

多峰型解析的 DP トラッキング

川野 裕希[†] フォン ヤオカイ^{††} 内田 誠一^{††}

[†] 九州大学大学院システム情報科学府 〒 819-0395 福岡市西区元岡 744

^{††} 九州大学大学院システム情報科学研究所 〒 819-0395 福岡市西区元岡 744

E-mail: [†]uchida@ait.kyushu-u.ac.jp

あらまし 高速かつオクルージョンや類似物体の存在に対する頑強性を持ったオフライン型の物体追跡手法として、多峰型解析的 DP トラッキング法を提案する。従来のオフライン型追跡手法の多くは、各フレームにおいて状態（位置や姿勢）の候補を多数準備した後、動的計画法 (DP) により全フレーム分の状態を一括最適選択する。ここで候補の準備が問題となる。すなわち、できる限り多くの候補を持たせると計算量が膨大になり、逆に少数にすると選択の幅が狭まり精度が低下する。このトレードオフを緩和するべく、本手法では、各フレームの比較的少数の候補の中から最良の 1 状態を選択した後、さらにその状態の周辺で真に最適な状態を再探索する。これら選択および再探索処理は、各フレーム独立ではなく、全フレーム分を考慮した大局的最適化の枠組みで実施される。具体的には、「離散的 DP」による最良候補選択の内側で「解析的 DP」による最良候補周辺での状態系列最適化が実行されるという、二重の最適化が図られる。この両最適化が共に DP の枠組みで効率的に実施されるところが、本手法の技術的特長の一つである。本論文では、本手法の詳細を説明し、さらにその有用性を代表的な追跡手法との比較実験を通して示す。

キーワード 物体追跡, 解析的 DP, 最適化

1. はじめに

動画像中の物体の追跡手法は、その計算過程により、オンライン型とオフライン型の 2 種類に大別される。前者は、各フレームが入力される毎にそのフレームでの追跡結果を確定する方法であり、リアルタイム追跡が実現可能である。Particle Filter [1] や Mean-Shift [2] といった代表的な追跡手法は、このオンライン型に属する。

これに対してオフライン型は、全フレームを取得した上で追跡結果を一括最適化する手法である。まず各フレームにおいて追跡対象の状態（位置や大きさ、回転など）の候補を複数準備する。各状態には評価値（尤度もしくはコスト）が付与される。その後、状態変化の連続性等を考慮しながら、各フレームの最適状態を全フレームにわたって一括最適選択する。この最適化法としては、動的計画法 (dynamic programming, 以下 DP) [3] が多く用いられている。

オフライン型の利点は、あるフレームでの追跡結果（最適状態）を得るのに過去と未来を含めた全フレーム分の情報が使える点である。このため、オンライン型に比べ破綻する可能性が低い。特にオクルージョンや類似物体の存在に対しての頑健性は魅力的である。ただし、リアルタイム追跡は原理的に実現不能である。従ってリアルタイム性よりも精度が重要視される場合や、追跡結果のマイニングや 2 次利用が主眼となる場合にはオフライン型を選ぶのが適切である。実はこうした応用は多く存在し、例えば顧客の店舗内動線解析、交通流解析、生物行動の統計解析、生体内の様々な動き解析などが挙げら

れる。

オフライン型の欠点は、その計算量の多さである。すなわち、各フレームで物体が取りうる状態が多様である上に、全フレーム分を一括して最適化するために、計算量が組み合わせ爆発するという問題を抱えていた。単純な対策として、取り得る状態を少数の候補に限定してしまうことが考えられる。しかし、限定された中に、真の最適状態が必ず含まれる保証はない。このため、粗い追跡精度しか得られない。結果的に粗密探索や事後補正処理といった工夫を別途施すの必要がある。

本論文では、オフライン型追跡手法の高精度性を保ちながら、計算の効率化を図った方法として、多峰型解析的 DP 法を提案する。本手法も、各フレームで少数の状態候補を準備する。従来法と異なるのは、候補中から選択された状態を、そのまま最終的な追跡結果にしない点である。すなわち、その選択された状態の周囲で、改めて真に最適な状態を再探索する。この「候補からの最良状態の選択」と「最良状態の周囲での再最適化」という二重の最適化処理により、従来より高精度な結果が得られる。

本手法の技術的特長の第一は、この二重の最適化処理を、離散的 DP と解析的 DP [4] という、同じ DP を用いた枠組みの中で同時進行する点である。すなわち、最良候補選択の後に周囲で再最適化、という二段階的な構造は採らない。これは確定した最良候補選択に誤りがあると、後段の再最適化で修正しきれないという問題がある。本手法では、再最適化により最終的にどのような最適状態が得られるかを見ながら、最良候補選択も順次進めて

