

混在直線からの消失点・消失線と直線の同時推定

皆川 明洋[†], 田川 憲男[†], 守屋 正[†], 後藤 敏行^{††}

[†] 東京都立大学大学院 工学研究科
〒192-0397 八王子市 南大沢 1-1

^{††} 横浜国立大学大学院 工学研究科
〒240-8051 横浜市 保土ヶ谷区 常盤台 79-5
E-mail: akihiro@eei.metro-u.ac.jp

従来の消失点・消失線検出手法は、まず特徴点群を同一直線上にあるべき点の集合にクラスタリングした後、各直線を検出してそれらが交わるべき点として消失点を決定し、さらに得られた複数の消失点から消失線を求めている。しかし、観測雑音を考慮した最適化問題として捉えた場合、これらの処理をすべて統合し、クラスタリング、直線検出、消失点・消失線検出を同時に行なうことが望ましい。そこで本稿では、特徴点群に含まれる観測ノイズに2次元正規混合分布モデルを仮定し、消失点・消失線を陽に含んだ形で尤度関数を定義することで、上記の同時検出を最尤推定問題として定式化する。さらにEMアルゴリズムに基づく反復計算手法を提案する。その際、パラメータの階層構造を考慮したパラメータ更新法ならびに計算量削減法についても検討し、それにより妥当な計算量で安定した収束が可能となることを示す。

消失点・消失線, 最尤推定, 正規混合分布モデル, EM アルゴリズム

Line Clustering with Vanishing Point and Vanishing Line Estimation

Akihiro MINAGAWA[†], Norio TAGAWA[†], Tadashi MORIYA[†], Toshiyuki GOTOH^{††}

[†] Graduate School of Engineering, Tokyo Metropolitan University
Hachioji-shi, 192-0397 JAPAN

^{††} Graduate School of Engineering, Yokohama National University
Hodogaya-ku, Yokohama-shi, 240-8051 JAPAN
E-mail: akihiro@eei.metro-u.ac.jp

In the conventional methods to detect a vanishing point and a vanishing line, first the observed feature points are clustered into the collections each of which represents a different line, secondly the multiple lines are detected and the vanishing points are detected as a cross points of the lines, and lastly the vanishing line is detected based on them. However, in consideration of an optimization problem, these processes should be integrated and be achieved simultaneously. In this paper, we assume that the observed noise model for the feature points is a two-dimensional normal mixture and define the likelihood function including obviously a vanishing point and a vanishing line. As a result, the above simultaneous detection can be formulated as a maximum likelihood estimation problem. Additionally, an iterative computation method to achieve this estimation is proposed based on the EM algorithm. In the method, we also propose the technique to gain a stable convergence and to reduce a computational cost. The effectiveness of the proposed method with these techniques can be confirmed by the computer simulation results.

Vanishing Point and Vanishing Line, ML estimation, Mixture Normal distribution model, EM algorithm

1 はじめに

消失点は画像平面に投影された実空間上の平行線群の収束点であり、カメラ中心と消失点を結ぶベクトルが実空間上の平行線の方向と一致することから、3次元解析に利用するための研究が進められてきた[1]。一方、消失点の検出については、実空間上の平行線に対応する直線群を延長し、それらの交点を検出する問題として研究された。しかし、画像の量子化や直線検出誤差の影響により、消失点を構成するはずの直線群が必ずしも一点で交差するとは限らないという問題があり、さまざまな手法が提案されている。これらを大別すると、Hough変換を用いる手法と、確率的評価に基づく手法に分けられる。

前者の方法としては、原画像の各画素を極座標系 (γ, α) で表現し、それを $1/\gamma$ と α で構成される座標系に射影することにより、消失点を構成する直線要素が消失点と原点を通る円上に分布するという性質を利用する方法が提案されている[2]。この手法では、さらに、この円が直線となるように再射影することによって、消失点を検出する。しかし、直線要素検出時の濃度勾配の揺らぎや多重の変換による量子化誤差の影響が明確でないという問題が残る。一方、特徴点を $\rho-\theta$ 平面に投票した後に、最小二乗法によるサイン曲線の当てはめを行うことによって消失点を推定する方法[3]や、サイン曲線上の投票総数を評価する方法[4]なども提案されている。しかし、これらの方法は、傾きが近いデジタル直線が交点近傍で複数画素を共有する影響で、特徴点の重複検出や検出漏れなどの問題があった。この問題に対して、筆者らはこれまでに、受容野に重複のない扇型オペレータを用いることによって、画像内に存在する消失点に対して、これを安定に検出する手法を提案している[5]。

