

# カテゴリ毎の変形特性を組み込んだ弾性マッチングによる 手書き文字認識

内田 誠一<sup>†</sup> 迫江 博昭<sup>†</sup>

<sup>†</sup>九州大学大学院システム情報科学研究院  
〒812-8581 福岡市東区箱崎 6-10-1  
E-mail: †{uchida,sakoe}@is.kyushu-u.ac.jp

あらまし 手書き文字の認識において、手書き変形を補償するための手法として、弾性マッチングの利用が検討されている。従来法がすべてのカテゴリに共通の変形特性を仮定していたのに対し、本報告では各カテゴリに固有の変形特性を組み込んだ手法を提案する。具体的には、各カテゴリの任意の変形をそのカテゴリに固有ないくつかの変形の加重和で表現する。その結果、各カテゴリ内に生じる変形だけが適切に補償されることになり、過変形の抑制および計算効率の向上といった効果が得られる。本手法は、一種の非線形最適化問題として定式化される。本報告ではその近似解法についても述べる。

キーワード 弾性マッチング, 手書き文字認識, 固有変形, 最適化

## Handwritten character recognition using elastic matching based on a category-dependent deformation model

Seiichi UCHIDA<sup>†</sup> and Hiroaki SAKOE<sup>†</sup>

<sup>†</sup> Faculty of Information Science and Electrical Engineering, Kyushu University  
Hakozaki 6-10-1, Higashi-ku, Fukuoka-shi, 812-8581 Japan  
E-mail: †{uchida,sakoe}@is.kyushu-u.ac.jp

**Abstract** For handwritten character recognition, a new elastic image matching (EM) technique based on a category-dependent deformation model is proposed. In the deformation model, any deformation of a category is described by a linear combination of eigen-deformations, which are intrinsic deformation directions of the category. The eigen-deformations can be estimated statistically from the actual deformations of handwritten characters. Experimental results show that the EM present technique can attain higher recognition rates than conventional EM techniques based on category-independent deformation models. The results also show the superiority of the present technique over those conventional EM techniques in computational efficiency.

**Key words** elastic matching, handwritten character recognition, eigen-deformations, optimization

### 1. ま え が き

手書き文字の認識において、弾性マッチング法の利用が検討されている。弾性マッチングの目的は、2つの画像パターンの最適な非線形整合を図ることにある。具体的には、何らかのモデルに従って一方のパターンを非線形に変形させ、もう一方のパターンに近づける処理を行う。最適整合の下での2パターン間の距離は、変形補償後の2画像間の距離であり、変形不変量となる。従ってそれを識別関数として用いることで、手書き変形に対して頑強な識別系を実現できる。

弾性マッチング法によって補償される変形の範囲は、その

弾性マッチング法が基づく変形モデルにより規定される。従って、変形モデルの設計は重要な検討事項である。従来の弾性マッチングにおいては、カテゴリ非依存の変形モデル、すなわちすべてのカテゴリで同一の変形モデルが用いられてきた。これは、すべてのカテゴリが同一の変形特性を持つという仮定に基づいている。ところが、実際の文字変形を見ると、この仮定は必ずしも妥当ではないことがわかる。例えば、図1に示すように、アルファベット“M”の2本の縦ストロークはしばしば互いに傾いて近づきあうが、こうした変形は“H”には見られない。この例からも予想されるように、カテゴリ非依存の変形モデルと用いると、ある文字種においては過変形が起り、逆に

ある文字種では変形補償能力の不足が生じる．

本報告では，カテゴリ依存の変形モデルに基づく弾性マッチング法を提案する．このモデルにおいては，各カテゴリに生じる任意の変形を，そのカテゴリに生じる代表的な幾つかの変形（以下，固有変形と呼ぶ）の重み付きの線形和によって表現する．その結果，カテゴリ内に生じる変形だけが適切に補償され，前述の問題を回避できると考えられる．また，過変形となるような不必要な変形は補償範囲，すなわち弾性マッチングの解空間から除外されるので，計算効率の向上も見込める．なお，固有変形は実際の手書き文字データから統計的に推定される．

