

EXTRAÇÃO DE CARACTERÍSTICAS PARA PALAVRAS MANUSCRITAS BASEADA EM CONCEITOS DA TEORIA DE CONJUNTOS FUZZY

N. R. Gomes¹, L. L. Lee

Departamento de Comunicações
Faculdade de Engenharia Elétrica e Computação - UNICAMP
Campinas, São Paulo - 130870, Brasil

ABSTRACT

Este artigo apresenta um método para extração de características de palavras manuscritas com base na teoria de conjuntos *fuzzy*. Nesse método, após efetuados os processos de segmentação e de extração de características, uma palavra manuscrita é representada por uma seqüência ordenada de segmentos de linha. Para cada um desses segmentos são calculados valores de pertinência a conjuntos *fuzzy* representando diferentes tipos de segmentos de linha curva e de linha reta. A posição dos segmentos de linha em uma letra ou em parte de uma letra resultante do processo de segmentação da palavra é também avaliada por meio de conjuntos *fuzzy*. Os Modelos Ocultos de Markov *Fuzzy* são empregados para classificar as palavras manuscritas. Uma base de dados composta por palavras manuscritas extraídas de cheques é utilizada para testar o sistema de reconhecimento de palavras.

1. INTRODUÇÃO

Muitos pesquisadores têm tratado o problema de reconhecimento de manuscritos impondo restrições ao vocabulário e/ou a quantidade de variações de estilos de escrita, e aumentando o número de amostras de palavras para treinamento do sistema [6][11]. Por exemplo, treinando um sistema de reconhecimento com um número grande de amostras para um número reduzido de variações de estilos de escrita pode-se melhorar significativamente o desempenho do sistema. No entanto, alguns sistemas de reconhecimento processam uma grande variedade de estilos de escrita, tornando difícil o armazenamento de uma quantidade adequada de amostras de treinamento capaz de cobrir essa variedade de estilos. Uma possível solução apresentada na literatura, é a extração de características que possam representar adequadamente palavras manuscritas, apesar da variabilidade de estilos. O objetivo deste artigo é propor um método para extrair características que sejam menos susceptíveis a variação de estilos de escrita utilizando a teoria de conjuntos *fuzzy*. Como um resultado, tal abordagem deve permitir treinar um sistema de reconhecimento com um número reduzido de amostras.

Este artigo está organizado da seguinte forma: Na seção 2 é apresentada uma visão geral do sistema desenvolvido; Na seção 3 é explicado o pré-processamento e o algoritmo de segmentação de palavras manuscritas; A seção 4 é dedicada a extração de características e aos vetores de características. Na

seção 5 é apresentado nosso procedimento de classificação. Finalizando, na seção 6 é mostrado alguns resultados experimentais e as comentários finais a respeito do trabalho desenvolvido.

2. VISÃO GERAL DO SISTEMA

A idéia básica em nosso sistema de reconhecimento diz respeito a transformação de uma palavra manuscrita em uma seqüência ordenada de linhas curvas, linhas retas e *loops* a fim de reduzir a variação de estilos de escrita. O sistema de reconhecimento proposto é composto de duas fases: uma fase de treinamento e uma fase de reconhecimento. Tanto na fase de treinamento como na fase de reconhecimento a imagem de uma palavra manuscrita é pré-processada, segmentada e suas características são extraídas. Os procedimentos incluídos no pré-processamento são bem conhecidos na literatura, nominalmente, suavização, rotação e correção de inclinação [3]. Após o pré-processamento a imagem de uma palavra é segmentada em caracteres. O resultado final dessa operação são letras e/ou partes de letras, ambas denominadas genericamente neste artigo como segmentos da palavra. No procedimento de extração de características cada segmento da palavra é decomposto em segmentos de linha, para os quais são calculados valores de pertinência a conjuntos *fuzzy* representando diferentes tipos de segmentos de linha curva e de linha reta. Dessa forma, é possível representar uma palavra como uma seqüência ordenada de linhas, sendo que cada uma dessas linhas apresenta um valor específico de pertinência a cada conjunto *fuzzy*. A referida seqüência é processada durante o procedimento de classificação por Modelos Ocultos de Markov *Fuzzy* (FHMMs) [11]. A palavra a ser reconhecida é classificada na classe de palavras que apresentar o maior valor de similaridade conforme um algoritmo de Viterbi *Fuzzy* [11].

