

# ブースティングによる機械学習に基づく海底物体の検出

正会員 丹 康 弘\*      タン ジュークイ\*  
金 亨 燮\*      石 川 聖 二\*

## Detection of Underwater Objects Based on Machine Learning

by    Ysuihiro Tan, *Member*      Joo Kooi Tan  
      Hyungseop Kim                    Seiji Ishikawa

### Summary

Side-scan and forward looking sonars are some of the most widely used imaging systems for obtaining large scale images of a seafloor, and their use continues to expand rapidly with their increasing deployment on Autonomous Underwater Vehicles. However, it is difficult to extract quantitative information from the images generated from these processes, in particular, for the detection and extraction of information on the objects within these images. We propose in this paper an algorithm for automatic detection of underwater objects in side-scan images based on machine learning employing adaptive boosting. Experimental results show that the method produces consistent maps of a seafloor.

## 1. 結 言

海底上の物体およびその位置の検出は、船舶航行の安全のために欠くことのできない重要な調査である。海底物体を検出する手法を大きく分類すると、光学機器を使用する手法、超音波を利用する手法、そして AUV (Autonomous Underwater Vehicles) を使用する手法に分けられる。なかでも水中での光伝搬の制限により、超音波を利用したソナーは、商用および軍事用ともに水中システムの重要な装置である。水中での可視性が悪い場合、ソナーシステムは、光ではなく超音波を使用することによって、より遠くの水中環境を明瞭に観察することを可能にし、水中を画像化する。一般的なソナーシステムの応用分野としての海底物体の検出は、沿岸域、また考古学や海洋科学など様々な分野で大きな課題となっている。従来の解析手法は、どの分野でも熟練した技術者が行っているのが現状である。これは、画像中に通常存在するノイズや、画像が環境により大きく変動する等のため、サイドスキャンソナー画像からの自動オブジェクト検出が困難であることに起因する。

サイドスキャンソナー画像を用いた海底物体の検出例は、海底の遺失物探査や海底面上の岩の分布状況判別等がある

が、それらのほとんどは、海底上の物体によって投影された影の特性を利用している<sup>1)</sup>。図 1 はサイドスキャンソナーによる画像生成のイメージである。物体は通常、背景よりも高い反射率を持つため、物体表面からの戻り値は、背景よりも高い値を示す。ソナー画像は、その値を用いて画像化する性質を持つ。

その他の手法としては、特別なハードウェアを搭載 (Computer Aided Detection/ Computer Aided Classification: CAD/CAC) すれば<sup>2)</sup>、単一の検出アルゴリズムに対して相対的に誤検出率を減少させるのに有効であることが示されている。

ソナー画像からの水中物体検出法として従来は主にニューラルネット<sup>3)</sup>が用いられていたが、海底物体の物体画像には対応していなかった。最近では、Sawas<sup>4)</sup>、Aulinas ら<sup>5)</sup>によって Haar 型特徴を用いた海底物体検出法が提案されているが、実験対象が実環境ではないこと、物体の検出に時間がかかることが問題点である。このため、実環境でのリアルタイム検出には不向きと言える。

そこで本論文では、サイドスキャンソナー画像の解析に、Haar 型特徴とカスケード型 AdaBoost による機械学習処理<sup>6)</sup>を用い、学習に用いる画像から得られる特徴量をクラスタリングし、Haar 型特徴のパターン数を最小限にすることにより、より高速に海底物体を検出する手法を提案する。また提案法を海底 (砂地盤および泥地盤) の実物体画像の検出に適用することにより、提案法の有効性を示す。

\* 九州工業大学大学院工学府




Fig. 1 Formation of an image by a side-scan sonar image.

