

時空間オブジェクトの混合分布によるモデリングと追跡

-greedy EM 法に基づく発生・消滅を考慮した追跡手法の検討 -

Examination of object tracking method for space-temporal data based on greedy EM algorithm

林 諒*¹
Ryo Hayashi

本田 理恵*¹
Rie Honda

*¹ 高知大学
Kochi University

Extracting objects such as clouds in weather images in the spatiotemporal data and tracing the changes of the shape, the position, the interaction between objects and events such as generation, extinction are important tasks in spatio-temporal data mining. The method of object extraction and tracking using mixture of multivariate normal distribution applying greedy EM algorithm is proposed. Experiments using artificial data showed effectiveness of the proposed method.

1. はじめに

地球観測衛星や気象レーダなどの時空間データのリアルタイム収集やアーカイブ化が進んでいる。具体的な例には、気象衛星ひまわり 8 号の取得画像や、3次元フェーズドアレイレーダデータによる降水コア発生のモニタリングなどがある。このようなデータから時空間変動のパターンを抽出することができれば、関連のある自然現象のメカニズムの理解や、極端な事象の発現の予測を予測に活用する事ができる。

我々は、気象画像やレーダ画像などの時系列2次元、3次元データから、気象画像における雲やレーダデータの降水コア（反射強度の高い部分）のような、周囲とは異なる特徴をもつ不定形の領域をオブジェクトとして抽出し、発生、成長、吸収、分裂、消滅などのオブジェクトの変遷を記載することで時空間変動のパターンを記載することを検討してきた[Matsunaga 2015][Hayashi 2017]。特に、オブジェクトの抽出には多変量正規分布の混合分布によるモデリングに基づく手法を検討してきたが、時間断面で取り出したオブジェクトの時間方向への連結については、前の時間の初期値を次の時間の初期値とするともに、解の削除や2重化を行う事によって、出現や消滅を扱う手法を提案してきた。しかし、実際には、分裂と出現の区別がつかない、オブジェクトの識別ラベルが入れ替わる、といった事象が起こっており、オブジェクトの追跡や、発生、吸収、分裂、消滅などの変遷を正しく把握する事には問題が残っていた。

本研究では、逐次的に成分を追加する greedy EM アルゴリズムを改良して取り入れることによって、オブジェクトの識別の精度を向上させる手法について検討する。また人工データを用いたその効果についての予備的な実験結果について報告する。

2. 手法

2.1 多変量正規分布の混合分布と EM アルゴリズムによるオブジェクトモデリング

まず基本的なモデリング手法について概観する。対象とする2次元、3次元データ中に、観測点が存在し、その分布が多変量正規分布の混合分布で表現できるものとする。簡単のため画像等の場合は閾値処理によって、閾値をこえた座標をもとめ、

輝度値そのものはここでは使用しないものとする。このように塊状に分布する M 次元のデータ集合 X の塊をオブジェクトとして表現する事を考える。

$$X = \{x_i \in R^M \mid i = 1, 2, 3, \dots, n\} \quad (1)$$

ここでデータ x を観測する確率密度分布が下記の通りの 1 つのオブジェクトの存在を表す多変量正規分布でモデル化できるものとする。

$$\phi(x|\mu, S) = \frac{1}{(\sqrt{2\pi})^M \sqrt{|S|}} \exp\left\{-\frac{1}{2}(x - \mu)^T S^{-1}(x - \mu)\right\} \quad (2)$$

$\mu \in R^M$ は多変量正規分布の中心ベクトル（平均値）、 S は $M \times M$ の分散共分散行列とする。 μ はオブジェクトの中心、 S はオブジェクトの広がりを表す。複数のオブジェクトが存在する時、座標 x においてオブジェクトを観測する確率密度分布は複数成分からなる多変量正規分布の重み付きの平均で表される。

$$f_K(x) = \sum \omega_j p(x|\mu_j, S_j) \quad (3)$$

ω_j は重み係数 ($\sum_{j=1}^K \omega_j = 1$)、 K は成分数を表す。パラメータを以下の通りまとめるものとする。

$$\theta = \{(\mu_j, S_j, \omega_j) \mid j = 1, \dots, K\} \quad (4)$$

ここで観測値 X はどの多変量正規分布から発生したものかを知ることができないいわゆる不完全データであり、最尤推定などの手法で直接パラメータを求めることができない。よって、EM (Expectation and Maximization) アルゴリズム [Dempster 1997] でパラメータを求める。EM アルゴリズムは、仮に与えたパラメータ θ からモデルを計算し、さらにモデルの対数尤度を増加させるような新しいパラメータ θ' を推定するという操作を繰り返すことによって対数尤度 $L(\theta)$ を最大化するパラメータ θ' を求めるものである。

