

エネルギー科学研究科
エネルギー社会・環境科学専攻修士論文
プラント機器の
題目： 迅速かつ確実な特定のための
撮影支援手法の提案と評価

指導教員： 下田 宏 教授

氏名： 大本 悠輔

提出年月日： 令和3年2月8日(月)

論文要旨

題目：プラント機器の迅速かつ確実な特定のための撮影支援手法の提案と評価

下田宏研究室，大本 悠輔

要旨：

電力の安定供給のためには二酸化炭素を排出しない大規模集中型電源である原子力プラントが不可欠であり、その保守作業も安全かつ確実に行わなければならない。原子力プラントの保守・解体作業の際には作業対象を確実に特定する必要がある。そのために、タブレットなどで現場を撮影した画像から現在地を特定し、写った機器を自動的に特定するという方法が考えられる。しかしこの方法を用いるにあたり、似た機器が並ぶプラント内部では一度の撮影のみで現在地や作業対象を特定することは難しい。このとき、追加で周辺を撮影する必要があるが、特定に繋がる情報が得られる周辺場所を作業員が判断するのは難しく、結果的に撮影に時間がかかり迅速な現在地特定ができない。そこで、現在地の特定につながる撮影経路をユーザに提示することで、迅速かつ確実に作業対象を特定可能にする撮影支援システムの開発を想定し、システムの実現のために、本研究ではプラント画像内の物体の認識手法と、効率的な撮影のための撮影経路を決定する手法を提案し評価することを目的とした。

本研究ではプラント内部の画像に写る配管や壁などの物体の認識を試みた。まず機械学習を用いて画像に写る物体を分類し、分類結果から配管の本数や位置を認識することで、外見的特徴ベクトルを生成した。

現在地の特定には撮影した画像から生成した外見的特徴ベクトルと事前準備で作成した、カメラ姿勢とその姿勢から得られる外見的特徴ベクトルが組になって保存されているデータベース内の外見的特徴ベクトルと比較する処理を複数回行うことで現在地の候補を絞り込むため、現在地特定のために効率的な撮影経路を決定する必要がある。そこで、本研究では、事前準備で原子力発電プラントの3D CADモデルを用いてデータベース構築し、構築したデータベースを用いて回転移動と平行移動を合わせた12パターンの方向に移動した際に得られる情報エントロピーを計算し、最大となる方向を次の撮影方向とする撮影経路決定手法を開発した。新型転換炉ふげん発電所での使用を想定したシミュレーションにより性能を評価し、人の動きを模擬して撮影経路を決定する手法と比較した結果、提案した手法では1/3から1/2程度の撮影回数で現在地を特定できることがわかった。

目次

第 1 章 序論	1
第 2 章 研究の背景と目的	3
2.1 研究の背景	3
2.2 既存の現在地特定手法とその問題点	4
2.3 研究の目的と意義	7
2.4 研究の概要	8
第 3 章 機械学習を用いたプラント画像内物体の認識	10
3.1 Semantic Segmentation の概要	10
3.2 プラント画像を用いた転移学習	11
3.2.1 使用したネットワーク	11
3.2.2 本研究での転移学習の実行方法	12
3.3 自作データセットを用いた学習	14
3.4 プラント画像に対する分類の実行例	19
3.5 分類結果を用いた配管の本数認識	20
3.5.1 本数認識の方法	21
3.5.2 本数認識の結果	28
第 4 章 撮影経路決定手法	34
4.1 撮影経路決定手法の概要	34
4.2 構築するデータベース	36
4.3 撮影経路決定手法の詳細	49
4.3.1 外見的特徴ベクトルを用いた現在姿勢の絞り込み	49
4.3.2 誘導先の決定方法	53
4.4 撮影経路決定手法の性能評価	56
4.4.1 評価の目的	56
4.4.2 評価の概要	56

4.4.3	評価の詳細	58
4.4.4	各種パラメータの調整	59
4.4.5	評価の結果と考察	61
第 5 章 結論		64
謝 辞		66
参 考 文 献		67

目 次

2.1	原子力プラント内部の画像例	3
2.2	人工マーカの例	5
2.3	自然特徴の例 ^[8]	5
2.4	自然特徴ベーストラッキングの手法 ^[9]	6
2.5	1枚の画像から現在地の特定が容易な例と困難な例	7
2.6	似た外見の場所を撮ってしまう様子	7
2.7	ナビゲーションの概念図	8
2.8	ナビゲーションの流れ	9
3.1	Semantic Segmentation を用いた画像内物体の分類例 ^[10]	11
3.2	学習に必要な画像セットの例	11
3.3	Semantic Segmentation の複数の層と転移学習 ^[20]	13
3.4	学習済モデルを用いた物体の分類例	13
3.5	labelme の物体領域を囲む際の作業画面	14
3.6	labelme で命名する際の作業画面	15
3.7	labelme で作成したラベル付け画像	15
3.8	境界線を表示させた場合の Piclabel の作業画面	16
3.9	境界線を表示させない場合の Piclabel の作業画面	16
3.10	Piclabel で作成したラベル付け画像	17
3.11	labelme でラベル付けするのに適した画像例	17
3.12	Piclabel でラベル付けするのに適した画像例	18
3.13	作成したデータセット	18
3.14	プラント内部の画像に対する分類の実行例1	19
3.15	プラント内部の画像に対する分類の実行例2	20
3.16	2本としてカウントされる曲がった配管の例	21
3.17	本数認識の流れ	22
3.18	分類結果を2値化する様子	23
3.19	収縮膨張処理でノイズを除去する様子	24

3.20	画像を回転させ複数の画像を作成する様子	25
3.21	配管領域を抜き出す流れ	26
3.22	1本の配管を2本と誤認識する様子	27
3.23	配管の本数認識の結果1	28
3.24	2本と認識された配管を1本に結合する様子	28
3.25	配管の本数認識の結果1	30
3.26	配管の本数認識の結果2	31
3.27	配管の本数認識の結果3	32
4.1	撮影経路決定手法の流れ	34
4.2	撮影経路決定手法の処理の流れ	35
4.3	構築するデータベース	36
4.4	データベース構築の流れ	37
4.5	原子力プラントの3DCADモデルの例 ^[22]	38
4.6	空間を撮影する際のカメラの姿勢	39
4.7	カメラのロール方向の回転	40
4.8	各座標系の設定	41
4.9	横向きの配管とカウントされる例	42
4.10	縦向きの配管とカウントされる例	42
4.11	カメラが平行移動する様子	43
4.12	カメラが回転移動する様子	44
4.13	平行移動先との隣接関係の求め方	45
4.14	回転移動先との隣接関係の求め方	46
4.15	回転平面から45度以上離れているものを除外する様子	47
4.16	回転移動先との隣接関係の関係を求める際の流れ	48
4.17	実行時の処理の流れ	50
4.18	データベースとの比較方法	51
4.19	追加の撮影による候補の絞り込みの様子	52
4.20	情報エントロピーの計算方法	54
4.21	グルーピングの方法	55
4.22	性能評価の概要	57
4.23	性能評価の流れ	59
4.24	エントロピー利用手法における平均撮影回数とLの関係	60

4.25 エントロピー利用手法における平均撮影回数と許容する誤差の関係 . . .	60
4.26 手法別の平均撮影回数	62
4.27 手法別の最多撮影回数	62

表 目 次

3.1	画像に映る配管の実際の本数と認識本数	33
4.1	データベースの構築に用いたふげん発電所の 3D CAD モデルの範囲 . .	58
4.2	性能評価に用いた誤差のパターン	59
4.3	撮影方向を決定するまでの平均処理時間	63
4.4	シミュレーションに用いた PC の仕様と使用した開発環境	63

第 1 章 序論

2011年3月に発生した東京電力福島第一原子力発電所の事故を受けて、国民の原子力プラントへの関心は高まっている。運転停止や廃炉になる原子力プラントが増加する^[1]一方で、再稼働の許可を受け発電を再開している原子力プラント^[2]もある。原子力プラントでの炉心建屋での作業は放射線を被曝する危険性がある。また、小さな作業ミスが重大な事故を引き起こす可能性があるため、廃炉に伴う解体作業や運転のための保守・点検作業は迅速かつ安全に行う必要がある。

一方、原子力プラントでは、長年作業に従事してきた経験の豊富な作業員の高齢化や、少子高齢化に伴い若い作業員の減少が見込まれることから、人材不足が深刻な問題となっている^[3]。したがって、従来より作業員の作業経験が不足している上に、作業員の数が少ない状況で安全を確保しつつ効率的に作業を進める必要がある。原子力プラント内部は非常に複雑かつ広大な上に、外見の似た機器や設備が多く並ぶ環境であるため、作業経験を積んでいない作業員が、作業経験が豊富な作業員と同じように効率的に作業するのは非常に困難である。特に、作業時に目の前の機器や設備が正しい作業対象であるかを確実に特定するのは難しい。作業の際に、目の前の機器や設備の確認に多くの時間をかけるのは手間がかかり非効率的である。

そこで、短い時間で確実に目の前の作業対象が目的とするものであるかを特定する手法が求められている。作業員の現在地（作業をしている位置と向いている方向）を求めることができれば、目の前の機器や設備が正しい作業対象であるかを確認することができるが、原子力プラントのような複雑で物体が多く存在する環境では、GPS等の従来からある位置特定手法は使えず、迅速かつ確実に現在地を特定する手法は確立されていない。原子力プラントでの有力な現在地特定手法として、カメラで撮影した画像を用いて現在地を特定する手法^[9]を利用することも考えられるが、広大で外見の似た箇所が多い原子力プラントでは似た画像が撮影される場合が多く、1枚の画像で現在地を特定することは困難であるため、複数回周辺を撮影して現在位置を特定する手がかかりを増やす必要があるが、迅速かつ確実に現在地の特定に繋がる領域を現場の作業員が判断することは難しい。そこで迅速かつ確実な特定のための効率的な撮影を支援する手法（以下、撮影支援手法）の開発を目的とする。

本論文は、第1章の序論を含め、全5章で構成される。第2章では、本研究の背景と

目的、および概要を述べる。第3章と第4章では、撮影支援手法を実現するために必要な、プラント画像内物体の認識と、撮影経路を決定する手法についての詳細を述べる。具体的には、第3章で機械学習を用いて原子力プラント内部の画像に写る物体を認識する方法とその認識結果について述べ、第4章でカメラで撮影した画像から抽出した外見的特徴を利用して現在地を特定するための撮影経路を決定する手法とその性能評価について述べる。第5章では、本研究のまとめと今後の課題について述べる。

第 2 章 研究の背景と目的

本章ではまず研究の背景として、原子力プラントでの保守・点検・解体作業の現状および課題について述べる。次に課題に対する解決案とその問題点について述べ、最後に本研究の目的と意義、及び概要について述べる。

2.1 研究の背景

原子力プラントでの保守・点検・解体作業の際には、目前の機器・設備が正しい作業対象機器であることを確認する必要がある。しかし図 2.1 に示すようにプラント内部は狭く入り組んでいる上に外見の似た場所や機器・設備が多いため、迅速に目前の機器・設備が正しい作業対象機器であるか否かを判断することは困難である。現状では、現場の機器に取り付けられている金属製のタグや手元の作業手順書を参考にして作業対象機器の確認が行われているが、この方法ではタグの管理に手間がかかったり、誤認や時間的ロスが発生するという問題がある。作業時に自分の場所を正確に特定することができれば、結果的に目前の作業対象が正しい機器であるか否かを判断することができる。現在地を特定する手法は様々あるが、以下では既存手法の概要と原子力プラント内部で用いるにあたっての問題点について述べる。



Copyright (C) 2021 Japan Atomic Energy Agency

図 2.1: 原子力プラント内部の画像例

2.2 既存の現在地特定手法とその問題点


現在地を特定する手法には、GPS(Global Positioning System) を用いるもの、磁気センサや超音波センサを用いるもの^{[4][5]}、カメラ等のビジョンセンサを用いるもの^[9]がある。

原子力プラント内部は屋根などの遮蔽物があり人工衛星からの電波を十分に受信することができないため、GPSを利用することはできない。磁気センサは機材が高価である上に、金属が多く存在する原子力プラント内部で使用するのは困難である。超音波センサは複雑な形状の物体が多い原子力プラントでは正確な反射波を受け取ることができないため、利用することができない。原子力プラント内部では以上のような各種制限により、使用できるセンサが限られる。

一方、カメラ等のビジョンセンサは通信を伴わず、周辺環境の素材や形状がセンサの測定精度に影響を与えないため原子力プラントでも利用可能である。ビジョンセンサを用いた現在地特定手法には図 2.2 に示すような人工マーカを利用する方法や撮影された画像内部の自然特徴を利用する方法^{[6][7]}などがある。このうち、人工マーカを利用する方法は設置に手間がかかる、作業の邪魔になる、汚れると精度が落ちるなど様々な問題点があるため、原子力プラントで利用するのは困難である。画像内の自然特徴を利用する方法は磁気センサや超音波センサのような制限も少なく、事前準備や管理の手間も少ないことから、原子力プラントでの利用に適している。環境中で認識される自然特徴の例を図 2.3 に、自然特徴を利用した現在地特定手法の一般的な方法を図 2.4 に示す。



図 2.2: 人工マーカの例



Copyright (C) 2021 Japan Atomic Energy Agency

図 2.3: 自然特徴の例^[8]




図 2.4: 自然特徴ベーストラッキングの手法^[9]

この手法では事前準備として環境を撮影し、環境中に存在する点や直線などの自然特徴を認識し、撮影時のカメラの位置・方向（以下、姿勢）を組にして保存しておくことでデータベースを構築する。実行時には撮影された画像から自然特徴を認識し、データベースと比較することで現在のカメラの姿勢を特定する。この手法を利用するにあたって、1枚の画像で位置と方向を特定できる場合とできない場合がある。前者の例として、図 2.5 の左のように広い範囲を撮影する場合は、撮影場所が異なると異なる画像が撮影される可能性が非常に高く、1枚の画像から現在地（カメラの位置、方向）の特定が可能である。一方後者の例として、狭く入り組んだ場所の多い原子力プラント内部では図 2.5 右に示すように、機器・設備との距離が近い画像が撮影される場合がある。このような画像が撮影される場所はプラント内部に多く存在するため1枚の画像から現在地を特定することは困難である。そこで、特定のために追加で周辺の領域を撮影をすることで新たに情報を得る必要があるが、似た外見の箇所が多い原子力プラント内部では、特定につながるような領域をユーザが判断するのは困難である。図 2.6 のように同じ外見の場所を繰り返し撮影してしまい、新たな情報を得るまでに時間的ロスが発生してしまう。



現在地の特定が容易



現在地の特定が困難

Copyright (C) 2021 Japan Atomic Energy Agency

図 2.5: 1 枚の画像から現在地の特定が容易な例と困難な例




図 2.6: 似た外見の場所を撮ってしまう様子

2.3 研究の目的と意義

以上のような背景から、現在地を特定するにあたり撮影すべき方向を自動的に決定し、ナビゲーションするような支援手法が必要である。そこで、過去に撮影して得た画像を元に、現在地の特定につながる撮影方向を自動的に決定してユーザに提示することで、迅速かつ確実に作業対象を特定可能にする手法の加発を想定し、本研究では画像内物体の認識手法と過去の撮影結果をもとに撮影経路を決定する手法の提案を

目的とした。本手法が実現すれば、目前の原子力プラントの特定までの時間を短縮することができる、原子力プラントでの作業の所要時間を短縮するとともに作業対象の間違いを減らすことができると期待される。

2.4 研究の概要

ナビゲーションの概念図を図 2.7 に、流れを図 2.8 に示す。本研究では、前節で述べたナビゲーションを実現するために、原子力プラント内部の配管や壁、タンクなどの物体を外見的特徴として利用する。具体的には、ユーザが作業対象が正しいものであるか確認するために、目前の機器・設備をタブレットで撮影すると、撮影された画像から配管などの物体が認識される。物体の認識には、機械学習を用いる。その後、現在地の画像から特定に必要な追加の撮影を効率的に実施するためのカメラの動かし方を自動的に決定してユーザをナビゲーションする。

次章以降では上記のナビゲーションを実現するにあたって必要な画像内の物体の認識と、過去の撮影結果をもとに今後の撮影経路を決定する手法（以下、撮影経路決定手法）について述べる。3 章では機械学習を用いたプラント画像内物体の認識の方法と結果について述べ、4 章では開発した撮影経路決定手法の詳細とその評価結果について述べる。




