

修士論文の和文要旨

研究科・専攻	大学院 情報理工学研究科 知能機械工学専攻 博士前期課程		
氏名	大野 翔平	学籍番号	1332012
論文題目	多偏波 SAR 画像を用いた自己組織化マップによる自動目標認識法		
要旨	<p>合成開口レーダ(SAR:Synthetic Aperture Radar)は、航空機・衛星にアンテナを搭載し、地表面を観測する画像レーダセンサとして有用とされている。SAR は、マイクロ波を用いることで昼夜・天候に依存しない観測が可能であり、広域かつ高分解能な画像を生成する。しかし、SAR 画像で用いる波長は数 cm 程度であり、光学画像で用いる波長(数百 nm)と大きく異なる。これにより、光学画像と比較して、視覚による目標認識が困難となる。そこで、近年、SAR 画像に対する機械学習等を用いた様々な自動目標認識法(ATR:Automatic Target Recognition)が提案されている。一般に自動目標認識では、前処理として目標領域を抽出する目標領域推定法が必要である。従来の目標領域推定法として PWF(Polarimetric Whitening Filter)が提案されているが、熱雑音のような白色性干渉信号に対しては目標領域推定精度が劣化する。また、従来の自動目標認識法として、ニューラルネットワークなどを用いた手法が提案されているが、雑音や方位方向変化に対してロバストではないという問題点を有する。これに対し、我々は既に、SOM(Self-organizing map)を用いた自動目標認識法を提案しており、分類において U-matrix 基準によるポテンシャル場を評価することで、認識精度の改善を実現した。しかし、同手法は、単一偏波 SAR 画像のみを考慮しており、目標の方位方向誤差に対しては、ロバスト性が不十分であった。一方、複数偏波による散乱データ解析により、目標形状情報の抽出を可能とする研究が多数報告されており、これら多偏波 SAR 画像を自動目標認識に用いることで、その精度向上が期待されている。</p> <p>本論文では、まず目標領域抽出のために、各偏波画像の PSNR(Peak Signal-to-Noise Ratio)より重み付け偏波合成法を提案する。さらに、従来の SOM を用いた目標認識法における入力ベクトルを多偏波 SAR データに拡張する。ここでは、基準 SAR 画像を用いた方位方向補正と円偏波基底変換を導入することで、目標の方位方向誤差に対するロバスト性を向上させる。実験では、X バンドレーダの 100 分の 1 スケールモデルを想定し、5 つの民間航空機模型を多偏波で観測する。まず、実験データより、PSNR による重み付け合成 SAR 画像により、目標領域を高精度に抽出することを示す。さらに、円偏波基底変換を用いた提案法より、従来の単一偏波や直線偏波基底を用いた手法よりも目標認識確率が向上したことを示す。</p>		

平成26年度修士論文

多偏波SAR画像を用いた自己組織化マップによる
自動目標認識法

学籍番号 1332012
氏名 大野 翔平
知能機械工学専攻 高度ITコース
指導教員 桐本 哲郎 教授
副指導教員 稲葉 敬之 教授
提出日 平成27年2月27日

多偏波 SAR 画像を用いた自己組織化マップによる 自動目標認識法

目次

第 1 章	序論	1
1.1	研究背景	1
1.2	目的	2
第 2 章	合成開口レーダ (SAR:Synthetic Aperture Radar)	3
2.1	合成開口レーダの結像処理	3
2.2	多偏波 SAR(PolSAR:Polarimetric SAR)	6
2.2.1	偏波パラメータ	6
2.2.2	散乱行列と基底変換	7
2.2.3	偏波平均化行列	9
2.2.4	四成分散乱分解	10
2.3	従来の SAR 画像における目標領域推定法	13
2.3.1	ポラリメトリックホワイトニングフィルタ	13
2.4	従来の SAR 画像における自動目標認識法	15
2.4.1	レンジプロフィールに基づく自動目標認識法	15
2.4.2	SOM を用いた自動目標認識法	16
第 3 章	多偏波 SAR 画像における目標領域推定法	20
3.1	観測ジオメトリ	20
3.2	偏波合成を用いた目標領域推定法	21
第 4 章	目標領域推定法の性能評価	23
4.1	実験緒元	23
4.2	評価方法	27
4.3	定量評価と考察	29
第 5 章	多偏波 SAR 画像における自動目標認識法	33
5.1	方位方向変化に対する画像の位置合わせ	33
5.2	円偏波基底 PolSAR 画像を用いた自動目標認識法	34
第 6 章	自動目標認識法の性能評価	39

6.1	実験緒元	39
6.2	定量評価と考察	43
6.2.1	方位方向補正性能	43
6.2.2	各基底における方位方向変化の影響	44
6.2.3	目標認識精度	51
第7章	結論	55
	参考文献	56

第1章 序論

1.1 研究背景

レーダ (RADAR:RADio Detection And Ranging) は電波を目標に照射し, 反射波を受信し解析することで, 目標の探知し, 距離・方向の測定を行う. マイクロ波は可視光に比べて波長が長く, 昼夜・天候に依存しない観測を可能とする全天候性を有する. しかし, 一般的なマイクロ波を用いたレーダは, 光学撮像装置と比較し, 分解能が非常に低い. 距離分解能を向上させるため, 従来は送信する電波のパルス幅に左右されていたが, パルス圧縮処理の開発により, 更なる高分解能化が可能となった. また, レーダの方位分解能を向上させるためには, アンテナの実開口長を大きくする必要はあるが, 物理的な限界が生じる. そこで, パルス圧縮処理と仮想的にアンテナ開口長を大きくするアジマス圧縮処理を組み合わせた高分解能なりモートセンシング技術として, 合成開口レーダ (SAR:Synthetic Aperture Radar) が注目されている. SAR はアンテナ装置を衛星や航空機等の移動型プラットフォームに搭載し, アンテナを走査させながら観測を行うことで, 仮想的に大きなアンテナを生成する. 受信信号に対し両圧縮処理を行うことで, 強度と位相情報を含んだ複素 SAR 画像が生成される. 一般的に, SAR 画像は画素毎の強度情報を用いた輝度画像として扱い, 受信機雑音, スペックルノイズ, 背景雑音などの揺らぎを多く有している. 更に, 我々が普段見慣れている光学画像と観測周波数などが大きく異なるため, 視覚的に SAR 画像を理解することは困難とされている. そこで, 近年機械学習などを用いた SAR 画像に対する自動目標認識法 (ATR:Automatic Target Recognition) が多く研究されており, ニューラルネットワーク [1], サポートベクターマシーン (SVM:Support Vector Machine)[2], そして自己組織化マップ (SOM:Self-organizing map)[3] を用いた手法が提案されている. その中でも特に, SOM を用いた自動目標認識法は, U-matrix 法より生成されたポテンシャル場を評価することで, 高精度な目標認識が可能であると報告されている. しかし, 同手法は単一偏波のみしか考慮しておらず, 多偏波データを利用することで更なる精度向上の可能性が期待される.

一方で, 近年, 偏波が目標形状や地表面について重要な情報を持っていることが注目されており, 多偏波 SAR(PolSAR:Polarimetric SAR) 画像を用いた技術開発が盛んに行われている [4]. PolSAR では, 水平偏波と垂直偏波を送受信

素子で切り替え，4つの組み合わせの偏波成分から観測される．この偏波成分は目標の形状に大きく左右され，地震災害時の被害状況把握，都市などの建造物検知や海上治安おける違法船舶の検出など多岐にわたり応用されている．特に，人工物の認識に関して，PolSAR 画像はより多くの目標情報を持つ一方，レーダの入射角，目標の方位方向変化などに対して感度が高く，観測状況や観測対象に適した偏波成分を選択する必要がある．

1.2 目的

本論文では，まず多偏波 SAR 画像において各偏波画像の PSNR(Peak Signal-to-Noise Ratio) で重みづけ合成を行うことで，雑音に対してロバスト性の高い目標領域推定法を提案する．更に，提案法では，従来の SOM に基づく ATR 法を多次元ベクトルを用いて多偏波に拡張し，基準画像を用いた方位方向補正及び円偏波基底変換を用いることで，認識精度の向上を実現する．本手法の有効性を中心周波数を除いた X バンドレーダの 1/100 スケールモデルを想定した実験データを用いた検証により有効性を示す．

第2章 合成開口レーダ (SAR:Synthetic Aperture Radar)

本章では、まず合成開口レーダの原理とその処理手順を示す。次に、SARに関する応用技術として、多偏波 SAR(PolSAR)、目標領域決定法及び認識法に関する先行研究について述べる。

2.1 合成開口レーダの結像処理

本節では地表面観測の画像レーダ技術として、合成開口レーダ (SAR:Synthetic Aperture Radar) の原理とその処理手順について述べる。合成開口レーダは、小型アンテナを衛星や航空機などの移動型プラットフォームに搭載し、アンテナを走査させながら目標の観測を行う。プラットフォーム移動方向をアジマス方向、垂直方向をレンジ方向と呼び、一般的にレンジ方向に電波を照射する。従来の方形パルスを用いたレンジ方向の画像生成方法では、パルス幅を短くするほどレンジ方向に対する空間分解能が向上する。しかし、実際にはパルス幅が無限小かつ出力が無限大のパルス (インパルス信号) を作成することは不可能であり、送信信号の出力が制限され、雑音耐性が劣化するなどの限界がある。同欠点を補う手法として、周波数に変調をかけた長いパルスの信号を相関処理するパルス圧縮技術が開発され、SARにも利用されている [5]。更に SAR では、アジマス方向における分解能向上のために、仮想的にアンテナ開口長を大きくするアジマス圧縮処理を施す。アジマス圧縮処理では、プラットフォームの移動によるアンテナと点散乱体の距離変化を位相補償し、アジマス方向に関して積分処理を行う。両圧縮処理より、レンジ方向及びアジマス方向に対する高分解能化が実現される。以下に、ベクトルネットワークアナライザ (VNA) を用いた実験環境を想定し、その処理手順の詳細を記す。

図 2.1 に点散乱体を観測した SAR のシステムモデルを記す。送信信号として、周波数が時間 t とともに変化する FM(Frequency Modulation) パルスを次式で定義する。

$$s(t) = \exp\{j2\pi(f_c + n\Delta f)t\} \quad \left(n = -\frac{N}{2}, \dots, 0, \dots, \frac{N}{2}\right) \quad (2.1)$$

ここで、 f_c は中心周波数、 Δf は周波数の刻みである。また、アンテナ位置 $(x_k, 0)$

における，目標 m からの反射信号は次式となる．

$$r(k, t) = \sum_{m=1}^M \sigma_m \exp \left\{ j2\pi (f_c + n\Delta f) \left(t - \frac{2R_k(x_m, y_m)}{c} \right) \right\} \quad (2.2)$$

ここで， σ_m は目標の後方断面積， M は目標の総数， c は光速を示す．但し， R_k はアンテナと目標の片道分のスラントレンジ距離を示しており，次式で導出される．

$$R_k(x_m, y_m) = \sqrt{(x_k - x_m)^2 + y_m^2 + z_0^2} \quad (2.3)$$

次に，受信信号 $r(k, t)$ に対して，同期検波を行い，次式の受信信号 $\alpha(k, n)$ を得る．

$$\begin{aligned} \alpha(k, n) &= \sum_m \sigma_m \exp \left\{ -j2\pi (f_c + n\Delta f) \frac{2R_k(x_m, y_m)}{c} \right\} \\ &= \sum_m \sigma_m \exp \left\{ -j\frac{4\pi}{\lambda} R_k(x_m, y_m) \right\} \exp \left\{ -j2\pi (n\Delta f) d_{k,m} \right\} \end{aligned} \quad (2.4)$$

実験環境下において，VNA では，FM パルスの生成から同期検波まで行われ，最終的に得られるデータは，受信信号 $\alpha(k, n)$ である．逆フーリエ変換より，時間領域に変換したレンジプロフィールは次式で定義される．

$$\begin{aligned} \beta(k, \tau) &= \frac{1}{N+1} \sum_{n=-N/2}^{N/2} \alpha(k, n) \exp \left\{ j\frac{2\pi}{N+1} (n\Delta f) \tau \right\} \\ &= \frac{1}{N+1} \sum_{n=-N/2}^{N/2} \exp \left\{ j2\pi n\Delta f \left(\frac{\tau}{N+1} - d_{k,m} \right) \right\} \\ &\quad \times \sum_m \sigma_m \exp \left\{ -j\frac{4\pi}{\lambda} R_k(x_m, y_m) \right\} \\ &\approx \text{sinc} \left\{ \pi B \left(\frac{\tau}{N+1} - d_{k,m} \right) \right\} \sum_m \sigma_m \exp \left\{ -j\frac{4\pi}{\lambda} R_k(x_m, y_m) \right\} \end{aligned} \quad (2.5)$$

ここで， B は帯域幅を示す．但し，パルス圧縮後の分解能は次式で定義される．

$$\Delta Y = \frac{c}{2B\sin\theta} \quad (2.6)$$

以上の処理より，レンジ方向にパルスが圧縮された高分解能な波形を各アンテナ位置毎に取得することができる．

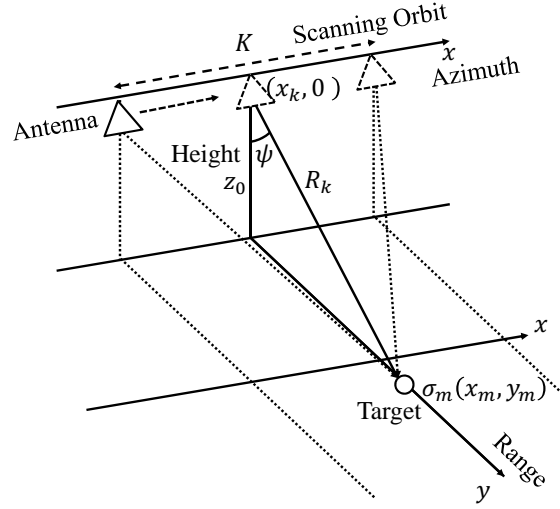


図 2.1: SAR のシステムモデル

次に，得られたレンジプロフィールに対し，位相補償及び積分処理することでアジマス圧縮を行う．次式に，アジマス圧縮後の SAR 画像を示す．

$$\begin{aligned}
 I(x_I, y_I) &= \sum_{k=-K/2}^{K/2} \beta(k, \tau) \exp \left[j \frac{4\pi}{\lambda} \{R_k(x_I, y_I)\} \right] \\
 &= A(x_I, y_I) \exp \left[-j \frac{4\pi}{\lambda} \{R_k(x_m, y_m) - R_k(x_I, y_I)\} \right] \quad (2.7)
 \end{aligned}$$

