

博士論文

テクスチャ情報と機械学習を組み合わせた

土地被覆分類精度向上に関する応用研究

Applied research on improving land cover classification accuracy
by combining texture information and machine learning.

2024年2月

五十嵐 貴大

目次

第 1 章 序論	1
1.1 背景	1
1.1.1 土地被覆分類.....	1
1.1.2 テクスチャ情報.....	1
1.1.3 Support Vector Machine (SVM)	2
1.2 課題	2
1.3 既往研究	3
1.3.1 マルチスペクトル画像への GLCM 適用事例.....	3
1.3.2 SAR データへの GLCM 適用事例	3
1.4 提案手法	4
1.5 目的	6
1.6 論文構成	6
第 2 章 高分解能マルチスペクトル画像と SAR データの特徴	7
2.1 高分解能マルチスペクトル画像 (UAV 取得画像) の特徴.....	7
2.2 SAR データの特徴.....	8
第 3 章 UAV 取得高分解能マルチスペクトル画像を用いた土地被覆分類精度評価 ..	10
3.1 テストサイトおよび使用データ	11
3.2 研究手法	14
3.2.1 土地被覆分類精度の比較手順.....	14
3.2.2 GLCM 算出用画像作成.....	15
3.2.3 GLCM および GLCM 特徴量算出方法.....	17
3.2.4 特徴ベクトル.....	19
3.2.5 Support Vector Machine (SVM)	20
3.2.6 交差検証を用いた精度評価手法.....	23
3.3 結果	27
3.3.1 土地被覆分類カテゴリとトレーニングデータ抽出.....	27
3.3.2 Stratified CV による土地被覆分類精度評価結果	28
3.3.3 Nested CV による土地被覆分類精度評価結果	32

3.4	考察	35
3.4.1	土地被覆分類におけるテクスチャ情報の有効性.....	35
3.4.2	トレーニングデータ中の影の影響.....	37
3.4.3	Kappa 係数の有意差検定	40
3.5	第 3 章まとめ.....	42
第 4 章	Sentinel-1 SAR データを用いた浸水域抽出	43
4.1	使用データ.....	45
4.2	Sentinel-1 データ前処理	48
4.3	研究手法	51
4.3.1	分類器と入力特徴ベクトル.....	52
4.3.2	テクスチャ情報.....	54
4.3.3	精度評価手法.....	56
4.4	結果	57
4.5	考察	60
4.5.1	浸水域抽出精度比較.....	60
4.5.2	単偏波における浸水域抽出精度比較.....	63
4.6	第 4 章まとめ.....	71
第 5 章	結論	72
5.1	GLCM 特徴量の定量的評価およびテクスチャ情報の有効性	72
5.2	提案手法の有効性と課題.....	72
5.3	最適な GLCM ウィンドウサイズおよびグレーレベル数	74
5.4	まとめおよび今後の課題.....	75
謝辞	76
論文リスト	77
参考文献	79
付録	85
A.	SVM 学習結果一覧.....	86

図表目次

Fig. 1-1 Comparison of the procedures in land cover classification between (a)the conventional research using GLCM features and (b) the proposed method in this research.	5
Fig. 2-1 An example of pixel-based image classification using SVM with high-resolution multi-spectral data.....	8
Fig. 2-2 An example of speckle noise on the VV-polarization image acquired by Sentinel-1B.9	
Fig. 3-1 Test site located at eastern part of Tomioka town in Fukushima prefecture.....	11
Fig. 3-2 RGB Ortho-mosaic image covering our test site.....	12
Fig. 3-3 Mask image to exclude artificial materials, such as houses and cars.	13
Fig. 3-4 Procedure of land cover classification analysis in Chapter 3.	15
Fig. 3-5 Grayscale image used for GLCM calculation.	16
Fig. 3-6 Proposed method for vectorizing GLCM elements.	19
Fig. 3-7 Schematic procedure of Stratified CV (K=5).	24
Fig. 3-8 Schematic diagram for searching parameters by Grid Search. Each grid point indicates an output of Stratified CV.....	25
Fig. 3-9 Schematic procedure of Nested Cross Validation (K=5).....	26
Fig. 3-10 Locations of extracting training samples for each category. (a)forest, (b)grassland, (c)baresoil, and (d)road.	27
Fig. 3-11 Change of land cover classification accuracies with window size and gray level. (a)(B)entropy, (b)(B)energy, (c)(B)contrast, (d)(B)mean, (e)(B)variance, (f)(B)correlation, (g)(B)homogeneity, (h)(B)dissimilarity, (i)(B)all, and (j)C.	30
Fig. 3-12 Example of classification results in Grid Search with Stratified CV. (a)A, (b)(B)entropy, (c)(B)all, and (d)C.	31
Fig. 3-13 Change of land cover classification accuracies with window size and gray level. (a)(B)entropy, (b)(B)energy, (c)(B)contrast, (d)(B)mean, (e)(B)variance, (f)(B)correlation, (g)(B)homogeneity, (h)(B)dissimilarity, (i)(B)all, and (j)C.	33
Fig. 3-14 Example of classification results in Nested Cross Validation. (a)A, (b)(B)entropy, (c)(B)all, and (d)C.	34
Fig. 3-15 Example of the GLCM entropy calculations in different gray level windows.....	36
Fig. 3-16 Locations of extracting training samples after excluding shadow area. (a)forest, (b)grassland, (c)baresoil, and (d)road.	37
Fig. 4-1 Inundation estimation map created by GSI.	46
Fig. 4-2 Test site and categories determined based on Fig. 4-1.	47
Fig. 4-3 Cut out area (972pixel×3739line) covering our test site.	49
Fig. 4-4 8-bit scaled and cutout γ^0 images. (a) VV image acquired on October 7 2019 , (b) VH image acquired on October 7 2019, (c) VV image acquired on October 13 2019, and (d) VH image acquired on October 13 2019.	50
Fig. 4-5 Procedure of inundation area detection.	51

Fig. 4-6 Configuration of input feature vectors. (a)Pattern A: γ^0 only , (b)Pattern B: γ^0 +GLCM texture feature , and	52
Fig. 4-7 Training and test areas selected.	53
Fig. 4-8 An example of GLCM texture and entropy calculation.	55
Fig. 4-9 Accuracy calculation scheme.....	56
Fig. 4-10 Example of inundation detection result images (a)pattern(A), (b)pattern(B)mean, (c)pattern(B)all, and (d)pattern(C).	59
Fig. 4-11 Probability distribution of $p(n)$ for the case of multi-look 4.	61
Fig. 4-12 Input feature vectors of the example images with similar gray level change.....	65
Fig. 4-13 Example of non-flooded built-up area detected by (C)VH ($N_g = 16$) . (a)training area and (b)test area.....	67
Fig. 4-14 VH gray level distribution in training area and test area. (a)correctly detected area and (b)mis-detected area.	68
Fig. 4-15 Example of non-flooded built-up area detected by (C)VV ($N_g = 8$) . (a)training area and (b)test area.....	69
Fig. 4-16 VV gray level distribution in training area and test area. (a)correctly detected area (b)mis-detected area.	70

Table 3-1 Characteristics of RedEdge-M multi-spectral camera.	12
Table 3-2 Summary of PCA analysis	16
Table 3-3 Comparison of maximum accuracies for land cover classification by Stratified K-Folds Cross Validation.....	29
Table 3-4 Comparison of maximum accuracies for land cover classification by Nested Cross Validation.	32
Table 3-5 Comparison of maximum accuracies for land cover classification by Stratified CV for the sampled data in Fig. 3-16.....	38
Table 3-6 Comparison of maximum accuracies for land cover classification by Nested CV for the sampled data in Fig. 3-16.	39
Table 3-7 List of derived Z in Nested CV for the samples in Fig. 3-10.....	41
Table 3-8 List of derived Z in Nested CV for the samples in Fig. 3-16.....	41
Table 4-1 Characteristics of Sentinel-1 SAR data.....	45
Table 4-2 Statistics of γ_0 Images.	49
Table 4-3 Summary of inundation detection results.....	58
Table 4-4 Result of calculation Kappa significant difference in flood area extraction.....	62
Table 4-5 Summary of inundation detection results for single polarization dataset	64
Table A-1 Chapter 4 training results list.....	87

第1章 序論

1.1 背景

1.1.1 土地被覆分類

人工衛星，航空機，および無人航空機（Unmanned Aerial Vehicle : UAV）等のプラットフォームに搭載されたセンサで取得したリモートセンシングデータの利用分野において，土地被覆分類はその代表的な解析手法の一つである¹⁾。これは，画像上のピクセル値（画素値）の特徴から，水域，森林域，およびアスファルト等の土地被覆を同定する解析手法であり，土地被覆図や土地利用図の作成に利用される他，森林，水域，および都市域等の特定の土地被覆の領域検出等に幅広く用いられている²⁾³⁾。

土地被覆分類は実地調査をもとに行われる場合もあるが，多くの場合はコンピュータによる教師あり分類もしくは教師なし分類を用いて行われる。従来の土地被覆分類では最尤法や最短距離法等を用いた統計学的手法が主流⁴⁾⁶⁾であったが，近年ではノンパラメトリックな機械学習的手法を用いた手法がよく使われるようになった⁷⁻⁹⁾。

コンピュータを用いた土地被覆分類では，この分類手法の精度が土地被覆分類結果に大きく影響するため，リモートセンシング分野の解析においては，土地被覆分類の精度向上は非常に重要な研究課題である。また，分類基準や元データの質によって分類精度が左右されるため，これらの基準の定義やデータの選定が重要となるが，リモートセンシング画像において，これら基準を決定することは難しい⁷⁾。

土地被覆分類手法には，ピクセルベース分類とオブジェクトベース分類がある。ピクセルベース分類は画素単位で分類を行う手法であり，オブジェクトベース分類は画素を予めセグメントと呼ばれる要素にグループ化し，セグメント単位で分類を行う手法である。ピクセルベース分類では個々の画素を独立して分類するため，単一画素に収まらない大きな地物や均質でない地物等では誤分類が発生しやすい。オブジェクトベース分類では，ピクセルベース分類よりも分類精度向上が期待でき¹⁰⁾，特に市街地域や森林域等の分類に適している。しかし，調整しなければならないパラメータが多く，設定が複雑になるほか，生成されたセグメントが必ずしも地物と対応しているとは限らない課題がある。

1.1.2 テクスチャ情報

リモートセンシングにおけるテクスチャ情報は，人工衛星画像や航空写真等の地表面画像から計算され，地表面の質感を表した面的な情報を表したものである。テクスチャ情報は，これら地表面画像の領域を識別するための重要な特性の一つであり，地表面の均質さや統計量を含む情報として，土地被覆分類の精度向上に利用されている。ピクセルベースの土地被覆分類では，個々の単一画素を独立して分類するため，周辺

画素の情報を考慮しないことにより分類精度が向上しにくい欠点がある。この欠点を補うために、面的な情報としてテクスチャ情報を利用する手法が研究されている^{11~14)}。

リモートセンシングで使用されるテクスチャ情報として **Gray-Level Co-occurrence Matrix (GLCM)**¹⁵⁾がある。GLCM は注目画素と近傍画素との画素値の出現頻度を表した行列であり、 i 行 j 列目の要素は、注目画素の画素値が i かつ近傍画素の画素値が j である確率として表される。リモートセンシング画像において GLCM は地表面の不均一さを表し、地表面が均一であれば GLCM は対角成分の値が大きくなり、不均一であれば対角から離れた成分が大きくなる傾向がある。

GLCM を使用する土地被覆分類では、その要素から計算される特徴量(以降「GLCM 特徴量」)を使用する。GLCM 特徴量を使用することで、GLCM の冗長性を削減できる。代表的な GLCM 特徴量には、エントロピー、分散、平均(期待値)、およびコントラスト等がある。この GLCM 特徴量を選択して使用することにより土地被覆分類精度向上が行われている^{11~14)}。

1.1.3 Support Vector Machine (SVM)

Support Vector Machine (SVM)¹⁶⁾は教師あり学習の一つである。SVM のアルゴリズムの最も大きな特徴は、マージン最大化と呼ばれる戦略をとることであり、識別境界とそれに最も近い特徴ベクトル(サポートベクトル)との距離が最大となるような識別境界を求めることである。この戦略により、学習データのサンプル数が少ない場合でも比較的良好な識別境界を求めることができ¹⁷⁾¹⁸⁾、入力データが特定の分布に従うことを仮定しないノンパラメトリックな手法になっている。リモートセンシングデータ解析で使用する画像はトレーニングデータを大量に用意することが困難なため、SVM はリモートセンシング分野に適した機械学習アルゴリズムである。また、土地被覆分類においては入力データの分布が仮定できない場合が多く、ノンパラメトリックな機械学習アルゴリズムである SVM は土地被覆分類において高い識別能力を持つ⁷⁾。以上の理由で、機械学習手法による土地被覆分類では、SVM がしばしば利用されている。

1.2 課題

1.1.2 節で述べたように、土地被覆分類を主眼においた研究では、有効な GLCM 特徴量を使用することで土地被覆分類における精度向上を実現している。しかし、土地被覆分類精度向上に有効な GLCM 特徴量を事前に検討する必要がある、現状では試行的に GLCM 特徴量を選択している^{11~14)}。従って、予めいくつかの GLCM 特徴量を用いた土地被覆分類精度の比較を行うことが必要になる。一般的には、土地被覆分類は可能な限り簡便かつ高い精度で行えることが望ましいため、有効な GLCM 特徴量の事前検討の必要がなく、高い精度で土地被覆分類を行える汎用的手法について研究する必要がある。

1.3 既往研究

リモートセンシング分野で使用されているマルチスペクトル画像と合成開口レーダ (Synthetic Aperture Radar : SAR) 画像に関する既往研究を以下にまとめる。

1.3.1 マルチスペクトル画像への GLCM 適用事例

Rao らは¹¹⁾、空間分解能 6m の IRS-1D パンクロマチックデータを使用した土地被覆分類において、テクスチャ情報として GLCM 特徴量を使用し、最尤法によって分類を行い、土地被覆分類精度が向上することを示した。また、小阪らは¹²⁾、QuickBird 衛星取得の空間分解能 0.6m のデータを使用して、スペクトル情報と GLCM 特徴量を組み合わせてオブジェクトベースの樹種分類を行い、GLCM 特徴量やスペクトル特徴量のみの解析よりも分類精度が向上したことを報告した。

UAV で取得した高分解能画像を使用した例として、Laliberte らは¹³⁾、UAV により取得した空間分解能 5cm の放牧地画像を使用し、Decision Tree を使用したオブジェクトベース土地被覆分類を行い、GLCM 特徴量 (特に Entropy) が土地被覆分類精度向上に有効であることを報告した。また、Feng らは¹⁴⁾、UAV により取得した空間分解能 7cm の都市域画像を使用した Random Forest を用いた土地被覆分類を行い、GLCM 特徴量を入力データに加えることで分類精度が向上したと報告した。

以上、様々な研究において、高分解能マルチスペクトル画像のテクスチャ情報として GLCM 特徴量を使用することによって、土地被覆分類精度向上に有効なことが示されている。しかし、現状は土地被覆分類に有効な GLCM 特徴量は試行的に選択されている状況であることがわかる。

1.3.2 SAR データへの GLCM 適用事例

橋本らは¹⁹⁾、SAR データから地形特徴量のパターンサイズに依存しない特徴量抽出を行うことを目的とし、Two Step GLCM 法を提案した。この新手法により、GLCM 特徴量より高次元特徴抽出が可能であることを示し、画像の局所的な特徴量と大域的な特徴量を分離することが可能であることを示している。Zakeri らは²⁰⁾、イランのテヘラン市の土地被覆分類において、SAR 後方散乱係数に 8 つの GLCM 特徴量を加えることで大幅に分類精度が向上することを示した。Leen-Kiat らは²¹⁾、SAR データを使用した海氷パターンマッピングにおいて、10 種類の GLCM 特徴量を使用し、GLCM 算出時の近隣画素の距離と方位について定量的評価を行っている。佐無田らは²²⁾、Pi-SAR-L2 を用いたオブジェクトベース分類の土地被覆分類において、GLCM 特徴量 8 種類から主成分分析を用いて 3 種類の GLCM 特徴量を選定し、土地被覆分類を行った。その結果、テクスチャ情報を追加することで若干の精度向上が見られたが、あまり大きな変化はなかったと報告しており、適切な GLCM 特徴量の選定が難しいこと

を示唆している。

以上のように、GLCM 特徴量は SAR データにおいても土地被覆分類精度向上に有効であることが示されている。しかし、土地被覆分類精度向上に有効な GLCM 特徴量の選定には課題が残っているのがわかる。

1.4 提案手法

1.2 節および 1.3 節で示したように、GLCM 特徴量を使用することで土地被覆分類精度を向上させることができるが、精度向上に有効な GLCM 特徴量の選定には課題が残っている。本研究では、課題解決策として、GLCM 特徴量ではなく、GLCM の行列要素（以降「GLCM 要素」）を直接使用する手法を提案する。Fig.1-1 に本手法の概要を示す。従来の手法では、グレースケール画像を使用して GLCM を算出した後、GLCM 要素から GLCM 特徴量を算出し、算出された GLCM 特徴量を用いて土地被覆分類を行うか、GLCM 特徴量と入力画像を組み合わせる土地被覆分類を行い、精度向上を図っていた。しかし、1.2 節で述べたように、使用する GLCM 特徴量により土地被覆分類精度が変化するため、予め GLCM 特徴量の候補をいくつか選択して土地被覆分類を行い、最も精度向上が見られた結果を利用しなければならず、有効な GLCM 特徴量の事前検討が必要であった。

本研究で提案する手法では、GLCM 特徴量を算出せずに GLCM 要素を直接特徴ベクトルに変換して使用することで、GLCM 特徴量の選定および算出の手順を踏む必要がなく、解析手順を簡略化できる。さらに、GLCM 要素をすべて使用することによって、GLCM 特徴量算出時に失っていた情報が含まれているため、精度向上が期待できる。なお、本提案手法では、GLCM を算出する際に対称行列化した上で正規化を行っているため、GLCM 要素の対角成分を含んだ上三角成分のみを使用することで、特徴ベクトルの次元数を削減している。機械学習アルゴリズムでは、一般的に特徴ベクトルの次元数が多くなるほど計算量が増加するため、GLCM を対称行列化することで計算量を削減する工夫を行っている。

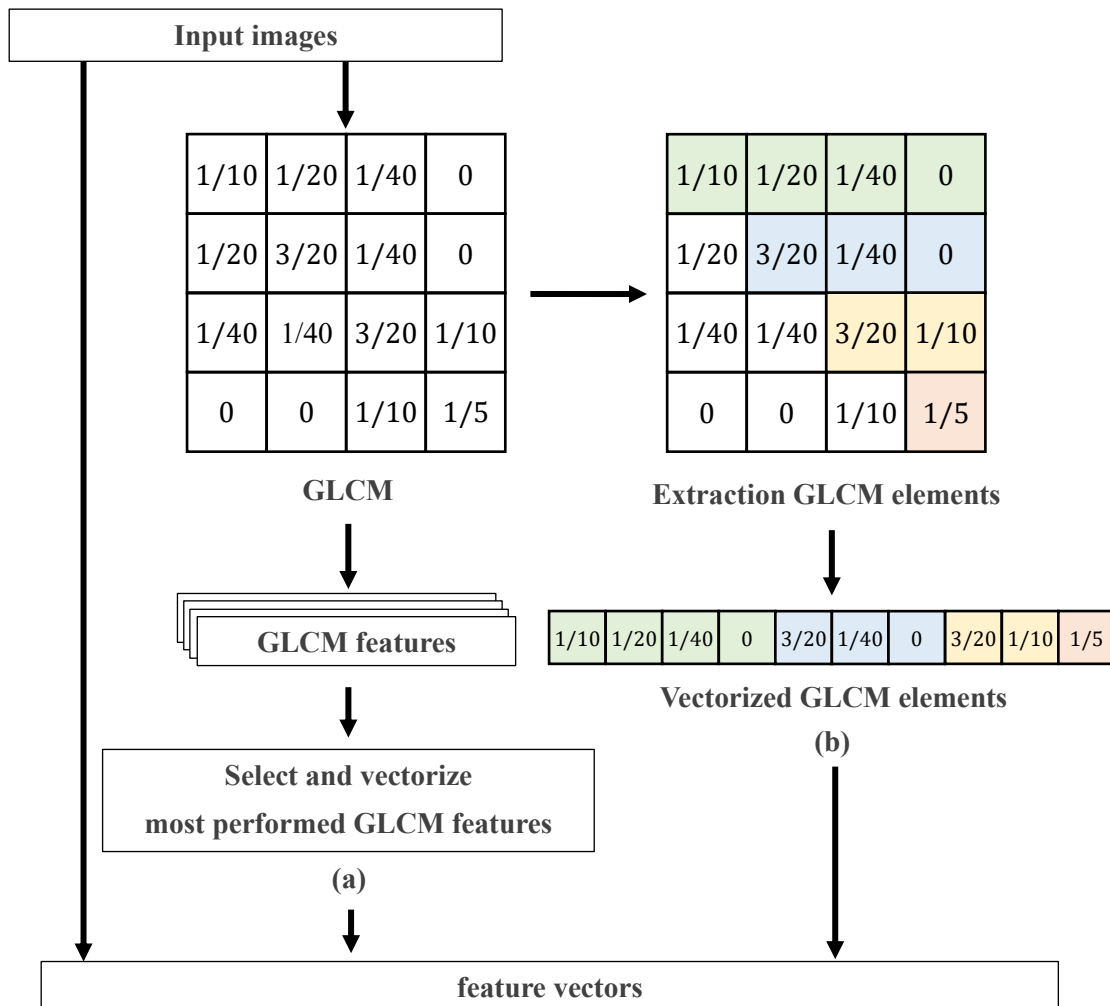


Fig. 1-1 Comparison of the procedures in land cover classification between (a) the conventional research using GLCM features and (b) the proposed method in this research.

1.5 目的

本研究では, SVMの学習データとして, GLCM特徴量を入力するのではなく, GLCM要素を直接学習データに組み込む手法を提案する。GLCM要素を直接使用することで, 有効なGLCM特徴量を事前検討することなく, テクスチャ情報を用いた土地被覆分類精度向上が期待できる。

本研究の目的を以下に示す。

- (1) 入力データの違いによる有効なGLCM特徴量の定量的評価を行う。
- (2) 提案手法の定量的評価を行い, 提案手法の有用性を示す。

本研究では, 従来手法との比較のため, 提案手法とGLCM特徴量を用いた土地被覆分類結果を比較することにより, 有意差があるか評価を実施する。対象データは, リモートセンシングデータの土地被覆分類で多用されるマルチスペクトル画像とSARデータとする。

はじめに, UAV取得の高分解能マルチスペクトル画像の土地被覆分類を行い, 高分解能マルチスペクトル画像に対する提案手法の有効性および有効なGLCM特徴量の定量的な評価を行う。

次に, SARの後方散乱係数(γ^0)画像の浸水域抽出を行い, 本手法が光学画像だけでなくSARデータに対して汎用的に有効な手法か検証した。SARデータに対しても土地被覆分類精度向上に有効なGLCM特徴量の定量的な評価を実施する。

以上の2種類データに対して, SVMを用いた土地被覆分類結果を比較することで, 提案手法が土地被覆分類精度向上に汎用的に有効かどうかを明らかにし, 同時に分類精度向上に有効なGLCM特徴量についても示す。

1.6 論文構成

本章では, この研究の背景および目的について記述した。

第2章では, 本研究で扱う高分解能画像とSARデータの特徴について述べる。

第3章では, UAVで取得された高分解能画像にテクスチャ情報を使用した場合の土地被覆分類について分類精度を比較し, 有効なテクスチャ情報について検証した結果を示す。

第4章では, Sentinel-1Bで取得された γ^0 画像から, テクスチャ情報を用いた浸水域抽出を行い, そのときの浸水域抽出精度を比較した結果を示す。

第5章では, 第3章および第4章で示した研究結果をもとに, 機械学習手法を用いた環境情報の抽出におけるテクスチャ情報の有効性について, 包括的に考察する。最後に本研究のまとめおよび今後の課題について示す。

第2章 高分解能マルチスペクトル画像と SAR データの特徴

2.1 高分解能マルチスペクトル画像 (UAV 取得画像) の特徴

リモートセンシングにおける人工衛星搭載センサの高性能化に伴い、高分解能商業衛星の空間分解能は1メートル以下に向上している。しかし、人工衛星による観測は、その観測地域や時期を柔軟に設定することが困難であり、特に光学センサの場合には、雲の影響で地表面が観測できない場合がある。観測頻度向上のため、近年は小型衛星コンステレーションによる高頻度観測を実現する動きもある²³⁾。有人航空機を用いた高分解能観測も可能ではあるが、一般的には観測コストが高い。近年、人工衛星や有人航空機より低高度で高分解能データを取得可能な UAV の普及によって、近接リモートセンシングデータを使用した農業や災害把握への応用に期待が高まっている。UAV により、低高度で観測されたデータの空間分解能は数センチメートル程度となり、リモートセンシングにおける UAV 観測データの有効性が示されている²⁴⁾²⁵⁾。

UAV は人工衛星と比較して、広域 (数十 km～数百 km) の画像は取得できないが、その代わり狭域 (数十 m～数百 m) において、数 cm 程度の高分解能な画像を取得できる。また、UAV によるデータ取得は、人工衛星によるデータ取得のように低頻度ではなく、飛行禁止区域を除けば容易にデータ取得が可能な点もメリットとして挙げられる。

空間分解能が数 m 以上の高分解能画像を使用した土地被覆分類は、高い解像度で土地被覆分類を行える反面、従来の数百 m から数十 m 程度の低分解能な画像にはない、高分解能画像特有の土地被覆分類の難しさがある²⁶⁾²⁷⁾²⁸⁾。Fig. 2-2 に高分解能画像の土地被覆分類の例を示す。Fig. 2-2 に示している例は、UAV で取得された空間分解能が約 7cm の 5 バンド (Blue, Green, Red, Rededge, Nir) の画像を使用して、森林域をピクセルベース (最尤法) で土地被覆分類した結果である。

一般的に低分解能画像では、分類対象物表面の凹凸や細かなスペクトル情報の違いが、画素内に平均化された状態で記録されている。そのため、外れ値にあたるような不均一な画素値 (スペクトル情報) が現れにくい。一方、空間分解能が低いことで、一画素内に複数のカテゴリが含まれるミクセル状態になりやすい。

しかし、数 cm 程度の高分解能画像では、1 画素の分解能よりも観測対象物のほうが大きくなることが高い確率で考えられる。このような場合、スペクトル情報が分類対象物全体で平均化されていない。そのため太陽光の反射や影等のスペクトル情報の外れ値が含まれやすく、不均一な画素が発生しやすい。ただし、低分解能画像で見られたような一つの画素内に複数のカテゴリが含まれるミクセル状態は低減される。Fig. 2-1 の土地被覆分類結果を見ても、木々の陰になっている部分では草地として誤分類されていることがわかる。

過去の研究を参照すると、数 m 規模の空間分解能においては、高分解能な画像であるほど分類精度が向上する傾向がある²⁸⁾²⁹⁾。UAV 取得画像のような数 cm 程度の空間

分解能での比較を行った研究は見られなかったが、この傾向は変わらないと推測される。しかし、前述したように、高分解能画像を対象としたピクセルベースの土地被覆分類においては、不均一な画素により誤分類が発生しやすい可能性がある。具体的な例として、木の葉と葉の間や、雲や立体物の影の影響を受ける可能性がある。

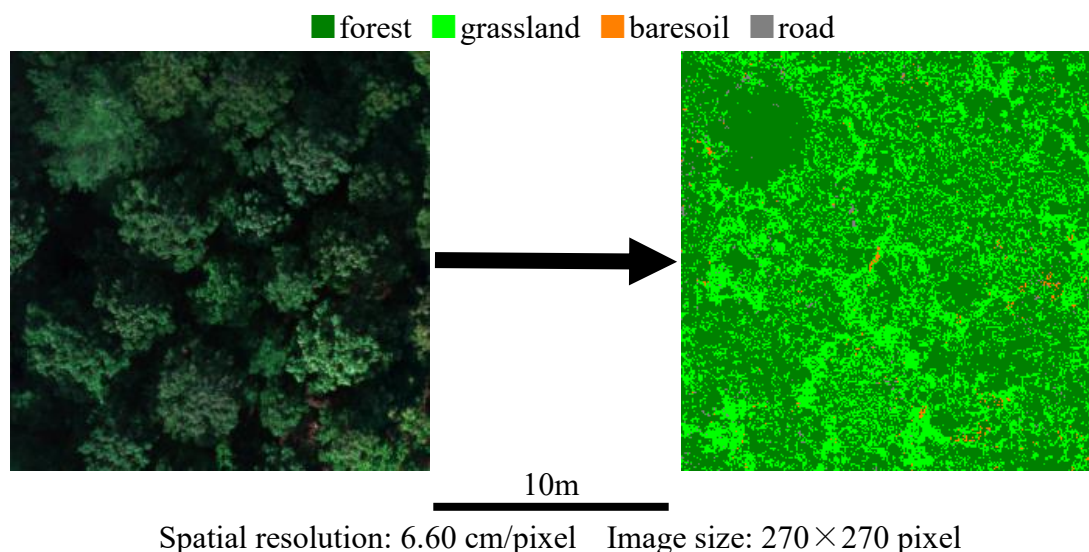


Fig. 2-1 An example of pixel-based image classification using SVM with high-resolution multi-spectral data.