図 2.7: ナビゲーションの概念図

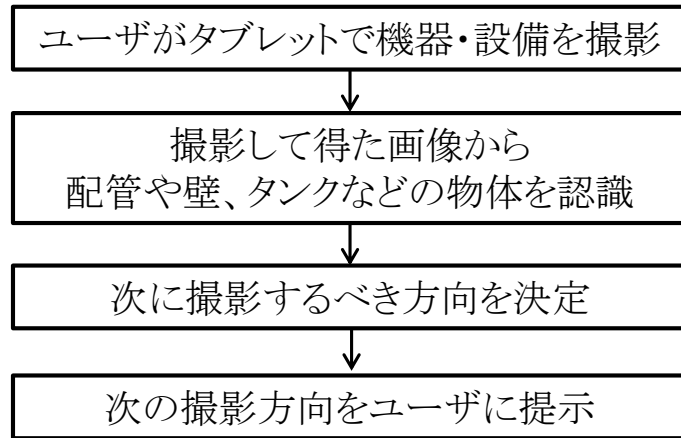


図 2.8: ナビゲーションの流れ

第 3 章 機械学習を用いたプラント画像内物体の認識

本章では撮影されたプラント内部の画像に映っている物体の認識の方法について述べる。本研究で想定するシステムでは、カメラで撮影された画像を用いた現在のカメラ姿勢の特定に利用可能な情報として外見的特徴を抽出する。そのため、配管や壁、タンク、床などの物体を認識した。本研究では、画像上に写っている物体を認識するにあたり、まず、画像系ディープラーニングの 1 種である Semantic Segmentation を用いた。以下では、機械学習を用いた Semantic Segmentation の概要について述べ、次に Semantic Segmentation をプラント内部の画像に応用したときの動作例と、その結果を用いた配管の本数認識について述べる。

3.1 Semantic Segmentation の概要

Semantic Segmentation とは図 3.1 のように画像に映っている物体が何であるかをピクセル単位で分類する手法である。Semantic Segmentation ではまず事前に用意された大量の画像を集めたデータセットを用いて学習をすることで、物体を分類するモデル（分類モデル）を生成する。学習には図 3.2 に示すような、実画像とその画像の各ピクセルが表している物体を示すラベルがつけられた画像（ラベル付け画像）が必要である。生成した分類モデルを新たな画像に適用することで画像内の物体を分類する。既に存在する分類モデルでは、犬や猫などの物体を分類することができるが、原子力プラント内部の画像に対して、物体の分類をできる分類モデルは存在しない。そのため、本研究では Semantic Segmentation をプラント内部の画像に応用して配管やタンクなどの物体を分類するモデルを作成することを試みた。

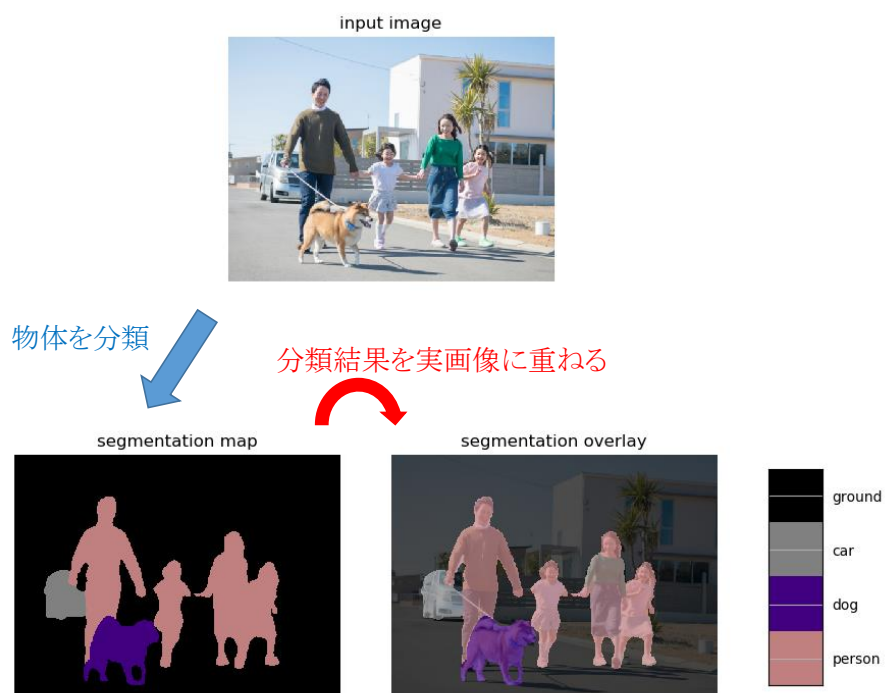


図 3.1: Semantic Segmentation を用いた画像内物体の分類例 [10]




図 3.2: 学習に必要な画像セットの例

3.2 プラント画像を用いた転移学習

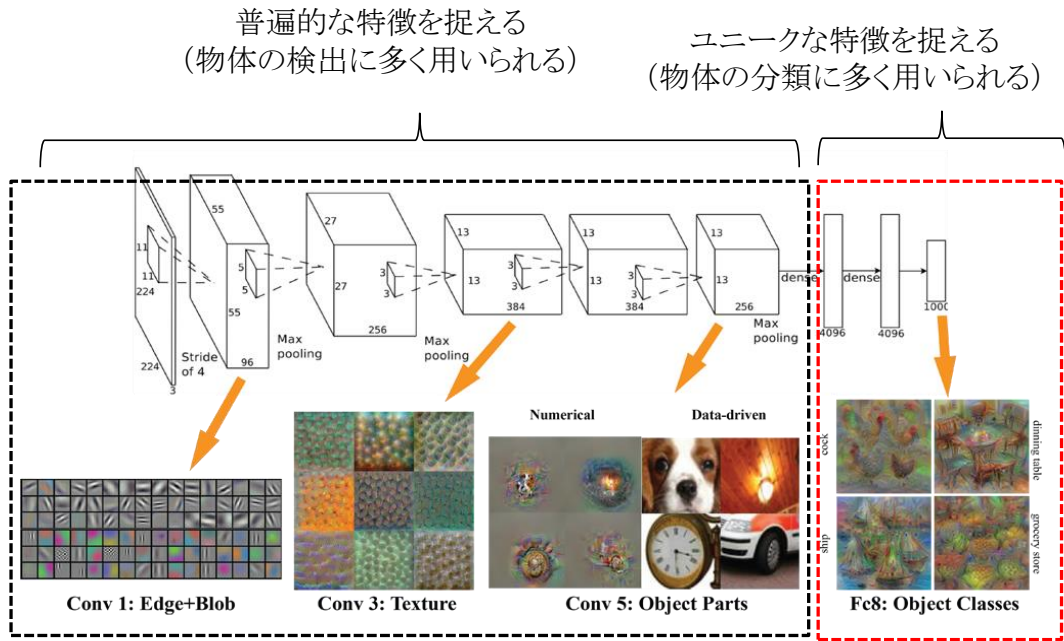
3.2.1 使用したネットワーク

機械学習を用いた Semantic Segmentation に用いられるネットワークとして Long らが提案した Fully Convolutional Network (FCN)^[11] と呼ばれるネットワークを基本として、U-Net^[12] や PSPNet^[13]、DeepLab 系ネットワーク^[14] など様々なものが存在する。その中で DeepLab 系ネットワークの中でも最新である DeepLab v3+ は、他のネット

ワークと比較して高精度で処理速度も速く^[15] 既往研究^{[16][17]}において多く利用されていることから、本研究でも DeepLab v3+を用いることにした。Semantic Segmentationの学習に用いられるデータセットはインターネット上に公開されているものが多くある。本研究では既存のデータセットによって既に学習された分類モデルに対して、次項で述べる転移学習^[18]と呼ばれる手法を用いて再学習することで、プラント内部の画像に対しても物体を分類できるモデルを作成することを試みた。

3.2.2 本研究での転移学習の実行方法

転移学習とは、あるタスクに用いるために既に学習されたモデルを新たなデータを用いて再学習することで、別のタスクにも適用可能にする手法である。Semantic Segmentationの学習のネットワークは図 3.3 のように複数の層からなる。前半の層ではエッジやテクスチャなどの、画像に映る物体の普遍的な特徴を捉え、後半の層では画像に映る物体のユニークな特徴を捉える。Semantic Segmentation を用いて画像に映る物体を分類する際には、まず画像の各ピクセルに対して物体が存在するかを判別し、存在する場合は何が映っているかを分類する。前半の層で捉えられた特徴は物体が存在する領域の検出に用いられ、後半の層で捉えられた特徴は映っている物体が何であるかの分類のために用いられる。そのため、前半の層の学習結果を再利用し、後半の層を分類したい物体に応じて再学習することで任意の物体を分類するモデルを作成することができる。本研究では、犬、猫、鳥などの 20 種類の物体と背景の合計 21 種類が含まれる実画像とラベル付け画像、16,551 組からなる Pascal VOC 2012^[19] というデータセットを、DeepLab v3+を使って学習することで生成された図 3.4 のような分類ができるモデルに対して、プラント内部の画像を再学習させることで、プラント内部の物体を分類できるモデルを作成した。本章次節以降では、実際にプラント内部の画像からなるデータセットの作り方、および作成したモデルによるプラント内部の画像に対する分類の実行例について述べる。



この層を利用目的に応じて再学習する

図 3.3: Semantic Segmentation の複数の層と転移学習 [20]

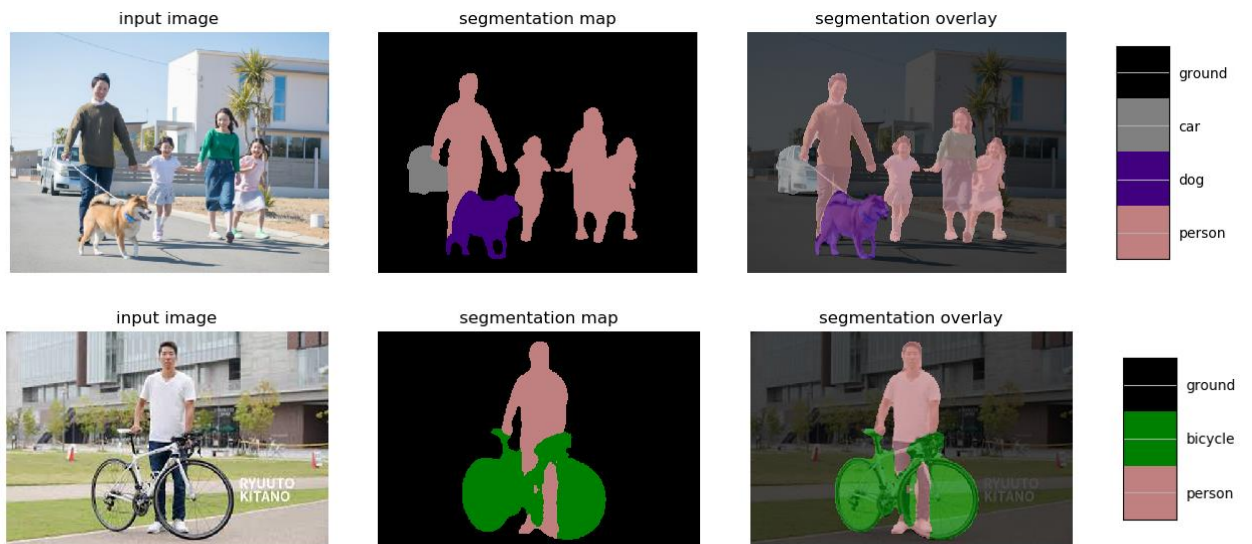



図 3.4: 学習済モデルを用いた物体の分類例

3.3 自作データセットを用いた学習

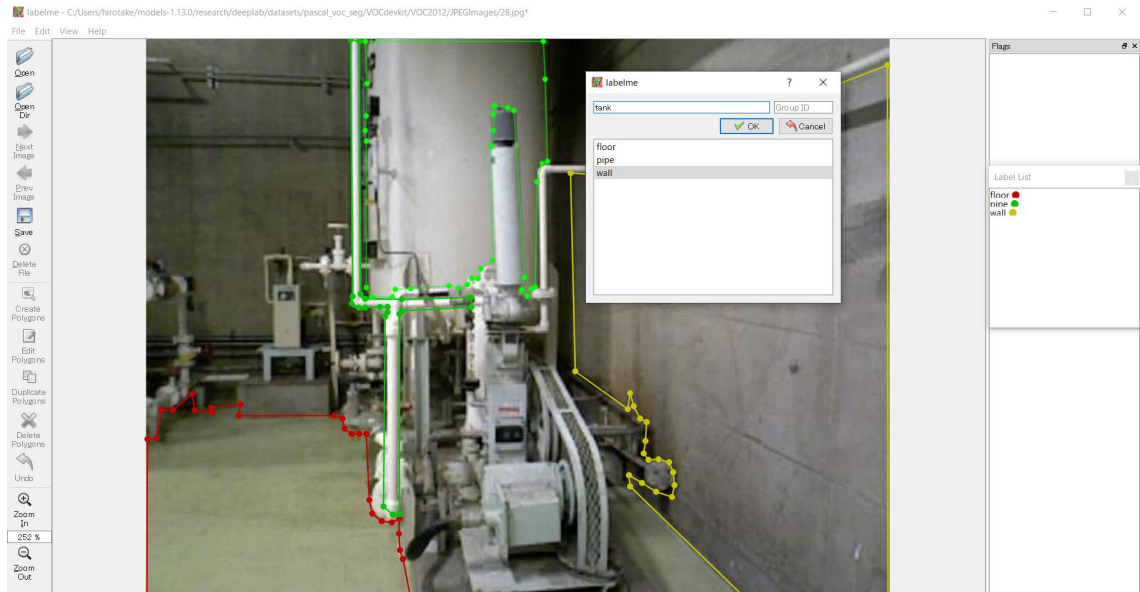
3.1.2 項で述べたように Semantic Segmentation の学習を実行するためには実画像とラベル付け画像が必要である。そこで、本研究では実際に新型転換炉ふげん発電所内部を撮影して得た画像を用意し、それらのラベル付け画像を作成した。ラベル付け画像は GUI のラベル付けツールである「labelme」^[21] と、ラベル付け用に作成したツール「Piclabel」の2つを用いて作成した。作成できる画像はどちらも同じものであるが、labelme は高い精度で画像のラベル付けができるため、物体が入り組んだ画像でもラベル付けができるが手間がかかる。それに対し、Piclabel は labelme ほど高精度ではないが、物体の境界が明確な画像に対しては短時間でラベル付け画像を作成することができる。

labelme では図 3.5 のように画像内の分類したい物体の輪郭線上をクリックすることで点をプロットして、物体領域を囲んだ後、図 3.6 のようにその物体の名前を決定することでラベルをつける。これを映っている物体に対して行うことで図 3.7 のようなラベル付け画像を作成することができる。本研究では写る可能性が高く、認識がしやすいと考えられる配管、タンク、壁、床をラベル付けの対象とした。



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.5: labelme の物体領域を囲む際の作業画面



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.6: labelme で命名する際の作業画面


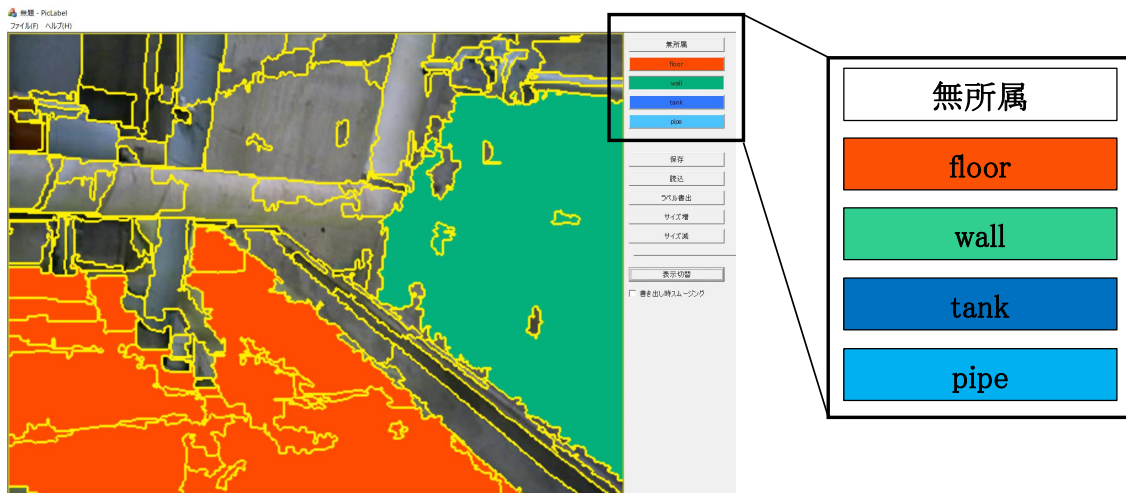


図 3.7: labelme で作成したラベル付け画像

一方、Piclabel ではまず実画像上の各ピクセルの RGB 値に応じて似た色の領域を自動的にまとめる。次に図 3.8 の右枠に含まれるラベルを選択した状態で領域内部をクリックすると、その領域にラベルを付けることができる。複数のピクセルを同じ領域と判定する際のしきい値が変更可能であり、小さくすればするほど細かく領域の分割ができる。また、作業しながら正しくラベル付けができていないかを確認しやすくするため、図 3.9 のように領域の境界線の有無を選択することができる。このようにして各物体にラベル付けをし、labelme と同様に図 3.10 のようなラベル画像を作ることができる。



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.8: 境界線を表示させた場合の Piclabel の作業画面



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.9: 境界線を表示させない場合の Piclabel の作業画面




図 3.10: Piclabel で作成したラベル付け画像

labelme の方が精度の高いラベル付けをできるが、1枚のラベル付き画像の作成に手間がかかり必要な時間が多いため、Piclabel で十分な精度でラベル付けできる画像については、Piclabel を用いて作成した。具体的には、図 3.11 のように画像内に映っている物体が多く、自動での領域分けが困難な画像については labelme を用いてラベル付けをし、図 3.12 のように画像内に映っている物体が少なく、領域分けが容易な画像については Piclabel を用いてラベル付けをした。以上のようにしてラベル付け画像を作成し、実画像と組み合わせたものを 1 セットとして 150 セット準備した。これらを用いて転移学習を実行し学習済モデルを再学習させることで、プラント内部の画像で物体の分類ができるモデルを作成した。



