 2017. ISSN 0101-3289. DOI: 10.1016/j.rbce.2015.10.015. Disponível em: <https://doi.org/10.1016/j.rbce.2015.10.015>.

GROEN, Frans; SPAAN, Matthijs; VLASSIS, Nikos. Robot Soccer: Game or Science. In: PROCEEDINGS CNR-2002 (CNR'02). [S.l.]: Editura Universitaria Craiova, Romania, nov. 2002. P. 92–98.

GUARNIZO, Jose; MELLADO, Martin. Robot Soccer Strategy Based on Hierarchical Finite State Machine to Centralized Architectures. **IEEE Latin America Transactions**, v. 14, p. 3586–3596, ago. 2016. DOI: 10.1109/TLA.2016.7786338. Disponível em: <https://doi.org/10.1109/TLA.2016.7786338>.

GURZONI, José Angelo et al. On the construction of a RoboCup small size league team. **Journal of the Brazilian Computer Society**, Springer Science e Business Media LLC, v. 17, n. 1, p. 69–82, jan. 2011. DOI: 10.1007/s13173-011-0028-4. Disponível em: <https://doi.org/10.1007/s13173-011-0028-4>.

HART, P. E.; NILSSON, N. J.; RAPHAEL, B. A Formal Basis for the Heuristic Determination of Minimum Cost Paths. **IEEE Transactions on Systems Science and Cybernetics**, v. 4, n. 2, p. 100–107, jul. 1968. ISSN 0536-1567. DOI: 10.1109/TSSC.1968.300136. Disponível em: <https://doi.org/10.1109/TSSC.1968.300136>.

HUANG, Zhanxiang; YANG, Yang; CHEN, Xiaoping. An Approach to Plan Recognition and Retrieval for Multi-agent Systems. In: FIRST ROBOCUP AUSTRALIAN OPEN, AORC2003, CSIRO. WORKSHOP on Adaptability in Multi-Agent Systems. [S.l.]: CSIRO, 2002.

HUGHES, Charles. **The Football Association Book Of Soccer Tactics and Skills**. Third. City: Gardners Books, 1998. ISBN 1852915455.

JIA, F.; LICHTI, D. A COMPARISON OF SIMULATED ANNEALING, GENETIC ALGORITHM AND PARTICLE SWARM OPTIMIZATION IN OPTIMAL FIRST-ORDER DESIGN OF INDOOR TLS NETWORKS. **ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences**, Copernicus GmbH, IV-2/W4, p. 75–82, set. 2017. DOI: 10.5194/isprs-annals-iv-2-w4-75-2017. Disponível em: <https://doi.org/10.5194/isprs-annals-iv-2-w4-75-2017>.

JOLLY, K.G. et al. Intelligent decision making in multi-agent robot soccer system through compounded artificial neural networks. **Robotics and Autonomous Systems**, v. 55, n. 7, p. 589–596, 2007. ISSN 0921-8890. DOI: 10.1016/j.robot.2006.12.011. Disponível em: <https://doi.org/10.1016/j.robot.2006.12.011>.

JORDEHI, A. Rezaee; JASNI, J. Parameter selection in particle swarm optimisation: a survey. **Journal of Experimental & Theoretical Artificial Intelligence**, Taylor & Francis, v. 25, n. 4, p. 527–542, 2013. DOI: 10.1080/0952813X.2013.782348. eprint: <https://doi.org/10.1080/0952813X.2013.782348>. Disponível em: <https://doi.org/10.1080/0952813X.2013.782348>.

KENNEDY, J. Small worlds and mega-minds: effects of neighborhood topology on particle swarm performance. In: PROCEEDINGS of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406). [S.l.: s.n.], 1999. v. 3, 1938 vol. 3. DOI: 10.1109/CEC.1999.785509. Disponível em: <https://doi.org/10.1109/CEC.1999.785509>.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: NEURAL Networks, 1995. Proceedings., IEEE International Conference on. [S.l.: s.n.], nov. 1995. v. 4, 1942–1948 vol.4. DOI: 10.1109/ICNN.1995.488968. Disponível em: <https://doi.org/10.1109/ICNN.1995.488968>.

KENNEDY, J.; MENDES, R. Population structure and particle swarm performance. In: EVOLUTIONARY Computation, 2002. CEC '02. Proceedings of the 2002 Congress on. [S.l.: s.n.], 2002. v. 2, p. 1671–1676. DOI: 10.1109/CEC.2002.1004493. Disponível em: <https://doi.org/10.1109/CEC.2002.1004493>.

KENNEDY, James. Particle Swarm Optimization. In: **Encyclopedia of Machine Learning**. Edição: Claude Sammut e Geoffrey I. Webb. Boston, MA: Springer US, 2010. P. 760–766. ISBN 978-0-387-30164-8. DOI: 10.1007/978-0-387-30164-8\_630. Disponível em: [https://doi.org/10.1007/978-0-387-30164-8\\_630](https://doi.org/10.1007/978-0-387-30164-8_630).

KENNEDY, James. The behavior of particles. In: PORTO, V. W. et al. (Ed.). **Evolutionary Programming VII**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998. P. 579–589. ISBN 978-3-540-68515-9. DOI: 10.1007/BFb0040809. Disponível em: <https://doi.org/10.1007/BFb0040809>.

KENNEDY, James; EBERHART, Russell C. A Discrete Binary Version of the Particle Swarm Algorithm. In: PROCEEDINGS of the IEEE International Conference on Systems, Man, and Cybernetics. Washington, DC, USA: IEEE Computer Society, out. 1997. v. 5, p. 4104–4108. DOI: 10.1109/ICSMC.1997.637339. Disponível em: <https://doi.org/10.1109/ICSMC.1997.637339>.