いく。

本手法の技術的特長の第二は、状態の再最適化処理に解析的 DP [4] を用いている点である。後述するように、解析的 DP とは、目的関数を 2 次関数表現とすることで、組み合わせ的な探索を経ずして高速に最適解を求めることができる手法である。このため、再最適化処理による計算量の増加を最小限に抑えることが可能である。

本手法の原理は、厳密ではないが、ガウス混合分布（多峰型の尤度分布）と関連付けると理解しやすい。すなわち、上述の二重の最適化過程のうち、外側の最良候補選択処理は、混合分布を構成するガウス分布の一つ選ぶことに類似する。そして、内側すなわち候補位置周辺での再最適化処理が、その選んだガウス分布を参照しながら最適状態を求める処理に類似する。

以下、2. で従来の一般的なオフライン型の追跡手法、特に DP を用いた追跡手法について概観した後、3. で本手法の出発点となる解析的 DP に基づく追跡手法 [4] について説明する。なお、本論文では 3. の手法を、本手法に対照するべく単峰型解析的 DP と呼ぶ。次に 4. では、本手法すなわち多峰型解析的 DP に基づく追跡手法について述べる。そして 5. では実験を通して本手法の有効性を検証し、オフライン型手法（Mean-shift および Particle filter）やオフライン型手法（単峰型解析的 DP）に比べ高精度な追跡が可能であることを示す。最後に 6. ではまとめと今後の課題について述べる。

2. 関連手法

前述のように、オフライン型の物体追跡には、最適化手法として DP やその確率的拡張である HMM が用いられることが多い [5] ~ [11]。DP には、大局的最適解を保証でき、確率的手法のような試行毎の揺らぎがなく、計算時の数値誤差もほとんどなく、さらに多様な評価関数や制約を利用できるという利点がある。従って高精度な追跡手法を希求するには格好の手法である。

ただし、従来の DP に基づく追跡法には多大な計算量を要すると言う問題があった。前述の通り、オフライン型追跡では、各フレームで物体が取りうる状態が多様で、さらに全フレーム分を一括最適化するためである。状態としてフレーム ($N \times N$ 画像とする) 内の座標だけを考えた場合でも、全 T フレームの追跡結果最適化には $O(N^4T)$ の計算量が必要となる。状態として位置に加えて大きさや回転まで考えると、さらに計算量は増える。

この計算量の問題を解決するべく、様々な試みがなされている。多くは、事前処理により、各フレームで取りうる状態を有望な候補のみに絞り込むという操作を施す。例えば文献 [9] では、追跡対象のテンプレートに類似した部分を k-d tree を用いて高速に見つけ、それらの位置を状態候補としている。文献 [10] では、AdaBoost を用いてテンプレートに近い部分を認識することで、状態候補を絞り込んでいる。こうした絞り込みは、DP の古典的

な高速化法である枝刈り (beam search と同) と本質的には同類である。文献 [11] でも、時空間を対象としたスペクトルクラスタリングとスプライン補間により事前に追跡経路を絞り込んだ上で、その結果付近で改めて HMM で経路をリファインしている。

これらに対し文献 [4] では、全く異なった高速化アプローチとして、通常の組み合わせ探索的な DP (以下、離散的 DP) の代わりに解析的 DP [12] の利用を提案している。解析的 DP とは、各フレームのコスト関数を単一の 2 次関数で近似表現することで微分可能とし、その上で DP の再帰計算を適用することで高速に最適解 (2 次関数近似表現下での大局的最適解) を解析的に求める手法である。ただし、単一の 2 次関数による表現能力には限界があり、類似物体の存在等により 2 次関数の中心位置が真の物体位置より大きくずれてしまうと、結果の精度が大幅に低下してしまうという問題があった。

本論文で提案する多峰型解析的 DP は、離散的 DP と解析的 DP の両方の長所を活かした手法となっている。すなわち、各フレームで少数の状態候補を準備した後、離散的 DP によって、それらから各フレームで最良状態を選択する。そして、解析的 DP により、その選択された状態周辺において真の最適状態を再最適化する。このように解析的 DP による詳細化処理が入るので、候補数は少なくてもよく、離散的 DP の計算量は少なく済む。加えて、解析的 DP は真の解の近傍を起点とした最適化は得意であり、極めて高速にかつ高精度に再最適化を実行できる。以上から、本手法は高速かつ高精度な手法となっている。

3. 単峰型解析的 DP による追跡手法

本節では、本手法の基盤技術である解析的 DP に基づく追跡手法 [4] を説明する。本手法と対照のため、本節の方法を単峰型解析的 DP と呼ぶ。

3.1 定式化

以下では説明の単純化のために、フレーム t での追跡対象の状態がフレーム内での位置 $w_t = (x_t, y_t)^T$ のみで表される場合、すなわち平行移動のみを考える場合で説明する。この時、オフライン型の追跡問題は、一般に、 w_t を変数とした以下の目的関数 F の最小化問題として定式化される。

$$F(w_1, \dots, w_T) = \sum_{t=1}^T d_t(w_t) + \lambda \sum_{t=2}^T (w_t - w_{t-1})^2 \quad (1)$$

