九州大学学術情報リポジトリ
Kyushu University Institutional Repository

Parzen推定を用いた動的背景モデル構築の高速化手法

田中, 達也
九州大学システム情報科学研究院知能システム学部門

島田, 敬士
九州大学システム情報科学研究院知能システム学部門

有田, 大作
九州大学システム情報科学研究院知能システム学部門

谷口, 倫一郎
九州大学システム情報科学研究院知能システム学部門

https://hdl.handle.net/2324/5954

出版情報：火の国情報シンポジウム, 2007-03
バージョン：
権利関係：

Parzen推定を用いた動的背景モデル構築の高速化手法

田中 達也† 島田 敬士‡ 有田 大作* 谷口 倫一郎**
九州大学工学部電気情報工学科†
九州大学大学院システム情報科学府‡
九州大学大学院システム情報科学研究院**
〒819–0395 福岡県福岡市西区元岡 744
財団法人九州システム情報技術研究所*
〒814–0001 福岡県福岡市早良区百道浜 2 丁目 1–22
E-mail: {tatsuya,atsushi,rin}@limu.is.kyushu-u.ac.jp, arita@isit.or.jp

あらまし 本稿では，確率密度関数をノンパラメトリックに推定する方法のひとつである Parzen 推定を利用した高速な動的背景モデル構築アルゴリズムについて述べる．動的背景モデル構築では画素単位で画素値の変化を確率密度関数で近似する方法が一般的であり，その近似を毎フレーム高速かつ精度良く行うことが重要である．提案手法では，新たに観測された画素値を基準にその周辺の確率密度関数のみを局所的に更新することで，背景モデルを更新するために必要な処理時間を大幅に短縮している．実験では，混合ガウス分布を利用したセミパラメトリックな手法に比べ，高速かつ高精度に背景モデルの更新および対象物体の抽出を行えることが確認できた．

キーワード 背景差分，物体抽出，動的背景モデル，背景変動，照明変化，Parzen 推定

A Fast Algorithm for Adaptive Background Models Using Parzen Density Estimation

Tatsuya Tanaka†, Atsushi Shimada‡, Daisaku Arita*, Rin-ichiro Taniguchi**
Department of Electrical Engineering and Computer Science, Kyushu University†
Department of Intelligent Systems, Kyushu University‡**
744, Motooka, Nishi-ku, Fukuoka, 819–0395, Japan
Institute of Systems & Information Technologies/KYUSHU*
2–1–22, Momochihama, Sawara-ku, Fukuoka, 814–0001, Japan
E-mail: {tatsuya,atsushi,rin}@limu.is.kyushu-u.ac.jp, arita@isit.or.jp

Abstract We propose a fast algorithm to estimate background models using Parzen density estimation in non-stationary scenes. Each pixel has a probability density which approximates pixel values observed in a video sequence. It is important to estimate a probability density function fast and accurately . In our approach, the probability density function is partially updated within the range of the window function based on the observed pixel value. The model adapts quickly to changes in the scene and foreground objects can be robustly detected. Several experiments show the effectiveness of our approach.

Key words Background Subtraction, Object detection, Non-stationary background, Illumination change, Parzen density estimation

1. はじめに

観測画像中から背景以外の物体を検出する手法は，数多くの視覚システムの最も基盤となる技術の一つである．例えばカメラを用いた監視システムでは，固定したカメラで撮影した動画像から移動物体を検出することが要求される．背景差分法は，あらかじめ用意した背景画像と観測画像との差分を計算することにより，物体に関する事前知識を必要とせずに物体領域を簡単に抽出することができるため，よく利用される物体検出法である．しかし，屋外などを観察する場合には，単純に背景画像を用意しただけでは，木々や水面の揺らぎなどの微小な変化や，天候による照明条件の変化による影響を受けるために，対象物体以外に様々なノイズが前景として抽出されてしまう．そこで，このような背景の変化に対応するため，動的な背景モデルとして，確率モデルを利用した動的背景モデル構築手法が提案されている [1–6].