2.2 SAR データの特徴

SAR はマイクロ波を利用した能動型センサであり、通常のレーダ（実開口レーダ）と同様に電磁波を照射してその反射を観測する。実開口レーダを用いて取得されるデータの空間分解能はアンテナの大きさに左右され、大きなアンテナほど取得するデータの空間分解能は小さくできる。しかし、人工衛星に搭載するアンテナの物理的な大きさに限界があるため、必要な空間分解能を実現するためにアンテナサイズを大きくすることが不可能な場合がある。実開口レーダと SAR との大きな違いは、合成開口技術を用いることで小さなアンテナでも高分解能データを取得可能な点にある。SAR による観測では、アンテナの進行方向をアジマス方向、マイクロ波の照射方向をレンジ方向と呼び、アジマス方向とレンジ方向とはそれぞれ異なる手法で取得データの高空間分解能化の工夫がされている。

アジマス方向では、ドップラー効果を用いたドップラー変調を利用した高分解能化が行われている。SAR から送信されたマイクロ波が、観測対象物で反射または散乱し、レーダ方向に戻ってくるマイクロ波（後方散乱）は、SAR アンテナで受信される。このとき、人工衛星は軌道上を高速で移動しているため、受信波はドップラー効果により周波数に変化が生じる。この周波数変化を利用した相関処理（合成開口処理）を用いることで空間分解能向上を実現している。レンジ方向については、周波数変調（FM）した送信波（チャープパルス）を用いて相関処理（パルス圧縮処理）を施すことで高

空間分解能化を実現している³⁰⁾。

SAR 観測で使用しているマイクロ波は、降雨、降雪、および雲の影響を受けにくい周波数帯を使用しているため、観測地域が悪天候や曇天の場合でも観測が可能である。また、自らマイクロ波を送信する能動型センサであり、昼夜問わず観測可能という特徴もあり、受動型の光学センサでは観測できない夜間や極域の観測にも適している。

SAR データにおけるもう一つの大きな特徴として、スペckルノイズと呼ばれるごま塩状のノイズがある。このノイズは、SAR の空間分解能領域中で、後方散乱を起こす複数散乱体がランダムな位置に存在することによって、発生するフェーディングによるゆらぎである。コヒーレントなマイクロ波センサで観測したデータ上に原理的に発生するものであり、空間分解能を落とすことなく取り除くことは不可能である。このノイズは、土地被覆分類において誤分類の要因となり得る。SAR データ上のスペckルノイズの例を Fig. 2-2 に示す。Fig. 2-2 は欧州宇宙機関 (ESA) が運用している Sentinel-1B が Interferometric Wide Swath (IWS) モードで 2019 年 10 月 13 日に取得された、局所入射角を補正した後方散乱係数 (γ^0) 画像の郡山市内の市街地における冠水域に発生したスペckルノイズの例である。マルチルック数 4 でピクセルスペーシング 10m でリサンプリング処理された VV 偏波画像である。画像上で確認できるごま塩状の濃淡がスペckルノイズである。

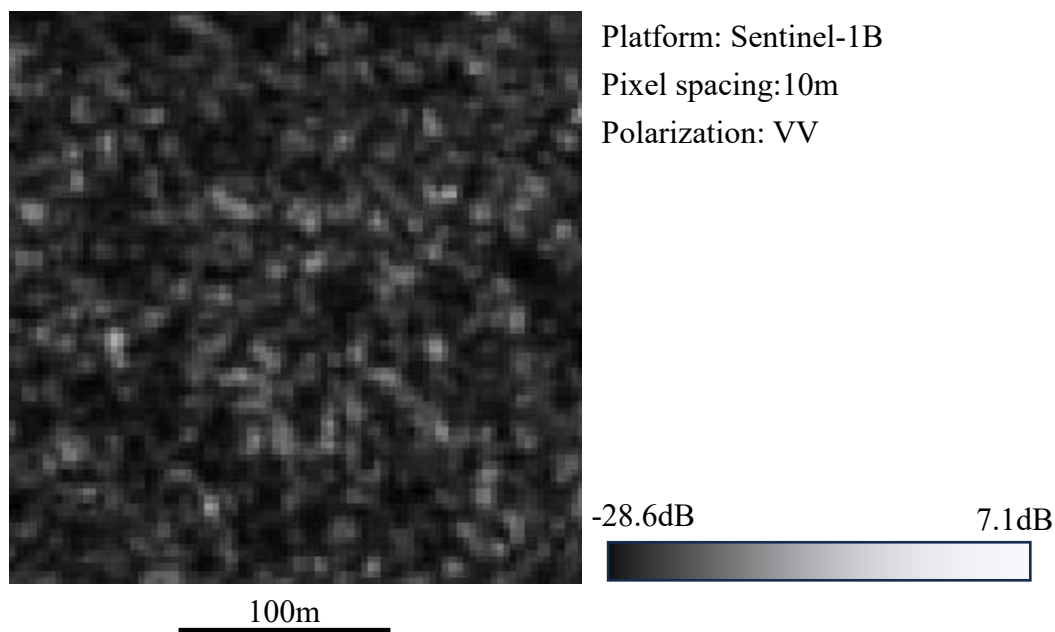


Fig. 2-2 An example of speckle noise on the VV-polarization image acquired by Sentinel-1B.

第3章 UAV 取得高分解能マルチスペクトル画像を用いた土地被覆分類 精度評価

第3章では、UAV で取得した高分解能マルチスペクトル画像を用いた土地被覆分類において、テクスチャ情報による土地被覆分類精度向上を目的とする。高分解能マルチスペクトル画像の土地被覆分類を通して、提案手法と既存手法をそれぞれ用いた場合の土地被覆分類精度を比較し、テクスチャ情報および提案手法の有効性を定量的に評価する。本章では次の4項目について評価を行なう。

- (1) 土地被覆分類におけるテクスチャ情報の有効性評価
- (2) 有効な GLCM 特徴量の定量的評価
- (3) 提案手法と既存手法との土地被覆分類精度の比較
- (4) 影が土地被覆分類精度に与える影響評価

具体的には、UAV で取得した空間分解能約 7 cm の画像を使用し、テクスチャ情報を使用しない場合、テクスチャ情報として GLCM 特徴量を使用する場合、および提案手法の3つのパターンについて、SVM による土地被覆分類を行い、土地被覆分類精度と GLCM の算出ウィンドウサイズおよびグレーレベル数について評価する。その後、影の有無による土地被覆分類精度の変化を考察するため、データセットから影の領域を除外して土地被覆分類を行い、精度の有意差を Kappa 有意差検定によって評価する。

3.1 テストサイトおよび使用データ

テストサイトの位置を Fig. 3-1 に示す。本テストサイトは、日本大学工学部と株式会社ふたばの共同研究により、2017 年度から継続してデータを取得している福島県双葉郡富岡町のサイトであり、可視近赤外マルチスペクトルカメラの検証用データ（UAV 観測および地上観測データ）を年 2 回程度取得している。本研究に使用した領域は約 300m×270m であり、領域内は家屋を中心として周辺に森林（杉）、草地、裸地、道路（アスファルト）がある土地被覆になっている。




Fig. 3-1 Test site located at eastern part of Tomioka town in Fukushima prefecture.

本研究に使用したデータは、2018 年 12 月 21 日に、Matrice 200 (Da-Jiang Innovations Science and Technology Co.,Ltd: DJI 社) に可視近赤外マルチスペクトルカメラ RedEdge-M (MicaSense 社) を搭載してデータ取得を行ったものである。Table 3-1 に RedEdge-M のカメラ諸元を示す³¹⁾。UAV 飛行高度を地上から 100m、画像取得時のオーバーラップおよびサイドラップ率ともに 80% に設定してデータ取得を行った。オルソモザイク処理に使用した画像数は 178 であり、テストサイト内には標定点（地上基準点）を設置して、オルソモザイク処理後の画像について幾何補正精度を算出した。Metashape (Agisoft 社) Ver. 1.6.2 を使用してオルソモザイク処理をした結果、作成されたオルソモザイク画像サイズは 4,504×4,126 ピクセル、地上における解像度は 6.6cm、地上基準点 5 点における幾何補正精度は約 1.2 cm と非常に良好であった。なお、画像のカウント値は UAV 飛行前に RedEdge-M の専用キャリブレーション板を撮像したデータを使用して反射率変換を行ったものである。

Fig. 3-2 にオルソモザイク処理後の画像（RGB 画像）を示す。テストサイト内の家屋や自動車等の人工物については、土地被覆分類の際に分類対象から除外するためにマスク画像を使用して無効領域にする処理を行った。この処理を行う理由は、家屋や自動車等の人工物は人工的に着色されている場合が多く、同一地物でも分光反射特性が異なる可能性があるためである。分光反射特性の違いにより土地被覆を判別する土地被覆分類では、人工物は分類精度向上の障害となる可能性がある。Fig. 3-3 にマスク処理を使用した画像を示す。以降の処理はマスク適用後の画像を使用している。




Fig. 3-2 RGB Ortho-mosaic image covering our test site.

Table 3-1 Characteristics of RedEdge-M multi-spectral camera.

Camera	RedEdge-M	
Output image size	1280×960 pixel	
Observation Bands	Central wavelength [nm]	Bandwidth [nm]
1 (Blue)	475	20
2 (Green)	560	20
3 (Red)	668	10
4 (Rededge)	717	10
5 (NIR)	840	40




Fig. 3-3 Mask image to exclude artificial materials, such as houses and cars.

3.2 研究手法

3.2.1 土地被覆分類精度の比較手順

本研究では、土地被覆分類におけるテクスチャ情報の有効性評価のため、土地被覆分類を3つのパターンに分けて Fig. 3-4 に示す手順で土地被覆分類精度を評価した。Fig. 3-4 中のパターン A は、テクスチャ情報を使用しないスペクトル情報のみの土地被覆分類である。パターン B はスペクトル情報に加えて、GLCM 特徴量を使用した既往手法の土地被覆分類であり、本研究では 8 種類の GLCM 特徴量を考慮する。パターン C はスペクトル情報に加えて、GLCM 要素を直接特徴ベクトルとして入力する土地被覆分類であり、本研究にて新たに提案する手法である。

パターン A は Table 3-1 に示した RedEdge-M の 5 バンドのスペクトル情報のみを入力データとして土地被覆分類精度を評価する。パターン B では、5 バンドのスペクトル情報に加え、GLCM 特徴量として Entropy, Angular Second Moment (Energy), Contrast, Mean, Variance, Correlation, Homogeneity, Dissimilarity をそれぞれ加えた場合と、8 つの GLCM 特徴量をすべて加えた場合の合計 9 種類の土地被覆分類精度を評価する。以降では、パターン B における土地被覆分類を、(B)entropy, (B)energy, (B)contrast, (B)mean, (B)variance, (B)correlation, (B)homogeneity, (B)dissimilarity, (B)all として記述する。パターン C は入力データとして 5 バンドのスペクトル情報に加えて GLCM 要素を直接特徴ベクトルに入力する場合の土地被覆分類精度を評価する。全てのパターンで、特徴ベクトルの各要素は最小値と最大値で、-1 から 1 に正規化を行なう。

パターン B および C の土地被覆分類においては、GLCM の算出ウィンドウサイズとグレーレベル数を変化させて土地被覆分類を行い、土地被覆分類精度の変化を解析する。GLCM の算出ウィンドウサイズは 3×3 から 21×21 の奇数ウィンドウサイズ合計 10 種類、GLCM の行列サイズに影響するグレーレベル数については 2 から 16 の 2 のべき乗の合計 4 種類変化させる。なお、本研究における土地被覆分類の分類器には SVM を用い、SVM のライブラリとして LIBSVM³²⁾ を使用し、土地被覆分類精度算出には交差検証を用いた。

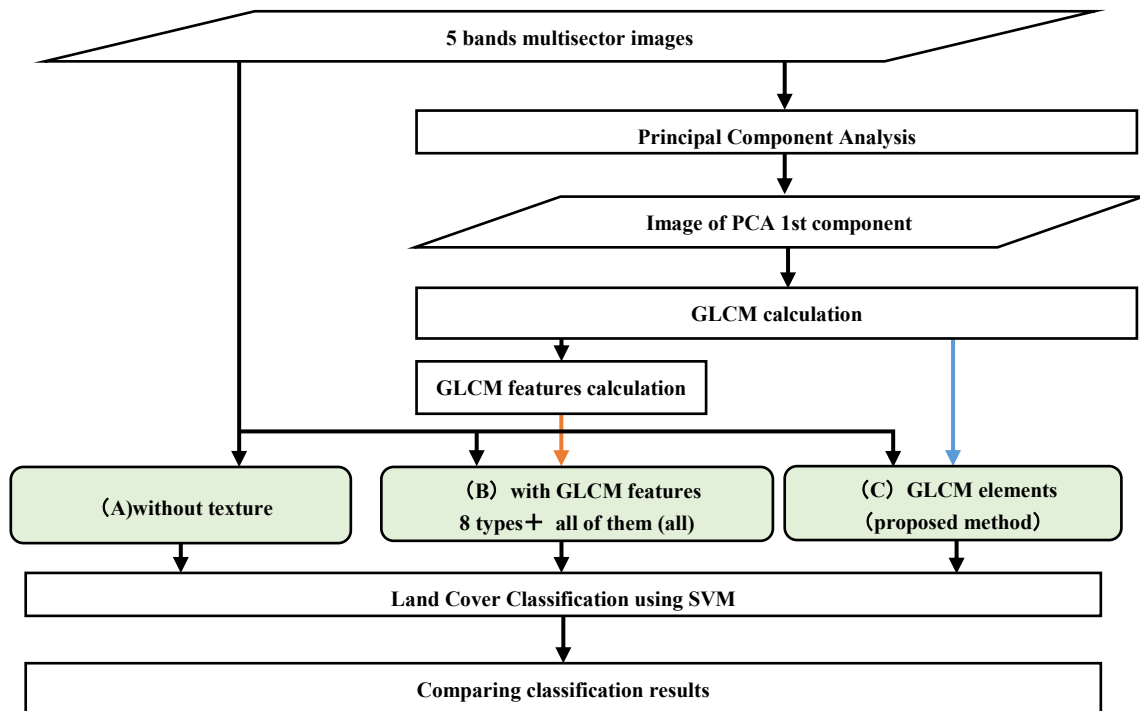


Fig. 3-4 Procedure of land cover classification analysis in Chapter 3.

3.2.2 GLCM 算出用画像作成

テクスチャ情報として GLCM を算出するため、グレースケール画像が必要となる。RedEdge-M の 5 バンド中のいずれかのバンドを使用することも可能であるが、本研究では 5 バンドのマルチスペクトラル画像を使用して主成分分析 (PCA) を行い、第 1 主成分画像からテクスチャ情報を算出した。第 1 主成分画像を使用した理由は、各バンドの持つスペクトル情報を合成して分散が最大となるグレースケール画像が作成可能なためである。このときの第 1 主成分の寄与率は 78.67% であった。主成分分析の結果算出された各バンドの固有ベクトル成分、標準偏差および第 1 主成分の因子負荷量を Table 3-2 に示す。ここで、因子負荷量とは主成分と各変数 (各バンドの画素値) との相関係数を表す。因子負荷量の算出式を式 (3-1) に示す。

$$y_i = \frac{\sqrt{l}h_i}{\sigma_{x_i}} \quad (3-1)$$

ここで、 y_i はバンド i の因子負荷量、 l は主成分の固有値、 h_i はバンド i の固有ベクトル成分、 σ_{x_i} はバンド i の標準偏差である。なお、第 1 主成分の固有値 l は 5068.24 であった。GLCM を算出するためのグレースケール画像は第 1 主成分画像について最大値と最小値を使用してスケーリングを行い、256 レベルでサンプリングを行った。算出したグレースケール画像を Fig. 3-5 に示す。また、GLCM 算出時のグ

レーベル数変換は最小値と最大値の範囲で線形変換を行った。

Table 3-2 Summary of PCA analysis

	Eigen vector	Standard deviation	Loading factor
Red	0.383	32.665	0.835
Green	0.428	32.387	0.940
Blue	0.300	28.377	0.753
Rededge	0.540	39.594	0.972
NIR	0.537	44.199	0.865



Fig. 3-5 Grayscale image used for GLCM calculation.

3.2.3 GLCM および GLCM 特徴量算出方法

GLCM は画像内の関連する位置における画素値の組み合わせの統計的分布から計算される¹⁵⁾³³⁾。グレースケール画像において、ピクセル距離 $(\Delta x, \Delta y)$ 離れた2つの画素値 (グレーレベル値) の組み合わせの出現頻度を示す行列であり、 i 行 j 列目の行列要素の値は一方の画素値が i かつもう一方の画素値が j である確率として表現される。本研究で使用した GLCM の算出式を以下に示す。ピクセル距離を $(\Delta x, \Delta y)$ とした場合の GLCM の行列要素を $P(i, j : \Delta x, \Delta y)$ 、算出ウィンドウサイズを $N \times M$ とすると GLCM の各要素は式 (3-2) および式 (3-3) で算出される。

$$P(i, j : \Delta x, \Delta y) = \frac{1}{2(N - \Delta x)(M - \Delta y)} \{ Q(i, j : \Delta x, \Delta y) + Q(j, i : \Delta x, \Delta y) \} \quad (3-2)$$

$$Q(i, j : \Delta x, \Delta y) = \sum_{n=1}^{N-\Delta x} \sum_{m=1}^{M-\Delta y} A$$

$$A = \begin{cases} 1 : (I(n, m) = i) \wedge (I(n + \Delta x, m + \Delta y) = j) \\ 0 : \text{elsewhere} \end{cases} \quad (3-3)$$

ここで、 $I(n, m)$ は算出ウィンドウにおける座標 (n, m) のグレーレベル値を表す。本研究では、UAV で取得した高分解能画像を扱うことを前提としているので、最小の解像度を反映できる $(\Delta x, \Delta y) = (1, 0)$ とした。以降、 $P(i, j : 1, 0)$ を $P(i, j)$ と表記することとする。なお、 N および M については、注目画素を中心とする奇数×奇数サイズのウィンドウを使用する。

本研究のパターン B で使用する GLCM 特徴量とその算出式を式 (3-4) から式 (3-11) に示す。パターン B では、どの GLCM 特徴量が土地被覆分類に有効なのか調べるため、既往研究と同様に 8 種類の GLCM 特徴量¹¹⁾¹³⁾¹⁴⁾を使用し、5 バンドのスペクトル情報に GLCM 特徴量を加えて各画素の特徴ベクトルを作成する。

Entropy

$$ENT = - \sum_{i,j} P(i, j) \log P(i, j) \quad (3-4)$$

Angular Second Moment (Energy)

$$ASM = \sum_{i,j} P(i, j)^2 \quad (3-5)$$

Contrast

$$CON = \sum_{i,j} (i - j)^2 P(i, j) \quad (3-6)$$

Mean

$$MEAN = \mu = \sum_{i,j} iP(i,j) \quad (3-7)$$

Variance

$$VAR = \sigma^2 = \sum_{i,j} (i - \mu)^2 P(i,j) \quad (3-8)$$

Correlation

$$COR = \sum_{i,j} \frac{ijP(i,j) - \mu^2}{\sigma^2} \quad (3-9)$$

Homogeneity

$$HOM = \sum_{i,j} \frac{P(i,j)}{1 + (i-j)^2} \quad (3-10)$$

Dissimilarity

$$DIS = \sum_{i,j} P(i,j)|i-j| \quad (3-11)$$

3.2.4 特徴ベクトル

提案手法のパターン C では、3.2.3 節に示した GLCM 特徴量は使用せず、GLCM 要素を直接特徴ベクトルに入力する方法を提案する。GLCM 要素から特徴ベクトルを作成する方法（GLCM が 4×4 の例）を Fig. 3-6 に示す。GLCM 要素から特徴ベクトルへの変換は、GLCM は対称行列であるため行列内の重複する要素は使用せず、GLCM 要素の上三角要素のみを行ごとに取り出して、5 バンドのスペクトル情報に加えて対象画素の特徴ベクトルとした。特徴ベクトルとして使用した GLCM 要素の値は、式 (3-2) および式 (3-3) で算出したものを使用し、特徴ベクトルの要素毎に最小値と最大値の範囲を -1 から 1 で正規化を行った。




Fig. 3-6 Proposed method for vectorizing GLCM elements.

この提案手法では、GLCM 要素から入力するベクトル長が GLCM サイズによって異なり、テクスチャを算出するグレースケール画像のグレーレベル数に依存する。グレーレベル数を G とすると GLCM 要素を 5 バンドに加えた場合の特徴ベクトルの次元数 D は式 (3-12) で与えられる。

$$D = \frac{(G + 1)G}{2} + 5 \quad (3 - 12)$$

3.2.5 Support Vector Machine (SVM)

SVM は教師あり学習アルゴリズムの一つである。アルゴリズムの特徴として、学習データと識別境界との距離が最大になるような識別関数を求めることで、学習モデルの汎化性能を向上させる戦略をとる。学習データと識別境界との最短距離のことをマージンと呼ぶ。SVM は、近年リモートセンシングデータを使用した土地被覆分類で使用されることが多くなった機械学習手法の一つであり、他の解析手法と比較して、少ないサンプリングデータでも高い分類性能を得られることが知られている⁴⁷⁾。

本研究で使用する非線形 SVM は、SVM を非線形に拡張したものであり、ピクセルベースの土地被覆分類が線形分離不可能であることを前提としているため、線形分離不可能なデータに対しても柔軟に識別境界を求められる³⁴⁾。本研究では、ソフトマージン SVM である C-Support Vector Classifier (C-SVC) を導入した¹⁶⁾³⁵⁾。以下に導出方法をまとめる。

非線形 SVM における識別関数 $D(\mathbf{x})$ は次のように表わされる。

$$D(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (3-13)$$

ここで、 \mathbf{w} , \mathbf{x} は n 次元のベクトルである。 \mathbf{w} は重み付けパラメータ、 $\varphi(\cdot)$ は n 次元特徴空間への写像、 b はバイアス項を示す。識別関数 $D(\mathbf{x})$ は以下のように 2 クラス (C_1, C_2) を識別する。

$$\begin{cases} \mathbf{x} \in C_1 & \text{if } D(\mathbf{x}) = 1 \\ \mathbf{x} \in C_2 & \text{if } D(\mathbf{x}) = -1 \end{cases} \quad (3-14)$$

$D(\mathbf{x}) = 0$ となる超平面を識別境界と呼ぶ。特徴ベクトルと識別境界との距離 M (マージン) は次のように表せる。

$$\frac{y_k D(\mathbf{x}_k)}{\|\mathbf{w}\|} \geq M \quad (3-15)$$

ここで、 \mathbf{x}_k は特徴ベクトル、 y_k はクラス C_1 , C_2 に対応するラベルであり、 k は 1 から N までの自然数である。 \mathbf{x}_k , y_k を組みとし、 N 個の学習データセットを入力とする。式 (3-16) に定義を示す。

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), (\mathbf{x}_3, y_3), \dots, (\mathbf{x}_N, y_N) \quad \text{ここで} \quad \begin{cases} y_k = 1 & \text{if } \mathbf{x}_k \in C_1 \\ y_k = -1 & \text{if } \mathbf{x}_k \in C_2 \end{cases} \quad (3-16)$$

式 (3-15) の M を最大化したものを M^* と定義する。 M^* は識別境界と特徴ベクトルとの最短距離に等しくなり、この条件を満たすベクトルはサポートベクトルと呼ばれる。

$$M^* = \max_{\mathbf{w}, \|\mathbf{w}\|=1} M \quad (3-17)$$

$$\min_k y_k D(x) = M^* \quad (3-18)$$

式 (3-17) および式 (3-18) をラグランジュの未定乗数法を用いて双対問題に変換する。以上、変換した式を整理すると、最終的に式 (3-19) の制約付きの双対問題の式となる。式 (3-19) を最大化させるラグランジュ乗数 α_k を求めることで双対問題における識別関数を求められる。

$$\begin{aligned} \max_{\alpha} J(\alpha) &= \sum_{k=1}^N \alpha_k - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s. t.} \quad 0 &= \sum_k \alpha_k y_k, \quad 0 \leq \alpha_k \leq C \quad (k = 1, 2, 3, \dots, N) \end{aligned} \quad (3-19)$$

ソフトマージンを導入したことにより、式 (3-19) の制約条件にパラメータ $Cost$ (C) が追加されている。 C は事前に決定する必要があるパラメータであり、 C を大きくすると誤りに対し厳しくなり、 C を小さくするとマージンを最大化することを優先する。従って、 C は識別誤差を最小にするか、マージンを最大化して汎化性能を上げるかのトレードオフの関係を示している。式 (3-19) 中の $K(\mathbf{x}_i, \mathbf{x}_j)$ はカーネル関数と呼ばれ、式 (3-20) で与えられる。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j) \quad (3-20)$$

カーネル関数は式 (3-20) から、 $\varphi(\cdot)$ の内積で表され、Mercer の条件を満たす関数を用いることでこの内積の計算を省きながら内積と等価な計算ができる。ここで、Mercer の条件を満たす非線形カーネル関数を用いることで、識別境界の計算を非線形に拡張できる³⁶⁾。

式 (3-19) を解くと、 α_k が求まる。求まった α_k を用いて識別関数 $D(\mathbf{x})$ を記述すると式 (3-21) のようになる。

$$D(\mathbf{x}) = \sum_k \alpha_k y_k K(\mathbf{x}, \mathbf{x}_k) + b \quad (3-21)$$

式 (3-21) のバイアス項 b は式 (3-14) を満たすために、式 (3-22) のように求められる。

$$b = -\frac{1}{2} \sum_k \alpha_k y_k [K(\mathbf{x}_A, \mathbf{x}_k) + K(\mathbf{x}_B, \mathbf{x}_k)] \quad (3-22)$$

本研究では、カーネル関数として一般的な Radial Basis Function (RBF) カーネルを

採用した⁷⁾³⁷⁾。RBF カーネルは次式で定義される。

$$K(\mathbf{x}, \mathbf{x}') = e^{-\gamma \|\mathbf{x} - \mathbf{x}'\|^2}$$
$$s. t. \quad \gamma = \frac{1}{2\sigma^2} > 0 \quad (3-23)$$

ここで、 γ は事前に決定しなければならないパラメータである。 γ が大きいほど識別境界の複雑さが増加し、小さいほど識別境界が単純になるため、 γ の値を小さくした場合は線形カーネルに類似した識別境界となる。式 (3-19) および式 (3-23) 中のパラメータ (C および γ) は事前に決定する必要があり、この2つのパラメータで学習モデルの性能が大きく左右されるため、最適なパラメータを探索する必要がある。

3.2.6 交差検証を用いた精度評価手法

土地被覆分類精度を評価するために、3.2.1 節に示した各パターンを入力データを教師データとして使用した交差検証を行う。機械学習によるリモートセンシングデータを使用した土地被覆分類精度評価や学習モデル評価には、交差検証を使用する方法がある^{38)~42)}。本研究では、教師データを SVM 分類器に入力し、分類結果を交差検証によって評価する。交差検証の方法はいくつか提案されているが、SVM による過学習についても考察を行うために、Stratified K-Folds Cross Validation (以降「Stratified CV」)⁴¹⁾と Nested Cross Validation (以降「Nested CV」)⁴²⁾の2つの方法による土地被覆分類精度評価を行った。

3.2.6.1 Stratified CV および SVM パラメータ最適化

SVM のパラメータ (C および γ) の決定には Stratified CV による Grid Search⁴⁾を用いて行った。Fig. 3-7 に Stratified CV の概要を示す。Stratified CV は学習データからモデルの性能評価を行う手法の一つである。以下に手順を説明する。

- (1) 学習データを K 個のフォールドと呼ばれるデータに分割する。このとき、フォールド毎のデータのカテゴリの比率が同じになるようにランダムサンプリングを行う。これにより、入力する学習データに偏りがあっても、各フォールドでは偏りなく学習データが分割される。
- (2) K 個のフォールド中の1つを検証用データとし、残りの $K-1$ 個のフォールドを学習用データとして学習モデルを作成する。学習モデル作成後に検証用データを用いて作成された学習モデルの精度評価を行う。
- (3) 検証用データとするフォールドを入れ替え、全てのフォールドに対して分類精度算出を行い、算出された分類精度の平均値を Stratified CV 精度とする。本評価は LIBSVM ライブラリに備わっている交差検証用関数を使用したため、Overall Accuracy (OVA) としている。

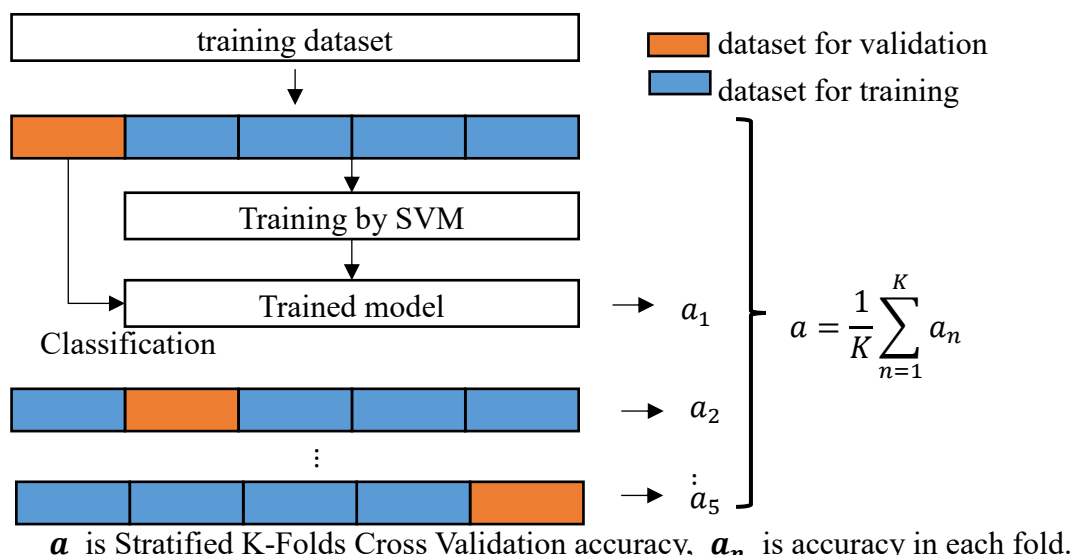


Fig. 3-7 Schematic procedure of Stratified CV (K=5).

