

空間情報を用いた
ハイパースペクトル画像に対する
クラスタリング手法

Clustering method using spatial information
for hyper-spectral image

北海道大学

工学部 情報工学科

複雑系工学講座 混沌系工学研究室

中野 智晴

平成 19 年度卒業論文

目次

第1章	序論	3
1.1	リモートセンシング	3
1.2	ハイパースペクトルセンサ	4
第2章	クラスタリング手法	6
2.1	従来のクラスタリング手法	6
2.1.1	k-means 法	6
2.1.2	最尤法	6
2.2	提案手法	7
2.2.1	アルゴリズム概要	7
2.2.2	region 生成の前処理	10
2.2.3	erosion 及び dilation 処理	10
2.2.4	計算量の推定	11
第3章	実験結果・考察	15
3.1	実験環境	15
3.2	分類精度の評価	16
3.3	計算時間の評価	25
第4章	結論	33
	謝辞	35
	参考文献	36

第一章 緒言

1.1 リモートセンシング

1900 年以降有人動力飛行機の登場から航空技術が目覚しく発展してきた。その中でもリモートセンシングという技術が特に発達した。「リモートセンシングとは、航空機，人工衛星，宇宙船，などの飛行体(プラットフォーム)を上空に打ち上げ，飛行体に積み込んだ望遠カメラやセンサを人間の眼の代用にして，地球や諸星の表面・海洋・大気などから放射・反射してくるエネルギーの強さを電磁波長別にデータ化して，画像などに加工して，これを分析・分類・解析する技術の総称をいう。」[1]がリモートセンシングの定義である。リモートセンシングは大きく分けて航空機にセンサを搭載する航空機リモートセンシングと衛星にセンサを搭載する衛星リモートセンシングの二つになる[2]。衛星リモートセンシング技術は 1960 年代から気象観測衛星として実用化され，現在もさまざまな衛星が打ち上げられている[3]。これらのリモートセンシングの利用法には，大気観測，水質の観測，土地被覆・土地利用・植生分布の調査，災害発生時の被災地の観測・災害の予測，GPS，地雷の検知などがあり，リモートセンシングが日常生活に深くかかわってきていることがわかる。衛星リモートセンシングで利用される人工衛星は米国の LANDSAT，仏国の SPOT 等多数存在する。日本でも MOS(もも)，JERS(ふよう)，ADEOS(みどり)などの衛星が打ち上げられている[1]。これらの衛星に積まれているセンサはマルチスペクトルセンサといい，一般的に数～数十バンドのスペクトルデータを取得する。ここ最近マルチスペクトルセンサよりも多量の情報を取得することができるハイパースペクトルセンサを搭載する衛星が出現してきた。EO-1 に搭載されている Hyperion や PROBA に搭載されている CHRIS などが衛星リモートセンシングで使われているハイパースペクトルセンサの例として挙げられる。衛星リモートセンシングのハイパースペクトルセンサは S/N 比と波長精度が利用者の要求を満たしていないために衛星リモートセンシングは実験的な利用しかされていない[4]。しかし，航空機リモートセンシングでのハイパースペクトルセンサはすでに実用化されており，CASI センサ[5]や AISA センサ[6]などがある。

1.2 ハイパースペクトルセンサ

ハイパースペクトルセンサはマルチスペクトルセンサの多バンド化を目的として作られたセンサである。ハイパースペクトルセンサの特徴は通常のカメラの持つ二次元画像に加え、分光器の持つ周波数分解能を持っていることである。さらにマルチスペクトルセンサは広帯域の周波数領域中のある一定波長領域を1バンドとして離散的なデータを取得しているが(短いものでバンド幅 $0.06 \mu\text{m} = 60\text{nm}$)、ハイパースペクトルセンサは狭帯域の周波数領域を波長分解能 2.5nm ほど(本研究で用いたハイパースペクトルカメラ)の感覚で連続的なデータを取得している。これによりマルチスペクトルセンサの情報だけでは得られなかった情報を得て解析することが可能になっている。また、その空間分解能に関してでもマルチスペクトルセンサの空間分解能が百～数千メートルであるのに対し、ハイパースペクトルセンサの空間分解能は十～数十メートルである。例として衛星リモートセンシングのハイパースペクトルセンサの性能は、バンド数がそれぞれ Hyperion($0.4 \sim 1.0 \mu\text{m} : 60$ バンド, $1.0 \sim 2.5 \mu\text{m} : 150$ バンド), CHRIS($0.40 \sim 1.05 \mu\text{m} : 61$ バンド)となっている。航空機リモートセンシングのハイパースペクトルセンサの性能は、バンド数がそれぞれ CASI ($0.4 \sim 1.05 \mu\text{m} : 288$ バンド) AISA ($0.4 \sim 1.0 \mu\text{m} : 270$ バンド)である。これらのハイパースペクトルセンサ、マルチスペクトルセンサはリモートセンシングだけでなく、食用の鳥やラットの肌の腫瘍の分析[7][8], ラットの脳の解析[9]など医学的な面にも活躍の場を広げている。

ハイパースペクトル画像(ハイパースペクトルデータ)とはハイパースペクトルセンサから得られるデータのことをいう。ハイパースペクトルセンサは高周波数分解能を持っていると前述したが、そのためデータ量が通常の画像サイズ×バンド数と膨大なものとなっている。ハイパースペクトルデータを解析する上で問題となってするのが特徴数(バンド数)の増加である[10]。バンド数が多いと、誤認識率の上昇、計算時間の増加といった問題が発生してくる。そういった問題点を解消するためにバンドの削減を実行するといった研究が多々行われている[11]。そのほか、バンド数の多いハイパースペクトルデータの役に立つ可視化のためのバンド削減[12], ハイパースペクトルデータの圧縮[13]といった研究もある。また、個人で撮影できるハイパースペクトルセンサが少なく、ハイパースペクトルデータの分析以前に特定の対象物に対する撮影法[14]の研究も行われている。

ハイパースペクトルデータの研究の中でもクラスタリングの研究が近年盛んに行われている。現在前述したバンド選択を用いた高速クラスタリングの研究が多数行われているが、そのようなスペクトル情報のみを用いるクラスタリング手法の場合どうしても数～数十ピクセル程度の細かいノイズが多数のってしまう。そういっ

たノイズを失くすために本研究ではマルチスペクトルデータ解析におけるセグメントベースでのクラスタリング[15]を参考にし，細かいノイズにロバストな，空間情報を用いたクラスタリング手法を提案する．

第二章では本研究で比較対象とする既存手法のアルゴリズムと提案手法のアルゴリズムと，提案手法の理解に必要なアルゴリズムの紹介をする．また，提案手法の計算量を議論する．

第三章では実験に使用するハイパースペクトルセンサの紹介をし，実際に撮影したハイパースペクトルデータにクラスタリングをし，既存の手法と提案手法の結果について精度と計算時間の面から比較する．また，パラメータの変化による結果の違いを論ずる．

第四章では提案手法のこれからの展望と課題となっている点，その改善策について述べる．

第二章 クラスタリング手法

2.1 従来のクラスタリング手法

2.1.1 k-means 法

k-means 法とはクラスタ数 k と初期クラスタの重心を与えることで n 個のデータを k 個のクラスに分類する手法である。簡単なアルゴリズムは以下のようになる。

1. 初期クラスタ数 k と初期クラスタの重心を与える。
2. データ $x_i (i=1,2,\dots,n)$ と各クラスタの重心間の距離を計算し、一番距離の少ないクラスタにデータ $x_i (i=1,2,\dots,n)$ を割り当てる。
3. n 個のデータ全てに対し 2 を行った後、新たにクラスタの重心を計算する
4. クラスタの重心が収束するまで 2, 3 を繰り返す

