

# 修 士 論 文

画像と超音波のセンサフュージョン  
による交通事象認識に関する研究

Traffic Event Recognition based  
on Vision and Ultrasonic Wave  
Sensor Fusion

指導教官

坂内 正夫 教授



東京大学大学院  
情報理工学系研究科  
電子情報学専攻

学籍番号・氏名

46430 藤平 健二

提 出 日

平成18年2月3日

# 目 次

<b>第 1 章 序論</b>	<b>1</b>
1.1 背景 . . . . .	2
1.2 目的 . . . . .	2
1.3 本論文の構成 . . . . .	3
<b>第 2 章 関連研究</b>	<b>4</b>
2.1 交通事象検出 . . . . .	5
2.2 センサ融合の交通監視への応用 . . . . .	5
<b>第 3 章 センサ融合技術</b>	<b>8</b>
3.1 道路監視で用いられるセンサ . . . . .	9
3.1.1 可視カメラ . . . . .	9
3.1.2 パルス式超音波感知器 . . . . .	12
3.2 センサの比較 . . . . .	15
3.3 センサ融合 . . . . .	16
3.3.1 複数種類センサによる検出精度の向上 . . . . .	17
3.3.2 検出エリアの拡大 . . . . .	17
3.3.3 融合アルゴリズム . . . . .	17
3.4 センサ融合の交通監視への応用 . . . . .	18
<b>第 4 章 既存交通監視システム概要</b>	<b>19</b>
4.1 事象検出アルゴリズム . . . . .	20
4.1.1 意味階層構造 . . . . .	20
4.1.2 事象検出ルール . . . . .	21

4.1.3	渋滞判定 . . . . .	21
4.1.4	異常事象判定 . . . . .	21
<b>第 5 章</b>	<b>画像センサの性能向上</b>	<b>24</b>
5.1	画像処理システムの未検出・誤報の傾向 . . . . .	25
5.2	事象検出アルゴリズムの改良 . . . . .	27
5.2.1	背景の汚れによる誤報の対策 . . . . .	27
5.2.2	混雑時の車線変更挙動による誤報の対策 . . . . .	30
5.2.3	未検出の対策 . . . . .	31
5.3	実験結果 . . . . .	31
5.3.1	recall rate の検証 . . . . .	31
5.3.2	誤報数の検証 . . . . .	32
<b>第 6 章</b>	<b>画像と超音波のセンサ融合</b>	<b>39</b>
6.1	システム概要 . . . . .	40
6.2	画像と超音波の融合による精度向上 . . . . .	42
6.2.1	Velocity_Volume-class . . . . .	42
6.2.2	Flow-class . . . . .	43
6.3	速度パルスエラーの除去 . . . . .	45
6.3.1	異常長速度パルス . . . . .	45
6.3.2	異常短速度パルス . . . . .	45
6.4	複数地点のセンサによる融合 . . . . .	47
6.5	同一センシング対象に対するセンサ融合 . . . . .	48
6.6	実験結果 . . . . .	51
6.6.1	recall rate の検証 . . . . .	51
6.6.2	誤報数の検証 . . . . .	53
<b>第 7 章</b>	<b>結論と今後の課題</b>	<b>62</b>
7.1	本研究のまとめ . . . . .	63
7.2	今後の課題 . . . . .	63

## 表 目 次

2.1	Incident type from AID algorithms . . . . .	6
2.2	連続カメラによる事故検出 (recall rate)[12] . . . . .	7
2.3	連続カメラによる障害物検知 (precision rate)[12] . . . . .	7
3.1	単眼可視カメラによる事象検出 (発表文献 [1] より) . . . . .	12
3.2	可視光カメラと超音波センサの比較 . . . . .	16
5.1	事故検出数 . . . . .	32
5.2	誤報数 . . . . .	34
6.1	事故検出数 . . . . .	51
6.2	誤報数 . . . . .	53



## 図 目 次

2.1	A Schematic Diagram of Data Fusion . . . . .	6
2.2	自由流中の停止車両 [12] . . . . .	7
2.3	渋滞中の停止車両 [12] . . . . .	7
3.1	画像センサによる前方空間検出 . . . . .	9
3.2	画像センサによる車線変更検出 . . . . .	10
3.3	S-T MRF によるトラッキング結果 . . . . .	11
3.4	S-T MRF から得られるオブジェクト ID マップ . . . . .	11
3.5	超音波センサの検出対象領域 . . . . .	13
3.6	実験地での超音波センサ設置状況 . . . . .	13
3.7	超音波センサ . . . . .	14
3.8	超音波センサの車両感知原理 [4] . . . . .	14
3.9	超音波センサの車両感知性能 . . . . .	15
4.1	意味階層構造 . . . . .	20
4.2	事故車両と前方空間による事故検出 . . . . .	22
4.3	事故車両に対する車線変更挙動による事故検出 . . . . .	23
4.4	車線変更挙動による事故検出 . . . . .	23
5.1	撮像範囲の限界領域に停止する事故車 . . . . .	25
5.2	背景の汚れによる未検出の例 . . . . .	26
5.3	背景に含まれるノイズ . . . . .	26
5.4	背景の汚れによる誤報の例 . . . . .	28
5.5	誤報時の背景に含まれるノイズ . . . . .	28

5.6 同一地点で車線変更が起こった場合に生じる誤報の例 . . . . .	29
5.7 Algorithm-(a) による事故検出時間 . . . . .	33
5.8 Algorithm-(b) による事故検出時間 . . . . .	33
5.9 Algorithm-(a),(b) による事故検出時間 . . . . .	34
5.10 式 5.2 による検出の遅れ . . . . .	35
5.11 式 5.1 によってマスクされた誤報 . . . . .	36
5.12 式 5.1 によってマスクされた誤報 . . . . .	36
5.13 式 5.2 によってマスクされた誤報 . . . . .	37
5.14 式 5.2 でマスクできなかった誤報 . . . . .	38
6.1 データ処理の流れ . . . . .	41
6.2 意味レベルでのセンサ融合 . . . . .	43
6.3 実験地での QV 分布 (20 秒平均) . . . . .	44
6.4 実験地での QV 分布 (60 秒平均) . . . . .	44
6.5 車線変更による異常長速度パルスの発生 . . . . .	46
6.6 渋滞中に生じた異常短速度パルス . . . . .	47
6.7 画像センサの検出領域に設置された超音波感知器 . . . . .	49
6.8 消失点付近で生じる停止判定の誤報 . . . . .	50
6.9 背景に生じる消失点付近のノイズ . . . . .	50
6.10 Algorithm-(c) による事故検出時間 . . . . .	52
6.11 Algorithm-(b),(c) による事故検出時間 . . . . .	52
6.12 Algorithm-(c) による検出時間の短縮 (36 秒→23 秒) . . . . .	54
6.13 Algorithm-(c) による検出時間の短縮 (109 秒→75 秒) . . . . .	55
6.14 Algorithm-(c) による事故検出 (未検出→81 秒で検出) . . . . .	56
6.15 同一地点に設置された超音波感知器による誤報のマスク . . . . .	58
6.16 同一地点に設置された超音波感知器による誤報のマスク . . . . .	59
6.17 式 6.4 による誤報 . . . . .	60
6.18 式 6.4 による誤報 . . . . .	61

# 第1章 序論

本研究では、既存の画像処理交通監視システムとのセンサ融合を目的として超音波感知器データ処理システムを開発し、より高い事故検出性能を得ることを試みた。その結果、画像処理システム単体よりも高い検出精度を得ることに成功した。

本章では、研究の背景と本論文の構成について述べる。

## 1.1 背景

シートベルト着用の徹底、延命措置の高度化など、これまで様々な取り組みがなされた結果、近年の日本における死亡事故、重傷事故などの大事故は減少傾向にあるが、軽傷事故を含む事故総数は依然増加し続けている。交通事故が引き起こす被害としては加害者・被害者の肉体的・精神的苦痛といった人的なものや構造物の破損といった直接的なものが注目されがちだが、事故渋滞による経済損失も深刻な問題である。平成 11 年度の統計によると、国内の事故渋滞による経済損失は年間で 1500 億円を超えている [20]。

このことから、死亡事故・重傷事故だけでなく、軽傷事故を含む事故数全体を削減することが課題となっている。国土交通省が行っている AHS の社会実験 [14][15] は、その具体策を示した一例であり、注目されている。首都高速道路 4 号線新宿線参宮橋区間の急カーブで渋滞末尾や停止車両などの突然の危険に起因する追突事故が多く発生しており、路上センサから得られる情報を VICS 対応カーナビ搭載車両に提供する安全走行支援サービスの実験が 2ヶ月間行われ、その効果が認められたと報告されている。

この社会実験でも一つの重要な要素となっているのが、停止車両、低速車両、渋滞などの交通事象を自動検出するリアルタイム交通監視システムである。実運用されている異常事象検出システムとしては、Traficon の異常事象検出システム [17] や国内での Taams(TrafficAccident Auto Memory System) などがあげられる。Traficon のシステムは画像処理によって停止、落下物などの異常事象を検出しているが、自由流での運用に限定されている。また、Taams は交差点で音響処理を行うことによって事故やニアミス、ヒヤリ、ハットなど事故につながる可能性のある危険を検出し、その映像を自動保存する。しかし、これは交差点での運用を前提としており、高速道路に既設の CCTV カメラ映像に応用することはできない。

## 1.2 目的

本研究では、これまで上條研究室で開発されてきた交通異常事象検出システム [3] の精度をセンサ融合によって向上させることを目指す。このシステムは、主要高速道路に既設の交通管制用 CCTV カメラの映像を画像処理することによって、事故などの異常事象をリアルタイムで検出するもので、これまで首都高速道路赤坂トンネル入り口で行った評価結果では 95% の recall rate で起こった事故を検出し、誤報が平均 1 日 5 件と、重交通量の映像を処理するには高い精度が得られている。しかし、単一のカメラ映像しか処理していないために検出できない事故が存在する。単一のカメラを用いる場合、カメラの撮像限界領域で事故が起こった場合には、該当車両の前後の領域の様子が十分に把握できないため、事故として検出することが難しい。

本研究では、単一カメラの情報を他のセンサを用いて補完することにより、精度の向上を試みた。首都高速道路には 200～300m おきに超音波センサが設置されており、これらから通過車両台数、速度、占有率などの交通データが得られるので、これを用いた。超音波センサから得られる情報は、センサヘッドの検出領域に車両がいるかないかの 1 ビットの情報のみだが、その検出性能は非常に高い。また、一地点に 2 ヘッドの超音波センサを配置することによって、その間の旅行時間と距離から車両速度を求めることも可能である。首都高速道路には、交通管制用 CCTV カメラも数 100m おきに設置されているが、特にトンネル内の映像は画角が低いため、現状では画像処理によって得られる情報よりも超音波センサから得られる交通データの方が信頼性が高い。一方で、事故を検出する上で重要な情報となる車線変更や停止車両前方に広がる空間の広さといった情報は、超音波センサから取得することができず、カメラ映像を画像処理する必要がある。このように、お互いに相補的な役割を担う画像センサと超音波センサを融合することによって、交通監視の精度を上げることが本研究の狙いである。

### 1.3 本論文の構成

第 2 章では、本研究の目的である交通監視について、センサ融合を応用した例も含め関連研究を紹介する。

第 3 章では、センサ融合技術の理論について紹介する。特に、本研究で扱うセンサを中心に議論を進める。

第 4 章では、坂内・上條研究室でこれまで開発が進められてきた画像処理交通監視システムについて説明する。このシステムの改良が本研究の目的となる。本論文の提案手法を実装する前の段階での機能について概説する。

第 5 章では、センサ融合を行うまえにまず既存の画像処理システム単体での異常事象検出性能の向上を試みたので、それについて報告する。

第 6 章では、第 5 で改良した画像処理システムと超音波感知器とのセンサ融合を行うことによって、さらなる精度向上が可能となったので、それについて述べる。

最後に第 7 章で結論と今後の課題を述べる。

## 第2章 関連研究

事故を含む異常事象に管制官が対処するための手助けとして、交通監視システムの開発研究が広く行われている。それらは、大きくわけて単一種類のセンサを1地点に配置して情報取得を行う手法と、複数種類または複数地点のセンサから情報を取得する手法に分けられる。本章では、これらの先行研究について説明する。

## 2.1 交通事象検出

交通監視を目的とした異常事象検出システムについては運用レベルに達していないものも含め広く研究が行われている。[21], [22] ではカルマンフィルタを用いることでオクルージョン等による精度の低下を防ぐ処理について記述されている。[23] では日中と夜間での照度条件の変化に対応するため、各々についてトラッキングアルゴリズムを用意する手法が提案されている。また [24] では、背景差分によって正確に動物体を認識するために、ピクセル単位で混合ガウス分布モデルを用いた背景更新について議論されている。その他にも、交通監視システムを目的とした画像処理に関する研究として [25], [26] などが挙げられる。

異常事象の検出アルゴリズムに焦点を当てた研究も多い。[27] ではベイジアンネットワークを用いた異常事象検出アルゴリズムが提案されている。[28] では 3 つのタイプのニューラルネットワークによるアルゴリズムを用意し、異常事象検出の精度だけではなく、場所が変わった場合の適応性にも着目して比較を行っている。その他にも、[29][30][2] といった先行研究が行われている。

## 2.2 センサ融合の交通監視への応用

複数種類のセンサを用いたセンサ融合による交通監視の研究は、シミュレーションデータを用いた解析の例が多く見られる [16][11]。この種の研究では、異なる性質のセンサ出力を融合するアルゴリズムに焦点をあてたものが多い。例として [11] で提案されている手法は、複数種類のセンサ (loop detector, CCD camera, Probe Vehicle 等) それぞれで独立に AID (automatic incident detection) アルゴリズム (California #8 等) を実行し、その結果得られる Incident Type とその確率を Dempster-Shafer の確率理論によって統合することによって異常事象検出を行う (図 2.1)。Incident Type としては表 2.1 に示した 5 タイプが用意されている。従来手法では粗密波による渋滞 (type2) を異常事象と区別できずに誤報が生じることが問題となっていた。複数種類のセンサを用いることによってこの種の誤報を削減することが、[11] で提案されている手法のねらいである。

これらの先行研究は複数種類のセンサから得られる出力を融合することによって、単一センサの情報に含まれる不確定性を解消することに焦点をあてている。しかし、これらの研究はいずれもシミュレーションデータを用いて実験が行われているため、各センサの出力特性が現実のものを反映しているとはいえない。実運用を考慮すると、例えば画像センサに固有のオクルージョン問題等がセンサ出力に及ぼす影響がシステム構築の際に重要な要素となる。

