

地理情報システムの時空間分解能向上のための
異高度撮影画像間の対応点探索法

2021年 3月

鳥屋 剛毅

地理情報システムの時空間分解能向上のための
異高度撮影画像間の対応点探索法

鳥屋 剛毅

システム情報工学研究科

筑波大学

2021年 3月

概要

衛星や航空機を用いたリモートセンシングによって得られた画像の利活用が防災の分野で一般化している。その中でも、可視光帯域を観測した EO 画像 (Electro-Optical 画像) が広く利用されており、これらは各画素に地理情報が付与され、GIS (地理情報システム) のデータベースで管理される。災害発生直後、被災し変化が生じた箇所を正確かつ迅速に把握するためには、数分～数時間の高時間分解能 (高頻度) の撮影や、数 cm～数十 cm オーダーの高空間分解能の局所領域撮影がされることが望ましいが、現状の GIS の画像データでは時空間分解能が不足するため実現が困難である。そこで本論文では、GIS の EO 画像データに加えて、SAR (合成開口レーダ) の画像や、ドローン・モバイルカメラの画像など、撮影高度の異なる画像群を用いることで GIS の時空間分解能の向上を図る。

変化検出には、2 画像間の幾何的な対応関係の算出処理 (画像レジストレーション処理) により変化前後の画像を重ね合わせ、差分を算出する必要がある。これまでの画像レジストレーション手法としては、機体の位置・姿勢といった画像撮影と同時に計測した情報に基づく手法や、DEM (デジタル標高モデル) を利用するオルソ補正、人手による GCP (Ground Control Point) の選定作業によって幾何対応関係を推定する手法がある。しかし、これらの手法をドローンやモバイルカメラの画像群へ適用するには、GCP 選定のための人的リソースが不足し、機体の揺動や手ぶれによるセンサの計測誤差も影響する。また、災害発生直後の局所的な状況把握への適用を考慮すると、地形が変化し DEM が有効に作用しない場合が考えられる。

本論文では、2 画像の幾何的な対応関係を得るために、両画像中から特徴的な点 (特徴点) を検出し、特徴点マッチング処理により対応する特徴点 (対応点) の探索を行う手法に着目した。EO 画像と SAR 画像の間の対応点探索と、EO 画像と地上撮影画像の間の対応点探索には、それぞれ、(課題 a) 撮影センサの観測波長の違いによる見え方の違いが生じる問題と、(課題 b) 撮影高度の違いによる空間分解能の違いと撮影方向の違いによる射影歪みが生じる問題がある。(課題 a) に対しては、DNN (深層畳み込みニューラルネットワーク) による SAR から EO への画像変換器を用いることで SAR 画像を疑似 EO 画像に変換して見た目を揃え、対応点探索処理を実行する。(課題 b) に対しては、撮影高度・撮影方向の 2 つの問題を分けて解決するために、ドローンにより撮影された低空撮影画像を導入する。低空撮影は、撮影高度が地上数十～百 m 程度で高空間分解能の画像が取得可能であり、撮影方向は鉛直下向きという特徴を持つためいわば EO と地上撮影の中間の性質をもつ撮影形態と見なせる。そのため、この低空撮影画像と、EO 画像・地上撮影画像それぞれの対応点探索を行うことで、最終的に EO 画像と地上撮影画像の幾何的な対応を推定する。

本論文における学術的貢献は、先に挙げた (課題 b) を分割し、最終的に以下の 3 つの課題を解決することと定める。(課題 1) 撮影センサの観測波長の違いによる見え方の差が生じている 2 画像間の対応点探索、(課題 2) 撮影高度の違いによる空間分解能の差が生じている 2 画像間の対応点探索、(課題 3) 撮影方向の違いによる射影歪みが生じている 2 画像間の対応点探索、であ

る。各課題について定量的な実証実験を行い、その有効性を確認した。

また、本論文の提案手法によって、EO・SAR・低空撮影・地上撮影の四つの異高度の撮影形態により得られた実践的な画像群を、一つのシステムに統合し、GISの時空間分解能の向上を実証した。実験場所は埼玉県秩父郡横瀬町の市街地とした。提案する画像ベースの対応点探索手法によって、EO画像とSAR・低空撮影・地上撮影の画像の幾何的な対応関係の算出と、地理情報の自動的な付与が可能となり、従来のGISでは実現できなかった高い時空間分解能を実現可能であることが、本実証実験によって確認された。

目次

第 1 章	序論.....	1
第 2 章	関連研究.....	4
2.1.	屋外撮影の 4 分類	4
2.1.1.	<i>Electro-Optical (EO)</i>	4
2.1.2.	合成開口レーダ (SAR)	5
2.1.3.	低空撮影	6
2.1.4.	地上撮影	6
2.2.	主要な関連技術	6
2.2.1.	対応点探索	6
2.2.2.	敵対的生成ネットワークによる画像のモーダル変換	7
2.3.	本論文で解決を試みる課題に関する従来研究	9
2.3.1.	EO 画像と SAR 画像の幾何的な対応関係推定	9
2.3.2.	EO 画像と低空撮影画像の幾何的な対応関係推定	9
2.3.3.	低空撮影画像と地上撮影画像の幾何的な対応関係推定の従来研究	10
第 3 章	EO 画像と SAR 画像の間の対応点探索	11
3.1.	対応点探索のための深層ニューラルネットワークによる SAR から疑似 EO 画像への画像変換	12
3.2.	条件付き敵対的生成ネットワークによる深層ニューラルネットワークの訓練	13
3.3.	特徴点検出器と特徴量記述子を用いた対応点探索	14
3.4.	誤対応の除去処理	15
3.4.1.	特徴点の輝度勾配方向を指標とした誤対応除去処理	15
3.4.2.	特徴点のスケール比を指標とした誤対応除去処理	16
3.5.	評価実験	18
3.5.1.	実験の目的と評価指標	18
3.5.2.	実験環境	18
3.5.2.1.	CGAN の生成器と識別器のネットワーク構成	18
3.5.2.2.	画像データセット	19
3.5.2.3.	エッジ強調フィルタ	19
3.5.2.4.	プログラムの実装および実行環境	20
3.5.3.	結果と考察	21
第 4 章	EO 画像と低空撮影画像の間の対応点探索	26
4.1.	特徴的な領域の画像超解像による空間分解能の大きく異なる 2 画像間の対応点探索	26

4.2.	局所領域の超解像処理	28
4.3.	空間分解能と対応点探索精度を考慮した縮小処理	29
4.4.	超解像画像と中間空間分解能画像の対応点探索と 2 次元射影変換行列の算出	29
4.5.	推定された 2 次元射影変換の誤差算出	30
4.6.	評価実験	31
4.6.1.	評価指標	31
4.6.2.	訓練データセット	32
4.6.3.	評価データセット	32
4.6.4.	超解像深層ニューラルネットワークの構成と訓練	33
4.6.5.	対応点探索手法	34
4.6.6.	結果と考察	35
第 5 章	低空撮影画像と地上撮影画像の間の対応点探索	37
5.1.	疑似俯瞰画像の生成による低空撮影画像との対応点探索	37
5.2.	疑似俯瞰画像の生成	38
5.3.	疑似俯瞰画像と低空撮影画像の間の対応点探索	40
5.4.	地上撮影画像と低空撮影画像の間の 2 次元射影変換行列の算出	41
5.5.	地上撮影カメラの位置姿勢推定	42
5.6.	評価実験	43
5.6.1.	評価指標	43
5.6.2.	実験環境・使用機材・データセット	44
5.6.3.	結果と考察	47
第 6 章	各手法を統合した異高度撮影画像間の対応点探索法の実証実験	52
6.1.	実験詳細	53
6.1.1.	データセット	53
6.1.1.1.	SAR 画像から疑似 EO 画像を生成する画像変換 DNN の学習データセット	53
6.1.1.2.	EO 画像に適用する超解像 DNN の学習データセット	54
6.1.1.3.	評価データセット	55
6.1.2.	SAR 画像を疑似 EO 画像に変換する画像変換 DNN の訓練	55
6.1.3.	EO 画像に適用する超解像 DNN の訓練	56
6.2.	実験結果	58
6.2.1.	EO 画像と SAR 画像の間の対応点探索と画像レジストレーション	58
6.2.2.	EO 衛星画像と低空撮影画像の間の対応点探索	60
6.2.3.	低空撮影画像と地上撮影画像の間の対応点探索	61
6.2.4.	EO 画像への画像レジストレーション結果	62

第 7 章	結論.....	67
謝辭	70
参考文献	71
研究業績	76

図目次

図 1-1 本論文における研究課題	2
図 2-1 屋外撮影 4 分類におけるそれぞれの特徴.....	4
図 2-2 EO 衛星画像と SAR 衛星画像の見え方の比較.....	5
図 2-3 SIFT の処理の流れ	7
図 3-1 Sentinel-2A/2B 衛星で 2019 年に撮影された埼玉県秩父郡横瀬町の画像群	11
図 3-2 画像変換 DNN を用いた SAR・EO 画像間の対応点探索法	12
図 3-3 従来の CGAN の生成画像（左）と正解の画像（右）	13
図 3-4 提案するエッジ強調を含んだ CGAN による生成器 G （画像変換 DNN）の訓練.....	14
図 3-5 訓練済み画像変換 DNN (G) を用いた疑似 EO 画像の生成と対応点探索	15
図 3-6 輝度勾配の差分値のヒストグラムと閾値処理による誤対応除去.....	16
図 3-7 オクターブ番号の差分値のヒストグラムと閾値処理による誤対応除去.....	16
図 3-8 誤対応除去処理の結果	17
図 3-9 生成器（上）と識別器（下）の図.....	19
図 3-10 画像変換の結果	21
図 3-11 提案の画像変換器による画質の向上	22
図 3-12 対応点探索の結果	24
図 3-13 平面仮定における SAR および EO 画像のレジストレーションの例	25
図 4-1 想定する空間分解能の違い	26
図 4-2 提案する適応的スケーリングの概要図.....	27
図 4-3 対応点探索に適した空間分解能を推定する処理の流れ	27
図 4-4 局所領域を推定する超解像 DNN を訓練するデータセットの生成プロセス.....	28
図 4-5 ORB+SIFT による対応点探索（左）と、画像レジストレーションの例（右）	30
図 4-6 誤差算出の概略.....	31
図 4-7 パッチ抽出の際のランダムシフト	32
図 4-8 評価実験に用いた LR 画像と HR 画像	33
図 4-9 生成器と識別器の構成.....	34
図 4-10 超解像倍率 6 倍の結果.....	36
図 4-11 6 倍超解像画像（左）と同地点の HR 画像（右）	36
図 5-1 撮影方向の違いに起因する地面領域の射影歪み	37
図 5-2 地上撮影画像と低空撮影画像との対応点探索.....	38
図 5-3 疑似俯瞰画像生成プロセスの概要図	39
図 5-4 地上撮影画像（左）と疑似俯瞰画像（右）	40
図 5-5 疑似俯瞰画像と低空撮影画像の対応点探索	41
図 5-6 地上撮影画像から低空撮影画像への射影変換行列の算出.....	42

図 5-7 撮影に用いたドローン	44
図 5-8 実験に用いた低空撮影画像.....	45
図 5-9 地上撮影画像の取得に用いたタブレット端末の設置	45
図 5-10 実験に用いた地上撮影画像.....	46
図 5-11 低空撮影画像中における地上撮影の地点と方位	46
図 5-12 誤差平均算出のサンプル数.....	47
図 5-13 地上撮影カメラの位置姿勢推定結果	48
図 5-14 空間分解能 4.0 cm/画素の場合の位置推定誤差	49
図 5-15 空間分解能 4 cm/画素の場合の対応点ペアの方向差分値ヒストグラム	49
図 5-16 誤対応除去に失敗した例	50
図 5-17 空間分解能の違いにより生じる実験場所の地面テクスチャの見え方の違い.....	50
図 5-18 地上撮影画像（左）と低空撮影画像との対応点探索の結果（右）	51
図 5-19 モバイルカメラの推定位置・方位と地上撮影画像をマッピングした結果	51
図 6-1 本章における実験の概要	52
図 6-2 実験場所の埼玉県秩父郡横瀬町の航空写真	53
図 6-3 画像変換 DNN の訓練における生成器の損失関数のグラフ	56
図 6-4 超解像 DNN の訓練における生成器の損失関数のグラフ	57
図 6-5 EO 画像と超解像画像.....	57
図 6-6 SAR 画像から疑似 EO 画像への変換	58
図 6-7 Sentinel-2 衛星画像と疑似 EO 画像の対応点探索結果.....	59
図 6-8 Sentinel-2 衛星画像との画像レジストレーション結果.....	59
図 6-9 GeoEye-1 衛星画像と低空撮影画像の対応点探索結果	60
図 6-10 GeoEye-1 衛星画像と低空撮影画像の画像レジストレーション	61
図 6-11 低空撮影画像と地上撮影画像より作成した疑似俯瞰画像の対応点探索結果.....	62
図 6-12 Sentinel-2 衛星画像と SAR 画像の重畳結果	62
図 6-13 EO 衛星画像と低空撮影・地上撮影画像のレジストレーション結果	64
図 6-14 提案手法による空間分解能向上の結果.....	65
図 6-15 地上撮影視点へ画像を重畳した結果	65

表目次

表 3-1 Cygnus のノードあたりの性能諸元.....	20
表 3-2 対応点探索の誤差 \bar{d}	23
表 3-3 得られた対応点の数.....	23
表 3-4 平均正対応率	23
表 4-1 提案手法による実験結果	35
表 4-2 Bicubic 補間による実験結果	35
表 6-1 画像変換 DNN の学習に用いた画像データセットの撮影日時.....	54
表 6-2 評価データセットの撮影時刻	55

第1章 序論

衛星や航空機を用いたリモートセンシング[1]によって得られた画像（以下，“高空撮影画像”と呼ぶ）の利活用が防災の分野で一般化している[2][3]。高空撮影画像の中でも可視光を観測した EO 画像（Electro-Optical 画像）が広く利用されており，これらは各画素に地理情報（緯度・経度・標高情報など）が付与され，地理情報システム（GIS: Geographic Information System）[4]–[6]のデータベースで管理される。災害発生直後，被災し変化が生じた箇所を正確かつ迅速に把握するためには，数分～数時間の高時間分解能（高頻度）の撮影や，数 cm～数十 cm オーダーの高空間分解能の撮影がされることが望ましいが，現状の GIS では画像データの時空間分解能が不足するため実現が困難である。そこで本論文では，GIS の EO 画像データに加えて，別センサの画像や，ドローン・モバイルカメラの画像など，撮影高度の異なる画像群を用いることで GIS の時空間分解能の向上を図る。

変化検出には，2 画像間の幾何的な対応関係の算出処理（画像レジストレーション処理）により変化前後の画像を重ね合わせ，差分を算出する必要がある。これまでの画像レジストレーション手法としては，機体の位置・姿勢といった画像撮影と同時に計測した情報に基づく手法や，デジタル標高モデル（DEM: Digital Elevation Model）を利用するオルソ補正（正射投影）[7, Ch. 19]，人手による GCP（Ground Control Point）の選定作業によって幾何対応関係を推定する手法[8, Ch. 7]がある。しかし，これらの手法をドローンやモバイルカメラの画像群へ適用するには，GCP 選定のための人的リソースが不足し，機体の揺動や手ぶれによるセンサの計測誤差も影響する。また，災害発生直後の局所的な状況把握への適用を考慮すると，地形が変化し DEM が有効に作用しない場合が考えられる。そこで本論文では，2 画像の幾何的な対応関係を得るために，両画像中から特徴的な点（特徴点）を検出し，特徴点マッチング処理により対応する特徴点（対応点）の探索を行う手法に着目した。この手法では，2 画像の対応点の位置関係から画像全体の幾何的な対応関係を推定するため，多数の正対応が得られれば統計的に正確な対応関係の算出が可能である。点という局所特徴の類似度から対応関係を求めるため，画像中に部分的な差違があっても共通する局所特徴から全体の幾何的な対応関係が推定可能であるという利点を有する。したがって，災害時における局所的な変化検出という本論文の研究内容の実利用シーンとの親和性が高い。

本論文では，GIS データベースの時空間分解能の向上のため，屋外撮影を“EO”・“SAR”・“低空撮影”・“地上撮影”の四つに分類し，EO 画像を基準として幾何的な対応関係を推定する手法を提案する。合成開口レーダ（SAR: Synthetic Aperture Radar）[9]–[11]は雲を透過して地表を撮影することが可能である。GIS データベースの EO 画像との対応点探索による幾何的な対応関係の算出が可能となることで，EO では雲に遮蔽されて地上の撮影ができない場合にも撮影が可能となり，GIS データベースの時空間分解能の向上に寄与する。地上撮影画像は，地表に近い場所からの撮影であるため空間分解能が高く，撮影デバイスの数が多いため撮影頻度が高く時間分解能が高いため，これらの画像と GIS データベースの EO 画像の間で対応点探索により幾何的

な対応関係を算出することで GIS データベースの時空間分解能の向上に寄与する。しかし、EO 画像と地上撮影画像の間の対応点探索を行うにあたっては、撮影距離の違いによる画像の空間分解能の差違と、撮影方向の違いによる射影歪みが主因となり、直接の対応点探索は非常に困難である。そこで、いわば両者の中間の特性を持つ低空撮影画像も活用することで解決を図る。

EO 画像と SAR 画像、EO 画像と低空撮影画像、低空撮影画像と地上撮影画像、それぞれの対応点探索には、以下の図 1-1 に示すような課題が存在する。

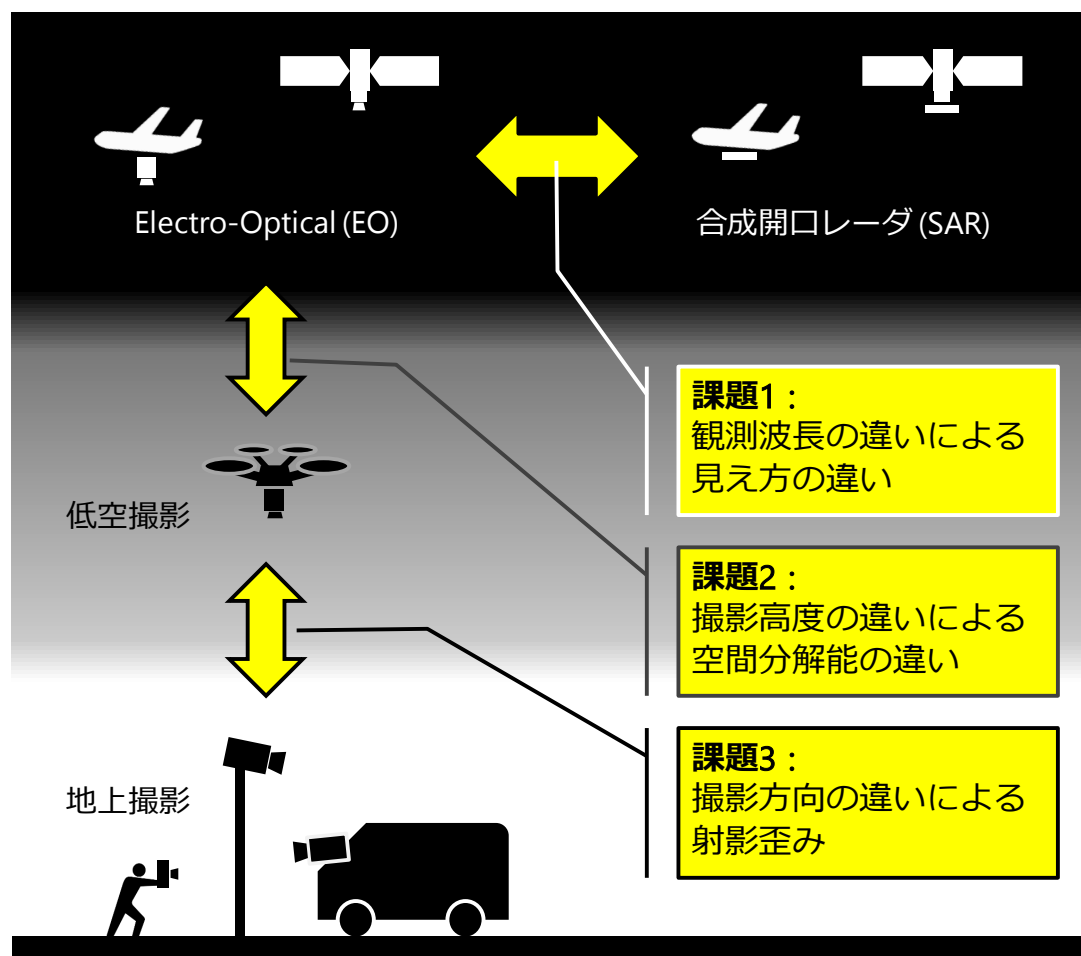


図 1-1 本論文における研究課題

EO 画像と SAR 画像の間の対応点探索においては、観測する電磁波の違いによって画像中の地表の見え方に差違が生じるため対応点探索が困難であるという課題がある。EO 画像と低空撮影画像の間の対応点探索においては、地表からの撮影高度の違いによって空間分解能に大きな違いが生じるため対応点探索が困難であるという課題がある。低空撮影画像と地上撮影画像の対応点探索においては、地上撮影画像の水平方向撮影によって画像中に写る地面領域に射影歪みが生じるため対応点探索が困難であるという課題がある。そこで、本論文の学術的貢献として、各課題に対して以下のような解決策を提案する。