以下、第 2 節では提案手法を説明する。また、第 3 節で様々な海底地形のサイドスキャンソナー画像に対する実験結果を示して考察を与え、第 4 節で結論を述べる。

## 2. 海底物体の検出

### 2.1 海底画像の獲得と前処理

サイドスキャンソナーを調査船で曳航し、海底面に向けて音波を発振し、その音波の反射強度の差を濃淡で映し出すことにより、海底を画像として表現する。海中を音波が伝搬していく過程では、音響エネルギーが他のエネルギーに変換されることによって減衰が生じる。これは吸収損失と呼ばれる<sup>7)</sup>。また、適切な検出を行うために、画像の前処理として、物体のエッジを保持したままノイズの軽減を行うエッジ保存フィルタ処理を行う。これは画像中の画素近傍の画素値の分散を計算し、分散値が閾値以下となる方向の画素の画素値を平滑化することにより、エッジを保持したままノイズを軽減させる手法である。海底のサイドスキャンソナー画像に前処理を行った例を図 2 に示す。同図(a)が原画像、(b)が前処理後の画像である。

### 2.2 Haar 型特徴と AdaBoost による機械学習

本研究では、画像特徴として Haar 型特徴、識別器構成法として AdaBoost、また高速処理のために、カスケード構造を持つ識別器を用い、使用する Haar 型特徴を k-means 法によるクラスタリングを用いて高速に海底物体を検出する手法を提案する。Haar 型特徴と AdaBoost による機械学習を用いた海底物体認識手法は、Sawas ら<sup>4)</sup>、Aulinas ら<sup>5)</sup>によって提案されたが、それらと提案手法の主な相違点は、Haar 型特徴の選択法である。

#### 2.2.1 特徴量の抽出

サイドスキャンソナー画像に映る海底物体のほとんどは以下のような共通の性質を持つ。

- (1)物体と影が対になっている。
- (2)影の領域は物体よりも暗い。
- (3)影の領域は背景よりも暗い。
- (4)物体領域は背景よりも明るい。
- (5)影はソナーから発射されたビームに対して反対方向

(横方向)にのみ生成される。

これらの特徴は物体検出を行う上で有益な基本情報である。これらの特徴を抽出するために、サイドスキャンソナーからの音波発信方向を考慮し、図 3 に示す Haar 型特徴を使用する。特徴量の値は、白い方形内の明度平均値と黒い方形内の明度平均値の差で表現される。Haar 型特徴に基づく弱識別器を次式で定義する。

$$h_i(x) = \begin{cases} +1 & \text{if } p \cdot z(x) > p \cdot \theta \\ -1 & \text{otherwise} \end{cases} \quad (1)$$




Fig. 2 Preprocessing of a side-scan sonar image: (a) An original image, (b) the processed image.




Fig. 3 The Haar-like feature employed in the proposed method: Schematic formation of relation(object/shadow).

ここで、 $z$  は 1 つの Haar 型特徴から算出される特徴量であり、 $\theta$  は閾値である。また、 $p$  は特徴量  $z$  と閾値  $\theta$  を比較する不等号の向きを決定する変数で、+1 もしくは -1 の値をとる。なお、Haar 型特徴の計算では、高速化のためにインテグラルイメージ<sup>8)</sup>を用いる。インテグラルイメージとは、原点(0,0)からピクセル( $i, j$ )までの濃淡値を式(2)を用いて総和した画像である。図 4 にインテグラルイメージを示す。

$$F_p \equiv F(i, j) = \sum_{ii=0}^i \sum_{jj=0}^j f(ii, jj) \quad (2)$$

求める明度領域が何度も出現し、様々な領域の明度を求める場合、領域中の計算が重複してしまい演算時間が非常に多くかかるため、あらかじめ明度マップを作成しておく手法がインテグラルイメージである。これにより、任意矩形で囲まれる明度の積分値を一定時間で求めることができる。




Fig. 4 Using the integral image, the sum of gray values within D can be computed as  $F_4+F_1-(F_2+F_3)$ .

### 2.2.2 Haar 型特徴の決定

Sawas, Aulinas らによって行われた Haar 型特徴と AdaBoost による機械学習を用いた海底物体認識手法は、海底物体から伸びる影に対応するため、様々な形状の Haar 型特徴を使用している。海底物体画像は、影の長さによって画像中の明部と暗部の比率が異なる (図 3)。そこで、Haar 型特徴のパターン数を最小限に抑えるため、海底物体画像のヒストグラムを算出し、明部と暗部の分離度を計算後、 $k$ -means 法により、パターンを最小限にクラスタリングする。クラスタリングされた分離度を Haar 型特徴の明部と暗部の比率とする。本手法の概要を図 5 に示す。

