

オンライン手書き文字認識 HMM における 座標情報と方向情報の利用法と効果

奥村 大樹[†] 内田 誠一^{††} 迫江 博昭^{††}

[†] 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

〒 812-8581 福岡市東区箱崎 6-10-1

E-mail: {okumura, uchida, sakoe}@human.is.kyushu-u.ac.jp

あらまし 本稿では、HMM に基づくオンライン手書き文字（特に漢字）認識の新たな手法として、“線分始点座標 + 方向情報出力型 HMM” を提案する。HMM をオンライン手書き文字認識に適用する場合、定常性が問題になる。HMM はパターンの特徴を“状態”に対応させるが、この状態は特徴量に関する何らかの定常性を仮定している。文字を線分近似して考えると、直線部分では方向情報はほぼ一定で、定常状態と見なせるが、座標情報は時々刻々と変化するため定常とは見なせない。本手法では、線分の始点を過渡状態として、ここでは座標情報を 1 回だけ出力し、線分内は定常状態としてここでは固有の方向情報を出力する形の HMM を提案する。さらに、筆順変動を伴う多画文字を扱うために、最適画対応サーチアルゴリズムであるキューブサーチ法にこの HMM を埋め込んだ手法を提案する。10 画漢字を対象とした認識実験により、本手法の有効性を確認した。

キーワード オンライン手書き文字認識, 隠れマルコフモデル, 線分始点座標 + 方向情報出力型 HMM, 筆順自由, キューブサーチ

An HMM Implementation for On-line Handwriting Recognition Based on Pen-Coordinate Information and Pen-Direction Information

Daiki OKUMURA[†], Seiichi UCHIDA^{††}, and Hiroaki SAKOE^{††}

[†] Graduate School of Information Science and Electrical Engineering, Kyushu University

^{††} Faculty of Information Science and Electrical Engineering, Kyushu University

Hakozaki 6-10-1, Higashi-ku, Fukuoka-shi, 812-8581 Japan

E-mail: {okumura, uchida, sakoe}@human.is.kyushu-u.ac.jp

Abstract An on-line handwritten character recognition technique based on a new HMM is proposed. In the proposed HMM, not only pen-direction features but also pen-coordinate features are utilized for describing the shape variation of on-line characters more accurately than conventional HMM where the pen-coordinate features are not utilized because of their non-stationarity. Specifically speaking, the proposed HMM outputs a pen-coordinate feature at each inter-state transition and outputs a pen-direction feature at each intra-state transition, i.e., self-loop. Thus, each state of the proposed HMM can specify the starting position and the direction of a line segment by its incoming inter-state transition and intra-state transition, respectively. The results of recognition experiments on 10-stroke Chinese characters show that the proposed HMM outperforms conventional HMMs.

Key words on-line character recognition, hidden Markov model, feature vector, pen-coordinate information and pen-direction information, cube search

1. はじめに

オンライン漢字認識では字形の変動と筆順変動が問題になる（画数変動の問題は本稿では扱わない）．字形変動に強く、標本点間隔のばら付きにも対応できる認識機構として HMM の適用が試みられている [1]．パターンが時系列として与えられることから例外なく LR 型の HMM が採用されている．その場合、入力特徴（HMM の出力値、観測値）をどう定義するかという点と、状態をどういう単位に対応させるかという基本的な問題が生じる．これらの間には相互に関連があり、LR 型の各自己遷移状態を特徴の定常な区間に対応させるのが原則である．

オンライン文字認識で利用される特徴としてまずペン座標情報が挙げられる．方向情報とあわせて用いられることも多い．座標情報には時系列的に見て定常性がなく、入力標本点の密度に匹敵する状態数のモデルを用意する必要がある．いわゆる確率 DP マッチングという認識過程になり、学習・認識に要する処理量は大きい [2], [3]．

ペン運動の方向情報は、線分内では定常性を有する．このため、状態：線分、入力特徴：方向情報というモデルが広く用いられている [4], [5]．しかし筆順自由な認識への拡張を見込んだ場合、方向情報だけでは画対応決定に不十分と予測される．DP マッチングをベースとした筆順自由認識実験では、状態の定常性の問題が生じないことから、座標情報と方向情報が併用されている [6] ~ [8]．