Fig. 3-8 に SVM のパラメータ最適化を目的とした Grid Search の概要を示す。Grid Search では探索範囲内に格子点を設定し，格子点上の各パラメータにおける学習モデル精度を算出する。これら格子点上で最も精度の高いパラメータの組み合わせを，最適値として採用する。本研究では，格子点上の学習モデルの精度算出に上述の Stratified CV を使用し，フォールド数 K を 10 とし，パラメータの探索範囲は $2^{-5} \leq C \leq 2^{15}$ および $2^{-20} \leq \gamma \leq 2^5$ とした。格子の刻み幅については少ない候補数で広域を探索するため， 2^n とし，指数 n を 2.0 ずつ変化させて探索した。

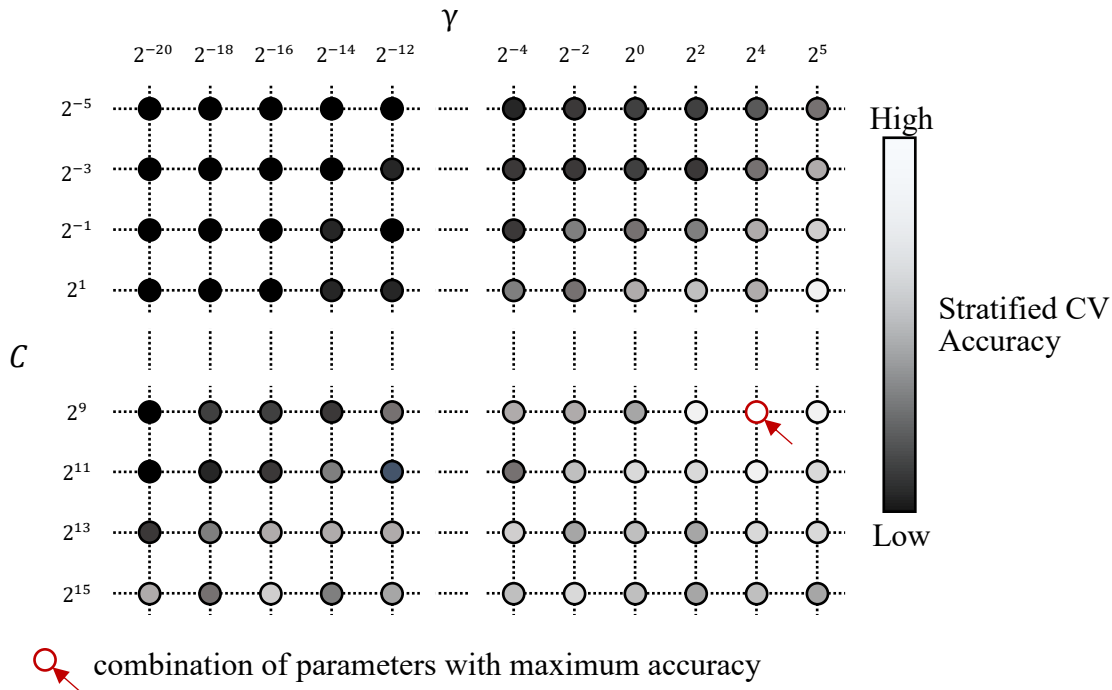


Fig. 3-8 Schematic diagram for searching parameters by Grid Search. Each grid point indicates an output of Stratified CV.

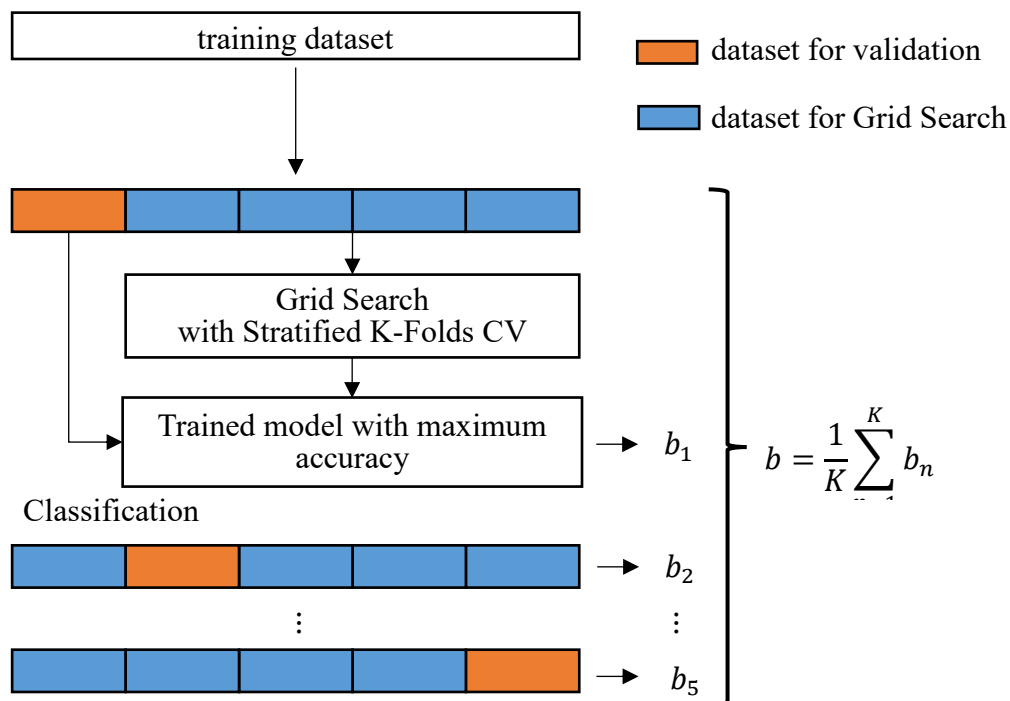
3.2.6.2 Nested CV およびモデル性能評価

3.3.6.1 に示した，Stratified CV を用いた土地被覆分類精度評価では，学習モデルのパラメータ決定に既知の学習データを使用していたため，未知のデータに対する分類精度評価（汎化性能評価）ができず，土地被覆分類精度向上が手法によるものか過学習によるものか判断できない可能性がある。これを防ぐため，交差検証手法の一つである Nested CV による土地被覆分類精度評価を行う。Fig. 3-9 に Nested CV の概要を示す。Nested CV の手順は以下の通りである。

- (1) 学習データを K 個のフォールドに分割し，その一つを検証用データとして保持する。
- (2) 残りのフォールドから Stratified CV を用いた Grid Search による学習モデルの作成を行う。
- (3) (1) で保持しておいた検証用データを用いて，(2) で作成した学習モデルの性能評価を行う。
- (4) 検証用とするデータを入れ替え，全てのフォールドに対して分類精度算出を行い，算出された分類精度の平均値をその精度とする。

以上の手順により，Nested CV を用いることで，モデル作成に用いるデータとモデルの性能評価を行うデータとを切り分けることができるため，汎化性能評価が可能となる。本研究では Nested CV のフォールド数を 5，モデル作成のための Stratified CV

のフォールド数を 2 として土地被覆分類精度の評価を行った。なお、LIBSVM には Nested CV の機能がなく、独自にプログラムを作成したため、精度評価はより信頼性の高い Kappa 係数による評価が可能となった。



b is Nested Cross Validation accuracy, b_n is accuracy of model in each fold (Kappa

Fig. 3-9 Schematic procedure of Nested Cross Validation (K=5).

3.3 結果

3.3.1 土地被覆分類カテゴリとトレーニングデータ抽出

土地被覆分類のカテゴリとして、森林 (forest), 草地 (grassland), 裸地 (bare soil), および道路 (road) の 4 カテゴリを設定した。トレーニングデータの 1 箇所あたりの取得領域は 11×11 ピクセルとした。取得領域のサイズは、道路において他カテゴリの領域と被らないサイズを基準としている。また各カテゴリのトレーニングデータの取得箇所は、無効領域や他カテゴリと被らないように注意しつつ、パターン A のサンプル数増加に伴う土地被覆分類精度の変化量が十分小さくなるまで増加させた。その結果、取得箇所は 34 箇所となり、カテゴリ毎に同数の合計 4114 個となった。カテゴリ毎のトレーニングエリア抽出箇所を Fig. 3-10 に示す。なお、トレーニングデータ抽出場所は現地調査結果から目視で決定した。

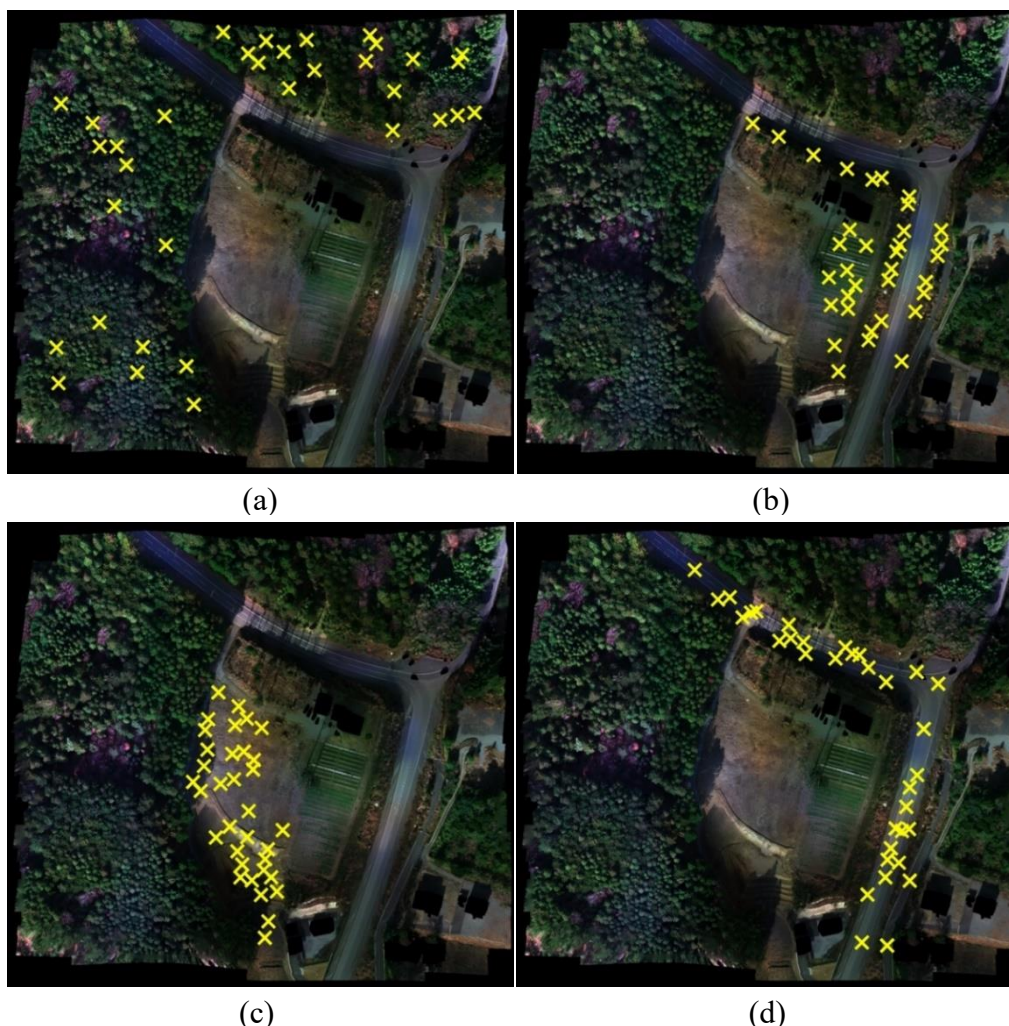


Fig. 3-10 Locations of extracting training samples for each category.
(a)forest, (b)grassland, (c)baresoil, and (d)road.

トレーニングエリアから抽出したデータセットには同値の重複するデータが含まれることがある。SVM において重複データは学習結果に影響を及ぼさないため、本研究では抽出した学習データセット内の重複データは削除した。重複データを削除したことで各カテゴリのデータサンプル数は不均衡となる。不均衡なデータはデータセットの学習時で土地被覆分類精度に影響を及ぼす。不均衡データの対処法として、カテゴリ毎の学習時のパラメータ C に重み付けを行い、不均衡データによる影響を低減させた。具体的には、式 (3-24) よりカテゴリ毎の重みを計算し、パラメータ C に対して重み付けを行った。

$$w_i = \frac{N_i}{N_{\min}} \quad (3-24)$$

ここで、 w_i はカテゴリ i の重み、 N_i はカテゴリ i のサンプル数、 N_{\min} は全カテゴリ中の最小のサンプル数を表す。

3.3.2 Stratified CV による土地被覆分類精度評価結果

Table 3-3 に Stratified CV で得られた各パターンの土地被覆分類精度の最大値を示す。各パターンの土地被覆分類精度を比較すると、パターン A の土地被覆分類精度が最も低く、次いでパターン B となり、パターン C の土地被覆分類精度が最も高い値となった。パターン B および C において土地被覆分類精度が最大値を示したものは、ウィンドウサイズ 21×21 でグレーレベル数 16 の場合であった。

テクスチャ情報を使用するパターン B およびパターン C は、ともにパターン A より土地被覆分類精度が向上している。パターン B に注目すると、GLCM 特徴量単体では (B)entropy が最も土地被覆分類精度が高く、(B)variance が最も土地被覆分類精度が低い結果となり、8 個の GLCM 特徴量すべてを追加した (B)all の場合が、土地被覆分類精度が最も高い結果となった。

ウィンドウサイズの増加に伴うグレーレベル数毎の土地被覆分類精度の変化を Fig. 3-11 に示す。ウィンドウサイズ 11×11 以下では急に、ウィンドウサイズ 11×11 以上では緩やかに土地被覆分類精度が向上しているのがわかる。この理由として、ウィンドウサイズが 11×11 より大きい場合、トレーニングエリアの取得領域よりもウィンドウサイズが大きくなることが要因として考えられる。3.3.1 節で述べたように、トレーニングエリアの取得領域サイズは、道路において他カテゴリと被らないという基準で設定したサイズであった。したがって、トレーニングエリアの取得領域よりもウィンドウサイズが大きくなったことで、他カテゴリのテクスチャ情報を含むデータとなった結果、分類精度向上が鈍化したのではないかと考えられる。これはパターン B および C とともに同様の傾向が見られたが、パターン C の方が (B)all と比較しても高い土地被覆分類精度結果となった。(B)correlation に関してはウィンドウサイズ 3×3 から 7×7 の範囲ではグレーレベル数 16 よりグレーレベル数 8 の方が高い土地被覆分類精

度となった。(B)all および C に関してはウィンドウサイズ 3×3 ではグレーレベル数の違いによる変化はほとんど見られなかった。Fig. 3-12 に、パターン A、パターン B の(B)entropy および(B)all, パターン C の土地被覆分類結果の一例を示す。Fig. 3-12 からパターン毎の分類結果の違いを判断するのは困難であることがわかる。

Table 3-3 Comparison of maximum accuracies for land cover classification by Stratified K-Folds Cross Validation.

Pattern		OVA [%]
A		88.72
B	entropy	98.37
	energy	98.00
	contrast	97.32
	mean	96.21
	variance	95.88
	correlation	95.92
	homogeneity	98.32
	dissimilarity	98.03
	all	99.72
C		99.76

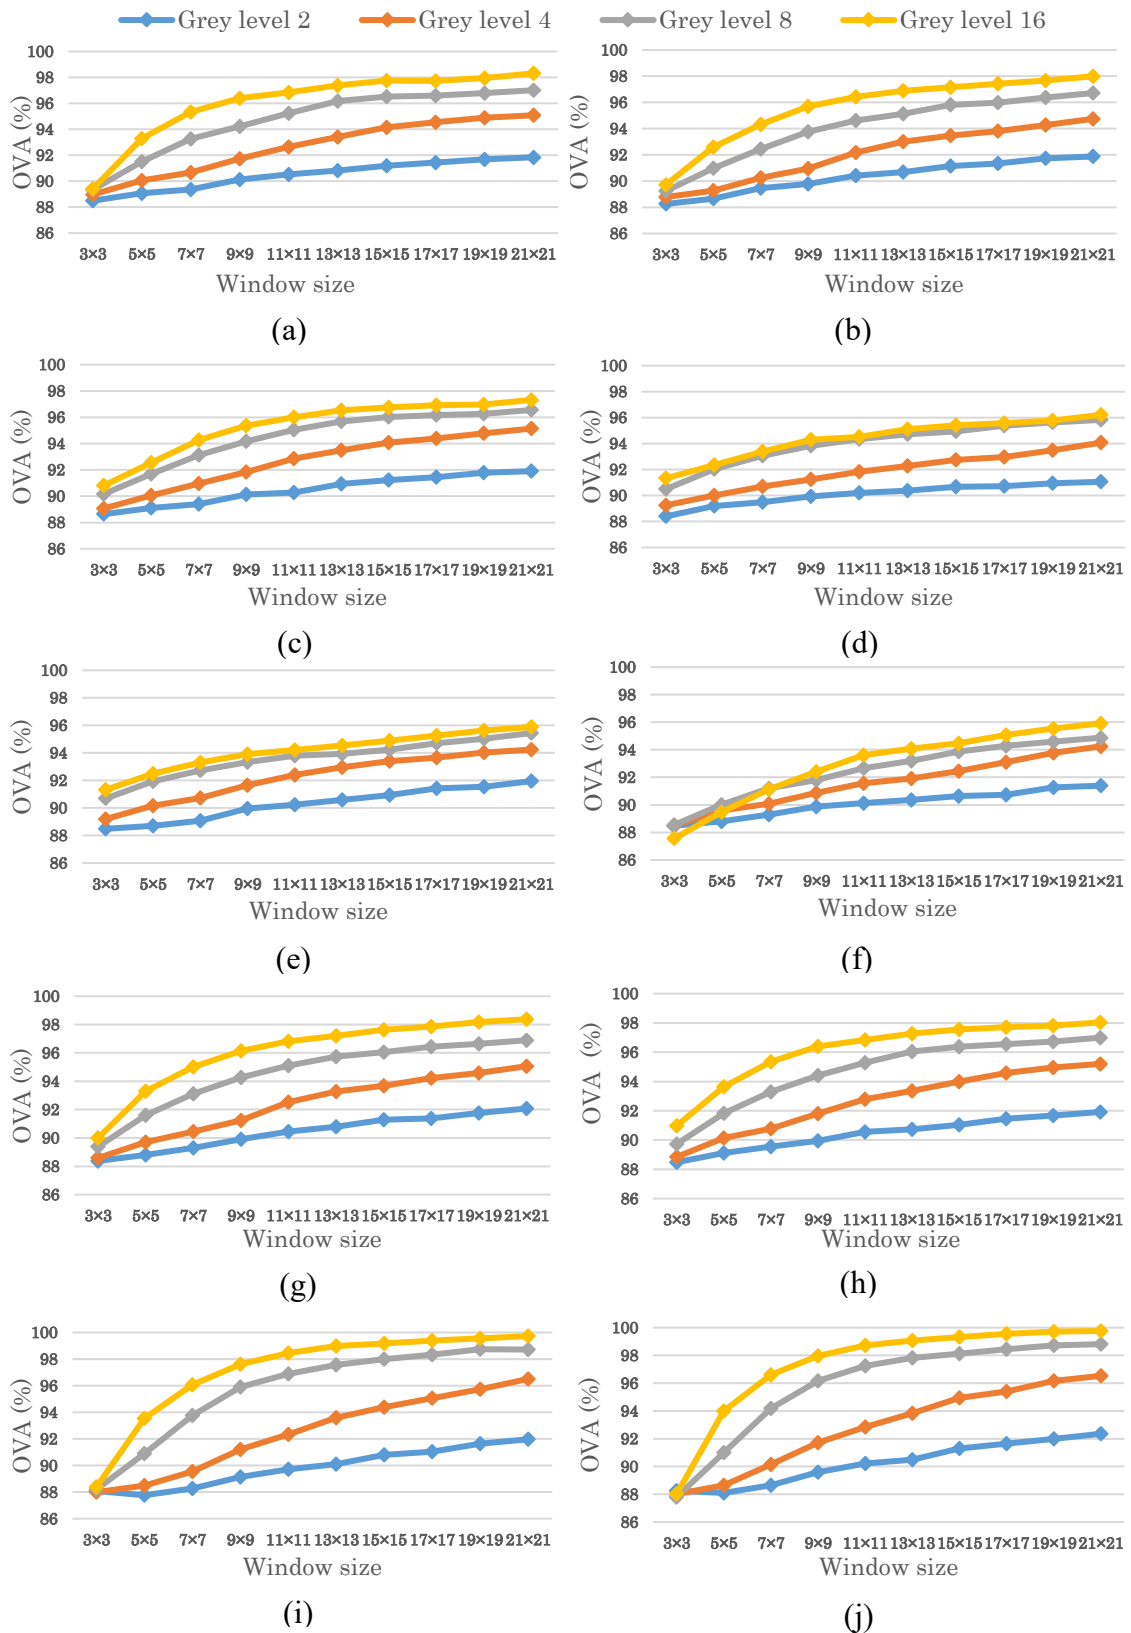



Fig. 3-11 Change of land cover classification accuracies with window size and gray level.

(a)(B)entropy, (b)(B)energy, (c)(B)contrast, (d)(B)mean, (e)(B)variance,
 (f)(B)correlation, (g)(B)homogeneity, (h)(B)dissimilarity, (i)(B)all, and (j)C.

■ Nodata ■ forest ■ grassland ■ baresoil ■ road



**Fig. 3-12 Example of classification results in Grid Search with Stratified CV.
(a)A, (b)(B)entropy, (c)(B)all, and (d)C.**

3.3.3 Nested CV による土地被覆分類精度評価結果

Table 3-4 に Nested CV で得られた各パターンの土地被覆分類精度の最大値を示す。Table 3-3 同様に、パターン A の土地被覆分類精度が最も低く、次いでパターン B となり、パターン C の土地被覆分類精度が最も高い値となった。パターン B および C において土地被覆分類精度が最大値を示したものは、ウィンドウサイズ 21×21 でグレーレベル数 16 の場合であった。パターン B 中の傾向も同様に、(B)entropy が最も土地被覆分類精度が高く、(B)variance が最も土地被覆分類精度が低い結果となった。

ウィンドウサイズの増加に伴うグレーレベル数毎の土地被覆分類精度の変化を Fig. 3-13 に示す。総じて、Fig. 3-11 に示した Stratified CV と同様の結果が得られた。また、Fig. 3-14 にパターン毎の土地被覆分類結果の一例を示す。

Table 3-4 Comparison of maximum accuracies for land cover classification by Nested Cross Validation.

Pattern		Kappa coef.
A		0.836
B	entropy	0.973
	energy	0.970
	contrast	0.955
	mean	0.938
	variance	0.936
	correlation	0.939
	homogeneity	0.972
	dissimilarity	0.969
	all	0.995
C		0.996

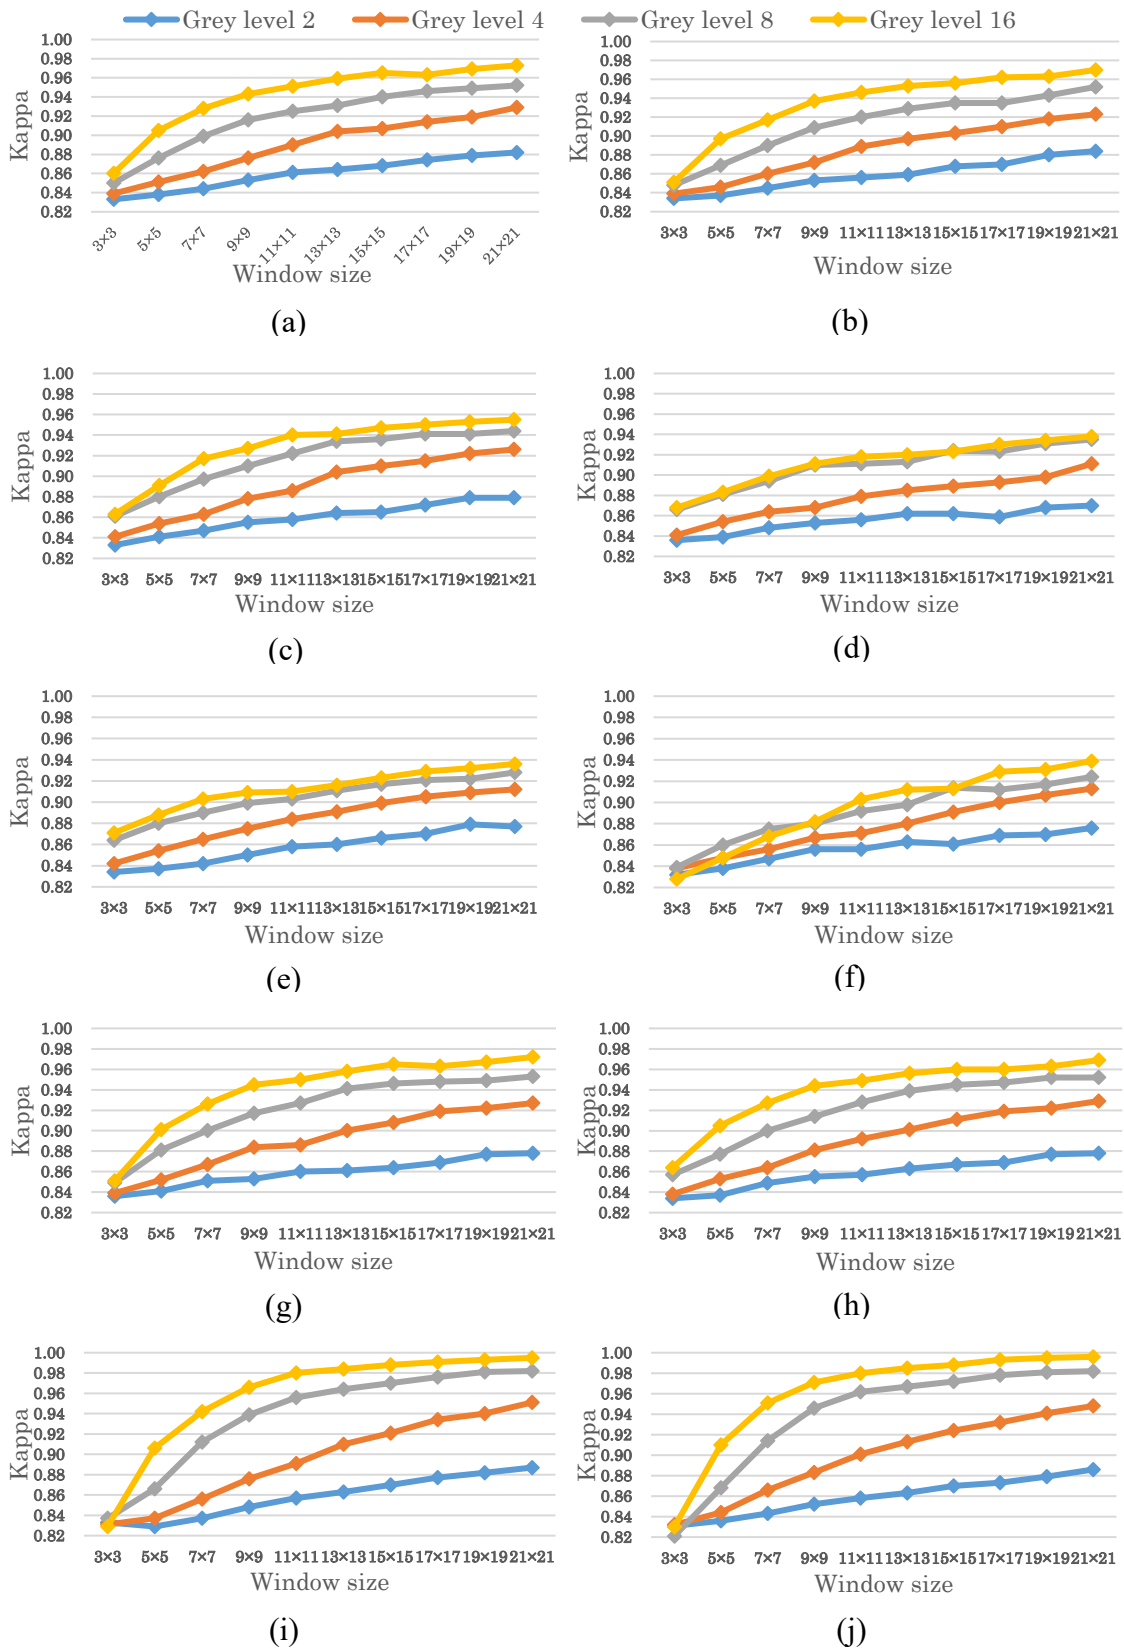




Fig. 3-13 Change of land cover classification accuracies with window size and gray level. (a)(B)entropy, (b)(B)energy, (c)(B)contrast, (d)(B)mean, (e)(B)variance, (f)(B)correlation, (g)(B)homogeneity, (h)(B)dissimilarity, (i)(B)all, and (j)C.

■ Nodata ■ forest ■ grassland ■ baresoil ■ road



(a)

(b)



(c)

(d)

Fig. 3-14 Example of classification results in Nested Cross Validation.

(a)A, (b)(B)entropy, (c)(B)all, and (d)C.

