



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

MATHEUS PAIXÃO GUMERCINDO DOS SANTOS

Título: Aplicação do Método FTOPSIS Class na Classificação e Seleção de Passes no Futebol de Robôs

Recife

2025

MATHEUS PAIXÃO GUMERCINDO DOS SANTOS

Título: Aplicação do Método FTOPSIS Class na Classificação e Seleção de Passes no Futebol de Robôs

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de bacharel em Ciência da Computação.

Área de Concentração: Otimização

Orientador (a): Adiel Teixeira de Almeida Filho

Recife

2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Santos, Matheus Paixão Gumercindo dos.

Aplicação do método FTOPSIS Class na classificação e seleção de passes no futebol de robôs / Matheus Paixão Gumercindo dos Santos. - Recife, 2025.
59 p. : il., tab.

Orientador(a): Adiel Teixeira de Almeida Filho

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Informática, Ciências da Computação - Bacharelado, 2025.

Inclui referências.

1. FTOPSIS-Class. 2. Seleção de Passe. 3. Tomada de decisão multicritério. 4. Classificação Fuzzy. 5. Small Size League. I. Almeida Filho, Adiel Teixeira de. (Orientação). II. Título.

000 CDD (22.ed.)

MATHEUS PAIXÃO GUMERCINDO DOS SANTOS

Aplicação do Método FTOPSIS Class na Classificação e Seleção de Passes no Futebol de Robôs

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de bacharel em Ciência da Computação.

Aprovado em: 15/08/2025

BANCA EXAMINADORA

Prof. Dr. Adiel Teixeira de Almeida Filho (Orientador)

Universidade Federal de Pernambuco

Profa. Dra. Edna Natividade da Silva Barros (Examinadora Interna)

Universidade Federal de Pernambuco

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela força e pela oportunidade de chegar até aqui e concluir mais uma importante etapa da minha vida.

Expresso minha profunda gratidão aos meus pais, Antônio e Edinalva, pelo suporte e apoio incondicional em todos os momentos, bons e difíceis, nunca poupando esforços para que eu pudesse crescer e evoluir, além do amor inestimável que sempre me ofereceram. Agradeço também à minha irmã, Duda, pelo cuidado, pelo companheirismo e pelos momentos de alegria que tornaram esta caminhada mais leve. Aos meus avós e tios, agradeço o carinho, o apoio e o encorajamento que sempre me transmitiram.

Sou grato a Bianca, que acompanhou de perto o crescimento meu e de minha irmã, e a Germana (Mana) e Azael (Seu Zal), meus padrinhos, pelo carinho e pelo suporte oferecido à minha família ao longo da minha criação. Registro também meu agradecimento aos amigos do colégio — Diogo, Leo, Luiz, Nicholas, Rafael, Gabriel, Sencades, Sophia, João, Camila, Cibele e George — pelos momentos de amizade, diversão e companheirismo.

Agradeço à minha vizinha Mary, que tanto ajudou minha mãe a cuidar de mim e de minha irmã, e aos seus filhos, especialmente Francisco (Chico), cuja influência foi fundamental na minha escolha pelo curso de Ciência da Computação. Sou grato ainda ao Colégio Rosa Gattorno e ao Colégio CBV, pelas bases de formação que me proporcionaram, e ao Centro de Informática pela estrutura de excelência que possibilitou meu desenvolvimento acadêmico e pessoal durante a graduação.

Estendo meus agradecimentos ao Prof^o Adiel Teixeira, pela orientação neste trabalho, e à Prof^a Edna Barros, pela orientação, cuidado e acolhimento ao longo do meu percurso no Robô-CIn. Ao RobôCIn, deixo meu sincero reconhecimento e agradecimento pelo papel fundamental na minha formação pessoal e profissional como um espaço de aprendizado, amadurecimento e amizades que levarei para a vida. A todos os colegas dessa equipe, agradeço pelas lições e pelo convívio, em especial a Lucas Cavalcanti, Riei Joaquim, Matheus Teotônio, José Victor, Matheus Lafayette, Felipe Nunes, Drielle, Roberto Fernandes, Marcela, João e Beatriz Barros.

Por fim, agradeço aos amigos que fiz durante a graduação, em especial Amadeo, Bruno, Cauê e Eduardo, cuja amizade tornou esta jornada mais significativa, enriquecedora e divertida.

RESUMO

Modelos de decisão em tempo real são essenciais para o desempenho de sistemas multia-
gentes. No contexto de futebol de robôs da RoboCup Small Size League (SSL), esses modelos
devem interpretar o estado do jogo, como as posições de aliados, adversários e oportunidades
de finalização, para otimizar escolhas e aumentar a efetividade ofensiva. Um dos desafios é a
seleção de qual passe vai ser dado, e muitas equipes ainda utilizam estratégias simples, como
soma ponderada ou multiplicação de métricas, em vez de métodos multicritério robustos. Este
trabalho propõe integrar o método FTOPSIS-Class, método fuzzy de classificação multicrité-
rio, ao pipeline de seleção de passes. Com a técnica proposta, o sistema gera alternativas de
passe, que são avaliadas por sete métricas, cujos valores são convertidos em classes linguísticas
e classificados em três categorias, priorizando as mais promissoras. A abordagem foi implemen-
tada no SSL-Unification, software de controle da equipe RobôCIn, e avaliada por simulação
contra a versão original baseada na multiplicação de métricas. A nova abordagem apresentou
maior posse de bola, passes de melhor qualidade e 6 vitórias em 10 partidas simuladas. Assim,
esse trabalho conclui que a classificação fuzzy pode aumentar a robustez e a qualidade das
decisões.

Palavras-chaves: FTOPSIS-Class. Seleção de Passes. Tomada de decisão multicritério. Clas-
sificação Fuzzy. Small Size League.

ABSTRACT

Real-time decision models are essential for the performance of multi-agent systems. In the context of RoboCup Small Size League (SSL) robot soccer, these models must interpret the game state, such as the positions of teammates, opponents, and scoring opportunities, to optimize choices and increase offensive effectiveness. One of the challenges is selecting which pass to make, and many teams still rely on simple strategies such as weighted sums or metric multiplication instead of robust multicriteria methods. This work proposes integrating the FTOPSIS-Class method, a fuzzy multicriteria classification approach, into the pass selection pipeline. With the proposed technique, the system generates pass alternatives, evaluates them using seven metrics, converts their values into linguistic classes, and classifies them into three categories, prioritizing the most promising ones. The approach was implemented in SSL-Unification, the control software of the RobôCIn team, and evaluated through simulations against the original version based on metric multiplication. The new approach demonstrated higher ball possession, better-quality passes, and 6 wins in 10 simulated matches. Thus, this work concludes that fuzzy classification can enhance both the robustness and the quality of decisions.

Keywords: FTOPSIS-Class. Pass Selection. Multi-criteria Decision Making. Fuzzy Classification. Small Size League.

LISTA DE FIGURAS

Figura 1 – Materiais da categoria SSL.	13
Figura 2 – Pipeline padrão para a seleção de passes.	16
Figura 3 – Versões do Raycast.	19
Figura 4 – Diferenças entre a projeção que tangencia o robô e a projeção utilizada nos cálculos.	19
Figura 5 – Pipeline proposto, com destaque à nova fase de classificação em amarelo.	26
Figura 6 – Geração e filtragem dos passes. A bola está localizada exatamente no centro do campo e é representada pelo círculo laranja.	28
Figura 7 – Distribuição das pontuações da métrica <i>Ally Time Margin</i> em três cenários, da esquerda para a direita: bola muito distante dos aliados (alta margem de tempo), distância moderada (margem média) e bola próxima (baixa margem). O gol aliado está na parte superior e o adversário, na inferior. Os círculos amarelos representam os jogadores aliados.	29
Figura 8 – Pontuações da métrica <i>Enemy Proximity</i> em três cenários, da esquerda para a direita: bola distante (grandes zonas vermelhas), moderadamente distante (zonas médias) e próxima aos adversários (zonas pequenas). O gol aliado está na parte superior, o adversário na inferior. Círculos azuis indicam os oponentes.	32
Figura 9 – Distribuição das pontuações calculadas pela métrica <i>Goal Distance</i> . As melhores pontuações estão próximas ao gol adversário, que está na parte de baixo da imagem.	34
Figura 10 – Distribuição das pontuações da métrica <i>Goal Opening</i> em duas situações distintas, da esquerda para a direita: adversários agrupados e adversários dispersos. O gol aliado está localizado na parte superior da imagem e o gol adversário, na inferior.	35
Figura 11 – Distribuição das pontuações da métrica <i>Ideal Range</i> , evidenciando: uma região central de baixa pontuação para passes muito próximos à bola, um anel verde correspondente à faixa ideal, e uma zona externa também de baixa pontuação para distâncias superiores ao ideal. O gol aliado está na parte superior e o adversário, na inferior.	38

Figura 12 – Distribuição das pontuações da métrica <i>Pass Interception</i> . Áreas vermelhas indicam regiões com alta chance de intercepção. O adversário próximo à bola não gera zona vermelha devido à possibilidade de um passe de "chip" por cima do robô. O gol aliado está na parte superior da imagem e o adversário, na inferior.	39
Figura 13 – Distribuição das pontuações calculadas pela métrica <i>Redirect Goal Kick</i> , com ênfase no ângulo considerado para o cálculo da métrica. O destino 1 recebe baixa pontuação pois o ângulo α_1 é maior que o limiar θ . Já o destino 2 recebe alta pontuação devido ao ângulo α_2 ser menor que θ	41
Figura 14 – Distribuição das pontuações calculadas pela métrica <i>Redirect Goal Kick</i> para 3 situações diferentes, da esquerda para a direita: bola próxima ao gol adversário, bola no meio de campo e bola próxima ao gol aliado. O gol aliado está localizado na parte superior da imagem, enquanto o gol adversário encontra-se na porção inferior.	41
Figura 15 – Fluxograma da fase de classificação. Em amarelo estão os passos do FTOPSIS-Class. Em azul, passos extras necessários para o funcionamento do método.	42
Figura 16 – Distribuição da classificação no campo, considerando posições específicas dos robôs aliados (em amarelo), adversários (em azul) e da bola (em laranja com um alvo ao redor). As regiões em verde indicam passes classificados como ótimos; as em amarelo, como aceitáveis; e as em vermelho correspondem a regiões avaliadas como sub-ótimas. O campo foi segmentado em áreas numeradas para destacar a influência de diferentes métricas na classificação final de cada região. As linhas tracejadas representam fronteiras aproximadas das regiões de influência de cada métrica.	45

LISTA DE TABELAS

Tabela 1 – Números fuzzy atribuídos a cada classe qualitativa e a cada nível de peso. .	43
Tabela 2 – Limiar inferior de cada faixa de classificação por métrica, utilizadas para classificar as pontuações nas cinco classes qualitativas.	44
Tabela 3 – Matriz de perfil. Indica os valores esperados que uma alternativa deve ter em cada critério para pertencer a uma classe específica.	44
Tabela 4 – Vetor de pesos. Define a importância relativa de cada critério no processo decisório.	44
Tabela 5 – Resultados gerais das partidas para as versões atual e nova	52
Tabela 6 – Valores de cada métrica por partida para as versões atual e nova do time. .	53
Tabela 7 – Médias por partida e percentuais das métricas para as versões atual e nova	54

SUMÁRIO

1	INTRODUÇÃO	12
2	FUNDAMENTAÇÃO	15
2.1	ESTRATÉGIAS EXISTENTES PARA AVALIAÇÃO DE PASSES E POSICIONAMENTO	15
2.2	CLASSIFICAÇÃO MULTICRITÉRIO COM FTOPSIS-CLASS	17
2.3	RAYCAST	18
2.4	MÉTRICAS UTILIZADAS NA AVALIAÇÃO DOS EXPERIMENTOS	20
2.4.1	Número de Passes Progressivos	20
2.4.2	Número de Passes-chave	21
2.4.3	Inclinação de campo	21
3	METODOLOGIA	23
3.1	TERMINOLOGIA	23
3.1.1	Passes	23
3.1.2	Suportes	24
3.2	PIPELINE DO POSICIONAMENTO DOS SUPORTES	25
3.2.1	Geração de passes	26
3.2.2	Filtragem de passes	27
3.2.3	Avaliação dos passes	28
3.2.3.1	<i>Ally Time Margin Score (ATM)</i>	29
3.2.3.2	<i>Enemy Proximity Score (EP)</i>	31
3.2.3.3	<i>Goal Distance Score (GD)</i>	33
3.2.3.4	<i>Goal Opening Score (GO)</i>	35
3.2.3.5	<i>Ideal Range Score (IR)</i>	36
3.2.3.6	<i>Pass Interception Score (PI)</i>	38
3.2.3.7	<i>Redirect Goal Kick Score (RGK)</i>	40
3.2.4	Classificação dos passes	42
3.2.5	Seleção dos passes	46
3.3	ALGORITMO SHADOW	48
3.3.1	Experimentos	50
4	RESULTADOS E DISCUSSÃO	52

5	CONCLUSÃO	56
5.1	LIMITAÇÕES	56
5.2	TRABALHOS FUTUROS	57
	REFERÊNCIAS	58

1 INTRODUÇÃO

O futebol é um jogo altamente estratégico e dinâmico. Desde sua origem no século XIX, as táticas evoluíram continuamente, da W-M ao Total Football, até os estilos contemporâneos. Entre esses, o jogo posicional, associado a treinadores como Pep Guardiola, destaca-se por priorizar o posicionamento dos jogadores, a manutenção da posse de bola e a ocupação racional dos espaços do campo com o objetivo de gerar desorganizações na linha defensiva adversária e, conseqüentemente, oportunidades de finalização de maior qualidade. Pela precisão posicional requerida e pela necessidade de sincronização entre os jogadores, esse estilo é frequentemente descrito como “robótico” e apresenta forte afinidade com soluções algorítmicas.

A RoboCup (ROBOCUP, 1997a), considerada a maior competição de robótica e inteligência artificial do mundo, estabelece como meta que, até 2050, um time de robôs humanoides autônomos deve ser capaz de vencer uma partida contra os campeões da Copa do Mundo de futebol, seguindo as regras oficiais da FIFA. Para alcançar esse objetivo, além do hardware e software capazes de replicar as habilidades de movimentação humanas, será fundamental incorporar táticas de futebol eficazes, a fim de aproximar o desempenho estratégico dos robôs ao de jogadores humanos. Nesse cenário, o jogo posicional surge como uma abordagem promissora para ser adaptada ao futebol de robôs, pois sua natureza sistemática e estruturada facilita a formulação de regras e heurísticas compatíveis com implementação computacional.

A categoria *Small Size League* (SSL) da RoboCup (ROBOCUP, 1997b) desafia equipes a desenvolver sistemas capazes de coordenar robôs autônomos em partidas de futebol. Nessa categoria, a bola utilizada é do tipo golfe, Figura 1(a), os robôs são cilíndricos e medem 18 cm de diâmetro por 15 cm de altura, como mostrados na Figura 1(b), e as partidas são disputadas entre dois times com 11 robôs cada, em um campo de 12×9 m. Embora as regras sejam semelhantes às do futebol tradicional, a SSL caracteriza-se por elevada dinamicidade. Assim, o posicionamento eficiente dos robôs e a rapidez e precisão na troca de passes são fundamentais para manter a posse de bola, construir jogadas ofensivas e criar oportunidades de finalização.

