

2020年度

学位論文[博士(工学)]

自律移動ロボットのためのノイズと誘拐問題にロバストな
リアルタイム自己位置同定法

東京工芸大学大学院
工学研究科
電子情報工学専攻
渡邊 香

目次

第 1 章	緒言	2
1.1	競技ロボットによる技術チャレンジ	2
1.2	自律移動ロボットによる自己位置同定技術	3
1.3	本研究の目的	4
第 2 章	ロボットのハードウェア構成	5
2.1	サッカーロボット概要	5
2.2	視覚システム	8
2.3	移動機構	9
2.3.1	オムニホイール	9
2.3.2	全方向移動機構	9
2.3.3	制御回路	11
2.4	その他の機構	13
2.4.1	保持機構	13
2.4.2	キック機構	13
2.4.3	その他のセンサ	14
第 3 章	全方位画像を用いた自己位置同定法	15
3.1	白線モデルの生成	16
3.1.1	HSI 色相変換による色抽出	16
3.1.2	白線モデルの校正	20
3.2	Model-based Matching 法を用いた自己位置の同定	22
3.2.1	フィールド領域と評価モデルの基本定義	22
3.2.2	白線モデルの定義	22
3.2.3	モデルに基づく適合度関数の定義	23
3.2.4	対象物探索問題の定式化	24
3.2.5	自己位置同定の性能評価	25
3.3	全探索による性能評価	28
3.4	パラメータ調整者の熟練度による自己位置同定の精度について	29
3.4.1	調整者毎の色調整による自己位置同定の精度の差	32
3.4.2	白線抽出結果の比較	36
3.4.3	フィールド抽出不足による白線モデルの喪失	39
3.4.4	誘拐状態以外の誤差検証	40
3.5	第 3 章まとめ	47

第 4 章	ノイズと誘拐問題に対する遺伝的アルゴリズムを用いたリアルタイム自己位置同定法	48
4.1	ノイズ問題・誘拐問題・リアルタイム性について	49
4.2	遺伝的アルゴリズムとは	51
4.3	GA を用いた対象物認識法	52
4.4	各種進化条件の設定	55
4.5	探索効率と自己位置同定精度の検証	59
4.6	誘拐状態における検証	61
4.7	ノイズに対するロバスト性の検証	67
4.8	実環境下における検証実験	73
4.9	第 4 章まとめ	78
第 5 章	結言	80
付録		87
A	パラメータ調整者別の色相調整結果を用いた自己位置同定結果	87
B	全てのノイズパターン	92
	謝辞	131

第 1 章 緒言

1.1 競技ロボットによる技術チャレンジ

近年，競技ロボットにおける様々な技術課題を通じて，研究・開発の促進と成果の普及を目指した技術チャレンジが多く実施されている^{1)~4)}．考慮すべき要素が多い実用上の問題とは異なり，競技上の課題として扱うことで一定の制約条件下に限定して研究・開発ができるため，基本的な要素技術の発展が期待できる．このような技術チャレンジの一つとしてサッカーを題材とした競技ロボットコンテスト，RoboCup 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⁵⁾．RoboCup 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，さまざま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⁶⁾．

RoboCup にはロボットによるサッカー競技「RoboCup サッカー」をはじめ，災害現場をテーマにしたフィールドで人命救助を行う「RoboCup レスキュー」，キッチンやリビングのような日常生活の場で人間との共同作業を追求する「RoboCup@ホーム」，将来の RoboCup を支える子供たちのリーグ「RoboCup ジュニア」の 4 分野に分かれている⁷⁾．RoboCup サッカーは其中でさらにロボットの大きさやルールによって「小型ロボットリーグ」「中型ロボットリーグ」「ヒューマノイドリーグ」「標準プラットフォームリーグ」「シミュレーションリーグ」に分かれており，本研究では中型ロボットリーグ（Middle Size League，以下 MSL）に用いるロボットの開発や要素技術の開発を行っている．

MSL は，縦横 52 cm 未満・高さ 80 cm のロボット 5 台でチームを構成し，RoboCup サッカー競技の中で最も大きい 18×12 m 以上のフィールドで競技を行う．MSL では，味方との通信は許可されているが，自己位置やボールの位置を含む周囲の状況を自身に搭載されているセンサのみで認識しなければならない．

1.2 自律移動ロボットによる自己位置同定技術

MSLにおいて競技を成立させるためには様々な技術課題をクリアする必要がある、その中でも実時間で実世界環境の認識を行う自己位置同定技術は、その先に続く戦略的協調動作の基点となるため、あらゆる競技において勝敗を決める重要な要素技術である⁸⁾。MSLでは基本的に屋内、かつパンチカーペット等を用いた簡易的なサッカーフィールドにおいて実施されるため、屋内における自己位置同定手法でしばしば用いられるような環境固定型デバイスの使用が困難である。近年自己位置推定等の研究で頻繁に使用されるレーザレンジファインダ (Laser range finder, 以下 LRF) は、ロボットを観測中心とした三次元的な距離計測に優れるため、固定型デバイスに頼らない自己位置同定のツールとして有用である^{9),10)}。しかし、RoboCupの競技フィールド内には位置同定に有用な三次元的な構造物が乏しいため、LRFを利用して計測した物体 (敵・味方ロボットやゴール等) との相対的な距離関係は正確に得られるが、フィールド内の絶対位置を推定することは困難である。

一般的に任意の空間内における自己位置同定に必要な指標の条件は、フィールド内のいかなる場所においても定常的に認識可能であること、及びフィールドの位置に依存した固有の特徴量を有することである。RoboCup 競技のフィールドにおいてこの条件を満たす特徴物は全域に描かれた白線であり、その認識はカメラを用いた画像情報に頼ることが多い。フィールド上に描かれた白線の形状を用いて自己位置を同定する手法は過去にも数多く提案されており、ハフ変換を用いる手法¹¹⁾ や誤差最小化に基づいた手法¹²⁾ が提案されている。しかし、ハフ変換を用いる手法は自己位置を推定する以外にも計算が発生するために処理時間が長く、誤差最小化法は局所的探索法となるため、初期位置の仮定が必要という問題がある。これらに対し、パーティクルフィルタによる Monte Carlo Localization (MCL)^{13),14)} を用いた手法が提案されており、多くのチームにおいて採用されている。MCLは大域的探索法であるためロボットの初期位置を仮定する必要がなく、散布するパーティクルの数を増やすことで精度を向上させることができる。しかし、パーティクルの数と処理時間はトレードオフの関係にあり、精度の向上が処理時間を増加させる問題がある。また、自己位置同定ではロボット同士の衝突やタイヤのスリップなどに起因する誤差の蓄積により、ロボットが真値とは全く異なる位置を自己位置として認識する問題があるが (以下、この問題を誘拐と呼ぶ)、MCLは誘拐問題に比較的脆弱であることが知られている。この問題に対してセンサをリセットする手法やパーティクルの分布を膨張させる方法¹⁵⁾ を用いることによって誘拐状態から復帰することができるが、これらの方法で誘拐状態から復帰するためには、近距離誘

拐 (0~4 m) で約 0.8 s, 遠距離誘拐 (4~8 m) では約 3 s の時間が必要である¹⁶⁾. ここ数年, MSL では速度 2~3 m/s で動作するロボットが主流であり, 上記の復帰時間では誘拐された状態から復帰するまでに競技状況は大きく変化してしまう.

1.3 本研究の目的

そこで本研究では, 誘拐状態からリアルタイムに復帰可能な自己位置同定手法を提案する. 具体的には, 全方位画像から得た白線形状に基づく探索モデルと既知フィールドデータを照合する Model-based Matching 法¹⁷⁾ をベースとして探索空間を形成し, 最適化処理に遺伝的アルゴリズム (以下 GA : Genetic Algorithm) を用いることで, リアルタイムに自己位置を同定する. 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^{18)~20)}. その最適化プロセスは系統的探索と発見的探索により構成され, この二面的な探索により局所的探索と同時に大域的探索を実現することができる. しかし, 局所的探索と大域的探索の分配は GA の各種進化条件の設定に大きく依存するため慎重に決定する必要がある. 本論文では, GA の大域的探索能力を利用するとともに, 条件設定の事前実験に誘拐問題を考慮した環境を用いることで, 誘拐問題に強い自己位置同定が実現できることを検証する.

本論文の構成は, 第 2 章に中型リーグ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 章では自己位置同定を行うまでの処理として, RoboCup におけるカメラ画像からの白線の認識, 白線情報の正規化のための距離校正処理, 白線モデルの生成とフィールドデータのマッチングによる自己位置同定法の構築について述べ, 全探索法における精度の確認を行う. さらに, 白線抽出する際に使用するパラメータの調整者の熟練度によって, 自己位置同定の精度がどのように変化するかを確認する. 第 4 章では探索法に GA を用いた場合の自己位置同定法の探索効率や精度について確認し, 実際の競技において問題になる誘拐問題とノイズに対するロバスト性の検証を行う. また, 実環境下における検証実験として, 実際にロボットをフィールド上で動作させ, 動的環境 (動画像を用いた自己位置同定) における有効性を確認する. そして, 最後に第 5 章において本研究のまとめを行う.

第 2 章 ロボットのハードウェア構成

本章では、次章以降に解説する自己位置同定のソフトウェアの解説・検証に先立ち、本研究で用いるサッカーロボットの概要を述べ、自己位置同定に絡む視覚システムと駆動機構を主としたロボット全体のハードウェア構成を解説する。

2.1 サッカーロボット概要

本研究とその関連研究では、RoboCup MSL におけるサッカー競技を実行する自律型サッカーロボットの要素技術を研究・開発しており、その成果の検証・発表の場として実際の競技に出場している。これまでに開発したロボット^{21),22)}と出場した大会、及びその成績を Fig. 2.1, Table 2.1 に示す。2009 年から本格的に JapanOpen に出場しており、近年では優勝争いに常に絡むようになってきている。さらに現在は検証の場を広げるために、海外で開催される競技会に参加している。



Fig. 2.1: Overview of previous robots

Table 2.1: Competitions and results

年	大会	場所	結果	使用ロボット
2008	Japan Open ※1	静岡	—	Y-I
2009	Japan Open	大阪	4位	Y-II
2010	Japan Open	大阪	予選落ち	Y-III
2011	Japan Open	大阪	準優勝	Y-IV, Y-V
2012	Japan Open	大阪	3位	M-I
2013	Japan Open	東京	準優勝	M-II
2014	Japan Open	福岡	準優勝	
2015	Japan Open	福井	準優勝	
2016	Japan Open	愛知	準優勝	
2017	Japan Open	石川	優勝	M-III
	World Championship	愛知	6位	
2018	Japan Open	岐阜	優勝	
2019	Japan Open	神奈川	準優勝	
	China Open	中国・紹興	3位	
	Asia Pacific	中国・天津	4位	

※1 テクニカルチャレンジのみ参加

現在のロボット²³⁾の構成図を Fig. 2.2 に示し、実際の外観を Fig. 2.3 に示す。MSL に出場する多くのチームは全方位カメラを採用しており、一般的に画像の取得範囲を考慮して視覚システムは最上部（サイズ規定：52 cm×52 cm，かつ高さ 80 cm によりカメラ高さは 80 cm）に搭載されている。カメラから取得された画像はメイン PC で画像処理され、自己位置の同定、敵機やボールの認識などの周囲情報の取得のために使用され^{24),25)}、それらの情報を基に次の行動・戦略を決定する。決定した行動・戦略の実現のため、ロボットの移動にはオムニホイールを用いた全方向移動機構を採用している。この移動機構は姿勢を変えずに前後左右に移動が可能であり、常に周囲の状況が変わっていく競技において有効である^{26),27)}。また、MSL ではドリブルやパス、シュートなど、ボールをキックすることがルールで求められているため、ロボットはソレノイドを使用したキック機構²⁸⁾、モータを利用した保持機構²⁹⁾を搭載している。これらに状況判断の補助要素としての様々なセンサやデバイスを加えたすべてのハードウェアが専用の制御ユニットで制御され、メイン PC（ノート型 PC）からの指示で動作する。




Fig. 2.2: Configuration of "M-III"



Fig. 2.3: Overview of "M-III"

2.2 視覚システム

ロボットは周囲環境（敵，味方，ボール，ゴール等）を認識するための視覚システムとして，Fig. 2.4 に示す 360 deg の視野を持つ全方位カメラを搭載している．全方位カメラは前方のみを認識可能な通常の単眼カメラとは異なり，1 枚の画像から全方向の情報を取得できるため，競技状況が素早く変化する MSL において有用である．

全方位カメラは解像度やサイズなどの関係により市販品の全方位カメラユニットではなく，個別で販売されているカメラと双曲面ミラーを組み合わせて自作した物を使用する．全方位カメラを構成するパーツを Fig. 2.5, 2.6 に示す．使用したカメラ Flea3³⁰⁾ の仕様は Table 2.2 となっており，小型でかつインターフェースとして USB3.0 を採用しているため，リアルタイムで高解像度の画像を取得することができる．双曲面ミラー³¹⁾ をカメラの上部に取り付け，カメラを上方向に向けて組み合わせることで全方位の画像を取得することが可能となる．




Fig. 2.4: Original omnidirectional camera unit



Fig. 2.5: Flea3 camera (FLIR Systems, Inc.)



Fig. 2.6: Hyperboloid mirror (Vstone Co.,Ltd)

Table 2.2: Camera specification

Interface	USB3.0
Frame Rate	60 fps
Power Requirements	5 V via USB3
Dimensions [W x H x L]	29×29×30 mm
Resolution	1280×1024

2.3 移動機構

MSLは、複数あるRoboCupの競技の中でも最も広いフィールド（22×16 m以上）が採用されており、ロボットはその中で周囲の状況によって適切に動作することが求められる。本研究で使用するロボットは、移動の即応性と移動パターンの多様性から全方向移動機構を採用している。ここではサッカーロボットの移動機構について説明する。

2.3.1 オムニホイール

全方向移動機構を構成するパーツは複雑であり、その中でも特に重要な要素がFig. 2.7に示すオムニホイールである。オムニホイールはフリーローラの働きにより全方向に移動が可能であるが、フリーローラが次々と接地するため、振動が発生する欠点がある。振動の大きさはロボット上部に搭載されたカメラ画像のブレに直結するため、振動はなるべく小さくするのが望ましい。そのため、オムニホイールを自作し、Fig. 2.8に示すようにフリーローラを柔らかい素材から製作することで振動を軽減している。

2.3.2 全方向移動機構

オムニホイールを用いた全方向移動機構では、Fig. 2.9のようにホイールを3個、もしくは4個搭載した機構が一般的である。本研究では、前進に対するトルクが大きい点や内部スペースを広く取れる点で競技に対し有利である点を考慮し、Table 2.3に示す高トルクモータ³²⁾を用いた4ホイールの機構を採用している。また、ホイールを4つ用いたロボットは常に全てのホイールが接地している保証がないため、Fig. 2.10の自作ホイールホルダにFig. 2.11に示すダンパ機構をFig. 2.12のように搭載することで、全てのホイールを地面に接地させている。



Fig. 2.7: Custom-made omni-wheel



Fig. 2.8: Custom-made free roller




Fig. 2.9: Differentiation by number of wheels

Table 2.3: RE40 Motor specification (maxon motor ag)

Nominal voltage	48 V
Weight	480 g
Length	91.7 mm
Diameter	$\phi 40$
Revolutions per minute	158 rpm/V
Torque	60.3 mNm/A




Fig. 2.10: Wheel holder




Fig. 2.11: Damper mechanism




Fig. 2.12: Omni-directional driving mechanism

2.3.3 制御回路

全方向移動機構のモータ制御には、Fig. 2.13, Table 2.4 の ESCON Module 50/5³³⁾ を使用しており、内部パラメータを設定することで自動的に回転数制御を行っている。駆動モータの制御に使用する ESCON コントローラ 4 つに加え、次節で説明する保持機構やキック機構、その他センサなどを一括して制御するために、RX62T³⁴⁾ マイコン (Table 2.5) を用いた Fig. 2.14 の制御ユニットを自作し、Fig. 2.15 に示す構成で全体の制御を行っている。独立したマイコンを使用して制御部分を分離することで、制御ユニットの処理は画像処理や行動戦略による負荷の変動から切り離され、安定的な駆動制御が可能となる。全方向移動機構を装備したロボット駆動部に制御回路類を埋め込んだ移動機構全体像を Fig. 2.16 に示す³⁵⁾。図中の拡張パネルは、必要に応じてセンサ等を拡張するためのターミナルである。




Fig. 2.13: ESCON Module 50/5

Table 2.4: ESCON specification (maxon motor ag)

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

Table 2.5: Renesas RX62T MCU specifications

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



Fig. 2.14: Custom-made control unit

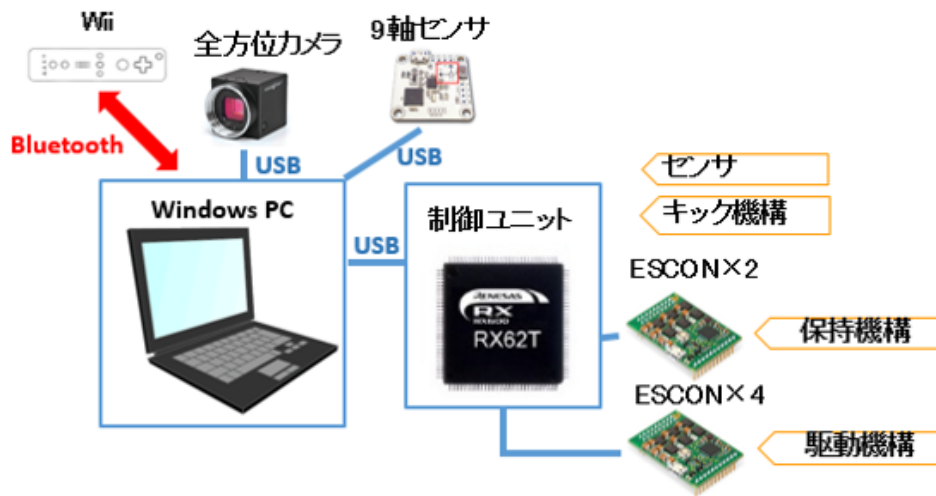


Fig. 2.15: Block diagram of control system



Fig. 2.16: Control system

2.4 その他の機構

本研究で使用するロボットは、前節までに説明した視覚システムと移動機構を搭載しているが、それ以外にも競技のために必要な機構や補助的なセンサを搭載している。ここでは、本研究に直接関連しない部分も含めて参考のために概要を紹介する。

2.4.1 保持機構

MSLの規定では、ロボットはボールの1/3までロボット内部に取り込むことが可能であり、ボールを保持したままで移動する際には、進行方向に対してボールが自然な回転方向を実現している必要がある。本研究のロボットはこれを実現するために Fig. 2.17 に示す保持機構を搭載している。衝撃吸収用のダンパ機構により懸架された左右のモータに接続されたタイヤを適正な回転数で制御することで、保持機構はボールの保持と同時に自然な回転を実現している。




Fig. 2.17: Ball-holding mechanism

2.4.2 キック機構

ロボットは競技において得点のためのシュート動作やパス動作を行う必要があるため、ボールを打ち出す機構として、ソレノイドを使用した Fig. 2.18 のキック機構を搭載している。Fig. 2.19 のバーを使用してキックの高低を打ち分けることで、幅広い戦略をとることができる。キック機構の制御回路図を Fig. 2.20 に示す。昇圧回路を経た 100 V の高電圧をコンデンサバンクに蓄電し、FET の開放によりソレノイドに大電流を流すことで、コイルを強力に励磁し、ソレノイド内部の鉄芯を打ち出すメカニズムとなっている。ゲートの開放時間の制御によりソレノイドに流す電流を変化させ、キックの強度を変更することが可能である。