本研究では、HMM をベースとした高精度筆順自由認識を目的として、座標情報と方向情報を定常性に関して矛盾なく利用できるモデルを検討した．基本的な考えは、各線分の始点でのみ座標情報を出力し、線分中では、定常性を有する方向情報を出力するというものである．状態間遷移で座標情報を、自己回帰遷移で方向情報を出力するという LR 型の HMM である．

以下、本稿ではモデルの概要を述べ、筆順固定、筆順自由の各場合において評価実験を行った結果を報告する．

2. 従来型の HMM の問題点

タブレットから入力されるオンライン文字の時系列データを $xy_1, \dots, xy_t, \dots, xy_T$ とする．ここで、 $xy_t = (x_t, y_t)$ は時刻 t におけるペン先の座標情報である．本章では特に断りの無い限りこの時系列が 1 つの画（ストローク）を表しているとする．すなわち、時刻 1 から T までにペンアップは無いものとする．漢字など多画文字を扱う場合については、4. で述べる．

従来型の HMM は、図 1 に示すように、画を構成する線分要素毎に状態を設け、各状態では対応する線分の局所的な方向情報 d_t を出力するものとして設計されることが多い [4], [5]．ここで方向情報 d_t とは、連続する 2 筆点 xy_{t-1}, xy_t の成すベクトルの方向に相当する．以下ではこの従来型の HMM のことを“線分方向情報出力型 HMM”と呼ぶ．

座標情報 xy_t の代わりに方向情報 d_t を用いるのは、1. で




図 1 線分方向情報出力型 HMM．各状態で方向情報 d_t が出力される．




図 2 提案する線分始点座標+方向情報出力型 HMM．状態間遷移では座標情報 (x_t, y_t) が、自己遷移では方向情報 d_t が出力される．

も述べたように、座標情報が HMM の前提条件である 1 状態内での定常性を満たさないためである．すなわち、座標情報は線分中で時変であり、1 線分を 1 状態に対応付けた HMM で用いると、例えば逆順の座標系列が与えられても差別化できなくなる．

しかし一方で、座標情報を排除したことにより問題も起きる．方向情報だけでは、線分の長さに関する情報が不足する．このため、長い線分を短い線分に対応付けるなど、不自然な対応付けが起こりうる．漢字など多画文字については、画間の位置関係に関する情報が不足し、例えば「土」と「工」の区別が曖昧になる．さらに、筆順自由の枠組みでは、この曖昧性がさらに悪用されてしまう可能性もある．

3. 線分始点座標 + 方向情報出力型 HMM

本稿では、図 2 の“線分始点座標 + 方向情報出力型 HMM”を提案する．本 HMM では、状態間の遷移において過渡的な情報である座標情報を出力し、1 状態内の遷移（自己遷移）において定常的な情報である方向情報を出力する．1 状態だけを取り出して考えると、その状態に入って来る遷移により線分の始点座標が規定され、その後の自己遷移によりその始点から伸びる線分の方向が規定されることになる．このように性質の異なる 2 つの情報を遷移別に適切に分けて扱うことで、両特徴を矛盾無く HMM の枠組みで利用できる．

以下、本 HMM における学習・認識の手順について、通常の HMM [9] と異なる点に絞って説明する．状態 i から j への遷移確率を $a_{i,j}$ とすると、線分始点座標 + 方向情報出力型 HMM では、前向き変数 $\alpha_t(i)$ 、後向き変数 $\beta_t(i)$ の各計算過程において、状態間遷移では $b_{i-1,i}(xy_t)$ を、自己遷移では $b_{i,i}(d_t)$ を評価するという具合に評価対象が切り替わる．ここで、 $b_{i-1,i}(xy_t)$ は状態間遷移 ($i-1 \rightarrow i$) における座標情

