

研究速報

相互制約付き多数決型アルゴリズムによる時系列パターン認識

福富 正弘[†] (学生員)

小川原光一^{††}

馮 堯楷^{†††}

内田 誠一^{†††} (正員)

Recognition of Sequential Patterns by Combining Mutually Constrained Local Classifiers

Masahiro FUKUTOMI[†], Student Member,

Koichi OGAWARA^{††}, Yaokai FENG^{†††}, Nonmembers, and

Seiichi UCHIDA^{†††}, Member

[†]九州大学大学院システム情報科学府, 福岡市

Graduate School of Information Science and Electrical Engineering, Kyushu University, Fukuoka-shi, 819-0395 Japan

^{††}九州大学高等研究院, 福岡市

Faculty of Institute for Advanced Study, Kyushu University, Fukuoka-shi, 819-0395 Japan

^{†††}九州大学大学院システム情報科学府, 福岡市

Faculty of Information Science and Electrical Engineering, Kyushu University, Fukuoka-shi, 819-0395 Japan

あらまし 本論文では、時系列パターンの認識手法として、各サンプル点（各時刻）で認識すなわちクラスラベルの決定を行い、最終的にクラスラベル数の多数決によってクラスを確定する手法を検討する。その一つの特徴として、必要に応じて複数サンプル点間に相互制約を設け、それらをできるだけ同じクラスにラベリングする点が挙げられる。これにより、クラスラベルの割当方を制御でき、自由度の高い識別が可能となる。クラスラベルの割当の組合せは総サンプル点数に対し指数関数的に増加する。そこで、グラフの最小切断アルゴリズムいわゆるグラフカットを用いることで、総サンプル点数に対して多項式時間での計算を実現する。オンライン文字データを対象とした認識実験を行い、本手法の有効性を検証した。

キーワード 時系列パターン認識, 多数決型アルゴリズム, オンライン文字, グラフカット

1. ま え が き

本論文では、時系列パターンの2クラス識別手法について検討する。時系列パターン認識手法[1]として、動的計画法(DP)を用いたマッチング法[2]や、Hidden Markov Model(HMM)を用いた手法[3]など多数の方法が提案されている。これら従来の方法では、パターン全体をいっば一つのベクトルのように見て一括して識別するというアプローチがとられている。

これに対し、パターンの各サンプル点ごとに認識すなわちクラスラベルの決定を行い、最終的にクラスラベル数の多数決によってクラスを確定する手法(以下、

多数決型アルゴリズムと呼ぶ)を考えることもできる。上述の従来手法では、あるサンプル点において、標準パターンとの間に非常に大きな差異が発生した場合、そのサンプル点の悪影響が非常に大きくなり、その結果誤認識となる可能性がある。これに対し、多数決型アルゴリズムでは、標準パターンとの差異が非常に大きいサンプル点が存在しても、それが全体に与える悪影響はその差異の大きさによらず $1/N$ であり(N は総サンプル点数)、多数決により正しい認識結果が得られるという利点がある。更に、冒頭数点の時点で認識結果を与えたいような問題設定[4](いわゆる早期認識)との相性もよい。

ただし単純に各サンプル点で独立した識別を行ってクラスラベルを割り当てると、いくつかのサンプル点において散発的に誤認識が発生し、結果的に全体としても誤認識となるおそれがある。そこで本手法では、複数のサンプル点对について、それらのクラスラベルが異なる場合にペナルティ(平滑化項)を与え、なるべく同じクラスにラベリングするという相互制約を設けることにより、散発的な誤認識を抑制する。

更に、各サンプル点における識別器の出力(識別コスト)と平滑化項の和が最小となるクラスラベルの割当方をグラフの最小切断(グラフカット)問題[5]に帰着させて解く。グラフカットは大局的最適化法の一つであり、画像修復[6],[7]、領域分割[8]、物体認識[9]等に多く利用されている。グラフカットにより、 N に対して多項式時間での計算が可能となる。