Fig. 2.18: Ball-kicking mechanism




Fig. 2.19: Kicking bar

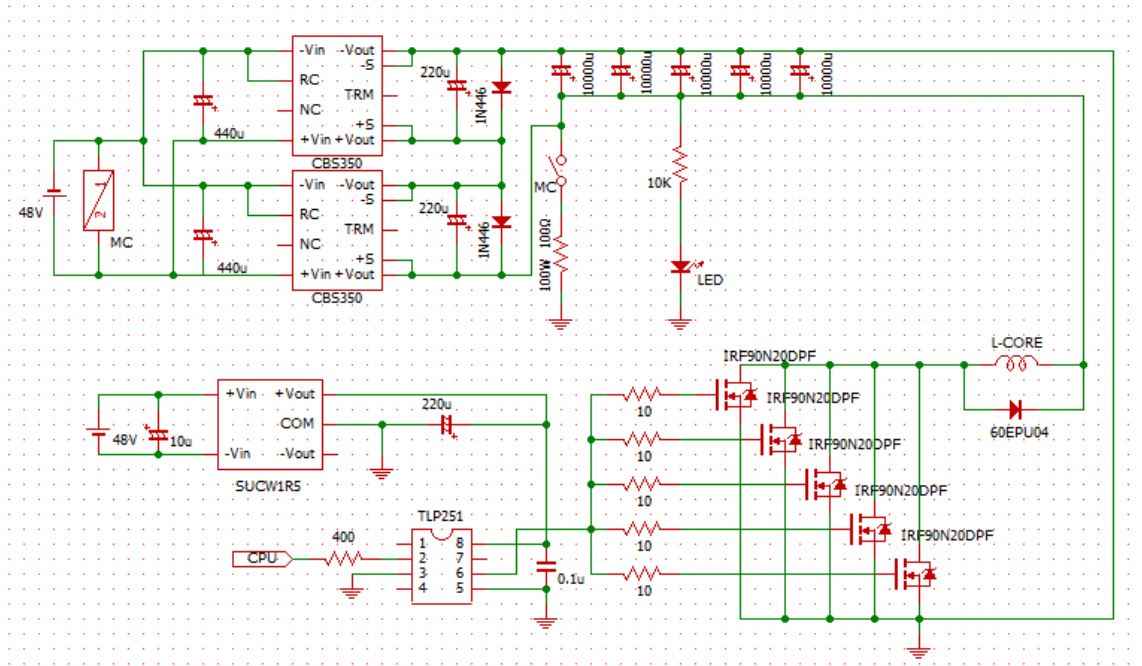


Fig. 2.20: Circuit of kicking mechanism

2.4.3 その他のセンサ

本ロボットにはここまで述べた機構やモジュールの他に、補助的な役割として加速度・角速度センサ、及び地磁気センサ（電子コンパス）を搭載している。加速度・角速度センサは、スリップの検知や走行誤差の補正のために使用しており、電子コンパスは本研究で提案する自己位置同定手法でも重要な要素であり、ロボットの姿勢角の検出に利用している。

第 3 章 全方位画像を用いた自己位置同定法

RoboCup では常に試合の状況が変化しており，ロボット自身も状況に応じて絶えずフィールド内を動き回らなければならない．そのような試合状況において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．一般的に任意の空間内における自己位置同定に必要な指標の条件は，フィールド内のいかなる場所においても定常的に認識可能であること，及びフィールドの位置に依存した固有の特徴量を有することである．ここで Fig. 3.1 に示す競技フィールドに着目すると，RoboCup 競技のフィールドにおいてこの条件を満たす特徴物は全域に描かれた白線であり，その認識はカメラを用いた画像情報に頼ることが多い．そこで本研究で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手法を構築する．




Fig. 3.1: Soccer field of RoboCup MSL

3.1 白線モデルの生成

MSL では周囲環境を認識するためのセンサとして、多くのチームが 360deg の視野を持つ全方位カメラをロボットに搭載しており、ロボットの周囲情報が一度に取得可能となる。本研究で用いるロボットでも全方位カメラを搭載し、Fig. 3.2 のような全方位画像が取得できる。フィールド内で取得する全方位画像には、ロボット周囲の白線情報だけでなく、ボールや敵、フィールド外の情報なども多く存在する。白線を取得するために全方位画像全体から白色抽出を行うと、ボールや敵はルールによって色が指定されているため抽出されないが、Fig. 3.3 のようにフィールド外に存在する同色ノイズ（白い壁や観客の白い服など）が抽出される。ここでは白線は必ずフィールドの内側に存在する特性を利用し、緑色のフィールド領域を抽出し、その範囲内からさらに白色の抽出を行う。

3.1.1 HSI 色相変換による色抽出

全方位カメラより入力された全方位画像は、一般的な RGB 表色系で表現されている。RGB 表色系とは一般的に加法混色を表現するのに使われており、各色につきそれぞれ 256 階調の濃淡レベルを持っている。しかし、RGB 表色系は原色濃度の組み合わせで色を表現するため、様々な合成色の色調を人間の感覚に合った色彩に処理することは容易でないことが知られている。そこで本研究では、人間の感覚として容易に色彩を表現することが可能な手法として、画素情報を色相 (Hue)、彩度 (Saturation)、明度 (Intensity) で表す HSI 表色系³⁶⁾を用い、カラー画像の認識を行う。




Fig. 3.2: Original image




Fig. 3.3: White noise in the detection image

RGB 直交座標系において、3 軸に接する立方体を考えると、R、G、B とその補色 C(シアン)、M(マゼンタ)、Y(イエロー) は Fig. 3.4 に示すような位置関係にある。この RGB 立方体の主対角軸を明度軸 I とし、

$$I = \max(R, G, B) \quad (\text{max は最大値を与える関数}) \quad (3.1)$$

と定義する。ここで、 I 軸に直行する平面に RGB 立方体を平行投影すると Fig. 3.5 に示すような正 6 角形が形成される。ある点 P が与えられたとき、点 P を通り I 軸に直行する平面上で色相 H と彩度 S を R 方向を 0 deg とし Fig. 3.6 のように定義する。こうして、RGB と HSI の間に Fig. 3.7 に示すような 6 角錐カラーモデルが形成される。




Fig. 3.4: RGB cube




Fig. 3.5: Parallel projection of RGB cube




Fig. 3.6: Definition of H and S

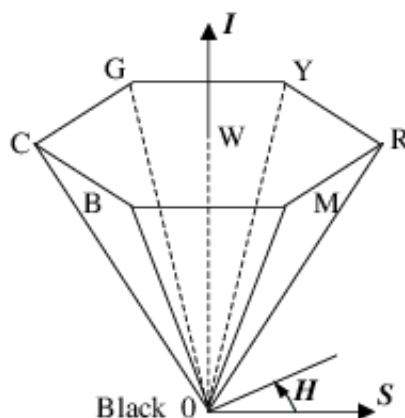


Fig. 3.7: HSI color model

RGB 表色系から HSI 表色系への変換方法を以下に示す.

i) $I = 0$ のとき

S と H を以下のように定める.

$$S = 0, \quad H = \text{不定} \quad (3.2)$$

ii) $I \neq 0$ のとき

まず, S を次式で定義する.

$$S = (I - i)/I \quad (3.3)$$

ここで, $i = \min(R, G, B)$ (\min は最小値を与える関数).

次に r, g, b を以下のように求める.

$$r = (I - R)/(I - i) \quad (3.4)$$

$$g = (I - G)/(I - i) \quad (3.5)$$

$$b = (I - B)/(I - i) \quad (3.6)$$

最後に, H を以下のように定める.

$$R = I \quad \text{のとき} \quad H = 60(b - g) \quad (3.7)$$

$$G = I \quad \text{のとき} \quad H = 60(2 + r - b) \quad (3.8)$$

$$B = I \quad \text{のとき} \quad H = 60(4 + g - r) \quad (3.9)$$

ただし, $H < 0$ のときは値に 360 を加えるものとする. 以上の手法は Smith の 6 角錐モデルとして知られており, HSV(Hue, Sturation, Value) 表色系とも呼ばれる. 以降, 本論文では上記の表色系を HSV 表色系と呼ぶ.

Fig. 3.2 からフィールド範囲の抽出を行うため, 上述した HSV 変換式より, 各項の範囲を定めた. HSV をそれぞれ適切に調整し, フィールド範囲のみを抽出した結果を Fig. 3.8 に, Fig. 3.8 の抽出範囲を Fig. 3.2 に当てはめた結果を Fig. 3.9 に示す. Fig. 3.9 からさらに HSV 変換式より各項を適切に調整することで, Fig. 3.10 のようにノイズのない白線情報を取得することが可能となった. ここで参考として, 緑のフィールドの抽出範囲と白線抽出範囲を Table 3.1 に示す.




Fig. 3.8: Result of field range detection



Fig. 3.9: Result of field extraction




Fig. 3.10: White-line in detection image

Table 3.1: Parameters for color detection of green field and white lines

	Hue	Sturation	Value
Green field range	62~128	56~120	30~125
White line range	28~330	0~50	198~255

3.1.2 白線モデルの校正

白線情報のみを抽出した Fig. 3.10 は，その特性により全方位画像上の距離変化は非線形であるため，直線が歪み正確なフィールド形状が得られていないことがわかる．そこで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 Fig. 3.11 の変換を行うことで，Fig. 3.12 のように歪みが解消され，ロボット周辺の本来の白線形状情報が得られる．これを距離校正と言う^{37),38)}．

Fig. 3.12 はロボットの現在位置を画像中心とした周囲の白線形状情報を表しており，フィールド全体の白線と照合することで現在位置が特定できる．しかし，一般的に環境情報と白線形状情報の照合を行う場合，白線形状の情報量（ここでは Fig. 3.12 の抽出点の数）は，照合時間に直接影響を及ぼすため，必要十分で最適な情報量に設定する必要がある．そこで，事前実験から得られた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. 3.13 を評価モデルとして用いる．具体的には，全方位画像から生成したモデルは近距離の白線をより多く取得する特徴を有するため，距離に依存した白線のサンプリングを行っている．ここで参考として，各地点から得られるモデル例を Fig. 3.14 に示す．

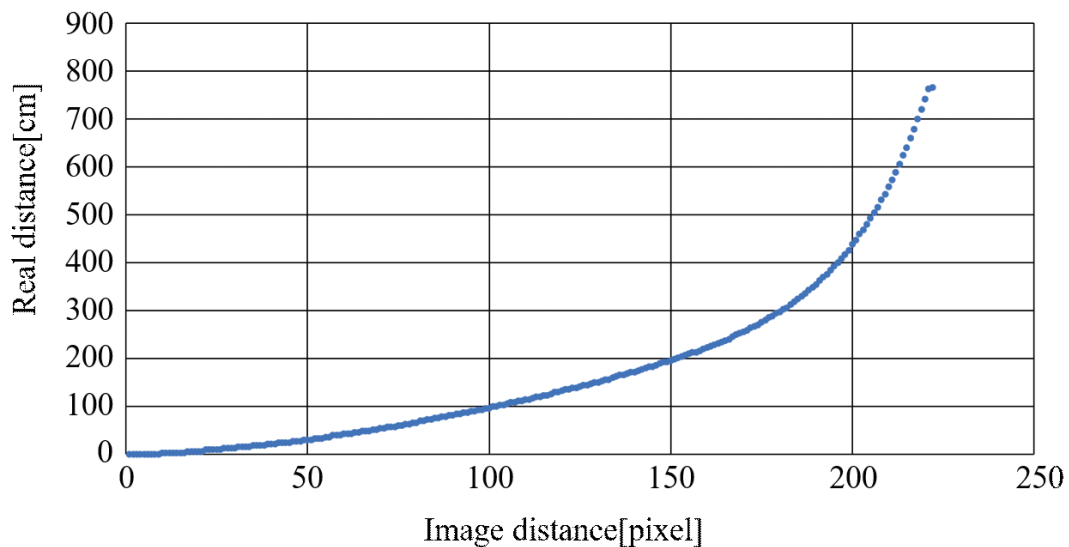


Fig. 3.11: Distance calibration function




Fig. 3.12: Orthogonalized image




Fig. 3.13: Search model

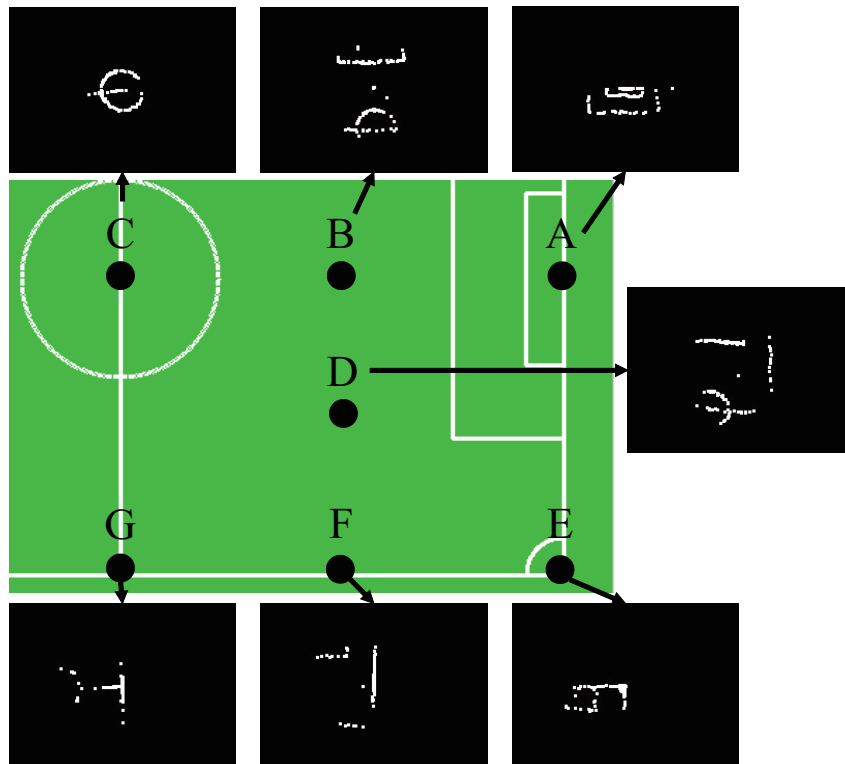


Fig. 3.14: Model examples at each position

3.2 Model-based Matching 法を用いた自己位置の同定

本研究では、Model-based Matching 法によって適合度を算出し自己位置を同定する。Model-based Matching 法とは、あらかじめ知識として得たモデル（評価モデル）を用いて入力される画像に対する評価を行い、目的とする対象物の位置を検出する手法である。但し、RoboCup における自己位置同定において視覚システムが得るのは全体モデル（サッカーフィールド）の一部である。つまり、ここでの知識はサッカーフィールド全体の形状であり、視覚システムから得られるモデルを用いてサッカーフィールド内の位置を推定することが本研究の目的である。本章では全方位カメラから得られるロボット周囲の白線形状をモデルとした、Model-based Matching 法について解説を行う。

3.2.1 フィールド領域と評価モデルの基本定義

Fig. 3.15 に示すように、サッカーフィールドの領域 Ω を

$$\Omega = \{ \mathbf{r} = (x, y) \mid 0 \leq x \leq x_{max}, 0 \leq y \leq y_{max} \} \quad (3.10)$$

と定義する。ここで x_{max} , y_{max} は正の定数であり、フィールド領域 x , y 方向の限界値である。 Ω 内における評価モデルの構成点を $\mathbf{r}_s = (x_s, y_s)$ とすると、評価モデルの輪郭は Fig. 3.15 に示すように $s(\mathbf{r}_s) = 0$ で定義される。このとき、モデル内の座標の集合 S は次式で与えられる。

$$S = \left\{ \mathbf{r}_s \in \mathbb{R}^2 \mid s(\mathbf{r}_s) \leq 0 \right\} \quad (3.11)$$

3.2.2 白線モデルの定義

前節で述べた評価モデルの基本定義に位置／姿勢パラメータを組み込み、本研究で使用する白線モデルを定義する。Fig. 3.16 に示す Ω 内で位置 $\mathbf{r} = (x, y)$ 、姿勢 θ を持つ白線モデルを考える。白線モデルの存在する範囲を

$$\Gamma = \left\{ \underline{\phi} = (\underline{x}, \underline{y}, \underline{\theta}) \in \mathbb{R}^3 \mid \mathbf{r} = (x, y) \in \Omega, -\pi < \underline{\theta} \leq \pi \right\} \quad (3.12)$$




Fig. 3.15: Object model and field area

と与える. さらに白線モデルの領域を表す集合 \underline{S} は, \mathbf{r}_s と $\underline{\phi}$ の関数として,

$$\underline{S}(\tilde{\mathbf{r}}(\mathbf{r}_s, \underline{\phi})) = \left\{ \tilde{\mathbf{r}} \in \Omega \subset \mathbb{R}^2 \mid \tilde{\mathbf{r}} = \mathbf{T}(\underline{\theta})\mathbf{r}_s + \underline{\mathbf{r}}, \mathbf{r}_s \in S, \underline{\phi} \in \Gamma \right\} \quad (3.13)$$

と表すことができる. ただし,

$$\begin{aligned} \tilde{\mathbf{r}}(\mathbf{r}_s, \underline{\phi}) &= \mathbf{T}(\underline{\theta})\mathbf{r}_s + \underline{\mathbf{r}} \\ &= \begin{bmatrix} \cos \underline{\theta} & -\sin \underline{\theta} \\ \sin \underline{\theta} & \cos \underline{\theta} \end{bmatrix} \begin{bmatrix} x_s \\ y_s \end{bmatrix} + \begin{bmatrix} \underline{x} \\ \underline{y} \end{bmatrix} \end{aligned} \quad (3.14)$$

である.

3.2.3 モデルに基づく適合度関数の定義

フィールド領域 Ω における白線モデル内の輝度値分布を,

$$p = p(\tilde{\mathbf{r}}), \quad \tilde{\mathbf{r}} \in \Omega \quad (3.15)$$

と表す. $\tilde{\mathbf{r}}$ は白線モデル内の画素の位置であり, p はその位置における輝度値を表す. フィールドデータと白線モデル領域 \underline{S} との相関を表す関数である適合度関数 F を,

$$F(\underline{\phi}) = \sum_{\tilde{\mathbf{r}} \in \underline{S}} p(\tilde{\mathbf{r}}) \quad (3.16)$$

と定める.




