

2022年度

学位論文[博士(工学)]

観測情報に基づく探索空間生成法を用いた  
実時間複数障害物認識法

東京工芸大学大学院  
工学研究科  
電子情報工学専攻  
馬 躍航

# 目次

第1章 緒言	2
第2章 ロボットのハードウェアとシステム構成	6
2.1 ロボットの仕様	6
2.2 ハードウェア	8
2.2.1 全方向移動機構	8
2.2.2 ボール保持機構	10
2.2.3 キック機構	11
2.3 制御システム	12
2.3.1 制御ユニット	12
2.4 通信機能とセンサ	14
2.4.1 通信機能	14
2.4.2 その他のセンサ	15
2.5 大会実績	16
第3章 複数センサを用いた障害物検出	17
3.1 全方位カメラによる障害物検出	18
3.1.1 全方位カメラ	18
3.1.2 フィールドと障害物の色抽出	20
3.1.3 フィールド領域画像の生成	22
3.1.4 障害物候補の特徴化	24
3.1.5 障害物の検出	26
3.1.6 全方位カメラによる障害物検出手法の精度検証	28
3.2 複合センサシステムによる検出精度の改善	29
3.3 全方位カメラとLiDARを用いた障害物検出	30
3.3.1 LiDAR	30
3.3.2 LiDARの基礎性能検証	31
3.3.3 LiDARの搭載と障害物検出精度の検証	35
3.4 フィールド座標系における複数障害物情報	37
3.4.1 自己位置情報と障害物検出情報の統合	37
3.4.2 障害物検出情報の誤差	38
第4章 複数障害物認識のための尤度空間の生成	45
4.1 障害物検出結果の統合とクラスタリング	45
4.2 尤度を用いた検出結果の統合	48
4.2.1 ガウス分布関数を用いた尤度表現	48
4.2.2 ガウス分布による尤度表現の問題点	50

4.2.3	フェルミ分布関数を用いた尤度表現 . . . . .	54
4.2.4	フェルミ分布による尤度表現の検証 . . . . .	55
4.2.5	多数の観測ロボットから生成した尤度空間の検証 . . . . .	59
4.3	フェルミ分布による尤度表現の精度検証 . . . . .	66
4.3.1	シミュレーションによる精度検証 . . . . .	66
4.3.2	観測ロボット数による精度の検証 . . . . .	67
4.4	複数障害物に対する尤度空間の生成 . . . . .	68
4.4.1	複数の被観測ロボットにおける干渉の検証 . . . . .	68
4.4.2	実際の競技における尤度空間 . . . . .	68
<b>第 5 章</b>	<b>Hybrid GA を用いた複数障害物の実時間認識</b>	<b>71</b>
5.1	複数障害物認識における問題点 . . . . .	71
5.2	人間の注意機構 . . . . .	72
5.2.1	視覚的注意 . . . . .	72
5.2.2	受動注意と能動注意 . . . . .	72
5.3	視覚的注意に着想した最適化手法の工学的実現 . . . . .	74
5.3.1	受動注意 (広視野低密度探索) の工学的実現 . . . . .	74
5.3.2	能動注意 (狭視野高密度探索) の工学的実現 . . . . .	75
5.3.3	注意密度分布 . . . . .	76
5.3.4	遺伝的アルゴリズムによる能動注意の実現 . . . . .	77
5.3.5	Hybrid GA . . . . .	79
5.3.6	注意の動的再構成 . . . . .	80
5.4	標準試験関数による検証実験 . . . . .	84
5.4.1	2次元多峰性関数による検証実験 . . . . .	84
5.4.2	3次元多峰性関数による検証実験 . . . . .	84
5.5	実時間性の検証 . . . . .	87
5.5.1	探索空間サイズに対する処理時間の検証 . . . . .	87
5.5.2	動的環境を考慮した実時間性の検討 . . . . .	88
5.5.3	総探索個体数に対する処理時間の検証 . . . . .	89
5.6	RoboCup MSL 環境における精度検証と実装 . . . . .	90
5.6.1	Hybrid GA 認識法の精度検証 . . . . .	90
5.6.2	実機による複数障害物認識実験 . . . . .	92
<b>第 6 章</b>	<b>結言</b>	<b>95</b>
	謝辞	110

# 第 1 章 緒言

自律移動ロボットが実空間において何らかの与えられた課題を正しく遂行するためには、自身を取り巻く周囲環境を正確に認識することが重要である。認識すべき環境情報としては、周囲の構造物や路面状況を把握するための空間情報、空間中の自身の座標である自己位置情報、空間内の静的遮蔽物や動的物体の位置情報など複数あり、近年の自律移動ロボットの発展とデバイスの進化に伴い様々な研究が行われている<sup>1)~3)</sup>。いずれの例においても、認識対象の情報を獲得するためにはその課題に特化したデバイスや手法を用いる必要があるため、実用への応用を意識しつつも実験状況や条件を限定して検証せざるを得ないという状況がある。一定の制約条件下に限定して研究・開発するために、競技を題材とした技術チャレンジ<sup>4)~7)</sup>を利用する例も多く、考慮すべき要素が多い実用上の課題と異なり、競技上の整った環境下における基本的な検証ができるため、自律移動ロボットの基礎的な要素技術の発展が期待できる。

そのような競技を利用した技術チャレンジの一つとしてRoboCup<sup>8),9)</sup>が知られており、様々な国や地域で活発な取り組みが行われている。RoboCupは様々な環境における技術チャレンジを同時展開しており、災害現場における人命救助や、人間共生空間における作業、インダストリー4.0<sup>10)</sup>を視野に入れた工場内の機械化と並び、サッカー競技を通じた自律移動ロボットの基本機能の開発・研究を目的としたRoboCupサッカーがある<sup>11),12)</sup>。RoboCupサッカーとは、西暦2050年までに「サッカーの世界チャンピオンチームに勝てる、自律型ヒューマノイドロボットのチームを作る」という夢に向かって人工知能やロボット工学などの研究を推進し、様々な分野の基礎技術として波及させることを目的としたランドマーク・プロジェクトである<sup>13),14)</sup>。RoboCupサッカーはさらにリーグにより細分化されており、小型<sup>15)</sup>、中型<sup>16)</sup>、人型、シミュレーション、標準プラットフォームに分類される。その中でも中型リーグ(Middle Size League, 以下MSL)は、縦横52×高さ80 cm未満のロボット5台でチームを構成し、最も広い1400×2200 cmのサッカーフィールドで競技を行うスピード感と迫力のあるリーグである。

RoboCup MSLでは、ボール位置認識<sup>89),90)</sup>、自己位置同定<sup>91)~93)</sup>、ゴール位置推定<sup>94)</sup>の各技術を搭載することで「競技進行に合わせて正しくポジショニングし、ボールを取得して、ゴール

まで運び、シュートする。」という一連の基本的な行動が実現できる。基本動作に続く応用技術として、戦術を考慮したパスやドリブルなどの知的な行動判断が求められ、これらを実現するためには、フィールド上の敵・味方全ての位置情報が正しく取得できていることが非常に重要となる<sup>95)</sup>。味方の位置情報は、各ロボットの自己位置同定情報のチーム内共有により得られるが、敵の位置情報は自身のセンサデバイス等から推定しなければならない。しかし、RoboCup MSLにおける広大なフィールドにおいては、ロボット単体で全ての敵位置情報を得ることは難しいため、各ロボットが得た敵情報を共有・統合し、そこから正しく敵の位置を推定する必要がある。そこで、本研究ではRoboCup MSLフィールド上に存在する複数の敵ロボットの位置情報を同時認識することを課題とし、複数の味方ロボット（観測ロボット）が得た検出情報を統合し、効率良く実時間で位置を推定する複数障害物のリアルタイム認識手法を提案する。尚、本研究では、敵ロボットについて、パスやドリブルで避けるべき対象と見なしていることから障害物と呼ぶ。

一般的に、自律移動ロボットから物体検出を行う場合、カメラから得た画像情報を用いることが多く、様々な分野においてカメラを用いた複数物体認識が研究されているが、処理が複雑になるため実時間性を議論しているものは少ない。Luら<sup>17)</sup>やMulyaら<sup>18)</sup>はRoboCup MSLにおけるフィールド内の複数物体認識を色や形状に基づいて行っているが、いずれも処理時間は100 ms前後を必要とする。さらに、RoboCup以外の一般的な用途における複数物体認識に目を向けてみても、Leeら<sup>19)</sup>のホームロボット（掃除ロボット）の研究は約90 msを必要とし、Markovićら<sup>20)</sup>の研究のように複数の動的物体を認識できていても処理時間を議論していない例が多い。

近年ではYOLO<sup>21)~25)</sup>などの深層学習を用いた物体認識が脚光を浴びている<sup>26),27)</sup>。深層学習による物体認識は事前学習を適切に行うことで環境変動に強靱な認識が可能であるが、前述の例と同様に、処理時間が100 msを越えてしまったり、議論されていない研究が多い<sup>28),29)</sup>。また、競技ロボットのようなスタンドアロンで使用する場合には、GPUを搭載したJetson<sup>30)</sup>のような高性能デバイスを必要とする。常に全方位に対する環境認識が必要なRoboCup MSLにおける物体認識に深層学習を利用する場合、必要な視野を確保するためには複数台の認識システムを並列的に配置する必要があるが、システムの複雑化やコストの面から妥当ではない。そこで本研究では、双曲面ミラーを用いた全方位カメラシステム<sup>31),32)</sup>を採用し、画像中からの障害物の特徴化にはRoboCup MSL規定<sup>33)</sup>におけるサイズと色を利用する。さらに、全方位カメラの欠点である遠方分解能に起因する距離精度を補償するために、二次元走査型の光距離センサLiDAR(Light Detection and Ranging)を複合させる。複数のセンサを用いて欠点を補うセンサシステムはセンサフュージョン<sup>34),35)</sup>と呼ばれ、様々な研究分野において取り入れられており、自動運転車の安

全確保などの実用事例も多い<sup>36)~40)</sup>。

RoboCup MSL ではチームロボット間における情報共有が許可されており、各観測ロボットから得た障害物情報が統合されるが、各検出座標は誤差を含むため一意的に障害物の座標を示さない。混戦等でロボット間の距離が近い場合、誤差を含んだ障害物同士の検出座標情報は交差し、得られた点群から真値である障害物の座標を正しく推定することは容易ではない。点群データを何らかの特徴量に基づいて分類する手法はクラスタリング、またはクラスタ分析と呼ばれ<sup>41)~43)</sup>、ユークリッド距離に基づくデンドログラムを用いる階層的クラスタリング分析や、重心演算による k-means<sup>44),45)</sup>、データ密度による DBSCAN<sup>46)</sup>、超球内の密度による Mean shift<sup>47)</sup>、マージン最大化による SVM<sup>48)</sup> などの非階層的クラスタ分析手法があるが、いずれの手法も点群を構成する各点の座標値そのものの評価や複数点データ間の関連性の評価を利用しており、その点情報取得時の観測距離や推定誤差などの環境情報を考慮しないため、推定される障害物の位置は真値とは異なる座標となってしまう。そこで本研究では、検出点取得時の環境情報である観測距離と推定誤差を障害物識別に反映させることを目的として、フェルミ・ディラック分布関数<sup>49)~51)</sup>を確率密度関数として用いた尤度による空間表現を採用する。フェルミ・ディラック分布関数は半導体における物質中の電子の存在確率を示す分布関数であり、その特徴を利用することで、効率良く適切な合成尤度空間を生成することができる。

生成された合成尤度空間において、複数障害物の座標は極大値として表現される。これは、フィールド上の複数障害物を認識する問題が、合成尤度空間を探索空間とする複数極大値の探索問題、つまり最適化問題として置き換えられたことを意味している。しかし、合成尤度空間による探索空間は、複数の異値極大値を持つ大域的多峰性空間であると同時に、特定の障害物を表す尤度の起伏において多峰性を有する局所的多峰性も特徴として持ち合わせる。さらに、RoboCup MSL の競技における利用を考慮すると、これらの処理全てを実時間<sup>52)</sup>で処理する必要がある。そこで本研究では、人間の視覚情報処理システムにおける負荷低減機能である“注意”<sup>53)~60)</sup>に着目する。近年、視覚的注意は浅く広範囲な外発的注意である“受動注意”と深く狭い範囲の内発的注意である“能動注意”により構成されていることが報告されている<sup>56)</sup>。本研究では、広視野低密度な受動注意に大域的探索に特化した Monte Carlo 探索法<sup>61)~65)</sup>を、狭視野高密度な能動注意に遺伝的アルゴリズム (GA)<sup>66)~71)</sup>をそれぞれ採用する Hybrid GA により疑似的に注意機能を構築し、合成尤度空間から効率よく実時間で複数障害物認識を行う手法を提案する。GA とは、系統的探索と発見的探索により大域的／局所的探索空間において効率的な最適化を実現できる生物の進化と遺伝にヒントを得た最適化アルゴリズムであり、Hybrid GA とは、GA 単体に他の手法を

組み合わせることで、新しい機能の追加や欠点の補完を行ったものである<sup>72),73)</sup>。

本論文は、第2章に RoboCup MSL で使用されるロボットのハードウェア構成と制御システムについて述べる。第3章では全方位カメラを用いた障害物検出手法について述べ、全方位カメラの遠方分解能に起因する距離誤差の補償のために二次元走査型光距離センサを複合させたセンサフュージョンについて解説する。さらに、検証した様々な誤差要因を用いて推定合成誤差を確認し、観測距離と推定誤差の関係性を求める。第4章では複数の観測ロボットより得た複数障害物情報を統合し、本課題における最適化対象となる探索空間（尤度空間）を構成する方法について述べる。第5章において、本研究で解決すべき課題を明確にし、その解決法として人間の注意機構にヒントを得た Hybrid GA 認識法を提案する。最後に、本手法の精度や処理時間に対する検証を行い、実機に搭載した実戦により効果を確認し、第6章においてまとめを行う。

## 第 2 章 ロボットのハードウェアとシステム構成

本研究では、RoboCup MSL 規格に準拠したサッカー競技用ロボット（以降は単純化のためにロボットと呼ぶ）を用いる<sup>96),74)</sup>。本章では、使用するロボットの仕様を述べ、ハードウェアと制御システムの構成について解説を行う。

### 2.1 ロボットの仕様

ロボットは、周囲環境のリアルタイムな把握、正確かつ高速な移動、ボールアプローチ（ボール保持、ドリブル、パス、シュート）が要件として求められるため、様々なハードウェアから構成される。RoboCup MSL の規定では、ロボットのサイズは  $52 \times 52 \times h80$  cm 以内、重量は 40 kg 以内と定められている。本ロボットは  $52 \times 52 \times h80$  cm、23 kg となっており、規格に準拠した構成となっている。Fig. 2.1, 2.2 にロボットの外観を、Fig. 2.3 にロボットの構成図を示す。ロボットは競技における有用性を考慮し、姿勢に依存せずに全方向に移動可能なオムニホイールによる全方向移動機構を駆動機構として採用している。また、ボールアプローチのためのエンドエ



Fig. 2.1: Front view of the robot



Fig. 2.2: Side view of the robot



フェクタとして、ソレノイドを使用したキック機構、モータを利用したボール保持機構が搭載されている。これらのハードウェアはRX62Tマイコンを用いた専用の制御ユニットで制御され、メインPCからの指示で動作する。また、ロボット上部には双曲面ミラーを用いた全方位カメラを搭載しており、周囲環境の認識に利用している（全方位カメラの詳細は第三章で述べる）。

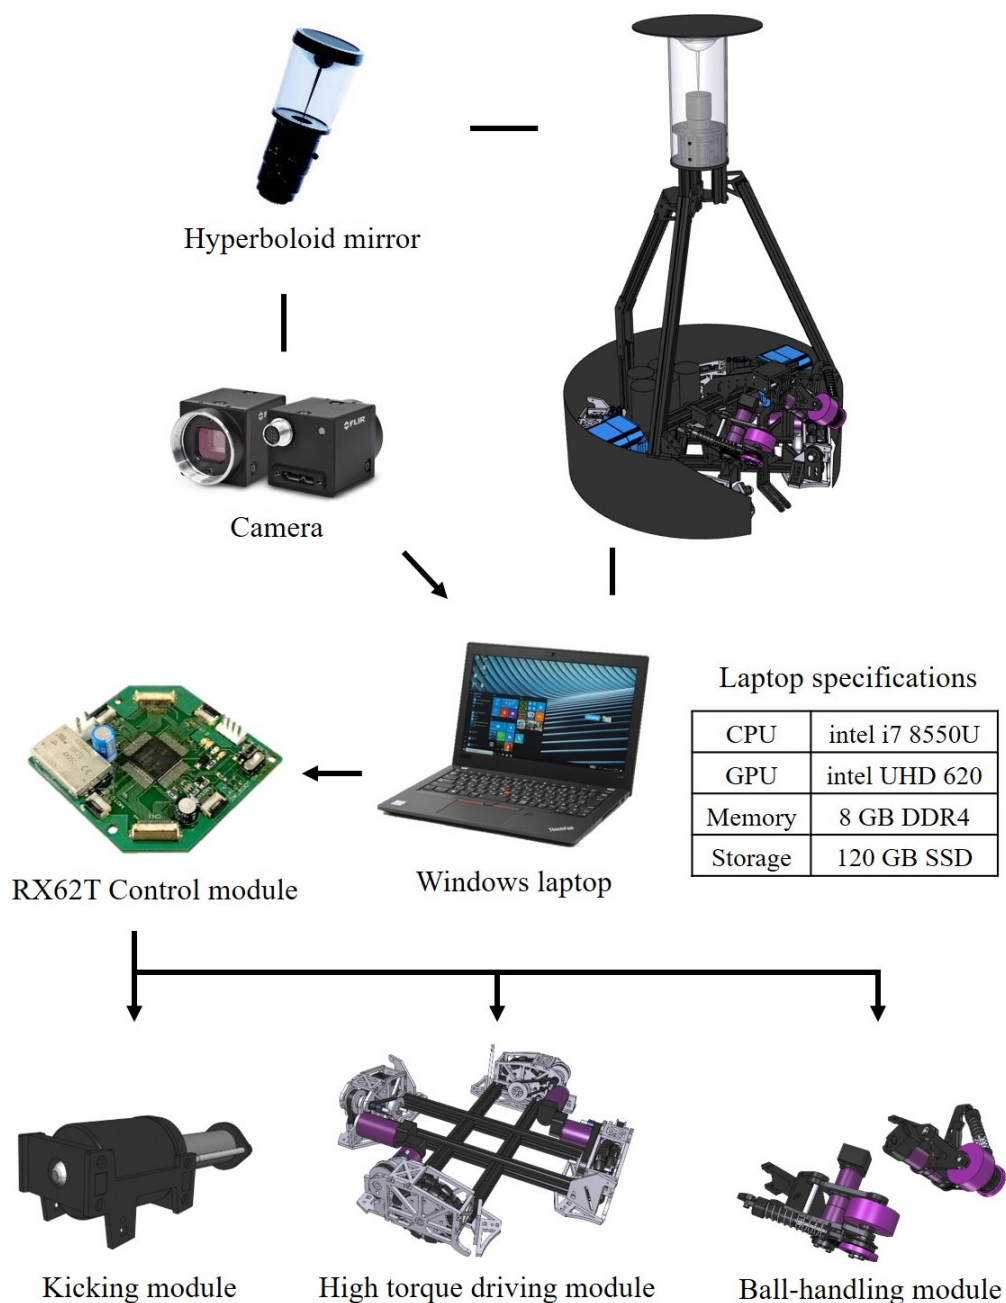


Fig. 2.3: Robot Composition

## 2.2 ハードウェア

### 2.2.1 全方向移動機構

RoboCup MSL では  $14 \times 22 \text{ m}$  という広大なフィールドが使用され、ロボットは周囲環境の変化に対して臨機応変かつスピーディに動作することが求められる。競技における実用性を考慮すると、一般的な独立二輪駆動式や二輪（四輪）操舵式は急激な進行方向の変化に対応できないため、Fig. 2.4 のようなオムニホイールを用いた全方向移動機構が有用である<sup>97),98)</sup>。全方向移動機構はオムニホイールに装着したフリーローラの働きにより車軸方向への移動が可能であり、姿勢に依存しない全方向移動が可能であるが、フリーローラが連続的に接地するため、振動が発生する欠点がある。画像認識に対する振動の影響を考慮し、フリーローラサイズの小型化と数量増加、材質変更により低振動化した自作オムニホイールを Fig. 2.5 に示す。ここで、自作のフリーローラは地面との摩擦力増加を意図して、デュロ硬度 A44 の熱可塑性エラストマー（TPE）を用いており、射出成形により製作している。さらに、フリーローラの軸受として、POM 樹脂製の内部パーツを使用し、接触摩擦の低減を図っている。自作したフリーローラを Fig. 2.6 に、自作オムニホールを用いたホイールホルダを Fig. 2.7 に示す。四輪のホイールを用いた駆動機構では常に全ての車輪が接地していることが保証出来ないため、Fig. 2.8 のようなダンパ機構を搭載して車輪を接地させる必要がある<sup>99)</sup>。各車輪の駆動用モータには高トルクな RE40（maxon 社製）<sup>75)</sup> を使用し、タイミングベルトとタイミングプーリを用いた自作減速機により約 6:1 の減速比で減速している。モータの外観と仕様を Fig. 2.9 と Table 2.1 にそれぞれ示す。




Fig. 2.4: Omnidirectional driving module



Fig. 2.5: Omni wheel



Fig. 2.6: Free roller




Fig. 2.7: Wheel holder




Fig. 2.8: Damper mechanism



Fig. 2.9: RE40 (maxon international ltd.)

Table 2.1: Motor specifications

Nominal voltage	48 V
Weight	480 g
Full length	91.7 mm
Outer diameter	40 mm
Speed constant	158 rpm/V
Torque constant	60.3 mNm/A
Terminal resistance	1.13 $\Omega$
Max. efficiency	92%

## 2.2.2 ボール保持機構

競技においてボールを自在に操作できることは重要な要素である。ボールの保持力を強力にすることで、相手ロボットとのボールの取り合いを有利にすることができ、パスも受け取りやすくなるため、より戦略的な行動が可能となる。本研究のロボットにはFig. 2.10のようなボール保持機構が搭載されている<sup>100)</sup>。このボール保持機構は左右のモータに接続されたタイヤを回転させ、ボールを巻き込むことでボール保持を実現している。Fig. 2.11, 2.12 にボールを保持しているロボットの様子を示す。左右のダンパ機構により衝撃を吸収し、パスやドリブル時にボールを保持しやすくしている。さらに、ボールを保持するタイヤの外側にもシリコン製の变形しやすい小型タイヤが搭載され、機構正面以外のボールも中心まで巻き込み保持することができる。ボールの保持方法は規定により厳しい制限があり、ボールがロボットの進行方向に対して自然な方向に回転していなければならない。本機構では、ロボットの移動方向・移動速度に合わせて回転数を適切に制御することで、自然な回転を実現している。




Fig. 2.10: Ball-handling module



Fig. 2.11: Front view of handing the ball



Fig. 2.12: Side view of handing the ball

### 2.2.3 キック機構

競技においてシュートやパスのためにボールを打ち出す必要があるため、ロボットはソレノイドを使用した Fig. 2.13 のキック機構を搭載している<sup>101)</sup>。100 V に昇圧した電力を大型コンデンサに蓄積し、FET の開放によりソレノイドに大電流を流すことで、鉄芯を強力に押し出す仕組みとなっている。ソレノイドに流す電流はゲートの開放時間で制御することが可能であり、これによりキックの強度を任意に変更することができる。また Fig. 2.14 のようなキックバーを必要に応じて左右に動かすことにより、鉄芯が直接ボールに当たる時に低い軌道のグラウンダーボール (Fig. 2.15)、キックバーに当ててボールをキックバーが蹴り上げる時に高い軌道のボール (Fig. 2.16) というように蹴り分けが可能である。様々な軌道のボールを蹴ることができるため、幅広い戦略を立てることができる。



Fig. 2.13: Kicking module




Fig. 2.14: Kicking bar




Fig. 2.15: Ground ball shoot




Fig. 2.16: Loop shoot

## 2.3 制御システム

### 2.3.1 制御ユニット

本研究のロボットは Fig. 2.3 に示したようにノート PC をメイン PC として制御しているが、ロボットに搭載されるハードウェア全てをメイン PC のみで制御することは、配線やソフトウェアの複雑化に繋がる。また、メイン PC は画像処理や行動戦略の計算量が多く、動作も不安定であるため、ハードウェアを効率よく安定して制御するためにマイコンを用いた専用の制御ユニットを導入している<sup>102)</sup>。制御ユニットとハードウェアの接続図を Fig. 2.17 に示す。ここで、モータコントロールには ESCON Module 50/5 (maxon 社製, Fig. 2.18, Table 2.2)<sup>76)</sup> を使用している。制御ユニットは各種センサやキック機構、ボール保持機構、駆動機構などの制御と同時に、様々な物理演算をリアルタイムで行う必要があるため、比較的高性能な RX62T マイコン (Fig. 2.19, Table 2.3)<sup>77)</sup> を使用している。専用の制御ユニットを使用することで全体の処理負荷が分散し、安定した動作を実現している。ロボット駆動部に専用の制御ユニットを搭載した様子を Fig. 2.20 に示す。

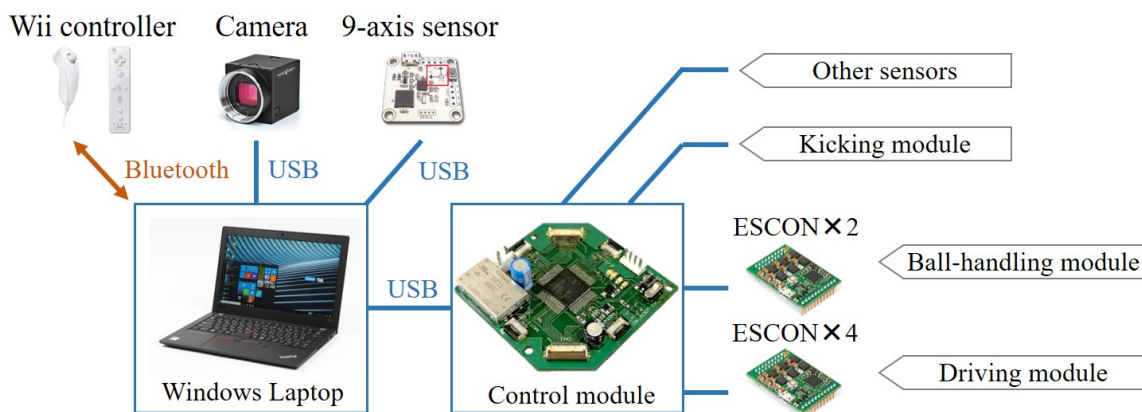


Fig. 2.17: Block diagram of the control module




Fig. 2.18: ESCON Module 50/5 (maxon international ltd.)

