

統計モデルと意味階層の結合による交通映像異常事象検出システム

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、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が期待されている。そのために交通監視システムは、潤沢な映像情報を活用し、異常交通事象の検出を行う。本研究では、任意の車線数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を開発し、2車線道路で検証実験を行った。本システムは高精度に車両を追跡し、様々な交通事象の検出を行う。車両追跡アルゴリズムには、時空間 MRF モデル [1][2][3][4] を適用し、隠れや照度変化に対して頑健な処理を行うと同時に高精度な車両軌跡を獲得する。異常事象検出アルゴリズムは、ルールベース手法に基づき、個々の車両の挙動に注目したもの、複数車両の相互挙動に注目したもの、特徴空間上の識別面で判別するものからなる、3つの異なるアルゴリズムを用意し、異常交通事象の検出を可能にする。実際の交通映像を用いた実験において、59件中56件の交通事故検出を達成した。

2. 開発したシステムの概要

開発したシステムの基本的な構成は、映像の撮影を行うテレビカメラと、映像の処理を行うPCの2つからなる。道路には既に多数のテレビカメラが設置されており、開発したシステムは既存の設備を活用する。全ての映像処理は、PC上でソフトウェアとして実装されている。

本システムは、大きく6つのブロック(映像入力部、映像処理部、背景生成部、車両追跡部、事象検出部、映像保存部)に別れている。各ブロックは、それぞれ独立したスレッドで動作しており処理の高速化がなされている。本システムにおける処理の流れを図1に示す。本システムは、大きく6つのブロック(映像入力部、映像処理部、背景生成部、車両追跡部、事象検出部、映像保存部)に別れている。各ブロックは、それぞれ独立したスレッドで動作しており処理の高速化がなされている。

映像入力部では、NTSC信号で入力される映像のPCへの取り込みを行っている。取り込まれた映像の量子化と標本化は、取得される映像によって異なる。例えば、地点1の映像に対しては、16bitのYUV422カラーフォーマット、640×480画素、10フレーム/秒で行っている。映像処理部では、映像の濃淡画像への変換、照度不変な画像への変換を行っている。入力がNTSC信号であるため、変換された濃淡画像はインターレス画像である。これを、ブランクになっているラインを前後のラインで線形補間し、仮想的にプログレッシブ化している。また、ノイズ対策としてガウシアンフィルタで平滑化も行う。そして、平滑化された画像を、照度不変な画像へと変換する。この処理は、開発したシステムのように24時間稼働することが求められる場合、光の強度の変化や局所的な輝度の変化に対して頑健

に処理するために必要となる。背景生成部では、動的な背景の生成を行う。車両追跡部では、時空間 MRF を適用したアルゴリズムを用いて、車両抽出・追跡を同時に行っている。事象検出部は、車両追跡の結果から車両の挙動把握を行い、車両挙動を特徴量として異常交通事象と通常との識別を行う。最後に、映像保存部において、異常交通事象の詳細な事後要因解析を行うために、事象の前後の映像の記録を行う。