Fig. 3.16: Movement of white-line model

3.2.4 対象物探索問題の定式化

S における輝度値情報 $p(\bar{r})$ がフィールドデータの輝度値情報の位置/姿勢と一致したとき、 $F(\underline{\phi})$ が最大値をとるため、フィールドデータ内におけるロボットの位置/姿勢の同定は、 F を最大にする $\underline{\phi}$ を探索する非線形関数の最大値探索問題に変換される³⁹⁾。ここで、ロボットの実際の位置/姿勢が $\phi_p = [x_p, y_p, \theta_p]$ であり、 $F(\phi_p) > F(\underline{\phi})$ 、 $\phi_p \neq \underline{\phi}$ かつ $F(\phi_p) = F(\underline{\phi})$ 、 $\phi_p = \underline{\phi}$ 、 $\underline{\phi} \in \Gamma$ を満たすとき、 ϕ_p を探索する問題は、

$$\begin{aligned} & \text{find } \underline{\phi} \text{ to maximize } F(\underline{\phi}) \\ & \text{subject to } \underline{\phi} \in \Gamma \end{aligned} \tag{3.17}$$

と表される。ここでは上式の解 ϕ_p を求める手法として全探索法を用いる。

3.2.5 自己位置同定の性能評価

本研究では Fig. 3.17 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 Ω とし、評価モデルとの Model-based Matching 法によって適合度を算出し自己位置を同定する。ロボット寸法規定 (52×52 cm) に対して、必要な自己位置同定精度を考慮し、探索空間 Ω の仮想フィールドデータを 1 pixel 当たり 10 cm とした 220×160 pixel を用いている。

ここで Fig. 3.18 に示す人工モデルを用い、Fig. 3.19 のように Ω 内全体に対し、 \underline{S} を 0~360 deg 回転させ評価を行う全探索法により、適合度 $F(\phi)$ を計算して自己位置同定精度を検証する。探索空間 Ω 全体における適合度 $F(\phi)$ を Fig. 3.20 に示す。検証のために作成した人工評価モデルの真値の地点において適合度 $F(\phi)$ は極大値となり、自己位置を正しく同定できていることがわかる。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ている。




Fig. 3.17: Matching space




Fig. 3.18: Artificial model




Fig. 3.19: Model matching

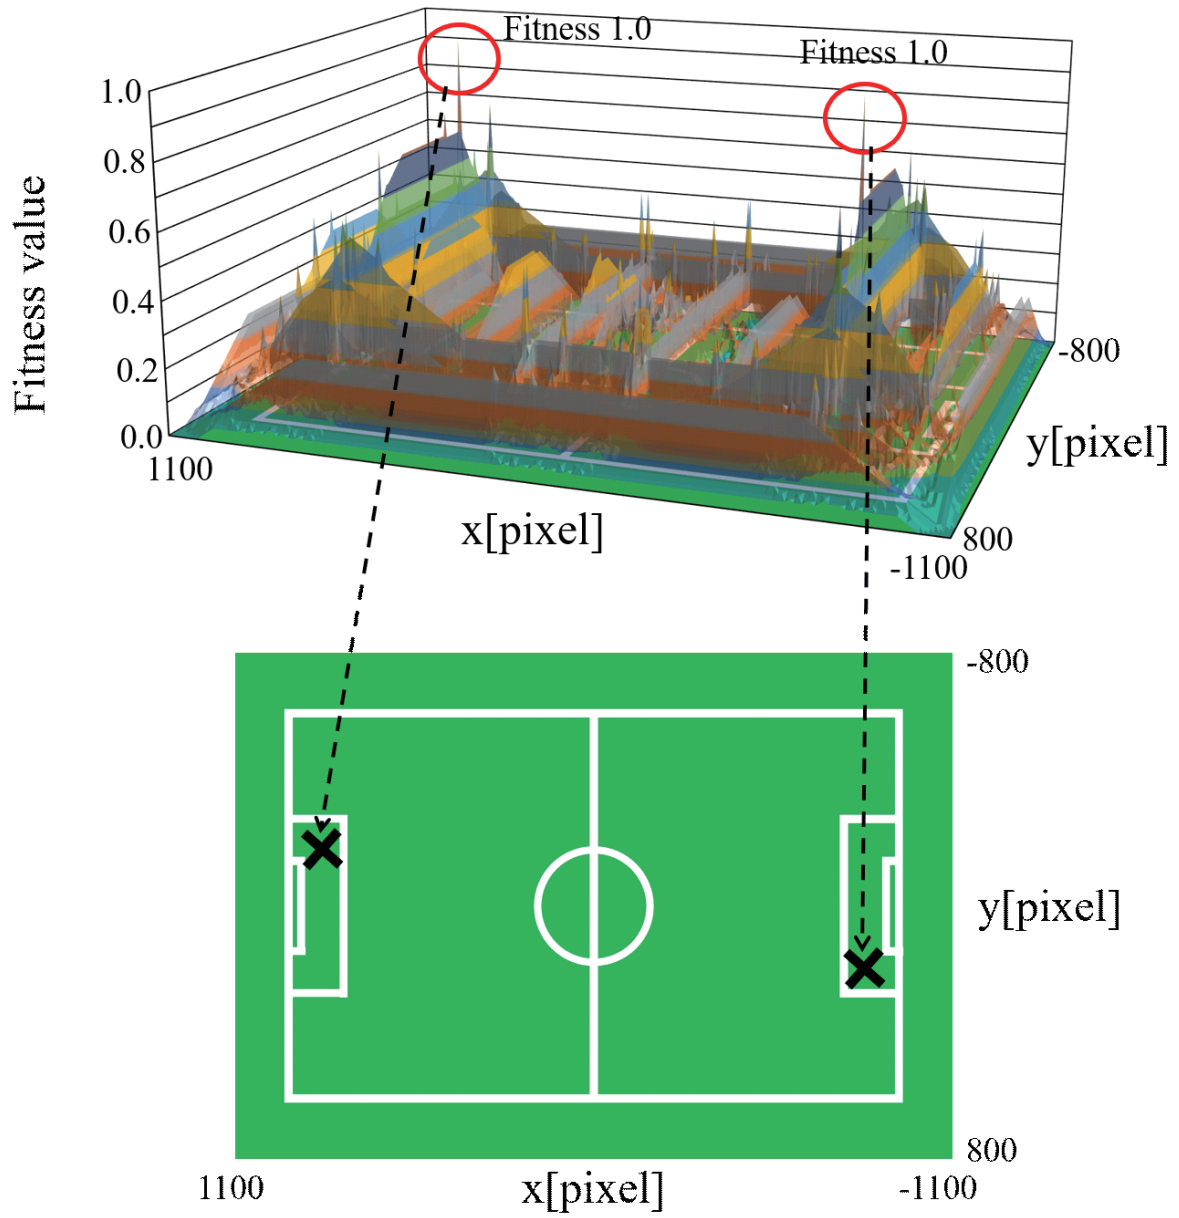


Fig. 3.20: Fitness value calculated by fitness function $F(\underline{\phi})$. The fitness value was set to a maximum of 1.0 by normalizing it with the maximum value at the target position.

3.3 全探索による性能評価

前節で述べた自己位置同定法を実際のロボットに用い、ロボットから取得した全方位カメラ画像における精度検証を行う。ここではフィールド全域の探索精度の検証が目的であるため、探索時間は考慮せず、全探索法を用いている。探索範囲は対称条件を踏まえ、22×16 m フィールド（白線外形は18×12 m）の4分の1を範囲とし、Fig. 3.21 に示す範囲内1 m 間隔の地点において、検証座標と自己位置同定結果の誤差を求めた。Fig. 3.22 に示す検証の結果より、最大誤差 36.1 cm、平均誤差 12.8 cm となり、フィールドサイズと比較しても誤差の値は小さく、自己位置を高精度で検出できている⁴⁰⁾。

ここでは、電子コンパスの検出角度を基準に ± 64 deg の姿勢を探索している。さらに、220×160 pixel の仮想フィールドデータに対して探索しているため、全探索法を用いた自己位置同定法では探索時に計算する全てのモデルの個数（総探索点数）は 4505600 点となる。これら全ての探索にかかる処理時間は1枚の入力画像毎に約 3000 ms が必要となるため、全探索法を用いた自己位置同定法では、競技中の状況変化への追従が難しい。以降、本報では自己位置同定法の計算コストの比較に上述の総探索点数を用いる。

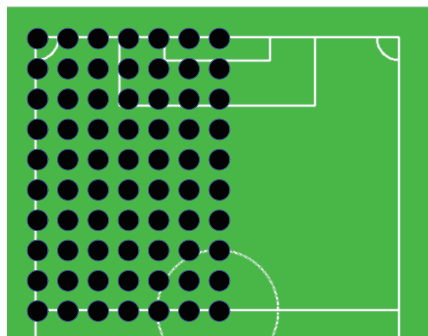


Fig. 3.21: Experimental position

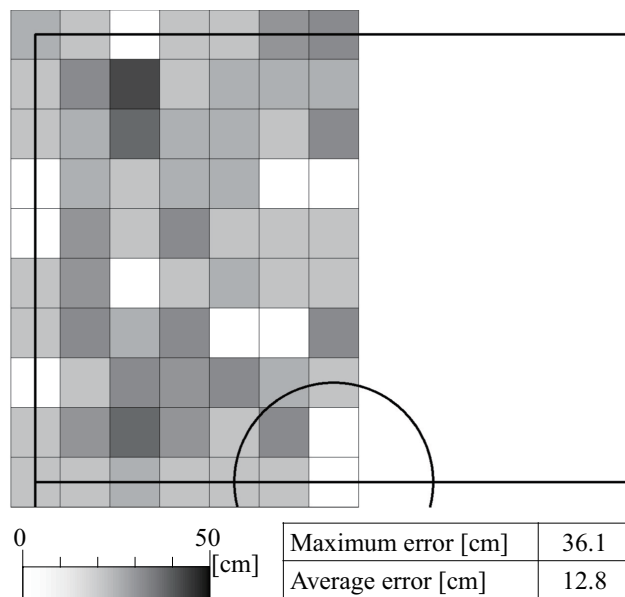


Fig. 3.22: Error in self-localization using whole searching . The severity of the error corresponding to the checking points is indicated by the brightness of the gray scale.

3.4 パラメータ調整者の熟練度による自己位置同定の精度について

実際の競技では前節までに説明したように HSV 色変換式を用いてフィールド範囲と白線の抽出を行う。そのため、競技に出場するロボットそれぞれに担当者を決めて各自が試合前に調整を行う。距離校正はロボットごとにカメラの取り付けしている高さや角度が異なるためロボットごとに生成が必要であるが、基本的に一度生成すればカメラの高さや角度が変わらない限り再調整の必要はない。一方、会場によって使用するフィールドのパンチカーペットや照明などの環境が異なるため、色合い（色相・彩度・明度）が異なる。また、会場の環境だけでなく、時間帯に依存してパラメータの値が変化するため、試合前には必ず色抽出調整の確認と再調整が必要となる。さらに、各ロボットには戦略上のポジション（ゴールキーパー等）が決まっており、ポジション毎に認識するために必要な色抽出範囲などが微妙に異なるため、すべてのロボットに同じパラメータを用いることはできない。

MSL のルールでは試合開始 30 分前から実際の競技用コート内で調整する時間が与えられており、その時間内ですべてのロボットの調整を終えなければならない。しかし、ロボットのポジション毎に異なる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、担当者が熟練者でない場合、調整の結果が不出来なものとなる。実際に元画像 Fig. 3.23 に対し熟練者が行った色抽出調整結果と、初心者が行った色抽出調整結果をそれぞれ Fig. 3.24~3.27 に示す。フィールドの抽出結果は緑色に、白線の抽出結果は青色にそれぞれ塗りつぶしており、Fig. 3.25, 3.27 は Fig. 3.24, 3.26 の一部を拡大したものである。Fig. 3.24 の熟練者がフィールドの形状と白線をほぼ抽出できているのに対し、Fig. 3.26 の初心者はフィールドの形状が綺麗に抽出できておらず、さらに遠方の白線も抽出できていない。

本節では試合前のパラメータ調整の内、最も調整頻度の高い色抽出調整において色抽出調整の熟練度がどの程度自己位置同定の精度に影響を与えるのか検証する⁴¹⁾。




Fig. 3.23: Original image




Fig. 3.24: Result of color adjustment by an expert. The detected field range and white lines are represented in green and blue, respectively.




Fig. 3.25: Enlarged image around the end line. The expert detected the white end line of the MSL field inside the red circle.




Fig. 3.26: Result of color adjustment by a beginner




Fig. 3.27: Enlarged image around the end line. The beginner could not detect the white end line of the MSL field inside the red circle.

3.4.1 調整者毎の色調整による自己位置同定の精度の差

調整者毎の色調整の違いを検証するため、本研究室の学生 19 名が同じロボットを使用して色抽出調整のみを行い、各調整者の色抽出調整パラメータを用いて、Fig. 3.28 に示す点で自己位置同定精度を導出した。この時、色相調整結果以外で精度の差を出さないようにするため、色調整以外のパラメータはすべて同じものを用いている。すべての調整者の最大誤差、平均誤差及び誘拐率を Table 3.2 に示す。なお、背景色がグレーになっている調整者は本研究室において比較的日常的に調整を行っている者、または大会に出ている回数が多く、調整を何度も行っている熟練者を示している。ここでは主に精度の話ではなく、初心者が調整することによって遠距離誘拐が多く発生することを確認するため、真値からの誤差が 100 cm を超える状態を対象として検証した。熟練者・初心者別の最大誤差、平均誤差と平均誤差率を Table 3.3 に示し、調整者毎の誘拐率のグラフを Fig. 3.29 に示す。なお、厳密には誘拐された場所についてはモデル形状に依存するため、誘拐量（誤差量）は意味を持たないが参考のため表記する。また、誘拐率は全探索点 70 点から何点誘拐状態になったかの割合を示している。

Table 3.3 や Fig. 3.29 に示したように熟練者と初心者では基本的に誤差率に大きな差があり、熟練者である調整者 A ～ L までは誘拐状態に陥らないのに対し、初心者では誘拐状態になる場合が多い。これらの結果から色抽出調整は自己位置同定の精度に影響を与えていることが明らかであるため、次節から色抽出調整がどのように自己位置同定の精度に影響を与えるのかを特に特徴的な結果となった Fig. 3.30 内の赤枠の箇所において検証する。ここで、参考として各調整者の精度マップを Fig. A.1 ～ A.19（付録）に示す




Fig. 3.28: Experimental positions




Fig. 3.29: Kidnapping rate by adjuster

Table 3.2: Error rate by adjuster

Person	Maximum Error [cm]	Avg Error [cm]	Kidnapped rate [%]
A	31.6	12.0	0.00
B	41.2	11.8	0.00
C	36.1	11.8	0.00
D	31.6	11.2	0.00
E	22.4	11.7	0.00
F	44.7	13.5	0.00
G	53.9	15.7	0.00
H	90.6	14.3	0.00
I	31.6	11.1	0.00
J	30.0	11.5	0.00
K	41.2	12.1	0.00
L	31.6	10.8	0.00
M	1560.0	33.2	1.43
N	1580.0	59.4	4.29
O	890.0	24.1	1.43
P	890.1	24.0	1.43
Q	1258.7	50.4	2.86
R	1630.0	92.8	7.14
S	1583.2	36.2	1.43

Table 3.3: Comparison of the results by expert and beginner

	Expert	Beginner
Maximum error [cm]	90.6	1630.0
Average error [cm]	12.3	45.7
Average error rate [%]	0.00	2.86

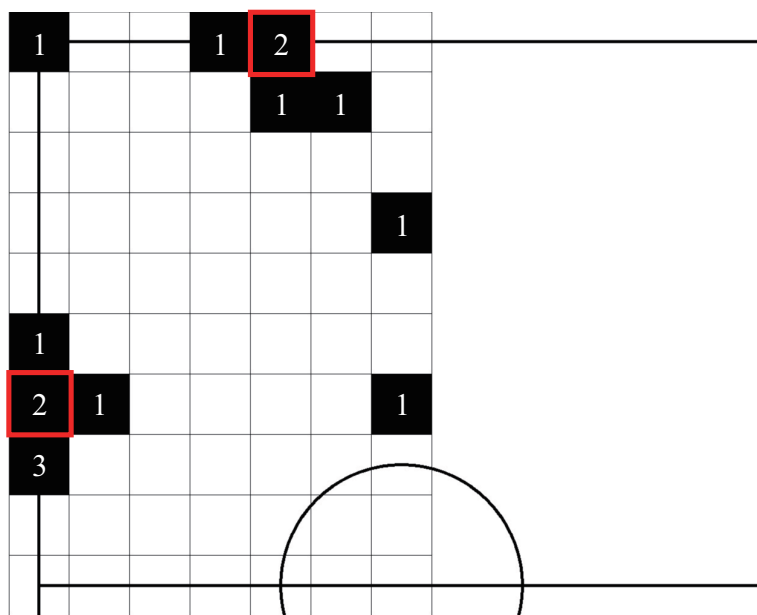


Fig. 3.30: Location of kidnapping. The black cells represent the position at which the robot is kidnapped in the accuracy map of each adjuster. The number in each black cell represents the number of times the robot is kidnapped at that position. The red boxes indicate the positions that will be verified in detail later.

3.4.2 白線抽出結果の比較

色抽出調整が原因で誘拐状態になる理由として、白線情報が正確に認識できていない可能性が考えられる。そこで、Fig. 3.31 の × 印の位置における調整熟練者 A と調整初心者 Q の白色抽出結果を確認する。Fig. 3.32 ~ Fig. 3.35 に熟練者 A の色抽出調整結果とそれを用いた自己位置同定結果を、Fig. 3.36 ~ Fig. 3.39 に初心者 Q の色抽出調整結果と自己位置同定結果をそれぞれ示す。

熟練者 A (Fig. 3.33) と初心者 Q (Fig. 3.37) の色抽出調整結果では、初心者 Q は遠方の白線が抽出できていないことがわかる。具体的には、熟練者 A (Fig. 3.34) はペナルティエリアが取得できているのに対し、初心者 Q (Fig. 3.38) はほぼサイドラインのみしか抽出できていない。このため、Fig. 3.35 のように熟練者 A は自己位置の真値に近い地点を同定したが、初心者 Q は Fig. 3.39 の通り誘拐状態になった。

競技環境ではフィールドの場所に依存して光環境が異なるため、ある場所で完全に周囲の白線情報が取得できても別の場所では白線情報が取得できない場合がある。熟練者と初心者の明確な違いは、熟練者は色抽出調整を行う際に 1 か所だけでなく、フィールド全体で確認を行い、フィールドのどの場所においても平均的に白線情報が取得できるようにパラメータを調整するが、初心者は熟練者と同様にフィールド全体を使い調整を行ってもパラメータを平均化することが難しい。これは熟練者は日常的に色抽出調整を行う事によって、フィールド全体の状態から平均的なパラメータを調整する感覚を養っているからであると考えられる。




Fig. 3.31: Verification points




Fig. 3.32: Result of color adjustment by expert A




Fig. 3.33: Enlarged image around the center line. Expert A could detect the white center line of the MSL field.




Fig. 3.34: Result of white adjustment by expert A




Fig. 3.35: Result of self-localization by expert A. The red X mark indicates the detected position. The red points represent the matching model.




Fig. 3.36: Result of color adjustment by beginner Q




Fig. 3.37: Enlarged image around the center line. Beginner Q could not detect the white center line of the MSL field.




Fig. 3.38: Result of white adjustment by beginner Q




Fig. 3.39: Result of self-localization by beginner Q

3.4.3 フィールド抽出不足による白線モデルの喪失

前節では熟練者と初心者の白線情報抽出の比較を行ったが、自己位置同定ではフィールド範囲の緑色抽出情報も色相情報として用いている。そこで本節ではフィールド範囲の抽出の確認を行う。

初心者 S の色相調整結果を Fig. 3.40 に示す。フィールドを抽出した範囲から白線抽出を行うため、Fig. 3.40(a) のように白線情報単体で見ると正常に白線の特徴を抽出できていても、フィールド範囲が正常に抽出できていない (b) と論理積を取ると (c) のように白線情報はほとんど見えなくなる。この結果、得られる白線モデルが (d) のように特徴点を持たないモデルとなり、フィールド上の様々な地点において適合度が高く、誘拐状態になりやすいモデルを生成してしまう。

フィールド範囲の抽出も白線の抽出同様に場所によって光環境が異なるため、フィールド全体を確認する必要がある。白線情報は自己位置同定の精度に直結しているため、調整者は白線抽出についてはフィールド全体を確認しながら調整を行うが、フィールド範囲の抽出に関しては軽視しがちである。

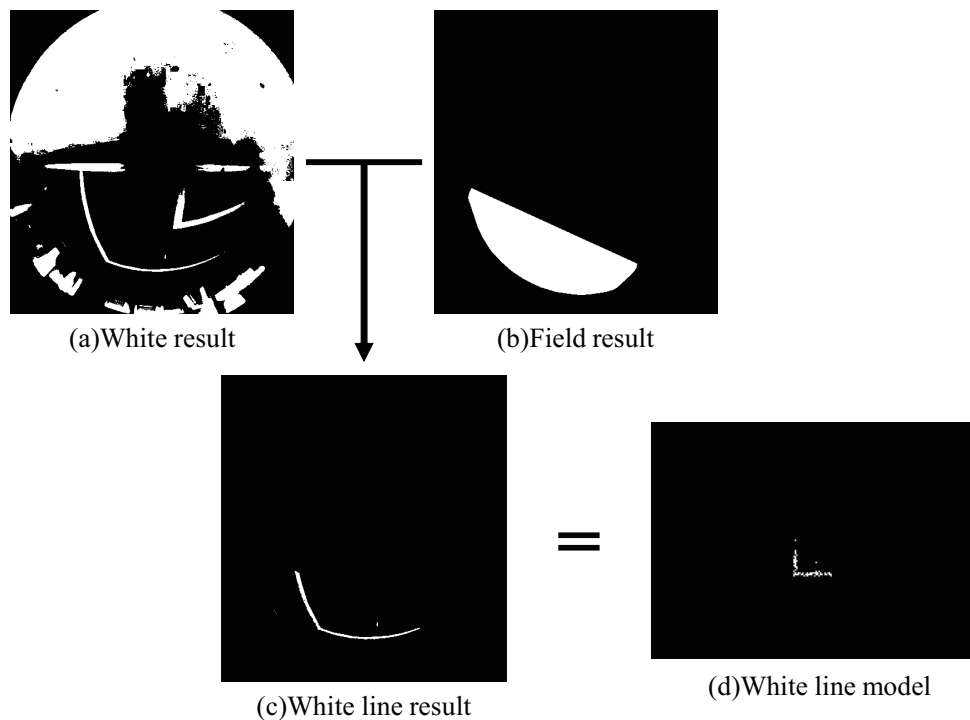


Fig. 3.40: Flow of making the white-line model. The white-line model lacks the end line because of insufficient field result.

