

漢字ドット・フォントからベクター・フォントへの変換

間下浩之

日本アイ・ビー・エム(株) 東京サイエンティフィックセンター

はじめに

漢字仮名混り文の処理が各所で行なわれるようになり、各種の漢字入出力装置[1][2]が出来てきました。東京サイエンティフィック・センターでは計算機の適用分野の拡大を目的に、日本語処理、画像処理、图形処理等の研究を行なっており、特に日本語処理のために漢字入出力の段階での融通性が必須となります。漢字を取り扱う適用分野、たとえば情報検索システム、高級編集システム等、における会話型システムについては表示装置が最大の問題となります。以下の要件があげられます。

- ① 漢字・画像・图形を同時に表示したい。
- ② 拡大・縮小・回転を容易に自由に行ないたい。

これらの要件を満足して画像・图形を容易に表示可能な映像表示装置(IBM 3250 映像表示装置[3])、3277 GRAPHIC ATTACHMENT + 映像表示装置[4]等)に同時に漢字等の文字も表示することを考えた。②の要件により字体発生方式はドット方式と比較してストローク方式(ベクターによりデータを持つ)の方が良い。しかしハードウェアによる文字発生は以下の理由で困難をため、ソフトウェアで補うこととした。


- 1) 文字によるデータ量が異常なデータである。[5]
- 2) 表示制御部の論理が複雑になる。[5]

一般にドット方式はかなり普及しているため、数多くの字体が存在するが、ベクター方式による字体(ベクター・フォント(ベクター字体))はほとんど手にはいらぬ状態である。本報告はドット字体からベクター字体作成のための変換を行なったので、その算法について述べる。また字体として 18×18 骨粗型字体、32×32明朝体について実験を行なったのでその差異についても述べる。

1. 18×18字体による実験

1.1 前提

- ① 字体は骨粗型で厚みを持つことないものとする。すなはち、ゴチック体や明朝体ではなく、表示装置用として使用するよう 18×18 の文字である。
- ② 結果のデータは X, Y 座標の相対番地(X, Y = 0 ~ 17)で表わす。始点・終点の文字情報をとるとデータ量が多くなるため、前の線分の終点と次の線分の始点が同じ場合は片方が省略できるようになる。ただしデータ中に制御文字(CC)を挿入した場合は、"ランク・ベクター"が引かれると考える。すなはち図 1 の文字は右のようにデータにする。これによりデータ量は最小となる。



1.2 走査の方法

① 处理1

図2のようき2次元の対象にたいして、縦、横、を
求め(45度)の4通りの走査を行なう。4通りの走査
によつて得られた線分の始点と終点の値を表1に挿入
する。表1の左側の数字は 18×18 の2次元配列の番地
を表わす。表の5列のうち左4列は4つの各方向によ
つてどの番地と結ばれたかを示す。4通りの走査を方
向性を持たせないように互いの番地に同じ情報を持た
せるようにする。たとえば番地1は①の走査で番地5
と結ばれ、番地5は①の走査で番地1と結ばれている。
一番右の列は結ばれた線分の本数である。始点・終点
の決定については後の規則の項でふられる。

② 处理2

表1の性質として“数が奇数である番地は、必ず始
点が終点に残りうる。”といふことがいえる。処理2
ではこの表を図1に示したようなペウターのデータに
するこれが役割である。処理12回のパスに分け1回
目には数が奇数である番地をすべて検索する。はじめに番
地3が見つかったら、その数から1を引き4つの列の
うちデータのある番地37へ飛ぶ。番地37で同じ処理が
行なわれ、飛べるくなる番地まで進む。その経路は番地
4から同様の処理が行なわれる。この操作を最後まで
行なうと必ず表1は数が偶数ばかりの番地だけになる。
2回目のパスは数が1以上であるものすべてに適用し
1回目と同じことを行なう。この操作の結果のデータ量は最小となる。




