

科学研究費助成事業 研究成果報告書

平成 26 年 5 月 13 日現在

機関番号：82626

研究種目：基盤研究(C)

研究期間：2010～2013

課題番号：22500172

研究課題名(和文) 訓練サンプル最適化による識別器の性能向上手法

研究課題名(英文) Performance Improvement for Classifiers by Optimizing Training Samples

研究代表者

西田 健次(Nishida, Kenji)

独立行政法人産業技術総合研究所・ヒューマンライフテクノロジー研究部門・主任研究員

研究者番号：50344148

交付決定額(研究期間全体)：(直接経費) 3,200,000円、(間接経費) 960,000円

研究成果の概要(和文)：車両検出・追跡手法の研究においては、ペア特徴を用いた追跡手法に訓練サンプルセットの最適化を適用することで、位置精度が高く、かつ、対象の見えの変化に頑健な追跡手法を確立することが出来た。訓練サンプルの最適化による汎化性能向上手法の研究においては、少数のサンプルによって訓練した識別器を統合することにより、学習時間が短く、かつ、汎化性能の高い識別器の構成手法を確立した。この手法では、訓練サンプルから抽出した少数のサンプルに対して訓練した複数の識別器を組み合わせることにより、大規模なサンプルで訓練した識別器よりも高い汎化性能を有する識別器を、より少ない学習時間で構成することが可能となった。

研究成果の概要(英文)：A precise vehicle detection-and-tracking algorithm that is robust for the appearance change of the objects has been determined using an optimization of the training sample-set. An algorithm for obtaining the Random-Subset SVM ensemble is determined. The algorithm combines some weak-classifiers that are trained by small samples extracted from whole training sample set. The required training time for the ensemble classifier is considered to be smaller than the training a classifier using full l-set of training samples, while attaining better generalization performance.

研究分野：総合領域

科研費の分科・細目：情報学 知覚情報処理・知能ロボティクス

キーワード：パターン認識 画像認識 データマイニング ITS

1. 研究開始当初の背景

道路上を走行中の車両追跡という課題において、次々と入力される画像情報は、膨大な数の学習サンプルとなり、新たな追跡対象となる車両が現れるたびに学習を繰り返す必要があるため、学習時間が短く、かつ、汎化性能の高い識別器が必要とされている分野であった。識別器の学習手法に関しては、カーネル法、サポート・ベクトル・マシン (SVM) など非線形識別手法の発達により、訓練サンプルに対しては 100% の識別率を実現することも困難ではなくなっている。しかし、識別器の実質的な性能となる未学習サンプルに対する識別性能 (汎化性) を向上させるためには、識別対象となるサンプルからどのような特徴量を抽出するか、また、識別に有効な特徴をそのようにして選択するかなど、多くの課題を解決する必要がある。また、ビッグデータなどと呼称される大規模なサンプルセットに対しては、サンプル数に起因する学習時間の増大も大きな問題となっている。そこで、大規模なサンプルに対して、汎化性能の高い識別器を効率よく学習させることのできる手法の開発が重要視されてくるようになった。従来より、汎化性向上のためには、識別に有効な特徴を選択する手法が用いられてきたが、サンプル数の増大などにより、学習に必要な時間が増大してきた。また、外れ値を持ったサンプルの影響を除去するために手法の必要となってきた。

2. 研究の目的

本研究の目的は、道路走行中の車両の検出・追跡に有効な、識別性能と汎化性能の両立した識別手法を確立することである。道路走行車両の検出・追跡のためには、隣接車両、および、類似車両との識別を確実に行う識別性能が必要であり、かつ、照明条件の変化、隠れなどによる同一車両の見えの変化に体操できる汎化性能も必要とされる。識別性能、汎化性能を含めた識別器の性能向上を行うためには、適切な特徴を選択し、同時に、適切な学習が行える適切な訓練セットを選択する必要がある。本研究では、共起特徴の一種であるペア特徴を用いた識別器での特徴選択手法と訓練セットの最適化手法を同時に進めることで、車両検出・追跡に有効な識別器の構成手法を確立することにあつた。この目的を達成するため、(1) ペア特徴を用いた車両検出・追跡手法の研究、(2) 訓練セット最適化による汎化性能向上手法の研究の二つのサブテーマを設定した。

3. 研究の方法

(1) ペア特徴を用いた車両検出・追跡手法の研究

本研究では、共起の最小構成要素と考えられる二つの画素 (ペア) の組み合わせをベースとした特徴量を用い、車両検出・追跡での性能向上を図る。本研究の提案者は、二つの画

素間の輝度差を特徴としたペア特徴による車両追跡手法を提案しており、正例と負例での判別基準によってペアを選択することで、照明条件などに対して頑健で、かつ、追跡能力の高い識別器が構成できることを示している (SPPRA2010)。ペアの組み合わせは膨大な数となり、準最適なペア特徴群を効率的に求める必要がある。また、ペア特徴に用いる局所特徴は、輝度に限るものではなく、エッジ強度、色情報など、様々な特徴が可能である。そこで、画素ペアだけでなく、特徴の組み合わせまで含めたペア特徴の有効性を検証した。