確率モデルを用いた背景モデルの構築手法は，パラメトリックな手法，ノンパラメトリックな手法，そしてそれらの中間的な手法であるセミパラメトリックな手法の 3 種類に分類することができる．パラメトリックな手法について，古山らは単一のガウス分布を用いて背景モデルを構築している [1]．照明条件が滑らかに変化する場合，単一のガウス分布を用いて背景モデルを作成することが可能であるが，照明条件が一時的に変化する場合や，急激に変化する場合などには，背景モデルの更新が間に合わず，背景の変化に対応することができない．このように，パラメトリックな手法は，確率密度の計算が比較的簡単であるが，真の分布と仮定したモデルが異なる場合には必ずしも良い推定結果が得られるとは限らない．そこで，混合ガウス分布を用いてセミパラメトリックに背景モデルを推定する手法 [2–4] や，Parzen 推定を用いてノンパラメトリックに背景モデルを推定する手法が提案されている [5].

セミパラメトリックな手法について，Stauffer らは各画素のガウス分布の数を固定して混合ガウス分布のパラメータを高速に推定する方法を提案している [2]．この方法は，すべての画素で同数のガウス分布を用いて背景モデルを構築しているため，照明条件の変化が小さい画素などでは，分布数が多すぎたり，また急激な照明変化に対しては，あらかじめ設定された分布数では不足するという分布数設定の問題が生じる．そこで Cheng らは，画素ごとにガウス分布の数を変動させることで，照明変化の大きい画素には適合的に分布の数を増やしている [3]．その結果，メモリの消費を抑えつつ背景の変化に柔軟に対応している．しかし，背景モデルの更新に EM アルゴリズムを用いているため，多くの計算が必要で実時間性という点に問題がある．一方，島田らは画素ごとにガウス分布の数を変動させつつ，高速に混合ガウス分布を推定する方法を提案している [4]．これらのセミパラメトリックな手法では，確率密度関数を複数のガウス分布を用いて近似するため，パラメトリックな手法に比べ，確率密度関数を精度良く推定することができる．しかし，用いるガウス分布の数が増えるにつれ，処理時間が増加するため，現実的に近似に用いることのできる分布数には限界がある．そのため状況によっては精度良く近似を行えない場合がある．

ノンパラメトリックな手法について，Elgammal らは Parzen 推定を用いて背景モデルを推定する手法を提案している [5]．ノンパラメトリックな手法では，パラメトリックな形式を仮定せずに確率密度関数を推定することができるため，真の分布がどんな関数系であっても精度良く背景モデルの推定を行うことができる．しかし，精度良く推定を行うためには十分なデータ数が必要であり，Elgammal らによって提案されている手法では確率密度関数の推定に多くの計算が必要なうえ，その計算量はデータ数に比例するため，実時間処理には向いていない．

そこで我々は，Parzen 推定を利用した高速な動的背景モデル構築アルゴリズムを提案する．提案手法では，新たに観測された画素値を基準にその周辺の確率密度関数のみを局所的に更新する手続きをとることで，背景モデルを更新するために必要な処理時間を大幅に短縮することができる．以下では，2 章で Elgammal らが提案している Parzen 推定を用いた従来の背景モデル推定法を紹介する．3 章では，我々が提案する高速な背景モデル推定法について述べる．提案手法

を用いた実験結果については 4 章で報告する．

2. Parzen 推定による背景モデル推定

この章では，まず 2.1 節で背景モデルの構築に用いる Parzen 推定について述べ，2.2 節で Elgammal らが提案している Parzen 推定を用いた動的背景モデルの構築法について述べる．

2.1 Parzen 推定

Parzen 推定では，過去に得られた画素値を基に，観測された画素値の確率密度関数をノンパラメトリックに推定する．画素 (x, y) における画素値を d 次元ベクトル $\boldsymbol{X}$ で表すことにすると，過去に観測された N 個の画素値 $\{\boldsymbol{X}_1, \cdots, \boldsymbol{X}_N\}$ の確率密度関数 $P(\boldsymbol{X})$ は Parzen 推定を用いて，

$$P(\boldsymbol{X}) = \frac{1}{N}\sum_{i=1}^{N} K(\boldsymbol{X} - \boldsymbol{X}_i) \tag{1}$$

と推定する．ここで，K は窓関数と呼ばれ，その積分値は 1 であり，適切な広がりを持っている関数である．滑らかな確率密度関数を推定するため，一般的にガウス分布が窓関数としてよく用いられている．以下では，K を $N(\boldsymbol{0}, \Sigma)$ で表されるガウス分布とする．その次元数を d とすると，式 (1) は，

$$P(\boldsymbol{X}) = \frac{1}{N}\sum_{i=1}^{N} \frac{1}{(2\pi)^{\frac{d}{2}}|\boldsymbol{\Sigma}|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(\boldsymbol{X} - \boldsymbol{X}_i)^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{X} - \boldsymbol{X}_i)\right) \tag{2}$$

