

# グラフ推定によるレンジドップラーマップ上の異種クラッタ領域検出技術

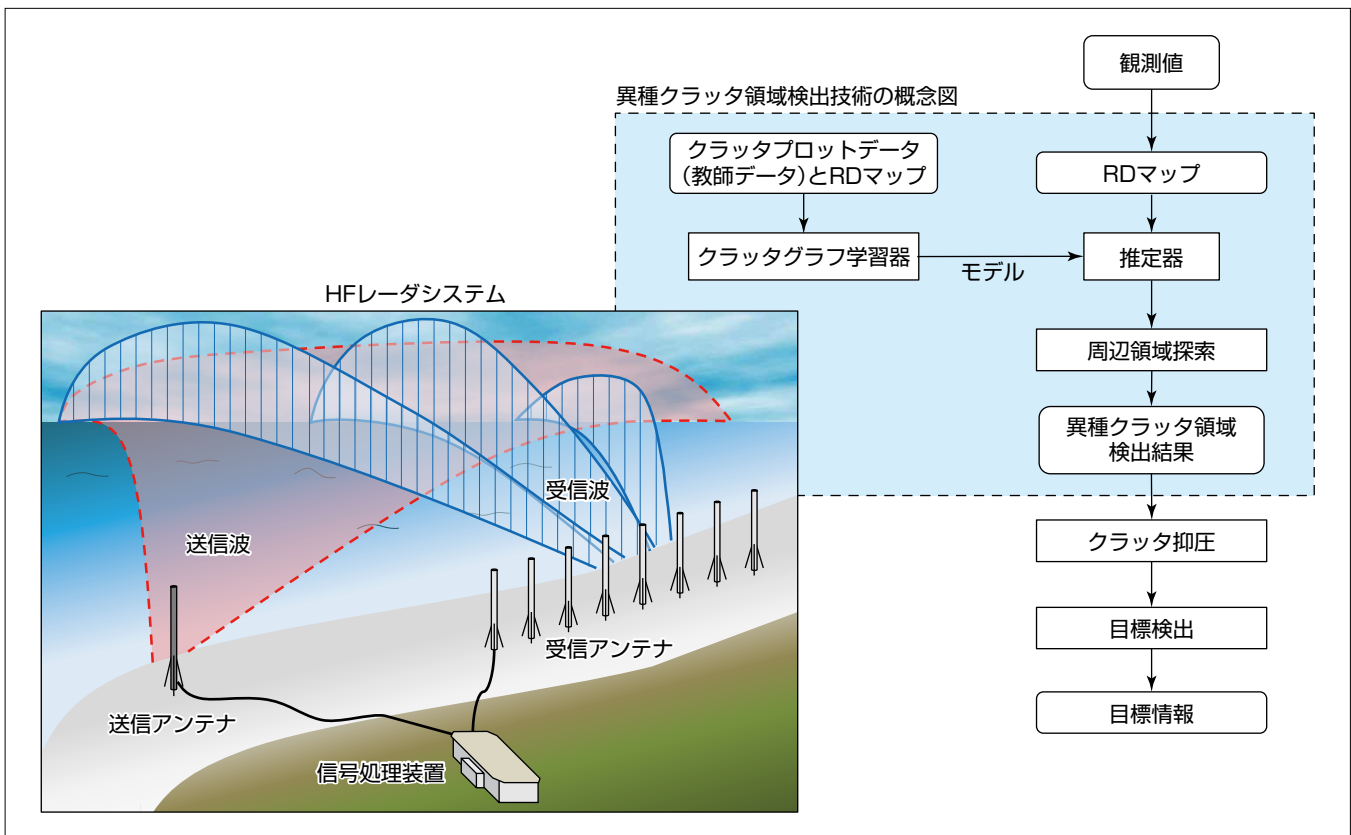
谷高 竜馬\*  
Ryoma Yataka  
平嶋 一貴\*  
Kazuki Hirashima  
白石 将\*  
Masashi Shiraishi

Graph-based Instance Segmentation Technique for Heterogenous Clutter on Range-doppler Map