(2) 訓練セット最適化による汎化性能向上手法の研究

訓練サンプルの一部をランダムに選択し、全訓練サンプルでの識別率を評価することで、汎化性向上に有効な訓練サンプルのセットを構成する手法 Ransac-SVM が既に提案され、全訓練サンプルよりも遥かに少ない数の訓練サンプルで識別器を構成しても、全訓練サンプルで訓練を行って構成された識別器よりも、汎化性能が高いことが示されていた。本研究では、更に効率的な訓練サンプルセットの最適化を行うため、遺伝的アルゴリズム (GA)、粒子群最適化法 (PSO)、メタヒューリスティクス、アニーリングなど、現在知られている最適化手法の適用可能性を検証していく。また、車両追跡に関しては、時系列データの最適化として、カルマンフィルタ、パーティクルフィルタ、Online Boosting などの手法を検討した。

3. 研究成果

(1) 車両検出・追跡手法の研究

路車協調型安全運転支援システム開発の一環としてペア特徴を用いた車両検出・追跡手法の研究を行ってきた。追跡手法に特化した学習法として、追跡対象が画像パッチの中心に位置するサンプルを正例、追跡対象が画像パッチの中心からずれた位置にあるものを負例として、位置精度の高い追跡を行う事を可能とした (図 1)。




図 1 追跡における正例と負例

この正例と負例の識別を高速に行うために、判別基準に基づいてペア特徴の選択を行った (図 2)。これにより、追跡対象に対する学習時間を短縮することが可能となり、かつ、追跡対象の位置を精度よく推定することが

可能となった。

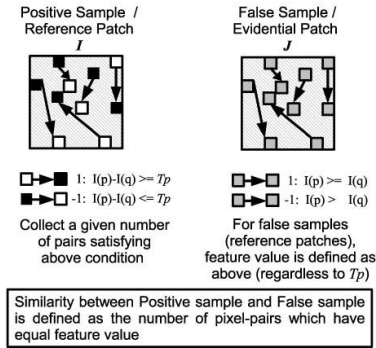


図2 ペア特徴

提案された追跡手法を、表1および図3に示すビデオシーケンスに対して適用し、その性能を評価した。

表1 実験に用いたシーケンス

Sequence	Time	Features	Number of Frames	Max Distance (approx.)
DAY1	Daytime	3 lanes / Shadows of roadside buildings and columns of a highway above the road / Heavy traffic	12,947	80m
DAY2	Daytime	2 lanes / Shadow of roadside trees (swayed by wind) / Change of the daylight	26,204	50m
NIGHT1	Nighttime	3 lanes (Same place as DAY1) / Reflection of headlights on the road surface / Heavy traffic	11,119	80m
NIGHT2	Nighttime	2 lanes (Same place as DAY2) / Reflection of headlights on roof of vehicles	3,000	50m
TAIL	Daytime to Nighttime	2 lanes / Highway / Tracking of tails of vehicles / Medium to Heavy Traffic	9,999	100m




図3 各シーケンスに特徴的な画像

評価に用いたビデオシーケンスは、日中のもの2種、夜間2種、夕刻(日中から夜間への変化)の5種であり、一般道、高速道の両者を含んでいた。

表2 トラッキング性能

Sequence Name	Number of Frames	Number of Vehicles / Motorcycles	Number of Misses of Detection	Number of False Positives	Number of False Positives per Frame
DAY1	12947	885	2 (0.226%)	2371	0.183
		46	5 (10.9%)	1038	0.0802
DAY2	26203	989	1 (0.101%)	6898	0.263
		57	7 (12.3%)	295	0.0113
NIGHT1	11118	741	5 (0.675%)	931	0.0837
		49	5 (10.2%)	1296	0.117
NIGHT2	3000	98	2 (2.04%)	186	0.062
		11	0 (0.0%)	98	0.0327
TAIL	9999	682	5 (0.733%)	2452	0.245

表2に、実験で得られたトラッキング性能をまとめる。日中のシーケンスでは、四輪車の未検知率は0.1%~0.23%、二輪車で10%~12%の性能が得られ、御検出率も0.1~0.2程度と十分な性能を得ることが出来た。夜間においては、四輪車の未検知率0.7%~2%と、日中よりやや劣る性能となったが、十分な性能と達成しており、誤検出率が0.1未満と優秀な性能となっている。

図4に、検出された例を示す



図4 検出例

(2) 訓練サンプルの最適化による汎化性能向上手法の研究

訓練サンプルから抽出した小規模なサブセットによって識別器の学習を行い、それらを統合することで、学習に必要な計算量を削減するとともに、汎化性能の高い識別器を構成する手法を検討し、評価を行った。

$$f(x) = \sum_{m=1}^P \beta_m \sum_{i \in S_m} \alpha_m y_i (K_m(x, x_i)) + b$$

$$= \sum_{m=1}^P \beta_m f_m(x) + b$$

式(1)

このアルゴリズムは、Multiple Random Subset Kernel Learning (MRSKL)と名付けられ、式(1)のように表現される。ここで、 f_m は抽出されたサブセットに対する弱識別器を意味し、 m は弱識別器を統合する際の重みである。