ここで、右辺の第一項の $d_t(w_t)$ は、追跡対象物体が時刻 t において状態 w_t にあると仮定した場合の局所コストである。第二項は、対象の状態変化の連続性評価項であり、定数 λ はその重みである。目的関数 F の最小値を与える状態系列 $w_1, \dots, w_T$ が最適追跡結果となる。

通常の離散的 DP では、局所コスト $d_t(w_t)$ を図 1(a)




図 1 局所コスト．(a) 離散的 DP，(b) 単峰型解析的 DP




図 2 単峰型解析的 DP による最適追跡結果の導出

のように各画素において離散的に設定する．これに対し，単峰型解析的 DP では，同図 (b) のように，局所コスト単一の 2 次関数で連続的に表現する点を特徴とする．従って，

$$d_t(w_t) = w_t^T P_t w_t + q_t^T w_t + r_t \quad (2)$$

と表される．ここで P_t は 2×2 の対称行列， q_t は 2 次元ベクトル， r_t はスカラーである．いずれも，3.3 で述べる方法等により予め与えられているものとする．

3.2 単峰型解析的 DP による最適追跡結果の導出

式 (1) に最適性の原理 [3] を適用すると，第 t フレームで位置 w_t に到達する最適状態系列の累積コスト $g_t(w_t)$ は次の漸化式で表される．

$$g_t(w_t) = d_t(w_t) + \min_{w_{t-1}} [g_{t-1}(w_{t-1}) + \lambda(w_t - w_{t-1})^2] \quad (3)$$

ここで局所コスト d_t と連続性評価項がともに状態 w_t を変数とする 2 次関数であることに注目すると，帰納的に累積コスト $g_t(w_t)$ も 2 次関数

$$g_t(w_t) = w_t^T A_t w_t + b_t^T w_t + c_t \quad (4)$$

で表現できることが証明できる (詳細略)．ここで， A_t は 2×2 対称行列， b_t は 2 次元ベクトル， c_t はスカラーとなる．係数 A_t, b_t, c_t は， P_t, q_t, r_t のような定数ではなく， w_t の最適化の過程で確定される変数である．

式 (2)(4) を (3) の右辺に代入すると次の式になる．

$$g_t(w_t) = w_t^T P_t w_t + q_t^T w_t + r_t + \min_{w_{t-1}} [w_{t-1}^T A_{t-1} w_{t-1} + b_{t-1}^T w_{t-1} + c_{t-1} + \lambda(w_t - w_{t-1})^2] \quad (5)$$

この右辺 $[\]$ 内の最小値を与える w_{t-1} は， $[\]$ 内が w_{t-1}

に関する 2 次関数であることから，微分によって解析的に求めることができる．すなわち，

$$\bar{w}_{t-1} = [A_{t-1} + \lambda I]^{-1} (\lambda w_t - b_{t-1}/2) \quad (6)$$

式 (6) を $w_{t-1} = \bar{w}_{t-1}$ として (5) に代入して，(4) と比較することで，2 次関数の係数 A_t, b_t, c_t を以下のように求めることができる．

$$\left. \begin{aligned} A_t &= \lambda I + P_t - \lambda^2 [A_{t-1} + \lambda I]^{-1} \\ b_t &= q_t + \lambda b_{t-1}^T [A_{t-1} + \lambda I]^{-1} \\ c_t &= -b_{t-1}^T [A_{t-1} + \lambda I]^{-1} b_{t-1} / 4 + c_{t-1} + r_t \end{aligned} \right\} \quad (7)$$

上式は， $A_{t-1}, b_{t-1}, c_{t-1}$ から A_t, b_t, c_t を逐次計算する方法を与えている．

以上の準備の下で，最適状態系列すなわち最適な追跡結果 $\bar{w}_1, \dots, \bar{w}_t, \dots, \bar{w}_T$ は，次のように解析的に求まる．すなわち，図 2 に示すように， $t = 1$ から T まで式 (7) により A_t, b_t, c_t を順次求める．そして，最終累積コスト $g_T(w_T)$ の最小値を与える状態 $w_T = \bar{w}_T$ を求め，そこから，式 (6) に従ったバックトラック処理により，最適状態系列 $\bar{w}_{T-1}, \dots, \bar{w}_t, \dots, \bar{w}_1$ を順次求めればよい．局所コストが事前に与えられていたとすれば，解析的 DP の計算量は，わずかに $O(T)$ である．