KENTZOGLANAKIS, Kyriakos; POOLE, Matthew. Particle Swarm Optimization with an Oscillating Inertia Weight. In: PROCEEDINGS of the 11th Annual Conference on Genetic and Evolutionary Computation. Montreal, Quebec, Canada: ACM, 2009. (GECCO '09), p. 1749–1750. ISBN 978-1-60558-325-9. DOI: 10.1145/1569901.1570140. Disponível em: <http://doi.acm.org/10.1145/1569901.1570140>.

- KHAJEH, Atieh; GHASEMI, Mohammad Reza; ARAB, Hamed Ghohani. Modified particle swarm optimization with novel population initialization. **Journal of Information and Optimization Sciences**, Taylor & Francis, v. 40, n. 6, p. 1167–1179, 2019. DOI: 10.1080/02522667.2017.1338605. eprint: <https://doi.org/10.1080/02522667.2017.1338605>. Disponível em: <https://doi.org/10.1080/02522667.2017.1338605%20https://doi.org/10.1080/02522667.2017.1338605>.
- KIM, Jong-Hwan et al. **Soccer Robotics**. 1. ed. [S.l.]: Springer, 2004. (Springer Tracts in Advanced Robotics 11). ISBN 978-3-540-21859-3. DOI: 10.1007/b95999. Disponível em: <https://doi.org/10.1007/b95999>.
- KLEINER, Alexander; DIETL, Markus; NEBEL, Bernhard. Towards a Life-Long Learning Soccer Agent. In: KAMINKA, Gal A.; LIMA, Pedro U.; ROJAS, Raúl (Ed.). **RoboCup 2002: Robot Soccer World Cup VI**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. P. 126–134. ISBN 978-3-540-45135-8. DOI: 10.1007/978-3-540-45135-8\_10. Disponível em: [https://doi.org/10.1007/978-3-540-45135-8\\_10](https://doi.org/10.1007/978-3-540-45135-8_10).
- KOK, Jelle R.; SPAAN, Matthijs T. J.; VLASSIS, Nikos. Multi-robot decision making using coordination graphs. In: ALMEIDA, A. T. de; NUNES, U. (Ed.). **Proceedings of the International Conference on Advanced Robotics (ICAR)**. Coimbra, Portugal: [s.n.], jun. 2003. P. 1124–1129.
- KONUR, Savas et al. Learning Decision Trees for Action Selection in Soccer Agents. In: WORKSHOP on Agents in dynamic and real-time environments. [S.l.: s.n.], 2004. DOI: 10.1.1.59.5313.
- LAM, Kevin; ESFANDIARI, Babak; TUDINO, David. A scene-based imitation framework for RoboCup clients. In: AAAI-06 (Ed.). **Workshop on Modeling Other Agents from Observations**. [S.l.]: AAAI Press, Boston, MA, USA, 2006.
- LARIK, Asma S.; HAIDER, Sajjad. A survey of nature inspired optimization algorithms applied to cooperative strategies in robot soccer. In: 2018 International Conference on Advancements in Computational Sciences (ICACS). [S.l.]: IEEE, fev. 2018. DOI: 10.1109/icacs.2018.8333485. Disponível em: <https://doi.org/10.1109/ICACS.2018.8333485>.
- LATTNER, Andreas D. et al. Sequential Pattern Mining for Situation and Behavior Prediction in Simulated Robotic Soccer. In: BREDENFELD, Ansgar et al. (Ed.). **RoboCup 2005: Robot Soccer World Cup IX**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. P. 118–129. ISBN 978-3-540-35438-3. DOI: 10.1007/11780519\_11. Disponível em: [https://doi.org/10.1007/11780519\\_11](https://doi.org/10.1007/11780519_11).
- LAUREANO, Marcos Aurelio Pchek; TONIDANDEL, Flavio. Analysis of the PSO Parameters for a Robots Positioning System in SSL. In: CHALUP, Stephan et al. (Ed.). **RoboCup 2019: Robot World Cup XXIII**. [S.l.]: Springer International Publishing, 2019. P. 126–139. ISBN 978-3-030-35699-6. DOI: 10.1007/978-3-030-35699-6\_10. Disponível em: [https://doi.org/10.1007/978-3-030-35699-6\\_10](https://doi.org/10.1007/978-3-030-35699-6_10).

LAUREANO, Marcos Aurelio Pchek; TONIDANDEL, Flavio. Performing and Blocking Passes in Small Size League. In: 2019 Latin American Robotics Symposium (LARS), 2019 Brazilian Symposium on Robotics (SBR) and 2019 Workshop on Robotics in Education (WRE). [S.l.]: IEEE Computer Society, 2019. P. 19–24. DOI: 10.1109/LARS-SBR-WRE48964.2019.00012. Disponível em: <https://doi.org/10.1109/LARS-SBR-WRE48964.2019.00012>.

LAVALLE, Steven M.; JAMES J. KUFFNER, Jr. Randomized Kinodynamic Planning. **The International Journal of Robotics Research**, v. 20, n. 5, p. 378–400, 2001. DOI: 10.1177/02783640122067453. eprint: <https://doi.org/10.1177/02783640122067453>. Disponível em: <https://doi.org/10.1177/02783640122067453>.

LEE, Jeongjun et al. A Tactics for Robot Soccer with Fuzzy Logic Mediator. In: HAO, Yue et al. (Ed.). **Computational Intelligence and Security**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. P. 127–132. ISBN 978-3-540-31599-5. DOI: 10.1007/11596448\_18. Disponível em: [https://doi.org/10.1007/11596448\\_18](https://doi.org/10.1007/11596448_18).