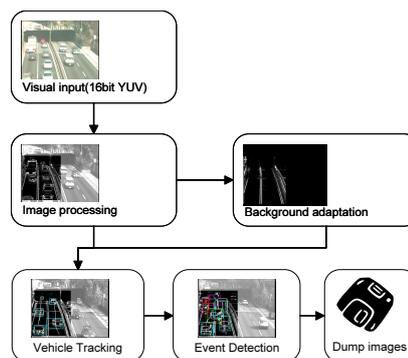


図1 システムの処理の流れ

3. Semantic Hierarchy によるシーン理解

3.1. 基本アイデア

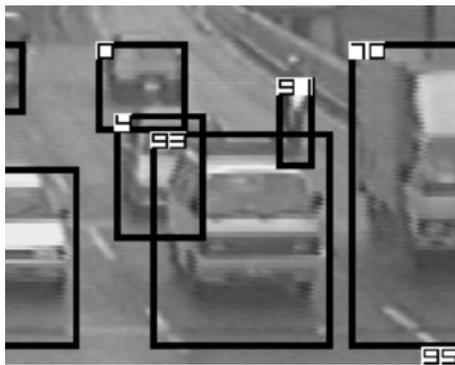
開発したシステムの事象検出は、3つの階層の記述子(座標クラス記述子、挙動クラス記述子、事象クラス記述子)で構築された、Semantic Hierarchy によって行われる。この Semantic Hierarchy は、人間のシーン理解を模倣している。まず座標クラス記述子は、人間の視覚を模倣している。これらは、各車両の座標情報を各フレームごとに算出する。座標情報は、トラッキング結果であるオブジェクトマップと動きベクトルマップを整理・結合することで獲得される。次に、挙動クラス記述子と事象クラス記述子は、人間のシーン理解を模倣する。挙動クラス記述子は、個々の車両の挙動を抽出する。挙動の抽出は、座標クラス記述子から獲得された時空間車両軌跡を解析することで分類される。こうして抽出された個々の車両の挙動を組み合わせ、事象クラス記述子によってどのような事象がシーンに発生しているのかを抽出する。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。

3.2. 時空間 MRF モデルを適用したトラッキング

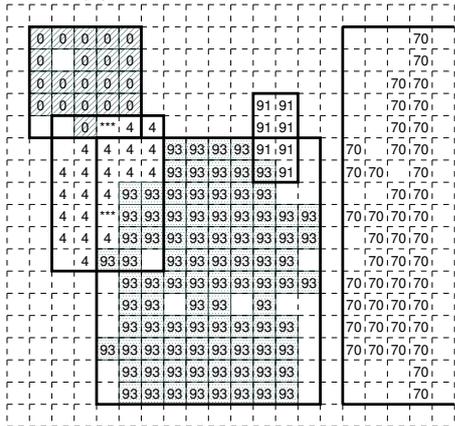
我々は、時空間画像を領域分割しそれを最適化する時空間 MRF モデルを開発した [1][2][3][4]。最適化は、各フレーム間でテクスチャを比較した結果と、ブロックごとの動き

*東京大学生産技術研究所

ベクトルを組み合わせて行われる．そして確率緩和過程が適用された時空間 MRF モデルは，オブジェクト同士が重なり合う場合においても，オブジェクトの境界を正確に決定する．



(a) Tracking Result Image



(b) Object-Map

図 2 トラッキング結果

図 2 は，トラッキング結果の例である．これは，高速道路の合流部という低画角の画像に対して時空間 MRF モデルを適用したものである．図 2 では，外接矩形が車両ごとに重なり合う部分がみられる．しかし，図 2(b) を参照すれば，可視化されたときに生じる外接矩形の重なりも，各車両ごとの領域として正しく分割されていることが確認できる．

4. 車両間の相互挙動に注目したルールベース手法

本章では，車両間の相互挙動に注目した事象検出について述べる．本論文では，この車両間の相互挙動に注目したルールベース手法による事象検出をアルゴリズム 1 とする．

4.1. 座標クラス記述子

トラッキング結果 (オブジェクトマップと動きベクトルマップ) から，各車両の座標情報を抽出するために以下の座標クラス記述子を定義した．

- $getCoordinates(V.i)$: 車両 $V.i$ の座標を返す．座標情報には，外接矩形の各頂点と車両の中心点の座標が含まれる．

- $getRegion(V.i)$: 車両 $V.i$ が，どの領域に含まれるかを返す．領域とは，入力画像に対して車線などの構造を元に独自に分割・設定したものである．

4.2. 時空間軌跡の解析

挙動クラス記述子を定義するために，座標クラス記述子によって獲得した車両の移動軌跡のクラスタリングを行う．図 3 は，その一例である．車両軌跡の分類を行う挙動クラス記述子である $typeOfTrajectory$ は，クラスタリングされた軌跡との比較を行う．