となり，この式により確率密度関数の推定を行う．

2.2 背景モデル構築アルゴリズム

画素ごとに背景モデルを構築するため，以下では特に断りがない限りひとつの画素 (x, y) に焦点を絞って考える．まず，式 (2) において，共分散行列を次式で近似する．

$$\boldsymbol{\Sigma} = \begin{pmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sigma_d^2 \end{pmatrix} \tag{3}$$

この式は，例えば$\boldsymbol{X}$が RGB 値で構成される場合，各色成分は独立であることを意味する．共分散成分を無視することになり精密さには欠けるが，逆行列などの複雑な計算を回避できるため，計算量を削減することできる．以上により，画素値$\boldsymbol{X}$が生起する確率は式 (4) を用いて推定することができる．

$$P(\boldsymbol{X}) = \frac{1}{N}\sum_{i=1}^{N}\prod_{j=1}^{d} \frac{1}{(2\pi\sigma_j^2)^{\frac{1}{2}}} \exp\left(-\frac{1}{2}\frac{(X - X_i)_j^2}{\sigma_j^2}\right) \tag{4}$$

具体的な背景モデル構築の手順は以下の通りである．

Step1 新たに画素値 $\boldsymbol{X}_{N+1}$ が観測されたとき，式 (4) を用いて $\boldsymbol{X}_{N+1}$ が生起する確率 $P(\boldsymbol{X}_{N+1})$ を求める．

Step2 Step1 で求めた $P(\boldsymbol{X}_{N+1})$ が閾値以上であれば背景，閾値以下であれば前景と判定する．

Step3 観測画素値 $\boldsymbol{X}_{N+1}$ を保存し，最も古い画素値データ $\boldsymbol{X}_1$ を削除する．

以上の処理を画素ごとに繰り返し行うことで，背景モデルの構築を行う．

3. 確率密度関数推定の高速化

2.2 節で述べた式 (4) を用いて画素値 $\boldsymbol{X}$ が生起する確率を毎フレーム求める場合，背景モデルの推定には多くの計算が必要である．Elgammal らは，全ての場合の $(\boldsymbol{X} - \boldsymbol{X}_i)$ について，窓関数 K の値をあらかじめ計算しておき，ルックアップテーブルを用いることで，処理時間を削減している．しかし，窓関数 K により求まる値を N 回足し合わせる計算をしなければならず，背景モデルを推定するのに時間がかかる．そこで，我々が提案する手法では，以下に示す方法でより高速に確率密度関数の推定を行う．

まず，提案手法では式 (5) に示す窓関数を用いる．ただし，h は窓関数の大きさを表すパラメータである (図 1 参照)．

$$K(u) = \begin{cases} \frac{1}{h^d} & \text{if } -\frac{h}{2} \leq u \leq \frac{h}{2} \\ 0 & \text{otherwise} \end{cases} \tag{5}$$

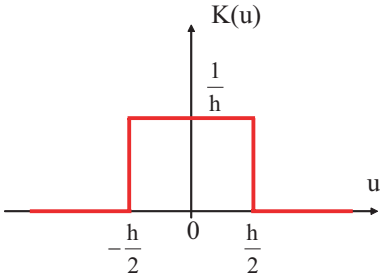

図 1: 提案手法で用いる窓関数

式 (5) を利用して，式 (1) は以下のように変形できる．

$$P(\boldsymbol{X}) = \frac{1}{Nh^d}\sum_{i=1}^{N}\psi(\frac{|\boldsymbol{X}-\boldsymbol{X}_i|}{h}) = \frac{k(\boldsymbol{X})}{Nh^d} \quad (6)$$

ここで，$k(\boldsymbol{X})$ は $\boldsymbol{X}$ を中心とする一辺 h の超立方体 R 内にある $\boldsymbol{X}_i$ の個数であり，

$$k(\boldsymbol{X}) = \sum_{i=1}^{N}\psi(\frac{|\boldsymbol{X}-\boldsymbol{X}_i|}{h}) \quad (7)$$