## 要 旨

短波(High Frequency: HF)レーダによる観測信号を処理して得られるレンジドップラー(Range-Doppler: RD)マップには、検出対象である目標のほかに海波や電離層等のクラッタが含まれる。従来クラッタへの対処として一定誤警報確率(Constant False Alarm Rate: CFAR)処理によるクラッタ抑圧が適用されているが、性質の異なる複数種類のクラッタが混在する状況では高精度な目標検出が困難という課題があった。このような状況でも高精度な目標検出器を構築するためには、あらかじめRDマップ内のクラッタ領域及び種別を推定し、クラッタ種別に応じて適切な抑圧を行うことが有効と考えられる。そこで、クラッタ抑圧の前処理として、一般物体検出等で高い性能が報告されているCNN(Convolutional Neural Networks)を応

用したセグメンテーション(領域分割)方式を開発した。一般的にセグメンテーションを実現するためには領域分割された教師データが必要であるが、クラッタ領域の境界は曖昧であるためアノテーションが困難である。この課題に対して開発方式では、CFARで誤検出したプロットからクラッタ領域ごとに生成したグラフを教師データとしてCNNを学習し、学習済みのCNNで推定したプロットの周辺領域を探索することでセグメンテーションを実現する。これによって、領域分割された教師データを用意することなくセグメンテーションが可能になる。評価実験を行い、各種クラッタの領域を種別及び詳細な境界として推定できることを確認した。



## グラフ推定によるRDマップ上の異種クラッタ領域検出技術

HFレーダは海面に電波を送信する送信アンテナと、目標で反射した電波を受信する受信アンテナ及び受信した信号を解析する信号処理装置で構成される。異種クラッタ領域検出技術はシークラッタや電離層クラッタ等の不要波を誤検出したデータを基にクラッタプロットを表現するグラフを学習することで、クラッタプロットを検出し、さらにその周辺領域の探索を行うことで種別ごとのクラッタ領域の検出を可能にする。

## 1. ま え が き

HF(3-30MHz)レーダは、表面回折伝搬のメカニズムに基づき動作するレーダであり、高周波電波を送信してその反射エコー(ドップラーエコー)を受信する。HFレーダの受信信号を解析することで、50km以遠の海の表層の流況(流向・流速)や船舶、低空飛行物体等の目標情報を取得可能なため、広範囲にわたる海の継続的な状態監視や不審船の検出のために広く利用されている。

一方で、クラッタ(シークラッタや電離層クラッタ等)は、HFレーダの目標検出性能を低下させる要因として知られており、目標検出を行う前にクラッタ抑圧を適用することが一般的である。クラッタを抑圧する主な技術として、HFレーダで観測した信号を処理することで得られるRDマップに対して施すPost-Doppler型の手法が研究されている。例えば、CFARを用いることで、クラッタを抑圧しつつ、目標検出を行うことができる。しかし、シークラッタや電離層クラッタ等の、性質の異なる複数種類のクラッタが混在する状況では、それら全てのクラッタをCFARだけの適用によって適切に抑圧することは困難であり、目標検出での誤警報確率が高くなるという問題があった。複数種類のクラッタが混在する状況でも高性能な目標検出器を構築するためには、あらかじめRDマップ内のクラッタごとにその領域と種別を推定した上で、クラッタ種別に応じて適切な抑圧手法を適用することが有効である。

本稿ではRDマップの目標検出で、クラッタ抑圧の前処理として適用するクラッタ検出技術について検討した結果を述べる。

## 2. CFARを用いたRDマップの信号解析

### 2.1 RDマップ

RDマップは、目標からの反射波を距離(レンジ)と速度(ドップラー)で表した二次元マップである。シークラッタや電離層クラッタ等はこのRDマップ上に高い信号電力値を持って分布しており、シークラッタはレンジ方向、電離層クラッタはドップラー方向に広がって分布する。これらの分布は天候や時間帯によって不規則に変化することでしばしば目標信号が埋もれてしまうため、これを避けるためにクラッタ抑圧を行う必要がある。

