


道路交通の監視・監視における画像処理と
その応用に関する研究

上田 裕次



報告番号 乙第 4957 号

①

道路交通の計測・監視における画像処理と
その応用に関する研究

上田 浩次

目次

1	まえがき	1
1.1	背景と目的および意義	1
1.2	本研究の立場とその特徴	2
1.3	本論文の概要	3
2	駐車車両検出アルゴリズム	6
2.1	はじめに	6
2.2	従来方式の問題点	7
2.3	画像処理方式	8
2.3.1	処理概要	8
2.3.2	遠近ひずみ成分の除去	8
2.3.3	車両の抽出	12
2.3.4	車両追跡による駐車、空有判定	15
2.3.5	車両の確定	19
2.3.6	処理方式のまとめ	20
2.4	画像処理方式の検証	20
2.4.1	検証システムと検証方法	20
2.4.2	検証結果とその検討	25
2.5	まとめ	27
3	背景画像差分を用いた移動車両の抽出	29
3.1	はじめに	29
3.2	従来方式の問題点	30
3.3	背景差分処理の改良	33
3.4	ハードウェア化の検討	38
3.5	方式の検証	40
3.5.1	車両が存在する場合のふるまい	40
3.5.2	SN 比向上効果	43
3.5.3	実用例	43
3.6	まとめ	45
4	ニューラルネットワークによる駐車状況の推定	47
4.1	はじめに	47
4.2	対象駐車場の形状と情報提供内容	48

4.3	部分領域とブロック全体との相関	50
4.4	線形回帰分析による駐車状況の推定	52
4.5	ニューラルネットワークによる駐車状況の推定	57
4.5.1	ニューラルネットワークの構成	57
4.5.2	中間層ユニット数および各種パラメータ	59
4.6	推定結果の比較	60
4.7	実用上の効果	67
4.8	まとめ	68
5	アナログ出力ニューラルネットワークによる駐車率の直接推定	69
5.1	はじめに	69
5.2	アナログ出力ニューラルネットワーク	70
5.3	シミュレーション実験	73
5.4	実測データを用いた検証結果	77
5.5	実用時の評価	82
5.6	まとめ	85
6	路面湿潤状況検出方式	87
6.1	はじめに	87
6.2	路面湿潤検出方式	88
6.3	画像処理方式	92
6.4	実験結果	97
6.5	まとめ	104
7	フィールド画像間情報を用いた車両走行速度の検出	106
7.1	はじめに	106
7.2	フレーム画像の構成	107
7.3	検出方式	107
7.4	実験	110
7.5	まとめ	111
8	あとがき	113
8.1	本研究の成果とまとめ	113
8.2	今後の課題	117
	付録	119
	謝辞	123
	参考文献	124

第1章

まえがき

1.1 背景と目的および意義

我が国におけるモータリゼーションは経済の発展や交通手段の変化など、様々な要因が重なり合って、急激な勢いで進展してきており、これにともない、交通事故による死傷者数についても年々増加し、昭和63年から平成6年末の7年間連続で1万人を越え、大きな社会問題となってきた。この状況に対し、国を挙げて取り組むべく、交通安全施設および道路整備事業が精力的に行われてきており、交通安全の拡充に努めている。この整備事業の中では、例えば道路情報表示板に代表されるように、前方の道路状況、交通情報を事前にドライバへ提供することで運転上の注意を促すシステムが整備されている。すなわち、道路管理側の交通安全に対する一つの施策としては、ドライバが安全で円滑、快適な運転を実現し得る情報を迅速、正確に収集、計測し、事前に提供するシステムの構築が挙げられる。このため、このような情報の収集、計測手段、方式に関する道路管理側からのニーズは非常に大きい。

これらの要求に対して、車両検出により交通量、車速等の情報を抽出する車両感知器として、道路上部、路側に設置した超音波センサによる超音波反射式車両感知器、道路内に埋設したコイル内の磁界の変化を抽出するループコイル式車両感知器等が古くから実用化され、交通流（交通量、車速等）計測用として現在も利用されている。また、これらの車両感知器を駐車場出入口に設置し、両者の検出結果から駐車状況を計測、表示し、点在する都市内の駐車場や高速道路のサービスエリア、パーキングエリアの利用状況をドライバへ事前に伝達することで利用の平準化を図るシステムにも応用されている。そのほか

にも、運転環境計測に関して、気象状態により大きく変化する走行路面の状況を計測し、ドライバの注意を促すシステムとして、路面上部に赤外光の投受光器を配置し、反射光量の差により路面状況を検出するセンサも実用化されている。しかし、これらの車両感知器は、計測原理から見れば、空間的に疎の計測となる。そのため、近年の交通事情から生じる道路幅員の拡充等の変遷に対し、情報の信頼度の維持、向上を考慮した細部の情報を得るためには、設置数の増加に頼らざるを得ない状況である。このような状況は路面状況の検出センサについても同様であり、計測範囲が局所的であることから、検出結果が周辺の路面状況とは異なるような問題が生じている。更に、駐車状況計測に関しては、24時間運用を基本とする高速道路のサービスエリア、パーキングエリアへの車両感知器の適用時において、出入口の検出誤差が累積して正確な状況計測が不能となるとともに、その誤差の補正および解消ができない等の問題が生じている。

このような中で、広範囲な計測空間を持つ交通状況センサとして、画像処理方式が考えられる。この方式を用いた計測は、2次元空間を対象にすることから、これまでのセンサと比べ、空間的に密な情報の収集が可能であるとともに、人間の視覚情報に置き換えて考え得ることから、より多くの情報収集に関する可能性を持つ。更に、監視映像との共有化も可能になり、その付加価値は大きく、この方式の検討に関する意義は大きい。本研究では、これらの現状、問題点を踏まえた上で、特に駐車状況抽出、路面状況抽出、車両走行速度抽出の計測項目に注目し、従来のセンサが達成できなかった広範囲な計測方式として、画像処理方式を検討するとともに、これまで問題となっていた屋外環境下での安定な計測の達成を目的として行った研究について述べる。更に、その方式の実フィールドにおける効果について示し、実用化への検討を行うとともに、知的計測方式へのアプローチについても検討するものである。

1.2 本研究の立場とその特徴

ここでは、本研究で注目している駐車状況抽出、路面状況抽出、車両走行速度抽出を中心として、画像処理方式を用いた研究例とその概略および問題点を以下に示す。そして、これら研究例に対する本研究の特徴についても示す。

まず、駐車状況計測に関して、これまでの研究状況を示す。駐車状況の計測では、広

範囲にわたる駐車車両検出が可能となることから、画像処理によるアプローチが行われてきている [1][2]。しかし、これらは、実験室等の安定した環境における結果であり、屋外輝度変動による影響が考慮されていないことや処理方式が複雑で実用化に課題を残している。本研究では、屋外輝度変動に対して影響されにくい車両抽出方式の検討および処理方式の実用化を考慮したハードウェアの検討もあわせて行う。また、計測範囲の車両検出および計数に留まらず、駐車場全体の駐車状況を検出する方式についても検討を行う。

次に、走行路面の状況抽出に関しては、路面に対する投光と受光の関係に注目した方式がこれまでに報告されている [3][4]。これらの研究例では、使用する光を規定し、自然光の影響を避けるようにしていることで共通している。しかし、これらの専用光の使用により検出範囲は局所となり、広範囲な計測が不可能となる。本研究では、自然光のもとで撮影された画像上から安定に、しかも広範囲な路面状況を抽出する画像処理方式について示す。なお、この路面状況の抽出に関して、画像処理を用いたアプローチについてはこれまでに例がない。

最後に、車両速度の計測に関しては、画像処理の応用が最も多く検討されてきた計測項目である。特に、交通流（交通量、車速）の計測として、その研究は古くからなされている [5]。現在、この項目では一部で試行 [6]、実用化 [7] の報告もされているが、基本方式について古くから変わっておらず、精度についても、従来の車両感知器には至っていないのが現状である。本研究では、これまでの画像処理方式とは全く異なり、空間周波数上での処理方式を基本とした画像処理方式について検討する。そして、精度上の検討についてもあわせて行う。

以上のように、本研究では、これまでの研究に対して、それぞれの視点で新しいアプローチを行っている。本論文では、これらの研究内容をまとめており、その概要については次節に示すとおりである。

1.3 本論文の概要

まず、第2章では、高速道路のサービスエリア、パーキングエリアのような広大な屋外駐車場を対象とした画像処理による駐車車両検出方式について示している。その基本となる駐車車両の検出方式としては、車両が移動体であることに注目し、時間方向にいつ

づく画像間の差分処理により車両の画像を抽出し、その画像の位置を逐次追跡する方式、すなわち、動画画像処理による駐車、出車の判断を行うものである。なお、実用上の検討を行うため、実際のパーキングエリアにおいて録画した映像にこの方式を適用した結果についても示している。

第3章では、第2章で用いた画像間の差分処理による車両抽出方式よりも更に安定に車両抽出を行うことのできる方式について述べている。すなわち、第2章で述べた差分処理の車両抽出画像が車両の移動速度に影響される点を検討し、その改良手法として、あらかじめ記憶した背景画像を屋外輝度の変化に対しダイナミックに追従させ、その背景画像と現在の画像間の差分を行う背景差分方式について示している。この方式では、従来行われてきた背景差分処理に比べ、より高いSN比で車両抽出像を得るためのアプローチを行い、更に、この方式を高速に実行するハードウェア化の方法についても検討している。また、実際の車両走行録画画像を用いた有用性の比較検討の結果についても示している。

第4章では、広大な駐車場の駐車状況判別方式として、ニューラルネットワークを適用した知的判別方式について示している。すなわち、広大な駐車場におけるセンサ（画像処理装置）の設置台数の削減がシステム構築上において重要な役割を持つことに注目し、部分的な駐車状況から全体の駐車状況を推定する知的処理方式について述べている。また、東名高速道路下り線足柄サービスエリアにおける収集データを用いたシミュレーション結果を示すとともに、第2章および第3章で述べた画像処理方式による装置とともに用いて、実用化した結果についても示している。

第5章では、駐車状況の基本となる駐車率を直接推定する方式に関して、ニューラルネットワークを適用した内容について述べている。すなわち、第4章のニューラルネットワークの出力形態がマクロ的な3ランク（「満車」、「混雑」、「空有」）へのカテゴリ化を行う機能を検討し、出力層の構成および出力関数に検討を加え、部分駐車率から全体駐車率を推定する方式について述べている。そして、この新しいニューラルネットワークの推定能力を検証するシミュレーションについて示すとともに、この結果をもとに東京外環道新倉パーキングエリアにおいて実用化した結果についても示している。

第6章では、道路交通に関わる計測の中でも、ドライバの運転環境の検出として、路面状況の抽出方式についてのアプローチを述べている。すなわち、頻発する路面状況とし

ての湿潤状況に注目し、光の反射の立場から、路面乾燥時を粗面による乱反射面、路面湿潤時を鏡面としてモデル化し、偏光成分画像を用いて自然光源のもとで両者を弁別する方式について述べている。また、本章ではこの方式を高速に実行するための画像処理上の検討および撮影画像内に混入する誤差成分についても言及し、その補正方法についても検討を加えている。この方式の効果について、実際の道路面に作成したシミュレーションサンプルによる検証および雨天時の路面への適用結果についても示している。

第7章では、道路交通状況計測の基本となる車両走行速度の検出に関する全く新しいアプローチについて述べている。すなわち、これまでの研究では、検討された車速検出方法がほとんどの場合、車両の追跡を基本とした処理であったものを、ここでは標準映像信号上のフィールド画像間に生ずるズレ成分がフレーム画像上では1/60秒間における対象車両の移動距離となることに注目し、その特徴量抽出を空間周波数上のフィルタ処理により行う方式について述べている。そして、この方式と従来の方式との比較検討の結果についても示している。

第8章はまとめであり、本研究の成果および残された課題を要約するとともに、実用化に関する将来の展望を述べた。

以上のように本論文では、種々の道路交通計測項目を対象にして、画像処理によるアルゴリズムと知的判断方式について提案し、その結果の実用化についても述べている。本論文で対象とした駐車場の駐車車両抽出、路面状況抽出、車速抽出のための画像処理に関しては、画像の持つ特長を大きく生かし、従来の車両感知器では成し得なかった広範囲な道路交通情報の計測手段を達成することができた。更に、駐車状況判別方式については、知的処理も含め、既に実用レベルに達しているものであり、足柄サービスエリアその他への設置に極めて良い結果を得ている。また、路面状況抽出、車速抽出についても、実際のフィールドでの画像を用いたシミュレーションによりその効果を確認しているとともに、ハードウェアへの展開についても一部に検討を加えており、実際の応用性を十分考慮したものになっている。

第2章

駐車車両検出アルゴリズム [53]

2.1 はじめに

近年、交通量の増加と都市域の過密が重なり合い、都市における駐車場不足が社会問題として取り上げられてきている。この対策として各地の主要都市では、各所に点在している駐車場の利用状況をラジオ放送、情報提供装置等により事前にドライバーへ伝達することで、利用効率の向上を計っている [8]。また、この問題は高速道路においても深刻であり、大都市近郊にある休憩施設（サービスエリア、パーキングエリア）では満車状態が頻発し、十分なサービス提供が受けられない状況となってきた [9]。特に、高速道路の休憩施設は疲労の回復、生理的要求の充足、自動車の機械的機能保持等、交通事故防止に重要な役割を果たすことから、その整備は急務とされてきており、利用台数の増加に合わせた駐車場の拡大が順次行われてきている [10]。また、高速道路上においても、休憩施設の利用状況（満車、混雑、空有等）を本線上のドライバーへ伝達することで、路線上に複数設置されている休憩施設の利用の平準化をはかるシステムが試行されている [11]。

このような状況の中、高速道路のサービスエリアやパーキングエリアのような広大な屋外駐車場を対象とし、情報提供の基本となる駐車場の利用状況を自動検出することを目的として、画像処理を用いた駐車車両検出アルゴリズムについて検討を行った。以下、この章では、従来行われてきた既存センサによる方法の問題点を整理し、その解決方法として、テレビカメラによって撮影された映像の画像処理を用いた駐車車両検出方式について詳細に述べる。また、実際のパーキングエリアにおいて録画した映像を用い、本方式の検証を行った結果についても示す。

2.2 従来方式の問題点

駐車場内の車両台数を管理する場合、図 2.1 のように車両入出部に車両センサを配置し、車両検出台数の結果から内部駐車台数を把握する方式が行われてきている [11]。この方式をサービスエリアおよびパーキングエリアに応用した場合、次のような問題点を生じる。

- (1) 一般の駐車場と異なり、24 時間連続で車両の入出があることから、車両センサ自体の誤差が内部の駐車台数に直接影響し、しかもその誤差台数が累積される。
- (2) 誤差の累積した状況を正確な値に校正する場合、安全走行のための休憩施設であることから、車両の入出規制はできず、校正自体も難しくなる。（校正中にも車両の入出がある。）

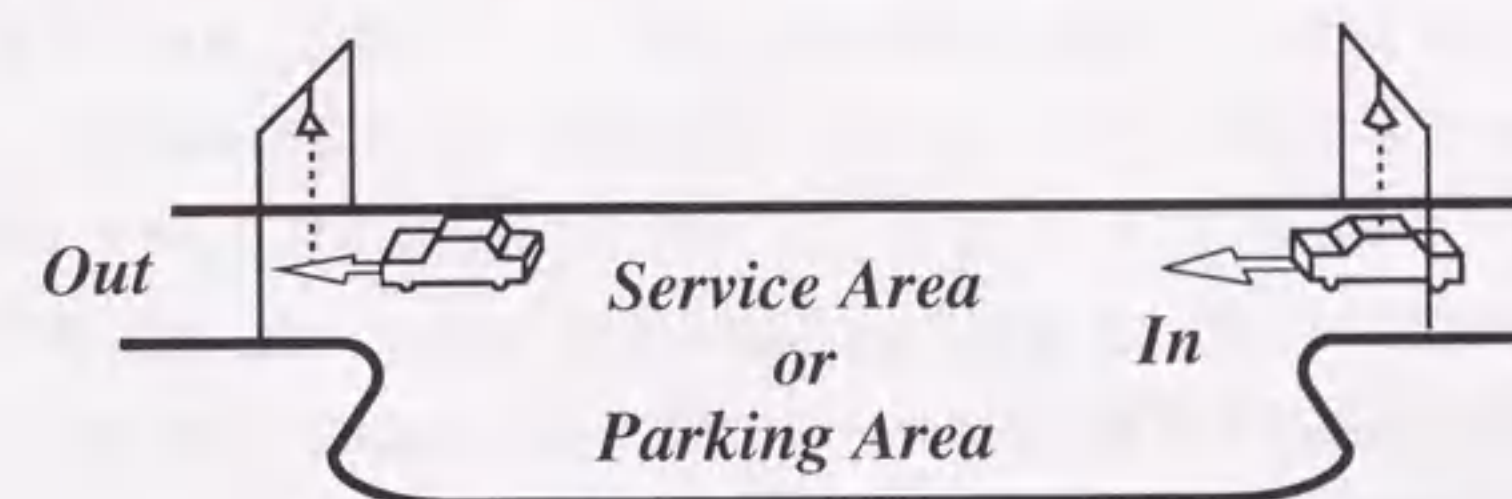


図 2.1: 従来方式

特に、この方式では時間の経過とともに誤差が累積されることが大きな問題となり、極端な場合では、内部状況に関係なく、表示が最大駐車台数を越えたり、その逆に駐車台数が負になることも起きている [11]。このことは、駐車場内部の状況の把握を間接的な検出方式に頼っていることに起因しており、この解決方法としては駐車領域を直接、しかも常時監視することが必要不可欠となる。この内部状況の監視を行うために、従来の車両センサ（超音波反射式、ループコイル式）[12]を用いた場合では、その検出範囲がスポット的であることから、各駐車マス毎にセンサを設置する必要があり、設置工事、美観上の問題をも生じる。そこで、空間的広がりを持った面情報を対象とする画像処理方式に注目した。この画像処理方式では、従来の車両センサに比べ、センサ 1 台当たりの検出範囲が飛

躍的に向上するとともに監視映像との共用も達成され、その付加価値は大きい。次節ではこの駐車車両抽出のための画像処理方式について詳細に述べる。

2.3 画像処理方式

2.3.1 処理概要

撮影画像上から駐車車両を検出するに当り、車両の特徴を抽出する必要がある。この場合、車両は人工構造体であることからその形状的特徴に注目することがまず考えられる。しかし、形状情報に注目した場合、テレビカメラの設置高さ、方向等の撮影条件に大きく影響され、今回のように広範囲な計測を要求される条件では、常時安定した形状情報が得られるとは限らない。そこで、車両が時間的に移動することに注目し、その移動情報を車両の特徴として抽出し、その動線を追跡することで、対象検出領域内の各駐車マスにおける駐車、出車を判定する方式を採用することとした。この場合、車両の抽出は移動する塊（移動成分）として得られることになり、形状情報に注目する場合と比べ、撮影条件において有利になると考えられる。結局、ここで採用する画像処理方式としては、(1) 画像上の移動成分抽出および、(2) 移動成分の追跡が主体となる。なお、撮影時に生じる遠近ひずみ成分の除去に関する前処理についても検討を行っており、この処理方法を含め、以下に詳細な処理内容を示す。

2.3.2 遠近ひずみ成分の除去

前述のように、テレビカメラにより撮影された映像から駐車車両の検出を行うため、検出領域は広範囲であることが要求される。このため、テレビカメラの設置条件としては、図 2.2(a) のように比較的高所から俯瞰撮影することが基本となる。この条件の下で得られた画像は、図 2.2(b) のように透視的な遠近ひずみおよび 2 次元回転成分を含んだものとなる。この画像上において各駐車マス毎の駐車管理を行う場合、処理のラスタースキャン動作（縦横順次動作）が困難となり、処理の煩雑が増し、処理時間の面で大きな障害となる。そこで、車両検出の前処理として、この遠近ひずみおよび回転成分の高速な補正手法について検討する。

図 2.3(a) は撮影された映像信号を AD 変換した後のフレームメモリ内の記録の一部分

を示し、横軸、縦軸はそれぞれ、メモリ上の画素に対する x, y 方向アドレスを示す。更に、図 2.3(b) は、図 2.3(a) のひずみ成分補正後の画像を書き込む画像メモリの内容である。なお、図 2.3(a) 同様、横軸、縦軸の M, N は画像メモリの x, y 方向アドレスを示す。また、図 2.3(a)、(b) において、○および●は各画素を示し、特に、●およびハッチング部分は駐車マスの白線部を疑似的に示している。

今、図 2.3(a) 内の bd を結んだ直線は駐車マスの白線部であり、透視的な遠近ひずみを受け、傾きを持った直線として表現されている。この図 2.3(a) 上の直線 bd を図 2.3(b) において傾きの無い直線 $b'd'$ として補正するにはこの点 $b(x_s, y_s)$ を補正始点とし、その直線 bd の傾き $(\Delta x, \Delta y)$ に沿って点 d まで読みだし、その読みだした画素の輝度データを画像メモリ図 2.3(b) 上へ順次書き込めば達成できる。この読みだし画素のメモリアドレス X, Y を求めるアルゴリズムについては次式のようなになる。


$$X = x_s + \Delta x \cdot i \quad (2.1)$$

$$Y = y_s + \Delta y \cdot i \quad (2.2)$$


$$i = 0, 1, 2, \dots, m$$

なお、この上式における m は、フレームメモリ上から読みだす最大画素数（サンプル数）を示し、画像メモリ上の M 方向に表現される大きさを制御するパラメータとなる。つまり、この m を任意に設定することで所望の大きさの画像を得ることができる。もちろん、このとき設定した m の値に応じて、読みだし間隔 $(\Delta x, \Delta y)$ を操作し、結果的に読みだす画素数が m 個となるように操作する必要がある、この $\Delta x, \Delta y$ については実数として扱うものとする。結局、この $(\Delta x, \Delta y)$ は読みだし間隔（サンプリング間隔）を制御する単位ベクトルとも言える。

元来、駐車マスを示す白線は平行で、その間は等間隔であるという幾何学的性質を持っている。そこで、まずこのアルゴリズムに従い、図 2.3(a) の直線 ab （白線部）に沿って補正始点およびそれに対応する直線 cd 上の点（終点）を設定し、式 (2.1), (2.2) に従って図 2.3(a) のフレームメモリから読みだし、順次 (b) の画像メモリへの書き込みを繰り返す。この処理により、指定された領域が画像メモリ上において回転成分の無い画像として表現できる。なお、ここで設定した始点、終点の対は画像メモリ上の N 方向に表現すべ




(a) カメラ設置位置



(b) 撮影画像

図 2.2: テレビカメラの設置位置とその見え方



(a) 原画像メモリ

(b) 補正結果メモリ

図 2.3: ひずみ補正のアルゴリズム

き画素数（本例では n 個）だけ必要となる。この設定に関しては、図 2.3(a) の点 a 、点 b および点 c 、点 d の間を n 等分することで仮想的な始点、終点を得ることができる。つまり、この (x_s, y_s) についても実数として扱うことになる。更に、この n 個の始点、終点間を結んだ直線に対して、各々の単位ベクトル $(\Delta x, \Delta y)$ の値を操作すれば、全てが M 方向に同一画素数（本例では m 個）とすることができ、結果的に遠近ひずみ成分が補正され図 2.3(b) のような方形状への補正が可能になる。ここで、本方式を一般化すると以下のようになる。

$$X = \text{INT}\{x_s(j) + \Delta x(j) \cdot i\} \quad (2.3)$$

$$Y = \text{INT}\{y_s(j) + \Delta y(j) \cdot i\} \quad (2.4)$$

$$i = 0, 1, 2, \dots, m$$

$$j = 0, 1, 2, \dots, n$$

ここで、 $x_s(j), y_s(j), \Delta x(j), \Delta y(j)$ はそれぞれ j 番目の補正始点および読みだし間隔（単位ベクトル）を示す。また、 INT は小数点以下を切り捨てる整数化関数である。

今、補正始点 $(x_s(j), y_s(j))$ および読みだし間隔 $(\Delta x(j), \Delta y(j))$ は上記アルゴリズムから、実数として扱っている。しかし、実際のメモリ上に構成される画素は整数アドレス部分に存在することから、式 (2.3), (2.4) では整数化処理 (INT) を行っている。このことから、式 (2.3), (2.4) において $\Delta x(j), \Delta y(j) < 1$ の場合、右辺の括弧内の演算結果が小数点以上に桁上げを生じない限りアドレスは変化せず同一画素が複数回読みだされることになり、それが画像メモリ上に順次書き込まれることから、画像メモリ上では見かけ上の画素数が増加し、拡大処理が達成される。また、この逆に $\Delta x(j), \Delta y(j) > 1$ の場合、画像メモリ上ではフレームメモリの画素を一定間隔で間引いた画像が得られ、結果的に縮小が達成できる。

この操作を検出対象となる駐車マス毎に行えば、画像メモリ上には注目する駐車マスすべてに対して遠近、回転ひずみが補正された画像が得られるとともに、すべて同じ大きさで扱うことができるようになる。しかも、ラスタスキャン動作の可能な方形状としても扱うことができるようになり、処理効率が大きく向上する。また、ここで示してきた処理方式では、検出対象領域のみを原画像から切り出して補正を行うことになり、画面全体を補正することと比較して、処理量も低減できる。更に、対象外の領域を除去する効果も合

わせて達成できる。なお、処理内容についても、読みだしメモリアドレスに対する加算演算のみで構成されることから、高速な補正処理が可能になる。

ここで述べてきた補正始点と読みだし間隔（単位ベクトル）の設定については、テレビカメラを固定して撮影することを前提にすれば、対象駐車領域は常に同一位置としてフレームメモリ上にサンプリングされるため、初期状態に上記のアルゴリズムに従った設定を行えば、以後は同一の設定値として扱って行くことが可能である。

ここで、実際のひずみ補正処理を施した画像を図 2.4 に示す。なお、図 2.4(b) の補正画像は、原画像 (a) の中の白線で囲まれた領域を補正したものである。




図 2.4: ひずみ補正結果

2.3.3 車両の抽出

画像情報を用いた対象領域内における駐車車両の抽出方法としては、車両の形状的特徴（ボンネット、ルーフ等）に注目した報告がすでにされている [1]。更に、車両の有無による輝度分散の変化に着目した報告もされている [2]。これらの研究例では、いずれも 1 枚の画像（静止画像）に対して処理を行っている点で共通している。しかし、停車車両の形状情報をもとに抽出処理を構成した場合、撮影条件（撮影高さ、方向等）により、注

目する形状部分が常時安定して得られるとは限らない。また、後者の研究例では、天候条件による輝度変化に影響されることが予想できる。そこで、撮影状態に左右されず、また比較的ゆっくりとした天候の変化（晴れ、曇り、雨、雪等）に対しても影響の少ない安定した車両の抽出を目的として、車両の形状情報を対象とするのではなく、移動情報（移動車両）を抽出し、その軌跡を追跡する手法を基本として処理を構成することとした。この移動車両の抽出に関しては、交通流をとらえる方法として過去にいくつかの研究例があるが、この中には、今回の目的のように停止している車両の検出を目的とした例は無い [13][14][5]。

車両の移動情報を抽出するに当たり、本方式では、時間的に隣接する 2 画像間の差分方式を採用した。この方式は式 (2.5) で示され、図 2.5 のようなアルゴリズムである。

$$s(t) = \{f(t-T) - f(t)\}^2 \quad (2.5)$$

式 (2.5) において、 T はサンプリング周期、 $f(t)$ は時刻 t におけるサンプリング画像、 $s(t)$ は差分画像である。

ここで、この処理結果を図 2.6 に示す。なお、この図 2.6 では、(a) で駐車していたトラック（駐車マスの上から 3 番目に駐車）が (b) のように出車する状況において、本処理を行った結果が (c) のようになり、出車中のトラックのみが抽出されている。この結果から分かるように、時間的に移動しない背景成分が処理画像上から除去され移動車両のみが抽出される。なお、この式 (2.5) では差分結果に対して 2 乗演算を行うことで、車両と背景間の輝度差により生じる差分極性を除去し、移動車両を一意的に扱うことを可能とするとともに、信号成分の強調効果もあわせて達成している。なお、この差分処理をハードウェア上で実行する場合、減算器と 2 乗変換テーブルのみの単純な構成で達成できることから、ビデオレートに追従する高速処理が可能となる。