EO 画像と SAR 画像の対応点探索：撮影センサの観測波長の差による撮像形態の違い（モードの違い）に起因する見え方の違いがある画像間の対応点探索のため、SAR 画像を入力として、疑似的に EO 画像のような見え方を再現した画像（疑似 EO 画像）を生成することで、両者の画像モデルを揃えることにより対応点探索を実現する。

EO 画像と低空撮影画像の対応点探索：撮影高度の違いに起因する空間分解能の大きな違いがある画像間の対応点探索のため、EO 画像に対しては画像超解像による拡大処理を、低空撮影画像に対しては縮小処理をそれぞれ施し、空間分解能を揃えることにより対応点探索を実現する。

低空撮影画像と地上撮影画像の対応点探索：撮影方向の違いに起因する射影歪みのある画像間の対応点探索のため、横向き撮影の地上撮影画像に対して、カメラの内部パラメータと撮影時の加速度センサの値に応じて地表領域の射影歪みを補正することで疑似的に俯瞰視点から見下ろしたような見え方となった疑似俯瞰画像を生成することで、両者の間の対応点探索を実現する。


以下、第 2 章で、本章で挙げた課題の関連研究について述べ、第 3 章で、異なる撮影センサの衛星画像間の対応点探索手法について、第 4 章で、EO 画像と低空撮影画像の間の対応点探索手法について、第 5 章で、低空撮影画像と地上撮影画像の間の対応点探索手法について説明する。そして第 6 章で、本論文で提案する手法が想定する応用事例への適用可能性を実証するために、3～5 章で述べた手法を統合した異高度撮影画像間の対応点探索法の実証実験について述べ、最後に第 7 章で結論を述べる。

第2章 関連研究

本章では、本論文の理解を助けるため、関連する研究について説明する。まず第 1 章で提示した屋外撮影の 4 分類についてそれぞれの特徴を説明し、その後、本論文における主要な関連技術である対応点探索と、画像のモーダル変換について説明する。最後に、本論文で解決を試みる三つの課題に關係する従来研究について概説する。

2.1. 屋外撮影の 4 分類

屋外環境を撮影する手法をその撮影高度の違いによって EO・SAR・低空撮影・地上撮影の四つに分類し、それぞれの手法で撮影された画像間（異高度撮影画像間）の対応点探索処理により幾何的な対応関係を算出する。図 2-1 は四つの分類における代表的な撮影デバイスと、それぞれの特徴を示したものである。



		撮影範囲	撮影角度	空間分解能	時間分解能	GISでの管理	センサ
高空撮影	EO	広	下向き	低 (30~cm/pix)	低	✓	可視光
	SAR	広	下向き	低 (30~cm/pix)	やや低	✓	SAR (合成開口レーダ)
低空撮影		中	下向き	高 (~10cm/pix)	やや高	✗	可視光
地上撮影		狭	横向き	高 (~10cm/pix)	高	✗	可視光

図 2-1 屋外撮影 4 分類におけるそれぞれの特徴

2.1.1. Electro-Optical (EO)

高空撮影画像の中でも、EO 画像は、可視光を観測し画像化されたものであるため、人間が見て理解しやすいという利点を有する。その利点ゆえ、DEM と人手による位置合わせ・オルソ補正がされ、Google Map[12]や地理院地図[13]など GIS アプリケーションで一般に利用できる画像データが既に多数存在している。しかしながら、空間分解能・時間分解能（撮影頻度）が低く、

短時間に生じた変化や局所的な変化の検出が困難であるという問題がある。空間分解能に関しては、撮影範囲とのトレードオフであるが、比較的高い分解能の画像であっても高々数十 cm/画素である。時間分解能に関しては、人工衛星の観測周期が 10～14 日程度であるということに加え、天候によっては雲による遮蔽が生じる場合もあり、現状では高々数日程度の時間分解能である。

2.1.2. 合成開口レーダ (SAR)

人工衛星や航空機で得られる高空撮影画像の一つに、合成開口レーダ (SAR: Synthetic Aperture Radar) [9]–[11]により撮影された画像がある。SAR は、合成開口技術により仮想的に大口径のレーダアンテナを構成し、実際のアンテナの口径と比べて非常に高い空間分解能を実現したイメージングレーダである。SAR の利点として、SAR による撮影はアクティブセンシングであるため、得られる画像情報は日照条件に依存しないことが挙げられる。また、SAR に一般的に用いられる電磁波の波長は 2.4～3.8 cm (X バンド SAR)、3.8～7.5 cm (C バンド SAR)、15～30 cm (L バンド SAR) であり、雲による散乱が少ないので天候不良による情報の欠落が少ないという利点も有する。EO 衛星で撮影できない状況で地上の撮影を行うことが可能であることから、GIS の高時間分解能化を実現可能である。SAR で得られる画像の各画素値は、SAR 衛星に搭載された SAR アンテナより地表へ照射された電磁波の後方散乱 (再帰性反射) の強度を表している。SAR で用いる電磁波の波長は可視光 (約 400～800 nm) と比べ非常に長いので、その反射特性の違いにより、図 2-2 に示すように、同一領域を撮影した場合でも SAR 画像と EO 画像の見た目は大きく異なるため、直接の対応点探索が困難であるという問題がある。




図 2-2 EO 衛星画像と SAR 衛星画像の見え方の比較
各衛星画像は[14]のデータセットより引用

2.1.3. 低空撮影

低空撮影を行うドローンは、高空間分解能な画像情報とその撮影地点の衛星測位情報を同時に取得可能である[15]–[17]。ドローンによる撮影には人間が介在するため柔軟な撮影計画の立案が可能であり、撮影の必要が生じた際に即座にドローンを飛ばして撮影をすることが可能であるという点から、高空撮影より高い時間分解能を実現している。しかしながら、電源供給と目視操作のために、撮影の地点は地表から数百 m の高度に抑えるのが一般的であるため、一度に撮影できるのは高空撮影と比べ狭い領域となり、広範囲の情報を得る場合には時間的・人的コストが増加するという問題を有する。また、撮影画像そのものには、各画素に地理座標値が付与されていない。

2.1.4. 地上撮影

地上撮影を行う監視カメラ・車載カメラ・モバイルカメラなどは、低空撮影と同等あるいはそれ以上の空間分解能で撮影が可能なデバイスである。また、機器の普及台数が EO・SAR・低空撮影の機器と比べても圧倒的に多数であり、非常に高い時間分解能を有する撮影形態と見なせる。低空撮影と同様に、撮影地点の衛星測位情報を撮影と同時に取得可能であるが、撮影画像そのものには、各画素に地理座標値が付与されていない。また、地上撮影特有の問題として、EO・SAR・低空撮影が下向き撮影であるのに対し、地上撮影は撮影方向が水平に近い方向であるため、共通して撮影される地面領域に射影歪みが生じることが挙げられる。

2.2. 主要な関連技術

2.2.1. 対応点探索

画像ベースの幾何学的レジストレーションを実現するために、画像の局所特徴量が利用される。特に、特徴点ベースの方法[18]–[22]は、テンプレートベースのマッチング方法と異なり、部分的な対応を用いて 2 画像間の対応関係を推定できるという利点がある。特徴点ベースの方法は、大きく特徴点検出・特徴量記述の 2 段階に分けられ、それぞれの処理アルゴリズムは特徴量検出器・特徴量記述子と呼ばれる。特徴点検出アルゴリズムとしては、SIFT[23], SURF[24], ORB[25], KAZE[26], AKAZE[27]などが代表的であり、これらは特徴量記述子を併せ持っている。深層学習を用いた機械学習ベースの特徴点検出器としては SuperPoint[28], Key.Net[29]などが提案されている。特徴量記述子としては、BRIEF[30], BRISK[31], FREAK[32], 機械学習ベースの特徴量記述子としては L2-Net[33], HardNet[34]などが提案されている。先に挙げた特徴点検出器は、検出した特徴点に対し、輝度勾配方向とスケールを算出する。特徴量記述子は、それらの輝度勾配方向・スケールの情報も加味して幾何学的な変動（回転、スケールなど）

および照明条件の変化に頑健な特徴量を記述する。対応する特徴点と類似した特徴を持つ特徴点のペア（対応点）を見つけ、最終的に画像間の対応関係の推定を実現する。ここではとくに、第3章以降で用いる SIFT（Scale Invariant Feature Transform）について概説する。

図 2-3 に SIFT の処理の概要を示す。まず特徴点検出ステップでは、DoG（Difference of Gaussian）画像を用いて、仮の特徴点と特徴量記述に用いる範囲（スケール）を検出する。その後のローカライズでは検出された仮の特徴点の中から特徴点に向かないものを削除しサブピクセルの位置推定を行う。そして、特徴量記述ステップでは、回転に不変な特徴を得るため各特徴点について輝度勾配から方向を定め、その方向とスケールにしたがって各特徴点に対しそれぞれ 128 次元の特徴量ベクトルを記述する。

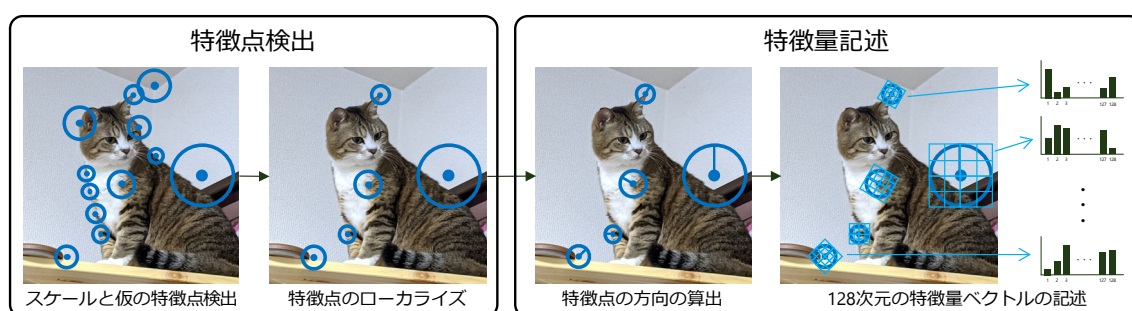


図 2-3 SIFT の処理の流れ[20, Ch. 1]

図は[20, Ch. 1]を参考に作成した。

SIFT は、画像スケール変化に対して不変な特徴量を記述するためにイメージピラミッドを構成する。特徴点のスケールを決定する際、ガウシアンフィルタの分散を σ_0 から一定の割合で増加させ続け、それに伴いフィルタサイズを拡大させ複数枚の DoG 画像を取得する。しかし、そのフィルタサイズが拡大し続けると、計算コストが増加するという問題が生じるため、SIFT では $2\sigma_0$ 毎に 1/2 倍の画像ダウンサンプリングによって相対的にフィルタサイズを拡大させる。この、画像が 1/2 倍、1/4 倍、1/8 倍…とダウンサンプリングされる様子をピラミッドに見立てイメージピラミッドと呼ばれる。このイメージピラミッドのどの階層（オクターブ）のどの画像中から特徴点を検出されるかという情報にしたがって、スケールを決定している。

2.2.2. 敵対的生成ネットワークによる画像のモーダル変換

画像のモーダル変換は、深層ニューラルネットワーク（DNN: Deep Neural Network）を用いた機械学習の手法が広く利用されている[35][36]。本論文では、主に DNN を用いた敵対的生成ネットワーク（GAN: Generative Adversarial Networks）[37][38]に焦点を当てる。GAN はランダムな入力からデータを生成する生成器（Generator）と、データの真贋を判断する識別器（Discriminator）を訓練し、両者の性能を競わせることによって本物のデータに類似したデータを

生成する生成器を得るネットワークである．GAN の損失関数 \mathcal{L}_{GAN} は、

$$\mathcal{L}_{\text{GAN}}(G, D) = \mathbb{E}_{\mathbf{y}}[\log D(\mathbf{y})] + \mathbb{E}_{\mathbf{z}}[\log (1 - D(G(\mathbf{z})))] \quad (1)$$

と表現される．ここで、 $G(\cdot)$ は生成器により生成されたデータを意味し、 $D(\cdot)$ は識別器に入力されたデータが真であると判断する確信度を意味する． \mathbf{x} , \mathbf{y} , \mathbf{z} はそれぞれ訓練の入力・正解・ランダム入力を意味している．GAN の目的は、識別器を欺けるほど訓練された生成器を得ることであり、それを G^* とすると、以下のように表現できる．

$$G^* = \min_G \max_D \mathcal{L}_{\text{GAN}}(G, D) \quad (2)$$

GAN の一つの発展形として、生成器にランダム入力の他に変換元のデータも入力とする条件付き GAN (CGAN: Conditional GAN) [39][40]を用いた画像変換における損失関数は以下のよう表現できる．

$$\mathcal{L}_{\text{CGAN}}(G, D) = \mathbb{E}_{\mathbf{y}}[\log D(\mathbf{y})] + \mathbb{E}_{\mathbf{x}, \mathbf{z}}[\log (1 - D(\mathbf{x}, G(\mathbf{x}, \mathbf{z})))] \quad (3)$$

また、その CGAN の発展形として提案された Pix2pix[41]は、多目的に用いることのできる画像変換手法として知られている．Pix2pix の損失関数 $\mathcal{L}_{\text{Pix2pix}}$ は、定数 λ と L1 ノルムを用いて、

$$\mathcal{L}_{\text{Pix2pix}}(G, D) = \mathbb{E}_{\mathbf{y}}[\log D(\mathbf{y})] + \mathbb{E}_{\mathbf{x}, \mathbf{z}}[\log (1 - D(\mathbf{x}, G(\mathbf{x}, \mathbf{z})))] + \lambda \mathbb{E}_{\mathbf{x}, \mathbf{y}, \mathbf{z}}[\|\mathbf{y} - G(\mathbf{x}, \mathbf{z})\|_1] \quad (4)$$

と表現され、式(2)と同様にして訓練された生成器を得る．この Pix2pix で得られる生成器は、画像を入力としてその画像を別モードの画像へ変換する画像変換器としての役割を有する．Pix2pix はその論文[41]において、線画像から実際の写真へのマルチモーダルな変換が可能であることを実証している．

GAN の一つ別の利点は、少ない訓練データセットでも効果が期待できる点である[41]．従来、機械学習には多くの訓練データセットが必要であったが、GAN は生成器モデルと識別器モデルにより、少ないデータセットで高いパフォーマンス期待できる．本論文の研究課題の場合、大量の訓練用 SAR・EO 画像データセットを準備することは困難であるため、非常に重要な利点である．

2.3. 本論文で解決を試みる課題に関する従来研究

2.3.1. EO 画像と SAR 画像の幾何的な対応関係推定

画像の幾何学的レジストレーションは、DEM を使用し、オルソ補正によって地図投影を行う手法が一般的である[7][8]。しかし、DEM を使用する手法では、高空間分解能の SAR 画像と EO 画像のレジストレーションを行う場合、DEM の空間分解能が高精度なレジストレーションに不十分となる場合が考えられる。また、災害直後の状況把握を想定する場合、災害の発生後に地形が大幅に変化し、その結果 DEM がその状況に適さないものになってしまう場合がある。したがって、DEM に依存しない画像特徴ベースのレジストレーション手法が必要とされている。しかしながら、SAR で用いられる電磁波は可視光と比べ長波長であるため、その反射・散乱特性の違いにより、同一領域を撮影した場合でも SAR 画像と EO 画像の見た目は大きく異なる。そのため、両者に共通する画像特徴を取得することは困難である。

DEM ベースではない、画像ベースのレジストレーションを行うには、観測波長の異なる 2 画像から共通の特徴量を検出する必要がある。テンプレートマッチングを用いた手法としては、二つの画像間の正規化相互相関 (NCC: Normalized Cross Correlation) や相互情報量 (MI: Mutual Information) を使用した手法が提案されている[42][43]。これらの方法は比較的広範囲の画像特徴を使用する必要があり、テンプレートのサイズが小さいとテンプレートのマッチング精度が低下し、テンプレートのサイズを大きくすると部分的な差異 (災害前後など) やオクルージョンへの頑健性が低下する。したがって、災害前後など地形が部分的に変化する状況を想定すると、より局所の画像特徴量によってレジストレーションする必要がある。

画像ベースの幾何学的レジストレーションを実現するためには、画像の局所特徴量が利用される[44]–[46]。特に、特徴点ベースの方法は、テンプレートベースのマッチング方法と異なり、部分的な対応を使用して 2 画像間の対応関係を推定できるという利点がある。局所特徴を使用するため、観測された領域の一部が変化した場合でも、その他の部分的な箇所から対応を取得できるという利点がある。

2.3.2. EO 画像と低空撮影画像の幾何的な対応関係推定

ドローンの低空撮影画像と、EO 画像とのレジストレーションの従来手法としては、複数枚のドローン画像に対して SfM (Structure from Motion) [47]を施して 3 次元モデルを生成し、地図情報と連携させる手法が提案されている[48][49]。しかし、これらの手法には複数枚のドローン画像が必要であり、単一のドローン画像への適用は困難である。少数の画像への適用には、3 次元モデルの生成誤差と衛星測位の誤差の影響が大きくなるといった問題が存在する。

画像特徴を用いたレジストレーション手法としては、SIFT 特徴点を用いて初期位置合わせを行った後、相互情報量を用いた繰り返し処理により回帰誤差を軽減する手法[50]や、NCC を用

いる手法[51]が提案されている。しかし、前者は SIFT 特徴点による初期位置合わせが失敗した場合に画像レジストレーションが困難となり、後者は 2 画像の間に射影歪みが生じている場合に対応が困難となることが知られている。

2.3.3. 低空撮影画像と地上撮影画像の幾何的な対応関係推定の従来研究

車載カメラと、上空から航空機などで真下を撮影した空撮画像を併用し、両画像に写り込んだ道路領域で対応点探索を行う手法が提案されている[52]。この手法は、車載カメラで撮影された画像中に写り込んだ地面領域に対し、カメラパラメータとカメラの俯角の情報に基づいて、俯瞰視点からの見え方を疑似的に合成することにより、射影歪みが補正された画像画像を得る。それから 2 画像の間で SURF による対応点探索を行うことで幾何的な対応関係を推定し、自動車の位置姿勢推定を行うものである。[52]では、姿勢が固定された車載カメラを使用しているため、射影歪みを補正するパラメータは固定であるとしているが、本論文が対象とするような姿勢が固定されていないモバイルカメラに応用するためには、改善の余地が残されている。

第3章 EO 画像と SAR 画像の間の対応点探索

本章では、撮影センサの異なる衛星画像（EO 画像と SAR 画像）に対し、GIS の時間分解能向上のため、特徴点検出・特徴量記述・特徴点マッチングによる対応点探索を実現する手法を提案する。

GIS の時間分解能を低下させる要因の一つとして、雲による遮蔽がある。特に日本など雨季がある地域では、雨季に時間分解能が低下する。図 3-1 は雲による地表の遮蔽の例として、埼玉県秩父郡横瀬町を 2019 年に欧州宇宙局の EO 衛星である Sentinel-2A, Sentinel-2B で観測した画像を示すものである。




図 3-1 Sentinel-2A/2B 衛星で 2019 年に撮影された埼玉県秩父郡横瀬町の画像群

左上から右下にかけて時系列順に並んでいる。全 67 枚のうち、雲がかかっておらず市街地を撮影することができたのは 18 枚であった。特に梅雨から秋雨の時期（3, 4, 5 段目）にかけて雲に遮蔽される頻度が高くなっていることがわかる。

豪雨災害など悪天候に起因する災害の場合、上空は雲に覆われているため EO 衛星では地表の情報が得られない場合がある。その点、SAR は雲を透過して地表を撮影することが可能なセンサであるため、EO 衛星で時間分解能が低下する場合であっても撮影が可能である。そこで、この SAR 画像と GIS の EO 画像の間で対応点探索を行い、画像レジストレーションを実現することで、GIS の時間分解能の向上が可能である。