3. PRÉ-PROCESSAMENTO

Neste trabalho as operações de pré-processamento visam a correção de rotação e correção de inclinação de palavras manuscritas. Antes e após efetuar essas correções, as imagens de palavras manuscritas sofrem um processo de suavização com objetivo de reduzir ruídos [3][7]. O algoritmo de correção de rotação faz uso do ângulo ϕ entre a linha de base da palavra e o eixo horizontal como é ilustrado na Figura 1. O ângulo ϕ é usado para normalizar a linha de base da palavra, fazendo-a paralela ao eixo horizontal. O algoritmo desenvolvido [7] para

¹ Pesquisa realizada com suporte financeiro da FAPESP.

correção de inclinação de palavras manuscritas é uma combinação de dois métodos descritos na literatura [3][4]. Esse algoritmo visa determinar os traços da palavra manuscrita que mais têm influência em sua inclinação, e que possibilitam o cálculo do ângulo médio de inclinação. Tais traços são identificados através do método apresentado em [4], o qual elimina os traços horizontais mais longos da palavra manuscrita bem como os traços verticais de menor comprimento. O resultado dessa operação é a permanência dos traços verticais que mais influenciam a inclinação de palavra. Esses traços verticais são usados no método descrito em [3] para calcular o ângulo α via um histograma de ângulos. O ângulo de maior ocorrência no histograma é usado para corrigir a inclinação da palavra. A Figura 2 mostra um exemplo de correção de inclinação para a palavra manuscrita *dez*.



Figura 1. Amostra de uma palavra *dez*. (a) Palavra rotacionada; (b) Palavra após correção de rotação.

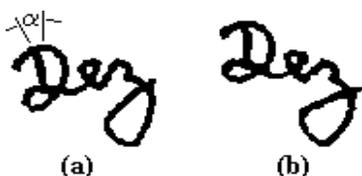


Figura 2. Amostra de uma palavra *dez*. (a) Palavra inclinada para esquerda; (b) Palavra após correção de inclinação.

3.1 Segmentação de Palavras Manuscritas

A segmentação de palavras manuscritas em caracteres [2], neste trabalho, é baseada na morfologia matemática [5].

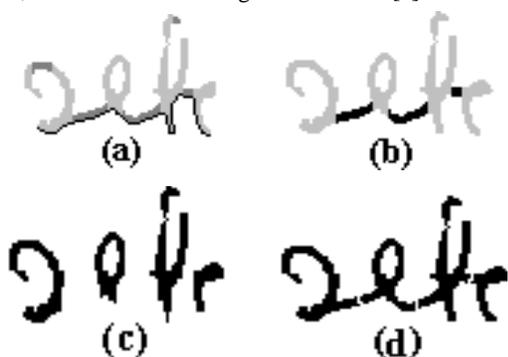


Figura 3. Amostra de uma palavra *sete*: (a) Contorno inferior; (b) Conexões pertencentes ao contorno inferior; (c) Eliminação das conexões; (d) Palavra segmentada após redução dos espaços entre caracteres ilustrados na Figura 5.(c).

Basicamente, aplicou-se o operador morfológico de abertura binária [5] com o objetivo de determinar as conexões entre letras em uma palavra. Esse operador quando empregando um elemento estruturante [6] adequado é capaz de eliminar as conexões entre letras de uma palavra e também os traços de menor espessura na palavra. São considerados como conexões os traços ligando dois caracteres em uma palavra [6] e pertencentes ao contorno inferior da palavra [7] como é apresentado na Figura 3(a). As operações envolvidas em nosso procedimento de segmentação podem ser melhor entendidas observando a Figura 3.