この差分処理結果に対して車両抽出を行う場合、移動車両による輝度分布の変化に注目すれば、車両候補が容易に抽出できる。このため、車両形状を認識する方式と比較して撮影条件の設定（撮影高さ、方向）に関して有利になる。更に、天候の変化に対する撮影輝度の影響については、天候状態の変化時間が早くても数分（例えば、晴れから雨）程度であると予想すれば、式 (2.5) におけるサンプリング間隔 T を十分短く設定（例えば秒単位もしくはそれ以下）することで、原理的に天候の状態変化に対する影響を受けにくく





図 2.5: 差分処理のアルゴリズム



(a) 駐車時

(b) 出車時



(c) 差分処理結果

図 2.6: 差分処理結果

なる。

なお、ここで目的としている駐車車両検出については、式 (2.5) の差分処理をシーケンシャルに行うことで、移動車両を抽出し、その移動軌跡から各駐車マスの駐車、空有を判定するようにした。この詳細については、次節以後に述べる。このように、移動車両の抽出に関しては、時間的に隣接する 2 画面間の差分処理をシーケンシャルに行なっており、以後この処理をシーケンシャルサブトラクション (SSUB) と呼ぶこととする。

2.3.4 車両追跡による駐車、空有判定

本節では、SSUBの結果をもとに、車両追跡による各駐車マスの駐車、空有判定方法とその追跡パラメータの算出法および、この追跡パラメータによる効果について述べる。

各駐車マスの駐車、空有判定については、以下のように考える。

駐車判定： 通路部から駐車領域内への移動過程があった後移動車両成分が消滅。

空有判定： 駐車領域内から移動車両成分が発生し、通路部へ移動した。

このように、駐車、空有の判定については、各駐車マスと通路部を 2 次元座標上で管理し、時間的前後の車両の位置により移動ベクトルを求め、その移動軌跡を追跡することで達成する。ここで用いた車両追跡パラメータ (車両の位置) としては、SSUB から得られた移動成分の輝度値に対する重心位置を用いた。その演算は、次式のようなになる。また、この演算における各駐車マスとその二次元座標の関係を図 2.7 に示し、その演算方法を式 (2.6)~(2.9) にそれぞれ示す。

$$G(N, x) = \sum_{y=y_N}^{y_N+n_y(N)} F(x, y) \quad (2.6)$$

$$C_x(N) = \frac{\sum_{x=x_N}^{x_N+n_x(N)} (G(N, x) \cdot x)}{\sum_{x=x_N}^{x_N+n_x(N)} G(N, x)} \quad (2.7)$$

$$H(N, y) = \sum_{x=x_N}^{x_N+n_x(N)} F(x, y) \quad (2.8)$$

$$C_y(N) = \frac{a \sum_{y=y_N}^{y_N+n_y(N)} (H(N, y) \cdot y^a)}{\sum_{y=y_N}^{y_N+n_y(N)} H(N, y)} \quad (2.9)$$

- $G(N, x)$: 列 (x 方向) の投影加算値
 $H(N, y)$: 行 (y 方向) の投影加算値
 $F(x, y)$: $SSUB$ 画像における座標 (x, y) 画素の輝度値
 $C_x(N), C_y(N)$: x, y 方向重心座標位置
 a : 累乗の定数
 N : 駐車マスの番号 ($N = 0, 1, 2, \dots, n$)





図 2.7: 駐車マスと座標の関係




(a) 車両駐車 (b) 車両出車

図 2.8: 車両ベクトル追跡による判定

このように、重心座標位置については、検出対象となる各駐車マス毎に算出する。この重心座標位置に関する時間方向の動きを連続的に示したものが、図 2.8(a),(b) である。なお、この図中の×印は重心座標位置を示している。このように、車両の移動とともに重心位置が移動するため、その時間的前後の重心位置における座標関係から、車両の移動ベクトルを導き、そのベクトルの方向、および位置から上記判定方法に照合して駐車、空有を判定する。なお、これらの式 (2.6)~(2.9) を用いて重心位置を算出した結果については図 2.9(a) に示す。この画像中の白線は $SSUB$ の結果に対し、各駐車マスを明確にするため、補助的に書き込んだものであり、同様に、重心座標位置の演算結果についても×印で示した。また、図 2.9(b) は対象としたひずみ補正処理後の画像である。

しかし、この結果からわかるように、1 台の車両の移動に対して、複数の駐車マスで重心位置が算出されている。このため、実際に入出車を生じた駐車マスが確定できなくなる。このことは、3 次元空間の情報を 2 次元空間へ投影することから、車両の高さ、奥行き情報が表面情報として表現されるために生じる。この点を解決するため、式 (2.9) で示したように、 y 方向重心演算において、累乗位置重み a を加えた後、全体を正規化することで、重心位置を車両成分の下端部に移動させるように操作した。この処理により、図 2.9(a) においては、 y 方向重心位置が連続する駐車マスの下端部に各々算出されている。今、隣接駐車マスでは同時に別の車両の移動は発生しないと仮定すれば、このような重心位置の y 方向における連続性は同一の塊 (1 台の車両) として判断できる。また、その移

動車両の駐車位置は、この y 方向重心が途切れる境界で、しかも撮影方向から見て一番手前側となる。このようにして、本方式の重心演算により追跡処理の基本となる車両の位置情報および、駐車位置の確定に関する情報を抽出した。なお、ここで示した重心演算に関しても、加算および乗算が中心となっており、高速な演算が達成できる。



(a) 差分処理後の重心算出結果

(b) ひずみ補正画像

図 2.9: 車両の重心位置の算出結果

これまで述べてきたように、車両の駐車、空有の判定は、各駐車マスが検出単位となる。この駐車マス毎の判定を行うことで、次のような利点も生じる。今、検出対象領域内の一つの駐車マスにおいて車両が駐車した状況を想定する。また、このとき何等かの要因でこの車両を検出できず、判定誤差を生じたとする。この場合、駐車車両が検出できていないため、この駐車マスは実際とは異なり空有状態となっている。しかし、この駐車車両が再度その駐車マスから出車して行くことを検出したとすれば、空有状態から更に車両が出車したことになる。しかし、この駐車マスは、“駐車車両無し”と判断しているためその状態は変わらない。結局、この時点で当初生じた誤差は解消されたことになる。このように、各駐車マスを独立に管理していることで、各駐車マスで車両の入出が繰り返されるたびに誤差が修正される可能性を持つことから、発生誤差に対する自己修正機能を持っていると言える。

2.3.5 車両の確定

これまで述べてきたように、移動車両の抽出に関しては、SSUBにより達成し、車両追跡および駐車位置確定情報に関しては、重心演算結果を用いた。しかし、対象駐車領域中には、車両以外の移動物体として代表的に人の移動があり、単に SSUB だけでは、この人の成分も同時に抽出される。




図 2.10: 車両と人の幅の違い

そこで、人と車両を弁別する方式として、図 2.10 のように両者の幅方向の大きさの差に着目した。この弁別を行うためのパラメータとしては、重心点からの輝度の広がり、つまり統計的手法で分散に相当する値を用いた。この分散演算に関しては次式のようになる。

$$\sigma^2(N) = \frac{1}{n_x(N)} \sum_{x=x_N}^{x_N+n_x(N)} (x - C_x(N))^2 \cdot G(N, x) \quad (2.10)$$

N : 駐車マスの番号 ($N = 0, 1, 2, \dots, n$)

ここで、この座標と駐車マスの関係は前記同様図 2.7 に示した通りで、 $n_x(N)$ は N 番目の駐車マスの x 方向画素数、 $C_x(N)$ は式 (2.7) で求めた x 方向重心位置、 $G(N, x)$ は式 (2.6) で示した座標 x における N 番目の駐車マス内の x 方向投影加算値である。

ここで示したように、分散演算では前記の重心演算の途中結果が利用できるため演算の連続性、効率性が高い。更に、 x 方向投影加算（式 (2.6)）の一次元データに対して演算を行うため、車両確定パラメータの算出に関しても高速性が得られる。

2.3.6 処理方式のまとめ

以上、画像情報を用いた駐車車両検出方式について述べてきた。ここで、この方式の特徴についてまとめると次のようになる。

- (1) 移動車両検出に関して、 $SSUB$ を採用し、そのサンプリング周期を短くすることで、天候のゆっくりした変化による撮影輝度の変動に影響されにくく、しかも高速な方式を構築した。
- (2) 移動車両抽出とその投影加算に対するの重心位置の追跡を主体として処理を構成したことで、撮影条件等による車両形状の見え方に左右されにくい方式を構築できた。
- (3) 常時、各駐車マス毎の入出車を個別に監視しているため、その検出誤差に対しての自己修正機能を有する。
- (4) 各演算処理において、加減乗算を主体に構成したことで、ビデオレートに追従した高速処理が可能となるとともに、ハードウェア化も容易となる。

2.4 画像処理方式の検証

2.4.1 検証システムと検証方法

ここで提案したアルゴリズムの実用性を検証するため、シミュレーションシステムを試作した。なお、このシミュレーションシステムの構成図を図 2.11 に示す。このシミュレーションシステムはビデオ信号を量子化する A/D 変換器、前述した各種演算を実行する画像処理プロセッサおよびフレームメモリ等で構成され、画像の取り込み、演算等の指令

および車両追跡による駐車、空有の判定はパーソナルコンピュータで行っている。なお、撮像系、処理系の仕様を表 2.1、表 2.2 に各々示す。また、上記のように、画像の取り込みに始まり、各種画像処理および車両追跡のための重心演算を行う一連のアルゴリズムをこのシミュレーションシステムで実行した時の処理サイクルは約 1.2 秒程度であった。

検証は実際のパーキングエリアにおいてビデオ録画を行い、その録画された映像に対して処理を実行させ、その車両駐車、空有判定の正誤で評価した。今回録画を行った場所は、東名高速道路上り線の中井パーキングエリアで、1990 年 5 月 5 日、6 日、8 日、9 日のゴールデンウィークを含む 4 日間で行った。なお、このときの天候は 5 月 5 日が雨で 6 日、8 日及び 9 日が晴れの状態であった。また、録画時間帯は、いずれの日も昼食時で混雑する 11 時～13 時の 2 時間を対象とした。ここで、図 2.12 には、このパーキングエリアの形状と検出範囲を示しており、この中の検出駐車マスは、小型駐車領域 26 台、大型駐車領域 9 台の計 35 台分である。なお、図 2.13 には、この録画画像の一例を示す。このようにして録画したビデオ画像に対して、各駐車マスへの駐車、出車を正確に検出したか否かについて人による実測と提案したアルゴリズムによる判定結果との間で比較する。なお、今回の検証に当たっては、管理側から要望されている実用精度が 80% 以上であったことから、この精度を目標とした。

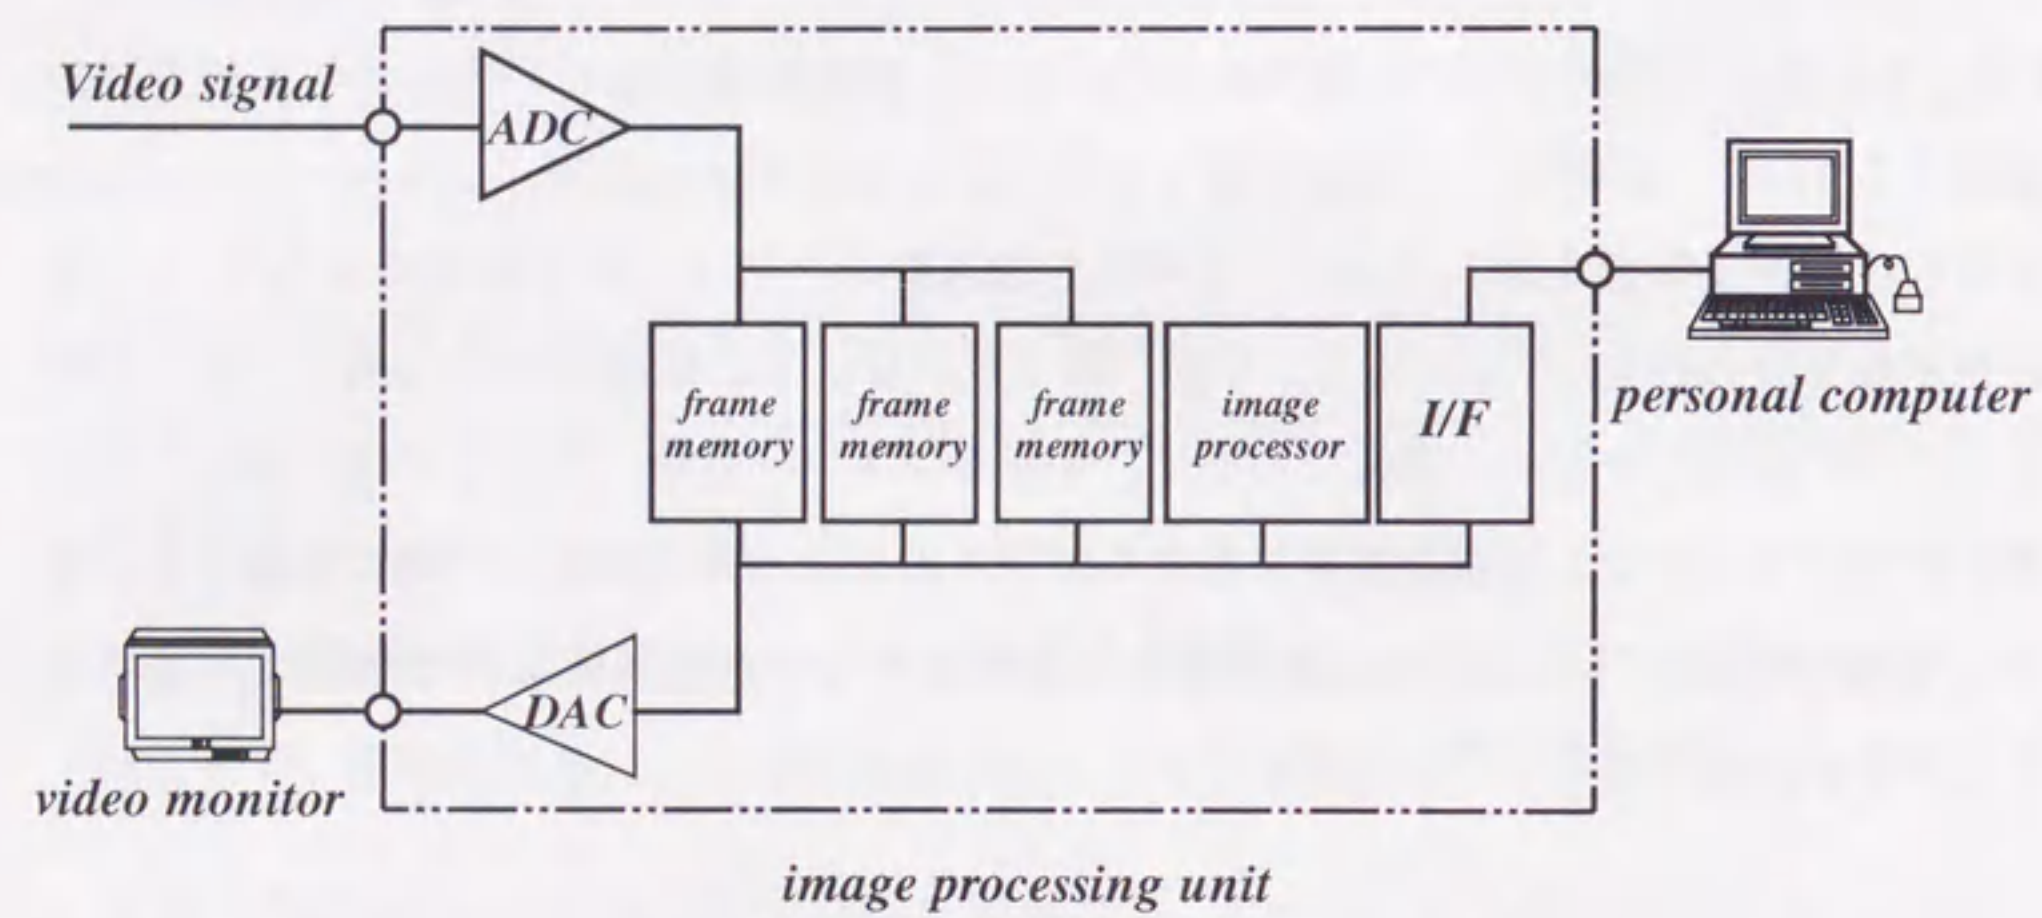


図 2.11: 試作システム

表 2.1: 撮像系の仕様

項目	内容
撮像素子	1/2 インチ CCD
カメラタイプ	B/W
走査方式	2:1 インターレス
解像度	水平 550TV 本 垂直 350TV 本
最低被写体照度	0.3lux
使用レンズ (焦点距離)	6mm アイリス (F1.2-F360)

表 2.2: 処理系の仕様

内容	項目
A/Dコンバータ	8bit
フレームメモリ	512× 512× 32bit
イメージプロセッサ	クロック:10MHz 2 画像間減算:26ms (512× 512× 32bit)
パソコン	cpu:80286 10MHz




図 2.12: 中井パーキングエリアの形状と検出領域



図 2.13: 撮影画像の例

2.4.2 検証結果とその検討

表 2.3 に、今回行った検証結果を示す。なお、表 2.3 における正解率は、次の通りである。

$$\text{正解率} = \frac{\text{全入出車台数} - \text{誤差台数}}{\text{全入出車台数}} \times 100 \quad [\%]$$

表 2.3: 検証結果

項目	日付				合計
	5月5日	5月6日	5月8日	5月9日	
全入出車台数	400	271	115	90	876
誤差台数	73	48	7	7	135
正解率	81.8%	82.3%	93.9%	92.2%	84.6%

ここで、全入出車台数とは、各駐車マスに対して駐車、出車を行った延べ車両台数である。

この結果から、4 日間の全入出車台数 876 台のうち、その状態判定の誤差台数は 135 台であった。この 4 日間の結果において、5 月 5 日、6 日の 2 日間はゴールデンウィークの後半であることから、5 月 8 日、9 日に比べ 2 倍以上の駐車、出車台数となっており、これに伴い、誤差台数も増加している。この誤差台数の増加について検討するため、誤差要因についてまとめた結果を表 2.4 に示す。なお、この表中における % 表示は誤差発生 の総数に対する相対的な割合を示す。また、この誤差要因は、判定の誤りを起こした時点で、車両検出から判定処理までの内部状態の推移を記録し、その推移を逆トレースする方法で導いた。以下に、この表 2.4 における誤差要因の詳細を示す。

表 2.4: 誤差要因

誤差要因	日付			
	5月5日	5月6日	5月8日	5月9日
車両輝度しきい値	18(24.6%)	2(4.4%)	1(14.3%)	1(14.3%)
車両移動速度	0(0.0%)	0(0.0%)	2(28.6%)	1(14.3%)
他車両の影響	33(45.2%)	21(46.7%)	3(42.8%)	3(42.8%)
複雑な移動軌跡	14(19.2%)	17(37.8%)	1(14.3%)	2(28.6%)
その他	8(11.0%)	5(11.1%)	0(0.0%)	0(0.0%)
合計	73	45	7	7

- (1) 車両輝度しきい値：車両かそれ以外かを大別するために、SSUBにより抽出される輝度成分に判定しきい値を設けており、このしきい値により車両として認識できなかった場合に生じる誤差。特に、アスファルトと車両間での輝度差が小さい場合に生じる。
- (2) 車両移動速度：処理速度と車両の移動速度の関係から追跡処理が追いつかない場合に生じる。
- (3) 他車両の影響：対象駐車マスに対して、車両の入出追跡を行っているあいだに他車両とのオクルージョンが重心位置の算出に影響を与え、移動方向等を誤る場合に生じる。
- (4) 複雑な移動軌跡：車両入出時に行う繰り返し等の動作により、移動軌跡自体が複雑になり生じる誤差。

この中で、(3)の他車両の影響についてはいずれの日付けにおいても、誤差台数の約半分程度を占めている。また、特に5月5日、6日に多くなっている。そこで、この誤差を生じる要因について検討する。この両日の状況としては、駐車場内部の車両台数が多いため、駐車マスへの入出時にその付近を移動する車両が存在する確率も多くなっている。このため、この両日で目立った誤差として現れてきた。この誤差は、判定アルゴリズム上において他の移動車両がおおよそ影響を考慮していないため生じている。具体的には、1台の車両が入出動作に入っている間にその隣接する駐車マスへ別の車両が入出を行った場合や同じように入出を行っている間にその駐車マスが接する共通路（図2.12ハッチング部分）を別の車両が通過した場合に誤差を生じた。いずれも、各車両の輝度成分が重なり合い、移動方向、存在位置等のパラメータである重心位置が変動的に変化するため、判定が確定できなくなったことによる。この誤差に対しては、他車両の存在で注目車両の位置情報がどのように変化していくかを十分検討する必要がある。特に、判定の基本方式が車両の動きを追跡することにある関係上、この通路部での移動過程についても情報として入力する必要があると考える。つまり、車両が入出車を行う場合には必ずこの通路部を通過してくることから、駐車マスの範囲内のみならず、通路の始点から駐車マスまでの移動情報、位置情報を追跡し、対象駐車マス近傍の複数車両を検出することで、この問題に対処

する考えであるが、その他にも移動後における駐車マス内の輝度状態等、各種情報を検討し、最善の解決方法を導く必要がある。

次に多い誤差成分として、(4)の複雑な移動軌跡によるものがある。今回の判定処理を構成するに当たり、我々が想定した車両駐車、出車時の移動軌跡は、前記図2.8のような比較的安定した状態である。このため、繰り返し等により、入車、出車の方向が連続的に変化することでその状態を追跡しきれず、判定誤差となって現れた。

以上のように誤差の要因について検討した結果を示した。ここで得られた結果から、特に、判定アルゴリズムの多様性について考慮する必要があると考える。しかし、この判定アルゴリズムの基本構成（車両抽出およびその追跡による駐車、出車判定）については、ここでの検証結果が示すように、876台の駐車、空有判定に対して、84.6%の正解率を得ることができ、目標とした80%以上の精度を達成できた。このことから、これまで述べてきた方式の実用上における十分な可能性を見出すことができた。

2.5 まとめ

画像処理を用いた駐車車両検出方式として、まず撮影時に生じるひずみ成分の補正を行い、ラスタースキャン動作を容易にした。更に、車両の駐車、出車検出方式としてSSUBを用いて動画像処理的に車両を抽出し、各駐車マス毎に算出したその移動成分の軌跡を追跡することで達成した。そして、各駐車マス毎の駐車管理により、誤差に対する自己修正機能をも達成した。また、この処理方式をシミュレーション装置で実現し、実際のパーキングエリアでの録画画像に対して検証を行った。この結果、876台の駐車、出車車両中135台の誤差（正解率84.6%）に納まり、当初の目標（正解率80%以上）を達成できた。この結果から、他の移動車両の影響および車両の複雑な移動軌跡等の判定アルゴリズムについて検討課題を残したものの、ここで基本とした車両追跡による駐車、出車計測の有用性が確認できた。特に、処理を構成するに当たり、天候の変化（晴れ、曇り、雨等）による撮影輝度変化に対しては、ほとんど影響を受けることなく、本処理で検討した内容がほぼ予想通りの結果となって表れた。更に、ほとんどの処理に対して、比較的容易で高速な演算（加減乗算、テーブル変換）で処理を構成しているため、処理方式のハードウェア化への可能性も十分であると考えられる。このハードウェア化の実現が可能になれば、本章で採

用したシミュレーション装置における処理サイクルが1.2秒程度要しているのに対して、ビデオオンライン処理への可能性をも十分考え得る。

第3章

背景画像差分を用いた移動車両の抽出 [51][52]

3.1 はじめに

第2章では、車両の特徴が移動体であることに注目し、時間的に連続する画像間の差分処理 (*SSUB*) により移動車両を抽出する方式について示し、この車両抽出画像の移動軌跡を追跡することで、駐車車両を検出するアルゴリズムを確立した。このように、車両の動きをダイナミックにとらえていく方法は、もちろん、交通流（車両速度、走行台数検出等）の基本アルゴリズムに成り得る。その意味では、交通分野における画像処理としては、このような動画画像処理が要求される検出項目も多く、ビデオオンライン計測に向けて必然的に処理速度の高い方式、システムが必要となる。このような観点から、*SSUB*は演算が単純であり、高速性は十分得られ、効果も高い。しかし、車両の形状が比較的単純な場合では、車両の移動速度とサンプリング周期の関係により車両の前端と後端部分が移動距離分だけ離れて抽出されるため、得られる車両成分の大きさが異なり、極端な場合では1台の車両が2台として処理画像上に現れるという問題点を持っている。第2章における検証結果のもとでは、車両移動に関する誤差が大半を占めていたために触れなかったものの、一部にこの問題点も含んでいる。また、駐車車両検出への応用時において、車両の移動速度が遅い場合では、同じ様な理由から、人等の移動と区別しきれないという問題点も生じている [16]。

そこで、この章では、このような問題点を原理的に解決し、しかも高速な動画画像処理に適する背景差分処理に注目する。この処理方式は、あらかじめ記憶した路面（背景）画像とその背景上に移動してきた車両を含んだ画像との差分により車両抽出を行うもので、

車両の移動速度に関係なく、単独の車両として抽出することが可能となる。また、記憶した背景画像を外界の輝度変化に対してダイナミックに追従、更新を行うことで屋外での適用も可能としている。しかし、これまで報告されている背景差分処理 [13][17] をそのまま採用した場合、初期状態の背景画像の取り込み時に問題点を含んでいた。

この章では、動画画像処理に適し、安定な車両抽出方法の確立を目的として、背景差分処理の持つ問題点、改善事項を詳細に検討し、移動車両抽出の観点に立った改良方式について示す。そして、この方式を高速に達成するために必要不可欠となるハードウェア化に関する検討を行い、その検討結果をもとにハードウェアを製作し、実際の録画画像に適用することで、その効果についても検証する。また、本方式の基本部分は、東名高速道路下り線足柄サービスエリアおよび東京外環道新倉パーキングエリアにおいて稼働をはじめている画像処理型駐車状況検出システムに組み込まれており、実用上の効果としてその状況についても示す。

3.2 従来方式の問題点

背景画像を路面輝度の変化に追従して常時ダイナミックに更新する方法として指数平均方式を用い、得られる背景画像とサンプリング画像間の差分を行うことにより車両のみを抽出し、交通流の認識等に応用している例が過去に報告されている [13][17]。このアルゴリズムは次式のとおりである。

$$\text{if } |f(x, y, t) - g(x, y, t - T)| \leq H \text{ then} \quad (3.1a)$$

$$g(x, y, t) = \alpha \cdot f(x, y, t) + (1 - \alpha) \cdot g(x, y, t - T) \quad (3.1b)$$

else

$$g(x, y, t) = g(x, y, t - T) \quad (3.1c)$$

この式 (3.1a)~式 (3.1c) のアルゴリズムにおいて、 f は時々刻々と変化する現時点の画像 (サンプリング画像) を示し、 g は背景画像を示す。また、 x, y は画像上の座標位置を示し、 t はそのサンプリング時刻、 T はサンプリング周期を示している。なお、 α は $0 < \alpha < 1$ の範囲の定数であり、 $(1 - \alpha)$ は背景画像 g における過去の情報の減衰係数を示すことになる。更に、 H は車両の存在による路面の輝度変化か、またはそれ以外の外界の輝度変化

によるものかを判定するためのしきい値である。

このように、各画素毎に行われた背景更新の結果画像 $g(t)$ とサンプリング画像 $f(t)$ から次式の差分演算を行うことで背景 (道路面) と輝度差の大きい車両を抽出する。

$$s(t) = f(t) - g(t) \quad (3.2)$$

このアルゴリズムでは背景画像を外界輝度の変化にダイナミックに追従させていくことが可能である。

しかし、このアルゴリズムを道路や駐車場内の車両抽出を目的として実行した場合、次のような問題点を生じる。

- (1) 初期状態で取り込まれる背景画像上に車両成分が存在する場合、その車両は更新されず残ったままとなる。
- (2) 車両抽出時に行われる道路輝度成分の無条件な差分により抽出成分の SN 比が低下する。

