

第十一章 物体判読の実際

1. マルチスペクトル画像とは？
2. マルチスペクトル画像の可視化
3. レベルスライスによる分類
4. 統計量に基づく分類
 - + 分類クラスの決定法
 - 教師付き分類
 - 教師なし分類
 - 分類クラスの各統計量と画素値との距離と尤度
 - 分類のフロー
5. マイクロ波を利用する

問題

1. 地球観測衛星に搭載されているセンサのほとんどは、可視域から熱赤外域のデータを取得する。なぜ、紫外域のデータは取っていないのか推察しなさい。

マルチスペクトル画像とは？

1. カラー画像

- 物体には様々な色がついており，それを認識できる．そしてその色は，光の3原色である赤・緑・青の強さの組み合わせとして表現できる．
- ところで，広い電磁波の波長帯からある範囲を選択した任意の波長域をスペクトルバンド或はスペクトル波長帯と呼んでいる．カラー画像は3つのスペクトルバンドのデータを持っていると言えよう．

2. マルチスペクトル画像

- 3つ以上のスペクトルバンドのデータを持つ画像をマルチスペクトル画像と呼んでいる．
- 全章の電磁波の波長帯域でも示したように可視光は(0.4~0.7 μm)と，非常に狭い領域である．物質は非常に広範囲の波長領域において放射・反射がなされている．したがって，たくさんのスペクトルバンドを持っているデータは，物質の判読において非常に有利である．特に，人工衛星に観測機器にマルチスペクトルセンサが搭載されたものが多く，物体の判読に役立てられている．

+ マルチスペクトルセンサの例

+ NOAA AVHRR :

- 可視域1，近赤外域1，中間赤外域1，熱赤外域2の合計5つのスペクトル領域を観測できる

+ Landsat TM :

- 可視域3，近赤外域1，中間赤外域2，熱赤外域1の合計7つのスペクトル領域を観測できる

+ JERS-1 OPS VNIR :

- 可視域1，近赤外域2の合計3つのスペクトル領域を観測できる

+ JERS-1 OPS SWIR :

- 中間赤外域4の合計4つのスペクトル領域を観測できる

マルチスペクトル画像の可視化

1. 可視化のためのスペクトルバンドの選択

- 先にも述べたように色を表現するには、赤(R)・緑(G)・青(B)の3種類の光を組み合わせなければならない。3つのスペクトル領域を持つ画像であれば、それぞれRGBに割り当てれば一度に全てのスペクトル領域の画像を見ることができる。
- ところが、人工衛星のスペクトル領域は通常3つを越えており、可視のRGBに対応する領域がすべて揃っていないか全くない場合もある。このような場合には、すべてのスペクトル領域の中から適当な3つを選んで可視化することもできる。しかし、実際に我々が見る色とは程遠い着色となってしまう。

2. フォールスカラー画像

- このように現実的でない着色の画像を単にフォールスカラー画像と呼ぶ。この画像は、近赤外領域を赤に割り当て、可視の赤領域を緑、可視の緑領域を青に割り当てるのが慣習的に取られている。普通衛星画像といえばこの着色でがなされている。植生が良く反射する近赤外領域を赤に割り当てているため、この画像は植生の目視判読に利用される。

3. トゥルーカラー画像

- 一方、人間が見た色に近いスペクトル領域をRGBに割り当てたものをトゥルーカラー画像と呼んでいる。Landsat TMは、可視の赤・緑・青の領域を持っているのでこの画像を得るには簡単であるが、他の衛星にはない。したがって、近赤外領域を緑にして、トゥルーカラーに近い画像を得る場合がある。

