

第4章

特徴貢献度に基づく識別器の調整

3章では、識別問題を分割統治することで高精度な識別器を構築する手法について述べた。しかし、実際の設置環境において学習サンプルの収集環境から大きく変化すると検出性能は低下するという問題がある。そこで、本章ではまず4.1において環境変動に頑健な特徴の選択と設置環境での調整の必要性について述べた後、特徴選択の従来法について述べる。そして、4.2においてBoosting識別器に基づく特徴量の貢献度を提案し、貢献度に基づいた特徴選択や識別器の感度調整に用いる手法について述べる。

4.1 識別器の調整と特徴量選択

統計的学習法を用いた物体検出システムを実際に運用する際、カメラの設置環境と学習時の環境が異なると性能が低下する問題がある。特に、屋外環境下で撮影された人や自動車等の認識では、天候等の照明変動に影響を受けない特徴量を選択する必要がある。環境変動に対して頑健性を向上する手法として、識別に大きく寄与する特徴量のみを選択する特徴選択が挙げられる。識別に大きく寄与しない特徴量は学習サンプルの時点で対象の判別が困難な特徴量であり、このような特徴量は外乱によって容易に変動すると考えられる。そのため、識別器の構築段階で入力から排除してしまうことでシステムの頑健性を確保する。特徴選択は、任意の特徴量を棄却して識別器を構築し、その識別性能により決定するのが一般的である。特徴量の有効性評価は特徴量を排除または挿入した際の識別性能を基準とする。以下に、オーソドックスな二種類の特徴選択法について詳述し、その問題点について述べる。

4.1.1 Sequential Forward Selection

Whitney らにより提案された Sequential Forward Selection (SFS) [26] は forward 型と呼ばれ、特徴数が 0 の状態からスタートし特徴を増やしていく方法である。全ての特徴についてその特徴を追加した際の評価値を求め、最も評価の高い特徴を特徴集合に追加する。これを繰り返して特徴を順次追加し、評価値が低下する、または変化が無くなれば終了する。この際の評価値には、一般に識別率が用いられる。

4.1.2 Sequential Backward Selection

Marill らにより提案された Sequential Backward Selection (SBS) [27] は全ての特徴を持つ状態からスタートし特徴を削除していく手法であり、backward 型と呼ばれる。SFS 法とは逆に、SBS 法は不要と評価された特徴量を 1 つずつ特徴集合から削減することになる。全ての特徴についてそれを削減した際の評価値を求め、その結果を用いて特徴を順次、特徴集合から削除する。評価値が低下、または変化が無くなれば終了する。

4.1.3 従来法の問題点

SFS 法や SBS 法の特徴選択アルゴリズムは識別性能を評価とするため、追加または排除される特徴の組み合わせの数だけ識別器を構築する必要があり、探索の計算コストが大きい。具体的には n 次元の特徴量から m 個の特徴量を削減するために、その全ての組み合わせ ${}_n C_{n-m}$ 回の試行を必要とする。識別器構築に伴い必要な特徴探索時間は特徴次元数に比例する。SBS 法は特徴量をすべてサブセットに持つ状態から開始するため、特徴探索時間の増大が特に顕著である。また、SFS 法は順次特徴を挿入していくため SBS 法に比べ高速ではあるが、同時に組み合わせることで有効となる

特徴を考慮することができないため、精度が低いという問題がある。これらの理由により、特徴次元が多く、識別器の構築に時間を必要とする物体検出において、高速性と高精度を併せ持つ特徴選択アルゴリズムが望まれている。

4.2 Boosting による特徴量の貢献度評価

本節では、Boosting で構築された識別器を解析することにより簡易に特徴の有効性を評価する貢献度について述べる。また、その応用として、貢献度を用いた特徴選択について述べる。

