

1. はじめに

事例ベース識別器の学習法である Exemplar-SVM[1] は、1つのポジティブサンプルから SVM 識別器を学習するアプローチであり、事例が持つ属性の分類が可能である。しかし、対象とする事例全ての識別器計算を行うため、多大な時間を要するという問題がある。そこで本研究では、Exemplar-SVM を決定木構造で表現する Exemplar-Random Forests (RF) を提案する。これにより、識別時間の高速化が期待できる。

2. Exemplar-SVM

Exemplar-SVM は、ポジティブサンプル群の中の1つのサンプルと、ネガティブサンプル群を分類する識別超平面を SVM により学習する。このとき、全てのポジティブサンプルに対して識別器を学習するため、ポジティブサンプル数 N の識別器が構築される。識別時には、入力サンプル \mathbf{x} に対し、 i 番目のポジティブサンプルの識別関数 $f_i(\mathbf{x}) = \mathbf{w}_i^T \mathbf{x} + b_i$ によりスコアを算出し、スコアが最大となる事例に分類する。全てのポジティブサンプルの識別スコアを算出するため、計算コストが大きいという問題点がある。また、個々の識別器を独立に学習しているため、事前に識別器のスコアのレンジを調整するためのキャリブレーションを必要とする。

3. Exemplar-RF

本研究では、汎化性能を保ちつつ識別時間を短縮するために、Exemplar-SVM を木構造で表現する Exemplar-RF を提案する。

3.1. Exemplar-SVM の分岐関数への導入

提案手法では、Random Forests の分岐関数に Exemplar-SVM の識別関数を用いる。各決定木の分岐ノードでは、図1に示すように情報利得が最大となる事例の重みベクトル \mathbf{w}_i と閾値 th を選択する。識別関数のスコアと閾値 th を用いて式 (1) より、分岐ノード n におけるサンプル集合 S_n を分岐する。

$$\begin{aligned} S_l &= \{\mathbf{x} \in S_n | f_i(\mathbf{x}) = \mathbf{w}_i^T \mathbf{x} < th\} \\ S_r &= S_n \setminus S_l \end{aligned} \quad (1)$$

このとき閾値には、算出されたスコアの最小値と最大値の間でランダムに決定する。末端ノードでは、以上の処理を繰り返して決定木を構築し、到達したデータのクラス確率を保存する。

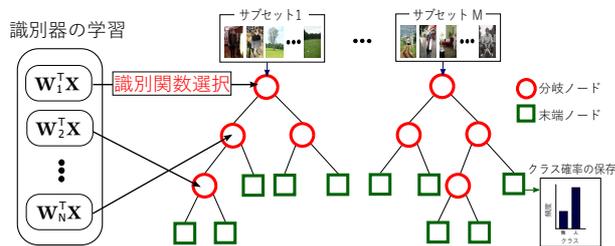


図1: Exemplar-SVM の識別関数の導入

3.2. 近似計算と早期分岐によるトラバースル

識別時は、未知入力サンプルを学習された各決定木に入力する。分岐ノードでは、学習により決定した識別関数と入力特徴ベクトルのスコアを算出し、閾値処理により左右の子ノードに分岐する。提案手法の識別処理は、最近傍探索により内積演算の回数を辿り着いた分岐ノード数に抑えることができる。スコア算出における内積演算には、Hare が提案したベクトル分解法 [3] を用いる。二値ベクトル \mathbf{x} と実数ベクトル \mathbf{w} の内積計算を二値ベクトル間の内積計算に置き換えることで、高速な演算が期待できる。さらに、ス

コアの近似計算の時には、スコアの近似計算結果が閾値より大きく離れた場合、近似計算を打ち切り早期分岐を行う。

4. 評価実験

提案手法の有効性を評価実験により確認する。

4.1. 実験概要

提案手法と従来法の汎化性能、識別速度を比較する。データセットは PASCAL VOC2007 の car を対象クラスとし、学習サンプル 2812 枚、評価サンプル 4952 枚を用いる。比較する従来法は、SVM, Exemplar-SVM で HOG 特徴量を複数の閾値を用いて 2 値化した B-HOG 特徴量を使用する。提案手法の学習パラメータは、決定木の本数 20 本、木の最大深さ 25、しきい値選択回数 50 回、サブセットは学習サンプルから 60% の割合でランダムサンプリングする。

4.2. 実験結果

DET カーブを図2に示す。SVM より性能が高く、Exemplar-SVM と同等の性能であることが確認できた。また、提案手法ではキャリブレーション無し、有りとともに同等の性能である。

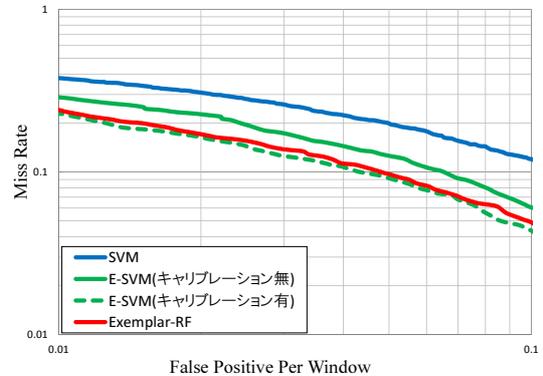


図2: DET カーブ

提案手法と従来法の平均識別時間 [ms] を表1に示す。分解法を適用した場合、提案手法は Exemplar-SVM と比べて約 47 倍高速である。さらに、早期分岐を導入した場合、約 60 倍高速であることがわかる。

表1: 平均識別時間 [ms]

従来法		提案手法		
SVM	E-SVM	分解なし	分解あり	分解+早期分岐
0.011	7.524	0.881	0.159	0.126

5. おわりに

本稿では、Random Forests の分岐関数に Exemplar-SVM の識別関数を導入した Exemplar-RF を提案した。評価実験より、従来の Exemplar-SVM の汎化性能を保ちつつ、約 60 倍の高速な識別が可能であることを確認した。また、提案手法は、Exemplar-SVM で必要となるキャリブレーションを必要としない。今後は、分岐ノードと末端ノードで選ばれた事例を確認し、各ノードにおいて選ばれたサンプルの傾向を調査する。

参考文献

- [1] T. Malisiewicz, *et al.*, "Ensemble of Exemplar-SVMs for Object Detection and Beyond", ICCV, 2011.
- [2] L. Breiman, "Random Forests", Machine Learning, vol. 45, no.1, pp.5-32, 2001.
- [3] S. Hare, *et al.*, "Efficient Online Structured Output Learning for Keypoint-Based Object Tracking", CVPR, pp.1894-1901, 2012.