3.4 考察

3.4.1 土地被覆分類におけるテクスチャ情報の有効性

Stratified CV および Nested CV の2つの交差検証ともに、スペクトル情報のみを使用したパターン A、スペクトル情報に GLCM 特徴量を追加したパターン B、スペクトル情報に GLCM 要素を直接特徴ベクトルに追加したパターン C の順番に土地被覆分類精度が向上した。以上の結果は、スペクトル情報に加えてテクスチャ情報を使用することによって土地被覆分類精度向上を実現した研究^{11)~14)}と同様の結果であり、テクスチャ情報を追加することは土地被覆分類精度向上に有効であると判断できる。

パターン B 中の GLCM 特徴量を比較すると、Entropy 次いで Homogeneity が高い精度を示している、土地被覆分類精度向上に有効であると判断できる。GLCM 特徴量の中で Entropy が有効であるという結果は、Laliberte ら¹³⁾の空間分解能 5cm の UAV 取得画像を使用した解析結果と一致している。パターン B のすべての GLCM 特徴量を追加したものよりパターン C の方が高い精度を示していることから、パターン C を使用することによって、有効な GLCM 特徴量を検討することなく、テクスチャ情報を有効に土地被覆分類精度向上に反映できることがわかった。

GLCM 特徴量は GLCM 要素から導出された2次統計量であり、GLCM 要素は領域内の2つのグレーレベルの相対的な出現頻度を表している。クラス内分散がクラス間分散よりも小さい場合に相対的になめらかであると定義され、クラス内分散がクラス間分散と同等以上である場合に粗いと定義される。この特徴は画像のなめらかな面（例えば水面や裸地）と粗い面（例えば都市域や植生域）を区別するのに役立つ¹³⁾。具体例として、Entropy は画素値の乱雑さを示し、Entropy が大きいことはテクスチャが粗いことを示す。Entropy と Homogeneity は負の相関があり¹¹⁾、本研究でも Entropy の次に Homogeneity が高い分類精度を示したことも一致している。

GLCM 特徴量を用いたパターン B より GLCM 要素を直接用いたパターン C のほうが高い土地被覆分類精度を示した理由については次のように考察する。GLCM 特徴量は式 (3-4) から式 (3-11) で示されるように GLCM 要素の線形結合で計算されるため、GLCM 要素が異なる値をとっても GLCM 特徴量が同値になることがある。具体例として Fig. 3-15 に示すグレーレベル数2、GLCM を算出するウィンドウサイズ 3×3 の領域 a および b を考える。領域 a と b は反転しているのでグレーレベルの相対的な出現頻度を表わす GLCM 要素は異なっているが、算出される GLCM 特徴量である Entropy は同値になる。以上のように、GLCM 要素中のグレーレベルの相対的な出現頻度情報が GLCM 特徴量では失われてしまうため、GLCM 要素のほうが GLCM 特徴量より多くのウィンドウ内のテクスチャ情報を含んでいると考えられる。従って、入力データとしてグレーレベルの相対的な出現頻度情報を持つ GLCM 要素の方が、SVM を使用した土地被覆分類に有効に機能し、高い土地被覆分類精度を示したと考

えられる。

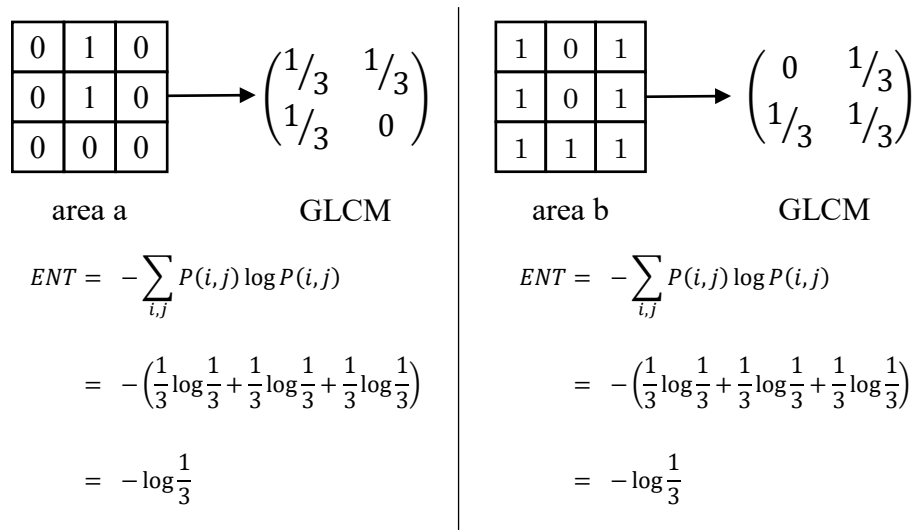


Fig. 3-15 Example of the GLCM entropy calculations in different gray level windows.

Fig. 3-11 および Fig. 3-13 から判断すると、GLCM を算出するウィンドウサイズについては、3×3 から 11×11 までとそれ以降で精度向上率が変化する。また、グレーレベル数については、2 では不十分であり、大きいほど精度が向上し、パターン(B)all およびパターン C では 8 以上とすることにより、より小さいウィンドウサイズでの精度向上が確認できた。空間分解能 7cm の UAV 搭載 RGB カメラデータを使用した都市域画像を対象にした Feng らの研究では、ウィンドウサイズ 31×31 でピークを示していたが 21×21 との差は小さかった¹⁴⁾。以上より、ウィンドウサイズとグレーレベル数は大きくすることにより高い精度が期待できるが、どちらも計算負荷に直接影響するパラメータであることを考慮する必要がある。具体的には、グレーレベル数増加は GLCM 行列サイズ増加となり GLCM 特徴量計算量増加や GLCM 要素数増加となる。また、ウィンドウサイズ増加は空間分解能に直接影響するため、データの空間分解能と分類対象物の大きさとの関係を考慮すると、あまり大きなサイズにしない方が良いと考えられる。

Stratified CV と Nested CV による土地被覆分類精度を比較した結果、両方とも同様の傾向を示していたことから、本章の土地被覆分類精度評価においては SVM の過学習の影響は少なかったと判断できる。本章では精度算出手法として交差検証を使用した。またトレーニングデータは 11×11pixel の局所領域から取得しているため、テクスチャ情報やスペクトル情報が類似したトレーニングデータを多く含んでいると考えられる。したがって、検証用データと学習したデータの乖離が少なく、結果的に過学習を起こしたとしても分類精度への影響は少なかった可能性がある。

パラメータ C と γ は、入力データによって最適値が異なり、Grid Search によるパラメータ最適化が機能していることがわかった。今回の結果では、最適値は、 C は 8 から 512, γ は 4 から 32 の範囲であり、Grid Search の探索範囲は、今後検討の余地がある。また、重複データによるカテゴリ毎のサンプル数の偏りは、カテゴリ毎の重

みからほぼ同比率のサンプル数であったため、土地被覆分類精度に影響しなかったと考えられる。

3.4.2 トレーニングデータ中の影の影響

Fig. 3-10 より、各カテゴリのトレーニングデータには画像中の影を含んだ領域も使用していたため、3.3.2 節および 3.3.3 節に示した土地被覆分類精度評価結果は、画像中にある影の影響による誤分類を含んだ結果となっている。本節では、トレーニングデータから影の領域を除外して土地被覆分類精度評価を実施した結果を示す。Fig. 3-10 に示すトレーニングエリア抽出箇所から影の領域にあるトレーニングエリアを除外した、各カテゴリ 18 箇所のトレーニングエリアを Fig. 3-16 に示す。




Fig. 3-16 Locations of extracting training samples after excluding shadow area.
(a)forest, (b)grassland, (c)baresoil, and (d)road.

Fig. 3-16 に示す各カテゴリ 18 箇所トレーニングデータを使用した土地被覆分類精度評価結果として、Table 3-5 に Stratified CV で得られた各パターンの土地被覆分類精度の最大値を、Table 3-6 に Nested CV で得られた各パターンの土地被覆分類精度の最大値を示す。Table 3-5 および Table 3-6 より、Stratified CV と Nested CV の結果は同様の傾向を示しているが、Table 3-3 および Table 3-4 と比較すると全体的に精度が上がっていることがわかる。また、パターン(B)all とパターン C は、Stratified CV および Nested CV とともに土地被覆分類精度が 100%に到達した。なお、3.4.2 節および 3.4.3 節同様に、いずれのパターンにおいてもウィンドウサイズ 21×21 でグレーレベル数 16 の場合に土地被覆分類精度が最大となった。

3.4.2 節および 3.4.3 節で示した結果と比較することによって、トレーニングデータに影の領域を含めることによる誤分類の影響を評価できる。影の領域の有無による土地被覆分類精度は、Stratified CV では、パターン A が 93.26%から 88.72%へ約 4.5 ポイント低下し、パターン(B)all では 100%から 99.72%へ約 0.3 ポイント低下、パターン C では 100%から 99.76%へ約 0.2 ポイント低下した。以上より、トレーニングデータ中の影の影響で生じるスペクトル情報の変化による誤分類の影響が、テクスチャ情報を追加することで緩和されたと結論できる。

Table 3-5 Comparison of maximum accuracies for land cover classification by Stratified CV for the sampled data in Fig. 3-16.

Pattern		OVA[%]
A		93.264
B	entropy	99.105
	energy	98.967
	contrast	98.140
	mean	98.290
	variance	98.163
	correlation	94.984
	homogeneity	98.519
	dissimilarity	98.772
	all	100.000
C		100.000

Table 3-6 Comparison of maximum accuracies for land cover classification by Nested CV for the sampled data in Fig. 3-16.

Pattern		Kappa coef.
A		0.908
B	entropy	0.986
	energy	0.984
	contrast	0.971
	mean	0.977
	variance	0.973
	correlation	0.928
	homogeneity	0.980
	dissimilarity	0.981
	all	1.000
C		1.000

パターン B 内に注目すると、(B)correlation および (B)variance の土地被覆分類精度から、影を含まない場合に最も分類精度が低下したのは Variance であり、影を含む場合に最も分類精度が低下したのは Correlation であった。このことから、影の有無により有効な GLCM 特徴量に変化すると考えられる。テクスチャ情報として GLCM 特徴量を使用する場合は、使用するデータにより有効な GLCM 特徴量を事前に検討する必要がある。

3.4.3 Kappa 係数の有意差検定

Nested CV で得られる土地被覆分類精度 (Kappa 係数) について, その有意差を評価するために, Congalton が提案した Kappa 係数の有意差を評価する手法⁴³⁾を使用した。2 つの土地被覆分類精度の結果として算出された Kappa 係数 (K_1 および K_2) について, 有意差があるか否かを判断する式を式 (3-25) に示す。

$$Z = \frac{|K_1 - K_2|}{\sqrt{\text{var}(K_1) + \text{var}(K_2)}} \quad (3-25)$$

ここで, K_1 および K_2 はそれぞれの Kappa 係数を示し, $\text{var}(K_1)$ および $\text{var}(K_2)$ は Kappa 係数の分散で Confusion matrix の要素から算出される。Z の値が 1.96 より大きくなった場合, 5%の有意水準で 2 つの Kappa 係数に差があると判断できることになる。

Table 3-7 に影を含むトレーニングデータの Kappa 有意差検定結果を, Table 3-8 に影を含まないトレーニングデータの Kappa 有意差検定結果を示す。Kappa 有意差検定結果はパターン A, (B)entropy, (B)all, C の 4 パターンで算出し, 算出には Nested CV で得られた 5 つの Confusion matrix の平均値を使用した。なお, 算出に使用したパターン(B)entropy, (B)all, C については, 最も土地被覆分類精度が高かったグレーレベル数, ウィンドウサイズを使用し, いずれもグレーレベル数 16, ウィンドウサイズ 21 × 21 で算出した。Table 3-7 および Table 3-8 の結果をみると, 両者ともパターン(B)all と C との組み合わせ以外では 1.96 以上と有意な差が見られたが, パターン(B)all と C とでは, 5%有意水準で有意な差が見られなかった。また, 影を含めなかった場合より影を含めた場合の方が, 全てにおいて Z の値が増加していた。このことから, パターン A やパターン(B)entropy の場合よりも, パターン(B)all やパターン C の場合のほうが, 土地被覆分類精度は有意に効果的であるが, パターン(B)all と C は, 5%有意水準で土地被覆分類精度に差が見られないと言える。ただし, 3.4.1 節および 3.4.2 節で示したように, パターン C の方がパターン(B)all と比較して土地被覆分類精度が高いことや, 3.4.1 節および 3.4.2 節で述べたように, 有効な GLCM 特徴量を事前に検討する必要がないことを踏まえると, 本研究で行った手法の中では, 提案手法のパターン C が最も土地被覆分類精度向上に有効であると判断できる。さらに, Table 3-5 および Table 3-6 を見るとパターン(B)all とパターン C は分類精度が飽和しており, 比較ができない状態であり, Table 3-3 および Table 3-4 の結果を見ても, 99%以上と十分に高い分類精度となっている。したがって, 両パターンともに分類精度が高かったために有意な差が現れなかった可能性が考えられる。そのため, より分類精度向上が難しいデータを用いた場合には有意な差が見られる可能性があり, その検証が必要であると考える。

Table 3-7 List of derived Z in Nested CV for the samples in Fig. 3-10.

		Pattern			
		A	B		C
			entropy	all	
Pattern	A		23.77	28.89	29.22
	B	entropy	23.77		13.24
		all	28.89	13.24	
	C	29.22	14.39	1.860	

Table 3-8 List of derived Z in Nested CV for the samples in Fig. 3-16.

		Pattern			
		A	B		C
			entropy	all	
Pattern	A		15.04	18.56	18.64
	B	entropy	15.04		8.875
		all	18.56	8.875	
	C	18.64	9.158	1.413	

3.5 第3章まとめ

UAV で取得された空間分解能約 7cm の 5 バンドの画像を使用して、3 パターンの入力データ（スペクトル情報のみ、スペクトル情報+GLCM 特徴量、スペクトル情報+GLCM 要素）について、SVM 分類器による土地被覆分類精度を交差検証によって比較した。その結果、テクスチャ情報が土地被覆分類精度向上に有効であることが確認できた。以下に本章の主要な成果をまとめる。

- (1) テクスチャ情報として GLCM 特徴量または GLCM 要素を直接特徴ベクトルに加えることで、土地被覆分類精度向上が確認できた。
- (2) スペクトル情報に加える GLCM 特徴量として、Entropy と Homogeneity が有効であることがわかった。
- (3) 提案手法の効果は有効な GLCM 特徴量を事前に検討することなく、テクスチャ情報を土地被覆分類精度向上に反映できることがわかった。

本章の提案手法とパターン(B)all との間で分類精度に有意な差が見られなかった。しかし、両手法による結果ともに分類精度が 99%を超えていることから、より精度向上が難しいデータの土地被覆分類では、有意な差が見られる可能性があるとは結論づける。なお、第 4 章では、土地被覆分類精度向上が難しいとされる SAR データを使用することによって、提案手法が汎用的に土地被覆分類精度向上に有意に有効か評価する。

第4章 Sentinel-1 SAR データを用いた浸水域抽出

第3章では、GLCM要素を使用する提案手法が、GLCM特徴量を使用した場合よりも、土地被覆分類精度が向上することを示したが、GLCM特徴量8種を使用した場合と提案手法との間に有意な差が見られなかった。第3章では、両パターンでの分類精度が既存手法を適用した時点で飽和していたために差が生じなかったことが可能性としてであると結論づけた。したがって、分類精度向上が難しいデータで比較する必要がある。

第4章では、2時期の局所入射角を補正したSAR後方散乱係数 (γ^0) 画像を用いた土地被覆分類を対象とする。2.2節で述べたように、SARデータを用いた土地被覆分類は一般的に分類精度向上が難しいことが知られている。そのため、 γ^0 画像を用いた土地被覆分類では、既存手法と提案手法との間に有意差が見られ、提案手法の優位性や汎用性を評価できる可能性がある。

本章では、2019年台風19号による福島県郡山市内の浸水被害を受けた市街地および水田域について、2時期のSentinel-1のSARデータを使用したSVMによる浸水被害域の抽出を行う。2019年10月12日19時頃に日本列島に上陸した同台風は東日本を中心とした広い範囲に甚大な被害をもたらした。同月10日から13日までの総降水量は1000mmに達し、東日本では500mmの記録的な大雨となった。この台風によって浸水被害、土砂災害等が発生し、死者91名、住家約30000棟が浸水する被害に見舞われた。特に福島県では阿武隈川が堤防越水および堤防決壊を起こし、床上浸水1161棟、床下浸水443棟の浸水被害が発生したほか、全国最多となる30名以上の死者数を記録する災害となった。また収穫直前の水田の冠水により米の生産量にも大きな被害が発生した⁴⁴⁾⁴⁵⁾。

SARを用いた浸水域抽出については水田域と市街地域で後方散乱特性の変化が異なる。冠水した水田域では鏡面反射が支配的になることにより後方散乱の低下が観測され、この後方散乱の変化を利用して浸水水田域を検出する方法は多くのSARデータで適用できることが過去の研究でも示されている⁴⁶⁾⁴⁹⁾。浸水した市街地域では、水面での鏡面反射と建物壁面反射の2回散乱により、後方散乱は増加する傾向にある⁵⁰⁾が、建物密度やSARの入射角、入射波の方位角と建物壁面の相対的角度によって増加の大きさが異なる。そのため市街地域における浸水域抽出ではコヒーレンスを用いた検出手法がしばしば用いられる⁵¹⁾⁵²⁾⁵³⁾。しかし、台風19号による郡山市の浸水被害に関して、Sentinel-1 SARデータ上に現れる浸水被害の影響を解析し、後方散乱係数やコヒーレンス上の浸水被害の影響を求めた結果、市街地の後方散乱係数変化は場所によって異なり、コヒーレンスは市街地の浸水域検出では有効だが、水田域の浸水域検出は困難であることが示された⁵⁴⁾。

また、浸水域の検出精度を向上させる手法として、テクスチャ情報を用いた浸水域の検出手法も検討されている。GLCMから算出されるテクスチャ情報は、SARデータによる浸水域の検出にも使用でき、後方散乱係数とテクスチャ情報の両方を組み合わ

せて使用すると，浸水域の抽出精度向上に有効であった⁵⁵⁾⁵⁶⁾。

本章では，浸水域抽出における提案手法および有効な GLCM 特徴量の定量的な評価を行うため，後方散乱係数変化にテクスチャ情報を加えることにより，浸水被害域の抽出精度に与える影響を示す。また，観測偏波が土地被覆分類にどのように寄与するか評価するため，2 偏波データ入力と単偏波データ入力の浸水域抽出精度を比較することによって，市街地と水田域の浸水領域抽出における観測偏波の有効性を評価した結果について報告する。本章では時系列 SAR 画像を使用して浸水域と非浸水域を検出するための土地被覆分類を行うが，本章では「浸水域抽出」と呼ぶことにする。

4.1 使用データ

本章では2019年台風19号により発生した浸水被害域の抽出を通して提案手法の有効性を評価する。

本章で使用する SAR データは10月7日午前5時43分 (JST) および10月13日午前5時42分 (JST) に取得された Sentinel-1 C-band SAR データである。これらのデータは欧州宇宙機関 (ESA) が運営する Copernicus Open Access Hub から取得した Level-1 プロダクトの Ground Range Detected (GRD) データである。Table 4-1 に取得したデータの概要を示す。

浸水域および非浸水域の真値データとして、本章では国土地理院 (GSI) が公開している浸水推定図⁴⁵⁾ (GSI が収集した情報と標高データを用いて、浸水範囲における水深を算出して深さごとに色別に表現した地図) を使用する。Fig. 4-1 に本研究で使用する浸水推定図を示す。浸水推定図を基に浸水域と非浸水域を選定し、それぞれから市街地域および水田域を目視によりカテゴリ分けを行なう。設定したカテゴリは浸水水田域 (flooded paddy), 浸水市街地域 (flooded built-up), 非浸水水田域 (non-flood paddy), および非浸水市街地域 (non-flood built-up) の4カテゴリとする。本研究におけるテストサイトおよび浸水域抽出におけるカテゴリを Fig. 4-2 に示す。

Table 4-1 Characteristics of Sentinel-1 SAR data.

Acquisition Time	5:43 AM 7 Oct. (JST)	5:42 AM 13 Oct. (JST)
Platform	Sentinel-1A	Sentinel-1B
Orbit Direction	Descending	Descending
Observation Mode	IWS	IWS
Polarization	VV + VH	VV + VH
Resolution (Range×Azimuth)	5m×20m	5m×20m

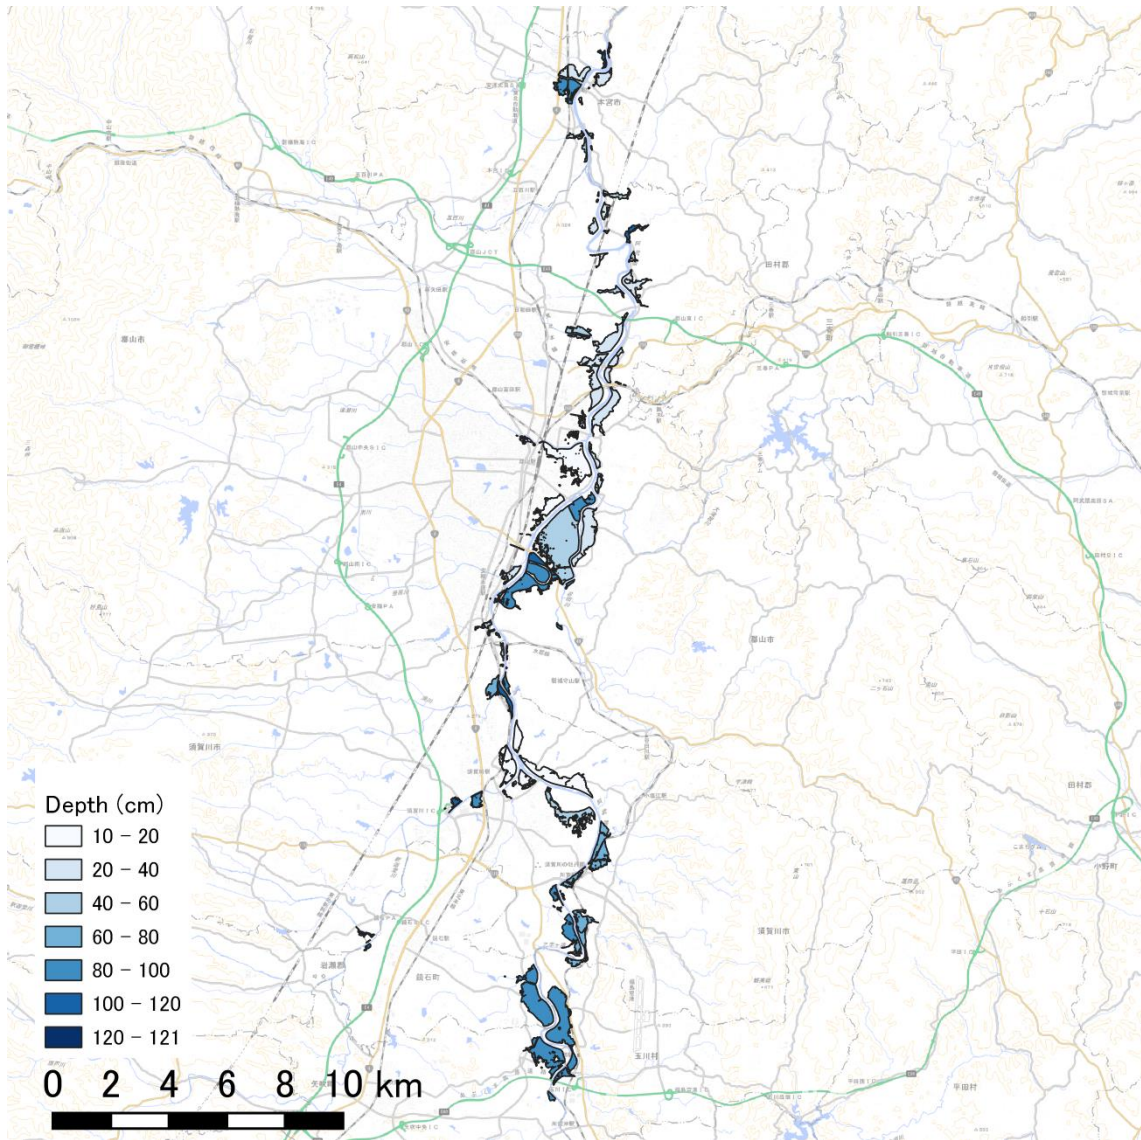


Fig. 4-1 Inundation estimation map created by GSI.

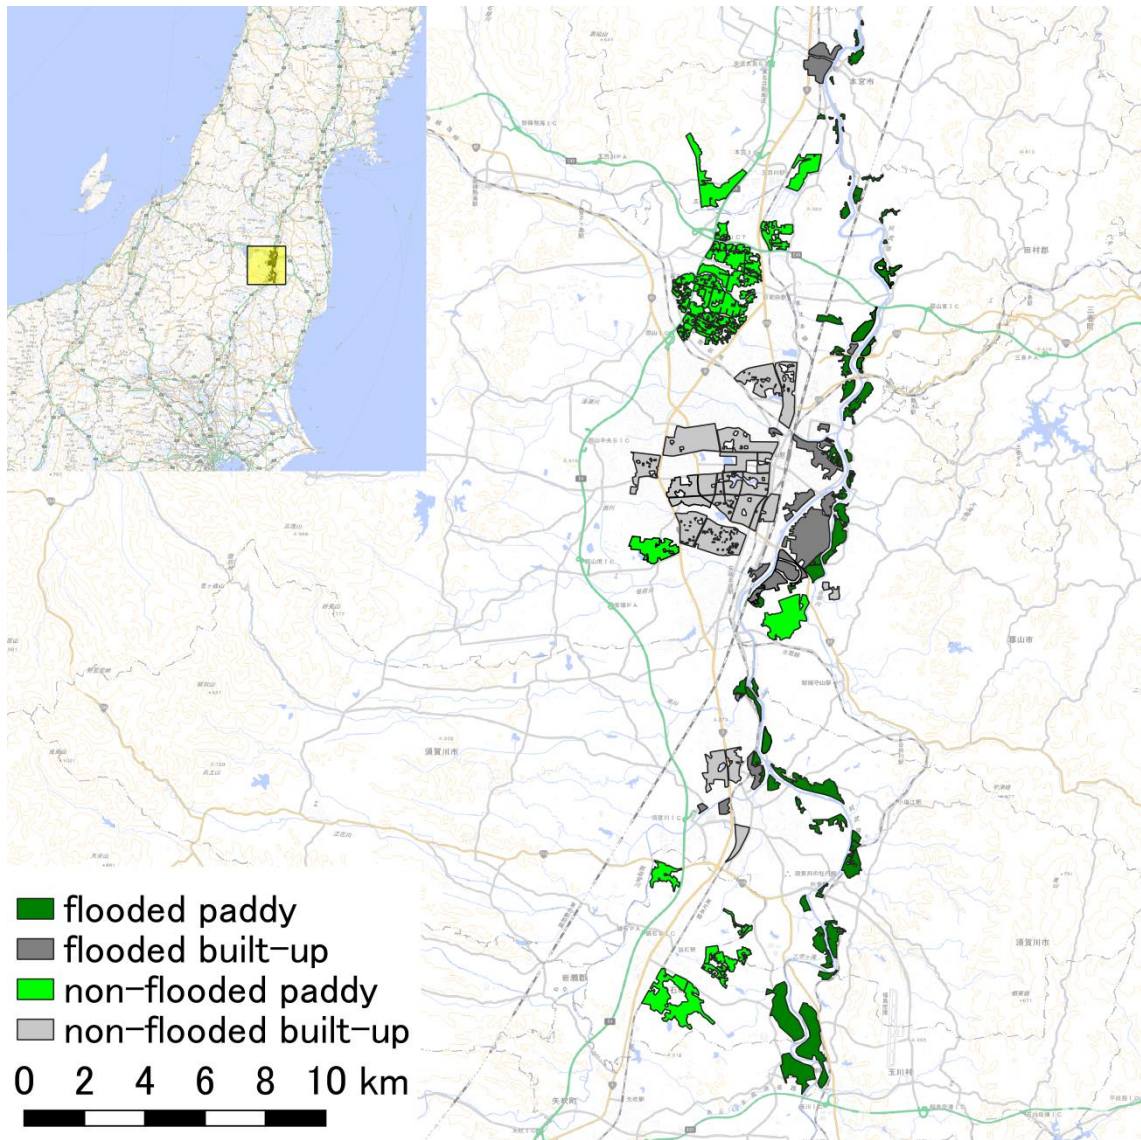


Fig. 4-2 Test site and categories determined based on Fig. 4-1.

4.2 Sentinel-1 データ前処理

本章のテストサイトである福島県郡山市は市街地を含め目立った起伏は無いため、後方散乱係数の局所入射角による影響は小さいと考えられるが、起伏の大きい地域への拡張性を考慮すると局所入射角による影響を補正することが望ましい⁵⁷⁾。したがって、本章では局所入射角による影響を補正した後方散乱係数画像 (γ^0) を入力データとした。浸水被害前後の γ^0 変化を使用して浸水域を検出するために10月7日および10月13日のVVおよびVH偏波の γ^0 画像を使用する。 γ^0 画像を作成するために、ESAが配布しているSentinel toolbox⁵⁸⁾を使用した。Sentinel toolboxを使用した γ^0 画像の作成は、Sentinel toolboxのデフォルト設定を使用した。また、テクスチャ情報として周辺画素の情報を等しいオフセットから取得するため、画素のアスペクト比が1になるようにピクセルスペーシング10mで地図投影を行っている。Sentinel toolboxによる γ^0 画像の作成手順を以下に示す。まず、高精度軌道データを取得後、熱雑音除去およびキャリブレーション処理を行った。その後、ラジオメトリックテラインフラットニング処理を行い、UTM座標系(zone 54N)にピクセルスペーシング10mでリサンプリングを行った。なお、ラジオメトリックテラインフラットニングおよび地図座標系投影にはSRTM-1デジタル標高モデル(DEM)を使用した。以降の処理は、関心領域のみを扱うため、テストサイトをカバーする972pixel×3739lineを抽出した。

作成した γ^0 画像は1ピクセルの表現が浮動小数点(32 bit float)でダイナミックレンジが広いため、飽和するデータをなるべく少なくするために、median interval 98%を採用し、-28.6 dB~7.1 dBの範囲を256階調(8bit)にスケーリングした。Table 4-2に作成した γ^0 画像の最大/最小値、 $\pm 3\sigma$ の範囲、およびmedian interval 98%における最大/最小値を示す。Fig. 4-3にテストサイトをカバーする領域の範囲、Fig. 4-4に抽出した γ^0 画像の8bitスケーリング後の画像を示す。

Table 4-2 Statistics of γ^0 Images.

Date	VV/VH	Max	Min	$+3\sigma$	-3σ	median interval 98%	
						Max	Min
7 Oct.	VV	35.2	-40.5	4.3	-19.4	5.3	-15.8
	VH	20.7	-59.2	-4.0	-25.3	-5.2	-24.1
13 Oct.	VV	35.6	-50.6	6.0	-21.0	7.1	-17.1
	VH	19.8	-55.6	-1.9	-27.8	-4.7	-28.6
				Max	Min	Max	Min
				6.0	-27.8	7.1	-28.6





Fig. 4-3 Cut out area (972pixel×3739line) covering our test site.