Table 2.2: ESCON Module 50/5 specifications

Operating voltage	10-50 V
Continuous output current	5 A
Max. output current	15 A
Max. speed	150000 rpm
Size	43.2×31.8×12.7 mm
Weight	12 g
A/D outputs	Analog 2, Digital 2
A/D inputs	Analog 2, Digital 2



Fig. 2.19: Renesas RX62T

Table 2.3: Renesas RX62T specifications

Operating Frequency	100 MHz
Supply voltage	5 V
RAM	16 KB
ROM	256 KB
Data flash	32 KB
I/O ports	55

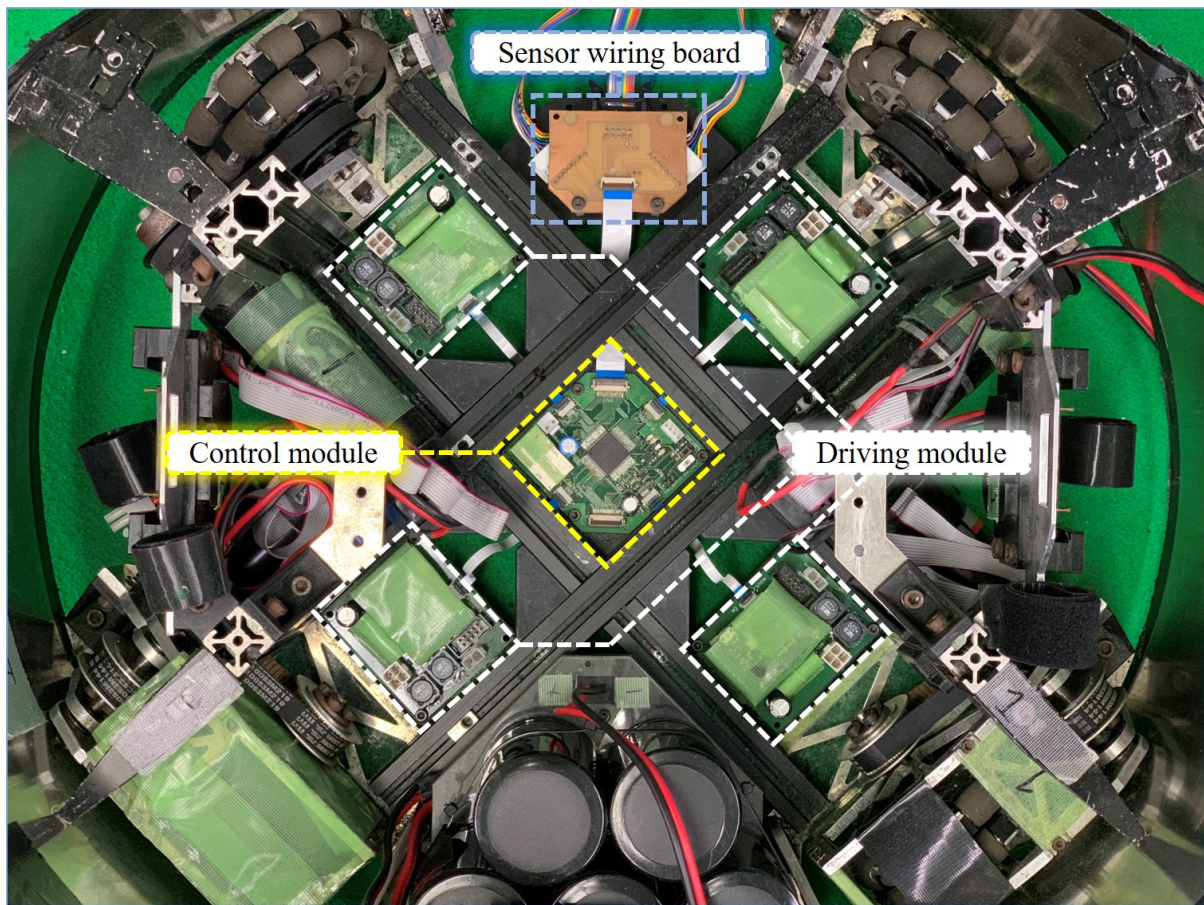


Fig. 2.20: Control module

## 2.4 通信機能とセンサ

### 2.4.1 通信機能

RoboCup MSL の競技は Referee Box と呼ばれる 1 台の PC が競技の再開, 停止, 各セットプレイを指示することで進行する. Referee Box より出された指示は, 各チームのホスト PC である Base Station が受け取り, 各チームの全ロボットに対して行動指示を行う. RoboCup MSL の競技規定では, 各ロボット及び 1 台の Base Station は, Fig. 2.21 に示したように IEEE 802.11 の各仕様を満たす無線通信設備で通信が可能である. 本研究のロボットはメイン PC の無線 LAN を用いてロボット間の外部通信を行っており, 競技進行の指示を受け取るのと同様にお互いの自己位置やその他の環境情報を共有している.

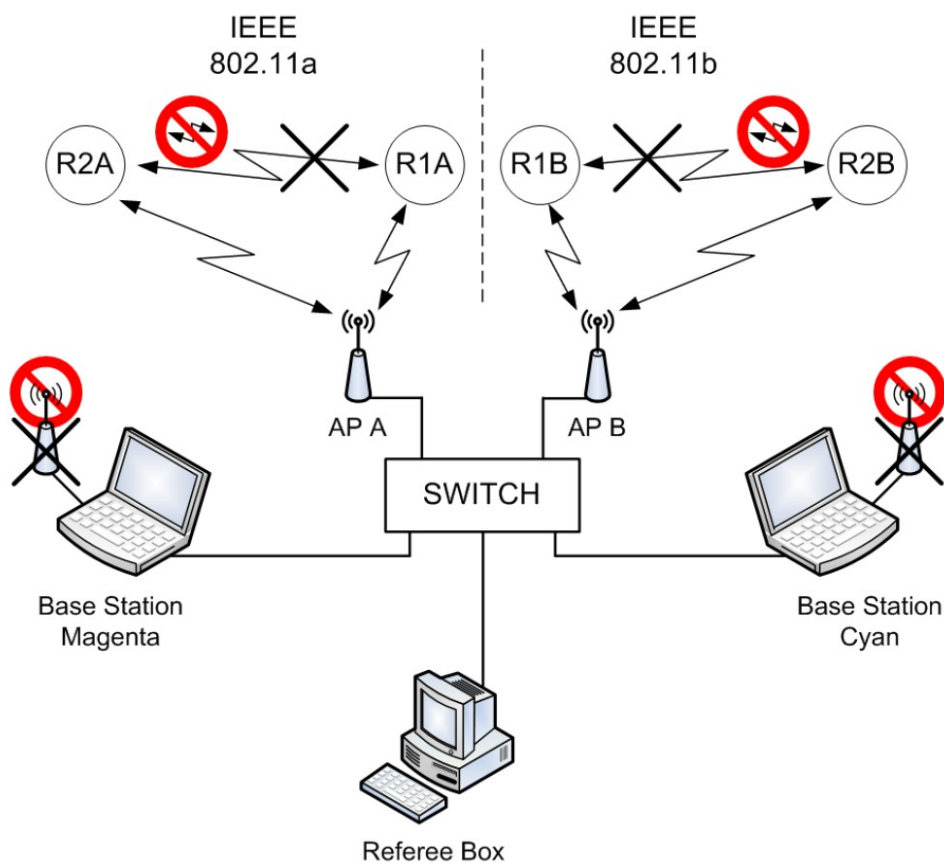


Fig. 2.21: Diagram of wireless communication



## 2.4.2 その他のセンサ

ここまで解説したハードウェアの搭載により、競技上で必要となる機能が概ね実装されるが、動作精度の向上や環境認識精度の向上のためにいくつかのセンサ等を補助要素として追加している。駆動部中央には Fig. 2.22 に示す IMU センサ (InvenSense MPU9250)<sup>78)</sup> が搭載されており、得られた加速度・角速度を用いて動作時の姿勢制御補償やデッドレコニングの誤差補正を行っている。また、自己位置同定の補助として Fig. 2.23 に示す地磁気センサを搭載しており、駆動用モータによる磁場変化の影響を考慮してロボットの上部に設置している。ここでは、地磁気センサ<sup>79)</sup> より得た磁気情報を用いてロボットの姿勢を推定する電子コンパスとして利用している。電子コンパスの情報を用いることで、自己位置同定の計算効率を大幅に向上している。ロボットには、これらの他にも現在のボールの有無を計測するセンサや、ボール保持機構の保持状態を確認するセンサなど、様々なセンサが搭載されている。



Fig. 2.22: IMU sensor




Fig. 2.23: Geomagnetic sensor

## 2.5 大会実績

本研究のロボットは、Table 2.4 に示すように多くの大会に参加しており、実際の競技において性能や動作安定性を十分に検証している。2009 年に Japan Open に出場してから 10 年以上改良を重ね、現在では日本の国内大会で優勝争いに常に絡むようになっている。さらに、検証の場を広げ、海外チームと交流するために、近年では海外で開催される競技会にも参加している。

Table 2.4: RoboCup competitions and results

Year	Competition	Venue	Result
2008	Japan Open	Shizuoka, Japan	Participated in the Tech Challenge only
2009	Japan Open	Osaka, Japan	4th Place
2010	Japan Open	Osaka, Japan	Failed to qualify
2011	Japan Open	Osaka, Japan	2nd Place
2012	Japan Open	Osaka, Japan	3rd Place
2013	Japan Open	Tokyo, Japan	2nd Place
2014	Japan Open	Fukuoka, Japan	2nd Place
2015	Japan Open	Fukui, Japan	2nd Place
2016	Japan Open	Aichi, Japan	2nd Place
2017	Japan Open	Ishikawa, Japan	1st Place
	World Championship	Aichi, Japan	6th Place
2018	Japan Open	Gifu, Japan	1st Place
2019	Japan Open	Kanagawa, Japan	2nd Place
	China Open	Zhejiang, China	3rd Place Best Whistle Award
	Asia-Pacific Tianjin Invitational Tournament	Tianjin, China	4th Place
2021	Asia-Pacific	Virtual	2nd Place(Scientific Challenge)

## 第 3 章 複数センサを用いた障害物検出

前章で解説したように、本研究ではすでに RoboCup MSL 競技への出場を重ねており、Table 2.4 に示した実績もある。RoboCup MSL において最低限の競技を行うためには、安定して動作するロボットのハードウェアに加えて以下の要素技術が必要となる。

- フィールド上のボール認識技術
- フィールドにおける自己位置同定技術
- ゴール位置の認識技術

これらの技術が揃うことで、「競技進行に合わせて正しくポジショニングし、ボールを取得して、ゴールまで運び、シュートする。」という一連の基本的な行動が実現でき、本研究は現在この段階を満足する技術レベルに位置している。

次の段階では戦術を考慮したパスやドリブルなどの知的な行動判断が求められ、これらを実現するためには、フィールド上の敵・味方全ての位置情報が正しく取得できていることが重要となる。味方の位置情報は、各ロボットの自己位置同定情報をチーム内で共有することにより得られるが、敵の位置情報は自身のセンサデバイス等から推定する必要がある。そこで、本研究ではフィールド上に存在する複数の敵ロボットの位置情報を実時間で認識する複数障害物のリアルタイム認識手法を提案する。本研究では、敵ロボットについて、パスやドリブルで避けるべき対象と見なししていることから障害物と呼ぶこととする。

### 3.1 全方位カメラによる障害物検出

RoboCup MSL ではロボット外装の基本色は黒色と規定されているため、本研究ではこの点に注目し、全方位カメラより取得した黒色の該当サイズの物体を障害物として検出する。競技では、フィールド（白線含めた緑色領域）外の障害物を考慮する必要はないため、フィールド内に限定した障害物検出を想定する。本節ではロボット最上部に搭載した全方位カメラシステムの解説と、それを用いた黒色の複数物体検出について述べる。

#### 3.1.1 全方位カメラ

RoboCup MSL のロボットは、周囲環境の情報を取得するためのセンサとして、前方のみを取得する通常のカメラとは異なり、 $360\text{ deg}$  の視野を持つ全方位カメラを使用することが多い。全方位カメラは1枚の画像から全方向の環境情報を取得できるため、試合状況が素早く変化するサッカー競技において有用であり、本研究のロボットも Fig. 3.1, 3.2 に示す全方位カメラシステムを搭載している。本システムは、解像度や画像サイズなどの問題により既製品ユニットではなく、一般的な単眼カメラと双曲面ミラーを組み合わせ自作している。本システムを構成するパーツを Fig. 3.3, 3.4 に示す。カメラは小型で USB3.0 を備えている Flea3（株式会社フリーシステムズ製、Table 3.1）を使用しており、リアルタイムで高解像度な画像の取得が可能である。カメラから全方向の環境情報を取得するために双曲面ミラー（VS-C450MR、ヴイストーン社製）を使用しており、ミラーを下方から撮影することで全方向の環境画像を一度に取得することが可能となる。Fig. 3.5 に全方位カメラより取得した画像を示す。画像中心にカメラ自身が映り込み、中心から円外周に向けて極端に分解能が低下する特徴を持つ。また、画像中の直線成分は放射方向以外では維持されないため、フィールドの白線が大きく歪曲していることがわかる。




Fig. 3.1: Camera system



Fig. 3.2: Omnidirectional camera



Fig. 3.3: USB camera



Fig. 3.4: Camera lens and hyperbolic mirror

Table 3.1: Camera specifications

Interface	USB 3.0
Power Requirements	5 V via USB3
Resolution	1280 × 1024
Frame Rate	60 fps
Readout Method	Global shutter
Dimensions [W x H x L]	29 mm × 29 mm × 30 mm





Fig. 3.5: Image from omnidirectional camera

### 3.1.2 フィールドと障害物の色抽出

Fig. 3.6 に RoboCup MSL のフィールド環境を示す。障害物認識を行う環境として、フィールド床、障害物の基本色がそれぞれ緑色と黒色であるという前提条件を利用するために、全方位カメラにより取得した画像から緑色と黒色の抽出画像を作成する。ここで、緑色と黒色の抽出にはそれぞれ HSV 変換と YUV 変換を用いる<sup>80)~82)</sup>。HSV 表色系は色相、彩度、明度の3属性情報により色を表現する表色系であり、緑色のような直接的な色相情報を扱う場合に有用である。また、YUV 表色系は輝度信号、青色成分の色差、赤色成分の色差の3つの情報により色を表現する表色系であり、輝度情報を中心とするため、黒色のような無彩色を扱う場合に有用である。事前のキャリブレーション（対象色の色情報範囲の確認作業）により設定したしきい値を用いて作成した緑色抽出画像と黒色抽出画像を Fig. 3.7 に示す。それぞれの色抽出結果において、正しく対象色が抽出できていることが確認できる。




Fig. 3.6: RoboCup MSL field



(a) Input image



(b) Black extracted image



(c) Green extracted image

Fig. 3.7: Color extraction

### 3.1.3 フィールド領域画像の生成

Fig. 3.7(b) で作成した黒色抽出画像には、フィールド外側にある物体が含まれており、この状態から障害物を判別することは困難である。そこで、Fig. 3.7(c) の緑色抽出画像からフィールド領域に相当するマスク画像を生成し、Fig. 3.7(b) に適用することで、フィールド領域内に限定した黒色抽出画像を得る。フィールド領域のマスク画像生成には、Fig. 3.8, 3.9 に示す放射状に得た緑領域の端点を用いた凸包処理を利用する。凸包（凸包絡）とは、与えられた点集合を全て含む凸集合であり、凹みが無い最少の多角形を得る手法である。凸包処理には、2段階の処理で凸包を決定する sklansky のアルゴリズムを用いており、その処理過程は以下の通りである。

1. 上下左右の最大点 (Fig. 3.10, TBLR) を基点に領域 R1~R4 をセグメンテーションする。
2. 注目点  $L(=i)$  と最隣点  $i+1$  を用いて  $i+2$  の点の採用/棄却を判断する (Fig. 3.11)。
3. 全点を順に判断し、凸包の最外周点群を得る。

以上の凸包処理により生成したマスク画像を Fig. 3.12 に示し、マスク処理により得たフィールド領域内に限定した黒色抽出画像を Fig. 3.13 に示す。




Fig. 3.8: Endpoint search in the field area




Fig. 3.9: Green termination point image






Fig. 3.10: Grouping of point sets




Fig. 3.11: Search procedure




Fig. 3.12: Field area recognition result




Fig. 3.13: Black extracted image in field area

### 3.1.4 障害物候補の特徴化

前節において得た Fig. 3.13 の黒色抽出画像では、中央にロボット自身が映り込んでいる。ロボット中心の直上に全方位カメラが設置されているというハードウェア条件より、Fig. 3.14 のように映り込んだロボット中心（画像中心とは異なる）を原点にとると、画像中の障害物の極座標  $(r_{image}, \theta_{image})$  は実環境のロボット座標系における障害物の位置情報  $(r_{target}, \theta_{target})$  と一致する。ただし、距離は後に述べる画素値を実距離に変換する距離変換関数  $D^{103),104)}$  を用いて  $r_{target} = D(r_{image})$ 、角度は  $\theta_{target} = \theta_{image}$  である。また、Fig. 3.14 は黒色の表現を統一するために Fig. 3.13 に対して適度なクロージング処理後、画素反転処理を施している。

Fig. 3.14 において自身の映り込みを除去後、極座標原点から障害物までの距離（画素数）を全周囲に対して確認したグラフを Fig. 3.15 に示す。ここでは、Fig. 3.14 中に緑線で示しているように角度は3度間隔でサンプリングしており、全方位カメラの特性により回転方向が逆（時計回り）となっている。Fig. 3.15 では、障害物はグラフの谷として表現されており、A～G の障害物候補が存在していることがわかる。Fig. 3.15 に対して Fig. 3.16 の距離変換関数  $D(r_{image})$  を適用した結果を Fig. 3.17 に示す。距離変換関数  $D$  は画素数と実距離の関係を事前実験により対応付けたものであり、グラフ右側の距離一定となっている部分は全方位画像における円形撮影領域外を表している。距離変換後の Fig. 3.17 では障害物候補 A～G が実距離として表現されている。

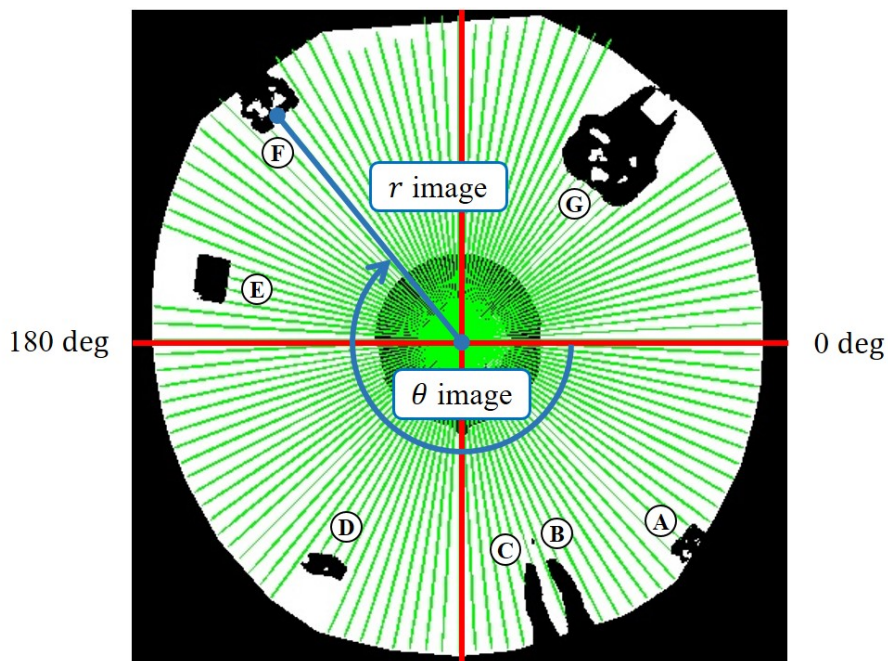


Fig. 3.14: Black width search in the field area




Fig. 3.15: Black width search result in field area

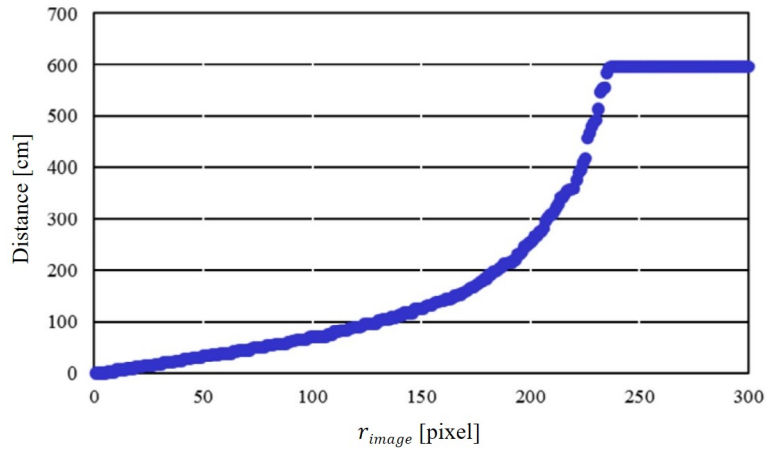


Fig. 3.16: Distance calibration




Fig. 3.17: Actual distance conversion

### 3.1.5 障害物の検出

Fig. 3.17 の障害物候補 A～G には対象である障害物（ロボット）以外の黒色物体も含まれている。そこで、RoboCup MSL に規定されたロボットの幅 50 cm 以内という条件を利用し、候補から対象の障害物のみを検出することを考える。ここで、RoboCup MSL のロボットは搭載すべきデバイスの多様性と複雑性から、どのチームにおいても概ね幅 50 cm となっている。

全方位カメラの特性により、画像中の障害物幅は距離  $r_{target}$  に依存して大きく変化する。ここでは Fig. 3.17 における障害物候補を表すグラフ谷部の幅を検出幅  $w_{target}$  とし、距離  $r_{target}$  における  $w_{target}$  の妥当性により障害物か否かを判断する。事前実験として Fig. 3.18, 3.19 のように既知の  $r_{image}$  に対する  $w_{target}$  を多数サンプリングして得た関係を Table 3.2, Fig. 3.20 に示し、Fig. 3.20 から得た  $w_{target}$  算出の近似式を次式に示す。

$$w_{target} = 43.05r_{image}^{-0.973} \quad (3.1)$$

Fig. 3.17 に対して上式を適用することで障害物以外を取り除いた結果を Fig. 3.21 に示す、黒いズボンの審判の足 (B, C) やフィールド上に置かれたノート PC などの黒色物体 (D, E) が除去され、フィールド内の障害物のみが正しく検出されていることがわかる。

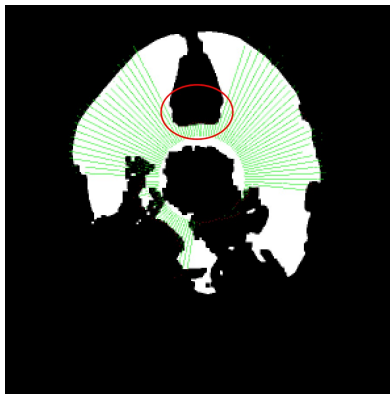


Fig. 3.18: Measurement result at 50 cm




Fig. 3.19: Measurement result graph at 50 cm

Table 3.2: Detection angle

Distance[cm]	Detection angle[deg]
50	45
100	21
150	15
200	12
250	9
300	6
350	6
400	6
450	6

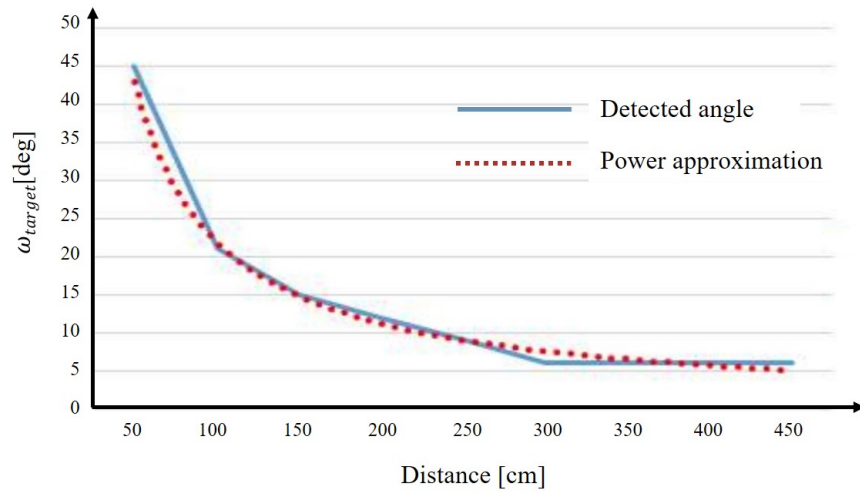


Fig. 3.20: Verification results between detection width and distance

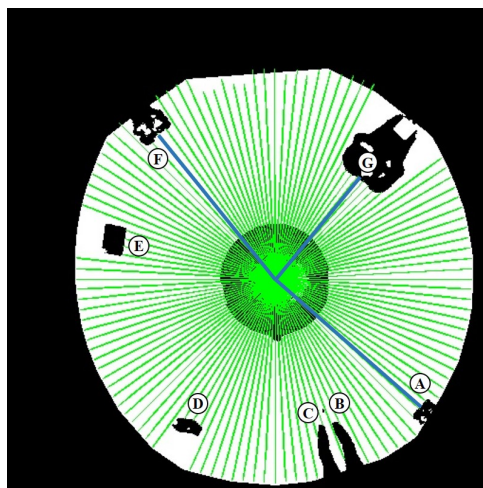


Fig. 3.21: Robots detection result

### 3.1.6 全方位カメラによる障害物検出手法の精度検証

前節までに述べた障害物検出手法の精度を検証する。ロボットの正面に配置した障害物のロボットを 100 cm 間隔で離していき、実際にメジャーを用いて計測した距離と検出した障害物との距離を確認する。検証は各距離において 5 回行い、各測定誤差の平均を Table 3.3 に示す。検証結果より、700 cm までは検出可能であったが、700 cm 以降は検出できなかった。これは、黒色抽出した際に障害物の領域が極端に小さくなったためである。

