

# 路車協調用画像センサの開発

— 未知シーンへの対応 —

東久保 政 勝\*・Epifanio Bagarinao・栗 田 多喜夫

Development of Image Processing Sensors for Cooperative Driving Safety Support Systems –To Respond to Unseen Situations — by Masakatsu Higashikubo, Epifanio Bagarinao and Takio Kurita — To realize Cooperative Driving Safety Support Systems (DSSS) aiming at the reduction of traffic fatalities and serious injuries, an image processing sensor needs to be installed on the road. With such a sensor, automobiles, motorbikes and pedestrians in a driver's blind corners are spotted and the obtained traffic data is provided to the driver. For this purpose, the sensor should be able to detect the position and travel speed of objects with a higher precision than that of traffic counters, regardless of weather conditions and time zones. The authors have developed an image processing algorithm which enables the reconfiguration of a highly precise detector, even in unknown situations, by adding small amount of training data and computation. In this paper, the authors report the outline and experimental results of the developed algorithm.

Keywords: DSSS, image sensor, Incremental SVM, re-training

## 1. 緒 言

交通事故抑止を目的とした路車協調型安全運転支援システムの実現のために、車両内からは見通し外となる範囲(図1)の交通状況を計測し、ドライバーに提供する画像センサが求められており、筆者らはその計測処理手法を開発した<sup>(1)</sup>。

この手法では、カメラ映像内から切り出した部分画像内に車両が存在するかどうかを識別する識別器を各種環境条件ごとに訓練し、これを用いることにより交差点付近の車両及び二輪車の位置を様々な環境条件(時間帯、天候)においても高精度に検出することを示した。しかし、条件Aにて訓練した識別器が他の条件Bにて高精度な検出を実現できない場合もあり、また各条件に応じた訓練を行うには、データ収集などのコストが膨大になる問題がある。筆者ら

は、条件Aにて訓練した識別器に、条件Bの少量の訓練データを追加することにより、少ない計算量で条件Bに適した識別器を再訓練する方式を開発した。本稿では、開発した識別器訓練手法の概要及び実験結果を報告する。

## 2. 開発の背景と目的

**2-1 社会情勢と路車協調型安全運転支援システム市場の出現** 我が国の交通事故発生状況は警察庁交通局の発表<sup>(2)</sup>の図2に示すように、交通事故による死者数は、8年連続で減少し、平成20年中の交通事故による死者数は5,155人となった。これは各種車載安全装置の普及や医療技術の向上に依るところが大きい。この状況を踏まえて、麻生総理は平成21年1月の施政方針演説において、今後10年間で、死者数を更に半減させ、「世界一安全な国、日本」を目指す方針を示しており、更なる事故抑止への取り組みが求められている。

事故発生状況を詳細に分析すると、事故の種類別においては、表1に示すように、追突、出会い頭及び右折時衝突事故が全体の6割以上を占めていることが分かる。また原付以上運転者(第1当事者)による交通事故件数を法令違反別にみると、表2に示すように安全不確認、脇見運転、動静不注視などの安全運転義務違反が全体の約4分の3を占めている。

このような事故発生状況において、施政方針演説の「今後10年間で、死者数を更に半減させる」という目標を達

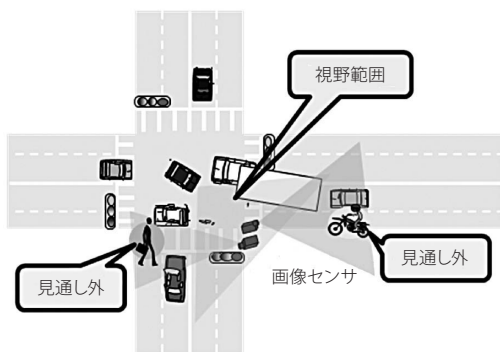



図1 路車協調用画像センサの計測範囲例



注1 昭和34年までは、軽微な被害事故（8日未満の負傷、2万円以下の物的損害）は含まない。  
 注2 昭和40年までの件数は、物損事故を含む。  
 注3 昭和46年までは、沖縄県を含まない。