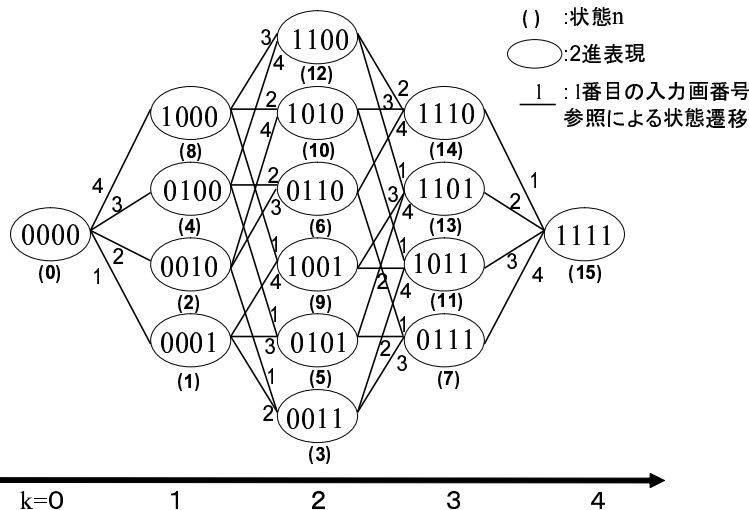


図3 画対応サーチグラフ

報の出力確率を表現する2次元正規分布であり、 $b_{i,i}(d_t)$ は自己遷移 ($i \rightarrow i$) における方向情報の出力確率を表現する1次元正規分布である。具体的には、前向き変数を

$$\alpha_t(i) = \alpha_{t-1}(i-1)a_{i-1,i}b_{i-1,i}(xy_t) + \alpha_{t-1}(i)a_{i,i}b_{i,i}(d_t) \quad (1)$$

により計算する。こうして得られた前向き変数および後ろ向き変数を用いて、従来のHMM同様、学習ならびに認識を行う。例えば認識時には、入力系列の尤度として $\alpha_T(N)$ を使用する。ここで N は状態数である。

複数の線分要素からなる画(例えば“一”状の画)を扱う場合は、各線分要素に応じて状態を設ける。最後以外の線分要素については、始点座標と共に終点座標が規定されることになる。なお、本手法において、入力画を事前に線分単位にセグメンテーションする必要はない。逆に、ピタビアルゴリズムを実行すれば、入力ストロークの自動的かつ最適なセグメンテーションが得られる。

4. 多画文字のための拡張 — キューブサーチHMM

前章では1画を表現するための線分始点座標+方向情報出力型HMMについて述べた。本章では、これを漢字などの多画文字を扱えるように拡張する。多画文字独特の問題の一つに筆順変動がある。本稿では、筆順変動対処法の一つであるキューブサーチ法[6]に、線分始点座標+方向情報出力型HMMを埋め込んだ手法を提案する。なお、1.でも述べたように、画数変動(続け書き)については今後の検討課題とし、本稿では扱わない。

4.1 キューブサーチ [6]~[8]

キューブサーチは、2つのオンライン文字パターン(入力パターンと標準パターン)間の相違度の総和を最小にする1対1の画対応を決定する方法であり、キューブサーチグラフと呼ばれるグラフ上の最適経路問題として定式化される。画数 K が4の場合のキューブサーチグラフを図3に示す。こ

のグラフは K 段からなり、第 k 段には入力パターンの画番号 k が対応している。第 k 段の各ノードは、入力パターンの第1画から第 k 画までが、標準パターンのどの画と対応付けられたかを意味している。具体的には、各ノードは K ビットで構成され、各ビットは既対応を示すフラグの働きをする。すなわち、最下位ビットから $1, 2, \dots, K$ と画番号が対応づけられており、第 k 段においては対応づけられた画番号に対応する k 個のビットが1となっている。ノード間遷移においては、いずれかのビットを0から1に反転させる。ノード m から n の遷移において、第 l ビットが反転する場合、 m, n 間のエッジには、コストとして入力パターンの第 k 画と標準パターンの第 l 画の画間距離 $\delta(k, l)$ が付随する。

以上により、画対応サーチの問題はキューブサーチグラフの初期ノード(00...0)から最終ノード(11...1)への経路のうち、画間距離の総和を最小にする経路を探索する問題として定式化される。文献[6]~[8]では、 $\delta(k, l)$ の計算を2画間のDPマッチングで行い、さらにキューブサーチグラフの最適経路もDPにより求める方法が提案されている。