となる．$|\boldsymbol{X}-\boldsymbol{X}_i|$ は d 次元のチェスボード距離であり，$\psi(u)$ は次式により得られる．

$$\psi(u) = \begin{cases} 1 & \text{if } -\frac{1}{2} \le u \le \frac{1}{2} \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

$\psi(u)$ は $\boldsymbol{X}$ を中心とする一辺 h の d 次元超立方体 R 内にある $\boldsymbol{X}_i$ の個数を数えるための関数であり，過去の観測画素値 $\boldsymbol{X}_i$ が $\boldsymbol{X}$ を中心とする窓関数内にある場合のみ 1 となりそれ以外の場合には 0 となる．

以上のことを整理すると，式 (6) を用いて確率密度関数の推定を行う場合，$P(\boldsymbol{X})$ の値は過去に観測された N 個の画素値のうち，$\boldsymbol{X}$ を中心とする窓関数内にいくつ存在するかを考慮すればよい．言い換えると，新たな画素値 $\boldsymbol{X}$ が観測されたときに確率密度関数の更新が必要となるのは，観測画素値を中心とする窓関数内と，最も古い画素値を中心とする窓関数内だけである．確率密度関数の推定に用いるデータ数は N 個なので，新たな画素値が観測された場合，最も古い画素値のデータを削除する必要がある．そのため，最も古い画素値を中心とする窓関数内も確率密度関数を更新する必要がある．提案手法では，このことを利用し，全ての画素値 $\boldsymbol{X}$ において確率密度関数を推定し直すのではなく，局所的に背景モデルの更新を行う．

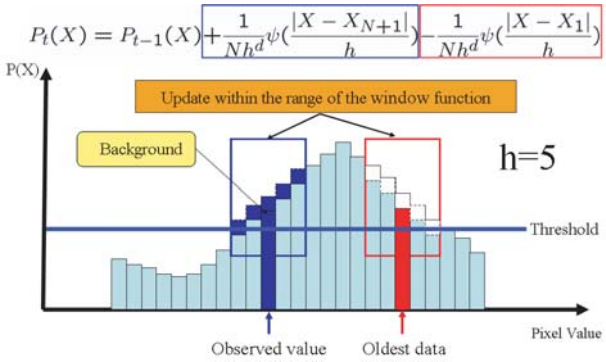

図 2: 背景モデル更新アルゴリズム

まず，画素値は離散値であるのですべての $\boldsymbol{X}$ における確率密度関数の値 $P(\boldsymbol{X})$ はあらかじめ計算し，保持しておくことが可能である．ここで，新たな観測画素値 $\boldsymbol{X}_{N+1}$ が得られた時，$P(\boldsymbol{X})$ は以下のようにして更新することができる．

$$P_t(\boldsymbol{X}) = P_{t-1}(\boldsymbol{X}) + \frac{1}{Nh^d}\psi(\frac{|\boldsymbol{X}-\boldsymbol{X}_{N+1}|}{h}) - \frac{1}{Nh^d}\psi(\frac{|\boldsymbol{X}-\boldsymbol{X}_1|}{h}) \quad (9)$$

これは，新たな観測画素値 $\boldsymbol{X}_{N+1}$ を中心とする窓関数の範囲内の確率を $\frac{1}{Nh^d}$ だけ高くし，$N+1$ フレーム前の観測値 $\boldsymbol{X}_1$ を中心とする窓関数の範囲内の確率を $\frac{1}{Nh^d}$ だけ低くする操作である．これにより，新たな画素値が観測されるたびに局所的に $P(\boldsymbol{X})$ を更新するだけでよく，処理時間の大幅な短縮が可能である．図 2 は背景モデル更新の様子を図で表したものである．

4. 実験

実験には PETS2001 のデータセット [7] を解像度 320×240 にリサイズしたものを用いた．映像には通りを行き交う人々や車の移動，木々の揺らめきなどが含まれている．この映像に対し，提案手法，分布数固定型および分布数可変型の混合ガウス分布による手法，Elgammal らが提案している手法を用いて実験を行い，その結果を比較

(a) 入力画像　(b) h=1　(c) h=5　(d) h=11　(e) h=25

図 4: 窓関数の大きさと背景差分の精度の関係

した．ここで，提案手法では各色成分は独立であると仮定し，R, G, B それぞれの軸で 1 次元の確率密度関数を推定する．なお，実験に用いた計算機は，Pentium4 3.2GHz の CPU および 2.5GB のメモリを搭載している．