一方、複数地点に配置されたセンサ出力を空間的に融合する試みは交通監視の開発

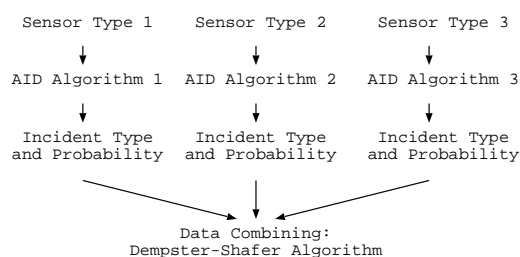


図 2.1: A Schematic Diagram of Data Fusion

表 2.1: Incident type from AID algorithms

Incident Type	Incident
1	異常事象発生
2	粗密波による渋滞
3	通常流
4	異常事象持続
5	異常事象終了

研究において実運用レベルで行われている。1 日平均交通量約 10 万台という重交通量の首都高速道路千代田トンネルでは、トンネル内に設置された交通管制用カメラの映像を処理する異常事象自動検知システムが松下電器によって運用されている [12][13]。この研究開発では、重交通量のトンネルで頻繁に生じる渋滞内の低速車両や停止車両と事故車両を区別することが課題であった。この区別は単独カメラの映像を処理するだけでは困難であるが、隣接カメラ間で交通流に速度差が生じているかどうかを確認することによって、停止、低速挙動が渋滞によるものかどうかを知ることができる。例えば、あるカメラ映像に停止車両が映っていて、下流側の隣接カメラ映像では自由流である場合は事故、下流側で渋滞していたら渋滞による停止挙動であると判断できる。このように、隣接カメラの情報を融合することによって、事故検出の recall rate、障害物検出の precision rate とともに 90% を超え (表 2.2、表 2.3)、低画各かつ重交通量の画像処理する上で非常に厳しい環境でも実運用に耐え得るシステムとなった。






図 2.2: 自由流中の停止車両 [12]




図 2.3: 渋滞中の停止車両 [12]

表 2.2: 連続カメラによる事故検出 (recall rate)[12]

Index	Results
accidents in record	34case
accidents detected by the system	31case
recall rate	91%

表 2.3: 連続カメラによる障害物検知 (precision rate)[12]

Index	Results
notification by the system	192case
actual obstables	178case
recall rate	93%

## 第3章 センサ融合技術

ITS では、可視カメラ、赤外カメラ、超音波センサ、ミリ波レーダなど、様々な特性をもったセンサがセンサが情報収集に利用されている。本章では、本研究で用いた可視カメラとパルス式超音波センサを中心に道路監視で用いられるセンサについて紹介し、それらの融合方法について述べる。

## 3.1 道路監視で用いられるセンサ

### 3.1.1 可視カメラ

CCTV カメラなどの可視光画像センサは車載システム、インフラ側システムの両方で広く利用されている。局所型センサが一点のみを検出対象とするのに対し、画像センサは撮像範囲に収まる空間全体をセンシング領域とする空間型センサであり、得られる情報量が潤沢という利点がある。例えば異常事象検出において、車両の停止挙動とその前方に広がる空間（図 3.1）や停止車両を避ける車線変更挙動（図 3.2）は、センシング対象を一点に限定する局所型センサでは検出することができないのに対し、画像センサを用いれば検出が可能である。




図 3.1: 画像センサによる前方空間検出

また、画像センサによって得られる映像はそのまま視覚的に人間が理解しやすいということも重要な利点である。超音波センサなどの局所型センサから得られるデータは数値化されたデータ（平均速度、台数、占有率など）であり、画像と比較すると理解のしやすさという点では劣る。

一方で、画像センサにはオクルージョンの問題がある。カメラが画像処理に適した場所に固定されとは限らないので、ある車両が他の車両に隠された時にも正確なオブジェクト認識を行えるトラッキング技術が必須となる。本研究室では、オクルージョンに頑健なトラッキングアルゴリズムとして S-T MRF モデル [1] によるトラッキング技術を開発し、これを用いてカメラを用いた交通流解析を行ってきた。図 3.3, 3.4 に S-T MRF のトラッキング例とその出力であるオブジェクト ID マップを示す。この例のように、低画角の映像であるために通過車両同士が重なってしまうような状況でも、



図 3.2: 画像センサによる車線変更検出

S-T MRF を用いれば正確にオブジェクトの分離を行うことができる。特に国内の交通流は諸外国と比較すると混雑しており、渋滞中に起こるオクルージョンの頻度が高く、オクルージョン対策は画像センサを用いてシステムを構築する際に重要な問題となる。

また、環境変動から受ける影響も画像センサを用いる際に問題となる。特に屋外の映像を処理する場合、昼夜の違いによる照度変化、晴れ・曇り・降雨・降雪といった天候変化によってセンシング能力は大きく変動する。24 時間稼動を前提としたセンシングシステムを開発するにはこれらの環境変動に頑健なフィルタリング処理を行う必要がある。

さらに、必要とされる CPU 処理能力の高さも画像センサの欠点となる。システムの用途にもよるが、画像サイズ 640×480 ピクセル、フレームレート 10~15fps の映像の場合、1 台の CPU で処理できる映像は 1 箇所が限界であり、数 10 地点のデータを一台の CPU で処理できる局所型センサと比較すると、得られる情報量が潤沢であるがゆえ、非常にハイスペックな処理能力が要求される。

発表文献 [1] にて詳説した通り、単一画像センサによる低速車両、渋滞、異常事象の検出は、リコールレート 100 % で可能である (表 3.1)。しかし、誤報 (事象が起こっていないにもかかわらず、システムが発報してしまうケース) は日照変化や交通量、画角、天候といった条件に左右される。条件のいい環境では 2 件/1 週間程度の誤報であるのに対し、条件が悪いと 5 件/1 日ほどの誤報が生じており、環境変動に弱いという画像センサの欠点が実験結果に現れている。




図 3.3: S-T MRF によるトラッキング結果

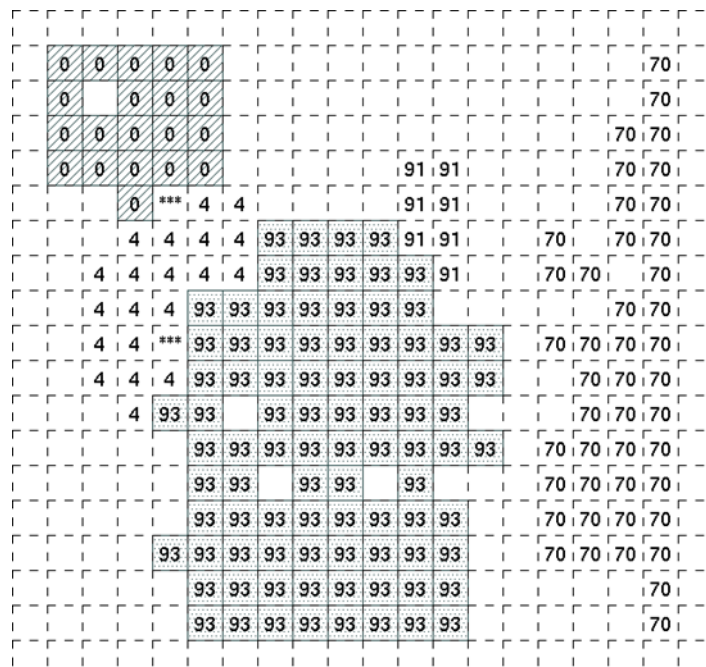


図 3.4: S-T MRF から得られるオブジェクト ID マップ

表 3.1: 単眼可視カメラによる事象検出 (発表文献 [1] より)

	学習データ		評価データ		計	
	検出	未検出	検出	未検出	検出	未検出
低速車両	23	0	42	0	65	0
渋滞	6	0	25	0	31	0
自由流の中での停止車両	4	0	6	0	10	0
事故	24	1	63	4	85	5

### 3.1.2 パルス式超音波感知器

パルス式超音波感知器は一般に、図 3.5 に示したように、構造物を道路の上に橋渡しし、そこに超音波の発信・受信部を取り付けて使用する。また、本研究で検証を行った首都高速道路では、超音波感知器が図 3.6 のように、道路横側に設置されている。図 3.6 のように、1 地点につきセット側ヘッドとリセット側ヘッドの 2 ヘッドを設置し、その間を車両が通過する時間から車両の速度も測定される。図 3.7 が本研究で用いた超音波センサである。超音波センサから発信された超音波は車両に反射し、その反射波が再び超音波センサによって受信される。超音波が発信されてから受信されるまでの時間を測定することによって車両の存在を感知することができる (図 3.8)。

パルス式超音波センサのセンシング対象領域は、直径 1 メートル前後の円内となり、前節で説明した画像式の空間型センサと比較すると非常に狭く、このことから超音波センサは局所型センサに分類される。

得られる情報は車両感知/無感知の 1 ビットのみで、これが 20msec/秒の単位で取得される。また超音波センサを一地点につき数メートル間隔で 2 ヘッド設置することによって、その間の旅行時間から車両速度を算出することもできる。得られる情報はこれらの限られたものであるが、特に車両の感知/無感知の情報を取得する用途では、検出性能が非常に高い。図 3.9 は、超音波センサの出力を図示したものである。横軸が時間 (秒)、縦軸が車両の感知/無感知を表している。緑線が超音波センサによって車両の存在が検出された時間、赤線が画像を目視でチェックし車両がセンサの検出領域内にいる時間をプロットしたものである。目視の結果と超音波センサの出力は 100% 一致しており、これほどの高精度を画像センサで実現することは現段階ではまだ不可能である。また、超音波センサはその検出原理ゆえ環境変動に頑健であり、さらに比較的低い処理能力で容易に検出を行えるという利点もある。




図 3.5: 超音波センサの検出対象領域




図 3.6: 実験地での超音波センサ設置状況



図 3.7: 超音波センサ




図 3.8: 超音波センサの車両感知原理 [4]






図 3.9: 超音波センサの車両感知性能

## 3.2 センサの比較

ITS でデータ収集用途に用いられるセンサは、大きく車載センサとインフラセンサに大別される。前者に関連する研究開発分野としては、車両に搭載されたカメラやミリ波レーダを用いた前方車両検出、カメラを用いた白線や標識などの道路環境把握、居眠り、よそ見防止を目的としたカメラによる運転者監視などがあげられる。

一方インフラセンサの用途には、通過車両台数、速度などの交通流計測や、事故などの異常事象発見がある。ここでは本研究と関連するインフラ用センサとして、可視光カメラとパルス式超音波センサをとりあげ、これらを比較する。表 3.2 は、これら 2 種類のセンサの特徴をまとめたものである。

まず、これらのセンサ間の最も大きな違いとして、センシング対象領域の広さが挙げられる。超音波センサは検出対象が一点に限られる局所型センサとして位置づけられるのに対し、画像センサは空間的に広い領域をセンシング対象とする空間型センサである。そのため、パルス式超音波センサを車両追尾目的で使用することは不可能であるのに対し、画像センサを用いれば撮像範囲内で車両の時空間軌跡を抽出し、それをもとに車両挙動や事象などといった情報を取得することができる。また検出対象領域の広さはセンサの設置コストとも関わってくる。例えば、複数車線道路や分合流地点、交差点を交通監視の対象とするケースでは、超音波センサを用いる場合全ての車線に対してセンサを設置しなければならないのに対し、画像センサを用いれば、その

表 3.2: 可視光カメラと超音波センサの比較

条件	可視光カメラ	超音波センサ (パルス式)
センシング領域の広さ	○	×
車両追尾	○	×
車両検出・台数計測	△	○
速度計測	△	○
日照変動 (昼・夜)	△	○
天候変動 (雨・霧・雪)	△	○
処理データ量	△	○

撮像範囲内の交通流はカメラ一台でカバーできるので、センサの設置コストを抑えることができる。これらを総合すると、超音波センサよりも画像センサの方が潤沢な情報が得られるということが言えるだろう。

一方、超音波センサを用いることの利点は、その検出性能の高さにある。車両検出や台数計測といった用途については画像センサと比較すると非常に高い精度で検出できる。さらに、パルス式超音波センサを一地点につき数メートル間隔で2ヘッド設置することによって、一台の車両がそれぞれのヘッドを通過した時間から速度を算出することも可能である。環境変動に強いことも超音波センサの強みである。超音波センサはその検出原理ゆえ昼夜間や晴れ・曇りの違いによって生じる日照変動によらず安定した検出を行うことができる。また、雨・霧・雪などといった天候変動にも頑健である。この特徴は、画像センサが有しないものであり、24時間365日の運用を考慮する場合は特に重要な要素である。すでに首都高速道路では200～300メートル間隔で全地点に超音波センサが設置されており、様々な形で交通流解析に役立っている。

### 3.3 センサ融合

センサ融合の代表例として、しばしば挙げられるのが人間である。人間は異なる5種類の感覚から得られる情報を総合的に解釈し、その結果に基づいて行動する。五感から得られるそれぞれの情報には不確実性が生じるものだが、そのあいまいさは五感それぞれが相補的な役割を担うことによって、より確からしい結論を導くことができる。

この考え方を工学の分野に適用することによって、従来単一センサで達成できなかった検出精度を実現することが可能になる。センサ融合には、同一の検出対象を、特性の異なる複数種類のセンサを用いてその検出精度を高めるという考え方と、センサを複数配置することによってその検出エリアを拡大することで、より多くの情報を取得するという考え方の2通りがある。

### 3.3.1 複数種類センサによる検出精度の向上

センサ融合は、狭義の意味では複数種類の相補的役割を担うセンサで同一の検出対象をセンシングすることによってその検出精度を高める考え方を指す [5]。安全運転支援を目的とした車載システムにおける、カメラとミリ波レーダまたはレーザスキャナのセンサ融合による前方車両検知が代表的な例である [6][7][8][9][10][19]。カメラは空間的に広い領域をセンシング対象とする空間型センサであり、ミリ波レーダ、レーザスキャナといった検出対象が一点に限定される局所型センサと比較すると、検出領域の面で大きな優位性を持っている。その一方でミリ波レーダやレーザスキャナはその検出原理ゆえに画像センサと比較して高い検出精度が期待できる。これらの長所・短所を考慮し、各センサに相補的な役割を持たせ共存させることによって、単一種類センサでは得られなかった高い精度での検出が可能となった。

### 3.3.2 検出エリアの拡大

検出対象エリアを拡大することを目的として複数地点に単一種類センサを配置するようなケースも広義の意味でセンサ融合と言える [5]。生態系観測、ITS などの分野では、すでにセンサネットワークを構築することによる効率的で高精度な情報収集が行われている。首都高速道路で運用されている画像センサによる事象検出システムは、既設の交通管制用カメラを利用している。単独カメラによる情報のみで事象検出を行っていた従来と比較して、ネットワーク化された隣接カメラの情報を取り入れることにより、事象検出の recall, precision 共に大きく改善されたと報告されている。

