

# 关于限制性手写体汉字的一种识别方法

傅 彦\*

(电子科技大学计算机系 成都 610054)

**【摘要】** 成功地提出了关于限制性手写体汉字的一种识别方法,并在 486 DX/66 PC 机上进行了模拟实验,取得了一定的效果。对于经预处理后的手写体汉字,采用结构识别法、统计决策法和模糊数学法相结合的一种方法。另外,提出了对相似文字的识别方法。

**关键词** 特征点; 特征向量; 模糊关系

**中图分类号** TP391.4

由于我国汉字数目十分庞大,汉字种类极其繁多,汉字字型结构极其繁杂,汉字中存在着很多相似文字,加之人为书写汉字的随意性,到目前为止,尽管有关限制性手写体汉字识别方法取得了很大的进展,但仍然存在着许多尚需进行研究和解决的问题,为此,本文提出了一种识别方法

## 1 输入汉字的分离

汉字种类繁多,字体千姿百态,按其结构类型可分为:单字体、内外型、上下型、左右型。下面就经预处理后的汉字进行讨论。

将汉字根作为不可分割的原子,字根间的构造信息作为连结字根的运算符,汉字可用字根与结构信息组成的字符串来表示。由于运算符是二目运算,所以此字符串可用一个二叉树来表示

### 1.1 汉字的结构文法表示

由于一棵二叉树可以用一个文法来表示,因此,可以把一个复杂的模式用类似于语言的结构方法来描述,即用模式的句法结构表示法来描述。此时,模式是用一个句子的形式来表示。

定义一个不可分割的字根和单字体作为基元(原始模式),原子表示其中间元,连结字根间的关系为运算符,则一个汉字可用下面的结构文法来描述<sup>[1]</sup>

$$G = \langle V_N, V_T, P, S \rangle$$

其中  $V_N = \{ \langle \text{原子} \rangle, \langle \text{运算符} \rangle \}$

$V_T = \{ \langle \text{字根} \rangle, \langle \text{单字体} \rangle \}$

$S = \langle \text{汉字} \rangle$

$P = \{ \langle \text{汉字} \rangle ::= \langle \text{单字体} \rangle \mid \langle \text{原子} \rangle \langle \text{运算符} \rangle \langle \text{原子} \rangle$

$\langle \text{原子} \rangle ::= \langle \text{字根} \rangle \mid \langle \text{原子} \rangle \langle \text{运算符} \rangle \langle \text{原子} \rangle$

$\langle \text{运算符} \rangle ::= L-R \mid U-D \mid I-B \}$

$L-R$  为左右结构,  $U-D$  为上下结构,  $I-B$  为内外结构

① 1995年12月9日收稿,1996年9月3日修改定稿

\* 女 33岁 硕士 讲师

## 1.2 汉字结构在机器中的表示

由于汉字语法树是一棵二叉树,在计算机中,语法树中的任一结点可用三个域表示为:

Lchild	Data	Rchild
--------	------	--------

其中 Lchild 与 Rchild 分别表示节点与左右子节点的链接指针; Data 表示节点有子节点时,存放左右两个子节点间关系的运算符的编码,无节点时存放字根(或单字体)的编码

## 1.3 输入汉字的分离原则和分离测试

从汉字本身的结构特征,搜索汉字中的分割线依次是上下扫描、左右扫描、变方向扫描,为此,汉字的分离为:左右分割 上下分割 内外分割<sup>[2]</sup>。下面仅以内外分割为例

由于内外型汉字种类繁多,因此,在扫描时采用变换方向的扫描 即沿着从左向右移动,从上向下扫描。令  $X_1(i) = \sum_{j=1}^N f(i, j)$ , 求出  $i_1, i_2$ , 满足如下条件,使得

$$X_1(i_1) = \min_{d_1 \leq i \leq d_2} X_1(i) \quad X_1(i_2) = \min_{N-d_2 \leq i \leq N-d_1} X_1(i)$$

然后再沿着从上向下移动,从左向右扫描,令  $Y_1(j) = \sum_{i=i_1}^{i_2} f(i, j)$ , 此时如能找到  $j_1, j_2$ , 使得

$$Y_1(j_1) = \min_{d_1 \leq j \leq d_2} Y_1(j) = 0 \quad Y_1(j_2) = \min_{N-d_2 \leq j \leq N-d_1} Y_1(j) = 0$$