#### 2.1.1 CFAR

RDマップ上でクラッタを抑圧して目標だけを検出する一般的な方法として、クラッタの誤検出を一定に保ちなが

ら検出処理を行うCFARがある。CFARはリファレンスセルと呼ばれる分解能セル領域の統計量からRDマップ内の各セルでの信号電力のしきい値を求め、しきい値以上の電力を持つセルを目標として検出する。CFARにはリファレンスセルを含め幾つかのハイパーパラメータがあり、それらの設計方法によって性能が変化する。シークラッタと電離層クラッタの特性は大きく異なるため、例えばRDマップ上でレンジ方向に分布するシークラッタを抑圧する設定を行った場合には、ドップラー方向に分布する電離層クラッタ等の誤警報が増加し、その逆も同様となる。さらに、クラッタは天候や時間帯によっても変化するため、性質の異なるクラッタを抑圧するには、その都度設計をし直す必要があるという問題がある。

## 3. 開発方式

クラッタに左右されずに汎用性の高い目標検出器を構築するためには、あらかじめRDマップ上に存在するクラッタごとにその領域と種別を推定し、領域ごとに適切なクラッタ抑圧を適用することが有効である。そこで、この研究では近年盛んに研究が行われているCNN<sup>(1)</sup>を応用したクラッタ領域のセグメンテーション方式を開発した。一般的に、セグメンテーションを実現するためには詳細に領域分割された教師データが必要である。しかし、RDマップ上のクラッタ領域は境界が曖昧なため人手によるアノテーションが困難になる。そこで、開発方式では実データでCFARで誤検出したプロットを加工することで各クラッタをクラッタグラフとして表現し、これを教師データとして利用する。クラッタグラフは、単一のクラッタ領域内で誤検出された複数のクラッタプロットを互い連結させて生成されるグラフである。これによって、詳細に領域分割された教師データを用意することなくセグメンテーション領域を学習することが可能になる。具体的なセグメンテーションの手順を図1に示す。まずRDマップを学習済みのCNNに入力し、RDマップ上の各クラッタ領域のクラッタグラフとその種別を推定する。その後、推定したクラッタグラフごとに、その周辺領域を探索してクラッタ領域(前景)とそれ以外の領域(背景)とに分離する。このような手順によって、RDマップ上のクラッタ領域のセグメンテーションが完了する。

### 3.1 教師データ用クラッタグラフの生成

開発方式では、CNNで各クラッタのクラッタグラフ(プロット位置とそのつながり方及びその種別)を学習する。しかし、プロットのごとのつながり方には膨大な組合せがあるため、各プロットをランダムに接続した場合には学習が収束

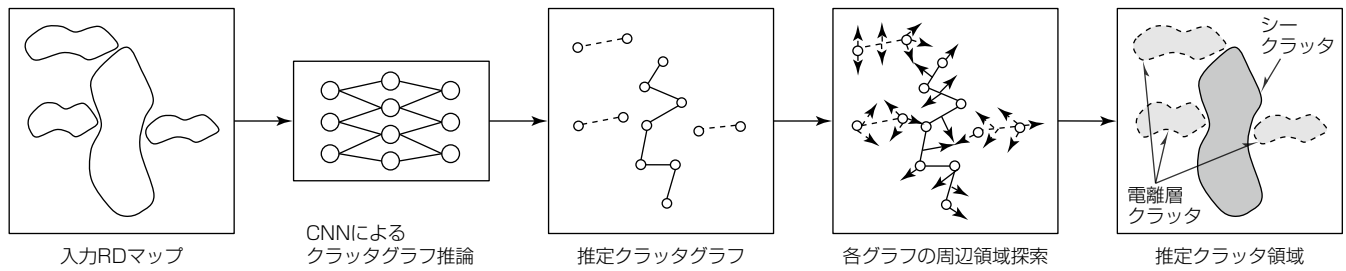


図1. RDマップでの異種クラッタ領域のセグメンテーション方式手順

しないという問題が生じる。よって、適切なつながり方を事前に定義する必要がある。本稿では、教師データに適したクラッタグラフとして、最小全域木に基づくグラフを構築した。最小全域木はグラフ理論にける各エッジの重みの総和が最小で、かつ余分なつながりを排除した全域木である。エッジの重みはRDマップの信号電力値に基づいて定義した。図2(a)に生成したクラッタグラフの例を示す。このような最小全域木を用いることで、教師データの生成に規則性が生まれ、ネットワークの学習が容易になる。