4.2.1 2 クラス問題に対する貢献度算出

AdaBoost に代表される Boosting 手法は、2.2.1 で示したように、それぞれの弱識別器が最終的な判別に及ぼす度合いを値として持つ重み付き多数決である。本研究では弱識別器を 1 特徴次元に基づく判別関数として用いている。そこで、各弱識別器に用いられる特徴量と出力値の大きさから、各特徴量が最終判定にどの程度影響力を持つかを特徴量の貢献度として算出する。貢献度算出の流れを 4.1 に示す。まず、全ての特徴量と学習サンプルを入力として Boosting 識別器を学習する。図 4.1 の例では AdaBoost を用いている。次に、構築した強識別器から、各弱識別器の応答値を求めて、弱識別器に用いられている特徴量毎に総和し、各特徴量の貢献度とする。弱識別器から特徴量の貢献度へは、式 (4.1)、式 (4.2) により換算する。

$$CR_f = \sum_{t=1}^T h_t^{response} \cdot \delta[\mathcal{F}(h_t), f] \quad (4.1)$$

$$h_t^{response} = \sum_{r=1}^R h_{t,r}^2 \quad (4.2)$$

ここで、 δ は Kronecker のデルタ関数、 R は弱識別器の区間数であり、しきい値関数を用いているなら 2、確率密度関数を用いているならその分解能 k と同数となる。 $h_{t,r}$ は弱識別器 h_t の区間 r における応答値であり、 $\mathcal{F}(h_t)$ は、 h_t に採用された特徴量を求める関数である。つまり、提案手法による貢献度 CR_f は弱識別器の各区間の応答の二乗和を用いて算出する。二乗するのは応答値の正負関係なく大きさのみを見るためである。

4.2.2 マルチクラス問題における貢献度算出

マルチクラス問題では識別器に、Joint Boosting を用いる。Joint Boosting による学習では、2 章で述べたように、各クラスに対する弱識別器とその応答値（判別への重み）が共有されて与えられ

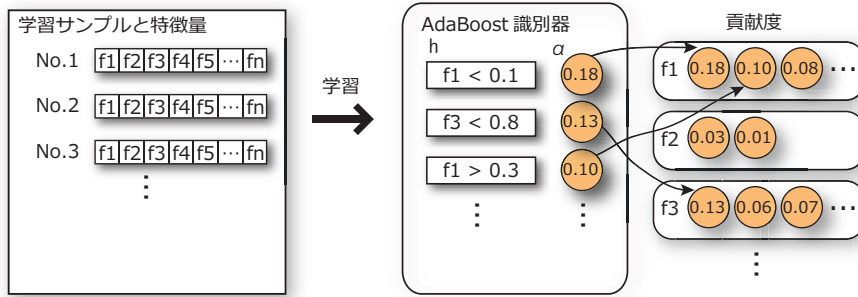


図 4.1: Boosting に基づく特徴量の貢献度評価.

る. そのため, クラス c に対する特徴量 f の持つ貢献度は式 (4.3) として算出する.

$$CR_{c,f} = \sum_{m=1}^M h_m^{response}(\mathbf{x}, c) \cdot \delta_K[F(h_m(\mathbf{x}, c)), f] \quad (4.3)$$

さらに, Joint Boosting が各クラス, クラス集合というノードについて弱識別器集合 G を構成しているため, 各ノード $S(n)$ に対する貢献度についても同様に, 弱識別器集合 $G^{S(n)}$ 内の弱識別器より式 (4.4) で求めることができる.

$$CR_{S(n),f} = \sum_{m=1, h_m(\mathbf{x}) \in G^{S(n)}}^M h_m^{response}(\mathbf{x}) \quad (4.4)$$

式 (4.4) は, 各弱識別器集合 $G(S(n))$ 毎に貢献度を収集したものであり, それぞれ複数クラスまたは個別クラスに対して特徴量がどれだけ有効であることを示す.

これにより, 複数のクラスで識別性能が低い際などにどの特徴量が問題であるかを客観的に評価できる.

4.2.3 貢献度に基づく特徴選択 (SBS-CRbB)

貢献度に基づく特徴選択は, 貢献度評価の値が最も低い特徴量を段階的に取り除くことで特徴を選択する. SBS 法と同じ backward 型であるが, SBS 法が 1 つの特徴量を削減するために削減候補と同数の識別器を構築する必要があるのに対し, 提案手法は 1 つの特徴量を削減するために 1 度の識別器の構築しか必要としない. これにより, 高速な特徴選択が可能となる. 貢献度による特徴選択アルゴリズムを **アルゴリズム 4.1** に示す. まず, n 次元の入力特徴セットと学習サンプルを入力する. 次に, 全特徴量を用いて識別器を構築し, 貢献度 CR_n を算出し, CR が最小であった特徴量を排除する.