4. EXTRAÇÃO DE CARACTERÍSTICAS

O método de extração de características proposto por este artigo foi desenvolvido com base na idéia de que é possível reconhecer uma letra através da observação da posição e do tipo dos segmentos de linha que a compõem [7]. Por conseguinte, os segmentos de uma palavra manuscrita, isto é, letras e/ou partes de letras resultantes da segmentação da palavra em caracteres, são analisados de cima para baixo com o propósito de situar seus segmentos de linha em seu (1) topo, (2) meio ou (3) base. Do mesmo modo, analisando o segmento de uma palavra da esquerda para a direita pode-se situar seus segmentos de linha a sua (4) esquerda, (5) centro ou (6) direita. Como a posição dos segmentos de linha em uma letra manuscrita varia conforme os diferentes estilos de escrita, foi utilizado o conceito de conjuntos *fuzzy* [7], para determinar a pertinência desses segmentos a cada uma das seis posições previamente descritas. Para aplicar tal procedimento é necessário identificar em cada segmento da palavra os segmentos de linha que o compõem, os quais foram denominados ramos. Os ramos são identificados através do assinalamento de pontos com características especiais de vizinhança nos segmentos da palavra manuscrita [7][8]: (1) ponto final, possui um único ponto como vizinho; (2) ponto de interseção, possui no mínimo 3 outros pontos como vizinhos; (3) ponto de inflexão, possui 2 pontos como vizinhos e onde ocorre uma mudança abrupta de direção no contorno do segmento da palavra. A Figura 4 ilustra esses pontos assinalados em uma letra "o" manuscrita.

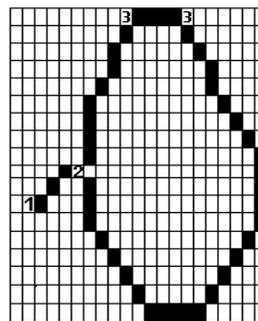


Figura 4. Pontos assinalados em uma letra "o": (1) Pontos finais; (2) Pontos de interseção; (3) Pontos de inflexão.

A pertinência de um ramo a cada uma das seis posições relativas anteriormente enumeradas é gerada a partir de uma

relação entre a quantidade de pontos em um ramo e a quantidade de pontos em seu segmento da palavra. Por exemplo, o valor de pertinência de um ramo à esquerda (*pre*), direita (*prd*) ou centro (*prc*) de seu segmento da palavra é expresso por:

$$pre = \frac{npsd}{npsd + npse}; \quad prd = \frac{npse}{npsd + npse}; \quad prc = 1 - \frac{|npsd - npse|}{npsd + npse}$$

Onde, *npse* (*npsd*) é o número de pontos do segmento da palavra à esquerda (direita) do ramo considerado. O mesmo procedimento é adotado para pertinência de um ramo em relação ao topo (*prt*), base (*prb*) e meio (*prm*) do seu segmento da palavra.

O método de extração de características também permite caracterizar uma letra ou uma palavra através dos diferentes tipos de ramos que a compõem. O principal problema em tal caracterização está nas variações causadas pelos diferentes estilos de escrita. A fim de reduzir essas variações e extrair características menos susceptíveis ao estilo de escrita, também foi empregada a teoria de conjuntos *fuzzy*. A principal idéia é usar a teoria de conjuntos *fuzzy* para representar determinados padrões de segmentos de linha ilustrados na Figura 5. Nessa Figura é adotada a seguinte convenção: (V) linhas verticais; (P) linhas com inclinação positiva; (N) linhas com inclinação negativa; (C) curvas tipo C; (D) curvas tipo D; (A) curvas tipo A; (U) curvas tipos U; (S) curvas tipo S; (Z) curvas tipo Z. Também são empregados como característica os *loops* (L) que ocorrem em letras de uma palavra manuscrita. Tal característica não é representada por um conjunto *fuzzy*. Somente segmentos de linha formando uma circunferência fechada são considerados como sendo *loops* (valor de pertinência igual a 1).

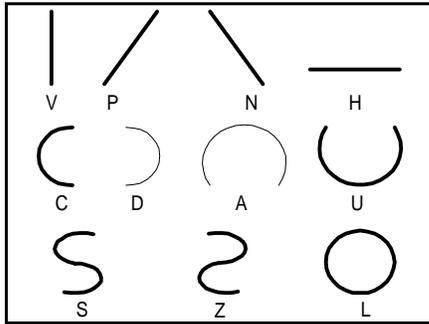


Figura 5. Padrões a serem representados por conjuntos *fuzzy*.

