

DPマッキング法とその応用

日本電気株式会社中央研究所 追江博昭

1. まえがき

音声パターンは代表的な時系列パターンであつてその時間軸正規化の問題に対しては古くから種々の試行がなされている。ここで述べるDPマッキングはAnalysis by Synthesisの考え方を立脚するものである。すなわち、時間軸変動を非線形変換で近似してモデル化し、モデル化された変動のもとで入力パターンと標準パターンとの間の最大一致をとることによって時間軸変動の影響を除去する。実際の計算の段階でダイナミックプログラミングが有効に利用されるのでこの方法をDPマッキング法と称している。

以下ではDPマッキングの考え方とその実行アルゴリズムを述べ、次いで単語音声認識、連続単語音声認識、識別関数学習、手書き文字認識などへの適用・実験例を示している。

2. DPマッキング

2.1 時間軸変動のモデルと時間正規化類似度

音声パタンをベクトル値を取る時間関数として

$$A = A(t) \quad ; \quad 0 \leq t \leq T_A \quad (1)$$

で示す。時間軸の変動を時間軸 t の非線形変換

$$t = u(s) \quad ; \quad 0 \leq s \leq T \quad (2)$$

によって近似する。ただし、

$$u(s) \in U \quad (3)$$

ここに、 U は変換されたパタン $A' = A(u(s))$ が A と同じ単語クラスに属するような $u(s)$ の集合を規定する。同様に別の音声パタン $B = B(t) ; 0 \leq t \leq T_B$ (4)

を考へ、(2)(3) 式に対応して次の(5)(6) 式を考える。

$$t = v(s) \quad ; \quad 0 \leq s \leq T \quad (5)$$

$$v(s) \in V \quad (6)$$

A と B の時間軸正規化類似度(以下類似度と略称)を

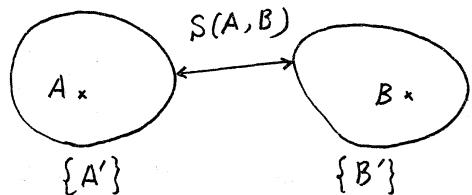
$$S(A, B) = \frac{1}{T} \min_{u(s), v(s)} \left[\int_0^T \|A(u(s)) - B(v(s))\| ds \right] \quad (7)$$

と定義する。この尺度は $A' = A(u(s))$ の集合 $\{A'\}$ と $B' = B(v(s))$ の集合 $\{B'\}$ の間の距離となつており(7.1), 次の性質をもつ。

$$(i) S(A, B) \geq 0 \quad (ii) S(A, A) = 0$$

$$(iii) S(A, B) = S(\tilde{A}, \tilde{B}) \quad \text{if } \tilde{A} \in \{A'\} \quad \tilde{B} \in \{B'\}$$

このように時間軸変動に対して
安定な性質は音声パターンのマッ
チング尺度として理想的である
と言えども、以上の定義をそのまま
実行することは困難で、Fig. 1 $S(A, B)$ の定義、
いくつかの近似が必要である。



2.2 類似度の近似式(対称形)

(3)(6) 式の条件は具体的には、音声パターンの各音素の継続長やスペクトラムの変化速度を限定するなどの意味を持つが、この条件を完全に実現するには音素レベルの認識が完了していなくてはならず実際的でない。よって次の条件で(3)式を近似する((6)式の $\mu(s)$ に対しても同様)

- | | | | |
|------------------------------------------------|-------------------|---|-----|
| (i) $u(s)$ は連続 | (ii) $u(s)$ は單調増加 | } | (8) |
| (iii) $u(s) \sim s$ すなわち $u(s)$ の値は s の近傍にある | | | |