4.2 線分始点座標+方向情報出力型HMMのキューブサーチへの埋め込み

画間の位置関係も考慮したHMM型筆順自由文字認識を実現するために、線分始点座標+方向情報出力型HMMを用いたキューブサーチ法—キューブサーチHMM—を提案する。具体的には、画間距離 $\delta(k, l)$ として、第 l 画用の線分始点座標+方向情報出力型HMMによる入力の第 k 画の尤度(3.の $\alpha_T(N)$)を用いる。従来の線分方向情報出力型HMMでも同様のキューブサーチを構築できるが、2.で述べたように、座標情報の欠落により、全く違う位置にある画を対応付けてしまう、いわゆる合わせ過ぎが多発すると思われる。座標情報を考慮したHMMに基づく本手法では、こうした問題は回避できると期待できる。

本稿のキューブサーチHMMでは、どのような筆順変動が起こり易いかを表現できるように、ノード間の遷移確率 p_{mn}

を導入する．ここで

$$\sum_{n \in \mathcal{N}(m)} p_{mn} = 1 \quad (2)$$

であり， $\mathcal{N}(m)$ はノード m から遷移可能なノードの集合である．結局，キューブサーチグラフ (図 3) のエッジには，遷移確率 p_{mn} と線分始点座標 + 方向情報出力型 HMM の両方が付随する．遷移確率 p_{mn} の導入により，起こりにくい筆順については，ペナルティが課されることになる．これにより筆順自由化時の合わせ過ぎの問題を回避できると期待できる．なお，以上の枠組みでは，入力各画に特定した筆順変動の生起確率が表現されていることになる．

また，この p_{mn} の導入により，キューブサーチグラフ全体を改めて HMM として捉えることができる．すなわち，キューブサーチグラフのノードが状態， p_{mn} が状態遷移確率，線分始点座標 + 方向情報出力型 HMM の出力する尤度が状態遷移時の出力確率となる．従って，入力文字の尤度は，このように捉えた場合の前向きアルゴリズムにより計算できる．

4.3 キューブサーチ HMM の学習

遷移確率 p_{mn} の学習については，HMM のパラメータと関連して，幾つかの方式が考えられる．本稿では，最も簡単な以下の 2 段階の学習方式を用いる．

まず，正規筆順学習パターンを用いて，各文字種の各画ごとに，線分始点座標 + 方向情報出力型 HMM の学習を行う．次にこれら HMM のパラメータは固定した上で，正規・非正規筆順データを用い， p_{mn} の学習を行う．このとき，同じ画に対応する線分始点座標 + 方向情報出力型 HMM は，キューブサーチグラフ上で共有される．(例えば，図 3 において，エッジ (0001) → (0011) およびエッジ (1100) → (1110) に付随するのは同じ第 2 画用 HMM である．)

5. 認識実験

5.1 実験試料

認識実験は，当研究室内部のオンライン手書き文字データ (筆記者 30 人分，楷書体を指示して筆記させたもの) と，東京農工大学中川研究室が公開しているデータ (“HANDS-kuchibue.d-97-06-10”，筆記者 10 人分，mdb0001 ~ mdb0010)[10] から抽出した 10 画の教育漢字を対象とした．以下便宜上，前者をデータセット A，後者をデータセット B と呼ぶ．学習不足の問題を回避するため，データ数の少ない文字種は除外した．その結果，付録に示す 70 文字種を学習・認識が対象となり，データセット A, B に含まれるサンプル数はそれぞれ 1444, 1051 となった．各文字データは前処理として 128×128 の大きさに線形正規化し，その後，等距離間隔となるようリサンプリングを施した．

5.2 全情報出力型 HMM

以下の実験では，従来法である線分方向情報出力型 HMM，本手法である線分始点座標 + 方向情報出力型 HMM に加え，図 4 に示す “全情報出力型 HMM” を用いた．この全情報出力型 HMM も，本手法や従来法と同じく，1 線分要素に 1 状

表 1 1 画化文字の認識率 (%)．学習にはデータセット A を使用．

テストデータセット	A (closed)	B (open)
線分方向情報出力型 HMM	99.9	99.3
全情報出力型 HMM	89.5	81.2
線分始点座標 + 方向情報出力型 HMM	100.0	99.9