### 3.3.3 融合アルゴリズム

センサ融合のアルゴリズムとしては、ルールベース手法、ニューラルネットワーク、ベイジアンネットワーク、デンプスター・シェイファー理論など、幾通りもの選択肢が考えられる。本研究で採用したルールベースによる手法は、他の手法と比較して少ない学習データによって融合が行える点で優れている。確率モデルをあらかじめ構築してそれを用いるベイジアンネットワークやデンプスター・シェイファー理論は、モデルの作成に大量の学習データが必要となるのに対し、ルールベース手法は少ない学習データでアルゴリズムの構築を行うことが可能である。また、データの処理過程が人間に分かりやすいということもルールベース手法の持つ優れた特徴である。ニューラルネットワークはシステムにデータが入力されてから出力が得られるまでのプロセスがブラックボックス化されている。そのためエラーが生じた場合にアルゴリズムの改良を行うことが容易ではない。確率モデルによってアルゴリズムが構築されるベイジアンネットワークやデンプスター・シェイファー理論も同様である。一方、

ルールベース手法を用いれば人間の認識過程を模倣したアルゴリズムを構築することが可能であり、入力されたデータが処理される過程を容易に理解することができる。人間の認識と高い親和性を保つことは、高いメンテナンス性につながる。つまり、エラーが生じたときその処理過程を追うことにより容易にエラーの原因をつきとめ、それを改善することができる。

### 3.4 センサ融合の交通監視への応用

首都高における松下電器の交通監視システム [12],[13] や、東京大学上條研究室で開発された交通監視システム [3] は、交通管制用途のために設置されている CCTV カメラを画像処理することによって、90%以上のリコールレートで異常事象を検出することが可能である。しかし、単独種類センサによる検出精度の向上には限界が見えてきており、今後は特性の異なる複数種類のセンサを融合することによって精度を上げることが必要である。

長所、短所の異なる相補的關係にある異種センサによって、お互いの短所を補いつつ高い精度を維持するという考え方が異種センサ融合の基本である。画像センサは潤沢な情報量が得られる一方で、非常にハイスpek的な処理能力が要求され、また、時間や天候といった環境変化の影響を受けやすい。その一方超音波センサの場合は車両感知/無感知の一ビットの情報が、200~300メートルおきに設置されたセンサヘッドから得られるのみであるが、その検出原理ゆえに精度の良いセンシングが可能である。また一地点に2ヘッドのセンサが設置されていればその間の旅行時間と距離から速度を計算することもでき、車両の交通量や速度をセンシングする能力は、現状では画像センサと比較すると非常に高い。

本研究は、首都高速道路西東京の赤坂、千代田区間に設置されている超音波センサと CCTV カメラを融合することによる交通監視の枠組みを提案するものである。従来は超音波センサが交通データ収集、CCTV カメラが交通管制補助と別々の用途に利用されていたが、本研究では超音波センサを交通管制補助の役割に用いることを検討し、その結果超音波センサが交通管制補助に有効であることが分かったので、以降の章で報告する。

## 第4章 既存交通監視システム概要

本章では、これまで本研究室で開発が進められてきたリアルタイム交通監視システムの概要を説明する。このシステムは無分岐直線道路を対象とした、画像センサによる事象検出システムで、意味階層構造に基づくルールベース手法によって事故、渋滞などの事象検出を行う。本研究では、超音波感知器とこのシステムを融合することによって、より高い事象検出性能を得ることを目的としている。

## 4.1 事象検出アルゴリズム

### 4.1.1 意味階層構造

本研究室でこれまで開発が進められてきたリアルタイム交通監視システムは、複数車線の無分岐直線道路を対象とする、画像処理システムである。首都高速道路に既設の交通管制用 CCTV カメラの映像を入力とし、交通流の中で起こっている事象を自動検出する。事象検出は図 4.1 に示した意味階層構造をとっている。意味階層構造とは、音声認識・自然言語処理から画像認識に至るまで広く使われている手法で、信号レベルの情報から人間が理解できる意味論的形式までを階層的に構築することで柔軟な状態認識を行う技術である。

意味階層構造の入力部は S-T MRF モデルによるトラッキング結果である。具体的には領域分割によるオブジェクト ID マップと動きベクトルマップに相当する。これらが第一階層である座標クラス (Coordinate-class) に入力される、低次情報である。次に、これらの情報が第二階層の軌跡クラス (Trajectory-class) へと渡され、一段階次元の高い情報として車両軌跡、速度の算出が行われる。さらにこれらの情報は、第三階層の挙動クラス (Behavior-class) へと渡される。この階層では停止、低速挙動、車線変更といった各車両の挙動に関する情報が抽出される。最後にこれらの挙動情報の組み合わせによる事象検出が第四階層の事象クラス (Event-class) で行われる。速度や台数の情報の組み合わせによる渋滞検出と、停止、車線変更といった挙動情報の組み合わせによる異常事象の検出が、この階層で行われる。

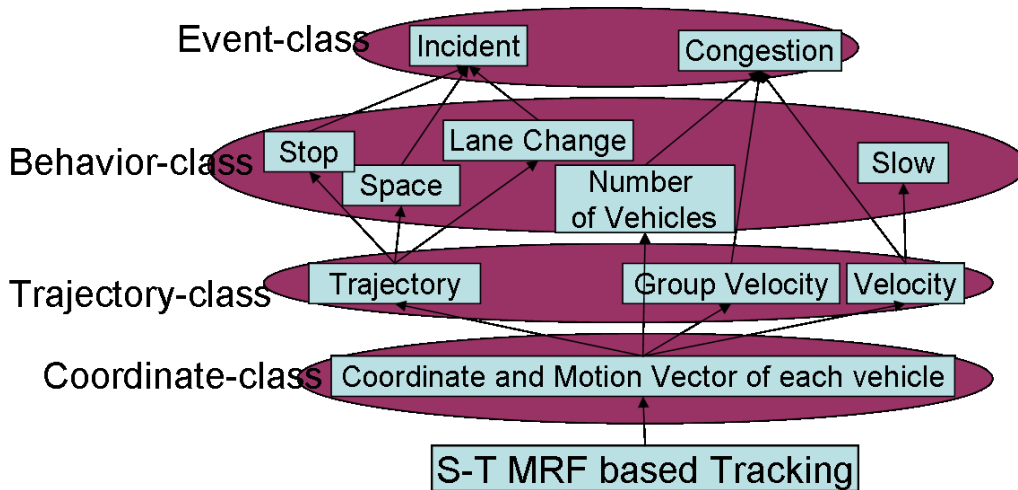


図 4.1: 意味階層構造

### 4.1.2 事象検出ルール

#### 4.1.3 渋滞判定

渋滞判定や、その基となる低速判定に用いる個々の車両速度情報と車群速度情報(画面内に存在する全ての車両速度の代表値)の抽出には、画面上のピクセル座標を実空間座標に変換するための plane-to-plane マトリクスを用いた。これは路面が平面であるという仮定のもとで、画像上の任意の点が表す路面上の位置を実世界での座標に変換するものである。本システムではこの変換を用いて画像上のピクセル値から実空間での座標を求め、車両速度の計算を行う。なお車両の進行方向について、求められた実空間座標の精度は 95% 以上となっている。

$$c \equiv runManyV() \wedge ave(getVel(V_i)) < V_1 \quad (4.1)$$

$$c \equiv (((T_{ex} = \sum_i^T objExist(t)) > 0.8 \times T_i) \wedge ((\sum_t^{T_{ex}} (getVelGr(t) < V_1)) > 0.95 \times T_{ex})) \quad (4.2)$$

*runManyV()*:通過車両台数が一定以上だった場合に *True* を返す

*getVel(V<sub>i</sub>)*:車両 *V<sub>i</sub>* の速度を返す

*objExist(t)*:時間 *t* にオブジェクトが存在するなら *True* を返す

*getVelGr(t)*:時間 *t* における車群速度を返す

渋滞の判定アルゴリズムは式 4.1, 式 4.2 の二つの論理で表される。式 4.1 は、通過車両台数とその平均速度が閾値以上であった場合に渋滞と判定する論理である。このルールは複数車線道路を扱う場合、各車線ごとで独立に適用される。

一方式 4.2 は、毎フレームで S-T MRF モデルから出力される動きベクトルマップから算出される車群速度に基づく判定アルゴリズムである。混雑時は背景にノイズが含まれやすくなるため、S-T MRF による車両の分割が困難となり、個々の車両速度を正確に求めることが難しい。そのため式 4.1 による渋滞判定が正常に動作しないことがある。そのような場合でも、S-T MRF が出力する動きベクトルマップを基に正確な車群速度情報を算出することは可能であり、式 4.2 によって渋滞の判定を行うことができる。

#### 4.1.4 異常事象判定

このシステムにおける異常事象 (Incident) の判定アルゴリズムは式 4.3, 式 4.4, 式 4.5 に示した 3 つのルールで記述される。これらは事故が起こった時画像処理によって観測可能な 3 つのパラメータ (停止挙動、車線変更挙動、停止車両前方の空間) に着目

$$b \equiv \exists (typeOfTpTrajectory(V.j) \wedge isSpace(V.j)) \quad (4.3)$$

$$b \equiv typeOfTpTrajectory(V.j) \wedge (3 \leq \sum_i \{LaneChanging = typeOfSpTrajectory(V.i, V.j)\}) \quad (4.4)$$

$$b \equiv 4 \leq \sum_i \{LaneChanging = typeOfSpTrajectory(V.i, L^k)\} \quad (4.5)$$

$typeOfTpTrajectory(V.j)$ : 車両  $j$  が停止挙動を示したとき、*True* を返す

$typeOfSpTrajectory(V.i, V.j)$ : 車両  $i$  が車両  $j$  に対してとった挙動を返す

$typeOfSpTrajectory(V.i, L^k)$ : 車両  $i$  が地点  $L^k$  においてとった挙動を返す

し、それらの組み合わせで事故を検出する論理である。なお、本システムの停止挙動判定には、画像内の車両進行方向に離散的に分布した 8 点を車両が通過した時間からその旅行時間を判定し、通常時の旅行時間と比較して著しく旅行時間が長い場合に停止と判定する。

式 4.3 は、車両の停止挙動とその前方に発生する空間の広さが閾値を超えたら、事故と判定する論理を表す。事故車両が画像内で停止挙動を示すと、後続車両の交通流がさえぎられるために停止車両前方に広い空間が生じやすい (図 4.2) ので、それを事故検出に利用するものである。




図 4.2: 事故車両と前方空間による事故検出

式 4.4 は、停止車両が観測され、かつそれに対する他車両の車線変更挙動が閾値以上に観測された場合に事故と判定するルールである。事故車両がカメラの撮像領域限界に停止してしまった場合は、その前方空間を把握することが原理的に不可能であり、式 4.3 のルールで事故を検出することができないが、式 4.4 の論理を用いることによって、このタイプの事故も検出可能となる (図 4.3)。






図 4.3: 事故車両に対する車線変更挙動による事故検出

式 4.5 は、停止車両が検出されない場合でも、同一地点で同じ方向（右車線から左車線、あるいはその逆）への車線変更挙動が閾値以上観測されたら、事故と判定する論理を表す。この論理による事故検出例を図 4.4 に示す。画像処理による異常事象検出を行う際、当該区間のような重交通量地点を扱う場合は特にオクルージョンが頻繁に発生するため、停止車両の検出がオクルージョンによって遅れることが多い。そのような場合でも式 4.5 のルールを用いることによって、事故の早期発見が可能となる。

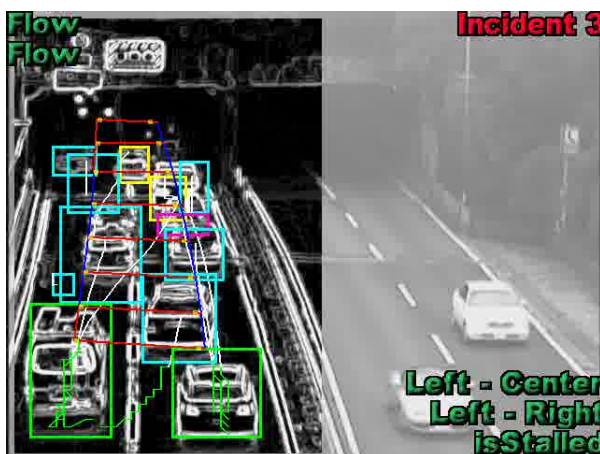


図 4.4: 車線変更挙動による事故検出

## 第5章 画像センサの性能向上

本研究では、これらの未検出、誤報の原因を考慮して、改善を試みた。本章では、まず画像処理システムのアルゴリズムのみを改良することによって解決されるものについてそれらを試みたので、それについて説明する。

## 5.1 画像処理システムの未検出・誤報の傾向

本研究で検出性能の向上を試みるのは、4 で説明したリアルタイム交通監視システムである。このシステムは、本研究室で事故 95 件を含む過去約 30 ヶ月間にわたる検証実験による性能評価が行われてきた。当該地点では、平均 10 日に 1 件事故が発生する。証実験の結果、recall rate (システムが検出した事故の件数/実際に起こった事故の件数) は 94%, 誤報 (実際には事象が起こっていないにもかかわらず、システムが発報してしまうケース) は平均して 5 件/日という精度が得られている。

未検出の原因は画像の撮像範囲の制限と、混雑による背景の汚れの 2 タイプに分けられる。撮像範囲の制限による未検出の例を図 5.1 に示す。図 4.4 のように、トラッキング限界領域に事故車両が停止した場合には、停止車両の前方空間が認識できないため、式 4.3 の論理での検出が原理的に不可能である。また、図 4.4 の例のように、非常に混雑した交通状態の場合、複数の車両を一台のオブジェクトとして認識してしまう等トラッキングの精度自体も低下するため、車線変更挙動の検出も難しい。こういった条件下で起こった事故は、既存のシステムで検出できないことがある。

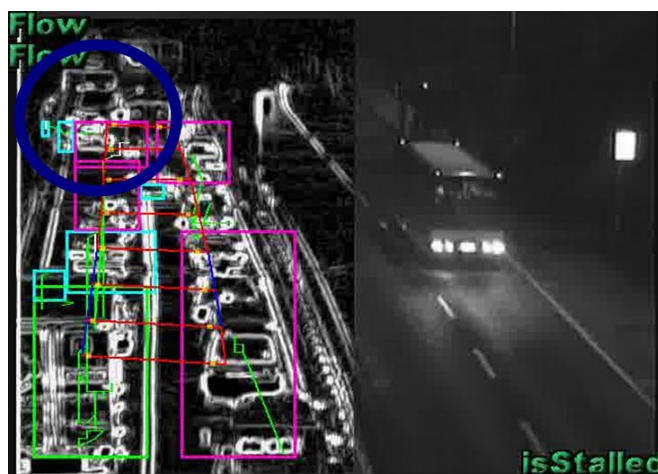


図 5.1: 撮像範囲の限界領域に停止する事故車

また、背景の汚れが原因で未検出となる場合の例を図 5.2、図 5.3 に示す。この例では、右車線中ほどで事故車両が停止しているが、背景に含まれるノイズのため、背景差分が十分に生じず、その結果トラッキング精度が低下し、事象検出に必要な意味情報 (停止挙動、車線変更挙動など) が抽出できないという問題が生じている。

