

NAIST-IS-MT9651001

修士論文

全方位画像を用いた記憶に基づく
位置推定に関する研究

栗飯原 述宏

1998年2月13日

奈良先端科学技術大学院大学
情報科学研究科 情報システム学専攻

本論文は奈良先端科学技術大学院大学情報科学研究科に
修士(工学)授与の要件として提出した修士論文である。

栗飯原 述宏

指導教官： 横矢 直和 教授
千原 國宏 教授
竹村 治雄 助教授

全方位画像を用いた記憶に基づく 位置推定に関する研究*

栗飯原 述宏

内容梗概

実環境において自己位置を認識することは、ロボットの視覚誘導等において重要な課題である。本論文では、全方位画像を用いた記憶に基づく自己位置推定法を提案する。提案手法では、まず、位置推定に有効な大局的な情報を含む全方位画像から自己相関画像を生成することによって、センサの向きに依らない位置に固有な情報を抽出する。さらに、生成された自己相関画像から固有空間を構成し、固有空間内で最も近接した学習画像を検索することによって位置推定を行なう。また、部分空間法を用いて画像検索のための候補数を削減し、さらに画像の時系列性を利用することによってロバストな位置推定を行なう手法も提案する。実際に屋内および屋外環境で撮影された時系列の全方位画像を用いて実験を行ない、提案手法の有効性を確認した。

キーワード

自己位置推定, 全方位画像, 自己相関, 固有空間

*奈良先端科学技術大学院大学 情報科学研究科 情報システム学専攻 修士論文, NAIST-IS-MT9651001, 1998年2月13日.

Memory-Based Self-Localization Using Omnidirectional Images*

Nobuhiro Aihara

Abstract

This paper proposes a new self-localization method using an omnidirectional image sensor which can observe a surrounding environment with 360-degrees of view. The method extracts information which is identical for the position of a sensor and invariant against the rotation of the sensor by generating an autocorrelation image from an observed omnidirectional image. The location of the sensor is identified by evaluating the similarity among the autocorrelation images in low dimensional eigenspaces. We have conducted experiments with real image sequences and examined the performance of the proposed method. The results show that accurate and robust estimation of the sensor's position is possible.

Keywords:

self-localization, omnidirectional images, autocorrelation, eigenspace

*Master's Thesis, Department of Information Systems, Graduate School of Information Science, Nara Institute of Science and Technology, NAIST-IS-MT9651001, February 13, 1998.

目次

1. はじめに	1
2. 関連研究と本研究の位置づけ	3
2.1 視覚情報を用いた位置推定の従来研究	3
2.2 記憶に基づく位置推定と本研究の方針	6
3. 全方位画像からの位置に固有な特徴の抽出	9
3.1 画像情報の獲得	9
3.2 位置に固有な特徴の抽出	11
3.3 自己相関画像の生成	12
3.4 自己相関画像の改良	15
4. 画像の記憶	20
4.1 固有空間法に基づく画像圧縮	20
4.2 固有空間の構成法	22
5. 画像の類似性に基づく自己位置の推定	25
5.1 擬似画像問題	25
5.2 大局的な位置推定	29
5.2.1 記憶する画像の空間的連続性を考慮したクラス分割	29
5.2.2 入力画像の時系列性を考慮したクラス分類の改良	30
5.3 局所的な位置推定	32
5.4 位置推定の手順	32
6. 実験	34
6.1 画像入力	34
6.1.1 画像入力装置	34
6.1.2 画像の前処理	34
6.2 屋内環境における実験 (建物内の通路において)	36
6.2.1 実験環境	36

6.2.2	実験結果および考察	37
6.3	屋外環境における実験 (学内の外周路において)	45
6.3.1	実験環境	45
6.3.2	実験結果および考察	45
7.	むすび	57
	謝辞	59
	参考文献	60

目 次

3.1	全方位視覚センサ HyperOmni Vision の外観	10
3.2	撮像された全方位画像の例	10
3.3	視覚系の構成	12
3.4	全周パノラマ画像の例	13
3.5	自己相関画像の生成	14
3.6	自己相関画像の例	15
3.7	テンプレート自己相関	17
3.8	テンプレート相互相関	18
3.9	モザイク化	19
4.1	特徴軸の抽出	21
4.2	画像ベクトル	22
5.1	学習多様体	26
5.2	類似性の関係	27
5.3	クラス分割による位置推定性能の向上	28
5.4	位置推定手法の概略	33
6.1	入力画像の前処理方法	35
6.2	全方位画像の撮影環境 (建物内の通路)	36
6.3	実験に用いた全方位画像の例	37
6.4	入力画像と 3 つの固有空間との類似度 (累積余弦)	39
6.5	固有空間の次元数に対する位置推定の正解率	40
6.6	学習画像集合のクラス分割	42
6.7	クラス分割数に対する位置推定の正解率	43
6.8	全方位画像の撮影環境 (学内の外周路)	46
6.9	実験に用いた全方位画像の例	47
6.10	入力画像と 10 個の固有空間 (A~J) との類似度 (累積余弦)	49
6.11	クラス C に対する固有空間内での軌跡	50
6.12	固有空間の次元数に対する位置推定の正解率	51
6.13	クラス分割数に対する位置推定の正解率	54

表 目 次

6.1	3つの自己相関画像に対する位置推定の正解率	41
6.2	位置推定の正解率	44
6.3	3つの自己相関画像に対する位置推定の正解率	52
6.4	クラスに含まれる画像枚数	54
6.5	位置推定の正解率	55

1. はじめに

人間の生活をより豊かなものにするために、ロボットは欠かせない存在になりつつある。工場では、テレビや冷蔵庫、自動車等を組み立てる産業ロボットが昼夜を問わず稼働し、海底や月面等の人間が直接行くのが困難な場所では、人間の代わりに調査を行なう移動ロボットが活躍している。しかし、これまで実用化されてきたロボットは、人間が直接あるいは間接的に操作しなければならないものが殆どであり、自律的に移動したり作業したりするロボットに関しては、まだまだ研究レベルに過ぎないのが現状である。しかし、自律移動ロボットは、監視ロボットや車の自動運転等、様々な分野で要望されており、今後ますます必要性が高まるものと考えられる。

ロボットが自律的に行動するための最も重要なタスクの1つとして、自己位置の認識がある。位置の認識を正確に行なうことができなければ、ロボットを正しくかつ安全に目的地まで誘導することはできない。ロボットの位置を認識するためには周囲の環境情報を獲得することが不可欠であり、超音波センサ、レンジファインダ、視覚センサ等の外界センサが主に使用されている。中でも視覚センサは、1度に多くの情報を獲得でき、また獲得された情報を位置推定以外にも様々な目的に利用できるため有望視されており、近年、視覚情報を用いた様々な位置推定法が提案されている [2-15]。

例えば、画像情報からエッジ情報等の局所的な環境モデルを抽出し、予め獲得しておいた環境全体のモデルと照合することによって位置推定を行なう手法 [5, 6] や、環境の3次元構造を復元することによって得られる距離情報を用いて、環境内での相対的な位置を推定するという手法 [3, 4] が従来よく使用されてきた。しかしこれらの手法は、2次元画像から3次元の環境モデルや環境構造を復元する際に不良設定問題を解く必要があるため誤差が発生しやすく、また計算量も非常に大きくなるという問題がある。

これに対して、記憶に基づく手法が注目を集めている [7-15]。このアプローチでは、予めロボットが移動する領域内で多くの画像をその位置情報とともに記憶しておく。そして、ロボットが移動しながら撮影した画像を記憶した画像集合と照合することによって、ロボットの位置を推定する。この手法は、画像の記憶容

量をいかにして削減するかという問題があるが、2次元画像から3次元情報を抽出する必要が無い場合位置推定処理を高速化することが可能であり、また複雑な環境においても記憶する画像枚数を単純に増やすことで認識性能の向上が期待できる。

そこで本研究では、この記憶に基づくアプローチを採用し、記憶に基づく新しい位置推定法を提案する。提案手法では、位置推定を行なうための画像として、周囲の大局的な視覚情報を含む全方位画像 [16] を使用する。ただし、ロボットの進行方向やセンサの向きによって、得られる画像が見ため上異なるため、ロボットの位置に固有な特徴量を全方位画像から抽出する必要がある。ここで、抽出される特徴量は非常に大きなサイズになるので、情報圧縮の手法として広く普及している固有空間法 [19–26] を用いて、記憶容量と照合コストを削減する。さらに、照合すなわち位置推定の段階においては、大局的および局所的という2段階の推定処理を行なうことにより、ロバストな位置認識を実現する。

各章の概略は以下の通りである。第2章において、関連研究について述べるとともに、本研究の位置づけ、ならびに方針について述べる。

第3章では、本研究で使用する全方位画像の特徴と、入力される全方位画像から位置推定に必要な特徴量を抽出する方法について述べる。

第4章では、全方位画像から抽出された特徴量を、固有空間法を用いてより少ない情報量で記憶する方法について述べる。

第5章では、記憶した画像と入力された画像とを照合させ、その類似性を基に現在位置の推定を行なう方法について述べる。ここでは、類似性を基にした位置推定における問題点を指摘し、これを解決するために本研究で提案する大局的および局所的な2段階の位置推定法について述べる。

第6章では、全方位画像を用いた実験とその結果を示す。実験は屋内および屋外シーンについて行ない、示された実験結果を基に手案手法の有効性を検証する。

最後に第7章で、結論および今後の展望について述べる。

2. 関連研究と本研究の位置づけ

本章では、視覚情報を用いた位置推定の代表的な手法を概観し、本研究の位置づけを明らかにする。移動ロボットが自己の位置を認識するための最も一般的な方法は、車輪エンコーダ等の内界センサを用いた推測航法 (**dead-reckoning**) である。この方法は、低コストで実現できるために広く用いられているが、長い距離を走行するうちに、スリップ等が原因で発生する推定誤差が累積していくという問題がある。

この問題を解決するためには、周囲の環境情報を獲得し、位置推定の誤差を修正する必要がある。環境情報を獲得する手段としては外界センサを用いるのが一般的であり、超音波センサを用いたもの、レンジファインダを用いたもの [1]、視覚センサを用いたもの [2-15] 等、様々な位置推定法が提案されている。中でも視覚センサは、一度に獲得できる情報量が豊富であり、また獲得された画像情報を位置推定以外の様々な目的 (物体認識等) に利用可能であることから有望視されている。そこで本研究では、この視覚センサを用いた位置推定法に着目し、視覚センサを搭載したロボットが移動しながら獲得する画像情報を基に、ロボットの位置を推定することを考える。また本研究では、位置推定には視覚情報のみを用い、ロボットの内界センサの情報は利用しないこととする。

以下では、まず視覚情報を用いて移動ロボットの自己位置を推定するための従来手法について概観する。次に、本研究で採用する記憶に基づく位置推定法について考察し、本論文で提案する手法の概略を示す。

2.1 視覚情報を用いた位置推定の従来研究

視覚情報を用いた位置推定の従来手法としては、

- ランドマークを用いた手法
- 3次元環境を復元する手法
- モデルマッチングを用いた手法
- 記憶に基づく手法

等が挙げられる。以下では、これらの手法の特徴および問題点について述べる。

ランドマークを用いた手法

ランドマークを用いた手法とは、位置情報の付加されたランドマークを予め環境内に人為的に配置しておき、獲得される画像からランドマークを抽出することによって位置を認識するというものである [2]。

この手法は、視覚情報を用いて位置推定を行なうための最も簡単な解決法であるが、ランドマークが常に観測可能でなければならず、障害物が多く存在する様な環境で使用することは困難である。また、予め環境に手を加えておかなければならないという問題もある。

3次元環境を復元する手法

3次元環境を復元する手法とは、画像情報から環境の3次元構造を復元し、その距離情報を基に環境内での自己位置を認識するというものである。環境の3次元構造を復元する手法としては、2枚の全方位画像からステレオ視を用いて環境の奥行き情報を抽出するもの [4]、全方位の動画像からオプティカルフローを検出し、ロボットの自己運動パラメータと環境の3次元構造を同時に推定するもの [3] 等が提案されている。

この手法は、未知環境においても自己位置の認識が可能であるが、計算コストが高く、またノイズの影響を受けやすい等の問題がある。

モデルマッチングを用いた手法

モデルマッチングを用いた手法とは、画像情報から局所的な環境の特徴モデルを抽出し、予め獲得しておいた環境全体のモデルと対応させることによって環境内の自己位置の認識を行なうというものである。CADモデルで表現される様な屋内環境においては、壁や柱等のエッジ情報をその特徴モデルとして、また、DEM(Digital Elevation Map)モデルで表現される様な屋外環境においては、稜線等の曲線情報をその特徴モデルとして使用する手法が一般的である。特徴モデルの全ての組合せに対してこの対応問題を解くことは計算量の点から困難である

ため、実際には、同時に観測することができない特徴モデルの組合せを予め削除しておく等の、何らかの幾何的な制約を設けることによって、解の探索空間を削減する手法が用いられる [5, 6].