Diversas equipes da RoboCup já se dedicaram à otimização do posicionamento e da troca de passes entre robôs. A abordagem mais comum envolve gerar múltiplas opções de passe, avaliá-las por diferentes métricas e, em seguida, combinar esses valores para selecionar as melhores alternativas. Entretanto, até onde se tem registro na literatura e nas práticas reportadas, não são utilizados métodos de decisão multicritério consolidados na literatura para essa agregação e

Figura 1 – Materiais da categoria SSL.

(a) Bola de golfe, utilizada na SSL.



(b) Robôs da SSL

**Fonte:** Elaborado pelo autor (2025)

seleção, recorrendo-se geralmente a estratégias simples e heurísticas próprias, que variam entre as equipes. Por exemplo, a equipe do RobôCIn utiliza um modelo que multiplica os valores das métricas e seleciona as opções com os maiores produtos (FRANCA et al., 2024). Embora simples e eficiente computacionalmente, essa estratégia apresenta uma limitação importante: um único valor muito baixo em alguma métrica pode comprometer toda a avaliação e mascarar a qualidade real das opções, mesmo que os demais indicadores sejam altamente favoráveis.

Diante desse cenário, este trabalho tem como objetivo principal investigar o uso de um método de tomada de decisão multicritério (MCDM) no processo de seleção de passes e posicionamento em jogos da RoboCup SSL. Para isso, propõe-se uma abordagem inovadora com a aplicação do método de classificação fuzzy FTOPSIS-Class (FERREIRA et al., 2018), cuja finalidade é aumentar a robustez na avaliação e na escolha das alternativas de passe disponíveis. Especificamente, busca-se avaliar, na prática, a aplicabilidade de um método MCDM consolidado na literatura em um contexto real de robótica autônoma, verificando se a abordagem fuzzy baseada no FTOPSIS-Class proporciona benefícios concretos em relação às estratégias convencionais utilizadas por equipes da SSL. Além dessa contribuição, o estudo busca formalizar matematicamente e conceitualmente um conjunto de métricas para avaliação de passes, oferecendo uma base sólida para futuras pesquisas e desenvolvimentos na área. Por fim, pretende-se analisar o impacto da técnica proposta de modo a fornecer evidências empíricas que orientem futuras aplicações de métodos fuzzy e multicritério em sistemas multiagentes colaborativos, com ênfase em competições de futebol de robôs.

O trabalho está estruturado da seguinte forma: a Seção 2 apresenta o referencial teórico e

técnico que serve de base para a proposta, abrangendo o método FTOPSIS-Class, a adaptação do algoritmo de Raycast e a formalização das métricas utilizadas na avaliação do experimento. Na Seção 3, descrevemos em detalhes a integração do método de classificação fuzzy FTOPSIS-Class ao pipeline existente de seleção de passes, bem como os algoritmos desenvolvidos e o protocolo experimental adotado para a validação da abordagem. Em seguida, a Seção 4 reúne e discute os resultados obtidos nos experimentos. Por fim, a Seção 5 apresenta as conclusões do estudo, suas limitações e as perspectivas para trabalhos futuros.

2 FUNDAMENTAÇÃO

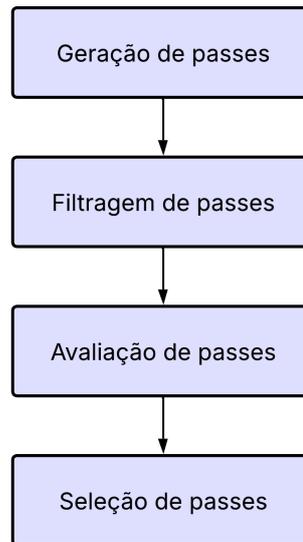
Neste capítulo, apresenta-se o referencial teórico e técnico que fundamenta a proposta desenvolvida e orienta as escolhas metodológicas realizadas. Inicialmente, discutimos o fluxo adotado por equipes da RoboCup Small Size League (SSL) para a avaliação de passes e posicionamento, destacando suas etapas principais e variações próprias das equipes. Em seguida, descrevemos o arcabouço de decisão multicritério empregado neste trabalho, com ênfase no método TOPSIS, em sua extensão fuzzy (FTOPSIS) e na variante FTOPSIS-Class. Na sequência, descreve-se a adaptação da técnica de Raycast ao contexto da SSL, com o objetivo de identificar obstruções em passes e finalizações. Por fim, apresentamos e fundamentamos as métricas táticas utilizadas para avaliar os experimentos.

2.1 ESTRATÉGIAS EXISTENTES PARA AVALIAÇÃO DE PASSES E POSICIONAMENTO

A otimização das decisões de passe e de posicionamento constitui um dos principais desafios táticos da RoboCup Small Size League (SSL). Diferentemente do contexto humano, em que tais decisões são tomadas de forma intuitiva, a implementação para robôs exige abordagens sistemáticas, formalizadas em algoritmos capazes de serem implementados programaticamente. Nesse sentido, as equipes de referência na SSL têm desenvolvido abordagens que estruturam esse problema em etapas bem definidas, o que permite a transformação de conhecimentos táticos em algoritmos executáveis.

De modo geral, tais abordagens seguem variações do fluxo descrito pela equipe TIGERs Mannheim (GEIGER et al., 2025), ilustrado pela Figura 2. Ele é composto por quatro etapas principais: (1) geração de múltiplas opções de passes ou posicionamentos; (2) filtragem das opções inviáveis; (3) avaliação das alternativas restantes, por meio de métricas específicas; e (4) seleção das melhores opções. As métricas empregadas na etapa de avaliação variam conforme a estratégia da equipe, mas usualmente consideram fatores como distância do passe, alinhamento com o gol, cobertura defensiva, ângulo de recepção e potencial de continuidade da jogada.

Figura 2 – Pipeline padrão para a seleção de passes.



Fonte: Elaborado pelo autor (2025)

A etapa de seleção final das opções avaliadas é um ponto de divergência entre as metodologias adotadas pelas diferentes equipes. A equipe TIGERs Mannheim, por exemplo, utiliza um sistema baseado em regras de decisão hierárquicas, nas quais os valores das métricas são analisados individualmente para cada tipo de ação, e as decisões são tomadas conforme uma ordem de prioridade predefinida (GEIGER et al., 2025). A prioridade das ações é definida conforme a seguinte ordem: chute a gol de primeira, chute a gol com preparação, passe de primeira e passe com preparação. A principal vantagem dessa estratégia é a interpretabilidade e previsibilidade das decisões. Porém, a rigidez hierárquica tende a sacrificar a flexibilidade em cenários não previstos.

Por sua vez, a equipe ZJUNlict, da Universidade de Zhejiang, combina os resultados das métricas em um valor único por meio de uma soma ponderada, em que cada métrica recebe um peso que reflete sua importância relativa para a decisão final (HUANG et al., 2023). As pontuações finais das alternativas são comparadas e as opções com maior valor agregado são selecionadas. Essa abordagem permite maior flexibilidade na modelagem das prioridades táticas da equipe e é computacionalmente simples, porém a necessidade de definir pesos a priori pode exigir um extenso processo de ajuste experimental e a solução pode não generalizar bem entre diferentes contextos de jogo.

Comparativamente, ambas as estratégias apresentam trade-offs entre interpretabilidade, flexibilidade e robustez. O uso de regras hierárquicas garante controle tático explícito e maior segurança em ações críticas, mas introduz rigidez ao processo decisório e reduz a capacidade

de adaptação a cenários imprevistos. Por outro lado, a soma ponderada confere simplicidade computacional e maior adaptabilidade, porém apresenta limitações para lidar com incertezas e para capturar relações não lineares entre os critérios considerados.

Um ponto em comum entre essas abordagens, e de modo geral entre as estratégias empregadas pelas equipes na SSL, é a ausência de métodos de tomada de decisão multicritério consolidados na literatura. Em vez disso, as equipes tendem a adotar soluções próprias. Nesse contexto, a incorporação de técnicas multicritério mais expressivas, como o FTOPSIS-Class, apresenta-se como alternativa promissora, pois permite representar incertezas de maneira estruturada e considerar não linearidades nas relações entre métricas, sem comprometer a flexibilidade da avaliação.

O tópico seguinte aprofunda a fundamentação teórica dos métodos de decisão multicritério disponíveis na literatura, estabelecendo as bases para a aplicação proposta neste trabalho.

2.2 CLASSIFICAÇÃO MULTICRITÉRIO COM FTOPSIS-CLASS

O TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution) é um método clássico de decisão multicritério (MCDM), proposto inicialmente por Hwang e Yoon (1981) (HWANG; YOON, 1981), que ordena alternativas com base em sua proximidade relativa a uma solução ideal e a uma solução anti-ideal. Posteriormente, Chen (2000) (CHEN, 2000) estendeu o método para lidar com cenários envolvendo avaliações imprecisas ou linguísticas, introduzindo o FTOPSIS, uma versão fuzzy do TOPSIS. Nesse modelo, valores precisos são substituídos por termos linguísticos e conjuntos fuzzy, permitindo representar a incerteza inerente às preferências humanas.

Com base nesse arcabouço, Ferreira et al. (2018) propuseram o FTOPSIS-Class, uma extensão fuzzy do TOPSIS voltada para problemas de classificação nominal (FERREIRA et al., 2018). Diferentemente do TOPSIS tradicional, que se limita a ranquear alternativas, o FTOPSIS-Class atribui cada alternativa a uma de p classes predefinidas. Cada classe é descrita por um perfil fuzzy característico, que define o desempenho mínimo necessário para que uma alternativa seja considerada pertencente a essa categoria. O método calcula, para cada alternativa, p índices de proximidade, sendo um para cada classe, que indicam o grau de similaridade entre o desempenho da alternativa e o perfil ideal da classe correspondente.

O FTOPSIS-Class já foi aplicado em diferentes domínios. Na aplicação original, Ferreira et al. (2018) (FERREIRA et al., 2018) utilizaram o método para classificar ativos de investimento

de acordo com o perfil de risco de investidores (conservador, moderado, arrojado e agressivo). No contexto de cadeias de suprimentos, Feitosa et al. (2019) (FEITOSA; CARPINETTI; FILHO, 2019) o aplicaram para avaliar a maturidade da gestão de riscos em organizações têxteis, classificando empresas em quatro níveis de maturidade. Mais recentemente, Borenstein (2022) (FILHO et al., 2023) desenvolveu um sistema de apoio à decisão para private banking, no qual o FTOPSIS-Class foi empregado para avaliar a adequação de alternativas de investimento aos perfis de clientes, considerando regulações financeiras.

A capacidade do FTOPSIS-Class de tratar incertezas e modelar relações complexas entre variáveis torna-o particularmente relevante para este trabalho, sendo aplicado na agregação das avaliações de passes. Entre as métricas consideradas, destacam-se aquelas voltadas à análise de visibilidade e à identificação de obstruções no campo, que serão detalhadas nas seções subsequentes. Nesse contexto, o próximo tópico apresenta o conceito de raycasting e sua adaptação ao ambiente bidimensional do futebol de robôs, estabelecendo a base técnica necessário para o cálculo dessas métricas.

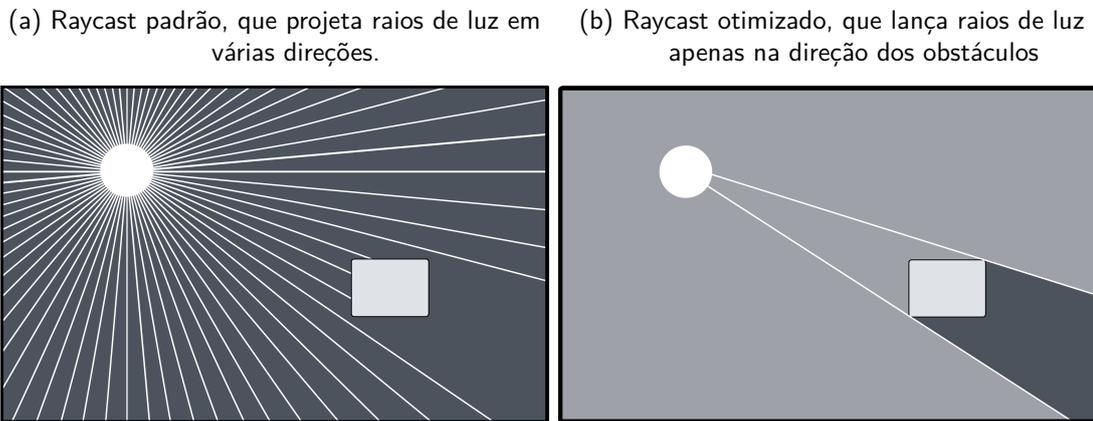
2.3 RAYCAST

O conceito de raycasting é fundamental para a compreensão do funcionamento das métricas Goal Opening Score (3.2.3.4) e Pass Interception Score (3.2.3.6). Originalmente desenvolvida para aplicações em computação gráfica, a técnica de raycasting foi uma das primeiras abordagens utilizadas para simulação de iluminação em cenas tridimensionais. Nessa configuração, o algoritmo projeta raios a partir de cada pixel da tela em direção à cena, identificando o primeiro objeto interceptado por cada raio e, a partir disso, calcula a cor do pixel com base nas propriedades do objeto. Como os raios cessam no primeiro obstáculo encontrado, essa técnica se mostra eficaz também para simular campos de visão, gerar sombras e ocultar objetos posicionados atrás de obstáculos.

No contexto de SSL, o campo pode ser representado como um plano cartesiano bidimensional, o que possibilita a adaptação do algoritmo de raycasting para uma versão em 2D. Essa adaptação permite verificar obstáculos que obstruem o campo de visão a partir de um ponto específico, por meio da projeção de raios e da identificação das regiões sombreadas, como ilustrado na Figura 3(a). Para este trabalho, foi implementada uma versão otimizada da técnica, apresentada na Figura 3(b), na qual apenas dois raios são lançados por obstáculo, diretamente em sua direção. Essa simplificação reduz significativamente o custo computacional,

pois elimina a necessidade de projetar múltiplos raios em várias direções, o que demandaria um elevado número de cálculos de interseção, e restringe o processamento às regiões de fato relevantes para a detecção de bloqueios.

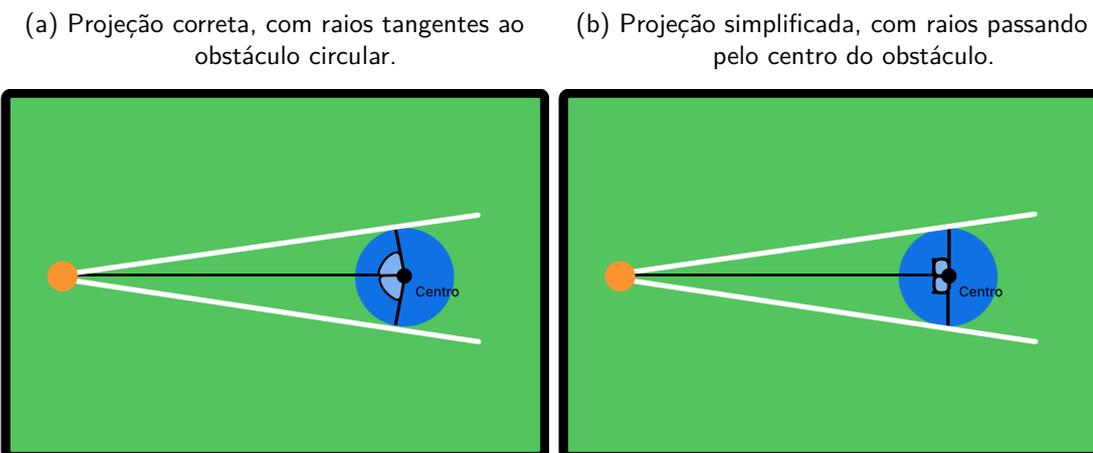
Figura 3 – Versões do Raycast.