図2 交通事故発生状況の推移<sup>(2)</sup>

表1 平成20年度の事故類型別交通事故件数<sup>(2)</sup>

事故類型	件数
追突	239,236
出会い頭	208,290
人対車両	70,704
右折時衝突	68,147
単独事故	38,671
正面衝突	19,247
その他	121,852
合計	766,147

表2 平成20年度の法令違反別交通事故件数<sup>(2)</sup>

法令違反	件数
信号無視	22,512
最高速度違反	8,613
一時不停止	33,670
運転操作不適	49,724
漫然運転	47,929
脇見運転	115,139
動静不注視	78,233
安全不確認	227,553
その他	140,147
合計	723,520

安全運転義務違反

通し外情報を計測し、検出結果及び画像情報を車両に提供することが重要である。また、その検出対象は、車両だけでなく、二輪車や歩行者も含み、それらの位置、速度及び移動方向を計測することにより、事故抑止に必要な情報をドライバー等に提供できる。具体的には、右折の際、対向する大型車両の死角で見えない二輪車の存在を知らせる、右左折時に他の車両に気を取られて見落とす歩行者の存在を知らせる、等である。

また、性能面においても、事故抑止実現のため、個々の車両や二輪車を様々な環境条件（時間帯、天候、カメラ設置位置、画角など）において高精度に計測する必要があり、従来の渋滞抑止を目的としたセンサよりも高度な計測処理技術が求められる。

成するには、従来の車両側、路側インフラ側のそれぞれのシステムにおける事故抑止だけでは回避できない事故の対策が必要であり、路側インフラ装置と車載装置が協調して事故を抑止する「路車協調型安全運転支援システム」<sup>(3)</sup>の実現が求められている。


この実現には、インフラ側の要素技術として、センシング、通信、交通信号制御の各種技術開発が必要であり、特にセンシング技術においては、計測範囲の広さ、製品寿命、コスト、性能のバランスを考慮し、画像処理方式が最有力と考える。

**2-2 路車協調用画像センサの目的と目標** 路車協調型安全運転支援システムを実現する画像センサの役割として、図1に示すように、車載装置単独では検出不可な見

### 3. 開発した識別器訓練手法

**3-1 計測処理全体の流れと課題** 図3に、報告済みの計測処理手法<sup>(1)</sup>の概要を示す。この手法における「大まかな検出処理」は、車両が存在する候補領域の絞り込み処理を担当しており、様々な環境条件（日照、画角など）における車両の見かけ上の変化やカゲ等の非車両との識別に対応する必要がある。この識別器としてSVM<sup>(5)\*1</sup>を適用しているが、条件Aにて訓練したSVMが他の条件Bにて高精度な検出が実現できない場合もあり、また各条件に応じた訓練を一から行うには、データ収集などのコストが膨大になる問題がある。

**3-2 提案手法** 筆者らは、条件Aにて訓練したSVMに、条件Bの少量のデータを追加することにより、少



検出手法	長所	短所	用途
HOG+SVM	検出漏れが殆どない 位置ズレでも検出可	検出枠内に少しでも侵入すれば検出する 正確な位置は検出できない	存在計測
EDGE強度+SVM	検出漏れが殆どない HOG+SVMより正しい位置を検出	検出枠内に少しでも侵入すれば検出する HOG+SVMより誤検出が多い	存在計測
矩形+Boosting	正確な位置の検出	類似物体の誤検出	位置検出

図3 計測処理全体の流れと各手法の特性

ない計算量で条件Bに適したSVMを再訓練する方式を開発した。図4に開発したSVMの再訓練手法を示す。

ここで、初期訓練セットは条件Aより抽出したデータセットであり、ラベル（車あり／車なし）付きのデータを十分に多く用意している。一方でターゲットセットは、条件Bより抽出したラベル付きデータであり、条件Bでの識別精度を検証するために必要最小限のデータ数を用意している。