一方、確率的評価に基づく手法として、金谷は直交性当てはめの信頼性を理論的に解析するとともに、エッジ統合、消失点検出などに関する統計的仮説検定基準を導出している[6]。そこでは、画像上のエッジ(特徴点)への直線当てはめに関する信頼性を定量的に評価し、それに基づいてもっとも信頼性の高い消失点を検出する手法を提案している。しかし、この方法は最適化処理を2段階に分けて行うために、画像の特徴点を直線上のあるべき集合としてクラスタリングする前処理の結果が、消失点の検

出結果に大きく影響するという問題もある。消失点を構成する直線群を検出する問題に対しては、1段階の最適化問題として統合し、クラスタリングも含めた処理全体の同時推定を行うことが自然であると考える。

特徴点群の各直線へのクラスタリングおよび直線検出に関する方法として、上記の二つの考え方を併用し、パラメータ空間内でその空間における特徴点群の散らばりを具合を考慮してクラスタリングした後、この結果に基づき画像平面上で最小自乗規範によって直線パラメータを定めるものが知られている[7]。しかし、この方法においても処理が2段階になっており、またクラスタリングの際の評価基準や消失点検出に及ぼす影響が明確となっていない。クラスタリングと複数直線の検出を画像平面上で同時に行なう方法として、Sekitaは特徴点群に正規混合分布モデルを仮定し、観測雑音に基づく最尤推定手法をEMアルゴリズムを用いて構成した[8]。しかし、観測雑音を1次元に制限している。


一方、従来の消失線推定問題においても直線がクラスタリングされているとして議論されており、上記と同様の問題が残されている。

本稿では上記のSekitaの考え方と同様に、画像平面上での観測雑音に基づき、特徴点群のクラスタリングと直線検出を正規混合分布モデルを用いた最尤推定として同時に実現する手法を提案する。その際、消失点・消失線を陽に含んだ形で直線群を表現することにより、これらも同時に検出でき、処理全体の最適化が可能となる。さらに筆者らは、画像の平面性を考慮して、観測雑音を2次元正規分布に従うものとして問題の定式化を行う。この際、計算量が問題となるために、1次元の観測雑音に対するものと同程度となるような工夫についても述べる。最後に提案手法が正しく動作することをシミュレーション実験によって示す。


2 消失線・消失点と直線の同時推定

2.1 正規混合分布モデルに基づく定式化

前章で述べたような観点から、直線を検出した後消失点を推定するのではなく、これらの特徴点群



(a) 消失点を持つ直線群



(b) 消失点・消失線を持つ直線群

図 1: 消失点・消失線と直線群の関係

の各直線へのクラスタリングと併せて同時に行なうことを考える。

図 1 のように、画像中での消失点位置を $\mathbf{v} = (v_x, v_y)$ とし、それを構成する直線番号 j 上の特徴点 $i: i = 1, 2, \dots, n$ の真の位置 $\bar{\mathbf{r}}(i)$ を以下のように表すものとする。

$$\bar{\mathbf{r}}(i) = c_{(i)} \mathbf{m}_{(j)} + \mathbf{v}, \quad (1)$$

$$\begin{aligned} \mathbf{m}_{(j)} &= (-\sin \phi_{(j)} \cos \phi_{(j)})^T, \\ \mathbf{n}_{(j)} &= (\cos \phi_{(j)} \sin \phi_{(j)})^T. \end{aligned} \quad (2)$$

このとき特徴点の観測量が $\mathbf{r}(i)$ であったとすると、特徴点 i の直線番号 j の要素であるときの条件付確率密度関数は以下の式で表される。

$$\begin{aligned} p(\mathbf{r}(i)|j; \mathbf{v}, c_{(i)}, \phi_{(j)}, \sigma_{(j)}^2) &= \frac{1}{2\pi\sigma_{(j)}^2 \det |V_{(j)}|} \\ &\times \exp \left[-\frac{1}{2\sigma_{(j)}^2} (\mathbf{r}(i) - \bar{\mathbf{r}}(i))^T V_{(j)}^{-1} (\mathbf{r}(i) - \bar{\mathbf{r}}(i)) \right]. \end{aligned} \quad (3)$$