まず、(1) の問題点が生じる原因について検討する。このシステムを稼働させる初期状態において、背景画像の取り込みがまず行われる。この場合、対象となる道路や駐車場に全く車両が存在しない状態で行うことが理想的であるが、一般に開通、開場後にこの状態を期待することは困難に近い。例えば図 3.1 のように、背景画像上に車両が存在するときには式 (3.1a) で示したアルゴリズムのしきい値 H に対して、車両の存在による輝度変化が大きくなるため、背景上の車両は式 (3.1c) に従い更新されない。また、初期状態において、車両の存在しない状態を取り込むことができたとしても、予想外のシステム停止、一時的な視界不良の発生等を起こしたような場合には次の起動時にこの問題が大きく影響することになる。また、ここで挙げた問題点については別の報告 [18] においても同様な指摘がされているが、その改善はなされていない。

次に (2) の問題点について検討する。式 (3.2) に示したように、車両抽出に関しては、車両が存在するサンプリング画像から背景である道路の輝度成分が無条件で差し引かれる。このため、抽出される車両自体の輝度値は常に道路輝度だけ低下する。

このように、これまで報告されてきた背景差分処理においては実用時での問題点を持つ。次節ではこの問題点を解決するための改良方法について述べる。




図 3.1: 背景画像が更新できない場合の例

3.3 背景差分処理の改良

前述の二つの問題点の生じる過程を明確にするため、式 (3.1a)~式 (3.1c) を次式のよう書き換える。

$$\text{if } |f(t) - g(t-T)| \leq H \text{ then} \quad (3.3a)$$

$$g(t) = g(t-T) + \alpha\{f(t) - g(t-T)\} \quad (3.3b)$$

else

$$g(t) = g(t-T) \quad (3.3c)$$

ここで、 $f(t) - g(t-T) = h(t)$ と置くと式 (3.3a), 式 (3.3b) は次式のとおりとなる。

$$\text{if } |h(t)| \leq H \text{ then} \quad (3.4a)$$

$$g(t) = g(t-T) + \alpha \cdot h(t) \quad (3.4b)$$

この式において、式 (3.3c) は式 (3.4a) の関係を満足しない場合であり、式 (3.4b) 右辺の $\alpha \cdot h(t)$ が 0 であることと等価である。つまり、式 (3.4b) における $\alpha \cdot h(t)$ の結果を $h(t)$ の関数 $\beta\{h(t)\}$ として表現すれば、この式 (3.3a)~式 (3.3c) のアルゴリズムは単に式 (3.5) として表すことができる。なお、この $\beta\{h(t)\}$ は背景更新値を示し、図 3.2 のような不連続関数となる。

$$g(t) = g(t-T) + \beta\{h(t)\} \quad (3.5)$$

初期状態において背景画像上に車両が存在する場合には $h(t) < -H, h(t) > H$ の範囲となるため、式 (3.5) の背景更新値 $\beta\{h(t)\}$ は 0 となり、 $g(t)$ は初期状態の背景画像と同じになる。結局、その背景画像上の車両成分はそこに残ることになる。このことは、背景の扱いが連続した時間間隔内で輝度変化の小さい道路面のみ限定されているため、初期状態において道路面と輝度差の大きい車両部分も背景成分として取り込んだ場合は、車両部分の背景が更新されず常にこの車両成分が抽出されることになる。しかし、あくまでも移動車両の抽出を目的とすれば、背景を道路面のみ限定する必要はなく、道路面のような非車両部分に加え、時間的に輝度変化を起こさない車両成分（停車車両）も含めた




図 3.2: 従来方式の応答関数

ものに拡大することでこの背景画像内に存在する車両成分の更新が可能になる。そこで、図 3.3 のように $h(t) < -H, h(t) > H$ の範囲において背景に一定の修正が加わるように変更する。この操作により、背景画像上に車両が存在する条件においても、サンプリング画像との輝度差が小さくなるように一定輝度値 a または $-a$ だけ背景画像に加算され、背景画像の更新が行われる。この結果背景画像 $g(t)$ 上においては初期状態の車両の有無にかかわらず更新が可能となる。ただし、停車車両等も背景として扱われることから、この改良方式から得られる抽出成分は移動車両となる。このため、もし車両が移動後停車したと仮定すると、この停車車両が検出できないと考えられる。しかし、この方式では高い輝度変化に対しても背景の更新はサンプリング間隔毎に、 $\beta\{h(t)\} = a$ または $-a$ だけ徐々に行われていくため、もし車両が停車した場合でも、直ちにこの車両が消去されるのではなく、最終差分画像 $s(t)$ 上では、当初、車両が抽出された後、車両構成輝度が徐々に減少していくことになる。言い換えれば、このように輝度成分が減少していく場合は、車両が停車したかもしくは停車から移動へ状態が移行したことを示すことになる。つまり、この輝度変化特性に注目することで移動から停車への状態変化を得ることができ、停車状態検出の可能性を持っている。

ここで、再度図 3.3 に示した $\beta\{h(t)\}$ について検討する。この関数において、 H は車両と外界輝度変化を弁別するためのしきい値であることは前述した。この図から明らかなように、このしきい値 H を境界として応答関数が不連続となっている。實際上、この値 H 近傍はどちらも判断のつかないあいまいな領域であり、図 3.3 のような階段状のしきい値処理ではこの領域の安定性は得られないと考えられる。そこで、この関数についても、図 3.4 のようにしきい値近傍で連続的な応答を示す関数を用いるように改良した。なお本論文では、このしきい値 H における応答が極点となる \sin 関数を用いている。




図 3.3: 改良型応答関数




図 3.4: sin 関数を用いた改良型応答関数

最終的に、式 (3.4a), 式 (3.4b) は次式のようにになる。

$$g(t) = g(t-T) + \beta\{h(t)\} \quad (3.6)$$

$$-2H \geq h(t) \leq 2H \quad \beta\{h(t)\} = A \cdot \left\{ \frac{h(t)}{2H} \cdot \frac{\pi}{2} \right\}$$

$$-2H > h(t) \quad \beta\{h(t)\} = -a$$

$$h(t) > 2H \quad \beta\{h(t)\} = a$$

$$h(t) = f(t) - g(t-T) \quad (3.7)$$

ここで、 A はこの sin 関数の振幅であり、しきい値 H における $\beta\{h(t)\}$ の応答の大きさを示す。

次に、第 2 の問題点として、車両を抽出するためサンプリング画像 $f(t)$ と更新背景画像 $g(t)$ の差分を行う際、道路面および背景と判断された部分の輝度値が無条件に差し引かれることから、得られる車両成分の SN 比が低下する点を示した。この問題点を解決するため、式 (3.2) に対して、次式に示すような処理を加える。

$$s(t) = f(t) - g(t) \quad (3.8)$$

$$s(t) > C \quad s(t) = f(t)$$

$$s(t) < -D \quad s(t) = \text{inv}\{f(t)\}$$

$$-D \geq s(t) \leq C \quad s(t) = \text{abs}\{s(t)\}$$

ここで、 $C, -D$ は車両成分を弁別するためのしきい値であり、 inv は輝度の反転処理（輝度構成ビットの反転）、 abs は絶対値処理を示す。

式 (3.8) の条件式では、最終差分結果において一定値 C 以上の輝度変化を生じた場合は車両であると確定し、原画像の輝度成分をそのまま最終差分結果へ持ち込むようにしている。また、その逆に値 $-D$ より小さい場合にも輝度差としては大きな変化を示しており、この場合は原画像成分の反転成分を差分結果として置き換えるようにした。そして、それ以外では背景の微小な輝度変化であるとして絶対値を出力する。このため、路面に対して輝度変化の大きい車両成分は原画像および原画像の逆勾配の輝度情報がそのまま抽出される。このことから、抽出画像の SN 比の向上はもとより、車両の持つ輝度勾配情報を差分画像上でも保存しているため、以後の車両検出に関して有効な情報と成り得る。特

に、一般的なしきい値処理による線形な輝度変換と比べ、後に続く車両認識段階において原画像の輝度情報を取り扱う方式との融合等が可能となり、効果が大きいと考えられる。

3.4 ハードウェア化の検討

ビデオオンライン計測を目指した動画処理を達成するためには処理方式の高速化と合わせて高速ハードウェアの実現が必要不可欠である。そこで、この節では上記方式をより高速に実現するハードウェアの構成について検討する。

式 (3.6) および式 (3.8) で示される改良方式において、式 (3.6) を実行する場合、 $h(t)$ の値に従い、関数演算の有無が決定される。このため、演算が固定できず、処理パイプラインの乱れを引き起こすことになる。また、関数演算についても処理速度に大きな影響を及ぼす。そこで、この部分の簡略化について検討する。

今、式 (3.6) の $\beta\{h(t)\}$ は $h(t)$ の値によりその応答が決定され、 $h(t)$ のダイナミックレンジは既知であることから、入力を $h(t)$ としたテーブルとして見る事ができる。この部分をテーブル化した場合、全ての入力に対する応答値をあらかじめ記憶させるため、複雑な関数演算は単なるテーブルメモリのアクセスに置き換えられる。このため、ハードウェアの簡易化、高速化をもたらし、絶大な効果を得る。また、演算の有無を選択的に行う判断処理も必要なく、処理単位が統一できるため、処理パイプラインが容易に構成できる。更に、このテーブル化は任意の関数の選択を可能とし、設定の自由度が高くハードウェアの変更なしで種々の要請（関数自体の変更、しきい値変更等）に対応することができる。関数のテーブル化自体は多くの分野で行われているが、特にこの分野でハードウェアの実現を意識した展開がなされた例はこれまでに報告されていないのが現状である。本方式の実行に当たっては、式 (3.8) の条件部分も考慮しなければならない。式 (3.8) では最終差分結果 $s(t)$ の値により、3種類の条件判断とその各々に対する置き換えが必要である。この条件判断は $s(t)$ の値により、演算の性質が異なるものではなく、あらかじめ用意された3種類の出力値の中の一つを選択するように考えることができる。このため、ハードウェア上の負荷としては、3入力1出力のマルチプレクサで構成できることから、条件判断の存在によるパイプライン処理の乱れは生じない。

以上のような検討の結果、最終的なハードウェア構成は図 3.5のハードウェアブロック

図のようになり、各演算ステージを容易にパイプライン構成とすることができる。このように、全てが高速演算の可能な加減算とテーブル変換で構成され、パイプライン化も容易となり、高速ハードウェアの実現が可能である。




図 3.5: 改良方式を用いたハードウェアブロック図

3.5 方式の検証

これまで述べてきた方式の効果を検証するため、屋外における車両走行状態をビデオテープに録画し、以下の各項目について評価した。なお、この検証を行うに当たっては、図 3.5 に示すハードウェアブロック図に従い試作したものを用いて行った。また、その動作仕様については表 3.1 のとおりである。

表 3.1: ハードウェア仕様

項目	仕様
演算方式	パイプライン方式
基本クロック	10MHz
処理速度	(背景差分処理) 1 画素当たり 100ns 1 画像当たり 26.2ms
メモリ構成	入力用 $f(t)$: $512 \times 512 \times 8bit$ 背景用 $g(t)$: $512 \times 512 \times 8bit$ 結果用 $s(t)$: $512 \times 512 \times 8bit$
接続バス	マルチバス (IEEE796)

3.5.1 車両が存在する場合のふるまい

図 3.6 は初期状態において背景に車両が存在する場合のサンプリング画像 (a) と背景画像 (b) を示している。また、(c) は最終差分結果を示し、(d) は背景画像上の白線部分のプロファイルを示す。更に、(I)~(IV) は時間経過方向を示しており、(I) は背景画像をサンプリングした初期状態を示す。また、(II)~(IV) はその後上記の処理が順次施された状態である。このように、サンプリング画像上に道路面が映し出されると背景画像上の車両と道路の輝度差が大きくなり従来の方式ではこの車両成分が背景画像上に残っていたものの、本方式では、このような状態においても背景の更新が徐々に行われていく。そして、最終的に (IV) においては、背景画像上から車両成分はほとんど消え、その時点の道路面の状態に近くなっている。また、この逆に車両が移動状態から停車状態に移行した場合を図 3.7 に示す。

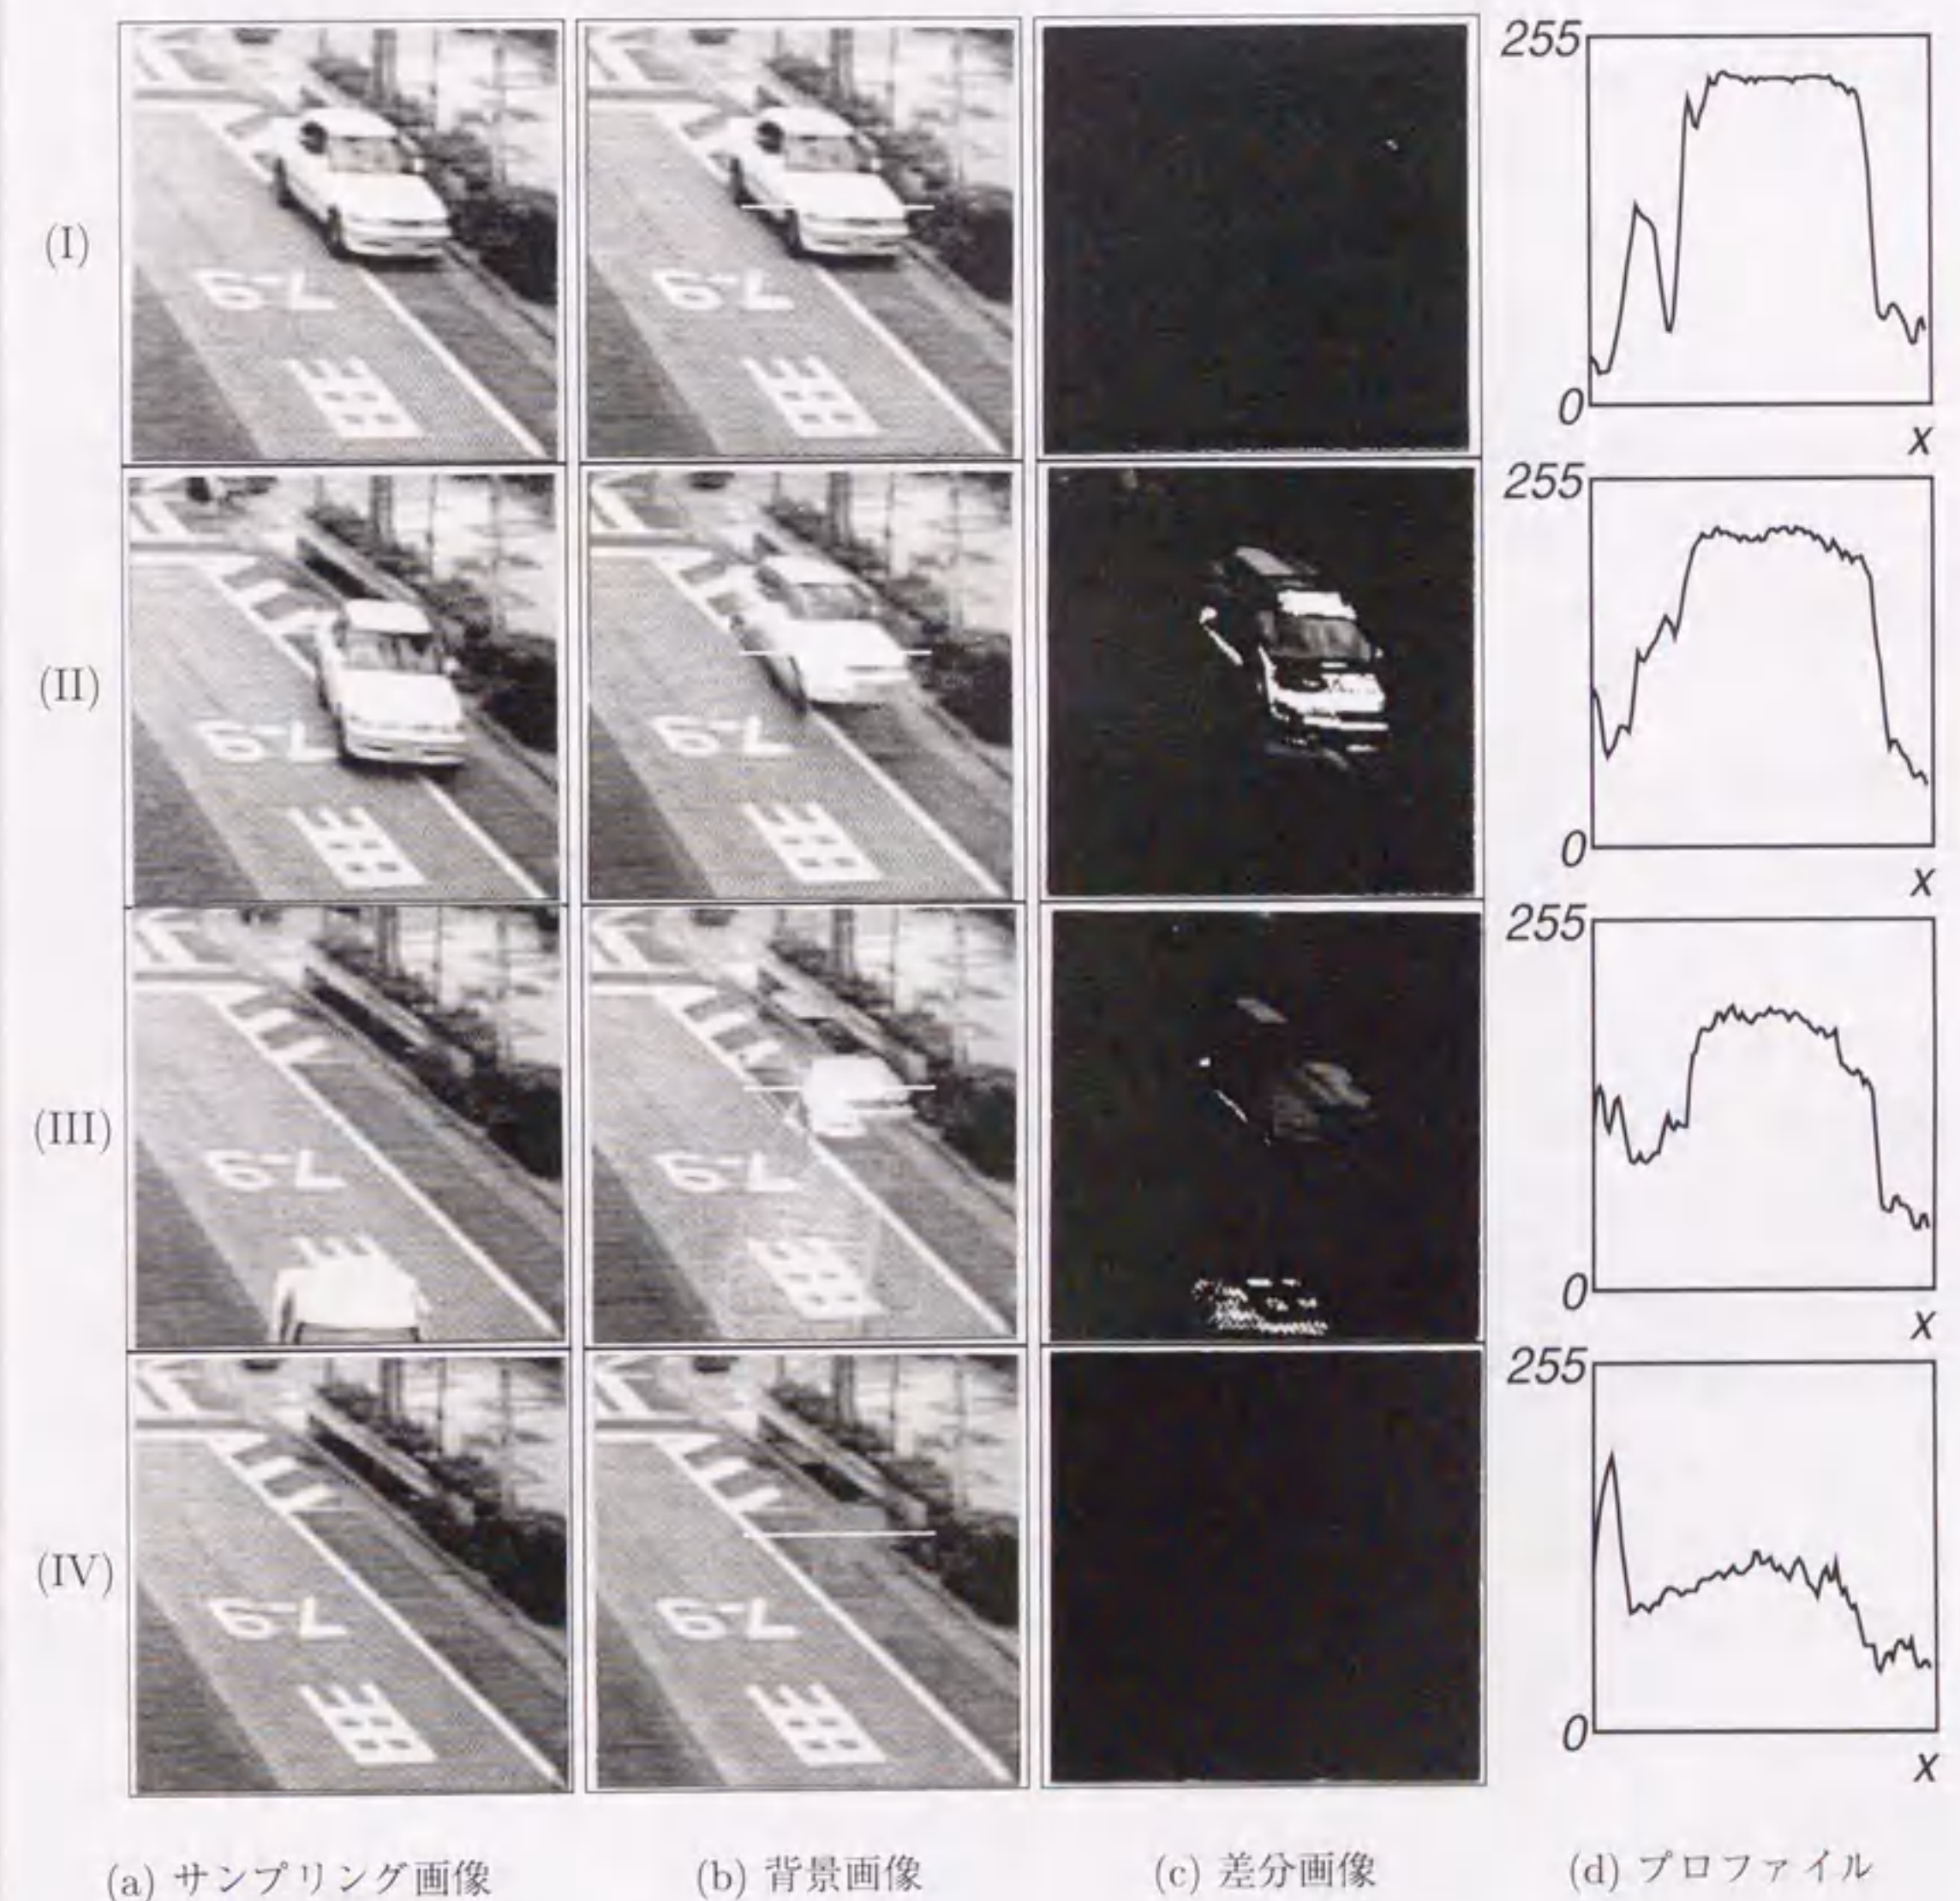


図 3.6: 背景画像の自動更新状況




図 3.7: 車両停車時の処理例

この図 3.7において (a) は最終差分結果を示し、(b) は (a) の白線上におけるプロファイルを示す。このように、最終差分画像上の抽出車両は徐々に消滅していく。つまり、車両停車時には、その輝度成分がサンプリング周期とともに徐々に減少するという特徴的なふるまいを示し、この輝度変化特性を利用すれば、移動車両のみならず停車車両の検出が可能であることがわかる。


3.5.2 SN 比向上効果

図 3.8(a) は対象とした原画像を示しており、(b), (c) は各々、今回提案した方式を用いた移動車両抽出画像と従来方式による抽出画像を示している。そして、(g) は (b), (c) の車両抽出画像上における白線部分のプロファイルであり、このプロファイル中の実線は (b) を、破線は (c) の輝度状態を示す。


この図 3.8(b) と (c) の抽出画像を比較して明らかなように、(b) における抽出車両の輝度成分が (c) に比べ全体に明るくなっていることがはっきりと分かる。更に、輝度値を比べてみると、原画像 (a) における車体部分の輝度値はほぼ 240 程度で、(b) ではこの原画像成分がそのまま差分画像上に持ち込まれているため同様にほぼ 240 の輝度値となっており、原画像の輝度成分、勾配が差分画像上でも保存されている。また、(c) ではこの輝度値が 100 程度であり、このときの道路面の平均輝度値は 140 前後であることから、ここで提案してきたように本方式では、ほぼ道路面の輝度分だけ SN 比が向上している。このため、以後の車両認識時に行われるしきい値処理、あるいは車両輝度情報を用いた認識処理において有用な情報と成り得る。同様に、(d) から (f) は黒い車両について行った結果であり、(h) は (e), (f) 上のプロファイルを示している。この結果においても、式 (3.8) の処理により、路面に比べてより暗い部分が強調され、陰の部分も含めて明確な車両抽出像が得られている。

3.5.3 実用例


これまで述べてきた処理アルゴリズムの基本部分とそのハードウェアは、1991 年 6 月に設置した東名高速道路下り線足柄サービスエリアおよび 1994 年 3 月に設置した東京外環道新倉パーキングエリアにおける駐車状況検出システムに適用されて稼動を始めてい



(a) 原画像 (b) 提案方式 (c) 従来方式



(d) 原画像 (e) 提案方式 (f) 従来方式



(g) (b),(c)のプロファイル (h) (e),(f)のプロファイル

図 3.8: 提案方式と従来方式の比較

る。この方式を含めたシステム上の評価については本システムを導入した管理者側の立場で発表 [19][20][51] されている。また、これまでの期間、システム精度上の問題も無く順調に稼動してきている。このように、実際のシステムに対する適用上においても特に大きな問題がなく動作しており、その意味からも本方式の実用上の効果が実証されている。なお、参考のために、この導入システムの概略構成およびこのシステムにおける画像処理装置の構成図を付録 A~C に示し、付録 D には足柄サービスエリアのシステム（付録 A）上の画像処理装置に関する駐車車両認識精度の検証結果を示す。

3.6 まとめ

移動車両の抽出方式として画像間差分処理の中でも背景の自動更新機能を有した背景差分処理に注目し、これまで行われてきた方式に対してその実用時に生じる問題点を検討し、その改良方式について述べるとともにビデオ映像を用いてその方式の検証を行った。

この章で述べてきた方式では、移動車両の抽出に主眼を置き、更新される背景の扱いを道路面のみでなく停車車両も含めたものとして拡大することで、初期状態において背景画像を取り込む際、車両成分が混入した場合においてもその車両成分が背景上に残ることではなく、背景は常に現時点の背景状態に近づくように更新される。また、得られる車両抽出結果に対しても、車両成分から背景成分が無条件で差し引かれる背景差分方式を改良し、車両成分がそのまま抽出されるようにすることで、抽出対象の SN 比の向上を達成した。更に、本方式では車両の停車についても抽出された車両輝度成分が直ちに消去することではなく、一定輝度ずつ徐々に減少していくという特徴的なふるまいを示すことになり、この輝度特性を用いて停車車両検出が可能となることについても示した。また、実用上不可欠であるハードウェア化についても、関数演算のテーブル化により、目的に合った自由な関数のあてはめ、処理の高速化、パイプライン化を達成し、ビデオレートに追従したハードウェアの実現を可能にした。そして、本方式を適用した足柄サービスエリアおよび新倉パーキングエリアでの駐車状況判別システムの稼動状況を実際の効果として示した。

しかし、ここで述べてきた方式により車両抽出に関する産業応用上の実用化は可能となったが、完全な車両抽出、認識を要求する場合、全ての問題点が解決されているわけではなく、車両の重なり、雲の流れによる輝度変化、夜間状況での処理方法等ここでは示さ

れていない問題もある。これらの問題点に対して別に検討 [21][22] を重ねてきているが、これらの問題点は処理の基本となる車両抽出と独立な関係ではない。その意味では、この章で確立した移動車両抽出方式を基本として、これらの未解決な問題点に対し新たな検討を加える必要がある。

第4章

ニューラルネットワークによる駐車状況の推定^[54]