この手法は教師データを必要としないという利点を持っている。しかし、同時にクラスタリングの結果が重心の初期値に依存してしまうこと、大量の計算時間を必要とすることという問題点も持っている。

2.1.2 最尤法

画素データ \bar{x} が観測されたとき、それが分類クラス k から得られるものである事後確率を尤度という。各クラスに対する画像データの尤度を求め、それが最大となるクラスに画素を分類する手法が最尤法である[16]。クラス k から \bar{x} が観測される条件付確率を $P(\bar{x}|k)$ とすると、尤度 L_k は

$$L_k = \frac{P(k) \cdot P(\bar{x}|k)}{\sum_i P(i) \cdot P(\bar{x}|k)} \quad (2.1)$$

と表現される。 $P(k)$ クラス k の事前確率であり、通常はどのクラスでも等しい値を

取ると想定する．また分母はどのクラスについても共通の値であるためクラス間で比較するときには無視できる．よって $P(\bar{x}|k)$ がわかれば尤度の比較ができることとなる．そこで $P(\bar{x}|k)$ を多次元正規分布と仮定し，その平均や分散共分散をトレーニングデータから取得すると画素データ \bar{x} のクラス k への尤度 L_k は

$$L_k = \frac{1}{2\pi^{n/2} |\bar{\Sigma}_k|^{1/2}} \exp\left\{-\frac{1}{2}(\bar{x} - \bar{\mu}_k)^t \cdot \bar{\Sigma}_k^{-1} \cdot (\bar{x} - \bar{\mu}_k)\right\} \quad (2.2.)$$

となる．ただし， n は特徴空間の次元数， $\bar{\mu}_k$ はクラス k の平均ベクトル， $\bar{\Sigma}_k$ はクラス k の分散・共分散行列である．さらに無関係な項を取り除くと

$$L_k = \frac{1}{|\bar{\Sigma}_k|^{1/2}} \exp\left\{-\frac{1}{2}(\bar{x} - \bar{\mu}_k)^t \cdot \bar{\Sigma}_k^{-1} \cdot (\bar{x} - \bar{\mu}_k)\right\}$$

となる．この対数をとると

$$f_k(\bar{x}) = \frac{1}{2} \ln |\bar{\Sigma}_k| + \frac{1}{2} (\bar{x} - \bar{\mu}_k)^t \cdot \bar{\Sigma}_k^{-1} \cdot (\bar{x} - \bar{\mu}_k) \quad (2.3)$$

という式がでてくる．この判別関数 $f_k(\bar{x})$ が最小の値をとるとき尤度 L_k は最大の値をとる．

2.2 提案手法

前述のクラスタリング手法ではハイパースペクトル画像のスペクトル情報だけを利用し，空間的なつながりを一切使用していない．そのような手法によりハイパースペクトル画像をクラスタリングすると，どうしても一様なクラスの中に数～数十ピクセル程度のノイズが発生してしまう．そこで，そのようなノイズに対してロバストなクラスタリングをするためにハイパースペクトル画像に対する，空間情報を用いたクラスタリング手法を提案する．

本研究では，1つ1つのピクセルを単位として考えるのではなく，複数の空間的に隣接しているピクセルを一つのかたまり(以下 **region**)として扱う．**region** を単位としたクラスタリングを行うことにより，数～数十ピクセル単位のノイズが除去され，スペクトルデータのみを使うクラスタリング手法よりも高精度な結果がでることを示す．

2.2.1 アルゴリズム概要

具体的なアルゴリズムは以下のようになる。図 1～図 7 はその例である。

Step1 元画像に対しスペクトルを利用するために k-means 法で大雑把にラベリングをし、各ピクセルにラベルを付ける (図 2.2)。ただし、全バンドを用いてラベリングすると処理時間が膨大なものになってしまうのでここでは RGB の 3 バンドを用いている。

Step2. 空間的なつながりを見つけるために各ピクセルに対し周囲 4 近傍に同じラベルを持つピクセルがあればそのピクセルと merge し、region を作る (図 2.3)。この作業には region の作成のために an iterative algorithm[17]を使用している。ここで注意するのは同じラベルになっていても違う region とされていることもある。ピクセル数の少ない region を foreground, ピクセル数の多い region を background とする。

Step3 foreground をノイズと見て、foreground がなくなるまで foreground とされた region 内のピクセルを周囲の background とされた region のラベルに割り当てていく (図 2.4)。図のように foreground である x_0 に割り当てられる region のラベルは x_0 の周囲 8 ピクセルの background であるピクセルのうち数をもっとも多いものとなる (図 2.1)。これを以降 region growing[15]と呼ぶ。

x_1	x_8	x_7
x_2	x_0	x_6
x_3	x_4	x_5

図 2.1:region growing の例

Step4 ノイズ除去が行われた後、自動的に大きな region をよりコンパクトな subregion に分けるために erosion により各 region に対し、subregion がないかどうかを確認する (図 2.4, 2.5)。もし subregion があつたなら dilation でサイズを戻す(図 2.6, 2.7)。サイズを戻したものに図 2.4 の画像を重ね合わせることで subregion 同士の境界を決める。

Step5 最後に各 region 内のピクセルの平均をとり、各 region の輝度値を決定する。その後クラスタリング精度をよりよいものとするために全スペクトルバンドを利用した最尤法により各 region がどのクラスに入るかを決定する。region 数はピクセル数と比べ圧倒的小数であることが予想されるので全スペクトルバンドを利用

しても計算時間はさほど問題ではなくなる.




図 2.2:k-means 法によるラベリング




図 2.3:region の作成




図 2.4:region growing




図 2.5:erosion



図 2.6:subregion ~分割



図 2.7:dilation




図 2.8:境界線決定

2.2.2 region 生成の前処理

an iterative algorithm は binary image で connected components を発見するアルゴリズムである。今回このアルゴリズムを binary image ではないものに対して使用しているのでアルゴリズムを若干変更した。内容は以下ようになる。

top-down 画像の左上から走査していく。対象のピクセルの左もしくは上に同じラベルのピクセルがあればそれらを同じ region とする。

bottom-up 画像の右上から走査していく。対象のピクセルの右もしくは下に同じラベルのピクセルがあればそれらを同じ region とする。

2.2.3 erosion 及び dilation 処理

erosion の対象となる画像A，構造要素Bがあるとき，構造要素Bの原点を図形A内で移動させたときの共通部分が erosion の結果となる（図 2.9）。

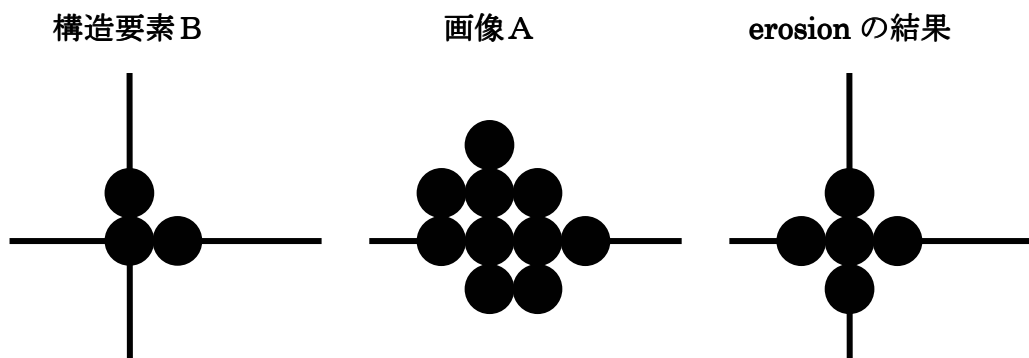


図 2.9:erosion の例

dilation させたい画像A，構造要素Bがあるとき，構造要素Bの原点を図形A内で移動させたときにBが覆うことができる領域が dilation の結果となる（図 2.10） [18].