4.1　窓関数の大きさに関する実験

Parzen 推定において窓関数は重要な役割を持っており，窓関数の大きさによって，推定する確率密度関数の分布の滑らかさを調整することができる．推定される分布の滑らかさが大きすぎる場合は，過度の平滑化が起こり良い推定結果が得られなくなる．一方，滑らかさが十分で無い場合には，確率密度関数が個々の画素値データに強く依存するようになり，観測頻度が低い画素値周辺では，データ過少によるノイズが発生してしまう．従って，良い推定結果を得るためには，窓関数の大きさを適切な値に決めることが重要となる．そこで本節では，Parzen 推定に用いる窓関数の大きさについて検証を行った．

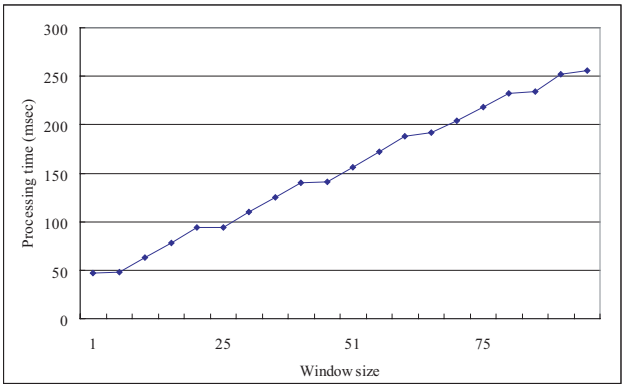

図 3: 窓関数の大きさと処理時間の関係

まず，図 3 に窓関数の大きさ h と処理時間の関係を示す．横軸は h，縦軸は処理時間である．図より，h の値が大きくなるにつれて処理時間が増加していることがわかる．提案手法では新たな画素値が観測されるたびに，窓関数内の確率密度関数を更新している．そのため，h の値が大きくなると確率密度関数の更新にかかる時間が増加し，それに伴って処理時間も増加している．実時間性を考慮すると，窓関数の大きさは 25 以下であることが望ましい．

図 4 は h の値をそれぞれ $1, 5, 11, 25$ にした場合の背景差分の結果を表す画像である．窓関数の大きさを 1 にした場合，物体領域以外のノイズも前景として抽出されている．これは窓関数を小さくしすぎたために，滑らかな確率密度関数の推定が行えなかったためであると考えられる．一方で，h を 25 にした場合は物体領域を正しく抽出できていない．これは窓関数を大きくしすぎたために，確率密度関数の過度の平滑化が起こったためと考えられる．以上のことから，処理時間と物体領域抽出の精度のバランスを考えると，窓関数の大きさは 5〜11 程度が妥当であると考えられる．

4.2　計算時間による評価

それぞれの手法を用いたときに 1 フレームを処理するのに必要な計算時間について検証を行った．ここで，提案手法において，$h = 5, N = 500$ としている．

図 5 に提案手法と，分布数固定型の混合ガウス分布による手法との比較について示す．横軸は，1 画素あたりのガウス分布の数であり，縦軸は映像を解析したときにかかった 1 フレームあたりの平均の処理時間である．混合ガウス分布を用いた手法では，画素ごとの分布数が増加するにつれて処理時間が増加する傾向があるが，提案手法では混合ガウス分布の画素ごとの分布数を 1

