

レーダ観測波形による目標類別 Auto target recognition using waveform of radar signal

川上かおり† 田中秀俊† 山本和彦†
Kaori Kawakami Hidetoshi Tanaka Kazuhiko Yamamoto

1. まえがき

我々はレーダの反射波から得られる諸特微量から、目標の種類や機種を類別する方法について研究を行っている。今回、諸特微量の一つであるレンジプロファイルの波形を対象に、類別実験を行った。高分解能なレンジプロファイルは、目標を特徴づける強力なパラメータである反射強度分布を与えることから、目標類別に有効であると考えられている。レンジプロファイルによる類別としては、目標の機体長などの特微量をレンジプロファイルから見積もって、機種を類別する方式[1]が提案されているが、本研究ではレンジプロファイル波形の形状そのものを用いて類別を行う。類別方法としてはサポートベクターマシン (SVM:Support Vector Machine) [2]を採用した。SVMは ISAR 画像における目標類別において、有効性が示されている[3][4]。本稿では、レンジプロファイルを対象とした類別実験方法、実験結果、考察について述べる。

SVM にはカーネルという仕組みが存在し、その基本である線形カーネルは、学習データのうち境界付近のみに注目し、2クラスの学習データ間の最小幅 (以下マージン) を最大化する線形判別器である。判別不能な場合には、誤判別される学習データの誤りの度合を示す変数 (スラック変数) が導入される (ソフトマージン)。さらに、非線形カーネルと呼ばれる、高次元空間での線形判別境界を算出する仕組みにより、適用可能な問題が増える。今回の実験では SVM^{light} [5]を用い、カーネルの選択では、実験の第一段階として、基本的枠組みである線形カーネルを採用した。スラック変数の係数に対応するパラメータ (以下 c) は、特に断らない限り、学習データのベクトル長から決まるデフォルト値を用いている。

2. 実験方法

2種のカテゴリ (カテゴリA, カテゴリB) に分類可能な4種の在空移動目標を対象とし、7種類の進行方向 ($90^\circ \sim 180^\circ$, 15度刻み) 毎に、100種の模擬的なレンジプロファイルデータを生成し、類別対象とした。具体的には、目標の進行方向から姿勢を見積り、その姿勢周辺のレンジプロファイルを100回のモンテカルロシミュレーションにより生成した。類別対象となる信号データ数は、 $7 \times 4 \times 100 = 2,800$ となる。なお、レンジプロファイルのデータ長は、全て 1,024 セルとする。また今回の実験では、レンジプロファイルの観測可能範囲はノイズ等の影響がない条件を前提とし、理想的な観測可能範囲とした。

ここで SVM では、属性数の増加に伴い、属性数に見合った数の学習データが必要とされる。ところが、今回の対象データでは、属性数が 1,024 程度であるのに対し、学習

対象とする参照信号数は各カテゴリ (カテゴリA/カテゴリB) で、高々100程度である。そこで今回の実験では、このような課題を克服するために、SVMの基本的な枠組みの一つである Leave-One-Out 実験を行った。Leave-One-Out 実験では、 n 個のデータのうち、 $n-1$ 個を学習データ、残り 1 個を類別対象データ (以下、テストデータ) として学習/類別処理を行う。この操作を、 n 個のデータ全てがテストデータになるよう n 回繰り返す。以上の処理を行うことにより、限られた学習データでの類別性能評価が可能となる。

また、各カテゴリが複数の機種からなる場合、大きく分けて「(同一カテゴリ間も含む) 機種間の類別」と「カテゴリ間の類別」が考えられるが、今回は実験の第一段階として、カテゴリ間の類別のみを対象とした。さらに、カテゴリ間の類別では、類別平面の構築を「カテゴリ間」に行う方法と、「異なるカテゴリに属する機種間 (カテゴリAの機種 A1 とカテゴリBの機種 B1)」に行う方法にわかれる。ここで一般的に、カテゴリ間に比べ、機種間に類別平面を構築する方が、比較的単純な類別平面となる可能性が高い。そのような場合に、類別平面をカテゴリ間に拡張すると、いたずらに類別平面を複雑化してしまう危険性が高い。そこで、今回は、異なるカテゴリに属する機種間で類別平面を構築するものとし、2クラス決定問題として類別実験を行う。7種類の各進行方向において、「カテゴリAの2機種 (A1, A2) × カテゴリBの2機種 (B1, B2)」の4通りの組み合わせ (計 28 パターン) が対象となる。

3. 類別実験

類別性能指標として適合率を考える。ここで適合率 (precision) とは「類別結果がどの程度、正解と適合するかを表す指標」であり、式(1)にカテゴリAの適合率 $Prec_A[\%]$ 、式(2)にカテゴリBの適合率 $Prec_B[\%]$ を示す。式(1)、(2)において、 d_A はカテゴリAのデータの誤答数、 d_B はカテゴリBのデータの誤答数、 n_A はカテゴリAの総データ数、 n_B はカテゴリBの総データ数とする。

$$Prec_A = \frac{n_A - d_A}{n_A - d_A + d_B} \times 100 \quad (1)$$

$$Prec_B = \frac{n_B - d_B}{n_B - d_B + d_A} \times 100 \quad (2)$$

表1に全体の適合率、表2にカテゴリAの適合率、表3にカテゴリBの適合率を示す。各表において列が機種の組み合わせ、行が進行方向を表す。

各カテゴリの平均適合率はカテゴリAで 98.53%、カテゴリBで 95.71%、全体の平均適合率は 96.89%となる。個々の進行方向に関しても、8割強の進行方向におい