### 3.2 CNNによるクラッタグラフ学習

プロット集合をクラッタグラフとして学習するCNNを構築した。図3に開発方式で用いるCNNのアーキテクチャの概念図を示す。このアーキテクチャは二つの枝で構成されており、一方はRDマップ $\mathbf{X} \in \mathbb{R}^{R \times V}$ を入力してクラッタグラフのノードの位置とその種別を推定するノードネットワーク $\Phi(\mathbf{X})$ 、他方はクラッタグラフのエッジとその種別を推定するエッジネットワーク $\Psi(\mathbf{X})$ である。 $R$ はレンジ方向のセル数、 $V$ はドップラー方向のセル数を表す。各ネットワークは、次の式で定義された損失関数 $f$ を最小

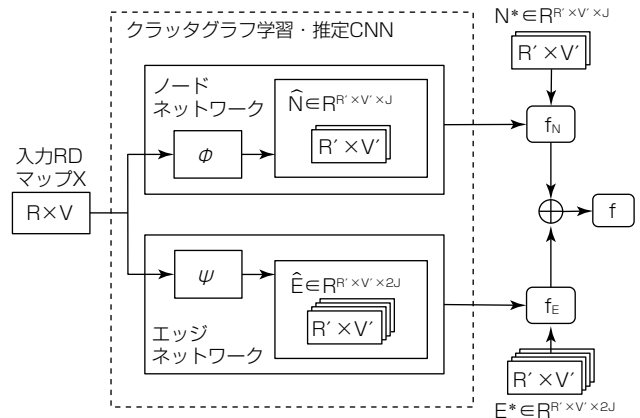


図3. 開発方式で用いるCNNアーキテクチャ

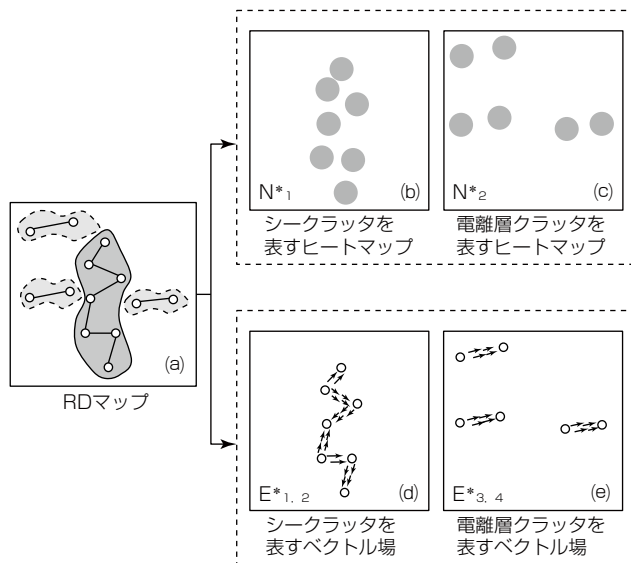
化することで最適化する。

$$f = f_N + f_E \dots \dots \dots (1)$$

$$f_N = \sum_{j=1}^J \sum_{\mathbf{p}} \|\hat{\mathbf{N}}_j(\mathbf{p}) - \mathbf{N}^*_j(\mathbf{p})\|_2^2 \dots \dots \dots (2)$$

$$f_E = \sum_{j=1}^{2J} \sum_{\mathbf{p}} \|\hat{\mathbf{E}}_j(\mathbf{p}) - \mathbf{E}^*_j(\mathbf{p})\|_2^2 \dots \dots \dots (3)$$