Fonte: Elaborado pelo autor (2025)

Quanto à precisão, a simplificação adotada resulta da forma como os robôs são representados no modelo 2D. Em vez de lançar raios tangentes ao círculo que representa o robô, como na Figura 4(a), a implementação utilizada projeta dois raios passando pelo centro do obstáculo e perpendiculares à direção de chegada da bola, conforme demonstrado na Figura 4(b). Essa aproximação torna o cálculo dos raios mais eficiente, mas provoca uma subestimação da área sombreada, já que a região considerada bloqueada é ligeiramente menor do que a real.

Figura 4 – Diferenças entre a projeção que tangencia o robô e a projeção utilizada nos cálculos.



Fonte: Elaborado pelo autor (2025)

2.4 MÉTRICAS UTILIZADAS NA AVALIAÇÃO DOS EXPERIMENTOS

Dada a complexidade tática e dinâmica de uma partida de futebol, é necessário adotar um conjunto de indicadores para avaliar o desempenho sob diferentes perspectivas. Nos experimentos realizados neste trabalho, foram utilizadas múltiplas métricas com o objetivo de capturar aspectos complementares da performance ofensiva da equipe. As métricas consideradas incluem: taxa de conclusão de passes, número médio de finalizações por partida, quantidade de gols marcados por jogo, número de passes progressivos, número de passes-chave (key passes) e inclinação de campo (field tilt).

A taxa de conclusão de passes mensura o percentual de passes completados com sucesso, ou seja, recebidos por um companheiro de equipe, em relação ao total de passes tentados. Já o número médio de finalizações por partida e o número de gols marcados são indicadores diretos de ofensividade e efetividade nas ações de ataque.

As demais métricas possuem natureza mais específica e são amplamente utilizadas em análises táticas modernas. Por esse motivo, apresentamos, nos parágrafos seguintes, uma fundamentação teórica e técnica para cada uma delas.

2.4.1 Número de Passes Progressivos

O conceito de passe progressivo é amplamente adotado na análise tática do futebol com o intuito de quantificar a capacidade de uma equipe ou jogador de romper linhas defensivas e promover avanços territoriais. Esses passes contribuem diretamente para a construção de jogadas ofensivas e a criação de oportunidades de gol, sendo indicadores importantes do desempenho coletivo e individual em campo.

De acordo com o glossário da Wyscout (WYSCOUT, 2025b), empresa especializada em análise de dados futebolísticos, um passe é classificado como progressivo quando há um avanço significativo da bola em direção ao gol adversário. Tal avanço é considerado significativo a depender da distância percorrida e da localização no campo. Especificamente, para um campo de futebol com as dimensões mínimas oficiais estabelecidas pela FIFA (100 × 64 metros), um passe é considerado progressivo se:

- A distância entre o ponto de origem e o ponto de recepção for de pelo menos 30 metros mais próximo do gol adversário, caso ambos estejam no campo de defesa da equipe;

- A distância for de pelo menos 15 metros, caso o ponto de origem e o de recepção estejam em metades opostas do campo;
- A distância for de pelo menos 10 metros, caso ambos os pontos estejam no campo de ataque da equipe (ou seja, no campo de defesa do adversário).

2.4.2 Número de Passes-chave

Um passe-chave é definido como aquele que resulta imediatamente em uma oportunidade clara de finalização para um companheiro de equipe (WYSCOUT, 2025a). O número de passes-chave mede a quantidade desses passes durante uma partida de futebol. O uso dessa métrica se dá pela sua capacidade de oferecer uma avaliação objetiva da influência ofensiva de um jogador. Além disso, ela reflete atributos como visão de jogo, tomada de decisão e capacidade de participação em jogadas decisivas.

2.4.3 Inclinação de campo

A métrica de inclinação de campo (field tilt) é calculada como a proporção de passes realizados no terço final do campo por uma equipe em relação ao total de passes no terço final de ambas as equipes (WILLIS, 2025). Por exemplo, se o time A completou 70 passes em seu terço ofensivo e o time B completou 30, a inclinação de campo será de 70% para o time A e 30% para o time B. A relevância dessa métrica nas análises de desempenho está na sua capacidade de quantificar o grau de domínio territorial ofensivo de uma equipe ao longo da partida. Conforme The Football Analyst, seu valor reside na capacidade de complementar a estatística de posse de bola tradicional (ANALYST, 2025). Enquanto a posse de bola, isoladamente, não revela a localização das ações em campo, a inclinação de campo permite identificar qual equipe manteve a posse em zonas de maior perigo ofensivo, oferecendo uma estimativa mais precisa da pressão ofensiva exercida.

Um exemplo de aplicação prática da métrica está no artigo “Should we care about Field Tilt?” (WILLIS, 2025), no qual um gráfico temporal de field tilt é utilizado para analisar a dominância territorial do Arsenal. O autor observa que a equipe venceu com maior frequência quando manteve um alto field tilt, com média de 63% nas vitórias. Apesar de não ser um estudo acadêmico, o caso ilustra o uso da métrica para fazer a correlação entre domínio territorial e

resultados das partidas.

3 METODOLOGIA

Esta pesquisa se caracteriza pela sua natureza experimental, sendo desenvolvida durante minha participação no RobôCIn. O foco principal foi o aprimoramento da tomada de decisão autônoma relacionada à seleção de passes ofensivos em partidas de futebol entre robôs. O sistema foi projetado para avaliar as opções de passes disponíveis a partir das informações do campo e realizar decisões vantajosas em tempo real.

Nesta seção, apresentamos em detalhes a implementação do pipeline de seleção de passes com a nova abordagem proposta, bem como os experimentos conduzidos para validar sua eficácia. Toda a implementação foi realizada no software de SSL do RobôCIn. Inicialmente, são definidos alguns termos fundamentais para a compreensão dos demais tópicos abordados ao longo do trabalho. Em seguida, descrevemos as etapas que compõem o pipeline, destacando suas especificidades e justificativas de implementação. Na fase de avaliação, cada métrica utilizada para análise dos passes é apresentada por meio de uma descrição conceitual, formulação matemática e exemplificação com figuras. Adicionalmente, é apresentado um algoritmo desenvolvido no decorrer do trabalho, essencial para a aplicação prática da abordagem proposta. Por fim, são descritos os experimentos de validação realizados, incluindo os procedimentos adotados e as métricas empregadas na análise dos resultados obtidos.

3.1 TERMINOLOGIA

Antes de aprofundar a explicação da metodologia proposta para aprimorar o posicionamento ofensivo atual dos robôs, é necessário definir alguns conceitos fundamentais que serão utilizados ao longo do texto, de forma a facilitar a compreensão dos tópicos que seguem.

3.1.1 Passe

O conceito de passe utilizado foi adaptado a partir do conceito descrito em (GEIGER et al., 2025). Os passes possuem os seguintes atributos:

- **Origem:** A posição de onde a bola vai ser chutada.
- **Posição-alvo:** O destino do passe, que indica onde ele deve ser recebido.

- **Velocidade do chute:** A velocidade inicial da bola ao ser chutada na origem.
- **Velocidade na posição-alvo:** A velocidade da bola ao chegar ao destino.
- **Duração:** O tempo que a bola levará para ir da posição de origem até a posição-alvo.

A duração do passe e a velocidade na posição-alvo são estimadas assumindo o movimento da bola como retilíneo uniformemente variado, em que esta desacelera até alcançar a posição-alvo. O conceito de passe foi implementado no software por meio de uma classe, responsável por armazenar todas as informações que o caracterizam. Essa implementação mostrou-se essencial para o funcionamento do pipeline de posicionamento ofensivo dos robôs, uma vez que organiza e centraliza os dados relevantes para a avaliação das métricas aplicadas em etapas posteriores. Dessa forma, reduz-se a necessidade de recomputar informações já disponíveis ao longo do fluxo, o que contribui para maior eficiência e desempenho computacional do sistema.

3.1.2 Suportes

No futebol tradicional, os jogadores são distribuídos em diferentes funções de acordo com suas responsabilidades no campo, como goleiro, zagueiro, lateral, meio-campista e atacante. De forma semelhante, os robôs de um time da *Small Size League* (SSL) também são organizados segundo funções específicas que podem exercer. No entanto, devido às particularidades do jogo na SSL em comparação com o futebol tradicional, as equipes adaptam as funções dos jogadores.

No RobôCIn, as funções atribuídas aos robôs são: goleiro, defensores, suportes, que serão definidos posteriormente, e *ball handler*. Este último corresponde ao robô que detém a posse de bola e, portanto, deve adotar comportamentos específicos para conduzi-la, realizar passes ou chutar a gol. Como todos os robôs possuem o mesmo hardware, a atribuição de funções é feita de forma dinâmica: um robô que atua como defensor pode, a qualquer momento, tornar-se um suporte ou até assumir o papel de *ball handler*, conforme a necessidade.

Apesar da importância do *ball handler*, é inviável progredir ofensivamente no campo apenas com um jogador. Surge, assim, a necessidade de passar a bola para robôs bem posicionados, permitindo o avanço da equipe e criando oportunidades de finalização. Os robôs designados como suportes são responsáveis por essa tarefa: eles se posicionam em regiões estratégicas do campo com o objetivo de receber passes, contribuindo para a manutenção da posse de bola

e promovendo a progressão ofensiva da equipe até a criação de uma chance clara de chute a gol.

3.2 PIPELINE DO POSICIONAMENTO DOS SUPORTES

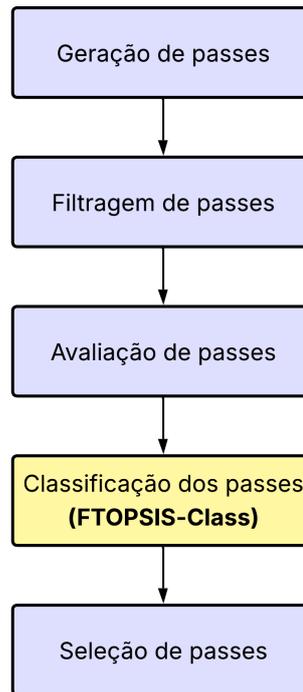
Como os suportes buscam se posicionar em regiões estratégicas para a recepção de passes, torna-se essencial identificar previamente essas regiões no campo. Conforme discutido na Seção 2.1, as equipes da SSL empregam uma abordagem padrão fundamentada nos trabalhos descritos em (FRANCA et al., 2024) e (GEIGER et al., 2025), ilustrada na Figura 2. No entanto, cada equipe implementa maneiras próprias de utilizar as avaliações obtidas para selecionar os passes, o que resulta em uma limitação recorrente: a ausência de métodos de tomada de decisão multicritério consolidados na literatura. Nesse contexto, este trabalho propõe a introdução do método FTOPSIS-Class, com o intuito de investigar se a aplicação de uma técnica de decisão multicritério pode aprimorar os resultados na seleção de passes.

A abordagem proposta segue uma lógica semelhante às metodologias anteriormente empregadas, conforme ilustrado na Figura 5. Assim como nas abordagens prévias, estão presentes as fases de geração, filtragem, avaliação e seleção de passes. Contudo, a principal inovação introduzida consiste na inclusão de uma etapa adicional: a classificação. Nessa fase, as pontuações atribuídas pelas métricas são utilizadas como entrada em um processo de classificação baseado na metodologia *FTOPSIS Class* (FERREIRA et al., 2018). Como resultado, cada passe é categorizado em uma das seguintes classes: ótimo, aceitável ou sub-ótimo. Essa etapa foi adaptada de modo a armazenar o índice de proximidade de cada passe em relação a cada uma das três categorias, informação posteriormente utilizada na fase de seleção.

Com a inclusão da fase de classificação, a etapa de seleção precisou ser adaptada. A adaptação consistiu em selecionar passes de acordo com suas classes e utilizar os índices que indicam o quão ótimo é um passe. Essa fase é responsável por escolher, entre os passes classificados como ótimos, aqueles com maior pontuação, enquanto evita a escolha de passes para pontos muito próximos entre si. Caso o número de passes ótimos não seja suficiente, o processo busca passes aceitáveis com alta pontuação e, se necessário, repete o procedimento com os passes sub-ótimos. Persistindo a necessidade de mais opções, o algoritmo permite pontos progressivamente mais próximos entre si até que a quantidade desejada de passes tenham sido selecionados.

Com a introdução da fase de classificação, a etapa de seleção foi adaptada para incorporar

Figura 5 – Pipeline proposto, com destaque à nova fase de classificação em amarelo.



Fonte: Elaborado pelo autor (2025)

as novas informações disponibilizadas. A adaptação consiste em selecionar passes considerando suas respectivas classes e os índices de proximidade que indicam o grau de qualidade de cada alternativa. Nessa etapa, o algoritmo prioriza escolher, entre os passes classificados como ótimos, aqueles com maior pontuação, enquanto evita selecionar passes para pontos muito próximos entre si. Caso a quantidade de passes ótimos seja insuficiente, o processo é estendido para incluir passes aceitáveis com alta pontuação e, se necessário, repete-se o procedimento para os passes classificados como sub-ótimos. Persistindo a necessidade de mais alternativas, o algoritmo permite pontos progressivamente mais próximos entre si até que o número desejado de passes seja alcançado.

As próximas seções detalham o funcionamento de cada fase desse pipeline.

3.2.1 Geração de passes

Para gerar os passes, pontos pré-computados no campo são utilizados como possíveis posições-alvo do passe. A versão implementada da geração dos pontos é bem simples: as posições-alvo dos passes formam uma grade de 24x18 no campo, como ilustrado na Figura 6(a). Essas dimensões da grade foram escolhidas pois são as dimensões máximas cujo número de pontos permite que a computação de todo o pipeline seja feita atendendo os requisitos

temporais do sistema e geram pontos com distâncias iguais entre si no X e no Y ($12/24 = 0,5$ metros e $9/18$ também $= 0,5$ metros). Os pontos são gerados a uma determinada distância das laterais e das linhas de fundo do campo, pois passes para posições muito próximas a essas regiões teriam risco maior de não serem recebidos e fazer a bola sair do campo.

A geração dos passes é realizada a partir de pontos pré-computados no campo, que são considerados como possíveis posições-alvo dos passes. A versão implementada adota uma abordagem simplificada: os pontos formam uma grade de 24×18 , conforme ilustrado na Figura 6(a). Essa configuração foi escolhida por representar o limite máximo de pontos que ainda permite a execução do pipeline completo dentro dos requisitos temporais do sistema, ao mesmo tempo em que assegura espaçamento uniforme entre as posições nos eixos X e Y, com distância de 0,5 metros entre pontos consecutivos em ambos os eixos. Os pontos são gerados a uma distância mínima das linhas laterais e de fundo do campo, uma vez que passes direcionados a regiões muito próximas dessas áreas apresentam maior risco de não serem completados, aumentando a probabilidade de a bola sair dos limites de jogo.