ここで $\sigma_{(j)}^2$ はノイズ分散であり、 $V_{(j)}$ は正規化された分散共分散行列である。また、式 (3) は以下と等価である [9]。

$$\begin{aligned} p(\mathbf{r}(i)|j; \mathbf{v}, c_{(i)}, \phi_{(j)}, \sigma_{(j)}^2) &= \frac{1}{2\pi\sigma_{(j)}^2 \det |V_{(j)}|} \exp \left[-\frac{1}{2\sigma_{(j)}^2} \right. \\ &\times \left. \left(\alpha_{vp(i,j)}^2 \mathbf{n}_{(j)}^T V_{(j)} \mathbf{n}_{(j)} + \beta_{vp(i,j)}^2 \mathbf{m}_{(j)}^T V_{(j)}^{-1} \mathbf{m}_{(j)} \right) \right]. \end{aligned} \quad (4)$$

ただし、

$$\alpha_{vp(i,j)} = \frac{\mathbf{n}_{(j)}^T (\mathbf{r}(i) - \mathbf{v})}{\mathbf{n}_{(j)}^T V_{(j)} \mathbf{n}_{(j)}}, \quad (5)$$

$$\beta_{vp(i,j)} = c_{(i)} - \frac{(\mathbf{r}(i) - \mathbf{v})^T V_{(j)}^{-1} \mathbf{m}_{(j)}}{\mathbf{m}_{(j)}^T V_{(j)}^{-1} \mathbf{m}_{(j)}}. \quad (6)$$

次に、複数の直線を考える。特徴点を各直線における正規混合分布モデルとみなし、 $j: j = 1, \dots, m$ 番目の直線の混合比を $q_{(j)}$ とすると、以下の式で確率密度関数を与えることができる。

$$\begin{aligned} p(\mathbf{r}(i); \mathbf{v}, c_{(i)}, \phi_{(j)}, \sigma_{(j)}^2) &= \sum_{j=1}^m q_{(j)} p(\mathbf{r}(i)|j; \mathbf{v}, c_{(i)}, \phi_{(j)}, \sigma_{(j)}^2). \end{aligned} \quad (7)$$

観測点 $i: i = 1, \dots, n$ における同時確率密度関数から、パラメータ $\Theta: \Theta = \{\mathbf{v}, c_{(i)}, \phi_{(j)}, \sigma_{(j)}^2\}, i = 1, 2, \dots, n, j = 1, 2, \dots, m$ に関する尤度関数 $L(\Theta)$ は、 $\theta_{(j)} = \{\phi_{(j)}, \sigma_{(j)}^2\}$ とすれば、

$$\begin{aligned} L(\Theta; \mathbf{r}(i)) &= \prod_{i=1}^n p(\mathbf{r}(i); \mathbf{v}, c_{(i)}, \theta_{(j)}) \\ &= \prod_{i=1}^n \sum_{j=1}^m q_{(j)} p(\mathbf{r}(i)|j; \mathbf{v}, c_{(i)}, \theta_{(j)}) \end{aligned} \quad (8)$$

となり、パラメータ推定値 $\hat{\Theta}$ は次式で算出される。

$$\begin{aligned} \hat{\Theta} &= \arg [\max L(\Theta; \mathbf{r}(i))] \\ &= \arg [\max \ln L(\Theta; \mathbf{r}(i))]. \end{aligned} \quad (9)$$

消失線から考えた場合も同様で、各直線はいずれかの消失点を通ることとし、さらにその消失点自体も以下に示す消失線上に存在しているものとする。消失点 k に関する拘束式として次式を用いる。

$$\mathbf{v}_{(k)} = a_{(k)}\mathbf{m}_v + b\mathbf{n}_v, \quad (10)$$

$$\begin{aligned} \mathbf{m}_v &= (-\sin \phi_v \cos \phi_v)^T, \\ \mathbf{n}_v &= (\cos \phi_v \sin \phi_v)^T. \end{aligned} \quad (11)$$

このとき消失点 $k: k = 1, 2, \dots, m_p$ をなす直線 j を直線番号 $s = s_{(j,k)}$ という通し番号で表すものとする、観測点 i が直線 s の要素であるとしたときの条件付確率密度関数は式 (4) に代わり、以下の式で与えられる。

$$\begin{aligned} p(\mathbf{r}_{(i)}|s; a_{(k)}, b, \phi_v, c_{(i)}, \theta_{(s)}) \\ = \frac{1}{2\pi\sigma_{(s)}^2 \det |V_{(s)}|} \exp \left[-\frac{1}{2\sigma_{(s)}^2} \right. \\ \left. \times \left(\alpha_{vl(i,s)}^2 \mathbf{n}_{(s)}^T V_{(s)} \mathbf{n}_{(s)} + \beta_{vl(i,s)}^2 \mathbf{m}_{(s)}^T V_{(s)}^{-1} \mathbf{m}_{(s)} \right) \right]. \end{aligned} \quad (12)$$