3.4.4 誘拐状態以外の誤差検証

前節では誘拐状態に陥る原因になる色抽出調整の結果を検証した。続いて誘拐状態以外の誤差について検証を行う。全調整者の自己位置結果の誤差を大きさ別にカウントしたグラフを Fig. 3.41 に、誤差が 40 ~ 100 cm になった個所を塗りつぶした画像を Fig. 3.42 に示す。Fig. 3.41 を確認すると、誤差 40 ~ 100 cm は頻度が極端に低く、多くの自己位置同定の誤差は 40 cm 未満であることがわかる。そこで誤差が 40 cm 以上であった Fig. 3.42 の赤枠の地点において熟練者と初心者と比較し、誤差が大きくなった原因を検証する。

熟練者 A と初心者 Q の色抽出調整結果と自己位置同定結果をそれぞれ Fig. 3.43 ~ Fig. 3.48 に示す。この時の自己位置同定結果の誤差は熟練者 A は真値から 10 cm、初心者 Q は 70 cm であった。Fig. 3.44 と Fig. 3.47 を比べると、Fig. 3.44 の熟練者の方が、エンドラインなどのより遠方の白線情報が抽出できているため、白線モデルを作成した際に Fig. 3.45 ではゴールエリア付近の情報が抽出できており誤差は微小となっている。対して、Fig. 3.48 の初心者は、センターサークルが抽出できているため大きく自己位置がずれることはないが、ゴールエリア付近の白線がほとんど抽出できていないので、誤差が大きくなっている。

熟練者 A と初心者 Q がそれぞれの白線部分を抽出できていたのかを抽出画像全域においてさらに詳細に比較した。熟練者 A のみが抽出した点は 414 点であり、初心者 Q のみが抽出した点は 97 点であった。特に差が大きかったゴールエリア付近の熟練者 A と初心者 Q の白線抽出結果を比較したものを Fig. 3.49 に示す。画像中の黄色の点が熟練者 A のみが抽出した点で、水色の点が初心者 Q のみが抽出した点となっている。Fig. 3.49 の結果より、熟練者 A のみがゴールエリアとペナルティエリアの側面部分の抽出ができていることがわかる。

続いて、初心者 Q は白線のどこが抽出できていないのか検証を行う。初心者 Q の白線抽出情報を色相 (H)・彩度 (S)・明度 (V) の要素別に抽出した画像と、フィールド範囲を合わせた 4 枚すべての論理積を取った比較画像を Fig. 3.50 に示す。ここで、Fig. 3.50 内の赤の線は HSV で抽出できた最も遠くの白線 (エンドライン) を示しており、緑の線はフィールドの抽出範囲の最奥を示している。色相・彩度・明度のすべてでペナルティエリア側面が抽出できているが、フィールド範囲の抽出が不完全であるため論理積を取ると白線が消えてしまう。白線抽出を行う際には HSV の抽出結果だけでなくフィールド抽出範囲も同時に積算しているため、フィールド抽出範囲が不完全だと 3.4.3 節と同様に白色抽出しても白線として認識されない。そこで、熟練者 A と初心者 Q のフィールド範囲の抽出結果を比較した結果画像を Fig. 3.51 に示す。Fig. 3.49 と同様に熟練者

Aのみ抽出した点を黄色とし，初心者Qのみ抽出した点を水色として処理しているが水色の点は1つもなく，熟練者Aが一回り大きく抽出しているのがわかる．これらの結果より，初心者Qのパラメータでは白色パラメータは正常にゴールエリア付近を抽出できているが，フィールド抽出範囲外のため，最終的に抽出している白線情報にゴールエリア付近が含まれないことがわかった．

さらに熟練者Aと別の熟練者B（誤差10 cm）のフィールド範囲抽出結果の比較画像を Fig. 3.52 に示す．熟練者Aの方がフィールド抽出範囲は広いが，初心者Qと比べると熟練者Bは広くフィールド範囲を抽出できていることがわかる．また，数点ではあるが熟練者Bのみが抽出できた点がある．これらの結果から，熟練者になるほど色抽出調整の結果は似てくるのではないかと考えられる．

これまでの検証の結果から，熟練者は白線情報だけでなく，フィールド範囲抽出においても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，結果として精度の低い自己位置同定結果となると考えられる．また，熟練者であっても，違う調整者によるパラメータは精度に若干の差異を生む可能性も確認できた．そこで以降，本研究における自己位置同定手法の検証では，検証毎に別の人が調整したパラメータを用いると検証結果の信頼性が低下するため，パラメータ調整の差異が検証結果に影響を与えないように，同一の調整者が調整したパラメータを用いることとした．また，手法の性能を正しく検証するため，パラメータ設定の安定性を重視し，調整者には熟練者の1名を選定した．尚，実戦においては同一調整者が全てのロボットの調整を行うことは現実的ではないため，ここまで述べてきたようなスキルの差異により自己位置同定精度の違いが発生する問題は解決できない．本論文で構築する自己位置同定手法における性能検証の主旨と外れるため，本報では問題の確認に留め，効果的な対策の構築，及び検証はこれ以上取り扱わないが，将来的な課題として本問題を認識しておく必要があることをここに述べておく．




Fig. 3.41: Frequency of error amounts




Fig. 3.42: Results of self-localization at positions having large errors. The gray cells represent positions at which the robot's position is mis-detected by self-localization in the range of values between 40 and 100. The red box indicates the positions that will be verified in detail later.




Fig. 3.43: Result of color adjustment by expert A




Fig. 3.44: Result of white-line adjustment by expert A




Fig. 3.45: Result of self-localization by expert A (error 10cm). The green marker represents the detected position of the robot, and its direction is represented as the yellow bar.



Fig. 3.46: Result of color adjustment by beginner Q




Fig. 3.47: Result of white-line adjustment by beginner Q




Fig. 3.48: Result of self-localization by beginner Q (error 70cm)




Fig. 3.49: Comparison of white-line extraction results around the goal area. The yellow and cyan dots respectively represent the points that only expert A and beginner Q could detect.




Fig. 3.50: Extraction results of beginner Q. The red line is an indicator of the rough position of the end line. The green line indicates the rough end position that beginner Q could detect as being the white line.


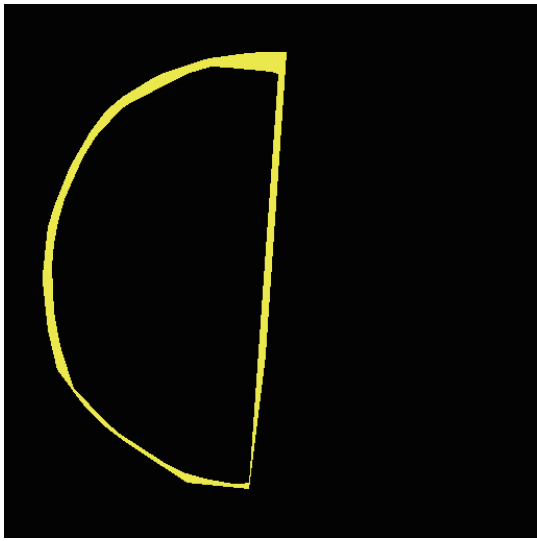


Fig. 3.51: Comparison of field-range extraction results. The yellow and cyan dots respectively represent the points that only expert A and beginner Q detected. In this figure, the points expert B detected. Expert B could detect only that only beginner Q detected do not exist. a few points.

3.5 第3章まとめ

第3章では、ロボットに搭載されている全方位カメラから得られる白線情報を指標とする自己位置同定法の構築，及び精度検証を行った．本手法では，全方位カメラから得られた白線情報を正規化することで白線モデルを生成し，フィールドデータとの照合を行うことで自己位置を認識することを可能とした．具体的には，全方位画像からHSV色変換を行い，得られたフィールドの範囲から白線を抽出する．しかし，抽出した白線は全方位画像の特性により，直線が歪んでしまっているため距離校正変換を用いることで白線の直交化を行い，これを白線モデルとして用いる．白線形状に基づく探索モデルと既知フィールドデータを照合する Model-based Matching 法をベースとして探索空間を形成し，自己位置を認識する問題を適合度関数の最適解探索問題に変換した．全探索法を用いて精度，及び探索時間の検証を行ったところ，平均誤差 12.8 cm，最大誤差 36.1 cm，探索時間は 3000 ms となった．

また，カメラ画像よりフィールド範囲，及び白線を抽出する際に必要となる色抽出調整について，調整者の熟練度による自己位置同定の精度の確認を行った．MSL では，試合の開始 30 分前より競技フィールドで調整を行う事ができ，距離校正変換などは基本的に一度調整すればハードウェア的なずれが発生しない限り再調整の必要はない．一方，色合い（色相・彩度・明度）は会場によって使用するフィールドや照明などの環境要因によって数値が異なり，さらに会場の環境だけでなく，時間帯に依存してパラメータの値が変化するため，試合前には必ず色抽出調整の確認と再調整が必要となる．さらに，各ロボットには戦略上のポジション（ゴールキーパー等）が決まっており，ポジション毎に認識するために必要な色抽出範囲などが微妙に異なるため，すべてのロボットに同じパラメータを用いることはない．そこで，熟練者と初心者併せて 19 名の調整結果から精度を確認したところ，初心者は白線やフィールド範囲の抽出が不十分であった．熟練者は白線情報だけでなくフィールド範囲抽出においても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，結果として精度の低い自己位置同定結果となる可能性が確認できた．

第 4 章 ノイズと誘拐問題に対する遺伝的アルゴリズムを用いたリアルタイム自己位置同定法

前節では、Model-based matching 法を用いた自己位置同定手法が高精度であることを検証したが、競技に使用するためにはリアルタイムな探索手法が必要である。特定の目的を持って構成された探索空間中より最適解（最大値または最小値）を探し出すことは最適化と呼ばれ、探索空間の全構成点を確認することなく効率的に最適化を行う様々な手法が研究されている^{11)~16)}。しかし、緒言で述べたように、サッカー競技のようなリアルタイム性を求められる環境においては適用が難しい手法が多く、さらに自律移動ロボットの自己位置同定課題では、局所的探索性能を特化したことに起因する誘拐問題も発生する。これらに対し、本研究では、局所的探索と同時に大域的探索を実現可能な遺伝的アルゴリズム（以下 GA : Genetic Algorithm）を利用することで、誘拐状態からリアルタイムに復帰可能な自己位置同定手法を構築する。

さらに、実際の競技環境では、自身の他に味方も含め最大 9 台のロボットがフィールド内に存在しており、またロボット以外にも主審や副審などの人も存在する。そのような状況では白線は遮蔽により一部欠け、正確な自己位置同定が取れなくなる可能性がある。そこで、実戦環境を想定しノイズに対するロバスト性を検証する。また、ここまでの検証は静的環境下（静止画）において検証してきた。提案手法の実用上の最終的な確認として、実際にロボットをフィールド上で動作させ、動的環境（動画像を用いた自己位置同定）における有効性の確認を行う。

4.1 ノイズ問題・誘拐問題・リアルタイム性について

ここでは本章で根幹となるノイズ，誘拐問題，リアルタイム性についての定義の述べる。

ノイズ問題とは，試合中に Fig. 4.1, 4.2 のように全方位画像上に自分以外のロボットや審判などが映り込み，白線の一部が隠れてしまう状態を表している．試合中に想定されるノイズが画面上に生じてても，自己位置が同定できる手法はノイズにロバストな自己位置同定手法であると言える．

また，誘拐問題とは，画面上のノイズやロボットの衝突などが原因で，Fig. 4.3 のように本来の真値から別の場所を自己位置と認識することを言う．画像上のノイズにロバストな自己位置同定法を用いても，ロボット同士の衝突など試合中の状況次第で誘拐状態に陥る可能性がある．そのような状態に陥っても，白線が正常に取得できる状況に戻った際に誘拐状態を素早く解消する性能を有していれば，誘拐問題にロバストな自己位置同定手法であると言える．

本論文で述べるリアルタイム性とは，Fig. 4.4 に示すようなロボットに搭載しているカメラのビデオレート（30 fps / 33 ms）に対して，次の画像が入力されるまでの間に自己位置を同定できることとして定義する．常に入力される画像に対して正しい自己位置を得ることがMSLでは重要であるため，ノイズや誘拐問題にロバストな自己位置同定法でもリアルタイムに処理されなければならない．




Fig. 4.1: A noisy situation due to the surrounding robots




Fig. 4.2: Another noisy situation due to the referee and the robot

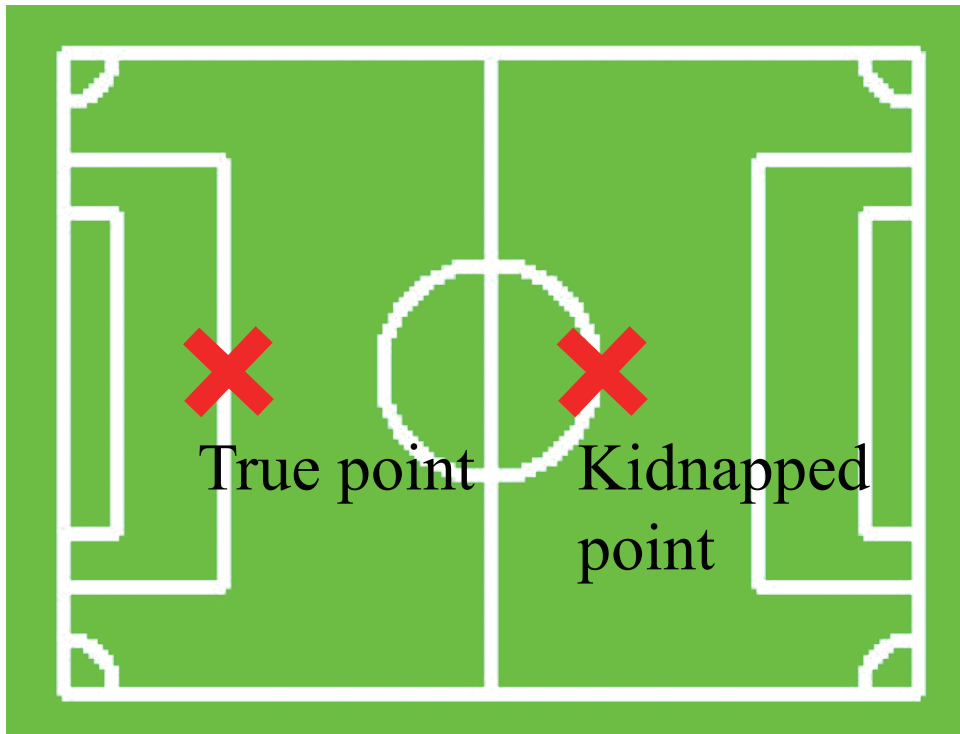


Fig. 4.3: Kidnapped robot problem




Fig. 4.4: Real-time ability and switching of image

4.2 遺伝的アルゴリズムとは

遺伝的アルゴリズム (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^{18),19)}。最適化アルゴリズムとは、ある探索空間より最適解を探索するための問題解決手法^{42),43)}であり、Fig. 4.5 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。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（計算値のピークが複数存在する）に弱く、局所解に陥り易い。一方、モンテカルロ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大値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²⁰⁾。このとき、大きさ n 個の記号列集合で処理されるスキーマタの数は次式で求められる²⁰⁾。

$$n_s = Cn^3 \quad (4.1)$$

この点については 4.3 節において全探索法と比較することで解説する。本研究では、上述した特徴を持つ GA を用いて多峰性関数 $F(\phi)$ の最大値である画像中の対象物の位置／姿勢の探索を行う。

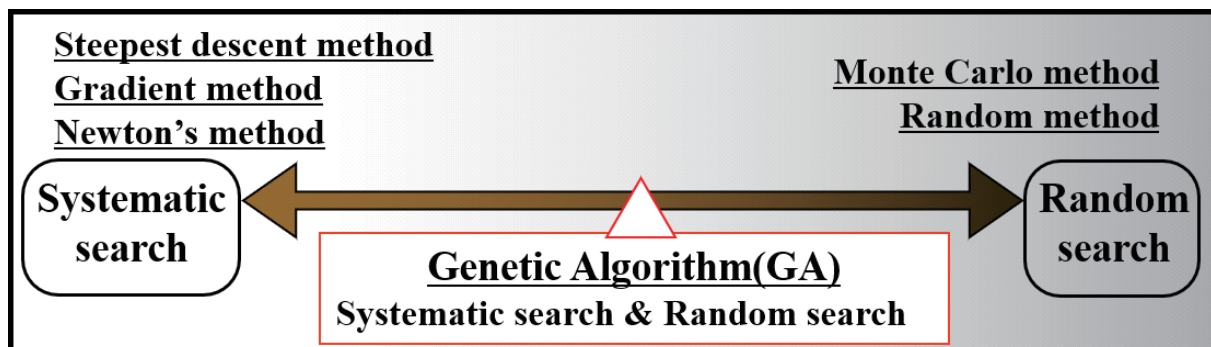


Fig. 4.5: Optimization algorithm

4.3 GA を用いた対象物認識法

Fig. 4.6 に GA と Model-based Matching 法を用いた画像認識法を示す。最初、第一世代として画像内にランダムに個体群がばらまかれ、各個体は自分の位置／姿勢情報 $\phi_i^1 = (x_i^1, y_i^1, \theta_i^1)$ を持っている。ここで、右肩添字の 1 は世代数を表しており、 i は個体群における番号である。 n 個の個体がばらまかれた場合は $i = 1, 2, \dots, n$ である。提案手法で用いる遺伝子情報は、(4.1) 式より、探索座標 x, y , 及び姿勢（角度） θ の探索範囲を考慮し Fig. 4.7 に示すように全 23bit で構成している。

次に、各個体は自分の位置／姿勢情報を用いて適合度関数 $F(\phi)$ により適合度 F_i^1 を得る。こ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. 4.6 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. 4.6 のように GA は対象物の位置／姿勢を表す最大値を発見する。

Fig. 4.8 に示すように各個体の位置情報を用いて適合度関数 $F(\phi)$ を計算し次世代の個体を生成する。 n 世代における i 番目の個体の適合度 F_i^n は遺伝子情報 $\phi_i^n = [x_i^n, y_i^n, \theta_i^n]$ を用いた適合度関数 $F(\phi_i^n)$ で評価され、選択・交叉・突然変異を経て $n + 1$ 世代の遺伝子 ϕ_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を採用している。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、一般的なバイナリ・コーディングは 10 進表記で隣り合っている値のハミング距離が 1 にならない問題を解消するためにグレイ・コーディングを用いる。また、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。