精度に関して見てみると、距離 300 cm 程度まではロボット 1 台分にも満たない比較的良好な精度で障害物が検出できているが、それ以降は距離に応じて検出誤差が大きくなっている。最大誤差は 700 cm の時に 96.76 cm となっており、ロボット 2 台分の幅に相当している。これは全方位カメラの分解能特性によって遠くに映っている物体の精度が低下してしまうことに起因している。

Table 3.3: Measurement error with omnidirectional camera

Distance[cm]	Measurement error[cm]
100	14.0
200	18.1
300	25.9
400	48.6
500	57.0
600	71.6
700	96.8
Average error rate	11.57%

### 3.2 複合センサシステムによる検出精度の改善

前節の精度検証で確認した遠方における精度低下は、全方位カメラの遠方分解能に起因しており、全方位カメラの構成上の問題であるため改善は難しい。700 cm でロボット 2 台分の平均誤差という結果は、障害物の回避を含めた経路計画の観点ではそれほど問題ではないが、幅 200 cm のゴールの空き領域（ゴールキーパーのいない側の空間）を推定する場合には得点率に大きな影響を及ぼす。そこで、新たにセンサデバイスを追加することで、攻撃や守備等の戦略行動のために精度の高い障害物情報を要する前方の検出精度の改善を図る。改良したセンサ構成図を Fig. 3.22 に示す。前節までに解説した全方位カメラによる検出手法に対し、前方距離情報の精度補償のために二次元走査型の光距離センサである LiDAR（Light Detection and Ranging）を複合させ、高精度な障害物検出を試みる。ここで、精度補償を行う範囲は前方約 270 度であり。これは、次節において紹介するデバイスの仕様に依存している。次節において全方位カメラと LiDAR の複合システムの詳細を述べる。




Fig. 3.22: Schematic of the composite sensor system

### 3.3 全方位カメラとLiDARを用いた障害物検出

#### 3.3.1 LiDAR

LiDAR(Light Detection and Ranging)とは、光でスキャンしながら検出物までの距離を測定する二次元走査型の光距離センサのことであり、特徴として測定距離の計測誤差が非常に小さいことが挙げられる。LiDARの特徴を利用し、全方位カメラによる障害物検出結果の距離情報を補うことで障害物検出精度を向上させる。搭載するLiDARには検出範囲(距離, 角度)と分解能を考慮し、UST-10LX(北陽電機株式会社製, Fig. 3.23, Table 3.4)を選定した。LiDARから得られる情報は、各走査角度に対する測距データであり、Fig. 3.24に示すようなレーダー方式の情報となる。ここでは、測定中心から放射状に伸びた線分が測定距離を表しており、障害物が存在する場合は図中の赤枠のようにレーダー上の遮へい物として凹みで表現される。



Fig. 3.23: UST-10LX

Table 3.4: UST-10LX specifications

Supply voltage	DC 12V/DC 24V
Supply current	150mA or less
Detection range	0.06m to 10m (white Kent sheet) 0.06m to 4m (diffuse reflectance 10%)
Max. detection distance	30m
Accuracy	±40mm
Scan angle	270°
Angular resolution	0.25°
Scan speed	25ms (Motor speed 2400rpm)
Dimensions (W×D×H)	50×50×70mm




Fig. 3.24: LiDAR detection result



### 3.3.2 LiDAR の基礎性能検証

選定した LiDAR の基礎的な性能を確認するため、環境や対象物等の条件を変えた検証実験を行う。ここでは、障害物となる敵ロボットの検出高さや床面の影響を考慮し、取付け高さを床面から LiDAR の測定面まで  $35\text{ cm}$  とし、汎用的な基礎データを得るために、RoboCup MSL ロボットと幅 (約  $50\text{ cm}$ )、色 (黒色) が近い直方体のキャリーケースを測定対象とした。実験は長い測定距離を確保するために Fig. 3.25 に示す廊下で行い、測量用レーザ距離計による計測距離  $100\text{ cm}$  毎に 3 回計測した平均誤差を記録する。実験結果を Table 3.5 に示す。LiDAR による測定精度 (誤差) は近距離で  $1\text{ cm}$  前後であり、遠方においても非常に高精度であることがわかる。また、 $1400\text{ cm}$  以降は安定してデータが取得できなかった。



Fig. 3.25: Experimental environment

Table 3.5: Distance measurement error of LiDAR

Distance[cm]	Measurement error[cm]
100	0.8
200	1.1
300	0.8
400	0.7
500	2.2
600	2.1
700	3.2
800	1.5
900	2.2
1000	2.3
1100	2.4
1200	1.6
1300	2.5
Average error rate	0.33%

次に、環境条件や対象の違いに対するロバスト性を検証する。測定方式は先の実験と同様であり、光環境の検証としてキャリーケースを対象として廊下の蛍光灯を消した環境、材質・形状・色の検証として測定対象を Fig. 3.26 に示す各種とした状況において実験した結果を Table 3.6 に示す。Table 3.5 の結果と比較して、いずれの検証結果も同等の誤差であり、LiDAR の計測は光環境や材質、色、形状に影響を受けずに安定して高精度な計測ができることがわかる。



Fig. 3.26: Material for experiments

Table 3.6: Experimental results with each material

Distance[cm]	Measurement error[cm]								
	Ambient lighting off	Material			Color			Shape	
		Fabric	Plastic reflector	Foamed Polypropylene	Plastic (black)	Plastic (white)	Plastic (blue)	Sponge (flat)	Sponge (wave)
100	1.5	1.4	4.0	0.8	2.4	1.8	0.2	1.6	0.2
200	2.3	1.0	2.3	2.1	2.6	1.7	1.4	2.3	0.3
300	1.2	0.7	3.1	1.5	1.6	1.5	0.3	1.8	0.4
400	1.9	0.4	3.7	1.5	0.3	1.5	1.0	1.2	2.5
500	1.7	1.4	2.9	2.1	1.9	0.9	0.8	1.7	2.6
600	2.3	1.0	2.0	0.9	4.1	0.7	1.7	2.5	1.1
700	1.6	0.1	2.7	1.4	2.3	2.0	1.4	2.9	2.6
800	1.1	0.5	0.1	0.5	0.4	1.9	2.1	3.5	3.4
900	1.4	0.8	4.5	1.1	1.5	2.6	1.8	2.6	1.0
1000	0.4	0.4	2.4	0.8	3.7	1.9	2.5	3.3	1.7
1100	1.8	0.8	2.2	2.3	2.4	3.2	1.8	2.8	2.8
1200	8.1	1.2	3.6	2.8	1.1	2.4	2.3	1.1	3.3
1300	0.6	1.2	2.3	0.1	1.9	2.1	1.5	0.9	3.0
Average error rate	0.44%	0.24%	0.76%	0.32%	0.52%	0.42%	0.24%	0.48%	0.28%

さらに, RoboCup MSL 競技を想定し, 味方や敵ロボットに搭載された LiDAR 同士の干渉について検証する. 実験環境として以下の 2 パターンを用いた.

1. 測定を行う LiDAR の前方に 2 台目の LiDAR を配置し, LiDAR 方向にレーザを照射する (直接照射, Fig. 3.27).
2. 測定を行う LiDAR の後方に 2 台目の LiDAR を配置し, 同じ被測定物方向にレーザを照射する (間接照射, Fig. 3.28).

検証の結果, いずれの状況においても LiDAR 間の干渉は認められなかった.




Fig. 3.27: Direct irradiation experiment




Fig. 3.28: Indirect irradiation experiment

### 3.3.3 LiDAR の搭載と障害物検出精度の検証

前節において LiDAR の性能が目的を満たしていることが確認できたため、3.2 節で述べた前方 270 度に対する計測を意図して Fig. 3.29 のようにロボット前方に LiDAR を搭載した。LiDAR の設置高さは前節の基礎実験同様に 35 cm である。ここでは、3.1 節において述べた全方位カメラによる障害物検出手法を基本とし、検出された障害物の角度と等しい LiDAR 走査角における測距データを最終的な該当障害物の距離情報として置き換えている。このロボットを用い、Fig. 3.30 のように 3.1.6 節と同様の障害物検出実験を行った結果を Table 3.7 に示す。各検証距離に対する LiDAR の検出誤差と併せ、参考のために Table 3.3 の全方位カメラのみによる検出誤差も転記している。全方位画像により黒色の障害物が検出可能な 100~700 cm において、LiDAR による検出結果は非常に誤差が小さく、精度が高いことがわかる。




Fig. 3.29: LiDAR setting location



Fig. 3.30: LiDAR performance measurement

Table 3.7: Comparison of measurement errors

Distance[cm]	Measurement error[cm]	
	Omnidirectional camera	LiDAR
100	14.0	0.8
200	18.1	2.3
300	25.9	2.0
400	48.6	0.6
500	57.0	0.9
600	71.6	2.9
700	96.8	2.7
Average error rate	11.57%	0.54%

### 3.4 フィールド座標系における複数障害物情報

#### 3.4.1 自己位置情報と障害物検出情報の統合

前節において得た距離精度の高い障害物検出情報はロボット座標系（測定ロボットからの距離と角度）の情報となっている。そこで、チーム内における障害物の位置情報共有を想定し、フィールド座標系へ変換する。ここではロボットが取得した自己位置情報を用い、検出した各障害物情報をフィールド座標に変換する。全方位カメラから取得した画像を Fig. 3.31 に、Fig. 3.31 より自己位置情報を取得した画像を Fig. 3.32 に、ロボットが障害物を検出した画像を Fig. 3.33 に、自己位置情報を用いてフィールド座標系に変換した各障害物情報を Fig. 3.34 に示す。Fig. 3.32, 3.34 の図は水色の四角形が推定した自己位置を表しており、紫色の四角形が障害物の位置を表している。全方位カメラと LiDAR により得たロボット座標系の障害物情報が正しくフィールド座標系に変換されていることがわかる。




Fig. 3.31: Omnidirectional camera image




Fig. 3.32: Self-located information

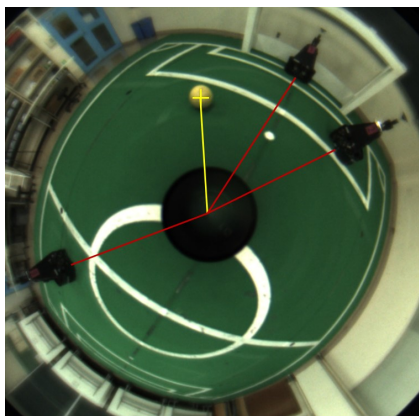


Fig. 3.33: Obstacle detection results




Fig. 3.34: Obstacles location information

### 3.4.2 障害物検出情報の誤差

ここまで述べた手法により、全方位カメラと LiDAR を用いた複数障害物のフィールド座標系における位置情報の検出が可能となった。本手法では LiDAR を併用しているため、全方位カメラにおける放射方向の検出距離精度が非常に高いが、円周方向については全方位カメラの遠方分解能の影響を受けるため、検出角度の誤差が発生する。また、ロボット座標系からフィールド座標系への変換時には、自己位置情報の持つ誤差が加算される。さらに、自己位置推定や障害物検出における色抽出においては、調整者による色パラメータのキャリブレーション能力が少なからず影響し、その後続く各処理の誤差として蓄積されることが過去の研究によりわかっている。ここでは、上記の様々な要因による誤差を統合し、本手法による検出誤差としてどの程度の影響となるか評価する。ここでは、LiDAR と統合している前方 270 度を対象としている。

#### 3.4.2.1 全方位画像の遠方分解能

全方位カメラにおける円周方向の遠方分解能に起因する誤差を調べるため、全方位画像における距離毎の円周方向分解能を確認する。ロボットの中心からメジャーで計測した 100 cm 毎に 700 cm まで計測対象物 (40×40 cm の黒いプラスチック段ボール) を配置し、全方位画像を取得する。全方位画像に対して角度を確認するための放射状線分 (3 度間隔) と距離を確認するための 100 cm 毎の同心円を Fig. 3.35 のように描画した。ここで、計測対象物の計測における基準点は Fig. 3.36 のようにロボット側端面としている。各距離における計測対象物の画素数を数えることで遠方における 1 画素毎の距離分解能を調べた結果を Table 3.8 と Fig. 3.37 に示す。ロボットから距離が離れる毎に分解能が低くなり、1 画素当たりの実距離が大きくなることがわかる。この結果を用いて障害物検出における遠方分解能に起因する誤差を確認する。Fig. 3.38, 3.39 に本手法の障害物特徴化時 (3.1.4 節) のサンプリング状態を示す。障害物の端はサンプリング間隔に起因して最大で 3 度の誤差を持つことになる。100~700 cm において Table 3.8 の分解能を用いて計算した障害物検出に対する影響を Table 3.9 と Fig. 3.40 に示す。500 cm 以上の遠方ではロボット幅 50 cm に対して半分以上の誤差の要因となることがわかる。






Fig. 3.35: Image for measurement




Fig. 3.36: Measurement reference point

Table 3.8: Distance resolution measurement results

Distance[cm]	Resolution[cm/pix]
100	0.89
200	1.29
300	1.82
400	2.00
500	2.35
600	2.50
700	3.08




Fig. 3.37: Distance resolution measurement results




Fig. 3.38: Angular resolution measurement image




Fig. 3.39: Enlarged image of Fig. 3.38

Table 3.9: Angular resolution measurement results

Distance[cm]	Resolution[cm]
100	5.34
200	11.61
300	18.20
400	22.00
500	25.85
600	30.00
700	36.96




Fig. 3.40: Angular resolution measurement results

### 3.4.2.2 全方向画像を用いた自己位置同定

RoboCupでは常に試合の状況が変化しており、協調行動や戦略行動を実行するためには、リアルタイムで正確な自己位置同定手法が求められる。本研究は渡邊らの提案した自己位置同定手法を用いており、本手法はロボット周辺の白線形状を認識することで、得られた特徴点から自己位置を同定する。ここでは、自己位置同定手法の概要を簡単に解説し、その精度について確認する。

本手法では、前処理として Fig. 3.41(a) の全方位カメラで撮影した画像から緑色のフィールド領域内に限定して白色抽出することで Fig. 3.41(b) のように白線のみを抽出する。抽出画像に対して画像中の座標情報と実距離の関係性を事前計測により得た距離変換関数を適用して Fig. 3.41(c) のように歪みを解消し、白線形状の特徴が保存される最小情報量（抽出点数）まで適切に間引いた Fig. 3.41(d) を評価モデルとする。Fig. 3.42 のように白線の幾何学的情報を含むサッカーフィールド全体を探索空間  $\Omega$  とし、評価モデルとの Model-based Matching 法<sup>83),84),105)</sup> によって適合度を算出することで自己位置を同定する。探索空間  $\Omega$  内の評価モデルの位置／姿勢がロボットの

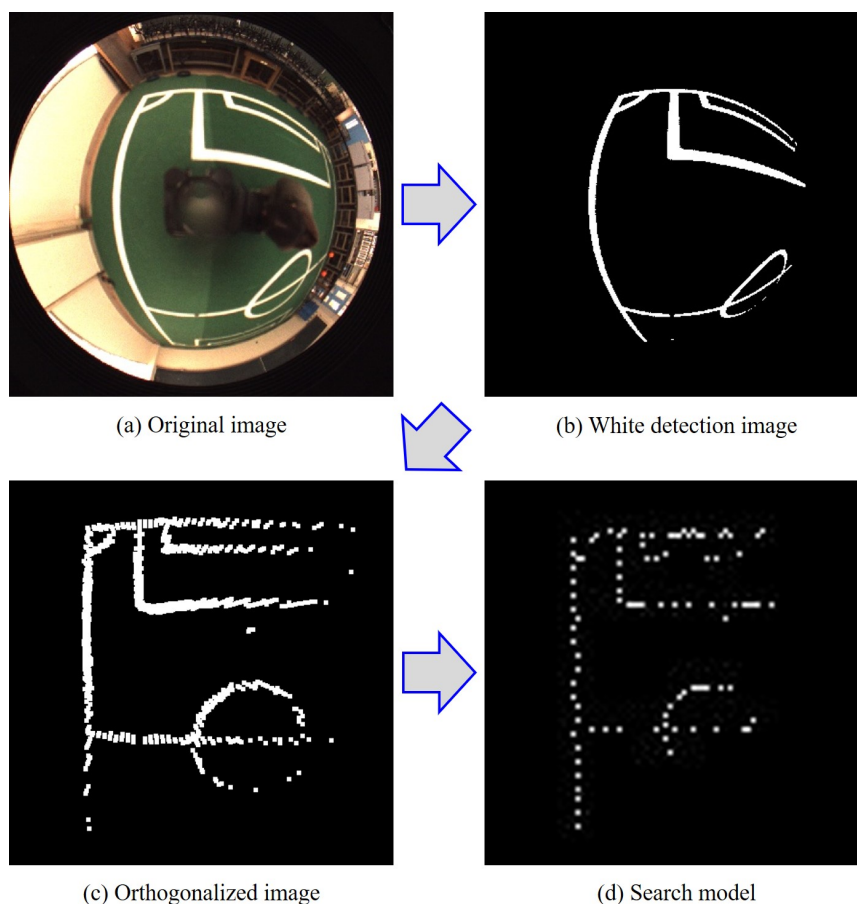


Fig. 3.41: Process of making search model

位置／姿勢と一致したときに最大適合度を取得することから，ロボットの現在位置／姿勢推定問題は Fig. 3.43 のように非線形関数の最大値探索問題に変換され<sup>106)~108)</sup>，ここでは最適化手法に遺伝的アルゴリズムを採用することでリアルタイム性を確保している．また，探索空間の回転対称性により最適解が2つ存在するが，ロボットに搭載した電子コンパスを用いて地磁気を検出することで解決し，最終的な自己位置情報を推定する．本自己位置同定手法の精度は最大誤差約 36 cm，平均誤差約 12.8 cm となっており，フィールドサイズと比較して自己位置を高精度で検出できる手法である．

障害物検出では上述した自己位置情報を用いてフィールド座標を求めめるため，自己位置同定における誤差がそのまま含まれることになる．ここでは合成時の障害物検出誤差として，前述した自己位置同定手法の平均誤差 12.8 cm を用いる．




Fig. 3.42: Matching area

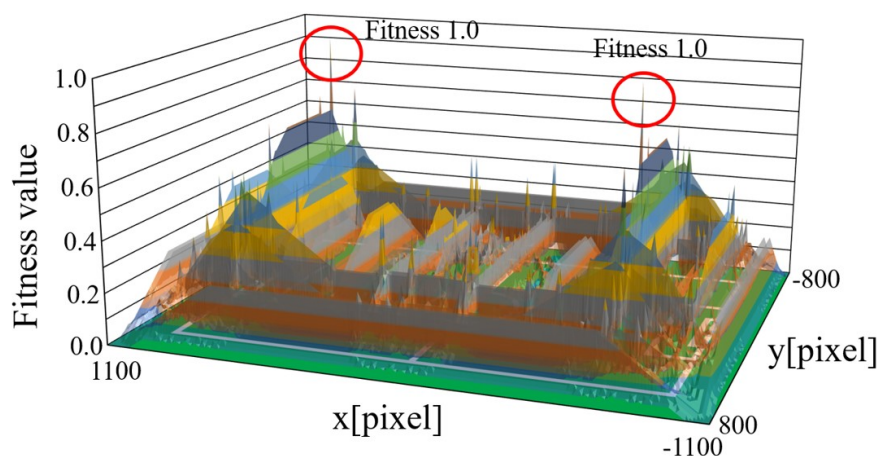


Fig. 3.43: Calculation result of the fitness function

### 3.4.2.3 調整者の色抽出スキル

競技会場では変化する光環境に依存して色相パラメータの値が変化するため、試合前には必ず色抽出パラメータの再調整が必要となる。しかし、パラメータ調整は明確な指標がないため担当者の感覚に依存しており、担当者が熟練者ではない場合、調整の結果が出来ないものとなることがわかっている<sup>109)</sup>。調整者毎の色調整スキルの違いを検証した結果を Fig. 3.44 に示す。ここでは調整者はチーム内において比較的日常的に調整を行っている者、または大会に出場している回数が多く、調整を何度も行っている者を熟練者として設定している。検証結果では検証座標と自己位置同定結果の誤差を視覚的に分かりやすく表すために検証点を中心とする正方形のマスを設置し、誤差をモノクロ濃淡で表している。検証の結果から、熟練者は自己位置同定結果の精度が高くなるようにパラメータ調整を行えるが、初心者は経験が少ないため、色抽出調整が不得手であり、平均誤差を増大させる要因となることがわかる。ここで、初心者の最大誤差が極端に大きいのは、真値と全く異なる位置を自己位置と誤認する誘拐現象によるものである。

この自己位置同定におけるパラメータ調整のスキル依存は、本研究における障害物の黒色抽出でも同様に発生することが確認されており、障害物検出では検出距離に依存して遠方では約 20 cm の調整スキル起因の誤差となることがわかっている。

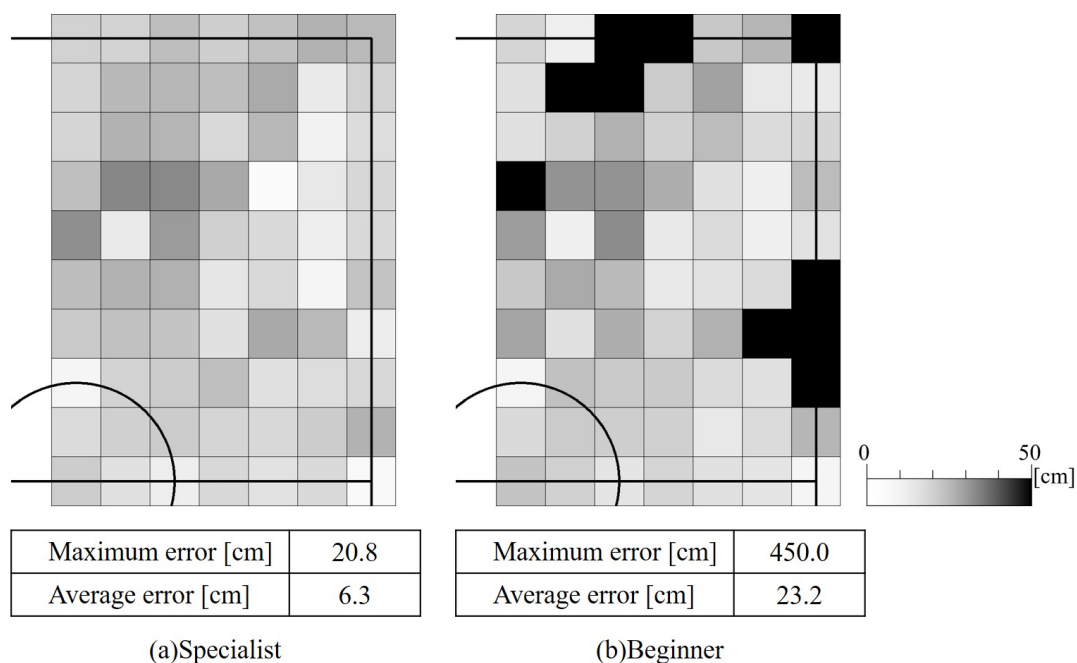


Fig. 3.44: Self localization error

### 3.4.2.4 障害物検出情報の推定誤差

3.4.2.1~3.4.2.3において確認した3つの誤差発生要因と誤差推定値を合成したものを Table 3.10 に示す。全方位カメラの遠方分解能による誤差と調整者の色相調整スキルによる誤差は距離に依存するため、合成した誤差も距離に対する依存性を持つ。合成誤差の距離依存性を Fig. 3.45 に示し、距離を  $\hat{d}$ 、推定合成誤差を  $\hat{e}$  とした一次近似による関係式を式 3.2 に示す。

$$\hat{e} = 0.0865\hat{d} + 9.45 \quad (3.2)$$

式 3.2 により得られる誤差推定値は Table 3.11 となり、本研究では以降この数値を誤差推定値として用いる。

Table 3.10: Integration results for each error factor

Distance[cm]	Error[cm]			
	Resolution	Self location	Tuning error	Total
100	5.3	12.8	0	18.1
200	11.6		3.3	27.7
300	18.2		6.7	37.7
400	22.0		10.0	44.8
500	25.9		13.3	52.0
600	30.0		16.7	59.5
700	37.0		20.0	69.8




Table 3.11: Approximate error range

Distance[cm]	Error[cm]
100	18.1
200	26.8
300	35.4
400	44.1
500	52.7
600	61.4
700	70.0

Fig. 3.45: Expected error in distance

## 第 4 章 複数障害物認識のための尤度空間の生成

前章において、全方位カメラと LiDAR を用いた距離精度の高い複数障害物の検出手法を解説した。RoboCup MSL では、2.4 節で述べたようにチーム内における環境情報の共有が許可されているため、フィールド上の各ロボットが得た障害物情報が共有される。本章では、複数の観測ロボットより得た複数障害物情報を統合し、次章で述べる複数障害物認識における最適化対象となる探索空間（尤度空間）を構成する方法について述べる。

### 4.1 障害物検出結果の統合とクラスタリング

Fig. 4.1 に複数のロボットより得た複数障害物の検出結果を処理する流れの例を示す。(a) は実際の配置を示しており、観測ロボット ①～③ の 3 台をそれぞれ赤、黄、青に色分けして表している。また、障害物である敵ロボットは E と書かれた 4 台であり、それぞれの形状を変えた黒色マークで表している。(b)～(d) は 3 台の観測ロボットが 3 章の手法により障害物検出したフィールド座標系における座標をプロットしており、ここでは説明のために元の障害物に相当する形状と観測ロボットの色で表している。前述したチームロボット間における情報共有によって (e) のように各観測ロボットから得た障害物情報が統合されるが、実際には全ての検出座標は Table 3.10 で示した誤差を含むため、一意的に障害物の座標を示さない。この状況において自チームロボットの自己位置に相当する情報を無視した上で図中 I～IV の点線の円のように点群から元の障害物の情報を障害物別にまとめ、真値を推定することでフィールド上の複数障害物認識が完了する。(e) では説明のために検出情報を形状別に表示しているが、実環境では (f) のようにどの検出座標がどの障害物を表したものは未知であり、混戦時にロボット間の距離が近い場合は誤差を含んだ座標情報が障害物同士で交差するため、得られた点群から真値を正しく推定することは容易ではない。




Fig. 4.1: Combination of obstacle detection results



点群データを何らかの特徴量に基づいてグループ分け(分類)する手法はクラスタリング<sup>41)~43)</sup>, またはクラスタ分析と呼ばれている. ユークリッド距離に基づくデンドログラムを用いる階層的クラスタリング分析や, 重心演算による k-means<sup>44),45)</sup>, データ密度による DBSCAN<sup>46)</sup>, 超球内の密度による Mean shift<sup>47)</sup>, マージン最大化による SVM<sup>48)</sup> などの非階層的クラスタ分析手法があるが, いずれの手法も点群を構成する各点の座標値そのものの評価や複数点データ間の関連性の評価を利用しており, その点情報取得時の環境情報(認識距離など)は考慮されない. さらに, 分類されたクラスタのプロトタイプは平均値や重心により表現される場合がほとんどであり, Fig. 4.1 (e) の点線の円Ⅲを例に挙げると, クラスタ内に含まれる点データにより推定される障害物の位置は, Fig. 4.2 のように真値とは異なる座標となってしまう. これは, 各検出点を検出座標情報のみで評価しており, 検出時の環境情報を考慮しないことに起因している. 検出時の環境情報とは, 検出座標に対する観測ロボットの距離や観測距離より推定される誤差情報である.