3.1. 対応点探索のための深層ニューラルネットワークによる SAR から疑似 EO 画像への画像変換

提案手法では、対応点探索処理を実行する前に GAN，とくに入力を伴う CGAN，により訓練された DNN ベースの画像変換器（以下，“画像変換 DNN”と呼ぶ）を使用し，SAR 画像の外観が EO へ変換された画像（以下，“疑似 EO 画像”と呼ぶ）に変換する前処理を採用する．図 3-2 に示すように，画像特徴ベースの特徴点検出，特徴量記述，および対応点探索アルゴリズムを使用し，マルチモーダル（SAR および EO）画像間の局所特徴対応を探索する方法を提案する．しかしながら，CGAN で画像変換 DNN を訓練する手法として Pix2pix[41]を使用した過去の研究[53]では，細部にブラーが生じ局所特徴を損なっているという問題があった．より多くの正確な対応点を得るためには，局所の情報を強調させるように訓練を行う必要がある．そこで，上記[53]の課題を克服するために，訓練に際し，正解画像データにエッジ強調フィルタを適用し，エッジ強調された画像データを用いて画像変換 DNN の訓練を行うことで，対応点探索に必要な局所情報を損なわない画像変換 DNN を得る手法を提案する．提案手法の適用の有効性と性能限界を定量的に確認するため，従来手法との比較評価実験を実施した．




図 3-2 画像変換 DNN を用いた SAR・EO 画像間の対応点探索法

3.2. 条件付き敵対的生成ネットワークによる深層ニューラルネットワークの訓練

入力として SAR 画像を，正解として EO 画像を使用して CGAN による画像変換 DNN の訓練を行い，変換を学習した画像変換 DNN の推論により，疑似 EO 画像を得る．GAN は，生成器と識別器を互いに競わせ，より高品質の疑似 EO 画像を取得する．従来の CGAN では，図 3-3 に示すように生成される画像にブラーが生じるため対応点探索の精度が低下する問題があった．図 3-3 提案手法では，識別器 D の訓練の際に正解画像に対してエッジ強調フィルタをかけることで，生成器 G の生成する画像の画質向上を図る．

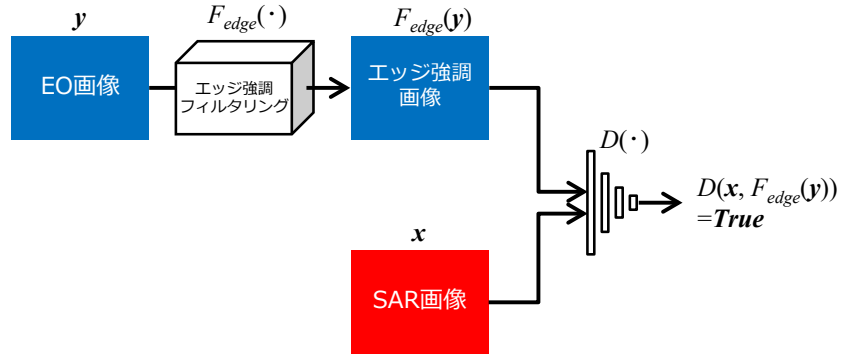


図 3-3 従来の CGAN の生成画像（左）と正解の画像（右）

左の画像ではブラーによって輝度勾配が滑らかになっており対応点探索の精度低下につながる．

図 3-4 は，提案手法の，DNN に画像変換を学習させる CGAN モデルを示している．すでに画像レジストレーションがされている SAR 画像と EO 画像のペアを準備し，SAR 画像を CGAN への入力 x として設定し，EO 画像 y にエッジ強調フィルタを施した結果である $F_{edge}(y)$ を，生成器 G （画像変換 DNN）と識別器 D の訓練に対する正解として設定する．この画像変換 DNN を用いて SAR 画像から疑似 EO 画像へ変換するプロセスにより，疑似 EO 画像は元の EO 画像と同じモダリティを持ち，従来の対応点探索処理を適用することが可能となる．

識別器の訓練



生成器の訓練

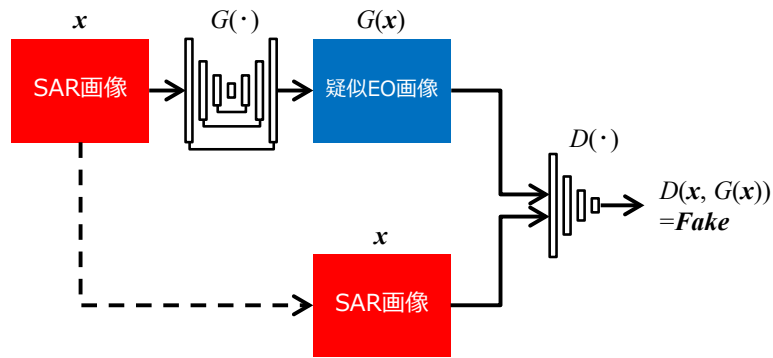


図 3-4 提案するエッジ強調を含んだ CGAN による生成器 G (画像変換 DNN) の訓練

このとき、提案手法の損失関数 $\mathcal{L}_{\text{Proposed}}$ は、(4)式の Pix2pix の損失関数を参考に以下のよう
に表現できる。

$$\begin{aligned} \mathcal{L}_{\text{Proposed}}(G, D) = & \mathbb{E}_{\mathbf{y}} [\log D(F_{edge}(\mathbf{y}))] + \mathbb{E}_{\mathbf{x}, \mathbf{z}} [\log (1 - D(\mathbf{x}, G(\mathbf{x}, \mathbf{z})))] \\ & + \lambda \mathbb{E}_{\mathbf{x}, \mathbf{y}, \mathbf{z}} [\|F_{edge}(\mathbf{y}) - G(\mathbf{x}, \mathbf{z})\|_1] \end{aligned} \quad (5)$$

ここで、定数 λ は Pix2pix の論文中的の実装に倣い、 $\lambda = 0.1$ とする。

3.3. 特徴点検出器と特徴量記述子を用いた対応点探索

提案手法の対応点探索処理の概要を図 3-5 に示す。前節で説明した学習モデルを使用して画像変換 DNN を取得し、その画像変換 DNN により SAR 画像を疑似 EO 画像へ変換する。対応点探索処理には SIFT を用い、疑似 EO 画像と実際の EO 画像の間で実行する。




図 3-5 訓練済み画像変換 DNN (G) を用いた疑似 EO 画像の生成と対応点探索

3.4. 誤対応の除去処理

対応点探索処理は、疑似 EO 画像と EO 画像の間で実行される。対応点を見つける過程で、結果に誤対応が含まれる場合があり、この誤対応によって画像レジストレーションの精度が低下するため、外れ値として削除する処理が必要となる。高空撮影画像間のレジストレーションの場合には、スケール・回転・並進の違いのみと見なすことができるため、誤対応を除去する処理は、特徴点のスケールと方向に従って行う事が可能である。

3.4.1. 特徴点の輝度勾配方向を指標とした誤対応除去処理

SIFT の特徴点マッチングアルゴリズムは、特徴点検出の際、その特徴点周りの輝度勾配方向を記録する。その方向の情報を元に誤対応を除去する。対応点ペアの方向の差分をとり、差分値ヒストグラムを生成する。最も出現頻度の高いビン (bin) の値を正対応時の勾配方向の差分値とする。図 3-6 に示すように、そのビンを中心とした一定の範囲内に、勾配方向の差分値が収まらない対応ペアは、誤対応点と判断し除去する。




図 3-6 輝度勾配の差分値のヒストグラムと閾値処理による誤対応除去

3.4.2. 特徴点のスケール比を指標とした誤対応除去処理

SIFT の特徴点マッチングアルゴリズムは、対応付けを行う際、スケール変化への頑健性を向上させるためにイメージピラミッドを構成する。特徴点検出の際に特徴点がイメージピラミッドのどのオクターブから検出された点であるか記録されるため、そのオクターブ番号を元に誤対応を除去する。まず対応点ペアのオクターブ番号の差分をとり、前節と同様に、図 3-7 に示すような差分値のヒストグラムを生成する、最も頻度の高いビンの値を正対応時の差分値とし、そのビンを中心とした一定の範囲内に、勾配方向の差分値が収まらない対応ペアは、誤対応点と判断し除去する。




図 3-7 オクターブ番号の差分値のヒストグラムと閾値処理による誤対応除去

図 3-8 は、誤対応除去処理の前後の対応点をプロットした結果を示している。除去処理適用前の図 3-8 上に比べ、適用後の図 3-8 下は対応点全体における誤対応の割合が減少していることがわかる。




図 3-8 誤対応除去処理の結果

上図は誤対応除去前、下図は誤対応除去後の結果を示している。黄色線は対応点を示す。左右に並べた 2 画像はレジストレーション済みであり、したがって対応点を結んだ黄色線が斜めである場合は誤対応である。

3.5. 評価実験

本節では、提案手法を検証するための実験について説明し、その結果から提案手法の有効性について考察する。

3.5.1. 実験の目的と評価指標

提案手法の有効性を検証するため、対応点探索の精度の定量評価を行う。具体的には、対応点が検出された座標値の精度と、対応点数を評価する。この実験のデータセットとして、レジストレーション処理済みの SAR および EO 画像のペア画像データセットを使用する。評価指標として、SAR 画像と EO 画像それぞれにおける対応点の座標値のユークリッド距離の平均 \bar{d} を以下のように定式化する。

$$\bar{d} = \frac{1}{n} \sum_i^n \|p_i - p_i'\| \quad (6)$$

ここで、 p_i と p_i' はそれぞれ EO 画像と SAR 画像における対応点の座標を意味する。レジストレーションが完全であるならば、理想的には対応点はそれぞれ同じ座標値を持つため、評価指標 \bar{d} は 0 に近いほど高精度である。

比較として、SAR 画像と EO 画像の間で対応点探索を行う従来手法である DLSC[44]・HOPC[45]・CFOG[46]と、提案手法の画像変換 DNN を Pix2pix で訓練したものに入れ替えたもの、Pix2pix で訓練した画像変換 DNN の画像変換結果にエッジ強調(EE: Edge Enhancement)を適用したもの、以上 5 手法と提案手法で、同様のデータセットを用いて実験を行った。

3.5.2. 実験環境

3.5.2.1. CGAN の生成器と識別器のネットワーク構成

図 3-9 に学習に用いるネットワークの構成を示す。生成器には U-Net[54]を用いる。U-Net は層にスキップ構造を有し、このスキップ構造により、畳み込み層による情報の圧縮前の情報を先の層へ情報の損失無く渡すことが可能になる。提案手法にはエッジやコーナーの特徴を保持した変換が適しているため、この U-Net は適切であると考えられる。識別器には、分割した入力画像に対して判断を行うことで局所に着目した識別が可能な PatchGAN discriminator[55]を使用する。識別器内部の構成には一般的な 7 層の畳み込み層からなるエンコーダーを採用した。生成器・識別器の損失関数にはそれぞれ L1 ノルム・バイナリクロスエントロピーを用いた。




図 3-9 生成器（上）と識別器（下）の図

3.5.2.2. 画像データセット

この実験には、欧州宇宙局[56]の Sentinel-1（C バンド SAR 衛星）および Sentinel-2（EO 衛星）の画像データから作成された SEN1-2 データセット[14]を使用した。データセットには、レジストレーション済みの Sentinel-1 および Sentinel-2 の画像パッチが含まれている。Sentinel-1 画像の各画素深度は符号無し 8 ビットグレースケールであり、画像サイズは 256 画素×256 画素を有する。Sentinel-2 画像は、符号無し 8 ビット RGB、256 画素×256 画素である。Sentinel-2 画像はグレースケール画像に変換し CGAN の正解データとした。Sentinel-1、Sentinel-2 画像ともに、 $[0, 255]$ の範囲の輝度値を $[-1, 1]$ の範囲に線形に正規化する。空間分解能は、10 m/画素である。SEN1-2 データセットの“spring”データから、災害時の重要性を鑑み、“市街地”・“農地”・“山地”エリアを選定し、それぞれから 2936 セット・3320 セット・3224 セットの画像ペアを抽出した。そのうち 300 セットを評価(Test)データとし、残りのうち 300 セットを検証(Evaluation)データ、さらに残った 2336 セット・2720 セット・2624 セットをそれぞれの訓練 (Training) データとした。

3.5.2.3. エッジ強調フィルタ

エッジ強調フィルタとして、以下に示すようなラプラシアンフィルタをベースにしたものを用いる。

$$F_{edge}(\mathbf{I}) = \begin{bmatrix} -v & -v & -v \\ -v & 1+8v & -v \\ -v & -v & -v \end{bmatrix} * \mathbf{I} \quad (7)$$

ここで、 v はエッジ強調の強度を設定するためのパラメータであり、本実験では事前に効果が確認された $v = 0.1$ を用いる。

3.5.2.4. プログラムの実装および実行環境

訓練に用いた画像の入力バッチサイズは 32、訓練時間は 72 時間である。生成器と識別器の学習率は 1.0×10^{-3} から開始し、24 時間ごとに半減させた。PatchGAN のパッチのサイズは 128 画素 \times 128 画素に設定した。特徴点検出器・特徴量記述子として SIFT を使用し、パラメータは OpenCV 3.4.3[57]のデフォルト値とした。また、対応点の距離の閾値を 1.5 画素とした。これは 1.5 画素を超える距離を持つ対応点は外れ値と見なされることを意味する。計算機として筑波大学計算科学研究センターの高性能計算機 Cygnus の 1 ノードを用いて 4 台の GPU で並列計算を行った。表 3-1 に Cygnus のノードあたりの性能諸元を示す。

表 3-1 Cygnus のノードあたりの性能諸元

OS	CentOS Linux release 7.7.1908
CPU	Intel Xeon Gold 6126 2.6GHz (12 core) \times 2 ソケット
GPU	NVIDIA Tesla V100 PCIe \times 4 台
CPU メモリ	192 GiB, 255.9 GB/秒
GPU メモリ	32 GiB \times 4 = 128 GiB, 900 GB/秒 \times 4 = 3600 GB/秒
ネットワーク	InfiniBand HDR100 \times 4 チャンネル (400Gbps \times 4)
ストレージ	NVMe 3.2 TB

3.5.3. 結果と考察

SAR から疑似 EO 画像への変換の結果を図 3-10 に示す。提案のネットワークで得られた生成器によって、SAR 画像が適切に疑似 EO 画像へ変換されていることがわかる。

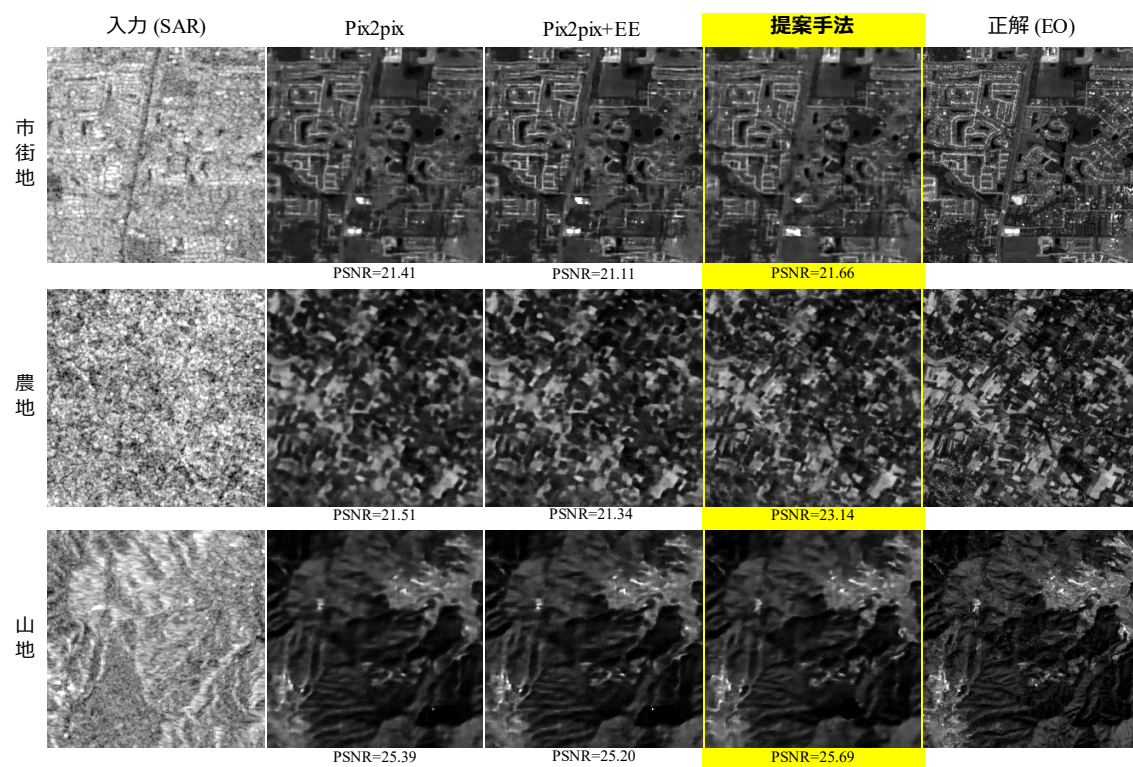


図 3-10 画像変換の結果

参考として、変換後の画像下に PSNR 値を示す。

図 3-11 に、提案手法によって改善された例を示す。Pix2pix で課題となっていた局所のブレイや再現性の低さが、提案手法によって改善されていることがわかる。




図 3-11 提案の画像変換器による画質の向上

表 3-2 に対応点探索の誤差 \bar{d} を示す。市街地・農地・山地それぞれのテストデータセットにおいて、提案手法は平均精度 0.538 画素, 0.569 画素, 0.577 画素という高精度な結果が得られ、これらは他の比較手法より高精度であった。絶対的な精度は市街地データセットが最も高精度であったが、改善値は農地・山地データセットの方が大きいという結果が得られた。これは、市街地は元々画像のコントラストが大きく、つまり人工構造物などエッジやコーナーのはっきりした強い局所特徴が得られる物体が多いためと考えられる。一方、農地や山地データセットでは市街地に比べ局所特徴が弱いいため提案手法が有効に作用したものと考えられる。

Pix2pix+EE の結果からわかるように、Pix2pix の推論結果にエッジ強調を施しても提案手法ほどの精度が得られないのは、推論結果に生じているアーティファクトに対しても等しく強調を施してしまうため、有効な局所特徴が強調されにくいためと考えられる。

表 3-2 に対応点探索の誤差 \bar{d} を示す。対応点探索の誤差は他の手法より高い精度を達成している。

表 3-2 対応点探索の誤差 \bar{d}

	DLSC[44]	HOPC[45]	CFOG[46]	Pix2pix[41]	Pix2pix + EE	提案手法
市街地	0.965	0.863	0.838	<u>0.564</u>	0.566	0.538
農地	0.847	0.847	0.700	<u>0.675</u>	0.676	0.569
山地	1.128	1.052	1.114	0.668	<u>0.668</u>	0.577

また、表 3-3 には得られた対応点数を、表 3-4 には全体の対応点数のうち正対応数の割合を示す。市街地・農地・山地それぞれのテストデータセットにおいて、提案手法は平均対応点数 75.0, 92.7, 76.4 という結果が得られた。表 3-2 の結果と同じく、改善値は農地・山地データセットの方が大きいという結果であった。表 3-3 中の市街地データセットにおいて唯一比較手法の HOPC が提案手法に勝っているが、このとき提案手法は 2 位であり総合的に提案手法の優位性が確認された。

表 3-3 得られた対応点の数

	DLSC[44]	HOPC[45]	CFOG[46]	Pix2pix[41]	Pix2pix + EE	提案手法
市街地	49.8	80.7	63.0	63.5	59.6	<u>75.0</u>
農地	62.5	<u>65.9</u>	62.1	47.8	47.8	92.7
山地	17.2	45.2	22.6	<u>48.1</u>	47.1	76.4

表 3-4 平均正対応率

	DLSC[44]	HOPC[45]	CFOG[46]	Pix2pix[41]	Pix2pix + EE	提案手法
市街地	0.437	0.703	0.575	0.900	<u>0.900</u>	0.913
農地	0.588	0.615	0.606	0.805	<u>0.815</u>	0.896
山地	0.155	0.396	0.200	<u>0.809</u>	0.808	0.880