軌跡のクラスタリングは以下の手順で行われる．まず空間軌跡 R を， n 個の点で離散化し，各点を $r_m (1 \leq m \leq n)$ とする．その結果， $R = \{r_1, \dots, r_n\}$ となり，軌跡は車両が表れてから消えるまでの時系列に並んだ点によって表される．本論文の実験では，画角，計測範囲等を考慮し，分割数 n を 8 とした．各点 r_m は座標値として (x,y) の 2 つの値を保持しているため，1 台の車両の軌跡は $2n$ 次元空間の 1 点として投影される．従って，2 つの軌跡が似ているほど $2n$ 次元空間上で近い点となる．この $2n$ 次元空間でクラスタリングを行うことによって，画像平面中の車線中心を求める．本研究では，クラスタリング手法に k -mean 法を用いた．そして，最小の分散を得る k_{min} をいくつかの k を試すことで求めた． k_{min} は，車線数と等しくなるため，本研究では $k_{min} = 2$ を得た．クラスタリングの結果を $C = \{c^k\} (1 \leq k \leq k_{min})$ でラベル付けすると，クラスタ c^k の中心は $L^k = \{l_m^k (1 \leq m \leq n, 1 \leq k \leq k_{min})\}$ という軌跡になる．このクラスタリングの結果獲得された軌跡は， k 番目の車線を表す．このようにして獲得した軌跡の空間成分は，挙動クラス記述子である $typeOfSpTrajectory$ に用いられる．

また，クラスタリングされた軌跡の空間成分だけでなく時間成分も挙動クラス記述子に用いる．ある車両の移動軌跡 $R = \{r_1, \dots, r_n\}$ に対して，隣接する 2 点間 r_m と r_{m+1} の旅行時間を各車両ごとに求める．これをある一定時間に通過するすべての車両に対して行い， l_m^k と l_{m+1}^k の 2 点間の平均旅行時間を算出する．この平均旅行時間と実際の車両の旅行時間の比較が，挙動クラス記述子である $typeOfTpTrajectory$ で行われる．

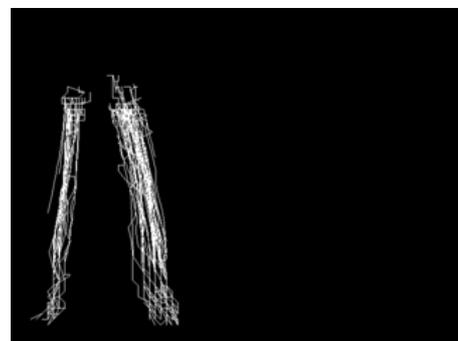


図 3 車両の累積軌跡

4.3. 挙動クラス記述子

座標クラス記述子で獲得した座標情報を用いることで，各車両の挙動を表す挙動クラス記述子を以下のように定義する．

- $typeOfSpTrajectory(V_i, V_j, t)$: 車両 V_i が車両 V_j に対して車線変更を行った場合 '車線変更' を、それ以外の場合に '直進' を返す。本研究では、車線情報として図 4 に示すように車線と直交する正規分布を仮定している。正規分布の数は車線数と同じである。車線変更判定はこのモデルに基づいて行われる。
- $typeOfSpTrajectory(V_i, L_m^k, t)$: 車両 V_i が地点 L_m^k に対して車線変更を行った場合 '車線変更' を、それ以外の場合に '直進' を返す。 L_m^k は、 k 番目の車線の m 個目の離散的な点を表す。
- $typeOfTpTrajectory(V_i, t)$: 車両 V_i が停止している場合は 'True' を、そうでない場合は 'False' を返す。この判定は、クラスタリングされた軌跡の区間ごとの平均旅行時間との比較により行われる。
- $isSpace(V_i, t)$: 車両 V_i の走行車線上の前方に他の車両の存在しない空間がある場合は 'True' を、そうでない場合は 'False' を返す。
- $isBlockaded(L.k, t)$: 車線 $L.k$ 上の交通流が塞ぎ止められている場合は 'True' を、そうでない場合は 'False' を返す。ただし、車線 $L.k$ 上に車両が存在しない場合は、'False' を返す。