アルゴリズム 4.1: 貢献度に基づく特徴選択アルゴリズム.

1. 入力: n 次元の特徴量セット $F = \{f_1, f_2, \dots, f_N\}$, I 個の識別器学習用データセット (\mathbf{x}_i, y_i) を用意

2. 初期化: 特徴集合 S に特徴量セット F の全ての特徴量を追加

・スコア $MaxScore=0$, $BestScore=0$

3. 特徴選択:

For Until $MaxScore < BestScore$ //スコア (識別性能) が低下するまで削除

・スコアの更新

$$BestScore = MaxScore$$

・ S に含まれる特徴量を用いて Boosting 識別器 $H(x)$ を構築

For $n = 1, \dots, N$ // 特徴量の貢献度, CR_1, CR_2, \dots, CR_N を算出

$$CR_n = \sum_{t=1}^T h_t^{response} \cdot \delta[\mathcal{F}(h_t), f_n]$$
$$h_t^{response} = \sum_{r=1}^R h_{t,r}^2$$

End for

・貢献度が最小の特徴 f_n を集合 S から削除

$$S = Exclusion(S, f_n)$$

・貢献度が最小の特徴量を削除した際の識別性能の算出

$$MaxScore = Score(S)$$

End for

4. 出力: 選択された特徴セット S

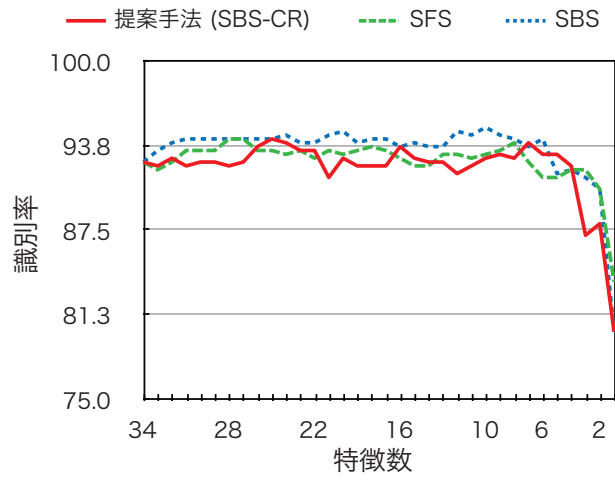
4.3 特徴貢献度に基づく特徴選択実験

貢献度に基づく特徴選択実験を行う。本実験では UCI-Machine Learning Repository[28] より, “ionosphere (34次元, 351 サンプル)”, “Heart (44次元, 80 サンプル)”, “Sonar (60次元, 208


サンプル) ”の三種類のデータセットを実験に用いる。学習サンプルはそれぞれ総サンプル数の半数を無作為に選択して使用し、残りの半数を評価用サンプルとして用いる。これらのデータセットに対し、貢献度に基づく特徴選択 (SBS-CRbB) と SFS 法、SBS 法による特徴選択を行い、その際の識別性能と計算時間を比較する。

4.3.1 特徴選択結果


各手法の特徴選択結果を図 4.2 に示す。まず、すべてのデータセットにおいて、提案手法は全特徴を使用したグラフ左端に比べ、特徴選択により良好な識別性能を得ることができた。SBS 法が最も高精度を獲得しており、提案手法は SBS 法の結果と同じ次元数にピークを持ち、SBS 法と傾向が似ていることがわかる。一方、SFS 法は特徴次元を少数にした際、識別性能が大幅に低下している。



(a) Ionosphere



(b) Heart



(c) Sonar

図 4.2: 特徴削減に対する識別性能の比較.