2. 多数決型アルゴリズム

2.1 多数決型アルゴリズムによる認識

多数決型アルゴリズムでは、サンプル点ごとに2クラス識別を行う。このクラス識別は、第 v サンプル点($v=1, \dots, N$)におけるクラスラベルを $X_v \in \{0, 1\}$ 、識別器の出力(識別コスト)を $g_v(X_v)$ とすると(注1)、次式の $J(X)$ を割り当て $X=(X_1, \dots, X_N)$ について最小化する問題と考えることができる。

$$J(X) = \sum_{v=1}^N g_v(X_v) \quad (1)$$

2.2 相互制約としての平滑化項の導入

サンプル点 u と v 間の平滑化項を $h_{uv}(X_u, X_v)$ とすると、式(1)は次式のように拡張される。

(注1): 正確には $g_v(X_v|y_v)$ と表記すべきであるが(ここで y_v は第 v サンプル点の特徴値)、 $g_v(X_v)$ と略記する。

$$J(X) = \sum_{v=1}^N g_v(X_v) + \sum_{(u,v) \in E} h_{uv}(X_u, X_v) \quad (2)$$

ここで、 E は 2 点対を表す集合で、 $(u, v) \in E$ のとき u と v 間に平滑化項が存在している。また、以下のとおり、平滑化項は非負の値を取り、2 サンプル点のクラスラベルが同じであれば零になるように定める。

$$h_{uv}(X_u, X_v) \begin{cases} = 0 & \text{if } X_u = X_v \\ \geq 0 & \text{otherwise} \end{cases} \quad (3)$$

3. グラフカットによる解法

式 (2) の $J(X)$ を最小化することを考える。クラスラベルの割当方は、総サンプル点数 N に対して 2^N 通り存在するため、総当りのな方式では膨大な計算時間を要する。ところで、式 (2) の平滑化項が submodularity と呼ばれる条件 $h_{uv}(0,0) + h_{uv}(1,1) \leq h_{uv}(0,1) + h_{uv}(1,0)$ を満たす場合には、グラフカットによって N に対する多項式時間で大局的最適解を得られることが知られており [5]、式 (3) はこの条件を満たすため、本研究ではグラフカットを用いる。

グラフカットでは、まず有向グラフ $G = (V, E)$ を準備する。 V は頂点の集合であり、 N 個のサンプル点それぞれに対応した頂点 v と、2 頂点 s, t から構成される。 $E \subset V \times V$ は辺の集合であり、 s から v への辺と v から t への辺及び頂点間の辺から構成される。また、辺 $(s, v), (v, t), (u, v)$ には、それぞれ $g_v(1), g_v(0), h_{uv}(0,1)$ を重みとして付与する。図 1 にグラフの例を示す。

次に、 $s \in S, t \in T, V = S \cup T, S \cap T = \phi$ を満たすように、頂点集合 V を S と T に分割 (切断) する。関数 $J(X)$ の最小化問題は、切断された辺の重みの和が最小となる最小切断を求める問題に帰着し、最大流最小切断定理に基づくグラフカットアルゴリズム




図 1 (a) 平滑化項が存在する点対 (実線), (b) グラフ
Fig. 1 (a) Sample point pairs that have smoothness terms (solid line), (b) Graph.

により多項式時間で解くことができる。最後に、 S 側の頂点に 0、 T 側の頂点には 1 のラベルを割り当て、ラベルの多数決により入力パターンのクラスを決定する。

4. 平滑化項の学習法

平滑化項 $h_{uv}(X_u, X_v)$ の値は認識対象に応じて適切に設定される必要がある。これまでに、平滑化項を学習データから学習する手法 [6], [7], [9] が提案されているが、一般的な手法は確立されていない。本手法では、図 2 の反復改善による学習法に従って決定する。