以上の行程から解を導き出す GA は、全探索法など他の探索法に比べ、効率性、有効性が高いことが知られているが、その探索性能は探索する対象や探索空間に大きく依存する。そこで、本節では GA が本研究で対象としている自己位置同定課題においても適用可能であるか確認するために GA のパラメータを調整し、探索効率と精度の検証を行う。

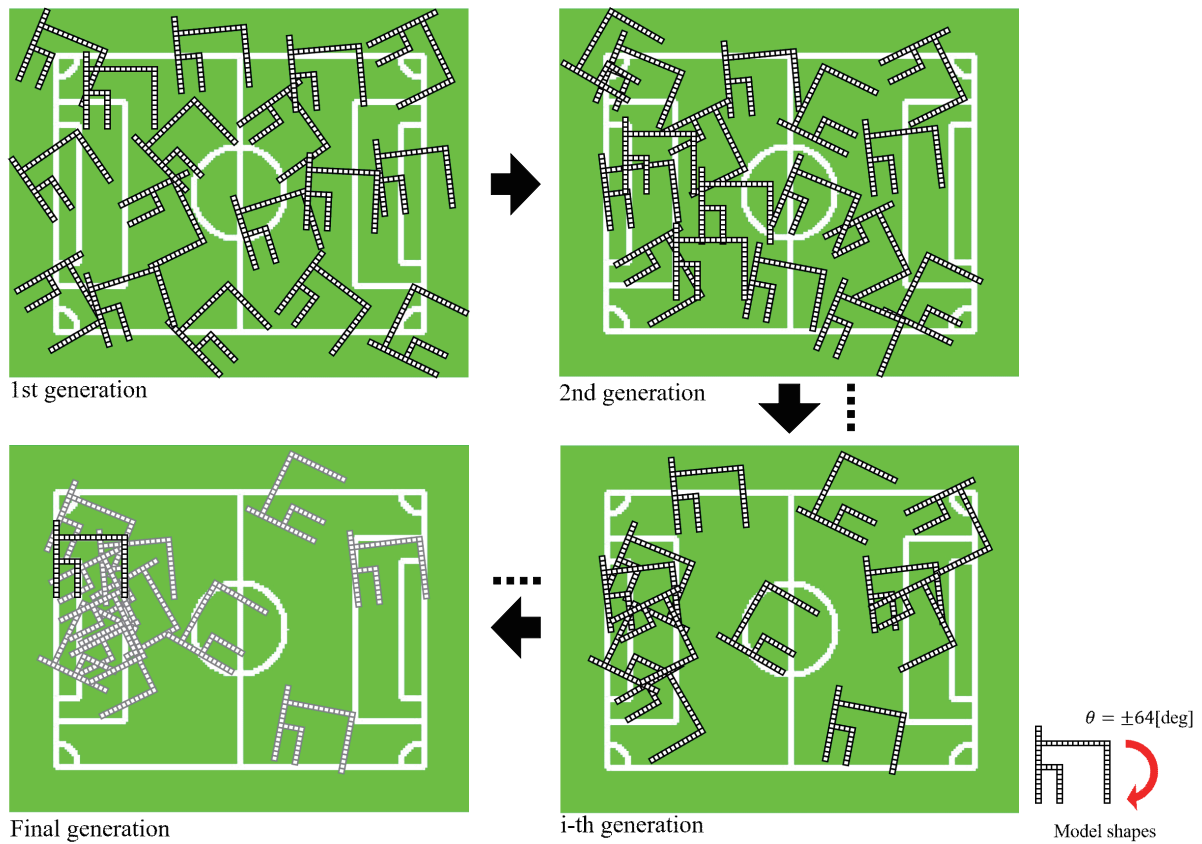


Fig. 4.6: Converging image of GA's individuals

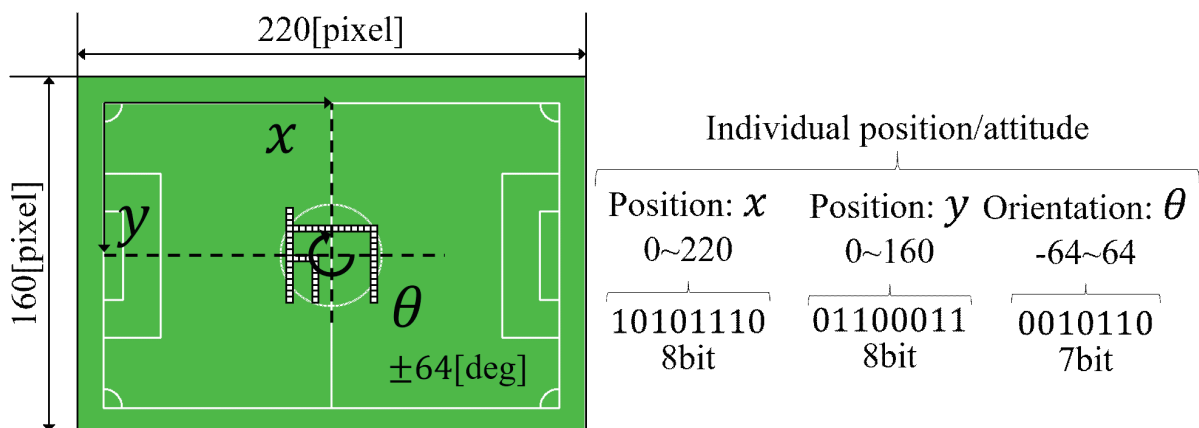


Fig. 4.7: Coding of the GA genes

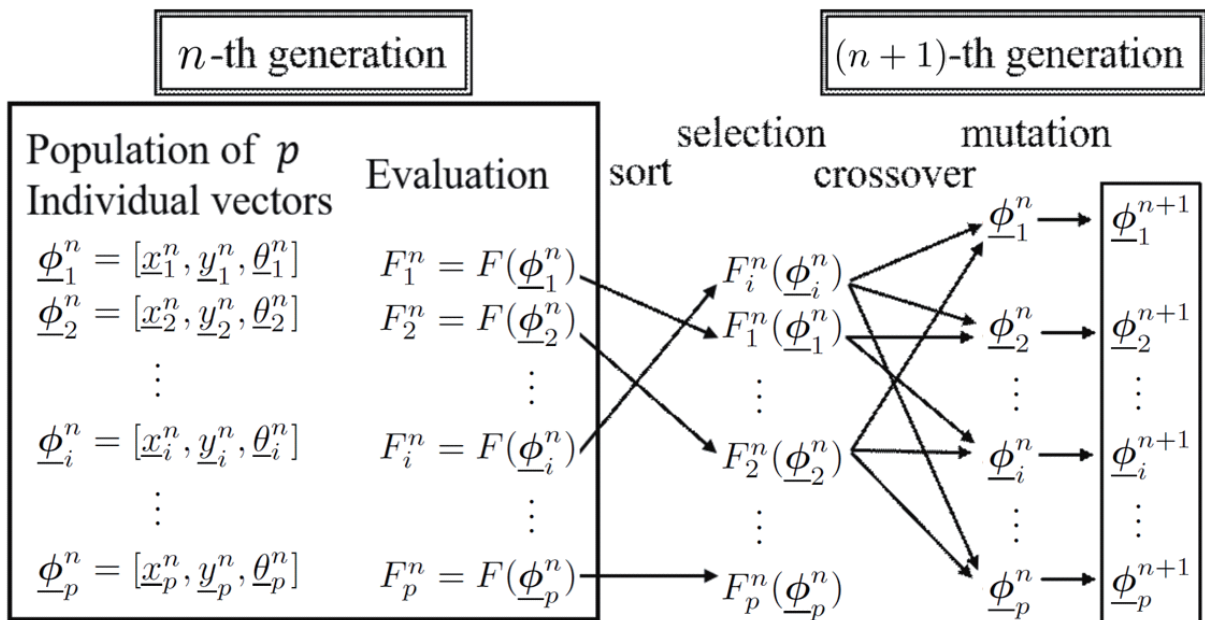


Fig. 4.8: Procedure of GA

4.4 各種進化条件の設定

GA 処理における各種進化条件の設定は、探索効率に大きな影響を及ぼすため、探索空間 Ω の特徴（最適化問題の特性）などを考慮して慎重に決定する必要がある。そこで本節では、誘拐状態からの復帰に強い自己位置同定を構築するために、重要な探索パラメータ（個体数・選択率・突然変異率）の実験的検証を行う。

GA における探索パラメータの組み合わせは膨大であり、単純に最適なパラメータセットを求めることは難しい。ここでは、GA の基本スキームである Implicit parallelism を利用して個体数を妥当な範囲に限定する。Implicit parallelism では、個体数 p とした場合、 p^3 のオーダーの探索空間に対して探索性能を有していることを示唆しており、ここでは前述の総探索点数（探索空間全体）から算出した数値を元に、個体数 50~150、間隔 10 で検証を行う。選択率と突然変異率は過去の研究での知見と局所解収束性能を考慮し、それぞれ 0.05~0.5 の範囲を 0.05 間隔、及び 0.04~0.24 の範囲を 0.02 間隔として検証する。

提案手法では、探索モデルがロボットの座標に依存して変化するため、フィールド内の特定地点の最適化に特化しないように、Fig. 4.9 に示す特徴点が大きく異なる 7 地点を検証対象とした。さらに、誘拐状態からの復帰に強い探索性能を有するパラメータセットを導き出すために、Fig. 4.9 に示すような疑似的な誘拐地点を設けて検証を行う。具体的には、検証の前処理として誘拐地点を真値としてある程度学習させた後、ステップ的に本来の真値（A~G のいずれか）を与え、収束するまでの総探索点数を検証した。検証は全てのパラメータの組み合わせを総当たりで、各パラメータセットにつき各地点で 1000 回（合計 7000 回）実施した。検証の評価としては真値に収束するまでの総探索点数（探索完了時間）が重要であるが、特徴量に依存して各地点で平均探索時間が大きく変動する。そこで、各地点における特徴の差異が影響しないように、各試行において総探索点数で順位を記録し、その順位平均を評価した。検証の結果、Table 4.1 に示すパラメータセットが最適な組み合わせであった。検証の妥当性と、パラメータ空間の連続性を確認するため、各パラメータを固定した検証結果を Fig. 4.10~4.12 に示す。Fig. 4.10 では、個体数を検証するために選択率と突然変異率を Table 4.1 の最適解に固定しており、Fig. 4.11, 4.12 も同様である。図中の縦軸は順位平均であり（小さい値のパラメータが優れている）、横軸は各パラメータの検証値である。

ここで Fig. 4.10 の評価値の推移をみると、図中に黒で示した最適解（個体数 100）を中心に、探索空間は個体数の変化に対して緩やかな勾配を示している。さらに、Fig. 4.11, 4.12 を合わせ、

3次元グラフにしたものを Fig. 4.13 に, Fig. 4.13 を 180 deg 回転したグラフを Fig. 4.14 に示す. 三次元図中の縦軸は見やすさのために順位平均を反転しており, 水平面はそれぞれ選択率と突然変異率を示している. Fig. 4.13, 4.14 を確認すると, 探索空間は連続性を有しており, 最適解である頂点を正しく設定できていることがわかる.

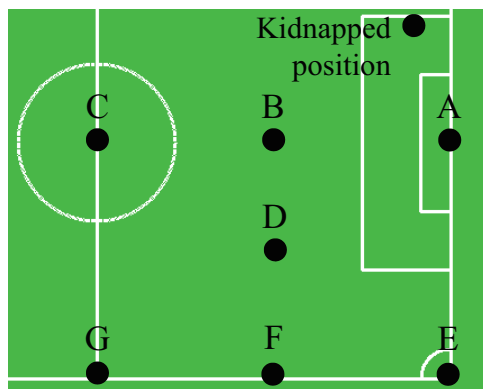


Fig. 4.9: Experimental positions for calibrating parameters

Table 4.1: Optimal parameters of GA considering the kidnapped robot problem

Population size	Selection rate	Mutation rate
100	0.15	0.16




Fig. 4.10: Verification of population size. The vertical axis represents the average of the ranking. Here the rank means the efficiency of the search in each trial, and high efficiency is represented as a high rank, i.e., small value.




Fig. 4.11: Verification of selection rate




Fig. 4.12: Verification of mutation rate




Fig. 4.13: Overview of parameter space between selection rate and mutation rate. The arrow and dotted line represent the optimized positions.

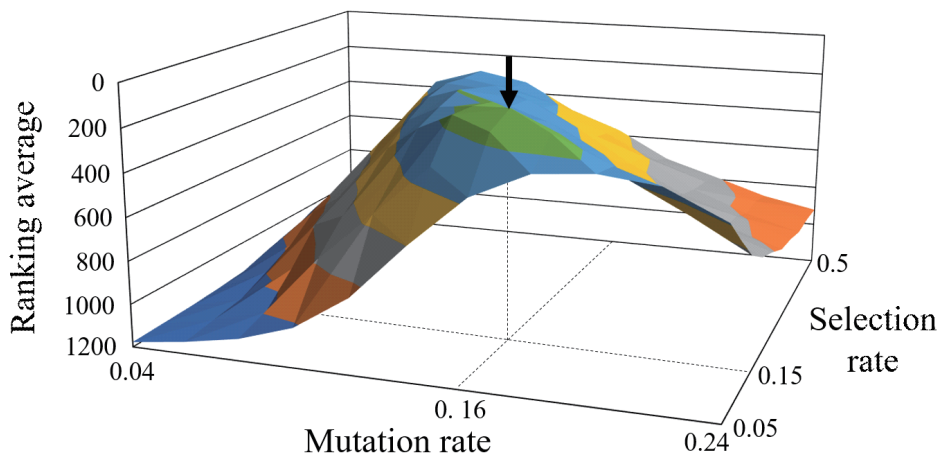


Fig. 4.14: Overview of parameter space between selection rate and mutation rate (another view)

4.5 探索効率と自己位置同定精度の検証

前節までに最適パラメータセットが確定したため、ここでは提案手法の探索効率と自己位置同定精度を確認する。Fig. 4.9の各地点における最適パラメータセット時の平均総探索点数をTable 4.2の上段に示す。さらに、収束状況を示す例として、A地点における収束グラフをFig. 4.15に示す。全地点における総探索点数の平均値2210は、探索時間に換算すると約15msであり、提案手法が非常に効率的かつリアルタイム（33 ms以内）な探索であることがわかる。

さらに、自己位置同定精度を検証するために、3.3節と同様の条件で検証した精度マップをFig. 4.16に示す。ここでは、誘拐問題全体に対するロバスト性を確保するために近距離誘拐も含めた50 cm以上を誘拐状態とした。最大誤差は36.1 cm、平均誤差は13.4 cmとなり、全探索法（最大誤差36.1 cm / 平均誤差12.8 cm）と同等の精度であることが確認できた。

Table 4.2: Search costs

A	B	C	D	E	F	G
909	1556	2658	3716	1671	2681	2276
Average			Whole search			
2210			4505600			




Fig. 4.15: Convergence of GA generations (point A)

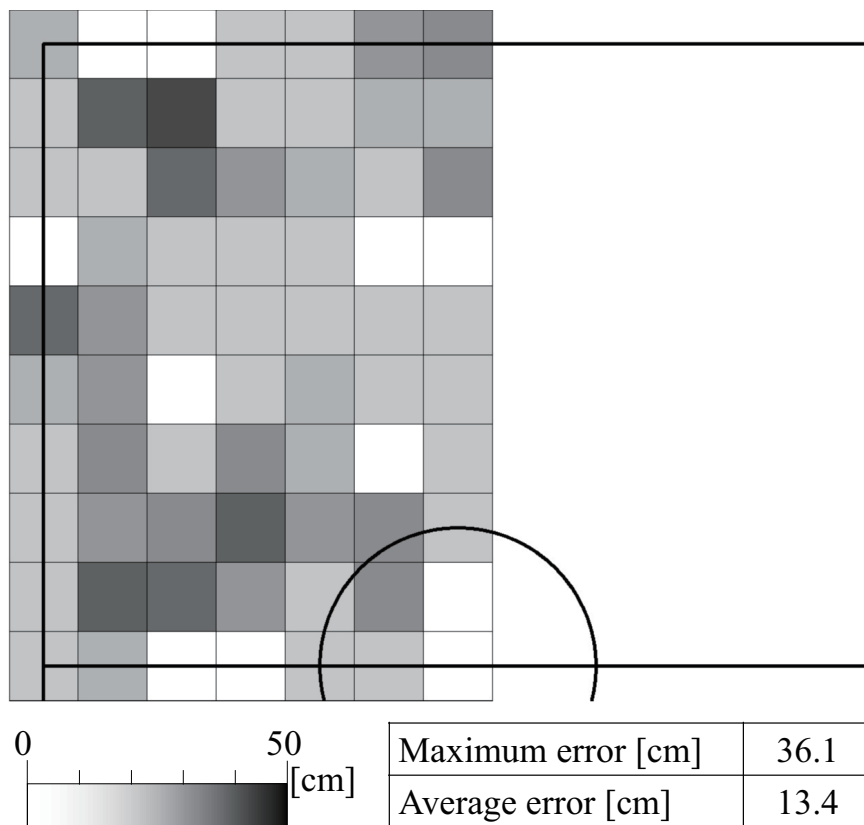


Fig. 4.16: Error of self-localization using GA

4.6 誘拐状態における検証

前節では提案手法の性能を確認したが、ここでは誘拐状態における復帰性能を検証し、パラメータセット検証時に設定した誘拐状態を考慮した探索環境の効果についても併せて検証する。検証における比較のために、誘拐状態を考慮しない探索環境において導き出したパラメータセットを Table 4.3 に示す。Table 4.3 のパラメータセットについても、最適化の妥当性とパラメータ空間の連続性を 4.4 節と同様に確認する。各パラメータを Table 4.3 の最適解に固定した検証結果を Fig. 4.17~4.19 に示し、Fig. 4.18, 4.19 を 3 次元グラフにしたものを Fig. 4.20 と Fig. 4.21 に示す。Fig. 4.17~4.21 を確認すると、誘拐状態を考慮した場合のパラメータと同様に、探索空間は連続性を有しており、最適解である頂点を正しく設定できていることがわかる。また、Table 4.3 のパラメータを用いた自己位置同定精度についても 4.5 節と同様に検証し、作成した精度マップを Fig. 4.22 に示す。検証結果より最大誤差は 36.1 cm、平均誤差は 13.8 cm となり、Fig. 3.22 の全探索における精度（最大誤差 36.1 cm / 平均誤差 12.8 cm）、及び Fig. 4.16 の誘拐状態を考慮したパラメータを用いた精度（最大誤差 36.1 cm / 平均誤差 13.4 cm）と同等であることが確認できた。

4.4 節において誘拐状態を考慮して最適化した Table 4.1 のパラメータと、上述した誘拐状態を考慮せずに最適化した Table 4.3 のパラメータを用い、4.5 節と同様に疑似的に誘拐状態を再現した環境に対するそれぞれの探索性能を検証する。ここで、疑似的誘拐の手法として、誘拐地点の全方位画像を入力画像とし、任意の回数 GA の世代を進め個体をある程度誘拐地点に収束させた後に、各検証地点の全方位画像を入力画像として切り替え、真値へ何世代で到達できるかを検証する。Fig. 4.23 に各地点における探索コストを検証したグラフを示し、Fig. 4.24 に誘拐状態からの復帰失敗率を示す。Fig. 4.23 の縦軸は平均総探索点数（探索コスト）、横軸は各検証地点であり、誘拐状態を考慮して設定した Table 4.1 のパラメータセットを濃い灰色、考慮していない Table 4.3 のパラメータセットを薄い灰色として並べて比較している。また、Fig. 4.24 の縦軸は全試行 1000 回中の復帰失敗回数を割合として示しており、横軸は各検証地点である。ここで、誘拐状態を考慮したパラメータセットは全試行において復帰に成功したため示していない。Fig. 4.23, 4.24 より、誘拐状態を考慮せずに設定した Table 4.3 のパラメータセットは、全体的に誘拐問題に対する探索性能が低いことがわかる。