レベルスライスによる分類

1. レベルスライスとは？

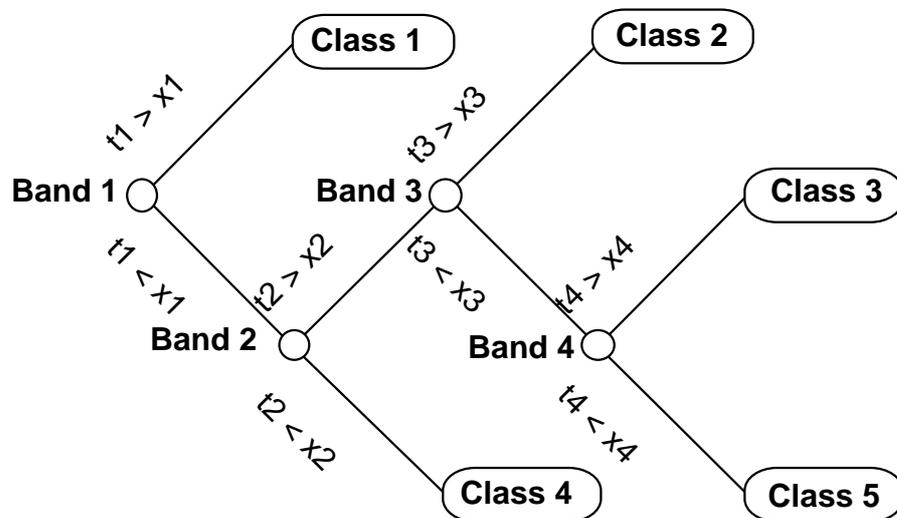
- あるスペクトルバンドの画像データがあり，その値は0～255の間全てに分布しているとする．この時，幾つかの範囲に値を区切り，例えば0～128の値を示すものを分類1に，128～255の値を示すものを分類2にするという分類方法をレベルスライスという．そして，分類の境に位置する値（この例では128）を閾（しきい）値という．
- 植生指標等をレベルスライスによって分類することもある．植生指標は，-1～1の範囲を取り，何らかの植生があれば，0以上の値を取る．このような条件を使ってレベルスライスによる分類がなされる．

2. マルチレベルスライス

- 複数のスペクトルバンドのデータがあり，それぞれのバンドにレベルスライスを適用する手法をマルチレベルスライスという．

3. ディジションツリー

- レベルスライスの拡張版ともいえる．一定のルールに従って，分類していく．例を下図に示す．例では，Band 1の値が X_1 より大きければClass 1に， X_1 より小さければ次の条件に岐しながら分類していく．



統計量に基づく分類

1. なぜ統計量を使うか？

- マルチスペクトル画像の分類において物体の分光反射特性を用いる手法では，我々の必要とする分類クラス（項目）にちゃんと対応できない．植生指標にしてもクロロフィルの量は推定できて，それが何の樹種なのか，草原なのか森林なのかといった判定は極めて難しい．たくさんのスペクトルバンドを持つ画像でも可視の赤バンドと近赤外バンドのデータのみしか利用していないのである．したがって，全てのスペクトルバンドのデータを利用するには統計量に頼るのが最も現実的な手法である．

2. 分類クラスの決定法

- 統計量を用いたマルチスペクトル画像の分類において，まず必要なことは，分類クラス（項目）の決定である．したに示したように，手動で決定する方法と自動で決定する方法の2種類ある．

+ 教師付き分類

- 画像を見て人間が分類クラスを決め，各分類クラスの最も典型的な箇所（トレーニングエリア）を抽出し，その統計量を使う分類法をいう．トレーニングエリアの抽出が最も重要な作業で，分類結果に大きく影響を与える．

+ 教師なし分類

- 画像全体の統計量から自動的に分類クラスを作成する方法をいう．多変量解析のクラスタリングが主に利用される．自動的に分類させた後，各分類クラスが何の地目に相当するかを判断しなければならない．

分類クラスの統計量

1. 平均

- nバンドのマルチスペクトル画像があったとする .
- k個のクラスに分類するべくトレーニングエリアを抽出した .
- + 各画素データは、ベクトルで表すことができる .

$$X = (x_1, x_2, x_3, \dots, x_n)$$

- + この時、クラスkの平均値ベクトルは、

$$\mu_k = (m_1, m_2, m_3, \dots, m_n)$$

$$m_i = \frac{1}{l} \sum_{j=1}^l x_{ij} \quad l: \text{トレーニングデータの個数}$$

2. 分散・共分散行列

- 分散・共分散行列は、

$$k = \begin{bmatrix} 11 & 12 & \dots & 1n \\ 21 & \cdot & & \cdot \\ \cdot & & \cdot & \cdot \\ \cdot & & & \cdot \\ \cdot & & & \cdot \\ n1 & \dots & & nn \end{bmatrix} \quad ii = \frac{\sum_{j=1}^l (x_{ij} - m_i)^2}{n - 1}$$