この手法は、モデルの対応づけさえ正確に行なうことができれば位置推定の強力な手段になり得る。しかし、一般に安定した特徴モデルの抽出は困難であり、特徴モデル数の増加に伴い対応づけに必要な計算量が大きく増加するという問題がある。

記憶に基づく手法

記憶に基づく手法とは、様々な場所で撮影された画像、あるいはそれらの画像情報に何らかの加工を施したものをそのまま記憶しておき、ロボットによって獲得された画像 (あるいはそれを加工したもの) と記憶した情報とを直接照合することによって、位置の推定を行なうというものである。

この手法は、適切なランドマーク等が抽出できない様な複雑な環境においても、記憶する画像枚数を単純に増やすことで認識性能の向上が期待できるが、記憶する画像の容量と画像の照合に必要な計算コストをいかにして削減するかということが課題となる。

この問題を解決するために、様々な位置推定法が提案されてきた。例えば、入力される視野画像列においてある閾値以上の変化がある画像のみを記憶し、テンプレートを用いた相関演算により照合を行なう手法 [9] や、画素値の平均を特徴量とすることで大幅に画像情報を削減した全方位画像を記憶し、動的計画法を用いて画像を照合する手法 [11, 12] がある。これらの手法は、記憶する情報量の少なさを画像の時系列性で補っているため、記憶した行動パターンと基本的に同じ (または類似した) 行動をする場合にしか位置推定を行なうことができない。

これに対してロボットの行動パターンに制限を設けない方法として、全方位画像をフーリエ変換することで位置に固有な特徴を抽出し、その低周波成分を記憶および照合に用いる手法 [8] がある。しかし、1枚につき 64×32 画素という記憶容量を必要とし、大量に記憶することは困難である。画像の記憶容量を削減するために固有空間法を用いる手法 [10] もあるが、複数方向の観察結果を統合するこ

とによってロボットの位置を推定するため、位置推定に必要な計算量が非常に大きくなるという問題がある。

以上の手法のうち、記憶に基づく手法は、様々な位置におけるあらゆるセンサ情報を記憶することができれば、環境に依存しないロバストな位置推定法になり得るため、最近非常に注目されている。次節では、本研究で対象とする記憶に基づく手法について考察し、本研究の方針について述べる。

2.2 記憶に基づく位置推定と本研究の方針

本研究では、自律移動ロボットの自己位置を推定するために、記憶に基づく認識法を適用することを考える。記憶に基づく認識法による自己位置推定においては、

1. どの様な画像情報を記憶するか、
2. 記憶する画像の容量や照合に必要な計算コストをいかにして削減するか、
3. 画像が類似していることと位置が近接していることが必要十分条件であることをどの様にして保証するか、

の3つの点が問題になると考えられる。以下では、この3点について、本研究でそれぞれどの様に対処するかについて述べる。

使用する画像情報

本研究では、位置推定を行なうための画像として全方位画像 [16] を用いる。全方位画像を用いることにより、位置推定のために有用なロボットの周囲の大局的な視覚情報を得ることが可能になる。ただし、ロボットの進行方向やセンサの向きによって得られる画像が見かけ上異なるため、ロボットの位置に固有な情報を抽出する必要がある。本論文では、3章において、全方位画像の取得方法を示すと同時に、全方位画像から自己相関画像を生成することによる位置に固有な情報の抽出法を提案する。生成された自己相関画像は記憶および照合のための特徴量として用いられる。

画像の記憶容量と照合コストの削減

記憶する画像の容量や照合に必要な計算コストの削減のためには、情報圧縮の一般的な手法である固有空間法を用いる。一般に、認識のロバスト性を高めるためには冗長性を増す必要がある。このため、データの冗長な部分を削除することによって記憶容量を削減することは、ロバストな位置認識を行なう上で好ましくない。そこで本研究では、冗長性を増すために連続した画像系列を使用し、冗長性を含んだそれらのデータ集合を、その情報量ができるだけ失われない様に圧縮記憶することが可能な固有空間法を用いる。固有空間法は、画像を多次元空間の1点とみなし、画像集合において個々の画像を識別するための特徴軸を Karhunen-Loève 展開に基づいて求めるものであり、認識の精度を下げることなく記憶する画像の容量を大幅に削減することができるという特長を持っている。

固有空間法は、顔画像認識 [19, 23, 24] や画像検索 [20, 25] 等のパターン認識の分野で広く用いられてきた手法である [40] が、最近になって、パラメトリック固有空間法 [27] と呼ばれる手法が提案され、物体の向き等のパラメータ検出にも応用されてきている。パラメトリック固有空間法は、パラメータ (物体の姿勢や光源の位置) を少しずつ変化させながら撮影した画像系列を用いて固有空間内に多様体を構成し、入力画像とその多様体を照合させることによって物体の向き推定等を行なうというものであり、物体の姿勢検出 [28, 29]、ロボットの位置推定 [10]、物体抽出 [30] 等で、その有効性が報告されている。本研究でも、基本的にこのパラメトリック固有空間法の考え方を利用し、これをロボットの位置推定に適用する。

本論文では、全方位画像から生成した自己相関画像の容量を、固有空間法を用いて削減する手法を 4 章で述べる。

画像の類似性と位置の近傍性の結び付け

画像の類似性の評価に基づいて記憶に基づく位置推定を行なう場合、画像の類似性と撮影位置の近傍性が必ずしも結び付かないことが問題となる [10]。すなわち、撮影された画像が仮に類似していたとしても、それらの画像が撮影された位置が近接しているとは限らず、遠く離れた場所が偶然似通った景色を持つ場合も

ある。この問題は、撮影位置の数を増やすにしたがって類似度の判定を行なう候補数が増加していくため、避けることが困難になってくる。

このため本研究では、記憶する画像集合をいくつかのクラスに分割し、入力画像がどのクラスに属するかを先に決定することによって、類似度判定のための候補を削減する手法を提案する。クラスの分割およびクラスの決定のためには、文字認識 [32–34] や顔認識 [35] 等のパターン分類問題において広く用いられている部分空間法 [31, 38] を使用する。

本論文では、5章において、部分空間法を用いてクラス決定を行なう手法について述べ、さらに、ロボットの移動の時間的空間的連続性を利用することにより、クラス決定のロバスト性を向上させる手法を提案する。

3. 全方位画像からの位置に固有な特徴の抽出

本章では、入力される画像情報から、位置推定のために必要な特徴量を抽出する方法について述べる。位置推定を行なうためには、周囲の環境情報を知ることが必要である。一般に、1枚の画像情報からだけでは距離情報を正確に復元することができないため、その画像が局所的な環境情報しか含まない様な場合には、環境内での自己位置を認識することは困難になる。このため、ステレオ画像、時系列画像等の複数の画像を用いて環境の3次元構造を復元する方法がよく用いられる。しかし、全周囲の環境情報を利用することができれば、環境が既知であるという条件の下、1枚の画像内に含まれる環境との相対的な位置関係からだけでも、ロボットの位置を推定することが可能であると考えられる。そこで本研究では、位置推定のために周囲360度の大局的な情報を含む全方位画像を使用する。

以下では、位置推定のために従来使用されてきたいくつかの画像情報について概観し、本研究で使用する全方位画像の特徴と、画像から位置に固有な情報を抽出する方法について述べる。

3.1 画像情報の獲得

位置推定を行なうための画像情報としては、通常のカメラ画像 [7, 9, 10], 垂直スリット画像を時間軸に沿って並べたパノラマ画像 [13], 全方位画像 [8, 11, 12] 等が使用されている。通常のカメラ画像を用いた場合、環境内のある方位に対する局所的な情報しか一度に獲得できないため、カメラ方向が異なれば、たとえ同じ位置で撮影されたものであっても画像は変化してしまう (例えば、同一通路内での行きと帰りでは撮影される画像は異なる)。従って、一方向のみを観測するだけでは、カメラ方向のずれ等により位置推定が困難になることが予想される。これを解決するためには、同じ位置で複数の方向の画像を撮影し、その観測結果を統合すればよい [10] が、位置推定に時間がかかるという問題がある。

時系列のパノラマ画像を用いた場合は、この画像自体が時系列性を含む表現になっているため、学習した経路を再び辿るのであれば、記憶したパターンと入力されたパターンの出現順序が変化しないという拘束条件の下で安定した照合を行な



図 3.1 全方位視覚センサ
HyperOmni Vision の外観



図 3.2 撮像された全方位画像の例

うことができる。しかし，途中で停止や逆走等の動作が入ると照合は困難になる．一方，全方位画像は周囲 360 度の視野情報を有するため，

- 同一位置で撮影された画像は同一の情報を含む，
- 1 枚の画像内に位置推定に必要とされる大局的な情報を含む，
- 環境の局所的な変動による画像変化の影響を，変化していない部分の画像情報を用いて吸収できる可能性が高い，

という性質を持ち，位置推定に適していると考えられる．

そこで本研究では，全方位視覚センサ HyperOmni Vision [17] を使用して取得した全方位画像を用いて位置推定を行なう．HyperOmni Vision は鉛直下向きの変曲面ミラーと鉛直上向きのカメラで構成された視覚センサで，周囲 360 度の大局的な視野領域が実時間で得られるという特徴がある．HyperOmni Vision の外観を図 3.1 に，実際に取得された全方位画像の例を図 3.2 に示す．

3.2 位置に固有な特徴の抽出

図 3.2 に示す様な全方位画像は、移動ロボットの向きが異なる場合、すなわちセンサ軸を中心としてカメラが回転している場合には、たとえ同一位置で撮影されていても見かけ上異なる画像になってしまう。この問題に対する最も単純な解決策として、撮影位置毎に少しずつ回転させた画像を作成し、それらを全て記憶する方法が考えられるが、記憶容量や照合のための計算コストの点から望ましくない。

そこで本研究では、全方位画像からセンサ位置に固有な (すなわちセンサ軸まわりの回転に不変な) 特徴量を抽出することを考える。提案する特徴量は、撮影された 1 枚の全方位画像を少しずつ回転させながら、元の画像と回転させた画像との相関 (自己相関) 値を順次計算することによって求める。本研究では、求められた相関値の組を自己相関画像と呼ぶことにする。

自己相関画像は、同じ場所で撮影された全方位画像から生成されたものであれば、センサ軸まわりの回転に対して不変であるという性質を持つ。このことから、移動ロボットが撮像した全方位画像から自己相関画像を生成し、それに最も類似した画像を記憶した自己相関画像の集合の中から検出することによって、検出した自己相関画像に付加された位置情報を基にロボットの位置を推定することが可能となる。ただし、全方位画像を回転させながら相関値を求めるためには、画像をある一定の角度だけ回転させる度に画像中の全ての画素に対応する輝度値を計算し直すことが必要であり、その計算コストは膨大なものになる。このため本研究では、全方位画像を全周パノラマ画像に変換し、それを視野の水平方向にシフトさせながら相関値を求めていくという手法をとる。また、相関値は全周パノラマ画像の各水平ライン毎に計算する。次節では、具体的な自己相関画像の生成手法について述べる。

3.3 自己相関画像の生成

本節では、撮像された全方位画像を全周 (円筒) パノラマ画像に変換する方法、変換された全周パノラマ画像を用いて自己相関画像を生成する方法についてそれぞれ述べる。

全周パノラマ画像の作成

全方位視覚センサ HyperOmni Vision は図 3.3 に示す様に、 Z 軸を鉛直軸とする 3次元座標系 $O-XYZ$ において、鉛直下向きに設置した双曲面ミラーと鉛直上向きに設置したカメラから構成される。図 3.3 において、 b は双曲面の形状を定義する定数、 c は原点 O からミラーの焦点 O_M までの距離をそれぞれ示している。また、 f はカメラのレンズ中心 O_C から画像面までの焦点距離である。




図 3.3 視覚系の構成

HyperOmni Vision の光学特性より、3次元空間内の任意の点 $P(X, Y, Z)$ と全方位画像上の写像点 $p(x, y)$ の間には、式 (3.1) で示す様な対応関係がある [18].



(a) ある位置で撮像された全周パノラマ画像



(b) カメラを 120 度回転させて撮像された全周パノラマ画像

図 3.4 全周パノラマ画像の例

$$\begin{aligned}
 x &= X \times f \times \frac{(b^2 - c^2)}{(b^2 + c^2)Z - 2bc\sqrt{X^2 + Y^2 + (Z + c)^2}} \\
 y &= Y \times f \times \frac{(b^2 - c^2)}{(b^2 + c^2)Z - 2bc\sqrt{X^2 + Y^2 + (Z + c)^2}}
 \end{aligned} \tag{3.1}$$

式 (3.1) において、点 $P(X, Y, Z)$ の自由度を Z 軸を中心とした円筒面に制限すれば、円筒面上 (すなわち全周パノラマ画像上) の点に対応する全方位画像上の点 $p(x, y)$ を求めることができる。この処理により、撮像された全方位画像を全周パノラマ画像に変換することが可能であり、このとき生成される全周パノラマ画像はミラー焦点から見た円筒面への透視投影画像となっている。実際に生成された全周パノラマ画像の例 (ミラー焦点からの俯角: $-11 \sim 54$ 度) を、図 3.4 に示す。

自己相関画像の生成

次に、全周パノラマ画像から自己相関画像を生成する方法について述べる．全周パノラマ画像の n ライン目の水平方向の画素ベクトルを $\mathbf{v}_n = (v_{n1}, \dots, v_{nM})$ とすると、各水平画素ベクトル \mathbf{v}_n に対する自己相関関数 $r_n(k)$ は、次式によって求められる [39]¹．

$$r_n(k) = \frac{\sum_{m=1}^M (v_{nm} - \bar{v}_n)(v_{n(m+k)} - \bar{v}_n)}{\sum_{m=1}^M (v_{nm} - \bar{v}_n)^2} \quad (k = 1, \dots, M) \quad (3.2)$$

ここで、 \bar{v}_n は \mathbf{v}_n の全ての要素の平均値である．式 (3.2) は、 $r_n(k)$ がベクトル \mathbf{v}_n とその各成分を k 画素シフトさせたベクトルとの正規化自己相関値であることを示しており、 $-1 \sim 1$ の値をとる．全周パノラマ画像の全てのラインについて式 (3.2) の処理を行なうことにより、 $M \times N$ の全周パノラマ画像から、成分数 M の自己相関ベクトルを水平画素ベクトルとして持つ $M \times N$ の自己相関画像が生成される (図 3.5)．





図 3.5 自己相関画像の生成

ただし、自己相関ベクトルの対称性のため、 $1 \sim \frac{M}{2} - 1$ 成分と $\frac{M}{2} + 1 \sim M - 1$ 成分は折り返された値になることと、第 M 成分が常に 1 になることから、実際には $\frac{M}{2} \times N$ の部分画像だけを考慮すればよい．図 3.4 の 2 つの全周パノラマ画