図 2.10:dilation の例

本研究で用いるアルゴリズムではただか数ピクセル程度でつながっている部分を切り離すために erosion を用い、dilation を元の画像とマスクするために各 subregion に対し行っている。構造要素を図 2.11 のように設定している。




図 2.11:提案手法で用いる構造要素

2.2.4 計算量の推定

ここでは提案アルゴリズムにかかる計算時間を全体を通して考えるのではなく部分的に分割して検討する。以下表 2.1 の変数を用いて議論する。

表 2.1:変数の定義

k-means 法の初期クラスタ数	C_k
バンド数	N_b
ピクセル数	N
反復回数	l_k
Step2.で作成された region 数	R

foreground である region 数	R_{fore}
R_{fore} のピクセル数	N_{fore}
反復回数	l_{rg}
subregion が存在する region 数	R_{sub}
ある region r の subregion 数	S_r
dilation の反復回数	l_{dil}
最終的な region 数	R_{dil}

Step1 3 バンドを用いた k-means 法である. 使用している距離はユークリッド距離である. よって距離の計算のオーダーは $O(N_b)$ である.

k-means 法のアルゴリズム 1 の計算量は $O(C_k N)$ となる.

k-means 法のアルゴリズム 2 の計算量は全ピクセルに対して各クラスターの重心との距離を計算しているので $O(C_k N_b N)$ となる.

k-means 法のアルゴリズム 3 の計算量はクラスターごとに重心を計算しているので $O(N_b N)$ となる.

この作業を l_k 回繰り返しているので全体の計算量は

$$O(l_k C_k N_b N)$$

(2.4)

となる.

Step2. An Iterative Algorithm を使用している.

Top-down の走査の計算量は $O(N)$ である.

Bottom-up の走査の計算量は regionA と regionB を同じ region にする際に片方の region 内のピクセル全てをもう片方の region 番号を代入している. この操作は走査しているピクセルの右もしくは下に同じ region があれば実行している. 走査しているピクセルの右もしくは下に同じ region がある確率はであり,

$$O(N^2)$$

(2.5)

となっている.

Step3 foreground であるピクセルに対し周囲 8 近傍と比較を行っているので計算

量は $O(R_{fore}N_{fore})$ である.

これを foreground がなくなるまで l_{rg} 回繰り返しているので全体で計算量は

$$O(l_{rg}R_{fore}N_{fore}) \quad (2.6)$$

となる.

Step4 ここでは計算量の議論を erosion 部分と dilation 部分とに分割して考えることにする.

erosion 部分 : 全ての region に対し, 構造要素を動かしているので計算量は

$$O(N) \quad (2.7)$$

となる.

dilation 部分 : subregion が存在する region に対して dilation を行うので $O(R_{sub}S_rN)$ である. これを図 2.4 の画像に重ね, 境界線を出すことのできる大きさになるまで l_{dil} 回反復するので全体で

$$O(l_{dil}R_{sub}S_rN) \quad (2.8)$$

となる.

Step5 最尤法の計算時間について考える. まず尤度を計算する段階でトレーニングデータの平均ベクトル \bar{x} と分散共分散行列 $\bar{\Sigma}_k$ とその行列式 $|\bar{\Sigma}_k|$, 逆行列 $\bar{\Sigma}_k^{-1}$ を計算し, その後各 region に対し式を利用して尤度が最大となるクラスを探す.

平均ベクトルと分散共分散行列を求める計算量は $O(N_tN_b)$, $O(N_tN_b^2)$ である.

行列式と逆行列の演算には LU 分解を使用している. よってその計算量は各クラスごとに $O(N_b^3)$ であり, 全体では $O(CN_b^3)$ となる.

尤度を計算するときの計算量は $O(N_b^2)$ である. これをトレーニングデータのクラス数だけ行うので $O(CN_b^2)$ となり, さらに各 region ごとに尤度を計算すると最終的な region 数を R_{dil} としたとき $O(CR_{dil}N_b^2)$ となる.

また, プログラムの実装上各 region も計算しなければならず, その分の計算量が

$O(NN_b)$ である.

これらを踏まえた上で全体の計算量を考えると

$$O(NN_b + CR_{dil}N_b^2) \tag{2.9}$$

となる.

第三章 実験結果

ここでは、実際にハイパースペクトルセンサを用いて撮影を行い、得られたハイパースペクトルデータに対して提案手法を実行し、その結果を最尤法と比較する。また、精度、計算時間、各パラメータの値を変化させたときの結果について議論する。

3.1 実験環境

今回の実験で使用したハイパースペクトルセンサはH S C 1700 といい、下記の表 3.1 がその性能である。また、その写真と撮影風景が図 3.1 である。

表 3.1:ハイパースペクトルセンサの性能

名称	H S C 1700
画像サイズ	640×480
撮影可能な周波数領域	400nm～800nm
バンド数	72、81
幅	約5.6nm、約




図 3.1:ハイパースペクトルセンサ(左)と撮影風景(右)

表 3.1 のバンド数と 1 バンドあたりの波長幅には二つのパラメータが記述してあるが、それは 2 台の別のハイパースペクトルセンサを用いたからである。

3.2 分類精度の評価

ここでは、実際にハイパースペクトルセンサを使用して撮影を行い、その画像に対して行ったクラスタリングの精度を比較する。

ブナ

この画像はブナ科の葉 5 種類と背景からなっている。葉は全てブナ科であるが、全て種類が違うので別クラスであるとし、背景も含め 6 クラスの画像になる。

画像サイズは 388×438 であり、1 ピクセルに 72 バンドのスペクトル情報を持っている。図 3.2 がその画像とトレーニングデータ、図 3.3 が分類結果となっている。