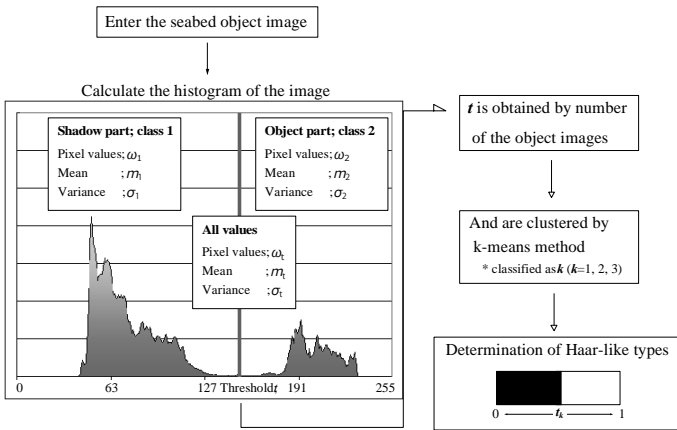


Fig. 5 Schematic diagram of the proposed method.

海底物体画像のヒストグラムは明部と暗部で、閾値  $t$  でクラス分けでき、閾値よりも輝度値が小さい側 (黒クラス) の画素数を  $\omega_1$ 、平均を  $m_1$ 、分散を  $\sigma_1$ 、輝度値が大きい側 (白クラス) の画素数を画素数を  $\omega_2$ 、平均を  $m_2$ 、分散を  $\sigma_2$ 、画像全体の画素数を  $\omega_t$ 、平均を  $m_t$ 、分散を  $\sigma_t$  とするとき、クラス内分散 (within-class variance)  $\sigma_w^2$  は次式で表される。

$$\sigma_w^2 = \frac{\omega_1 \sigma_1^2 + \omega_2 \sigma_2^2}{\omega_1 + \omega_2} \quad (3)$$

また、クラス間分散 (between-class variance)  $\sigma_b^2$  は、

$$\sigma_b^2 = \frac{\omega_1 (m_1 - m_t)^2 + \omega_2 (m_2 - m_t)^2}{\omega_1 + \omega_2} \quad (4)$$

で表される。このとき、クラス間分散とクラス内分散との比である分離度  $\sigma_b^2 / \sigma_w^2$  が最大となる  $t$  が閾値となる。

海底物体の学習画像の数だけ閾値  $t$  を算出し、 $k$ -means 法により  $t$  をクラスタリングする。 $k$ -means アルゴリズムは、十分な数の個別ケースがある場合に、事前に決められた  $k$  クラスにデータをクラスタリングするアルゴリズムである。

$k$ -means クラスタリングの手法を以下に示す。

$k$  個のクラスに分割するとき、

**Step1.**  $t$  個の点からランダムに  $k$  個の点を選択し、クラスタ中心の初期値とする。次いで、全てのデータ点をそれぞれ最短距離のクラスタ中心に割り振ってグ

ループ分けをする。各グループが 1 つのクラスタとなる。

**Step2.** 各グループに含まれるデータ点の平均値を求め、当該クラスタのクラスタ中心の更新値とする。

**Step3.** 全てのデータ点をそれぞれ最短距離のクラスタ中心に割り振ってグループ分けをする。グループ分けに変動がなかった場合は、それら  $k$  個のクラスタを出力して終了する。変動があれば **Step2** に戻る。

クラスタリングされた  $t_k (k=1, 2, \dots)$  を基に Haar 型特徴を決定する。 $k=3$  の場合の Haar 型特徴を図 6 に示す。




Fig. 6 Determination of Haar-like type features.