上の説明では触れなかったが，始端および終端 (すなわち第 1 および第 T フレームでの物体状態 $\bar{w}_1, \bar{w}_T$) については，離散 DP と同様，様々な扱い方が可能である．両端共にマニュアルで正解を与えることも可能であるし，始端もしくは終端のみ与えてもよいし，両端とも与えなくてもよい．始端のみに与えた場合， $\bar{w}_1$ は固定となるから， $g_2(w_2) = d_2(w_2) + \lambda(w_2 - \bar{w}_1)^2$ より A_2, b_2, c_2 を定めて，それから式 (7) を $t = 3, 4, \dots$ の順に計算すればよい．

3.3 局所コストの 2 次関数表現とその困難性

局所コスト d_t の 2 次関数表現法として，本論文では文献 [13] の手法を用いる．具体的には，何らかの方法で求めた状態 $\tilde{w}_t$ について，その箇所での局所コスト (図 1(a) の意味での局所コスト) およびその近傍状態の局所コストを求める．ただし， $\tilde{w}_t$ は周囲と比べて小さな局所コストを持つものとする．その後，それらとテイラー展開の原理により 2 次関数のパラメータ P_t, q_t, r_t を求める．簡単に言えば，図 1 (a) の局所コストを $\tilde{w}_t$ 付近で近似することで，同図 (b) の二次関数を求める．

以上で必要となる $\tilde{w}_t$ は，真の最適状態の近くに存在する必要がある．なぜなら，2 次関数 d_t の値は， $\tilde{w}_t$ から離れると急激に大きくなるので，結果的に最適解 $\bar{w}_t$ は $\tilde{w}_t$ 付近になる傾向が強い．従って， $\tilde{w}_t$ が真の最適状態から遠くずれていれば， $\bar{w}_t$ が真の最適状態付近になる可能性は低く，得られる最適状態系列の精度は悪くなる．

しかし実際問題として，真の最適状態の近くに $\tilde{w}_t$ を定めるのはそう容易ではない．明らかに，卵と鶏の問題




図 3 多峰型解析的 DP による最適追跡結果の導出

のような状況に陥ってしまう．要するに，解析的 DP は，真の最適状態の近傍付近からスタートするならばその能力を最大限発揮できるが，そうでなければ何らかの工夫が必要となってくる．この工夫として，文献 [4] では，反復改善法を導入している．これは，求めた $\bar{w}_t$ を次の $\tilde{w}_t$ として用いることを繰り返す方法である．一定の効果は見られるものの，収束の問題もあり，また計算量も増加する．本論文で提案する多峰型解析的 DP 法では，最大限の能力を発揮できるような条件下で解析的 DP を利用する．

4. 多峰型解析的 DP による追跡手法

4.1 複数の 2 次関数の導入

前節の単峰型解析的 DP に基づく追跡法の問題点は，各フレームで可能な全状態の局所コストを単一の 2 次関数で表現している点にあった．このため，その $\tilde{w}_t$ (2 次関数と言い換えてもよい) を真の最適状態に近い箇所で見つけることができなければ，高い精度は期待できない．残念ながら，類似物体が複数存在する場合など，どれが真の最適状態であるかを事前に確定するのは困難であり，結果的に，単峰型解析的 DP の性能限界を与えることになった．

そこで本手法では，各フレームで複数の 2 次関数を用いる．適当な数 (以下， K) の 2 次関数を何らかの方法で与えていれば，そのうちの一つぐらいは真の最適状態に近い可能性がある．よって，各フレームでその 2 次関数を適切に選択できれば，単峰型解析的 DP によっても，高精度な追跡結果，すなわち真の最適状態が得られるものと期待できる．

ところで，複数の 2 次関数を導入するということは，結局各フレームの局所コストを多峰型に見ていると言ってもよい．混合ガウス分布は複数のガウス分布の加重和による確率分布であるが，ガウス分布の対数を取ると 2 次関数になることから，本手法における多峰型局所コストと類似の関係にあると言ってよい．従って上記の 2 次関数の選択は，厳密ではないが，ガウス混合分布を構成するガウス分布のうち，最も見込みあるものを一つ選択する処理と見なせる．

4.2 多峰型解析的 DP による最適追跡結果の導出

図 3 に多峰型解析的 DP による最適追跡結果の導出の様子を示す．このように，各フレーム t において， K 個

の 2 次関数 $d_t^1(w_t), \dots, d_t^K(w_t)$ を考える．これらは， K 個の状態候補 $\tilde{w}_t^1, \dots, \tilde{w}_t^K$ のそれぞれの付近のコストを表したものであり，3.3 と同様の方法により求められる．各フレームで K 個の状態候補を求める具体的な方法は，4.5 で述べる．

この多峰型化により新たに発生した課題は，各フレームにおける最良状態 $\tilde{w}_t^k$ の選択 (最良な 2 次関数の選択と言い換えてもよい) である．全 T フレームで可能な選択は K^T 通り存在する．そしてそれらは図 3 にあるようにトレリス構造で表現される．このトレリス上で $t = 1$ から T までの経路のそれぞれが，一つの状態選択を表現する．従って，最良状態選択問題は，トレリス上の最適経路問題に相当する．