一方、実際に事象が起こっていないにもかかわらず、システムが事象発生というアラームを発する誤報のケースについては、2 通りのパターンが確認されている。ひとつは、背景生成に影響するほど非常に混雑した交通流の場合に生じる誤報である。図 5.4 のように全ての車両が一定時間以上停止するほど混雑すると、リアルタイムで動的に生




図 5.2: 背景の汚れによる未検出の例




図 5.3: 背景に含まれるノイズ

成される背景にそれらの車両が取り込まれてしまう 5.5。そのため、S-T MRF モデルによるトラッキングアルゴリズムで本来背景差分が生じるべきオブジェクトの領域で背景差分が生じなくなる。その結果、実際には車両が存在する場所が、オブジェクトの存在しない空間として認識され、停止車両とその前方に空間が広がっていると捉えられるので、式 4.3 の論理で異常事象の誤報となる。

もうひとつのパターンは、片側車線のみが混雑して、他方の車線が自由流というケースで混雑を避けるために混雑した車線から自由流の車線への車線変更が頻発し、式 4.5 の論理で異常事象と判定されてしまうパターンである。図 5.6 がその例である。ここでは、上から順番に時系列に観測された 4 度の車線変更を示している。右車線で下流側から混雑してきて、それを避けるために左車線への車線変更を行う後続車両が 40 秒間の間に 4 度検出されたために、異常事象として誤発報された。

本研究では、これらの未検出、誤報の原因を考慮して、改善を試みた。改善に際しては、まず画像処理システムのアルゴリズムのみを改良することによって解決されるものについてそれらを試みた。この作業は、画像処理システム単体センサとしてのセンシング能力を高めるという意味を持ち、超音波感知器とのセンサ融合を行う前に行うべき重要な作業である。そしてそれだけでは解決できない事項については超音波感知器とのセンサ融合を行うことによって解決した。当該区間には 200～300m おきに超音波感知器が設置されているので、センサ融合を行う際にはこれらの情報と画像処理結果を融合した。

## 5.2 事象検出アルゴリズムの改良

実際に異常事象が起こっていないにも関わらず、システムが発報してしまう原因は、道路混雑時に背景に含まれるノイズが原因で本来検出されるべき車両が認識されないタイプのものと、片側車線のみが混雑しているために頻繁に車線変更が生じてしまうタイプの 2 種類に分けられる。一方未検出の原因としては、撮像範囲の限界領域に事故車両が停止した場合に、その前方空間が把握できないことが挙げられる。本節ではこれらの対策について検討する

### 5.2.1 背景の汚れによる誤報の対策

非常に混雑した渋滞時には、リアルタイムで生成される背景画像に渋滞中の停止車両が取り込まれてしまうために、S-T MRF によるトラッキングの際に背景差分が認識されず、その結果実際には車両がいる地点がなにもオブジェクトが存在しない空間と捉えられてしまう。その結果、図 5.4, 図 5.5 のようなケースでは式 4.3 の理論で異

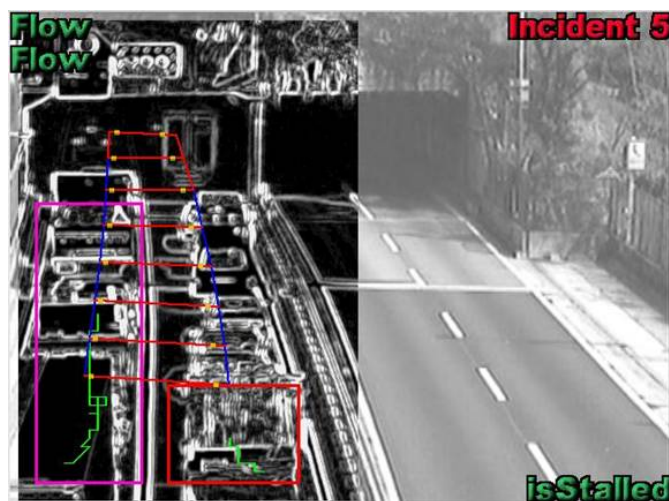


図 5.4: 背景の汚れによる誤報の例




図 5.5: 誤報時の背景に含まれるノイズ



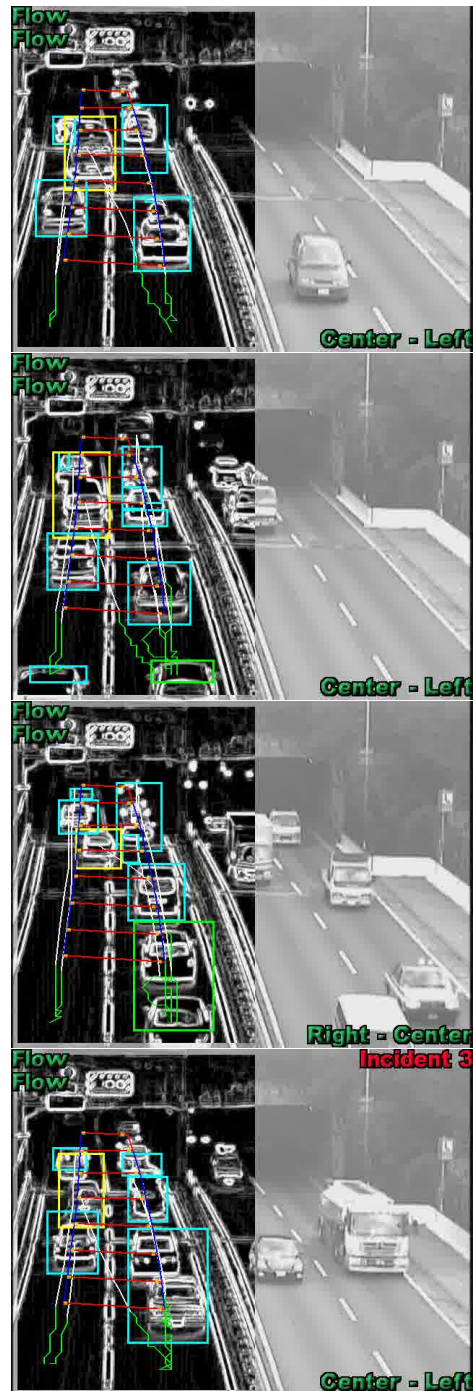


図 5.6: 同一地点で車線変更が起こった場合に生じる誤報の例

常事象の誤報が発報されてしまう。このタイプの誤報の対策として、式 4.1, 式 4.2 の論理による渋滞判定を利用することを提案する。

図 5.5 のようなノイズが背景に生じるほどの渋滞時には、画像処理システムが式 4.1 あるいは式 4.2 の論理によってすでに渋滞中であることを認識しているはずなので、渋滞中の場合は式 4.3 の論理による異常事象判定をマスクすれば、このタイプの誤報を防止することができる。このルールにより、式 4.3 は式 5.1 に置き換えられる。

$$b \equiv \exists(\text{typeOfTpTrajectory}(V.j) \wedge \text{isSpace}(V.j)) \wedge \neg \text{Congestion} \quad (5.1)$$

この方法で誤報をマスクすると、渋滞中の事故を式 4.3 の論理で検出することができなくなるが、渋滞中であれば確実に事故車両に対する避走挙動（車線変更によって停止車両を避けて走行する挙動）が観測されるはずであり、式 4.4 あるいは式 4.5 の論理によって事故の検出が可能である。

### 5.2.2 混雑時の車線変更挙動による誤報の対策

図 5.4 のように、車両が片側車線のみが混雑した状況では、同一地点で同一方向への車線変更挙動が頻繁に観測されるため、式 4.5 の論理によって異常事象の誤報が生じる。このタイプの誤報の対策として、直進車両（車線変更を行わずに撮像範囲内を通過した車両）が検出された場合にこの論理による異常事象判定をマスクするアルゴリズムを提案する。

式 4.5 は、混雑時にオクルージョンなどの影響で停止車両が正確に検出されなかったときでも確実に事故が検出されるための論理である。従って、確実に画像内に停止車両が存在しないことが分かっている場合にはこの論理による異常事象判定をマスクすべきである。本研究では、直進車両を検出することによって画像内この誤報をマスクすることにした。つまり、たとえ同一地点における同一方向への車線変更挙動が頻繁に観測されたとしても、その間に両車線ともで直進車両が観測された場合は、撮像範囲内に停止車両が存在しないはずであり、これらの車線変更は事故・停止車両の存在によるものではないと判断できる。この論理を式で表現すると、4.5 は式 5.2 で置き換えられる。

$$b \equiv 4 \leq \sum_i \{\text{LaneChanging} = \text{typeOfSpTrajectory}(V.i, L^k)\} \\ \wedge \neg(\text{RunStraight} = \text{typeOfSpTrajectory}(V.j)) \quad (5.2)$$



### 5.2.3 未検出の対策

実際に事象が起こっているにも関わらず、本画像処理システムが検出できないタイプは、図 5.1 に示したように撮像領域限界に事故車両が停止してしまうケースと、図 5.2、図 5.3 のように背景の汚れによる問題に分けられる。前者については停止車両が事故によって停車しているのか、下流側で渋滞が発生しているために停車しているのか、人間が目視でチェックしても判断できないことであり、これを単一画像センサのみで検出するのは原理的に不可能である。このため画像処理システム単体の性能向上によってこの問題を解決することは難しく、本研究ではこの問題を超音波感知器とのセンサ融合によって解決することにした。つまり、画像の撮像範囲のさらに下流側の超音波感知器出力を参照することにより、停止車両のさらに前方で渋滞が発生しているのかどうか判断可能となる。また後者については、停止、車線変更など車両挙動の抽出機能を超音波感知器などの局所型センサによって補助することは原理的に難しく、背景の生成方法が検討課題となるだろう。ただし、事故車両が偶然超音波感知器ヘッドの前に停止した場合や、停止車両が画像センサによって検出されて、その前方空間に超音波感知器の検出エリアが含まれている場合は、超音波とのセンサ融合によって解決できる問題となる。詳細は 6 節で述べる。

## 5.3 実験結果

提案アルゴリズムの検証を、首都高速道路のトンネル入口映像を用いて行った。recall rate の検証は、4ヶ月間の間に起こった事故データ 14 件を用いて行った。一方、誤報数の検証については、事故を含まない 100 時間のデータを用いて行った。recall rate の検証については、事故が発生してから 200 秒以内に発報された場合を検出成功と定義した。ここで、4 章で説明した交通監視システムはリアルタイム処理を前提として開発されたものであるが、映像をアナログ端子で PC に入力すると、同一の映像を処理しても実験結果に再現性がなく、そのため提案アルゴリズムの適用前後の変化がそのアルゴリズムの効果によるものかどうかの判断ができないという問題があった。このことを考慮して、本研究では入力画像としてあらかじめ PGM フォーマットの静止画列を用意し、それらのデータを入力して事象検出を行うオフラインでの検証を行った。なお、本論文では以後式 5.1、式 5.2 に示した誤報対策の論理を組み込む前の事象検出アルゴリズムを Algorithm-(a)、組み込んだ後のものを Algorithm-(b) と表記する。

### 5.3.1 recall rate の検証

式 5.1 と式 5.2 によるアルゴリズムの改良は、誤報の削減を目的としたものであり、原理的に recall rate が上がることはない。つまり、Algorithm-(a) から Algorithm-(b)

に変化したことによって、事故が検出できなくなるケースと事故の検出時間が長くなるケースがどれだけ存在するかが、本節の論点となる。

表 5.1 は、4ヶ月間の間に起こった事故 14 件のシステムによる検出結果である。recall rate は Algorithm-(a),(b) とともに 11/14(79%) となり、誤報対策による未検出件数の増加はなかった。また、Algorithm-(a) による事故検出時間、Algorithm-(b) による事故検出時間をそれぞれ図 5.7, 図 5.8 に、それらをまとめたものを図 5.9 にそれぞれ示した。事故検出に要した時間を 0 秒から 200 秒まで 10 秒ごとに区切ってカウントし、ヒストグラムで表示してある。横軸が検出時間、縦軸が事故件数を表す。なお、未検出となった事故については検出時間 200 秒以上としてヒストグラムに示されている。事故 14 件のうち、式 5.1 のマスク処理による事故検出の遅れはなかった。一方、式 5.2 のマスク処理による事故検出の遅れは 1 件確認された (図 5.10)。この実験結果では、図 (a) で検出された右から左への車線変更が図 (c) における左車線直進車両の誤検出によって、マスクされてしまった。この直進車両の誤検出は、図 (b) の左車線で、トラッキング領域下流側限界まで複数車両が 1 オブジェクトとして認識されてしまい、その後分離してしまったことによる誤報である。S-T MRF モデルによるトラッキングは背景差分による領域分割によってオブジェクトを追跡するため、この映像のように混雑した交通流の中で追従走行が生じるケースでは、複数車両が一つのオブジェクトとして認識されてしまう。この例では車線変更挙動が起こっている間は別車両であることが認識されていなかったが、その後分離してしまったため直進車両として検出される。

表 5.1: 事故検出数

	検出成功	検出失敗
Algorithm-(a)	11	3
Algorithm-(b)	11	3

### 5.3.2 誤報数の検証

平均 10 日に 1 件事故が起こる区間で取得した 100 時間の映像を用いて、誤報に関する検証を行った。Algorithm-(a),(b) による誤報数の違いを表 5.2 に示す。Algorithm-(a) では誤報数が 28 件であったのに対し、式 5.1、式 5.2 による誤報の対策を施した Algorithm-(b) による実験結果では、誤報は式 5.2 の論理によるもの 1 件のみであった。式 5.1 によってマスクされた誤報の例を図 5.11、図 5.12 に示す。これらの例のように、これまで前方空間の誤検出が原因で生じていた異常事象検出の誤報は 15 件あったのに対し、式 5.1 を適用することによってこれらの誤報はすべてマスクされた。ま




図 5.7: Algorithm-(a) による事故検出時間




図 5.8: Algorithm-(b) による事故検出時間





図 5.9: Algorithm-(a),(b) による事故検出時間

た、式 5.2 によってマスクされた誤報の例を図 5.13 に示す。これらの例のように、同一地点での車線変更のアルゴリズムによる誤報は式 5.2 を適用することによって 13 件から 1 件に削減された。式 5.2 でもマスクできなかった誤報は、車線変更の正検出と誤検出が短時間の間に同じ地点で発生したために生じたものである (図 5.14)。

表 5.2: 誤報数


誤報のタイプ (検出アルゴリズム)	停止&前方空間	同一地点での車線変更	合計
Algorithm-(a)	15	13	28
Algorithm-(b)	0	1	1



(a)



(b)



(c)