$$L(\theta) = \log \left(\prod_{i=1}^n P(x_i | \theta) \right) \quad (5)$$

$$\theta' = \operatorname{argmax}_{\theta} L(\theta) \quad (6)$$

EM アルゴリズムによるパラメータの計算手順を示す。

E ステップで寄与率を推定し、これをもとに M ステップで対数尤度を最大化するパラメータを推定し、この値を用いて寄与率を推定するというプロセスを収束するまで続ける。ここで寄与率 $z(i, j)$ は、観測値 x_i が j 番目の多変量正規分布 (オブジェクト) から発生したことを示す推定量である。

1. $\theta = \{(\mu_j, \Sigma_j, \omega_j) | j = 1, 2, \dots, K\}$ に初期値を与える。

2. E-Step: 寄与率 $z(i, j)$ を計算する。このとき変化 $z(i, j) - z'(i, j)$ が小さければ終了。そうでない場合 3 を実行する。

$$z'(i, j) = \frac{\omega_j p(x_i | \mu_j, \Sigma_j)}{\sum_{k=1}^K \omega_k p(x_i | \mu_k, \Sigma_k)} \quad (7)$$

3. M-Step: 対数尤度を最大化させるようモデルパラメータを更新し、 $z(i, j) \leftarrow z'(i, j)$ として 2 に戻る。

$$\omega_j' = \frac{\sum_{i=1}^n z'(i, j)}{n} \quad (8)$$

$$\mu_j' = \frac{\sum_{i=1}^n z'(i, j) x_i}{\sum_{i=1}^n z'(i, j)} \quad (9)$$

$$\Sigma_j' = \frac{\sum_{i=1}^n z'(i, j) (x_i - \mu_j)(x_i - \mu_j)^T}{\sum_{i=1}^n z'(i, j)} \quad (10)$$

なお成分数 K については総当たりで上記の手法でもとめたモデルパラメータに対してバイズの情報量基準 (BIC) [Schwarz 1978] を用いて、最適な (すなわちこれを最小化する) K を求める。 F は自由度である。

$$\text{BIC} = -2nL(\theta) + F \log n \quad (11)$$

2.2 先行研究での成分の追跡手法

2.1 の手法で求めたモデリングの結果を次の時間のモデリングに継承し、かつ計算時間を削減するため、先行研究 [Matsunaga 2015] [Hayashi 2017] では以下のような手法を使用した。

(1) 前の時刻 t の解, $\theta_t = \{(\mu_{j,t}, \Sigma_{j,t}, \omega_{j,t}, l_{j,t}) | j = 1, \dots, K\}$ を $\omega_{j,t}$ 値順にソートしたものを

$$\theta_{t+1,K} = \{(\mu_{j,t+1}, \Sigma_{j,t+1}, \omega_{j,t+1}, l_{j,t+1}) | j = 1, \dots, K\}$$

とする。ここで成分の追跡のためモデルパラメータにラベル l_j を追加している。

(2) 次の時間の初期値は以下のものとする

$$\theta_{t+1,K-N}, \dots, \theta_{t+1,K-1}, \theta_{t+1,K}, \theta_{t+1,K}, \theta_{t+1,K}, \dots$$

ここで $\theta_{t+1,K-k}$ は重み係数の小さい順に解候補を消去したものの $\theta_{t+1,K-k} = \{(\mu_{j,t+1}, \Sigma_{j,t+1}, \omega_{j,t+1}, l_{j,t+1}) | j = k, \dots, K\}$ とする。

一方 $\theta_{t+1,K+k}$ は重み係数の大きい順に解を複製して、新たに発生する解を扱えるようにしたもので、

$\theta_{t+1,K+k} = \{(\mu_{j,t+1}, \Sigma_{j,t+1}, \omega_{j,t+1}, l_{j,t+1}) | j = K - k, \dots, K\}$ で表されるものとする。