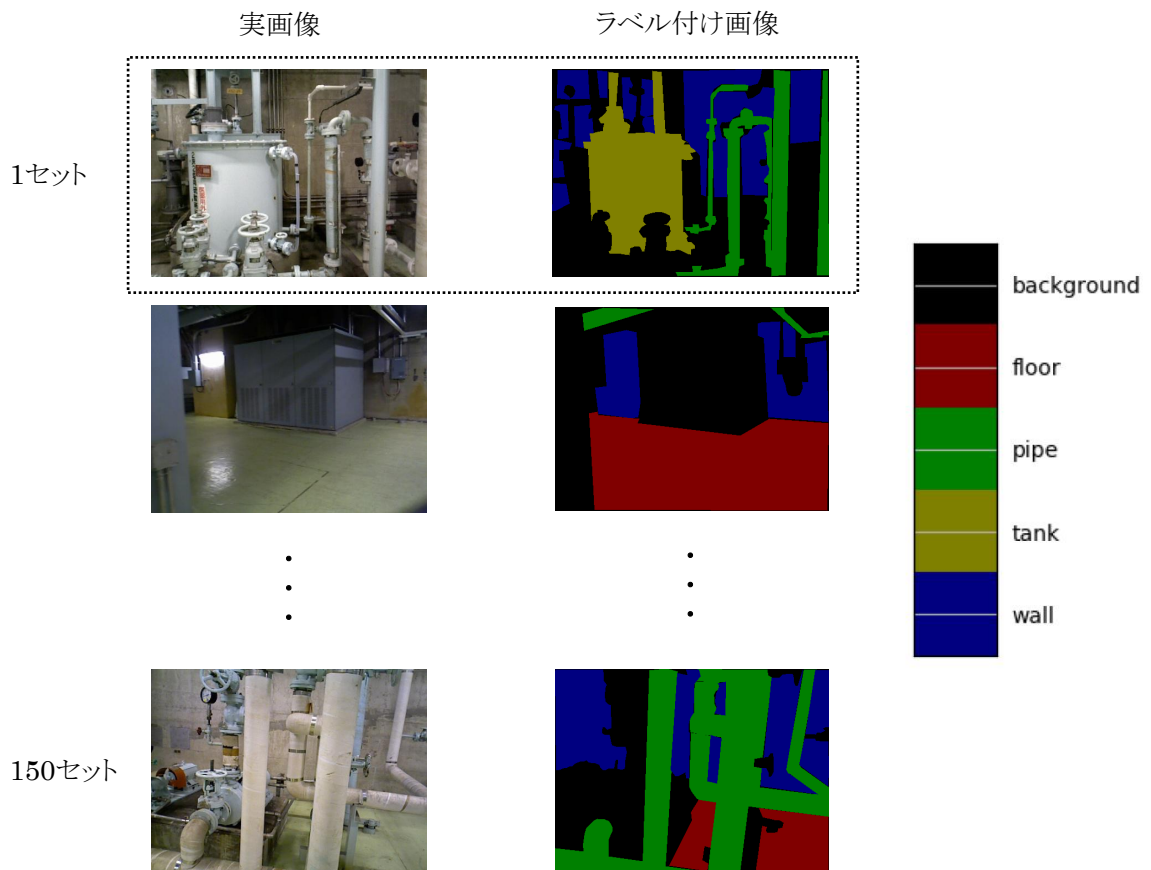
Copyright (C) 2021 Japan Atomic Energy Agency

図 3.11: labelme でラベル付けするのに適した画像例



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.12: Piclabel でラベル付けするのに適した画像例




Copyright (C) 2021 Japan Atomic Energy Agency

図 3.13: 作成したデータセット


3.4 プラント画像に対する分類の実行例

プラント内部の画像を使って作成した分類モデルを用いて、学習には使っていないプラント内部の画像に対して分類を実行した結果の例を図 3.14、図 3.15 に示す。赤色が床の領域を、緑色が配管の領域を、黄色がタンクの領域を、青色が壁の領域を表している。



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.14: プラント内部の画像に対する分類の実行例 1



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.15: プラント内部の画像に対する分類の実行例 2


図 3.14 の上図および下図のように、物体の領域がはっきりしている画像に対しては配管、壁、タンク、床を分類できていることがわかる。しかし中央の図の右上部分の配管が密集している個所では、配管領域とそれ以外の領域の境界線の部分が上手く分類できていないため、複数の配管領域が繋がっていて、実画像では天井の領域も配管領域に含まれている。また図 3.15 の図では、配管を配管領域に含めていない箇所が多くみられる。これは配管と配管を繋ぐバルブ部分を分類対象に含めていなかったため、配管が途中で切れてしまっていると考えられる。したがって、バルブを分類対象に含めた上で、より多くの配管の写り方のパターンを含めたデータセットで学習すれば精度は向上すると考えられる。

3.5 分類結果を用いた配管の本数認識

本節では分類結果を用いた配管の本数認識について述べる。まず認識の方法について述べ、その後認識結果について述べる。

3.5.1 本数認識の方法

4章で述べる撮影経路決定手法において、実際にユーザの現在地を特定する際には配管の本数を外見的特徴として用いるため、分類した結果を用いて配管の本数の認識を試みた。他にも外見的特徴として用いる壁や配管との距離は、現場を撮影する際にRGB-Dカメラを用いればデプス値を測定し抽出することができる。なお、本研究では原子力プラントの3D CADモデルを用いて配管の本数などの外見的特徴を認識するが、本研究で用いた新型転換炉ふげん発電所の3DCADモデルでも、曲がっている配管は複数の直線状の配管の組み合わせで表現されているため、図3.16のように1本の配管が途中で曲がっている場合、2本としてカウントする。



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.16: 2本としてカウントされる曲がった配管の例

以下では3.4節で述べたプラント画像の物体の分類の結果を用いて配管の本数を認識する手法について述べる。なお、本研究で作成した分類モデルで画像を分類した結果は500×375ピクセルの画像で出力されるため、本手法は500×375ピクセルの画像に対する処理を想定した。

図 3.17 に配管の本数を認識する流れを示す。まず、図 3.18 のように物体を分類した結果の画像を、配管領域とそれ以外の背景領域に 2 値化する。2 値化された画像のノイズを除去するために、図 3.19 に示す収縮膨張処理を行う。まず配管領域を 2 ピクセル収縮することで、処理前の画像に含まれるノイズを除去する。次に配管領域を 2 ピクセル膨張させることで、処理前の画像からノイズのみを除去した画像を得ることができる。次に図 3.20 ノイズ除去した画像を -90 度から 85 度まで回転させることで 34 枚の画像を作成する。

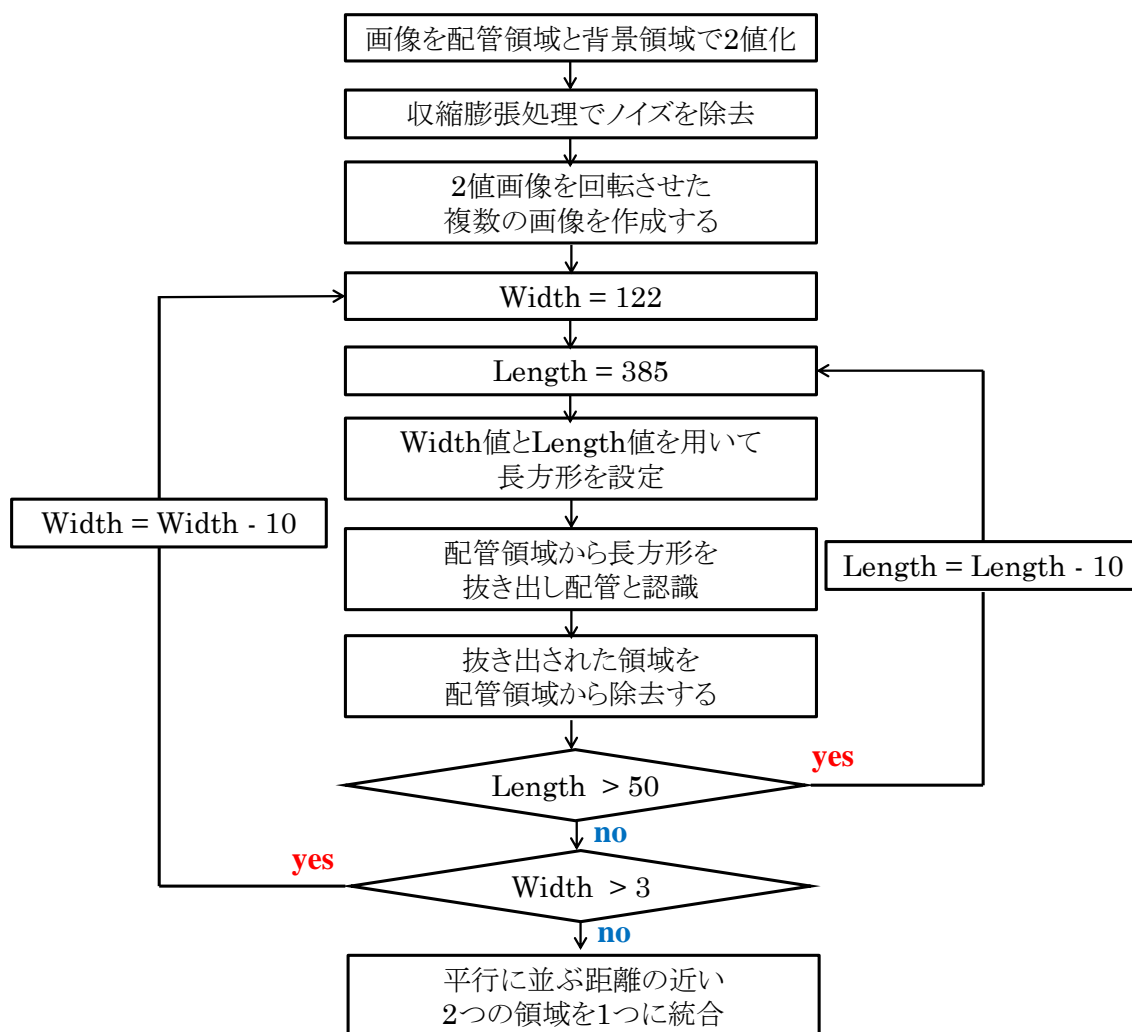


図 3.17: 本数認識の流れ





図 3.18: 分類結果を2値化する様子



各配管領域を2ピクセル収縮



各配管領域を2ピクセル膨張




図 3.19: 収縮膨張処理でノイズを除去する様子

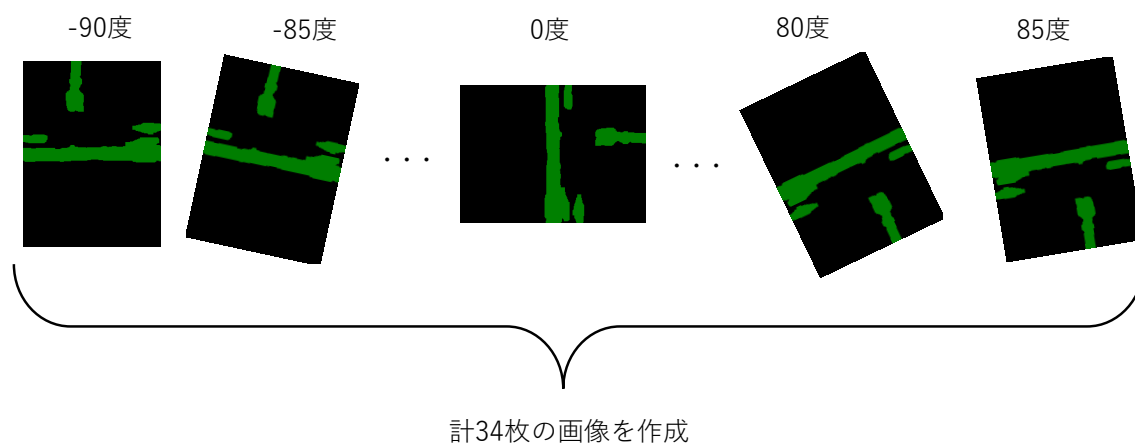


図 3.20: 画像を回転させ複数の画像を作成する様子

次に図 3.21 のように Width 値と Length 値を定め、縦の長さが Width、横の長さが Length の横向きの長方形を完全に含むことができる配管領域のうち、1 番面積の大きいものを 34 枚の画像群から抜き出す。抜き出すことができれば配管を 1 本認識したとし、その長方形領域を背景領域とする。Width 値と Length 値を徐々に小さくし、面積の大きい長方形から順に抜き出すことで複数の配管を認識する。




図 3.21: 配管領域を抜き出す流れ

処理した後の結果には図 3.22 のように 1 本の配管にも関わらず、2 本であると認識されるケースがある。これは配管領域の一部が欠けているため、2 つの長方形領域に分けて認識されるためである。そのため、平行に並ぶ距離の近い 2 つの長方形領域を 1 つにする必要がある。そこで、図 3.23 のように 2 本と認識された配管のうち、一方の配管の両端の 2 点と他方の配管の延長直線との距離を計算し、どちらも 20 以内であれば 1 本の配管であるとした。この処理によって、図 3.24 のように 2 本と誤認識されていた配管を 1 本と認識することができた。このように抜き出した長方形領域をカウントすることで、画像に写る配管の本数を認識した。




図 3.22: 1 本の配管を 2 本と誤認識する様子




図 3.23: 配管の本数認識の結果 1





図 3.24: 2本と認識された配管を1本に結合する様子

3.5.2 本数認識の結果


分類した画像から配管を認識した結果を図 3.25、図 3.26、図 3.26 に示す。また、実際に画像に映っている配管の本数と、認識した配管の本数、およびそれらの差を表 3.1 に示す。

平均で2.5本の差があり、最も差が大きい時は7本の誤認識がある。実際の配管の本数と、認識された配管の本数には差があることがわかる。これには様々な要因が考えられる。例えば図3.26の画像5の右上部分に映る4本の配管は、物体分類の際には配管と分類されているものの、配管であるとは認識されていない。これは配管が画面外に見切れていて、配管と認識された他の配管領域と比べて短く映っているためである。他にも図3.25の画像3の左上の配管領域も同様である。また、図3.27の画像5の右下部分や画像6の中央部分、図3.27の画像12の中央部分の配管領域では実際には複数の配管が映っているが、画像上で配管同士が重なっているため、1本として認識されている。


画像1





画像2



画像3




画像4




Copyright (C) 2021 Japan Atomic Energy Agency

図 3.25: 配管の本数認識の結果 1


画像5




画像6



画像7




画像8




Copyright (C) 2021 Japan Atomic Energy Agency

図 3.26: 配管の本数認識の結果 2

画像9




画像10



画像11



画像12



Copyright (C) 2021 Japan Atomic Energy Agency

図 3.27: 配管の本数認識の結果 3

表 3.1: 画像に映る配管の実際の本数と認識本数

画像番号	実際の本数	認識本数	差
1	3本	2本	1本
2	4本	5本	1本
3	13本	6本	7本
4	11本	10本	1本
5	11本	4本	7本
6	8本	4本	4本
7	4本	4本	0本
8	13本	9本	4本
9	9本	7本	2本
10	6本	5本	1本
11	6本	7本	1本
12	6本	5本	1本

このように配管の本数認識は正確なものではないため、次章で述べる撮影経路決定手法において外見的特徴として用いるには、物体分類による認識の際に含まれる誤差を考慮した上でアルゴリズムを考案する必要がある。4章ではプラント内部の画像から抽出可能な外見的特徴を用いて、撮影された画像から現在地を特定する手法についての詳細を述べる。

第 4 章 撮影経路決定手法

本章では、過去の撮影結果をもとに今後の撮影経路を決定する手法（撮影経路決定手法）について述べる。まず撮影経路決定手法の概要について述べ、事前準備として必要なデータベースの構築の方法について述べる。その後、撮影経路決定手法の詳細について述べ、最後に提案した撮影経路決定手法の性能評価について述べる。

4.1 撮影経路決定手法の概要

本手法では、ユーザが特定したい機器・設備をタブレット PC で撮影し、システムに入力する状況から開始することを想定する。この入力された画像が撮影された時のカメラの姿勢を特定するために必要な、追加の撮影を効率的に行うための撮影経路を決定する。撮影経路決定手法は、図 4.1 に示すように、事前準備としてのデータベース構築処理と、入力された画像を元に実際に撮影経路を決定する処理の大きく 2 つの処理に分けられる。各処理の詳細を図 4.2 に示す。