本手法ではこのトレリス上の最適経路問題を離散的 DP で解く．すなわち，トレリスのノード (t, k) に到達する最適経路を求めるべく，前ノード $(t-1, k')$ (ここで $k' \in \{1, \dots, K\}$) の中で最良なものを選択する．この処理を $t = 1$ から順に T まですべてのノードで行えば，離散的 DP により最適経路すなわち最良の 2 次関数選択結果が得られることになる．

本手法では，こうして最良選択された 2 次関数と解析的 DP を用いて， $\tilde{w}_t^k$ 周りでの状態を再最適化を行う．しかし前述のように「候補からの最良状態の選択」と「最良状態の周囲での再最適化」は独立に行うべきではない．すなわち，最適経路問題におけるノード選択の良さは，そのノードが対応する 2 次関数を用いた場合に得られる再最適化結果 (最適状態系列 $\bar{w}_1, \dots, \bar{w}_t$) の良さにによって評価されるべきである．このように，離散的 DP と解析的 DP の両者は同時並行的に進行する必要がある．

具体的には，外側の離散的 DP では，ノード (t, k) までの累積コスト $g_t^k(w_t)$ を求めるために， $t-1$ までの解析的 DP 計算で求まっている $g_{t-1}^1(w_{t-1}), \dots, g_{t-1}^k(w_{t-1}), \dots, g_{t-1}^K(w_{t-1})$ を評価し，最も妥当な $k = k'$ を選択する．(この累積コスト選択の際の評価基準については，4.3 で述べる．) そして，選択された $g_{t-1}^{k'}(w_{t-1})$ と $d_t^k(w_t)$ を用いて，単峰型解析的 DP による最適状態決定の漸化式 (3) と同様に以下の式を計算すればよい．

$$g_t^k(w_t) = d_t^k(w_t) + \min_{w_{t-1}} \left[g_{t-1}^{k'}(w_{t-1}) + \lambda(w_t - w_{t-1})^2 \right] \quad (8)$$

実際の計算に用いられるのは，単峰型の場合と同じく式 (7)(6) である．ただし A_t 等が A_t^k のように K 通り存在する点のみが異なる．最終状態系列すなわち最適追跡結果を求めるためには，まず最終フレームの累積コスト $g_T^1(w_T), \dots, g_T^K(w_T)$ の中から，最小値を与える k と $\bar{w}_T$ を探索する．そして，ノード (T, k) で選択した k' と (6) により $\bar{w}_T$ から $\bar{w}_{T-1}$ を求める．以下はこのバックトラック処理を $T-1, T-2, \dots, 1$ と繰り返して行けばよい．




図 4 多峰の解析的 DP における累積コスト $g_{t-1}^{k'}(w_{t-1})$ の選択．便宜上，状態 w_{t-1} を 1 次元表現している

4.3 累積コスト選択の際の評価基準

離散的 DP における経路選択基準すなわち累積コスト $g_{t-1}^{k'}(w_{t-1})$ の選択基準として，本論文では，

$$k' = \underset{l \in \{1, \dots, K\}}{\operatorname{argmin}} g_{t-1}^l(\tilde{w}_t^k) \quad (9)$$

を用いる．図 4 は， $K = 2$ とした時の累積コスト選択の様子である．このように g_{t-1}^1 と g_{t-1}^2 の相互関係によって， $k' = 1$ が選ばれるか， 2 が選ばれるかが変わってくる．

やや詳細な事項ではあるが，選択基準 (9) が準最適であることを注意しておく．絶対的に最適な経路は，全 K^T 通りの 2 次関数選択それぞれについて単峰型解析的 DP で求めた経路のうち，最小の F を与えるものである．一方，選択基準 (9) の下で求めた最適状態系列 $\bar{w}_1, \dots, \bar{w}_T$ はそれと必ず一致するとは限らない．図 4(a) の例では，(9) に従えば $g_{t-1}^1(w_{t-1})$ を選択するが，全コストすなわち目的関数 F の最小化の観点からは，実はこのフレームでは $g_{t-1}^2(w_{t-1})$ を選択したほうが，最終的にはより小さな F が求まる可能性もある．要するに時刻 t の 2 次関数の選択は，原理的には全時刻の最適状態系列 $\bar{w}_1, \dots, \bar{w}_T$ に影響するので，隣接時刻間のみのマルコフ的制約に依拠した離散的 DP では大局的最適性の保証はできない．

しかしながら実際には，(9) の選択基準でも，多くの場合において適切な経路が求まることが経験的にわかっている．まず，この選択基準ならば，図 4(a) のように，より近くに極小値を持つ累積コスト g が選ばれ易く，これは結果的に最適状態経路が連続的なものとなる効果を生む．さらに，同図 (b) からわかるように，全般に小さ

