

博士論文

道路画像を用いた車種認識手法に関する研究

Vehicle Type Recognizing Methods on
Time-sequence Road Images

横浜国立大学附属図書館



11792740

横浜国立大学大学院
情報情報学部

博士論文
MITSUBISHI

2009.9.30

1
5

寄贈者：鄭明燮

11792740
道路画像を用いた車種認識手法に関する研究

377.51
Z11

道路画像を用いた車種認識手法に関する研究

鄭 明燮

横浜国立大学大学院 環境情報学府

横浜国立大学附属図書館



11792740

指導教官

後藤 敏行 教授

2006年9月

Vehicle Type Recognizing Methods on Time-sequence Road Images

by

Mingxie ZHENG

Graduate School of Environment and
Information Sciences
Yokohama National University

Supervisor
Professor Toshiyuki Gotoh

September 2006

目次

第1章 序論	1
1.1 研究背景	1
1.2 従来研究	3
1.2.1 車両検出技術	3
1.2.2 車種判別技術	4
1.3 研究の目的	5
1.4 論文の構成	6
第2章 多重構造ニューラルネットワークを用いた車載センサ情報統合に 基づく車種認識	7
2.1 はじめに	7
2.2 車載センサを用いた走行環境認識	9
2.3 車種認識アルゴリズム	11
2.3.1 データの正規化	11
2.3.2 多重構造ニューラルネットワーク	13
2.3.3 フレーム単位の車種判定	16
2.3.4 画像情報に基づく車種判別	17
2.3.5 道路の走行環境モデルに基づいた時系列車両認識	19
2.4 実験と考察	20
2.4.1 実験条件	20
2.4.2 多重構造ニューラルネットワークの構築	22
2.4.3 車載センサの情報統合の評価	24
2.4.4 認識結果と考察	24
2.5 まとめ	30
第3章 車両モデル認識のための車両フロント領域の自動検出	31
3.1 はじめに	31
3.2 車両検出アルゴリズム	33
3.2.1 車両進入検知	34
3.2.2 車両フロント領域の検出	35
3.2.3 車両フロント領域の正規化	36
3.3 実験	37

3.3.1	実験条件	37
3.3.2	検出結果	39
3.4	考察	42
3.5	まとめ	43
第4章	類似モデルのグループ化による車両モデルの多段階認識	44
4.1	はじめに	44
4.2	車両モデルの自動識別処理の概要	46
4.3	車両モデルの認識アルゴリズム	48
4.3.1	車両フロント領域の特徴抽出	49
4.3.2	多段階認識法に基づく車種認識	51
4.3.2.1	部分空間法	51
4.3.2.2	多階層認識空間の生成	52
4.3.2.3	多段階認識処理	54
4.3.3	時系列車種認識	55
4.4	実験	56
4.4.1	実験条件	56
4.4.2	車両モデル認識に適合する特徴空間の検討	62
4.4.3	多階層認識空間の構築	64
4.4.4	フレーム単位の車両モデル認識	66
4.4.5	従来手法との比較	68
4.4.6	時系列処理の認識結果	69
4.4.7	環境変化における評価実験	70
4.5	考察	71
4.6	まとめ	74
第5章	結論	75
5.1	本研究のまとめ	75
5.2	今後の展望	78
	謝辞	79
	参考文献	80
	本研究に関連する発表文献	82

第 1 章

序論

1.1 研究背景

現代社会において自動車は、交通の主役として欠くことのできない役割を果たしている。しかしその反面、交通事故による死傷者は日本国内でさえ毎年百万人にもものぼり、事故に伴う人的・経済的な損失は多大である。また、都市部の道路や高速道路では連日の渋滞により、交通網が遮断され、物流に悪影響を与えているだけでなく、エネルギー問題や環境問題の観点から見ても忌々しき事態である。

この事態を解決すべく、現在、ITS (Intelligent Transportation Systems)の研究が進められている。ITS とは、最先端の情報通信技術を用いて人と道路と車両を情報ネットワーク化することにより、交通事故、渋滞などといった現在の道路交通問題の解決を目指す新しい交通システムのことである。この ITS は現在世界各国で推進されており、ITS 世界会議も今年のイギリス・ロンドンでの開催により第 13 回を数え、社会の認知度も年々高まっている。日本においても、1996 年 7 月、関係 5 省庁によって「ITS 推進に関する全体構想」が策定され、ナビゲーションの高度化、自動料金収受システム、安全運転の支援、交通管理の最適化、道路管理の効率化、公共交通の支援、商用車の支援、歩行者等の支援、緊急車両の運転支援など 9 つの開発分野において、21 の利用者サービスの構想が示された[1]。

ITS 実現においてセンシング技術は情報通信技術と並んで重要な技術分野のひとつである。その中でも、画像センシング技術は、安全で、安心な自動車社会を保つために重要な役割を果たしている。画像センサはすでにドライバーの運転支援や交通管理者への情報提供のために車両や道路上に設置されている。

「安全運転の支援」は ITS の中でも注目されている開発分野であり、前方の環境を認識してドライバーへの情報提供や警報、操作支援を行う運転支援システムの開発や自動車の知能化を目的とした環境認識技術の研究・開発が進められている。これは、交通事故による死傷者を大幅に減らすことと、反射能力や変化する周辺状況への適応能力の低下する高

齢ドライバーでも安心して運転できる道路交通環境を提供するなど、その実現への期待が大きい。

一方、道路交通管制分野において、スムーズな交通流を確保するためには、自動車の交通量監視は欠くことができない。交通流計測は渋滞回避、旅行時間予測、管制センターやドライバーに有益な情報を与えるものとし、ITSにおいて大きな役割を担っている。交通流計測は、古くから台数を人手によりカウントしてきたが、現在は自動化が進められて、超音波センサや磁気センサの車両感知器が使われるようになった。さらに高度な情報を得るためには、監視モニターから車両情報を取得、交通事故の検出などの高度な交通監視への自動化が期待されている。

近年、生活水準の向上、車両価格の低下により、各国の自動車の保有台数が増え続けている。しかしその反面、車両盗難件数も年々増えていって世界的な問題になっている。自動車盗難発生率をみると、アメリカやヨーロッパではおよそ100人に1人、日本でも1000人に1人は被害にあっている。日本の検挙率は世界的に見ると低くはないが、それでも8割ほどが検挙できないでいるのが現状である[2]。盗まれた車両はナンバープレートが偽装されるのが多いため、無事に戻ってくることはかなり少ないことが考えられる。この問題を解決するためには、盗難の防止策も重要であるが、偽装車両の捜査に情報を提供できるシステムの開発も必要である。

1.2 従来研究

1.2.1 車両検出技術

安全運転の支援のために、周囲の状況を把握するには、車両の検出が重要である。車両検出には、ミリ波レーダ、超音波レーダ、レーザレーダやカメラなどの車載センサを利用した技術が数多く開発されている。中では、ミリ波レーダやレーザレーダなどの距離センサによる先行車を対象とした車間距離計測技術は開発が進んでおり、車間距離自動制御システムとして、一部の自動車に搭載されている[3]。しかし、距離センサは遠距離でも高精度な距離情報が得られるという特長を持つ反面、対象物の種類の識別が難しい。また、これらのシステムは走行車線における自車の位置や、先行車との車間距離を検知し、自車の動作を制御しているが、実際の運転においては周囲の車や道路周辺の障害物との相互関係によって動作を判断する場面が多い。

これに対し、画像センサによる画像処理技術は道路状況と車両の同時検出が可能という特徴を持っている。障害物検出には、オプティカルフローを解析する手法が有効で、単眼カメラを用いて、自車に接近してくる車両を検出する手法として、路面の動きを画像の各画素の動きと異なる動き情報を用いて推定し、路面の動きと異なる動きをする領域を障害物領域として検出する手法が提案されている[4],[5]。これらの手法は、運動視差を利用した手法で、路面上に明瞭なテクスチャがある場合には有効であるが、実際の走行環境では路面にテクスチャがないことも多く、適用できるシーンが限られる。また、オプティカルフローに基づく方法は雑音に弱く、動きが不連続となる物体の境界などには信頼性が低くなるという問題がある。複数のカメラを用いた、ステレオ画像処理は距離計測も可能であるため、ステレオ視により先行車の位置を検出する手法も提案されている[6]。しかし、ステレオ計測は遠距離になるほど距離分解能が低くなるため、距離センサと比べて遠方の計測精度が低いという欠点がある。

このような車載センサの得失に対して、それぞれのセンサの特徴を活かしたセンサフュージョンの研究が注目されている[7],[8]。たとえば、下村らは遠距離の距離計測に適したスキャニングレーザレーダと近距離の高精度距離計測が可能な画像処理を統合して、前方追跡車両の計測位置を高精度に求める手法を提案している[9]。しかし、実際の運転においては、先行車はもちろん周囲の車や道路周辺の障害物など、車と環境の関係も含めて判断し、操作する必要がある。このような観点から、高速道路を対象として、白線検出用車載カメラとスキャニングレーザレーダによる車両と道路構造物を区別する手法も提案されている[10]。この手法は、路面の白線情報をもとに検出を進めるため、高速道路のように白線が明瞭な場面には有効であるが、一般道路などでは車線がないことも多く適用できる場面が限られる。一方、最近はより高度な運転支援システムを目指して、車両が停止や走行を繰り返す低速域での走行環境認識をも可能とするシステム実現への期待が大きい[11]。特に、一般道路で周囲の車種の走行特性や障害物の違いを考慮した運転制御も期待されている。

一方、交通監視システムにおいても画像処理による車両検出の研究開発が進められてきた。その主なものは、カメラを道路上部に設置し、その画像から、背景差分、時間差分、空間微分などの処理により、画像中に存在する移動車両を抽出するものや、3次元モデルや2次元モデルをもとに画像中の車両を検出、追跡するものなどである。しかし、これらの主目的は交通流計測のための車両の台数を計測することであり、車種判別機能を持つものはほとんどなかった。

1.2.2 車種判別技術

交通状況監視システムへの適用を目指した車種判別の研究として、ナンバープレートから車種情報を得る方法が古くからあって開発が進んでいる[12]。画像処理等によりナンバープレートを読み取り、車両ナンバーが特定されれば多くの情報が得られるが、プライバシーの問題が残る。また、路車間の通信により車両IDを送信する方法も提案されているが、車載装置が必要となるために適用範囲が限られる。

これらの問題に対して、路上のカメラ情報から車両の形状特徴に基づいて車両モデルの認識が可能になれば、個人情報へのアクセスや特別な装備なしに車両種別(トラックや乗用車など)だけではなく車両モデルの取得が可能になる。

これまで、車両の形状特徴に基づいて車種判別を行う研究としては、道路脇に設置した単眼カメラで車両後方画像を取得し、車両の断面形状を用いて車両を3種類に分類する手法[13]や、複数台のカメラで撮影した3次元計測結果を用いて、車両の輪郭形状から3種類の車種を識別する手法[14]などが提案されている。また、長谷川らは、対面通行の一般道路映像中から、移動対象物を6種類の種別に識別するとともにそれらの色の推定を行う手法を報告している[15]。このシステムは、対象の姿勢変化への対応は可能になっているが、対象の種類は6種類に限定されている。一方、影沢らは、赤外線画像によって一部が隠蔽されている場合でも、あらかじめ指定した特定の車種を道路画像から検出するシステムを提案しているが、識別対象が多い場合の評価は行われていない[16]。また、駐車車両を対象として Match refinement 法による車種認識手法が提案されているが、通過車両に対する検討は報告されていない[28]。このようにこれまでの研究では、乗用車やトラックといった車両の形の分類に関する方法は多く検討されてきたが、通過車両を対象として、A社N年式B型というような特定メーカーの特定のモデル(以後、車両モデルと呼ぶ)の認識を目指した研究はほとんどない。

1.3 研究の目的

本論文では、安全運転支援システムや車両監視システムへの応用を目指し、ドライバーに最適な車間距離を維持するための運転支援やナンバープレートに代わる車種情報の取得を目的として、観測した時系列道路画像から検出した車両の車種を高精度に認識する手法について論ずる。本論文では特に、車載センサの情報統合に基づく前方環境認識と路上カメラによる通過車両監視に関する研究開発をまとめる。

走行車両における前方環境認識の研究では、前方の複数の車両や障害物を検出し、検出した車両の種別(大型車, 普通車, 二輪車)を判別するために、最初に、高精度な距離計測と方向計測が可能なスキニングレーザレーダと、対象物や車両の画像特徴が得られる車載カメラの情報を統合する手法について述べる。また、複雑背景中で大きさの異なる対象物を高精度に識別するために、異なる受容野特性を持つ多重構造ニューラルネットワークを用いた車両認識手法を提案する。さらに、認識の安定性と高精度化を実現するために、車両の道路走行環境モデルを用いて、時系列的に観測した結果を統合評価する時系列認識評価手法について検討する。

次に、車両監視システムへの応用を目指した路上カメラによる通過車両のモデル認識の研究では、さらに詳しい車両情報を取得するために車両の形状特徴に基づいて車両モデル認識手法について述べる。車両モデルの認識が可能になれば、道路使用状況分析に車種別の交通流計測が可能になるばかりではなく、ナンバープレートの偽装に強い捜査情報の提供や、設計時の類似車両モデル検索などにも応用できる。さらに、ナンバープレート情報との照合により偽装車両を発見し、犯罪抑止に役立つシステムの構築にも利用できる。

通過車両の車両モデルを認識するためには、道路画像から車両を検出し、正確に車両の特徴を取得する必要がある。しかし、屋外で撮影が行われるために、道路画像は環境変動に影響を受けやすく、変形やぶれなどの問題もある。本研究では、車両モデルを認識するための自己対称テンプレートを用いた車両フロント領域の自動検出手法を提案する。また、多様な環境から収集した時系列道路画像を用いて実験を行い、検出手法の有効性を示すとともにカメラの設置条件について検討する。

車両モデルの認識に当たっては、市販されている車両モデルが多様で、車両の形状が類似したモデルも多く、同一の車両モデルの中でも車体の色違いや文字や模様が入る場合もあり、車両モデル認識を難しくする要因となっている。本研究では、このような問題に対して、類似車両モデルのグループ化を行い、それを用いて最適な特徴を選択する多段階認識法を提案する。さらに、時系列道路画像を用いて評価実験を行い、提案手法の有効性を検討する。

1.4 論文の構成

本論文は、5章より構成される。第1章は序論であり、画像認識技術を用いた車種認識の研究の背景および応用例について述べ、これまで開発された代表的な車種認識の特徴と問題点について考察し、本研究の位置づけと目的を明らかにする。

第2章では、安全運転支援システムへの応用を目的として、走行環境から前方の複数の車両および障害物を検出し、検出した車両の車種(大型車、普通車、二輪車など)を判別する車両検出・車種判別手法を提案する。この手法では、複雑背景中で大きさの異なる対象物を高精度に識別するために、多重構造ニューラルネットワークを用いて識別を行う。さらに、認識の安定性と高精度化を実現するために、車両の道路走行環境モデルを用いて、時系列的に観測した結果を統合評価する時系列認識評価手法について検討する。走行環境で収集された実データを用いて評価実験を行い、本手法の有効性を示す。

第3章では、車両監視システムへの応用を目的として、固定カメラで観測した通過車両の車両モデルを認識するための車両フロント領域の自動検出手法について述べるとともに、撮影時のカメラ設置条件について検討を行う。さらに、時系列道路画像を用いて自動認識に必要な車両フロント領域の特徴を精度よく安定に取れることを検証する。

第4章では、前章での自動検出手法で検出された車両特徴を用いて、類似モデルのグループ化による多段階車両認識法を提案する。この手法では、学習の段階で類似した車両モデルのグループを生成し、認識にあたってそのグループの中で車両の部分領域ごとの類似性を統合評価することで、環境変化の影響を回避しながら、類似した車両モデルの認識を行うものである。異なる環境において収集した時系列道路画像に本手法を適用し、高精度に認識できることを確認する。

最終章は結論であり、本研究で得られた成果の統括及び実用化に際しての課題についてまとめる。

第2章

多重構造ニューラルネットワークを用いた車載センサ情報統合に基づく車種認識

2.1 はじめに

近年、ITS 開発の一環として、安全運転支援への応用を目指した走行環境認識の研究開発が進められている[1]. なかでも、ミリ波やレーザレーダなどの距離センサによる先行車を対象とした車間距離計測技術は開発が進んでおり、車間距離自動制御システムとして、一部の自動車に搭載されるようになった[3]. しかし、距離センサは遠距離でも高精度な距離情報が得られるという特長を持つ反面、対象物の種類の識別が難しい. これに対して、車載カメラを用いた画像処理は道路状況および車両を検出できる可能性がある[4],[5]. また、ステレオ画像処理は物体までの距離が計測できるため、これを利用して先行車の位置を検出する手法[6]も提案されているが、計算コストや遠距離における計測精度の低下の問題がある.

このような車載センサの得失に対して、それぞれのセンサの特徴を活かしたセンサフュージョンの研究が注目されている[7],[8]. たとえば、下村らは遠距離の距離計測に適したスキャニングレーザレーダ(Scanning Laser Radar ; SLR)と近距離の高精度距離計測が可能な画像処理を統合して、前方追跡車両の計測位置を高精度に求める手法を提案している[9]. しかし、実際の運転においては、先行車はもちろん周囲の車や道路周辺の障害物など、車と環境の関係も含めて判断し、操作する必要がある. このような観点から、高速道路を対象として、白線検出用車載カメラと SLR による車両と道路構造物を区別する手法も提案されている[10]. この手法は、路面の白線情報をもとに検出を進めるため、高速道路のように白線が明瞭な場面には有効であるが、一般道路などでは車線がないことも多く適用できる

場面に限られる。一方、最近はより高度な運転支援システムを目指して、車両が停止・走行を繰り返す低速域での走行環境認識をも可能とするシステムは実現への期待が大きい[11]。特に、一般道路で周囲の車種の走行特性や障害物の違いを考慮した運転制御も期待されている。

本章では、先行車だけでなく周囲の車両や障害物を検出し、さらに、検出した車両については走行特性と運動特性に着目した3種の車種(大型車、普通車、二輪車)に判別することを目的として、一般道路でも適用できる車両・障害物検出、車種判別手法を提案する。以下本章では、高精度な距離と方向の計測が可能なSLRと、対象物や車両の画像特徴が得られる車載カメラの情報を統合する方法について述べるとともに、実際の走行データを用いた評価実験により提案手法の有効性を示す。

2.2 車載センサを用いた走行環境認識

本研究では、遠距離でも距離計測精度が高い SLR の情報に、対象物体の種類や位置特徴が得られる車載カメラの情報を統合することによって、車種の認識を可能にする手法を検討する。なお、本手法で車両の種類として、二輪車と四輪車を旋回特性の違いに着目し、また、一般乗用車と大型トラックをサイズと加速・制動特性の違い[17]に着目して、二輪車、普通車、大型車の3つの種類に分類する。

図 2.1 に本研究で使用する車載センサの関係を示す。カメラはルームミラー上部に設置し前方を観測する。SLR は車両前部のバンパー位置に設置し、路面と垂直のビームを水平方向に 1 次元走査し、自車から検出対象物までの距離とその反射強度を計測する。カメラおよび SLR の仕様は表 2.1 の通りである。カメラや SLR などの車載センサを用いて対象物を観測する際に、次のような検討課題がある。

- 1) 観測対象の見えの大きさが変化する。
- 2) 車種や障害物の大きさが多様である。
- 3) 背景が複雑で走行にともなって変化する。
- 4) 入力画像の撮影環境が変化する。

このような走行環境の変化やセンサの特性の問題に対して、走行環境認識システムには




図 2.1 車載センサの構成

Fig.2.1. A configuration of on-board sensors.

ロバストかつ高速な検出・認識性能が要求される。

本研究では、このような問題を踏まえてニューラルネットワーク (Neural Network; NN) をもとにする認識手法を提案する。ニューラルネットワークは雑音に対する頑健性と「学習」によってネットワークの性質を変化させることができる特徴を持つ[18]。本手法では、前処理として、遠距離でも距離計測精度が高いという SLR の特徴を利用してデータの正規化を行い、カメラ画像の見えの大きさ変化を補正する。しかし、単一のニューラルネットワークで対象の認識を行う場合、一定幅のデータを単純に切り出して判定に用いると、普通車や二輪車などの車幅の狭い車両は、観測データに対象と背景が混在するため誤認識が生じやすい。この問題を回避するために、対象物のサイズに応じてサイズが異なる受容野特性を持ったニューラルネットワーク（以下では識別器と呼ぶ）を並列に配置し、その結果を統合識別器を用いて評価することによって、複雑背景中で大きさの異なる対象物を高精度に識別する手法を提案する。

また、表 2.1 で示したとおり、SLR のスキャン範囲と車載カメラの視野範囲は異なる。SLR で車両の一部しか捕られていない場面では、車両に当たるデータを正しく取れないため、誤認識が発生する可能性が高い。このような SLR の検出範囲の境界付近で生じる誤認識を低減するために、画像情報に基づく車種判別により認識の安定化を図る。さらに、認識の安定性と高精度化を実現するために、車両の道路走行環境モデルを用いて、時系列的に観測した結果を統合評価する時系列認識評価手法について検討する。

表 2.1 センサの仕様

Table 2.1 Specifications of on-board sensors.