Fig. 4.2: Problems caused by clustering algorithms

## 4.2 尤度を用いた検出結果の統合

本研究では前節の問題に対し、検出点取得時の環境情報である観測距離と推定誤差を障害物識別に反映させることを目的として尤度による空間表現を試みる。本節では本研究で用いる尤度表現のための確率密度関数を検討する。

### 4.2.1 ガウス分布関数を用いた尤度表現

尤度とは尤もらしさを指標とした広がりを持つ分布で表され、Fig. 4.3のように基点を中心とした三次元の起伏で表現される。ここでの基点は、観測ロボットの検出した障害物の推定座標であり、クリスプ集合的な0/1の値しか持たない通常の単一点と異なり、基点との距離関係を用いたファジィ集合的な確率密度関数の値で構成される。

確率密度関数に一般的なガウス分布（正規分布）を用いた場合の分布の様子を Fig. 4.4 に示す。ここでは、極大値を1.0、半値半幅（半値幅の半分）を観測ロボットからの観測距離に応じた推定誤差  $\hat{e}$  (Table 3.11) としている。半値半幅は  $x$ - $y$  平面における半値幅を直径とする断面円の半径であり、検出点の推定誤差  $\hat{e}$  を用いることで障害物の存在範囲を尤度により表現している。また、複数の観測ロボットによる尤度が重なる場合、その尤度は単純加算で合算されるため、複数のロボットにより観測された障害物情報は高い尤度を示すことになる。




Fig. 4.3: Graph of likelihood space




Fig. 4.4: Representation of likelihood space

#### 4.2.2 ガウス分布による尤度表現の問題点

ガウス分布を用いた尤度について検証するために、問題を簡略化した二次元空間を考える。ここでのガウス分布の設定も、極大値 1.0、半値半幅を推定誤差  $\hat{e}$  としており、観測ロボットからの観測距離  $\hat{d}$  に応じて Fig. 4.5 のように起伏が変化する。尤度の合成について 2 つのガウス分布のパラメータを変化させ検証した結果を Fig. 4.6~4.12 に示す。各グラフ中における 2 つのガウス分布形状は等しく、Fig. 4.6 は観測距離  $\hat{d}$  に伴う推定誤差 (半値半幅)  $\hat{e}$  が  $(\hat{d}, \hat{e}) = (100, 18.1)$  であり、Fig. 4.7~4.12 はそれぞれ  $(\hat{d}, \hat{e}) = (200, 26.8) \sim (700, 70.0)$  である。2 つの分布の基点 (分布中心) 間の距離  $d_{12}$  は  $1.6\hat{e}$ ,  $1.8\hat{e}$ ,  $2.0\hat{e}$  の 3 パターンを検証しており、 $d_{12} = 2.0\hat{e}$  は 2 つのガウス分布が半値幅において交差する状態である。観測ロボットによる検出値が Table 3.11 の推定誤差に従う場合、2 台の観測ロボットの検出値間の距離  $2.0\hat{e}$  は、2 点が真値を中心として正反対の位置に最大推定誤差で存在することを意味しており、本研究手法において同一の障害物と認識すべき状況の中で最も  $d_{12}$  が大きい状態である。Fig. 4.6 を見ると、 $d_{12} = 1.6\hat{e}$  では 2 つの分布が合成され、基点間中心に極大値がある。これは左右 2 つの分布が同一、つまり観測距離  $\hat{d}$  とそれに伴う  $\hat{e}$  が等しい場合、どちらの観測点 (基点) も確からしさが等しいため、その中間点を最適な推定値である最適解として明示しており、合成された尤度分布として意図した通りとなっている。しかし、 $d_{12} = 1.8\hat{e}$ ,  $2.0\hat{e}$  では多峰性が現れており、それぞれ 2 つの基点が同値の極大値となっているため、どちらを最適解として選択した場合も片方の観測情報しか用いられず、意図した真値が得られない。Fig. 4.7~4.12 についても同様の結果となっている。




Fig. 4.5: Gaussian distribution graph shape by observation distance




Fig. 4.6: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (100, 18.1) \text{ cm}$




Fig. 4.7: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (200, 26.8) \text{ cm}$




Fig. 4.8: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (300, 35.4) \text{ cm}$




Fig. 4.9: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (400, 44.1) \text{ cm}$




Fig. 4.10: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (500, 52.7)$  cm




Fig. 4.11: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (600, 61.4)$  cm




Fig. 4.12: Gaussian distribution likelihood graph at  $(\hat{d}, \hat{e}) = (700, 70.0)$  cm

次に、2つの分布のパラメータ  $\hat{d}_1$ ,  $\hat{d}_2$  が異なる場合を検証した結果を Fig. 4.13~4.15 に示す、左の分布の観測距離  $\hat{d}_1$  と右の  $\hat{d}_2$ 、及びそれぞれによる推定誤差  $\hat{e}_1$ ,  $\hat{e}_2$  は図中に示しており、基点間距離  $d_{12}$  は前述の検証と同様になるように  $d_{12} = 0.8(\hat{e}_1 + \hat{e}_2)$ ,  $0.9(\hat{e}_1 + \hat{e}_2)$ ,  $1.0(\hat{e}_1 + \hat{e}_2)$  である。いずれの合成結果を見ても、最適値は観測距離が小さい  $\hat{d}_1$  側の分布基点とほぼ同一点となっており、多峰性を伴う場合もあることがわかる。

以上の検証結果より、尤度生成の確率密度関数として一般的なガウス分布を用いた場合、同一かつ近い観測距離という特定条件以外では、合成結果は得られた情報を有効に活用できず、確からしい最適解を有する尤度空間を生成できないことがわかる。




Fig. 4.13: Likelihood graph at  $(\hat{d}_1, \hat{e}_1) = (200, 26.8)$  cm,  $(\hat{d}_2, \hat{e}_2) = (400, 44.1)$  cm




Fig. 4.14: Likelihood graph at  $(\hat{d}_1, \hat{e}_1) = (400, 44.1)$  cm,  $(\hat{d}_2, \hat{e}_2) = (600, 61.4)$  cm




Fig. 4.15: Likelihood graph at  $(\hat{d}_1, \hat{e}_1) = (200, 26.8)$  cm,  $(\hat{d}_2, \hat{e}_2) = (600, 61.4)$  cm

### 4.2.3 フェルミ分布関数を用いた尤度表現

前節において検証したガウス分布による問題点の解決策として本研究ではフェルミ・ディラック分布関数（以降、フェルミ分布）の尤度表現への導入を提案する。フェルミ分布は半導体における物質中の電子の存在確率とエネルギー準位  $E$  の関係を表す分布関数であり、フェルミ準位  $E_f$  と温度係数  $\beta$  を用いて次式で表される。

$$f(E) = \frac{1}{1 + \exp^{(E-E_f)/\beta}} \quad (4.1)$$

Fig. 4.16 に 4.1 式により得られる分布形状を示す。フェルミ準位  $E_f$  とは電子の存在確率  $f(E)$  が 0.5 (50%) となる境界値であり、フェルミ分布はフェルミ準位を境界として点対称となる。分布形状は温度係数  $\beta$  に依存し、低温時 ( $\beta$  が小) は低エネルギー準位における存在確率が高くなり、高温時 ( $\beta$  が大) は高エネルギー準位にまで存在確率分布が広がる特徴を持つ。温度に依存する分布の形状変化は、本研究における障害物の検出環境に依存する形状変化と親和性が高く、フェルミ準位を境界とする点対称特性は尤度合成においてより真値に近い最適解を得るために都合が良いため、本研究では尤度の確率分布関数としてフェルミ分布を採用する。ここでは、エネルギー準位  $E$  は位置  $x$  となり、フェルミ準位  $E_f$  は観測ロボットからの観測距離  $\hat{d}$  により得られる推定誤差  $\hat{e}$  として置き換えられる。これらの関係性により 4.1 式は本研究における尤度関数として次式のように再定義される。

$$f(x) = \frac{1}{1 + \exp^{(x-\hat{e})/\beta}} \quad (4.2)$$




Fig. 4.16: Fermi distribution function



4.2 式により得られる分布形状の例を Fig. 4.17 に示す。観測距離  $\hat{d}$  が小さい時、つまり観測ロボットが近くの障害物を検出している時は、半値半幅となる推定誤差  $\hat{e}$  は小さく、確からしさも高いことから、基点を頂点として高確率領域が狭い範囲で限定的となる山形状となる。逆に  $\hat{d}$  が大きい時は、遠方の検出であるため  $\hat{e}$  は大きく、確からしさの低さを表す広範囲な高確率領域を持つ台地形状となっている。ここで、温度係数  $\beta$  は最近接距離時の極大値と最大検出距離時の分布形状から事前実験により決定した。

#### 4.2.4 フェルミ分布による尤度表現の検証

フェルミ分布を用いた尤度について検証するために、4.2.2 節と同様に二次元空間を考える。前節で解説した Fig. 4.17 のフェルミ分布を 2 つ使い、4.2.2 節と同様に分布パラメータを変化させて検証した結果を Fig. 4.18~4.24 に示す。各グラフにおける 2 つの分布形状は等しく、基点間距離  $d_{12}$  は  $1.6\hat{e}$ ,  $1.8\hat{e}$ ,  $2.0\hat{e}$  で検証した。Fig. 4.18~4.24 を見ると、全てのパターンにおいて 2 つの分布は合成され、基点間中心に極大値がある。また、 $d_{12} = 2.0\hat{e}$  の結果を見ると、基点間は極大値を持つ直線で接続されているが、左右の分布が示す尤度が同一（同観測距離）かつ最大推定誤差で正反対の位置の状態である境界条件の尤度としては一意的な極大値が存在しないのは妥当である。Fig. 4.25 に示すように、この境界状態より少しでも基点間距離が広がった場合は、2 台の障害物が隣接している状態として 2 つの等しい極大値で尤度が表現される。




Fig. 4.17: Fermi distribution graph shape by observation distance




Fig. 4.18: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (100, 18.1)$  cm




Fig. 4.19: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (200, 26.8)$  cm




Fig. 4.20: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (300, 35.4)$  cm




Fig. 4.21: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (400, 44.1)$  cm




Fig. 4.22: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (500, 52.7) \text{ cm}$




Fig. 4.23: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (600, 61.4) \text{ cm}$




Fig. 4.24: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (700, 70.0) \text{ cm}$




Fig. 4.25: Fermi distribution likelihood graph at  $(\hat{d}, \hat{e}) = (400, 44.1) \text{ cm}$

次に、2つの分布パラメータ  $\hat{d}_1$ ,  $\hat{d}_2$  が異なる場合を検証した結果を Fig. 4.26~4.28 に示す。こ  
こでも、 $d_{12} = 0.8(\hat{e}_1 + \hat{e}_2)$ ,  $0.9(\hat{e}_1 + \hat{e}_2)$ ,  $1.0(\hat{e}_1 + \hat{e}_2)$  である。いずれの結果を見ても、ガウス分布  
と異なり、極大値は基点間に位置しており、観測距離  $\hat{d}_1$ ,  $\hat{d}_2$  の確からしさに比例した妥当な位置  
となっている。ただし、合成した尤度空間はガウス分布と同様に多峰性を有する場合がある点に  
注意が必要である。

以上の結果より、尤度生成の確率密度関数としてフェルミ分布を用いた場合、多峰性を有する  
場合があるものの、全ての状況において妥当な極大値を示すことができ、合成結果は本研究課題  
に対して有効であることが確認できた。




Fig. 4.26: Fermi distribution likelihood graph at  $(\hat{d}_1, \hat{e}_1) = (200, 26.8)$  cm,  $(\hat{d}_2, \hat{e}_2) = (600, 61.4)$  cm




Fig. 4.27: Fermi distribution likelihood graph at  $(\hat{d}_1, \hat{e}_1) = (200, 26.8)$  cm,  $(\hat{d}_2, \hat{e}_2) = (400, 44.1)$  cm




Fig. 4.28: Fermi distribution likelihood graph at  $(\hat{d}_1, \hat{e}_1) = (400, 44.1)$  cm,  $(\hat{d}_2, \hat{e}_2) = (600, 61.4)$  cm

#### 4.2.5 多数の観測ロボットから生成した尤度空間の検証

前節では2台の観測ロボットによるフェルミ分布関数を用いた尤度空間を検証し、有用性を確認した。本節では、さらに多数（3～5台）の観測ロボットの取得情報により生成された尤度空間について検証する。

Fig. 4.29～4.31 に観測ロボットが3～5台で全て等観測距離の場合の結果を示す。被観測ロボットの座標（真値）はセンターサークル中心（フィールド座標系で原点  $(0, 0)$ ）であり、観測距離  $\hat{e}$  は全ての観測ロボットで  $0.8\hat{e}$ （具体的な各数値は図中に記載）としている。各図において (a) は各観測ロボットより得た検出座標を水色の丸、被観測ロボットを紫色の四角形として表しており、(b) はフェルミ分布を用いて合成した尤度空間と極大値の座標、(c) は等高線の様子、(d) は合成前の各半値幅円（点線）を (c) の等高線に重ねた様子である。各結果を見ると、半値幅円の合成中心にある真値（原点）に対して、(b) のフェルミ分布による合成結果の極大値が一致していることがわかる。

次に、観測距離が等距離ではない場合の検証結果を Fig. 4.32～4.40 に示す。Fig. 4.32～4.34 は3台の観測ロボットの場合であり、Fig. 4.35～4.37, Fig. 4.38～4.40 はそれぞれ4台、5台の場合である。いずれの結果でも、合成した分布の極大値が真値  $(0, 0)$  と一致しており、提案したフェルミ分布関数を用いた尤度空間の生成法は観測ロボットの数に依存することなく有効であることが確認できた。

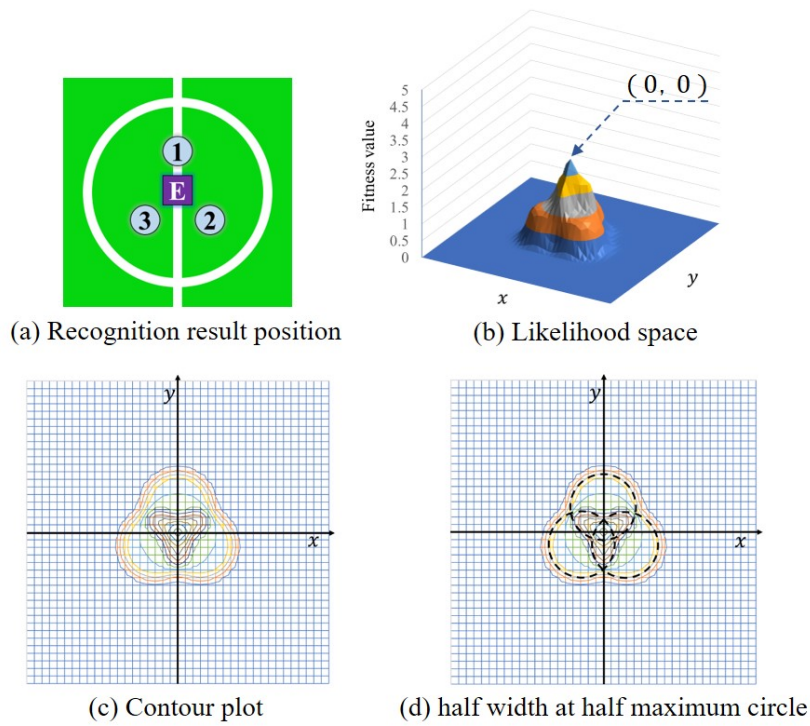


Fig. 4.29: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (400, 35.2) \text{ cm}$

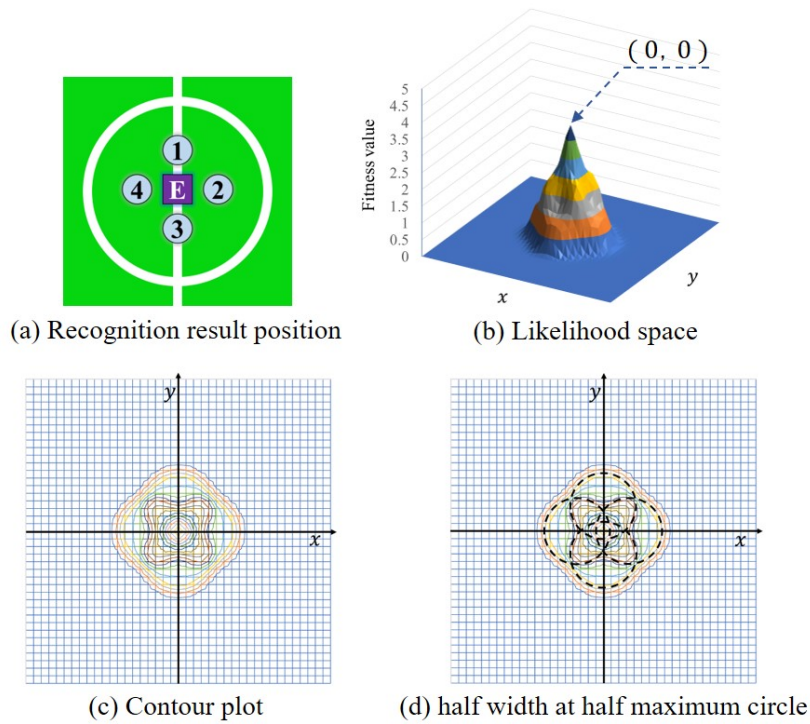


Fig. 4.30: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (400, 35.2) \text{ cm}$

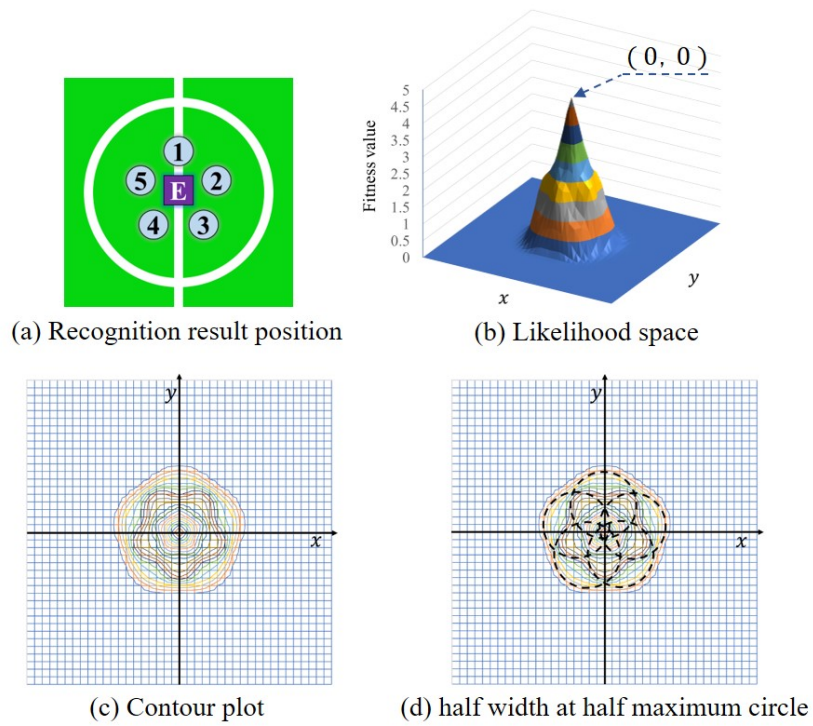


Fig. 4.31: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_5, \hat{e}_5) = (400, 35.2) \text{ cm}$

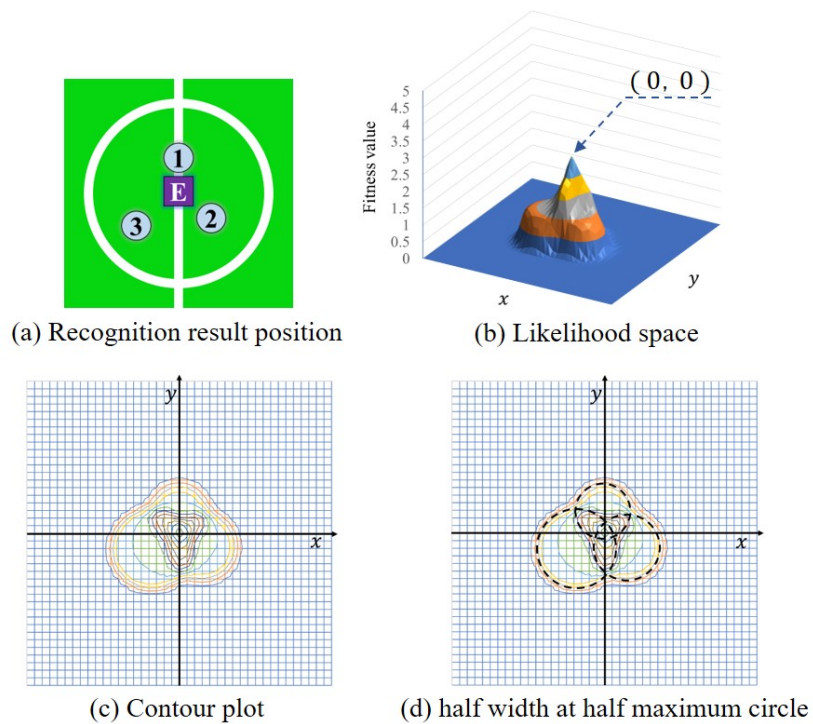


Fig. 4.32: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (300, 28.3) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (500, 42.2) \text{ cm}$

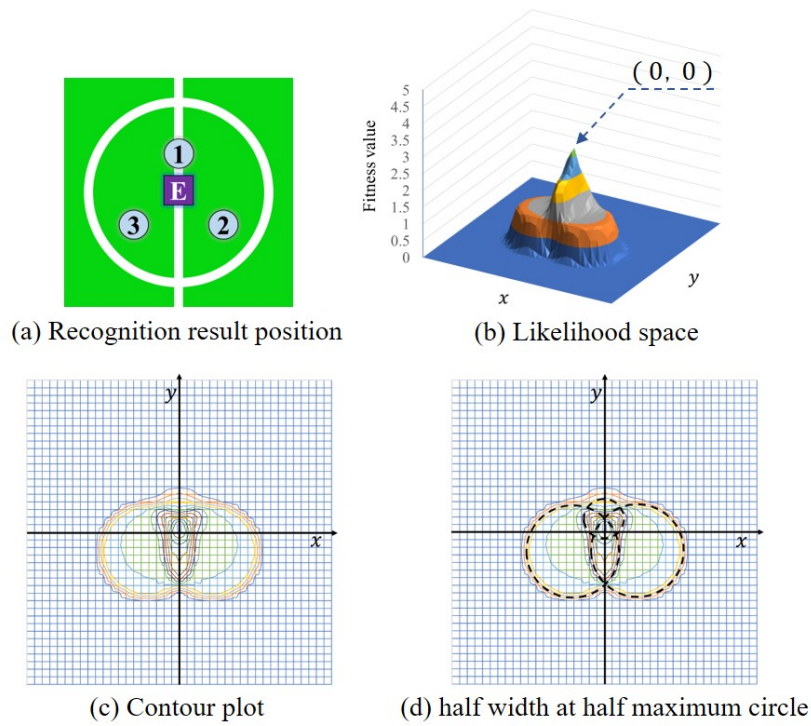


Fig. 4.33: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (200, 21.4) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (600, 49.1) \text{ cm}$

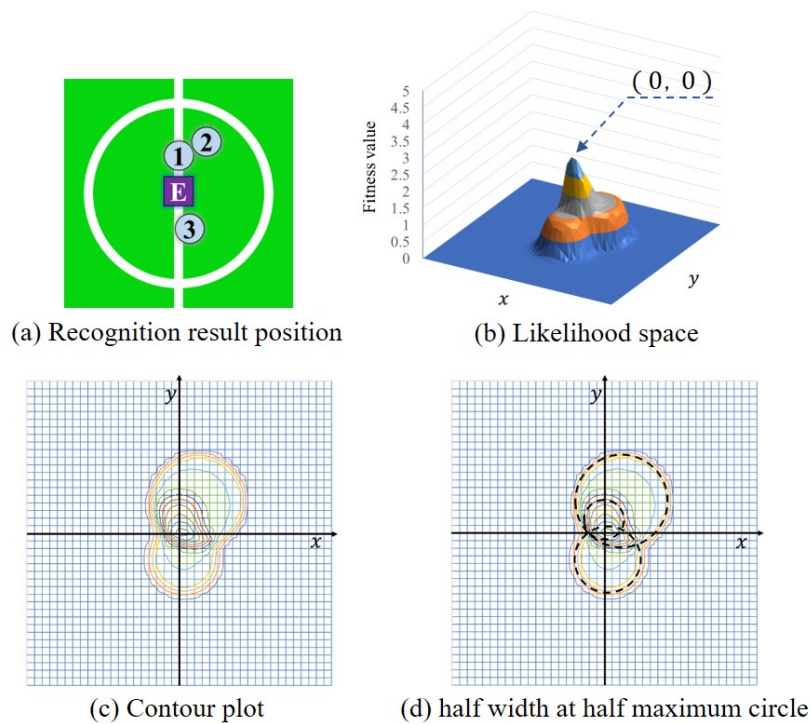


Fig. 4.34: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (200, 21.4) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (400, 35.2) \text{ cm}$