### 2.2.3. AdaBoost

AdaBoost はパターン識別のための学習アルゴリズムであり機械学習による汎化能力を得る手法の一つである。汎化能力とは学習用のデータ以外の未知のデータに対しても正しくアルゴリズムが作用する能力のことである。AdaBoost は実装が容易で高い識別性能が得られる利点がある。逐次的に学習サンプルの重みを変化させながら異なる識別器を作り、これら複数の識別器の重み付き多数決によって最終的な識別関数を与える。個々の識別器は弱識別器 (weak classifier) と呼ばれ、それらを組み合わせたものは強識別器 (strong classifier) と呼ばれる。単純で弱い識別器を逐次的に学習し、識別器の精度を増強 (Boost) する方法を総称して Boosting と呼ぶ。AdaBoost は適応的 (adaptive) にサンプルの重みを更新し、学習を行う Boosting アルゴリズムの一種である。弱識別器を  $h_t(x) (t=1, 2, \dots, T)$  とすれば、強識別器  $H(x)$  は次式で定義される。

$$H(x) = \text{sign} \left( \sum_{t=1}^T \alpha_t h_t(x) \right) \quad (5)$$

ただし、

$$\text{sign}(w) = \begin{cases} 1 & \dots > 0 \\ -1 & \dots \leq 0 \end{cases} \quad (6)$$

である。 $H(x)$  の値が +1 なら海底物体、-1 なら非海底物体と判定する (図 7 参照)。




Fig. 7 Classifier obtained by AdaBoost.

2.3 カスケード構造

カスケード構造の識別器は図 8 に示すように、N 個の強識別器( $H_n(x); n=1,2,\dots,N$ )を直列に接続したものである。画像をスキャンする操作ウィンドウ(sub-window)を入力とし、そのウィンドウ内に物体が含まれるか否かを識別する。第  $n$  段の強識別器  $H_n(x)$  は次式で定義される。

$$H_n(x) = \text{sign} \left( \sum_{t=1}^{T_n} \alpha_{n,t} h_{n,t}(x) - \theta_n \right) \quad (7)$$

ただし、 $h_{n,t}(x)$  は第  $n$  段に選択される  $t$  番目の弱識別器、 $T_n$  は第  $n$  段に選択される弱識別器の個数、 $\alpha_{n,t}$  は弱識別器  $h_{n,t}(x)$  の重み、 $\theta_n$  は第  $n$  段における閾値である。




Fig. 8 Schematic model of the cascade classifier.

カスケード前段に配置される識別器の役割は単純な背景領域を棄却することである。物体と単純な背景領域を区別するには、ごく少数の弱識別器があればよく、非常に小さい計算コストで画像の大部分を棄却し、次の位置のウィンドウの識別処理に移ることができる。後段の識別器は、前段で棄却されなかった複雑な背景と物体を区別できるように、より多くの弱識別器を用いる。最終段の識別器を通過したウィンドウのみが、物体であると判定される。物体検出は、画像を限なくスキャンする必要があるが、ほとんどの領域に物体は存在しない。また、背景領域の大部分は物体と明らかに異なるパターンを含んでいるため、即時棄却という考え方により高速化を実現でき、提案法では、さらに Haar 型特徴の個数の低減を図ることによって、一層の高速化を実現している。

カスケードの各段において、学習用物体画像を通過させる割合(物体画像通過率)を  $D_r$  ( $0 < D_r < 1$ )、学習用非物体画像を通過させる割合(非物体画像通過率)を  $F_p$  ( $0 < F_p < 1$ )とすると、カスケード  $n$  段通過後は、学習用物体画像は  $D_r^n$ 、学習用非物体画像は  $F_p^n$  だけ通過していることになり、例えば

$D_r = 0.999$ ,  $F_p = 0.5$  とした場合、 $n = 40$  のカスケード型識別器は学習用物体画像通過率は  $D_r^n = 0.999^{40} \approx 0.96$ 、学習用非物体画像通過率は  $F_p^n = 0.5^{40} \approx 10^{-13}$  となり、学習用物体画像をほとんど通過させ、学習用非物体画像をほとんど通過させない検出器となる。

3. 実験結果と考察

実験は実環境で得られたサイドスキャンソナー画像を用い、海底上に設置されている漁礁の探査を行う。設置されている漁礁は、金網製のかご状構造物の内部に自然石や碎石を中詰した広域型岩礁の漁礁である。使用したサイドスキャンソナーのスペックを表 1 に示す。探査範囲は泥地盤と砂地盤の 2 箇所の範囲で行った。

ソナーを調査船の船尾より投入後、幅約 300m、長さ 2000m の範囲を探査し、海底画像を取得した。探査範囲の水深は約 20m であった。ソナーの曳航深度を水面から 12m~14m の一定間隔に調整し、探査を行った。総航行時間は約 8 時間であった。この探査によって海底面は概ねフラットであることが判明した。サイドスキャンソナーによる海底画像を図 10(a)に示す。

Table 1 Specifications of sonar.