LEE, Kyun Ho; KIM, Ki Wan. Performance comparison of particle swarm optimization and genetic algorithm for inverse surface radiation problem. **International Journal of Heat and Mass Transfer**, Elsevier BV, v. 88, p. 330–337, set. 2015. DOI: 10.1016/j.ijheatmasstransfer.2015.04.075. Disponível em: <https://doi.org/10.1016/j.ijheatmasstransfer.2015.04.075>.

LI, H. R.; GAO, Y. L. Particle Swarm Optimization Algorithm with Exponent Decreasing Inertia Weight and Stochastic Mutation. In: 2009 Second International Conference on Information and Computing Science. [S.l.: s.n.], mai. 2009. v. 1, p. 66–69. DOI: 10.1109/ICIC.2009.24. Disponível em: <https://doi.org/10.1109/ICIC.2009.24>.

LINDFIELD, George; PENNY, John. Chapter 3 - Particle Swarm Optimization Algorithms. In: LINDFIELD, George; PENNY, John (Ed.). **Introduction to Nature-Inspired Optimization**. Boston: Academic Press, 2017. P. 49–68. ISBN 978-0-12-803636-5. DOI: 10.1016/B978-0-12-803636-5.00003-7. Disponível em: <https://doi.org/10.1016/B978-0-12-803636-5.00003-7>.

MA, Haiping et al. Conceptual and numerical comparisons of swarm intelligence optimization algorithms. **Soft Computing**, Springer Science e Business Media LLC, v. 21, n. 11, p. 3081–3100, dez. 2015. DOI: 10.1007/s00500-015-1993-x. Disponível em: <https://doi.org/10.1007/s00500-015-1993-x>.

MAGEL, Lukas. **Development of an Autonomous Referee Software for the Small Size League**. [S.l.], 2016.

MALIK, Reza Firsandaya; RAHMAN, Tharek Abdul; SITI ZAITON MOHD. HASHIM, and Razali Ngah. New Particle Swarm Optimizer with Sigmoid Increasing Inertia Weight. **International Journal of Computer Science and Security**, v. 1, n. 2, p. 35, 2007.

MENDOZA, Juan Pablo; SIMMONS, Reid; VELOSO, Manuela. Online Learning of Robot Soccer Free Kick Plans using a Bandit Approach. In: PROCEEDINGS of the Twenty-Sixth

International Conference on Automated Planning and Scheduling. London, UK: AAAI Press, 2016. (ICAPS'16), p. 504–508. ISBN 1577357574. DOI: 10.5555/3038594.3038657. Disponível em: <https://dl.acm.org/doi/abs/10.5555/3038594.3038657>.

MENDOZA, Juan Pablo et al. Selectively Reactive Coordination for a Team of Robot Soccer Champions. In: PROCEEDINGS of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, Arizona: AAAI Press, 2016. (AAAI'16), p. 3354–3360. DOI: 10.5555/3016100.3016373. Disponível em: <https://dl.acm.org/doi/10.5555/3016100.3016373>.

MIENE, Andrea; VISSER, Ubbo; HERZOG, Otthein. Recognition and Prediction of Motion Situations Based on a Qualitative Motion Description. In: POLANI, Daniel et al. (Ed.). **RoboCup 2003: Robot Soccer World Cup VII**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. P. 77–88. ISBN 978-3-540-25940-4. DOI: 10.1007/978-3-540-25940-4\_7. Disponível em: [https://doi.org/10.1007/978-3-540-25940-4\\_7](https://doi.org/10.1007/978-3-540-25940-4_7).

MILLONAS, Mark M. Swarms, phase transitions, and collective intelligence. In: [s.l.]: C.G. Langton (Ed.), 1994. Artificial Life III, p. 417–445. Disponível em: <https://arxiv.org/abs/adap-org/9306002v1>.

MONAJJEMI, Valiallah; KOOCHAKZADEH, Ali; GHIDARY, Saeed Shiry. grSim – RoboCup Small Size Robot Soccer Simulator. In: **RoboCup 2011: Robot Soccer World Cup XV**. Edição: Thomas Röfer. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. P. 450–460. ISBN 978-3-642-32060-6. DOI: 10.1007/978-3-642-32060-6\_38. Disponível em: [https://doi.org/10.1007/978-3-642-32060-6\\_38](https://doi.org/10.1007/978-3-642-32060-6_38).

NAKASHIMA, Tomoharu et al. Kick Extraction for Reducing Uncertainty in RoboCup Logs. In: YAMAMOTO, Sakae (Ed.). **Human Interface and the Management of Information. Information and Knowledge in Context**. Cham: Springer International Publishing, 2015. P. 622–633. ISBN 978-3-319-20618-9. DOI: 10.1007/978-3-319-20618-9\_61. Disponível em: [https://doi.org/10.1007/978-3-319-20618-9\\_61](https://doi.org/10.1007/978-3-319-20618-9_61).

NAKASHIMA, Tomoharu et al. Performance Evaluation of an Evolutionary Method for RoboCup Soccer Strategies. In: BREDENFELD, Ansgar et al. (Ed.). **RoboCup 2005: Robot Soccer World Cup IX**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. P. 616–623. ISBN 978-3-540-35438-3. DOI: 10.1007/11780519\_61. Disponível em: [https://doi.org/10.1007/11780519\\_61](https://doi.org/10.1007/11780519_61).

NASROLLAHY, A. Z.; JAVADI, H. H. S. Using Particle Swarm Optimization for Robot Path Planning in Dynamic Environments with Moving Obstacles and Target. In: 2009 Third UKSim European Symposium on Computer Modeling and Simulation. [S.l.: s.n.], nov. 2009. P. 60–65. DOI: 10.1109/EMS.2009.67. Disponível em: <https://doi.org/10.1109/EMS.2009.67>.