サブセットの抽出手法として、(1)正例負例の1ペア、(2)小規模(正例負例数個から十個程度)の二つの手法について検討を行った。実験は、20,000サンプルの人工データを用いて評価を行い、その最適な識別境界は図5のBayes estimationで示される。




図5 実験に用いたサンプルと識別境界

図6は、1ペアのサンプルをサブセットとして用いる手法での抽出されたペア数による識別境界の変化を示したものである。この結果は、20,000サンプルの学習セットに対して200ペア程度(400個のサンプル)を抽出すれば、ほぼ最適な識別境界が得られることを示している。




図6 実験結果

抽出されたペア数による識別率の変化を示す。図7は、学習サンプルに対する識別率、図8は、未学習サンプルに対する識別率である。




図7 訓練サンプルに対する識別率




図8 未学習サンプルに対する識別率

これらの結果は、全サンプルを用いて学習を行った識別器よりも、高い汎化性能を少数（400個程度）のサンプルで訓練することによって得られたことを示している。

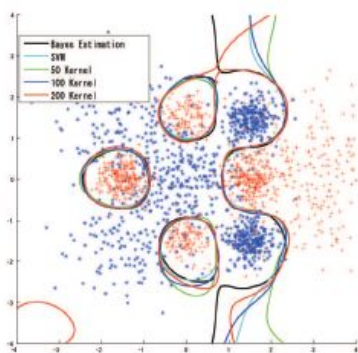


図9 10 サンプルサブセットによる識別境界

図9は、10サンプル（正例5個、負例5個）による弱識別器を統合した際の識別境界の変化を示す。1ペアサブセットの場合と同様に、200個の弱識別器を統合することで、ほぼ最適な識別境界が得られている。図10に、訓練サンプルに対する識別率、図11に未学習サンプルに対する識別率を示す。




図10 学習サンプルに対する識別率




図11 未学習サンプルに対する識別率

図10の結果は、訓練サンプルに対する過学習の傾向を示しているが、図11の未学習サンプルに対する識別率の変化によると、汎化性能の低下は避けられており、有効な手法であることが示されている。

5. 主な発表論文等

（研究代表者、研究分担者及び連携研究者には下線）

〔雑誌論文〕(計 1件)

Real-Time Vehicle Detection using a Single Rear Camera for a Blind Spot Warning System, 土谷 千加夫 (日産自動車株式会社), 田中慎也 (日産自動車株式会社), 古性 裕之 (日産自動車株式会社), 西田 健次, 栗田多喜夫 (広島大学), International Journal of Passenger Cars - Electron. Electr. Syst., 5-5, pp.146-153, 2012/05

〔学会発表〕(計 7件)

Road Plane Detection using Differential Homography Estimated

by Pair Feature Matching of Local Regions, 西田 健次、藤木 淳、土谷 千加夫 (日産自動車株式会社)、田中慎也 (日産自動車株式会社)、栗田多喜夫 (広島大学), Proc. SPPRA 2011, -, pp.23-29、2011/02

Multiple Random Subset-Kernel Learning, 西田 健次、藤木 淳、栗田多喜夫 (広島大学), Computer Analysis of Image and Patterns, 1-1, pp.343-350、2011/08

ENSEMBLE RANDOM-SUBSET SVM, 西田 健次、藤木 淳、栗田多喜夫 (広島大学), Proc. IJCCI 2011, -, pp.334-339, 2011/10

Road Region Detection by Spatio-Temporal Graph Segmentation of Optical Flows Using On-Board Camera, 西田 健次、藤木 淳、小林 匠、土谷 千加夫 (日産自動車株式会社)、田中慎也 (日産自動車株式会社)、栗田多喜夫 (広島大学), Proc. of International Conf. on Signal Processing, Pattern Recognition and Applications, -, pp.9-16、2012/06

Tracking by Shape with Deforming Prediction for Non-Rigid Objects, 西田 健次、小林 匠、藤木 淳 (福岡大学), Proc. 3rd International Conference on Pattern Recognition Applications and Methods, -, pp.580-587、2014/03

訓練セットのランダムサンプリングによるマルチカーネル学習法, 西田 健次、藤木 淳、栗田多喜夫 (広島大学), MIRU2011 論文集, -, pp.125-131、2011/0

環境変化やノイズに対してロバストな画像センサによる車両・二輪車計測, 小野祐樹 (住友電気工業)、東久保政勝 (住友電気工業)、荻内康雄 (住友電気工業)、栗田多喜夫 (広島大学)、西田 健次、稲吉 宏明, 第 10 回 ITS シンポジウム 2011 proceedings, -, pp.145-150、2011/11

6. 研究組織

(1) 研究代表者

西田 健次 (NISHIDA Kenji)

(独) 産業技術総合研究所・ヒューマンライフテクノロジー研究部門・主任研究員

研究者番号: 50344148

(2) 研究分担者

栗田 多喜夫 (KURITA Takio)

広島大学・大学院工学研究院情報部門・教授

研究者番号: 10356941