Towfish	
Frequency	340 kHz
Horizontal beamwidth	0.9 deg
Vertical beamwidth	60 deg
Range resolution	10 cm
Max operating depth	100 m
Max cable length	200+ m
Materials	Stainless steel, PVC and Polyurethane





Fig. 9 Snapshot of the objects on a seabed.

3.1 物体検出

$k$ -means 法によるクラス数  $k$  は試算した結果 3 とした。従来研究での Haar 型特徴の数は 4-7 個であるのに対して、提案手法では 3 個と低減された。  $k$ -means 法により決定した  $t_k$  の値を表 2 に示す。

物体を検出するためのカスケード型分類器の訓練画像は、物体画像 (24x32pixels; 3m x 4m に相当) が 4000 枚、また非物体画像が 1000 枚である。ただし、4000 枚の海底物体画像を準備するのは困難であるため、明るさを変化させた画像を作成し、物体画像を増加させた。図 9 に物体画像の例を示す。



**Fig. 10** Seabed objects on a side-scan sonar image and the result of the detection: (a) Original image, (b) detected objects, (c) rectangles indicating only the objects.


**Table 2** The value of threshold( $t_k$ ) determined.

The value of threshold determined	
$t_1$	0.6857
$t_2$	0.6357
$t_3$	0.5714

また、様々な大きさの海底物体を漏らさず検出する必要があるため、操作ウィンドウの大きさを 0.8 倍から 1.2 倍まで 0.1 倍刻みで変化させた。学習画像の大きさが 24x32pixels であることから、操作ウィンドウの変化率を 0.1 倍刻みとした。演算に使用した PC は 4GB メモリ、2.66GHz のインテル Core 2 Duo プロセッサである。海底物体の検出には約 60-95msec を要した。泥地盤での検出結果を図 10(b)に示す。


泥地盤に設置された物体の検出だけでなく、砂地盤に形成されているサンドウェーブ (砂の波紋) 上に設置された海底物体の検出も目視観測と比較しても良好であった。泥地盤、砂地盤それぞれの検出結果の代表例を図 11 に示す。

表 3 は 2 つの海域における物体の検出結果である。2 箇所 の範囲を探索した結果、目視観測結果を真値とした場合、第 1 の海域 (砂地盤) には 124 個の海底物体が存在し、目視結果と一致したのは 110 個であった。検出した正答率は 88.7% であった。次に第 2 の海域 (泥地盤) では 17 個の海底物体が存在し、目視結果と一致したのは 13 個であった。検出した正答率は 76.5% であった。表 3 中の誤検出 (False Objects) とは、検出したが、誤った箇所を検出した数と検出そのものができなかった数の合計である。



(a) Seabed object on the mud. (b) Seabed object on the sandy bottom.

**Fig. 11** Detection result of the seabed objects on the mud flat board and the sandy area board.



(a) Successful

(b) Failed

**Fig. 12** Examples of successful and failed detection.

**Table 3** Performance of the detector

	Sea area 01	Sea area 02
Total Objects	124	17
Detected True Objects	110	13
False Objects	14	4
Accuracy rate	88.7%	76.5%
<b>Average</b>	<b>82.6%</b>	

**Table 4** Comparison of the detection time of objects.

Detection time	
J. Sawas, et. al. <sup>4)</sup>	141-205msec
<b>Proposed method</b>	<b>65-90msec</b>

海底物体を認識できなかった箇所の原因として、海底物体の影の長さが十分ではなかったことがあげられる。これは、Haar 型特徴が黒領域と白領域の差を特徴量としており、物体画像が物体でも影でもない灰色の領域を含むため、用意した Haar 型特徴パターンでは濃淡値の差が十分に出ないことが原因である。検出成功例と失敗例を図 12 に示す。また、提案手法による検出時間と Sawas 手法による海底物体の検出時間を表 4 に示す。検出にかかった時間は 65msec-90msec と Sawas らの手法に比べ高速であった。またこの結果は、探知性能を落とさずに検出時間の短縮を実現している。従って、本提案手法は海底物体の高速検出に有効であり、海底物体検出の実時間処理につながるものである。