如  $j_1, j_2$  存在,则可判断为能进行内外分割,此时,  $i_1, i_2, j_1, j_2$  为其对应的分割线。

## 1.4 语法树的形成和汉字组装

汉字语法树是在字根分离和字根识别过程中建立的,字根的分离搜索出结构类型,而字根的识别得到字根的编码信息。由于汉字具有层次嵌套的形式,为此,在进行字根分离时,可采用递归手段。其分离结果可由二叉树表示,该二叉树的枝节点即为子模式的连结枢带,叶子为其子模式,将叶子通过枝节点连结起来,则为原模式。为此,其汉字组装就是遍历语法树,在设计时采用中序遍历。

## 2 标准模式的描述

标准模式实际上是在识别过程中所使用的样本,其建立是汉字识别中至关重要的一环。

对于任意一个字根,可按如下方式描述:用向量表示模式的各笔划的特征并存入计算机中,每一条笔划以其始点、终点、屈折点、交点来描述,同时给每一个特征点附加上方向。

设用向量  $R(k, M_k, N)$  表示具有  $M_k$  条笔划,每条笔划有  $N$  个等距离的特征点的候补分类  $k$  的等点近似模式为

$$R(k, M_k, N) = \{(r_{11}, r_{12}, \dots, r_{1N}), (r_{21}, r_{22}, \dots, r_{2N}), \dots, (r_{M_{k1}}, r_{M_{k2}}, \dots, r_{M_{kN}})\}$$

其中  $r_{mn} = (x_{mn}, y_{mn})$  表示第  $m$  条笔划的第  $n$  个笔点的  $x, y$  坐标。但以上表示有一个不足,对于笔划长度短的和长的,无法正确而准确的加以表达,为此进行如下修正

$$R(k, M_k, N_{M_k}) = \{(r_{11}, r_{12}, \dots, r_{1N_1}), (r_{21}, r_{22}, \dots, r_{2N_2}), \dots, (r_{M_{k1}}, r_{M_{k2}}, \dots, r_{M_{kN_{M_k}}})\}$$

其中  $r_{ij} = (r_{ij}, y_{ij}, a_{ij}, d_{ij}, h_{ij})$ ;  $x_{ij}, y_{ij}$  分别是向量  $r_{ij}$  的坐标位置;  $a_{ij}$  表示  $r_{ij}$  的几何学形状信息;  $d_{ij}$  表示  $r_{ij}$  的方向;  $h_{ij}$  表示  $r_{ij}$  的外围构造信息

## 3 标准字典的建立和分类

由于遍历语法树仅得到的一些编码信息,因此,须建立汉字点阵和编码相对应的汉字字典

一个标准字典可按如下方式建立:  $\{(\text{字根 } i, \text{特征向量 } i, \text{编码 } i)\}$

当识别字典很大时,为了减少字根的匹配次数,达到高效快速的识别,可采用聚类识别法对字典进行分类。聚类识别法大致分三类:合并聚类法、修正聚类法、模糊聚类法。根据模糊聚类法的基本思想<sup>[3]</sup>,首先建立  $X$  上的模糊相容关系阵  $R = (a_{ij})$ ,其中

$$a_{ji} = a_{ij} = \begin{cases} 1 & i = j \\ 1 - \frac{1}{\min(m_i, m_j)^*} \sum_{a=0}^{m_i} \left( \min_{c=0,1,\dots,m_j} \sum_{b=0}^a \frac{\|r_{ab} - r_{cb}\|}{\|r_{ab} + r_{cb}\|} \right) & i \neq j \end{cases}$$

从离散数学的观点,如要进行分类(划分),必须将  $R$  改造成模糊等价关系矩阵  $Q$ <sup>[4]</sup>。

根据定理,设  $X = \{\bar{R}_1, \bar{R}_2, \dots, \bar{R}_M\}$  是需要聚类的全体样本集,其中,  $\bar{R}_i$  对应于字根  $i$  的特征向量,如  $R$  是  $X$  集合上的模糊相容关系阵,则  $Q = R^{M-1}$  是一模糊等价关系阵。其次再根据规定的  $\lambda$  值,考察  $Q$  的截矩阵  $Q_\lambda$  的各元素,以此来作聚类。当  $\lambda$  值选得愈大 ( $0 < \lambda < 1$ ),分成的类别数愈多,当  $\lambda = 1$  时,各样本必会自成一类,而  $\lambda = 0$ ,所有样本则必会归成一类。为此可预先选定初值  $\lambda$ ,再根据得到的分类结果和希望数目调整  $\lambda$  使其符合要求。分类后的新字典建立如下:

{字根  $i$ , 特征向量  $R_i$ , 编码  $i$ , 链接指针}

## 4 输入模式描述

### 4.1 方向模式抽出

对于模式中的任一个黑点  $f(i, j) = 1$  ( $1 \leq i \leq M, 1 \leq j \leq N$ ),令  $r = (i, j)$ ,  $P_k(r)$  ( $k = 1, 2, \dots, 8$ ) 分别是黑点在其八个方向上的象素数(该方向上连续黑点的数目),八个方向的前进方向可由  $r_1 \sim r_8$  来反映,下面求  $P_k(r)$ 。

首先置  $P_k(r) = 0$ ,当  $f(r + r_k) = 0$  时,  $P_k(r) = P_k(r)$ ;当  $f(r + r_k) = 1$  时,  $P_k(r) = P_k(r) + 1$ ,反复此过程,直到遇到白点或边界点为止,此时  $P_k(r)$  为关于  $f(r)$  在  $1 \sim 8$  方向的象素数,此象素数可确定该黑点基于  $Q$  方向的几何学的距离  $d_k(r)$ ,即

$$\begin{cases} d_1(r) = \sqrt{2} (P_1(r) + P_5(r)) \\ d_2(r) = (P_2(r) + P_6(r)) \\ d_3(r) = \sqrt{2} (P_3(r) + P_7(r)) \\ d_4(r) = (P_4(r) + P_8(r)) \end{cases}$$

令  $d_k(r) = \max_{1 \leq m \leq 4} \{d_m(r)\}$ ,则可将原模式变成具有方向的模式,即令  $f(i, j) = k$ ,其中  $k$  是  $d_k(r)$  中的  $k$ 。

### 4.2 特征点的抽出

定义连结数  $N_{C4}$ <sup>[5]</sup>

$$N_{C4} = \begin{cases} 0 & \text{孤立点} \\ 1 & \text{端点(始,终点)} \\ 2 & \text{内点} \\ 3 & \text{三分枝点} \\ 4 & \text{四分枝点} \end{cases}$$

该  $N_{C4}$  可确定相应的特征点。但由此抽出的特征点并不能准确地反映输入模式,还需作如下改进。

设  $F = \{f_k\}$  ( $k = 1, 2, \dots, k$ ) 表示由上抽出的全部特征点集合,其中,  $f_k = (x_k, y_k, S_k, Q_k, \{C_k\}, H_k)$ 。  $x_k, y_k$  为特征点  $f_k$  的  $I, J$  坐标;  $S_k$  为  $f_k$  的种类(端点、分枝点、交点、抽样点、PSI分割点);  $Q_k$  为  $f_k$  的方向编码值;  $\{C_k\}$  为与  $f_k$  相连的特征点的番号集合;  $H_k$  为  $f_k$  的外围构造信息。则  $F = \{f_k\}$

为描述输入模式的特征,每个  $f_k$  都为多元向量,而  $F$  也可以看成是由多个特征点  $f_k$  组成的特征向量。

## 5 笔划的抽出

### 5.1 候补点的选择

由于特征点包括其位置、方向、几何学形状等诸种信息,为此,首先对笔划  $r_{mn}$ ,从  $f_1, f_2, \dots, f_k$  中找出凡与  $r_{mn}$  具有相同几何学形状信息点  $f_{k_1}, f_{k_2}, \dots, f_{k_i} (k_i < k)$ ; 然后,考虑其夹角  $\tau_{mn}$  和  $\alpha_{gl}$ , 其中  $\tau_{mn}$  为向量  $\overline{r_{mn}r_{mn+1}}$  与  $i$  轴所组成的角度,  $\alpha_{gl}$  为  $\overline{f_g f_j} (j \in \{C_g\}, g \in \{k_1, k_2, \dots, k_i\})$  与  $i$  轴成的角度中最小者,若  $|\tau_{mn} - \alpha_{gl}| < \theta_{mn}$  ( $\theta_{mn}$  为阈值), 则  $\overline{r_{mn}r_{mn+1}}$  与  $\overline{f_g f_j}$  是同方向, 此时将  $f_g$  作为其候补点, 设满足此条件的有  $i_j$  个, 设为  $f_d (d = i_1, i_2, \dots, i_j, i_j < k_i < k)$ ; 最后, 利用 Euclidian 距离求出  $D_d^{mn}$

$$D_d^{mn} = \| r_{mn} - f_d \| = \sqrt{(x_{mn} - x_d)^2 + (y_{mn} - y_d)^2} \quad (d = i_1, i_2, \dots, i_j)$$

将其结果进行排序  $D_1^{mn} \leq D_2^{mn} \leq \dots \leq D_{i_j}^{mn}$  ( $j = i_1$ ), 若  $i_j$  小于规定阈值  $L$ , 则  $f_{j_1}, f_{j_2}, \dots, f_{j_i}$  都是候补点, 否则,  $f_{j_1}, f_{j_2}, \dots, f_{j_L}$  为其对应的候补点