¹自己相関関数の計算は、フーリエ変換を用いることで高速化できる [41]



(a) 図 3.4(a) に対する自己相関画像



(b) 図 3.4(b) に対する自己相関画像

図 3.6 自己相関画像の例

像に対して求めた自己相関画像を、相関値が大きいほど輝度値が高くなる様に表示したものを図 3.6 に示す。ここで、図 3.4 の 2 つの全周パノラマ画像は、同一位置で撮像されたものであるが、センサ軸回りの回転によって見かけ上異なる画像となっている。しかし、生成される自己相関画像は非常に類似したものになっていることが分かる。

3.4 自己相関画像の改良

前節では、全周パノラマ画像から自己相関画像を生成する手法について述べた。しかし、前節の手法は水平ライン毎に自己相関関数を計算しているため、センサの僅かな傾きや振動により生じる高さ方向のずれによって自己相関画像は変化してしまう。そこで、その様な高さ方向の微小な変化による影響を吸収するために、

3つの異なる自己相関画像作成法を提案する．ここで提案する手法は全て前節の手法を基準としたものであるが，数ラインを1まとめにして構成されるテンプレート（あるいはブロック）という概念を導入することで，高さ方向を考慮した自己相関画像作成法となっている．

以下では，提案する3つの手法の概略についてそれぞれ説明する．また，これらの手法が位置推定性能にどのような効果を与えるかということに対する定量的な評価については，6章で実験結果により示す．

テンプレート自己相関を用いた手法

テンプレート自己相関を用いた手法とは，図 3.7 に示す様に， P 本のラインベクトルで構成されるテンプレートを全周パノラマ画像の上から下まで逐次更新していきながら，各テンプレートの水平方向への自己相関関数を計算していくというものである．このとき得られるテンプレートの数は全部で $(N - P + 1)$ 個であり，そのうちの n 番目のテンプレートを $T_n(x, y)$ ($x = 1, \dots, M, y = 1, \dots, P$) とすると， $T_n(x, y)$ に対する自己相関関数 $r_n(k)$ は次式によって求められる．

$$r_n(k) = \frac{\sum_{x=1}^M \sum_{y=1}^P (T_n(x, y) - \bar{T}_n)(T_n(x+k, y) - \bar{T}_n)}{\sum_{m=1}^M \sum_{y=1}^P (T_n(x, y) - \bar{T}_n)^2} \quad (3.3)$$

$$(k = 1, \dots, M)$$

ここで， \bar{T}_n はテンプレート $T_n(x, y)$ の全ての画素値の平均である． $(N - P + 1)$ 個のテンプレート全てについて式 (3.3) の処理を行なうことによって， $M \times (N - P + 1)$ の自己相関画像が得られる．しかし，生成される自己相関画像の対称性のため，実際に考慮するのはその半分の領域だけでよい．この手法を用いて作成された自己相関画像を，以下では $AutoCor^{(P)}$ と表記する．

テンプレート自己相関を用いた手法は，前節で述べた手法を高さ方向の画素変化による影響を吸収する様に拡張したものであり， $P = 1$ とすれば前節の手法と等価なものになる．すなわち，前節の手法を用いて作成された自己相関画像は $AutoCor^{(1)}$ として表される．

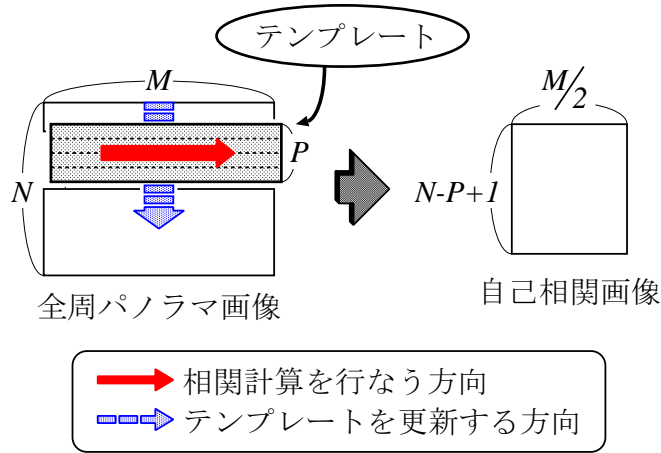


図 3.7 テンプレート自己相関

テンプレート相互相関を用いた手法

テンプレート相互相関を用いた手法とは、図 3.8 に示す様に、 P 本のラインベクトルで構成される基準テンプレートを設定し、これを全周パノラマ画像内で上下左右にシフトすることによって、基準テンプレートと部分パノラマ画像との相互相関値を逐次計算していくというものである。この手順は、全周パノラマ画像と基準テンプレートとの間で、正規化相関値基準を用いたテンプレートマッチング処理を行なう際の手順に等しい。具体的には、基準テンプレートを $T(x, y)$ ($x = 1, \dots, M, y = 1, \dots, P$)、全周パノラマ画像を $I(x, y)$ ($x = 1, \dots, M, y = 1, \dots, N$) とすると、 $T(x, y)$ を $I(x, y)$ 上で (k, l) 画素だけシフトした時の相互相関関数 $r(k, l)$ は、次式を用いて求められる。

$$r(k, l) = \frac{\sum_{x=1}^M \sum_{y=1}^P (I(x, y) - \bar{I}_{k,l})(T(x+k, y+l) - \bar{T})}{\sqrt{\sum_{m=1}^M \sum_{y=1}^P (I(x, y) - \bar{I}_{k,l})^2} \sqrt{\sum_{m=1}^M \sum_{y=1}^P (T(x, y) - \bar{T})^2}} \quad (3.4)$$

$$(k = 1, 2, \dots, M; l = 1, 2, \dots, N - P + 1)$$

ここで、 \bar{T} は基準テンプレートの全ての画素値の平均である。また、 $\bar{I}_{k,l}$ は基準テンプレートを (k, l) 画素だけシフトさせた時に、全周パノラマ画像上で対応




図 3.8 テンプレート相互相関

する $M \times P$ の部分画像の画素値の平均である．式 (3.4) の処理を行なうことによって， $M \times (N - P + 1)$ の自己相関画像が得られる．この手法を用いて生成された自己相関画像を，以下では $CrossCor^{(P)}$ と表記する．

テンプレート相互相関を用いた手法では，どのテンプレートを基準にするかという問題がある．ここで，ミラーの焦点と同じ高さにある（すなわち俯角 0 度の）環境内の点は，全周パノラマ画像内では常に同じライン (K とする) 上に射影されるという性質がある．このため，ロボットが水平面内を移動している限り，ライン K 上で主に発生する画像変化は横方向へのシフトのみである．これは，ライン K 以外では高さ方向へのシフトも発生することを考えると，ロボットの移動に伴う画像変化が比較的小さいことを意味しており，ここでは，このライン K を含めた P 本のラインベクトルで構成されるテンプレートを基準テンプレートとする．

この手法を用いて生成される自己相関画像は，高さ方向の画像変化による影響を吸収するだけでなく，高さ方向の相関関係を積極的に利用したものになっている．ただし，求められた自己相関画像には前節で示した様な対称性がないため，横のサイズは全周パノラマ画像と同じ M のままとなる．

モザイク化を用いた手法

この手法は、上述した2つの手法の様に高さ方向の画素を考慮して相関関数を計算するのではなく、相関関数を求める前に、予め高さ方向および水平方向の平滑化を行なっておくというものである。具体的には、図3.9に示す様に、予め全周パノラマ画像を $P \times P$ のブロック毎に分割しておき、全てのブロックをそれが含む画素値の平均で置き替える。すなわち、平滑化された画像のサイズは縦、横ともに全周パノラマ画像の $\frac{1}{P}$ になる。そして、平滑化された全周パノラマ画像に対して3.3節の処理を施すことによって、 $\frac{M}{P} \times \frac{N}{P}$ の自己相関画像が得られる。ただし、自己相関画像の対称性のため、実際に考慮する必要があるのはその半分の領域だけである。この手法を用いて作成された自己相関画像を、以下では $MosCor^{(P)}$ と表記する。




図 3.9 モザイク化

4. 画像の記憶

本章では、前章で述べた手法を用いて生成された自己相関画像の集合を、より少ない情報量で記憶する方法について述べる。前章の方法により、1枚の全方位画像から1枚の自己相関画像が生成される。ただし、自己相関画像をそのまま記憶すると、記憶容量や照合のための計算コストが膨大になってしまう。そこで、この様な自己相関画像の集合から識別に有用な特徴パラメータを抽出し、より簡潔に表現することが望ましい。

本研究では、実環境中で空間的に連続した位置で撮影された全方位画像を、記憶する学習画像集合として使用する。このため、これらの全方位画像から生成される自己相関画像の集合は、互いに相関の強いものになっていると考えられる。こうした相関の強い画像集合から効率良く特徴を抽出する手法として、固有空間法がある。

以下では、固有空間法に基づく特徴抽出の基本原理を説明するとともに、与えられた画像集合から1つの固有空間を構成する方法について述べる。

4.1 固有空間法に基づく画像圧縮

固有空間法は、多数のサンプルデータ間の相関関係を解析することにより、少ないパラメータで元のサンプルデータ全体を表現するという、線形な特徴抽出法であり、この基本原理は主成分分析と等価である。具体的には、Karhunen-Loève展開 (KL 展開) に基づいて求められた特徴軸を正規直交基底とし、そのうちの主要な (データの分散が大きい) 基底を用いて構成される低次元の正規直交部分空間 (特徴空間) にデータを射影することによってデータ量を圧縮する。

KL 展開に基づく正規直交基底は、サンプルデータの平均座標点を基点として、分散の大きな方向を示すベクトルから順に固有値問題を解くことによって求めていく。このベクトルはサンプルデータ集合の共分散行列から求められる固有ベクトルであるため、これらのベクトルで張られる部分空間は固有空間と呼ばれる。

実際に、2次元平面上にサンプルデータが散在している場合の例を用いて、KL 展開に基づく特徴軸抽出の概念について示す (図 4.1)。図 4.1 に示す様に、サン

プルデータが 2 次元 (x, y) 空間内の点の集合として与えられているとする。このとき、このデータ集合に対して KL 展開を行なうということは、2 次元 (x, y) 空間内のサンプルデータを、その空間を構成する正規直交基底 (x 軸, y 軸) を適当にシフトおよび回転させることによって得られる新たな 2 次元 (x', y') 空間内のデータとして表現し直すことに相当する。ここで、基底のシフトおよび回転パラメータは、各基底がデータ分散の大きい方向から順に選択されていく様に決定される。

データの分散が小さい基底 (図 4.1 の例では y' 軸) は、そのデータ集合を表現する際にあまり重要ではない特徴軸だと考えることができるため、削除してしまってもデータの近似に実質的に問題がない。この様に、空間の次元数を削減することでデータの圧縮を行なうことを固有空間法と呼び、圧縮された正規直交部分空間を固有空間と呼ぶ。固有空間法によって抽出されたこれらの特徴軸は、固有空間の作成に用いられた個々の画像を識別するために有効な特徴軸である。

一般に、固有空間は元の画像空間に比べてかなり低い次元の部分空間として構成できるため、元のサンプルデータを固有空間に射影することによって、データ量の大幅な圧縮が可能になる。このデータ圧縮は、元のサンプルデータと圧縮データから再構成されたデータとの差の 2 乗和を最小にすることが知られている [39].




図 4.1 特徴軸の抽出

4.2 固有空間の構成法

本節では、KL 展開に基づく特徴抽出法を画像集合に適用し、固有空間を構成する方法について述べる。

L 枚の画像からなる画像集合 \mathbf{S} を考える。各画像を、画素の輝度値を要素に持つ画像ベクトル Φ_j ($j = 1, \dots, L$) とする。画像内の画素数を n とすれば、画像ベクトル Φ_j は以下の様に、 n 次元空間内の点として表現される (図 4.2)。

$$\Phi_j = (x_1, \dots, x_n)^T \quad (j = 1, 2, \dots, L) \quad (4.1)$$




図 4.2 画像ベクトル

このとき、画像集合 $\{\Phi_j\}$ に対する固有空間 \mathbf{E} は、以下の様にして求められる。まず、画像集合 \mathbf{S} の $n \times n$ 共分散行列 \mathbf{C} を求める。

$$\mathbf{C} = \frac{1}{L} \sum_{j=1}^L (\Phi_j - \bar{\Phi})(\Phi_j - \bar{\Phi})^T \quad (4.2)$$

ここで、 $\bar{\Phi}$ は $\{\Phi_j\}$ ($j = 1, \dots, L$) の平均ベクトルである。

$$\bar{\Phi} = \frac{1}{L} \sum_{j=1}^L \Phi_j \quad (4.3)$$

次に、以下の固有方程式

$$\begin{aligned} \mathbf{C}\mathbf{u}_k &= \lambda_k \mathbf{u}_k \quad (k = 1, 2, \dots, L-1, L, \dots) \\ \lambda_1 &\geq \lambda_2 \geq \dots \geq \lambda_{L-1} \geq \lambda_L \geq \dots \end{aligned} \quad (4.4)$$

を解くことによって、固有値 λ_k 、ならびに固有ベクトル \mathbf{u}_k を求める²。一般に、 n (画像の次元数) $\gg L$ (画像の枚数) であるため、共分散行列の *rank* は $L-1$ となる³。このため、 λ_L 以降の固有値はほぼ 0 となり、それらの固有値に対応する固有ベクトルについては考慮する必要はない。従って、 $\nu_{nk} = (\Phi_j - \bar{\Phi})^T \mathbf{u}_k$ とすれば、画像ベクトル Φ_j の KL 展開は、

$$\Phi_j = \bar{\Phi} + \sum_{k=1}^{L-1} \nu_{jk} \mathbf{u}_k \quad (4.5)$$

と表される。

このとき、値の大きな固有値に対応する固有ベクトルほど、与えられた画像ベクトル集合を識別するために、すなわち各画像ベクトルを表現するために有用なベクトルである。このため、画像ベクトル Φ_j は、固有値の大きい上位 K 個の固有ベクトルを用いて

$$\Phi_j \approx \tilde{\Phi}_j = \bar{\Phi} + \sum_{k=1}^K \nu_{jk} \mathbf{u}_k \quad (4.6)$$