図 4 全情報出力型 HMM．各状態で，方向情報 d_t と座標情報 (x_t, y_t) の組が出力される．




図 5 本手法で正解，従来法で「息」に誤認識された 1 画化文字「恩」

態を対応させるものであるが，各状態において，座標情報と方向情報を同時に出力する点が異なる．従って，座標情報を扱っている点では本手法に類している．ただし，その扱い方には大きな違いがある．すなわち，本手法が 1 状態 (遷移) で線分の始点座標のみを表現するのに対し，全情報出力型 HMM では 1 状態で線分全体の座標情報を強制的に定常とみなして表現することになる．

5.3 筆順変動を含まない文字に関する実験

線分始点座標 + 方向情報出力型 HMM の基本的な性能を評価するために，筆順固定条件の下での実験を行った．具体的には，正規筆順データを 1 画化して生成した文字を学習・認識に用いた実験を行った．この 1 画化は，ペンアップ部分を直線で結ぶという方法で行った．このペンアップ部分についても，前節で述べたものと同様のリサンプリングを行った．

3 種の HMM の状態数 N については，同一文字種では同一とした．具体的には基本的に線分要素数程度となるよう設定した．なお，本実験は 1 画化文字を対象としているので，状態数は通常使用形態 (HMM で 1 画を表現) に比べ多くなる．HMM のパラメータの初期値は人為的に与え，その後，1 画化文字をセグメンテーションすることなく入力し，学習した．

データセット B には，正規筆順データが少なかったため，いずれの HMM もデータセット A から生成した 1 画化文字を学習用データとして用いた．データセット A ならびに B 中の正規筆順データ数は，それぞれ 1212, 767 であった．

結果を表 1 に示す．closed/open のいずれの設定においても，3 種の HMM のうち，本手法が最も高い認識率を挙げる

表 2 キューブサーチ HMM を用いた認識率 (%) . 学習にはデータセット A を使用 .

遷移確率 p_{mn}	不使用		使用	
	A (closed)	B (open)	A (closed)	B (open)
線分方向情報出力型 HMM	26.7	26.4	79.9	82.0
全情報出力型 HMM	94.5	85.6	96.7	91.2
線分始点座標 +方向情報出力型 HMM	97.7	93.9	98.5	97.4

ことができていることがわかる . 従来法 (線分方向情報出力型 HMM) で正しく認識され , 本手法で誤認識されたサンプルは無かった .

図 5 は , 従来法では「息」に誤認識され , 本手法では正解となったサンプル「恩」である . 従来法では , 「恩」の 1 画部分が「息」の 1, 2 画部分に対応付けられていた . これは , 「息」の HMM の最初の状態 (“/” の線分を担当) をほとんど自己遷移なしで通過してしまったためである . このように方向情報のみ用いると , 各線分の長さを表現する能力が不足するために , こうした不自然な対応付けが発生し , 誤認識の要因となる .

5.4 筆順変動を含むデータによる実験

4. で提案した , キューブサーチ HMM の有効性を検証するために , 3 種の HMM それぞれについてキューブサーチ HMM を実装し , 筆順変動を含むデータを対象とした学習・認識実験を行った . ある画を表現するための状態数は 3 つの HMM で同一とし , 具体的には , その画を構成する線分要素数とした . 例えば “一” 状の画については , 2 状態を用いた .

キューブサーチ HMM の学習は 4.3 で述べた 2 段階学習に依った . まずデータセット A の正規筆順 1212 サンプルを用いて各文字の各画の HMM を学習した . 次に , データセット A の全 1444 サンプルを用いて遷移確率 p_{mn} を学習した .

結果を表 2 に示す . 同表には遷移確率 p_{mn} を用いない場合 (すなわち一定値とした場合) , および用いた場合の両方の結果を示している . いずれの場合においても , 本手法が他の 2 つの HMM より有効であることがわかる . また , 遷移確率 p_{mn} を用いた方が認識率が高く , それが有効であることもわかる .

