

DP マatching 法とその応用

日本電気株式会社中央研究所 迫江 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っ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みがなされている。ここで述べる DP マatching は *Analysis by Synthesis* の考えに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atching 法と称している。

以下では DP マatching 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atching

2.1 時間軸変動のモデルと時間正規化類似度

音声パター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 は変換されたパターン $A' = A(u(s))$ 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

$$\text{音声パターン} \quad B = B(\tau) \quad ; \quad 0 \leq \tau \leq T_B \quad (4)$$

も考え、(2)(3) 式に対応して次の(5)(6) 式を考える。

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

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

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 $\{B'\}$ の間の距離となっており(Fig. 1), 次の性質をもつ。

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

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

このように時間軸変動に対して
安定な性質は音声パタンのマッ
チング尺度として理想的である
と言えるが、以上の定義をその
まま実行することは困難で、い
くつかの近似が必要である。




Fig. 1 $S(A, B)$ の定義

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のでない。よって次の条件で(3)式を近
似する((6)式の $u(s)$ に対しても同様)

- (i) $u(s)$ は連続 (ii) $u(s)$ は単調増加 } (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って(7)式の最
小問題は一応計算可能であるが、 $u(s)$ と $v(s)$ 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なくない。よっ
て次のような近似で 1 次元の問題に縮小する。

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

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

となり類似度 $S(A, B)$ は次のように近似される。

$$S_1(A, B) = \frac{1}{(T_A + T_B)} \min_{w(t)} \left[\int_{z=w(t)} \|A(t) - B(z)\| (dt + dz) \right] \quad (11)$$

$$\text{ここに, } w(t) = u(v^{-1}(t)) ; \quad 0 \leq t \leq T_A \quad (12)$$

2.3 DPによる計算⁽¹⁾⁽²⁾

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

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

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。

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

漸化式

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

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

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

$$S = u(s) = t \quad (23)$$

とする。このとき (17) 式は

$$S_2(A, B) = \frac{1}{T_A} \min_{u(t)} \left[\int_{\substack{0 \\ \tau = u(t)}}^T \|A(t) - B(\tau)\| dt \right] \quad (24)$$

となり，対称形の場合とほぼ同様の手順で計算できる。

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 τ 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

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

非対称形では

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

であることを考えると, 対称形の方が両者のパターンを“より




Fig. 2 対称形 DP マッチング

均等に比較する”性質をもっていると言える。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。

3. DP マッチングの応用と実験例

3.1 単語音声認識⁽²⁾⁽³⁾

104チャンネルの分析フィルタ出力を 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(標準パターンは各単語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,

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

と制限してマッチングを行なうことによつて認識率が99.2%に改善された。

3.2 連続単語認識⁽¹⁾⁽⁴⁾

各単語クラスに標準パターン B^n を設定する。入力パターン A は何個かの単語を連続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。

$$A_l = a_1 a_2 \dots a_l \quad (27)$$

(18) 式を拡張して A の第1単語と B の類似度を

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

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単語の認識結果とする。

次に B^{n_1} と B^n を接続したパターン $B^{n_1} \cdot B^n$ を標準パターンと考え、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ため残りの 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要であり、しかも所用計算量はセグメンテーションを行なって認識する場合と同等である。


男性5名の2桁数字合計500個に対する実験結果を表2に示す。標準パターンとしては各人の1桁数字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%に低減される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桁数字認識結果

3.3 識別関数学習問題への適用⁽⁵⁾

パーセプトロン式の誤訂正過程において、訓練パターン A を時間軸に関して変形して現在の識別関数 W で最も分離しにくい形 $\hat{A}$ として用いることによって時間軸変動に対



して安定な識別関数が能率良く得られる。パターンの変形は非

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% であったものが、 $r=3$ の範囲で変形して学習することによって 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って線分の系列として近似できる。各線分の方角を固定して線分長を独立に変化させることによっ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。よっ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 によっ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っ

ており、マッチングの結果として入力パターンを線分系列で最適に近似したパターンが得られるという特徴をもっている。

4. おすび

以上、DPマッチ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語の単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⁾。また文字パターンに対して数十文字の文字セットに対して毎秒100字程度の読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、共同研究者でもあった千葉研究主任に心から謝意を表します。

文献

- | | | |
|--------------|-----------------------|-----------|
| (1) 迫江・千葉 | 音響誌 Vol.27 No.9 P.483 | (1971) |
| (2) 迫江・千葉 | 音響学会 音声研資 573-22 | (1973) |
| (3) 迫江 | 音学大会予稿 1-2-15 | (1974-6) |
| (4) 迫江 | " " " 2-2-19 | (1974-10) |
| (5) 迫江 | 信学全大予稿 53 | (1972) |
| (6) 迫江 | 信学研資 PRL-74-20 | (1974) |
| (7) 鶴田・迫江・千葉 | 信学全大予稿 1596 | (1974) |