ただし、

$$\alpha_{vl(i,s)} = \frac{\mathbf{n}_{(s)}^T (\mathbf{r}_{(i)} - a_{(k)}\mathbf{m}_v - b\mathbf{n}_v)}{\mathbf{n}_{(s)}^T V_{(s)} \mathbf{n}_{(s)}}, \quad (13)$$

$$\begin{aligned} \beta_{vl(i,s)} \\ = c_{(i)} - \frac{(\mathbf{r}_{(i)} - a_{(k)}\mathbf{m}_v - b\mathbf{n}_v)^T V_{(s)}^{-1} \mathbf{m}_{(s)}}{\mathbf{m}_{(s)}^T V_{(s)}^{-1} \mathbf{m}_{(s)}}. \end{aligned} \quad (14)$$

ここで同様に正規混合分布モデルを考え、パラメータを $\Theta: \Theta = \{a_{(k)}, b, \phi_v, c_{(i)}, \theta_{(s)}\}$, $s = s_{(j,k)}$, $i = 1, 2, \dots, n$, $j = 1, 2, \dots, l_{(k)}$, $k = 1, 2, \dots, m_p$, $s = 1, 2, \dots, m$ とすると、最大化すべき尤度関数は、式 (8) と同じ形で定義される。以降の議論ではこれらを統一的に扱うこととする。なお、以上の議論では直線の数や消失点の数は既知とする。もし、これらをデータから決定する必要があるれば、これは AIC, MDL などの統計量基準を用いることで可能である。

2.2 ノイズ特性

まずノイズ分散 $\sigma_{(s)}^2$ は各直線で等しいとし、 $\sigma_{(s)}^2 = \sigma^2$ とする。2次元画像を考えた場合、観測ノイズは2次元等方的正規分布に従うとすることが自然である。すなわち $V = I$ となる。このとき、式 (12) は以下ようになる

$$\begin{aligned} p(\mathbf{r}_{(i)}|s; \Theta) \\ = \frac{1}{2\pi\sigma^2} \exp \left[-\frac{1}{2\sigma^2} \left(\alpha'_{(i,s)}{}^2 + \beta'_{(i,s)}{}^2 \right) \right]. \end{aligned} \quad (15)$$

ただし、

$$\alpha'_{(i,s)} = \mathbf{n}_{(s)}^T (\mathbf{r}_{(i)} - \mathbf{v}_{(k)}), \quad (16)$$

$$\beta'_{(i,s)} = c_{(i)} - \mathbf{m}_{(s)}^T (\mathbf{r}_{(i)} - \mathbf{v}_{(k)}). \quad (17)$$

3 計算方法

3.1 EM アルゴリズムの適用

前章の式 (9) を、解析的に解くことは困難である。これらの問題に対してよく用いられる計算法としては、極値への収束が保証されている EM アルゴリズムがある [10]。正規混合分布モデルを仮定する本稿の場合、 $z_{(i)}$ を観測点 i の ownership としたとき、完全データを $\{\mathbf{r}, \mathbf{z}\}$ 、不完全データを $\{\mathbf{r}\}$ とし、以下のステップを反復させることで解くことができる。

3.1.1 E ステップ

観測点 i の ownership を $z_{(i)}$ とし、ownership function $\delta'_{z_{(i)},s}$ を以下のように定義する。

$$\begin{aligned} \delta'_{z_{(i)},s} &= p(s|\mathbf{r}_{(i)}; \hat{\Theta}^{(t)}) \\ &= \frac{\hat{q}_{(s)} \frac{1}{2\pi\sigma^2} \exp \left(-\frac{\hat{\omega}_{(i,s)}}{2\sigma^2} \right)}{\sum_{s'} \left\{ \hat{q}_{s'} \frac{1}{2\pi\sigma^2} \exp \left(-\frac{\hat{\omega}_{(i,s')}}{2\sigma^2} \right) \right\}} \\ &= \frac{\hat{q}_{(s)} \exp \left(-\frac{\hat{\omega}_{(i,s)}}{2\sigma^2} \right)}{\sum_{s'} \left\{ \hat{q}_{s'} \exp \left(-\frac{\hat{\omega}_{(i,s')}}{2\sigma^2} \right) \right\}}, \end{aligned} \quad (18)$$

$$\begin{aligned} \hat{\omega}_{(i,s)} &= \left\{ \hat{\mathbf{n}}_{(s)}^T (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)}) \right\}^2 \\ &\quad + \left\{ \hat{c}_{(i)} - \hat{\mathbf{m}}_{(s)}^T (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)}) \right\}^2. \end{aligned} \quad (19)$$