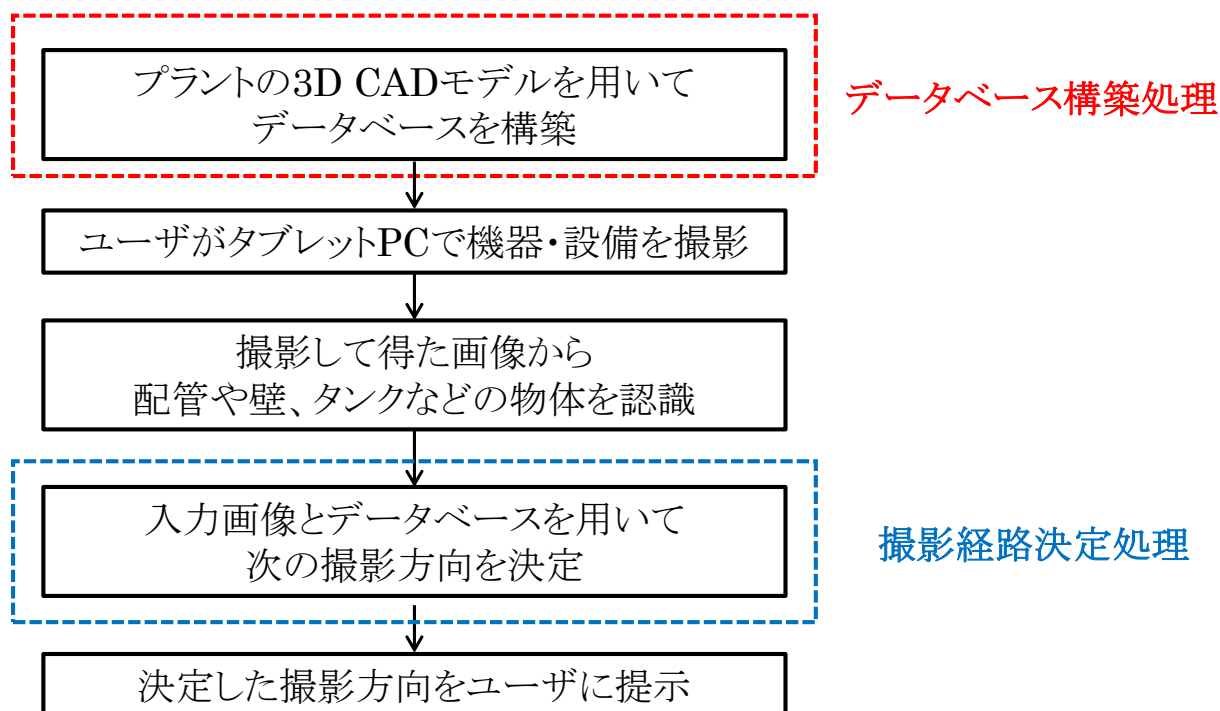
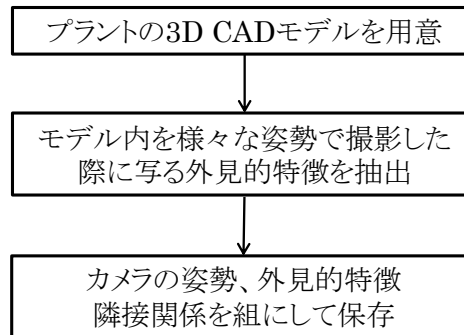


図 4.1: 撮影経路決定手法の流れ

データベース構築処理



撮影経路決定処理

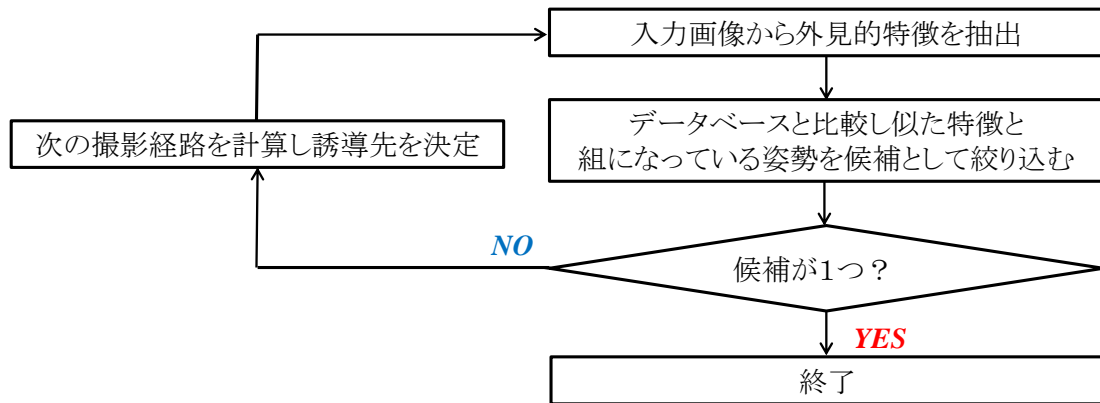


図 4.2: 撮影経路決定手法の処理の流れ

事前準備として原子力プラントの3D CADモデルを用いて、様々な姿勢からプラント内部をカメラで撮影した場合に映る配管などの外見的特徴を抽出し、撮影時のカメラの姿勢と組にして保存することでデータベースを構築する。入力画像が撮影されたカメラの姿勢を特定するには、まず初めに入力画像に映る外見的特徴を抽出しデータベース内のデータと比較することで、カメラの姿勢の候補を絞り込む。この1枚の画像だけで候補が絞り込めない場合は、入力画像をもとに初めに入力画像が撮影されたカメラの姿勢を特定するために必要な追加の撮影を効率的に行える新しいカメラの姿勢を決定する。決定した撮影経路に従い追加で撮影をすることで得た、新たな入力画像を用いて再び絞り込みを実行し、候補が1つに絞り込めた時点で処理を終了とする。なお、本研究では、ユーザは必ず指定された方向にカメラを移動させると想定し、指定に従わなかった場合の対策については将来課題とし、ここでは想定しない。

4.2 構築するデータベース

事前準備では、カメラの姿勢を特定する際に用いるデータベースを構築する。作成するデータベースの概要を図 4.3 に示す。カメラの姿勢、撮影される画像から得られる外見的特徴ベクトル、並進・回転の各 6 通りで移動した場合の新しい姿勢（以下、隣接関係）を組にして保存することでデータベースを構築する。なお、方向を表す 4 次元ベクトルは、前の 3 つの要素がカメラの撮影方向ベクトルを表し、最後の要素がカメラの注視方向周りの回転角度を表す。

Index	位置	外見的特徴ベクトル		
		方向	近くの姿勢との隣接関係	
1	(x_1, y_1, z_1)	$(vx_1, vy_1, vz_1, -40)$	P_1	Q_1
2		$(vx_1, vy_1, vz_1, -30)$	P_2	Q_2
⋮		⋮	⋮	⋮
558		$(vx_{62}, vy_{62}, vz_{62}, 40)$	P_{62}	Q_{62}
559	(x_2, y_1, z_1)	$(vx_1, vy_1, vz_1, -40)$	P_{63}	Q_{63}
560		$(vx_1, vy_1, vz_1, -30)$	P_{64}	Q_{64}
⋮		⋮	⋮	⋮
1116		$(vx_{62}, vy_{62}, vz_{62}, 40)$	P_{124}	Q_{124}
⋮	⋮	⋮	⋮	⋮
W - 61	(x_l, y_m, z_n)	$(vx_l, vy_l, vz_l, -40)$	P_{W-61}	Q_{W-61}
W - 60		$(vx_l, vy_l, vz_l, -30)$	P_{W-60}	Q_{W-60}
⋮		⋮	⋮	⋮
W		$(vx_{62}, vy_{62}, vz_{62}, 40)$	P_W	Q_W

総数 W
 $= 62 \times 9 \times l \times m \times n$

l : 撮影した空間の x 軸方向の立方体領域の数
 m : 撮影した空間の y 軸方向の立方体領域の数
 n : 撮影した空間の z 軸方向の立方体領域の数

$$\text{外見的特徴ベクトル } \mathbf{P} = \begin{pmatrix} \text{配管の本数} \\ \text{横方向の配管の本数} \\ \text{縦方向の配管の本数} \\ \text{最も近い配管との距離 [mm]} \\ \text{最も近い壁との距離 [mm]} \end{pmatrix}$$

$$\text{隣接関係ベクトル } \mathbf{Q} = \begin{pmatrix} \text{右に平行移動した際の姿勢の Index} \\ \text{左に平行移動した際の姿勢の Index} \\ \text{上に平行移動した際の姿勢の Index} \\ \vdots \\ \text{ロール方向に時計回りに回転した際の姿勢の Index} \end{pmatrix} \quad \left. \vphantom{\begin{pmatrix} \text{右に平行移動した際の姿勢の Index} \\ \text{左に平行移動した際の姿勢の Index} \\ \text{上に平行移動した際の姿勢の Index} \\ \vdots \\ \text{ロール方向に時計回りに回転した際の姿勢の Index} \end{pmatrix}} \right\} 12 \text{次元}$$

図 4.3: 構築するデータベース

データベース構築時の処理の流れを図4.4に示す。本処理では、図4.5に示すような3D CADモデルが利用可能であると想定する。まず初めに図4.6のように空間を事前に定めた大きさの立方体領域に分割し、各領域の中心から様々な方向に向けてカメラを設置した場合に写る配管や壁などを3D CADを用いて求める。本研究では、カメラの解像度は 640×480 ピクセルとした。なお本論文では、分割する際の立方体の一辺の長さの適切な値については4.4節で検討する。様々な方向にカメラを向ける際、その間隔をほぼ均等にするために、本研究では正20面体の各頂点、各辺の中点、各面の中心点の計62点を利用し、正20面体の中心から各62点への方向ベクトルを正規化したものを撮影方向ベクトルとする。さらに1つの撮影方向ベクトルに対して、図4.7のようにロール方向に -40 度から 40 度まで 10 度刻みで回転させることによって、1つの撮影方向ベクトルに対して9パターンのカメラ方向を得る。これにより、1つの座標でのカメラの向ける方向は 558 通りとなる。図4.8に座標系の設定方法を示す。ここでカメラ座標系とはカメラを原点とし、カメラの右方向 X 軸、カメラの上方向を Y 軸、カメラの注視方向を Z 軸とした座標系であり、スクリーン座標系とは、カメラが撮影する画像内部の座標系である。

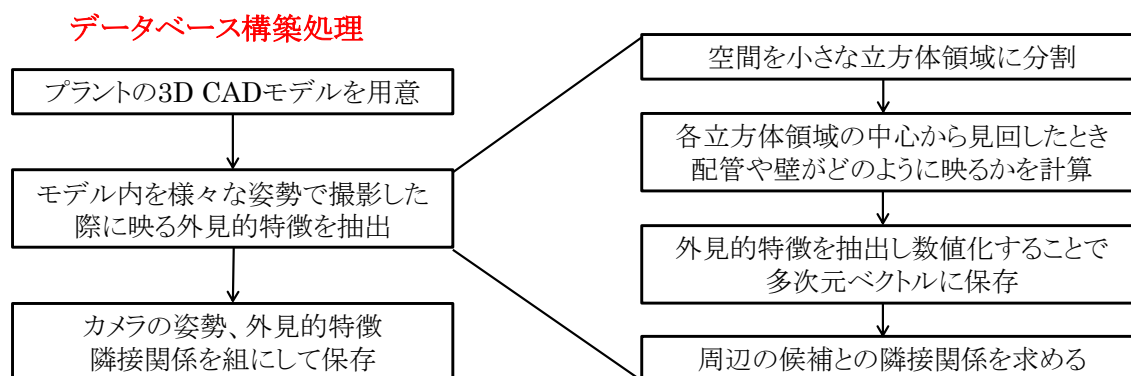


図 4.4: データベース構築の流れ




図 4.5: 原子力プラントの 3DCAD モデルの例 [22]

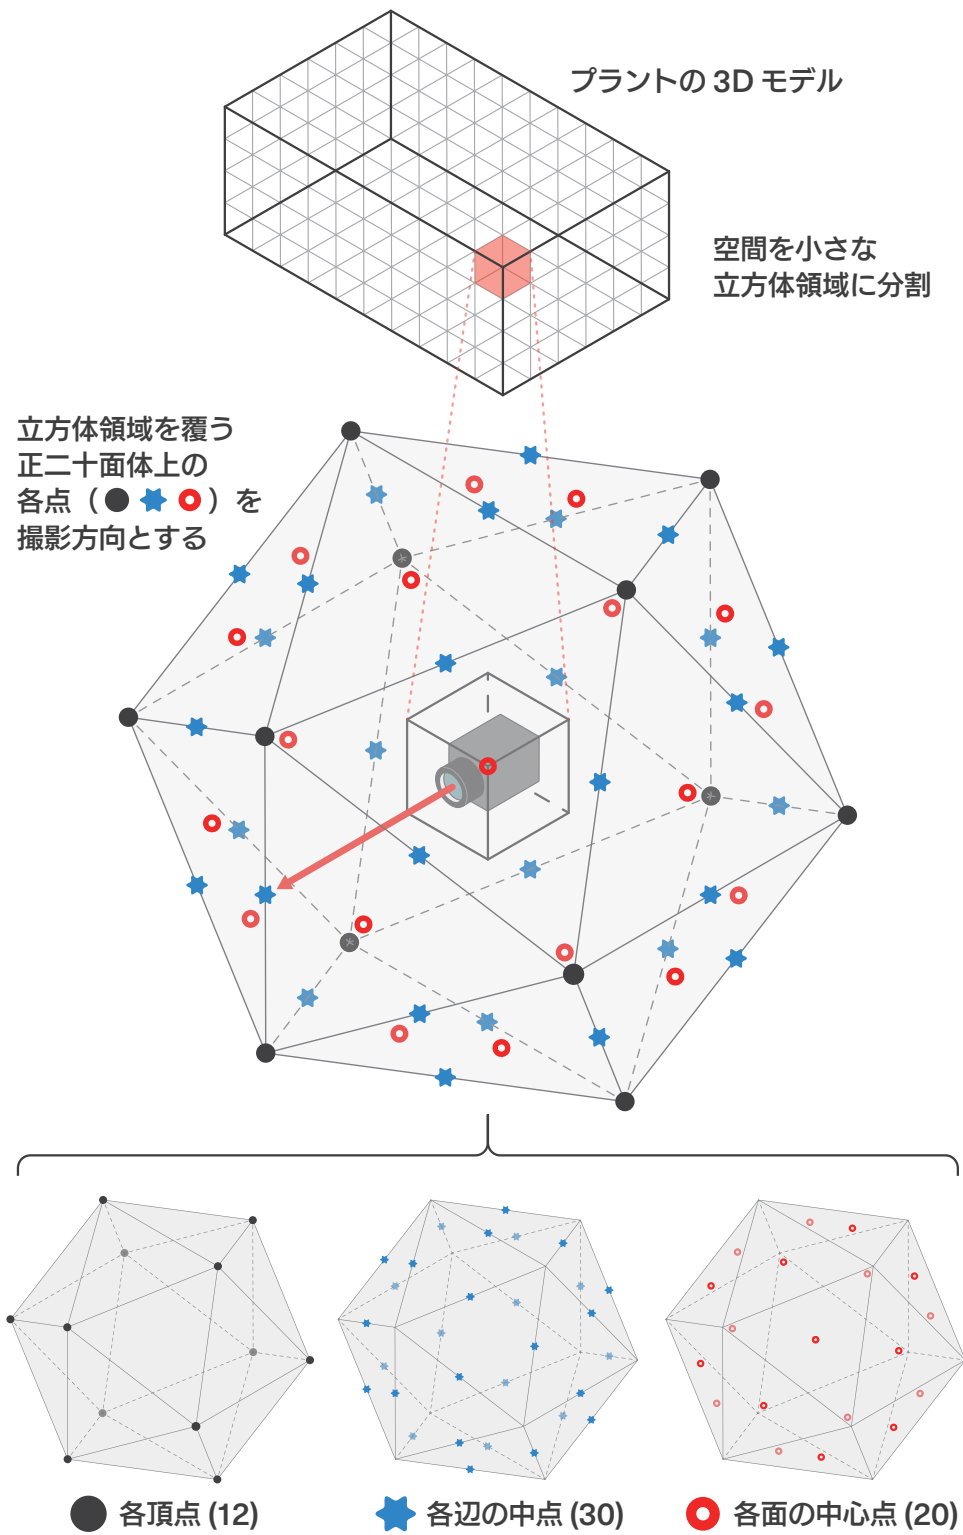


図 4.6: 空間を撮影する際のカメラの姿勢




図 4.7: カメラのロール方向の回転




図 4.8: 各座標系の設定

このように分割した全立方体領域の中心座標から上記 558 通りの方向で空間を撮影したときの配管や壁の写り方を計算し、外見的特徴を抽出することで多次元ベクトル（以下、外見的特徴ベクトル）を生成する。なお、カメラからの距離が遠い物体は現場で撮影する際には写らない可能性が高いため、外見的特徴ベクトルの生成はカメラからの距離が 5m 以内の物体を用いたものに限定する。本研究では、プラント内部に配管が多くあること、画像を撮影した際に壁が映り込む可能性が高いことを考慮して、映っている配管の本数、画面内の配管のうち画面の横軸と平行に近い角度で映っている配管（以下、横向きの配管）の本数、画面の縦軸と平行に近い角度で映っている配管（以下、縦向きの配管）の本数、カメラから最も近くにある配管との距離、最も近い壁との距離の 5 つの指標を含む 5 次元ベクトルを、絞り込みに用いるための外見的特徴ベクトルとする。なお、図 4.9 のように映っている配管の両端の Y 座標の差が 20 ピクセル以内の配管を縦向きの配管、図 4.10 のように映っている配管の両端の X 座標の差が 20 ピクセル以内の配管を横向きの配管とする。