図 3-12 は、EO 画像と疑似 EO 画像の間の対応点探索結果をプロットしたものである。十分な数の対応点が検出され、提案手法の画像変換 DNN が SAR から疑似 EO への変換に効果的であることが確認された。誤対応が残るケースもあるものの、概ね正対応に比べ低い割合であるため、RANSAC[58]のロバスト推定方法によって除去することが可能である。上段・市街地データセットの疑似 EO 画像の中央部分などの局所特徴が弱い領域での対応点は検出されないものの、残りの箇所では多くの対応点が検出されていることが分かる。画像の一部でしか対応点が見つからなかった場合でも、SIFT の特徴点検出/特徴量記述法は局所特徴を計算するため、画像全体を正しく変換できない場合であっても、正しく変換された部分の情報を使用して対応関係を推定することが可能である。

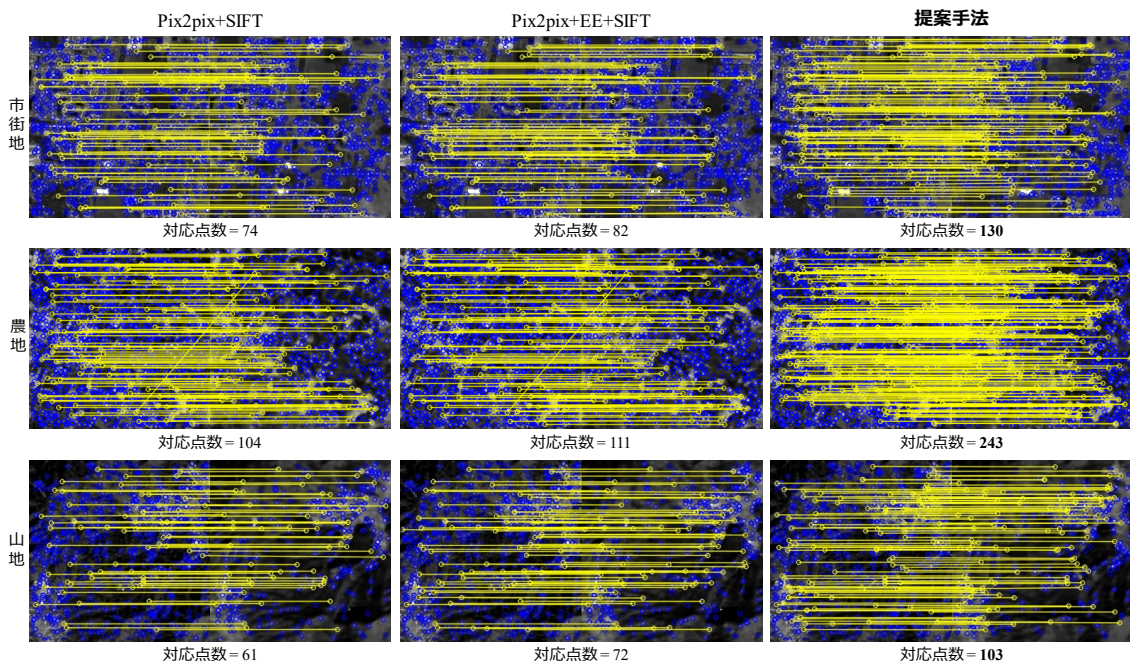


図 3-12 対応点探索の結果

図 3-13 に，平面仮定を置いた系において，提案手法を用いて SAR 画像から EO 画像への画像レジストレーションを施した実例を示す．画像データは前出の SEN1-2 を用いた．2 次元射影変換は，EO 画像と疑似 EO 画像の間の対応点探索結果から推定され，最終的に SAR 画像を 2 次元射影変換によって EO 画像上へ投影しレジストレーションを実現する．図 3-13 の結果より，提案手法によって高精度な画像レジストレーションが達成されていることを確認した．使用したデータセットはあまり広域のものではないこと，平坦な地表の市街地を撮影した画像であることから，平面仮定でも高精度な画像レジストレーションが可能であったと考えられる．あるいは，平面仮定がおけない場合であっても，必要に応じて，対応点の情報から 3 次元投影を推定することも可能である [59, Ch. 6]．




図 3-13 平面仮定における SAR および EO 画像のレジストレーションの例

対象となる EO 画像（図 a）に SAR 画像を重畳するために、EO 画像と疑似 EO 画像の局所的な特徴の対応関係を求めた後、推定された 2 次元射影変換を用いて元の SAR 画像を EO 画像に重畳する（図 b）。図 c は SAR 画像をチェッカーボード状に透過した画像である。図 d は道路に沿って黄色線を引いたもので、SAR と EO 画像間の画像レジストレーションが高精度で行われていることが確認できる。

第4章 EO 画像と低空撮影画像の間の対応点探索

本章では、図 4-1 に示す低空撮影画像（ドローン画像）と EO 画像（EO 衛星画像）のように、空間分解能が大きく異なる画像間の対応点探索の手段として、低空間分解能の画像に対して超解像処理を施すことで空間分解能を高め、同時に高空間分解能の画像に対して縮小処理を施し、2 画像の空間分解能を揃えて対応点探索処理の精度を高める手法を提案する。



ドローン画像 (4.0 cm/画素)

EO衛星画像 (48 cm/画素)

図 4-1 想定する空間分解能の違い

ドローンによる低空撮影画像は、地上数十 m～数百 m の高度から撮影されたものであり、GIS の EO 画像と比較して高空間分解能である。また、状況に応じて任意のタイミングで撮影を行うことが可能であるため時間分解能の向上にも寄与する。

4.1. 特徴的な領域の画像超解像による空間分解能の大きく異なる 2 画像間の対応点探索

俯瞰画像中の人工構造物は、比較的単純な形状で構成されていることに着目し、空間分解能の低い画像に対して超解像処理を施すことによって 2 画像の空間分解能の差を縮め、対応点探索の精度向上を実現する。この際、超解像倍率が高すぎると、不自然なテクスチャ（アーティファクト）の発生によって対応点探索精度が低下する問題が存在する。提案手法では、超解像度処理によるアーティファクトの発生を抑制しつつ可能な限り高い空間分解能を算出する方法を採用し、その倍率を用いて、図 4-2 に示すように、低空間分解能画像（以下、“LR 画像”と呼ぶ）の超解像度処理と、高空間分解能画像（以下、“HR 画像”と呼ぶ）の縮小処理を同時に行った後、対応点探索処理を行うことで、空間的分解能が高くかつ推定精度の高い画像レジストレーション処理を実現する。

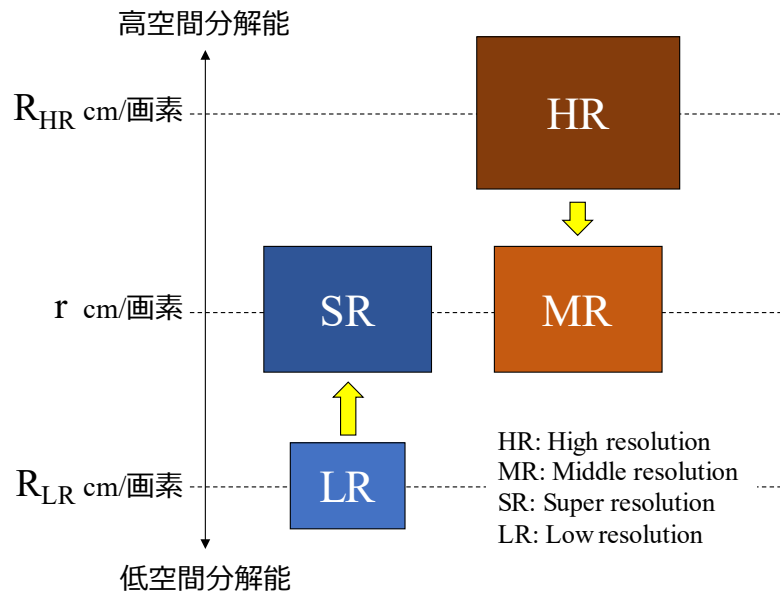


図 4-2 提案する適応的スケーリングの概要図

LR 画像への超解像の適用で超解像画像(SR 画像)を, HR 画像への縮小処理の適用で中間の空間分解能画像(MR 画像)を得て, 空間分解能の揃った両画像間に対応点探索を行う.

目標空間分解能 r を更新しながら適切な超解像の倍率を推定する本提案手法の流れを図 4-3 に示す.

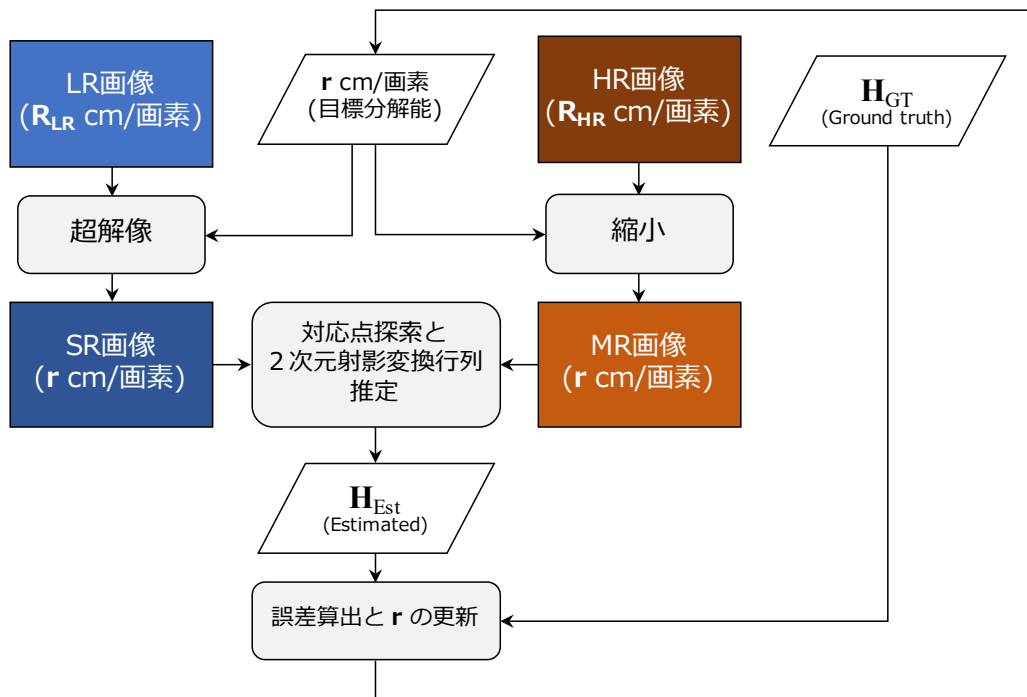


図 4-3 対応点探索に適した空間分解能を推定する処理の流れ

提案手法は大きく四つの処理からなる．空間分解能が低い EO 画像（LR 画像）に対して目標空間分解能 r cm/画素まで超解像を施し超解像画像（以下，“SR 画像”と呼ぶ）を得る処理（4.2 章），空間分解能が高い低空撮影画像（HR 画像）を縮小して SR 画像と同じ中間の空間分解能 r cm/画素をもつ画像（以下，“MR 画像”と呼ぶ）を得る処理（4.3 章），SR 画像と MR 画像との間に対応点探索を行い対応点情報から 2 次元射影変換行列 \mathbf{H}_{Est} を推定する処理（4.4 章），正解の 2 次元射影変換行列 \mathbf{H}_{GT} から \mathbf{H}_{Est} の推定誤差を算出し， r を更新する処理（4.5 章）である．

4.2. 局所領域の超解像処理

HR 画像と，LR 画像との間に対応点探索を実現するため，LR 画像に対して超解像処理を施し，SR 画像を生成する処理について述べる．本論文では，超解像処理として DNN ベースの手法を採用する．対応点探索を目的とした局所領域の超解像を行う DNN（以下，“超解像 DNN”と呼ぶ）を訓練するには，訓練データとして，対応点の検出に有効な領域を与える必要がある．図 4-4 に訓練データの生成プロセスを示す．ドローンで市街地を撮影した HR 画像群に対して SIFT 特徴点検出を施し，得られた特徴点周りの領域をパッチとして抽出する．また，HR 画像に対して縮小処理を行って LR 画像を生成する．LR 画像上において，HR 画像のパッチ領域と同じ領域からパッチを抽出する．この際，特徴点のサイズ（特徴点検出の際に用いた特徴点周辺領域の直径）が小さすぎると，LR 画像の空間分解能に満たない場合がある．そこで，HR 画像での特徴点検出の際，特徴点サイズも参照し，適切な閾値を用いて一定以上のサイズを有する特徴点周辺でのみパッチ抽出を行う．その際の閾値は HR 画像と LR 画像の空間分解能の倍率に従って決定する．




図 4-4 局所領域を推定する超解像 DNN を訓練するデータセットの生成プロセス

HR 画像上で特徴点検出を行ってその周辺領域をパッチとして抽出し，LR 画像の同じ領域からもパッチを抽出する．

4.3. 空間分解能と対応点探索精度を考慮した縮小処理

対応点探索を行う 2 画像の空間分解能を揃える処理について述べる。高精度な特徴点検出・特徴量記述・特徴点マッチングを実現するには、2 画像の空間分解能が揃っていることが望ましい [19]。LR 画像を超解像処理によって HR 画像の空間分解能に揃えて対応点探索を行うことが理想的であるが、超解像の倍率が大きくなるにつれ、DNN による推定にアーティファクトが出現し対応点探索の精度が低下する。そこで、対応点探索の精度が低下しない程度に高倍率の超解像処理を LR 画像に施し、HR 画像をそれに合わせるように縮小して HR 画像と LR 画像の中間の空間分解能をもつ MR 画像を生成し、空間分解能を揃えて対応点探索処理を行う。縮小処理の際には、モアレ（干渉縞）の発生を防ぐため、縮小倍率に応じた平滑化フィルタを事前に適用した後に縮小処理を施す。

4.4. 超解像画像と中間空間分解能画像の対応点探索と 2 次元射影変換行列の算出

提案手法における超解像処理は、構造物のエッジやコーナーの特徴を推定することが目的であるため、特徴点検出器は、それらの特徴を効率的に検出できるものであることが望ましい。また、ドローンを用いた低空撮影画像に方位情報が保持されとは限らないため、回転の変化に頑健な対応点探索が可能な特徴点検出器である必要がある。提案手法では、そのような条件を鑑み、特徴点検出器に ORB[25]、特徴量記述器に SIFT を用いる。ORB 特徴点検出器は、エッジやコーナー特徴を高速に検出可能な FAST[60]をベースにした手法であり、ORB はそれに加え特徴点検出に際して輝度勾配方向も算出するため、上述した条件に合致する。得られた対応点情報を用いて RANSAC のロバスト推定を行い、対応関係を推定する。図 4-5 に対応点探索と画像レジストレーションの例を示す。




図 4-5 ORB+SIFT による対応点探索（左）と、画像レジストレーションの例（右）

左図における青点是对应点が見つからなかった特徴点を示し、黄点是对应点が見つかった特徴点を示す。対応点同士を黄色線で結んで表示している。右図は、それら対応点情報から2次元射影変換を算出し低空撮影画像をEO画像に重畳させた結果である。

4.5. 推定された2次元射影変換の誤差算出

推定された2次元射影変換行列の誤差 ε を以下のように定式化する。

$$\varepsilon = \frac{r}{R_{LR}} \cdot \frac{1}{N} \sum_i^N \|\mathbf{H}_{\text{Est}} \mathbf{p}_i - \mathbf{H}_{\text{GT}} \mathbf{p}_i\| \quad (8)$$

ここで、図 4-3 に示したように、 R_{LR} はLR画像の空間分解能、 r はSR画像とMR画像の空間分解能を示す。 \mathbf{H}_{Est} と \mathbf{H}_{GT} はそれぞれ、対応点情報より推定した2次元射影変換行列と、正解の2次元射影変換行列を意味する。 N は、図 4-6 に示すように、MR画像上に格子状に配置した点の点数であり、 \mathbf{p}_i はその i 番目の格子点の座標ベクトルである。すなわち誤差 ε は、これら格子状に配置した点をそれぞれ \mathbf{H}_{Est} 、 \mathbf{H}_{GT} で2次元射影変換したときのユークリッド誤差の平均に空間分解能のバイアスを掛け合わせた、LR画像における画素誤差を意味している。




図 4-6 誤差算出の概略

R_{LR} は 48 cm/画素, r は 48, 24, 16, 12, 6, 4 cm/画素の場合で実験を行った. 2次元射影変換の正解値 \mathbf{H}_{GT} は, 手動で対応点を 4 ペア取得し算出した.

4.6. 評価実験

本章で提案する対応点探索の定量評価実験を行った. 超解像処理に代わり bicubic 法による画素補間を施した場合の結果との比較も行う.

4.6.1. 評価指標

低空撮影画像と EO 画像の間の対応点探索の精度を直接評価するには, 低空撮影画像の全画素が EO 画像に射影される正解の変換が求まっている必要があるが, 低空撮影画像は高度高々百 m からの撮影であるのに対し, EO 画像は高度数 km から数百 km からの撮影であり, 後者の画角は非常に狭角であるためほぼ平行投影と見なせるので, 高さのある物体も含めた全ての被写体に対して正解の射影変換を求めることは困難である.

そこで, 本実験では, 平面と見なせる地面領域から 4 点以上の対応点を手動で選出することで正解の 2次元射影変換を予め用意し, 4.5 節の手法によって得られる対応点情報から推定される 2次元射影変換との誤差を評価指標とする, これは, 地面領域を平面と見なせるので, 高精度な 2次元射影変換行列が推定できることは, 高精度な対応点探索がなされていることと同値と見なせるためである.

4.6.2. 訓練データセット

訓練データセット用の HR 画像として、2019 年 9 月 19 日に東京都大島町にてドローンで市街地を空撮した画像を用いた。ドローンは DJI 社の Phantom 4 を用い、HR 画像の空間分解能は 4.0 cm/画素である。HR 画像を目標とする超解像の倍率に基づいて縮小し、LR 画像を得た。特徴点サイズの閾値は 12.0 画素とし、また、図 4-7 に示すように、パッチ抽出の際にはランダムシフトを加えた。これは、事前の実験より、ランダムシフト無しの場合、パッチ中央に常に特徴点が位置することから SR 画像中に点状のアートファクトの出現が認められたためである。訓練用データセットのパッチサイズは 128 画素×128 画素、枚数は約 36000 枚とした。訓練データセットの画像の各画素深度は符号無し 8 bit RGB であったが、これをまずグレースケール変換し 1 チャンネルにした後、 $[0, 255]$ の範囲の輝度値を $[-1, 1]$ の範囲に線形に正規化し訓練の入力とした。




図 4-7 パッチ抽出の際のランダムシフト

4.6.3. 評価データセット

評価用のデータセットとして、HR 画像には埼玉県秩父郡横瀬町にてドローンで市街地を空撮した画像を、また、LR 画像として同地域を Maxar 社の GeoEye-1 衛星で撮影したパンクロマチック画像をそれぞれ用いた。HR 画像と LR 画像の空間分解能はそれぞれ 4.0 cm/画素と 48 cm/画素である。LR 画像から約 490 m 四方（1024 画素×1024 画素）を切り取り、その領域内の一部を撮影した HR 画像（4000 画素×3000 画素）を 7 パターン選定した。画像の各画素深度は HR 画像が符号無し 8 bit グレースケール、LR 画像が符号無し 16 bit グレースケールである。HR 画像に関しては、 $[0, 255]$ の範囲の輝度値を $[-1, 1]$ の範囲に線形に正規化し、LR 画像は、輝度平均 μ と標準偏差 σ をそれぞれ計算して $[\mu - 2\sigma, \mu + 2\sigma]$ の範囲の輝度値を $[-1, 1]$ の範囲に線形に正規化して入力とした。図 4-8 に、評価実験に使用した画像を示す。




図 4-8 評価実験に用いた LR 画像と HR 画像

4.6.4. 超解像深層ニューラルネットワークの構成と訓練

超解像 DNN の訓練には， CGAN を用いた． CGAN は， 入力に沿って目的の情報に生成する生成器 (Generator) と， 情報が生成されたものか真のものを識別する識別器 (Discriminator) を用意し， 両者を競い合わせるようにして訓練を進める． この CGAN を利用し， 生成器として LR 画像を入力， SR 画像を出力とする超解像 DNN を訓練する． 図 4-9 に， 生成器すなわち超解像 DNN と識別器に構成を示す． 生成器・識別器の損失関数にはそれぞれ L1 ノルム・バイナリクロスエントロピーを用いた．

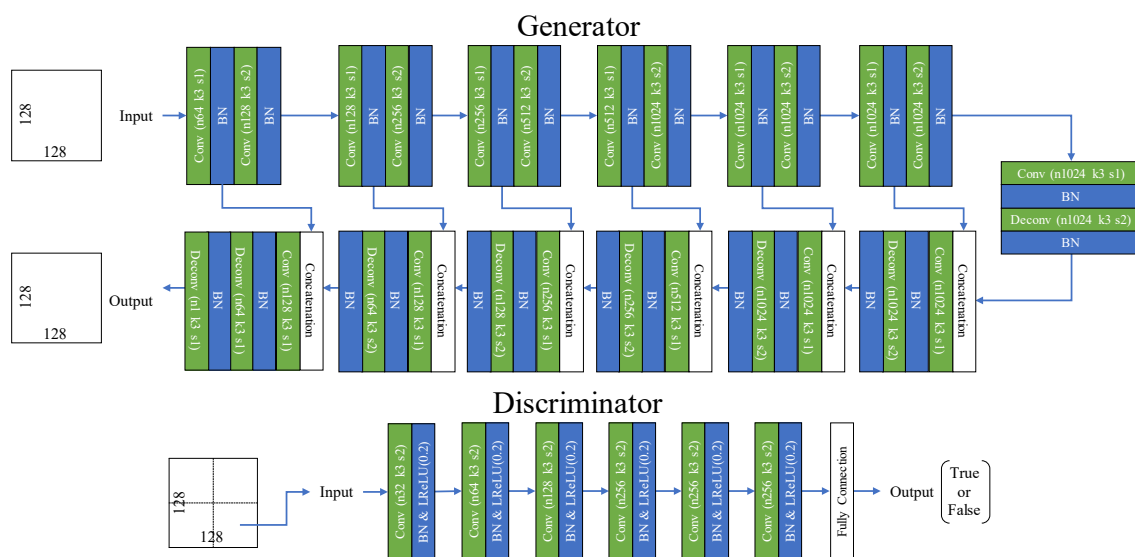


図 4-9 生成器と識別器の構成

Conv:畳み込みレイヤ (n:フィルタ数, k:フィルタサイズ, s:ストライド), BN:バッチ正規化レイヤ, Deconv:逆畳み込みレイヤ, なお生成器の出力層の活性化関数のみ tanh, 他の畳み込み・逆畳み込みレイヤの活性化関数は全て Leaky ReLU (負領域の傾き 0.1) である。

超解像 DNN は, Pre-upsampling の U-Net を採用した. LR 画像に対して一旦 bicubic 法によって HR 画像と同じ画像サイズになるように画素補間を行い, 図 4-9 に示す生成器によって SR 画像を得る. すなわち, 図 4-9 の生成器はデブラーを行う DNN であり, 本実験では bicubic 補間による Pre-upsampling 後にデブラーを行う処理をまとめて超解像としている. 識別器には, 入力を分割して識別を行う PatchGAN を採用する. PatchGAN により入力を分割することで局所領域に着目させることが可能である.