な値を持った $g_{t-1}^{k'}(w_{t-1})$ が選択され易いという傾向もある．

唯一，同図 (c) のようになってしまった場合は，上述の (a) の場合とは逆に，最適状態経路を不連続にになってしまう可能性がある．これを避けるべく，(9) ではなく， $\tilde{w}_t^k$ により近くに極小値を持つ $g_{t-1}^{k'}$ を選択するという方法も考えられる．しかしそれでは同図 (b) において g_{t-1}^1 が選ばれることとなり都合が悪い．このように， $g_{t-1}^{k'}(w_{t-1})$ の選択法にはそれぞれ一長一短があり，どの手法が最も良いかは今後も検討する必要がある．

4.4 多峰型解析的 DP の計算時間

単峰から多峰化したことで，計算量は確かに増加するが，それは以下の二つの理由で，さほど深刻なものにはなっていない．

- 第一に，本手法での離散的 DP の探索空間が小さい点である．すなわち離散的 DP が対象とするノード数は各フレームで K であるため，それに要する計算量は $O(K^2T)$ となる．ここで 2 次関数の個数 K は，本論文では 2 ～ 数十程度である．従って，例えば従来の離散的 DP が全画素をそのまま状態とした場合の計算量 $O(N^4T)$ に比べれば，依然として何桁も少ない計算量である．

- 第二に，離散的 DP および解析的 DP そのものに要する計算量は，全フレーム KT 個の 2 次関数の準備に要する計算量に比べれば，十分に少ない点である．従って $O(T) \rightarrow O(K^2T)$ のように計算量が増加したとしても，手法全体としての計算時間は K^2 倍にはならない．この事実は，5. の実験結果からも実証される．

既に 1. および 2. でも述べたことであるが，本手法により効率的に高精度な結果が得られることを再度強調しておく．前述の通り，離散的 DP は，そのままでは状態数が膨大になる．このため，少数の状態候補に限定する対策が採られる．本手法も K 個の 2 次関数を用いており，これは従来法における少数の状態候補の準備に相当する．ただし，従来法ではこれら状態候補から最適なものを選択してそのまま最適状態系列としていたのに対し，本手法ではそうではない．本手法では「候補からの最良状態の選択」と「最良状態の周囲での再最適化」を同時にかつ計算量の増加もほとんどなく DP の枠組みで統一的に実現しており，それが本手法の利点である．加えて「最良状態の周囲での再最適化」というタスクが解析的 DP が得意とするものであることも再度強調しておきたい．

4.5 複数の 2 次関数の準備

再三述べているように，各フレームで K 個の 2 次関数 $d_t^1(w_t), \dots, d_t^K(w_t)$ ，もしくは等価的にその中心 $\tilde{w}_t^1, \dots, \tilde{w}_t^K$ を状態候補として準備する必要がある．高精度な最終結果のためには，これら K 個のうち少なくとも一つは真に最適な状態の近くに存在する必要がある．




図5 物体位置候補の探索の処理過程．(a) 探索点の初期配置．(b) 各探索点ごとに Mean-Shift 実行．(c) Mean-Shift の収束結果．(d) 近接収束結果を統合

すなわち厳密である必要はないが，なるべく $\tilde{w}_k$ のうち一つは追跡対象付近に設定したい．

本論文では，図5に示すように， $\tilde{w}_t^1, \dots, \tilde{w}_t^K$ を Mean-Shift [2] を用いた手法 [11] で設定する．具体的な手順としては，まず同図 (a) のように各フレームで等間隔に複数の探索点を設定する．次に (b) のように，勾配法に基づき色ヒストグラムの類似度が増加する方向に探索点を逐次移動させる．そして，この逐次移動処理を繰り返し，(c) のように収束するまで行う．最後に (d) のように隣接する収束結果を統合する．この統合された結果のうち，より類似度の高いものから順に K 個選択し， $\tilde{w}_t^1, \dots, \tilde{w}_t^K$ とする．

5. 実験結果および考察

本手法の有効性を検証すべく，単峰型解析的 DP，Mean-Shift，および Particle Filter との比較実験を行った．比較を容易にするべく，いずれの手法でも，テンプレート (第1フレームの部分領域) との整合性もしくは相違度評価に，色ヒストグラムを利用した．本手法についてより具体的には，色ヒストグラム間の Bhattacharyya 距離に基づいて， $K = 5$ 個の2次のコスト関数を設定した．なお離散的 DP を単独で用いた方法については，後述するように膨大な計算量を要し，特に拡大縮小まで考えた場合には実行不可能であったため，今回の比較対象からは除外した．