SLR	Scanning angle	12 degrees
	Beam width (V)	4 degrees
	Beam width (H)	0.15 degrees
	Scanning cycle	10 cycles/s
	Measurement range	10 to 120 m
Camera	Field angle(H)	28 degrees
	Field angle(V)	21 degrees
	Image size (H×V)	256×220 pixels

2.3 車種認識アルゴリズム

本提案手法は、データ正規化、多重構造ニューラルネットワーク及び画像識別、時系列車両認識評価の4つの部分に大別できる。次に、各部分について詳しく説明する。

2.3.1 データの正規化

SLR は、放射状に走査することから、同じ物体であっても観測される角度範囲が変化する。すなわち、遠方の物体は反射するレーザ光の角度が狭く、近距離では広がる。また、反射強度も距離によって変化する。カメラによって得られる画像データも、同様に透視投影となることから、同じ物体の画像でも大きさや形状が変化する。本手法では、センサと対象の距離が十分に離れているものとし、カメラモデルとして弱中心投影を仮定する。具体的には、透視投影にともなう対象の変形を距離に逆比例した相似変換とみなして、SLR で計測された距離に応じて正規化を行い、物体までの距離の影響を補正する。レーザレーダの情報は表1に示すように、スキャニング範囲 12 deg.の間を 0.15 deg.間隔で 80 方向の距離と反射強度が得られる。図 2.2(a)に、レーザレーダによる対象物の検出結果をカメラ座標に変換して示す。道路を平面と仮定すると、SLR で検出した対象の方向と計測距離から対象の3次元位置が計算できるので、この情報を利用して画像上の走査開始点を定める。一方、レーザレーダおよびカメラである車両を観察した場合、その検出角度は車幅と車両までの距離によって変化する。この関係を用いて、画像およびSLR のデータ列から物理的な長さ(車幅)が一定になるようにサイズの正規化を行う。これによって、観測距離によらず、大型車の車幅の場合には、車幅に相当する長さ 2.0 m の範囲を 20 点のデータで表現

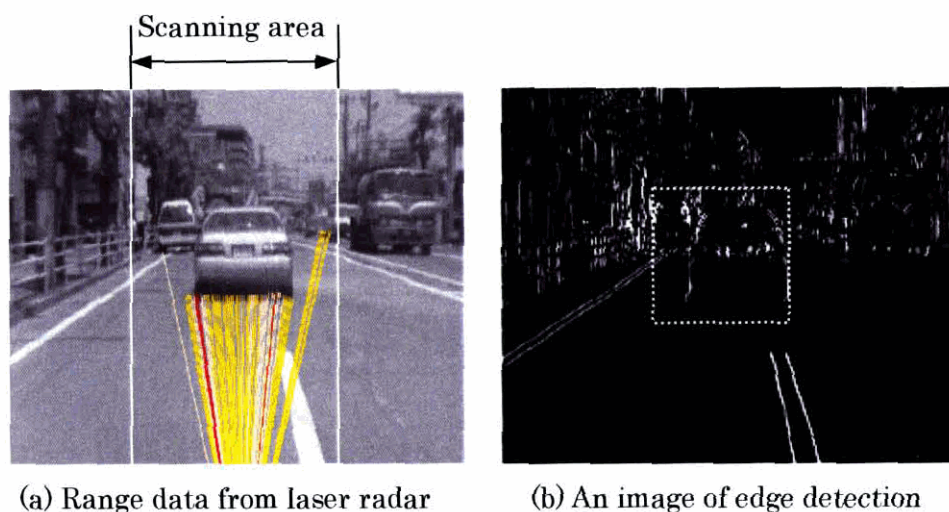


図 2.2 車載センサで取られるデータ

Fig.2.2. Data detected by on-board sensors.

するように変換する。図 2.2(b)の点線で囲まれている部分が画像上における車両の候補領域である。この領域内で原画像に対して水平方向の微分を行い、その結果を垂直方向に投影した平均エッジ分布を算出したのちにサイズの正規化を行う。この処理によって、各フレームにおいて、SLR の各観測位置(検知点)に対して、各車種の車幅に相当する SLR の距離データおよび強度データの組と、カメラ画像から得られた平均エッジ分布が正規化されて出力される。

2.3.2 多重構造ニューラルネットワーク

図 2.3 に、本手法で用いた多重構造ニューラルネットワーク (Multiple Structure Neural Network; MSNN) の構成を示す. MSNN は、4 つの識別器の組み合わせで構成されている. 正規化したデータに対して、二輪車、普通車、大型車のそれぞれの車幅に応じた受容野特性を持つ 3 種類の識別器を通して並列に評価し、これらの評価結果を統合識別器で比較評価することによって、障害物や車種を判別する. これにより、複雑背景の中で車幅の異なる車両に対する認識の安定性と高精度化が期待できる.

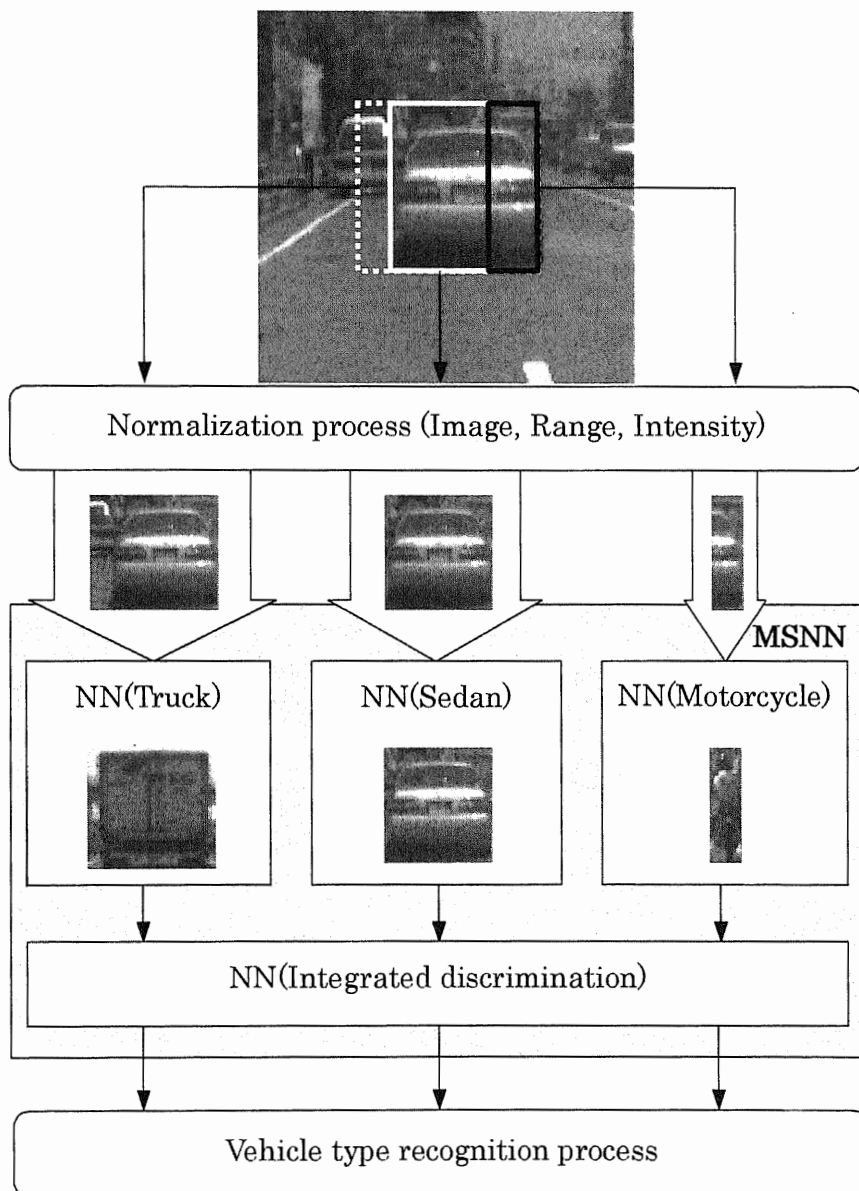


図 2.3 多重構造ニューラルネットワークによる認識

Fig.2.3. Frame recognition using multiplex structured neural network.

本手法で用いた各識別器はいずれも3階層型ニューラルネットワークである[19]. その構成を図2.4に示す. また, 学習手法は慣性項を含む誤差逆伝搬法を適用しており, 活性化関数としてはシグモイド関数を用いている.

各識別器で, 入力パターンの*i*番目のデータを I_i とし, *i*と*j*番目の中間層ユニットの間の結合荷重を V_{ji} , *j*番目の中間層ユニットと*k*番目の出力層ユニットの間の結合荷重を W_{kj} とした場合, *j*番目の中間層ユニットの出力 H_j , *k*番目の出力層ユニットの出力 O_k は次式のように表される.

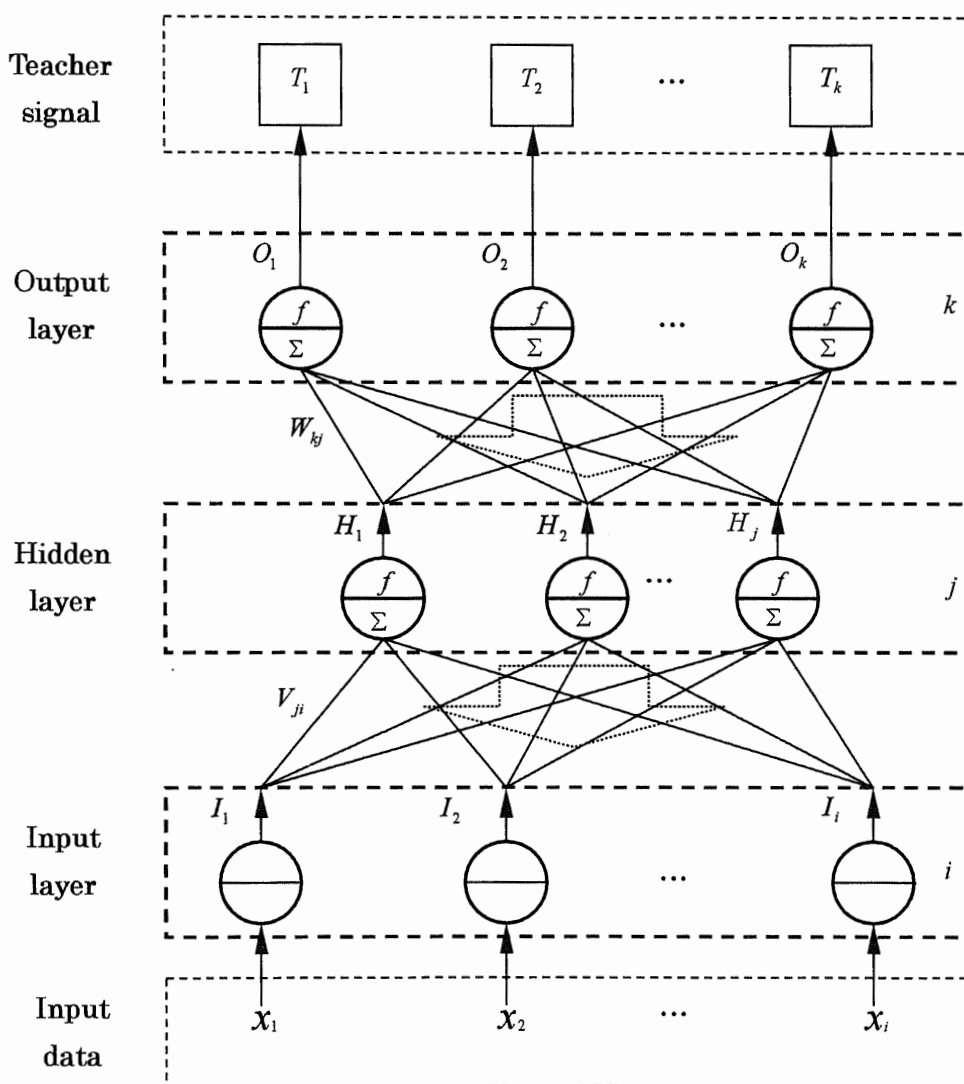


図2.4 3層の階層型ニューラルネットワーク
Fig.2.4. Three-layer feed forward neural network.

$$H_j = f\left(\sum_i V_{ji} I_i\right) \quad (2.1)$$

$$O_k = f\left(\sum_j W_{kj} H_j\right) \quad (2.2)$$

ここで,

$$f(x) = \frac{1}{1 + \exp(-\alpha x)}$$

はシグモイド関数である.

学習に際して, 教師信号を T_k とすると, あるパターン p に対する出力値と教師信号との平均二乗誤差関数を E_p , 全パターンの平均二乗誤差の総計を E_t とすると,

$$E_t = \sum_p E_p \quad (2.3)$$

ただし,

$$E_p = \sum_k (T_k - O_k)^2$$

である. 学習では, 与えられた学習データ系列に対して, 式(2.3)の誤差 E_t を最小とする加重係数 v_{ji} と w_{kj} の組を逐次計算により求める.

誤差逆伝搬法の学習アルゴリズムは以下のように要約することができる.

- 手順 1. すべての結合荷重の初期値をランダムに小さな値に設定する.
- 手順 2. 入力パターンと対応する教師信号を与える.
- 手順 3. 与えられた結合荷重と入力パターンにより, 入力層から出力層に向けて, 各ユニットの出力を計算する.
- 手順 4. 得られた出力と教師信号を用いて, 出力層から入力層に向けて, あるパターンに対する各層の結合荷重の更新量を計算して, 修正する.
- 手順 5. すべての学習パターンに対する二乗誤差が設定値以下になれば学習が収束したと判断して終了する. そうでなければ, すべての学習パターンに対して, 手順 1 から手順 4 まで操作を繰り返す.

なお, 本手法では大型車の車幅に対応する受容野の大きさを 2.0 m, 普通車の受容野の大きさを 1.7 m, 二輪車を 0.5 m と設定した. なお, 学習係数, シグモイド関数の傾き, 慣性項の係数, 中間層のユニット数および初期値については予備実験で決定した.

2.3.3 フレーム単位の車種判定

SLR のスキャン範囲内での各検知点に対する MSNN の出力値を用いて処理を進める。まず、すべての検知点($n=1,2,3, \dots, 80$)において、MSNN の各カテゴリ ($j=1,2,3$) の出力値 $Out_n^j(t)$ を最大にするカテゴリ i_n すなわち次式を満たす i_n を求める。

$$i_n = \arg \max_j \{Out_n^j(t)\} \quad (2.4)$$

次に、各検知点の最大値を比較して式(2.5)のようにさらに最大となる点 m を求める。

$$m = \arg \max_n \{Out_n^{i_n}(t)\} \quad (2.5)$$

ここから、最大となる点 m とその出力値を用いて対象物の種類を判定し、点 m を基準点とする。車両と判定された基準点から車種に相当する車幅の領域を検出する。最後に、検出した車両の領域を除いた領域から次に最大となる点を求めながら、処理を繰り返してスキャン範囲内の複数の対象物を検出し判定を行う。その処理の流れを図 2.5 に示す。

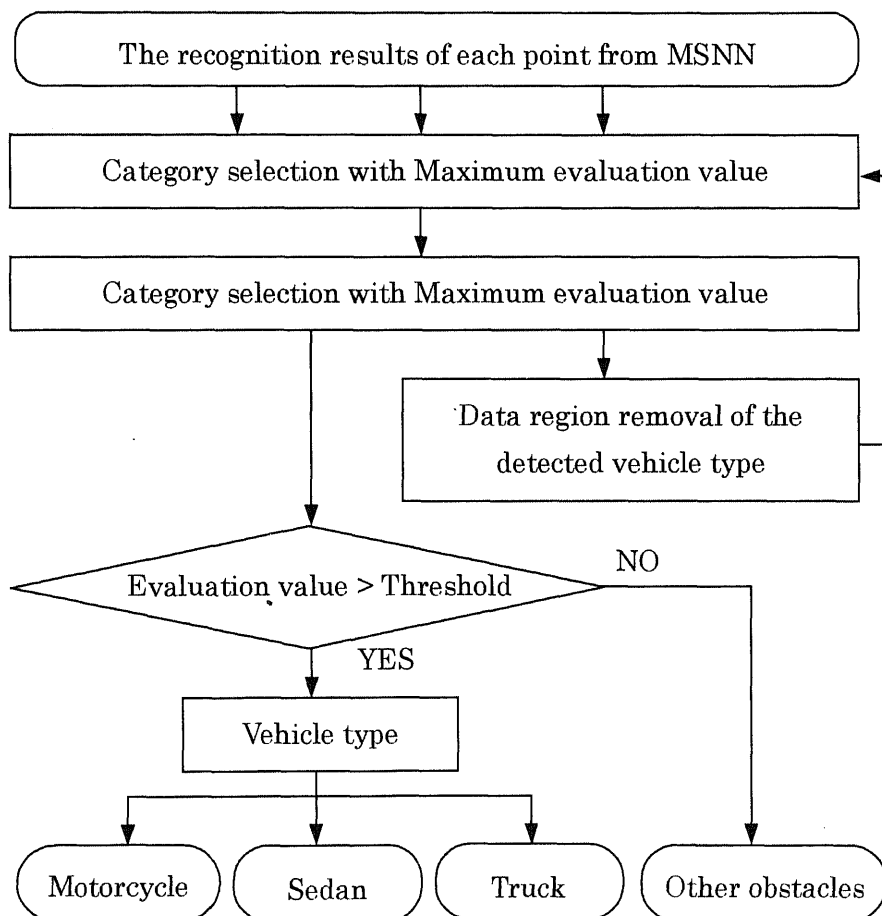


図 2.5 車両検出，車種判定のフローチャート
Fig.2.5. Flow chart of vehicle type recognition.

2.3.4 画像情報に基づく車種判別

図 2.2 に示したように車載カメラの観測範囲に比べて、SLR の検出範囲が狭い。SLR の検出境界の付近では車両全体のデータを観測できないために MSNN を用いた車種識別が難しい。そこで SLR の検出境界の付近にある対象に対しては、車載カメラからの情報のみに注目して画像のマッチングに基づく車両認識を行う。

図 2.6 に SLR 検出境界における画像処理の統合アルゴリズムを示す。

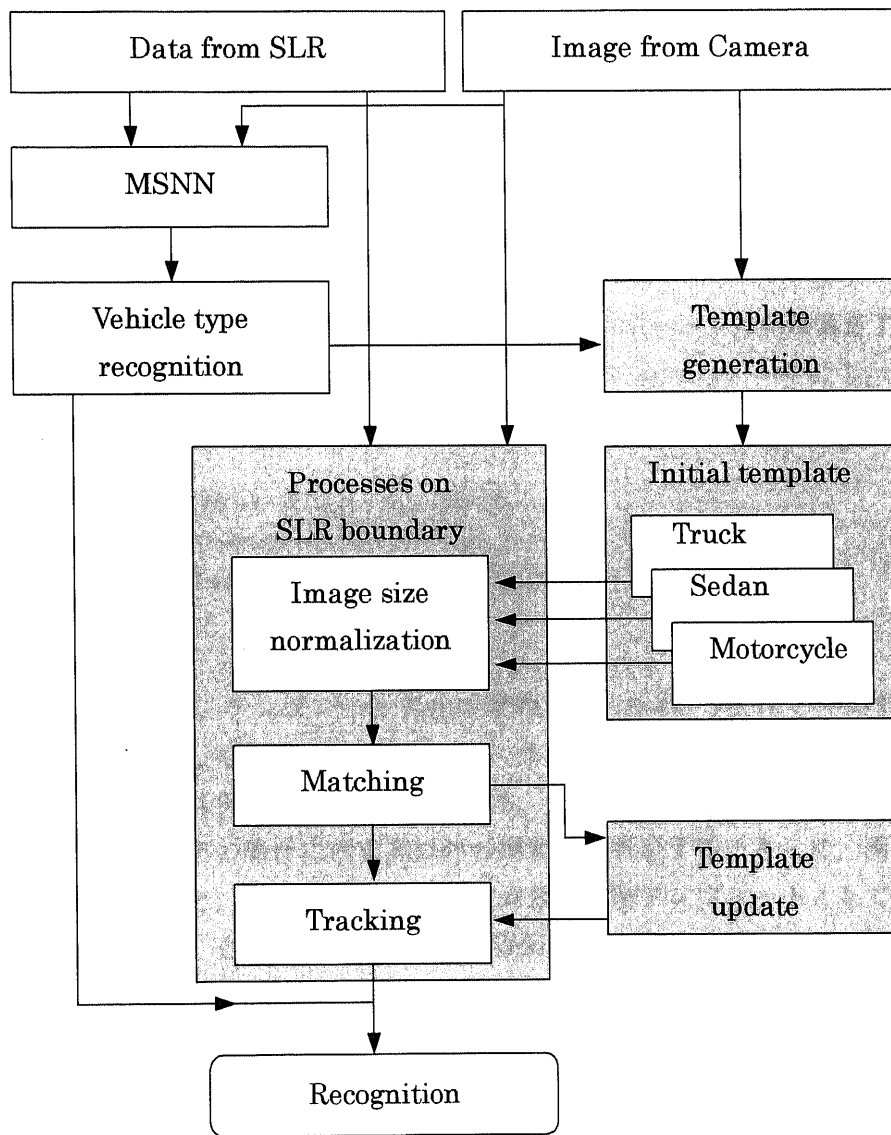


図 2.6 画像処理の統合アルゴリズム

Fig.2.6. Configuration of vision-based processes around the SLR sensing area boundary.