表 4.1 に、各特徴選択法による最も高い識別率の値と、選択された特徴次元数を示す。提案手法は SBS 法とほぼ同数の次元で同程度の識別率を獲得していることがわかる。

表 4.1: 最大識別率 (RR) とその次元数 (dim) の比較。

	IonoSphere		Heart		Sonar	
	dim	best RR	dim	best RR	dim	best RR
SBS-CRbB	7	0.94	8	0.96	13	0.91
SFS	28	0.94	26	0.92	48	0.88
SBS	10	0.95	9	0.96	15	0.93

4.3.2 特徴選択に要する計算時間の比較

次に、各手法による特徴選択に必要な計算時間を図 4.3 に示す。横軸は削減対象の特徴数であり、縦軸はそのために必要な計算時間である。計算時間の計測は Intel Xeon processor 3.0GHz を搭載したコンピュータで行った。図より、計算時間において SBS 法は特徴数に比例して指数関数的に増大しており、SFS 法は緩やかではあるがこれも指数関数的に増大することがわかる。これは、特徴量セット中の 1 つの特徴量評価のために、1 つの識別器構築を行う必要があることに起因している。一方、提案手法は特徴量セットに対して 1 つの識別器を構築することで、特徴量セット中のすべての特徴量の貢献度を算出して特徴削減を行う。そのため、特徴数が増加しても計算時間の増大を抑えることができる。

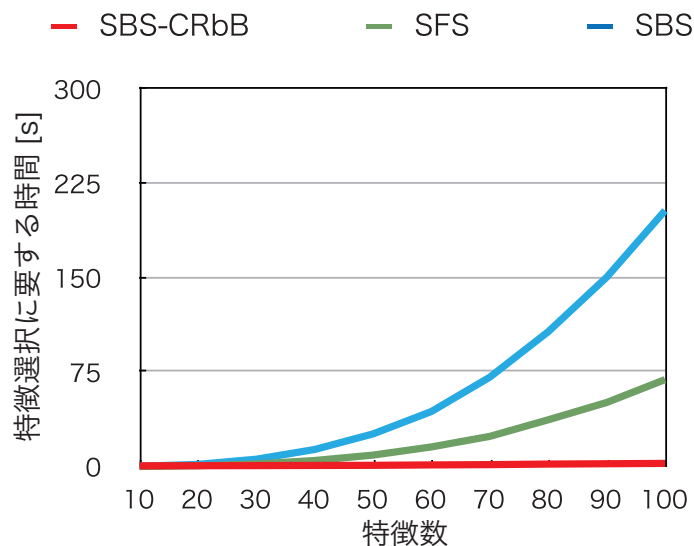


図 4.3: 計算時間の比較。

以上のことから、貢献度に基づく特徴選択は、SBS と同等の識別性能を獲得しながら、計算時間については SFS よりも高速で簡便な特徴選択法であるといえる。

4.4 貢献度に基づく識別器の調整

本節では、貢献度を用いて識別器を簡易に調整することで設置環境に対応させる手法について述べる。

4.4.1 貢献度に基づく識別器の調整法

屋外環境下における物体識別では、学習サンプルデータと設置現場で観測される物体の見えの違いから識別性能が低下する問題がある。これは、学習サンプル収集時の環境とシステム納入時における照明条件、天候などの違いにより発生する。このような問題への対処には、学習サンプルデータに設置環境で収集したデータを加え、識別器を再学習することが一般的である。また、環境変動に頑健な特徴量のみで構成されるよう特徴選択を行うことも有効である。しかし、システムを納入、設置する際の現場において、再学習や特徴選択による早急な対処は難しい。そこで、図 4.4 に示すような、貢献度を参考に、識別対象と各特徴量に対して識別時の感度が学習後に調整可能な識別器を考える。Boosting による識別器は、特徴次元のしきい値判別の結果を重みつき多数決することで識

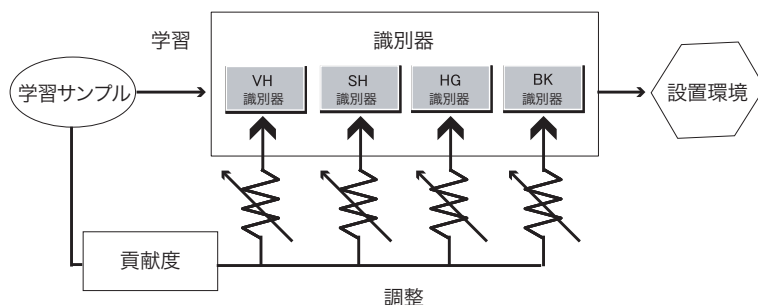


図 4.4: 特徴貢献度に基づく識別器の調整。

別を行う。そこで、弱識別器のしきい値を特徴量毎に調整することで、学習後の識別器を設置環境に対応させる。具体的には、式 (4.5) に示すように、学習後に得られた弱識別器におけるしきい値 θ を Δ_θ により調整することで、弱識別器の感度を変更する。

$$h_m(v, c) = a\delta(v^f > \theta + \Delta_\theta) + b \quad (4.5)$$

識別率の低い任意のクラスに対して貢献度の高い特徴量を優先的に調整することで、設置環境データに対して迅速な対応が可能となる。調整量 Δ_θ は自動決定することが望ましいが、本論文では実験的に求めた性能が低下しない値を与える。

