

ソナー画像に対する物体探知における アンサンブルを用いた汎用性向上の取り組み

Improving versatility using ensemble in object detection from sonar images

辰巳 嵩豊[†] 樋口 晴彦[†] 秋山 靖浩[†] 佐藤 慎祐[†]
Takato Tatsumi Haruhiko Higuchi Yasuhiro Akiyama Shinsuke Sato

1. はじめに

水上交通の安全確保等のため投棄物の検知・除去を目的にソナーを用いた水中の物体探知が行われている。探知対象となる場所が広大であることから、水中の物体を自動かつ高探知率・低誤探知率で探知する仕組みや無人機での運用が求められている。深層学習を用いてソナー画像から対象を検知する手法が開発されている[1]。

一方で、地理的状況やソナー深度（水面・水中・水底）の条件により、水中における音波の進み方や岩や水面による反射・散乱の影響が異なる。そのため、探知対象である標的の信号と対象外である背景（水面反射や水底反射）の信号が類似する場合があります、それぞれの条件で取得されたデータを統合した汎用的な物体探知モデルの生成は困難である。この場合、複数の識別器（弱学習器）の組み合わせるアンサンブルが汎用性向上の一手法として考えられるが、複数の弱学習器を動作させると処理時間が増大するため、リアルタイムな物体探知等ではより少ない数の弱学習器で汎用性を向上することが求められる。本研究では、少ない弱学習器で汎用性が高くなる組み合わせを選択する手法を提案する。オープンデータの分割により、実データにおける非共通性を模擬したデータを用い有効性を検証する。

2. 提案手法

説明のために、場所や対象物体の条件に基づき 5 つに分割されたデータ（表 1 における Data A～E）を想定する。まず、それぞれのデータを用いて弱学習器としての識別器を生成する（表 1 における Model 1～5）。弱学習器それぞれにおいてそれぞれのデータを対象に推論を行う。その推論結果から着目指標（探知確率(TPR)や誤検知確率(FPR)等）を求める。表 1 の例では Model も Data も 5 つずつあるため 25 個の指標が求まる。ここでの指標として、例えば探知確率など、値が大きいほど望ましいものを想定して説明する。

表 1 弱学習器の評価

	Model 1	Model 2	Model 3	Model 4	Model 5
Data A	○	○			
Data B		○			
Data C			○		○
Data D			○	○	○
Data E					○

上記の指標の値を用いて提案手法は汎用性が高いモデルの組み合わせを選択する。指標値に対して閾値以上を満たすか満たさないかを判定する。表 1 において○印が付いたセルが閾値以上を満たした指標値が求まった結果を、○印

[†] 株式会社 日立製作所 Hitachi, Ltd.

が付いていないセルが閾値以上を満たさなかった指標値が求まった結果を表す。

○印が多くデータでつくようにモデルを選択する。表 1 の例では、Model 2 は Data A, B に○印が付き、Model 5 は Data C, D, E に○印が付いており、Model 2 と 5 を組み合わせれば 5 つに○印が付くことになる。提案手法はこの Model 2 と 5 の組み合わせを選出する。つまり、○印の被りが少ないモデルの組み合わせが汎用化に効果的だとして選出される。選出されたモデルの解を統合したものを解とするアンサンブルは汎用性が高いと期待される。一方で、Model 1 と 2 や Model 3 と 5 など○印が少数あるいは被りが多い組み合わせは汎用性向上の期待が薄いため提案手法では選出されない。

3. 評価実験

3.1 評価対象タスク

Forward-Looking Sonar Marine Debris Datasets [2] の watertank-segmentation のデータを加工・分割し、分割データ間で共通する部分と共通しない部分があるタスクを模擬した。図 1 にデータ例を示す。赤枠で囲った部分が検知対象 (Bottle と Tire) である。

データセットには 10 のクラスがあるが、その中でもデータ数が多く、相互に被るデータ数が少ない 5 つのクラス (Bottle, Can, Chain, Drink-carton (以下 DC), Valve) によってデータを分割した。ただし、上記 5 クラスの内 2 つ以上が含まれるデータは対象から外し、Tire などその他のクラスは分割の条件に寄与せず、それぞれの分割データに含まれる。さらにクラス分けを廃し 1 クラスの物体探知タスクとした。また、評価指標は探知確率(TPR)とし、5 つの分割データ (Bottle, Can, Chain, DC, Valve) における平均値の高低によって提案手法の有効性を評価する。




図 1 データ例

3.2 実験設定

識別器として YOLOv8 [3] を用いた。ハイパーパラメータは学習回数: 200 epochs、バッチサイズ: 16、データ拡張: 回転とした。分割データの内 50% を学習、30% を評価(test)、20% を検証(validation)として用いた。また、本稿では弱学習器の採否に用いる閾値を 0.6 とした結果を示す。

3.3 実験結果

表 2 に 5 つのクラスそれぞれで学習した弱学習器の探知確率を示す。閾値 0.6 以上の探知確率となった結果が下線ありのセルで示されている。下線ありのセルは表 1 の○印にあたり、例えば Bottle モデルにおいて Bottle, Can, DC データで閾値以上の探知確率であることを示す。