A partir dos pontos gerados, inicia-se a fase de criação dos passes. Nessa etapa, são calculados, para cada ponto, todos os atributos que caracterizam um passe, tais como origem, posição-alvo, velocidade do chute, velocidade na posição-alvo e duração. Os objetos de passe resultantes são então armazenados em um contexto para serem utilizados em etapas subsequentes do pipeline e, caso necessário, em outras iterações do software.

3.2.2 Filtragem de passes

A etapa de filtragem de passes consiste na aplicação sequencial de filtros destinados a eliminar alternativas inviáveis ou indesejáveis. No contexto deste trabalho, foram implementados dois filtros com o objetivo de remover apenas passes estritamente inadequados, preservando as demais possibilidades para avaliação posterior.

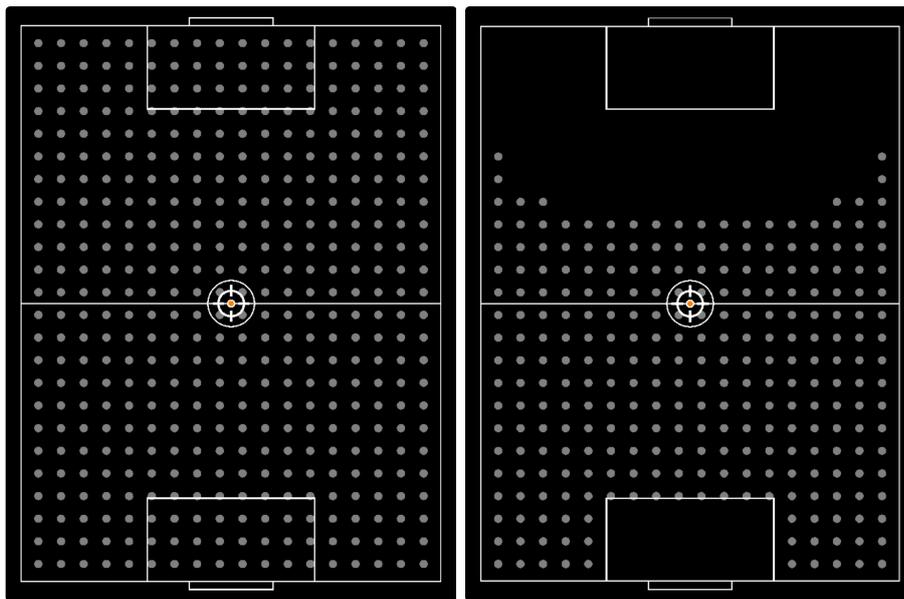
O primeiro filtro exclui passes cujo ponto de recepção se encontra dentro das áreas dos goleiros. Essa exclusão é necessária para o cumprimento das regras da competição, que proíbem a permanência de jogadores, exceto o goleiro, dentro dessas regiões. O segundo filtro, por sua vez, tem motivação estratégica: foi implementado para eliminar passes cuja recepção ocorre nas proximidades da área do goleiro da própria equipe. Essa restrição visa impossibilitar jogadas recuadas em direção à zona defensiva e induzir a priorização de alternativas voltadas ao campo ofensivo. Do ponto de vista tático, essa decisão busca mitigar o risco de interceptação de

passos e perdas de posse de bola próximas ao gol aliado, situações que poderiam resultar em oportunidades de finalização para o time adversário.

A Figura 6(b) ilustra a distribuição dos pontos de recepção válidos após a aplicação dos filtros mencionados.

Figura 6 – Geração e filtragem dos passes. A bola está localizada exatamente no centro do campo e é representada pelo círculo laranja.

(a) Distribuição dos destinos dos passes gerados. (b) Distribuição dos destinos dos passes após a filtragem.



Fonte: Elaborado pelo autor (2025)

3.2.3 Avaliação dos passes

Após a geração e filtragem dos passes, é preciso avaliar sua qualidade. O objetivo da fase de avaliação é utilizar as informações calculadas na geração dos passes, juntamente com as informações disponíveis do ambiente, como as posições dos robôs e da bola, para estimar o quão favorável é cada passe e identificar aqueles mais estratégicos para o posicionamento dos suportes.

Para isso, foi adotada uma abordagem baseada na avaliação por múltiplos critérios, cada um responsável por analisar um aspecto específico do passe. Cada métrica atribui pontuações normalizadas no intervalo de 0 a 1, em que 1 representa o melhor desempenho possível.

Diferentemente da estratégia descrita em (FRANCA et al., 2024), que combina as métricas por meio da multiplicação de seus valores para obter uma única pontuação final, a abordagem

proposta segue o modelo apresentado em (GEIGER et al., 2025), mantendo as pontuações separadas e independentes. Essa separação aumenta a interpretabilidade e modularidade da avaliação, além de possibilitar maior flexibilidade na etapa de classificação.

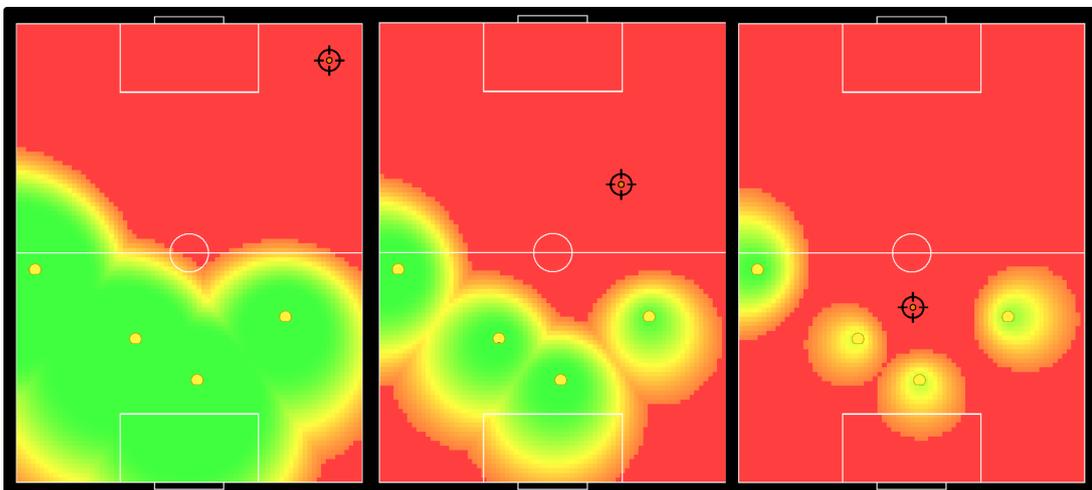
Ao todo, sete métricas foram implementadas para avaliar diferentes características dos passes, as quais são detalhadas a seguir.

3.2.3.1 *Ally Time Margin Score (ATM)*

Em cenários altamente dinâmicos, como as partidas de SSL, passes direcionados a locais inalcançáveis por robôs aliados implicam em alto risco de perder a posse de bola - seja porque a bola sai para fora do campo, seja por ser interceptada pela equipe adversária. Esta métrica é baseada no filtro de ponto alcançável (GEIGER et al., 2025) e na capacidade de recepção de passes por aliados (FRANCA et al., 2024), e tem como objetivo favorecer passes para posições nas quais um robô aliado consegue alcançar a posição-alvo do passe antes da bola.

Quanto maior a antecedência com que o robô atinge o destino do passe em relação à bola, maior a pontuação, como ilustrado na Figura 7, em que os pontos verdes têm alta pontuação, e os pontos vermelhos, baixa pontuação. Assim, esta métrica prioriza pontos nos quais um aliado tem tempo suficiente para se estabilizar e se preparar para a recepção, contribuindo para a continuidade da jogada e a manutenção da posse de bola ao reduzir a chance de falhas na recepção.

Figura 7 – Distribuição das pontuações da métrica *Ally Time Margin* em três cenários, da esquerda para a direita: bola muito distante dos aliados (alta margem de tempo), distância moderada (margem média) e bola próxima (baixa margem). O gol aliado está na parte superior e o adversário, na inferior. Os círculos amarelos representam os jogadores aliados.



Fonte: Elaborado pelo autor (2025)

Para avaliar se um robô aliado é capaz de alcançar o ponto de destino do passe em tempo hábil para receber a bola de forma adequada, essa métrica estima o tempo necessário para que cada aliado percorra o trajeto até o destino, assumindo um movimento retilíneo e sem obstáculos a 70% de sua velocidade máxima. O valor de 70% foi definido empiricamente a partir da experiência acumulada pelo RobôCIn em diversas competições e representa uma margem de segurança que considera os desvios e ajustes de trajetória realizados pelos robôs no caminho real até o destino.

Em seguida, esse tempo é comparado à duração que a bola levará para chegar ao mesmo ponto:

- **Pontuações altas** são atribuídas quando pelo menos um aliado consegue chegar com uma margem de tempo segura, indicando uma alta probabilidade de recepção bem-sucedida.
- **Pontuações baixas** ocorrem quando todos os aliados chegam tarde demais ou apenas ligeiramente antes da bola, reduzindo a confiança no passe.
- **Casos intermediários** são avaliados por meio de uma função que decai exponencialmente para que a pontuação decresça de forma gradual à medida que a margem de tempo diminui ou se torna negativa.

Robôs extremamente próximos do alvo recebem pontuação máxima pois já estão lá, e aliados que chegam muito atrasados não contribuem com pontuação alguma.

A seguir, apresenta-se a formulação matemática correspondente a essa métrica. Os valores numéricos empregados foram obtidos a partir de calibrações empíricas realizadas ao longo das participações do RobôCIn em competições da categoria SSL. Assim, sejam:

- t_{pass} : tempo que a bola leva para atingir o destino do passe;
- t_{ally} : tempo que um robô aliado leva para alcançar o mesmo destino;
- $\Delta t = t_{\text{pass}} - t_{\text{ally}}$: margem de tempo (positiva se o aliado for mais rápido);
- $M_{\text{ideal}} = 0,7s$: margem de tempo ideal para a recepção;
- $L_{\text{max}} = 0,2s$: atraso máximo permitido;

- $min_time = 0,05s$: tempo mínimo para considerar que o robô aliado já está na posição-alvo;
- $sharpness = 4,0$: grau de decaimento da pontuação;
- $\sigma = \frac{M_{ideal} + L_{max}}{sharpness}$: controla a inclinação da queda da pontuação;
- $score$: pontuação para um dado aliado.

Então:

$$score = \begin{cases} 1.0, & \text{se } \Delta t \geq M_{ideal} \text{ ou } t_{ally} \leq min_time \\ 0.0, & \text{se } \Delta t \leq -L_{max} \\ \exp\left(-\frac{(\Delta t - M_{ideal})^2}{2\sigma^2}\right), & \text{caso contrário} \end{cases}$$

A pontuação final dessa métrica é a pontuação máxima entre todos os aliados considerados no cálculo.

3.2.3.2 *Enemy Proximity Score (EP)*

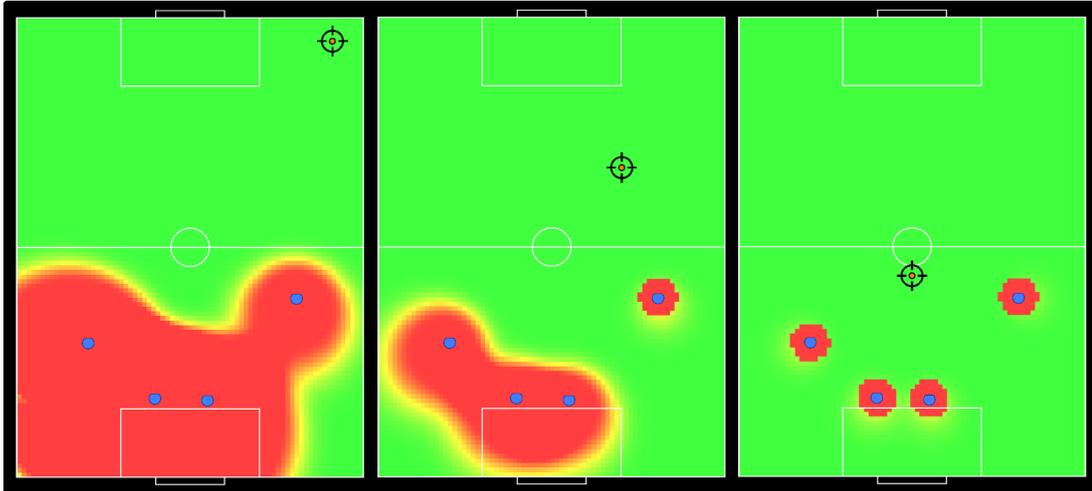
De forma semelhante à métrica anterior, esta métrica também é calculada com base em uma margem de tempo, porém considerando os adversários. Nas partidas de SSL, receber a bola sem pressão imediata dos adversários é fundamental para executar jogadas coordenadas e manter a posse de bola. Quando um adversário alcança a posição-alvo do passe antes da bola, a recepção é comprometida, pois o robô aliado terá menos tempo para a execução de sua ação, aumentando o risco de perda da posse.

Essa métrica baseia-se na diferença de tempo entre a primeira interceptação aliada e a primeira interceptação adversária, conforme mencionado em (HUANG et al., 2020), e penaliza cenários em que os adversários podem chegar ao destino do passe antes da bola. Ela recompensa situações em que o receptor possui tempo e espaço para controlar a bola antes de realizar a próxima jogada, favorecendo passes que terminam em zonas de baixa pressão adversária. A distribuição das pontuações ao longo do campo em uma situação típica de jogo está representada pela Figura 8, em que os pontos verdes representam as zonas de baixa pressão e os pontos vermelhos são aqueles próximos de adversários.

Para calcular a pontuação, a métrica avalia o tempo que os robôs adversários mais próximos levariam para alcançar o local de destino do passe, em comparação com o tempo que a bola

levará para chegar ao mesmo ponto. Se algum adversário conseguir alcançar o local antes ou pouco depois da bola, a pontuação é reduzida de acordo.

Figura 8 – Pontuações da métrica *Enemy Proximity* em três cenários, da esquerda para a direita: bola distante (grandes zonas vermelhas), moderadamente distante (zonas médias) e próxima aos adversários (zonas pequenas). O gol aliado está na parte superior, o adversário na inferior. Círculos azuis indicam os oponentes.



Fonte: Elaborado pelo autor (2025)

Em vez de considerar todos os adversários, apenas os três mais próximos são avaliados, com o objetivo de priorizar as ameaças mais imediatas. Cada inimigo contribui com uma penalidade na pontuação com base em quão cedo ele chega em relação à bola. Se um adversário já estiver no ponto de destino ou chegar com uma margem de tempo alta, sua penalidade será alta. Se estiver muito longe ou chegar atrasado demais, ele não contribui com penalidade alguma.

Um decaimento exponencial foi utilizado para modelar como os níveis de ameaça aumentam à medida que o tempo de chegada dos adversários se aproxima do tempo de chegada da bola. A pontuação final é dada por 1 menos a penalidade total, resultando em um valor entre 0 e 1, onde pontuações mais altas representam destinos de passe mais seguros e com baixa pressão adversária.

