

異種センサ融合ネットワークによる交通事象観測

上條俊介^{*}・坂内正夫^{*}

Shunsuke KAMIJO and Masao SAKAUCHI

1. 研究概要

交通監視システムは、事故の早期発見だけではなく、過去の事故要因を蓄積し、交通事故の未然の防止を実現する役割も期待されている。これまで行われてきた交通監視システムの開発では、重交通量区間における事象認識が課題とされてきた。本論文では、画像と超音波のセンサ融合によって、重交通にも適用可能な交通監視システムの開発を行った。画像センサとして用いたのは、複数車線の無分岐道路に特化したリアルタイム交通監視システムである[1]。このシステムは交通量40000台/日、事故発生頻度が1件/10日の区間でこれまで評価が行われてきた。本論文では、まずこの画像処理システムの事象検出アルゴリズムを改良して誤報の削減を行った。続いて複数地点の超音波センサ出力と融合することによって、単一センサでは検出が困難な事故検出を可能とした。検証の結果、recall rateは79%から86%に向上し、誤報数は100時間あたり28件から5件まで削減された。

2. センサ融合技術

本論文で用いた画像センサと超音波センサの特徴を表1に示す。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。また画像センサその撮像範囲内の交通流をカメラ一台でカバーできるので、各車線ごとに設置しなければならない超音波センサと比較すると設置コストを抑えることができる。

一方、超音波センサを用いることの利点は、検出性能の高さである。車両検出、台数計測、速度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。また、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や雨、霧などの天候変動によらず安定した検出を行うことができる。さらに扱うデータ量が画像よりも少なく、スペックの低い計算機でも複数地点のデータを処理できるという長所もある。

本論文では、これらの互いに相補的な特性をもつ複数地点の異種センサを融合することによって、単一センサを用いる場合よりも高精度な事象検出を行った。

3. 既存画像処理システム概要

3.1. 意味階層構造

本論文で用いた画像処理システムは、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

表1 可視カメラと超音波センサの比較

条件	可視カメラ	超音波センサ
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	△	○

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。

第一階層である座標クラス(Coordinate-class)の入力部にはS-T MRFモデル([2],[3][4][5])によるトラッキング結果が入力される。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異常事象や渋滞の検出が第四階層の事象クラス(Event-class)で行われる。このような処理による事象検出は、人間の認識過程との親和性が高く、交通管制官や交通工学研究者の理解との整合性を保つことができる。

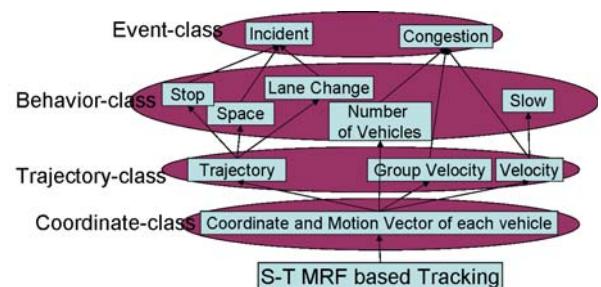


図1 意味階層構造

3.2. 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

*東京大学生産技術研究所

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。

$$c \equiv runManyV() \wedge ave(getVel(V_i)) < V_1 \quad (1)$$

$$c \equiv (((T_{ex} = \sum_i^T objExist(t)) > 0.8 \times T_i) \wedge ((\sum_t^{T_{ex}} (getVelGr(t) < V_1)) > 0.95 \times T_{ex})) \quad (2)$$

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

getVel(V_i):車両 *V_i* 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 1、式 2 の二つの論理で表される。式 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 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 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 2 によって渋滞の判定を行うことができる。

3.3. 異常事象判定

$$b \equiv \exists(typeOfTpTrajectory(V.j) \wedge isSpace(V.j)) \quad (3)$$

$$b \equiv typeOfTpTrajectory(V.j) \wedge (3 \leq \sum_i \{LaneChanging \\ = typeOfSpTrajectory(V.i, V.j)\}) \quad (4)$$

$$b \equiv 4 \leq \sum_i \{LaneChanging \\ = typeOfSpTrajectory(V.i, L^k)\} \quad (5)$$

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

このシステムにおける異常事象の判定アルゴリズム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)に着目し、それらの組み合わせで事故を検出する。異常事象判定アルゴリズムは 3 つの式(式 3、式 4、式 5)で構成される。式 3 は、車両の停止挙動とその前に発生する空間の広さが閾値を超えたたら、事故と判定する論理を表す(図 2)。式 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(図 3)。式 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(図 4)。