これらの条件のもとに DP を適用することによつて(7)式の最小問題は一応計算可能であるが、 $u(s)$ と $\mu(s)$ に関する 2 次元の最小問題となり所用計算量は必ずしも少くない。よつて次のような近似で 1 次元の問題に縮小する。

$$\text{対称形の近似} \quad s = (u(s) + \mu(s))/2 = (\tau + \tau)/2 \quad (9)$$

$$\text{これより} \quad ds = (d\tau + d\tau)/2 \quad (10)$$

となり類似度 $S(A, B)$ は次のように近似される。

$$S_1(A, B) = \frac{1}{(T_A + T_B)} \min_{w(t)} \left\{ \sum_{x=2}^{\infty} \|A(x) - B(x)\| (2^{x-1} dt) \right\} \quad (11)$$

$$\text{ここで}, \quad w(t) = U(V^{-1}(t)) ; \quad 0 \leq t \leq T_A \quad (12)$$

2.3 DPによる計算

音声パターン A, B を時間標本化して

$$A = a_1, a_2, \dots, a_i, \dots, a_I ; \quad B = b_1, b_2, \dots, b_j, \dots, b_J \quad (13)$$

と示す。 i と j の組合せの点 (i, j) を $(i+j)$ に関して正順にとり、番号 $k = 1 \sim K$ ($K = I + J$) を付して $(i(k), j(k))$ で示す。ただし、

$$i(1) = 1 \quad j(1) = 1, \quad i(K) = I \quad j(K) = J \quad (14)$$

とし、かつ隣り合う点の間には (8) の条件 (i) (ii) を考慮して

$$\begin{aligned} i(k) &= i(k-1), \quad j(k) = j(k-1) + 1 \\ \text{or } i(k) &= i(k-1) + 1, \quad j(k) = j(k-1) \\ \text{or } i(k) &= i(k-1) + 1, \quad j(k) = j(k-1) + 1 \end{aligned} \quad \left. \right\} \quad (15)$$

の 3 種の関係のみを許す。

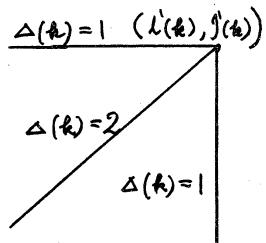
$$\text{いま } d(i, j) = \|a_i - b_j\| \quad (16)$$

とし、(10) 式に対応して

$$\Delta(k) = (i(k) - i(k-1)) + (j(k) - j(k-1)) \quad (17)$$

とおくと (11) 式は

$$S_1(A, B) = \frac{1}{(I+J)} \min_{i(k), j(k)} \left\{ \sum_{k=1}^K d(i(k), j(k)) \cdot \Delta(k) \right\} \quad (18)$$



となり、次のようなDP法の手続きで計算される。

$$\left. \begin{array}{l} \text{初期条件} \quad g(0, 0) = 0 \\ g(i, 0) = \infty \quad (i \neq 0) \\ g(0, j) = \infty \quad (j \neq 0) \end{array} \right\} \quad (19)$$

漸化式

$$g(i, j) = \min \left[\begin{array}{l} d(i, j) + g(i-1, j) \\ d(i, j) + g(i, j-1) \\ 2d(i, j) + g(i-1, j-1) \end{array} \right] \quad (20)$$

$$(1 \leq i \leq I, 1 \leq j \leq J)$$

制約条件（整合窓の条件）

$$j-r \leq i \leq j+r \quad (21)$$

類似度

$$S(A, B) = \frac{g(I, J)}{(I+J)} \quad (22)$$

(21) 式の整合窓の条件は(8)の(iii)の条件を近似する。

2.4 非対称形の近似⁽²⁾

(9)式のかわりに

$$S = u(S) = \sigma \quad (23)$$

とする。このとき(17)式は

$$S_2(A, B) = \frac{1}{T_A} \min_{u(t)} \left[\int_0^T \|A(t) - B(t)\| dt \right] \quad (24)$$