さらに、Table 4.4 にそれぞれのパラメータセットの各検証地点における誘拐状態からの復帰時間を示す。検証した全地点の復帰平均時間を見ると、誘拐状態を考慮して設定したパラメータセットはリアルタイムに収まっており、誘拐状態に強い探索性能を有していることがわかる。誘拐状態とは遺伝子群が誘拐地点の情報に偏っていることに起因している現象であるが、誘拐状態を想

定して設定したパラメータセットを用いることで、このような遺伝子群が探索に不利な状態であっても GA の発見的探索性能を最大限発揮し、リアルタイムな自己位置情報の復帰が可能となっていることがわかる。

この2つのパラメータの大きな違いとして、突然変異率が挙げられる。GA は広大な探索空間において1つの解を時間をかけて探し出す手法であり、突然変異率は小さく設定される場合が多いが、本手法では誘拐状態を想定したパラメータ設定を行ったため、局所解（真値以外）に収束した際にも突然変異を多く起こすことで真値を見つけやすくなるように通常より大きく突然変異率が設定されている。

Table 4.3: Optimal parameters of GA without considering kidnapped robot problem

Population size	Selection rate	Mutation rate
120	0.3	0.07

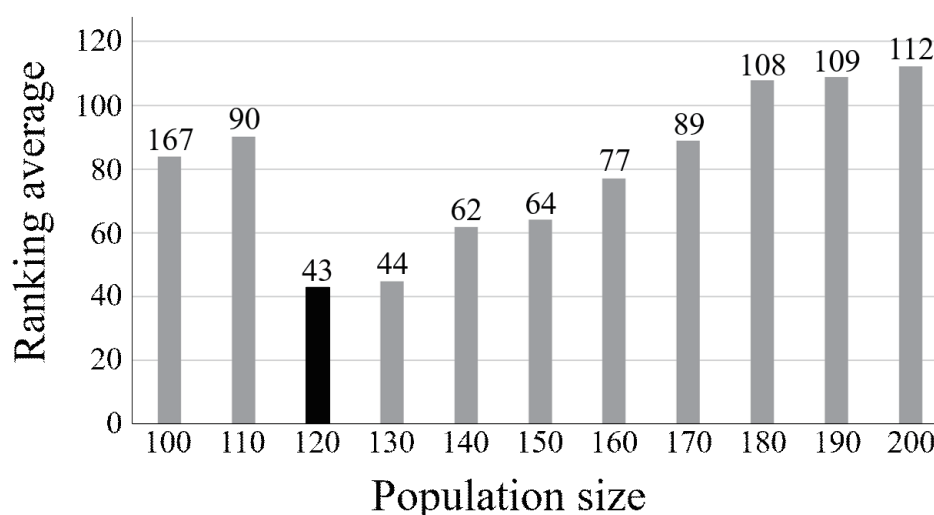


Fig. 4.17: Verification of population size without kidnap




Fig. 4.18: Verification of selection rate without kidnap




Fig. 4.19: Verification of mutation rate without kidnap




Fig. 4.20: Overview of parameter space between selection rate and mutation rate without kidnap

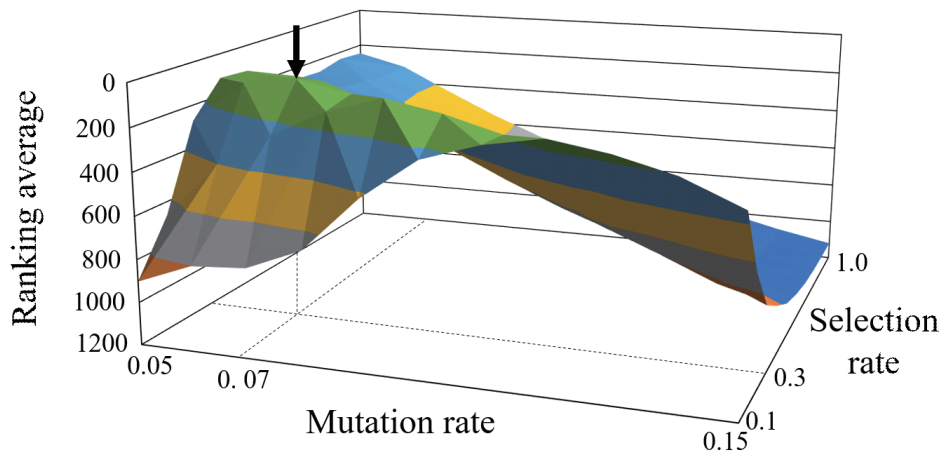


Fig. 4.21: Overview of parameter space between selection rate and mutation rate without kidnap (another view)




Fig. 4.22: Error of self-localization without kidnap




Fig. 4.23: Search cost for each experimental position




Fig. 4.24: Miss-detection rate for parameters in Table 4.3

Table 4.4: Recovery time of each experimental position

	A	B	C	D	E	F	G	AVG
With kidnapped problem [ms]	7.7	10.6	16.6	26.6	10.8	17.9	17.0	15.3
Without kidnapped problem [ms]	4.3	37.6	175.1	57.5	63.7	95.9	152.0	83.7

4.7 ノイズに対するロバスト性の検証

ここまでの自己位置同定の精度はすべてフィールド上に他のロボットがない理想環境下で行った精度であった。しかし、実際の競技環境では、味方も含め最大9台のロボットがフィールド内に存在しており、またロボット以外にも主審や副審などの人も存在する。そのような状況では白線は遮蔽により一部欠け、正確な自己位置同定が取れなくなる可能性がある。そこで、実戦環境を想定しノイズに対するロバスト性を検証する。

上述したようにノイズとなる物体はロボットや人など様々である。様々なノイズ状況における本手法の性能を比較しやすくするために、ここでは実際のノイズではなくロボットや人の遮蔽物を考慮した人工的なノイズを用いる⁴⁴⁾。人工ノイズは画像中心から外周に向けて扇状に30 deg 塗りつぶした物を1単位とし、ノイズ位置の変化や数の変化によって、自己位置同定結果や適合度がどのように変化するかを Fig. 4.25 に示した7地点において検証する。ここで、ノイズの位置は画像直上を0 deg として30 deg ずつ時計回りにずらし、ノイズの個数は均等配置としている。例として、A 地点でのノイズの角度の変化と個数の変化を Fig. 4.26, 4.27 に示す。また、参考として各地点のノイズ検証に使用した画像を Fig. B.20~Fig. B.89 (付録) に示す。

全体の検証結果概要を Table 4.5 に示す。表中の赤色の塗りつぶしは、真値からロボット1台分である50 cm 以上離れてしまい、誘拐状態に陥った結果である。ここで、参考として各地点のノイズ個数別の真値からの誤差を Table B.1~B.7 (付録) に示す。




Fig. 4.25: Verification points




Fig. 4.26: Change in angle of fan-shaped noise. Taking the center of the panoramic image as the center of the circle, we set a fan-shaped area with a center angle of 30 degrees as noise.




Fig. 4.27: Change in number of fan-shaped noise patterns

Table 4.5: Error amount and percentage for all situations in noise experiment

Error[cm]		Noise num									
Rate		1	2	3	4	5	6	7	8	9	10
Point	A	28.3	28.3	28.3	28.3	150.3	22.4	72.8	1510.0	28.3	131.5
		0.00%	0.00%	0.00%	0.00%	8.33%	0.00%	8.33%	66.67%	0.00%	16.67%
	B	14.1	14.1	14.1	14.1	31.6	14.1	41.2	22.4	648.5	1164.8
		0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	50.00%	100.00%
	C	10.0	14.1	0.0	10.0	14.1	10.0	14.1	10.0	14.1	10.0
		0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
	D	20.0	14.1	10.0	20.0	20.0	10.0	1310.3	429.5	676.8	1207.8
0.00%		0.00%	0.00%	0.00%	0.00%	0.00%	8.33%	66.67%	75.00%	100.00%	
E	22.4	22.4	22.4	58.3	1650.5	22.4	22.4	31.6	31.6	31.6	
	0.00%	0.00%	0.00%	33.33%	8.33%	0.00%	0.00%	0.00%	0.00%	0.00%	
F	30.0	30.0	41.2	14.1	20.0	40.0	20.0	40.0	41.2	370.1	
	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	66.67%	
G	10.0	10.0	40.0	120.0	40.0	10.0	820.1	900.1	890.1	900.1	
	0.00%	0.00%	0.00%	33.33%	0.00%	0.00%	33.33%	66.67%	75.00%	66.67%	

各地点において、特にノイズ個数が少ない画像の誤差について考察する。地点 A の誤差を見ると、ノイズ個数 5 (Fig. 4.28) において 150 cm の誤差が出ているが、これはノイズが代表的な白線を遮蔽したことによりゴールラインとペナルティラインを誤認したことに起因している。また、A 地点以外にも共通に言える極めて当たり前のことであるが、ノイズ個数が多い検証において誤差が増加しており、全体的に見るとノイズ個数 7 を境界として特徴的な地点を除き誤差が増大する傾向にある。ここで特徴的な地点とは、フィールド上の特徴を有するエリアを 2 箇所以上画像に含む地点 (B, F)、もしくはノイズの数によって特徴が消失しないセンターサークル中央 (C) である。A 地点以外にノイズ個数が少ない状態で誤差が発生している地点は E (Fig. 4.29 : 誤差 60 cm) と G (Fig. 4.30 : 誤差 120 cm) である。この 2 地点は、共に白線が直交する箇所であり、ノイズ個数 4 が直交配置になっていることに起因している。

次に、検証全体を通して特に誤差の大きい地点 E (誤差 1650 cm) について考察する。Fig. 4.31, 4.34 は同じ E 地点でのノイズがない場合とノイズ個数 5 の場合の自己位置同定結果である。それぞれ全方位画像からのモデルを Fig. 4.32, 4.35 に、これらのモデルを用いた自己位置同定結果の適合度を Fig. 4.33, 4.36 に示す。ノイズ個数 5 の配置によりフィールドの特徴点 (ゴールエリア, エンドライン, サイドライン) が完全に見えなくなっており、ペナルティエリアの一部とコーナーアークのみで特徴を捉えきれず誘拐状態になっていることがわかる。

以上の結果と Table 4.5 より、ノイズ個数 3 までは自己位置同定の誤差が小さく、ノイズ個数 4 では最大 120 cm の誤差が発生している。MSL のルールによって各チームは 1 台しかボールに対してアプローチが許可されておらず、実際の競技ではノイズ個数 4 以上、つまり全方位画像の 1/3 を占めるノイズが白線を隠す事態は発生し難いため、本提案手法はノイズに対してロバスト性を有していると言える。




Fig. 4.28: Case of 5 noise patterns at position A Fig. 4.29: Case of 4 noise patterns at position E Fig. 4.30: Case of 4 noise patterns at position G




Fig. 4.31: Case of no noise at position E

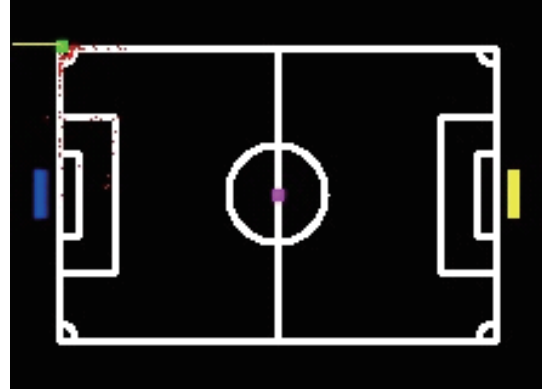


Fig. 4.32: Self-localization results at position E without noise




Fig. 4.33: 3D graph of fitness value at position E without noise




Fig. 4.34: Five-noise pattern image at position E




Fig. 4.35: Self-localization results at position E with noise




Fig. 4.36: 3D graph of fitness value at position E with noise

4.8 実環境下における検証実験

本研究の提案手法がノイズと誘拐問題にロバストであり、リアルタイムに正確な自己位置同定を実現できることを前節までに静的環境下において検証してきた。ここでは、提案手法の実用上の最終的な確認として、実際にロボットをフィールド上で動作させ、動的環境（動画像を用いた自己位置同定）における有効性を確認する。

検証に用いた3パターンの走行経路を Fig. 4.37~4.39 に示す。ここで、Fig. 4.37, 4.38 はリモコンを用いて手動で走行させ、Fig. 4.39 は競技用プログラムによる自動走行を行った。尚、Fig. 4.39 は、競技を想定してボールを実際に用い、競技同様の状況で動作させているため、正確な走行経路は示さずスタートした地点のみ示している。それぞれの検証で得られた自己位置同定の走行軌跡を Fig. 4.40, 4.42, 4.44 に、x 座標と y 座標を時系列に並べたグラフを Fig. 4.41, 4.43, 4.45 に示す。走行軌跡の図においてプロットした点はロボットが自己位置として認識した地点を示しており、時系列グラフは縦軸に各座標、横軸にタイムスタンプ（カメラ画像の取得フレーム番号）を示している。

Fig. 4.40, 4.42, 4.44 の走行軌跡を見てみると、いずれの検証においても、前節までに検証した誤差範囲に収まる程度の位置誤差は認められるが、設定した走行経路を正しく認識できていることがわかる。また、Fig. 4.41, 4.43, 4.45 を見てみると、スパイクノイズのように認識座標は急激に変化することなく（誘拐されることなく）連続性を保ったまま時系列で繋がっている。このことから、本研究で提案した自己位置同定手法は実環境下においても有効であることが確認できた。




Fig. 4.37: Test path 1 of verification experiment in actual environment

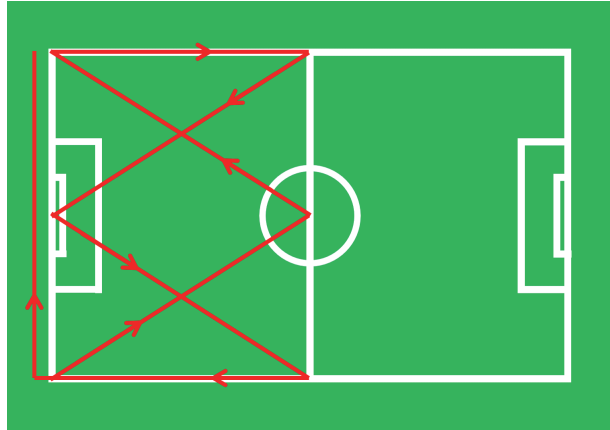


Fig. 4.38: Test path 2 of verification experiment in actual environment

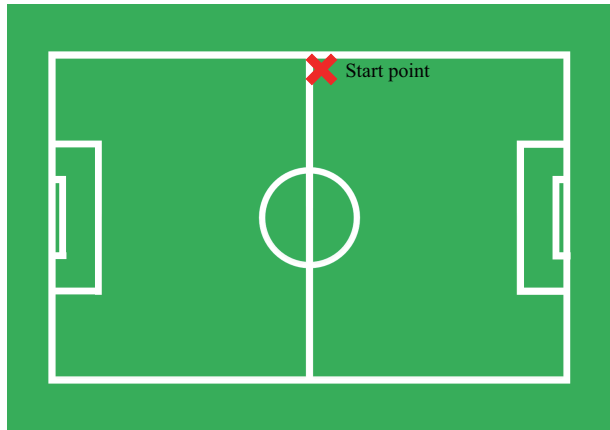


Fig. 4.39: Test path 3 of verification experiment in actual environment




Fig. 4.40: Result of self-localization on test path 1. The black dots represent the detected position at each camera frame.




Fig. 4.41: x, y coordinates of detected position at each frame number on test path 1

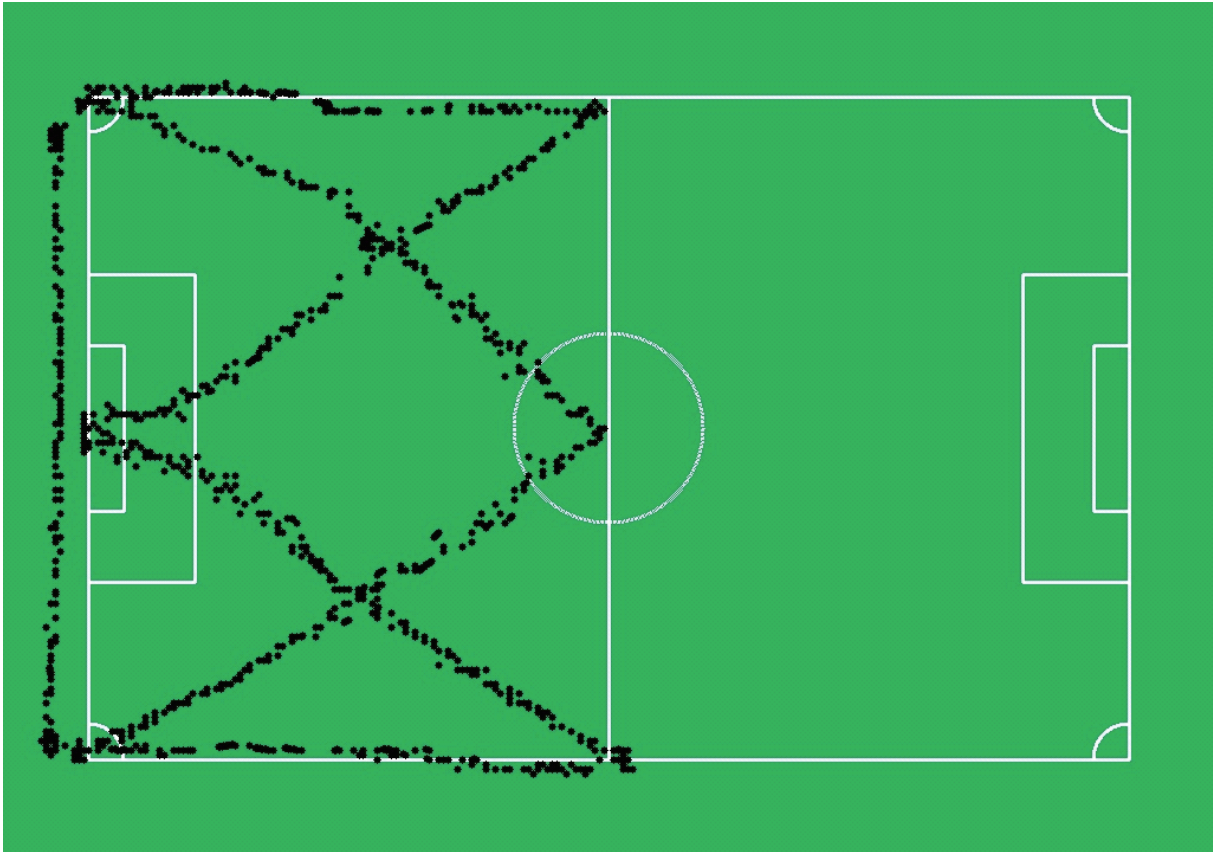


Fig. 4.42: Result of self-localization on test path 2




Fig. 4.43: x, y coordinates of detected position at each frame number on test path 2




Fig. 4.44: Result of self-localization on test path 3




Fig. 4.45: x, y coordinates of detected position at each frame number on test path 3

4.9 第4章まとめ

前節では、Model-based matching 法を用いた自己位置同定手法が高精度であることを検証したが、競技に使用するためにはリアルタイムな探索手法が必要である。第4章では、ロボットの現在位置を特定する自己位置同定において、局所的探索能力の高さに起因して発生する誘拐問題を課題とし、GAの大域的探索能力を利用することで、誘拐状態からの復帰を実現した。