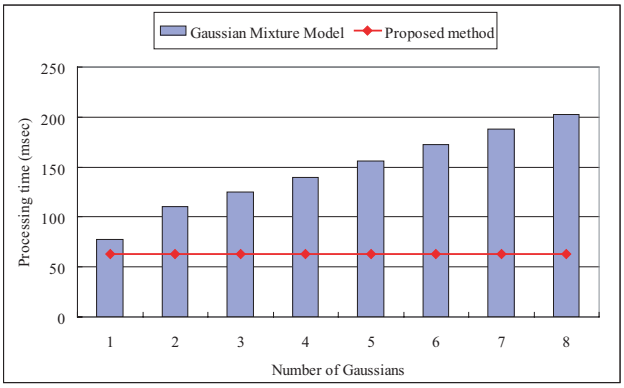

図 5: ガウス分布の数と処理時間の関係

に固定した場合よりも高速に処理ができていることがわかる．

次に，図 6 に提案手法と分布数可変型の混合ガウス分布による手法との比較について示す．横軸は処理したフレーム番号で，左の縦軸はそのフレームを処理するのにかかった時間，右の縦軸はそのフレームでの 1 画素あたりのガウス分布の平均の数を表している．同図中の 1000 フレーム辺りからガウス分布の数が増えている．このときの映像を見ると，映像に人や車などの物体が現れている時間帯であった．ガウス分布による手法では，これらの物体による映像の変化に対応するため，ガウス分布の数を増やして背景モデルを構築している．しかし，分布の数が増加するに従って処理時間も増加している．一方で提案手法では，どのフレームにおいても安定した速度で処理が行えていることがわかる．このことから，処理時間の安定性という面から見ても非常に優れた結果が得られていることがわかる．

最後に，図 7 に Elgammal らの手法との処理時間の比較について示す．Elgammal らの手法では，確率密度関数の推定に用いる画素値データの数が増加するにつれて処理時間も増加している．実時間性を考慮すると推定に用いることのできるデータ数は 150 個程度までということになる．一方で，提案手法ではデータ数にかかわらず，一定かつ短い処理時間で計算が行えていることがわかる．提案手法では，新たに観測された画素値および最も古い画素値を中心とする窓関数内の確率密度関数だけを更新しているので，一定の処理速度で計算を行うことができる．

4.3 再現率・適合率による評価

物体抽出に関する精度を比較するため，映像を解析したときの再現率と適合率について検証を行った．ここで，再現率，適合率は以下の式で定義される．

$$\text{再現率}\,(\%) = \frac{\text{正しく抽出した物体数}}{\text{抽出してほしい物体数}} \times 100 \tag{10}$$

$$\text{適合率}\,(\%) = \frac{\text{正しく抽出した物体数}}{\text{抽出した物体数}} \times 100 \tag{11}$$

