

目次

第 1 章 序論	1
1.1 研究の背景	2
1.2 研究目的	3
1.3 本論文の構成	4
第 2 章 統計的学習に基づく物体検出とその関連研究	7
2.1 統計的学習を用いた物体検出システム	8
2.2 統計的学習に基づく識別器	8
2.2.1 Boosting	8
2.2.2 Support Vector Machine	13
2.2.3 Boosting と SVM	16
2.3 マルチクラス識別器	17
2.3.1 One vs Other 戦略	17
2.3.2 AdaBoost.MH	18
2.3.3 Joint Boosting	20
2.4 統計的学習による物体検出を困難とする要因	22
2.4.1 物体の多様性に起因する問題	24
2.4.2 カメラの設置環境に起因する問題	24
2.5 まとめ	26
第 3 章 分割統治戦略による識別器の高精度化	29
3.1 複雑な物体分類の問題と分割統治戦略の導入	30
3.1.1 複雑な変化を持つ物体の分類	30
3.1.2 分割統治戦略の導入	31
3.2 弱識別器の応答値に基づくサンプルの分割	32
3.2.1 Spectral Clustering	33
3.2.2 ノンパラメトリックなクラスタリングへの対応	33
3.2.3 サンプル分割結果	34
3.3 Divide and Conquer Boosting によるサブカテゴリに対する効率的な学習	37
3.3.1 Joint Boosting アルゴリズムの分割統治戦略への適用	37

3.3.2	Joint Boosting との相違点	39
3.4	評価実験	39
3.4.1	実験概要	40
3.4.2	弱識別器の応答値によるサンプル分割の有効性	40
3.4.3	DaCBoost によるサブカテゴリ学習の有効性	41
3.5	まとめ	43
第 4 章	特徴貢献度に基づく識別器の調整	45
4.1	識別器の調整と特徴量選択	46
4.1.1	Sequential Forward Selection	46
4.1.2	Sequential Backward Selection	46
4.1.3	従来法の問題点	46
4.2	Boosting による特徴量の貢献度評価	47
4.2.1	2 クラス問題に対する貢献度算出	47
4.2.2	マルチクラス問題における貢献度算出	47
4.2.3	貢献度に基づく特徴選択 (SBS-CRbB)	48
4.3	特徴貢献度に基づく特徴選択実験	49
4.3.1	特徴選択結果	50
4.3.2	特徴選択に要する計算時間の比較	52
4.4	貢献度に基づく識別器の調整	53
4.4.1	貢献度に基づく識別器の調整法	53
4.4.2	識別器の調整実験	54
4.4.3	移動体識別のための特徴量	54
4.4.4	貢献度に基づく特徴量の有効性の解析結果	57
4.4.5	特徴貢献度に基づく識別器の調整結果	57
4.5	まとめ	61
第 5 章	生成型学習に基づく学習の効率化	63
5.1	学習サンプルの自動生成による効率化	64
5.1.1	3 次元人体モデルによる人画像生成	65
5.1.2	ランダムサンプリングによる背景サンプルの自動収集	66
5.2	Multiple Instance Learning の導入によるノイズ低減	67
5.2.1	MILBoost	67
5.2.2	Negative-bag MILBoost	68
5.3	評価実験	73
5.3.1	実験概要	73
5.3.2	生成画像に基づく特定シーン学習の有効性	76
5.3.3	Negative-bag MILBoost によるノイズ低減の有効性	78

5.4	まとめ	80
第 6 章	実利用シーンに対する再学習の効率化	81
6.1	物体検出における転移学習	82
6.1.1	転移学習	82
6.1.2	Covariate-shift Boost(CovBoost) による転移学習	82
6.1.3	転移学習の問題点	84
6.2	ハイブリッド型転移学習による学習の効率化	86
6.2.1	本研究の問題設定	86
6.2.2	HOG 特徴量における Feature Shift	87
6.2.3	ハイブリッド型転移学習による学習	88
6.2.4	学習効率 ζ に基づく特徴空間選択	89
6.3	評価実験	91
6.3.1	実験概要	91
6.3.2	俯角変化に対するハイブリッド型転移学習の精度	91
6.3.3	考察	91
6.3.4	ハイブリッド型転移学習の高速性	92
6.4	まとめ	93
第 7 章	転移学習の導入による Random Forest の効率化	95
7.1	マルチクラス分類における転移学習	96
7.2	Random Forest	96
7.2.1	Random Forest の学習アルゴリズム	96
7.2.2	Random Forest の識別処理	99
7.3	Random Forest の転移学習	100
7.3.1	共変量シフトに基づく転移学習を導入した Random Forest	100
7.4	評価実験	104
7.4.1	2 クラス分類問題の転移	104
7.4.2	2 クラス分類問題への転移学習の導入による効率化	105
7.4.3	マルチクラス分類問題の転移	107
7.4.4	マルチクラス分類問題への転移学習の導入による効率化	108
7.5	まとめ	109
第 8 章	結論と展望	111
8.1	結論	111
8.2	展望	113
謝 辞		115