図 3.2:ブナ科 5 種の画像と
トレーニングデータ

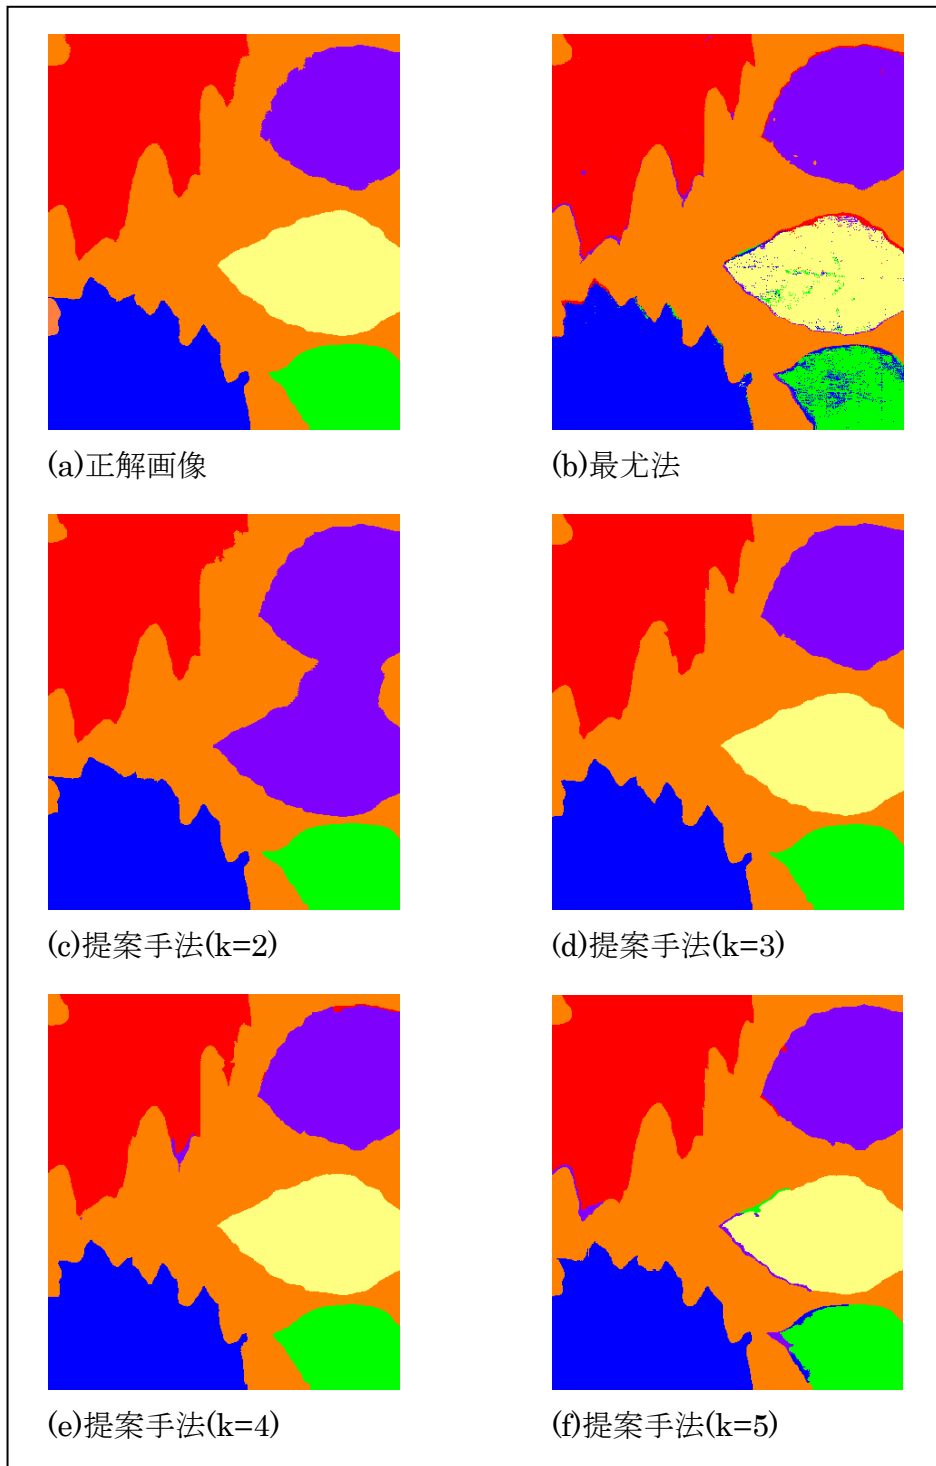


図 3.3:ブナ科 5 種の分類結果

次がその精度と計算時間の表である.

表 3.2: ブナ科 5 種の精度と計算時間

	精度(%)	計算時間(秒)
最尤法	95.2	564.7
提案手法(k=2)	84.5	44
提案手法(k=3)	97.9	193.6
提案手法(k=4)	97.2	213.1
提案手法(k=5)	97.1	341.6

精度に関して...

k=3,4,5 では約 2%最尤法よりも高くなっている. 図 3.3 を見てみると, 最尤法に見られる細かなノイズが一切なくなっていることがわかる. しかし, k=4,5 には大きめの範囲の誤認識があらわれてしまっている. これは最後に行う最尤法により region ごと誤認識されているからである. それを除けば, 細かなノイズ除去の効果が現れていることがわかる.

k=2 のときのみ精度が低い, これは 2 枚の葉が一つのクラスになってしまっているせいである. 元画像と出力画像を比べてみると 2 枚の葉を繋げてしまっている部分は影となっており, k=2 で k-means 法を実行してしまうと影が葉と誤認識されていると考えられる.

計算時間に関して...

いずれも最尤法と比べて短くなっていることがわかる. しかし, k の値を 2 から 3 に増やした際には格段と増加してしまっている. これは k が 2 から 3 になった時の region 数の増加によるものと思われる.

コリウス

シソ科コリウスの葉であり, 異なる品種の葉を 4 枚, さらに背景が加わり 5 クラスの画像になっている. この葉には赤い斑模様がついていて, スペクトル情報だけを用いてクラスタリングしようとする, 斑がノイズになり精度のよい分類ができな可能性もある. これにより, 色が一樣でないクラスで, 本手法によるノイズ除去の効果が現れるのを示す. 図 3.4 がその画像である.

画像は 450×200 であり, バンド数 81 のものを使用している.

下にクラスタリング結果とその精度と計算時間を示す.