本手法では最初に、各車種毎の初期テンプレートを作成する。具体的には、MSNNによる車種判別結果をもとに、SLRで検出した距離と方向に対応する画像上での車両位置を算出し、車両の横幅と基準高に合う領域を切り出す。切り出した車両の画像領域に対してサイズの正規化と水平方向の微分を行い、垂直方向の平均エッジ分布を算出する。この結果をもとに車種カテゴリごとに、平均エッジ分布テンプレートを作成し初期テンプレートとする。

次に、このようにして生成された初期テンプレートを用いて、SLRの検出境界付近で検出された対象物のマッチングを行う。ここで、SLRで観察された物体の位置は透視投影されているので、SLRの検出距離を用いて、初期テンプレートを拡大・縮小する。拡大後のテンプレートをSLRの検出点の付近を走査して、入力画像の平均エッジ分布特徴とマッチングし一致度が最大となる点を求める。ここで、テンプレートの走査範囲は、SLRで検出された点が対象の端にあることを考慮して、拡大後のテンプレートの幅と高さの2倍としている。なお、マッチングの類似度評価には、画像濃度の線形変換に対して不偏な正規化相関法を用いている。

ここでは、入力画像の特徴値を $f(i, j)$ 、カテゴリ k のテンプレートの特徴値を $T_k(i)$ としたとき、類似度評価値 R_k を、

$$R_k = \max_{(i,j)} \left(\frac{\sum_{l=0}^N (f(l+i-N/2, j) - f_M(i, j))(T_k(l) - T_{Mk})}{\sqrt{\sum_{l=0}^N (f(l+i-N/2, j) - f_M(i, j))^2} \sqrt{\sum_{l=0}^{N-1} (T_k(l) - T_{Mk})^2}} \right) \quad (2.6)$$

とする。ただし、 T_{Mk} は、テンプレート $T_k(i)$ の平均、 $f_M(i, j)$ は、 $f(i, j)$ の平均である。各車種カテゴリ k に対してそれぞれのテンプレートを用いて、類似度評価値 R_k を算出し、その最大値を取るカテゴリをその車種と判定する。ただし、最大の類似度評価値 R_k があらかじめ設定した閾値以下の場合には車両以外の障害物と判定する。さらに、画像上における位置座標および距離と、その画像特徴を特定対象の個別テンプレートとして保存し、次のフレームに対しては、その位置を基準として個別テンプレートを用いて追跡を行う。

2.3.5 道路の走行環境モデルに基づいた時系列車両認識

最後に、フレーム単位の認識結果に対して、道路走行環境モデルを用いて時系列画像の総合判定を行う。具体的には、実空間を運動する車両や障害物の動きは連続である。そこで、横方向および進行方向の相対速度はある範囲に限定でき、その位置や形状が急激に変化しないものと仮定する。ここでは、連続画像を一定時間に観測して、MSNN で得られたフレーム単位の認識結果をもとに、線形予測を用いて、対象物の種類と位置を再評価する。再評価に用いる予測式を次に示す。

$$P_{num}^j(t) = a_0 Out_{num}^j(t) + \sum_{k=1}^L a_k \cdot P_{num}^j(t-k) \quad (2.7)$$

ここで $Out_{num}^j(t)$ は時刻 t での MSNN で仮認識した num 番目の車両に対する各カテゴリ ($j=1, 2, 3$) の出力値である。 $P_{num}^j(t)$ は時刻 t の各カテゴリの再評価の予測値を表している。また、 a_0 と a_k は重み値であり、 $a_0 + a_k + \dots + a_L = 1$ とする。

一つの対象物に対する各カテゴリの予測値 $P_{num}^j(t)$ のなかから、さらに最大となるカテゴリを式(2.8)のように求め、そのカテゴリを用いて車種を再判定する。また、対象物の検出位置は 2.3.3 節の説明のとおり求めた点を基にして、決定する。この処理を SLR に検出された各対象物に対して繰り返し再評価する。

$$i_{num} = \arg \max_j \{P_{num}^j(t)\} \quad (2.8)$$

さらに、決定した結果が、一定時間に安定した場合、次のフレームから道路平面での水平距離 (Z 軸) と道路での横位置 (X 軸) が近い車両候補を追跡することで、車両認識の安定化を図る。ただし、レーザレーダのスキャン範囲以外に出る場合および SLR で検出できなかった場合は、追跡を中断し、新たに認識処理を行う。

2.4 実験と考察

2.4.1 実験条件

実験では、高速道路、一般道路、トンネルおよび料金所の4種類、計5時間分の走行環境のデータを利用して評価を行った。実験条件は表2.2の通りであり、これらのすべてのフレームに対して実験を行い、あらかじめ5秒ごとのフレームに対して目視判定により作成した正解データと処理結果の比較を行った。各走行環境の一例を図2.7に示す。

入力画像は30 [frame/s]で256×220 [pixel]の濃淡画像として取得しているが、処理はSLRのスキャン周期100 msに合わせて10 [frame/s]で行った。SLRの反射距離と反射強度のデータは計測保証距離が10 m～120 mとなっていることから、この範囲外のデータについては、処理対象から除外している。

表 2.2 走行環境の条件

Table 2.2 The conditions of road environment.

条件	状態			
	高速道路	一般道路	トンネル	料金所
天候	晴れ	晴れ	晴れ	晴れ
時間	昼	昼	昼	昼
道路環境	カーブ 平坦	カーブ 坂道	平坦	平坦
障害物	あり	あり	なし	あり
輝度変化	なし	なし	あり	あり
車種	普通車 大型車	普通車 二輪車	普通車	普通車
フレーム数(千枚)	216	216	81	27




(a) General road 1



(b) General road 2



(c) Express way 1



(d) Express way 2



(e) Tunnel



(f) Toll gate

図 2.7 各走行環境の例

Fig.2.7. Examples for various environments.


2.4.2 多重構造ニューラルネットワークの構築

はじめに、高速道路と一般道路の走行環境からランダムに収集した車種毎の 100 パターンとその他の 100 パターン計 400 パターンのデータセットを用いて誤差逆伝搬法に基づく学習を行い、MSNN 構築の予備実験を行った。まず、各車種識別用の識別器を最良になるようにそれぞれ構築し、次にその最良な構造を用いて統合識別器を構築した。そのときの評価は同数の認識用データを用いた。なお、今回の実験で学習係数は 0.1、シグモイド関数の傾きは 0.667、慣性項の係数は 0.1、中間層のユニット数はそれぞれ 30 (大型車用)、20 (普通車用)、10 (二輪車用)、10 (統合用) とし、初期値は 0.1~0.1 としている。図 6 に各識別器を通した認識用データの出力値をそれぞれ示している。図 2.8(a)、図 2.8(b) から大型車と普通車の識別器では高い確率で認識されている様子がわかる。また図 2.8(c) 二輪車識別器の結果では、一部がその他の障害物に近い値をとっているが、大型車及び普通車とは分離できていることが確認できる。このことから、異なる受容野特性を持つ識別器を用いることで、個々の識別器の長所を生かすことができたと考えられる。また、表 2.3 で各識別器からの出力値を統合識別器の入力層の入力として認識した結果と単一最良の識別器を用いた認識結果を示す。ただし、ここで車両判定の閾値を 0.5 とした。この表から本提案手法の MSNN を用いることで単一の識別器より高い認識率を得られたことが確認できる。


表 2.3 NN と MSNN の認識結果の比較

Table 2.3 Comparison between the results of NN and MSNN.


Vehicle type	Rate of NN recognition (%)	Rate of MSNN recognition (%)
Truck	81.0	96.0
Sedan	80.0	90.0
Motorcycle	79.0	89.0
Other obstacles	73.0	81.0
Average	78.3	89.0



(a) NN (Truck)



(b) NN (Sedan)



(c) NN (Motorcycle)

図 2.8 各車種識別器の出力結果

Fig.2.8. Output results of each neural network unit.

2.4.3 車載センサの情報統合の評価

車載の SLR とカメラの統合手法の有効性を確認するために評価実験を行った。ここでは、認識用データからランダムに抽出した車種毎の 100 パターンとその他の 100 パターン計 400 パターンのデータを用いて評価した。表 2.4 にその結果を比較して示す。表 2.4 の中で、LR、V および LR+V は評価に用いた入力情報の違いを意味する。LR は SLR からの距離情報と強度情報を入力として、V はカメラからの画像データのみを入力としている。また、LR+V は二つセンサからの情報を統合して評価に用いている。表 2.4 の結果から、二つのセンサ情報を統合する手法が一つのセンサ情報を用いたいずれの手法よりも有効であることが確認できた。

表 2.4 各センサの認識結果の比較
Table 2.4 Comparison of recognition ratio.

Vehicle type	LR (%)	V (%)	LR+V (%)
Truck	75.0	65.0	96.0
Sedan	80.0	75.0	90.0
Motorcycle	89.0	88.0	91.0
Others obstacles	70.0	39.0	84.0
Average	79.0	67.0	90.0

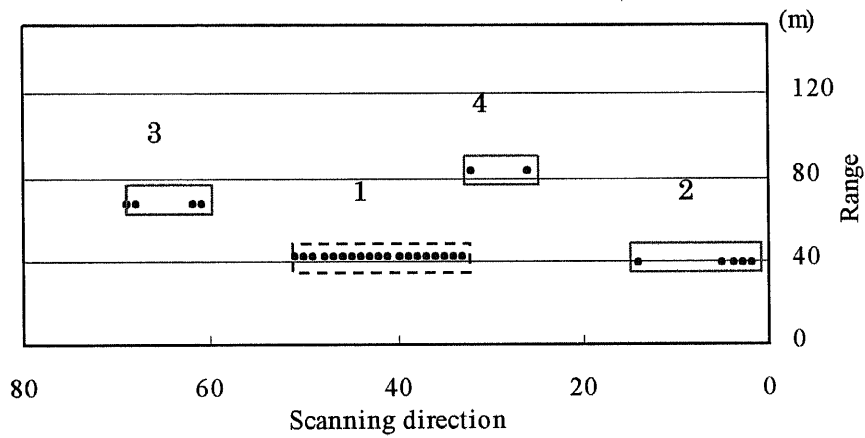
2.4.4 認識結果と考察

最初に、高速道路でのデータを用いて MSNN によるフレーム単位の認識結果について説明する。図 2.9(a)に入力された連続フレーム画像の一例であり、図中の縦線は SLR の走査範囲を示す。図中の各車線の車両に対する SLR で取られた検知点の距離データと強度データを図 2.9(c)に示す。この各検知点に対する MSNN の出力値は図 2.9(d)のとおりである。この MSNN の各カテゴリの出力値を二輪、普通、大型車らしさの判定基準として 2.3.3 節で述べた判定手法を用いて処理した結果を図 2.9(b)で示し、図中の番号で認識された各車両を表している。同図から、本手法により、異なる距離や位置にある複数の車両も同時に検出し、車種判定できたことがわかる。

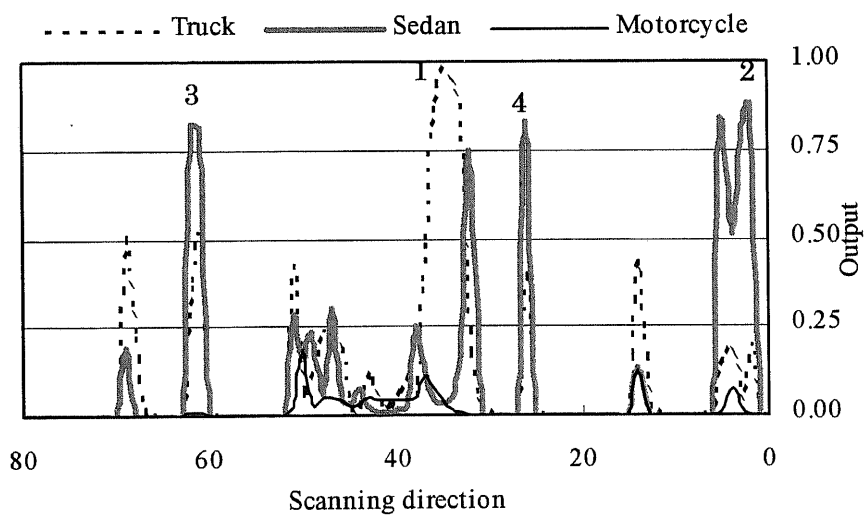


(a) Forward image

(b) The results of recognition



(c) Range data from SLR



(d) The output of MSNN for each category

図 2.9 MSNN による車種認識の例

Fig.2.9. An example of Frame recognition using MSNN.

次に、一般道路を走行時の認識について考察する。図 2.10 に認識結果の推移を示す。同図において、縦軸は時間、横軸は左右の方向を示しており、各線の色の違いが各フレームにおける認識結果を表している。この推移図での一例の画像を図 2.11(a)で示している。また、図 2.10(a)は目視で判定した正解データ、図 2.10(b)はフレーム単位の認識結果、図 2.10(c)は時系列観測モデルに基づく最終判定結果を示している。実験により、フレーム単位の認識では、時間の推移にともなって誤認識が時間的に散発的に生じ、また、同一車両の認識結果が揺らいでいることが分かる。これに対して、時系列的に観測した結果では、安定かつ正確な追跡が行われていることが確認できた。線形予測に基づく時系列認識は、フレーム認識で同一の認識誤りが継続して生じるような場合には、間違った認識結果を導く可能性がある。一方、本手法の場合、フレーム単位の認識結果は時間的に散発的かつランダムなカテゴリ(車種)に分散する傾向があり、線形予測を用いた時系列認識が有効に働いているものと考えられる。

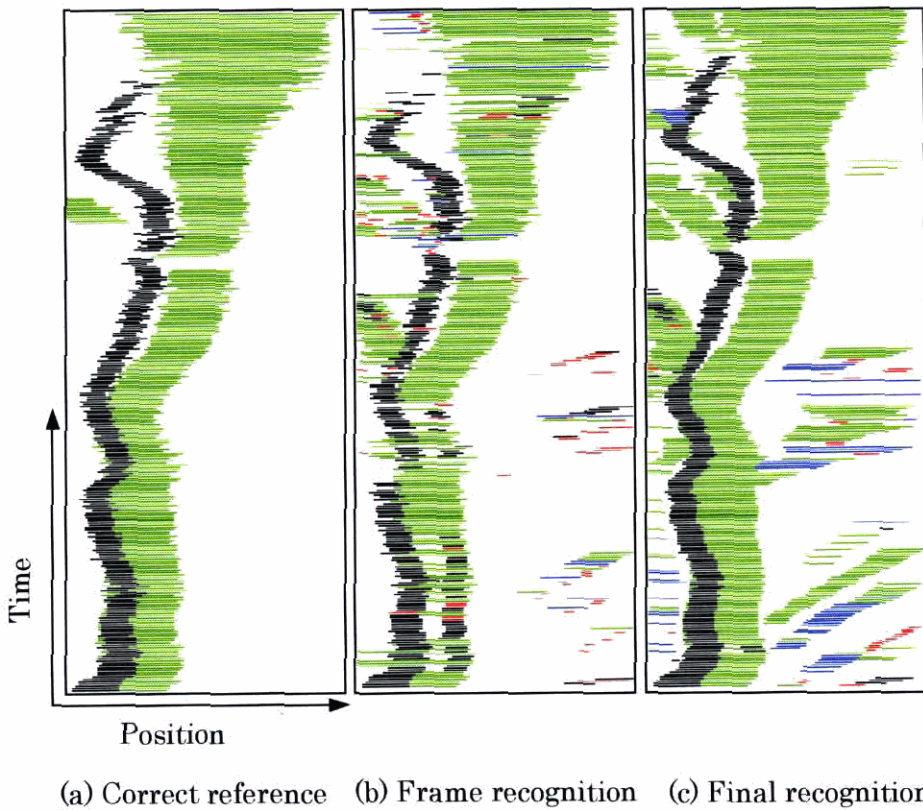


図 2.10 一般道路を走行時の認識結果の推移図

Fig.2.10. Recognition results using data sequence in a general road.

図 2.11 はそれぞれの走行環境における実験の最終結果の一例であり、四角で囲われた部分が車両の検出結果、その線の違いが車種を表している。この結果により、形や色が異なる車両や画像上での見え方が変化する場面でも正しい認識が行われていることが確認できる。また、観測環境が激しく変化する場面や SLR の検出境界でも車載センサの情報統合により認識が可能になっていることを確認した。また、図 2.12 に車以外の障害物の検出結果の一例を示す。同図において、黒の点線で囲まれた部分が検出結果である。ここでは、路側に設置されたポール、自転車に乗った人物、歩行中の人物などが検出できている。人物については、比較的近距离で SLR が届く場合は検出が可能であるが、遠距離では検出できない場合が生じる。

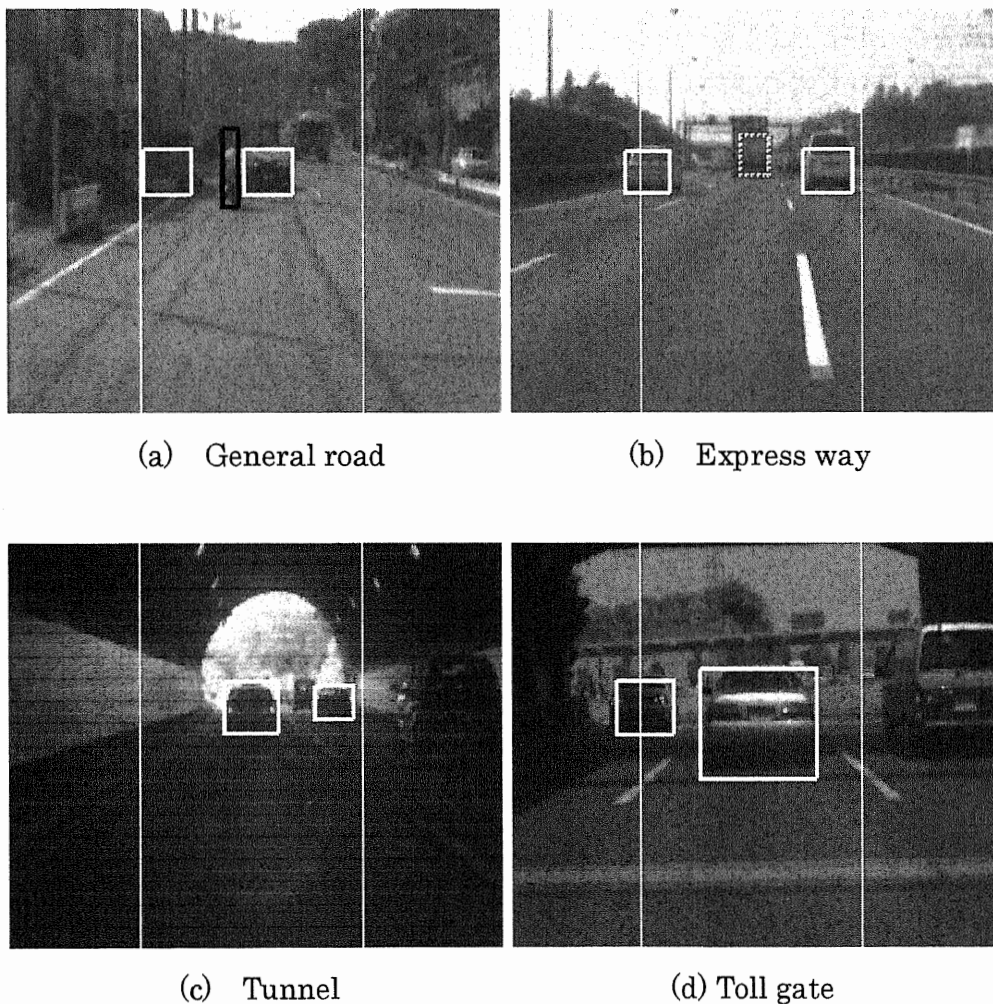


図 2.11 各走行環境での認識結果例

Fig.2.11. An example of recognition results for various environments.