この変形モデルの下での 2 画像パターンの弾性マッチング問題は，各固有変形の重み係数の最適化問題として見直し良く定式化される．しかしながら，本問題を直接解くことは困難である．これは，重み係数，すなわち制御変数が非線形 2 次元-1 次元関数である画像パターンの内部に含まれ，その結果として本問題は非線形最適化問題となるためである．そこで，本報告では，Simard ら [1]～[3] による tangent distance 法 (TD) の考えを援用した線形近似解法を提案する．この線形近似の結果，あるパターンの任意の変形画像は，幾つかの画像の重み付き線形和で表現されることになる．この各画像の重みの線形最適化問題を解くことで 2 パターンの準最適整合が解析的に得られる．

パターンに固有な変形方向を推定し利用するという考え方は，Cootes ら [4] による Point Distribution Models (PDM) に見ることができる．筆者らは，この PDM を 2 次元的に拡張するなどの幾つかの変更を加えたものを固有変形と呼び，文字認識に利用した [5], [6]．ただし文献 [5], [6] においては，従来の弾性マッチング（すなわちカテゴリ非依存の変形モデルに基づく弾性マッチング）の事後評価において固有変形を利用するに留まっていた．こうした間接的な利用形態に対し，本手法は弾性マッチングに直接固有変形を組み込んだものであり，より自然な利用形態であると言える．

## 2. カテゴリ依存の変形モデルに基づく弾性マッチング法

### 2.1 定式化

弾性マッチングにはパラメトリックな変形モデルに基づくものとノンパラメトリックな変形モデルに基づくものに大別される．前者は画素の変位を幾つかのパラメータからなる関数で表現し，そのパラメータを制御変数として最適整合を図る．後者は各画素の変位を直接制御変数として扱い，最適化を図る．本報告ではこのうち前者を扱う．

パラメトリックな変形モデルに基づく 2 画像パターン間の弾性マッチングは，一般に次の最適化問題として定式化される．

$$d(\mathbf{P}_c, \mathbf{E}) = \min_{\alpha} \|s(\alpha, \mathbf{P}_c) - \mathbf{E}\| \quad (1)$$

ここで  $\mathbf{P}_c = \{P_c(x, y)\}$  はカテゴリ  $c$  の標準パターンであり， $\mathbf{E} = \{E(x, y)\}$  は入力パターンである．また， $x, y = 1, 2, \dots, I$  は座標値である．関数  $s(\alpha, \mathbf{P}_c)$  は， $M$  個のパラメータ  $\alpha = \{\alpha_m | m = 1, \dots, M\}$  によって制御される変形モデルであり， $\mathbf{P}_c$  の変形画像である．弾性マッチングの目的はパラメータ  $\alpha$



図 1 各カテゴリに固有の変形方向が存在することの例証．文字 “M” の 2 本の縦ストロークはしばしば互いに近づくよう傾くが，同様の変形が “H” の縦ストロークに生じることはほとんどない．




図 2 カテゴリ “A” の標準パターン  $\mathbf{P}_c$  (上段)，同カテゴリの第 1, 2, 3 固有変形  $\mathbf{u}_{c,1}$ ,  $\mathbf{u}_{c,2}$ ,  $\mathbf{u}_{c,3}$  (中段)，および各固有変形により変形された標準パターン  $\{P_c(x + X_{c,m}(x, y), y + Y_{c,m}(x, y))\}$  (下段)．

を制御して式 (1) の最小化を図ることであり，言い換えると  $\alpha$  を制御して  $s(\alpha, \mathbf{P}_c)$  を  $\mathbf{E}$  に最も近づけることである．この最適化の結果得られる 2 パターン間の距離  $d(\mathbf{P}_c, \mathbf{E})$  は，入力パターン  $\mathbf{E}$  に生じた手書き変形に関して不変量となる．よってそれを識別関数値とし用いることで手書き変形に致して頑強な認識系を構築できる．

本報告では，次式のカテゴリ依存な変形モデルを用いた弾性マッチング法を提案する．

$$s(\alpha, P_c(x, y)) = P_c \left( x + \sum_{m=1}^M \alpha_m X_{c,m}(x, y), y + \sum_{m=1}^M \alpha_m Y_{c,m}(x, y) \right) \quad (2)$$

ここで  $(X_{c,m}(x, y), Y_{c,m}(x, y))$  はカテゴリ  $c$  の第  $m$  固有変形  $\mathbf{u}_{c,m}$  による画素  $(x, y)$  の変位を示している．この固有変形  $\mathbf{u}_{c,m}$  は，すべての画素  $(x, y)$  の変位を列挙した  $2I^2$  次元ベクトルであり，カテゴリ  $c$  の  $m$  番目に代表的な変形方向を表現している．このように，本変形モデル (2) においては，カテゴリ  $c$  に生じる任意の変形は， $M$  個の固有変形の重み付き線形和で表現される．2.4 で述べるように，固有変形は実際の手書き文字の集合から統計的に推定される．図 2 にカテゴリ “A” の第 1～3 固有変形を示す．この図より “A” において最も代表的な変形，すなわち最頻の変形 ( $\mathbf{u}_{c,1}$ ) は，全体的な傾斜変形であることが