CGAN による訓練の実行には筑波大学計算科学研究センター有する高性能計算機である Cygnus を使い, 学習時間は 72 時間であった. 学習率は生成器・識別器それぞれ 1.0×10^{-3} より開始し, 学習時間 24 時間ごとに半減させた. バッチサイズは 32 とした.

4.6.5. 対応点探索手法

ORB 特徴点検出・SIFT 特徴量記述の実装には OpenCV を用いた. 対応点探索の際, 3.4.1 節で説明した特徴点の回転角の分布にしたがって閾値を設定して誤対応を除去する処理を適用し, その閾値は 15 度とした. 特徴点数は, SR 画像からは 1024 画素×1024 画素あたり 6250 点, MR 画像からはその 10 倍の密度とした.

4.6.6. 結果と考察

表 4-1 は提案手法による実験結果を、表 4-2 は超解像に代わって bicubic 補間を行った場合の実験結果を示すものである。なお r が 48 cm/画素（倍率 1 倍）のときは、超解像も bicubic 補間も行っていないことを意味しており、入力画像が同一であるため結果も同一である。表内で“Failed”と表示されているのは、対応点情報からの 2 次元射影変換の推定に失敗していることを意味している。最下段の“Average”は、2 次元射影変換推定に成功した場合の誤差 ε の平均値である。超解像の倍率が高くなるにつれて誤差が少なく、超解像処理を適用することで空間分解能の大きく異なる画像間のレジストレーションが効果的に行われることを示している。しかし、超解像の倍率が高くなるほど対応点の検出精度が下がるため、本実験においては 4～6 倍程度の超解像が適切であると考えられる。

表 4-1 提案手法による実験結果

	r [cm/pixel]					
	48 (x1)	24 (x2)	12 (x4)	8 (x6)	6 (x8)	4 (x12)
#01	35.16	11.21	20.83	13.61	Failed	Failed
#02	99.15	43.45	9.30	3.87	Failed	Failed
#03	96.61	16.62	17.35	32.42	Failed	Failed
#04	Failed	11.24	3.02	Failed	Failed	Failed
#05	187.45	82.28	56.87	Failed	Failed	Failed
#06	82.18	47.24	10.20	Failed	Failed	Failed
#07	183.05	56.15	29.74	Failed	Failed	Failed
Average	113.9	38.3	21.0	16.6		

表 4-2 Bicubic 補間による実験結果

	r [cm/pixel]					
	48 (x1)	24 (x2)	12 (x4)	8 (x6)	6 (x8)	4 (x12)
#01	35.16	84.03	58.69	119.68	Failed	Failed
#02	99.15	21.40	50.85	25.75	Failed	Failed
#03	96.61	144.72	20.09	27.90	Failed	Failed
#04	Failed	10.624	15.54	Failed	Failed	Failed
#05	187.45	210.65	113.15	Failed	Failed	Failed
#06	82.18	86.10	227.22	Failed	Failed	Failed
#07	183.05	29.02	Failed	Failed	Failed	Failed
Average	113.9	83.8	80.9	57.8		

図 4-10 は対応点探索と画像レジストレーションの結果の一部を示すものである。図 4-10 左に比べ、図 4-10 右は正対応の割合が少ないことがわかる。




図 4-10 超解像倍率 6 倍の結果

正対応割合が高かった画像（#01）と低かった画像（#07）を示している。

図 4-11 は、図 4-10 右の一部を拡大した画像である。本実験では人工構造物を対象として超解像 DNN の訓練パッチデータセットを作成したため、植生領域やあぜ道などの復元は困難である。今回用いた超解像 DNN で対応困難な領域が入力となった場合、訓練パッチの中から比較的似ているテクスチャを当てはめるため、不自然な復元がなされる。その結果、それら不自然な復元がされた領域で誤対応が生じたと考えられる。



図 4-11 6 倍超解像画像（左）と同地点の HR 画像（右）

第5章 低空撮影画像と地上撮影画像の間の対応点探索

低空より鉛直方向を見下ろして撮影された低空撮影画像と、モバイルカメラで撮影された地上撮影画像との間で特徴点マッチングによる対応点探索を行い、幾何的な対応関係を算出する手法を提案する。

モバイルカメラ・車載カメラ・監視カメラなどによる地上撮影画像は、地上数 m～十数 m の高度から撮影されたものであり、GIS の EO 画像と比較して高い空間分解能を有する。また、普及している撮影デバイスの数が EO・SAR・低空撮影に比べて圧倒的に多く、時間分解能の向上にも寄与する。

5.1. 疑似俯瞰画像の生成による低空撮影画像との対応点探索

図 5-1 に示すように、地上撮影画像と低空撮影画像は撮影方向が大きく異なるため、手前の領域は空間分解能が高く、奥ほど低くなるような射影歪みが生じ、直接の対応関係の算出が困難である。その対策として、図 5-2 に示すように、モバイルカメラ画像中に写り込んだ地面領域を射影変換し、あたかも俯瞰視点から見下ろしたような疑似俯瞰画像を生成することによって対応点探索を容易にし、効果的に地上撮影画像と低空撮影画像の間の対応点探索を行うことを可能にする。




図 5-1 撮影方向の違いに起因する地面領域の射影歪み

左図は地上撮影画像、右図は低空撮影画像である。水平な地表を横向きに撮影をすると手前の領域は空間分解能が高く、奥ほど低くなるような歪み（射影歪み）が生じる。

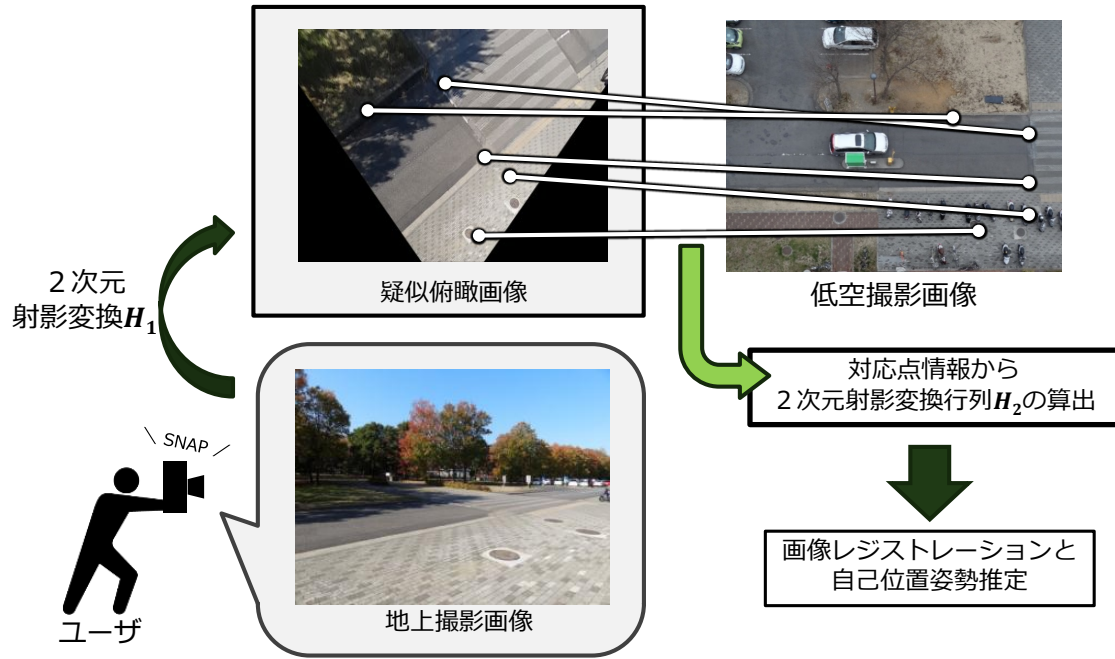


図 5-2 地上撮影画像と低空撮影画像との対応点探索

5.2. 疑似俯瞰画像の生成

図 5-3 に示す疑似俯瞰画像の生成手法について述べる．撮影に用いたカメラの透視投影行列 \mathbf{P} と、そのカメラを回転・平行移動させた俯瞰視点カメラの透視投影行列 \mathbf{P}' は、カメラの内部パラメータ行列 \mathbf{K} 、それぞれの回転行列 \mathbf{R} と \mathbf{R}' 、3次元位置 \mathbf{c} 、 \mathbf{c}' を用いてそれぞれ

$$\mathbf{P} = \mathbf{K}[\mathbf{R} | -\mathbf{R}\mathbf{c}] \quad (9)$$

$$\mathbf{P}' = \mathbf{K}[\mathbf{R}' | -\mathbf{R}'\mathbf{c}'] \quad (10)$$

と表現できる．回転行列 \mathbf{R} 、 \mathbf{R}' は撮影に用いたモバイル端末に搭載された加速度センサの値を元に算出するものとする．ここで、 \mathbf{R} から \mathbf{R}' への回転による座標変換行列（回転行列）を $\Delta\mathbf{R}$ と定義すると、撮影画像中の任意の点を回転変換 $\Delta\mathbf{R}$ によって射影する 2次元射影変換行列 $\mathbf{H}_{\Delta\mathbf{R}}$ は、(9)(10)式より

$$\mathbf{H}_{\Delta\mathbf{R}} = \mathbf{K}(\Delta\mathbf{R})\mathbf{K}^{-1} \quad (11)$$

であり、加速度センサの重力情報から求めることができる．一方、 \mathbf{c} から \mathbf{c}' への平行移動ベクトル $\Delta\mathbf{c}$ は、

$$\Delta c = c' - c \quad (12)$$

となる． Δc は生成される疑似俯瞰画像の空間分解能に依存する．通常は，対応点探索処理の効率化のために，低空撮影画像の空間分解能と疑似俯瞰画像の空間分解能が同等になるように Δc を設定する．画像中の任意の点を平行移動 Δc に応じて射影する2次元射影変換行列を $H_{\Delta c}$ とすれば，ユーザ視点カメラの撮影画像を俯瞰視点カメラの疑似俯瞰画像へ射影変換する2次元射影変換行列 H_1 は

$$H_1 = H_{\Delta c} H_{\Delta R} \quad (13)$$

と求めることができる．




図 5-3 疑似俯瞰画像生成プロセスの概要図

生成した疑似俯瞰画像の例を図 5-4 に示す．図 5-4 左のような地上撮影画像に対して，撮影に用いたカメラの内部パラメータと撮影時のカメラの姿勢情報から算出した2次元射影変換 H_1 により，図 5-4 右のような疑似俯瞰画像を生成する．地面領域の直線の平行・直角が再現されており，正しく疑似俯瞰画像が生成できていることがわかる．



図 5-4 地上撮影画像（左）と疑似俯瞰画像（右）

5.3. 疑似俯瞰画像と低空撮影画像の間の対応点探索

疑似俯瞰画像と低空撮影画像の間の対応点探索処理と、その結果を用いて疑似俯瞰画像を低空撮影画像に射影変換する 2 次元射影変換行列 \mathbf{H}_2 を推定する手法について説明する。

対応点探索には SIFT を用いる。SIFT によって記述された特徴量は、回転・スケール・照明変化に頑健であるという特長を有する。地上撮影画像を疑似俯瞰画像に変換することにより、両画像間の見え方の変動は、回転とスケール、および照明（天候）変動による明暗変化となるため、SIFT の特性を効果的に活用することが可能となり、図 5-5 に示すように、疑似俯瞰画像と低空撮影画像間の対応点を算出することができる。明暗変動に頑健であることにより撮影時刻の差異に対応可能である。全対応点に含まれる誤対応を除去するため、3.4 節で説明した輝度勾配とスケールを参照した手法を適用する。




図 5-5 疑似俯瞰画像と低空撮影画像の対応点探索

5.4. 地上撮影画像と低空撮影画像の間の 2 次元射影変換行列の算出

5.3 節で述べた対応点探索処理により得られた対応点情報から、RANSAC のロバスト推定によって、疑似俯瞰画像から低空撮影画像への 2 次元射影変換行列 \mathbf{H}_2 を推定する。図 5-6 に示すように、地上撮影画像から低空撮影画像への 2 次元射影変換行列 \mathbf{H} は、モバイルカメラ画像を疑似俯瞰画像に射影変換する 2 次元射影変換行列 \mathbf{H}_1 と、疑似俯瞰画像を低空撮影画像に射影変換する 2 次元射影変換行列 \mathbf{H}_2 の行列積として以下のように表現される。

$$\mathbf{H} = \mathbf{H}_2 \mathbf{H}_1 \quad (14)$$

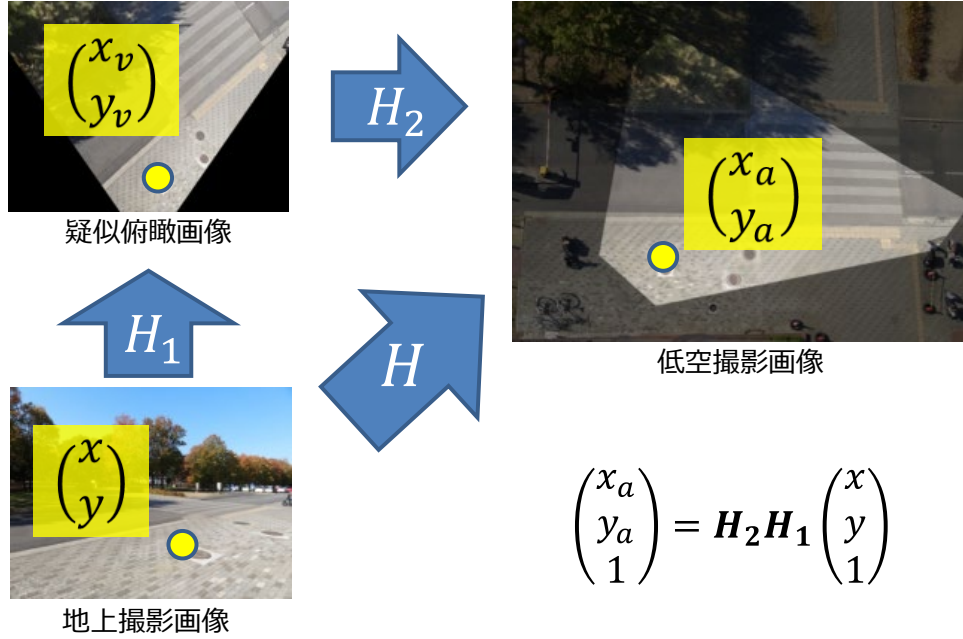


図 5-6 地上撮影画像から低空撮影画像への射影変換行列の算出

5.5. 地上撮影カメラの位置姿勢推定

本節では、求まった2次元射影変換行列から、低空撮影画像の座標系におけるモバイルカメラの位置姿勢推定を行う手法について説明をする。なお、本章で用いる低空撮影画像は、GISのEO画像データベースとの幾何的な関係が既に求まっていることを想定している。すなわち、低空撮影画像の各画素は地理座標系の座標値を有しており、低空撮影画像の座標系におけるモバイルカメラの位置姿勢の推定が可能であるならば、それは地理座標系における位置姿勢が推定可能であることを意味する。

平面から平面への2次元射影変換行列とカメラの内部パラメータ行列 \mathbf{K} が既知であるとき、それらから射影変換元の座標系におけるカメラの3次元位置と姿勢を求めることが可能である[61]。本節では、(14)式の2次元射影変換行列を用いて、地上撮影カメラの位置・姿勢を推定する手法を述べる。

(14)式の \mathbf{H} は、地上撮影画像から低空撮影画像への2次元射影変換行列なので、低空撮影画像からモバイルカメラ画像への2次元射影変換行列は \mathbf{H} の逆行列 \mathbf{H}^{-1} である。ここで、 \mathbf{h}_1 、 \mathbf{h}_2 、 $\mathbf{h}_3 \in \mathbb{R}^3$ を用いて

$$\mathbf{H}^{-1} \stackrel{\text{def}}{=} [\mathbf{h}_1 \ \mathbf{h}_2 \ \mathbf{h}_3] \in \mathbb{R}^{3 \times 3} \quad (15)$$

とすると，3次元空間における回転ベクトル \mathbf{r}_1 ， \mathbf{r}_2 ， \mathbf{r}_3 と並進ベクトル \mathbf{t} はカメラの内部パラメータ行列 \mathbf{K} と(15)式より，

$$\mathbf{r}_1 = \frac{\mathbf{K}^{-1}\mathbf{h}_1}{\|\mathbf{K}^{-1}\mathbf{h}_1\|} \quad (16)$$

$$\mathbf{r}_2 = \frac{\mathbf{K}^{-1}\mathbf{h}_2}{\|\mathbf{K}^{-1}\mathbf{h}_2\|} \quad (17)$$

$$\mathbf{r}_3 = \mathbf{r}_1 \times \mathbf{r}_2 \quad (18)$$

$$\mathbf{t} = \frac{\mathbf{K}^{-1}\mathbf{h}_3}{\|\mathbf{K}^{-1}\mathbf{h}_1\|} = \frac{\mathbf{K}^{-1}\mathbf{h}_3}{\|\mathbf{K}^{-1}\mathbf{h}_2\|} \quad (19)$$

と表現できるので，3次元空間における地上撮影カメラの回転行列 \mathbf{R} と位置ベクトル \mathbf{c} は，

$$\mathbf{R} = [\mathbf{r}_1 \ \mathbf{r}_2 \ \mathbf{r}_3] \quad (20)$$

$$\mathbf{c} = -\mathbf{R}^T \mathbf{t} \quad (21)$$

と算出することができる．

5.6. 評価実験

提案手法の有用性を確認するため，筑波大学構内においてドローン撮影によって得られた低空撮影画像と，タブレット端末を用いた地上撮影で得られた画像を用いた実験を行った．

地上撮影画像から疑似俯瞰画像を生成し，ドローンで撮影した高空間分解能な低空撮影画像を用いて，地上撮影カメラの位置姿勢推定実験を行った．低空撮影画像を段階的にリサイズし，低空撮影画像の空間分解能と，地上撮影カメラの位置姿勢推定の精度との相関関係を検証する．