²実際には特異値分解 [36] を用いることにより、 $L \times L$ 行列の固有値問題に帰着できる。

³共分散行列ではなく相関行列を用いた場合は、*rank* は L となる。

と近似できる．一般にこの K 次元の近似は，元の n 次元データ Φ_j と近似データ $\tilde{\Phi}_j$ との 2 乗誤差を最小にするという意味で最適であることが知られている．

このとき，この K 個の固有ベクトルを正規直交基底として構成される部分空間が固有空間 E であり，式 (4.6) は，平均ベクトル $\bar{\Phi}$ を原点とする K 次元の固有空間へ画像ベクトル Φ_j を射影することを意味している．すなわち各画像は，本来の n 次元の空間に比べて低い K 次元の固有空間内の点として表現される．この結果， n 次元空間での類似度計算を K 次元空間での類似度計算に置き換えることができるため， K の値を小さく設定することによって画像サイズと計算量の大幅な削減が可能となる．

5. 画像の類似性に基づく自己位置の推定

本章では、記憶された学習画像と入力された画像とを照合し、その類似性を基に現在位置の推定を行なう手法について述べる。

前章で述べた固有空間法を用いることにより、記憶しておいた画像集合から効率よく類似画像を検索することが可能になる。しかし、たとえ固有空間内で類似した画像であっても、実環境中での撮影位置が実際に近接しているとは限らない。例えば、遠く離れた場所が偶然似通った景色を持つ場合、画像の類似性を基に位置推定を行なうだけでは誤った学習画像を検出してしまふ恐れがある。

そこで本研究では、学習画像集合をいくつかの部分画像集合 (クラス) に分割し、入力画像がどのクラスに属するかを最初に決定することによって、誤った学習画像候補を大幅に削減することを提案する。そして、分類されたクラス内での距離を基に、入力画像に類似した学習画像を検出することによって位置推定を行なう。前者の方法は大局的な位置推定を行なうことに、また後者の方は局所的な位置推定を行なうことにそれぞれ相当する。

以下では、提案する位置推定方法が上述の問題をいかにして回避するかについて述べ、その2段階の推定処理について詳しく説明する。

5.1 擬似画像問題

画像の類似性に基づく位置推定の問題点

本研究では、床面あるいは地面、すなわち2次元平面上でのロボットの移動を考える。このため、空間的に連続した位置で撮影された学習画像集合は、互いに類似したものになっていると考えられる。一般に、類似した画像は固有空間に射影しても近接している [28] ことから、連続的に類似した学習画像集合は固有空間内において、実環境中での位置を表す x 軸方向と y 軸方向の2つのパラメータにより表現される学習多様体 (曲面) を構成する (図 5.1)。このとき位置推定は、入力画像に最も近い学習多様体上の点を検出し、検出された点から実空間中の2つのパラメータを推定することによって行なう。(ただし、本研究では便宜上、予め各学習画像に位置情報を付加しておき、入力画像に最も類似した学習画像を固

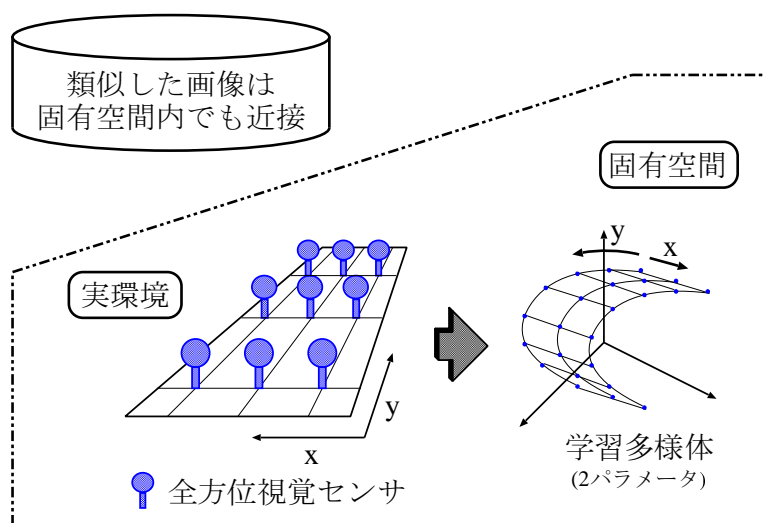


図 5.1 学習多様体

有空間内で検出することによって位置を同定する)

本研究では、全方位画像から生成される自己相関画像の類似性を固有空間内で判定する。このため、図 5.2 に示す関係 (\Downarrow) のうちの何れかが成立しない場合、たとえ固有空間内で画像が近接していても実際の撮影位置は近接していないという問題 (以下、**擬似画像問題** と呼ぶ) が発生すると考えられる。擬似画像問題が発生すると、入力画像を固有空間に射影したとき、その近傍の複数の学習画像候補の中に誤った (すなわち位置推定の致命的な失敗に導く様な) 画像候補が存在し、位置を誤推定する可能性がある。

この問題を解決するために、本研究では、学習画像集合をいくつかの部分画像集合 (クラス) に分割し、さらに入力画像として用いた時系列全方位画像の時間的連続性を考慮することを提案する。次に、提案手法を用いることで、位置推定における擬似画像問題をどの様に回避するかについて述べる。

擬似画像問題の回避

擬似画像問題が発生した場合、ある一部分で交差した学習多様体が構成されてしまうため、1 フレームの入力画像と学習画像との類似度を固有空間内で判定す

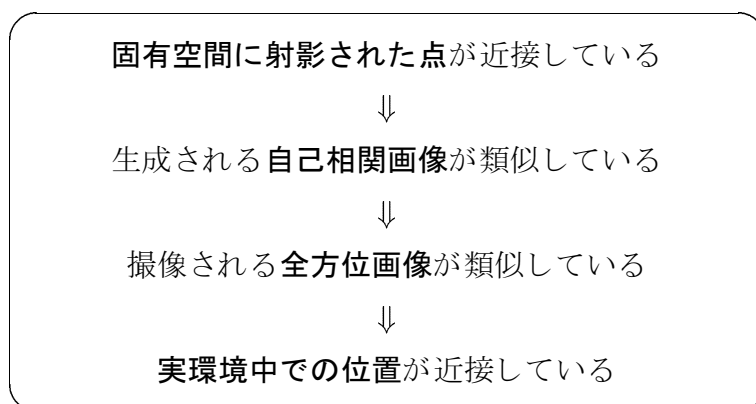


図 5.2 類似性の関係

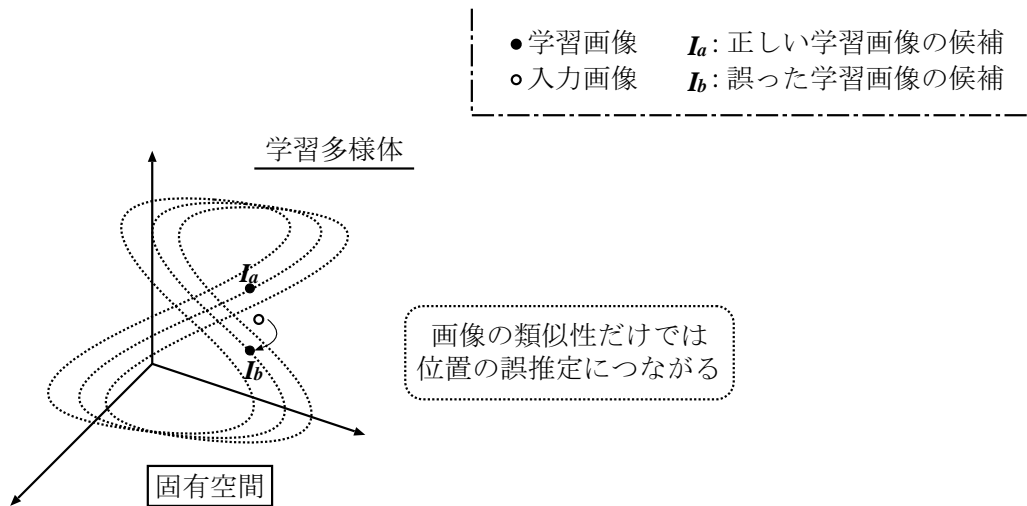
るだけでは、位置推定に失敗する可能性がある (図 5.3(a)). しかし、入力画像に類似した画像を検出する際の検索候補から、予め誤った画像候補を削除することができれば位置推定の失敗を防ぐことが可能である.

このため、学習画像集合 (学習多様体) をいくつかのクラス (部分多様体) に分割しておき、入力画像の時系列性を用いて、正しい画像候補を含むクラスを予め画像検索候補から抽出することを考える (図 5.3(b)). ここで、入力画像として用いられる時系列画像は、時間的空間的に連続したものであるため、固有空間内では 1 つの連続した軌跡として表される. すなわち、過去数フレームの画像についても考慮した入力画像の軌跡を、固有空間内のある部分多様体 (部分曲面) 上の曲線として対応づけることによって、1 フレームの情報からでは得られない実環境の空間的な連続性も考慮した画像の対応づけが可能になる (図 5.3(b)). 従って、


1. 各クラスに何らかの特徴づけを施すことによって、入力画像を正しいクラスに対応づける (大局的位置推定)
2. 対応づけられたクラス内でさらに画像の類似性を判定する (局所的位置推定)

様にすれば、擬似画像問題を回避した位置認識が可能になると思われる.

以下では、提案する 2 段階の推定法についてさらに詳しく説明する.



(a) 画像の類似性を基にした位置推定



(b) クラスの分割による画像候補の削減

図 5.3 クラス分割による位置推定性能の向上

5.2 大局的な位置推定

本節では、クラス対応づけ問題を解くことによる、ロボットの位置の大局的な推定を行なう方法について述べる。以下では、学習画像集合の分割と分割されたクラスに対する特徴づけに部分空間法を適用する方法について述べ、さらに入力画像の時系列性を考慮してクラス決定の精度を向上させる方法について述べる。

5.2.1 記憶する画像の空間的連続性を考慮したクラス分割

部分空間法とは、クラス毎にその学習パターンの分布を最適に近似する様な部分空間を構成する方法である。認識の際には、入力パターンと部分空間との類似性を何らかの評価尺度で比較し、類似度が最大となる部分空間を検出することによって、その部分空間を構成するクラスに入力パターンを対応づける [31, 38]。本研究では、この部分空間として固有空間を使用する。

まず、4章で述べた固有空間法を用いて、クラス毎に固有空間を構成しておく。一般に部分空間法は、画像をいずれかのクラスに分類するという処理を行なうだけであるので、画像集合全体の平均を基準として各固有空間を構成する [35]。しかしここでは、入力画像をいずれかのクラスに分類した後、そのクラスが構成する固有空間内でさらに類似画像を検索するという2段階の処理を行なう。そこで、固有空間を構成する際にそのクラスの平均を基準とする方が、クラス内の画像を識別する際には望ましい。この様にして構成される各固有空間は、クラス平均からの分散が大きい軸を基底ベクトルとして構成されるため、クラスの特徴をよく表したものとなっている。しかし、クラス毎にこれらの固有空間を構成するために各固有空間の原点が異なり、入力画像と異なる固有空間との類似度を単純に比較することはできず、各固有空間の原点を揃える必要がある。

そこで、各固有空間にクラス平均の成分を考慮した軸を新たに付け加える。具体的には、式 (5.1) で計算される基底ベクトルをクラス毎に作成し、各固有空間の軸として新たに付け加える [37]。

$$\left. \begin{aligned} \mathbf{u}_0 &= \frac{\bar{\Phi} - \sum_{k=1}^K \alpha_k \mathbf{u}_k}{\left\| \bar{\Phi} - \sum_{k=1}^K \alpha_k \mathbf{u}_k \right\|}, \\ \alpha_k &= \bar{\Phi}^T \mathbf{u}_k \quad (k = 1, 2, \dots, K) \end{aligned} \right\} \quad (5.1)$$

\mathbf{u}_0 は、クラス平均ベクトルをそのクラスが構成する K 次元の固有空間に射影した時の残差ベクトルを、その大きさを正規化した単位ベクトルである。すなわち、このベクトルは K 次元の固有空間に直交している。このとき、固有空間は $(K + 1)$ 個の基底ベクトルで構成されることになり、 $\rho_{jk} = \Phi_j^T \mathbf{u}_k$ とすれば式 (4.5) は以下の様に見えることができる。

$$\begin{aligned}
\Phi_j &= \bar{\Phi} + \sum_{k=1}^L \nu_{jk} \mathbf{u}_k \\
&= \left[(\bar{\Phi}^T \mathbf{u}_0) \mathbf{u}_0 + \sum_{k=1}^K \alpha_k \mathbf{u}_k \right] + \left[\sum_{k=1}^K \nu_{jk} \mathbf{u}_k + \sum_{k=K+1}^L \nu_{jk} \mathbf{u}_k \right] \\
&= (\bar{\Phi}^T \mathbf{u}_0) \mathbf{u}_0 + \sum_{k=1}^K (\alpha_k + \nu_{jk}) \mathbf{u}_k + \sum_{k=K+1}^L \nu_{jk} \mathbf{u}_k \\
&= \left[\Phi_j^T \mathbf{u}_0 - \sum_{k=K+1}^L (\nu_{jk} \mathbf{u}_k)^T \mathbf{u}_0 \right] \mathbf{u}_0 + \sum_{k=1}^K (\Phi_j^T \mathbf{u}_k) \mathbf{u}_k + \sum_{k=K+1}^L \nu_{jk} \mathbf{u}_k \\
&= \sum_{k=0}^K \rho_{jk} \mathbf{u}_k + \sum_{k=K+1}^L \nu_{jk} (\mathbf{u}_k - (\mathbf{u}_k^T \mathbf{u}_0) \mathbf{u}_0) \tag{5.2}
\end{aligned}$$