提案手法の有効性を確認するために、各走行環境における連続走行データに対して、フレーム単位の MSNN の認識と時系列処理の認識を行った。表 2.5 に、その認識結果を 5 秒間隔でサンプルし、正解データと比較したときの認識率を示す。表 2.5 の結果より、フレーム単位の認識では、認識率が平均 89.5% であるのに対して、時系列観測を行うことにより、96.1% に改善できていることが分かった。また、時系列処理後の認識では、一般道路は高速道路と比較して多少低下するが、その差は 1% 以下となっており、本手法が一般道路でも適用可能であることが分かった。

一方、フレーム単位の認識では、一般道路は高速道路の結果と比較して低い値となっている。図 2.13(a) に誤認識されたフレームの一例を示す。この例では、前方の車両の一部が直前の二輪車に隠蔽されたことにより、フレーム単位の認識では二輪車 2 台に誤認されている。これに対して、図 2.13(b) の時系列認識の結果は、正しく認識されている。また、表 2.5 の結果より、トンネル内部では他の条件に比べて認識率が低下している。この原因として、トンネル内では、学習用画像データと比べて照明環境の変化が大きいことが考えられる。図 2.13(c) は、トンネル内で誤認があるフレームの一例であるが、壁に設置された反射マーカを二輪車と判定している。この問題については、トンネル内のデータを用いた学習を行い、処理を切り替えることにより改善するなどの方策が考えられるが、具体的な検討は今後の課題とする。

本手法は SLR の距離情報に車載カメラの情報を統合するために、SLR の計測が不安定な条件では認識が困難となる。雨、雪、夜間など、多様な条件下での評価が必要である。

表 2.5 各走行環境での認識率

Table 2.5 Percent accuracy of recognition for various environments.

Roads of environment	Rate of frame recognition (%)	Rate of final recognition (%)
General road	85.4	96.5
Expressway	93.5	97.4
Tunnel	89.5	91.5
Toll gate	90.4	96.3
Average	89.5	96.1

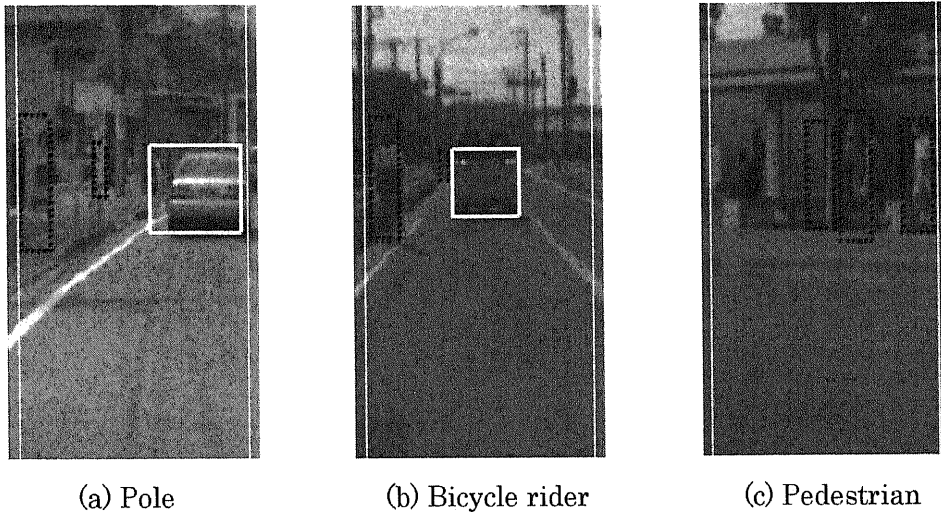


図 2.12 車以外の障害物の検出例
 Fig.2.12. Examples of detection of other obstacles.

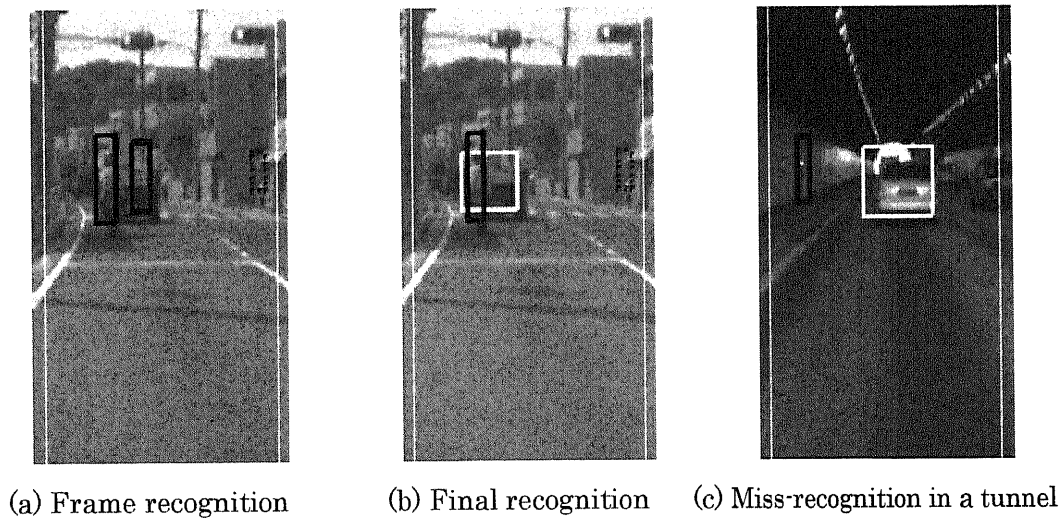


図 2.13 誤認識の考察
 Fig.2.13. Discussion for miss-recognition.

2.5 まとめ

本章では、ドライバーの安全運転を支援するために、車載のレーザレーダと画像情報を統合して道路環境から複数の障害物や車両を検出するとともに、検出した車両の車種(二輪車, 普通車, 大型車)を判別する手法について検討した。多様な走行環境化で対象物や障害物を検出する場合、複数の車載センサ情報を統合することが有効とされ、種々の手法が検討されてきた。

しかし、センサ情報統合手法にニューラルネットワークを用いる方法は、判定論理を開発者が作らなくても済み、また、学習機能により環境に適応的な手法を構成できる可能性があり有望であるが、検出対象のサイズが多様な場合に、対象と背景が混在し誤認識が生じやすい問題があった。この問題を回避するために、対象物のサイズに応じて、サイズが異なる受容野特性を持ったニューラルネットワークを並列に配置し、その結果を統合識別器で評価することによって、複雑背景中で大きさの異なる対象物を高精度に識別する手法を提案した。また、フレーム単位の認識結果を道路の走行環境モデルを利用して、高精度かつ安定に認識する時系列観測手法を検討した。

さらに、高速道路、一般道路、トンネル及び料金所の4種類の走行環境で収集された計5時間分の54万フレームの実データを用いて評価実験を行った。実験では最初に、ランダムに収集した認識用データを用いて提案手法と単一の識別器との比較実験を行い、MSNNを用いた提案手法が単一の識別器に比べて認識率が10%以上向上できることを確認した。また、二つのセンサ情報を統合する手法が一つのセンサ情報を用いたいずれの手法よりも高い認識率を得ることが確認でき、車載センサ情報統合の有効性を示した。時系列処理の導入により、平均認識率が96.1%で、一般道路でも認識率が96.5%に大きく改善することが分かり、本提案手法の有効性を確認した。

なお、連続的に出現する道路構造物に対する認識率の向上、さらに、トンネルなどの照明変化や多様な天候に対する対応は今後の課題である。

第3章

車両モデル認識のための車両フロント領域の自動検出

3.1 はじめに

前章では、車載センサを用いて前方の障害物を検出し、検出された車両を3種類の車種(大型車、普通車、二輪車)に判別する手法について述べた。高精度な距離、方向計測が可能なスキャニングレーザレーダと、対象物や車両の画像特徴が得られる車載カメラの情報を統合することによって、高精度な車両種別の判別が可能になったが、個別の車両モデルの認識には到っていない。第3章および第4章では、固定カメラで撮影された道路画像をもとに、個別の車両モデルを識別する画像処理手法について論ずる。本章では車両モデル認識のための車両検出手法について述べる。

車両検出はITSや監視システムのサービスにおいて必要不可欠な重要な技術である。交通流計測のための車両検出には、超音波式車両感知器が広く利用されてきた。その検出安定精度から、高速道路や自動車専用道路での実用化が進んでいる。一方、車両感知器は、計測範囲が局所的であって、車種の判別は困難であるという問題がある。これに対して、画像センサは広範囲をセンシングすることができ、画像認識と組み合わせることによって多くの情報を得ることができる。しかし、画像センサは環境変動による影響を受けやすく、背景の変化と環境から映り込みなどの要素を考慮しなければならない。

従来の画像処理による代表的な車両検出技術としては、道路画像から背景差分や空間微分などの処理により、画像中に存在する移動車両を抽出する方法や、3次元モデルや2次元モデルを利用して画像中の車両を検出し追跡する方法などである[21]-[24]。しかし、これらの研究の主な目的は交通流計測や車両種別を判別するための検出技術の開発であって、車両モデル認識のための車両検出を試みた事例は見当たらない。

変化する環境から移動物体を検知し、車両を特定するためには、車両特徴の検出精度とロバスト性が求められている。そこで、本章では、車両モデル認識の第一段階として車両

情報を取得するための車両フロント領域の検出手法について検討を行う。

3.2 車両検出アルゴリズム

本研究では、図3.1 に示すように、道路の走行レーンの上部に配置した1台の固定カメラで通過車両を観測し、その画像をもとに車両モデルを認識する手法について検討する。このうち、車両検出アルゴリズムでは、車両進入検知、車両フロント領域の検出、フロント領域の正規化を行う。処理の手順を図3.2に示す。




図 3.1 撮影環境

Fig. 3.1. Environment for locating camera.

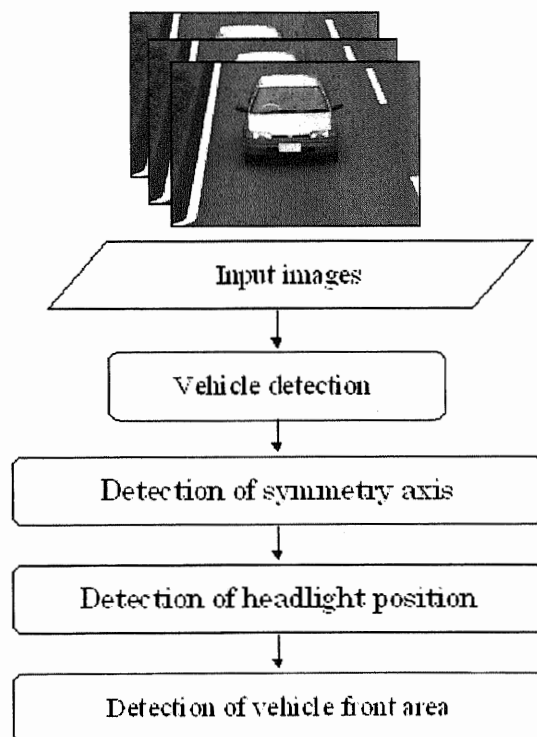


図 3.2 検出処理の手順

Fig. 3.2. Procedure of vehicle detection.

3.2.1 車両進入検知

車両進入検知処理では、最初に水平走査線ごとに、原画像 $f(i,j)$ に対して、車幅の半分の概寸 N に相当する部分画像を左右に反転させた自己対称テンプレートを用いて、各画素において近傍領域の対称性を示す対称判定画像 $R_x(i,j)$ を式(3.1)に基づいて算出する。

$$R_x(i,j) = \sum_{l=1}^N |f(i-l,j) - f(i+l,j)| / N \quad (3.1)$$

図3.3(a)に原画像、図3.3(c)に対称判定画像の一例を示す。同様に図3.3(b)と図3.3(d)には背景画像の原画像と対称判定画像を示している。対称判定画像は、道路領域のような濃度がほぼ均一な領域では、 $R_x(i,j)$ が低い値を取り、また、車両と道路の間のように左右で異なる濃度パターンが表れる部分では高い値となる。ここでは、 $R_x(i,j)$ を水平方向に累積した平均投影分布を判定することによって、車両の有無を検知するとともに、車両の先端位置 V_x を判定する。

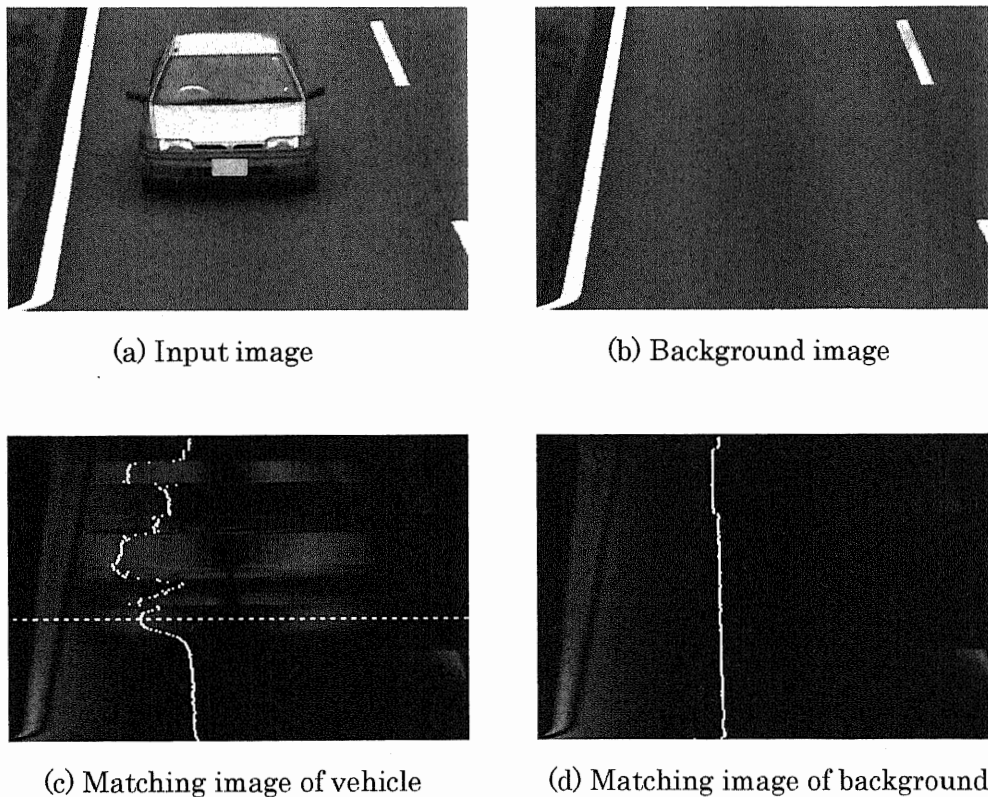


図 3.3 車両進入検知処理

Fig. 3.3. The processes of detection for vehicle.

3.2.2 車両フロント領域の検出

車両が検知された場合、その対称判定画像に対して次式で示すように、垂直方向の平均投影分布を求め、その局所的な極小値を検出し、車両領域の対称軸 S_Y を判定する(図3.4a).

$$S_Y = \arg \min_i \left(\sum_{j=1}^h R_x(i, j) / h \right) \quad (3.2)$$

$i: N \rightarrow w-N$

w, h : 入力画像の幅と高さ


次に、検出した対称軸を用いて、前照灯領域を検出する。ここでは最初に、原画像に対して、ソーベルオペレータによりエッジ強度 $e(i, j)$ (図3.4b)を検出したのちに、あらかじめ作成した左右1組の前照灯マスクを対称軸から左右等距離で幅を変えながら車両の先端位置の上方向に向けて走査し、前照灯領域を検出する。検出された前照灯領域の位置を図3.4(c)に示す。




(a) Detected symmetry axis



(b) Edge detection



(c) Detected headlight position



(d) Detected front area of vehicle

図 3.4 車両フロント領域の検出

Fig. 3.4. Detection of vehicle front area.

$$H_x = \arg \max_{(i,j)} \left(\sum_{l=1}^{T_w} \sum_{k=1}^{T_h} (e(i-l, j+k) + e(2S_y - i + l, j+k)) \right) \quad (3.3)$$

ただし, $i: S_y - N \rightarrow S_y$, $j: V_x \rightarrow h - T_h$

T_w, T_h : 左右前照灯マスクの平均幅と高さ

検出された前照灯の水平位置 H_x と対称軸の交点をフロント中心とする。フロント領域の検出結果を図3.4(d)に示す。

3.2.3 車両フロント領域の正規化

車両は道路上方から斜め下方に向けて設置したカメラで観察するために、車両の走行にともなって画像上の見えのサイズが変化する。本手法では、レーンを区分する白線から消失点を検出することによって、道路とカメラの光軸の関係を求め、空間上の長さが一定になるようにフロント領域のサイズを決定し、検出された領域を画像サイズが120×40 pixel となるように正規化する。

3.3 実験

3.3.1 実験条件

実験には、国道1号線岡沢町～浦島丘間で、歩道橋がある8個所でデータを収集した。撮影地点A～Hの道路における位置を図3.5に示し、それぞれの撮影環境の一例を図3.6に示している。この区間では交差点が23個所あって車両の入れ替わりが多い。撮影の日時、天候などの条件は次のとおりである。

- (1) 撮影期間：2004年7月～2006年3月
- (2) 天候：晴れ/曇り/小雨
- (3) 撮影時間帯：10:00～18:00
- (4) 撮影時間：延べ約10時間

ただし、入力画像はいずれも720×480画素、256階調であり、30 frame/sのフレームレートで収集した。

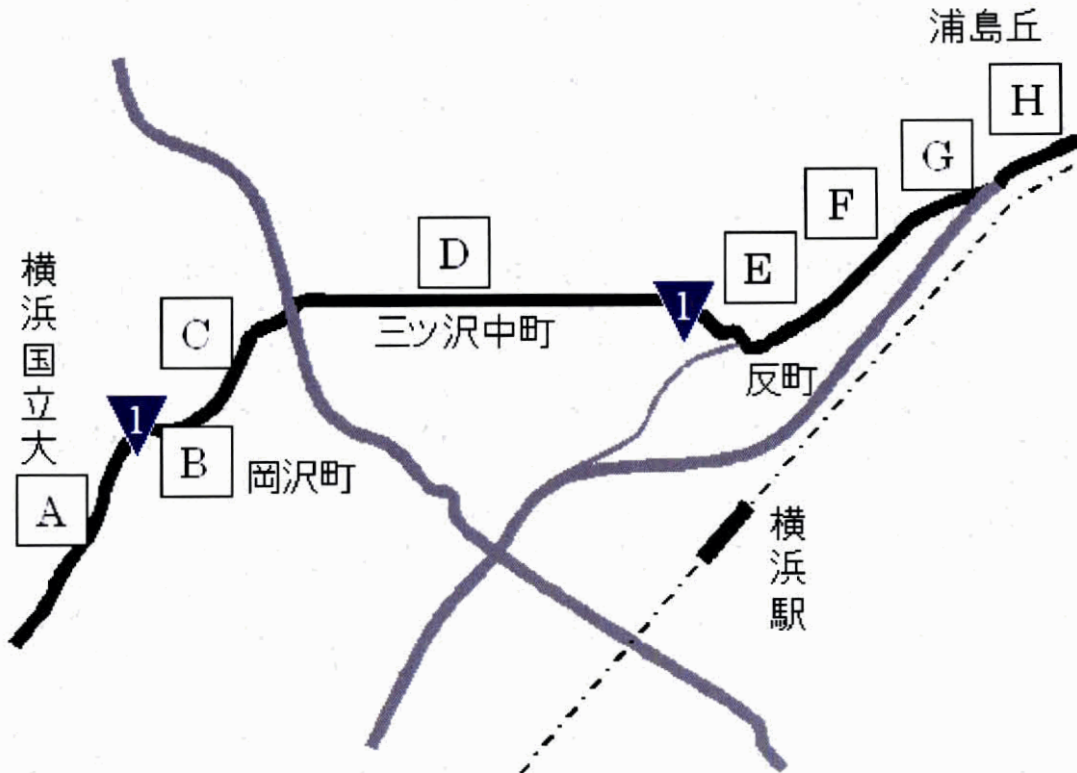



図 3.5 撮影地点
Fig. 3.5. Location.




(a) Position A



(b) Position B




(c) Position C




(d) Position D



(e) Position E



(f) Position F



(g) Position G



(h) Position H

図 3.6 各撮影環境の例

Fig. 3.6. Examples for various environments.