図 4.9: 横向き配管とカウントされる例

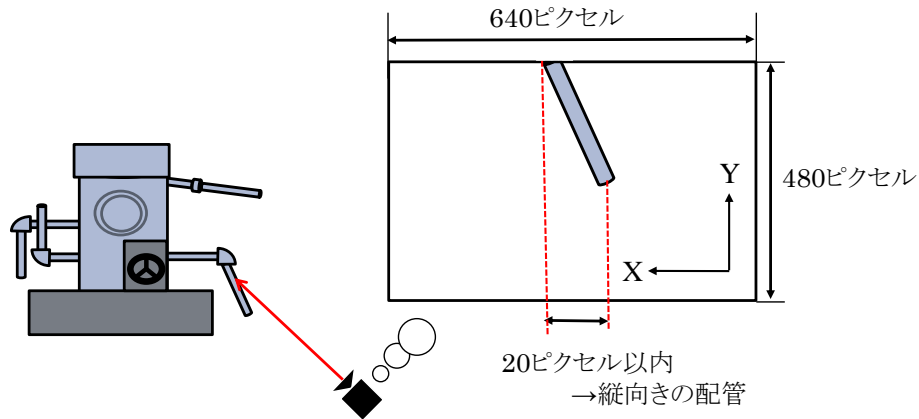


図 4.10: 縦向き配管とカウントされる例

次に、データベースの2つ目の要素である、カメラ姿勢間の隣接関係を求める方法を説明する。本研究ではカメラの動かし方（ユーザに次の撮影姿勢を示す際の指示のパターン）を図4.11と図4.12に示す計12パターンとする。この12パターンは、図4.11に示すような X_c 軸方向、 Y_c 軸方向、 Z_c 軸方向の座標がそれぞれ増減する計6パターンの平行移動と、図4.12に示すような Y_c 軸周りの回転、 X_c 軸周りの回転、 Z_c 軸周りの回転についてそれぞれ時計回り、反時計回りを考慮した計6パターンの回転移動で構成される。例としてある姿勢から右に移動した際の移動先の姿勢を求める方法を説明する。移動元の方角としては、前述の558通りの方角を向いている場合があり得る。

図4.8に示すように、移動元のカメラの方角によってカメラ座標系が決まるため、同じ位置から右に移動した際の姿勢を求める場合であっても、移動元のカメラの方角が異なれば、右方向も異なる。さらに、隣接関係はデータベースに含まれる姿勢間の関

係を表すものであるため、移動元の姿勢と、移動後の姿勢はどちらもデータベース内に存在する必要がある。しかし、ある姿勢から右に移動する際に移動直線上にデータベースに含まれる他の姿勢が存在するとは限らない。そのため、移動元の姿勢から微小距離間隔で一定の距離移動させた場合の他の姿勢との距離を繰り返し求め、最も近い姿勢を移動先とする。以下ではその求め方の詳細を述べる。