5.6.1. 評価指標

地上撮影画像と低空撮影画像の間の対応点探索の精度を直接評価するには，地上撮影画像の全画素が低空撮影画像に射影される正解の変換が求まっていなくてはならないが，数十枚の地上撮影画像に対してその正解の変換を求めることは困難である．

そこで、本実験では、地上撮影の際に地上撮影カメラの位置と姿勢を計測し、対応点情報から算出される 2 次元射影変換行列から推定した、地上撮影カメラの位置と姿勢の推定誤差を評価指標とする。これは、撮影場所が平面と仮定できる平坦な地面であるため、地上撮影カメラの位置姿勢が 2 次元射影変換行列より高精度に求まることは、高精度な対応点探索がなされていることと同値と見なせるためである。

5.6.2. 実験環境・使用機材・データセット

実験環境と用いた機材・データセットについて説明する。撮影場所は筑波大学中央図書館前広場で、低空撮影画像の撮影には、図 5-7 に示す、FREEFLY SYSTEMS 社のドローンである CineStar 6 を使用した。ドローンに設置したカメラは Canon EOS 6D で、レンズは Canon EF4028STM を用いた。ドローンの下部にカメラを鉛直下向きに設置し、地上およそ 20 m の高さまで飛んで撮影した。撮影時刻は 2013 年 12 月 5 日の午前 7 時頃である。撮影された低空撮影画像を図 5-8 に示す。画像サイズは 5472 画素×3648 画素で、空間分解能はおよそ 0.74 cm/画素である。Google Map において都心周辺の空撮画像として手に入るものがおよそ 12.5 cm/画素の空間分解能であることから、本実験では低空撮影画像の空間分解能を段階的に落とし、0.74, 1.0, 2.0, 3.0, 4.0, 5.0, 6.0, 7.0, 8.0, 9.0, 10.0, 11.0, 12.0, 13.0 cm/画素の 14 パターンで位置姿勢推定を実施する。



図 5-7 撮影に用いたドローン




図 5-8 実験に用いた低空撮影画像

地上撮影画像の撮影用の携帯端末として、ASUS 社の、GPS・加速度センサを搭載したタブレット端末 ASUS Pad TF700T (Android ver4.2.1 OS) を使用した。撮影時の高さを固定するために、図 5-9 のように、三脚に設置した状態で撮影を行った。カメラのレンズ部分の高さは 150 cm に設定した。広場の 4 地点から計 34 枚を撮影し、撮影と同時に加速度センサの値を取得して、その計測値を元に疑似俯瞰画像を生成した。図 5-10 に撮影した画像データセット、図 5-11 に撮影地点と撮影方位を示す。



図 5-9 地上撮影画像の取得に用いたタブレット端末の設置




図 5-10 実験に用いた地上撮影画像




図 5-11 低空撮影画像中における地上撮影の地点と方位

5.6.3. 結果と考察

図 5-12 に各空間分解能における取得回数のグラフを示す。これは、全 34 画像のうち、疑似俯瞰画像と低空撮影画像の間の SIFT を用いた対応探索の結果、対応点数が必要数に達しておらず 2 次元射影変換行列の算出に失敗していると判断可能なデータを除いた、モバイルカメラの位置と姿勢を出力可能なデータが得られた数を示している。




図 5-12 誤差平均算出のサンプル数

また、図 5-13 にモバイルカメラの位置姿勢推定の誤差を記したグラフを示す。有効数字は 3 桁とする。これらの数値は、図 5-12 に示したサンプルについてのみ取得している。

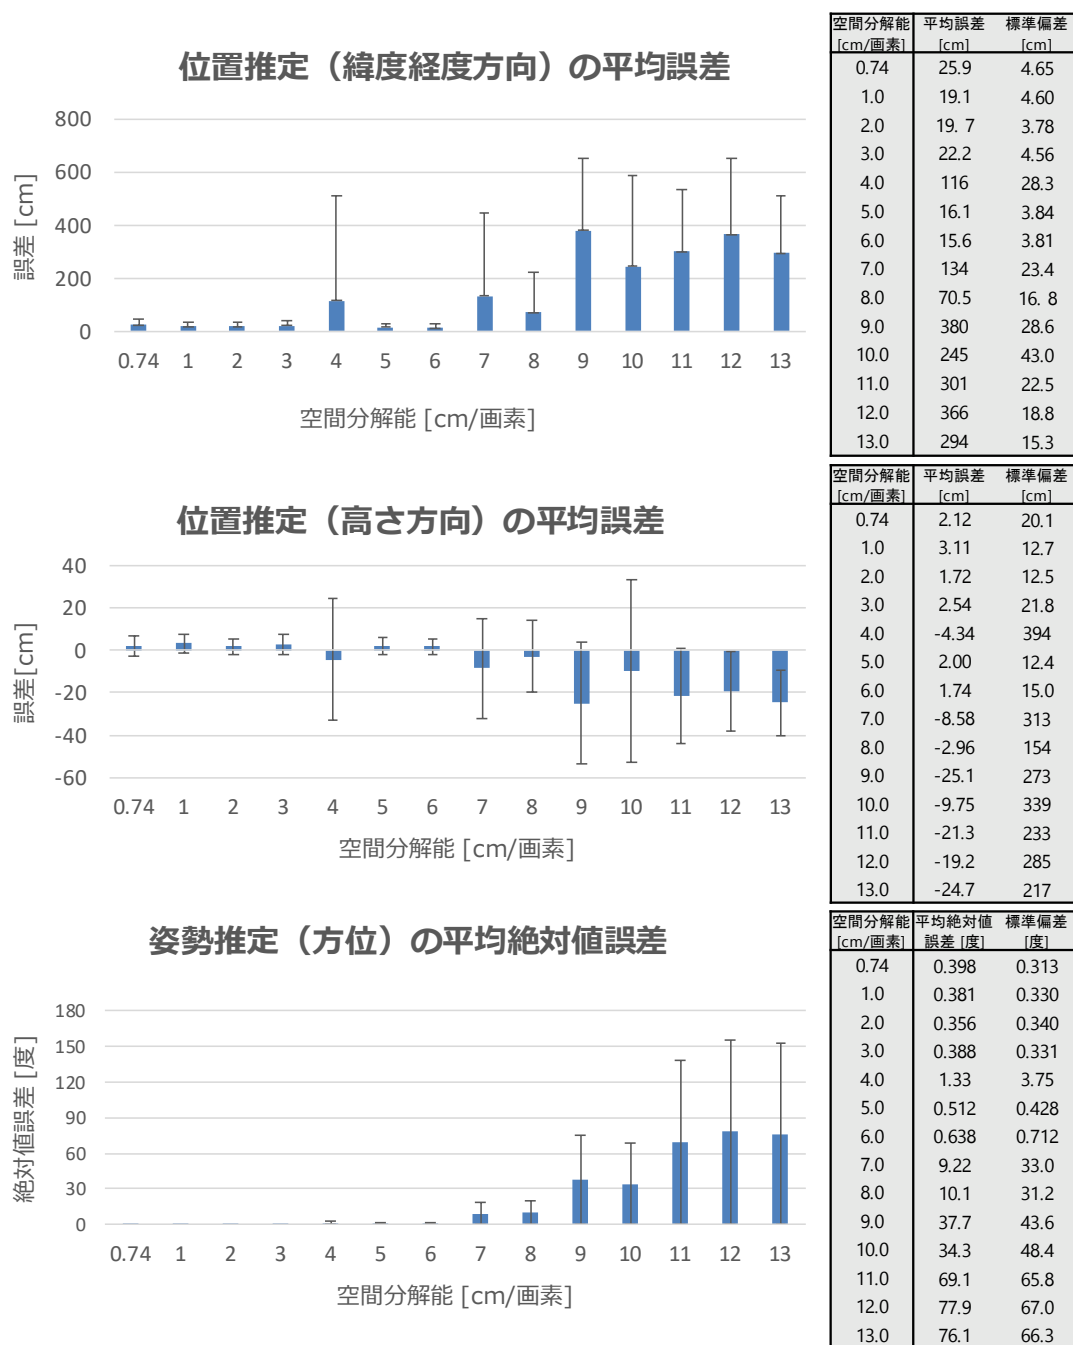


図 5-13 地上撮影カメラの位置姿勢推定結果

カメラ位置推定の誤差とそのグラフ（上段）、カメラ高さ推定の誤差とそのグラフ（中段）、カメラ方位推定の誤差とそのグラフ（下段）

図 5-12 より、低空撮影画像の空間分解能が 6 cm/画素より低くなると 2 次元射影変換行列の算出に失敗しやすくなることがわかる。この結果は、図 5-13 に示した位置姿勢推定の誤差が大きくなる空間分解能ともほぼ一致している。4.0 cm/画素の場合だけ位置推定の平均誤差が大きくなっているのは図 5-14 のグラフでわかるように 2 枚の画像で 13 m 以上の大きな誤差が出たためである。




図 5-14 空間分解能 4.0 cm/画素の場合の位置推定誤差

図 5-15 のヒストグラムと図 5-16 の誤対応除去の結果を見ると、最も頻度の高いビンが窓枠問題 (Aperture problem) [59, Ch. 4]により生じる誤対応であり数が多かったため、5.2 節の誤対応除去の手法では対応できず、本来誤対応として除去されるべき対応点が正対応として抽出されてしまっている。しかし図 5-15 を見ると、2 次元射影変換行列の推定に十分な数の正対応が検出されているので、誤対応除去の手法の工夫によっては改善が期待できる。




図 5-15 空間分解能 4 cm/画素の場合の対応点ペアの方向差分値ヒストグラム

ビン番号 190 付近は本来誤対応であるが最頻値であったため False positive として抽出されてしまっている。ビン番号 350 付近は False negative である。




図 5-16 誤対応除去に失敗した例

画像の空間分解能以外に、対応点探索の精度に影響する要素として、地面テクスチャが考えられる。図 5-17 は、空間分解能の違いによって生じる実験場所の地面テクスチャの見え方の違いを示すものである。実験場所は、図 5-17 に示すように、30 cm×60 cm のタイルが 1~3 cm 程度の隙間を空けて敷き詰められている。空間分解能が 6 cm/画素より粗くなると、タイルとタイルの隙間が表現できなくなり全体的に平坦なテクスチャとなってしまう特徴点の検出に必要な輝度勾配が失われるため、対応点探索の精度が低下するものと考えられる。




図 5-17 空間分解能の違いにより生じる実験場所の地面テクスチャの見え方の違い

図 5-18 は、実際の地上撮影画像と対応点探索の結果の一例を示したものである。疑似俯瞰画像を生成することでSIFTによる対応点探索が効果的に機能していることが確認できる。図 5-19 は、得られた対応点情報より、モバイルカメラの推定位置・方位と地上撮影画像を、低空撮影画像上へマッピングした結果の図である。図 5-19 左の、境界を拡大した図に見られるように地面のタイルの縁が綺麗に繋がっており、提案手法により高精度な対応点探索と画像レジストレーションが実現されていることが確認できる。




図 5-18 地上撮影画像（左）と低空撮影画像との対応点探索の結果（右）

右図では対応点を黄色線で結んで表示している。




図 5-19 モバイルカメラの推定位置・方位と地上撮影画像をマッピングした結果
対応点探索により高精度な画像レジストレーションが実現されていることが確認できる。

第6章 各手法を統合した異高度撮影画像間の対応点探索法の実証実験

第1章で設定した本論文の研究課題の解決法を、第3章、第4章、第5章でそれぞれ説明した。本章では、図6-1に示すように、それらの手法を統合し、現状で実際に入手可能な画像データを用いて、提案する異高度撮影画像間の対応点探索法によってGISの時空間分解能向上を実証する実験を行う。EO画像として、Sentinel-2衛星画像（約12.5 m/画素）・GeoEye-1衛星画像（約50 cm/画素）の2種類を用いるのは、現状で一般に入手可能なSAR画像の空間分解能は高くても数mであり、EO衛星画像の空間分解能が数十cmであることと比べると、本論文で提案したEO画像と低空撮影画像の対応点探索手法が有効に働かないためである。Sentinel-2・GeoEye-1衛星画像は既に各画素に地理情報が付与されておりレジストレーション済みの画像データとしてGISにて管理されているため、両者は空間分解能の違いはあるが同じ撮影形態の画像と見なすことができる。

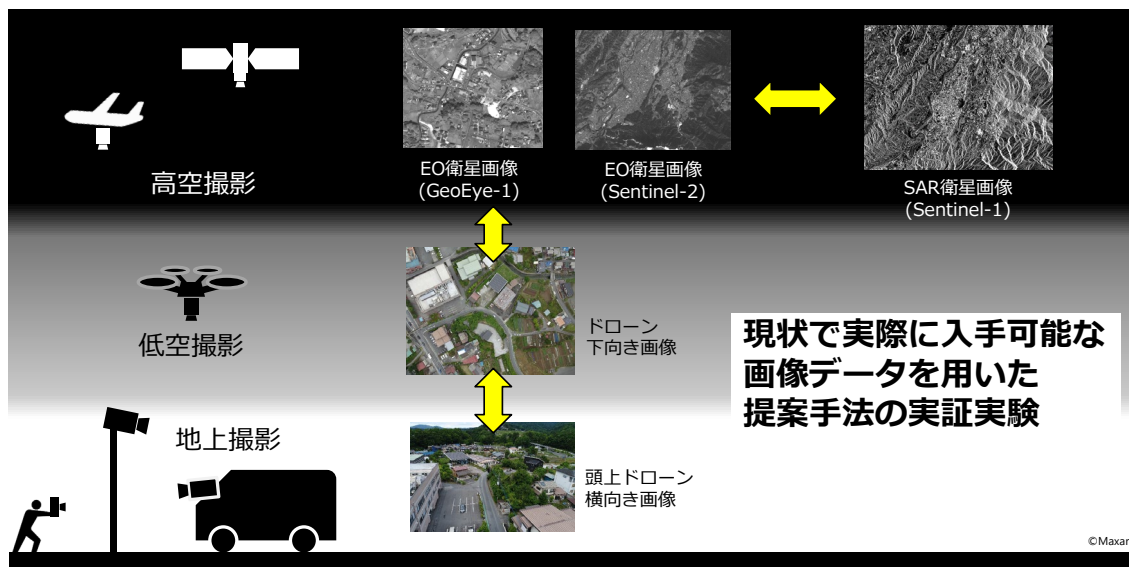


図 6-1 本章における実験の概要

図6-2に実験場所の航空写真を示す。実験場所は埼玉県秩父郡横瀬町で、山間部の市街地であり本手法を適用するには適切であると考えられる。実験データセットには、埼玉県秩父郡横瀬町の共通の領域を撮影したEO画像・SAR画像・低空撮影画像・地上撮影画像を用いた。




図 6-2 実験場所の埼玉県秩父郡横瀬町の航空写真
画像は地理院地図[13]より取得した。

6.1. 実験詳細

6.1.1. データセット

6.1.1.1. SAR 画像から疑似 EO 画像を生成する画像変換 DNN の学習データセット

EO 画像として欧州宇宙局の Sentinel-2A, Sentinel-2B 衛星の画像を, SAR 画像として同じく欧州宇宙局の Sentinel-1A 衛星画像を用いた。2019 年 1 月 1 日から 12 月 31 日までの期間に Sentinel-2A・Sentinel-2B 衛星で実験場所を含む領域を撮影された 67 画像(図 3-1)のうち, 実験場所の上空に雲がかかっていない 16 枚を選定し, 撮影日の近い Sentinel-1 衛星画像をそれぞれペアとして選定した。表 6-1 に選定した画像データセットを示す。16 枚のうち 1 枚は検証データセットとした。

表 6-1 画像変換 DNN の学習に用いた画像データセットの撮影日時
 ハイライト行は、検証データセットを意味する。

SAR 衛星画像 Satellite: Sentinel-1 Relative orbit number: 46		EO 衛星画像 Satellite: Sentinel-2 Relative orbit number: 74	
号機	撮影時刻 (UTC)	号機	撮影時刻 (UTC)
A	2019/01/03 - 20:43	B	2019/01/03 - 01:30
A	2019/01/15 - 20:43	B	2019/01/13 - 01:30
A	2019/01/27 - 20:43	B	2019/01/23 - 01:29
A	2019/02/08 - 20:43	B	2019/02/12 - 01:27
A	2019/02/20 - 20:43	A	2019/02/17 - 01:27
A	2019/03/04 - 20:43	A	2019/03/09 - 01:26
A	2019/03/16 - 20:43	B	2019/03/14 - 01:26
A	2019/03/28 - 20:43	B	2019/03/24 - 01:26
A	2019/04/09 - 20:43	B	2019/04/13 - 01:26
A	2019/04/21 - 20:43	A	2019/04/18 - 01:27
A	2019/05/03 - 20:43	A	2019/04/28 - 01:27
A	2019/05/15 - 20:43	B	2019/05/13 - 01:27
A	2019/10/06 - 20:43	B	2019/10/10 - 01:26
A	2019/10/30 - 20:43	B	2019/10/30 - 01:27
A	2019/11/11 - 20:43	B	2019/11/09 - 01:28
A	2019/11/23 - 20:43	A	2019/12/04 - 01:30

それぞれの画像ペアは、国土地理院の基盤情報ダウンロードサービス[62]より得た DEM を用いてレジストレーションを行い、それぞれの空間分解能を 12.5 m/画素として画素毎に重なり合うようにした。その画像から 256 画素×256 画素のパッチを縦横 128 画素毎に切り出し、訓練データセットとして 896 枚、検証データセットとして 56 枚を用意した。また、日照条件の変化による輝度分布の変化に頑健性を持たせるため、訓練・検証データセットの輝度平均 μ と標準偏差 σ をそれぞれ計算し、 $[\mu - 2\sigma, \mu + 2\sigma]$ の範囲の輝度値を $[-1, 1]$ の範囲に線形に正規化して訓練・検証に用いた。

6.1.1.2. EO 画像に適用する超解像 DNN の学習データセット

4.6.2 節と同じデータセットを超解像 DNN の学習データセットとして用いた。HR 画像として、2019 年 9 月 19 日に東京都大島町にてドローンで市街地を空撮した画像を用いた。ドローンは DJI 社の Phantom 4 を用い、HR 画像の空間分解能は 4.0 cm/画素である。HR 画像を 1/4

のサイズに縮小し LR 画像を得た．特徴点サイズの閾値は 12.0 画素とした．パッチサイズは 128 画素×128 画素，枚数は約 36000 枚である．訓練データセットの画像の各画素深度は符号無し 8 ビット RGB であったが，これをまずグレースケール変換し 1 チャンネルにした後，[0,255]の範囲の輝度値を[-1,1]の範囲に線形に正規化し入力とした．

6.1.1.3. 評価データセット

低空撮影画像としてドローンで高度 100 m 程度から鉛直下向き撮影を行った画像を，地上撮影としてドローンで高度約 15 m から斜め撮影を行った画像をそれぞれ使用した．これらドローンを用いた撮影は，2019 年 6 月 8 日に実施された．

EO 画像として，実験場所が雲で遮蔽されておらず，かつ低空撮影画像と地上撮影画像の撮影日に最も近い GeoEye-1 衛星画像（48 cm/画素）と Sentinel-2 衛星画像（12.5 m/画素）を用いた．SAR 画像として，Sentinel-1・Sentinel-2 衛星画像のなかでドローンの撮影日に最も近い撮影日のものを評価データとして用いた．ただし，2019 年 6 月 8 日に最も近い撮影日の Sentinel-2 画像中の実験場所は雲による遮蔽が生じていたため，疑似 EO 画像との対応点探索を行う Sentinel-2 画像は，雲に遮蔽されていない画像の中で 2019 年 6 月 8 日以前に撮影されたものを選定した．表 6-2 に用いた評価データセットを示す．

表 6-2 評価データセットの撮影時刻

SAR 画像 Satellite: Sentinel-1A Relative orbit number: 46	撮影時刻: 2019/06/08 - 20:43 (UTC)
EO 画像 Satellite: Sentinel-2B Relative orbit number: 74	撮影時刻: 2019/05/13 - 01:27 (UTC)
EO 画像 Satellite: GeoEye-1	撮影時刻: 2019/05/08 - 01:29 (UTC)