3.3.2 検出結果

提案手法の検出アルゴリズムを各撮影環境から収集した延べ10時間の約100万フレームの時系列道路画像に適用して実験を行った。各撮影環境における検出結果の一例を図3.7に示す。車両検知については、車体が長い大型車や、隣接レーンを走行する車両がある場合に、過剰に検出されるケースがあったが、通過車両はほぼ完全に検知できた(図3.7で横方向の点線)。車両領域対称軸の検出はどの撮影環境においても良好に検出できることが確認できた(図3.7で縦方向の点線)。

また、時系列道路画像における車両フロント領域の検出精度を評価するために、撮影地点B、E、Fで収集された延べ8時間のデータの中、車両が検知された約20万フレームの時系列道路画像を用いて実験を行った。検出結果はすべて目視で判定して、自動検出された車両フロント領域に車両の左右ヘッドライトが含まれている場合を正答とした。ただし、車幅が大きい大型車に対しては、車両のフロントグリルが検出領域の中に入ると正答としている。各撮影地点における車両フロント領域の検出率を表3.1にまとめて示す。また、撮影地点Eでの時系列画像における検出結果の一例を図3.8に示す。検出結果画像の中に水色の点線で囲まれている部分が検出された車両フロント領域である。この検出結果から、通過車両の走行に伴う画像上の見えのサイズ変化に対応しながら、車両フロント領域が正しく検出できていることが分かる。この評価実験では、3箇所の撮影地点における車両フロント領域の平均検出率98%以上を得ることができ、自動認識で必要な車両フロント領域の特徴を精度よく安定に取れることが確認できた。

表 3.1 車両フロント検出の結果

Table 3.1 Results of vehicle front detection.

Position	Number of vehicle	Rate of vehicle front detection
B	465	98.7%
E	1015	98.0%
G	415	98.8%

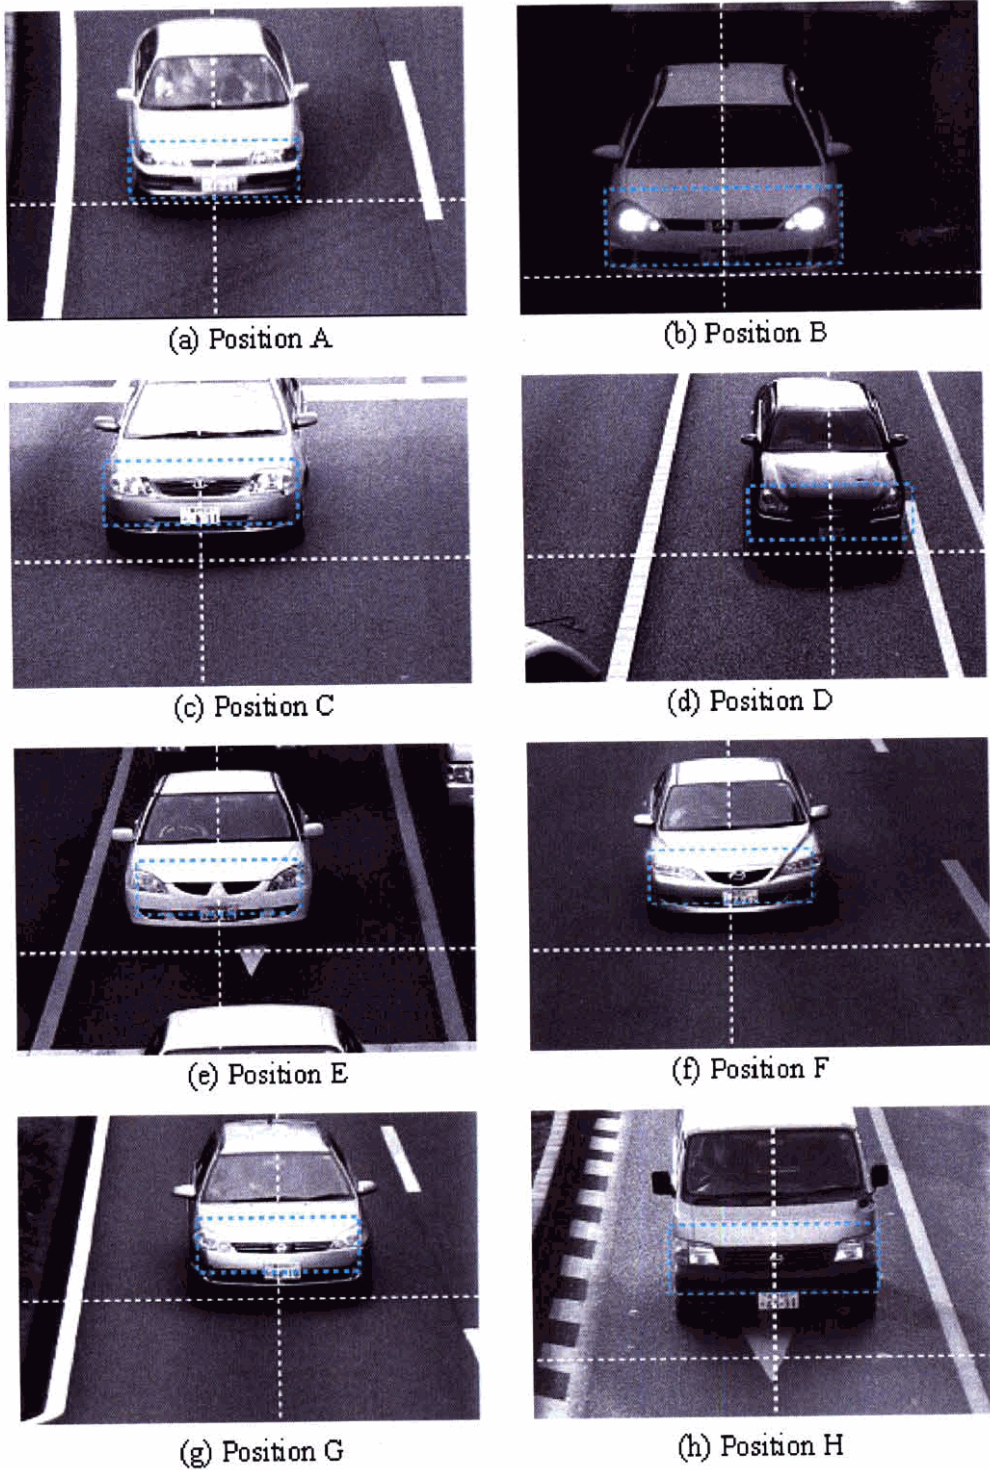


図 3.7 各撮影環境での検出例
 Fig. 3.7. Detected examples at various conditions.

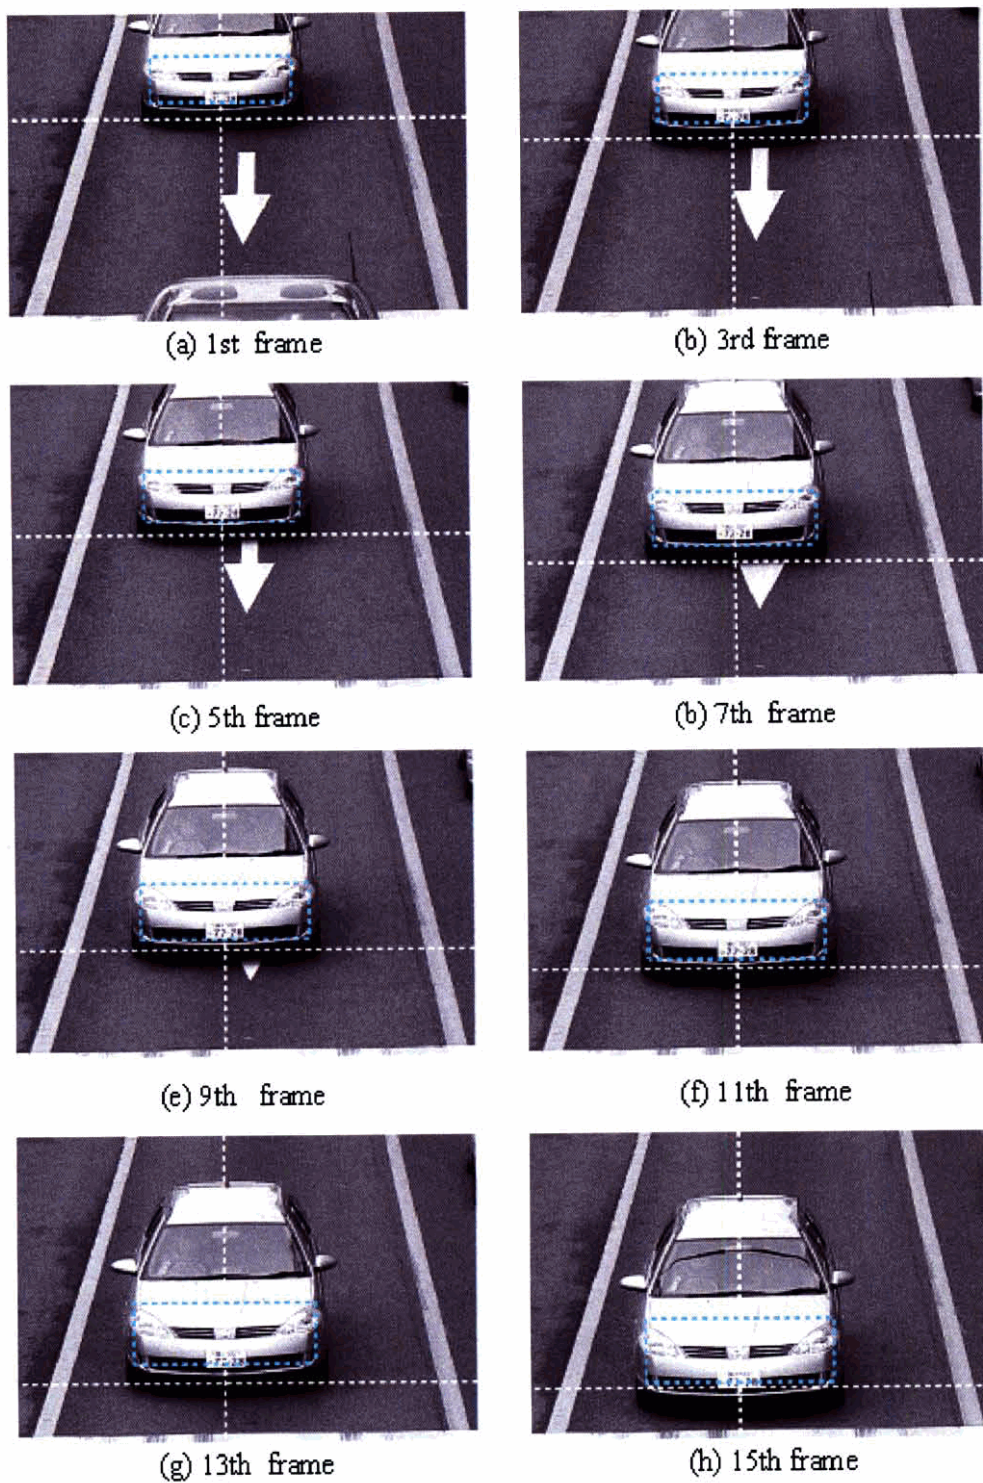


図 3.8 時系列画像におけるフロント領域の検出結果
 Fig.3.8. Detection results for time-sequence road images.

3.4 考察

本研究では走行レーンを走る二輪車以外のすべての車両を対象としている。なお、本章では車両形状特徴による車両モデル認識の前処理として、車両フロント領域の検出であることから、通過車両の重なりで車両のフロント部分が隠蔽されたケースは検出対象外としている。

車両検知に関しては、車体が長い大型車の一部分を車両のフロント領域として検出するケースがあった。図 3.9 に大型車の車体部分を車両フロントとして過剰に検出された例を示す。この問題については、過剰に検出した大型車の車体領域を認識段階で判定することにより、改善できる可能性があると考え。本手法は、車両の検出で対称性を求める車幅は普通車を基準としていることから、大型車に対しては車両の対称軸の検出に失敗するケースが見られた。この問題に対しては、車幅を自動的に認識して対称のテンプレートを計算することで、対応が可能になると考える。

図 3.7 で示した撮影地点 A, D のような道路画像では、車両フロントの領域は正しく検出できているが、画像上の見え方の変形が大きいことから、車両モデル認識に必要な車両特徴としては適切でないことが分かった。このことから、カメラの設置に関しては、設置したカメラの光軸と道路平面がなす角度を小さくする方が車両モデル認識のための特徴検出には望ましいと考える。

車両検出精度の評価実験には、主に天候が晴天と曇天に収集した道路画像を用いているが、雨天のデータは処理対象としなかった。ただし、図 3.7(b) に示すような場面では夕暮れに小雨が降っており、路面がヘッドライトの光を反射しやすい状況であるため、車両の過剰検知があったが、車両が通過する時には、フロント領域の検出に成功できた。このことから、照明を併用する方法が考えられるが、具体的な検討は今後の課題としたい。




図 3.9 車両を過剰に検出した例
Fig. 3.9. Examples of false positive.

3.5 まとめ

本章では，第4章で述べる車両モデル認識の前処理として，固定カメラで観測した道路画像から通過車両の車両フロント領域の自動検出手法について検討した．本車両検出アルゴリズムでは，環境変化にロバストな自己対称テンプレートを用いて車両の対称軸を求め，それに基づいて左右前照灯領域を検出することで車両フロント領域を高精度かつ安定に検出する手法を開発した．さらに，提案した検出手法を3箇所の異なる撮影環境で収集した延べ8時間，約20万フレームの道路画像を用いて検出精度の評価を行った．その結果，車両フロント領域の平均検出率が98%以上を得ることができ，自動認識に必要な車両フロント領域の特徴検出の精度と安定性を確認した．

今後の課題として，雨，雪，夜などの多様な天候に対する評価と対応が挙げられる．

第 4 章

類似モデルのグループ化による車両モデルの多段階認識

4.1 はじめに

第 3 章では、車両モデル認識のための車両検出手法について述べた。実際の道路画像を用いた評価実験で高い検出率を得ることができ、自動認識に必要な車両フロント領域の特徴を精度よく安定に取れることが確認できた。本章では、車両の自動検出処理で検出された車両特徴を用いて、車両モデルを認識する手法について論ずる。

交通状況監視システムへの適用を目指した研究としては、ナンバープレートから車種情報を得る方法[27]の開発は進み、また、路車間に通信により車両 ID を送信する方法も提案されている。しかし、これらは個人情報へのアクセスや車載装置が必要となるために適用範囲が限られる。これらの問題に対して、路上のカメラ情報から車両の形状特徴に基づいて車両モデルの認識が可能になれば、個人情報へのアクセスや特別な装備なしに車両種別（トラックや乗用車など）だけではなく車両モデルの取得が可能になる。これにより、道路使用状況分析に車種別の交通流の計測が可能になるばかりではなく、ナンバープレートの偽装に強い捜査情報の提供や、設計時の類似車両モデル検索などにも応用できる可能性がある。さらに、ナンバープレート情報との照合により偽装車両を発見し、犯罪抑止に役立つシステムの構築にも利用できる。

これまで、車両の形状特徴に基づいて車種判別を行う研究としては、道路脇に設置した単眼カメラで車両後方面像を取得し、車両の断面形状を用いて車両を 3 種類に分類する手法[13]や、複数台のカメラで撮影した 3 次元計測結果を用いて、車両の輪郭形状から 3 種類の車種を識別する手法[14]などが提案されている。また、長谷川らは、対面通行の一般道路映像中から、移動対象物を 6 種類の種別に識別するとともにそれらの色の推定を行う手法を報告している[25]。このシステムは、対象の姿勢変化への対応は可能になっているが、対象

の種類は 6 種類に限定されている。一方、影沢らは、赤外線画像によって一部が隠蔽されている場合でも、あらかじめ指定した特定の車種を道路画像から検出するシステムを提案しているが、識別対象が多い場合の評価は行われていない[26]。また、駐車車両を対象として Match refinement 法による車種認識手法が提案されているが、通過車両に対する検討は報告されていない[28]。このようにこれまでの研究では、乗用車やトラックといった車両の形の分類に関する方法は多く検討されてきたが、通過車両のモデル(A社 N 年式 B 型)認識を目指した研究はほとんどない。

本章では、車両の形状特徴に基づいて、車両モデルを識別する手法について検討する。車両モデルの識別にあたっては、車両の形状が類似したモデルの存在や、環境の変化にもなう車両の見え方の変化などが問題になる。これらの問題に対して、学習の段階で類似した車両モデルのグループを生成し、認識にあたってそのグループの中で車両の部分領域ごとの類似性を統合評価することで、環境変化の影響を回避しながら、類似した車両モデルの認識が行える多段階認識法を提案する。以下は、学習画像に基づいて車両モデルを分類する多段階認識法、および、時系列道路画像を用いた評価実験の結果について述べる。

4.2 車両モデルの自動識別処理の概要

本研究では、図 4.1 に示すように、道路の走行レーンの上部に配置した 1 台の固定カメラで通過車両を観測し、その時系列画像から車両のフロント部分の形状特徴に基づいて、個別の車両モデルを認識することを目的としている。車両モデルの認識は、屋外環境で撮影が行われるために、対象車両の画像は、隣接車両からの映り込みや環境からの反射などの影響を受けて変化する。また、図 4.2 に示すように、市販されている車両のモデルは多様である一方、車両の形状が類似したモデルも多い。さらに、同一の車両モデルの中でも車体の色違いや文字や模様が入る場合もあり、車種判別を難しくする要因がある。

このような問題点を踏まえて、本章では、類似車両モデルのグループを用いて、そのなかで最適な特徴を選択する多段階認識法を提案する。具体的には、学習の段階で、最初に認識対象のモデル（カテゴリ）ごとに類似モデルのグループをあらかじめ生成し、次にフロント画像を 4 つの部分に区分した領域単位に、グループ内のカテゴリを分離するに適した特徴の選別を行う。認識の段階では、最初にモデルグループの識別を行い、次にモデルグループ内で部分領域の特徴を用いて識別するというように、特徴選別と識別を多段階で行うことで類似した車両モデルの認識精度の向上を目指している。

また、多段階認識の第 1 段階のグループ認識では、フロント部分の対称軸を中心として

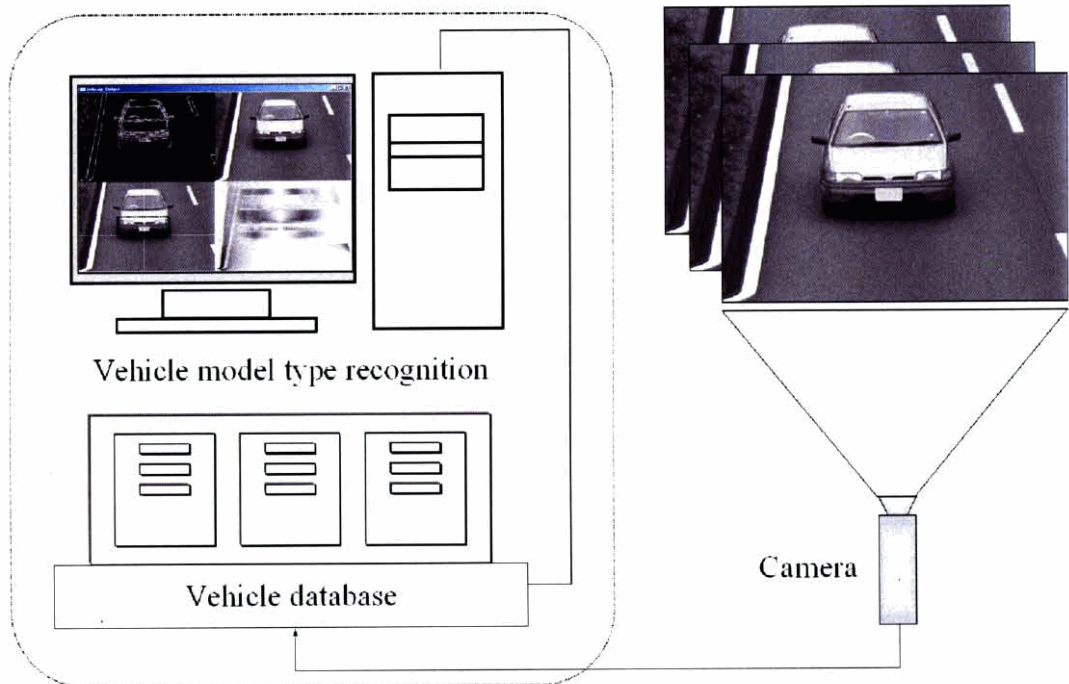


図 4.1 本研究の目的

Fig.4.1. Purpose of this study.

左右画像を折り返して平均化した平均対称特徴を用いることにより、太陽光の照射方向の違いによる陰影の影響を緩和している。さらに、第 2 段階では、領域を分割して、部分領域ごとに形状の類似性を判定する。これにより、部分的な差異を除外して、照合性が高い部分領域の数が多いカテゴリを選択することによって、環境の影響による車両フロント画像の部分的変化にロバストで高精度な車両モデルの認識を実現する。最後に、時系列的に観測した結果を統合評価することで、さらに高精度化を図っている。




図 4.2 対象車両の画像例

Fig.4.2. Example of vehicle images.