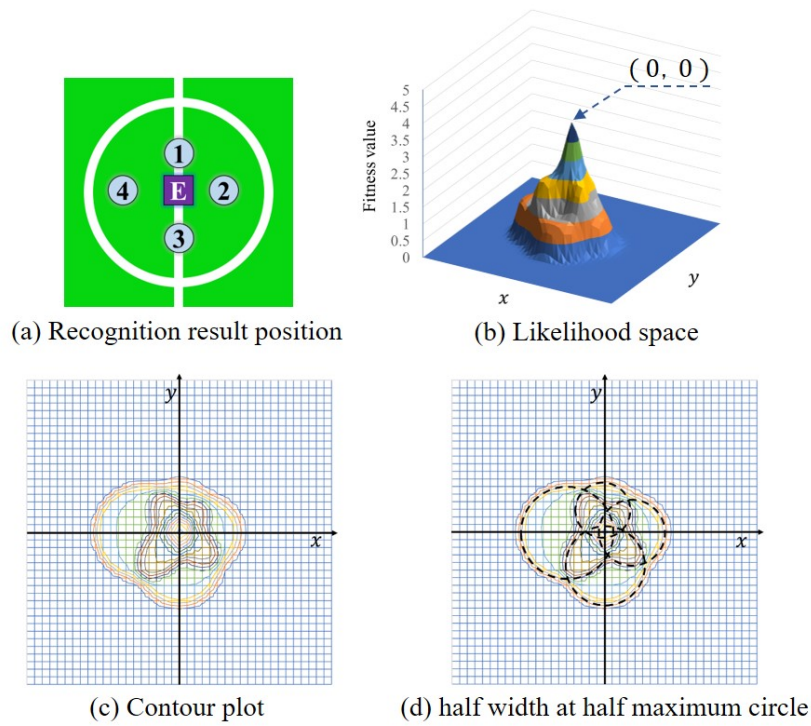


Fig. 4.35: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (300, 28.3) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (500, 42.2) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (600, 49.1) \text{ cm}$

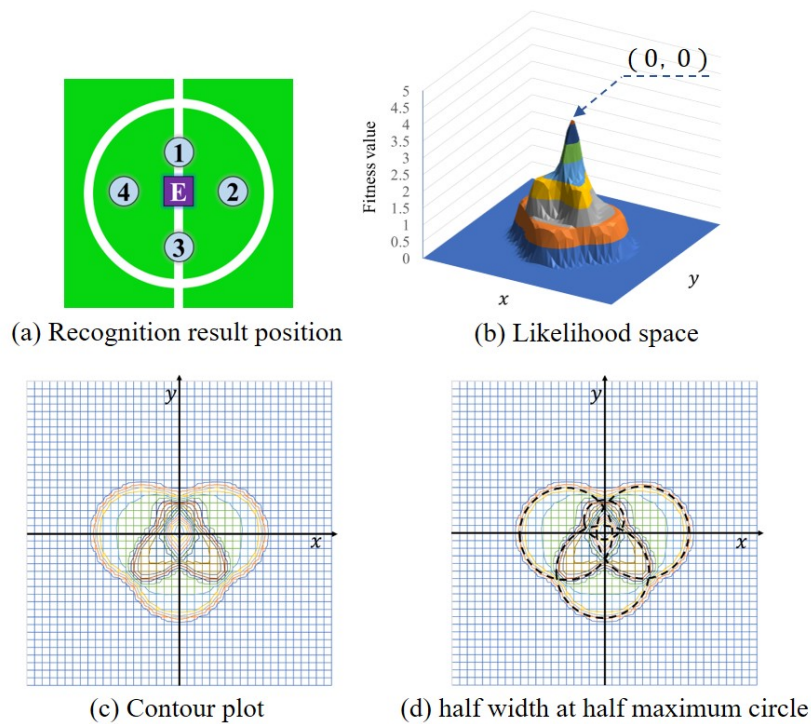


Fig. 4.36: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (200, 21.4) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (600, 49.1) \text{ cm}$

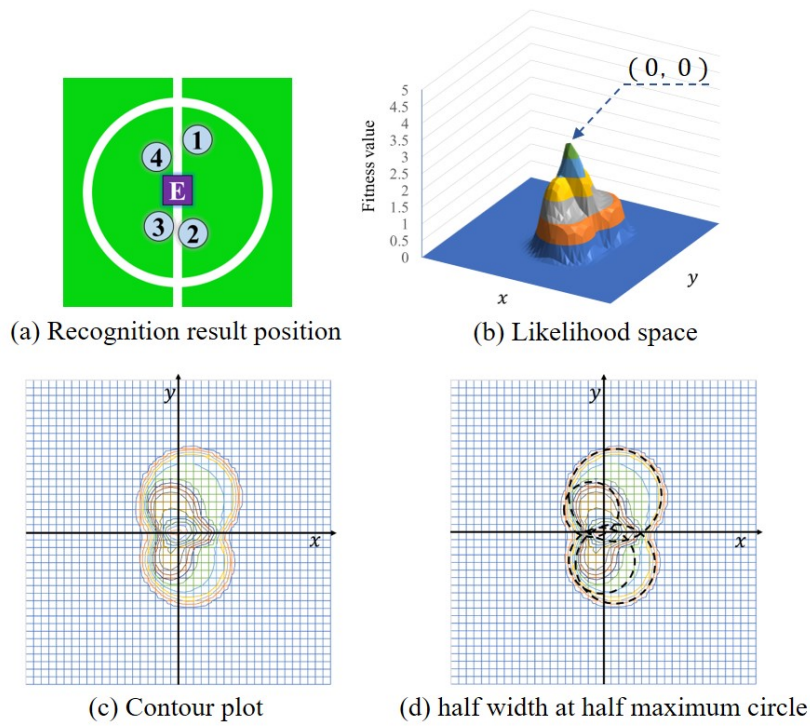


Fig. 4.37: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (500, 42.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (300, 28.3) \text{ cm}$

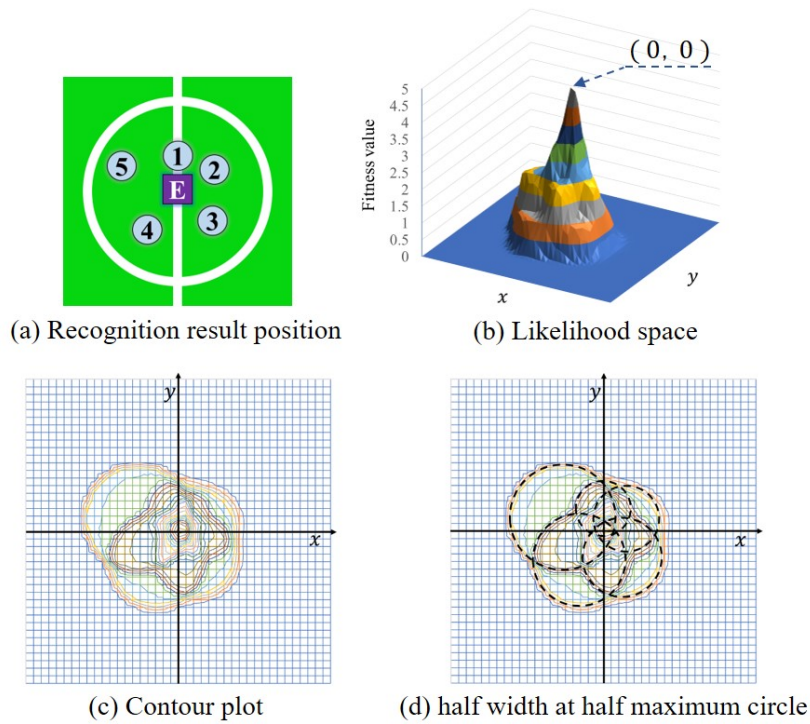


Fig. 4.38: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (300, 28.3) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (500, 42.2) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_5, \hat{e}_5) = (700, 56.0) \text{ cm}$

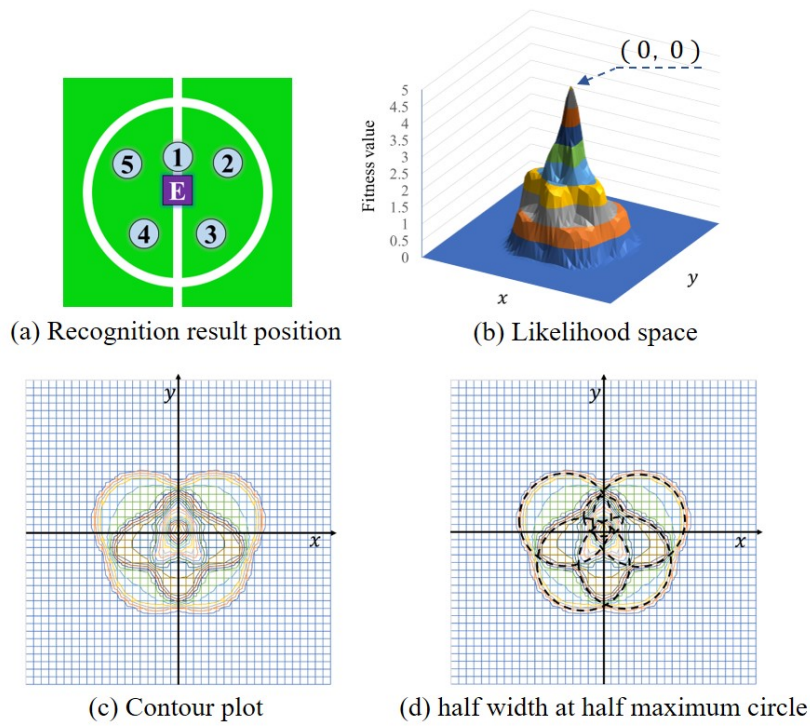


Fig. 4.39: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (200, 21.4) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_5, \hat{e}_5) = (600, 49.1) \text{ cm}$

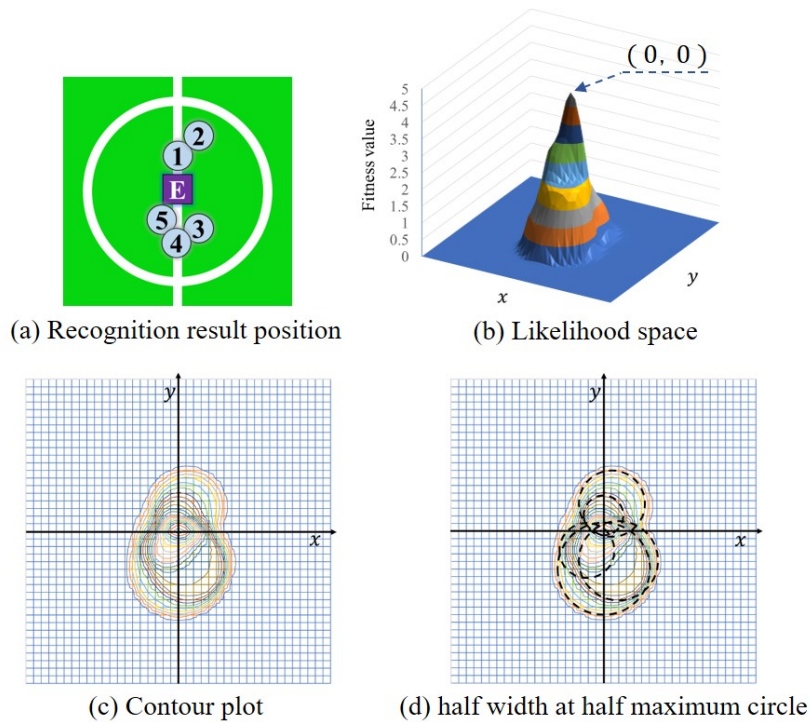


Fig. 4.40: Likelihood graph at  $0.8\hat{e}$ :  $(\hat{d}_1, \hat{e}_1) = (200, 21.4) \text{ cm}$ ,  $(\hat{d}_2, \hat{e}_2) = (400, 35.2) \text{ cm}$ ,  $(\hat{d}_3, \hat{e}_3) = (500, 42.2) \text{ cm}$ ,  $(\hat{d}_4, \hat{e}_4) = (600, 49.1) \text{ cm}$ ,  $(\hat{d}_5, \hat{e}_5) = (300, 28.3) \text{ cm}$

### 4.3 フェルミ分布による尤度表現の精度検証

前節の検証において、フェルミ分布を用いた尤度空間生成法は正しく真値に極大値を生成できることを確認したが、観測状況によっては真値近辺に同値の領域が生成されることに起因して、ある程度の誤差が発生することは避けられない。ここでは、様々なシチュエーションにおける本尤度生成手法の精度について検証する。

#### 4.3.1 シミュレーションによる精度検証

Fig. 4.41 に精度検証に用いるシミュレーション環境を示す。探索空間であるフィールドのサイズは  $1400 \times 2200 \text{ cm}$  であり、縦横  $10 \times 10 \text{ cm}$  の分解能セルで構成されている。被観測ロボットはフィールド中央のセンターサークル中心に配置され、観測ロボットは1〜5台がランダムに選択され、それぞれがフィールド内のランダムな座標に配置される。その状況において尤度空間を生成し、全探索法により得た合成尤度の極大値と真値の誤差を取得する。本試行を 100000 回行った結果、平均誤差は  $8.6 \text{ cm}$ 、最大誤差は  $63.2 \text{ cm}$  であった。ここでは、ランダム配置した観測ロボット全てが被観測ロボットを観測できない場合、つまり尤度空間が生成できない場合は除外している。

本検証結果より、得られた誤差はサッカー競技における実用範囲内であり、提案した尤度空間生成法は実用性を備えていることが確認できた。




Fig. 4.41: Simulation environment

### 4.3.2 観測ロボット数による精度の検証

前節における検証結果を観測ロボット数別に分類し、Table 4.1 に示す。観測ロボットが1台の場合、遠方では一意的に最適解が求まらないため、誤差が大きいことが明らかである。観測ロボット数の増加により誤差が小さくなっているが、これは情報量の増加に伴って最適解の領域が限定的になることに起因している。提案したフェルミ分布を用いた尤度空間生成法は、得られた情報を有効に活用しており、情報量の増加により精度も高くなることがわかる。これは、競技中に各ロボットがなるべく敵ロボットを多く検出できるように行動することでフィールド全体の環境把握能力が向上することを意味しており、本研究の後に続く複数ロボット間の協調行動戦略における1つの重要な指標となる可能性がある。

Table 4.1: The error caused by the number of robots

Number of robots	Average error [ <i>cm</i> ]	Maximum error[ <i>cm</i> ]
5	6.7	40.0
4	8.0	53.9
3	9.8	50.0
2	12.8	58.3
1	17.5	63.2

## 4.4 複数障害物に対する尤度空間の生成

ここまでの検証ではフェルミ分布を用いた尤度空間生成法の基本的な性能を検証・評価するため、被観測ロボットを1台に限定していた。ここでは、実用上の検証として被観測ロボットが複数（複数障害物）の場合を検証する。

### 4.4.1 複数の被観測ロボットにおける干渉の検証

Fig. 4.42 は本章冒頭で示した Fig. 4.1 (e) からセンターサークル付近を抜粋した Fig. 4.2 のシチュエーションであり、2台の被観測ロボットに対して3台のロボットが観測している状態である。複数の被観測ロボットの真値が近い場合、それぞれに対する複数の観測ロボットの観測結果は独立ではなく、Fig. 4.42 に示す例のように相互に干渉する場合がある。Fig. 4.42 のシチュエーションに対して提案手法を用いて生成した尤度空間は Fig. 4.43 のようになり、その等高線の場合と、等高線に各検出点の半値幅円を重ねた図を Fig. 4.44 に示す。前節までの検証において明らかであるように、他の被観測ロボットの観測結果が干渉しても、各半値幅円の重なる真値近くに極大値が生成されるため大きな影響は受けず、Fig. 4.43 の図中に示したように正しくそれぞれの被観測ロボットの真値に相当する位置に極大値が生成されていることがわかる。このように本提案手法は、各検出点に対応する本来の被観測ロボットの真値推定のための尤度生成を補助しつつ、一方で近くの異なる被観測対象の尤度生成において大きな影響を与えないという特徴を持っており、複数障害物に対する探索空間としての尤度空間の生成において有用である。

### 4.4.2 実際の競技における尤度空間

本章最後の検証として、実際の RoboCup MSL 競技を想定した実戦環境における尤度空間を検証する。実際の競技では、Fig. 4.45 に示すように自チーム観測ロボット5台、敵チーム被観測ロボット5台が存在する空間となる。フィールドサイズが大きく、各チームが戦略的に効率良くポジショニングするため、各チームの自陣エリア深くに位置するロボット（DF：ディフェンダーや GK：ゴールキーパーなど）は観測されない場面も多く発生する。Fig. 4.45 の実戦環境において提案手法により尤度化した空間を Fig. 4.46 に示す。これらは自チームロボットを含むため、各ロボットから得られる自己位置情報を用いて相当する尤度を除去した後の最終的な尤度空間は Fig. 4.47 となる。提案したフェルミ分布を用いた尤度空間生成法により複数の障害物（敵ロボット）は

それぞれ正しく尤度化され、その真値は極大値として表されるが、各極大値の持つ値は全て異なり、4.2.4節でも述べたように場面によっては多峰性も有する点に注意が必要である。


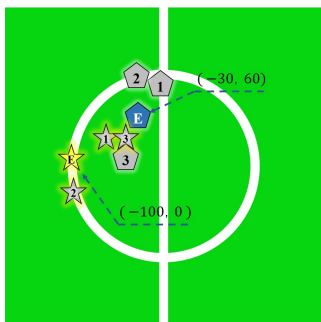


Fig. 4.42: Recognition result of Fig. 4.2

Fig. 4.43: Likelihood space of Fig. 4.2





Fig. 4.44: Contour plot and half width at half maximum circle of Fig. 4.2

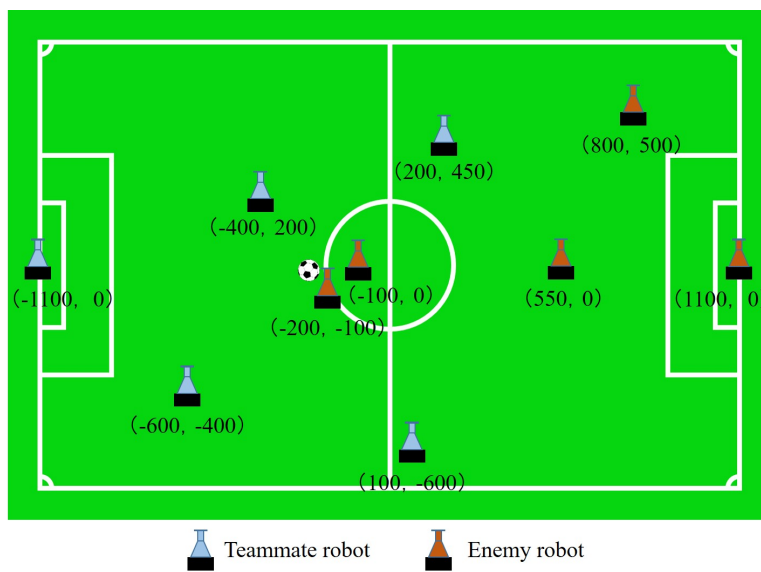


Fig. 4.45: Robot position in real game




Fig. 4.46: Likelihood space of real game




Fig. 4.47: Obstacle likelihood space



## 第 5 章 Hybrid GA を用いた複数障害物の実時間認識

ここまでの処理により，RoboCup MSL における複数障害物の位置情報を合成尤度空間内で適切に表現することが可能になった．本章では，合成された尤度空間より実時間で複数障害物を認識する手法について提案と解説，検証を行う．

本章ではまず，本研究における複数障害物認識の持つ技術的な意味とその問題点を述べ，その解決策として人間の視覚システムにヒントを得て工学的に実現した認識手法を解説する．構築した手法について，標準試験関数を用いた多峰性に対する基礎的な性能を検証し，さらに実時間性に対する検証を行った後，最終的な検証として実戦環境への適用を試みる．

### 5.1 複数障害物認識における問題点

前章までに，全方位カメラと LiDAR により検出した各観測ロボットの障害物情報をフェルミ分布を用いて統合し，フィールド内の複数障害物の座標を合成尤度空間の複数極大値として表現できる手法を構築した．これは，フィールド上の複数障害物を認識する問題が，合成尤度空間を探索空間とする複数極大値の探索問題，つまり最適化問題として置き換えられたことを意味しており，この最適化問題を解くことができれば本研究課題の目的が達成される．しかし，前章でも述べたように，合成尤度空間による探索空間は複数の極大値を持つ大域的多峰性空間であり，さらに各極大値の値が異なる特徴を有しているため，全探索法を筆頭に様々な探索法で解を得ることは非常に困難である．加えて，特定の障害物を表す尤度の起伏においても，場合によって 4.2 節で述べたように多峰性が発生することがわかっており，この局所的多峰性が探索問題をより難解にしている．さらに，RoboCup MSL の競技における利用を考慮すると，これらの処理全てを実時間<sup>52)</sup>で処理する必要がある．

つまり，本研究課題の解決には，大域的多峰性と同時に局所的多峰性を有する探索空間より，実時間で最適な複数極大値の組合せを発見することができる最適化手法が求められる．

## 5.2 人間の注意機構

### 5.2.1 視覚的注意

ここで、人間の視覚システムに目を向けてみる。人間の視覚情報処理システムは、取り巻く情報全てを処理するだけの能力を持ち合わせていないにも関わらず、時々刻々と変化する環境下においても複数対象の認識をいとも簡単に行っている。例えば、人間であれば本研究の最適化課題の一例である Fig. 4.47 より障害物に相当する複数の座標を瞬時に認識できることが明らかである。これは人間の視覚システムが非常に効率良く情報を取捨選択して処理量を低減する“注意”<sup>53)~60)</sup>と呼ばれる機能を持っていることに起因する。“注意”には、カクテルパーティ効果に代表されるような聴覚的注意、触覚的注意など様々な注意があるが、本研究で述べているのは視覚的注意であり、これは普段我々が「注意を払う」、「注意を引く」など使っている注意のことである。

### 5.2.2 受動注意と能動注意

近年、視覚的注意が2つの異なる特徴を持つ成分により構成されていることが報告されている<sup>56)</sup>。ひとつは内発的成分と呼ばれ、人間が意図的に注意を引かれる刺激駆動的な成分である。より簡単に言えば、Fig. 5.1 (a) のように人が対象物 (図中では黄色の星印を付けた歩行者) を認識する場合、意識的にその対象物近辺の狭い範囲に注意を向ける。しかし同時に、(b) のような視野の端に突然出現した物体 (図中では赤い星印を付けた走り寄ってくる人間) に無意識に気付くことができる。このように人間は注意深く狭い範囲を見ながらにして広い範囲も同時にある程度注意を払うことができる。これは注意密度が空間選択的に効率良く分布しているためである。本研究では用語を扱いやすくするために、文献<sup>56)</sup>の呼称に従い、前者の深く狭い範囲の内発的注意を“能動注意”，後者の浅く広範囲な外発的注意を“受動注意”と呼ぶ。

同様のシチュエーションを RoboCup MSL に置き換えた図を Fig. 5.2 に示す。(a) のようにすでに認識済の複数障害物に継続的に注意を向けつつ、(b) のように新規に認識範囲内に出現した障害物にも気付くことができる必要がある。前述の受動・能動注意の密度分布をヒントとして工学的に最適化手法として構築することで、効率良く適切に複数障害物を認識するシステムの実現を目指す。

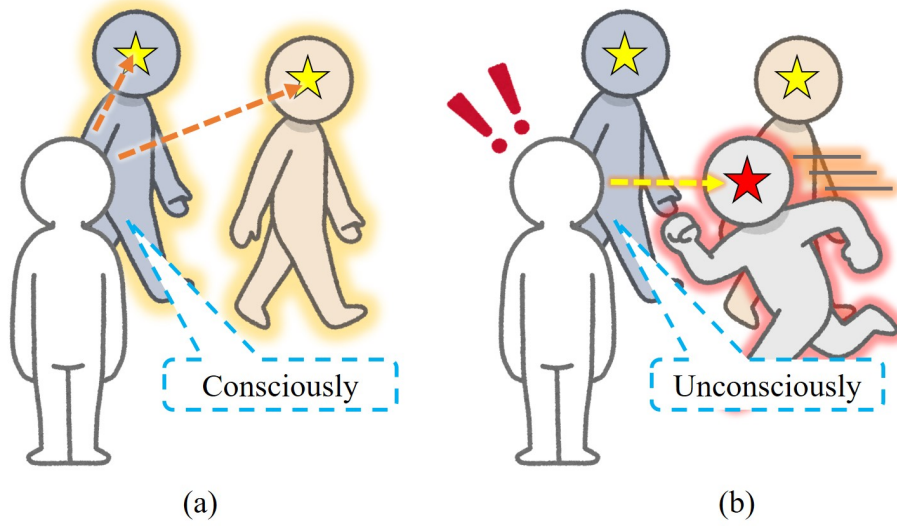


Fig. 5.1: Two types of human visual attention




Fig. 5.2: Two types of human visual attention (RoboCup situation)

### 5.3 視覚的注意に着想した最適化手法の工学的実現

本研究では、人間の非常に効率的な視覚的注意のシステムをヒントとして適切に複数障害物を認識する手法を構築する。具体的には、広視野低密度な受動注意と、狭視野高密度な能動注意にそれぞれ適した二つの最適化手法を採用し、効率良く連動させる Hybrid 型最適化手法を構築する。

#### 5.3.1 受動注意 (広視野低密度探索) の工学的実現

受動注意の役割は探索空間全体への低密度な監視による新しい対象物出現の検知である。一様な注意が空間全体に対して必要であるため本研究では Monte Carlo 探索法を適用する。Monte Carlo 探索法とは、空間上のいくつかの点を無作為に選択し、その選択された点のみに評価を行い最適解とする発見的最適化手法である。後に述べる能動注意における探索を考慮し、1つの探索点は Fig. 5.3(a) に示す 2 値パラメータを持った探索個体により表され、探索空間上のある 1 点の座標を情報として持っている。各探索個体は自身の持つ探索座標情報  $\phi = (\underline{x}, \underline{y})$  を用い、Fig. 5.3(b) のように探索空間上の該当座標における尤度  $F(\phi)$  を評価値として得る。本手法では、1 回の処理周期で  $P_r$  個の探索個体が探索空間全体に対し Monte Carlo 探索法に従って生成される。 $F(\phi)$  を事前設定したしきい値と比較することにより、次回の処理周期において能動注意の候補点とするか否かの判断を行う。

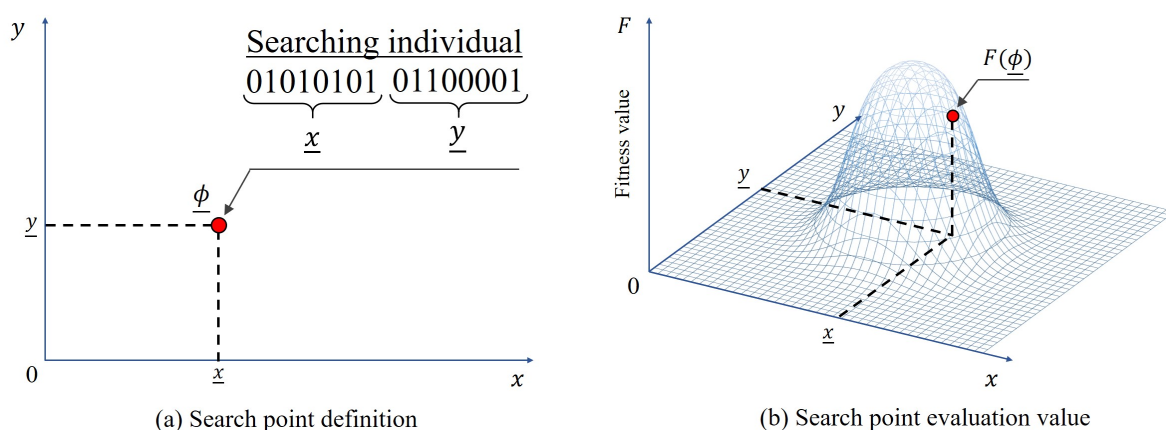


Fig. 5.3: Information about data instance for search

### 5.3.2 能動注意 (狭視野高密度探索) の工学的実現

能動注意は前述した受動注意の結果に基づき意図的に範囲が設定される. Fig. 5.4 のように受動注意における初期の探索範囲は探索領域  $\Omega$  を用いて

$$\Gamma_0 = \left\{ \underline{\phi} = (\underline{x}, \underline{y}) \in R^2 \mid \underline{\phi} \in \Omega \right\} \quad (5.1)$$

と表される. 受動注意による  $\Gamma_0$  の探索において, 尤度があるしきい値を超えたとき, その中心座標  $\underline{\phi}_1 = (\underline{x}_1, \underline{y}_1)$  を候補点と呼び, この時, 能動注意の範囲は, Fig. 5.4(b) のように候補点を中心とする円領域  $G_1$  により設定される.  $G_1$  は次式で定義される.

$$G_1 = \left\{ \underline{p} = (\underline{x}, \underline{y}) \in R^2 \mid r = |\underline{r}| = |\underline{p} - \underline{\phi}_1| \leq D_g/2 \right\} \quad (5.2)$$

ここで  $D_g$  は能動注意のサイズを与える定数であり, 円領域  $G_1$  の直径である. これにより, 次の処理における探索範囲  $\Gamma_1$  は,

$$\Gamma_1 = \Gamma_0 \cap \overline{G_1} \quad (5.3)$$

となる. 今, 時刻  $i$  において能動注意が  $n$  個存在していた場合, その時刻における探索範囲  $\Gamma_i$  は,

$$\Gamma_i = \Gamma_0 \cap \left( \bigcup_{j=0}^n \overline{G_j} \right) \quad (5.4)$$

となり, その時, 探索空間より対象物の位置  $\phi_p$  を探索する問題は,

$$\begin{aligned} & \text{find } \underline{\phi} \text{ to maximize } F(\underline{\phi}) \\ & \text{subject to } \underline{\phi} \in \Gamma_i \end{aligned} \quad (5.5)$$

と表される.