なお，提案手法と Elgammal らの手法において，$N = 500$ とし，提案手法において $h = 5$ としている．

図 8 に映像を解析したときの再現率と適合率

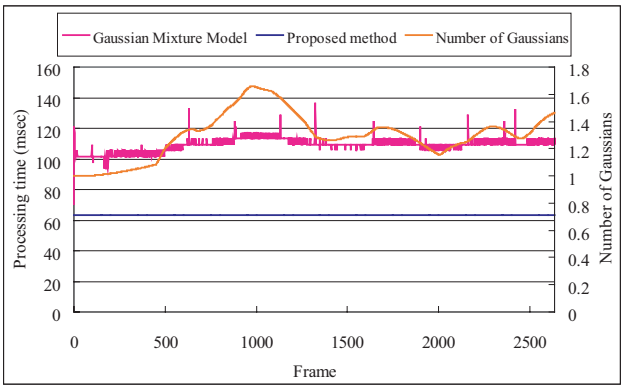

図 6: 分布数可変時の処理時間および 1 画素あたりの平均分布数

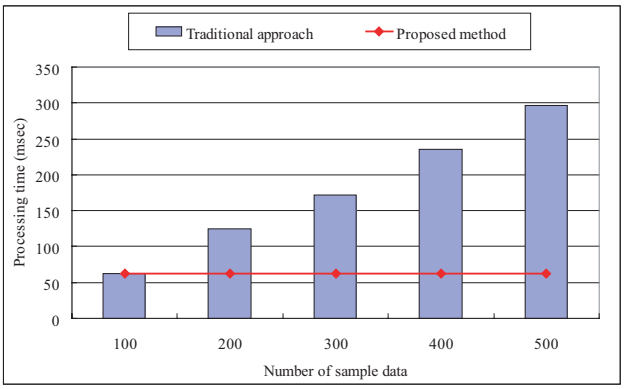

図 7: 確率密度関数推定に用いる画素値データ数と処理時間の関係

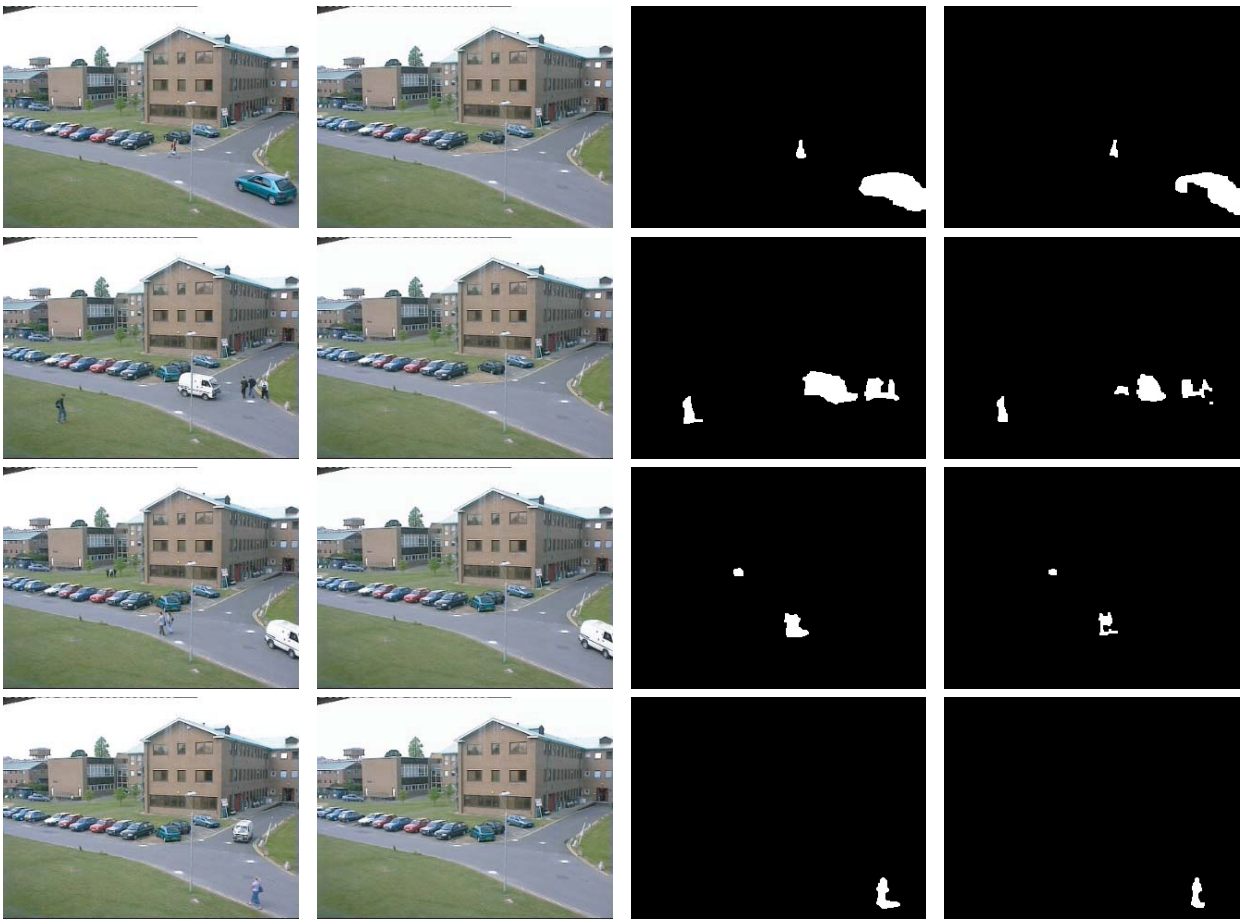

(a) 入力画像　(b) 背景画像　(c) 提案手法　(d) 混合ガウス分布による手法

図 9: 提案手法による背景差分の結果画像．(a) 入力画像，(b) 観測される確率が最も高い画素値による画像，(c) 提案手法により，背景差分で前景として抽出された画像，(d) 混合ガウス分布を用いた手法により，背景差分で前景として抽出された画像．

の関係を示す．縦軸は再現率，適合率である．まず，分布数可変型の混合ガウス分布による手法と比較すると，提案手法は非常に優れた結果であることがわかる．また，Elgammal らの手法と比べても同程度の精度が出ていることがわかる．このときの再現率は 94.38%，適合率は 88.89% あった．

最後に，提案手法による背景差分の結果を図 9 に示す．図 9(a) はあるフレームにおける入力画像である．図 9(b) はそのフレームにおける背景モデルであり，観測される確率が最も高い画素値を表している．図 9(c) は背景差分により得られた物体領域を示す画像である．また，比較のため，図 9(d) に分布数可変型の混合ガウス分布による手法を用いた場合の結果を示す．結果の画像を比較しても，提案手法が非常に良い結果が得られていることがわかる．