参考文献	117
研究業績一覧	123

目次

1.1	本論文の構成.	5
2.1	統計的学習法を用いた物体検出システム (例: 人検出).	8
2.2	AdaBoost による人の識別の流れ.	9
2.3	SVM によるマージン最大化.	13
2.4	カーネルトリックを用いた高次元への写像.	16
2.5	マルチクラス識別器.	18
2.6	弱識別器の共有.	22
2.7	物体の見えの変化 (INRIA person dataset).	24
2.8	視点の変化により発生する未検出.	25
2.9	標準的な学習サンプルの例 (INRIA Person Dataset).	26
3.1	分割統治的戦略による識別器の学習法 (概念図).	31
3.2	弱識別器応答値を用いたできる学習サンプルのカテゴリライズ.	32
3.3	Spectral Clustering の流れ.	33
3.4	medoid-shift と mean-shift の違い.	34
3.5	人手によるサンプル分割.	35
3.6	提案手法によるサンプル分割.	36
3.7	Joint Boosting と DaCBoost による境界の差.	39
3.8	INRIA Person Dataset での性能比較.	43
3.9	UIUC Image Database for Car Detection での性能比較.	43
4.1	Boosting に基づく特徴量の貢献度評価.	48
4.2	特徴削減に対する識別性能の比較.	51
4.3	計算時間の比較.	52
4.4	特徴貢献度に基づく識別器の調整.	53
4.5	モーメント特徴.	54
4.6	エッジ検出例.	55
4.7	オプティカルフローの抽出.	56
4.8	フローの分散の算出.	56

4.9	貢献度算出結果.	58
4.10	調整により改善された物体検出例.	60
5.1	生成型学習の流れ.	64
5.2	3次元人体モデル.	65
5.3	3次元人体モデル生成時のパラメータ.	66
5.4	実環境に対する3次元人体モデルの生成例.	67
5.5	提案手法におけるBagの構成.	68
5.6	Negative-Bag MILBoostによる学習サンプルの重みの更新.	71
5.7	学習データベース例.	75
5.8	各データベースで学習を行った際のDETカーブ.	76
5.9	人検出結果例 (緑: 正検出ウインドウ, 赤: 誤検出ウインドウ).	77
5.10	ノイズを混入した際の識別性能.	79
5.11	識別器の出力と重みの遷移.	79
6.1	俯角による学習サンプルの変化.	85
6.2	俯角の変化による転移学習の性能.	85
6.3	ハイブリッド型転移学習.	86
6.4	HOG特徴量の転移.	88
6.5	弱識別器のエラー率の推移 ϵ .	90
6.6	選択されたHOG特徴量.	92
7.1	Random Forestの構造.	97
7.2	Random Forestによる識別.	99
7.3	共変量シフトに基づく転移学習を導入したRandom Forest.	100
7.4	転移学習を導入したRandom Forestの構築.	101
7.5	各データベースのサンプル例.	104
7.6	転移学習を導入したRandom Forstsの識別性能.	106
7.7	マルチクラス分類問題のサンプル例.	107

表 目 次

3.1	サンプル分割手法の比較.	41
4.1	最大識別率 (RR) とその次元数 (dim) の比較.	52
4.2	調整前の識別性能.	57
4.3	識別器を再学習した際の識別性能.	59
4.4	識別器の調整 (HG).	59
4.5	識別器の調整 (SH,HG).	59
5.1	学習用データベースの内訳.	74
6.1	俯角による類似度の変化.	88
6.2	EER による性能評価.	91
6.3	目標識別器学習に必要な計算時間の比較.	92
7.1	Random Forest 構築のパラメータ.	105
7.2	マルチクラス分類問題に対する転移学習結果 (2,416 枚).	108
7.3	マルチクラス分類問題に対する転移学習結果 (800 枚).	108
7.4	マルチクラス分類問題に対する転移学習結果 (100 枚).	108