Fig. 5.4: Definition of search space

### 5.3.3 注意密度分布

能動注意の役割は、候補点をより詳しく探索することである。受動注意—能動注意間の処理概要を Fig. 5.5 に示す。今、2つの対象物が探索範囲内に存在し、大体の位置が受動注意により (a) のように検出されたと想定する。この時、2つの局所範囲に対する能動注意が次の処理周期で行われる。その際、能動注意のサイズは  $D_g$  で定義され、Fig. 5.5(b) のようにより正確な対象の位置を検出するためにその範囲内で詳しく探索が行われる。つまりこの場合の注意密度の分布は (c) のようになる。対象物存在の可能性が高い領域に能動注意が働いている間も新しい対象物を発見するための受動注意が働いている。この2種類の探索が探索空間に対して行われ、状況に応じて注意密度が変化する。また、設定された能動注意は後に説明する条件により消滅するまで存在し、詳しい探索を繰り返す。

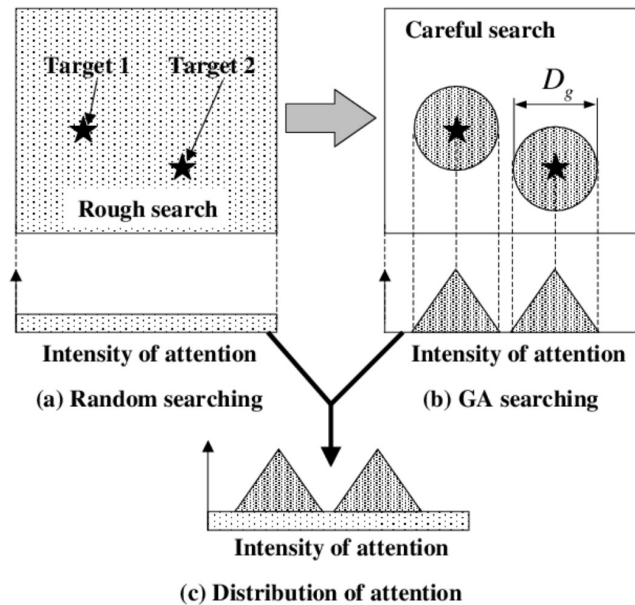


Fig. 5.5: Conceptual diagram of search method

### 5.3.4 遺伝的アルゴリズムによる能動注意の実現

能動注意では探索範囲を制限して詳しい探索を行うため、局所的最適化問題を取扱うことになる。5.1節で述べたように、局所的空間においても局所的多峰性と実時間性に対する解決策が求められるため、単純な手法では能動注意を工学的に実現することは難しい。そこで、本研究では、能動注意における最適化手法として遺伝的アルゴリズム（以降、GA）を採用する。GAとは、生物の進化と遺伝にヒントを得た最適化アルゴリズムの1つである<sup>66)~71)</sup>。最適化アルゴリズムは、Fig. 5.6に示すように一般的に系統的探索と発見的探索に大別される<sup>85),86)</sup>。系統的探索法に代表されるものとして、最急降下法、勾配法やニュートン法等があり、これらは探索空間を単一の点の評価の連続として最適解を探索する。そのため、本研究での探索空間  $F(\phi)$  に見られるような多峰性に弱く、局所解に陥り易い。一方、Monte Carlo法に代表される発見的探索法は、局所解に陥ることはないが、乱数に従って探索を行うため短時間では最適解が発見されない可能性がある。これらに対し、GAは系統的・発見的探索手法であり、その処理は遺伝子の進化と世代交代により構成される。GAは探索空間における解を遺伝子（パラメータ）として有する個体の集合を持ち、この集合を世代交代させることで最適解探索を行う。ここで、進化処理は選択、交叉、突然変異により構成され、選択・交叉により系統的探索を、突然変異により発見的探索を実現する。

このような集合の持つ複数の遺伝子で表される複数の点の評価に基づいて最適化を行うGAの探索効率は高く、その原理はSchemataを用いて説明されるImplicit Parallelismと呼ばれる概念により説明される<sup>69)</sup>。Fig. 5.7にGAによる局所空間最適化の様子を示す。最初、Fig. 5.7(a)のように第一世代として空間内にランダムに個体群がばらまかれ、各個体はFig. 5.3(a)に示した受動注意における探索個体同様に位置情報を持っている。各個体は自分の位置情報を用いて尤度を評価し、その値の優劣により進化処理が行われ、世代交代による次世代の集合が構成される。このとき、次世代の集合はFig. 5.7(b)のように前世代において適合度が高かった位置、つまり対象物




Fig. 5.6: Optimization algorithm

を表す適合度関数の最大値近辺に向かって近づく．この処理（世代交代）を繰り返すことにより，Fig. 5.7(d) のように GA は最終的に対象物の位置を表す最適解を発見する．

Fig. 5.8 に各個体の位置情報から得た尤度  $F(\phi)$  を用いて次世代の個体群を生成する様子を示す． $n$  世代における  $i$  番目の個体  $\phi_i^n = [x_i^n, y_i^n]$  は尤度  $F_i^n$  により評価され，選択・交叉・突然変異を経て  $n+1$  世代の遺伝子  $\phi_i^{n+1}$  が決定される．ここではグレイ・コーディングによるエリート保存戦略<sup>68)</sup>を採用する．グレイ・コーディングとは，2進化した遺伝子に対して変換を行い，10進数に2において隣り合う数値のハミング距離が1になるようにコード化したものであり，エリート保存戦略とは，各世代の最良解を交叉も突然変異も行わず次世代に残す手法である．

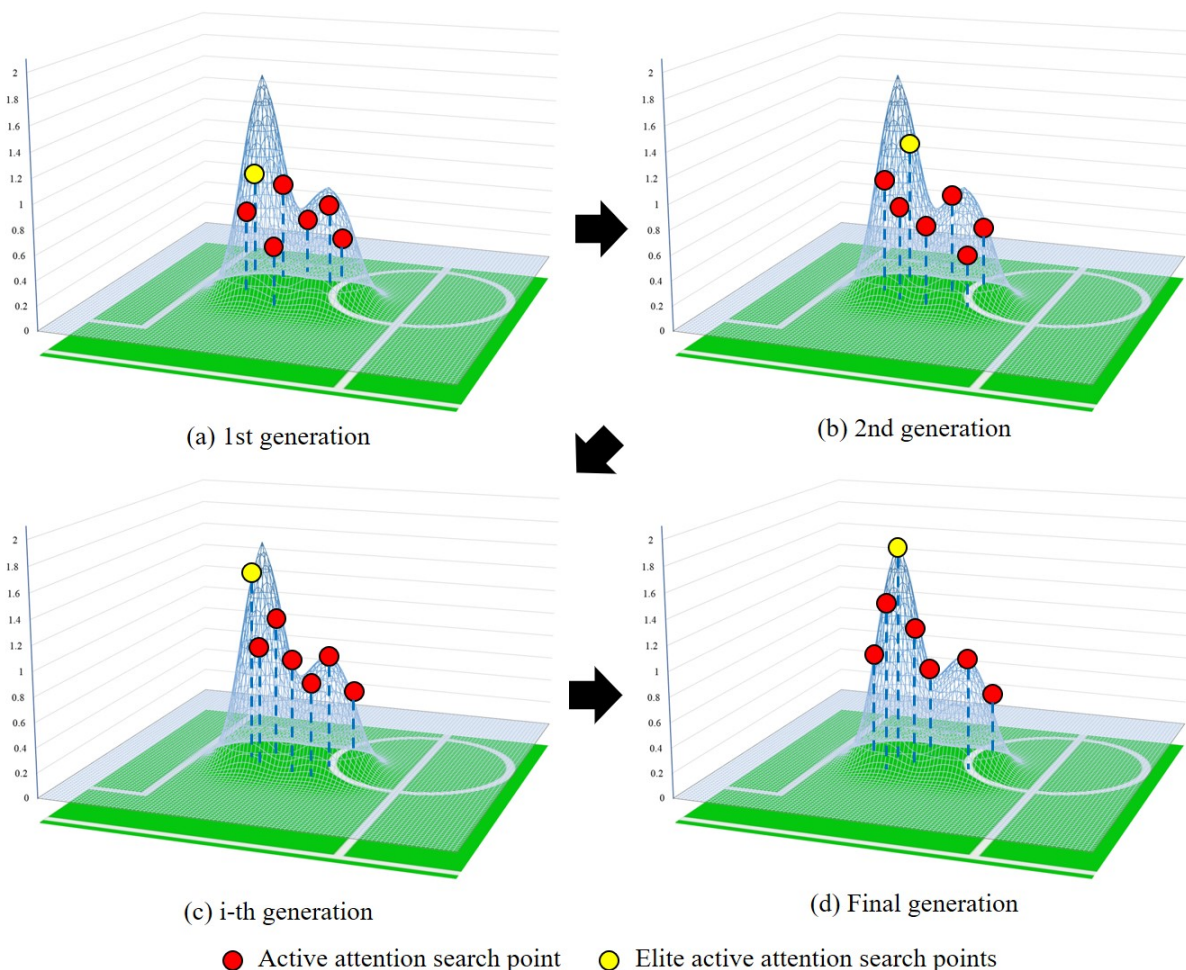


Fig. 5.7: Converging image of GA's individuals



### 5.3.5 Hybrid GA

本研究では、人間の視覚的注意の概念を用いて複数障害物の認識を実現する。ここまで述べてきたように受動注意に Monte Carlo 探索法を、能動注意に GA をそれぞれ採用して複合させる Hybrid GA である。Hybrid GA とは、GA 単体に他の手法を組み合わせることで、新しい機能の追加や欠点の補完を行った GA 全般の呼び名として知られている。例えば B.Ravichandran らは、次世代の集団を再構成する際に別手法を複合させることで認識時間の向上を図っている<sup>72)</sup>。

本研究で構築する Hybrid GA の具体的な処理過程を Fig. 5.9 に示す。受動注意により (a) のように能動注意に移行する候補点を探すために探索個体が Monte Carlo 法に従ってばらまかれ、(b) のように各点の尤度  $F(\phi)$  が評価される。ここでの例では 3 つの候補点がしきい値  $F_t$  を越えて選択され、各点を中心とした能動注意領域 I ~ III が (c) のように生成されている。能動注意領域 I ~ III は直径  $D_g$  の局所探索空間であり、それぞれに対して  $P_g$  個の探索個体が割り振られ (d) に示す GA 処理により最適化される。次に述べる注意の動的再構成を行いながらこれらの処理を繰り返すことで、認識済の障害物に対する認識を継続しつつ新規の障害物にも対応できる複数障害物の認識処理が維持される。

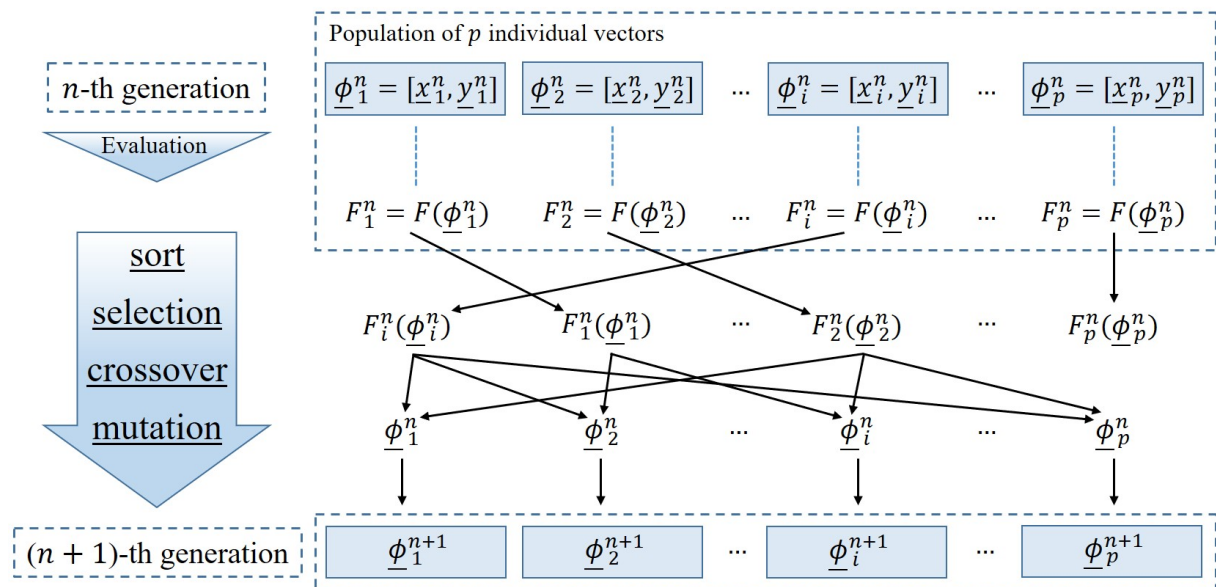


Fig. 5.8: Procedure of GA

### 5.3.6 注意の動的再構成

Fig. 5.9 の例では 3 つの障害物が存在し、3 つの異なる能動注意が各障害物に対し生成された場合、GA の処理に使用される総個体数は  $3 \times P_g$  となる。今、 $n$  個の障害物が存在したとき、受動注意と能動注意に使用できる総個体数を  $P_a$  と表すと、次世代で Monte Carlo 探索に用いることのできる個体数  $P_r$  は次式により決まる。

$$P_r = P_a - n \times P_g \quad (5.6)$$

ここで、総個体数  $P_a$  の限界個数は処理システムの性能により決定される一定値となる。

受動注意において障害物の存在が検出されなかった場合 ( $n = 0$ )、能動注意は生成されないの  
 で全ての探索個体が受動注意に使用され、認識システムは新障害物の出現に対して高い性能を有する。一方、多くの能動注意が存在する場合、認識システムは既知の複数障害物に対して高い認識性能を示し、新しく出現する障害物に対する感度が鈍くなる。これは人間で言えば、何かに極端に集中している場合、周りが見えなくなり視野内の変化を見落とすことに似ている。

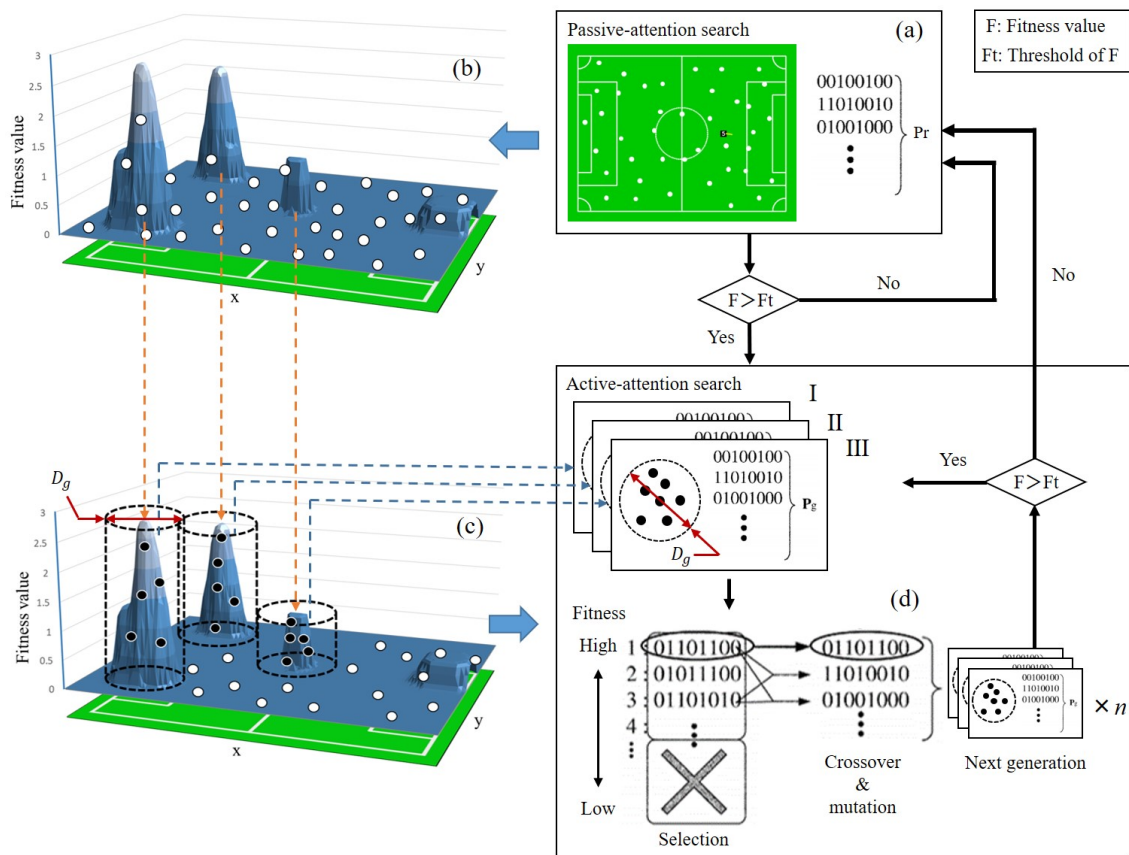


Fig. 5.9: Hybrid GA process

Fig. 5.10 に実際の認識中の探索個体分布状況を示す. 図中 (a) は障害物を認識していない状況 ( $n = 0$ ) であり, (b) (c) はそれぞれ障害物を 2つと 4つ同時認識している場合 ( $n = 2, n = 4$ ) である. (a) は能動注意が生成されていないため全ての探索個体が受動注意の個体数  $P_a$  として割り振られており, 新障害物の出現発見能力が高い. 対して (c) は 4つの能動注意が生成されているため受動注意による周囲監視能力は低い, 複数障害物を同時に認識する能力が高い. つまり, 新障害物の出現を検出する能力と複数の障害物を認識する能力はトレードオフの関係であると言える. 本手法は受動・能動注意の比重に依存して性能が大きく左右されるため, 探索個体数の割り振りを適切に行うことが重要である.

本研究では, 複数の障害物に対する認識性能が重要であると考え, 能動注意に対する割り振り

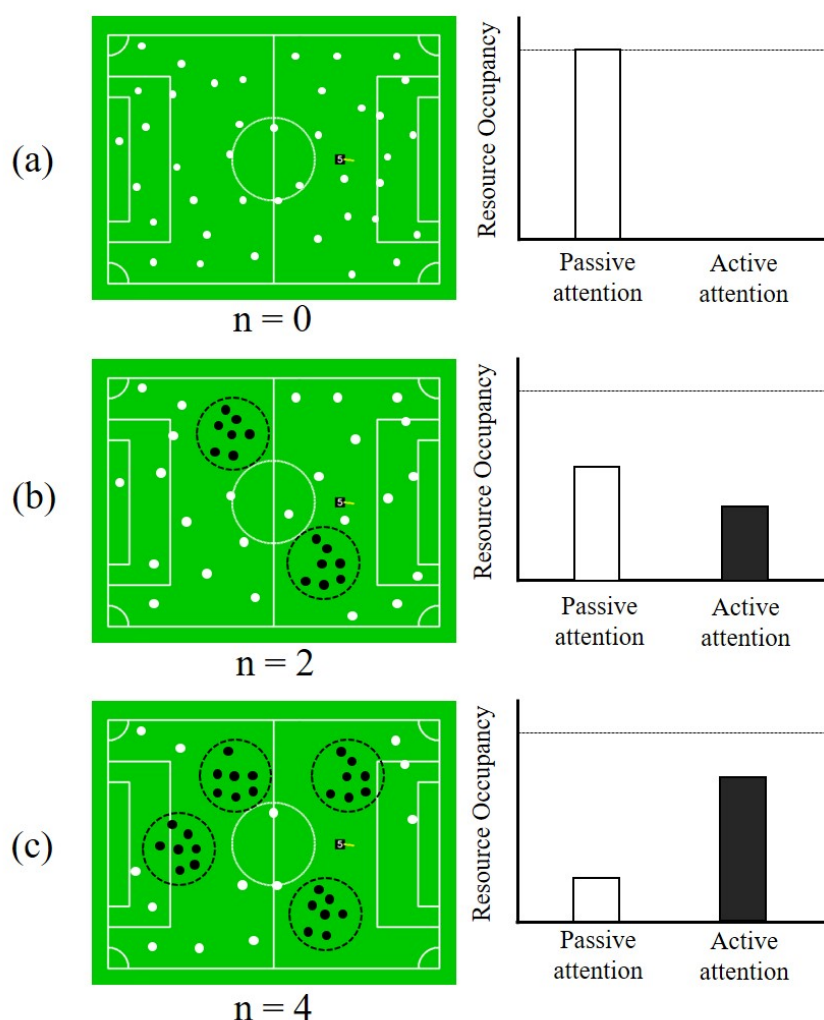


Fig. 5.10: Resource allocation for search methods

を優先する戦略をとる。処理の流れを Fig. 5.11 に示す。まず最初に設定済みの  $n$  個の能動注意による探索を行う。次に残りの個体数  $P_r$  ( $P_r = P_a - n \times P_g$ ) を用いて新しい障害物出現の検知を受動注意により行う。その後、処理プロセスの最後にこれらの結果を用いて能動注意の動的再構成が行われる。動的再構成は以下のルールに従う。

### 注意の生成

受動注意において適合度が設定したしきい値より高い値を示した時、能動注意がその位置情報に基づいて新たに作成される。ただし、すでに存在する能動注意数とその処理システムにおける処理限界数  $n_{max}$  であり、かつ各能動注意の最大適合度が発見値を上回る場合は生成されない。

### 注意の消滅

すでに存在する能動注意の適合度がある値を下回ったとき、その能動注意は消滅し、使用していた探索個体は解放される。また、能動注意が探索範囲外に移動したときも同様の処理が行われる。さらに、存在する2つの能動注意間の距離が設定値より小さくなったとき、評価値の低い能動注意は消滅する。

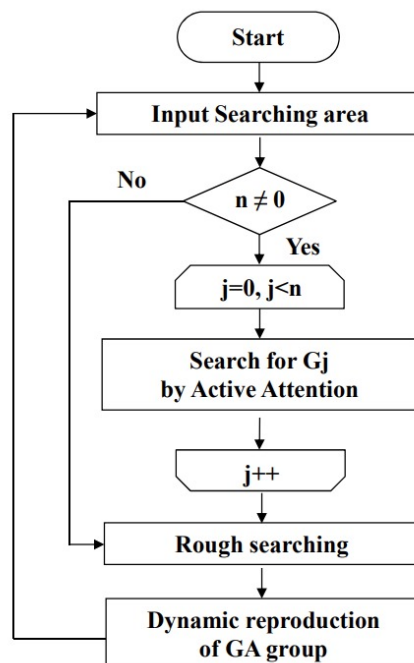


Fig. 5.11: Hybrid GA flow chart

## 注意の統合・分離

2つ以上の障害物がすれ違う場合等に生じる能動注意の統合・分離は、前述した注意の消滅・生成処理により実現される。2つの障害物が充分近づくと、消滅条件に従い評価値の低い方の注意が消滅することで統合処理が行われる。すれ違った後に離れる時、任意の一方の障害物に対しては先に統合された能動注意が継続される。そして、もう一方の物体に対して、設定距離以上離れた時点で生成処理に従い能動注意が新規生成されることにより、分離処理が行われる。

以上のように、実時間で能動注意を動的に制御・再構成することで、複数障害物認識において有効な注意分布を生成できる。このHybrid GA探索法を用い実時間での複数障害物の認識を試みる。

## 5.4 標準試験関数による検証実験

ここでは、前節で構築した複数障害物認識手法の基礎的な性能の検証のために、標準試験関数<sup>71),87)</sup>を用いた最適化実験を行う。標準試験関数とはベンチマーク関数/テスト関数とも呼ばれ、基礎的な関数から応用的な関数まで、単峰/多峰、連続/不連続など様々な特徴を有する関数群であり、最適化アルゴリズムの評価を目的として使用される。ここでは、多峰性に重点を置いたテスト関数を利用して本手法の最適化性能を検証する。

### 5.4.1 2次元多峰性関数による検証実験

複数障害物認識法の複数極大値に対する基本的な探索性能を確認するために、De Jong のテスト関数 F5 (De Jong's function 5)<sup>88)</sup>を二次元化した次式の多峰性関数を試験関数として検証を行う。

$$F(x) = \sin^6(5\pi x) \quad (5.7)$$

この関数は Fig. 5.12 に示すように  $x = 0 \sim 1.0$  の範囲で 5 つの極大値を持っており、本手法を適用することで全ての極大値の発見を試みる。実験では、総探索個体数 ( $P_a$ ) は 100, GA1 グループの集団サイズ ( $P_g$ ) は 10, そして, GA の最大グループ数 ( $n_{max}$ ) は 5 とした。また, GA 遺伝子のビット長を 8 bits ( $0 \sim 1.0$  を 256 等分で表現) とし, 適合度関数は遺伝子で表される  $x$  の値を用いた  $F(x)$  である。

シミュレーション結果を Fig. 5.13 に示す。図中に小さい丸で示しているのは、その世代において存在している各能動注意 (各 GA 集団) 内のエリート個体の位置である。4 世代目においてすでに大体の位置を発見し, 15 世代目には 5 つ全ての極大値が発見されていることから提案手法は複数極大値を探索する能力を持っていると言える。

### 5.4.2 3次元多峰性関数による検証実験

さらに提案手法の複数極大値に対する認識能力を検証するために、探索空間を 2 次元から 3 次元に拡大した次式で表される De Jong のテスト関数 F5 を用いて検証実験を行った。

$$F(x, y) = \{\sin(5\pi x) \sin(5\pi y)\}^6 \quad (5.8)$$

Fig. 5.14 に示すように, 5.8 式の多峰性関数は 25 個の極大値を持っている。実験では, 総探索個体数 ( $P_a$ ) を 350, 1 グループの集団サイズ ( $P_g$ ) を 10, GA の最大グループ数 ( $n_{max}$ ) を 25 と




Fig. 5.12: 5 peaks function

設定した. また, 探索空間が3次元に拡張されたため GA の遺伝子長は  $(x, y)$  を表現する 16 bits に設定し ( $x, y$  それぞれの 0~1.0 を 8 bits で表現), 終了世代数 100 で探索を行った. 評価関数は遺伝子で表される  $x, y$  の値を用いた  $F(x, y)$  である.