NICKABADI, Ahmad; EBADZADEH, Mohammad Mehdi. Particle swarm optimization algorithms with adaptive Inertia Weight: A survey of the state of the art and a Novel method. **IEEE Journal of Evolutionary Computation**, 2008.

NICKABADI, Ahmad; EBADZADEH, Mohammad Mehdi; SAFABAKHSH, Reza. A novel particle swarm optimization algorithm with adaptive inertia weight. **Applied Soft Computing**, v. 11, n. 4, p. 3658–3670, 2011. ISSN 1568-4946. DOI: 10.1016/j.asoc.2011.01.037. Disponível em: <https://doi.org/10.1016/j.asoc.2011.01.037>.

OKADA, H.; WADA, T.; YAMASHITA, A. Evolving Robocup Soccer Player formations by particle swarm optimization. In: SICE Annual Conference 2011. [S.l.]: IEEE Computer Society, set. 2011. P. 1950–1953.

OLLINO, Franco; SOLIS, Miguel; ALLENDE, Héctor. Batch Reinforcement Learning on a RoboCup Small Size League keepaway strategy learning problem. In: PROCEEDINGS of the 4th Congress on Robotics and Neuroscience, 2018. Aachen: [s.n.], mar. 2018. (CEUR Workshop Proceedings), p. 11–17. DOI: 10.21428/5b03f636. Disponível em: <https://doi.org/10.21428/5b03f636>.

OSBORNE, Martin J. **An Introduction to Game Theory**. [S.l.]: Oxford University Press, ago. 2003. ISBN 0195128958. Disponível em: <https://www.xarg.org/ref/a/0195128958/>.

PARK, Jong-Hwan et al. Recombinant Rule Selection in Evolutionary Algorithm for Fuzzy Path Planner of Robot Soccer. In: FREKSA, Christian; KOHLHASE, Michael; SCHILL, Kerstin (Ed.). **KI 2006: Advances in Artificial Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. P. 317–330. ISBN 978-3-540-69912-5. DOI: 10.1007/978-3-540-69912-5\_24. Disponível em: [https://doi.org/10.1007/978-3-540-69912-5\\_24](https://doi.org/10.1007/978-3-540-69912-5_24).

PARSOPOULOS, K. E.; VRAHATIS, M. N. Particle Swarm Optimization Method in Multiobjective Problems. In: PROCEEDINGS of the 2002 ACM Symposium on Applied Computing. Madrid, Spain: ACM, 2002. (SAC '02), p. 603–607. ISBN 1-58113-445-2. DOI: 10.1145/508791.508907. Disponível em: <http://doi.acm.org/10.1145/508791.508907>.

PARSOPOULOS, Konstantinos; VRAHATIS, Michael. **Particle Swarm Optimization and Intelligence: Advances and Applications**. [S.l.]: INFORMATION SCIENCE REFERENCE, 11 ago. 2010. 310 p. ISBN 978-1-61520-666-7. Disponível em: [http://www.ebook.de/de/product/10696477/konstantinos\\_e\\_parsopoulos\\_michael\\_n\\_vrahatis\\_particle\\_swarm\\_optimization\\_and\\_intelligence\\_advances\\_and\\_applications.html](http://www.ebook.de/de/product/10696477/konstantinos_e_parsopoulos_michael_n_vrahatis_particle_swarm_optimization_and_intelligence_advances_and_applications.html).

PAULI, Guilherme; TONIDANDEL, Flavio. Solving the Time Lapse from Vision System in a Robot Soccer Game Using Kalman Filter. In: 2019 Latin American Robotics Symposium (LARS), 2019 Brazilian Symposium on Robotics (SBR) and 2019 Workshop on Robotics in Education (WRE). [S.l.]: IEEE Computer Society, 2019. P. 7–12. DOI: 10.1109/LARS-SBR-WRE48964.2019.00010. Disponível em: <https://doi.org/10.1109/LARS-SBR-WRE48964.2019.00010>.

PERICO, D. H. et al. Hardware and Software Aspects of the Design and Assembly of a New Humanoid Robot for RoboCup Soccer. In: 2014 Joint Conference on Robotics: SBR-LARS Robotics Symposium and Robocontrol. [S.l.]: IEEE Computer Society, 2014. P. 73–78. DOI: 10.1109/SBR.LARS.Robocontrol.2014.39. Disponível em: <https://doi.org/10.1109/SBR.LARS.Robocontrol.2014.39>.

PIOTROWSKI, Adam P.; NAPIORKOWSKI, Jaroslaw J.; PIOTROWSKA, Agnieszka E. Population size in Particle Swarm Optimization. **Swarm and Evolutionary Computation**, v. 58, p. 100718, 2020. ISSN 2210-6502. DOI: 10.1016/j.swevo.2020.100718. Disponível em: <https://doi.org/10.1016/j.swevo.2020.100718>.

POLI, Riccardo; KENNEDY, James; BLACKWELL, Tim. Particle swarm optimization. **Swarm Intelligence**, v. 1, n. 1, p. 33–57, jun. 2007. ISSN 1935-3820. DOI: 10.1007/s11721-007-0002-0. Disponível em: <https://doi.org/10.1007/s11721-007-0002-0>.

PRAÇA, Gibson Moreira et al. Influence of additional players on collective tactical behavior in small-sided soccer games. en. **Brazilian Journal of Kinanthropometry and Human Performance**, scielo, v. 18, p. 62–71, fev. 2016. ISSN 1980-0037. DOI: 10.5007/1980-0037.2016v18n1p62. Disponível em: <https://doi.org/10.1590/1980-0037.2016v18n1p62>.

