

第8章

結論と展望

本論文では、物体検出技術の実用化のために、問題の分割統治による検出技術の高精度化と、特定環境への適応の効率化を行った。

8.1 結論

各章のまとめは次の通りである。

2章では、統計的学習法に基づく検出技術について述べた後、検出に用いられる統計的学習法各種について詳述した。統計的学習法は多量の学習サンプルの統計に基づき、対象とする物体を高精度に判別する。しかしながら、対象クラスが多様なバリエーションを含む場合については学習が困難となる問題、多量に用意した学習サンプルと実際の設置環境が相違する場合には性能が低下するという問題が存在することを述べた。

3章では、多様な見えのバリエーションを含む物体を高精度に検出するため、問題を弱識別器応答値に基づきサンプルを分割する手法と、分割された問題を弱識別器を共有しながら解決する DaCBoost について述べた。問題の分割は弱識別器の応答値空間において Spectral Clustering を行うことで、サンプル集合の分割として行われる。これにより、類似したバリエーションの見えをもつ問題は自動的に集合し、個別に解決することで高精度な識別が可能となる。さらに、そのまま個別に識別器を構築して解決すると弱識別器数が膨大になるため、DaCBoost により弱識別器の情報を共有しながら学習を行うことで、同じ弱識別器数において高精度な識別器を構築することが可能となる。

4章では、特徴量の貢献度評価を提案した後、その貢献度に基づき特徴削減や識別器を調整することで、現場環境に対して適応が可能となることを述べた。また、Boosting に基づき算出される貢献度は、特徴の有効性に妥当な評価を与えることができ、検出システム構築の一助となる。

5章では、設置対象とする特定環境に対してさらなる効率化、高精度化を実現するために、特定環境に特化した学習サンプルの自動生成手法を提案した。学習サンプルは実環境の背景画像と3次元人体モデル CG の合成で生成し、特定環境に特化した大量の学習サンプルを用いて学習することで高精度な識別が可能であることを示した。さらに、学習サンプル生成の自動化に伴い、ネガティブサンプルにノイズが混在し得る問題については、Multiple Instance Learning をネガティブサンプルに適用した Negative-Bag MILBoost により解決することを提案した。これにより、簡易に大量のサンプルを用意して、識別器を構築することが可能となる。

6章では、さらに別側面からの効率化として、新規収集するサンプルの数と学習に要する時間を削

減する手法について述べた。転移学習を導入することで識別器の学習は高速となる。しかしながら、ドメイン間の差が大きすぎるなど転移が困難な場合に、その識別性能は大きく低下する。この問題に対し、高速な転移特徴空間と低速であるが高精度な全探索特徴空間を切り替えながら学習するハイブリッド型転移学習を提案した。これにより、再学習より非常に高速で、転移学習より高精度な識別を実現することが可能となる。

7章では、より多様な問題に対応できる手法として、マルチクラス識別器である Random Forest に転移学習による効率化を導入した。転移学習を Random Forest に導入することで、マルチクラス分類問題においても、学習サンプルが少数でありながらも十分な学習を可能とする。

1章では、物体検出の実用化に向けた重要な要件として以下の条件を列挙した。以下に、各条件に対して、本研究での貢献についてまとめる。

- (1) 多様なバリエーションを持つ検出対象の高精度な識別
- (2) 再学習なくシステムを簡易に調整可能
- (3) 特定環境へシステムを容易に再学習可能
- (4) 少数の学習サンプルでシステムを再学習可能

条件 (1) については、3章で述べた分割統治戦略により多様なバリエーションを持つ物体の検出という複雑な問題を、弱識別器の応答値と Spectral Clustering により簡易な小問題の集合に分割して、個別に識別器を構築することで高精度な識別が可能となる。さらに、分割した各問題に対して、DaCBoost で学習を行うことで互いに共通する部分は情報を共有しながら効率的に識別器構築が可能となる。従って、多様な見えの変化を持つ物体に対する精度の低下や識別器の肥大化という問題を解決する高精度化となる。

条件 (2) については、4章で述べた貢献度に基づいた識別器の調整により、識別に有効な特徴量を選別し、再学習なく現場環境に適応可能となる。この問題に対して、Joint Boosting より貢献度を算出することで、各検出対象クラスの関連や共通して利用できる特徴量などを解析することが可能となる。また、貢献度は学習時に、環境変動に弱い特徴を除去する特徴選択にも用いることが可能である。そのため、従来用いられる SFS 法より高速に、SBS 法と同程度の精度で特徴選択が可能となる。従って、様々な環境にシステムを設置する際、識別器の再学習などで問題となる多大な人的コストを解消する。

条件 (3) については、5章で述べた特定環境に適した学習サンプルの自動生成により、人手のコストを最小限に、大量の学習サンプルを用いて再学習することが可能となる。これにより、特定の環境に適した識別器を安価に構築することが可能となるため、高精度な識別システムの実用が可能となる。さらに、サンプルの自動生成に起因するミスラベルについても、ノイズの影響を低減できる Negative-bag MILBoost を用いた学習により、ミスラベルを含む学習サンプルから問題なく高精度

な識別器を構築できる。従って、再学習が必要な、学習環境とシステム設置環境との差異が大きい場合において多大な人的コストが必要となる問題を解決することが期待できる。

条件 (4) については、6 章で述べたハイブリッド型転移学習により、更に少数のサンプル追加で高速に再学習することが可能となる。転移学習では高速性と引き換えに失われる識別性能を維持したまま、通常の再学習に比べ非常に高速な学習法となる。また、7 章で述べた Random Forests への転移学習の導入は、マルチクラス識別を中心とした多様な問題の効率化に寄与する。5 章で述べた特定環境に適した学習サンプルの自動生成にこれらの提案を加え、調整などでは対応できない差異を持つ設置環境に対しても識別性能を低下させることなく非常に効率的に適応可能となる。

8.2 展望

本論文では、物体検出技術の実用化のために統計的学習法に基づく物体検出の高精度化と効率化について述べた。そして、評価実験により、複雑な問題に対する精度の低下、特定環境への適応、より少数の学習サンプルでの学習という各問題に対して従来法に比べ効率的かつ高精度な成果を得た。今後、より実用的かつ汎用的な物体検出を実現するためには以下の 2 つの課題がある。

一つ目の課題は、同一環境内で時々刻々と変化する環境変動への対応である。本論文では異なる環境に適応する手法について種々述べたが、時間による光量の違い、一時的な影、遮蔽などの変化については対応していない。これらの変化は同一環境内でもシステム稼働時に周期的または突発的に発生するため、オンラインで学習して適応するアプローチが望ましい。

二つ目の課題は、より効率的な学習として、積極的な事前学習結果の利用が挙げられる。現在、本研究の手法も含む転移学習の多くは、事前ドメインから目標ドメインへのサンプルの転移を実現する手法が主軸であり、事前識別器はそのサンプルの取捨選択を補助するに過ぎない。しかし、効率的な転移という意味ではまさにその事前識別器で学習された識別ルールを転移可能とすべきである。これにより、再学習の無駄を大幅に低減し、すでにある識別器の調整で多様な環境に対応可能となることが期待できる。

また、本研究では物体検出の実用化にむけた条件に対して、分割統治による高精度化、貢献度に基づく識別器の調整法、学習サンプルの自動生成による効率化、ハイブリッド型転移学習による効率化を個々に提案した。物体検出の実用化のためには、本研究の成果を統合して扱うフレームワークの実現が重要である。