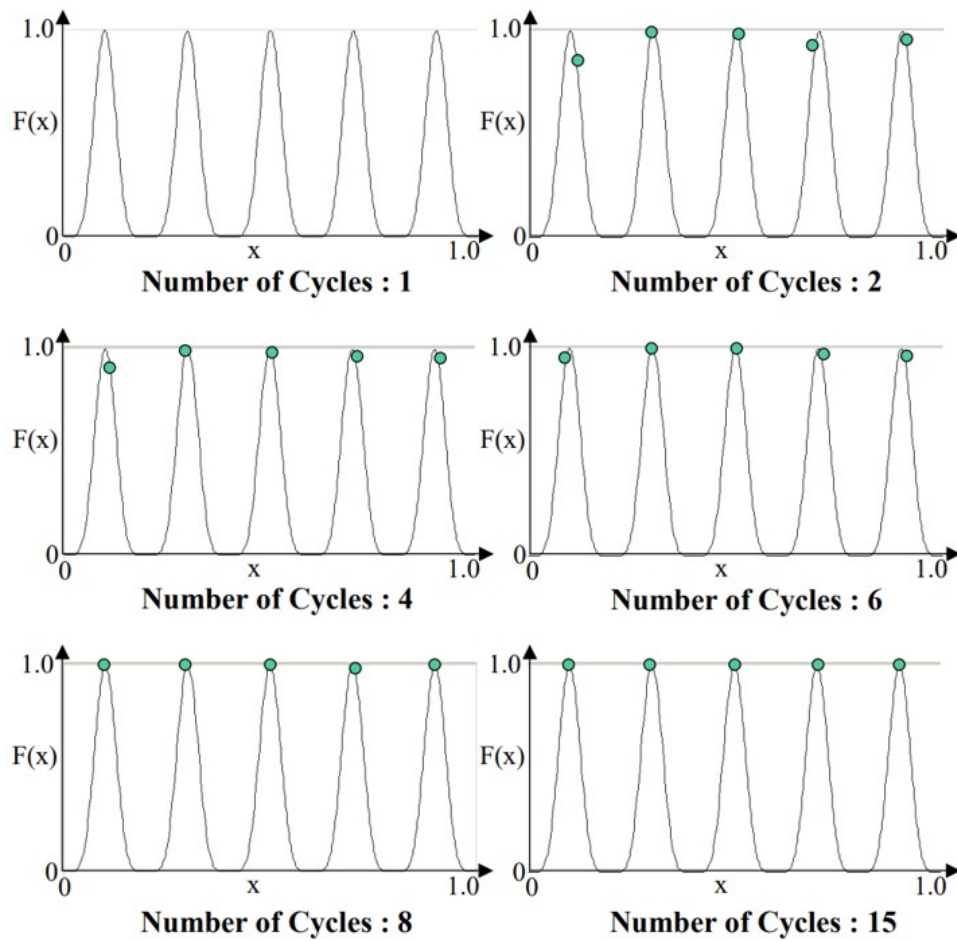


Fig. 5.13: Searching results of 5 peaks function

これらのパラメータ設定で 1000 回の実験を行った結果を Fig. 5.15 に示す。横軸は世代数であり、縦軸は該当世代において発見できた極大値の個数を全試行回数で平均した値である。1000 回の全試行において極大値 25 個全てが発見できなかった例はなく、全て発見し終えるまでの平均世代数は 16.7 世代であった。1 世代で計算を行う総探索個体数は  $P_a = 350$  のため、平均 5845 回の計算で 65536 の探索空間から 25 個の極大値を発見できることになる。本実験により、提案手法が大域的な多峰性に対して十分な最適化能力を有していることが確認できた。




Fig. 5.14: Search space with 25 peak values




Fig. 5.15: Number of detections in each generation



## 5.5 実時間性の検証

前節において提案手法の最適化能力を検証し、探索効率が高いことを確認した。ここでは、その具体的な処理時間を計測し、探索空間のサイズや総探索個体数の変化に対して検証することで、提案した Hybrid GA の実時間性を確認する。

### 5.5.1 探索空間サイズに対する処理時間の検証

4章において提案したフェルミ分布を用いた合成尤度空間は、各検出点を基点として生成されるフェルミ分布を重ね合わせて合成しているため、最終的な探索空間を構成するためには多重演算が発生し処理時間がかかってしまう。合成尤度空間全ての生成に要する処理時間は設定された探索空間のサイズに大きく依存し、空間サイズは分解能セルのサイズにより決まる。自チーム5台の味方ロボットにより敵チーム5台のロボットを観測した場合の合成尤度空間生成にかかる時間を実測したものを Fig. 5.16 に示す。横軸は空間サイズであり、縦軸は空間内の総探索点数と合成尤度空間生成にかかる時間である。ここでは尤度の計算のみを行い、極大値の探索は生成時間に含まれていない。実測値は試行1000回の平均値であり、計測には実戦環境を想定し、実際に競技で各ロボットに搭載しているノートPC (X390, CPU: intel i7-10510U, RAM: 8GB, Lenovo 社製) をバッテリー駆動で使用した。測定結果を見ると、空間サイズの増加に伴い生成時間が増加しており、 $140 \times 220$  の空間サイズにおいてすでに実時間処理ができていないことがわかる。 $140 \times 220$  の空間サイズは4.3.1節において精度検証に用いた合成尤度空間サイズであり、 $1400 \times 2200$  cm のフィールドサイズに対して分解能セルサイズ  $10 \times 10$  cm で構成した空間である。分解能セルサイズは最終的な認識精度に大きく影響を与えるため、可能な範囲で細かくすることが望ましい。しかしこの結果より、認識精度と処理時間がトレードオフの関係にあるため、全てを計算する手法では認識性能の限界が低くなることがわかる。

これに対し、本研究で提案している人間の視覚システムをヒントに工学的に実現した Hybrid GA 認識法を用いた場合の一代当たりの生成時間を Table 5.1 に示す。ここで、敵、味方チームのロボット数は前述の検証と同様であり、Hybrid GA の総探索個体数  $P_a$  は200、能動注意の集団サイズ  $P_g$  を10としている。空間サイズの拡大による GA 等の内部演算負荷増大に起因して若干の生成時間の増大は見られるが、いずれの空間サイズに対しても一代当たり  $0.2$  ms 前後で処理が完了している。本検証のような静的探索空間における認識処理では、一代当たりの生成時間に収束世代数（極大値発見までの世代数）を掛け合わせた時間が実際の認識時間であり、5.4節の例の

ように数十世代で収束すると想定した場合、認識時間は  $10\text{ ms}$  前後となる。総探索個体数を多少増やしても実時間以内で処理が完了するため、本提案手法は実時間性を有していると言える。

### 5.5.2 動的環境を考慮した実時間性の検討

前節の結論は認識問題を1コマとして切り出した場合の静的な視点における考察であり、本課題を動的な視点で考察すると、その結論は大きく異なる。動的な視点とは、時々刻々と変動する実際の競技状態のことであり、ある時刻  $n$  における対象探索空間は、1カメラフレーム ( $33\text{ ms}$ ) 固定された後、時刻  $n+1$  にはカメラ画像の新規入力に伴い次の探索空間に切り替わる。ここで、現実空間の物理的な制約により、1時刻の間の探索空間形状の動的変動は、ロボットが1時刻 ( $33\text{ ms}$ ) で移動できる範囲に留まるため、RoboCup MSL のロボットの平均的な最大移動速度 ( $3\text{ m/s}$ ) を考慮すると探索空間の変動は小さいという特徴がある。




Fig. 5.16: Search space size and search times

Table 5.1: Likelihood space size and build times use Hybrid GA

	Likelihood space size			
	140x220	256x256	512x512	768x768
Build times [ms]	0.12	0.14	0.21	0.29

この動的環境の特徴は提案した Hybrid GA 認識法との相性が非常に良い。毎時刻、全ての空間を計算する必要のある手法と比較し、提案した Hybrid GA 認識法は世代という小単位で探索が構成されるため、時刻入替えによる探索空間の小さな変動に大きな影響を受けることなく障害物の認識が次の探索空間に継承される。これは、Hybrid GA 認識法の 1 世代における進化能力（最適化能力）が 1 時刻における探索空間の環境変動を上回る場合、1 時刻当たりの必要進化世代数は 1 世代でも良いということの意味している<sup>92)</sup>。

### 5.5.3 総探索個体数に対する処理時間の検証

前節の動的環境における考察を念頭に、5.5.1 節と同じシチュエーションにおいて空間サイズを  $512 \times 512$  に固定し、Hybrid GA の総探索個体数  $P_a$  を増やした場合の検証結果を Fig. 5.17 に示す。横軸は総探索個体数、縦軸は生成時間である。総探索個体数の増加は、より広い探索空間における認識が可能となるため、分解能セル細分化による事実上の精度向上が期待できる。結果を見ると、総探索個体数を 1600 まで増加しても一世代の処理時間は 3 ms 程度となっている、これらの考察と検証結果より、提案した Hybrid GA 認識法は非常に高速であり、今後の改良に対して十分な余力を有していることがわかる。




Fig. 5.17: Number of search points and search times

## 5.6 RoboCup MSL 環境における精度検証と実装

ここまで、提案したフェルミ分布を用いた Hybrid GA 認識法の解説と様々な検証を行ってきた。最後に、RoboCup MSL 環境を用いた複数障害物に対する認識精度の検証を行う。さらに、構築した提案手法を実機に搭載し、実戦環境の動的空間において複数障害物の実時間同時認識を試みる。

### 5.6.1 Hybrid GA 認識法の精度検証

4.4.2 節 Fig. 4.45 の RoboCup MSL 環境より生成した Fig. 4.47 の探索空間を用い、提案手法による複数障害物認識を行った結果を Fig. 5.18, Table 5.2 に示す。Fig. 5.18 は提案手法が認識した座標を探索空間にプロットした図であり、Table 5.2 は Fig. 4.45 における設定座標（真値）と提案手法による認識結果の誤差である。ここで、Hybrid GA における各パラメータは事前実験により Table 5.3 のように設定している。Table 5.2 より、全ての障害物を適正に認識しており、認識誤差はフィールドサイズや競技利用の実用上の観点において小さい。また、本検証では観測ロボットが敵陣深くに存在しないため、敵ゴールキーパーは観測できず、認識できていない。さらに、同じ Fig. 4.47 の探索空間を用いて同様の認識実験を 1000 回試行したところ、全ての試行において 4 台全てを認識できており、平均誤差は 23.8 *cm* であった。

さらに、フィールド上の敵/味方のロボット配置を試行毎にランダムに選択して同様の検証を 1000 回行った。全試行において観測ロボットが検出した障害物は全て認識され、平均認識誤差は 26.7 *cm* であった。これより、提案したフェルミ分布を用いる Hybrid GA 認識法は、どのようなシチュエーションにおいても安定的に複数障害物を正しく認識できることを確認した。

Table 5.2: Recognition results in the RoboCup MSL environment

Location $(x, y)$ [ <i>cm</i> ]	Obstacle ①	Obstacle ②	Obstacle ③	Obstacle ④
Real location	(-100, 0)	(-200, -100)	(800, 500)	(550, 0)
Detected position	(-80, 0)	(-180, -100)	(800, 490)	(540, 0)
Error distance	20.0	20.0	10.0	10.0




Fig. 5.18: Recognition results in the RoboCup MSL environment

Table 5.3: Hybrid GA parameters

Total number of search points ( $P_a$ )	200
Population of active attention group ( $P_g$ )	10
Number of active attention groups ( $n_{max}$ )	10
Gene length	16 <i>bit</i>
Threshold to generate active attention	0.5
Selection rate	0.6
Mutation rate	0.1
Search range of active attention ( $D_g$ )	10

### 5.6.2 実機による複数障害物認識実験

前節において性能を検証した提案手法を2章において解説した実機に搭載し、RoboCup MSLの動的空間における複数障害物の認識実験を行った。ここでは実験環境の空間的制約によりフィールドサイズを $800 \times 1000 \text{ cm}$  ( $600 \times 800 \text{ cm}$ のフィールドに両端外側 $100 \text{ cm}$ の領域を加えている)、分解能セルは $10 \times 10 \text{ cm}$ 、味方チームの観測ロボット2台、敵チームの障害物ロボット2台とし、Hybrid GA認識法における各パラメータは前節と同じ値を用いた。

認識状況を個別に確認するため、敵/味方4台のうち敵チームの障害物ロボット1台のみをコントローラで操作した時の様子をFig. 5.19に示す。フィールド上を動く障害物を認識し続けるのと同時に、静止しているもう1台の障害物を正しく認識できていることがわかる。

最後に、動的環境における検証のために敵/味方4台全てを動かして実験を行った様子をFig. 5.20に示す。ここではコントローラ操作できるロボットの準備可能台数の制約により、敵ロボット2台については3.3.2節でも用いたRoboCup MSLロボットと幅、色が近い長方体のキャリケースを代用し人間が動かしている。敵/味方全てが動く環境においても複数の障害物が正しく認識できていることがわかる。

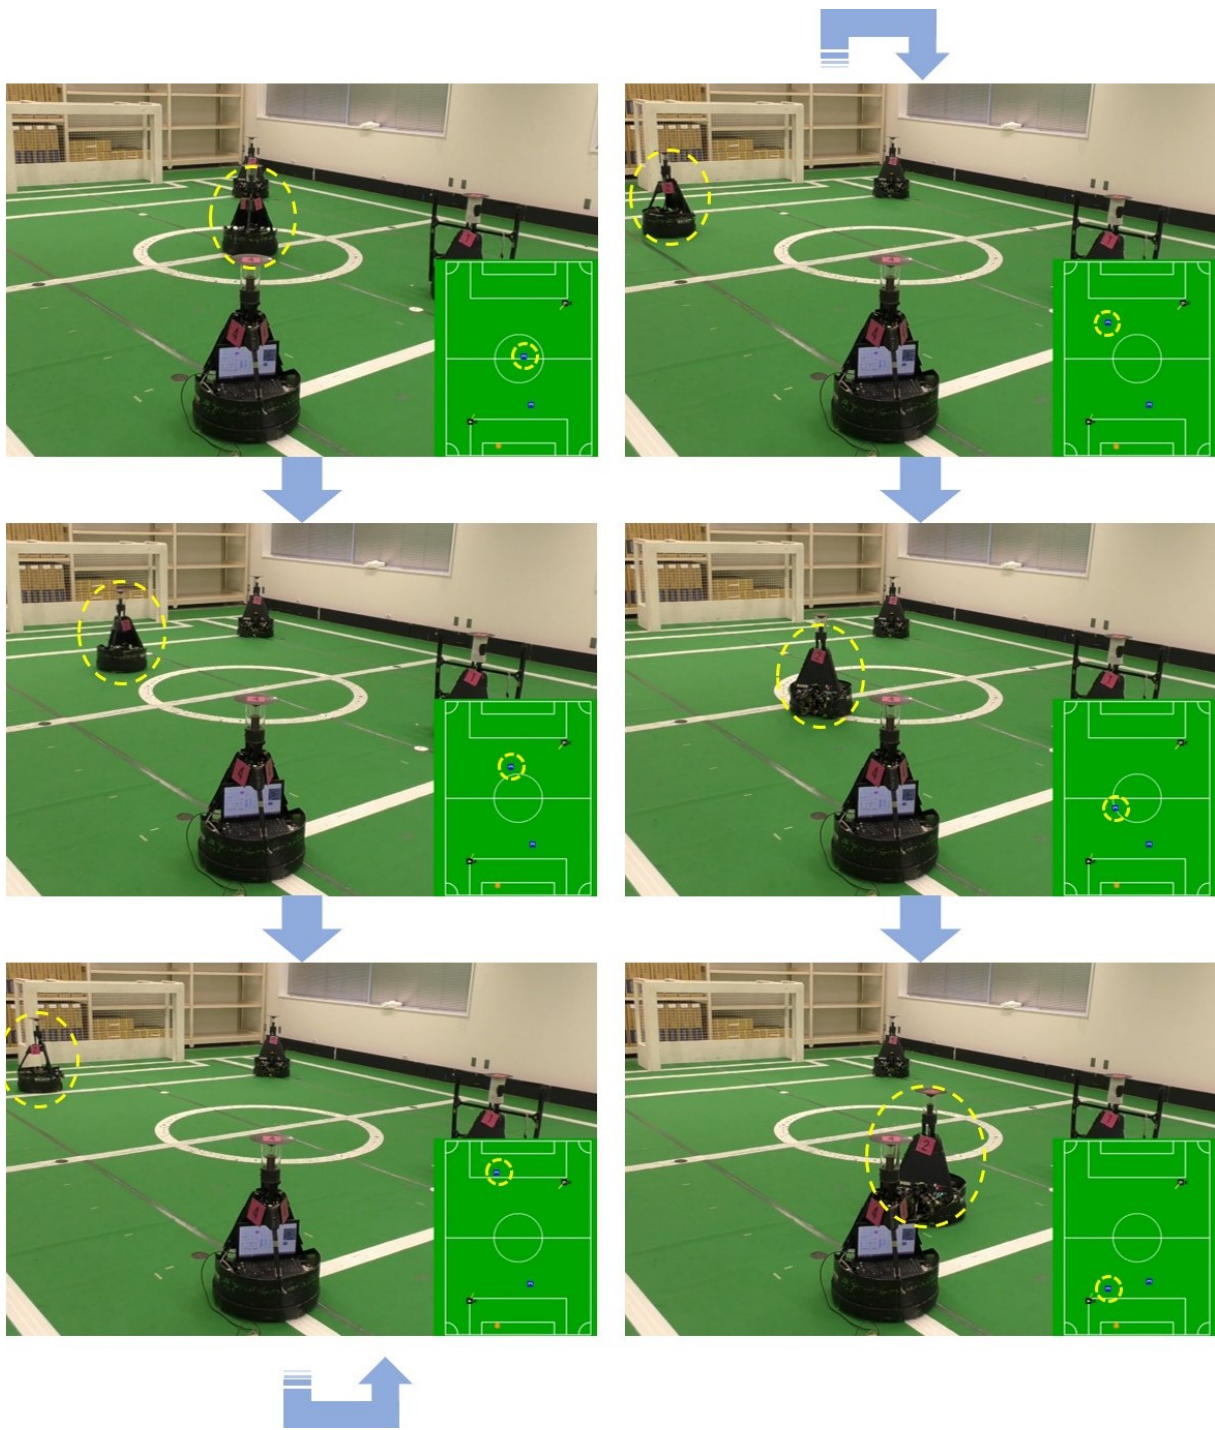


Fig. 5.19: Verification results using actual robot




Fig. 5.20: Verification results using actual robots



## 第 6 章 結言

RoboCup MSL では、応用技術として戦術を考慮したパスやドリブルなどの知的な行動判断が求められ、これらを実現するためにフィールド上の敵・味方全ての位置情報が正しく取得できていることが非常に重要となる。しかし、RoboCup MSL における広大なフィールドにおいては、ロボット単体で全ての敵位置情報を獲得することは難しいため、各ロボットが得た敵情報を共有・統合し、そこから正しく敵の位置を推定する必要がある。そこで、本研究では RoboCup MSL フィールド上に存在する複数の敵ロボットの位置情報を同時認識することを課題とし、複数の味方ロボット（観測ロボット）が得た検出情報を統合し、効率良く実時間で正しく認識する複数障害物のリアルタイム認識手法を提案した。

本研究では、双曲面ミラーを用いた全方位カメラシステムの欠点である遠方分解能に起因する距離精度を補償するために、二次元走査型の光距離センサ LiDAR を複合させたセンサフュージョンにより視覚系を構成した。RoboCup MSL 規定におけるサイズと色を利用して、全方位カメラより得た全方位画像に対して HSV 変換と YUV 変換を用いた色抽出を行い、フィールド領域内の黒色物体抽出後に障害物候補の特徴化を経て、LiDAR より得た距離情報を融合させることで障害物検出を行う手法を解説した。ここで発生する全方位カメラ円周方向の遠方分解能に起因する誤差と、フィールド座標変換時の自己位置同定誤差、調整者のスキルによる色相パラメータ調整誤差について検証し、これらの誤差要因を用いた推定合成誤差を確認することで観測距離と推定誤差の関係性を求めた。

RoboCup MSL におけるチーム間情報共有によって各観測ロボットから得た障害物情報を統合する際、各検出座標の誤差により一意的に障害物の座標を正しく推定できない問題に対し、フェルミ・ディラック分布関数を確率密度関数として用いる尤度による空間表現を採用した。複数観測ロボットに基づく障害物位置の極大値化の課題に対し、一般的な確率密度関数では困難である点を示し、フェルミ分布を用いて検出点取得時の環境情報である観測距離と推定誤差を尤度に反映させることで正しく極大値化できることを検証した。フェルミ分布を用いた尤度合成手法は、各検出点に対応する本来の被観測ロボットの真値推定のための尤度生成を補助しつつ、一方で近く

の異なる被観測対象の尤度生成において大きな影響を与えないという特徴を持っており、複数障害物に対する探索空間としての尤度空間の生成において有用であることを示した。

生成された合成尤度空間において、複数障害物の座標は複数極大値として表現され、フィールド上の複数障害物を認識する問題は合成尤度空間を探索空間とする複数極大値の最適化問題として置き換えられる。本研究では、複数の異値極大値を持つ大域的多峰性と同時に局所的多峰性を持ち合わせる合成尤度空間からの複数極大値探索問題に対し、人間の注意機構にヒントを得た Hybrid GA 認識法を提案した。具体的には、広視野低密度な受動注意に大域的探索に特化した Monte Carlo 探索法を採用し、狭視野高密度な能動注意に遺伝的アルゴリズム (GA) をそれぞれ採用することで注意機構を工学的に最適化手法として構築し、注意の動的再構成を進化処理として実現することで、効率よく実時間で合成尤度空間から複数障害物認識を行う。最適化問題における標準試験関数を用いて提案手法の最適化能力を確認し、認識精度と実時間性を検証した後に、実機に実装した結果、複数の観測ロボットにより複数障害物を実時間で実用上問題のない精度で認識できることがわかった。

本研究では、全方位カメラに加えて LiDAR を前方重視でセンサフュージョンさせた視覚システムを構成した。提案した Hybrid GA を用いた複数障害物認識法はセンサデバイスの制約はほとんど受けないため、重要視するセンシング方向とセンサデバイスを自由に選定することができる。緒言において触れたように、YOLO 等の深層学習を用いた強靱な物体認識技術は視野の制約を受けが、重要性の高い方向への部分利用として融合することで、本手法における前方認識精度を向上できる可能性がある。また、5.5.3 節において検証したように、提案したフェルミ分布を用いた複数障害物認識法は非常に高速であり、探索空間の分解能セル細分化による精度向上の余力を有している。今後の課題として、視覚システムにおけるセンサデバイスの再構成と探索空間設定における細分化による精度向上を検証する。

本論文では RoboCup MSL における障害物認識を対象として議論したが、第 4 章以降の提案手法は他の分野における複数物体の実時間認識手法として汎用的に利用できる可能性がある。ただし、Hybrid GA における各種パラメータ設定には試行錯誤的な調整が必要となるため、パラメータの汎用的な調整法の構築も今後の課題である。