まず、初期訓練フェーズでは、後述する非制約訓練または制約訓練にて、初期訓練セットを用いてインクリメンタルSVM手法によってSVMを訓練する。この段階では通常のSVM手法で訓練してもよい。次に、再訓練フェーズでは、ターゲットデータセットからデータを加えて、インクリメンタルSVM手法によってSVMを再訓練する。

3-3 手法説明 ここで、図4に示した各種手法の概要を説明する。

(1) 非制約訓練

ターゲットセットの識別精度の改善有無は考慮せずに、初期訓練セットを用いて、SVMを訓練する手法である。

- ①新規の訓練データを初期訓練セットから取得する。
- ②インクリメンタルSVM手法を用いて、SVMを更新する。
- ③更新したSVMを用いて、ターゲットセットを識別テストする。
- ④すべての訓練データを処理するまで①から繰り返す。

(2) 制約訓練

更新したSVMを用いて、ターゲットセットの識別テストを行い、識別精度が改善されたときのみ、SVMのサポートベクタ<sup>\*2</sup>を保持し、次の訓練に用いる手法である。非制約訓練に対して、ターゲットセットに適したSVMの訓練が期待できる。

図6に制約訓練の流れを示しており、概要は以下の通り。

- ①新規の訓練データを初期訓練セットから取得する。




図4 再訓練手法の流れ

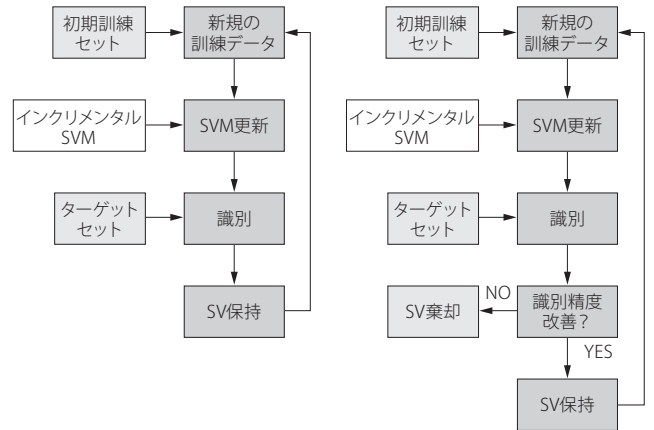


図5 非制約訓練の流れ

図6 制約訓練の流れ

- ②インクリメンタルSVM手法を用いて、SVMを更新する。
- ③更新したSVMを用いて、ターゲットセットを識別テストする。
- ④もし識別精度が改善されなかったら、更新したSVMのサポートベクタは保持しない。

⑤もし識別精度が改善されたら、更新したSVMのサポートベクタを保持する。

⑥すべての訓練データを処理するまで①から繰り返す。

### (3) インクリメンタルSVM

通常のSVM訓練では、用意したすべての訓練データを用いるのに対し、インクリメンタルSVM訓練では、一度に1つの訓練データを用いて最適化問題を解く。この手法の厳密な解法として、CauwenberghsとPoggioによって提案された手法<sup>(6)</sup>がある。この手法では、解となるサポートベクタセットに新規の訓練データを加える際に、それまでの訓練データがKuhn-Tacker条件<sup>\*3</sup>を維持するように再訓練する。

インクリメンタルSVMの実際の利点はオンライン学習にある。すなわち、新規の訓練データは一から再訓練することなく、既存の解に組み入れることができる。特に大規模な訓練データに対しては、通常のSVM訓練時間は非常に大きくなる問題があるが、インクリメンタルSVMにより、少ない計算時間で解決できるため、オンラインでの再訓練が実現可能になる。さらに、各サポートベクタの識別精度への貢献度も容易に評価することができる。これによって、ターゲットセットの識別を最適化する、適切なサポートベクタだけを選択することも可能になる。