### 5.2 对应点的决定

设  $(r_{mn}, r_{mn+1})$  为笔点  $r_{mn}$  与  $r_{mn+1}$  形成的笔点对, 从  $r_{mn}$  朝  $r_{mn+1}$  作向量  $U_{mn} = (r_{mn+1} - r_{mn})$ , 如  $(r_{mn}, r_{mn+1})$  存在候补点对  $(f_{mn}^+, f_{mn+1}^-)$ , 此  $(f_{mn}^+, f_{mn+1}^-)$  满足如下条件: 首先  $f_{mn}^+, f_{mn+1}^-$  是众多笔点对中具有最短路径的笔点对; 其次,  $r_{mn+1} - r_{mn}$  与  $f_{mn+1}^- - f_{mn}^+$  的相似度  $r$  最大, 即满足  $r \geq \theta_k$ 。其  $r$  规定为

$$r(U_{mn}, Z_{mn}, l_{mn}) = \begin{cases} k(U_{mn}) \frac{(U_{mn}, Z_{mn})}{\|U_{mn}\| \|Z_{mn}\|} & \text{如 } 1 - \frac{l_{mn}}{\|Z_{mn}\|} \leq W \\ 0 & \text{否则} \end{cases}$$

其中  $Z_{mn} = f_{mn+1}^- - f_{mn}^+$ ,  $l_{mn}$  为  $f_{mn}^+$  与  $f_{mn+1}^-$  之间的文字线长度;  $k$  是关于  $U_{mn}$  的权函数;  $W$  是阈值

以下将从  $\overline{r_{mn-1}r_{mn}}$  与  $\overline{r_{mn}, r_{mn+1}}$  来考察  $r_{mn}$  的对应点:

1) 若  $f_{mn}^+ = f_{mn}^-$ , 则  $f_{mn} = f_{mn}^+ = f_{mn}^-$  作为  $r_{mn}$  的对应点;

2) 若  $f_{mn}^+ \neq f_{mn}^-$ , 则将  $(f_{mn}^-, f_{mn+1}^+)$  作为其新的对应点的候补点, 此时, 若  $f_{mn}^-$  和  $f_{mn+1}^+$  是相连的, 则抽出其文字线, 并求  $\overline{r_{mn-1}r_{mn}}$  和  $\overline{r_{mn}, r_{mn+1}}$  的相似度  $r_-, r_+$ 。若  $r_- = r_+$ , 则  $f_{mn} = f_{mn}^+ = f_{mn}^-$ ; 若  $r_- \geq r_{TH}$  (阈值),  $r_+ \geq r_+$ , 则表明  $\overline{r_{mn-1}r_{mn}}$  与  $\overline{f_{mn}^- f_{mn+1}^+}$  相接近, 此时选  $f_{mn}^-$  作为  $r_{mn}$  的对应点 ( $f_{mn}^+$  为  $r_{mn-1}$  的对应点)。若  $r_+ \geq r_{TH}$ ,  $r_- \geq r_-$ , 则表明  $\overline{r_{mn}, r_{mn+1}}$  与  $\overline{f_{mn}^+ f_{mn+1}^-}$  相接近, 此时选  $f_{mn}^+$  作为  $r_{mn}$  的对应点 ( $f_{mn}^-$  为  $r_{mn+1}$  的对应点)。

## 6 字根的识别

根据字典的构成方式, 可按如下方式进行: 1) 反复调用对应点决定子程序, 直到输入字根与字典中的某个字根比较, 其标准字根的全部笔点都能找到唯一对应点对, 并记下该字根的编号, 如  $i$ , 并记  $S = \{i\}$ ; 2) 取出字根  $i$  的连接指针  $j$ ; 3) 若  $j = \Lambda$ , 则转 5), 否则转 4); 4) 对字根  $j$  进行如同 1) 的匹配, 若匹配成功, 则将  $j$  加入  $S$  得  $S = \{i, \dots, j\}$ , 同时  $j \rightarrow i$ , 转 2), 否则将  $j$  的连接指针送  $j$ , 转