ただし， $R_k(x_I, y_I)$ は各アンテナ位置から画像座標 (x_I, y_I) の距離を表す．また， $A(x_I, y_I)$ は SAR 画像の強度情報であり，次式で導出される．

$$A(x_I, y_I) = \sum_{k=-K/2}^{K/2} \text{sinc} \left\{ \pi B \left(\frac{\tau}{N+1} - d_{k,m} \right) \right\} \sum_m \sigma_m \quad (2.8)$$

同処理におけるアジマス方向の分解能は次式で定義される

$$\begin{aligned}
 \Delta X &= \frac{\lambda R}{2L_A} \\
 &= L_A/2 \quad (2.9)
 \end{aligned}$$

但し， L_A は合成開口長を表す．以上の処理により，高分解能な画像が取得できる．また，簡単のため時間領域において各圧縮処理を記述したが，処理速度を向上させるため，周波数領域における処理が主流である．

2.2 多偏波 SAR(PolSAR:Polarimetric SAR)

近年 SAR 画像を様々な偏波で観測し，解析を行うことでより多くの情報量を取得できることが確認されている．本節では，研究の基盤となる偏波パラメータ，散乱行列，及び基底変換について説明する．次に，偏波を用いた応用技術として，電力分解法について述べる．

2.2.1 偏波パラメータ

偏波とは，空間のある位置における単一周波数の電波を進行方向の後方から見たときの，電界ベクトル先端の軌跡のことである．この軌跡は，一般的に楕円形で表現され，扁平の極限として直線や円がある．楕円形を表現する方法としては，幾何学パラメータ，ストークスパラメータ，ポワンカレ球などがあるが，本節では直感的な理解が容易な幾何学パラメータの説明を述べる [6]．幾何学パラメータは，サイズ A ，膨らみ角 ε ，傾き角 τ の 3 つのパラメータから構成させる．図 2.2 に，各幾何学パラメータを図示する [6]．ここで， a は楕円の長軸， b は楕円の短軸である．楕円の大きさを表すサイズは $A = \sqrt{a^2 + b^2}$ で計算され， A^2 は電力の大きさである．楕円の膨らみ具合を表す膨らみ角は $\varepsilon = \tan^{-1}(b/a)$ で計算され， $\varepsilon = 0$ で直線， $\varepsilon = \pm\pi/4$ で完全な円となる．楕円の傾きを表す傾き角は，長軸と x 軸のなす角である．各幾何学的パラメータと楕円偏波の関係を図 2.3 に示す [6]．3 つのパラメータで様々な偏波状態を表現できることが分かる．




図 2.2: 偏波の幾何学的パラメータ




図 2.3: 幾何学的パラメータと楕円形状の関係

2.2.2 散乱行列と基底変換

偏波レーダでは，送信アンテナから水平偏波又は垂直偏波の電波を目標に照射し，両偏波のアンテナで散乱波を受信する．送受信アンテナの偏波成分を切り替えることで，4つの偏波の組み合わせから観測することをフルポラリメトリ観測と呼ぶ．フルポラリメトリ観測では，目標の形状情報など含む，偏波散乱特性を取得することができる．モノスタティックレーダで，距離 r 離れた目標に電波を照射したとき，後方散乱電界は次式で定義される．

$$\begin{bmatrix} E_x^s \\ E_y^s \end{bmatrix} = \frac{e^{-jkr}}{\sqrt{8\pi r}} \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \begin{bmatrix} E_x^t \\ E_y^t \end{bmatrix} \quad (2.10)$$

ここで， E は電界， S は偏波散乱特性， t は入射波， s は後方散乱波を示す．また， x, y は $x-y$ 平面における電界の方向を表す．定数項を無視し，偏波特性のみに着目すると，以下の Sinclair 散乱行列が導かれる．

$$[S] = \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \quad (2.11)$$

散乱行列の要素は，複素数であらわれ，互いに独立な量である．但し，モノスタティックレーダでは，相反定理から $S_{xy} = S_{yx}$ となることが知られており，3つの複素数要素となる．以降，本稿では $S_{xy} = S_{yx}$ が成立することを前提とし，記述する．また，直線偏波の場合， $x, y = H, V$ となり， H は水平偏波 (Horizontal polarization)， V は垂直偏波 (Vertical polarization) を表す．

円偏波を送受信する偏波レーダも存在するが，直線偏波アンテナの方が作りやすいなどの理由から一般的に直線偏波による観測が主流である．一方で，基底変換を行うことで，直線偏波で観測した散乱特性を傾けた直線偏波基底や円偏波基底に変換することが可能である．ここでは，直線偏波基底に対する様々な基底変換について記す．まず，一般的に用いられる直線偏波基底を θ 傾けた際の基底変換について述べる．直線偏波アンテナを用いた観測において，受信アンテナに誘起される電圧は次式で定義される．

$$V = \begin{bmatrix} h_x \\ h_y \end{bmatrix}^T \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \begin{bmatrix} E_x^t \\ E_y^t \end{bmatrix} \quad (2.12)$$

但し， E^t は送信電界， h は受信アンテナの方向を示す．ここで，基底を θ 傾け

た場合，基底変換前と電圧は等価となる．よって，次式が成立する．

$$V = \begin{bmatrix} h_{x,\theta} \\ h_{y,\theta} \end{bmatrix}^T \mathbf{Q}^T \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \mathbf{Q} \begin{bmatrix} E_{x,\theta}^t \\ E_{y,\theta}^t \end{bmatrix} \quad (2.13)$$

ここで，添え字 θ は基底変換後の方向成分， T は転置， \mathbf{Q} は回転行列を示す．また，基底変換後の h , E ，及び回転行列 \mathbf{Q} は次式で定義される．

$$\begin{bmatrix} h_x \\ h_y \end{bmatrix} = \mathbf{Q} \begin{bmatrix} h_{x,\theta} \\ h_{y,\theta} \end{bmatrix}, \quad \begin{bmatrix} E_x^t \\ E_y^t \end{bmatrix} = \mathbf{Q} \begin{bmatrix} E_{x,\theta}^t \\ E_{y,\theta}^t \end{bmatrix}, \quad \mathbf{Q} = \begin{bmatrix} \cos(\theta) & \sin(\theta) \\ -\sin(\theta) & \cos(\theta) \end{bmatrix} \quad (2.14)$$

以上より，基底変換後の散乱行列は次式となる．

$$\begin{bmatrix} S_{xx,\theta} & S_{xy,\theta} \\ S_{xy,\theta} & S_{yy,\theta} \end{bmatrix} = \mathbf{Q}^T \begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} \mathbf{Q} \quad (2.15)$$

例えば，目標が H ダイポールであり，目標 (又は送受信アンテナ) が $x - y$ 平面において， $\theta = 90^\circ$ 回転した場合について考える．図 2.4 に回転前後のモデル図を示す．基底変換前と基底変換後の各散乱行列は次式となる．

$$\begin{bmatrix} S_{xx} & S_{xy} \\ S_{xy} & S_{yy} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}, \quad \begin{bmatrix} S_{xx,\theta} & S_{xy,\theta} \\ S_{xy,\theta} & S_{yy,\theta} \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 0 & 1 \end{bmatrix} \quad (2.16)$$

これより，回転前は HH 偏波成分が支配的だとわかるが，回転後は H ダイポールを 90° 傾けているため，V ダイポールを観測したときと同等となる．よって，回転後は VV 偏波成分が支配的となる．また， $\theta = 45^\circ$ の場合は，HH 偏波成分が減少し，HV 偏波成分が増加する．このことから，目標の形状の特徴を偏波散乱行列が有していること，及び座標系の回転により偏波散乱行列が影響を受けることが分かる．

次に，実際の観測では直線偏波が多く使用されるが，直線偏波で観測された偏波成分を円偏波基底に基底変換することができる．基底変換による円偏波基底は次式で導出される．

$$\begin{bmatrix} S_{LL} & S_{LR} \\ S_{RL} & S_{RR} \end{bmatrix} = \frac{1}{2} \begin{bmatrix} 1 & j \\ j & 1 \end{bmatrix} \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \begin{bmatrix} 1 & j \\ j & 1 \end{bmatrix} \quad (2.17)$$

ここで，L は左回り円偏波，R は右回り円偏波を示す．円偏波基底の各要素を

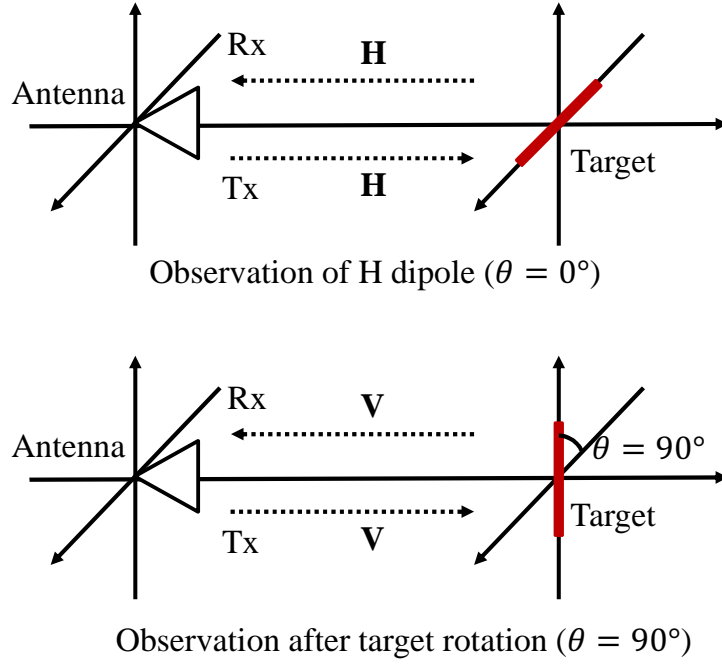


図 2.4: 回転前後における H ダイポールの観測モデル

直線偏波で表すと次式となる .

$$S_{LL} = \frac{1}{2}(S_{HH} - S_{VV} + 2jS_{HV}) \quad (2.18)$$

$$S_{LR} = S_{RL} = \frac{j}{2}(S_{HH} + S_{VV}) \quad (2.19)$$

$$S_{RR} = \frac{1}{2}(S_{VV} - S_{HH} + 2jS_{HV}) \quad (2.20)$$

2.2.3 偏波平均化行列

PolSAR における観測では, $\langle S_{ij}S_{ij}^* \rangle (i, j = H, V)$ のようにデータを平均化する場合が多い . ここで, $*$ は複素共役, $\langle \rangle$ は空間平均を表す . 空間平均をすることで, 空間分解能は低下してしまうが, ノイズに強くなる . 更に, 偏波におけるデータ解析では, エントロピーや偏波相関係数などの統計量を扱うことが多いため, データの平均化は利便性が高いといえる . データの平均化行列としては, Covariance 行列, Coherency 行列, Kennaugh 行列などが存在するが, 今回は平均化 Covariance 行列について記す . 直線偏波基底における平均化 Covariance 行列は次式で定義される .

$$[C] = \begin{bmatrix} \langle S_{HH}S_{HH}^* \rangle & \sqrt{2}\langle S_{HH}S_{HV}^* \rangle & \langle S_{HH}S_{VV}^* \rangle \\ \sqrt{2}\langle S_{HV}S_{HH}^* \rangle & 2\langle S_{HV}S_{HV}^* \rangle & \sqrt{2}\langle S_{HV}S_{VV}^* \rangle \\ \langle S_{VV}S_{HH}^* \rangle & \sqrt{2}\langle S_{VV}S_{HV}^* \rangle & \langle S_{VV}S_{VV}^* \rangle \end{bmatrix} \quad (2.21)$$





図 2.6: 体積散乱のモデル行列

Covariance 行列を用いることで、集合平均された空間の支配的な電力が分かり、その集合体は何で構成されているかの判別などに有効である。Covariance 行列の固有値は電力に対応しており、固有値解析を行うことで、エントロピーやアルファ角を求め、領域の識別・分類に応用されている。また、電力分解法の元となっており、様々な電力に分解する際に基盤となる行列である。

2.2.4 四成分散乱分解

前節より、偏波が目標物やその形状などに対し、特有の散乱メカニズムを持っていると予想できる。ここでは、実験的事実を元に、散乱メカニズムを構築し、対応したモデル行列にフィッティングすることで、散乱電力を分解する四成分散乱分解 [7] について記す。四成分散乱分解では、以下の 4 つの代表的な散乱モデルに電力分解する。

- 表面散乱 (P_s) : 地表面や海面などで生じる電波が 1 回 (奇数回) 反射するモデル

R:HH G:HV B:VV




PolSAR image

R:Pd G:Pv B:Ps



Three-component scattering decomposition

R:Pd G:Pv B:Ps



Four-component scattering decomposition

図 2.7: 各電力の RGB 画像 (新潟市鳥屋野潟周辺)
出所) 第 490 回電波研連 F 分科会 2004 年 12 月

2.3 従来の SAR 画像における目標領域推定法

本章では，従来法として目標領域推定法として，ポラリメトリックホワイトニングフィルタ (PWF: Polarimetric Whitening Filter) について記す．

2.3.1 ポラリメトリックホワイトニングフィルタ

SAR 画像は受信機雑音，背景雑音，スペckルノイズなど様々な雑音を有しており，光学画像よりも視覚的に目標を検知することは難しい．そこで，それらのノイズ成分を除去する技術は必要不可欠であり，目標領域推定技術として研究されている．本節では，偏波特性を用いることで，スペckルノイズの揺らぎを低減させ，目標領域推定手法として有用とされている PWF[9] について記す．スペckルノイズとは，コヒーレント系の信号が持つ特有の揺らぎであり，次式でスペckルノイズ量を定義する．

$$\frac{s}{m} = \frac{\text{st}(y)}{\text{mean}(y)} \quad (2.23)$$

ここで，分子は標準偏差，分母は平均値を示す． y はフルポラリメトリ観測で得られた各偏波成分の総電力を示しており，次式で定義される．

$$y = \begin{bmatrix} S_{HH} \\ S_{HV} \\ S_{VV} \end{bmatrix}^T \mathbf{A} \begin{bmatrix} S_{HH} \\ S_{HV} \\ S_{VV} \end{bmatrix} \quad (2.24)$$

ここで， $S_{i,j=H,V}$ は ij 偏波成分における観測値であり，複素数で表される．また， \mathbf{A} は重み行列を表している．PWF では， s/m が最小化されるような重み行列 \mathbf{A} を導出することで，スペckルノイズを低減する．式 (2.23) を解いていくと，重み行列は Covariance 行列の逆行列となる．よって，PWF による電力値は次式となる．

$$y = \left(|S_{HH}|^2 + \left| \frac{S_{HH}}{\sqrt{e}} \right|^2 + \left| \frac{S_{VV} - r^* \sqrt{g} S_{HH}}{\sqrt{g(1-|r|^2)}} \right|^2 \right) / 3 \quad (2.25)$$

但し， e, g は電力比， r は偏波相関係数であり，次式で定義される．

$$e = \frac{\langle |S_{HV}|^2 \rangle}{\langle |S_{HH}|^2 \rangle} \quad (2.26)$$

$$g = \frac{\langle |S_{VV}|^2 \rangle}{\langle |S_{HH}|^2 \rangle} \quad (2.27)$$

$$r = \frac{\langle S_{HH} \rangle \langle S_{VV}^* \rangle}{\sqrt{\langle S_{HH} \rangle \langle S_{HH}^* \rangle} \sqrt{\langle S_{VV} \rangle \langle S_{VV}^* \rangle}} \quad (2.28)$$



HH polarization image



Result of PWF

図 2.8: 海岸における船舶の PiSAR 画像

出所) IEEE. IGARSS, vol 3, pp 1190-1193, Jul, 2008.