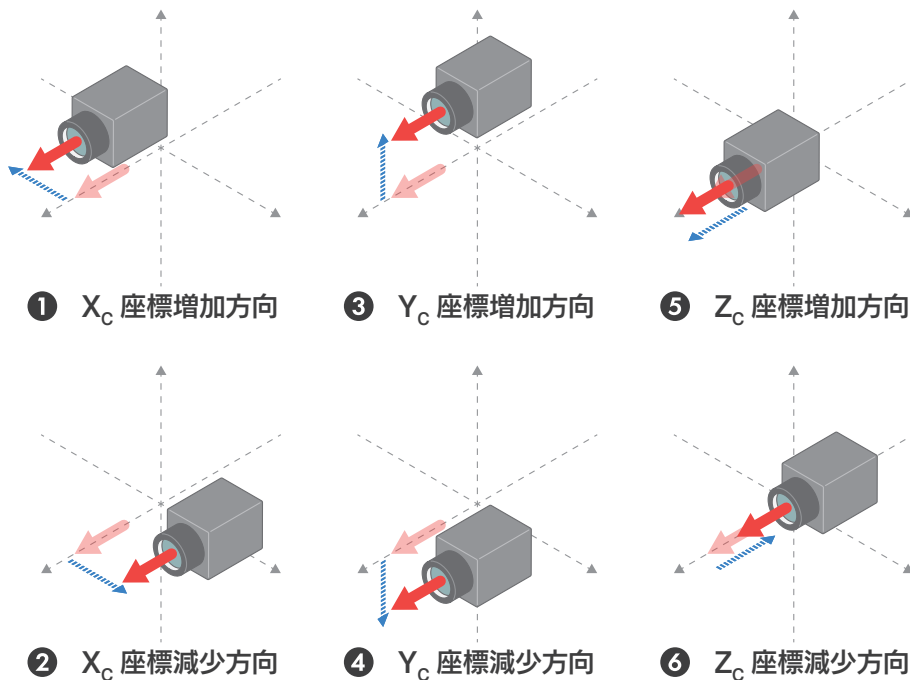


図 4.11: カメラが平行移動する様子

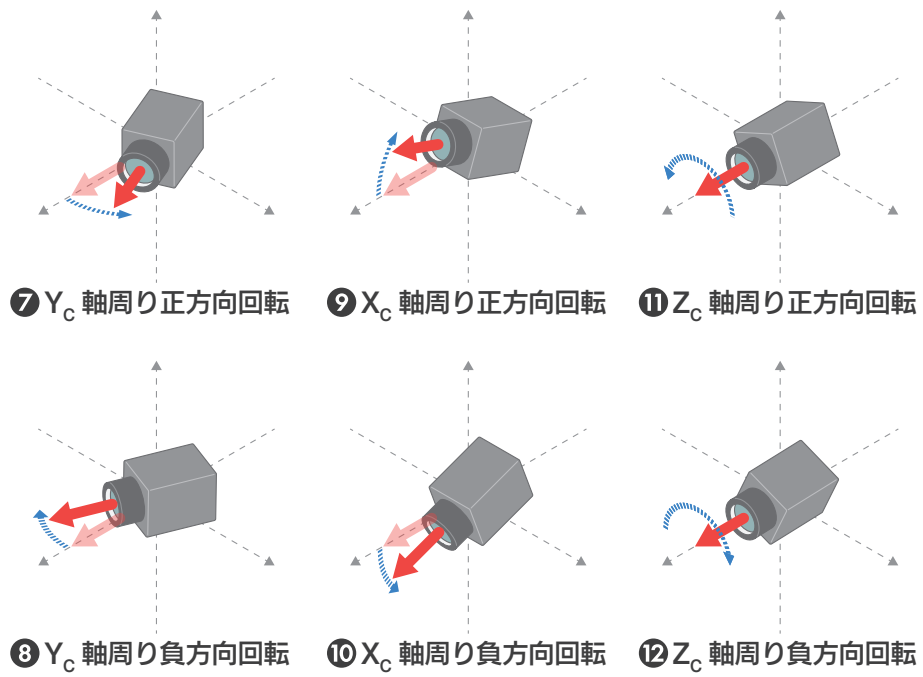


図 4.12: カメラが回転移動する様子

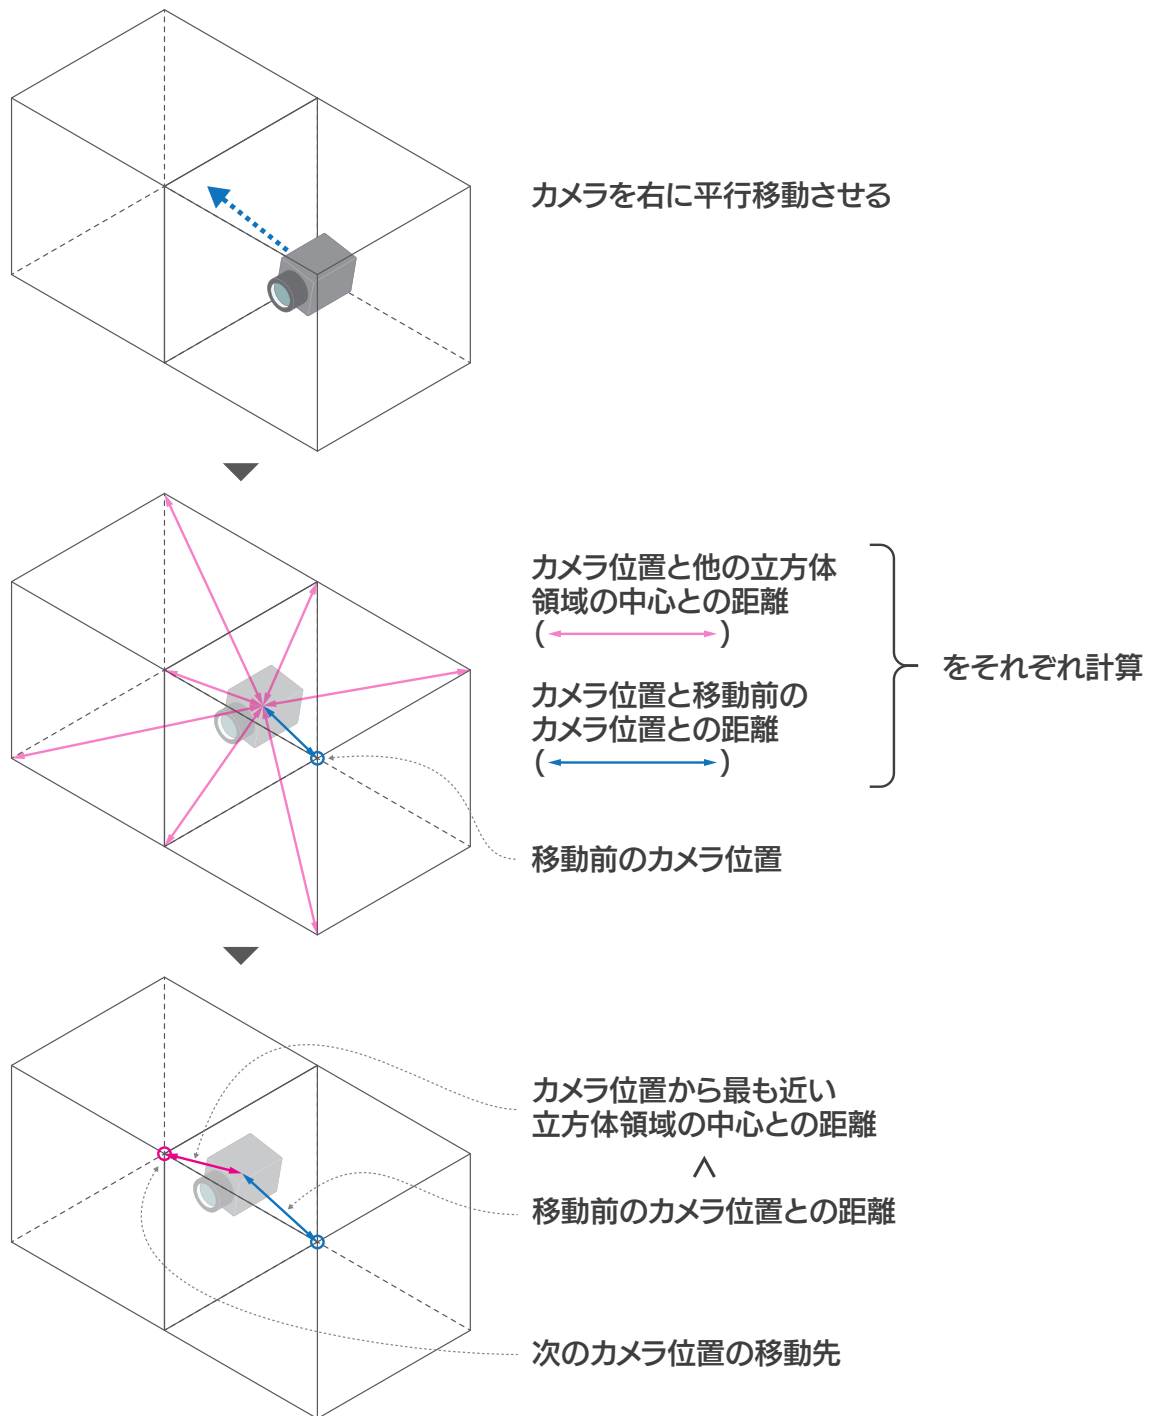


図 4.13: 平行移動先との隣接関係の求め方

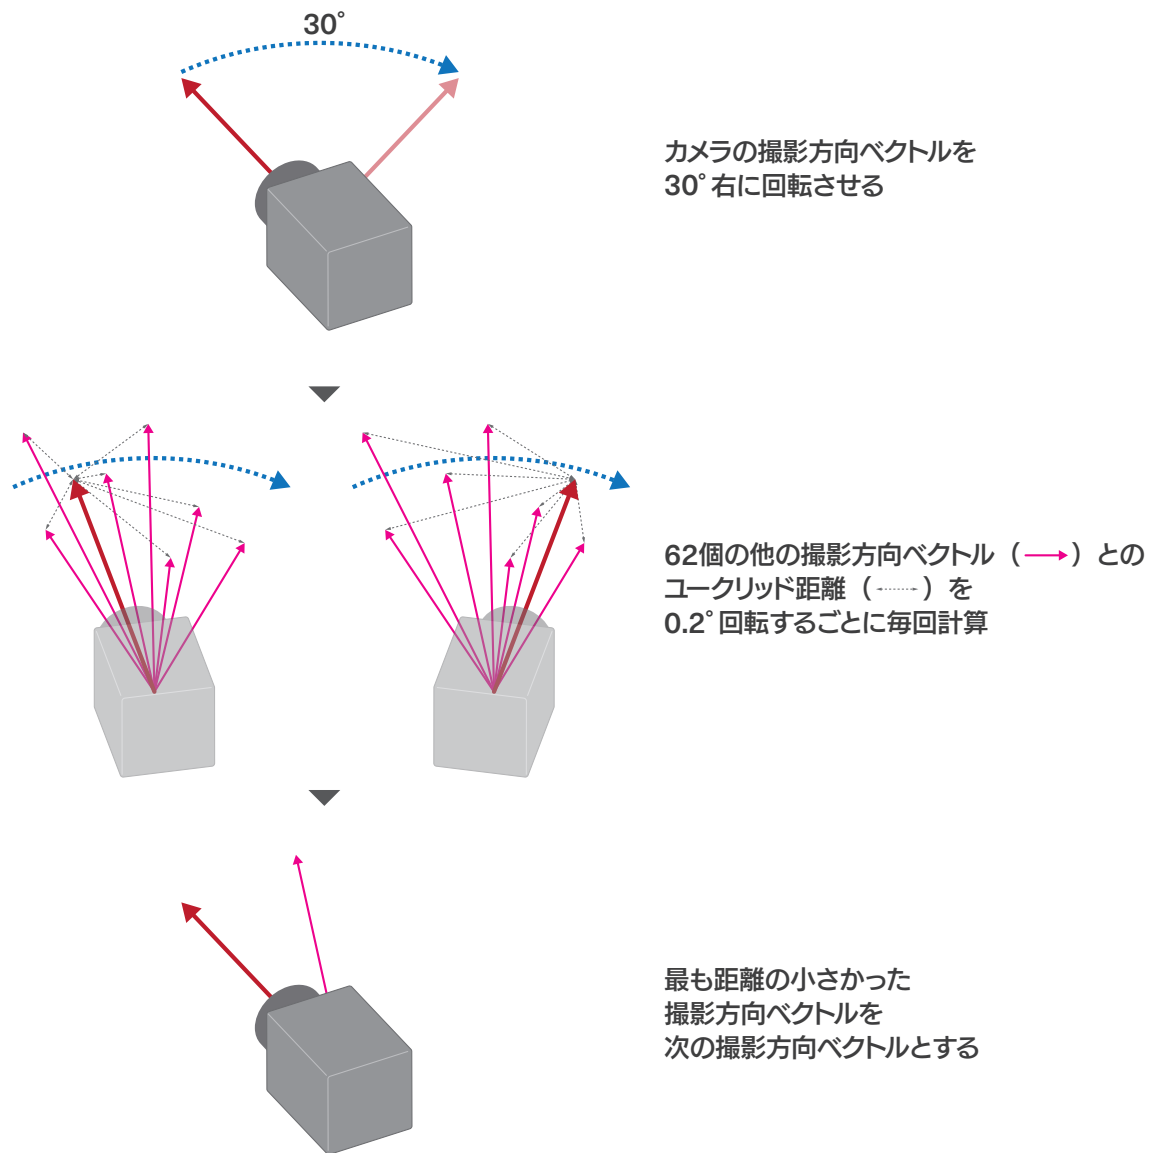


図 4.14: 回転移動先との隣接関係の求め方




図 4.15: 回転平面から 45 度以上離れているものを除外する様子

θ : 回転角度
 V_m : 最も近い撮影方向ベクトル
 D_m : 最も近い撮影方向ベクトルとの距離

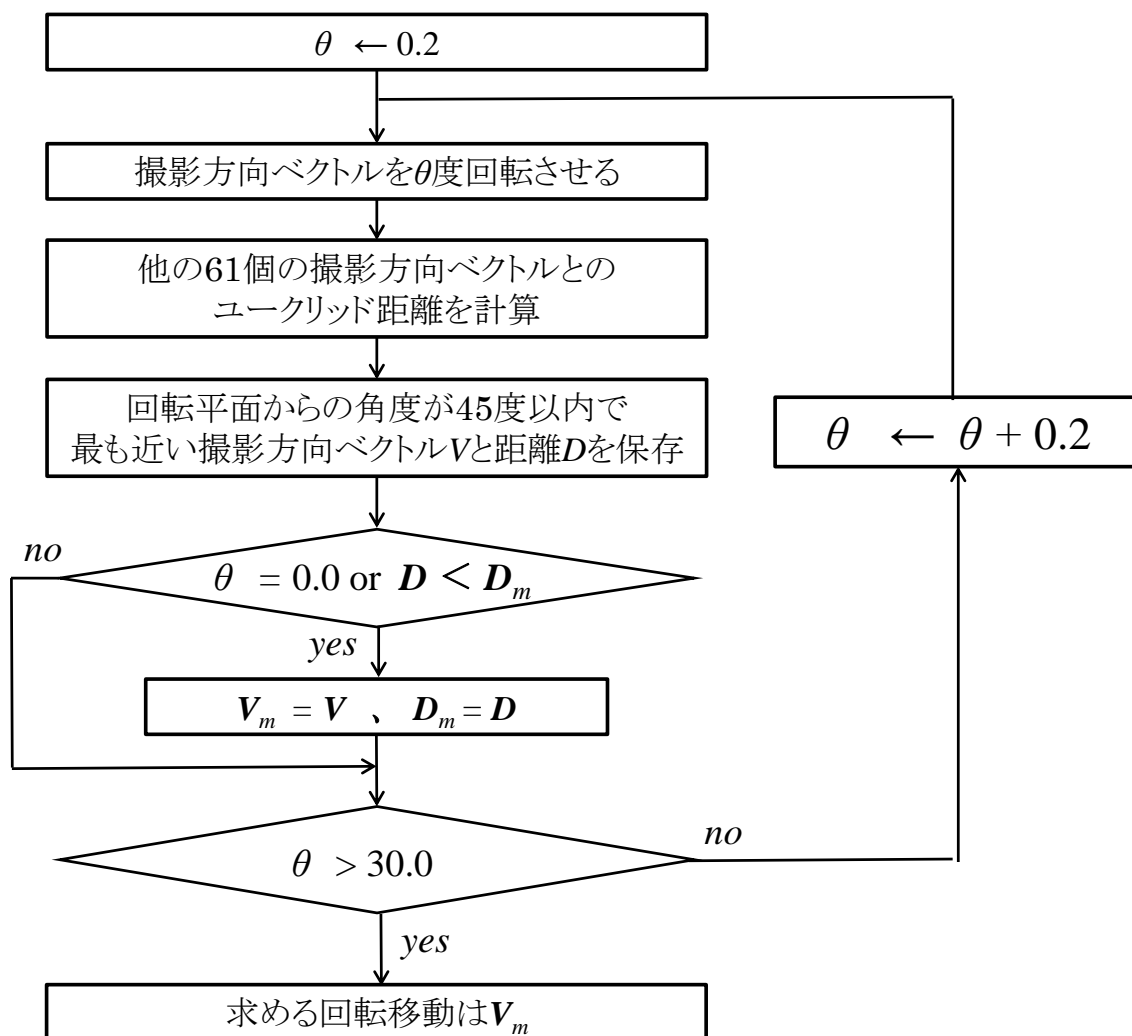


図 4.16: 回転移動先との隣接関係の関係を求める際の流れ

隣接関係の求め方を図 4.13、図 4.14 に示す。具体的にはある姿勢から右に平行移動した際に得られる姿勢を求めるためには、まず X_c 軸方向の座標が増加する方向へ徐々に移動させる。方向を維持したまま移動距離を徐々に増やすと、移動後のカメラ位置が移動前のカメラ位置よりも他の立方体領域の中心座標に近くなる。その立方体領域の中心座標を、ある姿勢から右に平行移動した場合の位置とする。この作業を平行移動の 6 パターンに対して行うことで、ある姿勢から平行移動した場合に得られる姿勢を求めることができる。

回転に関しても同様に、ある姿勢から右に回転移動した場合に得られる姿勢を求め

るために、 Y_c 軸を回転軸とした負方向の微小回転を繰り返して姿勢を徐々に変化させる。処理の流れを図 4.16 に示す。回転角度を定め、回転前のカメラの撮影方向ベクトルを、 Y_c 軸を回転軸として負方向に回転させることで、右向きに回転した際のベクトルを求める。回転後のベクトルと、全 62 個の撮影方向ベクトルから回転前の撮影方向ベクトルを除いた他の 61 個の撮影方向ベクトルとのユークリッド距離を計算する。回転角度を 0.2 度から 30 度まで 0.2 度刻みで変化させながらこの処理を繰り返し、最も距離の小さい撮影方向ベクトルを、ある姿勢から右に回転移動した場合に得られる撮影方向ベクトルとする。なお、図 4.15 回転平面から上下方向に 45 度以上離れている撮影方向ベクトルは、想定する移動先から大きく離れた移動先であるとして除外する。また、ロール方向に回転した際の姿勢は、 Z_c 軸を回転軸として回転させた場合の姿勢として求める。

4.3.2 項で詳細を述べるが、撮影経路を決定する際には姿勢から 12 パターンの移動をした際に得られる外見的特徴ベクトルを用いる。そのためデータベースを構築する際に、上述のようにして隣接関係を求めておくことで、ある姿勢から 12 パターンの移動をした先の姿勢と組になっている外見的特徴ベクトルを求められるようにしておく。

なお本研究では、データベースの構築に原子力プラントの 3D CAD モデルを用いるが、3D CAD モデルは現場を完全に再現しておらず、3 章での物体分類も完全ではないため、後述のカメラの位置方向を特定するアルゴリズムでは誤差が含まれることを考慮する必要がある。

4.3 撮影経路決定手法の詳細

本節では、撮影経路を決定する手法の詳細を述べる。まず、外見的特徴ベクトルを用いて初めの入力画像が撮影された姿勢の候補を絞り込む処理について述べ、次に入力画像を用いて次の撮影姿勢を決定するアルゴリズムについて述べる。

4.3.1 外見的特徴ベクトルを用いた現在姿勢の絞り込み

入力された画像を元に現在のカメラの姿勢を絞り込むための処理の流れを図 4.17 に示す。以下ではその具体的な方法について述べ、次に候補の絞り込みに使用する追加の情報を得るための撮影方向を決定するアルゴリズムについて述べる。4.2.1 項で述べたように、本節で述べる手法では画像から生成する外見的特徴ベクトルにある程度の誤差が含まれることを許容する必要がある。

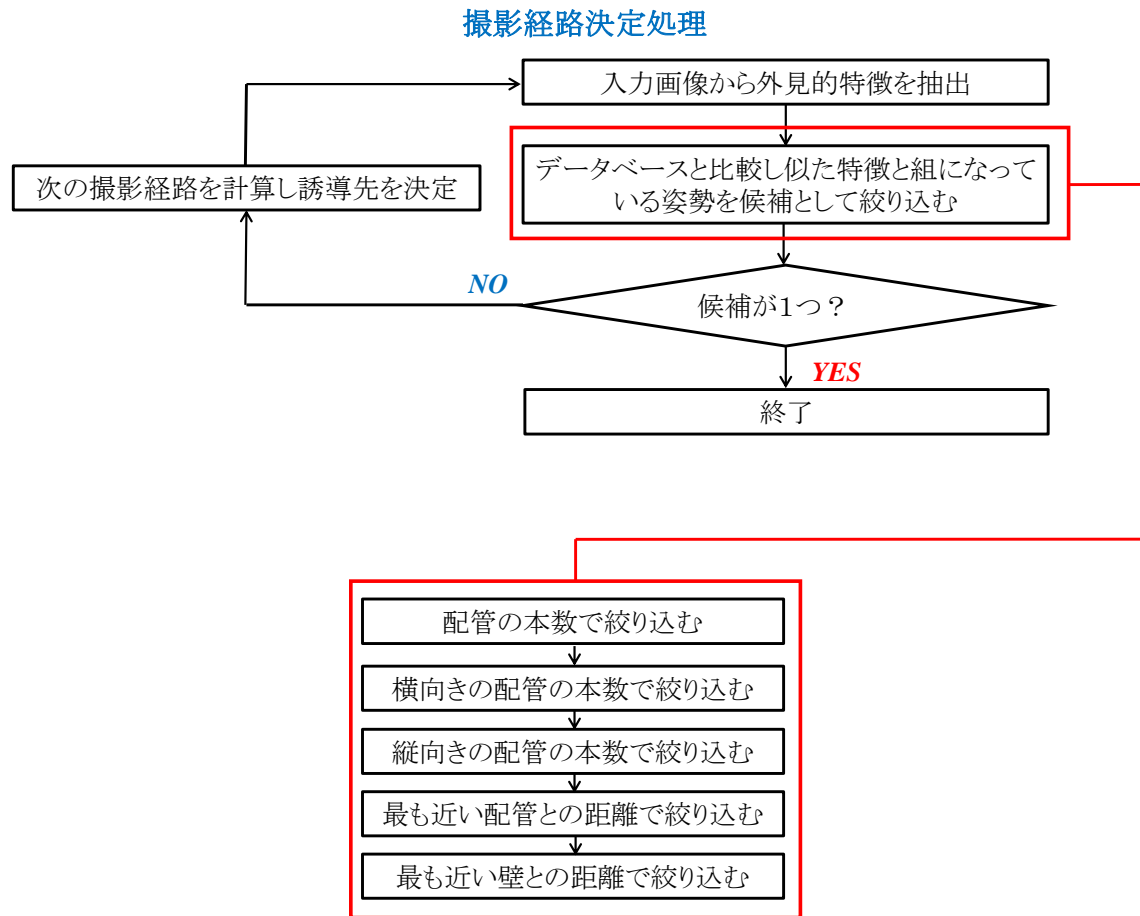


図 4.17: 実行時の処理の流れ

まず、1枚目の入力画像からデータベース構築時と同様に外見的特徴ベクトルを生成し、図 4.18 のように、生成した外見的特徴ベクトルのそれぞれの要素をデータベース内の全ての外見的特徴ベクトルと比較する。比較の際には、外見的特徴ベクトルの5要素に対してあらかじめ許容する誤差を定め、入力画像から生成した外見的特徴ベクトルの5要素との差が全て誤差の範囲内に収まるものを候補として残す。適切な誤差の範囲設定に関しては4.4節で検討する。原子力プラント内部は外見の似た場所が多い上に、3章で述べた様に正確に配管の本数などを認識することが困難なため、誤差の範囲を大きくせざるを得ず、1回の絞り込みでは多くの候補が残る。そこで、図 4.19 のように追加で得た新たな入力画像を用いて再び絞り込みを実行して、候補が1つになれば、初めに撮影された入力画像が撮影されたカメラの姿勢が特定できたとし、処理を終了する。

外見的特徴ベクトル

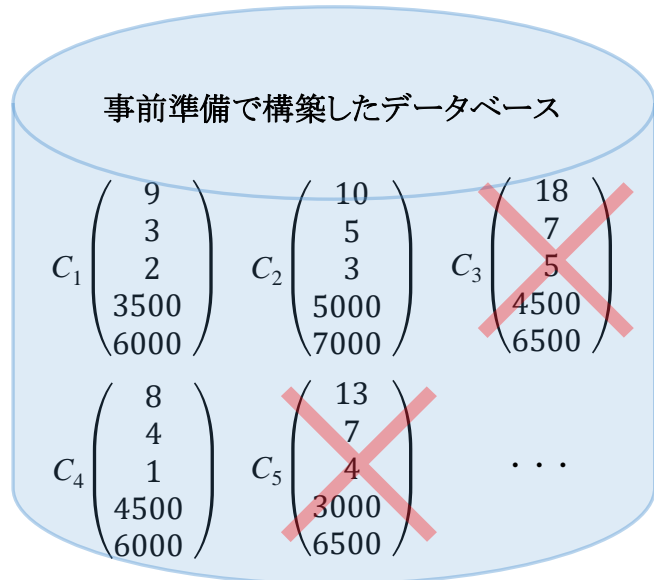
$$\begin{pmatrix} \text{配管の本数} \\ \text{横方向の配管の本数} \\ \text{縦方向の配管の本数} \\ \text{最も近い配管との距離[mm]} \\ \text{最も近い壁との距離 [mm]} \end{pmatrix}$$

$$\text{許容する誤差} = \begin{pmatrix} \pm 5 \\ \pm 3 \\ \pm 3 \\ \pm 1000 \\ \pm 1000 \end{pmatrix}$$

入力画像から生成した
外見的特徴ベクトル

$$I_1 \begin{pmatrix} 10 \\ 5 \\ 3 \\ 5000 \\ 7000 \end{pmatrix}$$

比較



1つでも誤差の範囲外なら候補から除外

図 4.18: データベースとの比較方法

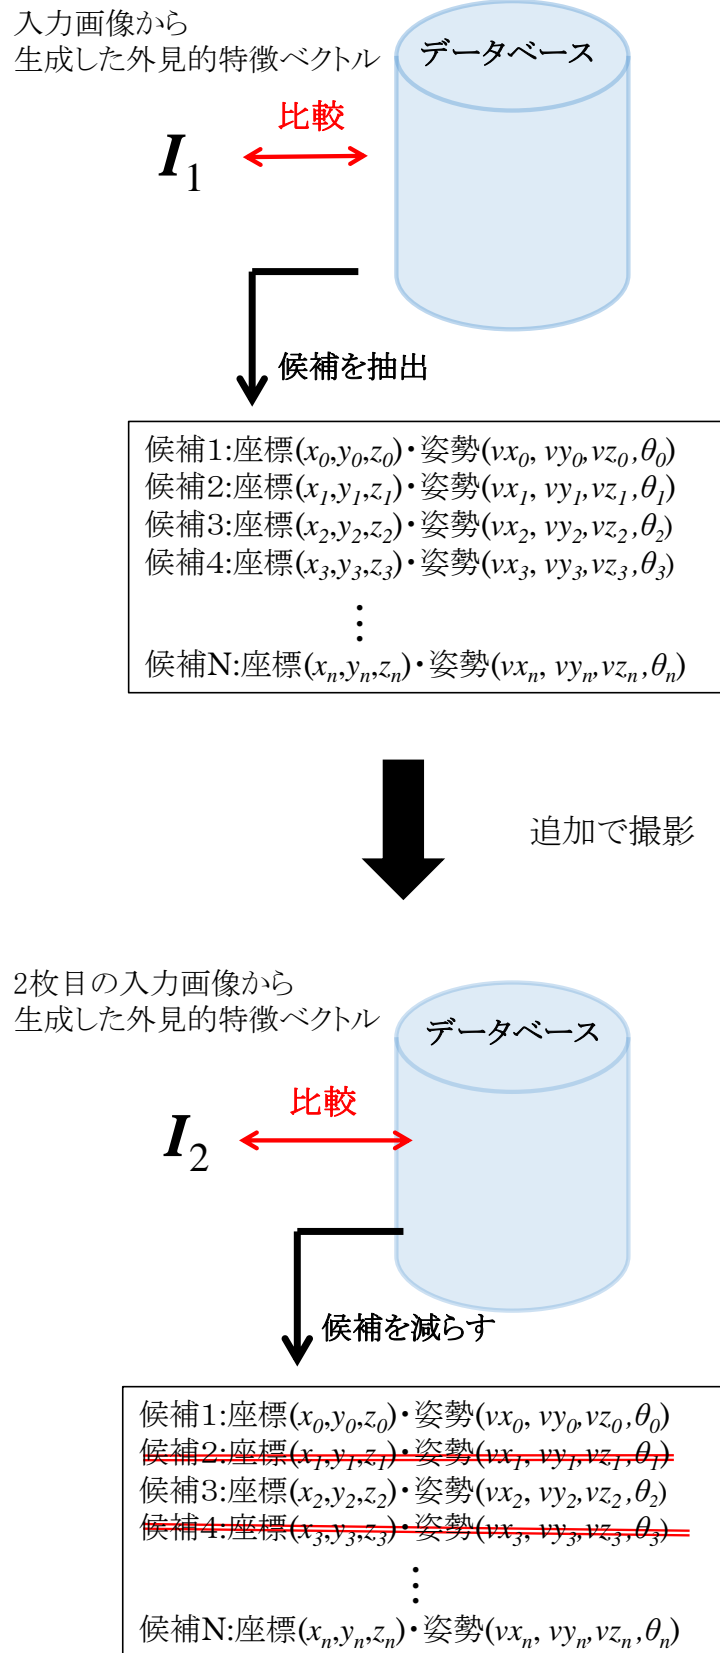


図 4.19: 追加の撮影による候補の絞り込みの様子

4.3.2 誘導先の決定方法

本項では追加の情報を得るための撮影を行う際に、より効果的な撮影方向を決定するアルゴリズムについて述べる。本研究では、Shannon が 1948 年に考案した情報エントロピー（平均情報量）^[24] を指標として撮影方向を決定する。情報エントロピーの考え方では A という事象が起こる確率を $P(A)$ したとき、事象 A が持つ情報量 $i(A)$ は

$$i(A) = -\log_2 P(A) \quad (4.1)$$

であると定義する。 $P(A)$ の値が小さい、つまり事象 A が起こりにくいほど情報量は大きな値になる。ここで N 個の独立な事象を持つ確率分布 X から得られる平均情報量 $E(X)$ は、それぞれの起こる確率を $p_i (i = 1, 2, 3, \dots, n)$ とすると

$$E(X) = -\sum_{i=1}^n p_i \log_2(p_i) \quad (4.2)$$

与えられる。平均情報量は全ての事象の起こる確率が等しい時に最大値を取り、確率分布に偏りがあるほど小さな値を取る。


本研究ではある姿勢から 4.3.2 項で述べた 12 パターンの移動方向全てに対して、そちらの方向に移動して新たに画像を取得した際に得られる情報エントロピーを計算し、得られる情報エントロピーが最大となる方向を誘導先とする。