ここで、 $J$ はクラッタの種別数( $J=2$ )、 $\hat{\mathbf{N}} \in \mathbb{R}^{R' \times V'}$ はノードネットワーク $\Phi(\mathbf{X})$ の $J$ 枚ある推定特徴マップの $j$ 枚目、 $\hat{\mathbf{E}}_j \in \mathbb{R}^{R' \times V'}$ はエッジネットワーク $\Psi(\mathbf{X})$ の $2J$ 枚ある推定特徴マップの $j$ 枚目である。 $\mathbf{p}$ はその特徴マップ内の位置を表す。また、 $\mathbf{N}^*_j$ 及び $\mathbf{E}^*_j$ は対応する正解特徴マップを表しており、クラッタの種別ごとに正解となる値が割り当てられている。ここで、教師データであるクラッタグラフのエッジは、3.1節で述べたとおり最小全域木として構築されるが、それらのノードの位置は、CFARのハイパーパラメータの設定に依存する。そのため、ノードの位置は分散が大きくて正解が一意に定まらないという問題が生じる。これを解決するために、 $\mathbf{N}^*_j$ はクラッタグラフの各ノードを1点ではなく、これらを頂点とする分散 $\sigma$ の二次元混合ガウス分布とし、 $\mathbf{E}^*_j$ は各エッジ上の信号電力に基づいて生成されるベクトル場として設計した(図2(b)~(e))。これによって、CFARのパラメータ等に大きく依存しない学習を可能にした。



○ クラッタグラフのノード(CFARで検出したクラッタプロット)  
 — クラッタグラフのエッジ

図2. クラッタグラフ及び正解特徴マップ




図4. 開発方式によるRDマップ上のシークラッタ及び電離層クラッタのセグメンテーション結果

### 3.3 推定プロット集合の周辺領域探索による領域セグメンテーション

推定したクラッタグラフごとに、その周辺領域の探索を行うことで、RDマップ上で各クラッタ領域の詳細なセグメンテーションを行う。この研究では、周辺領域の探索の方法としてグラフカット<sup>(2)</sup>を用いた。グラフカットはあらかじめ大まかに指定した前景領域と背景領域を基準として、それらの境界を求めるための最小切断問題を解くアルゴリズムである。開発方式では、CNNで推定したクラッタグラフを前景領域として、前景領域と一定の距離 $d$ 以上離れた領域を背景領域として設定した上で、グラフカットを適用した。

## 4. 評価実験

開発方式の有効性を示すための評価実験について述べる。実験で使用したデータは、国土交通省の海洋レーダを用いて東京湾の横浜大黒埠頭(ふとう)局から発せられている反射波を受信して得た信号である。表1に実験で用いたHFレーダの諸元を示す。教師データ生成時のCFARは、クラッタに複素ガウス分布を仮定するCA-CFAR(Cell-Averaging CFAR)を用いた。また、ノード・エッジネットワークはそれぞれ5層のCNNで構築し、学習時のエポック数を50とした。データセットとして $R=512$ 、 $V=100$ のRDマップを1,000枚用意し、これを学習用データと評価用データに9:1の割合で分割した。正解特徴マップ生成時の分散を $\sigma=1$ 、領域探索時の距離を $d=10$ とした。また、評価指標として、各データの領域推定結果と正解データとの重なり度合いを評価するmIoU(mean Intersection

表1. レーダの諸元

項目	値
最大探知距離(km)	250
ドップラー周波数(Hz)	$[-1, 1]$
チャープ信号のスweep幅(kHz)	100

表2. セグメンテーション評価結果

指標	シークラッタ	電離層クラッタ	平均
mIoU	0.906	0.751	0.829

over Union)を用いた。この指標は $[0, 1]$ の範囲で1に近いほど高精度であることを表す。

表2にmIoUの評価結果を示す。この結果からどちらのクラッタも高精度に領域推定ができていることが確認できる。また、図4にセグメンテーションの可視化結果の一例を示す。各推定結果から、RDマップ内のクラッタ領域をクラスごとに正しく検出できることを確認した。また、矩形(くけい)ではなく適切な形で推定可能なことを確認した。

## 5. むすび

HFレーダの信号を処理して得られるRDマップ上の異種クラッタのセグメンテーションを行う異種クラッタ領域検出技術について述べた。実験の結果、RDマップ内のシークラッタ及び電離層クラッタの領域をそれぞれ推定可能なことを確認した。

### 参考文献

- (1) Ian, G., et al.: Deep Learning, The MIT Press (2016)
- (2) Camille, C., et al.: Power Watershed: A Unifying Graph-Based Optimization Framework, IEEE Trans. on Pattern Analysis and Machine Intelligence, **33**, No.7, 1384~1399 (2011)