Assim, sejam:

- t_{pass} : tempo que a bola leva para atingir o destino do passe;
- t_i : tempo estimado para o i -ésimo inimigo mais próximo do destino do passe alcançá-lo;
- $\Delta t_i = t_{\text{pass}} - t_i$: margem de tempo entre a chegada da bola e a do inimigo.
- $M = 3$: número máximo de inimigos considerados. Regiões com mais que isso são consideradas muito povoadas;

- $P_{\max} = 1,0$: penalidade máxima por inimigo;
- $\tau = 0,7$: margem de tempo considerada perigosa, mesmo valor utilizado na métrica *Ally Time Margin*;
- $L_{\max} = 0,1s$: atraso máximo permitido; penalização máxima ocorre antes da *Ally Time Margin* por envolver adversários.
- $sharpness = 8,0$: grau de decaimento da penalidade, ajustado empiricamente para refletir o decaimento esperado das pontuações;
- $\sigma = \frac{\tau + L_{\max}}{sharpness}$: controla a inclinação da queda da penalidade;
- $score$: pontuação final do destino do passe.

Para cada um dos M inimigos mais próximos, define-se a penalidade como:

$$\text{penalty}_i = \begin{cases} P_{\max}, & \text{se } \Delta t_i \geq \tau \text{ ou } t_i \leq 0,25 \\ 0, & \text{se } \Delta t_i \leq -0,1 \text{ ou } t_i \geq 2,0 \\ P_{\max} \cdot \exp\left(-\frac{(\Delta t_i - \tau)^2}{\sigma}\right), & \text{caso contrário} \end{cases}$$

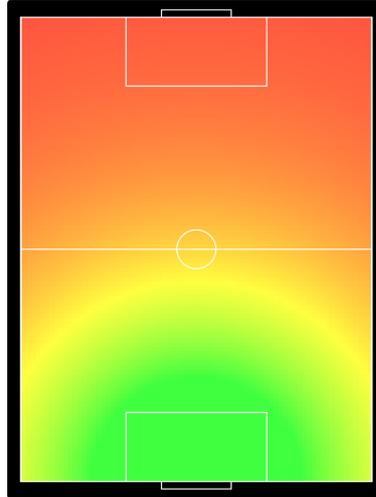
A pontuação final é dada por:

$$score = 1 - \min\left(1,0, \sum_{i=1}^M \text{penalty}_i\right)$$

3.2.3.3 Goal Distance Score (GD)

No futebol, a chance de marcar gols é maior quando os chutes são realizados a curta distância, já que a bola chega mais rapidamente ao gol e o goleiro tem menos tempo para reagir. Assim como em (HUANG et al., 2020) e na métrica *Pressure* (GEIGER et al., 2025), reconhece-se a importância de favorecer passes que posicionem a bola próxima ao gol adversário, aumentando a chance de um chute bem-sucedido. Com base nisso, o *Goal Distance Score* recompensa passes para pontos que estejam progressivamente mais próximos ao gol adversário e penaliza aqueles que mantêm a bola distante, como demonstrado na Figura 9, em que os chutes tendem a ser mais lentos e facilmente interceptados ou defendidos.

Figura 9 – Distribuição das pontuações calculadas pela métrica *Goal Distance*. As melhores pontuações estão próximas ao gol adversário, que está na parte de baixo da imagem.



Fonte: Elaborado pelo autor (2025)

Para realizar a avaliação, a distância Euclidiana entre o destino do passe e o centro do gol adversário é calculada. A pontuação é baseada em quão próxima essa distância está de um valor ideal predefinido.

- **Distância ideal:** Posições localizadas dentro ou exatamente no limite dessa distância ideal são consideradas ótimas para finalização e recebem a pontuação máxima.
- **Distâncias além do ideal:** À medida que o ponto-alvo se afasta do gol, a pontuação diminui exponencialmente. O decaimento é exponencial pois quanto mais longe do gol estiver a posição-alvo do passe, menor será seu valor em termos de potencial de finalização.

Dessa forma, sejam:

- d : distância do ponto de destino do passe até o centro do gol adversário;
- $d_{ideal} = 2,7$ metros: distância ideal para finalização, considerando as dimensões da área do goleiro ($3,6 \times 1,8$ m) e uma margem extra;
- $\alpha = 0,75$: constante de decaimento, calibrada empiricamente para refletir o decaimento desejado das pontuações;
- $score$: pontuação final atribuída ao passe.

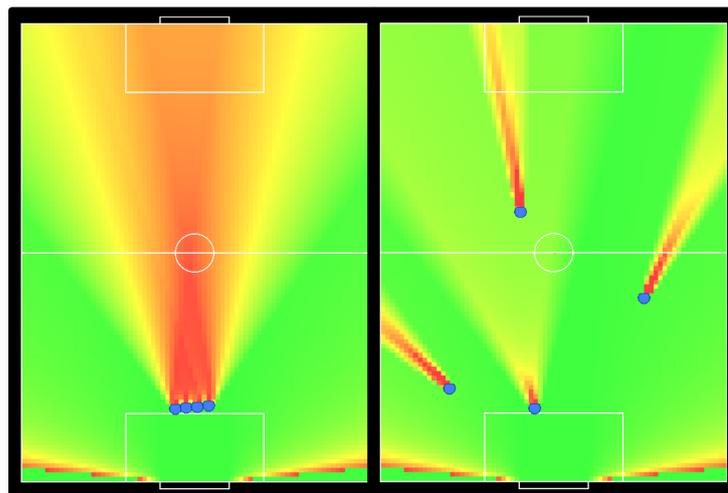
Então:

$$score = \begin{cases} 1.0, & \text{se } d \leq d_{ideal} \\ \exp\left(-\alpha \cdot \frac{|d - d_{ideal}|}{d_{ideal}}\right), & \text{caso contrário} \end{cases}$$

3.2.3.4 Goal Opening Score (GO)

Essa métrica tem como objetivo favorecer passes que posicionem o robô receptor em frente a uma porção ampla e desobstruída do gol adversário. Conforme discutido em (GEIGER et al., 2017) e no *Goal Kick Rating* (GEIGER et al., 2025), quanto menos obstruções no caminho da origem do chute para o gol, menos adversários existem nesse caminho e menor é a chance de um adversário interceptar um chute. Conseqüentemente, maiores são as chances de um chute a partir desse ponto ser bem-sucedido. Por outro lado, passes que terminam em regiões com muitas obstruções apresentam menor valor, pois tendem a resultar em chutes bloqueados ou de baixa qualidade. A Figura 10 mostra a distribuição de pontuação dessa métrica quando os adversários formam grandes zonas de obstrução e quando estão esparsos.

Figura 10 – Distribuição das pontuações da métrica *Goal Opening* em duas situações distintas, da esquerda para a direita: adversários agrupados e adversários dispersos. O gol aliado está localizado na parte superior da imagem e o gol adversário, na inferior.



Fonte: Elaborado pelo autor (2025)

Para calcular a pontuação, essa métrica analisa quanto do gol adversário está visível a partir do local de destino do passe. Para realizar esse cálculo, ela utiliza a versão otimizada do algoritmo de Raycast 2D, explicada na seção 2.3, para simular como os defensores adversários

obstruem o gol ao projetar sombras sobre ele. Essas sombras representam áreas onde um chute provavelmente seria bloqueado por oponentes ou pelas traves. Quanto maior a cobertura do gol por essas sombras, menor a área efetiva disponível para um chute.

Dessa forma, sejam:

- G : segmento entre as traves do gol adversário;
- A_{total} : comprimento de G (ou seja, a largura total do gol);
- A_{free} : comprimento de G que não está sombreado a partir do ponto de destino do passe;
- $w = 1 - \text{PASS_DISCOUNT}$: peso aplicado ao valor final;
- $score$: pontuação final atribuída ao passe.

O valor de A_{free} é calculado da seguinte forma:

1. Projeta-se sombras a partir do ponto de destino do passe em direção ao gol adversário, considerando os robôs adversários e as traves do gol;
2. Subtrai-se a soma dos comprimentos dessas sombras da largura total do gol;
3. Garante-se que o resultado não seja negativo:

$$A_{\text{free}} = \max \left(A_{\text{total}} - \sum_{\text{shadows}} \text{length}, 0 \right)$$

A *Goal Opening Score* é dada por:

$$score = \left(\frac{A_{\text{free}}}{A_{\text{total}}} \right) \cdot w$$

Esse valor final representa o percentual do gol que está desobstruído considerando um chute a partir do ponto de destino do passe.

3.2.3.5 *Ideal Range Score (IR)*

Passes muito curtos geralmente não contribuem de forma significativa para o avanço da bola em campo, enquanto passes excessivamente longos têm maior probabilidade de serem interceptados pelos adversários. Dessa forma, pode-se considerar a existência de uma “distância ideal” entre a origem e o destino do passe: não tão curtos a ponto de serem ineficazes, nem

tão longos a ponto de se tornarem arriscados. Essa métrica tem como objetivo priorizar passes que se aproximem dessa distância, promovendo uma progressão de bola estratégica ao longo do campo.

Para calcular a pontuação, a métrica avalia quão próxima a distância de um passe está de um valor ideal previamente definido, caracterizando uma “zona ótima” para a execução de passes. Essa zona ótima está demonstrada na Figura 11. A tolerância em torno dessa distância ideal é modelada por meio de uma região em forma de toro ao redor da origem do passe, conforme sugerido em (GEIGER et al., 2017).

- Se o passe for mais curto que o ideal, a tolerância para desvios é menor e a penalização é mais severa, pois passes muito curtos rapidamente se tornam ineficazes.
- Se o passe for mais longo que o ideal, a tolerância é um pouco maior, já que passes longos às vezes são necessários, embora impliquem maior risco.

A pontuação é máxima quando o comprimento do passe é exatamente igual à distância ideal e decai de forma suave à medida que a distância se desvia desse valor.

Os valores numéricos apresentados na formulação matemática a seguir foram calibrados empiricamente com base na experiência da equipe do RobôCIn em competições. Assim, definem-se:

- d : distância real do passe (em metros);
- $d_{\text{ideal}} = 4,5$: distância ideal do passe (em metros);
- $\sigma_{\text{short}} = 1,0$: tolerância para passes mais curtos que o ideal;
- $\sigma_{\text{long}} = 2,5$: tolerância para passes mais longos que o ideal;
- $score$: pontuação final atribuída ao passe.

A pontuação $score \in [0, 1]$ é calculada da seguinte forma:

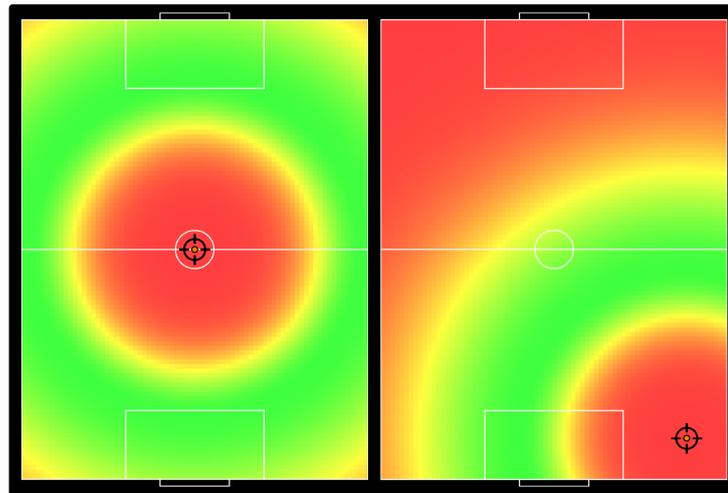
$$\text{diff} = d - d_{\text{ideal}}$$

$$\sigma = \begin{cases} \sigma_{\text{short}}, & \text{se } \text{diff} < 0 \\ \sigma_{\text{long}}, & \text{caso contrário} \end{cases}$$

$$score = \exp\left(-\frac{diff^2}{2\sigma^2}\right)$$

Essa fórmula gera uma curva Gaussiana centrada na distância ideal de passe (d_{ideal}), mas com larguras diferentes para penalizar de maneira distinta os passes curtos e longos.

Figura 11 – Distribuição das pontuações da métrica *Ideal Range*, evidenciando: uma região central de baixa pontuação para passes muito próximos à bola, um anel verde correspondente à faixa ideal, e uma zona externa também de baixa pontuação para distâncias superiores ao ideal. O gol aliado está na parte superior e o adversário, na inferior.



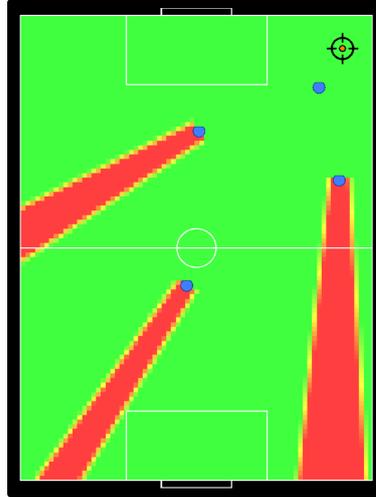
Fonte: Elaborado pelo autor (2025)

3.2.3.6 Pass Interception Score (PI)

Passes são fundamentais para o avanço ofensivo de um time em um jogo de futebol. No entanto, também representam momentos com alta probabilidade de perda da posse de bola, uma vez que esta está em movimento e pode ser interceptada por um adversário. Por essa razão, diversas equipes se preocupam em avaliar o risco de um passe ser interceptado antes de executá-lo (HUANG et al., 2020) (GEIGER et al., 2025). Nesse contexto, a métrica proposta busca favorecer passes com menor chance de interceptação por parte dos adversários, demonstrados pelas regiões verdes na Figura 12. Sua lógica é semelhante à do *Goal Opening Score*, mas, em vez de avaliar o espaço livre em direção ao gol, considera o espaço disponível ao redor do destino do passe, levando em conta a posição da bola no momento da origem do passe.

Para realizar o cálculo de pontuação, essa métrica também utiliza a adaptação do Raycast 2D que o *Goal Opening Score* utiliza, mas o alvo das sombras é um segmento no local de destino do passe ao invés de ser o gol. Além disso, o cálculo dessa métrica considera o movimento dos adversários no campo, estendendo as sombras de acordo com a velocidade dos inimigos.

Figura 12 – Distribuição das pontuações da métrica *Pass Interception*. Áreas vermelhas indicam regiões com alta chance de intercepção. O adversário próximo à bola não gera zona vermelha devido à possibilidade de um passe de "chip" por cima do robô. O gol aliado está na parte superior da imagem e o adversário, na inferior.



Fonte: Elaborado pelo autor (2025)

Isso ajuda a simular onde o oponente provavelmente estará nos próximos milissegundos, aumentando a robustez contra defensores em movimento. Passes para pontos próximos à origem são tratados com mais flexibilidade, assumindo que um passe de "chip", capaz de lançar a bola por cima dos robôs, evitaria interceptadores muito próximos. No geral, a pontuação é maior quando o segmento está sem obstruções, indicando que o passe é seguro. Uma pontuação menor reflete uma área-alvo bloqueada e passes mais arriscados, desfavorecendo essa escolha.

Assim, sejam:

- S : ponto de origem do passe (source);
- T : ponto de destino do passe (target);
- Segment: um pequeno segmento centrado em T , perpendicular ao vetor \overrightarrow{ST} , com largura ligeiramente superior ao diâmetro de um robô;
- A_{total} : comprimento total do segmento;
- A_{free} : porção do segmento que não está coberta por nenhuma sombra de intercepção;
- *score*: pontuação final atribuída ao passe.

O valor de A_{total} é calculado com base em um algoritmo semelhante ao utilizado no *Goal Opening Evaluator*, porém adaptado para prever o movimento dos oponentes e expandir dinamicamente as sombras.

$$A_{\text{free}} = \max \left(A_{\text{total}} - \sum_{\text{shadows}} \text{length}, 0 \right)$$

A pontuação é então calculada como:

$$\text{score} = \frac{A_{\text{free}}}{A_{\text{total}}}$$

Essa métrica mede o percentual do alvo do passe que está livre de interferências inimigas, indicando o quão seguro é realizar esse passe sem interceptação.