-28.6dB  7.1dB



(a)

(b)

(c)

(d)

**Fig. 4-4 8-bit scaled and cutout γ^0 images.
(a) VV image acquired on October 7 2019 ,
(b) VH image acquired on October 7 2019,
(c) VV image acquired on October 13 2019, and
(d) VH image acquired on October 13 2019.**

4.3 研究手法

本章の研究フローを Fig. 4-5 に示す。第 3 章との比較のため、第 3 章同様の研究手法となっている。第 3 章同様に、(A) : テクスチャ情報不使用の場合、(B) : テクスチャ情報として GLCM 特徴量を使用した場合、(C) : GLCM 要素を用いた場合 (提案手法) の 3 パターンのデータセットを作成し、それぞれに SVM を用いた浸水域抽出を行う。(B) で使用する GLCM 特徴量は第 3 章と同じものを使用する。GLCM の算出時のウィンドウサイズおよびグレーレベル数については、ウィンドウサイズを 3×3 , 7×7 , 11×11 , 15×15 , および 19×19 に、グレーレベル数を 2, 4, 8, および 16 で変化させ、計 20 通りの組み合わせを試行し、その中から最も精度向上が見られた組み合わせで各パターンの分類精度の比較を行う。

設定した 4 カテゴリにおいてそれぞれトレーニングエリアとテストエリアを設定し、トレーニングエリアから抽出したデータセットをトレーニングデータ、テストエリアから抽出したデータセットをテストデータとする。トレーニングデータを SVM で学習してモデルを作成し、作成した学習モデルによってトレーニングエリアおよびテストエリアにおける浸水域抽出精度を算出する。浸水域抽出精度の評価にはテストエリアの浸水域抽出結果から算出した Kappa 係数を使用し、各カテゴリの抽出精度の評価にはテストエリアの浸水域抽出結果から算出した F₁ Score (F 値) を使用する。

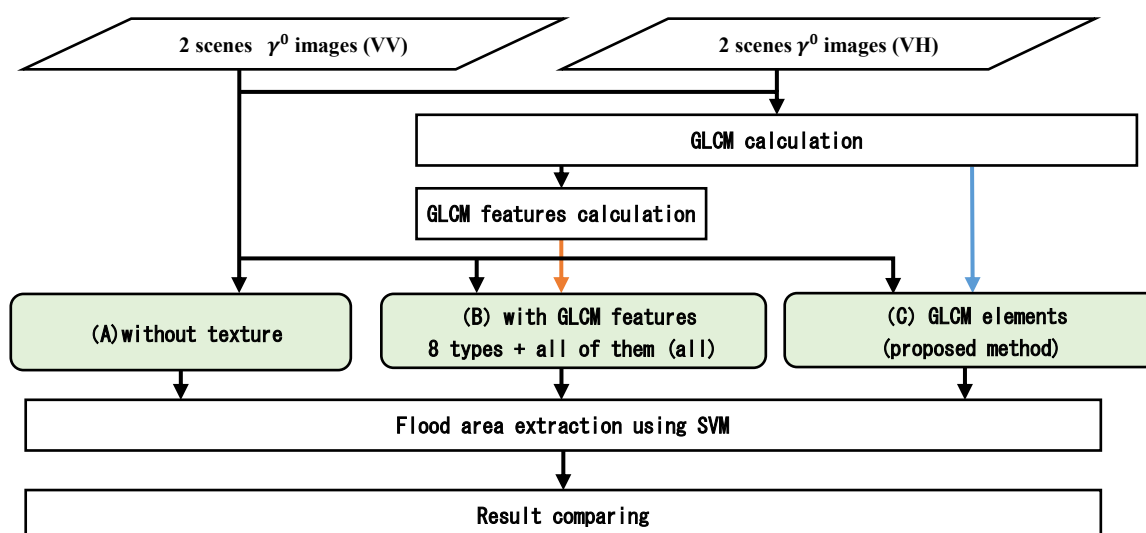


Fig. 4-5 Procedure of inundation area detection.

4.3.1 分類器と入力特徴ベクトル

第3章と同様の手法を実施するため、本章でも非線形 SVM として C-Support Vector Classifier (C-SVC) を使用し¹⁶⁾³⁵⁾, カーネル関数として RBF カーネルを使用した⁷⁾³⁷⁾。このとき調整が必要な2つのパラメータ (C と γ) の最適値探索に Stratified 5-fold Cross Validation⁴¹⁾を用いた Grid Search⁴⁾法を使用した。Grid Search での探索範囲は、 $2^{-10} \leq \gamma \leq 2^{10}$, $2^{-5} \leq C \leq 2^{15}$ とし、 γ の探索範囲を狭め、かつ高い値とした。主な理由として Grid Search にかかる時間の短縮化がある。 γ^0 画像の学習は、マルチスペクトル画像の学習よりも識別境界を求めるのに時間がかかった。SVM の学習モデル生成にかかる時間の大半は Grid Search が占めているため、探索範囲を狭めることで学習にかかる時間を効果的に削減できる。また式 (3-23) より、探索する γ の値は 0 に近づくほど線形カーネルに近似するため、 γ の探索範囲は 2^{-20} まで探索する必要はないと判断した。

SVM へ入力する特徴ベクトル構成は、浸水被害発生前の VV および VH 偏波 γ^0 , 浸水被害発生後の VV および VH 偏波 γ^0 の順に並べた。テクスチャ情報を付加する場合は浸水被害発生前の VV および VH 偏波のテクスチャ情報、浸水被害発生後の VV および VH 偏波のテクスチャ情報の順に追加した。Fig. 4-6 に使用した入力特徴ベクトル構成を示す。なお、入力データの特徴ベクトルについては、要素毎に最小値から最大値をスケールして-1 から 1 まで正規化を行っている。

トレーニングエリアの選定には、各カテゴリのトレーニングエリアの取得画素数に可能な限り差が生じないように調整し、浸水水田域から 5 ヶ所、浸水市街地域から 2 ヶ所、非浸水水田域から 1 ヶ所、および非浸水市街地域から 1 ヶ所選定した。Fig. 4-7 にトレーニングエリアおよびテストエリアを示す。トレーニングエリアの取得画素数は浸水水田域から 9158 画素、浸水市街地域から 9221 画素、非浸水水田域から 8403 画素、非浸水市街地域から 8327 画素取得した。取得したトレーニングデータは不均衡なデータ数なので、重複データを削除した後各カテゴリの重み付けを SVM 学習時に行うことにより、不均衡データの学習結果への影響を抑制した。

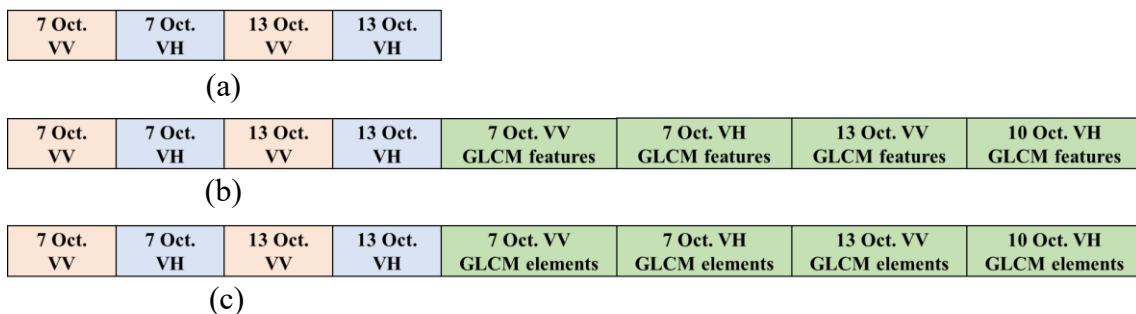
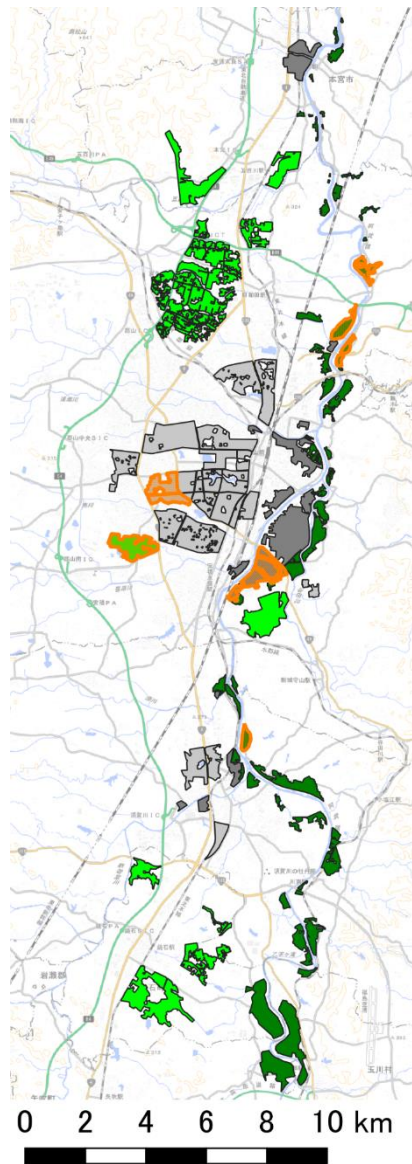


Fig. 4-6 Configuration of input feature vectors.

- (a)Pattern A: γ^0 only , (b)Pattern B: γ^0 +GLCM texture feature , and
(c)Pattern C: γ^0 +GLCM elements.



- flooded paddy
- flooded built-up
- non-flooded paddy
- non-flooded built-up

- training area
- test area

Fig. 4-7 Training and test areas selected.

4.3.2 テクスチャ情報

入力特徴ベクトルのテクスチャ情報として GLCM の要素から算出される特徴量を使用する。GLCM はグレースケール数が N_g であるグレースケール画像の相対位置 $(\Delta x, \Delta y)$ の位置関係にあるピクセル同士の画素値の出現頻度を表す行列であり、 $N_g \times N_g$ の正方行列となる。GLCM 行列の i 行 j 列目の要素は相対位置 $(\Delta x, \Delta y)$ であるピクセル同士の画素値が i と j である確率となり、 i と j はそれぞれグレースケール画像の画素値に対応する¹⁵⁾³³⁾。ウィンドウサイズが $M \times N$ の場合の GLCM の行列要素 $P(i, j : \Delta x, \Delta y)$ の算出式を式 (4-1) に示す。

$$P(i, j : \Delta x, \Delta y) = WQ(i, j : \Delta x, \Delta y) \quad (4-1)$$

ここで、式 (4-1) 右辺の W と $Q(i, j : \Delta x, \Delta y)$ は式 (4-2) および式 (4-3) で与えられる。

$$W = \frac{1}{(M - |\Delta x|)(N - |\Delta y|)} \quad (4-2)$$

$$Q(i, j : \Delta x, \Delta y) = \sum_{m=1}^{M-|\Delta x|} \sum_{n=1}^{N-|\Delta y|} A_{ij}(m + \delta(-\Delta x), n + \delta(-\Delta y) : \Delta x, \Delta y) \quad (4-3)$$

また、式 (4-3) 右辺の $A_{ij}(m, n : \Delta x, \Delta y)$ と $\delta(x)$ は式 (4-4) および式 (4-5) で与えられる。

$$A_{ij}(m, n : \Delta x, \Delta y) = \begin{cases} 1 : (I(m, n) = i) \wedge (I(m + \Delta x, n + \Delta y) = j) \\ 0 : \text{elsewhere} \end{cases} \quad (4-4)$$

$$\delta(x) = \begin{cases} x : x > 0 \\ 0 : \text{elsewhere} \end{cases} \quad (4-5)$$

式 (4-4) 右辺の $I(m, n)$ は算出ウィンドウの左上座標を $(1, 1)$ としたときの画像のグレースケール値を示す。SAR データでは、アジマス方向とレンジ方向で空間分解能が異なることから、GLCM 算出時の方位依存性が無いとは言い切れない。そのため、 $(\Delta x, \Delta y)$ については $(1, 0)$, $(1, 1)$, $(0, 1)$, $(-1, 1)$ の 4 方向について GLCM 算出を行い、各方位で得られた算出値を合算後に式 (4-6) に示すように対称行列化し正規化した。

$$P(i, j) = \frac{1}{2} W_t (Q_t(i, j) + Q_t(j, i)) \quad (4-6)$$

ここで、 W_t および Q_t は以下の式 (4-7) および式 (4-8) で与えられる。

$$W_t = \frac{1}{(M-1)N + 2(M-1)(N-1) + M(N-1)} \quad (4-7)$$

$$Q_t(i, j) = Q(i, j : 1, 0) + Q(i, j : 1, 1) + Q(i, j : 0, 1) + Q(i, j : -1, 0) \quad (4-8)$$

以上の GLCM 要素を使用してテクスチャ特徴量を算出し、SVM の入力特徴ベクトルの要素として加えた。使用したテクスチャ特徴量は 3.2.3 節に示したものと同じである。Fig. 4-8 に $(\Delta x, \Delta y) = (1, 0)$, グレーレベル数 4 のときの GLCM と Entropy の算出例を示す。GLCM テクスチャは周辺画素情報を加味した情報であるため、GLCM テクスチャを適用することにより、空間分解能を低下させることなく、浸水域抽出精度の向上が期待できる。よって γ^0 画像の空間分解能は変化していない。またこれは入力する画素値の整数化が必要なことを意味している。本研究では 4.2 節に示したように、入力画像を 8bit (256 階調) に整数化した上で、グレーレベル数を 2, 4, 8, および 16 に階調変換したものを各グレーレベル数として使用する。

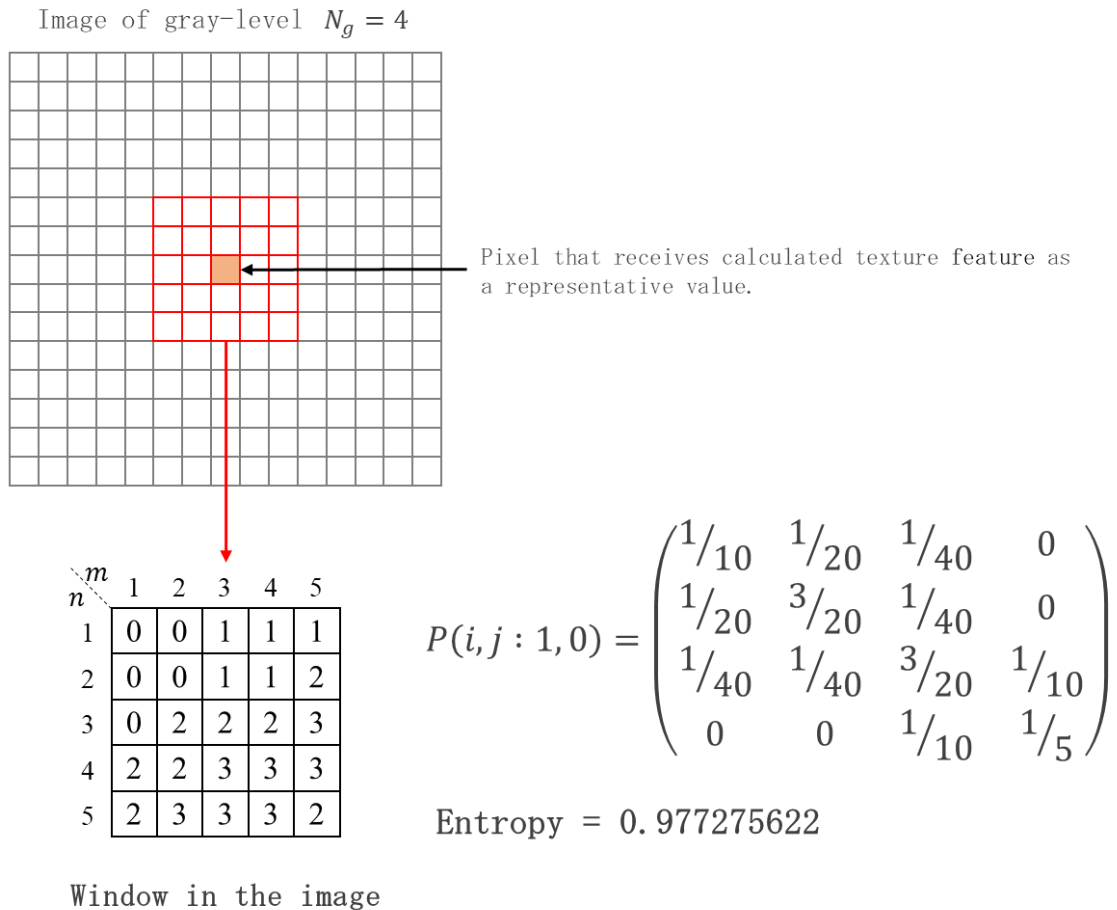


Fig. 4-8 An example of GLCM texture and entropy calculation.

4.3.3 精度評価手法

Fig. 4-9 に浸水域抽出精度の算出手順を示す。第 3 章では、適切な真値データがなくテストエリアを設定できなかったため、トレーニングエリア中で **Cross Validation** を使用することによって土地被覆分類精度を評価した。本章では、国土地理院の浸水推定図を浸水域真値として使用できるため、テストエリア設定が可能であり、テストエリアにおける浸水域分類精度算出を行なう。本章では、トレーニングエリアから取得したトレーニングデータを用いて **SVM** の学習モデルを作成し、作成された学習モデルでトレーニングデータおよびテストデータを分類することによりトレーニングエリアおよびテストエリアにおける浸水域抽出精度を算出する。パターン(B)および(C)では、これを各ウィンドウサイズおよびグレーレベル数で行い、4.3 節で述べた 20 通りの浸水域抽出精度を算出する。その後、算出された 20 通りのテストエリアの浸水域抽出精度の中から、最も浸水域抽出精度の高い組み合わせをそのパターンにおける浸水域抽出精度として採用し、トレーニングエリアおよびテストエリアの浸水域抽出精度を比較する。

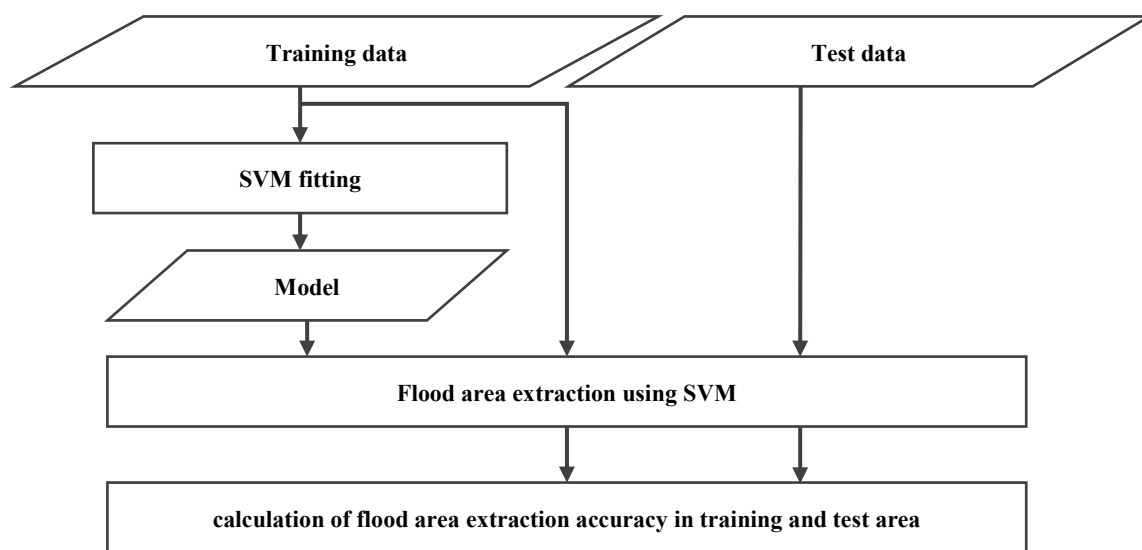


Fig. 4-9 Accuracy calculation scheme.

4.4 結果

Table 4-3 に各パターンのテストエリアにける浸水域抽出精度を示す。各パターンで最も浸水域抽出精度が向上したパターンは提案手法の(C)であった。その次に精度向上が見られたパターン(B)all であり、次いで(B)mean であった。Fig. 4-10 に各パターンの中から、(A)、(B)mean、(B)all、(C)の浸水域抽出画像を示す。この図においてテクスチャ情報を使用した浸水域抽出結果画像は、Table 4-3 に示されたウィンドウサイズおよびグレーレベル数の場合である。

(A)の場合の Kappa 係数はトレーニングエリアで 0.763、テストエリアで 0.615 となった。トレーニングエリアにおける各カテゴリの F 値を見ると、浸水水田域は 0.881、浸水市街地域は 0.794、非浸水水田域は 0.820、および非浸水市街地域は 0.791 となった。テストエリアにおける各カテゴリの F 値を見ると、浸水水田域は 0.747、浸水市街地域は 0.508、非浸水水田域は 0.755、および非浸水市街地域は 0.754 となった。

(B)については比較的浸水域抽出精度が大きく向上した(B)all と(B)mean について抜粋して述べる。(B)all で最も浸水域抽出精度が向上したウィンドウサイズとグレーレベル数の組み合わせは、ウィンドウサイズ 19×19、グレーレベル数 8 であった。このときの Kappa 係数はトレーニングエリアで 1.000、テストエリアで 0.838 となった。


トレーニングエリアにおける各カテゴリの F 値を見ると、全てのカテゴリで 1.000 となった。テストエリアにおける各カテゴリの F 値を見ると、浸水水田域は 0.907、浸水市街地域は 0.656、非浸水水田域は 0.935、および非浸水市街地域は 0.895 となった。(B)mean で最も浸水域抽出精度が向上したウィンドウサイズとグレーレベル数の組み合わせは、ウィンドウサイズ 19×19、グレーレベル数 4 であった。このときの Kappa 係数はトレーニングエリアで 0.994、テストエリアで 0.805 となった。トレーニングエリアにおける各カテゴリの F 値を見ると、浸水水田域は 0.999、浸水市街地域は 0.993、非浸水水田域は 0.999、および非浸水市街地域は 0.992 となった。テストエリアにおける各カテゴリの F 値を見ると、浸水水田域は 0.906、浸水市街地域は 0.632、非浸水水田域は 0.932、および非浸水市街地域は 0.848 となった。

(C)では、ウィンドウサイズ 19×19、グレーレベル数 16 の場合に、テストエリアにおいて最も浸水域抽出精度が向上した。このときの Kappa 係数はトレーニングエリアでは 1.000、テストエリアでは 0.859 となった。トレーニングエリアにおける各カテゴリの F 値を見ると、全カテゴリで 1.000 となった。テストエリアにおける各カテゴリの F 値を見ると、浸水水田域は 0.924、浸水市街地域は 0.736、非浸水水田域は 0.949、および非浸水市街地域は 0.896 となった。

Table 4-3 Summary of inundation detection results.

Pattern			(A)	(B)									(C)	
				entropy	energy	mean	variance	correlation	contrast	homogeneity	dissimilarity	all		
Training	Kappa Coefficient		0.763	0.993	0.981	0.994	0.980	0.910	0.960	0.979	0.948	1.000	1.000	
	F ₁	flooded	paddy	0.881	1.000	1.000	0.999	1.000	0.972	1.000	1.000	0.998	1.000	1.000
			built-up	0.794	0.990	0.973	0.993	0.974	0.893	0.953	0.971	0.930	1.000	1.000
	non-flooded	paddy	0.820	0.999	0.999	0.999	0.997	0.965	0.996	0.998	0.990	1.000	1.000	
		built-up	0.791	0.988	0.971	0.992	0.970	0.898	0.948	0.968	0.924	1.000	1.000	
Test	Window Size		-	19×19	19×19	19×19	19×19	19×19	19×19	19×19	19×19	19×19	19×19	
	Gray-Level		-	8	16	4	8	4	16	16	16	8	16	
	Kappa Coefficient		0.615	0.763	0.765	0.805	0.775	0.685	0.773	0.752	0.772	0.838	0.859	
	F ₁	flooded	paddy	0.747	0.894	0.894	0.906	0.902	0.849	0.895	0.892	0.894	0.907	0.924
			built-up	0.508	0.583	0.589	0.632	0.602	0.519	0.587	0.560	0.595	0.656	0.736
		non-flooded	paddy	0.755	0.904	0.902	0.932	0.886	0.792	0.885	0.901	0.887	0.935	0.949
			built-up	0.754	0.822	0.818	0.848	0.837	0.802	0.824	0.808	0.836	0.895	0.896

■ flooded paddy ■ flooded built-up ■ non-flooded paddy ■ non-flooded built-up



(a)

(b)

(c)

(d)

Fig. 4-10 Example of inundation detection result images (a)pattern(A), (b)pattern(B)mean, (c)pattern(B)all, and (d)pattern(C).

4.5 考察

4.5.1 浸水域抽出精度比較

Table 4-3 に示す各パターンの浸水域抽出精度を比較すると、(A)の後方散乱係数の変化のみを使用した結果のテストエリアにおける Kappa 係数は 0.615 であり、提案手法の(C)では浸水域抽出精度を 0.244 向上することが可能であった。また(B)all についても(A)と比較すると、0.223 の精度向上が可能であった。それ以外のパターンについても、テクスチャ情報不使用の場合と比較すると全てのパターンにおいて浸水域抽出精度の向上が見られた。以上より、後方散乱係数変化にテクスチャ情報の変化を加えることによって浸水域抽出精度を向上させることが可能であった。

Sentinel-1 の IW モードの有効ルック数はスキャンによって 4.4~4.5⁵⁹⁾⁶⁰⁾となっていて、画像上には有効ルック数に対応するスペックルノイズが存在する。GLCM のウィンドウサイズで計算されるテクスチャ情報は、そのスペックルノイズによる画素値変化も含んだものになり、より広いウィンドウサイズの GLCM 要素の方が、対象領域の特徴をテクスチャ情報としてより多く捉えるため、浸水域抽出精度を向上させることが可能であったと判断できる。

(B)において、単体で最も浸水域抽出精度向上が見られた GLCM 特徴量は Mean であった。第 3 章の高分解能マルチスペクトル画像の土地被覆分類においては、Entropy が最も有効であることが示されたのに対し、SAR の後方散乱係数を用いた浸水域抽出では、有効な GLCM 特徴量が異なる結果となった。GLCM から算出される特徴量 Mean は隣接する画素のグレーレベル数の出現頻度確率の期待値と解釈できる。GLCM 特徴量 Mean が最も精度向上が見られた理由として、SAR の後方散乱データに現れるスペックルノイズの統計的な特徴をよく表すことができたと仮定すると、このスペックルノイズの確率分布が正規分布と同様の分布になっていた可能性が考えられる。

SAR の後方散乱係数データにかかるスペックルノイズは式 (4-9) の形で現れる⁶¹⁾⁶²⁾。また、 g の平均は式 (4-10) のように表される。

$$g = f \cdot n \quad (4-9)$$

$$\overline{g} = \overline{f} \cdot \overline{n} \quad (4-10)$$

ここで、 g は後方散乱データの DN 値、 f は対象物特有の後方散乱、 n はスペックルノイズを表す。水域検出において、冠水した領域は均質面であるため、 f は一定の値になると考えられる。この場合、 g の確率密度関数はスペックルノイズの確率密度関数 $p(n)$ と同様になる。 $p(n)$ は式 (4-11) に示すような χ^2 分布で表される。

$$p(n) = \frac{2n^{2N-1}N^N e^{-Nn^2}}{\Gamma(N)} \quad (4-11)$$

ここで、 N はマルチルック数、 $\Gamma(N)$ はガンマ関数である。この確率密度関数の平均値 \bar{n} は式 (4-12) のように表される。

$$\bar{n} = \frac{\Gamma\left(N + \frac{1}{2}\right)}{N^{\frac{1}{2}}\Gamma(N)} \quad (4-12)$$

このとき、 N が大きくなるほど、 $p(n)$ は正規分布に近似され、 \bar{n} は1に近づいていく。すなわち、 N が大きくなるほど後方散乱データのDN値 g は対象物特有の後方散乱 f の値に近づく。

使用した SAR データのマルチルック数はおよそ 4 である⁶³⁾。このときのスペックルノイズの確率分布は Fig. 4-11 のようになり、理論平均値は 0.97 となる。Fig. 4-11 を見ると、正規分布に近い確率分布を示していることがわかる。したがって、GLCM 特徴量 Mean が表していた値は対象物の後方散乱 f の平均値に近似された値であり、スペックルノイズの確率分布と相性の良い GLCM 特徴量であったと考えられる。ただし、これは Mean において最も精度向上が見られたグレーレベル数が 4 であった理由とあわせて、実際の分布やを参照しながら確かめる必要があり、今後の課題としたい。

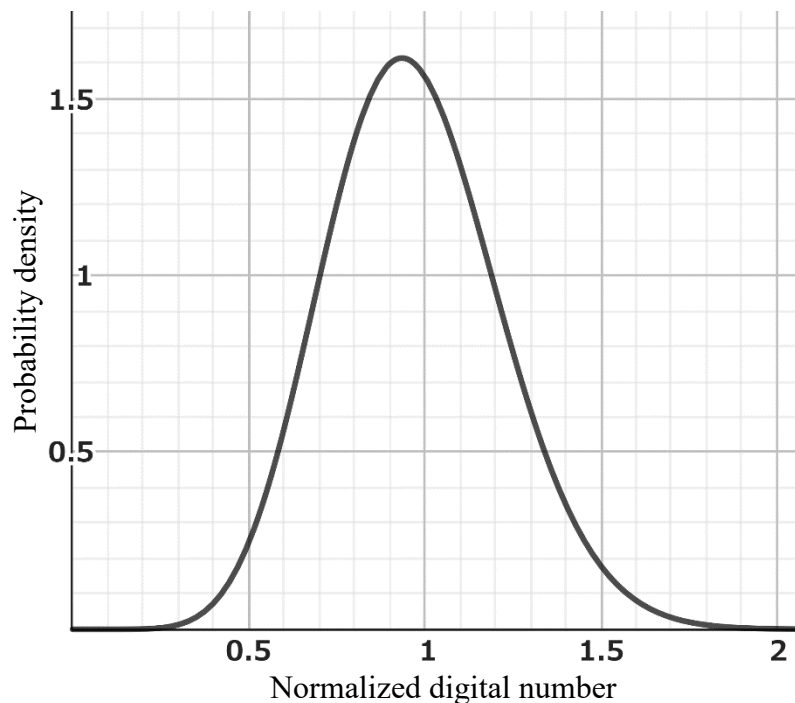


Fig. 4-11 Probability distribution of $p(n)$ for the case of multi-look 4.