PRATOMO, Awang Hendrianto et al. Position and Obstacle Avoidance Algorithm in Robot Soccer. **Journal of Computer Science**, Science Publications, v. 6, n. 2, p. 173–179, fev. 2010. DOI: 10.3844/jcssp.2010.173.179. Disponível em: <https://doi.org/10.3844/jcssp.2010.173.179>.

QUAN, Hao et al. A computational framework for uncertainty integration in stochastic unit commitment with intermittent renewable energy sources. **Applied Energy**, v. 152, n. 100, p. 71–82, 2015. DOI: 10.1016/j.apenergy.2015.0. Disponível em: <https://ideas.repec.org/a/eee/appene/v152y2015icp71-82.html>.

QUINTERO, Carlos et al. Learning Soccer Drills for the Small Size League of RoboCup. In: **RoboCup 2014: Robot World Cup XVIII**. Edição: Reinaldo A. C. Bianchi. [S.l.]: Springer International Publishing, 2015. P. 395–406. ISBN 978-3-319-18615-3. DOI: 10.1007/978-3-319-18615-3-32. Disponível em: [https://doi.org/10.1007/978-3-319-18615-3\\_32](https://doi.org/10.1007/978-3-319-18615-3_32).

REIS, Luís Paulo; LAU, Nuno; OLIVEIRA, Eugénio Costa. Situation Based Strategic Positioning for Coordinating a Team of Homogeneous Agents. In: **BALANCING Reactivity and Social Deliberation in Multi-Agent Systems**. [S.l.]: Springer Berlin Heidelberg, 2001. P. 175–197. DOI: 10.1007/3-540-44568-4\_11. Disponível em: [https://doi.org/10.1007/3-540-44568-4\\_11](https://doi.org/10.1007/3-540-44568-4_11).

REYES-SIERRA, Margarita; COELLO, Carlos Coello A. Multi-Objective Particle Swarm Optimizers: A Survey of the State-of-the-Art. **International Journal of Computational Intelligence Research**, v. 2, n. 3, p. 287–308, 2006. ISSN 0973-1873. DOI: 10.5019/j.ijcir.2006.68. Disponível em: <https://doi.org/10.5019/j.ijcir.2006.68>.

REYNOLDS, Craig W. Flocks, Herds and Schools: A Distributed Behavioral Model. **SIGGRAPH Comput. Graph.**, ACM, New York, NY, USA, v. 21, n. 4, p. 25–34, ago. 1987. ISSN 0097-8930. DOI: 10.1145/37402.37406. Disponível em: <http://doi.acm.org/10.1145/37402.37406>.

RIEDMILLER, M. et al. Karlsruhe Brainstormers - A Reinforcement Learning approach to robotic soccer. In: **STONE, Peter; BALCH, Tucker; KRAETZSCHMAR, Gerhard (Ed.)**.

**RoboCup 2000: Robot Soccer World Cup IV.** Berlin, Heidelberg: Springer Berlin Heidelberg, 2001. P. 367–372. ISBN 978-3-540-45324-6. DOI: 10.1007/3-540-45324-5\_40. Disponível em: [https://doi.org/10.1007/3-540-45324-5\\_40](https://doi.org/10.1007/3-540-45324-5_40).

ROBOCUP. **Small Size League.** [S.l.: s.n.], 2015. [http://wiki.robocup.org/wiki/Small\\_Size\\_League](http://wiki.robocup.org/wiki/Small_Size_League). Acessado em 04 de novembro de 2015. Disponível em: [http://wiki.robocup.org/wiki/Small%5C\\_Size%5C\\_League](http://wiki.robocup.org/wiki/Small%5C_Size%5C_League).

ROBOTICS ERLANGEN. **League Overview.** [S.l.: s.n.], 2017. Small Size League.

RODRÍGUEZ, Saith et al. Fast Path Planning Algorithm for the RoboCup Small Size League. In: BIANCHI, Reinaldo A. C. et al. (Ed.). **RoboCup 2014: Robot World Cup XVIII.** [S.l.]: Springer International Publishing, 2015. P. 407–418. ISBN 978-3-319-18615-3. DOI: 10.1007/978-3-319-18615-3\_33. Disponível em: [https://doi.org/10.1007/978-3-319-18615-3\\_33](https://doi.org/10.1007/978-3-319-18615-3_33).

ROS, Raquel et al. A case-based approach for coordinated action selection in robot soccer. **Artificial Intelligence**, v. 173, n. 9, p. 1014–1039, 2009. ISSN 0004-3702. DOI: 10.1016/j.artint.2009.02.004. Disponível em: <https://doi.org/10.1016/j.artint.2009.02.004>.

RUSSELL, Stuart J.; NORVIG, Peter. **Artificial Intelligence – A Modern Approach.** 3. ed. [S.l.]: Prentice Hall, 2010.

SAMESHIMA, Katsumichi et al. StRRT-based path planning with PSO-tuned parameters for RoboCup soccer. **Artificial Life and Robotics**, Springer Science e Business Media LLC, v. 19, n. 4, p. 388–393, nov. 2014. DOI: 10.1007/s10015-014-0177-6. Disponível em: <https://doi.org/10.1007/s10015-014-0177-6>.

SAMMUT, Claude. Robot soccer. **Wiley Interdisciplinary Reviews: Cognitive Science**, v. 1, n. 6, p. 824–833, 2010. DOI: 10.1002/wcs.86. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/wcs.86>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/wcs.86>.

SASKA, M. et al. Robot Path Planning using Particle Swarm Optimization of Ferguson Splines. In: 2006 IEEE Conference on Emerging Technologies and Factory Automation. [S.l.]: IEEE Computer Society, set. 2006. P. 833–839. DOI: 10.1109/ETFA.2006.355416. Disponível em: <https://doi.org/10.1109/ETFA.2006.355416>.