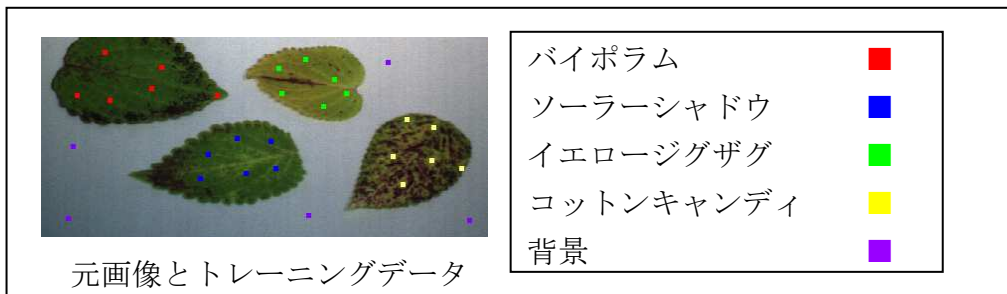


図 3.4: コリウス 4 種の元画像

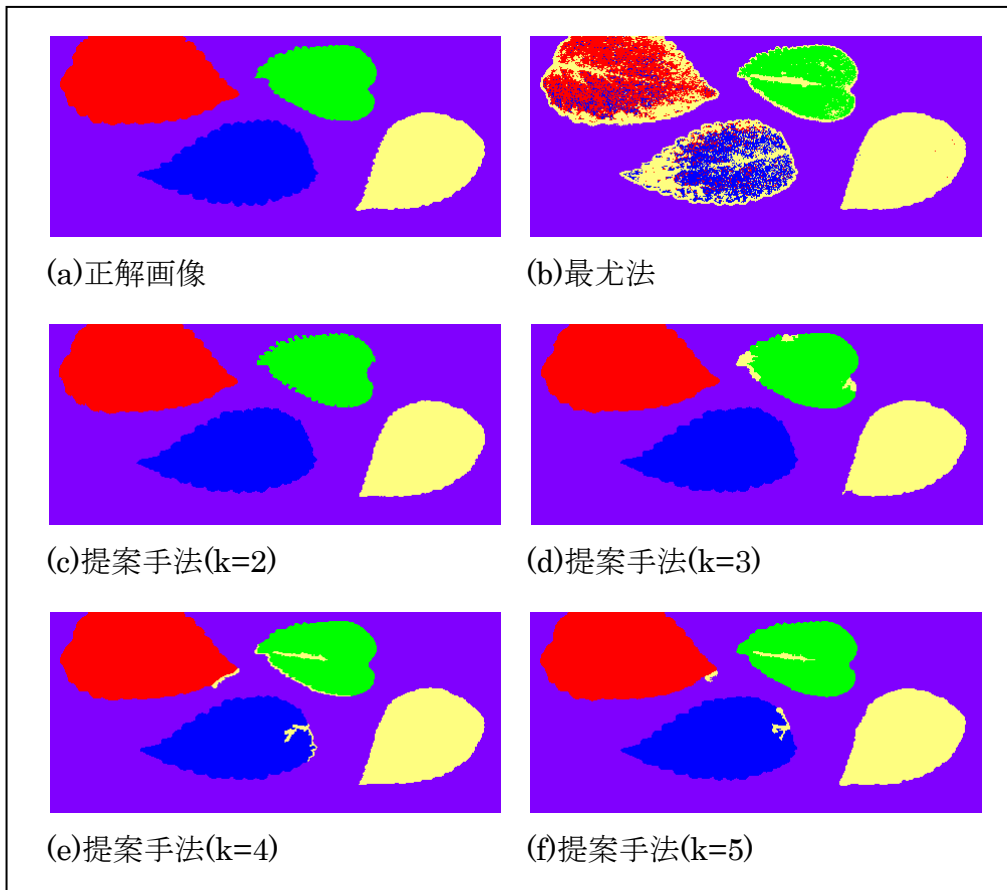


図 3.5: コリウス 4 種の画像の分類結果

表 3.3: コリウス 4 種の画像の精度と計算時間

	精度(%)	計算時間(秒)
最尤法	86.9	328.9
提案手法(k=2)	98.8	20
提案手法(k=3)	98.6	41.6
提案手法(k=4)	98.3	59.9
提案手法(k=5)	98.7	412.9

精度について…表 3.3 を見るといずれも最尤法よりも 11%ほど精度が上がり、全て 98%を上回る結果となった。図 3.5 を見るとコリウスでもブナの画像と同じように最尤法にみられる細かなノイズが無くなっている。これより、一様な色でないものをクラスタリングするときにも、提案手法はノイズ除去の効果を発揮し、対象の高精度なクラスタリングが可能である。

計算時間について…k=2,3,4 の場合、計算時間が最尤法の 15 分の 1 から 5 分の 1 ほどに減っているのがわかる。k=5 の場合のみ 412.9 秒と大量の時間を使ってしまっている。今回のノイズはある程度の大きさを持つものなので適度な大きさを持つ region が多数出現してしまい、region growing に時間がかかってしまうためである。

ハイビスカス

ここでは、ノイズを段階的に変化させ、どの程度のノイズに対して提案手法が通じるのかを示す。

図 3.6 のように一様な色の葉（ハイビスカス）に 3 段階にわけ砂（ノイズ）を撒いた。それぞれの段階での精度、計算時間を見る。正解画像は図 3.7 であり、ノイズの段階は図 3.8 である。