## 参考文献

- [1] 油田 信一：“複数の自律移動ロボットの協調行動”，日本ロボット学会誌，10 巻，4 号，p. 433-438 (1992)
- [2] 友納 正裕：“SLAM 入門—ロボットの自己位置推定と地図構築の技術”，オーム社 (2018)
- [3] S. Thrun, W. Burgard and D. Fox：“A real-time algorithm for mobile robot mapping with applications to multi-robot and 3D mapping”，Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No.00CH37065), pp. 321-328 vol.1 (2000)
- [4] 小島宏一，加藤雄資，福井善朗，中村文一：“開かれた環境が育むマイクロマウスの技術進化”，システム／制御／情報，Vol.55, No.7, pp.265-270 (2011)
- [5] “つくばチャレンジ論文特集号”，日本ロボット学会誌，Vol.30, No.3 (2012)
- [6] Yuya Nishida, Takashi Sonoda, Takayuki Matsuo, Shinsuke Yasukawa, Masanori Sato, Yasunori Takemura, Kazuo Ishii：“Reports of 7th underwater robot festival in Kitakyushu”，International Conference on Artificial Life and Robotics 2020(ICAROB2020), Vol.25, pp.110-113 (2020)
- [7] 石井 和男, 安川 真輔, 園田 隆, 李 冰賀：“競技会を通じたトマト収穫ロボットの開発”，第 31 回ファジィシステムシンポジウム講演論文集，pp167-170 (2015)
- [8] RoboCup Federation：<https://www.robocup.org/>
- [9] M. Asada, H. Kitano, I. Noda, M. Veloso：“RoboCup: Today and tomorrow-What we have learned”，Artificial Intelligence, Volume 110, Issue 2, pp.193-214 (1999)
- [10] M. Hermann, T. Pentek and B. Otto：“Design Principles for Industrie 4.0 Scenarios”，2016 49th Hawaii International Conference on System Sciences (HICSS), pp. 3928-3937 (2016)

- [11] RoboCup 日本委員会 : <http://www.robocup.or.jp/>
- [12] M. Asada, P. Stone, M. Veloso, D. Lee, D. Nardi : “RoboCup: A Treasure Trove of Rich Diversity for Research Issues and Interdisciplinary Connections” IEEE Robotics & Automation Magazine, Volume 26, Issue 3, pp.99-102 (2019)
- [13] 浅田稔, 松原仁 : “ロボカップみちしるべ : 第 1 回 ロボカップ創世記”, 情報処理, Vol.51, No.9, pp.1195-1200 (2010)
- [14] 野田五十樹, 南方英明, 小林邦和, 杉浦藤虎, 武村泰範, 秋山英久, 岡田浩之 : “ロボカップ西暦 2050 年を目指して (その 1)”, 知能と情報 (日本知能情報フアジィ学会誌), Vol.29, No.1, pp.2-13 (2017)
- [15] 高橋友一, 秋田純一, 渡辺正人 : “小型ロボットの基礎技術と製作 - RoboCup 小型リーグへの挑戦”, 共立出版 (2003)
- [16] 中村 恭之, 高橋 泰岳 : “中型ロボットの基礎技術 - 対戦のための協調行動に向けて”, 共立出版 (2005)
- [17] Huimin Lu, Shaowu Yang, Hui Zhang, Zhiqiang Zheng : “A robust omnidirectional vision sensor for soccer robots”, Mechatronics, Volume 21, Issue 2, pp.373-389 (2011)
- [18] A. K. Mulya, F. Ardilla and D. Pramadihanto : “Ball tracking and goal detection for middle size soccer robot using omnidirectional camera”, 2016 International Electronics Symposium (IES), Denpasar, Indonesia, pp. 432-437 (2016)
- [19] Lee T-J, Yi D-H, Cho D-I : “A Monocular Vision Sensor-Based Obstacle Detection Algorithm for Autonomous Robots”, Sensors 16, no. 3: 311. (2016)
- [20] I. Marković, F. Chaumette and I. Petrović : “Moving object detection, tracking and following using an omnidirectional camera on a mobile robot”, 2014 IEEE International Conference on Robotics and Automation (ICRA), pp. 5630-5635 (2014)
- [21] J. Redmon, S. Divvala, R. Girshick, A. Farhadi : “You Only Look Once; Unified, Real-Time Object Detection”, 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), pp. 779-788 (2016)

- [22] J. Redmon, A. Farhadi : “YOLO9000: Better, Faster, Stronger”, 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), pp.6517-6525 (2017)
- [23] J. Redmon, A. Farhadi: “YOLOv3: An Incremental Improvement”, arXiv:1804.02767(2018)
- [24] A. Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao : “YOLOv4: Optimal Speed and Accuracy of Object Detection”, arXiv:2004.10934 (2020)
- [25] Ultralytics : “YOLOv5”, <https://www.docs.ultralytics.com/>
- [26] S. Luo, et al : “Robot Detection and Localization Based on Deep Learning”, 2017 Chinese Automation Congress (CAC), DOI: 10.1109/CAC.2017.8244056 (2017)
- [27] V. Gies, et al : “Robot Club Toulon Team Description 2020”, <https://rct.univ-tln.fr/robocup-qualification-2021/>
- [28] Paulo Rogério de Almeida Ribeiro, Gil Lopes, Fernando Ribeiro : “Neural Network in Computer Vision for RoboCup Middle Size League ”, published by Journal of Software Engineering and Applications, Vol.9 No.7 (2016)
- [29] P. Ross, A. English, D. Ball, B. Upcroft and P. Corke : “Online novelty-based visual obstacle detection for field robotics”, 2015 IEEE International Conference on Robotics and Automation (ICRA), pp. 3935-3940 (2015)
- [30] NVIDIA Developer : “Jetson TX2 Developer Kit”, <https://www.developer.nvidia.com/>
- [31] FLIR Systems, Inc. : “Flea3(USB3 Vision Camera)”, Available from: <https://www.flir.com/products/flea3-usb3/>
- [32] Vstone Co.,Ltd. : “全方位ミラー製品”, [http://www.vstone.co.jp/products/sensor\\_camera/index.html](http://www.vstone.co.jp/products/sensor_camera/index.html)
- [33] MSL Technical Committee 1997-2022 : “Middle Size Robot League Rules and Regulations for 2022”, [https://msl.robocup.org/wp-content/uploads/2022/01/Rulebook\\_MSL2022\\_v23.0.pdf](https://msl.robocup.org/wp-content/uploads/2022/01/Rulebook_MSL2022_v23.0.pdf)
- [34] 石川 正俊 : センサフュージョン, 電気學會雜誌, 113 卷, 2 号, p. 131-138 (1993)

- [35] J.Z. Sasiadek : Sensor fusion, Annual Reviews in Control, Volume 26, Issue 2, pp. 203-228 (2002)
- [36] 埜 圭二：“ITSにおける車載画像センサの最新動向”，第10回画像センシングシンポジウムチュートリアル, pp. 51-62 (2004)
- [37] 青木 正喜：“ITSにおける画像計測と画像処理”，日本ロボット学会誌, Vol. 17, NO. 3, pp. 321-327 (1999)
- [38] 松下温, 屋代智之 (編)：“NetCom ライブラリ ITSと情報通信技術”，裳華房 (2003)
- [39] 古川 修：“ITSに関する自動車の制御技術の現状と今後の課題”，計測と制御, Vol.40, No.3, pp.207-213 (2001)
- [40] Yu X., Marinov M.：“A Study on Recent Developments and Issues with Obstacle Detection Systems for Automated Vehicles”, Sustainability 12, no. 8:3281 (2020)
- [41] ビジュアル情報処理編集委員会：“デジタル画像処理”，CG — ARTS 協会 (2006)
- [42] 赤穂 昭太郎：“EM アルゴリズム：クラスタリングへの適用と最近の発展”，日本ファジィ学会誌, 12 巻, 5 号, p. 594-602 (2000)
- [43] 神畷 敏弘：“データマイニング分野のクラスタリング手法 (1)：クラスタリングを使ってみよう!”, 人工知能, 18 巻, 1 号, p. 59-65 (2003)
- [44] Qifei Du, Dahu Wang, Lin Sha：“Recognition of Mobile Robot Navigation Path Based on K-Means Algorithm”, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 34, No. 08, 2059028, p. 59-65 (2020)
- [45] Jia Weikuan, Zhao Dean, Liu Xiaoyang, Tang Shuping, Ruan Chengzhi, Ji Wei：“Apple recognition based on K-means and GA-RBF-LMS neural network applicated in harvesting robot”, Transactions of the Chinese Society of Agricultural Engineering, Volume 31, Number 18, pp. 175-183 (2015)
- [46] M. E. Yabroudi, K. Awedat, R. C. Chabaan, O. Abudayyeh, I. Abdel-Qader：“Adaptive DBSCAN LiDAR Point Cloud Clustering For Autonomous Driving Applications”, 2022 IEEE International Conference on Electro Information Technology (eIT), pp. 221-224 (2022)

- [47] O. Kroemer, R. Detry, J. Piater J. Peters : “Active learning using mean shift optimization for robot grasping”, 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 2610-2615 (2009)
- [48] Konstantinos Charalampous, Ioannis Kostavelis, Antonios Gasteratos : “Thorough robot navigation based on SVM local planning”, Robotics and Autonomous Systems, Volume 70, pp. 166-180 (2015)
- [49] 清水 博文, 星 陽一, 池田 正則 : “基礎からの半導体工学”, 日新出版 (2012)
- [50] 高田 康民 : “多体問題 電子ガス模型からのアプローチ”, 朝倉書店 (1999)
- [51] Charles Kittel(著), 宇野 良清(共訳), 津屋 昇(共訳), 新関 駒二郎(共訳), 森田 章(共訳), 山下 次郎(共訳) : “キッテル固体物理学入門”, 丸善 (2005)
- [52] 谷内田 : “動画像処理”, 日本ロボット学会誌, Vol.1, No.4, pp.263-269 (1983)
- [53] 日本視覚学会(編) : “視覚情報処理ハンドブック”, 朝倉書店, (2000)
- [54] C.J.Downing, S.Pinker : “The spatial structure of visual attention”, In Attention and Performance XI(eds. M.I.Posner and O.S.M.Marin), Lawrence Erlbaum Associates, pp. 171-188 (1985)
- [55] R. Leigh and D. Zee : “The Neurology of Eye Movements”, 2nd Edition, F. A. Davis Company (1991)
- [56] 熊田孝恒 : “脳科学大辞典”, 甘利俊一(編), 朝倉書店 (2000)
- [57] 宮下保史 : “脳から心へ 高次機能の解明に挑む”, 下条信輔(編), 岩波書店 (1995)
- [58] デビッド・マー : “ビジョン”, 乾 敏郎, 安藤 広志(訳), 産業図書 (1987)
- [59] 福田, 佐藤 : “ブレインサイエンスシリーズ 14 脳と視覚 何をどう見るか”, 共立出版 (2002)
- [60] 川人 光男 : “脳の計算理論”, 産業図書 (1996)
- [61] 出村 公成, 中川 祐 : 「全方位カメラを用いたテンプレートマッチングに基づくモンテカルロ位置同定法」, 日本ロボット学会誌, Vol. 27, No.2, pp.249-257 (2009)

- [62] 石原 悠, 鈴木 崇文, 高橋 正樹:「自律移動ロボットにおける処理時間と推定精度を考慮したモンテカルロ位置推定法」, 第31回人工知能学会 AI チャレンジ研究会, SIG-Challenge-B001-4, pp.21-26 (2010)
- [63] F. Dellaert, D. Fox, W. Burgard and S. Thrun : “Monte Carlo localization for mobile robots”, Proceedings 1999 IEEE International Conference on Robotics and Automation (Cat. No.99CH36288C), pp. 1322-1328 vol.2 (1999)
- [64] M. Sridharan, G. Kuhlmann and P. Stone : “Practical Vision-Based Monte Carlo Localization on a Legged Robot”, Proceedings of the 2005 IEEE International Conference on Robotics and Automation, pp. 3366-3371 (2005)
- [65] F. Dellaert, D. Fox, W. Burgard and S. Thrun : “Monte Carlo localization for mobile robots”, Proceedings 1999 IEEE International Conference on Robotics and Automation (Cat. No.99CH36288C), pp. 1322-1328 vol.2 (1999)
- [66] 安居院 猛, 長尾 智晴: “ジェネティックアルゴリズム”, 昭晃堂 (1993)
- [67] 小林 重信: “遺伝的アルゴリズムの現状と課題”, 計測と制御, Vol. 32, no. 1, pp. 2-9 (1993)
- [68] 北野 宏明: “遺伝的アルゴリズム”, 産業図書 (1993)
- [69] D.E.Goldberg : “Genetic Algorithms in Search, Optimization and Machine Learning.”, Reading: Addison-Wesley (1989)
- [70] Z.Michalewicz: “Genetic algorithm + data structures = evolution programs.”, Spring-Verlag (1994)
- [71] T. Back : “Evolutionary Algorithms in Theory and Practice”, OXFORD UNIVERSITY PRESS (1996)
- [72] B. Ravichandran, A. C. Sanderson : “Model-Based Matching Using a Hybrid Genetic Algorithm”, Proceedings of the 1994 IEEE International Conference on Robotics and Automation, pp. 2064-2069 vol.3 (1994)



- [73] Lv, Y., Liu, W., Wang, Z. et al. : “WSN Localization Technology Based on Hybrid GA-PSO-BP Algorithm for Indoor Three-Dimensional Space”, *Wireless Pers Commun* 114, 167-184 (2020)
- [74] RV-Infinity Discription paper : <http://www.seit.t-kougei.ac.jp/vision/rv-infinity/2018Qualification.html>
- [75] マクソンジャパン株式会社 : “maxon RE モータ”, <https://www.maxongroup.co.jp/maxon/view/content/Overview-Page-DC-Motors>
- [76] マクソンジャパン株式会社 : “ESCON”, <https://www.maxongroup.co.jp/maxon/view/content/Overview-Page-Controls>
- [77] ルネサス エレクトロニクス株式会社 : “RX62T”, <https://www.renesas.com/jp/ja/products/microcontrollers-microprocessors/rx.html>
- [78] TDK InvenSense : “MPU-9250”, <https://www.invensense.com/products/motion-tracking/9-axis/mpu-9250/>
- [79] 株式会社アールティ : “USB 出力 9 軸 IMU センサモジュール”, <https://www.rt-net.jp/products/9axisimu2>
- [80] 谷口 慶治 : “画像処理工学 基礎編”, 共立出版 (1996)
- [81] 中島 正之, 安居院 猛 : “画像処理 [1] 画像処理の基礎”, 計測と制御, Vol.28, no.3, pp.237-245 (1989)
- [82] 高木幹雄, 下田陽久 (監修) : “画像解析ハンドブック”, 東京大学出版会 (1991)
- [83] G.Ao, H.Akazawa, M.Izumi, and K.Fukunaga : “A Method of Model-Based Object Recognition”, *Japan/USA Symposium on Flexible Automation (ASME)*, Vol. 2, pp. 905-912 (1996)
- [84] R.A.Brooks : “Model-Based Three-Dimensional Interpretations of Two-Dimensional Images”, *IEEE Transaction on Pattern Analysis and Machine Intelligence*, PAMI-5, 2, pp. 140-150 (1983)
- [85] 西川 ヨシー, 三宮 信夫, 茨木 俊秀 : “岩波講座情報科学 (19) 最適化”, 岩波書店 (1982)

- [86] 坂和 正敏：“非線形システムの最適化”，森北出版（1989）
- [87] Randy L. Haupt, Sue Ellen Haupt, SUE ELLEN AUTOR HAUPT：“Practical Genetic Algorithms”，Wiley（2004）
- [88] De Jong, Kenneth Alan：“Analysis of the behavior of a class of genetic adaptive systems”，University of Michigan ProQuest Dissertations Publishing（1975）
- [89] 中山 諒也, 山田 翔太, 鈴木 秀和：“RoboCup 中型リーグのためのボール認識”，第 20 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 186（2015）
- [90] 仲野 綾華, 鈴木 秀和, 渡邊 香：“同色ノイズにロバストなボール認識”，第 23 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 129（2018）
- [91] Kaori Watanabe, Yuehang Ma, Hitoshi Kono, Hidekazu Suzuki：“A Self-localization Method Using a Genetic Algorithm Considered Kidnapped Problem”，Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol. 26, No. 1, pp. 32-41（2022）
- [92] Yuehang Ma, Kaori Watanabe, Hitoshi Kono, Hidekazu Suzuki：“Verification of Robustness Against Noise and Moving Speed in Self-localization Method for Soccer Robot”，Journal of Robotics, Networking and Artificial Life, Vol. 8, No. 1, pp. 66-71（2021）
- [93] Kaori Watanabe, Yuehang Ma, Hidekazu Suzuki：“Real-time Self-localization using Model-based Matching for Autonomous Robot of RoboCup MSL”，Journal of Robotics, Networking and Artificial Life, Vol. 7, No. 2, pp. 98-102（2020）
- [94] 仲田 尚貴, 馬 躍航, 渡邊 香, 鈴木 秀和：“全方位カメラと深度センサによる環境認識のためのセンサフュージョン”，令和 3 年電気学会全国大会講演論文集, 3-038, pp. 55（2021）
- [95] Y. Ma, K. Watanabe, H. Suzuki：“Obstacle-recognition Method for Soccer Robot Based on Human Selective Attention”，Proceedings of The 3rd International Conference on Robotics Systems and Vehicle Technology (RSVT2022), SE5001, pp. 1-5（2022）
- [96] 八十原 良隆, 松下 健嗣, 鈴木 秀和：“チーム Koogei-RV のロボット紹介”，第 29 回フレンジシステムシンポジウム講演論文集, MF3-1, pp. 313-316（2013）

- [97] 吉田 哲也, 鈴木 秀和: “新産業ロボットのための全方向移動プラットフォーム”, 第 33 回ファジィシステムシンポジウム講演論文集, FE1-4, pp. 659-660 (2017)
- [98] 八十原 良隆, 鈴木 秀和: “ロボカップ中型リーグのための全方向移動機構の開発”, 第 31 回ファジィシステムシンポジウム講演論文集, WC3-2, pp. 151-152 (2015)
- [99] 松下 健嗣, 村田 真大, 鈴木 秀和: “全方向移動機構のためのサスペンションの開発”, 第 16 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 5 (2011)
- [100] 清水 孝成, 八十原 良隆, 鈴木 秀和: “RoboCup 中型リーグにおけるボール保持機構の開発”, 第 20 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 218 (2015)
- [101] 松田 治, 谷山 直将, 中野 翔吾, 松下 健嗣, 鈴木 秀和: “ロボカップ中型リーグにおけるキック機構の開発”, 第 18 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 152 (2013)
- [102] 福元 鉄平, 鈴木 秀和: “全方向移動機構の製作と性能評価”, 第 23 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 144 (2018)
- [103] 内藤 悠生, 渡邊 香, 鈴木 秀和: “ $n$  次多項式近似を用いた全方位カメラ画像の距離変換”, 第 16 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp.198 (2011)
- [104] 山田 翔太, 新田 卓也, 渡邊 香, 鈴木 秀和: “RoboCup 中型リーグのための距離校正を用いた自己位置同定法”, 第 18 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 170 (2013)
- [105] M. Minami, J. Agbanhan, H. Suzuki, T. Asakura: “Real-time Corridor Recognition for Autonomous Vehicle”, *Journal of Robotics and Mechatronics*, Vol.13, No.4, pp.357-370 (2001)
- [106] 見浪 護, 鈴木 秀和: “GA と生画像を用いた魚へのビジュアルサーボイングとキャッチング”, 計測と制御, Vol.40, No.9, pp. 641-646 (2001)
- [107] 見浪 護, 鈴木 秀和, ジュリアン アグバーン: “注視 GA ビジュアルサーボを用いたロボットによる魚の捕獲”, *日本機械学会論文集 (C 編)*, Vol.68, No.668, pp. 1198-1206 (2002)
- [108] H. Suzuki, M. Minami: “Visual Servoing to Catch Fish Using Global/Local GA Search”, *IEEE/ASME Transactions on Mechatronics*, Vol. 10, No. 3, pp. 352-357 (2005)

- [109] H. Suzuki, K. Watanabe, Y. Ma : “Accuracy Verification for Self-Localization Depending on Color Calibration Skill”, Proceedings of 2nd International Symposium for Color Science and Art 2020, pp. 37-38 (2020)

# 業績一覧

## 学術論文

- [1] Kaori Watanabe, Yuehang Ma, Hitoshi Kono, Hidekazu Suzuki, “A Self-localization Method Using a Genetic Algorithm Considered Kidnapped Problem” , Journal of Advanced Computational Intelligence and Intelligent Informatics, Vol. 26, No. 1, pp. 32-41, 2022
- [2] Yuehang Ma, Kaori Watanabe, Hitoshi Kono, Hidekazu Suzuki, “Verification of Robustness Against Noise and Moving Speed in Self-localization Method for Soccer Robot” , Journal of Robotics, Networking and Artificial Life, Vol. 8, No. 1, pp. 66-71, 2021
- [3] 渡邊 香, 馬 躍航, 内田 尚登, 河野 仁, 大海 悠太, 鈴木 秀和, “競技型ロボット教育科目における教育効果の検証” , 工学教育, Vol. 69, No. 6, pp. 100-105, 2021
- [4] Kaori Watanabe, Yuehang Ma, Hidekazu Suzuki, “Real-time Self-localization using Model-based Matching for Autonomous Robot of RoboCup MSL” , Journal of Robotics, Networking and Artificial Life, Vol. 7, No. 2, pp. 98-102, 2020

## 査読付き国際会議

- [1] Y. Ma, K. Watanabe, H. Suzuki, “Obstacle-recognition Method for Soccer Robot Based on Human Selective Attention” , Proceedings of The 3rd International Conference on Robotics Systems and Vehicle Technology (RSVT2022), SE5001, pp. 1-5, 2022
- [2] Y. Ma, K. Watanabe, H. Suzuki, “Robustness Verification Against Noise of Self-localization Method Using Omni-directional Camera for Soccer Robot” , Proceedings of The 2021 International Conference on Artificial Life and Robotics (ICAROB2021), OS22-1, pp. 393-396, 2021

- [3] Y. Ma, K. Watanabe, H. Suzuki, “Gait Learning Method for Quadrupedal Robot Using Chaos Time-series Analysis” , Proceedings of The 2020 International Conference on Artificial Life and Robotics (ICAROB2020), OS24-5, pp. 259-262, 2020
- [4] K. Watanabe, Y. Ma, T. Yoshida, H. Suzuki, ”Real-Time Self Localization for Autonomous Robot of RoboCup MSL”, Proceedings of The 2020 International Conference on Artificial Life and Robotics (ICAROB2020), OS22-1, pp. 94-97, 2020
- [5] K. Watanabe, Y. Ma, T. Yoshida, H. Suzuki, ”Real-Time Self-Localization Using a Genetic Algorithm Based on Color Detection”, Proceedings of The 6th International Workshop on Advanced Computational Intelligence and Intelligent Informatics (IWACIII2019), SUN4-A4, 2019

## 査読なし国際会議

- [1] H. Suzuki, K. Watanabe, Y. Ma, ”Accuracy Verification for Self-Localization Depending on Color Calibration Skill”, Proceedings of 2nd International Symposium for Color Science and Art 2020, pp. 37-38, 2020

## 国内発表

- [1] 宮下 和也, リカルド ケビン, 馬 躍航, 渡邊 香, 鈴木 秀和, “自律型サッカーロボットにおける距離センサを用いた障害物認識”, 第 27 回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 74, 2022
- [2] 馬 躍航, 渡邊 香, 鈴木 秀和, “サッカーロボットのためのリアルタイムな複数障害物認識”, 第 39 回日本ロボット学会学術講演会論文集, RSJ2021AC2K4-02, 2021
- [3] 馬 躍航, 渡邊 香, 鈴木 秀和, “画像情報を用いた位置認識手法におけるノイズに対するロバスト性の検証”, 令和 3 年電気学会全国大会講演論文集, 3-043, pp. 63, 2021
- [4] 馬 躍航, 渡邊 香, 鈴木 秀和, “RoboCup MSL のための自己位置同定法の構築”, 2021 年電子情報通信学会総合大会講演論文集, D-12-32, pp. 73, 2021

- [5] 斎藤 巧真, 馬 躍航, 渡邊 香, 鈴木 秀和, “RoboCup サッカーロボットにおける複数指標を利用した位置認識手法の構築”, 令和3年電気学会全国大会講演論文集, 3-039, pp. 57, 2021
- [6] 仲田 尚貴, 馬 躍航, 渡邊 香, 鈴木 秀和, “全方位カメラと深度センサによる環境認識のためのセンサフュージョン”, 令和3年電気学会全国大会講演論文集, 3-038, pp. 55, 2021
- [7] 河内 康希, 馬 躍航, 渡邊 香, 鈴木 秀和, “全方向移動機構の開発と制御”, 第26回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 103, 2021
- [8] 奥田 拓弥, 馬 躍航, 渡邊 香, 鈴木 秀和, “二足歩行ロボットの歩容学習のための評価法の構築”, 第26回電子情報通信学会東京支部学生会研究発表会講演論文集, pp. 84, 2021
- [9] 馬 躍航, 渡邊 香, 鈴木 秀和, “カオス時系列解析を用いた四足歩行ロボットの歩容生成法”, 第36回ファジィシステムシンポジウム講演論文集, 2020

# 謝辞

本研究の遂行及び論文の作成にあたり、学部時代から長い期間に終始ご指導、御鞭撻を賜りました東京工芸大学工学部の鈴木 秀和准教授に厚く御礼申し上げます。

同大学渡邊 香先生には、研究を進めるにあたり、終始適切な助言を賜り、丁寧に指導して下さいまして、深く感謝を表させていただきます。

また、辛 徳教授、姜 有宣教授、片上 大輔教授、安藤 吉伸教授には、本論文の副査として審査をお引き受け頂き、研究をまとめる上でアドバイスを多く頂きました。心より御礼申し上げます。

そして、実験遂行に様々な御協力を頂いた東京工芸大学工学部機械コースロボットビジョン研究室の歴代卒業生および在学生各位に心から感謝の意を表します。

さらに、世界中のチームとの交流、競い合う機会を提供し、研究を促進してくれた RoboCup 連盟に感謝したいと思います。将来的には本手法をさらに改良・整理し、手法概要とソースコードを公開することで、世界各国のチーム間の技術交流と後進チームの育成に貢献したいと考えています。

最後に、今に至るまで筆者を暖かく見守り、激励して下さいました恩師、諸先輩方、友人同志の皆様、そして家族に心より感謝の意を表します。

2023年3月

馬 躍航