3.2.3.7 Redirect Goal Kick Score (RGK)

Passes que possibilitam um chute rápido de primeira são extremamente valiosos. No contexto dinâmico das partidas de SSL, o tempo gasto recepcionando a bola e preparando o próximo chute pode permitir que a defesa adversária se recupere e bloqueie a próxima ação do robô com a posse da bola. Assim como proposto em (HUANG et al., 2020), (HUANG et al., 2023) e (GEIGER et al., 2025), torna-se necessário o uso de métricas que favoreçam passes passíveis de redirecionamento imediato em direção ao gol adversário, sem a necessidade de recepção e ajuste antes do próximo chute.

Para isso, a métrica avalia o quão alinhado o passe está com a direção do gol, verificando o alinhamento angular entre a direção pela qual a bola chega ao robô receptor (direção do passe) e a direção em direção ao gol adversário (direção do chute), como ilustra a Figura 13. Ângulos pequenos, até um limiar pré-definido, são considerados ideais, pois o robô receptor tem maior chance de conseguir redirecionar a bola para o gol imediatamente. Além disso, redirecionamentos com ângulos acima de um limiar são considerados inviáveis, o que exige que o robô recepcione e gire antes de chutar, causando atrasos na execução das ações. Entre o limiar ideal e o inviável, a pontuação decresce linearmente. O resultado final da avaliação considerando posições diferentes da bola está demonstrado na Figura 14.

Assim, seja:

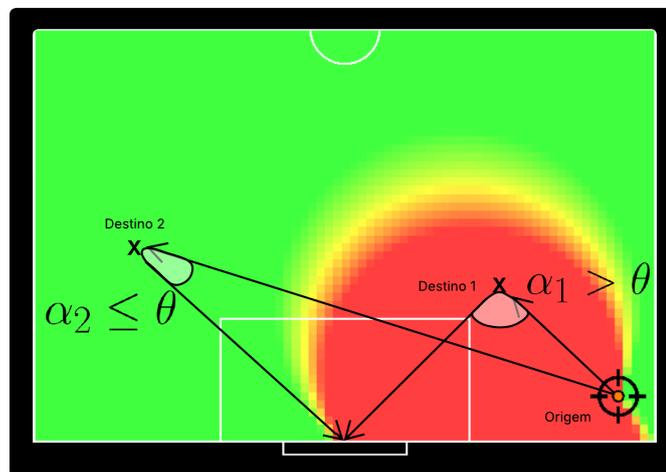
- θ : a diferença angular absoluta (em graus) entre o vetor do passe recebido e o vetor em direção ao gol adversário;
- $\theta_{\text{ideal}} = 50^\circ$: ângulo ideal para redirecionamento de passe;
- $\theta_{\text{max}} = 70^\circ$: ângulo máximo tolerado para redirecionamento;

- *score*: pontuação final atribuída ao passe.

O *score* é definido como:

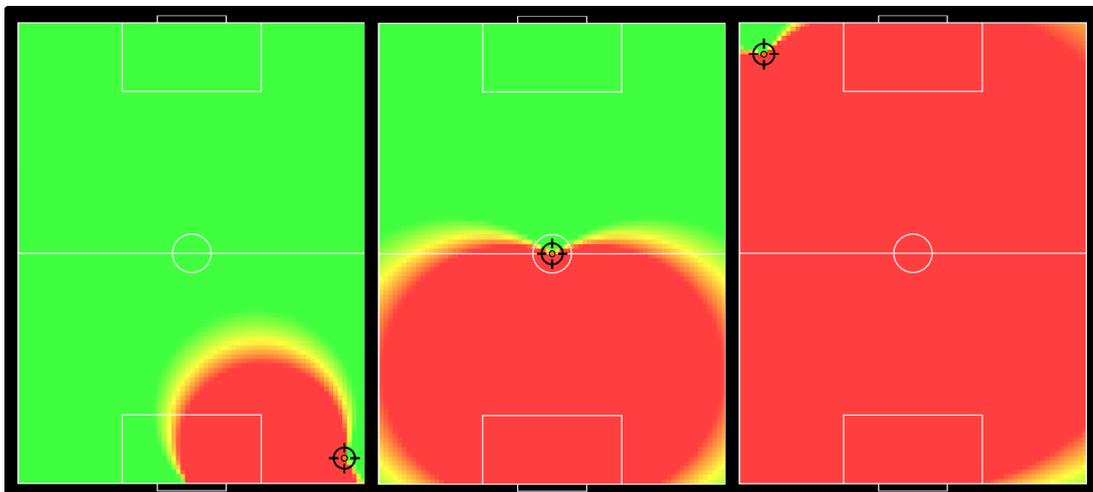
$$score = \begin{cases} 1.0, & \text{se } \theta \leq \theta_{ideal} \\ 0.0, & \text{se } \theta \geq \theta_{max} \\ 1.0 - \frac{\theta - \theta_{ideal}}{\theta_{max} - \theta_{ideal}}, & \text{caso contrário} \end{cases}$$

Figura 13 – Distribuição das pontuações calculadas pela métrica *Redirect Goal Kick*, com ênfase no ângulo considerado para o cálculo da métrica. O destino 1 recebe baixa pontuação pois o ângulo α_1 é maior que o limiar θ . Já o destino 2 recebe alta pontuação devido ao ângulo α_2 ser menor que θ .



Fonte: Elaborado pelo autor (2025)

Figura 14 – Distribuição das pontuações calculadas pela métrica *Redirect Goal Kick* para 3 situações diferentes, da esquerda para a direita: bola próxima ao gol adversário, bola no meio de campo e bola próxima ao gol aliado. O gol aliado está localizado na parte superior da imagem, enquanto o gol adversário encontra-se na porção inferior.



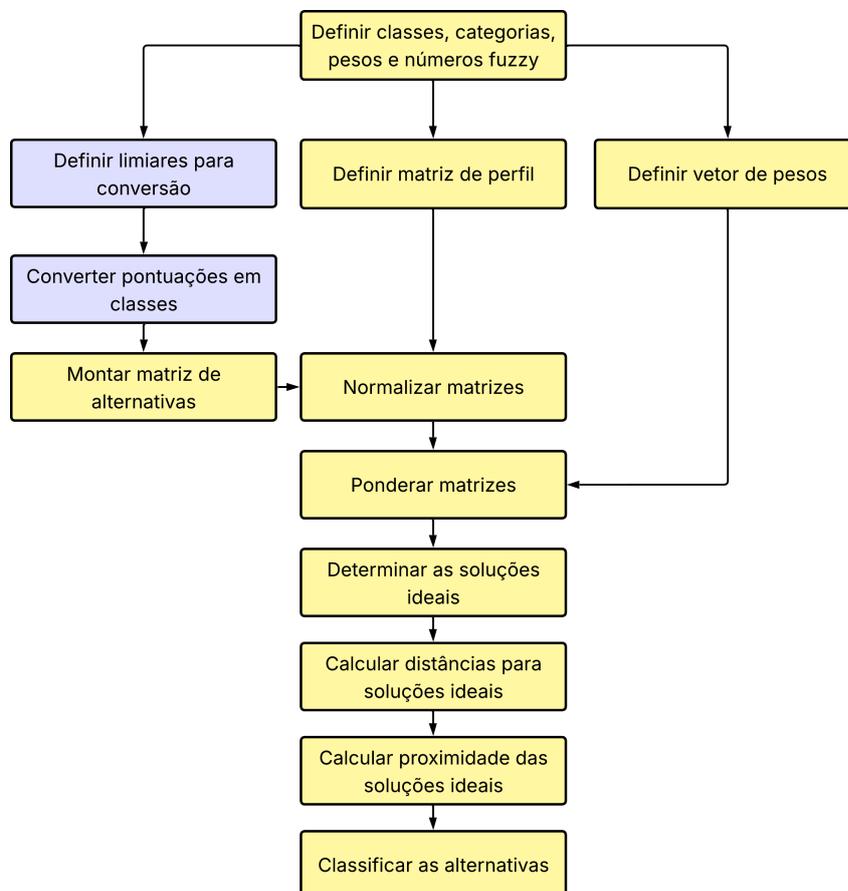
Fonte: Elaborado pelo autor (2025)

3.2.4 Classificação dos passes

A fase de classificação representa a principal novidade da abordagem proposta em relação à apresentada em (GEIGER et al., 2025). Seu objetivo é transformar as pontuações geradas na fase de avaliação em informações mais interpretáveis, capazes de refletir a qualidade de cada passe. Para isso, foi empregada a metodologia *FTOPSIS-Class* (FERREIRA et al., 2018), que permite classificar cada passe em uma das seguintes categorias: ótimo, aceitável ou sub-ótimo.

A escolha pelo *FTOPSIS-Class* (FERREIRA et al., 2018) se justifica por sua capacidade de lidar com múltiplos critérios qualitativos na classificação de alternativas. Além disso, o método permite atribuir pertencimentos parciais a diferentes classes, o que possibilita representar incertezas e nuances presentes em avaliações mais complexas. Essa característica é especialmente vantajosa no contexto da avaliação da qualidade de passes, em que muitas vezes um mesmo passe apresenta atributos que se situam entre duas ou mais categorias. O fluxo geral da fase de classificação está ilustrado no fluxograma da Figura 15.

Figura 15 – Fluxograma da fase de classificação. Em amarelo estão os passos do FTOPSIS-Class. Em azul, passos extras necessários para o funcionamento do método.



Fonte: Elaborado pelo autor (2025)

Inicialmente, são definidas as categorias de saída: ótimo, aceitável e sub-ótimo, bem como as classes, os pesos e os números fuzzy associados, conforme descrito na Tabela 1. Nesta abordagem, optamos pelo uso de funções de pertinência triangulares, sobretudo por razões de eficiência computacional: elas exigem apenas três parâmetros para sua definição, o que reduz significativamente o número de operações envolvidas no cálculo das pertinências, em comparação a funções mais complexas com mais parâmetros. Como a matriz de avaliação pode conter centenas de alternativas e o sistema deve operar em ciclos de tempo restritos, a simplicidade das funções triangulares contribui para a viabilidade prática da abordagem. Cabe destacar que não foram testadas outras funções de pertinência, uma vez que o objetivo principal deste trabalho é analisar o impacto da inclusão da etapa de classificação fuzzy na avaliação qualitativa dos passes, e não identificar a configuração ótima do modelo fuzzy.

Tabela 1 – Números fuzzy atribuídos a cada classe qualitativa e a cada nível de peso.

Classificação	Números Fuzzy Triangulares	Peso	Números Fuzzy Triangulares
Muito bom (MB)	(7.5, 10, 10)	Muito importante (MI)	(0.8, 0.8, 1)
Bom (B)	(5, 7.5, 10)	Importante (I)	(0.6, 0.8, 1)
Neutro (N)	(2.5, 5, 7.5)	Importância média (IM)	(0.4, 0.6, 0.8)
Ruim (R)	(0, 2.5, 5)	Pouco importante (PI)	(0.2, 0.4, 0.6)
Muito ruim (MR)	(0, 0, 2.5)	Sem importância (SI)	(0.2, 0.2, 0.4)

Fonte: Elaborado pelo autor (2025)

Paralelamente, para a aplicação do método, foi necessária a conversão das pontuações numéricas das métricas em classes qualitativas, de modo a compor a matriz de avaliação, utilizada como entrada no processo de classificação. Essa conversão é realizada a partir dos limiares estabelecidos na Tabela 2, definidos manualmente com base no conhecimento prévio acerca do comportamento esperado das métricas e nos intervalos considerados mais relevantes para a tomada de decisão. Cada classe corresponde a um intervalo de valores (por exemplo, de 0,4 a 0,6), o limiar apresentado na tabela indica o limite inferior da faixa, nesse caso, 0,4. A aplicação desse procedimento a todos os passes gera a matriz de alternativas, na qual cada passe é representado pelas classes associadas às suas pontuações em cada critério.

Tabela 2 – Limiar inferior de cada faixa de classificação por métrica, utilizadas para classificar as pontuações nas cinco classes qualitativas.

	ATM	EP	GD	GO	IR	PI	RGK
Muito bom (MB)	0,8	0,8	0,8	0,75	0,8	0,85	0,8
Bom (B)	0,6	0,6	0,55	0,55	0,6	0,65	0,6
Neutro (N)	0,4	0,45	0,4	0,4	0,4	0,4	0,45
Ruim (R)	0,2	0,2	0,2	0,2	0,2	0,2	0,25
Muito ruim (MR)	0,0	0,0	0,0	0,0	0,0	0,0	0,0

Fonte: Elaborado pelo autor (2025)

Por fim, além da matriz de avaliação, foi necessário definir previamente a matriz de perfil, que estabelece os valores esperados por classe em cada critério, bem como o vetor de pesos, que indica a importância relativa atribuída a cada critério no processo de classificação. Esses elementos estão apresentados nas Tabelas 3 e 4, respectivamente.

Tabela 3 – Matriz de perfil. Indica os valores esperados que uma alternativa deve ter em cada critério para pertencer a uma classe específica.

	ATM	EP	GD	GO	IR	PI	RGK
Ótimo	MB	MB	MB	B	B	MB	B
Aceitável	N	N	N	B	N	N	B
Sub-ótimo	R	MR	R	N	MR	MR	N

Fonte: Elaborado pelo autor (2025)

Tabela 4 – Vetor de pesos. Define a importância relativa de cada critério no processo decisório.

ATM	EP	GD	GO	IR	PI	RGK
I	MI	I	I	IM	MI	IM

Fonte: Elaborado pelo autor (2025)

Com as matrizes preparadas, inicia-se o procedimento do *FTOPSIS-Class* (FERREIRA et al., 2018). Primeiramente, a matriz de avaliação, já convertida para números fuzzy correspondentes a cada classe, é normalizada e ponderada segundo o vetor de pesos. O mesmo processo de normalização e ponderação é aplicado à matriz de perfil das classes.

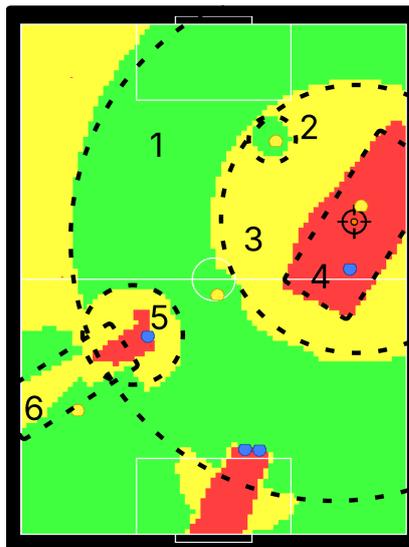
Em seguida, são determinadas as soluções ideais positivas e negativas para cada classe de perfil. Com essas soluções estabelecidas, calcula-se a distância de cada alternativa em relação às soluções ideais. A partir dessas distâncias, obtemos os índices de proximidade de cada

passa para cada classe, que quantificam o quão próximo cada passe está das condições ideais definidas para cada categoria.

Por fim, as alternativas são classificadas nas categorias ótimo, aceitável e sub-ótimo com base nos índices de proximidade. Os índices de proximidade resultantes são armazenados em conjunto com a classificação de cada alternativa para uso posterior na etapa de seleção, que utiliza essas informações para ordenar e filtrar as opções de passe durante a tomada de decisão.