図 2 事故車両と前方空間による事故検出

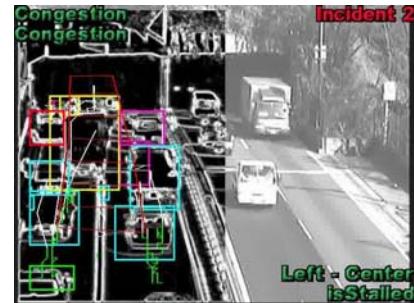


図 3 事故車両に対する車線変更挙動による事故検出

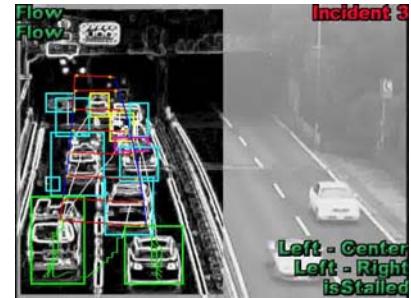


図 4 車線変更挙動による事故検出

4. 画像センサの性能向上

本章では、3 章で紹介した画像処理システムの改良案を述べる。このシステムの誤報の原因として挙げられているものは、渋滞時に生成される背景に車両が取り込まれてしまうことによる車両の未検知と、事故以外の原因で、同一地点での車線変更挙動の発生が挙げられる。

4.1. 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 のようなケースでは式 3 の理論で異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1、式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1あるいは式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3は式6に置き換えられる。

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

$$\wedge \neg Congestion \quad (6)$$



図5 背景の汚れによる誤報の例

4.2. 事故以外の車線変更挙動による誤報の対策

図6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るべきである。本論文では、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、式5は式7で置き換えられる。

$$b \equiv 4 \leq \sum_i \{ LaneChanging \\ = typeOfSpTrajectory(V.i, L^k) \} \\ \wedge \neg (RunStraight = typeOfSpTrajectory(V.j)) \quad (7)$$

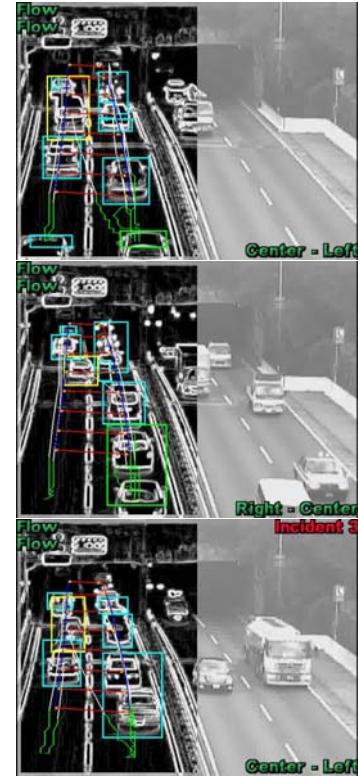


図6 同一地点で車線変更が起こった場合に生じる誤報の例

5. 画像と超音波のセンサ融合

本章では、画像センサとの融合を目的として開発した超音波感知器データ処理システムを紹介する。このシステムを前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。

5.1. システム概要

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、事象検出の3ブロックに分けられ(図7)、それぞれ独立したスレッドとして動作する。

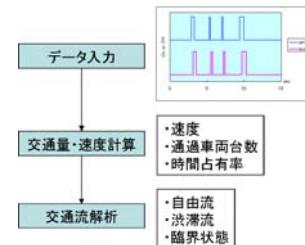


図7 データ処理の流れ

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 20 msec 毎の情報として入力部に入力される。本論文では、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。

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・速度計算部に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である通過車両数、車両速度、時間占有率の計算が行われる。

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）が 1 秒毎の頻度で行われる。

5.2. 画像と超音波の融合による検出精度向上

図 8 は、図 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 3 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。

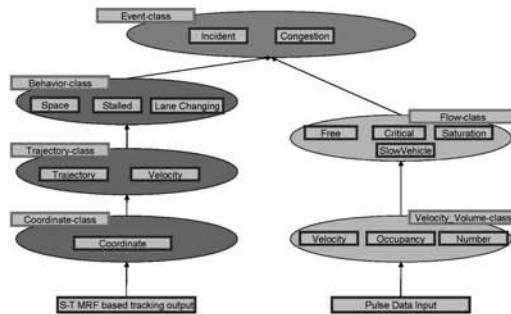


図 8 意味レベルでのセンサ融合

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。

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

Velocity_Volume-class で取得された情報はさらに一つ上の階層である 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。