4.1 Classificação do Tipo de Ramo

A classificação de um ramo conforme Figura 5 baseia-se inicialmente em sua similaridade a uma linha reta e a uma linha curva. O método dos mínimos quadrados [8] é empregado para estimar o segmento de linha reta que mais se assemelha ao ramo. A distância entre o ramo e a reta estimada é adotada como uma medida da similaridade entre ambos. Em outras palavras, quanto mais próximos os pontos do ramo estão do segmento de linha reta, maior é a similaridade entre ramo e segmento de linha reta. Uma vez que tal avaliação de similaridade é subjetiva

[7], adotou-se a função de pertinência $f(\cdot)$ ilustrada na Figura 6 para estimar a medida de similaridade

$$G_r = \min \left\{ \frac{1}{N} \sum_{i=1}^N f(d_y(i)), \frac{1}{N} \sum_{i=1}^N f(d_x(i)) \right\}, \text{ onde } d_y(i) \text{ e}$$

$d_x(i)$ são distâncias entre o i -ésimo ponto do ramo e o i -ésimo ponto da linha considerando, respectivamente, o eixo vertical y e o eixo horizontal x de um sistema Cartesiano; N denota o número total de pontos do ramo. A medida de similaridade (G_c) entre uma linha curva e um ramo pode ser determinada fazendo $G_c = 1 - G_r$.

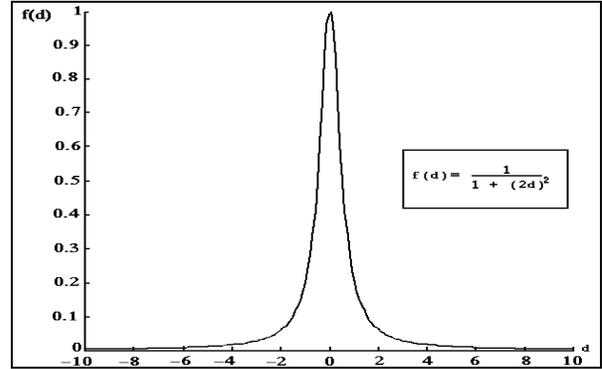


Figure 6. Função de pertinência para avaliar similaridade entre ramo e segmento de reta estimado.

Quando um ramo é avaliado como sendo um segmento de linha reta são observados os seguintes valores para o ângulo θ : 0° , 45° , 90° , 135° , 180° , 225° e 315° graus. Onde θ é o ângulo de inclinação do segmento de reta estimado para o ramo sendo analisado. Define-se então, respectivamente, as pertinências $H(\theta)$, $V(\theta)$, $P(\theta)$ e $N(\theta)$ de um ramo a um segmento de linha reta: horizontal, vertical, com inclinação positiva, com inclinação negativa.

$$H(\theta) = G_r \cdot \{1 - \min\{\min[|\theta|, |180 - \theta|], |360 - \theta|]/45, 1\}\}$$

$$V(\theta) = G_r \cdot \{1 - \min\{\min[|90 - \theta|, |270 - \theta|]/45, 1\}\}$$

$$P(\theta) = G_r \cdot \{1 - \min\{\min[|45 - \theta|, |225 - \theta|]/45, 1\}\}$$

$$N(\theta) = G_r \cdot \{1 - \min\{\min[|135 - \theta|, |315 - \theta|]/45, 1\}\}$$

De modo semelhante, um ramo pode ser avaliado de acordo com sua similaridade aos vários tipos de linha curva ilustrados na Figura 5, nominalmente, curvas tipo: C, D, A, U, S ou Z. A classificação de um ramo como sendo uma linha curva requer a determinação do ângulo θ . Esse ângulo correspondente a inclinação do segmento de linha (LN) conectando os pontos finais de um ramo como exemplifica a Figura 7. Baseando-se na inclinação de LN as funções de pertinência $HC(\theta)$ e $VC(\theta)$ são definidas e usadas para obter, respectivamente, a similaridade de um ramo a curvas horizontais e curvas verticais:

$$HC(\theta) = G_c \cdot \left\{ 1 - \min \left[\left| \frac{\theta}{180 - \theta} \right|, \left| \frac{360 - \theta}{180 - \theta} \right|, 1 \right] \right\}$$

$$VC(\theta) = G_c \cdot \left\{ 1 - \min \left[\left| \frac{90 - \theta}{270 - \theta} \right|, \left| \frac{270 - \theta}{90 - \theta} \right|, 1 \right] \right\}$$