この ownership function を用いて書き直すと、対数尤度の期待値は以下の式になる。

$$Q(\Phi; \hat{\Phi}^{(t)}) = \sum_{i=1}^n \sum_{s=0}^m \delta'_{z(i),s} \left(\ln q_{(s)} - \ln 2\pi\sigma^2 - \frac{\hat{\omega}_{(i,s)}}{2\sigma^2} \right). \quad (20)$$

上式 (20) を最大にするときの $c_{(i)}$ は式を偏微分し、ゼロとおいた結果から、以下のように表すことができる。

$$\hat{c}_{(i)} = \sum_{s=1}^m \delta'_{z(i),s} \hat{\mathbf{m}}_{(s)}^T (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)}). \quad (21)$$

したがって、式 (20) は以下のようになる。

$$\begin{aligned} Q(\Phi; \hat{\Phi}^{(t)}) &= \sum_{i=1}^n \sum_{s=1}^m \delta'_{z(i),s} \left(\ln \hat{q}_{(s)} - \ln 2\pi\sigma^2 \right) \\ &\quad - \frac{1}{2\sigma^2} \sum_{i=1}^n \sum_{s=1}^m \left\{ \delta'_{z(i),s} (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)})^T (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)}) \right\} \\ &\quad + \frac{1}{2\sigma^2} \sum_{i=1}^n \left\{ \sum_{s=1}^m \delta'_{z(i),s} \hat{\mathbf{m}}_{(s)}^T (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)}) \right\}^2. \quad (22) \end{aligned}$$

3.1.2 M ステップ

式 (22) の対数尤度の期待値に対して、制約条件 $\sum_{s=1}^m \hat{q}_{(s)} = 1$ をつけた以下の修正尤度関数に対する最大化をはかる。

$$\begin{aligned} Q^*(\Phi; \hat{\Phi}^{(t)}) &= Q(\Phi; \hat{\Phi}^{(t)}) + \lambda \left(\sum_{s=1}^m \hat{q}_{(s)} - 1 \right). \quad (23) \end{aligned}$$

ここで λ は Lagrange 未定乗数である。通常はすべてのパラメータを平等に扱い Newton 法等によって最大化を行なうが、本稿では次に示す工夫を行なう。

3.2 M ステップの改良

前節のとおり式 (23) を最大化し、 $\hat{\Phi}$ の更新を行なう。本問題の最大化の場合、Newton 法などの反復手法を用いると、2 つの変数 $\hat{\mathbf{v}}, \hat{\theta}_s$ に関して同時収束させることになる。しかしこれらのパラメータは、値域が異なり周期関数も含まれていることから、反復手法における演算結果が本来の対数尤度の期待値の最大化とは一致しないことがある。さらに本問題

では個々のクラスタで考えた場合、直線の尤度は低下することもあり、特に $\hat{\mathbf{v}}$ が線分内に存在するような場合、パラメータ $\hat{\theta}_s$ がすべてのクラスタに関係するパラメータ $\hat{\mathbf{v}}$ の更新に対して敏感に作用し、より不安定になる。上記のことから、本問題での更新では、でき得る限り解析に解くことが要求される。したがって本稿では各パラメータをレベル別に独立に考え、一般化 EM アルゴリズムの枠組で不完全データの尤度を高めてゆくことを考える。

EM アルゴリズムは以下の形で、その収束が保証されている。各反復において

$$Q(\Theta^{(k+1)} | \hat{\Phi}^{(k)}) \geq Q(\Theta^{(k)} | \hat{\Phi}^{(k)})$$

ならば、

$$L(\Theta^{(k+1)}; \mathbf{r}) \geq L(\Theta^{(k)}; \mathbf{r}).$$

したがって、上式を満たすように M ステップでパラメータの更新を行なうことにより、不完全データの尤度の最大化が可能であり、これが一般化 EM アルゴリズムと呼ばれる。