### 3.2 精度の検討

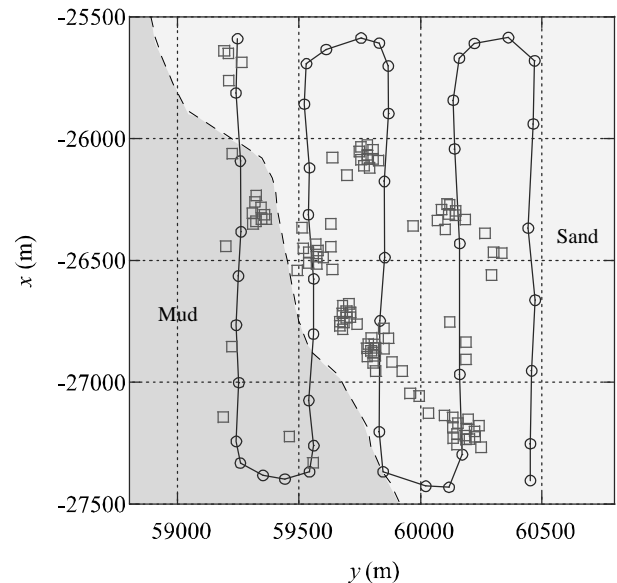
提案法を実環境で使用するには、位置精度が問題となる。ソナーを曳航する調査船には GNSS (Global Navigation Satellite Systems) が搭載されており、船舶の位置およびソナーの位置情報が得られる。そこで、この船舶の位置情報を基に、海底上の物体の位置と提案手法により検出された海底物体の位置を比較し、精度の検討を行った。なお、比較検討を行う際、海底上の物体は、金網製のかご状構造物の内部に自然石や砕石を中詰した広域型岩礁の漁礁(一辺約 3m の立方体)で画像中から目視で確認し、設置位置情報は音響画像中の物体中心の位置情報より取得した。

提案手法により検出された物体を囲む矩形は影を含んでおり、物体だけを囲む矩形が必要である。そこで、ソナーから発射されたビームは物体の側面のみで反射され、その幅は矩形領域の縦方向にほぼ一致するという特性に注目した。矩形領域中の海底物体側面側の一点を原点として、矩形の横方向の長さを矩形の縦方向の長さに一致させ正方形とした。ただし、この正方形は海底物体の輪郭を正確に捉えているとは限らないため、その正方形中の物体画像のエッジを強調し、輪郭のエッジに沿うように正方形をさらに変形し、物体を囲む矩形とした。その結果を図 10(c) に示す。また、隣り合う測線間で同一物体を検出しても、同時に検出するわけではないため、右舷側、左舷側で別々に検出結果を出力した際に検出座標値が許容誤差範囲である  $\pm 1.5\text{m}$  以内は同一物体であると判定 (物体の大きさ 3m, GNSS の精度 1m-2m であるため) し、マージ処理を行った。

検出された物体を囲む矩形の重心を計算し、実際に設置されている物体の設置位置情報と比較した。精度の比較結果を表 5 に示す。設置位置と検出位置の平均誤差は 0.501m で

**Table 5** Errors between the positions of the detected objects and their installed positions.

Unit (m)	
Number	Error value
1	0.259
⋮	
109	0.188
110	0.547
Average	0.501
Max error	0.615



**Fig. 13** Location of the detected objects on the seabed and the trajectory of a research vessel. The line shows the trajectory, whereas the dot indicates the objects. The  $x$ - $y$  axes show the Japan Geodetic Datum 2000.