Analisando a posição dos pontos de um ramo em relação ao segmento de linha LN de forma similar aquela usada para determinação da pertinência de um ramo à posição direita, esquerda ou centro do segmento da palavra, e fazendo uso das pertinências $HC(\theta)$ e $VC(\theta)$ são definidas as novas pertinências de um ramo a:

Curva tipo C, é uma curva vertical com pertinência (prd_{LN}) em relação ao lado direito de LN : $C(\theta) = VC(\theta) \cdot prd_{LN}$

Curva tipo D, é uma curva vertical com pertinência (pre_{LN}) em relação ao lado esquerdo de LN : $D(\theta) = VC(\theta) \cdot pre_{LN}$

Curva tipo S ou Z, nesse caso o ramo é analisado como uma curva vertical apresentando como característica quantidades semelhantes de pontos em ambos os lados de LN . Tal característica pode ser empregada para estimar um valor de pertinência (prc_{LN}) à região em que estão distribuídos os pontos em relação a LN : $S_v(\theta) = VC(\theta) \cdot prc_{LN}$ ou $Z_v(\theta) = VC(\theta) \cdot prc_{LN}$

Curva tipo A, curva horizontal com pertinência (prt_{LN}) em relação ao topo da linha LN : $A(\theta) = HC(\theta) \cdot prt_{LN}$

Curva tipo U, refere-se a uma curva horizontal com pertinência (prb_{LN}) em relação a base de LN : $U(\theta) = HC(\theta) \cdot prb_{LN}$

Curva S ou Z, nesse caso o ramo é analisado como sendo uma curva horizontal possuindo aproximadamente a mesma quantidade de pontos em ambos os lados de LN . Usando tal quantidade é calculada uma pertinência (prm_{LN}) à região em que estão distribuídos os pontos em relação a LN : $S_H(\theta) = HC(\theta) \cdot prm_{LN}$ ou $Z_H(\theta) = VC(\theta) \cdot prm_{LN}$.

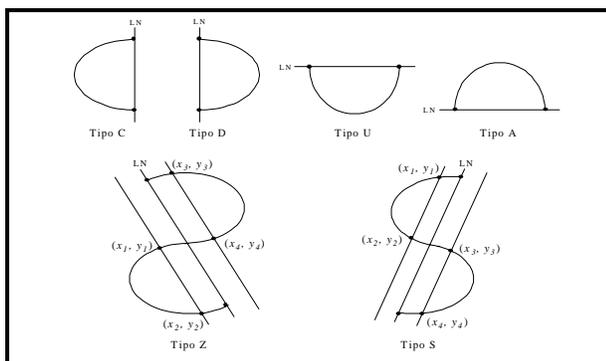


Figura 7. Segmentos de linha curva e suas posições relativas ao segmento de reta LN .

Para decidir entre uma curva S ou Z foi empregado o método sugerido por [9], o qual executa os seguintes testes: S_v se $\min(y_1, y_2) < \max(y_3, y_4)$; S_H se $\max(x_1, x_2) > \max(x_3, x_4)$; Z_v quando $\max(y_1, y_2) > \min(y_3, y_4)$; Z_H quando $\min(x_1, x_2) < \max(x_3, x_4)$.

4.2 Construção do Vetor de Características para um Ramo

Uma vez obtido o conjunto de valores de pertinências definido na seção anterior, pode-se construir o vetor de características requerido pelo processo de classificação. Note que o conjunto de características empregado contém informações sobre as pertinências do ramo a posições relativas ao segmento da palavra, isto é: (1)topo, (2)meio e (3)base, (4) esquerda, (5) centro e direita do segmento da palavra. Como resultado de uma multiplicação entre essas pertinências são geradas 9 novas pertinências: (1) topo-esquerda, (2)topo-centro, (3) topo-direita, (4) meio-esquerda, (5) meio-centro, (6) meio-direita, (7) base-esquerda, (8) base centro e (9) base direita. De modo similar, uma combinação entre cada pertinência relativa aos tipos de ramos ($V(\theta)$, $P(\theta)$, $N(\theta)$, $H(\theta)$, $C(\theta)$, $D(\theta)$, $A(\theta)$, $U(\theta)$, $S(\theta)$, $Z(\theta)$, (L)) e as 9 pertinências relativas a posição do ramo (topo-esquerda, topo-centro, topo-direita, meio-esquerda, meio-centro, meio-direita, base-esquerda, base-centro e base-direita) geram 99 características distintas, as quais são utilizadas como vetor de características para um ramo.