また、同処理における重み付けは、偏波特性を白色化したこと同義であるため、ホワイトニングフィルタと呼ばれる。実際に、PolSAR 画像において PWF を適用した画像を図 4.7 に示す。これは海岸に船舶が移動中の SAR 画像であり、左側が HH 偏波、右側が PWF を適用した出力画像である。図 2.8 より、スペックルノイズがかなり低減され、船舶の検出が可能であることが分かる。しかし、同手法では、偏波特性を無相関化することでスペックルノイズを低減しているが、相関のある目標信号も低減する問題点がある。

2.4 従来の SAR 画像における自動目標認識法

本章では、従来法の自動目標認識として、レンジプロフィールを用いた手法及び自己組織化マップ (SOM: Self-Organizing Map) を用いた手法について述べる。

2.4.1 レンジプロフィールに基づく自動目標認識法

従来の目標認識法として、目標のレンジプロフィールから目標の特徴量を抽出し、自動認識を行う手法が提案されている。[10] レンジプロフィールとは、目標回転角度毎やアンテナ位置毎の受信信号である。図 2.9 に、船のレンジプロフィールの概略図を示す。横軸は、船舶中心を基準とした距離、縦軸は反射電力を示す。図より、目標の輪郭情報を有していることが分かる。本手法では、目標を船と想定しており、強い反射が期待される HH と VV 偏波成分を使用する。HH, VV 偏波より観測されたレンジプロフィールより、以下の特徴量を抽出する。

- 側面の距離 (L) : 一定の閾値以上の始点と終点の差。
- 質量の中心 (M) : 範囲内の点を 0 から 1 に正規化し、質量中心を 0 と 1 の間で算出。
- ピークの数 (P) : 散乱体をカウントし、局所的なピーク数を識別。
- ピーク間距離 (DPK) : 2 つの最大ピーク間における距離。




図 2.9: 船舶のレンジプロフィールの概要

- ピークと端の距離 (DEP) : 最大ピーク位置と短い方の端の間の距離 .

上記の合計 10 個の指標を特徴量とする . 分類過程においては , ベイズ分類器 , 最近隣分析 , ニューラルネットワークを組み合わせた手法 [11] を用いて , 分類・認識を行う . しかし , 本手法は , 強いノイズ環境下や方位方向誤差において , 認識精度の劣化が生じる . ノイズ環境下においては , ピーク位置や数が大きく変化する可能性がある . 上記の特徴量より , ピーク位置や数は重要な特徴と捉えており , 特に最大ピークが変化してしまうと大きな精度劣化の原因となる . また , 目標の方位方向角度に誤差がある場合 , 全体的なレンジプロフィールのずれが生じ , 認識精度の劣化に繋がる .

2.4.2 SOM を用いた自動目標認識法

上記の問題に対して , 私たちは既に SOM を用いた自動目標認識法を提案している . 本手法では , 教師あり SOM と U-matrix 法に基づく分類法を導入することで , 雑音環境下においても高精度な目標認識を可能とする . 本手法は , SOM に教師画像を学習させる学習過程と未知画像のクラスを分類する分類過程から構成される . まず , 学習過程について記す . 本研究では , 雑音領域を除去するため , 大津の判別分析法 [14] より , SAR 画像を閾値処理する . 大津の判別分析法では , SAR 画像中の輝度と画素数のヒストグラムを作成し , 輝度の低い雑音領域と輝度の高い目標領域のクラスに分類する . 閾値処理後の SAR 画像を次式で定義する .

$$I(x, y) = \begin{cases} P(x, y) & (P(x, y) \geq I_{th}), \\ 0 & (\text{Otherwise}), \end{cases} \quad (2.29)$$

但し , $P(x, y)$ は SAR 画像の電力を示し , I_{th} は大津の判別分析法より求まる閾値である .

SOM の学習過程では , SNR 値が高い SAR 画像を教師画像として , SOM に入力する . 本研究において , SOM の出力層は二次元平面に配置された複数のノードから構成されており , マップの大きさを $M_x \times M_y$ とする . 閾値処理後の正規化された SAR 画像を次式で定義する .

$$\mathbf{x} = [\hat{I}(x_1, y_1), \dots, \hat{I}(x_1, y_{N_y-1}), \hat{I}(x_2, y_1), \dots, \hat{I}(x_2, y_{N_y-1}), \quad (2.30)$$

$$\dots, \hat{I}(x_{N_x-1}, y_1), \dots, \hat{I}(x_{N_x-1}, y_{N_y-1})] \quad (2.31)$$

$$\hat{I}(x, y) = \frac{I(x, y)}{\max_{x, y \in \Omega} I(x, y)} \quad (2.32)$$

Ω は SAR 画像中の全領域, N_x, N_y は SAR 画像の x, y 方向における画素数を示す．ここで, 教師画像は $\mathbf{x}_k^{\text{tr}}, (k = 1, 2, \dots, N_{\text{tr}})$ と表され, N_{tr} は教師画像の総数を示す．まず, 次式の線形結合を用いて出力層を初期化する．

$$\mathbf{y}(\mathbf{p}; t = 1) = \frac{\sum_{k=1}^{N_{\text{tr}}} a_k(\mathbf{p}) \mathbf{x}_k^{\text{tr}}}{\sum_{k=1}^{N_{\text{tr}}} a_k(\mathbf{p})}, \quad (2.33)$$

\mathbf{y} は出力層のデータ, \mathbf{p} はノード位置, t は学習回数, a_k は $[0 \ 1]$ の一様乱数を示す．一般的な SOM の初期化方法として, 処理速度向上のために主成分分析に基づく手法も提案されているが, 線形結合による手法でも十分な処理速度となるため, 本研究では, より簡単な線形結合を用いた．次に, 出力層に対し, 各教師画像と最も類似性が高いノードをユークリッドノルムより抽出し, 勝者ノードを選択する．次式より, 勝者ノード $\hat{\mathbf{p}}_k(t)$ を得る．

$$\hat{\mathbf{p}}_k(t) = \arg \min_{\mathbf{p} \in \mathbf{M}} \left\| \mathbf{y}(\mathbf{p}; t) - \mathbf{x}_k^{\text{tr}} \right\| \quad (2.34)$$

\mathbf{M} はマップの全領域, $\|*\|$ はユークリッドノルムを示す．選択された勝者ノードとその近傍にあるノードに対して, 教師画像を写像し, 活性化させる．更新則を次式で定義する．

$$\begin{aligned} \mathbf{y}(\mathbf{p}; t + 1) &= \mathbf{y}(\mathbf{p}; t) \\ &+ \beta(t) \frac{\sum_{k=1}^{N_{\text{tr}}} h(\hat{\mathbf{p}}_k(t), \mathbf{p}) (\mathbf{x}_k^{\text{tr}} - \mathbf{y}(\mathbf{p}; t))}{\sum_{k=1}^{N_{\text{tr}}} h(\hat{\mathbf{p}}_k(t), \mathbf{p})}, \end{aligned} \quad (2.35)$$

但し, $h(\hat{\mathbf{p}}_k(t), \mathbf{p})$ は活性化関数であり, 次式となる．

$$h(\hat{\mathbf{p}}_k(t), \mathbf{p}) = \exp \left(-\frac{|\hat{\mathbf{p}}_k(t) - \mathbf{p}|}{2\sigma(t)^2} \right) \quad (2.36)$$

ここで, $\beta(t), \sigma(t)$ はそれぞれ学習率と近傍領域に寄与する関数であり, 単調減少関数となる．

本手法における SOM は, 一括学習型 SOM (BLSOM: Batch Learning SOM) [15] と周期構造型 SOM (Torus SOM) [16] を導入している．一括学習型 SOM は, 更新則を適用する際に, 一括で教師画像を学習することで, 教師画像の学習順に依存しない安定した SOM を生成可能である．また, 基本的な SOM では, 学習を繰り返すことで教師画像の勝者ノードがマップの隅に追いやられてしまう．同問題点に対して, 周期構造型 SOM では, 出力層の上下左右を仮想的に連結

する。

次に、分類過程について記す。分類過程では、生成した SOM に対して未知画像を入力し、U-matrix 法 [17] より生成されたポテンシャル場を経路積分することで、評価する。学習を終えて SOM に対して、未知画像の勝者ノードを抽出する。

$$\hat{p}(t) = \arg \min_{p \in M} \|\mathbf{y}(p; T_{\text{som}}) - \mathbf{x}\| \quad (2.37)$$

T_{som} は総学習回数、 \mathbf{x} は未知画像を示す。学習過程において、勝者ノードを選択し近傍ノードを活性化するとき、近傍ノードは訓練画像との距離で決定されるのではなく、勝者ノードとのマップ上での結合関係の距離で選ばれる。これより、マップ上の単純な距離における分類では、未知画像と生成された SOM の類似性を十分に考慮できていない。そこで、本手法では、U-matrix 法を適用することで、より正確な分類を可能にする。U-matrix 法は、隣接するノードの距離情報を元に、ノード間の類似性をポテンシャル場として得ることができる。U-matrix フィールド上における未知画像の分類を次式で定義する。

$$R_k^{\text{som}} = \min_{C(\mathbf{x}_k^{\text{tr}}, \mathbf{x})} \int_{C(\mathbf{x}_k^{\text{tr}}, \mathbf{x})} U(\mathbf{p}) d\mathbf{p}, \quad (2.38)$$

\mathbf{p} は U-matrix フィールド上の位置、 $C(\mathbf{x}_k^{\text{tr}}, \mathbf{x})$ は未知画像の勝者ノード \mathbf{p} と教師画像の勝者ノード $\mathbf{p}_k(T_{\text{som}})$ 間の全てのマンハッタン距離を示す。但し、式 (2.38) における経路積分は、A-star 法 [12] より算出される。A-star 法は、最短経路探索法の 1 種であり、確実かつ高速に最短経路を導くことができる。これより、全探索などよりも計算量が大幅に削減され、大規模な SOM マップに対しても適用可能である。以上より、未知画像 \mathbf{x} は、全ての教師画像との最短経路積分値 R_k^{som} を算出し、 R_k^{som} が最小値となる k 番目の教師画像 \mathbf{x}_k^{tr} へと分類される。

次に、本手法の手順を示す。

学習過程

- 手順 1). 乱数を用いた線形結合より、初期マップ $\mathbf{y}(p; 1)$ を生成する。
- 手順 2). マップに対して、各教師画像 \mathbf{x}_k^{tr} の勝者ノード $\hat{p}_k(t)$ を選択する。
- 手順 3). 手順 2 の操作を教師画像の数 N_{tr} 行い、全教師画像の勝者ノードとその近傍に一括で更新則を適用する。

手順 4). 手順 2,3 の学習を T_{som} 回繰り返す、SOM マップを生成する。

分類過程

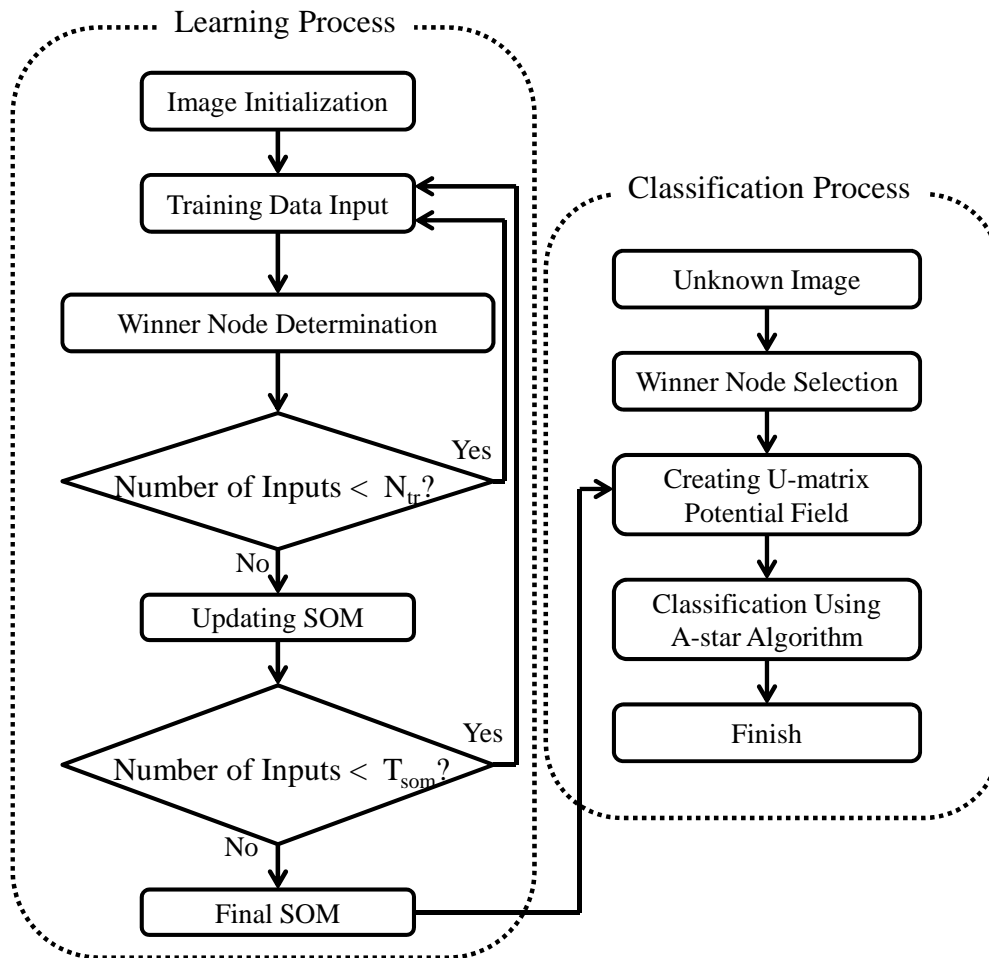


図 2.10: SOM を用いた自動目標認識法のフローチャート

手順 5). 生成された SOM $y(p; T_{\text{som}})$ に対して, U-matrix 法を適用し, U-matrix フィールド $U(p)$ を生成する.