図6は，Surveillance Performance Evaluation Initiative (SPEVI) データセット [14] の Multiple faces の動画像を用いて追跡実験を行った結果である．複数の人物が固定カメラの前を移動しており，その中の1人の顔を追跡している．追跡対象に類似した物体 (顔) が複数存在し，オクルージョン (第75フレーム付近) も発生している (添付資料 “SPEVI-MultiFace-1”)

図6(a)は本手法による追跡結果，(b)は5つの2次関数の設定領域である．また (c)-(e) はそれぞれ単峰型解析的 DP，Mean-Shift，Particle Filter による結果である．本手法は類似物体やオクルージョンがあっても正しく追跡できているのに対し，他の手法は失敗していることがわかる．

単峰型解析的 DP が追跡に失敗したのは，途中フレームで誤って追跡対象外の物体付近に (単一の) 2次関数を設定してしまったためである．同図 (b) の枠の色は，値が小さな2次関数からの順に，黄色 (実線)，黄緑色 (点線)，水色 (点線)，青色 (点線)，紫色 (点線) となっている．従って単峰型では黄色 (実線) の位置にのみ2次関数が設定されることになる．ここで第88，100フレームを見ると，追跡対象外の物体位置に2次関数が設定されてしまい，それら影響で追跡に失敗する．一方，本手法では，追跡対象が5個の候補の1つに常に含まれているため，正しく追跡できている．

Mean-Shift と Particle Filter はオクルージョンにより追跡に失敗している．前者は勾配法に基づく Greedy 最適化であるため，第75～115フレームにあるように一度追跡に失敗したときに回復が困難である．Particle Filter は，オクルージョンを起こした類似物体と追跡対象の2つにパーティクルが分散してしまい，その結果オクルージョンが発生した直後の第88～95フレーム間で追跡に失敗している．多峰型解析的 DP の結果では，オクルージョン前後で安定して追跡を続けており，オフライン型追跡手法の頑強性を例証している．

本手法を用いても図7(a)のように追跡に失敗することがあった．同図 (b) は2次関数の設定領域である．第29フレームで他の類似物体を誤追跡している．本手法が追跡に失敗したのは，照明状況の変化による追跡対象の見えの変化と類似物体の接近が同時に起こったためである．第29フレームでも追跡対象が5つの2次関数の設定領域には含まれているが，より局所コストが小さな候補が近くに存在したためそちらを誤追跡している．こうした誤追跡を回避するためには，局所コストの評価法の高精度化がまず挙げられる．本手法は，どのような局所コストであってもそれを基に2次関数表現さえできれば使えるので，様々な評価法を試す価値はある．

計算時間に関しては，本手法は単峰型解析的 DP に比べる1.28倍を要した．4.4でも予告したように，多峰性を導入しても，ほとんど計算量を増やさずに済んでいる．なお，計算量が $K^2 (= 25)$ 倍にならなかったのは，計算量の大部分が4.5で述べた2次関数の準備に要したためである．なお，文献 [4] の実験結果では，単峰型解析的 DP に比べ，離散的 DP は4桁以上の計算量を要することが示されている．以上より，多峰型化したとしても，依然として，離散的 DP に比べて遥かに高速であることがわかる．

以上では，対象物体の平行移動のみを考えてきたが，




図 6 追跡結果例．(a) 多峰型解析的 DP による追跡結果，(b) $K = 5$ 個の 2 次関数の設定領域，(c) 単峰型解析的 DP による追跡結果，(d) Mean-Shift による追跡結果，(e) Particle Filter による追跡結果

例えば拡大縮小を導入することも可能である．この場合，状態空間が劇的に広がるため，通常の離散的 DP ではもはや実行不能になる．これに対し本手法では，拡大縮小に対応した Mean-Shift [15] を用いて 2 次関数表現さえできてしまえば，あとはほとんど計算時間は増えない．最適化過程も，状態 w_t の表現が x, y 座標値の 2 次元から，スケールも含めた 3 次元になる程度の変更で済む．添付資料 (“PETS”) では，大きさの変化する人物を追跡させているが，オクルージョンや類似物体の存在があっても，

頑強に追跡できていることがわかる．

6. ま と め

本論文では，多峰型解析的 DP によるオフライン型物体追跡手法について提案した．本手法では，各フレームで複数の 2 次関数をコスト関数として準備しておき，それらのうち一つを最適選択しながら，そうして選択されたコスト関数を用いて改めて追跡経路を最適化する．アルゴリズム的には離散的 DP と解析的 DP と組み合わせ




図 7 多峰型解析的 DP による失敗例．(a) 追跡結果，(b) $K = 5$ 個の 2 次関数の設定領域

たものとなり，前者がコスト関数の最適選択，後者が追跡経路の最適化を担当する．一般に離散的 DP に基づく追跡手法は膨大な計算時間を要するが，ここでは単に少数のコスト関数を対象とした選択問題を解くだけなのでわずかな計算量で済む．解析的 DP はコスト関数が 2 次関数であることを利用して解析的にすなわち組み合わせ探索無しに大域的最適解を求める．その結果，オフライン型追跡手法としての精度を落とすことなく，少ない計算量で追跡結果を求めることができる．実験を通して，この事実を例証した．