- $\text{isFree}(L)$: 地点 L における交通が自由流である場合に True を返す
- $\text{isSaturated}(L)$: 地点 L における交通が渋滞流である場合に True を返す
- $\text{isSlow}(L, V_i)$: 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（図 9）。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。本報告書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。平均速度 40 km/h を境にクラスターが形成されたので、通過車両が存在する場合の交通流を、平均速度 40 km/h 以上（図中緑色のプロット）を自由流、平均速度 40 km/h 以下（図中青色のプロット）を渋滞流として扱った。また、 isSlow の速度閾値としては 30 km/h と設定することにした。

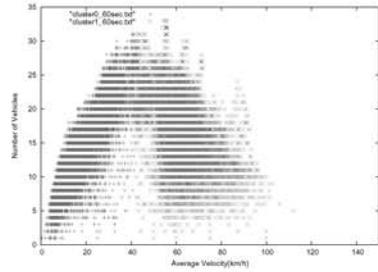


図 9 実験地での QV 分布
5.3. 複数地点のセンサによる融合

図 10 の青枠で示した例のように、撮像範囲の限界領域に事故車両が停止した場合、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、事故によるもののかといった区別をつけることができず、事象認識が原理的に不可能である。



図 10 撮像範囲の限界領域に停止する事故車

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 8 となる。なお、式 8 において $\text{isStalled}(V_i, L_{sl})$ は画像センサの機能、 $\text{isFree}(L_n)$ は超音波センサの機能となる。

$$b \equiv \exists (\text{isStalled}(V_i, L_{sl})) \wedge \text{isFree}(L_n) \quad (8)$$

$\text{isStalled}(V_i, L)$: 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

5.4. 同一センシング対象に対するセンサ融合

予備実験の結果、式8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。



図 11 消失点付近で生じる停止判定の誤報と背景

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こる(図11)。式8の論理を事象判定アルゴリズムに追加することによって生じたこのタイプの誤報は、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、マスクすることができる。画面内下流側で停止挙動が生じるときには、必ず同一地点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8を有効とすることにする。その結果、式8は式9に置き換えられる。

$$\begin{aligned} b \equiv & \exists (isStalled(V_i, L_{sl})) \wedge isFree(L_n) \\ & \wedge \exists (isSlow(V_i, T_{now} - T_{th} < t < T_{now})) \quad (9) \end{aligned}$$

$isSlow(V_i, T_{now} - T_{th} < t < T_{now})$: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

6. 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のPGMフォーマットによる静止画列と、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を用いて行った。recall rateの検証は、4ヶ月間の間に起きた事故データ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。

6.1. recall rate の検証

recall rateは画像センサのみの場合はアルゴリズム改良前後ともに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。さらに超音波センサと融合すると12/14(86%)と向上した(表2)。

表 2 recall rate

	検出	未検出	再現率 (%)
画像のみ 改良前	11	3	79
画像のみ 改良後	11	3	79
画像&超音波センサ	12	2	86

また、事故検出時間を図12に示した。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

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。画像センサのみによる検出では誤報マスクのアルゴリズムによる検出の遅れは、式7のマスク処理によるもの1件のみで、これは直進車両の誤検出によるものである。さらに、超音波センサの情報を融合することで、未検出が1件減った他に2件の検出時間が短縮された。センサ融合の成功例を図13に示した。グラフは停止判定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で、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。

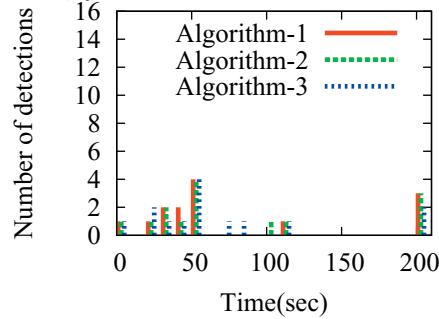


図 12 事故検出時間(赤: 画像のみ(改良前)、緑: 画像のみ(改良後)、青: センサ融合)

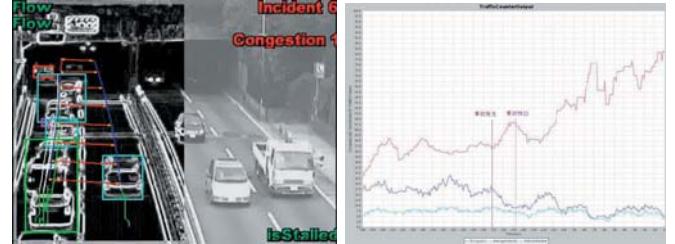


図 13 センサ融合による事故検出例(グラフ中2本の縦線は事故発生時間と事故検出時間)