ここで、 ν_{jk} ($k = K+1, \dots, L$) は非常に小さな値となるため、画像ベクトル Φ_j は以下の様に近似することができる。

$$\Phi_j \approx \sum_{k=0}^K \rho_{jk} \mathbf{u}_k \tag{5.3}$$

式 (5.3) により、クラス毎に構成される各固有空間の原点は 1 つに重なる。これにより、異なる固有空間との類似度の比較が可能になる。

5.2.2 入力画像の時系列性を考慮したクラス分類の改良

前節では、学習画像の空間的連続性を考慮した手法について述べたが、本節では、さらにクラス決定の精度を上げるために、入力画像の時系列性を考慮した手法を提案する。すなわち、現在の入力画像と各固有空間の類似度のみをクラス決定の基準とするのではなく、過去の類似度に対しても重みづけした累積類似度を

クラス決定の基準とする．一般に，画像と固有空間の類似性の尺度としては，画像と固有空間との距離（固有空間へ射影した時の誤差）や，固有空間への射影成分等が考えられる．しかし本研究では，過去の履歴を考慮した位置推定を行なうため，どの時刻における類似度基準も一定でなければならず，類似性の尺度は正規化されていることが望ましい．また，正規化することで閾値の設定が容易になるという利点もある．そこで，類似性の尺度として入力画像と固有空間との余弦（正規化相関）を用いる．以下に，具体的な累積類似度の計算方法を示す．

時刻 t における入力画像ベクトルを $\phi_t = (x_{t1}, \dots, x_{tn})$ とし，また， ϕ_t をクラス i によって構成される $(K + 1)$ 次元の固有空間 $\mathbf{E}^{(i)}$ に射影したベクトルを $\psi_t^{(i)} = (\rho_{t0}^{(i)}, \dots, \rho_{tK}^{(i)})$ とする．このとき，入力画像 ϕ_t と固有空間 \mathbf{E}_i との類似度（余弦） $s_i(t)$ は以下の式を用いて求められる．

$$s_i(t) = \frac{\|\psi_t^{(i)}\|}{\|\phi_t^{(i)}\|} = \frac{\sqrt{\sum_{k=0}^K (\rho_{tk}^{(i)})^2}}{\sqrt{\sum_{k=1}^n (x_{tk}^{(i)})^2}} \quad (5.4)$$

式 (5.4) の $s_i(t)$ は，意味的には，入力画像ベクトルとそれを固有空間 E_i に射影したベクトルとの正規化相関値と等価であり， $0 \sim 1$ の範囲で正規化されている．

このとき，時刻 t までの累積類似度（累積余弦） $S_i(t)$ を以下の漸化式を用いて更新する [11]．

$$\begin{cases} S_i(0) = s_i(0) \\ S_i(t) = \alpha \cdot s_i(t) + (1 - \alpha) \cdot S_i(t-1) \quad (t \geq 1) \end{cases} \quad (5.5)$$

ここで， α は正規化係数 ($0 \leq \alpha \leq 1$) である．式 (5.5) の漸化式を解くと次式の様になる．

$$S_i(t) = (1 - \alpha)^t \cdot s_i(0) + \sum_{k=1}^t \alpha(1 - \alpha)^{t-k} \cdot s_i(k) \quad (t \geq 1) \quad (5.6)$$

このとき， $s_i(k)$ に対する重みを $w(k)$ とすると，重み $w(k)$ の和は，

$$\sum_{k=0}^t w(k) = (1 - \alpha)^t + \sum_{k=1}^t \alpha(1 - \alpha)^{t-k} = 1 \quad (5.7)$$

となるため、いかなる t においても重みの和が 1 に正規化された累積類似度が得られる。そして、この累積類似度 (累積余弦) を最大にする様なクラス i に入力画像を分類する。

5.3 局所的な位置推定

前節では、画像と固有空間との類似性を基に、大局的な位置推定を行なう手法について述べた。本節では、検出された固有空間内での画像の類似性を基に、局所的な位置を推定する方法について述べる。

式 (5.3) を用いて固有空間に射影された画像は、固有空間内では 1 つの点として表現される。そこで本研究では、固有空間内での画像の類似性の尺度として、この射影された点の間の距離を用いる。すなわち、固有空間内での 2 点間の距離が近ければ、それら 2 つの画像は類似しているとする。ここで、固有空間 $E^{(i)}$ 内の 2 点 $\psi_a^{(i)}$ と $\psi_b^{(i)}$ 間の距離にはユークリッド距離 $d_{a,b}^{(i)}$ を用いる。

$$d_{a,b}^{(i)} = \|\psi_a^{(i)} - \psi_b^{(i)}\| = \sqrt{\sum_{k=0}^K (\rho_{ak}^{(i)} - \rho_{bk}^{(i)})^2} \quad (5.8)$$

実際に、位置推定は以下の様にして行なう。5.2 節の処理により、入力画像はあるクラス i に分類されている。ここで、クラス i が構成する固有空間 $E^{(i)}$ において、 L 枚の学習画像からなる学習多様体を $\{\psi_j^{(i)} | j = 1, \dots, L\}$ とする。また、入力画像を固有空間 $E^{(i)}$ 内の点として表したものを、 $\psi^{(i)}$ とする。このとき、 $\psi^{(i)}$ と全ての $\{\psi_j^{(i)}\}$ との距離を式 (5.8) を用いて求め、距離が最小となる学習画像を検出する。検出された学習画像に付加された位置情報を基に、現在の位置を推定する。

5.4 位置推定の手順

5.2, 5.3 節では、画像と固有空間との類似度、画像同士の類似度という 2 つの類似性の評価尺度を定義し、類似性を判断する基準について述べた。前節までの




図 5.4 位置推定手法の概略

処理をまとめると，本研究における位置推定は以下の手順で行なうことができる (図 5.4)．

[Step1] 入力された全方位画像を自己相関画像に変換し，予めクラス毎に構成された各固有空間に射影する．

[Step2] 入力画像との類似度 (累積余弦) が最大となる固有空間 $E^{(i)}$ を検出し，その固有空間を構成するクラス i に入力画像を分類する．すなわち，現在位置の大局的な推定を行なう．

[Step3] 選択された固有空間 $E^{(i)}$ 内でのユークリッド距離を基に入力画像に最も類似した学習画像を検出し，それに付加された位置情報から現在位置を推定する．すなわち，現在位置の局所的な推定を行なう．

6. 実験

本章では、前述した画像記憶および位置推定の手法を用いて、実際に位置推定の実験を行なった結果について述べ、提案手法の有効性を検証する。

提案手法の汎用性を確かめるために、屋内環境および屋外環境においてそれぞれ実験を行なった。屋内環境としては本学の建物内の通路、屋外環境としては本学内の外周路を使用した。以下では、これら 2 種類の実験とその結果について述べ、提案手法の特長および問題点について考察する。

6.1 画像入力

6.1.1 画像入力装置

本実験では使用する画像は、全方位視覚センサ HyperOmni Vision によってビデオレートで取り込まれる全方位画像を、Sirius Video 装置 (SGI 製) を用いてデジタル化したものである。Sirius Video 装置は、30 フレーム/秒、または 60 フレーム/秒の速度で動画像をメモリに格納することができ、格納した画像をハードディスクに連続して記録することができる。具体的には、屋内環境における実験では、HyperOmni Vision を用いて獲得される映像を直接 Sirius Video 装置に取り込むことによって、また屋外環境における実験では、HyperOmni Vision を用いて獲得される映像を一旦ビデオカメラ (Sony Handycam PRO 41 万画素の CCD×3, Hi8 方式) の外部入力を用いて撮影し、その撮影画像を Sirius Video 装置に取り込むことによって、それぞれ電子画像ファイルに変換した。

6.1.2 画像の前処理

画像入力に使用した Sirius Video 装置のアナログ・ビデオ・インタフェースは、1 フレーム内に時系列の異なる 2 枚の画像が含まれるインタレース信号である。そこで、実験で使用する画像が同一時刻に撮像された画素のみで構成されるようにするために、図 6.1 に示す様なフィールド単位の画像分割と、走査線方向に 1/2 に縮小する処理を行なった。

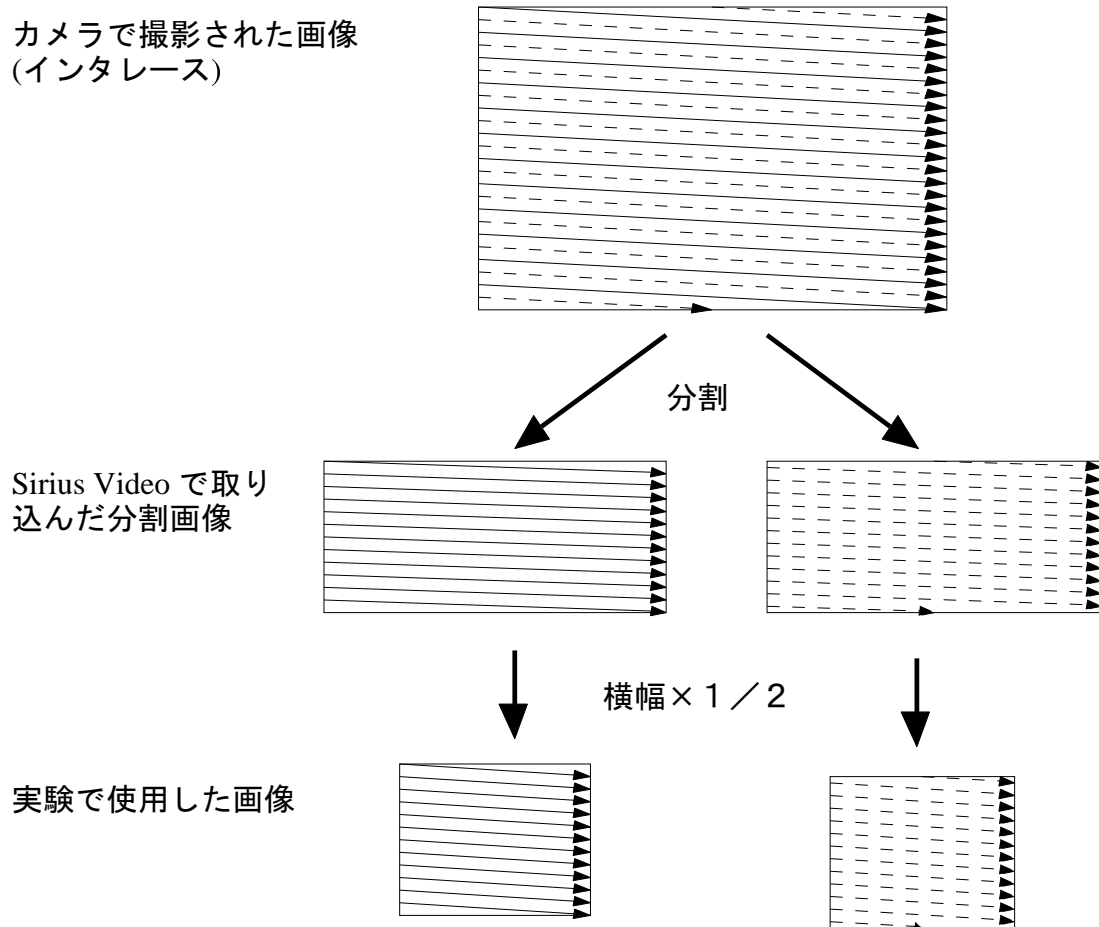


図 6.1 入力画像の前処理方法

この様にして得られた RGB 表色系のカラー画像を，式 (6.1) によりグレイスケール 256 階調 (画素値 : Z) の濃淡画像 (PGM 形式 : Portable Graymap File Format) に変換する.

$$Z = 0.299 \times R + 0.586 \times G + 0.114 \times B \quad (6.1)$$

6.2 屋内環境における実験 (建物内の通路において)

本節では、屋内環境において行なった実験について述べる。具体的には、本学建物内の通路において撮影された全方位画像を用いて位置推定の実験を行なった。

6.2.1 実験環境

本実験では、位置推定の精度がどの程度のものか正確に調査するために、学習画像および推定に用いる入力画像には、予め指定した位置で撮影しておいたものを用いた (図 6.2)。さらに、入力画像は図 6.2 (b) に示す様な経路をロボットが移動しながら撮影したものであると仮定した。





図 6.2 全方位画像の撮影環境 (建物内の通路)



(a) 学習画像の例

(b) 入力画像の例

図 6.3 実験に用いた全方位画像の例

学習画像および入力画像の撮影位置を，図 6.2 (a), (b) にそれぞれ示す．学習画像は 48 枚，入力画像は 63 枚を使用している．63 枚の入力画像のうち，32 枚は学習画像撮影位置 (学習位置) と同一の位置で撮影されたもの，残りの 31 枚は 2 つの学習位置の中間点で撮影されたものを用いた．学習位置の間隔は 50cm，入力画像撮影位置 (入力位置) の間隔は 25cm であり，学習画像と入力画像の方位差 (センサ軸まわりの回転) は約 120 度である．また，学習画像と入力画像は同時間帯に撮影されたものであり，環境の変化 (照明条件の変化等) は起きていない．実際に撮影された全方位画像の例を図 6.3 に示す．図 6.3 (a) では使用した学習画像の例を，また (b) では左の学習画像と同一位置で撮影された入力画像を示す．

6.2.2 実験結果および考察

まず，48 枚の全方位画像 (320×243 , 256 階調) をそれぞれ 256×64 の全周パノラマ画像に変換した．そして，変換された全周パノラマ画像から自己相関画像を生成し，18 枚ずつ 3 つの部分画像集合 (クラス) に分けて固有空間 A~C を作成した (図 6.2(a))．次に，63 枚の入力画像を用いて位置推定を試みた．