図3 変形モデル  $s(\alpha, \mathbf{P})$  の成す多様体, その接平面  $t(\alpha, \mathbf{P})$ , および  $\mathbf{E}$  と接平面との距離  $d_{TD}(\mathbf{P}, \mathbf{E})$ .




図4 濃淡画像表現したカテゴリ “A” の接ベクトル  $\phi_1, \phi_2, \phi_3$ . (画素値は 0 から 255 の範囲に正規化してある.)

わかる.

式 (2) のカテゴリ依存の変形モデルを用いることで, (i) 各カテゴリに生じる変形だけを効率的に補償でき, 同時に (ii) 各カテゴリには生じない変形を補償対象範囲から根本的に排除できる, という2つの効果が見込める. このうち前者 (i) は, そのカテゴリに生じる変形全体をコンパクトに, すなわち少ないパラメータ数で表現できていると見ることもできる. よって従来のカテゴリ非依存の変形モデルを用いて同様に変形全体を表現しようとする場合に比べ, パラメータ数が少なくて済むと考えられ, 従って計算効率の向上効果を期待できる. 一方後者 (ii) は, 従来の弾性マッチングにおいて問題となっていた異なるカテゴリの2パターンを合わせ過ぎてしまうとい問題, いわゆる過変形の問題を, 本モデルを用いることで回避できることを表している.

## 2.2 線形近似に基づく解法

変形モデル (2) に基づく式 (1) の最適化問題は, 最適化すべき制御パラメータ  $\alpha$  が 2D-1D 非線形関数  $\mathbf{P}_c$  に内包されているために, 直接は解けない. そこで, この非線形最適化問題を, Simard らによる tangent distance (TD) [1]~[3] の考え方を援用した線形近似を用いて解くことにする. 後述するように, この近似解法を式 (1) の最適化に用いることで, 次の2つのメリットが得られる.

- $\alpha$  の近似解 (準最適解) が解析的に与えられる. 従って解の収束性等に関する議論が不要である.
- 任意の変形画像が  $M$  個の画像の重み付き線形和により表現されるという, 再び簡潔で見通しのよい形式が得られる.

なお近似解法に関する以下の説明では, 混乱のない限りカテゴリを表す添字  $c$  を省略する.

この近似解法では, なんらかの変形モデル  $s(\alpha, \mathbf{P})$  に従って変形された標準パターン  $\mathbf{P}$  の集合が,  $I^2$  次元のパターン空間内で,  $M$  次元多様体を成すことに着目する. 例えばパラメータ数  $M$  が1の場合, 多様体は  $\alpha_1$  をパラメータとする曲線となる (図3). なお, 多様体は原パターン  $\mathbf{P}$  を  $\alpha = 0$  において通過する. 入力パターン  $\mathbf{E}$  と多様体  $s(\alpha, \mathbf{P})$  間の距離  $d(\mathbf{P}, \mathbf{E})$  は,  $\alpha = 0$  の周りで次のように線形近似できる (図3).

$$d_{TD}(\mathbf{P}, \mathbf{E}) = \min_{\alpha} \|t(\alpha, \mathbf{P}) - \mathbf{E}\| \quad (3)$$

ここで,  $t(\alpha, \mathbf{P})$  は多様体  $s(\alpha, \mathbf{P})$  の  $\alpha = 0$  における接平面である. この接平面は,  $s(\alpha, \mathbf{P})$  を  $\alpha = 0$  の周りでテイラー展開し, 2次の項以降を無視することで次のように与えられる.

$$t(\alpha, \mathbf{P}) = \mathbf{P} + \sum_{m=1}^M \alpha_m \phi_m \quad (4)$$

このように制御変数  $\alpha$  は非線形関数  $\mathbf{P}$  の外に出るため, 式 (3) はいわゆる最小2乗問題として容易に解くことができる. ここで  $\phi_m$  は多様体  $s(\alpha, \mathbf{P})$  の接ベクトルであり次式で表される.