A Figura 16 ilustra o resultado da classificação dos pontos do campo, considerando posições específicas dos robôs aliados (em amarelo), adversários (em azul) e da bola (em laranja com um alvo ao redor). O campo foi segmentado em regiões numeradas que evidenciam a influência de diferentes métricas na avaliação dos passes.

Figura 16 – Distribuição da classificação no campo, considerando posições específicas dos robôs aliados (em amarelo), adversários (em azul) e da bola (em laranja com um alvo ao redor). As regiões em verde indicam passes classificados como ótimos; as em amarelo, como aceitáveis; e as em vermelho correspondem a regiões avaliadas como sub-ótimas. O campo foi segmentado em áreas numeradas para destacar a influência de diferentes métricas na classificação final de cada região. As linhas tracejadas representam fronteiras aproximadas das regiões de influência de cada métrica.



Fonte: Elaborado pelo autor (2025)

As regiões 1 e 3 correspondem, respectivamente, a um anel de passes classificados como ótimos e a um círculo de passes aceitáveis ao redor da bola, formados principalmente pela influência da métrica *Ideal Range*. A região 2 destaca-se como uma área verde ao redor de um robô aliado, resultado da métrica *Ally Time Margin*, que favorece passes para regiões onde companheiros conseguem alcançar antes da bola.

A região 4 é caracterizada por passes sub-ótimos, marcados em vermelho, devido à influência combinada das métricas *Goal Opening*, uma vez que os robôs adversários próximos à área

bloqueiam potenciais finalizações, e *Ideal Range*, que penaliza distâncias pequenas em relação à bola. Já a região 5 apresenta uma formação circular de passes aceitáveis e sub-ótimos ao redor de um robô adversário, atribuída à métrica *Enemy Proximity*, que reduz a pontuação de pontos próximos a oponentes.

Por fim, a região 6 exibe uma área amarela posicionada atrás do robô adversário destacado na região 5, considerando a posição relativa da bola, localizada na região 4. Esse padrão reflete, principalmente, a influência da métrica *Pass Interception*, que penaliza passes suscetíveis à interceptação.

3.2.5 Seleção dos passes

A fase de seleção representa a etapa final do processo de avaliação e classificação de passes. Ela é responsável por identificar e escolher, dentre os passes classificados, aqueles com maior potencial de contribuir para o desempenho estratégico da equipe. As posições-alvo dos passes selecionados determinam os pontos de posicionamento dos suportes, influenciando a forma como a equipe é distribuída no campo. O principal objetivo desta fase é compor um conjunto de passes com alta relevância estratégica, priorizando a qualidade dos passes segundo a classificação fuzzy atribuída na etapa anterior.

A seleção recebe como entrada o número de passes a serem escolhidos, correspondente à quantidade de suportes a serem posicionados, bem como a matriz de passes classificados, com suas respectivas proximidades às categorias *ótimo*, *aceitável* e *sub-ótimo*. Além disso, essa etapa considera os passes selecionados na iteração anterior do sistema para realizar uma histerese, com o objetivo de decidir se os passes previamente escolhidos devem ser substituídos pelos candidatos atuais.

Devido à natureza altamente dinâmica do jogo na Small Size League (SSL), as avaliações de qualidade dos passes podem variar rapidamente a cada novo instante. Dessa forma, os passes anteriormente selecionados podem não ser mais os melhores no momento atual. No entanto, essa variação não implica necessariamente que os passes anteriores se tornaram inadequados, apenas que existem alternativas mais promissoras. Assim, com o intuito de evitar mudanças frequentes nas escolhas, o que poderia comprometer a estabilidade da execução das jogadas pelos robôs, adota-se uma abordagem que mantém os passes selecionados previamente, exceto quando os novos candidatos demonstram uma melhoria superior a um limiar pré-definido.

O processo de seleção dos candidatos ocorre de maneira iterativa e hierárquica. Inicial-

mente, as proximidades e classificações dos passes selecionados na iteração anterior são atualizadas com os valores da iteração atual. Esse processo é importante para a histerese realizada posteriormente. Após isso, a seleção é conduzida em três etapas sucessivas a partir da matriz de passes classificados, de acordo com a seguinte ordem de prioridade:

1. **Classe ótima:** são selecionados os passes classificados como ótimos, priorizando aqueles com maior proximidade em relação a essa categoria;
2. **Classe aceitável:** caso a quantidade de candidatos ainda não tenha atingido o total desejado, são selecionados passes da classe aceitável, priorizando os mais próximos da classe ótima;
3. **Classe sub-ótima:** persistindo a necessidade de selecionar mais passes, são escolhidos passes da classe sub-ótima, novamente com base na proximidade à classe ótima.

Durante cada uma dessas etapas, são aplicadas restrições de distâncias com o objetivo de evitar a seleção de passes cujos destinos estejam muito próximos entre si. Para isso, cada passe candidato é comparado aos passes já selecionados na iteração atual, sendo aceito apenas se respeitar uma distância mínima predefinida em relação a todos os demais.

Caso, ao final das três etapas, o número de passes selecionados ainda esteja abaixo do limite estabelecido, a distância mínima exigida entre os destinos dos passes é reduzida pela metade. Em seguida, as três etapas de seleção são reiniciadas com esse novo parâmetro. Esse processo é repetido até que a quantidade total de candidatos desejada seja alcançada.

Após a seleção preliminar, tem início a etapa de histerese. Para ela, estabelecemos um limiar mínimo de melhoria, estabelecido em 0,142 por meio de testes empíricos que serviram para definir um número capaz de fornecer trocas de passes selecionados que não fossem frequentes o bastante para causar instabilidade, mas que fossem frequentes o suficiente para evitar que a escolha de pontos ficasse muito estática, que representa a diferença mínima de pontuação necessária para que um novo passe candidato possa substituir um passe selecionado na iteração anterior do sistema. Assim, os candidatos atuais são comparados aos passes previamente escolhidos e, caso apresentem uma melhoria superior ao limiar estabelecido, substituem os passes antigos.

Após a seleção preliminar, tem início a etapa de histerese. Nessa fase, estabelece-se um limiar mínimo de melhoria, definido como a diferença mínima de pontuação necessária para que um novo passe candidato substitua um passe selecionado na iteração anterior do sistema. Esse

limiar, fixado em 0,142 com base em testes empíricos, foi determinado de forma a equilibrar dois fatores: evitar trocas excessivamente frequentes, que poderiam gerar instabilidade nas decisões, e impedir que a escolha de passes se tornasse excessivamente estática. Assim, os candidatos atuais são comparados aos passes previamente escolhidos, e apenas aqueles que apresentarem melhoria superior ao valor estabelecido substituem os anteriores.

Quando um passe candidato possui destino próximo ao de um passe previamente escolhido, a comparação é realizada entre esses dois, a fim de preservar a distribuição espacial e evitar a concentração de passes em uma mesma região. Caso o passe candidato não esteja próximo de nenhum dos anteriores, ele é comparado com aquele que apresenta a menor proximidade com a classe ótima, com o intuito de maximizar a qualidade global da seleção.

Essa estratégia garante que o conjunto final de passes represente não apenas as melhores opções disponíveis em termos de qualidade, mas também uma distribuição estratégica dos robôs ao longo do campo. Uma vez atingido o número máximo de passes selecionados, eles são repassados ao módulo de decisão, que se encarrega de atribuir um robô de suporte a cada posição-alvo correspondente.

3.3 ALGORITMO SHADOW

Para algumas das pontuações, é necessário identificar se o caminho percorrido pela bola, ao ser chutada, está obstruído. A abordagem utilizada pela equipe TIGERs Mannheim, descrita em (GEIGER et al., 2025), utiliza o conceito de *Moving Robots* para estimar a área de atuação dos robôs adversários e, assim, identificar possíveis interceptadores de passes. Uma abordagem mais simplificada, mas que segue a mesma intuição, consiste em verificar se a região de destino do passe está visível a partir da sua origem, semelhante ao que foi feito em (GEIGER et al., 2017). Neste trabalho, adotou-se essa segunda estratégia por meio da aplicação do algoritmo de Raycast 2D (2.3), que permite determinar, de forma eficiente, se há obstáculos entre dois pontos do campo.

Detalhes do algoritmo estão descritos em (FRANCA et al., 2024). A origem do passe ou do chute é considerada como uma fonte de luz, enquanto os robôs adversários são obstáculos que bloqueiam essa luz, criando sombras no segmento-alvo. Para chutes a gol, o segmento-alvo é o próprio gol e as traves também são consideradas como obstáculos. Para passes, o segmento-alvo é centrado no destino do passe, perpendicular à direção da origem ao destino e possui um tamanho um pouco maior que o diâmetro do robô. O pseudocódigo 1 descreve o

funcionamento do algoritmo.

Algoritmo 1: Calcular Sombras No Segmento

Input: world: estado do mundo (robôs, campo e bola)
 source: posição de origem da luz (ex.: posição da bola)
 segment: segmento sobre o qual calcular sombras (ex.: linha do gol)
 obstacles: lista de tipos de obstáculos a considerar
 purpose: finalidade da análise (ex.: passe ou chute)
Output: Lista de subsegmentos do segment cobertos por sombras

```

1 Inicializar lista shadows como vazia;
2 foreach tipo de obstáculo em obstacles do
3   foreach robô inimigo do tipo do
4     if tipo = ENEMIES then
5       Estimar as bordas laterais do robô, perpendiculares ao vetor source →
6         robô;
7       Usar purpose para decidir se a velocidade deve ser considerada na
8         extensão das bordas;
9       Projetar um cone de sombra de source até as bordas;
10      Interseccionar o cone com o segment para obter a sombra;
11      Determinar o trecho de segment coberto pelo cone de sombra;
12      Usar purpose para verificar se o robô pode ser ignorado;
13      if não pode ser ignorado then
14        | Adicionar trecho sombreado à lista shadows;
15      end
16    end
17  else if tipo = ENEMY_BOTTOM_POST then
18    | Mesma lógica, mas usando a trave inferior do gol como obstáculo;
19  end
20  else if tipo = ENEMY_TOP_POST then
21    | Mesma lógica, mas usando a trave superior do gol como obstáculo;
22  end
23 end
24 /* Unificar sombras sobrepostas */
25 Calcular a direção entre source e o centro de segment;
26 Rotacionar todas as sombras para um referencial alinhado com o segment;
27 Combinar intervalos sobrepostos;
28 Desfazer a rotação para as coordenadas originais;
29 Retornar a lista final de sombras unificada;
30 return shadows

```

3.3.1 Experimentos

Para avaliar a efetividade do novo processo de seleção de passes proposto neste trabalho, foi conduzido um experimento composto por partidas simuladas de SSL e posterior análise por métricas. O objetivo foi avaliar o quanto a nova abordagem contribui para a melhoria da performance ofensiva da equipe de futebol de robôs. Como forma de dimensionar esse impacto, foram utilizadas as seguintes métricas: quantidade total de passes, percentual de passes certos, passes progressivos, passes-chave (key passes), inclinação de campo (field tilt), número médio de finalizações por jogo e percentual de aproveitamento das finalizações. Essas métricas foram escolhidas por refletirem a eficácia tática do posicionamento dos jogadores de suporte e da tomada de decisão na escolha do passe.

A métrica de passes progressivos foi adaptada para o contexto da SSL, considerando as diferenças nas dimensões do campo em relação ao futebol profissional. Para isso, as distâncias utilizadas na definição original da métrica foram redimensionadas proporcionalmente, tomando como base a diagonal do campo. Considerando as dimensões mínimas oficiais da FIFA, que estabelecem um campo de 100×64 metros, a diagonal mede aproximadamente 118 metros. Em vez de adotar valores absolutos de 10, 15 e 30 metros para caracterizar a progressividade de um passe, utilizou-se a proporção equivalente em relação à diagonal: aproximadamente 8,5%, 12,7% e 25,4%. Aplicando essas proporções ao campo da SSL, que mede 12×9 metros e possui uma diagonal de cerca de 15 metros, os valores correspondentes são, aproximadamente, 1,3, 1,9 e 3,8 metros, utilizados neste estudo para identificar passes progressivos.

Um passe foi considerado concluído quando o próximo toque na bola foi realizado por um robô da mesma equipe que executou o passe. Passes-chave foram definidos como aqueles em que o robô receptor realizou uma finalização a gol logo após receber o passe, independentemente do resultado da finalização. Quanto à métrica de inclinação de campo, em vez de contabilizar apenas os passes executados no terço ofensivo, foram considerados todos os passes realizados na metade ofensiva do campo, adequando a métrica às dimensões reduzidas e às restrições de posicionamento na SSL.

O software-base utilizado para avaliar a influência do processo de seleção de passes foi o *SSL-Unification*, sistema de controle da equipe RobôCIn na categoria SSL, disponível no repositório GitHub do RobôCIn, embora com acesso restrito. O *SSL-Unification* contém o processo de seleção de passes descrito em (FRANCA et al., 2024), no qual foi implementada a nova abordagem proposta neste trabalho.

Além do *SSL-Unification*, as partidas simuladas foram realizadas por meio do simulador Simulator-CLI (ER-FORCE, 2025), com o auxílio da versão v3.18.0 do Game Controller (ROBOCUP-SSL, 2025), responsável pelo envio de comandos aos times. Utilizamos ainda a versão v1.6.0 do Auto Referee (MANNHEIM, 2025), árbitro automático encarregado de detectar faltas cometidas durante a partida.

O experimento consistiu em uma avaliação direta da evolução da estratégia de passes. Foram realizadas dez partidas simuladas entre duas versões do *SSL-Unification*: a versão atual, que representa o software original, sem as modificações propostas no pipeline de seleção de passes, e a versão nova, que incorpora o novo processo apresentado neste trabalho. Todos os parâmetros do simulador e do software foram mantidos idênticos para ambas as versões, garantindo que qualquer variação no desempenho decorresse exclusivamente da alteração no pipeline.

4 RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados do experimento realizado para avaliar a eficácia do novo pipeline de seleção de passes baseado no método FTOPSIS-Class, aplicado à equipe RobôCIn na categoria Small Size League (SSL). Os dados comparativos entre a versão original do sistema (*versão atual*) e a versão modificada (*versão nova*) foram analisados sob diferentes métricas a fim de garantir que a análise foi feita de forma global, considerando aspectos diferentes. A discussão busca relacionar os dados coletados com as hipóteses formuladas para explicar o desempenho superior da nova abordagem.

Considerando o processamento dos 274 candidatos de passe restantes após a filtragem, o pipeline completo apresenta tempo médio de execução de aproximadamente 6 milissegundos, sendo cerca de 4 milissegundos consumidos pelas etapas de geração, filtragem e avaliação, e 2 milissegundos pelas etapas de classificação e seleção. Em algumas ocasiões, esse tempo pode ultrapassar 10 milissegundos devido a variações na carga do sistema. Considerando que o framerate utilizado nos experimentos foi de 60 fps, o software completo deve ser capaz de processar cada frame em, no máximo, 8 milissegundos. O pipeline de seleção de passes representa uma parcela significativa desse tempo, o que poderia impactar o desempenho global do sistema, embora os resultados experimentais não tenham mostrado uma redução perceptível na performance. É possível reduzir o tempo de execução ajustando as dimensões da grade empregada na geração de candidatos de passe.