具体的には消失線を含む場合、更新が他のパラメータの更新に影響を及ぼさない $\hat{q}_{(s)}, \sigma^2$ に対しては毎回の M ステップで従来どおり最大化が可能である。しかしながら $\hat{b}, \hat{\alpha}_{(k)}, \hat{\phi}_v, \hat{\phi}_{(s)}$ の各パラメータについては、各パラメータを独立とみなし、一度の M ステップでいずれかのパラメータに関してのみ最大化を行なうこととする。つまり 4 回の反復ですべてのパラメータを更新することになる。消失点の場合も同様に、 $\hat{\mathbf{v}}, \hat{\phi}_{(j)}$ の 2 回の反復での更新を考える。1 回での尤度の向上は小さくなるものの、特にこのときは M ステップの中での反復演算が不要となる。

3.3 EM アルゴリズムの変形

3.3.1 binary ownership の適用

前節までは、攪乱母数を含む正規混合分布モデルに基づき問題を定式化してきた。攪乱母数とは、モデルを構成するためには必要な母数ではあるものの、その値について推測することには関心がない母数のことを指し、本問題では式 (1) の $c_{(i)}$ が相当する。この攪乱母数の影響で M ステップが複雑になる。そこで計算量の低減を目的とし、binary ownership

function[11] の考え方を適用することで、攪乱母数の除去を検討する。

binary ownership function の適用とは、E ステップで求めた ownership function を M ステップで以下のように変更して計算することに相当する。

$$\delta''_{z(i),s} = \begin{cases} 1 & s = s'. \\ 0 & \text{otherwise.} \end{cases} \quad (24)$$

ただし

$$s' = \arg \left[\max_s \delta'_{z(i),s} \right]. \quad (25)$$

上式を式 (18) の代わりに用いると消失点のみの場合、消失線まで考慮した場合はそれぞれ以下のように M ステップでの更新が容易となる。

消失点のみの場合

$$\hat{q}(j) = \frac{1}{n} \sum_{i=1}^n \delta''_{z(i),j}, \quad (26)$$

$$\hat{\sigma}^2 = \frac{1}{2n} \sum_{i=1}^n \sum_{j=1}^m \delta''_{z(i),j} \{ \mathbf{n}_{(j)}(\mathbf{r}_{(i)} - \hat{\mathbf{v}})^T \}^2, \quad (27)$$

$$\mathbf{v} = \left(\sum_{i=1}^n \sum_{j=1}^m \hat{N}_{(i,j)} \right)^{-1} \left(\sum_{i=1}^n \sum_{j=1}^m \hat{N}_{(i,j)} \mathbf{r}_{(i)} \right), \quad (28)$$

$$\hat{\mathbf{n}}_{(j)}^T \left\{ \sum_{i=1}^n \delta''_{z(i),j} (\mathbf{r}_{(i)} - \hat{\mathbf{v}})(\mathbf{r}_{(i)} - \hat{\mathbf{v}})^T \right\} \hat{\mathbf{m}}_{(j)} = 0. \quad (29)$$

ただし、

$$\hat{N}_{(i,j)} = \delta''_{z(i),j} \hat{\mathbf{n}}_{(j)} \hat{\mathbf{n}}_{(j)}^T.$$

前節の反復法を用いると、M ステップでは式 (26),(27),(28) と式 (26),(27),(29) の更新を交互に行なってゆけば良い。ただし、式 (29) は 2 つの固有値の固有ベクトルが $\hat{\mathbf{n}}_{(j)}$, $\hat{\mathbf{m}}_{(j)}$ となる。また、計算量に関しては表記上は $n \times m$ のオーダーであるが、 n のオーダーに落ちている。

消失線を考慮した場合

$$\hat{q}(s) = \frac{1}{n} \sum_{i=1}^n \delta''_{z(i),s}, \quad (30)$$

$$\hat{\sigma}^2 = \frac{1}{2n} \sum_{i=1}^n \sum_{s=1}^m \delta''_{z(i),s} \left\{ \hat{\mathbf{n}}_{(s)}^T (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)}) \right\}^2, \quad (31)$$

$$\hat{b} = \left(\sum_{i=1}^n \sum_{s=1}^m \hat{N}_n^2(s) \right)^{-1} \times \left\{ \sum_{i=1}^n \sum_{s=1}^m \hat{N}_n (\mathbf{r}_{(i)} - \hat{a}_{(k)} \hat{\mathbf{m}}_v) \right\}, \quad (32)$$