$$\phi_m = \left[ \frac{\partial s(\alpha, \mathbf{P})}{\partial \alpha_m} \right]_{\alpha=0} \quad (5)$$

接ベクトル  $\phi_m$  は原パターンと同じく  $I^2$  次元であり,  $I \times I$  画像  $\{\phi_m(x, y)\}$  として表現される. 式 (4) を (3) に代入すれば, この線形近似問題の解は次のように解析的に与えられる.

$$\alpha = \Phi^{-1} \lambda$$

ここで  $\Phi$  および  $\lambda$  はそれぞれ  $M \times M$  行列と  $M$  次元ベクトルであり, その要素  $\Phi_{m, m'}$  および  $\lambda_m$  ( $m, m' = 1, \dots, M$ ) は次式のようになる.

$$\Phi_{m, m'} = \sum_{x, y} \phi_m(x, y) \phi_{m'}(x, y)$$

$$\lambda_m = \sum_{x, y} \phi_m(x, y) (E(x, y) - P(x, y))$$

接平面  $t(\alpha, \mathbf{P})$  の表現式 (4) の右辺を観察すると,  $I \times I$  画像  $\phi_m$  の重み付き線形和となっている. ここで  $t(\alpha, \mathbf{P})$  がパターン  $\mathbf{P}$  の変形集合  $s(\alpha, \mathbf{P})$  の近似表現であることを考えると, 結局  $I \times I$  画像  $\mathbf{P}$  の任意の変形パターンを,  $M$  個の  $I \times I$  画像  $\phi_1, \phi_2, \dots, \phi_M$  の重み付き線形和で近似表現していることがわかる. ただし, この近似はあくまで  $\alpha = 0$  すなわち変形の無いパターン近傍のテイラー展開に基づくものであり, 従って大きな  $\alpha$  すなわち大きな変形に対しては近似誤差が大きくなるという欠点もある.

以上の近似解法の枠組みにおいて, 提案するカテゴリ依存変形モデルを利用することを考える. すなわち, 式 (5) に式 (2) を代入することで得られる接平面を用いて  $d_{TD}(\mathbf{P}, \mathbf{E})$  を求める. このとき接ベクトル  $\phi_m$  の第  $(x, y)$  要素は

$$\phi_m(x, y) = P_x(x, y) X_m(x, y) + P_y(x, y) Y_m(x, y) \quad (6)$$

として与えられる. ここで,  $P_x(x, y)$  と  $P_y(x, y)$  は  $P(x, y)$  を

$x$  および  $y$  に関して偏微分したものである．図 2 に示したカテゴリ “A” の最初の 3 つの固有変形をそれぞれ式 (6) に代入して得られた接ベクトル  $\phi_1, \phi_2, \phi_3$  を図 4 に示す．

接ベクトル  $\phi_m$  の計算においては，画像  $P$  の偏微分  $P_x, P_y$  が必要となる．ここでは，単純に差分近似するという方法ではなく，文献 [1] ~ [3] で採用されているように， $P$  をガウス関数  $G_\sigma(x, y)$  でぼかしたものを偏微分することで，差分近似を回避する．

$$P_x(x, y) \sim \frac{\partial P(x, y) * G_\sigma(x, y)}{\partial x} = P(x, y) * \frac{\partial G_\sigma(x, y)}{\partial x}$$

ここで，記号  $*$  は畳み込み演算を表す．ぼかし量のパラメータ  $\sigma$  は 1.25 とした．なお文献 [2] にも同様の指摘があるように， $\sigma$  の設定は微妙なものではなく，実際，我々の実験では  $\sigma \in [0.75, 1.5]$  の範囲ではほぼ同じ結果が得られた．

### 2.3 計算量

距離  $d_{TD}(P, E)$  を求めるための計算量は  $O(MI^2 + M^2)$  となる．後に 3. で示されるように，使用固有変形数  $M$  は実際には非常に小さな数 ( $\sim 3$ ) で済む．従って，計算量はおよそ  $O(MI^2)$  すなわち単純重ね合わせ法の  $M$  倍程度となり，従来の弾性マッチング法に比べれば同程度もしくは相当少い計算量で済む．なお，接ベクトル  $\phi_m$  と逆行列  $\Phi^{-1}$  は，入力パターン  $E$  とは無関係な値であるために，事前に 1 度だけ計算しておけばよい．