Table 4-3 のテストエリアにおける各カテゴリの F 値を比較すると、パターン(C)を除き、浸水市街地域の F 値のみが 0.5 程となっており、他のカテゴリと比較して低い結果を示している。しかしトレーニングエリアの浸水市街地域の F 値については 0.8 から 0.9 程であり、他のカテゴリと同様に比較的高い値を示している。これは前述した市街地の浸水による後方散乱係数変化が複雑であるために、トレーニングエリアの学習結果がテストエリアでの F 値の向上に繋がらなかったことが考えられる。また、(C)の場合については、浸水市街地において、どのパターンよりも大きく精度が向上していることから、提案手法は GLCM 特徴量を使用した場合より浸水市街地に対しても高い識別性能を持つと考えられる。

本章冒頭でも述べたように、市街地と水田では浸水による γ^0 の変化が異なることが知られている⁵⁴⁾⁶⁴⁾。市街地では浸水により水面での鏡面反射と建物の壁面との 2 回散乱の成分が増加し、水田域では稲が冠水することにより鏡面反射が支配的になるため後方散乱係数が低下する。したがって、浸水被害前後の後方散乱係数変化によって、市街地域と水田域それぞれの浸水域を検出できる可能性がある。今回、浸水被害のあった郡山市の水田域は収穫前であり、後方散乱係数の冠水による低下は大きいと考えられる。しかし、市街地の浸水被害による後方散乱係数変化は、SAR の入射波方位角と建物の壁の相対的角度や建物密度によっても後方散乱係数変化が異なることが予想される。従って、水田域に関してはしきい値による浸水被害域検出はある程度可能である⁶⁵⁾が、市街地の浸水被害域検出は単純なしきい値では困難である⁶⁴⁾。しかし、本章の結果から判断すると、市街地の浸水域抽出について、機械学習を適用することによって抽出精度向上が可能であると結論できる。

第 4 章においても第 3 章同様に Kappa 有意差検定を行った。Table 4-4 に Kappa 有意差検定結果を示す。Table 4-4 から、いずれのパターンにおいても提案手法が 5%水準で有意差が確認できる。したがって、VV および VH 偏波の両偏波を用いた 2 時期の浸水域抽出において、提案手法は既存手法と比較して分類精度向上に効果があると結論できる。

Table 4-4 Result of calculation Kappa significant difference in flood area extraction.

		Pattern				
		A	B		C	
			entropy	all		
Pattern	A		160.97	201.35	221.20	
	B	entropy	160.97		51.48	80.59
		all	201.35	51.48		31.55
	C	221.20	80.59	31.55		

4.5.2 単偏波における浸水域抽出精度比較

テクスチャ情報を用いた浸水域抽出において、各偏波がどの程度寄与するかを評価するため、VV 偏波のみおよび VH 偏波のみのデータセットを作成し、浸水域抽出結果を評価する。Table 4-5 に単偏波における浸水域抽出精度の比較をまとめる。テストエリアにおける(C)の VV 偏波のみと VH 偏波のみの場合の F 値を比較すると、(C)の VV 偏波の浸水市街地域は 0.717、(C)の VH 偏波の浸水市街地域は 0.532 となり、VV 偏波の方が VH 偏波に比べ高い値となった。一方、浸水水田域の F 値については、(C)の VV 偏波の浸水水田域は 0.799、(C)の VH 偏波の浸水水田域は 0.909 となり、VH 偏波の方が VV 偏波に比べ高い値となった。これは(B)mean, (B)all の F 値についても同様の傾向がみられた。以上より、VV 偏波は市街地域の浸水域抽出精度向上に、VH 偏波は水田域の浸水域抽出精度向上に有効であることが示唆される。市街地浸水域での後方散乱係数変化は水面での鏡面反射と建物の壁面との 2 回散乱成分の変化が貢献していると考えられるため、平行偏波である VV 偏波に顕著に現れることと一致する。また、水田域の浸水域については、収穫直前の水田域を対象にしていたため、後方散乱係数変化が交差偏波に顕著に現れたと考えられる。

VV 偏波のみ、VH 偏波のみの場合における各パターンの Kappa 係数を比較すると、単偏波のみの場合は両偏波使用した場合よりも総じて分類精度が低下した。また、単偏波のみの場合の(B)all と(C)を比較すると、VV 偏波では分類精度に違いがほぼ見られない結果となり、特に VH 偏波では(B)all の分類精度の方が高くなった。

Table 4-5 Summary of inundation detection results for single polarization dataset .

Pattern			(A)	(B)mean	(B)all	(C)	VV only			VH only				
							(B)mean	(B)all	(C)	(B)mean	(B)all	(C)		
Training	Kappa Coefficient		0.763	0.994	1.000	1.000	0.975	1.000	1.000	0.880	1.000	1.000		
	F1	flooded	paddy	0.881	0.999	1.000	1.000	0.974	1.000	1.000	0.984	1.000	1.000	
			built-up	0.794	0.993	1.000	1.000	0.988	1.000	1.000	0.828	1.000	1.000	
	non-flooded	paddy	paddy	0.820	0.999	1.000	1.000	0.972	1.000	1.000	0.947	1.000	1.000	
			built-up	0.791	0.992	1.000	1.000	0.990	1.000	1.000	0.877	1.000	1.000	
Test	Window Size		-	19×19	19×19	19×19	19×19	19×19	19×19	19×19	19×19	19×19		
	Gray-Level		-	4	8	16	8	16	8	4	16	16		
	Kappa Coefficient		0.615	0.805	0.838	0.859	0.773	0.791	0.792	0.659	0.730	0.719		
	F1	flooded	paddy	0.747	0.906	0.907	0.924	0.787	0.799	0.799	0.880	0.896	0.909	
			built-up	0.508	0.632	0.656	0.736	0.747	0.742	0.717	0.398	0.497	0.532	
		non-flooded	paddy	paddy	0.755	0.932	0.935	0.949	0.838	0.873	0.891	0.875	0.878	0.897
				built-up	0.754	0.848	0.895	0.896	0.901	0.899	0.895	0.707	0.808	0.740

VH 偏波において(C)の分類精度が向上しない理由について考察する。Fig. 4-12 に異なるグレーレベルの画像を例として、提案手法を用いる場合の入力特徴ベクトルの違いについて示す。Fig. 4-12(a)および Fig. 4-12(b) に同一パターンでグレーレベルが1レベル異なる画像の入力特徴ベクトル例を示す。同じような濃淡変化にも関わらず入力ベクトルの要素が異なる位置に配置されており、グレーレベルの変化が微小であっても、生成される入力特徴ベクトルの向きは大きく異なることを意味している。したがって、提案手法は入力画像のグレーレベル変化に感度が高く、トレーニングデータで未学習のグレーレベル変化がテストエリアに現れた場合に識別できない可能性がある。

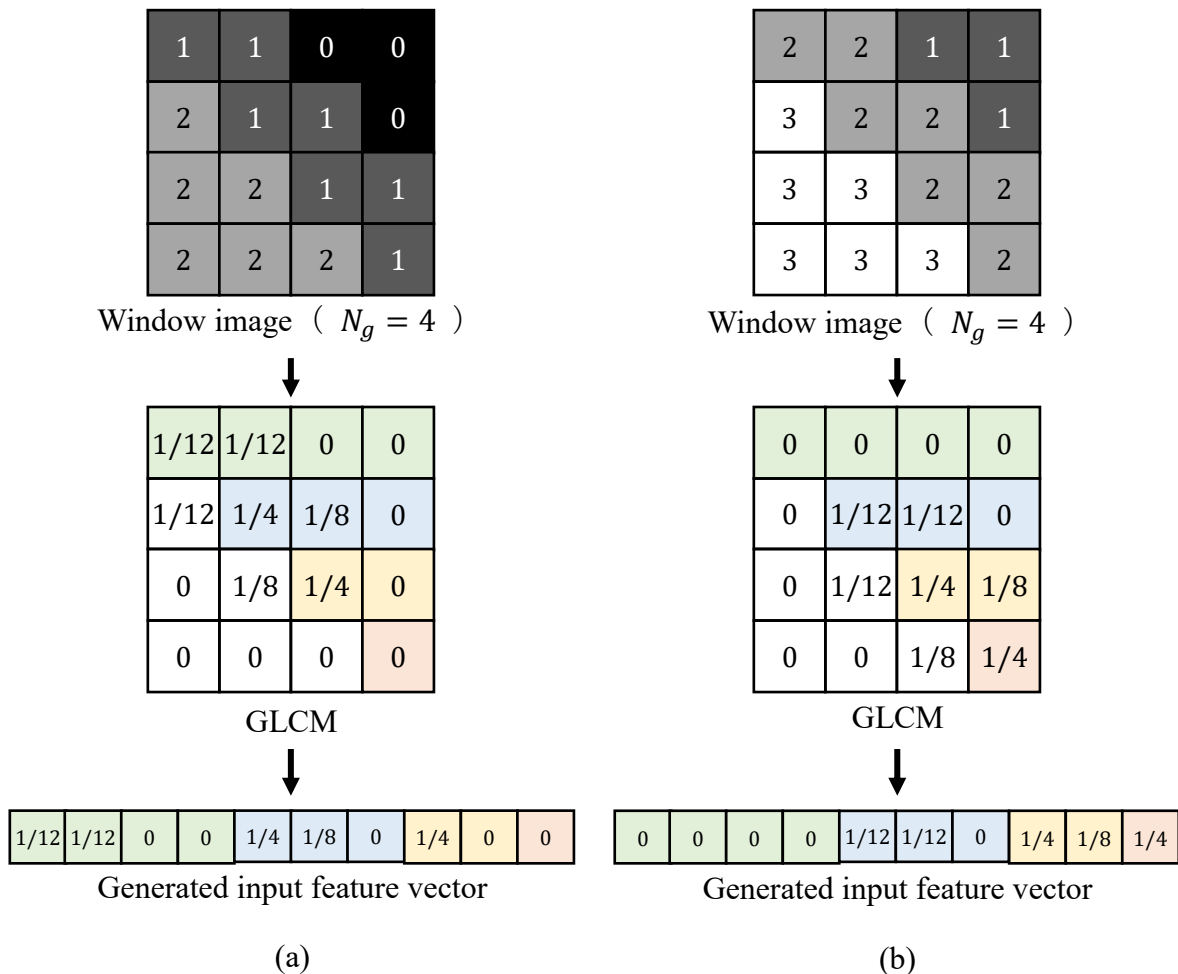


Fig. 4-12 Input feature vectors of the example images with similar gray level change.

(a)an image example and (b)its brighter image.

分類精度向上があまり見られなかった(C)の非浸水市街地についてグレーレベル値の分布を見る。Fig. 4-13 に VH 偏波のみの(C)について、非浸水市街地のトレーニングエリアおよび誤分類が多かったテストエリアの画像を示す。Fig. 4-13 の左側は実際のカテゴリ結果、右側は入力画像であり、画像赤成分に 10 月 7 日、緑成分に 10 月 13 日の VH 偏波のグレーレベル値を割り当てたものである。グレーレベル数は Table 4-5 に示したのと同じ 16 である。Fig. 4-13 に示した入力画像のグレーレベル値の分布を Fig. 4-14 に示す。Fig. 4-14 では正しく非浸水域を分類できたデータを Fig. 4-14(a) , 誤分類を起こしたデータを Fig. 4-14(b)に分け、それぞれを Fig. 4-13 に示すトレーニングエリアの分布と比較している。Fig. 4-14 をみると、正しく分類できたデータはトレーニングデータの分布と類似した分布となっているが、正しく分類できなかったデータはトレーニングデータの分布との違いが比較的大きく、グレーレベル値がトレーニングデータに比べ全体的に小さくなっている。


VV 偏波のみの(C)について、非浸水市街地のトレーニングエリアおよび誤分類が多かったテストエリアの画像とその分布を Fig. 4-15 および Fig. 4-16 に示す。VV 偏波の場合は最も精度向上が見られたグレーレベル数が 8 であり、VH 偏波のみの場合と比べて誤分類が少なかった。Fig. 4-16 から、正しく分類できたテストデータはトレーニングデータの分布と同じ分布であった。誤分類したテストデータは、トレーニングデータと少し異なるものの、概ねトレーニングデータの分布と同じ分布になっていることがわかる。したがって、VH 偏波のみの浸水域抽出において分類精度向上が見られなかった理由は、トレーニングデータとテストデータのグレーレベル値に小さな差があったことで、トレーニングデータから求めた識別境界がテストエリアにうまく適用できなかった可能性が考えられる。これは提案手法特有の特徴であり、既存手法である(B)all では発生しないため、VH 偏波のみの(B)all では分類精度が低下しないと考えられる。

VH 偏波のみの(B)mean が (C)同様に分類精度の向上があまり見られなかった理由についても、同様にトレーニングエリアとテストエリアでグレーレベル値の小さな差が原因であると考えられる。GLCM 特徴量 Mean は、画素値の出現頻度確率の期待値と解釈できるため、グレーレベル値に小さな差があった場合、トレーニングデータとテストデータで GLCM 特徴量 Mean の値が変化する。そのため提案手法の場合と同様に、トレーニングデータから求めた識別境界がテストデータへ適用できなかったと考えられる。



(C)および(B)mean の分類精度低下についてはどちらもトレーニングエリアとテストエリアのグレーレベル値の分布が異なることによるものである。しかし、誤分類の発生過程は両者で異なる可能性があることに留意する必要がある。(C)の場合は、トレーニングエリアとテストエリアのグレーレベル値の変化により、入力特徴ベクトルの各要素がトレーニングデータとテストデータで入れ替わることによるものであり、例えば、マルチスペクトル画像において RGB 画像で学習したモデルで、BRG 画像を分類することができないことに相当する。また、(B)mean の場合はトレーニングエリア

とテストエリアのグレースケール値の変化により、トレーニングデータとテストデータで適切な識別境界が異なるためであり、明るい画像で求めたしきい値を暗い画像に適用すると誤分類が発生することに似ている。以上の問題はトレーニングエリアにおけるサンプルがテストエリアを正しく説明できないデータであることに起因するものであり、この問題を解決するためには、トレーニングエリアとテストエリアとの間で、データの分布に偏りが発生しないよう、GLCM 算出時のグレースケール値を補正する必要があると考えられる。

■ flooded paddy ■ flooded built-up ■ non-flooded paddy □ non-flooded built-up




(a)




(b)

Fig. 4-13 Example of non-flooded built-up area detected by (C)VH ($N_g = 16$) .

(a)training area and (b)test area.



(a)



(b)

**Fig. 4-14 VH gray level distribution in training area and test area.
(a)correctly detected area and (b)mis-detected area.**

■ flooded paddy ■ flooded built-up ■ non-flooded paddy □ non-flooded built-up

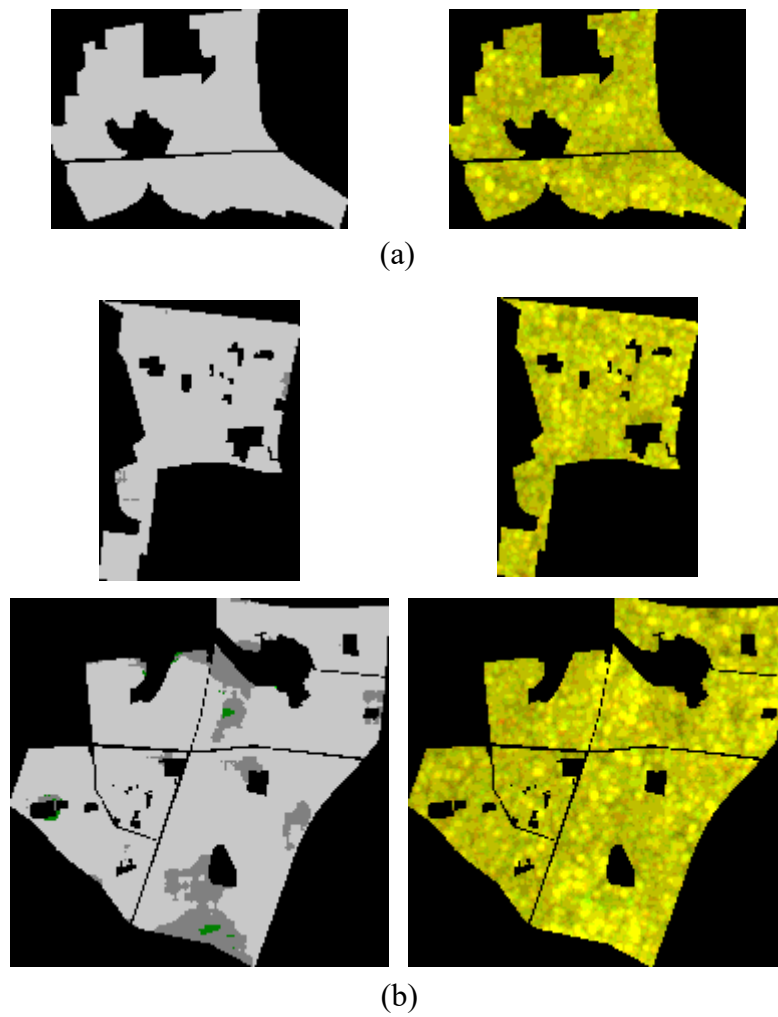




Fig. 4-15 Example of non-flooded built-up area detected by (C)VV ($N_g = 8$) .
(a)training area and (b)test area.



(a)



(b)

**Fig. 4-16 VV gray level distribution in training area and test area.
 (a)correctly detected area (b)mis-detected area.**

4.6 第4章まとめ

本章では、2019年台風19号により浸水被害を受けた福島県郡山市の市街地および水田域について、2時期の Sentinel-1 SAR データの浸水被害発生前後の後方散乱係数 (γ^0) 画像およびテクスチャ情報の変化を用いた浸水域抽出を行った。その結果、VV および VH 両偏波の後方散乱係数変化のみの入力にテクスチャ情報の変化を入力することで、Kappa 係数 0.20 程度の浸水域抽出精度向上があり、テクスチャ情報の有効性が確認できた。また、提案手法と既存手法で浸水域抽出精度を比較し、VV および VH 偏波の両方を使用した場合、提案手法は既存手法よりも有意に分類精度が向上できることを示した。さらに、最も精度向上が見られた GLCM 特徴量が Mean であることを示し、その理由について、スペックルノイズの確率分布と関連性について考察した。

VV または VH 偏波の単偏波のみを浸水域抽出に使用した場合の浸水域抽出精度を比較することで、各偏波が浸水域抽出にどのように寄与するかを考察した。その結果、VV 偏波は市街地域、VH 偏波は水田域における浸水域抽出精度向上に貢献することが示唆された。また、VH 偏波のみを使用した提案手法による浸水域抽出において既存手法よりも提案手法の分類精度が向上しなかった理由について、トレーニングエリアとテストエリアで入力画像のグレーレベル値の小さな差があった場合、提案手法では生成される入力特徴ベクトルが大きく異なることが原因であると考察した。さらに、VH 偏波のみの場合に(B)mean の分類精度が向上しにくかった理由についても、同様にトレーニングエリアとテストエリア間のグレーレベル値の差による可能性があることを考察した。提案手法を汎用的に使用するためには、適切なトレーニングエリアを設定し、トレーニングエリアとテストエリアのデータ分布の偏りを解消する必要があることを述べた。

以下に本章の主要な成果をまとめる。

- (1) テクスチャ情報は、SAR 後方散乱係数データを使用した浸水域抽出においても有効である。
- (2) GLCM 特徴量については、VV および VH 両偏波を使用した場合、Mean が最も有効である。
- (3) VV 偏波は市街地域、VH 偏波は水田域の浸水域抽出精度向上に寄与する。
- (4) 提案手法は両偏波を用いた場合に有意に分類精度向上に効果的である。ただし、トレーニングエリアとテストエリア間のグレーレベル値分布に差がある場合、浸水域抽出精度向上が難しく、グレーレベル値の差を解消する工夫が必要である。

第5章 結論

本章では、第3章および第4章から得られた研究結果をもとに、土地被覆分類における提案手法の有効性、テクスチャ情報の有効性、および課題を記述する。また、最適な GLCM ウィンドウサイズおよびグレーレベル数について記述する。最後に、本研究のまとめおよび今後の課題について記述する。

5.1 GLCM 特徴量の定量的評価およびテクスチャ情報の有効性

第3章および第4章ともにテクスチャ情報を使用した場合に土地被覆分類精度が向上した。第3章の Table 3-4 から、テクスチャ情報を使用した場合に、Kappa 係数が 0.836 から約 0.95 へと 0.1 ポイント程向上した。第4章の Table 4-3 から、テクスチャ情報を使用した場合に、Kappa 係数が 0.615 から 0.8 程へと 0.2 ポイント程度向上した。以上から、テクスチャ情報と SVM を組み合わせた土地被覆分類において、マルチスペクトル画像および SAR の後方散乱係数 (γ^0) 画像ともに、テクスチャ情報が土地被覆分類精度向上に有効であることを示した。

また、GLCM 特徴量を用いた土地被覆分類においては、高分解能マルチスペクトル画像には Entropy, 時系列 γ^0 画像には Mean が、それぞれ有効であることがわかった。以上より、土地被覆分類精度向上に有効な GLCM 特徴量については、土地被覆分類を行うデータにより異なることが確認できたため、入力データにより有効な GLCM 特徴量を事前に検討することが必要である。

5.2 提案手法の有効性と課題

提案手法では有効な GLCM 特徴量を事前検討する必要がない点において大きなメリットがあった。第3章では、高分解能マルチスペクトル画像を対象に既存手法と提案手法による土地被覆分類精度の比較を行った結果、分類精度は提案手法のほうが高かったが、Kappa 有意差検定からは、両者に有意な差がなく、分類精度の観点から有効性を示せなかった。第4章では、2時期の SAR γ^0 画像を対象に浸水域抽出の形で土地被覆分類を行い既存手法と提案手法で分類精度の比較を行った結果、VV および VH 両偏波を用いた場合で提案手法に有意な精度向上を確認できた。このことから、分類精度向上が難しい SAR データにおいて、提案手法は GLCM 特徴量を使用する既存手法よりも、分類精度向上に有効であるといえる。また 3.5 節で述べたように、第3章では既存手法、提案手法ともに分類精度が高かったことで分類精度に有意な差が現れなかった可能性を考慮すると、マルチスペクトル画像においても既存手法で分類精度向上が難しい場合には提案手法が有効な可能性がある。

加えて、第4章では提案手法の課題点を明らかにした。Table 4-5 で示したように、一部の単偏波 SAR の γ^0 画像を用いた場合、既存手法と比較して精度向上が見られなかった。第4章では、提案手法特有の課題として、提案手法が入力画像のグレーレベル値に感度が高く、トレーニングデータとテストデータ間のグレーレベル値に差があ

る場合、小さな差であっても入力特徴ベクトルの向きが大きく異なってしまい、分類精度向上が難しくなる例を示した。解決策として、グレーレベル値の分布を揃える必要があり、そのためにはグレーレベル値の補正アルゴリズムの開発が必要であると結論づけた。

第3章で使用したマルチスペクトル画像では、多バンド画像から主成分分析を行い、第1主成分から生成した画像を用いてテクスチャ情報を算出した。SARの時系列後方散乱データを用いた浸水域抽出では、使用した γ^0 画像上のスペックルノイズにも各偏波の特徴があるため、PCA解析を行わずに、2時期および2偏波の合計4種類の γ^0 画像を使用してGLCMを計算した。しかし、GLCM要素を直接入力データとして加える手法は、式(3-12)が示すようにグレーレベル数の2乗に比例し、グレーレベル数の増加によって入力特徴ベクトルの次元数が膨大となる。第4章の解析では、入力特徴ベクトルの次元数は最大で548次元となり、Grid Searchにかかる時間が膨大になった。以上、提案手法は入力特徴ベクトルの次元数が膨大になることにより、学習に時間がかかることが問題であり課題となった。

以上の課題から、提案手法は適切なトレーニングデータが用意できる場合には汎用的に精度向上が期待されるが、4.5.2節に示したように、トレーニングデータとテストデータ間のグレーレベル値に差ができる場合には、既存手法の分類精度のほうが向上する可能性がある。例として、高分解能マルチスペクトル画像においては、雲や建物の影のようにグレーレベル値が局所的に変化する領域では、テストエリアで誤分類が発生しやすくなる可能性がある。現実的にはあらゆるグレーレベル値の変化を想定してトレーニングエリアを設定することは困難であるため、有効なGLCM特徴量の検討が必要ないメリットを除けば、既存手法が優位となる可能性がある。また、既存手法において十分な分類精度が得られている場合には、提案手法を適用しても大きな精度向上を見込めないことを第3章で示している。

5.3 最適な GLCM ウィンドウサイズおよびグレーレベル数

第3章では GLCM ウィンドウサイズが大きくなるほど精度向上が見られる結果となり、ウィンドウサイズは大きい方が精度向上に貢献できることを示していた。しかし 3.4.1 節で述べたように、Feng らの研究や、Fig. 3-11 および Fig. 3-13 が示した、ウィンドウサイズ 11×11 以上において精度向上度合いが鈍化した結果から、際限なく大きくできるわけではないことが示唆され、最適な GLCM ウィンドウサイズは分類する観測対象物の物理的な大きさより変化すると考えられる。ウィンドウサイズを大きくしていくと、分類する対象地物以外の地物がテクスチャウィンドウ内に混入する割合が増大することで分類精度がいずれ向上しなくなると考えられる。

第3章では、グレーレベル数が最大 16 の場合に最も土地被覆分類精度の向上が見られた。しかし、第4章においては、最も浸水域抽出精度の向上が見られたグレーレベル数は必ずしも最大の 16 とはならなかった。このことから、時系列 SAR の後方散乱係数を使用した浸水域抽出においては、GLCM グレーレベル数について最適値があると考えられる。第3章では 5 バンドの第1主成分画像から GLCM を計算したが、第4章では 2 時期および 2 偏波の合計 4 種類の γ^0 画像からそれぞれ GLCM を計算したことを考慮すると、テクスチャ情報を算出する画像が複数ある場合には、小さいグレーレベル数で精度向上する要因があると考えられる。特に、第4章で使用した VV および VH 偏波の γ^0 画像では、Fig. 4-4 に示すように VV 偏波は市街地を中心に後方散乱係数が高い画素値が分布し、VH 偏波は全体的に比較的低い画素値が分布していることがわかる。以上の画素値分布の違いが、精度向上が見られるグレーレベル数と関連する可能性があり、後方散乱係数画像の適切なスケーリング等を行なうことにより、詳細に解析を行う必要性がある。

5.4 まとめおよび今後の課題

本研究では、UAV 取得の高分解能マルチスペクトル画像および時系列 SAR の後方散乱係数 (γ^0) 画像を使用して、テクスチャ情報と SVM を組み合わせて、土地被覆分類を行い分類精度の向上を図った。以下にその主要な成果を記述する。

- (1) 土地被覆分類の精度向上にテクスチャ情報が有効であった。高分解能マルチスペクトル画像の土地被覆分類精度と比較すると、時系列 SAR 後方散乱係数を使用した場合の方が、浸水域抽出精度向上が困難であった。
- (2) 高分解能マルチスペクトル画像と時系列 SAR 後方散乱係数では、有効な GLCM 特徴量は異なっており、マルチスペクトル画像では Entropy, 時系列 SAR 後方散乱係数では Mean が最も有効であった。
- (3) 本研究の提案手法は、既存研究の GLCM 特徴量を使用した場合以上の分類精度を確認できた。提案手法は、有効な GLCM 特徴量を事前に検討する必要のない、汎用的な分類手法である。しかし、前提としてトレーニングデータがテストデータを適切に説明できていることが必要である。

提案手法を用いる場合は適切なトレーニングデータセットの作成が重要であり、トレーニングデータとテストデータ間にグレーレベル値の小さな差がある場合には、分類精度が向上しない場合があることがわかった。このグレーレベル値の差について補正アルゴリズムを考えることでより精度向上が見込まれる。

今後の課題を以下に記述する。

- (1) 適切なトレーニングデータセットの作成手法について検討を行う。
- (2) 入力特徴ベクトルの次元数増加に伴う計算時間の増大を軽減する。

(1) については、解決するアプローチとして、データオーグメンテーションによるトレーニングデータの増強の他、トレーニングエリア設定の工夫やトレーニングデータのグレーレベル値の補正アルゴリズムを開発する必要がある。(2) については計算の最適化やランダムフォレストや決定木等の他機械学習アルゴリズムを利用することで、対処できる可能性がある。

謝辞

本研究は日本大学大学院情報工学専攻の研究として行われました。研究および論文執筆にあたりまして、主査として日本大学情報工学科の若林教授，副査として大山教授および岩井教授には多くのご指導ご鞭撻を頂きました。また，副査（外部審査委員）として茨城大学の外岡教授にご助言いただきました。ここに感謝の意を表します。

第3章について，使用した UAV 取得データは，株式会社ふたばおよび日本大学工学部の共同研究によって取得されました。また，これらの一部は JST/JICA SATREPS（JST Grant No.:JPMJSA1604）および JSPS 科研費（JP17H01983）の助成を受けました。第4章について，使用した Sentinel データは ESA から提供されました。また，本研究の一部は千葉大学環境リモートセンシング研究センター共同利用研究の支援を受け実施しました。ここに感謝の意を示します。

また本研究で使用したプログラムには LIBSVM の他，オープンソースのソースコードをいくつか参考にさせていただきました⁶⁶⁾⁶⁷⁾。ここに感謝の意を示します。

論文リスト

A. 基本論文

論文題目	公表の方法および時期	著者	関連する章
テクスチャ情報を用いた UAV 取得高分解能画像の土地被覆分類精度向上	日本リモートセンシング学会誌, Vol. 42, No. 2, 2022, pp. 101-118	<u>五十嵐 貴大</u> 若林裕之	第 3 章

B. 学会誌およびこれに準ずるもの

論文題目	公表の方法および時期	著者	関連する章
Sentinel-1 データを用いた 2019 年台風 19 号の浸水被害域抽出精度評価	日本リモートセンシング学会誌, Vol.43, No.4, 2023, pp.223-233	<u>五十嵐 貴大</u> 若林裕之	第 4 章
Flooded rice paddy detection using Sentinel-1 and PlanetScope data: a case study of the 2018 spring flood in West Java, Indonesia	IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, Vol. 14, 2021, pp.6291-6301	Hiroyuki Wakabayashi Chiharu hongo <u>Takahiro Igarashi</u> Yoshihiro Asaoka Boedi Tjahjono Intan Rima Permata	第 4 章
Detection of flood area caused by Typhoon Hagibis using learn-based method with Sentinel-1 data	Proceedings of International Geoscience and Remote Sensing Symposium, 2023, pp.7202-7205	<u>Takahiro Igarashi</u> Hiroyuki Wakabayashi	第 4 章
Flood damage analysis in Koriyama city caused by typhoon Hagibis using Sentinel-1 SAR data	Proceedings of International Geoscience and Remote Sensing Symposium, 2022, pp.6021-6024	Hiroyuki Wakabayashi <u>Takahiro Igarashi</u>	第 4 章