- 分散を対角成分に持ち、その他は全て0の行列

$$k = \begin{bmatrix} 11 & 0 & \dots & 0 \\ 0 & 22 & & \cdot \\ \cdot & & \cdot & \cdot \\ \cdot & & & \cdot \\ 0 & \dots & & nn \end{bmatrix}$$

分類クラスの統計量と各画素値との距離と尤度

+ 距離

- 各画素の値とすべての分類クラスの統計量とを距離 (d_k^2) で表すことができる。距離がもっとも短いものが、その分類クラスであると推定できる。以下に距離の算出法を示す。

+ ユークリッド距離

$$d_k^2 = (x - \mu_k)^t \cdot (x - \mu_k) \quad \text{添え字の} t \text{は転置行列を示す}$$

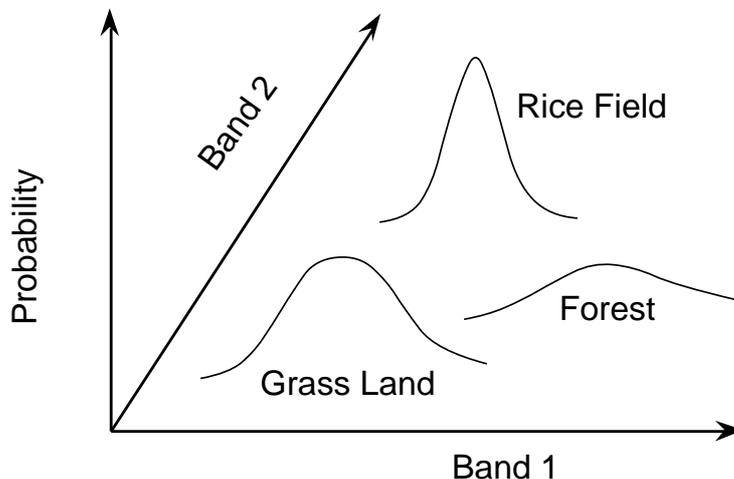
+ マハラノビス距離

$$d_k^2 = (x - \mu_k)^t \cdot \kappa^{-1} \cdot (x - \mu_k) \quad \text{添え字の} -1 \text{は逆行列を示す}$$

+ 尤度

- 各クラスに対する画素データの尤度を求め、最大の尤度のクラスにその画素を分類する。
- 尤度とは、画素データ x が観測された時、それが分類クラス k から得られたものである確率である。クラス k から x が観測される条件付き確率を $P(x|k)$ とすると尤度 L_k は次のように表現される。

$$\begin{aligned} L_k(x) &= P(k|x) = P(k) \cdot P(x|k) / P(i) \cdot P(x|i) \\ &= \{2^{-n/2} \cdot (\det \kappa)^{-1/2}\}^{-1} \cdot \exp \{(-1/2) \cdot (x - \mu_k)^t \cdot \kappa^{-1} \cdot (x - \mu_k)\} \end{aligned}$$



分類のフロー

1. 分類クラスの検討

- マルチスペクトル画像を目で見て、分類が可能と思われる項目について検討する。

2. 分類クラスを画像から抽出（トレーニングデータ取得）

- 画像において、典型的な各分類クラス的位置を抽出。この作業が最も重要。出来るだけノイズの少ない部分から抽出するよう心掛ける。

3. 分類クラスの統計量計算

- 平均・分散・共分散行列の計算。

4. 距離或は尤度の計算

- 全ての画素について、各クラスの統計量との距離や尤度を計算する。

5. 分類

- 分類結果を目で見て、明らかに分類エラーが在ると思われる時は、2の「分類クラスの画像からの抽出」に戻る。各クラスの統計量を見れば、どのクラスの距離が近いかが判るので、それを頼りにする。
- いくら分類クラスの抽出を行なってもうまくいかない場合は、「分類クラスの検討」をもう一度行う必要がある。もともと統計量に差がないものを分類しようとしていないかチェックする。

6. 分類後の処理

- 分類結果は、元画像によって大幅に違うものである。特に画像にノイズがある場合は厄介である。非常に細かなノイズがある場合には、画素ごとに周囲の結果と見比べて修正するフィルタリングが必要な場合がある。