4.1 はじめに

第2章で述べたように、高速道路のサービスエリアおよびパーキングエリアの整備として、利用台数の増加にあわせた駐車場の拡大が順次進んでおり、その許容台数は数百台規模に膨れ上がってきている場所もある。このような駐車場を対象とした場合、第2章および第3章で述べたような画像処理式を用いたとしても全駐車スペースを包括するには設備規模が極めて大きなものとなる。ただし、駐車場内部における細部の誘導を行う場合を除き、利用者に提供する情報内容は「満車」、「混雑」、「空有」のような全体の駐車状況をマクロ的にとらえた情報 [9], [8] であり、この程度の情報でも十分な状況把握が可能であるとともにも実用上の効果も得ている。このため、状況認識についても、全駐車スペースの車両の有無を漏れなく検出することを前提とするよりは、マクロ的な認識法に注目した方がセンサ台数の削減が可能となり、システム構築上において有利であると考えられる。

この認識方法に関するアプローチとして、駐車場内の部分領域の駐車率（全駐車スペースの中の一部における駐車率で、以後部分駐車率と呼ぶ）と全体駐車率との相関に注目し、線形回帰分析により部分駐車率から全体駐車率を推定する試みがなされた [11]。しかし、この利用状況は常に一定の線形関係を保つとは考えにくく、むしろ非線形な関係であると予想できる。そこで、この章では、この非線形推定問題を部分駐車率の情報をもとにした3つのカテゴリー（満車、混雑、空有）への分類としてとらえ、この推定方法として

ニューラルネットワーク（以後、NNと呼ぶ）を適用した新たな方式について示す。

NNは多層パーセプトロン（MLP）にバックプロパゲーション（BP）学習則 [23] を適用したモデルが実用的モデルとして注目されており、文字認識 [24] や音声認識 [25]、画像認識 [26] 等認識対象が非線形な性質を持つような系において積極的な応用研究が行われており、その能力、可能性を見いだすためにも種々の分野における、より多くの応用成果が望まれている。特に、NNは変換規則が不明で非線形な対象に対しても、与えられる教師信号をもとにニューロン素子間の結合強度（重み）を自動調整（学習）することで、所望の変換、認識結果を得るとともに、教師信号に含まれない入力に対しても、妥当な出力が得られる（汎化）能力を持つ点に大きな特徴を持つ。この NN を次のような機能として、マクロ的駐車状況推定に適用した。

学習能力：部分駐車率（入力）から全体駐車状況（出力）を推定する際、その変換則は複雑な関係であると予想されるが、与えられた教師データを学習することで非線形な入出力関係の自動抽出および駐車場固有の変換機能を NN 内部に構築する。

汎化能力：学習に用いたデータ以外に生じる部分駐車率の変化に対しても、適切な出力が期待できる。

この章では、駐車状況推定に対して NN を適用した場合の効果について検討することを目的とする。以下、NN の構成方法について詳細に述べ、実際のフィールドで収集した計測データを用いて、従来検討された線形回帰分析による結果との比較を行い、NN の適用における効果を検証する。また、ここで示す方式は第 2 章および第 3 章の基本方式を用いた画像処理型駐車車両検出装置（以後、単に検出装置と呼ぶ）[21] とともに東名高速道路下り線足柄サービスエリアにおいて既に設置されており、その実用時の状況についても述べる。

4.2 対象駐車場の形状と情報提供内容

今回対象とした駐車場は、東名高速道路下り線足柄サービスエリアで図 4.1 のような形状である。このサービスエリアは 4 つの大きな駐車ブロック（図 4.1 中、A～D）に分かれており、全駐車許容台数は小型車換算（大型車は小型 2 台分）で 604 台の巨大な駐車

場である。また、図 4.1 中のハッチング部分（②～⑮）は既に導入された検出装置 [27] の監視範囲であり、パーセント表示は各駐車ブロックにおける監視率を示している。更に、図 4.1 中①、⑮はそれぞれ出入口の通過台数を検出する検出装置であり、I～IV の矢印のように各方向の通過台数を計数している。




図 4.1: 足柄サービスエリアの形状

この駐車場内部における情報提供内容としては、広大な駐車場での混乱を防止するため、A～D の駐車ブロック入口部に「満車」、「混雑」、「空有」の 3 ランクによる表示提供が行われることになった。つまり、各駐車ブロックを各々一つの駐車場として扱い、情報提供が行われることになる。

そこで、以後の検討に当たっては、各駐車ブロック毎の駐車状況をそのブロックに属する部分駐車率から推定するように考える。また、出入口の通過台数についても、駐車状況と深い関係を持つことが十分予想できるため、部分駐車率と合わせて推定情報として利用する。

4.3 部分領域とブロック全体との相関

部分領域と全体との関係を導くに当たり、まず基本となるデータの収集を行った。データの収集は1991年5月1日、2日、6日の3日間に渡り、人が全駐車スペースの車両有無および出入口の通過台数を10分間隔で計数した。この計数データからブロック毎の全体駐車率とそのブロック内に属する部分駐車率（以後、部分駐車率と呼ぶ）を算出する。また、出入口の①、⑥においては10分間の最大通過台数を75台に規定し、その最大通過台数に対する割合（以後入・出車率と呼ぶ）として規格化した。なお、各ブロックにおける入・出車率の算出は、Aブロックが図4.1中I、IIIの方向の計数データを利用し、B、C、Dブロックでは共通でII、IVの計数データを用いることとした。この一例として、Aブロックにおける計数データの一部を表4.1に示す。

このようにして得た計数データをもとに、各ブロック毎の全体駐車率と部分駐車率との関係を調べるため、両者の相関係数を式(4.1)に従って算出した。その結果が表4.2である。

$$R = \frac{\sum_{i=1}^k (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^k (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^k (y_i - \bar{y})^2}} \quad (4.1)$$

- x_i : 10分間隔の部分駐車率
- y_i : 対象部分監視領域の属するブロックにおける10分間隔の全体駐車率
- \bar{x}, \bar{y} : 部分駐車率、全体駐車率各々の平均
- k : 計数データ数
- R : 部分領域毎の相関係数

なお、表4.2の結果は調査日3日間のうち5月1日のデータのみを用いて行っている。

この表4.2から、A、C、Dブロック内の部分領域との相関係数は0.7以上となり、かなり強い相関を示しているのに対して、Bブロックでは相関の弱い部分領域が存在している。実際のシステムにおいては、検出装置の設置位置は制限を受けることが十分考えられ、必ずしも相関の強い部分領域を選択することは難しく、このような状態は十分考慮に入れておく必要がある。また、一般的に考えれば、初期台数からの入・出車台数の差がその時点の内部台数として表現できることから、入・出車率と全体駐車率との相関は強くなることが予想できる。しかし、表4.2から明らかなように、最高の相関値を示しているA

表 4.1: 計数データの一部 (A ブロック)

Aブロック全駐車台数 138 台
 部分領域全駐車台数 Nb.2 : 14台 Nb.3 : 18台 Nb.4 : 16台 Nb.5 : 22台
 Nb.1,16 : 最大通過台数 75台
 1991年5月1日

部分領域 時間	Nb.1		Nb.2		Nb.3		Nb.4		Nb.5		Nb.16		全体 駐車 台数	全体 駐車 率
	入車 台数	入車率	駐車 台数	部分 駐車率	駐車 台数	部分 駐車率	駐車 台数	部分 駐車率	駐車 台数	部分 駐車率	出車 台数	出車率	全体 駐車 台数	全体 駐車 率
10:10	49	0.653	7	0.500	14	0.778	15	0.938	22	1.000	44	0.587	115	0.833
:20	58	0.773	8	0.571	16	0.889	16	1.000	21	0.955	27	0.360	120	0.870
:30	49	0.653	14	1.000	14	0.778	15	0.938	22	1.000	32	0.427	127	0.920
:40	63	0.840	14	1.000	17	0.944	15	0.938	22	1.000	33	0.440	128	0.928
:50	28	0.373	11	0.786	18	1.000	15	0.938	22	1.000	30	0.400	125	0.906
11:00	41	0.547	11	0.786	18	1.000	13	0.813	22	1.000	30	0.400	121	0.877
:10	44	0.587	10	0.714	17	0.944	13	0.813	19	0.864	33	0.440	108	0.783
:20	59	0.787	8	0.571	17	0.944	12	0.750	20	0.909	30	0.400	115	0.833
:30	53	0.707	10	0.714	17	0.944	14	0.875	21	0.955	29	0.387	116	0.841
:40	24	0.320	6	0.429	12	0.667	5	0.313	18	0.818	35	0.467	87	0.630
:50	60	0.800	2	0.143	17	0.944	11	0.688	21	0.955	31	0.413	107	0.775
12:00	53	0.707	13	0.929	17	0.944	16	1.000	20	0.909	26	0.347	127	0.920
:10	51	0.680	13	0.929	18	1.000	14	0.875	22	1.000	31	0.413	135	0.978
:20	22	0.293	11	0.786	12	0.667	13	0.813	21	0.955	30	0.400	113	0.819
:30	51	0.680	10	0.714	17	0.944	13	0.813	22	1.000	37	0.493	122	0.884
:40	47	0.627	12	0.857	17	0.944	16	1.000	21	0.955	38	0.507	127	0.920
:50	49	0.653	13	0.929	16	0.889	16	1.000	20	0.909	39	0.520	127	0.920
13:00	35	0.467	11	0.786	16	0.889	13	0.813	22	1.000	39	0.520	124	0.899

ブロックにおいても 0.7 程度で、部分駐車率と比べると劣っており、10 分間隔の入・出車率を前提とした場合、内部駐車スペースへの流入および内部からの流出時間等の影響を受けているものと考えられる。つまり、単純な入・出車台数の変化で内部駐車状況を予測するためには、車両の移動時間を十分に考慮した工夫が必要であると考えられる。また、B、C、D ブロックについては、出入口が共通しているため、相関が弱い結果となった。

表 4.2: 全体駐車率と部分駐車率の間の相関係数

A ブロック						B ブロック					
No.1	No.2	No.3	No.4	No.5	No.16	No.1	No.6	No.7	No.8	No.9	No.16
0.74	0.92	0.85	0.91	0.82	0.67	0.22	0.28	0.78	0.66	0.37	0.23

C ブロック					D ブロック				
No.1	No.10	No.11	No.12	No.16	No.1	No.13	No.14	No.15	No.16
0.24	0.90	0.93	0.87	0.20	0.25	0.92	0.79	0.80	0.02

4.4 線形回帰分析による駐車状況の推定

上記検討結果から、A~D の 4 つのブロックの中で、最も相関の強い A ブロックとその逆に相関の弱い B ブロックを検討対象として選んだ。まず、この両ブロックにおける計数データを用いて、線形回帰分析による駐車状況の推定を行う。その推定方法は以下の順序で行う。

- (1) 5 月 1 日の 10 分間隔計数データにおいて、A、B ブロック内に属する部分領域 $n(=2\sim 9)$ の単位時間 (10 分間隔) における部分駐車率および入・出車率 ($n = 1, 16$) を独立変数 (x_i)、その時の A および B ブロック各々における全体駐車率を従属変数 (y_i) として、各部分領域に対する 5 月 1 日の回帰直線方程式 (y_n) を求める。なお、 i は計数データの番号を示す。

$$y_n = ax + b,$$

$$\begin{aligned} a &= \bar{y} - b\bar{x}, \\ b &= \frac{\sum_{i=1}^k (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^k (x_i - \bar{x})^2} \end{aligned} \quad (4.2)$$

x : 変数
 \bar{x} : 部分駐車率の平均
 \bar{y} : 全体駐車率の平均
 k : 計数データ数

- (2) 得られた回帰直線方程式に各日の 10 分間隔の部分駐車率 (x_i) を代入し、A、B 各ブロック毎の単位時間推定全体駐車率 ($y_n(i)$) を算出する。この部分駐車率から求められる推定全体駐車率の平均をその単位時間における最終的な推定全体駐車率 ($P_A(i), P_B(i)$) とする。


$$\begin{aligned} P_A(i) &= \frac{\sum_{n=2}^5 y_n(i) + y_1(i) + y_{16}(i)}{6} \\ P_B(i) &= \frac{\sum_{n=6}^9 y_n(i) + y_1(i) + y_{16}(i)}{6} \end{aligned} \quad (4.3)$$

- (3) 情報提供内容と同じく、3 ランク判定を行うため、基準値を以下のように設定する。


満車 = 95%以上
 混雑 = 60%以上 95%未満
 空有 = 60%未満

なお、この基準値については、現在、東名高速道路において適用されている内容を用いた。この設定に対し、線形回帰分析から得られる推定全体駐車率 ($P_A(i), P_B(i)$) をこの設定範囲に当てはめ、最終的に 3 ランクの判定結果を得る。


ここで、図 4.2、図 4.3 はそれぞれ A、B ブロック内に属する部分駐車率とブロック別全体駐車率との散布図を示し、図中直線は回帰直線を表している。また、表 4.3、4.4 はその回帰係数の算出結果である。なお、表中の a は直線の傾き、 b は切片を示している。




(a) No.2




(b) No.3




(c) No.4



(d) No.5




(e) No.1




(f) No.16


図 4.2: A ブロックにおける散布図




(a) No.6




(b) No.7




(c) No.8



(d) No.9



(e) No.1



(f) No.16

図 4.3: B ブロックにおける散布図

表 4.3: 各部分領域に対する回帰係数 (A ブロック)

$$y_n = ax + b$$

(n は部分駐車率の番号で 1~16)

$n = 1$		$n = 2$		$n = 3$	
a	b	a	b	a	b
0.87	0.28	0.51	0.49	1.13	-0.20

$n = 4$		$n = 5$		$n = 16$	
a	b	a	b	a	b
0.59	0.34	1.67	-0.70	1.08	0.29

表 4.4: 各部分領域に対する回帰係数 (B ブロック)

$n = 1$		$n = 6$		$n = 7$	
a	b	a	b	a	b
0.20	0.62	0.20	0.55	0.59	0.32

$n = 8$		$n = 9$		$n = 16$	
a	b	a	b	a	b
0.39	0.45	0.29	0.49	-0.24	0.84

4.5 ニューラルネットワークによる駐車状況の推定

4.5.1 ニューラルネットワークの構成

今回採用した NN は図 4.4 のような 3 層 MLP 構成とし、各ユニットの応答関数は式 (4.4) に示すようなシグモイド関数を用いた。また、学習方法は式 (4.5) に示す BP 法を適用し、最も基本的な構成とした。

$$f(x) = \frac{1}{1 + \exp(-x + \theta)} \quad (4.4)$$

x : ユニットの入力総和
 θ : オフセット値 (しきい値)
 $f(x)$: ユニットの出力

$$\begin{aligned} E &= \frac{1}{2} \sum_{i=1}^k (O_i - T_i)^2 \\ \Delta w &= -\alpha \frac{\partial E}{\partial w} \\ w &= w + \Delta w \end{aligned} \quad (4.5)$$

E : 誤差評価関数
 O_i : 出力値
 T_i : 教師信号
 k : 出力ユニット数
 w : 重み係数
 Δw : 重み係数修正量
 α : 学習係数

この構成において、入力層には駐車ブロック上の各部分領域における 10 分間隔毎の部分駐車率および入・出車率がそれぞれ入力層の 1 ユニットに対応して入力され、出力層からは満車、混雑、空有の 3 ランク出力をそれぞれ得る。なお、出力層に与える教師データとしては、満車時 [1,0,0]、混雑時 [0,1,0]、空有時 [0,0,1] となる。




図 4.4: ニューラルネットワークモデル

4.5.2 中間層ユニット数および各種パラメータ

NNにおける中間層のユニット数はその認識能力に与える影響が大きく、理論的にはユニット数を増やしていくことで、あらゆる形の入出力関数が表現できることが証明されている [27]。しかし、中間層ユニット数の増加は、学習時の収束時間に影響を与え、むやみに増加させることは実用上の問題を生じる。また、最適な中間層ユニット数の決定方法についても、研究が進んでいるが [28]、現時点では確実な方法が存在していない。更に、式 (4.5) で示されている学習係数の決定方法についても同様な状況である。しかし、この章の検討目的としては、NNの適用による効果の確認にあるため、まず、これらのパラメータを固定し、その性質を見いだすことが必要であると考えた。そこで、学習係数は中間的な 0.5 に固定し、中間層ユニット数を 2, 7, 10 に変化させ、学習時の収束状況および学習速度を確認することで、今回の検討に用いるユニット数を決定することとした。なお、この学習に用いた学習データは、A ブロック 5 月 1 日の 34 データを用いた。




図 4.5: 中間層ユニット数による学習曲線の比較

この結果は図 4.5 のようになり x 軸は学習の繰り返し回数で対数軸として表し、 y 軸は式 (4.5) で示される 2 乗誤差量のサンプル数による平均を示す。このように、収束の初期

段階においては中間層ユニット数による学習速度の差が生じているが、100回以上の学習経過段階ではその収束形態および収束速度にほとんど差が無い。なお、ユニット数2の場合、最終収束段階の誤差量がやや大きく、7,10ではほぼ同じ結果を得ている。この結果から、最終収束時の誤差量の大きさ、学習に要する処理量および演算速度を考慮し、中間層ユニット数は7で統一して扱うこととした。また、学習回数も十分収束が可能な10,000回で統一した。

4.6 推定結果の比較

これまで述べてきた線形回帰分析およびNNによる駐車状況推定方法について、5月1日、2日、6日におけるA、Bブロック計数データを用いた推定結果を比較、検討する。なお、この場合、汎化性についての評価も重要な項目となるため、A、Bブロック両者の推定とも5月1日の34データをもとに得た分析、学習結果（線形回帰分析の場合は回帰係数、NNの場合は重み係数）から、5月2日の36データおよび5月6日の30データの駐車状況推定を行う。つまり、5月1日については、学習データによる推定となり、その推定結果をクローズ状態[29]と呼ぶことにする。また、5月2日、6日は未学習データによる推定となり、この結果をオープン状態[29]と呼ぶことにする。

表4.5は5月1日Aブロックにおける結果を示しており、これを図示したものが図4.6のようになる。更に、5月2日、6日の結果は図4.7、4.8のようになった。この結果、Aブロックにおいては、回帰分析による推定において誤り総数が5データ、NNでは4データとなり、両方法とも同等の推定結果を得た。また、5月2日、6日への適用に対する汎化能力の検証においても良い結果を得た。

表 4.5: 推定結果 (A ブロック)

1991年5月1日

種別 時間	計数結果		回帰分析結果		NN出力結果			
	全体 駐車率	判定	推定 駐車率	判定	満車 (01)	混雑 (02)	空有 (03)	判定
10:10	0.83	混	0.83	混	0.01	0.99	0.01	混
:20	0.87	混	0.83	混	0.01	0.99	0.01	混
:30	0.92	混	0.84	混	0.01	0.99	0.01	混
:40	0.93	混	0.90	混	0.05	0.99	0.01	混
:50	0.91	混	0.82	混	0.01	0.99	0.01	混
11:00	0.88	混	0.83	混	0.05	0.99	0.01	混
:10	0.78	混	0.79	混	0.01	0.99	0.01	混
:20	0.83	混	0.81	混	0.01	0.99	0.01	混
:30	0.84	混	0.83	混	0.01	0.99	0.01	混
:40	0.63	混	0.62	混	0.01	0.99	0.01	混
:50	0.78	混	0.78	混	0.01	0.98	0.02	混
12:00	0.92	混	0.84	混	0.01	0.99	0.01	混
:10	0.98	満	0.87	混 ×	0.96	0.99	0.01	混 ×
:20	0.82	混	0.72	混	0.01	0.99	0.01	混
:30	0.88	混	0.85	混	0.01	0.99	0.01	混
:40	0.92	混	0.87	混	0.01	0.99	0.01	混
:50	0.92	混	0.86	混	0.01	0.99	0.01	混
13:00	0.90	混	0.82	混	0.01	0.99	0.01	混
:10	0.81	混	0.85	混	0.01	0.99	0.01	混
:20	0.84	混	0.81	混	0.01	0.99	0.01	混
:30	0.91	混	0.86	混	0.01	0.99	0.01	混
:40	0.86	混	0.78	混	0.01	0.99	0.01	混
:50	0.85	混	0.84	混	0.01	0.99	0.01	混
15:10	0.48	空	0.57	空	0.01	0.01	0.99	空
:20	0.51	空	0.54	空	0.01	0.01	0.99	空
:30	0.43	空	0.51	空	0.01	0.01	0.99	空
:40	0.40	空	0.52	空	0.01	0.01	0.99	空
:50	0.36	空	0.48	空	0.01	0.01	0.99	空
16:00	0.39	空	0.49	空	0.01	0.01	0.99	空
:10	0.36	空	0.47	空	0.01	0.01	0.99	空
:20	0.51	空	0.67	混 ×	0.01	0.01	0.99	空
:30	0.56	空	0.61	混 ×	0.01	0.01	0.99	空
:40	0.49	空	0.51	空	0.01	0.01	0.99	空
:50	0.44	空	0.52	空	0.01	0.01	0.99	空

誤り計 3

誤り計 1

分類：満＝満車，混＝混雑，空＝空有




図 4.6: 比較結果 (5月1日,Aブロック)




図 4.7: 比較結果 (5月2日,Aブロック)




図 4.8: 比較結果 (5月6日,Aブロック)

同様に、Bブロックの5月1日の推定結果を図4.9に示す。この図4.9から、Bブロックの場合、部分駐車率と全体駐車率との相関が弱いため、線形回帰分析での結果では34データ中11データが誤りとなり、多くの誤差を生じている。また、Aブロックと同様に、オープン状態である5月2日に適用した結果を図4.10に示す。この図4.10において、線形回帰分析結果は36データ中半数以上の24データに誤りを生じ、相関関係が弱い場合には推定が良好に行われていない。しかし、NNでの結果についても5データに誤りを生じ、回帰分析を用いた推定結果よりは良いものの、Aブロックの結果に比べて誤り数は多くなっている。そこで、追加学習として、学習の基本となる5月1日の全データに、5月2日で生じた誤りデータ（回帰分析で24、NNで5データ）を加えて再度回帰分析およびNNの学習を行った。その結果を用いて推定したものを図4.11、4.12に示す。なお、図4.11は5月1日の結果、図4.12は5月2日の結果である。図4.12では両方法とも誤りデータは無く、学習が良好に行われている。しかし、図4.11の回帰分析による結果では、14データの誤りを生じ、基本データの追加前における図4.9の結果よりもさらに悪くなっている。結局、線形回帰分析の場合、1つの状態変化に追従させようとすると他の推定に影響を及ぼす結果となった。




図 4.9: 比較結果 (5 月 1 日, B ブロック)




図 4.10: 比較結果 (5 月 2 日, B ブロック)




図 4.11: 追加学習後の比較結果 (5 月 1 日, B ブロック)




図 4.12: 追加学習後の比較結果 (5 月 2 日, B ブロック)

これに対し、NNでは誤りデータが全て改善され、5月1日、2日も追加学習の効果が十分確認できた。更に、汎化性を確認するために、この分析、学習結果を5月6日に適用したものが図4.13である。この図4.13においても、回帰分析結果に比べ、NNでの推定結果が優れている。




図 4.13: 追加学習後の比較結果 (5月6日, Bブロック)

以上のように、部分駐車率と全体駐車率の間の相関関係が強く、安定している場合には、線形回帰分析、NNともほぼ同等の能力を発揮するが、この関係が弱く、非線形な状況ではNNでの推定能力が優れている。また、誤りデータの追加学習により、その状況変化を吸収し、柔軟な対応を達成した。更に、汎化性についてもNNでの推定結果の方がより良い結果を得た。このことから、NNの適用が可能であることが確認できた。また、このA、Bブロックに対するNNの適用においては、対象の相関関係の強弱が異なっている。この違いは、学習の容易性に影響を与えることが予想できるため、各々のブロックにおける5月1日の学習曲線を比較した。その結果を図4.14に示す。このように、部分と全体の関係がより複雑で相関関係が弱いBブロックにおいては、Aブロックに比べて学

習の進行状況が遅くなっている。今回の場合、NNの適用効果を第一の目的としたため、パラメータの一つである学習回数については固定して扱ったが、この結果から、相関関係の強弱により最適な学習回数が存在すると考えられ、NNの適用時における一つの性質を示している。




図 4.14: AブロックとBブロックの学習曲線の比較

4.7 実用上の効果

このNNを用いた駐車状況推定方法は、検出装置とともに1991年6月東名高速道路下り線足柄サービスエリアにおいて稼動を始めており、そのシステムおよび運用側からの評価については参考文献[19]のとおりであり、精度上満足のいく結果を得ている。また、これまでに1991年8月にサービスエリア内の休憩施設(売店)がオープンしたことで、内部の駐車形態が変化した(当初、混雑の無かった駐車スペースが常時混みだした)が、その状況において追加学習を加えることで、学習後の推定精度を検証したところ、データ収集を行った75データ中誤りが2データとなり、満足の行く結果を得た。1991年12月にも追加学習、状況検証を行い、12月25日から28日の4日間で280データ中誤りは7

データであった。このように、実用上においても良い結果を得ることができた。

4.8 まとめ

この章では部分駐車率から全体駐車状況を推定する方法としてニューラルネットワークの適用を提案し、線形回帰分析の推定結果との比較、検討を行った。その結果、マクロ的な3ランク推定にニューラルネットワークを用いた場合、相関関係の強弱にかかわらず、精度の高い駐車状況推定を可能とすることが分かった。特に、相関関係が弱い場合の推定事例において、誤りを生じたデータを用いた追加学習により、その能力の向上が確認できたことと、実用時に生じた駐車形態の変化に対しても、同様な学習行為により推定精度を維持できたことで、非線形な状況変化に対しても学習により柔軟に対応できることが確かめられた。また、駐車状況推定のためのニューラルネットワークの性質として、相関関係の違いにより学習曲線に差を生じ、相関関係が弱い場合には学習の収束が遅く、対象の相関関係により、最適な学習回数が存在することもわかった。

この章で目的とした駐車状況推定のためのニューラルネットワークの適用に関してはその実用性を確かめることができたが、より高い精度、安定性を追求するためには入・出車率の取扱いおよびカレンダー情報等、ニューラルネットワークへの入力データとしての工夫が必要であると考え。更に、学習回数、中間層の数、ユニット数、および学習係数等ニューラルネットワークの各種パラメータは演算速度、推定精度に影響を与えることから、これらパラメータの最適化も必要である。また、ここで述べた駐車状況のマクロ的な3ランク推定について示してきたが、その状況判定の基本は駐車率にあり、ニューラルネットワークを用いたシステムで直接的に全体駐車率を推定する方法についても検討が必要である。

第5章

アナログ出力ニューラルネットワークによる駐車率の直接推定^[57]

5.1 はじめに

第4章では、テレビカメラ（センサ）台数の削減を目的として、部分駐車状況から全体駐車状況をマクロ的に推定する方法に対して、NNを適用した新たなアプローチを行った。このNNの構成としては、3層構成とし、入力層に部分駐車状況（部分駐車率）を与え、出力層に3つのマクロ出力（「満車」、「混雑」、「空有」）のニューロンを配置し、状況出力を得るようにした。つまり、このNNの適用は全体駐車状況の推定を部分駐車状況（部分駐車率）入力による3つのカテゴリへの非線形分類問題としてとらえた。この結果、従来行われてきた線形回帰分析による推定方法^[11]に比べ、良い結果を得ており、汎化能力の高さ、非線形な変動に対する追従性の良さを実証した。しかし、学習に関しては全体状況が「満車」、「混雑」、「空有」となった時点の部分駐車率を教師データとして与えており、全体状況の判断基準の変更が必要な場合（例えば、管理形態の変更等から、全体の60%以下の駐車率の時「空有」状況としていたものを50%以下に変更）、変更後の基準に従った全体状況および部分駐車率を再度収集し、これを用いて再学習する必要がある。この教師データの収集に関しては人が全駐車車両台数を計数しているのが現状である。しかも、より多くの状況を学習させるため、極端な場合では導入当初と同様、平日、休日、連休等の各種状況を各日、数時間にわたって収集することが必要となる可能性を持ち、単純な基準変更も容易に実行できるとは言いきれない。これは、データ収集の困難さ

が故に生じる内容である。このデータ収集の困難さについては、この分野に留まるものではなく、一般的な NN の応用に関する研究課題として取り上げられている [30]。その意味では、この課題に対するより効率的な方法を検討し、改良を行っていくことも重要な項目であると言える。