$$\hat{a}_{(k)} = \left(\sum_{i=1}^n \sum_{k=1}^{m_p} \hat{N}_m^2(s) \right)^{-1} \times \left\{ \sum_{i=1}^n \sum_{k=1}^{m_p} \hat{N}_m (\mathbf{r}_{(i)} - \hat{b} \hat{\mathbf{n}}_v) \right\}, \quad (33)$$

$$\sum_{i=1}^n \sum_{s=1}^m \delta''_{z(i),s} \hat{\mathbf{n}}_{(s)}^T (\hat{a}_{(k)} \hat{\mathbf{n}}_v - \hat{b} \hat{\mathbf{m}}_v) \times \hat{\mathbf{n}}_{(s)}^T (\mathbf{r}_{(i)} - \hat{a}_{(k)} \hat{\mathbf{m}}_v - \hat{b} \hat{\mathbf{n}}_v) = 0, \quad (34)$$

$$\hat{\mathbf{n}}_{(s)}^T \left\{ \sum_{i=1}^n \delta''_{z(i),s} (\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)})(\mathbf{r}_{(i)} - \hat{\mathbf{v}}_{(k)})^T \right\} \hat{\mathbf{m}}_{(s)} = 0. \quad (35)$$

ただし、

$$\hat{N}_n(s) = \hat{\mathbf{n}}_{(s)}^T \hat{\mathbf{n}}_v,$$

$$\hat{N}_m(s) = \hat{\mathbf{n}}_{(s)}^T \hat{\mathbf{m}}_v.$$

これも消失点の場合と同様であり、式 (30),(31) は毎回の M ステップで更新し、式 (32),(33),(34),(35) に関しては、1 回の反復においていずれか 1 つの式に対して解くこととする。ただし式 (34) は反復解法によって $\hat{\mathbf{m}}_v$, $\hat{\mathbf{n}}_v$ を算出し、式 (35) は消失点同様その固有ベクトルから $\hat{\mathbf{m}}_{(s)}$, $\hat{\mathbf{n}}_{(s)}$ を算出する。

4 シミュレーション実験

図 2(a) は画像サイズ (320 × 240) 画素、直線本数 $m = 6$ 本、直線長 100 画素、直線幅 1.0 画素、消失点位置 $\mathbf{v} = (160, 50)$ のテスト画像である。また、

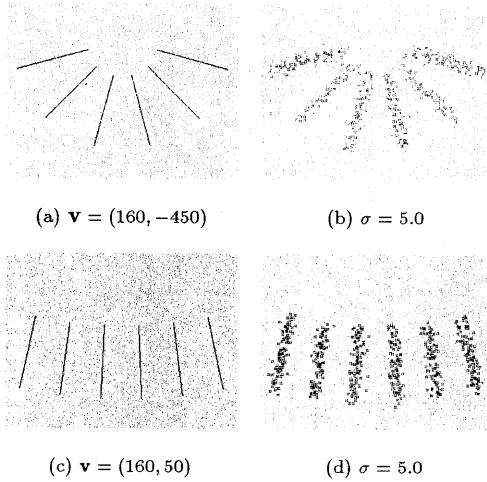


図 2: シミュレーション実験テスト画像

図 2(c)は消失点位置を $\mathbf{v} = (160, -450)$ とした画像である。図 2(b), 2(d)は図 2(a), 2(c)の画像に対して各々 $\sigma = 5.0$ のノイズを付加した画像である。また座標原点は画像の左上端とした。なお表示の都合上、特徴点を拡大して表示している。

図 3は図 2(b)のテスト画像に対する提案手法 (binary ownership) での収束過程であり、図 2(d)に対しても同様に安定な収束が見られた。このようにクラスタリングおよびそれに基づく最尤推定とも正しい動作をしていることがわかる。ノイズの大きさおよび初期値を実際的な範囲で変化させても同様の安定性が確認できた。

図 4は、normal ownership と binary ownership による 1000 回の試行による消失点推定値を示したものである。図からわかるように binary ownership の使用による推定量の明らかな偏りは見られず、normal ownership の場合と同等の推定精度となっていることが確認できる。

また、図 5は同様に行なった消失線の検出結果である。3 点の消失点を持つとして、 $\sigma = 3.0$ のノイズを付加して実験を行なった結果であり、本手法での有効性が確認できる。