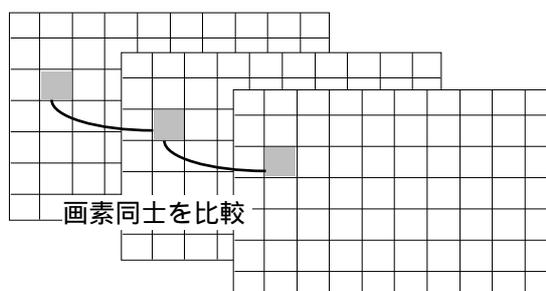
雲無し画像を作成する

1. 雲無し画像の必要性

- 太陽光の反射や放射を観測するいわゆる光学センサによって地表面を捉える場合，気象状況が画像に影響を与える．特に雲が観測領域を覆っているシーンは，使えない．
- 観測領域が広域の場合，観測領域の全域が晴れているケースは意外に少ないものである．したがって部分的に晴れている領域を組み合わせることで，最終的に雲のない画像を作成することになる．

2. 雲無し画像作成法

1. まず，比較的雲の少ない何シーンかを用意する．この時，出来るだけ同時期に得られたシーンを用いる．時期の違いによって地上の地目が変化することを避ける．
2. すべてのシーンに対して大気補正を施す．観測条件によって大気中の水蒸気量などが異なるため，これを補正しておく．
3. すべてのシーンに対して幾何補正を施す．幾何補正を施せば，すべてのシーンにおいて各画素の対応関係を得ることができる．
4. 画素ごとに可視域の値を比較（図参照）し，最も小さい値のものが雲のないものと推定され，その値を代表値とする．通常雲は反射率が非常に高いことによる．



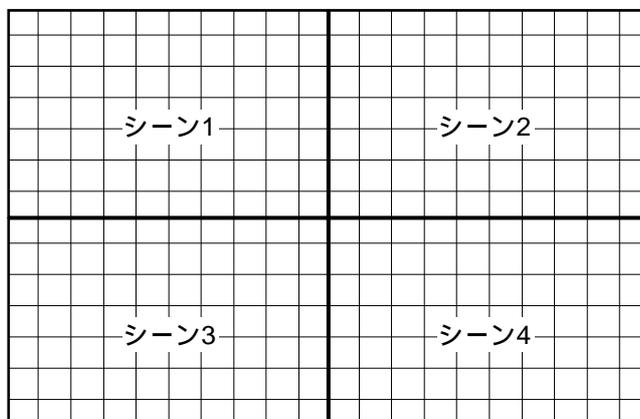
モザイク画像を作成する

1. モザイク画像の必要性

- 対象領域が広域で，しかも使用センサの観測幅が狭く，1シーンで観測領域全てをカバーできない場合，幾つかの画像を組み合わせるモザイク技術が必要となる．
- 対象領域を日本全土や全地球とした場合には必ず必要となる．

2. モザイク画像の作成法

1. まず，対象領域における雲のないシーンをすべて用意する．この時，出来るだけ同時期に得られたシーンを用いる．時期の違いによって地上の地目が変化することを避ける．
2. すべてのシーンに対して大気補正を施す．観測条件によって大気中の水蒸気量などが異なるため，これを補正しておく．
3. すべてのシーンに対して幾何補正を施す．
4. 幾何補正の情報をもとに，すべてのシーンを用いて隙間のできないように並べていく．



時系列画像を使用する

1. 分類精度を向上させるための時系列処理

- 分類を行う時，1時期のデータのみでは分類が困難であるものが，多時期のデータであれば分類可能となる場合がある．例えば，植生に四季を通しての変化が有り，それが分類のキーとなり得るのである．常緑樹林と落葉樹林とで，変化に差があることは容易に想像できる．
- 時系列画像の所為は，基本的に雲無し画像の作成と同じ過程を経る．雲の除去をするために行なった作業を時系列的な変化を追うための作業となるだけである．
- 用意された時系列データをどう分類に役立てるかであるが，年間に4シーン程度の画像から分類する場合と，週ごとのデータある場合とで処理法は異なる．年間4シーン程度のものであれば，シーンごとに分類しておいて，分類結果の変化を見ることで分類項目は向上するであろう．

2. トレンドを見るための時系列処理

- 週ごとのデータがある場合には，トレンドを見ることが出来る．大量データを処理する必要があるため，1シーンごとに分類するには多大な労力と時間がかかる．したがって，ある程度自動的に処理できるデータを用いるのが現実的である．例えば，植生指標や海面温度などは計算も非常にシンプルなので処理に適している．