手順 6). 未知画像の勝者ノード p を抽出し, 各教師画像の勝者ノード x_k^{tr} との経路積分値 R_k^{som} を算出する. 但し, 高速化のため A* アルゴリズムを用いた経路探索を行う.

手順 7). 経路積分値 R_k^{som} が最小となる k 番目の教師画像に, 未知画像を分類する.

しかし, 本手法は, 方位方向誤差に対するロバスト性が不十分であり, 多偏波 SAR 画像を本手法に発展させることで, 更なる認識精度向上が期待される.

第3章 多偏波SAR画像における目標領域推定法

本稿の主題となる自動目標認識法では、目標の認識及び分類を行う。しかし、前章で述べたように、SAR画像はノイズ成分を多く含むため、目標領域推定法の検出精度が目標認識法における認識精度を左右する可能性がある。そのため、前処理における検出精度の向上は、重要な課題といえる。本章では、従来の目標領域推定法における問題を解決するため、四成分散乱分解法及びPSNRによる重み付け偏波合成を用いた目標領域推定法について述べる。

3.1 観測ジオメトリ

図3.1に、本手法における観測ジオメトリを示す。モノスタティックレーダを想定しており、送受信アンテナを $y = y_0, z = z_0$ に設置する。アンテナを x 軸方向に直線走査し、目標に向けて電波を照射する。オフナディア角 ψ 、目標の方位方向角度を ϕ とする。本研究では、目標を航空機と想定しており、 $z = 0$ に目標を設置する。




図 3.1: 観測ジオメトリ

3.2 偏波合成を用いた目標領域推定法

偏波を用いた目標領域推定手法として、前章の PWF が提案されている。同手法は、偏波特性を無相関化することで、スペックルノイズを低減しているが、相関のある目標信号までも低減してしまう可能性がある。そこで、提案法では目標信号を多く含む偏波成分のみ抽出し、雑音に支配されやすい偏波成分を抑圧する必要がある。本節では、四成分散乱分解に基づく手法と PSNR 重みづけを用いた手法を提案する。まず、四成分散乱分解に基づく目標領域推定法について述べる。本研究で用いる目標は航空機を想定している。そこで、目標信号を多く含む電力は、航空機の表面から生じる表面散乱、地面と航空機や航空機の部位間に生じる 2 回散乱が支配的であると考えられる。一方で、体積散乱は森林などから、ヘリックス散乱は複数の建造物の集合などから強く反射されるため、今回の目標では電力が小さい。この理論より、四成分散乱分解により電力分解が正確に行われれば、航空機などの人工物検出に有効だと考えられる。次式より、四成分散乱分解による特徴量を定義する。

$$P(x, y) = P_s + P_d \quad (3.1)$$

ここで、 P_s は表面散乱、 P_d は 2 回散乱を示し、各電力は 2.2.5 節で述べた四成分散乱分解より算出される。

次に、PSNR 重みづけ合成を用いた目標領域推定法について示す。各偏波画像は、一般的に目標信号がノイズ成分よりも高いため、単純に加算合成するだけでも、単一偏波より目標信号が強調される。一方、観測目標によって、支配的な偏波成分が異なることが知られている。例えば、直線偏波基底において、人工物であれば HH 偏波や VV 偏波、草木であれば HV 偏波が支配的である。そこで、本手法は、PSNR で目標信号のノイズに対する比を求め、偏波の重み付け合成を行う。本手法における重み付け偏波合成画像を次式で定義する。

$$P(x, y) = \hat{\sigma}_{HH} \langle |S_{HH}|^2 \rangle + 2\hat{\sigma}_{HV} \langle |S_{HV}|^2 \rangle + \hat{\sigma}_{VV} \langle |S_{VV}|^2 \rangle \quad (3.2)$$

$\hat{\sigma}_{ij} (i, j = H, V)$ は正規化された重みであり、次式となる。

$$\hat{\sigma}_{ij} = \frac{\sigma_{ij}}{\sigma_{HH} + 2\sigma_{HV} + \sigma_{VV}} \quad (3.3)$$

$$\sigma_{ij} = \frac{\max_{x,y \in \Omega} \langle S_{ij}(x, y) S_{ij}^*(x, y) \rangle}{\max_{x,y \in \Omega_N} \langle S_{ij}(x, y) S_{ij}^*(x, y) \rangle} \quad (3.4)$$

σ_{ij} は各偏波画像毎の PSNR を示しており, Ω は SAR 画像の全領域, Ω_N は SAR 画像の目標信号以外の領域, $\langle * \rangle$ は空間平均である. HV 偏波成分に関しては, 2 の係数が付いているが, これは VH 偏波成分を含めた, 4 偏波を考慮しているためである. 上記の PSNR を指標とした重みづけは, 目標毎に適した電力を適応的に選択する. そのため, 前節の手法とは異なり, 目標が航空機という前提がなくても有効である.

第4章 目標領域推定法の性能評価

本章では，2章で述べた従来の目標領域推定法及び3章で述べた提案する目標領域推定法の目標領域推定精度を実験データを用いて評価する．

4.1 実験緒元

本節では，SAR 画像取得のための実験諸元を示す．実験における実際の実験風景を 4.1 に示す．実験は電波暗室で行い，余計な反射を防ぐために，周囲を電波吸収体で覆っている．本実験では，中心周波数を除いた X バンドレーダの 100 分の 1 モデルを想定しており，オフナディア角 $\psi = 65^\circ$ ，アンテナの高さを 1.14m，周波数掃引を 26GHz から 40GHz とする．アンテナを x 軸方向に直線走査し，合成開口長 1.6m において，200 点の観測点上で電波を送受信する．ここで，空間分解能は，レンジ方向に 1.18cm，アジマス方向に 1.25cm である．送信信号の生成及び受信信号の取得には VNA を用いており，レーダ装置の概要を図 4.2 に示す．図のように，送信側に 20dB の増幅器を用いる．図 4.3 に，目標となる 5 つの民間航空機模型 (B747, B787, B777, DC10, A320) の光学画像を示す．但し，各目標は金属スプレーを用いて，反射強度を増幅させている．アジマステーブルを用いて目標の方位方向を変化させており，目標のアジマス方向角度を ϕ とする．また，直線偏波アンテナの向きを送受信で，水平偏波及

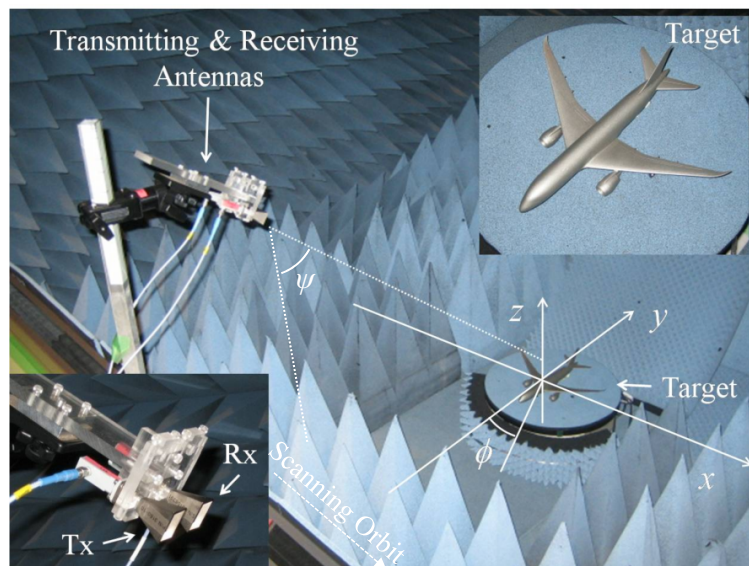


図 4.1: 実験風景

表 4.1: 各偏波の PSNR

	B747	B787	B777	DC10	A320	AVE
HH	35.1 [dB]	27.7 [dB]	30.6 [dB]	33.9 [dB]	28.8 [dB]	31.2 [dB]
VV	36.0 [dB]	27.4 [dB]	28.9 [dB]	32.2 [dB]	26.0 [dB]	30.1 [dB]
HV	30.2 [dB]	30.6 [dB]	30.4 [dB]	35.7 [dB]	33.2 [dB]	32.0 [dB]

表 4.2: 各偏波の P_N/P_R 値

	AVE
HH	30.4 [dB]
VV	30.5 [dB]
HV	20.8 [dB]

び垂直偏波に切り替えることで、フルポラリメトリ観測を行う。それぞれの受信信号対し、Back Projection 法 [13] を施し、複素 SAR 画像 $S_{ij}(i, j = H, V)$ を生成する。

図 4.4 に、実験で取得した VV 偏波の SAR 画像を示す。各機体毎に、SAR 画像が異なっており、エンジン部分やコックピット部分などの特徴が出ていることが分かる。次に、取得された SAR 画像の PSNR を計測する。PSNR を次式で定義する。

$$\text{PSNR} = 10 \log_{10} \frac{P_S}{P_N} \quad (4.1)$$

P_S は目標信号の最大電力、 P_N は SAR 画像中の目標信号以外の平均電力を示す。表 4.1 に、各偏波における各機体の PSNR とその平均値を示す。一般的に人工物に対して HV 偏波の目標信号は低いことが知られているが、全偏波において PSNR の変化があまり見られない。これは、 P_N が背景雑音と受信機雑音の両方を含んでいるからである。受信機雑音としてケーブル内における平均雑音電力を P_R とし、式 (4.1) と同様に、 P_N/P_R を求めると表 4.2 のようになる。これより、背景雑音は受信機雑音と比べて大きく、HV 偏波では目標信号も低下しているが、背景雑音も低下していることが分かる。

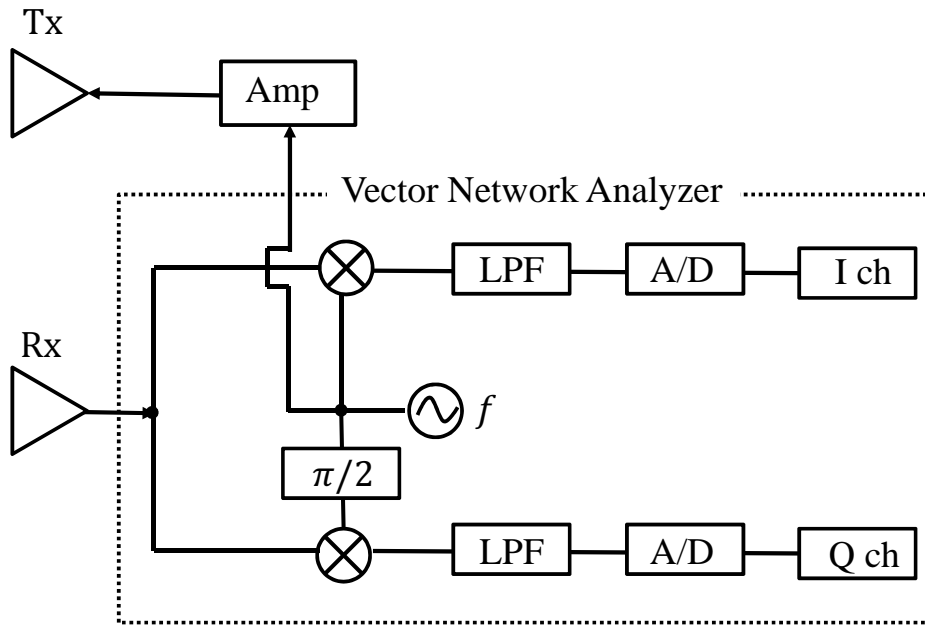


図 4.2: レーダ装置の概要







図 4.3: 目標の光学画像




B747




B787



B777



DC10



A320

図 4.4: VV 偏波の SAR 画像

4.2 評価方法

本節では、各特徴量において雑音に対する目標抽出精度を評価する。評価指標用いる、検出確率 P_D と誤警報確率 P_{FA} を以下の手順で算出する。

手順 1). 各特徴量における SAR 画像に大津の判別分析法 [14] を適用し、閾値以上の領域を真の目標領域、閾値以下の領域を真の雑音領域と定義する。ただし、SAR 画像は十分に PSNR が高いものを用いる。

手順 2). 図 4.5 のように、観測信号に白色複素ガウス雑音を付加し、低 PSNR の SAR 画像を生成する。

手順 3). 雑音が付加された SAR 画像の各領域において、輝度値と画素数のヒストグラムを作成する。

手順 4). ヒストグラム上で閾値を移動させ、目標領域で閾値以上の確率を検出確率 P_D 、雑音領域で閾値以上の確率を誤警報確率 P_{FA} を算出する。

図 4.6 に評価方法の概要を示す。観測信号に対し、数値的に白色複素ガウス分布の加法性ノイズを付加させることで、熱雑音や受信機雑音などを模擬している。ノイズの種類としては、他にもスッペクルノイズなどが上げられるが、人工物においてスッペクルノイズの分布を模擬するのは困難であるため、加法性ノイズのみを付加した。また、前節の表 4.2 より、実験において観測信号に多くの背景雑音も付加されていることがわかる。図 4.5 のように、周波数領域において加法性ノイズを付加している。また、ノイズは、各偏波画像に対して、大きさが等しく、ノイズパターンが異なる雑音を付加している。