GA 処理における各種パラメータは、探索効率に大きな影響を及ぼすため、実験的検証を行った。高効率な最適化の実現のために、探索空間の特徴（最適化問題の特性）と誘拐状態を考慮した検証を行い、重要な探索パラメータセット（個体数・選択率・突然変異率）を慎重に決定した。導出した最適パラメータセット（個体数：100，選択率：0.15，突然変異率：0.16）を用いて精度、及び探索時間の検証を行ったところ、平均誤差 13.4 cm，最大誤差 36.1 cm，探索時間 15 ms となり、提案手法は全探索法と同等の精度で真値を探索可能であり、かつその処理をリアルタイムに実現できることを確認した。

続いて、疑似的に誘拐状態を作り出し復帰性能を検証する実験を行うために、誘拐状態を考慮しない探索パラメータセットの導出を行った結果、個体数：120，選択率：0.3，突然変異率：0.07 となった。このパラメータセットを用いて精度、及び探索時間の検証を行ったところ、全探索法と誘拐状態を考慮したパラメータセットと同等の精度である、平均誤差 13.8 cm，最大誤差 36.1 cm となった。

さらに、導出した2つのパラメータセットを用いて誘拐地点における誘拐状態からの復帰時間を検証したところ、誘拐状態を考慮したパラメータではすべての状態から復帰ができたが、考慮しないパラメータセットでは最大 18%が復帰失敗した。この2つのパラメータの大きな違いとして、突然変異率が挙げられる。本手法では誘拐状態を想定したパラメータ設定を行ったため、局所解（真値以外）に収束した際にも突然変異を多く起こすことで真値を見つけやすくなるように通常より大きく突然変異率が設定されている。このことより、GAの大域的探索能力を利用するとともに、パラメータセットの設定に誘拐問題を考慮した環境を用いることで、リアルタイムな自己位置への復帰が実現できることを確認した。

実際の競技環境では、味方も含め最大 9 台のロボットがフィールド内に存在しており、またロボット以外にも主審や副審などの人も存在する。そのような状況では白線は遮蔽により一部欠け、正確な自己位置同定が取れなくなる可能性がある。そこで、人工的なノイズを用いて、ノイズに対するロバスト性を検証した結果、一部の特殊な状況を除き、ノイズが画像の半分以上を占める

と誘拐率が高くなるが、実戦で想定されるノイズに対してロバストであることが確認できた。

ここまでの検証で、本提案手法がノイズと誘拐問題にロバストであり、リアルタイムに正確な自己位置同定を実現できることを確認した。しかし、これまでの検証はすべて静的環境下においての検証であった。そこで最後の検証として、実際にロボットをフィールド上で動作させ、動的環境（動画像を用いた自己位置同定）における有効性の確認を行った。3パターンの走行を行い、いずれも自己位置が急激に変化することなく、連続性を保ったまま時系列で繋がり、設定した走行経路を正しく認識できていることが確認できた。

第 5 章 結言

RoboCup MSL では自己位置やボールの位置を含む周囲の状況を自身に搭載されているセンサーのみで認識しなければならない。その中でロボットが自己位置を認識するためには、フィールド内のいかなる場所においても定常的に認識可能であること、及びフィールドの位置に依存した固有の特徴量を有する指標が必要である。これらの条件を満たす特徴物として、フィールド上の白線が挙げられるため、本研究では白線を用いた自己位置同定を行った。さらに、試合の状況は常に変化しており、ロボット自身も状況に応じて絶えずフィールド内を動き回らなければならない。また、実際の競技環境では、他のロボットや主審や副審などの人も存在するため、自己位置を認識する指標である白線が常にすべて見えるとは限らず、状況によってはロボットが真値とは全く異なる位置を自己位置として認識する誘拐状態になる可能性がある。そこで本研究では、RoboCup MSL においてノイズや誘拐問題にロバストなロボットの現在位置を特定する自己位置同定手法の構築を目的として研究を行った。

第 2 章では、本研究で用いるロボットの紹介を行った。ロボットには周囲を認識するためのカメラシステムや、移動に用いる移動機構だけでなく、それらを制御するための制御回路や競技を成立させるためのボール保持機構やキック機構などを搭載している。

第 3 章では、ロボットに搭載されている全方位カメラから得られる白線情報を指標とする自己位置同定法の構築、及び精度検証を行った。本手法では、全方位カメラから得られた白線情報を正規化することで白線モデルを生成し、フィールドデータとの照合を行うことで自己位置を認識することを可能とした。具体的には、全方位画像から得た白線形状に基づく探索モデルと既知フィールドデータを照合する Model-based Matching 法をベースとして探索空間を形成し、自己位置を認識する問題を適合度関数の最適解探索問題に変換した。全探索法を用いて精度、及び探索時間の検証を行ったところ、平均誤差 12.8 cm、最大誤差 36.1 cm、探索時間は 3000 ms となった。高い精度で自己位置を認識できる手法ではあるが、実戦で用いるためには探索時間の長さが問題点であることを確認した。

また、カメラ画像よりフィールド範囲、及び白線を抽出する際に必要となる色抽出調整につい

て、調整者の熟練度による自己位置同定の精度の確認を行った。熟練者と初心者併せて19名の調整結果から精度を確認したところ、熟練者は白線情報だけでなくフィールド範囲抽出においても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、結果として精度の低い自己位置同定結果となる可能性が確認できた。

第4章では、ロボットの現在位置を特定する自己位置同定において、局所的探索能力の高さに起因して発生する誘拐問題を課題とし、GAの大域的探索能力を利用することで、誘拐状態からの復帰を実現した。GA処理における各種パラメータは、探索効率に大きな影響を及ぼすため、実験的検証を行った。高効率な最適化の実現のために、探索空間の特徴（最適化問題の特性）と誘拐状態を考慮した検証を行い、重要な探索パラメータセット（個体数・選択率・突然変異率）を慎重に決定した。最適パラメータを用いて精度、及び探索時間の検証を行ったところ、平均誤差13.4 cm、最大誤差36.1 cm、探索時間15 msとなり、提案手法は全探索法と同等の精度で真値を探索可能であり、かつその処理をリアルタイムに実現できることを確認した。さらに、疑似的に誘拐状態を作り出し復帰性能を検証する実験を行った。本来GAはリアルタイムな適合度探索法に利用されることは少ないが、近年のPCスペックの向上によってリアルタイムな処理が可能となっている。GAの大域的探索能力を利用するとともに、パラメータセットの設定に誘拐問題を考慮した環境を用いることで、リアルタイムな自己位置への復帰が実現できることを確認した。

実際の競技環境では、味方も含め最大9台のロボットがフィールド内に存在しており、またロボット以外にも主審や副審などの人も存在する。そのような状況では白線は遮蔽により一部欠け、正確な自己位置同定が取れなくなる可能性がある。そこで、人工的なノイズを用いて、ノイズに対するロバスト性を検証した結果、実戦で想定されるノイズに対してロバストであることが確認できた。

最後に、実際にロボットをフィールド上で動作させ、動的環境（動画像を用いた自己位置同定）における有効性の確認を行った。3パターンの走行を行い、いずれも自己位置が急激に変化することなく、連続性を保ったまま時系列で繋がり、設定した走行経路を正しく認識できていることが確認できた。

以上の結果より、緒言で挙げたTalbe 5.1の各手法の特徴に対し、本研究で提案した自己位置同定手法は、ノイズと誘拐問題に対してロバストであり、リアルタイムに自己位置を認識可能であることを確認した。高精度でリアルタイムな自己位置同定法は、障害物認識、セットプレイ、パスプランニングなど、より高度な技術の基本情報として使用される。

今後の課題として、調整者の熟練度の熟練度によって色抽出調整の精度が左右されないように

色抽出パラメータの自動調整化を目指す。また，実環境下における検証実験ではノイズがほぼない環境で行ったため，他のロボットなどノイズ環境を想定した環境下で自己位置同定の評価を行う。

本研究で対象としている競技ロボットのみならず，近年ではロボットの高性能化，自律化に伴い，スタンドアロンで行動するタイプのロボットが急速に普及してきている。これらのロボットは，過去の研究で多く行われてきたような演算装置のハードウェア的な恩恵を受けることが難しく，Jetson のような GPU を備えたシングルボードコンピュータ等で構成される場合が多い。さらにこれらのロボットは，本報で扱った自己位置同定情報以外にもリアルタイムに環境に適応するために様々な処理を並列処理する必要があるため，各処理の処理負荷を低減する技術は必須である。これに対し，本報では，誘拐状態からリアルタイムに復帰可能な自己位置同定手法をシンプルな GA を用いて構築してその性能を確認しており，今後の自律ロボットで前提となるであろう低コストな部分処理を実現できる可能性を示唆している。

Table 5.1: Performance comparison of self-localization methods

手法	特徴
ハフ変換を用いる手法	計算が多く発生するため処理時間が長い
誤差最小化に基づいた手法	局所的探索法となるため，初期位置の仮定が必要
Monte Carlo Localization	精度を向上させようとすると処理時間が増加する 誘拐状態からの復帰が比較的遅い
提案手法	ノイズと誘拐問題にロバストかつリアルタイム

参考文献

- [1] 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)
- [2] 「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)
- [3] 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)
- [4] 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)
- [5] RoboCup Federation : <https://www.robocup.org/>
- [6] 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)
- [7] RoboCup 日本委員会 : <http://www.robocup.or.jp/>
- [8] 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 (日本知能情報ファジィ学会誌), Vol.29, No.1, pp.2-13 (2017)
- [9] Masaki ISHII, Kazuaki YOKOYAMA : “Mapping and Correction Method in Static Environments for Autonomous Mobile Robot”, International Journal of the Society of Materials Engineering for Resources, Vol.20, No.2, pp.207-212 (2014)
- [10] 倉鋪 圭太, 深尾 隆則, 永田 純平, 石山 健二, 神谷 剛志, 村上 則幸:「レーザレンジファインダによる自己位置同定と逆最適制御を用いた果樹園 UGV の巡回走行」, 日本ロボット学会誌, Vol.30, No.4, pp.428-435 (2012)

- [11] Ton Peijnenburg, Jurge van Eijck, et. al. : “Robot Sports Team Description Paper ”, <https://www.robotsports.nl/index.php/en/documents/qualification-material-2016> (2016)
- [12] M. Lauer, S. Lange, and M. Riedmiller : “Calculating the perfect match : An efficient and accurate approach for robot self-localization”, RoboCup 2005 : Robot Soccer World Cup IX, pp.142-153, Springer-Verlag (2005)
- [13] 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)
- [14] 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)
- [15] 上田隆一, 新井民夫, 浅沼和範, 梅田和昇, 大隅久 : 「パーティクルフィルタを利用した自己位置推定に生じる致命的な推定誤りからの回復法」, 日本ロボット学会誌, Vol. 23, No. 4, pp.466-473 (2005)
- [16] 佐藤 佑介, 武村 泰範, 真田 篤, 北住 祐一, 小川 優, 山口 修司, 宮本 弘之 : 「ロボカップサッカー中型リーグにおける白線情報を用いた自己位置推定法の検討」, ロボティクス・メカトロニクス講演会講演概要集, _2P1-J14_1-_2P1-J14_4 (2008)
- [17] 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)
- [18] 安居院 猛, 長尾 智晴 : 「ジェネティックアルゴリズム」, 昭晃堂, pp.53-81 (1993)
- [19] 北野 宏明 : 「遺伝的アルゴリズム」, 産業図書 (1993)
- [20] D.E.Goldberg: “Genetic Algorithms in Search, Optimization and Machine Learning”, Reading : Addison-Wesley (1989)
- [21] 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回ファジィシステムシンポジウム講演論文集, MF3-1, pp. 313-316 (2013)

- [22] 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)
- [23] RV-Infinity Discription paper: <http://www.seit.t-kougei.ac.jp/vision/rv-infinity/2018Qualification.html>
- [24] 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)
- [25] 大森 浩二郎, 鈴木 秀和:「RoboCup 中型リーグのための障害物認識」, 第 35 回日本ロボット学会学術講演会講演論文集 DVD, 3C1-01 (2017)
- [26] 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)
- [27] 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)
- [28] 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 (2013.3)
- [29] 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 (2015.3)
- [30] FLIR Systems, Inc.: “Flea3(USB3 Vision Camera)”, Available from: <https://www.flir.com/products/flea3-usb3/>
- [31] Vstone Co.,Ltd.: “全方位ミラー製品”, http://www.vstone.co.jp/products/sensor_camera/index.html
- [32] 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>
- [33] マクソンジャパン株式会社: “ESCON”, <https://www.maxongroup.co.jp/maxon/view/content/Overview-Page-Controls>

- [34] 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>
- [35] 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 (2018.3)
- [36] ビジュアル情報処理編集委員会 : “デジタル画像処理”, CG ー ARTS 協会, 2006
- [37] 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)
- [38] 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)
- [39] 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)
- [40] 渡邊 香, 鈴木 秀和 : 「RoboCup のための基礎的な自己位置同定法の構築」, 第 28 回フェジィシステムシンポジウム講演論文集, TE3-4, pp. 709-710 (2012)
- [41] 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)
- [42] 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)
- [43] 坂和 正敏 : 「非線形システムの最適化」, 森北出版 (1989)
- [44] 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)

付録

A パラメータ調整者別の色相調整結果を用いた自己位置同定結果




Fig. A.1: Adjuster A




Fig. A.2: Adjuster B




Fig. A.3: Adjuster C




Fig. A.4: Adjuster D




Fig. A.5: Adjuster E




Fig. A.6: Adjuster F




Fig. A.7: Adjuster G




Fig. A.8: Adjuster H

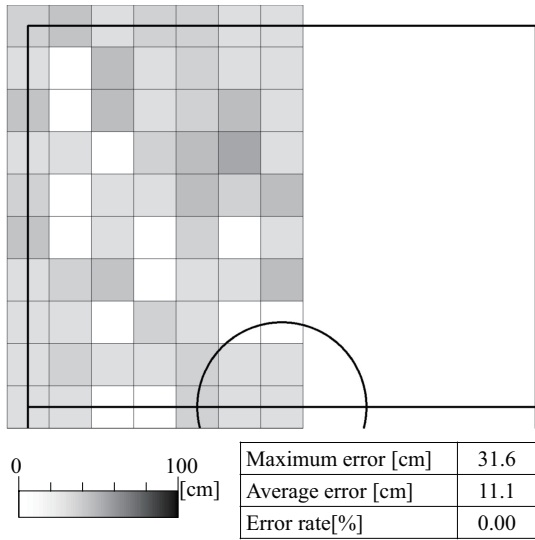


Fig. A.9: Adjuster I




Fig. A.10: Adjuster J




Fig. A.11: Adjuster K




Fig. A.12: Adjuster L




Fig. A.13: Adjuster M




Fig. A.14: Adjuster N




Fig. A.15: Adjuster O




Fig. A.16: Adjuster P




Fig. A.17: Adjuster Q




Fig. A.18: Adjuster R




Fig. A.19: Adjuster S

B 全てのノイズパターン

4.7節において各地点のノイズ検証に使用した画像を Fig. B.20~Fig. B.89 に示す。ノイズの位置は画像直上を 0 deg として 30 deg ずつ時計回りにずらし、ノイズの個数は均等配置としている。このため、ノイズの個数が1つでは12パターンあり、2つでは6パターンとなるように、個数に依存して重複する画像を省くため、検証する画像数が変動していることに注意されたい。また、各地点の検証結果を Table B.1~B.7 に示す。表中の赤色の塗りつぶしは、真値からロボット1台分である50cm以上離れてしまい、誘拐状態に陥った結果であり、斜線の数値は上述した重複画像の数値を表している（重複元と数値は同じ）。

Table B.1: Point A noise result

			Noise num									
			1	2	3	4	5	6	7	8	9	10
Noise angle	i	0	22.4	22.4	22.4	28.3	20.0	22.4	28.3	140.4	22.4	20.0
	ii	30	22.4	22.4	28.3	28.3	22.4	22.4	20.0	1510.0	28.3	22.4
	iii	60	28.3	22.4	22.4	22.4	14.1	22.4	22.4	22.4	28.3	28.3
	iv	90	28.3	28.3	28.3	28.3	41.2	22.4	72.8	140.4	28.3	10.0
	v	120	28.3	28.3	22.4	28.3	28.3	22.4	22.4	1510.0	22.4	22.4
	vi	150	22.4	22.4	28.3	22.4	150.3	22.4	28.3	22.4	28.3	131.5
	vii	180	22.4	22.4	22.4	28.3	22.4	22.4	22.4	140.4	28.3	20.0
	viii	210	22.4	22.4	28.3	28.3	28.3	22.4	28.3	1510.0	28.3	22.4
	ix	240	22.4	22.4	22.4	22.4	36.1	22.4	22.4	22.4	22.4	28.3
	x	270	22.4	28.3	28.3	28.3	22.4	22.4	28.3	140.4	28.3	10.0
	xi	300	22.4	28.3	22.4	28.3	28.3	22.4	36.1	1510.0	28.3	22.4
	xii	330	22.4	22.4	28.3	22.4	28.3	22.4	10.0	22.4	28.3	131.5




Fig. B.20: Position A / noise 1




Fig. B.21: Position A / noise 2




Fig. B.22: Position A / noise 3




Fig. B.23: Position A / noise 4




Fig. B.24: Position A / noise 5




Fig. B.25: Position A / noise 6




Fig. B.26: Position A / noise 7




Fig. B.27: Position A / noise 8




Fig. B.28: Position A / noise 9

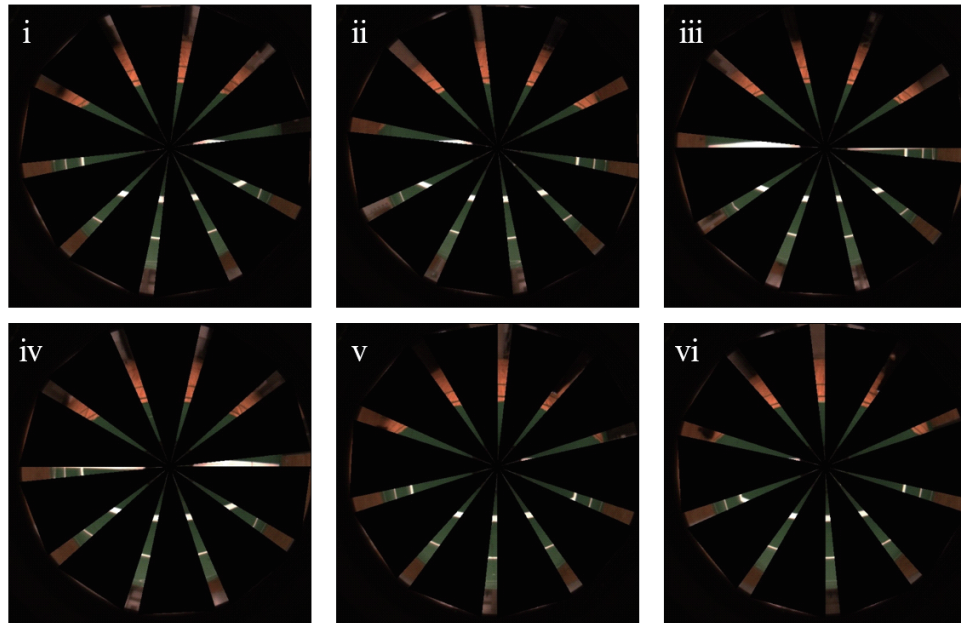


Fig. B.29: Position A / noise 10

Table B.2: Point B noise result

			Noise num									
			1	2	3	4	5	6	7	8	9	10
Noise angle	i	0	14.1	14.1	14.1	14.1	14.1	14.1	14.1	22.4	14.1	646.2
	ii	30	10.0	10.0	10.0	14.1	10.0	14.1	31.6	10.0	496.8	518.7
	iii	60	14.1	14.1	10.0	14.1	22.4	14.1	14.1	14.1	648.5	1164.8
	iv	90	14.1	14.1	14.1	14.1	22.4	14.1	41.2	22.4	14.1	651.9
	v	120	14.1	14.1	14.1	14.1	14.1	14.1	14.1	10.0	14.1	636.9
	vi	150	10.0	14.1	10.0	14.1	14.1	14.1	14.1	14.1	496.8	862.8
	vii	180	14.1	14.1	10.0	14.1	14.1	14.1	22.4	22.4	648.5	646.2
	viii	210	14.1	10.0	14.1	14.1	14.1	14.1	14.1	10.0	14.1	518.7
	ix	240	14.1	14.1	14.1	14.1	10.0	14.1	31.6	14.1	14.1	1164.8
	x	270	14.1	14.1	10.0	14.1	22.4	14.1	10.0	22.4	496.8	651.9
	xi	300	14.1	14.1	10.0	14.1	31.6	14.1	22.4	10.0	648.5	636.9
	xii	330	14.1	14.1	14.1	14.1	14.1	14.1	10.0	14.1	14.1	862.8