SCHWAB, Devin; ZHU, Yifeng; VELOSO, Manuela. Learning Skills for Small Size League RoboCup. In: PROCEEDINGS of the RoboCup Symposium. Montreal, Canada: Springer, jun. 2018. P. 83–95. ISBN 978-3-030-27544-0. DOI: 10.1007/978-3-030-27544-0\_7. Disponível em: [https://doi.org/10.1007/978-3-030-27544-0\\_7](https://doi.org/10.1007/978-3-030-27544-0_7).

SHAARI, Gad; TEKBIYIK-ERSOY, Neyre; DAGBASI, Mustafa. The State of Art in Particle Swarm Optimization Based Unit Commitment: A Review. **Processes**, v. 7, p. 733, out. 2019. DOI: 10.3390/pr7100733. Disponível em: <https://doi.org/10.3390/pr7100733>.

SHAKIBA, R.; NAJAFIPOUR, M.; SALEHI, M. E. An improved PSO-based path planning algorithm for humanoid soccer playing robots. In: 2013 3rd Joint Conference of AI

Robotics and 5th RoboCup Iran Open International Symposium. [S.l.: s.n.], abr. 2013. P. 1–6. DOI: 10.1109/RIOS.2013.6595312. Disponível em: <https://doi.org/10.1109/RIOS.2013.6595312>.

SHI, Yuhui; EBERHART, R.C. A modified particle swarm optimizer. In: 1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360). [S.l.: s.n.], mai. 1998. P. 69–73. DOI: 10.1109/ICEC.1998.699146. Disponível em: <https://doi.org/10.1109/ICEC.1998.699146>.

SILVA, I. J. et al. Using Reinforcement Learning to Improve the Stability of a Humanoid Robot: Walking on Sloped Terrain. In: 2015 12th Latin American Robotics Symposium and 2015 3rd Brazilian Symposium on Robotics (LARS-SBR). [S.l.]: IEEE Computer Society, 2015. P. 210–215. DOI: 10.1109/LARS-SBR.2015.41. Disponível em: <https://doi.org/10.1109/LARS-SBR.2015.41>.

SINGH, Garima; DEEP, Kusum. Role of Particle Swarm Optimization in Computer Games. In: DAS, Kedar Nath et al. (Ed.). **Proceedings of Fourth International Conference on Soft Computing for Problem Solving**. New Delhi: Springer India, 2015. P. 259–277. ISBN 978-81-322-2220-0. DOI: 10.1007/978-81-322-2220-0\_21. Disponível em: [https://doi.org/10.1007/978-81-322-2220-0\\_21](https://doi.org/10.1007/978-81-322-2220-0_21).

SMALL SIZE LEAGUE TECHNICAL COMMITTEE. **AutoRef Challenge**. [S.l.: s.n.], 2016. RoboCup Small Size League. Disponível em: <https://ssl.robocup.org/robocup-2016-technical-challenges/>.

SMALL SIZE LEAGUE TECHNICAL COMMITTEE. **Hall of Fame**. [S.l.: s.n.], 2019. RoboCup Small Size League. Acesso em 03/12/2019. Disponível em: <https://ssl.robocup.org/hall-of-fame/>.

SMALL SIZE LEAGUE TECHNICAL COMMITTEE. **Laws of the RoboCup Small Size League**. [S.l.], jan. 2018. Disponível em: <https://github.com/RoboCup-SSL/ssl-rules>.

SMALL SIZE LEAGUE TECHNICAL COMMITTEE. **Laws of the RoboCup Small Size League 2017**. [S.l.], mai. 2017. Disponível em: [http://wiki.robocup.org/images/1/12/Small\\_Size\\_League\\_-\\_Rules\\_2017.pdf](http://wiki.robocup.org/images/1/12/Small_Size_League_-_Rules_2017.pdf).

SMALL SIZE LEAGUE TECHNICAL COMMITTEE. **RoboCup Small Size League Shared Vision System**. [S.l.: s.n.], 2009. <https://github.com/RoboCup-SSL/ssl-vision>. Disponível em: <https://github.com/RoboCup-SSL/ssl-vision>.

SMALL SIZE LEAGUE TECHNICAL COMMITTEE. **Rules of the RoboCup Small Size League**. [S.l.], 2019. Disponível em: <https://robocup-ssl.github.io/ssl-rules/2019/sslrules.html>.

SPECTOR, Lee et al. Emergence of Collective Behavior in Evolving Populations of Flying Agents. In: CANTÚ-PAZ, Erick et al. (Ed.). **Genetic and Evolutionary Computation — GECCO 2003**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. P. 61–73. ISBN 978-3-540-45105-1.

STONE, Peter; VELOSO, Manuela; RILEY, Patrick. The CMUnited-98 Champion Simulator Team. In: ASADA, Minoru; KITANO, Hiroaki (Ed.). **RoboCup-98: Robot Soccer World Cup II**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1999. P. 61–76. ISBN 978-3-540-48422-6. DOI: 10.1007/3-540-48422-1\_5. Disponível em: [https://doi.org/10.1007/3-540-48422-1\\_5](https://doi.org/10.1007/3-540-48422-1_5).

TEOLDO DA COSTA, Israel et al. System of tactical assessment in Soccer (FUT-SAT): Development and preliminary validation. **Motricidade**, v. 7, p. 69–84, dez. 2010. Publicado também em português como: Sistema de avaliação tática no Futebol (FUT-SAT): Desenvolvimento e validação preliminar. DOI: 10.6063/motricidade.7(1).121.

TREVIZAN, Felipe W.; VELOSO, Manuela M. Learning Opponent's Strategies in the RoboCup Small-Size League. In: PROC. of AAMAS'10 Workshop on Agents in Real-time and Dynamic Environments. [S.l.: s.n.], 2010. Disponível em: <papers/trevizan10:robocup.pdf>.