A fim de ilustrar o procedimento observe o segmento de uma palavra representado pela letra E na Figura 8. As Tabelas 1 e 2 listam os valores de pertinência para os 3 ramos da referida letra.

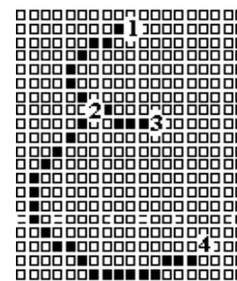


Figura 8. Letra E com seus ramos identificados

Tabela 1. Valores de pertinências relacionados as posições dos ramos no segmento de uma palavra.

Pertinências	Nós		
	1-2	2-4	2-3
Esquerda (pre)	0,48	0,84	0,58
Centro (prc)	0,96	0,32	0
Direita (prd)	0,52	0,16	0,23
Topo (prt)	1,0	0,69	0
Meio (prm)	0	0,63	0
Base (prb)	0	0,31	1,0

Tabela 2. Funções de pertinência relacionadas a cada tipo de ramo.

Função	Nós			Função	Nós		
	1-2	2-4	2-3		1-2	2-4	2-3
$H(\theta)$	0,2	0,45	0,71	$A(\theta)$	0,37	0	0
$V(\theta)$	0	0	0	$U(\theta)$	0	0,47	0
$P(\theta)$	0,82	0	0	$S(\theta)$	0	0	0
$N(\theta)$	0	0,55	0,29	$Z(\theta)$	0	0	0
$C(\theta)$	0,62	0,53	0	L	0	0	0
$D(\theta)$	0	0	0		-	-	-

5. CLASSIFICAÇÃO VIA HMM FUZZY

O resultado final do processo de extração de características para uma palavra é uma seqüência ordenada de vetores de características. Cada vetor representa um ramo analisado na palavra manuscrita. Cada elemento desses vetores representa um valor de pertinência a um dos segmentos de linha ilustrados na Figura 5, observada sua posição no segmento da palavra manuscrita. Os vetores de características de uma palavra são transformados em uma seqüência de símbolos de observações por meio de uma quantização vetorial [10][12]. A seqüência de símbolos de observações para uma palavra manuscrita é processada por Modelos Ocultos de Markov Fuzzy (FHMMs) [7][11]. A vantagem relacionada ao uso de FHMMs neste trabalho diz respeito a natureza das medidas empregadas para gerar os vetores de características, isto é, medidas *fuzzy*. Devido ao sistema de reconhecimento desenvolvido processar palavras escritas com letras maiúsculas, minúsculas ou ambos formatos, optou-se por modelar cada letra do vocabulário empregado. O número de estados dos FHMMs para uma determinada letra é o número médio de ramos apresentado em amostras dessa letra. A Figura 9 mostra um modelo para a letra "a", onde o último estado é um ponto de conexão para um outro modelo de letra.

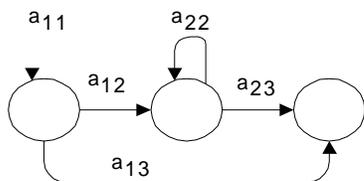


Figura 9. FHMM para a letra "a".

Observada a Figura 9, é importante mencionar que foram permitidos saltos entre estados a fim de prevenir situações onde o número de estados do FHMM é maior do que o número de símbolos de observações. Isso pode acontecer em razão da variação de estilos ou problemas de segmentação. Um outro problema diz respeito a uma palavra poder ser escrita com letras maiúsculas, minúsculas ou ambos formatos. Para solucionar esse problema, foi empregada uma topologia paralela para o FHMM [7][12][13] conforme é ilustrado na Figura 10. Cada palavra do vocabulário é modelada por um FHMM construído através de uma adequada concatenação dos modelos para letras. A

seqüência de observações é assinalada ao modelo de palavra que apresentar o maior de similaridade conforme um algoritmo de Viterbi *Fuzzy* [11].