6.2. 誤報数の検証

100時間の映像を用いて誤報に関する検証を行った結果を表3に示す。画像センサのみの場合、改良前は誤報数が28件であったのに対し、式6、式7による改良後の実験結果では、誤報は式7の論理によるもの1件のみであった。式6によってマスクされた誤報の例を図14に示す。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6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。また、式7によってマスクされた誤報の例を図15に示す。同一地点での車線変更のアルゴリズムによる誤報は式7を適用することによって13件から1件に削減された。式7でもマスクできなかつた誤報は、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。

そして超音波センサとの融合を行った結果、下流の感知器のみと融合した場合は誤報が17件増加したが、さらに画像センサと同一地点の感知器を融合することによって13件がマスクされ、結果として100時間データにおける誤報数は5件となった。同一地点の感知器データにより誤報のマスクが成功した例を図14に示す。また、マスクされなかつた誤報の例を図15に示す。誤報の原因是、渋滞時に生

表 3 誤報数

	停止&前方空間	車線変更	停止&下流が疎	合計
画像のみ 改良前	15	13	0	28
画像のみ 改良後	0	1	0	1
融合 (画像&下流の感知器)	0	1	17	18
融合 (画像&下流の感知器&同一地点の感知器)	0	1	4	5

じる疎密波によって下流感知器の位置と画像センサの位置とで大きな速度差が生じてしまったことである。



図 14 式 6 によってマスクされた誤報

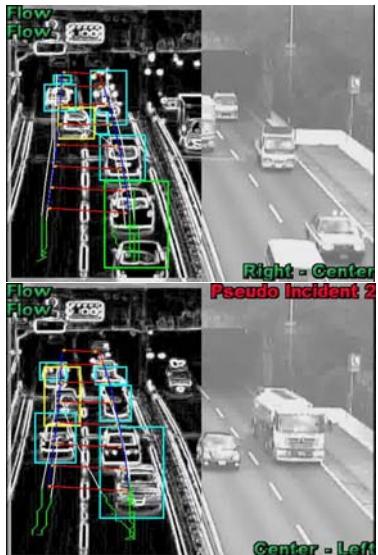


図 15 式 7 によってマスクされた誤報

7. おわりに

本研究では、既存画像処理システムの事象検出アルゴリズムを渋滞検出と直進車両検出を用いて改善する手法を提案し、さらに超音波感知器とのセンサ融合による精度の向上策を述べた。検証の結果、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。

今後の課題としては、開発したパルスデータ処理システムを用いて事故の原因究明があげられる。



図 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

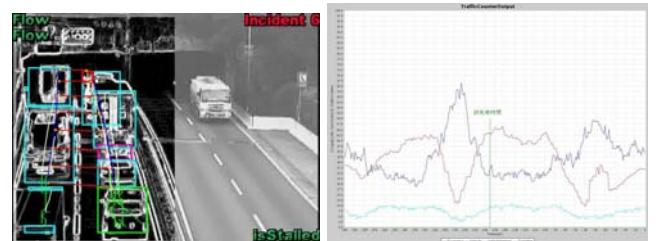


図 17 式 9 による誤報 (図中緑の縦線は誤報時間)

参考文献

- [1] 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
- [2] S.Kamijo, T.Nishida, M.Sakauchi, “Occlusion Robust and Illumination Invariant Vehicle Tracking for Acquiring Detailed Statistics from Traffic Images”, IEICE Trans. Information and Systems, Vol.E85-D No.11, pp1753-1764, November 2002.
- [3] S.Kamijo, Y.Matsushita, K.Ikeuchi, M.Sakauchi, “Occlusion Robust Tracking utilizing Spatio-Temporal Markov Random Field Model”, IEEE ICPR, Vol.1 pp142-147, 2000.
- [4] S.Kamijo, K.Ikeuchi, M.Sakauchi, “Illumination Invariant Segmentation of Spatio-Temporal Images by Spatio-Temporal Markov Random Field Model”, IEEE ICPR, Vol.2, pp.617-622, 2002.
- [5] S.Kamijo, Y.Matsushita, K.Ikeuchi, M.Sakauchi, “Traffic Monitoring and Accident Detection at Intersections”, IEEE Trans. ITS, Vol.1 No.2, pp.108-118, June 2000.