4.4.2 識別器の調整実験

本実験では、貢献度に基づき識別器を評価用データに対し調整し、実際の設置環境へ簡易に対応可能であることを示す。まず、貢献度による特徴量の評価を行い、次に、算出した貢献度に基づいて識別器の調整を行う。これにより、学習サンプルと設置環境の相違で低下した識別性能が改善可能であることを示す。本実験では屋外で撮影されたマルチクラス問題を対象として取り扱う。

データベースとしては、屋外環境下での移動体検出法の評価用データを用いる。屋外に設置したカメラ映像からの移動体の検出・識別は、屋外自動ビデオ監視システムの研究分野で重要なタスクであり、多くの研究が行われている [29][30]。路上に設置したカメラにより収集した識別対象は、自動車 (VH) / 人 (SH) / 複数の人 (HG) / 自転車 (BK) の4クラスについて各10シーケンス、計40シーケンスの動画像を用いる。1シーケンスから40フレーム分の特徴量を抽出し、5シーケンス分200フレームの画像を学習サンプルに用いる。残りの5シーケンス分の200フレームは評価用の設置環境データに用いる。

4.4.3 移動体識別のための特徴量

識別器への入力特徴として、形状に着目した特徴量 (2種類)、テクスチャに着目した特徴量 (4種類)、時間情報に着目した特徴量 (1種類) を用いる。

● 形状に着目した特徴量

物体の全体的な形状を現す特徴として、移動体検出により検出した物体領域に対して、図4.5に示すモーメント特徴 (縦横比、傾き) を用いる。また、人と自動車などの複雑さを表す特徴として複雑度 (周囲長²/面積) を用いる。




図 4.5: モーメント特徴.

- 縦横比と主軸の傾き (AS)
- 複雑度 (CS)

- **テクスチャに着目した特徴量**

物体の見えを現す特徴として、図 4.6 に示すようにエッジ強度とエッジ連結数をそれぞれ 45 度刻みの 4 方向について用いる。




図 4.6: エッジ検出例。

- 垂直方向エッジ (V)
- 水平方向エッジ (H)
- 右上がり方向エッジ (R)
- 左上がり方向エッジ (L)

- **時間変化に着目した特徴量**

「人」と「自転車」のような、見えが似ている物体においては、形状やテクスチャ情報から種別を識別することは困難である。そこで、物体の動きを表す特徴として、オプティカルフローを用いる。図 4.7 に示すように、剛体である自動車や自転車のフローの向きは一定方向に観測され、非剛体である人のフローは足等に向きのばらつきが生じる傾向がある。本章では、フローの検出に特徴点の追跡手法である KLT 法 [31] を用いる。図 4.8(a) のように物体矩形領域からフローを抽出し、図 4.8(b) に示すように、物体矩形領域を 6 分割し、各分割領域内の各フローの向きの分散を算出する。最後に、図 4.8(b) に示すようにその傾きを求め、特徴量とする。

- オプティカルフローの分散 (OF)

これまでに述べた形状情報、テクスチャ情報、時間情報に基づく計 12 個の特徴量を、特徴量毎にその最小値が 0、その最大値が 1 となるようスケール変換し、識別器への入力特徴として用いる。




図 4.7: オプティカルフローの抽出.