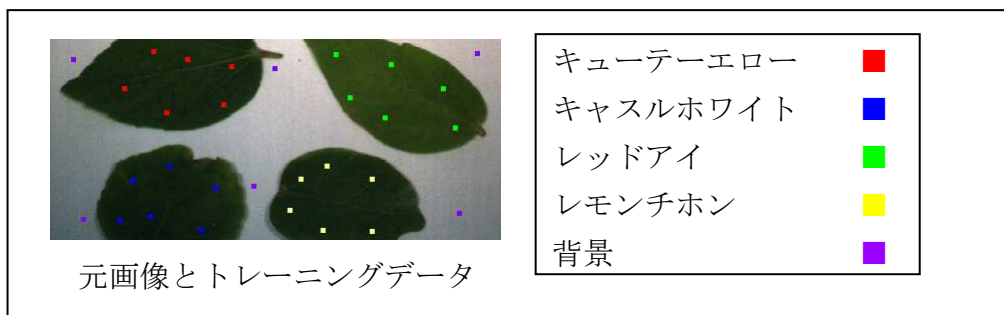


図 3.6: ハイビスカス 4 種の画像



図 3.7:正解画像




図 3.8:元画像

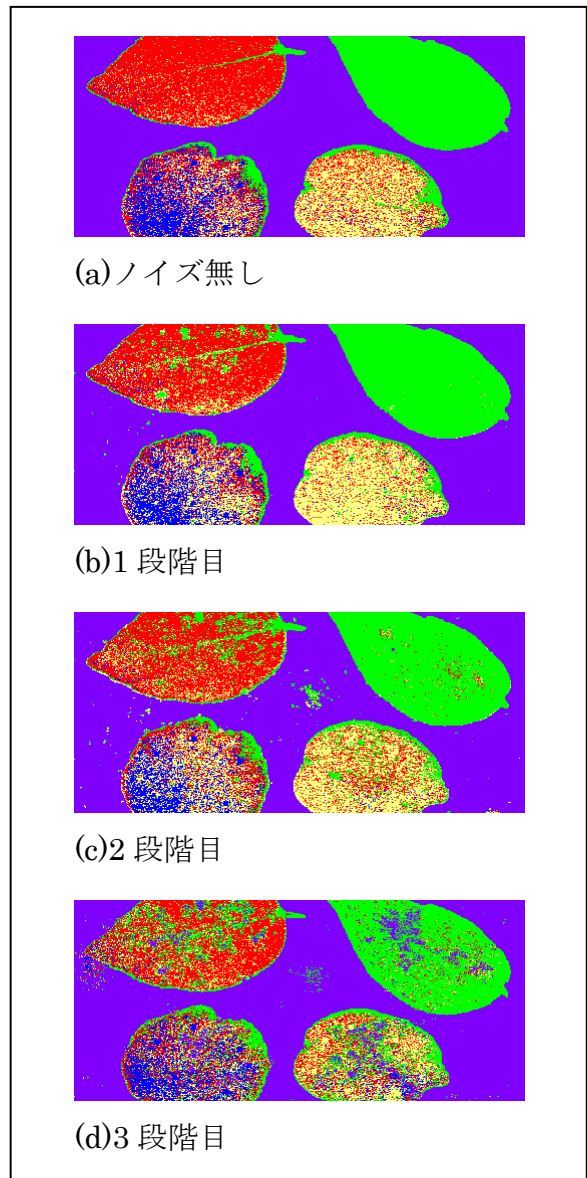


図 3.9:最尤法の分類結果

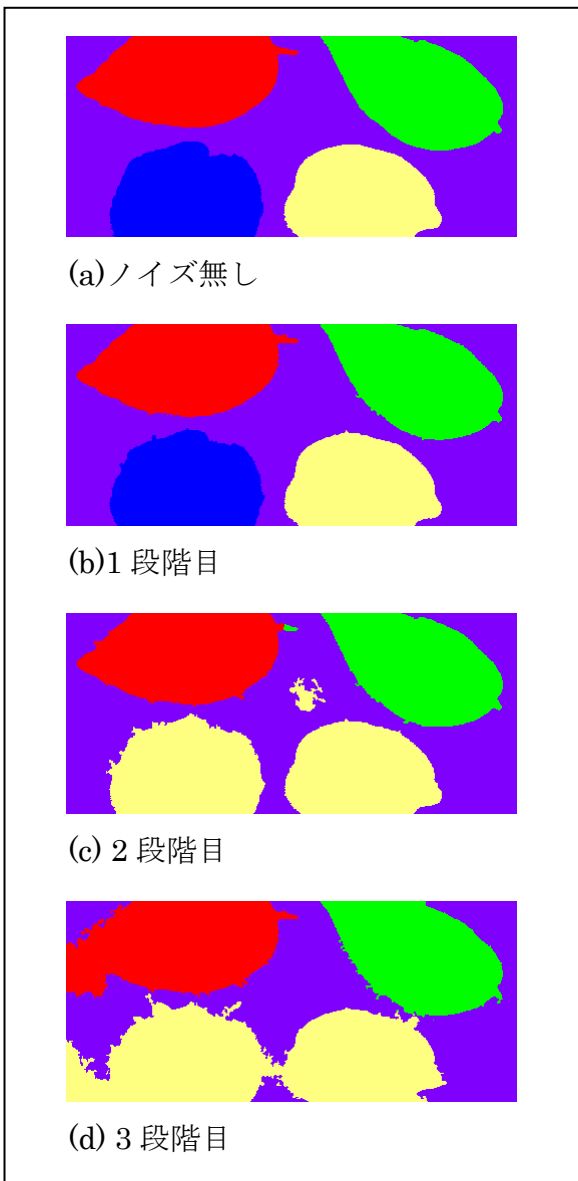


図 3.10:提案手法(k=2)の分類結

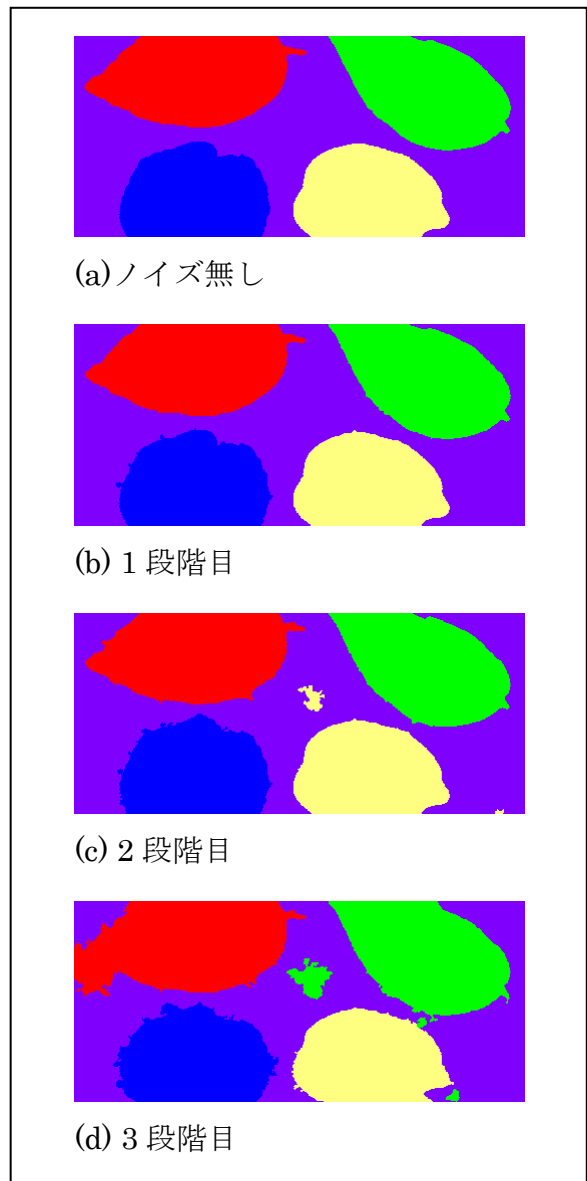


図 3.11:提案手法(k=3)の分類結果

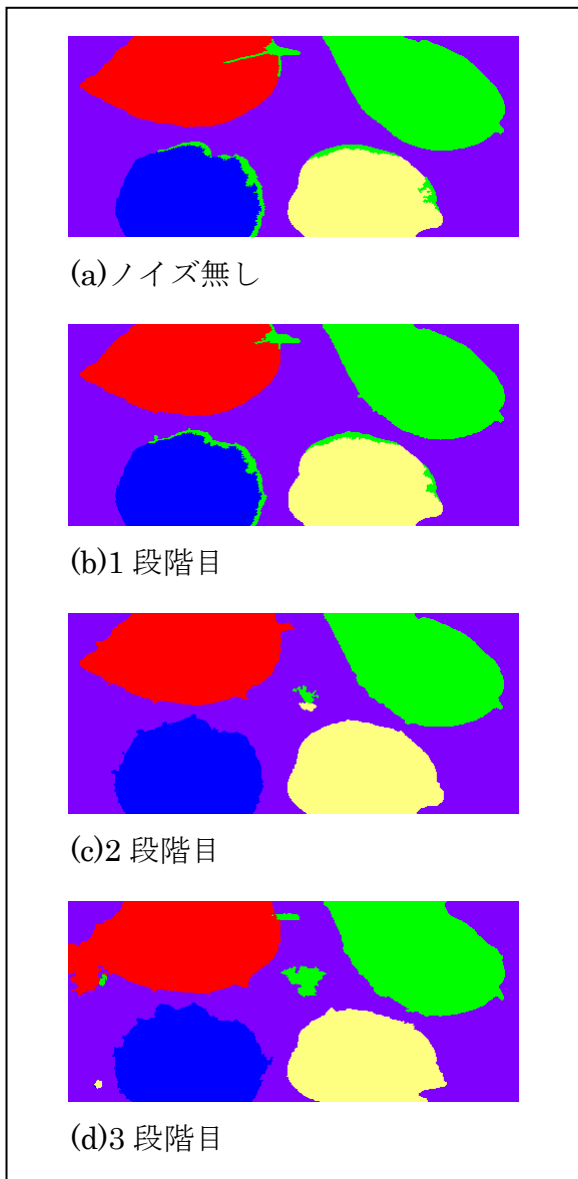


図 3.12:提案手法(k=4)の分類結果

表 3.4:各段階における精度

	最尤法	提案手法(k=2)	提案手法(k=3)	提案手法(k=4)
砂無し	84.2	99	99.3	97.3
1段階目	83.2	98.8	99.1	97.3
2段階目	78.6	85	98.2	98.4
3段階目	71.9	80	94.8	94.9

精度について…表 3.4 より $k=4$ の手法以外の手法では砂の量が増えるにつれて精度が悪くなっている。精度が下がる割合は $k=2$ が一番大きく、これは図 3.10 を見てわかるとおり 2 枚の葉を誤認識してしまっているせいである。region で最尤法をするとき、region の値は region 内のピクセルの平均をとっている。砂と葉が同じ region になってしまっていることで砂の影響がでて図 3.10(c)の誤認識が起こってしまったと考えられる。図 3.10(d)の誤認識は、下の 2 枚の葉が砂を通じて同じ region になってしまい、分けられなくなったためである。 $k=3,4$ の精度を段階順にみていくと、精度は悪くなっているものの 90%をキープしている。そしてどれも最尤法に勝る結果となっている。数値だけでなく、画像も交えて考えてみる。図 3.11 と図 3.12 を見ると提案手法では葉の中のノイズを効果的に除去することができているといえるが、全ての k において背景と重なっているノイズをご認識してしまっている。これに対し図 3.9 の最尤法は背景と重なっているノイズは少ないものの、葉の内側のノイズが非常に多くなっている。

表 3.5:各段階における計算時間

	最尤法	提案手法($k=2$)	提案手法($k=3$)	提案手法($k=4$)
砂無し	308.5	15.6	41.7	54.6
1段階目	297.9	21	42.2	170.4
2段階目	318.4	27.8	55.3	370.4
3段階目	305.9	40.5	72.5	451.3

計算時間について…表 3.5 より計算時間のみを比べると $k=2,3$ が最尤法よりも速いことがわかる。一方 $k=4$ は砂無しの段階では最尤法よりも計算時間が少なかったが、2 段階目以降は最尤法よりもかかる時間が多くなってしまった。これも前の画像と同様 region の増加のためである。