表 2 弱学習器の探知確率

		Model				
		Bottle	Can	Chain	DC	Valve
Data	Bottle	<u>0.93</u>	0.48	<u>0.74</u>	0.58	<u>0.65</u>
	Can	<u>0.68</u>	<u>0.89</u>	0.23	0.45	0.41
	Chain	0.36	0.39	<u>0.92</u>	0.39	0.45
	DC	<u>0.74</u>	<u>0.61</u>	<u>0.43</u>	<u>0.93</u>	0.23
	Valve	0.59	0.42	0.45	0.09	0.90

提案手法により選出される組み合わせは、2 モデルの場合は下線ありのセルが 4 データの(Bottle + Chain), (Bottle + Valve), (Can + Chain), (Can + Valve)となった。また、3 モデルの場合は下線ありのセルが 5 データの(Bottle + Chain + Valve), (Can + Chain + Valve)となった。一方で(Bottle + Can)や(Can + DC)等は下線ありのセルが少ないため選出されなかった。選出されない組み合わせ及び選出される組み合わせから(Can + DC), (Can + Chain), (Can + Chain + Valve)における探知確率を表 3 に示す。また、選出されたモデルの一例 Can, Chain, Valve)を白塗りのセルで強調する。(Can + DC)ではデータ Chain 及び Valve において閾値を下回ったが、(Can + Chain)では 5 データ全てで閾値以上となった。

表 3 アンサンブルの探知確率

		Model		
		Can + DC	Can + Chain	Can+Chain+Valve
Data	Bottle	0.78	0.86	0.87
	Can	0.90	0.89	0.90
	Chain	0.50	0.92	0.92
	DC	0.93	0.76	0.79
	Valve	0.43	0.79	0.93
Average		0.71	0.84	0.88

図 2 にアンサンブルの全組み合わせにおける探知確率の平均値をプロットしたものを示す。組み合わせ数 1 は表 2 に示されている各弱学習器を、組み合わせ数 2 は(Can + Chain)などの 2 つのモデルを組み合わせたものが該当する。組み合わせ数が増えるほど全体的に TP 精度が向上していた。組み合わせ数が 2 の場合には平均 TP 精度が 0.71 から 0.84 の間に分布していた。TP 精度が 0.71 となったのは (Can + DC)であり、0.84 となったのは(Can + Chain)である。また、上記で述べた 2 モデル 3 モデルにおいて選出された組み合わせも(Can + Chain)と同様に高い TP 精度となったことから、提案手法は汎用性が高い組み合わせを選出できると認められる。解の統合よりも推論に時間を要するため、提案手法によって選出されたモデルによってアンサンブルを構成することで、5 モデルのアンサンブルに対して処理時間が 2/5 あるいは 3/5 程度まで高速化される。




図 2 アンサンブルの平均探知確率

3.4 考察

表 2 よりデータ Chain はモデル Chain でのみ高探知確率となる。表 3 よりモデル Chain が含まれていない(Can + DC)ではデータ Chain に対する探知確率が低く、モデル Chain が含まれている(Can + Chain)ではデータ Chain に対する探知確率が高い。これは、アンサンブルの結果は組み合わせたモデルの結果が統合されたものであるため、組み合わせられた弱学習器のうち一つでも探知できていれば、そのアンサンブルは探知ができることを示している。また、モデル Can 及び Chain は Valve に対する探知確率が低い(Can + Chain)では Valve を含めて閾値以上の探知確率となっている。これはそれぞれのモデルが探知したものに重複が少ないためであると考えられる。しかし、(Can + Chain + Valve)の様にすべてのデータで閾値以上となるようにモデルを選択するとより確実に汎用性を高めることができる。上記より高探知確率となるデータが多くなるようにモデルの組み合わせを選出する提案手法は少ない弱学習器の組み合わせによる汎用性向上に適すると考えられる。

4. おわりに

物体探知タスクにおいて、組み合わせ候補となる弱学習器のそれぞれのデータにおける指標値を用いて、少ないモデルの組み合わせで汎用性が向上する組み合わせを選出する方法を提案した。検証に用いたデータでは 2 つあるいは 3 つのモデルを組み合わせただけで、5 つの条件のデータにおいて探知確率が閾値以上となり少ない数の組み合わせのアンサンブルで汎用化を達成した。今回の検証では探知確率を指標値として用いたが、誤探知率を指標値とし、小さいほど良い値であるため閾値以下となる結果に○印をつけることで同様に提案手法を適用することができる。

今後の課題に、データ取得条件が多様でデータ・モデルが多数となる場合への対応及び閾値の自動設定を実現するモデル組合せの選定自動化、短時間でモデル組み合わせを行うための弱学習器評価の簡略化を挙げ、改良検討を推進する。

参考文献

- [1] M. Sung, H. Cho, T. Kim, H. Joe and S. -C. Yu, "Crosstalk Removal in Forward Scan Sonar Image Using Deep Learning for Object Detection," in IEEE Sensors Journal, vol. 19, no. 21, pp. 9929-9944, 1 Nov. 2019.
- [2] M. Valdenegro, D. Singh, and D. C. Padmanabhan, "Forward-Looking Sonar Marine Debris Datasets." <https://github.com/mvaldenegro/marine-debris-fls-datasets>, 2022.
- [3] G. Jocher, A. Chaurasia, and J. Qiu, "YOLO by Ultralytics." <https://github.com/ultralytics/ultralytics>, 2023.