図 5.10: 式 5.2 による検出の遅れ

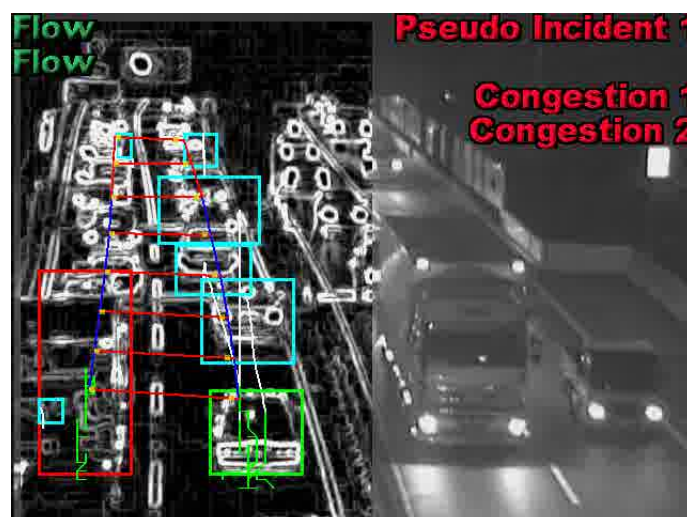


図 5.11: 式 5.1 によってマスクされた誤報

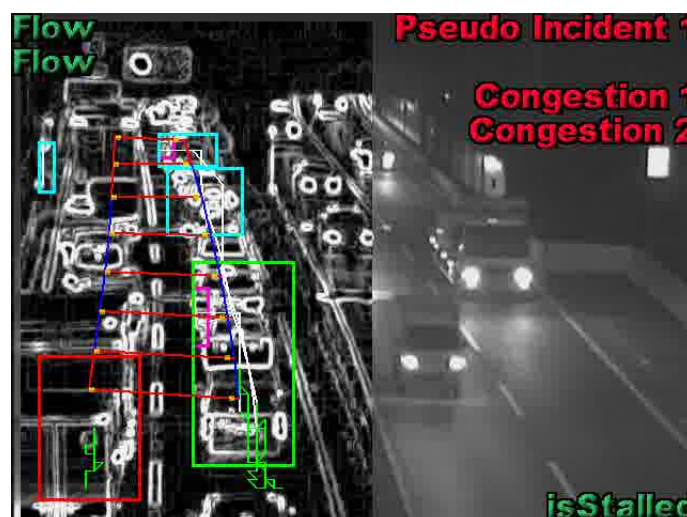


図 5.12: 式 5.1 によってマスクされた誤報




図 5.13: 式 5.2 によってマスクされた誤報






図 5.14: 式 5.2 でマスクできなかった誤報



## 第6章 画像と超音波のセンサ融合

本研究では、超音波感知器データを処理することにより交通事象認識に有効な情報を得ることを目的として、超音波感知器データの処理システムを開発した。このシステムを5章で説明した画像処理システムと融合することによって、既存の単体画像センサよりもさらに高い精度での事象認識が可能となる。本章では、まず超音波感知器データ処理システムの概要について説明する。続いて画像と超音波のセンサ融合による事象検出の検証を行ったので、それについて述べる。

## 6.1 システム概要

本章では 5 章で説明した既存の画像処理交通監視システムとのセンサ融合を目的として、超音波感知器データの処理システムを開発した。これまで、得られるパルスデータは一分間の統計データを計算するためだけに収集され、その目的が達せられるとデータサイズが大きいため廃棄されていた。しかし、パルスデータは 20msec 単位で得られる非常に粒度の細かいデータであり、特に異常事象の自動検知に用いるデータとしては、一分間データと比較して即応性という観点で優れている。特に、事故要因の一つと考えられている疎密波の伝播は数 10 秒間隔の細かい粒度で交通量を解析しなければ観測することができない。また発表文献 [2] では、超音波センサから得られる一分間データを用いて事故要因の解析を行ったところ、事故時の交通状況が追突事故や折込区間での車両接触と関連している可能性が示されている。事故時の詳細な交通状況を再現できるパルスデータを処理するシステムが実用化されれば、事故要因解析に大いに役立つデータを自動的に収集することも可能となる。

このパルスデータ処理システムは、PC 上で動作するソフトウェアとして実装した。システムで行われる処理は、大きくデータ入力、交通量・速度計算、事象検出、グラフ描画、画像処理システムとのネットワーク通信の 5 ブロックに分けられ (図 6.1)、それぞれ独立したスレッドとして動作する。本研究では入力データとして CSV フォーマットのパルスデータを用いたオフラインの解析を行ったが、同様の構成でリアルタイムでの動作も可能である。実験は Pentium 4 (3.2GHz)、メモリ 1024MB のマシンを用いて行った。このスペックのマシン一台で、11 地点  $\times$  2 車線  $\times$  2 ヘッド = 44 ヘッドのデータ処理が可能である。

データ入力部には、超音波センサから出力されるパルスデータが入力される。このパルスデータは、車両の感知・無感知の 1 ビットの情報が時系列に 20msec 毎の情報として得られるものである。1 地点につきセット側ヘッドとリセット側ヘッドの 2 ヘッドのパルスデータが得られ、車両が感知されている場合には 1、感知されない場合には 0 が入力される。また、車両が 1 地点に設置されているセンサの 2 ヘッドの間に存在する/しないを表す速度パルスも同様に 20msec 毎の情報として入力部に入力される。本研究では、入力パルスデータとして、あらかじめ CSV フォーマットで記述された超音波感知器データを用いた。この CSV ファイルには、感知パルスと速度パルスがそれぞれ 16 ビット表記で記述されている。例えば感知パルスが "...000FFFFFFFFF8000..." と記録されていたら、 $20\text{msec} \times 33 = 660\text{msec}$  の間、車両がセンサヘッドに感知されたことを意味する。同様に、例えば速度パルスが "...000FFFFFFFFFE..." と記録されていれば  $20\text{msec} \times 35 = 700\text{msec}$  の時間をかけて、位置地点に 5 メートル間隔で設置されている 2 ヘッドセンサの間を車両が移動したことを意味する。

データ入力部で得られた信号レベルのパルスデータは、交通量・速度計算部でより高レベルな交通流データへと加工される。このブロックでは交通流解析に必要な情報

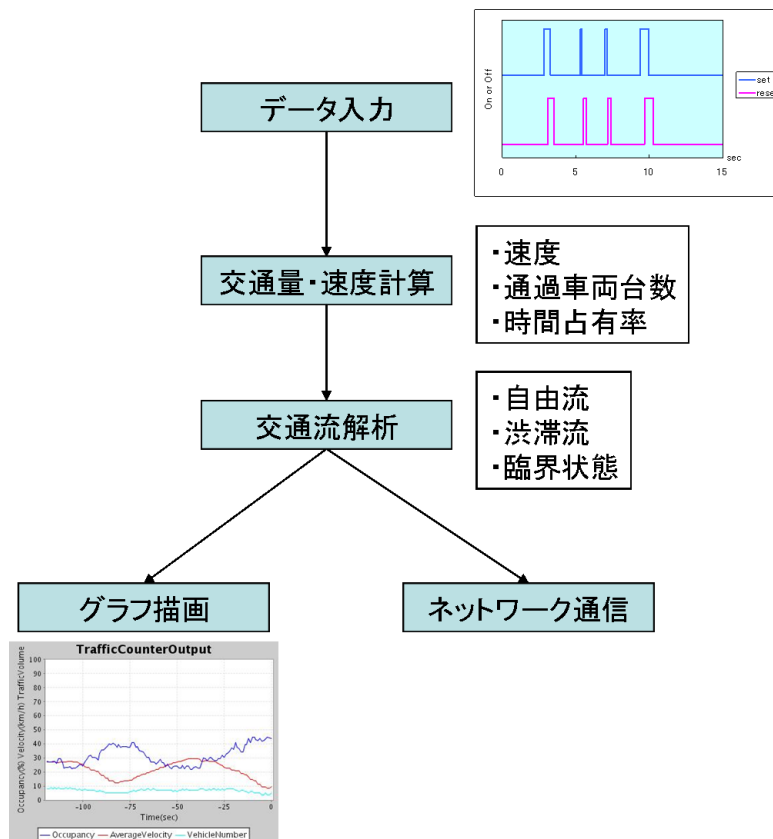


図 6.1: データ処理の流れ

である通過車両台数、車両速度、時間占有率の計算が行われる。ここで時間占有率は、ある時点から手前一定時間のうち、超音波センサヘッドが車両を感知した時間の割合として定義される。

さらに交通流解析部で、交通量・速度計算部で得られた交通流データを用いて、交通状態の認識（自由流・臨界状態・渋滞流）や疎密波の検出が 1 秒毎の頻度で行われる。そしてネットワーク通信部において、それらの情報が 4 章で説明した画像処理システムへネットワークを通じて提供される。画像処理システムは、画像処理システム単体で得られた情報にこれらの情報も融合して、事象検出を行う。また、これらの情報はグラフ描画部にも渡され、描画が行われる。

## 6.2 画像と超音波の融合による精度向上

5 章で、画像センサ単体の性能向上を行い、特に誤報数の削減という観点では大きな精度向上に成功した。本研究では、この画像センサと超音波感知器データ処理システムを融合することによって、さらなる事象検出精度の向上を目指した。センサ融合を行うにあたり、まず初めに図 4.1 に示した意味階層構造の中の上位階層（意味レベルの情報を有する階層）で融合するか、あるいは下位階層（信号レベルの情報を有する階層）で融合するかを決定する。階層が上位になるにつれて低レベルな情報（座標、動きベクトル等）から意味レベルの情報（停止、車線変更挙動等）への加工が行われるので、加工に際して失われる情報が存在する可能性はあるが、上位の情報の方が人間の認識と親和性が高い。このことは論理構造を明確にし、エラーに柔軟に対処するメンテナンス性の高さにつながる。本研究では、上位階層での意味情報を融合することによって論理構造を明確に保つことにした。

図 6.2 は、図 4.1 の意味階層構造にセンサ融合の処理を追加した様子を示したものである。図中左側の階層構造が 4 章で説明した画像処理システム、右側の階層構造が超音波感知器データ処理システムのフローをそれぞれ表す。超音波感知器データの処理は、画像処理システムと同様に信号レベルのパルスデータからよい意味レベルの高い情報（交通量、速度の算出、さらに渋滞流、自由流などの状態認識）へと加工を行い、最上位層で画像処理システムと融合され、事象検出が行われる。

### 6.2.1 Velocity\_Volume-class

図中パルスデータ処理システムの Velocity\_Volume-class では、超音波感知器から出力されるパルスデータをもとに、交通量、速度などといった、パルスデータよりも一段階意味レベルの高い情報の抽出が行われる。この階層で行われる 3 つのオペレーションを以下に示す。

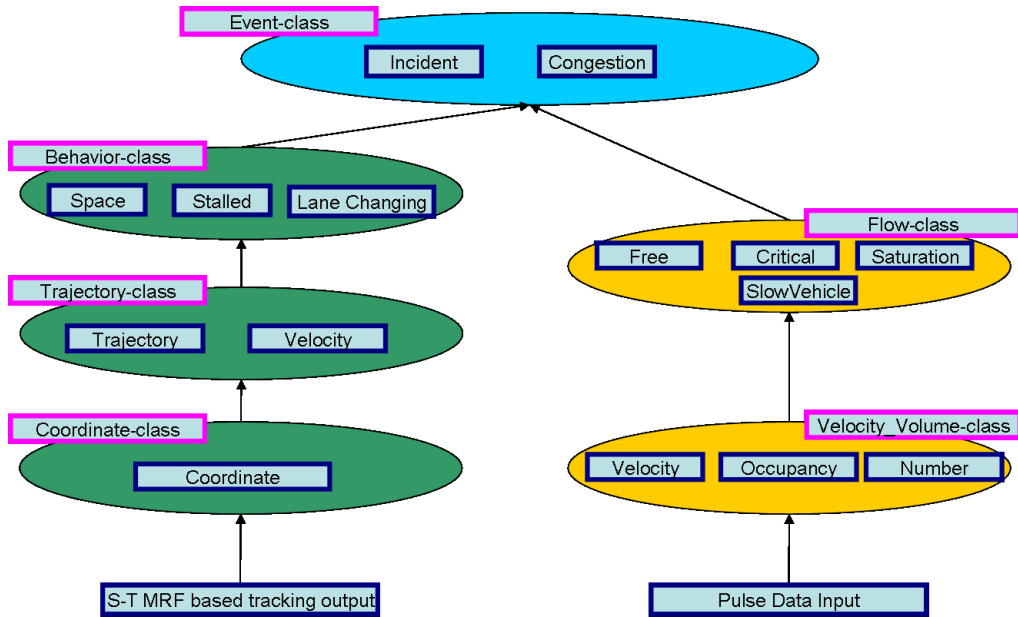


図 6.2: 意味レベルでのセンサ融合

- $getVelocity(L)$ : 地点  $L$  における速度を返す
- $getOccupancy(L)$ : 地点  $L$  における時間占有率を返す
- $getNumber(L)$ : 地点  $L$  における通過車両台数を返す

### 6.2.2 Flow-class

Velocity\_Volume-class で取得された情報はさらに一つ上位の階層である Flow-class で解釈され、交通流（渋滞流、自由流など）や低速車両の認識が行われた後、画像センサで取得された情報と融合され、事象検出が行われる。Flow-class に用意されているオペレーションを以下に示す。

- $isFree(L)$ : 地点  $L$  における交通が自由流である場合に True を返す
- $isSaturated(L)$ : 地点  $L$  における交通が渋滞流である場合に True を返す
- $isSlow(L, V_i)$ : 地点  $L$  において低速車両  $V_i$  が存在する場合に True を返す

自由流と渋滞流の境界（臨界状態）の設定を行うにあたり、当該区間の交通について QV 分布の解析を行った。20 秒平均、60 秒平均による QV 分布をそれぞれ図 6.3,

図 6.4 に示す。それぞれ、横軸が平均速度 (km/h)、縦軸が交通量 (台) を表す。一般に、渋滞流においては速度が増加すると交通量も増加し、自由流においては速度が増加するにつれて交通量が減少する。そして、その境界が臨界状態として定義される。本研究では実験地での臨界状態を定めるために、k-mean 法によって QV 分布のクラスタリングを行った。すると図に示されたとおり 20 秒平均、60 秒平均両方の場合について平均速度 40km/h を境にクラスが形成された。この結果をもとに、本研究では通過車両が存在する場合の交通流を、平均速度 40km/h 以上 (図中緑色のプロット) を自由流、平均速度 40km/h 以下 (図中緑色のプロット) を渋滞流として扱った。また、*isSlow* の速度閾値としては 30km/h と設定することにした。




図 6.3: 実験地での QV 分布 (20 秒平均)




図 6.4: 実験地での QV 分布 (60 秒平均)