以下ではまず、自己相関画像として $AutoCor^{(1)}$ を用いた場合の位置推定について詳しく説明し、その後、提案する3つの自己相関画像 ($AutoCor^{(P)}$, $CrossCor^{(P)}$, $MosCor^{(P)}$) を用いた場合の比較を行なう。さらに、2段階の位置推定処理によって位置推定性能が向上することを示し、最後に実験結果のまとめを述べる。

$AutoCor^{(1)}$ を用いた位置推定

位置推定は、クラスの分類とクラス内での距離に基づく画像検索の2段階で行なわれる。まず、クラスの分類に用いる累積類似度(累積余弦)をグラフに表したものを図6.4に示す。図6.4では、固有空間の次元数を10(寄与率:98~99%)とした場合の各フレームにおける入力画像と各固有空間との累積余弦を、式(5.5)の重み α が1.0(過去の履歴は考慮しない), 0.8, 0.5, 0.2の場合についてそれぞれグラフで示している。入力画像は、各フレームにおいて累積余弦が最大となるクラスに分類される。このグラフから、 α の値を小さくする(過去の履歴に対する重みを大きくする)に従って累積余弦が滑らかに遷移する様になり、ノイズ等に影響されることなく、より安定したクラスの分類が可能になることが分かる。

次に、1位選択されたクラスが構成する固有空間内での距離を基に、位置推定を行なった結果について示す。図6.5では、重み α を0.5とした時の固有空間の次元数に応じた位置推定正解率を、学習時と同一位置で撮影された場合(32枚), 異なる位置で撮影された場合(31枚), 両方を統合した場合(63枚)の3つの場合について示す。ここでの正解率は、学習時と同一位置で撮影された画像に対してはその学習位置が正しく推定された場合を正解とし、それ以外の画像に対しては最も近接した学習位置(入力位置の両隣の学習位置)が推定された場合を正解とすることによって求めた。この正解率にはクラス分類の際の誤りも含まれている。また、図6.5の固有空間の次元数は式(5.3)における K を意味しており、実際に使用する固有空間の次元数は $K+1$ である。以下、全て同様の表記を行なう。

図6.5のグラフから、固有空間の次元数を15とした場合に90%以上の位置推定正解率が得られていることが分かる。すなわち、8192(=128×64)次元の自己相関画像ベクトルを直接記憶することに比べて、位置推定性能を維持したまま記憶容量を大幅に圧縮可能であり、提案手法の有効性を示していると言える。




図 6.4 入力画像と 3 つの固有空間との類似度 (累積余弦)




図 6.5 固有空間の次元数に対する位置推定の正解率

提案する 3 つの自己相関画像に対する考察

ここでは、3.4 節で提案する 3 つの自己相関画像を用いた場合の実験結果について示す。表 6.1 では、重み α を 0.5 とし、テンプレート (またはブロック) の幅 P を 1, 2, 4, 8, 16 と変化させた時の固有空間の次元数に応じた位置推定の正解率を、3 つの自己相関画像についてそれぞれ示している。さらに、各次元数において最大の正解率を太字で示している。

$AutoCor^{(P)}$ と $CrossCor^{(P)}$ は、どちらも P の値を増加させることによって正解率が上昇している。すなわち、高さ方向の画素の影響も考慮した自己相関画像を用いることで、位置推定がよりロバストになっていることが分かる。 $MosCor^{(P)}$ に関しても同様のことが言えるが、モザイク化のサイズを大きくし過ぎると逆に推定率が低下している。これは、多少の位置ずれを吸収できる様にロバスト性を向上させることと、異なる場所を正しく識別できる様に位置判別性能を向上させることが、トレードオフの関係にあることを示している。

また、 $AutoCor^{(P)}$ は P の値の増加とともに徐々に位置推定の正解率も上がっているが、 $CrossCor^{(P)}$ の正解率の上昇は顕著である。さらに、自己相関画像を $CrossCor^{(16)}$ とした場合に最も正解率が高くなる (100%) ことも分かる。これは、 $AutoCor^{(P)}$ が高さ方向の画像変化による影響を吸収しようとするだけであるのに対して、 $CrossCor^{(P)}$ はそれに加えて高さ方向の画素の相関関係を積極的に利

用しているため、自己相関画像の性質が基準テンプレートの取り方に大きく依存することが原因である。このため、 P の値が小さいうちは基準テンプレートが安定せず位置推定の正解率は低い。しかし、 P の値を大きくするにつれて、センサの僅かな傾き等に影響されない安定した基準テンプレートを取得することが可能になり、さらに高さ方向の相関関係を考慮することでより位置に特有な特徴量が抽出できるため、この高い位置推定性能をもたらしていると考えられる。

表 6.1 3つの自己相関画像に対する位置推定の正解率 ($\alpha = 0.5$)

(a) $AutoCor^{(P)}$ を用いた場合

		P の値				
		1	2	4	8	16
次元数	5	77.8	77.8	84.1	84.1	87.3
	10	84.1	84.1	87.3	87.3	95.2
	15	90.5	93.7	96.8	95.2	98.4

(b) $CrossCor^{(P)}$ を用いた場合

		P の値				
		1	2	4	8	16
次元数	5	44.4	46.0	63.5	84.1	88.9
	10	74.6	69.8	76.2	95.2	100.0
	15	77.8	74.6	85.7	98.4	100.0

(c) $MosCor^{(P)}$ を用いた場合

		P の値				
		1	2	4	8	16
次元数	5	77.8	79.4	82.5	82.5	77.8
	10	84.1	87.3	87.3	92.1	84.1
	15	90.5	92.1	95.2	93.7	84.1

提案する 2 段階の位置推定法に対する考察

ここでは、本研究で提案する 2 段階の位置推定を行なうことによって、位置推定性能がどの様に変化するかについて示す。

(a) クラス分割の効果

まず、学習画像集合に対してクラス分割を行なうことによる位置推定正解率の変動を調べるために、クラス数を 1, 2, 3, 5 と変化させて位置推定実験を行なった。クラスの分割方法は図 6.6 に示す通りである。

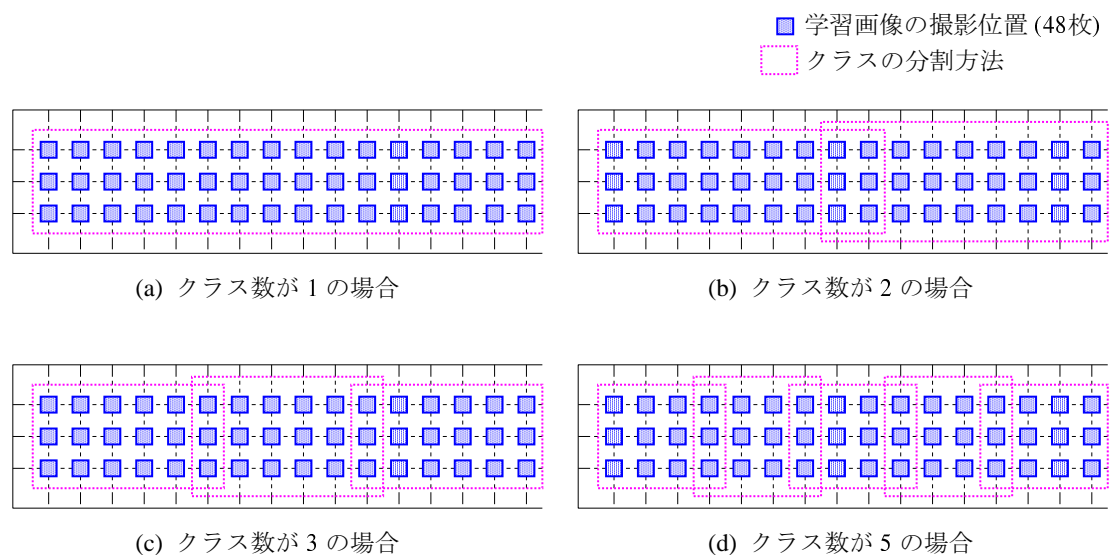


図 6.6 学習画像集合のクラス分割

この 4 つの分割方法に対する固有空間の次元数に応じた位置推定正解率を、図 6.7 に示す。ここで、自己相関画像には $AutoCor^{(1)}$ を用い、重み α は 0.5 としている。次元数は 15 まで表示しているが、クラス数が 5 のときは次元数 12 以上の軸には意味がなく (学習画像集合に対する $rank$ が 11 のため) 表示していない。

図 6.7 に示されている様に、次元数を同一とした場合の位置推定正解率は、学習画像集合を多く分割する (クラス数を増やす) ことで改善している。これは、1 つの固有空間を構成する学習画像の枚数が増加するにつれて、作成される固有空




図 6.7 クラス分割数に対する位置推定の正解率 ($AutoCor^{(1)}$, $\alpha = 0.5$)

間は個々の画像を識別するのに適切な空間とは限らなくなり、多くの固有空間の軸を用いてそれらの識別を行なう必要性が生じるためである。本実験では学習する画像枚数が少ないため、学習画像を増やした(すなわちロボットの行動領域を広くした)場合の評価についても行なう必要があるが、本実験の結果より、クラス分割処理を行なうことで位置推定性能が向上する見通しが得られた。

(b) 過去の履歴を考慮する効果

次に、過去の履歴を考慮することによって位置推定正解率がどの様に変化するかを調べるために、重み α の値を 1.0, 0.8, 0.5, 0.2 と変化させて位置推定実験を行なった。表 6.2 では、自己相関画像を $AutoCor^{(1)}$ 、固有空間の次元数を 5, 10, 15 とした場合についての位置推定の正解率をそれぞれ示す。さらに、使用した固有空間の次元数に対する最大の正解率を太字で示している。

表 6.2 の結果から、重み α を 0.5 としたときの正解率が、他のいずれの場合に比べても最大となることが分かる。しかし、示された 4 通りの場合を比較しても、正解率が顕著に変化しているわけではない。これは、学習画像の枚数が 48 枚と少なく、位置の誤推定を招く様な互いに類似した画像があまり存在しなかったためと思われる。

表 6.2 位置推定の正解率 ($AutoCor^{(1)}$)

		重み α			
		0.2	0.5	0.8	1.0
次元数	5	76.2	77.8	77.8	76.2
	10	82.5	84.1	82.5	82.5
	15	88.9	90.5	88.9	88.9

実験結果のまとめ

今回の実験では、自己相関画像を $CrossCor^{(P)}$ とした場合に、最高の位置推定率である 100% が得られた。これは、高さ方向の相関を考慮することによって、センサの傾き等によって生じる高さ方向の画像のずれに影響されにくい自己相関画像を生成できるためである。今回使用した全周パノラマ画像では、位置ずれによって発生する画像変化は高さ方向に比べて水平方向の方が大きい。このことから、水平ライン毎に相関を計算する $AutoCor^{(P)}$ や $MosCor^{(P)}$ よりも、高さ方向の相関についても計算する $CrossCor^{(P)}$ の方が、多少の位置ずれに対してロバストな位置推定を行なうためには有効であると言える。

また、 P の値を大きくした方が位置推定率は向上している。これは、 P の値を大きくすることによって、僅かな画像変化やノイズによる影響を吸収できるためである。

さらに、学習画像集合を幾つかのクラスに分割した方が、少ない次元数でより高い位置推定率が得られている。これは、各クラスから作成される複数の固有空間は、全ての学習画像集合を用いて作成された固有空間に比べて、それぞれの部分画像集合を識別するためにより適した空間になっているためである。

また、 α の値を 0.5 とした場合に最も高い正解率が得られた。これは、過去のフレームを考慮することによって、より安定したクラス分類ができるようになるためである。しかし、 α の値を小さくし過ぎると、過去のフレームの影響に引きずられてクラス間の遷移に遅れが生じてしまい、逆に位置推定率は低下する。

6.3 屋外環境における実験 (学内の外周路において)

本節では、屋外環境において行なった実験について述べる．具体的には、本学内の外周路において撮影された全方位画像を用いて位置推定の実験を行なった．

6.3.1 実験環境

本実験では、実環境中で撮影された時系列の全方位画像を用いて提案手法の有効性を調査した．なお本実験においては、学習画像、入力画像ともにこの時系列画像を用いることにする．すなわち、ロボットの行動を1次元的な移動のみに制限している．この制限は、屋外という広い環境において、あるルートに沿って移動するロボットの位置推定という目的のためには妥当なものであると考えられる．

実験画像は、全方位視覚センサ HyperOmni Vision を自動車に搭載し、本学敷地内の外周路に沿って移動しながらビデオ撮影することによって取得した．実際に通過した経路を、図 6.8 に矢印によって示す．外周路の1周は約 1km であり、自動車の速度を時速 20km でほぼ一定に保ちながら、外周路に沿って2周回分撮影した．撮影されたビデオ画像を 6.1 節の手法を用いて電子画像ファイルに変換し、さらに毎秒 7.5 枚の割合でサンプリングすることによって、1周目のデータとして 1328 フレーム、2周目のデータとして 1455 フレームの全方位画像データ (320×243, 8bit 濃淡階調) を取得した．撮影間隔は、自動車の速度とサンプリングレートを考慮すると、概ね 50~100cm と推定される．

実際に実験に用いた全方位画像の例を、図 6.9 に示す．図 6.9 では、1周目のデータである 1328 フレームの画像集合の中から 15 フレームを任意に選択して表示している．全方位画像の撮影は早朝 (午前 8:00 頃) に行ない、人物、自動車が出現している画像や太陽の写り込みが発生している画像もある．

6.3.2 実験結果および考察

位置推定の実験は、1周目のデータを学習画像集合、2周目のデータを位置を推定すべき入力画像集合として行なった．

まず、画像の記憶であるが、5節で述べた様に、1328枚の学習画像集合を予めいくつかのクラスに分割しておく．分割されたクラスにも空間的な連続性を持た




図 6.8 全方位画像の撮影環境 (学内の外周路)