4.3 車両モデルの認識アルゴリズム

車両モデル認識の流れ図を図 4.3 に示す。本手法は大別すると、車両特徴抽出処理、多段階認識法に基づく学習・認識処理、時系列の車種判定処理の三つの部分で構成されている。最初に、学習画像から検出された車両フロント領域の特徴抽出を行い、抽出された特徴をもとに特徴の選別と多段階の特徴空間を生成する。次に、認識に際しては、認識用の時系列画像から第 1 段階と第 2 段階の認識に必要な特徴を抽出し、多段階認識法に基づいてフレーム単位の車両モデル認識を行う。最後に、フレーム単位の認識結果をもとに、時系列に観測し、車両モデルとして総合判定を行う。これから各処理の概要について述べる。

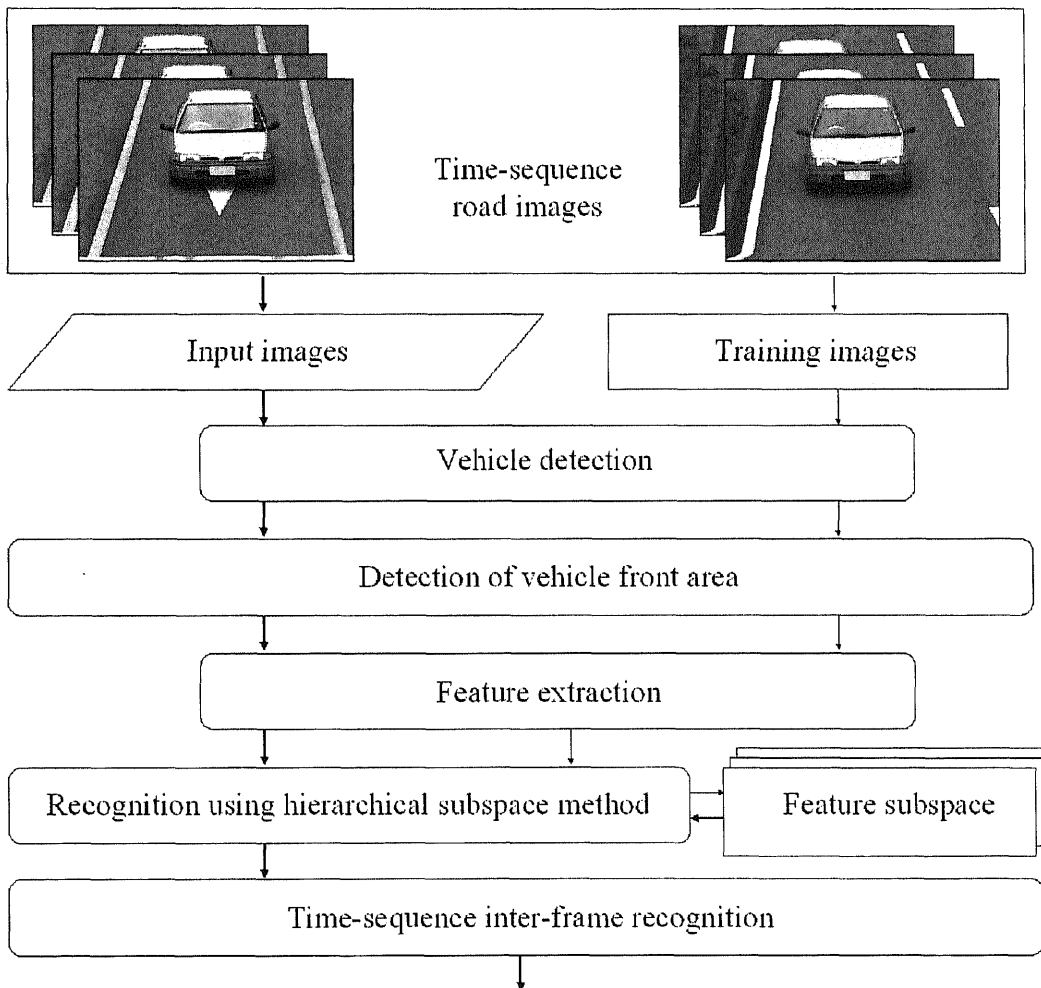


図 4.3 車両モデル認識の流れ図

Fig.4.3. Procedure of vehicle recognition.

4.3.1 車両フロント領域の特徴抽出

図 4.4(a)に原画像の一例で、図 4.4(b)は検出された車両フロント領域である。学習・識別処理の入力となるフロント領域内の基本特徴を、原画像上の $M=5$ 画素を反転した自己対称テンプレートを、水平方向および垂直方向に適用して、次式により算出した $R(i,j)$ を用いて求める。

$$R(i, j) = \sqrt{\frac{R_x^2(i, j) + R_y^2(i, j)}{2}} \quad (4.1)$$

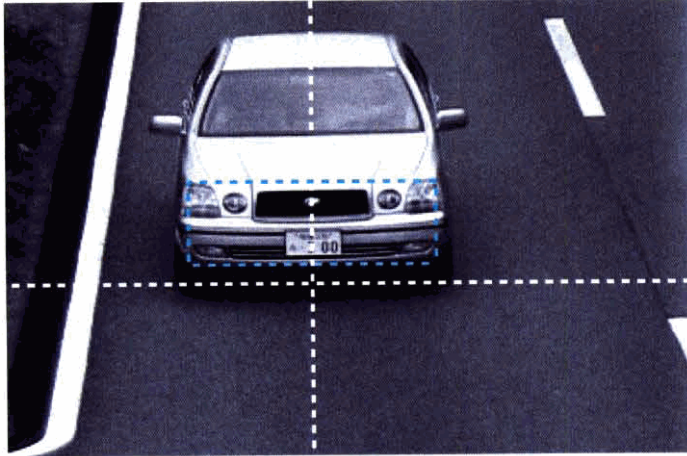
ただし、

$$R_x(i, j) = \sum_{l=1}^M |f_{(i-l, j)} - f_{(i+l, j)}| / M,$$


$$R_y(i, j) = \sum_{l=1}^M |f_{(i, j-l)} - f_{(i, j+l)}| / M$$

ここで、 $R_x(i,j)$ は水平方向、 $R_y(i,j)$ は垂直方向の自己対称判定画像である。


さらに、 $R(i,j)$ に対して 5×5 のフィルタで平滑化を行ったのちに、画像内の画素値を平均が 0、分散が 1 となるように輝度分布の正規化を行う。また、正規化された対称判定画像 $R_n(i,j)$ からフロントの対称軸を中心として左右対称に折り返した平均輝度を算出し、これを 15×10 pixel に縮小した画像 $R_{ns}(i,j)$ を第 1 段階の入力特徴として用いる。同時に、 $R_n(i,j)$ を 30×10 pixel に縮小した画像 $R_{nm}(i,j)$ を第 2 段階の入力特徴としている。第 1 段階と第 2 段階で用いる入力特徴の一例を図 4.4(c)と(d)に示す。




(a) An input data



(b) Front area



(c) The first step feature



(d) The second step feature

図 4.4 車両フロント領域の特徴抽出

Fig.4.4. Feature extraction.

4.3.2 多段階認識法に基づく車種認識

提案手法の各段階は、部分空間法に基づく学習と認識を基本とする。しかし、部分空間法は、特徴抽出と識別を同時に行うことができる認識法であるが[20]、カテゴリ単位で特徴の部分空間を選別するために、類似した認識カテゴリが存在する場合に、カテゴリの識別が困難になる。本手法では、類似したモデルに対応するために、学習の際に各カテゴリに対してそのカテゴリと類似性が高いカテゴリをまとめ、類似モデルグループを生成する。次に、それぞれのモデルグループ内で特定のカテゴリを識別するのに適した特徴を、フロント部分を分割した部分領域から抽出し選別を行う。認識にあたっては、最初にモデルグループを識別し、次にモデルグループ内でカテゴリを特定するという多段階で認識を行う方法を採用。これにより、類似したモデルグループ内の車両を区分するために適した特徴の選定が可能になり、類似車両に対する認識性能の向上が期待できる。

4.3.2.1 部分空間法

部分空間法は統計的パターン分類法の一つであり、多次元特徴空間のなかでカテゴリ内のサンプルの分布状態を反映した部分空間を作成しておき、各カテゴリの部分空間に対する射影量を評価して、未知の入力パターンを分類するアルゴリズムである。特徴空間内で部分空間を作成するために、同一カテゴリに属する学習サンプルを特徴空間に配置し、それらの分散の大きい軸を求める。実際には、特徴ベクトルの自己相関行列を作成し、自己相関行列の固有値問題を解くことに置き換えている。

カテゴリ a の学習画像 i を正規化された n 個の特徴量を要素として持つ特徴ベクトル

$$\mathbf{x}_i^{(a)} = (x_{i,0}^{(a)}, x_{i,1}^{(a)}, \dots, x_{i,n-1}^{(a)})^T$$

として表す。カテゴリ a の学習サンプルが m 個ある場合、それらの特徴ベクトルをならべ、

$$\mathbf{X}^{(a)} = \{\mathbf{x}_0^{(a)}, \mathbf{x}_1^{(a)}, \mathbf{x}_2^{(a)}, \dots, \mathbf{x}_{m-1}^{(a)}\}$$

とすると、自己相関行列 $\mathbf{R}^{(a)}$ は

$$\mathbf{R}^{(a)} = E(\mathbf{x}^{(a)} \mathbf{x}^{(a)T}) \quad (4.2)$$

で求められる。ただし、 $E(\mathbf{x})$ は行列 \mathbf{x} の各要素の平均値を算出する関数とする。ここで、 $\mathbf{R}^{(a)}$ の固有値問題

$$\mathbf{R}^{(a)} \boldsymbol{\mu}^{(a)}_l = \lambda^{(a)}_l \boldsymbol{\mu}^{(a)}_l \quad (4.3)$$

を解くことによって、カテゴリ a のサンプルの分散が大きい方向を示す直交基底ベクトルが、固有ベクトル $\boldsymbol{\mu}^{(a)}_l$ として得られる。ここで、 $\lambda^{(a)}_l$ を l 番目に値の大きい固有値、 $\boldsymbol{\mu}^{(a)}_l$ を $\lambda^{(a)}_l$ に対応する固有ベクトルとすると

$$\mu^{(a)T} \mathbf{R}^{(a)} \mu^{(a)}_i = \lambda^{(a)}_i \mu^{(a)T} \mu^{(a)}_i = \lambda^{(a)}_i$$

となることから、固有ベクトル $\mu^{(a)}_i$ 方向の学習サンプルの分散は $\lambda^{(a)}_i$ となる。部分空間法では、値の大きい k 個の固有値に対応する k 個の固有ベクトルで構成される部分空間を選別し、認識処理において、特徴ベクトルをカテゴリ別の部分空間への射影量を比較することにより、類似性を評価する。

4.3.2.2 多階層認識空間の生成

多段階認識の各段階で用いる特徴の選別を行う。第一段階では、各カテゴリと類似するカテゴリを判定し類似モデルグループ空間を生成する。第2段階において、それぞれのグループ内カテゴリの特徴部分空間を生成する。最初に、車両モデルが既知の時系列画像の各フレームを教師画像として、学習サンプルを準備する。車両のフロント領域検出における微妙な位置ずれの影響を回避するために、各フレームのフロント領域の検出位置を上下と左右に移動しながら1フレームについて複数の学習サンプルを利用する。また、第1段階では環境の影響を少なくし、カテゴリ内の分散を小さくするために、対称軸を中心に反転平均化した特徴を用いている。次に、第2段階では、類似カテゴリを区分するために、フロントの部分領域から抽出した特徴を入力とする。以下に、各段階の部分空間を生成する手順について説明する。

図4.5は、学習処理の流れであり、第1段階では、最初に、各カテゴリの学習用時系列画像から抽出した特徴画像 $R_{ns}(i,j)$ の画素の値を走査線に沿ってならべた150次元のベクトルを入力として、部分空間法に基づいて特徴の選別を行う。次に、学習画像のあるカテゴリの入力ベクトルと、各カテゴリの特徴空間(辞書部分空間)との類似度を求め、入力パターンと類似度が高いカテゴリを検出し、類似モデルグループを作成する。この処理を各カテゴリの入力ベクトルに対して行い、カテゴリごとに類似モデルグループを作成する。なお、類似モデルグループのカテゴリの数については予備実験で決定している。新しい車両(カテゴリ)の追加学習にあたっては、新たなカテゴリの類似グループを生成するとともに、既存カテゴリとの類似性を判定し、それが類似モデルグループ内メンバーの類似性よりも高い場合には、グループのメンバーを再編する。

次に、第1段階で分類されたそれぞれの類似モデルグループに対して第2段階の処理を行う。第2段階では、フロント部分の入力特徴画像 $R_{nm}(i,j)$ を左および右前照灯領域、フロントグリル領域、グリル下方領域の4領域に分割して、それぞれの領域に対応する50, 50, 50, 150次元の4つのベクトルを入力特徴とする。この入力ベクトルを用いて、類似モデルグループ内の各カテゴリに対して、各領域ごとに部分特徴空間(辞書領域部分空間)を作成する。

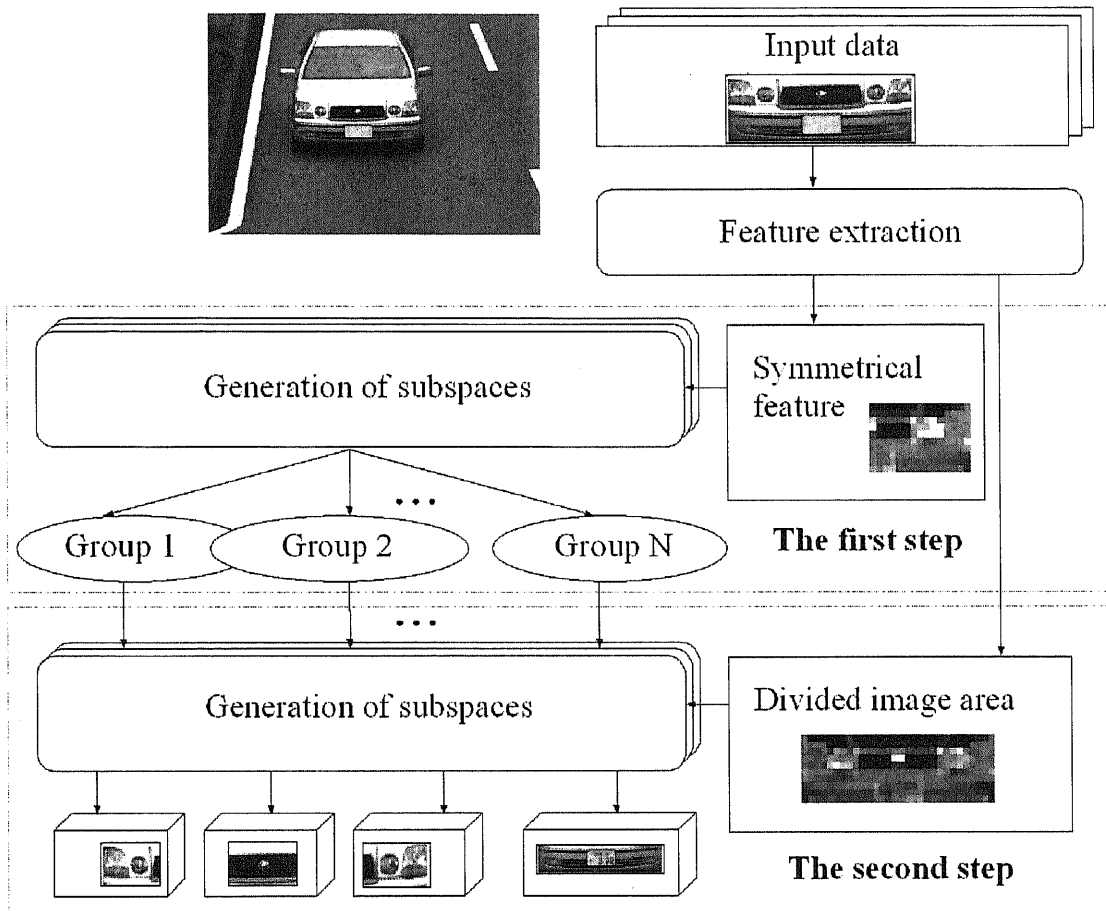


図 4.5 多段階学習の手続き

Fig.4.5. Procedure of learning based on hierarchical subspace method.

4.3.2.3 多段階認識処理

多段階認識法の流れを図 4.6 に示す。最初に、認識用の時系列画像の各フレームに対して特徴抽出を行い、入力特徴 $R_{ns}(i,j)$ と $R_{nm}(i,j)$ を抽出する。次に、入力特徴 $R_{ns}(i,j)$ を特徴ベクトルとして第 1 段階の特徴空間(辞書部分空間)との射影をもとに、入力パターンと類似度が最も高いカテゴリを代表とするグループを選択する。第 2 段階では、認識対象の入力特徴 $R_{nm}(i,j)$ を 4 つの部分領域に分割し、それぞれの領域に対応する特徴空間(辞書領域部分空間)に射影し、各領域ごとに最も類似度が高いカテゴリを判定する。4 つの領域のなかで同一の判定結果となるものがある場合、その一致した領域数が規定値 Ta より多いときは、そのカテゴリを認識結果と判定し、少ない場合は第 1 段階の照合結果を認識結果とする。また、第 1 段階の類似度が閾値 Ts より低い場合は棄却する。なお、4 つの領域の中で最大の類似度を第 2 段階認識の類似度とし、時系列認識で利用する。

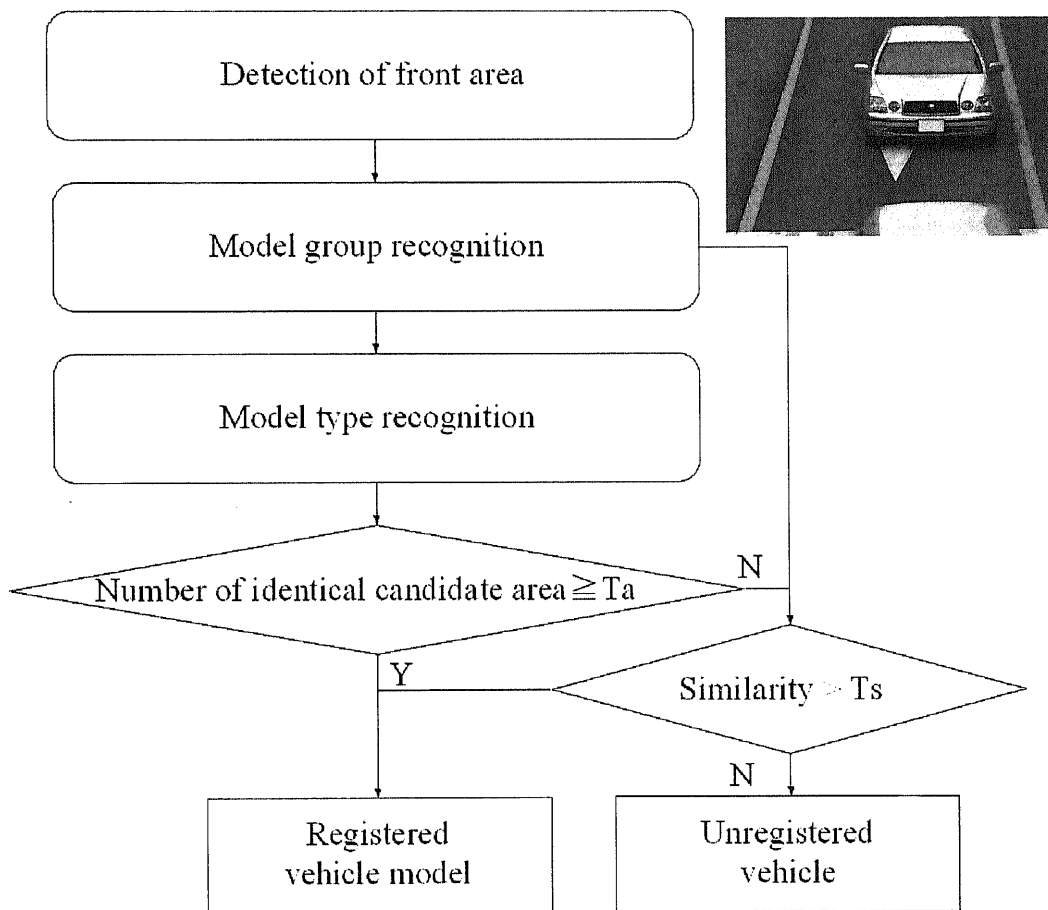


図 4.6 多段階認識の流れ図

Fig.4.6. Procedure of vehicle recognition using hierarchical subspace method.