(3) これらの初期値候補について EM アルゴリズムによりモデルパラメータを求め、BIC を最小にするものを選択する。

この手法を実際に気象画像等に適用すると、初期値が不適当でも EM アルゴリズムによるパラメータ決定の過程で柔軟に解の乗り換えを起こして、もっともらしいモデルを成分数の増減にも対応しながら求める事ができることを実験より確認している。しかし、特にオブジェクトの追跡に着目すると以下の問題点がある。

- A) 分裂が重みの大きいもので起こることを前提としているが必ずしも正しいとは限らない
- B) 消滅が重みの小さいもので起こることを前提としているが必ずしも正しいとは限らない
- C) A), B) の理由により、同一の成分を同じラベルで追跡する事ができない可能性がある
- D) 新規発生と分裂を識別する事ができない
- E) 消滅と吸収を識別することができない

特に A), B), C) の問題により、ラベル付けによって、追跡、発生、消滅、分裂、吸収等のオブジェクト間の相互作用を把握する事は困難である。本研究ではまず B), C) の問題を解決することを目的として、新規発生、消滅に対応した初期値設定に greedy EM アルゴリズムの考えを採用した手法を提案する。

2.3 greedy EM アルゴリズム

greedy EM アルゴリズム [Nikos 2002] は Nikos らによって提案された逐次的に成分を追加することによって多変量正規分布の混合分布を学習するために開発された手法である。greedy EM アルゴリズムでは、 K 成分からなる混合分布 $f_K(x)$ に対して成分 $\phi(x | \mu, \Sigma)$ を追加した $f_{K+1}(x)$ は以下の式で表されるものとする。

$$f_{K+1}(x) = (1 - \alpha) f_K(x) + \alpha \phi(x | \mu, \Sigma) \quad (12)$$

ここで α は 0 から 1 の範囲の実数である。 α と μ, Σ は新しい対数尤度 L_{K+1} を最大化するように決定される。

$$\begin{aligned} L_{K+1} &= \sum_{i=1}^n \log f_{K+1}(x_i) \\ &= \sum_{i=1}^n \log [(1 - \alpha) f_K(x_i) + \alpha \phi(x_i | \mu, \Sigma)] \end{aligned} \quad (13)$$

この手法では本来はまず成分数 $K=1$ からスタートして、仮のパラメータを求めて、ここから 1 成分ずつ追加しながらパラメータを決定していく。次の成分に進む際には、すべてのデータ x_i について、 L_{K+1} のローカルな推測値を最大化する点を見つけ、これを新しい成分の重心 μ として、部分的な EM アルゴリズムを実行し、 $L_{K+1} \leq L_K$ となるまで、成分の追加を繰り返す。

この手法を、生成消滅しながら時間変化する多変量正規分布の混合モデルに適用するには、 $f_K(x)$ を前の時刻の解として、次の時刻に発生した新規成分 $\phi(x | \mu, \Sigma)$ を追加する過程をおなじフレームワークで使うことが可能であることが予想できる。

2.4 時間変化する成分の追跡への対応

ここでは時間とともに生成・消滅する多変量正規分布の追跡に逐次的に成分を追加する greedy EM アルゴリズムを適用する際の変更点について述べる。大まかには、前の時間の解を既存の成分のパラメータとして仮置きして、greedy EM による成分数の増加の処理を行い、その後、不要になった成分を除去するというアプローチをとる。

(1) 成分増加時の処理

本来の greedy EM アルゴリズムでは、成分追加時に既存の成分のパラメータも決定し直すが、これによって解の乗り移りなどが発生して追跡が困難になることが予想される。よって既存の成分で一旦決定されたパラメータは、適切な成分数の追加が終わるまで変化させないものとする。また、成分数増加の判定では greedy EM では尤度を用いていたが、成分数が異なると自由度が異なるため、評価指標は BIC に変更する。

(2) 成分削減時の処理

次に消滅等によって不要になった成分を削除する。各成分を順番に削除して尤度が最大になる成分を削除候補成分とする。成分を削除した後に EM アルゴリズムを実行し、その後 BIC による判定を行う。

(3) 増加・削減をまとめた一連の処理

全体の手順を図 1 に示す。手順 2 の成分増加と手順 3 の成分削減処理の間に手順 3 として EM アルゴリズムによる全パラメータ調整を追加している。これは、greedy EM 中のパラメータの修正を追跡のために意図的に行っていないためである。