今後の課題としては，第一に，2 次関数の準備に，今回用いた Mean-Shift 以外の方法を試みることが挙げられる．文献 [9] のように k-d tree を用いた認識ベースの手法などにより，より正しい位置に 2 次関数を準備できる可能性がある．第二に，コスト評価法の再吟味が挙げられる．今回の実験では，単純な色ヒストグラム間の距離を用いたが，対象に特化した様々な評価法も当然考えられる．第三に状態の高次元化が挙げられる．これは対象物体の姿勢や見えなどをより多くのパラメータで表現できることを意味している．従来の離散的 DP に基づいた方法では，高次元化に伴って状態空間が爆発する影響をダイレクトに受けてしまい，実行不能になってしまう．これに対し本手法は，高次元化したとしても，準備する 2 次関数の数が変わらなければ計算量にほとんど変化はないため，そのような状況に陥る危険性は低い．第四に，多峰型解析的 DP の内部で行われる 2 次コスト関数選択方式について，他の方法を模索することが挙げられる．

文 献

- [1] M. Isard and A. Blake, "Condensation — Conditional Density Propagation for Visual Tracking," IJCV, vol. 29, no. 1, pp. 5-28, 1998.
- [2] D. Comaniciu, V. Ramesh, and P. Meer, "Real-Time Tracking of Non-Rigid Objects Using Mean Shift," Proc. CVPR, pp. 142-149, 2000.
- [3] 内田誠一, "DP マッチング概説 ～基本と様々な拡張～," 信学技報, PRMU2006-1006, 2006.
- [4] 藤村一行, 内田誠一, "大域的最適化に基づくトラッキング - DP トラッキング -, " 信学論, vol. J92-D, no. 8, pp. 1279-1288, 2009.
- [5] Y. Barniv, "Dynamic Programming Solution for Detecting Dim Moving Target," IEEE Trans. Aerospace and Electronic Systems, vol. 21, no. 1, pp.144-156, 1985.
- [6] J. Arnold, S. Shaw, and H. Pasternack, "Efficient Target Tracking Using Dynamic Programming," IEEE Trans. Aerospace and Electronic Systems, vol. 29, no. 1, pp. 44-56, 1993.
- [7] M. Han, W. Xu, H. Tao, and Y. Gong, "An Algorithm for Multiple Object Trajectory Tracking," Proc. CVPR, pp. 864-871, 2004.
- [8] P. Dreuw, T. Deselaers, D. Rybach, D. Keysers, and H. Ney, "Tracking Using Dynamic Programming for Appearance-Based Sign Language Recognition," Proc. FGR, pp. 293-298, 2006.
- [9] A. Buchanan and A. Fitzgibbon, "Interactive Feature Tracking Using k-d Trees and Dynamic Programming," Proc. CVPR, pp. 626-633, 2006.
- [10] Y. Wei, J. Sun, X. Tang, and H. -Y. Shum, "Interactive Offline Tracking for Color Objects," Proc. ICCV, pp. 1-8, 2007.
- [11] J. Sun, W. Zhang, X. Tang, and H. Shum, "Bi-directional Tracking Using Trajectory Segment Analysis," Proc. ICCV, pp. 717-724, 2005.
- [12] 内田誠一, 迫江博昭, "解析的 DP マッチング," 信学論, vol.90-D, no.8, pp.2137-2146, 2007.
- [13] M. Etoh, "Promotion of Block Matching: Parametric Representation for Motion Estimation," Proc. ICPR, vol. 1 of 2, pp. 282-285, 1998.
- [14] <http://www.eecs.qmul.ac.uk/~andrea/spevi.html>
- [15] R. Collins, "Mean-shift Blob Tracking through Scale Space," Proc. CVPR, pp. 234-240, 2003.

付 録

添付資料について

本論文では，添付資料として，本手法（多峰型解析的 DP），および単峰型解析的 DP，Particle Filter，Mean-Shift の比較実験結果を与えている．実験結果の資料が格納されているフォルダは以下の 4 つである．すなわち，本文中でも説明した複数人物がオクルージョンを起こしながら移動する SPEVI-MultiFace-1，同様の SPEVI-MultiFace-2，スポーツシーン（アメリカンフットボール）の標準動画像を使った Football，ならびに独自試料である Tennisball である．最後の Tennisball は，ほとんど同じ見えを持ったものが接触しながら移動するという極めて困難なタスクである．以上に加え，平行移動だけでなく拡大縮小まで含めた場合の本手法の結果結果を，別途 PETS フォルダに格納している．