### 6.3 速度パルスエラーの除去

開発した超音波感知器データの処理システム出力と画像を照らし合わせてみたところ、超音波センサの速度パルスにはエラーが含まれていることが分かった。確認されたエラーは 2 ヘッド間の車両存在時間が非常に長く測定される異常長速度パルスと、非常に短く測定される異常短速度パルスの 2 種類である。異常長速度パルスは 1 日の映像の中に 3 件、異常短速度パルスは 26 件確認された。1 日 40000 台の通過車両を考えると error rate は低い、事象検出の際には 1 日 29 件の速度パルスエラーが直接誤報につながる可能性がある、この種類の速度パルスエラーを削減する必要がある。

#### 6.3.1 異常長速度パルス

セット側ヘッドでオブジェクトが感知された後、リセット側ヘッドでオブジェクトが感知されるまでの時間が非常に長くなるタイプのエラーを異常長速度パルスと呼ぶ。セット側ヘッドで車両が感知された後、リセット側ヘッドまでの間に車線変更した時にこのようなエラーが生じる。この場合、非常に遅い速度が検出される。図 6.5 に、車線変更による異常長速度パルスの例を示す。グラフは図 (1),(2),(3) の右車線に設置されている超音波感知器の出力である。グラフ中赤線は個々の車両速度を表す。時間-180 秒で時速 2.5km/h の低速度が検出されたが、対応する時間には図中 (1),(2),(3) で時系列に示した車線変更挙動が超音波センサ 2 ヘッドの間で生じていた。24 時間の映像と、対応するパルスデータを確認したところ、車線変更が原因で 10km/h 以下と計測された速度パルスが 3 件存在することが分かった。

この種類のエラーを削減する方法ために、占有率を参照してエラーをマスクすることにした (式 6.1)。この結果、3 件のエラーは全てマスクされた。

$$vel\_err \equiv \exists (velocity < 10.0 \wedge occupancy < 8.0) \quad (6.1)$$

#### 6.3.2 異常短速度パルス

セット側ヘッドでオブジェクトが感知された直後にリセット側ヘッドでオブジェクトが感知された場合は、非常に短い速度パルスが検出される。高速車両が通過した場合を除くとこのタイプの速度パルスはエラーとなり、これを異常短速度パルスと呼ぶ。24 時間の映像と、対応するパルスデータをチェックしたところ、渋滞中にも関わらず 80km/h 以上と計測された速度が 26 件確認された。例を図 6.6 に示す。グラフは図 (1),(2),(3) の右車線に設置されている超音波感知器の出力である。グラフ中、時間-240 秒で 100km/h の速度が検出されているが、対応する時間は図 (1),(2),(3) に示した渋

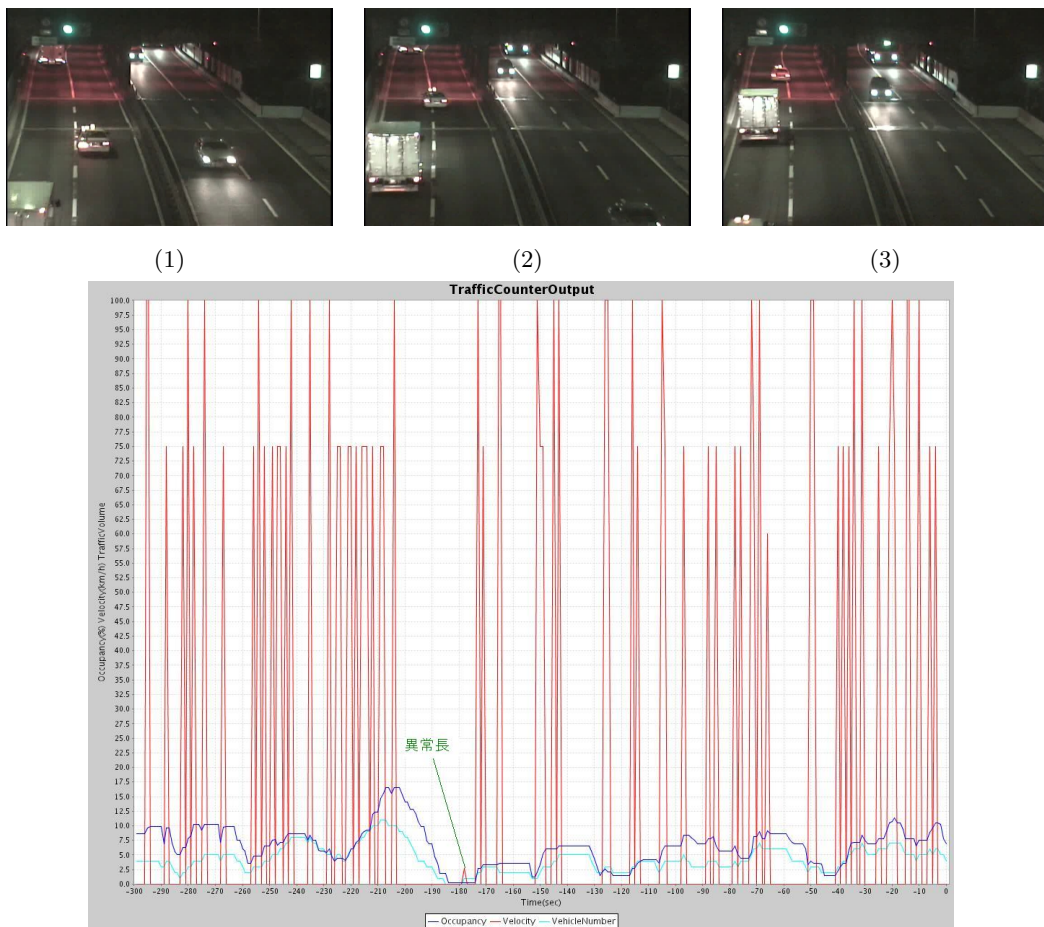


図 6.5: 車線変更による異常長速度パルスの発生



滞流であり、この速度検出はエラーと判断できる。この原因としては、2 台の車両が渋滞中にセット側ヘッドとリセット側ヘッドでほぼ同時に感知されたことが考えられる。

この種類のエラーを削減する方法ために、占有率を参照してエラーをマスクすることにした (式 6.2)。この結果、26 件のエラーのうち 18 件がマスクされた。

$$vel\_err \equiv \exists(velocity > 80.0 \wedge occupancy > 30.0) \quad (6.2)$$



図 6.6: 渋滞中に生じた異常短速度パルス

## 6.4 複数地点のセンサによる融合

本節では、検出対象領域が異なる画像センサと超音波センサを融合することによって、事象検出の精度を向上させる方法を述べる。検出精度の向上には、recall rate の

向上と誤報の削減の 2 通りが考えられる。誤報の削減については、5 章で、画像センサ単体による事象検出の誤報は式 5.2 の論理による 1 件のみと述べた。これは車線変更の誤検出が原因だが、車両追尾に不向きな局所型センサで車線変更挙動の情報を取得することは難しい。複数地点の超音波感知器の情報を取得しても、200～300m おきに設置された局所型センサを用いて車両追尾機能を実装することは難しい以上のことから、本節では複数地点のセンサによる融合で recall rate を向上させる方法について議論・提案を行う。

図 5.1 の例のように、撮像範囲の限界領域に事故車両が停止した場合、停止車両の前方に広がる空間を同一画像センサによって認識することが原理的に不可能であり、式 5.1 の論理による事象検出アルゴリズムが機能しない。画像内の最下流側で停止車両が検出されたとしても、さらに下流側の状況が把握できなければ停止挙動が渋滞末尾でのものなのか、事故によるものかといった区別をつけることができない。明確な避走挙動が観測されれば式 4.4、式 5.2 による検出も可能であるが、観測されない場合には未検出となってしまう。

このタイプの未検出は、画像センサのセンシング領域よりもさらに下流側に設置されているセンサを参照することによって解決できる。つまり、停止車両が画像内の最下流側で検出されたとき、さらに下流側の交通流が混雑している場合は渋滞、そうでない場合は事故による停止挙動と判定することで事故を検出することができる。この論理を式で表現すると式 6.3 となる。なお、式 6.3 において  $isStalled(V_i, L_{sl})$  は画像センサの機能、 $isFree(L_n)$  は超音波センサの機能となる。

$$b \equiv \exists(isStalled(V_i, L_{sl})) \wedge isFree(L_n) \quad (6.3)$$

$isStalled(V_i, L)$ : 車両  $i$  が地点  $L$  に停止している場合に True を返す

$L_{sl}$ : 画像センサのトラッキング限界領域

$L_n$ : 画像センサの検出領域より一つ下流側の超音波センサ設置地点

## 6.5 同一センシング対象に対するセンサ融合

本節では、センシング対象が一致している複数種類のセンサを用いて事象検出の精度を上げる方法について提案する。本研究の場合は画像センサの撮像範囲内に超音波センサが一台設置されており、これらの異種センサを融合することによって事象検出の精度を上げることができる。

recall rate の向上については、背景が汚れてしまって画像センサによる車両追尾が困難な場合、超音波感知器によって車両の挙動情報を補完できるケースはかなり限られる。例えば、偶然事故車両が超音波センサヘッダの前に停止した場合には、たとえ画像センサで停止挙動が検出できず、車線変更も検出できない場合でも超音波センサ



図 6.7: 画像センサの検出領域に設置された超音波感知器

によって停止車両の検出が可能であり、式 5.1 の論理で検出することもあり得る。しかし、このようなケースは稀であり、3ヶ月間の実験の中で得られた事故データの中に、このタイプの未検出は存在しなかった。

以上の理由から、本節では複数種類センサを用いた誤報の削減方法に焦点を絞って、センサ融合のアルゴリズムを提案する。予備実験の結果、式 6.3 の論理による事象検出では、背景の汚れによる誤報が生じることが分かった。

画像の中では下流に行くほど消失点に近づくため、リアルタイムで生成される背景で下流側にノイズが生じやすくなる。その結果背景差分が生じ、停止挙動の誤検出が起る。センサ融合を行う前にもこの種類の停止誤発報は起こっていたが、下流側のため前方空間が認識されず、また車線変更も発生しないので、これまで異常事象検出の誤報の原因とはならなかった。しかし本研究では式 6.3 の論理を事象判定アルゴリズムに追加するので、このタイプの誤報が増えることが予想される。そこで、画像センサによる停止挙動判定を、画像内の超音波感知器によって補正することで、誤報の削減を行う。画面内下流側で停止挙動が生じるときには、必ずその手前の超音波感知器が該当車両を低速車として検出しているはずなので、その条件が満たされていた場合のみ、式 6.3 を有効とすることにする。その結果、式 6.3 は式 6.4 に置き換えられる。

$$b \equiv \exists(isStalled(V_i, L_{sl})) \wedge isFree(L_n) \wedge \exists(isSlow(V_i, T_{now} - T_{th} < t < T_{now})) \quad (6.4)$$

$isSlow(V_i, T_{now} - T_{th} < t < T_{now})$ : 超音波感知器が手前  $T_{th}$  の時間内に低速走行車両を検出したら  $True$  を返す




図 6.8: 消失点付近で生じる停止判定の誤報



図 6.9: 背景に生じる消失点付近のノイズ

## 6.6 実験結果

画像センサと超音波感知器のセンサ融合による提案アルゴリズムの検証を行った。検証に用いたデータは、5 章で用いた画像データと、その時間に同じ地点に設置された超音波センサ、250m 下流側に設置された超音波センサから取得されたパルスデータである。recall rate の検証については、5 章と同様に事故が発生してから 200 秒以内に発報された場合を検出成功と定義した。また、5 章で述べたのと同様の理由から、画像データは PGM フォーマットの静止画列、パルスデータは CSV ファイルをシステムに入力するオフライン解析を行い、実験結果の再現性を持たせた。なお、本論文では以後センサ融合による式 6.4 を追加した事象検出アルゴリズムを Algorithm-(c) と表記する。

### 6.6.1 recall rate の検証

Algorithm-(c) は Algorithm-(b) に式 6.4 の論理を追加したので、原理的に recall rate が下がることはない。なお、式 6.3 から式 6.4 への変更による recall rate の低下や検出時間の延長は生じなかった。以上のことから、本節では recall rate の検証は未検出の削減、検出時間の短縮の 2 点に焦点をあてる。表 6.1 は、事故 14 件の検出結果である。画像センサのみによる検出 (Algorithm-(b)) では recall rate 11/14(79%) であったのに対し、超音波感知器との融合 (Algorithm-(c)) を行うことによって 12/14(86%) に向上した。また、各事故の検出時間を 10 秒区切りでヒストグラムにしたものを図 6.10(Algorithm-(c) のみ)、図 6.11(Algorithm-(b),(c)) に示す。なお、未検出となった事故については検出時間 200 秒以上としてヒストグラムに表示されている。センサ融合を行う前と比較すると、事故 13 件のうち、未検出だったものが検出できたケースが 1 件、検出時間が短縮されたケースが 2 件という結果であった。なお、検出時間が短縮されたケースのうちの 1 件は、式 5.2 によって検出時間が長くなってしまったものであった。

表 6.1: 事故検出数

	検出成功	検出失敗
Algorithm-(b)	11	3
Algorithm-(c)	12	2

検出時間が短縮されたケースを図 6.12、図 6.13、センサ融合によって初めて検出が可能となったケースを図 6.14 にそれぞれ示した。各図とも上側には、事故発生から事故検出までの状況を時系列画像で示している。また、下側に示したグラフは、停止判定




図 6.10: Algorithm-(c) による事故検出時間




図 6.11: Algorithm-(b),(c) による事故検出時間

が観測された車線の 250 メートル下流側に設置されている超音波感知器の出力をグラフで表したものである。グラフ中横軸が時間（単位は秒）、縦軸は速度 (km/h), 占有率 (%) 交通量 (台) を表す。赤線が平均速度、青線が占有率、水色線が交通量（それぞれ 20 秒間における計算結果）をそれぞれ示す。また、事故の発生時間と Algorithm-(c) による事故検出時間もグラフ中縦線で示している。それぞれ、事故検出時における下流の超音波センサ出力は平均速度 40km/h 以上の自由流を示しており、式 6.4 の論理から事故が検出された。なお、図 6.13、図 6.14 では事故車両の停止挙動（いずれも画像中左上）が画像センサによって検出できなかった。これは、後続の大型車両が事故車両を完全に隠してしまったことと、混雑時の事故のために後続車両と同一オブジェクトとして認識されてしまったことが原因である。事故車両が道路脇に停止したために後続車両の通過の妨げとなり、事故車両の停止地点が交通流のボトルネックとなっている。その結果、後続車両の通過速度が著しく低下し、画像内での旅行時間が長くなったため、それらの車両が停止判定によって検出され、式 6.4 によって事故が検出された。