- 1 前の時間の解の k 成分のパラメータを用いて初期化
- 2 発生した成分の追加
 - 2.1 すべてのデータ点 $\mathbf{x}_i$ を探索し、この値を新たな成分の平均 $\boldsymbol{\mu}$ として追加した時に尤度を最大化するデータ点 $\mathbf{x}_i$ を $\boldsymbol{\mu}$ に設定
 - 2.2 $S, \hat{\alpha}$ を初期化。
 - 2.3 $|L_{k+1}^n/L_{k+1} - 1| \leq (10^{-6})$ を収束条件として EM アルゴリズムにより追加パラメータを推定
 - 2.4 $BIC_{k+1} \leq BIC_k$ の場合は追加せずに終了、そうでない場合は追加のうえ 2.1 へ戻る
- 3 すべてのパラメータに対して EM アルゴリズムでパラメータを決定し直す。
- 4 消滅した成分の除去
 - 4.1 すべての成分を探索し、成分削減時に尤度を最大化する成分を選択
 - 4.2 $|L_{k+1}^n/L_{k+1} - 1| \leq (10^{-6})$ を収束条件として EM アルゴリズムにより全パラメータ推定
 - 4.3 $BIC_{k+1} \leq BIC_k$ の場合は削除せず終了、そうでない場合は当該成分を削除して、4.1 へ戻る

図 1 Greedy EM を応用した時間変化する多変量正規分布の混合モデルのパラメータ導出アルゴリズム

3. 実験

この追跡アルゴリズムの精度検証のために 2 次元の人工データを用いた 2 種類の検証実験を行った。実験内容は(1)時間移動による追跡性能の評価、(2)時間経過中に起こる新規発生、消滅等のイベントを適切にとらえられるかの検証を行った。

図 2 に (2)の実験結果の一例を示す。図中の青十字がデータ点で、3 から 5 程度の成分が時間とともに移動しながら、新規発生、消滅などを起こしている。本研究の手法によって求められた成分の平均、標準偏差がそれぞれ赤丸、青い円で、各成分につけられた数字は成分のラベルを表す。求められた成分は概ね画像中の成分の移動を正しく追跡しながらモデリングし、新規発生、消滅の際のラベル付にも対応していることが観察できる。また、時間 6 では発生と消滅の両方を正しく補足することができている。しかし時間 4 では本来 2 つになるべき成分を 1 つの成分(5)として捉えてしまっている。この問題に関しては、本研究では対象外としているが観測値の強度による重み付け【Hayashi 2017】を用いることで改善できると考えられる。その他詳細な実験結果に基づいた効果と問題に対する対策の考察については発表で述べる。




図 2. 実験による成分の移動、発生、消滅の補足の検証結果。青十字がデータ点、求められた成分の平均、標準偏差がそれぞれ赤丸、青い円が分散、各成分につけられた数字は成分のラベルを表す。

4. おわりに

greedy EM アルゴリズムの考えをオブジェクトの時間追跡に応用することによって、発生、消滅しながら時間変化するオブジェクトの追跡の精度を高める手法を考案した。また人工的データに対して予備実験を行い、その効果を確認した。今後はさらに残された”発生と分裂”、”消滅と吸収”の識別法についての検討をすすめて、フェーズドアレイレーダデータや気象画像の実画像についての検討を進める予定である。

謝辞

本研究は科研費 17K00158 補助により進められました。ここにお礼申し上げます。

参考文献

- [Matsunaga 2015] 松永知也: 時系列画像からのオブジェクトデータベースマイニング-オブジェクト抽出とデータベース化-, DEIM2015,2015
- [Hayashi 2017] 林諒:時系列 3 次元グリッドデータからのホットスポットの自動抽出・追跡法の開発-フェーズドアレイ気象レーダデータによる局地的大雨解析への適用-, DEIM2017,2017
- [Dempster 1997] A. P. Dempster et al., Maximum Likelihood from Imcomplete Data via EM Algorithm, Journal of the Royal Statistical Society, series B, vol. 39, no. 1,1-38, 1977.
- [Schwarz 1978] Schwarz, G., Estimating the dimension of a model, Annals of Statistics 6, 461-464, 1978

[Nikos 2002] Nikos Vlassis: A Greedy EM Algorithm for Gaussian Mixture Learning, Neural Processing Letters 15, Kluwer Academic Publishers , 2002.