右に平行移動した場合の情報エントロピーの計算方法を説明する。まず図 4.20 に示すように誘導先を決定する時点で残っている候補全てに対して、データベースに含まれる隣接関係の情報を利用して、右に平行移動した場合の外見的特徴ベクトルを求め全て列挙する。次にこれらの外見的特徴ベクトルを図 4.21 に示す方法で複数の組にグルーピングする。具体的にはまず候補として残っている外見的特徴ベクトルのうち、1 つ目の外見的特徴ベクトルをグループ 1 にグルーピングする。次に 2 番目以降の外見的特徴ベクトルと各グループの先頭の外見的特徴ベクトルの間の類似度を計算し、その値が閾値以上の場合には同じグループに追加し、そうでない場合は新たなグループを作成し、作成したグループの先頭の要素とする。類似度の計算にはコサイン類似度^[23]を用いる。2 つのベクトル \vec{p} と \vec{q} のコサイン類似度 $\cos(\vec{p}, \vec{q})$ は次式で定義される。

$$\cos(\vec{p}, \vec{q}) = \frac{\vec{p} \cdot \vec{q}}{|\vec{p}| |\vec{q}|} \quad (4.3)$$

2 つのベクトルが類似していると判定するしきい値については、グループ数が 10 前後にするために、本研究では 0.5 とした。なお、様々なグループ数を試行した結果、10 グ

ループ程度とする場合が最も効率的に撮影先を決定できる結果となったため、本研究ではグループ数を10とした。以上のようにして作成した各グループの要素数を全候補の総数で割ることによって、右に平行移動した場合にそのグループに含まれる外見的特徴ベクトルを得る確率を求めることができる。この確率をもとに情報エントロピーを計算する。この計算を12パターンの移動方向全てに対して行い、情報エントロピーが最大となる方向を次の撮影方向とする。なお、過去に撮影した場所を再び撮影する移動は、新たな情報が得られないことが自明であるため情報エントロピーは0とする。



右に平行移動する際の情報エントロピー E_I

$$E_I = -\frac{n_1}{N} \log_2 \frac{n_1}{N} - \dots - \frac{n_m}{N} \log_2 \frac{n_m}{N} = -\sum_{i=1}^m \frac{n_i}{N} \log_2 \frac{n_i}{N}$$

➡ 全12パターンの移動方向について計算する

図 4.20: 情報エントロピーの計算方法

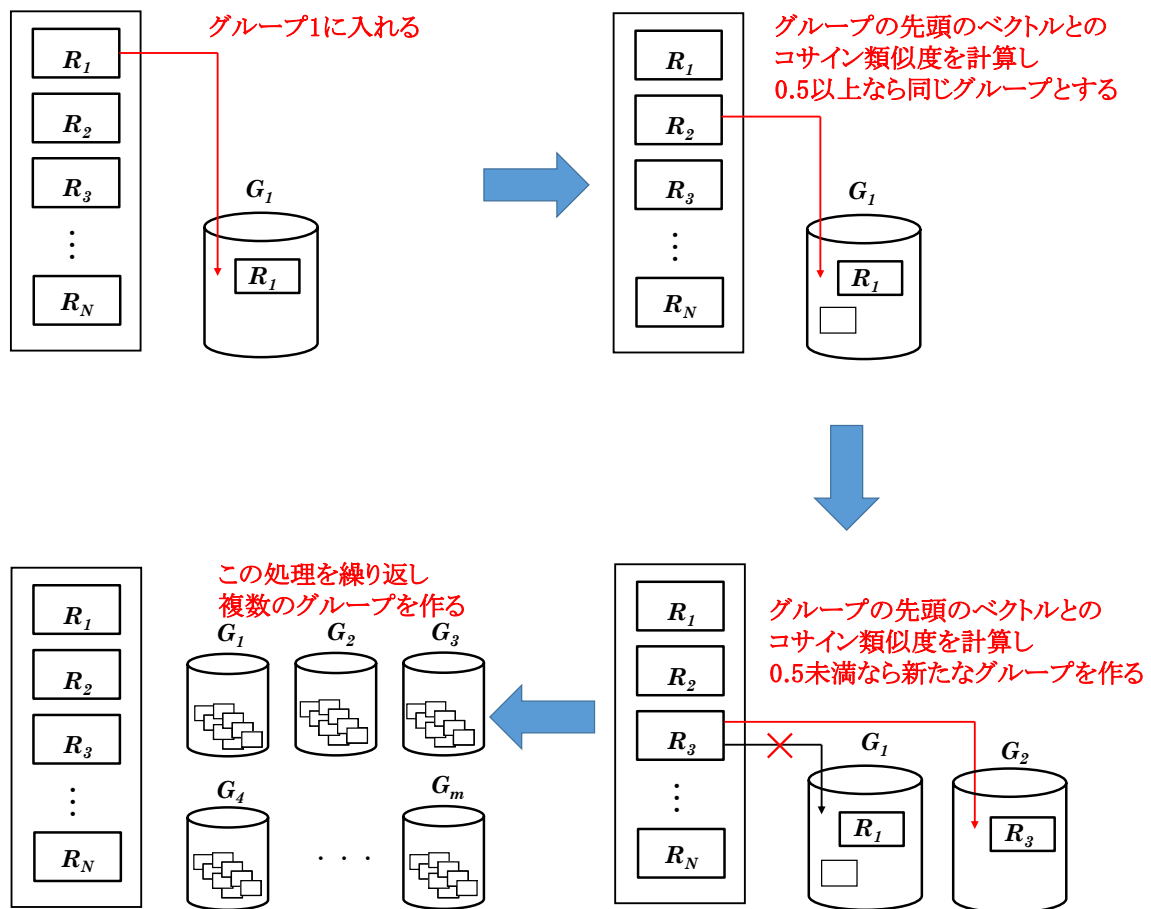


図 4.21: グルーピングの方法

4.4 撮影経路決定手法の性能評価

本節では考案した情報エントロピーを利用した撮影経路決定手法（以下、エントロピー利用手法）の性能評価について述べる。まず評価の目的について述べ、その後、評価の方法について述べる。次に現在姿勢の絞り込み処理を行う際の各種パラメータの適切な値について述べ、最後にエントロピー利用手法を他の撮影経路決定手法と比較した結果について述べる。

4.4.1 評価の目的

本評価では、ユーザがランダムにカメラを動かした場合と比較して、エントロピー利用手法に従ってカメラを動かした場合に、少ない撮影回数でカメラの姿勢を特定できるかを検証することを目的とした。

4.4.2 評価の概要

本研究では新型コロナウイルス感染拡大防止のため原子力プラントへの訪問が困難であったため、新型転換炉ふげん発電所での使用を想定したシミュレーションにより性能評価を行った。評価の流れを図 4.23 に、概念図を図 4.22 に示す。まずふげん発電所の 3D CAD モデルを用いてデータベースを構築した。その際、表 4.1 に示す範囲内を立方体領域に分割し、各領域の中心にカメラを設置したときの配管や壁の映り方を計算によって求めることで外見的特徴ベクトルを生成した。なお表 4.1 に示す各座標の単位は mm である。この際、カメラの焦点距離は 525 mm、光学中心は (320, 240) を想定した。次に空間内から無作為に抽出したカメラの姿勢から生成した外見的特徴ベクトルを、1 枚目の入力画像から生成した外見的特徴ベクトルと想定し、姿勢の特定のための絞り込み処理を複数回行い、姿勢の候補が 1 つになれば処理を終了とした。最後に候補として残った姿勢が、初めに無作為に抽出された姿勢と同じであれば成功とし、そうでなければ失敗とした。

空間から無作為に姿勢、外見的特徴ベクトルを抽出

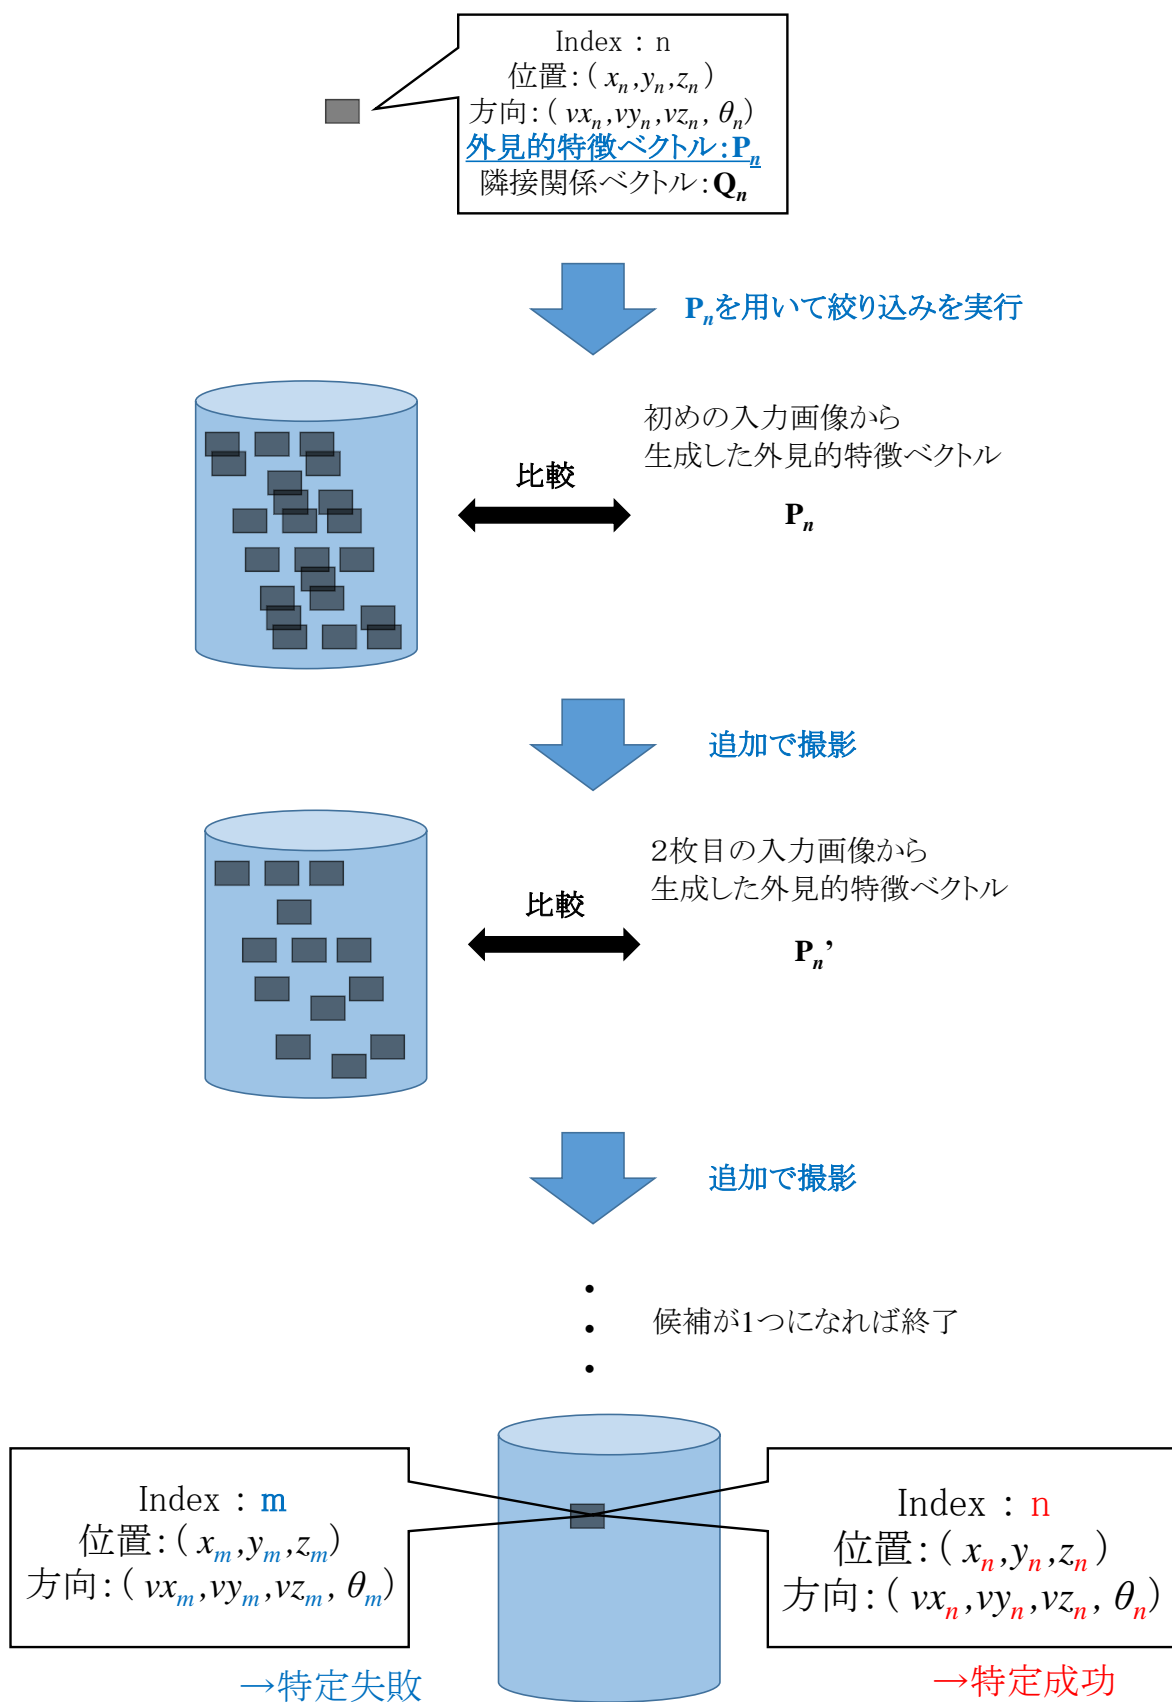


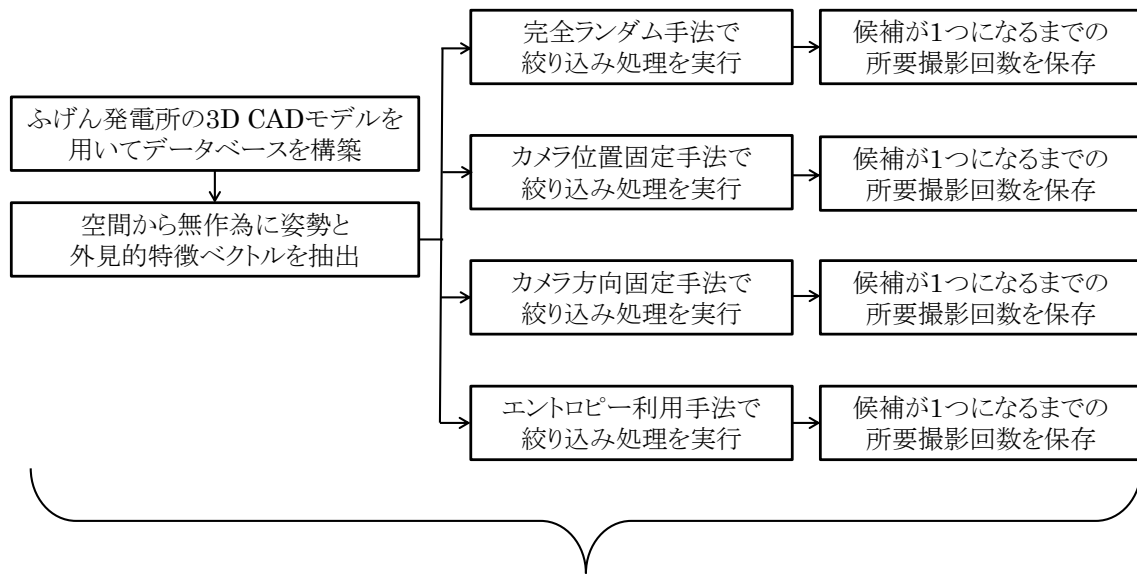
図 4.22: 性能評価の概要

表 4.1: データベースの構築に用いたふげん発電所の 3D CAD モデルの範囲

方向	幅
x 軸方向	20000
y 軸方向	200000
z 軸方向	50000

4.4.3 評価の詳細

評価の流れを図 4.23 に示す。本評価では、絞り込み処理における撮影経路の決定方法を複数パターン設定し、本研究で提案するエントロピー利用手法と性能を比較した。具体的には、ユーザが適当に次の撮影姿勢を決定する状況を想定して、全 12 パターンの撮影姿勢からランダムに次の撮影姿勢を決定する方法（ランダム手法）、ユーザが初めの位置から移動せずカメラを様々な方向に向ける状況を想定して回転移動の 6 パターンからランダムで次の撮影方向を決定する方法（カメラ位置固定手法）、ユーザがカメラの撮影方向を変えずに歩き回る状況を想定して平行移動の 6 パターンからランダムで次の撮影位置を決定する方法（カメラ方向固定手法）の 3 つの決定方法を設定した。評価指標には特定終了に必要な撮影回数、各手法での次の撮影姿勢の決定に必要な平均処理時間を用いた。各手法でランダムに初期姿勢を設定して特定するまでの処理を 1000 回繰り返し、評価指標の平均値を算出することで性能を比較した。4.4.4 節では、データベース構築時の立方体領域の一辺の長さの適切な値と、入力画像の外見的特徴ベクトルをデータベース内のデータと比較し候補を絞り込む際に許容する誤差の適切な範囲設定について述べる。4.4.5 節では様々な撮影経路決定方法を用いて絞り込み処理を行うことで、エントロピー利用手法の性能を評価した結果について述べる。