Fig. B.30: Position B / noise 1




Fig. B.31: Position B / noise 2




Fig. B.32: Position B / noise 3




Fig. B.33: Position B / noise 4




Fig. B.34: Position B / noise 5




Fig. B.35: Position B / noise 6




Fig. B.36: Position B / noise 7




Fig. B.37: Position B / noise 8




Fig. B.38: Position B / noise 9

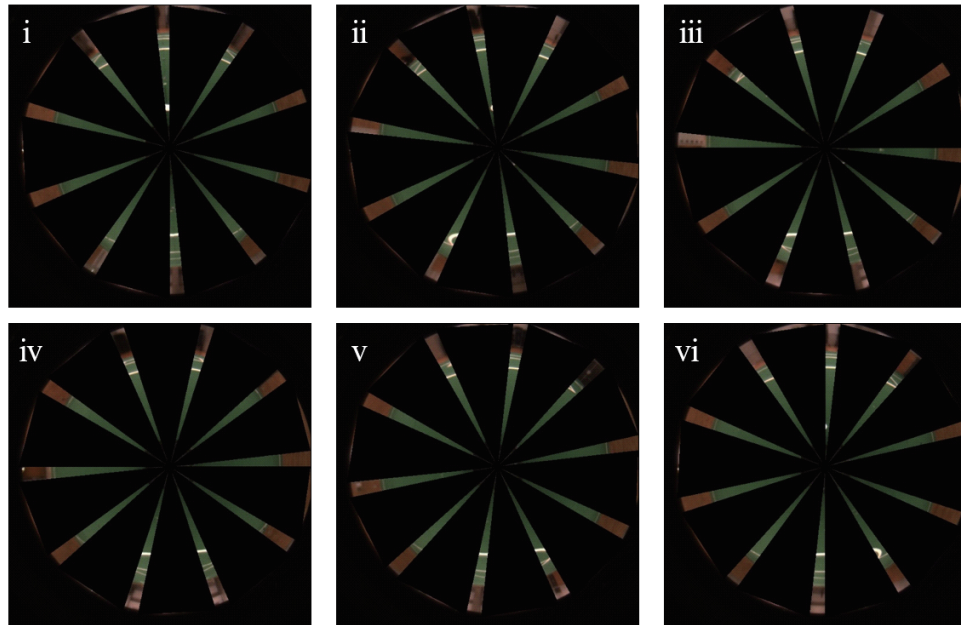


Fig. B.39: Position B / noise 10

Table B.3: Point C noise result

		Noise num										
		1	2	3	4	5	6	7	8	9	10	
Noise angle	i	0	0.0	0.0	0.0	0.0	10.0	0.0	10.0	0.0	0.0	10.0
	ii	30	0.0	14.1	0.0	0.0	14.1	10.0	10.0	10.0	10.0	10.0
	iii	60	0.0	14.1	0.0	10.0	0.0	0.0	10.0	10.0	0.0	10.0
	iv	90	0.0	10.0	0.0	0.0	0.0	10.0	0.0	0.0	14.1	10.0
	v	120	10.0	10.0	0.0	0.0	10.0	0.0	10.0	10.0	0.0	10.0
	vi	150	0.0	0.0	0.0	10.0	0.0	10.0	14.1	10.0	10.0	10.0
	vii	180	0.0	0.0	0.0	0.0	0.0	0.0	10.0	0.0	0.0	10.0
	viii	210	0.0	14.1	0.0	0.0	10.0	10.0	10.0	10.0	14.1	10.0
	ix	240	0.0	14.1	0.0	10.0	0.0	0.0	10.0	10.0	0.0	10.0
	x	270	10.0	10.0	0.0	0.0	0.0	10.0	10.0	0.0	10.0	10.0
	xi	300	10.0	10.0	0.0	0.0	0.0	0.0	0.0	10.0	0.0	10.0
	xii	330	0.0	0.0	0.0	10.0	14.1	10.0	10.0	10.0	14.1	10.0




Fig. B.40: Position C / noise 1




Fig. B.41: Position C / noise 2




Fig. B.42: Position C / noise 3




Fig. B.43: Position C / noise 4




Fig. B.44: Position C / noise 5




Fig. B.45: Position C / noise 6




Fig. B.46: Position C / noise 7




Fig. B.47: Position C / noise 8




Fig. B.48: Position C / noise 9

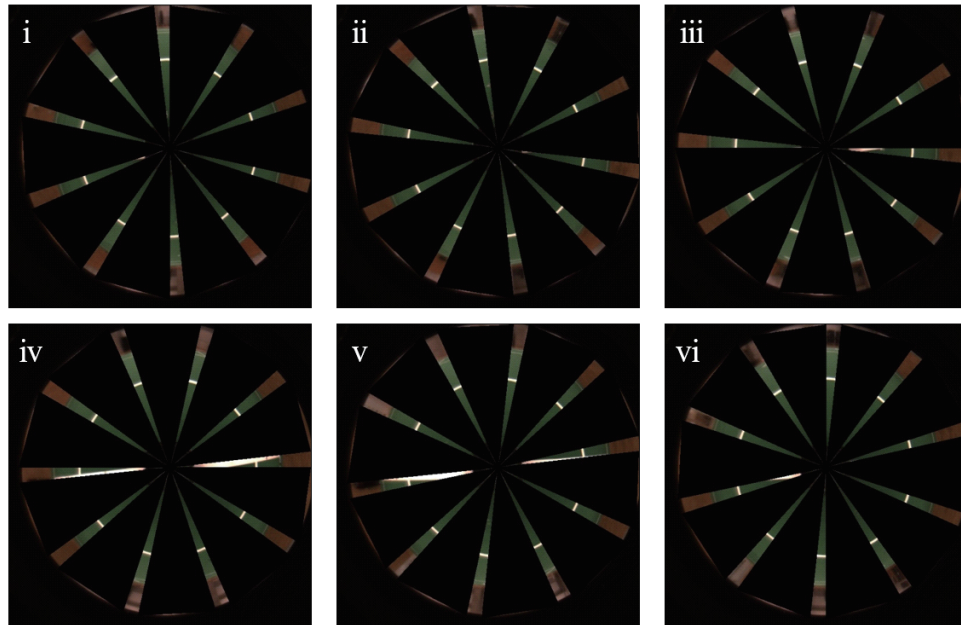


Fig. B.49: Position C / noise 10

Table B.4: Point D noise result

			Noise num									
			1	2	3	4	5	6	7	8	9	10
Noise angle	i	0	10.0	10.0	10.0	20.0	10.0	10.0	20.0	14.1	14.1	270.2
	ii	30	10.0	10.0	10.0	10.0	14.1	10.0	20.0	429.5	260.2	260.0
	iii	60	10.0	10.0	10.0	10.0	10.0	10.0	14.1	425.4	417.9	320.2
	iv	90	20.0	10.0	10.0	20.0	14.1	10.0	10.0	14.1	676.8	1207.8
	v	120	10.0	14.1	10.0	10.0	10.0	10.0	10.0	429.5	14.1	451.8
	vi	150	10.0	10.0	10.0	10.0	10.0	10.0	10.0	425.4	260.2	411.1
	vii	180	10.0	10.0	10.0	20.0	14.1	10.0	10.0	14.1	417.9	270.2
	viii	210	10.0	10.0	10.0	10.0	10.0	10.0	14.1	429.5	676.8	260.0
	ix	240	10.0	10.0	10.0	10.0	14.1	10.0	10.0	425.4	14.1	320.2
	x	270	10.0	10.0	10.0	20.0	10.0	10.0	10.0	14.1	260.2	1207.8
	xi	300	10.0	14.1	10.0	10.0	10.0	10.0	1310.3	429.5	417.9	451.8
	xii	330	10.0	10.0	10.0	10.0	20.0	10.0	10.0	425.4	676.8	411.1




Fig. B.50: Position D / noise 1




Fig. B.51: Position D / noise 2




Fig. B.52: Position D / noise 3




Fig. B.53: Position D / noise 4




Fig. B.54: Position D / noise 5




Fig. B.55: Position D / noise 6




Fig. B.56: Position D / noise 7




Fig. B.57: Position D / noise 8




Fig. B.58: Position D / noise 9

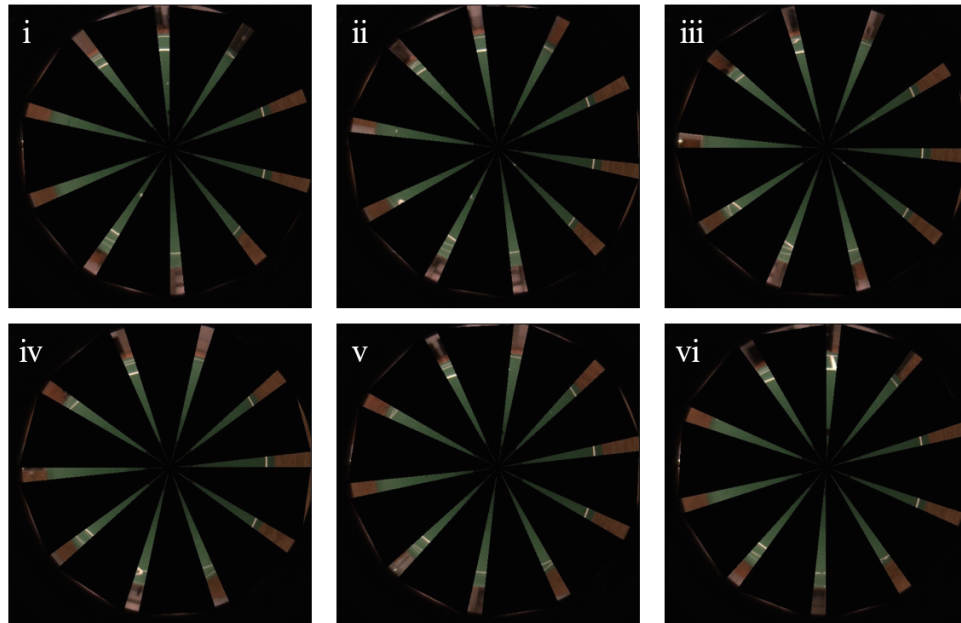


Fig. B.59: Position D / noise 10

Table B.5: Point E noise result

			Noise num									
			1	2	3	4	5	6	7	8	9	10
Noise angle	i	0	0.0	10.0	22.4	58.3	10.0	22.4	20.0	22.4	22.4	10.0
	ii	30	0.0	10.0	14.1	10.0	22.4	14.1	10.0	31.6	10.0	22.4
	iii	60	0.0	22.4	10.0	22.4	22.4	22.4	14.1	22.4	31.6	22.4
	iv	90	0.0	10.0	10.0	58.3	10.0	14.1	22.4	22.4	31.6	10.0
	v	120	0.0	0.0	22.4	10.0	22.4	22.4	10.0	31.6	22.4	20.0
	vi	150	0.0	0.0	14.1	22.4	0.0	14.1	20.0	22.4	10.0	31.6
	vii	180	10.0	10.0	10.0	58.3	1650.5	22.4	10.0	22.4	31.6	10.0
	viii	210	10.0	10.0	10.0	10.0	10.0	14.1	14.1	31.6	31.6	22.4
	ix	240	22.4	22.4	22.4	22.4	22.4	22.4	22.4	22.4	22.4	22.4
	x	270	10.0	10.0	14.1	58.3	14.1	14.1	10.0	22.4	10.0	10.0
	xi	300	0.0	0.0	10.0	10.0	10.0	22.4	22.4	31.6	31.6	20.0
	xii	330	0.0	0.0	10.0	22.4	31.6	14.1	10.0	22.4	31.6	31.6




Fig. B.60: Position E / noise 1




Fig. B.61: Position E / noise 2




Fig. B.62: Position E / noise 3




Fig. B.63: Position E / noise 4




Fig. B.64: Position E / noise 5




Fig. B.65: Position E / noise 6




Fig. B.66: Position E / noise 7




Fig. B.67: Position E / noise 8




Fig. B.68: Position E / noise 9




Fig. B.69: Position E / noise 10

Table B.6: Point F noise result

		Noise num										
		1	2	3	4	5	6	7	8	9	10	
Noise angle	i	0	0.0	14.1	0.0	14.1	10.0	40.0	10.0	40.0	10.0	0.0
	ii	30	10.0	10.0	10.0	0.0	14.1	0.0	20.0	14.1	41.2	370.1
	iii	60	10.0	10.0	41.2	10.0	0.0	40.0	10.0	10.0	31.6	370.1
	iv	90	10.0	0.0	0.0	14.1	14.1	0.0	10.0	40.0	14.1	310.2
	v	120	10.0	30.0	0.0	0.0	10.0	40.0	10.0	14.1	10.0	31.6
	vi	150	0.0	10.0	10.0	10.0	10.0	0.0	10.0	10.0	41.2	320.2
	vii	180	14.1	14.1	41.2	14.1	14.1	40.0	10.0	40.0	31.6	0.0
	viii	210	10.0	10.0	0.0	0.0	0.0	0.0	10.0	14.1	10.0	370.1
	ix	240	10.0	10.0	0.0	10.0	20.0	40.0	20.0	10.0	10.0	370.1
	x	270	0.0	0.0	10.0	14.1	0.0	0.0	10.0	40.0	41.2	310.2
	xi	300	30.0	30.0	41.2	0.0	10.0	40.0	0.0	14.1	31.6	31.6
	xii	330	0.0	10.0	0.0	10.0	10.0	0.0	0.0	10.0	10.0	250.2




Fig. B.70: Position F / noise 1




Fig. B.71: Position F / noise 2




Fig. B.72: Position F / noise 3




Fig. B.73: Position F / noise 4




Fig. B.74: Position F / noise 5




Fig. B.75: Position F / noise 6




Fig. B.76: Position F / noise 7




Fig. B.77: Position F / noise 8




Fig. B.78: Position F / noise 9




Fig. B.79: Position F / noise 10

Table B.7: Point G noise result

		Noise num										
		1	2	3	4	5	6	7	8	9	10	
Noise angle	i	0	10.0	10.0	40.0	10.0	10.0	10.0	280.2	10.0	70.0	20.0
	ii	30	10.0	10.0	10.0	10.0	10.0	10.0	820.1	900.1	890.1	850.0
	iii	60	10.0	10.0	10.0	120.0	10.0	10.0	10.0	870.0	10.0	900.1
	iv	90	10.0	10.0	10.0	10.0	40.0	10.0	30.0	10.0	130.0	900.1
	v	120	10.0	10.0	40.0	10.0	10.0	10.0	10.0	900.1	80.6	900.1
	vi	150	10.0	10.0	10.0	120.0	10.0	10.0	60.8	870.0	890.1	10.0
	vii	180	10.0	10.0	10.0	10.0	40.0	10.0	10.0	10.0	10.0	20.0
	viii	210	10.0	10.0	10.0	10.0	14.1	10.0	10.0	900.1	130.0	850.0
	ix	240	10.0	10.0	40.0	120.0	40.0	10.0	40.0	870.0	70.0	900.1
	x	270	10.0	10.0	10.0	10.0	10.0	10.0	10.0	10.0	890.1	900.1
	xi	300	10.0	10.0	10.0	10.0	10.0	10.0	30.0	900.1	10.0	900.1
	xii	330	10.0	10.0	10.0	120.0	10.0	10.0	790.1	870.0	130.0	10.0




Fig. B.80: Position G / noise 1




Fig. B.81: Position G / noise 2




Fig. B.82: Position G / noise 3




Fig. B.83: Position G / noise 4




Fig. B.84: Position G / noise 5




Fig. B.85: Position G / noise 6




Fig. B.86: Position G / noise 7




Fig. B.87: Position G / noise 8




Fig. B.88: Position G / noise 9




Fig. B.89: Position G / noise 10

業績一覧

学術論文

- [1] 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)
- [2] 渡邊 香, 馬 躍航, 鈴木 秀和, "大域的／局所的探索を利用したサッカーロボットのための自己位置同定法", 電気学会論文誌 C (投稿中)
- [3] 渡邊 香, 馬 躍航, 内田 尚登, 鈴木 秀和, "競技型ロボット教育科目のための教材開発と教育効果の検証", 日本教育工学会論文誌 (投稿中)
- [4] 鈴木 秀和, 森崎 巧一, 渡邊 香, 林原 泰子, 西 仁司, "動物型4脚ロボットにおける歩容生成と印象評価", 知能と情報 (日本知能情報フuzzy学会誌), Vol. 24, No. 5, pp. 1012-1022 (2012)

査読付き国際会議

- [1] 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)
- [2] 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)
- [3] 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)

- [4] K. Watanabe, H. Suzuki, "Gait Learning Method for Stable Motion Using Quadrupedal Robot", Proceedings of The 6th International Workshop on Advanced Computational Intelligence and Intelligent Informatics (IWACIII2019), SUN4-A3 (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)
- [2] K. Watanabe, H. Suzuki, "Real-Time Self-Localization Using a Genetic Algorithm Based on Color Detection", Proceedings of 1st International Symposium for Color Science and Art 2019, pp. 53-54 (2019)

国内発表

- [1] 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)
- [2] 宮代 雄大, 渡邊 香, 鈴木 秀和, "RoboCup ヒューマノイドリーグのための環境情報認識", 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. 131 (2018)
- [3] 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)
- [4] 宮代 雄大, 渡邊 香, 鈴木 秀和, "全方位カメラを用いた特定対象の認識", 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. 229 (2013)
- [5] 渡邊 香, 鈴木 秀和, "法線拡張モデル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. 228 (2013)

- [6] 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)
- [7] 渡邊 香, 鈴木 秀和, ”RoboCup のための基礎的な自己位置同定法の構築”, 第 28 回ファジィシステムシンポジウム講演論文集, TE3-4, pp. 709-710 (2012)
- [8] 渡邊 香, 鈴木 秀和, 森崎 巧一, 林原 泰子, 西 仁司, ”動物型 4 脚ロボットの複合動作における印象評価”, 第 28 回ファジィシステムシンポジウム講演論文集, WE2-1, pp. 219-220 (2012.9)
- [9] 土屋 聖也, 渡邊 香, 鈴木 秀和, 西 仁司, ”動物型 4 脚歩行ロボットの歩容生成と印象評価”, 第 17 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. 98 (2012.3)
- [10] 渡邊 香, 鈴木 秀和, ”RoboCup 中型リーグのための自己位置同定法の構築”, 第 17 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. 11 (2012)
- [11] 渡邊 香, 鈴木 秀和, ”中型リーグのための自己位置同定法の基礎研究”, 第 27 回ファジィシステムシンポジウム講演論文集, MD3-1, pp. 189-190 (2011)
- [12] 渡邊 香, 村田 真大, 鈴木 秀和, ”白線情報を用いた自己位置同定法の検証”, 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. 200 (2011)

謝辞

本研究の遂行及び論文の作成にあたり，終始ご指導，御鞭撻を賜りました鈴木秀和准教授に厚く御礼申し上げます。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電子機械学科教職員各位，及び東京工芸大学工学部電子機械学科ロボットビジョン研究室の皆様に心から感謝の意を表します。

2021年 3月

渡邊 香