あった。また、最大誤差は 0.615m であった。一般に海底探査には GNSS が使用されており、その位置精度はカタログ値で水平方向へ 1m から 2m の誤差であることを考慮すれば、本手法の位置誤差は良好であると考えられる。ただし、調査船より曳航しているケーブルは十分に長いことと、波浪中は調査を行わないため、調査船の波浪による動揺は考慮していない。物体の検出位置と調査船の航跡を図 13 に示す。青い線は航跡を示し、赤い点は海底物体を示す。また、図中の点線は、底質の砂-泥の境界を示している。なお、 $x$ - $y$  軸は日本列島を 19 の系に分けた測量座標の世界測地系 (JGD2000; I) を示している。

## 4. 結言

本論文では、サイドスキャンソナー画像中の海底物体検出を目的として、Haar 型特徴とカスケード型 AdaBoost による機械学習処理を用い、 $k$ -means クラスタリングによる従来法より少数の Haar 型特徴を用いて物体検出を行う手法を提

案した。提案法を、実海底物体を含む海底画像（砂地盤および泥地盤）に適用する実験によって、その有効性を示した。特に、 $k$ -means クラスタリングによる Haar 型特徴を用いて、従来法より高速な、実時間処理につながる海底物体検出を実現した。なお、海底地盤の状況（砂地盤、泥地盤）ごとの海底物体検出結果のデータは過去の文献には見られない。この点も本論文の特徴である。

海底画像中の影を含む海底物体の形状と Haar 型特徴の相性の良いことが、海底物体の検出に有効であったと考えられるが、影を形成しないような海底物体（例えば、板状物体）には別の手法を考える必要がある。

提案手法は  $k$ -means 法を用いており、分類クラス数  $k$  は経験則によりマニュアルで決定した。今後は、分類クラスをデータ群より自動で分類する教師なしクラスタ分類法の一つである SOM (Self-organizing maps)<sup>9)</sup> 等によるクラスタリングを目指す。

また、PCA (Principal Component Analysis) や ICA (Independent Component Analysis), あるいはその両方を用いて<sup>10)</sup>、原画像の明度やコントラストに依存しない海底物体検出のための前処理を検討する必要がある。

### 参考文献

- 1) J.M. Bell, E. Dura, S. Reed, Y.R. Petillot, D.M. Lane , "Extraction and classification of objects from sidescan sonar," [http://dsor.isr.ist.utl.pt/Projects/Exocet/Priv/Bibliography/CollectedByUAlg/NLNGSP\\_02.pdf](http://dsor.isr.ist.utl.pt/Projects/Exocet/Priv/Bibliography/CollectedByUAlg/NLNGSP_02.pdf), accessed 2011-8-19.
- 2) C. M. Ciany, W. C. Zurawski, I. Kerfoot, "Performance of fusion algorithms for computer-aided detection and classification of mines in very shallow water obtained from testing in navy Fleet Battle Exercise-Hotel 2000", Proc. of SPIE/OI, Vol. 4394, Orlando, Florida, 16-20, pp.1116-1122, April, 2001.
- 3) S. W. Perry, L. Guan, "Pulse-length-tolerant features and detectors for sector-scan sonar imagery", IEEE Journal of Oceanic Engineering, vol. 29, no. 1, pp. 138 - 156, January, 2004.
- 4) J. Sawas, et. al. , "Cascade of Boosted Classifiers for Rapid Detection of Underwater Objects", ECUA 2010 Istanbul Conference, 2010.
- 5) J.Aulinas, et. al., "Robust automatic landmark detection for underwater SLAM using side-scan sonar imaging", Proceedings of the 11th International Conference on Mobile Robots and Competitions, pp.21-26, 2011.
- 6) P. Viola, M. J. Jones, "Rapid object detection using a boosted cascade of simple features", Proc. of IEEE CVPR, vol.1, pp.511-518, 2001.
- 7) Ainslie M. A., McColm J. G., "A simplified formula for viscous and chemical absorption in sea water", Journal of the Acoustical Society of America, Vol.103, No.3, pp.1671-1672, 1998.
- 8) P. Viola, M. Jones, "Robust real-time object detection," Proc. of Workshop on Statistical and Computational Theories of Vision, 2001.
- 9) T. Kohonen, "Self-Organizing Maps", Springer, 2000, ISBN 978-3540679219.
- 10) M. S. Bartlett, J. R. Movellan, T. J. Sejnowski, "Face recognition by independent component analysis," IEEE Trans. on Neural Networks, Vol. 13, No. 6, pp. 1450-1464, 2002.