1000回実行し、各手法ごとの所要撮影回数の平均値を算出

図 4.23: 性能評価の流れ

4.4.4 各種パラメータの調整

本項では、各種パラメータを変化させながら絞り込み処理を行った結果と、各種パラメータの適切な値について述べる。分割する立方体領域の1辺の長さは $L=250\text{ mm}$ 、 $L=500\text{ mm}$ 、 $L=1000\text{ mm}$ の3パターンとした。また比較の際に許容する誤差のパターンについては、表 4.2 のようにパターン1からパターン6にかけて、許容する誤差範囲が徐々に大きくなるように設定した。

エントロピー利用手法で絞り込み処理を実行する際の立方体領域の一辺の長さ L 、および許容誤差パターンと平均撮影回数との関係を図 4.24、図 4.25 に示す。

表 4.2: 性能評価に用いた誤差のパターン

パターン	配管の本数	横向きの配管の本数	縦向きの配管の本数	最も近い配管との距離 [mm]	最も近い壁との距離 [mm]
1	±7	±4	±4	±1500	±1500
2	±8	±5	±5	±2000	±2000
3	±9	±6	±6	±2500	±2500
4	±10	±7	±7	±3000	±3000
5	±11	±8	±8	±3500	±3500
6	±12	±9	±9	±4000	±4000




図 4.24: エントロピー利用手法における平均撮影回数と L の関係




図 4.25: エントロピー利用手法における平均撮影回数と許容する誤差の関係

Lが小さいとデータベースを構築する際に分割が細くなるため、入力画像を用いて候補を絞り込む際に残る候補が多くなる。したがって、姿勢の候補が1つになるまでに必要な撮影回数が多くなる。また許容誤差パターンについては、許容誤差範囲を広げるほど外見的特徴ベクトルをデータベースと比較する際に多く候補が残るため、誤って正しい姿勢の候補を除外してしまう可能性は低くなるが所要撮影回数は多くなる。図

4.24に示すように、 $L=250\text{mm}$ とした時は、正しい姿勢の候補を除外してしまう可能性を低くするために誤差の許容範囲を広くすると撮影回数が多くなる。本手法では人が1枚ずつ画像を撮影するたびに絞り込みを実行するため、目前の機器が正しいものか確認するために、周辺の撮影を20回以上必要とする手法は手間がかかり非現実的である。また $L=1000\text{mm}$ とすると、所要撮影回数が少なくなるが最終的な姿勢特定の精度が落ちる。また、特に誤差の許容範囲を広くした際に、 $L=250\text{mm}$ とした時と $L=500\text{mm}$ とした時の平均撮影回数を比較すると半分近くまで減っているが、 $L=500\text{mm}$ とした時と $L=1000\text{mm}$ とした時を比較すると減少率は減っていることが分かる。つまり、立方体領域への分割を粗くしたことによる、所要撮影回数の減少の幅が小さくなっていることがわかる。 $L=500\text{mm}$ とすると、50cm単位で位置を特定することができる。プラント内部で50cm移動しても目前の機器が変わる可能性は低い。以上の理由から、カメラの姿勢の特定までの確実性、迅速性を考慮して本手法での立方体領域の一辺の長さは500mmが適切であると考えられる。

一方、誤差の許容範囲は図4.25に示すように、許容誤差パターン1から3にかけては所要撮影回数が大幅に増加しておらず、許容誤差パターン4以上に誤差の許容範囲を広くすると、平均撮影回数が大幅に増加していることがわかる。撮影回数に注目すると、許容する誤差範囲の最も狭いパターン1が少なくなっているが、許容する誤差の範囲を狭くすると、正しいカメラ姿勢の候補を誤って除外してしまい、誤ったカメラ姿勢を最終結果として残してしまう恐れがある。表4.2に示すように許容誤差パターン3では、配管の本数の誤認識を9本以内、最も近い配管、および壁との距離の誤認識を2500mmとしている。3章の結果より配管の誤認識が10本以上になることは少なく、実用の際に想定するRGB-Dカメラでは2.5m以上デプス値を誤って認識することも少ないことから、本手法では許容誤差パターン3の誤差範囲が適切であると考えられる。

4.4.5 評価の結果と考察

本項ではエントロピー利用手法の性能評価のために、他の撮影経路決定方法と比較した結果とその考察について述べる。なお、本評価はシミュレーションにより行ったため、いずれの方法を用いた場合でも最後に残った候補は初めに無作為に抽出された姿勢と一致しており特定に失敗することはなかった。しかし、現場で使用する際には画像を認識し外見的特徴ベクトルを抽出する際に誤差が含まれる可能性があるため、その誤差を考慮した上で確実な特定をできる手法にする必要がある。各誘導先決定手法での絞り込み処理に必要な平均撮影回数、および1000回シミュレーションを実行した

際に最も多い撮影を要したときの回数を図 4.26、図 4.27 に示す。




図 4.26: 手法別の平均撮影回数




図 4.27: 手法別の最多撮影回数

図 4.26 が示すように、エントロピー利用手法が最も少ない撮影回数で姿勢の候補を 1 つまで絞り込むことができることがわかった。また、図 4.27 が示すように、カメラ方向固定手法が最も平均撮影回数が多く、特に $L=250$ mm の時はエントロピー利用手法よりも 5 倍近くの回数を要している。これはカメラを動かして追加の撮影をする際、同じ位置からカメラの方向を変える場合に比べて、カメラの方向を変えずに平行移動する場合はもとの画像と追加で撮影した画像の変化が小さく、新たな情報を得づらかったためと考えられる。

最後に各決定手法の、候補が列挙されてから次の撮影方向を決定するまでに必要な平均処理時間を表 4.3 に示す。シミュレーションを行った PC の使用をと開発環境を表 4.4 に示す。平均処理時間が最長であるエントロピー利用手法でも平均 12 ms で次の撮影方向を決定でき、実用的な速度で処理できることがわかった。

表 4.3: 撮影方向を決定するまでの平均処理時間

手法	平均処理時間 [ms]
エントロピー利用手法	12.62
ランダム手法	3.32
カメラ位置固定手法	3.49
カメラ方向固定手法	2.62

表 4.4: シミュレーションに用いた PC の仕様と使用した開発環境

OS	Windows 10 Pro 64bit
CPU	Intel(R)Core(TM) i7-7700HQ(2.80GHz)
GPU	NVIDIA GeForce GTX 1060
RAM	16GB
開発環境	Visual Studio 2019
開発言語	C++

第 5 章 結論

原子力発電プラントでの保守・点検・解体作業を効率よく行うためには、目の機器が目的とする作業対象であるかを迅速かつ確実に特定する必要がある。そこで、機器・設備とその周辺を撮影した複数の画像を用いて現在地を特定する際に、効率的な撮影を実現するための支援手法を想定し、その際に必要な手法として本研究では、プラント内部を撮影した画像から、配管や壁、タンクなどの物体を認識し外見的特徴を抽出する手法と、抽出した外見的特徴を用いて迅速かつ確実に現在地を特定するための撮影経路決定手法の提案を目的とした。

まず、機械学習を用いてプラント画像内の配管、壁、床、タンクの4つの物体を分類し、分類結果を用いて配管の本数を認識した。プラントの実画像とそれらのラベル付け画像を作成し、転移学習を用いて学習済みの分類モデルを再学習させ、新たな分類モデルを作成することで画像内の物体を分類した。物体同士の境界線が明確になっている画像に対しては、今回の方法で物体が分類できることがわかった。しかし、配管が重なり合っている画像や、物体が入り組んでいて物体同士の境界線が明確でない画像に対する分類の精度は低かった。今回はふげん発電所の画像のみを用いたが、他のプラントや配管、タンクなどの画像を追加し学習画像を増やすことでより高い精度で物体を分類できる可能性がある。次に分類結果を用いて配管の本数を認識した結果、誤差が含まれるものの、分類結果から今回用いた配管認識の方法で配管の本数を認識できることもわかった。しかし、物体分類の段階では配管と分類されても、配管の一部が画面から見切れて画像に写る配管長が短く、本数認識の際に配管と認識されていないことや、実画像上では2本の配管が平行に並んでいるにも関わらず1本の太い配管と認識されることもあった。そのため、物体分類の精度を向上させた上で、配管の本数を認識する際の誤認識を減らせるアルゴリズムを設計して、より正確に配管の本数を認識する必要がある。

次にカメラで複数回機器・設備を撮影して得た画像から抽出した外見的特徴を用いて現在地を特定する際に、画像内の物体の認識の際の誤差が含まれた上でも、迅速かつ確実に特定につながる撮影経路を決定できる手法を提案し、その性能評価を行った。本研究では、事前に原子力発電プラントの3D CADモデルを用いてデータベースを構築し、現在地の候補の絞り込みに用いた。撮影経路の決定には情報エントロピーを指

標とし、人のカメラの動かし方を模擬した撮影経路決定手法と比較するための性能評価をシミュレーションで行ったところ、情報エントロピーを指標として撮影経路を決定する手法が最も少ない撮影回数で現在地を特定することができ、今回開発した撮影経路決定手法が有用であることがわかった。

本研究で行った性能評価は、シミュレーションにより行ったものであり、実際の現場には適用していない。そのため、実際の原子力発電プラントの環境で、3章で述べた物体認識の結果を用いて現在地を特定できるかという検証はできていない。したがって、現場で撮影した画像を用いた現在地特定の際に、本研究で提案した撮影経路決定手法が有用であるかの検証は今後の課題とする。

謝 辞

本研究は、様々な方のご協力のおかげで進めることができました。

研究生活において、研究会やミーティングでご指導頂いた下田宏教授に心より感謝いたします。研究以外のお話も学ぶことも多く、他学科からこの研究室に来て本当に良かったと思えました。進学を悩んでいる後輩がいたらぜひおすすめしようと思います。

毎週のミーティング、研究会などで数えきれないほどサポートしてくださった石井裕剛准教授に心より感謝いたします。熱心で丁寧なご指導のおかげで、入学当初プログラミングに関する知識が全くなかった自分がここまで研究を続けることができました。時には厳しい言葉も頂きましたが、全てが自分の成長に繋がりました。

在学中、様々な面でご支援をいただいた普照郁美秘書に深く感謝申し上げます。就職活動で自分が悩んでいた時に明るく話しかけてくださって、とても励みになりました。

毎回ミーティングに参加していただき、様々な助言をいただき、サポートしてくださったエネルギー情報学研究室の博士課程2回生の原園友規さんに深く感謝申し上げます。生意気で理解の遅い後輩でしたが、手厚く面倒を見てくださったおかげで、研究を進めることができました。

また、論文の執筆にあたって何度も文章の添削や、図表作成の相談に乗っていただいたエネルギー情報学研究室1回生の魚谷拓未君、湯村航平君に深く感謝いたします。拙い文章をチェックしていただき、まともな形に仕上げることができました。

研究のみならず、普段の生活を充実したものにしてくださった同級生の坂本佳樹君、坂本龍平君、高島由妃さん、宮崎大輔君、Xue Dingming 君に感謝します。皆様のおかげで非常に楽しい2年間を過ごすことができました。

また、コロナウイルスの影響で会う機会が少なくなりましたが、共に研究室生活を送ったエネルギー情報学研究室の博士課程3回生の上田樹美さん、修士1回生の山脇瑞記さん、山本理恵子さん、Liu Dongliang 君、工学部電気電子工学科4回生の浅場涉君、北山翔君、村山真大君に感謝します。

京都大学での6年間は楽しい思い出ばかりで、自分の中でかけがえのない財産になりました。充実した学校生活を送ることができたのは、周囲の友人や家族の支えのおかげです。

最後に、在学中関わったすべての人に心より感謝します。

参考文献

- [1] 経済産業省: 資源エネルギー庁ホームページ,
<http://www.enecho.meti.go.jp/about/whitepaper/2015pdf/>,
Accessed February 8, 2021.
- [2] 電気事業連合会: 国内の原子力発電所の再稼動に向けた対応状況,
<https://www.fepc.or.jp/theme/re-operation/> , Accessed February 8, 2021.
- [3] 国土交通省: 建設業及び建設工事従事者の現状,
<https://www.mlit.go.jp/common/001180947.pdf>, Accessed February 8, 2021.
- [4] Rune Vabo, L. Piotrowski, G. Rindahl: 3D representation of radioisotopic dose rates within nuclear plants for improved radioprotection and plant safety, International Journal of Nuclear Safety and Simulation, **1**(2), pp.127-133 (2010).
- [5] 屋良 朝克, 秋山 征己, 鷹野 孝典, 五百蔵 重典, 田中博: 超音波測位と慣性測位による広域屋内測位のための地図情報提示システムの設計と構築, マルチメディア, 分散, 協調とモバイルシンポジウム, pp.736-741 (2013).
- [6] Hirokazu Kato, Mark Billinghurst: Marker Tracking and HMD Calibration for a Video based Augmented Reality, 2nd IEEE and ACM International Workshop, pp.85-94 (1999).
- [7] Andrew J. Davison, Ian Reid, Nicholas D. Molton, Olivier Stasse: MonoSLAM: Real-Time Single Camera SLAM, IEEE Transactions on Pattern Analysis and Machine Intelligence, **29**(6), pp.1052-1067 (2007) .
- [8] 徳丸 博紀: 線分特徴を用いた絞り込み処理によるリローカリゼーション手法の開発, エネルギー科学研究科, 修士論文 京都大学 (2016).
- [9] 蔵田 武志, 清川 清: AR(拡張現実) 技術の基礎・発展・実践, 科学情報出版株式会社, pp.38-55 (2015).

- [10] Jamie Shotton: Home Page, <http://jamie.shotton.org/work/research.html>, Accessed February 8, 2021.
- [11] Jonathan Long: Fully Convolutional Networks for Semantic Segmentation, *Computer Vision and Pattern Recognition* (2015).
- [12] Olaf Ronneberger, Philipp Fischer, Thomas Brox: U-net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer Assisted Intervention* (2015).
- [13] Hengshuang. Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, Jiaya Jia: Pyramid Scene Parsing Network, *Computer Vision and Pattern Recognition* (2017).
- [14] Liang-Chieh Chen, George Papandreou, Iasonas Kokkinos, Kevin Murphy, Alan L. Yuille: Deeplab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected Crfs, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 99 (2017).
- [15] Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, Hartwig Adam: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, *Computer Vision and Pattern Recognition*, pp.833-851 (2018).
- [16] Dihua Wu, Xuqiang Yin, Bo Jiang, Mei Jiang: Detection of the Respiratory rate of Standing Cows by Combining the Deeplab V3+ Semantic Segmentation Model with the Phase-based Video Magnification Algorithm, *Biosystems Engineering*, 192, pp.72-89 (2020).
- [17] Weishen Yang, Jiangyi Zhang, Kun Hu: Real-time DeepLabv3+ for Pedestrian Segmentation, *Journal of Optical Technology*, **86**(9), pp.570-578 (2019).
- [18] 神寫 敏弘: 転移学習, *人工知能学会誌*, 25(4), pp.572-580 (2010).
- [19] Mark Everingham: Visual Object Classes Challenge 2012 (VOC2012), <http://host.robots.ox.ac.uk/pascal/VOC/voc2012/>, Accessed February 8, 2021.
- [20] Masaki Hirotsu: 転移学習とは何か, <https://medium.com/mhiro2/what-is-transfer-learning-1018d2a3fe7d>, Accessed February 8, 2021.

- [21] Bryan C. Russel, Antonio Torralba, Kevin. P. Murphy, William T. Freeman: Labelme: A Database and Web-based Tool for Image Annotation, *International Journal of Computer Vision*, 77, pp.157-173 (2008).
- [22] 山下製作所: <https://www.yamashita-seisaku.co.jp/business.html>, Accessed February 8, 2021.
- [23] 中村 哲也, 瀧 敬士, 野宮 浩揮, 上原 邦昭: 時系列データの効率的な類似度測定手法, *電子情報通信学会論文誌*, 91(11), pp.2579-2588 (2008).
- [24] Claude E Shannon: *The Mathematical Theory*, Dover Publications, New York, 1949.