この状況判断基準の変更時に生じるデータ収集の必要性については、ここで用いた NN が3つのカテゴリーへの分類形態をとっているために生じる。これを駐車率自体の推定出力として得られるようにすれば、基準変更のためのデータ収集の必要はなく、単純な基準テーブルの更新で済む。また、全体駐車率が直接推定できれば、最も基本となる情報を得ることができるため、例えば、現行の3ランクの情報提供のみならず、パーセント表示のような、多様な情報提供形態にも対応が可能となる。そこで、この章では上述したような実用時の課題を解決するために、部分駐車率から全体駐車率を直接推定する NN を提案する。そして、この中では駐車率出力を行うための NN の形態、応答関数等細部にわたる検討を行い、シミュレーション実験により、その効果を検証する。また、得られた結果をもとに、第4章で用いた東名高速道路足柄サービスエリアにおける実際の収集データによる評価を行い、実用上の効果を検討する。更に、ここでの方式を東京外環道新倉パーキングエリアにおいて実用化し、その実用時の状況についても示す。

5.2 アナログ出力ニューラルネットワーク

一般に NN の応答関数としては入力層に恒等関数、中間層および出力層は第4章の式 (4.4) と同様、式 (5.1) のシグモイド関数が用いられる。

$$o(x) = \frac{1}{1 + \exp(-x)} \quad (5.1)$$

このシグモイド関数の出力値は $[0,1]$ の実数として得られる。この出力形態を利用し、これまでのような複数の出力ニューロン間の出力値の比較によるカテゴリーへの分類ではなく、出力層のニューロン数を1個として、出力値をアナログ的に扱い、実際の駐車率 $([0,1])$ にあてはめれば、目的とした駐車率の直接推定が可能となると考えられる。元来、 NN の学習で用いられる BP 法 [23] は出力値と教師データ間の誤差を逐次減少させていく方法であることから、このような形態でアナログ的な学習は可能である。なお、 NN の学習則として一般的である BP 法は3層 NN の場合次のようになる。

今、教師データ T_k と出力 O_k の間の誤差評価関数は第4章の式 (4.5) と同様、次式で扱われる。なお、 k は正の整数で出力層のニューロン数である。

$$E = \frac{1}{2} \sum_k (O_k - T_k)^2 \quad (5.2)$$

BP 法では、各層間の結合重み W を変化させることで、誤差関数 E を最小化する。この重み W の変化量は次式のようになる。

$$\Delta W_{jk} = -\alpha \frac{\partial E}{\partial W_{jk}} = \alpha \cdot \delta_k \cdot H_j \quad (5.3)$$

$$\Delta W_{ij} = -\beta \frac{\partial E}{\partial W_{ij}} = \beta \cdot H_j \cdot (1 - H_j) \cdot \sum_k \delta_k \cdot W_{jk} \cdot I_i \quad (5.4)$$

ただし、 $\delta_k = \delta \cdot O_k \cdot (1 - O_k)$, $\delta = T_k - O_k$ であり、 i, j はそれぞれ正の整数で入力層、中間層のニューロンの番号、 I, H はそのニューロンの出力、そして W_{jk} は中間層の j 番目のニューロンと出力層における k 番目のニューロン間の結合重みを示し、同様に W_{ij} は入力層と中間層の結合重みである。また、 α, β は学習係数を示す。

この学習アルゴリズムに従い、図 5.1 のように、入力層に部分駐車率を入力し、その時の全体駐車率を連続値の教師データ T_1 として与え、出力 O_1 との間で学習することで、駐車率推定を行う。しかし、式 (5.1) の関数形態からわかるように、得られる出力の最小値 0.0 および最大値 1.0 を得るためには、 $-\infty, +\infty$ の入力が必要になる。実際に駐車率においてはこの最大、最小値が存在し、このままの応答関数では駐車率の両極値が出力されにくい形となる。また、この点を考慮して、学習に用いる教師データを $[0.1, 0.9]$ の範囲で扱う指摘がされている [23]。




図 5.1: アナログ値推定のための NN モデル

元来、3 層以上の層構造の場合、分類対象の性質、汎化性能等は中間層を持つことで実現される。このことは XOR 問題での実験により紹介されている [31]。また、分類対象の性質が中間層を含んだ重みにより表現されることも別に報告されている [32],[33]。これらの知見を基に、上述した極値での応答特性の改善を目的として、中間層には従来どおりのシグモイド関数を用いて非線形性への対応および汎化性能の確保を考慮し、出力層には式 (5.1) のシグモイド関数に代わり式 (5.5) に示す線形関数を新たに採用した駐車率推定用 NN を提案する。

$$o(x) = x + 0.5 \quad (5.5)$$

この線形関数を用いた NN は [0,1] の出力に限らず、連続値を表現できることから、以後アナログ出力 NN (ANN) と呼ぶ。一般に、出力関数を線形関数とした報告 [33],[34] はこれまでにされているものの、ここで対象としたような、極値での応答特性に対する改善を目的とした例はない。なお、この ANN における結合重みの学習量は式 (5.3)、式 (5.4) の誤差成分における応答関数の微分項が消え、次式のようになる。

$$\Delta W_{jk} = \alpha \cdot \delta \cdot H_j \quad (5.6)$$

$$\Delta W_{ij} = \beta \cdot H_j \cdot (1 - H_j) \cdot \sum_k \delta \cdot W_{jk} \cdot I_i \quad (5.7)$$

ただし、 $\delta = T_k - O_k$ である。

5.3 シミュレーション実験

上記のように、駐車率推定を行うことを目的とした ANN に関して、その能力を評価するため、ANN と NN を用いたシミュレーション実験を行う。なお、ANN では教師データを [0,1] の範囲で直接扱うようにし、NN に関しては、参考文献 [23] にあるように、[0,1] の範囲の教師データを直接扱うのではなく、教師データを [0.1,0.9] の範囲に一旦圧縮して学習し、学習後の重みを用いた NN の出力に関して、再度 [0,1] に拡張する方式とする。また、従来提案されている方法として、線形回帰分析による方法 [11] も対象となるが、第 4 章で示したように、駐車状況という非線形な対象に対しては NN での有効性を既に得ており、ここでは扱わないものとする。

この能力評価を行うに当たって、対象とするデータは $[0,1]$ の範囲で変化することを条件として、式 (5.8) に示す \sin 関数を用いることとした [35]。

$$f(x) = 0.5 \sin x + 0.5 \quad (5.8)$$




図 5.2: \sin 関数と学習点

この関数中、図 5.2 の \cdot 印の 17 点を教師データとして選び、学習を行う。なお、中間層のニューロン数については確実な決定方法が存在していないことから、第 4 章での決定方法と同様、従来の NN を用いて学習回数を 10,000 回、学習係数 0.5 に固定して、中間層ニューロン数を 2~5 まで可変させ、式 (5.2) の誤差が最も小さくなるものを用いることとした。この結果は表 5.1 のようになり、中間層のニューロン数が 4 個の時に誤差が最小となることから、このシミュレーションに関しては入力層 1、中間層 4、出力層 1 (以後、1-4-1 と呼ぶ) のニューロン構成とした。また、 NN と ANN の能力比較を基本とするため、ニューロン構成および学習に関する各種パラメータは ANN においても同一とした。

表 5.1: 中間層のニューロン数に対する誤差の比較

ニューロン数	誤差
2	0.02044
3	0.00573
4	0.00522
5	0.00642

この学習結果の重みを用いて、学習データ 17 点を含み、未学習である点間の値とあわせて 361 点を両ネットワークへ入力し、この出力値を得た。その結果を図 5.3 に示す。この図 5.3 から明らかなように、 NN に比べ ANN の方が極点での追従性が良く予想どおりの結果を得た。また、図 5.4 はこの時の学習曲線を示しており、 ANN の場合、学習が進んできた 1,000 回以降で非常に効率良く学習が行われている。学習後の誤差量 (式 (5.2)) は NN で 0.00522、 ANN で 0.0004 となっており、学習の最終誤差量としても桁が違う程の差がでている。これらの実験結果から $[0,1]$ の連続値に対して、 ANN の有効性を示すことができ、駐車率推定の可能性を得た。




図 5.3: 学習結果




図 5.4: 学習曲線

5.4 実測データを用いた検証結果

第4章の図4.1に示したように、東名高速道路下り線足柄サービスエリアはA~Dの4つの大きな駐車ブロックに別れており、駐車状況の検出に関しては各駐車ブロック単位で行われる。第4章では、図4.1中のハッチング部分①~⑥の部分駐車率および入・出車率から、3ランクの全体状況を推定するNN(第4章、図4.4)について示した。本項では、第4章で使用した足柄サービスエリアにおける実測データを流用し、図5.5のようなNNおよび出力層ニューロンの応答関数を線形関数としたANNによる駐車率の直接推定を行い、この両者の推定能力を検証し、実用化への可能性を検討する。

対象としたデータは、小型車の駐車領域であるAブロックの3日間(1991年5月1日、2日、6日)での収集データを用いて行う。なお、NN、ANNにおける入力層、中間層のニューロン数については各々6,7とし、出力層を除いて、第4章で示した構成と同一とした。もちろん、出力層は駐車率を直接出力するように1としている。そして、学習方法についても第4章同様、5月1日に収集した34データ(10分間隔)を教師データとして与え、式(5.2)の誤差が0.01になるまで学習を行った。なお、学習係数は0.1である。この時のNNの学習回数は135,508回、ANNでは130,148回となり、やはり、ANNにおける学習のほうが早く収束している。この学習結果を用いたクローズ状態(5月1日)での結果を図5.6(a)に示す。この図において、縦軸は駐車率、横軸は計測時間を示しており、図中細かい点線はNN、実線がANNでの推定結果で、点線は真値である。

この結果から、NN、ANNともに真値に良く追従していることが分かる。ここで、ANNの特徴である極値での応答性能を確かめるため、駐車率0.8以上のデータを抜き出し、拡大したものが図5.6(b)である。この図中において、ピークとなる正午(12:00)の点(駐車率真値0.978)ではNNの推定値に比べやはりANNでの追従が良くなっている。なお、この時の駐車率の推定値はNNが0.934でANNが0.961であった。

更に、この学習後の重みを用いて、未学習である5月2日(36データ)、6日(30データ)の駐車率推定を行った結果が図5.7である。つまり、図5.7がオープン状態である。






図 5.5: 足柄サービスエリア内 A ブロック向け ANN




(a) 全データ




(b) 駐車率 0.8 以上のデータ

図 5.6: 足柄サービスエリアの A ブロックにおける学習結果 (1991 年 5 月 1 日)



(a) 1991 年 5 月 2 日



(b) 1991 年 5 月 6 日

図 5.7: 足柄サービスエリアの A ブロックにおける検証結果

この推定結果を定量的に評価するため、真値からの標準偏差 (STD) を次式に従い算出した。

$$STD = \sqrt{\frac{\sum_{k=1}^N (T_1(k) - O_1(k))^2}{N}} \times 100[\%] \quad (5.9)$$

なお、この式 (5.9) において、 $O_1(k)$ はニューラルネットワークによる k 番目の駐車率推定結果、 $T_1(k)$ は、その時の真の駐車率、 N はデータ数を示す。また、この STD はパーセント駐車率として得られる。この結果は表 5.2 のようになり、クローズ状態である 5 月 1 日での結果は除いて考えても、5 月 2 日、6 日の 66 パターンに対して、真値からの標準偏差はパーセント駐車率で 10% 以内となり、汎化性能に対しても良い結果を得た。また、標準偏差を用いた総合的な評価に関しては、 NN と比べて大きな差は生じていないが、検証に用いた 3 日間のいずれの日においても、 ANN の応答が良い結果を得ている。


このように、 ANN の駐車率推定能力およびその大きな特長である駐車率 1.0 近傍の追従性について、実測データに対しても NN より優れたの結果を得ることができ、 ANN の実用上の可能性を十分得た。

表 5.2: 足柄 S.A における標準偏差の比較結果

日付	ANN STD [%]	NN STD [%]
1991 年 5 月 1 日	2.312	2.482
1991 年 5 月 2 日	6.416	6.678
1991 年 5 月 6 日	6.542	7.115

5.5 実用時の評価

上記のように、シミュレーション実験、実測データによる検証を通じて、駐車率推定に関する ANN の実用上における可能性を十分得た。この結果をもとに、この方式を東京外環道新倉パーキングエリアに適用し、駐車率推定型駐車状況検出システムの実用化を行った。




①—⑩ Monitoring area

図 5.8: 新倉パーキングエリアの平面図


図 5.8 は新倉パーキングエリアの平面図を示しており、中央の休憩施設を挟んで左側が小型車駐車領域（小型車 64 台駐車）、右側が大型車駐車領域（大型車 20 台駐車可能）である。この図のハッチング部分は第 2 章、第 3 章で述べた画像処理方式を採用した検出装置（付録 C）[51] の監視範囲であり、小型車領域では 46.9%、大型車領域で 69.5% の監視率となっている。このような、部分的監視範囲から全体駐車率を推定することになる。なお、この図の台形枠のそれぞれが部分駐車率の検出箇所となり、小型車領域で 6 箇所、大型車領域で 4 箇所の部分駐車率を検出している。また、このパーキングエリアは上下線共用であり、入・出路が複雑であることと、装置の設置上の問題から上記足柄サービスエ

リアのような入・出車台数をとらえるテレビカメラが設置できなかった。そこで、ANN への入力情報を強化するため、 $(\text{全監視範囲内の駐車台数}) / (\text{全監視範囲内のマス数})$ を小型車領域、大型車領域それぞれに求め、総合的な入力情報として加えることとした。つまり、入力層のニューロン数は小型車領域用として 7 個、大型車領域用として 5 個となる。また、中間層のニューロン数は上記足柄サービスエリアでの構成と同様に、入力層のニューロン数より 1 個多い形とした。結局、ANN の構成としては小型車領域用として 7-8-1、大型車領域用として 5-6-1 とした。


学習用データの収集に関しては、システム導入前の 1993 年 11 月 13 日、14 日の 2 日間に、小型車領域 76 パターン、大型車領域 50 パターンを収集した。このデータを教師データとして学習を行った。この学習については、現地での学習時間をできるだけ短くすることを考慮し、学習係数は 0.5、最終誤差量は 0.05 になるまで学習した。この時の学習回数は小型車に対して 20,834 回、大型車に対して 4,598 回となった。この学習結果の重みをもとに、1994 年 5 月 13 日、14 日、15 日に再度データ収集を行い、システム導入後の評価を行うこととした。なお、このデータは各日とも 10 分間隔で収集され、5 月 13 日が 51 パターン、14 日が 36 パターン、そして 15 日が 39 パターンの計 126 パターンで、小型車、大型車領域で同時に行っていることから、全パターン数はその 2 倍の 252 パターンとなった。このオープン状態のデータを用いた検証結果を図 5.9 に示し、式 (5.9) の標準偏差の算出結果を表 5.3 に示す。なお、図 5.9 中の点線は真値、実線は ANN での推定結果であり、縦軸は駐車率、横軸はデータの計測時間である。この図 5.9 からわかるように、ANN での推定が真値に良く追従している。また、表 5.3 から明らかなように、各日、各領域において真値からの標準偏差がパーセント駐車率で 10% 以内となっており、上記足柄サービスエリアでの結果と同様、実用時においても良い結果を得た。なお、この結果において、小型車領域での STD が大型車領域のそれと比べて悪くなっている。これは、小型車領域での監視率が大型車領域に比べ 20% 以上低いためと考えられる。元来、監視率を増やせば全体駐車率との相関は高くなり、推定精度はより良い方向になることが十分予想され、その意味では最適な監視率の選択も今後検討する必要がある。また、学習回数についても同様のことが生じている。このことは、第 4 章で述べたように、全体の状況と対象とした部分領域の相関の強さにより学習回数に差がでることから説明できる。ただし、




(a) 小型車エリア (1994 年 5 月 13 日)




(b) 大型車エリア (1994 年 5 月 13 日)




(c) 小型車エリア (1994 年 5 月 14 日)



(d) 大型車エリア (1994 年 5 月 14 日)



(e) 小型車エリア (1994 年 5 月 15 日)



(f) 大型車エリア (1994 年 5 月 15 日)

図 5.9: 新倉パーキングエリアにおける検証結果

学習回数については、対象とした学習パターン数に 26 パターンの差があり、その影響も受けているものの、学習回数自体は 4.5 倍以上の差があることから、やはり、監視率が少ない分だけ全体との相関も弱く、その影響を受けているものと考えられる。

表 5.3: 新倉 P. A における検証結果 (STD)

日付	小型車駐車エリア STD [%]	大型車駐車エリア STD [%]
1994 年 5 月 13 日	7.010	5.109
1994 年 5 月 14 日	9.416	4.999
1994 年 5 月 15 日	7.745	5.364

このように、小型車領域での推定結果が大型車領域での結果に比べて若干悪くなっているものの、総合的に評価すれば、3 日間いずれの日も STD 値が 10% 以下となり、十分な結果を得ている。なお、このシステムは 1994 年 3 月 28 日から運用を開始しており、現在も順調に稼働している [51]。

5.6 まとめ

ニューラルネットワークを用いた駐車状況推定に関して、システム導入後の判定基準値の変更時に生じる学習データの再収集問題を発端として、将来の情報提供形態の変化も考慮した駐車率の直接推定方法について検討した。この中では、出力層のニューロン数を 1 個とし、アナログ的な推定を行う形態を示した。そして、推定対象である駐車率が [0,1] の実数であり、その最大、最小値が 1.0,0.0 であることから、一般のニューラルネットワークの応答関数ではその極値が出力されにくい点を述べ、この点を改良するため応答関数として線形関数を用いたアナログ出力ニューラルネットワークを示した。このアナログ出力ニューラルネットワークの能力を評価するため、sin 関数を用いたシミュレーション実験を行い、ニューラルネットワークに比べアナログ出力ニューラルネットワークでの極値における応答性が極めて良いことを示した。また、アナログ出力ニューラルネットワークの実用上における可能性を検証するため、第 4 章で用いた足柄サービスエリアでの実測データを流用してニューラルネットワークとの比較を行ったところ、シミュレーション実験同

様、駐車率のピーク点における応答性の良さを示すことができた。そして、定量的な評価方法として、真値からの標準偏差を算出したところ、ニューラルネットワーク、アナログ出力ニューラルネットワークともにパーセント駐車率で10%以内の精度を得た。このように、総合的な精度としては両者とも同じような結果となったものの、評価に用いた総ての日でアナログ出力ニューラルネットワークの精度が良くなる結果を得た。更に、この結果をもとにして、東京外環道新倉パーキングエリアにこの駐車率推定システムを構築し、実用化を行った。そして、このシステムの導入後の評価を行い、5月13日~15日の3日間、252パターンのデータに対し、足柄サービスエリアでの結果と同様、真値からの標準偏差で10%以内の結果を得ることができ、形態の全く異なる二つの駐車場への適用に関して良い結果を得ることができたことから、アナログ出力ニューラルネットワークの駐車率推定が実用上も十分有効であることを示すことができた。以上のことから、ここで問題提起した導入後の基準変更に伴う学習用データの収集、再学習は単純な基準テーブルの更新として扱うことが可能になるとともに、将来に向けての提供内容の変更等にも柔軟に対応していくことが可能となった。

ただし、第4章でも述べたように、アナログ出力ニューラルネットワークの中間層数、学習係数、学習回数等の各パラメータに関しては、試行から導いており、この駐車率推定における効率的なパラメータ決定方法の検討が残されている。また、部分領域の監視率についても的確な方法を見いだしておらず、全体駐車率との相関を基本とした監視率決定法についても検討を要する。そして、このシステムを実際のフィールドに設置したことから、より多くの検証を繰り返し、追跡的な評価を行っていく必要があると考える。更に、アナログ出力ニューラルネットワークは駐車率推定のみではなく、[0,1]以外の連続値に対しても、応用が可能であると考えられることから、他分野への積極的な応用を行っていくことも重要な課題である。

第6章

路面湿潤状況検出方式 [55]

6.1 はじめに

この章では、ドライバーの運転環境支援のためのパラメータである走行路面の状況を検出する方法に関して、その路面状況の光学的変化を定性的にとらえている偏光特性を用いた方式を画像処理に適用する方法について述べる。この偏光特性の応用に関しては、物体表面状態の非接触、非破壊検査方法として良く知られている [39]。近年においても、画像処理時に弊害となる鏡面反射成分の除去・分離方法 [40] や専用光を用いずに表面反射成分と内部反射成分の分離抽出を行う方法 [41]、画像上からの材質の検出方法 [42] として用いた研究例、半導体製造時のガラス基板上におけるきず、ほこりの検出 [43]、更に、人の顔面皮膚表層の色素分布状況の検出 [44] に至るまで応用範囲は広い。これらの応用研究例においても、偏光特性の変化をとらえる点では共通しているが、ここでは道路交通分野の画像処理応用に関する新たなアプローチとして、頻発する路面の湿潤状況の変化を検出する方法にこの偏光の性質を利用し、しかも屋外環境下での広範囲な検出を行うようにする。

この偏光特性を用いた路面状況検出の研究例としては参考文献 [4][45] がある。この方式では、路面に対して専用光源の投光器、受光器を配置し、受光側での偏光変化により路面状況を検出する方式である。しかし、この方式では専用光を用いていることから検出範囲が狭く、広範囲に分布する路面状況を的確にとらえることはできない。そこで、本方式では、これまでの応用例とは異なり、屋外でしかも専用光源を用いず、自然光（散乱光）を光源として利用した画像処理方式を基本とする。そのため、光源の操作による被検査体

への入射角の制御が困難となる。そこで、テレビカメラの角度を偏光変化が最大となる Brewster 角になるように設置して撮影することで、路面からの反射光を受光する側で偏光変化の角度依存性を満足させる光学モデルを形成した。更に、自然光のもとでは、テレビカメラへ入射する反射光強度の変動を考慮する必要があり、その方法として水平、垂直両偏光画像の輝度比を得るようにした。また、画像撮影時に混入する誤差成分についても言及し、その補正方法についても示す。更に、画像を検出対象とすることから、大量の演算処理を必要とする関係上、より高速化を図るため輝度比の演算を対数差分演算に置き換える工夫も合わせて行い、その一連の処理手順を示す。そして、これらの方式の効果を確認するため、実際の路面上に作成した湿潤状況のシミュレーションサンプルによる予備実験を行うとともに、実際の雨天状況撮影画像に対して処理を施した結果についても示す。また、画像情報から得られる空間分布状況の検出効果を検討するため、路面湿潤から乾燥への移行状態を対象とし、湿潤領域の分布状況を実際の撮影画像から抽出した結果についても示す。

6.2 路面湿潤検出方式




図 6.1: 光の反射と屈折

図 6.1 に示すように、屈折率 n_1 の媒質 1 と n_2 の媒質 2 の境界面（鏡面） ξ 上の点 M に向って光のベクトル u_1 が入射した場合、その反射光 u_1' における垂直偏光成分（S 偏光

成分）と水平偏光成分（P 偏光成分）のエネルギー強度はそれぞれ異なった変化を示す。この S 偏光成分、P 偏光成分それぞれのエネルギー反射率を R_S, R_P とするとその関係は次式のようにになる。

$$R_S = \frac{\sin^2(\theta_1 - \theta_2)}{\sin^2(\theta_1 + \theta_2)} \quad (6.1)$$

$$R_P = \frac{\tan^2(\theta_1 - \theta_2)}{\tan^2(\theta_1 + \theta_2)} \quad (6.2)$$

今、式 (6.2) において、 $\theta_1 + \theta_2 = 90^\circ$ の場合では $R_P = 0$ となる。この入射角は Brewster 角と呼ばれ、 θ_b として記述する。ここで、Snell の法則から θ_b は次式のような関係となる [46]。

$$\frac{\sin \theta_b}{\sin\left(\frac{\pi}{2} - \theta_b\right)} = \tan \theta_b = \frac{n_2}{n_1} \quad (6.3)$$

$$\theta_b = \tan^{-1} \frac{n_2}{n_1}$$

ここで対象とする状況では、空気と水が媒質となることから、その各々の屈折率を用いた場合の Brewster 角 θ_b は 53.1° となる。なお、この場合の入射角（反射角）とエネルギー反射率 R_S, R_P の関係は図 6.2 のとおりである。




図 6.2: 入射角とエネルギー反射率の関係

この鏡面における偏光成分の関係に対して、次に、粗面を対象とした場合について考える。この場合では、一定の角度で入射した光に対しても反射光はあらゆる方向に拡散

(乱反射)する。結局、入射角、反射角の関係は特定できず、鏡面の性質は現れない。つまり、粗面における S 偏光成分、 P 偏光成分の反射率はほぼ $R_S = R_P$ の関係となる。

今、境界面に入射する光強度を I とすると、鏡面、粗面による反射係数の差はあるものの反射光の各偏光成分は次式のように表せる。

$$\begin{aligned} I_S &= R_S \cdot I \\ I_P &= R_P \cdot I \end{aligned} \quad (6.4)$$

しかし、式 (6.4) から明らかなように、各偏光成分の強度は入射光強度に依存した形となり、特に、今回対象とする屋外環境のもとでは、偏光成分の強度を用いた単純な比較が困難となる。そこで、式 (6.5) のように、両偏光成分の比 H を求めることでこの輝度変動成分の除去を行う。

$$H = \frac{I_S}{I_P} = \frac{R_S}{R_P} \quad (6.5)$$

そして、入射光 I の入射角が Brewster 角であり、しかも、この境界面が鏡面の場合では、上記反射率の性質から、式 (6.5) の偏光成分比 H は理想的には無限大となる。また、境界面が粗面の場合では入射角に依存せず、 $H = 1$ となる。結局、この偏光成分比 H をパラメータとして扱うことで、鏡面、粗面の状態は入射光強度に依存しない形で表現できる。このような鏡面、粗面における反射光の性質を道路面の冠水、湿潤、乾燥状態にあてはめることとする。

まず、道路面が乾燥している場合を考える。道路の乾燥状態は図 6.3(a) のようになり、粗面として振る舞うことが予想できる。このことから、偏光成分比は $H = 1$ なる関係が成り立つ。次に、この乾燥路面が冠水状態に移行した場合を考える。この場合、路面は図 6.3(b) のようになり、粗面が水で覆われる。このため、水を境界面とした鏡面での性質を示し、Brewster 角 53.1° での偏光成分比は理想的に $H = \infty$ となる。また、この乾燥と冠水の間期的状態（雨の降り始め、雨上がり等）では乾燥部分と湿潤部分が共存していることからこの偏光成分比 H も中間的となることが予想できる（図 6.3(c)）。

このように、路面状態が乾燥から湿潤へ変化すると偏光成分比 H は次第に大きくなって行き、冠水状態では理想的に無限大の値をとることとなる。この性質を用いて道路面の状態検出にあてはめる。




図 6.3: 路面状況

6.3 画像処理方式


自然光は太陽の存在する方角からの直接光だけではなく、大気中の空気および水分等により散乱し、太陽から離れた方角でも晴天時には空は青く、曇時にはどんよりとした曇天として目に映る [47],[48]。つまり、昼間においては太陽の方角から生じる直接光と合わせて、これら散乱光も存在しており、図 6.4(a) に示すように、あらゆる入射角の光が存在する。この状況において、直接光による反射光成分をとらえようとした場合、その反射光成分は散乱光によるものと比べてスポット的になり、しかも反射光輝度は非常に高くなることから、撮影するテレビカメラのダイナミックレンジを越え、計測が困難になることが予想される。そこで、この天空からの散乱光を光源として扱い、図 6.4(b) のように、テレビカメラの角度を Brewster 角となるように設置して道路面の撮影を行う。このような撮影系により、路面からの反射光を Brewster 角を中心とした画角（立体角）でとらえることが可能となり、自然光による偏光特性の検出に対する光学的モデルを形成できる。ただし、このようにした場合、対象とする反射光が Brewster 角に限定されていない。しかし、図 6.2 から明らかなように、偏光特性の変化は Brewster 角における一点のみに限らず、約 $30^\circ \sim 80^\circ$ までの広い範囲でその傾向を示している。このため、同様の原理を当てはめたととしても、十分な効果が期待できる。

このように設置したテレビカメラの前面に偏光素子を配置し、偏光角を垂直と水平各々の方向へ交互に切り替え、これに同期して S 偏光成分画像と P 偏光成分画像の 2 枚の画像を取り込む。その両画像上の各画素における輝度 $D_S(x, y)$, $D_P(x, y)$ は式 (6.4) から次式のように表現できる。


$$\begin{aligned} D_S(x, y) &= R_S(x, y) \cdot I(x, y) \\ D_P(x, y) &= R_P(x, y) \cdot I(x, y) \end{aligned} \quad (6.6)$$