### 6.6.2 誤報数の検証

本節では、式 6.3 から式 6.4 への改良による誤報の削減について実験結果を報告する。100 時間のデータを用いて行った誤報数の検証結果を表 6.2 に示す。超音波感知器との融合を行う前の段階では、誤報は 100 時間で式 5.2 の論理によるもの 1 件のみであった。ここに、式 6.3 の論理を追加して画像センサよりも下流側に設置された感知器情報を融合すると、前節で述べたとおり recall rate は上がったが誤報も 17 件増え、合計 18 件の誤報という結果になった。この主な原因は消失点付近で生じる背景の汚れがであり、それを解決するために式 6.3 を式 6.4 で置き換えたところ (表中 Algorithm-(c))、誤報数は合計で 5 件となった。

表 6.2: 誤報数

検出アルゴリズム	同一地点での車線変更	停止&下流の感知器出力	合計
Algorithm-(b)	0	1	1
Algorithm-(b) + 式 6.3	1	17	18
Algorithm-(c)	1	4	5

式 6.3 を式 6.4 に置き換えることによってマスクされた誤報の例を図 6.15、図 6.16 に示す。それぞれ上図が画像センサの出力、下図が画像センサの撮像範囲に設置されている超音波感知器の出力を表している。下図のグラフ中速度は個々の車両速度、占



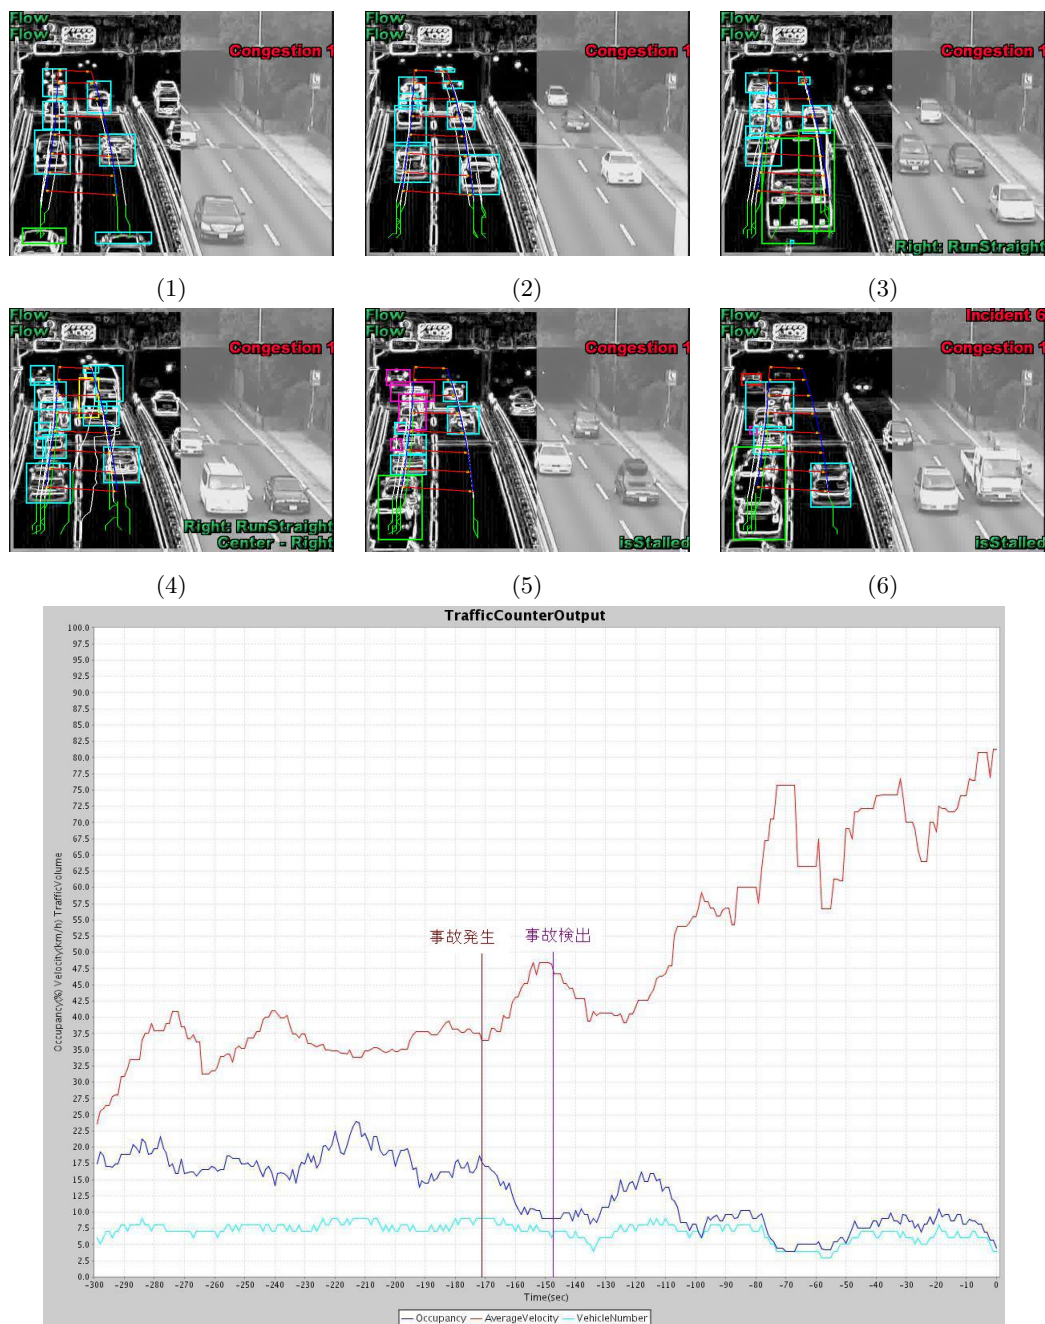


図 6.12: Algorithm-(c) による検出時間の短縮 (36 秒→23 秒)



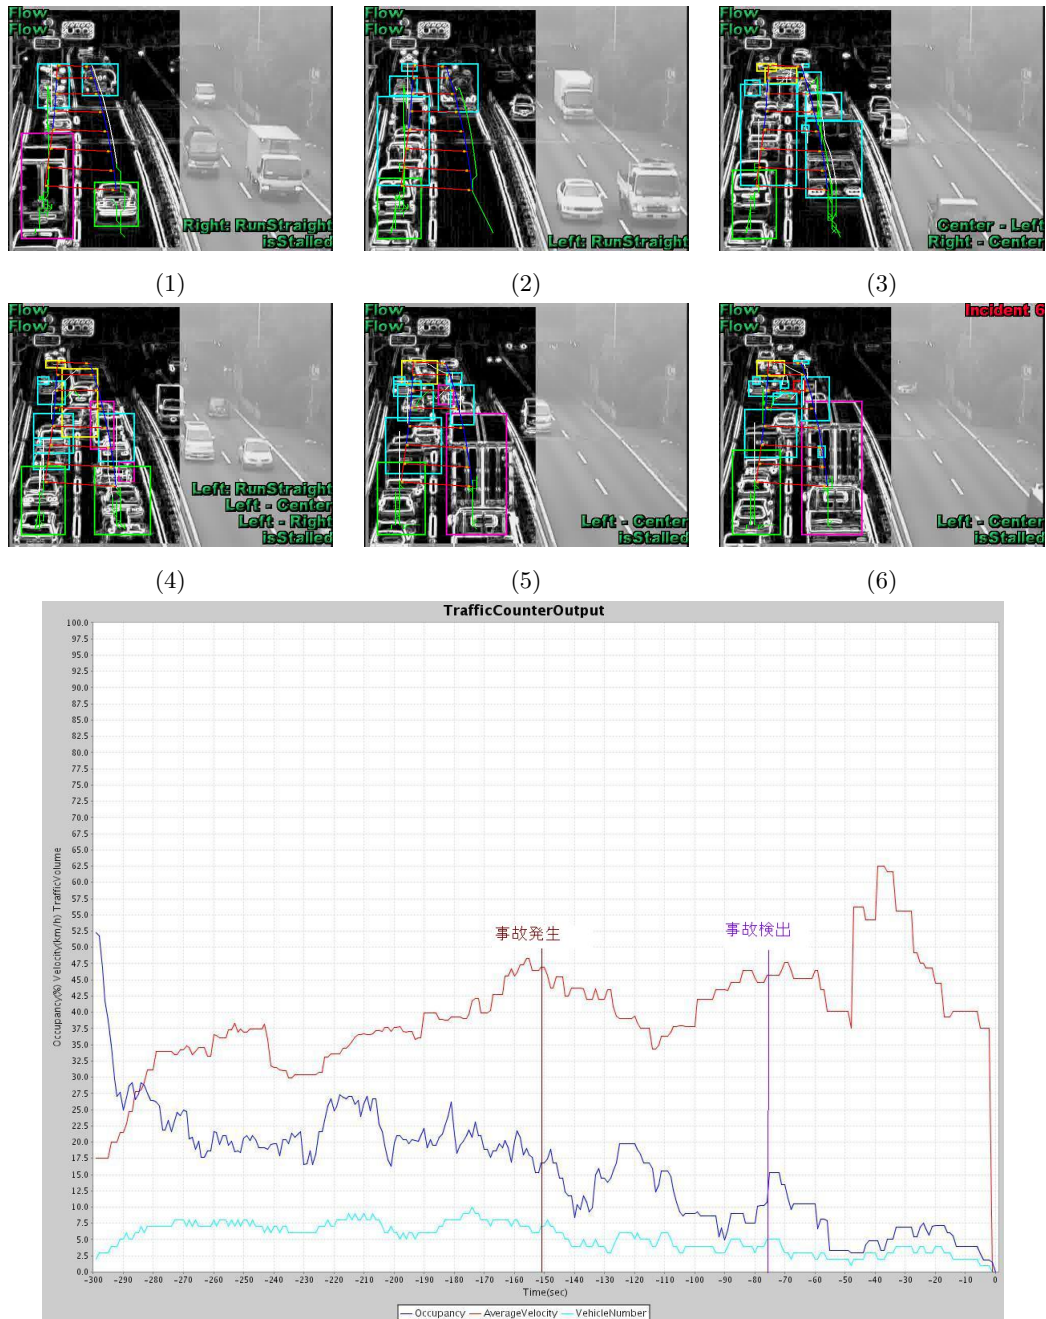


図 6.13: Algorithm-(c) による検出時間の短縮 (109 秒→75 秒)

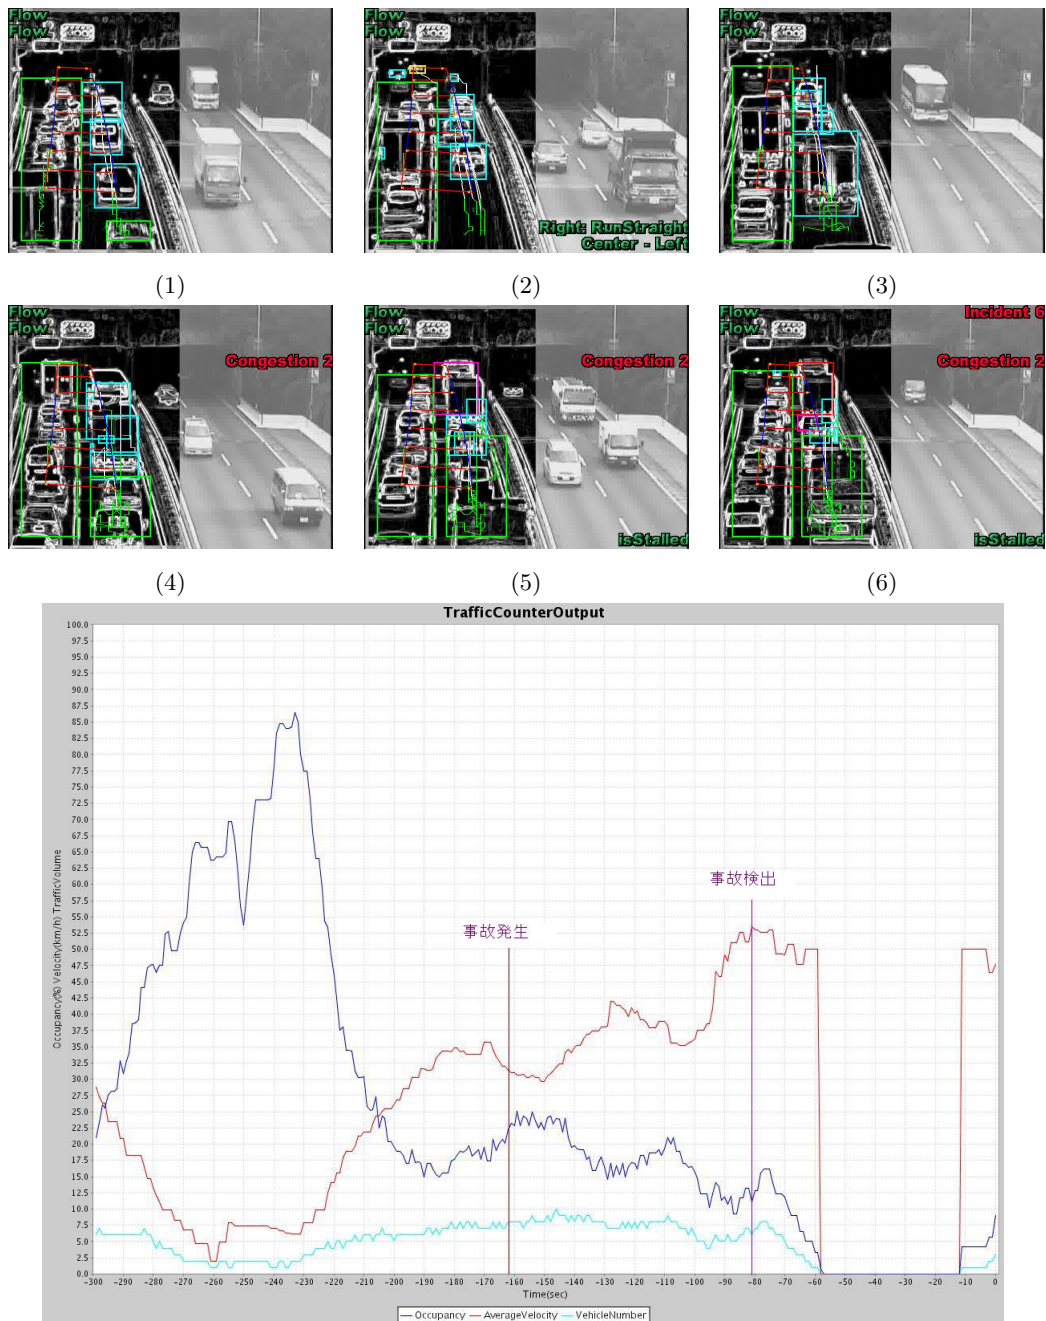


図 6.14: Algorithm-(c) による事故検出 (未検出→81 秒で検出)

有率、交通量は手前 20 秒間における計算結果である。いずれの場合も画像内下流側で停止判定の発報があった時点で、超音波センサにより該当低速車両が検出されなかったことから、誤報がマスクされた。