† 三菱電機 (株) 情報技術総合研究所,
Mitsubishi Electric Corp. Information Technology R&D Center

て、全体の適合率、及びカテゴリA, B で適合率が 9 割以上となり、良好な結果と言える。

表 1 : 全体の適合率[%]

	A1-B1	A1-B2	A2-B1	A2-B2
90	100	100	96	98
105	99	100	85.5	99.5
120	91.5	100	71	97.5
135	99.5	99.5	90	99.5
150	100	100	94	96.5
165	100	100	99.5	99.5
180	100	100	99	98

表 2 : カテゴリA の適合率[%]

	A1-B1	A1-B2	A2-B1	A2-B2
90	100	100	100	98
105	100	100	100	100
120	91.09	100	76.25	100
135	100	99.01	97.62	99.01
150	100	100	100	97.94
165	100	100	100	100
180	100	100	100	100

表 3 : カテゴリB の適合率[%]

	A1-B1	A1-B2	A2-B1	A2-B2
90	100	100	92.59	98
105	98.04	100	77.52	99.01
120	91.92	100	67.5	95.24
135	99.01	100	84.48	100
150	100	100	89.29	95.15
165	100	100	99.01	99.01
180	100	100	98.04	96.15

4. 考察




図 1 : 形状の異なる 2 目標から得られるデータの比較

全体の適合率、及びカテゴリA/B の適合率いずれも、進行方向が 120° 付近を中心に、類別性能が劣化している。ここで、進行方向 90° 付近と 180° 付近とにおける、目標の特徴量の現れ方の違いを考える。図 1 にカテゴリA, B に属する機種形状の特長を示す。カテゴリA に属する機種は「進行方向に対し、垂直方向の幅の広がり、比較的大きい目標 (図 1 の目標 1)」、カテゴリB に属する機種は「進行方向に対し、垂直方向の幅の広がり、相対的に少ない目標 (図 1 の目標 2)」であることがわかっている。

この場合、仮に “.” で示される反射点からのデータが得られた場合、90° では長さ $b1$ と $b2$, 180° では長さ $a1$ と $a2$ が得られる。図 1 において、 $a1$ と $a2$ では比較的、差が顕著であるのに比べ、 $b1$ と $b2$ の差はさほど大きくないため、特徴量の違いとして現れにくい。これにより、180° 付近に比べて、90° 付近では類別性能が劣化することが予想される。上記実験結果においては、180° よりも 90° に近い 120° 付近で性能が劣化しており、この点はほぼ予想通りであるが、90° よりも 120° で劣化している点は予想に反する。ここで、今回、実験に用いたデータでは、目標 2 が目標 1 に比べ相対的に小さく (実質、目標 2 は 1 つの点として観測される)、その場合は $b1, b2$ に差が現れるため、90° でもある程度の性能が期待できる。さらに目標 1 上に、上記反射点以外にも特徴的な反射点 (翼端等) が存在し、90° の場合に、その反射点が特徴量として抽出された可能性も考えられる。これらの結果の詳細な検証は、今後の課題とする。

5. むすび

レンジプロフィールを対象とした類別実験を行った。その結果、平均適合率がカテゴリA で 98.53%, カテゴリB で 95.71%, 全体の平均適合率は 96.89%と、良好な結果が得られ、また進行方向が 120° 付近で類別性能が低下する傾向にあることが明らかになった。ここで、目標の幅の広がりによって差がある場合、レンジプロフィールにおける特徴量の現れかたの違いから、180° 付近に比べて、90° 付近で性能が低下することが予想される。180° よりも 90° に近い 120° 付近で低下している点では、ほぼ予想通りであるが、90° よりも 120° で劣化している原因については、今後の検証課題とする。なお、今回の実験では、理想的な観測可能範囲を想定した条件下で行っているため、今後の課題としては、より実運用に即した観測可能範囲を設定した場合の類別実験や、観測条件等、何らかの条件の異なるデータとの比較検証が考えられる。

参考文献

- [1] ニューラルネットワークレーダプロセッサ, 特表 2003-507716 号公報, 2000.
- [2] C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, vol.2, no.2, pp. 121-167, 1998.
- [3] 田中, 川上, 山本, "アスペクト角不明の ISAR 画像による立体の識別, 信学技報, SANE2003-48, 2003.
- [4] 川上, 田中, 山本, "ISAR 画像における三次元形状類別, 信学技報, SANE2003-78, 2003.
- [5] T. Joachims, "Making large-Scale SVM Learning Practical. Advances in Kernel Methods - Support Vector Learning," B. Schölkopf, C.J.C. Burges, and A.J. Smola, eds, pp. 169-184, Cambridge, MA, MIT Press, 1999.