### 2.4 固有変形の推定

残る課題は，各カテゴリの固有変形  $\{u_{c,m}\}$  の推定である．文献 [5], [6] には，何らかの従来の弾性マッチング法と，主成分分析を組み合わせることで，この推定を自動的に行う方法が述べられている．本報告においてもその推定方法を利用する．以下ではその概略を述べる．

[ステップ 1: 実際の手書き変形の採集]

各カテゴリ  $N$  個の手書き文字パターン  $T_{c,n} (n = 1, \dots, N)$  を学習パターンとして準備し，それぞれに含まれる手書き変形を採集する．この変形は，変形を含まない標準パターン  $P_c$  と各  $T_{c,n}$  の間の弾性マッチングによる最適画素対応から求まる．例えば， $P_c$  の画素  $(x, y)$  が弾性マッチングの結果  $T_{c,n}$  の画素  $(x', y')$  に対応したならば， $T_{c,n}$  は  $P_c$  を画素  $(x, y)$  において  $(x' - x, y' - y)$  だけ変形 (変位) したものである．結果的に  $T_{c,n}$  全体の変形は変位  $(x' - x, y' - y)$  を全画素について列挙した  $2I^2$  次元ベクトルとして与えられる．

[ステップ 2: 主成分分析を用いた固有変形の推定]

固有変形  $\{u_{c,m}\}$  は頻出する変形であり，従って変形の成す分布の最大分散方向，いわゆる主軸に対応する．従って固有変形は，前ステップで求めた  $N$  個の  $2I^2$  次元変位ベクトルを主成分分析することで求まる．具体的には  $N$  個の変位ベクトルの共分散行列を固有値展開すれば，各固有ベクトルとして主軸すなわち固有変形が得られる．なお  $m$  は固有変形の寄与の順位に対応し，従って最大の固有値に対応する固有変形すなわち最頻変形が第 1 固有変形  $u_{c,1}$  となる．




図 5 ETL6 の文字データの例．大きさは  $16 \times 16$  に線形正規化されている．

ステップ 1 で用いる従来の弾性マッチング法としては次の要求を満たす任意の手法を利用できる．

- (i) 補償可能な変形の範囲が広い (回転等も補償可能)．
- (ii) 大域的に最適な画素対応を与えるアルゴリズムが存在．
- (iii) 変位ベクトルの実効次元数が  $2I^2$  よりも小さい．
- (iv) 結果として画素対応関係を明示的に与える．

要求 (i)(ii) は正確な変形すなわち画素対応を採集するための要求である．これら (i)(ii) を満たすような弾性マッチング法は，過変形の危険性が高く，また一般に多くの計算量を要する．しかしここでは同一カテゴリの文字パターン間のマッチングに利用され，さらに認識処理以前の学習処理において利用されるので，これらは問題にならない．要求 (iii) は限られた学習サンプル数でなるべく信頼性の高い固有変形を推定するためのものである．要求 (iv) は当然であるが，すべての弾性マッチング法が画素対応関係を明示的に与えるとは限らない点に注意すべきである．実際，tangent distance 法 [1] ~ [3] や本手法はこの要求 (iv) を満たさない．

以上の要求 (i)-(iv) を満たす弾性マッチング法として，次節の実験では区分線形 2 次元ワープ法 [7] を採用した．この方法では，画像パターンの各列の変位は中央の画素と上下端の画素の変位の線形補間で与えられる．従って実効次元数は例えば  $I = 20$  の時で  $74 (\ll 2 \times 20^2)$  となり，要求 (iii) も満たしている．なお，図 2 の固有変形はこの区分線形 2 次元ワープ法を用いて得られたものである．

## 3. 実験

### 3.1 実験試料

標準文字画像データベース ETL6 の英語大文字 26 カテゴリ各 1100 サンプルを用いて，認識実験を行った．すべてのサンプルについて，文字大きさを  $16 \times 16$  に線形正規化した後，周囲に 2 画素分のマージンを付け，結果的に  $I = 20$  とした．図 5 に正規化後のサンプルの例を示す．次に，各カテゴリ最初の 100 サンプルを単純平均して標準パターン  $P_c$  を作成した．次の 500 サンプルは，固有変形推定用の学習パターン  $T_{c,n}$  として用いた．残る 500 サンプル (全カテゴリで 13000 サンプル) は認識実験におけるテストサンプル  $E$  として用いた．