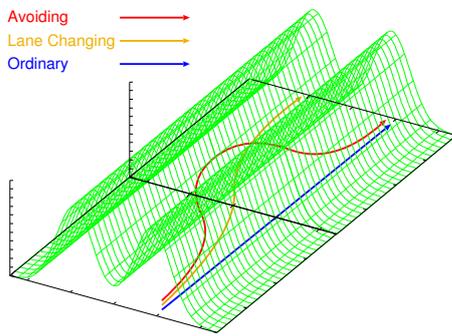


図 4 車両軌跡のモデル

$typeOfSpTrajectory$ は、以下の処理で判定が行われる。車両軌跡 $R = \{r_1, \dots, r_n\}$ を、複数の離散化された点から構成されるいくつかの部分軌跡 $\{r_m, r_{m+1}, r_{m+p-1}\}$ に分割する。そしてこの部分軌跡と、それに対応するクラスタリングされた軌跡の部分軌跡 $\{l_m^k, l_{m+1}^k, \dots, l_{m+p-1}^k\}$ との比較を行う。すべてのクラスタリングされた軌跡の部分軌跡とのユークリッド距離を求め、最も距離の小さい部分軌跡 $l_m^{k_{max}}, l_{m+1}^{k_{max}}, \dots, l_{m+p-1}^{k_{max}}$ を決定する。ただし、どのクラスタリングされた軌跡からも車両軌跡が離れている場合は、 k_{max} は一意に定まらない。距離の比較を、すべての区間 m に対して行うことで、移動軌跡はクラスタリングされた軌跡によってラベル付けが行われる。このラベルから車両軌跡の分類を行う。例えば 1 つの車両についてその軌跡に着目したとき、すべての部分軌跡のラベルが l^1 であった場合、この車両は車線 1 を直進したと判断する。また最初の区間で属する車線を l^1 とラベルづけされ、次に車線 1, 2 のどちらに属するか判定できない区間を経て、最後の区間で l^2 とラベルづけされた場合は、車線 1 から車線 2 へ車線変更したと判断する。

$typeOfTpTrajectory$ は、以下の処理で判定が行われる。車両軌跡のある 2 点間 (r_m から r_{m+1}) の旅行時間と、そ

れに対応するクラスタリングされた軌跡の 2 点間 (l_m^k から l_{m+1}^k) の旅行時間の比較を行う。ただし k は、あらかじめ $typeOfSpTrajectory$ の判定結果から求める。この比較の結果、車両軌跡の旅行時間がクラスタリングされた軌跡に対して、例えば 3 倍以上であった場合 '停止' していると分類する。

4.4. 事象クラス記述子

事象クラス記述子は、交通事故や緊急停止車両、工事といった交通事象を記述する。本論文では、交通事故を表す記述子を 3 つあげる。ただし、交通事故とその他の異常交通事象の区別は困難であるため、交通事故を表す記述子が他の異常交通事象を含むことがある場合がある。

1 つ目の事象クラス記述子は、停止挙動と前方空間に注目したものである。これは式 (1) のように表される。式 (1) は、事故後に車両が停止し、停止した車両の前方に空間が発生した状態を表している。

2 つ目の事象クラス記述子は、車両間相互について停止挙動と避走挙動に注目したものである。これは式 (2) のように表される。式 (2) は、事故後に車両が停止、後続車両が車線変更をし事故車両を避走している状態を表している。式 (2) では、車線変更車両の台数を数え、3 台を越えた場合は、それを単なる車線変更ではなく避走挙動として判定している。

3 つ目の事象クラス記述子は、車両と地点の相互関係に注目したものである。これは式 (??) で表される。この記述子は、事故発生後に事故車両が存在しない、あるいは停止と判定されていない状態を表す。停止車両が存在しない場合であっても、一定時間に同じ地点で車線変更があれば事故が発生したものとす。