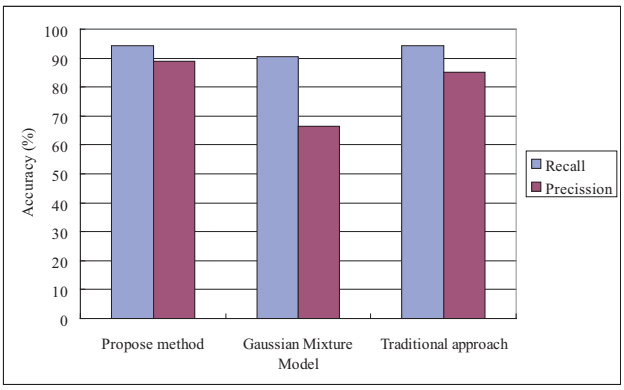

図 8: 再現率・適合率のグラフ

5. おわりに

本稿では，Parzen 推定を用いた動的背景モデル構築の高速化手法について述べた．提案手法では，新たに観測された画素値を基準にその周辺の確率密度関数のみを局所的に更新する手続きをとることで，背景モデルを更新するために必要な処理時間を大幅に短縮することができる．実験では，混合ガウス分布を用いた手法や，Parzen 推定を用いた従来の背景モデル推定法に比べ，高速かつ安定した処理時間で背景モデルの更新ができた．また物体領域の抽出精度に関しても，非常に優れていることが確認できた．今後の課題と展開としては以下のことがあげられる．

- **窓関数をガウス分布へ拡張：**
  提案手法では，Parzen 推定に用いる窓関数として式 (5) を用いた．しかし，窓関数としてガウス分布を用いる方がより滑らかに確率密度関数の推定を行うことができると考えられる．そこで，提案手法の動的背景モデル構築アルゴリズムを採用しつつ，窓関数をガウス分布に近づけるための仕組みが求められる．

- **影領域の除去：**
  今回提案した手法では，物体による影の領域も物体領域として抽出されてしまう．背景差分によって得られた物体領域を画像認識などに利用する場合，影領域は悪影響を及ぼす可能性があるため，影領域を除去する仕組みが求められる．

- **使用するメモリ領域の削減：**
  提案手法では，過去の画素値データおよび確率密度関数のヒストグラムを保持しておく必要があるため，映像の解析には多くのメモリ領域を確保する必要がある．解像度の高い画像に対し解析を行うことを考えた場合，使用するメモリ領域を減らすための工夫が必要である．

謝　辞

本研究は，文部科学省の平成 18 年度科学技術振興調整費による「科学技術連携施策群の効果的・効率的な推進」の一環として実施したものである．

参考文献

[1] 古山孝好, 向川康博, 亀田能成, 大田友一. “屋外大規模空間における自由視点映像生成のための選手領域抽出法”. 画像の認識・理解シンポジウム (MIRU2005), pp. 1412–1419, 2005.

[2] Chris Stauffer and W.E.L Grimson. “Adaptive background mixture models for real-time tracking”. *Computer Vision and Pattern Recognition (CVPR)*, Vol. 2, pp. 246–252, 1999.

[3] Jian Cheng, Jie Yang, and Yue Zhou. *“A Novel Adaptive Gaussian Mixture Model for Background Subtraction”*. Springer Berlin / Heidelberg, 2005.

[4] 島田敬士, 有田大作, 谷口倫一郎. “混合ガウス分布による動的背景モデルの分布数増減法”. 画像の認識・理解シンポジウム (MIRU2006), pp. 746–751, 2006.

[5] Ahmed Elgammal, Ramani Duraiswami, David Harwood, and Larry Davis. “Background and Foreground Modeling using Nonparametric Kernel Density Estimation for Visual Surveillance”. *Proceedings of the IEEE*, Vol. 90, pp. 1151–1163, 2002.

[6] 島井博行, 栗田多喜夫, 梅山伸二, 田中勝. “ロバスト統計に基づいた適応的な背景推定法”. 電子情報通信学会論文誌 D-II, Vol. J86-D-II, pp. 796–806, 2003.

[7] In Conjunction with IEEE Conference on Computer Vision and Pattern Recognition 2001. “Second IEEE International Workshop on Performance Evaluation of Tracking and Surveillance”. ftp://pets.rdg.ac.uk/PETS2001/, (accessed 2007/01/15).