

ロバスト LS-SVMによる雑音環境下での画像照合

Image Matching by Robust LS-SVM in The Presence of Noise

齋藤 登†

川上 肇‡

Noboru SAITO

Hajimu KAWAKAMI

1 はじめに

本研究の目的は、LS-SVM¹⁾(Least Squares Support Vector Machine) をロバスト画像認識に応用する方法を開発することにある。

近年、人間のよう学習能力を持つ機械を作るために機械学習の理論が盛んに議論されている。特に Support Vector Machine(SVM) は現実の問題への応用において優れた性能を持つことが報告されている。しかしながら学習パターン数が多くなると学習のための計算量が急激に増大することが問題となる。この問題を解決する方法として LS-SVM が提案されている。本論文ではこの LS-SVM をロバスト化することを目標とする。

2 ロバスト LS-SVM

LS-SVM では特徴空間 D 内の特徴ベクトル x を高次元空間 $\Phi(D)$ で 2 クラス $\in \{1, -1\}$ に分類する識別関数 $J(x) = \Phi(x) \cdot \omega - h$ を決定するとき、訓練サンプル $\{(x_i, y_i \in \{1, -1\}); i = 1, \dots, N\}$ の完全学習を避けることにより、計算量の低減を図る。ここで ω と h は訓練サンプルの学習で求めるべきパラメータである。その処理をさらにロバスト化する方法を説明する。

2.1 LS-SVM

LS-SVM では C を定数としたとき、下記の条件付最適化問題の解をパラメータ ω, h の値として用いる：

$$\text{目的関数: } \|\omega\|^2 + C \sum_{i=1}^N e_i^2 \rightarrow \text{最小化}$$

$$\text{制約条件: } y_i(\Phi(x_i) \cdot \omega - h) = 1 - e_i, \quad i = 1, \dots, N$$

ここで e_i は図1に示すように、 $y_i = 1$ としたとき境界 H_1 から他クラスの境界 H_{-1} への向きを正とした訓練サンプル x_i のエラーを表す。この最適化により、識別関数は次式で求まる：

$$J(x) = \sum_{k=1}^N C e_k y_k K(x, x_k) + h \quad (1)$$

ここで $K(x, x_k) = \Phi(x) \cdot \Phi(x_k)$ はカーネル関数と呼ばれ、一般に Mercer の定理を満たすように選ぶ。

2.2 ロバスト化

我々は解析的な分析に適したカーネル K として次式を導入する：

$$K_1(x, x_k) = \exp(a_1(x \cdot x_k) + a_2) \quad (2)$$

a_1, a_2 : 定数

そのうえで、ロバスト推定の考え方を式(1)に導入す

† 龍谷大学 理工学研究科 電子情報学専攻

‡ 龍谷大学 理工学部 電子情報学科

る。すなわち $|e_i|$ が大きな訓練サンプル x_i を下記手順にて訓練サンプルから除去することにより、outlier の学習を避ける：

手順1 (ソート) : $\{|e_i|; i = 1, \dots, N\}$ をソートして順序 $e_1^* \leq e_2^* \leq \dots \leq e_N^*$ を決める。

手順2 (サンプル除去) : e_i^* に対応する訓練サンプルの上位 $\alpha\%$ を訓練サンプルから除去する。その後、再び最適化問題を解いて識別関数 J を構成する。この方法を「**双方向サンプル除去法**」と呼ぶ。




図1: エラー e_i の説明

3 実験

2.2 で述べた処理の効果を調べるために、雑音に変動として混入する環境下でテキストチャ画像を識別する実験を行った。以下、その方法、結果、考察を述べる。

3.1 方法

以下ではクラスが p のテキストチャ画像 (512×256 画素) を 2 枚用意し、 I_p^1, I_p^2 とする。

(1) 訓練サンプルの生成：

I_p^1 から大きさ 41×41 画素の部分画像をオーバーラップなしに取り出す。各部分画像は平均値 0 に正規化した後 DCT 処理を行う。そこから低周波成分を優先して 100 成分を選び、それらを要素とするベクトルを単位ベクトル化して特徴ベクトルとする。

(2) テストサンプルの生成：

I_p^2 に最大振幅 Z の白色雑音を変動として加える。その後訓練サンプルの生成と同じ手順で部分画像を取り出し、そこから大きさ 1 の特徴ベクトルを作る。図2に取り出した部分画像例を示す。