5. 連続値化した識別面による手法

5.1. 基本アイデア

アルゴリズム 1 では論理積 (\wedge) が事象クラス記述子で用いられているため、全ての挙動クラス記述子が 'True' にならないと異常交通事象を検出することができない。実際に、いくつかの異常交通事象の中には、挙動クラス記述子が 'True' になる条件を満たさない場合が存在する。また個々の挙動クラス記述子においても、すべての異常交通事象に対して、'True' を返す閾値を定めることは困難である。例えば、アルゴリズム 1 の式 (2) では、車線変更車両の台数に対して 3 台という閾値を設定してある。しかし、この値が全ての異常交通事象に対して最適値にはならない。この問題は、ルールベース手法の決定木を細分化することで一応の解決が可能である。しかし、この手法はルール数が膨大な数になり、ルールを用意するコストを考えると現実的ではない。

また、車両挙動の時間距離も考慮する必要がある。短時間の間に特定の挙動が判定された場合と、そうでない場合ではそれを区別する必要がある。例えば、同じ位置での連続した車線変更は異常交通事象の可能性があるが、同じ位置であっても車線変更の間隔が長ければ、それは異常交通事象によるものである可能性は低いといえる。こうした時間距離を考慮するためには、車線変更の挙動クラス記述子が連続値の入力と出力を扱えるように拡張する必要がある。

$$b \equiv \exists(\text{typeOfTpTrajectory}(V,j,t) \wedge \text{isSpace}(V,j,t)) \quad (1)$$

$$b \equiv \text{typeOfTpTrajectory}(V,j,T) \wedge (3 \leq \sum_i \sum_t \{\text{LaneChanging} = \text{typeOfSpTrajectory}(V,i,V,j,t)\}) \quad (2)$$

$$b \equiv 4 \leq \sum_i \sum_t \{\text{LaneChanging} = \text{typeOfSpTrajectory}(V,i,L_m^k,t)\} \quad (3)$$

したがって、アルゴリズム 1 を改善するために、事象クラス記述子が連続値の入力と出力を扱えるように拡張する。また、事象クラス記述子で用いられる挙動クラス記述子も、同時に連続値化する。このようにして連続値化した識別面が構築できれば、異常交通事象と通常事象の識別は容易である。本論文では、この連続値化した識別面による手法を、アルゴリズム 2 とする。

5.2. 挙動クラス記述子

連続値化した事象クラス記述子を構築するために、挙動クラス記述子の出力も連続値化する。連続値を返す挙動クラス記述子は、以下のように再定義される。

- $\text{cntStop}(V,i)$: ある 2 地点間の平均旅行時間に対しての、車両 V,i の旅行時間の係数を返す。係数は旅行時間に対する次の式で求める。 $\frac{r_{m+1}-r_m}{l_{m+1}^k-l_m^k}$.
- $\text{cntSpace}(V,i)$: 車両 V,i の前方に発生した時空間面積を返す。この面積は次の式で求める。 $\int \text{space}(V,i,t)dt$.
- $\text{cntLaneChange}(V,i)$: 車両 V,i に対する車線変更の異常交通事象への尤度を返す。この尤度は、次の式で求める。 $\sum_{j=1}^n \alpha(V,i,V,j)\beta(V,i,V,j)$ 。ただし、 n は車線変更した総台数であり、 α は V,i と V,j の空間的距離、 β は時間的距離を求める関数である。

5.3. 事象クラス記述子

本章で再定義した挙動クラス記述子を用いて、事象クラス記述子は次のように定義される。

$$ax + by + cz + d = 0 \quad (4)$$

ただし x, y, z は、それぞれ $\text{cntStop}(V,i)$ 、 $\text{cntSpace}(V,i)$ 、 $\text{cntLaneChange}(V,i)$ が返す値である。式 (4) で定義したように、本論文では異常交通事象と通常事象の識別面は超平面になると仮定した。この超平面は、 a, b, c, d という 4 つの変数と、 $\alpha()$ と $\beta()$ の内部関数を最適化することで決定される。図 5 は、最適化された超平面である。ここで、最適化に際して投影された各点と平面との距離の二乗和の総和を評価関数として用い、学習データを用いてこの評価関数を最大化する平面を求めた。最適化された識別面の内側の空間に位置する事象を通常事象、外側に位置する事象を異常交通事象として分類し、異常交通事象の検出を行う。