本手法と従来法 (線分方向情報出力型 HMM に基づくキューブサーチ HMM) とを比較すると , 前節の実験よりも顕著な差異が見られる . 2. で述べたように , 方向情報しか用いない従来法では , 画間の位置関係の情報不足が問題となる . 特にキューブサーチという筆順自由の枠組みでは , 位置の全く違う画でも対応付けてしまう可能性が高くなり , 致命的な問題となる . このことは , 遷移確率 p_{mn} を用いない場合 , すなわち画を最も自由に対応づけられる場合に , 従来法の認識率がわずか 26% 程度に留まっていることから裏付けられる .

図 6(a) は , 従来法では「病」に誤認識され , 本手法では正解となったサンプル「校」である . 同図 (b) は従来法による




図 6 (a) 従来法 (線分方向情報出力型 HMM に基づくキューブサーチ) で「病」に誤認識されたサンプル「校」 . (b) 従来法による画対応 . (c) 本手法による画対応 . 同じ丸囲み数字を持つ画が対応付けられていることを意味し , 数字自体は入力画の番号を表す .




図 7 (a) 遷移確率 p_{mn} を用いなかった場合「徒」に誤認識された「原」 . (b) その際の画対応 .

「病」との画対応の結果である「校」の第 1 画と第 6 画と , それに対応している「病」の画では , 左右関係が逆転しており , 前述の通り , 座標情報の欠落により不自然な対応付けが起こることがわかる . この画対応時の尤度を見ても比較的高い値であった . すなわち , 何ら抑制は働いていないことがわかる . 「校」の第 3 画と第 9 画についても同様である . また , 「校」の第 2 画は直線状であるにも関わらず , 「病」の “一” 状の画と対応しまっている . これは , 画 “一” 用の HMM の最初の状態 (“一” の水平線分を担当) をほとんど自己遷移なしで通過したためであり , 前節の実験結果と同様 , 従来型の HMM の線分長の表現能力不足に困っている . 一方 , 同図 (c) には , 本手法を用いた場合の画対応の結果が示してある . 位置的に離れた画の対応付けが少なくなっていることがわかる . また , 多少位置的に離れているものの他との関係でやむを得ず対応付けられたと思われる第 2 画については , 尤度が非常に低くなっていることを確認しており , 「病」と認識することを抑制していることがわかる .

本手法に関して , 遷移確率 p_{mn} が有効に機能した文字「原」を図 7(a) に示す . 遷移確率 p_{mn} が無い場合 , この「原」は「徒」に誤認識された . 同図 (b) はその際の画対応である . 「原」の第 1 画が「徒」の第 4 画に対応付けられていることがわかる (図中①で表記) . 実際の文字においてこうした対応付けはほとんど起こらないにも関わらず , 何らペナルティが課されなかったことが誤認識の一因となっている . 一方 , 遷移確率 p_{mn} を入れた場合も , 標準パターン「徒」との画対応は変化しなかった . しかし , この場合のこの入力「原」は「原」として正答された . これは , 入力の第 1 画が「徒」の第 4 画に対応する確率が $p_{mn} = 0.015$ と低く学習されてお

り、その結果この対応付けには適切なペナルティが課されたためと考えられる。

全情報出力型 HMM は、座標情報を多少なりとも考慮しているため、従来法に比べると不自然な画対応を抑制する能力が高い。その結果、従来法よりも高い認識率を得ている (表 2)。しかしながら、本手法に比しての優位性は認められない。前述のように、全情報出力型 HMM では 1 つの線分の座標情報を強制的にただ 1 つの状態では表現している。従って、その座標値変動吸収能力には限界がある。このため形状変動を伴うと線分の尤度が低くなり易く、その結果として不自然な画対応となった場合が散見された。

6. ま と め

オンライン手書き文字認識のための“線分始点座標+方向情報出力型 HMM”を提案した。本 HMM では、文字を構成する線分要素の座標情報と方向情報を、それぞれ HMM の状態間遷移と自己遷移に分離して扱う。これにより過渡的な座標情報と定常的な方向情報をその特性に応じて利用できる。さらに、漢字など筆順変動を伴う多画文字に対応できるように、本 HMM を画対応付けアルゴリズムに埋め込んだ、キューブサーチ HMM を提案した。認識実験により、方向情報のみを扱う従来の HMM に比べて優位性を確認した。