4.3.3 時系列車種認識

フレーム単位の認識結果をもとに，時系列画像の結果を用いて，車両としての総合判定を行う．実空間を運動する車両の動きは連続であり，位置や形状が急激に変化しないものと仮定できる．ここでは，連続画像を一定時間の間，観測して，多段階認識で得られたフレーム単位の認識結果をもとに，次式に基づいて線形予測を行い，車両モデルを再評価する．

$$P_j(t) = a_0 S_j(t) + \sum_{k=1}^L a_k \cdot P_j(t-k) \quad (4.4)$$

ここで $S_j(t)$ は時刻 t での多段階認識で算出したカテゴリ j ($j = 1, 2, \dots, N$) に対する類似度で，第 1 段階と第 2 段階の類似度のうち大きい方を取っている． $P_j(t)$ は時刻 t のカテゴリ j の再評価値を表している．また， a_0 と a_k は重みであり，和を 1 に正規化している．
入力パターンに対する各カテゴリの再評価値 $P_j(t)$ のなかで，最大となるカテゴリを認識結果としている．

4.4 実験

4.4.1 実験条件

実験では連続した道路の三つの異なる地点で収集された延べ 8 時間のデータの中、車両が検知された約 20 万フレームの時系列道路画像を用いて評価を行った。各撮影環境の一例を図 4.7 に示し、それぞれの撮影条件を表 4.1 にまとめている。入力画像はいずれも 720×480 pixel, 256 階調であり, 30 frame/s のフレームレートで収集した。

最初に, 連続した道路で 700 m ほど離れた 2 つの場所 (E 地点, G 地点) に設置したカメラで同時刻に取得した延べ約 4 時間の時系列道路画像を用いた。なお, 両地点の間には交差点があるために車両の入れ替えがおきている。実験では, G 地点の画像を学習用, E 地点の画像を認識用として用いている。ここでは, G, E の地点で同一車両モデルが現れる 170 車種を学習用の登録車両, E 地点のその他の 180 車種を登録外車両として使用した。すべての車両に対して, 目視で判定して車種のラベルを付けた。図 4.8(a)~(d)には登録された全車種の例を示す。

次に, 環境変化による適応性を評価するために, E 地点と B 地点において, 異なる日時に収集した延べ約 4 時間のデータを用いて認識実験を行った。

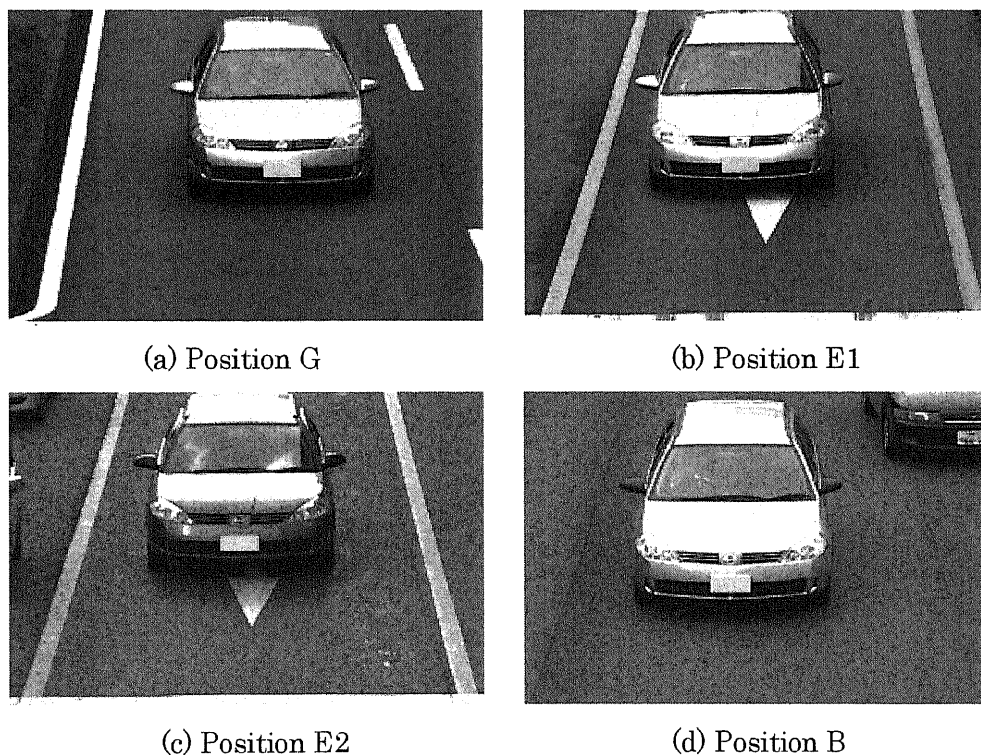


図 4.7 各撮影環境の例

Fig.4.7. Examples for road environment.

表 4.1 撮影環境の条件

Table 4.1. The conditions of road environment.

条件	撮影地点			
	G	E1	E2	B
天候	晴れ/曇り	晴れ/曇り	晴れ/曇り	晴れ
時間帯	昼	昼	昼	昼
季節	夏	夏	冬	春
輝度変化	あり	あり	あり	あり
通過車両(台)	415	539	476	465



(a)

図 4.8 登録された車両モデルの例(モデル 1~45)

Fig 4.8. Examples of vehicles registered.



(b)

図 4.8 登録された車両モデルの例(モデル 46~90)

Fig 4.8. Examples of vehicles registered.



(c)

図 4.8 登録された車両モデルの例(モデル 91~130)

Fig 4.8. Examples of vehicles registered.



(d)

図 4.8 登録された車両モデルの例(モデル 131~170)

Fig 4.8. Examples of vehicles registered.

4.4.2 車両モデル認識に適合する特徴空間の検討

最初に、部分空間法及び固有空間法を用いて異なる特徴空間を作成する実験を行い、テストデータを用いて認識結果を評価した。固有空間法は、部分空間法が多次元特徴空間のなかで識別カテゴリ毎に学習サンプルの分布状態を反映した部分空間を作成するのに対し、カテゴリに関係なく全学習サンプルの分離のよい空間軸を探して一つの固有空間を作成する手法である。認識サンプルは固有空間に射影し、固有空間内の各カテゴリの平均ベクトルとの距離を比較して最も距離の短いカテゴリに識別される。本実験で固有空間の評価尺度はユークリッド距離を用いた。

実験には 2 種類の学習サンプルを用意して両手法を用いてそれぞれの特徴空間を作成した。認識データは登録車両 170 車種のテストデータを使用した。

実験Ⅰ：1 フレームの中で車両フロント領域の検出位置を 1 箇所のみ取って、車種ごとに 9 フレーム分の画像データを用いた合計 1530(1×9×170)パターンを使用した。

実験Ⅱ：1 フレームの中で車両フロント領域の検出位置を 15 箇所移動させて、車種ごとに 9 フレーム分の画像データを取った合計 22950(15×9×170)パターンを使用した。

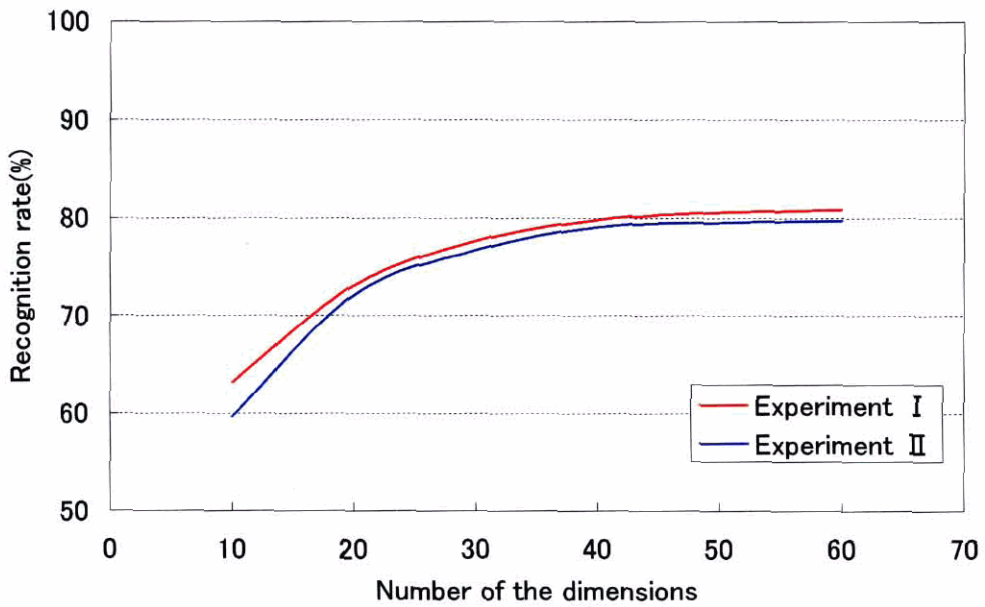
図 4.9(a)に固有空間法で生成した特徴空間を用いた認識結果を示し、図 4.9(b)には部分空間法で生成した特徴空間を用いた認識結果を示す。図 4.9(a)の中で、実験Ⅱの結果は実験Ⅰの結果より認識精度が低下している。これに対して、図 4.9(b)の中では、実験Ⅱの結果が実験Ⅰの結果に比べて認識精度が大きく向上できていることが分かる。これは車両フロントの検出位置の変動が認識精度に大きく影響することを示している。部分空間法による実験Ⅱでは、各フレームのフロント領域の検出位置を上下と左右に移動しながら 1 フレームについて複数の学習サンプルを学習させることで、対象の位置ずれに対応する部分空間が生成できたと考えられる。

また、表 4.2 は各実験の認識率を比較したものである。表 4.2 で、固有空間法の次元数は 50 次元とし、部分空間法の次元数は 6 次元としている。この表より、固有空間法を用いた認識では、最適な認識率が 80.6%であるのに対して、対象の位置ずれに対応する部分空間を利用した手法では 97%以上の高い認識率を得ることが確認でき、車両モデル認識に有効であることが分かった。

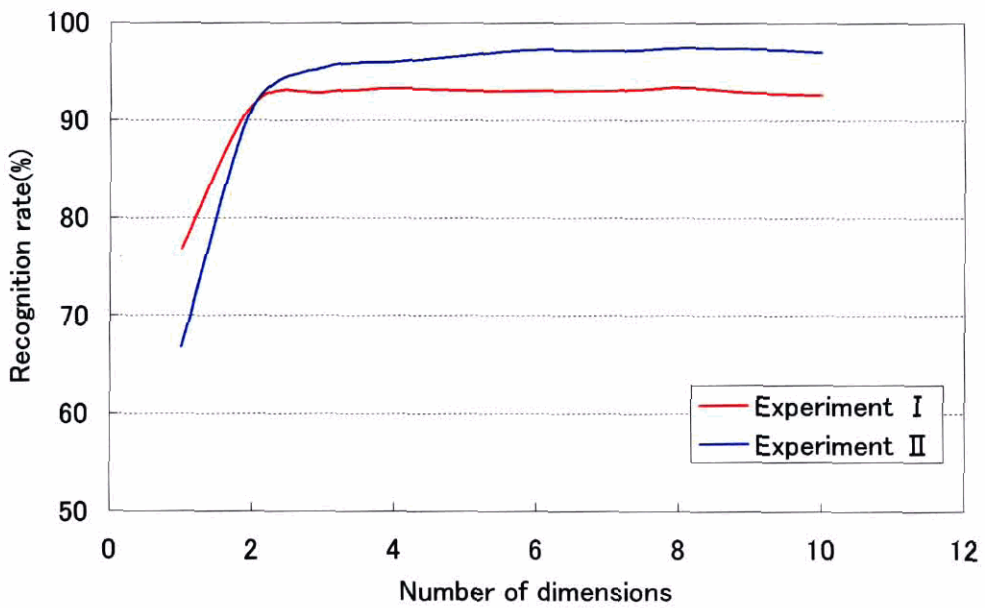
表 4.2 各実験の認識率の比較

Table 4.2 Comparison of recognition rate.

Experiment	Learning sample	Eigenspace method	Subspace method
I	1 × 9 × 170	80.6%	93.0%
II	15 × 9 × 170	79.5%	97.2%



(a) Eigenspace method



(b) Subspace method

図 4.9 特徴空間と認識率の関係

Fig.4.9. Relationship between feature spaces and recognition rates.

4.4.3 多階層認識空間の構築

学習には、G 地点の 170 車種の時系列画像から、図 4.10 に示すように 1 車種あたり 9 フレーム分の画像データを用いた。さらに、1 フレームの画像の中で検出位置を上下、左右一定範囲を 15 箇所移動させ、1 車種につき 135 パターンの学習サンプルとしている。

第 1 段階の学習において、類似モデルグループの作成に、時系列の複数フレームの学習データを用いているために、各類似モデルグループのカテゴリ数は異なっている。図 4.11 は、学習および認識用データに対する第 1 段階の認識結果である。図 4.11 において、横軸は候補の数、縦軸は候補の中に正当が含まれるとした場合の認識率を示す。図 4.11 の結果より、第 10 候補までを用いてグループを形成することにより、第一段階のグループ認識の誤りを 1% 程度に抑えられることが分かる。第 2 段階では、 30×10 pixel 大きさのフロント領域画像を 4 領域に分割した特徴画像を用い、類似モデルグループごとに学習を行った。

図 4.12 は、全 170 車種の入力部分空間からそれぞれ算出した累積寄与率の平均値の変化を示したものである。この結果より、比較的少ない基底ベクトルで、高い平均累積寄与率を取ることが分かる。これは、連続撮影した同一車両の画像を学習データとして用いていることを反映しているものと考えられる。本実験では、十分に高い累積寄与率(99.6%)かつ計算コストが低いという観点から、部分空間の次元を 6 次元と定めた。なお、第 2 段階の認識の領域数の閾値 T_a については、4 つの部分領域の中から、映り込みやマーク・装飾など学習サンプルとは異なる部分領域を排除するという考慮して 3 に設定している。




図 4.10 時系列入力例

Fig.4.10. Time-sequence road images.




図 4.11 候補による認識率の変化

Fig.4.11. Variation of recognition rates on the number of candidates.





図 4.12 次元数による累積寄与率の変化

Fig.4.12. Variation of cumulative contribution ratio dependent on the number of dimensions of the subspace.

4.4.4 フレーム単位の車両モデル認識


図 4.13 に、多段階認識法を用いた車両モデル認識の一例を示す。図 4.13(a)は入力された連続フレーム画像の一例である。この車両モデルの登録画像は図 4.13(d)に示す白色の車両(M6)と同一であるが、図 4.13(a)の認識画像はヘッドライト周辺に環境からの映り込みの影響がある。第 1 値段階の認識では、図 4.13(b)に示す車両(M5)と類似度が最も高い車両として選択された。図 4.13(e)は、車両モデル(M5)を代表とする類似モデルのグループであり、第 2 段階の認識において、このグループ中の 14 の車両モデルとの類似性が再評価される。図 4.13(f)は、第 2 段階認識で認識画像と類似グループ内モデルとの各部分領域における類似度を示したものである。車両モデル(M6)との類似度は 3 つの領域(図 4.13(c))が最も高い値を取っており、この画像は M6 と判定された。この結果では、多段階認識処理の導入により、環境からの映り込みによる車両画像の部分的な影響の回避が可能になっている。



(a) An input data




(b) A recognition result of group




(c) Segmented areas with maximum similarities



(d) Recognition result



(e) Vehicle models on the group



(f) Similarities of each area.

図 4.13 多段階認識の一例

Fig. 4.13. An example of hierarchical recognition process.

4.4.5 従来手法との比較

提案手法の有効性を確認するために、E地点で車両のフロント領域が検出できた4276枚の画像フレームを用いて、部分空間法単独と比較実験を行った。表4.3はその結果であり、部分空間法単独と本手法の結果を比較して示している。登録車両については、両手法とも99%以上という高い認識率が得られることが確認できた。一方、棄却率については、部分空間法と比較して本手法は、登録車両に対する棄却率が低く、また、登録外車両に対する棄却確率が高くなっており、認識能力が改善されていることが確認できた。図4.14はROC(Receiver Operating Characteristic)曲線を比較したものであり、破線が部分空間法の結果、実線が多段階認識法の結果である。図4.14において、縦軸はFRR(False Reject Rate)、横軸はFAR(False Accept Rate)となっている。

$$FRR = \frac{\text{閾値以下で棄却された登録車両のフレーム数}}{\text{登録車両の全フレーム数}} \quad (4.5)$$

$$FAR = \frac{\text{登録外車両を登録車両と判定した車両のフレーム数}}{\text{登録外車両の全フレーム数}} \quad (4.6)$$

図4.14の結果からも、FRRとFARが等しいときの割合EER(Equal Error Rate)が部分空間法単独の12.0%に対して、提案手法は9.4%に改善できており、認識系の信頼度が向上していることが分かる。

表 4.3 フレーム単位の認識率の比較
Table 4.3. Comparison of recognition rate.

	Vehicle	Recognition rate	Error rate	Reject rate
SM	Registered	2122/2127 (99.76%)	5/2127 (0.24%)	317/2444 (12.97%)
	Unregistered		174/1832 (9.50%)	1658/1832 (90.50%)
HSM	Registered	2198/2202 (99.82%)	4/2202 (0.18%)	242/2444 9.90%
	Unregistered		134/1832 (7.31%)	1698/1832 (92.69%)




図 4.14 HSM 法と SM 法の ROC 曲線の比較

Fig.4.14. Comparison between ROC curves for the recognition methods.

4.4.6 時系列処理の認識結果

表 4.4 は多段階認識法に時系列処理により, 539 台の通過車両に対する車両単位の認識を行った結果である. この結果から, 時系列的に観測して統合評価することで, 登録外車両の棄却率がさらに向上することが分かった.

表 4.4 時系列認識の結果

Table 4.4 Results of final recognition.

Vehicle	Number	Miss-recognition	Reject
Registered	299	0.00%	9.36%
Unregistered	240	5.00%	95.00%

4.4.7 環境変化における評価実験

最後に、環境変化による適応性を確認するために、E 地点と B 地点において、異なる日に収集した認識用データを用いて追加実験を行った。この実験で、E 地点では通過車両 476 台の中で登録車両が 129 台、登録外車両が 347 台であり、B 地点では通過車両 465 台の中で登録車両が 75 台でやや少なく、登録外車両が 390 台である。学習データは表 4.4 のものと同一である。表 4.5 と表 4.6 はその認識結果をまとめたものであり、登録車両の棄却率と誤認識率が、表 4.4 の結果と比較して多少上がっているが、登録外車両の棄却率はほぼ同様の結果となっており、本提案手法が有効に働いているものと考えられる。

表 4.5 異なる環境 E 地点での認識結果

Table 4.5 Experimental results in different environment (Position E).

Vehicle	Number	Miss-recognition	Reject
Registered	129	2	16
Unregistered	347	19	328

表 4.6 異なる環境 B 地点での認識結果

Table 4.6 Experimental results in different environment (Position B).