6. 評価実験

アルゴリズム 1,2,3 の有効性の評価を行った。図 6,7 は、それぞれアルゴリズム 1,2 の事故検出成功例である。

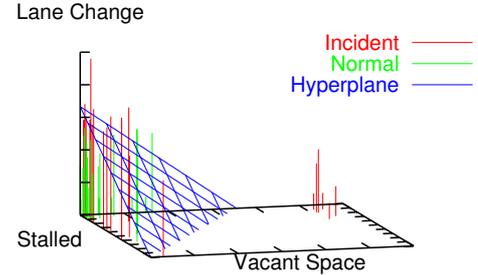


図 5 最適化された超平面

アルゴリズム 1 はすべての挙動クラス記述子の状態が 'True' にならなければ事象検出の判定を行わない。しかし、幾つかの事故はこの条件を満たさない。したがって図 7 のように、停止車両は存在するが停止車両の前方空間は閾値にはならず、また後続車両の車線変更も発生していない状態を、アルゴリズム 1 は事故として検出することができない。しかしアルゴリズム 3 では、識別面による事象判定を行うことで、特定の挙動 (図 7 の場合は停止時間) が突出している場合は、その挙動で他の挙動を補完し、図 7 のような事故でも検出が可能である。

アルゴリズム 1 は、車両間の相互挙動は考慮しているが、挙動の時間距離までは考慮していない。したがって、時間距離が離れており挙動同士に関連性が低いと考えられる場合でも、挙動を累積して判定してしまい、誤検出する場合がある。図 8 は、アルゴリズム 2 による誤検出である。図 8 では、同じ地点において時間距離が離れて車線変更が発生しているが、一定時間内に規定回数以上の車線変更が発生したため通常事象を異常交通事象として誤検出した。しかし、アルゴリズム 3 では、車両間の相互挙動に加え時間距離も考慮されているため誤検出はされない。

表 1 は、アルゴリズム 1,2,3 を実際の交通映像に対して適用し、その検出成功数をまとめたものである。実験に用いた映像は 1ヶ所で 24 時間 × 18ヶ月録画されたものであり、全てを目視チェックした結果得られた事故 59 件の映像を実験データとして用いた。偶数月の事故 25 件はアルゴリズム改良のための学習データとしてアルゴリズム 1 からアルゴリズム 1 への論理改良、アルゴリズム 2 におけるパラメータ学習に用いた。また奇数月の事故 34 件はアルゴリズム性能評価用のデータとして用いた。図 9 は、事故発生から検出までに要した時間をヒストグラムにしたものである。本実験では、事故発生から 200 秒以上経過してから検出したものは検出ミス扱いとした。ただし、本実験で用いた交通映像は膨大な交通量であり、長時間にわたる渋滞も多く含む、したがって、事故発生後 2,3 秒で事故検出することは非常に困難である。また実験に用いたデータ 59 件のうち、雨天時のものが 6 件あったが、雨天時のデータで