マイクロ波を利用する1

1. マイクロ波の利点

- 光学センサが大気の影響を受けることは既に述べた．マイクロ波は波長が非常に長いため大気の影響を受けにくい．地球も非常に弱いマイクロ波を放出しており，マイクロ波放射計はその微弱な電波を観測することができる．
- また，センサ自身がマイクロ波を地球に照射し，地面でマイクロ波が散乱して帰ってくる一部（後方散乱）の電波を観測するものもある．これが，いわゆるレーダである．

2. レーダ画像の原理

- 基本的にプラットフォームの進行方向直角（レンジ方向）にマイクロ波を照射し，後方散乱した成分がセンサに戻って来た時間と，その電波の強さによって画像が構成される．
- 地表面が滑らかであれば，後方散乱の成分は少なく鏡面反射に近くなる．一方，地表面が粗くなると，後方散乱の成分は多くなる．したがって，水面では後方散乱が少なく，でこぼこした地表では後方散乱が多くなる．

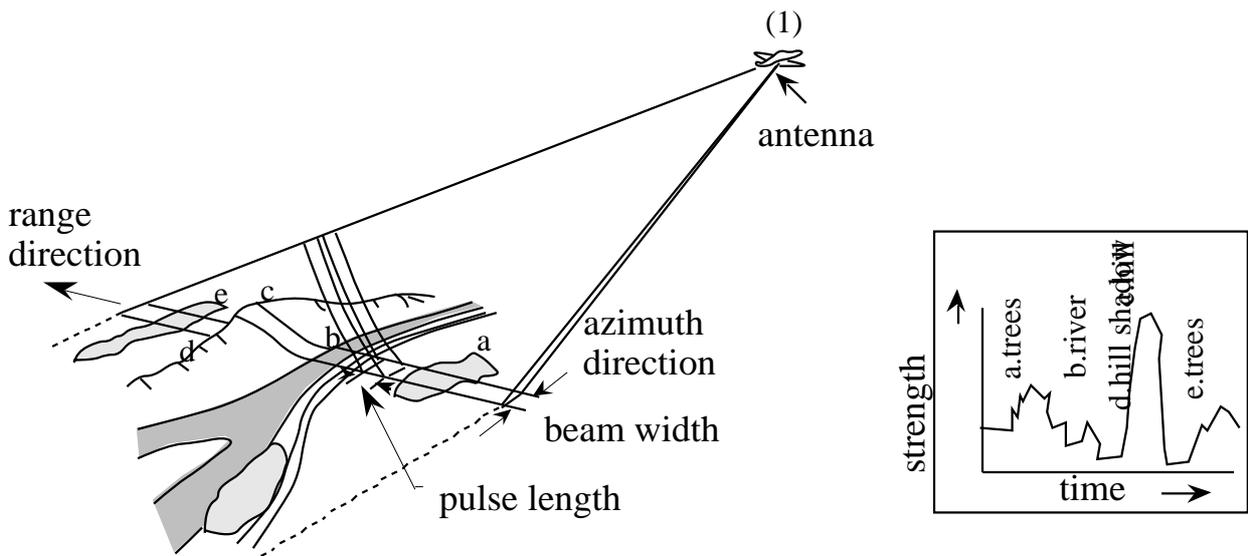


Fig.4.2.1 Side-looking airborne radar operation

マイクロ波を利用する2

1. 合成開口レーダとは

- レンジ方向の空間分解能はパルス幅に依存し，アジマス方向（プラットフォームの進行方向）の空間分解能は，アンテナの大きさに依存する．ところが，プラットフォームの進行に伴うドップラー効果を利用すれば，アンテナの大きさを小さくすることができる．このような仕組みのレーダを合成開口レーダと呼ぶ

2. レーダ画像の幾何学

- レーダ画像は，光学センサとは異なる幾何学を持つ．それは，センサから対象物までの距離（スラントレンジ）を等間隔に横方向に並べたものがピクセル方向の画像となる．これにより地形が複雑であれば，下に挙げるレーダ画像固有の現象が生じる．