図2

	→	↓	/	\	数
1	5				324 2
2					
3			37		1
4					
5	1				
322	324				1
323					
324	322	288		1	3

表1

1.3 実験1

処理1の始点・終点の決定において何の規則ももうけきりと図3のようにならなければ
なくてよい線分をわけて引くことにする。




図3

これを防ぐために簡単な基本規則をもうける。ここである線分の両はじめの点を
端点、それ以外の点を通過点と呼ぶ。

基本規則1

ある線分を考えた場合、それに所属するすべての点が他の線分の通過点であるならば、この線分は引かない。

この規則に従って簡単な実験を行なった結果以下の問題が生じた。

図4がこれを表わしているが、引かなければいけない線分が別々線分（この場合は左のもの）と干渉を起こして引かなくていいとき、である。漢字にはこのうちを1°ターンが数多く出現する。この点を考慮して基本規則を多少修正したものが基本規則1'である。




図4

基本規則1'

基本規則1の条件を長さ1のものだけに適用する。（長さ1とは端点どうしを結ぶ線分を表わし、以後長さmとはm+1の点を包含する線分を表わす）。ただし左のものに同じくはこれをあわせめまい。

国立国語研究所、現代雑誌90種用字用語調査における上位2000字（頻度順）について、基本規則1'を適用して行なった実験結果は以下の通りである。

成功 1346字 67.3%

失敗 654字 32.7%

失敗例を図5に示す。




図5

結果の考察

ななめの線分が問題になると想われるが、⑥, ⑦, ⑧, ⑨, ⑩, ⑪は縦、横の線分が問題となつた。⑫に関しては当然予想される結果であるが、二の形を持つ字が1%程度あり、た。

1.4 実験2

実際に使う立場として、標準の大きさの0.5倍から1.2倍程度まではこれらの欠点が目立たないが、それ以上に拡大した場合にこの成功率では問題がある。そこで成功率90%以上に向上させるために以下の特別な追加規則をもうけて実験してみることにした。

追加規則

1. 縦、横用

①長さ2で、すべての点が他の線分の通過点であり、真中の点を通る他の線分がその点によつて長さ2以上ずつに分割されている場合、この線分は引かない。図5の⑥, ⑩の修正である。

②つぎのパターンを持ったものは端点をずらす。図5の⑦の修正である。



③長さ1で上の端点が他の線分の通過点で、もう1つの端点が別の長さ2以上の線分の端点のつぎの2点が他の線分の通過点である場合は除く。次の図の様な場合が考慮される。図5の⑥, ⑪の修正である。




例外を考慮した場合

(ここではななめの線を考慮しない)


例外を考慮しなかった場合

2. ななめ用

①線分Xの端点A₁が他の線分の通過点であり、端点のとなりの点A₂が長さ3以上の他の線分の端点又は他の線分の通過点である場合、線分Xの端点はA₂となる。ただしA₂が他の線分の通過点でありA₃が長さ3以上の他の線分の端点であるときには、線分Xの端点はA₃となる。



⑥, ⑦, ⑩, ⑪の修正



⑥, ⑩の修正

②長さ 1 で 1 つの端点が他の線分の通過点で、もう 1 つの端点が他の線分の端点で A_1 あるいは A_2 に点があるとき、この線分は引かない。




ただし二の規則は必ず①の規則の後に適用した方が有効である。②は①、②と並べてみると正常になる。

3. 特別用

④のために特別に作られた規則である。処理上、処理 2 が終了した後に、制御文字から制御文字までの線分の数が 3 以上ものの検査する。その時に X_1, Y_1 をそれとの差分をと、それらが以下のパターンに当たるときは調整を行う。

$$X_1, Y_1, X_2, Y_2, X_3, Y_3, X_4, Y_4 \quad \text{---} \rightarrow$$

	$X_1 - X_2$	$Y_1 - Y_2$	$X_2 - X_3$	$Y_2 - Y_3$	$X_3 - X_4$	$Y_3 - Y_4$	差分
①	0	m	1	1	0	n	
②	1	1	0	m	1	1	