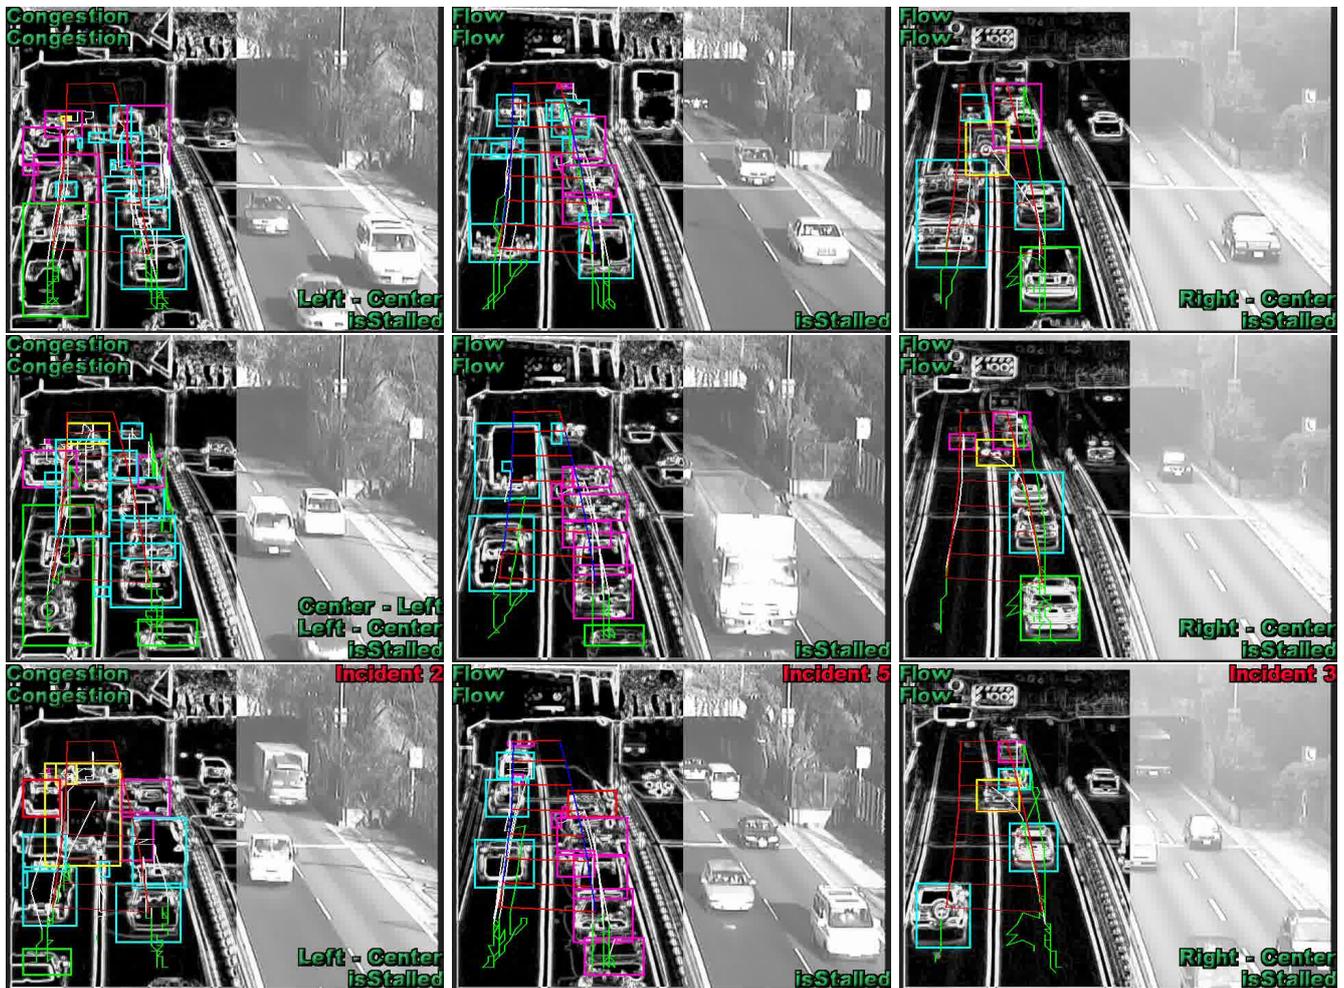


図 6 アルゴリズム 1 による検出例

図 7 アルゴリズム 2 による検出例

図 8 アルゴリズム 1 による誤検出例

検出ミスは生じなかった．さらに 7 件は夜の時間帯のものであったが，そのうち検出ミスは 1 件のみであった．本システムでは照度変化に頑健なフィルタリング処理を行っているので，これらの条件の違いによる影響はほとんどみられなかった．

7. おわりに

本論文では，時空間 MRF モデルによるトラッキングと統計解析を利用したルールベース手法とを組み合わせ，リアルタイム異常交通事象検出システムについて述べた．このシステムは，90% 以上の高い再現率で事故の検出を行う．今後は分合流や交差点といったより複雑な形状の道路において実験を行うとともに，さらに高い再現率と適合率の達成を目指す．

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 Trans. Information and Systems, Vol.E85-D No.11, pp1753-1764, November 2002.