まとめ

提案手法ではノイズが散りばめられていても同じ科であるハイビスカスの 4 つの品種の葉をそれぞれ分類することができた。このことから提案手法は細かいノイズに対してロバストなクラスタリングができる。

提案手法で $k=2$ の時の大きな誤認識が目立った。これは図 3.13 から図 3.14 のように $k=2$ がある点が 3 つ以上の region に接している際に対応できない場合があるからであると考えられる。よってパラメータ k の値は常に 3 以上に設定するとよい。だが、 k を増やすにつれ region が増えてしまうので 3, 4 が妥当だと思われる。




図 3.13:region の誤認識前




図 3.14:region の誤認識後

3.3 計算時間の評価

ここでは、前章で導き出したアルゴリズムの各部分の計算量と実際に k-means 法の初期値 k を変更した場合と対象画像のサイズを変更した場合の計算時間を比較する。

初期値 k を変更した場合

対象画像のサイズが 300×300 で、2 クラス問題について取り組んだ。

初期値 k を 2 から 6 までの数値に変えて実行した。そのときの k それぞれに対するアルゴリズムの各部分の計算時間（表 3.6）と、k=1 にかかるアルゴリズムの各部分の計算量を 1 としたときの計算時間とパラメータから計算した計算時間の近似の表と図が以下のものである。

表 3.6:初期値 k を増加させた各部分の計算時間
(括弧内は k=2 の場合を 1 としたときの比率)

k	2	3	4	5	6
k-means法	1522(1)	14803(9.7)	5688(3.7)	22282(14.6)	10106(6.6)
regionの作成 前半	3997(1)	8301(2.1)	13991(3.5)	16120(4)	22393(5.6)
region growing	47(1)	90(1.9)	158(3.4)	185(3.9)	365(7.8)
erosion	84(1)	80(1)	85(1)	83(1)	81(1)
regionの作成 後半	8732(1)	10862(1.2)	16334(1.9)	15450(2.8)	16836(1.9)
dilation	733(1)	41983(57.3)	57943(79)	95259(130)	158474(216.2)
最尤法	1205(1)	1282(1.1)	1309(1.1)	1539(1.3)	1716(1.4)

k-means 法




図 3.15:k の増加による k-means 法の計算時間の推移とその近似

k=2,4,6 の時は近似のグラフに近い値になっているが k=3,5 は大きくはずれてしまっている。これは近似のグラフでは収束までの反復回数を一定値として算出しているが、実際は k=2,4,6 の時にはすぐに収束し、k=3,5 のときには収束が遅いからであると予想される。

region の作成

このアルゴリズムは前半と後半 2 箇所挿入されている。一箇所はラベリングの後、一箇所は erosion の後である。これらの計算時間を見る前に、議論をよりわかりやすくするために region 数を調べた。それが表 3.7 である。

表 3.7:k の増加による各部分の region 数

k	2	3	4	5	6
k-means法後のregion数	6	15	171	219	529
foregroundのregion数	1	6	157	198	510
backgroundのregion数	5	9	14	21	19
erosion後のregion数	6	42	81	109	167




図 3.16:k の増加による region の作成の計算時間の推移とその近似

計算量の近似によると一定値をとるとなっているが、実際には増加している。プログラム中に if 分が多数存在しており、その if 文は region の数と形に依存して通っているため条件が非常に複雑である。その影響で近似より値が高くなり、k の値が増えるにつれ増加しているものと思われる。

region growing

region growing のグラフ化であるが、近似を k=2 の場合から図示すると比較できなくなるほど大きくなるので k=4~6 の場合のみ近似する。ここでは画素数は全て一定なので foreground のピクセル数、反復回数は全て等しいものと仮定する。




図 3.17:k の増加による region growing の計算時間の推移とその近似

k=4 以降は近似と似たようなグラフになったが、k=2 から近似すると近似とはかけ離れたものになってしまう。k=2 の時の region が少なすぎるのが理由だと思われる。

erosion




図 3.18:k の増加による erosion の計算時間の推移とその近似

erosion については式 (2.7) の計算量の近似どおりのグラフになっている.

dilation




図 3.19:k の増加による dilation の計算時間の推移とその近似

dilation の近似グラフを作る際, 各 background につき dilation する反復回数を background がどれも同じ大きさであると仮定した. これが原因となり. 近似が dilation のグラフよりも大きい数字を出している. グラフの形は妥当であると思われる.

最尤法




図 3.20:k の増加による最尤法の計算時間の推移とその近似

この近似ははっきりと判別できる数字で推定できたので, 実際の計算時間とのずれも少なく, 妥当であるといえる.

・画素数を変更した場合

対象画像の画素数を 20000 から 100000 まで 20000 刻みに変化させて、アルゴリズムの各部分の計算時間と region 数を調べた。k=3 と固定し、画像内のクラス数は 2 である。下の表 3.8 と表 3.9 が計算時間と region 数である。

表 3.8:画素数を増加させた各部分の計算時間
(括弧内は画素数 20000 の場合を 1 としたときの比率)

画素数	20000	40000	60000	80000	100000
k-means法	1941(1)	2941(1.5)	4906(2.5)	5038(2.6)	5682(2.9)
regionの作成 前半	853(1)	2623(3.1)	5450(6.4)	7305(8.6)	10028(11.8)
region growing	13(1)	111(8.5)	130(10)	86(6.6)	116(8.9)
erosion	17(1)	46(2.7)	57(3.4)	77(4.5)	100(5.9)
regionの作成 後半	1012(1)	3285(3.2)	6864(6.8)	8672(8.6)	11926(11.8)
dilation	883(1)	4278(4.8)	8911(10.1)	41123(46.6)	60003(68)
最尤法	416(1)	586(1.4)	726(1.7)	948(2.3)	1148(2.8)

表 3.9:画素数の増加による各部分の region

画素数	20000	40000	60000	80000	100000
k-means法後のregion数	39	27	63	22	37
foregroundのregion数	34	19	55	12	18
backgroundのregion数	5	8	8	10	19
erosion後のregion数	10	21	19	34	52

k-means 法




図 3.21:画素数の増加による k-means 法の計算時間の推移とその近似

計算量は、収束までの反復回数と一定と仮定すると、クラス数とバンド数が同じなので図 3.21 のように画素数に比例することになる。実際の計算時間とは少々はなれているが、 k の増加の時と同じように収束までの反復回数の影響によるものだと思われる。

region の作成




図 3.22:画素数の増加による region の作成の計算時間の推移とその近似

region の作成の計算量も k の増加のときの変化と同様に時間がかかってしまい、計算で出した近似とははなれたものになってしまう。

region growing

region growing の計算量を考える。前回は画素数が等しかったので反復回数と region のピクセル数を一定と仮定したが、今回は画素数に比例して foreground ピクセル数を増加させ、foreground が正方形だと仮定してその一辺の半分を反復回数とする(正方形の foreground region が region growing し終わる反復回数は一辺の約半分である)。すると近似は以下のようなになる。




図 3.23:画素数の増加による region growing の計算時間の推移とその近似

グラフの形は似たような形になったが、画素数 40000 の時は大きく離れる結果となっていました。原因はおそらく foreground のピクセル数の仮定と形の仮定であると思われる。

erosion




図 3.24:画素数の増加による erosion の計算時間の推移とその近似

erosion は仮定を必要とせず近似できる。よって図を見てもわかるとおり妥当な結果といえる。

dilation




図 3.25:画素数の増加による dilation の計算時間の推移とその近似

dilation の近似する際に, subregion のある region 数を background 数と同じに, 一つの region あたりの subregion 数を作成された subregion 数の平均に, 反復回数を全ての background が正方形であると仮定し, その一辺の長さに比例させた. すると図 3.25 のようなグラフになり, この近似は実際の dilation のグラフと若干の誤差はあるが形が似ているので妥当だといえる.