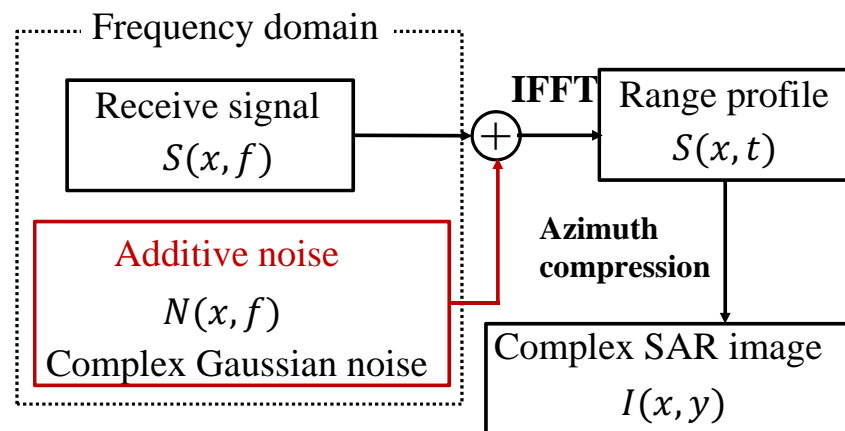


図 4.5: 雑音付加のモデル

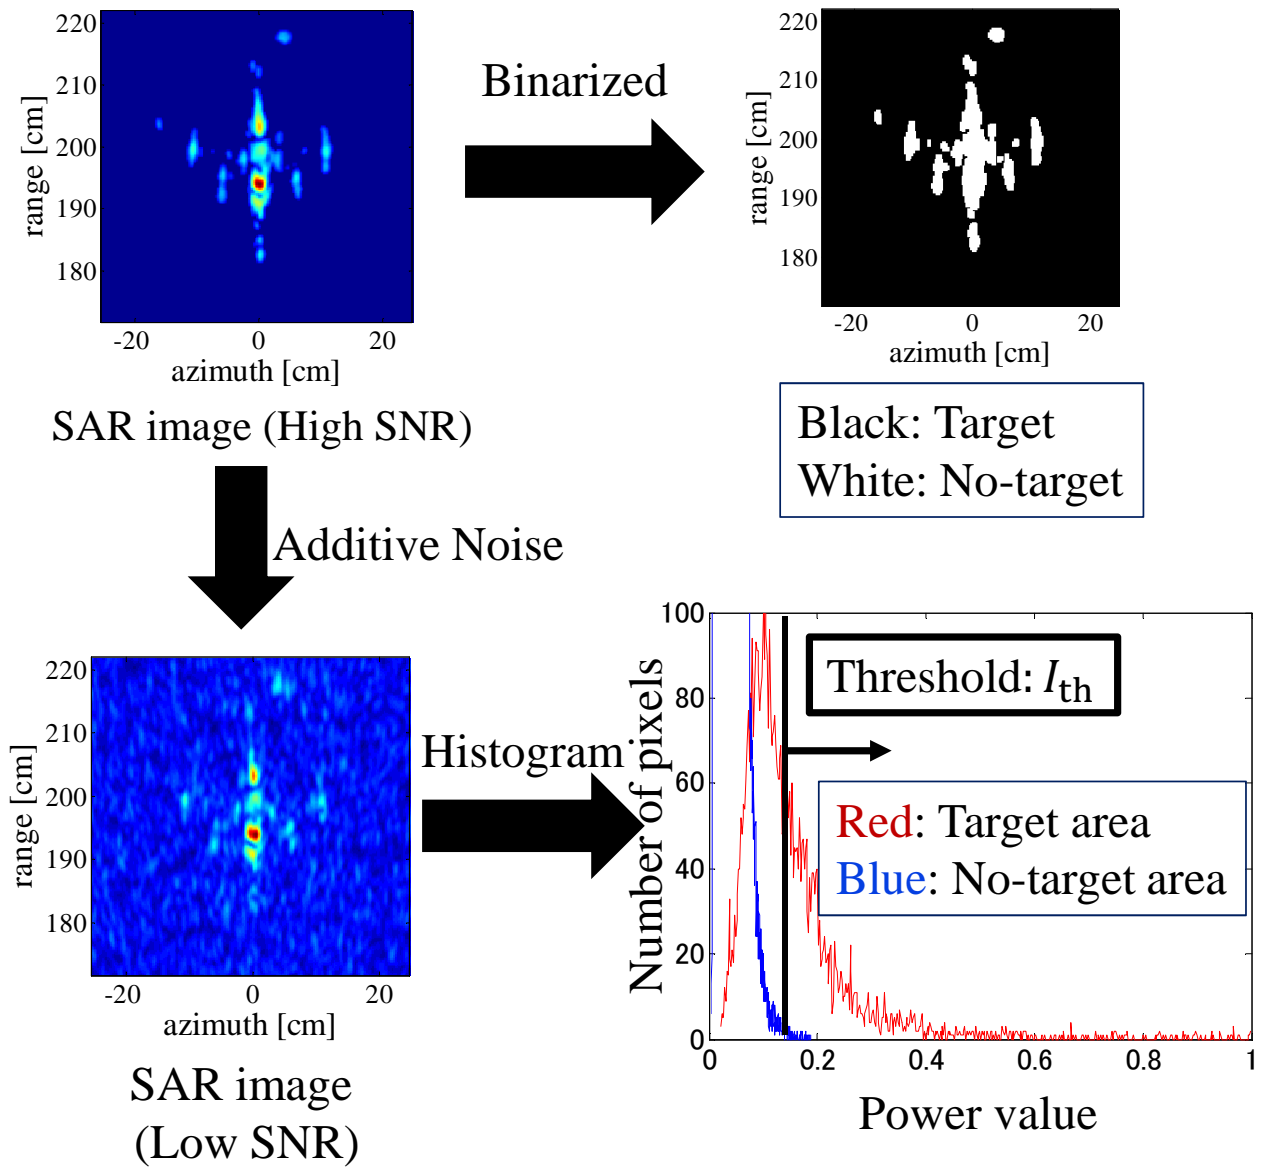


図 4.6: 評価方法の概要

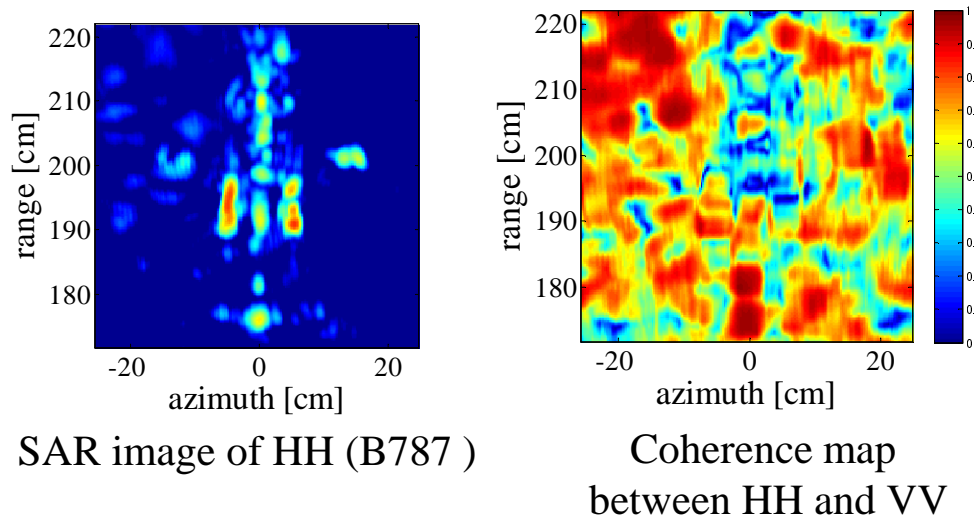


図 4.7: B787 の SAR 画像とコヒーレンス関数

4.3 定量評価と考察

前節の評価方法より，各 PSNR 毎において P_D ， P_{FA} を求める．図 4.8 に，各 P_{FA} における PSNR と検出確率 P_D の関係を示す．但し， P_D はノイズパターンの試行回数を 5 回とし，全機体において平均化した値である．また，横軸の PSNR は，全偏波及び全機体の平均値である．特徴量として，各単一偏波，PWF，四成分散乱分解に基づく手法，PSNR 重み付けを用いた手法を評価した．図より，HV 偏波の検出確率が PSNR の低下により著しく劣化していることが分かる．これは，HV 偏波は人工物に対して反射強度が低いため，ノイズの影響を受けやすいからである．一方で，従来法である PWF については，偏波特性に相関ある目標信号を抑圧することで，検出精度の劣化を招いていることが分かる．例として，図 4.7 に，B787 の HH 偏波画像及び HH 偏波と VV 偏波のコヒーレンス関数を記す．図より，右エンジン部分や胴体の一部において，HH 偏波と VV 偏波の相関が強いことが分かる．PWF では，式 (2.25) より，HH 偏波と VV 偏波の相関値が高い箇所を減少させるため，目標信号も抑圧してしまう．また，四成分散乱分解について，人工物は表面散乱と 2 回散乱が支配的であると考え，その和を特徴量とした．しかし，四成分散乱分解では，非線形的に散乱のモデル行列を切り替えているため，強い雑音により，電力分解が正確に行われな可能性がある．これにより，雑音付加の前後で電力分解が異なり，検出精度が劣化しているのだと考えられる．一方で，提案法では，PSNR の低下に対して，検出確率が他の手法よりも向上していることが分かる．これは，偏波画像間にお

ける PSNR の重みづけを行うことで、雑音に支配されやすい偏波画像の比率を抑圧しているからである。また、図 4.9 に、目標の方位角度 $\phi = 15^\circ$ における、PSNR と検出確率 P_D の関係を示す。各特徴量において検出確率の優劣が前後している箇所がある。これは、目標の方位方向変化により、支配的な偏波成分が変化するためである。しかし、提案法では、PSNR に基づき適応的に雑音に支配されにくい重みを選択するため、全ての PSNR 及び P_{FA} において、優位性を保持できる。



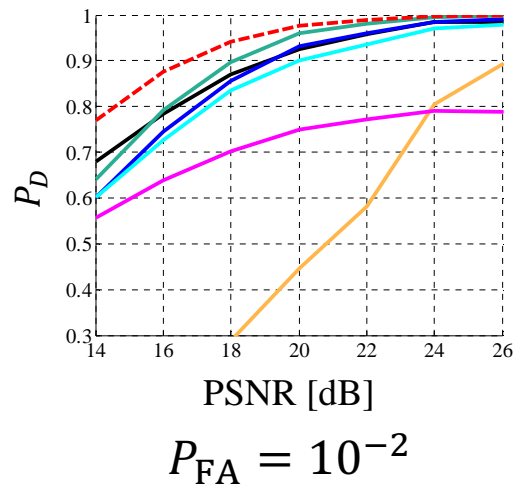




図 4.8: PSNR と検出確率の関係 ($\phi = 0^\circ$)


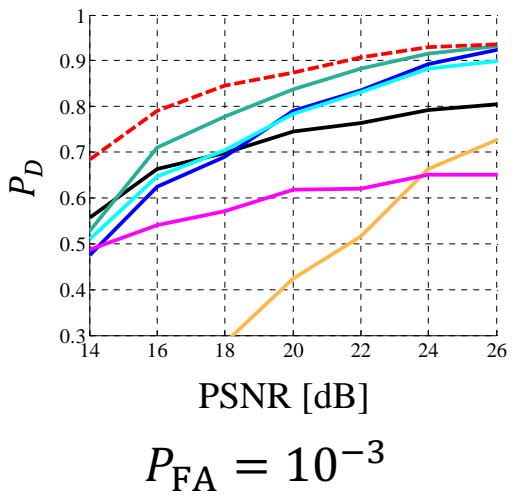
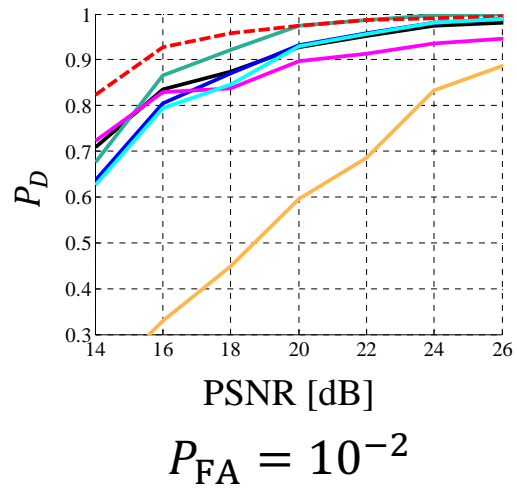

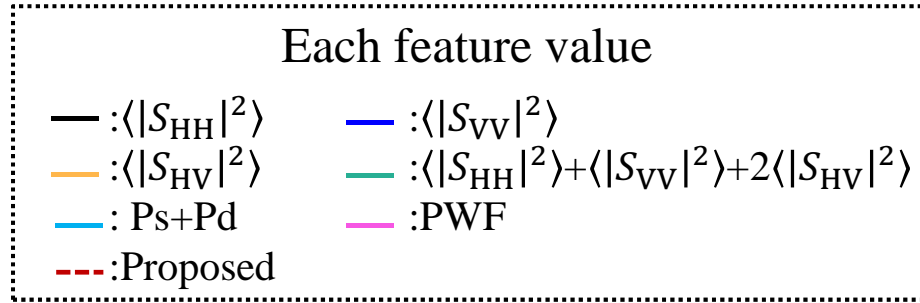


図 4.9: PSNR と検出確率の関係 ($\phi = 15^\circ$)

第5章 多偏波SAR画像における自動目標認識法価

2.4節の従来のSOMを用いた目標認識法では，目標の方位方向誤差に対するロバスト性が不十分であった．本章で述べる提案法では，同問題に対し，画像の方位方向補正及びSOMを多偏波に拡張することで，高精度な目標認識を行う．更に，多偏波データを用いる際，円偏波基底変換を用いることで，方位方向誤差に対するロバスト性を向上させる．

5.1 方位方向変化に対する画像の位置合わせ

目標が方位方向変化した場合，未知画像はSOMで学習した変化前の教師画像と大きな差異が生じる．そこで，前処理として，目標の方位方向変化に対して，画像の位置合わせをする必要がある．本手法では，正規化相互相関を行うことで，画像の方位方向を推定し，推定角度分だけ画像を補正する．まず，方位方向補正を行う前に，目標領域と背景領域を区別するために，未知画像に対して式(3.2)を適用し，特徴量 $P(x, y)$ を抽出する．第3章の性能評価より，目標領域の検出確率が最も良い特徴量を用いることで，雑音に対するロバスト性を向上させている．

次に，目標の方位方向 ϕ を推定する．目標の方位方向を次式で推定する．

$$\hat{\phi} = \arg \max_{-\pi \leq \phi \leq \pi} \frac{\sum_{x,y} P(x, y) P_{\text{ref}}(x, y, \phi)}{\sqrt{\sum_{x,y} P(x, y)^2} \sqrt{\sum_{x,y} P_{\text{ref}}(x, y, \phi)^2}}, \quad (5.1)$$