図 3: 提案手法の収束過程

5 まとめ

本稿では特徴点群に対して正規混合分布モデルを仮定し、交点が消失点であるという拘束条件の下での最尤推定として、直線のクラスタリングおよび消失点・消失線と直線のパラメータ推定を EM アルゴリズムを用いることで同時に実現した。また、従来 1 次元のノイズモデルに対してのみ適用されていた EM アルゴリズムをより一般的な 2 次元のノイズモデルの下での最適化として扱った。さらに計算量、収束性についても検討し、適切な工夫を施した。

本研究での対象は直線当てはめというもっとも基礎的な問題であり、従来の正規混合分布モデルに基づくクラスタリングを含んだ最尤推定問題の一般的な形での拡張という意味も含んでいる。従来の多くの研究では、各クラスタの混合比および各クラスタを規定する個別の共通母数 (本稿での直線パラメータ) のみが未知パラメータとして存在していた。これに対し本研究では各クラスタに攪乱母数が含まれ、かつすべてのクラスタに共通に関係する母数も存在する問題を扱っており、この考え方およびアルゴリズムは、コンピュータビジョンにおける他の多くの問題への適用が可能であると考えられる。

謝辞

本研究を行なうにあたり、正規混合分布モデルに関する有用な助言を頂いた電子技術総合研究所 赤穂昭太郎氏、計算機システムの面で研究を支援して

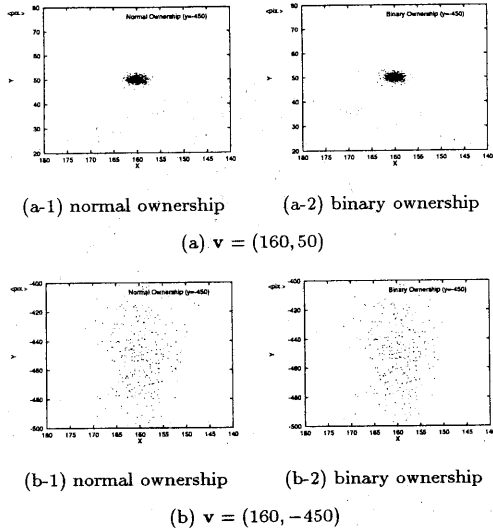


図 4: ownership function の違いによる消失点検出位置の比較 ($\sigma = 5.0$)

頂いた日本サンマイクロシステムズ(株)ならびに職業能力開発大学校 寺町康昌教授に感謝申し上げます。

参考文献

- [1] 江尻正員, 太田友一, 池内克史, “マシンビジョン,” 昭晃堂, 1990.
- [2] J.R.Kender, “Shape from texture,” Proc. 6th IJCAI, pp.475-480, 1979.
- [3] 松島緑朗, 恩田邦夫, 青木由直, “Hough 変換の性質を利用した無限遠点抽出法,” 信学論 (D), Vol.J70-D, No.5, pp.1051-1052, 1987.
- [4] H. Nakatani and T. Kitahashi, “Extraction of vanishing point and its application to scene analysis based on image sequence,” Proc. 5th ICPR, pp.370-372, 1980.
- [5] 皆川 明洋, 後藤 敏行, “扇型受容野特性を持つオペレータを用いた消失点検出法,” 信学論 (D-II), Vol.J80-D II, No.6, pp.1415-1422, 1997.




図 5: 消失線を含む場合の収束過程

- [6] 金谷 健一, “画像の3次元解釈の統計的信頼性,” 情処論, Vol.34, No.10, pp.2062-2070, 1993.
- [7] R.J.Schalkoff, “Pattern Recognition: Statistical, Structural and New Approaches,” Wiley, 1992.
- [8] I.Sekita, “On Fitting Several Lines Using the EM Algorithm,” CVVC'94, pp.107-109, 1994.
- [9] N.Tagwa, T.Suzuki and T.Moriya, “Cost-Effective Unbiased Straight-Line Fitting to Multi-Viewpoint Range Data,” IEICE trans., Vol.E80-A, No.3, pp.472-479, 1997.
- [10] A.P.Dempster, N.M.Laird and D.B.Rubin, “Maximum likelihood from incomplete data via the EM algorithm,” Journal of Royal Statistical Society B, Vol.39, pp.1-38, 1977.
- [11] G.J.McLachlan and K.E.Basford, “Mixture Models: Inference and Applications to Clustering,” Dekker, 1988.