C. 日本大学工学部紀要およびこれに準ずるもの

論文題目	公表の方法および時期	著者	関連する章
Backscattering and interferometric characteristics of flood damage in Koriyama City caused by Typhoon Hagibis	Proceedings of the 43rd. Asian Conference on Remote Sensing (ACRS), 2022	<u>Takahiro Igarashi</u> Hiroyuki Wakabayashi	第4章

D. 学会の大会，支部大会などの口頭発表

論文題目	公表の方法および時期	著者	関連する章
テクスチャ情報を用いた UAV 取得高分解能画像の土地被覆分類精度向上	日本リモートセンシング学会 第 70 回学術講演会論文集，2021 年 5 月，pp.75-78	<u>五十嵐 貴大</u> 若林 裕之	第 3 章
テクスチャ情報を用いた UAV 取得高分解能画像の土地被覆分類精度向上（その 2）	第 64 回日本大学工学部学術研究報告会論文要旨集（情報工学部会），情-8-1，2021 年 12 月，pp.126-127	<u>五十嵐 貴大</u> 若林 裕之	第 3 章
Sentinel-1 データを用いた令和元年台風 19 号の浸水被害域抽出精度評価	日本リモートセンシング学会 第 73 回学術講演会論文集，2022 年 11 月，pp.69-70	<u>五十嵐 貴大</u> 若林 裕之	第 4 章
Sentinel-1 データを用いた令和元年台風 19 号の浸水被害域抽出精度評価	第 65 回日本大学工学部学術研究報告会論文要旨集（情報工学部会），情-3-17，2022 年 12 月，pp.204-205	<u>五十嵐 貴大</u> 若林 裕之	第 4 章
Sentinel-1 データを用いた機械学習による 2019 年台風 19 号の浸水被害領域抽出	日本リモートセンシング学会 第 74 回学術講演会論文集，2023 年 6 月，pp.15-16	<u>五十嵐 貴大</u> 若林 裕之	第 4 章
Sentinel-1 SAR データのテクスチャ情報を用いた機械学習手法による浸水域抽出精度向上	第 66 回日本大学工学部学術研究報告会論文要旨集（情報工学部会），情-3-8，2023 年 12 月，pp.146-147	<u>五十嵐 貴大</u> 若林 裕之	第 4 章

参考文献

- 1) Eastman, J.R., "Guide to GIS and Image Processing 14", Clark University Manual, 2003, pp.239-247.
- 2) 佐藤 昶, 村上 智明, 中嶋 康博: 教師付き分類とオブジェクトベースのセグメンテーションを組み合わせた土地利用/土地被覆分類手法の提案 —牧草地における農用地及び更新草地の判別—, 日本リモートセンシング学会誌, Vol.39, No.3, 2019, pp.225-240.
- 3) 高岩 直彰, 羽柴 秀樹: 数種の高分解能衛星データへのオブジェクト指向分類を用いた都市公園内の植生分布評価, 土木学会論文集 F3 (土木情報学), Vol. 71, No. 2, 2015, pp.I18-I26.
- 4) A. E. Maxwell, T. A. Warner, and F. Fang, "Implementation of machine-learning classification in remote sensing: An applied review", *Int. J. Remote Sens.*, Vol.39, No.9, 2018, pp.2784-2817.
- 5) Le Yu, Lu Liang, Jie Wang, Yuanyuan Zhao, Qu Cheng, Luanyun Hu, Shuang Liu, Liang Yu, Xiaoyi Wang, Peng Zhu, Xueyan Li, Yue Xu, Congcong Li, Wei Fu, Xuecao Li, Wenyu Li, Caixia Liu, Na Cong, Han Zhang, Fangdi Sun, Xinfang Bi, Qinchuan Xin, Dandan Li, Donghui Yan, Zhiliang Zhu, Michael F. Goodchild, and Peng Gong, "Meta-discoveries from a synthesis of satellite-based land-cover mapping research", *International Journal of Remote Sensing*, Vol.35, No.13, 2014, pp.4573-4588.
- 6) V. N. Mishra et al., "Evaluating the effects of spatial resolution on land use and land cover classification accuracy", 2015 International Conference on Microwave, Optical and Communication Engineering (ICMOCE), 2015, pp.208-211.
- 7) G. Mountrakis, J. Im, and C. Ogole, "Support vector machines in remote sensing: A review", *ISPRS J. Photogramm. Remote Sens.*, 66(3), pp. 247-259, 2011.
- 8) M. Sheykhmousa, M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi and S. Homayouni, "Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review", *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol.13, pp.6308-6325, 2020.
- 9) U. Maulik and D. Chakraborty, "Remote Sensing Image Classification: A survey of support-vector-machine-based advanced techniques", *IEEE Geoscience and Remote Sensing Magazine*, Vol.5, No. 1, Mar. 2017, pp.33-52.
- 10) Sibaruddin H. I., Shafri H. ,Pradhan B., Haron N., "Comparison of pixel-based and object-based image classification techniques in extracting information from UAV imagery data", *IOP Conference Series: Earth and Environmental Science*, Vol.169, 2018, p.012098.
- 11) P. V. Narasimha Rao, M.V. R. Sesha Sai, K. Sreenivas, M.V. Krishna Rao, B. R. M. Rao, R. S. Dwibedi and L. Venkataratnam: Textural analysis of IRS-1D panchromatic data for land cover classification, *International Journal of Remote Sensing*, 23(17), pp. 3327-3345,

- 2002.
- 12) 小阪 尚子, 秋山 侃, 蔡 斌, 児島 利治: 高分解能衛星画像のテクスチャ特徴量とスペクトル特徴量を用いたオブジェクト指向型林分タイプ分類, 写真測量とリモートセンシング, 46(2), pp.27-36, 2007.
 - 13) A. S. Laliberte and A. Rango: Texture and scale in object-based analysis of subdecimeter resolution unmanned aerial vehicle (UAV) imagery, *IEEE Trans. Geosci. Remote Sens.*, 47(3), pp. 761-770, March, 2009.
 - 14) Q. Feng, J. Liu, and J. Gong: UAV remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sensing*, 7(1), pp. 1074-1094, 2015.
 - 15) R. M. Haralick, K. Shanmugam and I. Dinstein: Textural Features for Image Classification, *IEEE Trans. on Systems, Man and Cybernetics*, 3(6), pp. 610-621, 1973.
 - 16) C. Cortes and V. Vapnik: Support-vector networks, *Machine Learning*, 20(3), pp. 273-297, 1995.
 - 17) M. Pal and P. M. Mather: Support vector machines for classification in remote sensing, *International Journal of Remote Sensing*, Vol.265, No.5, 2005, pp.1007-1011.
 - 18) 五十嵐貴大, 若林裕之: テクスチャ情報を用いた UAV 取得高分解能画像の土地被覆分類精度向上, 日本リモートセンシング学会誌, 42(2), pp. 101-118, 2022. <https://doi.org/10.11440/rssj.2021.055>.
 - 19) 橋本 岳, 松尾 優, GLCM 法による合成開口レーダ画像のテクスチャ解析の一方法, 日本リモートセンシング学会誌, Vol.7, No.4, 1987, pp.335-345.
 - 20) Zakeri H, Yamazaki F, Liu W, "Texture Analysis and Land Cover Classification of Tehran Using Polarimetric Synthetic Aperture Radar Imagery", *Appl. Sci.*, Vol.7, 2017, 452. <https://doi.org/10.3390/app7050452>
 - 21) Leen-Kiat Soh and C. Tsatsoulis, "Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 2, pp. 780-795, March 1999, doi: 10.1109/36.752194.
 - 22) 佐無田夏希, リュウ ウェン, 山崎文雄: 他偏波 SAR 画像によるテクスチャを用いた土地被覆分類の基礎的検討, 日本リモートセンシング学会 第 61 回学術講演論文集, 2016, Dec., pp.91-94.
 - 23) 中田 晃司, 福原 始: 小型衛星コンステレーションビジネスの現状と将来, 日本リモートセンシング学会誌, 2021, Vol.41, No.2, pp.290-293, 2021.
 - 24) 田中圭, 近藤昭彦: 小型マルチコプターを用いた近接リモートセンシングによる水稲生育マップの作成, 日本リモートセンシング学会誌, 36(4), pp.373-387, 2016.
 - 25) 井上公, 内山庄一郎, 鈴木比奈子: 自然災害調査のためのマルチコプター空撮技術, 防災科学研究所研究報告, (81), pp.61-98, 2014.
 - 26) Qin, Rongjun and Liu, Tao: A Review of Landcover Classification with Very-High Resolution Remotely Sensed Optical Images —Analysis Unit, Model Scalability and Transferability., *Remote Sensing.*, Vol.14., 2022, p.646.

- 27) 越智 士郎: 画像オブジェクトに基づく高分解能衛星画像での土地被覆分類手法の検討, 東南アジア研究, Vol.46, No.4, 2009, pp.578-592.
- 28) 児島 利治, 宝 馨, 岡 太郎: リモートセンシング画像の分解能が土地被覆分類精度に及ぼす影響, 京都大学防災研究所年報. B, Vol.39, B-2, Apr. 1996, pp.445-458.
- 29) Fisher, J.R.B., Acosta, E.A., Dennedy-Frank, P.J., Kroeger, T. and Boucher, T.M.: Impact of satellite imagery spatial resolution on land use classification accuracy and modeled water quality, *Remote Sens Ecol Conserv*, Vol.4, 2018, pp.137-149.
- 30) 日本リモートセンシング学会: 基礎からわかるリモートセンシング, 2016, pp.255-269.
- 31) MicaSense: RedEdge-M User Manual, https://support.micasense.com/hc/en-us/article_attachments/115004168274/RedEdge-M_User_Manual.pdf (Accessed on October, 5, 2021)
- 32) C. -C. Chang and C. -J. Lin: LIBSVM : a library for support vector machines, *ACM Trans. on Intelligent Systems and Technology*, 2(3), pp.1-27, 2011.
- 33) F. Albrechtsen: Statistical texture measures computed from gray level cooccurrence matrices, University of Oslo, Department of Informatics, pp.1-14, 2008.
- 34) B. E. Boser, I. M. Guyon, and V. N. Vapnik: A training algorithm for optimal margin classifiers, *Proceedings of the Annual Conference on Computational Learning Theory*, New York, NY, USA, pp. 144-152, July, 1992.
- 35) W. Lv, Q. Yu, and W. Yu: Water extraction in SAR images using GLCM and support vector machine, *Proc. of IEEE 10th International Conference on Signal Processing*, Beijing, China, pp. 740-743, October, 2010.
- 36) K.-R. Muller, S. Mika, G. Ratsch, K. Tsuda, and B. Scholkopf: An introduction to kernel-based learning algorithms, *IEEE Trans. on Neural Networks*, 12(2), pp. 181-201, 2001.
- 37) Intisar Shadeed Al-Mejibli, Jwan K. Alwan, Dhafar Hamed Abd: The effect of gamma value on support vector machine performance with different kernels. *International Journal of Electrical and Computer Engineering (IJECE)*. 10(5). pp. 5497-5506, 2020. <http://doi.org/10.11591/ijece.v10i5.pp5497-5506>.
- 38) A. Brenning: Spatial cross-validation and bootstrap for the assessment of prediction rules in remote sensing: The R package *sperrorest*, 2012 IEEE International Geoscience and Remote Sensing Symposium, Munich, Germany, 2012, pp. 5372-5375, July, 2012.
- 39) R.C. Sharma, K. Hara, H. Hirayama H: A machine learning and cross-validation approach for the discrimination of vegetation physiognomic types using satellite based multispectral and multitemporal data, *Scientifica*, 2017, 8 p., Art. no. 9806479, 2017.
- 40) H. Meyer, C. Reudenbach, S. Wollauer, and T. Nauss: Importance of spatial predictor variable selection in machine learning applications ? Moving from data reproduction to spatial prediction, *Ecological Modelling*, 411, 2019.
- 41) C. A. Ramezan, T. A. Warner, and A. E. Maxwell: Evaluation of sampling and cross-

- validation tuning strategies for regional-scale machine learning classification, *Remote Sensing*, 11(2), Art. no. 185, 2019.
- 42) K. T. Awuah, P. Aplin, C. G. Marston, I. Powell I, I. P.J. Smit: Probabilistic mapping and spatial pattern analysis of grazing lawns in southern African savannahs using WorldView-3 imagery and machine learning techniques. *Remote Sensing*, 12(20), Art. no. 3357, 2020.
 - 43) R.G.Congalton: A review of assessing the accuracy of classification of remotely sensed data. *Remote Sens. Environ.*, 37, pp. 35-46, 1991.
 - 44) 内閣府: 令和元年台風第19号等に係る被害状況等について (令和2年4月10日 9:00 現在) , https://www.bousai.go.jp/updates/r1typhoon19/pdf/r1typhoon19_45.pdf (Accessed on Mar. 20, 2023)
 - 45) 国土地理院 : 令和元年東日本台風に関する情報 , <https://www.gsi.go.jp/BOUSAI/R1.taihuu19gou.html> (Accessed on Mar. 20, 2023)
 - 46) J. B. Henry, P. Chastanet, K. Fellah, and Y. L. Desnos : Envisat multi-polarized ASAR data for flood mapping, *International Journal of Remote Sensing*, 27(10), pp. 1921-1929, 2006. <https://doi.org/10.1080/01431160500486724>.
 - 47) S. Martinis, A. Twele, and S. Voigt: Towards operational near real-time flood detection using a split-based automatic thresholding procedure on high resolution TerraSAR-X data, *Natural Hazards Earth Syst. Sci.*, 9(2), pp. 303-314, 2009. <https://doi.org/10.5194/nhess-9-303-2009>.
 - 48) M. Ohki, M. Watanabe, R. Natsuaki, T. Motohka, H. Nagai, T. Tadono, S. Suzuki, K. Ishii, T. Itoh, T. Yamanoguchi, and M. Shimada: Flood Area Detection Using ALOS-2 PALSAR-2 data for the 2015 Heavy Rainfall Disaster in the Kanto and Tohoku Area, Japan, *Journal of The Remote Sensing Society of Japan*, 36(4), pp. 348-359, 2016. <https://doi.org/10.11440/rssj.39.S43>.
 - 49) J. Reksten, A. Salberg, and R. Salberg: Flood detection in Norway based on Sentinel-1 SAR imagery, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-3/W8, pp. 349-355, 2019. <https://doi.org/10.5194/isprs-archives-XLII-3-W8-349-2019>.
 - 50) G. Franceschetti, A. Iodice, and D. Riccio: A canonical problem in electromagnetic backscattering from buildings, *IEEE Trans. Geosci. Remote Sens.*, 40(8), pp. 1787-1801, 2002. <https://doi.org/10.1109/TGRS.2002.802459>.
 - 51) A. Refice, D. Capolongo, G. Pasquariello, A. D'Addabbo, F. Bovenga, N. Nutricato , F. Lovergine, and L. Pietranera: SAR and InSAR for flood monitoring : Examples with COSMO-SkyMed data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(7), pp. 2711-2722, 2014. <https://doi.org/10.1109/JSTARS.2014.2305165>.
 - 52) M. Chini, L. Pulvirenti, R. Pelich, N. Pierdicca, R. Hostache and P. Matgen: Monitoring Urban Floods Using SAR Interferometric Observations, *IGARSS 2018 - 2018 IEEE*

- International Geoscience and Remote Sensing Symposium, Valencia, Spain, pp. 8785-8788, Jul. 2018.
- 53) L. Pulvirenti, M. Chini, N. Pierdicca and G. Boni: Use of SAR Data for Detecting Floodwater in Urban and Agricultural Areas: The Role of the Interferometric Coherence, in IEEE Transactions on Geoscience and Remote Sensing, 54(3), pp. 1532-1544, 2016. <https://doi.org/10.1109/TGRS.2015.2482001>.
 - 54) H. Wakabayashi, T. Igarashi and S. Tsukamoto: Flood Damage Analysis in Koriyama City Caused by Typhoon Hagibis Using Sentinel-1 SAR Data, IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, pp. 6021-6024, Jul. 2022.
 - 55) H. Sohn, Y. Song, and G. Kim: Detecting water area during flood event from SAR image, Lecture Notes in Computer Science, 3481, pp.771-780, 2005. https://doi.org/10.1007/11424826_82.
 - 56) A. Dasgupta, S. Grimaldi, R. Ramsankaran and J. P. Walker: Optimized glcm-based texture features for improved SAR-based flood mapping, 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Fort Worth, TX, USA, pp. 3258-3261, Jul. 2017.
 - 57) D. Small: Flattening Gamma: Radiometric terrain correction for SAR imagery, IEEE Trans. on Geoscience and Remote Sensing, 49(8), pp. 3081-3093, 2011. <https://doi.org/10.1109/TGRS.2011.2120616>.
 - 58) ESA: ESA Sentinel toolboxes, <https://sentinel.esa.int/web/sentinel/toolboxes> (Accessed on Mar. 20, 2023)
 - 59) ESA: IW GRD Resolutions, <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-1-sar/products-algorithms/level-1-algorithms/ground-range-detected/iw/> (Accessed on Mar. 20, 2023).
 - 60) 59) ESA: Sentinel-1 Product Definition, <https://sentinels.copernicus.eu/documents/247904/1877131/Sentinel-1-Product-Definition> (Accessed on Mar. 20, 2023).
 - 61) Ulaby, F. T., R.K. Moore and A. K. Fung: Microwave Remote Sensing: Active and Passive, Volume III : From Theory to Applications, Artech House, Norwood, Massachusetts, 1986.
 - 62) 若林 裕之, 新井 康平: SAR スペックルノイズ低減化に関する一手法, 写真測量とリモートセンシング, Vol. 34, No. 2, 1995, pp.15-24.
 - 63) ESA: Sentinel-1 Product Specification, <https://sentinel.esa.int/documents/247904/1877131/Sentinel-1-Product-Specification> (Accessed on Jan. 8, 2024).
 - 64) M. Ariei : Sensitivity study of ALOS-2 data to floodwaters in Joso City in 2015 and its application, Journal of The Remote Sensing Society of Japan, 38(4), pp. 325-336, 2018. <https://doi.org/10.11440/rssj.38.325>.
 - 65) H. Wakabayashi, C. Hongo, T. Igarashi, Y. Asaoka, B. Tjahjono and I. R. Permata: Flooded

rice paddy detection using Sentinel-1 and PlanetScope data: a case study of the 2018 spring flood in West Java, Indonesia, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, pp. 6291-6301, 2021. <https://doi.org/10.1109/JSTARS.2021.3083610>.

- 66) A. Athanasopoulos, A. Dimou, V. Mezaris, I. Kompatsiaris, "GPU Acceleration for Support Vector Machines", *Proc. 12th International Workshop on Image Analysis for Multimedia Interactive Services (WIAMIS 2011)*, Delft, The Netherlands, April 2011.
- 67) Implementation of a constant-time dynamic storage allocator. Miguel Masmano, Ismael Ripoll, et al. *Software: Practice and Experience*. Volume 38 Issue 10, Pages 995 - 1026. 2008.

付録

A. SVM 学習結果一覧

ここでは SVM の学習結果を示す。学習結果は第 4 章のみを一覧として掲載する。第 3 章で実施した SVM の学習結果については、第 4 章より量が膨大であること、交差検証に使用した乱数シードの記録がなく再現性に欠けること、学習時間の計測条件が一定でないこと等の理由により掲載を断念した。Table A-1 に第 4 章の学習結果一覧を示す。ここで、表の各列は次のような意味である。

- pattern : パターン
- N_w : ウィンドウサイズ
- N_g : グレーレベル数
- L0 ~ L3 : 式(3-24)で算出された各カテゴリの重み係数
 - L0 : flooded paddy
 - L1 : flooded built-up
 - L2 : non-flooded paddy
 - L3 : non-flooded built-up
- seed : 交差検証に使用したシード値
- gamma : Grid Search によるハイパーパラメータ γ の探索結果
- cost : Grid Search によるハイパーパラメータ C の探索結果
- accuracy : 決定されたハイパーパラメータにより算出された交差検証の精度 (Kappa)
- elapsed time : 学習時間 (時分秒)

学習時間の計測は、Grid Search によるハイパーパラメータ決定から、学習モデル生成までを含む時間とした。計測環境は次のとおりである。

- CPU : Intel(R) Core(TM) i9-10980XE CPU @ 3.00GHz
- GPU : Nvidia GeForce RTX3090
- RAM : 256GB
- OS : Windows11 Pro (64bit)

また、Grid Search のハイパーパラメータ探索は 36 スレッドで並列計算させることで探索にかかる時間の短縮を図っているほか、GPU を用いた SVM カーネルの事前計算を行うことで学習にかかる時間を短縮している。

本研究では学習全体にかかる時間について検証は行っていないが、経験的には学習精度が高い場合ほどかかる時間は少なくなるようである。

Table A-1 Chapter 4 training results list.