ただし同図で平滑化項とは非負になるように制約された $h_{uv}(0,1)$ 及び $h_{uv}(1,0)$ を指し、常に 0 に固定されている $h_{uv}(0,0)$ 及び $h_{uv}(1,1)$ は含めない。また、誤認識の単調減少性を保証できないため、反復のうちで誤認識数が最小となったターンの平滑化項の値を学習結果とする。初期値 h_0 は経験的に与えている。

5. オンライン文字の認識実験

5.1 実験条件

提案手法の効果を検証するために、オンライン文字に対する 2 クラス認識実験を行った。実験には Ethem Alpaydin Digit の 0-9 のオンライン文字データを使用し、学習用に各数字 700 パターン、テスト用に各数字 300 パターンを用いた。各サンプル点における特徴値にはそのサンプル点の座標特徴 (x, y 座標) を用いた。前処理として一画化、文字の大きさ (外接方形の大きさ) が一定となるよう正規化を施し、また総サンプル数 N が 49 になるようリサンプリングを行った。各サンプル点での識別には学習パターンの分布によるマハラノビス距離を用いた。

5.2 実験結果

4. で述べた手法を用いて平滑化項を学習し、学習し

1. 初期値として、 (u, v) が隣接サンプル点であれば、その平滑化項を非負定数 h_0 に初期化し、そうでなければ零とする。ここでは、 u と v が時間的に隣り合うサンプル点すなわち $v = u + 1$ のとき、 (u, v) を隣接サンプル点とする。
2. すべての学習パターンに対し最適ラベル割当並びに多数決認識を行う。
3. 各 (u, v) について
 - ・ (u, v) が切断されており、認識結果は正しい
 - ・ (u, v) が切断されており、認識結果は誤り
 となった学習パターン数 C_1, C_2 を求める。
4. 各 (u, v) について
 - ・ $C_1 > C_2$ の場合、平滑化項を $-\epsilon$ 。
 - ・ $C_1 < C_2$ の場合、平滑化項を $+\epsilon$ 。
5. 誤認識数の変化がなくなるまで、若しくは一定回数繰り返す。

図 2 平滑化項の学習アルゴリズム

Fig. 2 Algorithm for learning smoothness terms.




図3 学習後に平滑化項が非零となったサンプル点对
Fig. 3 Sample point pairs that have non-zero smoothness terms.

表1 オンライン文字の認識率 [%]
Table 1 Recognition rate for online characters [%].

平滑化項	なし	隣接点のみ		学習により最適化
		(一定値)	(無限大)	
“6”-“9”	90.2	95.8	94.2	97.8
“5”-“8”	94.3	97.5	97.5	97.5
全体平均	91.6	93.8	93.9	94.3

た平滑化項を用いて認識実験を行った。クラス“0”-“9”のうち二つからなる組合せ45組全部の認識に要した時間、すなわち $300(\text{サンプル}) \times 2(\text{クラス}) \times 45(\text{対}) = 2.7 \times 10^4$ 回のラベル割当処理に要した時間は、民生用PCを用いて30s以下であった。したがって1回当りおよそ1msであり、十分高速といえる。

図3に、平滑化項が非零である2点の組をプロットしたものを示す。学習の結果、多くの2点間で平滑化項が非零であるクラス対と、平滑化項が隣接サンプル点間以外で零となるクラス対が見られた。図3には、前者の代表としてクラス対“6”-“9”を、後者の代表としてクラス対“5”-“8”を示している。

認識実験の結果を表1に示す。多くの平滑化項が非零であるクラス対“6”-“9”では認識率が向上しているが、平滑化項が隣接サンプル点間以外で零であるクラス対“5”-“8”では認識率に大きな変化は見られない。

クラス“6”と“9”では後半の形状が大きく異なるため、図4(a)に示すとおり、不正解ラベルが割り当てられたサンプル点(×印)より正解ラベルが割り当てられたサンプル点(○印)の方が多い。そのため、認識が容易であるサンプル点間に平滑化項を導入することで、図4(b)のように正解ラベルがより多く割り当てられると考えられる。また、形状が類似している前半部分では、不正解ラベルが多く割り当てられており、平滑化項は隣接サンプル点間以外零となっている。