せるため、クラスの分割には画像集合を単純に等間隔に分割していく等分割法を用い、クラスの個数は16 (クラス A~P) とした。実際に実環境領域がどの様に分割されたかを、図 6.8 に実線の矢印で示す。このとき、各クラスに含まれる画像の枚数は一律 83 枚となるが、実際には、前後 2 フレームずつを隣接クラスと重複させた 85 枚の画像集合を用いて 1 つのクラスとした。1 つのクラスに含まれる実環境中での自動車の移動距離は約 60m と推定される。そして、これらの画像集合を 256×64 の全周パノラマ画像に変換した。さらに、全周パノラマ画像から自己相関画像を生成し、16 個のクラス毎に固有空間を作成した。

次に、1455 枚の入力画像集合を用いて位置推定実験を行なった。この入力画像が実際の経路上で対応している位置を、図 6.8 に破線で示す。また、予め目視により、入力画像に対して正解となる学習画像の対応づけを行なっておく。




図 6.9 実験に用いた全方位画像の例

以下では、6.2 節と同様に、まず自己相関画像として *AutoCor*⁽¹⁾ を用いた場合の位置推定結果について説明し、その後、それ以外の自己相関画像を用いた場合の比較結果について示す。さらに、2 段階の位置推定を行なうことで位置推定性能が向上することを示し、最後に実験結果のまとめを述べる。

AutoCor⁽¹⁾ を用いた位置推定

位置推定は、屋内環境における実験と同様に、クラスの分類とクラス内での距離に基づく画像検索の 2 段階で行なわれる。まず、クラスの分類のために必要な、入力画像と各固有空間との累積余弦をグラフに表したものを図 6.10 に示す。図 6.10 では、固有空間の次元数を 20 (寄与率: 91~96%) とした場合の、各フレームにおける入力画像と各固有空間との累積余弦を、式 (5.5) の重み α が 1.0, 0.8, 0.5, 0.2 の場合についてそれぞれグラフに示している。ただし、グラフ表示の都合上、ここでは最初の 800 フレーム (約 600m) の結果についてのみ示し、さらに 16 個のクラスのうち、この区間中のいずれかのフレームで 1 位に選択された 10 個のクラス (A~J) に対する累積余弦のみ表示している。また、グラフ中の黒色の縦の破線は、1 位選択されるべきクラス (入力画像に対応づけられた学習画像を含むクラス) の変わり目を示している。すなわち、1 位選択されるべきクラスがこの位置で正しく入れ替わり、さらに次のクラスの変わり目までその状態を維持し続けられれば、入力画像に対して正しいクラス分類ができていると言える。

図 6.10 のグラフより、重み α がいずれの場合であってもほぼ正しくクラスの分類ができている (例えば、 $\alpha = 0.5$ のときのクラス分類の誤り率は 0.96%) ことが分かる。また、過去のフレームを考慮した (α の値を小さくする) 方が、より滑らかに累積余弦が遷移しており、安定したクラス分類ができている。しかし、過去のフレームを考慮し過ぎる ($\alpha = 0.2$) と、クラス間の遷移に多少の遅れが発生している。この遅れは、過去のフレームを考慮するあまり累積余弦がクラスの変化に鈍感になっているために生じており、各クラス間の重複フレームの枚数を増やすことで冗長性を増してやれば改善すると思われる。

本手法では、記憶していない画像が得られた場合、すなわち未知の環境に入り込んだ場合の処理については定義していない。しかし、図 6.10(d) を見ると、正







図 6.10 入力画像と 10 個の固有空間 (A~J) との類似度 (累積余弦)

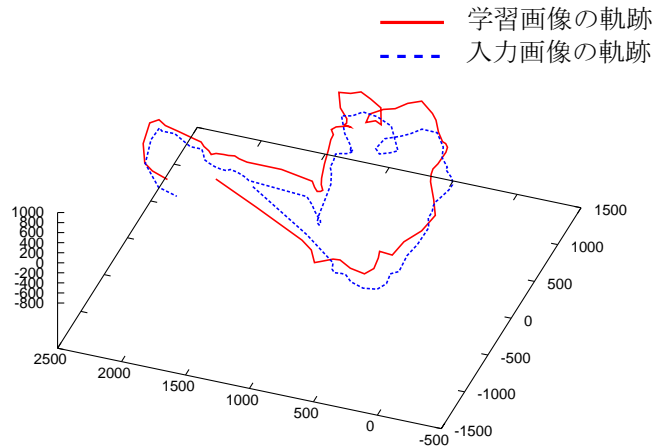


図 6.11 クラス C に対する固有空間内での軌跡

しいクラスに分類されているときの累積余弦は殆どこのところで高い値 (0.98 以上) となっており、このあたりに閾値を設定することによって未知環境かどうかの判断が可能になると考えられる。

次に、1 位選択されたクラスが構成する固有空間内での距離を基に、位置推定を行なった結果を示す。図 6.11 は、クラス C に属すると推定された 180~265 番目のフレームの入力画像を、クラス C が構成する固有空間 (上位 3 次元) に投影し、時系列性を考慮して各点の間を直線で補間したものを示している。図の赤色の実線はクラス C の学習データ、青色の破線は入力データをそれぞれ示しており、ほぼ類似した軌跡になっていることが分かる。

さらに、上述した様に、予め目視により入力画像と学習画像 (実環境中での位置) の対応づけを行なっておき、推定された位置がその対応位置の $\pm N$ フレーム以内に入っている時を正解とした場合の正解率を以下に示す。図 6.12 では、重み α を 0.5 とした時の固有空間の次元数に応じた位置推定正解率を、 $N = 1, 2, 4, 8$ の 4 つの場合についてそれぞれグラフで示す。図 6.12 のグラフより、固有空間の次元数を 20 とした場合でも、入力に用いた 1455 枚の画像集合の約 96% が 2 フ




図 6.12 固有空間の次元数に対する位置推定の正解率 ($\alpha = 0.5$)

レーム (約 1.5m) 以内の誤差の範囲で、また約 99%が 8 フレーム (約 6m) 以内の誤差の範囲でそれぞれ推定されていることが分かる。また、30 次元以上では正解率の変化は殆ど生じていないため、正解率を維持したまま固有空間の次元数を大幅に削減することが可能である。

以上の結果より、提案手法は、自己相関画像の 8192 次元に対して位置推定に利用する画像情報の次元数を極端に削減した場合においても、非常に高い推定性能を有することが確認できた。

提案する 3 つの自己相関画像に対する考察

ここでは、提案する 3 つの自己相関画像を用いた位置推定の結果について示す。表 6.3 では、重み α を 0.5, N を 2 とし、 P の値を 1, 2, 4, 8, 16 と変化させた時の固有空間の次元数に応じた位置推定正解率を、3 つの自己相関画像についてそれぞれ示している。さらに、各次元数において最大の正解率を太字で示している。

この結果から分かる様に、いずれの場合も P の値を増加させることによって正解率が低下しており、屋内環境における実験結果と比べて全く逆の結果になっている。これは、屋外で撮影された全方位画像は撮影対象までの距離が一様に長く、僅かな位置ずれでは画像の変化が殆ど生じないため、 P の値を増加させて高

表 6.3 3つの自己相関画像に対する位置推定の正解率 ($\alpha = 0.5, N = 2$)

(a) $AutoCor^{(P)}$ を用いた場合

		P の値				
		1	2	4	8	16
次 元 数	5	83.0	82.9	82.5	81.1	78.0
	10	92.9	92.6	91.9	90.4	89.8
	15	95.1	94.6	94.2	93.9	92.1
	20	96.2	96.1	95.5	95.1	93.5
	25	97.1	96.6	96.0	95.4	93.2
	30	97.4	96.8	96.4	95.6	93.4

(b) $CrossCor^{(P)}$ を用いた場合

		P の値				
		1	2	4	8	16
次 元 数	5	89.7	90.0	88.2	84.7	86.7
	10	95.7	95.3	94.2	92.9	93.3
	15	97.6	97.8	97.0	94.8	94.5
	20	98.0	97.9	97.3	96.1	95.5
	25	98.1	98.0	97.4	96.2	95.8
	30	98.6	98.4	97.5	96.8	96.2

(c) $MosCor^{(P)}$ を用いた場合

		P の値				
		1	2	4	8	16
次元数	5	83.0	82.9	80.9	74.2	54.8
	10	92.9	91.9	89.3	86.9	63.1
	15	95.1	94.6	92.6	88.9	64.5
	20	96.2	95.8	94.2	90.2	65.8
	25	97.1	96.6	94.8	90.5	45.6
	30	97.4	96.9	95.0	91.2	2.7

さ方向の画素変化による影響を吸収しようとする、逆に位置判別性能が低下してしまうことが原因であると考えられる。

また、自己相関画像を $CrossCor^{(P)}$ とすることによって位置推定正解率は一様に高くなり、さらに $CrossCor^{(1)}$ のときに最も正解率が高くなる (98.6%) ことが分かる。これは、位置推定を行なうために高さ方向の相関関係を考慮することは、屋外環境の場合においても有効であることを示している。

提案する 2 段階の位置推定法に対する考察

ここでは、本研究で提案する 2 段階の位置推定を行なうことによって、位置推定性能がどの様に変化するのかについて示す。

(a) クラス分割の効果

まず、学習画像集合に対してクラス分割を行なうことによる位置推定正解率の変動を調べるために、クラス数を 1, 2, 4, 8, 16 と変化させて位置推定実験を行なった。クラスの分割には等分割法を用い、このとき各クラスに含まれる画像枚数は表 6.4 の様になる。ただし、1328 枚の学習画像集合に対して等分割を行なった後、前後 2 フレームずつを隣接クラスと重複させることによって得られる画像

表 6.4 クラスに含まれる画像枚数

クラス数	1	2	4	8	16
画像枚数	1328	666	334	168	85




図 6.13 クラス分割数に対する位置推定の正解率 ($AutoCor^{(1)}$, $\alpha = 0.5$, $N = 2$)

集合を用いて、1つのクラスを構成している．このときの固有空間の次元数に応じた位置推定正解率を図 6.13 に示す．ここで、自己相関画像としては $AutoCor^{(1)}$ を用い、重み α は 0.5、 N は 2 としている．

図 6.13 の結果から分かる様に、本研究で提案する部分空間法を用いたクラス分割を行なうことによって位置推定正解率は改善している．これは、1つの固有空間を作成する画像枚数が増えれば増えるほど、固有空間の次元数を削減することによって発生する誤った画像候補の数が増加するためだと思われる．位置推定正解率の改善は、固有空間の次元数が低いほど顕著であり、次元数が高くなると正解率にそれほど差は見られない．しかし、記憶容量を小さくするために固有空間の次元数は低くすることが望ましく、低次元の固有空間においても高い位置推定性能を有している提案手法は、この目的に適していると考えられる．

表 6.5 位置推定の正解率 ($AutoCor^{(1)}$, $N = 2$)

		重み α			
		0.2	0.5	0.8	1.0
次元数	5	82.2	83.0	83.0	83.0
	10	91.7	92.9	93.1	93.2
	15	93.7	95.1	95.1	95.1
	20	95.0	96.2	96.3	96.3
	25	95.9	97.1	97.2	97.2
	30	96.1	97.4	97.4	97.4

(b) 過去の履歴を考慮する効果

次に、過去の履歴を考慮することによって位置推定正解率がどの様に変化するかを調べるために、重み α の値を 1.0, 0.8, 0.5, 0.2 と変化させて位置推定実験を行なった。表 6.5 では、自己相関画像を $AutoCor^{(1)}$ とし、 $N = 2$ とした時の正解率を、固有空間の次元数を 5, 10, 15, 20, 25, 30 とした場合についてそれぞれ示す。さらに、使用した固有空間の次元数に対する最大の正解率を太字で示している。

この結果から、過去の履歴を考慮する(重み α の値を小さくする)ことによって、位置推定の正解率は僅かながら低下していることが分かる。これは、実験環境である本学内の外周路では、5.2 節で述べた擬似画像問題が殆ど発生せず、逆に過去のフレームを考慮することで生じたクラス間遷移の遅れによる影響が現れてしまったためだと思われる。

また、他の自己相関画像についても実験したところ、 $MosCor^{(P)}$ は過去の履歴を考慮することによって正解率が改善した。これは、モザイク化を行なうことで、遠く離れているにも関わらず互いに類似しているという画像が増加したためだと思われる。しかしそれ以外の自己相関画像に対しては、正解率が低下するという傾向が見られた。これは、たとえ誤りをもたらす様な画像候補がいくつか存在したとしても、基本的には正しい候補が最も類似した画像であるため、1 フレーム

の画像しか使用しなくても正しい候補が検出可能であることに原因がある。今回の実験では行っていないが、例えば対向車の出現等の致命的なノイズが発生する様な入力画像を用いれば、1フレームの画像の類似性だけでは位置推定に失敗し、過去のフレームを考慮することによって位置推定性能が向上すると考えられる。今後、この様な実験についても行なう必要がある。

実験結果のまとめ

今回の実験では、自己相関画像を $CrossCor^{(P)}$ とした場合に、最高の位置推定率である 98.6% が得られた。これは、高さ方向の相関を考慮することによって、センサの傾き等によって生じる高さ方向の画像のずれに影響されにくい自己相関画像を生成できるためである。

しかし、屋内環境での実験結果とは異なり、 P の値を大きくすることで位置推定率は逆に低下している。これは、屋外の様な広い環境においては、一般に撮影対象までの距離が長くなり、僅かに位置が変位するだけでは、その違いを識別できるための変化が画像内に生じないためである。このため、 P の値を大きくして高さ方向の画素ずれを吸収したり、画像に対してモザイク化の処理を施したりすることは、異なる位置を識別する位置判別能力を却って低下させる要因になる。

また、学習画像集合を幾つかのクラスに分割することによって、少ない次元数でより高い位置推定率が得られている。これは、各クラスから作成される複数の固有空間は、全ての学習画像集合を用いて作成された固有空間に比べて、それぞれの部分画像集合を識別するためにより適した空間になっているためである。