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(A)	-	-	1.00262	1	1.09214	1.10331	792802531	4	128	0.7575	1h40m05.070s
(B)contrast	3	2	1.00557	1	1.09532	1.10638	137558098	4	8	0.7716	2h43m26.010s
(B)contrast	3	4	1.00601	1	1.09628	1.10668	580378234	1	2048	0.7831	2h26m19.750s
(B)contrast	3	8	1.00688	1	1.09735	1.10749	3546152440	4	512	0.7773	2h36m18.250s
(B)contrast	3	16	1.00688	1	1.09735	1.10736	3454366103	4	128	0.7883	2h25m13.200s
(B)contrast	7	2	1.00699	1	1.09735	1.10736	2807040433	4	32	0.8422	2h20m31.130s
(B)contrast	7	4	1.00688	1	1.09735	1.10736	4253929561	1	8192	0.8676	2h04m49.110s
(B)contrast	7	8	1.00688	1	1.09735	1.10736	2490808722	4	512	0.8397	2h05m56.510s
(B)contrast	7	16	1.00688	1	1.09735	1.10736	3533560887	1	2048	0.8464	2h05m17.410s
(B)contrast	11	2	1.00688	1	1.09735	1.10736	1895623877	16	8	0.8965	1h52m38.500s
(B)contrast	11	4	1.00688	1	1.09735	1.10736	2725598550	4	128	0.9362	1h42m22.160s
(B)contrast	11	8	1.00688	1	1.09735	1.10736	2496328792	1	8192	0.8881	1h55m26.850s
(B)contrast	11	16	1.00688	1	1.09735	1.10736	3058762568	1	8192	0.8964	1h52m23.840s
(B)contrast	15	2	1.00688	1	1.09735	1.10736	567131798	4	512	0.9254	1h41m30.560s
(B)contrast	15	4	1.00688	1	1.09735	1.10736	1733460975	4	128	0.9668	1h33m01.470s
(B)contrast	15	8	1.00688	1	1.09735	1.10736	2602961646	1	8192	0.9242	1h43m18.010s
(B)contrast	15	16	1.00688	1	1.09735	1.10736	522494324	1	8192	0.9296	1h43m02.530s
(B)contrast	19	2	1.00688	1	1.09735	1.10736	2177375001	4	512	0.9492	1h32m58.990s
(B)contrast	19	4	1.00688	1	1.09735	1.10736	1830803170	4	128	0.9821	1h27m03.460s
(B)contrast	19	8	1.00688	1	1.09735	1.10736	1133975718	1	8192	0.9477	1h39m33.380s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)contrast	19	16	1.00688	1	1.09735	1.10736	2796580984	4	512	0.9449	1h36m52.140s
(B)correlation	3	2	1.00568	1	1.09544	1.10664	2211565085	4	8	0.7623	2h39m38.710s
(B)correlation	3	4	1.00622	1	1.09651	1.10692	2393361812	4	32	0.7618	2h48m26.400s
(B)correlation	3	8	1.00677	1	1.09723	1.10724	2421704904	4	32	0.7602	3h03m55.900s
(B)correlation	3	16	1.00688	1	1.09735	1.10736	4061294608	4	32	0.7603	3h03m01.800s
(B)correlation	7	2	1.00699	1	1.09735	1.10736	4259176833	4	512	0.7848	2h37m36.860s
(B)correlation	7	4	1.00688	1	1.09735	1.10736	2841436476	4	2048	0.7815	2h41m43.280s
(B)correlation	7	8	1.00688	1	1.09735	1.10736	221729191	4	2048	0.7807	2h55m38.300s
(B)correlation	7	16	1.00688	1	1.09735	1.10736	3259195981	4	512	0.7831	2h43m03.930s
(B)correlation	11	2	1.00688	1	1.09735	1.10736	2942864277	4	2048	0.8149	2h29m09.830s
(B)correlation	11	4	1.00688	1	1.09735	1.10736	1888401445	4	2048	0.822	2h38m34.760s
(B)correlation	11	8	1.00688	1	1.09735	1.10736	1278027859	4	512	0.8129	2h29m25.060s
(B)correlation	11	16	1.00688	1	1.09735	1.10736	750824738	4	128	0.8156	2h35m16.860s
(B)correlation	15	2	1.00688	1	1.09735	1.10736	1776907646	4	512	0.8598	2h10m46.430s
(B)correlation	15	4	1.00688	1	1.09735	1.10736	3433597091	1	32768	0.8634	2h33m05.130s
(B)correlation	15	8	1.00688	1	1.09735	1.10736	492119012	4	128	0.8588	2h14m58.900s
(B)correlation	15	16	1.00688	1	1.09735	1.10736	2466845424	16	2	0.8574	2h18m48.130s
(B)correlation	19	2	1.00688	1	1.09735	1.10736	2521702676	4	512	0.8836	2h00m41.360s
(B)correlation	19	4	1.00688	1	1.09735	1.10736	2732691286	1	32768	0.8928	2h17m13.990s
(B)correlation	19	8	1.00688	1	1.09735	1.10736	504837476	16	2	0.8925	2h00m17.350s
(B)correlation	19	16	1.00688	1	1.09735	1.10736	284314511	16	2	0.8888	2h04m44.630s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)dissimilarity	3	2	1.00568	1	1.09544	1.10664	2715793828	1	2048	0.7668	1h28m55.500s
(B)dissimilarity	3	4	1.00568	1	1.0958	1.1066	4137470139	1	32	0.7826	1h42m18.090s
(B)dissimilarity	3	8	1.00644	1	1.09687	1.10701	3726657911	1	8192	0.7702	1h39m45.970s
(B)dissimilarity	3	16	1.00688	1	1.09735	1.10749	3861153752	0.25	8192	0.7694	1h28m36.360s
(B)dissimilarity	7	2	1.00699	1	1.09735	1.10736	227880957	4	32	0.8351	1h16m33.380s
(B)dissimilarity	7	4	1.00688	1	1.09735	1.10736	41217748	16	2	0.8864	1h17m08.090s
(B)dissimilarity	7	8	1.00688	1	1.09735	1.10736	1168827009	16	2	0.8451	1h42m22.450s
(B)dissimilarity	7	16	1.00688	1	1.09735	1.10736	1700876090	4	128	0.8328	1h53m23.250s
(B)dissimilarity	11	2	1.00688	1	1.09735	1.10736	2695198906	4	128	0.8923	1h36m58.970s
(B)dissimilarity	11	4	1.00688	1	1.09735	1.10736	2000958130	16	2	0.9425	1h29m53.190s
(B)dissimilarity	11	8	1.00688	1	1.09735	1.10736	856249466	16	2	0.8813	1h46m48.360s
(B)dissimilarity	11	16	1.00688	1	1.09735	1.10736	357570157	16	8	0.8852	1h45m10.950s
(B)dissimilarity	15	2	1.00688	1	1.09735	1.10736	2021288277	16	8	0.9187	1h35m03.720s
(B)dissimilarity	15	4	1.00688	1	1.09735	1.10736	640708040	16	8	0.9704	1h28m18.470s
(B)dissimilarity	15	8	1.00688	1	1.09735	1.10736	2499436319	16	8	0.9196	1h42m13.900s
(B)dissimilarity	15	16	1.00688	1	1.09735	1.10736	1172402664	4	128	0.9149	1h40m57.000s
(B)dissimilarity	19	2	1.00688	1	1.09735	1.10736	1537155359	16	8	0.9415	1h32m24.760s
(B)dissimilarity	19	4	1.00688	1	1.09735	1.10736	2839974694	16	8	0.9856	1h24m44.190s
(B)dissimilarity	19	8	1.00688	1	1.09735	1.10736	1839021532	4	128	0.9379	1h36m17.160s
(B)dissimilarity	19	16	1.00688	1	1.09735	1.10736	4270373030	4	128	0.9315	1h36m56.340s
(B)energy	3	2	1.00568	1	1.09544	1.1065	1095138431	1	2048	0.7677	1h26m41.830s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)energy	3	4	1.00622	1	1.09651	1.10692	11827678	0.25	2048	0.7892	1h48m10.300s
(B)energy	3	8	1.00688	1	1.09735	1.10749	2708532742	1	8	0.7769	1h32m34.070s
(B)energy	3	16	1.00688	1	1.09735	1.10736	1772971072	0.25	2048	0.7769	1h48m04.730s
(B)energy	7	2	1.00699	1	1.09735	1.10736	2039466927	1	2048	0.8394	1h15m30.040s
(B)energy	7	4	1.00688	1	1.09735	1.10736	3736788370	4	8	0.8986	1h14m42.220s
(B)energy	7	8	1.00688	1	1.09735	1.10736	2738520072	16	2	0.8702	1h45m30.560s
(B)energy	7	16	1.00688	1	1.09735	1.10736	2778106058	16	8	0.8507	1h48m18.880s
(B)energy	11	2	1.00688	1	1.09735	1.10736	3693584091	4	128	0.8985	1h34m18.750s
(B)energy	11	4	1.00688	1	1.09735	1.10736	2947306131	16	2	0.9632	1h29m59.960s
(B)energy	11	8	1.00688	1	1.09735	1.10736	2358935788	16	8	0.9217	1h42m17.430s
(B)energy	11	16	1.00688	1	1.09735	1.10736	3154512178	4	512	0.9051	2h32m28.170s
(B)energy	15	2	1.00688	1	1.09735	1.10736	3297865635	4	512	0.9308	1h31m58.240s
(B)energy	15	4	1.00688	1	1.09735	1.10736	608654943	16	2	0.9862	1h26m59.820s
(B)energy	15	8	1.00688	1	1.09735	1.10736	870591837	16	8	0.9544	1h37m02.720s
(B)energy	15	16	1.00688	1	1.09735	1.10736	2371968342	4	128	0.9445	1h36m46.740s
(B)energy	19	2	1.00688	1	1.09735	1.10736	2447414491	1	8192	0.9501	1h33m21.070s
(B)energy	19	4	1.00688	1	1.09735	1.10736	4253001391	16	8	0.9942	1h24m12.280s
(B)energy	19	8	1.00688	1	1.09735	1.10736	1530342315	16	8	0.9696	1h30m24.810s
(B)energy	19	16	1.00688	1	1.09735	1.10736	613197835	16	8	0.9607	1h31m09.090s
(B)entropy	3	2	1.00568	1	1.09544	1.1065	48785892	0.25	8192	0.7677	2h18m57.590s
(B)entropy	3	4	1.00622	1	1.09651	1.10692	2281108456	0.25	8192	0.7903	2h35m05.520s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)entropy	3	8	1.00688	1	1.09735	1.10749	3372910315	4	2	0.7835	2h31m17.700s
(B)entropy	3	16	1.00688	1	1.09735	1.10736	3509678124	4	8	0.7839	2h26m18.750s
(B)entropy	7	2	1.00699	1	1.09735	1.10736	4020654648	1	2048	0.8393	2h05m11.340s
(B)entropy	7	4	1.00688	1	1.09735	1.10736	3795549135	16	2	0.903	1h50m05.410s
(B)entropy	7	8	1.00688	1	1.09735	1.10736	820057631	16	2	0.8743	1h57m32.330s
(B)entropy	7	16	1.00688	1	1.09735	1.10736	274161430	16	2	0.8712	1h55m49.180s
(B)entropy	11	2	1.00688	1	1.09735	1.10736	47098107	4	128	0.8997	1h43m21.070s
(B)entropy	11	4	1.00688	1	1.09735	1.10736	2726494691	16	2	0.9557	1h37m15.990s
(B)entropy	11	8	1.00688	1	1.09735	1.10736	3141225602	16	8	0.9285	1h43m02.430s
(B)entropy	11	16	1.00688	1	1.09735	1.10736	2171803070	16	8	0.9249	0h32m59.280s
(B)entropy	15	2	1.00688	1	1.09735	1.10736	1111429935	1	8192	0.9317	0h35m13.350s
(B)entropy	15	4	1.00688	1	1.09735	1.10736	2608018707	16	2	0.9805	0h31m43.340s
(B)entropy	15	8	1.00688	1	1.09735	1.10736	1528328160	16	8	0.9575	0h42m27.310s
(B)entropy	15	16	1.00688	1	1.09735	1.10736	1138799275	16	8	0.9562	0h52m03.490s
(B)entropy	19	2	1.00688	1	1.09735	1.10736	3564806997	1	8192	0.9505	1h02m20.780s
(B)entropy	19	4	1.00688	1	1.09735	1.10736	855933924	16	8	0.9896	1h05m53.750s
(B)entropy	19	8	1.00688	1	1.09735	1.10736	756473667	16	8	0.9736	1h11m57.210s
(B)entropy	19	16	1.00688	1	1.09735	1.10736	585378301	16	8	0.9701	1h14m53.850s
(B)homogeneity	3	2	1.00557	1	1.09532	1.10638	2888829327	0.25	8192	0.7649	2h49m17.400s
(B)homogeneity	3	4	1.00579	1	1.09604	1.10657	983365513	0.25	8192	0.7814	3h08m53.000s
(B)homogeneity	3	8	1.00677	1	1.09723	1.10724	1064847568	1	8	0.7691	3h18m15.300s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)homogeneity	3	16	1.00688	1	1.09735	1.10736	3390517294	0.25	512	0.7721	3h16m17.300s
(B)homogeneity	7	2	1.00699	1	1.09735	1.10736	1104521237	4	32	0.8378	2h20m40.920s
(B)homogeneity	7	4	1.00688	1	1.09735	1.10736	3140654057	16	2	0.8819	2h10m51.460s
(B)homogeneity	7	8	1.00688	1	1.09735	1.10736	168428619	16	2	0.8501	2h27m31.360s
(B)homogeneity	7	16	1.00688	1	1.09735	1.10736	3713117365	16	2	0.8564	2h24m22.200s
(B)homogeneity	11	2	1.00688	1	1.09735	1.10736	1284120788	16	8	0.8914	1h54m14.020s
(B)homogeneity	11	4	1.00688	1	1.09735	1.10736	3784478182	16	2	0.9427	1h47m43.620s
(B)homogeneity	11	8	1.00688	1	1.09735	1.10736	3512205537	16	2	0.897	2h02m23.810s
(B)homogeneity	11	16	1.00688	1	1.09735	1.10736	146070023	16	2	0.9021	2h00m43.760s
(B)homogeneity	15	2	1.00688	1	1.09735	1.10736	2085672239	4	128	0.9215	1h40m58.220s
(B)homogeneity	15	4	1.00688	1	1.09735	1.10736	3753097286	16	8	0.9726	1h34m44.930s
(B)homogeneity	15	8	1.00688	1	1.09735	1.10736	531057524	16	8	0.9245	1h47m47.940s
(B)homogeneity	15	16	1.00688	1	1.09735	1.10736	1332093938	16	2	0.9315	1h45m43.590s
(B)homogeneity	19	2	1.00688	1	1.09735	1.10736	3063098062	4	128	0.9475	1h33m46.260s
(B)homogeneity	19	4	1.00688	1	1.09735	1.10736	651602386	16	2	0.9859	1h28m14.490s
(B)homogeneity	19	8	1.00688	1	1.09735	1.10736	1833607080	16	8	0.9479	1h38m47.960s
(B)homogeneity	19	16	1.00688	1	1.09735	1.10736	1038997438	16	8	0.9503	1h37m09.590s
(B)mean	3	2	1.00568	1	1.09544	1.10664	377058068	0.25	8192	0.7678	1h24m51.870s
(B)mean	3	4	1.00612	1	1.09639	1.10693	4236619071	1	2048	0.7926	1h32m35.920s
(B)mean	3	8	1.00677	1	1.09723	1.10724	1190452652	16	2	0.8074	1h14m08.050s
(B)mean	3	16	1.00688	1	1.09735	1.10736	1899541185	4	32	0.8173	1h15m16.790s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)mean	7	2	1.00699	1	1.09735	1.10736	837281844	4	32	0.8491	1h06m16.060s
(B)mean	7	4	1.00688	1	1.09735	1.10736	2978681833	16	2	0.9198	1h01m29.100s
(B)mean	7	8	1.00688	1	1.09735	1.10736	3636490778	16	8	0.9276	1h08m48.040s
(B)mean	7	16	1.00688	1	1.09735	1.10736	71941252	4	128	0.9306	1h18m49.640s
(B)mean	11	2	1.00688	1	1.09735	1.10736	1265930534	4	128	0.9155	1h29m47.670s
(B)mean	11	4	1.00688	1	1.09735	1.10736	398573553	16	2	0.9677	1h14m30.910s
(B)mean	11	8	1.00688	1	1.09735	1.10736	3569206310	16	8	0.9728	1h12m08.950s
(B)mean	11	16	1.00688	1	1.09735	1.10736	3023211668	16	8	0.9756	1h14m56.250s
(B)mean	15	2	1.00688	1	1.09735	1.10736	1831386212	4	128	0.9518	1h25m58.390s
(B)mean	15	4	1.00688	1	1.09735	1.10736	509056695	16	8	0.9854	1h13m38.750s
(B)mean	15	8	1.00688	1	1.09735	1.10736	1292594241	16	8	0.9886	1h11m58.840s
(B)mean	15	16	1.00688	1	1.09735	1.10736	309887228	16	8	0.9884	1h13m22.310s
(B)mean	19	2	1.00688	1	1.09735	1.10736	328568047	4	128	0.9772	1h19m44.270s
(B)mean	19	4	1.00688	1	1.09735	1.10736	3467219694	4	32	0.9924	1h11m28.320s
(B)mean	19	8	1.00688	1	1.09735	1.10736	4260031187	4	32	0.9949	1h10m53.730s
(B)mean	19	16	1.00688	1	1.09735	1.10736	146471743	16	8	0.9956	1h11m37.720s
(B)mean VV only	3	2	1.02363	1.7861	1	1.8726	3963659519	1	8192	0.6572	1h17m04.480s
(B)mean VV only	3	4	1	1.27443	1.01062	1.45749	838623255	4	512	0.6962	1h55m58.150s
(B)mean VV only	3	8	1	1.20045	1.09844	1.10594	1553421659	64	0.5	0.7552	1h14m17.360s
(B)mean VV only	3	16	1	1.12549	1.09139	1.10257	676355347	16	8	0.774	1h07m28.600s
(B)mean VV only	7	2	1	1.61087	1.08675	1.57857	3592994633	4	128	0.7765	0h52m50.720s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)mean VV only	7	4	1	1.06112	1.08916	1.13215	1459750123	16	8	0.8494	0h48m07.010s
(B)mean VV only	7	8	1	1.01722	1.09012	1.09981	2574846375	16	8	0.8839	0h40m58.520s
(B)mean VV only	7	16	1	1.00076	1.08998	1.0998	66337655	16	128	0.8881	0h36m51.370s
(B)mean VV only	11	2	1	1.41837	1.08973	1.3074	2658637830	16	8	0.8537	0h48m27.440s
(B)mean VV only	11	4	1	1.01093	1.08998	1.10297	2718051087	64	2	0.92	0h34m04.250s
(B)mean VV only	11	8	1.00426	1	1.09462	1.10448	29873033	1	8192	0.9384	0h28m57.570s
(B)mean VV only	11	16	1.00655	1	1.09699	1.107	4225187085	16	32	0.9402	0h27m58.370s
(B)mean VV only	15	2	1	1.30071	1.08973	1.18522	4153508909	16	32	0.8928	0h37m30.310s
(B)mean VV only	15	4	1.00295	1	1.09306	1.10383	1241231162	16	32	0.9484	0h30m06.960s
(B)mean VV only	15	8	1.00655	1	1.09699	1.107	3098769073	16	32	0.9633	0h24m37.160s
(B)mean VV only	15	16	1.00688	1	1.09735	1.10736	3357661354	16	32	0.9644	0h25m55.430s
(B)mean VV only	19	2	1	1.20834	1.08985	1.1344	887050371	16	8	0.9206	0h38m38.640s
(B)mean VV only	19	4	1.00601	1	1.09639	1.10707	49661379	64	8	0.966	0h27m29.320s
(B)mean VV only	19	8	1.00666	1	1.09711	1.10712	2676625201	0.000977	32768	0.9744	0h26m59.650s
(B)mean VV only	19	16	1.00688	1	1.09735	1.10736	4258365425	0.000977	32768	0.9738	0h27m09.640s
(B)mean VH only	3	2	1.98669	1	1.92033	1.06296	355834505	4	2048	0.4577	1h46m39.640s
(B)mean VH only	3	4	1.29926	1	1.60615	1.06813	2154551242	64	0.5	0.5418	2h13m50.350s
(B)mean VH only	3	8	1.04084	1	1.10276	1.10957	2337391865	4	2048	0.5822	2h04m07.300s
(B)mean VH only	3	16	1.01308	1	1.09883	1.10821	1264474026	1	2048	0.6023	1h54m20.300s
(B)mean VH only	7	2	1.71503	1	1.74035	1.10449	115649667	4	128	0.5875	0h57m52.640s
(B)mean VH only	7	4	1.04424	1	1.19917	1.10609	1296234305	64	0.5	0.6932	1h07m38.670s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)mean VH only	7	8	1.00688	1	1.09735	1.10749	826086954	16	8	0.7115	1h15m25.730s
(B)mean VH only	7	16	1.00688	1	1.09748	1.10736	1228774899	1	8192	0.7137	1h17m58.700s
(B)mean VH only	11	2	1.37176	1	1.42674	1.10736	680890103	1	128	0.7036	0h52m56.380s
(B)mean VH only	11	4	1.00975	1	1.10617	1.10736	285429974	16	8	0.7862	2h26m03.840s
(B)mean VH only	11	8	1.00688	1	1.09735	1.10736	3423001248	64	2	0.7966	0h50m16.950s
(B)mean VH only	11	16	1.00688	1	1.09735	1.10736	2227194213	4	32768	0.7959	1h19m02.110s
(B)mean VH only	15	2	1.18024	1	1.24326	1.10724	1725820637	4	512	0.7639	0h44m21.360s
(B)mean VH only	15	4	1.00743	1	1.09865	1.10749	2613771896	16	128	0.8318	0h42m39.600s
(B)mean VH only	15	8	1.00688	1	1.09735	1.10736	842682577	4	2048	0.8536	0h44m11.370s
(B)mean VH only	15	16	1.00688	1	1.09735	1.10736	2402365754	16	32	0.85	0h38m13.420s
(B)mean VH only	19	2	1.09617	1	1.159	1.10736	474536547	16	512	0.8107	0h37m18.860s
(B)mean VH only	19	4	1.00721	1	1.09787	1.10736	1704455101	16	128	0.8607	0h34m54.960s
(B)mean VH only	19	8	1.00688	1	1.09735	1.10749	606706134	16	32	0.883	0h32m03.240s
(B)mean VH only	19	16	1.00688	1	1.09735	1.10736	3318412931	4	8192	0.885	0h36m22.260s
(B)variance	3	2	1.00568	1	1.09544	1.10664	3630980495	0.25	8192	0.7623	2h36m43.730s
(B)variance	3	4	1.00612	1	1.09639	1.10693	2093321587	16	2	0.7873	2h30m58.450s
(B)variance	3	8	1.00677	1	1.09723	1.10724	2190774765	1	2048	0.773	2h39m09.680s
(B)variance	3	16	1.00688	1	1.09735	1.10736	2412586245	1	8192	0.7798	2h34m31.120s
(B)variance	7	2	1.00699	1	1.09735	1.10736	2920672287	1	2048	0.8343	2h20m17.220s
(B)variance	7	4	1.00688	1	1.09735	1.10736	100405403	16	2	0.8928	1h54m53.730s
(B)variance	7	8	1.00688	1	1.09735	1.10736	1724498953	16	8	0.856	2h02m14.690s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)variance	7	16	1.00688	1	1.09735	1.10736	3118208302	4	128	0.8568	2h02m12.610s
(B)variance	11	2	1.00688	1	1.09735	1.10736	1047745461	1	8192	0.8928	1h54m24.850s
(B)variance	11	4	1.00688	1	1.09735	1.10736	3632859366	16	2	0.9491	1h38m48.610s
(B)variance	11	8	1.00688	1	1.09735	1.10736	3829940467	16	8	0.9135	1h46m48.550s
(B)variance	11	16	1.00688	1	1.09735	1.10736	88018034	16	8	0.912	1h46m26.260s
(B)variance	15	2	1.00688	1	1.09735	1.10736	1899722763	1	8192	0.9287	1h42m16.520s
(B)variance	15	4	1.00688	1	1.09735	1.10736	1529634486	16	8	0.9751	1h31m48.630s
(B)variance	15	8	1.00688	1	1.09735	1.10736	1489108056	16	8	0.9458	1h35m35.010s
(B)variance	15	16	1.00688	1	1.09735	1.10736	2114211266	4	128	0.9483	1h36m21.670s
(B)variance	19	2	1.00688	1	1.09735	1.10736	2280924173	1	8192	0.9483	1h35m31.370s
(B)variance	19	4	1.00688	1	1.09735	1.10736	376180142	16	8	0.986	1h26m39.700s
(B)variance	19	8	1.00688	1	1.09735	1.10736	770858444	4	128	0.9665	1h28m54.900s
(B)variance	19	16	1.00688	1	1.09735	1.10736	2494353304	4	512	0.9698	1h28m47.550s
(B)all	3	2	1.00568	1	1.09544	1.1065	219792470	0.0625	2048	0.7693	1h04m28.230s
(B)all	3	4	1.00622	1	1.09651	1.10692	662462042	0.0625	512	0.8022	0h58m07.180s
(B)all	3	8	1.00688	1	1.09735	1.10736	284407795	0.25	32	0.8331	0h43m53.570s
(B)all	3	16	1.00688	1	1.09735	1.10736	2748314735	1	8	0.8588	0h38m08.930s
(B)all	7	2	1.00699	1	1.09735	1.10736	3065161515	4	8	0.8851	0h35m49.660s
(B)all	7	4	1.00688	1	1.09735	1.10736	1134440496	1	32	0.9671	0h30m46.040s
(B)all	7	8	1.00688	1	1.09735	1.10736	743632040	4	32	0.9932	0h29m54.270s
(B)all	7	16	1.00688	1	1.09735	1.10736	47907363	4	32	0.9956	0h28m03.800s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)all	11	2	1.00688	1	1.09735	1.10736	3647568747	4	32	0.9603	0h29m28.320s
(B)all	11	4	1.00688	1	1.09735	1.10736	3100141697	1	128	0.9967	0h32m53.420s
(B)all	11	8	1.00688	1	1.09735	1.10736	1553641898	1	512	0.9995	0h31m43.820s
(B)all	11	16	1.00688	1	1.09735	1.10736	986999550	1	128	0.9993	0h32m52.020s
(B)all	15	2	1.00688	1	1.09735	1.10736	627565440	4	32	0.9889	0h34m31.240s
(B)all	15	4	1.00688	1	1.09735	1.10736	3483426358	1	128	0.9997	0h34m55.260s
(B)all	15	8	1.00688	1	1.09735	1.10736	191228240	0.25	512	0.9999	0h36m54.730s
(B)all	15	16	1.00688	1	1.09735	1.10736	2681712316	0.25	512	0.9998	0h37m46.380s
(B)all	19	2	1.00688	1	1.09735	1.10736	2006092193	4	32	0.9977	0h35m38.360s
(B)all	19	4	1.00688	1	1.09735	1.10736	1633797609	1	32	0.9998	0h38m14.500s
(B)all	19	8	1.00688	1	1.09735	1.10736	2258327916	0.25	128	0.9999	0h39m19.840s
(B)all	19	16	1.00688	1	1.09735	1.10736	3107828199	0.0625	32768	1	0h38m00.540s
(B)all VV only	3	2	1.01327	1.78388	1	1.86673	912418935	0.0625	2048	0.6655	0h44m18.000s
(B)all VV only	3	4	1	1.18198	1.02031	1.45559	3455593819	0.25	2048	0.7145	1h16m22.190s
(B)all VV only	3	8	1	1.09603	1.09433	1.10544	3165332023	0.0625	8192	0.783	0h46m59.100s
(B)all VV only	3	16	1	1.03492	1.08985	1.10125	3784535509	0.25	2048	0.8139	0h39m50.900s
(B)all VV only	7	2	1	1.60147	1.08747	1.56876	1534759918	4	2	0.8148	0h36m24.850s
(B)all VV only	7	4	1	1.00022	1.08937	1.12859	666960204	4	8	0.9034	0h33m28.260s
(B)all VV only	7	8	1.00677	1	1.09723	1.10724	1982655063	4	32	0.9587	0h24m48.530s
(B)all VV only	7	16	1.00688	1	1.09735	1.10736	4213661152	16	8	0.9702	0h25m22.430s
(B)all VV only	11	2	1	1.40899	1.08973	1.29979	3797725941	16	2	0.8988	0h36m37.110s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)all VV only	11	4	1.00688	1	1.09735	1.10976	3718054109	16	8	0.9746	0h30m48.640s
(B)all VV only	11	8	1.00688	1	1.09735	1.10736	3642485992	4	128	0.996	0h18m37.960s
(B)all VV only	11	16	1.00688	1	1.09735	1.10736	3658280202	16	128	0.9971	0h33m54.100s
(B)all VV only	15	2	1	1.29008	1.08973	1.18155	2008937796	4	32	0.9395	0h29m06.770s
(B)all VV only	15	4	1.00688	1	1.09735	1.10803	3164612990	16	32	0.9941	0h20m24.340s
(B)all VV only	15	8	1.00688	1	1.09735	1.10736	3282373042	4	128	0.9993	0h22m08.650s
(B)all VV only	15	16	1.00688	1	1.09735	1.10736	734378337	4	512	0.9994	0h22m16.630s
(B)all VV only	19	2	1	1.19838	1.08985	1.13286	937436105	16	8	0.9601	0h29m53.300s
(B)all VV only	19	4	1.00688	1	1.09735	1.10736	3130255554	16	32	0.9989	0h24m50.860s
(B)all VV only	19	8	1.00688	1	1.09735	1.10736	285906366	1	512	0.9998	0h27m30.310s
(B)all VV only	19	16	1.00688	1	1.09735	1.10736	3933550832	4	32	0.9999	0h28m45.440s
(B)all VH only	3	2	1.98812	1	1.92318	1.06129	615871615	0.0625	2048	0.4785	1h47m21.960s
(B)all VH only	3	4	1.31115	1	1.59485	1.06653	2005040345	0.0625	2048	0.5556	1h50m24.720s
(B)all VH only	3	8	1.02151	1	1.09746	1.10709	1151602126	0.25	512	0.6206	1h40m44.990s
(B)all VH only	3	16	1.00732	1	1.09735	1.10736	3720848949	1	128	0.6554	1h16m53.840s
(B)all VH only	7	2	1.70068	1	1.71559	1.10472	1180240499	16	2	0.6323	0h59m47.220s
(B)all VH only	7	4	1.03879	1	1.18221	1.1064	3034908457	1	2048	0.7913	1h12m38.540s
(B)all VH only	7	8	1.00688	1	1.09735	1.10736	664449470	4	128	0.8574	0h50m12.290s
(B)all VH only	7	16	1.00688	1	1.09735	1.10736	1551574802	16	8	0.8876	0h44m44.680s
(B)all VH only	11	2	1.36023	1	1.40908	1.10736	3232268931	16	32	0.7591	0h47m30.530s
(B)all VH only	11	4	1.00897	1	1.10088	1.10736	4195886847	4	128	0.9216	0h42m34.400s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(B)all VH only	11	8	1.00688	1	1.09735	1.10736	1839561937	16	32	0.9671	0h41m06.710s
(B)all VH only	11	16	1.00688	1	1.09735	1.10736	2984905254	16	8	0.9753	0h47m50.700s
(B)all VH only	15	2	1.17139	1	1.23229	1.10724	1334813994	16	128	0.8463	0h51m44.060s
(B)all VH only	15	4	1.00688	1	1.09813	1.10736	1994463956	1	8192	0.9742	0h50m46.430s
(B)all VH only	15	8	1.00688	1	1.09735	1.10736	3596684224	4	512	0.9908	0h53m43.180s
(B)all VH only	15	16	1.00688	1	1.09735	1.10736	3791788048	4	512	0.9924	0h57m20.630s
(B)all VH only	19	2	1.09073	1	1.15479	1.10736	3650579485	16	128	0.8897	0h59m55.260s
(B)all VH only	19	4	1.00699	1	1.09787	1.10736	189894102	1	8192	0.9913	1h00m40.900s
(B)all VH only	19	8	1.00688	1	1.09735	1.10736	1490662506	1	8192	0.9969	1h03m13.400s
(B)all VH only	19	16	1.00688	1	1.09735	1.10736	2331307855	1	8192	0.997	1h06m23.390s
(C)	3	2	1.00568	1	1.09544	1.1065	2561520725	0.25	512	0.7738	1h41m29.540s
(C)	3	4	1.00622	1	1.09651	1.10692	2539158157	0.015625	32768	0.8027	1h53m03.760s
(C)	3	8	1.00688	1	1.09735	1.10736	1576893321	0.0625	512	0.8432	0h50m14.920s
(C)	3	16	1.00688	1	1.09735	1.10736	3510086878	0.25	8	0.9072	1h14m11.910s
(C)	7	2	1.00699	1	1.09735	1.10736	3340002556	4	8	0.8885	1h04m08.490s
(C)	7	4	1.00688	1	1.09735	1.10736	3621008909	4	8	0.9697	1h06m30.960s
(C)	7	8	1.00688	1	1.09735	1.10736	2949443351	1	32	0.9976	1h27m31.210s
(C)	7	16	1.00688	1	1.09735	1.10736	929807817	0.25	8	0.9992	1h41m23.910s
(C)	11	2	1.00688	1	1.09735	1.10736	3881097218	4	32	0.9555	1h21m51.050s
(C)	11	4	1.00688	1	1.09735	1.10736	2416140604	4	32	0.9979	1h22m33.410s
(C)	11	8	1.00688	1	1.09735	1.10736	2105436482	0.25	32	0.9996	1h32m46.530s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(C)	11	16	1.00688	1	1.09735	1.10736	2577789282	0.0625	32	0.9999	1h46m54.960s
(C)	15	2	1.00688	1	1.09735	1.10736	1596162330	4	32	0.9832	1h17m48.910s
(C)	15	4	1.00688	1	1.09735	1.10736	2037348711	1	8	0.9998	1h20m56.850s
(C)	15	8	1.00688	1	1.09735	1.10736	1522863961	0.015625	512	1	1h33m46.520s
(C)	15	16	1.00688	1	1.09735	1.10736	3325699962	0.015625	8	0.9999	0h36m50.700s
(C)	19	2	1.00688	1	1.09735	1.10736	4058601067	4	32	0.9951	0h22m45.540s
(C)	19	4	1.00688	1	1.09735	1.10736	641639138	1	8	1	0h29m22.840s
(C)	19	8	1.00688	1	1.09735	1.10736	1703334577	0.25	8	1	0h39m13.200s
(C)	19	16	1.00688	1	1.09735	1.10736	2486049195	0.003906	32	1	0h31m15.610s
(C) VV only	3	2	1.01327	1.78388	1	1.86673	2809644244	0.0625	32768	0.6666	1h29m29.270s
(C) VV only	3	4	1	1.18198	1.02031	1.45559	1252124012	0.25	2048	0.7155	1h51m06.680s
(C) VV only	3	8	1	1.09669	1.09433	1.10558	2067644336	0.0625	2048	0.7817	1h19m53.970s
(C) VV only	3	16	1	1.03586	1.08985	1.10125	1837445607	0.25	32	0.8201	1h22m15.760s
(C) VV only	7	2	1	1.60147	1.08747	1.56876	339357274	0.25	8192	0.8118	1h04m28.930s
(C) VV only	7	4	1	1.00022	1.08937	1.12859	3229340781	4	32	0.897	1h04m02.880s
(C) VV only	7	8	1.00666	1	1.09711	1.10712	1539172125	4	8	0.9777	1h01m13.090s
(C) VV only	7	16	1.00688	1	1.09735	1.10736	2066122230	1	32	0.9982	1h08m09.950s
(C) VV only	11	2	1	1.40899	1.08973	1.29979	753752844	4	32	0.895	1h01m42.020s
(C) VV only	11	4	1.00688	1	1.09735	1.10976	2617433577	16	8	0.9735	0h54m27.970s
(C) VV only	11	8	1.00688	1	1.09735	1.10736	2497647526	4	32	0.9993	1h01m38.490s
(C) VV only	11	16	1.00688	1	1.09735	1.10736	2091504204	1	2	0.9999	1h13m26.570s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(C) VV only	15	2	1	1.29008	1.08973	1.18155	2630891814	16	32	0.9352	0h56m39.930s
(C) VV only	15	4	1.00688	1	1.09735	1.10803	1704244095	16	32	0.9949	0h57m51.660s
(C) VV only	15	8	1.00688	1	1.09735	1.10736	3659687792	1	32	0.9999	1h02m52.800s
(C) VV only	15	16	1.00688	1	1.09735	1.10736	3116893278	0.25	2	1	1h13m36.200s
(C) VV only	19	2	1	1.19838	1.08985	1.13286	915451110	4	2048	0.9567	1h02m40.980s
(C) VV only	19	4	1.00688	1	1.09735	1.10736	477920710	16	32	0.999	1h02m16.040s
(C) VV only	19	8	1.00688	1	1.09735	1.10736	1755324599	1	2	1	1h05m17.140s
(C) VV only	19	16	1.00688	1	1.09735	1.10736	1099721155	0.25	0.5	1	1h14m26.770s
(C) VH only	3	2	1.98812	1	1.92318	1.06129	3510311382	0.0625	32768	0.4837	2h07m02.860s
(C) VH only	3	4	1.31135	1	1.59485	1.06666	2000661788	0.0625	8192	0.5551	2h13m43.220s
(C) VH only	3	8	1.02152	1	1.09734	1.10697	2351639879	0.0625	2048	0.6207	2h06m06.500s
(C) VH only	3	16	1.00732	1	1.09735	1.10736	1697380467	0.25	32	0.6728	1h56m48.070s
(C) VH only	7	2	1.70068	1	1.71559	1.10472	1494609996	1	8192	0.6269	1h39m48.790s
(C) VH only	7	4	1.03879	1	1.18221	1.1064	3134172653	4	8	0.7878	1h29m19.510s
(C) VH only	7	8	1.00688	1	1.09735	1.10736	4271497823	4	8	0.9358	1h11m24.130s
(C) VH only	7	16	1.00688	1	1.09735	1.10736	1016149111	1	32	0.9944	1h25m04.550s
(C) VH only	11	2	1.36023	1	1.40908	1.10736	2691113800	4	2048	0.752	1h18m14.890s
(C) VH only	11	4	1.00897	1	1.10088	1.10736	3234917088	4	32	0.9285	1h04m32.670s
(C) VH only	11	8	1.00688	1	1.09735	1.10736	3144916127	4	32	0.9945	1h11m38.000s
(C) VH only	11	16	1.00688	1	1.09735	1.10736	1436797735	0.25	32	0.9992	1h17m31.030s
(C) VH only	15	2	1.17139	1	1.23229	1.10724	747588117	16	128	0.8317	1h10m15.400s

pattern	N_w	N_g	L0	L1	L2	L3	seed	gamma	cost	accuracy	elapsed time
(C) VH only	15	4	1.00688	1	1.09813	1.10736	133324599	4	32	0.9816	1h06m08.700s
(C) VH only	15	8	1.00688	1	1.09735	1.10736	1610581345	1	32	0.9991	1h15m09.500s
(C) VH only	15	16	1.00688	1	1.09735	1.10736	609840636	0.0625	128	0.9998	1h25m00.550s
(C) VH only	19	2	1.09073	1	1.15479	1.10736	351425016	16	128	0.8748	1h08m17.960s
(C) VH only	19	4	1.00699	1	1.09787	1.10736	1072874102	4	128	0.9951	1h12m27.670s
(C) VH only	19	8	1.00688	1	1.09735	1.10736	3687495638	0.25	512	0.9999	1h17m49.880s
(C) VH only	19	16	1.00688	1	1.09735	1.10736	4024535940	0.003906	128	1	1h27m37.210s