

レーダパルス識別への SVM の適用

Radar pulse recognition using SVM

川上 かおり† 田中 秀俊† 三石 彰純†
Kaori Kawakami† Hidetoshi Tanaka† Akitoshi Mitsuishi†

1. まえがき

現状、レーダの機種をレーダパルスから識別する試みは既に行われている。例えば、パルスの間隔や搬送周波数など、レーダパルスに関するいくつかの特徴量を抽出し、それら特徴量の範囲の組をレーダの機種別辞書として用意しておく、その辞書と照合することによって、完全ではないにせよ、識別を試みることができる。一方、同一機種のレーダの個体識別は、著者らの知る範囲では試みられていない。そこで、同一機種2機のパルスデータを多数用意して、識別が可能か否かをまず検討した。識別には音声認識の手法を採用することとし、簡易な隠れマルコフモデル(HMM)に基づいてパルスモデルを構築し識別を試みたところ、搬送周波数によっては識別可能との結果が得られた[1]。本稿で述べる実験は、第一段階実験で識別不能となったケースに対する追試を目的としている。前述の簡易 HMM の各状態を対象として、サポートベクターマシン(SVM: Support Vector Machine)による識別を試みた。以下に、その手法と結果について述べる。

2. 隠れマルコフモデル

形式的には d 次 HMM、すなわち過去 d 個のデータが有限の数の状態を確率的にとり、その次のデータはとった状態毎に固有の確率で決まる状態遷移モデルとした。実質的には、 d 個のデータにウォルシュ変換を施して得られた w 次元ベクトルに対して、1 次 HMM を構築する方法を採用した。ただし、现阶段ではモデル適合度に状態遷移確率を算入せず、出力分布のみを用いている[1]。

3. サポートベクターマシン (SVM)

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、境界付近の学習データのみ注目し、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。線形判別不能、すなわち分離不可能な学習データが存在する場合には、そのデータへのペナルティを表す変数(以下、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。本稿の実験では、線形カーネルと、非線形カーネルの一つである多項式カーネルとを採用した。

4. 解析手法

4.1 前処理

前処理として「窓」を導入し、データをベクトル化する。以下、時間単位を T_u とする。レーダパルス信号に対し時間幅 d [T_u] の「窓」を、全測定時間にわたって $1/[T_u]$ ずつずらすことにより、測定時間数程度の窓データを生成する。レーダパルス信号から局所的周期性を特徴として捉えるために、得られた各窓データについて w 次までのウォルシュ係数を求め、 w 次元の中間データを生成する。

4.2 状態分類

各レーダのデータから p_i 本ずつパルスを選び、 w 次元の中間データに対し、レーダの区別をせずに、部分母集団の平均、標準偏差、及び混合比を求める。これらの値の算出には期待値最大化法を用いている。

4.3 状態遷移列の算出

各中間データがどの状態に属するかを、帰属確率を比較して決定する。この中間データの帰属状態の時系列から、各パルスの状態遷移列が得られる。

4.4 SVM用状態別データの抽出

状態遷移列に基づき、各状態のデータを抽出する。各パルスを構成するウォルシュ変換結果データの中から、個々の状態毎に、属するウォルシュ変換結果データを抽出し、クラスを表すレーダ識別子と組み合わせたものを SVM 用状態別データとする。最終的には、2 レーダの複数本のパルスに対するデータを 1 ファイルにまとめたものが SVM 用状態別データとなる。その際、2 レーダのウォルシュ変換結果データ数が等しくなるように調整する。

4.5 SVM による学習及び判別

SVM 用状態別データに対して学習を行い、判別境界を算出する。算出された判別境界に基づき、判別対象データの判別を行う。

5. 線形カーネルによる識別実験

5.1 データ生成処理

同一機種のレーダ2機について、まず[1]の実験で識別可能であった周波数 A において解析実験を行った。約 13 万 [T_u] の検波後のビデオ信号データであるパルスデータを、各レーダ/各周波数で 32 本ずつ用いた。16 次 12 状態 HMM($N=12, d=16$)を想定し、ウォルシュ変換により 8 次元の中間データ($w=8$)を作成した。状態分類には、各レーダ/各周波数のパルス 10 本($p_i=10$)の計 20 パルスを対象とし、さらにそれらのウォルシュ変換結果データを SVM 用状態別データに変換した。

なお、今回使用したパルスデータは、個々のレーダの移動平均に若干の差があり、この差が識別精度に大きく影響することが[1]より明らかになっている。そこで移動平均の差が直接的に影響しないよう、正規化による補正(以下、レーダ間正規化)を行った上で、ウォルシュ変換を施した。

5.2 学習/判別処理

SVM 用状態別データを各状態において学習後、自己識別テストを実施した。オープンソースのフリーソフトウェアである SVM^{light}[3]を用いた。状態数は 12 とし、パルス間の空状態とみなせる状態(状態 ID が 5~7)は対象外とした。カーネルは線形カーネルを採用した。

事前にデフォルトのパラメータ設定における予備実験を行ったところ、全状態の正解率は 49.67~52.00%の範囲で、平均正解率は 50.89%であった。そこで識別性能向上のため、以下に示すデ

ータ加工やSVM^{light}が提供しているパラメータの変更を行った。

(1) SVM用状態別データの成分間正規化

SVMでは学習データの各成分の振幅(絶対値の最大値)のばらつきが大きく影響すると考えられている。そこで、ウォルシュ変換後のデータを加工して成分間の正規化を行った。具体的には、学習対象となるデータの振幅の平均値を求め、平均振幅がほぼ均等になるよう、成分毎に異なる定数を乗じて正規化を行った。