また、 $MosCor^{(P)}$ を除く殆どの場合において、 α の値を小さくする (過去の履歴を考慮する) ことで位置推定率は僅かながら低下した。これは、今回使用した屋外の全方位画像集合では 5.1 節で述べたような擬似画像問題が殆ど発生せず、逆に α の値を小さくすることでクラス間の遷移に遅れが生じてしまっているためである。しかし、例えば画像内に未知の物体が出現する等の状況が発生すれば、現在のフレーム情報を用いるだけでは位置推定に失敗することが予想される。この様な状況では、過去のフレームを考慮することによって位置推定性能の改善が期待できる。

7. むすび

本論文では、全方位画像からカメラ位置に固有な自己相関画像を求め、その類似性を固有空間内で判定することによって自己位置の推定を行なう手法を提案した。本手法は、部分空間法を用いて探索空間を削減した上で、入力された画像に最も類似したものを記憶した画像の中から検索することによって位置の推定を行っており、クラス分類処理と画像検索処理を統合した位置推定法であると言える。実際に屋内および屋外において撮影された全方位画像を用いて位置推定の実験を行なった結果、どちらの場合においても提案手法が高い位置推定性能を有することを確認した。

本手法の特徴として、以下の点が挙げられる。

- 場所毎に学習画像を撮影し固有空間を作成するので、新たな画像の学習が容易である。
- 特徴量の計算に用いる自己相関関数はフーリエ変換を用いることで高速に計算でき、さらに類似画像の検索には射影等の比較的小さな計算量だけで済むため、位置推定処理の高速化が期待できる。
- 記憶に基づく手法を用いているため、あらゆる環境の画像を記憶することによって環境条件に依存しない位置認識が可能である。

提案手法の問題点として、以下の点が挙げられる。本手法で提案している自己相関画像は、正規化自己相関値を計算することによって生成しているため画像全体の線形な明度変化に対しては影響を受けないが、人物の出現や太陽光等による局所的な明度変化には敏感である。このため、例えば式 (3.2) において画素の平均値を用いるのではなく局所的な変化にロバストな中央値を用いる等の処理を施すことによって、局所的な明度変化に対してより安定な自己相関画像を生成することが必要である。

また屋外環境においては、撮影する時刻(すなわち太陽の位置)によって建物の影の形や大きさ等が変化してしまうため、同じ位置で撮影された画像であっても見た目が大きく変化してしまうという問題が生じる。この問題に関しては、本研

究の方針が記憶に基づく位置推定であることから、予め複数の時間帯で同一位置の画像を撮影することによって解決できると思われる。

また本手法では、環境は既知である(予め学習されている)ことが前提条件になっており、未知環境におけるロボットの移動については定義していない。より安全なロボットの誘導を行なうためには、ロボットが学習していない場所に入り込んだ場合についても想定しておかなければならない。このために、例えばクラス決定の際に閾値を設ける等の処理を行なうことにより、未知環境の検出を行なうことが必要となる。

さらに、この閾値処理は移動ロボットのより安全な誘導に応用することができる。ロボットが移動する環境内に未知の物体が出現すると画像に変化が生じるため、入力画像と固有空間との累積余弦は低下することが予想される。このため、累積余弦が予め設定しておいた閾値以下になれば、

1. ロボットが未知の環境を移動している
2. 環境中に未知の物体が出現している

という2つの状況のうちのどちらかが発生していると予想される。このような状況が発生すれば、例えば以下の様な手順でその状況を回避することが可能だと考えられる。累積余弦が閾値以下になれば、一旦ロボットを停止させる。そして、撮影画像内に局所的な移動領域が存在すれば未知の移動物体が出現していると判断し、それを回避する行動をとる。逆に、ずっと画像が静止したままであれば未知環境に入り込んでしていると判断し、これまで辿ってきたルートを引き返す。

今後の課題としては、固有空間との類似度計算の際に設定する閾値の検討、人物等の出現に影響されにくい位置推定手法の検討が挙げられる。また、固有空間内に構成される学習多様体を3次スプライン等で近似し、入力画像に最も近接した多様体上の点を検出することによって、より精度の高い位置推定を行なうことが考えられる。

謝辞

本研究を進めるにあたり，終始暖かい御指導を頂いた ソフトウェア基礎講座 横矢 直和 教授 に厚く御礼申し上げます。

副指導教官として御助言を頂いた 像情報処理講座 千原 國宏 教授，並びに ソフトウェア基礎講座 竹村 治雄 助教授 に深く感謝致します。

本研究への助言や研究環境の整備に協力して頂いた ソフトウェア基礎講座 岩佐 英彦 助手，並びに 山澤 一誠 助手 に深く感謝致します。

日々の研究室の活動を支えて下さった 福永 博美 女史，並びに 村上 和代 女史 に心より感謝申し上げます。

本研究を進めるにあたり，様々な助言を頂いた 藤本 泰史 氏 (現 東洋情報システム) に感謝致します。

本研究の実験の遂行に協力下さった 世利 至彦 氏 に感謝致します。

ソフトウェア基礎講座の諸氏には，本研究を進めるにあたり多大なる御協力を頂きました。ここに感謝の意を表します。

最後に，大阪大学を離れる際に温かく送り出して頂いた 大阪大学 基礎工学部 情報科学科 知能情報処理学研究室 井上 克郎 教授 に深く感謝致します。

参考文献

- [1] I. J. Cox: “Blanche: Position Estimation for an Autonomous Robot Vehicle,” *IEEE/RSJ Int. Workshop on Intelligent Robots and Systems*, pp.432–439, 1989.
- [2] C. Becker, J. Salas, K. Tokusei and J. C. Latombe: “Reliable Navigation Using Landmarks,” *Proc. IEEE Int. Conf. on Robotics and Automation*, vol.1, pp.401–406, 1995.
- [3] 榎本 雅幸, 三橋 渉: “全方位画像からの自己運動と 3 次元構造の復元,” 信学技報, PRU91-126, pp.1–8, 1991.
- [4] 茶園 篤, 山澤 一誠, 横矢 直和, 竹村 治雄: “全方位ステレオ視による 3 次元情報の獲得,” 映像情報メディア学会誌, vol.51, no.10, pp.1745–1753, 1997.
- [5] K. T. Simsarian, T. J. Olson and N. Nandhakumar: “View-Invariant Regions and Mobile Robot Self-Localization,” *IEEE Trans. on Robotics and Automation*, vol.12, no.5, pp.810–816, 1996.
- [6] R. Talluri and J. K. Aggarwal: “Mobile Robot Self-Location Using Model-Image Feature Correspondence,” *IEEE Trans. on Robotics and Automation*, vol.12, no.1, pp.63–77, 1996.
- [7] B. Crespi, C. Furlanello and L. Stringa: “Memory-Based Navigation,” *Proc. 13th Int. Joint Conf. on Artificial Intelligence (IJCAI-93)*, vol.2, pp.1654–1658, 1993.
- [8] 前田 武志, 石黒 浩, 辻 三郎: “全方位画像を用いた記憶に基づく未知環境の探索,” 情処研報, CV92-10, pp.73–80, 1995.
- [9] 松本 吉央, 稲葉 雅幸, 井上 博允: “視野画像列の記憶に基づく移動ロボットのナビゲーション,” 第 13 回日本ロボット学会学術講演会予稿集, no.1, pp.313–314, 1995.

- [10] 前田 佐嘉志, 久野 義徳, 白井 良明: “固有空間解析に基づく移動ロボットの位置認識,” 信学論 (D-II), vol.J80-D-II, no.6, pp.1502–1511, 1997.
- [11] 西村 拓一, Andreas Held, 岡 隆一: “全方位視覚センサを用いた大局的位置の推定,” 信学技報, PRMU96-33, pp.57–63, 1996.
- [12] 小島 浩, 伊藤 慶明, 岡 隆一: “Reference Interval-Free 連続 DP を利用した移動ロボットの時系列画像による位置同定システム,” 信学論 (D-II), vol.J80-D-II, no.3, pp.724–733, 1997.
- [13] J. Y. Zheng and S. Tsuji: “Panoramic Representation for Route Recognition by a Mobile Robot,” *Int. Journal of Computer Vision*, vol.9, no.1, pp.55–76, 1992.
- [14] 栗飯原 述宏, 岩佐 英彦, 横矢 直和, 竹村 治雄: “全方位画像を用いたイメージ記憶に基づく位置の推定,” 画像電子学会研究会予稿, 97-04-06, pp.21–24, 1997.
- [15] 栗飯原 述宏, 岩佐 英彦, 横矢 直和, 竹村 治雄: “時系列全方位画像を用いた記憶に基づく位置推定,” 信学技報, IE97-158, pp.101–108, 1998.
- [16] 八木 康史: “全方位画像の取得とその応用,” 信学技報, PRMU96-140, pp.89–96, 1997.
- [17] 山澤 一誠, 八木 康史, 谷内田 正彦: “移動ロボットのナビゲーションのための全方位視覚センサ HyperOmni Vision の提案,” 信学論 (D-II), vol.J79-D-II, no.5, pp.698–707, 1996.
- [18] 尾上 良雄, 山澤 一誠, 横矢 直和, 竹村 治雄: “全方位画像からの視線追従型実時間画像生成によるテレプレゼンス,” 信学技報, PRMU97-20, pp.151–157, 1997.
- [19] M. A. Turk and A. P. Pentland: “Face Recognition Using Eigenfaces,” *Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR'91)*, pp.586–591, 1991.

- [20] A. Pentland, R. W. Picard and S. Sclaroff: "Photobook: Content-Based Manipulation of Image Databases," *Int. Journal of Computer Vision*, vol.18, no.3, pp.233-254, 1996.
- [21] K. Ohba and K. Ikeuchi: "Recognition of the Multi-Specularity Objects Using the Eigen-Window," *Proc. IEEE 13th Int. Conf. on Pattern Recognition (ICPR'96)*, vol.I, pp.692-696, 1996.
- [22] 大場 光太郎, 池内 克史: "局所固有空間手法による金属物体の安定認識," 信学論 (D-II), vol.J80-D-II, no.12, pp.3147-3154, 1997.
- [23] 櫻井 保志, 岩佐 英彦, 竹村 治雄, 横矢 直和, 加藤 隆: "全周距離データを用いた固有空間法による顔認識," 信学技報, PRU95-193, pp.23-28, 1996.
- [24] D. L. Swets and J. Weng: "Using Discriminant Eigenfeatures for Image Retrieval," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.18, no.8, pp.831-836, 1996.
- [25] 藤本 泰史, 岩佐 英彦, 横矢 直和, 竹村 治雄: "固有空間内の軌跡の類似性に基づく動画像検索," 信学技報, PRMU96-110, pp.49-56, 1996.
- [26] 畠 直志, 岩井 儀雄, 谷内田 正彦: "KL 展開と隠れマルコフモデルによるジェスチャ認識," 情処研報, CVIM103-15, pp.115-122, 1997.
- [27] 村瀬 洋, シュリー・ナイヤー: "2 次元照合による 3 次元物体認識 —パラメトリック固有空間法—," 信学論 (D-II), vol.J77-D-II, no.11, pp.2179-2187, 1994.
- [28] H. Murase and S. K. Nayar: "Visual Learning and Recognition of 3-D Objects from Appearance," *Int. Journal of Computer Vision*, vol.14, no.1, pp.5-24, 1995.
- [29] 天野 敏之, 日浦 慎作, 山口 証, 井口 征士: "固有空間照合法に基づく距離画像からの物体の姿勢検出," 信学論 (D-II), vol.J80-D-II, no.5, pp.1136-1143, 1997.

- [30] 小迫 明德, Anca Ralescu, 武川 直樹: “ベイズ推定に基づく剛体の局所情報の統合 —パラメトリック固有空間表現によるパラメータからの物体抽出—,” 信学技報, PRU95-75, pp.151–156, 1995.
- [31] S. Watanabe and N. Pakvasa: “Subspace Method in Pattern Recognition,” *Proc. Int. Joint Conf. on Pattern Recognition*, pp.25–32, 1973.
- [32] 大倉 充, 小谷 弘之, 塩野 充, 橋本 礼治: “複数の部分空間による手書き類似漢字識別,” 画像の認識・理解シンポジウム (MIRU'92) 講演論文集I, pp.215–222, 1992.
- [33] 島田 恭宏, 大倉 充, 塩野 充, 橋本 禮治: “複数特徴部分空間法による手書き類似漢字識別,” 信学論 (D-II), vol.J78-D-II, no.10, pp.1460–1468, 1995.
- [34] 加藤 寧, 安倍 正人, 根元 義章: “改良型マハラノビス距離を用いた高精度な手書き文字認識,” 信学論 (D-II), vol.J79-D-II, no.1, pp.45–52, 1996.
- [35] 石川 則之, 有木 康雄: “正規化複数部分空間法による顔認識と話者認識の統合,” 信学技報, PRMU96-41, pp.31–38, 1996.
- [36] H. Murakami and B. V. K. V. Kumar: “Efficient Calculation of Primary Images from a Set of Images,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.PAMI-4, no.5, pp.511–515, 1982.
- [37] M. Uenohara and T. Kanade: “Use of Fourier and Karhunen-Loeve Decomposition for Fast Pattern Matching With a Large Set of Templates,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.19, no.8, pp.13–22, 1997.
- [38] エルッキ・オヤ (小川 英光, 佐藤 誠 訳): “パターン認識と部分空間法,” 産業出版, 1986.
- [39] 黒田 英夫: “画像符号化技術,” 昭晃堂, デジタル信号処理シリーズ第 15 巻, 1996.

- [40] 浜本 義彦: “パターン認識理論の最近の動向,” 信学誌, vol.77, no.8, pp.853–864, 1994.
- [41] W. H. Press, S. A. Teukolsky, W. T. Vetterling and B. P. Flannery (丹慶 勝市, 奥村 晴彦, 佐藤 俊郎, 小林 誠 訳): “NUMERICAL RECIPES in C,” 技術評論社, 1993.