UNISINOS. **Dicionário Olímpico**. Edição: Universidade do Vale do Rio dos Sinos. 2016. Disponível em: <http://www.dicionarioolimpico.com.br>. Acesso em: 29 mai. 2019.

UNISINOS. **Field – Dicionário de expressões de futebol**. Edição: Universidade do Vale do Rio dos Sinos. 2014. Disponível em: <http://dicionariofield.com.br/>. Acesso em: 29 mai. 2019.

VICSEK, Tamás et al. Novel Type of Phase Transition in a System of Self-Driven Particles. **Phys. Rev. Lett.**, American Physical Society, v. 75, p. 1226–1229, 6 ago. 1995. DOI: 10.1103/PhysRevLett.75.1226. Disponível em: <https://doi.org/10.1103/PhysRevLett.75.1226>.

VISSER, Ubbo; WELAND, Hans-Georg. Using Online Learning to Analyze the Opponent's Behavior. In: KAMINKA, Gal A.; LIMA, Pedro U.; ROJAS, Raúl (Ed.). **RoboCup**. [S.l.]: Springer, 2002. v. 2752. (Lecture Notes in Computer Science), p. 78–93. ISBN 3-540-40666-2. DOI: 10.1007/978-3-540-45135-8\_7. Disponível em: [http://dx.doi.org/10.1007/978-3-540-45135-8\\_7](http://dx.doi.org/10.1007/978-3-540-45135-8_7).

WAHAB, Mohd Nadhir Ab; NEFTI-MEZIANI, Samia; ATYABI, Adham. A Comprehensive Review of Swarm Optimization Algorithms. **PLoS One**, v. 10, mai. 2015. ISSN 1932-6203. DOI: 10.1371/journal.pone.0122827. Disponível em: <https://doi.org/10.1371/journal.pone.0122827>.

WAIBEL, Markus; FLOREANO, Dario; KELLER, Laurent. A Quantitative Test of Hamilton's Rule for the Evolution of Altruism. **PLOS Biology**, Public Library of Science, v. 9, n. 5, p. 1–7, mai. 2011. DOI: 10.1371/journal.pbio.1000615. Disponível em: <https://doi.org/10.1371/journal.pbio.1000615>.

WANG, Li et al. Obstacle-avoidance Path Planning for Soccer Robots Using Particle Swarm Optimization. In: 2006 IEEE International Conference on Robotics and Biomimetics. [S.l.]: IEEE Computer Society, dez. 2006. P. 1233–1238. DOI: 10.1109/ROBIO.2006.340104. Disponível em: <https://doi.org/10.1109/ROBIO.2006.340104>.

WEITZENFELD, Alfredo et al. RoboCup Small-Size League: Past, Present and Future. In: **RoboCup 2014: Robot World Cup XVIII**. Edição: Reinaldo A. C. Bianchi. [S.l.]: Springer International Publishing, 2015. P. 611–623. ISBN 978-3-319-18615-3. DOI: 10.1007/978-3-319-18615-3\_50. Disponível em: [http://dx.doi.org/10.1007/978-3-319-18615-3%5C\\_50](http://dx.doi.org/10.1007/978-3-319-18615-3%5C_50).

WU, Chia-Ju; LEE, Tsong-Li. A Fuzzy Mechanism for Action Selection of Soccer Robots. **Journal of Intelligent and Robotic Systems**, v. 39, n. 1, p. 57–70, jan. 2004. ISSN 1573-0409. DOI: 10.1023/B:JINT.0000010795.04819.90. Disponível em: <https://doi.org/10.1023/B:JINT.0000010795.04819.90>.

XIN, J.; CHEN, G.; HAI, Y. A Particle Swarm Optimizer with Multi-stage Linearly-Decreasing Inertia Weight. In: 2009 International Joint Conference on Computational Sciences and Optimization. [S.l.: s.n.], abr. 2009. v. 1, p. 505–508. DOI: 10.1109/CSO.2009.420. Disponível em: <https://doi.org/10.1109/CSO.2009.420>.

YANG, Xin-She. Firefly Algorithms for Multimodal Optimization. In: **Stochastic Algorithms: Foundations and Applications: 5th International Symposium, SAGA 2009, Sapporo, Japan, October 26-28, 2009. Proceedings**. Edição: Osamu Watanabe e Thomas Zeugmann. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. P. 169–178. ISBN 978-3-642-04944-6. DOI: 10.1007/978-3-642-04944-6\_14. Disponível em: [https://doi.org/10.1007/978-3-642-04944-6\\_14](https://doi.org/10.1007/978-3-642-04944-6_14).

YASUI, Kotaro et al. Analyzing and Learning an Opponent's Strategies in the RoboCup Small Size League. In: ROBOCUP 2013: Robot World Cup XVII. [S.l.: s.n.], jan. 2014. P. 159–170. ISBN 978-3-662-44467-2. DOI: 10.1007/978-3-662-44468-9\_15. Disponível em: [https://doi.org/10.1007/978-3-662-44468-9\\_15](https://doi.org/10.1007/978-3-662-44468-9_15).

YOON, Moonyoung; BEKKER, James; KROON, Steve. New reinforcement learning algorithm for robot soccer. **ORION**, v. 33, fev. 2016. DOI: 10.5784/33-1-542. Disponível em: <https://doi.org/10.5784/33-1-542>.

ZHANG, Yudong; WANG, Shuihua; JI, Genlin. A Comprehensive Survey on Particle Swarm Optimization Algorithm and Its Applications. **Mathematical Problems in Engineering**, v. 2015, p. 38, 2015. DOI: 10.1155/2015/931256. Disponível em: <http://dx.doi.org/10.1155/2015/931256>.