しかし、テレビカメラから取り込まれた画像には誤差成分としてビデオ回路系のアンプが持つオフセット成分 $B(x, y)$ が加算されるとともに、撮像素子面の感度むら $S(x, y)$ 等が混入している。これらの関係を考慮に入れると各画素の輝度は次式のようなになる。

$$\begin{aligned} D_S(x, y) &= R_S(x, y) \cdot I(x, y) \cdot S(x, y) + B(x, y) \\ D_P(x, y) &= R_P(x, y) \cdot I(x, y) \cdot S(x, y) + B(x, y) \end{aligned} \quad (6.7)$$



(a) 太陽光モデル



(b) テレビカメラの配置

図 6.4: 太陽光モデルとテレビカメラの配置

このように、誤差成分を含んだままの状態では、正確な状況を得ることができないと思われる。そこで、この誤差成分の補正について考えることとする。

式(6.7)から明らかなように、オフセット成分 $B(x, y)$ は加算的であり、テレビカメラに入射する光強度がゼロの状態でも得られる。そこで、輝度ゼロの状態（光を遮断した状態）を撮影したオフセット画像 $B(x, y)$ を用意し、オフセット成分を明確にする。また、撮像素子の感度むらについては、均一輝度 I_W を持つ対象（例えばグレーボード、白紙等）を撮影することで、式(6.8)のような感度むら $S(x, y)$ を含んだ撮影画像（応答画像） $W(x, y)$ を得ることができる。

$$W(x, y) = I_W \cdot S(x, y) + B(x, y) \quad (6.8)$$

このように、あらかじめ用意したオフセット成分 $B(x, y)$ および $W(x, y)$ を用いて、式(6.9)のように各偏光成分画像内に混入する誤差の補正を行う。

$$\begin{aligned} W'(x, y) &= W(x, y) - B(x, y) = I_W \cdot S(x, y) \\ D'_S(x, y) &= \frac{D_S(x, y) - B(x, y)}{W'(x, y)} \\ &= \frac{1}{I_W} R_S(x, y) \cdot I(x, y) \\ D'_P(x, y) &= \frac{D_P(x, y) - B(x, y)}{W'(x, y)} \\ &= \frac{1}{I_W} R_P(x, y) \cdot I(x, y) \end{aligned} \quad (6.9)$$

この両画像に対して、式(6.10)のように、2次元座標における各画素の比 $D_h(x, y)$ を求め、湿潤度検出画像を得る。

$$D_h(x, y) = \frac{D'_S(x, y)}{D'_P(x, y)} = \frac{R_S(x, y)}{R_P(x, y)} \quad (6.10)$$

なお、各画素に対してこの除算を行うに当たっては、演算時間が膨大になることが十分予想できる。特に、画像を対象とした演算では、必然的に演算量が増加するため、処理の効果は十分であっても実現上で問題を生じる場合もある。このため、処理の達成とともに演算時間の高速化、ハードウェア化をも合わせて検討する必要がある。そこで、本方式においては、式(6.9)における各補正画像に対して対数変換を行った後、その補正対数画像間の差分を行うことで同じ効果を達成するようにした。この演算は、テーブル変換と

差分演算という最も高速演算の可能な形に置き代わり、ハードウェア化も容易となる。なお、この除算を対数差分とすることに関しては周知の事項ではあるが、ビデオレートに追従する画像処理演算の達成、ハードウェアの簡略化に視点をおいた場合、処理の実現に向けて絶大なる効果をもたらすこととなる。結局、本方式のアルゴリズムは式(6.11)のようになり、その処理の流れを図6.5に示した。

$$\begin{aligned} \log D'_S(x, y) &= \log \{D_S(x, y) - B(x, y)\} - \log \{W'(x, y)\} \\ \log D'_P(x, y) &= \log \{D_P(x, y) - B(x, y)\} - \log \{W'(x, y)\} \\ \log D_h(x, y) &= \log \left\{ \frac{D'_S(x, y)}{D'_P(x, y)} \right\} \\ &= \log D'_S(x, y) - \log D'_P(x, y) \\ D'_h(x, y) &= \log D_h(x, y) \times G \end{aligned} \quad (6.11)$$

ただし、この式(6.11)における G は湿潤度合を画像の輝度として扱うためのゲイン補正量（定数）である。

なお、この方式においては式(6.10)のように、両偏光成分の比を求めることから式(6.9)で用いた感度むら補正用画像 $W'(x, y)$ は不要となる。しかし、各偏光画像自体を詳細に評価、検討する場合には感度むらの補正を加えて行う必要がある。

このようにして得られた画像において、路面が乾燥している状態では、 S 偏光成分 D'_S と P 偏光成分 D'_P はほぼ等しくなることから、湿潤度検出画像 D'_h （以後、検出画像と呼ぶ）は輝度値の低い（暗い）画像となる。また、路面が濡れている場合においては、 S 偏光画像 D'_S は P 偏光画像 D'_P より大きく（理想的には $D'_P = 0$ ）、検出画像 D'_h は輝度値の高い（明るい）画像が得られることになる。

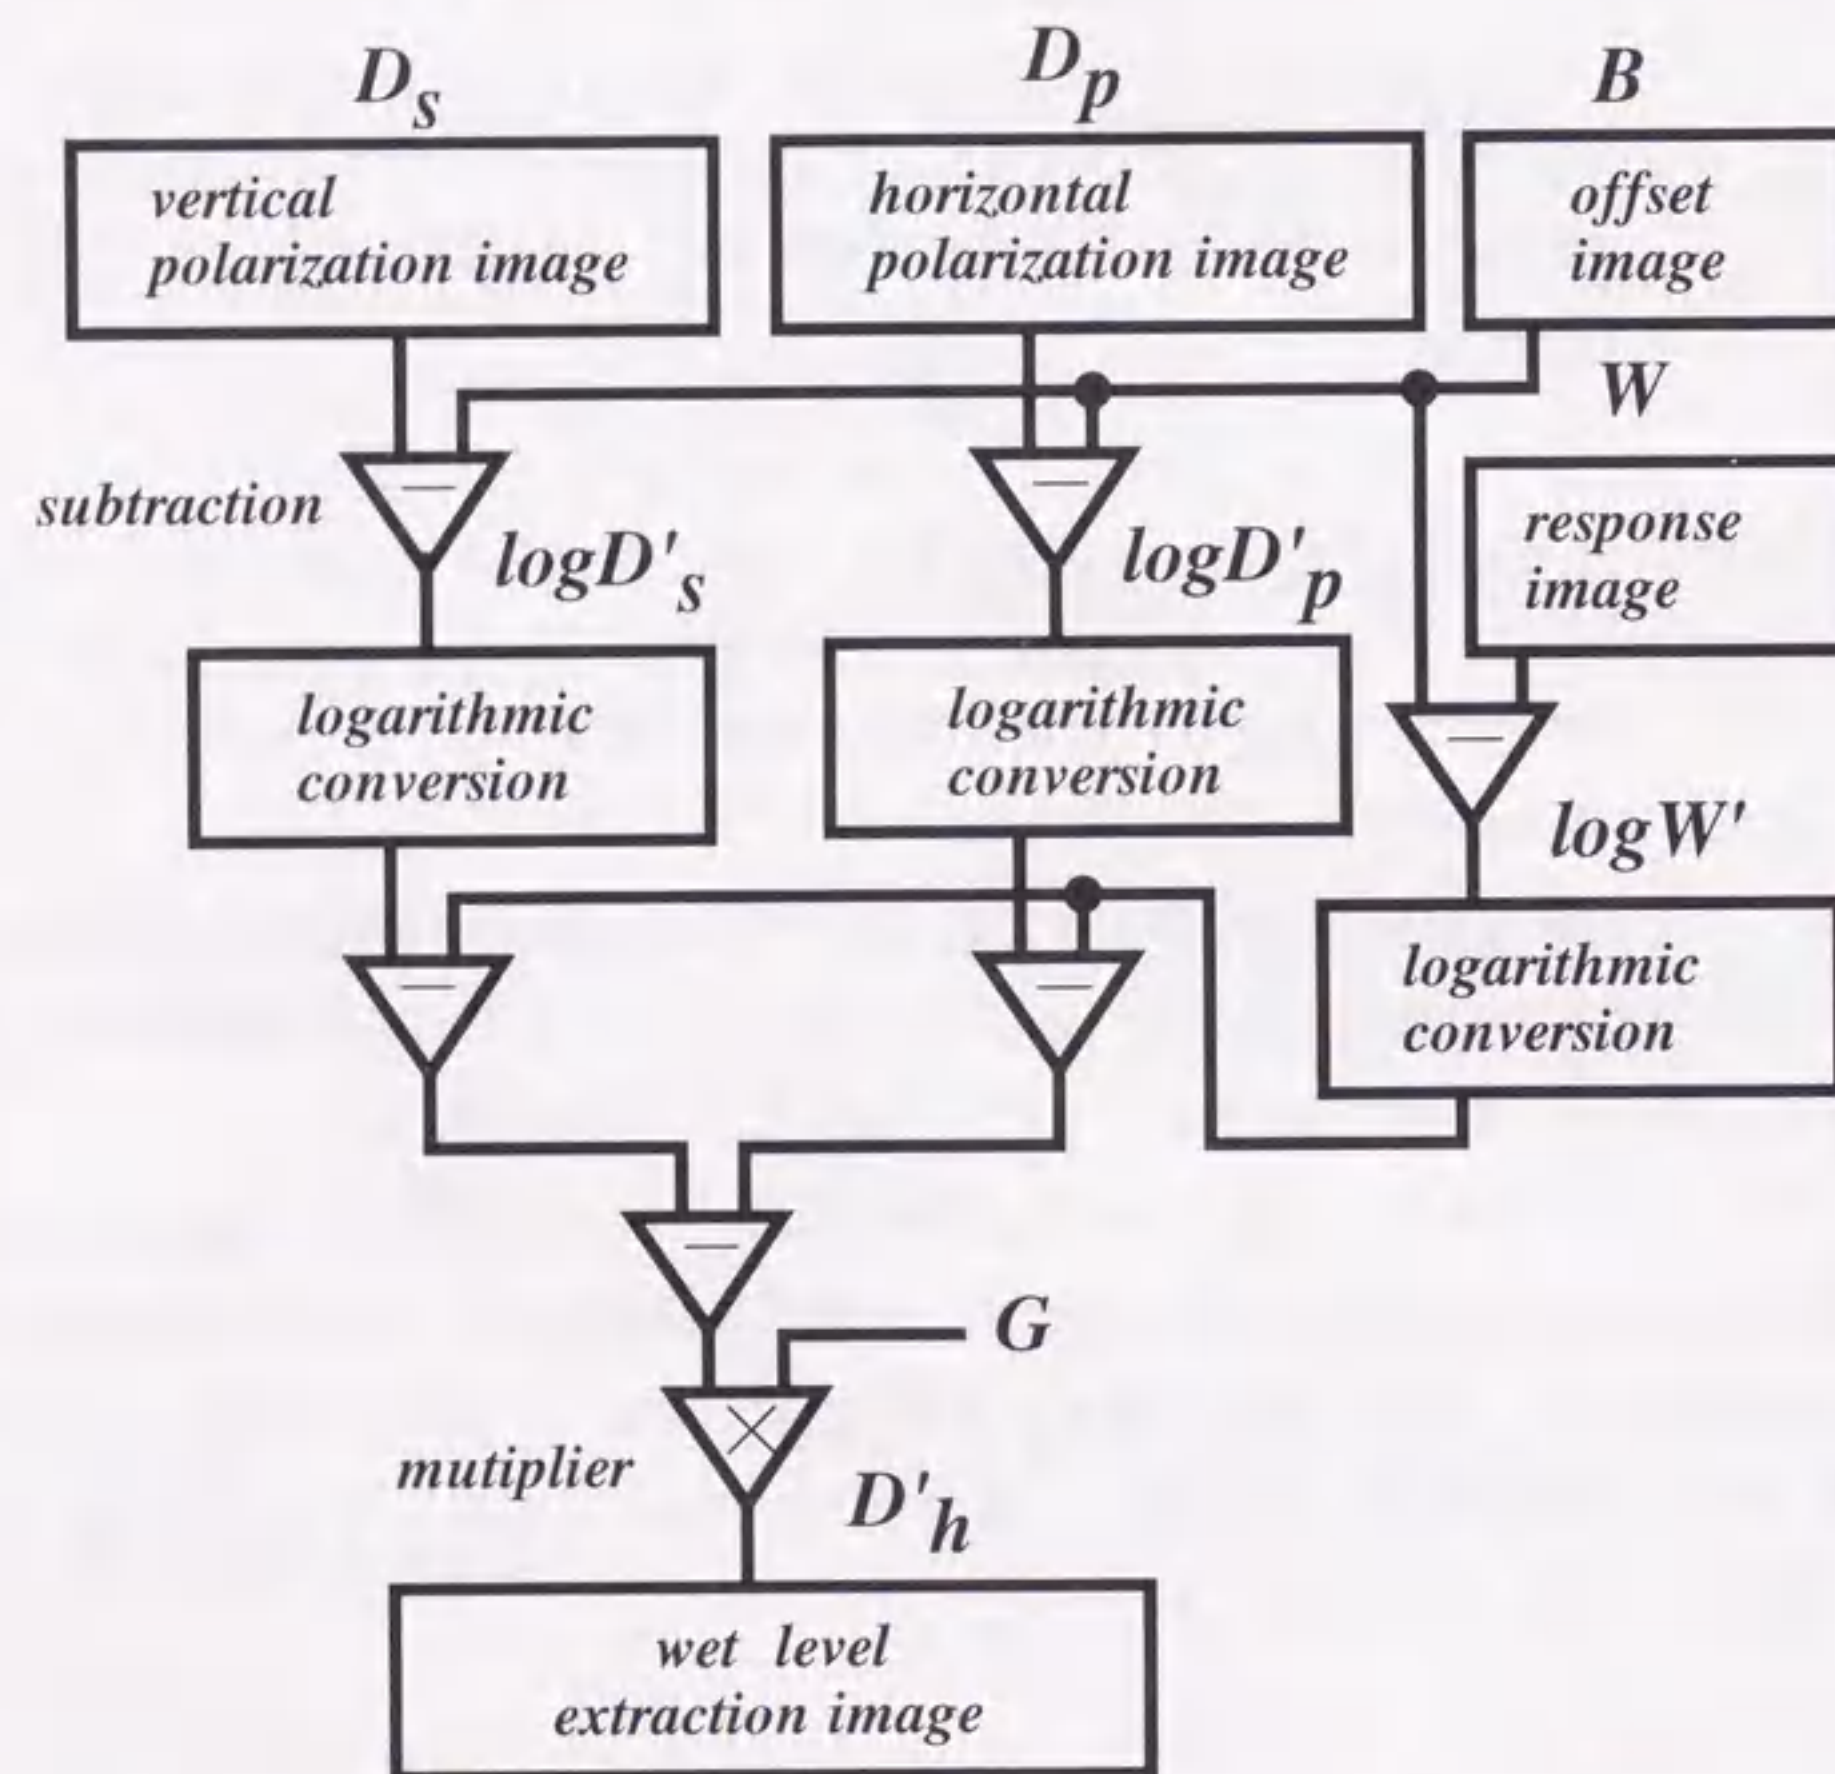


図 6.5: 処理のフローチャート

6.4 実験結果

ここで述べてきた方式を実験的に確かめるため、図 6.6 のような枠を名城大学構内の舗装部分に作り、図 6.4(b) のように、テレビカメラの角度を 53° (Brewster 角) となるように設置して撮影を行った。なお、ここで用いたテレビカメラおよびレンズの仕様は表 6.1 のとおりであり、対象となる垂直画角は鉛直に対し、約 38° から 68° の範囲となる。

この図 6.6 において左端 (a) は水が冠水状態となるようにし、右端 (c) では水を入れない乾燥状態とした。また、(b) においては (a) と (c) の中間的状态で、湿らせる程度とした。この様な状態を実際のアスファルト舗装部分に作成し、上記図 6.5 に示す流れにもとづいて処理を行い、その実験結果を図 6.7 に示した。

この図 6.7 において、(a) は撮影した垂直偏光像 D_s 、(b) は水平偏光像 D_p 、そして、(c) は本方式を施した検出画像 D'_h である。また、(d) のグラフは (c) の画像上に引いた白いライン上の輝度プロファイルを示しており、横軸は水平方向 (x 方向) の座標位置、縦軸はその位置の輝度値を示している。図 6.7(c) から明かなように、水の存在する領域は画像上において明るくなっている。また、(d) から水の量が多い枠ほど輝度値が高くなっていることもわかる。実際に撮影した場所では左側手前中央より少し傾斜しているため、そこに水が集まる傾向があった。その様子も検出画像 D'_h からはっきりと読み取れる。この結果から、路面冠水の有無および湿潤の程度が処理画像上から検出することができ、本方式による路面湿潤状況の検出が十分に可能であることがわかる。更に、実際の道路上における効果を検討するため、晴天と雨天の天候状態において、同じテレビカメラを用いて実験を行った。本実験では歩道橋上部 (約 8m) から路面を撮影し、その撮影範囲はカメラ近傍において幅約 10m (2 車線分)、遠方へ約 20m である。このように撮影された画像を用いて、図 6.5 に従い処理を施した。

ここで、晴天時の結果を図 6.8、雨天時を図 6.9 に示す。なお、この図 6.8、6.9 は処理画像の一部分を示している。この各々の図において、(a) は撮影された垂直偏光画像 D_s 、(b) は水平偏光像 D_p 、(c) は検出画像 D'_h である。そして、(d) は (c) の画像上に引いた白いライン上の輝度プロファイルを示している。この図 6.9 においても、乾燥時の図 6.8 の結果に比べ路面全体の輝度値が高く、湿潤状況が明確となっている。しかし、この図 6.9(c) の検出結果において、路側を示す白線部分では輝度値が低く、部分的に乾燥状態を示して






図 6.6: 路面上に作成した実験枠

表 6.1: テレビカメラレンズの仕様


項目	テレビカメラ仕様
撮像素子	2/3 インチ CCD(38 万画素)
カメラタイプ	B/W
走査方式	2:1 インターレス
解像度	水平 570TV 本 垂直 350TV 本
最低被写体照度	0.5lux
項目	レンズ仕様
焦点距離,F 値	12.5mm,F/1.8
絞り, フォーカス	手動
垂直画角	30°02′
水平画角	39°43′




(a) 垂直偏光画像



(b) 水平偏光画像




(c) 検出画像




(d) 白線上のプロファイル

図 6.7: 実験結果




(a) 垂直偏光画像



(b) 水平偏光画像



(c) 検出画像




(d) 白線上のプロファイル


図 6.8: 屋外での実験結果 (路面乾燥)




(a) 垂直偏光画像



(b) 水平偏光画像



(c) 検出画像



(d) 白線上のプロファイル

図 6.9: 屋外での実験結果 (路面湿潤)

いる。同様な結果が図 6.7(c) の白い枠の部分においても生じている。これは、撮影時におけるテレビカメラの絞りにより、白線部分の輝度はそのダイナミックレンジを超えて撮影されたため、この部分における輝度変化を表現できなかったことに起因する。このように撮影された画像を用いた場合、両偏光成分の輝度は同じように表現され、検出画像は低い輝度値となる。しかし、このような状況を引き起こす白線、横断歩道等は画像上において固定的で、しかも、あらかじめ既知である。そのため、路面状況の計測に限定すれば、処理上において計測対象部分から除外しておくことで、この問題が解決できる。

次に、画像処理による状況検出の効果としては面的な検出状況が得られる点がある。上記、実験結果においても路面全体の状況が把握できるが、この効果を明確にするため、路面が湿潤から徐々に乾燥していく状況において本方式を施した。この結果を図 6.10 に示す。この図において (a)、(b)、(c) は上記図 6.8、6.9 と同様である。また、(I) は路面全体が湿潤状態であり、(II)、(III) は徐々に路面が乾燥していく状況を示している。このように、(I) の (c) においては路面全体が明るく湿潤状態を示し、しかも画像中央部分に輝度の高い部分が存在していることが認められるため、この部分に水がたまっている傾向がよく表されている。また、この路面が徐々に乾燥していく (II)、(III) の検出画像 (c) においては、湿潤部分と乾燥部分がはっきり分かれており、湿潤部分の分布状態が抽出されている。このことから、従来、問題となっていた部分的湿潤による誤検出が防止できる。

このように、実際の撮影画像を用いた実験によりこの方式の効果を確認した。この結果、従来のスポット的なセンシング方式に比べ、広範囲な湿潤状況の検出が可能となった。また、その画角内における湿潤部分の分布状態についても検出が可能となる結果を得た。




図 6.10: 湿潤領域の分布状況

6.5 まとめ

自然光のもとで撮影された画像上から、偏光特性の変化を用いて路面の湿潤状態を検出する方法について示すとともに実際に路面を撮影した画像を用いた実験によりその効果を検証した。この結果、湿潤状態の有無およびその程度を処理画像上の輝度値として判別することを可能とした。また、撮影範囲の全てが検出領域となることから、従来の方式に比べ計測範囲を2次元的に広げることができた。更に、この撮影範囲における湿潤部分の分布状況についても抽出が可能になり、部分的な状況による誤検出の防止が可能となった。

ここで、この方式の特長をまとめると以下のようになる。

- (1) 特別な光源（波長、変調方式）や複雑な検出器を必要とせず、自然光を利用して計測を行うことができる。
- (2) 入射光の変動に比較的影響の少ない計測が可能である。
- (3) 冠水状態や湿潤状態を空間的広がりをもって検出することが可能であり、局所的な状況の違いによる誤検出が防止できる。（今回の実験では、幅 10m × 長さ 20m の範囲）
- (4) 処理方式内で用いられる除算演算を対数変換と差分演算に置き換えたことで、ビデオレートに追従する高速演算を可能とするとともに、ハードウェアの簡略化を実現できた。
- (5) 撮影画像を用いるため一般用の監視カメラとの共用が可能であり、付加価値の高いシステムの構築が期待できる。

このようにして、頻発する路面状況である湿潤状態を画像上から検出可能とした。上述のように、この方式では自然光を利用することで特別な光源（波長、変調方式）等は必要としない。しかし、検出領域が建物の陰等に入り込んだ場合や、自然光が著しく低下する夜間においては、検出が不可能となることが十分予想できる。その意味では、周囲の状況に応じて、照明光が必要となると思われる。しかし、この方式の原理では、光源に対し

て特別な波長、変調方式を選ぶ必要はなく、例えば、道路照明との併設や車両のヘッドライトの利用等でも対応が可能であると考えられる。ただし、これらの補助照明光の利用に当たっては、画像処理方式の特長である計測領域の広範囲化に対して問題があり、十分な検討が必要である。その他にも風等による冠水面のゆれの影響等も考えられ、ここで述べてきた方式をより多くの場面に適用し、実用上の問題点に対して深く検討していく必要がある。また、路面状況はこの他にも各種状況（路面の凍結、積雪）が存在する。今後、この偏光特性の変化を基本として、それらの状況に対しても画像上から検出する方式について検討し、実用化に向けて研究を進めていかなければならない。

第7章

フィールド画像間情報を用いた車両走行速度の検出 [56][58]

7.1 はじめに

交通状況を判断するための重要な情報収集項目の一つとして、車両の走行速度が挙げられる。従来、この非接触計測方法には、時間差型とドップラ型が実用化されている [12]。時間差型は一定距離間隔で設置されたセンサ間の車両検出時間差から計測される。そのセンサには超音波式と埋設ループコイル式が一般的である。また、ドップラ型では超音波や電波のドップラ現象を用いたものが実用化されているが、低速走行時の検出精度に問題があり、特定の速度検出以外には用いられていない [12]。更に、最近では監視映像との共用が可能で、広い検出範囲を持つ画像処理方式も開発されている。この画像処理を用いた代表的な方式としては、画像上に存在する車両成分の位置情報から単位時間あたりの移動量を求め、速度を算出している [14],[49]。

これらの状況をもとに、この章では、付加価値の高い交通計測センサとして注目を集めている画像処理を用いて、車両走行速度の新しい検出方式へのアプローチを行う。すなわち、標準映像信号から得られるフレーム画像が1/60秒間隔の2枚のフィールド画像から構成されることに注目し、このフィールド画像間に生じる車両移動量を空間周波数上のフィルタ処理により抽出する方式について示す。

7.2 フレーム画像の構成

映像信号は、ODD、EVENの2枚のフィールド画像で1フレーム画像を構成し、目視時のちらつきを防止するため、モニタ上では2:1インターレース走査が行われる。この信号形態のもとで移動車両を撮影した場合、モニタ上には車両位置の異なる2枚の画像が交互に置かれ、ズレのある画像が表示される。従来、このズレの影響を避けるため、フィールド画像のみを対象として処理が行われることが一般的である [50]。しかし、このズレの成分は1/60秒間に車両が移動した距離を示していることになり、次節ではこのズレの積極的な検出方法について示す。

7.3 検出方式

車両が走行している状態の映像信号をサンプリングした場合、各フィールド画像は図7.1(a),(b)のようになる。この2枚の画像を交互に置いたフレーム画像は図7.1(c)のようになり、車両のエッジ部分に1画素間隔で車両輝度の繰り返し成分が生じる。例えば、車両前端ではODDフィールド画像の路面輝度とEVENフィールド画像の車両輝度が交互に表示されている。




図 7.1: フィールド画像とフレーム画像

この輝度の繰り返しは、空間周波数上において、最高周波数（ナイキスト周波数）になることから、この周波数成分を抽出すれば 1/60 秒間の移動距離を知ることができる。この抽出方法として、次式のように 2 次元空間周波数上でフィルタ処理を行う。

$$I(\omega) = F\{i(t)\} \quad (7.1)$$

$$H(\omega) = I(\omega) \cdot G(\omega) \quad (7.2)$$

$$h(t) = F^{-1}\{H(\omega)\} \quad (7.3)$$

ここで、 $i(t)$ は時刻 t にサンプリングされたフレーム画像を示し、 F は 2 次元フーリエ変換演算である。また、 $G(\omega)$ は空間周波数上のフィルタ関数を示し、 ω は空間周波数である。また、 F^{-1} は逆フーリエ変換演算である。なお、式 (7.2) のフィルタ関数 $G(\omega)$ は式 (7.4) のように、ナイキスト周波数を中心としたガウス関数を用いた。

$$\begin{aligned} \omega_y \geq 0 : G(\omega_x, \omega_y) &= \exp\{-a(\omega_x^2 + (\omega_y - \omega_n)^2)\} \\ \omega_y < 0 : G(\omega_x, \omega_y) &= \exp\{-a(\omega_x^2 + (\omega_y + \omega_n)^2)\} \end{aligned} \quad (7.4)$$

ここで、 ω_x, ω_y は空間周波数、 ω_n はナイキスト周波数、 a はガウス関数の主軸方向の傾きであり、その関数の形状は図 7.2 のようになる。このガウス関数は、実空間への逆変換の結果もガウス関数として表現されるので、他のフィルタ関数のように、サイドローブによる輝度のリングングが生じないことから用いることとした。

このようにして得られた結果画像 $h(t)$ 上には、ナイキスト周波数成分を含む領域が抽出され、抽出成分の車両進行方向 (y 方向) の幅が 1/60 秒間の移動量となる。なお、この y 方向移動幅成分は矩形形状ではなく、ガウス関数形状として出力される。そこで、真の移動幅を一意に決定するため、シミュレーションデータを用いて、移動幅変換テーブルを作成した。このシミュレーションデータを図 7.3(a) に示し、(b) に処理画像を示す。(c) は処理画像 (b) 上における抽出成分のプロファイルであり、得られるガウス形状の輝度範囲による影響を避けるため、最大輝度値の 50% 幅を用いて真値との関係を作成した。このシミュレーション画像を複数作成し、得られた変換テーブルを (d) に示す。