今後の課題としては、以下が挙げられる。

- より大規模なデータセットを利用した、学習・認識実験を行う。

- 本稿ではキューブサーチ HMM の学習法として、単純な 2 段階法を用いた。今後は他の学習法として、遷移確率 p_{mn} と線分始点座標+方向情報出力型 HMM のパラメータを一括学習するような方式を検討する。

- 線分始点座標+方向情報出力型 HMM において混合正規分布の導入を検討する。現在は単一正規分布で出力分布を近似しているが、座標情報に関しては明らかに表現力が不足していると考えられる。文献 [11] のように、混合数を変化させながら、結果の変化を観察する予定である。

- 線分始点座標+方向情報出力型 HMM の最終遷移にも座標情報出力を設ける。

謝辞 実験では、東京農工大中川研究室のオンライン手書き文字データベース“HANDS-kuchibue_d-97-06-10”を利用させていただいた。ここに感謝する。本研究の一部は総務省戦略的情報通信研究開発推進制度の支援を受けた。

文 献

- [1] C. -L. Liu, S. Jaeger, and M. Nakagawa, “Online recognition of Chinese characters: the state-of-the-art,” IEEE Trans. PAMI, vol. 26, no. 2, pp. 198–213, 2004.
- [2] K. C. Jung, S. M. Yoon, and H. J. Kim, “Continuous HMM applied to quantization of on-line Korean character spaces,” Pattern Recognition Letters, vol. 21, no. 4, pp. 303–310, 2000.
- [3] C. Bahlmann and H. Burkhardt, “The writer independent online handwriting recognition system *frog on hand* and cluster generative statistical dynamic time warping,” IEEE Trans. PAMI, vol. 26, no. 3, pp. 299–310, 2004.
- [4] 高橋賢一郎, 安田英史, 松本隆, “Hidden Markov Model を用

いたオンライン手書き文字認識,” 信学技報, PRMU96-211, 1996.

- [5] 中井満, 嵯峨山茂樹, 秋良直人, 小場久雄, 下平博, “ストローク HMM に基づくオンライン手書き文字認識の性能評価,” 信学技報, PRMU2000-36, 2000.
- [6] 迫江博昭, 愼重弼, “筆順フリーなオンライン文字認識のための画対応サーチアルゴリズム,” 九州大学院システム情報科学研究科報告, vol. 2, no. 1, pp.99–104, 1997.
- [7] 愼重弼, 迫江博昭, “筆順・画数自由オンラインサーチ文字認識のための画対応決定法 - 多層キューブサーチ -,” 信学論, vol. J82-D-II, no. 2, pp. 230–239, 1999.
- [8] 愼重弼, 片山喜規, ムハマド マスルール アリ, 迫江博昭, “画間相互情報を用いた筆順自由オンライン文字認識アルゴリズム,” 信学論, vol. J82-D-II, no. 3, pp. 382–389, 1999.
- [9] L. R. Rabiner, “A tutorial on hidden Markov models and selected applications in speech recognition,” Proc. IEEE, vol. 77, no. 2, pp. 257–286, 1989.
- [10] 松本馨, 中川正樹, “オンライン手書き文字認識日本語文字バタンの解析,” 信学論, vol. J87-D-II, no. 5, pp. 1112–1119, 2004.
- [11] 秋良直人, 中井満, 下平博, 嵯峨山茂樹, “ストローク HMM に基づくオンライン手書き文字認識の特徴量の検討,” 信学技報, PRMU2000-134, 2000.

付 録

1. 実験で使用した漢字

本実験では、以下の 10 画漢字全 70 文字種を対象とした：案, 員, 益, 恩, 夏, 家, 害, 格, 株, 記, 起, 帰, 宮, 拳, 訓, 兼, 原, 個, 庫, 候, 校, 耕, 航, 高, 根, 差, 財, 索, 殺, 蚕, 残, 師, 紙, 時, 借, 弱, 酒, 修, 従, 純, 書, 消, 称, 真, 座, 素, 倉, 造, 息, 帯, 展, 徒, 島, 討, 党, 特, 納, 能, 配, 倍, 俵, 病, 粉, 勉, 脈, 容, 浴, 流, 旅, 料.