## 4. 実験結果

実験準備として、図7に示す4種の映像シーン（DAY1, DAY2, NIGHT1, NIGHT2）から、それぞれデータセットを数万枚ずつ手作業にて切り出して作成した。このデータセットには、車両が含まれるデータと、含まれないデータを同数程度用意しており、これらを識別するSVMの訓練及び識別精度を検証した。実験では各シーンのデータを10グループに分けて訓練に用いた。以降、各グループをDAY1\_n（nはグループ番号）と呼ぶ。また、SVM訓練に投入する特徴ベクトル情報として、各データをHOG特徴<sup>(4)\*4</sup>に変換したデータを用いた。

### (1) 非制約訓練

NIGHT1のグループ毎に非制約訓練を行い、全4シーンのデータに対して、ラベル（車あり/車なし）の識別実験




図7 映像シーンとデータセット

を行った。その結果を表3に示しており、同一シーンのデータに対しては99%以上の高精度な識別結果が得られており、また同種のNIGHT2に対しても同様の高精度識別となった。一方で、その他のシーン（DAY1, DAY2）に対しては、60%台まで精度低下する場合があった。

### (2) 制約訓練

DAY1のグループ毎に非制約訓練及び制約訓練を行い、DAY2に対する識別実験を行った。その結果を表4に示しており、制約訓練による2つの効果が見られる。つまり、DAY2の識別精度が10%前後向上しており、一方でDAY1の識別精度が同程度低下している。しかし、DAY2の識別精度を向上させることが目的であるため、DAY1の精度低下は問題ではない。

### (3) ターゲットデータを加えた再訓練

DAY1のグループ毎に、初期訓練フェーズにて、非制約訓練または制約訓練を行い、その訓練結果のSVMに対して、NIGHT1のデータを加えた再訓練結果のSVMによる識別実験を行った。その結果を表5に示しており、非制約

表3 非制約訓練結果（単位：％）

NIGHT1_n	NIGHT1	DAY1	DAY2	NIGHT2
0	99.9739	84.6013	75.1565	98.5896
1	99.9804	90.4915	67.9231	99.8433
2	99.9869	91.2442	72.4156	99.8668
3	99.9902	88.531	69.6002	99.8198
4	99.9755	91.1023	73.3942	99.7649
5	99.9739	90.524	73.3907	99.7649
6	99.9771	91.4256	72.7755	99.7963
7	99.982	91.2152	80.945	99.8041
8	99.9902	90.1887	70.3555	99.859
9	99.9788	91.624	77.9559	99.8746

表4 制約訓練結果（単位：％）

DAY1_n	非制約訓練		制約訓練	
	DAY1	DAY2	DAY1	DAY2
0	99.7331	81.6683	91.2186	91.0664
1	99.716	82.7728	86.4113	94.7753
2	99.6801	82.5388	86.3121	93.692
3	99.7143	80.9981	86.3172	93.9863
4	99.7844	83.1912	79.6931	93.3215
5	99.7998	85.2336	78.2252	92.8127
6	99.7571	77.4063	87.0819	95.2256
7	99.8341	81.8793	83.077	93.3481
8	99.7759	82.4342	86.0674	88.6038
9	99.7109	82.9519	88.8885	95.1299



訓練及び制約訓練に関わらず、NIGHT1 に対して、99%以上の高精度な識別結果が得られた。また、DAY1 に対しては、初期訓練フェーズにおいて非制約訓練の方が、99%以上の高精度となった。

表5 インクリメンタルSVMによる再訓練結果 (単位: %)

DAY1_n	非制約訓練		制約訓練	
	DAY1	NIGHT1	DAY1	NIGHT1
0	99.675	99.9935	89.0613	99.9951
1	99.7109	99.9935	90.9996	99.9886
2	99.6613	99.9902	93.0765	99.9935
3	99.7006	99.9951	96.0669	99.9706
4	99.7793	99.9967	90.9329	99.9967
5	99.8084	99.9918	90.666	99.9967
6	99.7536	99.9886	82.0351	98.6686
7	98.8777	99.4527	92.5308	99.9984
8	99.7827	99.9918	90.9466	99.9951
9	99.6921	99.982	97.9693	99.9918