3); 5) 若无法确定对应点, 则打拒识标志结束, 否则转 6); 6) 若  $|S| = 1$ , 同时  $\sum_{m=1}^M \sum_{n=1}^M \| r_{mn} - f_{mn}^i \| \leq W$  (阈值), 则将字根  $i$  作为识别结果, 返回其对应编码, 否则打拒识标志结束。若  $|S| > 1$ , 记下使  $\sum_{m=1}^M \sum_{n=1}^M \| r_{mn} - f_{mn}^i \| \leq W$  的  $i$ , 转 7); 7) 若  $S = \Lambda$ , 则打拒识标志, 若  $|S| = 1$ , 则打出对应字根  $i$  作为识别结果, 否则对任意  $i, i' \in S$ , 考察它们所对应的标准字根,  $i$  和  $i'$  的标准模式为  $R(i, M, N)$ ,

$\dot{R}(i, M, N)$  ( $M \leq \dot{M}$ ), 先求出  $i$  和  $\dot{i}$  的  $C$ -笔划,  $P$ -笔划,  $N$ -笔划. 下面考察输入模式与分类  $i$  和  $\dot{i}$  之间的一致度问题

设分类  $i$  的  $P$ -、 $N$ -笔划的条数分别为  $n_p, n_N$ , 相对于输入模式的  $P$ -、 $N$ -笔划为  $e_p, e_N$ , 分类  $\dot{i}$  为  $n_{\dot{p}}, n_{\dot{N}}$ , 相对于输入模式的为  $e_{\dot{p}}, e_{\dot{N}}$ , 则与分类  $i, \dot{i}$  的一致度为

$$d(i) = e_p + (n_N - e_N) \quad d(\dot{i}) = e_{\dot{p}} + (n_{\dot{N}} - e_{\dot{N}})$$

若此时 1)  $d(i) = d(\dot{i})$ , 则转 8); 2)  $d(i) > d(\dot{i})$ , 则输入模式为分类  $i$ ; 3)  $d(i) < d(\dot{i})$ , 则输入模式为分类  $\dot{i}$ .

8) 考察  $d(U_{mn}, U_{m'n'}) = \sum_{i=0}^1 \|r_{m+i} - r_{m'+i}\|$ , 若  $H_{mn} = H_{m'n'}$ , 则定义  $T(U_{mn}, U_{m'n'})$  为上式的值并返回 7); 否则规定  $d(U_{mn}, U_{m'n'}) = * (\infty)$ , 并打出拒识标志. 7)、8) 可对相似文字进行识别, 如 7) 可对“目”和“日”识别, 8) 可对“甲”和“由”识别

## 7 识别试验及考察

应用 LISP 语言在 486DX /66 机上进行模拟试验, 对手工输入的经预处理后的 300 多个汉字字根, 建立相应的字典. 在字典中, 若不进行分类, 则识别速度和结果准确率都有不同程度的增加和下降. 对于相似文字, 如“土”和“士”, 通过附加上反映字根的第二特征, 即笔划间的位置关系及外围构造信息, 即可得到正确的识别结果. 对如“日”和“目”等的相似字根, 对“目”, 在识别时, “日”与“目”的一切笔划都被抽出, 同时,  $d$  也满足小于规定的阈值, 此时可根据一致度来进一步判断, 以提高识别率. 另外, 对不存在与其大致相似的另外字根的字根, 则在字根集中只能找到唯一的候补模式.

字根集的分类可提高识别速度, 分类中建立模糊相容矩阵, 由此求模糊等价矩阵, 同时进行截值为“ $\lambda$ ”的聚类. “ $\lambda$ ”值是从 1 到 0 (步长为 -0.01), 当  $\lambda = 1$  时各字根自成一类,  $\lambda = 0$  时全部字根成一类,  $\lambda$  值的最终确定是由分类的数目或分类中元素数目的多少而确定.

### 参 考 文 献

- 1 陈尚勤. 模式识别理论及应用. 成都: 成都电讯工程学院出版社, 1985
- 2 Fujimura O. Structural patterns of chinese characters. New York: 1984
- 3 陈胎源. 模糊数学. 武昌: 华中工学院出版社, 1984
- 4 Quda R O, Hart P E. Decision in pattern recognition. Washington D C, 1987
- 5 Fu K S. Pattern recognition theory and application. New york: 1990

## A Recognition Method Based Limited-handwritten Chinese Character

Fu Yan

(Dept. of Computers, UEST of China Chengdu 610054)

**Abstract** A microcomputer-based limited-handwritten chinese character recognition method is proposed in this paper. The simulation test is built on the basis of a 486 DX /66 microcomputer. The method is to be put into effort. The proposed algorithms for preprocessing of limited-handwritten chinese character is a method combining structural pattern recognition and statistical pattern recognition and fuzzy mathematics. A recognition method about analog chinese character is proposed in this paper.

**Key words** characteristic point; characteristic vector; fuzzy relation

编辑 徐培红