全体平均では平滑化項により認識率の向上が見られる。特に単純多数決(平滑化項なし)並びに、従来のマッチング型識別(平滑化項無限大)に比べ、平滑化




図4 クラス対“6”-“9”の認識例 (a) 平滑化項なしの場合、(b) 学習した平滑化項を用いた場合
Fig. 4 Recognition of the class pair “6”-“9” (a) Without smoothness term, (b) With smoothness term.

項を適切な一定値に設定した場合や学習により最適化した場合の結果が優位であることは、平滑化項を導入した多数決型アルゴリズムの有用性を示している。

6. むすび

時系列パターンの認識のために、多数決型アルゴリズムを提案した。これは各サンプル点において2クラス識別すなわちクラスラベルの決定を行い、最終的にクラスラベル数の多数決により認識を行う手法である。サンプル点間に平滑化項を導入することにより、任意のサンプル点对をできるだけ同じクラスにラベリングするという制約を設けた。また、グラフカットを用いて各サンプル点へのクラスラベル割当の最適化を行い、非常に高速に大域的最適解が求まることを示した。本手法の有効性を検証するため、オンライン文字データを対象として認識実験を行い有効性を確認した。

今後の課題として、平滑化項の学習法の検討、画像のような二次元的なパターンへの拡張、時間伸縮への対応がある。他に、多クラス同時識別への対応が挙げられる。単純には多クラス識別は、2クラス識別の組合せを行う方法があるが、いわゆる三すくみの問題が残る。より本質的な対応として、 α -expansion等に基づくグラフカットの多値化も考えられよう。また各サンプル点における識別器の構成法も一考の余地がある。時間的拘束付きのboosting [10]による学習などが参考になるであろう。

文 献

- [1] 川嶋宏彰, 西村拓一, “コンピュータビジョンにおける時系列パターン認識,” 情処学研報, 2006-CVIM-154, pp.197-209, 2006.
- [2] 内田誠一, “DP マッチング概説—基本と様々な拡張,” 信学技報, PRMU2006-166, 2006.
- [3] L.R. Rabiner and B.H. Juang, “An introduction to hidden markov models,” IEEE ASSP Mag., vol.3, no.1, pp.4-16, 1986.

-
- [4] S. Uchida and K. Amamoto, "Early recognition of sequential patterns by classifier combination," Proc. ICPR, ThAT4.6, 2008.
- [5] V. Kolmogorov and R. Zabih, "What energy functions can be minimized via graph cuts?," IEEE Trans. Pattern Anal. Mach. Intell., vol.26, no.2, pp.147–159, 2004.
- [6] S. Kumar and M. Hebert, "Discriminative fields for modeling spatial dependencies in natural images," Advance in Neural Information Processing Systems 16 (Proc. NIPS, 2003), pp.1531–1538, 2004.
- [7] D. Cremers and L. Grady, "Statistical priors for efficient combinatorial optimization via graph cuts," Proc. ECCV, pp.263–274, 2006.
- [8] Y. Boykov and M.P. Jolly, "Interactive graph cuts for optimal boundary region segmentation of objects in n-d images," Proc. ICCV, pp.105–112, 2001.
- [9] D. Anguelov, B. Taskar, V. Chatalbashev, D. Koller, D. Gupta, G. Heitz, and A. Ng, "Discriminative learning of markov random fields for segmentation of 3d scan data," Proc. CVPR, pp.169–176, 2005.
- [10] R. Vidal and P. Favaro, "Dynamicboost: Boosting time series generated by dynamical systems," Proc. ICCV, pp.1–6, 2007.
- (平成 21 年 7 月 17 日受付, 12 月 18 日再受付)
-