## **APÊNDICE A – FUNÇÕES MATEMÁTICAS AUXILIARES**

Neste anexo estão disponíveis as equações matemáticas auxiliares utilizadas nas definições das métricas e equações de otimização.

#### A.1 VERIFICAÇÃO DE EXISTÊNCIA DE RETA

A função (51) verifica se os pontos  $P_1$ ,  $P_2$  e  $P_3$  formam uma reta.

$$f_{estaNaReta}(P_1, P_2, P_3) = ((P_{3y} - P_{2y}) \times P_{1x} + (P_{2x} - P_{3x}) \times P_{1y} + (P_{3x} \times P_{2y} - P_{2x} \times P_{3y})) = 0 \quad (51)$$

#### A.2 VERIFICAR SE UM PONTO ESTÁ ESQUERDA OU DIREITA

A função (52) verifica se o ponto  $P_1$  está a direita ou esquerda dos pontos  $P_2$  e  $P_3$ .

$$f_{DireitaEsquerda}(P_1, P_2, P_3) = \left\{ \begin{array}{ll} \text{ESQUERDA,} & \text{if } ((P_{3y} - P_{2y}) \times P_{1x} + \\ & (P_{2x} - P_{3x}) \times P_{1y} + (P_{3x} \times P_{2y} - P_{2x} \times P_{3y})) < 0 \\ \\ \text{DIREITA,} & \text{if } ((P_{3y} - P_{2y}) \times P_{1x} + \\ & (P_{2x} - P_{3x}) \times P_{1y} + (P_{3x} \times P_{2y} - P_{2x} \times P_{3y})) > 0 \\ \\ \text{CENTRO,} & \text{if } ((P_{3y} - P_{2y}) \times P_{1x} + \\ & (P_{2x} - P_{3x}) \times (P_{1y} + P_{3x} \times P_{2y} - P_{2x} \times P_{3y})) = 0 \end{array} \right. \quad (52)$$

#### A.3 DISTÂNCIA EUCLIDIANA

A função (53) retorna a distância Euclidiana entre dois pontos  $P_1$  e  $P_2$ .

$$f_{DistEuclidiana}(P_1, P_2) = \sqrt{(P_{1x} - P_{2x})^2 + (P_{1y} - P_{2y})^2} \quad (53)$$

#### A.4 CÁLCULO DE PONTO MÉDIO

A função (54) calcula o ponto médio entre os pontos  $P_1$  e  $P_2$ .

$$f_{pontoMedio}(P_1, P_2) = \left\{ \frac{P_{1x} + P_{2x}}{2}, \frac{P_{1y} + P_{2y}}{2} \right\} \quad (54)$$

## A.5 DISTÂNCIA DE UM PONTO A RETA

A função (55) retorna a distância do ponto  $P_1$  para a reta formada pelos pontos  $P_2$  e  $P_3$ .

$$f_{\text{DistanciaReta}}(P_1, P_2, P_3) = \frac{|a \times x_{P_1} + b \times y_{P_1} + c|}{\sqrt{a^2 + b^2}}$$

onde:

$$a = (y_{P_2} - y_{P_3}) \quad (55)$$

$$b = (x_{P_2} - x_{P_3})$$

$$c = x_{P_2} \times y_{P_3} - x_{P_3} \times y_{P_2}$$

## A.6 ÁREA DE UM CÍRCULO

A função (56) calcula a área do círculo de raio  $r$ .

$$f_{\text{areaCirculo}}(r) = r^2 \times \pi \quad (56)$$

## A.7 ÁREA DE INTERSEÇÃO DE DOIS CÍRCULOS

A função (57) calcula a área de interseção de dois círculos dado suas coordenadas e raios.

$$f_{\text{areaInterCirculo}}(P_1, P_2) = \begin{cases} 0 & \text{if } distancia > (P_{1\text{raio}} + P_{2\text{raio}}) \\ \pi \times r_b & \text{if } distancia \leq (|r_1 - r_2|) \wedge (r_1 \geq r_2) \\ \pi \times r_a & \text{if } distancia \leq (|r_1 - r_2|) \wedge (r_1 < r_2) \\ area\phi + area\theta & \text{otherwise} \end{cases}$$

**onde:**

$$distancia \leftarrow f_{DistEuclidiana}(P_1, P_2);$$

$$r_1 \leftarrow (P_{1\text{raio}})^2; \quad (57)$$

$$r_2 \leftarrow (P_{2\text{raio}})^2;$$

$$\phi \leftarrow \arccos\left(\frac{(r_1 + distancia^2 - r_2)}{(2 \times P_{1\text{raio}} \times distancia)}\right) \times 2;$$

$$\theta \leftarrow \arccos\left(\frac{(r_2 + distancia^2 - r_1)}{(2 \times P_{2\text{raio}} \times distancia)}\right) \times 2;$$

$$area\phi \leftarrow (0.5 \times \phi \times r_1) - (0.5 \times r_1 \sin(\phi));$$

$$area\theta \leftarrow (0.5 \times \theta \times r_2) - (0.5 \times r_2 \sin(\theta)).$$

## A.8 VERIFICAÇÃO DE RAIOS

A função (58) verifica se um determinado ponto  $P_2$  está no raio  $r$  de uma circunferência com centro em  $P_1$ .

$$f_{EstaNoRaio}(r, P_1, P_2) = \begin{cases} DENTRO, & \text{if } f_{DistEuclidiana}(P_1, P_2) < r \\ LIMITE, & \text{if } f_{DistEuclidiana}(P_1, P_2) = r \\ FORA, & \text{if } f_{DistEuclidiana}(P_1, P_2) > r \end{cases} \quad (58)$$