(3) 照合方法：

訓練サンプルを LS-SVM に学習させた後、2.2 で述べたロバスト化を行う。その際、訓練サンプルのソート法として下記の方法を用いた。

(i) **クラス別ソート法** : クラスごとに上位 $\alpha\%$ の outlier を除去する方法である。この方法では、クラス間で偏りのない除去を実現できる。

(ii) 全体ソート法: 合併したクラス全体から上位 $\alpha\%$ の outlier を除去する方法である。この方法では、片方のクラスに影響力の大きい訓練サンプルが多数ある場合に有効であると考えられる。

(4) 評価方法:

テストサンプルに加える白色雑音の Z を 0 から 5 刻みで最大 70 まで増加させながら識別率を測定する。この測定を 10 回試行し、 Z の値ごとの平均の識別率で識別法を評価する。

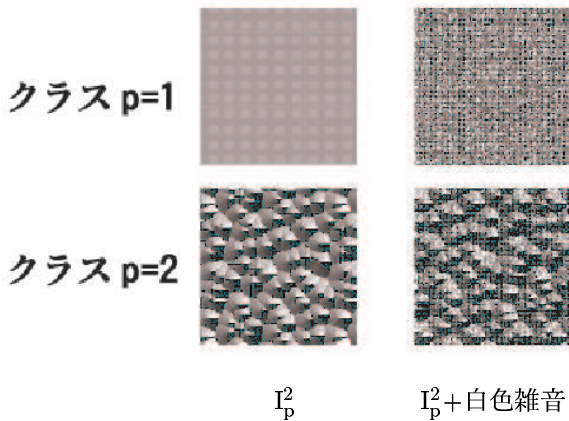


図 2: 取り出したテキストチャ画像例 (I_p^2 : テストサンプル用画像 (左), 雑音混入画像 $Z = 70$ (右))

3.2 結果

クラス別ソート法によるサンプル除去で $\alpha=0\%, 50\%$ とした場合の識別結果を、横軸 Z 、縦軸識別率でグラフにして図 3 に示す。同図に、カーネル K をガウスカーネル (分散 $=\sigma^2$) にした場合も併せて示す。グラフの記号を表 1 にまとめて示す。同様の実験を全体ソート法により行った結果を図 4 に示す。




図 3: クラス別ソート法での識別結果

3.3 考察

図 3 と 4 より、式 (2) に示すカーネル K_1 は LS-SVM のロバスト化に有効であることが分かる。特にカーネル K_1 は図 3 の $Z=50$ 付近以降において、2.2 のロバスト化により識別率の改善が現れている。同様の効果は図 4 の $Z=70$ 付近以降に現れている。

表 1: グラフの記号

	カーネル K_1 $a_1 = 0.02, a_2 = 1$	ガウスカーネル $\sigma = 7.07$
$\alpha=0\%$	○	●
$\alpha=50\%$	◇	◆




図 4: 全体ソート法での識別結果

この双方向サンプル除去法の効果を比較するために下記の除去法を用いて識別実験を行った。

正方向サンプル除去法: e_i^* が正方向に大きい訓練サンプルを除去する方法である。誤認識されたデータの除去によってより適切な識別関数を構成することができる。

負方向サンプル除去法: e_i^* が負方向に大きい訓練サンプルを除去する方法である。誤認識されていないデータでも識別面から大きく離れたデータは識別関数の構成に大きな影響を与えるので、それが悪影響となる場合にこの除去は有効である。

これらのサンプル除去法を組みこんだ実験でも識別法のロバスト化を実現することができたけれども、双方向サンプル除去法が最も有効であった。

4 まとめ

カーネル K_1 を使用した LS-SVM は、2.2 のロバスト化によって雑音強度が大きい場合に識別率が改善されることがわかった。今後、形成された識別面の特徴やエラー e_i の分布を考慮して除去率 α を自動調整する研究が必要であると思われる。

参考文献

- 1) J. A.K. Sukens, T. V. Gestel, J. D. Brabanter, B. D. Moor and Joos Vandewalle: "Least Squares Support Vector Machines", World Scientific (2002)
- 2) 津田 宏治; サポートベクターマシンとは何か 電子情報通信学会誌, Vol.83, No.6 (2001)