最尤法




図 3.26:画素数の増加による最尤法の計算時間の推移とその近似

仮定なしで近似した. 実際は係数がかかってくるので妥当な結果といえる.

第四章 結言

本研究ではスペクトルデータのみを使用してクラスタリングした場合に発生してしまう一様なクラスの中の数～数十ピクセル程度のノイズにたいしてロバストなクラスタリングをするために空間情報を使うクラスタリング手法を提案した。提案手法は以下のようなものである。

- ・ 低次元化された画像を **k-means** 法によりラベリングし、空間的に隣接し同じラベルであるピクセルの集合を **region** とする。次にピクセル数の少ない **region** をノイズとみなして消去し、**region** をより多くの **subregion** に分ける。最後に各 **region** に対し全バンドを用いた最尤法を行う。

ピクセル単位でクラスタリングするのではなく、このように隣接しているピクセルを一つの **region** とし、**region** 単位でクラスタリングすることにより一様なクラスの中の数～数十ピクセル程度のノイズにたいしてロバストなクラスタリングができること示した。提案手法の特性を調べるため、提案手法と既存の代表的なクラスタリング手法である最尤法との比較を行い、実験結果について考察を行った。

- ・ 特にノイズののっていない画像
- ・ 一様な色でないクラス(葉)のある画像
- ・ 故意的にノイズをのせた画像

特にノイズののっていない画像に対しては最尤法に見られるような細かなノイズがなくなり、それによって精度が 2～3%上がり、計算時間も 3 分の 1 程度になっていることがわかった。一様な色でないクラス(葉)のある画像は斑模様のあるシソ科コリウスの異なる 4 つの品種の葉に対してクラスタリングした。最尤法は斑模様の部分に細かいノイズが多数現れたのに対し、提案手法は若干の誤認識があるもののそのようなノイズが激減している結果になった。精度は 11%提案手法のほうが高く、計算時間も 15 分の 1 から 6 分の 1 程度に下がっている。ほかにはノイズのない元画像に対して故意にノイズとして砂を撒いた画像を使った。砂は 3 段階に分けて撒き、最尤法と提案手法で各段階における精度と計算時間を比較した。結果精度は $k=2$ を除いて 20%以上上がり、計算時間は $k=4$ を除いて 6 分の 1 程度になった。

しかしその一方

- ・ k の値次第ではうまく **region** に分割されない場合がある
- ・ 画像次第では **region** 数が非常に多くなってしまうため、計算時間が膨大になっ

てしまう場合がある。

といった欠点も浮かび上がってきた。

k の値に関しては 1 点が 3 つの **region** に接する場合 2 では対応できないので 3 以上にする必要はある。このように設定すれば不必要な **region** の結合は回避することができる。3 以上とはいってもあまりに多すぎると **region** 数が増え、それによって計算時間が必要以上にかかるようになってしまう。本研究では一様なクラスの中の数～数十ピクセル程度のノイズを除去することを目的としているので高速を意識したアルゴリズムを用いていない。各部分のアルゴリズムをより高速なものに変更することができれば計算時間もある程度抑えられる形になる。

また、**k-means** 法の時点でユークリッド距離でなく、その画像の特性に強い距離（影の濃くでている画像に対してはコサイン距離など）を使用することによって一層ノイズの除去が見込める可能性がある。

謝辞

本研究を進めるにあたり，適切な御指導，御助言をいただいた本研究室スタッフの和田充夫教授，井上純一准教授，石村康生助教に厚く御礼申し上げます．また，数々のご協力，助言をしていただいた研究室の皆様，撮影用の植物を採取させていただいた北海道大学植物園の皆様にも深く感謝いたします．最後に，ハイパースペクトルデータを提供していただいた北海道工業大学の佐鳥准教授とその研究室の方々にも深く感謝申し上げます．

参考文献

- [1] 星仰：リモートセンシングの画像処理，森北出版株式会社，pp. 1-11, October 2003
- [2] 長澤良太：リモートセンシングによる土地資源評価—東南アジアの土地利用—，古今書院，pp. 1-3, March 2003
- [3] 竹内延夫：地球大気の分光リモートセンシング，学会出版センター，pp. 10-13, February 2003
- [4] 社団法人 日本機会工業連合会，財団法人 資源探査用観測システム研究開発機構：平成 17 年度 衛星リモートセンシング用ハイパースペクトル技術高度化の調査研究報告書，March 2006
- [5] <http://www.imi-jp.com/press/2004/details/ITRES.html>
- [6] <http://www.pasco.co.jp/measure/air/aisa/>
- [7] Songyot Nakariyakul and David Casasent, “Fusion algorithm for poultry skin tumor detection using hyperspectral data,” APPLIED OPTICS, Vol. 46, pp. 357-364, January 2007
- [8] Seong G. Kong, Matthew E. Martin, and Tuan Vo-Dinh, “Hyperspectral Fluorescence Imaging for Mouse Skin Tumor Detection,” ETRI Journal, Vol. 28, pp. 770-776, December 2006
- [9] Douglas J. Fox, Jr., Hana Tysver Velde, Chrysanthe Preza, Joseph A. O’Sullivan, William H. Smith, and Thomas A. Woolsey, “Computational hyperspectral interferometry for studies of brain function : proof of concept,” APPLIED OPTICS, Vol. 45, pp. 3009-3021, May 2006
- [10] 石井健一郎，上田修功，前田英作，村瀬洋：わかりやすいパターン認識，オーム社，pp. 99, August 1998
- [11] S. LU, K. OKI, Y. SHIMIZU and K. OMASA, “Comparison between several feature extraction/classification methods for mapping complicated agricultural land use patches using airborne hyperspectral data,” International Journal of Remote Sensing, Vol. 28, pp. 963-984, March 2007
- [12] Jeffrey B. Cole, “Dimensionality Reduction for Useful Display of Hyperspectral Images—A Comparison of K-Nearest Neighbors, Artificial Neural

Networks, and A Novel Probabilistic Overlay Technique—,

[13] Barbara Penna, Tammam Tillo, Enrico Magli, Gabriella Olmo, “Transform Coding Techniques for Lossy Hyperspectral Data Compression,” IEEE Transactions on Geoscience and Remote Sensing, Vol. 45, pp. 1408-1421, May 2007

[14] Abhijit J Chaudhari, Felix Darvas, James R Bading, Rex A Moats, Peter S Conti, Desmond J Smith, Simon R Cherry and Richard M Leahy, “Hyperspectral and multispectral bioluminescence optical tomography for small animal imaging,” PHYSICS IN MEDICINE AND BIOLOGY, Vol. 50, pp. 5421-5441, November 2005

[15] Selim Aksoy and H.Gokhan Akcay, “Multi-resolution Segmentation and Shape Analysis for Remote Sensing Image Classification,” in 2nd Internatil Conference on Recent Advances in Space Technologies, June 2005

[16] 日本リモートセンシング研究会：改訂版 図解リモートセンシング，日本測量協会， pp. 220-221, May 2001

[17] Robert M. Haralick, Linda G. Shapiro, “Computer and Robot Vision Vol1,” Addison-Wesley Publishing Company, pp. 32-33, June 1992

[18] 小畑秀文：モルフォロジー，コロナ社， pp. 12-42, November 1996