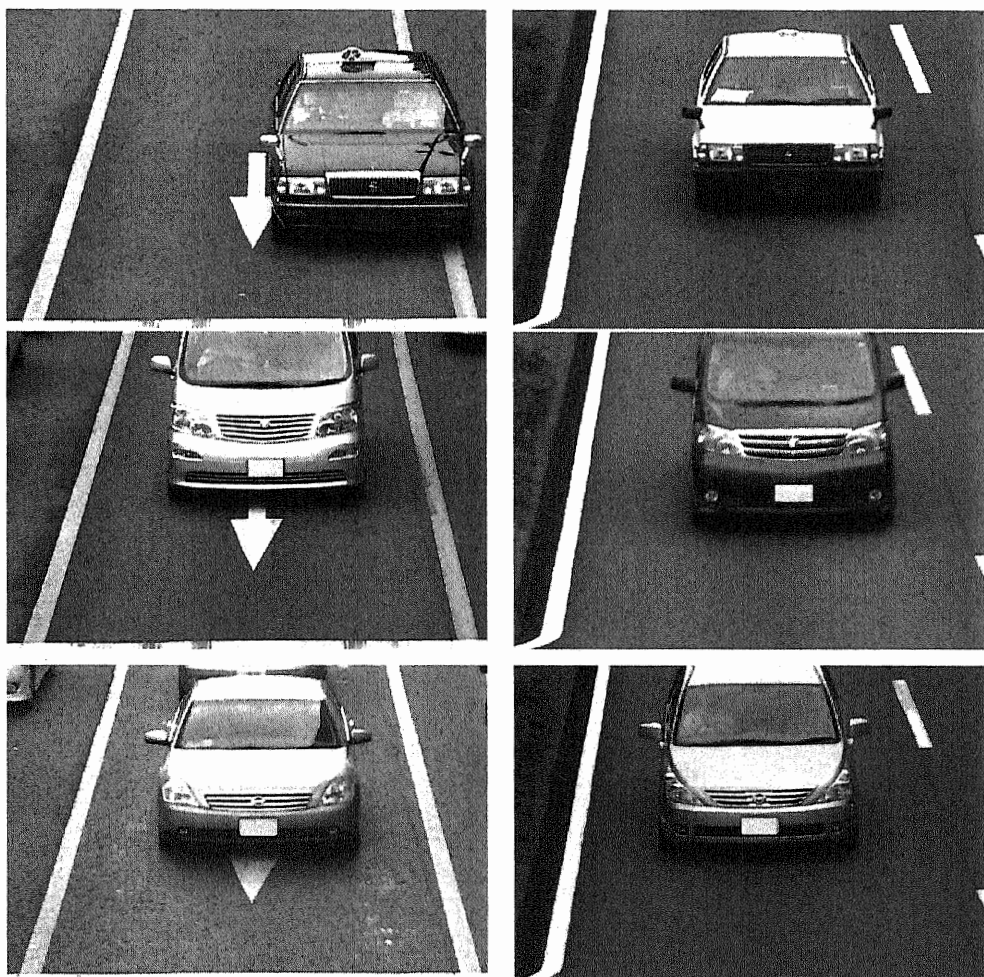
Vehicle	Number	Miss-recognition	Reject
Registered	75	1	10
Unregistered	390	17	373

4.5 考察

図 4.15 および図 4.16 に、提案手法で登録外車両が登録車両として誤認識された結果と、登録車両モデルが棄却された結果の一例を示す。図 4.15 の各列において、左側が入力車両、右側が認識結果である。また、図 4.16 では、右側に第 1 候補の画像を示している。図 4.15 の誤認識の結果および図 4.16 の第 1 候補は、入力画像と全体形状の類似性が高いものが多く、提案手法の安定性を示唆するものと考えられる。

一方、登録外車両を発見するような用途に使う場合では、認識率よりも登録外車両の棄却率をさらに向上させる必要性がでてくるものと考えており、車両の詳細特徴の抽出法などの検討が必要である。

今回の実験では、天候が晴天と曇天に収集した道路画像を用いて、また車両の重なりがある画像は車両フロント領域の特徴を十分に取れないことから認識実験に含まれていない。これに関しては、もう一台のカメラを設置して、車両後方を認識する方策などが考えられるが、学習データも含め、実験の再構成が必要になるために、対象外としている。なお、雨、雪、夜などの多様な天候に対する評価と対応は今後の課題である。




Input data to be tested

Result of recognition

図 4.15 登録外車両に対する誤認識の例

Fig.4.15. Misrecognized examples for unregistered vehicles.



Input data to be tested

First candidate

図 4.16 棄却された登録車両と第 1 候補の車両

Fig.4.16. Rejected vehicles which is registered, and the first candidates.

4.6 まとめ

本章では、車両監視システムへの応用を目的として、固定カメラで観測した道路画像から通過車両の形状特徴に基づいて、車両モデルを認識する手法について述べた。車両モデルの識別にあたっては、車両の形状が類似したモデルの存在や、環境の変化にともなう車両の見え方の変化などが問題になる。これらの問題に対して、学習の段階で類似した車両モデルのグループを生成し、認識にあたってそのグループの中で車両の部分領域ごとの類似性を統合評価することで、環境からの部分的な映り込みの影響を回避しながら、類似した車両モデルの認識が行える多段階認識法を提案した。また、認識段階で車両の切り出し精度が認識率に大きく影響することを見出し、その問題を回避するための部分空間生成法を提案した。

本提案手法を固定カメラで撮影された延べ8時間、約20万フレームの時系列道路画像を用いて評価実験を行った。評価実験では最初に、学習段階で各フレームのフロント領域の検出位置を移動しながら1フレームについて複数の学習サンプルを用いて位置ずれに対応する部分特徴空間を生成することで、位置ずれを考慮していない特徴空間に比べて認識率が大幅に向上することを確認した。また、4276枚の時系列道路画像を用いた実験により、フレーム単位の認識でも登録外車両を92%棄却した上で、登録車両に対して99%以上の認識率を得ることができ、従来困難であると考えられてきた車両モデルの詳細判別の実現性を確認した。従来法との比較では、EERが部分空間法単独の12.0%に対して、多段階認識を導入した提案手法は9.4%に改善できており、認識系の信頼度が向上していることが分かった。さらに、異なる環境で収集したデータに適用して、提案手法が有効に働いていることを確認した。

なお、実用化にあたっては、さらに多様な天候でのデータを用いた手法の検証が必要である。

第5章

結論

5.1 本研究のまとめ

本研究では、安全な道路環境、安定的な自動車社会に役立てることを目的として、画像処理を用いて時系列道路画像から車種を認識することで、ドライバーに最適な車間距離を維持するための運転支援や、道路画像中から個別車両モデルを認識することにより犯罪抑止に役立つシステムの構築を可能にする基盤技術を開発した。本論文では主に、車種を正確かつ高精度に認識する研究開発についてまとめた。最初に、車載センサを統合して多重構造ニューラルネットワークを用いた車種認識手法を提案し、ドライバーの安全運転支援のための前方複数対象物の検出・車種判別の高精度化が可能となった。次に、固定カメラで観測した道路画像から通過車両の車両モデルを認識するために不可欠な車両自動検出手法を提案し、自動認識に必要な車両フロント領域の検出精度を得ることができた。最後に、類似モデルのグループ化による車両モデルの多段階認識手法を提案し、従来はほとんど手がついてなかった通過車両のモデル認識の実現可能性を示した。

第2章では、ドライバーの安全運転を支援するために、道路上での複数の車両を検出し、車種判定を行うことを目的として、多層構造ニューラルネットワークを用いた車両検出・車種認識手法について論じた。ここでは、観測データに対象と背景が混在するため誤認識が生じやすい問題を回避するために、対象物のサイズに応じてサイズが異なる受容野特性を持ったニューラルネットワークを並列に配置し、その結果を統合識別器で統合評価することによって、複雑背景中で大きさの異なる対象物を高精度に識別する手法を提案した。また、正確かつ安定な認識を目指して、道路の走行環境モデルを利用した時系列観測手法を検討した。レーザレーダの距離情報から得られる幅特徴とレーザレーダの強度から得られる車種毎に特定の分布を示す特徴及びカメラ画像からの輪郭情報など三つの情報元に、多重構造ニューラルネットワークを用いて統合認識することで、下記の特徴をもつ車両認

識が可能になった。

- 1) 多様な背景への対応
- 2) 部分的に隠れた対象物への対応
- 3) 複数車両の同時検出, 車種判別

さらに, 高速道路, 一般道路, トンネル及び料金所の 4 種類の走行環境で収集された実データを用いて評価実験を行った。実験では最初に, ランダムに収集した認識用データを用いて提案手法と単一の識別器との比較実験を行い, MSNN を用いた提案手法が単一の識別器に比べて認識率が 10%以上向上できることを確認した。また, 二つのセンサ情報を統合する手法が一つのセンサ情報を用いたいずれの手法よりも高い認識率を得ることが確認でき, 車載センサ情報統合の有効性を示した。時系列処理の導入により, 平均認識率が 96.1%で, 一般道路でも認識率が 96.5%に大きく改善することが分かり, 本提案手法の有効性を確認した。

第 3 章では, 時系列道路画像から車両モデル認識のために車両フロント領域を高精度に検出する手法について論じた。車両モデルを認識するためには, 道路画像から車両を検出し, 正確に車両の特徴を取得する必要だが, 撮影が屋外で行われるために, 道路画像は背景が多様で, 環境変動に影響を受けやすいなどの問題がある。このような問題を解決するために, 自己対称テンプレートを用いて, 背景と環境変動にロバストでかつ高精度に車両フロント領域を検出する手法を提案した。さらに, 車両フロント領域の検出精度を評価するために, 時系列道路画像を用いた評価実験で, 車両フロント領域の平均検出率が 98%以上を得ることができ, 自動認識で必要な車両フロント領域の特徴を精度よく安定に取れることを確認した。

第 4 章では, 車両監視システムへの応用を目的として, 固定カメラで観測した道路画像から通過車両の形状特徴に基づいて, 車両モデルを認識する手法について論じた。最初に, 類似車両に対応するために類似車両モデルのグループを用いて, そのなかで最適な特徴を選択する多段階認識法を提案した。ここでは, 学習の段階で, 最初に認識対象のモデルごとに類似モデルのグループをあらかじめ生成し, 次にフロント画像を 4 つの部分に区分した領域単位に, グループ内のカテゴリを分離するに適した特徴の選別を行い, 特徴選別と識別を多段階で行うことで類似した車両モデルの認識精度の向上を可能にした。また, 部分的な差異を除外して, 照合性が高い部分領域の数が多いカテゴリを選択することによって, 環境の影響による車両フロント画像の部分的変化にロバストで高精度な車両モデルの認識が可能になった。さらに, 車両の切り出し精度が認識率に大きく影響することを見出し, その問題を回避するため, 対象の位置ずれに対応する部分空間を利用した車両モデル認識法を提案した。

最後に, 時系列道路画像を用いた評価実験では, フレーム単位の認識でも登録外車両を

92%棄却した上で、登録車両に対して 99%以上の認識率を得ることができ、従来困難であると考えられてきた車両モデルの詳細判別の実現性を確認した。従来法との比較では、EER が部分空間法単独の 12.0%に対して、多段階認識を導入した提案手法は 9.4%に改善でき、認識系の信頼度が向上していることが分かった。さらに、異なる環境で収集したデータに適用して、提案手法が有効に働いていることを確認した。

本研究では、晴天/曇天の昼間の時間帯で収集した道路画像を用いて評価実験を行った。しかし、ITS における実際の安全運転支援システムと車両監視システムにおいては、良天候だけではなく、人間が見えにくい悪天候や夜の環境での検証も重要となっている。実用化にあたっては、さらに多様な天候でのデータを用いた手法の検証が必要である。

5.2 本研究の展望

本研究では、安全運転支援システムや車両監視システムへの応用を目指し、車載センサの情報統合に基づく前方環境認識と路上カメラによる通過車両監視に関する研究開発を行った。

走行車両における前方環境認識においては、車載 SLR に画像センサを統合することによって、障害物の検出範囲を広げてかつ検出した車両の種別を認識することができ、現存 SLR の性能を維持しつつ、その性能を向上させることが可能となった。このシステムは、車載の SLR とカメラを統合することで、小型、高速、低コストが実現できるので車載適応性が高いシステムとは言える。また、本研究の成果は、前方車両の走行特性による車間距離の制御やドライバーの見落としを補うようなシステムへの適用は有効であると考えられる。

しかし、車載の SLR とカメラの統合は、霧、豪雨、雪など視界の悪い環境での適用が困難である。この問題に関しては、本研究の成果を活かして、悪天候でも有効なミリ波センサとの統合手法を構築していくことで、天候へのロバスト性強化が可能になると考える。また、本研究を ITS の運転支援システムへ活かすためには、多数の情報を利用した制御方法、情報提示方法などと組み合わせることで研究を進めていくことが重要と考える。

一方、車両監視システムにおいては、路上のカメラ情報から車両の形状特徴に基づいた車両モデルの多段階認識手法を提案し、類似車両モデルを含む通過車両のモデル認識が可能となった。これによって、ナンバープレートの偽装に強い捜査情報の提供や、設計時に類似した車両モデルの検索などにも応用が可能であると考えられる。さらに、本手法による車種モデル認識と、ナンバープレート認識に基づく登録情報との照合により偽装車両を発見し、犯罪抑止に役立つシステム構築の実現にも道を開いたと考えている。

謝辞

本研究を進めるにあたり、終始親身にご指導をくださった横浜国立大学大学院環境情報研究院・学府の後藤敏行教授に心から深く感謝の意を表し、厚くお礼を申し上げます。後藤教授とともに多角的な面から様々なご指導をいただきました影井清一郎教授に深く感謝いたします。

また、学位論文の審査とともに貴重なご意見をいただきました長尾智晴教授、田中裕久教授、有澤博教授、岡嶋克典助教授に感謝いたします。研究の進め方、論文の執筆にあたり、多くの助言をしていただきました影井研究室の孔昌一助手に深く感謝いたします。

本論文中の第2章の研究において、様々なご指摘やアドバイスを頂いた(株)日産自動車電子総合研究所の下村倫子博士をはじめ、研究データの収集等ご協力いただき、お世話になった(株)日産自動車電子総合研究所の方々に感謝いたします。また、本論文の第3章と第4章の研究において、共同研究を始めるきっかけを作ってください、研究を遂行する上で多大なサポートを頂きました(株)富士通研究所 画像・バイオメトリクス研究センターの佐々木繁センター長、画像パターン処理研究部の塩原守人部長に深く感謝いたします。また、本研究の一部は、環境情報研究院共同研究プロジェクト経費を受けて行われました。ここで、横浜国立大学環境情報研究院に深く感謝いたします。

研究室の先輩として様々な相談に乗っていただくとともに、的確な助言をくださった燕山典子博士（現：横浜国立大学）、竹上健博士（現：高崎商科大学）、朝倉輝博士（現：フジミック）に深く感謝いたします。データの収集にあたり、協力していただきました、大嶋千紘氏、神澤嘉範氏、談躍文氏、佐々木学氏に感謝いたします。また、ここに記してなくても、本研究にご助力くださった諸氏に感謝いたします。

また、平成13年度～平成18年度までの研究生活が順調に進んだ一因として文部科学省国費奨学金の支援があります。受給に際して全面的にサポートしていただきました横浜国立大学ならびに日本政府に感謝いたします。

最後に、日頃の研究に理解をもち筆者を支えてくれた家族に感謝します。

参考文献

- [1] “ITS Handbook”, 国土交通省, 2001.
- [2] <http://www.carmoni.com/manual/index.html>
- [3] 下村倫子:“AHSにおける車載センシング技術,”電気学会全国大会[5], pp. 2495-2498, 2000.
- [4] S. Carlsson and J. -O. Eklundh, “Object detection using model based prediction and motion parallax,” Proceeding of First European Conference on Computer Vision, pp.297-306, 1990.
- [5] 吉沢博一, 松田一朗, 伊東晋:“道路領域の予測に基づいた車載カメラ映像からの車両検出,” 電子情報通信学会技術報告, Vol.101, No.131, pp.21-26, 2001.
- [6] 小野口一則, 武田信之, 渡辺睦:“ステレオ画像の平面投影による移動障害物位置検出,” 電子情報通信学会論文誌(D-II), Vol.J81-D2, No.8, pp.1895-1903, 1998.
- [7] 室英夫, 下村倫子, 藤本和子, 沖孝彦:“センサフュージョンによる障害物検知技術”, 自動車技術, Vol.56, pp.40-43, 2002.
- [8] U. Hofmann, A. Rieder, E. D. Dickmanns, “Radar and vision data fusion for hybrid adaptive cruise control on highways,” Machine Vision and Applications, Vol.14, No.1, pp.42-49, 2003.
- [9] 下村倫子, 中村聡史, 後藤敏行, 藤本和巳, 室英夫:“車載カメラとレーザレーダフュージョンによる前方車両追跡”, 電気学会論文誌 C, Vol.123-C, No.8, pp.1427-1438, 2003.
- [10] N. Shimomura, K. Fujimoto, T. Oki, H. Muro, “A study on Discrimination of Forward Objects on the Road Using Laser Radar and a Camera,” T. IEE Japan, Vol.122-E, No.5, pp.261-266, 2002.
- [11] Y. Yamamura, M. Tabe, M. Kanehira, T. Murakami, “Development of an Adaptive Cruise Control System with Stop-and-Go Capability,” SAE, No.2001-01-0798, pp.37-43, 2001.
- [12] 内藤 貴志, 山田 啓一, 山本 新:“撮像位置にロバストなナンバープレート認識方法”, 電子情報通信学会論文誌 A, Vol.J81-A, No.4, pp.536-545, 1998.
- [13] 松崎吉紀, 小沢慎治:“単眼画像からの断面形状の認識による車種判別”, 電気学会論文誌 D, Vol.120-D, No.10, pp.1182-1188, 2000.
- [14] 大山宏, 村上伸一:“交通車両の車種自動認識法に関する一検討”, 画像電子学会, Vol.25, No.5, pp.486-494, 1996.

- [15] 長谷川修, 金出武雄: “一般道路映像中の移動物体の識別・色の推定と特定対象の検出”, 情報処理学会論文誌, Vol.44, No.7, pp.1795-1807, 2003.
- [16] 影澤政隆, 上野信一, 池内克史, 柏木寛: “並列画像処理ボード IMAP-vision を利用した赤外画像による車両認識システム”, 電子情報通信学会論文誌 A, Vol.J85-A, No.5, pp.597-605, 2002.
- [17] 山崎俊一, 山口泉, 加賀美公彦: “大型車の停止距離と制動初速度の算出自動車研究”, Vol.24, No.6, pp.11-18, 2002.
- [18] 松山隆司, 久野義徳, 井宮淳: “コンピュータビジョン: 技術評論と将来展望”, 新技術コミュニケーションズ, pp.177-192, 1998.
- [19] Robert Hecht-Nielsen, “Theory of the back propagation neural network,” Proceeding of the International Joint Conference on Neural Networks (IJCNN), Vol.1, pp.593-605, New York, 1989.
- [20] S. Watanabe, N. Pakvasa, “Subspace method of pattern recognition,” Proceeding of First International Joint Conference on Pattern Recognition, pp.2-32, 1973.
- [21] S. Ozawa, “Image Sensors in Traffic and Vehicle Control,” Technical Digest of the 18th Sensor Symposium 2001, Kawasaki, pp.355-358, 2001.
- [22] M-P. D. Jolly, S. Lakshmanan, A. K. Jain, “Vehicle Segmentation and Classification Using Deformable Templates,” IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.18, no.3, pp.293-308, 1996.
- [23] S. Gupte et al., “Detection and classification of vehicles,” IEEE Transactions on Intelligent Transportation Systems, Vol.3, No.1, pp.37-47, 2002.
- [24] T. Yoshida et al., “Vehicle Classification System with Local-Feature Based Algorithm Using CG Model Images,” IEICE Transactions on Information and Systems, Vol.E85-D, No.11, pp.1745-1752, 2002.
- [25] O. Hasegawa and T. Kanade, “Type classification, color estimation, and specific target detection of moving targets on public streets,” Machine Vision and Applications, Vol.16, No.2, pp.116-121, 2005.
- [26] M. Kagesawa, S. Ueno, K. Ikeuchi, H. Kashiwagi, “Recognizing Vehicles in Infrared Images Using IMAP Parallel Vision Board,” IEEE Transactions on Intelligent Transportation Systems, Vol.2, No.1, pp.10-17, 2001.
- [27] A. Shio, “Character recognition in scene images,” Proceedings CASA/SME AUTOFACT '89, pp.10-33 – 10-44, 1989.
- [28] V. S. Petrovic and T. F. Cootes, “Vehicle type recognition with match refinement,” Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference, Vol.3, pp.95-98, 2004.

本研究に関連する発表文献

公表論文

- [1] 鄭明燮, 後藤敏行, 下村倫子: “多重構造ニューラルネットワークによる車載センサ情報統合を用いた車両認識”, 映像情報メディア学会, Vol.59, No.4, pp.17-24, 2005.
- [2] 鄭明燮, 後藤敏行, 塩原守人: “道路通行画像を用いた車両モデルの多段階認識法”, 電気学会論文誌 E, Vol.126, No.8, pp.403-411, 2006.
- [3] Mingxie ZHENG, Toshiyuki GOTOH, Noriko SHIMOMURA : “Vehicle type Recognition Using the On-board Sensor Information Integration by the Multiple Structure Neural Network”, Review of Automotive Engineering Vol.26, No.2, pp.185-190, 2005.

国際会議論文

- [1] Mingxie Zheng, Toshiyuki Gotoh, Morito Shiohara, “A Hierarchical Algorithm for Vehicle Model Type Recognition on Time-sequence Road Images”, Proceedings of 2006 IEEE Intelligent Transportation Systems Conference, Toronto, Canada, Sep. 2006. (Accepted)

国内学会発表

- [1] 鄭明燮, 後藤敏行, 下村倫子: “多重構造ニューラルネットワークによる車載センサを用いた車種判別”, 2003年映像情報メディア学会冬季大会講演予稿集, 2003.
- [2] 鄭明燮, 後藤敏行, 下村倫子: “多重構造ニューラルネットワークによる車載センサ情報統合を用いた車両認識”, 2004年自動車技術会春季学術講演会前刷集, No.54-04, 2004.
- [3] 鄭明燮, 後藤敏行, 大嶋千紘: “時系列道路画像を用いた通行車両の車種モデル認識”, 2004年映像情報メディア学会冬季大会講演予稿集, 2004.
- [4] 鄭明燮, 後藤敏行, 塩原守人: “類似モデルのグループ化による通行車両の多段階認識法”, 2005年映像情報メディア学会冬季大会講演予稿集, 2005.

新聞報道など

- [1] “前方の車種判別, レーダと CCD 駆使車間距離最適に”, 日経産業新聞, 2004年1月21日(水), 朝刊, 2004.