ここで， $P_{\text{ref}}(x, y, \phi)$ は，参照画像 $P_{\text{ref}}(x, y, 0)$ を目標中心点を基準に ϕ だけ方位方向変化させた画像である．但し， $P(x, y)$ 及び $P_{\text{ref}}(x, y, \phi)$ は，背景雑音を除去するために，大津の判別分析法より，二値化処理を施す．図5.1に，目標の方位方向補正の概要を示す．同処理では，参照画像 $P_{\text{ref}}(x, y, 0)$ から一定刻み ϕ で参照画像を複数枚用意する．次に，未知画像 $P(x, y)$ と相関係数が最大となる参照画像 $P_{\text{ref}}(x, y, \phi)$ の組み合わせを求め，そのときの方位方向を $\hat{\phi}$ として算出する．未知画像に対して，推定角度 $\hat{\phi}$ 分だけ逆方向に画像を方位方向補正させることで，画像の座標を $\phi = 0^\circ$ のものに補正する．式(2.34)におけるSOMの評価関数では，画素毎の特徴量のユークリッドノルムを評価しているため，未知画像と教師画像の座標系が異なると正確な評価ができない．本前処理を行うことで，教師画像と未知画像の座標系を合わせることができ，同じ散乱点の特徴量を評価することができる．

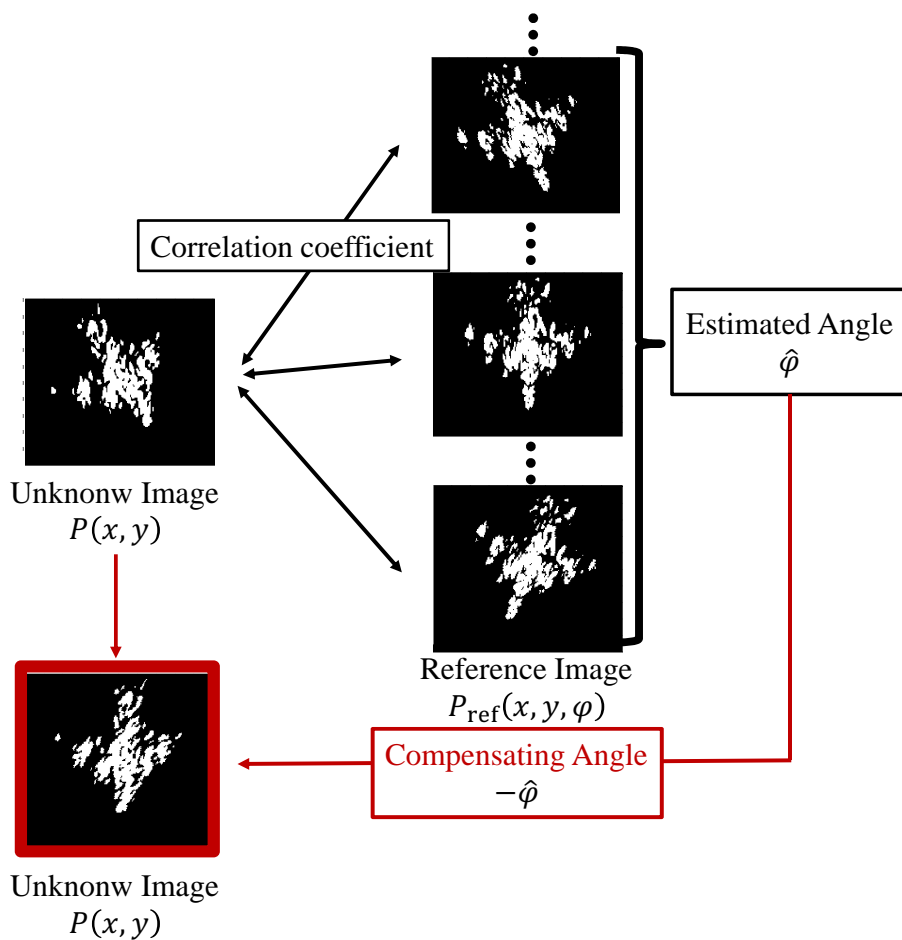


図 5.1: 目標の方位方向推定の概要

5.2 円偏波基底 PoSAR 画像を用いた自動目標認識法

偏波成分は互いに独立な特徴量であるため，単純に独立な情報量が増加し，目標認識などにおいて精度向上を可能にする．多偏波 SAR 画像は一般的に，直線偏波アンテナを用いるため直線偏波基底が用いられる．一方で，直線偏波基底において目標が方位方向変化した場合，散乱特性が方位方向における変化前後で変化してしまうことが報告されている．[18] SOM では，式 (2.34) のように，同画素における電力値のユークリッドノルムを評価しており，多偏波に拡張した場合は，各偏波毎に評価することとなる．しかし，目標の方位方向変化により偏波毎の散乱特性が変化してしまう直線偏波基底では，方位方向変化に対するロバスト性が不十分である．そこで，提案法では，円偏波基底変換を行い，散乱特性を方位方向変化に対して不変量とすることで，方位方向誤差に対するロバスト性を向上させる．

図 5.2 に、目標の方位方向変化前後の SAR の観測ジオメトリを示す．ここで、 ϕ は目標の方位方向、 ψ はレーダの入射角を示す．本研究では、目標がアジマス方向に変化した場合を想定しており、レーダの入射角は一定とする．目標は楕円と三角形を組み合わせた航空機を模擬しており、方位方向変化前を青、方位方向変化後を赤で示す．また、アンテナ平面と水平な面を $x_H - y_V$ とし、 θ は $x_H - y_V$ 平面における方位方向変化前後のなす角である．2 章で述べた式 (2.15) に適用するため、目標の方位方向 ϕ を θ に座標変換する． $x_H - y_V$ 平面における回転角度を偏波オリエンテーション角 θ と呼び、次式で定義される．[19]

$$\tan(\theta) = \frac{\tan(\phi)}{\cos(\psi)} \quad (5.2)$$

本研究では、 ϕ のみを変数であるため、方位方向により偏波オリエンテーション角 θ が変化することが分かる．式 (2.15) より、目標の方位方向変化後の直線偏波基底における各偏波成分を次式で示す．

$$S_{HH}^{\theta} = S_{HH} \cos^2(\theta) - S_{HV} \sin(2\theta) + S_{VV} \sin^2(\theta) \quad (5.3)$$

$$S_{HV}^{\theta} = \frac{\sin(2\theta)}{2} (S_{HH} - S_{VV}) + S_{HV} \cos(2\theta) \quad (5.4)$$

$$S_{VV}^{\theta} = S_{HH} \cos^2(\theta) + S_{HV} \sin(2\theta) + S_{VV} \cos^2(\theta) \quad (5.5)$$

S は変化前の散乱特性の要素、 S^{θ} は変化後の散乱特性の要素である．上式より、目標の方位方向変化により各偏波成分間で強度や位相が変化してしまうことがわかる．一方で、式 (2.20) により、直線偏波基底を円偏波基底に変換した場合の散乱特性について考えてみる．円偏波基底における方位方向変化後の各偏波成分は次式で定義させる．

$$S_{LL}^{\theta} = S_{LL} \exp(j2\theta) \quad (5.6)$$

$$S_{LR}^{\theta} = S_{LR} \exp(j2\theta) \quad (5.7)$$

$$S_{RR}^{\theta} = S_{RR} \exp(-j2\theta) \quad (5.8)$$

ここで、添え字 L は左回り円偏波、R は右回り円偏波を示す．上式より、円偏波基底において、方位方向変化の影響は、 S_{LL} 及び S_{RR} の位相成分のみに出現し、強度や電力に関しては、不変量であることが分かる．提案法では、SOM に入力する特徴量を円偏波基底に変換することで、方位方向変化による散乱特性の変化を抑圧し、認識精度の向上が期待される．

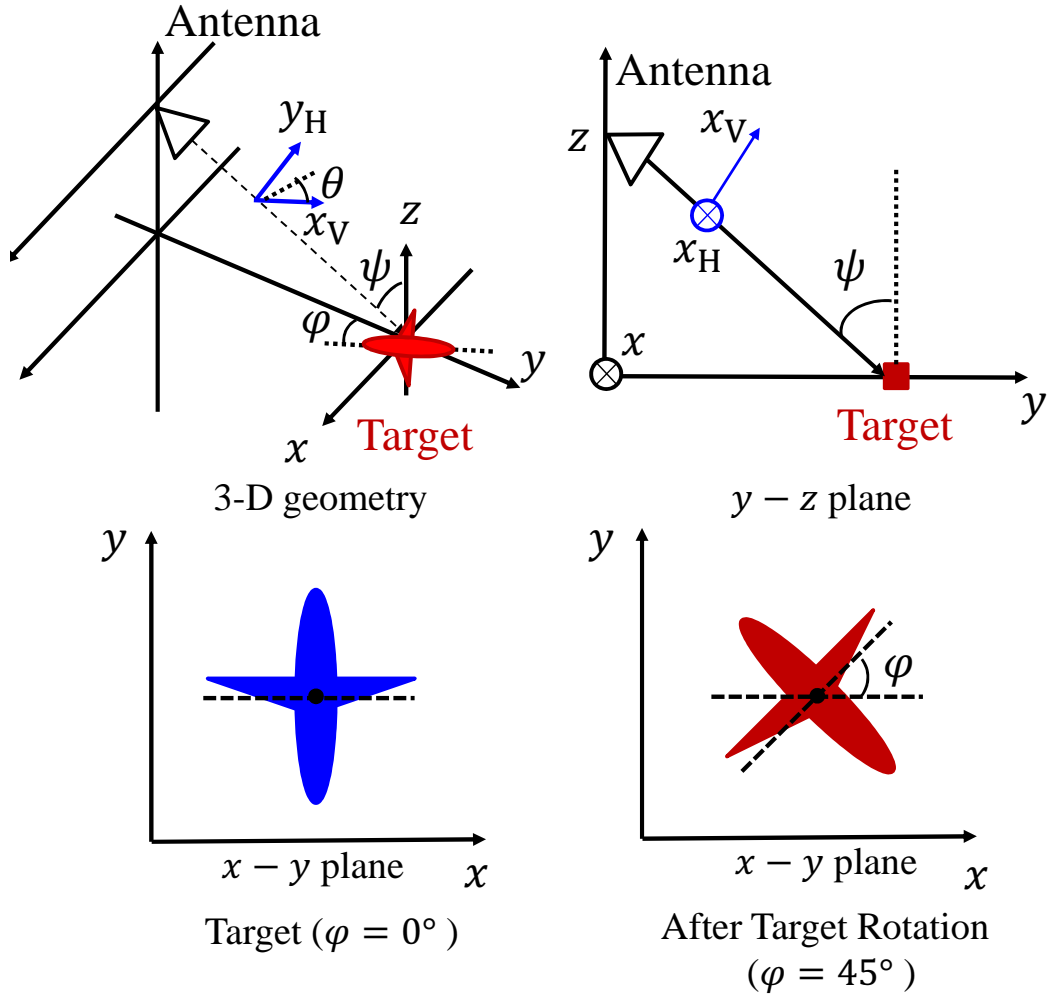


図 5.2: 目標の方位方向変化前後の観測ジオメトリ

提案法における，教師画像及び未知画像の特徴量を次式で定義する．

$$\mathbf{X}_{\text{CP}} = \frac{[\mathbf{x}_{\text{LL}}, 2\mathbf{x}_{\text{LR}}, \mathbf{x}_{\text{RR}}]}{\max_{x,y \in \Omega} (\mathbf{x}_{\text{LL}} + 2\mathbf{x}_{\text{LR}} + \mathbf{x}_{\text{RR}})} \quad (5.9)$$

添え字 CP は円偏波基底 (Circular Polarization) を示している．また， \mathbf{x}_{ij} ($i, j = \text{L, R}$) は， ij 偏波成分における画像をベクトル化したものであり，次式より定義される．

$$\mathbf{x}_{ij} = [I_{ij}(x_1, y_1), \dots, I_{ij}(x_1, y_{N_y-1}), \dots, I_{ij}(x_{N_x-1}, y_{N_y-1})] \quad (5.10)$$

I_{ij} は ij 偏波の SAR 画像であり，式 (2.29) より定義される． N_x, N_y は SAR 画像の x, y 方向における総ピクセル数を示す．上式では，全偏波成分の総和が最大となる画素の値で，各偏波画像 \mathbf{x}_{ij} を正規化している．正規化を行うことで，

偏波成分の電力値の強弱を維持した特徴量となる。更に、送信信号の電力が異なったり、アンテナと目標間における距離が変化しても、特徴量の変化が抑えられ、観測ジオメトリに依存しにくい特徴量といえる。

図 5.3 に、提案法による教師画像及び未知画像生成の処理手順を示す。

手順 1). 直線偏波アンテナで取得した各偏波画像 $S_{ij}(i, j = H, V)$ において、目標領域と雑音領域を区別するために、式 (3.2) より、特徴量 $P(x, y)$ を算出する。

手順 2). 式 (5.1) より、参照画像と未知画像の相関を取り、目標の方位方向推定及び補正を行う。但し、未知画像 $P(x, y)$ と参照画像 $P_{\text{ref}}(x, y)$ は大津の判別分析法を適用し、二値化処理する。

手順 3). 方位方向変化において不変な特徴量に変換するために、各偏波成分に対し、直線偏波基底から円偏波基底に変換する。

手順 4). 円偏波基底の各偏波成分から正規化された特徴量 X_{CP} を決定する。但し、教師画像生成の際は、未知画像の方位角度が既知のため、手順 2 の方位方向補正は行わない。以上の処理より、目標領域推定、方位方向補正、特徴量の決定を行い、SOM に教師画像及び未知画像として入力する。