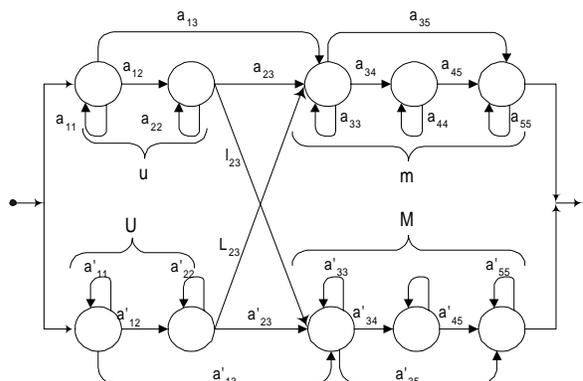


Figura 10. FHMM para a palavra *um*.

Alguns procedimentos de pós-processamento são usados durante o procedimento de classificação. O pós-processamento executa uma avaliação do número e posição dos segmentos ascendentes e descendentes [3] em uma palavra com o objetivo de melhorar o desempenho do sistema de reconhecimento.

6. RESULTADOS EXPERIMENTAIS

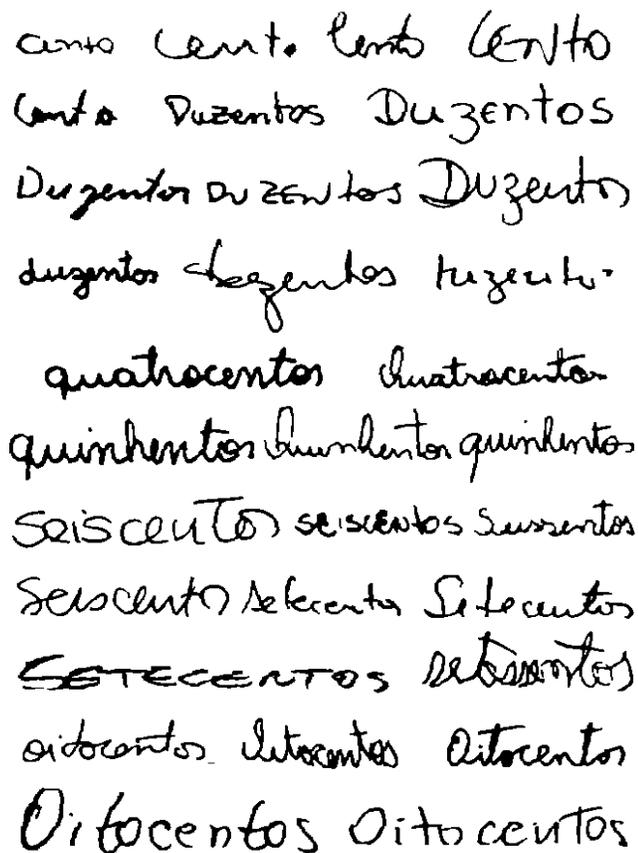
Nossa base de dados consiste de 2416 imagens de palavras manuscritas escritas por cerca de 90 pessoas. As palavras foram extraídas de cheques brasileiros e apresentam uma grande variedade de estilos. Foi adotado o procedimento de validação cruzada [7][10] para treinar e testar o sistema. Em outras palavras, a base de dados foi dividida em 10 grupos distintos, cada grupo contendo amostras de todas as palavras no vocabulário empregado. O sistema foi então treinado com 9 grupos e teve seu desempenho testado com o grupo restante. Esse procedimento é empregado para cada uma das 10 possíveis escolhas de grupo para teste, sendo o desempenho final uma média de todos os 10 resultados obtidos [7]. O desempenho geral do sistema e os resultados parciais de cada grupo considerando as N melhores posições são apresentadas na Tabela 3.