+ フォアショートニング

- 通常の斜面に置いては，斜面の長さが短くなる現象

+ レイオーバ

- 非常に標高の高いところだと，斜面が画像に現れず尾根のみが倒れ込んだように描かれる現象

+ レーダシャドウ

- 急峻な地形であれば，山の向こう側がレーダの陰になって現れない現象

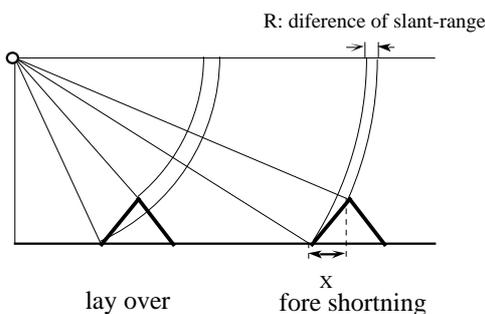


Fig.4.4.3 Fore shortening and lay over

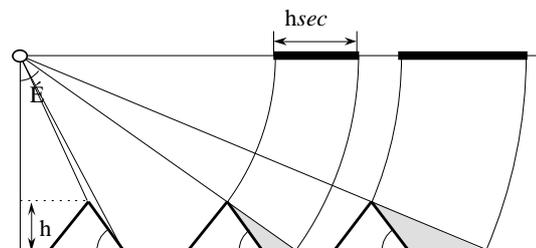


Fig.4.4.4 Radar shadow

マイクロ波を利用する3

1. 合成開口レーダの利用例

- 合成開口レーダは、地表面の粗さのみを見ているに過ぎないので、実際レーダ画像を用いて地上に何があるのかを判断するのは非常に難しい。

+ 時系列データの利用

- 光学センサにおいて時系列データの有用性について述べたが、レーダ画像においても同様である。地表面の変化は、植生の有無等が反映されるためである。

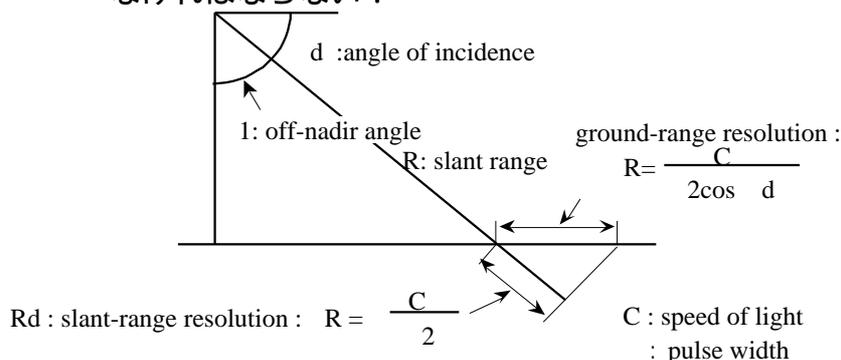
+ マルチバンドデータの利用

+ マイクロ波も様々な波長帯（周波数帯）域を持つ。特に波長が長いほど大気や極薄い植生等を透過して観測できるので、各種波長帯のデータも有効なものとなりうる。

- Lバンド（1-2 GHz）：波浪などが対象
- Sバンド（3-4 GHz）：地質
- Cバンド（4-8 GHz）：土壌水分
- Xバンド（8-12 GHz）：降雨
- Kuバンド（12-18 GHz）：ジオイド
- Kバンド（18-27 GHz）：植生

+ レーダ画像の幾何補正

- 光学センサで用いた中心投影法の幾何学は通用しない。
- 地形が単調な地域においては、スラントレンジの画像をグラウンドレンジ（地上幅）の画像に変換する。スラントレンジとグラウンドレンジとは、余弦関数で表すことができる。
- なお、地形が複雑な地域においては、地形の情報を併用しなければならない。



マイクロ波を利用する4

+ マイクロ波を利用した他のセンサ

+ マイクロ波放射計

- マイクロ波をセンサから照射しない受動センサ .
- 地球の熱放射を計測できる .
- 他のセンサのための大気補正データとしても利用できる .

+ マイクロ波散乱計

- マイクロ波を4方に照射し , 表面より返って来た受信電力を計測する .
- 海上風の風速ベクトルを2次元的に測定可能 .

+ マイクロ波高度計

- センサ直下の地表面との距離を計測する .
- ジオイドの計測
- 海流・波高・潮流の計測