6.1.2. SAR 画像を疑似 EO 画像に変換する画像変換 DNN の訓練

画像変換 DNN の構成は 3.5.2.1 節で示したものと同一である．訓練に用いた画像サイズは 256 画素×256 画素，入力バッチサイズは 16，訓練時間は 12 時間を要した．生成器と識別器の学習率は， 1.0×10^{-3} とした．損失関数はそれぞれ，L1 ノルムとバイナリクロスエントロピーを用いた．また，PatchGAN のパッチのサイズは 128 画素×128 画素に設定した．計算機として筑波大学計算科学研究センターの高性能計算機 Cygnus を用いた．訓練時間については，図 6-3 に示す

生成器（画像変換 DNN）の検証データにおける損失関数の値に長時間変化が現れないことが確認されたため 12 時間で訓練を打ち切り，検証データにおける損失関数が最小値 1.668×10^{-1} であったパラメータを用いて画像変換 DNN を構成した．




図 6-3 画像変換 DNN の訓練における生成器の損失関数のグラフ

青線は訓練データに対する損失関数，オレンジ線は検証データに対する損失関数の値をそれぞれ示すものである．

6.1.3. EO 画像に適用する超解像 DNN の訓練

超解像 DNN の構成は 4.6.4 節で示したものと同一である．訓練に用いた画像サイズは 256 画素 \times 256 画素，入力バッチサイズは 128，訓練時間は 48 時間を要した．生成器と識別器の初期の学習率は 1.0×10^{-3} とし，24 時間後に半減させた．損失関数はそれぞれ，L1 ノルムとバイナリクロスエントロピーを用いた．また，PatchGAN のパッチのサイズは 64 画素 \times 64 画素に設定した．計算機として筑波大学計算科学研究センターの高性能計算機 Cygnus を用いた．訓練時間については，図 6-4 に示す生成器（画像変換 DNN）の検証データにおける損失関数の値に長時間変化が現れないことが確認されたため 48 時間で訓練を打ち切り，検証データにおける損失関数が最小値 7.775×10^{-2} であったときのパラメータを用いて超解像 DNN を構成した．




図 6-4 超解像 DNN の訓練における生成器の損失関数のグラフ

青線は訓練データに対する損失関数，オレンジ線は検証データに対する損失関数の値をそれぞれ示すものである。

図 6-5 は，用いた超解像 DNN による超解像の結果の一部を示すものである．とくに構造物のエッジやコーナーにおいて超解像が有効に働いていることが確認できる。



図 6-5 EO 画像と超解像画像

それぞれの空間分解能は，入力 of EO 画像が 48 cm/画素，超解像画像が 12 cm/画素である。

6.2. 実験結果

6.2.1. EO 画像と SAR 画像の間の対応点探索と画像レジストレーション

図 6-6 は、評価データセットの Sentinel-1 画像と、それを入力として 3.2 節と 6.1.2 節で説明した画像変換 DNN によって得られた疑似 EO 画像を示すものである。




図 6-6 SAR 画像から疑似 EO 画像への変換

左: Sentinel-1 の SAR 画像 (2019 年 6 月 8 日撮影), 右: 疑似 EO 画像

図 6-7 は、SIFT を用いた Sentinel-2 衛星画像と図 6-6 に示した疑似 EO 画像の対応点探索の結果を示すものである。Sentinel-2 画像は、実験場所に雲による遮蔽が生じていないデータセットの中で最もドローン画像の撮影日 (2019 年 6 月 8 日) に近いデータセットであった, 2019 年 5 月 13 日のものを用いている。画像変換 DNN による SAR から疑似 EO 画像への変換が有効に働いており, 対応点が得られていることが確認できる。




図 6-7 Sentinel-2 衛星画像と疑似 EO 画像の対応点探索結果

Sentinel-2 衛星画像は，2019 年 5 月 13 日に撮影された雲による遮蔽のない画像である．

また，図 6-8 は，図 6-7 に示した対応点情報から推定した 2 次元射影変換により Sentinel-2 衛星画像上に疑似 EO 画像と SAR 画像を重畳した結果である．提案手法により高精度な対応点探索と画像レジストレーションが実現できていることが確認された．




図 6-8 Sentinel-2 衛星画像との画像レジストレーション結果

左:疑似 EO 画像の重畳結果と，右:SAR 画像の重畳結果，を示す．重畳先の EO 画像は，2019 年 5 月 13 日に撮影された Sentinel-2 衛星画像である．

6.2.2. EO 衛星画像と低空撮影画像の間の対応点探索

EO 衛星 (GeoEye-1) 画像に対して超解像処理を施すことで SR 画像を, 低空撮影画像 (ドローン画像) には縮小処理を施すことで MR 画像を得て, ORB 特徴点検出と SIFT 特徴量記述によって対応点探索を行った. 超解像の倍率は, 4.6.6 節の結果を踏まえ, 安定した結果が期待できる 4 倍に設定した. 図 6-9 は, SR 画像と MR 画像の対応点探索結果を示すものである.




図 6-9 GeoEye-1 衛星画像と低空撮影画像の対応点探索結果

図 6-10 は, 図 6-9 に示した対応点情報から推定した 2 次元射影変換行列により低空撮影画像を GeoEye-1 衛星画像に重畳した結果である. 超解像処理と縮小処理が有効に働き, 空間分解能に大きな違いのある GeoEye-1 衛星画像と低空撮影画像の間で適切な画像レジストレーションが実現されていることが確認された.



図 6-10 GeoEye-1 衛星画像と低空撮影画像の画像レジストレーション

6.2.3. 低空撮影画像と地上撮影画像の間の対応点探索

低空撮影画像と地上撮影画像の間の対応点探索のために、地上撮影画像の地面領域の射影歪みを補正し疑似俯瞰画像を生成する。地上撮影に用いたカメラの内部パラメータとカメラの俯角は、事前のカメラキャリブレーションと撮影時のドローンの姿勢情報より取得した。図 6-11 は、ドローンで撮影した低空撮影画像と、地上撮影画像より得た疑似俯瞰画像との間の対応点探索結果を示すものである。地上撮影画像の手前にある平面領域においてとくに対応点が多く検出できていることが確認される。




図 6-11 低空撮影画像と地上撮影画像より作成した疑似俯瞰画像の対応点探索結果

6.2.4. EO 画像への画像レジストレーション結果

ドローン撮影が行われた 2019 年 6 月 8 日に最も近い撮影日の Sentinel-2 衛星画像の撮影日は、前日の 2019 年 6 月 7 日であったが、雲による遮蔽が生じていた。しかし、SAR は雲を透過しての撮影が可能であるため、図 6-12 に示すように、SAR 画像より得られた疑似 EO 画像を重畳することで、EO では撮影ができない状況でも地表の状況を把握することが可能となり、本論文の目的である GIS の時間分解能の向上が可能である。




図 6-12 Sentinel-2 衛星画像と SAR 画像の重畳結果
Sentinel-2 衛星画像の撮影日は 2019 年 6 月 7 日である。

また、図 6-13 は、EO 画像と、SAR 画像・低空撮影画像・地上撮影画像の対応点探索結果から画像レジストレーションを行った結果を示すものである。本論文の目的である GIS の時空間分解能の向上が、EO・SAR・低空撮影・地上撮影の画像群の対応点探索によって実現されていることが確認できる。

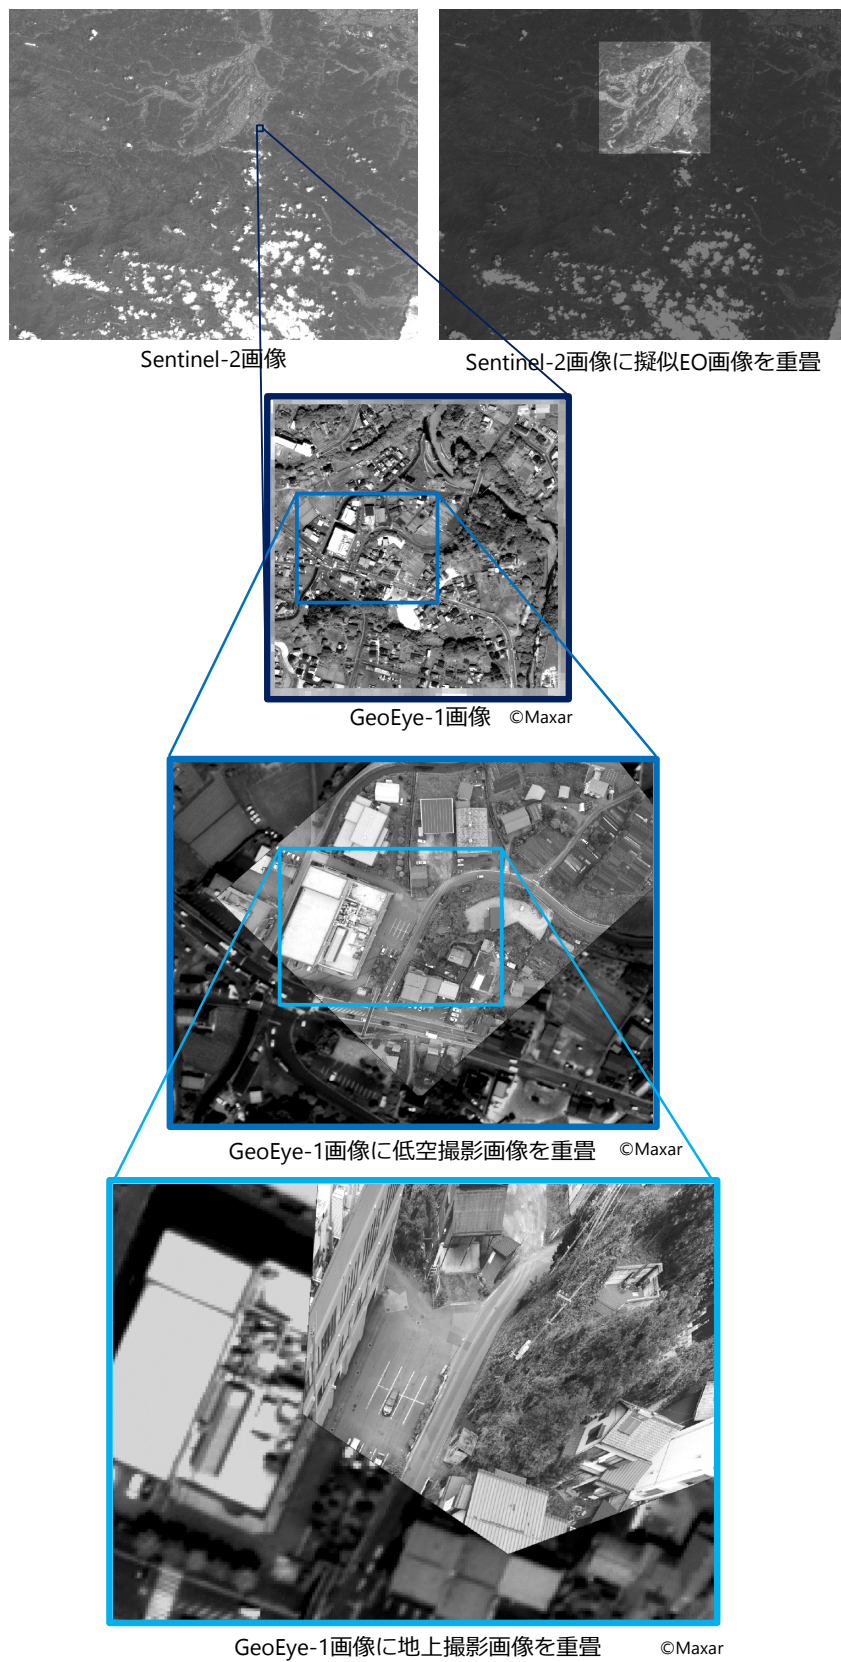


図 6-13 EO 衛星画像と低空撮影・地上撮影画像のレジストレーション結果

図 6-14 は、特に提案手法が有効に働いている領域を拡大して並べたものである。図 6-14 左図では視認できないマンホールが図 6-14 中央では視認できるようになり、さらに図 6-14 右では、地上撮影画像による更なる高空間分解能化によって地面のひび割れや水たまりなども視認が可能となっていることが確認できる。



GeoEye-1衛星画像

低空撮影画像

地上撮影画像

図 6-14 提案手法による空間分解能向上の結果

また、本論文の提案手法の適用により、GIS データベースの地理情報を含む画像と、地上撮影画像との幾何的な対応関係の算出が可能となるため、図 6-15 に示すように横向き撮影された地上撮影画像座標へ幾何変換することも可能である。



地上撮影画像

低空撮影画像を重畳

GeoEye-1衛星画像を重畳

Sentinel-1衛星画像を重畳

図 6-15 地上撮影視点へ画像を重畳した結果
それぞれ透明度 0.25 でオーバーレイしている。

GIS の EO 画像への画像レジストレーションには、撮影機器の位置姿勢情報に加え、人手の GCP 選出が必要であったが、本論文の提案する画像ベースの手法によって、SAR・低空撮影・地上撮影の画像であっても地理情報を自動的に付与することが可能となり、従来の GIS では実現できなかった高い時空間分解能を実現可能であることが本実験によって確認された。

第7章 結論

衛星や航空機を用いたりリモートセンシングによって可視光を観測して得られた EO 画像が防災の分野で一般化している。これらは撮影時のセンサ情報・地形情報・人手の調整などによって各画素に地理情報が付与され、GIS のデータベースで管理される。この EO 画像と、SAR 画像や地上撮影の画像データの間で幾何的な対応関係の算出が可能となれば、数分～数時間の高時間分解能の撮影による変化検出や、数 cm～数十 cm の高空間分解能の局所領域撮影による変化検出が可能となり、現状の GIS では対処が困難な災害発生直後の被災地の局所的な状況把握に有用である。本論文では、屋外環境を撮影する手法をその撮影高度の違いによって EO・SAR・低空撮影・地上撮影の四つに分類し、以下に示す三つの課題を設定し解決することで、異高度撮影画像間に対する対応点探索により幾何的な対応関係を算出し GIS の画像情報の時空間分解能を向上させる手法を提案した。

- 観測波長の異なる 2 画像、とくに、EO 衛星画像より得られた EO 画像と SAR 衛星より得られた SAR 画像における、観測する電磁波の波長の差により画像上での見え方の差が生じ、共通の画像特徴の抽出が困難である状況下での対応点探索の実現。
- 撮影高度の異なる 2 画像、とくに、EO 衛星画像より得られた EO 画像とドローンより得られた低空撮影画像における、空間分解能に大きな差が生じており局所特徴が損なわれている状況下での対応点探索の実現。
- 撮影方向の異なる 2 画像、とくに、ドローンにより得られた低空撮影画像とモバイルカメラにより得られた地上撮影画像における、共通して写り込む地面領域に射影歪みが生じている状況下での対応点探索の実現。

これら各課題に対して提案手法の評価を行い、有効性を確認した。以降にそれらをまとめる。

EO 画像と SAR 画像の間の対応点探索

モードの異なる 2 画像 (EO 画像・SAR 画像) に対応点探索処理を適用する方法として、CGAN により訓練された DNN をベースとした画像変換 DNN を用い、SAR 画像を疑似 EO 画像に変換してモードを揃えた後に、対応点探索を行う方法を提案した。画像変換 DNN により、この SAR 画像から疑似 EO 画像を取得した後、モードが揃った画像 (疑似 EO 画像と EO 画像) 間に対応点探索処理を実行し、最終的に SAR 画像と EO 画像の対応点を検出する。Pix2pix の生成器による SAR 画像から疑似 EO 画像への変換では、ブラーが生じて局所特徴が損なわれるという課題があったが、提案手法では、訓練データにエッジ強調フィルタを適用することで、局所特徴を強く学習するように生成器の訓練を行うことで改善した。

既にレジストレーション済みの EO 画像・SAR 画像がペアになった画像データセットを用いて、対応点探索の精度を定量的に評価することにより、提案手法によって得られた生成器によっ

て生成された疑似 EO 画像と元の EO 画像の間で、既存の手法と比較してもより高精度な対応点探索を実現できることが確認された。

これにより、EO 画像だけでは雲による遮蔽で時間分解能が低下する場合であっても、雲を透過して撮影が可能な SAR 画像との幾何的な対応関係の算出によって、GIS の時間分解能の向上に貢献するものであると確認された。

EO 画像と低空撮影画像の間の対応点探索

EO 画像と低空撮影画像の間での対応点探索手法を提案した。EO 衛星画像とドローン画像を対象とした、空間分解能が大きく異なる画像間での対応点探索を実現する。低空間分解能の画像に対してアーティファクトの影響を抑えつつ超解像処理を施すことで空間分解能を高め、2 画像の空間分解能を揃える処理を適用した。

埼玉県秩父郡横瀬町を実験場所とし、同実験場所を撮影した EO 衛星画像とドローン画像を用いた定量的な評価実験により、12 倍の空間分解能の違いのある 2 画像に対し、4~6 倍の超解像を適用することで高精度な対応点探索処理が実現できることを確認した。

これにより、GIS の EO 画像では実現困難な、任意のタイミングの撮影による高時間分解能と、数 cm オーダーの高空間分解能を実現し、GIS の時空間分解能の向上に貢献するものであると確認された。

低空撮影画像と地上撮影画像の間の対応点探索

低空撮影画像と地上撮影画像の間での対応点探索手法を提案した。地上撮影は、カメラの撮影方向が低空撮影と異なるため両者に共通して写り込む地面領域に射影歪みが存在し、対応点探索の精度を低下させていた。そこで提案手法では、地上撮影に用いたカメラの内部パラメータと加速度センサで測定した重力方向から、あたかも俯瞰視点から撮影したような疑似俯瞰画像を生成することで射影歪みを補正し、対応点探索を実現した。

対応点探索の精度を検証するため、対応点情報から撮影に用いたモバイル端末の自己位置姿勢推定を行う実験を行った結果、6.0 cm/画素の空間分解能をもつ低空撮影画像を用いれば、およそ平均誤差 17 cm 以下の位置推定、絶対値平均誤差 0.6 度以下の方位推定が可能であることを確認した。この自己位置姿勢推定精度は、GPS などの衛星測位による自己位置推定より高精度であり、屋外 AR など、屋外において正確な位置姿勢の推定が必要となるシーンへの本手法の応用の可能性を示すものであり、高精度な対応点探索がなされていることを確認した。

これにより、GIS の EO 画像では実現困難な、任意のタイミングの撮影画像による高時間分解能と、数 cm オーダーの高空間分解能を実現し、GIS の時空間分解能の向上に貢献するものと確認された。

また、本論文の提案手法によって、EO・SAR・低空撮影・地上撮影の四つの異高度の撮影形態により得られた実践的な画像群を、一つのシステムに統合し、GIS の時空間分解能の向上を実証した。

本提案手法の応用例としては、災害直後の被災箇所の情報共有が考えられる。本手法の適用によって、道路の陥没や小規模な構造物の倒壊など、高空撮影では撮影が困難な局所的な変化の撮影とその情報共有が容易になる。また、発災直後、高空撮影を待たずに即時の情報共有が可能になる。別の応用例としては、屋外 XR (AR: Augmented Reality, VR: Virtual Reality, MR: Mixed Reality の総称) が考えられる。図 6-15 に示したように、GIS の情報を地上撮影視点に重畳提示するシステムの実現が可能である。ただし、図 6-15 右下のように、衛星画像を直接地上撮影視点に重畳すると、空間分解能の違いにより有用な情報を提示する事ができないため、高空撮影画像から抽出した情報をベクタレイヤに変換して地上撮影視点に重畳表示するなど、空間分解能の差違を考慮したシステムを構築する必要がある。

今後の更なる展望としては、クラウドソーシング[63][64]により収集された画像群に対して本提案手法を適用することで、あらゆる地点の高時空間分解能化が可能となり、現状の GIS とは一線を画す言わば“次世代型 GIS”の構築が期待できる。この次世代型 GIS は、撮影デバイスの差違・撮影場所の差違・撮影時間の差違を超えた情報の瞬時の共有を実現するものであり、実現すれば情報インフラとして社会に必要不可欠な情報源として役立つものと確信している。本論文がその実現の一助になれば幸いである。

謝辞

本学位論文の執筆にあたり、終始懇切丁寧な御指導を賜りました、本学大学院システム情報工学研究科・北原格教授に心より感謝の意を表します。研究内容や論文執筆に関する御指導に加え、研究とは何か、研究者とはどうあるべきか、研究者である以前に社会人として如何にあるべきか等、厳しく優しい御助言の数々は私にとって何より価値あるものでした。改めて感謝申し上げます。

本学画像情報研究室に在籍した計6年間、本学・大田友一名誉教授、本学大学院システム情報系・亀田能成教授、ならびに本学計算科学研究センター・宍戸英彦助教には、ゼミやミーティングを通し色々な御助言を頂きましたことを心より御礼申し上げます。