図 7.2: フィルタの形状




(a) 対象画像

(b) 処理画像




(c) (b) 上のプロファイル



(d) 変換テーブル

図 7.3: シミュレーションデータを用いたテーブル作成

7.4 実験



(a) 原画像

(b) 処理画像

図 7.4: 処理画像例

図 7.4(a) は一定速度で車両を走行させた撮影画像の一例で、(b) は本方式の処理結果画像を示す。なお、車両はデジタルスピードメータを登載しており、そのメータの読みについては、一定距離の走行時間により校正した。また、撮影に関しては、図 7.5 のように高さ 8.2m の歩道橋上部から、約 31m 先までの距離を撮影しており、その映像中の連続フレーム画像 10 枚を取り込み、各々の画像に対して上述の処理を施す。そして、各処理画像内における移動幅成分の平均値を算出し、撮影幾何学系へ当てはめることで車両速度を算出した。また、従来方法との比較のために、1 フレーム画像を ODD、EVEN の 2 枚のフィールド画像としてとらえ、両画像間の相互相関により移動速度を算出する方式も合わせて試みた。その結果を図 7.6(a),(b) に示す。ここで、(a) については車両速度 37km/h、(b) は 35km/h の一定走行時の結果であり、図中の実線は本方式の結果、一点鎖線は従来方式の結果であり、点線は真値を示す。そして、この結果を定量的に評価するため、真値からの標準偏差を求め、これを表 7.1 に示した。

表 7.1: 真値からの標準偏差

速度真値	従来方式の 標準偏差 (km/h)	本方式の 標準偏差 (km/h)
37km/h	5.84	2.57
35km/h	5.09	2.15

この結果から、本方式では 37km/h、35km/h の実画像において、従来方式と比べ良い結果を得ているとともに、その精度においても、真値からの標準偏差が 10% 未満となり、満足の結果を得た。しかし、図 7.6 から明かなように、テレビカメラの設置位置から離れるに従い、誤差が正方向に大きくなる傾向がある。これは、遠近歪により遠方における 1 画素の占める距離が長くなり、若干の誤差でも実距離では大きく影響されるためであると考えられる。また、遠方へ行くほど車高成分の倒れ込みが大きく、抽出された移動幅が車高分前方へ倒れ込むため、実距離への換算時にこの正方向の誤差を生じると考えられる。

7.5 まとめ

交通計測項目の一つである車両走行速度計測法に関して、フィールド画像間に生じる車両の移動がフレーム画像上においてナイキスト周波数成分を持つことに着目し、空間周波数上におけるフィルタ処理により、この移動量を検出する新しい方式について述べた。そして、実際の撮影画像に適用し、その精度について検証したところ、真値からの標準偏差で 10% 未満の良い結果を得た。本方式では特に、1 フレーム画像のみからの速度抽出を可能としており、これまでにない計測方式を達成した。

今後、より高い精度を得るために、周波数フィルタの形状、移動量換算に対する考察、抽出成分の SN 比向上等についての検討を加える必要がある。また、誤差、精度の理論的な考察等のアプローチに関しても重要な検討項目である。更に、これらの検討結果をもとに、適用データを増加して検証を重ね、処理方式の安定化を図る必要がある。




図 7.5: 撮影幾何学系




図 7.6: 実験結果

第 8 章

あとがき

8.1 本研究の成果とまとめ

本論文では、道路交通における種々の計測項目に対して、新しいセンシング方式を確立することを目的として、画像処理を用いたアルゴリズムおよび知的計測方式について提案し、それぞれの方式に対して実用上への検討ならびにその結果の確認についてまとめたものであって、まず最初に交通計測項目の中から、駐車状況の検出に関して検討を加えた。

すなわち、第 2 章では高速道路のサービスエリアおよびパーキングエリアにおいて、従来方式の持つ問題点であった車両感知誤差の累積を防止することを目的として、駐車場内部を直接的にしかも広範囲に監視する画像処理方式について検討を加えた。ここで用いた画像処理方式としては、まず、撮影時に生じる台形状の遠近歪に対して、画像メモリ間の画素の置き換えにより任意の方形形状へ変換する高速な補正方式をはじめて提案した。この高速補正方式の達成により、対象領域である駐車マス内のラスタスキャン的走査が可能となり、演算効率の大幅な向上を達成し、車両抽出の前処理として確立した。そして、車両抽出方式としては、車両が移動体であることに注目し、一定時間間隔毎の画像間で差分処理を行うシーケンシャルサブトラクションを採用することで、自然環境の輝度変動に極めて影響されにくい移動車両抽出方式を提案した。また、駐車、空有状態の判断に関しては、シーケンシャルサブトラクションにより抽出された移動車両成分に対し、駐車マスを基本単位として抽出成分の重心座標を逐次算出し、その重心座標の軌跡から車両の方向性および停止状態を検出することで各駐車マスでの駐車、空有状態を判断する動画像処理

を達成することができた。この駐車マス単位での車両状態の検出および管理は、誤差発生に対しても次回の車両状態の検出時に修正がなされ、誤差の自己修正が可能であり、従来方式が持つ誤差の累積問題を解決した。このように、本章では駐車、空有という車両の静的な状態をその移動過程から動画画像処理により抽出するという新しい方式を構築し、更に、それを実際のパーキングエリアにおける録画画像を用いて検証した結果、正解率 80 % 以上の高い精度を確認することができ、実用化への大きな第一歩となった。

第 3 章では、第 2 章で採用したシーケンシャルサブトラクションにおいて、その移動車両抽出像の大きさが車両の走行速度に依存して変化することを改良するため、新たに背景差分処理による移動車両抽出方式について提案した。すなわち、従来の背景差分処理においては、初期状態に取り込まれる背景画像上に車両が存在した場合その車両部分の背景が更新されず安定な車両抽出ができないことに触れ、時間的に輝度変化の生じない領域については車両であっても背景の一部として扱い、背景画像の更新を行うように演算方式を改良し、従来の方式の持つ問題点を完全に解決することができた。また、背景更新量の関数化を行い、より安定な背景更新方式を示した。更に、この背景更新の関数演算部分をテーブル化し、適切な関数の選択を容易にし、高い SN 比の車両抽出を可能とするとともに、演算量の低減をも達成した。この関数演算のテーブル化はハードウェアの容易性に関しても絶大なる効果を発揮し、実際に試作システムを作成して評価を行ったところ、元来、浮動小数点演算器等を含む複雑な構成となるものが加減算器、テーブルメモリ等の簡単な構成で実現可能となり、ビデオフレームレートに追従するより高速なハードウェアを構築できた。そして、このハードウェアを用いて、各種録画画像での方式の確認を行い、屋外輝度の変動に対してダイナミックに追従可能な移動車両抽出のための背景差分方式を確立した。

このような画像処理方式を用いることで、従来のスポットセンサが成し得なかった検出領域の広範囲化を達成することができたが、高速道路におけるサービスエリアやパーキングエリアのような数百台に及ぶ駐車容量の駐車場にシステム導入をする場合、画像処理方式と言えどもテレビカメラの設置台数が増加し、システム展開上での問題を持つ。このような実用上の課題に対して、第 4 章ではテレビカメラの設置数を削減し効率の良いシステムの確立を目的として、人間の知的処理を模範にし、部分的な状況から全体の状況を

推定することでこの目的を達成することを考慮した。この場合、部分状況の抽出のみで全体状況を判断できることから、センサ設置台数の削減が可能になる。そして、この知的推定方式としてニューラルネットワークモデルを新たに採用し、汎化能力を持った推定方式を構築した。この推定モデルの評価として、実際に収集した駐車状況データにそれを適用し、「満車」、「混雑」、「空有」の 3 ランク推定を行った結果、部分状況と全体状況の間の相関関係が低い場合において、従来の回帰分析による予測方式の推定精度が著しく低下するのに対して、この方式ではそれらの影響をほとんど受けず、安定な推定結果が得られることが確認された。この成果をもとに、駐車状況判別装置として画像処理を含めたシステムを東名高速道路下り線足柄サービスエリアへ設置し、評価を行ったところ、実用上十分な精度であることを確認することができた。

第 4 章での推定方式が上記 3 ランクへの弁別を達成しているのに対し、第 5 章では、駐車状況の基本となる駐車率を部分状況から直接推定するニューラルネットワークについて検討した。この駐車率を直接推定する場合、ニューラルネットワークの出力は $[0,1]$ の範囲の連続値である必要があることから、出力層のニューロン数を 1 個とし、連続値を直接出力する構成とした。しかし、一般的に用いられているニューロンの応答関数（シグモイド関数）では 0,1 の極値において土無限大の入力を必要とすることから、その応答関数として線形関数を採用した。そして、 $[0,1]$ の範囲で変化する \sin 関数値を評価対象としてシミュレーションを行い、リニア関数を出力ニューロンの応答関数としたアナログ出力ニューラルネットワークの極値での推定能力の高さおよび推定精度高さを確認した。また、実際の駐車率推定に関しては、東京外環道新倉パーキングエリアに新たに導入したシステムでの収集データを用いて評価を行い、真の駐車率からの標準偏差で 10 % 以内の良い結果を得ることができ、実用上においても十分な推定精度であることを確認することができた。

第 6 章では道路交通計測の中で運転環境認識の分野である路面状況の認識方式について検討した。従来の路面状況検出方式では、特定光源による投受光の関係を抽出していたことから、その検出範囲が直径数十 cm 程度の局所情報であり、信頼度の向上のため、より広範囲な検出方式が求められていた。本章では、特に、路面状況の中でも頻発する湿潤状況を対象として、湿潤時の路面が水で覆われることで鏡面となることに注目し、自然光

源のもとで撮影された水平、垂直偏光画像間の輝度値の比を算出することで輝度変動に対して比較的安定した湿潤状況の抽出方式を確立し、画像処理による広範囲な湿潤状況検出を可能とした。また、この検討を行うにあたって、画像撮影時に混入するビデオ回路系からのオフセット誤差および撮像面の感度むらの補正についても合わせて検討しており、厳密な計測方式を確立することができた。更に、画像間の比の演算を対数差分として表現し、演算量の低減、ハードウェア化への容易性をも得た。そして、この方式の効果を検証するため、実際の路面上に冠水、湿潤、乾燥の3つの状態を作成して、本方式のシミュレーションを行った結果、処理結果画像の輝度により、乾燥、湿潤の違いを明確に弁別できることを確認した。また、実際の雨天時での評価についても、シミュレーション結果と同様の抽出結果を得た。更に、雨天時から路面乾燥への路面状況の変化過程において、湿潤領域の分布状況を2次元平面上で明確に抽出でき、画像を用いた広範囲な検出に関する効果についても確認することができた。

第7章では、交通流計測の基本となる車両走行速度計測方式として、走行車両を標準的なテレビカメラで撮影した場合に生じるズレ成分の積極的な抽出方法について新しいアプローチを行った。この方式ではモニタ上に表示される走行車両のズレ成分がODD,EVENフィールド画像間(1/60秒間)における車両の移動距離を示すとともに、モニタに映されるフレーム画像上ではナイキスト周波数成分となることに注目した。そして、空間周波数上の車両進行方向ナイキスト周波数を中心としたガウス関数による周波数フィルタにより、その移動成分のみを抽出し、速度算出を達成する方式を確立した。更に、定速走行状態の録画画像を用いてこの方式の速度精度を算出した結果、真の速度に対する標準偏差が10%以内の高い精度を得ることができ、この全く新しい方式の有用性を確認することができた。

以上のように、本研究は道路交通状況の監視、計測、制御の分野における駐車状況検出、路面状況検出、車両走行速度検出の大きな3つの計測項目を対象とした画像処理応用方式と駐車状況検出については知的状況判別方式についても合わせてまとめたものである。第2章から第5章で対象とした駐車状況検出に関しては、画像処理の特長を十分に生かし、従来センサが成し得なかった広範囲にわたる状況の扱いを可能とする実用レベルの処理方式を確立することができた。また、この方式は移動車両の抽出、追跡を主体に

構成しており、この検出項目に留まらず、交通流計測の基本としてもその応用価値は大きい。更に、ニューラルネットワークによる知的計測方式の採用により、システム実装上の問題であるテレビカメラの設置台数の削減も可能とした。この2つの技術により我国で最初の画像処理による駐車状況判別システムの実用化に成功しており、交通計測分野における工業的意義は極めて大きいものである。また、第6章で対象とした路面状況の検出についても、画像処理を用いることで広範囲な状況検出を達成しており、情報の信頼度の向上につながるものである。また、この計測項目に関する画像処理応用については、これまではほとんど触れられてきていないのが現状であるが、ドライバの安全運転の確保に欠かすことのできないものである。

なお、第7章での車速計測方式に関しては、これまでに類を見ない全く新しい方式を確立することができた。また、ここで述べてきた画像処理方式のすべてが自然環境のもとでの計測であり、それぞれの方式の中で輝度変動に対する配慮を行っている。また、現在のハードウェア技術の基盤上に立った検討を随所に盛り込んでおり、これらの成果は今後の各種道路交通計測へのアプローチに関する基礎として重要な資料になるものであると思われる。

8.2 今後の課題

第2章および第3章で述べた車両検出方式は、実用性の高い一つの方式であるが、実用上のニーズの変化も考え得る。その意味では、この研究で得た成果、実フィールドの振る舞い等を基盤に置き、新しい方式へ目を向けることも重要な課題である。また、第4章および第5章で用いたニューラルネットワークに関しては、その構造的検討および各種係数との関係が明確になっていない。これらの検討により、より精度の高い判定機能の確立を目指す必要がある。

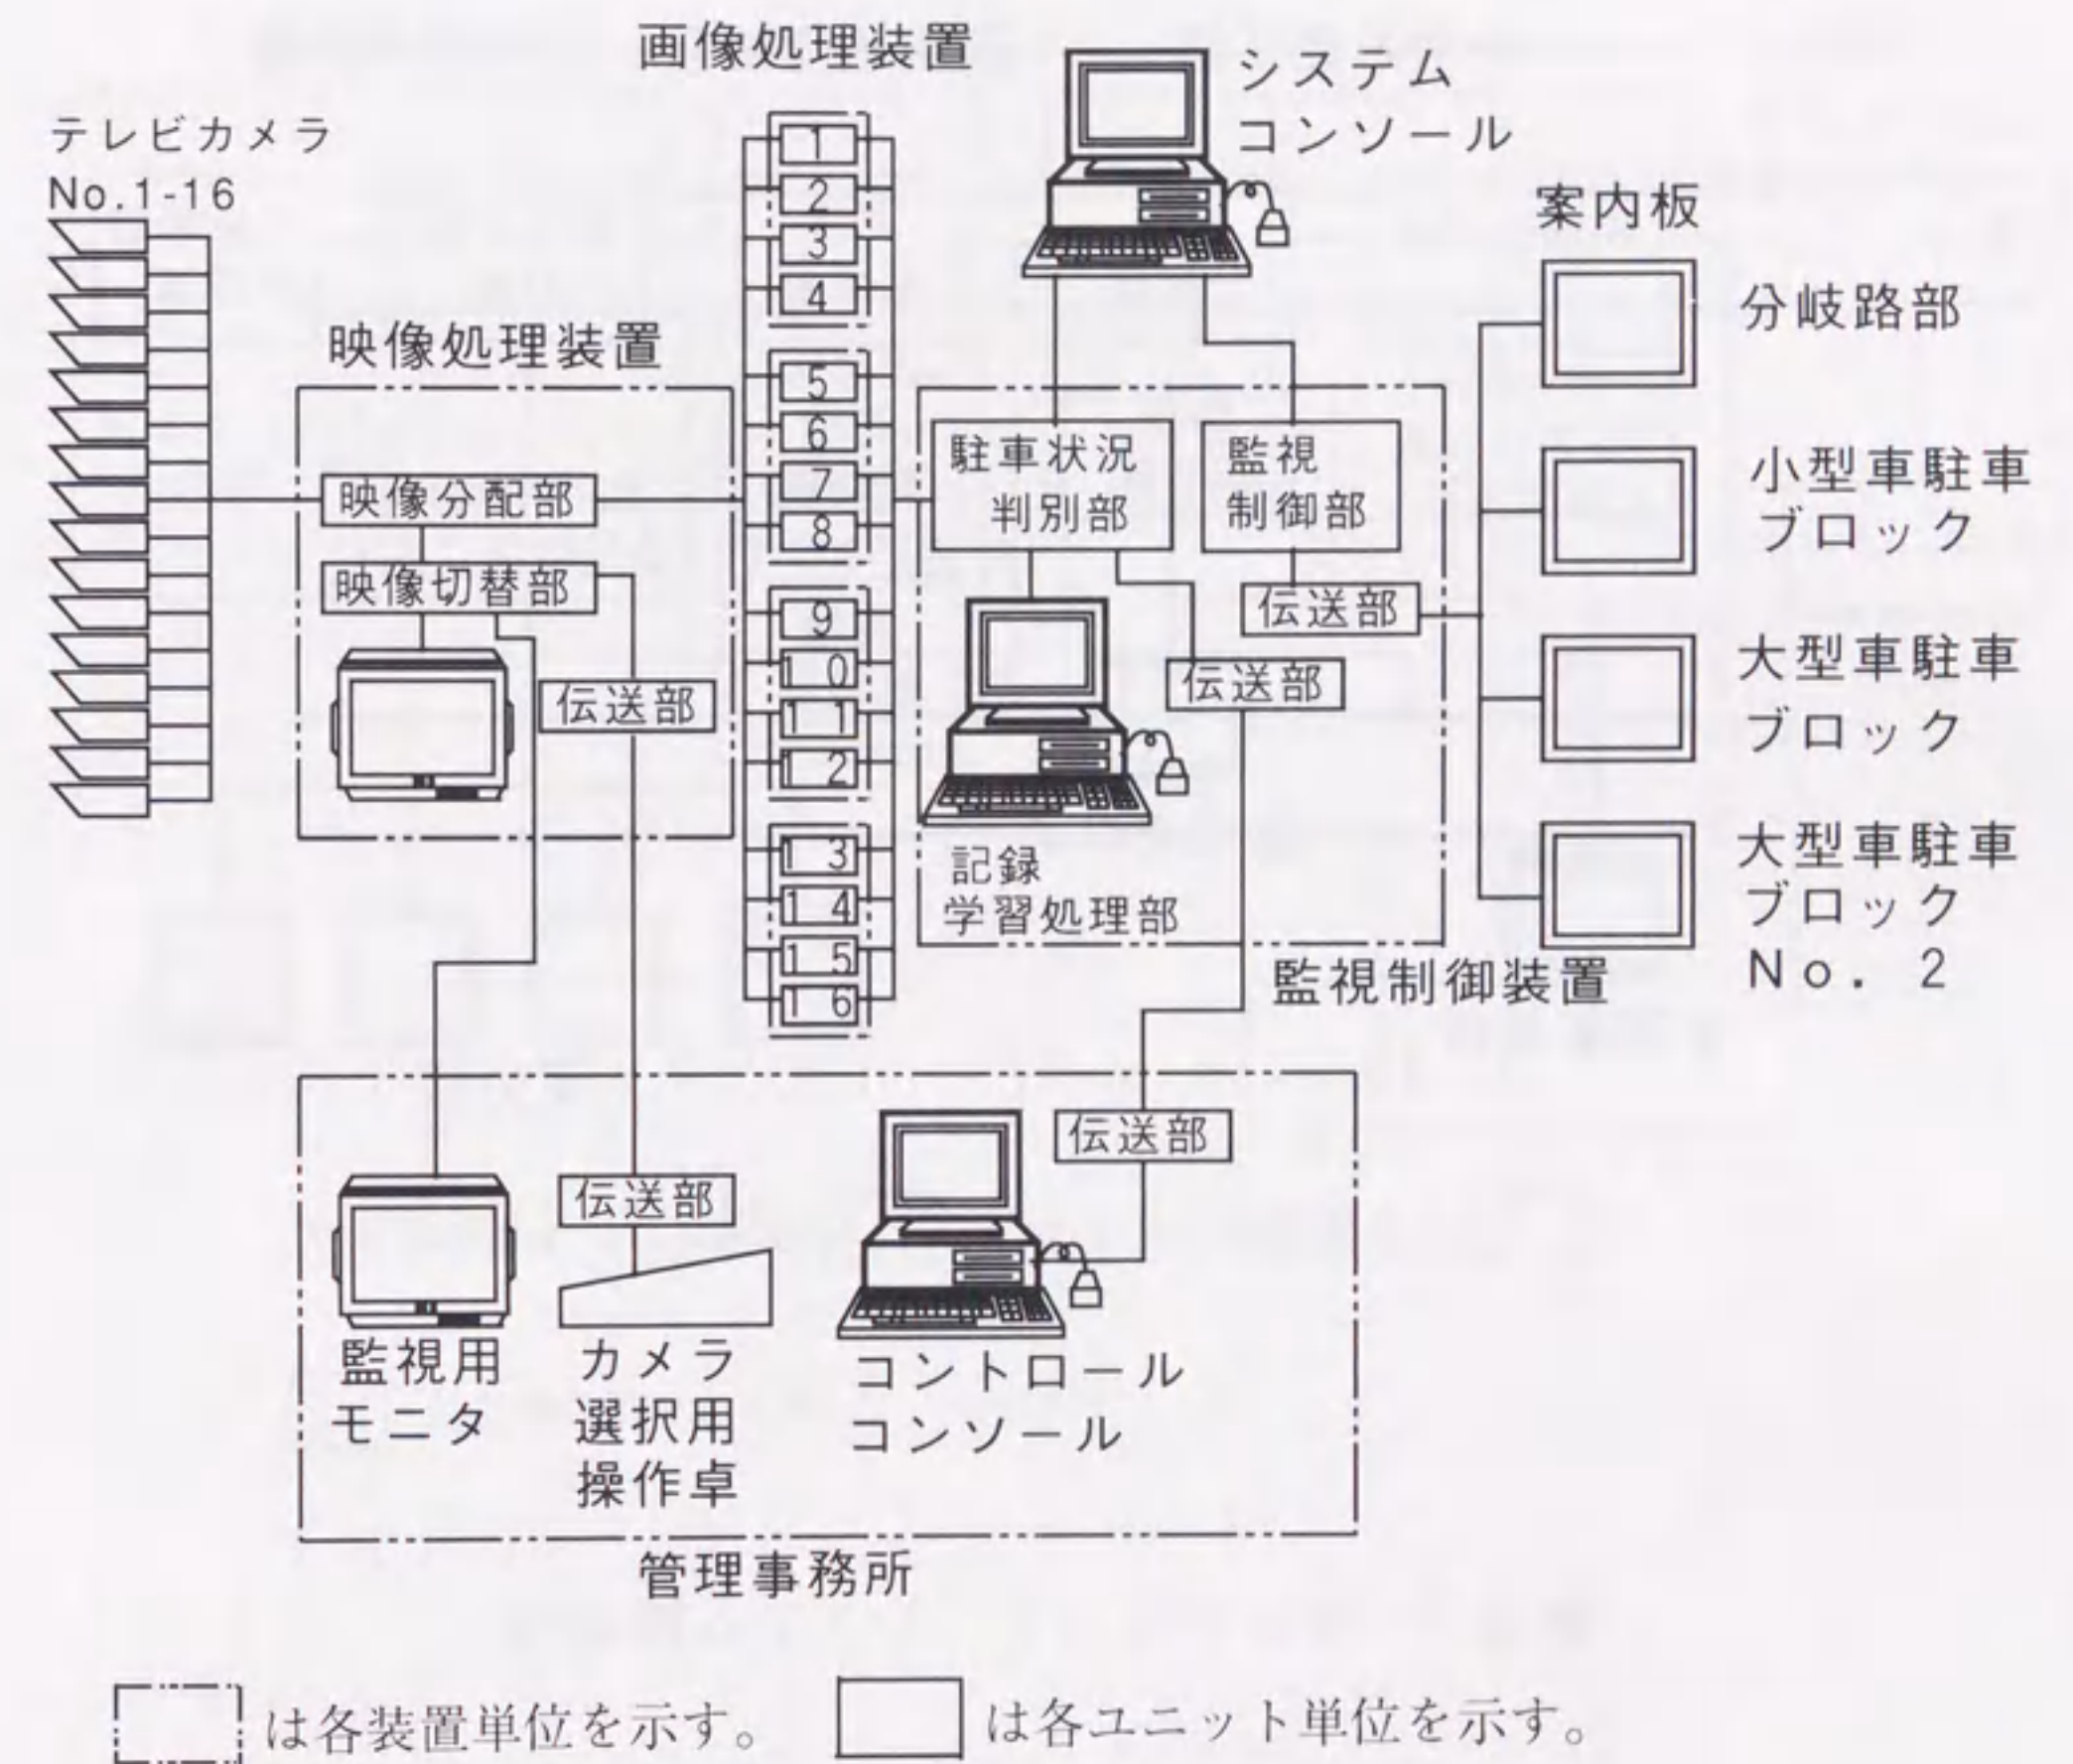
第6章では路面湿潤を対象としたが、自然界における路面状況としては、この他に凍結、積雪等、安全運転確保のために重要な状況検出項目が検討されていない。今後、これらの残された課題に対して順次取り組んでいく予定である。