となり、対称形の場合とほぼ同様の手続きで計算できる。

この場合にはAの時間軸tを標準として固定してBの時間

軸 t を最適に変換し、 t 軸上で比較していることになる。これに対して対称形では A と B の時間軸のズレ($t - \tau$)を最適に補正して $(t + \tau)$ 軸の上で比較していることになる(Fig. 2)。

対称形と非対称形の優劣を一般的に論ずることはむずかしい。しかし対称形では

$$0 \leq \frac{dt}{ds} \leq 1, \frac{ds}{dt} \leq 1$$

非対称形では

$$\frac{dt}{ds} = 1, 0 \leq \frac{ds}{dt} < \infty$$

であることを考えると、対称形の方が両方のパターンを"より均等に比較する"性質をもつてていると言える。実際には、 A と B の時間軸が元来異なる(たとえば標本化周期が異なる)時は一方の時間軸を基準と考えて非対称形を用い、そうでない時は対称形によるのが適当であろう。

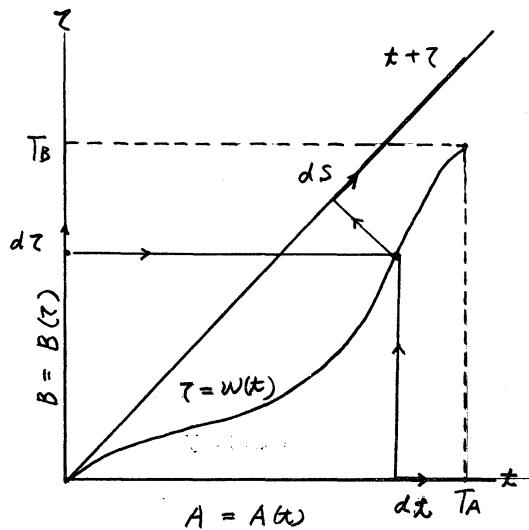


Fig. 2 対称形 DPマッチング

3. DPマッチングの応用と実験例

3.1 單語音声認識⁽²⁾⁽³⁾

10ケヤヘルの分析ファイルタ出力を20ms周期で標本化したパターンを用い、男性10名、女性5名の合計1500サンプルの数字単語の認識を行なった結果を表1に示す(強制判定)。標準パターンは各人の10数字2回を用いた。この実験では対称形の

類似度による方が非対称形による場合に比して格段に良い結果が得られている。

	男性 10名	女性 5名	合計
対称形	0.1	0.0	0.07
非対称形	0.5	0.0	0.34

表1 数字単語 認識結果 誤り率(%)

男女各2名の地名单語合計1000サンプルを認識した結果98.1%の認識率であった(標準パターンは各单語1個)。極端な時間軸変換を排除してクラス間の分離を改善するために $\tau = w(t)$ の傾斜に制限を導入して、

$$\frac{2}{3} \leq \frac{dt}{ds}, \frac{d\tau}{ds} \leq 1 \quad (26)$$

と制限してマッチングを行なうことによって認識率が99.2%に改善された。

3.2 連続单語認識⁽¹⁾⁽⁴⁾

各单語クラス間に標準パターン B^n を設定する。入力パターンAは何個かの单語を連續発声したものであるとする。Aの部分パターン A_l を次のように定義する。

$$A_l = \alpha_1, \alpha_2, \dots, \alpha_n \quad (27)$$

(18)式を拡張してAの第1单語とBの類似度を

$$S_1(A, B) = \min_{J-r \leq l \leq J+r} [S_1(A_l, B)] \quad (28)$$

と定義する。すべての標準パターン B^n について $S_1(A, B^n)$ を求めてそれが最小となる $n = n_1$ を第1单語の認識結果とする。

次に B^{n_1} と B^n を接続したパタン $B^{n_1} \cdot B^n$ を標準パタンと考えすべての n について $S_1(A, B^{n_1} \cdot B^n)$ を計算し、それが最小となる $n = n_2$ を第2単語の認識結果とする。このとき DP 計算は B^{n_1} の部分に関してはすでに終了しているので残りの B^n の部分について行なうと十分である。第3単語以下に関しても同様である。この手続きでは単語間のセグメンテーションは不用であり、しかも所用計算量はセグメンテーションを行なつて認識する場合と同等である。