本報告では，画素特徴  $(P_c(x, y), E(x, y))$  として，輝度特徴と 4 方向特徴 [8] からなる 5 次元ベクトルを用いた．前節の議論をこの高次元特徴ベクトルに対応させるのは容易である．

### 3.2 認識結果

図 6 に本手法によって得られた認識率を使用固有変形数  $M$  に関するグラフとして示す．最高認識率は 99.21% であり，これは単純重ね合わせ法 (単純マッチング) に比べ 1.12% の改善



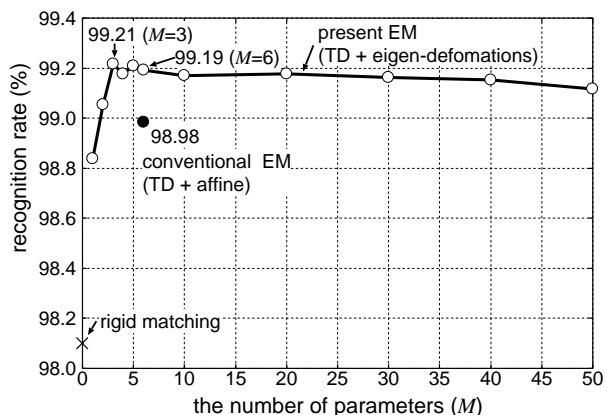


図6 本手法およびアフィン変形モデルに基づく弾性マッチング法による認識率。




図7 本手法およびアフィン変形モデルに基づく弾性マッチング法によるマッチング結果。

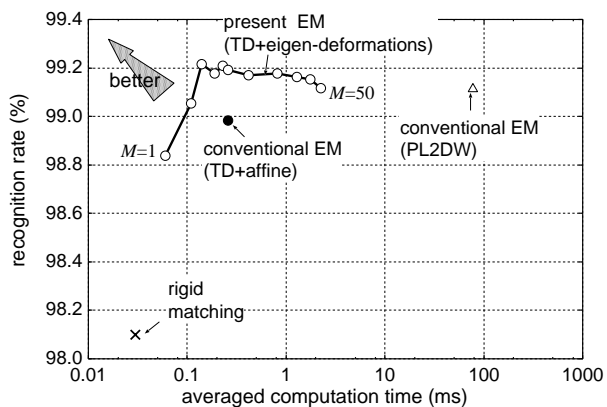


図8 計算時間 (ms) と認識率 (%) の関係。

(145 サンプル分 = 199 改善サンプル - 54 改善サンプル) である。認識率は使用固有変形数  $M$  の増加に従って急激に向上し、 $M = 3$  ですでに飽和している。このことは、式 (2) のカテゴリ依存変形モデルを用いることで、各カテゴリに発生する変形を非常に少ないパラメータ数で効率的に表現できることを示している。さらに、 $M$  が非常に小さいことで、本手法の実際の計算量は非常に少なくて済むことがわかる。具体的には  $M = 3$  のときに 1 回のマッチングに PC (CPU: Xeon 2.0GHz) が要した平均時間は 0.14 (ms) であった。

図7上段に、本手法によるマッチング結果例を示す。この例ではカテゴリ “M”, “R”, “V” の各標準パターン  $P_c$  が、それぞれ同カテゴリを正解とする入力パターン  $E$  に整合するべく、本手法により適切に変形されていることがわかる。

### 3.3 カテゴリ非依存の変形モデルに基づく弾性マッチングとの比較

カテゴリ依存変形モデルに基づく本手法の有効性を確認するために、2種類のカテゴリ非依存の変形モデルに基づく弾性

マッチング法との比較実験を行った。比較事項は認識率と計算効率の2点とした。

#### 3.3.1 比較実験1

比較対象とした第1の方法は、本手法と同様の枠組みにおいて、カテゴリ依存変形モデル (2) の代わりに次のアフィン変形モデルを用いた弾性マッチング法 [1] ~ [3] である。

$$s(\alpha, P_c(x, y)) = P_c(x + (\alpha_1 x + \alpha_2 y + \alpha_3), y + (\alpha_4 x + \alpha_5 y + \alpha_6)) \quad (7)$$

従って、この弾性マッチング法は、すべてのカテゴリの変形が共通してアフィン変換によって表現できるという仮定に基づいている。また補償可能な変形は線形変換によって表現可能なものに限られている。