式 6.3 を式 6.4 に置き換えてもマスクされなかった誤報の例を図 6.17、図 6.18 に示す。グラフは画像センサよりも 250m 下流に設置された感知器の出力であり、グラフ中の速度は手前 20 秒間での平均速度を描画している。いずれの場合も画像センサでは渋滞による車両の停止挙動が正しく検出されている。グラフによれば該当する時間の前後では平均速度が 20 秒前後の短い周期で 10km/h 以下から 40km/h 以上まで大きく振動するショックウェーブ状の交通流となっており、このような状況のなかで 250m の区間において大きな速度差が生じ、異常事象と誤判定してしまったといえる。





図 6.15: 同一地点に設置された超音波感知器による誤報のマスク



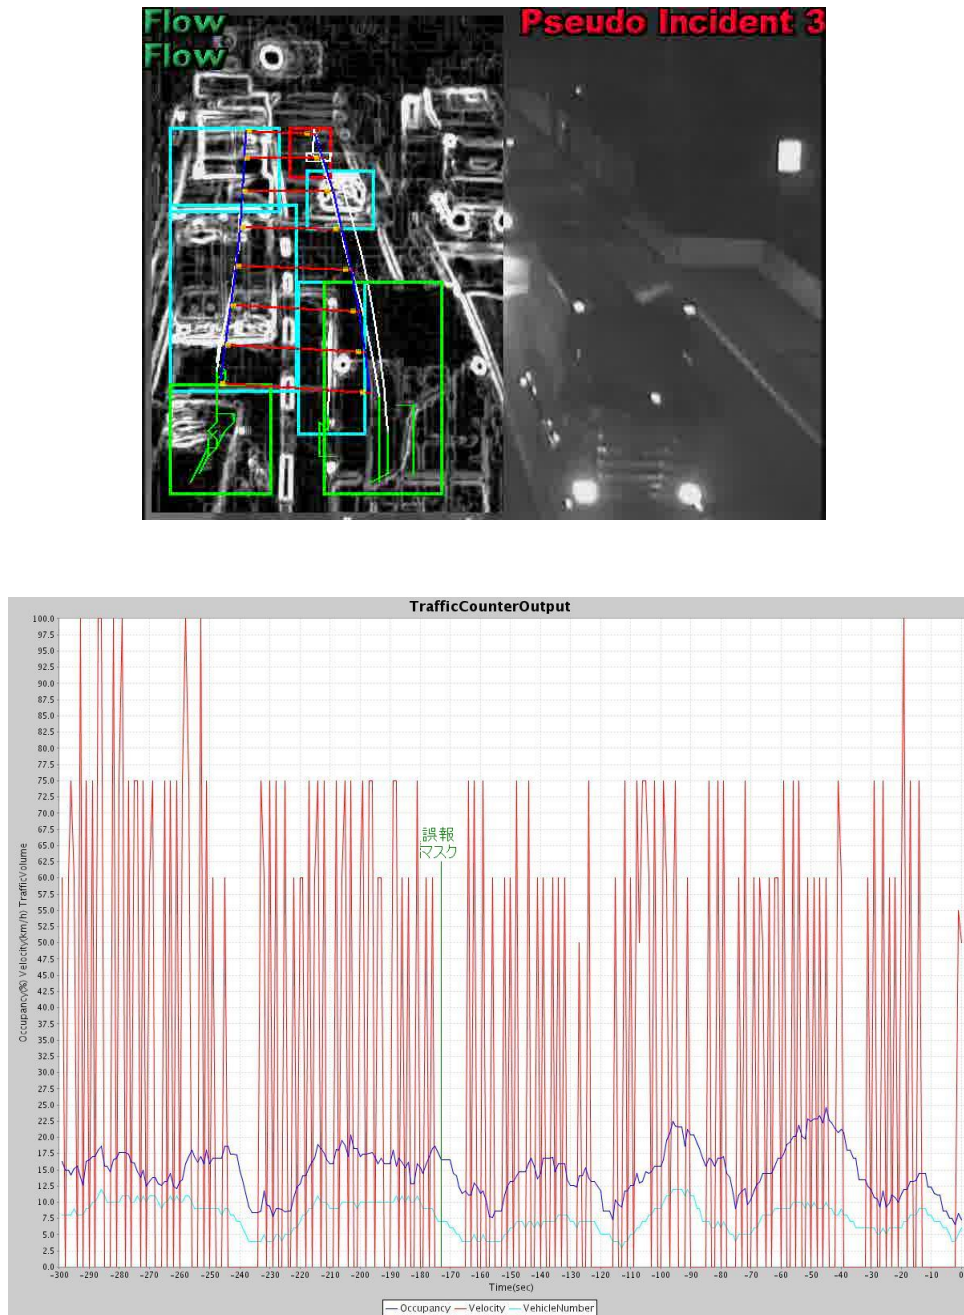


図 6.16: 同一地点に設置された超音波感知器による誤報のマスク





図 6.17: 式 6.4 による誤報





図 6.18: 式 6.4 による誤報

## 第7章 結論と今後の課題

本章では、本研究のまとめと今後の課題について述べる。



## 7.1 本研究のまとめ

本研究では、坂内・上條研究室で開発が進められてきた、画像処理交通監視システムの精度向上のために、画像処理システムのアルゴリズム改良と超音波感知器とのセンサ融合を提案した。

画像処理システムの改良は、主に誤報の削減に焦点をあてたものであり、事故 11 件中検出時間が長くなったものが 1 件あったものの、誤報が 100 時間あたり 28 件あったものが、1 件まで削減された。

続いて超音波感知器とのセンサ融合を行うことによって更なる検出精度の向上を試みた。同一地点の感知器と下流側の感知器を両方用いることで、「複数種類センサによる同一検出対象の精度向上」、「検出エリアの拡大」の両方の意義を満たすセンサ融合を行った。その結果、誤報が 100 時間あたり 1 件から 5 件に増えた一方で、事故の recall rate が 79% から 86% に上がり、検出時間が短くなった事故も 14 件中 2 件確認された。

結果として、既存システムと比較すると recall rate は 79% から 86% に向上、誤報数は 100 時間あたり 28 件から 5 件に減少した。

## 7.2 今後の課題

提案手法によって削減されたものの、いまだに生じる未検出・誤報の問題は今後も課題として取り組んでいく必要がある。混雑時に生じる背景のノイズによる未検出、ショックウェーブ状の交通流による誤報はの問題が課題として残った。

また、システムの評価を行うためには実験データがいまだ不十分であり、信頼できる結果を得るためには多くの評価データを用いて検証を行う必要がある。

さらに、開発したパルスデータの処理システムを用いた事故の原因究明も今後の課題となる。この用途のためには、車両感知性能だけでなく速度検出性能も高い精度が要求される。そのためには、速度パルスの異常長、異常短エラーの解決が重要である。

## 謝辞

本研究を進めるにあたり、適切な御指導、御助言をいただきました坂内正夫教授、上條俊介助教授に深く感謝致します。鋭いものの見方と柔軟な発想にはいつも敬服させられました。

また研究に欠かすことのできない交通資料を御提供いただき、貴重なご意見をくださいました首都高速道路株式会社の皆様に感謝の意を表したいと思います。

素晴らしい研究環境を整えてくださった技官の佐藤秀さん、映像チェックやデータ管理に協力していただいた技術補佐員の小師尚子さん、実験の手伝いを快く引き受けてくださった研究室の皆様にはいくら感謝してもしたりないくらいです。いろいろと至らない点もあり、皆様に御迷惑をお掛けしましたが、私にとって楽しく有意義な2年間でした。

最後に重ねて御礼申し上げます。

## 発表文献

- [1] Kenji Fujihira, Xiaolu Liu, Howard Koo, Shunsuke Kamijo and Masao Sakauchi, “AN INCIDENT DETECTION SYSTEM BASED ON SEMANTIC HIERARCHY AND DECISION SURFACE METHOD”, 12th World Congress on Intelligent Transport Systems. Paper No. 6455
- [2] 藤平健二, 福壽康弘, 割田博, 田中淳, 上條俊介, “大規模事故データからの事故要因知識発見 - 不確定データ空間の多次元探索による仮説生成 -”, 第4回 ITS シンポジウム 2005 O1-5
- [3] 藤平健二, 福壽康弘, 割田博, 田中淳, 上條俊介, “大規模事故データからの事故要因知識発見 - 不確定データ空間の多次元探索による仮説生成 -”, 電子情報通信学会 2005 年度 ITS 研究会

## 参考文献

- [1] S. Kamijo, T. Nishida, M. Sakauchi, "Occlusion robust and Illumination Invariant Vehicle Tracking for Acquiring Detailed Statistics from Traffic Images," IEICE TRANSACTIONS on Information and Systems, Vol. E85-D, No. 11, pp. 1753-1764, November 2002
- [2] H. Ikeda, T. Matsuo, Y. Kaneko, and K. Tsuji, "Abnormal incident detection system employing image processing technology," in Proc. IEEE Int. Conf. Intelligent Transportation Systems (ITS'99), Oct. 1999, pp. 748-752.
- [3] 上條俊介, 原田将弘, 坂内正夫, "統計モデルと意味階層構造の結合による交通映像異常事象検出システム", 電子情報通信学会論文誌 A Vol. J88-A No.2 pp.152-163
- [4] 電気学会・道路環境 センシング調査専門委員会編 "ITS 道路交通センシング", オーム社
- [5] 山崎弘郎, 石川正俊 "センサフュージョン" コロナ社
- [6] Nico Kaempchen, Klaus C.J.Dietmayer "Fusion Of Laserscanner And Video For Advanced Driver Assistace Systems" Proceedings of ITS 2004, 11th World Congress on Intelligent Transport Systems, October 2004, ITS 2004 Nagoya
- [7] Naoki Kawasaki "Standard Platform For Sensor Fusion On Advanced Driver Assistance System Using Baysean Network" Proceedings of ITS 2004, 11th World Congress on Intelligent Transport Systems, October 2004, ITS 2004 Nagoya
- [8] K.Sakagami, H. Takizawa, K.Yamada, T.Ito, "Forward-Looking Method Using Sensor Fusion with Monaural Camera and Radar", Proceedings of ITS 2004, 11th World Congress on Intelligent Transport Systems, October 2004, ITS 2004 Nagoya
- [9] Zhaosheng Yang, Jinqiao Feng, Ge Gao, Lixia Bao, "Research on Multi-Sensor Traffic Information Fusion Based on Kalman Filtering Theory", Proceedings of ITS 2004, 11th World Congress on Intelligent Transport Systems, October 2004, ITS 2004 Nagoya

- [10] Johannes Eschler, Luisa Andreone, “The Project Euclide: Human Machine Interaction of a Collision Warning System Based on Sensor Data Fusion” Proceedings of ITS 2004, 11th World Congress on Intelligent Transport Systems, October 2004, ITS 2004 Nagoya
- [11] S.C.Byun, D.B.Choi, B.H.Ahn, Hanseok Ko “Traffic Incident Detection Using Evidential Reasoning Based Data Fusion” Proceedings of ITS 1999, 6th World Congress on Intelligent Transport Systems
- [12] Eiichi Hasegawa, Masatoshi Onda, YOshihisa Kazuno, Shunsuke Kamijo “Development of Traffic Obstacles Detection System on Urban Tunnels with Heavy Traffic Flow”, 12th World Congress on Intelligent Transport Systems. Paper No. 3979
- [13] 田沢誠也, 長谷川栄一, 数野慶久, 上條俊介, “重交通量トンネルにおける交通異常検出の精度向上” 第4回 ITS シンポジウム 2005 O1-2
- [14] 牧野浩志, 山崎勲, 平沢隆之, 山田康右, 水谷博之, “路車協調システムを活用したカーブ区間における安全走行支援サービスの社会実験結果について” 第4回 ITS シンポジウム 2005 P1-13
- [15] 安全走行支援サービス参宮橋社会実験ホームページ  
<http://sangubashi.ahsra.or.jp/pc/index.html>
- [16] Kim Thomas, Hussein Dia “Neural Network incident detection on arterials using fusion of simulated probe vehicle and loop detector data”, 12th World Congress on Intelligent Transport Systems. Paper No. 6272
- [17] traficon web site  
<http://www.traficon.com/>
- [18] A. Mainwaring, J. Polastre, R. Szewczyk, D. Culler, and J. Anderson, “Wireless Sensor Networks For Habitat Monitoring” presented at the 1st ACM Int. Workshop Wireless Sensor Networks and Applications, Atlanta, GA, 2002
- [19] 山田憲一, 伊藤敏夫, “ネットワーク型センサ融合による走行環境理解の一手法” 電子情報通信学会論文誌 Vol.J86-D- No.2 pp.223-232 2003 年 2 月
- [20] “交通事故による経済的損失に関する調査研究報告書概要” available from  
<http://www8.cao.go.jp/koutu/chou-ken/sonshitsu.pdf> “内閣府 交通安全対策ホームページ”

- [21] H. Veeraraghavan, O. Masoud, and N. P. Papanikolopoulos, “Computer Vision Algorithms for Intersection Monitoring”, IEEE Trans. ITS, VOL.4, NO.2, June 2003
- [22] Y. Jung, K. Lee, and Y. Ho “Content-Based Event Retrieval Using Semantic Scene Interpretation for Automated Traffic Surveillance”, IEEE Trans. ITS, VOL.2, NO.3, Sept 2001
- [23] R. Cucchiara, M. Piccardi, and P. Mello “Image Analysis and Rule-Based Reasoning for a Traffic Monitoring System”, IEEE Trans. ITS, VOL.1, NO.2, June 2000
- [24] X. ZHANG, J. WANG, T. Fang, “Improving the Mixture Gaussian Model for Video-based Traffic flow Detection System”, 11th World Congress on ITS, Nagoya, Oct 2004
- [25] T. N. Schoepflin and D. J. Dailey, “Dynamic Camera Calibration of Roadside Traffic Management Cameras for Vehicle Speed Estimation”, IEEE Trans. ITS, VOL.4, NO.2, June 2003
- [26] J. Versavel, “Securing Our Roads: Automatic Incident Detection, The European Experience”, 10th World Congress on ITS, Madrid, Nov 2003
- [27] K. Zhang and M. A P Taylor, “A New Method for Incident Detection on Urban Arterial Roads”, 11th World Congress on ITS, Nagoya, Oct 2004
- [28] D. Srinivasan, X. Jin, and R. Long Cheu, “Evaluation of Adaptive Neural Network Models for Freeway Incident Detection”, IEEE Trans. ITS, VOL.5, NO.1, March 2004
- [29] J. Ohya, et.al., “Development of Automatic Incident Detection Algorithm Using Cumulative Trips Data”, 10th World Congress on ITS, Madrid, Nov 2003
- [30] Y.Satoshi and A.Atsushi, “Development and Implementation of an Algorithm to Detect Unusual Traffic Conditions on the Hanshin Expressway”, 11th World Congress on ITS, Nagoya, Oct 2004