第7章では新しい速度検出方式について述べたが、今後、各種環境条件のもとでの適用を行い、処理の安定化の検討および問題点の抽出、改良を重ね、ハードウェアも含め、

実用化を目指した処理のまとめが必要である。

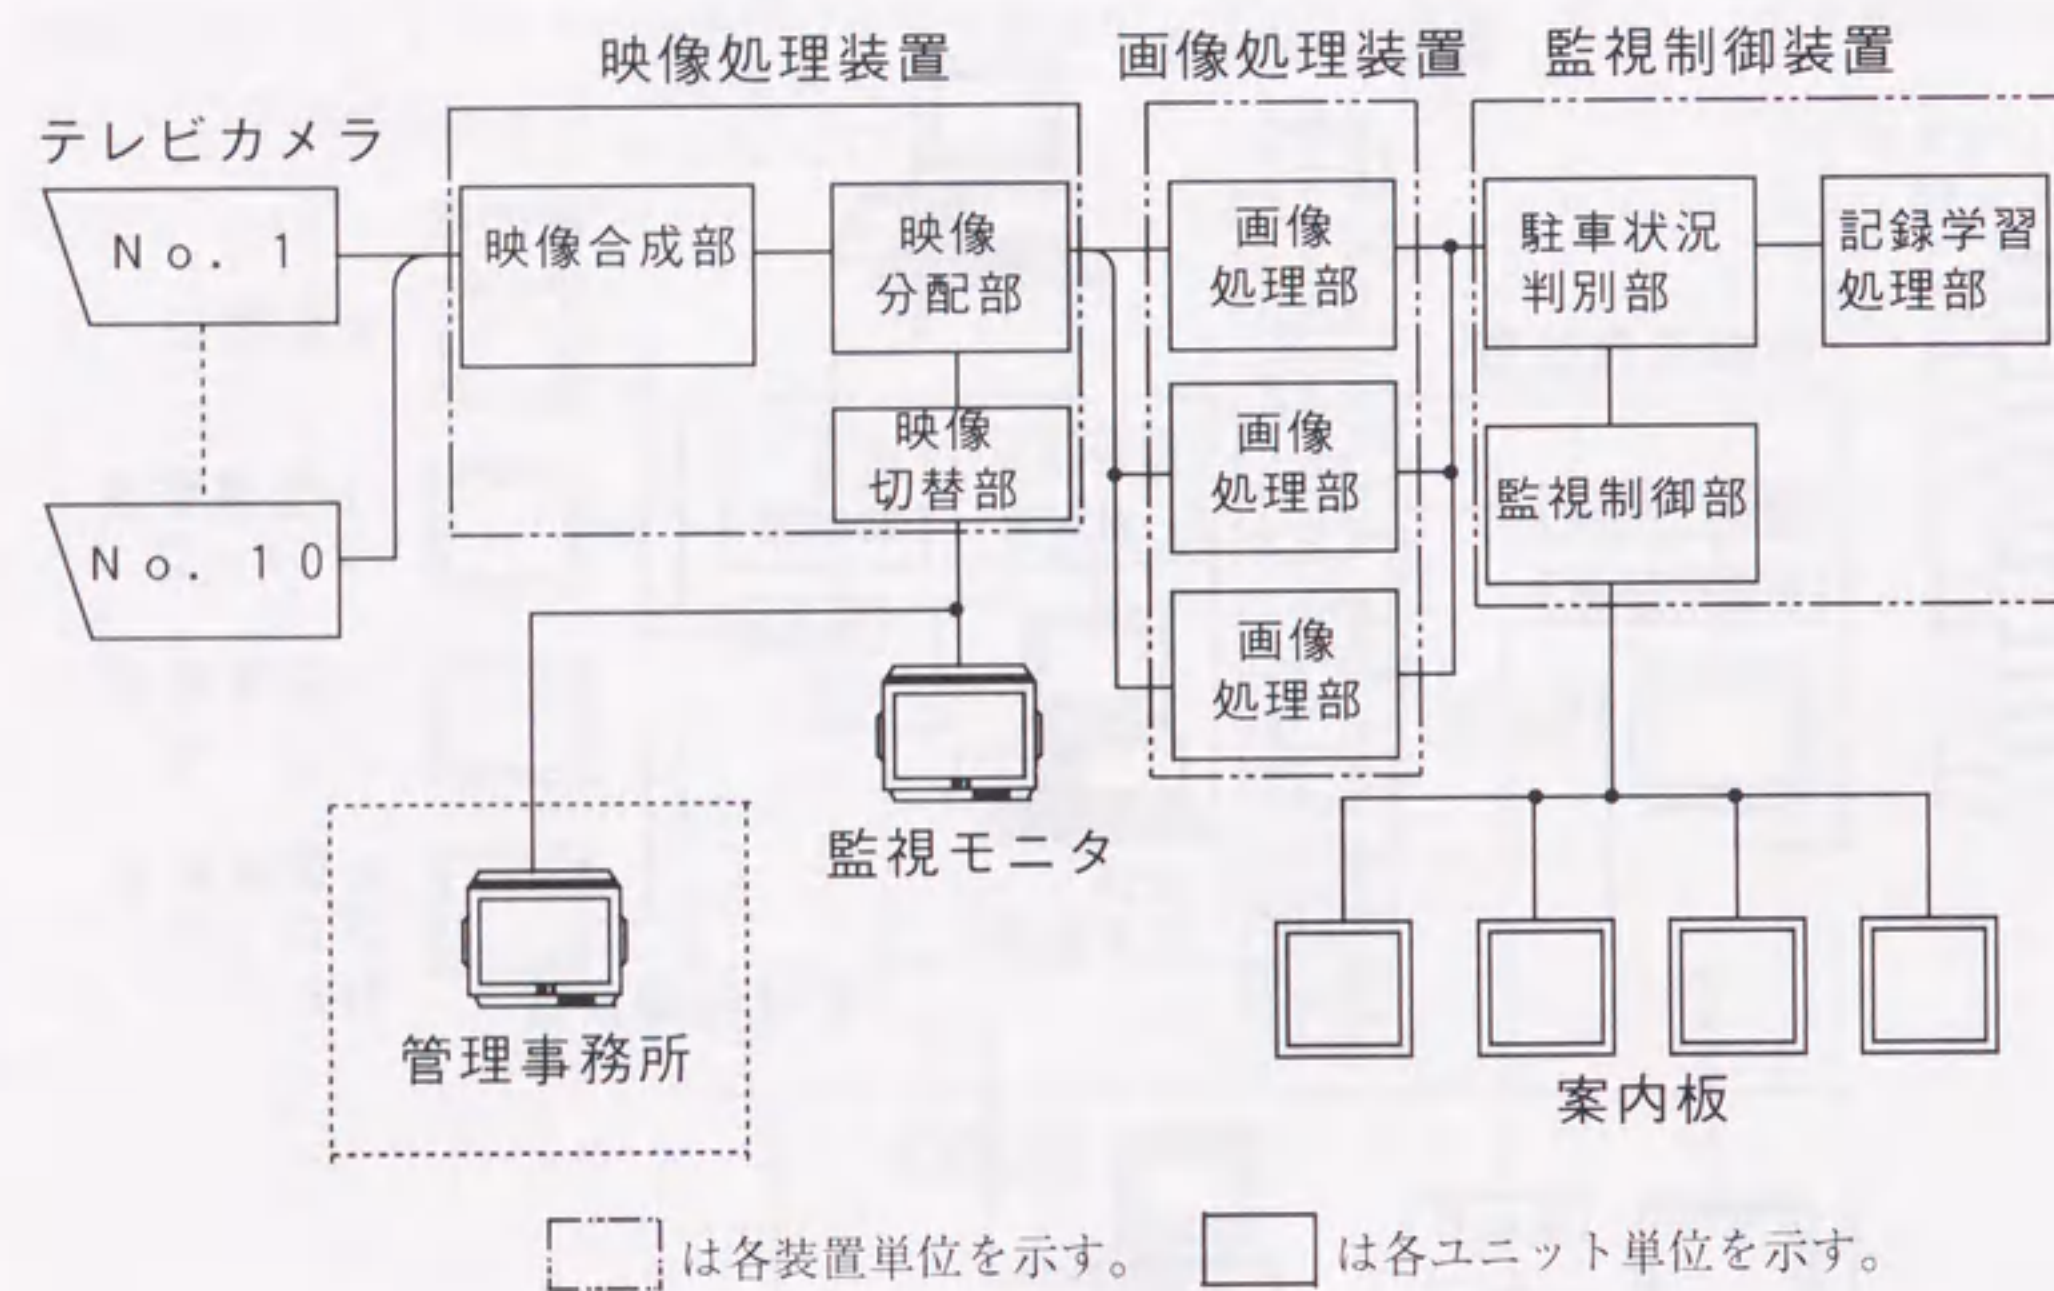
更に、交通計測分野において検討が待たれている各種計測項目、研究課題に対しても、本研究で得たフィールドでの知識、成果を基盤とした新しい研究、アプローチを積極的に行っていく予定である。

付録 A



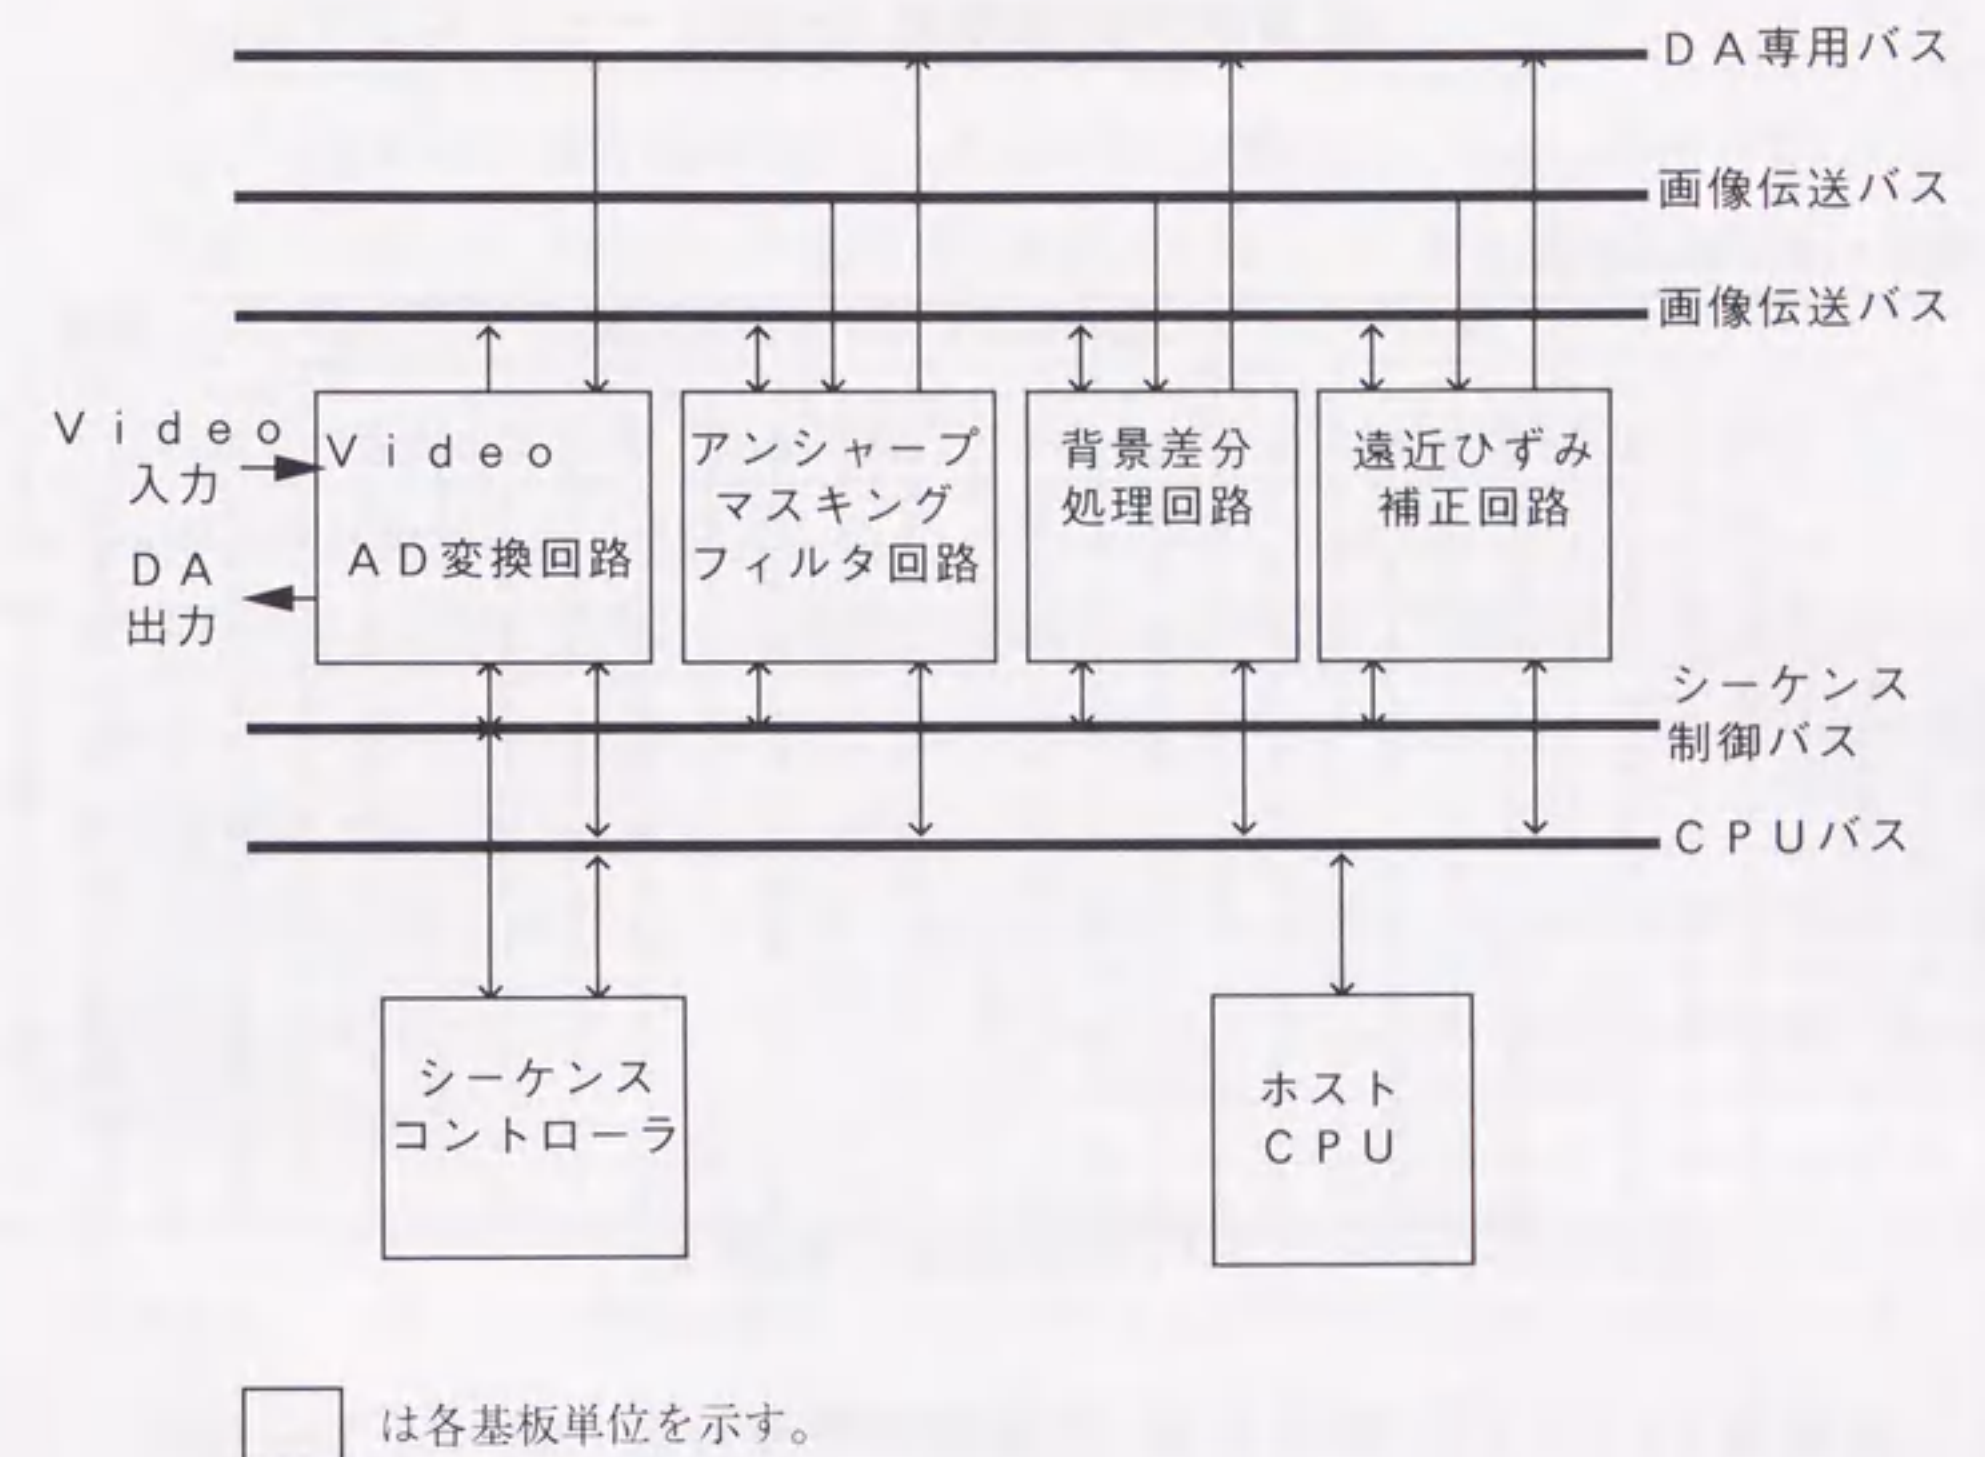
足柄サービスエリア システム構成図

付録B



新倉パーキングエリア システム構成図

付録C



画像処理部システム構成図

付録D

駐車車両認識精度 (足柄サービスエリア)

計測日：1991 年 6 月 17 日

時刻	各 ITV カメラの監視範囲に対する誤差台数														誤差 小計	正解率 (%)
	No.2	No.3	No.4	No.5	No.6	No.7	No.8	No.9	No.10	No.11	No.12	No.13	No.14	No.15		
13:00	2	0	1	0	0	0	0	0	4	0	5	2	0	3	17	93.5
13:10	0	2	1	6	0	1	4	0	2	3	5	1	2	3	30	88.5
13:20	1	1	1	2	1	3	0	0	3	1	1	2	1	3	20	92.4
13:30	3	0	2	2	1	1	2	6	2	1	0	1	2	3	26	90.1
13:40	1	0	0	2	2	2	1	6	4	1	0	2	2	1	24	90.8
13:50	0	2	0	1	0	1	0	4	2	0	2	1	0	1	14	94.7
14:00	0	1	1	3	1	2	1	6	3	0	2	2	0	0	22	91.6
14:10	0	1	1	3	0	0	1	3	6	1	3	4	1	2	26	90.1
14:20	0	2	3	3	2	2	1	2	4	3	3	1	1	1	28	89.3
14:30	0	1	3	4	0	1	1	0	6	3	3	1	1	1	25	90.5
14:40	1	1	1	2	2	3	1	2	2	3	4	2	1	1	26	90.1
14:50	2	0	0	3	2	1	1	7	2	1	4	2	1	1	27	89.7
15:00	2	2	0	4	3	3	1	4	3	1	4	2	2	1	32	87.8

(No.2~No.15 は第4章図4.1のITVカメラの監視範囲に相当する)

$$\text{正解率 (\%)} = \{1.0 - (\text{誤差台数} / \text{監視駐車車両台数 (262 台)})\} \times 100$$

謝辞

本研究を進めるにあたり、多くの方々のお世話になりました。すべての方を網羅することはできませんが、特にお世話になった方のお名前を記し、心から御礼を申し上げます。

本論文に関して、終始熱心な御指導と御教示を賜った名古屋大学鳥脇純一郎教授に心から厚く御礼申し上げます。

本論文の作成にあたり、数々の御教示を賜った名古屋大学内川嘉樹教授並びに名古屋大学大西昇教授に深く感謝致します。

本研究を進めるにあたり、昭和61年名城大学大学院修士課程入学から現在までの長きにわたり、いろいろ御指導、御検討、御助言等を下さり、終始支えていただいた名古屋大学名誉教授池谷和夫先生に心から御礼申し上げます。

本研究の全般に関して、大局から細部に至るまで御指導、御検討をいただき、研究の進め方、研究者としてのあるべき姿をお教えたいただいた、名城大学理工学部電気電子工学科堀場勇夫助教授に心から感謝致します。

本研究の成果は名城大学情報システム工学研究室との共同研究により得たものであり、卒業研究の一環として研究に参加していただきました研究室の皆様に感謝の意を表します。

また、このような研究の機会を与えて下さるとともに、終始暖かいご支援をいただきました名古屋電機工業株式会社代表取締役社長服部正裕氏、常務取締役服部哲二氏、顧問井上賀方氏、並びに技術部部长小野寺浩氏に感謝の意を表します。

最後に、本研究は、苦勞をともにした名古屋電機工業株式会社技術部開発課の皆様の多大な協力を得て行ったものであり、ここに深く感謝の意を表します。

参考文献

- [1] 国分直樹 小島秀登 小沢慎治：“領域分割された画像からの車両の抽出法”信学春季全大 D-261 pp.253 (1988).
- [2] 高橋裕子 石井健一郎：“駐車場内の車の有無判定”信学技報 IE89-114 pp.47-53 (1990).
- [3] 建設省：“路面積雪計および凍結検知器の開発”評価書 建技評第 79104 号 pp.10-12 (1980).
- [4] 板倉安正 堤捨男 竹鼻俊夫：“反射の偏光特性を利用する車両登載用路面湿潤状態検出センサ”，照明学会論文誌，Vol.66，No.10，pp.20-24，(1982).
- [5] 尾上守夫 浜野亘男 大場一彦：“差信号 I T V による交通流計測”電学全大 pp.642 (1973).
- [6] 山本裕嗣 内藤丈嗣 辻邦彦 黒川正幸：“画像処理によるトンネル内交通流監視支援システム”，電気学会道路交通研究会，RTA-92-12，(1992).
- [7] K.Sakai M.Ishige T.Itoh and T.Uemura：“In-Tunnel Traffic Flow Measuring and Monitoring System Using ITV Cameras”26th International Symposium on Automobile Technology and Automation pp.639-646 (1993).
- [8] 松田文夫 大野正大 浅井邦彦：“名古屋市駐車場整備計画について”第 18 回日本道路会議論文集 1028 (1989).
- [9] 小野寺浩：“交通情報の監視制御システム”電学論 Vol.110-D No.6 pp.612-616 (1990).
- [10] 吉川良平：“東名足柄サービスエリアの大規模改良”高速道路と自動車 Vol.32 No.7 pp.46-52 (1989).
- [11] 竹谷栄一 田中直樹：“休憩施設の駐車情報システムの研究”高速道路と自動車 Vol.32 No.1 pp.37-49 (1989).
- [12] 交通工学研究会編：“交通工学ハンドブック”技報堂出版 pp.862-863 (1984).
- [13] S.Takaba M.Sakauchi and T.Kaneko：“Measurement of Traffic Flow Using Real Time Processing of Moving Pictures”Proc. 32nd IEEE Conf. on Vehicle Technology San Diego U.S. pp.488-494 (1982).
- [14] H.Kobatake Y.Inoue T.Namai and N.Hamba：“Measurement of Two Dimensional Movement of Traffic by Image Processing”Proc. ICASSP pp.614-617 (1987).
- [15] 前田英作 高橋裕子 石井健一郎：“環境変動にロバストな物体有無判定法”信学論 Vol.J74-D-II No.12 pp.1731-1740 (1991).
- [16] 長谷川為春 松本泰輔 小沢慎治：“車両の移動に着目した駐車場における車両計数”信学春季全大 D-624 (1991).
- [17] Mecocci A.：“Moving object recognition and classification in external environments”Signal Proc. Vol.18 No.2 pp.183-194 (1989).
- [18] M.Takato T.Kitamura Y.Okuyama Y.Kobayashi K.Kikuchi and H.Nakanishi：“Traffic flow measuring system using image processing”Proc. SPIE Automated Inspection and High-Speed Vision Architectures Vol.1197 pp.172-180 (1989).
- [19] 小泉光政 小山泰一：“東名高速道路足柄 S A (下り線) 駐車状況判別システム (画像処理型)”高速道路と自動車 Vol.35 No.1 pp.32-40 (1992).
- [20] 内丸年雄 小山泰一：“足柄 SA 駐車場誘導システム”日本道路会議 1037 (1991).
- [21] 内丸年雄 小山泰一 小野寺浩 上田浩次 堀場勇夫 池谷和夫：“東名高速道路足柄 S A (下り) における画像処理型駐車場案内システム”電気学会道路交通研究会 RTA-91-14 (1991).
- [22] 三宅雅彦 上田浩次 小野寺浩 堀場勇夫 池谷和夫：“画像処理を用いた駐車場内夜間車両検出方法”電気学会道路交通研究会 RTA-91-20 (1992).
- [23] Rumelhart D.E. and McClelland J.L.：“Parallel distributed processing”Vol.1 and Vol.2 MIT Press (1986).
- [24] 森吉弘：“PDP モデルによる手書き漢字認識”信学論 Vol.J73-D-II No.8 pp.1268-1274 (1990).
- [25] 磯健一 渡辺隆夫：“ニューラル予測モデルを用いた不特定話者音声認識”信学論 Vol.J73-D-II No.8 pp.1315-1321 (1990).
- [26] 大橋剛介 大矢晃久 名取道也 中島真人：“超音波エコー画像の 3 次元表示のためのニューラルネットワークを用いた輪郭抽出法”信学論 Vol.J76-D-II No.2 pp.368-373 (1993).
- [27] B.Irie and S.Miyake：“Capabilities of three-layered perceptrons”Proc.IEEE ICNN88 I-641 (1988).
- [28] 栗田多喜夫：“情報量基準による 3 層ニューラルネットの隠れ層のユニット数の決定法”信学論 Vol.J73-D-II No.11 pp.1872-1878 (1990).

- [29] 大友照彦 原敏之 大内隆夫 原健一：“神経回路モデルを用いた手書き漢字の2段階認識法” 信学論 Vol.J74-D-II No.2 pp.158-165 (1991).
- [30] 西村和夫：“ニューラルネットワーク応用の現状と今後の課題” 情報処理学会誌 Vol.35 No.6 pp.541-542 (1994).
- [31] 中野馨：“ニューロンコンピュータ” 技術評論社 (1989).
- [32] 中内茂樹 白井支朗 三宅誠：“3層ニューラルネットによる色学習とその内部表現解析” 信学論 Vol.73-D-II No.8 pp.1242-1248 (1990).
- [33] 入江文平 川人光男：“多層パーセプトロンによる内部表現の獲得” 信学論 Vol.73-D-II No.8 pp.1173-1178 (1990).
- [34] 林原香織 山下雅史 阿江忠：“シグモイド関数の連続性/離散性とニューラルネットワークのマシン能力について” 信学論 Vol.73-D-II No.8 pp.1220-1226 (1990).
- [35] 鈴木賢治 上田浩次 堀場勇夫 池谷和夫：“アナログ値予測用ニューラルネットワーク” 電気関係学会東海支部連合大会 572 p.286 (1992).
- [36] 小島幸夫 田久保宣晃：“気象要因が車両の安全走行に及ぼす影響” 科学警察研究所報告 Vol.29 No.1 pp.107-126 (1988).
- [37] T.Morita S.Yamaoka M.Hayashida and M.Toyama：“Image Processing Vehicle Detector for Urban Traffic Control Systems” IEEE The 3RD International Conf. on Vehicle Navigation & Information systems pp.98-103 (1992).
- [38] 中本明夫 羽田尚 小武孝榮 丸田良則 福島敏弘：“画像処理による交通流計測装置の調査研究” 電気学会電気鉄道研究会資料 TER-91-7 pp.61-70(1991).
- [39] 芳野俊彦：“光応用計測の現状” 計量管理 Vol.36 No.9 pp.2-6 (1987).
- [40] Wolff L.B.：“Using Polarization to Separate Reflection Components” IEEE Computer Society Conference on Computer Vision and Pattern Recognition pp.363-369 (1989).
- [41] 山田啓一 中野倫明 山本新：“液晶を用いた光沢除去のための視覚システム” 電学論 C Vol.113 No.12 pp.1087-1093 (1993).
- [42] Wolff L.B.：“Polarization/Radiometric Based Material Classification” IEEE Computer Society Conference on Computer Vision and Pattern Recognition pp.387-395 (1989).
- [43] 住江伸吾 西元善郎：“ガラス基板表面のきずとほこりの識別” 電学論 C Vol.112 No.2 pp.89-96 (1992).
- [44] 渋谷ゆう子 小山内宰 竹内栄次郎 岩井秀隆 峰松義博：“女性顔面の肌色および色ムラ評価の新しい試み” 日本化粧品技術者会誌 Vol.26 No.2 pp.120-130 (1992).

- [45] 竹鼻俊夫：“路面反射の偏光特性を利用した路面状態センサ”，光技術コンタクト，Vol.27, No.3, pp.158-164, (1989).
- [46] 石黒浩三：“光学” pp.26-31 共立出版 (1986).
- [47] 児玉帯刀：“光” pp.427-428 槇書店 (1993).
- [48] 小口高 渡辺堯：“太陽からの贈り物” pp.155-162 丸善 (1992).
- [49] 吉沢 顕 青木正喜：“画像を用いた交差点における交通流計測” 電気学会道路交通研究会 RTA-90-25 (1990).
- [50] 北村隆則 大浦高資 金山憲司 加藤裕 澤田誠一：“FT-CCD シャッタカメラの開発と交通センサへの応用” 電気学会交通・電気鉄道研究会 TER-88-21 (1988).
- [51] N.Mizukoshi I.Horiba K.Ueda and H.Onodera：“Parking Condition Discrimination System of Image Processing Type Using a Neural Network Model(On Tokyo Ring Expressway Niikura Parking Area)” Vehicle Navigation & Information Systems International Conference A2-5 (1994).
- [52] 古田博也 上田浩次 小野寺浩 堀場勇夫 池谷和夫：“画像処理を用いた移動車両検出アルゴリズムとそのハードウェア” 電気学会道路交通研究会 RTA-92-9 pp.21-30 (1992).
- [53] 上田浩次 堀場勇夫 池谷和夫 小野寺浩：“画像処理を用いた駐車車両検出アルゴリズム” 信学論 Vol.J74-D-II No.10 pp.1379-1389 (1991).
- [54] 上田浩次 堀場勇夫 池谷和夫 小野寺浩：“ニューラルネットワークを適用した駐車状況推定方法” 情報処理学会論文誌 Vol.35 No.2 pp.281-290 (1994).
- [55] 上田浩次 堀場勇夫 池谷和夫 大井史倫：“画像処理を用いた路面湿潤状況検出方式” 情報処理学会論文誌 Vol.35 No.6 pp.1072-1080 (1994).
- [56] 上田浩次 浅井律雄 堀場勇夫 池谷和夫：“フィールド画像間情報を用いた車両走行速度検出方式” 信学論 Vol.J77-D-II No.9 pp.1931-1933 (1994).
- [57] 上田浩次 山田宗男 堀場勇夫 池谷和夫 鈴木賢治：“アナログ出力ニューラルネットワークを適用した駐車率の直接推定方法” 情報処理学会論文誌 Vol.36 No.3 pp.627-635 (1995).
- [58] K.Ueda R.Asai K.Ikegaya and I.Horiba：“Vehicle-Speed Detection Method Using Movement Information Obtained from Two Field Images”, Proc. of the Second World Congress on Intelligent Transport Systems, Vol.I pp.224-229 (1995).