1 の部分は -1 もよい。①の場合 $X_2 Y_2$ を、②の場合 $X_3 Y_3$ を削除してそれを $X_1 Y_1$ と $X_3 Y_3$ と、 $X_2 Y_2$ と $X_4 Y_4$ を連結する。

このようすを追加規則によつて同じ 2000 字を実験した結果は以下の通りである。

成功	1936 字	96.8 %
失敗	64 字	3.2 %

失敗例を図 6 に示す。




図 6

結果の考察

②', ③', ④', ⑤' に見られるように、失敗の大部分は連結してはいけないものを連結している現象である。これらは小さな範囲しかチェックしきり規則では解決できず、困難な問題である。②' は追加規則上 - ① の拡張で解決できるかもしれない。④', ⑤' は追加規則上 - ②' にと、引き起こされた現象である。正解は片方が延長されて連結しなければならぬのが、厳密に見なければ問題ないかもしれない。

2. 32 × 32 文字による実験

2.1 前提

- ① 文字は印刷装置等にも使用可能な 32×32 ドット・マトリックス明朝体である。
- ② 結果は 18×18 の場合と同様のデータ形にする。

2.2 走査の方法

18×18 と同じ方法で実験をすると、厚みを持つ文字のためまわりぶらに走査が目立つ。それを解消するため 1, 2 における 4 方向に 30 度, 60 度といい、左角度の方向 4 つを追加してみた。図 7 のように 8 方向の走査を行なう。よって 1, 2 の処理②における表 1 は 4 列追加されることになる。当然のことながら行は $(32 \times 32 - 18 \times 18 = 700)$ 行追加となる。




図 7

	→	↓	↗	↖	↑	↘	↙	数
1	5		6		8			3
2						5		1
3		5				2		2
4	150		100					2
5	1	3					2	
6			1				1	
1022					1024			1
1023		1000						1
1024					1022			1

表 2





図 8

18×18 の基本規則 1 を用いて実験を行なうと図 8 のようになる。厚みのある字體のため、ふらどりは重要であるが内部は線分を引かずくでかまわない。図 8 にあひてはまだ余分な線分があるため次の規則によつてそれらの消去を試みた。

基本規則 2

あひ線分を考えた場合、それに所属するすべての点のうち 1 点以外が他の線分の通過点であるならばその線分は引かずることとする。ただし新たに追加した 30 度と 60 度の 4 方向についてでは、すべての点が通過点である場合に限り線分を引かない。

この規則によつて実験した結果を図 9 に示す。




図 9

これにより余分な線分はかなり取り除かれる。図 8 に比べてデータ量としては 1~2 割程度減少しているようと思われる。

このように 24×24 , 32×32 , 48×48 等の字體にあひて、すべてのストロークが厚みを持つならば OCR のような技術によつてふらどりを行ない、後で中ぬりをする算法の方が有効かもしれないが、ストロークにより厚みがないものが存在するとの論理が複雑になり、上記の規則のようす方式が良いと思われる。 32×32 字體にあひてもすべての字(所持していける漢字)について行なう、下山けでは否いので、それほどには、きりしたことはない。また、正とえふらどりができるとしても、中ぬりの処理をハードウェアで行なうなければその算法が困難なためうまくいかない。

3. 字体編集システム

18×18 字體の設り修正や新たに漢字を追加する場合のために字体編集システムを作成した。このシステムでは図 10 のような格子状の座標を画面に用意し、使用者が图形を見ながら適当な修正が可能となるようにした。各ストロークは方向性を持つデータとして取扱つてため筆順の変更が可能になる。これによりデータ量は増加するが、他の適用分野(たとえば、電子計算機書道、計算機教育)にも有効なデータとなる。以下にシステムの命令を示す。