図6に示されているように、この手法の最高認識率は98.98%であり、従って本手法の99.21%よりも低い。さらにこれらの認識率を与えたときのパラメータ数  $M$  は、それぞれ6と3であるから、本手法のほうが半分のパラメータ数で高い認識率を与えたことがわかる。この結果より、カテゴリ依存の変形モデル (2) を用いたほうが、カテゴリ非依存の変形モデルを用いるよりも、各カテゴリの生じる変形をよりの確にかつ効率的に表現できていると言える。なお、アフィン変形モデルに対する本手法の改善率は0.23% (= 99.21 - 98.98) であるが、これは誤認識数を約3/4に低減できたことに相当する。

図7に示した3例は、本手法では正しく認識されたが、アフィン変形モデルに基づく方法では誤認識されたテストサンプル  $E$  に関するものである。同図下段には、アフィン変形モデルによる弾性マッチングの結果も示しているが、同図上段に示す本手法の方が、 $P_c$  を  $E$  に近づくよう変形できており、変形補償能力が高いことがわかる。

#### 3.3.2 比較実験2

カテゴリ非依存の変形モデルに基づく弾性マッチングの第2の方法として、固有変形の推定時に利用した区分線形2次元ワープ [7] を用いた。ノンパラメトリックな変形モデルに基づくため、変形補償能力は前述のアフィン変形モデルに比べ高く、非線形な変形も補償可能である。また、動的計画法に基づく2次元組み合わせ最適化アルゴリズムにより大域的に最適な整合が可能である。

最高認識率は99.12%であり、これは本手法の99.21%をわずかながら下回っている。高い変形補償能力を持ちながら高い認識率を達成できなかった理由は、2.4でも述べたように、変形モデルのカテゴリ非依存性に起因した過変形による誤認識の影響があったためである。一方、カテゴリ依存変形モデルに基づく本手法は過変形となるような変形がモデル (2) の範囲に含まれないので、カテゴリ間の差異まで吸収してしまうような過変形が生じず、結果的に優位となったと考えられる。なお、カテゴリ内の比較的小さな変形の補償能力において両者はほぼ同一と考えられる。これは、本手法の固有変形が、区分線形2次元ワープによって与えられた変位ベクトルから推定されているためである。ただし、大きな変形の補償能力については、線形近似の影響により本手法のほうが低いと考えられる。

計算量的には両手法の間には劇的な違いがある．図 8 に本手法と区分線形 2 次元ワープ法の計算時間と認識時間の関係を示している．同一認識率で両手法を比較すると，本手法は区分線形 2 次元ワープ法のおよそ 1/500 から 1/1000 程度の計算量で済んでいることがわかる．区分線形 2 次元ワープ法は，前述のように 2 次元組み合わせ最適化問題を解く必要があるため，他のノンパラメトリックな弾性マッチング法（例えば [9]）に比べても計算量は多い．よって，他のパラメトリックな弾性マッチング法と本手法を比較した場合はこの計算量の差はもう少し縮まると考えられる．ただし前述のように本手法の計算量は  $O(MI^2)$  と少ないので，他のノンパラメトリックな弾性マッチング法に対しても計算量的優位性を保てると見込まれる．

## 4. 検 討

### 4.1 固有変形の他の利用形態

弾性マッチングを用いた文字認識における，固有変形の他の利用形態として，事後評価における利用が提案されている [5], [6]．具体的には，まず従来法の弾性マッチングを行った後，その際の変位を固有変形と比較照合し，逸脱が見られた場合にこれを過変形としてペナルティを与えるというものである．文献 [5], [6] では，この間接的な利用形態によっても，十分高い認識率が得られると報告されている．

しかしながら，計算効率の面では，本手法のほうが有利と考えられる．事後評価を行う方式で用いられた従来の弾性マッチングの解空間には，図 1 に示した“H”の両縦ストロークを傾けるような不要な変形が含まれている．従って計算コストをかけて無駄な探索を一旦は行うことになる．これに対し本手法は，変形モデルに直接固有変形を組み込んだ新しい弾性マッチング法であり，結果的に無駄な変形を根本的に排除し，効率的/高速なマッチングを可能としている．

また，事後評価型の利用形態においては，マッチングコストと事後評価値をの比重を定めるパラメータの値が重要であり，それにより性能が大きく左右される．一方，本手法にはそうしたパラメータは不要である．

### 4.2 他の最適化アルゴリズム

本報告では式 (1) の非線形最適化問題をテラー展開により線形近似して解いた．2.2 で述べたように，この線形近似には利点もあるが，近似の有効範囲が  $\alpha = 0$ ，すなわち原パターン  $P_c$  の近傍に限られるという欠点もある．これはカテゴリ依存変形モデルの変形表現能力を十分活用できていないことを意味しており，一考の余地がある．