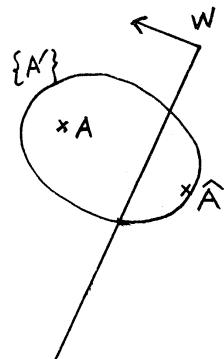
男性 5 名の 2 衔数字合計 500 個に対する実験結果を表 2 に示す。標準パタンとしては各人の 1 衔数字 2 回を用いている。なお、別の実験では(26)式の傾斜制限を導入することによって誤り率が 2.2% から 0.5% に低減されたという結果が得られた。

発声者	認識率(%)
A	99.5
B	99.5
C	100
D	99.5
E	99.0
平均	99.6

表 2 2 衔数字認識結果

3.3 識別関数学習問題への適用⁽⁵⁾

ペーセプトロン式の誤訂正過程において、訓練パタン A を時間軸に關して変形して現在の識別関数 W で最も分離しにくいう形 \hat{A} として用いることによつて時間軸変動に対して安定な識別関数が能率良く得られる。パタンの変形は非



対称形の DP マッチングで効率良く処理できる。男性 1 名の数字音声に関する実験では、通常の学習で 91.3% であつたものが、 $r = 3$ の範囲で変形して学習することによつて 99.5% に改善された。なお、この方法は LP による識別関数計算にも適用できる。

3.4 手書き文字認識への適用 (Rubber String matching⁽⁶⁾)

手書き文字は本質的に線図形であつて線分の系列として近似できる。各線分の方向を固定して線分長を独立に変化させることによつて文字パターンの変動をモデル化する。このモデルによると文字の拡大・縮小の他に回転や字体の本質的な変形をも良好に近似できる。よつて標準パターンを方向が指定される線分の系列で与え、各線分の長さを変数として、2 次元メッシュ状の入力パターンとの間に一致度の評価関数を加法的に定義してその最大化を DP によつて行なうことにより、文字パターンの変動に対して安定なマッチングを効率よく行なうことができる。

20 名の手書き数字 2000 サンプルに対する予備的な実験では 12 個の標準パターンで 99.95% 正しく認識できるという結果を得ている。

この方法は、元来時間軸の無い 2 次元パターンに自動的に時間軸を発生し、正規化し、マッチングを行なう手続きになつ

ており、マッキングの結果として入力パタンを線分系列で最適に近似したパタンが得られるという特徴をもつていて。

4. むすび

以上、DPマッキングの考え方とその実行アルゴリズム及び応用・実験例を述べた。2.2 及び 2.3 節で導入した幾つかの近似は、実験結果から見て、実用上さしつかえないものと考えられる。実際には所用計算量が問題になるが、NEAC M4/n ミニコンピュータに専用の DP プロセッサを接続したシステムで 100 語の準語セットに対して実時間認識が可能なシステムをすでに実現している⁽⁷⁾。また文字パタンに対しても十数字の文字セットに対して毎秒 100 字程度の読み取り速度をもつ装置を構成することは容易であると考えている。

謝辞 日頃御指導いただく加藤研究課長に深謝します。
また以上の研究のほとんどについて指導いただき、また共同研究者でもあつた千葉研究主任に心から謝意を表します。

文献

- (1) 追江・千葉 音響誌 Vol.27 No.9 P.483 (1971)
- (2) 追江・千葉 音楽学会音声研究資料 S73-22 (1973)
- (3) 追江 音学大会予稿 1-2-15 (1974-6)
- (4) 追江 " " " 2-2-19 (1974-10)
- (5) 追江 信学全大予稿 53 (1972)
- (6) 追江 信学研究資料 PRL-74-20 (1974)
- (7) 鶴田・追江・千葉 信学全大予稿 1596 (1974)