図 10

命令群

① Bottom

データ中の最後のストロークをカレント・ストロークにする。

② DEDelete

カレント・ストロークを消去する。

③ Edit <漢字符号>

字体編集モードにはいる。指定された漢字符号のデータがファイルから作業域に読み込まれる。

④ FILE

字体編集モードを終了し作業域の結果をファイルに書きこむ。

⑤ Input

字体入力モードにはいる。今後入力されたストロークはカレント・ストロークの後に順に挿入される。字体編集モードには空白行によるともどる。

⑥ Locate <ストローク>

指定されたストロークをカレント・ストロークにする。

⑦ Move

字体接続モードにはいる。今後既存のストロークを入力することにより、そのストロークをカレント・ストロークの後に続ける。筆順変更などに使用される。

⑧ Next

カレント・ストロークの次のストロークをカレント・ストロークにする。

⑨ Point <現在点> <変更点>

現在点はと、指定された点を始終点とするすべてのストロークにたりして、現在点から変更点への移動が行なわれる。

⑩ QUIT

字体編集モードを終了する。ただし作業域の結果はファイルに書きこまれない。

⑪ Replace <ストローク>

カレント・ストロークを消去し指定されたストロークをカレント・ストロークにする。指定されたストロークは既存のものでなくともよい。

⑫ Shift <水平移動量> <垂直移動量>

字体全体を指定された移動量に従って平行移動する。

図の点αは L4 又は 4L で書かす。又は
 ブラシへのストロークは 4L 9Q, 4L Q
 9, L 4 9Q, L 4 Q 9 のいずれかで書か
 す。このストロークには方向性を持たせ
 るために始点は始めに終点を後ろに書き、
 画面上には終点に矢印が書きられる。編集
 作業は現在ポイントアビレカレント・ス
 トロークと呼ばれるストロークを左側に
 行なわれる。カレント・ストロークは二重
 輝度によつて表示される。

⑬ TOP

データ中の最初のストロークをカレニストロークにする。

⑭ Up

カレニストロークの前のストロークをカレニストロークにする。

このような機能によって字体の編集は容易に行えますため、変換が100%にする必要はない。又、自分の好みの图形、地図マーク等を簡単に漢字符号として入力可能で、他の適用分野に亘りても広く利用が可能である。なお、このような座標指定による編集で多くのキャラクタ入力による編集も現在考慮中である。

4. おわりに

18×18字体において7000字を変換して実際に使用してみると、現状では1.2倍以下で使用されることが多くこの程度ではわざわざ編集しなくとも何ら問題は起きない。なお7000字のデータ量の平均は、各点及び動的文字を2バイトとし計算すると100バイト弱にある。32×32字体は実験的に1000字程度しか変換してみたのがあまかの傾向はつかめた。この2つの字体の実験によると世の中には存在する字体の何割かは同様の規則に従って変換する事が可能となるだとう。最初からベクター字体を設計するよりむしろこの変換によってかなりの労働が削減可能と思われる。既存の映像表示装置に漢字を表示することを簡単にすると思われる。

謝辞

漢字字体編集システムを作成していただいた東京サイエンティフィック、電子データ研究員の宇野栄氏、また議論に参加していただいた諸研究員の方々に感謝いたします。

参考文献

- [1] 荒井・桑原「実用の輸出がる漢字情報処理」 日経エレクトロニクス
pp. 76 ~ pp. 113 1978 12-11
- [2] 菅井「漢字入・出力装置開発の現状と展望」 コニカビュートビア
pp. 52 ~ pp. 60 1978. 9.
- [3] 菊池・蓮藤・首藤「漢字ディスプレイ技術」 日本語情報処理シンポジウム報告集
情報処理学会 pp. 220 ~ pp. 227 1978 7.17~20
- [4] IBM パンフレット「IBM 3250 映像表示システム」 NJG518-5083
- [5] IBM マニマリ「IBM 3277 display station Graphic Attachment」 G.I. GA33-3039
- [6] 国立国語研究所「現代雅語九十種の用語用字(2)」 精英出版