A Tabela 5 sintetiza os resultados gerais de vitórias, empates, derrotas e gols totais marcados por cada equipe. Observa-se que a nova versão obteve desempenho consideravelmente superior, registrando 6 vitórias, 3 empates e apenas 1 derrota em comparação à versão atual do processo de avaliação e seleção de passes. Além disso, a versão nova marcou um total de 12 gols, cerca de quatro vezes superior à quantidade marcada pela versão atual, reforçando o impacto positivo da nova estratégia de seleção de passes no desempenho final da equipe.

Tabela 5 – Resultados gerais das partidas para as versões atual e nova

Equipe	Vitórias	Empates	Derrotas	Gols marcados
Versão nova	6	3	1	12
Versão atual	1	3	6	3

Fonte: Elaborado pelo autor (2025)

A Tabela 6 apresenta os dados brutos coletados nas dez partidas, detalhando o desempenho

obtido em cada confronto. Observa-se que, além de registrar resultados superiores no placar final, a nova versão do sistema também apresentou desempenho mais favorável na maioria dos indicadores ao longo das partidas. Em nove dos dez jogos, verificou-se maior volume de passes em comparação à versão atual. Do mesmo modo, a nova versão também obteve valores superiores de inclinação de campo e de passes-chave em sete das dez partidas. A combinação desses resultados indica que a equipe com a nova abordagem foi capaz de manter a posse de bola em regiões ofensivas por mais tempo, favorecendo a criação de oportunidades de finalização com maior qualidade.

Tabela 6 – Valores de cada métrica por partida para as versões atual e nova do time.

Partida	P		PC		PP		PCA		IC		KP		F		G	
	VA	VN	VA	VN	VA	VN	VA	VN	VA	VN	VA	VN	VA	VN	VA	VN
1	28	32	15	15	9	7	9	7	56,25%	43,75%	3	4	19	6	0	1
2	35	40	17	27	7	12	8	15	34,78%	65,22%	5	8	9	20	1	2
3	27	31	14	17	9	7	10	14	41,67%	58,33%	2	7	13	9	0	0
4	30	45	17	26	6	15	7	10	41,18%	58,82%	3	5	10	10	1	0
5	30	36	17	18	11	9	9	8	52,94%	47,06%	4	7	13	16	0	0
6	40	25	23	14	16	5	17	11	60,71%	39,29%	5	8	22	10	1	2
7	24	42	10	27	9	9	7	9	43,75%	56,25%	4	4	13	8	0	0
8	32	45	16	24	9	12	10	12	45,45%	54,55%	3	6	11	12	0	1
9	36	41	19	22	7	11	12	13	48,00%	52,00%	8	5	16	11	0	3
10	31	32	10	17	7	10	6	10	37,50%	62,50%	5	4	13	11	0	3

Legenda das siglas: P = Passes totais; PC = Passes certos; PP = Passes progressivos; KP = Passes-chave;

PCA = Passes no campo adversário; IC = Inclinação de campo; F = Finalizações; G = Gols;

VA = Versão atual do time; VN = Versão nova do time

Fonte: Elaborado pelo autor (2025)

A Tabela 7 condensa esses resultados, apresentando as médias das métricas de avaliação acompanhadas de seus respectivos percentuais em relação ao total de passes e finalizações. Destaca-se que a nova versão executou, em média, 5,6 passes a mais por jogo, com uma taxa de acerto aproximadamente 6% superior. Esses números sugerem que a abordagem baseada no método FTOPSIS Class favorece a seleção de passes mais seguros, contribuindo para a manutenção da posse de bola e possibilitando a construção de um maior número de jogadas ofensivas.

A métrica de inclinação de campo reforça essa análise, pois representa a proporção de passes efetuados na metade ofensiva do campo. Na nova versão, essa métrica apresentou valores superiores, fortalecendo a hipótese do aumento na capacidade de manter a circulação da bola em setores avançados e de exercer pressão ofensiva sobre o adversário. Tal desempenho pode ser atribuído ao fato de que a abordagem proposta não é utilizada apenas na seleção

de passes, mas também é empregada no posicionamento dos suportes. A combinação entre maior inclinação de campo, maior volume de passes e maior taxa de acerto sugere que o posicionamento dos jogadores foi melhorado, selecionando posições que possibilitam a rápida recepção e passagem da bola. Essa melhoria contribui para a manutenção da posse e para a continuidade das jogadas, resultando em um fluxo ofensivo mais consistente e efetivo.

Tabela 7 – Médias por partida e percentuais das métricas para as versões atual e nova

Métrica	Versão atual	Versão nova
Passes totais	31,3	36,9
Passes certos	15,8 (50,48%)	20,7 (56,10%)
Passes progressivos	9,0 (28,75%)	9,7 (26,29%)
Passes-chave	4,2 (13,42%)	5,8 (15,72%)
Inclinação de campo	46,22%	53,78%
Finalizações	13,9	11,3
Gols marcados	0,3 (2,16%)	1,2 (10,62%)

Os valores representam **médias por partida**.

O percentual de gols é calculados em relação à média de finalizações.

Os percentuais das métricas de passe são calculados em relação à média de passes.

Fonte: Elaborado pelo autor (2025)

Outro indicativo de melhoria qualitativa das jogadas é o aumento na taxa de aproveitamento das finalizações, calculada pela razão entre finalizações e gols, que aumentou de 2,16% para 10,62%. Embora a nova versão apresente um menor número absoluto de finalizações, o crescimento no número de gols sugere que os passes selecionados tendem a originar oportunidades de chute a gol mais qualificadas. Esse resultado é compatível com o aumento do percentual de passes-chave, responsáveis por criar chances claras de gol, de 13,42% para 15,72%.

Por fim, embora a nova abordagem apresente um percentual inferior de passes progressivos, observa-se um aumento na geração de passes-chave. Esse comportamento reforça a hipótese de que a introdução da etapa de classificação fuzzy no processo de seleção de passes favorece a criação de oportunidades concretas de finalização em detrimento do simples avanço pelo campo. Tal resultado evidencia que, para o desempenho ofensivo, a qualidade e a seletividade dos passes têm maior impacto do que o volume absoluto de progressões no campo.

De maneira geral, os resultados do experimento indicam que a equipe com a nova abordagem apresentou um padrão de jogo mais eficiente, caracterizado por um maior número de

passes e uma menor quantidade de finalizações, mas com aproveitamento significativamente superior e mais gols marcados. Esses resultados indicam que a nova estratégia priorizou a manutenção da posse de bola e foi mais criteriosa na seleção das oportunidades de finalização, favorecendo uma progressão estratégica até regiões do campo com maior potencial de sucesso nas finalizações. Como consequência, as finalizações executadas apresentaram maior qualidade e maior probabilidade de resultar em gol.

5 CONCLUSÃO

Neste trabalho, propomos a integração do método de classificação multicritério fuzzy FTOPSIS-Class ao pipeline de seleção de passes da equipe RobôCIn, participante da categoria Small Size League (SSL) da RoboCup. O objetivo central foi verificar se a aplicação de um método de tomada de decisão multicritério, destinado a reduzir o espaço de busca das opções de passe antes da escolha final, poderia efetivamente aprimorar a tomada de decisão em comparação à abordagem tradicional baseada na multiplicação direta das métricas. O pipeline proposto emprega o FTOPSIS-Class para classificar as alternativas de passes em três categorias, com base em sete métricas de desempenho, e prioriza a seleção de passes pertencentes à classe com maior potencial de sucesso.

Para validar a abordagem proposta, realizamos dez partidas simuladas entre duas versões de um mesmo sistema: uma incorporando o novo pipeline e outra mantendo a configuração original. O desempenho de cada versão foi comparado com base em métricas utilizadas no futebol tradicional. Os resultados demonstraram ganhos consistentes na versão com o método proposto, incluindo aumento no número total e na precisão dos passes, bem como melhoria na qualidade das jogadas, culminando em seis vitórias, três empates e apenas uma derrota.

Tais resultados indicam que a adoção de um método de tomada de decisão multicritério fuzzy, proveniente da literatura, é capaz de aprimorar de forma significativa a efetividade e o desempenho de uma equipe de futebol de robôs, apresentando-se como uma alternativa promissora para a otimização de estratégias ofensivas. Adicionalmente, este estudo formalizou matematicamente um conjunto de métricas que podem ser utilizadas para avaliar passes no contexto do futebol de robôs da SSL, oferecendo uma base para futuras pesquisas e desenvolvimentos na área.

5.1 LIMITAÇÕES

A principal limitação identificada neste estudo refere-se à definição manual dos parâmetros de limiar utilizados para categorizar as métricas, da classificação de cada métrica nos perfis das classes e dos pesos atribuídos a cada métrica. Essa abordagem não assegura que os valores adotados sejam efetivamente os mais adequados ou otimizados para maximizar o desempenho do método. Outra limitação diz respeito ao fato de a avaliação ter sido realizada exclusivamente

em ambiente simulado, o que demanda a validação com robôs reais, considerando que fatores relacionados ao hardware podem influenciar os resultados obtidos.

5.2 TRABALHOS FUTUROS

Apesar dos resultados positivos, o método proposto ainda pode ser aprimorado. Investigar técnicas para o ajuste automático dos limiares e pesos das métricas, bem como a avaliação de diferentes formatos de funções de pertinência, para além das triangulares, pode potencializar o desempenho do modelo e trazer resultados melhores. Além disso, também se faz necessária a realização de experimentos com um número maior de partidas e a validação da nova abordagem em robôs reais, incluindo testes contra sistemas de outras equipes, a fim de avaliar o desempenho do método em cenários reais e diante de estratégias de jogo diferentes.

REFERÊNCIAS

- ANALYST, T. F. *Field Tilt – Football Statistics Explained*. 2025. <<https://the-footballanalyst.com/field-tilt-football-statistics-explained>>. Acessado: 05-08-2025.
- CHEN, C.-T. Extensions of the topsis for group decision-making under fuzzy environment. *Fuzzy Sets and Systems*, v. 114, n. 1, p. 1–9, 2000. ISSN 0165-0114. Acessado: 11-08-2025. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0165011497003771>>.
- ER-FORCE. *ER-Force Framework*. [S.l.]: GitHub, 2025. <<https://github.com/robocin/framework>>. Acessado: 05-08-2025.
- FEITOSA, I. S. C. d. S.; CARPINETTI, L. C. R.; FILHO, A. T. d. A. Aplicação de ftopsis-class para classificação da maturidade da gestão de risco em cadeias de suprimentos. In: *Simpósio Brasileiro de Pesquisa Operacional*. [S.l.]: SOBRAPO, 2019. Acessado: 11-08-2025.
- FERREIRA, L.; BORENSTEIN, D.; RIGHI, M. B.; de Almeida Filho, A. T. A fuzzy hybrid integrated framework for portfolio optimization in private banking. *Expert Systems with Applications*, v. 92, p. 350–362, 2018. ISSN 0957-4174. Acessado: 23-05-2025. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417417306619>>.
- FILHO, D. M. d. O.; FILHO, A. T. d. A.; FERREIRA, L.; RIGHI, M. B.; BORENSTEIN, D. Fuzzy-based decision support system for private banking. *Pesquisa Operacional*, Sociedade Brasileira de Pesquisa Operacional, v. 43, p. e264857, 2023. ISSN 0101-7438. Acessado: 11-08-2025. Disponível em: <<https://doi.org/10.1590/0101-7438.2023.043.00264857>>.
- FRANCA, A.; BARROS, B.; GOMES, C.; SILVA, C.; ALVES, C.; BARBOSA, D. C.; XAVIER, D.; ARAÚJO, E.; PEREIRA, F.; BATISTA, H. A.; CAVALCANTI, L. H.; ASFORA, M.; ALVES, M.; PAIXÃO, M.; VASCONCELOS, M.; VINÍCIUS, M.; MELO, J. G.; SILVA, J. R.; CRUZ, J. V.; LEITE, J.; SANTANA, P. H.; OLIVEIRA, P. P.; RODRIGUES, R.; MORAIS, R.; TEOBALDO, T.; DUTRA, V.; ARAÚJO, V.; BARROS, E. *RoboCIn Small Size League Extended Team Description Paper for RoboCup 2024*. 2024. <https://ssl.robocup.org/wp-content/uploads/2024/04/2024_ETDP_RoboCIn.pdf>. Acessado: 28-05-2025.
- GEIGER, M.; CARSTENSEN, C.; RYLL, A.; OMMER, N.; ENGELHARDT, D.; BAYER, F. *Tigers Mannheim (Team Interacting and Game Evolving Robots) Extended Team Description for RoboCup 2017*. 2017. <https://ssl.robocup.org/wp-content/uploads/2019/01/2017_ETDP_TIGERs_Mannheim.pdf>. Acessado: 28-05-2025.
- GEIGER, M.; OMMER, N.; RYLL, A.; RATZEL, M. *Tigers Mannheim (Team Interacting and Game Evolving Robots) Extended Team Description for RoboCup 2025*. 2025. <https://ssl.robocup.org/wp-content/uploads/2025/04/2025_ETDP_TIGERs-Mannheim.pdf>. Acessado: 28-05-2025.
- HUANG, Z.; HAN, C.; SHEN, N.; YANG, J.; YU, J.; ZHAO, A.; CHEN, Z.; DU, H.; WEN, L.; WANG, Y.; GUO, D.; XIONG, R. *ZJUNlict Extended Team Description Paper Small Size League of Robocup 2023*. 2023. <https://ssl.robocup.org/wp-content/uploads/2023/02/2023_ETDP_ZJUNlict.pdf>. Acessado: 28-05-2025.

HUANG, Z.; ZHANG, H.; GUO, D.; JIA, S.; FANG, X.; CHEN, Z.; WANG, Y.; HU, P.; WEN, L.; CHEN, L.; LI, Z.; XIONG, R. *ZJUNlict Extended Team Description Paper for RoboCup 2020*. 2020. <https://ssl.robocup.org/wp-content/uploads/2020/03/2020_ETDP_ZJUNlict.pdf>. Acessado: 28-05-2025.

HWANG, C.-L.; YOON, K. Methods for multiple attribute decision making. In: _____. *Multiple Attribute Decision Making: Methods and Applications A State-of-the-Art Survey*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1981. p. 58–191. ISBN 978-3-642-48318-9. Acessado: 11-08-2025. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-642-48318-9_3>.

MANNHEIM, T. *TIGERs Mannheim AutoReferee*. [S.l.]: GitHub, 2025. <<https://github.com/TIGERs-Mannheim/AutoReferee>>. Acessado: 05-08-2025.

ROBOCUP. *Robocup Organization Website*. 1997. <<https://www.robocup.org/>>. Acessado: 25-07-2025.

ROBOCUP. *Robocup Small Size League Organization Website*. 1997. <<https://ssl.robocup.org/>>. Acessado: 25-07-2025.

ROBOCUP-SSL. *SSL Game Controller*. [S.l.]: GitHub, 2025. <<https://github.com/RoboCup-SSL/ssl-game-controller>>. Acessado: 05-08-2025.

WILLIS, S. *Should we care about Field Tilt?* 2025. <<https://www.cannonstats.com/p/should-we-care-about-field-tilt>>. Acessado: 05-08-2025.

WYSCOUT. *Key pass*. 2025. <https://dataglossary.wyscout.com/key_pass/>. Acessado: 05-08-2025.

WYSCOUT. *Progressive pass*. 2025. <https://dataglossary.wyscout.com/progressive_pass/>. Acessado: 05-08-2025.