この欠点を回避する一手法として，線形近似解法の代りに反復解法を使って非線形最適化問題 (1) を直接解くことが考えられる．反復解法を用いる場合，モデルや目的関数に対する近似は不要であり，比較的大きな変形（大きな  $\alpha$ ）も補償できると期待できる．反面，解の収束の制御には多少の工夫が必要になるものと考えられる．Wakahara らは，アフィン変形モデル (7) に基づく弾性マッチングにおいて，反復解法を提案している [10]．この枠組みにおいてアフィン変形モデルを固有変形に基づくカテゴリ依存型変形モデル (2) に置き換えれば，そのま

ま本手法の反復解法が得られる．

### 4.3 部分空間法との関係

線形近似された変形モデル (4) は，任意の変形画像を複数の画像（基底画像）の線形和で近似表現するという点で，部分空間法 [11] と類似している．ただし両者は同一ではなく，例えば本モデル (4) の基底画像  $\phi_m$  はパターン空間内において互いに直交していないが，部分空間法の基底画像は直交している．両者の比較は今後の課題であるが，パターンの分布を数個の基底画像で表現する上で，それぞれ異なった役割を相補的に担う可能性も考えられる．

## 5. む す び

手書き変形に対して頑強な文字認識を目的として，カテゴリ依存変形モデルに基づく弾性マッチング方を提案した．この変形モデルでは，あるカテゴリの任意の変形をそのカテゴリに固有な幾つかの変形方向の重み付き線形和で表現する．このようなモデルを用いることで，そのカテゴリに生じる変形だけを効率的に表現でき，過変形の排除や計算量の低減が可能となる．本手法は非線形最適化問題として定式化される．本報告では線形近似に基づくその一解法を提案した．認識実験の結果，本手法はカテゴリ非依存（すなわち全カテゴリ共通）な変形モデルを用いた従来の弾性マッチング法に比べ，認識率の点でも，計算量的にも優位であることがわかった．

謝辞: 実験では，電子技術総合研究所（現 産業技術総合研究所）の文字データベース ETL6 を利用させて頂いた．ここに感謝する．本研究の一部は文部科学省科学研究費補助金（若手 B No.14780293）によった．

### 文 献

- [1] P. Simard, Y. Le Cun, J. Denker, and B. Victorri, “An efficient algorithm for learning invariances in adaptive classifier,” *Proc. 11th ICPR*, 2:651–655, 1992.
- [2] P. Simard, Y. Le Cun, and J. Denker, “Efficient pattern recognition using a new transformation distance,” *Advances in Neural Information Processing Systems*, 5:50–58, 1993.
- [3] P. Simard, Y. Le Cun, and J. Denker, “Memory-based character recognition using a transformation invariant metric,” *Proc. 12th ICPR*, 2:262–267, 1994.
- [4] T. F. Cootes, C. J. Taylor, D. H. Cooper, and J. Graham, “Active shape models - their training and application,” *Comput. Vis. Image Und.*, 61(1):38–59, 1995.
- [5] 内田誠一，迫江博昭，“固有変形の利用による手書き文字認識の高精度化,” 画像の認識・理解シンポジウム (MIRU2002), I-391–396, 2002.
- [6] S. Uchida and H. Sakoe, “Eigen-deformations for elastic matching based handwritten character recognition,” *Pattern Recognition*, to appear, 2003.
- [7] 内田誠一，迫江博昭，“区分線形 2 次元ワープ法の検討,” 信学論, J83-D-II(12):1643–1649, 2001.
- [8] 齊藤泰一，山田博三，山本和彦，“手書き漢字の方向パターン・マッチング法による解析,” 信学論, J65-D(5):550–557, 1982.
- [9] 水上嘉樹，古賀和利，鳥岡豊士，“変位抽出を行う手書き文字認識システム,” 信学論, J80-D-II(1):63–72, 1997.
- [10] T. Wakahara, Y. Kimura, and A. Tomono, “Affine-invariant recognition of gray-scale characters using global affine transformation correlation,” *IEEE Trans. PAMI*, 23(4):384–395, 2001.
- [11] 石田健一郎，上田修功，前田英作，村瀬 洋，わかりやすいパターン認識，オーム社，1998.