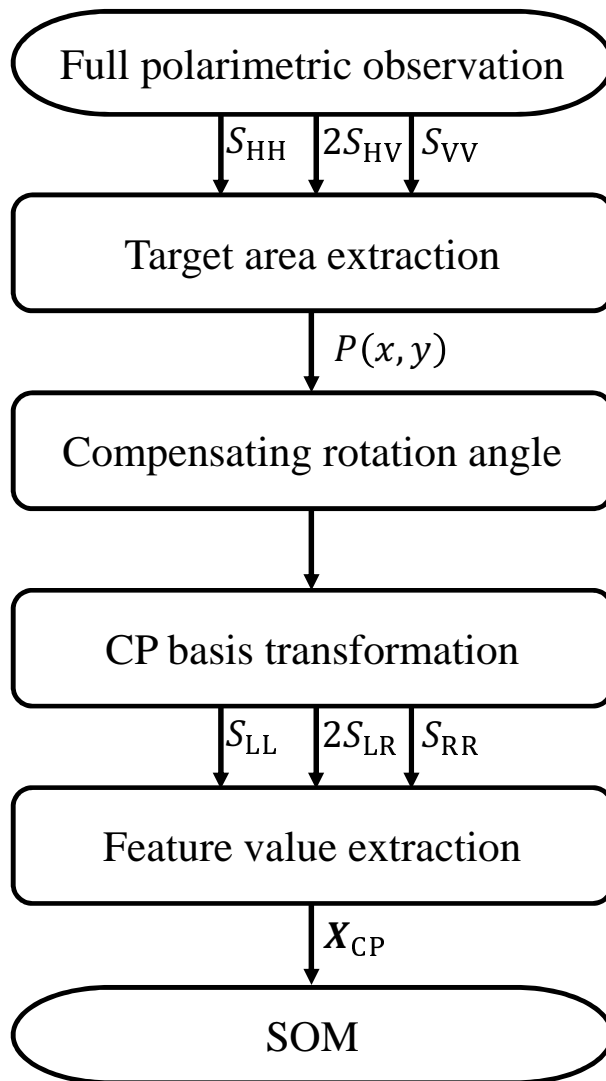


図 5.3: 提案法のフローチャート

第6章 自動目標認識法の性能評価

本章では，実験データによる自動目標認識法の性能評価を行う．

6.1 実験緒元

実験の観測ジオメトリやパラメータは4章と同一に設定する．表6.1に，実験諸元を記す．但し，自動目標認識法では，目標の方位方向誤差に対するロバスト性を検証するため，目標を方位方向変化させる．図6.1に，目標の方位方向変化の概要を示す．時計回りを正，反時計回りを負とする．方位方向は， $-30^\circ \leq \phi \leq 30^\circ$ とし，間隔は 2° とする．図6.2に， $\phi = 0^\circ$ の直線偏波基底で観測された多偏波SAR画像のRGB変換画像を示す．RGB変換では，各偏波画像毎に色を割り当て，0から255のカラースケールで画像を出力している．直線偏波基底では，R(Red)をHH偏波，G(Green)をHV偏波，B(Blue)をVV偏波と割り当てている．図より，各機体毎の部位ごとに，色の分布が異なることが分かる．例えば，B747の胴体部分はHH偏波が支配的なのに対して，B777ではVV偏波が支配的である．多偏波SAR画像のベクトル化は，この偏波画像毎の電力分布の違いを保持している．そのため，機体毎に色の分布が異なるということは，有効な特徴量であり，認識精度向上に繋がると考えられる．また，全体的に赤や青色が支配的であり，人工物がHH偏波やVV偏波を強く反射するという特性が確

表 6.1: 実験緒元

モード	パラメータ
中心周波数	33 GHz
帯域幅	14 GHz
高度	1.14 m
オフナディア角	65°
アジマス分解能	1.25 cm
レンジ分解能	1.18 cm
目標方位方向角度	$-30^\circ \leq \phi \leq 30^\circ$
合成開口長	1.6 km






図 6.1: 目標の方位方向変化


認できる．図 6.3 に， $\phi = 30^\circ$ における RGB 変換画像を示す．画像が単純に方位方向変化しているのではなく，全体的に歪んでいることが確認できる．特に，エンジンやコックピットなどの曲面になっている箇所では歪みが強く，多重散乱が原因だと考えられる．また，色の分布も $\phi = 0^\circ$ の際と比較し，異なっていることが分かる．全体的に，緑が増加しており，HV 偏波成分が増加していることが分かる．直線偏波基底では，散乱特性が変化するためである．航空機において，正面から観測した場合，胴や翼はおおよそ水平や垂直に位置しているが，目標が方位方向変化することで傾く．これは，ダイポールが傾いたときと同様に考えることができ，2.2.3 節のように HH 偏波や VV 偏波が減少し，HV 偏波が増加する．




B747




B787



B777



DC10



A320



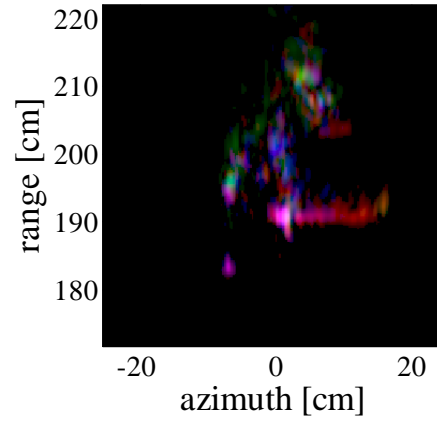



図 6.2: 直線偏波基底における RGB 画像 ($\phi = 0^\circ$)




B747




B787



B777



DC10



A320




図 6.3: 直線偏波基底における RGB 画像 ($\phi = 30^\circ$)

表 6.2: 推定角度の性能評価

True value	-30°	-20°	-10°	0°	10°	20°	30°
B747	-31°	-21°	-10°	2°	10°	20°	33°
B787	-29°	-18°	-10°	-1°	9°	18°	-12°
B777	-26°	-23°	-10°	1°	10°	24°	35°
DC10	-31°	-21°	-11°	2°	12°	21°	38°
A320	-42°	-21°	-11°	4°	14°	28°	34°

6.2 定量評価と考察

本節では，前処理の回転補正の性能評価及び各基底における回転の影響を評価する．次に，雑音なしとありの場合における認識精度の評価する．

6.2.1 方位方向補正性能

本節では，提案法による方位方向の推定精度について示す．式 (5.1) のように，方位方向推定では，基準となる参照画像が必要である．本研究では，認識する目標は全て航空機であると前提があるため，どの機体においても十字型の機体形状はあまり変わらない．そこで，本手法では，機体サイズが最も大きい B747 の二値化 SAR 画像を参照画像とした．これは，機体サイズが小さいものでは，コックピットやエンジン部分などからの反射強度が強く，形状の特徴を現す部分の相関値が取れない可能性があるからである．表 6.2 に，10° 毎の推定角度を示す．但し，参照画像は中心点を基準に $\phi = 1^\circ$ 毎に作成した．B787 の一部では，方位方向変化によりコックピット部分が消えたり，歪みが強いため，大きな誤差が生じている．また，RMSE による角度推定精度を次式より算出する．

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_N (\phi_{\text{true}} - \hat{\phi})^2} \quad (6.1)$$

N は推定する角度の総数， $\hat{\phi}$ は推定された方位方向， ϕ_{true} は方位方向の真値である．本手法では，RSME = 4.5° となり，おおよその方位方向推定が可能であることが分かる．従来の SOM を用いた自動目標認識法 [3] において，未知画像と教師画像の方位角度の差異が $\pm 10^\circ$ 程度でも認識に成功していたため，この程度の誤差は問題ないと考える．

表 6.3: 方位方向変化による各基底における電力比の変化

	ϕ	B747		B787		B777		DC10		A320	
		0°	30°	0°	30°	0°	30°	0°	30°	0°	30°
LP basis	HH	40 [%]	32 [%]	27 [%]	33 [%]	12 [%]	20 [%]	16 [%]	28 [%]	34 [%]	29 [%]
	HV	17 [%]	24 [%]	24 [%]	21 [%]	27 [%]	34 [%]	33 [%]	19 [%]	26 [%]	34 [%]
	VV	43 [%]	43 [%]	49 [%]	46 [%]	61 [%]	46 [%]	51 [%]	53 [%]	40 [%]	37 [%]
CP basis	LL	33 [%]	35 [%]	28 [%]	27 [%]	31 [%]	32 [%]	33 [%]	28 [%]	26 [%]	31 [%]
	LR	35 [%]	34 [%]	38 [%]	43 [%]	38 [%]	38 [%]	39 [%]	42 [%]	39 [%]	38 [%]
	RR	32 [%]	31 [%]	33 [%]	30 [%]	31 [%]	30 [%]	28 [%]	30 [%]	35 [%]	31 [%]

6.2.2 各基底における方位方向変化の影響

本節では、まず各基底における電力比を評価する。図 6.4 に、円偏波基底における $\phi = 0^\circ$ の各機体の RGB 画像を示す。円偏波基底では、R(Red) を LL 偏波、G(Green) を LR 偏波、B(Blue) を RR 偏波と割り当てている。直線偏波基底とは、色の分布が大きく異なることが分かる。また、図 6.5 に、 $\phi = 30^\circ$ の RGB 画像を示す。直線偏波基底に比べて、色の分布が方位方向変化の前後であまり変化しないことが分かる。これは、円偏波基底において、目標の方位方向変化により同じ散乱点の散乱特性が変化しないからである。次に、定量的に各偏波成分の電力比を評価する。電力比は、回転中心付近の窓内毎において、各偏波の総電力より算出する。窓の大きさは、図 6.4 における B747 に記した赤い四角形の大きさとする。画像全体の電力比を評価してしまうと、シャドーなどの総電力の変化が大きく出てしまう。特に、B787 や DC10 の SAR 画像では、 $\phi = 30^\circ$ のときに右翼が殆ど映らなくなっている。また、コックピット、尾翼、エンジン部分などは、方位方向変化による歪みが激しい。そこで、同一散乱点付近の散乱特性の変化を評価するため、方位方向による散乱点の位置ずれや歪みが最も少ない回転中心付近に注目する。表 6.3 に、方位方向の変化前後における各基底の偏波電力比を示す。また、図 6.6, 6.7 に各基底の偏波電力比変化を横棒グラフで表す。表より、変化前後において、直線偏波基底では電力比が全体的に 8% 程変化しており、電力比の著しい変化があることが確認できる。一方で、円偏波基底では、全体的に 1, 2% しか変化していない。図 6.6 では、方位方向の変化前後の電力比変化を表す点線が傾いており、電力比変化が大きいこ


とが分かる．図 6.7 では，点線が殆ど垂直であり，円偏波基底は方位方向変化による散乱特性の変化が少ないことを意味する．以上より，円偏波基底は，目標の方位方向変化に対する偏波成分の電力比変化を抑圧できていることが分かる．また，理論上は，円偏波基底で散乱特性は全く変化しない．しかし，実験による測定誤差や方位方向変化による SAR 画像の歪みより，理論値とは異なる．全く同じ散乱点を評価することは困難なため，変化前後の差が 0 となることは難しい．

次に，統計的な評価をする．先程の定量的評価では，部分的な電力比を評価している．一方，SOM の評価関数では，各偏波 SAR 画像全体の画素毎における電力を評価している．そこで，SOM と同等の評価関数で，各基底における方位方向変化前後の散乱特性変化を評価する．SOM の評価関数を用いた方位方向における変化前後の評価を次式で定義する．


$$\Delta\gamma_{\text{basis}} = \left\| \mathbf{X}_{\text{basis}}^{\phi_0} - \mathbf{X}_{\text{basis}}^{\phi} \right\| \quad (6.2)$$

\mathbf{X} は画像の特徴ベクトルを示しており，式 (5.9) より定義される．添え字 basis は偏波の基底 (LP：直線偏波基底，CP：円偏波基底)， ϕ_0 は変化前 ($\phi_0 = 0^\circ$)， ϕ は変化後を示している．これは式 (2.34) における SOM の評価関数と同じであり，類似性を示している． $\Delta\gamma_{\text{basis}}$ が小さいほど類似性が高く， $\Delta\gamma_{\text{basis}}$ が大きいほど類似性が低い．上式では，同機体における方位方向変化前後の類似性を評価しており，方位方向変化後でも同じ機体の類似性が高いほど，ロバストな特徴量といえる．方位方向変化により，類似性が下がってしまえば，目標を正しく認識できない可能性があがる．図 6.8 に，各機体における方位方向変化に対する評価関数の値を示す．横軸が方位方向 ϕ ，縦軸が評価値である．青線が直線偏波基底，赤線が円偏波基底である．全機体において方位方向 $|\phi|$ が大きくなるほど，評価関数の値が増加し，類似性が低下していることが分かる．しかし，円偏波基底では，直線偏波基底と比較し，評価値の増加が全体的に抑えられていることがわかる．特に，方位方向が大きい $20^\circ \leq |\phi| \leq 30^\circ$ において，円偏波基底の評価値が抑圧されている．これは，前述した方位方向変化による散乱特性変化を抑圧しているからであり，SOM の評価でも円偏波基底が有効であることが確認できる．また，式 (6.2) における評価関数は，散乱特性の変化以外の要因も含んでいるため，評価値が著しく増加している．原因として，方位方向変化による反射強度の変化，シャドウなどによる総電力の変化，SAR 画像の歪み


による散乱点の位置ずれなどが考えられる。しかし、これらの要因を取り除くことは困難であり、今後の課題といえる。




B747




B787



B777



DC10



A320



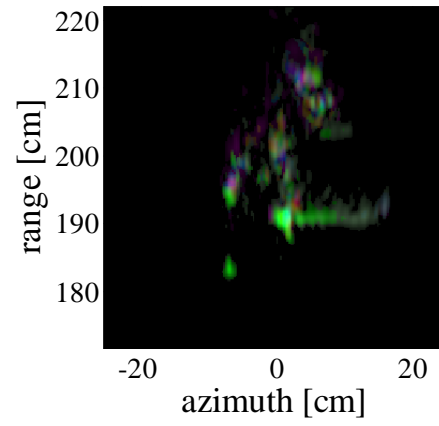



図 6.4: 直線偏波基底における RGB 画像 ($\phi = 0^\circ$)




B747




B787



B777



DC10



A320




図 6.5: 直線偏波基底における RGB 画像 ($\phi = 30^\circ$)

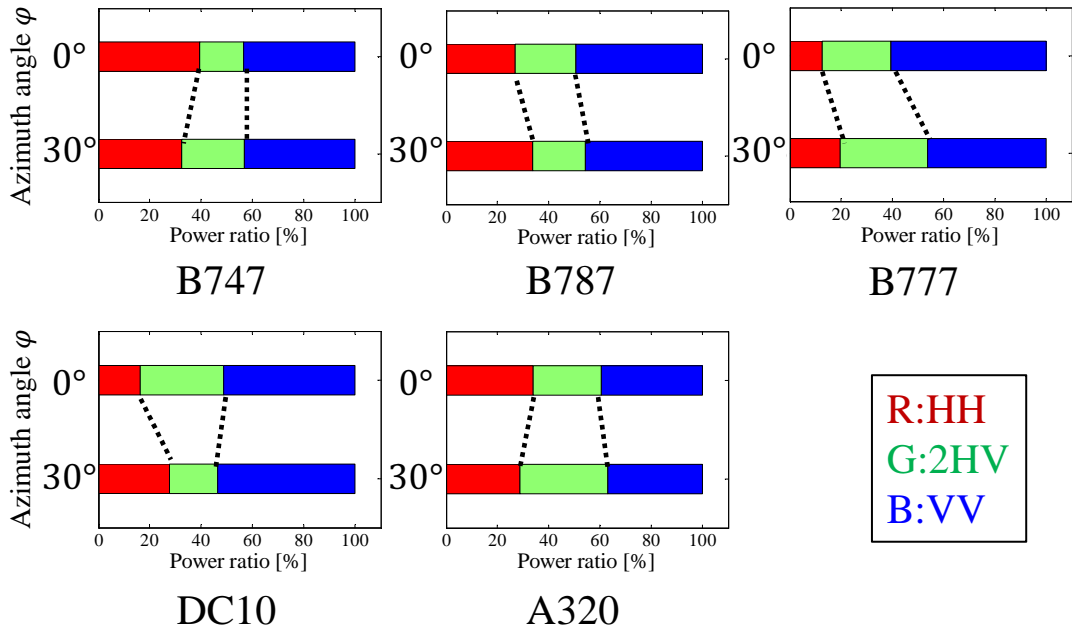


図 6.6: 直線偏波基底における方位方向前後の強度比変化







図 6.7: 円偏波基底における方位方向変化前後の強度比変化




B747




B787



B777



DC10



A320

図 6.8: 目標の方位方向と評価値の関係

表 6.4: 各特徴量における認識精度 (平均 PSNR=32dB)