#### (4) 再訓練時の追加データ数

再訓練におけるターゲットデータの追加数とターゲットセットの識別精度の変化を図8にまとめた。同図左は、初期訓練セットをDAY1\_0、ターゲットセットをDAY2とした場合であり、同図右は、初期訓練セットをDAY1\_0、ターゲットセットをNIGHT1とした場合である。初期訓練フェーズにおいて非制約訓練を行った場合でも、数十から数百のデータを追加するだけで、高精度なSVMを再訓練可能であることが分かった。




図8 再訓練時の追加データ数と識別精度

#### (5) 実験結果まとめ

初期訓練セットのみに対する制約訓練によって、ターゲットセットに対する認識精度を高めたSVMを訓練可能であることを確認した。さらに、ターゲットデータを加えた再訓練を行うと、数百個程度のデータ追加によって、

ターゲットセットを高精度に識別するSVMの再訓練を実現した。再訓練にインクリメンタルSVM手法を適用することにより、全訓練データを一から訓練する場合に比べて大幅な計算時間削減が見込まれる。また、初期訓練フェーズにおいては非制約訓練を行った上で、ターゲットデータを加えた再訓練を行うことにより、初期訓練セット及びターゲットセットに対する高精度なSVMを訓練可能であることが分かった。

今後は、訓練時間の詳細検証及び更に多くのシーンでの識別精度検証を行うとともに、追加するラベル付きターゲットデータを自動的に収集する方式の開発を進めている。

## 5. 結 言

車両及び二輪車の検出機能の実用化に向けて、様々な環境条件(時間帯、天候、カメラ設置位置、画角など)においても少ない計算量で高精度に、その機能を実現する手法を開発した。この手法を用いることにより、オンラインでの再訓練が可能になり、さらに追加データの自動収集機能を付加することにより、初期訓練セットには含まれていない未知シーンにおいても自動的にかつ高精度な検出機能の実現が見込まれる。

そして、この方式による計測結果をドライバーに提供することによって、交通事故抑止の実現に貢献していく。

### 用語集

#### ※1 SVM

Support Vector Machineの略。データを2クラスに分類する手法の1つで、未知データに対する分類エラーが最小となる境界面を算出する。

#### ※2 サポートベクタ

SVMによる境界面を構成するために必要なサンプルデータ。

#### ※3 Kuhn-Tacker条件

不等式制約付きの最適化問題の解法において、最適値が存在するための条件。

#### ※4 HOG特徴

Histogram of Oriented Gradientsの略。画像の局所領域において、輝度の勾配強度を方向ごとにヒストグラム化した特徴ベクトルであり、人検出における特徴量として有力な手法の1つである。

参 考 文 献 -----

- (1) 東久保政勝、栗田多喜夫、「路車協調用画像センサの開発」、SEIテクニカルレビュー、第175号、pp.108-113 (2009)
- (2) 警察庁交通局、「平成20年中の交通事故の発生状況」、<http://www.npa.go.jp/toukei/koutuu48/H20.All.pdf> (2009)
- (3) 社団法人新交通管理システム協会、「安全運転支援システム (DSSS)」、<http://www.utms.or.jp/japanese/system/dsss.html>
- (4) N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection", IEEE Conference on Computer Vision and Pattern Recognition, pp. 886-893, Jun (2005)
- (5) 栗田多喜夫、「サポートベクターマシン入門」、<http://www.neurosci.aist.go.jp/~kurita/lecture/svm/svm.html>
- (6) Cauwenberghs, G. and Poggio, T., "Incremental and Decremental Support Vector Machine Learning.", Leen, T.K., Dietterich, T.G., and Tresp, V. (eds) Advances in Neural Information Processing Systems, vol. 13, pp. 409-415. MIT Press (2001)

-----  
執 筆 者 -----

東久保政勝\* : 情報通信研究所 主席  
道路交通計測用画像センサの研究開発に  
従事



Epifanio Bagarinao : (独) 産業技術総合研究所 Ph.D.

栗田多喜夫 : (独) 産業技術総合研究所 工学博士

-----  
\* 主執筆者