Tabela 3. Resultados experimentais de reconhecimento

Grupo	Taxa de Acertos de Reconhecimento (%)		
	N=1	N=5	N=10
1	51	82	95
2	50	85	93
3	47	83	95
4	53	85	96
5	51	83	93
6	52	80	92
7	51	83	97
8	44	78	93
9	50	82	92
10	47	81	93
Média do Sistema	50	82	94

6.1 Comentários Finais

Neste artigo foi proposto um método baseado na teoria de conjuntos *fuzzy* visando a redução da variação intra-classe causada pelos diferentes estilos de escrita. Reduzindo a variação relacionada ao estilo de escrita busca-se reduzir o número de amostras requeridas para treinamento do sistema. Ao mesmo tempo, espera-se alcançar um resultado razoável de reconhecimento. Na Tabela 3 são mostrados os resultados atingidos com o método proposto, considerando que a correta classe para uma palavra sendo reconhecida se encontre entre as N classes de maior valor de similaridade. Note que o sistema desenvolvido não impôs restrições aos tipos de palavras manuscritas sendo reconhecidas (e.g., palavras escritas somente com letras minúsculas) e também não empregou informações contextuais a fim de melhorar a taxa de reconhecimento [1][9]. Além disso, as palavras que compõem o vocabulário usado são bastante semelhantes (e.g., sessenta e seiscentos) fazendo que o processo de reconhecimento seja não trivial. Acreditamos que os resultados alcançados sejam satisfatórios (50% para $N=1$, 82% para $N=5$, 94% para $N=10$) e que o sistema pode ser melhorado com o uso de métodos capazes de selecionar as características empregadas. Esses métodos permitirão uma redução do espaço de característica e por conseguinte uma menor dimensão do vetor de características. A Figura 11 apresenta uma amostra das palavras que compõem nosso banco de dados.



cento cento cento cento
cento duzentos duzentos
duzentos duzentos duzentos
duzentos trezentos trezentos
quatrocentos quatrocentos
quinhentos quinhentos quinhentos
seiscentos seiscentos seiscentos
seiscentos setecentos setecentos
setecentos setecentos
oitocentos oitocentos oitocentos
Oitocentos Oitocentos

Figura 11: Amostra de palavras manuscritas.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] A. Kundu, Y. He, P. Bahl. "Word Recognition and Word Hypothesis Generation for Handwritten Script : A Hidden Markov Model Based Approach". *IEEE Proc. Conf. Computer Vision and Pattern Recognition*, pp. 457-462, 1988.
- [2] Richard G. Casey and Eric Licolinet. "A Survey of Methods and Strategies in Character Segmentation". *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 18, nº 7, pp. 690-706, Jul. 1996.
- [3] D. Guillevic, *Unconstrained Handwritten Recognition Applied to the Processing of Bank Checks*. Tese de Doutorado, Concordia University, Montreal, Quebec, Canada, 1995.
- [4] Radmilo M. Bozinovic and Sargur N. Srihari. "Off-line Cursive Script Word Recognition". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 11, nº 1, pp. 68-83, Jan. 1992.
- [5] J. Serra. *Image Analysis and Mathematical Morphology*. Academic Press Inc., London, England, 1982.
- [6] M. Chen, *Handwritten Word Recognition Using Hidden Markov Models*. Tese de Doutorado, University of New York at Buffalo, USA, 1995.
- [7] N. R. Gomes. *Reconhecimento de Palavras Manuscritas Baseado em HMM e no Emprego de Características Topológicas e Geométricas*. Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, UNICAMP, Ago., 2001.
- [8] G. Baptista e K. M. Kulkarni "A High Accuracy Algorithm for Recognition of Handwritten Numerals". *Pattern Recognition*, Vol. 21, nº 4, pp. 287-291, 1988.
- [9] P. Siy e C. S. Chen. "Fuzzy Logic for Handwritten Numeral Character Recognition". *IEEE Transactions on Systems, Man, and Cybernetics*, Nov., 1974.
- [10] K. Fukunaga. *Introduction to Statistical Pattern Recognition*. Academic Press, 1990.
- [11] M. A. Mohamed. *Handwritten Word Recognition Using Generalized Hidden Markov Models*. Tese de Doutorado, Faculty of the Graduate School University of Missouri-Columbia, Mai., 1995.
- [12] L. R. Rabiner, "A Tutorial on Hidden Markov Models and Selected Applications in Speech". *Proceedings of IEEE*, Vol.77, no 2, Fev., 1989.
- [13] A. El-Yacoubi, M. Gilloux, R. Sabourin, C. Y. Suen. "An HMM-Based Approach for Off-Line Unconstrained Handwritten Word Modeling and Recognition". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 21, nº 8, pp. 752-760, Ago., 1999.