		B747	B787	B777	DC10	A320	AVE
Single polarization	HH	100 [%]	39 [%]	74 [%]	93 [%]	100 [%]	81 [%]
	VV	90 [%]	58 [%]	97 [%]	90 [%]	48 [%]	77 [%]
	HV	58 [%]	58 [%]	100 [%]	100 [%]	87 [%]	80 [%]
Full polarization	LP basis	81 [%]	49 [%]	90 [%]	100 [%]	100 [%]	84 [%]
	CP basis	97 [%]	77 [%]	97 [%]	100 [%]	97 [%]	94 [%]

6.2.3 目標認識精度

本節では、実験データを用いた目標認識精度を評価する。まず、数値的な雑音を付加していない、生の実験データを用いて評価する。表 4.1 より、平均 PSNR は 32dB である。SOM を生成する際のパラメータとして、SOM マップの大きさを 31×31 、総学習回数 $T_{\text{som}} = 30$ とする。教師画像として、各機体の $\phi = 0^\circ$ における SAR 画像を学習させ、SOM を生成する。表 6.4 に、各特徴量における各機体の目標認識精度を示す。教師画像及び未知画像の特徴量としては、単偏波の HH, VV, HV 偏波、多偏波の直線偏波基底、円偏波基底を用いる。但し、多偏波では特徴量を偏波成分ごとにベクトル化しており、直線偏波基底では、 $\mathbf{X}_{\text{LP}} = [\hat{\mathbf{x}}_{\text{HH}}, 2\hat{\mathbf{x}}_{\text{HV}}, \hat{\mathbf{x}}_{\text{VV}}]$ 、円偏波基底では、式 (5.9) より定義される。認識確率は、未知画像の機種が正しく分類された確率を示している。表 6.4 において、各機体の認識確率は、全ての目標方位方向角度 ϕ で平均化されている。各特徴量において、機体毎の認識確率が前後しているが、これは特徴量ごとに分類しやすい機体の変化からである。例えば、HH 偏波において B747 は他の機体と画像が大きく異なり、認識精度が向上している。一方、HV 偏波では他の機体との類似性が高くなり、誤認識を招いている可能性がある。ゆえに、認識精度はどれか一つの機種に対して良いのではなく、平均的に認識精度が高くなることが求められる。認識精度の向上は、方位方向変化に対してロバストな特徴量の導入、機種毎に独立性が高い情報を利用することで可能となる。表より、単一偏波と多偏波では、多偏波の方が総じて認識精度の平均値が高い。多偏波では、互いに独立な偏波情報をベクトル化しており、独立な情報量が増加しているからだと考えられる。更に、円偏波基底では、直線偏波基底よりも高精度に認識ができています。これは、円偏波基底変換を導入することで、方位方向に不変な特徴量とし、方位方向変化に対するロバスト性が向上したからである。

表 6.5: 雑音付加後の各偏波における PSNR

	B747	B787	B777	DC10	A320	Ave
HH	25.5 [dB]	17.9 [dB]	21.5 [dB]	24.5 [dB]	19.7 [dB]	21.8 [dB]
VV	26.1 [dB]	19.6 [dB]	20.4 [dB]	21.8 [dB]	17.5 [dB]	21.1 [dB]
HV	13.1 [dB]	13.6 [dB]	13.4 [dB]	17.5 [dB]	14.6 [dB]	14.4 [dB]

表 6.6: 各特徴量における認識精度 (平均 PSNR=18dB)

		B747	B787	B777	DC10	A320	AVE
Single polarization	HH	99 [%]	41 [%]	50 [%]	88 [%]	56 [%]	67 [%]
	VV	91 [%]	57 [%]	90 [%]	87 [%]	47 [%]	74 [%]
	HV	46 [%]	47 [%]	5 [%]	96 [%]	41 [%]	47 [%]
Full polarization	LP basis	75 [%]	46 [%]	77 [%]	100 [%]	99 [%]	79 [%]
	CP basis	95 [%]	74 [%]	80 [%]	90 [%]	88 [%]	86 [%]

図 6.9 に、各特徴量における方位方向と認識精度の関係を示す。横軸を方位方向 ϕ 、縦軸を認識精度としており、認識精度は全機体の平均値である。全体的に、 $\pm 10^\circ$ 程度では、どの機体も認識に成功していることが分かる。それ以外の範囲では、単一偏波から順に認識精度が低下している。一方で、赤線の円偏波基底では、より広範囲の角度でも高い認識精度を維持しており、提案法の有効性が確認できる。

次に、数値的にノイズを加えた場合の認識精度について述べる。4.2 節と同様に、加法性ノイズを付加することで、低 PSNR 下を模擬する。このときの平均 PSNR は 19dB である。表 6.5 に、雑音付加後の各偏波における PSNR を示す。但し、雑音パターンは 5 通りとし、認識確率は平均化する。表 4.1 と異なり、背景雑音よりも模擬した受信機雑音の方が高くなるため、反射強度の低い HV 偏波は PSNR が著しく低下する。表 6.6 に、雑音付加時の各特徴量における各機体の目標認識精度を示す。HV 偏波では PSNR の低下とともに、認識精度も著しく劣化していることが確認できる。多偏波では、式 (5.9) のように特徴量を最大電力で正規化しているため、その特徴量は電力値の強弱も含んでいる。これにより、例えば直線偏波基底において、もともと電力の低い HV 偏波よりも電力の高い HH 偏波や VV 偏波の方が重要視される。よって、雑音に支配されやすい HV 偏波を含んでいても認識精度の劣化を防いでいる。図 6.10 に、各特徴量における方位方向と認識精度の関係を示す。雑音付加の影響で、全体的に、




図 6.9: 各特徴量における目標方位方向と認識精度の関係 (平均 PSNR=32dB)

認識精度が劣化している．特に，HV 偏波は方位方向誤差があまりなくても認識が失敗している場合が多く，殆ど認識できてないといえる．一方，多偏波はより広範囲な方位角度でも認識確率を維持しており，その中でも赤線の円偏波基底は最も高い認識精度となっている．これは，多偏波の目標領域推定精度が良好なこと，特徴量が雑音に支配されやすい偏波に影響しにくいことなどに依存する．以上より，提案法である円偏波基底の雑音及び方位方向変化に対するロバスト性の高く，認識精度の向上が確認できる．




図 6.10: 各特徴量における目標方位方向と認識精度の関係 (平均 PSNR=18dB)

第7章 結論

本論文では、PSNR 重み付け合成を用いた目標領域推定法及び円偏波基底 PolSAR を用いた自動目標認識法を提案した。従来の目標領域推定法として、PWF を用いた手法が提案されているが、加法性ノイズを考慮しておらず、目標信号も抑圧してしまうという問題点がある。同問題に対して、四成分散乱分解法に基づく手法と PSNR 重み付け合成を用いた手法を提案した。実験データを用いて、数値的に受信機雑音などの複素ガウス雑音を付加し、雑音に対する目標領域推定のロバスト性を評価した。四成分散乱分解法に基づく手法は加法性ノイズに対して、電力分解が正確に行われず、目標推定精度の劣化が顕著となった。一方、提案した PSNR 重み付け合成を用いた手法は、合成重み係数を PSNR に応じて変化させるため、散乱強度が強い偏波 SAR 画像に注目して、目標領域を決定することができ、目標領域推定精度を向上させた。

次に、SAR 画像における自動目標認識法について検討した。従来の SOM を用いた自動目標認識法では、単一偏波しか考慮しておらず、目標の方位方向変化に対してロバスト性が不十分であった。本論文では、従来の自動目標認識法を多偏波に拡張した。本手法では、前処理として、方位方向における座標のずれを局所的な相互相関係数を評価関数として導入し、補正した。更に、目標の方位方向変化に不変量な散乱特性である円偏波基底変換を導入した。実験データによる評価より、円偏波基底は方位方向変化による散乱特性の変化を抑圧できることを確認した。一方、目標認識精度においても、円偏波基底に基づく手法では、各単一偏波及び直線偏波基底に基づく手法よりも高精度に認識できることが示された。今後の課題として、SAR 画像の歪みの解消、方位方向変化による電力変化の補正法などの検討が挙げられる。また、本実験における検討では、X バンドレーダの 1/100 スケールモデルによる実験システムを想定したが、計測装置の限界により、中心周波数に関しては、同スケールに合わせられなかった。このため、同手法の実際の特性を検証するため、リアルデータを用いた性能評価が必要である。

参考文献

- [1] B. Widrow, R. G. Winter and R. A. Baxter, “ Layered Neural Nets for Pattern Recognition, ” *IEEE Trans. Acoustics, Speech and Signal Processing*, vol. 36, no. 7, pp. 1109–1118, Jul., 1988.
- [2] X. Yu, Y. Li and L.C. Jiao, “ SAR Automatic Target Recognition Based on Classifies Fusion, ” *Proc. of 2011 International Workshop on Multi-Platform Multi-sensor Remote Sensing and Mapping*, pp. 1–5, Jan, 2011.
- [3] S. Ohno, S. Kidera and T. Kirimoto., “ Efficient SOM Based ATR Method for SAR Imagery with Azimuth Angular Variations, ” *IEEE. Geosci. Remote. Sens. Letters*, vol. 11., pp.1901-1905, Apr., 2014.
- [4] F. Sadjadi., “ Improved Target Classification Using Optimum Polarimetric SAR Signatures, ” *IEEE Transactions on Aerospace and Electronic Systems*, vol. 38., pp.38-49, Jan., 2002.
- [5] 大内和夫, “リモートセンシングのための合成開口レーダの基礎,” 東京電機大学出版局, 第2版, 2009.
- [6] 山口芳雄, “レーダポーラリメトリの基礎と応用,” 電子情報通信学会, 第1版, 2007.
- [7] Y. Yamaguchi, T. Moriyama, M. Ishido, and H. Yamada, “ Four-component scattering model for polarimetric SAR image decomposition, ” *IEEE Trans. Geosci. Remote Sens*, vol.43, no.8, pp.1699-1706, Aug. 2005.
- [8] A. Freeman, S. L. Durden, “ A Three-Component Scattering Model for Polarimetric SAR Data, ” *IEEE Trans. Geosci. Remote Sens*, vol. 36, pp.963-973, May. 1998.
- [9] L.M. Novak, M.C. Buri, W.W. Irving and G.J. Owirka, “ OPTIMAL POLARIMETRIC PROCESSING FOR ENHANCED TARGET DETECTION, ” *IEEE Trans Aero. Elec. Sys.*, vol. 1., pp.69-75, Mar., 1991.
- [10] C .M. Pilcher and A. Khotanzad, “ Maritime ATR Using Classifier Combination and High Resolution Range Profiles, ” *IEEE Trans. Aerospace and Electronic Systems*, vol. 47, no. 4, pp. 2558-2573, Oct, 2011.
- [11] Duda, R. O., Hart, P., and Stork, D. Pattern Classification. *John Wiley and Sons*, 2001.

- [12] E. P. Hart, N. J. Nilsson and B. Raphael, " A Formal Basis for the Heuristic Determination of Minimum Cost Paths," *IEEE Transactions of Systems Science and Cybernetics*, vol. ssc-4, no. 2, July, 1968.
- [13] Desai, M. and Jenkins, W., " Convolution backprojection image reconstruction for spotlight mode synthetic aperture radar, " *IEEE Transactions on Image Processing*, vol. 1., pp.505-517, Oct., 1992.
- [14] N. Otsu, " A Threshold Selection Method from Gray-Level Histograms, " *IEEE Trans. Systems, Man and Cybernetics*, vol. 9, no. 1, pp. 62-66, Jan, 1979.
- [15] H. Matsushita and Y. Nishio, " Batch-Learning Self-organization Map with False-neighbour degree between neurons, " *IEEE Proc. of IJCNN 2008*, pp. 2259-2266, Jun. 2008.
- [16] M.Ito, T.Miyoshi and H.Masuyama, " The characteristics of the torus Self Organizing Map, " Proceedings of 6th International Conference on Soft Computing, Fukuoka, Japan, pp.239-244(2000).
- [17] A. Ultsch and H. P. Siemon, " Kohonen 's Self Organizing Feature Maps for Exploratory Data Analysis, " Proc. of International Neural Network Conference, pp. 305-308, 1990.
- [18] Kimura. H, Papathanassiou, K.P and Hajnsek, I," Polarization orientation effects in urban areas on SAR data, " *IGARSS '05. Proceedings. 2005 IEEE International.*, vol. 7., pp.4863-4867 , July., 2005.
- [19] Jong-Sen Lee, Schuler. D.L, Ainsworth. T.L, Krogager. Ernst, Kasilingam. D. and Boerner. W.-M. " On the estimation of radar polarization orientation shifts induced by terrain slopes, " *Geoscience and Remote Sensing, IEEE Transactions on* , pp. 30-41 , 2002.

謝辞

本研究を進めるにあたり，厳しくも優しく見守ってくださり，多大なるご指導を賜りました桐本哲郎教授に心から御礼申し上げます．学会発表や論文作成など，ご多忙の中，丁寧かつ熱心なご指導を頂きました木寺正平准教授に深く感謝致します．事務手続きに関し，日頃から支えて頂きました猪原園子秘書に感謝の意を表します．最後に，研究に限らず互いに励まし合い，研究室生活に刺激を与えて下さった桐本研究室の皆様感謝し，本論文の結びとさせていただきます．