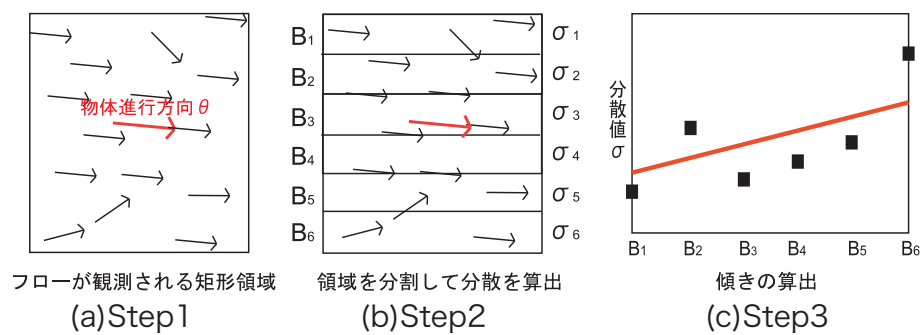


図 4.8: フローの分散の算出.

4.4.4 貢献度に基づく特徴量の有効性の解析結果

図 4.9 に、各ノードに対する特徴量の貢献度を示す。3 クラスで共有されるノードにおける貢献度を図 4.9(a) に、2 クラスで共有されるノードにおける貢献度を図 4.9(b) に、共有のない、自己と他すべてを分けるために有効な貢献度を図 4.9(c) に示している。なお、本問題では背景クラスが存在しないため、4 クラス全てと背景を分類する弱識別器集合 G^{1234} は選択されない。また、自動車 (VH)、複数の人 (HG)、自転車 (BK) と人 (SH) との分類に有効な弱識別器集合 G^{134} は、本実験では選択されなかった。

図 4.9(a-1) より、自動車 (VH)、人 (SH)、複数の人 (HG) の集合と自転車の分類には垂直方向のエッジ成分の貢献度が非常に高く、有効であることがわかる。また、図 4.9(a-2) や (a-3) より、それぞれエッジ情報が共有可能であることがわかる。さらに、図 4.9(b-2) では人、複数の人 (HG) と自動車 (VH)、自転車 (BK) という剛体、非剛体の分類に有効な特徴量として垂直方向のエッジ成分に加えて OF が非常に有効に働いていることがわかる。同様に、図 4.9(b-4) より自動車 (VH)、複数の人 (HG) と人 (SH)、自転車 (BK) の分類には、斜め方向のエッジに加え形状情報、中でも AS が非常に有効であることが観測できる。最後に、図 4.9(c) に着目すると、自動車 (VH) とその他の分類に対する水平エッジの有効性が非常に顕著に表れている。このように、提案手法は各特徴量の評価をクラスとその集合単位で詳細に表現することが可能である。

4.4.5 特徴貢献度に基づく識別器の調整結果

貢献度を用いた調整実験を行う。まず、未調整状態における設置環境データに対する識別結果を表 4.2 に示す。表より、調整前の識別器は、複数の人 (HG) クラスを自転車 (BK) クラスに誤識別することが多く、識別性能が低い。

表 4.2: 調整前の識別性能.

	VH	SH	HG	BK	識別率 [%]
VH	120	0	0	0	100.0
SH	4	100	0	16	83.3
HG	28	5	25	62	20.8
BK	7	1	10	112	93.3

そこで、図 4.9 の G^{34} に着目し、複数の人 (HG)、自転車 (BK) 共に貢献度が高い特徴である複雑度 (CS) と左上がり方向エッジ (L) を選択し、HG クラスの識別感度を調整する。ここで問題となるのが、どの弱識別器に対してどの程度変更を加えるかという点である。本研究では、任意のクラス固有のノードの弱識別器 (複数の人 (HG) クラスであれば G^3) に対して調整を加える。調整量については調整/再学習用設置環境データを用いて高性能であった $\Delta th = 0.3$ を採用した。表 4.3 に設置環境データを加えて再学習した結果を示す。表 4.4 に貢献度に基づいた調整を行った際の