(2) スラック変数の導入(パラメータ c)

SVM^{light}のパラメータ c は、線形分離が不可能な場合における、最小化を行う目的関数のペナルティ項の係数(すなわちスラック変数の係数)の意味合いを持つ。パラメータ c を大きくすると、分離不可能な学習データへのペナルティが厳しくなり(=修正コストが大きくなる)、学習データの正解率の向上が期待できる。しかしペナルティを厳しくするとマージンは狭くなる傾向にあるため、そのトレードオフの調整が重要となる。

5.3 判別結果(線形カーネル)

成分間正規化後、及びパラメータ c 導入後の各状態での正解率を表1に示す。なおパラメータ c は、ほぼ全状態において、実行時間内で収束可能な最大値として、試行実験で得られた $c=10^{-6}$ を用いた。

表1: (1)成分間正規化 / (2)パラメータ c 導入後の正解率[%]

状態	0	1	2	3	4	8	9	10	11
(1)	56.50	59.00	52.33	51.67	53.83	53.33	55.33	51.33	53.17
(1) +	61.83	59.33	51.33	56.17	54.33	59.33	56.83	53.83	56.33
(2)									

ほぼ全ての状態で成分間正規化及びパラメータ c の導入により正解率が向上している。しかし、正規化のみの場合が 51.33 ~ 59.00[%] (平均 54.05[%])、パラメータ c の導入で 51.33 ~ 61.83[%] (平均 56.59[%]) と、全体で 11[%]程度の向上であり、識別可能とは言い難い結果であった。

6. 多項式カーネルによる識別実験

6.1 多項式カーネル

多項式カーネルは式1のように定義される。今回の実験では、線形カーネルの際に用いたパラメータ c と、式1を構成するパラメータのうち、次元を表すパラメータ D のみを変更対象とし、その他のパラメータ r, s はデフォルト設定のままとした。また対象とする状態は任意に抽出した状態(状態4)のみとした。

$$K(x_i, x_j) = (r + s x_i x_j)^D \quad (\text{式1})$$

6.2 判別結果(多項式カーネル)

各状態で得られた最良の正解率 R [%] を表2に示す。なおパラメータ c は、各状態において1~3時間程度で収束可能な最大値とした¹。なお、成分間正規化データによる学習では、演算上の誤差が生じたため、学習データ全体の振幅の平均値を使って、各成分の最大振幅が1.0前後になるように正規化したデータを用いた。

¹各状態において、パラメータ c が大きいほど正解率が向上する傾向が見られ、また c 及び D が大きいほど実行時間は増大した。

表2: 多項式カーネルにおける正解率 R [%] (状態4)

D	2	3	4	5	6	7	8	9
c	50	10	0.2	10^{-2}	4×10^{-4}	10^{-5}	10^{-6}	10^{-8}
R	62.5	70.3	72.3	76.0	77.8	79.5	83.5	80.2

$c=10^{-6}$ 、 $D=8$ (8次元)の場合に最良の正解率 83.5[%]が得られ、また全状態でも 62.5 ~ 83.5[%]、平均 75.3[%]の正解率となった。なお、 $D=10$ では上記時間内で収束不可能であった。以上より、多項式カーネル導入による識別率向上の効果が明らかになった。

上述の結果は全て学習データを対象とした自己識別の結果であり、「8次元多項式カーネル程度の個体差」があると言える。しかし、実際に識別できるかは今後の大きな課題である。本実験での最良の結果が得られたパラメータの組み合わせを用いて、非学習データを対象に実験を行ったところ、平均正解率は 52.2 [%]となり、まだ非学習データに対して識別可能といえる結果は得られていない。また、そもそも今回のデータは工場内で採取した非常にきれいなデータであって、フィールドで採取したものではない。

非学習データに対する正解率が大幅に低下した原因の一つとして、パラメータ c を、収束可能な範囲内で最大にした点も考えられる。 c が大きくなるほど、ペナルティがきつくなり、学習データでの正解率が向上する反面、マージンが狭くなり、非学習データでの正解率低下につながった可能性が高い。その他にも多項式カーネルの次元数や、カーネルそのものの適性等、識別性能に影響する要因は多数考えられる。非学習データでの正解率向上のために、これらパラメータの調整、手法の改良などを今後検討する。

7. むすび

本報告では、レーダパルスを識別する一方法を提案し、評価結果を示した。(1)パルスデータ分割(2)状態分類(3)状態内でのSVMによる判別の手順で、隠れマルコフモデルをベースとした状態分類を行い、各状態内でのSVMによる判別精度を検証した。実験から、SVMの線形カーネルによる正解率は50[%]前後と低く、各データの成分間の正規化や、スラック変数の導入によって11[%]程度の向上は見られたが、識別可能といえる結果は得られなかった。次に多項式カーネル導入による実験では、学習データを対象に、8次元の場合に最良の正解率 83.5[%]が得られ、多項式カーネル導入の効果を示すことができた。しかし非学習データでは、平均正解率は 52.2 [%]となり、識別可能といえる結果は得られなかった。非学習データでの正解率低下に関して、スラック変数の設定方法、カーネルの次元数、カーネルの選択方法等、多数の要因が考えられるため、今後は、これらのパラメータの調整や手法の改良等を検討する予定である。

参考文献

- [1] 川上 他, “隠れマルコフモデルによるレーダパルス識別,”信学技報, SANE2001-118, pp.39-44, 2002.
- [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] 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.