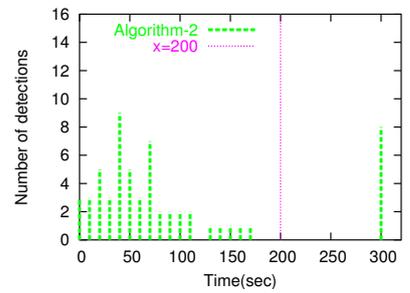
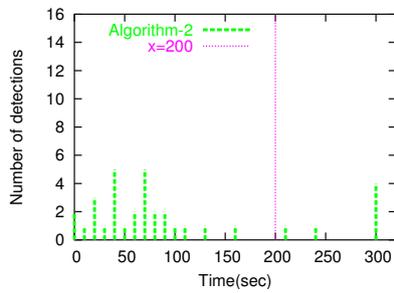
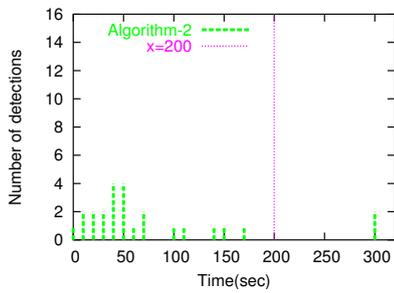
[2] S.Kamijo, Y.Matsushita, K.Ikeuchi, M.Sakauchi, "Occlusion Robust Tracking utilizing Spatio-Temporal Markov Random Field Model", IEEE ICPR, Vol.1 pp142-147, 2000.

[3] 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.

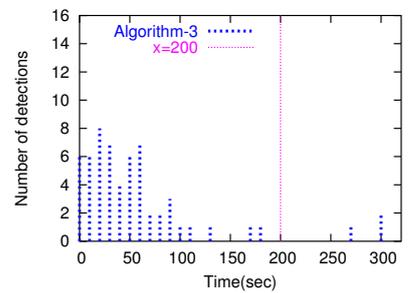
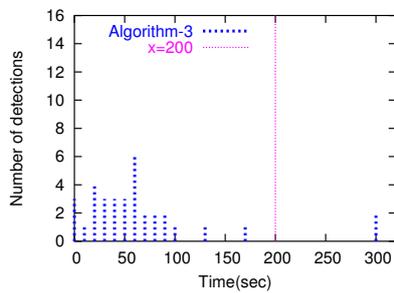
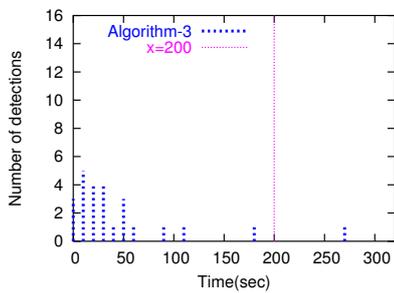
[4] S.Kamijo, Y.Matsushita, K.Ikeuchi, M.Sakauchi, "Traffic Monitoring and Accident Detection at Intersections", IEEE Trans. ITS, Vol.1 No.2, pp.108-118, June 2000.

表 1 検出成功数一覧

	Even -numbered Months		Odd-numbered Months		Total	
	Positive	Negative	Positive	Negative	Positive	Negative
Algorithm-1	23	2	30	4	53	6
Algorithm-2	24	1	32	2	56	3



Algorithm-1



Algorithm-2

Even-numbered Months

Odd-numbered Months

Total

図 9 検出時間