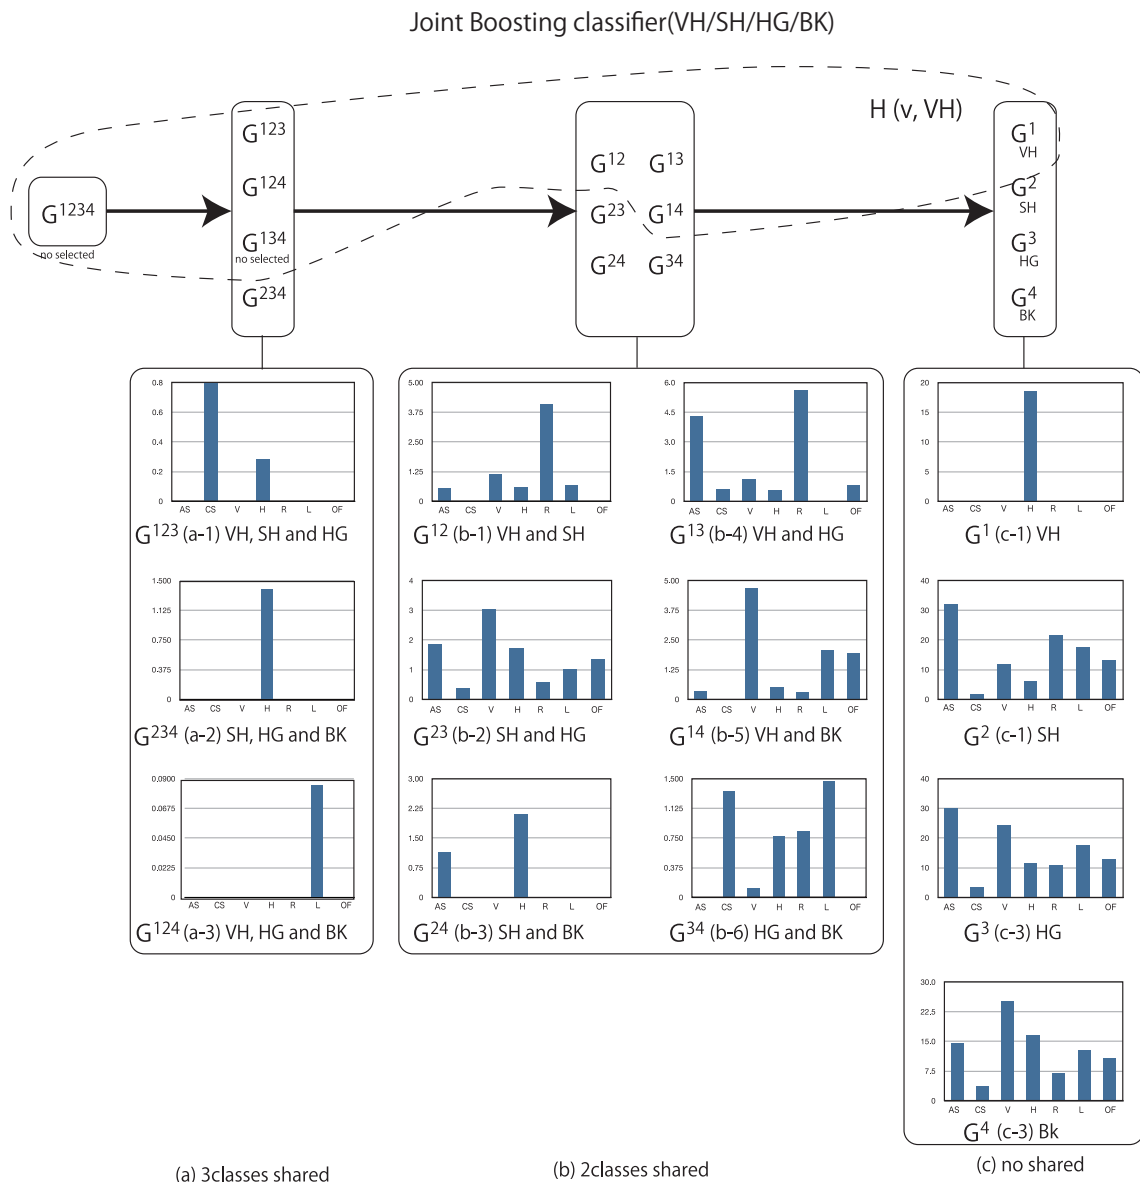


図 4.9: 貢献度算出結果.

結果を示す.