博士学位論文審査において、貴重な御助言をいただいた秋田大学国際資源学研究科・川村洋平教授、本学図書館情報系・森嶋厚行教授、本学システム情報系・山口友之助教に心より御礼申し上げます。

豪州 Curtin 大学・Ashraf Dewan 博士 (School of Earth and Planetary Sciences) には、ジオサイエンス・リモートセンシング分野の御指導・御助言を頂きました。また留学中の研究生生活のサポートもしていただきました。心より御礼申し上げます。

最後に、職を辞しての博士後期課程進学という私の決断に対し、理解し応援してくれた両親と兄弟姉妹に心より感謝いたします。

参考文献

- [1] 土屋清, リモートセンシング概論. 朝倉書店, 1990.
- [2] 山崎文雄, “防災におけるリモートセンシング技術利用の 最新動向,” 土木技術, vol. 68, no. 12, pp. 9–14, 2013.
- [3] K. Cho *et al.*, “Rapidmap project for disaster monitoring,” in *Asian Conference on Remote Sensing*, 2014.
- [4] 佐土原聡, Ed., 時空間情報プラットフォーム. 東京大学出版会, 2010.
- [5] 近津博文, 熊谷樹一郎, 佐田達典, 鹿田正明, and 淵本正隆, 空間情報工学概論. 日本測量協会, 2005.
- [6] 橋本雄一, G I S と地理空間情報. 古今書院, 2019.
- [7] J. Le Moigne, N. Netanyahu, and R. Eastman, *Image Registration for Remote Sensing*. Cambridge University Press, 2011.
- [8] J. R. Jensen, *Introductory Digital Image Processing: A Remote Sensing Perspective*, 4th ed. Prentice Hall Press, 2016.
- [9] H. Floyed M and L. Anthony J, *Principles and applications of imaging radar. Manual of remote sensing: Third edition, Volume 2*, Third edit. John Wiley & Sons, Inc., 1998.
- [10] 大内和夫, リモートセンシングのための合成開口レーダの基礎, 2nd ed. 東京電機大学出版局, 2009.
- [11] 大内和夫 *et al.*, レーダの基礎. コロナ社, 2017.
- [12] “Google Maps.” [Online]. Available: <https://maps.google.com/>. [Accessed: 01-Jan-2021].
- [13] “地理院地図 (電子国土Web).” [Online]. Available: <https://maps.gsi.go.jp>. [Accessed: 20-Oct-2020].
- [14] M. Schmitt, L. H. Hughes, and X. X. Zhu, “THE SEN1-2 DATASET for DEEP LEARNING in SAR-OPTICAL DATA FUSION,” in *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2018, vol. 4, no. 1, pp. 141–146, doi: 10.5194/isprs-annals-IV-1-141-2018.
- [15] 内山庄一郎, 必携 ドローン活用ガイドー災害対応実践編ー. 東京法令出版, 2020.
- [16] 野波健蔵, ドローン産業応用のすべてー開発の基礎から活用の実際までー. コロナ社, 2018.
- [17] 野波健蔵, 続・ドローン産業応用のすべてー進化する自律飛行が変える未来ー. コロナ社, 2020.
- [18] K. Mikolajczyk and C. Schmid, “A performance evaluation of local descriptors,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 27, no. 10, pp. 1615–1630, Oct. 2005, doi: 10.1109/TPAMI.2005.188.
- [19] S. A. K. Tareen and Z. Saleem, “A comparative analysis of SIFT, SURF, KAZE, AKAZE,

- ORB, and BRISK,” in *International Conference on Computing, Mathematics and Engineering Technologies*, 2018, vol. January, pp. 1–10, doi: 10.1109/ICOMET.2018.8346440.
- [20] 藤吉弘亘 *et al.*, コンピュータビジョン最先端ガイド 2. 2010.
- [21] Y. Xiang, F. Wang, and H. You, “OS-SIFT: A Robust SIFT-Like Algorithm for High-Resolution Optical-to-SAR Image Registration in Suburban Areas,” *IEEE Trans. Geosci. Remote Sens.*, 2018, doi: 10.1109/TGRS.2018.2790483.
- [22] M. I. Patel, V. K. Thakar, and S. K. Shah, “Image Registration of Satellite Images with Varying Illumination Level Using HOG Descriptor Based SURF,” in *Procedia Computer Science*, 2016, vol. 93, pp. 382–388, doi: 10.1016/j.procs.2016.07.224.
- [23] D. G. Lowe, “Distinctive image features from scale-invariant keypoints,” *Int. J. Comput. Vis.*, vol. 60, no. 2, pp. 91–110, Nov. 2004, doi: 10.1023/B:VISI.0000029664.99615.94.
- [24] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, “Speeded-Up Robust Features (SURF),” *Comput. Vis. Image Underst.*, 2008, doi: 10.1016/j.cviu.2007.09.014.
- [25] E. Rublee, V. Rabaud, K. Konolige, and G. Bradski, “ORB: An efficient alternative to SIFT or SURF,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2011, pp. 2564–2571, doi: 10.1109/ICCV.2011.6126544.
- [26] P. F. Alcantarilla, A. Bartoli, and A. J. Davison, “KAZE features,” in *European Conference on Computer Vision*, 2012, doi: 10.1007/978-3-642-33783-3_16.
- [27] P. F. Alcantarilla, J. Nuevo, and A. Bartoli, “Fast explicit diffusion for accelerated features in nonlinear scale spaces,” in *British Machine Vision Conference*, 2013, doi: 10.5244/C.27.13.
- [28] D. DeTone, T. Malisiewicz, and A. Rabinovich, “SuperPoint: Self-supervised interest point detection and description,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 224–236.
- [29] A. B. Laguna, E. Riba, D. Ponsa, and K. Mikolajczyk, “Key.Net: Keypoint detection by handcrafted and learned CNN filters,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2019, vol. 2019-Octob, pp. 5835–5843, doi: 10.1109/ICCV.2019.00593.
- [30] M. Calonder, V. Lepetit, C. Strecha, and P. Fua, “BRIEF: Binary robust independent elementary features,” in *European Conference on Computer Vision*, 2010, pp. 778–792, doi: 10.1007/978-3-642-15561-1_56.
- [31] S. Leutenegger, M. Chli, and R. Y. Siegwart, “BRISK: Binary Robust invariant scalable keypoints,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2011, pp. 2548–2555, doi: 10.1109/ICCV.2011.6126542.
- [32] A. Alahi, R. Ortiz, and P. Vandergheynst, “FREAK: Fast retina keypoint,” in *IEEE*

- Conference on Computer Vision and Pattern Recognition*, 2012, pp. 510–517, doi: 10.1109/CVPR.2012.6247715.
- [33] Y. Tian, B. Fan, and F. Wu, “L2-Net: Deep learning of discriminative patch descriptor in Euclidean space,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2017, vol. 2017-Janua, pp. 6128–6136, doi: 10.1109/CVPR.2017.649.
 - [34] A. Mishchuk, D. Mishkin, F. Radenović, and J. Matas, “Working hard to know your neighbor’s margins: Local descriptor learning loss,” in *Advances in Neural Information Processing Systems*, 2017, pp. 4827–4838.
 - [35] E. Simo-serra, “Learning to Simplify: Fully Convolutional Networks for Rough Sketch Cleanup,” 2016.
 - [36] K. Enomoto, K. Sakurada, W. Wang, N. Kawaguchi, M. Matsuoka, and R. Nakamura, “Image translation between SAR and optical imagery with generative adversarial nets,” in *International Geoscience and Remote Sensing Symposium*, 2018, pp. 1752–1755, doi: 10.1109/IGARSS.2018.8518719.
 - [37] I. J. Goodfellow *et al.*, “Generative adversarial nets,” in *Advances in Neural Information Processing Systems*, 2014, vol. 3, no. January, pp. 2672–2680.
 - [38] A. Radford, L. Metz, and S. Chintala, “Unsupervised representation learning with deep convolutional generative adversarial networks,” in *International Conference on Learning Representations*, 2016.
 - [39] M. Mirza and S. Osindero, “Conditional Generative Adversarial Nets,” Nov. 2014.
 - [40] T. Miyato and M. Koyama, “cGANs with projection discriminator,” in *International Conference on Learning Representations*, 2018.
 - [41] P. Isola, J. Y. Zhu, T. Zhou, and A. A. Efros, “Image-to-image translation with conditional adversarial networks,” in *IEEE Conference on Computer Vision and Pattern Recognition*, 2017, vol. 2017-Janua, pp. 5967–5976, doi: 10.1109/CVPR.2017.632.
 - [42] A. Dame and E. Marchand, “Accurate real-time tracking using mutual information,” in *IEEE International Symposium on Mixed and Augmented Reality*, 2010, doi: 10.1109/ISMAR.2010.5643550.
 - [43] B. Xiong, W. Li, L. Zhao, J. Lu, X. Zhang, and G. Kuang, “Registration for SAR and optical images based on straight line features and mutual information,” in *International Geoscience and Remote Sensing Symposium*, 2016, doi: 10.1109/IGARSS.2016.7729667.
 - [44] Y. Ye, L. Shen, M. Hao, J. Wang, and Z. Xu, “Robust Optical-to-SAR Image Matching Based on Shape Properties,” *IEEE Geosci. Remote Sens. Lett.*, vol. 14, no. 4, pp. 564–568, Apr. 2017, doi: 10.1109/LGRS.2017.2660067.
 - [45] Y. Xiang, R. Tao, F. Wang, and H. You, “Automatic Registration of Optical and SAR Images VIA Improved Phase Congruency,” in *International Geoscience and Remote Sensing*

- Symposium*, 2019, pp. 931–934, doi: 10.1109/IGARSS.2019.8898506.
- [46] Y. Ye, L. Bruzzone, J. Shan, F. Bovolo, and Q. Zhu, “Fast and Robust Matching for Multimodal Remote Sensing Image Registration,” *IEEE Trans. Geosci. Remote Sens.*, vol. 57, no. 11, pp. 9059–9070, Nov. 2019, doi: 10.1109/TGRS.2019.2924684.
 - [47] N. Snavely, S. M. Seitz, and R. Szeliski, “Photo tourism: Exploring photo collections in 3D,” in *ACM SIGGRAPH*, 2006, pp. 835–846, doi: 10.1145/1179352.1141964.
 - [48] M. A. Fonstad, J. T. Dietrich, B. C. Courville, J. L. Jensen, and P. E. Carbonneau, “Topographic structure from motion: a new development in photogrammetric measurement,” *Earth Surf. Process. Landforms*, vol. 38, no. 4, pp. 421–430, Mar. 2013, doi: 10.1002/esp.3366.
 - [49] K. Kobayashi, H. Shishido, Y. Kameda, and I. Kitahara, “A Method to Collect Multi-view Images of High Importance Using Disaster Map and Crowdsourcing,” in *IEEE International Conference on Big Data*, 2019, pp. 3510–3512, doi: 10.1109/BigData.2018.8622193.
 - [50] S. M. Huang, C. C. Huang, and C. C. Chou, “Image registration among UAV image sequence and Google satellite image under quality mismatch,” in *International Conference on ITS Telecommunications*, 2012, pp. 311–315, doi: 10.1109/ITST.2012.6425189.
 - [51] B. Fan, Y. Du, L. Zhu, and Y. Tang, “The registration of UAV down-looking aerial images to satellite images with image entropy and edges,” in *International Conference on Intelligent Robotics and Applications*, 2010, pp. 609–617, doi: 10.1007/978-3-642-16584-9_59.
 - [52] M. Noda *et al.*, “Vehicle ego-localization by matching in-vehicle camera images to an aerial image,” in *Asian Conference on Computer Vision*, 2010, pp. 163–173, doi: 10.1007/978-3-642-22819-3_17.
 - [53] H. Toriya, A. Dewan, and I. Kitahara, “SAR2OPT: Image Alignment between Multi-Modal Images Using Generative Adversarial Networks,” in *International Geoscience and Remote Sensing Symposium*, 2019, doi: 10.1109/IGARSS.2019.8898605.
 - [54] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2015, vol. 9351, pp. 234–241, doi: 10.1007/978-3-319-24574-4_28.
 - [55] C. Li and M. Wand, “Precomputed real-time texture synthesis with markovian generative adversarial networks,” in *European Conference on Computer Vision*, 2016, vol. 9907 LNCS, pp. 702–716, doi: 10.1007/978-3-319-46487-9_43.
 - [56] M. Berger, J. Moreno, J. A. Johannessen, P. F. Levelt, and R. F. Hanssen, “ESA’s sentinel missions in support of Earth system science,” *Remote Sens. Environ.*, vol. 120, pp. 84–90,

- May 2012, doi: 10.1016/j.rse.2011.07.023.
- [57] “OpenCV.” [Online]. Available: <https://opencv.org/>. [Accessed: 16-Sep-2020].
 - [58] M. A. Fischler and R. C. Bolles, “Random sample consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography,” *Commun. ACM*, vol. 24, no. 6, pp. 381–395, Jun. 1981, doi: 10.1145/358669.358692.
 - [59] R. Szeliski, *Computer Vision : Algorithms and Applications*. Springer Verlag, 2009.
 - [60] E. Rosten and T. Drummond, “Machine learning for high-speed corner detection,” in *European Conference on Computer Vision*, 2006, vol. 3951 LNCS, pp. 430–443, doi: 10.1007/11744023_34.
 - [61] Z. Zhang, “A flexible new technique for camera calibration,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 22, no. 11, pp. 1330–1334, 2000, doi: 10.1109/34.888718.
 - [62] “国土地理院 基盤地図情報ダウンロードサービス.” [Online]. Available: <https://fgd.gsi.go.jp/download/menu.php>. [Accessed: 11-Dec-2020].
 - [63] J. Howe, “The Rise of Crowdsourcing,” *Wired Mag.*, 2006, doi: 10.1086/599595.
 - [64] 森嶋厚行 and 喜連川優, クラウドソーシングが不可能を可能にする. 共立出版, 2020.

研究業績

査読付き雑誌論文

- 1) Hisatoshi Toriya, Itaru Kitahara, Yuichi Ohta, “Mobile Camera Localization Using Aerial-View Images,” IPSJ Transactions on Computer Vision and Applications (CVA), Vol.6, pp.111-119, October 2014.

査読付き国際会議論文

- 1) Hisatoshi Toriya, Ashraf Dewan, Itaru Kitahara, “Adaptive Image Scaling for Corresponding Points Matching between Images with Differing Spatial Resolutions,” IEEE Workshop on Human-in-the-Loop Methods and Future of Work in BigData (IEEE HMDData), Atlanta, GA, USA, 8 pages, December 2020.
- 2) Hisatoshi Toriya, Ashraf Dewan, Itaru Kitahara, “SAR2OPT: IMAGE ALIGNMENT BETWEEN MULTI-MODAL IMAGES USING GENERATIVE ADVERSARIAL NETWORKS,” IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Yokohama, Japan, 4 pages, July 2019.
- 3) Hisatoshi Toriya, Kenta Senzaki, Masato Tsukada, Minoru Murata, “ESTIMATING THREE DIMENSIONAL POSITIONS OF PERSISTENT SCATTERERS AND DEVELOPING A PS-INSAR ANALYSIS SYSTEM,” IEEE International Geoscience and Remote Sensing Symposium (IGARSS), INSPEC Accession Number:17397538, Fort Worth, Texas, USA, 4 pages, July 2017.
- 4) Hiromichi Hirata, Ryo Saito, Hideya Tomita, Takakazu Ishii, Yukie Inoue, Hisatoshi Toriya, Minoru Murata, “PS-INSAR ANALYSIS AND ACCURACY EVALUATION OF A KNOWN TARGET WITH HEIGHT CHANGE,” 36th Asian Conference on Remote Sensing (ACRS), Quezon City, Metro Manila Philippines, 2 pages, October 2015.
- 5) Hisatoshi Toriya, Itaru Kitahara, Yuichi Ohta, “A Mobile Camera Localization Method Using Aerial-View Images,” The 2nd Asian Conference on Pattern Recognition (ACPR), INSPEC Accession Number:14197971, Naha, Okinawa, Japan, 5 pages, November 2013.
- 6) Itaru Kitahara, Hisatoshi Toriya, Yuichi Ohta, “A Mobile Camera Localization Method for Updating Topography Map,” The 3rd International Workshop on Soft Computing and Disaster Control (SocDic), Bali, Indonesia, 2 pages, November 2013.

その他の研究発表

- 1) 鳥屋剛毅, Ashraf Dewan, 北原格, “適応的画像スケーリング処理による空間解像度が異なる画像間の対応点探索精度の向上,” 第 61 回 複合現実感研究会(SIG-MR), 北海道, 6 pages, 2020 年 10 月.
- 2) 鳥屋剛毅, Ashraf Dewan, 北原格, “敵対的生成ネットワークを用いた SAR 衛星画像と光学衛星画像の対応点探索法,” 第 60 回 複合現実感研究会(SIG-MR), 奈良, 6 pages, 2020 年 1 月.
- 3) 鳥屋剛毅, 北原格, “注目領域の見え方変化を軽減するバレットタイム映像スタビライジング法,” 画像の認識・理解シンポジウム (MIRU), 北海道, 4 pages, 2018 年 8 月.
- 4) 鳥屋剛毅, 先崎健太, 塚田正人, “PS-InSAR を用いた都市域解析のための PS 点信頼性評価手法,” 日本リモートセンシング学会学術講演会 2017 年秋季大会, 日本リモートセンシング学会学術講演会論文集(CD-ROM) 63rd, ROMBUNNO.B39, 北海道, 4 pages, 2017 年 11 月.
- 5) 鳥屋剛毅, 先崎健太, 塚田正人, “数値表層モデルを用いた PS-InSAR 解析における PS 点対応付けシステム,” 日本リモートセンシング学会学術講演会 2016 年秋季大会, 日本リモートセンシング学会学術講演会論文集(CD-ROM) 61st, ROMBUNNO.P6, 新潟, 2 pages, 2016 年 11 月.
- 6) 鳥屋剛毅, 青木啓史, 塚田正人, “BM3D による SAR スペックル軽減に関する考察,” 電子情報通信学会総合大会, 福岡, 1 page, 2016 年 3 月.
- 7) 鳥屋剛毅, 北原格, 大田友一, “空撮画像との対応点情報を用いたモバイルカメラの位置・姿勢推定手法,” パターン認識・メディア理解研究会 (PRMU), 信学技報, NII 論文 ID (NAID):110009728783, 112(441), pp.1-6, 大阪, 2013 年 2 月.
- 8) 鳥屋剛毅, 北原格, 大田友一, “位置情報付き俯瞰画像を用いたモバイルカメラの位置と方位の推定,” 第 11 回情報科学フォーラム (FIT), 情報科学技術フォーラム講演論文集, NII 論文 ID (NAID):110009622446, 11(3), pp.541-546, 東京, 2012 年 9 月.

特許出願

- 1) 鳥屋剛毅, 戸田真人, “レーダ画像処理装置、レーダ画像処理方法、および記憶媒体,” PCT/JP2019/011209, 2019 年 3 月 19 日.
- 2) 鳥屋剛毅, “情報処理装置、情報処理方法、および記憶媒体,” PCT/JP2017/032973, 2017 年 9 月 13 日.

- 3) 鳥屋剛毅, “情報提供装置、情報提供方法、および記憶媒体,” PCT/JP2017/020172, 2017 年 5 月 31 日.
- 4) 鳥屋剛毅, 田中大地, “情報処理装置、情報処理方法、プログラムを記憶した記憶媒体,” PCT/JP2017/018524, 2017 年 5 月 17 日.
- 5) 鳥屋剛毅, “画像処理装置、画像処理方法および画像処理プログラム,” PCT/JP2017/001535, 2017 年 1 月 19 日.

研究助成

- 1) 科学技術振興機構 (JST) CREST, AIP チャレンジ, “空間解像度が大きく異なる画像間の対応点探索手法,” 2020 年 6 月～2021 年 3 月, 100 万円. (研究代表者)
- 2) 日本学術振興会 (JSPS), 特別研究員 DC2 奨励費, “GIS データの多重解像度化のための多様な撮像系から得た画像群のレジストレーション,” 2019 年 4 月～2021 年 3 月, 170 万円. (研究代表者)
- 3) 科学技術振興機構 (JST) CREST, 海外派遣助成, 2018 年 9 月～2019 年 2 月, 300 万円.
- 4) 科学技術振興機構 (JST) CREST/AIP チャレンジ, “光学衛星画像とレーダ画像を高精度にレジストレーションする手法の開発,” 2018 年 8 月～2019 年 3 月, 100 万円. (研究代表者)