再学習と調整のどちらも複数の人 (HG) クラスの識別性能が大きく改善され、平均で7%以上識別性能を向上していることがわかる。しかし、再学習の表 4.3 では、再学習前では存在しなかった自転車 (BK) クラスから人 (SH) クラスへの誤識別が27%増加している。これは、再学習前に問題であった複数の人 (HG) クラスについては改善されたものの、別の問題が発生したといえる。一方、提案手法は貢献度の高い特徴を問題のクラスについてピンポイントで調整することで、問題であった複数の人 (HG) クラスを自転車 (BK) クラスへ誤識別する点を解決しながら、他クラス間の誤

表 4.3: 識別器を再学習した際の識別性能.

	VH	SH	HG	BK	識別率 [%]
VH	120	0	0	0	100.0
SH	0	119	0	1	99.1
HG	0	44	71	5	59.1
BK	3	33	13	87	72.5

表 4.4: 識別器の調整 (HG).

	VH	SH	HG	BK	識別率 [%]
VH	120	0	0	0	100.0
SH	3	86	17	14	71.6
HG	9	2	77	32	64.1
BK	6	0	19	111	92.5

識別は大きく変化していない。これは、設置環境下において特定の問題が発生した場合、その問題に対して直接アプローチできる提案手法の利点を表している。さらに、提案手法は再学習と異なり、この上に微調整を加えることができる。複数の人 (HG) クラスに対する調整により識別率が低下した人 (SH) クラスについて、図 4.9(c-1) より人 (SH) クラスと他の分類に最も有効である AS について行った結果を表 4.5 に示す。表 4.5 より、再度の微調整を行うことで、平均性能で再学習を上回ることも可能であることがわかる。

表 4.5: 識別器の調整 (SH,HG).

	VH	SH	HG	BK	識別率 [%]
VH	0	120	0	0	100.0
SH	2	96	11	11	80.0
HG	9	8	75	28	62.5
BK	5	3	19	109	90.8

本実験の最後に、人 (SH) クラス、自転車 (BK) クラスと誤識別されていたが調整により複数の人 (HG) クラスと正解できたデータ例を図 4.10(a), (b), (c) に示す。

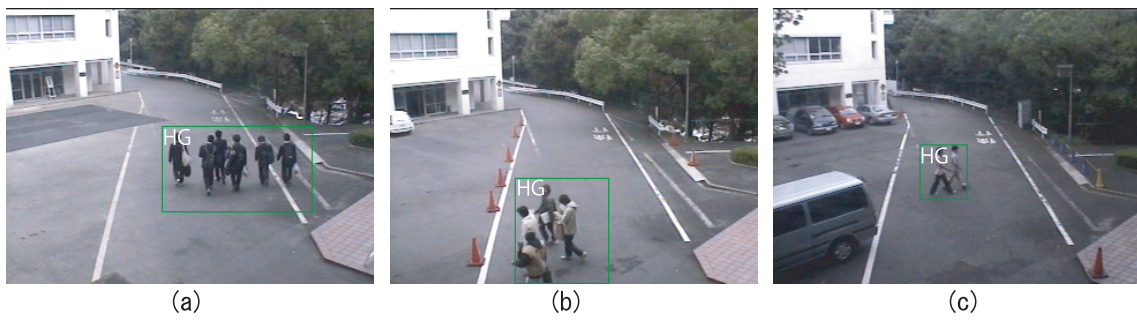


図 4.10: 調整により改善された物体検出例.

4.5 まとめ

本章では、まず、識別器における特徴削減や調整の必要性と従来法の持つ計算コストの問題を述べた。次に、Boosting 識別器より特徴量の識別への貢献度を算出することを提案し、貢献度を用いた特徴削減法と、識別器の調整法について述べた。特徴削減の対象として UCI-ML Repository から 3 種類の問題について評価実験を行い、貢献度に基づいた特徴削減を行うことで、SFS 法以上の高速性で SBS 法と同程度の高精度であることを確認した。

また、設置環境において Boosting 識別器を簡易に直接調整するフレームワークを提案した。評価実験では、屋外環境下で撮影された映像における移動体を自動車／人／複数の人／自転車の各クラスに識別するための入力特徴として、形状に着目した特徴量 (2 種類)、テクスチャに着目した特徴量 (4 種類)、時間情報に着目した特徴量 (1 種類) を使用した。評価実験の結果、貢献度に基づいて調整を行うことで、調整前と比べて 7% 以上性能が向上することを確認した。これにより、識別器を設置現場で簡易に調整し、短時間で設置環境へ適応することが可能となる。

